



KIRGIZISTAN TÜRKİYE MANAS ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

UYKU HASTALIKLARININ TESPİTİ İÇİN EEG
SİNYALLERİNİN DERİN ÖĞRENME İLE
İŞLENMESİNDE YENİ BİR YAKLAŞIM

Hazırlayan
Göksu Zekiye ÖZEN

Danışman
Doç. Dr. Rayimbek SULTANOV

Doktora Tezi

Aralık 2020
BİŞKEK, KIRGIZISTAN

KIRGIZİSTAN TÜRKiYE MANAS ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

UYKU HASTALIKLARININ TESPİTİ İÇİN EEG
SİNYALLERİNİN DERİN ÖĞRENME İLE
İŞLENMESİNDE YENİ BİR YAKLAŞIM

Hazırlayan
Göksu Zekiye ÖZEN

Danışman
Doç Dr. Rayımbek SULTANOV

Doktora Tezi

Aralık 2020
BİŞKEK, KIRGIZİSTAN

ÖNSÖZ

Çalışmalarım boyunca farklı bakış açıları ve bilimsel katkılarıyla beni aydınlatan, yakın ilgi ve yardımlarını esirgemeyen ve bu günlere gelmemde en büyük katkı sahibi Sayın Hocam Doç. Dr. Rayimbek SULTANOV'a teşekkürü bir borç bilirim.

Deneysel çalışmalarım sırasında karşılaştığım zorlukları aşmamda yardımlarından ve desteklerinden dolayı Sayın Dr. Öğr. Üyesi Yunus ÖZEN ve bütün hocalarıma teşekkür ederim.

Ayrıca, çalışmalarım süresince sabır göstererek beni daima destekleyen ve bugünlere gelmemde üzerimde büyük emekleri olan aileme sonsuz teşekkürlerimi sunarım.

Göksu Zekiye ÖZEN

Bişkek, Aralık 2020

UYKU HASTALIKLARININ TESPİTİ İÇİN EEG SİNYALLERİNİN DERİN ÖĞRENME İLE İŞLENMESİNDE YENİ BİR YAKLAŞIM

Göksu Zekiye ÖZEN

Kırgızistan Türkiye Manas Üniversitesi, Fen Bilimleri Enstitüsü

Doktora Tezi, Aralık 2020

Danışman:Doç Dr. Rayimbek SULTANOV

KISA ÖZET

Uyku kalitesinin değerlendirilmesi ve uyku hastalıklarının teşhisi için öncelikle uyku evreleri tespit edilmektedir. Giyilebilir EEG cihazlarının üretilmesi ile tek kanallı EEG sinyalinde uyku evreleri tespiti yapılabilmesi için çalışmalar başlamıştır. Uyku hastalıkları, beyin fonksiyon bozuklukları ile ilişkili olduğundan EEG sinyali uyku rahatsızlıklarının tespitinde de kullanılmaktadır. Uyku hastalıklarının da tek kanallı EEG sinyalinde kabul edilebilir bir doğruluk oranında tespit edilebilmesi ile bireylerin çok daha erken tedaviye başlamasının yolu açılacaktır. Bu tez çalışmasında tek kanallı ham EEG sinyali kullanarak uyku evreleme yapan ve uyku hastalıklarını tespit eden otomatik bir sistem sunulmaktadır. Bu amaçla ham EEG sinyalleri ile Evrişimli Sinir Ağı (ESA) modelleri eğitilmiştir. Geliştirilen ESA modelleri uyku verisini sınıflandırmakta, Santral Apne(CA), Obstrüktif Apne(OA) ve Hipoapne(HA) rahatsızlıklarını tespit etmektedir. Yapılan testlerin sonuçlarına göre önerilen sistemin evreleme başarımı %93 makro F1-skoru ve %92 doğruluk olarak bulunmuştur. Sistem ayrıca uyku hastalıklarını ise %85 makro F1-skoru ve %85 doğrulukla tespit etmektedir. Yapılan çalışma literatürde yer alan güncel çalışmalarla karşılaştırıldığında, önerilen evreleme modelinin başarımı daha yüksektir, hastalık tespiti ise çok kanallı modellerle yaklaşık aynı başarımlara sahiptir.

Anahtar Kelimeler: otomatik uyku evreleme, otomatik uyku hastalıkları tespiti, EEG, ESA.

**A NEW APPROACH TO PROCESSING EEG SIGNALS WITH DEEP
LEARNING FOR THE DETECTION OF SLEEP DISEASES**

Göksu Zekiye ÖZEN

Kyrgyzstan-Turkey Manas University, Graduate School of Natural and Applied Sciences

Ph.D Dissertation, December 2020

Advisor: Assoc. Prof. Rayimbek SULTANOV

ABSTRACT

Sleep stages are determined firstly for the evaluation of sleep quality and the diagnosis of sleep diseases. Studies have begun for the detection of sleep stages from single-channel EEG signals obtained from wearable EEG devices. Since sleep diseases are associated with brain function disorders, the EEG signal is also used to detect sleep diseases. The way for individuals to start treatment much earlier will be opened with the detection of sleep diseases at an acceptable accuracy rate from the single-channel EEG signal. In this thesis study, an automatic system that performs sleep staging and detects sleep diseases using a single channel raw EEG signal is presented. Convolutional Neural Network (CNN) models were trained with the raw EEG signal. The developed CNN model classifies the sleep data and detects Central Apnea (CA), Obstructive Apnea (OA), and Hypopnea (HA) diseases. According to the test results, the sleep staging performance of the proposed system was found to be 93% macro F1 score and 92% accuracy. The system also detects sleep diseases with an 85% macro F1-score and 85% accuracy. Compared to active studies in the literature, the performance of the proposed staging model is higher, and disease detection has approximately the same performance rates as current multi-channel models.

Keywords: automatic sleep staging, automatic sleep disorders detection, EEG, CNN.

НОВЫЙ ПОДХОД К ОБРАБОТКЕ EEG-СИГНАЛОВ С ГЛУБОКОМ ОБУЧЕНИЕМ ДЛЯ ОПРЕДЕЛЕНИЯ ЗАБОЛЕВАНИЙ СНА

Гоксу Зекие ОЗЕН

Кыргызско Турецкий Университет «Манас», Институт естественных наук

Докторская диссертация, декабрь 2020

Научный руководитель: Доц. доктор Райымбек СУЛТАНОВ

Аннотация

С производством доступных по цене носимых устройств EEG для индивидуального использования были начаты исследования по обнаружению стадий сна с помощью одноканального сигнала EEG. Поскольку нарушения сна связаны с дисфункцией мозга, сигнал EEG используется для обнаружения самого сна, а также его нарушений. В этой диссертации представлена автоматическая система, которая определяет стадии сна и обнаруживает его нарушения с помощью использования необработанного одноканального сигнала EEG. С этой целью были обучены модели Сверточной Нейронной Сети (convolutional neural network, CNN) с необработанными сигналами EEG. Разработанные модели CNN классифицируют данные сна, отобранные и выявляют нарушения центрального апноэ (СА), обструктивного апноэ (ОА) и гипопноэ (НА). По результатам тестов, этапный успех предлагаемой системы был определен как 93% макро F1-балла и 92% точности, а также выявляет болезни сна с 85% макро F1-баллом и точностью 85%. По сравнению с текущими исследованиями в литературе эффективность предлагаемой модели стадирования выше, а обнаружение заболеваний имеет примерно такие же показатели эффективности, как и многоканальные модели

Ключевые Слова: автоматического распознавания стадий сна, автоматическое обнаружение нарушений сна, EEG, CNN.

**УКТОО ООРУЛАРЫН АНЫКТОО ҮЧҮН ТЕРЕҢ ҮЙРӨНҮҮ МЕНЕН ЕЕГ
СИГНАЛДАРЫНЫН ИШТЕТҮҮДӨ ЖАҢЫ ЫКМА**

Гөксу Зекие ӨЗЕН

Кыргыз-Түрк “Манас” университети, Табигый илимдер институту

Доктордук диссертация, декабрь 2020

Илимий жетекчи: доц. доктор Райымбек СУЛТАНОВ

Кеңири аннотация

Бүгүнкү күндө уйку ооруларынын диагнозун аныктоо жана уйкунун сапатын баалоо уйку техниктери жана невропатологдор тарабынан кол менен жасалып келет. Полисомнография (PSG) деп аталган бул системада дененин ар кайсы бөлүктөрүнө туташтырылган сенсорлордон жазылгын электроэнцефалограмма (EEG), электрокардиограмма (ECG), электроокулограмма (EOG), электромиограмма (EMG) сыяктуу сигналдар колдонулат. Бул системанын чыгарган ар кандай кыйынчылыктары бар. PSG жазуулары уйку адистер тарабынан кол менен режимделип, белгиленип жана бааланууда. Уйку клиникаларында адистер жана орундар жетиштуу болбогондуктан, талаптар канааттандыраарлык эмес. Бул процессти автоматташтыруу керек. PSG системалары үй шартында колдонууга ылайыксыз, ооруканаларда лабораторияларда гана колдонулуучу кымбат жана өзгөчө апараттар. Арзан жана колдонууга жеңил ыкмалар менен дагы уйкунун сапатын өлчөп билүү жана уйку ооруларын аныктап билүү керек. PSG сигналдарын алуу үчүн объектилерге туташтырылган кабелдердин жана электроддордун саны көп. Кошумча кабелдерди жана электроддорду колдонуу өлчөп жатканда ызы-чууну жаратат жана объектилердин уйку сапатынын төмөндөшүнө себеп болот. Мындан аз электроддорду жана кабелдерди колдонуп жогорку натыйжаларды берген системаларга муктаждык бар. PSG сигналдарын кол менен баалоо медик уйку адистеринин көп убактысын алат жана аларды чарчатат.

Бул жагдай адам баласына байланыштуу болуп уйку жазууларын баалоо иштеринде катачылыктарга да себеп болушу мүмкүн. Уйку адистерисиз баалап берүүчү автоматтык системаларга муктаждык бар. Уйку техниктерин коюу стилинде айырмачылыктар болгон үчүн ортого койгон маалыматтардын тууралыгы талкууга алынат. Ал эми бул процессти автоматташтыруу үчүн иштелип чыккан алгоритмдер ар дайым окшош ыкма менен бирдей натыйжа берет жана дагы да ырааттуу иштейт.

PSG системасынын чектелгендигинен жана көйгөйлөрүнөн улам жазууларда, уйку режими жана ооруну аныктоону автоматташтырууга багытталган көптөгөн ыкмалар сунушталды. Бул ыкмаларды: кол менен өзгөчөлүктүн натыйжасы жана эксперттик билимге багытталган эрежелерди колдонуу, кол менен өзгөчөлүктүн натыйжасы жана машина үйрөнүү классификациясынын гибридик колдонуусу, автоматтык өзгөчөлүктү алуу жана классификациялай турган терең окутуу методдорун колдонуу түрдө топтоштурууга болот. Жасалма интеллектке негизделген системаларын жайылышы менен бирге, эрежеге негизделген ыкмалары бааланбай калды. Машина үйрөнүү ыкмаларында колдонулган системаларындагы алгоритм, эксперттер тарабынан чыгарылган өзгөчөлүктөрү менен окутулгандыктан, колдонулган алгоритмдин ийгилиги, эксперттер тарабынан колдо жасалган өзгөчөлүктөрдүн сапатына жана маалыматтын алдын-ала иштөөсүнө көз каранды. Акыркы жылдары изилдөөлөрдө автоматтык түрдө өзгөчөлүктөрдүн натыйжасын жасаган терең үйрөнүү моделдерин колдонуусу кеңири жайылды. Бул ыкмалардын артыкчылыгы - эң ылайыктуу функцияларды, адамдын таасири болбостон алгоритм өзү тандай алат. Бул изилдөө ишинде терең үйрөнүү методдорунун бири болгон Конволюциялык Нейрон тармагы (ESA) тандалды.

Жеке колдонуу үчүн чыгарылган, арзан баада, кийилүүчү EEG аппараттардын чыгышы менен бир каналдуу EEG сигналынан уйку режимдерин аныктоо үчүн изилдөөлөр башталды. Уйку оорулары, мээнин функциялык бузулушу менен байланыштуу болгондуктан, EEG сигналы уйку жана уйкунун бузулушун аныктоодо да колдонулууда. Уйку ооруларынын бир каналдуу EEG сигналынан алгылыктуу тактык ченинде аныктоо менен бирге, адамдардын эрте дарыланып баштоосуна жол ачат. Бул изилдөө иштериндеги өзгөчөлүктөрдү бир каналдуу

жаңы EEG сигналын колдонуп, уйку режимдерин аткаруучу жана уйку ооруларын аныктоочу автоматтык бир система сунушталат. Жаңы EEG сигналдары жана Конволюциялык нейрон тармагы (ESA) моделдери ушул максатта окутулду. ESA моделдери кирүү сигналына жасалган бир конволюциялык чыпканы камтыйт. Ар бир чыпканын кириши - нейрон салмагынан турат. Артка жайылуу аркылуу бул салмактарды үйрөнсө болот жана кирүү сигналында болгон өзгөчөлүктөргө ылайыкташа алат. Ар бир чыпка кире бериштен жогору 'сканерден' өтөт жана чыпка өзөгү үчүн, ошол аймактын активдешүүсүн кайтарат. Катмарлар үйүлөт жана ар бир катмар мурунку катмардагы өзгөчөлүктөргө караганда, дагы абстракттуу өзгөчөлүк чагылдырылышы түзүшү мүмкүн. Бул процесс аркылуу, көрүнүш жана EEG сигналдары сыяктуу жаңы маалыматтардан абстракттуу өзгөчөлүктөр чыгарылышы мүмкүн. Катмарлардын үч түрү бар. Алар: конволюциялык нейрон тармактарындагы конволюциялык катмарлар, бекитүү катмарлары жана толугу менен бириккен катмарлар. ESA колдонуунун жардамы менен кандайдыр бир өзгөчөлүктөрдү чыгаруунун кажети жок.

Бул изилдөөдө колдонулган EEG сигналдары, PhysioNet сайтында жалпыга ачык жарыяланган полисомнографиялык маалымат базасы MIT-BIH дан алынды. Субъекттери Бостондогу Бет Израиль ооруканасы уйку лабораториясында өнөкөт обструктивдүү уйку апноэ синдромун баалоо үчүн каралган. Базада төрт, алты жана жети каналдуу полисомнографиялык жазуулар бар. Алардын ар бири уйку этабына, апноэга ылайык анализделген EEG, EKG жана дем алуу сигналдары болгон 80 сааттан ашык баалуулук бар. Маалымат базасында ар кандай даражада уйку апноэнын ээси, 32-56 жаш арасында 16 эркек субъектке таандык 8 бөлүк, түнү бою полисомнографиялык уйку жазуулары бар. Ар бир жазууда EEG сигналы, инвазивдик кан басымын сигналы, дем алуу сигналы жана 250 Гц жыштыгында моделделген EEG сигналы камтыйт. Иштелип чыккан ESA моделдери 30 секундалык сегменттерге бөлүнгөн. Уйкунун маалыматын 5 баскычтагы уйку режиминин системасына жараша классификацияланат, Борбордук Апноэ (CA), Obstruct Apnea (OA) жана Нуроapnea (NA) оорууларын аныктоодо.

Python үчүн Keras китепканасы жана Tensorflow китепканасы боюнча эксперименттер өткөрүлгөн. Окуу процесси үчүн Google Cloud чөйрөсүндө 15 ГБ диск, 32 Гбайт эс тутум жана 16 негизги процессор колдонулган. Эксперименттер

UBUNTU 18.0.4 LTS платформасында өткөрүлгөн. Тиркемелер Python 3.6 версиясы менен коддолгон.

Жасалган тесттердин натыйжасына жараша сунушталган системанын коюлган ийгилиги: 93% макро F1-эсеби менен 92% тактык катары табылган. Ал эми уйку ооруларын 85% макро F1-эсеби жана 85% тактык менен аныктайт. Аткарылган иш, азыркы изилдөөлөр менен салыштырганда, сунуш кылынган этап моделинин көрсөткүчү жогору, ал эми ооруну аныктоо көп каналдуу моделдер болжол менен ошол эле аткаруу көрсөткүчтөрүнө ээ болот.



İÇİNDEKİLER

UYKU HASTALIKLARININ TESPİTİ İÇİN EEG SİNYALLERİNİN DERİN ÖĞRENME İLE İŞLENMESİNDE YENİ BİR YAKLAŞIM

BİLİMSEL ETİĞE UYGUNLUK	i
YÖNERGEYE UYGUNLUK.....	ii
KABUL VE ONAY	iii
КАБЫЛ АЛУУ ЖАНА ЧЕЧИМ	iv
ÖNSÖZ	v
KISA ÖZET	vi
ABSTRACT	vii
Аннотация.....	viii
Кеңири аннотация	ix
İÇİNDEKİLER	xiii
KISALTMALAR VE SİMGELER.....	xv
TABLolar LİSTESİ.....	xvii
ŞEKİLLER LİSTESİ	xviii
1. GİRİŞ VE AMAÇ	1
1. 1. Tezin konusu ve problemin tanımlanması.....	1
1. 2. Literatürde sunulan çalışmaların özetleri	2
1. 3. Tez çalışmasının katkıları.....	3
1. 4. Tezin organizasyonu.....	4
2. UYKU ve UYKU HASTALIKLARININ TESPİTİ	5
2. 1. Giriş.....	5
2. 2. Uyku	5
2. 3. Uyku evrelemesi.....	6
2. 4. Uyku hastalıkları	11
2. 5. Yapay sinir ağı.....	13
2. 6. Aktivasyon fonksiyonları	16
2. 7. Derin öğrenme	22

2. 7. 1. Evriřimli sinir aęları	23
2. 7. 2. Tekrarlı sinir aęları	29
2. 8. Deęerlendirme metrikleri	35
2. 9. Model doęrulama yöntemleri	38
3. DERİN ÖĞRENME İLE UYKU EVRELEMESİ VE UYKU HASTALIKLARI TESPİTİ	40
3. 1. Deney ortamı	40
3. 2. Uyku veriseti	41
3. 3. Evriřimli sinir aęı ile uyku evrelemesi	43
3. 4. Evriřimli sinir aęı ile uyku hastalıklarının tespiti.....	46
4. EVRİřİMLİ SİNİR AęI İLE TASARLANAN SİSTEMLERİN BAřARIM DEęERLENDİRMESİ	53
4. 1. Evriřimli sinir aęı ile uyku evrelemesi bařarımı	53
4. 2. Evriřimli sinir aęı ile uyku hastalıkları tespiti bařarımı	55
5. TARTIřMA- SONUÇ ve ÖNERİLER	58
KAYNAKLAR	61
ÖZGEÇMİř	69

