



**MAKİNA ÖĞRENMESİ ALGORİTMALARI YARDIMI
İLE POLİSOMNOGRAFİ SİNYALLERİNDEN UYKU
EVRELERİ SINIFLANDIRILMASI**

Yüksek Lisans Tezi

Hilal Sultan DURANOĞLU TUNÇ
Elektrik - Elektronik Mühendisliği Anabilim Dalı
Elektronik Bilim Dalı
Prof. Dr. Mehmet ERTUĞRUL
2019
Her Hakkı Saklıdır

**ATATÜRK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

YÜKSEK LİSANS TEZİ

**MAKİNA ÖĞRENMESİ ALGORİTMALARI YARDIMI İLE
POLİSOMNOGRAFİ SİNYALLERİNDEN UYKU EVRELERİ
SINIFLANDIRILMASI**

Hilal Sultan DURANOĞLU TUNÇ

**ELEKTRİK - ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI
Elektronik Bilim Dalı**

**ERZURUM
2019**

Her Hakkı Saklıdır



TEZ ONAY FORMU

MAKİNE ÖĞRENMESİ ALGORİTMALARI YARDIMI İLE POLİSOMNOGRAFI
SİNYALLERİNDEN UYKU EVRELERİ SINIFLANDIRILMASI

Prof. Dr. Mehmet ERTUĞRUL danışmanlığında, Hilal Sultan DURANOĞLU TUNÇ tarafından hazırlanan bu çalışma, 04/09/2019 tarihinde aşağıdaki jüri tarafından Elektrik-Elektronik Mühendisliği Anabilim Dalı Elektronik Bilim Dalı'nda Yüksek Lisans tezi olarak **oybirliği** ile kabul edilmiştir.

Başkan: Prof. Dr. Mehmet ERTUĞRUL

İmza :

Üye : Doç. Dr. Ahmet DUMLU

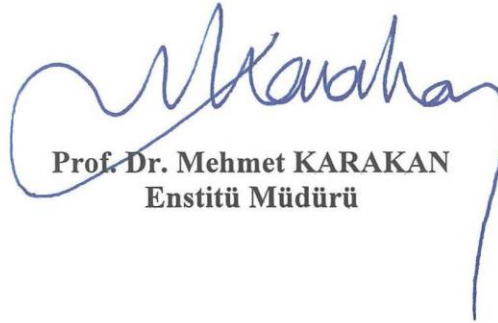
İmza :

Üye : Dr. Öğr. Üyesi Emin Argun ORAL

İmza :

Yukarıdaki sonuç;

Enstitü Yönetim Kurulu'nun 26.09./2019 tarih ve 38...../109..... nolu kararı ile onaylanmıştır.


Prof. Dr. Mehmet KARAKAN
Enstitü Müdürü

Not: Bu tezde kullanılan özgün ve başka kaynaklardan yapılan bildiriş, çizelge, şekil ve fotoğrafların kaynak olarak kullanımı, 5846 sayılı Fikir ve Sanat Eserleri Kanunundaki hükümlere tabidir.

ÖZET

Yüksek Lisans Tezi

MAKİNA ÖĞRENMESİ ALGORİTMALARI YARDIMI İLE POLİSOMNOGRAFİ SİNYALLERİNDEN UYKU EVRELERİ SINIFLANDIRILMASI

Hilal Sultan DURANOĞLU TUNÇ

Atatürk Üniversitesi
Fen Bilimleri Enstitüsü
Elektronik Mühendisliği Anabilimdalı
Elektronik Bilim Dalı

Danışman: Prof. Dr. Mehmet ERTUĞRUL

Bu tez çalışmasında, Physionet Challenge 2018 Database olarak internet üzerinden erişime açık polisomnografi bilgisi içeren bir veri seti kullanılmıştır. Polisomnografi veri seti bir çeşit biyolojik sinyaller dizisidir ve uyku evrelerinin otomatik olarak sınıflandırılması için kullanılmaktadır. Uyku, Amerikan Uyku Akademisi tarafından 2007’de yayınlanan AASM Uyku El kitabı’nda belirlenen standartlara göre beş aşamadan oluşan bir süreçtir, bunlar; Wake, NonRem1, NonRem2, NonRem3 ve REM evreleridir (AASM 2007). Uyku evrelerinin süresi ve uyku evrelerine girip çıkma sayısı kişinin uyku verimliliğini etkilemektedir ve aynı zamanda bu değişkenler çeşitli uyku bozukluklarının da nedeni olabilmektedir. Uyku ile ilgili rahatsızlıklarda uyku evrelerinin gözlemlenebilmesi büyük önem taşımaktadır.

Uyku evrelerinin otomatik olarak sınıflandırılması amacına yönelik çalışma yapılırken ilgili sinyal dizisi üzerinde öncelikle bazı kanallar seçilerek bu kanallara özellik çıkarma işlemi uygulanmıştır. Bu işlemler; MFCC, ICA olarak seçilmiştir. Sonrasında çıkarılan özellikler LSTM yazılım mimarisi kullanılarak sınıflandırma işlemine tabi tutulmuştur. Kişi bağımlı algoritma kullanılmak suretiyle elde edilen en yüksek doğruluk oranı %93,36 olmuştur. Kullanılan özellik çıkarma yöntemi sırasıyla ICA ve MFCC’dir, kullanılan kanal yalnızca 1. Kanaldır. Kişi bağımsız algoritma kullanılarak elde edilen en yüksek doğruluk oranı %86,89 olarak bulunmuştur. Bu doğruluk oranına erişilirken yalnızca MFCC ile özellik çıkarılmıştır ve 7. Kanalın sinyal bilgisi kullanılmıştır.

Yapılan çalışmada, bir uzman tarafından ve zaman gerektiren bir işlem olan bu sınıflandırma işlemi otomatik olarak yapılmaktadır. Uyku evresinin sınıflandırılması gibi tıbbi teşhis amaçlı uygulamaların otomatize edilmesi gelişen teknoloji ve bilimsel çalışmaların bir sonucu olmakla birlikte tezimi bu alanda yazmış olmamın da bu çalışmalara katkı sağlayacağını ummaktayım.

2019, 89 sayfa

Anahtar Kelimeler: Polisomnografi, Sinyal İşleme, Makine Öğrenmesi, LSTM, MFCC, ICA.

ABSTRACT

Master Thesis

SLEEP STAGE CLASSIFICATION FROM POLYSOMNOGRAPHY SIGNALS BY USING MACHINE LEARNING ALGORITHMS

Hilal Sultan DURANOĞLU TUNÇ

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

Supervisor: Prof. Dr. Mehmet ERTUĞRUL

In this thesis study, Pysionet Challenge 2018 Database which is consist of different kinds of biological signals (so we call this Database ‘Polysomnography’) is used for classifying sleep stages. While working for the purpose which is written above, firstly a few channels of the Database were tried to enhance the accuracy. Secondly different Feature Extraction Algorithms were tried to get the features of the Database (These feature extraction algorithms are: MFCC, ICA). Finally the Database was classified by using a software architecture which has the name of Long Short Term Memory.

Sleep consists of five stages, they are; Wake, NonRem1, NonRem2, NonRem3, Rem (AASM Manual). Duration of Sleep Stages and number of times in and out of these sleep stages are influential on the efficiency of sleeping and these topics can cause sleep disorders in different ways. It is of great importance to observe sleep stages in sleep disorders.

In this thesis study, the sleep stage classification process which is done by an expert and which takes a lot of time and human effort is done by computer automatically. So this automatic process saves human effort and time concurrently. Sleep stages were classified into 5 groups. The highest accuracy obtained using the subject dependent algorithm was 93,36%. The feature extraction method which is used ICA and MFCC, respectively, the channel used is only the first one. The highest accuracy rate obtained using the subject independent algorithm was found to be 86,89%. In achieving this accuracy, only the MFCC feature was used and the signal information of Channel 7 was used.

I would like to note that the automation of medical diagnostic applications such as the classification of the sleep stage is a result of developing technology and scientific studies, and I hope that my master thesis in this area will contribute to these studies.

2019, 89 pages

Keywords: Polysomnography, Signal Processing, Machine Learning, LSTM, MFCC, ICA.

TEŐEKKÜR

Çalıőmalarımnda yardımını esirgemeyen Tez Danıőmanım Sayın Prof. Dr. Mehmet ERTUĐRUL'a, tezimde yardımcı olan hocalarım Sayın Doç Dr. İbrahim Yücel ÖZBEK'e ve Sayın Dr. Emin Argun ORAL'a, beni bugünlere getirmiş olan kıymetli annem Hacer DURANOĐLU ve kıymetli babam Mehmet DURANOĐLU'na, bana her zaman destek olan sevgili eőim Selçuk TUNÇ'a, bitmez tükenmez enerjisiyle bana yaşam enerjisi aőılayan ođlum Ahmet Faik TUNÇ'a, tez ve ders dönemim boyunca her sıkıntıda yanımda olan arkadaşlarım Sultan ERTAŐ'a, Hayriye Tuba SEKBAN'a ve őükran Merve TÜZEMEN'e teőekkür ediyorum. Son olarak Physionet Cinc 2018 'You Snooze You Win' veri setinin oluőturulmasında emeđi geçen tüm çalıőan ve hastalara teőekkür ediyorum.

Hilal Sultan DURANOĐLU TUNÇ
Eylül, 2019

İÇİNDEKİLER

ÖZET.....	i
ABSTRACT	ii
TEŞEKKÜR.....	iii
SİMGELER ve KISALTMALARIN DİZİNİ.....	vii
ŞEKİLLER DİZİNİ.....	ix
ÇİZELGELER DİZİNİ	xi
1. GİRİŞ.....	1
2. KAYNAK ÖZETLERİ	3
2.1. Otomatik Uyku Evresi Sınıflandırması Üzerine Yapılmış Çalışmalar	4
2.2. Physionet Cinc Challenge 2018 Veri Seti Kullanılarak Yapılan Çalışmalar	6
2.3. Tek Boyutlu Sinyal Üzerine Yapılan Makine Öğrenmesi ve Derin Öğrenme Çalışmaları.....	9
3. MATERYAL ve YÖNTEM.....	10
3.1. Uyku ve Uykunun Evreleri.....	10
3.1.1. Uykunun tanımı	10
3.1.2. Uykunun evreleri	11
3.1.3. Uykunun evreleri ile beyin dalgaları arasındaki ilişki.....	12
3.2. Uyku Evrelerinin Sınıflandırılması İçin Kullanılan Temel İş Akışı	14
3.2.1. Veri setinin oluşturulması	16
3.2.2. Veri setinin eğitim ve test veri kümelerine ayrılması.....	18
3.2.3. Kullanılacak kanal veya kanal kombinasyonunun seçilmesi	18
3.2.4. Özellik çıkarma algoritmasının seçilmesi ve belirlenmiş olan kanal veya kanal kombinasyonundan özellik çıkarılması	19
3.2.5. Eğitim veri kümesi için özellik matrisi ile etiket bilgisinin ilişkilendirilmesi	20
3.2.6. Sınıflandırıcının eğitilmesi	20
3.2.7. Test veri kümesinden çıkarılan özelliklere göre sınıflandırıcının test veri kümesinin epokları için uyku evresi tahmininde bulunması.....	21

3.2.8. Test veri kümesinin etiketleri kullanılarak sınıflandırıcının tahminlerinin kontrol edilmesi ve doğruluk oranına erişilmesi.....	21
3.3. Polisomnografi	21
3.3.1. EEG (Elektroensefalografi).....	22
3.3.2. EOG (Elektrookülogram)	25
3.3.3. EMG (Elektromiyografi).....	26
3.3.4. ECG (Elektrokardiyografi).....	28
3.3.5. Solunum eforu	30
3.3.6. Oksihemoglobin saturasyonu	30
3.3.7. Hava akımı	31
3.4. Özellik Çıkarma Yöntemlerinin Tanıtılması.....	32
3.4.1. Mel kepstrum katsayıları	32
3.4.1.a. MFCC katsayılarının elde edilme sürecinin maddeler halinde incelenmesi.....	33
3.4.2. Bağımsız bileşen analizi (Independent component analysis-ICA).....	37
3.4.2.a. Bağımsız bileşen analizi yöntemi'nin teorik alt yapısı.....	39
3.4.2.b. ICA yönteminin tezin içerisinde kullanımı	40
3.5. Sınıflandırma metodu	40
3.5.1. Zaman serisi ve öğrenme kavramı.....	41
3.5.1.a. Zaman serisi.....	41
3.5.1.b. Öğrenme	42
3.5.1.c. Veri setini eğitim, doğrulama ve test setlerine ayırma	43
3.5.2. Yapay sinir ağları ve derin öğrenme kavramları	43
3.5.2.a. Sinir ağları	43
3.5.2.b. Yapay sinir ağları	43
3.5.2.c. Yapay sinir ağlarının farklı modelleri	46
3.5.3. Tez çalışmasında kullanılan algoritmalar ve elde edilen sonuçlar	51
3.5.3.a. Kişi bağımlı ya da kişiden bağımsız diye ayırmaksızın uygulanan algoritma.....	51
3.5.3.b. Kişi bağımlı algoritma.....	53
3.5.3.c. Kişiden bağımsız algoritma	55
3.6. Veri Setinin Tanıtılması	57

3.7. Performans Ölçütleri	59
3.7.1. Doğruluk oranı	59
3.7.2. 10 kat çapraz doğrulama yöntemi	60
3.7.3. Karmaşıklık matrisi (Hata matrisi).....	60
4. ARAŞTIRMA BULGULARI	64
5. TARTIŞMA ve SONUÇ.....	73
5.1. Çalışmalar Sonucu Bulunan Doğruluk Oranını Etkileyen Faktörler.....	78
5.2. Sonuç	80
KAYNAKÇA	83
ÖZGEÇMİŞ	90

SİMGELER ve KISALTMALARIN DİZİNİ

Simgeler

$\hat{X}(f)$: Sinyalin frekans düzlemindeki karşılığı
A	: Karıştırma matrisi
c(n)	: Kepstral alanında elde edilen sinyal
f	: Frekans
s(n)	: Örneklenmiş tek boyutlu sinyal
s	: Bağımsız kaynak sinyalleri
T	: Transfer Fonksiyonu
w	: Yapay sinir ağındaki ağırlık değeri
z	: Yapay sinir ağının çıkış vektörü
η	: Öğrenme oranı
$x(t)$: Sinyalin zaman düzlemindeki karşılığı
N_e	: Hatalı sınıflandırılan epok sayısı
N	: Toplam epok sayısı

Kısaltmalar

CNN	: Convolutional Neural Networks
DCT	: Discrete Cosine Transform
DCU	: Dense Convolutional Units
DSO	: Doğru Sınıflandırma Oranı
DVM	: Destek Vektör Makineleri
DWT	: Discrete Wavelet Transform
ECG	: Elektrokardiyogram
EEG	: Elektroensefalogram
EMG	: Elektromyogram

EOG	: Elektrokulogram
FN	: False Negative
FP	: False Positive
HR	: Heart Rate
HRV	: Heart Rate Variability
ICA	: Independent Component Analysis
IFFT	: Inverse Fourier Transform
LDA	: Linear Discriminant Analysis
LMS	: Least Mean Square
LMSE	: Least Mean Square Error
LSTM	: Long Short Term Memory
MFCC	: Mel Frequency Cepstrum Coefficients
MSPCA	: Multiscale Principal Component Analysis
NonRem1	: Rem olmayan uykunun ilk aşaması
NonRem2	: Rem olmayan uykunun ikinci aşaması
NonRem3	: Rem olmayan uykunun üçüncü aşaması
Rem	: Rem uykusu
PCA	: Principal Component Analysis
PSD	: Power Spectral Density
RIP	: Respiratory inductance plethysmography
RMS	: Root Mean Square
SD	: Standart Deviation
STFT	: Short Time Fourier Transform
SVM	: Support Vector Machines
TFCWT	: Time Frequency Continuous Wavelet Transform
TN	: True Negative
TP	: True Positive
Wake	: Uyanıklık hali
WT	: Wavelet Transform

ŞEKİLLER DİZİNİ

Şekil 3.1. Uyku evrelerinin beyin dalgaları ile ilişkisi.....	13
Şekil 3.2. Uyku evresi sınıflandırması için kullanılan temel iş akışı.....	15
Şekil 3.3. Ham EEG, EOG, EMG ve ECG sinyalleriyle 30 saniyede görüntülenen örnek bir PSG dosyası	17
Şekil 3.4. Sinyalin Etiket Bilgisi kullanılarak çizdirilen Hipnogram	17
Şekil 3.5. EEG sinyalinin oluşumu	23
Şekil 3.6. 10-20 Sistemine göre elektrot yerleşimi	25
Şekil 3.7. Gözlerin sağa ve sola dönmesi halinde elde edilen EOG sinyali	26
Şekil 3.8. Elektromiyografi cihazının temsili çalışma şekli	27
Şekil 3.9. Sağlıklı kişinin temel ECG dalga şekli	29
Şekil 3.10. Parmaktan oksihemoglobin saturasyonu ölçme.....	30
Şekil 3.11. MFFC katsayılarının elde edilmesinin blok diyagramı	33
Şekil 3.12. Frekans ölçeği ile mel ölçeği arasındaki ilişki.....	35
Şekil 3.13. 20 filtre için mel aralıklı filtre bankası örneği	36
Şekil 3.14. Karıştırılacak kaynak sinyaller	38
Şekil 3.15. Kaynak sinyallerin karıştırılması ile elde edilmiş iki farklı sinyal	38
Şekil 3.16. Karışım sinyallere ICA yöntemi uygulanması sonucu elde edilen bağımsız bileşen sinyalleri	38
Şekil 3.17. McCulloch ve Pitts modeli	44
Şekil 3.18. Tek kutuplu ve iki kutuplu sigmoid fonksiyonlar (Hatipoğlu 2016).....	45
Şekil 3.19. İleri Beslemeli yapay sinir ağı (Feed Forward Neural Network)	47
Şekil 3.20. Tekrarlayan yapay sinir ağı (Recurrent Neural Network)	47
Şekil 3.21. İleri beslemeli yapay sinir ağı.....	48
Şekil 3.22. Tamamen tekrarlayan yapay sinir ağı.....	50
Şekil 3.23. Uzun kısa süreli bellek topolojisinde hazırlanmış basit bir yapay sinir ağı .	51
Şekil 3.24. Kişi bağımlı ya da kişi bağımsız diye ayırmaksızın deney yapılırken kullanılan algoritma.....	52
Şekil 3.25. Kişi Bağımlı ve Kişiden Bağımsız Algoritmalar için kullanılan genel yapı.....	53

Şekil 3.26. Kişi Bağımlı Algoritma	54
Şekil 3.27. Kişiden bağımsız algoritma	56
Şekil 3.28. 10 kat çapraz doğrulama – 10 fold cross validation	60
Şekil 3.29. 2 x 2'lik Karmaşıklık Matrisinin görüntüsü	61
Şekil 3.30. 5'li sınıflandırma problemi için karmaşıklık matrisi	62



ÇİZELGELER DİZİNİ

Çizelge 3.1. Physio.net computing in cardiology challenge 2018 veriseti içeriği.....	58
Çizelge 4.1. Kanal bilgisi.....	64
Çizelge 4.2. MFCC değerlerinin ‘input size’ karşılığı.....	65
Çizelge 4.3. Kişi Bağımlı ya da Kişi bağımsız diye ayırmaksızın AASM standartlarına uygun olarak 5’li sınıflandırma için elde edilen deney sonuçları.....	67
Çizelge 4.4. Kişi Bağımlı ya da Kişi bağımsız diye ayırmaksızın AASM standartlarına uygun olarak 5’li sınıflandırma için elde edilen deney sonuçları içinde en yüksek doğruluk oranına sahip deney sonucu	68
Çizelge 4.5. Kişi bağımlı algoritma kullanılarak AASM standartlarına uygun olarak 5’li sınıflandırma için deney sonuçları	69
Çizelge 4.6. Kişi bağımlı algoritma kullanılarak AASM standartlarına göre 5’li sınıflandırma için en yüksek doğruluk oranını veren deneyin 10 kat çapraz doğrulama ile elde edilen sonucu	70
Çizelge 4.7. Kişi bağımlı algoritma kullanılarak AASM standartlarına göre 5’li sınıflandırma için en yüksek doğruluk oranını veren deneyin 10 kat çapraz doğrulama ile elde edilen sonucunun karmaşıklık matrisi	70
Çizelge 4.8. Kişiden bağımsız algoritma kullanılarak AASM standartlarına göre 5’li sınıflandırma için deney sonuçları	71
Çizelge 4.9. Kişiden bağımsız algoritma kullanılarak AASM standartlarına göre 5’li sınıflandırma için en yüksek doğruluk oranı	72
Çizelge 5.1. Physionet Challenge 2018 ‘You snooze you win’ veri seti kullanılarak yapılmış uyku evresi sınıflandırma çalışmaları	73
Çizelge 5.2. Qiao Li ve arkadaşlarının 2018 yılında yayınladığı çalışma ile kıyaslama için tez çalışmasından elde edilen 2 sınıflı sınıflandırma sonucu	74
Çizelge 5.3. Qiao Li ve arkadaşlarının 2018 yılında yayınladığı çalışma ile kıyaslama için tez çalışmasından elde edilen 2 sınıflı sınıflandırma sonucunun karmaşıklık matrisi	75

Çizelge 5.4. Physionet Challenge 2018 ‘You snooze you win’ veri seti kullanılarak yapılmış uyku evresi sınıflandırma çalışmaları	75
Çizelge 5.5. Howe - Patterson ve arkadaşlarının 2018 yılında yayınladığı çalışmadaki ikili sınıflandırmanın ilgili tezde uygulanmış hali.....	76
Çizelge 5.6. Howe - Patterson ve arkadaşlarının 2018 yılında yayınladığı çalışma ile kıyaslama için tez çalışmasından elde edilen 2 sınıflı sınıflandırma sonucunun karmaşıklık matrisi	76
Çizelge 5.7. Howe - Patterson ve arkadaşlarının 2018 yılında yayınladığı çalışma ile kıyaslama için tez çalışmasından elde edilen 2 sınıflı sınıflandırma sonucunun AUROC sonucu.....	76
Çizelge 5.8. Polisomnografi sinyalleri kullanılarak elde edilmiş literatürden derlenmiş, 5 sınıflı sınıflandırma sonuçları	77

1. GİRİŞ

Uyku, fiziksel ve psikolojik anlamda yaşam kalitesi için önemli bir etkidir, klinisyenler ve arařtırmacılar uyku üzerine uzun yıllardır arařtırmalar yapmaktadırlar. Uyku oldukça karmařık bir yapıdır ve üzerine yapılan alıřmalar hala sürmektedir(Collop *et al.* 2008). Uyku arařtırmalarını destekleyen yaygın yöntemlerden biri ‘uyku evresi sınıflandırması’ kavramıdır. Uzun yıllardır uyku evrelerinin skorlanması uyku mimarisinin anlaşılması için temel yöntem kabul edilmiştir ve bu yöntem hala uyku arařtırmalarında standart bir kavram olmaya devam etmektedir(Silber *et al.* 2007, Rechtschaffen and Kales 1968). Uyku evresi sınıflandırması için önerilen yaklařımlardan en bilineni el ile skorlama tekniğidir. Bu yöntem bir uyku uzmanı tarafından gerçekleştirilir. Bu işlemin gerçekleştirilebilmesi için uyku skorlaması yapılacak kişiden uyurken alınan polisomnografi bilgisi gerekmektedir. Teknolojinin gelişmesi ve standart yaklařımlardan kaynaklanan sorunlara çözüm olması umudu ile arařtırmacılar sınıflandırma sürecinin etkinliğini, güvenilirliğini ve doğruluğunu artırabilecek yöntemlerin arayışına girmiştir(Danker-Hopfe *et al.* 2004).

Uyku alıřması olarak da adlandırılan ‘polisomnografi’ birden ok biyosinyal verisini içeren, ok kanallı bir sinyal dizisidir. Bu sinyal dizisinin içerisinde EEG, EOG, EMG, Oksijen saturasyonu bilgisi, ECG, Solunum Sinyali bilgileri bulunmaktadır (Jafari *et al.* 2010). Hastanın ve hastalığın durumuna göre bu bilgilerin yanı sıra bacak hareketleri bilgisinin alınması için ekstra EMG bilgisi, ya da daha az veya fazla EEG kanalı bilgisi kullanılabilir. Polisomnografi verisinin toplanmasındaki amaç uyku ile ilgili hastalıkları teşhis etmektir. Bu biyolojik sinyaller yardımı ile bir uyku uzmanı hastanın uyku sorununu teşhis edebilmektedir. Bu süreç oldukça zaman alan ve uyku uzmanı açısından da detaylı ve dikkatli bir inceleme gerektirmesi açısından oldukça yorucu bir süreçtir. Uyku bozuklukları ve uykunun diğerk hastalıklarla ilişkisi de hesaba katıldığında bu sürecin hızlandırılması ve bilgisayar desteği ile yapılması sağlık alanına büyük katkı sağlayacaktır. Tez alıřmasındaki birinci amaç bu olmakla birlikte, edinilmiş olan Polisomnografi biyolojik sinyal dizisi pek ok sinyali ve dolayısı ile de biyolojik anlamda

pek çok bilgiyi içermektedir. Bu sinyal dizisi kullanılarak yapılacak farklı arařtırmalar da bilime katkı saęlayabilme olasılıęına sahiptir.

İnsan vücudu kimyasal ve elektriksel sinyallerden oluşmaktadır (Reilly and Lee 2010). Biyoelektrik yaşamsal fonksiyonlar için insan vücudunda kesinlikle olması gereken bir bileşendir (Reilly and Lee 2010). İnsan vücudunda üretilen biyolojik sinyallerin biyomedikal cihazlar yardımı ile alınması ve bilgisayar aracılığı ile işlenmesi başta tıp bilimi olmak üzere disiplinler arası pek çok alanda etkilidir ve önemi gün geçtikçe artmaktadır (Reilly and Lee 2010). Bu bakımdan polisomnografi sinyal dizisi biyolojik kaynaklı pek çok sinyali içermektedir ve incelenmesi de aynı anda pek çok sinyali incelemek olacağından amaçlanan ve amaçlananın dışında bilime katkı sunması olasıdır.

2. KAYNAK ÖZETLERİ

Uyku sinirbilim konusunda bilimsel anlamda ve insanların yaşamında sağlık için önemli bir role sahiptir (Pang *et al.* 2007). Canlıların vazgeçilmez ihtiyacı olan uyku, beyin hücrelerinin ve vücut sisteminin düzenli çalışmasını sağlayabilmesi için gerekli olan yaşamsal bir faz olarak tanımlanabilir. İyi bir uyku alındığının başlıca ölçütü sabah dinç uyanmak ve kişinin kendisini gün içinde zinde hissetmesidir (Anonymous 2018). Uyku olmadan beyin yeni olguları öğrenmeye ve hatıraları hatırlamaya izin veren yolları oluşturamaz veya koruyamaz, uyku eksikliğinde konsantre olmak ve hızlı bir şekilde yanıt vermek daha zor olur (Moorcroft 2005). Uyku, sinir hücrelerinin (nöronların) birbirleriyle nasıl iletişim kurduğunu da içeren birçok beyin fonksiyonu için önemlidir. Uykuya tüm canlıların ihtiyaç duyduğu bilinmektedir (Moorcroft 2005). Uyku vücuttaki hemen hemen her tür doku ve sistemi etkilemektedir; beyin, kalp, akciğerler, metabolizma, bağışıklık fonksiyonları, ruh hali ve hastalık direnci bunlara örnek olarak gösterilebilir (Moorcroft 2005). Aslında polisomnografi gibi pek çok biyolojik sinyali içeren bir sinyal seti ile uyku hastalıkları tanısı konulmasının nedeni de budur. Tez çalışmasında kullanılan veri seti Physionet Internet Sitesi üzerinden erişime açık olan Physionet Challenge 2018 isimli Polisomnografi Datasetidir. Physionet Challenge 2018 Dataseti 994 kişiden oluşan Training, 989 kişiden oluşan Test dosyalarını içermektedir (Ghassemi *et al.* 2018). Bu bir yarışma için oluşturulmuş bir veri seti olduğu için test veri setinin etiketlerine erişilememiş ve sadece eğitim veri seti kullanılmıştır. Test veri setinin etiketlerine erişilemediği için 994 kişiden oluşan eğitim veri seti; eğitim, doğrulama ve test olacak şekilde parçalanmıştır. Eğitim veri seti kullanılarak model oluşturulmuştur. Test olarak ayrılmış olan veri seti kısmı ile de model test edilmiştir. Üzerinde çalışılan Polisomnografi veri seti EEG, ECG, EMG, SaO₂ (oksijen saturasyonu) ve EOG bilgilerini içermektedir. İlk altı kanal EEG sinyalini oluşturmaktadır, 7. Kanal EOG (Sol göz EOG bilgisi), EMG bilgileri ise çene göğüs ve karından alınmaktadır. SaO₂ hariç tüm sinyaller 200 Hz örnekleme frekansı ile örneklenmiştir ve mikrovolt mertebesinde ölçüm yapılmıştır. Uyum göstermesi açısından SaO₂ de sonrasında 200 Hz'de örneklenmiştir (Anonymous 2018).

Uyku evreleri için standart kurallar ilk olarak Rechtschaffen ve Kales tarafından 1968'de ortaya konmuştur (Moser *et al.* 2009). 2007 yılında Amerikan Uyku Bilimi Akademisi (AASM) R&K'nın kurallarında çeşitli değişiklikler yapmıştır (Berry *et al.* 2012). Bu kurallara göre uyku aşamalarının sayısı beştir (Danker-Hopfe *et al.* 2009).

Bu aşamalar:

- 1)NonRem1
- 2)NonRem2
- 3)NonRem3
- 4)Rem
- 5)Wake

Otomatik uyku evresi sınıflandırması ile ilgili yapılan çalışmalar polisomnografi sinyal seti ya da bu sinyal setinden seçilmiş bir veya birden fazla sinyal kullanılarak uykunun bu beş evresinin otomatik olarak tahmin edilmesine dayalıdır. Kimi çalışmada Rem olmayan uyku evreleri (NonRem) birleştirilerek sınıflandırma problemi üç sınıflı bir problem haline getirilmiştir. Bu alanda yapılmış olan literatür taraması üç başlık altında toplanabilir.

