



T.C.
KONYA TEKNİK ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ



UYKU APNESİ İLE UYKU EVRELERİ
ARASINDAKİ İLİŞKİNİN TESPİT EDİLMESİ

Sena ÇEPER

YÜKSEK LİSANS TEZİ

Bilgisayar Mühendisliği Anabilim Dalı

Haziran-2022
KONYA
Her Hakkı Saklıdır

TEZ KABUL VE ONAYI

Sena ÇEPER tarafından hazırlanan “Uyku Apnesi ile Uyku Evreleri Arasındaki İlişkinin Tespit Edilmesi” adlı tez çalışması 27/06/2022 tarihinde aşağıdaki jüri tarafından oy birliği ile Konya Teknik Üniversitesi Lisansüstü Eğitim Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı’nda YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

Jüri Üyeleri

İmza

Başkan

Doç. Dr. Humar Kahramanlı ÖRNEK

Danışman

Prof. Dr. Gülay TEZEL

Üye

Doç. Dr. Ahmet BABALIK

Yukarıdaki sonucu onaylarım.

Prof. Dr. Saadettin Erhan KESEN
Enstitü Müdürü

Bu tez çalışması TÜBİTAK tarafından 119E127 nolu proje ile desteklenmiştir.

TEZ BİLDİRİMİ

Bu tezdeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edildiğini ve tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını bildiririm.

DECLARATION PAGE

I hereby declare that all information in this document has been obtained and presented in accordance with academic rules and ethical conduct. I also declare that, as required by these rules and conduct, I have fully cited and referenced all material and results that are not original to this work.

İmza

Sena ÇEPER

Tarih:

ÖZET

YÜKSEK LİSANS TEZİ

UYKU APNESİ İLE UYKU EVRELERİ ARASINDAKİ İLİŞKİNİN TESPİT EDİLMESİ

Sena ÇEPER

Konya Teknik Üniversitesi
Lisansüstü Eğitim Enstitüsü
Bilgisayar Mühendisliği Anabilim Dalı

Danışman: Prof. Dr. Gülay TEZEL

2022, 82 Sayfa

Jüri
Prof. Dr. Gülay TEZEL
Doç. Dr. Humar Kahramanlı ÖRNEK
Doç. Dr. Ahmet BABALIK

Uyku, insan yaşamı için önemli bir süreçtir. İnsan vücudu için en temel dinlenme biçimidir ve kalitesi insan yaşamını önemli derecede etkilemektedir. Uyku kalitesizliğinden kaynaklanan kalpte ve beyinde sorunlara neden olabilen birçok hastalık vardır. Bu hastalıkların en basiti horlama en ciddiisi uyku apnesidir. Uyku evreleme, günlük hayatı olumsuz yönde etkileyen ve ölüme sebep olabilen uyku rahatsızlıklarının özellikle de uyku apnesinin teşhisinde önemli rol oynamaktadır. Uyku evreleme uyku esnasında kaydedilen biyomedikal sinyallerin uyku uzmanı tarafından Amerikan Uyku Tıbbi Akademisi (American Academy of Sleep Medicine – AASM) tarafından belirlenen standartlara göre değerlendirilmesi ile yapılmaktadır. Bu sinyaller (Elektroensefalogram (EEG), Elektromiyogram (EMG), Elektrokardiyogram (EKG) ve Elektrookülogram (EOG)), Polisomonografi (PSG) cihazı ile uyku laboratuvarlarında kaydedilmektedir. Uyku, uyanıklık (Wake) evresi hariç kendi içerisinde iki ana bölüme ayrılmaktadır: Hızlı Olmayan Göz Hareketleri (NREM) ve Hızlı Göz Hareketleri (REM). NREM evresi de kendi içerisinde NREM1, NREM2, NREM3 olarak üç kısma ayrılmaktadır. Her birey uyku sırasında belli bir düzende NREM ve REM evrelerini yaşamaktadır. Bu evreleri uyku esnasında oluşma sıklığı bireyin uyku kalitesi ve sağlığı hakkında bilgi verir.

Bu tez çalışmasında, PSG ile kaydedilen sinyallerden biri olan EEG ile uyku evreleme yaptıktan sonra, uyku apnesinin uyku evreleri ile ilişkisinin incelenmesi amaçlanmıştır. Uyku evreleme yapılırken, EEG sinyalinden üç farklı özellik seti oluşturulmuştur. Birinci özellik seti Ayrık Dalgacık Dönüşümü yöntemi ile elde edilen alt bantlardan çıkarılan 80 özellikten oluşmaktadır. İkinci özellik seti Ampirik Mod Ayırıştırma (Empirical Mode Decomposition- EMD) yöntemi kullanılarak elde edilen 26 adet özellikten ve üçüncü özellik seti de Varyasyon Mod Ayırıştırma (Variational Mode Decomposition- VMD) yöntemi ile çıkarılan 26 özellikten oluşturulmuştur. Özellik setlerindeki tüm özellikler birleştirilerek 132 özellikten oluşan dördüncü özellik seti elde edilmiştir. Son olarak dördüncü özellik setine Relief özellik seçme yöntemi uygulanarak en etkin 91 özellik seçilmiştir ve seçilen bu özelliklerle beşinci özellik seti oluşturulmuştur. Bu beş özellik setinin her biri için Yapay Sinir Ağları (Artificial Neural Network- ANN), Destek Vektör Makineleri (Support Vector Machine- SVM), k En Yakın Komşu Algoritması (k Nearest Neighbors- kNN) ve Torba Ağaç Algoritması (Bagged Tree- BT) sınıflandırıcıları için uyku evreleme işlemi yapılmıştır. En yüksek test başarıları %70.02 ile EMD yöntemi ile çıkarılan özellikler ve ANN sınıflandırıcısı ile elde edilmiştir. En yüksek sınıflandırıcı modeli kaydedilerek, evrelemede kullanılmayan farklı 9 hasta validasyon için kullanılmıştır ve bu 9 hastanın uyku apnesi rahatsızlığının evreler ile olan ilişkisi incelenmiştir.

Anahtar Kelimeler: Ampirik Mod Ayırıştırma, REM, Uyku Apnesi, Uyku Evreleme, Yapay Sinir Ağları

ABSTRACT

MS THESIS

DETECTION OF RELATIONSHIP BETWEEN SLEEP APNEA AND SLEEP STAGES

Sena ÇEPER

**Konya Technical University
Institute of Graduate Studies
Department of Computer Engineering**

Advisor: Prof. Dr. Gülay TEZEL

2022, 82 Pages

**Jury
Prof. Dr. Gülay TEZEL
Assoc. Prof. Dr. Humar Kahramanlı ÖRNEK
Assoc. Prof. Dr. Ahmet BABALIK**

Sleep is an important process for human life. It is the most basic form of rest for the human body and its quality significantly affects human life. There are many diseases that can cause problems in the heart and brain caused by poor sleep quality. The simplest of these diseases is snoring and the most serious is sleep apnea. Sleep staging plays an important role in the diagnosis of sleep disorders, especially sleep apnea, that negatively affect daily life and can cause death. Sleep staging is done by evaluating the biomedical signals recorded during sleep by a sleep specialist according to the standards set by the American Academy of Sleep Medicine (AASM). These signals (Electroencephalogram (EEG), Electromyogram (EMG), Electrocardiogram (EKG) and Electrooculogram (EOG)) are recorded in sleep laboratories with the Polysomnography (PSG) device. Except for the wake phase, sleep is divided into two main parts: Non-Rapid Eye Movements (NREM) and Rapid Eye Movements (REM). The NREM phase is also divided into three parts: NREM1, NREM2, and NREM3. Every individual experiences NREM and REM stages in a certain order during sleep. The frequency of these stages during sleep gives information about the sleep quality and health of the individual.

In this thesis, it was aimed to examine the relationship between sleep apnea and sleep stages after sleep staging with EEG, which is one of the signals recorded with PSG. While staging sleep, three different feature sets were created from the EEG signal. The first feature set consists of 80 features extracted from the subbands obtained by the Discrete Wavelet Transform method. The second feature set was composed of 26 features obtained using the Empirical Mode Decomposition (EMD) method, and the third feature set was composed of 26 features extracted by the Variation Mode Decomposition (VMD) method. By combining all the features in the feature sets, the fourth feature set consisting of 132 features was obtained. Finally, the most effective 91 features were selected by applying the Relief feature selection method to the fourth feature set, and the fifth feature set was created with these selected features. For each of these five feature sets, sleep staging was performed for Artificial Neural Networks (ANN), Support Vector Machines (SVM), k Nearest Neighbor Algorithm (kNN) and Bagged Tree Algorithm (IT) classifiers. The highest test success rate of 70.02% was obtained with the features extracted by EMD method and ANN classifier. By registering the highest classifier model, 9 different patients not used in staging were used for validation, and the relationship of sleep apnea disease of these 9 patients with stages was examined.

Keywords: Artificial Neural Network, Empirical Mode Decomposition, REM, Sleep Apnea, Sleep Staging

ÖNSÖZ

Bu tez çalışmam boyunca değerli vaktini, bilgi ve tecrübelerini benimle paylaşan, gelişmemde büyük emeği olan danışman hocam sayın Prof. Dr. Gülay TEZEL'e teşekkürü bir borç bilirim. Ayrıca eğitim hayatım boyunca maddi ve manevi yönden her zaman beni destekleyen, üzerimde büyük emekleri bulunan canım aileme sonsuz teşekkür ederim.

Sena ÇEPER
KONYA-2022



İÇİNDEKİLER

ÖZET	iv
ABSTRACT.....	v
ÖNSÖZ	vi
İÇİNDEKİLER	vii
SİMGELER VE KISALTMALAR	viii
1.GİRİŞ	1
2.KAYNAK ARAŞTIRMASI	6
3. MATERYAL VE YÖNTEM.....	12
3.1. Veri Seti	13
3.2. Ön İşlem.....	15
3.2.1. Elektrot Kopması	15
3.3. Özellik Çıkarma Yöntemleri.....	16
3.3.1. Ayırık Dalgacık Dönüşümü (Discrete Wavelet Transform - DWT)	16
3.3.2. Tekil Değer Ayrışımı (Singular Value Decomposition- SVD)	18
3.3.3. Güç Spektral Yoğunluğu	18
3.3.4. Ampirik Mod Ayrıştırma (Empirical Mode Decomposition-EMD).....	19
3.3.5. Varyasyon Mod Ayrıştırma (Variational Mode Decomposition-VMD)	22
3.4. Zaman Özellikleri	22
3.5. Minimum Maximum Normalizasyon	23
3.6. Relief Özellik Seçme Yöntemi	24
3.7. Sınıflandırma Algoritmaları.....	26
3.7.1. Yapay Sinir Ağları (Artificial Neural Network- ANN).....	26
3.7.2. k En Yakın Komşu Algoritması (k Nearest Neighbors Algorithm- kNN) ...	28
3.7.3. Destek Vektör Makineleri (Support Vector Machine- SVM)	29
3.7.4. Torba Ağaç Algoritması (Bagged Tree Algorithm- BT).....	30
3.7.5. k Kat Çapraz Doğrulama (k-Fold Cross Validation)	31
3.8. Performans Değerlendirme Ölçütleri.....	32
4.ARAŞTIRMA SONUÇLARI VE TARTIŞMA.....	34
4.1. Ham Veri ile Temiz Veri Evreleme Sonuçlarının Karşılaştırılması	34
4.2. Temiz Veri ile Yapılan Uyku Evreleme Çalışmalarının Sonuçları	37
4.3. REM ve/veya Pozisyon Bağımlı OSAS Hastalarının Tespit Edilmesi.....	64
5. SONUÇLAR VE ÖNERİLER	70
KAYNAKLAR	71

SİMGELER VE KISALTMALAR

Kısaltmalar

AASM	:	Amerikan Uyku Tıbbı Akademisi
AHI	:	Apne Hipopne İndeksi
ANN	:	Yapay Sinir Ağları
BT	:	Torba Ağaç Algoritması
CSA	:	Merkezi Uyku Apnesi
DN	:	Doğru Negatif
DP	:	Doğru Pozitif
DWT	:	Ayrık Dalgacık Dönüşümü
EEG	:	Elektroensefalogram
EKG	:	Elektrokardiyogram
EMD	:	Ampirik Mod Ayrıştırma
EMG	:	Elektromiyogram
EOG	:	Elektrookülogram
IMF	:	İçsel Mod Fonksiyonu
kNN	:	k En Yakın Komşu Algoritması
MSA	:	Bileşik Uyku Apnesi
NREM	:	Hızlı Olmayan Göz Hareketleri
OSA	:	Tıkayıcı (Obstrüktif) Uyku Apnesi
OSAS	:	Tıkayıcı Uyku Apne Sendromu
ÖS	:	Özellik Seti
PSG	:	Polisomnografi
REM	:	Hızlı Göz Hareketleri
SVD	:	Tekil Değer Ayrışımı
SVM	:	Destek Vektör Makineleri
VMD	:	Varyasyonel Mod Ayrıştırma
YN	:	Yanlış Negatif
YP	:	Yanlış Pozitif

1.GİRİŞ

Uyku, insanın dış dünya ile bağlantısının kesildiği kısa bir dönemdir. İnsanların ömrünün üçte birini uyku oluşturmaktadır. Uyku, insan vücudu için en temel dinlenme biçimidir ve uykunun kalitesi insanın sosyal yaşamını ve sağlığını ciddi derecede etkilemektedir. Uyku kalitesizliğinden kaynaklı birçok hastalık bulunmaktadır. Bunlara horlama, uyku apnesi örnek verilebilir. Uyku apnesi, uyku esnasında solunumun durması olarak tanımlanmaktadır. Kalpte ve beyinde ciddi sorunlara sebep olmaktadır (Köktürk, 2013). Uyku apnesi olan hastalar, uyudukları süre boyunca birkaç dakika süren boğulmalar yaşamaktadır. Bu boğulmalarda hastanın kan değerlerinde düşüş görülmektedir ve bu da beyin uyandırılmasına sebep olur. Beyin, solunum fonksiyonlarının durduğunu vücuda uyarılar yollayarak haber verir ve hasta uykudan uyanır. Uyku apnesi olan hastalar uyudukları süre boyunca birkaç defa uyanırlar. Bu durum, hasta uykusunu kaliteli bir şekilde uyumadığı için yorgunluk ve uykusuzluğa sebep olmaktadır. Merkezi Uyku Apnesi (Central Sleep Apnea-CSA), Bileşik Uyku Apnesi (Mixed Sleep Apnea-MSA), Tıkayıcı Uyku Apnesi (Obstructive Sleep Apnea-OA) olmak üzere üç çeşit apne türü vardır. Tıkayıcı Uyku Apnesi, solunumun tıkanması ile oluşan hastalıktır. Bu apne tipinde, solunum yolu tıkanır ve akciğere yeteri kadar hava girişi olması engellenir. Uyku sırasında, nefes almanın durması birçok kez olabilir. Nefes almanın durmasından kaynaklı olarak beyin, kalp ve başka organlar yeteri kadar oksijen alamaz. Merkezi Uyku Apnesi, beyindeki solunum merkezindeki bozukluktan kaynaklı apne çeşitidir. Merkezi uyku apnesi, Tıkayıcı Uyku Apnesine göre çok daha az görülmektedir. Vücudumuzda solunumu kontrol eden kaslar bulunmaktadır. Beyin bu kaslara yeteri kadar sinyal gönderemediği durumlarda Merkezi Uyku Apnesi ortaya çıkmaktadır. Bileşik Uyku Apnesi, hem Merkezi Uyku Apnesi hem de Tıkayıcı Uyku Apnesinin bir arada görüldüğü apne çeşididir. Bu apne çeşidinde, önce Tıkayıcı Uyku Apnesi görülmektedir. Tıkayıcı Uyku Apnesi tedavisi yapıldıktan sonra Merkezi Uyku Apnesi belirtileri ortaya çıkmaktadır.

Uyku ile ilgili rahatsızlıklar Polisomonografi (PSG) cihazı ile kaydedilen sinyaller ile belirlenmektedir. PSG cihazı, Elektroensefalogram (EEG), Elektrookülogram (EOG), Elektromiyogram (EMG) ve Elektrokardiyogram (EKG) gibi sinyalleri, solunum yollarındaki hava akışını, kan oksijen seviyelerini, vücut pozisyonlarını ve kasların elektriksel aktivitesini kaydedebilmektedir. Uyku rahatsızlıklarının tespitinde hastanın

uyku kalitesinin tespit edilmesi gerekli olduğu için uyku evrelemenin yapılması öncelikli işlemdir.

Uyku evreleme, uyku uzmanları tarafından Amerikan Uyku Tıbbı Akademisi (American Academy of Sleep Medicine – AASM) tarafından belirlenen uykunun evrelerine göre sınıflandırılmasını ifade etmektedir. Uyku, uyanıklık (Wake) evresi hariç 2 ana evreden oluşmaktadır. Bu evreler Hızlı Olmayan Göz Hareketleri (NREM) ve Hızlı Göz Hareketleri (REM)'dir. NREM evresi uykunun ilk anlarında görülmektedir. NREM evresi de kendi içerisinde 3 kısımdan oluşur. NREM1, uykuya dalma anında görülmektedir. Bu evrede vücuttaki yaşamsal faaliyetler yavaşlamaya başlar. NREM1 evresinde kişi uyku için en rahat pozisyonu bulana kadar yatak içerisinde hareket eder. Dışarıdan gelen en küçük uyarıda evreden çıkılıp, kişi uyanabilir. Boşluğa düşme ya da havada uçuş gibi hisler de bu evrede oluşur. NREM2 evresinde uyku için uygun pozisyon bulunmuştur ve NREM1 evresine göre daha derin bir uykuya geçilmiştir. Kas hareketleri bu evrede biraz daha azalır. NREM3 ise derin uykunun başladığı evredir. Uykunun en dinlendirici evresidir. NREM1 evresinden NREM3 evresine geçerken beyin dalgalarının genlikleri artar, frekansları azalır. REM evresinde rüya içeriğine bağlı olarak göz hareketleri bulunmaktadır. REM evresinde beyin fonksiyonları uyanıklıktaki kadar fazladır. REM evresinde uyanıklık evresine benzer şekilde beyin dalgalarının genlikleri düşüktür ve karışık frekanslı dalgalar bulunmaktadır. Herkes uyku esnasında NREM ve REM evrelerinden geçmektedir. Bu evrelerin uykuda oluşma sıklığı kişinin sağlığı hakkında bilgi vermektedir (Ersoy, 2019). Uyku esnasında NREM-1 %2-5, NREM-2 %45-55, NREM-3 %20-25, REM %20-25 gibi yüzdelik oranlara sahiptirler. Uyku esnasındaki uyanıklık süresi uykunun %5'inden azdır (İlhan Algın ve ark., 2016). Bu evrelerin tespiti için gece boyunca hastadan kaydedilen PSG sinyallerinden EKG, EMG, EOG ve EEG'den çıkarılan özellikler ve farklı yapay zeka yöntemleri ile yapılmış çalışmalarla literatürde karşılaşılmaktadır (Aydoğan ve ark., 2015, Güneş ve ark., 2009, Özşen ve ark., 2010). Güneş ve ark. (2009) çalışmalarında EEG, EOG, EMG sinyalleri kullanarak uyku evreleme üzerinde en etkili olan özelliği araştırmış ve EEG sinyalinden hesaplanan Skewness değerinin uyku evreleme üzerinde diğer özelliklere göre daha etkili olduğunu tespit etmişlerdir. Özşen ve ark. (2010), yaptığı çalışmada çıkarılan özelliklerin uyku evreleme üzerindeki etkisi üzerinedir. EEG, EOG, EMG sinyallerini kullanarak yapılan çalışmada EEG sinyalinin spektrumundan elde edilen Alpha Slow Wave Index (ASI) değerinin uyku evreleme üzerinde etkisinin yüksek olduğu gösterilmiştir. Literatürde, daha az sinyal ve daha az işlem maliyeti odaklı çalışan ve sadece tek bir PSG

sinyaline odaklanan çalışmalar da mevcuttur. Bu çalışmalarda da tercih edilen sinyal çoğunlukla beynin elektriksel aktivitesini gösteren EEG sinyalidir (Basha ve ark., 2020, Güneş ve ark., 2009, Huang Wu ve ark., 2020, Michielli ve ark., 2019, Uçar ve ark., 2014). Güneş ve ark. (2010), yaptıkları çalışmada ise EEG sinyali kullanarak frekans ortamında özellik çıkarma işlemi yapabilmek için Welch metodu kullanmıştır.

EEG sinyali, beynin elektriksel aktivitesini görmek amacıyla hastanın başının üzerine belli bir düzende elektrotların yerleştirilmesi ile kaydedilir. Uyku evrelemede kullanılan EEG sinyali, nörolojide kullanılan EEG sinyalinden farklıdır. Nörolojide kullanılan EEG sinyali klinik EEG, uyku evrelemede kullanılan EEG sinyali ise uyku EEG'si olarak adlandırılır. Klinik EEG'de çok sayıda elektrot ile kayıt yapılırken uyku EEG'sinde yalnızca birkaç elektrot kullanılmaktadır. Elektrotlar yerleştirildikleri bölgelerle ifade edilirler. Santral elektrotlar için C, oksipital elektrotlar için O, auricular bölge için A (Yeni terminolojide M=Mastoid) harfleri kullanılır. Kayıt elektrodu ilgili bölgeye yerleştirilirken, kulak veya mastoid bölgeye referans elektrotu yerleştirilir (Köktürk, 2013). Uyku EEG'sinde evreleme yapmak çoğunlukla bir kanal bazen daha çok sayıda kanal ile çalışılmaktadır.

Uykunun her evresinde fizyolojik farklılıklar yaşanmaktadır. Bu farklılıklar da en çok EEG sinyalinin frekans ve genlik açısından değişim göstermesine neden olmaktadır. Bu nedenle evrelemede en önemli sinyal olarak tanımlanabilir (Güneş ve ark., 2010, Michielli ve ark., 2019, Uçar ve ark., 2014). Beyinle ilgili pek çok hastalığın tespitinde kritik öneme sahip olduğu için EEG sinyalleri, diğer sinyallerden farklı olarak, belli frekans aralıklarına göre tanımlanmış özel alt bantlarla (Beta, Alfa, Teta, Delta dalgaları) ifade edilmektedir. Bu alt bantlar hastalıklara göre EEG sinyallerinin frekans ve genlik bakımından gruplandırılmasını kolaylaştırmaktadır. Beta dalgası, yüksek dikkat gerektiren durumlarda, heyecanlandığında, uyanık olunan anlarda görülmektedir. Frekansı 12 Hz'in üzerindeki dalgadır. Alfa dalgası, uyanıkken ama normal ve sakin anlarda uykuya dalmadan önce oluşmaktadır. Frekansı 8-12Hz arasındaki dalgadır. Teta dalgası, uykunun ilk aşamasında oluşur ve frekansı 4-8 Hz arasındaki dalgadır. Delta dalgası, derin uyku sırasında oluşur ve frekansı 3 Hz in altındaki dalga türüdür. Beyin dalgaları, sinyal incelendiğinde kişinin o an hangi evrede olduğu bilgisini vermekte bu nedenle de EEG sinyalinin bu alt dalgaları uyku evrelemede kullanılmaktadır.

EEG sinyalleri ile yapılan çalışmaların çoğu sinyallerin bu alt bantlarına herhangi bir yöntem ile eriştikten sonra farklı özelliklerin çıkarılması prensibine dayanmaktadır.

Alfa, Beta, Delta, Teta alt bantlarını elde edebilmek için de Ayrık Dalgacık Dönüşümü ve Bant Geçiren Filtrelerin kullanıldığı görülmüştür (Basha ve ark., 2020).

