

**KOCAELİ ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ**

**ELEKTRONİK VE HABERLEŞME MÜHENDİSLİĞİ  
ANABİLİM DALI**

**DOKTORA TEZİ**

**EEG İŞARETLERİNDE EVRİŞİMLİ SINIR AĞLARI İLE  
EPİLEPTİK NÖBET TAHMİNİ**

**AHMET REMZİ ÖZCAN**

**KOCAELİ 2020**

**KOCAELİ ÜNİVERSİTESİ**  
**FEN BİLİMLERİ ENSTİTÜSÜ**


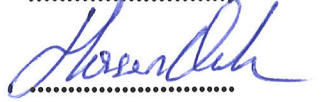

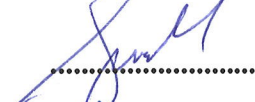

**ELEKTRONİK VE HABERLEŞME MÜHENDİSLİĞİ**  
**ANABİLİM DALI**

**DOKTORA TEZİ**

**EEG İŞARETLERİNDE EVRİŞİMLİ SINIR AĞLARI İLE**  
**EPİLEPTİK NÖBET TAHMİNİ**

**AHMET REMZİ ÖZCAN**

**Prof. Dr. Sarp ERTÜRK**  
**Danışman, Kocaeli Üniversitesi**  
**Prof. Dr. Hasan OCAK**  
**Jüri Üyesi, Kocaeli Üniversitesi**  
**Doç. Dr. Osman BÜYÜK**  
**Jüri Üyesi, Kocaeli Üniversitesi**  
**Doç. Dr. Koray KAYABOL**  
**Jüri Üyesi, Gebze Teknik Üniversitesi**  
**Doç. Dr. Ahmet MERT**  
**Jüri Üyesi, Bursa Teknik Üniversitesi**

  
.....  
  
.....  
  
.....  
  
.....  
  
.....

**Tezin Savunulduğu Tarih: 05.02.2020**

## ÖNSÖZ VE TEŞEKKÜR

Bu tez çalışmasında, evrişimli sinir ağları temelli, hastaya özel mühendislik gerektirmeyen ve herhangi bir kafa derisi EEG veri setine genelleştirilebilen, hasta tabanlı bir nöbet tahmin yöntemi sunulmuştur. Çalışmamın bu alanda çalışan araştırmacılara katkı sağlaması dileğiyle.

Doktora eğitimi boyunca birikimlerini benimle paylaşan, çalışmalarına yön veren, bana güvenen, destekleyen ve zaman ayıran değerli hocam Prof. Dr. Sarp Ertürk'e teşekkürlerimi sunarım. Tez çalışması süresince değerli görüşleriyle tezime katkı sağlayan değerli hocalarım Prof. Dr. Hasan Ocak ve Doç. Dr. Alp Ertürk'e teşekkürlerimi sunarım. Tez çalışmam boyunca bilgisi ve uzmanlığı ile bana yol gösteren, zor zamanlarımda beni destekleyen ve cesaretlendiren babam Prof. Dr. Abdulcemal Özcan'a teşekkürlerimi sunarım.

Hayatım boyunca benden maddi ve manevi desteklerini esirgemeyen, zor zamanlarımda güç veren anneme, babama ve aileme, hayatıma girdiği andan itibaren desteğini ve sevgisini yanımda hissettiğim sevgili eşime çok teşekkür ederim.

Şubat - 2020

Ahmet Remzi Özcan

## İÇİNDEKİLER

ÖNSÖZ VE TEŞEKKÜR.....	i
İÇİNDEKİLER.....	ii
ŞEKİLLER DİZİNİ.....	iv
TABLolar DİZİNİ.....	vii
SİMGELER VE KISALTMALAR DİZİNİ.....	viii
ÖZET.....	x
ABSTRACT.....	xi
GİRİŞ.....	1
1. KURAMSAL TEMELLER.....	4
1.1. Epilepsi.....	4
1.2. EEG.....	5
1.2.1. Normal EEG işareti.....	7
1.2.2. Epileptik EEG işareti.....	8
1.3. Epileptik Nöbet Tahmini.....	10
1.4. Nöbet Tahmininde EEG Tabanlı Ölçümler.....	13
1.4.1. Doğrusal ölçüm yöntemleri.....	13
1.4.1.1. Dalgacık dönüşümü.....	13
1.4.1.2. Spektral bant gücü.....	14
1.4.1.3. Spektral kenar gücü.....	15
1.4.1.4. Otokorelasyon ve otoregresif modelleme.....	15
1.4.1.5. İstatistiksel momentler.....	15
1.4.1.6. Hjorth parametreleri.....	16
1.4.1.7. Basit senkronizasyon ölçümü.....	16
1.4.1.8. Korelasyon yapısı.....	16
1.4.2. Doğrusal olmayan ölçüm yöntemleri.....	17
1.4.2.1. Algoritmik komplekslik.....	17
1.4.2.2. Birikimli enerji.....	18
1.4.2.3. Dinamik benzerlik indeksi.....	18
1.4.2.4. Lyapunov üsteli.....	18
1.4.2.5. Korelasyon boyutu.....	19
1.4.2.6. Yinelenme kaybı ve yerel akış.....	20
1.4.2.7. Entropi.....	20
1.4.2.8. Faz senkronizasyonu.....	20
2. YAPAY SİNİR AĞLARI.....	22
2.1. Tek Katmanlı Algılayıcı.....	23
2.2. Çok Katmanlı Sinir Ağları.....	24
2.3. Aktivasyon Fonksiyonu.....	26
2.4. Kayıp Fonksiyonu.....	27
2.4.1. Ortalama karesel hata (L2) kaybı.....	27
2.4.2. Çapraz entropi kaybı.....	29
2.5. Geri-Yayımlı Algoritması.....	30
3. EVRİŞİMLİ SİNİR AĞLARI.....	33

3.1. Evrişimli Sinir Ağı Modellerinin Gelişimi .....	34
3.2. Evrişimli Sinir Ağı Mimarisi.....	36
3.2.1. Evrişim katmanı.....	37
3.2.2. Birleştirme katmanı .....	38
3.2.3. Tam-bağlı katman.....	39
3.3. Evrişimli Sinir Ağlarının Eğitimi .....	40
3.3.1. Gradyan azalma tabanlı optimizasyon .....	40
3.3.2. Evrişimli sinir ağlarının eğitiminde zorluklar .....	43
3.3.3. Ağırlık ilklendirme .....	45
3.3.4. Düzenleştirme.....	46
3.3.5. Ağ seyreltme .....	47
3.3.6. Erken durdurma .....	47
4. MATERİYAL VE YÖNTEM.....	49
4.1. Veri Seti .....	49
4.2. Öznitelik Çıkarımı .....	50
4.3. EEG Zaman Serilerinden Görüntü Oluşturma .....	52
4.4. Evrişimli Sinir Ağı .....	55
4.4.1. Tek-çerçeve CNN modeli .....	56
4.4.2. Çok-çerçeve CNN modeli .....	57
4.5. Eğitim.....	58
4.6. Kritik Bölge Isı Haritalarının Oluşturulması .....	60
5. DENEYSEL SONUÇLAR .....	62
5.1. Epileptik Evre Sürelerinin Nöbet Tahmin Başarımına Etkisi .....	65
5.2. Değişken Ağırlıklı Öğrenmenin Nöbet Tahmin Başarımına Etkisi .....	65
5.3. Şans Tahmincisine Karşı Test .....	68
5.4. Epileptik EEG’de Kritik Bölgelerin Belirlenmesi.....	70
6. TARTIŞMA.....	74
7. SONUÇLAR VE ÖNERİLER .....	80
KAYNAKLAR .....	82
EKLER .....	91
KİŞİSEL YAYIN VE ESERLER.....	101
ÖZGEÇMİŞ .....	102

## ŞEKİLLER DİZİNİ

Şekil 1.1.	Epileptik nöbetlerin sınıflandırması.....	5
Şekil 1.2.	Uluslararası 10-20 sisteminde kafa derisi elektrotlarının yerleşimi.....	7
Şekil 1.3.	Normal EEG işareti örnekleri. Uyanıklık durumunda alfa dalgalarının ortalama frekansı 10 Hz civarında iken, erken uyku ve derin uyku evrelerinde ortalama frekans azalmaktadır. Çığneme, kablo gürültüsü ve göz kırpması gibi bozucu etkiler rahatlıkla seçilebilmektedir .....	9
Şekil 1.4.	Epileptik nöbet EEG işareti örneği.....	11
Şekil 1.5.	EEG işaretlerinde epileptik evreler .....	12
Şekil 2.1.	Biyolojik sinir hücresi ve yapay sinir modeli.....	23
Şekil 2.2.	İki gizli katmanlı ileri beslemeli bir sinir ağının temel mimarisi .....	25
Şekil 2.3.	Çeşitli aktivasyon fonksiyonları .....	28
Şekil 2.4.	Hesaplamalı çizgelerde zincir kuralının gösterimi .....	31
Şekil 3.1.	LeNet5 evrişimli sinir ağı modelinin genel mimarisi.....	34
Şekil 3.2.	Evrişim katmanlarında gerçekleştirilen evrişim işlemi.....	37
Şekil 3.3.	Birleştirme katmanında $2 \times 2$ pencere ile gerçekleştirilen maksimum ve ortalama birleştirme işlemi .....	39
Şekil 3.4.	Evrişim katmanı öznitelik haritaları ile tam-bağlı katmanlar arasındaki bağlantılar.....	40
Şekil 3.5.	L1 ve L2 düzenleme metotlarının 2 boyutlu öznitelik uzayında gösterimi .....	46
Şekil 3.6.	Sinir ağında tam-bağlı katmanlara uygulanan seyreltme işlemi.....	47
Şekil 3.7.	Erken durdurma ile doğrulama hatasının artmaya başladığı adımda eğitimin sonlandırılması .....	48
Şekil 4.1.	Nöbet tahmin aralığı ve gerçekleşme periyodu tanımlamaları .....	49
Şekil 4.2.	Tanımlanan epileptik evre zamanlamaları.....	50
Şekil 4.3.	EEG elektrot yerleşimlerinin topoloji-korumalı iz düşümü. (a) Kafa derisi elektrotlarının 3-boyutlu uzaydaki yerleşimi. (b) Elektrot konumlarının Azimutal Eş Uzaklıklı İz Düşümü.....	53
Şekil 4.4.	Çok kanallı EEG öznitelikleri kullanılarak farklı metotlarla oluşturulan öznitelik görüntülerinin karşılaştırılması. (a) Topoloji-korumalı 2-boyutlu izdüşümden enterpolasyon ile elde edilen öznitelik görüntüsü, (b) topoloji korunmadan elde edilen öznitelik görüntüsü.....	53
Şekil 4.5.	EEG zaman serilerinden EEG öznitelik görüntülerinin oluşturulması. (a) Spektral bant gücü, istatistiksel moment ve Hjorth parametreleri özniteliklerinin elde edilmesi (b) Kübik enterpolasyon ile EEG öznitelik görüntülerinin oluşturulması.....	54
Şekil 4.6.	Öğrenme kapasitesinin temsili gösterimi. (a) Öğrenme kapasitesi yeterlidir. (b) Evrişim çekirdeği boyutu yeterli büyüklükte olmadığından öğrenme kapasitesi yetersiz kalmaktadır .....	56
Şekil 4.7.	Tek-çerçeve CNN modeli .....	57