KISALTMALAR VE SİMGELER

Sembol	Anlamı
PSG	Polisomnografi
EEG	Elektroensefalogram
ECG	Elektrokardiyogram
EOG	Elektrookülogram
EMG	Elektromiyogram
SaO ₂	Oksijen satürasyonu
ESA	Evrişimli sinir ağı
AUTA	Amerikan Uyku Tıbbı Akademisi
REM	Hızlı göz hareketi uykusu
UAS	Uyku apnesi sendromu
OUA	Obstrüktif uyku apnesi
SUA	Santral uyku apnesi
TBA	Temel bileşen analizi
DSA	Derin sinir ağı
DOSED	Dreem One Shot Event Detector
YSA	Yapay sinir ağları
ÇKA	Çok katmanlı algılayıcı
ReLU	Doğrultulmuş doğrusal birim
LReLU	Leaky ReLU fonksiyonu
ELU	Üstel doğrusal değerler fonksiyonu
TSA	Tekrarlı sinir ağı
UKDB	Uzun kısa dönem bellek
P-UKDB	Paylaşımlı UKDB

Y-UKDB	Yığılmış UKDB
ÇY-UKDB	Çift yönlü UKDB
ÇB-UKDB	Çok boyutlu UKDB
DP	Doğru pozitif
YN	Yanlış negatif
YP	Yanlış pozitif
DN	Doğru negatif



TABLÖLAR LİSTESİ

Tablo 2-1 Band frekansına göre beyin dalgalarının gösterimi	7
Tablo 2-2 R&K standardının AUTA dönüşümü.	8
Tablo 2-3 İkili sınıflandırma problemi için kullanılan karışıklık matrisi yapısı	36
Tablo 2-4 Yapay zekâ algoritmalarında kullanılan değerlendirme metrikleri.....	37
Tablo 2-5 Kappa katsayısına göre uyum değerlendirmesi.	38
Tablo 3-1 Uyku verisetinde yer alan dosyaların uzuntaları ve açıklamaları	42
Tablo 3-2 Aux alanında yer alan açıklamalara karşılık gelen kodlar.	42
Tablo 3-3 Otomatik uyku evrelemesi yapan ESA modelinin özellikleri.....	45
Tablo 3-4 Çalışmada kullanılan ESA modeli ve parametreleri	52
Tablo 4-1. Başarım sonuçları.	54
Tablo 4-2 Yapılan çalışmanın literatürdeki diğer çalışmalarla karşılaştırılması	55
Tablo 4-3 Başarım sonuçları.	56
Tablo 4-4 Uyku hastalıkları tespit eden çalışmanın literatürdeki diğer çalışmalarla karşılaştırılması.	57

ŞEKİLLER LİSTESİ

Şekil 2-1 Uluslararası 10-20 elektrod yerleşim sistemi [15].....	7
Şekil 2-2 Örnek bir hipnogram görüntüsü.	9
Şekil 2-3 Bir Algılayıcının gösterimi.....	14
Şekil 2-4 Tek gizli katmana sahip basit bir ÇKA.	15
Şekil 2-5 Sigmoid fonksiyonunun grafiği.....	17
Şekil 2-6 tanh fonksiyonunun grafiği.	19
Şekil 2-7 ReLu fonksiyonunun grafiği.	20
Şekil 2-8 LReLu fonksiyonunun grafiği.....	21
Şekil 2-9 ELU fonksiyonunun grafiği.....	22
Şekil 2-10 Evrişimli Sinir Ağının yapısı.....	24
Şekil 2-11 Evrişimli filtreler	25
Şekil 2-12 Transfer fonksiyonu uygulama örneği.....	25
Şekil 2-13 Sahte kenarlar	26
Şekil 2-14 Havuzlama örneği.....	27
Şekil 2-15 Tam bağlı katman örneği.....	28
Şekil 2-16 Dropout örneği.	29
Şekil 2-17 Tekrarlı sinir ağının basit gösterimi.	30
Şekil 2-18 t zamanı boyunca tekrarlı sinir ağının gösterimi	30
Şekil 2-19 Bir hücreli UKDB hafıza bloğu.....	33
Şekil 2-20 P-UKDB örneği, ağaç yapılarında UKDB bir bellek ağı.	34
Şekil 2-21 k-katlamalı çapraz doğrulama işlemi.....	39
Şekil 3-1 Otomatik uyku evrelemesi yapan ESA modelinin yapısı.....	44
Şekil 3-2 Hastalık belirtisi bulunmayan W(Uyanıklık) evresi.	46
Şekil 3-3. Hastalık belirtisi bulunmayan EEG kaydı. REM uyku evresi.	47
Şekil 3-4. Hastalık belirtisi bulunmayan EEG kaydı. S1 uyku evresi.	47
Şekil 3-5. Hastalık belirtisi bulunmayan EEG kaydı. S2 uyku evresi.	48
Şekil 3-6. Hastalık belirtisi bulunmayan EEG kaydı. SWS uyku evresi.	48

Şekil 3-7. Hipoapne belirtisi bulunan bir EEG sinyali. S2 uyku evresi.....	49
Şekil 3-8. Obstrüktif Hipoapne belirtisi bulunan bir EEG sinyali. S2 uyku evresi ...	49
Şekil 3-9. Santral Uyku Apnesi belirtisi bulunan bir EEG sinyali. S2 uyku evresi...	50
Şekil 3-10 Uyku hastalıklarını tespit etmede kullanılan ESA modeli	51
Şekil 4-1 Uyku Evreleme İşlemine Ait Karışıklık Matrisi	53
Şekil 4-2 Slp59 verisinin ESA ile otomatikleştirilmiş uyku evreleri hipnogramı	54
Şekil 4-3. Tek Kanal EEG kullanıldığında oluşan karışıklık matrisi.....	56



1. GİRİŞ VE AMAÇ

Uyku, tüm canlıların yaşamlarını sürdürebilmeleri için gerekli olan doğal bir süreçtir. Sağlıklı bir uyku birbirini takip eden farklı evrelerin gece boyunca belirli sayıda tekrar etmesi ile oluşmaktadır. Uyku kalitesinin değerlendirilmesi ve uyku bozukluklarının teşhisi için öncelikle uyku evreleri tespit edilmektedir. Polisomnografi (PSG) sinyalleri vücudun farklı kısımlarına yerleştirilen elektrodlar yardımıyla elde edilen elektroensefalogram (EEG), elektrookülogram (EOG), elektrokardiyogram (ECG), elektromiyogram (EMG), hava akımı, oksijen satürasyonu (SaO2) gibi çoklu fizyolojik sinyallerden oluşur. Gece boyunca sürekli olarak kaydedilen bu çoklu sinyaller uykunun analiz edilmesinde en yaygın kullanılan araçlardır [1]. Uyku kalitesi; uyku süresine, uyku evrelerine ve gece uyanma sayısına bağlıdır [2]. Normal uyku düzenini bozan durumlar uyku hastalıkları olarak tanımlanmaktadır. Bu tez çalışmasında uyku evreleme ve uyku hastalıklarını tek kanal ham EEG sinyali kullanarak tespit eden Evrişimli Sinir Ağı (ESA) modelleri kullanan bir yöntem sunulmuştur. ESA kullanımı sayesinde herhangi bir özellik çıkarımı yapılmasına ihtiyaç bulunmamaktadır. Geliştirilen ESA modeli 250 Hz’de örneklenmiş, 30 sn’lik segmentlere bölünmüş uyku verisini 5 sınıflı uyku evreleme sistemine göre sınıflandırmaktadır ve çeşitli uyku bozukluklarını tespit edebilmektedir. Bu tezde sunulan çalışma ile çoklu sinyal ölçümüne ve işlenmesine gerek kalmadan giyilebilir cihazlardan bile alınabilen tek kanallı bir EEG sinyalinden uyku kalitesi ölçümü ve uyku bozukluğu olup olmadığını otomatik olarak tespit edebilmektedir. Daha az sayıda fizyolojik sinyal kullanarak otomatik evreleme yapabilen ve uyku hastalıklarını tespit edebilen bu sistem, ev tabanlı sağlık izleme gibi pek çok alanda kullanılabilecektir.

1. 1. Tezin konusu ve problemin tanımlanması

Uyku evreleme ve uyku hastalıklarını tespit etmede karşılaşılan problemler aşağıda listelenmiştir.

- ✓ PSG kayıtları uyku uzmanları tarafından manuel olarak evrelenmekte, işaretlenmekte ve değerlendirilmektedir. Uyku kliniklerinde yeterli uzman ve

yatak bulunmaması nedeniyle talepler karşılanamamaktadır. Bu işlemin otomatikleştirilmesi gerekmektedir.

- ✓ PSG sistemleri ev kullanımı için uygun olmayan, yalnızca hastane ve laboratuvarlarda kullanılan pahalı ve özel cihazlardır. Ucuz ve kullanımı kolay yöntemlerle de uyku kalitesi ölçülebilmeli ve uyku hastalıkları tespit edilebilmelidir.
- ✓ PSG sinyallerini elde etmek için deneklere bağlanan kablo ve elektrodların sayısı fazladır. Ekstra kablo ve elektrod kullanımı ölçümlerde gürültülere ve deneklerin uyku kalitesinin düşmesine sebep olmaktadır. Daha az elektrod ve kablo ile kabul edilebilir düzeyde sonuçlar üreten sistemlere ihtiyaç vardır.
- ✓ PSG sinyallerinin uyku uzmanları tarafından manuel olarak değerlendirilmesi hem zaman alıcı hem de yorucu bir işlemdir. Bu durum insan faktörüne bağlı olarak uyku kayıtlarının değerlendirilmesi çalışmalarında hataya da neden olabilmektedir. Uyku uzmanlarına gerek kalmadan değerlendirme yapan otomatik sistemlere ihtiyaç vardır.
- ✓ Uyku teknisyenlerinin evreleme tarzında farklılıklar olması etiketledikleri verinin doğruluğunu tartışılır hale getirmektedir [3]. Literatürde yer alan yalnızca birkaç veri seti üzerinde uyku teknisyenlerinin verdiği etiketler birbiri ile tutarlıdır. Hatta bu veri setlerinde bile teknisyenler arası tutarlılık 0.79 (Cohen's Kappa) civarındadır [3, 4]. Bu işlemi otomatikleştirmek için geliştirilen algoritmalar her zaman aynı yöntemle aynı sonucu üretecektir ve daha tutarlı çalışacaktır.

Günümüzde kişisel kullanıma uygun giyilebilir EEG cihazlarının üretilmiş olması sadece bu sinyallerin kullanıldığı uyku evreleme ve uyku hastalıkları tespiti yapan sistemlere olan ihtiyacı artırmıştır. Uyku bozukluklarının yaygınlığı da göz önüne alınırsa yukarıda sayılan problemlere çözüm için mevcut işaretlenmiş verilerden de yararlanılarak eğitilmiş yapay zekâ tabanlı çözümler üretilmelidir.

1. 2. Literatürde sunulan çalışmaların özetleri

Literatürde uyku evreleme ve hastalık tespitini otomatikleştirmeyi hedefleyen birçok yöntem önerilmiştir. Bu yöntemleri üç sınıfa ayırmak mümkündür:

- ✓ Elle özellik çıkarımı ve uzman-bilgisi-odaklı kural seti kullanımı.
- ✓ Elle özellik çıkarımı ve makine öğrenmesi sınıflandırmasının hibrit kullanımı.
- ✓ Otomatik özellik çıkarımı ve sınıflandırma yapabilecek derin öğrenme yöntemlerinin kullanımı.

Kural tabanlı sistemler uzmanların manuel olarak yaptığı işlemler sırasında aradıkları desenlerin ve koşulların yazılımsal olarak tanımlandığı ve kullanıldığı sistemlerdir. Yapay zekâ tabanlı sistemlerin yaygınlaşmasıyla birlikte bu tür yöntemler tercih edilmemektedir. Uzmanlar tarafından manuel çıkarılan özellikler üzerinde makine öğrenmesi yöntemlerinin uygulandığı sistemlerde algoritma uzmanlar tarafından çıkarılan özelliklerle eğitilir. Bu özellikler genellikle istatistiksel özelliklerdir. Sınıflandırıcı, giriş özelliklerinden sınıf etiketlerini tahmin etmeye çalışır. Literatürde önerilen birçok sınıflandırıcı iyi başarımlar göstermektedir. Ancak bu yöntemde kullanılan algoritmanın başarımları elle çıkarılmış olan özelliklerin kalitesine ve veri ön işlemeye bağlıdır. Literatürde son yıllarda sunulan çalışmalarda otomatik özellik çıkarımı yapan derin öğrenme modellerinin kullanımı yaygınlaşmıştır. Bir algoritmaya girilen veri setinden ayırıcı bir deseni bulması istenmektedir. Bu yöntemler özellikleri girilen veriden kendi kendine öğrenebilmektedir. En temel avantajı insan önyargısı olmaksızın en uygun özellikleri algoritmanın kendi kendine seçebilmesidir. Dezavantajı ise seçilen özelliklerin insanlar için soyut ve anlaşılmaz olması ve karar sürecini belirsiz hale getirmesidir. Bu tez çalışmasında da derin öğrenme yöntemleri tercih edilmiştir [5]. Bölüm 2’de tez çalışması kapsamında incelenen literatür çalışmaları ayrıntılı olarak verilmektedir.

1. 3. Tez çalışmasının katkıları

Bu tez çalışmasının literatüre katkıları aşağıda sunulmaktadır:

- ✓ Tek kanal üzerinden elde edilen EEG sinyalleri üzerinden uyku evrelemesi ve uyku hastalıkları tespiti yapan derin öğrenme modelleri geliştirilmiştir. Uyku kliniklerinde kullanılan pahalı PSG cihazlarına gerek duymadan, daha ucuz giyilebilir cihazlarla da bu işlemlerin yapılabilmesi olanaklı hale gelmiştir.
- ✓ Elle özellik çıkartma ya da elle uyku evreleme, uyku bozukluklarını tespit etme gibi zaman alıcı ve yorucu işlere gerek kalmadan geliştirilen derin öğrenme

modelleri kendisine gelen sinyalleri otomatik olarak evrelemekte ve uyku bozukluklarını tespit edebilmektedir.

- ✓ Geliştirilen derin öğrenme modelleri etiketlenmiş veriden özellik çıkarımını otomatik olarak yaptığı için uzmanların özellik çıkardığı modellerle karşılaştırıldığında daha hatasız sonuçlar üretilmektedir.
- ✓ Uyku teknisyenlerinin farklı yaklaşımlarından kaynaklanan tutarsızlıklar ortadan kalkmıştır, daha tutarlı evreleme ve hastalık tespiti sonuçları üretilmektedir.
- ✓ PSG sinyallerini ölçerken kişilere bağlanan ekstra kablo kullanımı ve kişilerin uyku kalitesini bozan, sinyallere ekstra gürültüler ekleyen durumlar tek kanallı EEG kullanımı ile ortadan kalkmıştır.

1. 4. Tezin organizasyonu

Sunulan tez çalışmasının sonraki bölümleri şu şekilde düzenlenmiştir. Bölüm 2’de uykunun özellikleri, evreleri ve yaygın uyku hastalıkları hakkında bilgi verilmektedir. Uyku evrelerinin hesaplanması ve yaygın uyku hastalıklarının tespiti için literatürde sunulan mevcut çalışmalar ve kullanılan yöntemler açıklanmaktadır. Bu tez çalışmasında kullanılan yapay zeka yöntemleri detaylandırılmaktadır. Yapay zeka kullanarak geliştirilen sistemlerin işleyişi ve eğitilmesi ve karşılaşılan sorunlar hakkında detaylı bilgiler verilmektedir.

Bölüm 3’te, önerilen modellerin çalışma mekanizması ve performans parametre ayarları anlatılmaktadır. Geliştirilen sistem ve parametre ayarları ayrıntılı olarak ele alınmaktadır. Bölüm 4’te eğitilen modellerin başarımlarının değerlendirilmesi sunulmaktadır. Benzetim sonuçları ve başarımlarının değerlendirilmesi literatürdeki benzer çalışmalar ile karşılaştırılarak verilmektedir.

Bölüm 5’te ise tez çalışmasında geliştirilen modellere ait genel değerlendirmeler aktarılmaktadır.

2. UYKU ve UYKU HASTALIKLARININ TESPİTİ

2. 1. Giriş

Uyku, tüm gelişmiş organizmaların günlük rutinlerinde geçirdikleri bir tepki süresi azalması periyodu olarak tanımlanır [6]. Uykunun amacı henüz tam olarak anlaşılamamış olsa da, bellek pekiştirmesi ve sinirsel yenilenme işlevi olduğuna dair güçlü kanıtlar vardır [7, 8]. Tüm memeliler arasında uyku süresi 2 - 20 saat arasında değişmekte olup, insanlar her gece ortalama 7.5 saat uykuya ihtiyaç duymaktadır [9, 10]. İnsanlar neredeyse ömürlerinin üçte birini uykuda geçirirler. Uykusuzluk ve solunuma bağlı uyku sorunları çok sık karşılaşılan durumlardır ve bu durumlar fiziksel ve mental sağlığı ciddi şekilde etkileyebilir. Uyku evreleme işlemi insan uykusunu analiz etmede kullanılan en önemli standarttır [11]. Uyku evreleme işlemi uyku hastalıklarının teşhis ve tedavisinde hayati öneme sahiptir [12].

Bu bölümde uyku, uykunun evrenmesi ve uyku hastalıklarının tespit edilmesi, literatürde yapılan çalışmalar ve karşılaşılan problemler sunulacaktır. Literatürde uyku evrelemesi ve uyku hastalıklarının tespitini otomatik olarak yapan çalışmalara bakıldığında yapay sinir ağlarının bir alt sınıfı olan makine öğrenmesi algoritmaları ve son yıllarda bir makine öğrenmesi çeşidi olan derin öğrenme algoritmalarının kullanıldığı görülmektedir. Bu tez çalışmasında sunulan çalışmada da otomatik uyku evrelemesi ve uyku hastalıkları tespitinde derin öğrenme algoritmaları tercih edilmiştir. Bu bölümde ayrıca yapay sinir ağı, derin öğrenme ve derin öğrenme çeşitleri de açıklanacaktır.


2. 2. Uyku

Uyku, beyin için gereklidir özellikle fiziksel ve zihinsel fonksiyonlarının yerine getirilmesinde büyük rol oynar Çoklu fizyolojik sinyallerden biri olan EEG beyin dalgaları aktivitesinin elektriksel yöntemle izlenmesini ölçmek için tercih edilir [13]. Uyku esnasında beynin sinir sisteminin bir kısmı pasif hale geçer ve beyin daha az karmaşık hale gelir. Bu nedenle beyinle ilgili uyanıklık haliyle tespit edilemeyen

bozukluklarda da ölçümlerin uykuda yapılması daha çok tercih edilen bir yoldur [5]. Uyku sırasında kaydedilen sinyaller ile beyin aktivitelerinin farklı aşamaları tanımlanabilmektedir.