2.1. Otomatik Uyku Evresi sınıflandırması üzerine yapılmış çalışmalar.

2.2. Physionet Cinc Challenge 2018 Dataseti Üzerine yapılan çalışmalar.

2.3. Tek Boyutlu sinyal üzerine yapılan Makine Öğrenmesi ve Derin Öğrenme çalışmaları.

2.1. Otomatik Uyku Evresi Sınıflandırması Üzerine Yapılmış Çalışmalar

Otomatik uyku evresi sınıflandırması üzerine incelenmiş yayınlardan ilki 'Oral ve arkadaşlarının 2017 yılında gerçekleştirdiği 'Genelleştirilmiş Süzgeç Tasarımı ile Uyku Evresi Sınıflandırma' çalışmasıdır. Bu çalışmada tek kanal EEG sinyali kullanılarak ikili sınıflandırma (Uyuyor / Uyumuyor) yapmak amaçlanmıştır. Kullanılan veritabanı

Physionet Veri Bankasının Sleep-Edf veritabanıdır. Çalışmada kepstrum katsayılarına dayalı özellikler kullanılarak Destek Vektör Makineleri ile ikili sınıflandırma yapılmıştır.

İki kat çapraz doğrulama (2 fold cross validation) kullanılarak elde edilen doğru sınıflandırma oranı %98.40 ve Kappa katsayısı %96.70'tir (Oral vd 2017).

Fonseca ve arkadaşlarının 2015 yılında gerçekleştirmiş olduğu 'ECG ve Solunum Çabası Sinyali Kullanılarak Uyku Evresi Sınıflandırılması' isimli çalışmada ECG sinyali ve Solunum Çabası Sinyali kullanılarak öncelikle dörtlü sınıflandırma yapılmıştır. Yapılan dörtlü sınıflandırmadaki uyku evreleri 'Uyanık', 'Rem uykusu', 'Nonrem Uykusu-Hafif, 'Nonrem Uykusu – Ağır' şeklinde belirlenmiştir. Daha sonra Nonrem uykusu ağır ve hafif olarak ayrılmadan tek bir evre olarak değerlendirilip üçlü sınıflandırma yapılmış ve sonuçlar kıyaslanmıştır (Fonseca *et al.* 2015). Kullanılan veri tabanında solunum çabası sinyali üzerinde gürültü gidermek için çeşitli filtreleme ve normalizasyon işlemleri yapılmıştır. Sonrasında ECG ve Solunum Çabası (RIP) sinyalinden özellik çıkarma işlemi gerçekleştirilmiştir. Sınıflandırıcı olarak doğrusal ayırdedici sınıflandırıcı (linear discriminant classifier -LDC) kullanılmıştır. Test ve train datasının ayrılmasında ise 10 kat çapraz doğrulama kullanılmıştır. Dörtlü sınıflandırma problemi için Kappa katsayısı:0.49, Doğruluk oranı: %69 bulunmuştur (Fonseca *et al.* 2015). Üçlü sınıflandırma problemi için Kappa katsayısı 0.56, Doğruluk oranı %80 olarak bulunmuştur (Fonseca *et al.* 2015).

Alickovic ve Subaşı tarafından yapılmış olan 'Otomatik Uyku Evreleri Sınıflandırma Problemi için çoklu SVM kullanımı' isimli çalışmada tek kanaldan alınmış olan EEG sinyali kullanılarak 5 uyku evresini otomatik olarak sınıflandırmak amaçlanmıştır. Bu çalışmada literatürde kullanılan gürültü giderme yöntemlerine ek olarak Çok Ölçekli Temel Bileşen Analizi (Multiscale Principal Component Analysis - MSPCA) yöntemi kullanılmıştır (Alickovic and Subasi 2018). Bu yöntem Dalgacık dönüşümünün (WT-Wavelet Transform) ve Temel Bileşen Analizi'nin (PCA) özelliklerini birleştirmek için Bakshi (Bakshi 1998) tarafından 1998 yılında ortaya konmuştur. Ön işleme tabi tutulmuş olan EEG sinyalinden özellik çıkarılmış (Ayrık Dalgacık Dönüşümü Yöntemi

kullanılmıştır), sınıflandırma işleminde ise Rotasyonel SVM adında modifiye edilmiş bir SVM uygulanmıştır (Alickovic and Subasi 2018). Beşli Uyku Evresi Sınıflandırması için elde edilmiş olan doğruluk oranı %91.1 olarak bulunmuştur(Alickovic and Subasi 2018). Patanaik ve arkadaşları tarafından 2018 yılında yapılan ‘Gerçek zamanlı otomatik uyku aşaması sınıflandırması için uçtan uca çalışan bir yapı’ isimli çalışmada 2 EEG ve 2 EOG kanalı kullanılmıştır, özellik olarak sinyalin spektrogramı çıkarılmış, sınıflandırma için ise Derin Evrişimsel Sinir Ağları (Deep Convolutional Neural Network) ve Çok Katmanlı Algılayıcı (Multilayer Perceptron) kullanılmıştır (Patanaik *et al.* 2018). 4 Farklı veri setine uygulanan bu çalışmada elde edilen en yüksek doğruluk oranı %90 olmuştur(Patanaik *et al.* 2018).

Khemiri ve arkadaşlarının 2015 yılında yaptığı ‘Somnografik ECG sinyali kullanılarak yavaş dalga uykusu ve REM uyku aşamalarının otomatik sınıflandırılması’ isimli çalışmada otomatik uyku aşaması sınıflandırması çalışması yalnızca ECG sinyaline dayanarak yapılmıştır (Khemiri *et al.* 2015). Kullanılan Database Physiobank Polysomnographic ECG 2011 Veri setidir, amaç Rem ve Rem olmayan uykunun sınıflandırılmasıdır. Sinyale sırası ile filtreleme ve özellik çıkarma işlemi uygulanmıştır. Elde edilen doğruluk oranları ise Rem olmayan uyku için %92.28 iken Rem Uykusu için %91.82’dir (Khemiri *et al.* 2015).

2.2. Physionet Cinc Challenge 2018 Veri Seti Kullanılarak Yapılan Çalışmalar

Tez çalışmasında kullanılmış olan Physionet Cinc Challenge 2018 veri seti kullanılarak tezin yazıldığı ana kadar 15 yayın yapılmış bulunmaktadır. Bu yayınların konusu polisomnografi verisinden otomatik uyku evresi sınıflandırma ve polisomnografi verisinden apne kaynaklı olmayan uyarılmanın teşhis edilmesi, uyarılma tipinin belirlenmesi (apne kaynaklı ya da apne kaynaklı olmayan uyarılma) şeklindedir. Tez çalışmasında kullanılan yöntemler bir bütün olarak ilgili yayınlarda kullanılmamıştır.

Bahsi geçen yayınlardan kısaca bu başlık altında söz edilecektir. Yapılan yayınlarda kullanılan yöntem bakımından polisomnografi verisi kullanılarak sınıflandırma yapılırken temelde 2 farklı temel yöntem kullanıldığı görülmektedir.

İlk yöntem insan zihni yardımıyla veri setinden çeşitli özellikler çıkarma ve bu özellikleri çeşitli sınıflandırıcı metotları ile sınıflandırma, ikinci yöntem ise Derin Öğrenme mimarisi geliştirerek bilgisayarın özellikleri kendisinin çıkarmasını sağlamaktır.

İlk yöntem, tamamen bilgisayar destekli özellik çıkarma ve sınıflandırma yöntemine göre daha eski bir yöntemdir. Diğer taraftan Derin Öğrenme Algoritmaları yardımı ile özellik çıkartma yöntemi oldukça yeni bir yaklaşımdır.

Farklı fizyolojik işaretler kullanarak derin sinir ağları (DNN'ler) ile uyarılmaların belirlenmesi (He *et al.* 2018) isimli çalışmanın amacı uyku apnesi kaynaklı olmayan uyarılmaları otomatik olarak teşhis etmektir. Bu amaçla yeni bir derin öğrenme algoritması geliştirilmiştir (He *et al.* 2018). Bu yeni algoritma iki ana parçadan oluşmaktadır, ilk parça Tek Katmanlı Evrimsel Sinir Ağından (One Layer Convolutional Neural Network -1 Layer CNN) oluşmaktadır ve amacı fizyolojik sinyalden özellik çıkarmaktır. İkinci parça ise İki Yönlü Uzun Kısa Dönem Hafıza mimarisinden (Bidirectional Long Short Term Memory – BLSTM) oluşmaktadır ki bu parçanın amacı da teşhis işlemini gerçekleştirmektir (He *et al.* 2018). Çalışmanın test veri setine uygulanması sonucunda elde edilen AUPRC değeri: 0.43'tür (He *et al.* 2018).

Birden çok fizyolojik sinyalden faydalanarak derin öğrenme ile uykuda uyarılma anlarının belirlenmesi (Li *et al.* 2018) isimli çalışmanın amacı uyku apnesi kaynaklı olmayan uyarılmaları otomatik olarak teşhis etmektir. Bu amaçla insan desteğiyle özellik çıkarma ve seçme işlemleri olmaksızın teşhis etme ve sınıflandırma işlemlerinin bilgisayar tarafından yapılması amaçlanmıştır. Veri setindeki tüm kanallar çalışma için kullanılmamıştır, 6 EEG kanalı ile 3 EMG kanalı kullanılmıştır (Li *et al.* 2018). Bu kanalların kullanılmasının sebebi Apne kaynaklı olmayan uyarılmaların bu kanallar vasıtasıyla daha kolay ayırdedilebileceği fikridir (Li *et al.* 2018). Her bir sinyal kanalı

görüntü olarak kabul edilmiş, bütün kanallar birbirine bağlanmıştır. Bu şekilde bu kanalların bütününden özellik çıkarma işlemi gerçekleştirilmiştir.

Çalışmanın Eğitim Veri Setine Uygulanması sonucu elde edilen AUPRC değeri 0,3173 ve AUROC değeri 0.8646 olurken Test veri setine uygulanması sonucunda elde edilen değerler AUPRC için 0,315 ve AUROC için 0,858 olmuştur(Li *et al.* 2018).

Tekrarlamalı Yapay Sinir Ağları Kullanarak Solunum Eforu Sinyalinden Uyarılma Anlarının Teşhisi (Práinsson *et al.* 2018) isimli çalışmanın amacı polisomnografi verisi yardımıyla uykuda uyarılma anlarını teşhis etmektir (Práinsson *et al.* 2018). Bu çalışmada insan desteği ile çıkarılacak özellikler seçilmiş, özellik çıkarma işlemi gerçekleştirilmiş ve çıkarılan özellikler kullanılarak LSTM (BRNN-LSTM kullanılmıştır) yardımıyla teşhis etme işlemi gerçekleştirilmiştir (Práinsson *et al.* 2018). Bu çalışmada bütün biyosinyal kanalları kullanılmıştır, fakat hepsinden kendi yapısına uygun olarak farklı özellikler çıkarılmıştır (Práinsson *et al.* 2018). EEG sinyalinden Dalgacık Dönüşümü yöntemi ile özellik çıkarılmış, Oksijen Saturasyonundan istatistiksel özellikler çıkarılmış, karın ve göğüs'ten alınan EMG sinyalleri arasındaki korelasyon hesaplanmış, ECG sinyalinden kalp atım hızı (Heart Rate -HR) ve kalp atım hızı değişimi (Heart Rate Variability - HRV) vektörleri bulunmuş ve bunlardan farklı özellikler çıkarılmıştır(Práinsson *et al.* 2018). Práinsson ve arkadaşlarının yaptığı bu çalışmada sınıflandırma aşamasında LSTM kullanılmıştır, çalışmanın sonucunda elde edilen değerler eğitim seti için AUPRC 0.452 ve AUROC 0.901 olurken Test Seti için AUPRC 0.452 olarak paylaşılmıştır (Práinsson *et al.* 2018).

Yoğun Evrişimsel Sinir Ağları Kullanarak Uykuda Uyarılma Anlarının Polisomnografi Bilgisinden Teşhis Edilmesi (Howe-Patterson *et al.* 2018) isimli çalışmada 'uyarılma'nın yakalanması, 'uyarılma'nın sınıflandırılması (Apne kaynaklı ya da doğal uyarılma), Uyku evresi sınıflandırma (Uyuyor / Uyumuyor şeklinde ikili sınıflandırma) incelenmiştir (Howe-Patterson *et al.* 2018) . Kullanılan yapı 'end to end programming' kavramına uygun şekilde tasarlanmıştır, insan desteği ile özellik çıkarma aşaması yoktur. Bunun için kullanılan derin öğrenme mimarisinde Çoklu Derin Evrişimsel Birimler (Multiple Dense Convolutional Units) ve Çift Yönlü Uzun Kısa Süreli Hafıza Katmanı(Bidirectional Long

Short Term Memory) kullanılmıştır (Howe-Patterson *et al.* 2018). Eğitim seti kullanılarak elde edilen uyarılma için AUROC değeri 0.91 olurken AUPRC değeri 0.528 olarak bulunmuştur (Howe-Patterson *et al.* 2018). Yine eğitim Seti kullanılarak Uyuyor / Uyanık şeklinde ikili sınıflandırma için AUROC değeri 0.953, AUPRC 0.820 olarak bulunmuştur(Howe- Patterson *et al.* 2018).

Test Seti kullanılarak elde edilen Uyarılma için AUROC değeri 0.931, AUPRC değeri 0.543 (Howe-Patterson *et al.* 2018) Yine Test Seti kullanılarak elde edilen Uyuyor / Uyanık şeklinde ikili sınıflandırma için AUROC değeri 0.960, AUPRC değeri 0.832'dir (Howe-Patterson *et al.* 2018) .

2.3. Tek Boyutlu Sinyal Üzerine Yapılan Makine Öğrenmesi ve Derin Öğrenme Çalışmaları

İnvaziv olmayan metotla elde edilmiş olan elektroensefalografi kayıtlarından bağımsız bileşen analizi metoduyla özellik çıkarılması (Azhar *et al.* 2017) isimli çalışmada EEG sinyallerinden ICA ile özellik çıkarabilmek için bir algoritma önerilmektedir. Önerilen algoritmada yapılan özellik çıkarma işleminin aynısı EEGlab ile yapılmış ve bu iki algoritmanın sonuçları karşılıklı olarak incelenmiştir(Azhar *et al.* 2017). Bu şekilde ICA ile EEG kayıtlarından özellik çıkarma işlemi yapılabileceği görülmüştür.

3. MATERYAL ve YÖNTEM

Dünyada, uyku bozukluklarından muzdarip çok sayıda insan bulunmaktadır (Ebrahimi *et al.* 2008). EEG, EMG, ECG ve EOG gibi bir dizi biyomedikal sinyal uyku laboratuvarlarında toplanmakta ve uyku evrelerinin skorlanması için kullanılmaktadır (Ebrahimi *et al.* 2008). Uyku ile ilgili hastalıkların tanı ve tedavisi için genel yöntem uyku evresinin sınıflandırılmasıdır, bunun için kullanılan en bilinen yaklaşım ise bir uyku uzmanı tarafından yapılan görsel incelemedir. Bu çok zaman alan ve zahmetli bir işlemdir (Ebrahimi *et al.* 2008). Otomatik uyku evresi sınıflandırması bu süreci kolaylaştırabilmektedir (Ebrahimi *et al.* 2008). Materyal ve Yöntem başlığı altında bu tez çalışmasında uyku evrelerinin sınıflandırılması amacı ile kullanılan yöntem ve tez çalışmasında kullanılan materyal açıklanacaktır.

3.1. Uyku ve Uykunun Evreleri

3.1.1. Uykunun tanımı

Yapılan çalışmalar gösteriyor ki uyku insanların günlük yaşantısını, fiziksel ve zihinsel sağlığını bilinenden fazla etkilemektedir. Artık beynin uyku sırasında çok aktif olduğu bilinen bir gerçektir (Mendelson 2017). Nörotransmitterler olarak adlandırılan kimyasallar, beyindeki farklı sinir hücreleri veya nöron gruplarına etki ederek uykuda mı uyanık mı olduğunu kontrol eder. Beyni omurilikle bağlayan beyin sapındaki nöronlar, insan uyanıkken beyin bazı kısımlarını aktif tutan nörotonin ve norepinefrin gibi nörotransmitterler üretir. Beynin belli kısımlarındaki nöronlar, uykuya dalındığında sinyal vermeye başlar. Bu nöronlar insanı uyanık tutan sinyalleri “kapatıyor” gibi davranır. Ayrıca araştırmalar gösteriyor ki insanlar uyanıkken ve uyuşukluk halindeyken adenosin adı verilen bir kimyasal kanda birikir, uyurken ise bu kimyasal yavaş yavaş bozulur (Mendelson 2017).

3.1.2. Uykunun evreleri

Uyku evreleri konusunda yapılan çalışmalar incelendiğinde Alan Rechtschaffen ve Anthony Kales'in 'İnsan Deneklerinin Uyku Aşamaları İçin Standartlaştırılmış Terminoloji, Teknikler ve Puanlama Sistemi El Kitabı', Amerikan Uyku Tıbbi Akademisi'nin (AASM) bugün yürürlükte olan ve uluslararası olarak kullanılan revizyonları yaptığı 2007 yılına kadar standart sınıflandırma metodu olarak kullanılmaktadır (Mendelson 2017). Bu tez çalışmasında kullanılan sınıflandırma yöntemi Amerikan Uyku Tıbbi Akademisi'nin oluşturduğu standarda göre hazırlanmıştır. Bu standarda göre Uyku evrelerinin sayısı 5'tir (AASM Manual). Bu evreler Wake, NonRem1, NonRem2, NonRem3, Rem olarak isimlendirilmektedir (AASM Manual).

Her bir uyku evresi belirli beyin dalgalarına ve nöronal aktiviteye bağlıdır. Tipik bir gece boyunca, sağlıklı bir kişi Nonrem ve Rem diye adlandırdığımız tüm uyku aşamalarını yaşar, sabahları daha uzun ve derin REM dönemleri oluşmaktadır (Colten and Altevogt 2006).

NonRem1: Rem olmayan uykunun birinci aşaması uyanıklık halinden uyku haline geçiştir. Bu kısa süren evre boyunca (yaklaşık birkaç dakika sürer) kalp atışlarımız, nefes alışverişlerimiz, göz hareketlerimiz yavaşlar ve kaslarımız ara sıra seğirmelerle gevşer. Beyin dalgalarımız (EEG ölçümleri ile eriştiğimiz sinyaller) uyanık durumdakine nazaran yavaşlamıştır, yani frekansında küçülme söz konusudur (Colten and Altevogt 2006), (AASM Manual).

NonRem2: Rem olmayan uykunun ikinci evresi, daha derin bir uykuya girmeden önceki hafif bir uyku dönemidir. Kalp atışlarımız ve nefes alışverişlerimiz bu aşamada da yavaşlığını korurken kaslar daha da gevşer, vücut ısısı düşer, göz hareketleri durur. Beyin Dalgaları yavaşlar, ancak bu evrede kısa süreli elektriksel aktivite patlamaları olmaktadır ve bu da Rem olmayan uykunun ikinci evresi için karakteristik bir özelliktir (Colten and Altevogt 2006), (AASM Manual).

NonRem3: Rem olmayan uykunun üçüncü evresi, sabahları yenilenmiş hissetmemizi sağlayan uyku evresidir. Uykunun en derin olduğu aşama bu aşamadır. Kalp atışları ve nefes alışverişleri bu aşamada en düşük seviyeye iner, kaslar gevşemiştir. Uykunun bu evresindeki kişiyi uyandırmak oldukça güç olabilir. Bu aşamadaki kişinin beyin dalgaları ise daha da yavaşlamıştır (Colten and Altevogt 2006), (AASM Manual).

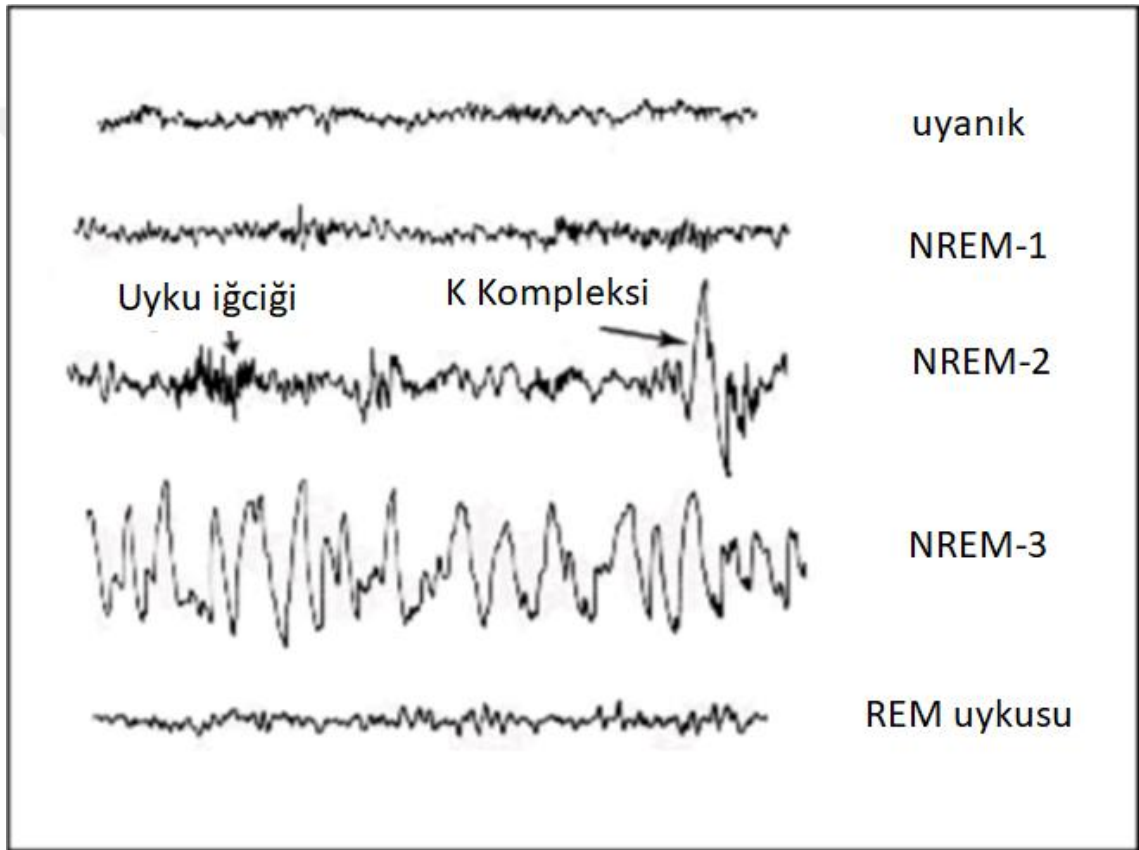
Rem: İlk Rem uykusu uykuya daldıktan yaklaşık olarak 90 dakika sonra görülür. Gözler, kapalı göz kapaklarının arkasında sağa sola hızla hareket eder. Karışık frekanslı beyin dalgası aktivitesi (EEG) uyanıklık halindekiye oldukça yakındır. Solunum daha hızlıdır ve düzensiz seyreder. Kalp atış hızı ve kan basıncı ise uyanıklıktaki değerlerine göre yüksektir (Colten and Altevogt 2006), (AASM Manual).

Kimi zaman Rem olmayan uykuda da rüya görülebildiği gibi rüya görme olayı sıklıkla Rem uykusunda olur. Kol ve bacak kasları bu aşamada geçici olarak felç olur ki bu durum rüyada görülen eylemleri fiziksel olarak gerçekleştirmemizin önüne geçer. Yaşlandıkça Rem uykusunun süresi kısalır. Bellek tamiratı, yenilenmesi için büyük ihtimalle hem Rem hem de Rem olmayan uykunun varlığına ihtiyaç duyulmaktadır (Colten and Altevogt 2006).

3.1.3. Uykunun evreleri ile beyin dalgaları arasındaki ilişki

Beyin dalgası aktivitesi açısından NonRem1 uykusu hem Alfa hem de Teta dalgaları ile ilişkilidir. NonRem1 uykusunun erken kısmı, nispeten düşük frekanslı (8-13Hz) ve yüksek genlikli dalgalar üretir. Bu dalgalar Alfa dalgaları olarak isimlendirilmektedir. Bu beyin dalgası aktivitesi şekli, sinyalin alındığı kişinin o sırada çok rahatlamış ama uyku durumuna geçmemiş biri olduğuna işaret eder. Birey Nonrem1 uykusuna devam ettikçe, Teta dalga aktivitesinde bir artış olur. Teta dalgaları Alfa dalgalarından daha düşük frekanslı (4-7 Hz), daha yüksek genlikli beyin dalgalarıdır. Birini NonRem1 uykusundan uyandırmak kolaydır (Šušmáková 2004).

NonRem2 uykusuna geçerken, beden derin bir rahatlama durumuna girer. Teta dalgaları hala beynin aktivitesinde baskındır, uyku iğcikleri olarak bilinen kısa süreli aktivite patlamaları bu evrede görülmektedir (Šušmáková 2004). Uyku iğcikleri, öğrenme ve hafıza için önemli olabilecek yüksek frekanslı beyin dalgalarının hızlı bir patlamasıdır (Fogel and Smith 2011). K-kompleksleri de bu evrede görülen bir dalga şeklidir ve NonRem2 uykusunun karakteristik bir özelliğidir (AASM Manual).



Şekil 3.1. Uyku evrelerinin beyin dalgaları ile ilişkisi (Šušmáková 2004)

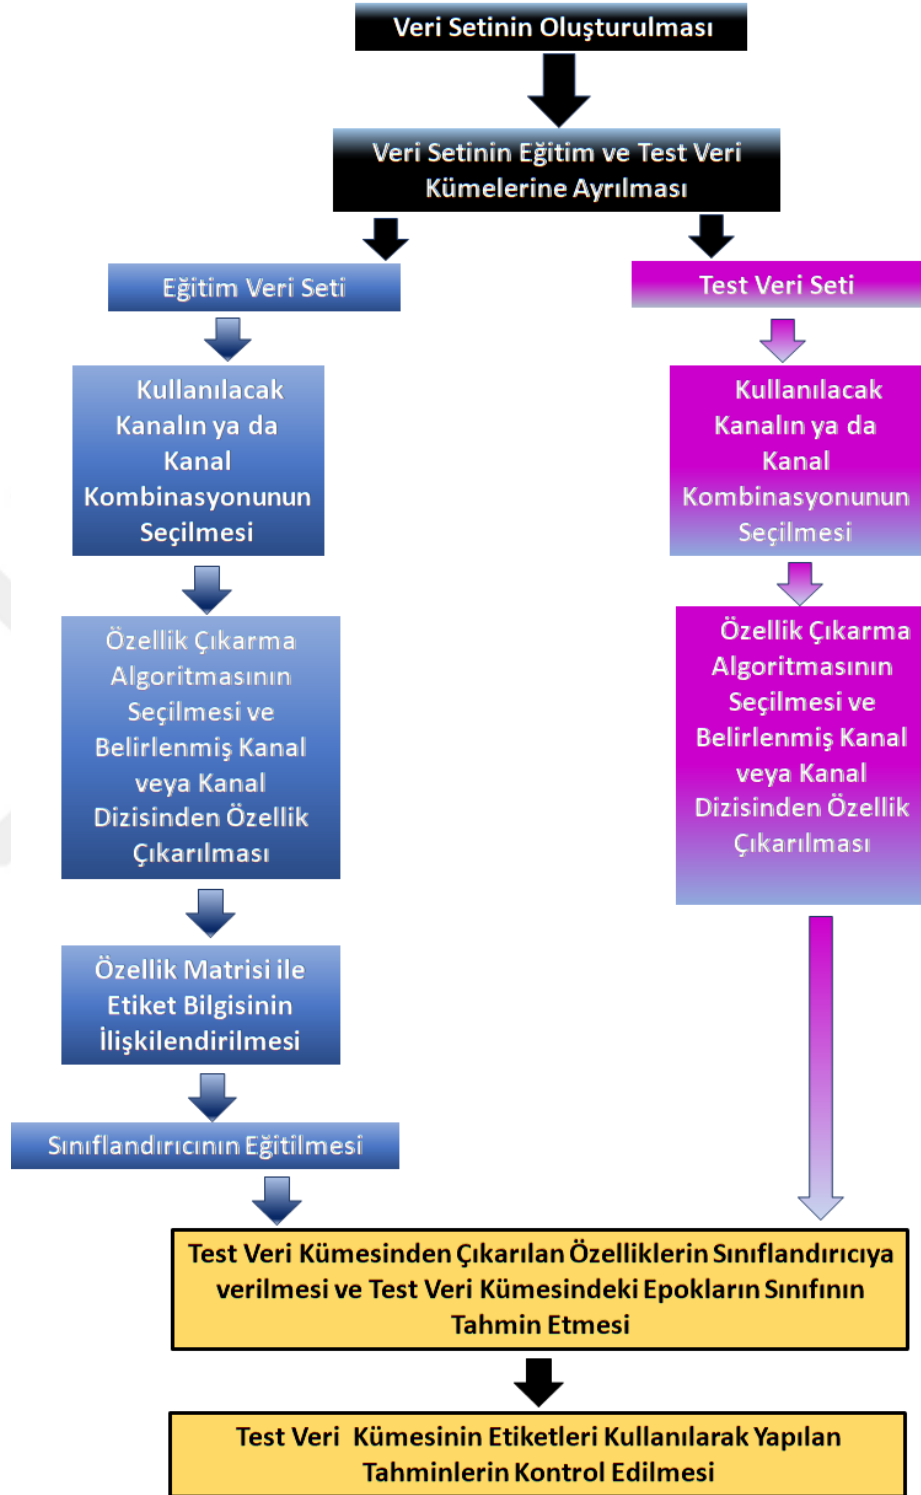
Uykunun NonRem3 aşaması genellikle derin uyku veya yavaş dalga uykusu olarak adlandırılır, çünkü bu aşama düşük frekans (4 Hz'e kadar) ve yüksek genlik özelliklerine sahip delta dalgaları ile karakterize edilir. Bu süre zarfında, bir kişinin kalp atış hızı ve solunum hızı önemli ölçüde yavaşlar. NonRem3 sırasında birini uykudan uyandırmak, önceki evrelerde uyandırmaktan daha zordur. İlginçtir ki, NonRem3 boyunca artmış Alfa beyin dalgası aktivitesi (uyanık olma hali ve NonRem1 ile karakterize olan dalga şekli)

olan bireyler, ne kadar uyuduklarına bakılmaksızın uyandıktan sonra kendilerini yorgun olarak bildirmişlerdir (Stone *et al.* 2008).