Şekil 4.8. Çok-çerçeve CNN modeli .....	58
Şekil 4.9. Çok-katmanlı algılayıcı modeli .....	60
Şekil 4.10. Kritik bölge ısı haritasının oluşturulmasında kullanılan kapama testi. Sol üstte verilen örnek görüntü için kayar pencere ile küçük bir bölge kapatılarak ağın doğru etiketi tahmin etme eğilimi test edilmektedir .....	61
Şekil 5.1. MLP, CNN ve 3B CNN modelleri ile MIT Physionet sEEG veri setinde Hasta-1 için elde edilen nöbet tahmin değerleri .....	62
Şekil 5.2. Hasta-1'in nöbet tahmin değerleri için oluşturulan işlem karakteristiği eğrisi.....	63
Şekil 5.3. Farklı epileptik evre süreleri ile yapılan denemeler. Preiktal ve interiktal evre arasındaki gri alanlar eğitim dışı bırakılmıştır.....	65
Şekil 5.4. Oluşturulan modellerin farklı epileptik evre uzunlukları için nöbet tahmin başarımları, AUC değeri ortalamaları ve standart sapmaları ile verilmiştir. $\leq 0,01$ , $\leq 0,05$ ve $> 0,05$ anlamlılık seviyeleri sırasıyla $\blacktriangledown$ , $\nabla$ , ve $\triangle$ ile işaretlenmiştir.....	66
Şekil 5.5. Tek taraflı Wilcoxon işaretli sıralama testi ile elde edilen anlamlılık değerleri (p-değeri) matrisi, (a) MLP, (b) CNN, (c) 3B CNN modelleri için farklı epileptik evre uzunluklarının birbirine üstünlüğünü (dikey eksenin yatay eksene üstünlüğü) ortaya koymaktadır. Anlamlılık değerleri $< 0,05$ için kalın olarak işaretlenmiştir .....	67
Şekil 5.6. MIT Physionet sEEG veri setinden 8 hasta için preiktal ve iktal evre örneklerinden elde edilen kritik bölge ısı haritaları. Öznitelik görüntüleri, ilgili hastadaki tüm preiktal ve iktal kayıtlar boyunca 14 öznitelik ortalamasını temsil eder. Kritik bölge ısı haritaları, görüntüdeki bölgelerin CNN ile sınıflandırmada ne kadar etkili olduğunu göstermektedir .....	72
Şekil 5.7. MIT Physionet sEEG veri setinde Hasta-1 için öznitelik tabanlı kritik bölge ısı haritaları .....	73
Şekil 6.1. Khan ve ark., Truong ve ark. ve bu tez çalışmasında MIT Physionet sEEG veri setindeki hastalar için nöbet tahmininde elde edilen AUC değerleri karşılaştırması.....	77
Şekil A.1. Wilcoxon işaretli sıralama testinde hipotez kabul ve hipotez reddetme bölgeleri .....	93
Şekil B.1. MIT Physionet sEEG veri setinde Hasta-3 için öznitelik tabanlı kritik bölge ısı haritaları .....	94
Şekil B.2. MIT Physionet sEEG veri setinde Hasta-5 için öznitelik tabanlı kritik bölge ısı haritaları .....	95
Şekil B.3. MIT Physionet sEEG veri setinde Hasta-9 için öznitelik tabanlı kritik bölge ısı haritaları .....	96
Şekil B.4. MIT Physionet sEEG veri setinde Hasta-14 için öznitelik tabanlı kritik bölge ısı haritaları .....	97
Şekil B.5. MIT Physionet sEEG veri setinde Hasta-20 için öznitelik tabanlı kritik bölge ısı haritaları .....	98

Şekil B.6. MIT Physionet sEEG veri setinde Hasta-21 için öznitelik tabanlı kritik bölge ısı haritaları .....	99
Şekil B.7. MIT Physionet sEEG veri setinde Hasta-23 için öznitelik tabanlı kritik bölge ısı haritaları .....	100





## TABLolar DİZİNİ

Tablo 1.1. Literatürde nöbet tahmininde kullanılan bazı EEG tabanlı ölçüm yöntemleri .....	14
Tablo 4.1. Tez çalışmasında test edilen MIT Physionet sEEG veri setindeki hastalar için interiktal veri uzunlukları ve nöbet sayıları .....	51
Tablo 5.1. MLP modelinin MIT Physionet sEEG veri seti için nöbet tahmin başarımı .....	63
Tablo 5.2. CNN modelinin MIT Physionet sEEG veri seti için nöbet tahmin başarımı .....	64
Tablo 5.3. 3B CNN modelinin MIT Physionet sEEG veri seti için nöbet tahmin başarımı .....	64
Tablo 5.4. MLP modelinin MIT Physionet sEEG veri seti için değişken ağırlıklı öğrenme ile nöbet tahmin başarımı .....	68
Tablo 5.5. CNN modelinin MIT Physionet sEEG veri seti için değişken ağırlıklı öğrenme ile nöbet tahmin başarımı .....	69
Tablo 5.6. 3B CNN modelinin MIT Physionet sEEG veri seti için değişken ağırlıklı öğrenme ile nöbet tahmin başarımı .....	69
Tablo 6.1. MIT Physionet sEEG veri seti için bu tez çalışmasında önerilen yöntemin ve diğer epileptik nöbet tahmin çalışmalarının başarımlarını sonuçları .....	75
Tablo 6.2. MIT Physionet sEEG veri setindeki hastalar için interiktal-iktal evre uzaklığına bağlı olarak toplam interiktal veri uzunluğunun değişimi .....	78
Tablo A.1. Wilcoxon işaretli sıralama testinde, istatistik değeri W için alt ve üst kritik değerler .....	93

## SİMGELER VE KISALTMALAR DİZİNİ

$\alpha$	: EEG alfa frekansı
$\beta$	: EEG beta frekansı
$\delta$	: EEG delta frekansı
$\gamma$	: EEG gama frekansı
$\lambda$	: Düzenleştirme gücü
$\lambda_i$	: Lyapunov üsteli
$\lambda_w$	: Poisson oranı
$\mu$	: Öğrenme hızı
$\nabla$	: Gradyan
$\nabla E(w)$	: Hata gradyanı
$\Phi(\cdot)$	: Aktivasyon fonksiyonu
$\rho_w$	: Uyarıda harcanan zaman
$\theta$	: EEG teta frekansı
$AE_m$	: Birikimli enerji
$E$	: Ortalama karesel kata
$E_n$	: Çapraz entropi kaybı
$E_i$	: Ani enerji
$L(p, y)$	: Logaritmik kayıp fonksiyonu
$p_n(\cdot)$	: Softmax kayıp fonksiyonu
$S_n$	: Duyarlılık
$S_{nc}$	: Şans tahmincisi duyarlılığı
$S_x$	: Spektral güç yoğunluğu
$y$	: Doğru etiket değeri
$\hat{y}$	: Tahmin değeri
$w$	: Ağ ağırlığı

## Kısaltmalar

3B	: 3 Boyutlu
AEP	: Azimuthal Equidistant Projections (Azimutal Eşuzaklıklı İzdüşüm)
AUC	: Area Under the ROC Curve (ROC Eğrisi Altında Kalan Alan)
BT	: Bilgisayarlı Tomografi
CNN	: Convolutional Neural Network (Evrışimli Sinir Ağı)
EEG	: Elektroensefalografi
FPR	: False Positive Rate (Yanlış Pozitif Oranı)
GPU	: Graphics Processing Unit (Grafik İşlem Birimi)
ILSVRC	: ImageNet Large Scale Visual Recognition Competition
iEEG	: Interictal EEG (Kafa içi EEG)
L1	: Least Absolute Deviation (En Küçük Mutlak Sapma)
L2	: Least Squares (En Küçük Kareler)
LReLU	: Leaky Rectified Linear Unit (Sızan Düzeltilmiş Doğrusal Birim)
LSTM	: Long Short-Term Memory (Uzun Kısa-Süreli Hafıza)
MIT	: Massachusetts Institute of Technology
MLP	: Multilayer Perceptron (Çok-katmanlı Algılayıcı)
MNIST	: Modified National Institute of Standards and Technology Database
MR	: Manyetik Rezonans

PSD	: Power Spectral Density (Spektral Güç Yoğunluğu)
ReLU	: Rectified Linear Unit (Düzeltilmiş Doğrusal Birim)
ROC	: Receiver Operating Characteristic (Alıcı İşlem Karakteristiği)
sEEG	: Scalp EEG (Kafa derisi EEG)
SOP	: Seizure Occurrence Period (Nöbet Gerçekleşme Periyodu)
SPH	: Seizure Prediction Horizon (Nöbet Tahmin Aralığı)
STFT	: Short-time Fourier Transform (Kısa-sürelî Fourier Dönüşümü)



## EEG İŞARETLERİNDE EVRİŞİMLİ SINIR AĞLARI İLE EPİLEPTİK NÖBET TAHMİNİ

### ÖZET

Epilepsi tekrarlı ve ani gelişen nöbetlerle karakterize edilen, toplumda her 200 kişiden birini etkileyen, yaygın görülen bir nörolojik hastalıktır. Epilepsi hastalarının %30'una epilepsi ilaçları tedavi edici etki sağlamamakta, bir çoğu için ise cerrahi operasyon seçeneği mümkün olamamaktadır. Nöbet tahmini için yüksek başarımlı yöntemlerin geliştirilmesi, bu gruba giren hastalar için yaklaşmakta olan nöbetin öngörülmesini ve zararlarının en aza indirilmesini sağlayacaktır.

Epileptik nöbetler, epileptik ağlarda zamansal ve uzamsal olarak gelişen bir sürecin sonucu olarak ortaya çıkmaktadır. Bu tez çalışmasının amacı, çok kanallı EEG sinyallerinden elde edilen özniteliklerdeki uzamsal ve zamansal korelasyonun değerlendirilerek, hastaya özgü, genelleştirilebilir bir nöbet tahmin yöntemi geliştirmektir. EEG sinyallerinin frekans ve zaman bölgesi özelliklerini ortaya çıkarmak amacıyla spektral bant gücü, istatistiksel moment ve Hjorth parametreleri öznitelikleri kullanılmıştır. Elde edilen öznitelikler, EEG kanallarının topolojisi korunarak, çok renkli görüntü dizisine dönüştürülmüş ve bir evrişimli sinir ağına girdi olarak verilmiştir. Oluşturulan modellerin eğitimi sırasında farklı epileptik evre süreleri denenmiş, bu sürelerin nöbet tahmin başarımı üzerindeki etkileri araştırılmıştır. Önerilen 3B CNN modeli, MIT Physionet kafa derisi EEG veri setinden 16 hasta ile yapılan testlerde, %85,7 duyarlılığa ve 0,096/saat yanlış tahmin oranına, %10,5 uyarıda geçen zaman oranı ile ulaşmıştır. Sonuçlar, önerilen yöntemin Poisson bazlı bir şans tahmincisine üstünlüğünün, 0,05 anlamlılık düzeyinde, hastaların %93,7'si için istatistiksel olarak anlamlı olduğunu ortaya koymuştur. Farklı zamanlama kısıtlamaları ile yapılan denemelerde, epileptik evre uzunluklarının nöbet performansını etkileyen önemli bir faktör olduğu sonucuna ulaşılmıştır.

Bu tez çalışmasında, hastaya özel mühendislik gerektirmeyen ve herhangi bir kafa derisi EEG veri setine genelleştirilebilen, hasta bazlı bir nöbet tahmin yöntemi sunulmuştur.

**Anahtar Kelimeler:** EEG, Epilepsi, Epileptik Evre Uzunluğu, Evrişimli Sinir Ağları, Nöbet Tahmini.

# **EPILEPTIC SEIZURE PREDICTION IN EEG SIGNALS USING CONVOLUTIONAL NEURAL NETWORKS**

## **ABSTRACT**

Epilepsy is a common neurological disorder characterized by recurrent and sudden seizures affecting one in every 200 people in the community. Epilepsy medications do not provide therapeutic effect in 30% of epilepsy patients, and surgical options are not possible for most of them. The development of high-performance methods for seizure prediction will ensure that the upcoming seizure is predicted for patients in this group, and that its harm is minimized.

