

T.C.
DICLE ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

EEG İŞARETLERİNDEN EPİLEPSİ TÜRLERİNİN
SINIFLANDIRILMASINDA SKALOGRAM TABANLI DERİN
ÖĞRENME YAKLAŞIMI

Ömer TÜRK

DOKTORA TEZİ

ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

DIYARBAKIR

Temmuz - 2019

**T.C.
DICLE ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**EEG İŞARETLERİNDEN EPİLEPSİ TÜRLERİNİN
SINIFLANDIRILMASINDA SKALOGRAM TABANLI DERİN
ÖĞRENME YAKLAŞIMI**

Ömer TÜRK

DOKTORA TEZİ

ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

DIYARBAKIR

Temmuz - 2019

T.C
DİCLE ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ MÜDÜRLÜĞÜ
DİYARBAKIR

Ömer TÜRK tarafından yapılan “EEG İşaretlerinden Epilepsi Türlerinin Sınıflandırılmasında Skalogram Tabanlı Derin Öğrenme Yaklaşımı” konulu bu çalışma, jürimiz tarafından Elektrik-Elektronik Müh. Anabilim Dalında DOKTORA tezi olarak kabul edilmiştir.

Jüri Üyesinin

Ünvanı Adı Soyadı

Başkan: Prof.Dr.Necmettin SEZGİN.....

Üye : Prof.Dr. Mehmet Sıraç ÖZERDEM.....

Üye : Prof.Dr. Veysi AKPOLAT.....

Üye : Prof.Dr. İbrahim KAYA.....

Üye : Doç. Dr. Resul DAŞ.....

Tez Savunma Sınavı Tarihi: 08/07/2019

Yukarıdaki bilgilerin doğruluğunu onaylarım.

.../...../201..

Prof. Dr. Sevtap SÜMER EKER

ENSTİTÜ MÜDÜR V.

(MÜHÜR)

TEŐEKKÜR

Bu alıŐma, DÜBAP (MÜHENDİSLİK. 18.003) projesi kapsamında desteklenmiŐtir. Desteklerinden ötürü Dicle Üniversitesi Bilimsel AraŐtırma Projeleri Koordinatörlüğüne teŐekkür ederim.

Deęerli vaktini bana harcıyıp bilgi ve tecrübesi ile her türlü imkanı sunan, beraber alıŐmaktan mutluluk duyduğum, deęerli danıŐmanım sayın Prof. Dr. Mehmet Sıra ÖZERDEM 'e ok teŐekkür ederim.

Ayrıca doktora eęitimim boyunca raporlarımı dikkatle deęerlendiren, önemli görüŐ ve önerileriyle tezime katkı saęlayan tez izleme jüri üyeleri sayın Prof. Dr. Veysi AKPOLAT ve sayın Prof. Dr. Mehmet AKIN 'a teŐekkürlerimi sunuyorum.

Tezimi varlıkları ile en büyük destekileri olan eŐim ve ocuklarım Mehmet Őahin, Zeynep, Esra Nur ve Mustafa Berkan 'ıma ithaf ediyorum.

İÇİNDEKİLER

	Sayfa
TEŞEKKÜR	I
İÇİNDEKİLER	II
ÖZET..	IV
ABSTRACT	VI
ÇİZELGE LİSTESİ.....	VIII
ŞEKİL LİSTESİ.....	IX
KISALTMA VE SİMGELER.....	XI
1. GİRİŞ	1
1.1. Tezin amacı	2
1.2. Tezin önemi.....	3
1.3. Tezin içeriği	3
2. KAYNAK ÖZETLERİ	5
3. MATERYAL VE METOT	15
3.1. EEG işaretleri ve Epilepsi İlişkisi	15
3.1.1. Elektroensefalogram	16
3.1.2. EEG İşaretlerinin Ölçümü.....	18
3.1.3. Nörolojik Açıdan Epilepsi ve Tespitinde Kullanılan EEG Kayıt Süreci	19
3.1.4. Epilepsi Nöbetlerin Sınıflandırılması.....	20
3.2. Makine Öğrenmesi	21
3.2.1. Yapay Sinir Ağları (YSA).....	23
3.2.2. Derin Öğrenme Ağları.....	24
3.2.3. Derin Öğrenme Mimarileri	27
3.2.4. Otomatik Kodlayıcılar.....	28
3.2.5. Kısıtlı Boltzmann Makineleri.....	29
3.2.6. Derin Boltzmann Makineleri.....	29
3.2.7. Tekrarlayan Sinir Ağları (RNN)	30
3.2.8. Evrişimsel Sinir Ağları (ESA)	31
3.2.9. Derin Öğrenme Kütüphaneleri	42
3.2.10. K En Yakın Komşu (k-NN) Algoritması	43
3.3. Dalgacık Dönüşümü.....	43
3.3.1. Sürekli Dalgacık Dönüşümü	44
3.3.2. Ayrık Dalgacık Dönüşümü	46
3.4. Bonn Veri Seti Kullanılarak Yapılan Çalışma	47

3.4.1.	Bonn Veri Seti.....	47
3.4.2.	Bonn Veri Seti için İzlenen İşlem Akışı	48
3.4.3.	Bonn Veri Seti için Önerilen ESA Mimarisi.....	49
3.5.	Dicle Üniversitesi Nöroloji Kliniği Veri Seti Kullanılarak Yapılan Çalışma	51
3.5.1.	DÜ Nöroloji Kliniği Veri Seti.....	51
3.5.2.	DÜ Nöroloji Kliniği Veri Seti için İzlenen İşlem Akışı.....	53
3.5.3.	DÜ Nöroloji Kliniği EEG Veri Seti için Önerilen ESA Mimarisi	54
3.5.4.	DÜ Nöroloji Kliniği Veri Seti için Önerilen Konvansiyonel Yöntem	55
3.6.	Performans Değerlendirmesi.....	58
4.	ARAŞTIRMA BULGULARI	59
4.1.	Bonn Veri Seti ile Elde Edilen Bulgular	59
4.1.1.	Sınıflandırma Performansının Literatürdeki Benzer Çalışmalar ile Karşılaştırılması ...	64
4.2.	DÜ Nöroloji Kliniği Veri Seti ile Elde Edilen Bulgular	65
4.2.1.	DÜ Nöroloji Kliniği Veri Setinden Konvansiyonel Yöntem ile Elde Edilen Bulgular .	68
5.	SONUÇ VE ÖNERİLER.....	71
5.1.	Tez Kapsamında Yapılan Yayınlar	72
6.	KAYNAKLAR	73
	ÖZGEÇMİŞ	81

ÖZET

EEG İŞARETLERİNDEN EPİLEPSİ TÜRLERİNİN SINIFLANDIRILMASINDA SKALOGRAM TABANLI DERİN ÖĞRENME YAKLAŞIMI

DOKTORA TEZİ
Ömer TÜRK

DİCLE ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
ELEKTRİK – ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

2019

Bu tez çalışmasında, EEG işaretlerinden Epilepsi türlerinin sınıflandırılması amaçlanmıştır. Türlerinin sınıflandırılmasında, EEG işaretinin boyutu artırılarak skalogram tabanlı bir derin öğrenme yaklaşımı önerilmiştir. Bu tez konusunun çalışabilmesi; en basit paradigmlar karşısında beyinde oluşan temel salınımları, EEG gibi aktivite ölçüm tekniklerini ve işaret işleme yöntemlerini bilmeyi gerektirir.

Beynin denetimsel faaliyetleri sırasında, sinir hücre gruplarının elektriksel aktiviteleri, salınımlar meydana getirir. Kompleks yapıda olan bu biyopotansiyel salınımlar, Elektroensefalogram (EEG) işaretleri olarak adlandırılır. Bu işaretler kullanılarak belirli hastalıklar tespit edilebilmektedir. Bu hastalıklardan biri de epilepsidir. Epilepsi, kendini nöbetler şeklinde gösteren bir hastalıktır. Bu nöbetler farklı karakteristikler şeklinde kendini gösterir. Bu farklı özellikler, epilepsi nöbet türlerini temelde iki ana gruba ayırır. Bu nöbetler, jeneralize ve parsiyel epilepsi olarak adlandırılır. Hekimler için bu nöbet türlerinin tespiti, hastalığın tedavisi açısından önem arz etmektedir. Epilepsi tespiti ve takibinde kullanılan uzun süreli EEG kayıtlarının görsel olarak değerlendirilmesi, zaman açısından maliyetli olmaktadır. Bu maliyetin minimize edilmesini sağlayacak yöntemlerin mühendislik alanlarında önerilebileceği görülmektedir. Mühendislik alanında literatürde var olan EEG tabanlı çalışmalar, bu tez çalışmasında iki ana grupta değerlendirilmiştir. Bu çalışmalar; a) Konvansiyonel Yöntemlere Dayalı Çalışmalar, b) Derin Öğrenme Yöntemlerine Dayalı Çalışmalardır.

Bu tez çalışmasında, EEG işaretlerinden Epilepsi türlerinin sınıflandırılması amaçlanmıştır. Bu amaç doğrultusunda skalogram tabanlı bir derin öğrenme yaklaşımı önerilmiştir. Önerilen yöntemin başarısını değerlendirmek amacıyla, Dicle Üniversitesi (DÜ) Nöroloji Kliniği EEG veri seti ve literatürde çok sık kullanılan Bonn EEG veri seti kullanılmıştır. Önerilen yöntemde, EEG işaretine Sürekli Dalgacık Dönüşümü (SDD) uygulanarak boyutu artırılmıştır. Boyutu artırılan iki boyutlu (2D) frekans-zaman skalogram görüntüleri, Evrişimsel Sinir Ağına giriş örüntüleri olarak kullanılmış ve eğitilerek sınıflandırılmıştır.

Bonn EEG veri seti, farklı paradigmlar ile sağlıklı ve epilepsi hastalığının farklı zaman/konum işaretlerini içerir. Bu işaretler A, B, C, D ve E şeklinde etiketlenmiştir. Yapılan sınıflandırma çalışmasında; A-E ve B-E veri setleri %99.50(±1.50), A-D ve B-D veri setleri %100(±0.00), A-D-E veri setleri %99.00(±1.33), A-C-D-E veri setleri %90.50(±1.70) ve B-C-D-E veri setleri %91.50(±2.29), A-B-C-D-E veri setleri ise %93.60(±3.07) doğruluk oranları elde edilmiştir.

DÜ Nöroloji Kliniğinden elde edilen EEG veri seti; sağlıklı, jeneralize nöbet öncesi, jeneralize nöbet anı ve parsiyel epilepsi olmak üzere 4 sınıf olarak etiketlenmiştir. Gerçekleştirilen sınıflandırma çalışmasında; normal, Jeneralize nöbet öncesi ve Jeneralize nöbet anı EEG kayıtları %90.16(±0.20); sağlıklı, Jeneralize nöbet öncesi, Jeneralize nöbet anı ve Parsiyel EEG kayıtları ise %84.66(±0.48) doğruluk ortalaması ile sınıflandırılmıştır. Bu sonuçlara

göre elde edilen karışıklık (Confussion) matrisinde; normal EEG kayıtları %91.29, jeneralize epileptik nöbetler (nöbet anı) %96.50, parsiyel EEG kayıtları %89.63, nöbet öncesi EEG kayıtları ise %90.44 doğruluk başarımı elde edilmiştir. Çalışmada önerilen yöntemin sonuçları, hem literatürdeki benzer çalışmaların ve hem de konvansiyonel yöntemlerin sonuçları ile karşılaştırılmıştır. Sonuç olarak, önerilen yöntemin başarımı, kabul edilebilir seviyede olduğu görülmüştür.

Anahtar Kelimeler: Epilepsi, EEG, Sınıflandırma, Skalogram, Evrişimsel Sinir Ağı



ABSTRACT

SCALOGRAM BASED DEEP LEARNING APPROACH FOR CLASSIFICATION OF EPILEPSY TYPES FROM EEG SIGNALS

PhD THESIS

Ömer TÜRK

DEPARTMENT OF ELECTRICAL AND ELECTRONICS ENGINEERING
INSTITUTE OF NATURAL AND APPLIED SCIENCES
UNIVERSITY OF DICLE

2019

In this thesis, it is aimed to classify different types of epilepsy from EEG signals. A scalogram-based deep learning approach was proposed by increasing the size of the raw EEG signal in the classification process. To be able to study this thesis; basic oscillations in the brain in the face of the simplest paradigms, activity measurement techniques such as EEG and signal processing methods.

During the supervisory activities of the brain, the electrical activities of the nerve cell groups produce oscillations. These complex biopotential oscillations are called electroencephalogram (EEG) signals. Certain diseases can be detected using these signals. One of these diseases is epilepsy. Epilepsy is a disease that manifests itself as seizures. These seizures manifest themselves in different characteristics. These different characteristics divide epilepsy seizure types into two main groups. These seizures are called generalized and partial epilepsy. For physicians, detection of these types of seizures is important for the treatment of the disease. Visual evaluation of long-term EEG recordings used in the detection and follow-up of epilepsy is costly in terms of time. It is seen that the methods to minimize this cost can be proposed in engineering fields. In the literature, EEG-based studies in the field of engineering have been evaluated in two main groups. These studies; a) Conventional methods based studies, b) Deep learning methods based studies.

In this thesis, it is aimed to classify different types of epilepsy from EEG from EEG signals. For this purpose, a scalogram-based deep learning approach has been proposed. In order to evaluate the success of the proposed method, the EEG data set of the Dicle University Neurology Clinic and the Bonn EEG data set, which are frequently used in the literature, were used. In the proposed method, the size of the EEG signal was increased by applying Continuous Wavelet Transform (CWT). Two-dimensional (2D) time-frequency scalogram images with increased dimensions were used as input patterns to the convolutional neural network and classified by training.

The Bonn EEG data set includes different paradigms and different time / position signals of healthy and epilepsy. These signals are labeled A, B, C, D and E. As a result of classification process; A-E and B-E datasets were 99.50%(± 1.50), A-D and B-D datasets were 100%(± 0.00), A-D-E datasets were 99.00%(± 1.33), A-C-D-E datasets were 90.50%(± 1.70) and B-C-D-E datasets were 91.50%(± 2.29) and A-B-C-D-E data sets were obtained with an accuracy of 93.60%(± 3.07).

EEG data set obtained from DU Neurology Clinic as labeled four classes; healthy, generalized pre-seizure, generalized seizure and partial epilepsy. In the classification study performed for normal, generalized pre-seizure and generalized seizure EEG recordings 90.16% (± 0.20); healthy, generalized pre-seizure, generalized seizure time and partial EEG records were

classified with an average of 84.66% (± 0.48) accuracy. According to these results, in the confusion matrix obtained; normal EEG recordings were 91.29%, generalized epileptic seizures (seizure time) 96.50%, partial EEG records 89.63%, pre-seizure EEG records 90.44% accuracy was achieved. The results of the proposed method were compared with the results of both similar studies and conventional methods. As a result, the performance of the proposed method was found to be acceptable.

Keywords: Epilepsy, EEG, Clasification, Scalogram, Convolutional Neural Network



ÇİZELGE LİSTESİ

<u>Çizelge No</u>	<u>Sayfa</u>
Çizelge 3.1. EEG işaretlerinin içerdikleri frekans bandları	17
Çizelge 3.2. Epilepsi nöbetlerinin sınıflandırması	21
Çizelge 3.3. Derin öğrenmenin gelişimi (Wang ve Raj 2017)	25
Çizelge 3.4. Aktivasyon fonksiyonları	34
Çizelge 3.5. Bonn EEG veri setlerine ilişkin kümeler ve özellikleri	47
Çizelge 3.6. Önerilen ESA mimarisinin ana parametreleri	49
Çizelge 3.7. Her bir çapraz doğrulamada ESA mimarisi için kullanılan EEG skalogram görüntü sayıları	50
Çizelge 3.8. Çalışmada her bir sınıf için oluşturulan görüntü sayısı	53
Çizelge 3.9. Önerilen ESA mimarisi ana parametreleri	54
Çizelge 3.10. ADD sonucu elde edilen dalgacık katsayılarının band aralıkları	56
Çizelge 3.11. Özniteliklerin denklemleri	57
Çizelge 3.12. Karışıklık matrisi (confussion matrix) ve model başarımlar ölçütleri	58
Çizelge 4.1. İkili sınıf başarımları	60
Çizelge 4.2. Üçlü sınıf başarımları	61
Çizelge 4.3. Dörtlü sınıf başarımları	63
Çizelge 4.4. Beşli sınıf başarımları	63
Çizelge 4.5. Literatürde Bonn veri seti kullanılarak yapılan çalışmalar	64
Çizelge 4.6. Üç sınıf için 5 çapraz doğrulamada elde edilen karışıklık matrisi	66
Çizelge 4.7. Üç Sınıf için sınıflandırma performans sonuçları	67
Çizelge 4.8. Dört sınıf için 5 çapraz doğrulamada elde edilen karışıklık matrisi	67
Çizelge 4.9. Dört sınıf için sınıflandırma performans sonuçları	68
Çizelge 4.10. DÜ Nöroloji Kliniği EEG veri setinin ESA ve k-NN sınıflandırma başarımları karşılaştırılması	69

ŞEKİL LİSTESİ

<u>Sekil No</u>	<u>Sayfa</u>
Şekil 2.1. Konvansiyonel yöntemler kapsamında genel olarak izlenen işlem adımları	6
Şekil 2.2. Derin öğrenmeye dayalı yöntemlerde izlenen işlem adımları	9
Şekil 3.1. Beyin bölgeleri	18
Şekil 3.2. Uluslararası 10-20 sistemine göre EEG elektrot yerleşim düzeni	19
Şekil 3.3. Öğrenme çeşitleri	22
Şekil 3.4. Çok katmanlı örnek YSA mimarisi	23
Şekil 3.5. Neocognitron yapısı	26
Şekil 3.6. Otomatik Kodlayıcı için örnek yapı	28
Şekil 3.7. Kısıtlı Boltzman makinesi	29
Şekil 3.8. Derin Boltzman makinesi	30
Şekil 3.9. Tekrarlayan ağ mimarisi	30
Şekil 3.10. Tekrarlayan ağların çalışma biçimleri	31
Şekil 3.11. Evrişim işlemine ilişkin bir örnek uygulama	32
Şekil 3.12. Evrişim işleminin bir sinir hücresine uyarlanması	33
Şekil 3.13. ReLu aktivasyon fonksiyonu	33
Şekil 3.14. Maksimum ve ortalama pooling işlemi için örnek bir uygulama	35
Şekil 3.15. Uzaysal piramit pooling katmanı ile ağ yapısı	36
Şekil 3.16. Def-Pooling katmanına ilişkin örnek bir görsel	37
Şekil 3.17. Tam bağlı katman	37
Şekil 3.18. Softmax fonsiyonu	38
Şekil 3.19. Ezberlemenin önüne geçmek için izlenen stratejik düzenekler	39
Şekil 3.20. LeNet-5 yapısı	40
Şekil 3.21. Alexnet yapısı	40
Şekil 3.22. GoogLeNet yapısı	40
Şekil 3.23. VGGNet yapısı (Alom ve ark. 2018)	41
Şekil 3.24. Microsoft RestNet Yapısı	41
Şekil 3.25. Microsoft RestNet 'in yapı bloku	42
Şekil 3.26. Morlet dalgacığı	45
Şekil 3.27. Farklı sınıflara ait 1 sn'lik EEG işaretlerinin dalgacık skalogram örnekleri	46
Şekil 3.28. Çalışmada kullanılan Bonn EEG veri kümelerine ilişkin örnekler	48
Şekil 3.29. Çalışmada izlenen adımlar	48
Şekil 3.30. Her bir kümeye ilişkin birer bölütün örnek Skalogram değişimleri	49

Şekil 3.31. Üç sınıf için önerilen ESA mimarisi	50
Şekil 3.32. NicoletOne vEEG ile kayda alınan EEG işaretine ilişkin örnek kayıt (Monopolar)	51
Şekil 3.33. NicoletOne vEEG ile kayda alınan EEG işaretine ilişkin örnek kayıt (Bipolar)	52
Şekil 3.34. Çalışmada kullanılan DÜ Nöroloji Kliniği EEG veri kümelerine ilişkin örnekler	52
Şekil 3.35. Çalışmada izlenen adımlar	53
Şekil 3.36. Dört sınıf için önerilen ESA Mimarisi	54
Şekil 3.37. EEG işaretine ilişkin SDD Skalogram örnek görüntülerinin evrişim, havuzlama ve tam bağlı katmanlarda elde edilen örnek özellik haritaları.	55
Şekil 3.38. Konvansiyonel yöntemde izlenen adımlar	56
Şekil 4.1. k-fold çapraz doğrulama ($k = 5$)	65
Şekil 4.2. Fold doğrulukları	66
Şekil 4.3. k-NN fold doğrulukları	69
Şekil 4.4. ESA ve konvansiyonel yöntemlerin fold doğrulukları karşılaştırılması	70

KISALTMA VE SİMGELER

a	: Ölçekleme faktörü
ADD	: Ayrık dalgacık dönüşümü
b	: Öteleme parametresi
BBA	: Beyin bilgisayar arayüzü
ESA	: Evrimsel sinir ağı
İLAE	: Uluslararası epilepsiyle savaşımlar birliği
BPN	: Basit parsiyel nöbet
KPN	: Kompleks parsiyel nöbet
DVM	: Destek vektör makineleri
EEG	: Elektroensefalogram
SOM	: Kendini organize eden harita (Self Organization Map)
TBA	: Temel bileşen analizi
k-NN	: K En yakın komşu
ÇKYSA	: Çok katmanlı yapay sinir ağları
ME	: Mixture of experts
EM	: Beklenti-maksimizasyon
IMF	: Intrinsic mod function
1B-YİÖ	: Bir boyutlu yerel ikili örüntü
$h[n]$: Yüksek geçiren filtre
Hz	: Frekans
KZFD	: Kısa zaman Fourier dönüşümü
QEn	: Q-tabanlı entropi
CEEMDAN	: Complete Ensemble Empirical Mode Decomposition with Adaptive Noise
T-F	: Zaman-Frekans
MEMD	: Multivariate empirical mode decomposition
ApEn	: Yaklaşım entropi
HHT	: Hilbert Huang dönüşümü
SDD	: Sürekli dalgacık dönüşümü
LS-DVM	: Least squares version of Support Vector Machine

α	: Alfa
β	: Beta
γ	: Gamma
δ	: Delta
θ	: Teta
$\psi(x)$: Dalgacık fonksiyonu
ASD	: Otizm Spektrum bozukluğu
P-1D-ESA	: Ensemble of pyramidal one-dimensional convolutional neural network
GPCA	: Global Teme Billeşen Analizi
SDAEs	: Stacked denoising autoencoders
ERD/ERS	: Event-Related Desynchronization (ERD)/Event-Related Synchronization
MI-EEG	: Motor imagery of EEG signals
ROC	: Receiver Operating Characteristic
CssCDBM	: Contractive Slab and Spike Convolutional Deep Boltzmann Machine

1. GİRİŞ

Epilepsi hastalığı, dünyada milyonlarca insanı etkilemektedir (Banerjee ve ark., 2009). Belirsiz olan doğası, insanın yaşam kalitesini olumsuz yönde etkilemekte ve buna bağlı olarak birçok sorun yaşamasına neden olmaktadır. Bu hastalığın hem tespiti hem de tedavi süreci çok zor ve zahmetli olmaktadır.

Epilepsi, beyinde geçici olarak meydana gelen sinir hücre gruplarındaki anormal elektriksel aktivitedir. Bu aktivitenin başlangıç alanı ve dağılımlarına bağlı olarak çeşitli klinik belirtilerle kendini gösterebilir. Gösterilen belirtilerin sahip olduğu çeşitlilik, epileptik nöbetlerin sınıflandırılmasının gerekliliğini ortaya çıkarmıştır. Nöbet tipine göre yapılan sınıflandırmada, nöbetler parsiyel ve jeneralize olmak üzere iki ana gruba ayrılır. Jeneralize epileptik nöbetler, beynin her iki yarısında aynı anda görülen ve tüm beyne yayılan anormal aktivitenin sonucunda meydana gelir. Parsiyel epileptik nöbetler ise, beynin yalnızca bir kısmından (sağ veya sol hemisferinden) başlayarak meydana gelmektedir. Kliniklerde, bu tür nöbet ve türlerinin tespiti, uygulanacak tedavi yöntemi açısından hayati derecede önemli olmaktadır.

Epilepsi hastalığında, nöbet ve türlerinin tespitinde klinisyenler tarafından birçok tıbbi araç kullanılmaktadır. Bu araçlardan biri de Elektroensefalogram (EEG) işaretleridir. Nörologlar, bu işaretlerin dalga morfolojilerini inceleyerek, olası anormallikleri tespit edebilmektedirler. Ancak alınan kayıtların çok uzun süreli olması ve dalga morfolojisinin çeşitliliği nedeniyle bu işlem verimsiz olmaktadır. Bundan dolayı, bu verilerden çıkarsama yapabilecek yöntemler önem arz etmektedir. Bu durum; günümüzde çok popüler olan, bu türden uzun süreli ve büyük verilerin işlenmesini kolaylaştıran ve girdi olarak aldığı veriden öğrenme gerçekleştirebilen makine öğrenme yöntemlerini değerli kılmaktadır.

Makine öğrenmesi, bu türden çok fazla veriyi işleyebilmekte ve girdi olarak aldığı bu veriden çıkarsama yapabilmektedir. Bundan dolayı bu yöntemler, zaman açısından ekonomik olmakta ve çok büyük verilerin işlenmesine olanak sağlamaktadırlar. Literatürde önerilmiş birçok makine öğrenme yöntemi mevcuttur. Bu alanda önerilmiş en popüler yöntemlerin başında derin öğrenme ağları gelmektedir. Bundan dolayı derin öğrenme ağları dışında kalan makine öğrenme yöntemleri, bu tez çalışmasında klasik makine öğrenme yöntemleri olarak adlandırılmıştır. Büyük veriler, klasik makine öğrenme yöntemlerinde işlenirken, veri boyutunun düşürülmesi hedeflenir. Bu yöntem,

1. GİRİŞ

veriden elde edilen küçük boyutun yanında, çok önemli bilgilerin de kaybolmasına neden olabilmektedir. Bu nedenle, klasik makine öğrenme yöntemlerinde çok büyük verileri işleme açısından kısıtlılıklar bulunmaktadır. Bundan dolayı, insan çabasına dayanmayan, ham veriden öğrenme yapabilecek yöntemler araştırılmıştır. Bu araştırmalar sonucu, derin öğrenme ağları geliştirilmiştir.

Günümüzde, derin öğrenme ağları neredeyse her alanda uygulama alanı bulmuştur. Bu ağların ham veriden öğrenme gerçekleştirmesi, hem zaman hem de maliyet açısından çok önemlidir. Diğer taraftan, bu ağların, veriyi doğrusal olmayan aktivasyon fonksiyonlarından geçirecek verinin karmaşıklığını öğrenmesi ve katmanlarında farklı filtreler kullanarak verinin farklı özelliklerini ortaya çıkarması sayesinde, yapılan uygulamalarda başarı performansları tatmin edici bir noktaya gelmiştir. Literatürde, bu ağlar için önerilmiş birçok mimari bulunmaktadır. Bu mimarilerden biri de Evrişimsel Sinir Ağıdır (ESA). ESA mimarisi katmanlı bir yapıya sahiptir. Bu katman yapılarında farklı filtreler kullanılabilmesi sayesinde, görüntü işleme alanında büyük bir başarı sağlamıştır.

Yukarıda açıklanan, epilepsi nöbet ve tür tespitinin önemi, uzun süreli EEG kayıtlarının makine öğrenme yöntemlerinde işlenmesinin maliyet ve katkıları, ayrıca klasik makine öğrenme yöntemlerine göre derin öğrenme ağlarının avantajları, bu tez çalışmasının motivasyon kaynağını oluşturmaktadır.

Bu bölümde tezin amacı, hedefi ve kapsamı genel hatlarıyla anlatılmıştır.

1.1. Tezin amacı

Bu tez çalışmasında, EEG işaretlerinden Epilepsi türlerinin sınıflandırılması amaçlanmıştır. Türlerinin sınıflandırılmasında, EEG işaretinin boyutu artırılarak skalogram tabanlı bir derin öğrenme yaklaşımı önerilmiştir.

