

TOBB EKONOMİ VE TEKNOLOJİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**OBSTRÜKTİF UYKU APNESİNİN DERİN ÖĞRENME KULLANILARAK
TAHMİN EDİLMESİ**



DOKTORA TEZİ

Hüseyin NASİFOĞLU

Biyomedikal Mühendisliği Anabilim Dalı

Tez Danışmanı: Prof. Dr. Osman EROĞUL

MAYIS 2022

TEZ BİLDİRİMİ

Tez içindeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edilerek sunulduğunu, alıntı yapılan kaynaklara eksiksiz atıf yapıldığını, referansların tam olarak belirtildiğini ve ayrıca bu tezin TOBB ETÜ Fen Bilimleri Enstitüsü tez yazım kurallarına uygun olarak hazırlandığını bildiririm.



Hüseyin NASIFOĞLU

ÖZET

Doktora Tezi

OBSTRÜKTİF UYKU APNESİNİN DERİN ÖĞRENME KULLANILARAK

TAHMİN EDİLMESİ

Hüseyin NASIFOĞLU

TOBB Ekonomi ve Teknoloji Üniversitesi
Fen Bilimleri Enstitüsü
Biyomedikal Mühendisliği Anabilim Dalı

Danışman: Prof. Dr. Osman EROĞUL

Tarih: Mayıs 2022

Nefes alışverişinin en az on saniye boyunca durması olarak tanımlanan uyku apnesi, günümüzde sık karşılaşılan bir uyku hastalığı olarak bilinmektedir. Obstrüktif uyku apnesi (OUA), solunum yolunda tıkanmaya bağlı gerçekleşen en yaygın uyku hastalıklarından biridir. Bu sendromun geliştirilen modeller yardımıyla otomatik olarak tespit edilebilmesinin yanında ön görülebilmesi de ciddi seviyelerde sağlık problemlerini ve hayati tehlikeyle karşı karşıya kalma durumunu önlemek açısından önemlidir. Yüksek doğrulukla çalışan tahmin modellerinin geliştirilmesi ile OUA rahatsızlığı yaşayan kişilerin sendrom anı gelmeden uyarılması ve uykudan uyandırılması ile olası risklerin yaşanmadan önlenmesi mümkün olabilecektir. Bu tez çalışmasında, derin öğrenme yöntemlerinden biri olan Evrişimsel Sinir Ağları (Convolutional Neural Networks, CNN) ile OUA tanısı konmuş hastalara ait elektrokardiyografi sinyalleri kullanılarak apne tahmini yapan modeller sunulmuştur. Bu modellerden birincisi, önceden eğitilmiş mimariler ile yapılan sıfırdan eğitim çalışmasıdır. İkinci model, önceden eğitilmiş mimariler ile transfer öğrenme yöntemi kullanılarak yapılan çalışmadır. Üçüncü model, ilk iki modelde gözlemlenen bulgulara bağlı olarak önerilmiş yeni bir modeldir. Son modelde ise üçüncü modelde önerilen derin öğrenme mimarisinden elde edilen özneliklerin, mimarinin kendi sınıflandırıcısı yerine Destek Vektör Makineleri, Rastgele Alt Uzay k-En yakın Kom-

şuluk ve Rastgele Alt Uzay Diskriminant Analizi yöntemleri ile sınıflandırıldığı durumda gözlemlenen sonuçlar sunulmuştur. Çalışmanın sonucunda gözlemlenen yüksek doğruluktaki bulgular, önerilen modellerin OUA tahmininde iyi bir belirteç olarak kullanılabilceğini göstermektedir.

Anahtar Kelimeler: Evrişimsel sinir ağıları, Obstrüktif uyku apnesi, Derin öğrenme, Elektrokardiyografi, Tahminleme



ABSTRACT

Doctor of Philosophy

OBSTRUCTIVE SLEEP APNEA PREDICTION USING DEEP LEARNING

Hüseyin NASIFOĞLU

TOBB University of Economics and Technology
Institute of Natural and Applied Sciences
Biomedical Engineering Science Programme

Supervisor: Prof. Dr. Osman EROĞUL

Date: May 2022

Sleep apnea is defined as the cessation of breathing for at least ten seconds and known as a common sleep disorder. Obstructive sleep apnea (OSA) is the most common type of sleep apnea that occurs due to obstruction in the airway. Besides the detection of sleep apnea with the help of developed algorithms, early prediction of this syndrome is important in order to prevent serious health problems and life-threatening situations. With the prediction models working with high accuracy, it will be possible to prevent the possible risks without experiencing them by stimulating the OSA patients before the syndrome occurs and waking them up from sleep. In this thesis, models that predict apnea using electrocardiographic signals of patients diagnosed with obstructive sleep apnea by using Convolutional Neural Networks (CNN) are presented. The first model is the training from scratch with pre-trained architectures. The second model is the study of using the transfer learning method with pre-trained architectures. The third model is the study in which the new results observed with the changes made on the architecture that performed the best prediction performance in the first two models. In the last model, the results are presented when the features obtained from the deep learning architecture proposed in the third model are classified by Support Vector Machines, Random Subspace k-Nearest Neighborhood and Random Subspace Discriminant Analysis methods instead of the architecture's own classifier. The high accuracy findings observed at the end of the study show that the proposed model can

be used as a good indicator for the prediction of OSA syndrome.

Keywords: Convolutional neural networks, Obstructive sleep apnea, Deep learning, Electrocardiography, Prediction



TEŞEKKÜR

Çalışmalarım boyunca değerli yardımları ve katkılarıyla beni yönlendiren çok kıymetli hocam Prof. Dr. Osman Eroğul'a, Prof. Dr. Ziya Telatar'a, Prof. Dr. Fatih Büyükserine'e, Doç. Dr. Fatih Demirci'ye, kıymetli tecrübelerinden faydalandığım TOBB Ekonomi ve Teknoloji Üniversitesi Biyomedikal Mühendisliği Bölümü öğretim üyelerine ve manevi desteğiyle yanımda olan dostum Erdem İnanç Budak'a teşekkür ederim. Ayrıca asistanlık dönemim boyunca bana sağladığı özel başarı bursu ve destek için TOBB Ekonomi ve Teknoloji Üniversitesi'ne şükranlarımı sunarım.

Tez dönemim boyunca manevi desteğiyle hep yanımda olan, moral ve motivasyonumu yüksek tutmamı sağlayan yol arkadaşım sevgili eşim Nazan Nasıfoğlu'na kalpten dokunuşu için çok teşekkür ederim. Farklı ülkelerde olsak da her zaman yanımdaymış gibi hissettiren, benden desteklerini esirgemeyen çok kıymetli annem Firdevs Nasıfoğlu'na ve babam Niyazi Nasıfoğlu'na sonsuz teşekkür ederim. Çalışmalarımı sizlerin desteği olmadan tamamlayamazdım. Doktora tezimi eşime ve aileme armağan ediyorum.

İÇİNDEKİLER

	<u>Sayfa</u>
ÖZET	iv
ABSTRACT	vi
TEŞEKKÜR	viii
İÇİNDEKİLER	ix
ŞEKİL LİSTESİ	xi
ÇİZELGE LİSTESİ	xiii
KISALTMALAR	xiv
SEMBOLE LİSTESİ	xv
1. GİRİŞ	1
1.1 Tezin Amacı ve Önemi	2
1.2 Tezin Kapsamı.....	3
2. KURAMSAL TEMELLER VE LİTERATÜR ARAŞTIRMASI	5
2.1 Obstrüktif Uyku Apnesi (OUA).....	5
2.2 Elektrokardiyografi (EKG) ve Uyku Apnesi ile İlişkisi.....	6
2.3 Derin Öğrenme	7
2.4 Evrişimsel Sinir Ağları.....	8
2.4.1 Girdi katmanı.....	9
2.4.2 Evrişim katmanı.....	9
2.4.3 Doğrultulmuş doğrusal birim aktivasyon fonksiyonu	11
2.4.4 Havuzlama katmanı	12
2.4.5 Tam bağlantı katmanı	13
2.4.6 Sınıflandırma katmanı	13
2.4.7 Dizi normalizasyonu ve dropout.....	15
2.4.8 Geri yayılım.....	16
2.5 Transfer Öğrenme	17
2.6 Destek Vektör Makineleri	21
2.7 Rastgele Alt Uzay k-En Yakın Komşuluk Sınıflandırıcısı.....	24
2.8 Rastgele Alt Uzay Diskriminant Sınıflandırıcısı.....	25
2.9 Gradyan Ağırlıklı Sınıf Aktivasyon Haritalama	27
2.10 OUA Tespiti ve Tahmini Alanında Öne Çıkan Çalışmalar.....	28
3. MATERYAL VE YÖNTEM	33
3.1 Kullanılan Veri Setleri	33
3.2 Taban Hattı Düzeltmesi ve Z-Skoru Normalizasyonu	36
3.3 Sinyallerin Bölütlenmesi	37
3.4 Sentetik Veri Artırımı.....	38
3.5 Spektrogram Görüntülerinin Üretilmesi.....	41
3.6 Skalogram Görüntülerinin Üretilmesi	43
4. ÖNERİLEN MODEL VE BULGULAR	47
4.1 Sıfırdan Eğitim Sonuçları	48
4.2 Transfer Öğrenme Sonuçları	51
4.3 Önerilen Model Mimarisi	57
4.4 Önerilen Model Bulguları	60
4.5 Derin Özellikler ve Farklı Sınıflandırıcı ile Gözlemlenen Sonuçlar	65
5. DEĞERLENDİRME VE TARTIŞMA	71

6. SONUÇ	81
KAYNAKLAR	83
ÖZGEÇMİŞ	91



ŞEKİL LİSTESİ

Sayfa

Şekil 2.1 : EKG dalgası: (1) P dalgası; (2) QRS kompleksi; (3) T dalgası; (4) PR aralığı; (5) QRS aralığı; (6) QT aralığı; (7) ST aralığı; (8) PR bölütü; (9) ST bölütü; (10) R-R aralığı (veya atım); (11) Kardiyak döngüsü.	6
Şekil 2.2 : ESA'nın genel mimarisi.....	9
Şekil 2.3 : Evrişim işlemi.....	11
Şekil 2.4 : ReLU aktivasyon fonksiyonu.	11
Şekil 2.5 : Maksimum havuzlama ve ortalama havuzlama örneği.....	12
Şekil 2.6 : Global maksimum havuzlama ve global ortalama havuzlama örneği.	13
Şekil 2.7 : Sigmoid fonksiyonu.....	14
Şekil 2.8 : Softmax fonksiyonu.....	14
Şekil 2.9 : (a) Dropout öncesi sinir ağı, (b) Dropout uygulandıktan sonra sinir ağı..	15
Şekil 2.10 : AlexNet mimarisi.....	19
Şekil 2.11 : GoogleNet mimarisindeki başlangıç modülü.	19
Şekil 2.12 : GoogleNet mimarisi.....	20
Şekil 2.13 : ResNet artık bağlantı yapısı.....	21
Şekil 2.14 : ResNet18 mimarisi.	21
Şekil 2.15 : (a) İki sınıflı doğrusal sınıflandırma, (b) İki sınıflı doğrusal olmayan sınıflandırma.	22
Şekil 2.16 : Doğrusal olarak ayrılabilen veri kümesi için belirlenen hiper düzlem... 22	
Şekil 2.17 : Örnek Grad-CAM görüntüleri (a) OUA olmayan kesit, (b) OUA kesiti.28	
Şekil 3.1 : Çalışmanın akış diyagramı.....	34
Şekil 3.2 : (a) Taban hattı düzeltilmesi öncesi EKG kesiti, (b) Taban hattı düzeltilmesi sonrası EKG kesiti.	36
Şekil 3.3 : Pre-OUA aralıklarının bölütlenmesi.....	38
Şekil 3.4 : (a) Orijinal EKG kesiti, (b) SMOTE algoritması ile üretilen sentetik EKG kesiti.	39
Şekil 3.5 : Uygulanan ön işlemler ve dengeli veri setinin oluşturulması.....	40
Şekil 3.6 : (a) Zaman ekseninde OUA kesiti, (b) Zaman ekseninde Non-OUA kesiti, (c) OUA kesitinin spektrogram görüntüsü ve (d) Non-OUA kesitinin spektrogram görüntüsü.....	42
Şekil 3.8 : (a) Zaman ekseninde OUA kesiti, (b) Zaman ekseninde Non-OUA kesiti, (c) OUA kesitinin skalogram görüntüsü ve (d) Non-OUA kesitinin skalogram görüntüsü.....	43
Şekil 3.9 : (a) 0-30 sn kesiti, (b) 30-60 sn kesiti ve (c) 60-90 sn kesiti için skalogram görüntüleri.	44
Şekil 3.10 : OUA olaylarının tespiti ve tahmininde izlenen adımlar.	45
Şekil 4.1 : Doğruluk sonuçları (a) AlexNet, (b) GoogleNet ve (c) ResNet18.	54
Şekil 4.2 : TL ve Non-TL eğitimlerinde skalogram görüntüleri için AlexNet doğruluk ve kayıp grafikleri; (a) Doğruluk, (b) Kayıp.....	55
Şekil 4.3 : TL ve Non-TL eğitimlerinde skalogram görüntüleri için GoogleNet doğruluk ve kayıp grafikleri; (a) Doğruluk, (b) Kayıp.	55
Şekil 4.4 : TL ve Non-TL eğitimlerinde skalogram görüntüleri için ResNet18 doğruluk ve kayıp grafikleri; (a) Doğruluk, (b) Kayıp.	55

Şekil 4.5 : TL ve Non-TL eğitimlerinde spektrogram görüntüleri için AlexNet doğruluk ve kayıp grafikleri; (a) Doğruluk, (b) Kayıp.....	56
Şekil 4.6 : TL ve Non-TL eğitimlerinde spektrogram görüntüleri için GoogleNet doğruluk ve kayıp grafikleri; (a) Doğruluk, (b) Kayıp.....	56
Şekil 4.7 : TL ve Non-TL eğitimlerinde spektrogram görüntüleri için ResNet18 doğruluk ve kayıp grafikleri; (a) Doğruluk, (b) Kayıp.....	56
Şekil 4.8 : Önerilen mimarinin katman bağlantıları.....	58
Şekil 4.9 : Önerilen model için skalogram ve spektrogram görüntülerinin doğruluk grafiği.	61
Şekil 4.10 : Grad-CAM görüntüleri; (a) Non-OUA skalogram, (b) Non-OUA spektrogram, (c) OUA skalogram, (d) 0-30 sn Pre-OUA skalogram, (e) 30-60 sn Pre-OUA skalogram, (f) 60-90 sn Pre-OUA skalogram, (g) OUA spektrogram, (h) 0-30 sn Pre-OUA spektrogram, (i) 30-60 sn Pre-OUA spektrogram, (j) 60-90 sn Pre-OUA spektrogram.	62
Şekil 4.11 : Önerilen modelin doğruluk ve kayıp grafikleri (a) Skalogram doğruluk, (b) Skalogram kayıp, (c) Spektrogram doğruluk ve (d) Spektrogram kayıp.	63
Şekil 4.12 : Önerilen modelin 10 kat çapraz validasyon sonuçları.	64
Şekil 4.13 : Önerilen modelin ROC eğrileri (a) Skalogram, (b) Spektrogram.....	65
Şekil 4.14 : Önerilen model ile farklı sınıflandırıcıların OUA tespiti ve tahmini için doğruluk performansları.	68

ÇİZELGE LİSTESİ

Sayfa

Çizelge 3.1 : HomePap veri setinden seçilen kayıtlara ait bilgiler.	35
Çizelge 3.2 : ABC veri setinden seçilen kayıtlara ait bilgiler.	36
Çizelge 3.3 : Orijinal kesit sayıları ve sentetik veri artırımı sonrası kesit sayıları.....	40
Çizelge 4.1 : AlexNet modeli için sıfırdan eğitim (Non-TL) sonuçları.	49
Çizelge 4.2 : GoogleNet modeli için sıfırdan eğitim (Non-TL) sonuçları.	49
Çizelge 4.3 : ResNet18 modeli için sıfırdan eğitim (Non-TL) sonuçları.....	50
Çizelge 4.4 : AlexNet modeli için transfer öğrenme (TL) sonuçları.	52
Çizelge 4.5 : GoogleNet modeli için transfer öğrenme (TL) sonuçları.	52
Çizelge 4.6 : ResNet18 modeli için transfer öğrenme (TL) sonuçları.	53
Çizelge 4.7 : Önerilen model mimarisi.	59
Çizelge 4.8 : Önerilen model bulguları.	60
Çizelge 4.9 : Derin özniteliklerin DVM ile sınıflandırma sonuçları.....	66
Çizelge 4.10 : Derin özniteliklerin RAU-kNN ile sınıflandırma sonuçları.	67
Çizelge 4.11 : Derin özniteliklerin RAU-D ile sınıflandırma sonuçları.	67
Çizelge 4.12 : Bir kesit için görüntü üretimi ve önerilen ResNet18 modelinin sınıflandırma sonucu vermesi için gerektirdiği süreler.	69
Çizelge 4.13 : Bir kesit için görüntü üretimi ve DVM, RAU-kNN, RAU-D modellerinin sınıflandırma sonucu vermesi için gerektirdiği süreler.	69
Çizelge 5.1 : OUA tahmini için literatür karşılaştırması.	76
Çizelge 5.2 : OUA tespiti için literatür karşılaştırması.	77

KISALTMALAR

AASM	: Amerikan Uyku Tıbbı Akademisi (American Academy of Sleep Medicine)
AHI	: Apne/Hipopne İndeksi
APAP	: Otomatik-titrasyon Pozitif Havayolu Basıncı (Auto-titrating Positive Airway Pressure, APAP)
AUC	: Eğri altında kalan alan (Area Under Curve)
CPAP	: Sürekli Pozitif Havayolu Basıncı (Continuous Positive Airway Pressure)
DA	: Diskriminant Analizi
DNN	: Derin Sinir Ağları (Deep Neural Network)
DVM	: Destek Vektör Makineleri
EDR	: EKG sinyalinde türetilen solunum (ECG Derived Respiration)
EEG	: Elektroensefalografi
EKG	: Elektrokardiyografi
EMG	: Elektromiyografi
EOG	: Elektrookülografi
ESA	: Evrimsel Sinir Ağları
FN	: Yanlış Negatif (False Negative)
FP	: Yanlış Pozitif (False Positive)
Grad-CAM	: Gradyan Ağırlıklı Sınıf Aktivasyon Haritalama (Gradient-weighted Class Activation Mapping)
GRU	: Kapılı Tekrarlayan Hücre (Gated Recurrent Unit)
HMM	: Gizli Markov Modeli (Hidden Markov Model)
kNN	: k-En Yakın Komşuluk (k-Nearest Neighbor)
KZFD	: Kısa Zamanlı Fourier Dönüşümü
MSE	: Ortalama Kare Hatası (Mean Square Error)
MUA	: Merkezi Uyku Apnesi
Non-TL	: Sıfırdan Eğitim
OUA	: Obstrüktif Uyku Apnesi
PPV	: Pozitif Tahmin Değeri (Positive Predictive Value)
PSG	: Polisomnografi
RAU-D	: Rastgele Alt Uzay Diskriminant
RAU-kNN	: Rastgele Alt Uzay k-En Yakın Komşuluğu
ReLU	: Doğrultulmuş Doğrusal Birim (Rectified Linear Unit)
SDD	: Sürekli Dalgacık Dönüşümü
TL	: Transfer Öğrenme (Transfer Learning)
TN	: Doğru Negatif (True Negative)
TP	: Doğru Pozitif (True Positive)
YSA	: Yapay Sinir Ağları

SEMBOL LİSTESİ

Bu çalışmada kullanılmış olan simgeler açıklamaları ile birlikte aşağıda sunulmuştur.

Simgeler	Açıklama
m	Görüntü matrisinin satır sayısı
n	Görüntü matrisinin sütun sayısı
g	Görüntünün boyutu
p	Kenarlık değeri
f	Filtre boyutu
a	Adım sayısı
z	Girdi vektörü
μ_B	Mini dizi ortalaması
σ_B^2	Mini dizi varyansı
σ	Standart sapma
γ	Optimizasyon katsayısı
β	Optimizasyon katsayısı
L	Kayıp fonksiyonu
w	Ağırlık değeri
η	Öğrenme katsayısı
b	Yanlılık
a_i	i indisindeki Lagrange çarpanı
M	Global ortalama
C	Sınıf içi dağılım matrisi
F_i	Diskriminant fonksiyonu
P	Olasılık değeri
X	Test verisi
A	Aktivasyon haritası
$L^{Grad-CAM}$	Ağırlıklı aktivasyon haritası
∂	Türev operatörü
ξ	0-1 aralığında seçilen rastgele seçilen değer
π	Pi sayısı
ψ	Ana dalgacık
τ	Kaydırma faktörü

1. GİRİŞ

Uyku apnesi, uyku esnasında yapılan solunumun 10 saniyeden daha uzun bir süre boyunca durması olarak bilinmektedir [1]. Uyku esnasında yaşanan bu rahatsızlığın tanı ve tedavisi için farklı yöntemler uygulansa da hekimin tanı koymasına yardımcı olabilen yazılım tabanlı uygulamaların sayısı gün geçtikçe artmaktadır. Bu çalışmalarda genellikle apne tanısı konmuş kişilerden kaydedilen fizyolojik sinyaller üzerinde kişinin apneye girdiği anlar otomatik olarak tespit edilmeye çalışılmıştır. Yüksek başarı oranlarının yakalandığı bu çalışmalarda amaç, kişinin nefes alışverişinin durduğu anları doğru bir şekilde tespit ederek gece boyu bu sendromun kaç kez tekrarlandığını gözlemleyebilmek ve tanıya yönelik bilgileri hekime sunabilmektir. Bu sayede kişide eğer apne sendromu varsa, bunun seviyesi de yüksek doğrulukla belirlenebilmekte ve daha hızlı bir şekilde tedavi planlaması yapılabilmektedir.

Apne tanısı konmuş kişilerde apne anlarının tespitinin yanı sıra nefes alışverişinin duracağı anları öngörebilmek de kişinin sağlığı açısından oldukça önemlidir. Başarı oranı yüksek modellerin önerilmesi ile apne anlarının doğru bir şekilde öngörülebilmesi, kişinin solunum durmasından kaynaklı hayati tehlikeler ile karşılaşmasını önleyebilecektir. Bu modellerin geliştirilmesinde kullanılan referans fizyolojik ölçümler, uyku esnasında gece boyu kaydedilmiş sinyallerdir. Bu sinyallerde apneye girilen anlar bilindiği takdirde bu anlardan önceki belirli zaman aralıkları dikkate alınarak fizyolojik ve morfolojik değişimler analiz edilebilir. Bu sayede, apne öncesi solunum ve normal solunum kesitleri arasındaki farkların ortaya konmasıyla makine öğrenmesi yöntemleri ile gelecekle ilgili yorumlar yapan modeller önerilebilir.

Sınıflar arasındaki ayırt edici özelliklerin el ile tespit edilmesi oldukça zor ve zaman gerektiren bir süreçtir. Bunun yanında doğru öznelik seçiminin ve sayısının belirlenmesinde öznelik mühendisliğinde uzman kişilerin tecrübesi gerekmektedir. Bu süreçteki olası zorlukların ortadan kaldırılmasında günümüzde sıkça tercih edilmeye başlanan derin öğrenme yöntemi, özellikleri otomatik olarak tespit edilebilmesiyle öne çıkmaktadır. Derin öğrenme yöntemlerinden Evrimsel Sinir Ağ-

ları (ESA), kullandığı evrişim katmanları ile girdi verileri üzerinde filtrelemeler yaparak özneliklerin tespit edilmesini sağlamaktadır. Böylelikle gözlemlenen özneliklerin sınıflandırılması ile hızlı ve yüksek doğrulukla sınıflandırma yapan modeller önermek mümkün olmaktadır.

Sayısal sinyal işleme yöntemleri ve sınıflandırma algoritmalarının sunduğu hızlı ve güvenilir sonuçların yanında bir diğer amaç ise kişiye bağlanan ölçüm sensörlerinin sayısını azaltarak daha az fizyolojik sinyal kullanımı ile yüksek doğrulukla çalışan modeller önermektir. Örneğin, apne tanısı için uyku laboratuvarında yatmış bir kişiden gece boyu elektrokardiyografi (EKG), elektroensefalografi (EEG), elektromiyografi (EMG), solunum, vücut pozisyonu, elektrookülografi (EOG) gibi birçok sinyal eş zamanlı kaydedilmektedir. Bu yöntem hem masraflı hem de kişi için düşük konforlu bir yöntemdir. Güncel makine öğrenmesi çalışmalarında ise altın standart olarak kabul edilen bu ölçümler referans alınarak daha az sayıda kayıt kullanan yeni modeller önerilmektedir. Bu çalışmalar sayesinde kişinin uyku laboratuvarına yatmadan daha az fizyolojik ölçüm bağlantısı ile daha konforlu bir alanda kayıt alması hedeflenmektedir. Tahminleme çalışmalarında da benzer durum söz konusudur. Daha az fizyolojik sinyal kaydı ile geliştirilen bu modellerde kişinin uyku apnesine girme anından önce bunun öngörülmesi ve erken uyarı sistemiyle kişiye basit bir uyarımın yapılması veya alarm mekanizmasıyla kişinin apneye girmeden önce uyarılması amaçlanmaktadır. Bu sayede kişi, solunumun durma anından önce uyandırılmış ve sendromun yaratabileceği olası hayati tehlikelerden kaçınmış olacaktır.

1.1 Tezin Amacı ve Önemi

Uyku çalışmalarında altın standart olarak kabul edilen polisomnografi (PSG) kayıtları ile gece boyu uyku esnasında kaydedilmiş fizyolojik ölçümler ile hastalık tanısına yönelik birçok bilgi edinilebilmektedir. Bu sayede, uzman hekimlerin edinilen bilgileri analiz etmesiyle hastalığın tanısı ve tedavisine yönelik planlama yapılabilmektedir. Otomatik olarak çalışabilen yazılım tabanlı uygulamalar sayesinde ise bu işlemler hız kazanabilmektedir. Önerilen sınıflandırma modelleri, hekimin tanı koymasına yarayan yardımcı araçlar olarak nitelendirilmekte birlikte hasta açısından da daha az sayıda ölçüm kullanarak kişinin daha konforlu ortamda bir uyku geçirmesini sağlamaktadır.

Bu tez çalışmasında,

- OUA tanısı konmuş hastalara ait EKG kayıtları kullanılarak OUA öngörüsünün araştırılması,
- Derin öğrenme yöntemlerinden biri olan Evrişimsel Sinir Ağı (ESA) yöntemi ile uyku apnesinin en yaygın türü olan Obstrüktif Uyku Apnesi (OUA) tahmini yapan modellerin önerilmesi,
- Farklı tahmin sürelerinin OUA tahminindeki başarısının araştırılması,
- OUA tahmininde önceden eğitilmiş mimarilerin sıfırdan eğitim ve transfer öğrenmesi kullanıldığı durumdaki başarılarının analiz edilmesi ve karşılaştırılması,
- EKG sinyallerinden üretilen iki boyutlu skalogram ve spektrogram görüntülerinin OUA tahminindeki başarılarının ölçülmesi ve karşılaştırılması,
- Önceden eğitilmiş mimarilerin OUA tahminindeki başarısının analiz edilmesiyle daha yüksek performans ile çalışabilen bir mimarinin sunulması,
- ESA derin özniteliklerinin Destek Vektör Makineleri, Rastgele Alt Uzay k-En Yakın Komşuluk ve Rastgele Alt Uzay Diskriminant Analizi yöntemleri ile sınıflandırılması durumunda performans sonuçlarının analiz edilmesi ve karşılaştırılması amaçlanmıştır.

1.2 Tezin Kapsamı

Bu tez çalışmasında, OUA tanısı konmuş hastalardan alınan PSG kayıtları arasından EKG sinyalleri kullanılarak OUA tahmini yapan evrişimsel sinir ağı modelleri önerilmiştir. Bu amaçla, farklı tahmin süreleri dikkate alınarak EKG sinyalleri kesitlere bölünmüş ve bu kesitler üzerinde ön işlemlerin uygulanmasının ardından ESA modellerinin sınıflandırma başarıları irdelenmiştir. Gözlemlenen sonuçlara bağlı olarak OUA tahmin performansını artıran yeni modeller önerilmiş ve bulgular analiz edilmiştir.

Çalışmanın ikinci bölümünde, OUA, elektrokardiyografi ve evrişimsel sinir ağları, transfer öğrenme, Destek Vektör Makineleri, Rastgele Alt Uzay k-En Yakın Komşuluk Sınıflandırıcısı ve Rastgele Alt Uzay Diskriminant Sınıflandırıcısı

hakkında genel bilgiler verilmiştir. Ardından, OUA tespiti ve tahminine yönelik yapılan arařtırmalarda öne çıkan çalışmalar özetlenmiştir.

Üçüncü bölümde, kullanılan veri setleri hakkında bilgiler verilmiş olup bu veri setlerindeki kayıtların hangi kriterlere göre seçildiğine değinilmiştir. Daha sonra, seçilen sinyaller üzerinde yapılan ön işlemler, bölütleme, sentetik veri artırımı ve evrişimsel sinir ağı modellerinde girdi olarak kullanılmak üzere verilerin tek boyutlu sinyallerden iki boyutlu skalogram ve spektrogram görüntülerine dönüştürme işlemleri aktarılmıştır.

Dördüncü bölümde, önerilen modeller hakkında bilgiler verilmiş ve gözlemlenen bulgular paylaşılmıştır. Önceden eğitilmiş mimarilerinin sıfırdan eğitim ve transfer öğrenme yöntemleri için sınıflandırma performansları karşılaştırmalı olarak sunulmuştur. Ardından, gözlemlenen sonuçlarına bağlı olarak yeni bir model önerilmiş ve bu modelin detayları hakkında bilgiler paylaşılmıştır. Son olarak, ESA mimarisinin kendi sınıflandırıcısı yerine farklı sınıflandırıcılar kullanıldığı durumda gözlemlenen performans sonuçları sunulmuştur.

Beşinci bölümde, önerilen modellerde gözlemlenen bulgular hakkında yapılan değerlendirmelere, literatürdeki benzer çalışmalar ile yapılan karşılaştırmaya ve çalışmadaki kısıtlamalara yer verilmiştir. Tez çalışması kapsamında önerilen modellerden için yapılan genel değerlendirme ise altıncı bölümde sunulmuştur.