Epileptic seizures result from a process in epileptic networks that develops over time and space. The aim of this thesis is to develop a patient-specific, generalizable seizure prediction method by evaluating the spatial and temporal correlation of the features obtained from multichannel EEG signals. Spectral band power, statistical moment and Hjorth parameters were used to reveal the frequency and time domain characteristics of EEG signals. The obtained features were transformed into a sequence of multi-color images according to the topology of the EEG channels and given as input to a convolutional neural network. During the training of the models, different epileptic stage lengths were tested and their effects on seizure prediction performance were investigated. The proposed 3D CNN model achieves a sensitivity of 85.7%, a false prediction rate of 0.096/h, and a proportion of time in warning of 10.5%, in the tests with 16 patients from the MIT Physionet scalp EEG dataset. The results showed that the superiority of the proposed method to a Poisson-based chance predictor was statistically significant for 93.7% of the patients, at significance level of 0.05. Experiments with various timing constraints have shown that epileptic stage lengths are an important factor affecting seizure performance.

In this thesis, a patient-based seizure prediction method that can be generalized to any scalp EEG dataset without the need for subject-specific engineering was presented.

**Keywords:** EEG, Epilepsy, Epileptic Stage Length, Convolutional Neural Networks, Seizure Prediction.

## GİRİŞ

Epilepsi, tekrarlayan ve ani gelişen epileptik nöbetlerle karakterize edilen, dünya genelinde 40 milyondan fazla insanı etkileyen yaygın bir nörolojik hastalıktır [1]. Beyinde bulunan çok sayıda sinir hücresinin olağan dışı ve eş zamanlı bir şekilde çalışması sonucu epileptik deşarj meydana gelmektedir. Bu deşarjlar gerçekleştiği bölgeye ve büyüklüğe göre epileptik nöbetlere neden olabilmektedir. Epilepsi hastalarının %30'unda, yan etkileri göze alınarak kullanılmasına rağmen, epilepsi ilaçları etkili olamamaktadır [2]. Bazı durumlarda beyinde epileptik nöbete neden olan bölgenin ameliyatla alınması alternatif bir çözüm olarak tercih edilmekle birlikte, hayati önem taşıyan bölgelere zarar verme olasılığından dolayı yüksek riski de beraberinde getirmektedir [3]. Dolayısıyla, her üç epilepsi hastasından biri ilaç tedavisi yada cerrahi operasyon uygulanmadığından, ne zaman ortaya çıkacağı bilinmeyen bir nöbet tehlikesiyle yaşamak zorundadır.

Nöbet tahmin yöntemleri geliştirilmeden önce, epileptik nöbetlerin izole ve ani gelişen vakalar olduğuna inanılmaktaydı. Araştırmalar, nöbetlerin epileptik bir ağda zamansal ve uzamsal olarak gelişen süreçlerin bir sonucu olarak ortaya çıktığını göstermektedir. Epilepsi hastalarının EEG verileri üzerinde yapılan çalışmalar, nöbetlerin klinik olarak başlamadan dakikalar veya saatler önce gelişmeye başladığına dair güçlü kanıtlar ortaya koymaktadır [1]. Günümüzde, hastalardan alınan uzun süreli EEG kayıtları, bilgisayar teknolojisindeki gelişmeler, EEG verilerinin daha iyi analiz edilmesini sağlayan matematiksel yöntemler, epileptik nöbet öncüllerinin tanımlanmasına olanak sağlamaktadır [2]. Nöbet tahmin çalışmalarının çoğunda, epileptik EEG sinyallerinde interiktal, preiktal, iktal ve postiktal olmak üzere ardışık dört beyin aktivite durumu olduğu kabul edilmektedir [1]. Bununla birlikte, bazı yeni çalışmalar epileptik EEG sinyallerinin farklı aktivite durumları olarak sınıflandırıldığı kategorik bir nöbet tahmini yerine, sürekli bir nöbet olasılığı tahmini sağlayan bir yaklaşım benimsemiştir [4–8]. Bu yaklaşıma göre nöbet riskinin arttığı dönem, pro-iktal evre olarak tanımlanmaktadır [6].

Nöbet tahmininde genel olarak amaç, interiktal evreyi, nöbetin klinik olarak gerçekleştiği iktal evreden hemen öncesi olarak tanımlanan preiktal evreden ayırt etmektir. Bu yaklaşım, nöbet tahminini epileptik EEG verilerinin interiktal veya preiktal olarak sınıflandırıldığı bir ikili sınıflandırma problemine dönüştürmektedir. Klinik EEG verileri üzerinde yapılan çalışmalar, çıkarılan özniteliklerin iktal

aşamadan önce farklılaşmaya başladığına işaret etse de , aynı ölçümleri veya öznitelikleri kullanan çalışmaların çoğunun farklı veri kümelerinde veya hastalarda kabul edilebilir performans sağlayamaması, epileptik nöbet tahmininin hala zorlu bir problem olduğunu göstermektedir [9–12]. Epileptik evrelerin süreleri, karakteristikleri ve dinamikleri hastadan hastaya geniş ölçüde değişkenlik gösterdiğinden, ilgili hasta için eğitim gerçekleştirmeksizin, her hasta için yüksek nöbet tahmin performansı elde edecek genel bir nöbet kestirim metodu henüz önerilmemiştir. Bu nedenle, nispeten yüksek nöbet tahmin duyarlılığı elde edilen çalışmaların çoğunda, hasta-tabanlı bir yaklaşım benimsenmiştir [10–16].

Sinyallerin toplandığı yere bağlı olarak, birkaç EEG kayıt tipi bulunmaktadır. EEG işaretleri kafa içi EEG’de (iEEG) doğrudan beyin açık yüzeyine yerleştirilen elektrotlarla toplanırken, kafa derisi EEG’de (sEEG) kafa derisine yerleştirilen elektrotlardan elde edilir. Her ne kadar bazı çalışmalar uzun süreli nöbet danışma sistemlerinde iEEG’nin kullanılmasının daha uygun olduğunu gösterse de [17, 18], sEEG klinik pratikte daha kolay uygulanabilir bir yöntem olduğundan ve veri setlerine erişim kolaylığı nedeniyle çalışmalarda yaygın olarak kullanılmaktadır.

Nöbet tahmini çalışmalarında, nöbet öncesi EEG’deki değişiklikleri saptamak amacıyla doğrusal ve doğrusal olmayan birçok öznitelik önerilmiştir. Doğrusal öznitelikler olarak mutlak ve göreceli spektral bant gücü [9, 14, 19, 20], otoregresif katsayılar [21], birikimli enerji [22], Hjorth parametreleri ve istatistiksel momentler [23] kullanılmıştır. En büyük Lyapunov üssü [24], korelasyon boyutu [25], dinamik benzerlik endeksi [26] ve faz senkronizasyonu [16, 27] dahil olmak üzere çeşitli doğrusal olmayan öznitelikler de nöbet tahmininde kullanılmıştır. Yakın dönemde yapılan çalışmalarda, epileptik sinyallerden öznitelik çıkarımında dalgacık dönüşümü [11, 28], kısa-süreli Fourier dönüşümü [12], kesirli Fourier dönüşümü [29] gibi daha karmaşık yöntemler tercih edilmiştir. Özelliklerin sınıflandırılmasında ise destek vektör makineleri [9, 20, 21, 30], Bayes sınıflandırıcı [13, 31] ve evrişimli sinir ağları [11, 12] gibi makine öğrenmesi algoritmaları kullanılmıştır.

Bu tez çalışmasında epileptik nöbetleri başarıyla öngörebilecek bir yöntemin geliştirilmesi amaçlanmıştır. Bununla birlikte beyinde nöbet aktivite bölgesinin tespitine yönelik olarak epileptik aktivitenin uzamsal ve zamansal dinamikleri de araştırılmıştır. Yapılan çalışmalarla bu amaca yönelik en uygun yaklaşımın, EEG sinyallerinden elde edilen özniteliklerin, uzamsal yapının korunduğu bir görüntüye dönüştürülerek işlenmesi olduğu sonucuna ulaşılmıştır. Önerilen yaklaşımın uygulanabilirliğinin araştırıldığı ön çalışmada, ardışık bağlı CNN ve LSTM ağları kullanılarak çok kanallı EEG sinyallerinden elde edilen çok boyutlu görüntü serileri

ile hastadan bağımsız bir nöbet tahmini yapılmıştır [32]. Ön çalışmada önerilen modelde, uzamsal ilinti CNN'deki birinci katmandan itibaren değerlendirilirken, zamansal ilintinin değerlendirilmesi yapıdaki LSTM ağlarına kadar ertelenmektedir. Ayrıca eğitim aşamasında k-kat çapraz doğrulama kullanılmaktadır. Tez çalışmasında, ön çalışmada önerilen modelin eksiklikleri giderilerek, çok kanallı EEG sinyallerinde hem uzamsal hem de zamansal ilintinin ilk katmandan itibaren değerlendirildiği, 3B CNN tabanlı hastaya özgü bir nöbet tahmin modeli önerilmektedir. Ayrıca, test performansının gerçek koşullara daha yakın olmasını sağlamak için birisi-dışarıda (leave-one-out) çapraz doğrulama kullanılmaktadır.

Tez çalışmasının ilk bölümünde epilepsi hakkında genel bilgiler verilerek, normal ve epileptik EEG işaretinin karakteristik özellikleri tanımlanmıştır. Ayrıca bu bölümde epileptik nöbet tahmini ve literatürde nöbet tahminine yönelik olarak kullanılan EEG tabanlı ölçüm yöntemleri açıklanmıştır.

İkinci bölümde yapay sinir ağlarına giriş yapılarak tek katmanlı algılayıcı ve çok katmanlı sinir ağları irdelenmiş, bu yapıların tasarımında kullanılan aktivasyon fonksiyonları, kayıp fonksiyonu ve geri-yayımlı algoritması detaylandırılmıştır.

Üçüncü bölümde evrişimli sinir ağı modellerinin gelişimi ve mimarisi hakkında temel bilgiler verilmiştir. Ayrıca bu bölümde evrişimli sinir ağlarının eğitiminde kullanılan yöntemler, karşılaşılan zorluklar ve bu zorlukların üstesinden gelmek amacıyla başvurulan tekniklerden bahsedilmiştir.

Dördüncü bölümde tez çalışmasında kullanılan veri seti hakkında bilgi verilmiş, öznitelik çıkarımı ve bu özniteliklerden görüntü oluşturma işlemi açıklanmıştır. Yine bu bölümde tez çalışması kapsamında önerilen tek-çerçeve CNN ve çok-çerçeve CNN modellerinin mimarisi anlatılmış, gerçekleştirilen eğitim işleminden bahsedilmiştir.

Beşinci bölümde önerilen nöbet tahmin yönteminin deneysel sonuçları verilmiş, epileptik evre sürelerinin ve değişken ağırlıklı öğrenmenin nöbet tahmin başarımına etkisi irdelenmiştir ve elde edilen sonuçların şans tahmincisine olan üstünlüğü ortaya konulmuştur. Son olarak önerilen nöbet tahmin modelinin epileptojenik beyin bölgesi tespitine uygulanabilirliği araştırılmıştır.

Altıncı bölümde tez kapsamında önerilen yöntemin başarımı literatürdeki diğer nöbet tahmin çalışmaları ile karşılaştırılmış ve elde edilen sonuçların nedenleri tartışılmıştır.

Tezin son bölümünde ise genel sonuç ve öneriler sunulmuştur.