Uyku apnesi, epilepsi gibi hastalık tespitine odaklanan (Bazil ve Walczak, 1997, Gangstad ve ark., 2019, Sathyanarayana ve ark., 2021) ya da sadece evreleme yapmayı hedefleyen sınıflandırma problemlerinde, sinyallerden çıkarılan özellikler yanında evrelerin tespit edilmesi için doğru sınıflandırıcının seçimi de önemli bir kriterdir. Literatürdeki çalışmalar incelendiğinde Yapay Sinir Ağları (Artificial Neural Network- ANN) uyku evreleme, apne tespiti gibi çalışmalarda en çok tercih edilen yöntem (Aydoğan ve ark., 2015, Basha ve ark., 2020) olmakla birlikte Destek Vektör Makineleri (Support Vector Machine- SVM) sınıflandırıcısı ile de başarılı sonuçlar elde edilmiştir (Alickovic ve Subasi, 2018, Basha ve ark., 2020, Casal ve ark., 2019, Huang Wu ve ark., 2020). Literatürde, ANN ve SVM sınıflandırıcılara ek olarak k En Yakın Komşu algoritması (k Nearest Neighbors- kNN) ve Torba Ağaç (Bagged Tree- BT) algoritmasının uyku evrelemede kullanıldığı görülmüştür (Taran ve ark., 2020). Literatürde, çalışmaların performansını etkileyen diğer bir faktör de kullanılan veri setidir. Bazı çalışmalarda (Aydoğan ve ark., 2015, Ersöz ve Özşen, 2011, Güneş ve ark., 2009, Güneş ve ark., 2010, Özşen ve ark., 2010, Uçar ve ark., 2014) kullanılan sinyaller hastaneden alınmış ham veri setleri iken bazı çalışmalarda ise (Al-Salman ve ark., 2019, Alickovic ve Subasi, 2018, An ve ark., 2021, Basha ve ark., 2020, Casal ve ark., 2019, Kumari ve ark., 2019, Li ve ark., 2022, Liu ve ark., 2021, Michielli ve ark., 2019, Taran ve ark., 2020, Yang ve Liu, 2020) hazır veri tabanından elde edilen sorunlu kısımları ayrıştırılmış public olarak tanımlanmış temiz veri setleri kullanılmıştır. Sorunsuz sinyaller olduğu için hazır veri tabanlarından elde edilen veri setlerinin uyku evrelemedeki başarılarının, ham veri setlerinden daha yüksek olduğu görülmüştür.

Bu tez çalışmasının temel amacı, Necmettin Erbakan Üniversitesi Meram Tıp Fakültesi Uyku Laboratuvarında hastalarda uyku apnesinin varlığının ve şiddetinin teşhis edilmesi için gece boyunca PSG cihazı ile kaydedilen EEG sinyalleri kullanılarak Wake, NREM ve REM olarak uyku evrelerinin tespit edilmesi ve evrelerin apne oluşumuna etkisinin belirlenmesidir.

Uykunun derinlik seviyesi, beyinin elektriksel aktivitesinin değişmesine neden olduğu için farklı uyku evrelerinde farklı aktivite düzeyleri oluşmaktadır. Bu nedenle, beyin elektriksel aktivitesini temsil eden EEG sinyalleri ve EEG sinyallerini oluşturan dalga tipleri göz önüne alınarak yapılan evreleme işlemi performansı olumlu yönde etkilemektedir. Bu durum dikkate alınarak, bu tez çalışmasında, farklı tekniklerle (Ayrık

Dalgacık Dönüşümü (Discrete Wavelet Transform- DWT, Ampirik Mod Ayırıştırma (Empirical Mode Decomposition- EMD ve Varyasyon Mod Ayırıştırma (Variational Mode Decomposition- VMD) çıkarılmış 3 farklı sinyal özellik seti ve farklı makine öğrenmesi algoritmaları yardımıyla evreleme süreci gerçekleştirilmiştir.

Ayrıca, literatürde yapılan çalışmalar genellikle hasta bazlı değil epok bazlı çalışmalardır. Bu tez çalışması 119E127 TÜBİTAK 1001 projesi kapsamında gerçekleştirildiği ve hastaların Tıkayıcı Uyku Apne Sendromu (Obstructive Sleep Apnea Syndrome – OSAS) hastası olup olmadıkları ve OSAS iseler apne derecelerinin tespit edilmesine odaklanıldığı için bu tez çalışmasında da hasta bazlı evrelemeye odaklanılmıştır.

Ayrıca literatürde EEG sinyalleri ile uyku evreleri tespit edildikten sonra erken teşhis edilen apne tipine bağlı olarak uygun tedavinin yapılmasına katkıda bulunabilecek olan uyku evreleri ve/veya hastanın yatış pozisyonu ile apneik atak oluşumu arasındaki ilişkiyi bulmak amacını güden bir çalışmaya rastlanmamıştır. Bu nedenle, bu çalışmada, ikincil amaç olarak, uyku apnesine sahip hastaların uyku evrelerine ve/veya yatış pozisyonuna bağlı bir apneye sahip olup olmadığının tespit edilmesi hedeflenmiştir. Çünkü, uyku apnesinin tespit edilmesinin yanında uykunun hangi evresinde apne olduğu da hastalığın seyrinin anlaşılması açısından önemlidir. Özellikle REM döneminde görülen apneik ataklar klinik tedavinin uygulanması açısından kritik öneme sahiptir. Çünkü REM bağımlı apne teşhisinin erken yapılması ile ilerleyen yaşlarda karşılaşılabilecek NREM bağımlı apne oluşumunun engellenmesi yönünde tedavi uygulanabilecektir. REM döneminde tıkayıcı solunumsal olayların sıklığı ve süresi daha fazla, oksijen desatürasyonu daha derin görülmektedir. REM ile ilişkili Tıkayıcı Uyku Apne Sendromu hastalarında yaşın ilerlemesi ve kilonun artışı ile başlangıçta yalnızca REM’de görülen solunum olaylarının NREM’de de görülmektedir, böylelikle kişideki apne hem REM hem de NREM döneminde solunumsal olayların görüldüğü, (ağır dereceli) bir OSAS’a dönüşmektedir (Yalçın, 2018).

2.KAYNAK ARAŞTIRMASI

Literatürde uyku evreleme üzerine farklı biyomedikal sinyaller kullanılarak yapılan birçok çalışma vardır. Çalışmaların çoğunda sadece EEG sinyali tercih edilmesine rağmen EKG, çene EMG ve EOG sinyallerinin de uyku evrelemeye etkisi incelenmiştir. Ayrıca asıl hedef başarıyı yükseltmek olsa da etkin özellikleri tespit etmeye odaklanan çalışmalar da mevcuttur. Sonuçlar göstermiştir ki kullanılan sinyal(ler) ve bu sinyallerden çıkarılan özellikler uyku evrelemenin başarısını etkilemektedir.

Güneş ve ark. (2009) çalışmalarında Selçuk Üniversitesi Meram Tıp Fakültesi uyku laboratuvarındaki PSG cihazından alınan EEG, EOG, EMG sinyallerini kullanarak bu sinyaller üzerinden zaman domeni özelliklerini çıkarmışlardır. Çıkardıkları özelliklerin uyku evreleri ile olan ilişkisi incelenmiştir. Her sinyalden ortalama değer, standart sapma, maksimum tepe değeri, Skewness, Kurtosis ve şekil faktörü değeri olmak üzere toplamda 6 özellik çıkarılmıştır. EEG sinyalinden çıkarılan Skewness değerinin uyku evreleme işleminde diğer özelliklere göre daha etkili olduğu gösterilmektedir. Uyku evreleme üzerinde etkili özelliğin bulunması için çalışmada çıkarılan özelliklerin korelasyon değerleri ile işlemler yapılmıştır. Skewness özelliğinin yanında sol ve sağ göz EOG sinyalinin standart sapması ve EMG sinyalinin ortalama değerinin de uyku evreleme üzerinde etkili olduğu belirtilmiştir.

Özşen ve ark. (2010), çalışmalarında Meram Tıp Fakültesinde PSG cihazından elde edilen EEG, EOG, EMG sinyalleri kullanılarak özellik çıkarma işlemini uygulamıştır ve sonrasında sıralı özellik seçme yöntemi uygulanarak hangi özelliklerin uyku evrelemede daha yüksek başarı verdiği incelenmiştir. EEG, sol ve sağ göz EOG, çene EMG sinyali ile toplamda 4 sinyalin her birinden 9 zaman özelliği çıkarılmış ve ayrıca EEG sinyalinde 31 adet frekans özelliği, 7 adet EMG frekans özelliği olmak üzere toplamda 74 özellik kullanılmıştır. Sıralı özellik seçme yöntemi kullanılmış olup seçilen her bir özellik sayısı için yeni özellik kümesi oluşturularak performansa etkileri incelenmiştir. Sol göz EOG sinyalinin zaman ortamında maksimum, minimum, genlik değerinin, EEG sinyalinin spektrumundan elde edilen Alpha Slow Wave Index (ASI) değerinin, sol göz EOG sinyalinde zaman ortamında elde edilen entropy değerinin ve son olarak EEG sinyalinden zaman ortamında elde edilen maksimum minimum genlik değerinin sistem başarısını %69.30 yaptığı anlaşılmıştır.

Güneş ve ark. (2010), diğer çalışmalardan farklı olarak bu çalışmada sadece EEG sinyali kullanmıştır. Sinyal, Selçuk Üniversitesi Meram Tıp Fakültesi uyku

laboratuvarındaki PSG cihazından elde edilmiştir. EEG sinyalinin 129 tane frekans ortamında özellikler çıkarılmıştır. Frekans ortamında özellikler çıkarılması için Welch metodu kullanılmıştır. 129 özellik 4 özelliğe indirilmiştir. Bu 4 özellik istatistikî özelliklerdir. Bu özellikler KMCFW (K-Means Clustering Based Feature Weighting) yöntemi ile ağırlıklandırılmıştır. Daha sonrasında sınıflandırma için K-NN ve Karar Ağaçları kullanılmıştır. Özellikler ağırlıklandırmadan önce k-NN ve Karar ağacı kullanarak sınıflandırma yapıldığında başarı %55.88 olarak hesaplanmıştır. Ağırlıklı özellikler ile sınıflandırma yapıldığında başarı %82.15 olduğu görülmüştür.

Ersöz ve Özşen (2011), çalışmalarında kullandıkları EEG sinyali Meram Tıp Fakültesi uyku laboratuvarında PSG cihazından kaydetmişlerdir ve bu sinyali kullanarak uyku evreleme işlemi yapmışlardır. EEG sinyali epoklara ayırdıktan sonra her epoka Ayırık Dalgacık Dönüşümü uygulayarak sinyali ayırtmıştır ve Alfa, Beta, Delta, Teta alt bantlarına ulaşmıştır. Alt bantlarından zaman domeninde ortalama, maksimum, minimum, standart sapma, enerji özellikleri, frekans domeninde alt bantların gücü özellikleri çıkarılarak toplamda 15 özellik ile uyku evreleme işlemi yapılmıştır. Sınıflandırma yapmak için Yapay Sinir Ağı yapısı kullanılmıştır. Çalışmanın başarısının %80 olduğu görülmüştür.

Uçar ve ark. (2014), sadece EEG sinyali kullanılarak evreleme işlemi yapmışlardır. EEG sinyali, Sakarya Hendek Devlet Hastanesi Göğüs Hastalıkları uyku laboratuvarında bulunan PSG cihazında kaydedilmiştir. Diğer çalışmalara göre farkı gürültüyü azaltmak için sayısal filtreler kullanılmıştır. Çalışma iki kola ayrılmıştır. EEG sinyalinin öncelikle sayısal filtreleme işlemi uygulanmadan özellik çıkarma işlemi yapılmıştır. Çıkarılan özellikler Olasılıksal Yapay Sinir Ağları kullanılarak sınıflandırılmıştır. Bu işlemdeki başarı %69.32 olarak hesaplanmıştır. Daha sonra sayısal filtreleme yapılmıştır. Sayısal filtreler, FIR ve IIR'dir. Bu filtreler de kendi içlerinde yöntemlere ayrılmaktadır. En iyi sonucu sağlayan %86,45 başarı ile IIR Chebyshev Type 2 olduğu görülmüştür.

Aydoğan ve ark. (2015), çalışmalarında beynin santral, frontal ve oksipital bölgelerinden alınan 6 adet EEG sinyali, sağ göz ve sol gözden alınan 2 adet EOG sinyali ve çeneden alınan 1 adet EMG sinyali kullanılmıştır. EEG, EOG ve EMG sinyalleri Kahramanmaraş Sütçü İmam Üniversitesi uyku laboratuvarında yatan uyku apnesine sahip hastalardan PSG cihazı ile kaydedilmiştir. Toplamda 33 özellik çıkarılmıştır. Bu özellikler; her bir EEG sinyaline ait enerjisi, etkin değeri, ortalaması, standart sapması, ortalama frekansı özellikleri, delta, teta, alfa, sigma, beta bantlarını gücü, sol ve sağ göz

EOG sinyallerinin gücü, çene EMG sinyalinin gücüdür. Çıkarılın 33 özellikten ve sınıf etiketlerinden oluşan veri seti %70'i eğitim %30'u test için ayrılarak ANN ile sınıflandırılmıştır. Elde edilen başarı %90.8'dir. Sonrasında 10 katlı çapraz doğrulama yapılmıştır. Veriler %90 eğitim %10 test olarak ayrılmıştır. Bu işlemdeki başarı ise %90,4 olarak görülmüştür.

Alickovic ve Subasi (2018), Physionet sitesinden herkesin erişim sağlayabileceği veri setlerinde sadece EEG sinyalinin kullanarak evreleme işlemi yapmıştır. Evreleme işlemi yapmadan önce EEG sinyali Temel Bileşen Analizi yöntemi ile özellik boyutunun azaltılması sağlanmıştır. Sinyalin alt bantlarına Ayrık Dalgacık Dönüşümü yöntemi ile ulaşılmıştır ve her bir alt banttan alt banttaki katsayıların mutlak değerlerinin ortalaması, ortalama gücü, standart sapması, bitişik alt bantların mutlak ortalama değerlerinin oranı, her bir alt bandın Skewness değeri, Kurtosis değeri özellikleri çıkarılmıştır. Toplamda 41 özellik ile evreleme işlemi yapılmıştır. Çalışmada sınıflandırıcı olarak Ensemble sınıflandırıcılardan biri olan Rotational SVM sınıflandırıcı kullanılmıştır. 5 sınıflı evreleme sonucu %91.1 olarak belirlenmiştir.

Michielli ve ark. (2019), çalışmalarında Physionet sitesindeki Sleep-EDF veri setini kullanmışlardır. EEG sinyalinden zaman ve frekans ortamında toplamda 55 özellik çıkarılmıştır. Zaman ortamında, ortalama, varyans, standart sapma, Hjorth parametreleri, medyan, ortalama karekök, tepeden tepeye genlik, zero crossing özellikleri çıkarılmıştır. Frekans ortamında, ortalama frekans, spektral entropi, reny entropi özellikleri kullanılmıştır. Çalışmada sınıflandırma yapmak için iki tür sınıf seçeneği vardır. W, NREM1, NREM2, NREM3, REM olmak üzere 5 sınıflı ve NREM, REM olmak üzere 2 sınıflı LSTM-RNN yapısı oluşturulmuştur. Özellik seçme yöntemi olarak 4 sınıflı yapı için Minimum Redundancy Maximum Relevance (mRMR) yöntemi, 2 sınıflı yapı için Temel Bileşen Analizi (PCA) yöntemi kullanılmıştır. 4 sınıflı yapıda elde edilen başarı %90,8 iken 2 sınıflı yapıdaki başarı %83.6'dır.

Kumari ve ark. (2019), Physionet sitesinden apne teşhisi konulan hastaların EEG sinyalinin kullanarak uyku apnesi tipinin belirlenmesi üzerine çalışma yapmışlardır. 3 tür apne tipi vardır. Obstructive (Tıkalı), Central (Merkezi) ve Mixed (Karışık) uyku apnesidir. EEG sinyali Ayrık Dalgacık Dönüşümü kullanılarak alt bantlarına (Alfa, Beta, Delta, Teta, Gama) ayrılmıştır. Sinyalin alt bantlarından enerji, varyans, standart sapma, ortalama (mean), ortanca (median), maksimum, minimum özellikleri çıkarılmıştır ve her hasta için karın hareketleri, burun akışı, göğüs kafesi hareketleri, horlama tanımlanmıştır. Bu özellikler, apne tipinin belirlenmesi için kullanılmıştır.

Al-Salman ve ark. (2019), çalışmalarında Mons Üniversitesi-TCTS Laboratuvarında sekiz farklı hastadan elde edilen EEG sinyalinin uyku iciklerini tespit etmek amacıyla kullanmışlardır. Öncelikle EEG sinyali kayan pencere tekniğı kullanılarak 0.5 sn uzunluklu pencereler ile segmentlere ayrılmıştır. Her bir segment ulaşmak istenen frekans bantlarını (Alfa, Beta, Delta, Teta, Gama) tanımlamak için Ayrık Dalgacık Dönüşümü ve Fast Fourier Dönüşümünün kombinasyonu ile oluşturulmuş Dalgacık Fourier Dönüşümünden geçirilmiştir. Elde edilen frekans bantlarından Ortanca (Median), Minimum, Maksimum, Ortalama (Mean), Mod, Standart Sapma, Varyans, Skewness, Kurtosis özellikleri çıkarılmıştır. Sınıflandırıcı olarak, kNN, k-Means, Karar Ağaçları ve SVM kullanılmıştır. En iyi başarıyı veren %97.5 ile SVM olduğu görülmüştür.

Casal ve ark. (2019), çalışmalarında kalp atış hızı (heart rate) sinyalinin kullanarak hastanın uyanık mı yoksa uykuda mı olduğuna karar veren bir sistem önermiştir. Çalışmada kullanılan sinyaller, Uyku Kalp Sağlığı Çalışması (Sleep Heart Health Study) veri setinden elde edilmiştir. 5000 veri 2 alt kümeye ayrılmıştır. 500 tanesi çalışmanın tasarım aşamasını optimize bir şekilde çalışması için ve özellik seçimi için kullanılmıştır. Entropi, Karmaşıklık ölçüleri, Frekans ve Zaman domenli ölçekli metotlar, klasik istatistiki yöntemler kullanılarak 70 özellik çıkarılmıştır. 4500 veri eğitim ve test aşamasında sınıflandırmak için kullanılmıştır. Sinyal tasarım aşamasında 30 sn uzunluklu pencerelere ayrılmıştır. Her bir pencere bir durumu barındırmaktadır. Durumlar Awake ve Asleep şeklindedir. SVM sınıflandırıcı kullanılarak sınıflandırma işlemi yapılmıştır. Çalışmanın başarısı %85.2'dir.

Basha ve ark. (2020), çalışmalarında herkese açık veri tabanından (Kemp 2000) elde ettikleri EEG sinyalinin kullanarak uyku evreleme yapmışlardır. EEG sinyaline band geçiren filtresi uygulanarak alt bantlar olan Alfa, Beta, Delta, Teta alt bantlarına ulaşılmıştır. Alt bantlar üzerinde özellik çıkarma işlemi uygulanmıştır. Çıkarılan özellikler, ortalama, standart sapma, Hjorth Parametreleri, Renyi Entropi, Kraskov Entropi, Kurtosis, enerjidir. Çalışmanın sınıflandırma kısmında Fuzzy Kernel SVM ve Simple Recurrent Network (SRN) kullanılmıştır. SRN yapısı İleri Beslemeli Ağ (Feed Forward Network) ve Yenilenen Sinir Ağı (Recurrent Neural Network) olmak üzere iki ana bölümden oluşmaktadır. İki yapı beraber kullanılmıştır ve elde edilen başarı %90.2'dir.

Huang Wu ve ark. (2020), diğer çalışmalardan farklı olarak EEG sinyalinin tek kanalıyla işlem yapmak yerine çoklu kanalları ile uyku evreleme yaptığı görülmüştür.

Kullanılan EEG sinyali, Physionet sitesinden MIT-BIH veri setinden elde edilmiştir. Sinyale öz işlem olarak çok kanallı sinyal süper pozisyonu uygulanmıştır. Daha sonra özellik çıkarma işlemi uygulanmıştır. Zaman, frekans ve lineer olmayan ortamlardan toplamda 62 özellik çıkarılmıştır. Relief algoritması kullanılarak 62 özellik 14 özelliğe indirilmiştir. Sonrasında bu 14 özelliğe Pearson Korelasyon Katsayısı uygulanarak 12 özellik seçilmiştir ve sınıflandırma 12 özellik ile yapılmıştır. Sınıflandırma işlemi SVM kullanılarak yapıldığı görülmüştür. Sistem başarısı %98.28'dir.

Yang ve Liu (2020), çalışmalarında Physionet sitesinden ulaştıkları CAP uyku veri setindeki EEG sinyalini insomnia hastalığının tespiti için kullanmıştır. Bu çalışmayı yaparken tek boyutlu Evrişimli Sinir Ağı yapısı ile insomnia tespiti yapılmıştır. 9 sağlıklı ve 9 insomnia hastasından alınan EEG sinyaline sonlu darbe cevabı (FIR) uygulanarak gürültüsü azaltılmıştır. Daha sonra Hjorth parametreleri ve güç özelliği sinyalden elde edilmiştir. Sinyal 4 alt kümeye ayrılmıştır. Tüm uyku evreleri alt kümesi (ALL-DS), REM uyku evresi alt kümesi (REM-DS), hafif uyku evresi alt kümesi (LSS-DS) ve uyku evresi alt kümesi (SWS-DS). Bu 4 alt küme sırasıyla Evrişimli Sinir Ağına verilmiştir. REM ve SWS alt kümeleri diğer data setlere göre en iyi sonuçları vermiştir. REM ve SWS alt kümelerinden elde edilen başarı sırasıyla %98.98 ve %99.16'dır.

Taran ve ark. (2020), uyku evreleme yapmak için Physionet tarafından herkese açık olan EEG sinyallerini kullanmışlardır. Çalışmada EEG sinyallerinin alt bantlarına ulaşabilmek için Optimize Esnek Analitik Dalgacık Dönüşümü (Optimize Flexible Analytic Wavelet Transform (OFAWT)) kullanılmıştır. Alt bantlara ulaşıldıktan sonra her bir alt banttı ortalama genlik değışikliğı (Average Amplitude Change (AAC)), boşluk faktörü (Clearance Factor (CLF)), çeyrekler arası aralık (Interquartile Range (IQR)) ve basit kare integral (Simple Square Integral (SSI)) özellikleri elde edilmiştir. Sırasıyla 6 sınıflı, 5 sınıflı, 4 sınıflı, 3 sınıflı ve 2 sınıflı olmak üzere toplamda beş farklı uyku evre kategorisi oluşturulmuştur. Karar ağaçları, Diskriminant Analiz, KNN ve Ensemble sınıflandırıcıları sınıflandırma işlemi için kullanılmıştır. En iyi sonuç, Ensemble Sınıflandırıcı olan Bagged Tree 'den alınmıştır. 2 sınıflı Bagged Tree modelinin başarısı %99.36'dır.

Liu ve ark. (2021), çalışmalarında EEG sinyali kullanarak evreleme işlemi yapmışlardır. Ancak bu çalışmada 3 ayrı veri seti ile evreleme işlemi yapılmıştır ve hangi veri setinin evrelemede daha iyi sonuç vereceğı incelenmiştir. Bu veri setleri Physionet'ten elde edilen Sleep EDF veri seti, the DREAMS Subjects veri seti, Sleep Heart Health Study'nin veri setidir. Çalışmada, EEG sinyalinin alt bantlarına ulaşabilmek


için her bir epoğa Ensemble EMD metodu uygulanmıştır. Ensemble EMD sonucunda her bir epoktan 7 tane İçsel Mod Fonksiyonları (Intrinsic Mode Function - IMF matrislerine ulaşılmıştır. IMF'ler incelendiğinde IMF1'in betay₁, IMF2'nin alfay₁, IMF3'ün tetay₁, IMF4, IMF5, IMF6 ve IMF7'nin deltay₁ barındırdığı görülmüştür. IMF'lerin her birinden özellikler çıkarılmıştır. Sınıflandırma işlemi yapılırken eXtreme Gradient Boosting (XGBoost) algoritması kullanılmıştır. Hem 5 sınıflı hem de 4 sınıflı XGBoost modeli oluşturulmuş ve her üç veri seti için de uyku evreleme yapılmıştır. En iyi sonucu %93,1 ile 4 sınıflı Sleep EDF veri setinde alınmıştır.

An ve ark. (2021), EEG sinyalinin Physionet sitesindeki Sleep-EDF veri setinden elde etmişlerdir. Bu EEG sinyalinin kullanarak evreleme işlemi yapmışlardır. Çalışma NREM evresini S1 olarak belirtmiştir. Çalışmada yalnızca S1 ve REM evrelerinin tespiti üzerine yoğunlaşmıştır. EEG sinyalinin alt bantlarına ulaşabilmek için Fast Fourier Transform kullanılmıştır. Sinyalin alt bantlarından özellikler çıkarılmıştır ve sınıflandırıcı olarak SVM kullanılmıştır. Sistem başarısı %93'tür.

Li ve ark. (2022), çalışmalarında Physionet sitesinden elde ettikleri EEG, EOG ve EMG sinyallerini kullanmışlardır. Sinyallerin alt bantlarına ulaşmak için FIR bant geçiren filtresi uygulanmıştır. Sınıflandırma yapmak için Random Forest algoritması kullanılmıştır. Çalışma iki ayrı kola ayrılmıştır. Öncelikle EOG ve EMG sinyalleri ile evreleme işlemi yapılmıştır. EOG sinyalinden 108, EMG sinyalinden 6 özellik çıkarılmış ve toplamda 124 özellik ile yapılan evreleme başarısı %80,8'dir. Daha sonrasında bu özelliklere ek olarak EEG sinyalinden de 324 özellik çıkarılmıştır. Toplamda 438 özellik ile uyku evreleme yapılmıştır ve %84,7 başarıya ulaşılmıştır.