2. KURAMSAL TEMELLER VE LİTERATÜR ARAŞTIRMASI

2.1 Obstrüktif Uyku Apnesi (OUA)


Uyku apnesi, uyku esnasında yapılan solunumun 10 saniyeden daha uzun bir süre boyunca durması olarak bilinmektedir [1]. Uyku apnesi üç farklı tipte incelenmektedir. Bunlar, Obstrüktif Uyku Apnesi (OUA), Merkezi Uyku Apnesi (MUA) ve Mikst Uyku Apnesi'dir. OUA, soluk alıp-verme eforunun olduğu ancak solunum yolunda gerçekleşen tıkanıklıktan dolayı nefes alışverişinin durduğu en yaygın apne türüdür. MUA, solunumun durduğu ve aynı zamanda soluk alıp-verme eforunun olmadığı durumlarda gerçekleşirken, Mikst Uyku Apne'sinde ise OUA ve MUA davranışları bir arada görülmektedir. Kadınlara kıyasla erkeklerde görülme olasılığının üç kat daha fazla olduğu gözlemlenen OUA, özellikle obezite ve 60 yaş üzeri kişilerde daha sık görülmektedir [2]. OUA sendromu yaşayan kişilerde solunumun 10 saniye ve üzeri durması ile oksijen doygunluğunun %90'ın altına inmesinin sonucu olarak uyanma, hipoksemi, yüksek kan basıncı gibi kısa zamanlı etkilerin görülmesiyle birlikte kardiyovasküler hastalıklar, diyabet, depresyon ve kalp krizi gibi hayat kalitesini etkileyen önemli sağlık sorunlarının ortaya çıktığı gözlemlenmiştir [3,4].

Uyku laboratuvarlarında kişiden uyku esnasında alınan polisomnografi (PSG) kayıtları OUA tanısının konulmasında altın standart olarak kabul edilmektedir [5]. Polisomnogram kayıtları aynı anda kaydedilmiş EKG, EMG, EEG, oksijen doyumu, solunum, vücut pozisyonu, EMG, EOG, horlama gibi fizyolojik kayıtlarından oluşmaktadır [6]. PSG kayıtlarından tespit edilen Apne/Hipopne indeksinin (AHI) değerine bağlı olarak apne tanısı konabilmektedir [2]. AHI, ortalama bir saat başına düşen toplam apne ve hipopne sayılarının toplamıdır. Burada hipopne, solunumun uyku esnasında kısmi olarak durduğu anları ifade etmektedir [7,8]. $AHI \geq 5$ apne tanısının konması için yeterlidir [9]. Öte yandan $AHI < 5$ kişide OUA olmadığını ifade ederken, $5 \leq AHI < 15$ hafif derece OUA, $15 \leq AHI < 30$ orta derece OUA ve $30 \leq AHI$ ağır derece OUA'yı ifade etmektedir. Sürekli Pozitif Havayolu Basıncı (Continuous Positive Airway Pressure, CPAP), OUA tedavisinde en çok tercih edilen yöntemdir.

CPAP, uyku esnasında hava yolu açıklığını sağlamak amacıyla burun veya ağız yoluyla sürekli hava basıncının uygulandığı bir yöntemdir. CPAP ile sabit bir hava basıncı uygulamak yerine hava basıncını adaptif olarak değiştiren yöntemler de geliştirilmiştir. Otomatik-titrasyon Pozitif Havayolu Basıncı (Auto-titrating Positive Airway Pressure, APAP) uygulanan hava basıncı seviyesini adaptif olarak değiştirerek CPAP terapisinin etkinliğini artırmayı amaçlamaktadır. Alternatif olarak, oral cihaz terapisi veya ameliyat gibi tedavi yöntemleri uygulanmaktadır.

2.2 Elektrokardiyografi (EKG) ve Uyku Apnesi ile İlişkisi

Elektrokardiyogram, kalbin elektriksel aktivitesini sürekli olarak takip edebilmek ve kaydetmek için kullanılan bir yöntemdir [10]. Kalbin elektriksel aktivitesinin ölçülmesi ile kalp atımlarının takip edilmesi, kalp atım hızının ölçülmesi ve kalp atımındaki normal olmayan durumların tanısı EKG kayıtları ile tespit edilmektedir. Bir EKG döngüsünü oluşturan bileşenler P dalgası, QRS kompleksi ve T dalgalarıdır (Şekil 2.1). Bu döngüde kalp atımının gerçekleştiği an QRS kompleksindeki R tepesinin görüldüğü andır.



Şekil 2.1 : EKG dalgası: (1) P dalgası; (2) QRS kompleksi; (3) T dalgası; (4) PR aralığı; (5) QRS aralığı; (6) QT aralığı; (7) ST aralığı; (8) PR bölütü; (9) ST bölütü; (10) R-R aralığı (veya atım); (11) Kardiyak döngüsü [11].

Morfolojik ve geçici değişimlerin sık görüldüğü bu kayıtlarda tanı koymak bazen zor bir görev olabilmektedir. Bunun nedeni, EKG kayıtlarının kişiden kişiye değişiklik gösterebilmesi ve bazı durumlarda aynı hastalık için birbirinden farklı morfolojik değişimlerin gözlemlenebilmesidir. Bu durumun önüne geçilebilmesi amacıyla yazılım tabanlı karar destek sistemleri ile hekimin tanı koymasına yarayan yardımcı modeller geliştirilmeye başlamıştır. Uyku apnesi de bu alanda ele alınan konulardan biridir.

Apne gerçekteştiđi esnada solunumun durmasından kaynaklı vücutta farklı fizyolojik etkiler gözlemlenmektedir. Solunumun kalp atışı ile de ilintili olunduđu dikkate alındığında apne esnasında kalp atımına bađlı deđişiklikler gözlemleneceđi de söylenebilir. Yapılan arařtırmalara göre, uyurken nefes alma durduđunda kandaki oksijen miktarının azaldığı, kalp atım hızının düřtüđu ve ardından istem dıřı reflekslerin mikro uyarılmaya (arousal) neden olduđu gözlemlenmiřtir [12]. Ardından, apne sonuna dođru kalp atım hızının arttıđı ve kan basıncının yükseldiđi vurgulanmıřtır. Bařka bir çalıřmanın bulgularına göre, R-R aralıklarının bařlangıçta arttıđı, sonra azaldığı görölürken ($p<0,01$), P dalgası genliđinde artış ($p=0,03$), PR ve QRS kompleksi genliklerinde artış ($p=0,1$), QT genliđinde artış ($p=0,01$) gözlemlenmiřtir [13]. Bařka bir arařtırmaya göre, bir apne olayı meydana geldiđinde kandaki oksijen seviyesinin düřtüđu ve kardiyovasküler sistemin, vücuda yeterli oksijen tedarikini sürdürmesi için yönlendirildiđi vurgulanmıřtır. Bu nedenle, düzensiz kalp aktiviteleri veya yüksek kalp hızı deđişkenliđi gözlemlenmiřtir [14]. Yapılan bir diđer arařtırmada ise OUA tanısı konmuş kiřilerde kalp atım hızı deđişkenliđinin güç spektral yoğunluđundaki düřük frekans bölgesinin enerjisinin daha büyük olduđu görölmüřtür [15].

2.3 Derin Öğrenme

Yapay zekâ uygulamalarından biri olan derin öğrenme, makine öğrenmesinin bir alt kümesi olarak bilinen ve günümüzde sıkça tercih edilen bir yöntemdir. Yeni bir yaklaşım gibi gözükse de ilk fikirler 1950’li yıllarda ortaya konmaya bařlamıřtır. Derin öğrenmenin gelişim süreci yapay sinir ađları arařtırmalarının temellerine dayanmaktadır. 1940-1960 yılları arasında “sibernetik” olarak bilinen yapay sinir ađları, tek bir nöronun eđitilmesi olgusuyla karřımıza çıkmıřtır [16]. 1980-1995 döneminde “bađlantıcılık” adıyla devam eden arařtırmalarda yapay sinir ađının bir veya birden fazla gizli katman ile eđitilmesi ele alınmıřtır [17]. 2006 itibariyle “Derin Öğrenme” adıyla devam eden çalıřmalarda ise derin ađların eđitilmesi arařtırılmaya bařlanmıřtır [18-20].

Temelde insan beyninin çalıřma mekanizmasının referans alındığı sinir ađı modellerinde biyolojik sinir sistemindeki nöronların uyarılması ve sinirler arasındaki bađlantılar makineye öğretilmeye amaçlanmıřtır [21]. Derin öğrenme algoritmalarının 1980lerde var oluřu; fakat 2006’ya kadar gündemde yer edemeyiři bu algoritmaları


çalıştırabilecek donanımların 1980'li yıllarda mevcut olmamasına bağlanmaktadır. İlerleyen yıllarda grafik işleme birimlerinde kaydedilen gelişmeler ile daha hızlı veri işleme mümkün olmaya başlamış ve derin öğrenmenin yeniden gündeme gelmiştir. Veri setindeki özelliklerin katmanlar tarafından otomatik olarak çıkarılıyor olması derin öğrenmeyi geleneksel makine öğrenmesi yöntemlerinden ayıran en önemli özelliktir. Bunun yanında büyük veri kümelerinin sınıflandırılmasında gösterdiği yüksek performans da bu yöntemin avantajlarından biri olarak değerlendirilmektedir [22]. Bir diğer farklılık ise, derin öğrenme teknikleri sorunu uçtan uca çözme eğilimindeyken, makine öğrenimi teknikleri problemin önce farklı parçalara ayrılmasına ve ardından sonuçlarının son aşamada birleştirilmesine ihtiyaç duyar. Örneğin, derin öğrenme bir görüntüyü girdi olarak kullanıp görüntüdeki nesnelerin yerini ve ismini çıktıda verebilirken, geleneksel makine öğrenmesi önce ilgili nesneleri tanımak için bir algoritmaya ihtiyaç duyar ve bu algoritmadan bulunan özellikleri sınıflandırmaya çalışır. Genel olarak, derin öğrenme algoritmalarının eğitim süresi geleneksel makine öğrenmesi yöntemlerine kıyasla oldukça uzundur. Sınıflandırıcıların test aşamasında ise bu durum çoğu zaman tam tersidir. Ses tanıma, nesne tanıma, doğal dil işleme, video işleme, tümör tespiti, hastalık teşhisi, hastalık tahmini, sınıflandırma ve birçok endüstriyel alanda tercih edilmeye başlanan derin öğrenmenin sunduğu avantajlar ve ilerleyen teknoloji sunduğu imkanlar ile önümüzdeki yıllarda daha da yaygınlaşacağı düşünülmektedir.

2.4 Evrişimsel Sinir Ağları

Evrişimsel sinir ağları (ESA), girdi görüntülerini çeşitli katmanlarla işleyen sinir ağı modelleridir. Derin öğrenme yöntemlerinden biri olan ESA'nın sağladığı en büyük avantaj, kullandığı evrişim katmanları ile öznitelikleri otomatik olarak tespit etmesidir. Klasik makine öğrenme yöntemlerinde sınıflar arası farklılıkları ortaya koyan ayırt edici özniteliklerin belirlenmesi hem zaman alan hem de ilgili konuda uzman kişilerin tecrübelerini gerektiren bir süreçtir. Yanlış bir yaklaşımla veya yetersiz sayıda öznitelik çıkarımının yapılması durumunda sınıflandırıcı performansı önemli ölçüde etkilenebilmekte ve modelin başarısı düşük olabilmektedir. Evrişimsel sinir ağları bu probleme farklı boyutlarda filtreler ve evrişim katmanları ile çözüm bulmaktadır. Girdi görüntülerine evrişim katmanlarında uygulanan farklı sayıda filtreler sayesinde model, öznitelikleri otomatik olarak belirlemekte ve sonraki katmanlara aktararak

işlemektedir. Bu noktada, modelin doğru bir şekilde eğitilebilmesi ve ayırt edici özneliklerin tespit edilebilmesi için klasik makine öğrenmesi yöntemlerine kıyasla daha çok sayıda girdi verisine ihtiyaç duyulmaktadır. Veri sayısının yetersiz olabileceği durumlarda ise transfer öğrenmesi, sentetik veri artırımı, dropout kullanımı gibi bazı yöntemler geliştirilmiş olup; modelin doğru bir şekilde eğitilmesi sağlanmaktadır.

Evrişimsel sinir ağları beş temel katmandan oluşmaktadır. Bunlar girdi, evrişim, havuzlama, tam bağlantı ve sınıflandırma katmanlarıdır. Basit bir ESA mimarisinin temel yapısı Şekil 2.2’de verilmiştir.



Şekil 2.2 : ESA'nın genel mimarisi.

2.4.1 Girdi katmanı

ESA mimarilerinde kullanılan ilk katmandır. Geleneksel makine öğrenmesi yöntemlerinde sınıflara ait özelliklerin önce belirlenip, ardından modelde girdi olarak kullanılmasının aksine, burada girdi verileri doğrudan kullanılmaktadır. Kullanılan girdinin boyutu modelin performansını önemli ölçüde etkilemektedir. Yüksek boyutlarda seçilen girdilerin çıktındaki başarısının yüksek olması beklense de eğitim süresinde artma meydana gelmektedir. Ayrıca, yüksek boyutlu girdilerin işlenmesi bellekte daha fazla işlem gücü gerektirmektedir. Öte yandan oldukça küçük boyutlardaki girdiler ise yetersiz sayıda özelliklerin çıkmasına neden olup çıktındaki başarıyı düşürebilmektedir. Bu nedenle, iyi bir ağ başarısının yakalanabilmesi için doğru bir girdi boyutunun seçilmesi oldukça önemlidir.

2.4.2 Evrişim katmanı

Evrişim katmanı, eğitim verisine ait özelliklerin çıkarıldığı katmandır. Sınıfları birbirinden ayırmak ve sınıflandırma sonucunda model başarısının yakalanmasında önemli bir rol oynamaktadır. Evrişim katmanının sunduğu en önemli avantajlardan biri

ağırlıkların paylaşılmasıdır. Ağırlıkların filtreler ile temsil edilmesinin bir sonucu olarak aynı filtrenin tüm görüntü üzerinde evrişim işlemine tabii tutulması, daha az parametre ile hesaplama yapmayı mümkün kılmaktadır.


Evrişim katmanında, farklı boyutlarda bir dizi filtrenin yerel bölgeler üzerinde uygulanmasıyla veri sınıflarına ait ayırt edici özellikler çıkarılmaktadır. Evrişim işleminde filtreler yatay ve dikey eksen boyunca görüntü üzerinde hareket ettirilip ve filtrenin görüntü üzerinde kapladığı alandaki piksel değerleri ile filtrenin değerleri çarpılıp toplanır. Hesaplanan sonuçlar yeni bir matriste depolanır (Şekil 2.3). Bu matris, özellik haritası veya aktivasyon haritası olarak adlandırılır. Uygulanan filtre sayısı kadar aktivasyon haritası elde edilir.

Çıktıda elde edilen aktivasyon haritasının boyutları, filtrenin adım sayısı (stride) ve kenarlık (padding) parametreleriyle belirlenmektedir (Eşitlik 2.1). Burada adım sayısı filtre penceresinin kayma miktarını ifade ederken; kenarlık değeri kaynak görüntünün sınırları dışına sıfır değerinde yeni piksellerin eklenmesi sırasında belirlenen ek kenar sayısıdır. Kenarlık değerinin kullanılmasıyla, evrişim işlemi sonucunda orijinal matris boyutu ile aynı boyutta bir matris elde edilebilmektedir.

$$(m, n) = \frac{g+2p-f}{a} + 1 \quad (2.1)$$

Eşitlik 2.1'de g görüntü boyutunu, p kenarlık değerini, f filtre boyutunu ve a adım sayısını ifade etmektedir. Bu eşitliğe göre, $64 \times 64 \times 3$ boyutundaki bir görüntüye $5 \times 5 \times 3$ boyutunda, kenarlık değeri 0 ve adım sayısı 1 değerleriyle evrişim işlemi uygulandığında çıktı matrisinin boyutu $60 \times 60 \times 1$ olacaktır. Buradan da anlaşılacağı gibi evrişim işlemi esnasında kenarlık değerinin işleme katılmadığı durumda çıktı görüntüsünün boyutu her koşulda azalmaktadır.

Evrişim katmanlarının sayısı arttıkça özellik seviyesi derinleşmekte; başka bir deyişle daha detaylı özellikler elde edilmeye başlanmaktadır [23]. Burada daha fazla özellik çıkarımı modelin her zaman daha iyi sınıflandırma performansı sunacağı anlamına gelmemektedir. Öte yandan, az sayıda seçilen evrişim katmanı, eğitim verisinde yeterli sayıda ayırt edici özelliğin tespit edilememesine ve model başarısının olumsuz yönde etkilenmesine neden olmaktadır. Bu nedenle, hedeflenen performans başarısını yakalamak için uygun sayıda katman kullanımına dikkat edilmesi gerekmektedir.




Şekil 2.3 : Evrşim işlemi [Url-1'den değiştirilerek alınmıştır].

2.4.3 Doğrultulmuş doğrusal birim aktivasyon fonksiyonu

ESA mimarilerinde aktivasyon fonksiyonu kullanımının amacı katman çıktısını doğrusal olmayan bir yapıya dönüştürmektedir. Doğada karşılaşılan birçok olayın doğrusal olmadığı dikkate alındığında, ESA mimarilerinde de hedeflenen modelin bu olayları algılayabilmesidir. Aktivasyon fonksiyonunun uygulanmadığı durumda, sınıflandırma doğrusal yapılacaktır ve sinir ağının sınırlı bir öğrenme gücü olacaktır. Bu bağlamda, eğitilen bir sınıflandırıcının yalnızca doğrusal ilişkileri değil, aynı zamanda doğrusal olmayan ilişkileri de öğrenmesi amaçlanmaktadır.

Sigmoid, tanh gibi farklı yapılar da aktivasyon fonksiyonları yapay sinir ağlarında oldukça tercih edilirken ESA'da çoğunlukla Doğrultulmuş Doğrusal Birim (Rectified Linear Unit, ReLU) kullanılmaktadır (Şekil 2.4).



Şekil 2.4 : ReLU aktivasyon fonksiyonu [24].


Diğer aktivasyon fonksiyonlarına kıyasla ileri besleme ve geri yayılımda sunduğu hızlı tepki süresi ile ön plana çıkan ReLU fonksiyonu, uygulandığı görüntüde negatif değerlere sıfır ataması yaparken pozitif değerleri olduğu gibi çıktıya aktarmaktadır (Eşitlik 2.2).

$$f(x) = \max(0, x) \quad (2.2)$$

2.4.4 Havuzlama katmanı


Genellikle evrişim katmanının ardından kullanılan havuzlama katmanında amaç aktivasyon haritalarının boyutunu ve ağ parametrelerinin sayısını azaltmaktır [25]. Çok sayıda veri ve ağın derinliği dikkate alındığında havuzlama katmanı sayesinde parametre sayısının azalmasıyla işlemsel yük de hafiflemektedir. Bu amaçla, bir önceki katmandan gelen çıktının üzerinde pencereleme uygulanır. Pencere içerisinde kalan pikseller üzerinde ortalama, maksimum bulma, toplama gibi işlemler yapılarak bulunan değer yeni bir piksel değeri olarak atanır.

Girdi verisinin boyutunun değiştirilmesinden ötürü havuzlama işlemi aşağı örnekleme olarak da adlandırılır. Örneğin 4 x 4 boyutundaki bir girdi görüntüsü için adım sayısı 2 olan 2 x 2 boyutunda pencereleme uygulanarak ortalama ve maksimum havuzlama işlemi yapıldığı durum ele alınsın. Bu durumda 2 birim kayan pencereler içerisinde kalan alanda ortalama ve maksimum bulma işlemleri yapılarak yeni piksel değerleri tespit edilecek ve bu değerler çıktıya aktarılacaktır (Şekil 2.5).



Şekil 2.5 : Maksimum havuzlama ve ortalama havuzlama örneği.

Bir diğer tercih edilen havuzlama yöntemi ise global maksimum ve global ortalama işlemleridir. Burada, pencere boyutu ile görüntü boyutu aynıdır ve aktivasyon haritasına uygulanan işlem sonucunda tek bir değer elde edilmektedir (Şekil 2.6).



Şekil 2.6 : Global maksimum havuzlama ve global ortalama havuzlama örneği.

2.4.5 Tam bağlantı katmanı

Tekrarlanan evrişim ve havuzlama katmanlarının ardından elde edilen iki boyutlu aktivasyon haritaları tam bağlantı katmanına gelerek düzleştirme işlemi ile vektöre dönüştürülmektedir. Genellikle birden fazla tam bağlantı katmanı tercih edilmektedir. Bu sayede ESA performansının artırılması amaçlanmaktadır.

Tam bağlantı katmanı, içerdiği parametre sayısının fazla oluşu nedeniyle yüksek bir işlemsel güç gerektirmektedir. Yapay sinir ağlarında olduğu gibi burada da nöronlar arasında yoğun bir ilişki kurulmakta ve bu ilişkiden elde edilen bilgiler son adım olan sınıflandırıcı katmanına iletilmektedir.


2.4.6 Sınıflandırma katmanı

Adından da anlaşılacağı gibi sınıflandırmanın yapıldığı katmandır. Tam bağlantı katmanından sonra gelen mimarinin son katmanı olan sınıflandırma katmanında sigmoid (Eşitlik 2.3), softmax (Eşitlik 2.4) gibi fonksiyonlar kullanılarak sınıf olasılığı belirlenmektedir. Problemin tanımına göre belirlenen sınıf sayısı bu katmanda kullanılması gereken bir parametredir. Örneğin iki sınıflı bir problem ele alınmışsa sınıflandırma katmanının çıktı değeri iki olarak belirlenmelidir. Bu sayede uygulanan fonksiyon ile çıktıda sınıf sayısı kadar olasılık değerleri üretilir. En yüksek değer hangi sınıf için elde edilmişse girdi verisi o sınıfa atanır.

$$f(z)_i = \frac{1}{1+e^{-z_i}} \quad (2.3)$$


Eşitlik 2.3'te z girdi vektörünü, i girdi vektörünün her bir elemanını, $f(z)$ çıktı olasılığını ifade etmektedir. Sigmoid fonksiyonu, uygulama için gereken süreyi azaltmaktadır. Öte yandan, fonksiyon türevinin kısa bir aralığa sahip olması nedeniyle

önemli bir bilgi kaybına neden olması, Sigmoid fonksiyonunun önemli bir dezavantajıdır. Şekil 2.7’de Sigmoid fonksiyonu görselleştirilmiştir.



Şekil 2.7 : Sigmoid fonksiyonu.

SoftArgMax veya Normalleştirilmiş Üstel İşlev olarak da bilinen Softmax fonksiyonu, girdi vektöründeki her bir elemanı üsteliyle orantılı bir olasılık dağılımına normalize eden bir aktivasyon fonksiyonudur (Şekil 2.8).



Şekil 2.8 : Softmax fonksiyonu [26].

Softmax öncesi, bazı girdi verileri negatif veya 1'den büyük olabilir. Softmax uygulandıktan sonra, her bir elemanın değeri 0 ile 1 aralığında olmakta ve elemanların toplamı 1 etmektedir. Bu şekilde, çıktıdaki veriler bir olasılık dağılımı olarak yorumlanabilmektedir.

$$f(z)_i = \frac{e^{z_i}}{\sum_{i=1}^K e^{z_i}} \quad (2.4)$$


Eşitlik 2.4’te z girdi vektörünü, i girdi vektörünün kaçınıcı değeri için işlem yapıldığını, K ise vektördeki eleman sayısını; yani sınıf sayısını ifade etmektedir.

2.4.7 Dizi normalizasyonu ve dropout

Dizi normalizasyonu (batch normalization) önceki katmandaki ağırlıkların, sonraki katmana kıyasla oldukça büyük olduğu durumda katmanlar arasındaki kovaryansı azaltmak amacıyla yapılan normalizasyon tekniğidir. Bu sayede hem eğitimin hızlanması hem de eğitim esnasında aşırı öğrenme (overfitting) durumunun da önüne geçilmesi mümkün olabilmektedir. ESA'nın eğitiminde kullanılan en önemli hiperparametrelerinden biri mini dizi boyutudur. Burada, tüm verinin tek seferde eğitime verilmesi yerine veri küçük paketlere bölünerek eğitime verilir ve işlemsel yük hafifletilir. Dizi normalizasyonu da buradaki mini dizilere uygulanmaktadır (Eşitlik 2.5).

$$BN_{\gamma,\beta}(x_i) = \gamma \frac{x_i - \mu_B}{\sqrt{\sigma_B^2 + \epsilon}} + \beta \quad (2.5)$$

Eşitlik 2.5'te x mini diziyi, μ_B mini dizi ortalamasını, σ_B^2 mini dizi varyansını, γ ve β katsayıları ise eğitim sırasında optimize edilen katsayıları ifade etmektedir. Dropout, aşırı öğrenmeyi önlemek amacıyla eğitim sırasında rastgele bazı nöronların ağırlık güncelleme sırasında kullanılmaması için tercih edilmektedir [27]. Ağın büyük olduğu, uzun süren eğitimin gerektirdiği ve veri sayısının az olduğu durumlarda aşırı öğrenmenin önlenmesinde etkili bir yöntemdir. Nöronların olasılık bazlı olarak seçildiği bu yöntemde, modele olasılık değerinin girilmesi gerekmektedir. Örneğin dropout değerinin 0,5 olduğu durumda model, katmana gelen nöron sayısının rastgele %50'sini kullanmaktadır. Şekil 2.9'da görüldüğü üzere katmanlar arasındaki bazı bağlantıların dropout işlemi ile ihmal edildiği durum görselleştirilmiştir.



Şekil 2.9 : (a) Dropout öncesi sinir ağı, (b) Dropout uygulandıktan sonra sinir ağı [27].

2.4.8 Geri yayılım

Geri yayılım, model eğitimi aşamasındaki en önemli adımlardan biridir. Doğru ve başarılı bir eğitimin gerçekleşmesi için çok katmanlı yapılarda sınıflandırma aşamasında ortaya çıkan hatanın minimize edilmesi hedeflenmektedir. Bu amaçla ilk olarak, hedeflenen ve bulunan değerler arasındaki hata miktarı hesaplanmaktadır. Daha sonra, gözlemlenen hata değeri optimize edilerek azaltılmaya çalışılmakta ve katman ağırlıklarının yeni değerlere göre güncellenmesi sağlanmaktadır. Bu işlem, hata değeri minimum değere ulaşana kadar tekrar edilmektedir.

Hata miktarının bulunması aşamasında bir kayıp (maliyet) fonksiyonu kullanılmaktadır. Ortalama Kare Hatası (Mean Square Rrror, MSE) yaygın olarak bilinen bir kayıp fonksiyonu iken ikili sınıflandırmada Çapraz Entropi Kaybı (Cross Entropy Loss) ESA mimarilerinde sıkça tercih edilen bir kayıp fonksiyonudur (Eşitlik 2.6 – 2.7).

$$L = -\sum_{i=1}^2 t_i \log(p_i) \quad (2.6)$$

$$L = -[t \log(p) + (1 - t) \log(1 - p)] \quad (2.7)$$

Eşitlik 2.6 – 2.7’de verilen denklemlerde t sınıfa ait gerçek etiketin olasılığını; p ise softmax çıktısındaki tahmin edilen etiketin olasılığını ifade etmektedir.

Kayıp fonksiyonunun değeri düşük olana kadar ağırlıklar rastgele değiştirilebilir fakat bu, verimli bir yaklaşım değildir. Bu amaçla, optimizasyon işlemi uygulanarak ağırlıklar optimize edilir. Gradyan azalma algoritması (Gradient Descent Algorithm) ile her veri seti yinelemesinden sonra ağırlıklar küçük artışlarla değiştirilmeye çalışılır. Burada kayıp fonksiyonunun türevini belirli bir ağırlık kümesinde hesaplayarak, minimumun hangi yönde olduğunu görebilmek mümkündür. Eşitlik 2.8’de ağ çıktısının aktivasyon cinsinden eşitliği verilmiştir. Toplam hata miktarının (L) ağdaki ağırlığa (w_{ji}) göre türevi ise Eşitlik 2.9’da gösterilmiştir. Yeni ağırlık değeri (w_{ji}'), eğitim başında belirlenen öğrenme katsayısı (η) ile işleme alınarak Eşitlik 2.10’daki gibi hesaplanmaktadır.

$$f(a_j) = \sum_i x_i w_{ji} \quad (2.8)$$

$$\frac{\partial L}{\partial w_{ji}} = \frac{\partial L}{\partial f(a_j)} \frac{\partial f(a_j)}{\partial w_{ji}} \quad (2.9)$$

$$w_{ji}' = w_{ji} - \eta \frac{\partial L}{\partial w_{ji}} \quad (2.10)$$

2.5 Transfer Öğrenme

Geleneksel makine öğrenimi, aynı özellik alanına ve benzer veri dağılımına sahip eğitim ve test verileri ile karakterize edilmektedir. Eğitim verileri ve test verilerinin dağılımlarında büyük farklar gözlemlendiğinde, modelin tahmin başarısı düşebilmektedir [28]. Bazı senaryolarda, test verilerinin özellik alanı ve öngörülen veri dağılım özellikleriyle eşleşen eğitim verilerinin elde edilmesi zor ve maliyetli bir işlem olabilmektedir. Bu nedenle, kaynak etki alanı ile eğitilmiş bir hedef etki alanı için yüksek performanslı bir öğrenici oluşturmaya ihtiyaç vardır. Transfer öğrenmenin temel motivasyonu buradan gelmektedir.

Transfer öğrenimi, halihazırda eğitilmiş bir model tarafından edinilen kaynak bilginin farklı bir hedef alana aktarmaya çalışan bir tekniktir [29]. Kaynak alanı D_s ve bu alana bağlı öğrenim görevi T_s olduğu düşünülürse, hedeflenen alan D_T ve bu alana bağlı öğrenim görevi T_T ise transfer öğrenmenin amacı, D_T alanını D_s ve T_s 'den edinilen bilgileri kullanarak öğrenebilmektir. Problemin tanımına, kaynak ve hedef etki alanlarında bulunan verilerin doğasına bağlı olarak, transfer öğrenimi için farklı ayarlar tanımlanabilmektedir [30].

ESA eğitimleri sırasında eğitim veri kümesinin büyük olması istenir. Eğitim başında rastgele ağırlıkların optimizasyonu sırasında veri sayısının yetersiz ise eksik öğrenme (underfitting) veya aşırı öğrenmeye (overfitting) görülebilmektedir. Transfer öğrenmenin sunduğu en önemli avantajlardan biri, ESA eğitimi için yeterli sayıda veri olmadığı durumda bu sorunların önlenmesine yardımcı olmasıdır. Ayrıca önceden eğitilmiş bir ESA modelinde halihazırda optimize edilmiş ağırlıkların olması ve modelin bu ağırlıklarını kullanarak yeni görev için optimize edilmesi, eğitim süresinin kısalmasında etkili olmaktadır.