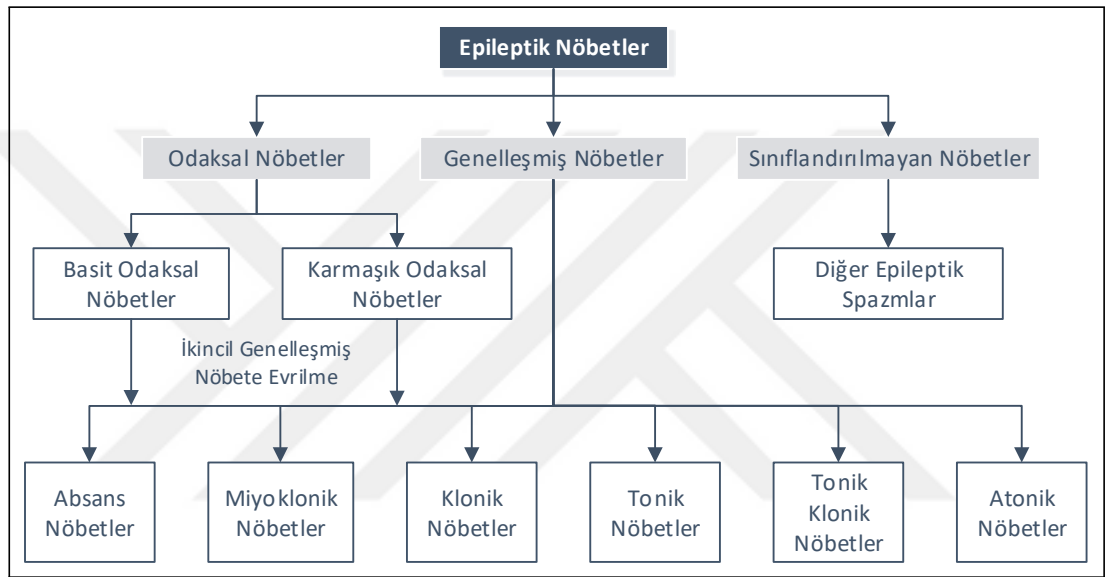
## 1. KURAMSAL TEMELLER

### 1.1. Epilepsi

Epilepsi, beyinde tekrarlayan ve sebepsiz nöbetlere karşı süregelen bir yatkınlık ile karakterize edilen bir nörolojik hastalıktır. Alkol yoksunluğu veya aşırı kan şekeri gibi bilinen ve geri dönüşümlü bir tıbbi durumdan kaynaklanmayan en az iki sebepsiz nöbet geçiren bir hastaya epilepsi tanısı konulmaktadır. Epileptik nöbetler beyin hasarı veya aile eğilimine bağlı olarak gelişebilmekle birlikte çoğu kez nedeni bilinmemektedir. Nöbet sırasında hastanın maruz kaldığı nöbet türüne bağlı olarak beyinin belirli alanlarında anormal nöronal aktiviteler tespit edilmektedir. Dünya nüfusunun yaklaşık %1'inin epilepsi hastası olduğu tahmin edilmektedir ve bu kişilerin %30'unda epilepsi ilaçlarının etkili olmadığı kanıtlanmıştır [2]. Epilepsi hastalarının ne zaman ve nerede gerçekleşeceğini bilmedikleri bir nöbet tehdidiyle yaşamak zorunda kalmaları, araba kullanmak, yüzmek veya yemek yapmak gibi günlük faaliyetlerden kaçınmalarına neden olarak yaşam kalitesinde ciddi bir düşüşe yol açmaktadır. Bazı durumlarda, epilepsi hastalığının kendisi başlı başına hayatı tehdit edici olabilmektedir.

Epilepsi terimi bir çok semptomu tanımlamak amacıyla kullanılmakla birlikte, epilepsi genellikle hastanın maruz kaldığı nöbet tiplerine göre alt sınıflara ayrılmaktadır. Uluslararası Epilepsiyle Mücadele Birliği (ILAE) tarafından standartları belirlenen nöbet tiplerinin sınıflandırılmasında, beyinde nöbetin gerçekleştiği anatomik pozisyondan ziyade klinik belirtiler ve EEG kayıtları göz önünde bulundurulmaktadır [33]. Buna göre epileptik nöbetler Şekil 1.1. ile verildiği üzere odaksal(kısmi) ve genelleşmiş olmak üzere iki sınıfta incelenmektedir. Odaksal nöbetler başlangıçta beyinin sadece bir yarım küresini etkileyen, dolayısıyla genelleşmiş nöbetlere kıyasla daha küçük bir bölgede gerçekleşen nöbetlerdir. Hastanın nöbet nedeniyle bilincinde bir değişiklik geçirip geçirmediğine bağlı olarak basit ve karmaşık nöbet olarak iki alt sınıfa ayrılmaktadır. Basit bir kısmi nöbetten sonra hasta bilincini kaybetmez ancak hastada motor, duyuşal ve otonomik belirtiler gözlenebilmektedir. Epilepsi tanısı konulan hastalardan yaklaşık %60'ı kısmi nöbet geçirmektedir. Genelleşmiş nöbetler, beyinin iki yarım küresini etkileyen ve bilinç kaybına neden olan nöbetlerdir. Bu nöbetler hastada gösterdiği semptomlara bağlı olarak altı alt sınıfa ayrılmaktadır. Absans nöbetleri, hastada ani ve çok kısa süreli (30 saniyeden daha az) bilinç kayıpları ile karakterize edilen en sık görülen genelleşmiş

nöbet türüdür. Nöbet sonrasında EEG işaretlerinde postiktal evre genellikle gözlenmemektedir. Bu epilepsi türü bazı durumlarda hasta tarafından hayal kurmakla karıştırılabilmektedir [34]. Miyoklonik nöbetler, nöbet sırasında kasların çok kısa bir süre boyunca istemsiz kasılmasıyla kontrolsüz hareketlere neden olan bir genelleşmiş nöbet türüdür. Klonik nöbetlerde ise kasların istemsiz kasılması her 2 ila 3 saniyede tekrarlanmaktadır. Tonik-Klonik nöbetler, kasların ritmik olarak kasılmaya başladığı bir klonik nöbetin ardından bazı kasların güçlü bir şekilde kasılmasıyla karakterize edilmektedir. Atonik nöbetlerde, kas tonusunda hastayı yere düşürecek seviyede bir azalma görülebilmektedir.



Şekil 1.1. Epileptik nöbetlerin sınıflandırması [33]

## 1.2. EEG

Epilepsinin teşhisinde gerekli bilgilerin çoğu elektroensefalogram (EEG) işaretlerinin kullanımı ile elde edilmektedir. EEG, beyin kendiliğinden oluşan elektriksel aktivitesinin, belirli bir periyot boyunca, sıklıkla kafa derisine yerleştirilen elektrotlar aracılığıyla ölçülerek oluşturulan elektriksel işaret olarak tanımlanmaktadır [35]. EEG işaretleri epilepsi teşhisi dışında uyku bozuklukları, anestezi derinliği, koma, beyin ölümü, ensefalopati gibi hastalık ve durumların tespitinde de kullanılmaktadır. Daha önce tümör, inme ve diğer odaksal beyin hastalıklarının ilk tanısında da sıklıkla kullanılan EEG yerine, günümüzde gelişen teknoloji ile birlikte manyetik rezonans görüntüleme (MR) ve bilgisayarlı tomografi (BT) gibi yöntemler daha çok tercih edilmektedir. Her ne kadar elektrot sayısı ve yerleşimi gibi sınırlamalara bağlı olarak MR ve BT gibi görüntüleme tekniklerine göre sınırlı bir uzamsal çözünürlük sunsa da, zamansal alanda sağladığı milisaniye uzunluğundaki çözünürlük ile EEG ölçümleri değerli bir klinik yöntem olmayı sürdürmektedir. Beyindeki elektriksel

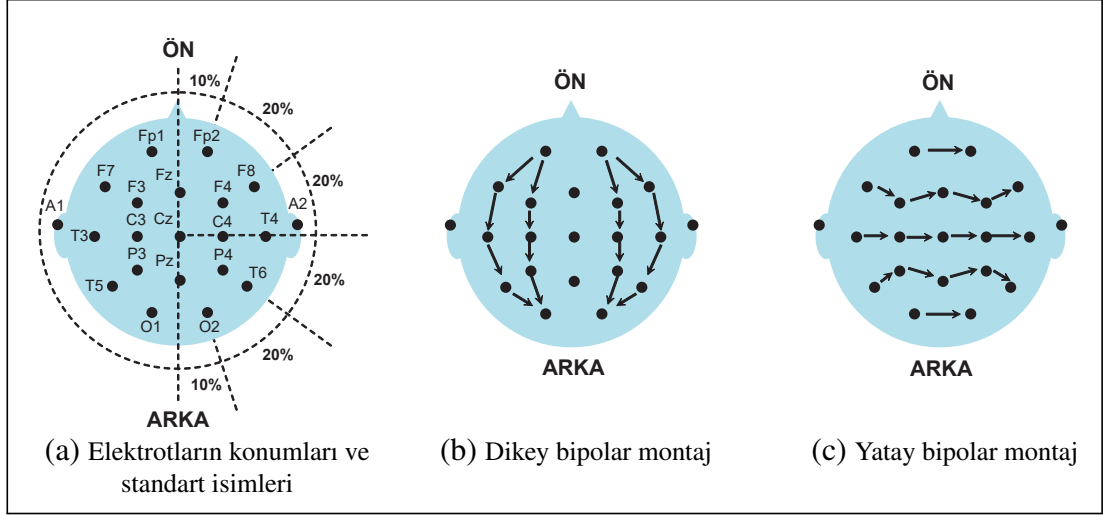
aktivitelere dair ilk bulgular 1875 yılında İngiliz nörofizyolog Richard Caton tarafından tavşan ve maymunlar üzerinde açık beyin ölçümleri ile elde edilmiş olmasına rağmen, EEG ölçümleri invaziv olmayan bir uygulamanın mümkün olduğu 1920'lere kadar klinik olarak uygun hale gelmemiştir [36].

EEG ölçümleri farklı uzamsal ölçeklerde gerçekleştirilebilmektedir. İnvazif olmayan bir yöntem olarak kafa derisi üzerinden dolaylı olarak, ya da cerrahi yöntemler aracılığıyla invazif olarak beyin korteksi içinden EEG işaretleri elde edilebilmektedir. Her iki yöntemin de bazı avantaj ve dezavantajları bulunmaktadır:

1. Kafa Derisi EEG (sEEG): Beyinde oluşan elektrik işareti sinirsel olmayan farklı doku katmanlarından (beyin omurilik sıvısı, kafatası ve kafa derisi) yayılarak derideki elektrotlara ulaşmaktadır. Bu yayılım sonucu elektrotlarda oluşan işaret çok zayıfladığından, kayda değer bir EEG sinyalinin elde edilebilmesi için beynin daha büyük bir bölümünün aktif ve senkron olması gerekmektedir. Uygulaması kolay ve ucuz bir yöntem olan kafa derisi EEG (sEEG) klinik olarak çoğu durumda yeterli bilgi sağlamaktadır. Ayrıca bazı durumlarda daha detaylı kafa içi EEG kaydından önce bir ön teşhis aracı olarak kullanılır. Kafa derisi EEG kayıtlarının bir hasta için veya hastalar arasında karşılaştırılabilir olmasını sağlamak amacıyla, elektrot yerleşiminde çeşitli standartlar oluşturulmuştur. Elektrot yerleşiminde kullanılan uluslararası 10-20 standardı Şekil 1.2.'de verilmektedir. Bu yerleştirme sisteminin avantajı, elektrotların konumlarının standart mesafelerin yüzdesi olarak hesaplanmasıdır. Bu şekilde, EEG kayıtlarında her bir kanalın farklı hastalarda beynin aynı bölgesindeki elektriksel aktiviteyi göstermesi mümkün olmaktadır. Şekil 1.2.b ve Şekil 1.2.c bipolar kayıt için iki standart elektrot montaj şeklini göstermektedir. Şekil 1.2.b ile verilen elektrot montajında dikey olarak komşu elektrotlar arasındaki potansiyel fark, Şekil 1.2.c'de ise yatay komşu elektrotlar arasındaki potansiyel fark kaydedilmektedir.