2. 3. Uyku evrelemesi

Uyku gece boyunca belirli aralıklarla farklı faaliyetlerin devam ettiği bir dizi döngülerden oluşur. Bu döngülerde yer alan her bir faaliyet uyku evresi olarak isimlendirilir. Uyku evreleme işleminde beynin aktivitesini ve varyasyonlarını araştırmaya imkân tanıyan EEG sinyalleri tek başına kullanılabileceği gibi diğer sinyallerle de beraber kullanılabilir. Saçlı deri üzerinden elde edilen EEG sinyallerinin genliği 1-100 μ V arasında, frekansı ise 0.5–100 Hz aralığındadır. EEG sinyallerini kaydetmek için uluslararası 10-20 sistemi kullanılır. Elektrodların konumu EEG sinyallerinin genliğini ve frekansını etkiler. 10-20 sistemi, kafatası üzerindeki belirli kemiklerin arasındaki mesafeleri kullanır. Kafatasının ön ve arka tarafında yer alan bu kemikler arasındaki toplam mesafe %10 ya da %20'lik aralıklara bölünür. Aralıkların kesişimi ile elektrodların yerleşim düzeni belirlenir. Şekil 2-1'de elektrodların yerleşimi için kullanılan uluslararası 10-20 sistemi görülmektedir. Erişkinler için elektrod kayıt kombinasyonları için kafa derisinin üzerindeki F₄-A₁, C₄-A₁, O₂-A₁ bölgelere, yedek elektrodlar ise F₃-A₂, C₃-A₂ ve O₁-A₂'ye yerleştirilmelidir. PSG kaydı sırasında bir bozukluk olursa F₃-A₂, C₃-A₂, O₁-A₂ bölgelerinden elde edilen sinyaller kullanılmalıdır [14].



Şekil 2-1 Uluslararası 10-20 elektrod yerleşim sistemi [15].

Uyku evrelerinin ve işlevlerinin belirlenmesinde EEG dalgaları kullanılarak farklı frekans aralıklarıyla ayırt edilen beş ana beyin dalgası görülebilir [16]. Bu dalgalar ve dalgaların frekans aralıkları Tablo 2-1’de görülmektedir. Bu farklı frekansa sahip dalgalar uykunun farklı evrelerinde karışık aktiviteler halinde görülebilir.

Tablo 2-1 Band frekansına göre beyin dalgalarının gösterimi

Dalga Frekansının Adı	Dalgaın Frekansı (Hz)
Delta (δ)	0.5 - 4
Teta (θ)	4-8
Alfa (α)	8 - 13
Beta (β)	13 - 30
Gama (γ)	>30

EEG sinyallerini kullanarak uyku evreleme işlemi, 1960'larda ortaya atılmasından günümüze kadar çok az değişmiştir ve uyku laboratuvarlarında yaygın olarak kullanılmaktadır. Uyku birbirini belirli sürelerle takip eden NREM (None-REM) ve REM (hızlı göz hareketleri) evrelerinden oluşmaktadır. NREM uykusunun sırasıyla S1 (Evre 1), S2 (Evre 2), S3 (Evre 3) ve S4 (Evre 4) şeklinde 4 dönemden oluşur R&K [17]. Uykuya dalma esnasındaki ilk uyanık dönemden hemen sonra NREM uyku evresinin 1,


2, 3 ve 4. evreleri görülür takriben 90 dakika sonra ise REM evresi başlar. Başlangıçtan REM evresine kadar olan kısım bir uyku siklusudur yani bir uyku siklusunda NREM ve REM evreleri yer almaktadır. Bir uyku siklusu kişiden kişiye göre değişmekle beraber 90 ila 120 dakika arasındadır. Tüm uyku boyunca bu sikluslar 4 ila 6 arasında tekrarlanır. İlk REM evresi diğer sikluslarda yer alan REM evrelerine göre daha kısadır ve ortalama 5 - 15 dakika sürer [18]. Amerikan Uyku Tıbbı Akademisi (AUTA) tarafından R&K standartları temel alınarak yayınlanan güncel standart [14], dört farklı uyku evresinden oluşmaktadır. Bu evreler S1 (uyku hali), S2 (hafif uyku), S3 / SWS (Yavaş Dalga Uyku) ve REM (Hızlı Göz Hareketi Uykusu) olarak adlandırılmaktadır. AUTA standardı R&K standardının [14] yeniden düzenlenmiş halidir. AUTA ve R&K arasındaki dönüşüm işlemi Tablo.2-2’de sunulmaktadır.

Tablo 2-2 R&K standardının AUTA standardına dönüşümü.

R&K	S1	S2	S3/S4	REM	Uyanıklık
AUTA	S1	S2	SWS	REM	Uyanıklık

Tablo 2-2’de gösterilen R&K standardında yer alan S3 ve S4 uyku evreleri AUTA standardında birleştirilerek tek bir uyku evresi olan SWS olarak kabul edilmiştir. Uzman bir doktor veya uyku teknisyeni polisomnografik kayıtları 30 saniyelik epoklara bölütlere (epok) ayırarak uyku evreleme kurallarına göre her bir epoku bir evrede işaretlerler. Epokların 30 sn olarak seçilmesinin hiçbir biyolojik dayanağı yoktur. İlk yapılan EEG çalışmaları esnasında sinyaller kâğıtlar üzerine analog olarak yazdırılmaktaydı. Bir kâğıt sayfa üzerine sadece 30 sn’lik EEG sinyali çizilebilmekteydi. O yüzden günümüze kadar gelen bütün çalışmalarda EEG sinyali 30 sn’lik epoklar halinde değerlendirilmiştir. Bu evreleme işlemi 8 saatlik bir polisomnografi kaydı için bir uyku teknisyeninin yaklaşık olarak 30-90 dakikasını almaktadır [19].

Gece boyunca uyku evrelerinin seyri hipnogram adı verilen grafiklerle gösterilir. Hipnogram, tüm gece boyunca uyku evrelemesine genel bir bakış sağlamak için kullanılır. Hipnogram grafikleri tüm gece boyunca süren uykunun durumunu analiz etmek için önemli bilgiler içerir. Şekil 2-2’de örnek bir hipnogram görülmektedir.



Şekil 2-2 Örnek bir hipnogram görüntüsü.

Şekil 2-2’de verilen grafikte yatay eksen 30 saniyelik epokları, dikey eksen ise uyku evrelerini göstermektedir.

Literatürde yer alan çalışmalara bakıldığında, EEG sinyali, manuel ya da otomatik skorlama işlemlerinde uyku evrelemesi işlemlerinde kullanılan en yaygın sinyallerden biridir [5]. Literatürde EEG tabanlı otomatik uyku evrelemesi yapan çalışmalarda özellik çıkarımı yapmak için farklı yöntemler önerilmiştir. Bunlar zaman alanı domeni, frekans alanı domeni ve zaman-frekans domeni alanı analizleridir. Bazı otomatik uyku evreleme işlerinde doğrusal ayırmacılık analizi, destek vektör makineleri, yapay sinir ağı, k-en yakın komşu algoritması ve rassal orman gibi sınıflandırma problemlerinde kullanılan makine öğrenmesi algoritmaları kullanılmıştır.

Makine öğrenmesi ile yapılan çalışmalarda Radha [20] vd. 6 farklı EEG sinyalini zaman, frekans ve doğrusal olmayan sinyal işleme özellikleri kullanarak işlemişlerdir ve en iyi performansın, spektral lineer özelliklere sahip frontal EEG sinyalleri kullanılarak bulunduğunu ve bir rassal ormanın, destek vektör makinaları ile sınıflandırıcısının daha yüksek performansa sahip olduğunu gözlemlemişlerdir. Sınıflandırmada rassal orman ve destek vektör makinaları kullanarak sinyali farklı sayıda uyku evresi içerecek şekilde sınıflandırmışlardır. Yapılan çalışma 6, 5, 4, 3, 2 sınıflı uyku evrelerinde sırasıyla %85.57, %86.53, %87.49, %89.77 ve %95.05 doğruluk elde edilmiştir. Fraiwan [21] vd. tek kanallı EEG sinyali ve bir yapay sinir ağı kullanarak Wigner-Ville dağılımı, Hilbert-Hough spektrumu ve sürekli dalgacık dönüşümünden entropi özellik çıkarımına dayalı otomatik uyku evreleme modeli oluşturmuşlardır. Çalışmadaki diğer yaklaşımlara göre

Wigner-Ville dağılımının sınıflandırma doğruluğu çok daha yüksek olmakla beraber %84 olarak bulunmuştur. Koch [22] vd. yaptıkları çalışmada 2 EEG ve 2 EOG kanalı içeren çoklu sinyalden gizli Dirichlet tahsisi yöntemi ile uykuyu evrelemişlerdir. Yapılan çalışmanın doğruluğu %68 olarak bulunmuştur.

Literatürde uyku evrelerini EEG, EOG ve EMG gibi çoklu sinyaller kullanarak otomatik olarak sınıflandıran çeşitli çalışmalar da yer almaktadır. Sokolovsky [23] vd. EEG ve EOG sinyallerini kullanarak bir ESA modeli ile otomatik uyku evrelemesi yapan bir sistem geliştirmişlerdir. Modelin makro F1-skoru %77 ve doğruluğu %81 olarak bulunmuştur. Bununla birlikte tek kanallı EEG sinyalleri kullanarak da benzer bir doğruluk başarımına sahip çalışmalar bulunmaktadır. Bu çalışmaların bazılarında geleneksel makine öğrenmesi yöntemleri tercih edilmiştir ve başarımı çok kanallı çalışmalardan düşük değildir. Ghimatgar [24] vd. tarafından yapılan çalışmada tek kanallı EEG sinyali kullanarak bir özellik seçici yöntemiyle uyku epoklarından elle özellik çıkarımı yapılmış, bir makine öğrenmesi yöntemi olan rassal orman sınıflandırıcı ile veri sınıflandırılmıştır. 6 aşamalı R&K ve 5 aşamalı AUTA'ya göre modelin uyku evreleme başarımı sırasıyla en yüksek %87,4 ve %80,4 doğruluk olarak bulunmuştur. Elle özellik çıkarımı yapmak yerine otomatik özellik çıkaran derin öğrenme yöntemleri kullanıldığında da önerilen modellerin başarımı düşmemiştir. Tsinalis [25] vd. tarafından önerilen otomatik uyku evrelemesi yapan tek kanallı ham EEG sinyallerini işleyebilen ESA modeli, genel bir veriseti üzerinde %74 F1-skoru ve %81 doğrulukla evreleme yapmıştır. Zhang [26] vd. iki genel verisetinden alınan tek kanallı EEG sinyallerine Hilbert–Huang dönüşümü uygulamışlar ve 2 boyutlu zaman-frekanslı görüntüler elde etmişlerdir. Çalışmada önerilen Ortogonal ESA ile eğitilen model uyku evrelemesinde sırasıyla %88.4 ve %87.6 toplam sınıflandırma doğruluğu elde etmiştir.

Sors [27] vd. tarafından yapılan çalışmada 12 evrişim katmanı ve 2 tam bağlı katmana sahip bir ESA kullanılmıştır. Etiketli ve tek kanallı ham EEG sinyalleri herhangi bir önışlemeye ya da özellik seçimine gerek kalmadan sisteme verilmiştir. 5 sınıflı uyku evrelemesi yapan sistemin doğruluğu %0.81 kappa katsayısıyla, %87 olarak bulunmuştur. Supratak [28] vd. MASS ve Sleep-EDF adlı iki ayrı veriseti üzerinde sınıflandırma yapan iki aşamalı bir model geliştirmiştir. Tek kanallı EEG kullanarak EEG epoklarından özellik çıkarımı için ESA ve uyku evreleri arasındaki geçiş kurallarını öğrenmek için çift yönlü uzun-kısa dönem bellek kullanmışlardır. Modelin doğruluk ve makro F1-skoru

sırasıyla MASS için %86.2 ve %81.7 olarak, Sleep-EDF için ise %82 ve %76.9 olarak bulunmuştur. Karmaşık bir yöntem tercih edilmesine rağmen sunulan çalışmanın başarımı literatürdeki tek kanallı EEG kullanan çalışmalardan daha yüksek değildir.

2. 4. Uyku hastalıkları

Uyku hastalıkları kişinin yaşam kalitesini ve sağlığını etkiler. Kalitesiz uyunan bir uykunun kalp, diyabet ve obezite gibi birçok farklı hastalıklarla bağlantısı olabilmektedir [29-30]. Hemen hemen tüm psikiyatrik bozukluklara uyku bozuklukları da eşlik etmektedir [31]. Her yıl tıbbi ve psikolojik alanda uyku ve uyku bozuklukları üzerine yüzlerce makale yayınlanmaktadır. Uyku ile ilgili çok çeşitli rahatsızlıklar bulunmaktadır. Bunlardan en sık görülen uyku bozuklukları arasında uykuda solunum bozuklukları olan uyku apnesi sendromu (UAS) ve hipoapnedir. Hipoapne kişinin uykuda solunumunun yavaşlaması olarak tanımlanır. UAS ise uyku esnasında solunumun kesilmesi ya da durması şeklinde ortaya çıkan bir uyku hastalığıdır. Uyku apnesi, hastaları şiddetli gece horlaması ve tüm gün boyunca uyuklama (narkolepsi), depresyon, hafıza kaybı hatta kalp hastalıkları gibi yaşamı tehdit edici şekilde ortaya çıkabilir. Uyku apnesinin obstrüktif ve santral Uyku apnesinin en yaygın görülen çeşitleri obstrüktif uyku apnesi ve santral uyku apnesidir. Obstrüktif uyku apnesi (OUA) üst solunum yolunun tıkanmasıyla solunumun duraksaması olarak tanımlanır. Santral uyku apnesi (SUA) ise solunumu kontrol eden merkezi sinir sisteminin dengesizliği sonucunda solunumun durması olarak ifade edilir [32].

Uyku evreleme işlemi uyku ile ilişkili hastalıkların araştırılmasının yanı sıra uyku mekanizmalarının ve işlevlerinin keşfi çalışmalarında da kullanılmaktadır [33]. Uyku kalitesi uyku süresine, uyku evrelerine ve gece uyanma sayısına bağlıdır.

Uyku nörofizyolojik bir süreçtir. Uyku bozuklukları, beyin işlevlerinin bozukluklarından kaynaklandığından EEG sinyalleri uyku esnasında beyin aktivitesinin dinamik değişkenlerini araştırmak için kullanılan en iyi veridir [34]. Uyku hastalıklarının tespitinde de uyku hastalıklarını otomatik olarak tespit edebilen sistemlere ihtiyaç duyulmaktadır. Literatürde yer alan geçmiş dönem çalışmaları incelendiğinde uyku hastalıklarının otomatik olarak tespitinde makine öğrenmesi yöntemlerinin yapılan çalışmalarda daha çok kullanıldığı görülmektedir. Tuncer [35] vd. yaptıkları çalışmada

görüntü işleme tekniklerinde kullanılan AlexNet ve VGG-16 derin öğrenme yöntemleriyle özellik çıkarma işlemi yapılmış ve destek vektör makinası ve k-en yakın komşu algoritmasıyla yapılan iş sınıflandırılmıştır. En yüksek doğruluk başarımı AlexNet modeli ve destek vektör makinası sınıflandırıcı bir arada kullanıldığında %92.64 olarak bulunmuştur. Buettner [36] vd. yaptığı çalışmada REM uyku davranışı bozukluğunu tespit etmeye çalışmak için bir uyku merkezinden 22 hasta ve 16 sağlıklı denekten elde ettikleri REM uykusu verisini çeşitli sinyal ön işleme teknikleri ile gürültüden arındırdıktan sonra sinyale hızlı Fourier dönüşümü uygulayarak sinyali analiz etmişlerdir. Rassal orman tekniği ile verileri sınıflandırılmıştır. Sistemin doğruluğu %90.12 olarak bulunmuştur. Wafaa [37] vd. obstrüktif uyku apnesi tespiti için Phsyionet web sitesinden aldıkları veriseti üzerinde sonsuz dürtü yanıtı ve butterworth band geçiren filtreler kullanarak sinyali analiz etmişler ve destek vektör makinası, yapay sinir ağı, doğrusal ayrımcılık analizi, naive bayes gibi bir takım makine öğrenmesi algoritmaları ile sınıflandırmışlardır. Sınıflandırılan veriyi birbirleriyle karşılaştırarak en iyi sınıflandırıcının %97.14 doğruluk oranı ile destek vektör makinası olduğuna ulaşmışlardır. Uçar [38] vd. Sakarya Devlet Hastanesi Göğüs Hastalıkları Bölümünden 10 OUA hastasından elde ettikleri tek kanallı ECG verisi üzerinde özellik çıkarımı yapmışlardır. Fisher özellik seçim algoritması ve Temel Bileşen Analizi (TBA) kullanılarak özellik sayısı indirgenmiştir. Elde edilen özellikler KA, DVM, k-en yakın komşuluk algoritması ve topluluk sınıflandırıcılar gibi yöntemlerle sınıflandırılmıştır. Doğruluk başarımının %85.12 oranı ile en yüksek topluluk sınıflandırıcısı olarak bulunmuştur.


Literatürde son yıllarda yer alan çalışmalarda derin öğrenme yöntemleri de kullanılmıştır ve başarımları makine öğrenmesi yöntemleri ile kıyaslandığında daha yüksek olduğu görülmektedir. Erdenebayar [39] vd. yaptıkları çalışmada 86 uyku apnesine sahip bireyden alınan elektrokardiogram ECG veriseti üzerinde derin sinir ağı (DSA), 1 boyutlu evrişimli sinir ağı (ESA), 2 boyutlu ESA, tekrarlı sinir ağı, uzun kısa dönem bellek, geçitli tekrarlayan birim olmak üzere 6 farklı derin öğrenme modelini üzerinde kullanmışlardır. En iyi performansın %99.0 doğruluk oranı ile 1 boyutlu ESA ve %99.0 duyarlılık ile geçitli tekrarlayan birim olduğunu bulmuşlardır. Chambon [40] vd. 4 farklı ham EEG uyku verisi üzerinde uyku iğciği, k-kompleksi ve uyarılmalar gibi 3 farklı durumu, Dreem One Shot Event Detector (DOSED) olarak isimlendirdikleri ESA modeli üzerinde tespit

etmeye çalışmışlardır. DOSED modelinin F1 skorlaması %0.3 olarak bulunmuştur. Biswal [41] vd. tekrarlı derin öğrenme ağı kullanarak geniş bir veritabanı seti ile eğittikleri SleepNet isimli model ile çeşitli uyku hastalıklarını tespit edebilmektedirler. Sistemin doğruluğu %85.6'tır. Mahmud [42] vd ESA kullanarak St. Vincent's Üniversite Hastanesi'nde yatan uyku hastalarından toplanan PSG verileri üzerinde gerçek zamanlı UAS tespit eden bir çalışma gerçekleştirmişlerdir. Doğruluk değeri %81,8 olarak bulunmuştur. Sugi [43] vd ESA kullanarak Toranomom Hastanesi'nde yatan uyku hastalarından toplanan PSG verileri üzerinde EEG uyarılmalarının tespitini yapmışlardır. Bu çalışmanın doğruluk değeri %86'dır.

2. 5. Yapay sinir ağı

İnsan düşünce sistemi ve karar verme becerisini modellemek ve insan gibi düşünen sistemler oluşturmak için nörobilimci olan McCulloch ve Pitts tarafında geliştirilen ve beyin fonksiyonlarının işlevlerini mantıksal olarak hesaplayan bir sistemdir [44]. Bu sistem insan sinir sisteminin işleyişine benzer şekilde çalışan Yapay Sinir Ağlarının (YSA) temelini oluşturmuştur.