Derin öğrenme ağlarının görüntü işleme alanındaki başarısı ve EEG işaretlerinin boyut artırılarak sınıflandırma performansının artırılabilmesi, önerilen yöntemin sebeplerini oluşturmaktadır. Bundan dolayı, EEG işaretlerine sürekli Morlet dalgacık dönüşümü uygulanarak, frekans-zaman içerikli skolagram görüntüleri elde edilmiştir. Elde edilen görüntüler, ESA mimarisine uygulanarak nöbetin doğru bir şekilde belirlenmesi ve epilepsi türlerinin sınıflandırılması sağlanmıştır. Ayrıca önerilen yaklaşımın başarısı, konvansiyonel yöntemlerin başarısı ile karşılaştırılmıştır.

Tez kapsamında önerilen yöntemin başarısını değerlendirmek amacıyla çalışmada iki farklı EEG veri seti kullanılmıştır. Bunlardan birincisi literatürde çok sık kullanılan Bonn veri seti, diğeri ise Dicle Üniversitesi (DÜ) Nöroloji Kliniğinde yatan hastalardan alınan EEG kayıtlarıdır.

Bu çalışmanın literatürdeki araştırmalara göre farkı şöyle özetlenebilir.

- Bu çalışmada (Sağlıklı, Jeneralize nöbet öncesi, Jeneralize nöbet anı ve Parsiyel epilepsi gibi) epilepsi türleri farklı boyutuyla sınıflandırılmıştır.
- Artifakt içeren ham EEG verileri, ön işlem uygulamaksızın değerlendirilmeye katılmıştır.
- Ham EEG verilerinin frekans-zaman skalogramları elde edilmiş ve Evrişimsel Sinir Ağı (ESA) için eğitim örüntüsü olarak kullanılmıştır.

1.2. Tezin önemi

Teknolojinin ilerlemesiyle beraber, yapay zeka yöntemleri sayesinde, hastalık tespitlerinin daha etkin yapılması beklenmektedir. Ancak literatürde, tıp dahil birçok alanda başarılı olarak kullanılan ve bir yapay zeka ürünü olan derin öğrenmenin, EEG işaretlerine uygulanması konusunda çok az çalışmanın olduğu görülmektedir. Bunun yanısıra, epilepsi türlerinin, derin öğrenme ağları kullanılarak sınıflandırılması için yapılan herhangi bir çalışma bulunmamaktadır. Dolayısıyla mühendislik alanında özellikle epilepsi türlerinin tespitine yönelik, klinisyenlere yardımcı araç olabilecek çalışmaların yapılması gerektiği açıktır. Bu çalışmada ise skalogram tabanlı ESA mimarisi ile EEG işaretlerinden epilepsi türleri (Parsiyel/Jeneralize) sınıflandırılmıştır. Bu yaklaşım literatürde söz konusu olan eksikliği giderme bakımından bir başlangıç olacağı öngörülmektedir.

1.3. Tezin içeriği

Bu tez çalışmasının **ikinci bölümünde**, literatürde EEG kullanılarak yapılan çalışmalar değerlendirilmiştir. Literatürde yapılan çalışmalar; a) Konvansiyonel Yöntemlere Dayalı Çalışmalar, b) Derin Öğrenme Yöntemlerine Dayalı Çalışmalar olmak üzere iki ayrı sınıfta değerlendirilmiştir.

Materyal ve metot kısmını oluşturan **üçüncü bölümde**, tez kapsamında kullanılan konvansiyonel yöntemler, veri tabanı ve önerilen yaklaşım yer almaktadır. Diğer bir

1. GİRİŞ

değişle, bu bölümde; EEG işaretleri ve bu işaretlerin epilepsi ile olan ilişkisi, epilepsi türleri, derin öğrenme ağları, K En yakın komşu algoritması, Ayrık Dalgacık Dönüşümü, Sürekli Dalgacık Dönüşümü (SDD), çalışmada kullanılan veri setleri, bu veri setleri için önerilen yöntemler, çalışmada kullanılan veri setleri için önerilen ESA mimarileri ve parametleri anlatılmıştır.


Dördüncü bölümde, çalışma sonucu elde edilen sınıflandırma performansları ve literatürdeki benzer çalışmalar ile karşılaştırılmaları değerlendirilmiştir. Bonn veri seti ve DÜ Nöroloji Kliniği EEG veri seti ile elde edilen bulgular ayrı ayrı alt başlıklarda tartışılmıştır. Bu bölümde ayrıca DÜ Nöroloji Kliniği EEG veri seti için uygulanan konvansiyonel yöntemle ilişkin bulgular değerlendirilmiştir.

Tezin sonuçlar bölümü olan son bölümde ise, önerilen yöntemin katkıları ve yapılabilecek yeni çalışmaların detayları verilmiştir.

2. KAYNAK ÖZETLERİ

Bu tez çalışmasında, sağlıklı ve farklı epilepsi türleri içeren EEG verilerine SDD uygulanarak elde edilen skalogram görüntülerinin bir derin öğrenme türü olan Evrişimsel Sinir Ağında değerlendirilmesi amaçlanmıştır. Literatürde epilepsi tür tespiti noktasında yeterince yayın olmamasına rağmen, EEG tabanlı birçok çalışmanın olduğu görülebilmektedir. Bundan dolayı, EEG verileri kullanılarak yapılan çalışmalar iki ayrı sınıfta değerlendirilmiştir. Bu çalışmalar; a) Konvansiyonel Yöntemlere Dayalı Çalışmalar, b) Derin Öğrenme Yöntemlerine Dayalı Çalışmalar.

a) Konvansiyonel Yöntemlere Dayalı Çalışmalar: EEG işaretleri, doğası gereği öngörülemez işaretlerdir. Bu işaretler kayda alındığında, ilk olarak elde edilen bilgi, zaman-genlik bilgisidir. Ancak, EEG işaretleri farklı frekanslarda potansiyeller içerir. Bundan dolayı EEG işaretlerinden aktivite tespitleri yapılırken, işaretin yapısını koruyacak ve aynı zamanda baskın (dominant) frekansları tespit edebilecek dönüşüm yöntemleri ön plana çıkmaktadır. Genel olarak, bu yöntemlerin temel amacı; EEG işaretini zaman-genlik domeninden, frekans-zaman domenine taşıyarak farklı özniteliklerin elde edilmesidir. Bu dönüşüm yöntemlerine; Hızlı Fourier Dönüşümü (HFD), Kısa Zamanlı Fourier Dönüşümü (KZFD), Dalgacık Dönüşümü (DD) gibi yöntemler örnek verilebilir. Bu dönüşümlerden sonra sınıflandırma işleminde kullanılacak verinin uzun olmasından dolayı, veri setinin karakteristiğini ve farklılığını temsil edebilecek öznitelik yöntemlerine gereksinim duyulur. Bu kapsamda sıklıkla kullanılan yöntemlerden bazıları; istatistiksel parametreler (ortalama, maksimum, minimum...), Hjorth parametreleri, spektral kestirim yöntemleridir (Motamedi-Fakhr ve ark. 2014). Elde edilen bu öznitelikler, bir sınıflandırıcı kullanılarak ayrıştırılır. Sıklıkla kullanılan sınıflandırma algoritmalarından bazıları; K En Yakın Komşu (k-NN) Algoritması, Çok Katmanlı Yapay Sinir Ağları (ÇKYSA), Karar Ağaçları Yöntemi ve Destek Vektör Makinesi (DVM) gösterilebilir (Motamedi-Fakhr ve ark. 2014). Yukarıda sözü edilen işlem akışı konvansiyonel yaklaşım olup, akışın genel adımları Şekil 2.1. 'de gösterilmiştir.



Şekil 2.1. Konvansiyonel yöntemler kapsamında genel olarak izlenen işlem adımları

Literatürde konvansiyonel yöntemlere dayalı yapılan temel çalışmaların özetleri aşağıda belirtilmiştir.

Subasi (2007), Mixture of experts (ME) denetimli öğrenme için modüler sinir ağı mimarisi kullanmıştır. Çalışmada, Epileptik nöbetin saptanması için ME ağ yapısına çift döngülü bir Beklenti-Maksimizasyon (EM) algoritma önerilmiştir. Çalışmada Ayrık Dalgacık Dönüşümü (ADD) kullanılarak EEG işareti alt bandlara ayrıştırılmıştır. Daha sonra bu alt-bant frekansları, normal ve epileptik olarak ME ağına girdi olarak verilmiştir. Çalışmada % 94.5 başarı elde etmiştir.

Chandaka ve arkadaşları (2009), çapraz korelasyon destekli DVM tabanlı sınıflandırıcı olarak adlandırılan bir örüntü tanıma tekniğini önermişlerdir. Önerilen teknik, EEG işaretlerinin çapraz korelogram özniteliklerini kullanarak, ikili sınıfa ayırmaktadır. Çalışmalarında %95.96 sınıflandırma başarısı elde etmişlerdir.

Li ve ark. (2013), çalışmalarında, ampirik mod ayrıştırması (EMD- Empirical Mode Decomposition) ve DVM yöntemlerini kullanarak temel bir yaklaşım önermişlerdir. Çalışmalarında; EMD yöntemi kullanılarak EEG işareti İçsel Mod İşlevlerine (Intrinsic Mod Function-IMF) ayrıştırılmış ve daha sonra bu IMF'lerden varyasyon katsayısı ve dalgalanma indeksi, öznitelik olarak değerlendirilmiştir. Elde edilen bu öznitelikler, DVM sınıflandırıcıda ayrıştırılmıştır. Çalışmada normal ve epilepsi EEG sınıfları, %98.00 duyarlılık ve %99.40 özgünlük oranında ayrıştırılmıştır.

Xiang ve ark. (2015), epileptik nöbetlerin tespiti için Bulanık Entropiye (Fuzzy Entropy) dayanan bir yöntem önermişlerdir. Yöntemde; nöbet anı, nöbet öncesi ve nöbet sonrası sürecinde alınan EEG kayıtlarındaki Bulanık Entropi değerleri hesaplanmaktadır. Elde edilen sınıflandırma özniteliklerinin eğitilmesi için DVM tabanlı grid optimizasyon

yöntemi önerilmiştir. Çalışmada, normal ve nöbet anı süreci %100 sınıflama başarısıyla gerçekleştirilmiştir.

Bhattacharyya ve ark. (2017), EEG işaretlerini çok-ölçekli entropiler hesaplayarak analiz etmişlerdir. Çalışmada, EEG işaretlerinin farklı frekans bantlarındaki entropi hesabı için kalite faktör (Q) tabanlı çok-ölçekli entropi yöntemi önerilmiştir. Q-tabanlı entropide (QEn); işaret, ayarlanabilir Q dalgacığı ile ayrıştırılarak hesaplanmıştır. Ayrıca, alt bantlardan kümülatif olarak K-en yakın komşu (K-NN) entropisi hesaplanmıştır. Elde edilen öznitelikler, DVM sınıflandırıcısına verilmiştir. Çalışmada, normal ve nöbet süreci EEG işaretinden, %100 sınıflama doğruluğu bulunmuştur.

Jia ve ark. (2017), öznitelik çıkarma işleminde, Gürültü Uyarlamalı Ampirik Mod Ayrıştırması (CEEMDAN) tekniğini kullanmışlardır. Elde ettikleri büyüme eğrisinden çeşitli istatistiksel öznitelikler çıkarmışlardır. Bu öznitelikler Random Forest Classifier ile sınıflandırılmıştır. Çalışmada 10 çağraz doğrulama işlemi gerçekleştirilmiştir. Normal ve nöbet süreci EEG işaretinden, %98.00 sınıflama doğruluğu bulunmuştur.

Zahra ve ark. (2017), çalışmalarında, işaretin zaman-frekans (T-F) analizini gerçekleştirmek için Çok Değişkenli Ampirik Mod Ayrışımı (MEMD- Multivariate Empirical Mode Decomposition) yöntemini önermişlerdir. Öznitelik elde etme aşamasında, daha düşük frekans ve gürültüye sahip IMF'ler dikkate alınmamıştır. Geriye kalan IMF 'lere, Hilbert dönüşümü uygulayarak, anlık frekans ve genlik bilgileri elde edilmiştir. Elde edilen bu öznitelikler, yapay sinir ağları kullanılarak sınıflandırılmıştır. Çalışmada kullanılan 5 farklı EEG veri seti, %87.20 doğruluk oranı ile sınıflandırılmıştır.

Sharmila ve ark. (2018), EEG işaretinden epilepsi tespiti için Ayrık Dalgacık Dönüşümünü (ADD) kullanmışlardır. Ayrıştırma sonucu oluşan alt bantların, Shannon ve Yaklaşım entropi (ApEn) değerleri elde edilmiştir. Elde edilen bu öznitelikler, DVM sınıflandırıcıda değerlendirilmiştir. Çalışmada normal ve nöbet süreci EEG işaretinden, %100 sınıflama doğruluğu elde edilmiştir.

Lu ve ark. (2018) tarafından yapılan çalışmada, öznitelikler elde etmek için Hilbert Huang Dönüşümü (HHD) 'ne dayanan Kraskov entropisi önerilmiştir. Çalışmada, EEG işaretleri IMF 'lerine ayrıştırdıktan sonra her bir IMF 'nin Kraskov entropisi ve Ayarlanabilir (Tunable-Q) Dalgacık Dönüşümü 'nün Kraskov entropisi hesaplanmıştır. Elde edilen bu öznitelikleri sınıflandırmak için LS-DVM (Least Squares Version of

Support Vector Machine) kullanılmıştır. Farklı EEG sınıfları için yapılan çalışmada, sınıflandırma başarı performansı %81.96 ile %98.75 aralığında bulunmuştur.


Ibrahim ve ark. (2018), epilepsi ve Otizm Spektrum Bozukluğu (OSB) tanısına yardımcı olabilecek bir yöntem önermişlerdir. Çalışmada, EEG işareti, ADD kullanılarak alt bandlarına ayrıştırılmıştır. Elde edilen bu bandlardan standart sapma, bant gücü, Shannon entropisi ve en büyük Lyapunov üssü elde edilmiştir. Bunun yanı sıra, alt bandlarına ayrıştırılmayan işaretin kanalları arasındaki senkronizasyonu ölçmek için çapraz korelasyon yöntemi kullanılmıştır. Çalışmada farklı sınıflandırıcılar kullanarak normal ve nöbet süreci EEG işaretinden, en yüksek %100 sınıflama doğruluğu elde edilmiştir.

Khoursheed, ve Essa (2019), tarafından yapılan çalışmada, öznitelik elde etmek için, farklı ADD seviyeleri ve farklı sayıda Temel Bileşen Analiz (TBA) yöntemi önerilmiştir. Öznitelikler farklı ADD seviyelerinden elde edilmiştir. Elde edilen bu öznitelik vektörünün boyutlarını azaltmak için TBA yöntemi kullanılmıştır. Boyutları indirgenen öznitelik vektörü DVM kullanılarak sınıflandırılmıştır. Çalışmada, nöbet ve normal EEG işaretlerinin F-ölçümünü % 100 olarak elde edilmiştir.

Wang ve ark. (2019), çalışmasında, EEG verilerinden epilepsi tespiti için 4. seviye Symlet dalgacığı kullanılmıştır. Çalışmada, EEG işaretlerinin delta, teta, alfa, beta ve gama bandları öznitelik vektörü olarak kullanılmıştır. Bu bandlardan elde edilen verinin boyutunu azaltmak için TBA yöntemi kullanılmıştır. Çalışmada, Gradient Boosting Machine sınıflandırıcı kullanılarak öznitelikler sınıflandırılmıştır. Epilepsi nöbet süreci ve sağlıklı EEG işaretlerinden, %93.2 ile %100 aralığında sınıflama başarıları elde edilmiştir.

b) Derin Öğrenme Yöntemlerine Dayalı Çalışmalar: Literatürde, verinin çok az bölümünün sınıflandırmaya dahil edildiği yöntemlere alternatif olarak, son zamanlarda büyük verilerin değerlendirildiği derin öğrenme tabanlı yöntemlerin ilgi gördüğü gözlenmektedir. Bu ilginin nedeni; konvansiyonel yöntemlerde verilerin özniteliklerle temsil edilmesi ile birlikte işaret içinde saklı olan bilgilerin kaybına neden olması şeklinde değerlendirilebilir. Böylelikle EEG işareti, derin öğrenme ağları ile ham olarak işlenebilme imkanına kavuşmuştur. Derin öğrenmenin en önemli avantajı, öznitelik evresini kendisinin gerçekleştirmesidir. Diğer bir ifadeyle, derin öğrenme ağları aldığı

veriyi işleyerek, bulduğu farklılıkları öznitelik haritalarına işleyebilmesidir. Derin öğrenme yöntemlerine dayalı genel olarak izlenen işlem akışı Şekil 2.2. 'de verilmiştir.



Şekil 2.2. Derin öğrenmeye dayalı yöntemlerde izlenen işlem adımları

Literatürde EEG tabanlı derin öğrenme çalışmalarına bakıldığında, farklı içeriklerde çalışmaların yapıldığı görülebilmektedir. Yapılan bu farklı içerikteki çalışmalar genel olarak iki sınıfta incelenebilir. Bunlardan birincisi, EEG işaretlerinin veri noktası (data point) olarak; ikincisi ise EEG işaretlerinden çeşitli yöntemler kullanılarak elde edilen görüntülerin, derin öğrenme ağlarında işlenmesidir.

I. EEG işaretlerinin veri noktası (data point) olarak değerlendirilmesi: EEG'nin derin öğrenme ağlarında veri noktası (data point) olarak işlenmesi genel olarak iki farklı yaklaşımla gerçekleştirilir. Bu yaklaşımlardan birincisinde, EEG verilerinden öznitelik matrisi elde edilir ve derin öğrenme ağının girişine uygulanır. İkincisinde ise veriler üzerinde hiçbir işlem yapılmadan ham olarak derin öğrenme ağının girişine uygulanır. Bu kapsamda yapılan temel çalışmalardan bazıları aşağıda özetlenmiştir.

(Bonn veri seti kullanılarak yapılan sınıflandırma çalışmaları) Acharya ve ark. (2018); çalışmalarında, Bonn Üniversitesi Epileptoloji bölümü veritabanından alınan (A, B, C, D, E olmak üzere 5 farklı işaret grubunu içeren) EEG kayıtlarını kullanmışlardır. Normal, nöbet öncesi ve nöbet anı olmak üzere toplam 3 sınıfı tespit etmek için EEG kayıtlarına, 13 katmanlı ESA algoritması uygulanmıştır. Her bir EEG veri seti 100x4097 veri noktasından (data point) oluşmaktadır. Çalışmada, veri setinin %90 oranı eğitim, %10 oranı da test için ayrılmıştır. Eğitim setinin %30 oranı da eğitim aşamasında doğrulama (validation) seti olarak kullanılmıştır. Önerilen yaklaşım ile %88.67 doğruluk, %90.00 özgüllük ve %95.00 duyarlılık başarıları elde edilmiştir.

Ullah ve ark. (2018), epilepsi nöbetini tespit etmek için çalışmalarında Bonn veri setini 1024'lük 4 adet alt segmente ayırmışlardır. Daha sonra bu segmentler %50 örtüşen

2. KAYNAK ÖZETLERİ

ve 512 pencere uzunluğunda alt segmentlere indirgenmiştir. Bu şekilde elde edilen EEG veri seti, Ensemble of Pyramidal One-Dimensional ESA (P-1D-ESA) yöntemi kullanılarak sınıflandırılmıştır. Çalışmada nöbet saptama doğruluğu %99.1 olarak elde edilmiştir.

Hussein ve ark. (2018) çalışmalarında, EEG kayıtlarında ardışık veri örnekleri arasındaki korelasyonu ölçmüşlerdir. EEG verileri, örtüşmeyen bölütler dizisine dönüştürülmüştür. Normal ve nöbet süreci EEG işaretlerinin üst düzey özniteliklerini öğrenmek için Uzun Kısa Süreli Bellek (LSTM) ağı ve sınıflandırma için de Softmax kullanılmıştır. Çalışmada nöbet saptama doğruluğu, %90.0 ile %100 aralığında bulunmuştur.

Yuan ve ark. (2017), EEG kayıtlarını DD kullanarak EEG skalogram dizilerine dönüştürmüşlerdir. Küresel temel bileşen analizi (GPCA), yığılmış kodlayıcılar (SDAEs) ve ham EEG bölütleri kullanılarak, sırasıyla küresel, kanal-temelli ve zamansal özellikler elde edilmiştir. Birleştirilen öznitelikler, EEG nöbet tespiti için DVM sınıflandırıcısının girişine uygulanmıştır. Çalışmada normal ve nöbet süreci EEG işaretinden, %100 sınıflandırma doğruluğu elde edilmiştir.

(Araç sürücü düzeylerinin belirlenmesi) Hajinoroozi ve ark. (2016); sürücülerin arabayı kullanma aşamalarında, sürücü düzeylerini ölçmeye çalışmışlardır. Frekans özelliklerinin elde edilmesi için, EEG işaretinin 250 örneklilik segmenti dikkate alınmıştır. Hamming pencere HFD, her kanalın EEG segmentine uygulanmıştır. Elde edilen güç spektrum yoğunluğu, 4 standart EEG frekans bandına (delta, teta, alfa ve beta) ayrıştırılmıştır. Bu frekans bantları için dört farklı öznitelik elde edilmiştir. Bunlar; dominant frekans, dominant tepe noktalarının ortalama gücü, ağırlık merkezi frekansı ve frekans değişkenliğidir. Elde edilen öznitelik vektöründen, Akıllı (Wise) Evrimsel Sinir Ağı ile %86 oranında başarı elde edilmiştir.

(Sol-sağ el hareketlerinin sınıflandırılması) Tang ve ark. (2017) tarafından yapılan çalışmada; iki deneğin sol ve sağ el hareketlerinden oluşan 28 kanallı EEG kayıtları sınıflandırılmıştır. Elde edilen EEG kayıtları 1000 Hz'de örneklenmiş ve 0.5- 100 Hz arasında band geçiren filtre ile filtrelenmiştir. EEG kayıtları alfa ve beta frekans bantlarına ayrıştırılmıştır. Her bir sınıfın ERD/ERS değerleri hesaplanmıştır. Çalışmada ESA mimarisi kullanılarak, %86.41 sınıflandırma başarısı elde edilmiştir.

(Depresyon gibi ruh hali bozukluğunun tespiti) Ay ve arkadaşları (2019), depresyon gibi ruh hali bozukluğunu tespit etmek için EEG işaretlerini kullanmışlardır. EEG kayıtları 15 normal ve 15 depresyonda olan deneklerden alınmıştır. Beynin sol ve sağ yarım kürelerinden elde edilen EEG işaretleri kullanılmıştır. Kullanılan EEG işaretleri 256 Hz örnekleme frekansına sahiptir. Çalışmada kullanılan veri seti, her biri 2000 veri noktasına (data point) sahip 4798 depresyon ve 4318 normal EEG kaydından oluşmaktadır. Çalışmada depresyonu saptamak için ESA ve Uzun Kısa Süreli Bellek mimarisi kullanılarak hibrid bir model önerilmiştir. Bu modelde, işaretlerin zamansal özellikleri, ESA eğitiminde kullanılmıştır. Sıralı öğrenme işlemi de Uzun Kısa Süreli Bellek mimari katmanları aracılığıyla sağlanmıştır. Çalışmada, sağ ve sol yarım küre EEG işaretlerinden sırasıyla % 99.12 ve % 97.66 sınıflandırma başarımı elde edilmiştir.

(Uyku aşamalarının sınıflandırılması) Mousavi ve arkadaşları (2019) çalışmalarında; uyku aşamalarının EEG işaretinden otomatik olarak sınıflandırılması için tek kanallı yeni bir yaklaşım önermişlerdir. Kullanılan EEG işaretlerinin örnekleme frekansı 100 Hz dir. EEG verileri, Kafkas erkek ve bayanlarından (21 ila 35 yaşları arası) alınmıştır. Çalışmada önerilen ağ mimarisi 9 evrişim ve 2 tam bağlı katman içermektedir. Çalışmalarında önerilen yöntemin sonuçları 2 ila 6 sınıf uyku evresi için sırasıyla %98.10, %96.86, %93.11, %92.95, %93.55 oranında doğruluk ve Kappa katsayısı da sırasıyla % 0.98, %0.94, % 0.90, % 0.86 ve %0.89 olarak elde edilmiştir.

II. EEG işaretlerinin görüntü olarak değerlendirilmesi: EEG işaretlerinden elde edilen görüntülerin derin öğrenme ağlarında işlenmesi çalışmalarında ise, EEG verileri çeşitli yöntemler uygulanarak farklı domenlere dönüştürülmektedir. Bu dönüşümler ile EEG işaretlerinin boyutu artırılarak, saklı detay bilgilerin de işleme katılması sağlanmıştır. Bu dönüşüm sonucu elde edilen görüntüler derin öğrenme ağlarına uygulanmaktadır. Bu kapsamda yapılan temel çalışmalardan bazıları aşağıda özetlenmiştir.

(Beyin hasarının sınıflandırılması) Yuan ve ark. (2017), beyin hasarı oluşan, koma teşhisi ve beyin ölümü tanısı olmak üzere iki farklı EEG seti sınıflandırmışlardır. Alınan EEG verilerinin spektrogram görüntüleri, KZFD yöntemi kullanılarak elde edilmiştir. EEG işaretlerinin her 20 saniyesinden bir Spektrogram görüntüsü elde edilmiştir. Elde edilen Spektrogram görüntüleri, tasarlanan ESA 'nın giriş formatına uygun olabilmesi için 256×256 boyutuna indirgenmiştir. Çalışmada koma hastalarından üretilen 2400 görüntü

2. KAYNAK ÖZETLERİ

ve beyin ölümü hastalarından elde edilen 3600 görüntü olmak üzere toplamda 6000 spektrogram görüntüsü kullanılmıştır. Bu görüntülerin %80 oranı eğitim, kalanı ise test seti olarak kullanılmıştır. Maksimum epoch 12000 olarak ayarlanmış ve ağı eğitmek için ekran kartı (Graphical Process Unit-GPU) kullanılmıştır. Eğitim süresi 26 dk olan bu ağın, test doğruluğu %99.8 olarak elde edilmiştir.

(Zihinsel iş yükünün sınıflandırılması) Zhang ve Yin (2017) tarafından yapılan çalışmada, zihinsel iş yükünü (mental work load) sınıflandırmak için altı denekten alınan EEG kayıtları kullanılmıştır. Ölçülen EEG verileri, düşük geçişli (0-40 Hz) filtre kullanılarak filtrelenmiştir. Filtrelenen veriler KZFD yöntemi kullanılarak 6 alt banda ayrıştırılmıştır. Bu bantlar; delta (1-4Hz), teta (5-8Hz), alfa (9-13Hz), düşük beta (14-16Hz), yüksek beta (17-30Hz) ve gama (31-40Hz) bantlarıdır. Çalışmalarında kullandıkları ESA mimarisinden %7.63 test hatası elde edilmiştir.

(Sol-sağ el hareketlerinin sınıflandırılması) Tabar ve Halici (2016); 9 denekten alınan ve sağ/sol el hareketlerini içeren EEG kayıtlarını sınıflandırmışlardır. Çalışmada, EEG kayıtlarının her 2 saniyesine KZFD uygulanmıştır. Her bir kanal için 6-30 Hz aralığında görüntü elde edilmiştir. Elde edilen her bir EEG kanal görüntüsü örtüşmeden üst üste konarak tek bir görüntüye dönüştürülmüştür. Çalışmada görüntüleri sınıflandırma için karma (combined) bir yapı olarak ESA ve Stacked Autoencoder (SAE) kullanılmıştır. ESA mimarisinde, 1-D filtrelili bir evrişim katmanı kullanılmıştır. ESA girişine verilen görüntüler evrişim katmanından sonra 900 nöron girişli ve iki çıkışlı SAE ağına uygulanmıştır. Çalışmada, EEG kayıtlarından %75.10 başarı ortalaması ve 0.547 kappa değeri elde edilerek, diğer çalışmalardan %9 daha fazla doğrulama performansı elde edilmiştir.