2. Kafa İçi EEG (iEEG): Bu yöntemde beyinde oluşan elektriksel aktivite beyin korteksine ya da talamus gibi bölgelerin bulunduğu korteks altına cerrahi operasyon ile yerleştirilen elektrotlar ile ölçülmektedir. Cerrahi operasyon öncesinde, alınacak beyin bölgelerinin belirlenmesinde kafa içi EEG kayıtlarından faydalanılmaktadır. Bu tür yöntemler nispeten nadir uygulansa ve bu nitelikteki verilerin elde edilmesi daha zor olsa da beyinde hastalıklı bölgenin tespitinde kafa içi EEG kayıtlarının kullanımı ile çok daha hassas sonuçlar elde edilebilmektedir. Kafa içi elektrot yerleşimine hasta bazında karar verildiğinden belirli bir standardizasyon oluşturulmamıştır.

EEG'de ölçülen potansiyel beyinde gerçekleşen nöronsal aktivitelerin bir toplamıdır. Daha açık bir ifade ile, EEG işareti uzamsal ve zamansal alanda büyük bir nöron grubunun hücre dışı postsinaptik potansiyellerinin toplamını temsil etmektedir.



Şekil 1.2. Uluslararası 10-20 sisteminde kafa derisi elektrotlarının yerleşimi [37]

Oluşan potansiyelin kafatasının dışında dahi ölçülebilir olması için, sinir hücrelerinin aynı yüzey üzerinde birbirine paralel olarak konumlanmış olması gerekmektedir. Bu koşulu sağlayan en büyük hücre grubu, beyin korteksinde bulunan piramidal sinir hücreleridir [37]. EEG işaretlerini oluşturan sinirsel aktivitenin büyük bir kısmı bu hücrelerden kaynaklanmaktadır. Korteks altı sinir ağlarının kafa derisi EEG kayıtlarındaki etkisinin çok az olduğu varsayılmaktadır [35]. EEG kayıtları, büyük nöron gruplarının elektriksel aktivitesinin küresel dinamiklerini yansıttığından, epilepsi tanısında da oldukça faydalı olmaktadır.

EEG kayıtlarının uzamsal çözünürlüğünü kafa derisine yerleştirilen elektrotların sayısı belirlemektedir. Klinik pratikte 27 ila 32 elektrot kullanılmakla birlikte bazı araştırmalarda kafa derisine 256 adet elektrot yerleştirilebilmektedir. Literatürde yüksek yoğunluklu EEG olarak adlandırılan bu ölçümler geleneksel EEG kayıtlarına göre daha yüksek bir duyarlılığa sahiptir [38].

### 1.2.1. Normal EEG işareti

Bir EEG işaretininin EKG işareti gibi karakteristik bir şekli bulunmamaktadır. Fakat insan yaşamının farklı aşamalarında, uyku veya uyanıklık gibi farklı farkındalık seviyelerinde ve gözlerin açık ya da kapalı olması gibi farklı davranış durumlarında, EEG işaretinde bazı belirgin değişiklikler meydana gelmektedir. EEG işaretleri için bu durumlarda bile belirli bir standart belirlenemediğinden, EEG işaretlerini değerlendirecek uzman sistemlerin geliştirilmesi diğer biyomedikal işaretlere göre daha zordur. Normal bir EEG işaretinin nasıl olması gerektiğinin tanımı, toplumun

çoğunluğunda tutarlı bir şekilde var olan genel kalıplar üzerinden yapılmaktadır. Bu nedenle tek başına EEG işareti epilepsi tanısı için yeterli değildir ve diğer gözlemlerle desteklenmesi gereklidir.

EEG işaretlerinin genel yapısını gösteren temsili EEG kayıtları Şekil 1.3. ile verilmektedir. Burada normal EEG işaretlerinde görülebilecek tipik ritimler veya kalıplar yer almaktadır. Bunlardan en yaygın olanı Şekil 1.3.a ile verilen, kafanın arka bölgelerinde uyanıklık sırasında ortaya çıkan, 8-13 Hz frekansındaki alfa dalgalarıdır. Sağlıklı erişkinlerde gözlerin kapalı olduğu durumlarda daha iyi gözlenen alfa dalgaları, çoğunlukla zihinsel olgunlaşma ve sağlığın bir göstergesi olarak kabul edilmektedir. Ancak bu yaygın olarak görülen olguda bile kişiden kişiye gerilim, yayılma veya kalite açısından farklılıklar gözlemlenmektedir.

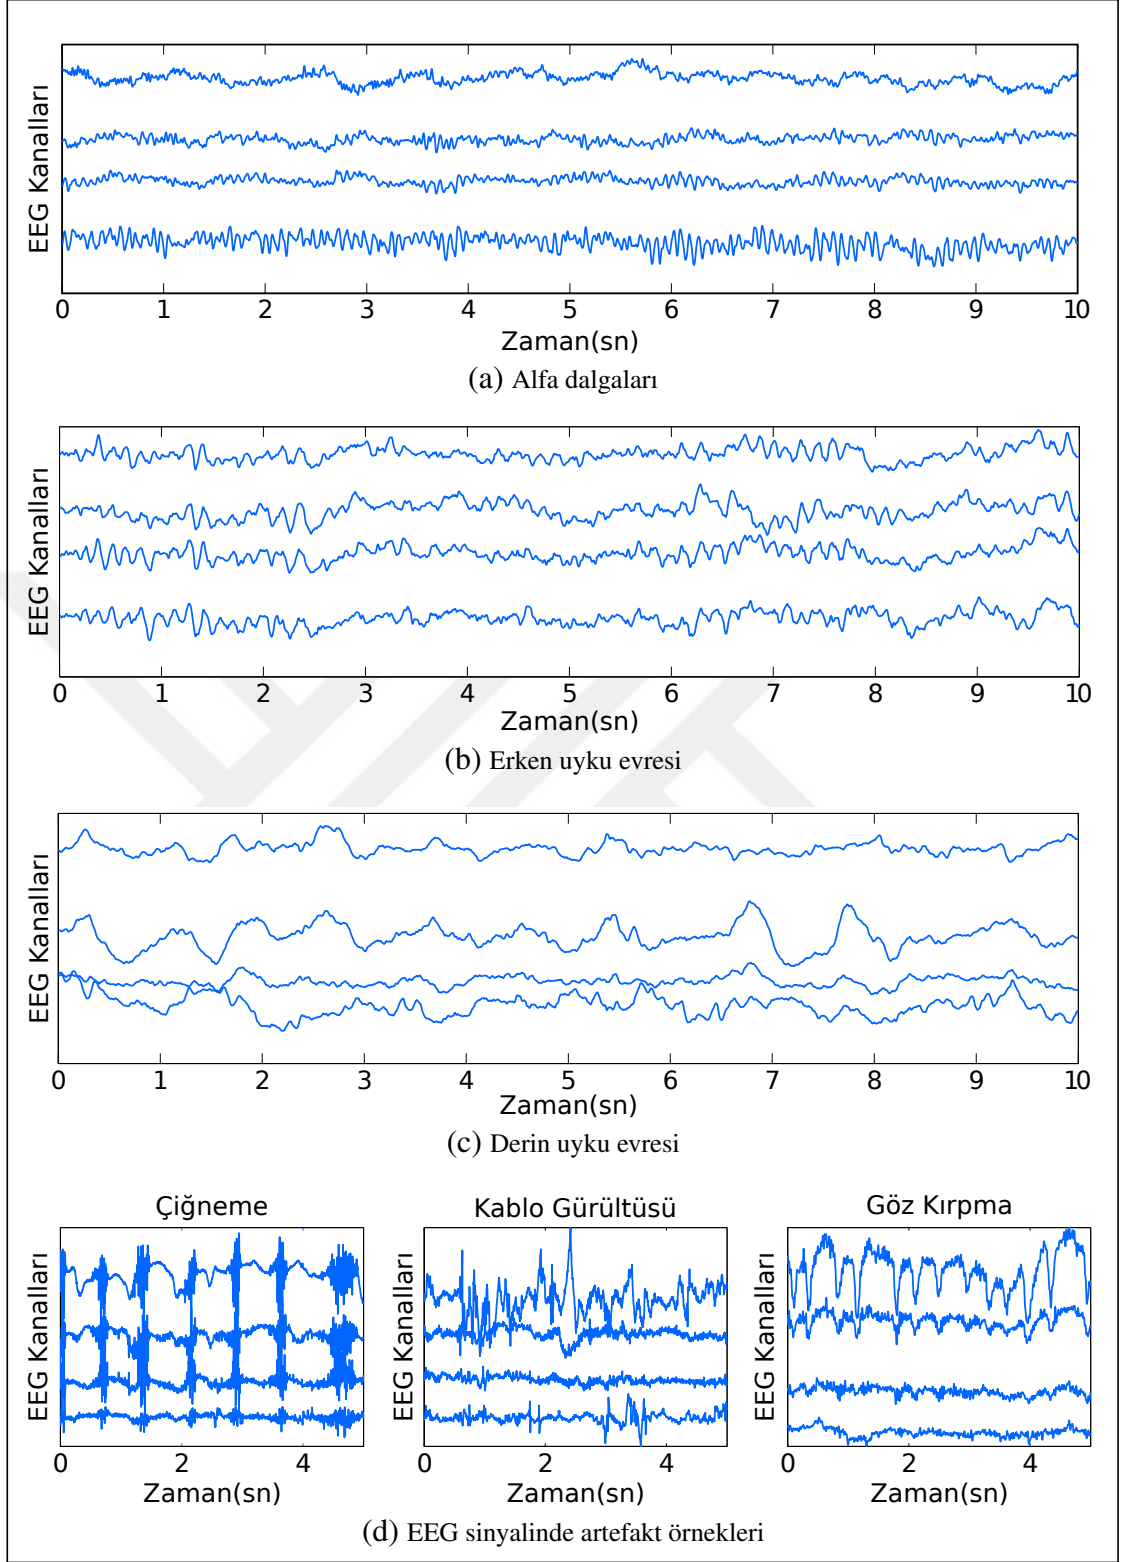
Uyku çeşitli evrelerinde, uyanıklık durumundan farklı EEG işaretleri oluşmaktadır. Erken uyku ve derin uyku evrelerinde gözlemlenen EEG işaretleri sırasıyla Şekil 1.3.b ve Şekil 1.3.c ile verilmektedir. Bu evrelerde oluşan dalga formları nispeten daha düşük frekanslı, farklı kanallardaki EEG işaretleri birbiriyle benzerdir. Fakat yine de uyku sırasında hızlı aktivite durumları ve ani yükselmeler meydana gelebilmektedir.