3. MATERYAL VE YÖNTEM

Bu tez çalışması, TÜBİTAK 119E127 numaralı proje kapsamında gerçekleştirilmiştir (Etik Kurul Raporu 2017/287). Çalışmada kullanılan veri seti, Necmettin Erbakan Üniversitesi Meram Tıp Fakültesi Uyku Laboratuvarında PSG cihazı ile kaydedilen EEG sinyallerinden oluşmaktadır. EEG sinyalleri öncelikle 30 sn'lik epoklara ayrılmıştır. Tez çalışması, üç aşamalı olarak gerçekleştirilmiştir. İlk olarak, EEG sinyalinin ham hali ile uyku evreleme işlemi yapılmıştır. Daha sonra, sinyallerden elektrot kopmaları silinerek temiz veri seti elde edilmiştir. Ham ve temiz veri setleri ile üç sınıf uyku evreleme yapılarak elde edilen performanslar karşılaştırılmıştır. Son olarak, en iyi sonucu veren veri seti ve yöntem ile kişinin uyku apnesinin uyku evreleri ya da uyku pozisyonu ile ilişkili olup olmadığı kontrol edilmiştir. Uyku evreleme işlemi, Matlab'ın Classification Learner uygulaması ile gerçekleştirilmiştir. Şekil 3.1'de tez çalışmasının blok diyagramı verilmiştir.




Şekil 3.1. Tez çalışmasının blok diyagramı

3.1. Veri Seti

Gerçekleştirilen tez çalışmasında Necmettin Erbakan Üniversitesi Meram Tıp Fakültesi Uyku Laboratuvarında PSG cihazı ile kaydedilen EEG sinyalleri kullanılmıştır. Polisomnografi, apne, uyku kalitesi ve uykuya dair bozuklukların tanısında kullanılan ve gece uykusu boyunca hastanın beyin dalgaları (EEG), göz hareketleri (EOG), solunum faaliyetleri, kanındaki oksijen yüzdesi, kas aktivitesi (EMG) gibi sinyallerin bütün gece boyunca kaydedilmesi ile yapılan incelemenin adıdır. Bu inceleme PSG cihazı ile yapılmaktadır.

PSG cihazı ile kayıt yapılırken, hastanın uyku laboratuvarında bir gece geçirmesi istenir. Kayıt yapılacak hastanın vücudunun belirli bölgelerine çeşitli elektrotlar ve sensörler takılır. Şekil 3.2’de PSG kaydı gösterilmektedir.




Şekil 3.2. PSG kaydı (Göğüş, 2020)

PSG cihazında eşzamanlı olarak birden fazla sinyal kaydı yapılmaktadır. EEG, EKG, EMG, EOG gibi sinyallerin yanı sıra kandaki oksijen seviyesi, vücut pozisyonları da kaydedilir. EEG sinyali, uyku ile ilgili bozuklukların incelenmesinde kullanılan en önemli sinyallerden biridir. EEG sinyalinin dört ana alt dalgası mevcuttur. Alt dalgaların bulundukları frekans aralıkları Çizelge 3.1’de verilmiştir.

Çizelge 3.1. EEG Dalgalarının frekansı ve oluştukları durumlar.

EEG Dalga Tipi	Frekans Aralıkları	Uykudaki Yeri
Delta Dalgası	Frekansı 3 Hz altındaki beyin dalgalarıdır.	Derin uyku halinde oluşur.
Teta Dalgası	Frekansı 4-7 Hz arasındaki beyin dalgasıdır.	Uykulu halde uykunun ilk aşamasında oluşur.
Alfa Dalgası	Frekansı 8-12 Hz arasındaki beyin dalgasıdır.	Uyanık,normal ve sakin zamanlarda oluşur.
Beta Dalgası	Frekansı 12 Hz üzerindeki beyin dalgasıdır.	Merkezi sinir sisteminin kuvvetli aktivasyonunda veya gerginlik hallerinde ortaya çıkar.

EEG sinyalinin Alfa, Beta, Delta, Teta alt bantları uykunun evreleri ile de ilişkilidir. Sinyal incelendiğinde oluşan dalganın hangi alt banda ait olduğu ve o alt bandın hangi evre içerisinde olduğu bilgisi anlaşılmaktadır. Uyku evreleme yapmak için alt bantların evreler ile olan ilişkisinden yararlanılır. Şekil 3.3'te alt bantların hangi evrelerde görüldüğü bilgisi verilmiştir.



Şekil 3.3. Uyku evreleri ve beyin dalgaları ilişkisi (Köktürk, 2013)

Bu tez çalışmasında 200 Hz örnekleme frekansına sahip, toplamda 124 kişiden elde edilen EEG sinyali uyku evreleme amacıyla kullanılmıştır. 124 kişinin 94'ü hasta, 30'u sağlıklı kişilerdir. Bu 124 kişinin, ortalama yaşı $51 \pm 13,61$ ve ortalama Vücut Kitle Index (Body Mass Index-BMI) değeri 32.81 ± 5.16 'dır. Ayrıca, 124 hastanın hiçbirisi REM ve/veya pozisyon bağımlı olmadığı için ilave olarak 9 hastanın PSG sinyalleri ve sonuç raporları elde edilmiştir. Bu 9 hasta ile apnenin evre ve pozisyon ilişkisi test edilmiştir.

Bu çalışmada kullanılan bütün sinyallerin, uyku uzmanları tarafından skorlanmaları 30 sn uzunluğundaki epoklar dikkate alınarak yapılmıştır. Bu skortlama, epokların apneik olup olmamasını, evresini ve uyku pozisyonunu gösterecek şekilde gerçekleştirilmiştir. Skorlanmış sinyaller kullanılarak bu tez çalışmasında da doğru şekilde sınıflandırma yapabilmek için aynı şekilde 30 s'lik epoklarla çalışılmıştır.

3.2. Ön İşlem

Çalışmada kullanılan EEG sinyali sistem başarısının artırılması için birtakım ön işlemlerden geçirilmiştir. Öncelikle EEG sinyali 30 sn'lik epoklara ayrılmış ve her epok skorlanan uyku evrelerine (Wake, NREM ve REM) göre sırasıyla -1, 0 ve 1 olarak etiketlenmiştir. Böylece elde edilen ve ham olarak adlandırılan veri seti ve her bir epoğa filtreleme işlemi uygulanarak elde edilen temiz veri seti ile ayrı ayrı uyku evreleme işlemi yapılmıştır. Temiz veri seti elde etmek için elektrot kopması bulunan epoklar tespit edilerek silinmiştir.

3.2.1. Elektrot Kopması

Elektrot kopması, kişiden kayıt alındığı sırada uyku esnasında, elektrotların terleme, gerilme gibi nedenler ile çıkmasından kaynaklı sinyalin kaydedilememesi ve sinyalde kopukluklar olması durumlarını ifade etmektedir. Bu durumlar, sinyallerde gürültü oluşmasına neden olmakta ve evrelerin hangi epoğa ait olduğunun tespitini güçleştirmektedir. Bundan dolayı sinyal üzerinde gürültü temizleme işleminin yapılmasının uyku evrelemenin başarısını etkileyeceği düşünülmüştür.

Örnekleme frekansı 200 Hz olan EEG sinyalinde elektrot kopmaları filtreleme işlemi yapılarak silinmiştir. Sinyale aşırı filtreleme uygulanması durumunda önemli detaylar kaybolabilir. Her sinyale öncelikle çentik filtre (Şebeke frekansı 50/60Hz) uygulanmıştır. Daha sonra, EEG sinyali 0.5-35 Hz frekans aralığında 6.dereceden

Butterworth bant geçiren filtre ile filtrelenmiştir ve içerisinde bulunan elektrot kopmaları temizlenmiştir (Koca 2022).

Çizelge 3.2’de ham veride bulunan evre sayısı ve temizlenmiş veride bulunan evre sayıları verilmiştir. Çizelge 3.2’den de görüldüğü gibi temizlenmiş veri seti, toplamda 6217 gürültülü epok silinerek elde edilmiştir. Ham veri setinde de temiz veri setinde de uyku evrelerine göre epok dağılımı dengeli değildir. Özellikle REM evresinin yaşandığı epok sayısı oldukça azdır. Bu da REM evrelerinin tespit edilmesinde önemli bir dezavantajdır.

Çizelge 3.2. Evre sayıları

Veri seti	Wake	NREM	REM	Toplam
Ham	17.415	44.474	5.594	67.483
Temizlenmiş	14.476	41.372	5.418	61.266

3.3. Özellik Çıkarma Yöntemleri


Bu tez çalışmasında, EEG sinyallerinin farklı niteliklerini tespit edebilmek amacıyla farklı özellik çıkarma yöntemleri kullanılarak üç farklı özellik seti elde edilmiştir.

3.3.1. Ayırık Dalgacık Dönüşümü (Discrete Wavelet Transform- DWT)


Dalgacık Dönüşümü (Wavelet Transform- WT), işlenmemiş sinyali içerdiği farklı frekans bileşenlerine ayıran her bir bileşeni kendi skala değerine göre bir çözünürlükte inceleyen bir matematiksel dönüşüm fonksiyonudur. Bir sinyalin zaman-frekans analizi için kullanılan bir yöntemdir. Dalgacık temelli sinyal analizinin durağan olmayan sinyaller ve nümerik sinyal işleme üzerine pek çok uygulama olanağı vardır. Ses ve işaret işleme, görüntü ve video işaretleri işleme, haberleşme, jeofizik, ekonomi ve tıp gibi özellikle bir boyutlu ve iki boyutlu işaret işleme uygulamalarında yoğun olarak kullanılmaktadır (Ersöz ve Özşen, 2011).

Dalgacık terimi, küçük dalga anlamında dalgacık olarak ifade edilir. Bu küçük dalga, belirli uzunlukta pencere fonksiyonu olarak tanımlanabilir. Farklı özellik ve kullanım amaçlarına sahip birçok ana dalgacık mevcuttur. Dalgacık dönüşümünde kullanılan bazı ana dalgacık fonksiyonları Şekil 3.4’de verilmiştir (Öner ve ark., 2017). Ayırık Dalgacık Dönüşümü, birden fazla seviyede uygulanabilmektedir. Ölçek değerleri

2'nin kuvvetleri şeklinde seçilerek yalnızca belirli noktalarda dalgacık katsayıları hesaplanmakta ve böylece işlem sayısı azaltılmaktadır. Ayırık dalgacık dönüşümü kullanılarak, alt bantlardan yaklaşım (A) ve detay katsayıları (D) elde edilir. Yaklaşım katsayıları, alçak frekans bileşenlerini, detay katsayıları, yüksek frekans bileşenlerini içerir. Bir sinyalden istenen bilgi genellikle alçak frekans bileşenlerinde bulunur. Bir sinyale birden fazla seviyede DWT uygulanabilir (Yılmaz ve Bozkurt, 2013). Bir seviyeli DWT'nin bir $X[n]$ sinyaline uygulanması Şekil 3.5'te verilmiştir.



Şekil 3.4. Ana dalgacık fonksiyonları (Budu, 2014)



Şekil 3.5. Bir seviyeli DWT işlemi

Bu tez çalışmasında, 200 Hz örnekleme frekansı dikkate alınarak EEG sinyalinin alt bantlarına ulaşmak için 6.dereceden DWT, uygulanmıştır. 4.seviyenin detay katsayısında Beta dalgasına, 5.seviyenin detay katsayısında Alfa dalgasına, 6.seviyenin detay katsayısında Teta dalgasına ve 6.seviyenin yaklaşımlar katsayısında ise Delta dalgasına ulaşılmıştır. Bu işlemde, EEG sinyaline en uygun dalgacık tipi olan ‘Daubechies-2’(db2) dalgacığı seçilmiştir (Kumari ve ark., 2019). Elde edilen Beta, Alfa, Teta ve Delta alt bantları özellik çıkarmak için kullanılmıştır. Bu alt bantlardan özellik çıkarılırken hem zaman domeninden hem de frekans domeninden istatistiki özellikler hesaplanmıştır.

3.3.2. Tekil Değer Ayrışımı (Singular Value Decomposition- SVD)

Bir matrisin tekil değerlerine ayrılması demek, matrisin çarpanlarına ayrılması demektir. SVD, matrisi üç parçaya ayırarak tutar. Sinyal işleme, görüntü damgalama, istatistikler gibi pek çok alanda kullanılmaktadır. Herhangi bir $m \times n$ boyutlarındaki A matrisi ($A = [a_1 \ a_2 \ a_3 \ a_4 \dots a_n]$) SVD yöntemi ile Denklem 3.1’de verilen U, S, V matrislerine dönüştürülür.

$$A = USV^T \quad (3.1)$$

Burada U $m \times n$ ve V^T , $n \times n$ boyutunda ortogonal matrislerdir. S ise $n \times n$ boyutlarında bir köşegen matristir ve tekil değerleri tutmaktadır (Doğan, 2011).

3.3.3. Güç Spektral Yoğunluğu

Bu tez çalışmasında, sinyalin frekans özelliklerini elde edebilmek için Welch metodu kullanılmıştır. Çizelge 3.3’te “Frekans domeni” olarak belirtilen özellikler, Welch metodu ile sinyalin frekans alanına ulaşılmasından sonra elde edilmiştir. Bir sinyale uygulanan spektral analiz yöntemleri parametrik ve parametrik olmayan şeklinde iki kategoride incelenmektedir. Welch metodu, Fourier Dönüşümü yöntemine dayanan bir parametrik olmayan spektral analiz yöntemidir. Bir sinyalin frekans bileşenlerinin güç spektral yoğunluğunu bulmak için periodogram yöntemi kullanılır. Periodogram yöntemi, sinyalin güç spektral yoğunluğunu elde etmek için sinyal örneklerinin ayırık zamanlı Fourier dönüşümünü bulduktan sonra sonucun genlik bazında karesini alır

(Yücelbaş, 2017). Bir EEG sinyalinin periodogram yöntemi ile güç spektral yoğunluğunun elde edilmesi için, EEG işareti 64, 128, 256... şeklinde 2'nin üssü olacak şekilde pencerelere ayrılır. Welch metodu, sinyali segmentlere ayırıp, bu segmentlere periodogram uyguladıktan sonra ortalamasını alarak hesaplanır. Welch metodu, periodogramı yönteminin değiştirilmiş halidir. Burada önemli olan segmentlerin belli bir oranda çakışmasıdır (Yücelbaş, 2017). Denklem 3.2'de i.inci iyileştirilmiş periodogramı denklemi verilmiştir (Yücelbaş, 2017).

$$\hat{P}_{xx}^{(i)}(f) = \frac{T_s}{KM} \left| \sum_{n=0}^{M-1} x_i(n)w(n).e^{-j2\pi fn} \right|^2 \quad (3.2)$$

Denklem 3.2'de, $f = f_s$ normalize edilmiş frekans değişkeni, T_s örnekleme faktörü, $w(n)$ pencereleme fonksiyonu, M pencere sayısı ve K Denklem 3.3'te belirtildiği gibi normalize sabitidir (Yücelbaş, 2017).

$$K = \frac{1}{M} \sum_{n=0}^{M-1} w^2(n) \quad (3.3)$$

Welch metodunun güç spektral yoğunluğu Denklem 3.4 ile hesaplanmaktadır (Yücelbaş, 2017).

$$\hat{P}_{xx}^W(f) = \frac{1}{L} \sum_{i=0}^{L-1} \hat{P}_{xx}^{(i)}(f) \quad (3.4)$$

Burada L , işaretin uzunluğudur. Bu tez çalışmasında, Welch yöntemi parametresi L 200 olarak seçilmiştir. L uzunluğunda dikdörtgen pencere seçilmiş ve örtüşme oranı pencere boyutunun yarısı olarak belirlenmiştir.


3.3.4. Ampirik Mod Ayırıştırma (Empirical Mode Decomposition-EMD)

EMD, herhangi bir sinyalin farklı salınımlar yapan basit alt sinyallerin toplamından oluştuğu düşüncesine göre işlemler yapar. Bu alt sinyaller, İçsel Mod Fonksiyonlarıdır (Intrinsic Mode Function – IMF). Sinyalden IMF çıkarma işlemine eleme denilir (Tosun ve Çetin, 2021). Bir sinyal n adet IMF'ye ayrılabilir. Bu işlem yapılırken IMF sonucunda ek olarak kalıntı adı verilen bir sinyal daha oluşmaktadır.

IMF'ler Hilbert Huang Transform yöntemi ile bulunmaktadır. Bunun için öncelikle sinyalin minimum ve maksimum noktaları belirlenmektedir. Bu belirlenen noktalar, yukarı ve aşağı zarf adı verilen iki fonksiyondan oluşur. Yukarı zarf ve aşağı zarf fonksiyonlarının ortalaması alınmaktadır. Orijinal sinyalden daha düşük frekanslı bir sinyal elde edilir. Yukarı zarf ve aşağı zarf fonksiyonlarının ortalamalarının orijinal sinyalden çıkarılması ile IMF elde edilir (Tunçer ve ark., 2017). Her IMF'nin iki koşulu sağlanması gerekmektedir:

1. Maximum ve minimum nokta sayıları ile sıfır geçiş noktası sayısı aynı veya aralarında bir fark olmalıdır,
2. Yerel ortalama sıfıra eşit olmalıdır.

Bu iki şart sağlanana kadar IMF bulma işlemi devam eder (Tunçer ve ark., 2017). IMF bulma işlemi, bir önceki bulunan IMF üzerinden elde edilir. Uyku evrelemede özellik çıkarmak amacıyla doğrusal olmayan sinyallerde kullanılan bir yöntem olan EMD, bu tez çalışması kapsamında da EEG sinyallerinden özellik çıkarmak amacıyla kullanılmıştır. Özellik seti 2'de (ÖS2) EEG sinyalinden özellik çıkarma işlemi yapılırken IMF sinyallerinin ilk 4 tanesi (IMF1-IMF4) kullanılmıştır. Şekil 3.6'da örnek bir sinyalden çıkarılan IMF'ler verilmiştir.



Şekil 3.6. Örnek bir sinyalden çıkarılan IMF sinyalleri a) IMF1 sinyali b) IMF2 sinyali c) IMF3 sinyali d) IMF4 sinyali e) IMF5 sinyali f) IMF6 sinyali g) IMF7 sinyali h) IMF8 sinyali

Şekil 3.6'ya bakıldığında, bir sinyalin ilk 4 IMF'si sinyale daha çok benzemektedir. IMF5 ve sonrasında genlik artmakta ve özellik çıkarılması için uygun sinyaller olmadığı düşünülmektedir. Bu sebeple elde edilen IMF'lerin IMF1, IMF2, IMF3 ve IMF4 özellik çıkarmada kullanılan sinyallerdir.

3.3.5. Varyasyon Mod Ayırıştırma (Variational Mode Decomposition-VMD)

Varyasyon Mod Ayırıştırma (VMD) yönteminin amacı, gerçek değerli bir giriş sinyali f'yi ayrık sayıda alt sinyale (mod) ayırıştırma (Dragomiretskiy ve Zosso, 2013). VMD, varyasyonel teknikler kullanarak bir sinyali IMF'lere ayırmaktadır. Her IMF modu için VMD, Hilbert dönüşümü aracılığıyla analitik sinyali oluşturur ve tek taraflı frekans spektrumunu hesaplar. Ardından modun spektrumu Fourier dönüşümünün yer değiştirme özelliğine göre temel banda kaydırılır ve sonrasında bant genişliği H1 Gauss düzgünlüğü ile tahmin edilir. Bunu yapmaktaki amaç IMF bant genişliklerinin toplamını minimize etmektir (Lian ve ark., 2018).

3.4. Zaman Özellikleri

Bu tez çalışması kapsamında “Zaman özellikleri” olarak tanımlanan kategoride aşağıda verilen özellikler çıkarılmıştır:

1. Minimum değer: Sinyalin en küçük değerini ifade etmektedir.
2. Maximum değer: Sinyalin en büyük değerini ifade etmektedir.
3. Ortalama değer:

$$X_o = \frac{1}{N} \sum_{i=1}^N X_i \quad (3.5)$$

N: Sinyal uzunluğu.

4. Standart Sapma

$$X_{ss} = \sqrt{\frac{1}{N} \sum_{i=1}^N (X_i - X_o)^2} \quad (3.6)$$

5. Eğrilik (Skewness) değeri

$$X_{skewness} = \frac{\sum_{n=1}^N (X(n) - X_o)^3}{(N-1)X_{ss}^3} \quad (3.7)$$

6. Basıklık (Kurtosis) değeri

$$X_{kurtosis} = \frac{\sum_{n=1}^N (X(n) - X_o)^4}{(N-1)X_{ss}^4} \quad (3.8)$$

7. Karekök Ortalama (Root Mean Square-RMS)

$$X_{rms} = \sqrt{\frac{1}{N} \sum_{i=1}^N X_i^2} \quad (3.9)$$

8. Entropi

$$X_{entropi} = - \sum_{i=1} p(X_i) \log p(X_i) \quad (3.10)$$

p: i. değerin olasılığını ifade etmektedir.

9. Enerji

$$E = \sum_{n=-\infty}^{\infty} |X[n]|^2 \quad (3.11)$$

10. Güç

$$G = \lim_{M \rightarrow \infty} \frac{1}{2M+1} \sum_{n=-M}^M X[n] \quad (3.12)$$

11. Hjorth Parametreleri

1970’te Hjorth tarafından, EEG sinyallerini zaman domeninde tanımlayabilmek için üç adet özellik tanımlanmıştır. Bu özellikler Hjorth parametreleri olarak bilinir. Bu üç özellik Etkinlik (Activity), Hareketlilik (Mobility) ve Karmaşıklık (Complexity) olarak isimlendirilir (Pourzare, 2012).

(a) Hareketlilik (Mobility)

$$\text{Hareketlilik (X)} = \frac{\sigma_{X'}}{\sigma_X} \quad (3.13)$$

(b) Karmaşıklık (Complexity)

$$\text{Karmaşıklık (X)} = \frac{\sigma_{X''}/\sigma_{X'}}{\sigma_{X'}/\sigma_X} \quad (3.14)$$

$\sigma_{X''}$: sinyalin ikinci türevinin standart sapmasıdır.

$\sigma_{X'}$: sinyalin birinci türevinin standart sapmasıdır.

12. İlgili bant değerleri ile sinyal değerlerinin oranı

13. Sinyalin tekil değerleri: Tekil değer ayrışımı yöntemi ile her bir alt banta ait tekil değerlerdir.

14. Relatif Güç: İlgili banda ait güç ile o bandın ait olduğu epoğun güçlerinin oranı olarak tanımlanmıştır.

3.5. Minimum Maximum Normalizasyon

Normalizasyon, veri setini standartlaştırmak için kullanılır. Standartlaştırmak, veri seti içerisindeki veriler arasındaki farklılığın çok fazla olduğu durumlarda verileri tek bir düzen içerisinde ele almaktır. Tez çalışmasında veri içerisindeki değerleri [0-1] aralığına dönüştürmek, minimum maximum normalizasyon yöntemi kullanılmıştır. Min-Max Normalizasyon yöntemi, özellik çıkarma işlemleri bittikten sonra hasta bazlı olarak uygulanmıştır. Denklem 3.15’te Min-Max Normalizasyon formülü verilmiştir. Denklem 3.15’te verilen X örnek bir veri kümesidir.

$$X^* = \frac{(X - \min(X))}{(\max(X) - \min(X))} \quad (3.15)$$

3.6. Relief Özellik Seçme Yöntemi

Özellik seçmedeki asıl amaç en etkin özelliklerin bulunup evreleme başarısının artırılmasıdır. Bu tez çalışması kapsamında çıkarılan özelliklere Relief özellik seçme uygulanarak evreleme başarısından alınan sonuçlar incelenmiştir. Kira ve Rendell (1992) tarafından önerilen Relief özellik seçme yöntemi, özellik seçimini özellik değerleri arasındaki bağımlılıklara göre yapmaktadır. Relief yönteminin mantığı ile komşuluk algoritmalarının mantığı birbirine benzemektedir. Bu yöntem özelliklerin bağımlılıklarını, veri setinde bulunan örneğin bulunduğu sınıftaki diğer örneklerle olan yakınlığı ve farklı sınıflar ile uzaklığını hesaplar. Özellik seçme yapılırken şu adımlar uygulanır (Yılmaz ve Sümer) :

1. Her sınıfa ait en yakın özellikler belirlenir,
2. Özelliklerin ağırlıkları belirlenir,
3. Hesaplanan özellik ağırlıkları sıralanır,
4. Bu ağırlıklara göre en iyi N kadar özellik seçilir.