(Alzheimer hastalığının erken teşhisi) Bi ve Wang (2019); tarafından önerilen yöntemde, Alzheimer hastalığının erken teşhisi için EEG işaretlerinin spektral görüntüleri kullanılmıştır. Çalışmada, görüntülerin sınıflandırılması için hibrit bir yapı olan, Contractive Slab ve Spike Evrişimli Derin Boltzmann Makinesi (CcssCDBM) kullanılmıştır. Kullanılan EEG kayıtları; 4 sağlıklı, 4 hafif Kognitif Bozukluk ve 4 Alzheimer hastası olmak üzere toplamda 12 katılımcıdan elde edilmiştir. EEG kayıtları, 64-kanallı ve 500 hz örnekleme frekansına sahiptir. Elde edilen bu EEG kayıtlarına HFD uygulanarak; teta (4-7 Hz), alfa (8-13 Hz) ve beta (13-30 Hz) bantlarının spektral görüntüleri elde edilmiştir. Çalışmada, her katılımcı için, 32×32 çözünürlükte 1000 tane

olmak üzere, toplamda 12000 adet EEG spektral görüntüsü kullanılmıştır. Çalışmada %95 ROC ortalaması elde edilmiştir.

Bu tez çalışması kapsamında ise ilgili EEG verileri için boyut artırımına gidilerek çalışma performansının artırılması amaçlanmıştır. Bu yaklaşıma göre bu tezde önerilen yöntem, yukarıda belirtilen sınıflardan “EEG işaretlerinin görüntü olarak değerlendirilmesi” sınıfında yer almaktadır.





3. MATERYAL VE METOT

Bu tez çalışmasında, sağlıklı kişiler ile farklı sınıflara ait epilepsili hastalardan alınan EEG kayıtlarının sınıflandırılması için skalogram tabanlı ESA mimarisi önerilmiştir. Çalışmada DÜ Nöroloji kliniğinde yatan hastalardan alınan EEG kayıtları kullanılmıştır. Ayrıca önerilen yöntemin başarısını değerlendirmek amacıyla, literatürde sıkça kullanılan Bonn Üniversitesi Epileptoloji bölümü veri seti çalışmaya dahil edilmiştir. Derin öğrenmenin görüntü işleme alanındaki başarısından dolayı, veri setlerine SDD uygulanarak frekans-zaman skalogram görüntüleri elde edilmiştir. Böylelikle EEG işaretlerinin boyut artırımı sağlanmıştır. Sağlıklı, Jeneralize nöbet öncesi, Jeneralize nöbet (anı) süreci ve Parsiyel olmak üzere toplam 4 farklı sınıfın tespiti için elde edilen görüntüler, bir derin öğrenme ağı olan ESA 'da değerlendirilmiştir. Bundan dolayı bu bölümde; EEG işaretleri ve bu işaretlerin epilepsi ile olan ilişkisi, epilepsi türleri, derin öğrenme ağları, SDD, veri setleri ve bu veri setlerinin işlenmesi ile birlikte önerilen ESA mimarilerinin detayları anlatılmıştır.

3.1. EEG işaretleri ve Epilepsi İlişkisi

Epilepsi hastalığı, insanoğlu tarafından bilinen en eski ve halen en sık görülen nörolojik hastalıklardan biridir (Görgülü ve Fesci 2011). Bu hastalığın dünyada milyonlarca insanı etkilediği tahmin edilmektedir (Acharya ve ark. 2013). Epilepsi; beyinde anormal elektriksel aktivite sonucu meydana gelen, duyuşsal rahatsızlık ve bilinç kaybına yol açan nörolojik bir hastalıktır (Buluş 2014). Epilepsi nöbeti ise, santral sinir sistemindeki bir nöron kümesinin anormal, aşırı, hipersenkronize deşarjlarına bağılı olarak ortaya çıkan, geçici olarak görülen ani bir olaydır (Fisher ve ark. 2005; Buluş 2014). Epilepsinin, çoğu zaman belirsiz olan doğası, hastanın yaşam kalitesini olumsuz yönde etkilemekte ve birçok psikososyal sorunlar yaşamasına neden olmaktadır. Epileptik nöbetin önceden kestirimi, nöbet öncesi görülen dalgalardaki değışimlerden kısmen anlaşılabilir. Bu tartışma konusunun nörologlar arasında yapılabildiğı literatürden görülebilmektedir (Noachtar ve Rémi 2009) ancak mühendislik açısından bu tartışma yapılamamaktadır. Gerekçe olarak ortak çalışmaların yeterince yapılamamış olması gösterilebilir.

Epilepsi tespiti için birçok tıbbi araç kullanılmaktadır. Bunlardan en yaygın kullanılan araçlardan biri de Electroencephalogram (EEG) işaretleridir. Çünkü EEG işaretleri hem düşük maliyetli hem de çok fazla bilgi içeren bir veri kaynağıdır (Cohen

2017). EEG, elektrotların kafa derisine yerleştirilerek beyindeki nörolojik aktivitelerin kayıt edilmesiyle elde edilir (Misra ve Kalita 2005). Kayıt edilen bu işaretlerin çeşitli yöntemlerle işlenmesi sonucu, beyinde oluşan anormallikler tespit edilebilmektedir. Bu tespitler yapılırken büyük miktarda EEG verisinin görsel olarak incelenmesinin ciddi dezavantajları bulunmaktadır. Nörologlar tarafından yapılan görsel inceleme, özellikle uzun süreli kayıtlarda çok zaman alıcı ve verimsizdir. Buna ek olarak, kayıttaki analizlerin öznel niteliği ve aralıklı diken dalga morfolojisinin çeşitliliği nedeniyle nörologlar arasında anlaşmazlık olabilmektedir. Mühendislik açısından bakıldığında, epileptik nöbetlerin otomatik olarak saptanması için geliştirilen yöntemler, EEG verilerinin daha nesnel ve hesaplama uygun olarak incelenmesine olanak sağlar. Bu imkan, nörologların karar noktasında anlaşmazlıklarının önüne geçebilir. Dolayısıyla çalışmalarda önerilen mühendislik tabanlı yöntemler, hekimler için destek sağlayan değerli klinik araçları olarak kabul edilebilir.

Literatürde konvansiyonel yöntemler kullanılarak, EEG işaretlerinden epilepsi tespiti ile ilgili birçok çalışma bulunmaktadır (Adeli ve Dadmehr 2003; Fakhr ve ark. 2014; Kumar ve ark, 2015; Kaya ve ark. 2014; Aiswal 2017). Bu çalışmaların büyük bir kısmında, EEG işareti frekans-zaman domenlerine dönüştürülmekte ve elde edilen dönüşüm işaretlerinin çok uzun olmasından dolayı, çeşitli yöntemler ile işaretin karakteristiğini temsil edebilecek öznitelikler elde edilmektedir. Ancak işaretin dönüşümü ve öznitelik çıkarma işlemlerinde, işaret gürültü oranı ve veri kaybı çok olduğundan, sınıflandırma doğruluğu büyük oranda etkilenmektedir. Aynı zamanda bu yöntemler kullanılarak yapılan çalışmalarda, sınıflandırma doğruluklarının artırılması, hem araştırma açısından yoğun çaba gerektirmekte hem de zaman açısından maliyetli olmaktadır. Dolayısıyla, işaretin özniteliklerini kendi içinde çıkarabilen yöntemlerin varlığı, veri kaybını minimize etmek açısından önem arz etmektedir. Böyle bir durumda derin öğrenme ağlarının kullanılması, bu tez çalışmasında önerilen yöntemin odak noktasını oluşturmaktadır.

3.1.1. Elektroensefalogram

EEG, beyin sinir hücre gruplarının elektriksel aktivitesidir (Bilir 1999). EEG işaretleri serebral kortekste bulunan nöronlar tarafından üretilmektedir. EEG işaretleri, beyinde uyarılara verilen yanıtlardır (Güler ve ark, 2001).

İlk insan EEG 'sini Hans Berger 1929'da kayıt etmiştir. Daha sonra Gibbs,

okspital alfa dalgasını keşfetmiştir. 1930 yılında, Lennox ve Jasper, jeneralize diken-dalga, fokal keskin ve diken dalgaların epilepsiyle ilişkisini göstermişlerdir (Sanei ve Chambers 2007).

Kafatasına yerleştirilen elektrotlar yardımıyla alınan EEG işaretleri, genliği 10 μ V ile 100 μ V aralığında ve frekansı 0.5 Hz ile 100 Hz aralığında olan, durağan olmayan dinamik işaretlerdir (Adeli ve Dadmehr 2003). EEG işaretleri farklı frekans bileşenlerinden oluşması nedeniyle, frekans bileşenleri gruplandırılmıştır. Bu gruplar temelde delta, teta, alfa, beta ve gama olarak adlandırılmıştır (Başar 2001; Tülay 2009). Söz konusu gruplanan bandların frekans aralıkları Çizelge 3.1. 'de verilmiştir.

Çizelge 3.1. EEG işaretlerinin içerdikleri frekans bandları

Alt Bant	Frekans Aralığı
Delta (δ)	0.5 – 4 Hz
Teta (θ)	4 – 8 Hz
Alfa (α)	8 – 13 Hz
Beta (β)	13 – 30 Hz
Gama (γ)	30 – 100 Hz

Her biri farklı salınım özelliklerine sahip olan EEG frekans bandlarının özellikleri aşağıda açıklanmıştır.

a) Delta Bandı


0.5-4 Hz aralığında olan EEG aktivitesidir. Erişkinlerde uykunun NREM-III uyku evresinde gözlenir.

b) Teta Bandı

Frekansı 4-8 Hz aralığında, süresi 125-250 msn dir. Erişkinlerde uykunun başlangıcında frontal bölgede ve bazen normal kişide uyanık-istirahatta iken temporal ve oksipital bölgelerinde gözlemlenebilir.

c) Alfa Bandı

Uyanık, gözleri kapalı bir erişkinde hemisferlerin parietal ve oksipital bölgelerinde ortaya çıkan, göz açmakla zayıflayan 8-13Hz aralığında gözlemlenen bir aktivitedir. Mental aktivite ve göz açıp kapamaya reaktivite gösterir; gözler kapanınca ve gevşeme ile ortaya çıkar, gözler açılınca ve mental aktivite ile bloke olur. 8-10 Hz (7-11 Hz) frekanslı EEG aktivitesi Mu ritmi olarak adlandırılır. Mu ritmi, göz açmakla bloke olmaz. Uyanıklıkta görülür, uyuklama veya uyku esnasında kaybolur.



Şekil 3.2. Uluslararası 10-20 sistemine göre EEG elektrot yerleşim düzeni
(http://docs.neu.edu.tr/staff/asli.aykac/EEG-2015_94.pdf)

EEG kayıtları genel olarak iki şekilde kayıt edilmektedir. Bunlar monopolar ve bipolar olarak adlandırılır. Çalışmada kullanılan kayıtlar monopolar olarak kaydedilmiştir. Monopolar montaj, tüm kanallar için ortak bir referans kullanır. Genellikle bu referans, elektriksel olarak nötr olduğu kabul edilen bir alana yerleştirilir (ör. kulak memesi). Bipolar montajda ise referans sürekli olarak değişir. Bu kayıt türünde, bir önceki kanalın ikinci girişi, bir sonraki kanalın birinci girişi olarak kullanılır (Karakaş ve Baran 2010). Bu kanallardan bir tanesi referans olarak kullanılır.

3.1.3. Nörolojik Açıdan Epilepsi ve Tespitinde Kullanılan EEG Kayıt Süreci

Epilepsi, nöbetler halinde kendini gösteren nörolojik bir hastalıktır (Buluş 2014). Epilepsi tanısı ve sınıflandırması için birçok veri kaynağı kullanılmaktadır. Kullanılan en yaygın veri kaynaklarından biri de Elektroensefalografi (EEG) aktivitesidir.

EEG; epilepsinin tanısı, takibi ve cerrahi müdahale öncesi değerlendirmesinde kullanılan temel teşhis yöntemidir (Pillai 2006). Epilepsinin teşhisi aşamasında, EEG kayıtları farklı dönemlerde alınabilmektedir. Bu kayıtlar, nöbet (anı) süreci (İktal) ve nöbet öncesi (inter-iktal) alınabilmektedir. Genellikle epilepsinin tespitinde her iki kaydın kullanıldığı görülebilmektedir.

a) İnter-İktal Sürecinde EEG Kayıtları

Epilepsi tespitinde ve takibinde, inter-iktal EEG kaydı sık kullanılan ve kolay bir yaklaşımdır (Wyllie ve ark. 2012; Buluş 2014). Bu EEG kayıtları nöbet öncesi veya nöbetler arası alınmaktadır. Normal EEG kayıtları hasta uyanık iken yapılmaktadır. Anormallikleri ortaya çıkarmak için normal EEG kayıtları tamamlandıktan sonra

hiperventilasyon (sıkça nefes alıp-verme) ve uyku gibi aktivasyon yöntemleri kullanılabilir (Buluş 2014).

b) İktal Sürecinde EEG Kayıtları

İktal EEG, epilepsi tanısında kullanılan en önemli metod olarak yerini korumaktadır. Bu kayıtlar hasta nöbetleri sırasında alınan kayıtlardır. Nöbetlerin epileptik olup olmadığını anlamak, nöbet tipinin sınıflandırılmasını (parsiyel-jeneralize) sağlamak ve nöbetin kaynaklandığı alanı lateralize (beynin sağ veya sol lobu) ve lokalize etmekte etkilidir. İnter-iktal EEG kayıtlarına göre, iktal EEG kayıtlarının epileptojenik alanın belirlenmesinde çok daha başarılı olduğu söylenmektedir (Chabolla ve Cascino 1996; Buluş 2014).

3.1.4. Epilepsi Nöbetlerin Sınıflandırılması

Epilepsi nöbetlerinin çeşitli olmasından dolayı, bu nöbetlerin sınıflandırılması gerekliliği ortaya çıkmıştır. Böyle bir durumda, her kesimin kabul edebileceği bir gruplamanın yapılması, altta yatan etkenlerin ortaya çıkarılması, bilimsel araştırmaların ilerletilmesi ve sonuçların mukayese edilmesi açısından önemlidir. Bundan yola çıkarak Uluslararası Epilepsiyle Savaşım Birliği (ILAE) tarafından epileptik nöbetlerin ilk sınıflandırması 1969 yılında kabul edilmiştir. Bu sınıflama; nöbetin klinik tipi, EEG'nin nöbet öncesi ve nöbet anı özellikleri, beden yapısı, etiyoloji ve yaş kriterlerine göre yapılmıştır.

Epilepsi, nöbetler halinde kendini gösteren bir hastalık olduğundan dolayı nöbetler birçok şekilde gruplanabilmektedir. Bunlar; nedene göre idyopatik (primer) veya semptomatik (sekonder); kaynaklandıkları yere göre; klinik şekillerine göre (jeneralize veya fokal); sıklıklarına göre veya elektrofizyolojik karşılıklarına göre sınıflandırılabilir (Sucak 2011; Altıokka 2015).

Nöbet tipine göre yapılan sınıflandırmada nöbetler parsiyel ve jeneralize olmak üzere iki ana gruba ayrılmıştır. Klinik ve elektroensefalografik değişiklikler parsiyel nöbetlerin tek bir hemisfer kısmından, jeneralize nöbetlerin ise her iki hemisferden yaygın olarak başladığını göstermektedir (Sucak 2011; Eser 2014; Altıokka 2015). Epilepsi nöbetlerinin sınıflandırılması Çizelge 3.2. 'de gösterilmiştir.

Çizelge 3.2. Epilepsi nöbetlerinin sınıflandırması

Epilepsi Nöbetlerinin Sınıflandırması	
I. Jeneralize Nöbetler	A. Absans Nöbetleri
	B. Miyoklonik Nöbetler
	C. Klonik Nöbetler
	D. Tonik Nöbetler
	E. Tonik-Klonik Nöbetler
II. Parsiyel Nöbetler	A. Basit Parsiyel Nöbetler
	B. Kompleks Parsiyel Nöbetler
III. Sınıflandırılmayan Epilepsi Nöbetleri: (Veri yetersizliği veya nöbetlerin yukarıdaki formlara benzemediği durumlar için geçerlidir.)	

a) Jeneralize Epilepsi

Beynin her iki hemisferinde aynı anda oluşan ve beynin tamamına yayılan epilepsi nöbetleridir. Jeneralize epileptik nöbetler, tüm beyne yayılırlar. Jeneralize epilepsi nöbetleri ILAE 2010 sınıflandırması ile uyumlu olarak absans, miyoklonik, tonik ve klonik nöbetler olarak sınıflandırılmaktadır.

b) Parsiyel Epilepsi

Parsiyel epileptik nöbetler, beynin yalnızca bir kısmından başlayarak meydana gelir. Basit parsiyel nöbet ve kompleks parsiyel nöbet olarak tanımlanan nöbet çeşitleri vardır. Parsiyel epilepside rutin EEG'nin duyarlılığı ve özgüllüğü epileptik beyin dokusunun lokalizasyonuna, kayıt süresine, ilave elektrodların kullanılmasına, nöbet sıklığına ve geçirilen son nöbet ile EEG kaydı arasındaki zamanlamaya bağlıdır.

Kompleks parsiyel nöbetler ile basit parsiyel nöbetler arasındaki en önemli fark bilinç durumudur. Bu tür nöbetlerde bilincin varlığı ya da tam bilinçlilik halinin bozulması en önemli ayırt edici etken olmaktadır. (Erbey 2005).

3.2. Makine Öğrenmesi


Günümüzde veri miktarlarının oldukça büyük olması, insan gücü ile yapılacak analizleri olanaksız kılmaktadır. Bu amaçla geçmişteki verileri kullanarak gelecek için tahminlerde bulunacak yöntemlere ihtiyaç duyulmuştur. Bu motivasyonla, makine öğrenmesi yöntemleri geliştirilmiştir. Makine öğrenmesi, geçmiş deneyimleri veya örnek örüntüleri kullanarak daha iyi sonuçlar üretmek üzere geliştirilmişlerdir. Bir başka ifadeyle, mevcut örüntü kümelerinden probleme yönelik çeşitli çıkarımlar yaparlar

3. MATERYAL VE METOT

(Buczak ve ark. 2016). Makine öğrenmesi; bilgisayarla görü, konuşma tanıma, yüz tanıma, sağlık alanında teşhis koyma ve robotik gibi birçok alanda çözüm aracı olarak kullanılabilir.

Makine öğrenmesi; yapay zekada, sayısal öğrenme ve model tanıma çalışmalarından geliştirilmiş bilgisayar biliminin bir alt dalıdır. Makine öğrenmesi, fonksiyonel olarak öğrenebilen ve bu öğrenme sonucu veriler üzerinden kestirim yapabilen algoritmalar bütünüdür (Altay 2019). Makine öğrenimi, hemen hemen her alanda çalışılan bir konudur. Bundan dolayı makine öğrenmesi kapsamında önerilmiş çok sayıda yaklaşım ve algoritma mevcuttur. Bu yaklaşımların bir kısmı tahmin, bir kısmı da sınıflandırma yapabilme becerisini içermektedir. Bu yaklaşımlar, karşılaşılan probleme göre değişkenlik gösterebilir, bundan dolayı farklı problemlerde farklı performans özelliği gösterebilirler (Merih 2018).

Makine öğrenmesinin çeşitli öğrenme stratejileri mevcuttur. Bunlar: Denetimli Öğrenme, Denetimsiz Öğrenme ve Takviyeli Öğrenmedir (Şekil 3.3.).



Şekil 3.3. Öğrenme çeşitleri (Fadlullah ve ark. 2017)


Denetimli Öğrenme, giriş ile çıkışların birbirleriyle örtüştüğü örüntülerden yola çıkarak bir fonksiyonun öğrenilmesini amaçlar. Bu öğrenme türünde, bir gözetici tarafından girişlerle çıkışların birbirleriyle eşleştirilmesi gerçekleştirilir (Alpaydın 2004).

Denetimsiz öğrenmede bir gözetici yoktur. Bu yüzden, bu öğrenme türünde giriş verilerine karşılık bir çıkış (hedef küme) verilmez. Denetimsiz öğrenme herhangi bir çıkış değeri verilmemiş girişler kullanarak, bir örüntü bulmayı hedefler. Bu öğrenme türünde; makine öğrenmesi, belirsiz ve karmaşık bir ortamda bir hedefe ulaşmayı öğrenir. Takviyeli öğrenmede ise; makine öğrenmesi yapılmak isteneni sağlamak adına gerçekleştirdiği eylemler için ödül veya ceza alır. Bu öğrenme türünde amaç, toplam ödülü en üst düzeye çıkarmaktır (Alpaydın 2004).

Günümüzde makine öğrenme yöntemlerinin nerdeyse tüm çalışmalarında derin öğrenme yöntemlerinin kullanılmaya başlandığı görülmektedir. Şekil 3.3. 'te görüldüğü üzere, tüm öğrenme yöntemlerinde (Denetimli/Denetimsiz/Takviyeli) derin öğrenme algoritmaları olduğu görülmektedir.

3.2.1. Yapay Sinir Ağları (YSA)

Yapay Sinir Ağları (YSA), makine öğrenmesi kapsamında kullanılan önemli yaklaşımlardan biridir. YSA, üç katmandan (giriş katmanı, gizli katman ve çıkış katmanı) oluşur; her katman, birbirine bağlı olan ve nöron olarak adlandırılan uyarlanabilir işlem birimlerinden oluşur. Bir nöron, n girdi alan ve tek bir çıktı üreten genel bir hesaplama birimidir. Nöronların çıktılarını ayıran parametre, bağlantı ağırlıklarıdır. Bir katmandaki her bir nöron (birim), bir üst katmandaki tüm nöronlara farklı ağırlıklarla bağlıdır. Giriş katmanı, girdi olarak gelen verileri ağırlıklarla çarparak gizli katmana iletilmesini sağlar (Baxter ve ark. 2001). Gizli katmanda toplanan bu çarpım sonuçlarından çıktı elde etmek için bir transfer fonksiyonu kullanılır. Örnek bir $(n:m:2)$ YSA mimarisi Şekil 3.4'de gösterilmiştir.



Şekil 3.4. Çok katmanlı örnek YSA mimarisi

YSA 'da giriş ve gizli katmanında bulunan her bir nöron, bir sonraki katmanın nöronlarına (Şekil 3.4.) bağlanır ki bu yapı klasik sinir ağları yapısıdır. YSA mimarisinde gizli katman sayısı ihtiyaca binaen artırılabilir. L adet katman ve her katmanda N adet nöron içeren bir ağın eğitilmesi için gereken parametre sayısı hesabı güç bir problem olabilir. Büyük bir parametre yığını ile çalışmak, pratik olmamakla birlikte eğitilemez bir ağın meydana çıkmasına sebep olabilir. Bu tür sorunların üstesinden gelmek için derin öğrenme ağları önerilmiştir.

3.2.2. Derin Öğrenme Ağları

Özellikle son yıllarda bilgisayarlı örüntü tanımada başarılı sonuçların elde edilmesinin altında yatan temel neden, görsel verinin istatistiksel olarak işlenmesinin insan beynine göre uyarlanmasıdır. Bu uyarlamadan geliştirilen derin öğrenme ağları, yapay zekânın kaybettiği popülerliği tekrardan kazanmakta ve üzerinde yoğun çalışmalar yapılmasını sağlamaktadır. Bu kapsamda derin öğrenme algoritmaları ve buna paralel olarak geliştirilen ESA, aktif bir araştırma alanı sağlamaktadır. Klasik makine öğrenmesi ile derin öğrenme arasındaki en önemli fark; derin öğrenmede verilerin ölçeği arttıkça performansın artmasıdır.

Derin öğrenme; kavramları, iç içe geçmiş hiyerarşi olarak değerlendirir. Her kavramın daha basit kavramlarla ilişkili olarak tanımlanmasını sağlar. Bu öğrenme türünde, çoklu işlem katmanlarından oluşan hesaplamalı modellerin, birden fazla özetleme seviyesiyle verilerin temsillerini öğrenmesine olanak tanır. Yöntemin bu yaklaşımından ve performansından dolayı; konuşma tanıma, imge tanıma ve nesne algılama gibi birçok alanda kullanıldığı görülmektedir (Poultney ve ark. 2007; Guo ve ark. 2016; Wang ve ark. 2017; Ravi ve ark. 2017; Jia 2017; LeCun ve ark. 2017; Costilla ve ark. 2017).

Derin öğrenme ağları, kendi içinde oluşturduğu öznitelikleri öğrenme aşamasında geri yayılım algoritmasını kullanır. Sinir ağlarının ve olasılıksal graf modellerinin temsilcileri olarak kullanım alanı yaygınlaşan, eğitim ve mimarisindeki benzerlikleri nedeniyle bir bütün olarak derin öğrenme ismi ile tanımlanan teknikler, verinin doğrusal özniteliklerini çıkarmak yerine daha özet ve karmaşık ilişkilerinin modellenmesini sağlamaktadırlar.

Derin öğrenmenin temelleri yapay sinir ağlarına dayanmaktadır. Çizelge 3.3. 'te derin öğrenmenin günümüze kadar gelişimi gösterilmiştir.


Çizelge 3.3. Derin öğrenmenin gelişimi (Wang ve Raj 2017)

Yıl	Araştırmacı(lar)	Çalışmanın Özellikleri
1943	Warren S. McCulloch ve Walter H. Pitts	Yapay Sinir Modelinin atası olarak kabul edilen MCP Modeli tanıtıldı.
1949	Donald Hebb	Yeni Sinir Ağının temellerini oluşturan Hebbian Öğrenme Kuralı tanıtıldı. Bu kural “Birlikte ateşlenenleri birlikte bağla” şeklinde özetlenebilir. Aynı anda ateşlenen sinir hücreleri, aynı anda ateşlenmeleri halinde sisteme etkileri daha fazla olmaktadır.
1958	Frank Rosenblatt	Modern perceptrona oldukça benzeyen ilk perceptron tanıtıldı.
1974	Paul Werbos	Geri Yayılım Algoritması tanıtıldı.
1980	Teuvo Kohonen	Kendini organize eden harita (Self Organization Map-SOM) sunuldu. Verilerin boyutunu genellikle bir veya iki boyuta indirmek için kullanılan güçlü bir tekniktir.
1980	Kunihiko Fukushima	Evrimsel Sinir Ağı'na ilham kaynağı olan Neocognitron tanıtıldı. Görsel korteks fikrinden yararlanılmıştır.
1982	John Hopfield	Hopfield Ağı tanıtıldı. İkili (Binary) eşik sinir birimleri ile tamamen bağlı bir sinir ağıdır. Bu birimler, çift yönlü ağırlıklarla tamamen bağlantılıdır.
1985	Hilton ve Sejnowski	Boltzmann Makinesi tanıtıldı.
1986	Paul Smolensky	Kısıtlanmış Boltzmann Makinesi olarak da bilinen Harmonium tanıtıldı. Boltzmann Makinesinin bir versiyonudur. Hem görünür hem de gizli birimler arasında bağlantı bulunmaması kısıtlanmıştır.
1986	Michael I. Jordan	Tekrarlı (Recurrent) Yapay Sinir Ağı tanıtıldı.
1990	Yann LeCun	LeNet tanıtıldı. Pratikte derin sinir ağlarının olabilirliği gösterildi.
1997	Yann LeCun	İki Yönlü Yinelemeli Sinir Ağı tanıtıldı.
1997	Schuster ve Paliwal	Tekrarlayan sinir ağlarında sıfırlanan (kaybolan) gradyan sorunu çözüldü.
2006	Geoffrey Hinton	Derin öğrenme Ağları ve katmanlı ön eğitim tekniği tanıtıldı ve derin öğrenme çağı başladı.
2009	Salakhutdinov ve Hinton	Derin Boltzmann Makinelerini tanıtıldı.
2012	Geoffrey Hinton	Sinir ağlarının eğitiminde etkili bir yol olan Dropout tanıtıldı.
2012	Alex Krizhevsky	AlexNet ImageNet yarışmasında sınıflandırma hata oranını %15.3 'e düşürmüştür. 5 evrim ve havuzlama katmanı ile 3 tam bağlantı katmandan oluşturulmuştur. Filtreler 11x11 boyutunda belirlenmiştir. Bu mimari 1000 nesneyi sınıflandıracak şekilde tasarlanmıştır.
2014	Simonyan ve Zisserman (Görsel Geometri Grubu - VGGNet)	Bu mimari, ILSVRC 2014 yarışmasında önerilmiştir. Model, ağ derinliğinin ESA mimarisinde kritik bir bileşen olduğunu göstermiştir. VGGNet, düzgün bir mimariye sahiptir.
2014	Christian Szegedy (GoogLeNet)	2014 yılında yapılan ImageNet yarışmasını, 22 katmanlı ve %5.7 hata oranı ile GoogLeNet kazanmıştır. Birbirine bağlı modüller kullanılır.
2015	Kaiming He (Microsoft ResNet)	Bu mimari 152 katmanda oluşmaktadır. ILSVRC 2015 yılında yapılan yarışmada %3,6 hata oranı ile birinci olmuş bir yapıdır.
2016	FractalNet Şirket Araştırmacıları	FractalNet mimarisi, nominal derinliğe sahip büyük modellerin tasarlanması için önerilmiştir. ResNet modelinin gelişmiş ve alternatif bir mimarisidir.