Daha önce de belirtildiği gibi, REM uykusu gözlerin hızlı hareketleriyle karakterizedir (AASM Manual). Bu uyku evresi ile ilişkili beyin dalgaları, gösterildiği gibi, bir insanın uyanık halinde gözlenen beyin dalgalarına çok benzerdir ve bu uyku evresi, rüya görmenin gerçekleştiği uyku evresidir. Ayrıca, dolaşım ve solunum işlemini mümkün kılanlar dışında, vücuttaki kas sistemlerinin felci ile de ilişkilendirilen bir uyku dönemidir. Bu nedenle, normal bir bireyde REM uykusunda istemli kasların hareketi olmaz; REM uykusu, bu yüksek beyin aktivitesi ve kas tonusunun eksikliği nedeniyle paradoksal uyku olarak adlandırılır (Colten and Altevogt 2006).

3.2. Uyku Evrelerinin Sınıflandırılması İçin Kullanılan Temel İş Akışı

Çalışmadaki bütün algoritmalar temel olarak Şekil 3.2’de görülen blok diyagrama göre düzenlenmiştir.




Şekil 3.2. Uyku evresi sınıflandırması için kullanılan temel iş akışı

3.2.1. Veri setinin oluşturulması

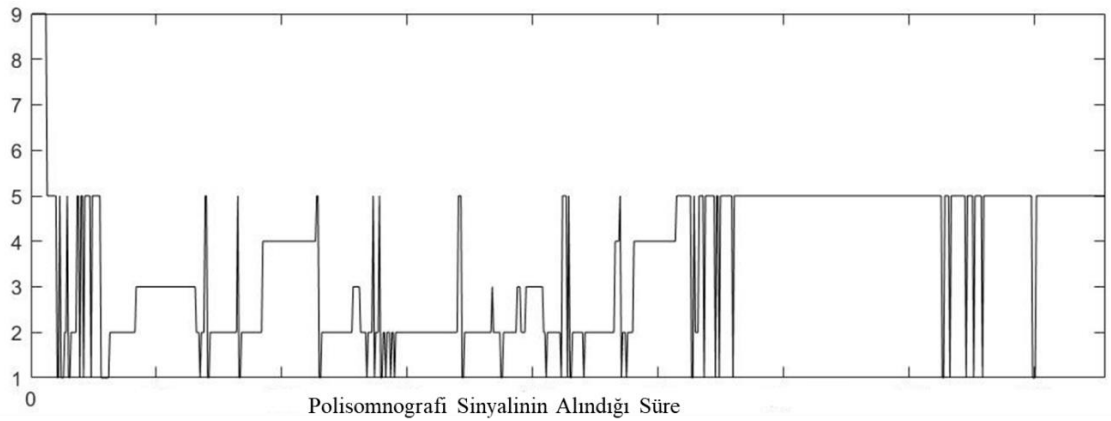
Bu tez çalışmasında ‘You Snooze, You Win: the PhysioNet/Computing in Cardiology Challenge 2018’ isimli veri seti kullanılmıştır (Ghassemi *et al.* 2018). Bu veri seti 1983 kişinin polisomnogram bilgisinden oluşmaktadır. Physionet isimli internet sitesi üzerinden herkesin erişimine açık olan veri seti hastane ortamında gerek görülen bireylerden polisomnografi sinyali kaydı alınarak oluşturulmuştur. Veri setinin içeriği ile ilgili detaylı bilgi 3.6 başlığı altında verilmiştir. Tez çalışması sürecinde veri seti oluşturulma işlemi yapılmamıştır. Bu veri seti çerisindeki 1983 kişinin tamamının polisomnografi sinyalleri verilmekle birlikte yalnızca eğitim veri seti olarak hazırlanmış olan 994 kişinin etiket bilgisi paylaşılmıştır. Tez çalışmasında kullanılan veri seti kısmı ise internet sitesinde eğitim veri seti olarak isimlendirilmiş olan, sinyallerle birlikte etiketlerine de erişilebilen veri kümesidir ve yapılan çalışmada 994 birey içermektedir.

Polisomnografi sinyal bilgisi Şekil 3.3’deki gibi bir dizi sinyalin eş zamanlı olarak toplanmasından oluşmaktadır. Veri seti ile birlikte oluşturulan etiket dosyası ilgili sinyale bakarak bir uyku uzmanının her bir epok için bir uyku evresi belirlemesi neticesinde oluşturulmuştur. Uyku evresi sınıflandırmasında bir standart olarak her bir epok 30 sn çerçeve genişliğine sahiptir.



Şekil 3.3. Ham EEG, EOG, EMG ve ECG sinyalleriyle 30 saniyede görüntülenen örnek bir PSG dosyası (Fehrmann 2013)

Matlab programı içinde Arousal ismi ile saklanan etiket bilgisi ise Matlab’de çizdirilirse Şekil 3.4’deki grafik elde edilir.



Şekil 3.4. Sinyalin Etiket Bilgisi kullanılarak çizdirilen Hipnogram

Şekil 3.4'de y ekseninde görülen 1'den 9 a kadar olan sayılar Uyku evrelerini temsil etmektedir. Wake 5 ile, Rem uykusu 4 ile, NonRem3 Uykusu 3 ile, NonRem2 Uykusu 2 ile, NonRem1 Uykusu 1 ile, etikette tanımsız olarak nitelenen kısım ise 9 ile ifade edilmektedir.

3.2.2. Veri setinin eğitim ve test veri kümelerine ayrılması

994 kişilik veri seti Eğitim, Doğrulama, Test veri seti olarak 3 parçaya ayrılmıştır. Bu ayırma işlemi yapılırken seçilen örnekler tamamen rastgele bir biçimde seçilmektedir. Uygulanan oranlar ise eğitim, doğrulama ve test için sırasıyla 0.5, 0.2, 0.3'tür. Bu bölme işleminde `cvpartition` ve `dividerand` isimli Matlab fonksiyonları kullanılmıştır. `Dividerand` fonksiyonu ve `cvpartition` fonksiyonu makine öğrenmesi algoritmalarında sıklıkla kullanılan fonksiyonlardır. `Cvpartition` komutu `dividerand` komutundan farklı olarak Eğitim, Doğrulama, Test setlerini rastgele ayırmasının yanı sıra her bir veri kümesine kabaca eşit miktarda her bir sınıftan epok koymaktadır (Anonymous 2019). Yani `cvpartition` kullanılarak veri kümelerine ayrıldığında dağılım rastgele ama dengeli bir şekilde sağlanmış olur.

3.2.3. Kullanılacak kanal veya kanal kombinasyonunun seçilmesi

Polisomnografi veri seti her bir kişi için 13 kanaldan oluşmaktadır. Kullanılacak kanal ve kullanılan kanaldan çıkarılacak özellik kombinasyonları ile doğruluk oranının optimum yapılması bu tez çalışması için bir optimizasyon problemi oluşturmuştur. Kanal özellik kombinasyonları denenerek en yüksek doğruluk oranı yakalanmaya çalışılması bir yaklaşım olduğu gibi bu noktada bir özellik seçimi algoritması geliştirilmesi de ayrı bir yaklaşımdır. Tez çalışması kapsamında ilk yaklaşım kullanılmış olup ekstra bir algoritma geliştirilmemiştir.

3.2.4. Özellik çıkarma algoritmasının seçilmesi ve belirlenmiş olan kanal veya kanal kombinasyonundan özellik çıkarılması

Sınıflandırma için etkili olan özelliklerin çıkarımı literatürde sıklıkla karşılaşılan sinyal kullanılarak sınıflandırma yapma aşamalarından biridir (Ceylan 2018). Özellik çıkarımı aşaması ile sınıflandırma performansını artıran özelliklerin tespiti özellikle biyomedikal sinyallerle çalışılıyorsa hastalığın teşhisinde büyük önem arz etmektedir (Ceylan 2018). Bu nedenle etkili bir algoritma ile yapılan özellik çıkarma aşaması sınıflandırmanın doğruluk oranını arttırdığı gibi sınıflandırıcının işlem süresini de kısaltmaktadır (Ceylan 2018). Özellik çıkarma işlemi ile tek boyutlu sinyaller ileri analiz ve işleme için bir tür parametrik gösterime dönüştürülür. Bu şekilde sinyallerin ilgili sınıflandırma için etkili olacak özellikleri ön plana çıkarırken diğer taraftan boyutsal olarak da küçülme olduğu için işlem süresi kısalmış ve işlem karmaşıklığı da aynı zamanda azaltılmış olur.

Tez çalışması kapsamında iki farklı özellik çıkarma algoritması kullanılmıştır. Bunlar MFCC ve ICA Metotlarıdır. Bu metotlarla özellik çıkarma işlemi yapılırken MFCC yöntemi önce tek başına kullanılarak doğruluk oranı belirlenmiş, sonrasında doğruluk oranını artırmak için MFCC yöntemi ile özellik çıkarma işlemi yapılmadan önce sinyal ICA yöntemi ile bağımsız bileşenlerine ayrılmıştır. Bu şekilde aynı sinyale arka arkaya uygulanan özellik çıkarma işlemi ile doğruluk oranı artırılmaya çalışılmıştır.

Tez çalışmasındaki algoritma gereğince öncelikle veri seti eğitim, doğrulama ve test olmak üzere üç veri kümesine 3.2.2 numaralı başlıkta anlatıldığı gibi ayrılmıştır. Sonrasında bu üç veri kümesinden ayrı fonksiyonlar ile özellik çıkarma işlemi gerçekleştirilmiştir. Veri kümeleri farklı olmakla birlikte veri kümelerinden çıkarılan özellikler ve kullanılan kanallar tüm veri kümeleri için aynı seçilmiştir. Sinyalden çıkarılmış olan özellik bir matris belirtir, bu özellik matrisi'nin sütun sayısı kişiden kişiye farklılık göstermektedir. Özellik matrisinin satır sayısı ise her bir kişi için sabittir. Özellik çıkarma yöntemleri 3.4 numaralı başlık altında detaylı olarak açıklanmıştır.

3.2.5. Eğitim veri kümesi için özellik matrisi ile etiket bilgisinin ilişkilendirilmesi

Eğitim veri kümesinden çıkarılan özelliklerin hangi epok için hangi etikete sahip olduğunun belirlenmesi sınıflandırıcının eğitilebilmesi için önemli bir adımdır. Bu noktada Matlab'deki Table yapısı kullanılarak etiketler ile ilgili etikete karşılık gelen sinyal birbirine bağlanmıştır. Sinyalin her bir epok aralığı için bir etiket değeri belirlenmiştir.

Bu aşamada 9 ile ifade edilen tanımsız sınıfı tez içerisinde araştırılmayacağı için etiketten ve tanımsız etiketine karşılık gelen kısım sinyalden çıkarılmıştır. Bir sonraki aşama olarak her bir Özellik Parçası (Sinyalin özellik bilgisini içeren Matris parçaları) etiketteki ismine göre birer hücre içine yerleştirilmiştir (Hücre denilerek Matlab'deki hücre yapısı kastedilmektedir).

Bir sonraki adım olarak Uyku aşamaları bilgisini içeren sinyal Matlab'in hücre dizisi (cell array) yapısı ile bir araya getirilmiştir.

3.2.6. Sınıflandırıcının eğitilmesi

Tez çalışmasında sınıflandırıcı olarak LSTM kullanılması literatürde de zaman serisi sinyallerinde alınmış olunan sonuçlar değerlendirilerek uygun görülmüştür (Abdullayeva 2019, Hochreiter *et al.* 1997, Schellenberger *et al.* 2018, He *et al.* 2018, Práinsson *et al.* 2018). LSTM yazılım mimarisi içerisinde bulunan çeşitli parametrelerin değiştirilmesine olanak sağlayan hazır bir yapı olarak Matlab 2018b ortamında sunulmaktadır. Bu yapı ve çıkarılmış olan özellikler kullanılarak LSTM modeli eğitilmiştir. Yapılan tez çalışmasında görülmüştür ki LSTM parametreleri doğruluk oranı üzerinde çok etkili olmaktadır.

LSTM mimarisinde kullanılan parametrelerin tanımları ve doğruluk oranına nasıl etki ettikleri 5.1 başlığı altında detaylı olarak açıklanmıştır.

3.2.7. Test veri kümesinden çıkarılan özelliklere göre sınıflandırıcının test veri kümesinin epokları için uyku evresi tahmininde bulunması

Bu aşamada eğitim verisi kullanılarak eğitilmiş olan model kullanılarak test veri kümesinden çıkarılan özellikler yardımı ile test veri kümesinin epoklarının hangi sınıfa dahil olduğu tahmin edilmektedir. Sınıflandırıcı hakkında detaylı bilgi 3.5 başlığı altında verilmektedir.

3.2.8. Test veri kümesinin etiketleri kullanılarak sınıflandırıcının tahminlerinin kontrol edilmesi ve doğruluk oranına erişilmesi

Tez çalışmasının son aşaması olarak belirlenen bu aşamada sınıflandırıcının tahminleri ile uzman tarafından belirlenmiş olan uyku sınıflarının her bir epok için eşleşip eşleşmediği kontrol edilmektedir.

Doğruluk oranı Test verisinde tahmin edilen etiketler ile gerçekteki etiketlerin toplam eşleştikleri epok sayısının Test veri setindeki bütün epok sayısına bölünmesi ile bulunur. Burada uygulanan yöntemle ilgili detaylı bilgi 3.7. Performans Ölçütleri başlığı altında verilmiştir.

3.3. Polisomnografi

Polisomnografi (PSG) uyku ve bozukluklarının değerlendirilmesinde en önemli laboratuvar tekniğidir. PSG uyku sırasında çoklu fizyolojik özelliklerin kayıtlarından oluşur. Uykunun laboratuvarında değerlendirilmesi ve uyku bozukluklarına önem verilmesi fikri yavaş yavaş gelişmektedir, özellikle son yüzyılda bu yönde büyük ilerlemeler kaydedilmiştir (Jafari and Mohsenin 2010).

Polisomnografi cihazı ile elde edilen fizyolojik sinyaller alt başlıklar olarak sıralanmıştır.


3.3.1. EEG (Elektroensefalografi)

Elektroensefalografi (EEG), beynin elektriksel aktivitesini kaydetmek için elektrofizyolojik bir izleme yöntemidir. EEG invaziv olmayan elektrotlar aracılığı ile beynin nöronlarındaki iyonik akımdan kaynaklanan voltaj dalgalanmalarını ölçer. Klinik olarak, EEG beynin elektriksel aktivitesinin belli bir süre boyunca kaydedilmesini ifade eder (Tatum *et al.* 2008).

Hans Berger 1929 ve 1938 yılları arasında yaptığı çalışmalarıyla insanlardan EEG kaydı almayı başaran ilk bilim insanı olmuştur. Hans Berger, Alfa ve Beta beyin dalgalarını bulmuştur, ayrıca elektroensefalogram cihazına bu ismi veren kişidir (Ahmed vd 2013).

Fourier Dönüşümü Yönteminin EEG sinyallerine uygulanması ile uyku bozukluklarının EEG sinyalleri ile incelenmesi 1950'li yıllarda gerçekleşmiştir (Sanei *et al.* 2007).

Merkezi sinir sistemi sinir hücreleri ve nöronlardan oluşur. Sinir hücresi dendrit, akson ve hücre gövdesinden oluşmaktadır. Sinir hücresi tarafından taşınan sinyal aksiyon potansiyeli olarak adlandırılır. Aksiyon potansiyeli sinir hücresinin gövdesinde oluşur ve tek yönde hareket eder. Nöron zarı boyunca iyonların değişimi aksiyon potansiyelini oluşturur (Altın 2017).



Şekil 3.5. EEG sinyalinin oluşumu (Altın 2017)

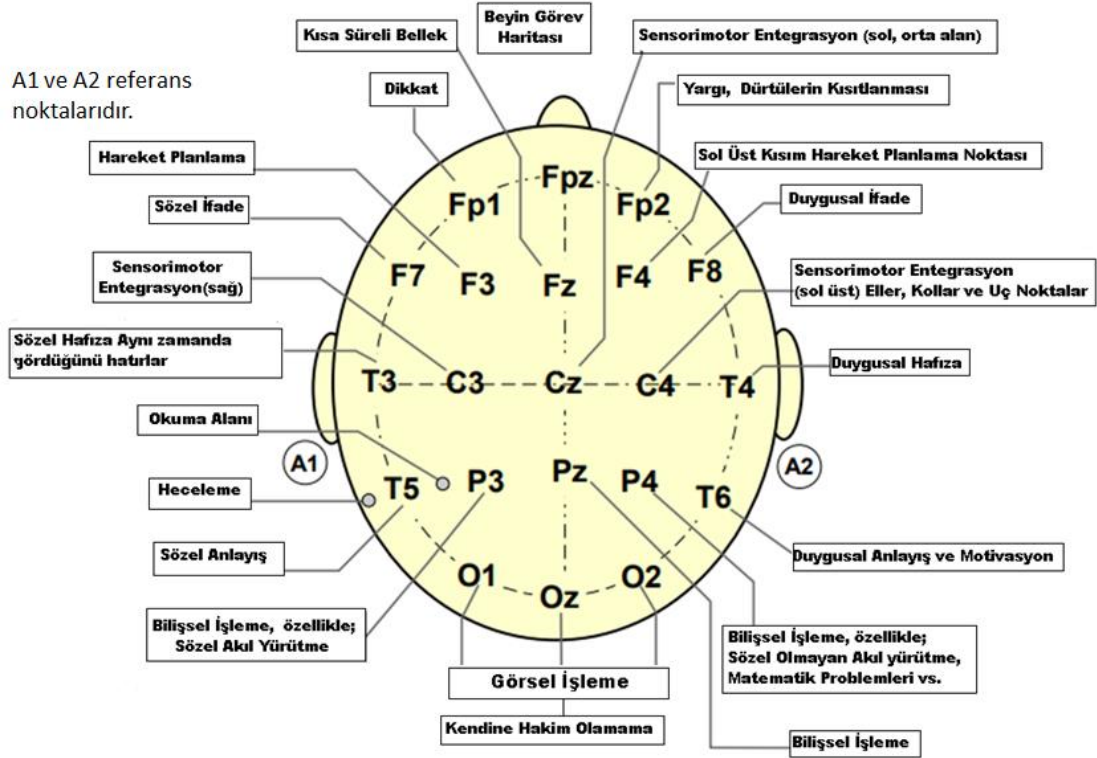
Şekildeki iki elektrot aracılığı ile kortikal nöron zarındaki sinaps sonrası potansiyellerin neden olduğu voltaj farklılıkları kaydedilir. Bu iki elektrot farklı voltaj seviyelerindedir, elektrotlar arasındaki bu farklılıklar dalga şeklinde ölçülür (Altın 2017).

İyon değişimleri nedeniyle oluşan dalgalar kafatasına yerleştirilen elektrotlara ulaştığında metal malzemeden yapılmış olan elektrottan elektron alır veya elektroda elektron verir. Metaller elektron alışverişini kolayca yapabilirler bu nedenle herhangi iki elektrot arasında oluşan potansiyel farkı voltmetre aracılığı ile ölçülür. Bu gerilimlerin zamanla değişimi ve ölçülmesi EEG sinyalinin verir. Sadece bir nöron tarafından oluşturulan gerilim farkının Elektroensefalografi cihazı ile algılanabilmesi mümkün değildir. Bu nedenle EEG aktivitesi milyonlarca nöron tarafından oluşturulan aktivitelerdir.

EEG sinyalleri oldukça düşük genliğe sahip biyolojik bir sinyaldir. Bu özelliğinden ötürü EEG sinyalleri; EOG, ECG ve EMG sinyallerinden çokça etkilenmektedir. Çünkü bahsedilen bu sinyaller EEG'ye nazaran çok daha baskındırlar. Bunun yanısıra EEG sinyalleri elektrot temasına bağlı olarak oluşan gürültüler, 50 Hz şehir şebekesi gürültüsü ve EEG sinyali alınırken etrafta var olan elektronik cihazların yaydığı elektromanyetik dalgalardan gelen gürültüler tarafından da kirletilir (Altın 2017).

EEG Elektrotlarının yerleşimi


EEG sinyali günümüzde birden çok kanal içeren cihazlarla alınmaktadır. Bu birden fazla kanal içeren cihazların elektrotları da beynin farklı bölgelerinden sinyal alabilmek için farklı bölgelere yerleştirilmektedir. Bu yerleştirme ile ilgili uluslararası bir standart (10-20 Sistemi) düzenlenmiştir. 10-20 Sistemi Şekil 3.6'da gösterilmiştir. Bu elektrot yerleştirme sistemine göre her elektrot çeşitli harfler ve rakamlar bütünü ile ifade edilir. Bu sistemde toplam 21 adet elektrot bulunmaktadır. Elektrotların konumunu ifade eden isimlendirmelerinde F, T, C, P, O harfleri sırasıyla "frontal", "temporal" "central" "parietal" "occipital" kelimelerini ifade eder. Adlandırmada eğer çift rakam varsa bu demek olur ki o elektrot kafatasının sağ yarısında, tek rakam var ise elektrot kafatasının sol yarısındadır. Küçük z harfi ise isimlendirilen elektrotun, beynin sol ve sağ yarısını ayıran hattın üzerinde olduğunu göstermektedir. Bunların yanı sıra isimlendirmede kullanılan sayı küçüldükçe ilgili elektrotun merkeze yaklaştığı anlaşılmalıdır (Altın 2017).



Şekil 3.6. 10-20 Sistemine göre elektrot yerleşimi (Altın 2017)

3.3.2. EOG (Elektrookülogram)

Elektrookülogram (EOG), retina pigment epiteli (RPE) ile fotorseptörler nedeniyle oluşan, retinanın dinlenme potansiyelini ölçmek ve kaydetmek için kullanılır. Özellikle göz hareketlerinin incelenmesinde bu yöntem tercih edilmektedir. Gözün Kornea tabakası negatif yük taşıırken Retinanın arkasındaki tabaka pozitif yük taşımaktadır. EOG bu iki tabaka arasındaki potansiyel farkını ölçen elektrofizyolojik bir yöntemdir. Bu potansiyel farkına da dinlenme potansiyeli denilmektedir. Gözler durgun haldeyken elektrotlar aynı potansiyele sahiptir ve hiçbir potansiyel fark ölçülmez. Gözün sağa doğru hareket etmesi durumunda bir potansiyel fark oluşur, hareketin olduğu yöndeki elektrot diğer elektrota göre daha pozitif bir değer alır. Gözün sola doğru hareket etmesi durumunda ise hareketin yönündeki elektrot diğer elektrota göre daha negatif bir değer alır. EOG ölçümü yapıldığı sırada hastanın sağa ve sola bakması halinde nasıl bir sinyal değişimi gözleneceği Şekil 3.7'de gösterilmiştir.



Şekil 3.7. Gözlerin sağa ve sola dönmesi halinde elde edilen EOG sinyali (Altın 2017)


Elektrookülogram metodu ile sinyal ölçülmesi ve kaydedilmesinde çeşitli kolaylıklar ve zorluklar bulunmaktadır. En büyük zorluk, kornea retinal potansiyelin sabit olmayıp, yavaş bir şekilde değişkenlik göstermesidir. Avantajlarından en önemlileri ise hastaya büyük rahatsızlık vermemesi ve göz kapakları kapalı iken de ölçüm yapmaya olanak vermesidir (Altın 2017). Göz kapakları kapalı şekilde ölçüm yapılmasına olanak tanınması EOG sinyalinin polisomnografi sinyali içerisinde yer almasını ve özellikle REM uykusu tanısında gerekli olduğunu göstermektedir. EOG sinyalini etkileyen faktörlere kısaca değinecek olursak; Elektrotların yerleşimi, temas ettikleri yüzey ile ilgili sorunlar, Göz çıkıklıkları, Göz hareketlerinin hızı, yaş, cinsiyet ve diğer biyosinyal gruplarını etkileyen gürültü çeşitleri sayılabilir.

3.3.3. EMG (Elektromiyografi)

Elektromiyografi, çizgili kaslar (iskelet kasları) tarafından üretilen elektriksel oluşumun değerlendirilmesi ve kaydedilmesi için oluşturulmuş tıbbi bir tekniktir. EMG,

elektromiyograf adı verilen bir araç kullanılarak gerçekleştirilir ve sonucunda elektromiyogram adı verilen bir kayıt elde edilir.

EMG sinyalinin oluşumu çizgili kaslardaki iyon (Na, Cl, K) konsantrasyonları farkı ile açıklanır. İyon konsantrasyonları arasındaki fark iki nokta arasında gerilim farkı oluşturur. Burada aslında İyonik bir aktivite olan EMG sinyalini ölçülebilen ve kaydedilebilen elektriksel aktiviteye dönüştüren yapılar elektrotlardır (Albulbul vd 2013).



Şekil 3.8. Elektromiyografi cihazının temsili çalışma şekli (Weiss *et al.* 2004)

Elektromiyografi tekniği ile elde edilen fizyolojik sinyalin genliği 0-10 mV aralığındadır (Altın 2017). EMG sinyali pek çok gürültü tarafından kirlenmeye açıktır. Gürültü diye nitelendirilen istenmeyen elektrik sinyallerinin özelliklerini anlamak çalışmada uygulanacak filtreleme ve özellik çıkarma tekniklerinin seçimi açısından oldukça önemlidir. EMG sinyalini etkileyen gürültülerden bahsedilecek olursa;

EMG sinyalinin kendisinden kaynaklanan doğal gürültüsü: EMG sinyali de diğer pek çok biyosinyal gibi rastgele bir sinyaldir. EMG sinyali aktif motor nöronların sayısı ve kas

fiberlerinin mekanik etkileşimi ile değişkenlik gösterir, bu durum da sinyali kararsızlaştırır (Arutha and Arul 2017).

EKG gürültüsü: Elektrokardiyografi sinyali kalbin atımıyla oluşan biyosinyaldir ve vücuttaki en güçlü biyolojik sinyallerden biridir. EMG ve EKG sinyallerinin frekans aralıkları büyük benzerlik gösterir ve bu nedenle de bu gürültünün EMG sinyalinden uzaklaştırılması oldukça zordur (Arutha and Arul 2017).

Elektrot teması nedeniyle oluşan gürültüler: EMG sinyalinin sinyal-gürültü oranı elektrot ile deri temasından etkilenmektedir. Bu sebeple deri, EMG sinyali alınmadan önce bu uygulamaya hazır hale getirilmelidir (Arutha and Arul 2017).


EMG Sinyali alınırken kullanılan elektronik cihazlar nedeniyle oluşan gürültüler: Bütün elektronik cihazlar belli ölçüde gürültü yayarlar, dolayısı ile EMG cihazının kendisinin de oluşturduğu bir gürültü vardır. Bu gürültülerin oluşmasını en aza indirebilmek için yüksek kaliteli devre elemanları kullanılmalı ve iyi bir devre tasarımı yapılmalıdır. Bu tip gürültüler 0 Hz ile birkaç bin Hz arasındaki frekans değerlerine sahip olabilmektedir (Arutha and Arul 2017). 50 Hz şebeke gürültüsü de çevresel kaynaklı bir gürültü tipidir ve bu gürültünün oluşmasının önüne geçmek imkânsızdır. Görüldüğü gibi EMG sinyali birçok gürültü tarafından kirletilmektedir. Bu yüzden EMG sinyali ile ilgili yapılacak çalışmalar öncesinde sinyal, filtreleme gibi ön işlemler ile bu gürültülerden arındırılır (Arutha and Arul 2017).

3.3.4. ECG (Elektrokardiyografi)

İnsan kalbi elektromekanik bir pompanın biyolojik versiyonu gibi çalışır, görevi vücutta kan dolaşımını sağlamaktır. Yaklaşık olarak 250-300g ağırlığındadır ve her bir kalp atımında vücuda 70 ml kan pompalamaktadır, bu da dakikada yaklaşık olarak 5.6litre kan pompalayabildiğini göstermektedir (Altın vd 2017). Kalp atışı kalpte olduğu esnada oluşan elektriksel akım kalbi çevreleyen komşu dokulara da yayılır. Bu akımın küçük bir kısmı kalbin yüzeyine yani göğüs derisine kadar ulaşır. Göğüs yüzeyine elektrotlar

yerleştirilirse akım tarafından oluşturulan elektriksel potansiyel farkı ölçülüp kaydedilebilir. Bu sinyale elektrokardiyogram (ECG) denir. Kalbin çalışması için iki temel olayın gerçekleşmesi gereklidir, bunlar kalp kasının kasılması ve gevşemesidir. Kalp kasının gevşemesi ile birlikte kalbe kan dolar, bu evreye diyastol denir. Kalp kasının kasılması ile birlikte kalpten dışarı kan pompalanır, bu evreye de sistol denir. Bu iki olay sürekli birbirini takip ederek tekrarlanır ve böylece kalp atımı oluşur (Hall *et al.* 2013).

Sağlıklı bir kişinin EKG grafiği temel dalga formu Şekil 3.9'da gösterildiği gibi PT aralığı ve QT aralığından oluşmaktadır. Bu iki aralık QRS kompleksinin başlamasıyla ayrılmıştır.



Şekil 3.9. Sağlıklı kişinin temel ECG dalga şekli (Anonymous 2018)

Kalbin normal atımı esnasında oluşan ilk dalga P dalgasıdır. Bu dalga şekli pozitif yönlüdür, atriumlar (kulakçıklar) kasılmaya başlamadan önce depolarize olurlar, bu sırada elektriksel potansiyel oluştururlar. Bu elektriksel potansiyel P pozitif dalgasını oluşturur. İkinci olarak QRS kompleksi oluşur. QRS kompleksi, depolarizasyon sinyalinin atriumdan ventriküllere yayılması neticesinde oluşur. Zamanlaması fizyolojik olarak ifade edilmek istenirse, ventriküllerin kasılmasından hemen öncedir. T dalgası, repolarizasyon durumuna işaret eder, ventriküllerin(karınçıkların) depolarizasyon durumu sona ermiş ise T dalgası oluşur (Hall *et al.* 2013; Ramli *et al.* 2013).