YSA, biyolojik sinir ağları tarafından yapılan hesaplamalara dayanan bir makine öğrenmesi çeşididir. YSA'daki en basit algılayıcı; k sayıda birden çok giriş alır (in_k), her bir girişi w_k ağırlıkları ile çarpar. Girişler ile ağırlıkların çarpımının toplamından çıkış aktivasyonunu hesaplamak için bir aktivasyon fonksiyonu kullanır. Şekil 2-3'de örnek bir algılayıcı gösterilmektedir. Nöron çıkışı ise Denklem 1'de sunulmaktadır.




Şekil 2-3 Bir Algılayıcının gösterimi

$$O = Af \left(\sum in_k * w_k \right) \quad (1)$$

Denklem 1’de Af Aktivasyon fonksiyonunu, in_k girişleri, w_k o girişlere ait ağırlıkları göstermektedir. Aktivasyon fonksiyonu, nöronun çıktısının değerini sahip olduğu eşik değeri ile kontrol eder ve nöronun çıkış değerini ayarlar. YSA’da genellikle doğrusal olmayan aktivasyon fonksiyonları kullanılır böylece çıkış doğrusal olmayan değerlerle ifade edilir. Bu da doğrusal olmayan karmaşık modellerin tasarlanabilmesini sağlar. Nöronun çıkış değeri olması gereken değer ile karşılaştırılır ve bunun sonucunda bir hata oranı hesaplanır. Gradyan inişi kullanılarak hata oranı en aza indirilebilecek yönde yeniden hesaplanır. Gradyan inişi herhangi bir değerle başlatılarak fonksiyonun global minumum noktalarını hesaplanmaya çalışılır. Hesaplanan hata oranı her defasında bir katman olacak şekilde geriye yayılır ve nöronların ağırlıkları yeniden güncellenir. Bu olaya geriyayılım denir. Geriyayılım işleminde geriye doğru türev alınarak farkın bulunması sağlanır ve bulunan fark değeri öğrenme katsayısı ile çarpılır ve çıkan sonuç ağırlık değerlerinden çıkarılarak yeni ağırlık değerleri hesaplanır. Öğrenme katsayısı istenilen sonuca ulaşmak için çözümün uygun adımlarla tahmin edilmesini sağlar. Öğrenme katsayısı sabit değer olarak seçilebileceği gibi artırımlı bir değer olarak da belirlenebilir. Ağın eğitimi tamamlanıncaya kadar bu işlemler sürekli devam eder [45] Ağırlıkların değişimi Denklem 2’de sunulmaktadır.

$$\Delta w_k = (\text{gerçek} - \text{çıkış}) * i_k * \text{öğrenme_oranı} \quad (2)$$

Birçok algılayıcı nöron, çok katmanlı bir algılayıcı (ÇKA) oluşturmak üzere istiflenebilen çok sınıflı çıktıya izin vermek için bir nöron tabakası oluşturacak şekilde paralel olarak yerleştirilebilir. Şekil 2-4’de örnek bir ÇKA görülmektedir. Bu ÇKA bir saklı katman h_k bir de çıkış katmanı o_k olmak üzere iki katmana sahiptir. Giriş katmanı i_k bir katman olarak sayılmamaktadır. Hesaplamalarda başarıma herhangi bir etkisi yoktur [46].



Şekil 2-4 Tek gizli katmana sahip basit bir ÇKA.

YSA eğitilirken karşılaşılan sorunlardan biri de aşırı öğrenme problemidir. YSA uygun katsayıları öğrendiğinde, öğrenilmemiş test verileri üzerinde aynı başarıyı gösteremediğinde aşırı öğrenme problemi ortaya çıkar. Aşırı öğrenmeye karşı ağırlık büyüklüklerinin sınırlandırılması [47] ya da ağı gürültülü ortamda çalışmaya zorlamak gerekir [48]. Birçok farklı eğitim modu vardır. Öğrenme sürecinin her örnek için ayrı ayrı gerçekleştirilmesi yerine toplu modda da eğitim gerçekleştirilebilir. Toplu modda, ağırlık değişimlerinin ortalaması alınır ve güncelleme yalnızca birkaç örneğe uygulanır. Ağ içerisinde yer alan uç örnekler ağı ağırlıklarının durumunu çok fazla değiştirmez. Bu nedenle ağı ağırlık ortalamasını almak daha düzgün bir öğrenme eğrisi oluşturmamızı sağlar.

2. 6. Aktivasyon fonksiyonları

Aktivasyon fonksiyonları, bir sinir ağında girişlerin ağırlıklarla çarpılması ile elde edilen toplamı alarak sahip olduğu eşik değeri ile karşılaştırır ve nöronun çıkış değerini ayarlar. Bu işlemler sırasında genellikle gradyan inişi kullanılır [49].

Lineer doğrusal bir modelde, x girdilerin, w ağırlıkları toplamı hesaplanır ve bias değeri eklenerek Denklem 3'teki gibi bir $f(x)$ çıktısı üretilir:

$$f(x) = w^T x + b \quad (3)$$

Denklem 3'de w ağırlıkları, x girişleri ve b biası temsil eder. Bir yapay sinir ağı Denklem 3'deki eşleştirmelerden doğrusal sonuçlar üretir ve veride yer alan daha fazla deseni öğrenebilmesi için ve daha fazla hesaplama yapabilmesi için bu sonuçları doğrusal olmayan çıktıya dönüştürmesi gerekir. Bu dönüşüm için bir aktivasyon fonksiyonuna ihtiyaç vardır. Yapay sinir ağının çıktıları Denklem 4'de gösterilmiştir.

$$y = (w_1 x_1 + w_2 x_2 + \dots + w_n x_n + b) \quad (4)$$

Her katmanın çıktısı bir sonraki katman için girdi olarak belirlenir. Bu işlem çıktı katmanına gelene kadar böyle devam eder ve çıktı standart olarak doğrusaldır. Bu doğrusal çıktıları doğrusal olmayan çıktıya dönüştürmek için ağda aktivasyon fonksiyonları kullanılır. Ağda kullanılan aktivasyon fonksiyonunun çeşidine göre istenen çıktılar üretilebilir.

$$y = \alpha(w_1 x_1 + w_2 x_2 + \dots + w_n x_n + b) \quad (5)$$

Denklem 5'de gösterilen α aktivasyon fonksiyonudur. Doğrusal girdiyi doğrusal olmayan çıktıya dönüştürerek derin ağlar için yüksek dereceden polinomların öğrenilmesine yardımcı olmaktadır. Doğrusal olmayan aktivasyon fonksiyonlarının türevleri alınabilir. Eğer böyle bir özellikleri olmasaydı derin sinir ağlarının geri yayılımı esnasında gerekli hesaplamalar yapılamazdı [49].


Derin mimariler, her biri verilen bir görevi yerine getirmek için birlikte öğrenilen hem doğrusal hem de doğrusal olmayan işlemleri içeren birkaç işlem katmanından oluşur. Bu

daha derin ağırlara daha iyi performans sağlar ancak bununla beraber 1'den küçük türev terimleri gradyanın kaybolması problemini ortaya çıkarır. Bu türev terimlerinin art arda çarpılmasıyla, değer küçülür ve sıfıra yaklaşır, dolayısıyla gradyan kaybolur. Eğer değerler 1'den büyükse, ardışık çarpma değerleri artacak ve gradyan sonsuza ıraksıyacaktır ve bu durumda da gradyan patlayacaktır. Aktivasyon fonksiyonları gradyanların değerlerini belirli bir sınırdan tutarak bu durumun önüne geçer. Aktivasyon fonksiyonları, farklı matematiksel işlevler kullanılarak elde edilir. Sinir ağı hesaplaması için aktivasyon fonksiyonlarının kullanılması 1993 yılında Eliot tarafından ortaya atılmıştır [50].

Aşağıda YSA'da yaygın olarak kullanılan aktivasyon fonksiyonları verilmektedir.

Sigmoid fonksiyonu: Sigmoid fonksiyonu daha çok ileri beslemeli sinir ağlarında kullanılır ve doğrusal olmayan bir fonksiyondur [51]. Sigmoid fonksiyonu Denklem 6'da gösterilmektedir. Sigmoid fonksiyonunun grafiği Şekil 2-5'de gösterilmektedir.

$$f(x) = \left(\frac{1}{1 + e^{-x}} \right) \quad (6)$$




Şekil 2-5 Sigmoid fonksiyonunun grafiği.

Sigmoid fonksiyonu, derin öğrenme mimarilerinin çıktı katmanlarında tercih edilir ve olasılığa dayalı çıktıyı tahmin etmek için kullanılır. Sigmoid ikili sınıflandırma problemlerinde başarılı sonuçlar üretmektedir, lojistik regresyon görevlerinin yanı sıra diğer sinir ağı modellerinde de kullanılmaktadır [52]. Sigmoid işlevlerinin temel avantajları, anlaşılması kolay olması ve çoğunlukla sığ ağlarda kullanılmasıdır. Sigmoid aktivasyon fonksiyonu ile bir sinir ağı başlatılırken ağırlıklarına rastgele ilk değer ataması yapılırken küçük değerler verilmemesi önerilmektedir [53]. Sigmoid aktivasyon fonksiyonunun daha derin gizli katmanlardan giriş katmanına geri yayılımı esnasında bazı bölgelerde türev değerlerinin çok küçük olması nedeniyle öğrenme işleminin çok yavaş olmasına sebep olmaktadır [54].

Hiperbolik Tan Fonksiyonu: Hiperbolik tanjant fonksiyonu, derin öğrenmede kullanılan başka bir aktivasyon fonksiyonu türüdür ve derin öğrenme uygulamalarında kullanılan bazı farklılıklara sahiptir. Tanh fonksiyonu olarak bilinen hiperbolik tanjant fonksiyonu, -1 ile 1 aralığındadır.

tanh fonksiyonu Denklem 7'de verilmektedir. Tanh fonksiyonunun grafiği 2-6'da gösterilmektedir.

$$f(x) = \left(\frac{e^x - e^{-x}}{e^x + e^{-x}} \right) \quad (7)$$



Şekil 2-6 tanh fonksiyonun grafiği.


Tanh fonksiyonu, özellikle çok katmanlı sinir ağlarında sigmoid fonksiyonu ile kıyaslandığında performansı daha iyi olduğu için tercih edilen bir fonksiyondur [49, 52]. Tanh fonksiyonu, sigmoid fonksiyonunda görülen kaybolan gradyan sorununu tam olarak çözemez. Ancak sıfır merkezli çıktı üretmesi nedeniyle geri yayılım sürecini kolaylaştırır. Tanh fonksiyonun bir özelliği yalnızca girdinin değeri 0 olduğunda, yani x sıfır olduğunda, yalnızca 1 derecesine ulaşabilmesidir. Bu tanh fonksiyonunun hesaplama sırasında bazı ölü nöronlar üretmesini sağlar. Ölü nöronlar gradyanların sıfır olması durumu olarak nitelendirilebilir [49].

Doğrultulmuş Doğrusal Birim Fonksiyonu:) Nair ve Hinton tarafından 2010 yılında önerilen doğrultulmuş doğrusal birim fonksiyonu (ReLU) derin öğrenme alanında günümüzde en yaygın kullanılan fonksiyonlardan biridir [55]. ReLU, derin öğrenmede sigmoid ve tanh fonksiyonları ile kıyaslandığında daha iyi bir performansa sahiptir ve daha hızlı öğrenebilen bir aktivasyon fonksiyonudur. [56 – 58]. ReLU, neredeyse doğrusal bir işlevi temsil eder ve bu nedenle, doğrusal modellerin özelliklerini gradyan-iniş yöntemleriyle optimize etmeyi kolaylaştıran özelliklerini korur [59]

ReLU aktivasyon fonksiyonu, sıfırdan küçük değerlerin sıfıra eşitler ve böylece ReLU'nun verildiği her giriş elemanı için bir eşik işlemi gerçekleştirir.

ReLU fonksiyonu Denklem 8’de verilmektedir. ReLu fonksiyonun grafiđi 2-7’de gör÷lmektedir.

$$f(x) = \max(0, x) = \begin{cases} x_i, & \text{Eđer } x_i \geq 0 \\ 0, & \text{Eđer } x_i < 0 \end{cases} \quad (8)$$




Şekil 2-7 ReLu fonksiyonunun grafiđi.

Hesaplama ReLu aktivasyon fonksiyonunun kullanılmasının bir avantajı da, genel hesaplama hızıyla birlikte üstel sayıları ve bölmeleri hesaplamadığından daha hızlı hesaplama yapabilmesidir [60]. ReLU'nun bir diđer özelliđi de sıfırdan maksimuma kadar deđerleri sıkıştırırken gizli katmanlarda tüm nöronları aktive etmemesidir. Bununla birlikte, ReLU'ların aşırı öğrenmesinin etkisini azaltmak için dropout tekniđi benimsenmiştir. Derin sinir ađlarının performanslarını iyileştirmiş olmasına rağmen, ReLU aşırı öğrenme problemine sahiptir. ReLu negatif bölgelerdeki ölü nöronlar sıfır aktivasyon sağladığından öğrenmeyi engeller [59]. Bu sorunları çözmek için Leaky ReLU önerilmiştir.

Leaky ReLu Fonksiyonu (LReLU): LReLU, 2013 yılında ReLu’daki ölü nöronlara bir çözüm geliştirmek için ReLu’nun sıfır gradyana sahip olduđu bölgeye negatif eğimli

doğrusal bir doğru eklenmesiyle elde edilen aktivasyon fonksiyonudur [61]. Alfa parametresi, eğitim sırasında herhangi bir zamanda gradyanların sıfır olmayacağı şekilde ReLU'ların ölü nöron problemine bir çözüm olarak geliştirilmiştir. LReLU 0.01 aralığında negatif gradyan α için çok küçük bir sabit değere sahip gradyanı hesaplar, LReLU aktivasyon fonksiyonu Denklem 9'da verilmektedir. LReLU fonksiyonun grafiği Şekil 2-8'de verilmektedir.

$$f(x) = \alpha x + x = \begin{cases} x, & \text{Eğer } x > 0 \\ \alpha x, & \text{Eğer } x \leq 0 \end{cases} \quad (9)$$



Şekil 2-8 LReLU fonksiyonun grafiği


Üstel Doğrusal Değerler Fonksiyonu: Üstel doğrusal birimler (ELU'lar), Clevert vd. tarafından 2015'te önerilen başka bir aktivasyon fonksiyonu türüdür ve derin sinir ağlarının eğitimi hızlandırmak için kullanılırlar. Ortalama birim aktivasyonunun sıfıra yaklaştırılmasına izin veren, böylece hesaplama karmaşıklığını azaltan ve öğrenme hızını artıran negatif değerlere sahiptirler. ELU, eğitim sırasında ortalama aktivasyonu sıfıra doğru iterek bias kaymalarını azalttığı için ReLU'ya iyi bir alternatiftir [61].

ELU fonksiyonu Denklem 10'da verilmiştir.

$$f(x) = \begin{cases} x, & \text{Eğer } x > 0 \\ \alpha \exp(x) - 1, & \text{Eğer } x \leq 0 \end{cases} \quad (10)$$

ELU denkleminin türevi veya gradyanı Denklem 11’de verilmiştir. ELU fonksiyonun grafiği Şekil 2-9’da gösterilmektedir.

$$f' = \begin{cases} 1, & \text{Eğer } x > 0 \\ f(x) + \alpha, & \text{Eğer } x \leq 0 \end{cases} \quad (11)$$



Şekil 2-9 ELU fonksiyonunun grafiği.

Buradaki α , ELU hiperparametresidir. Genellikle 1.0 olarak ayarlanan negatif net girdiler için gradyan saturasyonu noktasını kontrol eder. Bununla birlikte, ELU'nun sınırlılığı, ELU'nun değerleri sıfırda ortalamamasıdır [62].

2. 7. Derin öğrenme

Derin öğrenme bir geniş yapay sinir ağı modelidir. Derin öğrenme modellerinde de öğrenme işinin yapıldığı katmanlar çok katmanlı YSA’dan meydana gelir. Derin


öğrenme, çok sayıda katmandan oluşan hesaplamalı bir yöntemdir. Derin öğrenme yapay zekânın bir alt öğrenmesi olan makine öğrenmesinin de bir alt sınıfıdır [49].

Derin öğrenme ağları; önışleme, boyut azaltma ve sınıflandırma gibi işlemleri tek bir model içinde birleştirir. Bu tekil modelde her bir katmanın çıkışı kendisinden sonra gelen katmanın girişı olarak kullanılır ve bilgi tüm katmanlar boyunca birinden diğetine doğru bu şekilde ilerler ve öğrenme adım adım gerçekleştirilir. Tüm katmanlarda ve farklı seviyelerde yer alan nöronlar kendi ağırlıklarını hesaplarlar ve sonrasında bu bilgiyi çıkış katmanına kadar bir sonraki seviyeye taşırlar [63].

Çeşitli derin öğrenme yöntemleri olmakla birlikte sınıflandırma işlemlerinde yaygın olarak kullanılan derin öğrenme yöntemleri evrişimli sinir ağları ve tekrarlı sinir ağlarıdır.

2. 7. 1. Evrişimli sinir ağları


Yapay zekâ alanındaki son gelişmelerin birçoğı evrişimli sinir ağlarının (ESA) kullanılmasıyla mümkün olmuştur [64]. En basit haliyle bir ESA, bir giriş sinyaline uygulanan bir evrişimli filtre içerir. Filtre kelimesi yerine çekirdek de kullanılmaktadır. Fitrenin tüm girişleri nöral ağırlıklardan meydana gelir. Geri yayılım ile bu ağırlıklar daha sonra öğrenilebilir ve giriş sinyalinde mevcut olan özelliklere uyum sağlayabilir. Her filtre, girişin üzerinde 'tarama' yapar ve filtre çekirdeğı için o bölgenin aktivasyonunu döndürür. ÇKA'ya benzer şekilde katmanlar arka arkaya bağlanabilir ve her katman kendinden önce gelen katmanda yer alan özelliklerden daha soyut özellik çıkarımı yapabilir. Bu yolla, biyolojik sinyal ya da gibi işlenmemiş verilerden soyut özelliklerin çıkarılması mümkün olabilmektedir. Evrişimli sinir ağlarında evrişimli katmanlar, havuzlama katmanları ve tam bağı katmanlar olmak üzere üç çeşit katman bulunmaktadır. ESA'da yer alan bu katmanlar ve dizilimi Şekil 2-10'da gösterildiğı gibidir. Bir ESA modelinde onlarca filtre kullanılır. Bu sayede şekilde görülen evrişim katmanları oluşur.



Şekil 2-10 Evrişimli Sinir Ağının yapısı.


Evrişimli katmanlar filtre ve özellik haritalarından oluşur. Filtreler katmanların nöronlarıdır. Her bir filtrenin giriş ağırlığı ve çıkış değeri vardır. Desen ya da alıcı alan olarak adlandırılan giriş boyutu sabit bir karedir. Evrişim katmanı bir giriş katmanı olarak seçilmişse, giriş deseni piksel değerler olacaktır. Ağ mimarisi derinleştikçe her bir evrişim katmanı bir önceki katmandan gelen özellik haritalarını girdi olarak alır. Önceki katmana uygulanan bir filtrenin çıkışı özellik haritası olarak isimlendirilir. Bir filtre tüm önceki katmanlar boyunca her işlemde bir piksel hareket ederek işlenir. Her pozisyon nöron aktivasyonu ile sonuçlanır ve çıktı özellik haritasında toplanır. Alıcı alanın aktivasyondan aktivasyona bir piksel taşınması durumunda alanın önceki aktivasyonun (alan genişliği - 1) giriş değerleri ile çakışacağı açıktır.