3. MATERYAL VE METOT

2017	Gao Huang ve ark. (DenseNet)	Yoğun Bağlantılı Ağ (DenseNet), iki bitişik yoğun blok arasına yerleştirilmiş birkaç yoğun blok ve geçiş bloğundan oluşur.
2017	Sabour ve ark. Kapsül ağları (CapsNet)	Bu ağ, özelliklerin özünü içermeye yaklaşımına dayanmaktadır. Bu mimari, farklı bilgilerle yüzleri verimli bir şekilde algılamayı hedeflemiştir. Kapsül ağları, birkaç kapsül katmanından oluşur. Kapsül ağının ilk versiyonu (CapsNet), üç katman kapsüllü düğümde oluşturulmuştur.

Derin öğrenmenin, 1943 yılında McCulloch ve Pitts 'in ilkel sinir ağını elektrik devreleri ile modellemesi ile başladığı söylenebilir. Derin öğrenme çalışmalarından en önemli kilit taşı; 1980 'lerde Kunihiro Fukushima'nın Neocognitron yapısını tanıttmasıdır. Bu yapı, görsel korteks fikrinden yararlanılarak oluşturulmuş ve günümüzde popüler olan ConvNet'in ilham kaynağı olmuştur. Neocognitron yapısı, Şekil 3.5.'te verilmiştir.



Şekil 3.5. Neocognitron yapısı (Fukushima 1998)

Bu yapı, iki farklı katmandan oluşan bir sinir ağıdır. Yapıda, öznelik çıkarıcı olarak S-katmanı ve çıkarılan özellikleri düzenlemek için yapısal bağlantı sağlayan C-katmanı bulunur. S-katmanı, birçok S-hüresinden oluşur ve bu hücreler görsel korteks hücresi olup özellik çıkarıcı olarak işlev görür. Her bir S-hücresi, alıcı alanından sunulan özelliğe duyarlı bir şekilde eğitilebilir. Bu yapıda, yerel özellikler alt katmanlarda çıkarılırken, genel özellikler üst katmanlardan elde edilir. C-katmanı, görsel korteksin üst yolundaki kompleks hücrelere benzetilmiştir. Parametre öğrenme işlemi sırasında yalnızca S-katmanının parametreleri güncellenir. S-katmanlarından iyi bir özellik elde etmek için denetimsiz olarak eğitilebilmektedir. Bu yapı insanın nesnelere algılama yapısına oldukça benzemektedir. Bu çalışmaları takip eden süreçte, özellikle 2006 yılında Geoffrey Hinton tarafından başlatılan ve aynı yıl birçok çalışma yapılan derin öğrenme

yaklaşımı, nesne tanıma, konuşma ve doğal imgelerin incelenmesi gibi birçok alanda başarıyla kullanılmıştır (Poultney ve ark. 2007; Hinton ve ark. 2006).

3.2.3. Derin Öğrenme Mimarileri

Günümüzde veri madenciliği alanında derin öğrenme mimarileri, birçok alanda farklı amaçlar için kullanılmaktadır. Bunun en önemli nedeni, bu mimarilerin ilgili algoritmalar ile verilerden öznitelikleri otomatik olarak elde edebilmesidir. Derin öğrenme mimarileri, karmaşık gösterimlere ilişkin özneliği çıkarmak için büyük miktarda denetimli veya denetimsiz veri kullanabilmektedirler. Bu mimariler bunu gerçekleştirirken, insan beyninin karmaşık problemleri çözmek için var olan gözleme, analiz etme, öğrenme ve karar verme yeteneğini taklit ederler (Kayaalp ve Süzen 2018).

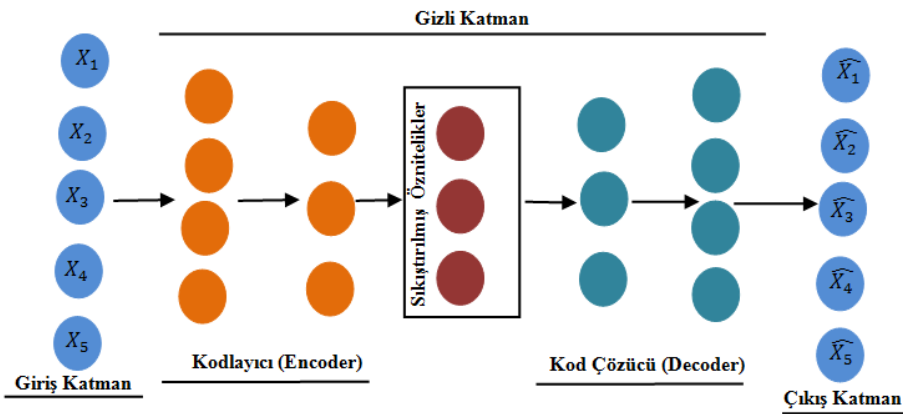
Diğer taraftan, karar ağaçları, DVM gibi sık öğrenme mimarilerine dayanan modeller, karmaşık yapılardan faydalı bilgiler çıkarmaya çalışırken yetersiz kalabilmektedir. Buna karşılık derin öğrenme mimarileri, verideki çevre değişiminden (komşuluk bağlantılarından) bağımsız ilişkiler üretebilme kabiliyetine sahiptirler. Bu işlevleri gerçekleştirirken verilerin karşılığı olan karmaşık gösterimleri elde edilir. Yapay zekanın amacı, insan bilgisinden bağımsız ve değişmeyen öznitelikler elde etmektir. Bu amaç doğrultusunda geliştirilen derin öğrenme mimariler ile verilerin karşılığı olan karakteristiklerin daha düşük boyutlu formunda elde edilmesini sağlarlar.

Derin öğrenme ağları, ardışık katman mimarisine dayanmaktadır. Bu mimarilerde veriler (örneğin görüntüdeki pikseller), ilk katmandan itibaren işlenmeye başlar ve her katmanın çıktısı bir sonraki katmana girdi olarak uygulanır. Derin öğrenme katmanlarında işlenecek olan bir örüntü (örneğin imge), ilk etapta piksel değerleri formuna dönüştürülür. Bu piksel değerleri girdi olarak ağa verilir ve ilk katmana gelir. İlk katmanda, görüntünün belirli yön ve konumuna ait kenar yapılarının özellikleri öğrenilir. İkinci katmanda, belirli kenar yapılarını öğrenen mimari, bunları birleştirerek desenleri tespit eder ve üçüncü katmana iletir. Üçüncü katmanda, örüntünün benzer parçalarına karşılık gelen daha büyük desenler birleştirilir. Mimarinin sonraki katmanlarında ise örüntü, elde edilen desenlerin bir kombinasyonu olarak algılanır (LeCun ve ark. 2015). Derin ağ mimarilerindeki bu katmanlarda, verilerdeki ayırt edici faktörleri çıkarmak amacıyla doğrusal olmayan dönüşüm yöntemleri kullanılır.

Literatürde, derin öğrenme kapsamında farklı mimarilerin türetildiği görülmektedir. Otomatik Kodlayıcılar, Boltzmann Makineleri, Kısıtlı Boltzmann Makineleri ve ESA mimarileri sıklıkla kullanılan mimariler olduğu görülmektedir.

3.2.4. Otomatik Kodlayıcılar

Genel olarak, makine öğrenmesinde veriye dayalı öğrenmeden elde edilen öznitelikler, veriyi daha başarılı bir biçimde temsil edebilmektedir. Otomatik Kodlayıcı, bu amaç için tasarlanmış klasik bir yapay sinir ağıdır. Spesifik olarak, bir Otomatik Kodlayıcı, Şekil 3.6. 'da gösterildiği gibi aynı sayıda giriş ve çıkış nöronuna sahip bir yapıda oluşur. Bu yapı, giriş verilerine sınıf etiketi atamak yerine, giriş vektörünü yeniden oluşturmak için eğitilir (Ravive ark., 2016). Bu nedenle, bu yöntem denetimsiz bir öğrenmedir. Bu yöntemde, girdi verileri yüksek boyutlara sahip ise, tüm verileri temsil etmek için sadece bir gizli katmanın kullanımı yeterli olmayabilir. Bunun çözümü için birçok otomatik kodlayıcı sıralı olarak bağlanır ve böylelikle derin bir otomatik kodlayıcı mimarisi oluşturulmuş olunur (Ravive ark., 2016).

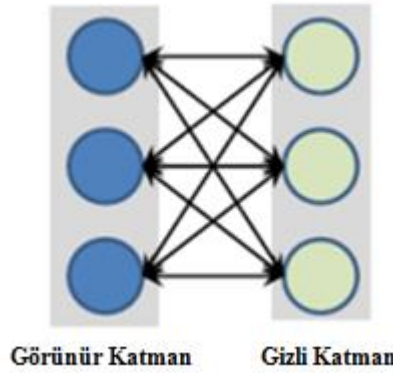


Şekil 3.6. Otomatik Kodlayıcı için örnek yapı

Şekil 3.6'da görüldüğü üzere, girdi olarak verilen veri seti kodlayıcı katmanında aktivasyon fonksiyonundan geçirilerek sıkıştırılır. Bunun sonucu olarak veriye ait küçük boyutlu sıkıştırılmış öznitelikler elde edilir. Sıkıştırılmış özniteliklerden giriş verilerine benzer çıkışlar üretmek için kod çözücü katman kullanılır. Kod çözücü katman sıkıştırılmış veriyi aktivasyon fonksiyonundan geçirerek girdi vektör boyutu kadar çıktı üretir. Buradaki amaç, verinin farklı nitelikte gösterimini sağlamaktır (Ravive ark. 2016).

3.2.5. Kısıtlı Boltzmann Makineleri

Kısıtlı Boltzmann makinesi (KBM), Geoffrey Hinton tarafından önerilmiştir. KBM, stokastik bir YSA olan Boltzmann makinesinin bir çeşididir. Bu tür ağlar, belirli bir dağılıma sahip (Gaussian dağılımı gibi) olan stokastik birimlerin kullanılması ile modellenmiştir. Öğrenme prosedürü, Gibbs örnekleme adı verilen ve yeniden yapılandırma hatasını en aza indirmek için ağırlıkları kademeli olarak ayarlayan birkaç adım içermektedir (Ravive ark. 2016; Zhao ve ark. 2016).




Şekil 3.7. Kısıtlı Boltzmann makinesi
(Ravive ark. 2016)

Şekilde 3.7. 'de görüleceği üzere KBM 'de, birinci katman görünür, ikinci katman ise gizli katman olarak adlandırılır. KBM 'lerde hesaplamalar gizli katman düğümlerinde gerçekleşir. Görünür katmandaki düğümlere girdi olarak gelen veriden bir özellik alınır. Görünür katmanda bulunan düğümlerdeki verilerin işleme alınabilmesi için gizli katmanın bir düğümüne iletilir. Bu işlem tüm gizli katmandaki düğümler için gerçekleştirilir. Bu yapıda girdilerden çıkış alabilmek için aktivasyon fonksiyonları kullanılır (Ravive ark. 2016; Kayaalp ve Süzen 2018).

3.2.6. Derin Boltzmann Makineleri

Derin Boltzmann Makinesi (DBM), olasılığın alt sınırını maksimize etmek için stokastik bir maksimum olabilirlik algoritması kullanır. Boltzmann ailesine dayanan bu makine öğrenme yaklaşımı, ağın tüm katmanları arasında yönlendirilmemiş bağlantılara (koşullu olarak bağımsız) sahiptir (Şekil 3.8.). Bu da DBM 'nin en büyük dezavantajlarından biri olmaktadır. Diğer bir deyişle, görünür birimler ile gizli birimler arasındaki etkileşimlerden dolayı, arka dağılımın hesaplanması için olasılığın alt sınırının doğrudan maksimize edilememesi, söz konusu dezavantajı oluşturmaktadır. Bu sebeple


stokastik maksimum olabilirlik tabanlı algoritma, DBM 'nin eğitiminde olasılığın alt sınırını maksimize etme amacı ile kullanılır (Ravive ark., 2016).



Şekil 3.8. Derin Boltzman makinesi (Ravive ark. 2016)


3.2.7. Tekrarlayan Sinir Ağları (RNN)

Tekrarlayan sinir ağları 1990 yılından Jeff Elman tarafından önerilmiştir. Bu ağ yapısında; giriş katman ve gizli katman olmak üzere iki katman bulunur. Tekrarlayan sinir ağları, ardışık bilgilerin kullanılması mantığına dayanmaktadır. Bu ağ yapısındaki gizli katman, çıktısını tekrar kendi girişine yönlendirmektedir. Bu işlevinden dolayı bu ağlar tekrarlayan olarak isimlendirilir. Şekil 3.9. 'da gösterilen ağ mimarisinde, X ve h değişkenleri sırasıyla ağın girdi ve çıktı değerini, A ise gizli katmanı temsil etmektedir.



Şekil 3.9. Tekrarlayan ağ mimarisi

Şekil 3.10.'da gösterildiği gibi Tekrarlayan sinir ağlarının bu çalışma yaklaşımı ile girdi ve çıktı arasında farklı korelasyonların kurulumu sağlanır.



Şekil 3.10. Tekrarlayan ağların çalışma biçimleri

3.2.8. Evrişimsel Sinir Ağları (ESA)

Büyük veri (Big data) genellikle, geleneksel veri tabanlarının ve veri analiz tekniklerinin tipik depolama, işleme ve hesaplama kapasitesini aşan veriler olarak ifade edilir. Uzmanlar açısından, büyük veriden girdi olarak gelen her yeni veri türünden özellikler çıkarmak geleneksel veri analizi yaklaşımları ile zorluklar içerirken, derin öğrenme ağları sayesinde bu zorluk aşılabilmektedir. Derin öğrenme algoritmaları her katman için önceden tanımlanmış bir temsil dizisi oluşturmaz, bunun yerine genel olarak farklı katmanlarda doğrusal olmayan dönüşümleri gerçekleştirir. Bu dönüşümler, verilerdeki varyasyon faktörlerini çözme amaçlıdır. Yukarıda sözü edilen katmanlı yapılardan biride Evrişimsel Sinir Ağıdır (ESA). Bu ağın adı, evrişim filtresini kullanarak karmaşık işlemleri gerçekleştirmenin kolay bir yolu olan evrişim operatöründen gelir.

ESA, görüntü sınıflandırma yöntemlerinde ve öznelikleri öğrenmede en yaygın kullanılan derin öğrenme mimarisidir. ESA, biyolojik sinir ağından esinlenerek geliştirilmiştir. Genel olarak bir ESA mimarisi; evrişim, pooling ve tam bağlı katman olmak üzere üç temel katmandan oluşur. Bu katmanların her biri farklı görevlerde kullanılmaktadır.

a) Evrişim Katmanı

Evrişim işleminde bir pikselin çıkış değeri, kendisinin ve komşu piksellerin değerlerinin bir ağırlıklı toplamı olarak elde edilir. Ağırlıklar matrisi, evrişim filtresi (kernel) olarak adlandırılır. ESA mimarisinde ağırlıklar, ağın görüntüler üzerinde evrişim işlemleri gerçekleştireceği şekilde paylaşılır. Bu şekilde, mimari, bir görüntünün farklı konumlarda meydana gelen aynı özellikleri için ayrı bir algılayıcı oluşturmaz. Bu da giriş örneklerini dönüştürmede ağın eşit olmasını sağlar. (Poultney ve ark. 2007; Guo ve ark. 2016; Wang ve ark. 2017; Ravi ve ark. 2017; Jia, 2017; LeCun ve ark. 2017; Costilla ve ark. 2017). ESA mimarisi bu katmanda, çeşitli öznelilik haritalarını oluşturmak, tüm

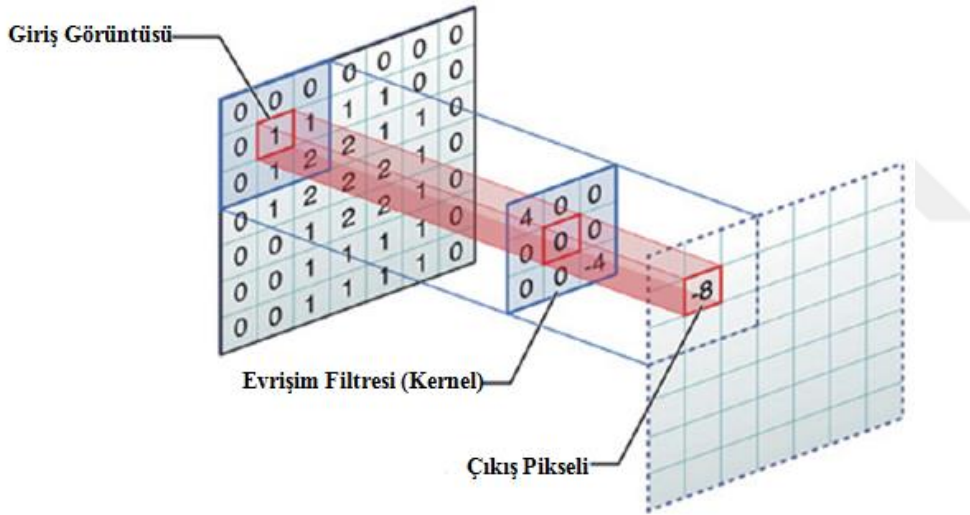
3. MATERYAL VE METOT

görüntüyü bu öznetellik haritalarında birleştirmek için çeşitli filtreler kullanır. Evrişim işleminin üç temel avantajı vardır: **a)** Aynı özellik haritasındaki ağırlık paylaşım mekanizması, parametre sayısını azaltır, **b)** Local bağlantı sayesinde, komşu pikseller arasındaki korelasyonlar öğrenilir, **c)** Örüntünün konumuna göre değişmezdir (Jia, 2017).

Temel olarak evrişim işlemine ilişkin hesap, eşitlik 3.1'de verilmiştir.


$$b_k = \sum_{n=0}^{N-1} x_n h_{k-n} \quad (3.1)$$

Burada; b , x , h ve N sırasıyla çıkış vektörünü, işaretin kendisini, filtreyi ve eleman sayısını ifade eder. Evrişim işleminin görüntü piksellerine uygulanması ilişkin örnek bir hesap, Şekil 3.11 'de gösterilmiştir.



Şekil 3.11. Evrişim işlemine ilişkin bir örnek uygulama (Lee ve ark. 2017)

Evrişim işleminin bir sinir hücresine uyarlanması işlemleri Şekil 3.12. 'de verilmiştir.




Şekil 3.12. Evrişim işleminin bir sinir hücresine uyarlanması
(Jia 2017)

Genel olarak bir ESA mimarisinde, evrişim işleminden sonra aktivasyon işlemi gerçekleşir. Derin öğrenme ağlarında aktivasyon işleminde sıklıkla, Doğrultulmuş Lineer Birim (Rectified Linear Unit, ReLU) fonksiyonu kullanılır. Bu fonksiyon derin öğrenme ağları için oluşturulmuştur (Bashivan ve ark. 2015). ReLU aktivasyon fonksiyonuna ilişkin matematiksel ifade, Eşitlik 3.2 'de verilmiştir.

$$f(x) = \begin{cases} 0 & \text{if } x < 0 \\ x & \text{if } x \geq 0 \end{cases} \quad (3.2)$$

ReLU aktivasyon fonksiyonu Şekil 3.13. 'te verilmiştir.

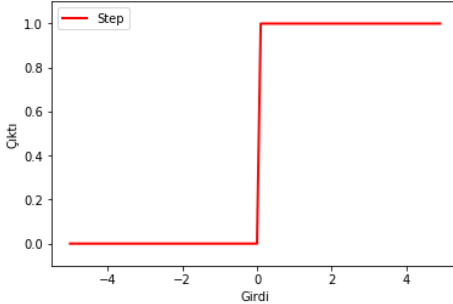
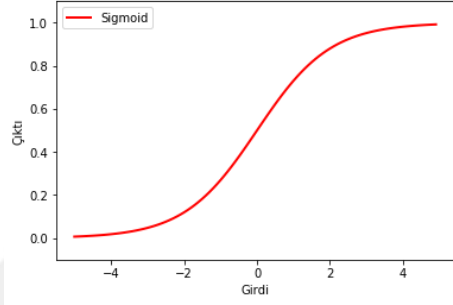
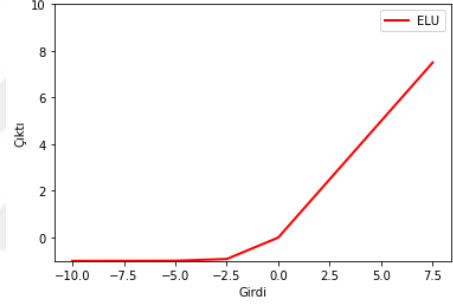
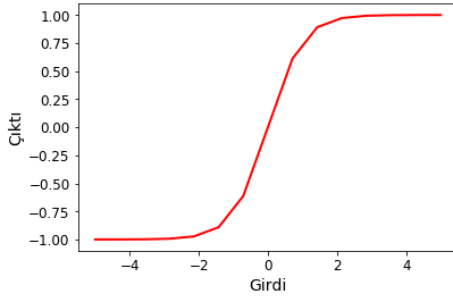


Şekil 3.13. ReLu aktivasyon fonksiyonu

Bu aktivasyon fonksiyonu dışında kullanılacak aktivasyon fonksiyonları da mevcuttur. Bu fonksiyonlardan bazıları çizelge 3.4 'te verilmiştir.

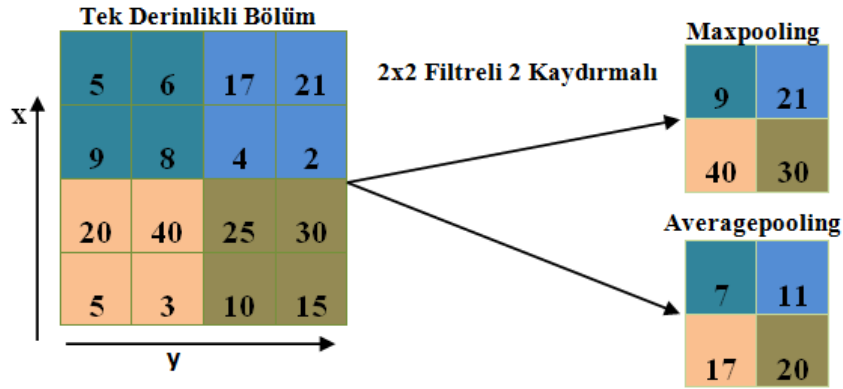
3. MATERYAL VE METOT

Çizelge 3.4. Aktivasyon fonksiyonları

Fonksiyon Adı	Denklemi	Grafik
Step	$f(x) = \begin{cases} 1 & \text{eğer } x \geq 0 \\ 0 & \text{eğer } x < 0 \end{cases}$	
Sigmoid	$f(x) = \frac{1}{1 + e^{-x}}$	
ELU	$f(x) = \begin{cases} x & \text{eğer } x \geq 0 \\ a(e^x - 1) & \text{eğer } x < 0 \end{cases}$	
TanH	$f(x) = \frac{2}{1 + e^{-2x}} - 1$	

b) Pooling Katmanı (Havuzlama)

Pooling katmanında, ESA mimarisine verilen görüntülerin küçültülmesi ve parametre sayısını azaltılması amaçlanır. Havuzlama katmanı, görüntü haritasındaki komşu nöron gruplarının çıktılarını özetlemektedir. Bu katman, doğrusal olmayan alt örnekleme bir biçimindedir. Pooling işleminde, giriş görüntüsünden örtüşmeyen dikdörtgenler kümesi oluşturulur. Oluşturulan bu her alt bölgenin (dikdörtgenin) maksimum veya ortalama değeri elde edilir. Bu yöntem kullanılarak, görüntülerin istenildiği kadar küçültülmesi sağlanabilmektedir. (Uktveris ve Jusas 2017; Jia 2017).



Şekil 3.14. Maksimum ve ortalama pooling işlemi için örnek bir uygulama

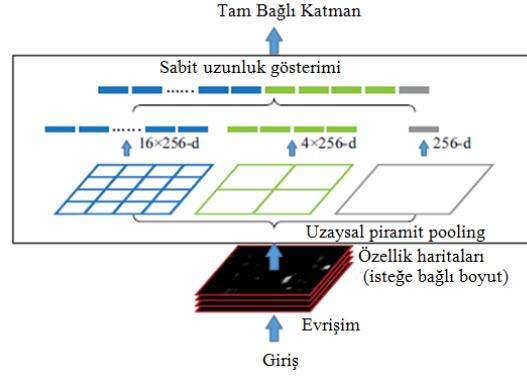
Örüntü haritasına 2x2 maxpooling ve averagepooling işleminin 2 adım (piksel) kaydırılarak uygulanması sonucu elde edilen örnek bir uygulama Şekil 3.14’de gösterilmiştir. Böylelikle görselin içindeki piksellerin maksimumu ve ortalaması elde edilmiş ve çıkışta 4’te 1 boyutlu bir veri (16 piksel içeren bir görüntüden 4 piksellik çıktı) elde edilmiş olur.

Ortalama ve maksimum pooling işlemlerinden farklı olarak kullanılabilir yöntemlerde mevcuttur. Bunlar; stokastik pooling, uzaysal piramit pooling ve def-pooling yöntemleridir.

Stokastik Pooling: Maksimum pooling işleminin önemli bir dezavantajı eğitim setinde aşırı uyarlamaya duyarlı olmasıdır. Böylece test örneklerinin genelleştirilmesi oldukça zor olmaktadır. Bu problemin üstesinden gelebilmek için stokastik pooling işlemi önerilmiştir. Aynı pooling bölgesinde, ağa bilgi aktarırken dikkate alınması gereken ek aktivasyonlar olabilmektedir. Stokastik pooling, bu maksimize edilmeyen etkinleşmelerin de kullanılmasını sağlamaktadır. Dolayısıyla, stokastik pooling, bir bölgedeki aktivasyonların çoklu mod dağılımlarını temsil etmektedir. Bu yöntem kullanılarak, ezberleme sorununun çözümü için sağlıklı sonuçlar elde edilebilmektedir. (Zeiler ve Fergus 2013).

Uzaysal piramit pooling: ESA tabanlı yöntemler sabit boyutlu imgeler üzerinde uygulanmaktadır. Algoritmanın sabit boyutlu giriş görüntüsü için tasarlanması, rastgele boyutlu için yapılan analizlerde elde edilecek performansları düşürmektedir. Uzaysal piramit pooling işlemi ile elde edilecek öznetelik vektör görüntüsü her boyutta olabilir. Böylelikle farklı boyuttaki görüntülerin analizinde başarılı sonuçların elde edilmesi

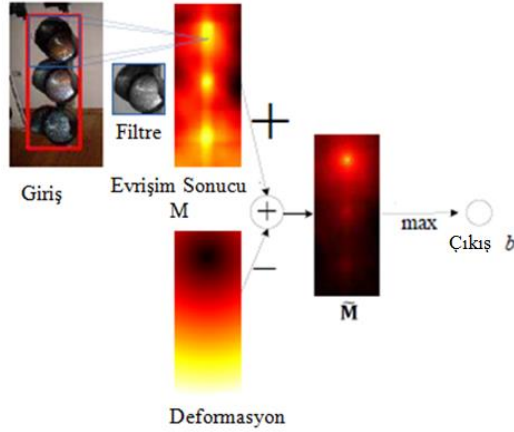
mümkün olabilmektedir (He ve ark. 2015). Şekil 3.15. 'te Uzaysal bir piramit pooling işlemi gösterilmektedir.



Şekil 3.15. Uzaysal piramit pooling katmanı ile ağ yapısı (He ve ark. 2015)

Uzaysal piramit pooling 'nin çıktı vektörleri filtre sayısına bağlı olmaktadır. Uzaysal piramit pooling girdi görüntüsü her boyutta olabilir. Ayrıca isteğe bağlı en ve boy oranları dışında, aynı zamanda isteğe bağlı ölçeklere de izin vermektedir (He ve ark. 2015).