Denklem 3.16'da özellik ağırlığını hesaplama formülü verilmiştir.

$$Relief_{skor(i)} = Relief_{skor(i-1)} - (x_i - A_i)^2 + (x_i - F_i)^2 \quad (3.16)$$

Denklem 3.16'da verilen A, aynı sınıfa ait en yakın özellik değerini, F, farklı sınıfa ait en yakın özellik değerini belirtmektedir. Bu tez çalışmasında da ağırlıklar hesaplandıktan sonra ağırlığı 10^{-4} 'ten büyük olan özellikler ile evreleme işlemi yapıldı.

Çizelge 3.3 ve Çizelge 3.4'te tez çalışmasında kullanılan özellik setleri ve çıkarılan özellikler belirtilmiştir. Çizelge 3.4 hem EMD hem de VMD yöntemleri ile çıkarılmış özellikleri göstermektedir. Özellik seti 2 (ÖS2) EMD ile Özellik seti 3 (ÖS3) ise VMD ile çıkarılmış özellikleri ifade etmektedir.

Çizelge 3.3. Özellik seti 1 (ÖS1) için tanımlanan özellikler

Num.	Özellik
ÖS1_1/ ÖS1_21/ ÖS1_41/ ÖS1_61	İlgili banda ait Minimum değer (Zaman domeni)
ÖS1_2/ ÖS1_22/ÖS1_42/ÖS1_62	İlgili banda ait Maksimum değer (Zaman domeni)
ÖS1_3/ ÖS1_23/ÖS1_43/ÖS1_63	İlgili banda ait Ortalama değer (Zaman domeni)
ÖS1_4/ ÖS1_24/ÖS1_44/ÖS1_64	İlgili banda ait Standart sapma (Zaman domeni)
ÖS1_5/ ÖS1_25/ÖS1_45/ÖS1_65	İlgili banda ait Skewness(çarpıklık) (Zaman domeni)
ÖS1_6/ ÖS1_26/ÖS1_46/ÖS1_66	İlgili banda ait Kurtosis(basıklık) (Zaman domeni)
ÖS1_7/ ÖS1_27/ÖS1_47/ÖS1_67	İlgili banda ait RMS değeri (Zaman domeni)
ÖS1_8/ ÖS1_28/ÖS1_48/ÖS1_68	İlgili banda ait Entropy (Zaman domeni)
ÖS1_9/ ÖS1_29/ÖS1_49/ÖS1_69	İlgili banda ait Enerji
ÖS1_10/ ÖS1_30/ÖS1_50/ÖS1_70	İlgili banda ait Güç
ÖS1_11/ ÖS1_31/ ÖS1_51/ÖS1_71	İlgili banda ait Hjorth Parametresi (Mobility)
ÖS1_12/ ÖS1_32/ ÖS1_52/ÖS1_72	İlgili banda ait Hjorth Parametresi (Complexity)
ÖS1_13/ ÖS1_33/ ÖS1_53/ÖS1_73	İlgili banda ait değerler/ Tüm dalga değerleri (Zaman domeni)
ÖS1_14/ ÖS1_34/ ÖS1_54/ÖS1_74	İlgili banda ait tekil değerler (SVD) (Zaman domeni)
ÖS1_15/ ÖS1_35/ ÖS1_55/ÖS1_75	İlgili banda ait relatif güç (Zaman domeni)
ÖS1_16/ ÖS1_36/ ÖS1_56/ÖS1_76	İlgili banda ait relatif güç (Frekans domeni)
ÖS1_17/ ÖS1_37/ ÖS1_57/ÖS1_77	İlgili banda ait ortalama değer (Frekans domeni)
ÖS1_18/ ÖS1_38/ ÖS1_58/ÖS1_78	İlgili banda ait standart sapma (Frekans domeni)
ÖS1_19/ ÖS1_39/ ÖS1_59/ÖS1_79	İlgili banda ait skewness (çarpıklık) (Frekans domeni)
ÖS1_20/ ÖS1_40/ ÖS1_60/ÖS1_80	İlgili banda ait kurtosis (basıklık) (Frekans domeni)


Çizelge 3.4. Özellik seti 2 (ÖS2) (EMD) ve Özellik seti 3 (ÖS3) (VMD) için tanımlanan özellikler

Num.	Özellik
ÖS2_1/ ÖS2_2/ÖS2_3/ ÖS2_4 ÖS3_1/ ÖS3_2/ÖS3_3/ ÖS3_4	IMF1/IMF2/IMF3/IMF4 ortalama değeri
ÖS2_5/ ÖS2_6/ÖS2_7/ ÖS2_8 ÖS3_5/ ÖS3_6/ÖS3_7/ ÖS3_8	IMF1/IMF2/IMF3/IMF4 standart sapması
ÖS2_9/ ÖS2_10/ÖS2_11/ ÖS2_12 ÖS3_9/ ÖS3_10/ÖS3_11/ ÖS3_12	IMF1/IMF2/IMF3/IMF4 varyasyon değeri
ÖS2_13/ ÖS2_14/ÖS2_15/ÖS2_16 ÖS2_13/ ÖS3_14/ÖS3_15/ÖS3_16	IMF1/IMF2/IMF3/IMF4 Fluctuation index değeri
ÖS2_17/ ÖS2_18/ÖS2_19/ ÖS2_20 ÖS3_17/ ÖS3_18/ÖS3_19/ ÖS3_20	IMF1/IMF2/IMF3/IMF4 Güç değeri
ÖS2_21/ ÖS2_22/ÖS2_23/ÖS2_24 ÖS3_21/ ÖS3_22/ÖS3_23/ÖS3_24	IMF1/IMF2/IMF3/IMF4 Sample Entropy değeri
ÖS2_25/ ÖS2_26 ÖS3_25/ ÖS3_26	IMF2/IMF4 Fractal Dimension değeri

3.7. Sınıflandırma Algoritmaları


3.7.1. Yapay Sinir Ağları (Artificial Neural Network- ANN)

Yapay Sinir Ağları (ANN), insan beyninin en önemli özelliği olan öğrenme, tecrübeler edinme, keşfetme gibi özellikleri dikkate alarak, beyni oluşturan biyolojik sinir hücrelerinin matematiksel modellenmesi ile oluşturulmuş bilgisayar sistemleridir. ANN, birbirine bağlı ve paralel olarak çalışan yapay hücrelerden (nöronlardan) oluşmuş bir yapıdır (Tezel, 2007). ANN yapısı, insan beyninin biyolojik sinir ağı yapısına benzemektedir. Şekil 3.6’da biyolojik sinir ağı yapısı ile ANN yapısı verilmiştir.



Şekil 3.6. Biyolojik sinir ağı yapısı ve Yapay sinir ağı yapısı benzerliği (Ayyüce, 2018)

ANN yapısı, giriş katmanı gizli katman ve çıkış katmanından oluşmaktadır. Katmanların her birinde nöronlar bulunmaktadır. Giriş katmanı ANN'e dış dünyadan girdilerin geldiği kısımdır. Bu katmanda bilgi işleme gerçekleşmez, gelen girdiler bir sonraki katmana aktarılır. Gizli (Ara) katman(lar), giriş katmanından çıkan bilgilerin aktarıldığı katmandır. Çıkış katmanı, ara katmandan gelen bilgileri işleyerek ağın çıktısını üreten katmandır. Bu katmanda üretilen çıkış değeri dış dünyaya gönderilir (Tezel, 2007). Şekil 3.7'de tek ve iki gizli katmanlı iki farklı ANN yapısı gösterilmiştir.




Şekil 3.7.a. Tek gizli katmanlı ANN b. İki gizli katmanlı ANN (Ayyüce, 2018)

Aynı katman içerisindeki nöronlar birbiri ile bağlantılı değildir. Nöronlar, sistemde öğrendikleri bilgiyi sonraki katmana aktarma işlemi görürler. Her bir nöron kendinden bir önceki ve bir sonraki katmanlardaki nöronlar ile bağlantılıdır. ANN'nin içerisinde toplam fonksiyonları ve aktivasyon fonksiyonları bulunmaktadır. Örneklerin çıktılarına göre bu fonksiyonlar seçilmektedir. Örneklerin belirli bir kısmı ile ANN

eğitilir ve daha sonra kalan kısmı ile test ettirilir. Test kısmı bize ANN'nin başarısını veren kısımdır.

Tez çalışmasında kullanılan iki ANN yapısı bulunmaktadır. Birinci ANN yapısı 2 gizli katmandan oluşmaktadır. Bu ANN yapısı ham veri ile temiz verinin sınıflandırılması için kullanılmıştır. Aktivasyon fonksiyonu, evre etiketleri -1 0 1 olduğu için Tanjant Sigmoid fonksiyonu transfer fonksiyonu olarak kullanılmıştır. İkinci ANN yapısı Matlabın Classification Learner Toolbox'ında bulunan hazır ANN yapısıdır. Şekil 3.8'da Tanjant Sigmoid fonksiyonunun grafiği gösterilmiştir.



Şekil 3.8. Tanjant Sigmoid Fonksiyonu

3.7.2. k En Yakın Komşu Algoritması (k Nearest Neighbors Algorithm- kNN)

k En Yakın Komşu algoritması (kNN), sınıflandırılması istenen verinin daha önce sınıflandırılmış veriler ile mesafesine göre sınıflandırma yapan bir makine öğrenmesi algoritmasıdır. Makine öğrenmesi yöntemleri arasında en basit ve az maliyetli sınıflandırma yöntemidir. kNN, sınıflandırılacak yeni verinin daha önce sınıflandırılmış kümedeki değerler ile uzaklığını hesaplar. En düşük uzaklığa sahip örnek hangi sınıfta ise yeni veriyi o sınıf ile etiketlemesine dayanmaktadır. Uzaklığı ölçmek için Minkowski, Manhattan, Dilca, Chebyshev ve Öklid gibi uzaklık ölçütleri kullanır. Uzaklığı hesaplamak için kullanılan ölçüt genelde Öklid mesafesidir. kNN, sınıflandırma yöntemi veri setini sınıflandırırken şu adımları izler (Göğüş, 2020) :

1. k değeri belirlenir.
2. Sınıflandırılacak örneğin, örnek kümesi içindeki her biri örnek ile uzaklığı hesaplanır.
3. Uzaklıklar sıralanır ve en yakın k adet örnek belirlenir.
4. Belirlenen k adet örneğin bulunduğu sınıflara bakılır ve en çok örneğin bulunduğu sınıf, yeni örnek için belirlenen sınıf olur.


3.7.3. Destek Vektör Makineleri (Support Vector Machine- SVM)

Destek Vektör Makineleri (SVM), sınıflandırma problemlerinde tercih edilen makine öğrenmesinin gözetimli öğrenme tekniklerinden biridir. SVM, 1999 yılında Vapnik tarafından geliştirilmiştir. Bu yöntem, istatistiki öğrenme teoremine dayanmaktadır. SVM'deki temel amaç, ayırım yapılacak veriler arasındaki mesafeyi maximuma çıkarmaktır. Düşük boyutlu uzaydaki veriler, yüksek boyutlu uzaya eşlenir ve böylece yüksek boyutlu uzayda doğrusal olarak veriler ayrılabilir. Bu eşleme çekirdek fonksiyonları tarafından yapılmaktadır. Böylelikle doğrusal olmayan veriler, yüksek boyutlu uzayda doğrusal olarak ayrılabilir (Huang Yinglai ve ark., 2018). Çizelge 3.5'te yaygın kullanılan çekirdek fonksiyonları gösterilmiştir.


Şekil 3.9'da örnek bir sınıflandırılacak veri kümesi verilmiştir. SVM, örnekleri ayırırken hedef sınıfları temel alarak ayırmaya çalışır. Birden fazla doğrusal çizgi ile ayırma işlemi yapar. Asıl amaç, hangi çizginin daha iyi olduğunu ve optimal çizginin nasıl bulunacağıdır (Karakoyun ve Hacibeyoğlu, 2014). Şekil 3.9'da noktali olarak gösterilen çizgiler en yakın vektörler arasındaki mesafeyi ayıran çizgiye paralel olarak çizilir. Sınıflandırılacak örnekler doğrusal bir çizgi ile ayrılamayacak durumda olabilir. Şekil 3.10'da doğrusal olmayan sınıflandırma örneği verilmiştir.

Çizelge 3.5. Yaygın kullanılan çekirdek fonksiyonları (Huang Yinglai ve ark., 2018)

Çekirdek Fonksiyon Adı	Denklemleri
Lineer	$k(X_i, X_j) = X_i^T X_j + c$
d dereceli Polinomal	$k(X_i, X_j) = (aX_i^T X_j + c)^d$
Sigmoid	$k(X_i, X_j) = \tanh(a(X_i^T X_j) + c)$




Şekil 3.9. Destek vektörlerin gösterimi (Karakoyun ve Hacibeyoğlu, 2014)



Şekil 3.10. Doğrusal olmayan sınıflandırma örneği (Karakoyun ve Hacibeyoğlu, 2014)

Doğrusal olmayan sınıflandırma örneklerini, SVM sınıflandırırken doğrusal olmayan bir çizgi ile sınıflandırmak yerine çekirdek fonksiyonları ile verileri bir başka uzaya taşır. Bu sebeple daha tutarlı bir ayırım sağlanmış olur (Karakoyun ve Hacibeyoğlu, 2014). Şekil 3.11’de çekirdek fonksiyonları ile örneklerin üst boyuta taşınması gösterilmiştir.



Şekil 3.11. Çekirdek fonksiyonu ile üst boyuta taşınması (Karakoyun ve Hacibeyoğlu, 2014)

Birçok alanda kullanılan (sınıflandırma, tahmin) SVM, tez çalışmasında kullanılan sınıflandırma yöntemlerinden biridir. Matlab Classification Learner Toolbox’ında çalıştırılmıştır. Çekirdek fonksiyonu Polinomal ’dır.

3.7.4. Torba Ağaç Algoritması (Bagged Tree Algorithm- BT)

Torba Ağaç Algoritması, Breiman tarafından 1996’da tanıtılmıştır. Torba Ağaç Algoritması, birçok sınıflandırma probleminde etkisini göstermiş olan topluluk modellerinden (ensemble model) biridir. Torba Ağaç Algoritması, çoklu sınıflandırıcılar ve çoğunluk oylama yaklaşımını kullanmaktadır. Yeni bir veriyi sınıflandırmak için bir dizi sınıflandırıcıyı eğitir. Sınıflandırma işlemi yaparken, çoğunluk oylamaya göre yeni

veriyi sınıflandırır (Das ve ark., 2017). Bu yöntem, varyansı düşürür bundan dolayı aşırı öğrenmenin önüne geçen bir algoritmadır. Temel amacı, birden fazla eğitime örneğini oluşturmaktır. Bu amaca yönelik olarak bir eğitime verisinin farklı kombinasyonları üretilir. Örneğin, bir eğitim verisi N adetten oluştuğu düşünülürse, bir sonraki üretilen eğitim verileri de N adetten oluşması gerekir ve bu üretme işlemi rastgele seçimle yerine koymalı olarak yapılır. Eğitime verisindeki N adet örneğin hepsi diğer veri setlerinde bulunmak zorunda değildir. Bazı örnekler hiç bulunmazken bazı örnekler birden fazla kez bulunabilir. Her ağaç bu şekilde farklı kombinasyonlar ile oluşturulan eğitime verileri ile eğitilir. Sonuç çoğunluk oylama yapılarak belirlenir (Atasever ve Özkan, 2012).

Matlab Classification Learner Toolbox'ında çalıştırılan Torba Ağaç Algoritmasının öğrenme modeli 'bag' yani torbalama olarak ayarlanmıştır. Bu tez çalışmasında kullanılan sınıflandırıcılar Matlab 2021a'da Classification Learner Toolbox'ında çalıştırılmıştır ve sınıflandırıcıların parametreleri Çizelge 3.6'da verilmiştir.

Çizelge 3.6. Tez çalışması kapsamında kullanılan sınıflandırıcıların parametreleri

ANN	SVM	kNN	BT
Aktivasyon Fonk: Tanjant Sigmoid	Çekirdek Fonksiyonu: Quadratik	Komşu Sayısı: 10	Topluluk Metodu: Torba (Bag)
Katman Boyutu: 25	Çekirdek Ölçeği: Otomatik	Uzaklık metriği: Öklid	Öğrenme Tipi: Karar Ağacı
İterasyon sayısı: 1000	Çoklu Sınıf Metodu: Birebir	Uzaklık ağırlığı: Kare Ters	Öğrenme Çevrim Sayısı: 30
Performans Fonksiyonu: Ortalama Kare Hata (Mean Squared Error-MSE)			

3.7.5. k Kat Çapraz Doğrulama (k-Fold Cross Validation)

k Kat Çapraz doğrulama, ver setini eğitim ve test olarak ayırmak için kullanılan bir yöntemdir. Veri seti k adet alt kümeye ayrılır. Sınıflandırma işlemi k kez çalıştırılır. Her seferinde, k adet alt kümenin bir tanesi test diğer k-1 tanesi eğitim olacak şekilde sınıflandırma yapılır. Her sınıflandırma işlemi sonucunda o kat için ortalama hata belirlenir. k kez sınıflandırma işlemi bittikten sonra ortalama hataların genel ortalaması sınıflandırma performansını vermektedir (Yücelbaş, 2017).

3.8. Performans Değerlendirme Ölçütleri

Bu tez çalışmasında, kullanılan yöntemlerin performanslarının karşılaştırılması için sınıflandırma doğruluğu (accuracy), duyarlılık (recall), özgüllük (specificity), kesinlik (precision), F-skor ölçütleri hesaplanmıştır. Bu ölçütlerin hesaplanması, her sınıflandırma sonucunda elde edilen konfüzyon matrisleri üzerinden yapılmıştır. Çizelge 3.7’de örnek bir konfüzyon matrisi verilmiştir.

Çizelge 3.7. Konfüzyon matrisi

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

Çizelge 3.7’de belirtilen değerlerin anlamları aşağıda belirtilmiştir.

Doğru Pozitif (DP): Gerçekte pozitif olup, sınıflandırma sonucunda da pozitif sınıflandırılan verilerin sayısıdır.

Yanlış Negatif (YN): Gerçekte pozitif olup, sınıflandırma sonucunda negatif sınıflandırılan verilerin sayısıdır.

Yanlış Pozitif (YP): Gerçekte negatif olup sınıflandırma sonucu pozitif sınıflandırılan verilerin sayısıdır.

Doğru Negatif (DN): Gerçekte negatif olup sınıflandırma sonucunda da negatif sınıflandırılan verilerin sayısıdır.

Konfüzyon matrisinden elde edilen doğruluk (accuracy), duyarlılık (recall), özgüllük (specificity), kesinlik (precision), F-skor ölçütleri Denklem 3.17 –Denklem 3.20’de gösterildiği gibi hesaplanmaktadır. Doğruluk, sınıflandırıcı sonucu tüm doğru sınıflandırılan veri sayısının, toplam veri sayısına bölünmesi ile bulunur. Recall doğru pozitif sayılarının, doğru sınıflandırma oranını, özgüllük, doğru negatiflerin doğru sınıflandırma oranını belirtmektedir. Precision, doğru tahmin edilmiş doğru pozitif sayısının tüm pozitif sayılara (hem gerçek pozitif sayısı hem de tahmin edilen pozitif sayısı) oranı ile hesaplanmaktadır. F-skor, recall ve precision değerlerinin harmonik ortalaması alınarak hesaplanır. Denklem 3.21’de F-skor formülü verilmiştir.

$$\text{Doğruluk (Accuracy)} = \frac{DP+DN}{DP+DN+YN+YP} \quad (3.17)$$

$$\text{Duyarlılık (Recall)} = \frac{DP}{DP+ YN} \quad (3.18)$$

$$\text{Özgüllük (Specificity)} = \frac{DN}{YP+ DN} \quad (3.19)$$

$$\text{Kesinlik (Precision)} = \frac{DP}{DP+ YP} \quad (3.20)$$

$$\text{F skor} = 2 \times \frac{(\text{Kesinlik} \times \text{Duyarlılık})}{(\text{Kesinlik} + \text{Duyarlılık})} \quad (3.21)$$



4.ARAŞTIRMA SONUÇLARI VE TARTIŞMA

Bu tez çalışmasında, 119E127 nolu TÜBİTAK projesi kapsamında, hastaların apne rahatsızlıklarının evre bağımlı ve/veya pozisyon bağımlı olup olmadığını tespit etmek için üç sınıf uyku evreleme üç aşamalı olarak gerçekleştirilmiştir. İlk aşamada, gürültünün evreleme performansına etkisini değerlendirmek amacıyla ön çalışma yapılmış ve ham veri ile temiz veri arasındaki uyku evreleme sonuçları karşılaştırılmıştır. Bu ön çalışmada hem ham hem de gürültüden arındırılmış verilerden sadece ÖS1 ile verilen özellikler çıkarılmış ve ANN, SVM ve kNN ile evreleme işlemi gerçekleştirilmiştir. Yapılan denemeler sonucunda, temiz verinin daha iyi sonuç verdiği görülmüş ve ikinci aşamada sadece temiz veri ile ilave özellik çıkarma yöntemleriyle özelliklerden oluşan veri setleri ve sınıflandırıcılar ile uyku evreleme yapılarak elde edilen sonuçlar karşılaştırılmıştır. Üçüncü aşamada, en iyi model diğer bir deyişle en iyi sonucu veren özellik çıkarma yöntemi ve sınıflandırıcı seçildikten sonra kişinin uyku apnesinin evre bağımlı ve/veya pozisyon bağımlı olup olmadığı kontrol edilmiştir. Bu aşamada daha önce eğitime ve test işleminde hiç kullanılmayan 9 hasta verisinin kullanılması uygun görülmüştür. Bu bölüm, tez çalışması kapsamında elde edilen tüm bu işlemlerin sonuçlarını içermektedir.

4.1. Ham Veri ile Temiz Veri Evreleme Sonuçlarının Karşılaştırılması

Ham veri, veri setinin sadece epoklara ayrılmış halinden oluşmaktadır. Herhangi bir ön işlem uygulanmamıştır. Temiz veri, elektrot kopması ve majör vücut hareketlerinden kaynaklanan gürültülerin temizlenmesi sonucunda elde edilmiştir. Çizelge 3.2’de ham verideki ve temiz veri için her bir evreye ait epok sayıları verilmiştir.

124 hastaya ait ham veride toplamda 67483 epok bulunmaktadır. Bu epokların, 17415 tanesi Wake evresine, 44474 tanesi NREM evresine, 5594 tanesi REM evresine aittir. Ham veri epoklarının çoğu NREM evresine aittir. Temiz veride ise toplamda 61266 epok vardır. Bu epokların, 14476 tanesi Wake, 41372 tanesi NREM, 5418 tanesi REM evresine aittir. Yine bu veri setinde de çoğunluk NREM evresine aittir. REM evresine ait 176 epokta elektrot kopmaları tespit edilmiş ve bu epoklar silinmiştir. Toplamda 6217 epok silinerek temiz veri seti oluşturulmuştur.

Bu iki veri seti elde edildikten sonra hem ham veriden hem de temiz veriden ÖS1’de belirtilen özellikler çıkarılmış ve her bir epokun uzman tarafından skorlanmış

uyku evreleri dikkate alınarak Wake, NREM, REM sırasıyla -1, 0 ve 1 olarak etiketlemesi yapılmıştır. Daha sonra ANN, SVM, kNN sınıflandırıcılar ile rastgele karıştırılmış veri seti ile sınıflandırma işlemi 5 kat çapraz doğrulama ile gerçekleştirilmiştir. Çizelge 4.1’de ham verinin sınıflandırma sonucu oluşan konfüzyon matrisleri verilmiştir.