Transfer öğrenme tercih edildiği takdirde önceden eğitilmiş ESA modelinde yeni görevin sınıf sayısına göre sınıflandırıcı katmanındaki sınıf sayısı değiştirilmelidir. Genellikle mevcut modelin son üç adımı olan tam bağlantı katmanı, softmax ve sınıflandırma katmanı yenilenir ve diğer katman bilgileri korunarak eğitim başlatılır.

Modelin son katmanları üzerinde yapılan düzenlemelere hassas ayarlama (fine tuning) denmektedir. Ele alınan problemin yapısına göre yalnızca bazı katmanlara transfer öğrenme uygulayıp diğer katmanları sıfırdan eğitmek mümkündür. Başka bir uygulama ise, transfer öğrenmenin uygulanacağı katmanların dondurularak (freezing) ağırlık güncellemesinin bu katmanlar için yapılmamasını sağlamaktır. Bu sayede kaynak bilgi, doğrudan ve güncellenmeden kullanılabilir. Diğer bir kullanım şekli, transfer öğrenmenin tüm katmanlar için uygulanması (fine-tuning katmanları hariç) ve tüm ağırlıkların eğitim boyunca yeniden optimize edilmesidir. Burada modelin başarısı problemde değiştiği için hangi senaryonun daha iyi sonuçlar vereceğini söylemek mümkün olmamaktadır. Transfer öğrenmede en yaygın kullanım, ImageNet veri seti ile eğitilen modeller ile yapılmaktadır. 1000 adet kategoride sınıflama yapabilen bu modeller arasında AlexNet, GoogleNet, ResNet18, VGG16 gibi mimariler sundukları performans başarıları ile farklı görevler için yeniden eğitilmek üzere sıkça tercih edilmektedir.

2.5.1 AlexNet mimarisi

AlexNet, bir milyondan fazla görüntü içeren ImageNet veritabanı ile eğitilmiş ve 60 milyon öğrenilebilir parametre ile 150.000 ImageNet verisi üzerinde test edilmiş sıralı yapıda tasarlanmış önceden eğitilmiş bir ağ modelidir [31]. AlexNet, giriş katmanında 227×227 boyutlarında RGB görüntüler kabul etmektedir. Ağ 5 evrişim katmanı ve 3 tam bağlı katmandan oluşmaktadır. Birinci evrişim katmanı $11 \times 11 \times 3$ boyutunda adım sayısı 4 olan 96 adet filtre içermektedir. Evrişim katmanı çıktılarına ReLU ve çapraz kanal normalizasyonu uygulanmaktadır. Burada çapraz kanal normalizasyonu kanal bazlı normalizasyon amacıyla kullanılmaktadır. Maksimum havuzlama katmanı, ReLU veya normalizasyon çıktısındaki parametre sayısının azaltılması amacıyla kullanılmaktadır. İkinci evrişim katmanı $5 \times 5 \times 48$ boyutunda, adım sayısı 1 ve kenarlık sayısı 2 olan 2 grup 128 filtreden oluşmaktadır. Üçüncü evrişim katmanı adım sayısı 1 ve kenarlık sayısı 1 olan $3 \times 3 \times 256$ boyutunda 384 adet filtre içerirken; dördüncü evrişim katmanı $3 \times 3 \times 192$ boyutunda adım sayısı 1 ve kenarlık sayısı 1 olan 192 adet filtre içermektedir. Son evrişim katmanı ise dördüncü evrişim katmanı ile aynı özelliklerde olup; burada farklı olarak 128 adet filtre kullanılmaktadır. Birinci tam bağlantı katmanı 4096 boyutlu bir öznitelik vektörü vermektedir. AlexNet, aşırı öğrenme durumunun önüne geçilebilmesi için olasılığı 0.5 olan dropout kullanılmaktadır. İkinci tam bağlantı katmanı birinci ile aynı özelliklerde olup; üçüncü

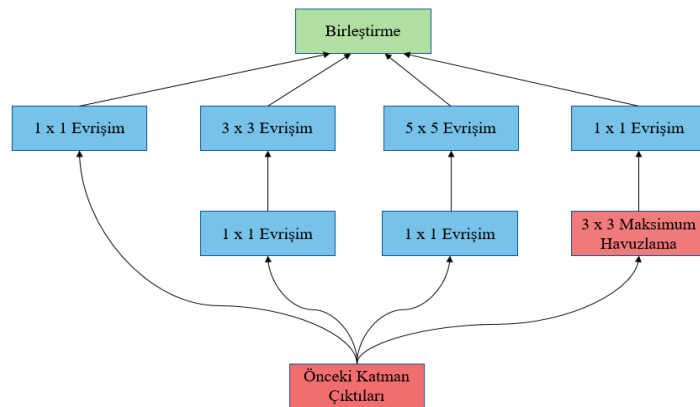
tam bağlantı katmanı ise çıktığı 1000 adet düğüme eşlemektedir. Yani AlexNet son katman itibarıyla görüntüleri 1000 kategoriye sınıflayabilmektedir. Son adımda, softmax fonksiyonu sınıflandırmayı yapmaktadır. Şekil 2.10'da AlexNet mimarisindeki katmanlar ve her bir katman çıktısının boyutları gösterilmiştir.



Şekil 2.10 : AlexNet mimarisi [32].


2.5.2 GoogleNet mimarisi

GoogleNet, Google ekibi tarafından önerilen ve 7 milyon öğrenilebilir parametreye sahip 22 katmanlı bir evrişimsel sinir ağıdır. Önceden eğitilmiş bu ağ, AlexNet mimarisinde olduğu gibi görüntüleri 1000 kategoride sınıflandırabilmektedir. AlexNet ağında olduğu gibi GoogleNet de ImageNet veri seti ile eğitilmiştir. 224 x 224 boyutlarında RGB görüntülerini girdi olarak kabul eden GoogleNet mimarisinin temel farkı 9 adet başlangıç (inception) modülü kullanmasıdır. Bu modüller, paralel yapıda çalışan ve eğitim esnasındaki hesaplama maliyetini azaltmak için kullanılan bir yaklaşımdır. GoogleNet bu başlangıç yapısında ReLU ile aktive edilmiş 1 x 1, 3 x 3 ve 5 x 5 filtreler ile evrişim işlemi ve havuzlama katmanı kullanmaktadır (Şekil 2.11). Evrişim işlemlerinin ardından elde edilen çıktılar birleştirme katmanında bir araya getirilerek sonucun bir sonraki katmana aktarılması sağlanmaktadır [33].



Şekil 2.11 : GoogleNet mimarisindeki başlangıç modülü.

GoogleNet, AlexNet'ten farklı olarak son birleştirme katmanından sonra global ortalama havuzlama katmanı kullanarak ağıdaki parametre sayısını önemli ölçüde azaltır ve bu katmanın hemen ardından da 0,4 olasılığı olan bir dropout katmanı kullanarak modelin aşırı öğrenmeye girmesini engellemeye çalışır. Şekil 2.12'de GoogleNet mimarisi verilmiştir. Burada beyaz renk ile gösterilen bloklar girdi ve softmax çıktıları, mavi renk evrişim katmanlarını, kırmızı renk havuzlama katmanlarını, yeşil renk birleştirme katmanlarını ve sarı renk softmax aktivasyonunu ifade etmektedir.



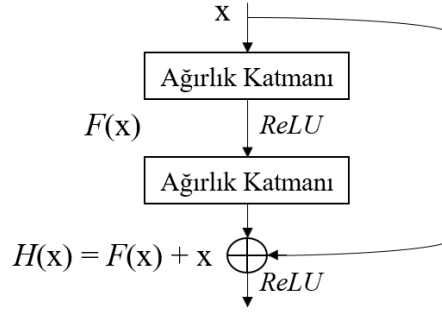
Şekil 2.12 : GoogleNet mimarisi [33].

2.5.3 ResNet18 mimarisi

ResNet18, 11,7 milyon öğrenilebilir parametreye sahip artık (residual) katmanlar içeren 18 katman derinliğe sahip önceden eğitilmiş bir ESA mimarisidir. Bu ağ, GoogleNet mimarisinde olduğu gibi 224 x 224 boyutlarında RGB görüntülerini girdi olarak kullanmaktadır.

ResNet'in arkasındaki ana fikir, ağın derinliği arttığında önceki katmanlarda ihmal edilebilir öğrenmenin gözlemlenmesine dayanmaktadır [34]. Başka bir deyişle, derin bir modeli kullanıldığında ağın önceki katmanlarındaki ağırlıklara göre gradyanlar, geri yayılma sırasında yok olacak kadar küçülebilmekte ve bu da öğrenmede düşük performansla yol açabilmektedir. Bu soruna “kaybolan gradyan (vanishing gradient)” denir. Başka bir problem ise büyük bir parametre uzayında optimizasyonun zorlaşmasıdır. Bu durum ise “bozulma sorunu (degradation problem)” olarak adlandırılır. Bu sorunların üstesinden gelmek için ResNet18, eğitim sırasında önceki katmanların özelliklerini yeniden kullanmaktadır (Şekil 2.13). Şekil 2.13'te önceki katmandan gelen “x” çıktısı ağırlık katmanına girerek ReLU aktivasyon fonksiyonu ile $F(x)$ çıktısını vermektedir. Ardından $F(x)$ 'in bir sonraki ağırlık katmanı çıktısına “x” eklenerek $H(x)$ çıktısı üretilmektedir. Bu sayede, “x” girdisinin ağırlıkları ilk


ağırlık katmanında sıfırlanacak olsa bile iki katman sonra tekrardan girdi olarak kullanılabilir.



Şekil 2.13 : ResNet artık bağlantı yapısı.

Artık bağlantı uygulanmadığı durum düşünülecek olursa sıfırlanan “x” girdisinin sonraki katmanın sonucuna bir etkisi olmayacaktır. ResNet kullandığı bu artık bağlantılarla önceki katmandaki değerlerin sonraki katmanlara daha güçlü bir şekilde iletilmesini sağlamaktadır.

ResNet18 mimarisi, 8 artık bağlantı bloğu sonrası global ortalama havuzlama, 1000 düğümlü tam bağlı katman ve softmax fonksiyonu ile sınıflandırma yapmaktadır (Şekil 2.14). Her bir evrişim katmanı çıktısı ise dizi normalizasyonu kullanılarak normalize edilmektedir.



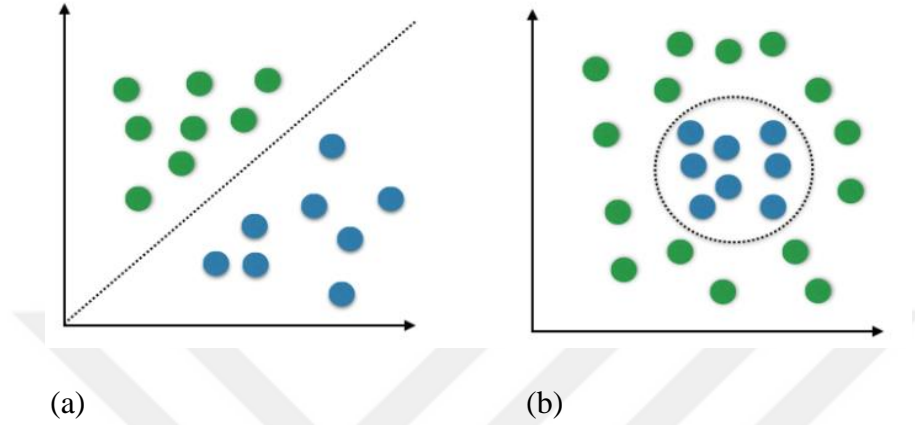
Şekil 2.14 : ResNet18 mimarisi [35].

Şekil 2.14’te verilen ResNet18 mimarisi için sürekli olarak çizilmiş artık bağlantılarda girdi doğrudan iki katman sonrasına eklenmektedir. Kesikli çizilmiş bağlantılarda ise aktarılan veri üzerinde 1 x 1 boyutunda filtreler ile evrişim işlemi uygulanmaktadır.

2.6 Destek Vektör Makineleri


Geleneksel makine öğrenmesi yöntemlerinden biri olan Destek Vektör Makineleri (DVM), ele alınan problemi temsil eden özellikleri kullanarak sınıflar arasındaki

farklılığı ortaya koyan bir sınıflandırma algoritmasıdır. DVM ile eğitilmiş modele modelin daha önce görmediği bir test verisi girdi olarak verilerek bu veri hakkında tahminleme veya genelleme yapılabilmektedir. İki sınıflı problemlerde performans başarısı yüksek olan DVM aynı zamanda çok sınıflı problemlerde ve doğrusal olmayan sınıflandırıcının gerektirdiği durumlarda da kullanılabilir (Şekil 2.15).



Şekil 2.15 : (a) İki sınıflı doğrusal sınıflandırma, (b) İki sınıflı doğrusal olmayan sınıflandırma [36].

İki sınıfın birbirinden doğrusal bir model ile ayırt edilebildiği durumlarda DVM, verileri sınıflandırmak için en uygun fonksiyonu hiper düzlem tanımlayarak yapmaktadır [37]. Bu amaçla, çok boyutlu uzayda farklı sınıflara ait en yakın noktalar hesaplanmakta ve bu noktaları birbirinden ayıran hiper düzlem belirlenmektedir (Şekil 2.16).



Şekil 2.16 : Doğrusal olarak ayrılabilen veri kümesi için belirlenen hiper düzlem.

Şekil 2.16’da kesikli çizgiler sınır düzlemlerini, kesikli olmayan çizgi hesaplanan hiper düzlemi, kırmızı ve mavi renkli noktalar ise iki farklı sınıfı ifade etmektedir.

Destek vektörlerinin belirlenmesinde kullanılan noktalar burada yeşil renkte gösterilmiştir. Sınır düzlemlerine eşit mesafede olan hiper düzlem $w^T x + b = 0$ denklemi ile ifade edilir. Burada w ağırlık vektörü ve b eşik değeridir. Sınır düzlemleri arasındaki mesafe ise $2/\|w\|$ değerindedir. Burada $\|w\|$, w 'nin normunu ifade etmektedir.

İki sınıflı bir problemde n adet x girdisi için bu girdilere karşılık gelen y etiketinin bilindiği durum ele alınsın. Etiket değeri -1 ve 1 olarak düşünülürse, sınır düzlemlerinin koşulu Eşitlik 2.11 ve Eşitlik 2.12'deki gibi olmaktadır.

$$w^T \cdot x_i + b \geq 1, y_i = 1 \quad (2.11)$$

$$w^T x_i + b \leq -1, y_i = -1 \quad (2.12)$$

Eşitlik 2.11 ve Eşitlik 2.12'nin tek denklem olarak ifade edilmiş hali ise Eşitlik 2.13'te verilmiştir.

$$y_i(w \cdot x_i + b) \geq 1 \quad (2.13)$$

Sınır düzlemleri arası $2/\|w\|$ mesafesinin maksimum olması için $\|w\|$ 'nin minimum değeri bulunmalıdır. Bu bir optimizasyon problemi olarak tanımlanır ve problemin çözümü için Lagrange Çarpanları yöntemi kullanılır (Eşitlik 2.14).

$$L(w, b, a) = \frac{1}{2} \|w\|^2 - \sum_{i=1}^n a_i y_i (w \cdot x_i + b) + \sum_{i=1}^n a_i \quad (2.14)$$

Eşitlik 2.14'te a_i Lagrange çarpanlarıdır. Denklemin çözümü için Eşitlik 2.14'ün w ve b 'ye göre ayrı ayrı kısmi türevleri alınıp sıfıra eşitlenmelidir. Türev işleminin sonucunda Eşitlik 2.15 ve Eşitlik 2.16'deki koşullar elde edilir.

$$w = \sum_{i=1}^n a_i y_i x_i \quad (2.15)$$

$$\sum_{i=1}^n a_i y_i = 0 \quad (2.16)$$

Bu koşulların Eşitlik 2.14'te yerine konmasıyla denklem Eşitlik 2.17'deki gibi olacaktır. Görüldüğü üzere bu eşitlikte artık w ve b 'ye bağımlılık ortadan kalkmaktadır. Eşitlik 2.17'de a_i çözümünün bulunmasıyla w ağırlıkları hesaplanabilir ve optimizasyon problemine çözüm üretilebilir.

$$L(a) = \sum_{i=1}^n a_i - \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n a_i a_j y_i y_j (x_i \cdot x_j) \quad (2.17)$$

Son durumda karar fonksiyonu Eşitlik 2.18'deki gibi elde edilir ve yeni bir u test verisinin ilgili sınıfa ataması bu eşitlik üzerinden yapılır.

$$f(x) = \text{sgn}[(\sum_{i=1}^n a_i y_i x_i \cdot u) + b] \quad (2.18)$$

Doğrusal olmayan problemlerde ise eğitim verisine uygun bir dönüşüm yapılmakta ve farklı kernel (doğrusal, polinom, radyal, vb.) kullanımı ile doğrusal yaklaşımlar uygulanarak sınıflandırma yapılmaktadır.

2.7 Rastgele Alt Uzay k-En Yakın Komşuluk Sınıflandırıcısı

Diğer geleneksel sınıflandırıcılardan biri olan k-En Yakın Komşuluk algoritması (k-Nearest Neighbor, kNN), çok boyutlu uzayda birbirine yakın olan verilerin aynı sınıfa ait olduğu varsayımına dayanmaktadır. Sınıflandırıcı, çok boyutlu uzayda test verisinin eğitim verilerine olan mesafesini hesaplamaktadır. Mesafenin hesaplanmasında genellikle Öklid mesafesi kullanılmaktadır [38,39]. Burada “k” değerine bağlı olarak test verisine en yakın komşuluklar bulunur ve bu komşuluklardaki verilerin hangi sınıfa ait olduğuna bakılır. Bu k komşuluktaki çoğunluk hangi sınıfa ait ise yeni test verisi o sınıfa atanır. Sınıflandırıcının k değerinin seçilmesi özniteliklerin uzaydaki dağılımına bağlıdır. Bu durumda, farklı k değerlerinin denenmesiyle minimum hatayı veren k değeri, sınıflandırıcı için optimum k değeri olarak belirlenir.

Rastgele Alt Uzay (RAU) algoritması Diskriminant Analizi ve kNN sonuçlarını iyileştirmek için tercih edilen bir yöntemdir [Url-2]. Bu yöntem daha az bellek kullanımı ile de avantaj sağlamaktadır [Url-2]. RS yöntemi, öznitelikleri rastgele alt uzaylara bölmekte ve bu alt uzaylar için sınıflandırıcılar eğitmektedir. Nihai sınıflandırma, eğitilen bu sınıflandırıcıların kararlar değerlendirilerek oy çokluğuna göre yapılmaktadır. RS algoritması, temel olarak aşağıdaki parametreleri kullanır:

- 1) Her bir sınıflandırıcı için seçilen değişkenlerin sayısı (m)
- 2) Öznitelik sayısı (d)
- 3) Sınıflandırıcı sayısı (n)

Algoritma adımları şu şekildedir:

- 1) d adet öznitelik arasından rastgele m adet öznitelik seçilir.
- 2) Bu öznitelikler için eğitim yapılır.
- 3) Birinci ve ikinci adımlar n sınıflandırıcı sayısı kadar tekrarlanır.
- 4) Eğitilen sınıflandırıcıların skorlarının ortalaması alınır ve yüksek skorlu sınıf sonucuna göre nihai sınıflandırma yapılır.

Rastgele Alt Uzay kNN (RAU-kNN) algoritması yukarıdaki adımları takip ederek sınıflandırıcı sayısı kadar kNN algoritmasını alt uzaylar için çalıştırır. Eğitilen her bir alt uzayda test verileri k komşuluğa göre sınıflandırılır ve sınıflandırıcı çıktılarının verdiği skora göre oy çokluğu hesaplanarak nihai kNN sınıflandırması yapılır.

2.8 Rastgele Alt Uzay Diskriminant Sınıflandırıcısı

İstatistiksel karar verme yöntemlerinden biri olan Diskriminant Analizi (DA), verinin ait olduğu sınıfı belirleyen bir fonksiyonun üretilmesi için gruplar arasındaki farklılığı maksimize etmeye çalışan bir yöntemdir [40]. Bu amaçla sınıflar arasındaki mesafeyi maksimize edecek şekilde yeni boyutlar oluşturulur.

Sınıflandırma öncesi, eğitim seti verilerinin hangi sınıflara ait oldukları bilinmelidir. DA, burada bazı varsayımlar kullanılmaktadır. Bunlardan biri, bağımsız değişkenlerden birisinin başka bir bağımsız değişkenin doğrusal bileşimi olmadığını varsaymasıdır. Diğer varsayım ise değişkenlerin normal dağılıma sahip olduğunun kabul edilmesidir. Her özelliğin aynı varyans değerine sahip olduğu ve her değişken değerlerinin ortalama olarak aynı miktarda değiştiği varsayılır. Yapılan varsayımlarla DA, her bir sınıf için verinin ortalama ve varyansını tahmin eder. Bu sayede doğrusal diskriminant fonksiyonlarının hesaplanmasında kullanılan formüllerin elde edilmesi kolaylaşır [40].

DA, test kümesinin her bir sınıfa ait olma olasılığı hakkında tahminlerde bulunur ve en yüksek olasılık değerine göre sınıflandırma yapar. Örneğin elimizde X_1 ve X_2 sınıflarından oluşan iki sınıflı bir sınıflandırma problemi olduğu düşünülün. Bu sınıflar için 3 adet öznitelik kullanıldığı varsayalım. Diskriminant fonksiyonun üretilmesinde takip edilen adımla şu şekildedir:

- 1) İki sınıftaki örneklerin global ortalaması (M) bulunur.
- 2) Sınıflar için ayrı ayrı ortalama vektörü (M_i) hesaplanır ($i=1,2$).

- 3) Sınıflar için ayrı ayrı kovaryans matrisi (C_i) hesaplanır ($i=1,2$).
- 4) Sınıf içi dağılım matrisi (C) hesaplanır.
- 5) Diskriminant fonksiyonları (F_i) oluşturulur ($i=1,2$).

Yukarıda ifade edilen 1-4 adımların hesaplanmasının ardından Eşitlik 2.19'da en genel haliyle verilen diskriminant fonksiyonu hesaplanarak (beşinci adım) F_i değerinin sonucuna göre test verisinin sınıflandırılması yapılır.

$$F_i = M_i C^{-1} X^T - 0.5 M_i C^{-1} M_i^T + \ln(P_i) \quad (2.19)$$

Eşitlik 2.19'da X test verisini, P ise sınıf i 'nin ilk olasılığını ifade etmektedir.

Birinci adımda iki sınıfa ait n adet g özelliklerin (özniteliklerin) ortalaması hesaplanarak global ortalama Eşitlik 2.20-2.22 kullanılarak elde edilebilir.

$$K_1 = \frac{1}{P_1+P_2} \left[\sum_{n=1}^{P_1} (g_{1,n})_{X_1} + \sum_{n=1}^{P_2} (g_{1,n})_{X_2} \right] \quad (2.20)$$

$$K_2 = \frac{1}{P_1+P_2} \left[\sum_{n=1}^{P_1} (g_{2,n})_{X_1} + \sum_{n=1}^{P_2} (g_{2,n})_{X_2} \right] \quad (2.21)$$

$$K_3 = \frac{1}{P_1+P_2} \left[\sum_{n=1}^{P_1} (g_{3,n})_{X_1} + \sum_{n=1}^{P_2} (g_{3,n})_{X_2} \right] \quad (2.22)$$

Eşitlik 2.20-2.22'de P_1 birinci sınıfa ait özniteliklerin gözlem sayısını ve P_2 ikinci sınıfa ait özniteliklerin gözlem sayısını ifade etmektedir. K_1 , K_2 ve K_3 değerlerinin hesaplanmasıyla $M = [K_1 \ K_2 \ K_3]$ global değeri bulunur. Ardından sınıflar için ayrı ayrı ortalama vektörler Eşitlik 2.23 ve Eşitlik 2.24 ile bulunur.

$$M_1 = \left[\frac{1}{P_1} \sum_{n=1}^{P_1} (g_{1,n})_{X_1} \quad \frac{1}{P_1} \sum_{n=1}^{P_1} (g_{2,n})_{X_1} \quad \frac{1}{P_1} \sum_{n=1}^{P_1} (g_{3,n})_{X_1} \right] \quad (2.23)$$

$$M_2 = \left[\frac{1}{P_2} \sum_{n=1}^{P_2} (g_{1,n})_{X_2} \quad \frac{1}{P_2} \sum_{n=1}^{P_2} (g_{2,n})_{X_2} \quad \frac{1}{P_2} \sum_{n=1}^{P_2} (g_{3,n})_{X_2} \right] \quad (2.24)$$

Birinci sınıfa ait kovaryans matrisi C_1 Eşitlik 2.25 ve 2.26 kullanılarak elde edilir. Benzer şekilde ikinci sınıfa ait kovaryans matrisi C_2 Eşitlik 2.27 ve Eşitlik 2.28 ile bulunur.

$$A = \sum_{k=1}^3 \sum_{n=1}^{P_1} (g_{k,n})_{X_1} - M \quad (2.25)$$

$$C_1 = \frac{1}{P_1} A A^T \quad (2.26)$$

$$B = \sum_{k=1}^3 \sum_{n=1}^{P_1} (g_{k,n})_{X_2} - M \quad (2.27)$$

$$C_2 = \frac{1}{P_2} B B^T \quad (2.28)$$

Sınıf içi dağılım matrisi C Eşitlik 2.29 kullanılarak elde edilir. Son olarak hesaplanan parametreler Eşitlik 2.19'da yerine konarak iki sınıf için F fonksiyonunun değeri hesaplanır. Gözlemlenen değerlerin büyüklükleri karşılaştırılır ve sınıf ataması yapılır.

$$C = \frac{P_1}{P_1+P_2} C_1 + \frac{P_2}{P_1+P_2} C_2 \quad (2.29)$$

Rastgele Alt Uzay Diskriminant (RAU-D), RAU-kNN yönteminde olduğu gibi öznitelikleri rastgele alt uzaylara böler ve bu alt uzaylar için eğitim yapar. Bu sınıflandırıcıların sonucuna bağlı olarak test verisi oy çokluğuna göre ilgili sınıfa atanır.

2.9 Gradyan Ağırlıklı Sınıf Aktivasyon Haritalama

Gizli katmanlardaki yüksek düzeyde soyutlama nedeniyle yorumlanabilirlik ESA modellerinde bir sorun olarak kabul edilir [41]. Ağların sınıfa özgü ayırt edici özelliklerini görselleştirmek ve ESA ağırlıklarını yorumlamak için Gradyan-ağırlıklı Sınıf Aktivasyon Haritaları (Gradient-weighted Class Activation Mapping, Grad-CAM) yöntemi uygulanabilmektedir. Bu yöntem, sınıflandırılan test verisi için ağırlıklarını kullanarak ortalama bir ısı haritası üretmekte ve verideki ayırt edici özellikleri vurgulamaktadır. Grad-CAM görüntüleri sayesinde sınıflandırılan ayırt edici özelliklerin görüntünün hangi bölgelerinde baskın veya baskın olmadığı görselleştirilebilmektedir [42].

Grad-CAM yönteminde ilk olarak geri yayılım ile “ c ” sınıfına ait Softmax öncesi skor değerinin (y_c) evrişim katmanından elde edilen aktivasyon haritasına (A^k) göre gradyan değeri hesaplanır. Nöron önem ağırlıklarını (a_k^c) elde etmek için geriye doğru akan bu gradyanlara, genişlik (i) ve yükseklik (j) boyutlarına göre global ortalama havuzlama işlemi uygulanmaktadır (Eşitlik 2.30).

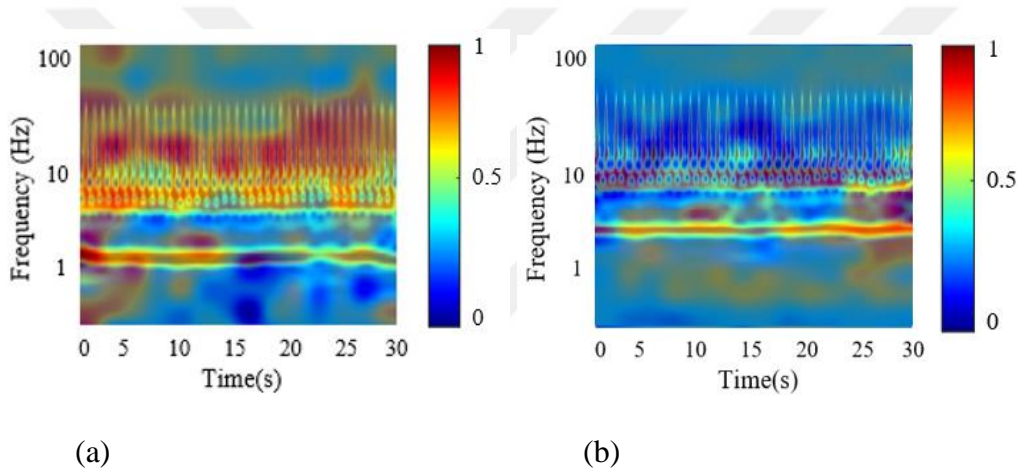
$$a_k^c = \frac{1}{Z} \sum_i \sum_j \frac{\partial y^c}{\partial A_{ij}^k} \quad (2.30)$$

Eşitlik 2.30'un uygulanmasının ardından ağırlıklı aktivasyon haritaları, ReLU aktivasyon fonksiyonu ile Eşitlik 2.31'deki gibi elde edilir. Haritaların doğrusal

kombinasyonuna ReLU uygulanmasının sebebi, yalnızca ilgili sınıf üzerinde olumlu etkisi olan özniteliklerle ilgilenilmesidir. Şekil 2.17’de OUA kesiti ve OUA olmayan bir kesit için skalogram görüntülerinin Grad-CAM çıktıları örnek olarak gösterilmiştir.

$$L_{Grad-CAM}^c = ReLU(\sum_k a_k^c A^k) \quad (2.31)$$

Şekil 2.17’de görüldüğü üzere EKG kayıtlarına ait OUA olmayan ve OUA’nın gerçekleştiği ana ait skalogram görüntülerinin Grad-CAM çıktılarında fizyolojik ve morfolojik farklılıklardan dolayı ayırt edici özellikler gözle görülür bir şekilde farklı renk tonlamalarında ifade edilmiştir. Burada kırmızı bölgeler, ağırlıkların baskın olduğu yerleri ifade ederken mavi renkteki tonlamalar ise ağırlıkların düşük olduğu bölgeleri vurgulamaktadır.