Def-pooling: Özellikle obje tanıma görevlerinde deformasyonun ele alınması, bilgisayarlı görü uygulamalarında maliyetli bir uğraştır. Maksimum ve ortalama pooling işlemleri kullanılarak objelerin geometrik modelleri öğrenilemez. Geliştirilen def-pooling işlemi ile örüntülerin deformasyonları öğrenilerek, derin öğrenme mimarisi zenginleştirilmeye çalışılmıştır. Def-pooling tabakası, maksimum pooling tabakasının değiştirilmesi ve örüntülerin deformasyon özelliklerinin herhangi bir bilgi özetleme seviyesinde öğrenilmesi için kullanılabilir (Ouyang ve ark. 2015). Def-pooling işlemine ilişkin örnek bir görsel uygulama Şekil 3.16'da gösterilmiştir. Şekil 3.16, örüntü tespit haritası ve deformasyonu özetlemektedir. Burada blok-bazlı maksimum pooling, deformasyon ve öznitelik haritalarının toplamından elde edilir. Böylece boyut b çıktısı elde edilir.

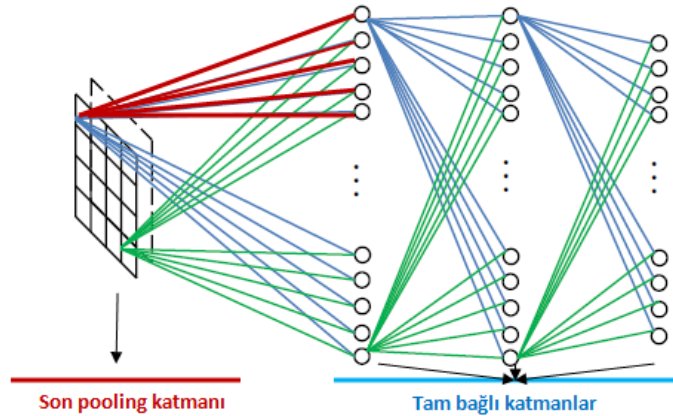


Şekil 3.16. Def-Pooling katmanına ilişkin örnek bir görsel uygulama (Ouyang ve ark. 2015)

Çalışmalarda farklı havuzlama yöntemlerinin kullanılabildiği görülebilmektedir. Farklı görevler için tasarlanmış olan bu havuzlama yöntemlerinin farklı avantaj ve dezavantajları bulunmaktadır. Bu çalışmada iyi sonuçlar vermesi nedeniyle maksimum pooling kullanılmıştır (Boureau 2010).

c) Tam Bağlı Katman

Tam bağlı katman, geleneksel bir sinir ağı gibi performans gösterir ve bir ESA mimarisindeki parametrelerin yaklaşık %90 'ını içerir. Önceki katmandan gelen çok boyutlu veriler, tam bağlı katmana uygulanabilmesi için önceden tanımlanmış uzunluktaki bir vektöre dönüşümü sağlar. Bu sayede, verinin desenine ilişkin öznelilikler, bir boyutlu öznelilik vektörlerine dönüştürülür (Lin ve ark. 2013). Bu işlem vektörizasyon olarak adlandırılır. Son pooling katmanından sonra oluşan tam bağlı katman, Şekil 3.17. 'de gösterilmiştir. Tam bağlı katmanın, çok fazla parametre içermesinden dolayı, hesaplama yükü de paralelinde artmaktadır.




Şekil 3.17. Tam bağlı katman (Guo ve ark. 2016)

d) Sınıflandırma Katmanı (Softmax)

Son katmandaki özellik haritaları, tam bağlı katmanlara iletilirken, skaler değerlere sahip vektörlere dönüştürülür. Tam bağlı ileri beslemeli sinir ağı katmanları, Softmax fonksiyonunu sınıflandırma katmanı olarak kullanır. Softmax fonksiyonu, k adet çıkış sınıflarının olasılık dağılımını Eşitlik 3.3'de verildiği şekilde hesaplar.

$$p_j = \frac{e^{x_j}}{\sum_{k=1}^k e^{x_k}} \quad j = 1, \dots, k \quad (3.3)$$

Buradaki x değişkeni girişi ifade eder. p değişkeni ise çıkışı ifade etmekle birlikte, elde edilen değerler 0 ile 1 aralığında ve toplamları 1'e eşit olur. Örneğin, bir softmax fonksiyonunun giriş verilerine karşılık verebileceği çıkışlar Şekil 3.18'de gösterildiği şekilde olabilir.



Şekil 3.18. Softmax fonksiyonu

e) Öğrenme Stratejileri


Derin öğrenme diğer bilinen öğrenme algoritmaları ile kıyaslandığında analizi yapılacak örüntülerden daha özetlenmiş bilgiyi derin mimarisi ile çıkarabilmektedir. Ancak derin mimari klasik yöntemlere göre daha fazla parametre barındırdığından çeşitli dezavantajlara sahip olacaktır. En önemli dezavantajlardan biri ezberleme (overfitting) problemidir. Başka bir ifade ile algoritma esas problemi çözmekten uzaklaşır ve kendisine verilen hedefleri tutturmaya çalışır. Anlık çözümlerde mükemmel sonuçlar doğurmasına karşın, asıl çözmesi gereken problemi çözmekten uzaklaşır. Bu şekilde parametrelerin aşırı derecede uygunlaştırılması ve esnekliğin ortadan kaldırılması, sinir ağı öğrenme yaklaşımında uygul görülemez. Buna karşı derin ağ mimarilerindeki hedef, verilen problemler için uygun genelleştirmenin yapılabilmesidir. ESA mimarisinde yukarıda bahsi edilen ezberleme durumundan kaçınmak için bir takım düzenlemeler

uygulanır. Ağın eğitim performansını etkileyen birtakım düzenlemeler aşağıda listelenmiştir (Wan ve ark. 2013).

Aktivasyon Kesici (Dropout)

Bağlantı Kesici (Drop Connect)

Söz konusu düzenlemelerin çalışma yaklaşımları şekilsel olarak Şekil 3.19'da gösterilmiştir.



Şekil 3.19. Ezberlemenin önüne geçmek için izlenen stratejik düzenekler (Jia 2017)

Bu düzenlemeler içinde literatürde en sık kullanılan yaklaşım, aktivasyon kesicidir (dropout). Derin ağ mimarilerinde aktivasyon kesici (dropout) tekniği, ağın aşırı öğrenmesini engellemek için kullanılır. Bu yaklaşım ile ağ yapısının gizli katmanlarındaki bazı nöronların bağlantıları kesilir. Bağlantıları kesilen bu nöronlar ağ dışında bırakılır. Örneğin, dropout oranı 0.5 olarak belirlendiği zaman, gizli katmandaki nöronların %50 oranı kullanılmayacak anlamına gelir. Böylelikle küçülen ağ ile aşırı öğrenmenin önüne geçilmiş olunur.

Bağlantı kesici (Drop Connect), aktivasyon kesiciden (Dropout) türetilmiştir. Bu teknikte, rasgele seçilen ağırlıklar sıfırlanır (Wan ve ark. 2013).

Günümüze kadar farklı amaçlar için geliştirilmiş çeşitli ESA mimarileri mevcuttur. Bu mimarilerden bazıları büyük veri analizlerinde, bazıları ise genel amaçlı olarak tasarlanmıştır. Bu mimarilerin bazılarının detayları aşağıda açıklanmıştır.

LeNet-5: 1998 yılında LeCun ve arkadaşları tarafından geliştirilmiştir. Bu mimari, rakamları sınıflandırmak için tasarlanmıştır. Sayısallaştırılmış banka çeklerinin üzerindeki el yazısı rakamlarını tanımak için kullanılan bu mimaride, 7 evrişim katmanı kullanılmıştır. Uygulamada her giriş imgesi, gri tonlamalı ve 32x32 piksel boyutuna


VGGNet: ILSVRC 2014 yarışmasında önerilen bu mimari, Simonyan ve Zisserman tarafından geliştirilmiştir. Model, ağ derinliğinin ESA mimarisinde kritik bir bileşen olduğunu göstermiştir. Bu mimaride, ReLU aktivasyon fonksiyonunu kullanan evrişim katmanları bulunur. Evrişim katmanlarından sonra maksimum havuzlama işlemi gerçekleştirilir. Birkaç tane tam bağlı katman bulunduran bu mimaride sınıflandırma için Softmax katmanı kullanılır. VGGNet, düzgün bir mimariye sahip olmakla birlikte, AlexNet mimarisine benzer bir yapısı vardır. VGGNet mimarisi Şekil 3.23’de gösterilmiştir.



Şekil 3.23. VGGNet yapısı (Alom ve ark. 2018)


Mimaride, yalnızca 3x3 boyutlu filtreler kullanır. Özellikle görüntülerden öznitelik çıkarmak için tercih edilmektedir. Ayrıca VGGNet mimarisi, 138 milyon parametreden oluşur.

Microsoft RestNet: 52 katmanda oluşan bu mimari, en derin öğrenme mimarilerinden biri olarak tasarlanmıştır. 2015 yılında yapılan yarışmada %3.6 hata oranı ile birinci olmuş bir yapıdır (İnik ve Erkan 2017). Microsoft RestNet mimarisi Şekil 3.24.’te gösterilmiştir.



Şekil 3.24. Microsoft RestNet Yapısı (He ve ark. 2016)

Şekil 3.25 ’de görüleceği üzere, bu mimari Residual bloklardan oluşmaktadır. Bir x girdisinin evrişim-ReLu-evrişim işleminden sonra bir $F(x)$ değeri elde edilmektedir. Elde edilen bu sonuç, x girişine eklenmekte ve bu işlem $H(x) = F(x) + x$ olarak ifade edilmektedir (İnik ve Erkan 2017).



Şekil 3.25. Microsoft ResNet 'in yapı bloku (He ve ark. 2016)

Geliştirilen derin öğrenme mimarileriyle beraber, bu mimarilerin uygulama alanları için programlama dillerinde farklı kütüphaneler oluşturulmuştur. Derin öğrenme uygulamalarında kullanılan kütüphanelerin bazıları bir sonraki başlıkta açıklanmıştır.

3.2.9. Derin Öğrenme Kütüphaneleri

Farklı uygulamalar için geliştirilen derin öğrenme mimarilerinde, farklı programlama dilleri kapsamında farklı kütüphaneler servis edilmiştir. Bu bölümde Python programlama dilinde kullanılan kütüphaneler anlatılmıştır.

a) Keras

Keras, içinde birçok derin öğrenme kütüphanesi barındıran bir programlama arayüzü sunar. Aynı zamanda TensorFlow kullanımına da izin verir. Keras derin öğrenme kütüphanesi kullanılarak, sıralı katmanlardan oluşan ağ mimarileri oluşturulabilir. Bu tez çalışması kapsamında, önerilen ağ mimari yazılımı python ortamında, Keras derin öğrenme kütüphanesi kullanılarak gerçekleştirilmiştir.

b) TensorFlow

TensorFlow, Google'ın büyük ölçekli makine öğrenme mimarilerinin uygulanması ve dağıtılması için kullandığı bir sistemdir. Derin öğrenme merkezli bir uygulama olmasına rağmen, TensorFlow diğer öğrenme algoritmaları da dahil olmak üzere çok çeşitli mimarileri desteklemektedir.

Bir TensorFlow mimarisi, bir hesaplamayı temsil eden veri akışı grafiğidir. Bu mimari açık kaynaklı bir derin öğrenme kütüphanesidir. Grafiklerdeki düğümler çeşitli işlemleri temsil etmektedir. Bu düğümler; toplama ve matris çarpımı gibi matematiksel fonksiyonları, sabitleri, indeksleri, tensör değerlerinin başlangıç değerleri için işlemleri, hata ayıklama işlemleri için günlük özetleri (log) ve tasarlanan modele ait parametrelerin depolanması için gereken farklı işlemleri temsil eder.

c) Theano

Theano, çok boyutlu dizileri (tensörleri) ve matematiksel hesaplamaları hızlı bir şekilde gerçekleştirebilen bir Python kütüphanesidir. Derin öğrenmede kullanılan büyük sinir ağ algoritmalarında gerekli hesaplama türlerini gerçekleştirmek için tasarlanmıştır.

3.2.10. K En Yakın Komşu (k-NN) Algoritması

k-NN algoritması, basit ve gürültülü verilerde bile iyi sonuç vermesi nedeniyle örüntü tanıma ve veri madenciliğinde yaygın olarak kullanılmaktadır. Bu algoritmada benzerlik, özellik alanındaki uzaklıkla ölçülmektedir. Bu nedenle bu algoritmaya K En Yakın Komşu algoritması denir. k-NN algoritması, özellik uzayındaki bir t_i noktasına en çok benzer örneklerin bulunduğu belirli bir kategori olması durumunda, t_i noktasının bu kategoriye girdiğine karar verir. Bu sınıflandırıcıda, eğitime verilecek veri setinin etiketi bilinmelidir. Daha sonra, etiketi bilinmeyen ve özellik alanında bir vektör tarafından ortaya koyulan bir t_i verisi için, eğitim veri setindeki her nokta ile arasındaki mesafe hesaplanır. Mesafelerin hesaplanma sonuçları sıraladıktan sonra, en yakın k değerine göre, t_i test verisinin sınıf etiketi belirlenir. n -boyutlu uzayda her noktanın koordinatları, p -vektörü olarak ifade edilebilir (Eşitlik 3.4.). (Kuang ve Zhao 2009).

$$p = (p_1, p_2, p_3, \dots, p_n) \quad (3.4)$$

Çok boyutlu özellik uzayındaki iki nokta arasındaki mesafeyi hesaplamak için genellikle Öklid uzaklığı kullanılır. Öklid uzaklığının hesaplanması Eşitlik 3.5. 'te verilmiştir.

$$\text{öklit}(p, t) = \sqrt{\sum_{i=1}^n (p_i - t_i)^2} \quad (3.5)$$

Bu tez çalışmasında, k değeri farklı değerlerde denenmiş ve en iyi performansın 3 olduğu belirlenmiştir.

3.3. Dalgacık Dönüşümü

EEG verilerinden güç ve faz bilgisi elde etmekte kullanılan en önemli yöntemlerden biri Dalgacık Dönüşümüdür (DD). DD yöntemi, işaretlerin zamana bağlı frekans değişimlerini ele alan alternatif bir yöntem olup ilk olarak Dennis Morlet

tarafından ortaya konmuştur. Dalgacık dönüşümü de tıpkı diğer dönüşüm yöntemlerinde olduğu gibi temel olarak işaretin ve çekirdek işaretin yer aldığı bir evrişim işlemi sayesinde gerçekleşir. Dalgacıklar diğer çekirdek işaretlerinden farklı olarak zamanda kısıtlı bir sürede varlık göstermek, sıfır genlik değeriyle başlamak ve yine sıfır genliğe yaklaşmak gibi özelliklere sahiptirler.

DD, ölçekleme işlemini istenilen zaman parçası büyüklüğünde gerçekleştirebilmektedir. Bu sayede işaret bileşenlerinin, frekans-zaman alanındaki ilişkileri daha detaylı olarak incelenir (Misiti ve ark 2010; Falamarzi ve ark. 2010). Bu dönüşüm, özellikle durağan olmayan işaretler üzerinde oldukça etkili bir yöntemdir. Bu avantajlarından dolayı; işaret işleme, görüntü işleme, görüntü sıkıştırma, gürültülü verilerin temizlenmesi ve benzeri diğer tüm veri işlem uygulamalarında dalgacık dönüşümü günümüzde yaygın olarak kullanılmaktadır. Literatürde, dalgacık dönüşümü, sürekli ve ayrık olmak üzere iki şekilde kullanılabilir.

Bu tez çalışmasında, ESA mimarisinde sınıflandırmak üzere oluşturulan giriş örüntüleri, SDD kullanılarak elde edilen EEG frekans-zaman skalogram görüntüleridir. Bunun yanı sıra konvansiyonel yöntemlerde de ADD kullanılarak EEG işaretleri alt bandlarına ayrıştırılmıştır.

3.3.1. Sürekli Dalgacık Dönüşümü

Dalgacık Dönüşümünde, KZFD 'den farklı olarak pencere görevini ana dalgacık denilen bir fonksiyon üstlenir ve bu ana dalgacık, dönüşüm işlemi süresince hem ölçeklenir hem de ötelenir. Bu sayede daha iyi bir frekans-zaman çözünürlüğü sağlamak için; düşük frekanslarda uzun zaman aralıklı, yüksek frekanslarda ise kısa zaman aralıklı pencereleme seçilir (Misiti ve ark. 2010; Falamarzi ve ark. 2010). Bu dönüşüm özellikle EEG gibi durağan olmayan işaretler üzerinde oldukça etkili bir yöntemdir (Misiti ve ark. 2010; Falamarzi ve ark. 2010).

SDD 'nin sürekli zamandaki matematiksel gösterimi Eşitlik 3.6' da verilmiştir:


$$W_x(s, \tau) = \frac{1}{\sqrt{s}} \int_{-\infty}^{+\infty} x(t) \psi^*\left(\frac{t - \tau}{s}\right) dt \quad (3.6)$$

Burada; $W(s, \tau)$ dalgacık katsayıları, $x(t)$ zaman işaretini, $\psi(t)$ temel dalgacık fonksiyonu eşleniği, s ölçek ve τ pozisyon parametresidir.

Çeşitli parametreler yardımıyla üretilebilecekleri gibi literatürde sıklıkla kullanılan dalgacık çeşitleri de mevcuttur. Çalışmada özellikle nörolojik işaretlerin frekans-zaman analizlerinin gerçekleştirilmesinde önemli bir yapı taşı olan ve durağan olmayan işaretlerin spektral analizi açısından diğer dalgacık ailelerine göre daha uygun olan Morlet dalgacığı kullanılmıştır (Kareem ve Kijewski 2002; Yi ve ark. 2014). Morlet dalgacığı, sanal bileşenler içermesi nedeniyle hem genlik hem de faz bileşenini aynı anda tespit edebilmektedir (Kareem ve Kijewski 2002; Yi ve ark. 2014). Morlet ana dalgacığının matematiksel ifadesi Eşitlik 3.7' da verilmiştir.

$$\Psi(t) = \frac{1}{\sqrt{2\pi}} e^{-ift} e^{-\frac{t^2}{2}} \quad (3.7)$$

Bu eşitlikte f dalgacığın merkezi frekansını temsil etmektedir. Morlet dalgacığı Şekil 3.26 'da gösterilmiştir.




Şekil 3.26. Morlet dalgacığı

Çalışmada, EEG sinyallerine sürekli Morlet dalgacığı uygulanarak skalogram görüntüleri elde edilmiştir. Skalogram, her dalgacık $w_{\tau,s}$ 'nin Heisenberg kutusundaki x işaretinin enerjisini ölçen yerel frekans-zaman enerji yoğunluğu olarak adlandırılır (Bialasiewicz 2015; Guo ve ark. 2016; Peng ve ark. 2002). Skalogram denklemi Eşitlik 3.8. 'de verilmiştir.

$$P_w x(\tau, s) = |W_x(s, \tau)|^2 \quad (3.8)$$

Bu tez çalışmasında sürekli Morlet dalgacığı kullanılmıştır. Uygulama sonucunda elde edilen; sağlıklı, nöbet öncesi ve farklı epilepsili bireylerine ilişkin örnek skalogram görüntüleri Şekil 3.27 'de verilmiştir.



Şekil 3.27. Farklı sınıflara ait 1 sn'lik EEG işaretlerinin dalgacık skalogram örnekleri

Skalogram görüntülerindeki renk değişiklikleri sayesinde, EEG işaretindeki ani değişimler gözlemlenebilmektedir. Bu renk değişimleri, EEG işaretindeki kaotik davranışların oluşturduğu enerji yoğunluklarını ifade etmektedir (Lau ve ark. 1995; Guo ve ark. 2016).

3.3.2. Ayrık Dalgacık Dönüşümü

ADD yönteminde, ayrıştırılacak sinyale alçak ve yüksek geçiren dalgacık filtreleri uygulanarak yaklaşım ve detay bileşenlerine ayrıştırılır. Ayrıştırma sonucu elde edilen yaklaşım bileşenleri, alçak frekanslı ve yüksek ölçeklidir. Detay bileşenleri ise yüksek frekanslı ve düşük ölçeklidir. ADD dönüşümünde, SDD fonksiyonunun temel özelliklerini temsil eden ölçekleme ve öteleme parametreleri belli bir basamağa göre seçilir ise ADD bağıntısı elde edilir. ADD hesabı Eşitlik 3.9. 'da verilmiştir.

$$ADD(m, n) = \sum_m \sum_n x(k) 2^{-\frac{m}{2}} \Psi(2^{-m} k - n) \quad (3.9)$$

Burada, $x(t)$, $ADD(m, n)$, ψ sırasıyla; işareti, ayrık dalgacık dönüşümünü, ana dalgacık fonksiyonunu, m ölçek ve n ise kaydırma parametresini ifade eder.

Bu işlemlerde kullanılan yüksek ve alçak geçiren filtrelerin matematiksel ifadeleri 3.10. ve 3.11. eşitliklerinde verilmiştir.

$$g(k) = \sum_n x(t)g(2k-t) \quad (3.10)$$

$$h(k) = \sum_n x(t)h(2k-t) \quad (3.11)$$

Çalışmada DÜ Nöroloji Kliniği EEG veri setini alt bandlarına ayırıştırmak için ADD kullanılmıştır. Bu amaçla EEG veri setine Daubechies-3 dalgacığı uygulanarak, 7. seviye ayırıştırma yapılmıştır.

Literatürde EEG işaretlelerinin ayırıştırılmasında DD sıklıkla kullanılmaktadır (Unser ve ark. 1996; Tolić ve Jović 2013; Faust ve ark. 2015). Bu çalışmaları büyük çoğunluğunda ADD kullanılmıştır. Bunun en büyük nedeni çok fazla verinin konvansiyonel yöntemlerde işlenememesidir. Günümüzde ise derin öğrenme ağıları sayesinde büyük verilerin işlenmesi mümkün hale geldiğinden, bu çalışmada, EEG işaretlelerine SDD uygulanarak elde edilen skalogram görüntüleri kullanılmıştır.

Bu tez kapsamında iki çalışma gerçekleştirilmiştir. Bu çalışmaları birincisinde 5 farklı aktivite içeren Bonn EEG veri seti kullanılmıştır. İkinci çalışmada ise Dicle Üniversitesi Nöroloji kliniğinden alınan ve 4 farklı sınıftan oluşturulan EEG kayıtları kullanılmıştır.

3.4. Bonn Veri Seti Kullanılarak Yapılan Çalışma

Bu tez kapsamında iki tür veri seti (Bonn veri seti ve DÜ Nöroloji klinik verisi) kullanılarak önerilen yöntemin performansı değerlendirilmiştir. Bu aşamada Bonn veri seti anlatılmış ve kurgulanan yöntemin detayları açıklanmıştır.

3.4.1. Bonn Veri Seti


Bonn veri seti A, B, C, D ve E olmak üzere beş kümeden oluşmaktadır. Her bir kümenin özellikleri Çizelge 3.5. 'te verilmiştir.

Çizelge 3.5. Bonn EEG veri setlerine ilişkin kümeler ve özellikleri

A	B	C	D	E
Sağlıklı	Sağlıklı	Epilepsi Hastası	Epilepsi Hastası	Epilepsi Hastası
Toplam 100 bölüt	Toplam 100 bölüt	Toplam 100 bölüt	Toplam 100 bölüt	Toplam 100 bölüt
Her bölütün süresi 23.6s	Her bölütün süresi 23.6s	Her bölütün süresi 23.6s	Her bölütün süresi 23.6s	Her bölütün süresi 23.6s
Gözler açık kayıt	Gözler Kapalı kayıt	Nöbet Öncesi, hipokampal karşı yarım küreden alınan kayıt	Nöbet Öncesi, epileptik bölgeden alınan kayıt	Nöbet anında alınan kayıt

EEG kayıtları, uluslararası 10-20 elektrot konumlandırma sistemi kullanılarak alınmıştır. Her bir küme 23.6 sn süreli ve tek kanallı 100 bölütten oluşmaktadır. Kullanılan EEG işaretleleri 0.5-40Hz bant geçiren filtre ile filtrelenmiştir. Filtrelenen EEG

işaretlerinin örnekleme hızı 173.61 Hz 'dir. Bu beş kümeye ilişkin örnek işaretler Şekil 3.28.'de gösterilmiştir.




Şekil 3.28. Çalışmada kullanılan Bonn EEG veri kümelerine ilişkin örnekler

3.4.2. Bonn Veri Seti için İzlenen İşlem Akışı

Bonn veri seti; ikili (Örneğin, A - B), üçlü (Örneğin A-B-E), dördü (Örneğin A-C-D-E) ve beşli (Örneğin A-B-C-D-E) olmak üzere farklı kombinasyonlarda sınıflandırılmıştır. Bu yaklaşımın amacı; hem önerilen yöntemin gücünü ve hem de kendine özgü bir karakteristiğe sahip her veri setinin sınıflandırılabilmesini göstermektir.


EEG işaretleri doğası gereği öngörülemez işaretlerdir. Ancak bu işaretlerin görüntülenmesinde herhangi bir engel yoktur. Örneğin, beyin dinamiğindeki öngörülmez davranışına göre EEG işaretlerinin anlık değişimleri, farklı frekans bandında görülebilmektedir. Bundan dolayı bu çalışmada frekans-zaman dönüşümü açısından çok fazla bilgi içermesinden ve EEG işaretini iki boyutlu (2-D) temsil edebileceğinden ötürü, SDD kullanılmıştır. Çalışmada izlenen adımlar Şekil 3.29. 'da gösterilmiştir.



Şekil 3.29. Çalışmada izlenen adımlar

Çalışmada her bir sınıfa ilişkin **ham** EEG işaret bölütüne, SDD uygulanarak frekans-zaman görüntüsü elde edilmiştir. Bu dönüşümde, sürekli Morlet dalgacığı kullanılmıştır.

Her kümeye ilişkin örnek skalogram görüntü örnekleri Şekil 3.30. 'da gösterilmiştir. Elde edilen bu görüntüler 662x536 boyutlarındadır. Bu görüntülerin tasarlanan ESA girişine uygulanabilmesi için 32x32 boyutuna kubik interpolasyon (cubic interpolation method) yöntemi ile indirgenmiştir. Oluşturulan bu frekans-zaman görüntüleri ESA girişine uygulanmıştır.



Şekil 3.30. Her bir kümeye ilişkin birer bölütün örnek Skalogram değişimleri

Her bölüttten bir skalogram görüntü elde edilmiş olmasından ötürü, toplamda (A için 100, B için 100, C için 100, D için 100 ve E için 100) 500 görüntü analize dahil edilmiştir.

3.4.3. Bonn Veri Seti için Önerilen ESA Mimarisi

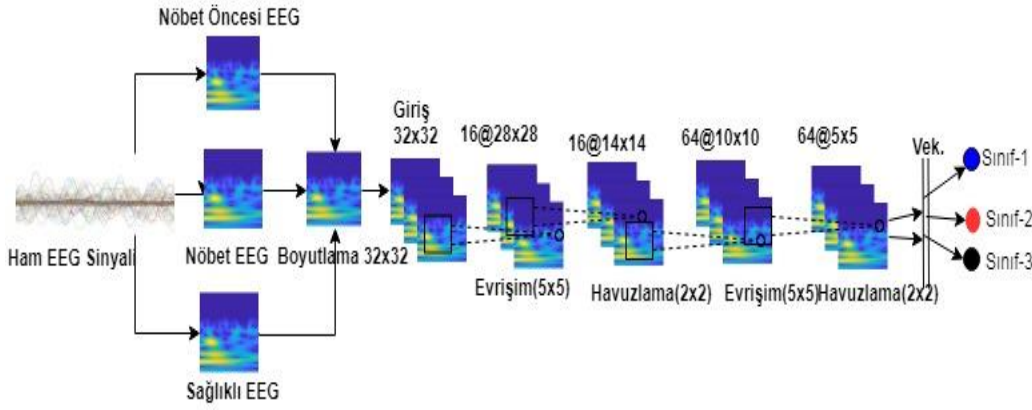
Bu çalışma, Python ortamında, Keras derin öğrenme kütüphanesi vasıtasıyla gerçekleştirilmiştir. Veri setinden skalogram görüntülerinin oluşturulması ve boyutlandırılması Matlab ortamında yapılmıştır.