Çizelge 4.1. Ham verinin sınıflandırma sonucu oluşan konfüzyon matrisleri a)ANN sonucu b) SVM sonucu c) kNN sonucu

ANN		Doğru sınıf		
Tahmin edilen sınıf		-1	0	1
	-1	517	757	63
	0	16891	43703	5510
	1	6	12	21

(a)

SVM		Doğru sınıf		
Tahmin edilen sınıf		-1	0	1
	-1	7179	18566	2334
	0	7221	18471	2334
	1	3015	7437	926

(b)

kNN		Doğru sınıf		
Tahmin edilen sınıf		-1	0	1
	-1	5233	10608	1260
	0	10911	30567	3177
	1	1271	3299	1157

(c)

Çizelge 4.1.a incelendiğinde, ANN sınıflandırıcısında 17414 adet Wake evresinin %2.96’sı, 44472 adet NREM evresinin %98.27’si, 5594 adet REM evresinin ise %0.37’si doğru tahmin edilmiştir. ANN sınıflandırıcısında en iyi tahmin edilen evre NREM iken en kötü tahmin edilen evre REM evresi olmuştur. Çizelge 4.1.b’ye bakıldığında ise Wake evresindeki başarı %41.22, NREM evresindeki başarı %41.53, REM evresindeki başarı ise %16.55’tir. SVM sınıflandırıcısındaki en iyi tahmin edilen evre ANN ‘de olduğu gibi NREM evresidir. ANN ve SVM sınıflandırıcılarının evrelemedeki başarıları karşılaştırıldığında Wake ve REM evresindeki SVM başarısı, ANN ‘den daha iyi iken, NREM evresindeki başarı ANN ‘de daha iyidir. Çizelge 4.1.c, kNN sınıflandırıcı sonuçlarını içermektedir. kNN sınıflandırıcısında Wake %30.04, NREM %68.73, REM ise %20.68’lik tahmin başarısında sahiptir. kNN sınıflandırıcısında da SVM ve ANN sınıflandırıcılarında olduğu gibi en iyi tahmin edilen evrenin NREM olduğu anlaşılmaktadır. Bu sonuçlara göre ham verideki Wake evresinde en iyi başarı SVM ‘den, NREM evresinde en iyi başarı ANN ‘den ve REM evresindeki en iyi başarı ise kNN ‘den alınmıştır. Aynı özellikler kullanılarak temiz verinin sınıflandırma sonuçlarından oluşan konfüzyon matrisleri Çizelge 4.2’de verilmiştir.

Çizelge 4.2. Temiz verinin sınıflandırma sonucu oluşan konfüzyon matrisleri a) ANN sonucu b) SVM sonucu c) kNN sonucu

ANN		Doğru sınıf		
Tahmin edilen sınıf		-1	0	1
	-1	6158	3158	216
	0	8087	37245	3622
	1	231	969	1579

(a)

SVM		Doğru sınıf		
Tahmin edilen sınıf		-1	0	1
	-1	3979	1385	72
	0	10466	39939	5156
	1	31	48	190

(b)

kNN		Doğru sınıf		
Tahmin edilen sınıf		-1	0	1
	-1	8880	4080	326
	0	5089	35612	1335
	1	507	1680	3757

(c)

Çizelge 4.2'ye genel olarak bakıldığında konfüzyon matrislerindeki tahmin edilen değerler ham verinin tahmin değerlerinden daha iyidir. Temiz veriden elde edilen sonuçlar incelendiğinde ise, Çizelge 4.2.a'da verilen ANN sınıflandırıcısının sonuçlarına göre, 14476 adet Wake evresinin %42.53'ü, 41372 adet NREM evresinin %90.02'si, 5417 adet REM evresinin ise %29.14'ü doğru tahmin edilmiştir. ANN sınıflandırıcısında NREM evresindeki başarı Wake ve REM evresindeki başarılarla göre daha iyidir. Çizelge 4.2.b'ye bakıldığında, SVM sınıflandırıcısında Wake evresinin %27.48'i, NREM evresinin %96.53'ü ve REM evresinin %3.50'si doğru tahmin edilmiştir. Bu sınıflandırıcı da ANN 'de olduğu gibi en iyi başarıyı NREM evresinde vermiştir. REM evrelerindeki başarılar ANN ve SVM sınıflandırıcılar için karşılaştırıldığında ANN'nin REM başarısının daha yüksek olduğu anlaşılmaktadır. Çizelge 4.2.c'de kNN sınıflandırıcısı, Wake evresinde %61.34'lük başarıya, NREM evresinde %86.07'lik başarıya, REM evresinde ise %69.34'lük başarıya ulaşmıştır. kNN sınıflandırıcısı, SVM ve ANN sınıflandırıcılarına göre Wake ve REM evresinde en yüksek başarıya ulaşırken, NREM evresinde en yüksek başarıya SVM sınıflandırıcısı ulaşmıştır.

Çizelge 4.1 ve Çizelge 4.2'ye bakıldığında, en iyi sonuçların temiz veriden alındığı görülmüştür. İki çizelgeye göre Wake ve REM evrelerindeki en yüksek başarı temiz veri ile çalıştırılan kNN sınıflandırıcısından alınmıştır. NREM evresindeki en yüksek başarı ise ham veri ile çalıştırılan ANN sınıflandırıcısından alınmıştır. Çizelge 4.3'te ham verinin ve temiz verinin performans değerlendirme ölçütleri verilmiştir.

Çizelge 4.3. Ham verinin performans değerlendirme ölçütleri

Veri seti	Sınıflayıcı	Doğruluk	Recall	Özgüllük	Precision	F skoru
Ham veri	kNN	0.688	0.398	0.692	0.397	0.397
	SVM	0.394	0.331	0.666	0.332	0.311
	ANN	0.655	0.339	0.670	0.529	0.284
Temiz veri	kNN	0.788	0.722	0.847	0.715	0.718
	SVM	0.720	0.425	0.727	0.719	0.430
	ANN	0.734	0.539	0.772	0.658	0.574

Çizelge 4.3'e bakıldığında, ANN'nin doğruluğunda 0.079'luk bir artış olduğu, SVM'nin doğruluğunda 0.326'lık bir artış olduğu ve kNN'nin doğruluğunda ise 0.1'lik bir artış olduğu görülmektedir. Temiz veriden elde edilen sonuçlar, ham verinin sonuçlarından daha iyi olduğu anlaşılmıştır. Bundan sonraki işlemlerin tamamı bu sebepten dolayı temiz veri ile yapılmıştır.

4.2. Temiz Veri ile Yapılan Uyku Evreleme Çalışmalarının Sonuçları

Bu tez çalışmasının bu aşamasında, EEG sinyalleri kullanılarak yapılan uyku evreleme denemelerinde ÖS1, ÖS2 ve ÖS3 olarak belirtilen özellik setlerinin, bu üç veri seti birleştirilerek elde edilmiş ve Relief ile seçilmiş özelliklerden oluşan özellik setlerinin ANN, SVM, kNN ve BT sınıflandırıcıları ile denemeler yapılmış ve elde edilen sonuçlar değerlendirilmiştir. İlk olarak çapraz doğrulama uygulamadan 124 hastanın 100 tanesi eğitim 24 tanesi test olarak kullanılmıştır. Çizelge 4.4'te eğitim ve test verilerindeki epok sayıları ve bu epoklardaki evre sayıları verilmiştir.

Çizelge 4.4. Eğitim ve test verilerinin evre sayıları

	Wake	NREM	REM	Toplam
Eğitim	11524	30776	2864	45164
Test	2952	10596	2554	16102

Çizelge 4.5- Çizelge 4.20'de verilen çizelgeler 5 kat çapraz doğrulama uygulanmadan elde edilen sonuçlardır. Çizelge 4.5'te ÖS1'in eğitim verisi ile sınıflandırıcılardan elde edilen konfüzyon matrisleri verilmiştir.

Çizelge 4.5. ÖS1 ile elde edilen eğitim sonuçlarının konfüzyon matrisleri a) ANN sonucu b) SVM sonucu c)kNN sonucu d) BT sonucu

ANN		Doğru sınıf		
Tahmin edilen sınıf		-1	0	1
	-1	5769	2088	93
	0	5639	28209	1371
	1	116	479	1400
(a)				
SVM		Doğru sınıf		
Tahmin edilen sınıf		-1	0	1
	-1	11266	12	14
	0	254	30761	496
	1	4	3	2364
(b)				
kNN		Doğru sınıf		
Tahmin edilen sınıf		-1	0	1
	-1	4993	752	115
	0	6437	29853	1379
	1	94	171	1370
(c)				
BT		Doğru sınıf		
Tahmin edilen sınıf		-1	0	1
	-1	11509	1	0
	0	15	30775	9
	1	0	0	2855
(d)				

Çizelge 4.5 incelendiğinde, 11524 adet Wake evresinin ANN sınıflandırıcısında %50.06'sı, SVM sınıflandırıcısında %97.76'sı, kNN sınıflandırıcısında %43.32'si ve BT sınıflandırıcısında ise %99.86'sı doğru tahmin edilmiştir. Wake evresindeki en iyi tahmin etme başarısı BT sınıflandırıcısından alınmıştır. 30776 adet NREM evresi için, ANN 'den %91.65, SVM'de %99.95, kNN 'de %97.00 ve BT'de %99.99'luk başarılar elde edilmiştir. BT sınıflandırıcısı Wake evresinde olduğu gibi NREM evresinde de neredeyse tüm NREM evrelerini doğru tahmin etmiştir. 2864 adet REM evresi incelendiğinde ise, ANN %48.88, SVM %82.55, kNN %47.83, BT %99.68'lik başarı göstermiştir. REM evresinde de en iyi başarı BT sınıflandırıcısından alınmıştır. Eğitim sonuçlarında BT sınıflandırıcısının başarısı tüm evrelerde çok iyi olduğu görülmektedir. Çizelge 4.6'da test sonuçlarından elde edilen konfüzyon matrisleri verilmiştir.

Çizelge 4.6. ÖS1 ile elde edilen test sonuçlarının konfüzyon matrisleri a) ANN sonucu b) SVM sonucu c) kNN sonucu d) BT sonucu

ANN		Doğru sınıf		
Tahmin edilen sınıf		-1	0	1
	-1	1367	1959	330
	0	1481	8195	1880
	1	104	442	344

(a)

SVM		Doğru sınıf		
Tahmin edilen sınıf		-1	0	1
	-1	90	161	37
	0	2851	10387	2445
	1	11	48	72

(b)

kNN		Doğru sınıf		
Tahmin edilen sınıf		-1	0	1
	-1	739	1208	262
	0	2142	9065	2086
	1	71	323	206

(c)

BT		Doğru sınıf		
Tahmin edilen sınıf		-1	0	1
	-1	1292	2090	493
	0	1634	8403	1957
	1	26	103	104

(d)

Çizelge 4.6'ya bakıldığında, eğitim sonuçlarındaki başarı kadar yüksek bir başarı hiçbir test verisi ile çalıştırılan sınıflandırıcıdan elde edilemediği anlaşılmaktadır. 2952 adet Wake evresinin ANN'de %46.30'u, SVM'de %3.04'ü, kNN'de %25.03'ü ve BT'de ise %43.76'sı doğru tahmin edilmiştir. Test verisinin Wake evresindeki en iyi tahmin oranı ANN sınıflandırıcısından alınmıştır. 10596 adet NREM evresinin, ANN'de %77.34'ü, SVM'de %98.02'si, kNN'de %85.51'i, BT'de ise %79.30'u doğru tahmin edilmiştir. Test verisinin NREM evresinde en iyi tahmin yüzdesi SVM sınıflandırıcısından alınmıştır. 2554 adet REM evresinin ise, ANN'de %13.46'sı, SVM'de %2.81'i, kNN'de %8.06'sı, BT'de %4.07'si doğru tahmin edilmiştir. REM evresi test verisindeki en kötü tahmin edilen evre olmuştur. Çizelge 4.7'de ÖS2 için elde edilen eğitim verisinin konfüzyon matrisleri verilmiştir.

Çizelge 4.7. ÖS2 için elde edilen eğitim sonuçlarının konfüzyon matrisleri a) ANN sonucu b) SVM sonucu c) kNN sonucu d) BT sonucu

ANN		Doğru sınıf		
Tahmin edilen sınıf		-1	0	1
	-1	5538	2482	70
	0	5889	27897	1775
	1	97	397	1019

(a)

SVM		Doğru sınıf		
Tahmin edilen sınıf		-1	0	1
	-1	7862	473	55
	0	3633	30269	1849
	1	29	34	960

(b)

kNN		Doğru sınıf		
Tahmin edilen sınıf		-1	0	1
	-1	4269	1226	219
	0	7138	29343	1938
	1	117	207	707

(c)

BT		Doğru sınıf		
Tahmin edilen sınıf		-1	0	1
	-1	11498	7	1
	0	26	30769	21
	1	0	0	2842

(d)

Çizelge 4.7’de verilen tahmin değerleri, hemen hemen Çizelge 4.6’da verilen tahmin değerlerine yakın değerler olduğunu göstermektedir. Eğitim verisinde ANN’nin tahmin yüzdesi Wake evresi için %48.05, NREM evresi için %90.64, REM evresi için %35.57’dir. SVM’nin tahmin değerleri Wake evresi için %68.22, NREM evresi için %98.35 ve REM evresi için %33.51’dir. kNN’nin tahmin yüzdeleri hesaplandığında Wake evresi için %37.04, NREM evresi için %95.34, REM evresi için %24.68’dir. BT sınıflandırıcısında ise Wake evresinin %99.77’si, NREM evresinin %99.97’si, REM evresinin ise %99.23’ü doğru tahmin edilmiştir. Eğitim verisindeki en iyi tahmin değerleri BT sınıflandırıcısında alınmıştır. Çizelge 4.8’de ÖS2 için elde edilen test verisinin konfüzyon matrisleri verilmiştir.

Çizelge 4.8. ÖS2 için elde edilen test sonuçlarının konfüzyon matrisleri a) ANN sonucu b) SVM sonucu c) kNN sonucu d) BT sonucu

ANN		Doğru sınıf		
Tahmin edilen sınıf		-1	0	1
	-1	1437	1461	195
	0	1460	8834	2018
	1	55	301	341

(a)

SVM		Doğru sınıf		
Tahmin edilen sınıf		-1	0	1
	-1	754	859	110
	0	2187	9673	2346
	1	11	64	98

(b)

kNN		Doğru sınıf		
Tahmin edilen sınıf		-1	0	1
	-1	798	1140	288
	0	2106	9291	2119
	1	48	165	147

(c)

BT		Doğru sınıf		
Tahmin edilen sınıf		-1	0	1
	-1	1332	1702	316
	0	1593	8766	2087
	1	27	128	151

(d)

Çizelge 4.8’de verilen test verisindeki konfüzyon matrisleri incelendiğinde, yine ÖS1’de olduğu gibi test verisindeki tahmin edilen evre sayılarında düşüş olduğu anlaşılmaktadır. ANN sınıflandırıcısında, Wake evresinin %48.67’si, NREM evresinin %83.37’si, REM evresinin %13.35’i doğru tahmin edilirken, SVM sınıflandırıcısında Wake evresinin %25.54’ü, NREM evresinin %91.28’i, REM evresinin ise %3.83’ü doğru tahmin edilmiştir. kNN sınıflandırıcısına bakıldığında, Wake evresinde %27.03’lük, NREM evresinde %87.68’lik, REM evresinde %5.75’lik bir tahmin yüzdesi elde edilmiştir. Son olarak BT sınıflandırıcı sonuçlarına bakıldığında Wake evresinin %42.12’si, NREM evresinin %82.72’si ve REM evresinin %5.91’i doğru tahmin edilmiştir. Test verisi sonuçlarında Wake ve REM evrelerinde ANN, NREM evresinde ise SVM en yüksek başarıya ulaşmış sınıflandırıcılardır. Çizelge 4.10’da ÖS3 için elde edilen eğitim verisinin konfüzyon matrisleri verilmiştir.

Çizelge 4.9.a’da ANN sınıflandırıcısında, Wake evresinin %49.33’ü, NREM evresinin %90.4’ü, REM evresinin %39.10’u doğru tahmin edilmiştir. Diğer özellik setlerinde olduğu gibi yine NREM evresi en yüksek tahmin edilme oranına sahip evredir. Çizelge 4.9.b’de SVM sınıflandırıcısının sonuçlarına bakıldığında, Wake evresinin %62.64’ü, NREM evresinin %97.29’u, REM evresinin %32.89’u doğru tahmin

edilmiştir. SVM sınıflandırıcısı da en iyi tahmin etme oranına NREM evresinde ulaşmıştır. Çizelge 4.9.c’de kNN sınıflandırıcısı için Wake evresinde %42.04, NREM evresinde %94.89, REM evresinde %49.47’lik tahmin etme oranı bulunmaktadır. NREM evresi kNN sınıflandırıcısında da en iyi tahmin edilme oranına sahip evredir. Çizelge 4.9.d’de BT sınıflandırıcı sonuçları incelendiğinde ise, Wake evresinin %99.72’si, NREM evresinin %99.98’i, REM evresinin %99.54’ü doğru tahmin edilmiştir. BT sınıflandırıcısının, eğitim verisinde en iyi başarıya ulaştığı görülmüştür. Çizelge 4.10’da ÖS3 için elde edilen test verisinin konfüzyon matrisleri verilmiştir.

Çizelge 4.9. ÖS3 için elde edilen eğitim sonuçlarının konfüzyon matrisleri a) ANN sonucu b) SVM sonucu c) kNN sonucu d) BT sonucu

ANN		Doğru sınıf		
Tahmin edilen sınıf		-1	0	1
	-1	5685	2492	73
	0	5715	27824	1671
	1	124	460	1120

(a)

SVM		Doğru sınıf		
Tahmin edilen sınıf		-1	0	1
	-1	7219	685	63
	0	4238	29943	1859
	1	67	148	942

(b)

kNN		Doğru sınıf		
Tahmin edilen sınıf		-1	0	1
	-1	4845	1286	149
	0	6535	29206	1298
	1	144	284	1417

(c)

BT		Doğru sınıf		
Tahmin edilen sınıf		-1	0	1
	-1	11492	5	1
	0	32	30771	12
	1	0	0	2851

(d)

Çizelge 4.10. ÖS3 için elde edilen test sonuçlarının konfüzyon matrisleri a) ANN sonucu b) SVM sonucu c) kNN sonucu d) BT sonucu

ANN					SVM				
		Doğru sınıf					Doğru sınıf		
Tahmin edilen sınıf		-1	0	1	Tahmin edilen sınıf		-1	0	1
	-1	1348	1435	223		-1	803	949	154
	0	1536	8984	2151		0	2133	9580	2370
	1	68	177	180		1	16	67	30

(a)					(b)				
		Doğru sınıf					Doğru sınıf		
Tahmin edilen sınıf		-1	0	1	Tahmin edilen sınıf		-1	0	1
	-1	793	1114	318		-1	1351	1854	410
	0	2109	9309	2150		0	1574	8636	2080
	1	50	173	86		1	27	106	64

(c)					(d)				
		Doğru sınıf					Doğru sınıf		
Tahmin edilen sınıf		-1	0	1	Tahmin edilen sınıf		-1	0	1
	-1	793	1114	318		-1	1351	1854	410
	0	2109	9309	2150		0	1574	8636	2080
	1	50	173	86		1	27	106	64

Çizelge 4.10'daki ÖS3 için test verileri incelendiğinde, Wake evresinin ANN'de %45.66'sı, SVM'de %27.20'si, kNN'de %26.86'sı ve BT'de %45.76'sı doğru tahmin edilmiştir. SVM ve kNN sınıflandırıcılarının tahmin etme yüzdeleri ile ANN ve BT sınıflandırıcılarının tahmin etme yüzdeleri hemen hemen birbirine yakındır. Wake evresindeki en iyi tahmin edilme oranı BT sınıflandırıcıdan alınmıştır. NREM evresinin ANN'de %84.78'si, SVM'de %90.41'i, kNN'de %87.85'i, BT'de ise %81.5'si doğru tahmin edilmiştir. NREM evresindeki tahmin yüzdesi Wake evresine göre daha iyidir. NREM evresini en iyi tahmin eden sınıf SVM'dir. REM evresine bakıldığında ise ANN'de %7.04'ü, SVM'de %1.17'si, kNN'de %3.36'sı ve BT'de ise %2.5'i doğru tahmin edilmiştir. REM evresi en kötü tahmin edilen evre olmuştur. Çizelge 4.11'de verilen sonuçlar eğitim veri setine Çizelge 4.11'de verilen sonuçlar test veri setine ait performans ölçme kriterleridir.

Çizelge 4.11. 3 özellik seti için eğitim verisinin sınıflandırma sonuçları

Özellik Seti	Sınıflayıcı	Doğruluk	Recall	Özgüllük	Precision	F skoru
ÖS1	kNN	0.8020	0.6272	0.8082	0.8275	0.6853
	SVM	0.9830	0.9332	0.9823	0.9903	0.9589
	ANN	0.7830	0.7428	0.8511	0.6353	0.6745
	BT	0.9990	0.9985	0.9994	0.9997	0.9991
ÖS2	kNN	0.7600	0.5236	0.7729	0.7322	0.5688
	SVM	0.8660	0.6670	0.8673	0.9074	0.7312
	ANN	0.7630	0.7142	0.8322	0.5809	0.6238
	BT	0.9990	0.9966	0.9988	0.9993	0.9979
ÖS3	kNN	0.7850	0.6214	0.8009	0.7760	0.6691
	SVM	0.8440	0.6428	0.8496	0.8504	0.7019
	ANN	0.7670	0.7122	0.8350	0.5962	0.6362
	BT	0.9990	0.9975	0.9989	0.9994	0.9984

Çizelge 4.12. 3 özellik seti için test verisinin sınıflandırma sonuçları

Özellik Seti	Sınıflayıcı	Doğruluk	Recall	Özgüllük	Precision	F skoru
ÖS1	kNN	0.6220	0.3955	0.6970	0.4532	0.3919
	SVM	0.6550	0.3463	0.6729	0.5081	0.2999
	ANN	0.6150	0.4899	0.7331	0.4571	0.4511
	BT	0.6090	0.4238	0.7139	0.4934	0.3990
ÖS2	kNN	0.6360	0.4015	0.7027	0.4847	0.3932
	SVM	0.6540	0.4022	0.6991	0.5616	0.3914
	ANN	0.6590	0.5571	0.7583	0.4847	0.4855
	BT	0.6370	0.4458	0.7222	0.5317	0.4297
ÖS3	kNN	0.6330	0.3936	0.7003	0.4402	0.3789
	SVM	0.6470	0.3959	0.6973	0.4556	0.3764
	ANN	0.6530	0.5270	0.7521	0.4583	0.4485
	BT	0.6240	0.4325	0.7181	0.4670	0.4042

Çizelge 4.11-4.12'ye göre en yüksek eğitim başarısı üç özellik seti için de BT sınıflandırıcı ile elde edilmişken en yüksek test başarısı ÖS1 için SVM'den ÖS2 ve ÖS3 için ANN'den elde edilmiştir. Veri seti eğitime ve test olarak ayrıldığında en yüksek test başarısı Çizelge 4.12'de görüldüğü gibi ANN sınıflandırıcısı ile ÖS2'den elde edilmiştir.

Bütün özelliklerin bir arada başarısını görmek için, ÖS1, ÖS2, ÖS3 özellik setlerinin hepsi birleştirilerek elde edilen toplu veri seti (ÖS4) ile sınıflandırma işlemi yapılmıştır. Çizelge 4.13'te toplu veri setinin eğitim verisinden elde edilen konfüzyon matrisleri verilmiştir.

Çizelge 4.13. ÖS4 için elde edilen eğitim sonuçlarının konfüzyon matrisleri a) ANN sonucu b) SVM sonucu c) kNN sonucu d) BT sonucu

ANN		Doğru sınıf		
Tahmin edilen sınıf		-1	0	1
	-1	6992	2149	53
	0	4438	28207	856
	1	94	420	1955
(a)				
kNN		Doğru sınıf		
Tahmin edilen sınıf		-1	0	1
	-1	5668	753	77
	0	5764	29846	1068
	1	92	177	1719
(c)				
SVM		Doğru sınıf		
Tahmin edilen sınıf		-1	0	1
	-1	11289	8	1
	0	226	30764	439
	1	9	4	2424
(b)				
BT		Doğru sınıf		
Tahmin edilen sınıf		-1	0	1
	-1	11504	5	0
	0	20	30771	13
	1	0	0	2851
(d)				

Çizelge 4.13'te verilen konfüzyon matrislerine göre, Wake evresinin ANN'de %60.67'si, SVM'de %97.96'sı, kNN'de %49.18'i, BT'de %99.82'si doğru tahmin edilmiştir. Wake evresindeki en iyi tahmin edilme oranı BT'den alınmıştır. NREM evresinin ANN'de %91.65'i, SVM'de %99.96'sı, kNN'de %96.97'si, BT'de %99.98'i doğru tahmin edilmiştir. NREM evresinde de en iyi tahmin edilme değerleri BT sınıflandırıcısından alınmıştır. REM evresinin sonuçları incelendiğinde, ANN'de %68.26'luk, SVM'de %84.63'lük, kNN'de %60.02'lik ve BT'de %99.54'lük tahmin yüzdesi oluşmuştur. BT sınıflandırıcısı, eğitim verisinde tüm evreler için en iyi tahmin etme değerlerine ulaşmıştır. Çizelge 4.14'te toplu veri setinin test verisinden elde edilen konfüzyon matrisleri verilmiştir.