Şekil 2.17 : Örnek Grad-CAM görüntüleri (a) OUA olmayan kesit, (b) OUA kesiti.

2.10 OUA Tespiti ve Tahmini Alanında Öne Çıkan Çalışmalar

Gece boyu uyku laboratuvarında kaydedilmiş PSG kayıtları OUA şüphesi ile gelen kişilerin hastalık tanısında altın standart olarak kabul edilmektedir. Bu kayıtların uzman hekimler tarafından incelenmesi hem zaman gerektiren hem de tecrübe gerektiren bir süreçtir. İlerleyen teknolojinin sunduğu imkanlar ile gelişen yapay zekâ uygulamaları, otomatik olarak bu kayıtların analiz edilmesini ve hastalığın tanısına veya tahminine yönelik bilgiler sunan modellerin geliştirilmesini sağlamıştır. Performans başarısının objektif kriterlerle değerlendirildiği bu modellerde gözlemlenen yüksek doğruluk başarısı, hem maliyet hem de hız açısından hekimlere bir karar destek mekanizması sunmaktadır. Bunun yanında PSG kayıtlarındaki çok

sayıdaki sensör bağlantılarının aksine daha az sensör kullanımı ile kişilerin daha konforlu bir uyku süreci geçirmesi sağlanmaktadır.

OUA tespiti çalışmalarında genellikle EKG, oksijen doyumu, EEG, EMG ve hava akımı gibi PSG kayıtları tek başına veya bir arada kullanılmaktadır. Yapılan araştırmaların birçoğunda, bu kayıtların zaman ve frekans alanı bilgilerinin analiz edilerek doğrusal olmayan özelliklerin öznitelik mühendisliği ile tespit edildiği görülmektedir [43-47]. Fakat bu çalışmalarda karşılaşılan en büyük zorluklardan biri doğru özniteliklerin kaç adet ve hangi kriterlere göre seçileceğidir. Bu bağlamda, ayırt edici özelliklerin belirlenmesinde araştırma konusu ile ilgili yeterli bilgi ve deneyime sahip uzman araştırmacılara ihtiyaç duyulmaktadır.

ESA, giriş ve çıkış arasındaki karmaşık işlevleri öğrenerek sınıflar arasındaki ayırt edici özellikleri otomatik olarak tespit eden bir tür derin sinir ağıdır. Bu ağlarda öznitelikler evrişim katmanları ile otomatik olarak çıkarıldığından, manuel öznitelik çıkarımının doğurduğu sorunlara çözüm sunulmaktadır. Genel olarak, derin öğrenme modelleri iki boyutlu (2B) sinyalleri işlemek için kullanılır, ancak çoğu durumda biyolojik sinyaller tek boyutludur (1B). Bazı araştırmalar, 2B girdi görüntüleri gerektiren modeller üzerinde değişiklikler yaparak bu modellerin 1B sinyallerin sınıflandırmasında kullanılmasını sağlarken, bazıları da 1B sinyallere dalgacık dönüşümü [48-50] ve Kısa Zamanlı Fourier Dönüşümü (KZFD) [51-54] uygulayarak 2B skalogram ve spektrogram görüntüleri ile ağı beslenmesini sağlamaktadır. Bu sayede yalnızca zaman-genlik bilgisini kullanmak yerine hem zaman hem de frekans özellikleri bir arada değerlendirilerek, biyolojik sinyallerin çok boyutlu analizinin yapılması mümkün olmaktadır.

Singh ve Majumder, EKG kayıtlarına ait skalogram görüntülerini kullanarak OUA tespiti yapan bir AlexNet modeli önermiştir [50]. Önerilen ağda, 60 saniye uzunluğunda kesitler kullanılmış ve ESA sınıflandırmasında OUA kesitlerinin %90 hassasiyet ve %86,22 doğrulukla tespit edildiği gözlemlenmiştir.

Zhang ve diğerleri, EKG kayıtlarını kullanarak ESA ve LSTM (Long Short Term Memory) yöntemlerini bir arada kullanan bir uyku izleme modeli önermiştir [55]. Önerilen model OUA olaylarının başlangıç ve bitiş anlarını tespit etmekte ve bu kesitleri sınıflamaktadır. 10 saniye uzunluğunda örtüşen pencerelerin kullanıldığı

durumda elde edilen sonuçlara göre OUA kesitlerinin yüksek hassasiyet ve özgüllükle tespit edildiği gözlemlenmiştir.

Shen ve diğerleri, çok ölçekli 1B-ESA ve Ağırlıklı Kayıp Zaman Bağımlı (weighted-loss time-dependent) yöntemlerini kullanarak uyku apnesini kesit başına tanımlamada %89,4 doğrulukla tespit eden bir model sunmuştur [56].

Gao ve diğerleri, EKG kayıtlarında bir R dalgasından sonraki R dalgasına kadar geçen süre olan RR aralığını ve R tepe genliklerini kullanarak apne tespiti yapan bir 1B-ESA modeli önermiş ve çalışmanın sonucunda %87,9 doğruluk gözlemlemiştir [57].

Singh ve diğerleri, hem RR-zaman serisi hem de EKG sinyalinden türetilen solunum (ECG Derived Respiration, EDR) özelliklerini kullanarak uyku apnesini tespit etmiştir [58]. Araştırmacılar burada, RR zaman serisi ve EDR sinyallerinin yeniden yapılandırılmış bileşenlerinden elde edilen öznitelikler ile yığılmış otomatik kodlayıcı tabanlı derin sinir ağları (deep neural networks, DNN) ve destek vektör makinesi kullanılarak normal ve apne kesitlerinin sınıflandırmasını yapmıştır.

Chen ve diğerleri, apne tespiti için önceden eğitilmiş ResNet ağının farklı bir versiyonunu önermiş ve ResNet'e kıyasla yaklaşık %1 doğruluk artışı gözlemlemiştir [59].

Li ve diğerleri, seyrek otomatik kodlayıcı (sparse auto-encoder) kullanarak EKG sinyallerinden türetilen öznitelikleri sınıflandırmak için DVM ve Yapay Sinir Ağı (YSA) tabanlı bir sınıflandırıcı kullanmıştır [60]. Çalışmanın sonucunda kesit başına sınıflandırmanın doğruluğu %84,7 ve duyarlılık %88,9 olarak gözlemlenmiştir.

Song ve diğerleri, OUA tespiti için Gizli Markov Modeli (Hidden Markov Model, HMM) yöntemini kullanarak EKG sinyallerinden zaman ve frekans ölçeklerinde öznitelikler tespit etmiştir [14]. Öznitelik mühendisliğinin uygulandığı bu çalışmada gözlemlenen bulgulara göre, HMM modeli %86,2 doğruluk ve %82,6 duyarlılık ile apne sınıflandırması yapmıştır.

Urtnasan ve diğerleri, EKG sinyallerini 10 saniyelik kesitlere bölmüş ve uyku 1B-ESA, 2B-ESA, DNN modelleri, tekrarlayan sinir ağları, uzun kısa süreli bellek ve Kapılı Tekrarlayan Hücre (Gated Recurrent Unit, GRU) modellerinin apne tespitindeki performanslarını karşılaştırmıştır [52].

Wang ve diğeri, LeNet-5 mimarisi üzerinde iyileştirme çalışması yaparak bir dakikalık kesitlerde uyku apnesini tespit eden bir model önermiştir [61]. Kesit başına sınıflandırmada %87,6 doğruluk, %83,1 duyarlılık ve %90,3 özgüllük değerleri gözlemlenmiştir.

Urtnasan ve diğeri, tek kanal EKG kayıtlarını kullanarak OUA sınıflandırması için bir derin öğrenme mimarisi önermiştir [62]. Gözlemlenen sonuçlar, apne kesitlerini %90,8 doğruluk, %87 duyarlılık ve %87 kesinlik başarıyla ile sınıflandırmanın mümkün olduğunu göstermektedir.

Literatürdeki öne çıkan OUA çalışmalarının çoğunda OUA tespit edilmeye çalışıldığı; çok az sayıda çalışmanın apne gerçekleşmeden önce bunu tahmin etmeye odaklanıldığı görülmektedir. OUA esnasında karşılaşılan olası semptomların meydana gelmesinden önce bu semptomların ön görülebilmesi, hasta sağlığı açısından etkili bir araç olabilmektedir. Bunun yanında, anormal bir solunum durumunun ön görülebilmesi, tedavi amaçlı uygulanan APAP tedavisinde basınç seviyelerinin daha etkin bir şekilde yönetilmesini sağlayabilir. Ayrıca tahmin modelleri, OUA hastaları hakkında tutarlı ve destekleyici bilgiler sunarak uzman hekimler için de yardımcı bir araç olarak kullanılabilir. Bu motivasyonla yapılan araştırmaların birinde, Waxman ve diğeri gelecekteki OUA ve hipopne olaylarını tahmin etmek için apne anı öncesindeki farklı uzunlukta ve farklı tahmin sürelerini kullanarak LAMSTAR sinir ağı modeli ile tahmin çalışması yapmıştır [63]. 74 denekten kaydedilen altı tip fizyolojik sinyalde ayrık dalgacık dönüşümü uygulanarak apne öncesindeki solunumu normal solunumdan ayırt eden öznitelikler tespit edilmiştir. Önerilen tahmin modeli, olayları 30 saniyeye kadar önceden tahmin etmek için 30 saniyelik kesitler kullanıldığı durumda %80,26 duyarlılık, %72,78 özgüllük ve %75,1 pozitif tahmin değeri ile en yüksek performans sonuçlarını sunmuştur.

De Falco ve diğeri, EKG kayıtlarını kullanarak üç dakikalık kesitlerden elde edilen bilgilere göre takip eden dakikada OUA'nın gerçekleşip gerçekleşmeyeceğini tahmin eden bir model önermiştir [64]. 35 deneğin kalp atım hızı değişkenliği parametrelerinin kullanıldığı çalışmada algoritmanın geliştirilmesi için IF-THEN kuralları uygulanmış ve ortalama %84,26 başarı ile OUA kesitlerinin doğru tahmin edildiği gözlemlenmiştir.

Maali ve Al-Jumaily çeşitli tahmin süreleri için üç tip sinir ağını (Elman, Radyal Tabanlı Fonksiyon ve İleri Beslemeli Geri Yayılım) karşılaştırmıştır [65]. Burun hava akışı, göğüs ve karın hareket sinyallerinin kullanıldığı çalışmada ayırt edici istatistiksel özellikler, dalgacık dönüşümünün katsayılarından ve ham sinyallerden çıkarılmıştır. Gözlemlenen sonuçlara göre, en yüksek performans ortalama 0,866 eğri altında kalan alan değeri ile ileri beslemeli sinir ağı kullanıldığında (Area Under Curve, AUC) gözlemlenmiştir.

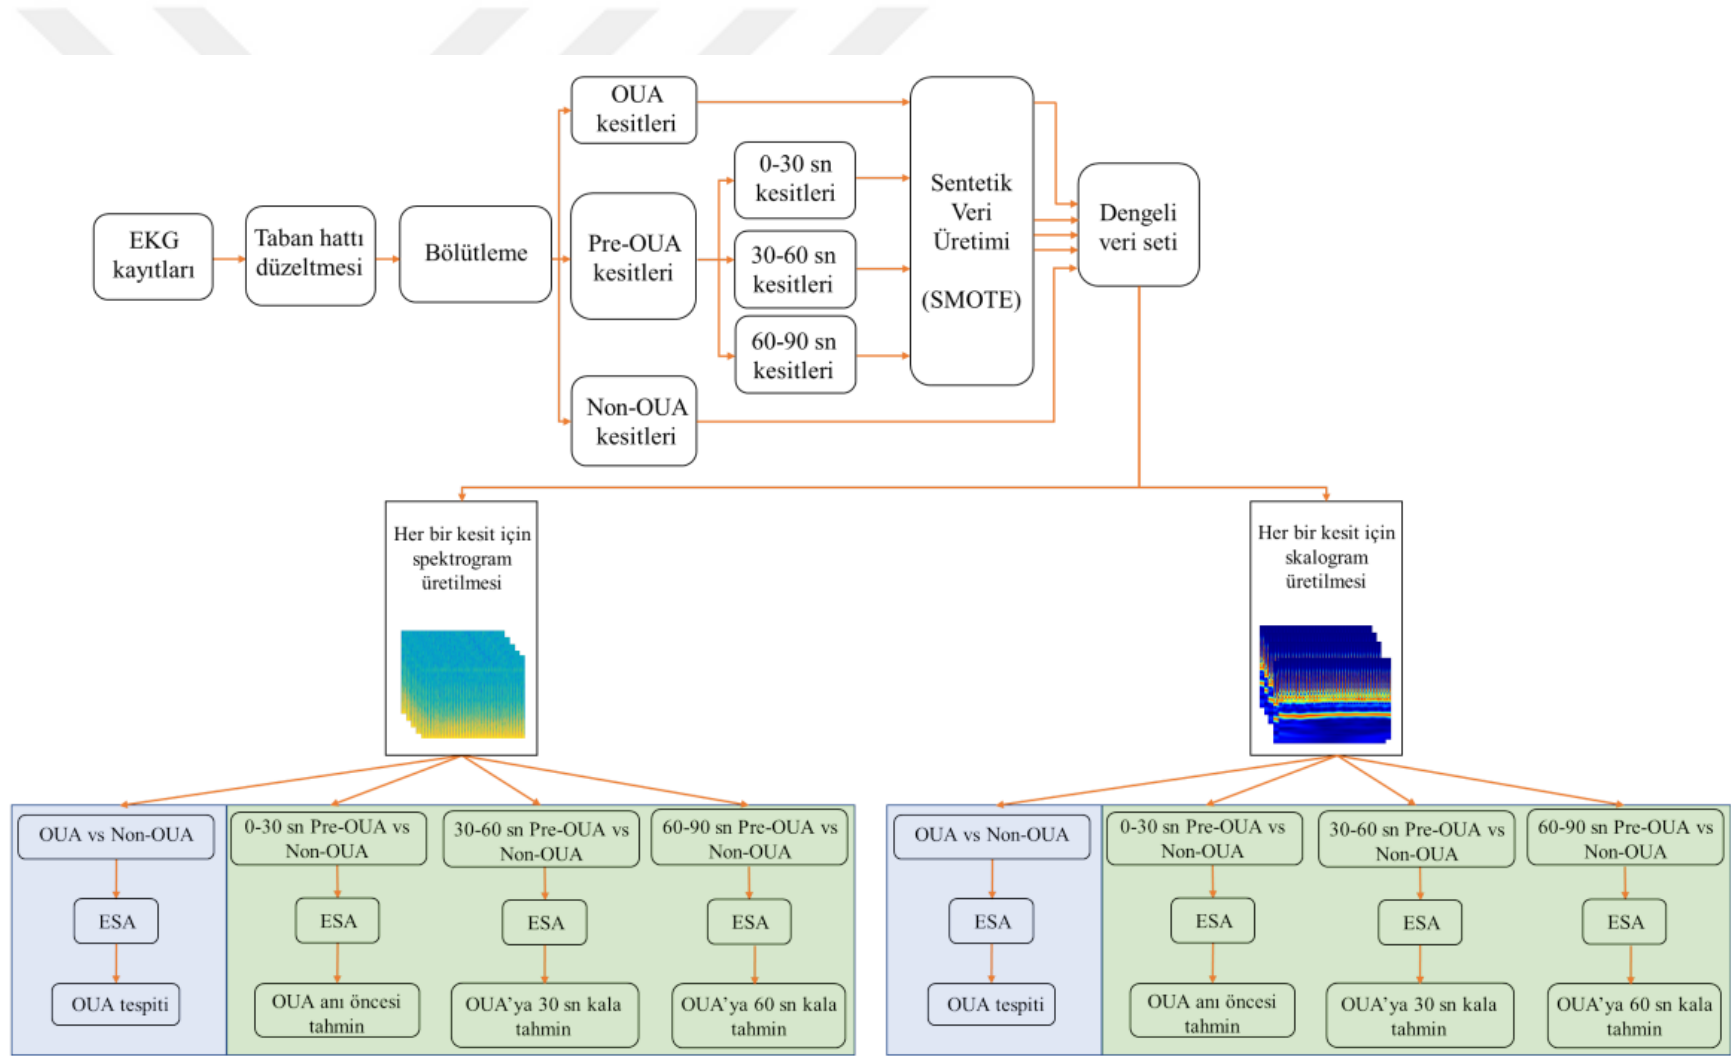


3. MATERYAL VE YÖNTEM

Bu bölümde ilk olarak kullanılan veri setlerine, bu veri setlerinden sinyal seçimi yapılırken hangi kriterlerin dikkate alındığına değinilmiştir. Ardından, sinyaller üzerinde uygulanan taban hattı düzeltmesi, Z-Skoru Normalizasyonu ve bölütleme işlemleri hakkında bilgiler verilmiştir. Daha sonra, çalışma kapsamında ele alınan ESA modellerinde aşırı öğrenme durumunu engellemek ve farklı sınıflara ait bölütler için dengeli bir veri tabanı oluşturabilmek adına uygulanan sentetik veri artırımı yöntemine ve bu yöntemin sonucunda elde edilen örnek sayılarına değinilmiştir. Çalışmanın son ön işleme adımında ise 1B boyutlu EKG sinyallerinin 2B skalogram ve spektrogram görüntülerine dönüştürülmesi işlemleri hakkında bilgiler verilmiştir. Oluşturulan bu skalogram ve spektrogram görüntüleri ESA mimarilerinde girdi olarak kullanılmıştır. OUA tespiti ve farklı tahmin zamanları için eğitilen modellerin performansı, test verileri ve 10 kat çapraz validasyon yöntemi kullanılarak analiz edilmiştir. Önerilen çalışmada izlenen adımlara ait akış şeması Şekil 3.1’de verilmiştir.

3.1 Kullanılan Veri Setleri

Tez çalışması kapsamında eğitim, validasyon ve test işlemleri için çevrimiçi ortamda halka açık olarak paylaşılan HomePap ve ABC veri setleri kullanılmıştır [66]. Bu iki veri setinin seçilmesinin nedenlerinden biri, farklı kaynaklardan kaydedilen EKG kayıtlarının farklı varyasyonlar içermesi sonucu olarak kapsamlı bir çalışma yürütebilmek ve daha güvenilir sonuçlara ulaşabilmektir. Bir diğer sebebi ise ESA mimarilerinin çok sayıda örnek içeren büyük veri setine ihtiyaç duymasıdır. Transfer öğrenme her ne kadar bu sorunu çözmeye çalışsa da transfer öğrenmenin kullanılmadığı ESA mimarilerinde, veri setindeki örnek sayısının mümkün olduğunca yüksek olması, az veya aşırı öğrenme durumu ile karşılaşmamak açısından avantaj sağlamaktadır. Yapılan çalışmada hem transfer öğrenme hem de sıfırdan eğitim uygulamaları ele alındığından, daha güvenilir sonuçların elde edilebilmesi için veri tabanının oluşturulması aşamasında iki adet veri setinin bir araya getirilmesi tercih edilmiştir.



Şekil 3.1 : Çalışmanın akış diyagramı.

HomePap veri seti, laboratuvar ve ev ortamında gece boyu uyku esnasında kaydedilmiş PSG kayıtlarından oluşmaktadır. Bu kayıtlar arasından OUA etkinliklerinin başlangıç anlarının Amerikan Uyku Tıbbı Akademisi (American Academy of Sleep Medicine, AASM) standartlarına göre etiketlenmiş laboratuvar kayıtları kullanılmıştır. Bu laboratuvar kayıtları gece boyu kaydedilmiş toplam 191adet PSG kaydından oluşmaktadır. Çalışma kapsamına Merkezi Uyku Apnesi, Mikst Uyku Apnesi ve kardiyovasküler hastalıklar dahil edilmemiştir. Bu nedenle, OUA içermeyenler kayıtlar çalışmada kullanılan veri tabanına dahil edilmemiştir. Bazı kayıtlarda ise hasta hareketlerinden veya uyku esnasında sensör bağlantısının kopmasından kaynaklı olabilecek bozulmalar gözlemlenmiştir. Bu kayıtlar da veri tabanına dahil edilmemiştir. Bu durumda hafif seviyeden ağır derece seviyesine kadar tanısı konmuş OUA hastalarına ait toplam 113 adet PSG kaydı elde edilmiştir. Son olarak, PSG kayıtları arasından EKG kayıtları seçilmiş ve çalışmadaki veri tabanı oluşturulmuştur. HomePap veri setinde dikkate alınan kriterler sonucu elde edilen bu 113 adet EKG kaydına ait hasta ve kayıt bilgileri Çizelge 3.1’de verilmiştir.

Çizelge 3.1 : HomePap veri setinden seçilen kayıtlara ait bilgiler.

AHI	28,74 ± 19,31
Yaş (yıl)	48,40 ± 12,40
Toplam Uyku Süresi (saat)	5,54 ± 1,20
Vücut Kitle İndeksi (kg m⁻²)	35,81 ± 8,50
Örnekleme Frekansı	256 Hz


ABC veri seti, hafif seviden ağır seviyeye kadar OUA hasta kayıtları içeren toplam 49 adet PSG kaydından oluşmaktadır. Yukarıda bahsedilen kriterler bu veri setinde de uygulanmış ve toplamda 39 adet EKG kaydı çalışmada kullanılan veri tabanına dahil edilmiştir. Bu durumda veri tabanı için toplamda 152 hastaya ait EKG kaydı elde edilmiştir. ABC veri setinden ayıklanan kayıtlara ait hasta ve kayıt bilgileri Çizelge 3.2’de özetlenmiştir.

Çizelge 3.2 : ABC veri setinden seçilen kayıtlara ait bilgiler.


AHI	32,43 ± 23,78
Yaş (yıl)	48,83 ± 9,91
Toplam Uyku Süresi (saat)	6,12 ± 1,17
Vücut Kitle İndeksi (kg m⁻²)	36,21 ± 3,23
Örnekleme frekansı	256 Hz

3.2 Taban Hattı Düzeltmesi ve Z-Skoru Normalizasyonu

EKG ölçümleri sırasında elektrik yüklü elektrotlar veya kişi hareketlerinden kaynaklanan düşük frekanslı gürültüler gözlemlenmektedir. Taban hattının düzeltilmesi, EKG kaydındaki bu etkileri filtrelemek için uygulanmaktadır. Bu gürültü 0,5 Hz kesim frekansına sahip sonlu darbe yanıtı yüksek geçiren sıfır fazlı filtre ile filtrelenebilmektedir [67]. Taban hattı düzeltilmesi için örnek bir gösterim Şekil 3.2’de verilmiştir.



(a)



(b)

Şekil 3.2 : (a) Taban hattı düzeltilmesi öncesi EKG kesiti, (b) Taban hattı düzeltilmesi sonrası EKG kesiti [68].

Z-Skoru normalizasyonu, sinyal genliğini standartlaştırmak için uygulanan temel ön işlemlerden biridir. Bu sayede farklı sinyaller arasındaki genlik farklılıkları belirli bir standartta analiz edilebilmektedir (Eşitlik 3.1).

$$z = \frac{x - \mu}{\sigma} \quad (3.1)$$

Eşitlik 3.1’de x girdi sinyalini, μ sinyalin ortalama değerini ve σ sinyalin standart sapmasını ifade etmektedir.

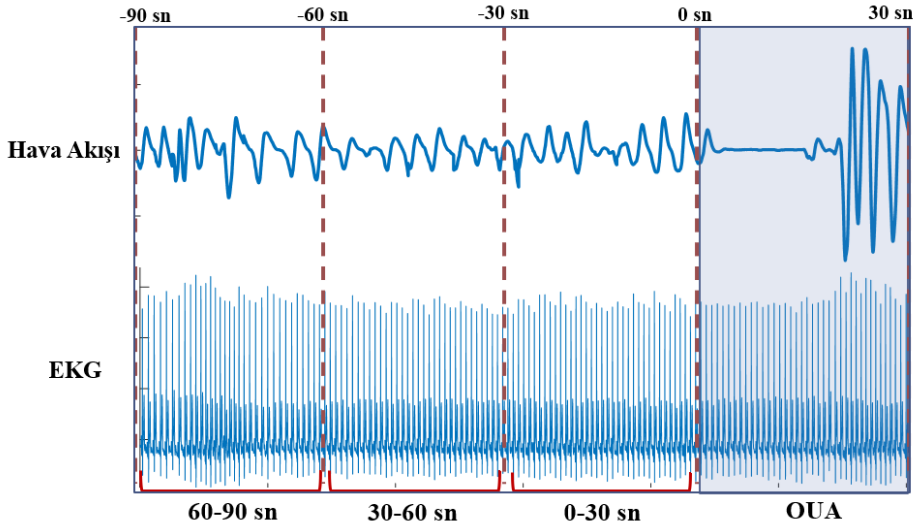
3.3 Sinyallerin Bölütlenmesi

Waxman ve diğerleri, yaptıkları apne tahmini çalışmasında farklı kesit sürelerinin tahmin performansına etkisini araştırmışlardır [63]. Bu araştırmanın sonucunda, apne başlangıç anı öncesinde seçilen 30 saniye uzunluğundaki kesitlerin gelecekteki bir apne olayına yönelik en fazla bilgiyi sunduğunu gözlemlenmiştir. Waxman, farklı kesit uzunluklarını da karşılaştırmış ve kesit süresinin artırıldığı durumda sınıflandırma tahmin başarısının düştüğünü vurgulamıştır. Bu bilgilerden faydalanarak tez çalışması kapsamında kullanılan EKG kayıtları, uzunluğu 30 saniye olan Pre-OUA (OUA öncesi) ve Non-OUA (OUA içermeyen) olacak şekilde kesitlere bölütlenmiştir. Ek bir çalışma olarak, apne olaylarının gerçekleştiği anlar (OUA başlangıcından itibaren 30 saniye sonrasına kadar olan aralıklar) da dikkate bölütlenerek önerilen modellerin OUA tahminindeki başarısının yanında OUA tespitindeki başarısı da araştırılmıştır.

Farklı tahmin sürelerinin OUA tahminindeki başarısını araştırmak için Pre-OUA kesitleri apne anı öncesi farklı zamanlar için örtüşmeyecek şekilde bölütlenmiştir. Burada apne anının hemen öncesinden başlayarak 30 saniye öncesine kadar olan bölüm “0-30 saniye kesiti”, apne anından 30 saniye öncesinden başlayarak 60 saniye öncesine kadar olan bölüm “30-60 saniye kesiti” ve apne başlangıç anının 60 saniye öncesinden başlayarak 90 saniye öncesine kadar olan bölüm “60-90 saniye kesiti” olarak adlandırılmıştır.

Farklı tahmin sürelerine ait bu kesitler herhangi bir apne olayı içermeyecek şekilde seçilmiştir. Buradaki amaç, eğitim esnasında yanlılık (bias) durumunun yaşanmaması için bir standart uygulanmasıdır. Non-OUA, normal solunumun devam ettiği ve

herhangi bir OUA, MUA veya Mikst apne içermeyen kesitlerden oluşmaktadır. Şekil 3.3'te bölütlenen Pre-OUA kesitleri için bir örnek gösterilmiştir.



Şekil 3.3 : Pre-OUA aralıklarının bölütlenmesi.

3.4 Sentetik Veri Artırımı

Pre-OUA kesitlerinin farklı tahmin süreleri için bölütlenmesinin ardından elde edilen kesit sayıları eğitim başarısı ve eğitimin yorumlanması açısından önemlidir. Ağır seviyedeki OUA hastalarında AHİ değerinin yüksek olduğu dikkate alındığında iki OUA olayı arasında geçen süre kimi zaman 30 saniye veya 60 saniyeden daha kısa olabilmektedir. Bir önceki bölümde de belirtildiği üzere 0-30 sn, 30-60 sn ve 60-90 sn içerisinde apne olayı gözlemlenen kesit var ise bu kesitler eğitimde yanlılık oluşturmaması için veri tabanına dahil edilmemiştir. Bu kriter dikkate alındığında farklı tahmin süreleri için elde edilen kesitlerinin sayısında farklılık görülebilecektir.

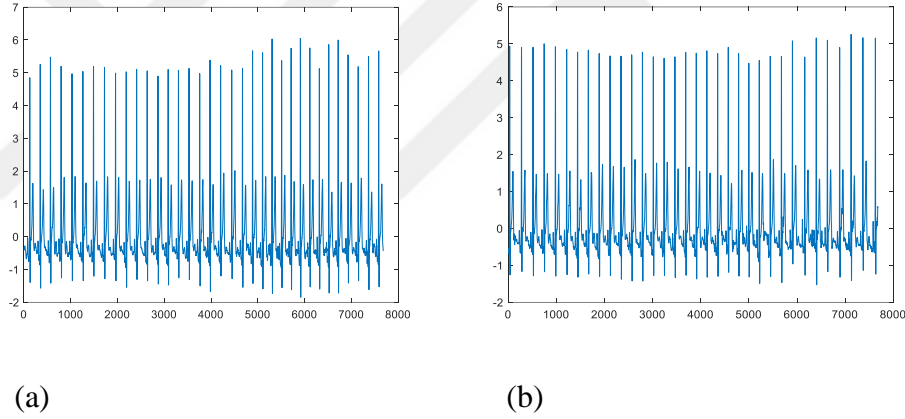
Bu amaçla ilk olarak bölütlenen kesit sayıları incelenmiştir. Yapılan gözlemler sonucunda OUA ve 0-30 sn kesit sayılarının en fazla olduğu görülmüştür. Bunu takiben 30-60 sn kesit sayısının daha az ve 60-90 sn kesit sayısının en az olduğu gözlemlenmiştir. Bunun nedeni apne anından geriye doğru gidildikçe başka bir apne olayına denk gelinmesi ve bu kesitlerin veri tabanına dahil edilmemesidir. Bu durumda veri tabanının %54,5'i Non-OUA, %14'ü OUA, %14'ü 0-30 sn, %9,45'i 30-60 sn ve %8,05'i 60-90 sn kesitlerinden oluştuğu görülmüştür.

EKG kesitlerine ait veri sayısında gözlemlenen dengesizlik problemi için Chawla ve diğerleri SMOTE (Synthetic Minority Oversampling Technique) yöntemini

önermişlerdir [69]. Bu yöntem aşırı öğrenme durumunu önlemek ve veri dağılımında denge kurabilmek için EKG zaman serilerini kullanarak sentetik yapay örnekler üretmektedir [70-72]. Eşitlik 3.2’de SMOTE algoritmasının sentetik veri üretmek için kullandığı formül verilmiştir.

$$x^{synthetic} = x^i + (x^j - x^i) \cdot \xi \quad (3.1)$$

Eşitlik 3.2’de seçilen örnek x^i , bu örneğin k-komşuluğundan rastgele seçilen örnek x^j , ve 0-1 aralığında seçilen değer ξ olarak gösterilmiştir. Algoritmaya göre, $(x^j - x^i)$ farkının ağırlıklandırılıp, x^i örneğine eklenmesi ve bu işlemin belirlenen tekrar sayısı kadar tekrarlanmasının ardında sentetik EKG verisi elde edilmektedir. Şekil 3.4’te örnek bir kesit için üretilmiş sentetik SMOTE çıktısı gösterilmiştir. Görsellerde yatay eksen örnek sayısını, dikey eksen ise sinyal genliğini ifade etmektedir.