Şekil 2-11’de bir evrişimli filtrenin uygulaması görülmektedir. 3x3 boyutunda bir filtre 7x7 boyutundaki bir kaynak şekil üzerine uygulanmaktadır. Filtreler şekil üzerinde kenarların ve çizgilerin keşfedilmesine yarar. Daha fazla filtre daha fazla ayrıntının keşfedilmesi ile sonuçlanır. Filtre uygulandıktan sonra oluşan yeni matrise özellik haritası denilmektedir. Her bir evrişim işlemi sonunda özellik haritasının boyutu giriş verisine göre küçülmektedir. Bununla birlikte uygulanan filtre sayısı kadar yeni özellik haritası oluşacaktır.




Şekil 2-11 Evrşimli filtreler.

Her bir katmandan sonra uygulanan transfer fonksiyonları lineerliği kırar ve lineer olmayan bir yapıya tekrar dönüşmesini sağlar. Şekil 2-12 üzerinde ESA’larda yaygın olarak kullanılan ReLu fonksiyonunun uygulaması örnek olarak görülmektedir.




Şekil 2-12 Transfer fonksiyonu uygulama örneği.

Filtrenin her aktivasyondan önceki katmandaki giriş boyunca taşındığı mesafe adım olarak adlandırılmaktadır. Bir önceki katmanın boyutu, filtrenin alıcı alanının ve adımın büyüklüğüne göre bölünemezse, alıcı alan giriş özelliği haritasının kenarını okumaya çalışacaktır. Bu gibi durumlarda sıfır dolgu gibi teknikler kullanılır. Sıfır dolgu tekniğinde alıcı alanın doğru adımlama sayısına bölünebilmesi için sıfır değerlerle genişletilmiş sahte kenarlar oluşturulur. Şekil 2-13 üzerinde sahte kenarlar görülmektedir.



Şekil 2-13 Sahte kenarlar.

Havuzlama katmanları önceki katmanlardan çıkarılan özelliklerin boyutunu indirmek için kullanılır. Havuzlama katmanları, bir veya daha fazla evrişim katmanı dizisini takip eder. Bu katmanlar öğrenilen ve önceki katmanlarda özellik haritasında ifade edilen özellikleri birleştirmek için tasarlanmıştır. Bu şekilde havuzlama, özellik gösterimlerini sıkıştırmak veya genelleştirmek için bir teknik olarak düşünülebilir ve genellikle eğitim verilerinin modele göre aşırı öğrenmesini azaltmaktadır. Şekil 2-14 üzerinde bir havuzlama işlemi örneği görülmektedir. Çeşitli havuzlama yöntemleri vardır. Yaygın olarak kullanılan havuzlama yöntemi maksimum havuzlamadır. Şekilde renkli olarak işaretlenen pencerelerin içerikleri sağ tarafa taşınırken maksimum havuzlamanın bir özelliği olarak pencere içerisinde yer alan en büyük değer taşınmıştır. Böylece boyut küçültülürken aynı zamanda istenen özellikler de muhafaza edilmektedir.



Şekil 2-14 Havuzlama örneği.


Evrişim işlemleri tamamlandıktan sonra tam bağlı katmanlara yani YSA'ya vermeden önce bir düzleştirme işlemi yapılarak bütün filtrelerin sonuçları birleştirilmektedir. Şekil 2-15 üzerinde solda yer alan matris sağdaki gibi bir vektöre dönüştürülmüştür.

Havuzlanmış Özellik Haritaları




Şekil 2-15 Havuzlama işlemi örneği.

ESA'nın en son adımı olan YSA'yı oluşturan tam bağı katmanlar genellikle normal düz ileri beslemeli bir YSA modelidir. Bir giriş katmanı, bir çıkış katmanı ve ihtiyaç kadar da gizli katmandan meydana gelir. Bu katmanlar, sınıf tahminlerinin olasılığını çıkarmak için doğrusal olmayan bir aktivasyon fonksiyonuna sahip olabilir. Bu katmanlar, evrişimli katmanlar ve havuz katmanları tarafından gerçekleştirilen öznetelik çıkarımı ve birleştirme işlemlerinden sonra ağın sonunda ağ için tahmin yapmak ve özelliklerin doğrusal olmayan birleşimlerini oluşturmak için kullanılırlar [65]. Şekil 2-15 üzerinde bir tam bağı katman örneği görülmektedir.



Şekil 2-15 Tam bağı katman örneği


Geliştiren modelde aşırı öğrenme olmaması için çeşitli yöntemler geliştirilmiştir. Güncel çalışmalarda yer alan aşırı öğrenmeyi engelleme yöntemi dropout yöntemidir. Dropout ile bir YSA üzerinde her bir eğitim sırasında belli düğümler yokmuş gibi davranılarak yapısında geçici bir farklılık oluşturulur. Böylece ağın her seferinde aynı şekilde öğrenmesinin önüne geçilir. Bu yöntemin başarılı sonuçlar vermesi sayesinde hemen hemen her ESA modelinde dropout işlemi kullanılmaktadır. Bu oran genellikle 0.2-0.5 arasında olmaktadır. Şekil 2-16 üzerinde dropout işlemi görülmektedir.



Şekil 2-16 Dropout örneği.


2. 7. 2. Tekrarlı sinir ağları

Tekrarlı sinir ağı, bir hücrenin sadece mevcut girişini değil aynı zamanda önceki durumunu da göz önünde bulunduran bir (evrişimli sinir ağı) ESA çeşididir. Tekrarlı sinir ağı (TSA) bir denetimli makine öğrenme çeşididir ve bir veya birden fazla geri besleme döngüsüne sahip olan nöronlardan oluşmaktadır [66]. Geri besleme döngülerinde çıkışlar daha önceki katmanlara girişi olacak biçimde bağlanır. Şekil 2-17’da bir TSA’nın en basit hali gösterilmektedir.



Şekil 2-17 Tekrarlı sinir ağının basit gösterimi.

Basit bir TSA, Şekil 2-17’de de gösterildiği gibi üç katmana sahiptir. Bunlar giriş, saklı tekrarlı katman ve çıkış katmanlarıdır.



Şekil 2-18 t zamanı boyunca tekrarlı sinir ağının gösterimi.

Şekil 2-18’de giriş katmanı N tane elemana sahiptir. Bu katmana $\{..., X_{t-1}, X_t, X_{t+1}, ...\}$ gibi gönderilen girişler, $X_t = (x_1, x_2, ..., x_N)$ gibi bir vektör dizisidir. Gizli katman, t zamanı boyunca tekrarlı bağlantılarla birbirine bağlanmış $h_t = \{h_1, h_2, h_3, ..., h_m\}$ M elemana sahiptir. W_x giriş, W_y ise çıkış katmanının ağırlık vektörleridir. $Y_t = \{y_1, y_2, y_3, ..., y_P\}$ P elemana sahip çıkış vektörüdür. Gizli birimlerin sıfıra yakın küçük değerlerle başlatılması, ağırlık kararlılığını ve genel performansını artırabilir.

Gizli katman, sistemin durum alanını veya “hafızasını” Denklem 12’deki şekilde tanımlar:

$$h_t = f_{H(o_t)} \quad (12)$$

Burada o_t

$$o_t = W_x X_t + W_s h_{t-1} + b_h \quad (13)$$

Denklem 12’de f_H gizli katman aktivasyon fonksiyonu, b_h gizli katmanın bayes (önyargı) vektörüdür. Saklı katmandaki nöronlar W_s ağırlık vektörü ile çıkış katmanına bağlıdır. Çıkış katmanı, Denklem 14’deki şekilde hesaplanan $Y_t = \{y_1, y_2, y_3, ..., y_P\}$, P elemana sahiptir.

$$Y_t = f_o(W_y h_t + b_o) \quad (14)$$

Denklem 14’te f_o çıkış katmanının aktivasyon fonksiyonu ve b_o da çıkış katmanının bayes vektörüdür. Girdi-hedef çiftleri zaman içinde sıralı olduklarından, yukarıdaki adımlar sonuçta $t = (1, ..., T)$ zamanlarında tekrarlanır. Denklem 12 ve Denklem 14, bir TSA’nın zaman içinde yinelenen belirli doğrusal olmayan durum denklemlerinden oluştuğunu göstermektedir. Her bir zaman adımında gizli katmanda yer alan nöronlar girdi vektörlerine göre çıktı katmanında bir tahmin sağlar. Bir TSA’nın gizli durumu, herhangi bir dış faktörün etkisinden ayrı olarak, ağırlık geçmiş durumları hakkında zaman aşımına uğrayan tüm gerekli bilgileri özetleyen bir değerler kümesidir [67].

Uzun kısa dönem bellek: Tekrarlayan bağlantılar, birbirini takip eden olayları anlama yeteneklerini geliştirerek sinir ağlarının performansını iyileştirmiştir. Tekrarlayan

bağlantılardan elde edilen bellek, TSA'ların eğitimi için kullanılan algoritmalar ile eğitilebilir. Günümüze kadar TSA'lardaki tüm modeller eğitim sırasında kaybolan gradyan sorunu nedeniyle başarısız olmuşlardır bu durum ağıın veriden uzun süreli bağımlılıkları öğrenememesine neden olmuştur.


Uzun kısa dönem bellek (UKDB), kaybolan gradyanların etkilerini azaltmak için kullanılan yöntemlerden biridir [68]. UKDB, gizli katmanlarda yer alan nöronların giriş ve çıkışlarını kontrol eden kapılar sigmoid ya da tanh gibi fonksiyonlardan hafıza hücrelerine değiştirerek gizli katmandaki nöronların bilgi akışını kontrol ederler ve önceki zaman adımlarında öğrenilen özellikleri de saklarlar [67, 68]. Sürekli bir dizilim için, UKDB modelinin dâhili değerlerinin sınırlama olmaksızın büyüyebileceği gösterilmiştir. Sürekli sekanslar doğal olarak tekrar eden özelliklere sahip olsalar bile, ağıın hangi bilgilerin artık alakalı olmadığını saptaması mümkün değildir. Unutma kapısı, bellek hücresinde depolanan değerin tutulmasını ya da unutulmasını sağlayan ağırlıkların öğrenilmesini sağlar [69]. Giriş ve çıkış kapılarının aktif olmadığı ve unutma kapısının da aktif edilmediği durumlarda bellek hücresi durumunu değiştirmez ve böylece diğer zaman adımlarında da geriyayılım esnasında hatanın gradyanı sabit kalır [67]. Bu yapı sayesinde ağı uzun süre boyunca bilgileri tutma potansiyeline sahip oluyor.

UKDB, gizli katmanda daha fazla parametreye sahip olduğundan karmaşıktır. Aynı gizli katmana sayısına sahip basit bir UKDB ile basit bir TSA karşılaştırıldığında, UKDB'nin 4 kat daha fazla parametreye sahip olduğu görülmektedir [66]. UKDB yönteminin amacı, minimal veya en uygun düzeni bulmaktan ziyade, uzun vadeli bağımlılıkları öğrenmeyi geliştirebilecek bir yapı oluşturmaktır [66, 67].

Çeşitli UKDB modelleri vardır. Çok boyutlu ve ızgara UKDB ağıları, uzun süreli bağımlılıkları basit bir UKDB ağına göre daha iyi öğrenebilir.

Standart UKDB; tipik bir UKDB hücresi, giriş, unutma ve çıkış kapılarından ve bir hücre aktivasyonundan oluşur. Şekil 2-19'da basit bir UKDB hafıza bloğu görülmektedir. UKDB birimleri diğer birimlerden gelen verileri çoğaltır. Çoğaltma işlemi gelen verinin birimlere girişine ve çıkışına izin vermek ya da reddetmek için kullanılan bir işlemdir. Bu işlemde UKDB birimleri sigmoid ya da tanh gibi lojistik fonksiyonları kullanarak 0 ile 1 arasında bir değer hesaplarlar. UKDB birimlerinin hiçbirinin aktif edilmediği durumda hafıza bloğunun geçitleri, tekrar eden diğer zaman dilimlerinde de veriyi değiştirmeden

tutabilirler Bu durum tekrar eden bir dizi zaman aralığında karmaşık ve ayrık bağımlılıklarla verilerin işlenmesini ve verilerin mükemmelleştirilmesini sağlar [70].



Şekil 2-19 Bir hücreli UKDB hafıza bloğu.

Paylaşımlı UKDB; UKDB iç mekaniği ağın daha uzun dizi korelasyonunu öğrenmesine yardımcı olurken, bir sekanstan daha karmaşık girişleri anlamakta başarısız olabilir. Paylaşımlı UKDB (P-UKDB) modeli, kaybolan gradyan sorunu çözmek ve daha uzun süreli bağımlılıkları öğrenmeyi sağlamak için tasarlanmıştır. Bir P-UKDB ağı, P-UKDB bellek bloklarında yer alan giriş ve çıkış kapılarından oluşur ve hiyerarşik bir yapıya sahiptir [69, 70]. Şekil 2-20'de sunulan ağ yapısında, zaman dilimleri sırasında alt hücrelerin hafızası tekrarlanarak bir hafıza hücresine yansıtılmaktadır. Şekil 2-20, köke yakın kapıların gradyanların kaybolma probleminden (daha koyu daire) daha az etkilenirken, daha düşük seviyedeki ağaçlardaki dallar gradyanların kaybolması probleminden (açık renkli daireler) dolayı hafızasını kaybeder. Şekil 2-20'deki gibi bir kısa çizgi kullanarak alt dallardan sinyal almaması için bir kapı kapatılabilir. Bir ağaç düğümü birden fazla kendine bağlı hücrelerden gelen bilgileri dikkate alabilir. Beyaz

Yığılmış UKDB; Yapay sinir ağlarındaki derinlik fikri, ağ kapasitesini artırmak için uzayda UKDB hücreli farklı gizli katmanları istifleyerek UKDB'lere de uygulanabilir. Yığılmış UKDB (Y-UKDB)'de, bir yığın işaretçisi, UKDB 'deki hangi hücrenin önceki bir zaman adımının durum ve bellek hücrelerini sağladığını belirleyebilir [71]. Böyle bir kontrollü yapıda, sadece denetçi yığının sabit bir zamanda tepesine itip çıkarabildiği gibi, aynı zamanda bir UKDB yığın içeriğinin sürekli olarak gömülü bir alanını koruyabilir [72].

Çift Yönlü UKDB; Derin çift yönlü UKDB (ÇY-UKDB) olarak adlandırılan yapı UKDB hücrelerinin gizli katmanlarının arka arka bağlanarak oluşturulmuş şeklidir. Bu yöntemle çift yönlü TSA'ların kapasitesini artırmak mümkündür [72]. Tek yönlü UKDB ağları ile

ÇY-UKDB ağlarını karşılaştırdığımızda, tek yönlü UKDB ağlarına göre daha güçlüdür [74]. Bu ağlar hesaplama esnasında tüm girdi dizilerinin verisini içerir. ÇY-UKDB dağıtık gösterim özelliği, doğal dil işleme gibi farklı uygulamalar için çok önemlidir [75]. ÇY-UKDB modeli, aynı zamanda kaybolan gradyan probleminin de üstesinden gelir. Giriş dizisinin geçmiş ve gelecekteki doğrusal ilişkisini diğer UKDB ağlarına göre daha iyi yakalar ancak çift yönlü öğrenme nedeniyle UKDB ile karşılaştırıldığında hesaplama karmaşıklığını arttırması bir dezavantajdır.

Çok Boyutlu UKDB; Klasik UKDB modeli, tek bir unutma kapısı üzerinden tekil bağlantı yoluyla kendine dönen bir yapıya sahiptir. Aktivasyon işlemi basit bir UKDB ağındaki gibidir. Çok Boyutlu UKDB (ÇB-UKDB), farklı boyutlarında yer alan tipik UKDB hafıza bloklarını önceki duruma bağlayarak ağ genişletilmiştir [76]. ÇB-UKDB, girişleri N boyutlu bir biçimde alır. Gizli durum vektörleri ve bellek vektörleri, her boyut için önceki durumdan ÇB-UKDB dizisinin girişine gönderilir [70]. ÇB-UKDB yapısından dolayı çok boyutlu dizileri kolayca modelleyebilir. ÇB-UKDB sahip olduğu çoklu gizli durum vektörleri, basit UKDB ağına göre daha fazla hesaplama gerektirir bu durum yüksek hafıza gereksinimi anlamına gelir. Ağın boyutu ve derinliği arttıkça kararsızlığı da artar.

Izgara UKDB; ÇB-UKDB modeli, alandaki ızgara boyutu ve UKDB derinliği arttıkça kararsız hale gelir. Izgara UKDB modeli bu probleme çıkış vektörlerinin hesaplanma yöntemlerini değiştirerek bir çözüm sunar. Izgara UKDB’de basit bir LSTM modelinde yer alan bloklar bir derinlik boyunca genişletilir ve bu katmanlar arasında birleştirilirler [70]. Artan ızgara büyüklüğüne sahip çok boyutlu dizileri kolayca modelleyebilir. Çoklu tekrarlayan bağlantılar nedeniyle UKDB’den daha fazla hesaplama karmaşıklığına sebep olur ve yüksek hafıza gereksinimine ihtiyaç duyar.

2. 8. Değerlendirme metrikleri

Kullanılan yapay zekâ algoritmasının yaptığı işin performansı bir takım metrikler kullanarak ölçülmektedir. Sonuçların doğru yorumlanabilmesi için uygun metriklerin seçilmesi önemlidir. Hem eğitim aşamasında hem de test aşamasında üretilen sonuçlar için bu metrikler hesaplanır [77].

Literatürde yer alan değerlendirme metrikleri eşik, olasılık ve sıralama olmak üzere üç gruba ayrılmaktadır. Her metriğin kullanım amacı ve yorumlanma şekli farklıdır. Ölçüm metrikleri ağın performansını tek bir skalar puan değeri kullanarak ifade ederler. Bu sayede modellerin karşılaştırılması ve duruma göre mevcut modelde iyileştirme yapılması mümkün olmaktadır. Eşik ve sıralama metrikleri yapay zekâ modellerinin performanslarını ölçmede araştırmacıların en sık kullandıkları metriklerdir [78]. Eşik tipi metriklerden birisi karışıklık matrisidir. Tablo 2-3’de karışıklık matrisinin yapısı görülmektedir.

Tablo 2-3 İkili sınıflandırma problemi için kullanılan karışıklık matrisi yapısı

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

Tablo 2-3’e göre DP ve DN sırasıyla doğru sınıflandırılan pozitif ve negatif örneklerin sayısını, YP ve YN, sırasıyla yanlış sınıflandırılan negatif ve pozitif örneklerin sayısını belirtir. Karışıklık matrisi çoklu sınıflandırma problemlerinde de başka metriklerle beraber kullanılır [78, 79].