3.3.5. Solunum eforu

Solunum eforunu ölçebilmek için atmosfer basıncına göre farklılık oluşturan basınç değişiklikleri saptanmalıdır. Üç farklı metot kullanılarak bu değişim belirlenebilir;

- a) Respiratuar indüktans pletismografi (RIP), göğüs ve karın hareketlerinden doğan sinyallerin toplamı (Karadağ, 2018)
- b) Özofagus basınç değişimi ölçümü (Çentik 2013)
- c) Piezoelektrik bantlar yardımı ile ölçüm (Çentik 2013)

3.3.6. Oksihemoglobin saturasyonu

Kan içerisindeki gazlardaki değişiklikleri belirleyerek azalmış hava akımının oluşturduğu fizyolojik etkileri saptamak mümkündür (Çentik vd 2013). 'Pulse oksimetre' isimli yöntem oksihemoglobin saturasyonunu ölçmek için kullanılan yöntemlerin başında gelmektedir. Bu yöntemde kan, kulak memesi, tırnak yatağı gibi bölgelerden geçerken içerisinde bulunan farklı hemoglobin formlarının kırmızı ışığı absorbe etme seviyelerine dayanarak ölçüm yapılır. Aşağıda Şekil 3.10'da oksihemoglobin saturasyonu ölçme yönteminin görseli bulunmaktadır.



Şekil 3.10. Parmaktan oksihemoglobin saturasyonu ölçme (Çentik 2013)

Oksihemoglobin saturasyonu ölçme cihazları 3 ila 21 saniye arasında değişen bir sürede yaptıkları ölçümün ortalama değerini yansıtırlar (Çentik 2013). Vücuttaki kan dolaşımı

süresine bağı olarak solunum anından itibaren 7-9 saniye sonra kulak memesinde veya bu süreden daha uzun bir süre sonra tırnak yatağında oksihemoglobin saturasyon grafiğinin en düşük düzeyine ulaştığı gözlenmektedir (Silber *et al.* 2004).

3.3.7. Hava akımı

Hava akımı ölçümünde kullanılan cihaza pnömotakometre denilir, bu cihazla doğrudan hava akımı ölçümü yapmak mümkündür ancak bu yöntemle ölçüm yapılacaksa hastanın yüzüne tam oturan bir maske takması gerekir. Bu yöntem hasta için rahatsız edici olduğu için kullanışsızdır ve çokça tercih edilmez. Bu metot yerine doğrudan olmayan ama daha kullanışlı olan farklı iki yöntemden biri seçilebilir.

İlk yöntem; termistörlerin ve termokuplların ağız ve her iki burun deliği önüne yerleştirilmesi suretiyle hava akımı neticesinde oluşan ikincil ısı değişiminin ölçülmesidir. Termistör, oda sıcaklığından etkilenebilen bir yapıda olduğu için bu yöntem son zamanlarda kullanılmamaktadır (Levy *et al.* 1992).

İkinci yöntem; ‘Nazal Basınç Transdüser’i kullanılarak hava akışı ölçümü esasına dayalıdır. Hava akımına bağı olarak burun deliklerinin girişinde ölçülebilecek miktarda basınç değişimi olur. Bu basınç değişiklikleri burun deliklerinin önüne yerleştirilen basınç transdüseri ve nazal kanül aracılığıyla ölçülür ve sonrasında yorumlanır. Bu şekilde de hava akışı ölçümü yapılmış olur. Bu yöntemler Hava Akışının kısıtlandığı durumların tespitinde çok etkilidir. Doğru seçilmiş bir örnekleme hızıyla kaydedildiğinde dalga formu değişiklikleriyle de solunum problemlerinin varlığı ve niteliği hakkında bilgi sağlar (Çentik 2013).

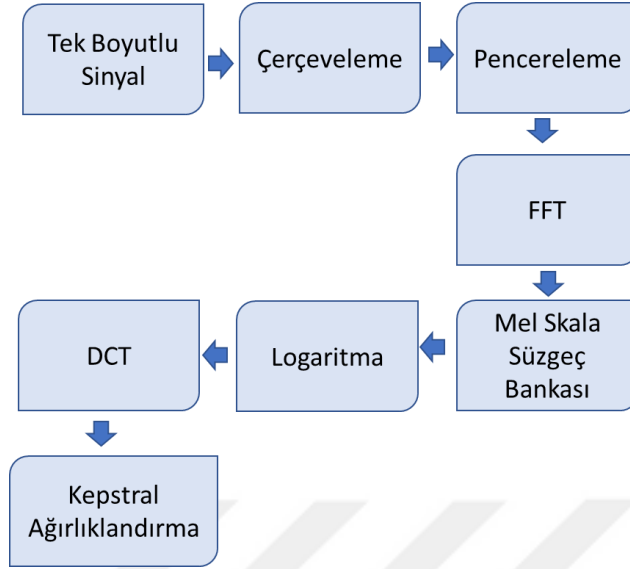
3.4. Özellik Çıkarma Yöntemlerinin Tanıtılması

Bu bölümde öncelikle tezde kullanılan 2 Özellik çıkarma yöntemi anlatılacak ve bu özelliklerin hangi veri setine nasıl uygulandığı açıklanacaktır.

Özellik Çıkarmanın Amacı: Bu modülün amacı, tek boyutlu sinyalleri ileri analiz ve işleme için bir tür parametrik gösterime dönüştürmektir.

3.4.1. Mel kepstrum katsayıları

Bir ses, temel bir frekansın ve onun harmoniklerinin bir kombinasyonu olan darbelerden oluşur. Bir darbenin temel frekansı, perde olarak bilinir (Alkan 2005). Başka bir deyişle herhangi bir tonun temel veya ilk harmoniği, perde olarak isimlendirilir. Çeşitli algoritmalar kullanılarak sesin perdesi belirlenebilmektedir. MFCC'ler, doğrusal olmayan insan sesi algısını dikkate alan bir ses sinyali spektrumu gösterimidir. Sinyal öncelikle pencerelere ayrılır. MFCC' ler, herbir pencerenin Kısa Zamanlı Fourier Dönüşümü katsayılarını 13-40 katsayı kümesine gruplanması ile hesaplanır. Bu işlemi yaparken arka arkaya filtreler kullanılır ve bu yapılan işlemle aslında insanın işitme sisteminin frekans algısı taklit edilir. Daha sonra elde edilen katsayıların logaritması alınır ve bunları birbirinden ayırmak için Ayrık Kosinüs Dönüşümü (Discrete Cosine Transform-DCT) uygulanır. Şekil 3.11'de Mel Kepstrum katsayılarının elde edilişi için blok diyagramı görülmektedir.



Şekil 3.11. MFCC katsayılarının elde edilmesinin blok diyagramı (Gelegin ve Bolat 2011)

Kepstrum, konuşma tanıma uygulamalarında, büyüklük spektrumunun logaritmasının ters Fourier dönüşümü olarak tanımlanır. Kepstrum kullanımı, iki Kepstral özellik vektörü arasındaki benzerliğin basit bir Öklid mesafesi olarak hesaplanmasını sağlar. MFCC'ler, insan kulağının işitme bant genişliğinin, frekans ile bilinen varyasyonuna dayanmaktadır.

3.4.1.a. MFCC katsayılarının elde edilme sürecinin maddeler halinde incelenmesi

1. Ön Vurgu: Tek boyutlu sinyal 1. Dereceden FIR filtreden geçirilir (Gelegin ve Bolat 2011).

2. Çerçeveleme: Çerçeveleme işlemi ile tek boyutlu sinyalin daha küçük parçalara ayrılması ve özelliklerinin belirli bir boyutta sabit kalması amaçlanır (Gelegin ve Bolat 2011). Sinyalin çerçevesizliği bu çalışma için 30sn seçilmiştir. Çünkü Uyku evresi sınıflandırması standartlarına göre (AASM) uyku 30 sn'lik epoklar kullanılarak sınıflandırılmaktadır. MFCC özneliği ses sinyalinden çıkarılmak isteniyorsa farklı çerçeve genişlikleri kullanılması da olasıdır ve en doğru sonucu veren çerçeve genişliği deneyerek bulunabilir (Dal 2015). Çerçeveleme işleminde kullanılan bir diğer parametre

ise örtüşme miktarıdır. Bir önceki çerçeve sonundaki işaret ile bir sonraki çerçeve başındaki işaret belirlenen örtüşme miktarı kadar örtüşür. Bu işlem sayesinde çerçeve sonundaki işaretin önemini kaybetmesi önlenir ve bir çerçeveden diğerine geçişin yumuşak olması sağlanır (Gelegin ve Bolat 2011).

3. Pencereleme: Bu işlem adımında her bir karenin başlangıcındaki ve sonundaki sinyal süreksizliklerini en aza indirecek şekilde her bir çerçeveye pencereleme işlemi yapılır. Buradaki uygulama, sinyali her karenin başında ve sonunda sıfıra çekmek için pencereyi kullanarak spektral bozulmayı en aza indirmektir (Dal 2015).


4. Hızlı Fourier Dönüşümü: Bu işlem adımında, her bir penceredeki sinyali zaman alanından frekans alanına dönüştüren Hızlı Fourier Dönüşümü kullanılır. FFT, ayrık Fourier dönüşümünü hesaplamak için gereken hesaplama süresini azaltır, DFT'ye göre performansı da yükseltir (Gelegin ve Bolat 2011).

5. Mel Filtre Bankası: Psikofiziksel çalışmalar insanın konuşma sinyalleri için seslerin frekans içeriğini algılamasının doğrusal bir ölçeğe uymadığını göstermiştir. Böylece, Hz cinsinden ölçülen gerçek frekanslı her ton için, öznel bir adım olarak nitelendirebilecek olan 'mel'ölçeği adı verilen bir ölçek karşılığı bulunur. Mel frekans ölçeği, 1000Hz frekans değeri altındaki frekans değerleri için lineer bir frekans aralığı ve 1000 Hz'nin üzerindeki frekans değerleri için de logaritmik bir frekans aralığı ifade eder. Bir referans noktası olarak, algısal işitme eşiğinin üzerinde 40 dB olan 1 kHz frekansa sahip tonun perdesi 1000 mel ölçeğine karşılık gelir (Eskidere 2007).

Mel Skalası, doğrusal frekans eksenini (Hz) ile algısal frekans eksenini (mel) arasında bir birim dönüşümüdür (Bolat 2006). Bu dönüşüm aşağıdaki eşitlik uyarınca gerçekleştirilir (Bolat 2006).

$$f_{mel} = 2595 * \log(1 + f_{lineer}/700) \quad (3.1)$$

f_{mel} , mel ölçeği cinsinden frekansı ifade ederken f_{linear} , Hz cinsinden normal frekanstır (Bolat 2006). Bu iki parametre arasındaki ilişki Şekil 3.12’de gösterildiği gibidir.

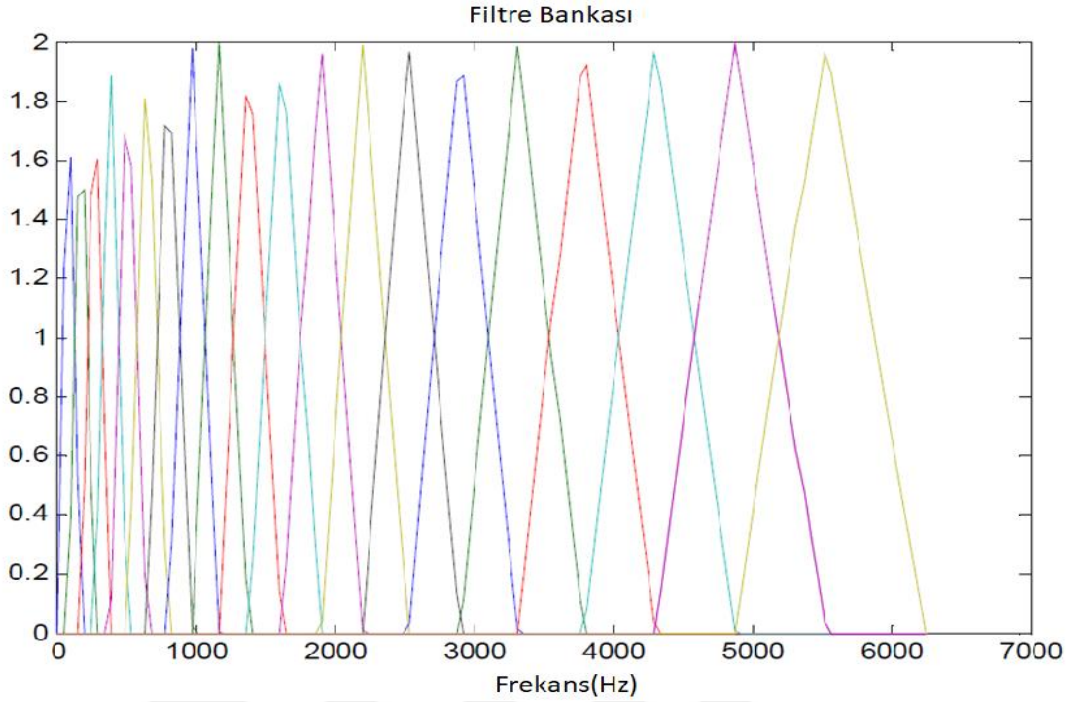


Şekil 3.12. Frekans ölçeği ile mel ölçeği arasındaki ilişki (Do 2015)

Mel Ölçeği elde edilirken eşit aralıklı bir Filtre Bankası kullanılmaktadır (Bkz. Şekil 3.13). Bu filtre bankası üçgen şeklinde filtrelerden oluşmaktadır, bu sebeple de frekans yanıtı üçgen şekline uyumlu bir şekilde bant geçiren bir filtre gibi olmaktadır. Bant genişliği ise sabit bir mel frekans aralığı ile belirlenmektedir. Son olarak giriş spektrumunun temsili her bir üçgen filtreden elde edilen çıkış güçleri ile oluşturulur. Filtre Bankasında kullanılan filtre sayısı Mel spektrum katsayısı diye isimlendirilir ve bu tipik olarak ise 20 seçilir. Bu nedenle Şekil 3.13’de 20 mel spektrum katsayısına sahip bir filtre bankası görülmektedir (Rajsekhar 2008). Tez çalışmasında örnekleme frekansı 200 Hz olarak belirlenmiştir. Buradan filtre sayısı

$$\text{NumoFilter}=\text{floor}(3*\log(\text{Fs})); \quad (3.2)$$

Şeklinde hesaplanmaktadır ve hesaplamının sonucu 15 çıkmaktadır. Dolayısıyla tez çalışmasında mel kepstum katsayıları hesaplanırken kullanılan mel filtre bankası 15 bant geçiren filtreden oluşmaktadır.



Şekil 3.13. 20 filtre için mel aralıklı filtre bankası örneği (Rajsekhar 2008)

6. Kepstrum: Kepstrum kısaca otospektrumun logaritmasının fourier dönüşümü olarak tanımlanır (Bhartie *et al.* 2015). Bu da sinyalin güç spektrumunun logaritmasının ters fourier dönüşümüne eşittir. Bu işlem otospektrumdaki periyodiklikleri belirlemek için kullanışlıdır. Kepstrum alanındaki eklemeler, frekans alanındaki çarpıma ve zaman alanındaki bükülmeye karşılık gelir (Rajsekhar 2008). Kepstrum terimini matematiksel olarak ifade edebilmek için denklem 3.3 kullanılır.

$$c(n) = \text{ifft}(\log|\text{fft}(s(n))|) \quad (3.3)$$

Denklem (3.3)'teki formülde $s(n)$ örneklenmiş tek boyutlu sinyaldir ve $c(n)$ de kepsral alanında elde edilen sinyaldir (Rajsekhar 2008).

Son adım olarak da Mel Spektrumun logaritmasının zaman düzlemindeki karşılığı bulunur, bu şekilde MFCC katsayıları elde edilmiş olur. Mel Spektrumun logaritmasının zaman düzlemindeki karşılığı bulunurken kullanılan yöntem Ayrık Kosinüs Dönüşümü

(DCT) olarak adlandırılır. Böylece kepstrum katsayıları elde edilir. Mel Frekansı Kepstrum Katsayıları $mel(c(k))$ aşağıdaki denklemde ifade edilmektedir.

$$Mel(c(k)) = \sum_{k=1}^{15} x(k) * \cos\left(i * \frac{k-1}{2} * \frac{\pi}{20}\right) \quad k=1, 2, 3, \dots, M \quad (3.4)$$

Bu ifadede M, kepstrum katsayılarının sayısını ve $x(k)$, $k= 1, 2, 3, \dots, 15$ için filtrenin logaritmik enerji çıkışı göstermektedir.


3.4.2. Bağımsız bileşen analizi (Independent component analysis-ICA)

Bağımsız Bileşen Analizi Yöntemi'nin en iyi bilinen uygulamaları, sinyal işleme alanındadır: biyomedikal, konuşma ve haberleşme sinyalleri. Beyin aktivitesini yansıtan, elektrik ve manyetik alanların kayıtlarından oluşan elektroensefalogram (EEG), manyetoensefalogram (MEG) veya fonksiyonel manyetik rezonans görüntüleme (fMRI) de ICA'nın yararlandığı alanlardandır (Bingham vd 2003). Bu tez çalışmasında da buna dayanarak ICA yöntemi özellik çıkartma aşamasında birinci adım olarak kullanılmaktadır.


Yukarıda bahsi geçen sinyaller farklı fiziksel aktivitelerin ve dış gürültü kaynaklarının karışımı olarak nitelendirilebilir (Bingham *et al.* 2003). ICA, birden çok kaynak tarafından oluşturulan sinyalleri, farklı kaynakların yarattığı sinyallere ayırma amacıyla kullanılmaktadır (Bingham *et al.* 2003). Bu özelliği nedeniyle de benzer şekilde, farklı yerlerde mikrofonlara kaydedilen farklı konuşma sinyallerinin ayrılması, zaman gecikmesi ve gürültünün bozduğu sinyallere ayırma işlemleri uygulanarak sinyalin saflaştırılması, ICA çerçevesinde değerlendirilebilecek problemlerdendir (Brock 2006).

ICA, farklı sinyaller farklı fiziksel süreçlerden kaynaklanıyorsa, bu sinyallerin istatistiksel olarak bağımsız olduğu varsayımı üzerine kuruludur (Brock 2006). Bağımsız bileşen analizi (ICA), verilerdeki alt katmanları bulmak için iyi bir yöntemdir (Bingham *et al.* 2003). ICA, bilinmeyen alt katmanların kombinasyonundan oluşmaktadır. Bu alt


katmanlar, kaynaklar veya bağımsız bileşenler olarak adlandırılır ve birbirlerinden istatistiksel olarak bağımsız oldukları varsayılır (Bingham *et al.* 2003). ICA yöntemi bir örnek üzerinden incelenecek olursa, karıştırılacak olan kaynak sinyalleri Şekil 3.14'deki gibi Sinüs dalgası ve Testere dişi olarak belirlenmiştir.



Şekil 3.14. Karıştırılacak kaynak sinyaller (Brock 2006)



Şekil 3.15. Kaynak sinyallerin karıştırılması ile elde edilmiş iki farklı sinyal (Brock 2006)



Şekil 3.16. Karışım sinyallere ICA yöntemi uygulanması sonucu elde edilen bağımsız bileşen sinyalleri (Brock 2006)

Şekil 3.14, 3.15 ve 3.16'dan da görüldüğü üzere Bağımsız Bileşen Analizi Yönteminde bazı belirsizlikler oluşmaktadır. Ayırıştırılan sinyalde kaynakların sırası, orijinal genliği ve faz bilgisi belirlenemez (Brock 2006). Bununla birlikte, bu belirsizliklerin hiçbiri, kaynak sinyallerinin ayırışma sonucu elde edildiği gerçeğini değiştirmez (Brock 2006).

EEG sinyali işlenmesinde Bağımsız Bileşen Analizi kullanılması daha önceki çalışmalarda da gözlenmiştir. Bir elektroensefalogram bilgisi beyin aktivitesinin elektriksel kayıtları olarak düşünülürse, EEG verileri, kafa derisindeki birçok farklı konumdaki elektrik potansiyellerin kayıtlarından oluşur. Bu potansiyellerin ise beyin aktivitesinin altında yatan bazı bileşenlerin karıştırılmasıyla yaratıldığı tahmin edilmektedir (Hyvarinen *et al.* 2001). Beyin aktivitesinin orijinal bileşenlerinin bulunmak istenmesi, ancak bileşenlerin karışımlarının sadece elektroensefalogram yardımıyla gözlemlenebiliyor olması durumu sözkonusudur (Hyvarinen *et al.* 2001). ICA bağımsız bileşenlerine erişim sağlayarak beyin aktivitesi hakkında ilginç bilgiler ortaya çıkarabilir (Hyvarinen *et al.* 2001).

3.4.2.a. Bağımsız bileşen analizi yöntemi'nin teorik alt yapısı

Bağımsız Bileşen Analizi teorik olarak, denklem 3.5, denklem 3.6, denklem 3.7'de görülen üç ana denkleme dayanır.

$$x = A * s \quad (3.5)$$

$$s = W * x \quad (3.6)$$

$$x = \sum_{i=1}^n a_i * s_i \quad (3.7)$$

Yukarıdaki denklemlerde x karışım sinyallerinin bir kümesidir. s ile bağımsız kaynak sinyalleri ifade edilmektedir. A matrisi karıştırma matrisidir, kaynak sinyalleri bu karışıma matrisine göre karışmıştır diye varsayılır. Son denklemde görülen a_i , A

matrisinin bir kolonunu ifade eder. Yine Denklem 3.7’de açıkça görülmektedir ki x kaynak sinyallerinin lineer kombinasyonunu belirtir. Denklem 3.6’da görülen w ifadesi ise karıştırıcı olmayan matris olarak isimlendirilir, bu matris kullanılarak kaynak sinyalleri karışım sinyallerinden türetilmeye çalışılır (Brock 2006).

Denklem 3.5, 3.6, 3.7 kaynak sinyallerin istatistiksel bağımsızlığını ya da normal dağılımdan uzak olma hallerini maksimum yapacak şekilde bir karıştırıcı matrisin kestirilmesi için kullanılır ki bu da Bağımsız Bileşen Analizi’nin temel amacıdır (Brock 2006).

3.4.2.b. ICA yönteminin tezin içerisinde kullanımı

Tez çalışmasında özellik çıkarma aşamasını iki adımda tamamlamanın sonuçları olumlu etkileyeceği fikri ile veri setinden önce ICA yöntemi ile özellik çıkartılmış (Yani tek boyutlu sinyaller dizisi bağımsız bileşenlerine ayrılmış), ikinci aşama olarak Bağımsız Bileşenlerin Mel Kepstrum Katsayıları (MFCC) alınıp bunlar vasıtasıyla model eğitilmiştir. Sonrasında eğitilmiş olan model kullanılarak test veri seti sınıflandırma işlemine tabi tutulmuştur. Alınan sonuçlar Araştırma Bulguları bölümünde sunulmuştur. ICA yöntemi kullanılarak çok büyük boyutlu bir veri setini bağımsız bileşenlerine ayırmak oldukça uzun sürecek bir işlemdir, bu sorunun önüne geçebilmek için Helsinki Teknoloji Üniversitesinden Prof. Dr. Aapo Hyvärinen’in hazırlamış olduğu MATLAB ile uyumlu bir paket program olan FastICA yazılım mimarisi kullanılmıştır. Bu yazılım mimarisi sayesinde bağımsız bileşenlerine ayırma süreci daha kısa sürede bitirilmiştir.

3.5. Sınıflandırma metodu

Bu bölümde özellik çıkarımı yapılan veri setinde kullanılan sınıflandırma algoritması teorik olarak açıklanmıştır. Veri seti tek boyutlu bir dizi sinyalden oluşmuştur. Yapılan literatür taraması sonucu LSTM adı verilen yazılım mimarisinin tek boyutlu sınıflandırma problemlerinde olumlu sonuçlar verdiği bilinmektedir (He *et al.* 2018; Práinsson *et al.* 2018). Bu bölümün amacı LSTM yazılım mimarisini detaylı bir şekilde anlatmak

olacaktır. Bunun için öncelikle Zaman Serisi ve Makine Öğrenmesi Kavramları anlatılacak, sonrasında da Yapay Sinir Ağları ve Derin Öğrenme Kavramlarına değinilecek ve son olarak da LSTM açıklanacaktır.

3.5.1. Zaman serisi ve öğrenme kavramı

3.5.1.a. Zaman serisi

Zaman serileri, sıralı olan özel bir veri türüdür. Sıralı olma özelliği, veri noktalarına bağımlılığı ve verilerin anlamını etkilediği için çok önemlidir. Zaman serilerini oluşturan veri noktaları daha önceden tanımlanmış özelliklere sahiptir. Bu özelliklerden biri, veri noktalarının zaman içinde eşit aralıklarla tekrarlanan ölçümler yoluyla elde edilmesinin gerekliliğidir. Veri noktalarının zaman aralığı sürekli olmalı ve birim gözlemlerin her zaman en fazla bir veri noktasına sahip olması gerekir (Hatipoğlu 2016).

Zaman serileri, istatistik, ekonomi, örüntü tanıma, kontrol mühendisliği, sinyal işleme, astronomi, meteoroloji, eğlence gibi pek çok alanda kullanılmaktadır. Zaman serisi analizleri son yıllarda ivme kazanarak gelişmekte ve diğer alanlara da çok katkı sağlamaktadır. Bu hızlı gelişime rağmen zaman serileri alanında hala pek çok açık konu bulunmaktadır. Zaman serilerindeki gürültü, temel sorunlardan biridir ve yanlış tahminlere neden olmaktadır (Yang *et al.* 2006). Gürültülü, yüksek boyutlu ve karmaşık zaman serisi verileri, nonlineer sınıflandırma kabiliyeti zayıf, geleneksel ve basit yöntemlerle modellenemez. Verinin boyutunu azaltmak, gürültüyü ortadan kaldırmak ve böylece aslında karmaşıklık derecesini düşürmek için verilere çeşitli boyut azaltma teknikleri (temel bileşen analizi-PCA, bağımsız bileşen analizi-ICA) uygulanabilir. Fakat bu uygulanan prosedürler çoğu zaman uzman bilgisi gerektirir ve verilerin bilgilendirici kısımlarınının da sadeleştirme amacıyla kaybedilmesine neden olabilirler. Diğer bir konu ise zaman serilerindeki veri noktalarının sayısı ile ilgilidir. Geçmişten daha fazla veriye sahip olmak hassasiyeti ve detaylı analiz şansını artırır. Fakat veri noktalarının sayısının artması demek karmaşıklığın artmasını da beraberinde getirmektedir. Yani, verilerin

hassasiyet özelliğini arttırırken, modelin veri işleme ile baş edememe riskini de arttırmış olur (Längkvist *et al.* 2014).

3.5.1.b. Öğrenme

Eğitim örneklerinden bir sınıflandırıcı tasarlamak için bilgi alan herhangi bir yaklaşım veya yonteme öğrenme denilebilir (Hatipoğlu 2016). Denetimli, denetimsiz ve pekiştirmeli öğrenme, makine öğrenmesinin temel biçimleridir. Öğrenme türleri kullanılan veri tipi ile yakından ilişkilidir. Kullanılan veriler etiketli ve etiketsiz olmak üzere iki gruba ayırabilmektedir. Etiketli ve etiketsiz veriler uygulamaların kapsamı bakımından farklı şekilde ele alınır. Etiketli veriler genellikle yeni gözlemlerin (veya örneklerin) hedef niteliklerini (veya sınıf etiketlerini) tahmin etmek için kullanılırken, etiketlenmemiş veriler verilerdeki kümelenme veya araştırma için yararlıdır. Etiket bilgileri hariç tutulan verinin özniteliklerine makine öğrenmesinde genellikle özellikler denir. Öğrenme tipleri denetimli öğrenme, denetimsiz öğrenme ve pekiştirmeli öğrenme olarak üç gruba ayrılmaktadır. Tez çalışmasında denetimli öğrenme yöntemi tercih edilmiştir.

Denetimli Öğrenme

Denetimli öğrenmede, önceden hedef bilgileri içeren veriler eğitim için sağlanmıştır dolayısıyla bir miktar etiketlenmiş verinin bulunması gereklidir (Hatipoğlu 2016). Bu etiketlenmiş veriler kullanılarak hata oranı azaltma çabası söz konusudur. Denetimli öğrenme algoritmaları bir kural geliştirmek için eğitim verilerini kullanır, yeni gelen veri örneklerini (test verisi) haritalamak için bir model oluşturur. Öğrenme modeli eğitildikten sonra, test verisinin hedef niteliğini (veya sınıf etiketini) sınıflandırabilir veya tahmin edebilir. Tahmini hedef özellikleri etiket ise, denetlenen öğrenme görevi sınıflandırma olarak adlandırılır. Ancak, öngörülen nitelik sürekli bir sayısal değer ise, algoritma regresyon veya tahmin olarak adlandırılır. Hem sınıflandırma hem de regresyon problemlerinde, algoritmalar hatayı minimize etmek için uygun bir fonksiyon arar (Hatipoğlu 2016).

3.5.1.c. Veri setini eğitim, doğrulama ve test setlerine ayırma

Veri setinin tamamını eğitim, doğrulama ve test setine rastgele olarak bölmek, istatistiksel olarak veri analizinde çok yaygındır. Veri setini eğitim, doğrulama ve test bölümlerine ayırmanın yolu için önceden tanımlanmış ve genel bir kural yoktur, bu noktada eğitimin örneklem büyüklüğü denetimli öğrenme için en belirleyici faktördür.

3.5.2. Yapay sinir ağları ve derin öğrenme kavramları


3.5.2.a. Sinir ağları

Sinir ağları canlı organizmalardaki kompleks yapıları biyolojik sinir ağlarından ilham alan matematiksel olarak yapılandırılmış bir modeldir. Yapay sinir ağı ile gerçek sinir sistemi arasındaki ilişki zayıf olmasına rağmen, gerçek sinir sisteminin çalışma prensipleri yapay sinir ağları tarafından basit bir şekilde taklit edilmeye çalışılmaktadır. Yapay sinir ağları, görüntü işleme, zaman serisi tahmini, sınıflandırma, veri işleme, regresyon analizi, örüntü tanıma, astronomi, karar verme, süreç kontrolü, bilişsel bilimler gibi alanlarda yaygın olarak kullanılmaktadır (Adorf 1989, McCloskey 1991).

3.5.2.b. Yapay sinir ağları

Yapay sinir ağının temel bloğu, biyolojik bir nöronla bazı benzerlikler gösteren yapay bir nörondur. Biyolojik bir nöron diğer nöronlardan gelen sinyalleri dendritleriyle toplar; daha sonra bu sinyaller toplanır ve cevap bir hücre tarafından üretilir. Daha sonra yanıt, aksonlar tarafından diğer nöronlara dağıtılır. Benzer şekilde, yapay nöron çalışırken, ayrı ayrı ağırlıklı girdiler yapay nöronların gövdesine iletilir. Yapay nöronun gövde kısmı, ağırlıklı girişleri ve eğilimleri (bias) toplar. Ardından toplam, tanımlanan transfer fonksiyonuna göre işlenir.