Şekil 3.4 : (a) Orijinal EKG kesiti, (b) SMOTE algoritması ile üretilen sentetik EKG kesiti.

SMOTE ile sentetik veri üretimi sonrası her kesit için 13506 örnek elde edilmiştir. Bu durumda Non-OUA/OUA, Non-OUA/0-30 sn, Non-OUA/30-60 sn ve Non-OUA/60-90 sn sınıflandırmalarında eğitim, validasyon ve test için toplam 27012’şer kesit kullanılmış olacaktır. Sınıflandırma için veri tabanının %80’i eğitime, %10’u validasyona ve kalan %10’u test için ayrılmıştır. Sentetik veri artırımı öncesi ve sonrası için elde edilen kesit sayıları Çizelge 3.3’te verilmiştir.

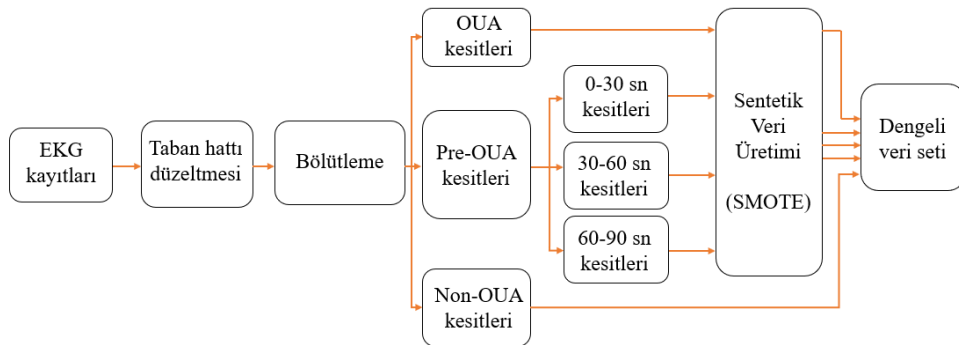
HomePap kesitlerinin sayısı, her iki sınıf için ABC veri setindeki kesit sayısının üçte ikisidir. Bu nedenle eğitim, validasyon ve test setleri için orantısal bir dağılım yapılmıştır. Eğitim setinin %60’ı HomePap veri setine, kalan %40’ı ise ABC veri setine

ait olacak şekilde oranlama yapılmıştır. Benzer şekilde, validasyon ve test kümeleri de aynı orana sahiptir.

Çizelge 3.3 : Orijinal kesit sayıları ve sentetik veri artırımı sonrası kesit sayıları.

	Orijinal Kesit Sayısı	Sentetik Veri Artırımı Sonrası Kesit Sayısı
OUA Kesitleri	3469	13506
0-30 sn Kesitleri	3469	13506
30-60 sn Kesitleri	2342	13506
60-90 sn Kesitleri	1995	13506
Non-OUA	13506	13506
Eğitim Seti	-	21610
Validasyon Seti	-	2701
Test Seti	-	2701

Rotasyon, kaydırma, ölçeklendirme, kırpma gibi geometrik dönüşümler 2B görüntülerden sentetik veri üretmek için kullanılan en yaygın yöntemlerdendir. Ancak, bu yöntemler EKG skalogram ve spektrogram görüntülerine uygulamak için uygun değildir. Bunun nedeni, bu sinyallerin zaman içinde değişkenlik göstermesi ve öznelik çıkarımı yapılsa bile özneliklerin hala zaman serilerinden ibaret olmalarıdır. Dolayısıyla, üretilen skalogram ve spektrogram görüntüleri üzerinde geometrik dönüşümler uygulandığı takdirde zaman alanı özellikleri bozulacaktır. Bu nedenle, sentetik veri üretimi ilk olarak zaman serileri üzerinde uygulanmış; ardından orijinal ve sentetik veriler kullanılarak skalogram ve spektrogram görüntüleri üretilmiştir. Uygulanan ön işlemlerin adımları ve dengeli veri setinin oluşturulması Şekil 3.5'te özetlenmiştir.



Şekil 3.5 : Uygulanan ön işlemler ve dengeli veri setinin oluşturulması.


3.5 Spektrogram Görüntülerinin Üretilmesi

Başarılı bir sınıflandırma için en önemli hususlardan biri özniteliklerin doğru seçilmesidir. Bu çalışmada EKG kesitlerinden özniteliklerin çıkarımı için zaman serisi verileri eğitim, validasyon ve test süreçlerinde girdi olarak kullanılmak üzere zaman ve frekans bilgisi içeren 2B spektrogram ve skalogram görüntülerine dönüştürülmüştür. KZFD, zamanla değişen özelliklere sahip yerel dalgaların hem anlık frekansını hem de anlık genliğini araştırmak için kullanılan bir yöntemdir [73]. KZFD ile bir kesitin frekans bileşenlerini zaman verilerine göre izlemek ve bu bileşenleri görüntü olarak temsil etmek mümkündür (Eşitlik 3.2).


$$KZFD\{x[n]\} = x[n, k] = \sum_{m=0}^{L-1} w[m] \cdot x[n + m] \cdot e^{-jm\left(\frac{2\pi k}{N}\right)} \quad (3.2)$$

Eşitlik 3.2’de $x[n]$ EKG kesitini, n zaman bileşenini, k frekans bileşenini ve $w[m]$ pencere fonksiyonunu temsil etmektedir. Pencere fonksiyonu seçiminde ESA performansına dayalı olarak, kabul edilebilir ve algılanabilir spektrogram görüntüleri üretmek için farklı pencere fonksiyonları, pencere boyutları ve örtüşme değerleri test edilmiştir. Yapılan analizler sonucunda, morfolojik değişiklikleri algılama ve dinamik olarak değişen EKG detaylarını ifade etmekteki verimliliği nedeniyle Hanning penceresi tercih edilmiştir [73]. Burada pencere uzunluğu 128 örnek ve örtüşme değeri 64 örnek olarak belirlenmiştir. Bu değerler, frekans dağılımında düşük varyanslı spektrogram görüntüleri üretmek için ampirik olarak belirlenmiştir. Üretilen her bir görüntünün boyutu, ağın giriş boyutuna göre belirlendiğinden, her spektrogram ağın gereksinimine göre yeniden boyutlandırılmıştır. OUA ve Non-OUA kesitlerine ait örnek spektrogram görüntüleri Şekil 3.6’da verilmiştir.


Anormal kalp aktiviteleri, spektrogram gösterimlerinde QRS komplekslerinin genlik ve frekans bileşenlerinin büyüklüklerinde değişimler gözlenmesine neden olabilmektedir (Şekil 3.6 (c)). 2B görüntülerdeki görsel olarak tespit edilmesi zor olan bu değişimler, daha sonrasında ESA modelleri tarafından tespit edilecek olup; iki sınıfı birbirinden ayırt eden özellikler olarak kullanılacaktır. Pre-OUA kesitlerine ait örnek spektrogram görüntüleri Şekil 3.7’de gösterilmiştir.




(a)



(b)




(c)




(d)


Şekil 3.6 : (a) Zaman ekseninde OUA kesiti, (b) Zaman ekseninde Non-OUA kesiti, (c) OUA kesitinin spektrogram görüntüsü ve (d) Non-OUA kesitinin spektrogram görüntüsü.



(a)



(b)



(c)

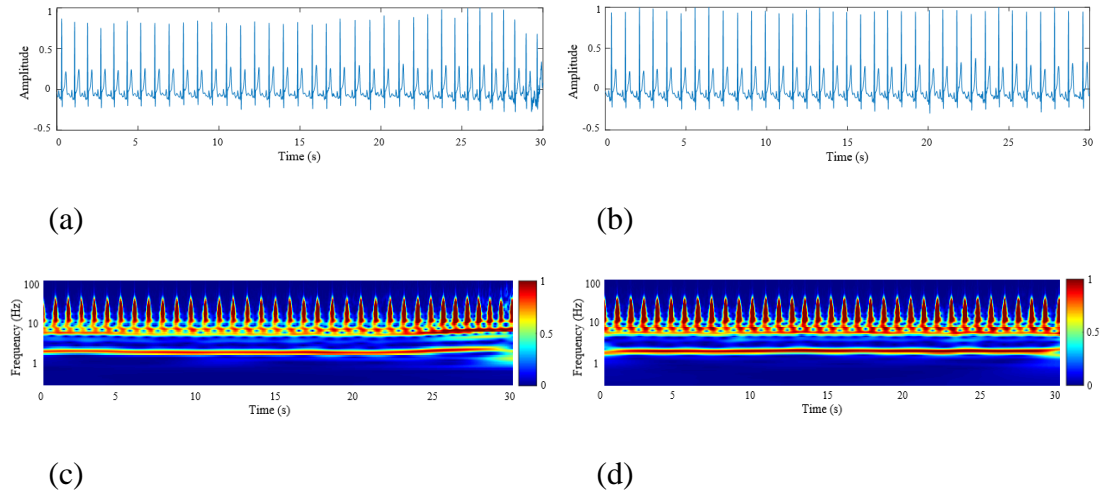
Şekil 3.7 : (a) 0-30 sn kesiti, (b) 30-60 sn kesiti ve (c) 60-90 sn kesiti için spektrogram görüntüleri.

3.6 Skalogram Görüntülerinin Üretilmesi

1B sinyalleri 2B zaman-frekans bileşenleri ile temsil etmenin bir diğer yolu, skalogram olarak adlandırılan Sürekli Dalgacık Dönüşümü (SDD) katsayılarının mutlak değerini kullanmaktır. KZFD ve SDD arasındaki temel fark, Fourier analizinin sinyali çeşitli frekanslardaki sinüzoidlerle temsil ederken SDD'nin çok ölçekli analiz yapabilmek için sinyali ana dalgacık kullanarak ölçeklendirilmiş veya kaydırılmış varyantlara ayrıştırmasıdır. Ana dalgacığın morfolojisi, sinyal ayrıştırılmasında daha az bozunuma sahip ve gürültüsü daha iyi filtrelenmiş bileşenler elde etmek açısından önemlidir [74]. Yapılan bir araştırmada Morse dalgacıklarının EKG sinyallerini verimli bir şekilde ayrıştıran uygun bir ana dalgacık ailesi olduğu vurgulanmıştır [49]. Bu nedenle, önerilen çalışmada ana dalgacık olarak oktav başına ses sayısı (voices per octave) 12'ye eşit olan Morse dalgacıkları kullanılmıştır. Skalogram üretimi sırasında kullanılan SDD dönüşümü eşitlik Eşitlik 3.3'te verilmiştir.

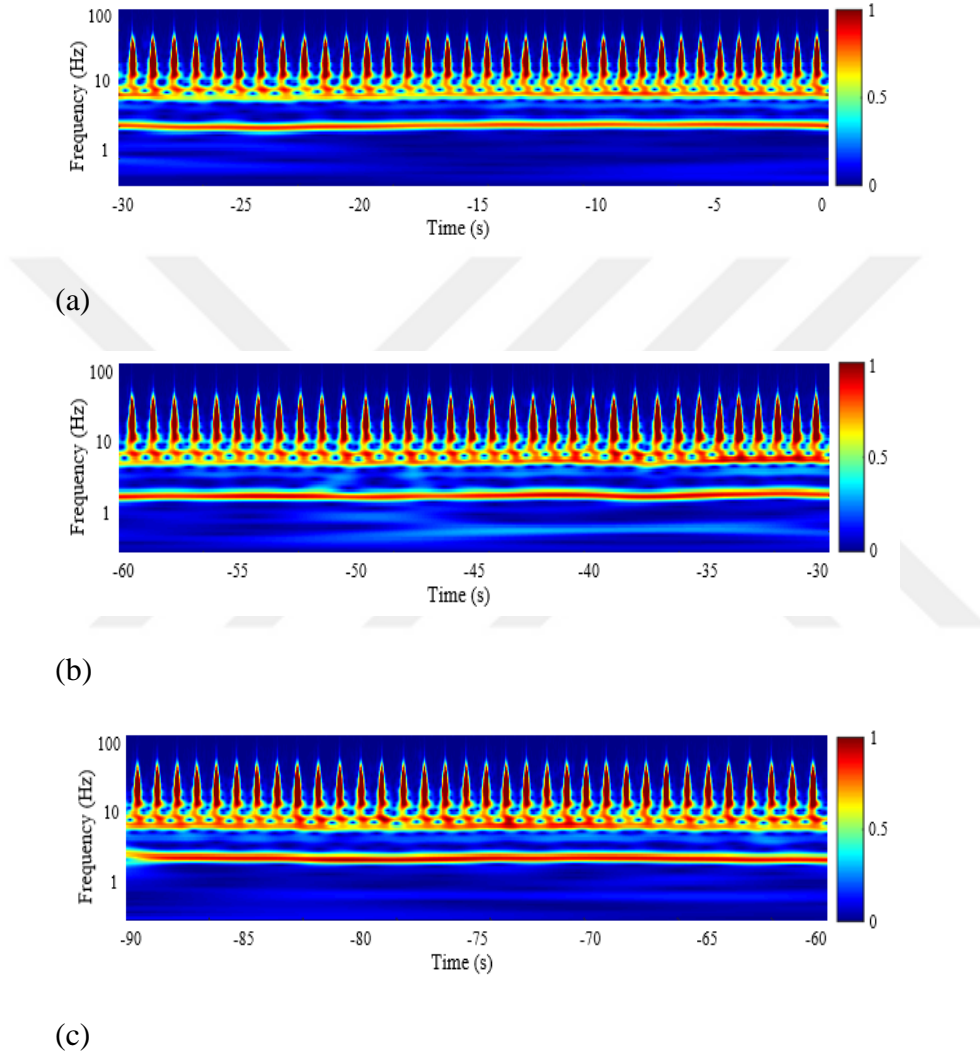
$$SDD(a, \tau) = \frac{1}{\sqrt{a}} \int_{-\infty}^{\infty} f(t) \psi^* \left(\frac{t-\tau}{a} \right) dt \quad (3.2)$$

Eşitlik 3.2'de $f(t)$ EKG kesitini, ψ ana dalgacığı, t zaman değişkenini, τ kaydırma faktörünü ve a ölçekleme faktörünü ifade etmektedir. Bu eşitlikten bulunan sonucun mutlak değerinin alınmasıyla zaman-frekans ölçekli skalogram üretilmektedir. OUA ve Non-OUA kesitlerine ait örnek skalogram görüntüleri Şekil 3.8'de gösterilmiştir.



Şekil 3.8 : (a) Zaman ekseninde OUA kesiti, (b) Zaman ekseninde Non-OUA kesiti, (c) OUA kesitinin skalogram görüntüsü ve (d) Non-OUA kesitinin skalogram görüntüsü.

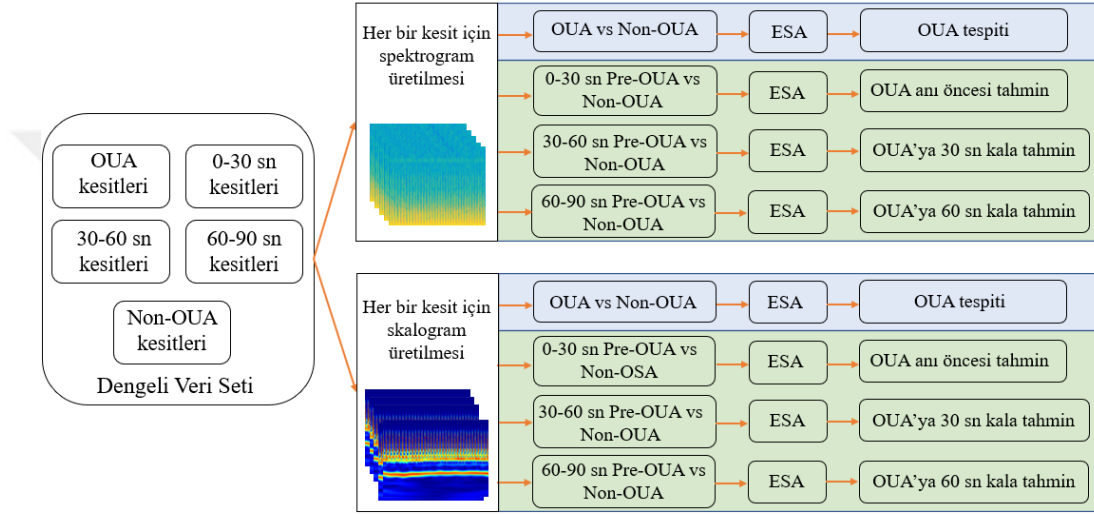
OUA sırasında, R–R sürelerinde artışa [13], QRS kompleksi sürelerinde değişime [75], S dalgaları ve RS desenlerinde değişikliklere neden olan anormal kalp aktiviteleri meydana gelmektedir [76]. Bu durum, skalogram gösterimlerinde zaman-frekans bileşenlerinin büyüklüklerinde değişikliklere neden olabilmekte ve apne olayı bitene kadar morfolojik değişikliklere yol açabilmektedir (Şekil 3.8 (c)). Pre-OUA kesitlerine ait örnek skalogram görüntüleri Şekil 3.9’da gösterilmiştir.



Şekil 3.9 : (a) 0-30 sn kesiti, (b) 30-60 sn kesiti ve (c) 60-90 sn kesiti için skalogram görüntüleri.

Şekil 3.9 görsel olarak incelendiğinde farklı tahmin sürelerinde EKG bileşenlerindeki morfolojik değişimlere bağlı olarak bileşen büyüklüklerinin farklı renk tonlarıyla ifade edildiği görülmektedir. Şekil 3.8 ve Şekil 3.9’daki kesitlerdeki bu görsel farklılıkların ESA modeli ile tespit edildiği durumda ortaya çıkan sonuçlar Bölüm 4’te Grad-CAM bulgularında gösterilmiş ve değerlendirilmiştir.

Dengeli veri setinin oluşturulmasının ardından spektrogram ve skalogram görüntülerinin sınıflandırılmasında izlenen adımlar Şekil 3.10’da özetlenmiştir. Tahmin sürelerine ait kesitler Non-OUA ile ayrı ayrı karşılaştırılacak şekilde ikili sınıflandırma problemi oluşturulmuştur. Bu sayede farklı tahmin sürelerinin birbirinden bağımsız olarak OUA tahmininde ne kadar başarılı olduğu araştırılmıştır. Sınıflandırma yapılırken, farklı ESA modellerinin ayrı ayrı spektrogram ve skalogram görüntülerindeki performansı da irdelenerek hangi görüntü tipinin OUA tahmininde daha iyi öngörü sonuçları verdiği araştırılmıştır.



Şekil 3.10 : OUA olaylarının tespiti ve tahmininde izlenen adımlar.



4. ÖNERİLEN MODEL VE BULGULAR

Tez kapsamında tüm ön işleme ve ESA modelleri MATLAB (R2020a) ortamında tasarlanmıştır. Kullanılan bilgisayar Windows 10 64 bit işletim sistemine sahip olup, donanımsal olarak NVIDIA GeForce GTX950M ekran kartına, Intel(R) Core™i7-6700HQ işlemcisine, 16GB RAM belleğine sahiptir. Tüm deneyler gözetimli olarak gerçekleştirilmiştir. Optimizasyon yöntemi olarak Gradyan Azalma Algoritması kullanılmıştır. Çapraz entropi kayıp fonksiyonunun minimize edilmesi için 0,0001 öğrenme oranı tercih edilmiştir. Bu öğrenme oranı daha sonra, son tam bağlantı katmanının yanlılık ve öğrenme hızının çarpımı sonucu bulunan değer ile çarpılmıştır. Ağdaki ağırlıkların rastgele başlaması nedeniyle, eğitim tekrarlandığında sonuçlar değişebilmektedir. Bu nedenle, transfer öğrenme (TL) veya sıfırdan eğitim (Non-TL) uygulamalarında önerilen tahmin modelinin performansını değerlendirmek için eğitim süreci on kez tekrarlanmış ve bulgularda bu tekrarlama sonucunda gözlemlenen ortalama değerler paylaşılmıştır.

Potansiyel morfolojik değişimler OUA başlangıç anı öncesine ait bir kesite kıyasla, OUA anı itibarıyla daha sık meydana geldiğinden OUA ve Non-OUA sınıfları arasındaki farklılıkları koymak adına daha fazla ayırt edici özellikler gözlemlenebilir. Bu nedenle, OUA olaylarının tespit performansının tahmin sonuçlarından daha iyi olması beklenmektedir. Bu bilgiden yola çıkarak tahmin sonuçlarını daha iyi yorumlayabilmek için ek olarak OUA tespiti yapan ağlar da eğitilmiştir.

Uygulanan testlerin başarısı doğruluk, duyarlılık, özgüllük ve pozitif tahmin değeri (positive predictive value, PPV) kriterleri ile objektif olarak değerlendirilmiştir (Eşitlik 4.1-Eşitlik 4.4).

$$\text{Doğruluk} = \frac{TP + TN}{TP + TN + FP + FN} \times 100 \quad (4.1)$$

$$\text{Duyarlılık} = \frac{TP}{TP + FN} \times 100 \quad (4.2)$$

$$\text{Özgüllük} = \frac{TN}{TN + FP} \times 100 \quad (4.3)$$

$$PPV = \frac{TP}{TP + FP} \times 100 \quad (4.4)$$

Yukarıda verilen eşitliklerde TP doğru pozitif, TN doğru negatif, FP yanlış pozitif, FN yanlış negatif değerlerini ifade etmektedir. TP , gerçek etiketi Pre-OUA/OUA olan kesitlerin kaç tanesinin Pre-OUA/OUA olarak sınıflandırıldığını, TN gerçek etiketi Non-OUA olan kesitlerin kaç tanesinin Non-OUA olarak sınıflandırıldığını, FP gerçek etiketi Non-OUA olan kesitlerin kaç tanesinin Pre-OUA/OUA olarak sınıflandırıldığını ve FN ise gerçek etiketi Pre-OUA/OUA olan kesitlerin kaç tanesinin Non-OUA olarak sınıflandırıldığını ifade etmektedir.

Çalışmada ilk olarak önceden eğitilmiş mimarilerin apne tespiti ve tahminindeki Non-TL performansları araştırılmıştır. Ardından aynı mimariler için TL kullanılarak bu yöntemin öngörü başarısına etkisi incelenmiştir. Sonraki adımda, gözlemlenen sonuçlara bağlı olarak yeni bir model önerilmiş ve bu modelden elde edilen sonuçlar paylaşılmıştır. Son uygulamada ise, EKG kesitlerine ait derin öznetelikler kullanılarak farklı sınıflandırıcıların performansları araştırılmış ve karşılaştırılmıştır. Uygulanan tüm ESA modellerinin eğitimi için epok sayısı 30 olarak belirlenmiştir.

4.1 Sıfırdan Eğitim Sonuçları

Bu bölümde sıfırdan eğitim kullanıldığı durumda AlexNet, GoogleNet ve ResNet18 modellerinin OUA tespiti ve OUA tahminindeki başarısı araştırılmıştır. AlexNet mimarisi 227 x 227, GoogleNet ve ResNet18 mimarileri 224 x 224 girdi boyutlarını kabul ettiğinden tüm skalogram ve spektrogram görüntüleri sınıflandırma öncesi mimarinin gereksinimlerine göre yeniden boyutlandırılmıştır. Sıfırdan eğitim sürecinde önceden eğitilmiş herhangi bir ImageNet bilgisi veya optimize edilmiş ağırlık kullanılmamıştır. Tüm mimariler için son üç katman çalışmadaki sınıf sayısına göre yeniden düzenlenmiştir. Eğitimin on kez tekrarlanması ile elde edilen ortalama sonuçlar Çizelge 4.1-4.3'te verilmiştir.

Çizelge 4.1-4.3'te tespit sütunu OUA kesitlerinin tespit edilme başarısını ifade ederken 0-30 sn, 30-60 sn ve 60-90 sn sütunları OUA öncesi farklı tahmin sürelerinden alınan kesitlerin OUA tahminindeki performansını ifade etmektedir. Non-TL uygulamasında skalogram görüntülerinin spektrogram görüntülerine kıyasla genel olarak daha yüksek doğrulukla sınıflandırıldığı görülmüştür.

Çizelge 4.1 : AlexNet modeli için sıfırdan eğitim (Non-TL) sonuçları.

		AlexNet			
		Tespit	0-30 sn	30-60 sn	60-90 sn
Doğruluk (%)	Skalogram	82,78	73,63	68,40	65,36
	Spektrogram	78,59	70,44	65,41	59,00
Duyarlılık (%)	Skalogram	85,39	77,68	69,36	65,59
	Spektrogram	80,52	72,23	67,75	60,14
Özgüllük (%)	Skalogram	80,44	72,84	64,03	61,08
	Spektrogram	77,85	68,83	64,78	57,91
PPV (%)	Skalogram	82,38	76,85	67,02	66,21
	Spektrogram	78,70	73,37	63,53	59,95

Çizelge 4.2 : GoogleNet modeli için sıfırdan eğitim (Non-TL) sonuçları.

		GoogleNet			
		Tespit	0-30 sn	30-60 sn	60-90 sn
Doğruluk (%)	Skalogram	70,67	63,85	60,25	58,37
	Spektrogram	72,70	67,83	59,39	57,19
Duyarlılık (%)	Skalogram	70,03	62,21	59,54	55,47
	Spektrogram	70,56	64,17	57,38	55,43
Özgüllük (%)	Skalogram	71,36	68,88	62,19	59,57
	Spektrogram	74,68	68,09	61,33	60,65
PPV (%)	Skalogram	70,54	65,82	59,99	57,34
	Spektrogram	73,40	65,46	59,39	56,80

Buradaki tek istisna, GoogleNet modelinin OUA tespitinde spektrogramları %2,03 ve 0-30 sn kesitlerinde %3,98'lik farkla skalogramlara göre daha doğru sınıflandırması ve özgüllük değerlerinin duyarlılık değerinden daha yüksek değerde elde edilmesidir (Çizelge 4.2). Fakat bu sonuçlar genel değerlendirmede AlexNet ve ResNet18 performansının gerisinde kalmıştır. Öte yandan AlexNet ve ResNet18 mimarileri için gözlemlenen duyarlılık değerlerinin özgüllük değerlerinden daha yüksek olduğu

gözlemlenmiştir. Duyarlılık oranının özgüllüğe daha yüksek olması Eşitlik 4.2'ye göre OUA/Pre-OUA kesitlerinin Non-OUA kesitlerine göre daha iyi tespit ve tahmin edildiğini göstermektedir.

Çizelge 4.3 : ResNet18 modeli için sıfırdan eğitim (Non-TL) sonuçları.

		ResNet18			
		Tespit	0-30 sn	30-60 sn	60-90 sn
Doğruluk (%)	Skalogram	80,69	75,45	73,13	70,42
	Spektrogram	80,55	74,52	72,59	68,89
Duyarlılık (%)	Skalogram	82,38	77,27	74,75	72,91
	Spektrogram	82,86	75,65	72,92	70,45
Özgüllük (%)	Skalogram	78,81	73,93	70,17	69,00
	Spektrogram	78,48	72,18	69,56	66,46
PPV (%)	Skalogram	80,87	76,34	73,54	71,28
	Spektrogram	83,50	75,90	73,15	71,67

0-30 sn kesitleri kullanılarak yapılan tahmin çalışmasında AlexNet ile ResNet18'in duyarlılık performansı karşılaştırıldığında iki mimarinin de oldukça yakın sonuçlar (%77,68 ve %77,27) sunarak OUA olaylarını Non-OUA olaylarına kıyasla daha doğru tahmin ettiği görülmektedir. Benzer şekilde özgüllük ve PPV kriterleri için de oldukça yakın sonuçlar gözlemlenmiştir.

Sonuçlar incelendiğinde tüm mimarilerde OUA kesitlerinin tespit edilme başarısının beklenildiği gibi OUA tahmin başarısından daha yüksek olduğu görülmüştür. Tespit performansında özellikle AlexNet mimarisi skalogram görüntülerinde tüm değerlendirme kriterleri için sunduğu başarıyla ön plana çıkarken; OUA tahmininde ResNet18 mimarisi tüm tahmin sürelerinde diğer mimarilere kıyasla en iyi öngörü performansını sunmuştur. Beklenildiği üzere apne anından öncesine gidildikçe EKG kesitlerindeki varyasyonlar normal solunuma daha yakın bir davranış sergilediğinden ayırt edici özellikler azalmış ve modelin tahmin etme başarısı düşmüştür. Bu bağlamda en yüksek tahmin başarısı %75,45 doğrulukla 0-30 sn kesitlerinde gözlemlenmiştir (Çizelge 4.3).

4.2 Transfer Öğrenme Sonuçları

Daha önceden de belirtildiği üzere AlexNet, GoogleNet ve ResNet18 mimarileri milyonlarca görüntü içeren ImageNet veri tabanı ile eğitilerek transfer öğrenme yönteminin kullanılmasına olanak sağlamaktadır. Önceden eğitilmiş modellerde optimize edilmiş parametreler kullanılarak yeniden eğitim başlatılması durumunda mevcut parametreler yeni eğitim setine göre eğilecektir. Bu sayede halihazırda optimize edilmiş parametrelerin kullanımı eğitim süresini de olumlu yönde etkileyecek ve daha kısa sürede eğitimin tamamlanmasını sağlayacaktır.

Bahsedilen mimariler önceki uygulamada olduğu gibi tüm süreçler için transfer öğrenme yöntemiyle tekrardan eğitilmiştir. Görüntülerin girdi boyutları benzer şekilde mimari gereksinimlerine göre yeniden boyutlandırılmıştır. Mimarilerin son üç katmanı yeniden düzenlenerek varsayılan olarak belirlenen 1000 sınıf yerine iki sınıflı (OUA – Non-OUA, 0-30 sn – Non-OUA, 30-60 sn – Non-OUA, 60-90 sn – Non-OUA) sınıflandırıcı kullanılmıştır.