Çizelge 4.14. ÖS4 için elde edilen test sonuçlarının konfüzyon matrisleri a) ANN sonucu b) SVM sonucu c) kNN sonucu d) BT sonucu

ANN		Doğru sınıf		
Tahmin edilen sınıf		-1	0	1
	-1	1557	1916	329
	0	1322	8325	1954
	1	73	355	271

(a)

SVM		Doğru sınıf		
Tahmin edilen sınıf		-1	0	1
	-1	124	138	29
	0	2822	10436	2497
	1	6	22	28

(b)

kNN		Doğru sınıf		
Tahmin edilen sınıf		-1	0	1
	-1	765	1141	232
	0	2116	9121	2112
	1	71	334	210

(c)

BT		Doğru sınıf		
Tahmin edilen sınıf		-1	0	1
	-1	1464	2044	436
	0	1478	8520	2085
	1	10	32	33

(d)

Çizelge 4.14'e bakıldığında ÖS4 için test verisinde, Wake evresinin ANN'de %52.74'ü, SVM'de %4.20'si, kNN'de %25.91'i ve BT'de %49.59'u doğru tahmin edilmiştir. Wake evresini en iyi tahmin eden sınıflandırıcı ANN'dir. NREM evresine bakıldığında, ANN tarafından %78.56'sı, SVM tarafından %98.49'u, kNN tarafından %86.07'si ve BT tarafından %80.40'ı doğru tahmin edilmiştir. NREM evresini en iyi tahmin eden sınıflandırıcı SVM'dir. REM evresinin sonuçları incelendiğinde ANN %10.61'ini, SVM %1.09'unu, kNN %8.22'sini ve BT %1.29'unu doğru tahmin etmiştir. Çizelge 4.15'de ÖS4'ün eğitim ve test verisinin sınıflandırma sonuçları verilmiştir.

Çizelge 4.15. ÖS4'ün eğitim ve test verilerinin sınıflandırma sonuçları

	Sınıflayıcı	Doğruluk	Recall	Özgüllük	Precision	F skoru
Eğitim	kNN	0.8240	0.6873	0.8314	0.8502	0.7408
	SVM	0.9850	0.9419	0.9844	0.9909	0.9643
	ANN	0.8230	0.7981	0.8775	0.7353	0.7619
	BT	0.9990	0.9979	0.9992	0.9995	0.9987
Test	kNN	0.6270	0.4007	0.6993	0.4608	0.3983
	SVM	0.6580	0.3460	0.6731	0.5295	0.2967
	ANN	0.6310	0.5049	0.7446	0.4731	0.4593
	BT	0.6220	0.4376	0.7204	0.5054	0.4004

Toplu veri setinde de diğer veri setlerinde olduğu gibi eğitim verisinde en iyi sonucu BT sınıflandırıcı verirken test verisinde en iyi sonucu SVM vermiştir. Sınıflandırma sonuçları incelendiğinde REM başarısındaki düşüklük dikkat çekmektedir. 5 kat çapraz doğrulama uygulamadan, veri setinin 100 hastası eğitim 24 hastası test olarak ayrılmış özellik setleri ve sınıflandırıcıların test başarılarına bakıldığında, Wake evresindeki en iyi başarı ÖS1 için %46.30 ile ANN 'den, ÖS2 için %48.67 ile ANN 'den, ÖS3 için %45.76 ile BT'den, ÖS4 için %52.74 ile ANN 'den alınmıştır. ÖS1, ÖS2, ÖS3 ve ÖS4 özellik setleri arasında en yüksek doğrulukla tahmin eden ÖS4 ile ANN 'dir. NREM evresi için bakıldığında tüm özellik setleri için SVM sınıflandırıcısı en iyi tahmin değerine ulaşmıştır. SVM sınıflandırıcı NREM evresinin ÖS1 'de %98.02'sini, ÖS2'de %91.28'ini, ÖS3'te %90.41'ini ve ÖS4'te %98.49'unu doğru tahmin etmiştir. En yüksek başarı ise Wake evresinde olduğu gibi NREM evresinde de ÖS4 ile alınmıştır. Son olarak, REM evresinde tüm özellik setleri için en yüksek başarı ANN 'den alınmıştır. ANN sınıflandırıcı REM evresinin ÖS1'de %13.46'sını, ÖS2'de %13.35'ini, ÖS3'te %7.04'ünü ve ÖS4'te %10.61'ini doğru tahmin etmiştir. REM evresinde en iyi başarı gösteren özellik seti ÖS2'dir. Performans değerlendirme kriterlerine bakıldığında ise ÖS2'nin ANN 'den elde ettiği %65.90'lık doğruluk diğer tüm sınıflandırıcı başarılarından yüksektir. BT algoritması, eğitimde, bütün veri setleri için en iyi performansı gösterirken test aşamasına gelindiğinde kötü sonuçlar vermiştir.

Algoritmaların ve veri setlerinin performanslarını görmek için son olarak, bütün verilerin hem eğitime hem de test olarak kullanıldığı 5 kat çapraz doğrulama ile denemeler yapılmıştır. Bu denemeler için her bir kata ait veri setleri, REM sayılarına dikkat edilerek seçilen bireylerin verilerinden oluşturulmuştur. REM evresindeki başarının bu kadar

düşük olmasının sebebinin, veri setindeki REM evrelerindeki sayıdan kaynaklı olduğu düşünülmektedir. Bu yüzden, bu aşamada, 5 kat çapraz doğrulamada bütün katlarda yaklaşık olarak eşit sayıda REM bulundurulması amaçlanmıştır. Çizelge 4.16'da 5 kat çapraz doğrulama uygulanmış ÖS1'in eğitim sonuçlarının konfüzyon matrisleri bulunmaktadır.

Çizelge 4.16. ÖS1'in 5 kat çapraz doğrulama sonucu ortalama eğitim sonuçlarının konfüzyon matrisleri
a) ANN sonucu b) SVM sonucu c) kNN sonucu d) BT sonucu

ANN					SVM				
		Doğru sınıf					Doğru sınıf		
Tahmin edilen sınıf		-1	0	1	Tahmin edilen sınıf		-1	0	1
	-1	5313,2	2167,8	87,8		-1	11244,8	11,6	4,4
	0	6087	30156,2	2279,8		0	322,2	33075	581,8
	1	180,6	773,6	1966,8		1	13,8	11	3748,2
(a)					(b)				
kNN					BT				
		Doğru sınıf					Doğru sınıf		
Tahmin edilen sınıf		-1	0	1	Tahmin edilen sınıf		-1	0	1
	-1	5507,2	1078,6	139,2		-1	11561,2	2,2	0,4
	0	5881	31663	2010		0	19,6	33095	12,6
	1	192,8	356,2	2185,2		1	0	0,2	4321
(c)					(d)				

Çizelge 4.16'ya göre Wake evresinin ANN sınıflandırıcısında ortalama %45.87'si, SVM sınıflandırıcısında ortalama %97.08'u, kNN sınıflandırıcısında ortalama %47.55'i, BT sınıflandırıcısında ise ortalama %99.83'ü doğru tahmin edilmiştir. Wake evresinin en iyi tahmin değerleri BT sınıflandırıcısından alınmıştır. NREM evresine bakıldığında, ANN sınıflandırıcısında ortalama %91.11'i, SVM sınıflandırıcısında ortalama %99.93'ü, kNN sınıflandırıcısında ortalama %95.66'sı, BT sınıflandırıcısında ise ortalama %99.99'u doğru tahmin edilmiştir. NREM evresinde de en iyi tahmin yüzdesine BT sınıflandırıcı ulaşmıştır. REM evresi için sonuçlar incelendiğinde, ANN sınıflandırıcısı %45.37'ini, SVM sınıflandırıcısı %86.47'sini, kNN sınıflandırıcısı %50.41'ini, BT sınıflandırıcısı ise %99.70'ini doğru tahmin etmiştir. Bu durumda BT sınıflandırıcı 5 kat çapraz doğrulama uygulanmış ÖS1'in eğitim verisinde en iyi sonucu

vermiştir. Çizelge 4.17’de ÖS1’in test sonuçlarının 5 kat çapraz doğrulama sonucu ortalama konfüzyon matrisleri verilmiştir.

Çizelge 4.17. ÖS1’in 5 kat çapraz doğrulama sonucu ortalama test sonuçlarının konfüzyon matrisleri a) ANN sonucu b) SVM sonucu c) kNN sonucu d) BT sonucu

ANN		Doğru sınıf		
Tahmin edilen sınıf		-1	0	1
	-1	1034,8	1007,6	64,4
	0	1781,4	6981	857,6
	1	79	285,8	161,6
(a)				
SVM		Doğru sınıf		
Tahmin edilen sınıf		-1	0	1
	-1	124,4	63,4	10,4
	0	2759	8161,6	968,2
	1	15,2	49,4	105
(b)				
kNN		Doğru sınıf		
Tahmin edilen sınıf		-1	0	1
	-1	592,2	734,4	100,4
	0	2204	7226	844,2
	1	99	314	139
(c)				
BT		Doğru sınıf		
Tahmin edilen sınıf		-1	0	1
	-1	943	912,8	97
	0	1925	7215,6	859,8
	1	27,2	146	131
(d)				

Çizelge 4.17’de verilen konfüzyon matrislerine göre ÖS1’in 5 kat çapraz doğrulama uygulanmış ortalama test verisinde Wake evresinin ANN %35.74’ünü, SVM %4.29’unu, kNN %20.45’ini, BT %32.51’ini doğru tahmin etmiştir. Test verisinde Wake evresinden en iyi tahmin değerleri ANN sınıflandırıcısından alınmıştır. NREM evresinin ANN tarafından %84.36’sı, SVM tarafından %98.63’ü, kNN tarafından %87.32’si, BT tarafından %87.20’si doğru tahmin edilmiştir. NREM evresindeki en iyi tahmin yüzdesi SVM sınıflandırıcısından alınmıştır. REM evresine bakıldığında ANN %14.91’ini, SVM %9.68’ini, kNN %12.82’sini, BT %12.04’ünü doğru tahmin etmiştir. REM evresindeki doğru tahmin yüzdesi Wake ve REM evrelerinden düşüktür. ÖS1 için yapılan sınıflandırma sonuçları incelendiğinde en iyi tahmin değerleri eğitim verisinde BT’den alınırken, test verisinde Wake ve REM evresi için ANN ’den, NREM evresi için SVM’den alınmıştır. ÖS2 için elde edilen eğitim verisinin 5 kat çapraz doğrulama sonuçlarının konfüzyon matrisleri Çizelge 4.18’de verilmiştir.

Çizelge 4.18. ÖS2'nin 5 kat çapraz doğrulama sonucu ortalama eğitim verisinin konfüzyon matrisleri a) ANN sonucu b) SVM sonucu c) kNN sonucu d) BT sonucu

ANN		Doğru sınıf		
Tahmin edilen sınıf		-1	0	1
	-1	5195,8	2439,8	87,2
	0	6245,4	29971	2808,4
	1	139,6	686,8	1438,8

(a)

SVM		Doğru sınıf		
Tahmin edilen sınıf		-1	0	1
	-1	7648,4	421,4	67,4
	0	3881	32575	3017
	1	51,8	101	1250

(b)

kNN		Doğru sınıf		
Tahmin edilen sınıf		-1	0	1
	-1	4640	1596,4	242
	0	6737	31073	2936
	1	203,8	427,8	1156,8

(c)

BT		Doğru sınıf		
Tahmin edilen sınıf		-1	0	1
	-1	11550,4	3,8	0
	0	30,4	33094	26
	1	0	0	4308,4

(d)

Çizelge 4.18'e göre, ÖS2'nin eğitim verisinde Wake evresinin ANN %44.86'sını, SVM %66.04'ünü, kNN %40.06'ını, BT %99.73'ünü doğru tahmin etmiştir. NREM evresine bakıldığında ANN %90.55'lik, SVM %98.42'lik, kNN %93.88'lik ve BT %99.98'lik tahmin etme yüzdesine sahiptir. REM evresinin, ANN %33.19'unu, SVM %28.83'ünü, kNN %26.68'ini, BT %99.40'ını doğru tahmin etmiştir. Bu durumda ÖS2'nin eğitim verisinde en iyi sonucu BT sınıflandırıcı vermiştir. Çizelge 4.19'da ÖS2'nin 5 kat çapraz doğrulama uygulanmış test sonuçlarının konfüzyon matrisleri bulunmaktadır.

Çizelge 4.19. ÖS2'nin 5 kat çapraz doğrulama sonucu ortalama test sonuçlarının konfüzyon matrisleri a) ANN sonucu b) SVM sonucu c) kNN sonucu d) BT sonucu

ANN		Doğru sınıf		
Tahmin edilen sınıf		-1	0	1
	-1	1089,2	766,8	53
	0	1752,8	7304,8	853
	1	53,2	202,8	177,6

(a)

SVM		Doğru sınıf		
Tahmin edilen sınıf		-1	0	1
	-1	594,4	387,8	34
	0	2284	7825	983
	1	16,8	61,2	66,6

(b)

kNN		Doğru sınıf		
Tahmin edilen sınıf		-1	0	1
	-1	718,6	733,6	102
	0	2115	7361	874
	1	61,4	180	107,6

(c)

BT		Doğru sınıf		
Tahmin edilen sınıf		-1	0	1
	-1	1119,2	984,4	102
	0	1738	7149	836,8
	1	37,8	140,8	144,8

(d)

ÖS1'de olduğu gibi ÖS2'de de test verisindeki başarı eğitim verisindeki başarı kadar yüksek değildir. Çizelge 4.19 incelendiğinde Wake evresinin ANN'de %37.62'si, SVM'de %20.53'ü, kNN'de %24.82'si, BT'de %38.65'i doğru tahmin edilmiştir. Wake evresindeki en yüksek tahmin değerine BT tarafından ulaşılmıştır. NREM evresinin ANN'de %88.28'i, SVM'de %94.57'si, kNN'de %88.95'i, BT'de %86.40'ı doğru tahmin edilmiştir. NREM evresindeki en iyi tahmin değerine SVM sınıflandırıcı ulaşmıştır. REM evresinin sonuçları incelendiğinde ise, ANN %17.38'ini, SVM %6.14'ünü, kNN %9.92'sini, BT %13.36'sını doğru tahmin etmiştir. Burada da REM başarısındaki düşüş dikkat çekmektedir. 5 kat çapraz doğrulama işleminde, ÖS2'den elde edilen sonuçlara genel olarak bakıldığında, eğitim verisindeki konfüzyon matrisleri arasında en iyi tahmin değeri BT'den alınmıştır. ÖS2'nin test verisindeki konfüzyon matrislerine bakıldığında, Wake evresi için en iyi tahmin yüzdesi BT'den, NREM evresi için en iyi tahmin yüzdesi SVM'den, REM evresi için en iyi tahmin yüzdesi ANN 'den alınmıştır. ÖS3 için elde edilen eğitim sonuçlarının konfüzyon matrisleri Çizelge 4.20'de verilmiştir.

Çizelge 4.20. ÖS3'ün 5 kat çapraz doğrulama sonucu ortalama eğitim sonuçlarının konfüzyon matrisleri
a) ANN sonucu b) SVM sonucu c) kNN sonucu d) BT sonucu

ANN		Doğru sınıf		
Tahmin edilen sınıf		-1	0	1
	-1	5304,8	2456,8	91,2
	0	6104,4	29934,2	2783,6
	1	171,6	706,6	1459,6

(a)

SVM		Doğru sınıf		
Tahmin edilen sınıf		-1	0	1
	-1	6873,4	685,8	79
	0	4634	32243	3099
	1	73,6	169	1156

(b)

kNN		Doğru sınıf		
Tahmin edilen sınıf		-1	0	1
	-1	5300,2	1752,2	204,6
	0	6082	30887	2373
	1	199	458,8	1756,6

(c)

BT		Doğru sınıf		
Tahmin edilen sınıf		-1	0	1
	-1	11559,8	4,4	0,4
	0	21	33093,2	20,4
	1	0	0	4313,6

(d)

Çizelge 4.20'ye göre ÖS3'ün eğitim verisinde Wake evresinin ANN'de %45.80'i, SVM'de %59.35'i, kNN'de %45.76'sı, BT'de %99.81'i doğru tahmin edilmiştir. En yüksek tahmin değerleri BT sınıflandırıcıdan alınmıştır. NREM evresinin ANN'de %90.44'ü, SVM'de %97.41'i, kNN'de %93.31'i ve BT'de %99.98'i doğru tahmin edilmiştir. NREM evresinde de Wake evresinde olduğu gibi en yüksek tahmin değerlerine BT sınıflandırıcı ulaşmıştır. REM evresi için ANN'de %33.67'lik, SVM'de %97.41'lik, kNN'de %40.52'lik, BT'de %99.52'lik tahmin yüzdesi oluşmuştur. En yüksek tahmin değeri ÖS1 ve ÖS2'nin eğitim verilerinde olduğu gibi BT sınıflandırıcıdan alınmıştır. Çizelge 4.21'de ÖS3 için elde edilen test sonuçlarının 5 kat çapraz doğrulama sonucu oluşan ortalama konfüzyon matrisleri verilmiştir.

Çizelge 4.21. ÖS3'ün 5 kat çapraz doğrulama sonucu ortalama test sonuçlarının konfüzyon matrisleri a) ANN sonucu b) SVM sonucu c) kNN sonucu d) BT sonucu

ANN		Doğru sınıf		
Tahmin edilen sınıf		-1	0	1
	-1	1148,6	874	60,2
	0	1690,2	7216,6	903
	1	56,4	183,8	120,4

(a)

SVM		Doğru sınıf		
Tahmin edilen sınıf		-1	0	1
	-1	665,4	458	48,2
	0	2207	7744	994,8
	1	22,6	76,8	40,6

(b)

kNN		Doğru sınıf		
Tahmin edilen sınıf		-1	0	1
	-1	837,8	878,6	134,6
	0	1982	7163	834
	1	75,2	232,8	115

(c)

BT		Doğru sınıf		
Tahmin edilen sınıf		-1	0	1
	-1	1132	1026,8	122,4
	0	1735,6	7141	830,6
	1	26,8	106,6	130,6

(d)

Çizelge 4.21 incelendiğinde ÖS3'ün test verisinde, Wake evresi için ANN 'den %39.67'lik, SVM'den %22.98'lik, kNN 'den %28.93'lük, BT'den %39.11'lik doğru tahmin yüzdesi oluşmaktadır. Bu sonuçlara göre test verisinde Wake evresini en iyi tahmin eden sınıflandırıcının ANN olduğu görülmektedir. NREM evresinin ANN %87.27'sini doğru tahmin ederken, SVM %93.54'ünü, kNN %86.56'sını ve BT %86.30'unu doğru tahmin etmiştir. NREM evresi için en iyi tahmin sonucunu, SVM sınıflandırıcı vermiştir. REM evresine bakıldığında ANN %11.11'ini, SVM %3.74'ünü, kNN %10.61'ini, BT %12.05'ini doğru tahmin etmiştir. Yine diğer özellik setlerinin test verilerinde olduğu gibi ÖS3'ün test verisinde de REM evresinin tahmin değerleri en düşüktür. ÖS3'ten elde edilen konfüzyon matrislerinin genel değerlendirmesi yapıldığında yine ÖS1 ve ÖS2'de olduğu gibi eğitim verisinde BT sınıflandırıcısının en iyi tahmin değerine ulaştığı görülmektedir. Test verisindeki tahmin değerlerine bakıldığında, Wake evresinde ANN sınıflandırıcısının, NREM evresinde SVM sınıflandırıcısının ve REM evresinde BT sınıflandırıcısının daha iyi tahmin değerlerine ulaştığı anlaşılmaktadır. Çizelge 4.22-4.23'te üç özellik setinin 5 kat çapraz doğrulama uygulanan eğitim ve test verilerinin performans değerlendirme ölçütleri verilmiştir.

Çizelge 4.22. 3 özellik setlerinin eğitim verisine 5 kat çapraz doğrulama ile elde edilen ortalama sınıflandırma sonuçları

Özellik Seti	Sınıflayıcı	Doğruluk	Recall	Özgüllük	Precision	F skoru
ÖS1	kNN	0.8030	0.6453	0,8197	0,8080	0,6962
	SVM	0.9806	0.9450	0.9808	0.9885	0.9651
	ANN	0.7636	0.7195	0.8391	0.6080	0.6464
	BT	0.9990	0.9984	0.9993	0.9996	0.9990
ÖS2	kNN	0.7526	0.5353	0.7762	0.7100	0.5770
	SVM	0.8462	0.6444	0.8501	0.8856	0.7029
	ANN	0.7468	0.6919	0.8235	0.5620	0.6016
	BT	0.9990	0.9971	0.9988	0.9993	0.9982
ÖS3	kNN	0.7744	0.6453	0.8197	0.8080	0.3789
	SVM	0.6470	0,6116	0,8295	0,8459	0,6663
	ANN	0.6530	0.5270	0.7521	0.4583	0.4485
	BT	0.6240	0.4325	0.7181	0.4670	0.4042

Çizelge 4.23. 3 özellik setlerinin test verisine 5 kat çapraz doğrulama ile elde edilen sınıflandırma sonuçları

Özellik Seti	Sınıflayıcı	Doğruluk	Recall	Özgüllük	Precision	F skoru
ÖS1	kNN	0.6504	0.4019	0.7026	0.4599	0.4072
	SVM	0.6856	0.3757	0.6835	0.6269	0.3519
	ANN	0.6682	0.5085	0.7497	0.4493	0.4639
	BT	0.6772	0.4391	0.7257	0.5435	0.4534
ÖS2	kNN	0.6688	0.4130	0.7134	0.4909	0.4195
	SVM	0.6936	0.4045	0.7091	0.5798	0.4058
	ANN	0.7002	0.5702	0.7787	0.4737	0.4926
	BT	0.6872	0.4619	0.7404	0.5553	0.4758
ÖS3	kNN	0.6628	0.4216	0.7200	0.4813	0.4294
	SVM	0.6908	0.4021	0.7116	0.5135	0.3997
	ANN	0.6928	0.5397	0.7727	0.4593	0.4736
	BT	0.6858	0.4585	0.7404	0.5678	0.4725

Performans değerlendirme ölçütleri incelendiğinde, eğitim verisinde BT sınıflandırıcısı en iyi başarıyı verirken, test verisinde ANN sınıflandırıcısı en iyi başarıyı vermiştir. 5 kat çapraz doğrulama yöntemi ile eğitim/test ayrımı ile yapılan denemeler

karşılaştırıldığında sınıflandırıcıların çapraz doğrulama ile test başarısının çok daha iyi olduğu görülmüştür. En yüksek test başarısının elde edildiği veri seti 5 kat çapraz doğrulama uygulanan EMD yöntemi kullanılarak özellikler çıkarılan ÖS2 ve %70.02 ile ANN ‘den alınmıştır. Tüm özellik setlerinin birleştirilmesi ile elde edilen veri setinin (ÖS4) eğitim sonuçlarının 5 kat çapraz doğrulama sonucu oluşan konfüzyon matrisleri Çizelge 4.24’te verilmiştir.

Çizelge 4.24. ÖS4’ün 5 kat çapraz doğrulama sonucu ortalama eğitim sonuçlarının konfüzyon matrisleri
a) ANN sonucu b) SVM sonucu c) kNN sonucu d) BT sonucu

ANN		Doğru sınıf		
Tahmin edilen sınıf		-1	0	1
	-1	6423,4	2238,4	59,2
	0	5006,2	30083,6	1471,4
	1	151,2	775,6	2803,8

(a)

SVM		Doğru sınıf		
Tahmin edilen sınıf		-1	0	1
	-1	11279,4	6,2	2,4
	0	285,2	33074	648,4
	1	16,2	17,8	3684

(b)

kNN		Doğru sınıf		
Tahmin edilen sınıf		-1	0	1
	-1	6093,8	1104,6	112,2
	0	5298	31596	1642
	1	189	397	2581

(c)

BT		Doğru sınıf		
Tahmin edilen sınıf		-1	0	1
	-1	11563,6	2,2	0
	0	17,2	33095	10,6
	1	0	0	4324

(d)

ÖS4’ün eğitim verisi sonuçları incelendiğinde (Çizelge 4.24), Wake evresinin ANN sınıflandırıcıda %55.46’sı, SVM sınıflandırıcıda %97.39’u, kNN sınıflandırıcıda %52.61’i ve BT sınıflandırıcıda %99.85’i doğru tahmin edilmiştir. NREM evresinin ANN’de %90.89’u, SVM’de %99.92’si, kNN’de %95.46’sı ve BT’de %99.99’u doğru tahmin edilmiştir ve Wake ve NREM evrelerinde en iyi tahmin değerleri BT sınıflandırıcıdan alındığı anlaşılmıştır. REM evresinin bu özellik setinde de diğer özellik setlerinin eğitim verilerinde olduğu gibi BT sınıflandırıcı diğer sınıflandırma yöntemlerinden daha iyi sonuçlar vermiştir.