EEG işaretleri üzerinde bozucu etkiye yol açan artefaktlar, beyinden kaynaklanmayan fakat kayıt sırasında da giderilemeyen bazı aktiviteler sonucu meydana gelmekte, özellikle kafa derisi EEG kayıtlarında güçlü gürültülere yol açmaktadır. Bu artefaktlar, ortamdaki elektromanyetik girişim ya da hatalı elektrot bağlantısı gibi harici etkenlere bağlı olarak gelişebileceği gibi göz kırpması, çiğneme ve kafa derisindeki kas hareketleri gibi fizyolojik etkenlere bağlı olarak da meydana gelebilmektedir. Bu olguların örnekleri Şekil 1.3.d'de verilmektedir. Her ne kadar bu artefaktlar bir uzman tarafından kolayca saptanıp sınıflandırılabilirse de, gerçek sinirsel aktivite işaretlerini etkilemeden bu gürültülerin temizlenmesi zorlu bir problemdir.

### **1.2.2. Epileptik EEG işareti**

Epileptik EEG işaretleri için tek bir karakteristikten söz edilememektedir. Nöbetler arası süreler hastaya bağlı olarak birkaç saniye kadar kısa olabileceği gibi yeni bir nöbetin gerçekleşmesi yılları bulabilmektedir. Bir nöbet sırasında meydana gelen değişimler genel olarak şu şekilde tanımlanmaktadır:

- Senkronizasyon: Sinirsel aktivite geniş bir korteks bölgesinde benzer olduğundan EEG kanallarında birbirine benzer değişimler gözlenmektedir. Bu durum birkaç EEG kanalında gerçekleşebileceği gibi tüm EEG kanallarında da oluşabilmektedir.
- Genlik Artışı: EEG işareti genliğinde epileptik nöbet başlangıcından itibaren nöbet



Şekil 1.3. Normal EEG işareti örnekleri. Uyanıklık durumunda alfa dalgalarının ortalama frekansı 10 Hz civarında iken, erken uyku ve derin uyku evrelerinde ortalama frekans azalmaktadır. Çiğneme, kablo gürültüsü ve göz kırpması gibi bozucu etkiler rahatlıkla seçilebilmektedir [37]

öncesine göre bir artış olabilmektedir. Bu durum kortekste daha fazla nöronun aktif olması ya da kanallar arasındaki senkronizasyonun bir sonucu olarak ortaya çıkmaktadır.


– Salınım: Nöbet sırasında her kanal normal EEG işaretinin aksine çoğunlukla salınımlı hale gelmektedir. Bu salınımlar tipik olarak korteksin geniş bir alanında gözlemlenmektedir.

Bu değişimler sadece temsili olarak verilmektedir ve çoğu zaman sadece arka plan aktivitesindeki keskin bir değişiklik sayesinde belirlenebilmektedir. Bir nöbette bu değişimlerin bir kısmı ya da hiçbiri gözlemlenmeyebilir. Örneğin, birçok nöbet büyük genlik salınımları içermekle birlikte, genliği önceki aktiviteden daha büyük olmayan nöbetler de bulunabilmektedir. Kanallarda nöbet sırasında genel bir senkronizasyon gözlemlenmekle birlikte tüm kanalların mutlaka bu senkronizasyona dahil olması gerekmemektedir. Nöbet başlangıçları genellikle anidir ancak bazı nöbetlerde gelişim çok daha yavaş olabilmektedir. Nöbetten sonra, belirgin bir şekilde azalmış aktivitenin olduğu ve bu süre zarfında hastanın derin bir uykuya benzer bir durumda olduğu, bir "sessiz" EEG evresi gözlemlenebilmektedir. Tüm bu farklılıklar hastalar arasında olabileceği gibi, aynı hastada nöbetler arasında veya tek bir nöbet içinde dahi meydana gelebilmektedir. Tipik bir epileptik nöbet EEG işareti örneği Şekil 1.4.'de verilmektedir. Burada nöbet boyunca EEG işaretinin hem şeklinde hem de frekansında değişiklikler meydana geldiği görülmektedir. Nöbet sırasında salınımların şeklinde farklılıklar görülebilse de her bir kanaldaki işaret normalden daha salınımlıdır. Nöbet sırasında meydana gelen EEG işaretlerinin bir süre için Şekil 1.3.d'de verilen çiğneme sırasında meydana gelen EEG işareti ile benzerlik taşıması, "normal" ve "epileptik" EEG arasındaki ayrımın bazı durumlarda ne kadar zor olabileceğinin bir kanıtıdır.

Epileptik EEG işaretlerinde nöbetler arası evrede diken dalga olarak tanımlanan epileptik deşarjlar meydana gelebilmektedir. Bu deşarjlar karakteristik olarak epileptik odağın merkezinde veya çevresinde kendini gösteren, yüksek genlikli, senkronik ve çok fazlı aktiviteye sahip kısa süreli ataklardır. Bazı çalışmalarda gelişmiş bir nöbetin diken dalga ataklarının uzun süreli bir türü olduğu öne sürülmektedir [35].

### **1.3. Epileptik Nöbet Tahmini**

Epileptik EEG işaretleri üzerinde yapılan araştırmalar ve klinik gözlemler beyin dalgası örüntülerinin nöbet öncesinde, nöbet sırasında ve nöbetten sonra farklılaştığını



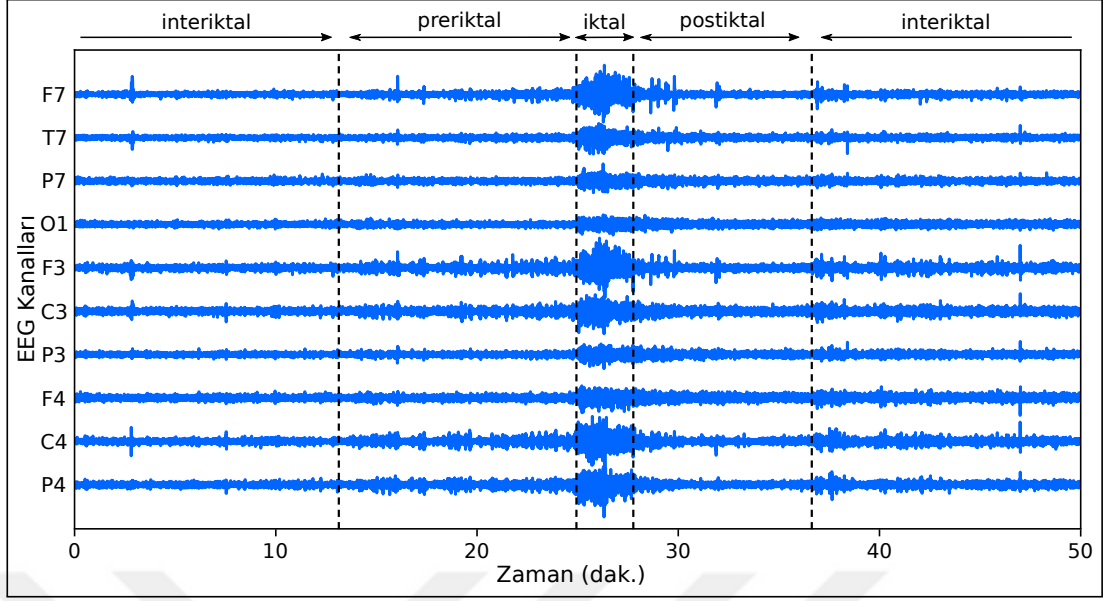
Şekil 1.4. Epileptik nöbet EEG işareti örneği [37]

ortaya koymaktadır [1]. Bu nedenle çoğu epileptik nöbet tahmini çalışmasında beyin dalgaları dört farklı evreye ayrılarak incelenmiştir [39]. Şekil 1.5. ile verilen bu evreler aşağıdaki gibi tanımlanmaktadır.

- İnteriktal evre: Ardışık iki epileptik nöbet arasında, normal beyin dalgalarının gözlemlendiği aktivite durumu
- Preiktal evre: Nöbetten hemen önce, beynin nöbete evrildiği aktivite durumu
- İktal evre: Epileptik nöbetin gerçekleştiği aktivite durumu
- Postiktal evre: Nöbetten sonra, beynin normal duruma evrildiği aktivite durumu.

Epilptik nöbet tahmininde genellikle amaç preiktal evreyi tespit etmektir. Bunun için en genel strateji, pencerelemiş EEG sinyalinden bir öznitelik kümesi çıkararak, bu kümeyi preiktal ve interiktal olmak üzere iki sınıflı bir sınıflandırma problemine dönüştürmektir. Epilptik nöbetten hemen önceki evre olarak tanımlanan preiktal evre, nöbet belirtilerinin başlangıç zamanına bağlı olarak nöbetten bir kaç saniye





Şekil 1.5. EEG işaretlerinde epileptik evreler

öncesinden birkaç saat öncesine kadar uzanabilmektedir [40]. Preiktal evre süresinin doğru olarak seçilmesi, nöbet tahmininde daha hassas sonuçlar elde etmede büyük önem taşımaktadır.

Epileptik nöbet tahmini genel olarak iki aşamadan meydana gelmektedir. İlk aşamada epileptik evreleri zaman boyunca karakterize edecek EEG-tabanlı öznelikler çıkarılmaktadır. Bu bağlamda, kayar pencere analizi kullanılarak EEG işaretlerinden doğrusal veya doğrusal olmayan ölçümlerle öznelikler elde edilmektedir. Analiz pencerelerinin süresi çalışmada kullanılan yaklaşıma bağlı olmakla birlikte, genellikle 2 ile 40 saniye arasında seçilmektedir. İkinci aşamada ölçümlerle elde edilen öznelikler, preiktal ve interiktal evrelere sınıflandırılmaktadır. Çoğu çalışmada iktal ve postiktal evreler, gerçekleşecek yeni bir nöbete dair bilgi içermediği düşünülerek nöbet tahmininde değerlendirmeye alınmamıştır [1].

Epileptik nöbet tahminine yönelik çalışmalar 1960'larda sayısal elektroensefalografi (EEG) kayıtlarının alınmasıyla başlamaktadır. Yapılan ilk çalışmalar spektral analiz ve örüntü tanıma tabanlı iken doğrusal olmayan dinamik teorisindeki gelişmelerle birlikte zaman serileri analizi nöbet tahmini için umut verici bir araç olmuştur. 1990'lardan sonra preiktal fenomenini esas alarak yapılan çalışmalarda epileptik evrelerin karakterize edilmesi amacıyla en büyük Lyapunov üsteli [41] ve dinamik benzerlik indeksi gibi ölçümler kullanılmıştır. Günümüze kadar epileptik nöbetlerin preiktal evredeki karakteristiğini çıkarmak ve interiktal evreden farklılıklarını ortaya koymak üzere çok sayıda çalışma yapılmıştır. Bu çalışmalarda gerçekleşecek nöbetlerin öncülleri olarak özgün ve güvenilir öznelikler çıkarmak üzere EEG

tabanlı ölçümler kullanılmıştır. Bu ölçümler daha çok epileptik döngünün preiktal evresi ile ilintilidir [1]. Yapılan çalışmalarda önceleri EEG işaretlerinden çıkarılan ölçümlere basitçe bir eşik değeri uygulanarak [42] ya da doğrusal olmayan analiz yöntemleriyle [43, 44] epileptik nöbet tahmininde bulunulmuştur. Daha yeni çalışmalarda ise preiktal evreyi tespit edebilmek için yüksek boyutlu öznelik uzayları tabanlı sınıflandırma metotları kullanılmıştır [9–12, 14–16, 20, 21, 30, 39, 45].