Farklı katmanlarda “dondurma (freezing)” işleminin uygulanması bu katmanlardaki parametrelerin ilgili katmanlarda eğitim boyunca güncellenmemesini sağlamaktadır. Bu sayede daha hızlı bir eğitim süreci yakalanabilmektedir. Bu bağlamda, transfer öğrenme ile sınıflandırmanın yapıldığı uygulamada farklı katmanlar dondurularak eğitim tekrarlanmış; fakat bu denemeler sonucunda dondurma işleminin model performansını olumsuz yönde etkilediği görülmüştür. Bu nedenle transfer öğrenme uygulamasında herhangi bir katmanda dondurma işlemine gidilmemiş ve tüm katmanlar eğitim boyunca güncellenmiştir. Eğitimin on kez tekrarlanması ile gözlemlenen ortalama sonuçlar Çizelge 4.4-4.6’da verilmiştir.

Çizelge 4.4’teki sonuçlara göre AlexNet mimarisi sıfırdan eğitime kıyasla bu kez %2,18’lik bir farkla spektrogram görüntüleri ile OUA tespitinde daha yüksek bir doğruluk başarısı göstermiştir. Önceki sonuçlara benzer şekilde AlexNet mimarisi apne tespitinde GoogleNet ve ResNet18 mimarilerinden doğruluk, hassasiyet ve özgüllük kriterleri için daha yüksek performansla sonuç vermiştir.

OUA tahmininde ise ResNet18 mimarisi skalogram görüntüleri ile 0-30 sn kesitleri için en iyi tahminleme sonuçlarını (%78,05 doğruluk, %79,89 hassasiyet) sunmuştur (Çizelge 4.6). Bunun yanında, 30-60 sn ve 60-90 sn kesitlerinde skalogram görüntüleri

için ResNet18 modeli GoogleNet ve AlexNet mimarisine kıyasla OUA tahmininde daha yüksek başarı oranları ile sonuçlar sunmuştur.

Çizelge 4.4 : AlexNet modeli için transfer öğrenme (TL) sonuçları.

		AlexNet			
		Tespit	0-30 sn	30-60 sn	60-90 sn
Doğruluk (%)	Skalogram	83,68	77,27	73,52	70,75
	Spektrogram	84,96	76,74	72,61	69,53
Duyarlılık (%)	Skalogram	84,31	78,27	75,63	71,50
	Spektrogram	86,87	77,73	74,99	70,84
Özgüllük (%)	Skalogram	81,04	76,38	71,17	69,17
	Spektrogram	84,22	75,81	71,95	67,31
PPV (%)	Skalogram	83,00	79,45	75,75	72,82
	Spektrogram	84,64	75,65	74,10	68,03

Çizelge 4.5 : GoogleNet modeli için transfer öğrenme (TL) sonuçları.

		GoogleNet			
		Tespit	0-30 sn	30-60 sn	60-90 sn
Doğruluk (%)	Skalogram	80,04	69,04	66,10	62,11
	Spektrogram	78,92	68,75	66,02	61,38
Duyarlılık (%)	Skalogram	82,59	71,09	68,30	62,64
	Spektrogram	79,93	70,86	66,45	61,63
Özgüllük (%)	Skalogram	79,08	67,52	65,19	60,47
	Spektrogram	78,68	67,26	64,16	57,90
PPV (%)	Skalogram	79,96	68,63	65,58	61,56
	Spektrogram	78,96	69,96	64,63	61,75

GoogleNet, Non-TL uygulamasında olduğu gibi burada da en düşük tespit ve tahmin sonuçlarını vermiştir. Buna karşın, GoogleNet mimarisinin OUA tespitini %80,04 doğrulukla yapabilmesi kabul edilebilir bir performans olarak değerlendirilmiştir. Skalogram görüntüleri spektrogram görüntülerine kıyasla 0-30 sn kesitlerinde %0,53


(AlexNet), 30-60 sn kesitlerinde %1,4 (ResNet18) ve 60-90 sn kesitlerinde %3,49'luk (ResNet18) bir farkla daha doğru sınıflandırılmıştır. TL için yalnızca AlexNet mimarisinde spektrogram görüntülerinin skalogram görüntülerine göre kıyasla %1,28 oranla daha doğru sınıflandırıldığı görülmüştür.

Çizelge 4.6 : ResNet18 modeli için transfer öğrenme (TL) sonuçları.


		ResNet18			
		Tespit	0-30 sn	30-60 sn	60-90 sn
Doğruluk (%)	Skalogram	83,67	78,05	75,05	73,77
	Spektrogram	83,40	77,78	73,65	70,28
Duyarlılık (%)	Skalogram	84,43	79,89	75,26	74,25
	Spektrogram	85,45	78,68	73,93	70,36
Özgüllük (%)	Skalogram	83,00	76,00	73,55	72,71
	Spektrogram	82,78	76,79	73,35	68,23
PPV (%)	Skalogram	85,42	78,29	75,39	74,88
	Spektrogram	83,06	78,93	74,29	70,30

Çizelge 4.4-4.6'da gözlemlenen ortak sonuçlardan bir diğeri, apne başlangıcından öncesine gidildikçe tahmin başarısının düştüğünün gözlemlenmesidir. Bu durum apne anı yaklaştıkça EKG örneklerindeki morfolojik değişimlerin artmaya başladığının ve apne anında nefesin durmasıyla kalp aktivitelerindeki değişimin en fazla olduğunun bir göstergesidir. Buna bağlı olarak apne anının başlangıcı öncesi solunum ve normal solunum arasındaki ayırt edici özellikler belirgin hale gelmekte; bu da ESA modelleri tarafından daha doğru bir şekilde tespit edilmektedir. Bu sebeple, sınıflar arası farklılığın en fazla apne kesitlerinde, en az da 60-90 sn kesitlerinde olduğu görülmektedir. Bu gözleme bağlı olarak TL ve Non-TL sonuçlarında en iyi tahmin başarısı apne başlangıcının hemen öncesindeki 30 saniye (0-30 sn) aralıkları kullanıldığında gözlemlenmiştir. TL ve Non-TL sonuçlarında ResNet18 mimarisi tüm tahmin zamanları için AlexNet ve GoogleNet'ten daha iyi tahminleme performansı sunmuştur. Bu nedenle ResNet18'in OUA tahmininde diğer modellerden daha etkili olduğu sonucuna varılmıştır. Şekil 4.1'de görüldüğü üzere önceden eğitilmiş modellerde transfer öğrenme kullanımı sıfırdan eğitime göre çoğu senaryoda daha yüksek performans sonuçları sunmuştur. Bunun yanında skalogram görüntülerinin


özellikle AlexNet ve ResNet18 mimarileri için çoğunlukla daha iyi sınıflandırıldığı açıkça görülmektedir. Kullanılan mimariler için hem TL hem de Non-TL eğitimlerinde gözlemlenen doğruluk ve kayıp grafikleri Şekil 4.2-4.7’de gösterilmiştir.



(a)




(b)




(c)

Şekil 4.1 : Doğruluk sonuçları (a) AlexNet, (b) GoogleNet ve (c) ResNet18.

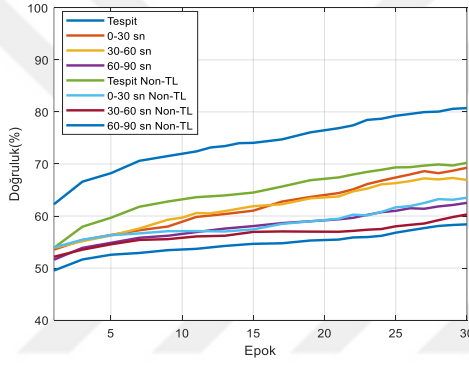


(a)




(b)

Şekil 4.2 : TL ve Non-TL eğitimlerinde skalogram görüntüleri için AlexNet doğruluk ve kayıp grafikleri; (a) Doğruluk, (b) Kayıp.




(a)




(b)

Şekil 4.3 : TL ve Non-TL eğitimlerinde skalogram görüntüleri için GoogleNet doğruluk ve kayıp grafikleri; (a) Doğruluk, (b) Kayıp.




(a)




(b)

Şekil 4.4 : TL ve Non-TL eğitimlerinde skalogram görüntüleri için ResNet18 doğruluk ve kayıp grafikleri; (a) Doğruluk, (b) Kayıp.




(a)




(b)

Şekil 4.5 : TL ve Non-TL eğitimlerinde spektrogram görüntüleri için AlexNet doğruluk ve kayıp grafikleri; (a) Doğruluk, (b) Kayıp.




(a)




(b)

Şekil 4.6 : TL ve Non-TL eğitimlerinde spektrogram görüntüleri için GoogleNet doğruluk ve kayıp grafikleri; (a) Doğruluk, (b) Kayıp.



(a)



(b)

Şekil 4.7 : TL ve Non-TL eğitimlerinde spektrogram görüntüleri için ResNet18 doğruluk ve kayıp grafikleri; (a) Doğruluk, (b) Kayıp.

4.3 Önerilen Model Mimarisi

Bu bölümde, önceden eğitilmiş ESA mimarileri ile transfer öğrenme ve sıfırdan eğitim uygulamalarında gözlemlenen sonuçlara bağlı olarak OUA tahmininde model başarısını artıran yeni bir mimari hakkında bilgilere yer verilmiştir. Önerilen mimari, temelde ResNet18 mimarisinin geliştirilmiş bir versiyonu olarak değerlendirilmektedir.

Ele alınan problemde, ResNet18 mimarisinin geri yayılım sırasında mimarinin ilk katmanlarına doğru etkisini kaybeden ağırlıkların artık bağlantılar ile eğitim sürecine dahil edilmesinin modelin tahmin başarısını olumlu yönde etkilediği görülmüştür. Bu bağlamda OUA tahmini için sıralı veya başlangıç modülleri yapısındaki katman kullanımlarının başarıya etkisinin düşük olduğu söylenebilir. Önerilen modeldeki motivasyon, artık blok yapıları kullanımı ile ResNet18 mimarisinden daha iyi bir tahmin başarısını yakalamak ve modelin parametre sayısını azaltarak işlemsel maliyeti indirmektir.

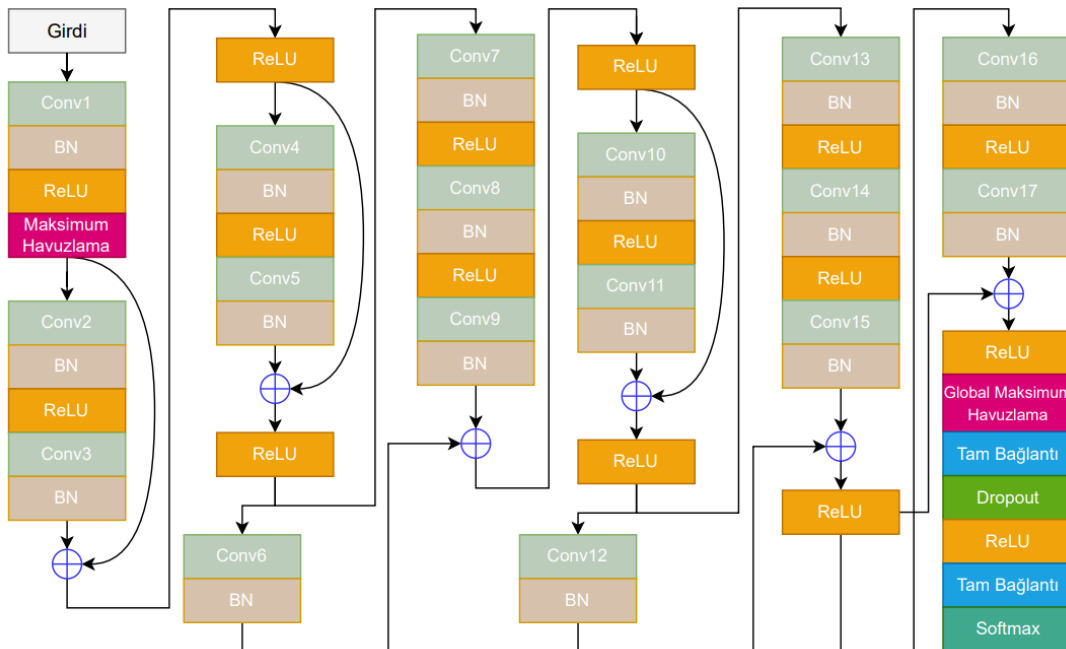
Önerilen yeni modeldeki amaç; OUA tahmininde mevcut modellerden daha iyi çalışan ve yüksek doğrulukla sonuçlar veren bir model ortaya koymaktır. Bu nedenle OUA tespiti sonuçları için herhangi bir iyileştirilme çalışması yapılmamıştır. Daha önceden de belirtildiği üzere, OUA olaylarının tespit edilme başarısının tahmin edilme başarısından daha yüksek olması beklenmektedir. Bu durum dikkate alındığında, önerilen modelin OUA tahmini için Bölüm 4.1 ve Bölüm 4.2'deki uygulamalardan daha iyi sonuçlar vermesi durumunda OUA tespiti için de daha yüksek performans göstermesi beklenmektedir.

Yapılan iyileştirme çalışmalarında, ResNet18 mimarisinin katman sayılarında artırma/azaltma, farklı havuzlama yöntemlerinin kullanımı, artık bloklara katman ekleme/çıkarma, tam bağlantı katmanların düğüm sayısında değişiklik ve dropout kullanımı gibi birçok deneme ile ağ başarısı iyileştirilmeye çalışılmıştır. Katman sayısının artırıldığı taktirde öğrenilebilir parametre sayısında artış olduğu, eğitim sürecinin uzadığı ve performans başarısının önemli ölçüde değişmediği gözlemlenmiştir. Havuzlama yönteminde ise global ortalama havuzlama yerine maksimum havuzlama kullanıldığında modelin tahmin performansının olumlu yönde etkilendiği görülmüştür. Ek olarak, sıfırdan bir eğitim süreci için modelin aşırı öğrenme durumu ile karşılaşılması için son tam bağlantı katmandan önce 0,2

olasılıklı dropout eklenmiştir. Çizelge 4.7’de önerilen modele ait katman tipleri, filtre sayıları, filtre boyutları ve aktivasyon fonksiyonlarının çıktı boyutları, filtrelerde uygulanan adım sayıları ve aktivasyon fonksiyonları verilmiştir.

Çizelge 4.7’de “Conv” evrişim katmanını ve “BN” dizi normalizasyonunu ifade etmektedir. Görüldüğü üzere önerilen modelde birinci tam bağlantı katmanı 512 bağlantılı iken, ikinci tam bağlantı katmanı hedeflenen sınıf sayısına bağlı olarak 2 bağlantılıdır. Ağırlıkların optimizasyonu için Gradyan Azalma Algoritması kullanılmıştır. Önerilen model toplamda 9.354.114 öğrenilebilir parametre içermektedir. Bu bağlamda, orijinal ResNet18 mimarisinden (11.694.056 adet öğrenilebilir parametre) daha az sayıda parametre içeren bir mimari elde edildiği söylenebilmektedir.

Şekil 4.8’de önerilen mimarinin katman bağlantıları görselleştirilmiştir. Orijinal ResNet18 mimarisinde sekiz adet artık bağlantının kullanımına kıyasla önerilen mimaride artık bağlantıların sayısının altı adet olduğu görülmektedir. Diğer bir yenilik, ResNet18’deki son dört evrişim katmanının önerilen mimaride kullanılmamasıdır. Bunun yerine “Conv8” ve “Conv14” evrişim katmanlarına BN-ReLU-Conv-BN katmanları eklenmiştir.



Şekil 4.8 : Önerilen mimarinin katman bağlantıları.

Çizelge 4.7 : Önerilen model mimarisi.

Katmanlar	Filtre Sayısı	Filtre Boyutları	Çıktı	Adım	Aktivasyon Fonksiyonu
Girdi	-	-	224x224x3	-	-
Conv1	64	7x7	112x112x64	2	ReLU
BN	-	-	112x112x64	-	-
Maksimum Havuzlama	-	3x3	56x56x64	2	-
Conv2	64	3x3	56x56x64	1	ReLU
BN	-	-	56x56x64	-	-
Conv3	64	3x3	56x56x64	2	ReLU
BN	-	-	56x56x64	-	-
Conv4	64	3x3	56x56x64	1	ReLU
BN	-	-	56x56x64	-	-
Conv5	64	3x3	56x56x64	1	ReLU
BN	-	-	56x56x64	-	-
Conv6	256	1x1	28x28x256	2	ReLU
BN	-	-	28x28x256	-	-
Conv7	128	3x3	28x28x128	2	ReLU
BN	-	-	28x28x128	-	-
Conv8	128	3x3	28x28x128	1	ReLU
BN	-	-	28x28x128	-	-
Conv9	256	3x3	28x28x256	1	ReLU
BN	-	-	28x28x256	-	-
Conv10	256	3x3	28x28x256	1	ReLU
BN	-	-	28x28x256	-	-
Conv11	256	3x3	28x28x256	1	ReLU
BN	-	-	28x28x256	-	-
Conv12	512	1x1	14x14x512	2	ReLU
BN	-	-	14x14x512	-	-
Conv13	256	3x3	14x14x256	1	ReLU
BN	-	-	14x14x256	-	-
Conv14	256	3x3	14x14x256	1	ReLU
BN	-	-	14x14x256	-	-
Conv15	512	3x3	14x14x512	1	ReLU
BN	-	-	14x14x512	-	-
Conv16	512	3x3	14x14x512	1	ReLU
BN	-	-	14x14x512	-	-
Conv17	512	3x3	14x14x512	1	ReLU
BN	-	-	14x14x512	-	-
Global Maksimum Havuzlama	-	-	1x1x512	-	-
Tam Bağlantı Katmanı	-	-	1x1x512	-	ReLU
Dropout	-	-	1x1x512	-	-
Tam Bağlantı Katmanı	-	-	1x1x2	-	Softmax

4.4 Önerilen Model Bulguları

Önerilen mimarinin eğitimi ve testi için önceden eğitilmiş ESA mimarilerine uygulanan parametreler kullanılmıştır. Önerilen mimari önceki uygulamalarda olduğu gibi 30 epok boyunca eğitilmiş, Gradyan Azalma Algoritması ile optimize edilmiş ve eğitim on kez tekrarlanmıştır. Çizelge 4.8’de skalogram ve spektrogram görüntüleri için gözlemlenen ortalama değer sonuçları verilmiştir.


Çizelge 4.8 : Önerilen model bulguları.

		Önerilen mimari			
		Tespit	0-30 sn	30-60 sn	60-90 sn
Doğruluk (%)	Skalogram	85,20	82,30	78,91	75,66
	Spektrogram	84,70	80,13	77,57	74,55
Duyarlılık (%)	Skalogram	86,27	83,22	80,01	76,14
	Spektrogram	85,80	81,99	78,97	74,95
Özgüllük (%)	Skalogram	85,01	82,27	77,87	75,16
	Spektrogram	83,89	77,25	77,23	74,24
PPV (%)	Skalogram	85,66	82,95	80,33	75,75
	Spektrogram	84,76	78,74	77,62	74,37

Çizelge 4.8’de görüldüğü üzere, AlexNet, GoogleNet ve ResNet18’e benzer şekilde OUA olaylarının gerçekleşme anına yaklaştıkça önerilen modelin tahmin performansının arttığı görülmektedir. Denenen diğer modellere kıyasla ağ, skalogram görüntüleri için OUA tespitinde %85,20 ve OUA tahmininde %82,30'luk en yüksek doğruluk değerine ulaşmıştır. Bunun yanında, önceden eğitilmiş modellere benzer şekilde, önerilen ağın OUA tahmininde skalogram görüntüleri için en yüksek doğruluk performansını sunduğu gözlemlenmiştir (Şekil 4.9).

Önerilen ağ, Bölüm 4.1 ve Bölüm 4.2’de gözlemlenen bulgulara kıyasla tüm tahmin süreleri için hem skalogram hem de spektrogram görüntülerinde daha yüksek duyarlılık sonuçları sunmuştur. Benzer şekilde, skalogram görüntüleri için daha yüksek pozitif tahmin değerleri elde edilmiştir. Gözlemlenen sonuçlardan, önerilen

ESA modelinin önceden eğitilmiş mimarilerin transfer öğrenme ve sıfırdan eğitim bulgularına kıyasla OUA tahmininde daha etkili olduğu görülmüştür.

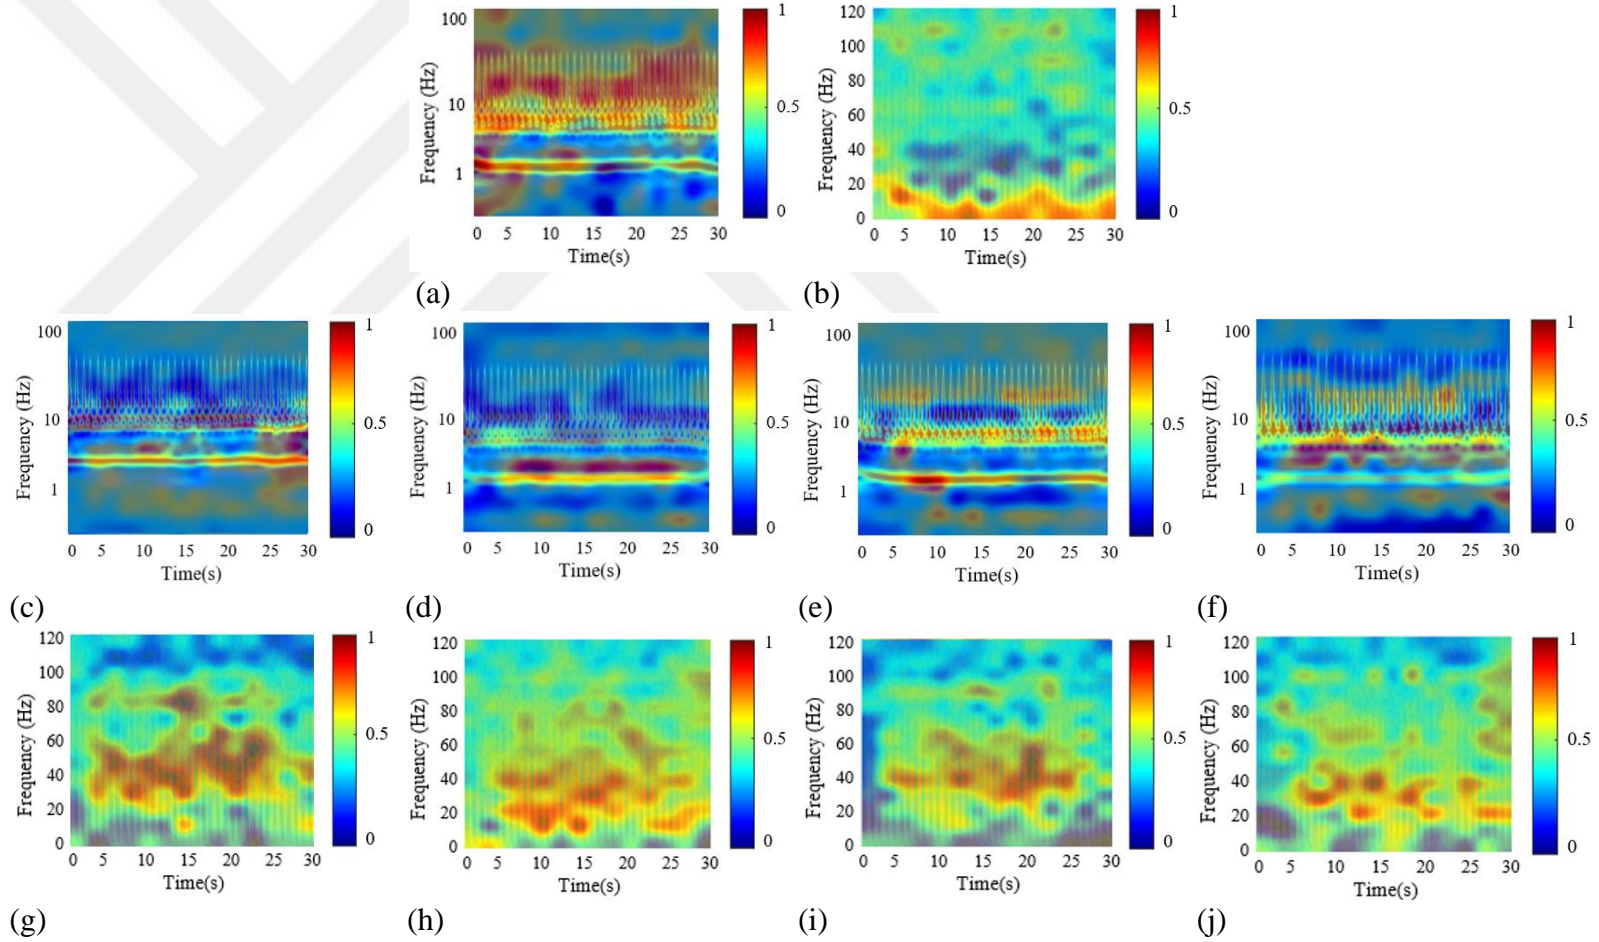


Şekil 4.9 : Önerilen model için skalogram ve spektrogram görüntülerinin doğruluk grafiği.



Şekil 4.10'da tespit ve tahmin kesitleri için Grad-CAM görüntüleri gösterilmiştir. Grad-CAM algoritmasının, test verilerine ait ayırt edici derin özellikleri maviden kırmızıya doğru tonlamalar ile ifade ettiği görülmektedir. EKG kesitlerinde sınıfları birbirinden ayıran özelliklerin farklı renk tonları ile görsel olarak sunulması sınıflar arası farklılıkları vurgulamıştır. Şekil 4.10 (a)'da Non-OUA için ayırt edici özellikler 20 Hz dolaylarında gözlemlenmiştir, ancak bu bölgelerin Pre-OUA skalogram kesitlerinde ayırt edici olmadığı görülmektedir.

Şekil 4.10 (b)'de sınıflandırıcının tespit ettiği ayırt edici özelliklerin spektrogram görüntülerinin alt bölümünde 10-20 Hz dolaylarında yoğunlaştığı görülmektedir. Başka bir deyişle, orta seviye frekanslar ve bu frekansların harmoniklerine ait genlikler, spektrogram sınıflandırmasında Pre-OUA ve Non-OUA sınıfları için ayırt edici farklılıkları ifade etmektedir. Gözlemlenen bulgular ve Grad-CAM sonuçları, kalbin elektriksel aktivitelerinin sadece OUA olayları sırasında değil, OUA öncesinde de değişebileceğini açıkça ortaya koymaktadır.

Önerilen ESA mimarisinin eğitimi sırasında elde edilen doğruluk ve kayıp grafikleri Şekil 4.11'de verilmiştir.





Şekil 4.10 : Grad-CAM görüntüleri; (a) Non-OUA skalogram, (b) Non-OUA spektrogram, (c) OUA skalogram, (d) 0-30 sn Pre-OUA skalogram, (e) 30-60 sn Pre-OUA skalogram, (f) 60-90 sn Pre-OUA skalogram, (g) OUA spektrogram, (h) 0-30 sn Pre-OUA spektrogram, (i) 30-60 sn Pre-OUA spektrogram, (j) 60-90 sn Pre-OUA spektrogram.



(a)

(b)



(c)

(d)

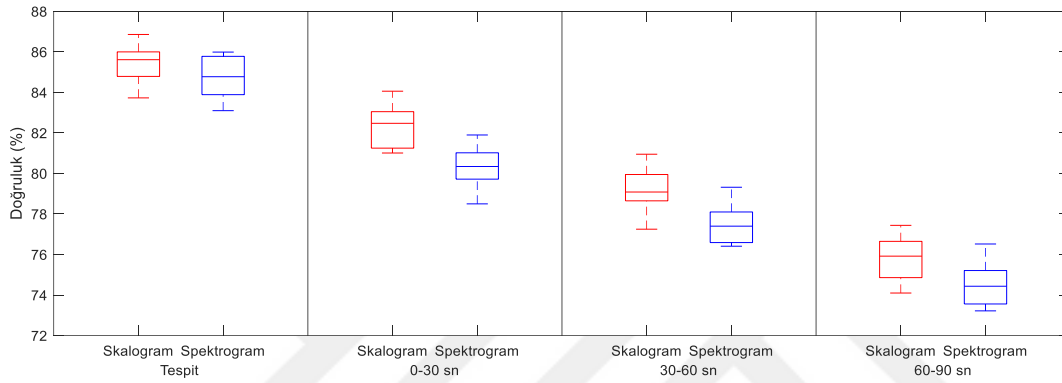
Şekil 4.11 : Önerilen modelin doğruluk ve kayıp grafikleri (a) Skalogram doğruluk, (b) Skalogram kayıp, (c) Spektrogram doğruluk ve (d) Spektrogram kayıp.

Şekil 4.11’de görüldüğü üzere test başarısında olduğu gibi eğitim başarısında da tespit doğruluğunun en yüksek olduğu ve bunu takiben 0-30 sn, 30-60 sn, 60-90 sn kesitlerinin geldiği görülmektedir. Kayıp grafiğinde ise beklenildiği üzere en az kayıp OUA tespit modelinde; en fazla kayıp ise OUA tahmininde 60-90 sn kesitlerinin kullanıldığı durumda olmuştur. Önerilen modelin güvenilirliğini ve tutarlılığını değerlendirmek için 10 kat çapraz validasyon (10 fold cross validation) uygulanmıştır. Burada, tüm veri seti rastgele olarak 10 parçaya bölünmüş, bunlardan biri test için geri kalanlar ise eğitim için kullanılmıştır. Bu işlem on kez tekrarlanmıştır.

Önerilen modelin validasyon sonuçları Şekil 4.12’de gösterilmiştir. Skalogram görüntülerinin validasyon sonuçlarına göre, ortalama doğruluk değeri OUA tespiti için $85,38 \pm 0,95$, 0-30 sn kesitler için $82,36 \pm 1,07$, 30-60 sn kesitler için $79,09 \pm 1,17$ ve 60-90 sn kesitler için $75,77 \pm 1,11$ olarak tespit edilmiştir.

Spektrogram görüntülerinde ise tespit için $84,68 \pm 0,98$, 0-30 sn kesitler için $80,24 \pm 1,04$, 30-60 sn kesitler için $77,59 \pm 1,05$ ve 60-90 sn kesitler için $74,58 \pm 1,13$ doğruluk değerleri gözlemlenmiştir.