Çizelge 4.25. ÖS4'ün 5 kat çapraz doğrulama sonucu ortalama test sonuçlarının konfüzyon matrisleri a) ANN sonucu b) SVM sonucu c) kNN sonucu d) BT sonucu

ANN		Doğru sınıf		
Tahmin edilen sınıf		-1	0	1
	-1	1259,8	1227,2	75,8
	0	1537,8	6682,2	761,4
	1	97,6	365	246,4

(a)

SVM		Doğru sınıf		
Tahmin edilen sınıf		-1	0	1
	-1	128,2	50,8	11
	0	2756	8171	959,6
	1	10,8	52,2	113

(b)

kNN		Doğru sınıf		
Tahmin edilen sınıf		-1	0	1
	-1	682	711,6	104
	0	2114	7239	808
	1	99,4	323	172

(c)

BT		Doğru sınıf		
Tahmin edilen sınıf		-1	0	1
	-1	1157	1003,6	101,4
	0	1724	7181	868,8
	1	14	90	113

(d)

Çizelge 4.25'deki ÖS4'ün test sonuçları incelendiğinde, Wake evresinin ANN 'de %43.51'i, SVM'de %4.42'si, kNN 'de %23.55'i, BT'de %39.96'sı doğru tahmin edilmiştir. Wake evresinin eğitim verisindeki başarısına göre test verisindeki başarısı oldukça düşük olduğu görülmektedir. NREM evresine bakıldığında ANN %80.75'ini, SVM %98.75'ini, kNN %87.49'unu, BT ise %86.78'ini doğru tahmin etmiştir. NREM evresi en yüksek başarıya SVM sınıflandırıcı ile ulaşmıştır. ÖS4'ün test verisinde REM evresinin ANN %22.73'ünü, SVM %10.42'sini, kNN %15.86'sını, BT ise %10.43'ünü doğru tahmin etmiştir.

Çizelge 4.26. ÖS4'ün eğitim ve test sonuçlarının 5 kat çapraz doğrulama ile elde edilen ortalama sınıflandırma sonuçları

	Sınıflayıcı	Doğruluk	Recall	Özgüllük	Precision	F skoru
Eğitim	kNN	0.8214	0.6920	0.8394	0.8241	0.7378
	SVM	0.9800	0.9410	0.9801	0.9876	0.9624
	ANN	0.8022	0.6095	0.8154	0.7500	0.6532
	BT	0.9994	0.9987	0.9994	0.9997	0.9992
Test	kNN	0.6608	0.4229	0.7140	0.4888	0.4325
	SVM	0.6874	0.3789	0.6848	0.6513	0.3575
	ANN	0.6680	0.3288	0.6682	0.3399	0.2012
	BT	0.6900	0.4575	0.7404	0.5808	0.4704

Bütün veri setleri ile sınıflandırma denemeleri yapıldıktan sonra performansı arttırmak için Relief ile özellik seçme uygulanmış ve ÖS4'te bulunan 132 özellikten 41 tanesi Relief özellik seçme yöntemi ile çıkarılmıştır. Bu özellik seti ÖS5 olarak adlandırılmıştır. Kalan 91 özelliğin daha etkili olduğu düşünülerek sınıflandırma işlemleri bu 91 özellik ile yapılmıştır. Çizelge 4.27'de 132 özellik seti arasından çıkarılan 41 özellik verilmiştir.

Çizelge 4.27. Relief sonucu çıkarılan özellikler

Sıra No	Özellik
1	Beta frekans bandına ait relatif güç (Frekans Özelliği)
2	Alfa frekans bandına ait relatif güç (Frekans Özelliği)
3	Alfa frekans bandına ait standart sapma (Frekans Özelliği)
4	Alfa frekans bandına ait skewness(çarpıklık) (Frekans Özelliği)
5	Alfa frekans bandına ait kurtosis(basıklık) (Frekans Özelliği)
6	Teta frekans bandına ait relatif güç (Frekans Özelliği)
7	Teta frekans bandına ait ortalama değer (Frekans Özelliği)
8	Teta frekans bandına ait standart sapma
9	Teta frekans bandına ait skewness(çarpıklık) (Frekans Özelliği)
10	Teta frekans bandına ait kurtosis(basıklık) (Frekans Özelliği)
11	Alfa frekans bandına ait enerji (Zaman Özelliği)
12	Alfa frekans bandına ait güç (Zaman Özelliği)
13	Alfa frekans bandına ait relatif güç (Zaman Özelliği)
14	Teta frekans bandına ait ortalama değer (Zaman Özelliği)
15	Teta frekans bandına ait enerji (Zaman Özelliği)
16	Teta frekans bandına ait güç (Zaman Özelliği)
17	Teta frekans bandına ait değerler/ Tüm dalga değerleri (Zaman Özelliği)
18	Teta frekans bandına ait relatif güç (Zaman Özelliği)
19	Delta frekans bandına ait entropy değeri (Zaman Özelliği)
20	EMD sonucunda elde edilen IMF2'nin ortalama değeri
21	EMD sonucunda elde edilen IMF3'ün ortalama değeri
22	EMD sonucunda elde edilen IMF4'ün ortalama değeri
23	EMD sonucunda elde edilen IMF4'ün standart sapması
24	EMD sonucunda elde edilen IMF1'in Fluctuation Index değeri
25	EMD sonucunda elde edilen IMF2'nin Fluctuation Index değeri
26	EMD sonucunda elde edilen IMF3'ün Fluctuation Index değeri
27	EMD sonucunda elde edilen IMF4'ün Fluctuation Index değeri
28	EMD sonucunda elde edilen IMF3'ün güç değeri
29	EMD sonucunda elde edilen IMF4'ün güç değeri
30	EMD sonucunda elde edilen IMF4'ün Fractal Dimension
31	VMD sonucunda elde edilen IMF1'in ortalama değeri
32	VMD sonucunda elde edilen IMF2'nin ortalama değeri
33	VMD sonucunda elde edilen IMF3'ün ortalama değeri
34	VMD sonucunda elde edilen IMF4'ün ortalama değeri
35	VMD sonucunda elde edilen IMF1'in Fluctuation Index değeri
36	VMD sonucunda elde edilen IMF2'nin Fluctuation Index değeri
37	VMD sonucunda elde edilen IMF3'ün Fluctuation Index değeri
38	VMD sonucunda elde edilen IMF4'ün Fluctuation Index değeri
39	VMD sonucunda elde edilen IMF3'ün güç değeri
40	VMD sonucunda elde edilen IMF4'ün güç değeri
41	VMD sonucunda elde edilen IMF4'ün Fractal Dimension

Özellik seçme sonucunda oluşturulan yeni özellik seti (ÖS5) ile sınıflandırma işlemleri 5 kat çapraz doğrulama uygulamadan ve 5 kat çapraz doğrulama uygulayarak sonuçlar elde edilmiştir. ÖS5'te eğitim ve test verisi olarak ayrılarak işlemler yapılmıştır. Çizelge 4.28'de verilen sonuçlar 5 kat çapraz doğrulama uygulanmamış eğitim verisinin sınıflandırıcı sonuçlarıdır.

Çizelge 4.28. ÖS5 için elde edilen eğitim sonuçlarının konfüzyon matrisleri a) ANN sonucu b) SVM sonucu c) kNN sonucu d) BT sonucu

ANN		Doğru sınıf		
Tahmin edilen sınıf		-1	0	1
	-1	6492	2220	46
	0	4922	28094	1025
	1	110	462	1793
(a)				
SVM		Doğru sınıf		
Tahmin edilen sınıf		-1	0	1
	-1	11223	8	3
	0	286	30764	407
	1	15	4	2454
(b)				
kNN		Doğru sınıf		
Tahmin edilen sınıf		-1	0	1
	-1	5619	750	73
	0	5813	29837	1026
	1	92	189	1765
(c)				
BT		Doğru sınıf		
Tahmin edilen sınıf		-1	0	1
	-1	11507	0	1
	0	17	30776	7
	1	0	0	2856
(d)				

Çizelge 4.28'de verilen ÖS5'in eğitim sonuçlarına göre Wake evresindeki en iyi tahmin edilme oranı BT'de %99.85'tir. BT'den sonra Wake evresinin %99.38'ini doğru tahmin eden SVM sınıflandırıcı gelmektedir. ANN, Wake evresinin %56.33'ünü doğru tahmin ederek üçüncü sıradadır. kNN ise Wake evresinin %48.75'ini doğru tahmin etmiştir ve en kötü sonucu veren sınıflandırıcıdır. NREM evresinin ANN %91.28'sini, SVM %99.96'sını, kNN %96.94'ünü ve BT %100'ünü doğru tahmin etmiştir. En yüksek başarı NREM evresinde de BT sınıflandırıcıdan alınmıştır. REM evresine bakıldığında ise ANN %62.60'ını, SVM %85.68'ini, kNN %61.62'sini, BT %99.72'sini doğru tahmin etmiştir. REM evresinde de en iyi başarı BT'den alınırken, en kötü başarı kNN'den alınmıştır. ÖS5'in test sonuçlarından elde edilen konfüzyon matrisleri Çizelge 4.29'da verilmiştir.

Çizelge 4.29. ÖS5 için elde edilen test sonuçlarının konfüzyon matrisleri a) ANN sonucu b) SVM sonucu c) kNN sonucu d) BT sonucu

ANN		Doğru sınıf		
Tahmin edilen sınıf		-1	0	1
	-1	4	16	4
	0	2948	10580	2550
	1	0	0	0

(a)

kNN		Doğru sınıf		
Tahmin edilen sınıf		-1	0	1
	-1	2778	10395	2484
	0	174	201	70
	1	0	0	0

(c)

SVM		Doğru sınıf		
Tahmin edilen sınıf		-1	0	1
	-1	0	0	0
	0	2952	10596	2554
	1	0	0	0

(b)

BT		Doğru sınıf		
Tahmin edilen sınıf		-1	0	1
	-1	756	2717	1003
	0	2196	7879	1551
	1	0	0	0

(d)

Çizelge 4.29’da alınan sonuçlar incelendiğinde ÖS5’in test sonuçlarının diğer özellik setleri arasındaki en kötü başarıya sahip olduğu görülmektedir. REM evresini hiçbir sınıflandırıcı doğru tahmin edememiştir. Wake evresinin ise ANN %0.13’ünü, kNN %94.10’unu, BT %25.60’ını doğru tahmin ederken SVM sadece NREM evresini doğru tahmin etmiştir. Çizelge 4.30’da görüldüğü üzere, performans değerlendirme ölçütlerinde en kötü test başarısı BT’den alınmıştır. BT eğitim verisinde en iyi sonucu verirken test verisinde en kötü sonucu veren sınıflandırıcı olmuştur.

Çizelge 4.30. ÖS5 için eğitim ve test verilerinin sınıflandırma sonuçları

	Sınıflayıcı	Doğruluk	Recall	Özgüllük	Precision	F skoru
Eğitim	kNN	0.8240	0.6911	0.8312	0.8495	0.7430
	SVM	0.9840	0.9434	0.9837	0.9898	0.9649
	ANN	0.8050	0.7749	0.8652	0.7007	0.7309
	BT	0.9990	0.9986	0.9994	0.9997	0.9991
Test	kNN	0.6270	0.3200	0.6588	0.3146	0.1675
	SVM	0.6580	0.3333	0.6667	0.6581	0.7938
	ANN	0.6570	0,2749	0,6638	0,3333	0,2653
	BT	0.5360	0.3332	0.6789	0.4233	0.4563

ÖS5'e 5 kat çapraz doğrulama uygulanarak sınıflandırıcı sonuçları incelenmiştir. Çizelge 4.31'de 5 kat çapraz doğrulama uygulanması ile elde edilen eğitim sonuçlarının konfüzyon matrisleri verilmiştir.

Çizelge 4.31. ÖS5'in 5 kat çapraz doğrulama ile elde edilen ortalama eğitim sonuçları için konfüzyon matrisleri a) ANN sonucu b) SVM sonucu c) kNN sonucu d) BT sonucu

ANN		Doğru sınıf		
Tahmin edilen sınıf		-1	0	1
	-1	6243,6	2280,2	55,4
	0	5198,4	30034,4	1618
	1	138,8	783	2661

(a)

SVM		Doğru sınıf		
Tahmin edilen sınıf		-1	0	1
	-1	11180,2	5,4	3,2
	0	380,6	33066	270,4
	1	20	25,8	4060

(b)

kNN		Doğru sınıf		
Tahmin edilen sınıf		-1	0	1
	-1	6593,8	1178	116,2
	0	4802	31553	1372
	1	185,4	367	2845,8

(c)

BT		Doğru sınıf		
Tahmin edilen sınıf		-1	0	1
	-1	11565,6	2,4	0
	0	14,8	33095	5,8
	1	0,4	0,4	4329

(d)

Çizelge 4.31'de verilen konfüzyon matrisleri incelendiğinde, Wake evresinin ANN %53.91'ini, SVM %96.54'ünü, kNN %56.93'ünü, BT %99.86'sını doğru tahmin etmiştir. Wake evresindeki en iyi başarı BT'den alınmıştır. En kötü başarıyı ise ANN vermiştir. NREM evresinin ANN %90.74'ünü, SVM %99.90'ını, kNN %95.33'ünü, BT

%99.99'ünü doğru tahmin etmiştir. NREM evresinde de BT en iyi başarıya ulaşmıştır. NREM evresindeki en kötü başarı ise ANN'den alınmıştır. REM evresinin ANN %61.39'unu, SVM %93.68'ini, kNN %65.66'sını, BT %99.86'sını doğru tahmin etmiştir ve diğer evrelerde olduğu gibi REM evresinde de BT en iyi başarıyı vermiştir. REM evresinde en kötü başarı ANN'den alınmıştır. Çizelge 4.32'de ÖS5'in 5 kat çapraz doğrulama uygulanmış test sonuçlarının ortalama konfüzyon matrisleri verilmiştir.

Çizelge 4.32. ÖS5'in 5 kat çapraz doğrulama ile elde edilen ortalama test sonuçları için konfüzyon matrisleri a) ANN sonucu b) SVM sonucu c) kNN sonucu d) BT sonucu

ANN		Doğru sınıf		
Tahmin edilen sınıf		-1	0	1
	-1	1211,2	1086,2	69
	0	1592,6	6825	765
	1	91,4	363,2	249,6

(a)

SVM		Doğru sınıf		
Tahmin edilen sınıf		-1	0	1
	-1	123	60,4	14,2
	0	2757	8153	951,8
	1	15,2	61	118

(b)

kNN		Doğru sınıf		
Tahmin edilen sınıf		-1	0	1
	-1	725,4	766,4	107,6
	0	2063	7171	787,2
	1	107	337	188,8

(c)

BT		Doğru sınıf		
Tahmin edilen sınıf		-1	0	1
	-1	1167,8	1008,8	88,4
	0	1710	7186	885
	1	17,4	80	110

(d)

Çizelge 4.32'de verilen 5 kat çapraz doğrulama uygulanmış ÖS5'in test verisi için, Wake evresinde en iyi tahmin yüzdesini ANN %41.83 ile vermektedir. ANN 'den sonra en iyi tahmin yüzdesi BT'den %40.33 olarak alınmıştır. Wake evresinin kNN %25.05'ini doğru tahmin etmiştir ve SVM ise %4.24'ünü doğru tahmin ederek en kötü başarıyı göstermiştir. NREM evresini en iyi tahmin eden sınıflandırıcı %98.5 ile SVM'dir. NREM evresinin ANN %82.48'ini, kNN %86.66'sını, BT %86.84'ünü doğru tahmin etmiştir. REM evresinin tahmin edilme yüzdeleri diğer özellik setlerinin sonuçlarında olduğu gibi ÖS5'te de çok düşüktür. REM evresinin ANN %23.03'ünü, SVM %10.88'ini, kNN %17.42'sini, BT %10.15'ini doğru tahmin etmiştir.

5 kat çapraz doğrulama uygulanmış ÖS5'in sonuçları, uygulanmamış halinden daha iyi sonuç vermiştir. Bunun sebebinin 5 kat çapraz doğrulama yapılırken verilerin

hasta bazlı olarak ayrılmasından kaynaklı olduğu düşünülmektedir. 5 kat çapraz doğrulama uygulanmamış sonuçlarda veri seti rastgele olarak 100'ünü eğitim 24'ünü test olarak kullanıp sınıflandırma işlemi yapılmıştır. 5 kat çapraz doğrulamada ise hasta bazlı olarak veri seti 5 parçaya ayrılmıştır. Hastanın verisinin genliği de hastaya bağlı olarak değiştiği için çapraz doğrulamada sonuçların daha iyi çıktığı anlaşılmaktadır. Buradan 5 kat çapraz doğrulamanın etkisi görülmektedir. Çizelge 4.33'te ÖS5'in her bir sınıf için performans değerlendirme ölçütleri verilmiştir.

Çizelge 4.33. ÖS5 için eğitim verisinde 5 kat çapraz doğrulama ile elde edilen ortalama sınıflandırma sonuçları

	Sınıflayıcı	Doğruluk	Recall	Özgüllük	Precision	F skoru
Eğitim	kNN	0.8364	0.7264	0.8550	0.8379	0.7675
	SVM	0.9858	0.9672	0.9860	0.9896	0.9780
	ANN	0.7944	0.7618	0.8598	0.6869	0.7167
	BT	0.9996	0.9991	0.9995	0.9997	0.9994
Test	kNN	0.6600	0.4306	0.7174	0.4911	0.4413
	SVM	0.6858	0.3789	0.6845	0.6205	0.3576
	ANN	0.6760	0.5378	0.7618	0.4906	0.5054
	BT	0.6912	0.4581	0.7409	0.5854	0.4706

Çizelge 4.33 incelendiğinde, en iyi eğitim ve test verisindeki başarının BT sınıflandırıcıdan alındığı görülmektedir. Performans değerlendirme ölçütleri incelendiğinde ise eğitim verisinde ANN sınıflandırıcının test verisinde kNN sınıflandırıcısının en kötü başarıya ulaştığı anlaşılmaktadır. Tüm özellik setlerinden alınan sınıflandırma sonuçları incelendiğinde REM evresinin başarısının çok düşük olduğu görülmektedir. Bunun sebebinin veri setindeki REM sayılarının az olmasından kaynaklı olduğu düşünülmektedir. Tüm özellik setleri arasında en iyi test sonucu çapraz doğrulama uygulanarak ÖS2 ile yapılan sınıflandırmadan %70.02 başarı ile ANN'den alınmıştır. Konfüzyon matrislerinden elde edilen performans değerlendirme kriterlerindeki sonuçlar ortalama değerleri göstermektedir. ÖS2 kullanılarak ANN ile yapılan uyku evreleme sonucunda ortalama Recall %57.02, Özgüllük %77.87, Precision %47.37, F skoru %49.26 çıkmıştır. Veri setindeki sınıflandırıcı sayılarındaki dengesizlik sonucunda Recall ve Precision değerleri düşük çıkmıştır. F skoru da Recall ve Precision değerlerinin harmonik ortalaması sonucu elde edildiği için bu değer de düşük çıkmıştır.

Bu yüzden apnenin evre ve/veya pozisyon bağımlı olup olmadığı durumu ANN sınıflandırıcısının eğitilmiş modeli ile yapılmıştır.

Tez çalışmasının literatürdeki diğer uyku evreleme çalışmaları ile karşılaştırıldığı Çizelge 4.34’te verilmiştir.

Çizelge 4.34. Literatürde yapılan çalışmalar ile tez çalışmasının karşılaştırılması

Çalışmayı Yapan	Kullanılan Sinyaller	Kullanılan Veri Seti	Sınıflandırma Doğruluğu
Özşen ve ark. (2010)	EEG, EOG, EMG	Hastane	%69.30
Güneş ve ark. (2010)	EEG	Hastane	%82.15
Ersöz ve Özşen (2011)	EEG	Hastane	%80
Alickovic ve Subasi (2018)	EEG	Hazır veri seti	%91.1
Michielli ve ark. (2019)	EEG	Hazır veri seti	%90.8
Huang Wu ve ark. (2020)	EEG	Hazır veri seti	%98.28
Tez çalışması	EEG	Hastane	%70.02

Literatürdeki bazı çalışmalar ile karşılaştırıldığında Çizelge 4.35’te görüldüğü gibi, çalışmaların bazıları (Alickovic ve Subasi, 2018, Huang Wu ve ark., 2020, Michielli ve ark., 2019) hazır veri setleri ile uyku evreleme yaptıkları için evreleme başarılarının çok yüksek çıktığı düşünülmektedir. Bu tez çalışmasında kullanılan veri seti hem hastaneden alınan gürültülü veriler olduğu için hem de yeteri kadar REM evreleri bulunduran veriler olmadığı için başarı çok yüksek çıkmamıştır. Ancak REM evresinin çok olduğu ve herhangi bir gürültü bulunmayan veri setlerinde çalışmanın iyi başarı elde edileceği düşünülmektedir.

4.3. REM ve/veya Pozisyon Bağımlı OSAS Hastalarının Tespit Edilmesi

Bu tez çalışmasında kullanılan 124 hastanın hiçbirinin REM ve/veya pozisyon bağımlı olmamasından dolayı bu kriterlere uyan ek olarak uyku laboratuvarında alınmış 9 hasta kaydı temin edilmiştir. 9 hastaya ait demografik bilgiler Çizelge 4.35’te verilmiştir. Bu süreçte, öncelikle, bu 9 hastanın EEG sinyallerinden elektrot kopması ve majör vücut hareketleri gürültüleri ön işlem olarak temizlenmiş ve Çizelge 4.36’da her bir hasta için ham ve temizlenmiş veri setlerinde bulunan Wake, NREM ve REM evre sayıları ayrı ayrı gösterilmiştir. Çizelge 4.35’te AHI olarak ifade edilen kısım, Apne-

Hipopne İndeks'tir. AHI, hastanın uyku süresi boyunca oluşan apne hipopne sayılarının uyku süresine bölünmesi ile oluşan bir değerdir ve kişinin hangi seviyede uyku apnesine sahip olduğu hakkında bilgi verir. AHI değeri, uyku apnesine sahip olmayan kişiler için 5'ten küçük olması gerekmektedir. AHI değeri, 5 ile 15 arasında ise hasta hafif derecede uyku apnesine, 15 ile 30 derece arasında ile orta derecede uyku apnesine, 30'dan büyük ise ağır derecede uyku apnesine sahiptir.

Çizelge 4.35. 9 hastaya ait demografik bilgiler

Hasta No	Yaş	Cinsiyet	BMI	AHI
1	39	E	2,40	93,2
2	50	E	32,8	50,1
3	49	E	27,3	63,9
4	55	E	27,8	23,90
5	52	E	30,3	32
6	50	E	34	35,3
7	42	E	28,4	7,9
8	42	E	23,9	15,5
9	46	E	30	5,6

Çizelge 4.36. 9 hastanın ham ve temizlenmiş sinyallerinden bulunan epok sayısı

Hasta No	HAM VERİ				TEMİZLENMİŞ VERİ			
	Wake	NREM	REM	TOPLAM	Wake	NREM	REM	TOPLAM
1	152	370	0	522	112	294	0	406
2	70	1016	35	1121	63	886	25	974
3	472	364	23	859	399	358	23	780
4	215	837	0	1052	168	768	0	936
5	266	503	40	809	197	493	40	730
6	140	1032	175	1347	97	989	174	1260
7	183	559	127	869	181	547	125	853
8	397	427	86	910	145	623	78	846
9	148	498	35	681	86	493	35	614

Tez çalışmasında temiz veri ile daha iyi sınıflandırma performansı elde edildiği 9 hastanın temiz verileri ile uyku evreleri tespit edilmiştir. Test işlemi yapılmadan önce uyku evreleme sonuçlarına göre en iyi sonucu veren ÖS2 ile ANN sınıflandırıcı olduğu için 9 hastadan ÖS2'den çıkarılan özellikler çıkarılmış ve özellik setleri oluşturulmuştur. Daha sonra eğitilmiş ANN modeline bu hastaların her biri tek tek test olarak verilmiştir. OSAS hastalarının REM ve pozisyon bağımlılığının tespit edilmesinde dünya literatüründe AASM tarafından belirlenmiş kriterler vardır. Bunun yanında, bu kriterlerin

belirlenmesinde pratikte yaşanan sorunlar nedeniyle manuel uygulamada uyku uzmanlarının tecrübeleri doğrultusunda gerçekleştirdikleri farklı uygulamalar söz konusudur.