#### **1.4. Nöbet Tahmininde EEG Tabanlı Ölçümler**

Nöbet tahminine yönelik yapılan EEG tabanlı ölçümler tek-değişkenli ve çok-değişkenli ölçümler olarak iki gruba ayrılmaktadır. Tek-değişkenli ölçümde, çok-değişkenli ölçümden farklı olarak her EEG kanalı bağımsız olarak değerlendirilmektedir. Çok-değişkenli ölçümde ise iki veya daha fazla kanal arasındaki senkronizasyon, korelasyon gibi bazı ilişkiler ortaya çıkarılabilmektedir. Tek-değişkenli ve çok-değişkenli ölçümlerin her biri doğrusal ve doğrusal olmayan ölçüm olarak iki gruba ayrılabilir. Doğrusal ölçümlerle sinyalinin faz, frekans ve genlik gibi öznelikleri çıkarılabilirken, doğrusal olmayan ölçümlerle sinyalinin doğrusal olmayan dinamiği ile ilgili öznelikler elde edilebilmektedir [39]. Tek-değişkenli doğrusal ölçümlere istatistiksel moment, spektral bant gücü, spektral kenar gücü, otokorelasyon ve Hjorth parametresi örnek olarak verilmektedir. Tek-değişkenli doğrusal olmayan ölçümler ise korelasyon boyutu, en büyük Lyapunov üsteli, yerel akış, algoritmik komplekslik, taşıyıcı zaman serileri ve yinelenme kaybı olarak sıralanabilir. Çok değişkenli doğrusal ölçümlere basit senkronizasyon ölçümü, maksimum doğrusal çapraz korelasyon ve otoregresif spektral analiz örnek olarak verilebilirken, çok-değişkenli doğrusal olmayan ölçümlere doğrusal olmayan bağımlılık, koşullu olasılık tabanlı indeks ve Shannon entropisi tabanlı indeks örnek olarak verilmektedir [1]. Literatürde nöbet tahminine yönelik kullanılan EEG tabanlı ölçümlerden bazıları Tablo 1.1. ile verilmektedir.

##### **1.4.1. Doğrusal ölçüm yöntemleri**

###### **1.4.1.1. Dalgacık dönüşümü**

Dalgacık (Wavelet) dönüşümü işaret işlemede sıklıkla kullanılan matematiksel dönüşümlerden biridir. Çoklu-çözünürlüklü doğası düşünüldüğünde, durağan olmayan EEG sinyallerini işlemede kayda değer bir önemi olduğu anlaşılabilmektedir. Dalgacık dönüşümünde işaret, ana dalgacığın ölçeklendirilmiş ve dönüştürülmüş toplamlarına ayrıştırılmaktadır. Petrosian ve arkadaşları Daubiches-4 (db4) dalgacığının EEG işaretlerinin zaman ve frekans domenindeki yerleşimini iyi

Tablo 1.1. Literatürde nöbet tahmininde kullanılan bazı EEG tabanlı ölçüm yöntemleri[1, 2, 40]

Tek-Değişkenli Ölçümler	
Doğrusal Yöntemler	Doğrusal Olmayan Yöntemler
Kısa Süreli Fourier Dönüşümü	Algoritmik Komplekslik
Dalgacık Dönüşümü	Birikimli Enerji
Spektral Bant Gücü	Dinamik Benzerlik İndeksi
Spektral Kenar Gücü	En Büyük Lyapunov Üsteli
Otokorelasyon ve Otoresif Modelleme	Korelasyon Boyutu
İstatistiksel Momentler	Korelasyon Yoğunluğu
Hjorth Parametreleri	Taşıyıcı Zaman Serileri
	Yinelenme Kaybı ve Yerel Akış
Çok-Değişkenli Ölçümler	
Doğrusal Yöntemler	Doğrusal Olmayan Yöntemler
Basit Senkronizasyon Ölçümü	Faz Senkronizasyonu
Korelasyon Yapısı	Kısa Zamanlı En Büyük Lyapunov Üsteli T İndeksi
Maksimum Doğrusal Çapraz Korelasyon	Koşullu Olasılık Tabanlı İndeks
Otoresif Spektral Analiz	Doğrusal Olmayan Bağımlılık
Senkronizasyonun Otoresif Ölçümü	Shannon Entropisi Tabanlı İndeks

gösterdiği sonucuna ulaşmıştır [46]. Bandarabadi ve arkadaşları nöbet tahminine yönelik olarak geliştirdikleri özel dalgacıklar ile yaptıkları çalışmada ümit verici sonuçlar elde ettiklerini bildirmiştir [47].

#### 1.4.1.2. Spektral bant gücü

EEG sinyalleri temel olarak 5 frekans bandına ayrılmaktadır. Bunlar; delta ' $\delta$ ' (0.5-4 Hz), teta ' $\theta$ ' (4-8 Hz), alfa ' $\alpha$ ' (8-13 Hz), beta ' $\beta$ ' (13-30 Hz) ve gama ' $\gamma$ ' (30 Hz ve yukarısı)'dır. Spektral bant gücü, zaman serilerinin gücünün frekans bantlarında nasıl dağılım gösterdiğini ortaya koymaktadır. Ham EEG sinyalinin spektral gücü, pencerelenmiş EEG sinyaline spektral güç yoğunluğu (PSD) fonksiyonu uygulanarak çıkarılmaktadır. Spektral güç yoğunluğu  $S_x$ , otokorelasyon fonksiyonunun Fourier dönüşümü olarak tanımlanabilir. Yapılan çalışmalarda belirli durumlar için beyin aktiviteleriyle birlikte bazı frekans bantlarındaki gücün arttığı ya da azaldığı gözlemlenmektedir. Mormann ve arkadaşlarının yaptığı bir çalışmada EEG dalgasında interiktal evreden iktal evreye geçişte delta bandındaki gücün azaldığı bildirilmiştir [19]. Netoff ve arkadaşları yaptıkları çalışmada 9 frekans bandı (delta, teta, alfa, beta, gama'nın 4 alt bandı ve sinyalin tümü) için oluşturulan spektral bant gücü özniteliklerinin kullanıldığı hasta-tabanlı bir nöbet tahmin yöntemi sunmuştur [48]. Çalışmalarında iEEG'de özellikle yüksek frekanslı alt bantlarda olmak üzere belirli alt bantların epileptik nöbet tahmininde kilit bir rol oynadığı savunulmaktadır.

Park ve arkadaşları, yaptıkları hasta-tabanlı nöbet tahmin çalışmasında iEEG işaretlerinden 4 farklı yaklaşımla (ham, bipolar, zaman-farksal ve bipolar/zaman-farksal) spektral güç özneliği oluşturmuştur [20]. 433,2 saatlik interiktal EEG verisinde, gerçekleşen 80 nöbet üzerinde yapılan testlerde en iyi sonuç, %97,5 duyarlılık ve saat başına 0,27 yanlış pozitif oranı ile bipolar yaklaşımla elde edilmiştir. Bandarabadi ve arkadaşları çalışmalarında farklı kanallarda farklı alt frekans bantlarının spektral güçlerini karşılaştırarak, aradaki ilişkiden öznelilik çıkarımında bulunmuş, yüksek boyutlu çok değişkenli öznelilik uzayında en iyi özneliliklerin seçiminde genlik dağılım histogramlarını temel alan bir denetimli öznelilik seçim metodu önermiştir. Sınıflandırmada destek vektör makinasının kullanıldığı bu çalışmada, hasta-tabanlı bir denetimli öğrenme gerçekleştirilmiştir [9].

#### **1.4.1.3. Spektral kenar gücü**

EEG sinyalinde spektral güç tüm frekanslara dağılmış olmakla birlikte bu gücün önemli bir bölümü 40 Hz'den daha düşük frekanslarda bulunmaktadır. Spektral kenar gücü, gücün frekans dağılımı hakkında bilgi veren bir ölçüm olarak, ilgili frekanstan düşük frekanslardaki gücün toplam güce oranını göstermektedir [39].

#### **1.4.1.4. Otokorelasyon ve otoregresif modelleme**

EEG sinyalinin farklı zamanlardaki büyüklükleri arasında otokorelasyon yöntemlerinin kullanımı ile preiktal evre karakterize edilebilmektedir [49, 50]. Otokorelasyon, ilgilenen zaman serilerinin durağanlığını tespit etmede kullanışlı bir metottur. Dekorelasyon zamanı ise otokorelasyon fonksiyonunun ilk sıfır-geçişini olarak tanımlanmaktadır. Mormann ve arkadaşları yaptıkları çalışmada epileptik EEG işaretlerinin dekodeleme zamanında preiktal evreyi interiktal evreden ayıracak bir azalma tespit etmiştir [19].

Otoregresif modellemede ise incelenen zaman serilerinin şimdiki değerleri, belirli bir gürültüyle birlikte önceki değerlerinin ağırlıklı toplamı olarak ifade edilmektedir. Bu modelde sinyalin durağan olduğu kabul edildiğinden, EEG sinyalleri kısa süreli yarı-durağan parçalara ayrılarak değerlendirilmektedir. Otoregresif modelleme ile gerçekleşecek nöbetin öncülü olan preiktal değişikliklerin tespit edilebildiği belirtilmiştir [41].

#### **1.4.1.5. İstatistiksel momentler**

İstatistiksel momentler zaman serilerinde genliğin dağılımı hakkında bilgi vermektedir. İlk istatistiksel moment dağılımın ortalaması, ikinci istatistiksel moment

varyans, üçüncü istatistiksel moment dağılımdaki çarpıklık (skewness), dördüncü istatistiksel moment ise dağılımdaki basıklığı (kurtosis) göstermektedir. Ortalama ve varyans sinyalde dağılımın yeri ve yayılımı hakkında bilgi verirken çarpıklık ve basıklık sinyalin şekli hakkında bilgi vermektedir. İstatistiksel momentlerin yüksek genlikli nöbet sinyallerinde erken nöbet tespitinde yararlı olabileceği belirtilmiştir [2].

#### 1.4.1.6. Hjorth parametreleri

Aktiflik, mobilite ve komplekslik olmak üzere zaman domenindeki 3 parametre ile ifade edilen Hjorth parametreleri, EEG işaretlerini nicel olarak tanımlamaktadır [51]. Mormann ve arkadaşları yaptıkları çalışmada, preiktal evrede EEG sinyalinin mobilitesi (güç spektrumunun standart sapmasının oranı) ve karmaşıklığında (işaretin sinüs işareti ile benzerliği) önemli oranda artış olduğunu bildirmiştir [19]. Bir  $y(t)$  zaman serisi için, aktivite Denklem (1.1), mobilite Denklem (1.2), karmaşıklık Denklem (1.3) ile verilmektedir.

$$\text{aktivite} = \text{var}(y(t)) \quad (1.1)$$

$$\text{mobilite} = \sqrt{\frac{\text{var}\left(\frac{dy(t)}{dt}\right)}{\text{var}(y(t))}} \quad (1.2)$$

$$\text{komplekslik} = \sqrt{\frac{\text{mobilite}\left(\frac{dy(t)}{dt}\right)}{\text{mobilite}(y(t))}} \quad (1.3)$$

#### 1.4.1.7. Basit senkronizasyon ölçümü

Epileptik nöbet süresince EEG dalgalarında senkronize bir aktivite gözlenmekte, bu aktivitenin nöbetin gerçekleşmesinden saatler önce başladığı düşünülmektedir. Senkronizasyonun otoregresif ölçümü çok kanallı EEG işaretlerinden elde edilmektedir. Bu ölçümde her yeni veri ilgili kanalda önceki verilerin doğrusal bir kombinasyonu olarak elde edilmektedir. Quiroga ve arkadaşları yaptıkları çalışmada iki EEG kanalı arasındaki senkronizasyonu ölçmek için çok değişkenli bir yöntem önermiştir [52]. Bu yöntemde ilk olarak bir sinyal çifti için belirli olgular tanımlanmakta, ardından belirlenen bir  $t$  zamanı için bu olgunun gerçekleşme sayısı bulunmaktadır.