Tasarlanan ESA mimarisinde 2 adet evrişim katmanı ve 2 adet havuzlama katmanı kullanılmıştır. Bu katmanların içerdiği ana parametreler Çizelge 3.6. 'da verilmiştir.

Çizelge 3.6. Önerilen ESA mimarisinin ana parametreleri

Katman	Filtre Boyutu	Filtre Sayısı	Nöron Sayısı	Adım
Evrişim-1	5x5	16	--	1
Havuzlama	2x2	--	--	2
Evrişim-2	5x5	64	--	1
Havuzlama	2x2	--	--	2
Tam Bağlı Katman	--	--	1000	--

Çalışmamızda önerdiğimiz ağ yapısında EEG işaret görüntülerinin işleme adımları Şekil 3.31.' de verilmiştir.



Şekil 3.31. Üç sınıf için önerilen ESA mimarisi

Görüntüler ESA girişine 32x32 olarak verilir. İlk evrişim katmanındaki işlemler neticesinde 16 öznitelik haritası oluşturulur ve görüntüler 16@28x28 boyutuna dönüştürülür. Bir sonraki katman olan havuzlama (maxpooling) katmanında, görüntüler 16@14x14 boyutuna indirgenir. İkinci evrişim katmanından çıkan görüntü boyutu 64@10x10 olmakta ve 64 adet öznitelik haritası elde edilmektedir. Son katman olan maxpooling ile bu boyut 64@5x5 ebadına indirgenir. Bir sonraki katmanda bu görüntüler vektörizasyon işlemine tabi tutulur ve tam bağlı katmana aktarılır. Çalışmada ESA mimarisi için, öğrenme oranı 0.001, momentum 0.9, iyileştirici (optimizer) Adadelta, epoch sayısı 50, dropout oranı 0.4 ve uygun batch size 4 olarak belirlenmiştir.

Çalışmada EEG skalogram görüntüleri açıklanan ESA mimarisinde 10 eşit parçaya bölünmüş, bu parçaların 9 parçası eğitim, geri kalan 1 parçası da test verisi olarak kullanılmıştır. Eğitim aşamasında, ezber olayını önlemek için, eğitim verisinin %20 oranı doğrulama verisi olarak ayrılmıştır. Çalışmada anlatılan bu aşamalarda kullanılan görüntü sayıları Çizelge 3.7 'de verilmiştir.

Çizelge 3.7. Her bir çapraz doğrulamada ESA mimarisi için kullanılan EEG skalogram görüntü sayıları


Değerlendirilmeye alınan veri seti	Toplam Görüntü Sayısı	Eğitim için Kullanılan Görüntü Sayısı	Doğrulama için Kullanılan Görüntü Sayısı	Test için Kullanılan Görüntü Sayısı	ESA çıkışındaki sınıf sayısı
İki	200	144	36	20	2
Üç	300	216	54	30	3
Dört	400	288	72	40	4
Beş	500	360	90	50	5

3.5. Dicle Üniversitesi Nöroloji Kliniği Veri Seti Kullanılarak Yapılan Çalışma

Bu aşamada Dicle Üniversitesi (DÜ) Nöroloji Kliniği veri seti anlatılmış ve kurgulanan yöntemin detayları açıklanmıştır.

3.5.1. DÜ Nöroloji Kliniği Veri Seti


Çalışmada kullanılan EEG veri seti, DÜ Nöroloji kliniğinde 2012-2018 yılları arasında yatan hastalardan alınan kayıtlardır. EEG sırasında eş zamanlı video kaydı yapılmıştır. EEG kayıtlarında NicoletOne vEEG sistemi kullanılmıştır. Elektrotlar uluslararası 10-20 sistemine göre yerleştirilmiştir. Çalışmada; 10 sağlıklı kişi (3 bayan, 7 erkek, yaş ortalaması: 26.6, standart sapma 11.25), 7 jeneralize epilepsi hastası (3 bayan, 4 erkek, yaş ortalaması: 33.83 standart sapma: 14.16) ve 4 parsiyel epilepsi hastası (3 bayan, 1 erkek, yaş ortalaması: 28.25, standart sapma: 11.78) olmak üzere toplam 21 kişiden alınan EEG kayıtları kullanılmıştır. Çalışmada kullanılan DÜ Nöroloji Kliniği EEG kayıtlarının kullanımı için DÜ Tıp Fakültesi Etik kuruldan gerekli izinler alınmıştır.



Şekil 3.32. NicoletOne vEEG ile kayda alınan EEG işaretine ilişkin örnek kayıt (Monopolar)


EEG kaydı toplam 23 elektrottan alınan (Fp1, Fp2, F3, F4, C3, C4, P3, P4, O1, O2, F7, F8, T3, T4, T5, T6, A1, A2, Fz, Cz, Pz, T2, T1) ve 500 Hz örnekleme frekansına sahip işaretleri içermektedir. Artefaktlardan ve şebeke gürültüsünden dolayı, kayda alınan EEG işaretlerine ön işlem olarak sırasıyla 5. seviye 0.5-100 Hz band geçiren Butterworth filtresi ve 50 Hz lik Notch filtresi uygulanmıştır. Çalışmada kullanılan EEG kayıtlarına ait örnek bir segment, monopolar ve bipolar olarak sırasıyla, Şekil 3.32 ve Şekil 3.33 'de verilmiştir.

3. MATERYAL VE METOT



Şekil 3.33. NicoletOne vEEG ile kayda alınan EEG işaretine ilişkin örnek kayıt (Bipolar)

Hastaların EEG kayıtları ile birlikte eş zamanlı olarak video kayıtları da alınmaktadır. Olası anormal aktiviteler video kayıtlarında da görülebilmektedir ancak video kayıtları bu çalışmaya dahil edilmemiştir. DÜ Nöroloji Kliniği EEG kayıtlarına ilişkin örnek işaretler Şekil 3.34.'te gösterilmiştir.



Şekil 3.34. Çalışmada kullanılan DÜ Nöroloji Kliniği EEG veri kümelerine ilişkin örnekler

3.5.2. DÜ Nöroloji Kliniği Veri Seti için İzlenen İşlem Akışı

Çalışmada hastalardan alınan EEG kayıtları, DÜ Nöroloji kliniğinde görev yapan hekimler tarafından hazırlanan hasta raporları dikkate alınarak, nöbet türlerine göre 4 sınıf altında toplanmıştır. Birinci sınıf olarak belirlenen EEG kayıtları, herhangi bir hastalık aktivitesi olmayan sağlıklı kişilerden oluşmaktadır (H). İkinci sınıf, jeneralize epilepsi

hastalarına ilişkin nöbet öncesindeki EEG kayıtlarını kapsar (J1). Üçüncü sınıf, aynı Jeneralize epilepsi hastalarının nöbet sürecindeki EEG kayıtlarını kapsar (J2). Son sınıf olarak, parsiyel epilepsi hastalarının EEG kayıtları dikkate alınmıştır (P). Parsiyel epilepsi hastaların EEG verileri genel olarak yavaş ve diken dalga içermesi nedeniyle, bu sınıfın segmentleri herhangi bir zaman sürecinden seçilmiştir.

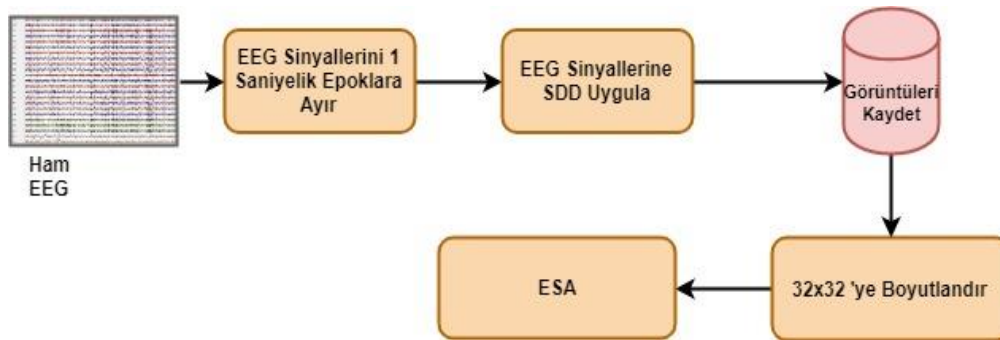
Analizde kullanılacak 23 kanalın 1 saniyelik EEG segmentleri (epokları), seri olarak birleştirilmiş ve ardından her segmentin skalogram görüntüleri elde edilmiştir. Sınıflarda yer alan kişi sayısı farklı olsa dahi, analizlerin daha doğru sonuç üretmesi açısından her sınıf için eşit sayıda skalogram görüntüsü elde edilmiştir. Çalışmada her sınıf için kullanılan skalogram sayısı Çizelge 3.8 'de gösterilmiştir.

Çizelge 3.8. Çalışmada her bir sınıf için oluşturulan görüntü sayısı

Sınıf	Görüntü
Sağlıklı (H)	10 000*
Jeneralize - Nöbet Öncesi (J1)	10 000*
Jeneralize - Nöbet Süreci (J2)	10 000*
Parsiyel - Herhangi bir zaman süreci (P)	10 000*
Toplam	40 000

* : 10 000 saniye/23 kanal = 434 782 saniye

Elde edilen EEG veri setinden görüntü oluşturulması ve bu görüntülerin tasarlanan ESA girişine uygun hale getirilmesi ile ilgili işlemler Şekil 3.35 'te gösterilmiştir.



Şekil 3.35. Çalışmada izlenen adımlar

Çalışmada kullanılan veri seti, hastaların görüntüleri incelenerek oluşturulmuştur. Kişilerden alınan 23 kanallı EEG kayıtları, her biri 1 'sn lik ve 500 veri noktasından (data point) oluşan veri setine dönüştürülmüştür. Daha sonra oluşturulan veri setine SDD uygulanarak, 508x679 boyutlarında frekans-zaman skalogramları elde edilmiştir. Elde

edilen bu görüntülerin tasarlanan ESA girişine verilebilmesi için yeniden 32x32 'lik boyuta indirgenmiştir.

3.5.3. DÜ Nöroloji Kliniği EEG Veri Seti için Önerilen ESA Mimarisi


Bu çalışma, 8 GB Ram, Intel i7-7500U işlemcili bilgisayar kullanılarak, Python ortamında, Keras derin öğrenme kütüphanesi vasıtasıyla gerçekleştirilmiştir. Veri setinden skalogram görüntülerinin oluşturulması ve boyutlandırılması Matlab ortamında yapılmıştır.

Çalışmada önerilen ESA mimarisi; 1 giriş, 3 evrişim, 3 havuzlama, 1 adet tam bağlı katmandan oluşmaktadır. Çizelge 3.11. 'de evrişimsel sinir ağ mimarisine ilişkin ana parametreler listelenmiştir. Çizelgede verilen değerler, bir grup denemeler sonunda elde edilen en iyi ağ mimarisidir.

Çizelge 3.9. Önerilen ESA mimarisi ana parametreleri

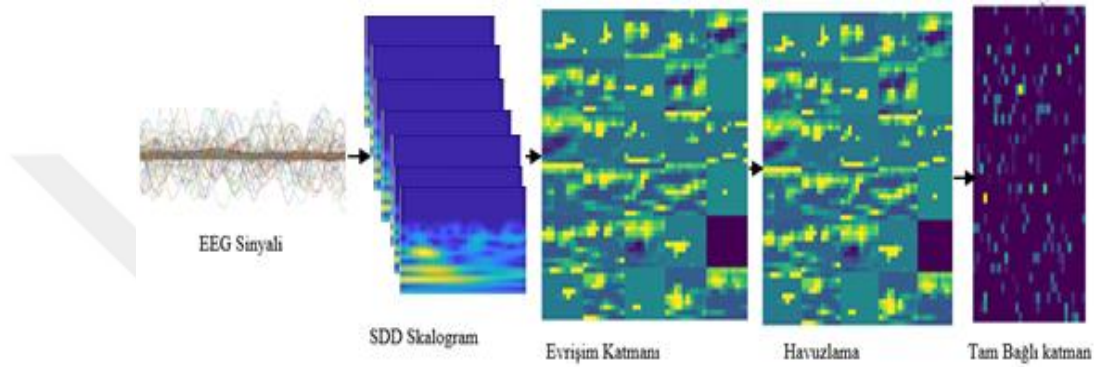
Katman	Filtre Boyutu	Filtre Sayısı	Nöron Sayısı	Adım
Evrişim-1	5x5	32	--	1
Havuzlama	2x2	--	--	2
Evrişim -2	5x5	64	--	1
Havuzlama	2x2	--	--	2
Evrişim -3	3x3	128	--	1
Tam Bağlı Katman	--	--	1000	--

Çizelge 3.9.'da görüldüğü üzere, ilk iki evrişim katmanında 5x5 'lik filtre ve 3. evrişim katmanında ise 3x3 'lük filtreler kullanılmıştır. Havuzlama katmanında, maxpooling yöntemi kullanılmıştır. Maxpooling boyutu (stride) 2 olarak belirlenmiştir. Çalışmada ilk katmanda 32, ikinci evrişim katmanında 64 ve son olarak 128 öznitelik haritası oluşturulmuştur. Tam bağlı katman 1000 nöron olarak oluşturulmuştur ve dropout oranı ise 0.4 olarak seçilmiştir (Şekil 3.36). Böylelikle, önerilen model için optimum parametre değerleri belirlenmiştir.



Şekil 3.36. Dört sınıf için önerilen ESA Mimarisi

Şekil 3.36.'da görüleceği üzere; ESA girişine 32x32 olarak verilen görüntüler, ilk evrişim katmanındaki işlemler neticesinde 28x28 boyutuna dönüşür. Bir sonraki katman olan maxpooling katmanında, görüntüler 14x14 boyutuna indirgenir. İkinci evrişim katmanından çıkan görüntü boyutu 10x10 olmakta ve bu katmanı takip eden maxpooling ile bu boyut 5x5 ebadına indirgenir. Son evrişim katmanında görüntü boyutu 3x3 olur. Bir sonraki katmanda bu görüntüler vektörizasyon işlemine tabi tutulur ve tam bağlı katmana aktarılır. Tasarlanan ESA mimarisine uygulanan örnek bir EEG işaretinin, dönüşüm aşamasında elde edilen görüntüler Şekil 3.37' de verilmiştir.

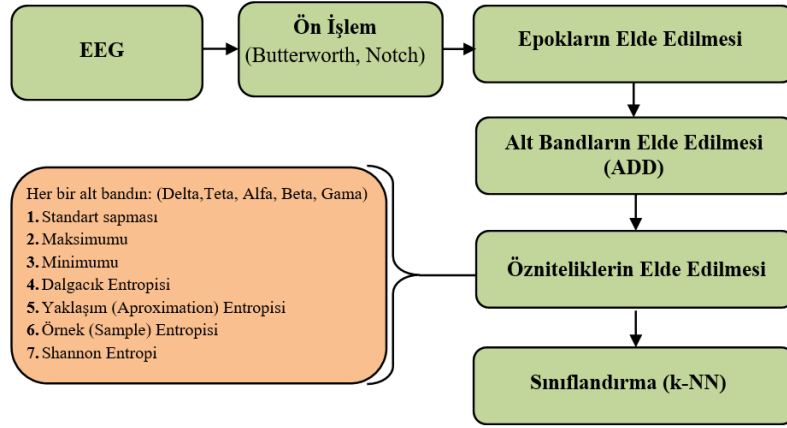


Şekil 3.37. EEG işaretine ilişkin SDD Skalogram örnek görüntülerinin evrişim, havuzlama ve tam bağlı katmanlarda elde edilen örnek özellik haritaları.

Elde edilen skalogram görüntüleri çapraz doğrulama yöntemi kullanılarak 5 parçaya ayrıştırılmıştır. Eğitim için kullanılan veri setinin %20 oranı doğrulama verisi olarak kullanılmıştır. Çalışmada ESA mimarisi için, öğrenme oranı 0.001, momentum 0.9, iyileştirici (optimizer) Adadelta, epoch sayısı 20, dropout oranı 0.4 ve uygun batch size 128 olarak belirlenmiştir. Oluşturulan ESA mimarisinde, eğitim için toplam 100 epoch gerçekleştirilmiştir.

3.5.4. DÜ Nöroloji Kliniği Veri Seti için Önerilen Konvansiyonel Yöntem

Konvansiyonel yöntemlerde yapılan sınıflandırma çalışmaları, genel olarak üç adımdan oluşmaktadır. Bunlar; **a)** veri ön işleme, **b)** Öznitelik elde etme, **c)** Sınıflandırma adımlarıdır. Çalışmada, DÜ Noroloji Kliniği veri setinin konvansiyonel yöntem ile sınıflandırılmasında izlenen işlem adımları Şekil 3.38.'de verilmiştir.



Şekil 3.38. Konvansiyonel yöntemde izlenen adımlar

Çalışmada kullanılan ve 500 Hz örnekleme frekansına sahip olan DÜ Nöroloji Kliniği veri setine önışlem aşamasında önceki bölümlerde açıklandığı üzere band geçiren Butterworth ve şebeke gürültüsünde dolayı Notch filtre uygulanmıştır. Öznitelik elde etme aşamasında; veri seti her biri 500 veri noktası (data point) içeren bölütlere dönüştürülmüştür. Elde edilen bu EEG bölütlerine ADD dönüşümü kullanılarak 7. seviye ayrıştırılmıştır. Bu ayrıştırma sonucu elde edilen alt bandlar ve içermiş oldukları frekans aralıkları Çizelge 3.10. 'da verilmiştir.

Çizelge 3.10. ADD sonucu elde edilen dalgacık katsayılarının band aralıkları

Alt Band (Dalgacık Katsayısı)	Frekans Aralığı
cD1	125-250
cD2	62.5-125
Gama (cD4)	31.2-62.5
Beta (cD5)	15.6-31.2
Alfa (cD6)	7.8-15.6
Teta (cD7)	3.9-7.8
Delta (cA7)	0.5-3.9

Çalışmada, ADD sonucu oluşan cA7, cD7, cD6, cD5 ve cD4 dalgacık katsayıları kullanılmıştır. Bu dalgacık katsayılarından öznitelik elde etmek için her bir alt bandın; Dalgacık entropisi, ortalama değeri, standart sapması, Yaklaşım entropisi (ApEn), Örnek entropisi (SampEn), maksimum ve minimum değerleri hesaplanmıştır.

Çalışmada elde edilen özniteliklerin denklemleri Çizelge 3.11. 'de verilmiştir.

Çizelge 3.11. Özniteliklerin denklemleri

Öznitelik	Denklemler	Açıklama
Dalgacık Entropi	$DE = - \sum_{i < 0} p_i \ln p_i$	p_i bir zaman serisi işaretinin dağılım olasılığını ifade eder ve i farklı kararlılık seviyelerini ifade eder.
Ortalama	$Ort = \frac{1}{N} \sum_{n=1}^N X_n$	
Standart Sapma	$Std = \sqrt{\frac{1}{N} \sum_{n=1}^N (X_n - X_{ort})^2}$	
Yaklaşım Entropi (ApEn)	$ApEn = \ln \left(\frac{C_m(r)}{C_{m+1}(r)} \right)$ $C_{im}(r) = \frac{n_{im}(r)}{N - m + 1}$	$C_m(r)$, m uzunluğunun örüntü ortalamasıdır. $C_{m+1}(r)$ 'de $m+1$ uzunluğunun örüntü ortalamasıdır. $C_{im}(r)$, m uzunluğunun örüntü sayısını gösterir. $m = 2$ ve $r = 0.5$ kat olarak hesaplanmıştır
Örnek Entropi (SampEn)	$SampEn = - \log \left(\frac{A}{B} \right)$	A , $m+1$ uzunluğunun vektör çiftlerinin toplam sayısını içerir ve B , m uzunluğunun vektör çiftlerinin toplam sayısını ifade eder. m 'in değeri 2 olarak alınmıştır
Maksimum	$Mak = \max(X_n)$	
Minimum	$Min = \min(X_n)$	

Çizelge 3.11. de verilen Dalgacık entropi; EEG işaretlerinin farklı frekans bantlarındaki bağıl enerjilerinin ölçütü olarak tanımlanır. İşaretin farklı fraksiyonları arasındaki benzerlik derecesini hesaplar. Aynı zamanda Dalgacık Entropi, çoklu frekans işaretlerinin düzensizlik derecesi ölçütüdür (Rosso ve ark. 2001; Kannathal ve ark. 2005).

Yaklaşım entropi; işarettaki değişim (varyasyon) kararsızlığını belirlemek için kullanılır (Acharya ve ark. 2015; Seely, ve Macklem 2000; Richman ve Moorman 2000).

Örnek entropi; fizyolojik bir işaretin düzenliliğini ölçer ve örüntü uzunluğundan bağımsızdır. Örnek Entropi 'nin yüksek değeri, işaretin yüksek oranda tahmin edilemez olduğu anlamına gelir. Düşük bir Örnek entropi değeri ise işaretin tahmin edilebilir olduğunu gösterir (Acharya ve ark. 2015; Seely ve Macklem 2000; Richman ve Moorman 2000; Song ve Liò 2010).

3.6. Performans Değerlendirmesi

Çalışmada elde edilen sonuçların güvenilirliği için Bonn veri seti kullanılarak yapılan çalışmada 10 çapraz doğrulama yapılmıştır. DÜ Nöroloji biriminden alınan veri seti için ise 5 çapraz doğrulama kullanılarak tüm veriler sistem performansında değerlendirilmiştir. Ayrıca model başarımı için doğruluk, duyarlılık, özgünlük ve f-skor ölçümleri hesaplanmıştır. Hesaplama için kullanılan değerler Çizelge 3.12 'de verilmiştir.

Çizelge 3.12. Karışıklık matrisi (confussion matrix) ve model başarımlar ölçütleri

		Tahmin Edilen Sınıf	
		Sınıf=1	Sınıf=0
Gerçek Sınıf	Sınıf=1	True Positive (TP)	(False Positive) FP
	Sınıf=0	(False Negative) FN	(True Negative) TN

$$\text{Doğruluk} = \frac{TP + TN}{TP + FP + FN + TN} \quad (3.9)$$

$$\text{Duyarlılık} = \frac{TP}{TP + FP} \quad (3.10)$$

$$\text{Özgünlük} = \frac{TN}{FP + TN} \quad (3.11)$$

$$\text{Hassaslık} = \frac{TP}{TP + FN} \quad (3.12)$$

$$\text{Recall} = \frac{TP}{TP + FN} \quad (3.13)$$

$$F - \text{Skor} = 2 * \frac{\text{Hassaslık} * \text{Recall}}{\text{Hassaslık} + \text{Recall}} \quad (3.14)$$

Model başarımlar ölçümlerinden doğruluk; tıbbi tanıya ilişkin modelin test işleminde, var olan sınıfları tahmin etme başarısını ifade eder (Eşitlik (3.9)). Duyarlılık; test kümesindeki hasta olan örüntülerin doğru tahmin etme başarımını ifade eder (Eşitlik (3.10)). Özgünlük; test kümesindeki sağlıklı örüntülerin doğru tahmin etme başarımını ifade eder (Eşitlik (3.11)). Son olarak, f-skor ise test edilen verilerin doğruluğunun ölçümünü ifade eder (Eşitlik (3.14)) (Sokolova ve ark 2006).

4. ARAŞTIRMA BULGULARI

Bu tez çalışmasında EEG işaretlerinden epilepsi tespiti için skalogram tabanlı ESA mimarisi kullanılmış ve önerilen yöntemin başarısını test etmek için iki farklı veri kullanılmıştır. Bu veri setleri farklı katmanlardan oluşturulan ağlarda eğitilmiştir. Her iki veri seti için de çapraz doğrulama gerçekleştirilmiştir. Çapraz doğrulama sonucu elde edilen karışıklık (confussion) matrisinden, model başarımlar ölçümü hesaplanmıştır. Model başarımının değerlendirilmesi için doğruluk, duyarlılık, özgünlük ve f-skor değerleri hesaplanmıştır. Bu ölçümlerde karışıklık matrisinden hesaplanan değerler, tüm veri seti üzerinden gerçekleştirilmiştir.

Çalışma sonucu elde edilen sınıflandırma performansları ve literatürdeki benzer çalışmalar ile karşılaştırılmaları bu bölümde anlatılmıştır.

4.1. Bonn Veri Seti ile Elde Edilen Bulgular

Çalışmada EEG işaretlerinden elde edilen frekans-zaman görüntüleri ESA mimarisinde değerlendirilmiştir. Her biri farklı aktivite içeren EEG işaretlerinin tüm kombinasyonları kendi içinde karşılaştırılmıştır. Çalışmada karşılaştırılan sınıflar;

İkili veri setleri için: A-B, A-C, A-D, A-E, B-C, B-D, B-E, C-D, C-E ve D-E

Üçlü veri setleri için: A-B-C, A-B-D, A-B-E, A-C-D, A-C-E, B-C-D, B-C-E, B-D-E, D-C-E ve A-D-E

Dörtlü veri setleri için: A-C-D-E ve B-C-D-E

Beşli veri setleri için: A-B-C-D-E, şeklindedir.

Bu bölümde her sınıf için yapılan çalışmanın başarı performansları tablolar halinde verilmiştir.

Çalışmada EEG kayıtlarının ikili gruplar halinde sınıflandırmasında elde edilen başarımlar ölçümleri Çizelge 4.1.'de verilmiştir.

4. ARAŞTIRMA BULGULARI

Çizelge 4.1. İkili sınıf başarımı

			Tahmin Edilen		Doğruluk (%)	Duyarlılık (%)	Özgünlük (%)	f-skor (%)
			A	B				
A-B	Gerçek Sınıf	A	97	3	95.50	94.17	96.90	95.50
		B	6	94				
			Tahmin Edilen					
A-C	Gerçek Sınıf	A	94	6	96.50	98.94	94.28	96.41
		C	1	99				
			Tahmin Edilen					
A-D	Gerçek Sınıf	A	100	0	100	100	100	100
		D	0	100				
			Tahmin Edilen					
A-E	Gerçek Sınıf	A	100	0	99.50	99.00	100	99.50
		E	1	99				
			Tahmin Edilen					
B-C	Gerçek Sınıf	B	99	1	99.00	99.00	99.00	99.00
		C	1	99				
			Tahmin Edilen					
B-D	Gerçek Sınıf	B	100	0	100	100	100	100
		D	0	100				
			Tahmin Edilen					
B-E	Gerçek Sınıf	B	100	0	99.50	100	100	99.50
		E	1	99				
			Tahmin Edilen					
C-D	Gerçek Sınıf	C	88	12	80.00	75.86	85.71	81.48
		D	28	72				
			Tahmin Edilen					
C-E	Gerçek Sınıf	C	99	1	98.50	98.01	98.98	98.50
		E	2	98				
			Tahmin Edilen					
D-E	Gerçek Sınıf	D	99	1	98.50	98.01	98.98	98.50
		E	2	98				

Çalışmada, C ve D veri setlerinin E veri seti ile sınıflandırılmasında aynı sonuçlar elde edilmiştir. Diğer taraftan, C ve D veri setlerinin ikili sınıflandırmasında, %80.00(±16.12) doğruluk oranında ayrıştırılabildiği görülmüştür. Elde edilen bu doğruluk oranından, nöbet öncesi EEG işaretlerinin ölçüm bölgesinin farklılık gösterdiği söylenebilir. Referans A veya B veri seti alınması durumunda en yüksek başarımlar D veri setinden, referans E veri seti alınmasında ise en yüksek başarımlar A ve B veri setlerinden elde edilmiştir. Aynı şekilde C ve D veri setlerinin E veri seti ile

sınıflandırmasında aynı özellikleri gösterdiği görülmüştür. Bu nedenle, nöbet öncesi işaretin, nöbet anı işareti ile karşılaştırmasında beyin bölgesinin önemli olmadığı şeklinde değerlendirilebilir. Buna karşın nöbet öncesi işaretlerin (C veya D) sağlıklı işaret (A veya B) ile karşılaştırmasında beyin bölgesinin önemli olduğu görülmektedir. Ayrıca sağlıklı olan A ve B veri setlerinin ayrıştırmasında, önerilen yöntemin göz açık kapalı olma durumundaki farklılığı da önemli ölçüde yakalanabildiği görülebilmektedir (%95.50(±4.72)). Diğer taraftan; sağlıklı ve gözü açık olarak işlenen işaretin, epilepsi nöbet anı işareti ile karşılaştırılmasında, gözü kapalı olan işaretten daha başarılı sınıflandırıldığı görülmüştür (A-E, B-E). Ayrıca, sağlıklı gözü kapalı olarak işlenen işaretin, nöbet öncesi epileptik işaret ile karşılaştırılmasında, sağlıklı ve gözü açık olan işaretten daha başarılı sonuç verdiği görülmüştür (A-C, B-C).