Literatürdeki çalışmalarda [79] gösterildiği gibi, ikili veya çok sınıflı sınıflandırma problemleri için pratikte en çok kullanılan değerlendirme ölçütü doğruluktur.

Doğruluk, birçok araştırmacı tarafından sınıflandırıcıların genelleme performansını değerlendirmek için kullanılan uygulamada en yaygın metriklerden biridir. Doğruluk, eğitilmiş olan ağın yeni veriler ile test edilmesi sonucunda doğru şekilde tahmin edilen örneklerin toplam örnek sayısına oranıdır.

Doğruluk metriği çok sınıflı ve çok etiketli problemlerin ölçülmesinde kolay anlaşılır bir sonuç göstermektedir. Ancak bu metriğin dengesiz veya az sayıda veri içeren verisetlerinde tek başlarına kullanılmaları yeterli değildir. Bu nedenle diğer metriklere bakılması gerekir. Tablo 2-4’de bu metrikler açıklamalarıyla yer almaktadır. Tablo 2-4 de yer alan son metrikler çok sınıflı problemlerde sıklıkla kullanılmaktadır [80].

Tablo 2-4 Yapay zekâ algoritmalarında kullanılan değerlendirme metrikleri

Metrik	Formülü	Açıklama
Doğruluk	$\frac{DT+DN}{DP+YN+YP+DN}$	Doğruluk, doğru olarak tahmin edilen örneklerin sayısını toplam örnek sayısına oranlar.
Hassasiyet	$\frac{DP}{DP+YN}$	Hassasiyet, doğru tahmin edilen örnek sayısının oranını ölçmek için kullanılır.
Kesinlik	$\frac{DP}{DP+YP}$	Kesinlik, doğru tahmin edilen pozitif örnek sayılarının toplam pozitif örnek sayısına oranı ölçmek için kullanılır.
Özgüllük	$\frac{DN}{DN+YP}$	Özgüllük, doğru şekilde sınıflandırılan negatif örnek sayısının oranını ölçmek için kullanılır.
F1 Skorlama	$2 \times \frac{(\text{Hassasiyet} \times \text{Kesinlik})}{\text{Hassasiyet} + \text{Kesinlik}}$	F1 skorlama hassasiyet ile kesinliğin harmonik ortalaması olarak bulunur.

Cohen's Kappa Analizi: Yapay zekâ algoritmalarında çok sınıflı bir sınıflandırma işleminde doğruluk, hassasiyet, kesinlik ve özgüllük metrikleri işlemin performansını ifade etmekte yetersiz kalabilmektedir. Bu durumda F1 skorlama kullanılmaktadır. Bununla birlikte tutarlılığı ve uyumu görmek amacıyla Cohen's Kappa Analizi kullanılır. Bu analiz sayesinde Kappa katsayısı elde edilir. Cohen's Kappa formülü Denklem 15'de verilmiştir.

$$\kappa = \frac{P_o - P_e}{1 - P_e} = 1 - \frac{1 - P_o}{1 - P_e} \quad (15)$$

Denklemden P_o ölçülen sonucu, P_e ise beklenen sonucu ifade etmektedir. Denklemden elde edilecek katsayı 0-1 aralığında bir uyum değeri gösterir ya da 0'dan küçük sonuçlar vererek uyumsuzluğu gösterir. Katsayıların yorumlanması Tablo 2-5'e göre yapılmaktadır [81].

Tablo 2-5 Kappa katsayısına göre uyum değeriendirilmesi.

Kappa Katsayısı	Anlamı
<0.00	Uyum yok
0.0 – 0.20	Önemsiz derecede uyum
0.21 – 0.40	Minimal uyum
0.41 - 0.60	Orta derecede uyum
0.61 – 0.80	Önemli derecede uyum
0.81 - 1	Neredeyse mükemmel uyum

2. 9. Model doğrulamayöntemleri

Sınıflandırma yapan bir yapay zekâ algoritmasının daha önce öğrendiği verilerle başarımı test edilmeye çalışıldığında sistemin başarımı çok yüksek çıkacaktır. Ancak algoritmanın bilinmeyen verilerle sınıflandırma yapması istendiğinde çoğu veriyi doğru sınıflandıramadığı görülecektir. Bu duruma aşırı öğrenme denir [82]. Bu durumdan kaçınmanın bir yolu eğitim verisi ile test verisini birbirinden ayırmaktır. Bir algoritmanın doğruluğunu belirlemek için kullanılan farklı yöntemler vardır. Literatürde alandaki çalışmalar incelendiğinde k katlamalı çapraz doğrulamanın başarımının yüksek olduğu görülmektedir[83]

K-katlamalı çapraz doğrulamada, veriseti k adet alt veri kümesine bölünür ve her bir veri kümesi k adet tekrarlanır. K adet tekrarlanan bu işlemin her bir tekrarında k adet veri test için k-1 adet veri eğitim için kullanılır. İşlemin her bir k adımında bir hata değeri hesaplanır ve sonradan bu hataların ortalaması alınarak ortalama hata değeri hesaplanır. Bu yöntemde verilerin hangi şekilde bölündüğü çok önemli değildir. Çünkü her bir bölüt bir defa test aşamasına k-1 kez defa da eğitim kümesine sokulur. Bu yöntemin avantajı her bir test kümesinin büyüklüğü ve tekrarlama sayısının bağımsız olarak seçebilmesidir. Eğitim aşamasının k defa tekrar edilmesi değerlendirme işlemi için k kere kadar hesaplama yapılması anlamına gelir bu durum da işlemin maliyetini artırır [84]. Şekil 2.21’de k-katlamalı çapraz doğrulama işlemi görülmektedir.

3. DERİN ÖĞRENME İLE UYKU EVRELEMESİ VE UYKU HASTALIKLARI TESPİTİ

Uyku evreleme sürecini otomatikleştirme çalışmaları 1960'ların sonlarında bilgisayar tabanlı analizin erken döneminde başlamıştır [85]. Son yıllarda derin öğrenme alanındaki çalışmalarda yer alan gelişmeler sonucunda özellikle biyolojik sinyallerin derin öğrenme yöntemleri ile işlenmesi alanında çalışmalar artmıştır. Bu bölüm altında uyku ile ilgili bozuklukların tespit edilmesinde standart haline gelen uyku evrelemesi işlemi otomatik olarak yapabilen girişleri tek boyutlu olan bir ESA modeli sunulmaktadır. Uyku evrelerinden hipnogram grafikleri oluşturularak tek bir katılımcının uyku kaydının evreleri görselleştirilmiştir. Bu bölüm altında ayrıca uyku apnesi, hipoapne, OSA, SUA gibi uyku hastalıklarının tespiti için geliştirilen girişleri tek boyutlu bir matris olarak alabilen bir ESA modeli de açıklanmaktadır.

3. 1. Deney ortamı

Derin öğrenme modellerinin eğitiminde ve çalıştırılmasında kullanılan çeşitli platformlar vardır. Son yıllarda Python programlama dili en fazla tercih edilen dil olmuştur. Bu sayede Python dili ile geliştirilmiş çeşitli programlama çatıları ve kütüphaneler ortaya çıkmıştır. Aynı zamanda Python ile derin öğrenme yapma üzerine topluluklar oluşmuş, ek kütüphaneler yazılmış ve soru cevap web siteleri, bloglar üretilmiştir. Bu tez çalışmasında geliştirilen modeller de Python dilinin 3.6 sürümü kullanılarak kodlanmıştır. Derin öğrenme algoritmaları yapay sinir ağları ve geleneksel makine öğrenmesi algoritmalarına göre çok daha büyük veri kümeleri çalışabilmekte ve çok daha fazla donanım kaynağı tüketmektedir. Bunun için çeşitli kütüphaneler geliştirilmiştir.

Google tarafından geliştirilen Tensorflow Kütüphanesi bu alanda kullanılan en yaygın kütüphanelerden biridir. Bu çalışmada da Tensorflow kütüphanesinin 2.1 sürümü kullanılmıştır. Tensorflow ölçeklenebilir ve dağıtık çalışabilir bir derin öğrenme kütüphanesidir. Birçok donanım platformunda çalışabilmekte ve grafiksel işlemciler üzerinde de işleri dağıtabilmektedir. Bu sayede tek bir bilgisayar platformunda haftalarca sürecek işlemler bulut ortamında CPU ya da GPU'lara dağıtılarak saatlerle ifade edilebilir sürelerde tamamlanabilmektedir. Data işlenirken tensor adı verilen çok boyutlu matrislerle ifade edilir ve düğümlerden oluşan işlem grafları tanımlanır.

Tensorflow ile tensorların tanımlanması, oturum ve akışların organize edilmesi işlerini kolaylaştırmak ve daha okunabilir bir soyutlama sağlamak için topluluk tarafından geliştirilen Keras kütüphanesi zamanla Tensorflow'un bir parçası haline gelmiştir. Her ne kadar birçok dağıtık algoritmayı soyutlamak için yazılmış olsa da Keras zamanla Tensorflow ile algoritma geliştirmenin de-facto standardı haline gelmiştir.

Derin öğrenme algoritmalarının çalıştırılması için kişisel bilgisayarlar yeterli olmamaktadır. Bunun için güçlü donanımsal özelliklere sahip sunucular ve grafiksel işlemcilerle donatılmış özel bilgisayar platformları kullanılmaktadır. Bu donanımlara erişim imkânı olmayan durumlarda bulut sağlayıcılardan saatlik kiralama yöntemi ile istenen özelliklerde sanal sunucular kiralayıp bu işlemleri yapmak mümkün olmaktadır. Bu tez çalışmasında geliştirilen modellerin eğitimi işlemi için Google Cloud ortamında 15GB disk, 32GB bellek ve 16 çekirdek işlemcili sanal makineler kullanılmıştır. Deneyler Ubuntu 18.0.4 LTS platformu üzerinde gerçekleştirilmiştir.

3. 2. Uyku veriseti

Bu araştırmada kullanılan EEG sinyalleri PhysioNet'te açık olarak yayınlanan polisomnografik veritabanı MIT-BIH'den [86] alınmıştır. Katılımcılar, Boston'daki Beth Israel Hospital Uyku Laboratuvarı'nda solunum bozukluklarından kaynaklanan kronik obstrüktif uyku apne sendromunun değerlendirilmesi için kayıt altına alınmıştır. Veritabanında, dört, altı ve yedi kanallı polisomnografik kayıtlar her biri uyku evresine ve apneye göre açıklamalı EEG, EKG ve solunum sinyalleri içeren 80 saatin üzerinde değer bulunmaktadır. Veritabanında farklı derecelerde uyku apnesine sahip 32-56 yaşları arasındaki 16 erkek deneğe ait 8 adet tüm gece polisomnografik uyku kaydı bulunmaktadır. Her bir kayıta 250 Hz frekansında örneklenmiş bir EEG sinyali, EKG sinyali, bir solunum sinyali ve invazif bir kan basıncı sinyali yer almaktadır. Bu 18 kaydın her biri 4 farklı türde dosya içermektedir. Dosyaların uzantıları ve açıklamaları Tablo 3-1'de gösterilmektedir.

Tablo 3-1 Uyku verisetinde yer alan dosyaların uzantıları ve açıklamaları

Dosya Uzantı Türü	Açıklama
.st	Uyku / Apne açıklamaları
.ecg	Kalp ritim açıklamaları
.dat	Sinyaller
.hea	Başlık dosyaları

st uzantılı dosyaların içindeki uyku evresi ve uyku apnesi gibi açıklamaların tamamı aux alanında yer almaktadır. st uzantılı dosyalardaki her bir açıklama notu, açıklama notunu takip eden kaydın otuz saniyesine uygulanır. Aux alanındaki kodlama ve açıklama bilgileri Tablo 3-2’de yer almaktadır.

Tablo 3-2 Aux alanında yer alan açıklamalara karşılık gelen kodlar.

Aux Alanında Yer Alan Kodlar	Açıklama
W	Uyanıklık
1	Uyku evresi 1
2	Uyku evresi 2
3	Uyku evresi 3
4	Uyku evresi 4
R	REM evresi
H	Hipoapne
HA	Uyarılma ile Hipoapne
OA	Obstrüktif Hipoapne
X	Uyarılma ile Obstrüktif Hipoapne
CA	Santral Uyku Apnesi
CAA	Uyarılma ile Santral Uyku Apnesi
L	Bacak Hareketleri
LA	Uyarılma ile Bacak Hareketleri
A	Belirsiz Uyarılma
MT	Hareket Zamanı

16 deneğin EEG sinyalleri kafa derisi üzerinde aynı bölgelerden alınmamıştır. Burada slp02 kayıtları O2-A1 elektrot çiftinden, slp01, slp32, slp37, slp41 kayıtları C4-A1

elektrot çiftinden, diğer kayıtlar ise C3-O1 elektrot çiftinden gelmektedir. Bu çalışmada sadece EEG kanalı kullanılmıştır.


3. 3. Evrişimli sinir ağı ile uyku evrelemesi

Bu alt bölümde evrişimli sinir ağı ile uyku evrelemesi için geliştirilen tek boyutlu ESA modelinin ağ mimarisi, modelin deney düzeneği, modelin eğitimi, test edilmesi için kullanılan veriseti ve başarımları için kullanılan ölçütler yer almaktadır.

Deneklerin PSG kayıtlarında etiketlenmemiş olarak yer alan epoklar ESA'ya gönderilmeden önce sinyalden çıkarılmıştır. Verisetini dengeli hale getirebilmek ve gereksiz kaynak kullanımını engellemek için uykuya geçilmeden önceki ve uykudan uyandıktan sonraki uyanıklık evreleri sinyalden çıkarılmıştır. AUTA tarafından tavsiye edilen şekilde uyku evreleri W, S1, S2, SWS (S3 ve S4), REM şeklinde etiketlenmiştir, yani S3 ve S4 evreleri SWS olarak birleştirilmiştir.

Bu çalışmada giriş olarak tek kanallı EEG ham sinyali alan ve özellikleri kendisi öğrenen bir ESA modeli kullanılmıştır. Önerilen ESA modeli blok diyagramı Şekil 2'de gösterilmektedir. Aktivasyon fonksiyonu olarak tüm katmanlarda ELU (Üstel Doğrultulmuş Birim) [61] kullanılmıştır.

Oluşturulan ESA modelinde 1 epokluk giriş dizisi, farklı sayılarda filtre ve çekirdeklere sahip 4 evrişimli katman ve her bir evrişim katmanının sonunda aynı boyutta oluşturulan maksimum havuzlama katmanı bulunmaktadır. Evrişim katmanlarının sonunda bir düzleştirici katman ve 25 nörona sahip bir tam bağlı katman ile de sınıflandırma işlemi yapılmaktadır. Tüm evrişimli katmanlara normalizasyon eklenmiştir. Sistemin ezberlemesinin engellenmesi için tüm katmanlara deneyler sonucu bulunan en uygun dropout değeri eklenmiştir.



Şekil 3-1 Otomatik uyku evrelemesi yapan ESA modelinin yapısı.

Tablo 3-3'te model mimarisi, çıktı boyutları ve parametre sayıları detaylı olarak sunulmaktadır. Sıralı yapıda bir model kullanıldığı için bir önceki katmanın çıkışı bir sonraki katmanın girişi olacak şekilde çalışmaktadır.

Tablo 3-3 Otomatik uyku evrelemesi yapan ESA modelinin özellikleri

Katman Tipi	Katmanlar	Çıktı Biçimi	Parametre Sayısı
Evriscim Katmanı_1	Conv1D_1 (Conv1D)	(7500, 40)	3240
	Batch_Normalization_1	(7500, 40)	160
	Activation_1	(7500, 40)	0
	Max_Pooling1d_1	(7500, 40)	0
	Dropout_1	(750,40)	0
Evriscim Katmanı_2	Conv1D_2(Conv1D)	(750, 60)	48060
	Batch_Normalization_2	(750, 60)	240
	Activation_2	(750, 60)	0
	Max_Pooling1d_2	(150,60)	0
	Dropout_2	(150,60)	0
Evriscim Katmanı_3	Conv1D_3(Conv1D)	(150,80)	48080
	Batch_Normalization_3	(150,80)	320
	Activation_3	(150,80)	0
	Max_Pooling1d_3	(30,80)	0
	Dropout_3	(30, 80)	0
Evriscim Katmanı_4	Conv1D_4(Conv1D)	(30,100)	32100
	Batch_Normalization_4	(30, 100)	400
	Activation_4	(30,100)	0
	Max_Pooling1d_4	(6,100)	0
	Dropout_4	(6, 100)	0
Düzleştirici Katman	Flatten_1	(600)	0
	Dense_1 (Dense)	(50)	30050
	Dropout_5	(50)	0
Çıkış Katmanı	Dense_2(Dense)	(5)	255


ESA modeli 5 katlamalı çapraz doğrulama kullanılarak verinin %80'i eğitim, %20'si test olacak şekilde ayrılmıştır. Çapraz doğrulama kullanıldığı için test setinde yer alan epoklar her bir katlamada rastgele seçilmiş ve böylece her katlamada farklı verilerle test işlemi yapılmıştır.

Sistemin ezberlemesini engellemek için kullanılan dropout değerleri tüm katmanlarda 0.3 olarak kullanılmıştır. 5 epok boyunca doğrulama setinde hiç iyileşme olmazsa eğitim durdurulmuştur. Eğitim tamamlandıktan sonra çıkışlar 5'li olarak sınıflandırılmıştır. Bu sınıflar REM, S1, S2, SWS ve W şeklindedir.

3. 4. Evriřimli sinir ađı ile uyku hastalıklarının tespiti


Bu alt bölümde evriřimli sinir ađı ile uyku hastalıklarının tespiti amacıyla geliřtirilen tek boyutlu ESA modelinin ađ mimarisi, modelin kurulumundaki deney düzeneđi, modelin eđitimi, test edilmesi için kullanılan veriseti ve bařarım için kullanılan ölçütler sunulmaktadır.

Bir katılımcıdan alınan uyku hastalığı belirtisi görülmeyen Uyanıklık(W) evresindeki 1 epokluk (30sn) 250 Hz, EEG dalga formu Şekil 3-2’de gösterilmektedir. Yatay eksen zaman(sn) olarak, dikey eksen dalganın genliğini göstermektedir.




Şekil 3-2 Hastalık belirtisi bulunmayan W(Uyanıklık) evresi.

Bir katılımcıdan alınan uyku hastalığı belirtisi görülmeyen REM uyku evresindeki 1 epokluk (30sn) 250 Hz, EEG dalga formu Şekil 3-3’te gösterilmektedir.




Şekil 3-3. Hastalık belirtisi bulunmayan EEG kaydı. REM uyku evresi.

Bir katılımcıdan alınan uyku hastalığı belirtisi görülmeyen S1 uyku evresindeki 1 epokluk (30sn) 250 Hz, EEG dalga formu Şekil 3-4’de gösterilmektedir.




Şekil 3-4. Hastalık belirtisi bulunmayan EEG kaydı. S1 uyku evresi.

Bir katılımcıdan alınan uyku hastalığı belirtisi görülmeyen S2 uyku evresindeki 1 epokluk (30sn) 250 Hz, EEG dalga formu Şekil 3-5’de gösterilmektedir




Şekil 3-5. Hastalık belirtisi bulunmayan EEG kaydı. S2 uyku evresi.