Temel anlamda yapay nöron modelinin ilk tanımı 1943 yılında McCulloch ve Pitts (McCulloch and Pitts 1943) tarafından yapılmıştır. Bu tanımda çıktı fonksiyonu bir basamak fonksiyonudur. Bu da demek oluyor ki, belirli bir eşik değeri karşılandığı zaman, çıktı bir değer alır; diğer durumda çıktı sonucu değeri sıfırdır. McCulloch ve Pitts modeli Şekil 3.17'de incelenebilir.



Şekil 3.17. McCulloch ve Pitts modeli (Hatipoğlu 2016)

Ağırlıklar w ile, girdi x ile, çıktı y ile ve transfer fonksiyonu T ile ifade edilmiştir

McCulloch ve Pitts modelinin matematiksel ifadesi:

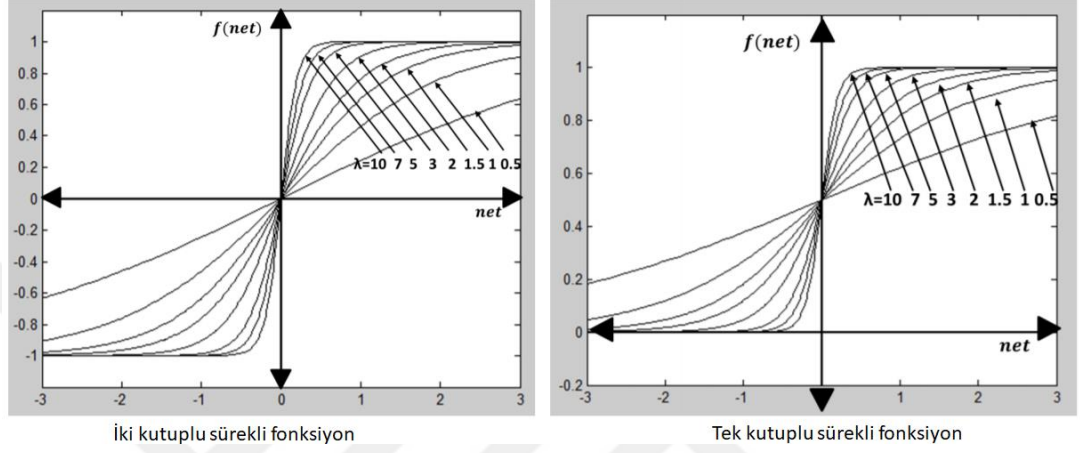
$$Çıkış^{k+1} = \begin{cases} \sum_{i=1}^n w_i x_i^k \geq T \text{ ise } 1 \\ \sum_{i=1}^n w_i x_i^k < T \text{ ise } 0 \end{cases} \quad (3.8)$$

Transfer fonksiyonu, ağırlıklı giriş sinyallerini ve sapmaları (bias) işler. Dolayısıyla, genel matematiksel model aşağıdaki formülle ifade edilebilir.

$$y(k) = F(\sum_{i=1}^n w_i(k)x_i(k) + b) \quad (3.9)$$

Çoklu doğrusal fonksiyonların doğrusal bir kombinasyonu yine doğrusal fonksiyonlardır. Bu nedenle, bir yapay sinir ağındaki nöronların her biri doğrusal bir işlev kullanıyorsa, sinir ağının son çıkışı girdilerin doğrusal işlev kombinasyonları olacaktır. Genellikle nöronlar, aktivasyon işlevlerinde doğrusal olmayan işlemi gerçekleştirir. Tipik olarak kullanılan uygulama fonksiyonları, iki kutuplu sürekli / ikili fonksiyonlar veya tek kutuplu sürekli / ikili fonksiyonlardır. Tek kutuplu ve iki kutuplu fonksiyonlar arasındaki

fark, iki kutuplu fonksiyonların hem olumsuz hem de olumlu tepkiler üretebilmesidir, tek kutuplu fonksiyonlar ise yalnızca olumsuz olmayan tepkiler üretmektedir (Hatipoğlu 2016).



Şekil 3.18. Tek kutuplu ve iki kutuplu sigmoid fonksiyonlar (Hatipoğlu 2016)

Bipolar (iki kutuplu) sürekli aktivasyon fonksiyonu:

$$f(net) = \left(\frac{2}{1 + \exp(-\lambda_{net})} \right) - 1 \quad (3.10)$$

Unipolar (tek kutuplu) sürekli aktivasyon fonksiyonu:

$$f(net) = \left(\frac{2}{1 + \exp(-\lambda_{net})} \right) \quad (3.11)$$

Şekil 3.18' de gösterilen tek kutuplu ve iki kutuplu sürekli fonksiyonlar genellikle sigmoid fonksiyonlar olarak adlandırılır. Bipolar yapılar yapay ağlardaki unipolar fonksiyonlardan daha yaygındır ve bipolar sigmoid fonksiyonlar en yaygın olarak kullanılan fonksiyon tipidir. Ayrıca, ikili ve sürekli transfer fonksiyonuna sahip yapay nöronlara sırasıyla ikili ve sürekli yapay nöron perseptronu denir. İkili perseptron, sınıflandırma problemleri için oluşturulmuş olan yapay sinir ağlarının çıktı katmanında en yaygın olarak kullanılan tipteki perseptrondur.

Bipolar ikili aktivasyon fonksiyonu aşağıdaki gibi ifade edilebilir.

$$f(net) = \text{sgn}(net) = \begin{cases} net > 0 \text{ ise } 1 \\ net < 0 \text{ ise } -1 \end{cases} \quad (3.12)$$

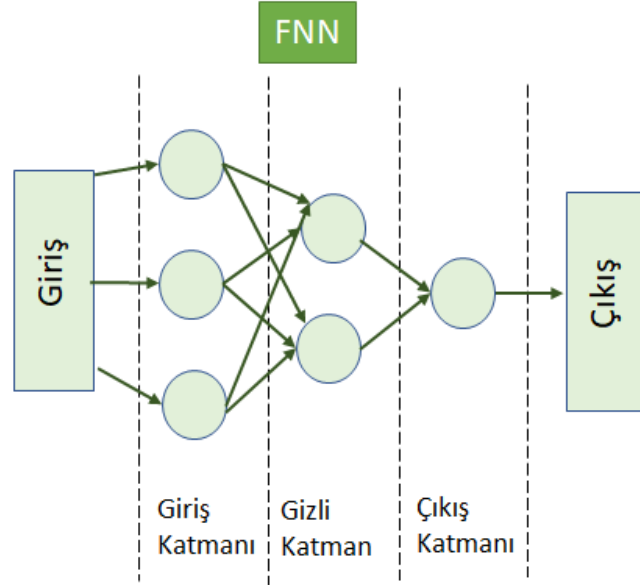
Unipolar ikili aktivasyon fonksiyonu da aşağıdaki gibi ifade edilebilir.

$$f(net) = \text{sgn}(net) = \begin{cases} net > 0 \text{ ise } 1 \\ net < 0 \text{ ise } 0 \end{cases} \quad (3.13)$$

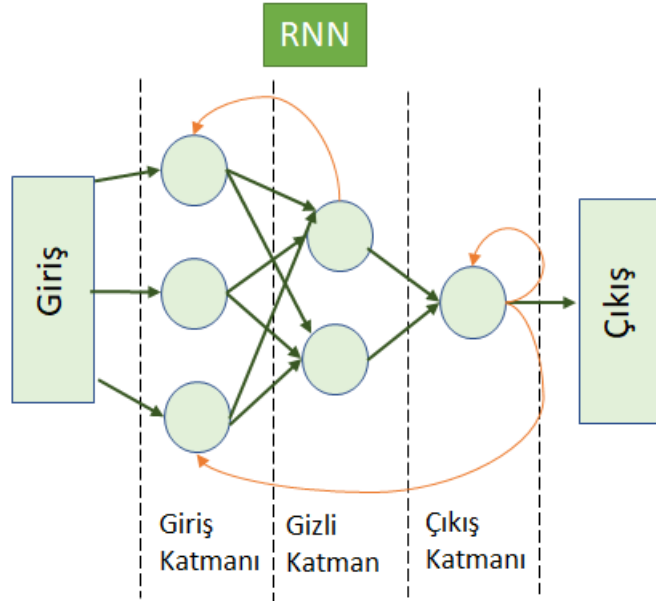
3.5.2.c. Yapay sinir ağlarının farklı modelleri

Tek bir yapay sinir hücresi gerçek yaşam problemlerini çözebilme konusunda yetersizdir, ancak iki veya daha fazla yapay sinir hücresini birleştirmek karmaşık gerçek yaşam problemlerini çözebilir. Sinir ağı, nöronların birbirine bağlanması olarak tanımlanabilir. İlgili nöron çıkışları ve girişleri ağırlıklar vasıtasıyla bağlanır. Gerektiğinde nöronların arasına gecikme bloğu yerleştirilebilir (Hatipoğlu 2016).

Yapay bir sinir ağı oluşturulurken nöronlar birbirine rastgele bağlanmaz. Yapay sinir ağlarının standart topolojileri vardır. Bu topolojiler, problemleri etkin ve kolay bir şekilde çözmek için hazırlanır ve önceden tanımlanmıştır. Bu topolojiler ileri ve geri topolojiler olan iki temel sınıfta incelenebilir. İleri besleme durumunda, bilgiler girdiden çıktıya yalnızca bir yönde akar. Bu nedenle ileri beslemeli sinir ağı (FNN-feed-forward neural network) topolojisine döngüsüz grafik de denir. Diğer taraftan basit tekrarlayan sinir ağı (RNN-recurrent neural network) topolojisinde bilgi sadece girdiden çıktı yönüne akmaz, aynı zamanda çıktıdan girdi yönüne de akar. Bu yüzden bu tür topolojiler yarı döngüsel grafikler olarak adlandırılabilir (Krenker *et al.* 2011).



Şekil 3.19. İleri Beslemeli yapay sinir ağı (Feed Forward Neural Network) (Hatipoğlu 2016)



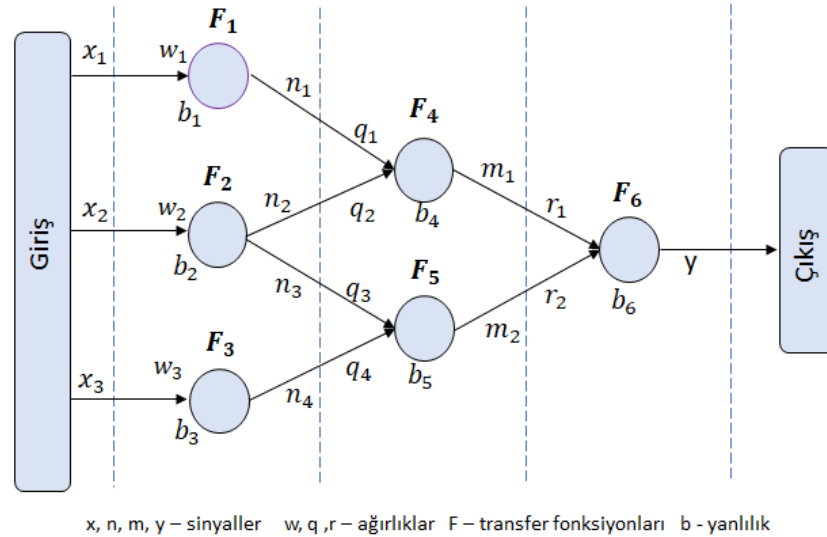
Şekil 3.20. Tekrarlayan yapay sinir ağı (Recurrent Neural Network) (Hatipoğlu 2016)

Yapay Sinir Ağlarındaki nöronlar Şekil 3.19 ve Şekil 3.20’de gösterildiği gibi, sinir ağının hangi katmanına dahil olduğuna göre isimlendirilebilir. Girişten çıkış yönüne, ilk katman girdi katmanı, son katman ise çıktı katmanı olarak adlandırılır. Giriş ve çıkış

katmanı arasına yerleştirilen tüm kalan katmanlar gizli katmanlar olarak etiketlenir. Gizli katmanlar, sinir ağlarının eğitim örneklerinin ara sonuçlarının saklandığı yerdir. Sınırlı sayıda birime sahip olan tek bir gizli katman ağına sahip olan yapay sinir ağı, evrensel yaklaşım teoremine göre herhangi bir rastgele fonksiyonu, kabul edilebilir bir hata oranıyla ifade etmek üzere eğitilebilir. Her bir fonksiyonu öğrenmek için tek bir gizli katman ağı yeterli gibi görünüyor olmasına rağmen birden çok gizli katman ile tasarlanmış yapay sinir ağları daha iyi sonuçlar verebilmektedir (Hatipoğlu 2016).

1. İleri Beslemeli Yapay Sinir Ağları

İleri beslemeli yapay sinir ağı, temel olarak ileri beslemeli topolojiye sahip yapay sinir ağıdır. Bu topoloji, bilgilerin yalnızca girdiden çıktı yönüne akması gereken bir temel koşula sahiptir. Transfer fonksiyonlarının türü, nöronlar arasındaki bağlantıların sayısı veya derin ağlar gibi katmanların sayısı ile ilgili herhangi bir sınırlama veya kısıtlama yoktur (Hatipoğlu 2016). Bir gizli katmana sahip basit bir ileri beslemeli yapay sinir ağı, Şekil 3.21’de gösterilmektedir.



Şekil 3.21. İleri beslemeli yapay sinir ağı (Hatipoğlu 2016)

F1, F2, F3, giriş sinyalleri x_1, x_2, x_3 tarafından beslenen giriş katmanı transfer fonksiyonlarıdır. W_i, q_i ve r_i ile gösterilenler ise sırasıyla gizli girdi ve çıktı katmanlarının ağırlıklarıdır.

Gizli katmanları besleyen girdi katmanlarının çıktısı n_i ' dir. Gizli katmanlara ait transfer fonksiyonları (F3, F4) tarafından üretilen çıkış sinyalleri aşağıdaki denklemlerde m_i olarak gösterilmiştir. Sapma değerleri, aşağıdaki denklemlerin hepsinde b_i olarak temsil edilmiştir. Son olarak, sınıf etiketlerini atayan ileri besleme ağı'nın çıktısı y' dir.

İleri beslemeli yapay sinir ağlarının ayrıntılı matematiksel temsili, aşağıdaki formüller ile ifade edilmiştir.

$$n_1 = F_1(w_1 \cdot x_1 + b_1) \quad (3.14)$$

$$n_2 = F_2(w_2 \cdot x_2 + b_2) \quad (3.15)$$

$$n_3 = F_2(w_2 \cdot x_2 + b_2) \quad (3.16)$$

$$n_4 = F_3(w_3 \cdot x_3 + b_3) \quad (3.17)$$

$$m_1 = F_4(q_1 \cdot n_1 + q_2 \cdot n_2 + b_4) \quad (3.18)$$

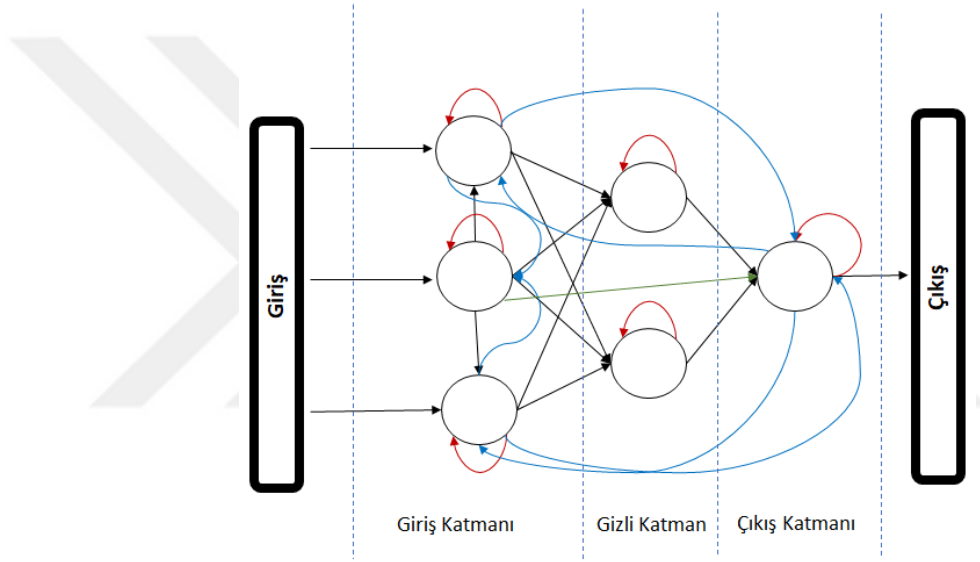
$$m_2 = F_5(q_3 \cdot n_3 + q_4 \cdot n_4 + b_5) \quad (3.19)$$

$$y = F_6(r_1 \cdot m_1 + r_2 \cdot m_2 + b_6) \quad y = F_6[r_1 (F_4[q_1 \cdot F_1 [w_1 x_1 + b_1] + q_2 F_2[w_2 \cdot x_2 + b_2]] + b_4) + \dots + r_2 (F_5[q_3 F_2[w_2 \cdot x_2 + b_2] + q_4 F_3[w_3 \cdot x_3 + b_3] + b_5) + b_6] \quad (3.20)$$

Yapay sinir ağlarının parametrelerinin elle hesaplanması pratik ve uygulanabilir değildir, dolayısıyla sinir ağını tüm topoloji tiplerine yönelik inşa etmek ve optimize etmek için bilgisayarlar ve özel yazılımlar kullanılır.

2. Tekrarlayan Yapay Sinir Ağları

Tekrarlayan yapay ağ, temelde tekrarlayan topolojiye sahip yapay sinir ağıdır. Bu topolojide bilgi akışı yönünde herhangi bir kısıtlama yoktur. Bilgi geriye doğru ve ayrıca aynı seviyedeki nöronlar arasında akabilir. Geriye doğru akış yeteneği, tekrarlayan ağların, giriş dizilerini incelemek için dahili hafızalarını kullanmalarını sağlar (Hatipoğlu 2016).

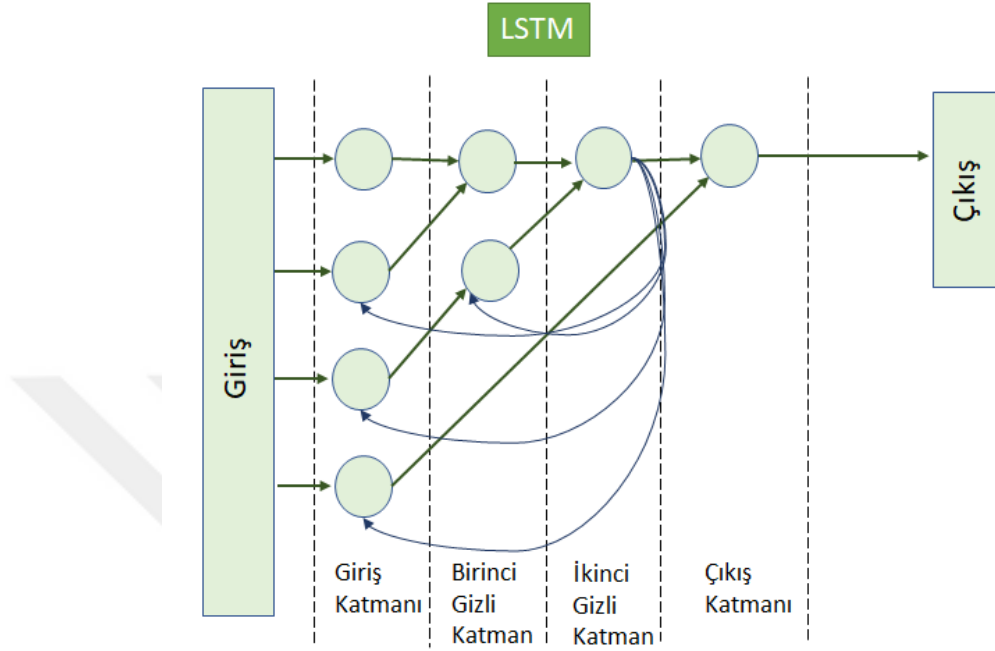


Şekil 3.22. Tamamen tekrarlayan yapay sinir ağı (Hatipoğlu 2016)

a. Uzun Kısa Süreli Hafıza (LSTM – Long Short Term Memory)

Uzun Kısa Süreli Bellek, tekrarlayan yapay sinir ağlarının bir çeşit topolojisidir. Önemli olaylar arasındaki hem kısa hem de uzun gecikme süreleri ile zaman serilerini sınıflandırabilir ve tahmin edebilir. Uzun Kısa Süreli Bellek, temel tekrarlamalı yapay sinir ağlarından daha çok bilgiyi hatırlama yeteneğine sahiptir (Hatipoğlu 2016). Uzun Kısa Süreli Belleğin giriş katmanının aktarım fonksiyonu sigmoid fonksiyondur.

Uzun Kısa Süreli Hafızanın Mimarisi Şekil 3.23'de görülmektedir.



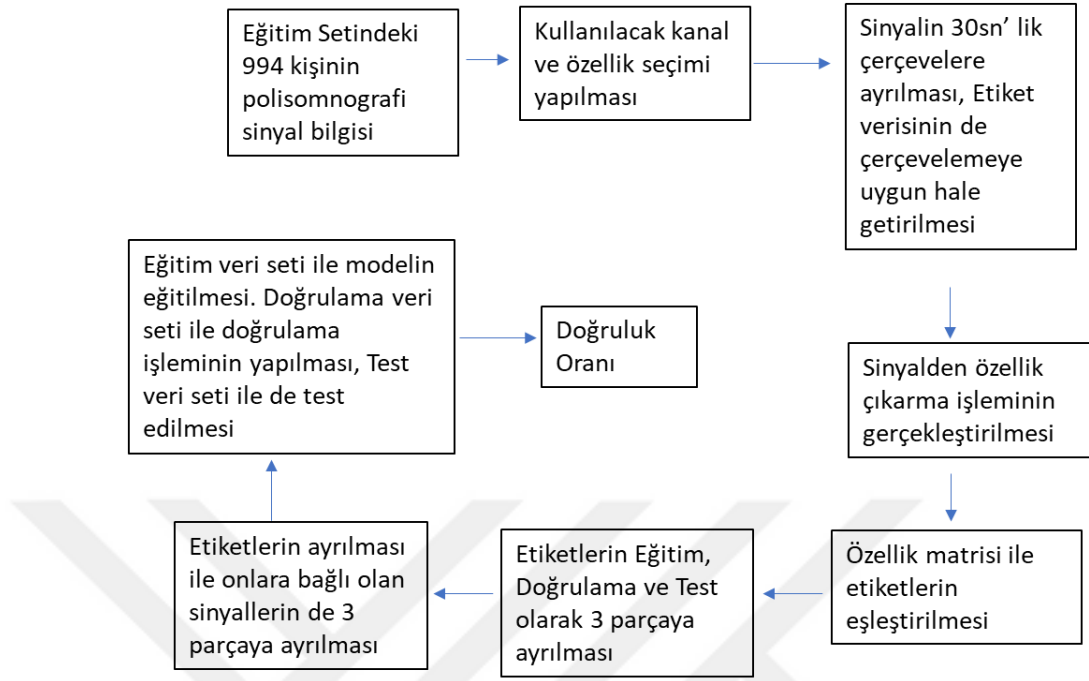
Şekil 3.23. Uzun kısa süreli bellek topolojisinde hazırlanmış basit bir yapay sinir ağı (Hatipoğlu 2016)

Giriş katmanındaki en önemli nöronlar üçüncü ve dördüncü nöronlardır. Üçüncü nöron, bellek ünitesinin bilgileri ne kadar süre hatırlayacağını belirlerken dördüncü nöron, bellekten gelen değerın çıkışa ne zaman gönderilmesi gerektiğine karar verir (Krenker *et al.* 2011).

3.5.3. Tez çalışmasında kullanılan algoritmalar ve elde edilen sonuçlar

3.5.3.a. Kişi bağımlı ya da kişiden bağımsız diye ayırmaksızın uygulanan algoritma

Eğitim Seti 994 kişiden alınan 13 kanallı bir sinyal dizinidir. Bu veri seti üzerinde kullanılmış olan ilk algoritmada sonucun kişi bağımlı ya da kişiden bağımsız olması dikkate alınmamıştır. Doğruluk oranları 5'li sınıflandırma için bulunmuştur. Kullanılan algoritma Şekil 3.24'deki gibidir.

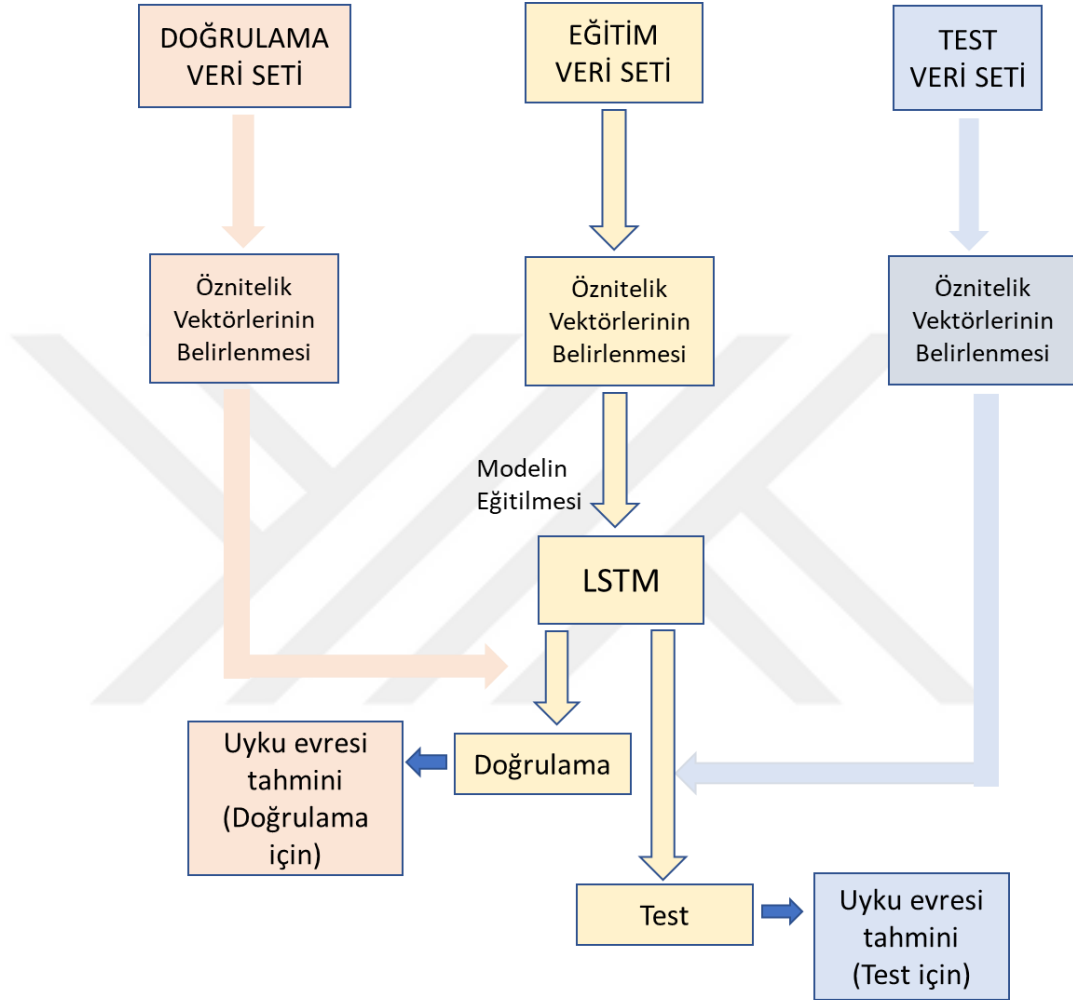


Şekil 3.24. Kişi bağımlı ya da kişi bağımsız diye ayırmaksızın deney yapılırken kullanılan algoritma

994 kişinin polisomnogram bilgisini içeren sinyal ve etiketi Matlab ortamında bir folder içerisinde bulunmaktadır. Çerçeve genişliği ve örtüşme miktarı 30 sn olarak belirlenmiştir, her bir kişi için özellik çıkarma işlemi gerçekleştirilmiştir. Tüm veri setinden çıkarılan özellikler ile bu özelliklere ait etiketler birbiri ile ilişkilendirilmiştir.

Sınıflandırma basamağından hemen önceki adım olarak etiketleriyle ilişkilendirilmiş sinyal parçaları eğitim, doğrulama ve test verisetleri olarak 3 parçaya ayrılmıştır. Bu verisetlerinin 994 kişilik baştaki veri seti içindeki oranları sırası ile 0.5, 0.2, 0.3 olarak seçilmiştir. Veri seti parçalanırken rastgele olması ve dağılımının dengeli olması için Matlab'deki cvpartition fonksiyonu kullanılmıştır. Son aşama olarak belirlenen LSTM yazılım mimarisi parametreleri ile sınıflandırma işlemi gerçekleştirilmiştir. Kullanılan LSTM yazılım mimarisi parametreleri doğruluk oranını büyük ölçüde etkilediği için bu parametreler ve doğruluk oranına etkileri sonuçlar kısmında detaylı olarak incelenmiştir.