Çalışmada üçlü gruplar halinde yapılan sınıflandırma başarımları Çizelge 4.2. 'de verilmiştir.

Çizelge 4.2. Üçlü sınıf başarımları

			Tahmin Edilen			Doğruluk (%)	Duyarlılık (%)	Özgünlük (%)	f-skor (%)
			A	B	C				
A-B-C	Gerçek Sınıf	A	92	3	5	95.00	92.00	96.50	92.46
		B	5	95	0	97.26	95.00	94.44	95.95
		C	2	0	98	97.60	98.00	97.39	96.55
			Tahmin Edilen			Doğruluk (%)	Duyarlılık (%)	Özgünlük (%)	f-skor (%)
			A	B	D				
A-B-D	Gerçek Sınıf	A	96	2	2	96.99	96.00	97.48	95.52
		B	4	95	1	97.64	95.00	98.98	96.44
		D	1	0	99	98.63	99.00	98.45	98.01
			Tahmin Edilen			Doğruluk (%)	Duyarlılık (%)	Özgünlük (%)	f-skor (%)
			A	B	E				
A-B-E	Gerçek Sınıf	A	96	4	0	96.30	96.96	95.97	94.58
		B	5	95	0	96.63	95.00	97.46	95.00
		E	3	1	96	98.62	96.00	100	97.95
			Tahmin Edilen			Doğruluk (%)	Duyarlılık (%)	Özgünlük (%)	f-skor (%)
			A	C	D				
A-C-D	Gerçek Sınıf	A	94	4	2	95.65	94.00	96.59	94.00
		C	2	87	11	88.88	87.00	89.84	84.05
		D	1	16	83	89.79	83.00	93.29	94.69
			Tahmin Edilen			Doğruluk (%)	Duyarlılık (%)	Özgünlük (%)	f-skor (%)
			A	C	E				
A-C-E	Gerçek Sınıf	A	96	4	0	97.18	96.00	97.82	96.00
		C	3	97	0	93.55	97.00	91.79	91.07
		E	1	16	83	94.19	83.00	100	90.71
			Tahmin Edilen			Doğruluk (%)	Duyarlılık (%)	Özgünlük (%)	f-skor (%)
			A	C	E				

4. ARAŞTIRMA BULGULARI

			B	C	D	Doğruluk (%)	Duyarlılık (%)	Özgünlük (%)	f-skor (%)
B-C-D	Gerçek Sınıf	B	98	1	1	98.56	98.00	98.87	98.00
		C	1	91	8	91.94	91.00	92.42	88.34
		D	1	14	85	91.94	85.00	95.45	87.62
			Tahmin Edilen						
			B	C	E	Doğruluk (%)	Duyarlılık (%)	Özgünlük (%)	f-skor (%)
B-C-E	Gerçek Sınıf	B	100	0	0	98.99	100	98.49	98.52
		C	1	99	0	99.32	99.00	99.49	99.00
		E	2	1	97	98.99	97.00	100	98.47
			Tahmin Edilen						
			B	D	E	Doğruluk (%)	Duyarlılık (%)	Özgünlük (%)	f-skor (%)
B-D-E	Gerçek Sınıf	B	100	0	0	98.98	100	98.47	98.52
		D	1	98	1	98.65	98.00	98.98	98.00
		E	2	2	96	98.32	96.00	99.49	97.46
			Tahmin Edilen						
			D	C	E	Doğruluk (%)	Duyarlılık (%)	Özgünlük (%)	f-skor (%)
D-C-E	Gerçek Sınıf	D	82	17	1	89.71	82.00	93.95	84.97
		C	10	88	2	84.89	88.00	83.83	79.63
		E	1	16	83	92.67	83.00	98.26	89.24
			Tahmin Edilen						
			A	D	E	Doğruluk (%)	Duyarlılık (%)	Özgünlük (%)	f-skor (%)
A-D-E	Gerçek Sınıf	A	100	0	0	99.00	100	98.50	98.52
		D	2	98	0	99.33	98.00	100	98.98
		E	1	0	99	99.66	99.00	100	99.49

Çizelge 4.2.' den görüldüğü üzere, sağlıklı işaretlerin nöbet öncesi işaretlerle sınıflandırılmasında, gözü kapalı işaretin (B veri seti), gözü açık olan işaretten (A veri seti) daha iyi sonuç verdiği görülmektedir. Çalışmada bir diğer göze çarpan önemli konu, sağlıklı işaretlerin nöbet anı işareti (E veri seti) ile sınıflandırma başarımının, nöbet öncesi işaretlere göre (C ve D veri seti) düşük olmasıdır. Üçlü sınıflandırmada en düşük sınıflandırma performansı %88.00(±8.72) ile A-C-D veri setlerinden elde edilirken, en yüksek başarı performansı ise %99.00(±1.33) ile A-D-E veri setinden elde edilmiştir.

Çalışmada 10 çarpaz doğrulama (cross validation) sonucu elde edilen neticelerin ortalaması ile elde edilen doğruluk ortalaması (overall); A-B-C grubu için %95.00(±4.01), A-B-D grubu için %96.67(±2.58), A-B-E grubu için %95.67(±3.96), A-C-E grubu için %97.00(±3.14), A-C-D grubu için %88.00(±8.72), A-D-E %99.00(±1.33), B-C-D grubu için %91.33(±5.42), B-C-E grubu için %98.67(±2.21), B-D-E grubu için %98.00(±2.21) ve D-C-E grubu için %89.00(±4.73).

Dörtlü gruplar halinde yapılan sınıflandırma başarımları Çizelge 4.3. 'te verilmiştir.

Çizelge 4.3. Dörtlü sınıf başarımları

		Tahmin Edilen				Doğruluk (%)	Duyarlılık (%)	Özgünlük (%)	f-skor (%)	
		A	C	D	E					
A-C-D-E	Gerçek Sınıf	A	98	1	1	0	96.79	98.00	96.35	94.23
		C	4	81	15	0	92.58	81.00	95.56	84.81
		D	5	9	85	1	91.87	85.00	94.21	84.15
		E	1	0	1	98	99.00	98.00	99.62	98.49
		Tahmin Edilen				Doğruluk (%)	Duyarlılık (%)	Özgünlük (%)	f-skor (%)	
		B	C	D	E					
B-C-D-E	Gerçek Sınıf	B	98	1	1	0	98.65	98.00	98.89	97.51
		C	1	86	13	0	92.89	86.00	95.23	86.00
		D	0	13	84	3	92.42	84.00	95.27	84.84
		E	2	0	0	98	98.65	98.00	98.89	97.51

Çalışmada 10 çarpaz doğrulama (cross validation) sonucu elde edilen neticelerin ortalaması ile elde edilen doğruluk ortalaması (overall); A-C-D-E % 90.50(± 1.70), B-C-D-E % 91.50(± 2.29). Bu sınıflandırmada A ve B veri setlerinin diğer sınıflar ile sınıflandırmasında hemen hemen aynı özellikleri gösterdikleri söylenebilir. Aynı şekilde (A-C-D-E) ve (B-C-D-E) sınıflandırmalarında A, B ve E veri setlerinin aynı duyarlılık oranlarında ayrıştırılabildiği görülmüştür.

Tüm sınıfların dahil edildiği sınıflandırma başarımları Çizelge 4.4. 'te verilmiştir.

Çizelge 4.4. Beşli sınıf başarımları

		Tahmin Edilen					Doğruluk (%)	Duyarlılık (%)	Özgünlük (%)	f-skor (%)	
		A	B	C	D	E					
A-B-C-D-E	Gerçek	A	95	3	0	0	2	97.90	95.00	98.67	95.00
		B	3	97	0	0	0	98.52	97.00	98.93	96.51
		C	1	1	87	11	0	95.31	87.00	97.44	88.32
		D	0	0	10	90	0	95.70	90.00	97.17	89.55
		E	1	0	0	0	99	99.36	99.00	99.46	98.50

Çalışmada 10 çarpaz doğrulama (cross validation) sonucu elde edilen neticelerin ortalaması ile elde edilen doğruluk ortalaması (overall); A-B-C-D-E %93.60(± 3.07). Çizelge 4.4.' e bakıldığında, en yüksek E veri setinden, %99.36 doğruluk sonucu bulunmuştur.

4. ARAŞTIRMA BULGULARI

4.1.1. Sınıflandırma Performansının Literatürdeki Benzer Çalışmalar ile Karşılaştırılması

Önerilen yöntemle elde edilen başarımların literatürdeki benzer çalışmalar ile karşılaştırılması, Çizelge 4.5. 'te verilmiştir.

Çizelge 4.5. Literatürde Bonn veri seti kullanılarak yapılan çalışmalar

Çalışma	Kullanılan Yöntem	Veri Seti	Başarı(%)
Bhattacharyya ve ark. 2017	TQDD+ K-NN Entropy	A-E	100
Ibrahim ve ark. 2018	DD + SE/SD/BP+ KNN/DVM	A-E	100
Wang ve ark. 2019	DD+PCA, GBM, RF, DVM	A-E	100
Swami ve ark. 2016	LMD+GA+DVM	A-E	100
Hussein ve ark. 2018	L1-Penalized Robust Regression + RF	A-E	100
Kumar ve ark. 2014	Bulanık Yaklaşım Entropi + DVM	A-E	100
Polat ve ark. 2007	HFD ve Karar Ağaç Sınıflandırıcı	A-E	98.70
Lee ve ark. 2014	Dalgacık Dönüşümü, Faz, Öklit Uzaklığı	A-E	98.17
Nigam ve ark. 2004	Yapay Sinir Ağları	A-E	97.50
Kaya ve ark. 2014	1-D-LBP ve Bayes Net	A-D	99.50
Zhang ve ark. 2017	LMD+GA+DVM	D-E	98.10
Wang ve ark. 2019	DD+PCA, GBM, RF, DVM	D-E	98.10
Bhattacharyya ve ark. 2017	TQDD- k-NN Entropi	D-E	98.00
Jia ve ark. 2017	CEEMDAN + RF	D-E	98.00
Swami ve ark. 2016	DTSD + GRNN	D-E	98.00
Tawfik ve ark. 2016	Ağırlıklı Permütasyon Entropisi + DVM	D-E	96.50
Kumar ve ark. 2014	ADD+Bulanık Yaklaşım Entropi+DVM	D-E	95.85
San-Segundo ve ark. 2019	ESA +FD+DD+EMD	A-C-E	96.5
Zhang ve ark. 2017	LMD+GA+DVM	A-D-E	98.47
Kumar ve ark. 2014	ADD+Bulanık Yaklaşım Entropi+DVML	A-D-E	95.67
Acharya ve ark. 2018	ESA	A-D-E	88.70
San-Segundo ve ark. 2019	ESA +FD+DD+EMD	A-D-E	95.7
Kaya ve ark. 2014	1D-YİÖ ve Bayes Net (1D-YİÖ tümü)	A-D-E	95.67
Zahra ve ark. 2017	MEMD + YSA	A-B-C-D-E	87.2
Bu çalışmada	ESA+ Skalogram	A-E	99.50
	ESA+Skalogram	A-D	100
	ESA+Skalogram	D-E	98.50
	ESA+Skalogram	A-C-E	97.00
	ESA+Skalogram	A-D-E	99.00
	ESA+Skalogram	A-B-C-D-E	93.60

Literatürde yer alan temel çalışmalara bakıldığında (Çizelge 4.5.); farklı öznitelliklerin elde edildiği görülmektedir. Bazı çalışmalarda ise, boyut indirgeme yöntemleri kullanılarak başarımın artırılması amaçlanmıştır. Bunun yanısıra çoğu çalışmada sadece belirli sınıflar karşılaştırılabilmektedir. Bunun iki nedeni olabileceği düşünülmektedir. Bunlar a) EEG işaretlerinden nöbet öncesi ve nöbet anı durumunun tespiti, b) Her bir EEG verisinin karakteristiğinin farklı olmasıdır ki bu durum her özniteliğin her veri grubu için uygun olamayacağı anlamına gelmektedir. Dolayısıyla,

önerilen yaklaşımlar, EEG işaretlerinin sınıflandırma aşamaları için pratik bir çözüm olmayabilirler. Literatürdeki benzer çalışmalara bakıldığında, bu tez çalışmasının farklılıkları aşağıdaki şekilde tarif edilebilir;

- EEG veri setinden herhangi bir öznitelik elde edilmemiştir. Aynı zamanda herhangi bir boyut indirgeme yöntemi de kullanılmamıştır.
- Ham EEG verilerinin frekans-zaman skalogramları doğrudan ESA mimarisinde değerlendirilmiştir.
- Önerilen yönteme ilişkin performansın değerlendirilmesinde, tüm sınıfların karşılaştırılması yapılmıştır. Her bir EEG grubunun kendine özgü karakteristiğinin önerilen yöntem ile başarıyla ayrıştırılabildiği görülmüştür.
- Literatürde, sınıf sayısının artmasıyla yöntemlere ilişkin performansın düşmesi söz konusuysen, tez kapsamında önerilen yöntem ile performansın arttığı gözlemlenmiştir.

4.2. DÜ Nöroloji Kliniği Veri Seti ile Elde Edilen Bulgular

Çalışmada DÜ Nöroloji kliniği veri seti 5 eşit parçaya bölünmüştür. Kullanılan veri setinin 4 parçası eğitim seti, geri kalanı test verisi olarak değerlendirilmiştir. Gerçekleştirilen çapraz doğrulama işleminde, verilerin gruplandırılma yaklaşımı Şekil 4.1 'de verilmiştir.

Fold-1	Fold-2	Fold-3	Fold-4	Fold-5
Test	Eğitim	Eğitim	Eğitim	Eğitim
Eğitim	Test	Eğitim	Eğitim	Eğitim
Eğitim	Eğitim	Test	Eğitim	Eğitim
Eğitim	Eğitim	Eğitim	Test	Eğitim
Eğitim	Eğitim	Eğitim	Eğitim	Test


Test	Test	Test	Test	Test
------	------	------	------	------

Şekil 4.1. k-fold çapraz doğrulama (k = 5)

DÜ Nöroloji kliniği veri seti çalışmasında, iki ayrı aşamada veriler değerlendirilmiştir. Birinci aşamada, H-J1-J2 (toplam üç sınıf), ikinci aşamada ise H-J1-J2-P (toplam dört sınıf) EEG sınıf skalogramları dikkate alınmıştır. Her bir sınıfın açıklaması ve görüntü sayısı, Çizelge 3.8. 'de verilmiştir.

Yukarıda sözü edilen her iki aşamada, çapraz doğrulama işleminde elde edilen sınıflandırma doğruluğu Şekil 4.2 'de gösterilmiştir.

4. ARAŞTIRMA BULGULARI



Şekil 4.2. Fold doğrulukları (Üç Sınıf için; H, J1 ve J2. Dört Sınıf için; H, J1, J2 ve P kullanılmıştır.)

Şekil 4.2. 'deki sonuçlara göre; 3 farklı EEG kaydının (H, J1 ve J2) ayrıştırılmasında, en yüksek doğruluk oranı %90.43 ile 2. Fold, en düşük doğruluk oranı ise %89.93 ile 5. Fold işleminde elde edilmiştir. 4 farklı EEG kaydının ayrıştırılmasında ise, en düşük sınıflandırma 1 ve 2. Fold 'da %84.21 olarak elde edilirken, en yüksek doğruluk performansı %85.48 ile 4. Fold işleminde elde edilmiştir.

Çalışmada, sağlıklı (H), Jeneralize nöbet anı (J2) ve Jeneralize nöbet öncesi (J1) olan EEG kayıtlarının 5 çarpaz doğrulama (cross validation) sonucu elde edilen neticelerin ortalaması ile elde edilen doğruluk ortalaması (overall); %90.16 ($\pm 0.20\%$) olarak elde edilmiştir. Bu sınıflandırma sonucu oluşan karışıklık matrisi Çizelge 4.6. 'da verilmiştir.

Çizelge 4.6. Üç sınıf için 5 çarpaz doğrulamada elde edilen karışıklık matrisi (H: Sağlıklı, J1: Jeneralize nöbet öncesi, J2: Jeneralize nöbet anı)

		Tahmin Edilen		
		H	J1	J2
Gerçek Sınıf	H	8974	261	765
	J1	283	9343	374
	J2	843	425	8732

Her bir sınıftan 10000 adet görüntünün bulunduğu sınıflandırma işleminde, sağlıklı görüntülerden 261 adeti nöbet öncesi, 765 adeti de nöbet anı olarak sınıflandırılmıştır. Aynı şekilde nöbet öncesi sınıfına ait görüntülerden 283 tanesi sağlıklı, 374 tanesi de nöbet anı olarak bulunmuştur. Son olarak nöbet anı sınıfına ait 843 görüntü

sağlıklı, 425 ise nöbet öncesi olarak elde edilmiştir. Karışıklık matrisinden elde edilen model başarımlar ölçümü Çizelge 4.7. 'de verilmiştir.

Çizelge 4.7. Üç Sınıf için sınıflandırma performans sonuçları

Sınıf	Doğruluk (%)	Duyarlılık (%)	Özgünlük (%)	f-skor (%)
Sağlıklı (H)	92.63	89.74	94.13	89.29
J. Nöbet Öncesi(J1)	95.26	93.43	96.27	93.29
J. Nöbet Anı (J2)	91.82	87.32	94.14	87.88

Model başarımlar ölçümünde; sağlıklı (H), Jeneralize nöbet öncesi (J1) ve Jeneralize nöbet (J2) anına ilişkin skalogram görüntülerin doğruluk oranları sırasıyla %92.63, %95.26 ve %91.82 olarak bulunmuştur. Diğer model ölçüm başarımları olan Duyarlılık, Özgünlük ve f-skor 'ları sırasıyla en yüksek %95.26, %96.27, 93.29 ile Jeneralize nöbet öncesi görüntülerinden elde edilmiştir.

Çalışmanın bir diğer amacı olan epilepsi türlerinin ayrıştırma başarımlarını elde edebilmek için varolan görüntü sınıflarına parsiyel epilepsi hastalardan oluşturulan skalogram görüntüleri de eklenmiştir. Çalışmada 5 çarpaz doğrulama (cross validation) sonucu elde edilen neticelerin ortalaması ile elde edilen doğruluk ortalaması (overall); %84.66 ($\pm 0.48\%$) olarak elde edilmiştir. Bu sınıflardan elde edilen karışıklık matrisi ise Çizelge 4.8. 'de verilmiştir.

Çizelge 4.8. Dört sınıf için 5 çarpaz doğrulamada elde edilen karışıklık matrisi

(H: Sağlıklı, J1: Jeneralize nöbet öncesi, J2: Jeneralize nöbet anı ve P: Parsiyel EEG kaydı)

		Tahmin Edilen			
		H	J1	J2	P
Gerçek Sınıf	H	8307	583	215	895
	J1	560	8313	352	775
	J2	187	322	9150	341
	P	790	780	336	8094

Karışıklık matrisinden görüleceği üzere en yüksek oranda jeneralize, en düşük oranda ise parsiyel epilepsi hastaların skalogramları ayrıştırılmıştır. Bu sınıflardan elde edilen model başarımlar ölçümü Çizelge 4.9. 'da verilmiştir.

4. ARAŞTIRMA BULGULARI

Çizelge 4.9. Dört sınıf için sınıflandırma performans sonuçları

	Doğruluk (%)	Duyarlılık (%)	Özgünlük (%)	f-skor (%)
Sağlıklı (H)	91.29	83.07	94.32	83.72
J. Nöbet Öncesi (J1)	90.94	83.13	93.81	83.13
J. Nöbet anı (J2)	96.50	96.60	94.47	93.72
Parsiyel (P)	89.63	80.94	92.76	80.51


Çizelge 4.9. 'da; sağlıklı (H) EEG kayıtları %91.29, Jeneralize epilepsi (J2) %96.50, parsiyel (P) epilepsi %89.63, Jeneralize nöbet öncesi (J1) ise %90.94 oranında doğru olarak sınıflandırılmıştır. Aynı şekilde jeneralize nöbetin (J2) %96.60 duyarlılık oranında, sağlıklı (H) kayıtların ise %94.32 özgünlük oranında ayrıştırılabildiği görülmüştür.

Literatürde, DÜ Nöroloji klinik veri setinin kullanıldığı çalışmalar, çoğunlukla tıp alanındaki nörologların yaptığı çalışmalardır. Ancak mühendislik açısından bakıldığında, bu verilerin literatürde değerlendirilmediği görülmektedir. Dolayısıyla, önerilen yöntemin literatürdeki benzer çalışmalar ile karşılaştırılması yapılamamıştır. Karşılaştırmanın sadece yöntem boyutuyla yapılabileceği görülmekte olup, bir önceki bölümde bu karşılaştırma yapılmıştır. Klinikten alınan veri setinin sınıflandırılmasında, dikkati çeken bulgular aşağıda listelenmiştir:

- Kullanılan veri grup sayısı arttıkça, ESA mimarisine ilişkin başarısının kabul edilebilir seviyede olduğu,
- ESA mimarisi kullanılarak epilepsi türlerinin ayrıştırılabildiği,
- EEG işaretlerine daha fazla boyut kazandırılarak sınıflandırma performanslarının artırılabilceği görülmüştür.

4.2.1. DÜ Nöroloji Kliniği Veri Setinden Konvansiyonel Yöntem ile Elde Edilen Bulgular

Her bir sınıfı 10000 adet EEG bölütünden oluşan veri seti için; 5 alt band ve 7 öznitelik olmak üzere 3 sınıf için 30000x35, 4 sınıf için ise 40000x35 boyutunda öznitelik vektörü elde edilmiştir. Elde edilen bu öznitelik vektörü, 5 çapraz doğrulama (cross-validation) yapılarak, k-NN sınıflandırıcıda sınıflandırılmıştır. Elde edilen sınıflandırma başarısı Şekil 4.3. 'te verilmiştir.



Şekil 4.3. k-NN fold doğrulukları (Üç Sınıf için; H, J1 ve J2. Dört Sınıf için; H, J1, J2 ve P kullanılmıştır.)

Çalışmada, sağlıklı (H), Jeneralize nöbet öncesi (J1) ve Jeneralize nöbet anı (J2) olan EEG kayıtlarının 5 çarpaz doğrulama (cross validation) sonucu elde edilen neticelerin ortalaması ile elde edilen doğruluk ortalaması (overall); %73.12 olarak, bu sınıflara parsiyel epilepsi sınıfı eklendiğinde oluşan 4 sınıfın doğruluk ortalaması (overall) ise; %62.70 olarak elde edilmiştir.


DÜ Nöroloji Kliniği EEG veri setinden; konvansiyonel yöntemler kullanılarak elde edilen sınıflandırma başarımının, ESA sınıflandırma başarımı ile karşılaştırılması Çizelge 4.10. 'da verilmiştir.

Çizelge 4.10. DÜ Nöroloji Kliniği EEG veri setinin ESA ve k-NN sınıflandırma başarımları karşılaştırılması

Sınıf	ESA+ Skalogram Başarımı (%)	k-NN +ADD Başarımı (%)
Üç Sınıf (H-J1-J2)	90.16	73.12
Dört Sınıf (H-J1-J2-P)	84.66	62.70

Bu çalışmada, Çizelge 4.12. 'de görüleceği üzere ESA yönteminin konvansiyonel yöntemlere göre daha iyi sınıflandırma performansı gösterdiği görülmüştür. Ayrıca her bir çağraz doğrulamada, iki yöntemde de elde edilen başarı performanslarının karşılaştırılması Şekil 4.4. 'te verilmiştir.

4. ARAŞTIRMA BULGULARI



Şekil 4.4. ESA ve konvansiyonel yöntemlerin fold doğrulukları karşılaştırılması (üç sınıf için; H, J1 ve J2, dört sınıf için; H, J1, J2 ve P kullanılmıştır)

Şekil 4.4. 'te yapılan Fold doğrulukları karşılaştırmasında, en fazla farkın üç ve dört sınıfın ayrıştırılma başarımında 2. Fold işleminde gerçekleşmiştir. Öte yandan, en az farkın, üç sınıfın ayrıştırılmasında 4. Fold, dört sınıfın ayrıştırılmasında ise 5. Fold işleminde gerçekleştiği görülmüştür. Çalışmada, iki yöntemin karşılaştırılmasında belirgin en önemli nokta, sınıf sayısı ve buna bağlı olarak veri seti arttıkça, ESA yöntemi ile konvansiyonel yöntemlerin başarımları arasındaki farkın artmasıdır.

5. SONUÇ VE ÖNERİLER

Bu tez çalışmasında, EEG işaretlerinden Epilepsi türlerinin sınıflandırılması amaçlanmıştır. Türlerinin sınıflandırılmasında, EEG işaretinin boyutu artırılarak skalogram tabanlı bir derin öğrenme yaklaşımı önerilmiştir.

Derin öğrenme ağlarının görüntü işleme alanındaki başarısı ve EEG işaretlerinin boyut artırılarak sınıflandırma performansının artırılabilmesi, önerilen yöntemin temelini oluşturmaktadır. Bundan dolayı, EEG işaretlerine sürekli Morlet dalgacık dönüşümü uygulanarak, frekans-zaman içerikli skoloqram görüntüleri elde edilmiştir. Elde edilen görüntüler, ESA mimarisine uygulanarak nöbetin doğru bir şekilde belirlenmesi ve epilepsi türlerinin sınıflandırılması sağlanmıştır.

Tez kapsamında önerilen yöntemin başarısını değerlendirmek amacıyla çalışmada iki farklı EEG veri seti kullanılmıştır. Bunlardan birincisi literatürde çok sık kullanılan Bonn veri seti ve diğeri ise DÜ Nöroloji Kliniğinde yatan hastalardan alınan EEG kayıtlarıdır.

Yapılan çalışmanın bulguları, literatür ile birlikte değerlendirildiğinde, elde edilebilecek sonuçlar aşağıda listelenmiştir.

- Teknolojinin ilerlemesiyle beraber, yapay zeka yöntemleri sayesinde, hastalık tespitlerinin daha etkin yapılması beklenmektedir. Ancak literatürde, tıp dahil birçok alanda başarılı olarak kullanılan ve bir yapay zeka ürünü olan derin öğrenmenin, EEG işaretlerine uygulanması konusunda çok az çalışmanın olduğu görülmektedir. Ayrıca, tez konusu olan epilepsi türlerinin, derin öğrenme ağları kullanılarak sınıflandırılmasına ilişkin literatürde herhangi bir çalışma bulunmamaktadır. Dolayısıyla mühendislik alanında özellikle epilepsi türlerinin tespitine yönelik, klinisyenlere yardımcı araç olabilecek çalışmaların yapılması gerektiği açıktır. Bu çalışmada (Sağlıklı, Jeneralize nöbet öncesi, Jeneralize nöbet anı ve Parsiyel) epilepsi türleri farklı boyutuyla sınıflandırılmıştır. Bu yaklaşım, literatürde söz konusu olan eksikliği giderme bakımından bir başlangıç olacağı öngörülmektedir.
- Önerilen yöntem Bonn veri setine uygulanmış ve literatürdeki benzer çalışmalarla kıyaslandığında; sınıf sayısı arttıkça önerilen yöntemin en iyi performansı ürettiği gözlemlenmiştir.

- DÜ Nöroloji Kliniğinin artifakt içeren ham EEG verileri, ön işlem uygulamaksızın değerlendirilmeye alınmıştır. Elde edilen performans, önerilen yöntemin gürbüz bir yapıda olduğu kanaati oluşturmuştur.
- EEG kayıtlarının analizlerinde geleneksel olarak uygulanan boyut indirgeme çalışmaları, modellerin performansını düşürmektedir. Bu çalışmada, önerilen yöntem ile EEG kayıtları için boyut artırımına gidilmiş ve öznelik vektör içeriği zenginleştirilmiştir. Tez kapsamında elde edilen yüksek başarımın, boyut artırımından kaynaklı olduğu düşünülmektedir.
- Önerilen yöntemde, elektrotun konumundan bağımsız olarak EEG kayıtları değerlendirildiğinden, beyin dinamiği konusunda fikir edinilememiştir. Gelecek çalışmalarda bu konu üzerine yönelinmesi planlanmaktadır.
- Yeni yaklaşımların etkisini görmek amacıyla, gelecekte veri seti için KZFD yöntemi kullanılarak spektogram görüntülerinin elde edilmesi ve derin öğrenme mimarileri ile değerlendirilmesi planlanmaktadır.