Bir katılımcıdan alınan uyku hastalığı belirtisi görülmeyen SWS uyku evresindeki 1 epokluk (30sn) 250 Hz, EEG dalga formu Şekil 3-6’da gösterilmektedir




Şekil 3-6. Hastalık belirtisi bulunmayan EEG kaydı. SWS uyku evresi.

Bir katılımcıdan alınan ve uyku hastalığı belirtisi (Hipoapne) gösteren 1 epokluk (30sn) EEG dalga formu Şekil 3-7’de gösterilmiştir.




Şekil 3-7. Hipoapne belirtisi bulunan bir EEG sinyali. S2 uyku evresi.

Bir katılımcıdan alınan ve uyku hastalığı belirtisi (Obstrüktif Hipoapne) gösteren 1 epokluk (30sn) EEG dalga formu Şekil 3-8’de gösterilmiştir.



Şekil 3-8. Obstrüktif Hipoapne belirtisi bulunan bir EEG sinyali. S2 uyku evresi


Bir katılımcıdan alınan ve uyku hastalığı belirtisi SUA gösteren 1 epokluk (30sn) EEG dalga formu Şekil 3-9’da gösterilmiştir.



Şekil 3-9. Santral Uyku Apnesi belirtisi bulunan bir EEG sinyali. S2 uyku evresi

Bazı klinik raporlar uyku EEG dalga formlarının UAS ile dalgalanacağını göstermiştir [87] Ayrıca, [88] 'de bildirildiği gibi, uyku apnesi sona erdiğinde EEG aktivitesinin delta dalgasından teta ve alfa dalgalarına (4-14 Hz aralığında) kaydığı EEG sinyalinde ani bir frekans kayması vardır. Uyku hastalıklarının bu şekilde EEG dalgasında değişikliğe yol açıyor olması EEG'ye dayanan uyku hastalığı saptamasını araştırmak için teşvik eden motivasyondur. Derin öğrenme algoritmalarının özellik çıkarımını da otomatik olarak yaptığı göz önüne alınırsa ham EEG verisi üzerinden uyku hastalıklarının tespiti mümkün olacaktır.

Bu tez çalışmasında giriş olarak ham sinyalleri alan ve özellikleri kendisi öğrenen bir ESA modeli kullanılmıştır. ESA modeli Şekil 10.'da gösterilmiştir. Aktivasyon fonksiyonu olarak tüm katmanlarda ELU (Üstel Doğrultulmuş Birim) kullanılmıştır. Oluşturulan ESA modelinde: 1 epok (30sn) 7500 örnekleme alan bir input giriş dizisi, farklı sayılarda filtre ve çekirdeklere sahip 3 Evrişimli katman, her bir evrişim katmanında aynı boyutta oluşturulan maksimum havuzlama katmanı ve 25 nörona sahip bir düzleştirici katman bulunmaktadır. Tüm katmanlara aynı normalizasyon ve dropout değerleri eklenmiştir.



Şekil 3-10 Uyku hastalıklarını tespit etmede kullanılan ESA modeli.

Tablo 3-4'te model mimarisi, çıktı boyutları ve parametre sayıları detaylı olarak sunulmaktadır. Sıralı yapıda bir model kullanıldığı için bir önceki katmanın çıkışı bir sonraki katmanın girişi olacak şekilde çalışmaktadır.

Tablo 3-4 Çalışmada kullanılan ESA modeli ve parametreleri

Katman Tipi	Katmanlar	Çıktı Biçimi	Parametre Sayısı
Evrişim Katmanı-1	Conv1D_1 (Conv1D)	(7421, 20)	1620
	Batch_Normalization_1	(7421, 20)	80
	Activation_1	(7421, 20)	0
	Max_Pooling1d_1	(1480, 20)	0
	Dropout_1	(1784,20)	0
Evrişim Katmanı-2	Conv1D_2(Conv1D)	(1465, 40)	16040
	Batch_Normalization_2	(1465, 40)	160
	Activation_2	(1465, 40)	0
	Max_Pooling1d_2	(293,40)	0
	Dropout_2	(293,40)	0
Evrişim Katmanı-3	Conv1D_3(Conv1D)	(284,60)	24060
	Batch_Normalization_3	(284,60)	240
	Activation_3	(284,60)	0
	Max_Pooling1d_3	(56,60)	0
	Dropout_3	(56, 60)	0
Düzleştirici Katman	Flatten_1	(800)	0
	Dense_1 (Dense)	(25)	20025
	Dropout_5	(25)	0
Çıkış Katmanı	Dense_2(Dense)	(4)	130


Bir ESA modeli 5 katlamalı çapraz doğrulama kullanılarak verinin %80'i eğitim, %20'si test olacak şekilde ayrılmıştır. Dropout değerleri tüm katmanlarda 0.3 olarak kullanılmıştır. Ağın girişi her bir epok için 1 epok (30sn), 250 Hz (7500) örneklemedir. 5 epok boyunca doğrulama setinde hiç iyileşme olmazsa eğitim durdurulmuştur. Eğitim tamamlandıktan sonra çıkış dörtlü olarak sınıflandırılmaktadır. Bu sınıflar: Santral Apne, Obstrüktif Apne, Hipoapne, ve Hastalısız şeklinde seçilmiştir.

4. EVRİŞİMLİ SINIR AĞI İLE TASARLANAN SİSTEMLERİN BAŞARIM DEĞERLENDİRMESİ

Bu bölümde uyku evrelerini derin sinir öğrenme ağları ile otomatik olarak evreleyebilen ve uyku hastalıklarını tespit eden modellerin başarımlarını değerlendirilmeleri sunulmaktadır.


4. 1. Evrişimli sinir ağı ile uyku evreleme başarımları

Uyku evreleme çalışmasında sunulan sisteme ait test sonuçları Şekil 3’de karışıklık matrisi olarak gösterilmektedir. En yüksek doğruluk değeri %99.8 ile SWS evresinde, en düşük doğruluk değeri ise %88.3 ile W evresinde hesaplanmıştır. W evresi en çok S1 evresi ile karıştırılmıştır.



Şekil 4-1 Uyku Evreleme İşlemine Ait Karışıklık Matrisi

Verisetinden örnek olarak seçilen slp59 kaydı için makalede sunulan ESA modeli tarafından uyku evrelemesi yapılarak elde edilen evreler ile elle skorlanmış evrelerin birlikte gösterildiği hipnogram görüntüsü Şekil 4-2’de gösterilmektedir. Turuncu renk ile gösterilen uyku evreleri ESA modeli tarafından, mavi renk ile gösterilen uyku evreleri ise uzmanlar tarafından elle etiketlenmiştir. Evreler yüksek bir oranda birbiri ile örtüşmüştür.



Şekil 4-2 Slp59 verisinin ESA ile otomatikleştirilmiş uyku evreleri hipnogramı.

Modeli test etmede kullanılan değerlendirme ölçeklerine göre başarımlar sonuçları Tablo 4-1’de sunulmaktadır.

Tablo 4-1. Başarımlar sonuçları.

Uyku Evreleri	Kesinlik	Hassasiyet	F1-Skorlama
REM	0.85	0.95	0.90
S1	0.96	0.91	0.93
S2	0.99	1.00	0.99
SWS	0.93	0.97	0.95
W	0.93	0.85	0.89
Makro F1 Skorlama	0.93	0.94	0.93
Doğruluk			0.92

Sunulan modelin literatürde yapılan diğer tek kanallı EEG sinyali kullanılarak yapılan çalışmalarla karşılaştırması Tablo 4-2’de gösterilmiştir. Her bir çalışma için kullanılan veriseti, bu verisetinde kullanılan kanallar ve denek sayıları, evreleme çeşidi, çalışmalar için kullanılan yöntemler ve çalışmaların başarımlar sonuçları tabloda yer almaktadır.


Tablo 4-2 Yapılan çalışmanın literatürdeki diğer çalışmalarla karşılaştırılması

Çalışma	Veriseti	Kanal Seçimi	Denek Sayısı	Evreleme Tipi	Kullanılan Yöntem	Doğruluk	F1-skoru
Sors	SHHS-1	Tek Kanal EEG	5728	R&K	ESA	%87	%87
Tsinalis	Sleep-EDF	Tek Kanal EEG	20	R&K	ESA	%74	%81
Zhang	MIT-BIH	Tek Kanal EEG	16	R&K	Hilbert Huang Dönüşümü, OESA	%88.4	%85.8
Supratak	MASS	Tek Kanal EEG	32	AUTA	ESA UKDB	- %86	%86
Bu çalışma	MIT-BIH	Tek Kanal EEG	16	AUTA	ESA	%92	%93

Makalede sunulan tek kanallı EEG kullanan ESA modelinin hem doğruluk hem de F1-skoru değeri literatürdeki rakiplerine göre yüksek çıkmıştır. Zhang vd. tarafından sunulan çalışmada da MIT-BIH veriseti kullanılmış, sinyaller Hilbert Huang Dönüşümü ile resim işleme aşamasından geçirilmiş olmasına rağmen modelin doğruluk başarımı %88.4'te kalmıştır. Ham EEG sinyalinde dönüştürme işlemleri yapmadan da uygun bir ESA modeli ile daha yüksek başarımlar sonuçları alınabilmektedir.

4. 2. Evrişimli sinir ağı ile uyku hastalıkları tespiti başarımı

Tek kanal EEG kullanıldığında ve çapraz doğrulama yapıldığında ortaya çıkan sonuçlar karışıklık matrisi olarak Şekil 4-3. üzerinde görülmektedir.



Şekil 4-3. Tek Kanal EEG kullanıldığında oluşan karışıklık matrisi

Santral Apne(CA), Obstrüktif Apne(OA), Hipoapne(HA) ve Hastalısız (NA) şeklinde sınıflandırılan verilerle oluşturulan karışıklık matrisine göre CA (%87), OA(%91.5), HA(%75) ve NA(%88) olarak bulunmuştur. Çalışma sonuçlarına göre OA diğerlerine göre daha yüksek doğrulukla bulunmuştur. En düşük doğruluk oranına HA sahiptir ve en çok NA ile karışmıştır.

Tablo 4-3 Başarım sonuçları.

Uyku Evreleri	Kesinlik	Hassasiyet	F1-Skorlama
CA	0.85	0.90	0.86
OA	0.93	0.91	0.90

HA	0.77	0.73	0.75
NA	0.93	0.85	0.88
Makro F1 Skorlama	0.87	0.83	0.85
Doğruluk			0.86

Sunulan modelin literatürde yapılan diğer tek kanallı EEG sinyali kullanılarak yapılan çalışmalarla karşılaştırması Tablo 4-3’de gösterilmiştir. Her bir çalışma için kullanılan veriseti, bu verisetinde kullanılan kanallar ve denek sayıları, evreleme çeşidi, çalışmalar için kullanılan yöntemler ve çalışmaların başarımları sonuçları tabloda yer almaktadır.

Tablo 4-4 Uyku hastalıkları tespit eden çalışmanın literatürdeki diğer çalışmalarla karşılaştırılması.

Çalışma	Veriseti	Kanal Seçimi	Denek Sayısı	Evreleme Tipi	Kullanılan Yöntem	Doğruluk	F1-skoru
Mahmud vd.	ST.Vincent's u.	EEG, EKG, EMG, EOG	5	AUTA	ESA	%81.8	---
Sugi vd.	Toronomon Hospital	EEG, EMG, EKG, EOG	8	AUTA	ESA	%86	----
Biswall	MGH	EEG, EOG, EMG, EKG	10000	AUTA	UKDB	%88.2	----
Bu çalışma	MIT-BIH	Tek Kanal EEG	16	AUTA	ESA	%86.3	%85

5. TARTIŞMA- SONUÇ ve ÖNERİLER

Günümüzde uyku hastalıklarının teşhisi ve uyku kalitesinin değerlendirilmesi uyku teknisyenleri ve nöroloji uzmanları tarafından manuel olarak yapılmaktadır. Polisomnografi (PSG) adı verilen bu sistemde vücudun çeşitli bölgelerine bağlı sensörlerden kaydedilen elektroensefalogram (EEG), elektrokardiyogram (ECG), elektrookülogram (EOG), elektromiyogram (EMG) gibi sinyaller kullanılmaktadır. Bu sistemin ortaya çıkardığı çeşitli zorluklar bulunmaktadır. PSG kayıtları uyku uzmanları tarafından manuel olarak evrenlenmekte, işaretlenmekte ve değerlendirilmektedir. Uyku kliniklerinde yeterli uzman ve yatak bulunmaması nedeniyle talepler karşılanamamaktadır. PSG sistemleri ev kullanımı için uygun olmayan, yalnızca hastane ve laboratuvarlarda kullanılan pahalı ve özel cihazlardır. PSG sinyallerini elde etmek için deneklere bağlanan kablo ve elektrodların sayısı fazladır. Kablo ve elektrod kullanımı ölçümlerde gürültülere ve deneklerin uyku kalitesinin düşmesine sebep olmaktadır. PSG sinyallerinin uyku uzmanları tarafından manuel olarak değerlendirilmesi hem zaman alıcı hem de yorucu bir işlemdir. Bu durum insan faktörüne bağlı olarak uyku kayıtlarının değerlendirilmesi çalışmalarında hataya da neden olabilmektedir. Uyku teknisyenlerinin evreleme tarzında farklılıklar olması etiketledikleri verinin doğruluğunu tartışılır hale getirmektedir.

PSG sisteminin sınırlılıklarından ve problemlerinden dolayı literatürde uyku evreleme ve hastalık tespitini otomatikleştirmeyi hedefleyen birçok yöntem önerilmiştir. Bu yöntemleri elle özellik çıkarımı ve uzman-bilgisi-odaklı kural seti kullanımı, elle özellik çıkarımı ve makine öğrenmesi sınıflandırmasının hibrit kullanımı, otomatik özellik çıkarımı ve sınıflandırma yapabilecek derin öğrenme yöntemlerinin kullanımı şeklinde gruplandırmak mümkündür. Yapay zekâ tabanlı sistemlerin yaygınlaşmasıyla birlikte kural tabanlı yöntemler artık tercih edilmemektedir. Makine öğrenmesi yöntemlerinin uygulandığı sistemlerde algoritma uzmanlar tarafından çıkarılan özelliklerle eğitildiğinden dolayı kullanılan algoritmanın başarımı uzmanlar tarafından elle çıkarılmış olan özelliklerin kalitesine ve veri ön işlemeye bağlıdır. Literatürde son yıllarda sunulan çalışmalarda otomatik özellik çıkarımı yapan derin öğrenme modellerinin kullanımı yaygınlaşmıştır. Bu yöntemlerin avantajı insan etkisi olmaksızın en uygun özellikleri algoritmanın kendi kendine seçebilmesidir. Bu tez çalışmasında da derin öğrenme yöntemlerinden olan Evrişimli Sinir Ağı (ESA) tercih edilmiştir.

Bireysel kullanım için üretilen uygun fiyatlı giyilebilir EEG cihazlarının üretilmesi ile tek kanallı EEG sinyalinin uyku evreleri tespiti yapılabilmesi için çalışmalar başlamıştır. Uyku hastalıkları, beyin fonksiyon bozuklukları ile ilişkili olduğundan EEG sinyali uyku ile uyku rahatsızlıklarının tespitinde de kullanılmaktadır. Uyku hastalıklarının da tek kanallı EEG sinyalinin kabul edilebilir bir doğruluk oranında tespit edilebilmesi ile bireylerin çok daha erken tedaviye başlamasının yolu açılacaktır. Bu tez çalışmasında tek kanallı ham EEG sinyali kullanarak uyku evrelemesi yapan ve uyku hastalıklarını tespit eden otomatik bir sistem sunulmaktadır. Bu amaçla ham EEG sinyalleri ile Evrişimli Sinir Ağı (ESA) modelleri eğitilmiştir.

Bu çalışmada kullanılan EEG sinyalleri PhysioNet'te açık olarak yayınlanan polisomnografik veritabanı MIT-BIH'den alınmıştır. Denekler, Boston'daki Beth Israel Hospital Uyku Laboratuvarı'nda kronik obstrüktif uyku apne sendromunun değerlendirilmesi için izlenmiştir. Veritabanında, dört, altı ve yedi kanallı polisomnografik kayıtlar her biri uyku evresine ve uyku apnesine göre açıklamalı EEG, EKG ve solunum sinyalleri içeren 80 saatin üzerinde değer bulunmaktadır. Veritabanında farklı derecelerde uyku apnesine sahip 32-56 yaşları arasındaki 16 erkek deneye ait 80 adet tüm gece polisomnografik uyku kaydı bulunmaktadır. Her kayıta bir EKG sinyali, invazif bir kan basıncı sinyali, bir solunum sinyali ve 250 Hz frekansında örneklenmiş bir EEG sinyali bulunmaktadır.

Bu tez çalışması kapsamında geliştirilen ESA modelleri 30 sn'lik segmentlere bölünmüş EEG verisini 5 sınıflı uyku evrelemesi sistemine göre sınıflandırmakta, Santral Apne(CA), Obstrüktif Apne(OA) ve Hipoapne(HA) rahatsızlıklarını tespit etmektedir. Geliştirilen derin öğrenme modelleri Python programlama dili 3.6 sürümü ile, Keras ve Tensorflow yazılım kütüphaneleri yardımıyla kodlanmış ve deneyler gerçekleştirilmiştir. Modellerin eğitimi için Google Cloud ortamında 15GB disk, 32GB bellek ve 16 çekirdek işlemcili sanal makineler kullanılmıştır. Deneyler Ubuntu 18.0.4 LTS platformu üzerinde gerçekleştirilmiştir.

Yapılan testlerin sonuçlarına göre önerilen sistemin evreleme başarımı %93 makro F1-skoru ve %92 doğruluk olarak bulunmuştur. Uyku hastalıklarını ise %85 makro F1-skoru ve %85 doğrulukla tespit etmektedir. Yapılan çalışma literatürde yer alan güncel çalışmalarla karşılaştırıldığında, önerilen evreleme modelininin başarımı daha yüksektir, hastalık tespiti ise çok kanallı modellerle yaklaşık aynı başarımlara sahiptir.

Bu tezde sunulan çalışma ile çoklu sinyal ölçümüne ve işlenmesine gerek kalmadan giyilebilir cihazlardan bile alınabilen tek kanallı bir EEG sinyalinden uyku kalitesi ölçümü ve uyku bozukluğu olup olmadığını otomatik olarak tespit edebilmektedir. Daha az sayıda fizyolojik sinyal kullanarak otomatik evreleme yapabilen ve uyku hastalıklarını tespit edebilen bu sistem, ev tabanlı sağlık izleme gibi pek çok alanda kullanılabilecektir. Tek kanallı EEG sinyalleri ile bu tez kapsamında yer almayan diğer beyinle ilişkili rahatsızlıklar için de çalışmalar yapılabilir. Literatürde kabul görmüş verisetlerinin tamamına yakını PSG sistemleri ile çok kanallı olarak kaydedilmiş ve işaretlenmiştir, uyku hastalarından tek kanallı ve giyilebilir cihazlar yardımıyla da ölçümler yapıp veriseti oluşturulmasına ihtiyaç vardır. Literatürde yer alan otomatikleştirme çalışmaları tıpta yaygın olarak uygulamaya geçirilememiştir. Bu modellerin uygulamaya geçirilmesi ile uyku kalitesinde yaşanan sıkıntılar ve uyku rahatsızlıkları daha erken tespit edilebilecektir. Ayrıca uygulamalar artınca araştırmacılar için henüz bilinmeyen yeni zorluklar ve çalışma konuları ortaya çıkacaktır.