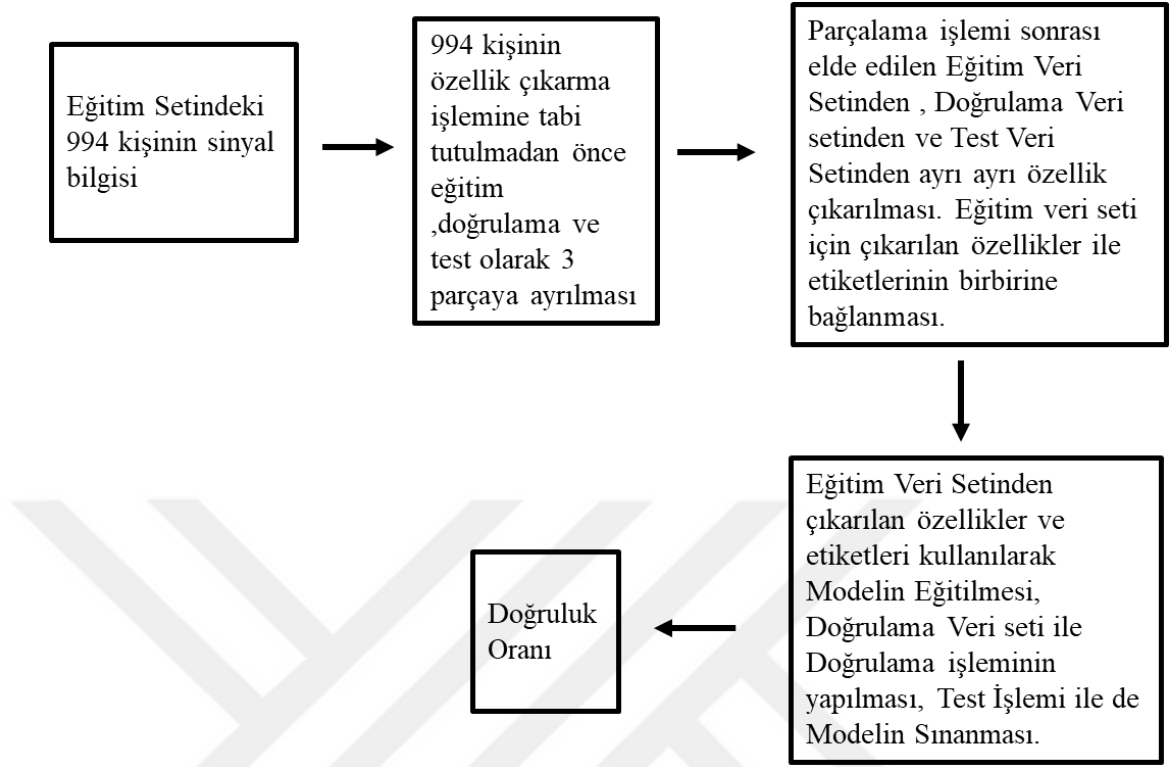
Şekil 3.25’de Kişi Bağımlı ve Kişiden Bağımsız Algoritmalar için kullanılmış olan genel blok diyagram bulunmaktadır.



Şekil 3.25. Kişi Bağımlı ve Kişiden Bağımsız Algoritmalar için kullanılan genel yapı

3.5.3.b. Kişi bağımlı algoritma

Kişi Bağımlı Algoritma ile elde edilen sonuçlar kişiye bağımlı bir şekilde özellik çıkarma işlemi neticesinde elde edilmiştir. Kişi Bağımlı algoritmanın blok diyagramı üzerinden süreç incelenecek olursa;



Şekil 3.26. Kişi Bağımlı Algoritma

İlk uygulanan adım Matlab ortamında Sinyal ve etiketlerin bulunduğu folder'ın açılması ve sonrasında algoritma gereği 994 kişilik veri setinin eğitim, doğrulama, test veri seti olarak 3 parçaya ayrılmasıdır. Bu ayırma işlemi yapılırken seçilen kişiler tamamen rastgele bir biçimde seçilmektedir. Uygulanan oranlar ise Eğitim, Doğrulama ve Test için sırasıyla 0.5, 0.2, 0.3'tür. Bu bölme işleminin cvpartition ile değil 'dividerand' fonksiyonu ile yapılması uygun görülmüştür. 'Dividerand' fonksiyonu da tıpkı 'cvpartition' fonksiyonu gibi makine öğrenmesi algoritmalarında sıklıkla kullanılan bir fonksiyondur. Kişi Bağımlı ya da Kişiden Bağımsız Diye Ayırmaksızın Uygulanan Algoritma'dan farklı olarak eğitim, doğrulama ve test veri setlerine ayırma işlemi özellik çıkarma işleminden önce yapılmıştır. Buradaki amaç veri setinden özellik çıkarılırken özelliğin kişiye bağımlılığını bozmamaktır. Özellik çıkarma işleminin kişi bazlı yürütülmesi esastır.

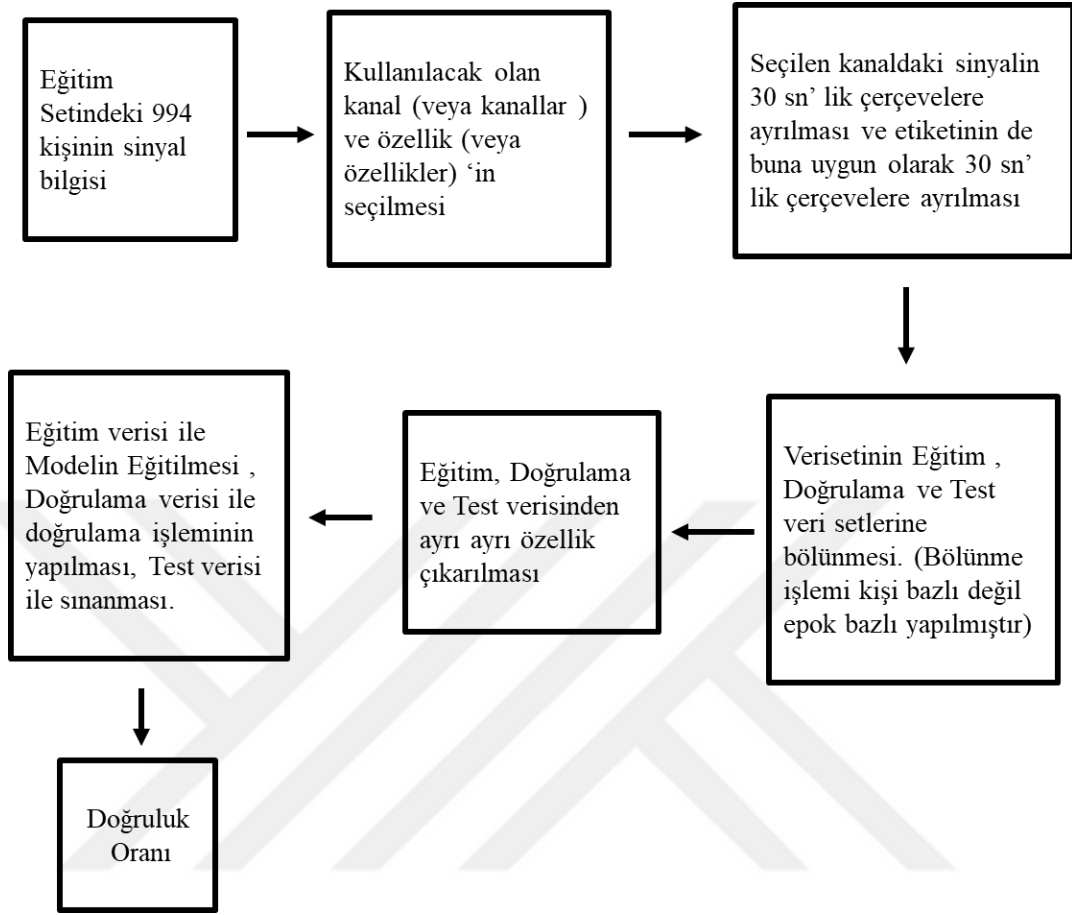
Özellik çıkarma aşaması her bir veri seti için ayrı fonksiyonlar ile yapılmıştır. Çıkarılan özellik ve işlemin uygulandığı kanal ise bütün fonksiyonlarda aynı tanımlanmıştır. Bu işlemin sonucunda her bir veri setinden ayrı ayrı çıkarılmış özellik matrisleri elde

edilmiştir. Bu özellik matrisleri ilk algoritmada anlatıldığı şekilde etiketleri ile ilişkilendirilmiştir. Bu aşamalar bütün algoritmalarda aynı seyretmekle beraber, değişiklik yaratan durum işlemlerin sırasıdır.

Özellik Çıkarma işlemi tamamlandıktan sonra eğitim veri setinden çıkarılan özelliklerin oluşturduğu matris ve etiketleri kullanılarak sınıflandırmada kullanılacak model eğitilmiştir. Sonraki adımda doğrulama veri setinden çıkarılan özelliklerin oluşturduğu matris kullanılarak doğrulama işlemi yapılmıştır. Bu şekilde model adeta bir ön sınava tabi tutulmuştur. Bu ön sınav aracılığı ile öğrenilmek istenen şey modelin eğitiminde aşırı uyma (overfitting) ya da eksik uyma (underfitting) olup olmadığını anlamaktır. Son olarak da test veri seti kullanılarak model sınanmıştır ve doğruluk oranı diye adlandırılan yüzdeleri değere erişilmiştir. Bu değer, modelin yüzde kaç doğrulukla çalıştığı hakkında bir fikir verir. Daha kesin bir sonuca varmak için Performans Ölçütleri Bölümünde detaylı bir şekilde açıklanmış olan 10 kat çapraz doğrulama (10 fold cross validation) gibi bir yöntemle Doğruluk oranı işlemi tekrar edilip ortalama alınmalıdır. Doğruluk oranının nasıl hesaplandığı ve 10 kat çapraz doğrulama kavramları Performans Ölçütleri başlığı altında açıklanmıştır.

3.5.3.c. Kişiden bağımsız algoritma

Bu şekilde elde edilen sonuçlar kişiden bağımsız bir şekilde özellik çıkarma işlemi neticesinde elde edilmiştir. Kişiden Bağımsız Deney için uygulanan algoritmanın blok diyagramı Şekil 3.27’de görülmektedir.



Şekil 3.27. Kişiden bağımsız algoritma

Kişiden Bağımsız Algoritma da diğer iki algoritma gibi 994 kişinin Polisomnografi bilgisinin Matlab ortamına girişi ile başlar. Kullanılacak olan kanal ve özellik çiftleri yazılımı yapan kişi tarafından belirlenmelidir. Bu algorithmada amaç özellik çıkarma işleminin kişi bazlı olmamasıdır. Bunu gerçekleştirebilmek için sinyallerin eğitim, doğrulama ve test veri setlerine bölünmesi çerçeve sayısı baz alınarak yapılmıştır. Bu amaçla sinyal özellik çıkarma adımından önce 30 sn'lik çerçevelere ayrılmıştır. Çerçevenilmiş sinyal etiket sayısına göre `cvpartition` fonksiyonu kullanılarak eğitim, doğrulama, test veri setlerine bölünmüştür. Ayrılma oranları diğer algoritmalarda olduğu gibi sırası ile 0.5, 0.2, 0.3 olarak belirlenmiştir. Ayrı veri setlerine ayrı ayrı özellik çıkarma işlemi uygulanmıştır. Son aşama olarak tıpkı diğer algoritmalarda olduğu gibi eğitim veri setinden çıkarılan özelliklerin oluşturduğu matris ve etiketleri kullanılarak sınıflandırmada kullanılacak model oluşturulmuştur, doğrulama veri setinden çıkarılan

özelliklerin oluşturduğu matris kullanılarak doğrulama işlemi yapılmıştır. Son olarak da test veri seti kullanılarak model sınanmıştır ve doğruluk oranı diye adlandırılan, performans ölçütleri kısmında 3.7.1 başlığı altında nasıl bulunduğu gösterilmiş olan değere erişilmiştir.

3.6. Veri Setinin Tanıtılması

Bu bölümde üzerinde çalışılan veri seti detaylı olarak anlatılacaktır. Bu tez çalışmasında ‘You Snooze, You Win: the PhysioNet/Computing in Cardiology Challenge 2018’ isimli veri seti kullanılmıştır (Ghassemi *et al.* 2018). Bu veri seti 1983 kişinin polisomnogram bilgisinden oluşmaktadır.

Veri setinde 13 tane kanal bilgisi bulunmaktadır. 1. Kanal ile 6. Kanal arası (6. Kanal da dahil olmak üzere) EEG sinyalleridir. EEG kanalları Uluslararası 10 – 20 standardına göre yerleştirilmiştir (Ghassemi *et al.* 2018). (Uluslararası 10 – 20 standardına göre EEG elektrodu yerleşimi Şekil 3.6’da gösterilmektedir.) 6 kanaldan EEG bilgisi alınmıştır ve bu kanalların isimleri; F3-M2, F4-M1, C3-M2, C4-M1, O1-M2 ve O2-M1’dir (Ghassemi *et al.* 2018). 7. kanaldan EOG verisi alınmıştır, sadece sol gözün EOG verisi alınmıştır (Ghassemi *et al.* 2018). 8. kanal, 9. Kanal ve 10. Kanal EMG sinyali içermektedir. 8. Kanal çeneden alınan EMG verisini, 9. Kanal karından alınan EMG verisini, 10. Kanal göğüsten alınan EMG verisini içermektedir (Ghassemi *et al.* 2018). 11. kanal hava akışı bilgisini, 12. Kanal Oksijen saturasyonu bilgisini ve 13. kanal ECG bilgisini içermektedir (Ghassemi *et al.* 2018). Oksijen Saturasyonu dışındaki bütün sinyaller 200Hz’lik örnekleme frekansı ile kaydedilmiştir. Oksijen Saturasyonu bilgisi ise 200Hz’e üst örnekleme (upsample) yapılarak diğer sinyaller ile senkronizasyonu sağlanmıştır (Ghassemi *et al.* 2018).

Verisetindeki bireyler hasta, sağlıklı, ilaç kullanan ya da kullanmayan ve geniş bir yaş skalasında olan bireylerdir (Ghassemi *et al.* 2018). Veriseti ile ilgili bu karakteristik bilgiler Çizelge 3.1’de anlatılmıştır. 1983 kişiden oluşan bu veriseti 2 bölümden oluşmaktadır. Birinci bölüm Eğitim kısmıdır, bu kısım 994 örnek ve bu örneklere ait

etiketleri içermektedir. 989 kişiden (örnekten) oluşan test kısmının ise etiketlerine internet üzerinden erişim mümkün değildir. Bu nedenle tez çalışmasında sadece 994 kişilik Eğitim seti üzerinde çalışılmıştır. Eğitim Seti diye isimlendirilen 994 kişinin polisomnografi kayıtlarından oluşan veri setinin etiketleri bir uyku uzmanı tarafından belirlenmiştir ve Matlab'a uyumlu şekilde internet üzerinden erişime açıktır. Bu veri seti ile çalışılırken üç çeşit algoritma geliştirilmiş ve sonuçları karşılaştırmalı olarak tezin sonuçlar kısmında paylaşılmıştır. Algoritmaların Blok diyagramları ve açıklamaları ise 3.5.3 başlığı altında verilmiştir.

Çizelge 3.1. Physio.net computing in cardiology challenge 2018 veriseti içeriği (Ghassemi *et al.* 2018)

Klinik Özellik	Toplam	Eğitim Verisi	Test Verisi
Örnek Sayısı	1983	994	989
Yaş	55 (14.4)	55 (14.3)	55 (14.4)
Cinsiyet (Erkek Yüzdesi)	65	67	63
BMI	33 (7.6)	33 (7.8)	33 (7.5)
AHI	19 (14.4)	19 (14.6)	18.9 (14.4)
ESS	8.6 (5.3)	8.5 (5.3)	8.7 (5.3)
Kayıt Süresi (saat)	7.7 (0.7)	7.7 (0.7)	7.7 (0.7)
Yatakta geçirilen süre (saat)	7.5 (0.7)	7.5 (0.7)	7.5 (0.7)
Uyku süresi (saat)	6.2 (1.2)	6.2 (1.1)	6.1 (1.2)
İlaç Kullanımı (%)			
Hipertansiyon	40.9	41.0	40.6
Uyku İlacı	28.3	29.0	27.8
Antidepresan	26.1	25.7	26.5
Nöroaktif	19.1	20.8	17.5
Benzodiazepine	16.1	16.9	15.4
Diyabetik	11.7	11.9	11.5
Opiate	7.4	8.1	6.7
Antihistamin	4.8	4.8	4.8
Uyarıcı	4.7	3.9	5.5
Nöroleptik	4.2	4.5	3.8
Bitkisel	4.2	4.3	4.0
Hastaneye gelme sebebi			
Teşhis Amaçlı	41.8	41.16	42.47
Gece boyunca aralıklı CPAP	38.35	37.95	39.03

Polisomnografi sinyal dizisinin işlendiği bu çalışma Matlab programı kullanılarak yapılmıştır. Matlab, bilim adamları ve mühendisler tarafından çokça tercih edilen ve dünya çapında bilinen bir programdır. Matlab kendi içinde kütüphaneler bulundurmaktadır. Bu kütüphanelerdeki hazır fonksiyonlar ile karmaşık matematiksel ve istatistiksel işlemler kolay ve hızlı bir şekilde gerçekleştirilmektedir (Korkmaz 2016).

Özellik çıkarma aşamasında detaylı olarak anlatılacak olan Mel Kepstrum katsayılarının çıkarılması için de Imperial College London'da görevli olan bilim insanı Mike Brooks'un Matlab'de kullanım için hazırlamış olduğu Voicebox isimli kütüphaneden faydalanılmıştır (Brooks 1997).

Tez çalışmasında diğer bir özellik çıkarma işlemi olarak kullanılmış olan Bağımsız Bileşen Analizi işleminin yapılabilmesi için de Helsinki Teknoloji Üniversitesi'nden Aapo Hyvärinen adlı bilim insanının hazırlamış olduğu fastICA algoritmasından ve hazır fonksiyonundan faydalanılmıştır (Hyvärinen *et al.* 2001).

3.7. Performans Ölçütleri

3.7.1. Doğruluk oranı

Otomatik uyku evresi sınıflandırması çalışmalarında amaç her bir epogun uyku evresinin doğru bir şekilde tespit edilmesidir (Oral vd 2015). Yapılan çalışmada N_e hatalı sınıflandırılan epok sayısı, N toplam epok sayısı kabul edildiğinde performans ölçümü doğru tahmin edilen epok sayısının toplam epok sayısına oranı dikkate alınarak yapılmakta ve aşağıdaki gibi hesaplanmaktadır (Dal vd 2015).

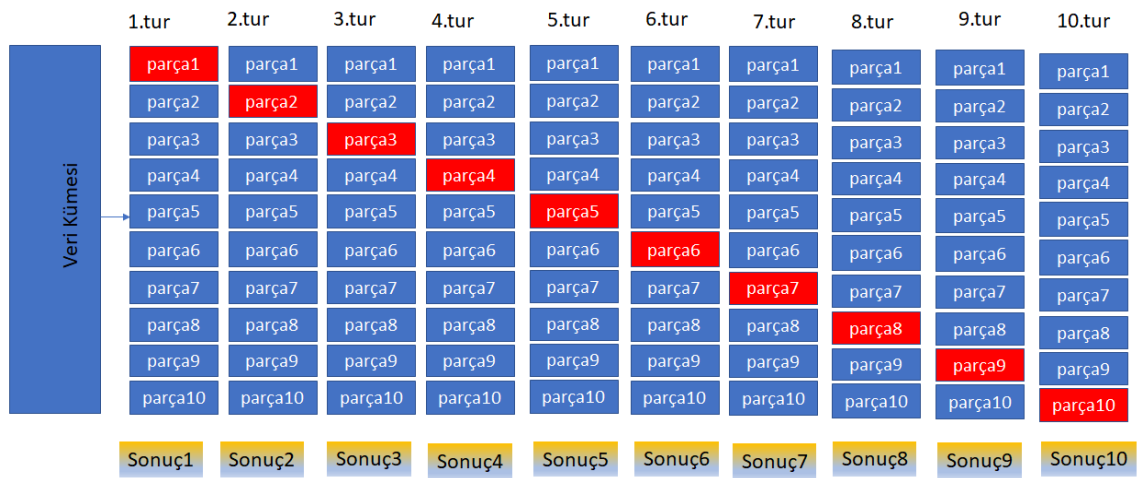
N_e : Hatalı Sınıflandırılan Epok Sayısı

N: Toplam Epok Sayısı

$$P = \left[\frac{N - N_e}{N} \right] * 100 \quad (3.20)$$

Tez çalışmasındaki doğruluk oranına Denklem 3.20 kullanılarak erişilmiştir. Bu değer, Modelin yüzde kaç doğrulukla çalıştığı hakkında bir fikir verir. Daha kesin bir sonuca varmak için K katlamalı çapraz doğrulama (K fold cross validation) gibi bir yöntemle Doğruluk oranı işlemi tekrar edilip ortalama alınmalıdır.

3.7.2. 10 kat çapraz doğrulama yöntemi



Şekil 3.28. 10 kat çapraz doğrulama – 10 fold cross validation

10 kat çapraz doğrulama işlemi yapılırken yukarıda görüldüğü gibi veri seti 10 eşit parçaya ayrılır, her bir bölünmüş veri setinde 1 parça test diğer parçalar ise eğitim seti olarak rastgele seçilir (Rodriguez and Perez 2010). Algoritma eğitim ve test verileri için 10 defa tekrar ettirilmiştir, her bir tekrardan elde edilen doğruluk oranlarına sonuç denilirse her bir tur için bir sonuç elde edilmiş olur. Sonra sonuç değerleri toplanıp 10'a bölünür yani sonuçların aritmetik ortalaması bulunmuş olur. Bu elde edilen değer sınıflandırıcının performansı bakımından ilk elde edilen doğruluk oranı değerine nazaran daha güvenilirdir (Rodriguez and Perez 2010).

3.7.3. Karmaşıklık matrisi (Hata matrisi)

Karmaşıklık matrisinin bir diğer adı Hata Matrisidir (Stehman 1997), bu matris bir algoritmanın görselleştirilmesini sağlayan özel bir tablo düzenidir. Matrisin her satırı

öngörülen bir sınıftaki örnekleri temsil ederken her sütunu da gerçek bir sınıftaki örnekleri temsil eder (Satırlar ile sütunlar yer değiştirebilir) (Powers 2007). Hata matrisi, doğru sınıflandırmaların sadece oranından daha fazla analiz yapılmasına olanak sağlar.

		TAHMİN	
		YOK	VAR
GERÇEK	YOK	TN	FP
	VAR	FN	TP

Şekil 3.29. 2 x 2'lik Karmaşıklık Matrisinin görüntüsü

Şekil 3.29 daki hata matrisinde TN, TP, FP, FN ile gösterilen kısaltmalar

TN: Burada yazan değer gerçek değer 0 ve tahmin edilen değer 0 olduğu durum sayısıdır.

TP: Burada yazan değer gerçek değer 1 ve tahmin edilen değer 1 olduğu durum sayısıdır.

FP: Burada yazan değer gerçek değer 0 ve tahmin edilen değer 1 olduğu durum sayısıdır.

FN: Burada yazan değer gerçek değer 1 ve tahmin edilen değer 0 olduğu durum sayısıdır.

Tezde üzerinde çalışılmış olan 5 sınıflı karmaşıklık matrisi ve bu matristeki değerlerin yerleşimi Şekil 3.30'daki gibidir. Satırlar tahmin, sütunlar ise gerçekteki durumu belirtmektedir.

	WAKE	NONREM 1	NONREM 2	NONREM 3	REM
WAKE	TP_{wake}	$E_{w/NR1}$	$E_{w/NR2}$	$E_{w/NR3}$	$E_{w/rem}$
NONREM 1	$E_{NR1/W}$	$TP_{Nonrem1}$	$E_{NR1/NR2}$	$E_{NR1/NR3}$	$E_{NR1/REM}$
NONREM 2	$E_{NR2/W}$	$E_{NR2/NR1}$	$TP_{Nonrem2}$	$E_{NR2/NR3}$	$E_{NR2/REM}$
NONREM 3	$E_{NR3/W}$	$E_{NR3/NR1}$	$E_{NR3/NR2}$	$TP_{Nonrem3}$	$E_{NR3/REM}$
REM	$E_{REM/W}$	$E_{REM/NR1}$	$E_{REM/NR2}$	$E_{REM/NR3}$	TP_{rem}

Şekil 3.30. 5’li sınıflandırma problemi için karmaşıklık matrisi

Yukarıdaki şekildeki kısaltmalar kısaca açıklanacak olursa;

TP_{wake} : Tahmin edilen durum Wake, gerçekteki durum Wake olduğunda elde edilen doğruluk durumunu ifade eder.

$E_{w/NR1}$: Gerçekteki durum Wake, tahmin edilen durum ise NonRem1 olduğunda elde edilen hatayı ifade eder.

$E_{w/NR2}$: Gerçekteki durum Wake, tahmin edilen durum ise NonRem2 olduğunda elde edilen hatayı ifade eder.

$E_{w/rem}$: Gerçekteki durum Wake, tahmin edilen durum ise Rem olduğunda elde edilen hatayı ifade eder.

$E_{NR1/w}$: Gerçekteki durum NR1, tahmin edilen durum ise Wake olduğunda elde edilen hatayı ifade eder.

TP_{Nonem1} : Tahmin edilen durum NonRem1, gerçekteki durum NonRem1 olduğunda elde edilen doğruluk durumunu ifade eder.

$E_{NR1/NR2}$: Gerçekteki durum NonRem1, tahmin edilen durum ise NonRem2 olduğunda elde edilen hatayı ifade eder.

$E_{NR1/NR3}$: Gerçekteki durum NonRem1, tahmin edilen durum ise NonRem3 olduğunda elde edilen hatayı ifade eder.

$E_{NR1/Rem}$: Gerçekteki durum NonRem1, tahmin edilen durum ise Rem olduğunda elde edilen hatayı ifade eder.

$E_{NR2/w}$: Gerçekteki durum NonRem2, tahmin edilen durum ise Wake olduğunda elde edilen hatayı ifade eder.

$E_{NR2/NR1}$: Gerçekteki durum NonRem2, tahmin edilen durum ise NonRem1 olduğunda elde edilen hatayı ifade eder.

TP_{Nonem2} : Tahmin edilen durum NonRem2, gerçekteki durum NonRem2 olduğunda elde edilen doğruluk durumunu ifade eder.

$E_{NR2/NR3}$: Gerçekteki durum NonRem2, tahmin edilen durum ise NonRem3 olduğunda elde edilen hatayı ifade eder.

$E_{NR2/rem}$: Gerçekteki durum NonRem2, tahmin edilen durum ise Rem olduğunda elde edilen hatayı ifade eder.

$E_{NR3/w}$: Gerçekteki durum NonRem3, tahmin edilen durum ise Wake olduğunda elde edilen hatayı ifade eder.

$E_{NR3/NR1}$: Gerçekteki durum NonRem3, tahmin edilen durum ise NonRem1 olduğunda elde edilen hatayı ifade eder.

$E_{NR3/NR2}$: Gerçekteki durum NonRem3, tahmin edilen durum ise NonRem2 olduğunda elde edilen hatayı ifade eder.

TP_{Nonem3} : Tahmin edilen durum NonRem3, gerçekteki durum NonRem3 olduğunda elde edilen doğruluk durumunu ifade eder.

$E_{NR3/rem}$: Gerçekteki durum NonRem3, tahmin edilen durum ise Rem olduğunda elde edilen hatayı ifade eder.

$E_{rem/w}$: Gerçekteki durum Rem, tahmin edilen durum ise Wake olduğunda elde edilen hatayı ifade eder.

$E_{rem/NR1}$: Gerçekteki durum Rem, tahmin edilen durum ise NonRem1 olduğunda elde edilen hatayı ifade eder.

$E_{rem/NR2}$: Gerçekteki durum Rem, tahmin edilen durum ise NonRem2 olduğunda elde edilen hatayı ifade eder.

$E_{rem/NR3}$: Gerçekteki durum Rem, tahmin edilen durum ise NonRem3 olduğunda elde edilen hatayı ifade eder.

TP_{Rem} : Tahmin edilen durum Rem, gerçekteki durum Rem olduğunda elde edilen doğruluk durumunu ifade eder.

4. ARAŞTIRMA BULGULARI

Hazırlanan tez kapsamında, bireylere ait polismonografi sinyali kullanılarak uyku evresinin tahminini gerçekleştiren deneysel çalışmalar yapılmıştır. Bu deneysel çalışmalarda makine öğrenmesi tekniklerinden Uzun Kısa Dönem Hafıza (Long Short Term Memory – LSTM) adıyla bilinen tekrarlamalı yapay sinir ağı topolojisi kullanılmıştır. Bu topoloji ile birlikte iki farklı özellik çıkarma yöntemi denenmiştir. Bu yöntemler Bağımsız Bileşen Analizi ve Mel Kepstrum Katsayıları'dır.

Uyku evresi sınıflandırma işlemi yapılırken polisomnografi sinyali ve bu sinyalle birlikte sağlanan etiketler kullanılarak LSTM modeli eğitilmiştir. Sonrasında etiketi olmayan sinyallerin (Test veri seti olarak ayrılan veri kümesi) etiketleri, eğitilmiş olan LSTM modeli ile tahmin edilmeye çalışılmıştır. Aşağıda gösterilen çizelgede hangi kanalın hangi sinyale karşılık geldiği gösterilmektedir.

Çizelge 4.1. Kanal bilgisi (Ghassemi *et al.* 2018)

1. Kanal	EEG
2. Kanal	EEG
3. Kanal	EEG
4. Kanal	EEG
5. Kanal	EEG
6. Kanal	EEG
7. Kanal	EOG
8. Kanal	EMG
9. Kanal	EMG
10. Kanal	EMG
11. Kanal	Hava Akışı
12. Kanal	Oksijen Saturasyonu
13. Kanal	ECG

- Araştırma bulgularının paylaşıldığı tablolarda 1. Kanal, 2. Kanal, 3. Kanal, 4. Kanal, 5. Kanal, 6. Kanal, 7. Kanal, 8. Kanal, 9. Kanal, 10. Kanal, 11. Kanal, 12. Kanal, 13. Kanal diye belirtilen kanal isimlerinin hangi sinyallere karşılık geldiği Çizelge 4.1 ile ifade edilmiştir.

Tez çalışması kapsamında ulaşılan sonuçlar Intel (R) Core i7 – 6700HQ CPU, 16.00 GB RAM, 64-bit işletim sistemine sahip bilgisayar ve Matlab 2018b kullanılarak elde edilmiştir.

Araştırma bulgularının toplandığı tablolarda LSTM parametreleri başlığı altında görülen input size parametresi LSTM yazılım mimarisinin dahili parametreleri ile ilgili değildir. Bu parametre kullanılan özellik matrisinin satır sayısına göre değişmektedir. Bu büyüklük, yapılan tez çalışmasında sınıflandırma aşamasından hemen önceki özellik çıkarma yöntemi MFCC olduğu için, mel kepstrum katsayılarının özelliklerine bağlıdır.

Mel Frekans Kepstrum Katsayıları (Bu özneliğin yalnız bir derecesi kullanılmıştır, 13 satırlık bir özellik matrisi oluşturur) ve optimum sonuçlara ulaşılabilmesi için Mel Frekans Kepstrum Katsayıları'nın birinci ve ikinci dereceden türevi özellik matrisine eklenerek denemeler tekrar edilmiştir. Değiştirilen MFCC özelliklerine karşılık gelen 'input size' bilgisi Çizelge 4.2 gösterilmiştir.