5.1. Tez Kapsamında Yapılan Yayınlar

Science Citation Index (SCI) veya Science Citation Index Expanded (SCI-E) Yayınlar

- Türk, Ö., Özerdem, M. S. 2019. Epilepsy Detection by Using Scalogram Based Convolutional Neural Network from EEG Signals. *Brain sciences*, 9(5), 115.
- Ömer Türk, Veysi Akpolat, Sefer Varol, Ufuk Aluçlu, Mehmet Sıraç Özerdem, Classifications of Continuous Wavelet Transform Based EEG images using Convolutional Neural Networks, (Değerlendirme Aşamasında).

Konferans / Sempozyum Bildirileri

- Ömer TÜRK, Mehmet Sıraç ÖZERDEM, EEG Sinyallerinden Epilepsi Tespiti için Derin Öğrenme Yaklaşımı, 1st International Engineering and Technology Symposium (1st IETS) 03–05 May, 2018 Batman University.
- TÜRK, Ö., ÖZERDEM, M. S. 2018. İmleç Hareketine ilişkin EEG Kayıtlarının Evrimsel Sinir Ağı ile Sınıflandırılması, 2018 Innovations in Intelligent Systems and Applications Conference (ASYU), Adana.

6. KAYNAKLAR

- Acharya, U. R., Fujita, H., Sudarshan, V. K., Bhat, S., Koh, J. E. 2015. Application of entropies for automated diagnosis of epilepsy using EEG signals: A review. *Knowledge-Based Systems*, 88, 85-96.
- Acharya, U.R., Oh, S.L., Hagiwara, Y., Tan, J.H.; Adeli, H. 2018. Deep convolutional neural network for the automated detection and diagnosis of seizure using EEG signals. *Comput. Boil. Med.*, 100, 270–278.
- Acharya, U.R., Sree, S.V., Swapna, G., Martis, R.J., Suri, J.S. 2013. Automated EEG Analysis of Epilepsy: A Review, *Knowledge Based Systems*, 45,147–165.
- Adeli, H.Z., Dadmehr, Z.N. 2003. Analysis of EEG Records in An Epileptic Patient Using Wavelet Transform, *Journal of Neuroscience Methods*, Vol. 123, pp. 69-87.
- Aiswal K. J, Banka H. 2017. Local Pattern Transformation Based Feature Extraction Techniques for Classification of Epileptic EEG signals. *Biomedical Signal Processing and Control*, 34,81–92.
- Alom, M. Z., Taha, T. M., Yakopcic, C., Westberg, S., Sidike, P., Nasrin, M. S., Asari, V. K. 2018. The history began from alexnet: A comprehensive survey on deep learning approaches. **arXiv preprint** Erişim :[arXiv:1803.01164]. Erişim Tarihi: 21.06.2019.
- Alpaydın, E., 2004, Introduction to Machine Learning, The MIT Press, Printed and bound in the United States of America. ISBN 0-262-01211-1.
- Altay E., Yeni Teknolojiler İle Öğrenmenin 5 Yolu: Erisim: [https:// altayece558640192.wordpress.com/teorik-dersler/ 9-hafta-kavram- haritalama-2/]. Erişim Tarihi:11.05.2019.
- Altiokka U. 2015. Göz Kapağı Miyoklonisi Olan İdyopatik Jeneralize Epilepsi Olgularında Klinik Ve Eeg Özellikleri, Göz Kırpma Refleksi İle Glut-1 Mutasyonunun Araştırılması, Uzmanlık Tezi, İstanbul Üniversitesi İstanbul Tıp Fakültesi Nöroloji Anabilim Dalı, İstanbul.97.
- Ay, B., Yildirim, O., Talo, M., Baloglu, U. B., Aydın, G., Puthankattil, S. D., Acharya, U. R. 2019. Automated Depression Detection Using Deep Representation and Sequence Learning with EEG Signals. *Journal of medical systems*, 43(7), 205.
- Banerjee PN, Filippi D, Hauser WA. (2009). The descriptive epidemiology of epilepsy. *Epilepsy Research* ,85:31-45.
- Bashivan, P., Rish, I., Yeasin, M., Codella, N. 2015. Learning representations from EEG with deep recurrent-convolutional neural Networks. (*arXiv:1511.06448*).
- Başar, E., Başar-Eroglu, C., Karakaş, S., Schürmann, M. 2001. Gamma, alpha, delta, and theta oscillations govern cognitive processes. *Int. J. Psychophysiol*, 39, 241–248.
- Baxter, C. W., Zhang, Q., Stanley, S. J., Shariff, R., Tupas, R. R., Stark, H. L. 2001. Drinking water quality and treatment: the use of artificial neural networks. *Canadian Journal of civil engineering*, 28(S1), 26-35.
- Bhattacharyya, A., Pachori, R., Upadhyay, A., Acharya, U. 2017. Tunable-Q wavelet transform based multiscale entropy measure for automated classification of epileptic EEG, *signals. Appl. Sci.*, 7, 385.

- Bi, X., Wang, H. 2019. Early Alzheimer's disease diagnosis based on EEG spectral images using deep learning. *Neural Networks*, 114, 119-135.
- Bialasiewicz, J. T. 2015. Application of Wavelet Scalogram and Coscalogram for Analysis of Biomedical Signals. In Proceedings of the 2nd International Conference on Biomedical Engineering and Systems, Barcelona, Spain.
- Bilir, E. 1999. Beyin Elektriksel Faaliyetinde Nörolojik Rahatsızlıklara Başlı Değişiklikler, Tübitak Beyin Dinamiği Multidisipliner Lisans Üstü Yaz Okulu: Nörofizyoloji ve Kognitif Süreçlerde Entegrasyon, Ders Notu, Dicle Üni., Diyarbakır.
- Bonn Dataset: Available online Erişim: [<http://www.meb.unibonn.de/epileptologie/science/physik/eeegdata.html>]. Erişim Tarihi: 17.12.2018.
- Boureau, Y. L., Ponce, J., LeCun, Y. 2010. A theoretical analysis of feature pooling in visual recognition. In Proceedings of the 27th international conference on machine learning (ICML 2010), 21–24 June 2010, Publisher: Haifa, Israel, pp. 111–118.
- Buluş E. 2014. Epilepsi Hastalarında Refleks Nöbet Uyarıcı Taraması Ve Refleks Nöbet Uyarıcı Varlığında, Kognitif Fonksiyonların İnteriktal Eeg Üzerine Etkisinin Araştırılması, Uzmanlık Tezi, İstanbul Üniversitesi Cerrahpaşa Tıp Fakültesi Nöroloji Anabilim Dalı, İstanbul.92.
- Chabolla DR, Cascino GD. 1996. Interpretation of extracranial EEG. In: Wyllie E, editor. The treatment of epilepsy: principles and practice. Baltimore: Williams and Wilkins. p. 264-9.
- Chandaka, S., Chatterjee, A., Munshi, S. 2009. Cross-correlation aided support vector machine classifier for classification of EEG signals. *Expert Syst. Appl.*, 36, 1329–1336.
- Cohen, M. X. 2017. Where does EEG come from and what does it mean?. *Trends in neurosciences*, 40(4), 208-218.
- Costilla R., O., Scully, P., Ozanyan, K. B. 2017. Deep Neural Networks for Learning Spatio-Temporal Features from Tomography Sensors. *IEEE Transactions on Industrial Electronics*.
- Erbey F. 2005. Kompleks parsiyel epilepsili hastalarda klinik ve psikososyal prognoz, Uzmanlık Tezi, Çukurova Üniversitesi Tıp Fakültesi Çocuk Sağlığı ve Hastalıkları Anabilim Dalı, Adana. 67.
- Fadlullah, Z. M., Tang, F., Mao, B., Kato, N., Akashi, O., Inoue, T., Mizutani, K. 2017. State-of-the-art deep learning: Evolving machine intelligence toward tomorrow's intelligent network traffic control systems. *IEEE Communications Surveys & Tutorials*, 19(4), 2432-2455.
- Fakhr, S., M., Torbati M. M., Hill M., Hill, C., M., White, P., R. 2014. Signal processing techniques applied to human sleep EEG signals—A review, *Biomedical Signal Processing and Control* 10,21–33,.
- Falamarzi, Y., Palizdan, N., Huang, Y. F., Lee, T. S. 2014. Estimating evapotranspiration from temperature and wind speed data using artificial and wavelet neural networks (WNNs). *Agricultural Water Management*, 140, 26-36.
- Faust, O., Acharya, U. R., Adeli, H., Adeli, A. 2015. Wavelet-based EEG processing for computer-aided seizure detection and epilepsy diagnosis. *Seizure*, 26, 56-64.

- Fisher, R. S.; Boas, W. V. E.; Blume, W.; Elger, C.; Genton, P.; Lee, P.; Engel Jr, J. 2005. Epileptic seizures and epilepsy: definitions proposed by the International League Against Epilepsy (ILAE) and the International Bureau for Epilepsy (IBE). *Epilepsia*, 46, 470–472.
- Fukushima, K. 1988. Neocognitron: A hierarchical neural network capable of visual pattern recognition. *Neural networks*, 1(2), 119-130.
- Görgülü, Ü., Fesci, H. 2011. Epilepsi ile yaşam: Epilepsinin psikososyal etkileri. *Göztepe Tıp Dergisi*, 26(1), 27-32.
- Guo, Y., Liu, Y., Oerlemans, A., Lao, S., Wu, S., Lew, M. S. 2016. Deep learning for visual understanding: A review. *Neurocomputing*, 187, 27-48.
- Güler, I., Kıymık, M.K., Akın, M., Alkan, A. 2001. AR Spectral Analysis of EEG Signals By Using Maximum Likelihood Estimation, *Comp. in Biology and Medicine*, Vol. 31, pp. 441-450.
- Hajinorozi, M., Mao, Z., Jung, T. P., Lin, C. T., Huang, Y. 2016. EEG-based prediction of driver's cognitive performance by deep convolutional neural network. *Signal Processing: Image Communication*, 47, 549-555.
- He, K., Zhang, X., Ren, S., Sun, J. 2015. Spatial pyramid pooling in deep convolutional networks for visual recognition. *IEEE transactions on pattern analysis and machine intelligence*, 37(9), 1904-1916.
- Hinton, G. E., Osindero, S., Teh, Y. W. 2006. A fast learning algorithm for deep belief nets. *Neural computation*, 18(7), 1527-1554.
- Hussein, R., Elgendi, M., Wang, Z.J., Ward, R.K. 2018. Robust detection of epileptic seizures based on L1-penalized robust regression of EEG signals. *Expert Syst. Appl.*, 104, 153–167.
- Ibrahim, S., Djemal, R., Alsuwailem, A. 2018. Electroencephalography (EEG) signal processing for epilepsy and autism spectrum disorder diagnosis. *Biocybern. Biomed. Eng.*, 38, 16–26.
- İnik, Ö., Erkan, Ü. 2017. Derin Öğrenme ve Görüntü Analizinde Kullanılan Derin Öğrenme Modelleri. *Gaziosmanpaşa Bilimsel Araştırma Dergisi*, 6(3), 85-104.
- Jia, J.; Goparaju, B.; Song, J.; Zhang, R.; Westover, M. B. 2017. Automated identification of epileptic seizures in EEG signals based on phase space representation and statistical features in the CEEMD domain. *Biomed. Signal Proces.*, 38, 148–157.
- Jia, X. 2017. Image recognition method based on deep learning. In Control And Decision Conference (CCDC), 2017 29th Chinese (pp. 4730-4735). IEEE.
- Kannathal, N., Choo, M. L., Acharya, U. R., Sadasivan, P. K. 2005. Entropies for detection of epilepsy in EEG. *Computer methods and programs in biomedicine*, 80(3), 187-194.
- Karakaş, S., Baran, Z. (2010). Beynin Elektriksel Faaliyeti: Kavramlar, işlemler, olaylar ve analiz teknikleri (Böl. 6). N. Yüksel (Ed.) Temel Psikofarmakoloji.
- Kareem, A.; Kijewski, T. 2002. Time-frequency analysis of wind effects on structures. *J. Wind Eng. Ind. Aerod.*, 90, 1435–1452.

- Kaya Y., Uyar M., Tekin R., Yıldırım S. 2014. 1D-Local Binary Pattern Based Feature Extraction For Classification of Epileptic EEG Signals, *Applied Mathematics and Computation*, 243209–219.
- Kayaalp, K., Süzen, A. A. 2018. Derin Öğrenme ve Türkiye’deki Uygulamaları. IKSAD Publishing House.92p.
- Khoursheed, E. A., Essa, A. S. 2019. EEGs Feature Extraction by Multi-Level DWT with Different Numbers of Principal Components. In *2019 International Conference on Advanced Science and Engineering (ICOASE)* (pp. 1-6). IEEE.
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). Imagenet classification with deep convolutional neural networks. *In Advances in neural information processing systems* (pp. 1097-1105).
- Kuang, Q., Zhao, L. 2009. A practical GPU based kNN algorithm. In *Proceedings. The 2009 International Symposium on Computer Science and Computational Technology (ISCSCI 2009)* (p. 151). Academy Publisher.
- Kumar T. S., Kanhangad V., Pachori R. B. 2015. Classification of Seizure and Seizure-Free EEG Signals Using Local Binary Patterns , *Biomedical Signal Processing and Control*, 15,33–40.
- Kumar, Y., Dewal, M. L., Anand, R. S. 2014. Epileptic seizure detection using DWT based fuzzy approximate entropy and support vector machine. *Neurocomputing*, 133, 271–279.
- Lau, K. M., Weng, H. 1995 Climate signal detection using wavelet transform: How to make a time series sing. *Bulletin of the American meteorological society*, 76(12), 2391-2402.
- LeCun, Y., Bengio, Y., Hinton, G. 2015. Deep learning. *Nature*, 521(7553), 436-444.
- Lee, J. G., Jun, S., Cho, Y. W., Lee, H., Kim, G. B., Seo, J. B., Kim, N. (2017). Deep learning in medical imaging: general overview. *Korean journal of radiology*, 18(4), 570-584.
- Lee, S. H., Lim, J. S., Kim, J. K., Yang, J., Lee, Y. 2014. Classification of normal and epileptic seizure EEG signals using wavelet transform, phase-space reconstruction, and Euclidean distance. *Comput. Meth. Prog. Bio.*, 116, 10–25.
- Li, S., Zhou, W., Yuan, Q., Geng, S.; Cai, D. 2013. Feature extraction and recognition of ictal EEG using EMD and SVM. *Comput. Biol. Med.*, 43, 807–816.
- Lin, M., Chen, Q., Yan, S. 2013. Network in network. Erişim: [<https://arxiv.org/abs/1312.4400>]. Erişim Tarihi: 19.12.2018
- Lu, Y., Ma, Y., Chen, C., Wang, Y., Gómez, C., Schwarzacher, S.P., Zhou, H. 2018. Classification of single-channel EEG signals for epileptic seizures detection based on hybrid features. *Technol. Heal. Care*, 26, 337–346.
- Merih K. 2018. R yazılımı ile makine öğrenmesi (Machine Learning) I – Genel Tanımlar, Erişim: [<http://bilisim.io/2017/03/03/r-yazilimi-ile-makine-ogrenmesi-machine-learning-i-genel-tanimlar>]. Erişim Tarihi 12.04.2019.
- Misiti, M., Misiti, Y., Oppenheim, G., Poggi, J.M. 2013. Wavelets and their Applications. John Wiley & Sons: Great Britain, 2013.

- Misra UK, Kalita J. 2005. Clinical electroencephalography. 1st ed. Noida: Elsevier, a division of Reed Elsevier India Private Limited.
- Motamedi-Fakhr, S., Moshrefi-Torbati, M., Hill, M.; Hill, C.M., White, P. R. 2014 Signal processing techniques applied to human sleep EEG signals—A review. *Biomed. Signal Proces.*, 10, 21–33.
- Mousavi, Z., Rezaii, T. Y., Sheykhivand, S., Farzamnia, A., Razavi, S. N, 2019. Deep convolutional neural network for classification of sleep stages from single-channel EEG signals. *Journal of neuroscience methods*, 108312.
- Naz S. Y., Karaağaç N. 2005. Epilepsiler, Nörolog Olmayanlar İçin Nöroloji Sempozyum Dizisi No: 42, s. 159-175.
- Nigam, V.P.; Graupe, D. 2004. A neural-network-based detection of epilepsy. *Neurol. Res.*, 26, 55–60.
- Noachtar, S., Rémi, J. 2009. The role of EEG in epilepsy: a critical review. *Epilepsy & Behavior*, 15(1), 22-33.
- Ouyang, W., Wang, X., Zeng, X., Qiu, S., Luo, P., Tian, Y., Tang, X. 2015. Deepid-net: Deformable deep convolutional neural networks for object detection. *In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition* (pp. 2403-2412).
- Peng, Z., Chu, F., He, Y. 2002. Vibration signal analysis and feature extraction based on reassigned wavelet Skalogram. *Journal of Sound and Vibration*, 253(5), 1087-1100.
- Pillai J, Sperling MR. 2006. Interictal EEG and the diagnosis of epilepsy. *Epilepsia*, 47 Suppl 1:14-22.
- Polat, K.; Güneş, S. 2007. Classification of epileptiform EEG using a hybrid system based on decision tree classifier and fast Fourier transform. *Appl. Math. Comput.*, 187, 1017–1026.
- Poultney, C., Chopra, S., Cun, Y. L. 2007. Efficient learning of sparse representations with an energy-based model. *In Advances in neural information processing systems* (pp. 1137-1144).
- Ravi, D., Wong, C., Deligianni, F., Berthelot, M., Andreu-Perez, J., Lo, B., Yang, G. Z. 2017. Deep learning for health informatics. *IEEE journal of biomedical and health informatics*, 21(1), 4-21.
- Richman, J. S., Moorman, J. R. 2000. Physiological time-series analysis using approximate entropy and sample entropy. *American Journal of Physiology-Heart and Circulatory Physiology*, 278(6), H2039-H2049.
- Rosso, O. A., Blanco, S., Yordanova, J., Kolev, V., Figliola, A., Schürmann, M., Başar, E. 2001. Wavelet entropy: a new tool for analysis of short duration brain electrical signals. *Journal of neuroscience methods*, 105(1), 65-75.
- Sanei, S., Chambers, J. A. 2007. EEG Signal Processing. John Wiley and Sons Ltd, 289, United Kingdom.
- San-Segundo, R., Gil-Martín, M., D'Haro-Enríquez, L. F., Pardo, J. M. (2019). Classification of epileptic EEG recordings using signal transforms and convolutional neural networks. *Computers in biology and medicine*, 109, 148-158.

- Seely, A. J., Macklem, P. T. 2004. Complex systems and the technology of variability analysis. *Critical care*, 8(6), R367.
- Sharmila, A., Aman Raj, S., Shashank, P. 2018. Mahalakshmi, P. Epileptic seizure detection using DWT-based approximate entropy, Shannon entropy and support vector machine: a case study. *J. Med. Eng. Technol.*, 42, 1–8.
- Sokolova, M., Japkowicz, N., Szpakowicz, S. 2006. Beyond accuracy, F-skor and ROC: a family of discriminant measures for performance evaluation. In Australasian joint conference on artificial intelligence, Springer: Berlin, Heidelberg, 2006, pp. 1015–1021.
- Song, Y., Liò, P. 2010. A new approach for epileptic seizure detection: sample entropy based feature extraction and extreme learning machine. *Journal of Biomedical Science and Engineering*, 3(06), 556.
- Subasi, A. 2007. EEG signal classification using wavelet feature extraction and a mixture of expert model. *Expert Syst. Appl.*, 32, 1084–1093.
- Sucak T., 2011. Kompleks parsiyel nöbetli hastalarda Pozitron emisyon tomografisinin tanısal Rolünün elektroensefalografi ve manyetik Rezonans görüntüleme ile karşılaştırmalı Olarak değerlendirilmesi, Uzmanlık Tezi, Gazi Üniversitesi Tıp Fakültesi, Nükleer Tıp Anabilim Dalı, Ankara.124.
- Swami, P., Gandhi, T.K., Panigrahi, B.K., Tripathi, M., Anand, S. 2016. A novel robust diagnostic model to detect seizures in electroencephalography. *Expert Syst. Appl.*, 56, 116–130.
- Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Rabinovich, A. 2015. Going deeper with convolutions. In Proceedings of the IEEE conference on computer vision and pattern recognition (pp. 1-9).
- Tabar, Y. R., Halici, U. 2016. A novel deep learning approach for classification of EEG motor imagery signals. *Journal of neural engineering*, 14(1), 016003.
- Tang, Z., Li, C., Sun, S. 2017. Single-trial EEG classification of motor imagery using deep convolutional neural networks. *Optik-International Journal for Light and Electron Optics*, 130, 11-18.
- Tawfik, N.S., Youssef, S.M., Kholief, M. 2016. A hybrid automated detection of epileptic seizures in EEG records. *Comput. Electr. Eng.*, 53, 177–190.
- Tolić, M., Jović, F. 2013. Classification of wavelet transformed EEG signals with neural network for imagined mental and motor tasks. *Kinesiology: International journal of fundamental and applied kinesiology*, 45(1), 130-138.
- Tülay, E.E. 2009. Beyin elektriksel aktivitesinin ölçümü ve sinyal analizi, Yüksek Lisans Tezi, İ.K.Ü. Fen Bilimler Enstitüsü, İstanbul.53.
- Uktveris, T., Jusas, V. 2017. Application of Convolutional Neural Networks to Four-Class Motor Imagery Classification Problem. *Inf. Technol.*, 46, 260–273.
- Ullah, I., Hussain, M., 2018. Aboalsamh, H., An automated system for epilepsy detection using EEG brain signals based on deep learning approach. *Expert Syst. Appl.*, 107, 61–71.
- Unser, M., Aldroubi, A. 1996. A review of wavelets in biomedical applications. *Proceedings of the IEEE*, 84(4), 626-638.

- Wan, L., Zeiler, M., Zhang, S., Le Cun, Y., Fergus, R. 2013, February. Regularization of neural networks using dropconnect. *In International Conference on Machine Learning* (pp. 1058-1066).
- Wang, H.; Raj, B. 2017. On the origin of deep learning. Erişim: [<https://arxiv.org/abs/1702.07800>]. Erişim Tarihi: 21.01.2019.
- Wang, X., Gong, G., Li, N. 2019. Automated Recognition of Epileptic EEG States Using a Combination of Symlet Wavelet Processing, Gradient Boosting Machine, and Grid Search Optimizer. *Sensors*, 19, 219.
- Wyllie, E., Cascino, G. D., Gidal, B. E., Goodkin, H. P. 2012. Wyllie's treatment of epilepsy: principles and practice. Lippincott Williams & Wilkins: Philadelphia, USA.
- Xiang, J., Li, C., Li, H., Cao, R., Wang, B., Han, X., Chen, J. 2015. The detection of epileptic seizure signals based on fuzzy entropy. *J. Neurosci. Methods*, 243, 18–25.
- Yi, D., Lei, Z., Liao, S., Li, S. Z. 2014. Deep metric learning for person re-identification. In proceedings of 2014 22nd International Conference on Pattern Recognition, Stockholm, Sweden, 24-28 August 2014, IEEE: Piscataway, NJ, USA, pp. 34–39.
- Yuan, L., Cao, J. 2017. Patients' EEG data analysis via spectrogram image with a convolution neural network. In International Conference on Intelligent Decision Technologies(pp. 13-21). Springer, Cham.
- Yuan, Y., Xun, G., Jia, K., Zhang, A. 2017. A novel wavelet-based model for eeg epileptic seizure detection using multi-context learning. In Proceedings of 2017 IEEE International Conference on Bioinformatics and Biomedicine (BIBM), Kansas City, MO, USA, 13–16 November 2017, IEEE: Piscataway, NJ, US, pp. 694-699. doi: 10.1109/BIBM.2017.8217737
- Zahra, A., Kanwal, N., urRehman N.; Ehsan, S., McDonald-Maier, K. D. 2017. Seizure detection from EEG signals using multivariate empirical mode decomposition. *Comput. Biol. Med.*, 88, 132–141.
- Zeiler, M. D., Fergus, R. 2013. Stochastic pooling for regularization of deep convolutional neural networks. *arXiv preprint arXiv:1301.3557*.
- Zhang, J., Li, S., Yin, Z. 2017. Pattern Classification of Instantaneous Mental Workload Using Ensemble of Convolutional Neural Networks. *IFAC-PapersOnLine*, 50(1), 14896-14901.
- Zhang, T., Chen, W., 2017. LMD based features for the automatic seizure detection of EEG signals using SVM. *IEEE T. Neur. Sys. Reh.*, 25, 1100–1108.
- Zhao, R., Yan, R., Chen, Z., Mao, K., Wang, P., Gao, R. X. 2016. Deep learning and its applications to machine health monitoring: Erişim: [<https://arxiv.org/abs/1612.07640>]. Erişim Tarihi:10.01.2018.



ÖZGEÇMİŞ

Adı Soyadı: Ömer TÜRK

Doğum Yeri: Diyarbakır

Doğum Tarihi: 04.03.1981

Medeni Hali: Evli

Yabancı Dili: İngilizce

Eğitim Durumu (Kurum ve Yıl)

Lise: Diyarbakır Yunus Emre Lisesi / Diyarbakır, 1998

Lisans: KTMÜ, Bilgisayar Mühendisliği / Bişkek, 2005

Yüksek Lisans: Fırat Üniversitesi Bilgisayar Mühendisliği / Elazığ, 2011

Çalıştığı Kurum / Kurumlar ve Yıl: Mardin Artuklu Üniversitesi Öğretim Görevlisi (2009 - Halen), Mardin





DİCLE ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
TEZ İNTİHAL FORMU

ÖĞRENCİ BİLGİLERİ

ADI VE SOYADI	Ömer TÜRK
ÖĞRENCİ NO	14805502
EĞİTİM – ÖĞRETİM YILI	2018-2019
YARIYIL	<input type="checkbox"/> Güz <input checked="" type="checkbox"/> Bahar
ANABİLİM DALI	Elektrik-Elektronik Mühendisliği
PROGRAM	Doktora
TEZ KONUSU	EEG İşaretlerinden Epilepsi Türlerinin Sınıflandırılmasında Skalogram Tabanlı Derin Öğrenme Yaklaşımı

İNTİHAL RAPORU BİLGİLERİ

RAPOR TÜRÜ	Tez Savunma Sınavı Sonrası
SAYFA SAYISI	98
BENZERLİK ORANI	%20
RAPORLAMA TARİHİ	19/07/ 2019

Yukarıda başlığı/konusu gösterilen tez çalışmamın kapak sayfası, giriş, ana bölümler, sonuç ve tartışma kısımlarından oluşan toplam 98 sayfalık kısmına ilişkin, 19/07/2019 tarihinde şahsım/tez danışmanım tarafından *Turnitin* adlı intihal tespit programından aşağıda belirtilen filtrelemeler uygulanarak alınmış olan intihal raporuna göre, tezimin benzerlik oranı %20 'tür.

Uygulanan filtrelemeler:

- Kabul/Onay sayfaları hariç,
 Kaynakça hariç
 Alıntılar hariç/dâhil
 Diğer

Dicle Üniversitesi Fen Bilimleri Enstitüsü Lisansüstü Programlarda Tez Çalışması İntihal Raporu Uygulama Esasları'nı inceledim ve bu Uygulama Esasları'nda belirtilen azami benzerlik oranlarına göre tez çalışmamın herhangi bir intihal içermediğini; aksinin tespit edilmesi durumunda doğabilecek her türlü hukuki sorumluluğu kabul ettiğimi ve vermiş olduğum bilgilerin doğru olduğunu beyan ederim.

Gereğini saygılarımla arz ederim.

Ömer TÜRK
(İMZA/TARİH)
06.08.2019

Prof. Dr. Mehmet Sıraç ÖZERDEM
Tez Danışmanı
(İMZA/TARİH)
06.08.2019

Doç. Dr. Bilal GÜMÜŞ
Anabilim Dalı Başkanı
(İMZA/TARİH)
06.08.2019

Formdaki bilgiler bilgisayar ortamında doldurulmalıdır. El yazısı ile doldurulan formlar geçersiz sayılmaktadır.