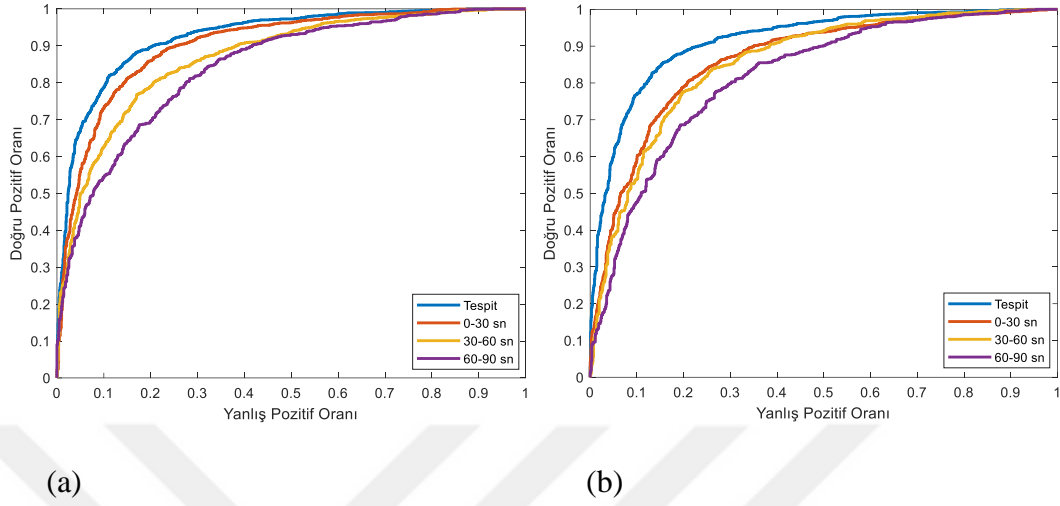
Önerilen modelin 10 kat çapraz validasyon sonucunda gözlemlenen ortalama doğruluk değerleri sırasıyla tespit, 0-30 sn, 30-60 sn ve 60-90 sn kesitleri için soldan sağa doğru Şekil 4.12’de gösterilmiştir. Çizelge 4.8’deki performans sonuçlarının çapraz validasyon sonuçları ile oldukça yakın değerlerde gözlemlenmesi önerilen modelin kararlılığını ve tekrarlanabilirliğini ortaya koymaktadır.



Şekil 4.12 : Önerilen modelin 10 kat çapraz validasyon sonuçları.

Diğer bir doğrulama yöntemi, ROC eğrisinin analizidir. ROC eğrisi, eğitilmiş bir modelin test aşamasında yanlış pozitif bulma oranına karşılık doğru pozitif bulma oranının değişimini göstermektedir. Bu değişimden elde edilen eğri altında kalan alanın (Area Under Curve, AUC) yorumlanmasıyla modelin doğruluğu ve uygulanabilirliği hakkında yorum yapılabilmektedir. AUC sonucunun 0,5 olması sınıflar arasındaki farkın görülmemesi; rastgele sınıflandırma olarak kabul edilir [77]. 0,85 üzeri AUC değerleri, yüksek sınıflandırma doğruluğu olarak değerlendirilirken, 0,75-0,85 AUC orta seviye ve 0,75’ten düşük değerler de düşük doğrulukla sınıflandırma olarak yorumlanmaktadır [78]. Yapılan analizler sonucunda skalogram görüntülerinde tespit için 0,928, 0-30 sn kesitler için 0,901, 30-60 sn kesitler için 0,860 ve 60-90 sn kesitler için 0,833 ortalama AUC değerleri gözlemlenmiştir. Spektrogram görüntülerinde ise tespit için 0,912, 0-30 sn kesitler için 0,878, 30-60 sn kesitler için 0,852 ve 60-90 sn kesitler için 0,815 ortalama AUC değerleri gözlemlenmiştir. Skalogram görüntülerinin OUA tahmininde spektrogram görüntülerinden daha yüksek performans değerleri ile sonuç vermiştir. Bunun bir sonucu olarak gözlemlenen AUC değerlerinde de benzer durumun olduğu görülmektedir. Buna karşılık, iki görüntü tipi

için de elde edilen AUC değerlerinin tüm tahmin zamanları için 0,815 ve üzerinde gözlemlenmesi, modelin OUA tahmininde uygulanabilirliğini ortaya koymaktadır. Önerilen modelin ortalama ROC eğrilerine ait grafikler Şekil 4.13'te gösterilmiştir.



Şekil 4.13 : Önerilen modelin ROC eğrileri (a) Skalogram, (b) Spektrogram.

4.5 Derin Özellikler ve Farklı Sınıflandırıcı ile Gözlemlenen Sonuçlar

Çizelge 4.8'deki önerilen model sonuçları ESA mimarisinin kendi sınıflandırıcısı kullanarak elde edilmiştir. Burada farklı bir uygulama olarak, ESA modelinden elde edilen özneliklerin farklı sınıflandırıcılar ile sınıflandırıldığı durumdaki başarıları analiz edilmiş ve karşılaştırılmıştır. Derin öğrenmenin sağladığı avantajla otomatik olarak çıkarılan öznelikler bu kez mimarinin kendi sınıflandırıcısı yerine üç farklı sınıflandırıcı ile sınıflandırılmıştır. Bu sınıflandırıcılar Destek Vektör Makineleri (DVM), Rastgele Alt Uzay k-En Yakın Komşuluk RAU-kNN) ve Rastgele Alt Uzay Diskriminant'dır (RAU-D). Önceki uygulamada en iyi tespit ve tahminleme sonuçları skalogram görüntülerinde gözlemlendiği için çalışmanın geri kalanına yalnızca bu görüntü tipi dikkate alınarak devam edilmiştir.

Mimarinin katman derinliği arttıkça bu katmanlarda daha detaylı; başka bir deyişle daha karmaşık seviyelerde öznelikler gözlemlenmektedir. Bu öznelikler karmaşık hale geldikçe sınıflandırıcının başarısı olumsuz yönde de etkilenebilmektedir. Bu nedenle önerilen modelin katman derinliğinin seçimi probleme uygun bir şekilde belirlenmelidir. Ayrıca kullanılacak olan harici bir sınıflandırıcı için yeterli sayıda özneliğin elde edilmesi de sınıflandırıcının performansını etkileyebilmektedir. Bu çalışmada ilk olarak önerilen değiştirilmiş ResNet18 mimarisinin farklı

katmanlarından elde edilen özniteliklerin farklı sınıflandırıcılardaki başarıları araştırılmıştır. Yapılan gözlemler sonucunda birinci tam bağlantı katmanı öncesindeki Global Maksimum Havuzlama katmanından elde edilen özniteliklerin sınıflandırmada daha başarılı sonuçlar sunduğu görülmüştür. Bu sınıflandırıcıların 10 kat çapraz validasyon için sunduğu performans sonuçları Çizelge 4.9 – 4.11’de verilmiştir.

Çizelge 4.9 : Derin özniteliklerin DVM ile sınıflandırma sonuçları.

	DVM			
	Tespit	0-30 sn	30-60 sn	60-90 sn
Doğruluk (%)	85,30 ± 0,12	82,43 ± 0,11	78,15 ± 0,23	75,54 ± 0,23
Duyarlılık (%)	86,01 ± 0,27	84,5 ± 0,17	79,44 ± 0,38	77,9 ± 0,25
Özgüllük (%)	84,68 ± 0,25	81,13 ± 0,23	76,8 ± 0,22	74,06 ± 0,30
PPV (%)	87,03 ± 0,19	82,27 ± 0,17	78,09 ± 0,19	75,83 ± 0,25

Çizelge 4.9-4.11 sonuçları incelendiğinde hem OUA tespiti hem de tahmininde en iyi başarıyı RAU-kNN sınıflandırıcısı göstermiştir. Global maksimum havuzlama katmanından çekilen 512 adet özniteliğin kullanıldığı çalışmada RAU-kNN, apne olaylarını %89,70 ± %0,28 doğrulukla tespit etmiş ve tahminlemede en iyi sonuçları 0-30 sn kesitleri kullanıldığı durumda %86,97 ± %0,35 doğrulukla vermiştir. Önceki validasyon sonuçlarına göre OUA tespit doğruluğunda % 4,3, 0-30 sn kesitlerinde %4,6, 30-60 sn kesitlerinde %5,4 ve 60-90 sn kesitlerinde %6,4 oranında bir artış olduğu gözlemlenmiştir.

DVM ve RAU-D sınıflandırıcıları bu çalışmada hemen hemen aynı sonuçları vermiştir. DVM, apne kesitlerini %0,08 oranında daha az bir doğruluk oranı ile tespit ederken, RAU-D %0,11 farkla apne kesitlerini daha az doğrulukla tespit etmiştir. Benzer şekilde tahminleme için kullanılan kesitlerde de DVM ve RAU-D, önerilen ESA modelinin sonuçları ile yaklaşık olarak aynı sonuçları vermiştir. Bu bağlamda RAU-kNN sınıflandırıcısının OUA tespit ve tahmininde performans başarısını olumlu ve etkili bir şekilde iyileştirdiği söylenebilmektedir.


Çizelge 4.10 : Derin özniteliklerin RAU-kNN ile sınıflandırma sonuçları.

	RAU-kNN			
	Tespit	0-30 sn	30-60 sn	60-90 sn
Doğruluk (%)	89,70 ± 0,28	86,97 ± 0,35	84,54 ± 0,32	82,14 ± 0,43
Duyarlılık (%)	90,39 ± 0,51	88,19 ± 0,52	87,14 ± 0,53	85,86 ± 0,66
Özgüllük (%)	85,57 ± 0,52	84,26 ± 0,95	82,71 ± 0,90	80,28 ± 0,76
PPV (%)	87,69 ± 0,35	85,7 ± 0,63	83,85 ± 0,60	81,21 ± 0,55

Çizelge 4.11 : Derin özniteliklerin RAU-D ile sınıflandırma sonuçları.

	RAU-D			
	Tespit	0-30 sn	30-60 sn	60-90 sn
Doğruluk (%)	85,27 ± 0,27	82,16 ± 0,23	78,62 ± 0,27	75,48 ± 0,30
Duyarlılık (%)	85,38 ± 0,38	84,69 ± 0,31	80,54 ± 0,49	78,66 ± 0,42
Özgüllük (%)	85,15 ± 0,30	80,34 ± 0,37	76,61 ± 0,25	74,31 ± 0,29
PPV (%)	86,44 ± 0,25	81,72 ± 0,27	78,14 ± 0,20	75,28 ± 0,26

Şekil 4.14'te önerilen ESA mimarisinin kendi sınıflandırıcısından elde edilen 10 kat çapraz validasyon sonuçları ile derin özniteliklerin DVM, RAU-kNN ve RAU-D sınıflandırıcısının sonuçları arasındaki farklar bar grafiği olarak gösterilmiştir. Görüldüğü üzere doğrusal kernellerin kullanıldığı DVM ve RAU-D sınıflandırıcıları sınıf ayırımında kısıtlı bir performans göstererek önerilen model ile yakın sonuçlar sunmuştur. RAU-kNN yöntemi ise parametrik olmayan yapısı itibarıyla eğitim verisi için bir varsayımda bulunmamaktadır. Bu durum, doğrusal olmayan verilerin sınıflandırılmasında RAU-kNN'in sonuçları net bir şekilde iyileştirmesini sağlamıştır.



Şekil 4.14 : Önerilen model ile farklı sınıflandırıcıların OUA tespiti ve tahmini için doğruluk performansları.

Çizelge 4.12’de skalogram ve spektrogram görüntülerinin tespit ve farklı tahmin süreleri için bir EKG kesitini (30 saniye) kullanarak görüntü oluşturma ve önerilen değiştirilmiş ResNet18 modelinin verdiği sınıflandırma cevabı için gereken süreler paylaşılmıştır. Gözlemlenen sonuçlara göre SDD, KZFT’ye kıyasla daha kısa süre içerisinde görüntü üretmektedir. Sınıflandırma süresinin ~0,63 sn olduğu dikkate alındığında toplam tepki süresi skalogram görüntüleri için en fazla 1,01 sn, spektrogram görüntülerinde ise en fazla 1,73 sn ’ye ulaşmaktadır. Çizelge 4.13’te ise aynı EKG kesitlerinin DVM, RAU-kNN ve RAU-D ile sınıflandırıldığı durumda gereken tepki süreleri paylaşılmıştır. Burada, test görüntüsünün sınıflandırılmasında üç sınıflandırıcının da ResNet18 modelinden daha hızlı tepki verdiği görülmektedir. Geleneksel makine öğrenmesi yöntemlerinin kullanıldığı bu uygulamada 2B ESA modeli ile çıkarılan özneliklerin sınıflandırılma süresi en kısa RAU-D modelinde en uzun ise RAU-kNN modelinde olmuştur. Performans başarısı ve tepki süreleri karşılaştırıldığında RAU-D, OUA tahmininde 0,69 sn’de %82,16 doğrulukla cevap verebilirken, RAU-kNN 0,82 sn’de %86,97 doğrulukla cevap verebilmektedir. Tüm sınıflandırıcıların tepki süreleri OUA kestirimi için yeterli olarak değerlendirilmiş ve OUA tahmin başarısı daha yüksek olan model olan RAU-kNN, önerilen çalışmada en başarılı model olarak değiştirilmiştir. Skalogram görüntülerini kullanan bu modeli kullanan bir erken uyarı sisteminin geliştirilmesi durumunda, OUA yaklaşık 0,7 sn gecikmeyle ön görülerek kişinin uyarılması sağlanabilecektir. Bu sayede OUA sendromunda karşılaşılabilecek olası sendromlar gerçekleşmeden son bulabilecektir. Bu bağlamda, donanımsal yeteneklerin daha fazla olduğu bir ortamda tepki sürelerinin azalması da beklenmektedir.

Çizelge 4.12 : Bir kesit için görüntü üretimi ve önerilen ResNet18 modelinin sınıflandırma sonucu vermesi için gerektirdiği süreler.

	Skalogram	Spektrogram
	Görüntü Üretimi + Tepki Süresi	Görüntü Üretimi + Tepki Süresi
Tespit	0,97 sn	1,73 sn
0-30 sn kesit	0,99 sn	1,70 sn
30-60 sn kesit	1,01 sn	1,71 sn
60-90 sn kesit	0,97 sn	1,72 sn

Çizelge 4.13 : Bir kesit için görüntü üretimi ve DVM, RAU-kNN, RAU-D modellerinin sınıflandırma sonucu vermesi için gerektirdiği süreler.

	Skalogram		
	Görüntü Üretimi + Tepki Süresi		
	DVM	RAU-kNN	RAU-D
Tespit	0,71 sn	0,85 sn	0,68 sn
0-30 sn kesit	0,70 sn	0,82 sn	0,69 sn
30-60 sn kesit	0,70 sn	0,81 sn	0,72 sn
60-90 sn kesit	0,69 sn	0,77 sn	0,70 sn



5. DEĞERLENDİRME VE TARTIŞMA

Bu tez çalışmasında, tanısı konmuş EKG sinyalleri kullanılarak OUA tahmini yapan ESA modelleri önerilmiştir. İlk olarak, kullanılan veri setlerinde taban hattı düzeltmesi ve z-skoru normalizasyonu uygulanarak kayıtlar için bir standart oluşturulmuştur. Ardından bu sinyaller 30 saniyelik kesitlere bölütlenerek OUA'nın gerçekleştiği aralık, OUA başlangıcı öncesi 30 saniye aralığı (0-30 sn), OUA öncesi 30-60 sn aralığı, OUA öncesi 60-90 sn aralığı ve tanımlanan bu bölgeler dışındaki 30 sn aralıkları (Non-OUA) belirlenmiştir. Bölütlenen kesit sayılarında farklılık gözlemlenmesi sonucu SMOTE algoritması ile sentetik veri artırımı uygulanmış ve dengeli bir veri seti kümesi oluşturulmuştur. Daha sonra, her bir kesit için skalogram ve spektrogram görüntüleri üretilerek ESA modellerine girdi için kullanılacak veritabanı hazırlanmıştır. Ardından bu veri tabanının %80'i eğitim, %10'u validasyon ve %10'u test için bölünmüştür. Veri tabanının eğitim, validasyon ve test kümelerine bölünmesinde OUA/Pre-OUA ve Non-OUA dağılımı oransal olarak dengeli olacak şekilde düzenlenmiştir.

Daha önceki bölümlerde de belirtildiği üzere çalışmadaki temel amaç derin öğrenme modellerinde EKG sinyallerini kullanarak OUA tahmini yapabilmektir. OUA tespit başarısının tahmin başarısından daha yüksek olması gerektiği önceki bölümlerde bahsedilen gerekçelerle açıklanmıştır. Bu durumu doğrulamak ve önerilen tahmin modellerinin başarısını yorumlayabilmek adına ek bir uygulama olarak OUA tespiti de yapılmıştır. Gözlemlenen bulgularda OUA tespitinin en yüksek sınıflandırma başarısını vermiş olması, tahmin uygulamaları için de iyi bir gösterge olarak değerlendirilmiştir.

Uygulanan testlerin başarısı doğruluk, duyarlılık, özgüllük ve pozitif tahmin değeri kullanılarak değerlendirilmiştir. İlk olarak önceden eğitilmiş AlexNet, GoogleNet ve ResNet18 mimarileri kullanılarak bu mimarilerin optimize edilmiş ağırlıkları kullanılmadan sıfırdan eğitim yapılarak skalogram ve spektrogram görüntülerinin OUA tespit ve tahmin performansı irdelenmiştir. Gözlemlenen sonuçlara göre skalogram görüntüleri spektrogram görüntülerine kıyasla daha iyi sınıflandırma sonuçları vermiştir.

AlexNet mimarisi OUA tespitinde daha iyi performans (%82,78 doğruluk) gösterirken ResNet18 mimarisi OUA tahmininde daha başarılı (0-30 sn kesitlerde %75,45, 30-60 sn kesitlerde %73,13 ve 60-90 sn kesitlerde %70,42 doğruluk) bulunmuştur.

Uygulamanın bir diğer adımı, transfer öğrenme kullanımı ile çalışmanın tekrarlanması olmuştur. Burada ImageNet veri seti kullanılarak ağırlıkları önceden optimize edilmiş mimariler için yeniden bir eğitim tanımlanmıştır. AlexNet, GoogleNet ve ResNet18 mimarilerindeki mevcut optimize ağırlıklar kullanılarak yeniden bir ağırlıklandırma yapılmak üzere eğitim tekrarlanmıştır. ImageNet veri setine ait görüntülerinde herhangi bir OUA kesitine ait skalogram veya spektrogram görüntüsü bulunmadığından modelin eğitimi sırasında katmanlarda dondurma (freezing) işlemi başarıyı oldukça düşürmüştür; bu nedenle eğitim için herhangi bir katmanda dondurma uygulanmamıştır. Sıfırdan öğrenme ve transfer öğrenme için hassas ayarlama (fine tuning) yapılarak sınıflandırma katmanının sınıf sayısı iki olacak şekilde düzenlenmiştir.

Transfer öğrenme sonuçlarına bakıldığında, ResNet18 skalogram görüntüleri için yine en iyi tahminleme sonuçlarını (0-30 sn kesitlerde %78,05, 30-60 sn kesitlerde %75,05 ve 60-90 sn kesitlerde %73,77 doğruluk) verirken AlexNet bu kez spektrogram görüntüleri ile en iyi tespit sonuçları sunmuştur. Sıfırdan eğitim sonuçlarına kıyasla transfer öğrenmede sonuçların iyileşmiş olması, önceden eğitilmiş ağırlıkların yeniden optimizasyonunun sınıflandırmayı olumlu şekilde etkilediğini göstermektedir. GoogleNet, her iki çalışmada da en düşük performans sonuçlarını vermiştir. Buna karşın skalogram görüntüleri kullanıldığı durumda GoogleNet OUA tespitinde %80,04 doğruluk değeri ile kabul edilebilir bir performans sunmuştur.

GoogleNet diğer iki mimariye kıyasla katman derinliği en fazla olan mimaridir. Burada katman derinliğinin artmasıyla, kaybolan gradyan etkisinin ortaya çıkması test performansının çoğunlukla düşük olmasına neden olmuştur. Performans düşüklüğünün bir diğer nedeni olarak GoogleNet mimarisinin katman derinliğine bağlı olarak 30 saniyelik kesitler için ürettiği yüksek seviyeli özneliklerin OUA tahmin modeli önermek için uygun olmadığı söylenebilir. Diğer yandan sıralı yapıdaki düşük katman sayısındaki AlexNet mimarisi ise ele alınan problemin yüksek başarıda sınıflandırılmasında yetersiz kalmaktadır. ResNet18'in artık bağlantı bloğu kullanması ile kaybolan gradyan problemine çözüm bulması OUA sınıflandırma probleminde diğer iki mimariye göre en iyi başarıyı ortaya koymuştur.

Sıfırdan eğitim ve transfer öğrenmesi uygulamalarında ResNet18 mimarisinin sunduğu başarının üzerine, bu mimari üzerinde OUA tahmin başarısını artırmaya yönelik değişiklikler uygulanmıştır. Bu amaçla, katman sayısında artırma/azaltma, farklı havuzlama yöntemlerinin kullanımı, artık bloklara katman ekleme/çıkarma, tam bağlantı katmanlarının düğüm sayısında değişiklik ve dropout kullanımı gibi birçok deneme ile ağ başarısı iyileştirilmeye çalışılmıştır. Uygulanan testler sonucunda ağ başarısı için en etkili bulunan modelin detayları Çizelge 4.7’de verilmiştir. Global ortalama havuzlama yerine global maksimum havuzlama kullanımı model başarısını olumlu yönde etkilerken, dropout ve 512 düğümlü tam bağlantı kullanımı toplam bağlantı sayısını azaltarak aşırı öğrenme durumunun önüne geçilmesini sağlamıştır. ResNet18’e kıyasla daha az öğrenilebilir parametre sayısı içeren bu geliştirilmiş mimaride OUA tespiti için skalogram görüntüleri %85,20 doğruluk değerine ulaşırken OUA tahmininde ise %82,30 (0-30 sn), %78,91 (30-60 sn) ve %75,66 (60-90 sn) doğruluk değerleri gözlemlenmiştir. Önerilen modelin kararlılığını ve güvenilirliğini gözlemlenmek için 10 kat çapraz validasyon yöntemi uygulanmıştır. Validasyon sonuçlarına göre skalogram görüntülerinde ortalama doğruluk değeri OUA tespiti için $85,38 \pm 0,95$, 0-30 sn kesitler için $82,36 \pm 1,07$, 30-60 sn kesitler için $79,09 \pm 1,17$ ve 60-90 sn kesitler için $75,77 \pm 1,11$ olarak tespit edilmiştir. Spektrogram görüntülerinde ise OUA tespiti için $84,68 \pm 0,98$, 0-30 sn kesitler için $80,24 \pm 1,04$, 30-60 sn kesitler için $77,59 \pm 1,05$ ve 60-90 sn kesitler için $74,58 \pm 1,13$ doğruluk değerleri gözlemlenmiştir. Gözlemlenen test performansı ve validasyon sonuçlarının tutarlılığı önerilen modelin güvenilirliğini, doğruluğunu ve sağlamlılığını (robustness) ortaya koymuştur.

OUA olaylarından hemen önceki 30 saniyelik kesitler gelecekteki bir OUA olayı için diğer tahmin sürelerine kıyasla daha yüksek doğruluk tahmininde bulunmuştur. Bu durum kardiyak aktivitesindeki değişikliğin OUA başlangıcından hemen önceki 30 saniye içinde en fazla olduğunu göstermektedir. Tahmin süresi arttıkça tanısal bilginin kaybolmaya başlaması; bu nedenle gözlemlenen özneliklerin daha az ayırt edici olması ve EKG sinyalindeki durağansızlığın apne anından öncesine gidildikçe artması, sınıflandırma performansının azalmasına neden olmuştur. Bu nedenle gözlemlenen bulgular, apne anından önce QRS kompleksinin genliğinde, R-R aralıklarının süresinde veya bir kalbin elektrofizyolojik davranışında olası değişikliklerin olabileceğini desteklemektedir.

Skalogram görüntüleri genel olarak spektrogram görüntülerine kıyasla daha iyi bir sınıflandırma başarısı sunmuştur. Skalogram görüntülerinin bu başarısı şu şekilde gerekçelendirilmektedir. Fourier dönüşümüne kıyasla dalgacık dönüşümünün en önemli avantajı hem yerel spektral hem de zamansal bilgiyi çıkarma yeteneğidir. Öte yandan KZFD, bir sinyali bölümlere ayırıp her bölüm üzerinde bir Fourier dönüşümü uygulamaktadır. Gözlemlenen bulgulara göre, dalgacık dönüşümünün sunduğu bu ayırıştırma yeteneği ve Morse ana dalgacıkların EKG sinyalini temsil etmede daha başarılı olması üzerine skalogram görüntüleri daha etkili sonuçlar sunmuştur.

Önerilen model sonuçlarının yorumlanabilirliği için Grad-CAM ile sınıflar arasındaki ayırt edici öznitelikler ısı haritası kullanılarak görsel olarak sunulmuştur (Şekil 4.10). Skalogram ve spektrogram görüntülerine ait Grad-CAM çıktılarında baskın olan frekans bileşenlerinin farklı frekans aralıklarında ortaya çıkması görselde ilk göze çarpan sonuçlardan biridir. Özellikle Non-OUA kesitlerine ait skalogram görüntülerinde ayırt edici özellikler görüntünün orta bölümünde ön plana çıkarken Pre-OUA kesitlerinde bu frekans bileşenlerine ait genliklerinin düşük olduğu gözlemlenmiştir. Spektrogram görüntülerinde ise Non-OUA kesitlerinde ayırt edici özelliklerin görüntünün alt bölümlerinde baskın olduğu gözlemlenirken Pre-OUA kesitlerinde bu özelliklerin görüntünün orta bölümünde yoğunlaştığı görülmektedir.

Son uygulamada, değiştirilmiş ResNet18 mimarisinin özniteliklerini belirleyen katman bilgileri kullanılarak mimarinin sınıflandırıcısını kullanmak yerine DVM, RAU-kNN ve RAU-D algoritmaları ile sınıflandırma çalışması yapılarak klasik makine öğrenme yöntemlerinin derin öznitelikleri sınıflandırmasındaki başarısı araştırılmıştır. Geleneksel kNN ve DA yöntemlerine kıyasla öznitelik uzayını alt uzaylara bölen ve her bir alt uzayın sınıflandırılması sonucunda nihai sınıflandırma kararını oy çokluğuna göre belirleyen RAU-kNN ve RAU-D algoritmalarının, sınıflandırma performansının iyileştirilmesinde daha etkili olduğu vurgulanmıştır [Url-2]. Doğrusal kernel kullanımı yerine verilerin birbirine olan mesafesine göre sınıflandırıldığı parametrik olmayan bir yöntem olan RAU-kNN, skalogram görüntülerine ait doğrusal olmayan özniteliklerin sınıflandırılmasında daha etkili bulunmuştur. 10 kat çapraz validasyon sonuçlarına göre RAU-kNN sınıflandırıcısı, DVM ve RAU-D'ye kıyasla doğruluk başarısında yaklaşık %4 oranında iyileştirme sağlamıştır. Sonuç itibarıyla, önerilen mimari ile tespit edilen özniteliklerin RAU-kNN

ile sınıflandırıldığı yaklaşımda çalışmadaki en yüksek performans sonuçları gözlemlenmiştir.

Literatürdeki OUA tahmini için yapılan benzer çalışmaların bulguları ile önerilen modelde ulaşılan performans sonuçlarının karşılaştırması Çizelge 5.1’de verilmiştir. Ayrıca, OUA tespiti için gözlemlenen sonuçların literatürdeki benzer çalışmalar ile karşılaştırması Çizelge 5.2’de verilmiştir.

Çizelge 5.1’e göre Waxman ve diğerleri, LAMSTAR sinir ağında 30 saniyelik kesitler kullanarak gelecekteki bir apne kesitini %80,2 duyarlılık, %72,7 özgüllük ve %75,1 PPV ile tahmin etmeyi başarmıştır [63]. Çalışmada 6 adet fizyolojik sinyal kullanılmış olup öznitelik çıkarımı manuel olarak yapılmıştır. Bu sonuçlara kıyasla önerilen ESA modelinde otomatik öznitelik çıkarımı ile yalnızca EKG kayıtları kullanılarak OUA tahmininde daha etkili sonuçların gözlemlenebildiği görülmüştür. De Falco ve diğerleri, 35 hasta verisinden kalp atım hızı değişkenliği özniteliklerini çıkararak bu öznitelikleri IF-THEN kurallarına göre sınıflandırmıştır [64]. Önerilen tahminleme çalışmasının sonucunda %84,2 doğruluk, %84,7 duyarlılık, %81,1 özgüllük ve 0,84 AUC değeri gözlemlenmiştir. Ancak, kullanılan veri seti bir dakikalık kesitler boyunca etiketlenmiş olup, kullanılan algoritma yalnızca bu kesitler içerisinde apne olup olmadığını kontrol etmektedir. Bu yapıya göre OUA olayının kesitin başlarında veya sonlarına doğru gerçekleşmesi durumunda bu kesit OUA kesiti olarak etiketlenmektedir. Yani, OUA olayının başlangıç anı belirsiz olmaktadır. Bu çalışmaya kıyasla önerilen tez çalışmasında OUA olaylarının başlangıç anına göre tahmin kesitlerinin belirleniyor olması, modelin daha kesin ve güvenilir sonuçlar sunmasını sağlamaktadır. Maali ve Al-Jumaily [65], burun hava akışı, göğüs ve karın hareketleri sinyallerini kullanarak önerdikleri ileri beslemeli geri yayılım algoritması ile 30 sn önceden tahminleme için ortalama 0,86 AUC değeri gözlemlenmiştir. Bu çalışmaya kıyasla önerilen ESA mimarilerinin hem skalogram ve spektrogram görüntüleri için daha iyi AUC sonuçları verdiği görülmekte hem de otomatik olarak çıkarılan özniteliklerin sınıflandırmada daha başarılı sonuçlar verdiği gözlemlenmektedir.

Kayıtlı veride solunumun durmasından kaynaklı fizyolojik ve morfolojik değişimin en fazla olduğu an, apne anının gerçekleştiği sırada meydana gelmektedir. Böylelikle, apne süreci ile apne olmayan bir süreç arasındaki farklılık en fazla olacaktır. Bu nedenle aynı model kullanılarak yapılan bir çalışmada OUA tespit başarısının tahmin

başarısından daha yüksek olması beklenmektedir. Önerilen çalışmada, bu durumun doğruluğunu test etmek için ve doğrulamak için OUA tespiti de yapılmıştır.

Çizelge 5.1 : OUA tahmini için literatür karşılaştırması.