Çizelge 4.2. MFCC değerlerinin 'input size' karşılığı

Öznelik Tipi	İnput size
13	13
13 + 13 Δ	26
13 + 13 Δ + 13 $\Delta\Delta$	39

Yukarıdaki çizelgede Δ ile ifade edilmek istenen ilgili özneliğin türev değeridir. Yapılan çalışmada sadece öznelik tipi değiştirilmek suretiyle deney tekrarı yapılmamış olduğu için öznelik tipinin doğruluk oranına etkisini gösteren bir tablo bulunmamaktadır. Öznelik doğrudan LSTM yapısının giriş parametresi olan 'input size' parametresini değiştirmektedir.

Önerilen ilk algoritma kullanılarak 'Kişi Bağımlı ya da Kişi Bağımsız diye ayırmaksızın'deneylerinde (Bolat 2006; Rajseklar 2008; Dal 2015; Dal vd 2015; Bharti and Bansal 2015) referanslarında uygulandığı gibi MFCC ile özellik çıkarılması amaçlanmıştır. Çizelge 4.3'de görüldüğü gibi farklı kanallar tek başına ve kanal kombinasyonları olarak denenmiştir. LSTM parametreleri değiştirilerek doğruluk oranı arttırılmaya çalışılmıştır. Doğruluk oranının bir miktar daha arttırılması amacı ile (Hyvärinen *et al.* 2001; Bingham *et al.* 2003; Brock 2006; Azhar *et al.* 2012) çalışma ve yayınlarından esinlenilerek ICA ile özellik çıkarma işlemi yapılmıştır.

Çizelge 4.3'de kişi bağımlı ya da kişi bağımsız diye ayırmaksızın AASM standartlarına uygun olarak 5'li sınıflandırma için elde edilen deney sonuçları görülmektedir. Bu deney sonuçları elde edilirken belirlenen LSTM parametreleri ile birinci ve ikinci kanallar birlikte kullanılmış, sonrasında aynı LSTM parametreleri ile 13 kanalın tamamı kullanılmıştır. Elde edilen sonuç ilk iki kanal ile elde edilen sonuca göre düşük olmuştur. Bunun üzerine 13 kanalın tamamı kullanılarak yapılan deneylere devam edilmiş LSTM parametreleri değiştirilerek elde edilen doğruluk oranı iyileştirilmeye çalışılmıştır. Bu çalışmalar neticesinde en yüksek doğruluk oranı değeri olarak %83,05 bulunmuştur. Çizelge 4.3'de de görüldüğü gibi ilk dört deney için yalnızca MFCC özellik çıkarma yöntemi kullanılmıştır. Sonraki aşama olarak özellik çıkarma yöntemlerine ikincisi eklenmiş ve deney sonuçları tekrar edilmek istenmiştir. Fakat iki defa özellik çıkarma ve on üç kanalın tamamını kullanma donanım yetersizliği ile gerçekleştirilememiştir. Bu noktada ilk 6 kanal kullanılarak, ikili özellik çıkarma işlemi yapılmış ve %79,74 doğruluk oranına erişilmiştir. Altıncı deneyde sadece yedinci kanal kullanılmıştır ve son olarak ilk yedi kanal bir arada kullanılmıştır. Son üç deney yapılırken LSTM parametreleri ve özellik çıkarma yöntemi değiştirilmemiş sadece kanal özelliklerinin etkisi anlaşılmasına çalışılmıştır. Yapılan çalışmada ilk altı kanal ile elde edilen doğruluk oranı ilk yedi kanal ile elde edilen doğruluk oranından ve sadece yedinci kanal ile elde edilen doğruluk oranından daha yüksektir.

Çizelge 4.3. Kişi Bağımlı ya da Kişi bağımsız diye ayırmaksızın AASM standartlarına uygun olarak 5’li sınıflandırma için elde edilen deney sonuçları

Kullanılan Özellikler	LSTM mimarisinde kullanılan parametreler	Kullanılan Kanallar	Doğruluk Oranı
MFCC	mini batch size: 50 input size: 13 Number of hidden layers: 1 number of hidden units: 50 Maksimum epochs: 100	1. ve 2. kanal	74,30%
MFCC	mini batch size: 50 input size: 13 Number of hidden layers: 1 number of hidden units: 50 Maksimum epochs: 100	13 kanalın tamamı	70,92%
MFCC	mini batch size: 10 input size: 13 Number of hidden layers: 1 number of hidden units: 100 Maksimum epochs: 100	13 kanalın tamamı	79,10%
MFCC	mini batch size: 5 input size: 13 Number of hidden layers: 1 number of hidden units: 100 Maksimum epochs: 100	13 kanalın tamamı	83,05%
ICA MFCC	mini batch size: 10 input size: 13 Number of hidden layers: 1 number of hidden units: 100 Maksimum epochs: 100	1., 2., 3., 4., 5., 6. kanal	79,74%
ICA MFCC	mini batch size: 10 input size: 13 Number of hidden layers: 1 number of hidden units: 100 Maksimum epochs: 100	7. kanal	78,38%
ICA MFCC	mini batch size: 10 input size: 13 Number of hidden layers: 1 number of hidden units: 100 Maksimum epochs: 100	1., 2., 3., 4., 5., 6., 7. Kanallar	76,94%

Yapılan deney sonuçlarında ‘Kişi Bağımlı ya da Kişi Bağımsız diye ayırmaksızın uygulanan algoritma’ için AASM el kitabı standartlarına göre uyku evresi sınıflandırma probleminde en yüksek doğruluk oranı Çizelge 4.4’de görüldüğü gibidir.

Çizelge 4.4. Kişi Bağımlı ya da Kişi bağımsız diye ayırmaksızın AASM standartlarına uygun olarak 5’li sınıflandırma için elde edilen deney sonuçları içinde en yüksek doğruluk oranına sahip deney sonucu

Kullanılan Özellik	LSTM Parametreleri	Kullanılan Kanal	Doğruluk Oranı
MFCC	mini batch size: 5 input size: 13 Number of hidden layers: 1 number of hidden units: 100 Maksimum epochs: 100	13 kanalın tamamı	83,05%

Kişi Bağımlı Algoritmada da tıpkı ilk önerilen algoritmadaki gibi farklı kanal kombinasyonları, özellik kombinasyonları denenmiş, bu işlem yapılırken de LSTM parametreleri optimum bir değere getirilmeye çalışılmıştır. Kişi Bağımlı Algoritma kullanılarak 13 kanalın tümü ile çalışılmamıştır. 13 kanalın tümünden özellik çıkarılıp sınıflandırma yapıldığı durum için gereken işlem süresi yaklaşık 8 gündür (ilk önerilen algoritmadaki hali ile, bkz Çizelge 4.3). Gerek kişi bağımlı algoritma için gerekse ilk önerilen algoritma için 13 kanalın tümü kullanılarak ICA ve MFCC ile özellik çıkarılıp sınıflandırma yapılmaya çalışılmış olsa da 7. Günden sonra çalışılan bilgisayar hafıza hatası vererek programı çalıştırmayı durdurmuştur. Bu nedenle iki aşamalı özellik çıkarma yöntemleri ile 13 kanalın birlikte kullanıldığı bir deney sonucu tablolarda bulunmamaktadır. Örnek Bağımlı Algoritmada aynı LSTM parametrelerine sahip aynı kanallara ICA ve MFCC ile özellik çıkarma işlemi ve sadece MFCC ile özellik çıkarma işlemi denenmiştir. Bu şekilde MFCC ile özellik çıkarma işlemi öncesinde bağımsız bileşenlere ayırma işleminin doğruluk oranını olumlu yönde etkileyip etkilemediğine bakılmak istenmiştir. Fakat kanallar için bu durum farklı sonuçlanmıştır. Çizelge 4.5’de görüleceği üzere 1. kanal’dan ICA ve MFCC ile özellik çıkarma işlemi yapıldığında, sadece MFCC ile özellik çıkarma işlemi yapılmasına göre daha iyi doğruluk oranı elde edilmiş olmasına rağmen 5. Kanaldaki deney sonuçları incelendiğinde bunun tersi görülmektedir. Daha fazla deney yapıp bu bakımdan doğru sonuca erişilmesi gelecek çalışmalar fikrine katkı sağlamaktadır.

Çizelge 4.5. Kişi bağımlı algoritma kullanılarak AASM standartlarına uygun olarak 5'li sınıflandırma için deney sonuçları

Kullanılan Özellikler	LSTM mimarisinde kullanılan parametreler	Kullanılan Kanallar	Doğruluk Oranı
ICA, MFCC	mini batch size: 10 input size: 13 Number of hidden layers: 2 number of hidden units: 125, 100 Maksimum epochs: 300	1. kanal	92,45%
MFCC	mini batch size: 10 input size: 13 Number of hidden layers: 2 number of hidden units: 125, 100 Maksimum epochs: 300	1. kanal	88,45%
ICA, MFCC	mini batch size: 10 input size: 39 Number of hidden layers:2 number of hidden units: 125, 100 Maksimum epochs: 300	5. kanal	86,18%
MFCC	mini batch size: 10 input size: 39 Number of hidden layers:2 number of hidden units: 125, 100 Maksimum epochs: 300	5. kanal	90,11%
ICA, MFCC	mini batch size: 10 input size: 39 Number of hidden layers: 2 number of hidden units: 125, 100 Maksimum epochs: 300	7. kanal	91,11%
ICA, MFCC	mini batch size: 10 input size: 39 Number of hidden layers: 2 number of hidden units: 125, 100 Maksimum epochs: 300	1., 2., 3., 4., 5., 6., 7. kanallar	92,37%

Kişi Bağımlı Algoritma için deney sonuçları incelendiğinde en yüksek doğruluk oranına Çizelge 4.6'da görülen parametrelerde erişilmiştir.

Çizelge 4.6. Kişi bağımlı algoritma kullanılarak AASM standartlarına göre 5’li sınıflandırma için en yüksek doğruluk oranını veren deneyin 10 kat çapraz doğrulama ile elde edilen sonucu

Kullanılan Algoritma	Kullanılan Özellikler	LSTM Mimarisinde kullanılan parametreler	Kullanılan Kanallar	10 Kat Çapraz Doğrulama Oranı
Örnek Bağımlı Algoritma	ICA, MFCC	Mini Batch Size: 10 Input Size: 13 Number of Hidden Layers: 2 Nuber of Hidden Units: 125, 100 Maximum Epochs: 300	1. Kanal	93,96%

Çizelge 4.7. Kişi bağımlı algoritma kullanılarak AASM standartlarına göre 5’li sınıflandırma için en yüksek doğruluk oranını veren deneyin 10 kat çapraz doğrulama ile elde edilen sonucunun karmaşıklık matrisi

	NonRem1	NonRem2	NonRem3	Rem	Wake
NonRem1	853,2	119,8	1	1	12,1
NonRem2	2	983,1	1,4	0	0,6
NonRem3	0,2	34,4	889,4	1,2	1
Rem	24	71,8	10,2	842,4	1,2
Wake	4,2	4,9	0,8	0,2	977

Kişiden Bağımsız Algoritma için de diğer iki algortmada kullanılan yöntemler denenmiştir. Fakat her bir deney için gerekli işlem süresinin uzun oluşundan ve zaman yetersizliğinden ötürü kişiden bağımsız algoritma için ICA ve MFCC ile özellik çıkarma yöntemi denenememiştir. Bu şekilde karşılaştırmalı bir çalışma yapılması gelecekte yapılacak çalışmalar dahilinde değerlendirilecektir. Kişiden Bağımsız Algoritma ile yapılan deneyler değerlendirildiğinde en yüksek sonuca Çizelge 4.9’daki parametrelerle erişilmiştir. Kişiden Bağımsız Algoritma ile çalışılırken özellikler değiştirilerek sonuç alınmaya çalışılmamıştır. Sadece LSTM parametreleri ve özellik matrisinin büyüklüğünde değişiklik yapılmıştır. Özellik matrisinin büyüklüğündeki değişiklik Çizelge 4.2’de gösterildiği gibi yapılmıştır. Bu çizelgeye göre ‘input size’ parametresi 13 olduğunda Mel Frekansı Kepstrum Katsayılarının yalnızca birinci değeri kullanılmıştır. ‘input size’ parametresi 26 olduğunda Mel Frekansı Kepstrum Katsayılarının birinci

değeri ile oluşturulan özellik matrisine katsayıların birinci dereceden türevi eklenmiş demektir. 'input size' parametresi 39 olduğunda Mel Frekanslı Kepstrum Katsayılarının birinci değeri ile oluşturulan özellik matrisine katsayıların birinci dereceden türevi ve ikinci dereceden türevi eklenmiş demektir.

Çizelge 4.8. Kişiden bağımsız algoritma kullanılarak AASM standartlarına göre 5'li sınıflandırma için deney sonuçları

Kullanılan Özellikler	LSTM mimarisinde kullanılan parametreler	Kullanılan Kanallar	Doğruluk Oranı
MFCC	mini batch size: 10 input size: 13 Number of hidden layers: 1 number of hidden units: 100 Maksimum epochs: 300	7. kanal	79,41%
MFCC	mini batch size: 10 input size: 26 Number of hidden layers: 2 number of hidden units: 150, 125 Maksimum epochs: 300	7. kanal	86,89%
MFCC	mini batch size: 10 input size: 13 Number of hidden layers: 2 number of hidden units: 125, 100 Maksimum epochs: 300	1. kanal	86,05%
MFCC	mini batch size: 10 input size: 39 Number of hidden layers: 2 number of hidden units: 125, 100 Maksimum epochs: 300	5. kanal	83,21%

Kişiden Bağımsız Algoritma ile elde edilen en yüksek doğruluk oranına 7. Kanal kullanılarak erişilmiştir. Bu kanal EOG bilgisi içermektedir ve genel olarak diğer algoritmalarda ve özellik çıkarma yöntemlerinin kullanıldığı deneylerde de doğruluk oranını yükselttiği görülmektedir. Kullanılan özellik çıkarma yöntemi MFCC olarak belirlenmiş olup Mel Frekanslı Kepstrum Katsayılarının yalnızca birinci değerine bu değer türevi de eklenerek $(13 + 13\Delta)$ %86,89 değerindeki doğruluk oranına erişilmiştir.

Çizelge 4.9. Kişiden bağımsız algoritma kullanılarak AASM standartlarına göre 5'li sınıflandırma için en yüksek doğruluk oranı

Kullanılan Özellikler	LSTM mimarisinde kullanılan parametreler	Kullanılan Kanallar	Doğruluk Oranı
MFCC	mini batch size: 10 input size: 26 Number of hidden layers:2 number of hidden units: 150, 125 Maksimum epochs: 300	7. kanal	86,89%

5. TARTIŞMA ve SONUÇ

Physionet Challenge 2018 ‘You snooze you win’ veri seti kullanılarak yapılmış uyku evresi sınıflandırma çalışmaları incelendiğinde bulunan değerler Çizelge 5.1 ve 5.2’de görülmektedir. Çizelge 5.1’de bahsedilen çalışmanın konusu tek kanallı elektrokardiyogram bilgisi ile zaman frekans düzleminde derin öğrenme kullanılarak uyku evresi sınıflandırma (Deep Learning in the cross time frequency domain for sleep stage classification from a single lead electrocardiogram)’dır. Bu yayında polisomnografi veri setindeki kanallardan yalnız biri (ECG) kanalı kullanılmıştır (Qiao Li *et al.* 2018). Kullanılan algoritma kişiye bağımlı olarak belirlenmiştir.

Çizelge 5.1. Physionet Challenge 2018 ‘You snooze you win’ veri seti kullanılarak yapılmış uyku evresi sınıflandırma çalışmaları (Qiao Li *et al.* 2018)

Sınıflandırılan Uyku Evreleri	10 kat çapraz Doğrulama Sonuçları	
	Ortalama Doğruluk Oranı (%)	Toplam Doğruluk Oranı (%)
4 Sınıf	65,6 ± 1,3	65,6
3 Sınıf (a)	76,5 ± 1,0	76,5
3 Sınıf (b)	68,2 ± 1,0	68,2
2 Sınıf	79,4 ± 1,0	79,4

İlgili çalışmada Sınıflandırılan uyku evreleri açıklanacak olursa;

4 Sınıf: Uyanık olma durumu, Uykunun Rem aşaması, Hafif Nonrem Uykusu (Rem olmayan uykunun hafif hali), Ağır Nonrem Uykusu (Rem olmayan uykunun ağır hali) birer uyku evresi olarak değerlendirilmiş böylelikle uyku 4 sınıfa ayrılmıştır (Qiao Li *et al.* 2018).

3 Sınıf (a): Uyanık olma hali, Rem uykusu, Nonrem uykusu (Rem olmayan uyku aşamalarının tümü) birer uyku evresi olarak değerlendirilmiş böylelikle uyku 3 sınıfa ayrılmıştır (Qiao Li *et al.* 2018).

3 Sınıf (b): Uyanık Olma Durumu ile Uykunun Rem aşaması tek bir uyku evresi sayılmıştır. Hafif NonRem Uykusu ve Ağır NonRem Uykusu da ayrı ayrı birer aşama sayılarak uyku 3 evreye sınıflandırılmıştır (Qiao Li *et al.* 2018).

2 Sınıf: Uyanık olma hali ve Rem uykusu bir tek aşama, NonRem uykusu (Rem olmayan uyku aşamalarının tümü) ayrı bir aşama sayılmış ve böylelikle uyku 2 evreye ayrılmıştır (Qiao Li *et al.* 2018).

İlgili çalışmada ECG sinyali kullanılarak elde edilen spektrogram görüntüleri ile evrişimsel sinir ağları (CNN) kullanılarak sınıflandırma yapılmıştır. Yapılan çalışma Physionet Challenge 2018 ‘You snooze you win’ veri seti ile uyku sınıflandırması üzerine yapılmış iki çalışmadan biridir. Qiao Li ve arkadaşlarının 2018 yılında yaptığı çalışma ile kıyaslama yapılabilmesi açısından bu çalışmada 2 sınıf olarak nitelendirilen sonuçlar tez çalışmasındaki metotla tekrar edilmiş ve 10 kat çaprazlama sonucuna göre aşağıdaki doğruluk oranı ve karmaşıklık matrisi elde edilmiştir.

Çizelge 5.2. Qiao Li ve arkadaşlarının 2018 yılında yayınladığı çalışma ile kıyaslama için tez çalışmasından elde edilen 2 sınıflı sınıflandırma sonucu

Sınıflandırılan Uyku Evreleri	10 kat çaprazlama için Toplam Doğruluk Oranı (%)
2 Sınıf	91.53

Qiao Li ve arkadaşlarının 2018 yılında yayınladığı çalışma ile kıyaslama için tez çalışmasından elde edilen 2 sınıflı sınıflandırma sonucunun karmaşıklık matrisi aşağıdaki çizelgede görülmektedir.

Çizelge 5.3. Qiao Li ve arkadaşlarının 2018 yılında yayınladığı çalışma ile kıyaslama için tez çalışmasından elde edilen 2 sınıflı sınıflandırma sonucunun karmaşıklık matrisi

	Wake+Rem	NonRem
Wake+Rem	982,77	4,44
NonRem	162,77	825,44

Physionet Challenge 2018 ‘You snooze you win’ veri seti ile yapılan bir diğer uyku evresi sınıflandırma çalışması Howe – Patterson ve arkadaşları tarafından Cardiology in Computing platformunda 2018 yılında yapılan ‘apne kaynaklı olmayan uyarılmanın otomatik teşhisi’ konulu yarışma için yapılmıştır (Howe - Patterson *et al.* 2018). Çalışmada Qiao Li ve arkadaşlarının 2018 yılında yaptığı çalışmanın (Qiao Li *et al.* 2018) aksine, sadece ECG kanalı 13 kanaldan çıkarılmış, 12 sinyal kanalı kullanılarak sonuca ulaşılmıştır. Bu çalışmada 2018 Physionet yarışma veritabanındaki 12 polisomnografi verisi kullanılarak (ECG çıkarılmıştır) uyarılma anlarının tespiti için Çoklu Evrimsel Sinir Ağları ile birlikte LSTM bloklarını içeren Yoğun Evrimsel Sinir Ağlarının değiştirilmiş bir versiyonu kullanılmıştır. Kişi Bağımlı Algoritma tercih edilmiştir, algoritma uygulanırken 794 kişinin polisomnografi sinyali eğitim veri setine dahil edilmiş, 100 kişinin polisomnografi sinyali doğrulama veri seti olarak kullanılmış, 100 kişinin polisomnografi verisi de test veri seti olarak kullanılmıştır. Model iki performans ölçütüne göre değerlendirilmiştir, bunlar AUPRC ve AUROC eğrilerinin altında kalan alan hesaplanarak elde edilmiştir. Değerlendirme aşamasında ayrıca 4 kat çapraz doğrulama uygulanmıştır. Uyku evresi sınıflandırma için elde edilen sonuçlar Çizelge 5.4’de görülmektedir. (Yalnızca Eğitim verisi kullanılarak elde edilen sonuçlar paylaşılmıştır).

Çizelge 5.4. Physionet Challenge 2018 ‘You snooze you win’ veri seti kullanılarak yapılmış uyku evresi sınıflandırma çalışmaları (Howe - Patterson *et al.* 2018)

2’li sınıflandırma (uyuyor/uyanık)	AUROC	0,953
2’li sınıflandırma (uyuyor/uyanık)	AUPRC	0,82

Howe – Patterson ve arkadaşlarının 2018 yılında yapmış olduğu bu çalışmadaki gibi 2’li sınıflandırma (uyuyor/uyanık) ilgili tez çalışmasında da gerçekleştirilmiştir. Yapılan deney sonuçlarının 10 kat çapraz doğrulama kullanılarak ortalaması alınmıştır. Doğruluk oranı, karmaşıklık matrisi ve AUROC sonuçları sırası ile Çizelge 5.5, Çizelge 5.6 ve Çizelge 5.7’de görülmektedir.

Çizelge 5.5. Howe - Patterson ve arkadaşlarının 2018 yılında yayınladığı çalışmadaki ikili sınıflandırmanın ilgili tezde uygulanmış hali

2 Sınıf (Sleep/Wake)	10 kat çapraz doğrulama sonucu: %97.8702 (kişi bağımlı algoritma)
-------------------------	--

Çizelge 5.6. Howe - Patterson ve arkadaşlarının 2018 yılında yayınladığı çalışma ile kıyaslama için tez çalışmasından elde edilen 2 sınıflı sınıflandırma sonucunun karmaşıklık matrisi

	Wake	Sleep
Wake	988	1,75
Sleep	40,37	948,37

Çizelge 5.7. Howe - Patterson ve arkadaşlarının 2018 yılında yayınladığı çalışma ile kıyaslama için tez çalışmasından elde edilen 2 sınıflı sınıflandırma sonucunun AUROC sonucu

2 Sınıf (Sleep/Wake)	10 kat çapraz doğrulama AUROC sonucu: 0.9746 (kişi bağımlı algoritma)
-------------------------	--

AASM standartlarına göre yakın zamanda yapılan uyku evresi sınıflandırma çalışmalarından derlenmiş tablo Çizelge 5.3’de görülmektedir. Bu çalışmalara bakılarak yapılan tez çalışmasından elde edilen doğruluk oranları değerlendirildiğinde tez çalışmasının sonuçlarının kabul edilebilir derecede iyi olduğu görülmektedir.

Çizelge 5.8. Polisomnografi sinyalleri kullanılarak elde edilmiş literatürden derlenmiş, 5 sınıflı sınıflandırma sonuçları (Gharbali 2018)

Çalışmayı Yapan kişi ya da kişiler	Kullanılan Sınıflandırma Yöntemi	Sınıflandırılan Uyku Evreleri	Bulunan Doğruluk Oranı	Kullanılan Sinyal
Ebrahimi et al 2008	İleri Beslemeli Sinir Ağları (Geri Yayılım Algoritması ile birlikte)	Wake, NonRem1, NonRem2, NonRem3, Rem	93%	EEG
Özşen 2013	Yapay Sinir Ağları	Wake, NonRem1, NonRem2, NonRem3, Rem	90,93%	EEG EMG EOG
Hsu et al 2013	Elman Tekrarlamalı Yapay Sinir Ağı	Wake, NonRem1, NonRem2, NonRem3, Rem	87,20%	EEG
Şen vd 2014	Rastgele Orman Sınıflandırıcı	Wake, NonRem1, NonRem2, NonRem3, Rem	98,02%	EEG
Jinwoo Kim et al 2014	Destek Vektör Makineleri	Wake, NonRem1, NonRem2, NonRem3, Rem	86%	EEG
Virkkala et al 2007	Karar Ağaçları Sınıflandırıcı	Wake, NonRem1, NonRem2, NonRem3, Rem	72,50%	EOG
Alvarez-Esteves et al 2013	Bulanık Mantık	Wake, NonRem1, NonRem2, NonRem3, Rem	90%	EEG, EOG EMG
Fraïwan et al 2012	Rastgele Orman Sınıflandırıcı	Wake, NonRem1, NonRem2, NonRem3, Rem	83%	EEG
Liang et al 2012	Karar Ağaçları Sınıflandırıcı	Wake, NonRem1, NonRem2, NonRem3, Rem	86,68%	EEG EOG EMG
Šušmáková et al 2008	Diskriminant Analizi	Wake, NonRem1, NonRem2, NonRem3, Rem	77%	EEG EOG EMG ECG
Chapotot et al 2009	İleri Beslemeli Sinir Ağları (Geri Yayılım Algoritması ile birlikte)	Wake, NonRem1, NonRem2, NonRem3, Rem, Hareket anı	Wake: %34 NonRem1: %43 NonRem2: %51 NonRem3: %83 Rem: %82 Hareket Anı: %13	EEG EMG
Zoubek et al 2007	İleri Beslemeli Sinir Ağları (Geri Yayılım Algoritması ile birlikte)	Wake, NonRem1, NonRem2, NonRem3, Rem	Yalnız EEG ile: %71 EEG,EOG ve EMG ile: %80	EEG EMG EOG

5.1. Çalışmalar Sonucu Bulunan Doğruluk Oranını Etkileyen Faktörler

Bu tez kapsamında veri tabanındaki kişilere ait polisomnografi sinyal dizisi kullanılarak uyku evreleri sınıflandırması tahmini yapılmıştır. Yazılmış olan kodların çalıştırılması neticesinde bulunan doğruluk oranını etkileyen faktörler:

- 1) Özellik Seçimi
- 2) Kanal Seçimi
- 3) Seçilen algoritma (kişi bağımlı ya da kişi bağımsız olması)
- 4) Kullanılan LSTM mimarisi parametreleri

Son aşama olarak bu maddelerdeki parametrelerin Doğruluk Oranlarını nasıl etkilediklerini anlayabilmek için yapılan denemeler yorumlanmalıdır.

Özelliklerin içinde en iyi sonuçları Kişi Bağımlı Algoritma için, fastICA algoritması ile bağımsız bileşenlerine ayrılmış tek boyutlu sinyal dizisinden MFCC algoritması ile mel kepstrum katsayıları elde edilerek erişilmiştir. Kullanılmış olan kanal yalnızca 1. Kanaldır. Bu iki aşamalı özellik çıkarma işlemi, modelin eğitim süresini bir hayli uzatmakla birlikte en iyi sonucu vermektedir. Kullanılan LSTM parametreleri Araştırma Bulguları bölümünde görülmekle birlikte bu başlık altında da açıklanmıştır.

Kanalların içinde en iyi sonuçlar ilk 7 kanalın farklı kombinasyonları ile ve 13 kanalın tümünün kullanıldığı durumda alınmaktadır. Bu bakımdan değerlendirildiğinde EEG ve EOG bilgisi uyku evreleri sınıflandırma işleminde tezde kullanılan özellikler için diğer kanallardan daha belirleyici olmuştur.

Kullanılan LSTM mimarisi parametreleri maddeler halinde yazılarak doğruluk oranına olan etkilerine bakılacak olursa;

Mini batch size: Matlab’de hazırlanmış temel LSTM mimarisinin ilk parametresidir. Bu parametrenin LSTM mimarisine etkisini anlayabilmek için önce ‘batch’ kavramını anlamak gereklidir. ‘Batch size’, yani ‘grup büyüklüğü’, dahili model parametrelerini güncellemeden önce çalışılacak örnek sayısını tanımlayan bir hiperparametredir. Bu bir örnek üzerinden açıklanmak istenirse; bir grup (batch) bir veya daha fazla örnek üzerinde yinelenen ve tahminlerde bulunulan bir döngü olarak değerlendirilebilir. Gruba uygulanan iterasyon işlemleri tamamlandığında, tahminler beklenen çıkış değişkenleriyle karşılaştırılır ve buna göre bir hata hesaplanır. Bu hatayı, güncelleme algoritması modeli geliştirmek için kullanır. Bir eğitim veri kümesi bir veya daha fazla gruba ayrılabilir. Tüm eğitim örnekleri yalnızca bir grup oluşturmak için kullanıldığında, öğrenme algoritmasına toplu gradyan inişi (batch gradient descent) denir. Grup sadece bir örnekten ibaret olduğunda, öğrenme algoritmasına stokastik gradyan inişi (stochastic gradient descent) denir. Güncelleme için kullanılan grup birden fazla örnek içerdiğinde ve eğitim veri kümesinin boyutundan küçük olduğunda, öğrenme algoritmasına ‘mini batch gradient descent’ adı verilir (Anonymous 2019). Bu değer çok küçük seçilirse hatası hesaplanıp güncellemede kullanılacak grup çok az örnek içeriyor demektir. Bu, doğruluk oranını artırma yönünde olumlu olsa da işlem süresini çok uzatır. Çok büyük olması da LSTM mimarisinin kendini çok geniş aralıklarla güncellemesine işaret eder ki bu da doğruluk oranına olumsuz yansiyabilir. Bu bakımdan denemelerin sonucuna göre bu değer 10 seçildiğinde en yüksek doğruluk oranına ulaşılırken işlem süresinin de kabul edilebilir bir ölçekte olduğu görülmüştür.

LSTM mimarisinin 2. Parametresi ‘input size’ dır. Bu parametre aslında çıkarılan özellik matrisinin satır sayısının yazıldığı kısımdır. Bu parametre doğruluk oranını doğrudan etkilemese de seçilen özellik aracılığı ile etkilemektedir. Çıkarılan özellik sayısı arttıkça belli bir noktaya kadar doğruluk oranı da artış gösterir, belli bir noktadan sonra ise bu artış devam etmez. Özellik matrisinin çokça büyümesi işlemi karmaşılaştırır ve işlem süresini uzatır.