Apne tespitinde kullanılan terimlerden olan REM AHI, apnenin REM evresinde bulunduğu epok sayısının REM süresine bölünmesi ile, NREM AHI, apnenin NREM evresinde bulunduğu epok sayısının NREM süresine bölünmesi ile bulunur.

AASM'nin yayınladığı kriterler doğrultusunda Türk Toraks Derneğinin yayınlamış olduğu rapora (Çiftçi, 2012) göre OSAS hastalığının REM'e ve pozisyona bağımlılığının belirlenmesinde kullanılmak üzere yaptıkları çalışmada, kurallar toplam AHI değerinin 5'ten büyük olması yani hastanın OSAS hastası olması üzerine kurulmuştur. İlave olarak, bir hastaya REM bağımlı OSAS denilebilmesi için NREM-AHI'nin normal sınırlarda olması (5'ten küçük olması) ve REM-AHI'nin NREM-AHI'nin en az 2 katı olması gerekmektedir.

Pozisyon bağımlı apne tespitinde Supin, Nsupin terimleri hastanın pozisyonunu ifade etmektedir. Supin, hastanın sırt üstü yatmasına verilen isimdir. Hastanın supin harici bulunduğu pozisyonlar (Sağ, Sol) Nsupin olarak ifade edilir. Pozisyon bağımlı apnede de REM bağımlı apnede olduğu gibi Supin AHI ve Nsupin AHI değerleri hesaplanır. Supin AHI, apnenin Supin pozisyonu esnasında olduğu epok ayısının Supin süresine bölünmesi ile, Nsupin AHI, apnenin Nsupin pozisyonu esnasında olduğu epok sayısının Nsupin süresine bölünmesi ile hesaplanır. Pozisyon bağımlı OSAS tanısı, Nsupin-AHI'nin normal sınırlarda olması (5'ten küçük olması) ve Supin-AHI'nin Nsupin-AHI'nin en az 2 katı olması gerekmektedir. Bunun yanında, hastaya tanı konulurken, hastanın pozisyon bağımlı olup olmadığının belirlenmesi sırasında, uyku kliniğinde uyku uzmanları tarafından, pratik uygulamalarda hastanın Nsupin süresinin yaklaşık olarak en az 60 dakika olması şartı aranmakta ve hatta uyku laboratuvarında REM bağımlı ve pozisyon bağımlı diyebilmek için teorik kurallardan farklı olarak NREM-AHI<5 ve Nsupin-AHI<5 şartları dikkate alınmamaktadır.

Bu kriterler dikkate alınarak, uyku uzmanı tarafından klinikte, Hasta2, Hasta4, Hasta6 ve Hasta8 sadece pozisyon bağımlı ve Hasta5, Hasta7 ve Hasta9 hem REM bağımlı hem de pozisyon bağımlı olarak etiketlenmiş ve raporlanmıştır. Hasta1 ve Hasta3 REM ve/veya pozisyon bağımlı değildir. Bu tez çalışması kapsamında raporlara göre değerlendirme yapılmıştır. Bu tanıların etiketlenmiş epoklara göre uyumunu görmek adına hasta için yapılan evreleme sonuçları baz alınarak uykuda oldukları epoklar,

olaylar, REM, NREM, apne sayıları ve hesaplanmış AHI değerleri REM bağımlılığı görebilmek için Çizelge 4.37’de verilmiştir.

Çizelge 4.37. 9 hasta için Ham veride evre ve olay sayıları ve hesaplanan AHI değerleri

Hasta No	REM AHI	NREM AHI	REM (Sayı)	NREM (Sayı)	Nwake (Sayı)	REM+Apne (Sayı)	NREM+Apne (Sayı)	Total AHI	Sonuç
1		86,5	0	370	370	0	267	86,6	0
2	61,7	45,7	35	1016	1051	18	387	46,2	0
3	26,0	55,7	23	364	387	5	169	54,0	0
4		21,2	0	837	837	0	148	30,1	0
5	69	26,9	40	503	543	23	113	32,5	1
6	46,6	30,1	175	1032	1207	68	259	7,7	0
7	16,0	5,7	127	559	686	17	27	22,0	1
8	4,1	25,5	86	427	513	3	91	21,2	0
9	20,5	4,3	35	498	533	6	18	5,4	1

REM (Sayı), REM epok sayısını, NREM (Sayı), NREM epok sayısını, Nwake, Wake olmayan epok sayısını, REM+Apne, hem REM hem apne olan epok sayısını, NREM+Apne, hem NREM hem apne olan epok sayısını

Çizelge 4.37’de “Sonuç” olarak ifade edilen son sütunda “1” değeri hastanın REM bağımlılığını ifade etmektedir. Hasta1’de ve Hasta4’te hiç REM evresi bulunmamaktadır. Hem skorlanmış evrelere göre hem de raporlara gör Hasta5, Hasta7 ve Hasta9 REM bağımlı hastalardır (Çizelge 4.37). Çizelge 4.38’de ANN sınıflandırıcı ile yapılan evre tahminlerini ve bu tahminler kullanılarak hesaplanan REM-AHI ve NREM-AHI değerlerini ve REM bağımlı (1) veya bağımlı değil (0) sonucunu göstermektedir.

Çizelge 4.38. 9 hasta için ANN ile tahmin edilen evre ve olay sayıları ve AHI değerleri

Hasta No	REM AHI	NREM AHI	REM (Sayı)	NREM (Sayı)	Nwake (Sayı)	REM+Apne (Sayı)	NREM+Apne (Sayı)	Sonuç
1	0,0	79,7	4	378	382	0	251	0
2	57,2	44,2	86	974	1060	41	359	0
3	19,5	40,6	37	405	442	6	137	0
4	0,0	16,7	1	827	828	0	115	0
5	52,0	24,8	30	575	605	13	119	1
6	45,0	30,6	8	1093	1101	3	279	0
7	10,7	5,4	56	670	726	5	30	1
8	0,0	16,7	12	595	607	0	83	0
9	6,1	4,8	98	448	546	5	18	0

Çizelge 4.38’de görüldüğü üzere ANN sınıflandırıcı ile elde edilen sonuçlarda Hasta5’in ve Hasta7’nin REM bağımlılığı doğru tespit edilmiştir. Hasta9, REM bağımlı

olarak tanımlanmamıştır. Hasta9'un yanlış değerlendirilmesinin sebebinin Total AHI değerinin 5'in hemen üstüne olması (5,4), REM süresinin çok kısa olmasından (raporlara göre 17.5 dk) kaynaklandığı düşünülmektedir. Eğitim setinde hastaların REM epoklarının sayısının NREM ve Wake evrelerine göre çok az olması, REM epoklarının tespit edilmesindeki başarıyı düşürmüştür. Bunun sonucu olarak, hasta bazlı değerlendirmede Çizelge 4.36'da verilen REM sayıları ile karşılaştırıldığında sınıflandırıcıların evreleme başarısının çok yüksek olmadığı görülmektedir. Bu sorunun üstesinden gelmek için eğitime işleminin REM evresinin daha fazla olduğu hastalar ile yapılması gerekmektedir.

Pozisyon bağımlı hastaların tespit edilmesi için yapılan çalışmalarda başlangıçta uyku kliniğinde yapılan etiketlemeler dikkate alınmış fakat uyku uzmanının gerçekleştirdiği skorlamalarda epokların Nsupin etiketlemeleri, olayların başlamasından sonra yapıldığı için Nsupin sayıları eksik kalmış ve Nsupin süresinin hesaplanmasında sorun yaşanmıştır. Dolayısıyla etiketleme yapılarak elde edilen Nsupin epok sayısı ile Nsupin süresi tutarlı değildir. Raporda verilen Nsupin süresi yerine, skorlanmış Nsupin'lere (Nsp-AHI1) göre sınıflandırma sonuçları dikkate alındığında bütün yöntemler için hiçbir hastada Supin AHI değerinin Nsupin AHI değerinin iki katı olması şartı sağlanamamaktadır. Bu nedenle, bu sorunun üstesinden gelmek için, Nsupin-AHI değerinin hesaplanmasında raporda belirtilen sağ ve sol yanda geçirdikleri sürelerin toplamı kullanılmıştır. Bu özellik Çizelge 4.39'da "Nsupin süresi" olarak verilmiştir. Çizelge 4.39'da "Sonuç" olarak ifade edilen son sütunda "1" değeri hastanın pozisyon bağımlı olduğunu göstermektedir. Pozisyon bağımlı apne tespitinde, uyku laboratuvarında pratik uygulamada gerçekleştirilen tanılamada, hasta Nsupin'de yaklaşık olarak en az 60 dk geçirmelidir ve AASM'nin kriterlerinde göre Supin-AHI, Nsupin-AHI'nin iki katı olmalıdır kuralına göre Hasta2, Hasta4, Hasta5, Hasta6, Hasta7, Hasta8, Hasta9 pozisyon bağımlı OSAS olarak raporlanmıştır.

Çizelge 4.39. 9 hasta için Ham veride uyku pozisyon süreleri, olay sayıları ve AHI değerleri

HNo	Sp AHI	Nsp AHI1	Sp (Sayı)	Nsp (Sayı)	Sp+Apne (Sayı)	Nsp+Apne (Sayı)	Nsp süresi (dk)	Nsp AHI2	Sonuç
1	95,8	40	333	3	266	1	2	30	0
2	83,1	71,3	394	222	273	132	304,1	26,0	1
3	96,3	76	193	30	155	19	36,6	31,1	0
4	96	92,3	80	39	64	30	183,5	9,8	1
5	85,7	71,4	168	47	120	28	259,5	6,4	1
6	96,8	75	88	104	71	65	218	17,8	1
7	78,6	75	87	432	57	270	557,2	29,0	1
8	88,6	70,5	46	17	34	10	217,8	2,7	1
9	80	68,5	24	14	16	8	163,6	2,9	1

Sp AHI: Supin AHI, Nsp AHI1: Skorlanan Nsupin sayılarına göre Nsupin AHI, Sp: Supin epok sayısı, Nsp: Nsupin epok sayısı, Nwake: Wake olmayan epok sayısı, Sp+Apne: Hem Supin hem apne olan epok sayısı, Nsp+Apne: Hem Nsupin hem apne olan epok sayısı, Nsp süresi: Raporda verilen Nsupin süresi, Nsp Ahi2: Rapordaki Nsupin süresine göre hesaplanan Nsupin AHI değeri

Çizelge 4.40. 9 hasta için ANN ile tahmin edilen uyku pozisyon süreleri, olay sayıları ve AHI değerleri

Hasta No	Sp AHI	Nsp AHI1	Sp (Sayı)	Nsp (Sayı)	Sp+Apne (Sayı)	Nsp+Apne (Sayı)	Nsp süresi (dk)	Nsp AHI2	Sonuç
1	94,3	40	318	3	250	1	2	30	0
2	82,5	72,5	384	225	264	136	112,5	72,5	1
3	97,2	72	158	25	128	15	12,5	75	0
4	80	71,4	135	42	90	25	21	71,4	0
5	96,5	75,9	87	98	70	62	49	6,4	0
6	74,2	75,4	84	366	52	230	183	17,8	1
7	85,7	66,6	35	18	25	10	9	66,6	0
8	97,6	82,5	75	32	61	22	16	41,5	0
9	80	64,6	24	13	16	7	6,5	64,8	0

Çizelge 4.40'ta Sonuç olarak ifade edilen kısım, hastanın Nsupin süresinin 60 dakikadan büyük olmasına dikkat edilerek hesaplanmıştır. Son olarak, uyku evreleme ve pozisyon ve/veya REM bağımlılık tespitinde kayıtlardaki evre sayıları, doğru skorlanmaları, hasta sayısının ve çeşitliliğinin fazla olması gibi parametreler çalışmanın başarısını ve geçerliliğini arttıran önemli parametrelerdir. Bu tez çalışmasında da bu konuda yaşanan zorluklar performansı etkilemiştir. REM bağımlı hastaların üç tanesinden ikisi başarılı bir şekilde tespit edilmiştir. Pozisyon bağımlı hastaların ise sekiz tanesinden iki tanesi doğru tahmin edilmiştir. Pozisyon bağımlı apne tespitindeki başarının düşük olması, verilerdeki Supin ve Nsupin pozisyon sayısının uyku uzmanları tarafından etiketleme yapılırken apnenin başlangıcında pozisyon bilgileri etiketlendiği için yetersiz sayıda kalmasından kaynaklı olduğu düşünülmektedir.

5. SONUÇLAR VE ÖNERİLER

Bu tez çalışmasında PSG cihazından elde edilen EEG sinyali kullanılarak uyku evreleme işlemi yapılmış ve daha sonrasında hastanın apne durumunun evre ve/veya pozisyon bağımlı olup olmadığı kontrol edilmiştir. Toplamda 124 hastanın EEG sinyalleri ile yapılan çalışmada öncelikle EEG sinyalinin ham hali ile gürültüden arındırılmış halinin evreleme başarıları karşılaştırılmıştır. Sinyaldeki gürültülerin, evreleme başarılarını düşürdüğü anlaşılmıştır. Bu yüzden gürültüden arındırılmış EEG sinyalinden evreleme işleminde en iyi sonucu alabilmek için birden fazla özellik seti ile uyku evreleme yapılmıştır. Bu özellik setleri ile uyku evreleme yapılırken k kat çapraz doğrulamanın sınıflandırma başarısındaki etkisini de görebilmek için her özellik setine hem k kat çapraz doğrulama uygulayarak hem de k kat çapraz doğrulama uygulamadan evreleme yapılmıştır. Sınıflandırma işlemi ANN, SVM, kNN ve BT olmak üzere dört sınıflandırıcı ile yapılmıştır. En iyi sonuç alınan özellik seti ve sınıflandırıcı belirlendikten sonra apnenin bağımlılık olayı kontrol edilmiştir.

Bu tez çalışmasında elde edilen sonuçlar incelendiğinde en iyi sonuç ÖS2 ile geliştirilen ANN ile alınmıştır. ÖS2, EMD yönteminden özellik çıkarılarak oluşturulmuş bir özellik seti olduğu için EMD yönteminin uyku evrelemedeki başarısının VMD ve DWT yöntemlerinden çok daha etkili olduğu anlaşılmaktadır. Kullanılan sınıflandırma yöntemleri arasında ANN başarısı bu özellik setinde en iyi test başarısına %70.02 ile ulaşmıştır. ANN ‘den sonra en iyi test başarısına ulaşan sınıflandırıcı SVM’dir.

ANN sınıflandırıcı ile eğitilen modele, 9 adet hastanın REM ve/veya pozisyon bağımlı olma durumu kontrol edildiğinde, REM bağımlı hastalardan sadece bir tanesi doğru tahmin edilmezken, pozisyon bağımlı hastaların sekiz tanesinden ikisi doğru tahmin edilmiştir. Sonuç olarak evreleme başarısının yüksek olması apnenin evreler ile olan ilişkisinin de doğru tahmin edilmesini sağlamaktadır.

Literatürdeki çalışmalara bakıldığında, evreleme işleminin sonunda apnenin REM ve/veya pozisyon bağımlı olma durumunu kontrol eden bir çalışmaya rastlanmamıştır. Bu tez çalışması, hastaların REM ve Nsupin sayılarının yeterli olduğu her durumda başarılı bir şekilde tespit etme işlemini gerçekleştirebilir.

KAYNAKLAR

- Al-Salman W, Li Y , Wen P. 2019. Detecting sleep spindles in EEGs using wavelet fourier analysis and statistical features. Biomedical Signal Processing Control 48;80-92.
- Alickovic E , Subasi A. 2018. Ensemble SVM method for automatic sleep stage classification. IEEE Transactions on Instrumentation Measurement 67;1258-65.
- An P, Yuan Z, Zhao J, Jiang X , Du B. 2021. An effective multi-model fusion method for EEG-based sleep stage classification. Knowledge-Based Systems 219;106890.
- Atasever ÜH , Özkan C. 2012. Arazi Örtüsünün Belirlenmesinde Torbalama-Karar Ağaçları Yönteminin Kullanımı. IV. Uzaktan Algılama ve Coğrafi Bilgi Sistemleri Sempozyumu.
- Aydoğan O, Öter A, Kıymık MK , Tuncel D. 2015. Automatic classification of sleep stages with artificial neural networks according to visual scoring rules. 2015 23rd Signal Processing and Communications Applications Conference (SIU). IEEE, 399-402.
- Ayyüce K. 2018. Şu Kara Kutuyu Açalım: Yapay Sinir Ağları [Online]. Available: <https://ayyucekizrak.medium.com/%C5%9Fu-kara-kutuyu-a%C3%A7alim-yapay-sinir-a%C4%9Flar%C4%B1-7b65c6a5264a> [Accessed 1 Ocak 2021].
- Basha AJ, Balaji BS, Poornima S, Prathilothamai M , Venkatachalam K. 2020. Support vector machine and simple recurrent network based automatic sleep stage classification of fuzzy kernel. Journal of Ambient Intelligence Humanized Computing;1-9.
- Bazil CW , Walczak TS. 1997. Effects of sleep and sleep stage on epileptic and nonepileptic seizures. Epilepsia 38;56-62.
- Budu K. 2014. Comparison of wavelet-based ANN and regression models for reservoir inflow forecasting. Journal of Hydrologic Engineering 19;1385-400.
- Casal R, Di Persia LE , Schlotthauer G. 2019. Sleep-wake stages classification using heart rate signals from pulse oximetry. Heliyon 5;e02529.
- Çiftçi TU 2012. Türk Toraks Derneği Obstrüktif Uyku Apne Sendromu Tanı Ve Tedavi Uzlaşısı Raporu.
- Das T, Ghosh A, Guha S , Basak P. 2017. Classification of eeg signals for prediction of seizure using multi-feature extraction. 2017 1st International Conference on Electronics, Materials Engineering and Nano-Technology (IEMENTech). IEEE, 1-4.
- Doğan Ş, Tuncer, E., Gülten, A. 2011. Tekil Değer Ayırımı Metodu ile Renkli Resimler İçin Bir Damgalama Uygulaması. 6th International Advanced Technologies Symposium (IATS'11).
- Dragomiretskiy K , Zosso D. 2013. Variational mode decomposition. IEEE Transactions On Signal Processing 62;531-44.
- Ersoy E. 2019. Obstrüktif Uyku Apnesi Sendromlu Hastalarda Komorbidite ve Obezite Arasındaki İlişki. Kırklareli Üniversitesi Sağlık Bilimleri Enstitüsü
- Ersöz A , Özşen S. 2011. Uyku EEG Sinyalinin Yapay Sinir Ağ Modeli ile Sınıflandırılması. Elektrik-Elektronik ve Bilgisayar Sempozyumu;298-301.
- Gangstad SW, Mikkelsen KB, Kidmose P, et al. 2019. Automatic sleep stage classification based on subcutaneous EEG in patients with epilepsy. 18;1-17.
- Göğüş FZ. 2020. Osas Hastaları için CPAP Cihazlarındaki Optimum Basıncın Yapay Zeka ile Tahmini. Konya Teknik Üniversitesi

- 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. 2009 14th national biomedical engineering meeting. IEEE, 1-4.
- Güneş S, Polat K , Yosunkaya Ş. 2010. Efficient sleep stage recognition system based on EEG signal using k-means clustering based feature weighting. Expert Systems with Applications 37;7922-8.
- Huang W, Guo B, Shen Y, et al. 2020. Sleep staging algorithm based on multichannel data adding and multifeature screening. 187;105253.
- Huang Y, Shiyu M, Xiaoshuang L , Wenyi F. 2018. A classification method for wood vibration signals of Chinese musical instruments based on GMM and SVM. Traitement du Signal 35;137.
- İlhan Algın D, Akdağ G , Erdiñç O. 2016. Kaliteli Uyku ve Uyku Bozuklukları. Osmangazi Tıp Dergisi 38.
- Karakoyun M , Hacibeyoğlu M. 2014. Biyomedikal Veri Kümeleri İle Makine Öğrenmesi Sınıflandırma Algoritmalarının İstatistiksel Olarak Karşılaştırılması. Dokuz Eylül Üniversitesi Mühendislik Fakültesi Fen ve Mühendislik Dergisi 16;30-42.
- Koca Y. 2022. PSG Kayıtları Kullanılarak Uyku Evrelerinin Sınıflandırılması. YÜKSEK LİSANS TEZİ, Konya Teknik Üniversitesi
- Köktürk O. 2013. Uyku Kayıtlarının Skorlanması. 15;14-29.
- Kumari CU, Mounika G , Prasad SJ. 2019. Identifying Obstructive, Central and Mixed Apnea Syndrome Using Discrete Wavelet Transform. International Conference on Emerging Trends in Engineering. Springer, 16-22.
- Li Y, Xu Z, Zhang Y, Cao Z , Chen HJPM. 2022. Automatic sleep stage classification based on two-channel EOG and one-channel EMG.
- Lian J, Liu Z, Wang H , Dong X. 2018. Adaptive variational mode decomposition method for signal processing based on mode characteristic. Mechanical Systems Signal Processing 107;53-77.
- Liu C, Tan B, Fu M, et al. 2021. Automatic sleep staging with a single-channel EEG based on ensemble empirical mode decomposition. 567;125685.
- Michielli N, Acharya UR , Molinari F. 2019. Cascaded LSTM recurrent neural network for automated sleep stage classification using single-channel EEG signals. Computers in biology medicine 106;71-81.
- Öner İV, Yeşilyurt MK , Yılmaz EÇ. 2017. Wavelet Analiz Tekniğı ve Uygulama Alanları. Ordu Üniversitesi Bilim ve Teknoloji Dergisi 7;42-56.
- Özşen S, Güneş S , Yosunkaya Ş. 2010. Examining the effect of time and frequency domain features of eeg, eog, and chin emg signals on sleep staging. 2010 15th National Biomedical Engineering Meeting. IEEE, 1-4.
- Pourzare S. 2012. Eeg İşaretlerindeki Göz Ve Çene Hareketi Artifaktlarının Sınıflandırılması. Yüksek Lisans Tezi, Karadeniz Teknik Üniversitesi
- Sathyanarayana A, El Atrache R, Jackson M, et al. 2021. Measuring the effects of sleep on epileptogenicity with multifrequency entropy. 132;2012-8.
- Taran S, Sharma PC , Bajaj V. 2020. Automatic sleep stages classification using optimize flexible analytic wavelet transform. Knowledge-Based Systems 192;105367.
- Tezel G. 2007. Biyomedikal işaretlerin yeni bir adaptif aktivasyon fonksiyonlu yapay sinir ağı ile sınıflandırılması. Selçuk Üniversitesi Fen Bilimleri Enstitüsü
- Tosun M , Çetin O. 2021. Ampirik Mod Ayırıştırması ve Welch Yöntemini Kullanarak Dört Sınıflı Motor Hayali EEG Sinyallerinin Derin Öğrenme ile Sınıflandırılması. Avrupa Bilim ve Teknoloji Dergisi;284-8.
- Tunçer E, Olcay BO , Ünlü MZ. 2017. Deneysel mod ayırıştırması uygulanmış yazma hareket bilgisi kullanılarak el yazısı karakter tanıma. 25th Signal Processing and

- Communications Applications Conference, SIU 2017. Institute of Electrical and Electronics Engineers Inc.
- Uçar MK, Bozkurt MR, Polat K , Bilgin C. 2014. EEG Sinyalleri Kullanılarak Uyku Evrelerinin Sınıflandırılmasında Sayısal Filtrelemenin Etkisi Effect of Digital Filtering to Sleep Stage Classification Using EEG Signals. Eleco Elektrik–Elektronik–Bilgisayar ve Biyomedikal Mühendisliği Sempozyumu.
- Yalçın G 2018. Ağır Obstrüktif Uyku Apne Sendromlu ve Rem İlişkili Obstrüktif Uyku Apne Sendromlu Hastalarda Diabetes Mellitus İlişkisi. Uzmanlık Tezi, Süleyman Demirel Üniversitesi, Tıp Fakültesi.
- Yang B , Liu H. 2020. Automatic identification of insomnia based on single-channel EEG labelled with sleep stage annotations. IEEE Access 8;104281-91.
- Yılmaz A , Sümer E. Relief Özellik Seçim Yöntem Tabanlı Önerilen Hibrit Model ile Kalp Hastalığı Teşhisi. Avrupa Bilim ve Teknoloji Dergisi;609-15.
- Yılmaz Z , Bozkurt MR. 2013. Ayrık Dalgacık Dönüşümü Kullanarak Aritmilere Ait Özniteliklerin Çıkarılması. XIV. Akademik Bilişim Konferansı;23-5.
- Yücelbaş Ş. 2017. EKG Parametrelerinin Uyku Evreleri ve OSAS ile İlişkisinin İncelenmesi. Doktora Tezi, Selçuk Üniversitesi