	Kullanılan Sinyaller	Yöntem	% Doğruluk	% Duyarlılık	% Özgüllük	% PPV	% AUC
[63]	EEG, EOG, EMG, kalp atım hızı, burun basıncı, nefes sıcaklık değişimi	ANN	-	80,2	72,7	75,1	-
[64]	EKG	IF-THEN kuralları	84,2	84,7	81,1	-	0,84
[65]	Burun hava akışı, göğüs ve karn hareket sinyalleri	ANN	-	-	-	-	0,86
Önerilen model	EKG	2B – ESA Skalogram	82,3	83,2	82,2	82,9	0,90
		2B – ESA Spektrogram	80,1	81,9	77,2	78,7	0,87
		2B – ESA + DVM	82,4	84,5	81,1	82,2	0,90
		2B – ESA + RAU-kNN	86,9	88,1	84,2	85,7	0,94
		2B – ESA + RAU-D	82,1	84,6	80,3	81,7	0,89

Çalışmadaki motivasyon, apne tahmininde ESA'nın performansını yorumlamak ve iyileştirmek olduğundan, OUA tespitinin iyileştirilmesi için ayrıca bir çalışma yapılmamıştır. Buna karşılık önerilen RAU-kNN modelinin, literatürdeki benzer çalışmalara kıyasla doğruluk (%89,7), duyarlılık (%90,4), PPV (%87,7) ve AUC (0,94) kriterleri için daha iyi sonuçlar verdiği gözlemlenmiştir (Çizelge 5.2). Çizelge 5.2'ye göre önerilen modelde skalogram veya spektrogram görüntülerinin kullanıldığı durumda literatürdeki benzer çalışmalara yakın sonuçlar elde edildiği görülmektedir.

Çizelge 5.2 : OUA tespiti için literatür karşılaştırması.

	Kullanılan Sinyaller	Yöntem	% Doğruluk	% Duyarlılık	% Özgüllük	% PPV	% AUC
[56]	EKG	1B – ESA	89,4	89,8	89,1	83,6	0,96
[61]	EKG	1B – ESA	87,6	83,1	90,3	-	0,95
[79]	EKG	TDCS	85,1	86,2	84,4	77,2	0,85
[50]	EKG	2B – ESA	86,2	90,0	83,8	-	0,88
[60]	EKG	Karar Birleşimi	84,7	88,9	82,1	-	0,86
Önerilen model	EKG	2B – ESA Skalogram	85,2	86,2	85,0	85,6	0,92
		2B – ESA Spektrogram	84,7	85,8	83,8	84,7	0,91
		2B – ESA + DVM	85,3	86,0	84,7	87,0	0,92
		2B – ESA + RAU-kNN	89,7	90,4	85,6	87,7	0,94
		2B – ESA + RAU-D	85,2	85,4	85,2	86,4	0,91

Önerilen çalışmadaki temel motivasyon tahminleme sonuçlarını iyileştirmek olduğundan, OUA tespitinin iyileştirilmesi için veya literatürdeki benzer çalışmaların sunduğu bulguların üzerine çıkılması için ayrıca bir çalışma yapılmamıştır. Bu nedenle 2B-ESA skalogram ve spektrogram sonuçlarının mevcut çalışmalara kıyasla daha düşük performans sunmasının nedeni OUA özelinde iyileştirmeye gidilmemesidir. Sonuçlar arasındaki farklılıkların muhtemel sebepleri önerilen mimarilerin yapısına, kullanılan veri setlerinde seçilen örnek sayısına, kullanılan doğrulama yöntemlerine, optimizasyon farklılıklarına ve hiperparametrelerin seçimine dayanmaktadır. Buna karşın, derin özniteliklerin geleneksel makine öğrenmesi yöntemleri ile sınıflandırıldığı durumda gözlemlenen performans sonuçlarına göre literatürdeki benzer çalışmalardan doğruluk, hassasiyet ve PPV kriterlerine göre daha yüksek sonuçlar elde edildiği gözlemlenmiştir. Bir boyutlu EKG kesitlerine ait zaman-genlik bilgisi yerine 2B skalogram görüntüleri ile hem zaman hem de frekans eksenine ait bilgilerin bir arada değerlendirilmesi ve belirlenen özelliklerin RAU-kNN ile

sınıflandırılması, farklı modeller kullanan benzer çalışmalardan daha etkili sonuçlar sunmuştur.

Uygulanan testlerde apne başlangıcından itibaren 90 saniyeden daha uzak bir mesafedeki kesitlerin düşük tahmin performansı gösterdiği gözlemlenmiştir. Bu nedenle 90 saniyeden uzun tahmin süreleri için analiz yapılmamıştır.

OUA tahmininde, optimum kesit süresini belirlemek için değişen kesit süreleri test edilmiştir. 30 saniyenin altındaki aralıklar kullanıldığında performans sonuçlarının düşmeye başladığı tespit edilmiştir. Bunun nedeninin, daha kısa sürelerin morfolojik varyasyonlarının, yaklaşan olayları öngörmeye yetersiz kalması ve OUA olaylarını OUA olmayanlardan ayırabilmek için ayırt edici özellikleri uygun şekilde ifade etmemesi olduğu düşünülmektedir. Daha uzun kesit süreleri kullanıldığı durumda, performans sonuçlarının EKG'deki durağansızlık ve gürültü ile ilişkili olarak önemli ölçüde düştüğü gözlemlenmiştir. Apne uzunluğunun en az 10 saniye olduğu düşünüldüğünde, olayların başlangıcından önceki 30 saniye kesitlerinin, yaklaşan olaylar hakkında önemli bilgiler sağladığı gözlemlenmiştir. Bu sebeplere bağlı olarak, değişen kesit süreleri için sonuçların iyileştirilmesine ve optimize edilmesine odaklanılmamıştır. Bunun yanında Waxman ve diğerlerinin farklı kesit sürelerini dikkate aldığı çalışmada kesit uzunluğunun 30 sn kesit seçildiği durumda en iyi tahminleme sonuçlarının gözlemlendiği görülmüştür [63]. Bu nedenle önerilen çalışma kapsamında 30 saniye uzunluğundaki kesitlerin optimum uzunluk olduğuna karar verilmiştir.

Varsayılan yapılandırma olarak, GoogleNet ve ResNet18 224 x 224 boyutunda; AlexNet ise 227 x 227 boyutunda RGB görüntülerini girdi olarak kabul etmektedir. Transfer öğrenimi sırasında ağırlıklar bu girdi boyutlarına göre optimize edildiğinden, önceden eğitilmiş ağların optimize edilmiş parametrelerinden yararlanmak için orijinal girdi boyutlarının kullanımı tercih edilmiştir. Benzer şekilde, uyumluluğu korumak ve orijinal ResNet18 modeline sadık kalmak için ResNet18 mimarisi üzerinde değişiklikler yapılırken 224 x 224 giriş boyutunun kullanımı tercih edilmiştir.

Önerilen çalışmanın belirli sınırlamaları vardır. İlk olarak, önerilen modeller yalnızca OUA olaylarını öngörmektedir ve Merkezi, Mikst apne ve Hipopne gibi diğer uyku rahatsızlıklarını dikkate almamaktadır. Bu nedenle, diğer uyku bozukluklarına bağlı solunum olaylarıyla karşılaşıldığında yanlış sınıflandırma yapılabilir. İkinci olarak,

sınırlı sayıda denek verisi kullanılmıştır. Daha fazla denek kullanarak daha geniş bir eğitim ve test setine sahip olmak, doğruluk başarısını daha güvenilir kılacaktır. Son olarak, hareket ve horlama aktiviteleri EKG sinyallerinden tamamen filtelenmemiştir. Bu nedenle hareket ve horlama aktivitelerine bağlı olarak modelin yanlış pozitif verme olasılığı vardır. Yeterli veri etiketlemesinin yapıldığı ve veri sayısının artırıldığı takdirde bu sınırlamalara çözüm üreten, farklı apne türlerini de dikkate alarak tahminleme yapan kapsamlı modellerin geliştirilmesi gelecek çalışmalarda mümkün olacaktır.





6. SONUÇ

Bu tez çalışmasında, derin öğrenme kullanılarak OUA olaylarının otomatik tahmininin kapsamlı bir analizi sunulmuştur. Evrişimsel sinir ağları kullanılarak önerilen modellerde EKG kesitlerine ait skalogram ve spektrogram görüntüleri mimarilerde girdi olarak kullanılmıştır. Bu amaçla, farklı tahmin zamanlarına ait Pre-OUA ve Non-OUA kesitlerinin zaman-frekans özellikleri ESA modelleri tarafından tespit edilmiş ve bu iki sınıfı birbirinden ayıran ayırt edici özelliklerin saptanmasıyla gelecekteki OUA olayları hakkında yorum yapabilen modeller önerilmiştir. Tahminleme çalışmasının doğruluğu ve güvenilirliğini test etmek adına önerilen modellerin OUA tespitindeki başarısı da araştırılmıştır.

Çalışmada ilk olarak AlexNet, GoogleNet ve ResNet18 mimarileri ile sıfırdan eğitimin yapıldığı durumda tahmin performansı incelenmiştir. Bunun ardından, transfer öğrenme yöntemi ile eğitim süreci tekrar edilmiştir. ResNet18 mimarisinin artık blok kullanımı ile gradyan azalma problemine çözüm bulması, bu mimarinin performansını hem sıfırdan eğitim hem de transfer öğrenme yönteminde ön plana çıkarmıştır. ResNet18'in gösterdiği başarının ardından bu mimari üzerinde iyileştirmeler yapılarak tahmin başarısı artırılmaya çalışılmıştır. Çizelge 4.7'de paylaşılan mimari özelliklerinin belirlenmesiyle daha az öğrenebilir parametre kullanan ve OUA tespit/tahmin performansında iyileştirme sağlayan modifiye edilmiş yeni bir ResNet18 modeli önerilmiştir. Önerilen bu modelin güvenilirliği 10 kat çapraz validasyon yöntemi kullanılarak doğrulanmıştır. Ek olarak Grad-CAM yöntemi kullanılarak eğitilen mimaride sınıflar arası farklılıklar görsel olarak ortaya konmuş ve bulgular desteklenmiştir.

EKG kesitlerine ait skalogram görüntülerinin ortaya koyduğu performans üzerine önerilen model için farklı bir uygulama daha yapılmıştır. Bu uygulamada önerilen yeni ResNet18 modelinin katman bilgilerinden faydalanılarak sınıflara ait öznelikler tespit edilmiş ve bu öznelikler mimarinin kendi sınıflandırıcısı yerine DVM, RAU-kNN ve RAU-D ile sınıflandırılmıştır. Skalogram görüntülerinin kullanıldığı bu uygulamada doğrusal kernel kullanan DVM ve RAU-D yöntemlerine kıyasla RAU-kNN sınıflandırıcısı OUA tespitinde $\%89,70 \pm 0,28$, 0-30 sn kesitlerde $\%86,97 \pm 0,35$,

30-60 sn kesitlerde $\%84,54 \pm 0,32$ ve 60-90 sn kesitlerde $\%82,14 \pm 0,43$ doğruluk başarıyla çalışma kapsamındaki en yüksek tahmin sonuçlarını sunmuştur.

Gözlemlenen sonuçlar, literatürdeki benzer çalışmalar ile kıyaslanmış ve tahminleme çalışmalarında mevcut modellere kıyasla daha yüksek performans sonuçlarının elde edildiği görülmüştür. Önerilen modeller arasında hem değiştirilmiş ResNet18 hem de farklı sınıflandırıcıların kullanıldığı model bulguları, tek uçlu EKG sinyallerinin muhtemel OUA olaylarını tahmin etmede iyi bir belirteç niteliğinde kullanılabileceğini göstermektedir. Tahminleme modeli, OUA hastalarının gece uykusunda solunumunun durması sonucu hayati tehlike yaşamalarına önlem olarak bir alarm veya uyarı mekanizmasıyla, potansiyel OUA öncesi uyandırılmasını; bu sayede hayati tehlike riskinin önüne geçilmesini mümkün kılacaktır. Ayrıca önerilen modellerin, CPAP ve APAP sistemlerinde basınç değerlerinin adaptif olarak ayarlanmasına katkı sağlayacağı düşünülmektedir.

KAYNAKLAR

- [1] **Task Force AASM**, (1999). Sleep-related breathing disorders in adults: Recommendations for syndrome definition and measurement techniques in clinical research, *Sleep*, 22(5). 667–689.
- [2] **Semelka, M., Wilson, J., Floyd, R.**, (2016). Diagnosis and treatment of obstructive sleep apnea in adults, *American Family Physician*, 94(5), 355-360.
- [3] **Koskenvuo, M., Kaprio, J., Telakivi, T., Partinen, M., Heikkilä, K., Sarna, S.**, (1987). Snoring as a risk factor for ischaemic heart disease and stroke in men, *Br. Med. J.*, 294, 9–16.
- [4] **McDaid, C., Griffin, S., Weatherly, H., Duree, K., Van der Burgt, M., Van Hout, S., Akers, J., Davis, R. J., Sculpher, M., Westwood, M.**, (2009) Continuous positive airway pressure devices for the treatment of obstructive sleep apnoea-hypopnoea syndrome: a systematic review and economic analysis, *Health Technol. Assess.*, 13, 43–274.
- [5] **Qaseem, A., Dallas, P., Owens, D. K., Starkey, M., Holty, J. E. C., Shekelle, P., Clinical Guidelines Committee of the American College of Physicians**, (2014). Diagnosis of obstructive sleep apnea in adults: a clinical practice guideline from the American College of Physicians, *Annals of Internal Medicine*, 161(3), 210-220.
- [6] **Smallwood, P., Quinn, D. K., Stern, T. A.**, *Patients with Disordered*. Massachusetts General Hospital Handbook of General Hospital Psychiatry: Vol.2., Elsevier, (2010).
- [7] **Iber, C., Ancoli-Israel, S., Chesson, A. L., Quan, S. F.**, (2007). The new sleep scoring manual—the evidence behind the rules, *Journal of Clinical Sleep Medicine*, 3(02), 107-107.
- [8] **Berry, R. B., Budhiraja, R., Gottlieb, D. J., Gozal, D., Iber, C., Kapur, V. K., Marcus, C. L., Mehra, R., Parthasarathy, S., Quan, S. F., Redline, S., Strohl, K. P., Davidson, S. L., Tangredi, M. M.**, (2012). Rules for scoring respiratory events in sleep: update of the 2007 AASM manual for the scoring of sleep and associated events: deliberations of the sleep apnea definitions task force of the American Academy of Sleep Medicine, *Journal of Clinical Sleep Medicine*, 8(5), 597-619.
- [9] **Adult Obstructive Sleep Apnea Task Force of the American Academy of Sleep Medicine**, (2009). Clinical guideline for the evaluation, management and long-term care of obstructive sleep apnea in adults, *Journal of Clinical Sleep Medicine*, 5(3), 263-276.
- [10] **Alberdi, A., Aztiria, A., Basarab, A.**, (2016). Towards an automatic early stress recognition system for office environments based on multimodal measurements: A review, *Journal of Biomedical Informatics*, 59, 49-75.

- [11] **Yeh, Y. C., Wang, W. J.**, (2008). QRS complexes detection for ECG signal: The Difference Operation Method, *Computer Methods and Programs in Biomedicine*, 91(3), 245-254.
- [12] **Penzel, T., Kantelhardt, J. W., Lo, C. C., Voigt, K., Vogelmeier, C.**, (2003). Dynamics of heart rate and sleep stages in normals and patients with sleep apnea, *Neuropsychopharmacology*, 28(1), 48-53.
- [13] **Reddy, P., Valladares, E. M., Akkad, A., Garabet-Diramerian, L., Orban, M., Chang, P., Doshi, R. N., Hammond, T., Konecny, T.**, (2017). Acute ECG changes during authentic obstructive sleep apnea and hypopneas in humans, *Circulation*, 136(suppl_1), A17281-A17281.
- [14] **Song, C., Liu, K., Zhang, X., Chen, L., Xian, X.**, (2015). An obstructive sleep apnea detection approach using a discriminative hidden Markov model from ECG signals, *IEEE Transactions on Biomedical Engineering*, 63(7), 1532-1542.
- [15] **Bayrak, T., Koçak, O., Erdamar, A.**, (2011). Uyku Bozukluklarının Araştırılmasında Biyomedikal Mühendislik Yaklaşımları, *TMMOB EMO Ankara Şubesi Haber Bülteni*, 2, 12-14.
- [16] **Rosenblatt, F.**, (1958). The perceptron: a probabilistic model for information storage and organization in the brain, *Psychological Review*, 65(6), 386.
- [17] **Rumelhart, D. E., Hinton, G. E., Williams, R. J.**, (1986). Learning representations by back-propagating errors, *Nature*, 323(6088), 533-536.
- [18] **Hinton, G. E., Salakhutdinov, R. R.**, (2006). Reducing the dimensionality of data with neural networks, *Science*, 313(5786), 504-507.
- [19] **Bengio, Y., Lamblin, P., Popovici, D., Larochelle, H.**, (2006). Greedy layer-wise training of deep networks, *Advances in Neural Information Processing Systems*, 19.
- [20] **Ranzato, M. A., Poultney, C., Chopra, S., Cun, Y.**, (2006). Efficient learning of sparse representations with an energy-based model, *Advances in Neural Information Processing Systems*, 19.
- [21] **Chen, Y., Li, L., Xiao, J., Yang, Y., Liang, J., Li, T.**, (2018). Particle swarm optimizer with crossover operation, *Engineering Applications of Artificial Intelligence*, 70, 159-169.
- [22] **De Silva, D. D. N., Fernando, S., Piyatilake, I. T. S., Karunarathne, A. V. S.**, (2019). Wavelet based edge feature enhancement for convolutional neural networks, *Eleventh International Conference on Machine Vision (ICMV 2018)*, Munich, Germany, November 1-3.
- [23] **Hijazi, S., Kumar, R., Rowen, C.**, (2015). Using convolutional neural networks for image recognition, *Cadence Design Systems Inc.: San Jose*, 9, 1-12.
- [24] **Agarap, A. F.**, (2018). Deep learning using rectified linear units (relu), *arXiv preprint arXiv:1803.08375*, 1-7.

- [25] **Guo, Y., Liu, Y., Oerlemans, A., Lao, S., Wu, S., Lew, M. S.,** (2016). Deep learning for visual understanding: A review, *Neurocomputing*, 187, 27–48.
- [26] **Shen, L., Zhang, Q., Cao, G., Xu, H.,** (2018). Fall Detection System Based on Deep Learning and Image Processing in Cloud Environment. Complex, *Intelligent, and Software Intensive Systems*, 590-598.
- [27] **Srivastava, N., Hinton, G. E., Krizhevsky, A., Sutskever, I., Salakhutdinov, R.,** (2014). Dropout: a simple way to prevent neural networks from overfitting, *Journal of Machine Learning Research*, 15 (1), 1929-1958.
- [28] **Shimodaira, H.,** (2000). Improving predictive inference under covariate shift by weighting the log-likelihood function, *Journal of Statistical Planning and Inference*, 90(2), 227-244.
- [29] **Tan, C., Sun, F., Kong, T., Zhang, W., Yang, C., Liu, C.,** (2018). A survey on deep transfer learning, *International Conference on Artificial Neural Networks*, 270-279, Springer, Cham.
- [30] **Shao, L., Zhu, F., Li, X.,** (2014). Transfer learning for visual categorization: A survey, *IEEE Transactions on Neural Networks and Learning Systems*, 26(5), 1019-1034.
- [31] **Krizhevsky, A., Sutskever, I., Hinton, G. E.,** (2012). Imagenet classification with deep convolutional neural networks, *Advances in Neural Information Processing Systems*, 25.
- [32] **Han, X., Zhong, Y., Cao, L., Zhang, L.,** (2017). Pre-trained alexnet architecture with pyramid pooling and supervision for high spatial resolution remote sensing image scene classification, *Remote Sensing*, 9(8), 848.
- [33] **Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Erhan, D., Vanhoucke, V., Rabinovich, A.,** (2015). Going deeper with convolutions, *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, Boston, USA, June 7-12.
- [34] **He, K., Zhang, X., Ren, S., Sun, J.,** (2016). Deep residual learning for image recognition, *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, Las Vegas, USA, June 27-30.
- [35] **Ou, X., Yan, P., Zhang, Y., Tu, B., Zhang, G., Wu, J., Li, W.,** (2019). Moving object detection method via ResNet-18 with encoder–decoder structure in complex scenes, *IEEE Access*, 7, 108152-108160.
- [36] **Raschka, S.,** (2014). Naive bayes and text classification i-introduction and theory, *arXiv preprint arXiv:1410.5329*, 1-20.
- [37] **Vapnik, V.N.,** *The Nature of Statistical Learning Theory*, (Sf.188), New York, Springer-Verlag, (1995).
- [38] **Zhang, S., Li, X., Zong, M., Zhu, X., Cheng, D.,** (2017). Learning k for knn classification, *ACM Transactions on Intelligent Systems and Technology (TIST)*, 8(3), 1-19.

- [39] **Hmeidi, I., Hawashin, B., El-Qawasmeh, E.,** (2008). Performance of KNN and SVM classifiers on full word Arabic articles, *Advanced Engineering Informatics*, 22, 106-111.
- [40] **Klecka, W. R.,** *Discriminant analysis*, Vol. 19. Sage, (1980).
- [41] **Andreotti, F., Phan, H., De Vos, M.,** (2018). Visualising convolutional neural network decisions in automatic sleep scoring, *CEUR Workshop Proceedings*, 70-81.
- [42] **Selvaraju, R. R., Cogswell, M., Das, A., Vedantam, R., Parikh, D., Batra, D.,** (2017). Grad-cam: Visual explanations from deep networks via gradient-based localization, *Proceedings of the IEEE International Conference on Computer Vision*, Venice, Italy, 22-29 October.
- [43] **Li, K., Pan, W., Li, Y., Jiang, Q., Liu, G.,** (2018). A method to detect sleep apnea based on deep neural network and hidden Markov model using single-lead ECG signal, *Neurocomputing*, 294, 94-101.
- [44] **Pinho, A., Pombo, N., Silva, B. M., Bousson, K., Garcia, N.,** (2019). Towards an accurate sleep apnea detection based on ECG signal: The quintessential of a wise feature selection, *Applied Soft Computing*, 83, 105568.
- [45] **Prabha, A., Trivedi, A., Kumar, A. A., Kumar, C. S.,** (2017). Automated system for obstructive sleep apnea detection using heart rate variability and respiratory rate variability, *2017 International Conference on Advances in Computing, Communications and Informatics (ICACCI)*, Udupi, India, September 13-16.
- [46] **Fatimah, B., Singh, P., Singhal, A., Pachori, R. B.,** (2020). Detection of apnea events from ECG segments using Fourier decomposition method, *Biomedical Signal Processing and Control*, 61, 102005.
- [47] **Kalaivani, V.,** (2020). Automated recognition of obstructive sleep apnea using ensemble support vector machine classifier, *International Journal of Biomedical Engineering and Technology*, 33(3), 274-289.
- [48] **Andreotti, F., Phan, H., De Vos, M.,** (2018). Visualising convolutional neural network decisions in automatic sleep scoring, *CEUR Workshop Proceedings*, 70-81.
- [49] **Byeon, Y. H., Pan, S. B., Kwak, K. C.,** (2019). Intelligent deep models based on scalograms of electrocardiogram signals for biometrics, *Sensors*, 19(4), 935.
- [50] **Singh, S. A., Majumder, S.,** (2019). A novel approach osa detection using single-lead ECG scalogram based on deep neural network, *Journal of Mechanics in Medicine and Biology*, 19(04), 1950026.
- [51] **Tuncer, S. A., Akilotu, B., Toraman, S.,** (2019). A deep learning-based decision support system for diagnosis of OSAS using PTT signals, *Medical Hypotheses*, 127, 15-22.
- [52] **Erdenebayar, U., Kim, Y. J., Park, J. U., Joo, E. Y., Lee, K. J.,** (2019). Deep learning approaches for automatic detection of sleep apnea events from an electrocardiogram, *Computer Methods and Programs in Biomedicine*, 180, 105001.

- [53] **Nikkonen, S., Korkalainen, H., Kainulainen, S., Myllymaa, S., Leino, A., Kalevo, L., Oksenberg, A., Leppänen, T., Töyräs, J.,** (2020). Estimating daytime sleepiness with previous night EEG, EOG and EMG spectrograms in patients with suspected sleep apnea using a convolutional neural network, *Sleep*, 43, 1–7.
- [54] **Raghu, S., Sriraam, N., Temel, Y., Rao, S. V., Kubben, P. L.,** (2020). EEG based multi-class seizure type classification using convolutional neural network and transfer learning, *Neural Networks*, 124, 202-212.
- [55] **Zhang, J., Tang, Z., Gao, J., Lin, L., Liu, Z., Wu, H., Liu, F., Yao, R.,** (2021). Automatic detection of obstructive sleep apnea events using a deep cnn-lstm model, *Computational Intelligence and Neuroscience*, 2021, 1-10.
- [56] **Shen, Q., Qin, H., Wei, K., Liu, G.,** (2021). Multiscale deep neural network for obstructive sleep apnea detection using RR interval from single-lead ECG signal, *IEEE Transactions on Instrumentation and Measurement*, 70, 1-13.
- [57] **Gao, Q., Shang, L., Zhang, Y.,** (2020). Automated detection of sleep apnea using convolutional neural network from a single-channel ECG signal, *Proceedings of the 2020 2nd International Conference on Robotics, Intelligent Control and Artificial Intelligence*, Shanghai, China, October 17-19.
- [58] **Singh, H., Tripathy, R. K., Pachori, R. B.,** (2020). Detection of sleep apnea from heart beat interval and ECG derived respiration signals using sliding mode singular spectrum analysis, *Digital Signal Processing*, 104, 102796.
- [59] **Chen, Q., Yue, H., Pang, X., Lei, W., Zhao, G., Liao, E., Wang, Y.,** (2020). Mr-ResNeXt: a multi-resolution network architecture for detection of obstructive sleep Apnea, *International Conference on Neural Computing for Advanced Applications*, Shenzhen, China, July 3-5.
- [60] **Li, K., Pan, W., Li, Y., Jiang, Q., Liu, G.,** (2018). A method to detect sleep apnea based on deep neural network and hidden Markov model using single-lead ECG signal, *Neurocomputing*, 294, 94-101.
- [61] **Wang, T., Lu, C., Shen, G., Hong, F.,** (2019). Sleep apnea detection from a single-lead ECG signal with automatic feature-extraction through a modified LeNet-5 convolutional neural network, *PeerJ*, 7, e7731.
- [62] **Urtnasan, E., Park, J. U., Lee, K. J.,** (2018). Multiclass classification of obstructive sleep apnea/hypopnea based on a convolutional neural network from a single-lead electrocardiogram, *Physiological Measurement*, 39(6), 065003.
- [63] **Waxman, J. A., Graupe, D., Carley, D. W.,** (2010). Automated prediction of apnea and hypopnea, using a LAMSTAR artificial neural network, *American Journal of Respiratory and Critical Care Medicine*, 181(7), 727-733.

- [64] **De Falco, I., De Pietro, G., Sannino, G.,** (2015). On finding explicit rules for personalized forecasting of obstructive sleep apnea episodes, *2015 IEEE International Conference on Information Reuse and Integration*, San Francisco, USA, August 13-15.
- [65] **Maali, Y., Al-Jumaily, A.,** (2013). Multi neural networks investigation based sleep apnea prediction, *Procedia Computer Science*, 24, 97-102.
- [66] **Zhang, G. Q., Cui, L., Mueller, R., Tao, S., Kim, M., Rueschman, M., Mariani, S., Mobley, D., Redline, S.,** (2018). The National Sleep Research Resource: towards a sleep data commons, *Journal of the American Medical Informatics Association*, 25(10), 1351-1358.
- [67] **Jayant, A., Singh, T., Kaur, M.,** (2013). Different techniques to remove baseline wander from ECG signal, *Int. J. Emerg. Res. Manag. Technol*, 2, 16-19.
- [68] **Singh, P., Srivastava, I., Singhal, A., Gupta, A.,** (2019). Baseline wander and power-line interference removal from ECG signals using Fourier decomposition method, *Machine Intelligence and Signal Analysis*, 25-36.
- [69] **Chawla, N. V., Bowyer, K. W., Hall, L. O., Kegelmeyer, W. P.,** (2002). SMOTE: synthetic minority over-sampling technique, *Journal of Artificial Intelligence Research*, 16, 321-357.
- [70] **Zhang, H., Dong, Z., Gao, J., Lu, P., Wang, Z.,** (2020). Automatic screening method for atrial fibrillation based on lossy compression of the electrocardiogram signal, *Physiological Measurement*, 41(7), 075005.
- [71] **Pandey, S. K., Janghel, R. R.,** (2019). Automatic detection of arrhythmia from imbalanced ECG database using CNN model with SMOTE, *Australasian Physical & Engineering Sciences in Medicine*, 42(4), 1129-1139.
- [72] **Jiang, J., Zhang, H., Pi, D., Dai, C.,** (2019). A novel multi-module neural network system for imbalanced heartbeats classification, *Expert Systems with Applications: X*, 1, 100003.
- [73] **Huang, J., Chen, B., Yao, B., He, W.,** (2019). ECG arrhythmia classification using STFT-based spectrogram and convolutional neural network, *IEEE Access*, 7, 92871-92880.
- [74] **Seo, J. I., Park, E. K., Jang, J. Y.,** (2016). Comparison of ERG denoising performance according to mother function of wavelet transforms, *Journal of Korean Clinical Health Science*, 4(4), 756-761.
- [75] **Gupta, S., Cepeda-Valery, B., Romero-Corral, A., Shamsuzzaman, A., Somers, V. K., Pressman, G. S.,** (2012). Association between QRS duration and obstructive sleep apnea, *Journal of Clinical Sleep Medicine*, 8(6), 649-654.
- [76] **Shankar, S., Gupta, S. S., Rojas-Martel, G., Demir, S., Saxena, A., Obiagwu, C., Aggarwal, N., Rai, A. K., Kamholz, S., Shetty, V., Kupfer, Y.,** (2019). Electrocardiographic associations seen with obstructive sleep apnea, *Sleep Disorders*, 2019, 1-5.

- [77] **Hosmer D.W., Lemeshow S.,** *Applied Logistic Regression*, 2nd Ed. Chapter 5, New York, John Wiley and Sons, (2000).
- [78] **D'Agostino, J. V., Rodgers, E., Mauck, S.,** (2018). Addressing inadequacies of the observation survey of early literacy achievement, *Reading Research Quarterly*, 53(1), 51-69.
- [79] **Feng, K., Qin, H., Wu, S., Pan, W., Liu, G.,** (2020). A sleep apnea detection method based on unsupervised feature learning and single-lead electrocardiogram, *IEEE Transactions on Instrumentation and Measurement*, 70, 1-12.
- Url-1** <<https://towardsdatascience.com/simple-introduction-to-convolutional-neural-networks-cdf8d3077bac>>, alındığı tarih: 25.12.2021.
- Url-2** <<https://www.mathworks.com/help/stats/ensemble-algorithms.html#btbbds9>>, alındığı tarih: 02.01.2022.