Seçilen bir diğer parametre ise ‘maxEpochs’ parametresidir. Bu parametreyi anlayabilmek için kısaca Epoch kavramının açıklanması gerekmektedir. Epoch sayısı, öğrenme

algoritmasının tüm eğitim veri kümesi boyunca çalışacağı sayıyı tanımlayan bir hiperparametredir. Başka bir deyişle Yapay Sinir Ağı boyunca, tüm veri seti ileri yönlü ve geri yönlü olarak hareketini tamamladığında 1 Epoch tamamlanmış olur. Epoch sayısını 1 seçmek sureti ile tüm veri setini yalnızca bir kere tüm sinir ağından geçirmek ise yanlış bir yaklaşım olacaktır. Çünkü yalnızca tek bir geçişle ağırlıkları güncellemek eksik öğrenme'ye (underfitting'e) neden olur. Epoch Sayısının çok yüksek olması ise hem işlem süresini uzatır hem de 'aşırı öğrenme'ye (overfitting'e) neden olabilmektedir. Bu açıklamadan da açıkça anlaşılıyor ki Epoch sayısının belli bir seviyeye kadar yüksek tutulması doğruluk oranını olumlu etkiler, diğer yandan olması gerekenden fazla olduğu durumlarda da işlem yükünü artırır ve işlem süresini uzatır. Tez süresince yapılan çalışmalarda 'maxEpoch'parametresi 300 olarak seçildiğinde optimum değerlere ulaşılmaktadır.

'Number of hidden units'parametresi ise bir sinir ağının öğrenme kapasitesinin doğrudan bir temsilidir. 'Number of hidden units'parametresini yüksek bir değerde tutmak, tüm eğitim setini mükemmel bir şekilde öğrenmeyi muhtemel kıldığı gibi daha uzun işlem süresi ve overfitting olma ihtimali de oluşturur.

'Number of hidden units'parametresi LSTM mimarisinde kullanılacak katman sayısına göre belirlenir. Katman sayısı 1'den 2'ye çıkarıldığında, 1. Katmanda kullanılacak 'Number of hidden units'parametresi ile 2. Katmanda kullanılacak olan 'Number of hidden units'parametresi ayrı ayrı belirlenmelidir. Her ikisi için de eşit sayıda 'Number of hidden units'değeri verilebileceği gibi farklı değerler de verilebilmektedir. Diğer taraftan bir parametre girişi gerektirmemekle birlikte kod satırına eklenecek birkaç satır ile yukarıda bahsedildiği gibi katman sayısı artırılabilir ve bu da doğruluk oranı değerini olumlu yönde etkiler.

5.2. Sonuç

Bu tez çalışması kapsamında Physionet Cinc 2018 'You Snooze You Win' veri setinin eğitim için ayrılan kısmındaki 994 kişinin polisomnografi sinyalleri ve bu sinyaller için

bir uzman tarafından oluşturulmuş etiket dosyası kullanılmıştır. Yapılan çalışmada sinyale uygulanan çerçeveleme yönteminde kullanılan çerçeve uzunluğu hiç değiştirilmemiştir ve 30 sn olarak belirlenmiştir. Kaydırma miktarı ise çerçeveleme miktarı ile aynı belirlenmiştir ve testler süresince hiç değiştirilmemiştir. 994 kişinin sinyal ve etiketleri 3 temel parçaya ayrılmıştır. Bu temel veri kümelerine Eğitim veri kümesi, Doğrulama veri kümesi, Test veri kümesi denilmektedir. Eğitim veri kümesi ve etiketleri ile model eğitilmiş elde edilen model kullanılarak Test veri setindeki sinyal dizisine ait etiketler tahmin edilmeye çalışılmıştır. Bu tahmin işlemi için tekrarlamalı yapay sinir ağları kategorisinde yer alan LSTM adlı yazılım mimarisi kullanılmıştır. Tahmin işlemindeki doğruluk oranı değerini arttırmak için farklı özellik çıkarma yöntemleri denenmiştir. Bu yöntemler yalnız MFCC, önce ICA sonra MFCC yöntemlerinin arka arkaya kullanılması şeklinde sıralanmaktadır.

Kişi Bağımlı Algoritma için optimum sonuç; özellik çıkarma işleminde ICA ve MFCC'nin ard arda kullanılması sonucu elde edilmiştir. Kullanılan sinyal ise yalnız 1. Kanaldan elde edilen sinyaldir. 1. Kanal EEG sinyali bilgisi içermektedir. Bu değerleri etkileyen diğer etken ise LSTM yazılım mimarisi kullanılırken belirlenen parametreler olmaktadır. Bu parametreler Çizelge 4.6'da LSTM parametreleri başlığı altında yazılmış ve açıklaması 5.1 başlığı altında detaylı olarak yapılmıştır. Kısaca kullanılan LSTM parametrelerine değinilecek olursa doğruluk oranını en etkili şekilde artıran parametrenin LSTM mimarisindeki katman sayısının arttırılması olduğu açıktır. Katman sayısını arttırmak için 'number of hidden layers'2 olarak belirlenmiş, her bir katman için 'number of hidden units'değerleri seçilmiştir. Yine bu doğruluk oranına erişilmesi esnasında 'mini batch size'parametresi 10 olarak seçilmiş, 'maxEpochs'parametresi de 300 olarak belirlenmiştir. 'input size'parametresi daha önceden de belirtildiği gibi doğrudan özellik matrisinin satır sayısına bağlıdır ve özellik çıkarma aşamasının son adımı olarak MFCC ile özellik çıkarma işlemi kullanıldığı için 13 olarak seçilmiştir. Özellik matrisinin büyüklüğü ile LSTM yazılım mimarisinin 'input size'parametresi arasındaki ilişki çizelge 4.2'den incelenebilir.

Kişiden Bağımsız Algoritma için optimum sonuç; özellik çıkarma işleminde MFCC'nin kullanılması sonucu elde edilmiştir. Bu algoritma için ICA ve MFCC ard arda kullanılarak özellik çıkarma işlemi denenmemiştir. Kullanılan sinyal ise yalnız 7. Kanaldan elde edilen sinyaldir. 7. Kanal EOG sinyal bilgisi içermektedir. Doğruluk oranı değerini etkileyen diğer etken ise LSTM yazılım mimarisi kullanılırken belirlenen parametreler olmaktadır. Bu parametreler Tablo 4.8'de LSTM parametreleri başlığı altında yazılmış ve açıklaması 5.1 başlığı altında detaylı olarak yapılmıştır. Kısaca kullanılan LSTM parametrelerinden bahsedilecek olursa kişiden bağımsız algorithmada da tıpkı kişi bağımlı algorithmada olduğu gibi en yüksek doğruluk oranına birden çok gizli katman kullanılarak erişilmiştir. Optimum doğruluk oranına erişilirken 'number of hidden layers' parametresi 2 olarak belirlenmiş ve her bir gizli katman için belirlenen 'number of hidden units' değerleri sırası ile 150 ve 125 olarak belirlenmiştir. Kullanılan 'mini batch size' parametresi 10 olarak belirlenmiştir. 'max epoch' parametresi 300 olarak seçilmiştir. Özellik matrisinin satır sayısına göre belirlenmesi gereken 'input size' parametresi ise 26 olarak seçilmiştir. Özellik matrisinin büyüklüğü ile LSTM yazılım mimarisinin 'input size' parametresi arasındaki ilişki Çizelge 4.2'de açıklanmıştır.

KAYNAKÇA

- Abdullayeva, G., 2019. Application and Evaluation of LSTM Architectures for Energy Time Series Forecasting, Master Thesis. University of Tartu. Institute of Computer Science, Tartu.
- Aboalayon, K.A.I., Faezipour M., 2014. Multi-Class SVM Based on Sleep Stage Identification Using EEG Signal. Health Innovations and Point-of-Care Technologies Conference, October 8-10, 181-184.
- Adorf, M., 1989. Connectionism and neural networks. In Knowledge-Based Systems in Astronomy, Springer, 213-245.
- Ahmed, O.J., Cash S.S., 2013. Finding synchrony in the desynchronized EEG: the history and interpretation of gamma rhythms. *Frontiers in Integrative Neuroscience*, vol. 7, 58.
- Albulbul, A., 2013. Analyzing the effect of an externally applied force on the electrode-skin impedance, Master of Applied Science, Carleton University, Canada.
- Alickovic, E., Subasi A., Haziran 2018. Ensemble SVM Method for Automatic Sleep Stage Classification. *IEEE Trans Instrum Meas.*, 67(6), 1258-65.
- Alickovic, E., Subasi A, Feb. 2015. Effect of multiscale PCA denoising in ECG beat classification for diagnosis of cardiovascular diseases, *Circuits and Systems Signal Process.*, 34(2), 513–533.
- Alkan, M., 2005. Warship Sound Signature Recognition Using Mel Frequency Cepstral Coefficients. Master Thesis, Turkish Naval Academy Naval Science and Engineering Institute Department Of Computer Engineering, İstanbul.
- Altın, C., 2017. Dört Rotorlu İnsansız Hava Aracının Görsel Geri Beslemeli Birleştirilmiş Eeg Ve Emg Biyolojik Sinyalleri İle Kontrolü. Doktora Tezi, Bozok Üniversitesi Fen Bilimleri Enstitüsü Mekatronik Mühendisliği, Yozgat.
- Álvarez-Estévez, D., Fernández-Pastoriza J.M., Hernández-Pereira E., Moret-Bonillo V., 2013. A method for the automatic analysis of the sleep macrostructure in continuum, *Expert Syst. Appl.*, vol. 40, no. 5, 1796–1803.
- Anonymous, 2018. <https://commons.wikimedia.org/w/index.php?curid=31447187>(05.11.2018).
- Anonymous, 2018. <https://en.wikipedia.org/wiki/Electroencephalography> (03.08.2018).
- Anonymous, 2018. https://en.wikipedia.org/wiki/Mel-frequency_cepstrum (12.05.2018).
- Anonymous, 2019. <https://machinelearningmastery.com/use-different-batch-sizes-training-predicting-python-keras/> (22.05.2019).
- Anonymous, 2018. <https://physionet.org/physiobank/database/challenge/2018/> (11.05.2018).
- Anonymous, 2018. https://tr.wikipedia.org/wiki/Uyku_apnesi (25.06.2018).
- Anonymous, 2019. <https://ch.mathworks.com/help/stats/cvpartition.html> (06.07.2019).
- Anonymous, 2019. The AASM Manual for the Scoring of Sleep and Associated Events, <https://static1.squarespace.com/static/5459a5d0e4b09a5cc2e5497a/t/54f8d3dbe4b03ea829c7ef53/1425593307109/Sleep+Stage+Scoring+c3+version.pdf>, (15.06.2019).

- Arutha, N., Arul V.H., 2017. A Review on Noises in EMG Signal and its removal. *International Journal of Scientific and Research Publication*, Volume 7, Issue 5, s23-27.
- Azhar, M., Ahmed I., Iqbal S.T., Jahangir M., Rehman R., Shah N.A., 2017. Feature Extraction Using Independent Component Analysis Method from Non-Invasive Recordings of Electroencephalography (EEG) Brain Signals. *Journal of Basic and Applied Sciences*, 13(0), 259-267.
- Bajaj, V., Pachori R.B., 2013. Automatic classification of sleep stages based on the time-frequency image of EEG signals. *Comput Meth Programs Biomed.*, Aralık 2013, 112(3), 320-8.
- Bakshi, B.R., 1998. Multiscale PCA with application to multivariate statistical process monitoring. *AIChE Journal*, Temmuz 1998, 44(7), 1596-610.
- Berry, R.B., Budhiraja R., Gottlieb D.J., Gozal D., Iber C., Kapur V.K., 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 Med.*, 8(5), 597-619.
- Bharti, R., Bansal P., 2015. Real Time Speaker Recognition System using MFCC and Vector Quantization Technique. *International Journal of Computer Applications*, Volume 117, 25-31.
- Bingham, E., 2003. *Advances In Independent Component Analysis With Applications To Data Mining*. Doctoral Thesis, Helsinki University Technology Dissertations in Computer and Information Science, Espoo.
- Bolat, B., 2006. *Enstrüman Seslerinin Tanınması ve Sınıflandırılması*, Doktora tezi. YTÜ Elektronik ve Haberleşme Anabilim Dalı, İstanbul.
- Brock, J., 2006. *Acoustic classification using independent component analysis*. Master Thesis, Rochester Institute of Technology, New York.
- Brooks, M., 1997. *Voicebox: Speech Processing Toolbox for Matlab*, Imperial College, London.
- Ceylan, R., 2018. The Affect of Feature Extraction Based on Dictionary Learning on ECG Signal Classification, *International Journal of Intelligent Systems and Applications in Engineering*, 6(1), 40-46.
- Chapotot, F. and Becq G., 2009. Automated Sleep-Wake Staging Combining Robust Feature Extraction, Artificial Neural Network Classification, and Flexible Decision Rules, *Int. J. Adapt. Control Signal Process.*, vol. 24, no. 5, 409-423.
- Childers, D.G., Skinner D.P., Kemerait R.C., 1977. The cepstrum: A guide to processing, *Proceedings of the IEEE*, 65(10), 1428-43.
- Colten, H.R., Altevogt B.M., 2006. *Sleep Disorder and Sleep Deprivation: An Unmet Public Health Problem*. National Academies Press, Washington DC. S(33-39).
- Constable, P.A., Bach M., Frishman L.J., Jeffrey B.G., Robson A.G., 2017. *International Society for Clinical Electrophysiology of Vision. ISCEV Standard for clinical electro-oculography (2017 update)*. *Doc. Ophthalmol.*, 134(1), 1-9.
- Cysarz, D., Bettermann H., Lange S., Geue D., Leeuwen P.A., 2004. Quantitative comparison of different methods to detect cardiorespiratory coordination during night-time sleep. *Biomedical Engineering Online*, 3(1):44-44.
- Çentik, G., 2013. *Makine Öğrenmesi Yöntemlerinin Polisomnografik Verilere Uygulanması*, T.C. Trakya Üniversitesi Fen Bilimleri Enstitüsü Doktora Tezi, 89.

- Dal, F., 2015. Kalp Sesleri Kullanarak Kişi Tanıma, Yüksek Lisans Tezi, Atatürk Üniversitesi, 36, Erzurum.
- Dal, F., Ozbek, I., ve Coşgun, S., 2015. Kalp Sesi ile Cinsiyet Tanıma. Signal Processing and Communications Applications Conference (SIU), İnönü Üniversitesi.
- Danker-Hopfe, H., Anderer P., Zeitlhofer J, Boeck M., Dorn H., Gruber G.,2009. Interrater reliability for sleep scoring according to the Rechtschaffen & Kales and the new AASM standard. *Journal of Sleep Research*, 18(1):74-84.
- Danker-Hopfe, H., Kunz D., Gruber G., Kloesch G., Lorenzo J.L., Himanen S.L., Kemp B., Penzel T., Kloschke G., Dorn H., Schlogl A., Trenker E., and Dorffner G., 2004. Interrater reliability between scorers from eight European sleep laboratories in subjects with different sleep disorders. *Journal of Sleep Research*, 13(1):63–69.
- Deller, J.R., Proakis J. G., Hansen J.H., 1993. *Discrete Time Processing of Speech Signals*. Prentice Hall PTR, 936, New Jersey.
- Do, B.N., 2015. *Neural Networks for Automatic Speaker, Language and Sex Identification*, Master Thesis. Prague.
- Duda, R.O., Hart P.E, Stork D.G.,2001. *Pattern classification*. John Wiley & Sons press, 2nd edition, 738, USA.
- Ebrahimi, F., Mikaeili M., Estrada E., Nazeran H., 2008. Automatic Sleep Stage Classification Based on EEG Signals by Using Neural Networks and Wavelet Packet Coefficients, *Conf. Proc. IEEE Eng. Med. Biol. Soc.*, vol. 2008, 1151–1154.
- Eskidere, Ö., 2007. İstatistiksel Modelleme ile Konuşmacı Tanıma, Doktora tezi. Uludağ Üniversitesi , Bursa.
- Fehrmann, A.E., 2013. *Automated Sleep Classification Using the New Sleep Standards*, Rochester Institute of Technology Master Thesis, 85.
- Fogel, S.M., Smith C.T., 2011. The function of the sleep spindle: a physiological index of intelligence and a mechanism for sleep-dependent memory consolidation. *Neuroscience Biobehave Revision April 2011*, 35(5), 1154-65.
- Fonseca, P., Long X., Radha M., Haakma R., Aarts R.M., Rolink J., 2015. Sleep stage classification with ECG and respiratory effort. *Physiological measurement*, 36(10), 2027-40.
- Fraiwan, L., Lweesy K., Khasawneh N., Wenz H., Dickhaus H., 2012. Automated sleep stage identification system based on time-frequency analysis of a single EEG channel and random forest classifier. *Computer Methods and Programs in Biomedicine*, 108(1), 10-9.
- Gelegin, İ., ve Bolat, B., 2011. Ayrık Kelime Tabanlı Bir Konuşma Sistemiyle Bilgisayar Kontrolü. *Elektrik-Elektronik ve Bilgisayar Sempozyumu*, Fırat Üniversitesi,Elazığ.
- Gharbali, A.A., 2018. *Sleep Stage Classification: A Deep Learning Approach*. Master Tezi, Teknoloji Fakültesi, Lisboa Üniversitesi, Portekiz.
- Ghassemi, M., Moody E.B., Lehman L.W.H., Song C., Li Q., Sun H., Mark R., Westover B., Clifford G., 2018. You Snooze, You Win: the PhysioNet/Computing in Cardiology Challenge 2018, Vol 45.
- Gökgöz, E. and Subaşı A., 2014. Effect of multiscale PCA de-noising on EMG signal classification for diagnosis of neuromuscular disorders, *Journal of Medical Systems*, 38(4), 31.

- Güneş, S., Polat K., Dursun M., Yosunkaya S., 2009. Examining the Relevance with Sleep Stages of time domain features of EEG, EOG and chin EMG signals. 14th National Biomedical Engineering Meeting, İzmir, Turkey.
- Hatipoğlu, P. U., 2016. Time Series Classification Using Deep Learning, A Master Thesis, Graduate School Of Natural And Applied Sciences Of Middle East Technical University, Ankara.
- He, R. , Wang K., Zhao N., Liu Y, 2018. Identification of Arousals With Deep Neural Networks (DNNs) Using Different Physiological Signals. *Computing in Cardiology 2018*; Vol 45.
- Hochreiter, S., Schmidhuber J., 1997. Long Short Term Memory. *Neural Computation*, 9(8), 1735-1780.
- Howe-Patterson, M., Porbabaee B., Benard F., 2018. Automated Detection of Sleep Arousals from Polysomnography Data Using a Dense Convolutional Neural Network., *Computing in Cardiology 2018*, Vol 45, 1-4.
- Hsu, Y.L., Yang Y.T., Wang J.S., Hsu C.Y., 2013. Automatic sleep stage recurrent neural classifier using energy features of EEG signals, *Neurocomputing*, vol. 104, s 105–114.
- Hyvärinen, A., Karhunen J., Oja E., 2001. *Independent Component Analysis*. John Wiley & Sons Book, 505, New York.
- Hyvärinen, A., Oja E., 2000. *Independent Component Analysis: Algorithms and Applications*, Neural Networks Research Centre Helsinki University of Technology *Neural Networks*, 13(4-5):411-430, 2000.
- Hyvärinen, A., Oja E., Karhunen J., 2001. *Independent Component Analysis*. John Wiley Press, 503, New York.
- Iber, C., Ancoli-Israel S., 2005. Chesson A.L. and Quan S.F., *The AASM Manual for the Scoring of Sleep and Associated Events: Rules, Terminology and Technical Specification*, American Academy of Sleep Medicine, Westchester, USA.
- Ichimaru, Y., Clark K.P., Ringler J., Weiss W.J., 1990. Effect of sleep stage on the relationship between respiration and heart rate variability. *Proceedings Computers in Cardiology*, 657-60.
- Jafari, B. and Mohsenin V., 2010. *Polysomnography*, *Clinics in Chest Medicine*, 31, 287-297.
- Karadağ, M., *Polisomnografide Solunum Kayıtları Temel Bilgiler*, 40. http://file.toraks.org.tr/TORAKSFD23NJKL4NJ4H3BG3JH/10_kongre_kurs/sunum/m_karadag_polisomnografide_solunum_kayitlari.pdf (15.06.2018)
- Kevric, J., Subasi A., 2014. The effect of multiscale PCA de-noising in epileptic seizure detection. *Journal of Medical Systems*, 38(10), 131.
- Khemiri, P.S., Aloui K., Naceur M.S., 2015. Automatic classification of slow-wave sleep and REM-sleep stages using somnographic ECG signal: some preliminary results for obese and no-obese. *International Journal of Signal and Imaging Systems Engineering*, 8(1/2), 11.
- Kim, J., 2014. A Comparative Study on Classification Methods of Sleep Stages by Using EEG. *J. Korea Multimed. Soc.*, vol. 17, no. 2, 113–123.
- Korkmaz, O.E., 2016. *Ses Sinyalinden Duygu Tanıma*, Yüksek Lisans Tezi, Karadeniz Teknik Üniversitesi, Trabzon.

- Krenker, A., Bešter J., Kos A., 2011. Introduction to the artificial neural networks. *Methodological Advances and Biomedical Applications InTech*. 1-17. <http://cdn.intechweb.org/pdfs/14881.pdf>
- Längkvist, M., Karlsson L., Loutfi A., 2014. A review of unsupervised feature learning and deep learning for time-series modeling, *Pattern Recognition Letters*, 42, 11–24.
- Levy, P., Peppin J.L., Wuyam B., Veale D., 1992. Respiratory Monitoring in Sleep Apnea Syndrome, *Sleep* 1992, 15, 5-8.
- Li, Y., Wong K.M., Bruin H.D., 2012. Electroencephalogram signals classification for sleepstate decision - A riemannian geometry approach. *IET Signal Processing*, Haziran 2012, 6(4), 288-99.
- Li, H., Cao Q., Zhong Y., Pan Y., 2018. Sleep Arousal Detection Using End-to-End Deep Learning Method Based on Multi-Physiological Signals. *Computing in Cardiology* 2018; Vol 45.
- Li, Q., Li Q., Liu C., Shashikumar P. S., Nemati S., Clifford G.D., 2018. Deep Learning in the cross time frequency domain for sleep stage classification from a single lead electrocardiogram, *Physiological Measurement*, 39, 124005, pp12.
- Long, X., Fonseca P., Foussier J., Haakma R., Aarts R.M., 2014. Sleep and Wake Classification With Actigraphy and Respiratory Effort Using Dynamic Warping. *IEEE Journal of Biomedical and Health Informatics*, 18(4), 1272-84.
- McCloskey, M., 1991. Networks and theories: The place of connectionism in cognitive science. *Psychological Science*, 2(6), 387–395.
- McCulloch, W.S., Pitts W., 1943. A logical calculus of the ideas immanent in nervous activity. *The bulletin of mathematical biophysics*, 5(4), 115–133.
- Mendelson, W.B., 2017. *What it is, how it works, why it matters*. Chicago University Press.
- Moorcroft, W.H., 2005. *Understanding Sleep and Dreaming*, Springer Press, Luther College of Sleep and Dreaming Laboratory and Psychology Department, s335, USA.
- Moser, D., Anderer P., Gruber G., Parapatics S., Loretz E., Boeck M., 2009. Sleep Classification According to AASM and Rechtschaffen & Kales: Effects on Sleep Scoring Parameters. *Sleep*, 32(2), 139-49.
- Collop, N.A., Salas R.E., Delayo M., and Gamaldo C., 2008 Normal sleep and circadian processes. *Critical Care Clinics*, 24(3):449–60.
- Oral, E.A., Çodur M.M., Ozbek I.Y., 2017. Generalized filter bank design for sleep stage classification. *International Artificial Intelligence and Data Processing Symposium (IDAP)*, 1-6.
- Orr, W.C., 1985. Utilization of polysomnography in the assessment of sleep disorders. *Medical Clinics of North America*, 69(6), 1153-67.
- Özşen, S., 2013. Classification of sleep stages using class-dependent sequential feature selection and artificial neural network, *Neural Comput. Appl.*, vol. 23, no. 5, 1239–1250.
- Pang, Z., Liu D., Lloyd S.R., 2007. Classification of Obstructive Sleep Apnea by Neural Networks. *ISNN 2007, Part II, LNCS 4492*, 1299–1308.
- Patanaik, A., Ong J.L., Gooley J.J., Ancoli-Israel S., Chee M.W.L., 2018. An end-to-end framework for real-time automatic sleep stage classification. *Sleep*, 41(5).

- Powers, D.M.W., 2011. Evaluation: From Precision, Recall and F-Measure to ROC, Informedness, Markedness & Correlation, *Journal of Machine Learning Technologies*. 2 (1): 37–63.
- Proakis, J.G. and Manolakis D.G., 1995. *Digital Signal Processing*, Prentice Hall, 1033, New Jersey.
- Rajseklar, A.G., 2008. Real Time Speaker Recognition Using MFCC and VQ. Master Thesis, National Inst. Of Technology, s70, Rourkela.
- Ramli, S.N., Ahmad R. ve Faizal Abdollah M., 2013. Electrocardiogram (ECG) Signals as Biometrics in Securing Wireless Body Area Network' *IEEE*, 536-541.
- Rechtschaffen, A., Bergmann B.M., Everson C.A., Kushida C., Gilliland M.A., 1989. Sleep deprivation in the rat: X. Integration and discussion of the findings, *Sleep*, 25(1), 68-87.
- Rechtschaffen, A., Kales A., 1968. *Manual of standardized terminology, techniques and scoring systems for sleep stages of human subjects.*, U. G. P. Office, Washington DC Public Health Service.
- Reilly, R.B. and Lee T.C., 2010. Electrograms (ECG, EEG, EMG, EOG). *Technology and Health Care*, 18(6), 443-58.
- Sanei, S., Chambers J.A., 2007, *EEG Signal Processing.*, John Wiley & Sons Ltd., 290, United Kingdom.
- Schellenberger, S., Shi K., Mai M., Philipp W. J., Steigleder T., Eskofier B., 2018. Detecting Respiratory Effort-Related Arousals in Polysomnographic Data Using LSTM Networks, *Computing in Cardiology 2018*; Vol 45.
- Silber, M.H., Krahn L.E., Morgenthaler T.I., 2004. *Sleep Medicine in Clinical Practice*. Taylor & Francis Press, 401, USA.
- Silber, M.H., Ancoli-Israel S, Bonnet M.H., Chokroverty S., Grigg-Damberger M.M., Hirshkowitz M., Kapen S., Keenan S.A., Kryger M.H., Penzel T., Pressman M.R., and Iber C., 2007 The visual scoring of sleep in adults. *Journal Of Clinical Sleep Medicine*, 3(2): 121–131.
- Stevens, S.S., Volkman J., 1940. The relation of pitch to frequency: A revised scale, *The American Journal of Psychology*, 53(3), 329–353.
- Stehman, S.V., 1997. Selecting and interpreting measures of thematic classification accuracy, *Remote Sensing of Environment*. 62 (1): 77–89.
- Stone, J.V., 2004. *Independent Component Analysis: A Tutorial Introduction*. The MIT press, 213, London.
- Stone, K.C., Taylor D.J., McCrae C.S., Kalsekar A., Lichstein K.L., 2008. Nonrestorative sleep. *Sleep Medical Reviews*, 12(4), 275-88.
- Šušmáková, K., 2004. Human Sleep and Sleep EEG, *Measurement in Biomedicine*, Volume 4, Section 2, 69-74.
- Şen, B., Peker M., Çavuşoğlu A., Çelebi F.V., 2014. A Comparative Study on Classification of Sleep Stage Based on EEG Signals Using Feature Selection and Classification Algorithms. *Journal Med. Syst.*, vol. 38, no. 3, sayfa18.
- Tatum, W.O., Husain A.M., Banbadis S.R., Kaplan P.W., 2008. *Handbook of EEG Interpretation*. Demos Medical Publishing, s4.
- Þráinsson, H., Ragnarsdóttir H., Fannar K.G., Marinósson B., Finnsson E., Gunnlaugsson E., 2018. Automatic Detection of Target Regions of Respiratory Effort-Related Arousals Using Recurrent Neural Networks. *Computing in Cardiology 2018*, Vol 45.

- Virkkala, J., Hasan J., Värri A., Himanen S.L., Müller K, 2007. Automatic sleep stage classification using two-channel electro-oculography, *J. Neurosci. Methods*, vol. 166, no. 1, 109–115.
- Yang, Q., Wu X., 2006. 10 Challenging Problems In Data Mining Research. *International Journal of Information Technology and Decision Making*, 05(04), 597-604.
- Zaveri, H.P., Williams W.J., Sackellares J.C., Beydoun A., Duckrow R.B., Spencer S.S., 1999. Measuring the Coherence of Intracranial Electroencephalograms. *Clinical Neurophysiology*, 110(10), 1717-25.
- Zhu, G., Li Y., Wen P., 2014. Analysis and Classification of Sleep Stages Based on Difference Visibility Graphs From a Single-Channel EEG Signal. *IEEE Journal of Biomedical and Health Informatics*, 18(6), 1813-21.
- Zoubek, L., Charbonnier S., Lesecq S., Buguet A., Chapotot F., 2007. Feature selection for sleep/wake stages classification using data driven methods. *Biomedical Signal Processing and Control* 2007, 2(3), 171–179.

ÖZGEÇMİŞ

1986 yılında İstanbul'da doğan Hilal Sultan DURANOĞLU TUNÇ, ilköğretim ve orta öğrenimini sırasıyla Güzelcehisar İlköğretim Okulu ve Fevzi Çakmak Lisesinde tamamlamıştır. 2004 yılında kazandığı Yıldız Teknik Üniversitesi Elektrik Mühendisliği bölümünü 2009 yılında başarıyla tamamlamıştır. Mezun olduktan sonra yeni mezunlara yönelik açılan sınavın birincisi olarak girdiği Çalık Holding'de iş analisti olarak 2 yıl çalışmıştır. 2017 yılında Atatürk Üniversitesi Fen Bilimleri Enstitüsü Elektronik Mühendisliği Anabilim dalında Yüksek Lisans Eğitimine başlamıştır. 2019 yılında da Gaziantep Üniversitesi Elektronik Anabilimdalı'nda araştırma görevlisi olarak çalışmaya başlamıştır. Hilal Sultan DURANOĞLU TUNÇ iyi derecede İngilizce bilmektedir.