KAYNAKLAR

- [1] Marcos, JV, Hornero R, and Álvarez D, Automated Detection of Obstructive Sleep Apnoea Syndrome from Oxygen Saturation Recordings Using Linear Discriminant Analysis, *Med. Biol. Eng. Comput*, 48(1) (2010): 895–902.
- [2] Mindell JA, Telefski LS and Wiegand B, A Nightly Bedtime Routine: Impact on Sleep in Young Children and Maternal Mood, *Sleep*, 32(5) (2009): 599–606.
- [3] Silber MH, Ancoli-Israel S, Bonnet MH, Chokroverty S, The Visual Scoring of Sleep in Adults, *Journal of Clinical Sleep Medicine*, 3(1) (2007): 121-131.
- [4] Whitney CW, Gottlieb DJ, Redline S, Norman RG, Reliability of Scoring Respiratory Disturbance Indices and Sleep Staging, *Sleep*, 21(1) (1998): 749-757.
- [5] Aboalayon KA, Faezipour M, Almuhammadi WS, Sleep Stage Classification Using EEG Signal Analysis: A Comprehensive Survey and New Investigation, *Entropy*, 18 (9) (2016): 272-301.
- [6] Cirelli C and Tononi G, (2008): “Is Sleep Essential?”, *PLoS Biology*, 6(8) (2008):1605-1611.
- [7] Lee-Chiong T, *Sleep: A Comprehensive Handbook*, John Wiley and Sons, New Jersey, pp. 169-253, 2005.
- [8] Rasch B ve Born J, About Sleep's Role in Memory, *Physiological Reviews*, 93(2) (2013):681-766
- [9] Campbell S and Tobler I, Animal sleep: A review of Sleep Duration Across Phylogeny, *Neuroscience and Biobehavioral Reviews*, 8(3) (1984):269-300.
- [10] Carskadon MA, Dement WC, Kryger MH, *Normal Human Sleep: An Overview*, Elsevier Saunders, pp. 16-26, 2005.
- [11] Kun-Chan L, Dai-Wei C, Chih-En K and Ming-Zhi W, Using Off-The-Shelf Lossy Compression for Wireless Home Sleep Staging, *Journal of Neuroscience Methods*, 246 (2015): 142-152.
- [12] Álvarez D, Hornero R and Marcos JV, *Spectral Analysis of Electroencephalogram and Oximetric Signals in Obstructive Sleep Apnea Diagnosis*, *31st Annual International Conference of the IEEE*, September 2-6, 2009, Minnesota-USA.

- [13] Natarajan K, Acharya UR, Alias F, Tiboleng T and Puthusserypady SK, Nonlinear Analysis of EEG Signals at Different Mental States, *BioMedical Engineering*, 3(7) (2004): 1-11.
- [14] Ancoli-Israel S, Chesson AL and Quan SF, American Academy of Sleep Medicine Sleep Skoring, pp. 1-60, 2007.
- [15] Mansor W, Shaifulrizal M, Rani A and Nurfatehah W, Integrating Neural Signal and Embedded System for Controlling Small Motor, *Advances in Mechatronics*, pp. 20-77, 2011.
- [16] Estrada E, Nazeran H, Barragan J, BurkFarideh JR and Mikaeili M, EOG and EMG: Two Important Switches in Automatic Sleep Stage Classification, *Proceedings of the 28th IEEE EMBS Annual International Conference*, Aug 30-Sept 3, 2006, New York-USA.
- [17] Rechtschaffen A and Kales A, A manual of standardized terminology, techniques and scoring system for sleep stages of human subjects. Washington, D.C. United States Government Printing Office, pp. 1-53, 1968.
- [18] Şahin L ve Aşçıoğlu M, Uyku ve Uykunun Düzenlenmesi, *Sağlık Bilimleri Dergisi*, 22(1) (2013): 93-98.
- [19] Danker-Hopfe H, Anderer P, Zeitlhofer J and Boeck M, Interrater reliability for sleep scoring according to the Rechtschaffen & Kales and the new AASM standard, *Journal of Sleep Research*, 18 (2009): 74-84.
- [20] Radha M, Garcia-Molina G and Poel M, Comparison of feature and classifier algorithms for online automatic sleep staging based on a single EEG signal, *36th Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, August 23-30, 2014, Chicago- USA
- [21] Fraiwan L, Lweesy K and Khasawneh N, Automated Sleep Stage Identification System Based on Time–Frequency Analysis of a Single EEG Channel and Random Forest Classifier, *Computer Methods and Programs in Biomedicine*, 108 (2012): 10-19.
- [22] Kocha H, Julie AE, .Rune F and Marielle Z, Automatic Sleep Classification Using a Data-Driven Topic Model Reveals Latent Sleep States, *Journal of Neuroscience Methods*, 235 (2014): 130-137.

- [23] Sokolovsky M, Guerrero F, Paisarnsrisomsuk S and Ruiz C, Deep Learning for Automated Feature Discovery and Classification of Sleep Stages, *IEEE/ACM Transactions on Computational Biology and Bioinformatics*, 1 (2019): 1-11.
- [24] Ghimatgara H, Kazemia K, Helfrousha MS and Aarabib A, An Automatic Single-Channel EEG-Based Sleep Stage Scoring Method Based on Hidden Markov Model, *Journal of Neuroscience Methods*, 324 (2019): 270-285.
- [25] Tsinalis O, Matthews PM and Guo Y, Automatic Sleep Stage Scoring Using Time-Frequency Analysis and Stacked Sparse Autoencoders, *Annals of Biomedical Engineering*, 44 (2016): 1587-1597.
- [26] Zhang J, Yao R, Ge W and Gao J, Orthogonal Convolutional Neural Networks for Automatic Sleep Stage Classification Based on Single-Channel EEG, *Transactions of the Institute of Measurement and Control*, 38 (2019): 435-451.
- [27] Sors A, Bonnet S, Mirek S, Vercueil L and Payen J, A Convolutional Neural Network for Sleep Stage Scoring from Raw Single-Channel EEG, *Biomed. Signal Proc. Control*, 42 (2018): 107-114.
- [28] Supratak A, Dong H, Wu C and Guo Y, DeepSleepNet: A Model for Automatic Sleep Stage Scoring Based on Raw Single-Channel EEG, *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 25(11) (2017): 1998-2008.
- [29] Jackson CL, Redline S, Kawachi I, and F. Hu FB, Association Between Sleep Duration and Diabetes in Black and White Adults, *Diabetes Care*, 36 (2013): 3557-3565
- [30] Miller M and Cappuccio F, (2007): Inflammation, Sleep, Obesity and Cardiovascular Disease, *Current Vascular Pharmacology*, 5 (2007): 93-102.
- [31] Franzen PL and Buysse DJ, Sleep in Psychiatric Disorders, in *Sleep Disorders Medicine*, *Sleep Disorder Medicine*, 1 (2017):977-996.
- [32] Jiang D and Ma Y, (2018). A Multi-Scale Parallel Convolutional Neural Network for Automatic Sleep Apnea Detection Using Single Channel EEG Signals. *Image and Signal Processing, BioMedical Engineering and Informatics on 2018 11th International Congress*, October 13-15, 2018, Beijing-China.
- [33] Barkoukis TJ and A. Y. Avidan AY,(2007): Review of Sleep Medicine, Philadelphia, PA: Elsevier 4th Edition pp. 350-402.

- [34] Penzel T, Kantelhardt W and Grote L, Comparison of Detrended Fluctuation Analysis and Spectral Analysis for Heart Rate Variability in Sleep and Sleep Apnea, *IEEE Transactions on Biomedical Engineering*, 50(10) (2003): 1143-1151.
- [35] Arslan Tuncer S, Akilotu B and Toraman S, A Deep Learning-based Decision Support System for Diagnosis of OSAS Using PTT Signals, *Medical Hypotheses*, 127 (2019): 15-22.
- [36] Buettner R, Grimmeisen A and Gotschlich A, High-Performance Diagnosis of Sleep Disorders: A Novel, Accurate and Fast Machine Learning Approach Using Electroencephalographic Data, *Proceedings of the 53rd Hawaii International Conference on System Sciences*, January 07, 2020, Hawaii-USA.
- [37] Wafaa A, Aboalayon K and Faezipour M, Efficient Obstructive Sleep Apnea Classification Based on EEG Signals, *11th IEEE Long Island Systems Conference*, May 1-5, 2015, Farmingdale-USA.
- [38] Uçar MK, Orenc S and Bozkurt MR, Evaluation of the Relationship Between Chronic Obstructive Pulmonary Disease and Photoplethysmography Signal, *Medical Technologies National Congress (TIPTEKNO)*, October 12-14, 2017, Trabzon-Turkey.
- [39] Erdenebaya U, Kim YJ, Jonk-Uk P and Joo EY, Deep Learning Approaches for Automatic Detection of Sleep Apnea, *Computer Methods and Programs in Biomedicine*, 180 (2019): 1-10.
- [40] Chambon S, Thorey V and Arnal PJ, DOSED: A Deep Learning Approach to Detect Multiple Sleep Micro-Events in EEG Signal, *Journal of Neuroscience Methods*, 321 (2019): 64-78.
- [41] Biswall S, Sun H, Goparaju B and Westover MB, Expert-Level Sleep Scoring with Deep Neural Networks, *Journal of the American Medical Informatics Association*, 25(12) (2018): 1643–1650.
- [42] Mahmud T, Ansari AA, Mahmud TI and Khan IA, Real Time Sleep Apnea Event Detection with Deep Neural Network, *IEEE International Conference on Biomedical Engineering, Computer and Information Technology for Health (BECITHCON)*, November 28-30, 2019, Dhaka-Bangladesh.
- [43] Sugi T, Kawana F and Nakamura M, Automatic EEG Arousal Detection for Sleep Apnea Syndrome, *Biomedical Signal Processing and Control*, 4(4) (2009): 329-337.

- [44] McCulloch WS and Pitts W, A Logical Calculus of the Ideas Immanent in Nervous Activity, *The Bulletin of Mathematical Biophysics*, 5 (1943): 115-133.
- [45] Benvenuto N and Piazza F, On the Complex Backpropagation Algorithm, *IEEE Transactions on Signal Processing*, 40(4) (1992): 967-969.
- [46] Hornik K, Approximation Capabilities of Multilayer Feedforward Networks, *Neural Networks*, 4(2) (1991): 251-257.
- [47] Girosi F and Jones M, Regularization Theory and Neural Networks Architectures, *Neural Computation*, 7 (1995): 219-269.
- [48] Srivastata N, Hinton G and Krizhevsky A, Dropout: a Simple Way to Prevent Neural Networks from Overfitting, *The Journal of Machine Learning Research*, 15(1) (2104): 1-15.
- [49] LeCun Y, Bengio Y and Hinton G, Deep learning, *Nature*, 521(7553) (2015): 436–444, [Online], Available: <https://doi.org/10.1038/nature14539>.
- [50] D. L. Elliott, A Better Activation Function for Artificial Neural Networks, 1993. [Online]. Available: <https://drum.lib.umd.edu/handle/1903/5355>, Date of Access: 2020/11/02.
- [51] Han J and Moraga C, The Influence of the Sigmoid Function Parameters on the Speed of Backpropagation Learning, *In Natural to Artificial Neural Computation. IWANN*, 1995, Heidelberg-Berlin.
- [52] Neal RM, Connectionist Learning of Belief Networks, *Artificial Intelligence*, vol. 56(1) (1992): 71–113.
- [53] Glorot X and Bengio Y, Understanding the Difficulty of Training Deep Feedforward Neural Networks, *In International Conference on Artificial Intelligence*, 2010.
- [54] Courbariaux M, Bengio Y, and David JP, BinaryConnect: Training Deep Neural Networks with binary weights during propagations, *arXiv*, (2015): 3123–3131.
- [55] Nair V and Hinton GE, Rectified Linear Units Improve Restricted Boltzmann Machines, *In Proceedings of the 27 th International Conference on Machine Learning*, December 2-6, 2010, Haifa-Israel.
- [56] Ramachandran P, Zoph B and Le QV, Searching for Activation Functions, *ArXiv*, 2017. [Online]. Available: [1710.05941;http://arxiv.org/abs/1710.05941](https://arxiv.org/abs/1710.05941), Date of Access: 2020/07/21.

- [57] Zeiler MD, Ranzato M, Monga R and Hinton GE, On Rectified Linear Units for Speech Processing, *In International Conference on Acoustics, Speech and Signal Processing*, May 26-31, 2013, Vancouver-Canada.
- [58] Dahl GE, Sainath T, and Hinton GE, Improving Deep Neural Networks for LVCSR Using Rectified Linear Units and Dropout, *In International Conference on Acoustics, Speech and Signal Processing*. May 26-31, 2013, Vancouver-Canada.
- [59] Goodfellow I, Bengio Y, and Courville A, Deep learning. MIT Press, 2016. Available: <http://www.deeplearningbook.org>, Date of Access: 2018/11/21.
- [60] Maas A, Hannun A, and Ng A, Rectifier Nonlinearities Improve Neural Network Acoustic Models, *In International Conference on Machine Learning*,
- [61] Clevert DA, Unterthiner T and Hochreiter S, Fast and Accurate Deep Network Learning by Exponential Linear Units (ELUs), arXiv, 2015, Available: <http://arxiv.org/abs/1511.07289>, Date of Access: 2020/11/20.
- [62] Trottier L, Giguere P and Chaib-Draa B, Parametric Exponential Linear Unit for Deep Convolutional Neural Networks, arXiv, 2018, Available: <https://arxiv.org/pdf/1605.09332v1.pdf>, Date of Access: 2020/11/05.
- [63] Alom MZ, Taha TM, Yakopcic C, Westberg S, Hasan M and Esesn BV, The History Began from AlexNet: A Comprehensive Survey on Deep Learning Approaches, arXiv, 2018, Available: <http://arxiv.org/abs/1803.01164>, Date of Access: 2020/11/5.
- [64] Shea KO, and Nash R, An Introduction to Convolutional Neural Networks, arXiv, 2015, Available: <https://arxiv.org/abs/1511.08458>, Date of Access: 2020/10/20.
- [65] Brownlee J, Deep Learning with Python, <https://machinelearningmastery.com/deep-learning-with-python/>, Date of Access: 2019/11/05.
- [66] Mikolov T, Joulin A and Mathieu M, Learning Longer Memory in Recurrent Neural Networks, arXiv 2014, <https://arxiv.org/abs/1412.7753>, Date of Access: 2019/12/11.
- [67] Sutskever I, Martens J, Dahl G and Hinton GE, On the Importance of Initialization and Momentum in Deep Learning, *Proceedings of the 30th International Conference on Machine Learning*, June 17-19, 2013, Atlanta-Georgia.
- [68] Hochreiter S, Long Short-term Memory, *Neural Computation* 9(8) (1997):1735-80.
- [69] Gers F, Schmidhuber J and Cummins F, Learning to Forget: Continual Prediction with LSTM, *Neural Computation* 12(10) (2000):2451-2471.

- [70] Salehinejad H, Sankar S and Colak E, Recent Advances in Recurrent Neural Networks, arXiv, 2018, <https://arxiv.org/abs/1801.01078>, Date of Access: 2020/05/05.
- [71] Graves A, Generating Sequences With Recurrent Neural Networks, arXiv, 2013, <https://arxiv.org/abs/1308.0850>, Date of Access: 2020/10/13.
- [72] Yao K, Chon T and Vylomova K, Depth-Gated LSTM, arxiv, 2015, <https://arxiv.org/abs/1508.03790>, Date of Access: 2020/10/23.
- [73] Abdel-Hamid O, Deng L and Yu D, Exploring Convolutional Neural Network Structures and Optimization Techniques for Speech Recognition, *INTERSPEECH 2013*, August 25-29, 2013, Lyon-France.
- [74] Graves A, Framewise Phoneme Classification with Bidirectional LSTM and Other Neural Network Architectures, *Neural Networks* 18(5-6) (2005):602-10.
- [75] Wang S and Jiang J, Learning Natural Language Inference with LSTM, arXiv, 2015, <https://arxiv.org/abs/1512.08849>, Date of Access: 2020/09/11.
- [76] Graves A, Fernandez S and Schmidhuber J, Multi-Dimensional Recurrent Neural Networks, arXiv, 2007, <https://arxiv.org/abs/0705.2011>, Date of Access: 2020/09/08.
- [77] Hossin M and Sulaiman MN, Review on Evaluation Metrics for Data Classification, *International Journal of Data Mining & Knowledge Management Process*, March 12-17, 2015, Lisbon-Portugal.
- [78] Hossin M, Sulaiman MN and Mustapha N, A Novel Performance Metric for Building an Optimized Classifier”, *Journal of Computer Science*, 7(4) (2011):582-509.
- [79] Hossin M, Sulaiman MN, Mustapha A and Rahmat R, OAERP: a Better Measure than Accuracy in Discriminating A Better Solution for Stochastic Classification Training, *Journal of Artificial Intelligence*, 4(3) (2011):187-196.
- [80] Huang J and Ling CX, Using AUC and Accuracy in Evaluating Learning Algorithms, *IEEE Transactions on Knowledge Data Engineering*, 17 (2005): 299-310.
- [81] Landis JR, Koch GG, The measurement of observer agreement for categorical data, *Biometrics*, 33(1) (1997): 159–174.
- [82] Li H, Li J, Guan X and Liang B, Research on Overfitting of Deep Learning, *15th International Conference on Computational Intelligence and Security (CIS)*, December 13-16, 2019, Macao-China.

- [83] Yadav S and Shukla S, Analysis of k-Fold Cross-Validation over Hold-Out Validation on Colossal Datasets for Quality Classification, *IEEE 6th International Conference on Advanced Computing (IACC)* , February 27-29, 2016, Bhimavaram-India
- [84] Alippi C and Roveri M, Virtual k-fold cross validation: An effective method for accuracy assessment, *International Joint Conference on Neural Networks (IJCNN)*, July 18-23, 2010, Barcelona-Spain.
- [85] Itil TM, Sahapiro DM and Max-Fink MD, Digital Computer Classifications of EEG Sleep Stages, *Electroencephalography and Clinical Neurophysiology*, 27(1) (1969): 76-83.
- [86] PhysioNet MIT-BIH Arrhythmia Database, <https://physionet.org/content/mitdb/1.0.0/>, Date of Access: 2018/12/10.
- [87] Culebras A, *Clinical Handbook of Sleep Disorders Hardcover*, Butterworth-Heinemann Medical, USA, pp. 121-239.
- [88] Silage A, Spectral and Coherence Analysis Applied to Sleep Apnea, *IEEE Eng Med Biol Mag.*, 9(1) (1990):76-80.