#### 1.4.1.8. Korelasyon yapısı

Epileptik EEG işaretlerinin analizinde diğer bir metot tüm EEG kanalları arasında korelasyon işlemi gerçekleştirmektir. Korelasyon matrisini tanımlamak için EEG

sinyalinin bir bölümü belirli uzunlukta pencerelere ayrılarak incelenmektedir. Ardından EEG sinyali bu zaman pencereleri içerisinde kanallara göre normalize edilmektedir. m kanallı bir EEG sinyali için korelasyon matrisi C, Denklem (1.4) ile tanımlanmaktadır. Burada  $w_1$  pencere uzunluğu, i ve j EEG kanallarını temsil etmektedir.

$$C_{ij} = \frac{1}{w_1} \sum_{t \in w} EEG_i(t) \cdot EEG_j(t) \quad (1.4)$$

Williamson ve arkadaşları yaptıkları çalışmada çok-değişkenli EEG öznitelikleri ile hasta-tabanlı bir nöbet tahmin yöntemi önermiştir [53]. Bu yöntemde EEG verilerinden çeşitli gecikme oranı uygulanmış 15 saniyelik pencerelerin korelasyon ve kovaryans matrisleri oluşturularak, bu matrislerin özdeğer spektrumları hesaplanmaktadır. Bu özniteliklerin temel bileşenleri epileptik çevrimin preiktal ve interiktal evrelerini sınıflandırmada kullanılmıştır. Destek vektör makinesi kullanılarak elde edilen sınıflandırma sonuçlarının 15 dakikalık ortalaması alınarak nihai tahmin gerçekleştirilmiştir.

## 1.4.2. Doğrusal olmayan ölçüm yöntemleri

### 1.4.2.1. Algoritmik komplekslik

Guo ve arkadaşlarının epileptik nöbet tahminine yönelik yaptıkları çalışmada öznitelik olarak sinyalin çizgi uzunluğunu kullanılmıştır [54]. Çizgi uzunluğu dalga formunun boyutsal değişikliklerini yansıtan, işaretin genlik ve frekansındaki değişiklikleri duyarlı bir ölçümdür. İşaretin kompleksliği ya da dalga formunun fraktal boyutu hakkında bilgi veren çizgi uzunluğu ölçümü, Esteller ve arkadaşları tarafından sunulan Katz'ın fraktal boyutu ile benzer özellikler taşımaktadır [55]. Diğer bir çalışmada algoritmik komplekslik, EEG'nin genlik-frekans karakteristiği ile ilgili birleştirilmiş bir öznitelik olarak epileptik işaretlerde nöbetsizliği ölçmede kullanılmıştır [56]. Bir sinyalin çizgi uzunluğu L, sinyalin ardışık örnekleri arasındaki dikey uzunlukların toplamı olarak, Denklem (1.5)'deki gibi verilmektedir. Burada zaman serisi x'in uzunluğu N ile verilmektedir.

$$L = \frac{1}{N-1} \sum_{i=1}^{N-1} \text{abs}(x_{i+1} - x_i) \quad (1.5)$$

#### 1.4.2.2. Birikimli enerji

Uzun-vadeli enerji olarak da adlandırılan birikimli enerji ölçümü sinyalin enerjisindeki uzun vadeli artışı ortaya çıkarmaktadır [22]. Epileptik nöbet gelişiminin saatler süren bir EEG olayları zinciri olduğu kabulünden hareketle, epileptik EEG evreleri arasında uzun vadeli enerjilerde farklılıklar olduğu öngörülmüştür. Bu ölçümde ilk çıkarılan öznelik, Denklem (1.6) ile verilen EEG sinyal dizisinin ani enerjisi  $E_i$ 'dir.  $E_i$ 'den M-uzunluklu kayar ortalama ile Denklem (1.7)'de verilen  $E_k$ ,  $E_k$  enerjilerinin N-uzunluklu ortalamalarının kümülatif toplamı ile Denklem (1.8)'de verilen birikimli enerji  $AE_m$  elde edilir.

$$E_i(n) = x(n)^2 \quad (1.6)$$

$$E_k = \frac{1}{M} \sum x(n)^2 \quad (1.7)$$

$$AE_m = \frac{1}{N} \sum E_k + AE_{m-1} \quad (1.8)$$

Bu ölçüm özel koşullar altında, epileptik nöbet öncüllerini tanımlamada bazı vaatler sunuyor olsa da, farklı veri setleri arasındaki sonuçların tutarlı olmadığı görülmüştür [2].

#### 1.4.2.3. Dinamik benzerlik indeksi

Dinamik benzerlik indeksinin, gerçekleşecek epileptik nöbetin öncülleri olan beyin dinamiğindeki mekan-zamansal değişiklikleri izleyebildiği varsayılmaktadır. EEG zaman serilerinin iki pozitif sıfır-geçiş aradaki zaman aralığı ile oluşturulan faz uzayı ve referans ile test pencereleri arasındaki çapraz korelasyon integrali kullanılarak dinamik benzerlik indeksi hesaplanmaktadır [2]. Feldwisch-Drentrup ve arkadaşları yaptıkları çalışmada uzun vadeli iEEG verilerinde ortalama faz eşvreliliği ve dinamik benzerlik indeksini incelemiş, birden fazla ölçümü birleştirerek oluşturdukları metodun epileptik nöbet tahmin başarımını arttırdığı sonucuna ulaşmıştır [57].

#### 1.4.2.4. Lyapunov üsteli

EEG işaretleri doğrusal olmayan sistemlerin birçok özelliğini içermektedir. Bir çok araştırmacı epileptik beyin EEG'sinin deterministik ve düzgün kaotik özellikler barındıran doğrusal olmayan bir sinyal olduğunu belirtmiştir [19, 58, 59]. Lopes da Silva çalışmasında epileptik nöbetin gelişimine dair iki senaryo önermiştir [60]. İlk senaryoya göre epileptik nöbet aniden, öncesinde EEG'de tespit edilebilecek dinamik değişikliklere neden olmayan bir sinyal geçiştir. İkinci senaryoda ise bu sinyal geçişi

sinyalin dinamiğinde tespit ve tahmin edilebilecek kademeli veya kaskad değişikliklere yol açmaktadır. Son yıllarda yapılan çalışmalarda temporal bölge epileptik nöbetlerinde, EEG sinyalinin dinamik özelliklerinde değişiklikler olduğuna dair deneysel kanıtlara ulaşılmıştır.

Lyapunov üsteli dinamik bir sistemde iki komşu yörüngeyi ortalama yakınsama/ıraksama oranını ölçen, başlangıç koşullarına duyarlı, doğrusal olmayan bir metottur [61]. Kararlı-durum davranışa sahip herhangi bir sistemin kararlılığını saptayan bu dinamik ölçü, epilepsi hastalarından alınan EEG ve EKG verilerinde preiktal evredeki değişiklikleri tanımlamak için kullanılmıştır [41, 59]. Lyapunov üstelleri verilen dinamik sistemin zaman gelişimini tanımlayan hareket denkleminde yola çıkarak bulunmaktadır [62]. Dinamik sistemin yörüngesini tanımlayan hareket denkleminin yokluğunda, Lyapunov üstelleri skaler zaman serileri  $x(t_n) = x(n\delta t)$  gözlenerek tespit edilmektedir. Bu durumda amaç, skaler EEG verisinin türediği durum uzayını tanımlayan, skaler veri  $x(t)$ 'de yer alan en büyük boyutlu vektörü üretmektir. Faz uzayında 0 ve t anındaki iki komşu nokta düşünüldüğünde, i. yöndeki noktalara olan uzaklıklar sırasıyla  $\|\delta x_i(0)\|$  ve  $\|\delta x_i(t)\|$  olmaktadır. Lyapunov üsteli ilk uzaklığın ortalama büyüme oranı  $\lambda_i$  olarak, Denklem (1.9)'deki gibi tanımlanmaktadır [63]. Lyapunov üstelindeki azalma daha düzenli bir duruma geçişi göstermektedir.

$$\lambda_i = \lim_{t \rightarrow \infty} \frac{1}{t} \log_2 \frac{\|\delta x_i(t)\|}{\|\delta x_i(0)\|} \quad (1.9)$$

#### 1.4.2.5. Korelasyon boyutu

korelasyon boyutu en önemli doğrusal olmayan EEG tabanlı ölçüm yöntemlerinden biridir. Kaos teorisinde, bir çeşit fraktal boyut olarak da bilinen korelasyon boyutu, rastgele noktalarla dolu bir uzayın boyutluluğunun bir ölçüsüdür. Rastgele sinyallerle deterministik zaman serileri arasındaki farkı ortaya çıkaran korelasyon boyutu, EEG zaman serilerinin durum uzay gösteriminden hesaplanmaktadır [64].

Pjin ve arkadaşları nöbet tahmini için korelasyon boyutunu kullanmış, nöbet aktivitelerinin çoğu defa bir düşük-boyutlu osilasyon olarak meydana geldiğini bulmuştur [65]. Genel olarak bir nöbet süresince düşük ve yüksek komplekslikteki fazların her iki türü de gerçekleşebilmektedir. Yine de düşük boyutlu fazlar daha çok iktal evre başlangıcı ve benzeri yapılarda bulunmuştur. Yapay sinir ağları ve doğrusal olmayan kestirim metotlarında, korelasyon boyutunun yüksek başarımlı algoritmalar geliştirmede en önemli ölçüm metotlarından biri olduğu bildirilmiştir [1].



#### **1.4.2.6. Yinelenme kaybı ve yerel akış**

Bir işaretin durağanlığının derecesi, zaman uzunluklarının durağan koşullar altında frekans dağılımı hesaplanarak belirlenebilir. Durağan olmayan bir sistemde, bu dağılımdaki sapmanın artışı referans civarında uzak zaman indislerinin olmamasından kaynaklanmaktadır. Yineleme kaybı bir zaman serisinin durağanlığının derecesini ölçmektedir. Osorio ve arkadaşları gerçekleşecek nöbetin tahmin edilebilirliğini saptamak üzere yinelenme kaybını kullanmıştır [58].

#### **1.4.2.7. Entropi**

Bir sinyalin düzensizliğini ifade eden bir kavram olarak entropi, epileptik nöbet tahmininde kullanılan doğrusal olmayan ölçüm yöntemlerinden biridir. Yapılan çalışmalarda yaklaşık entropi, örnek entropi, faz entropisi 1 (S1) ve faz entropisi 2 (S2) olmak üzere EEG kayıtlarından 4 entropi özneliği çıkarılmış, bu öznelikler örüntü tanıma ya da sınıflandırma modellerinde kullanılarak, incelenen sinyalin preiktal ya da iktal evre olma olasılığı ölçülmüştür.

Blanco ve arkadaşları EEG sinyallerinin farklı frekans bantlarındaki spektral entropi sonuçlarını karşılaştırarak hangi frekans bandının epileptik nöbet tahmininde kullanımının uygun olacağını araştırmıştır [66]. Epileptik nöbetten 4 ila 32 dakika öncesinde alınan EEG sinyallerinin düşük, orta ve yüksek frekans fourier spektrum entropilerinin ölçüldüğü bu çalışmada, yüksek frekans bandındaki entropi ölçümlerinin nöbet öncesinde farklılıklar gösterdiği ve nöbet tahmini için kullanılabilmesi sonucuna ulaşılmıştır. Drongelen ve arkadaşları yaptıkları çalışmada çocuk hastalarda epileptik nöbet tahmininde Kolmogorov entropisini kullanmış, yaklaşan nöbetleri 2 ile 40 dakika öncesinden öngörebilmişlerdir [67]. Kolmogorov entropisi sistemin gelecek durumlarının zamanla belirsizliğini ölçmektedir. Li ve arkadaşları çalışmalarında epileptik nöbet tahmininde permütasyon entropisi kullanmıştır [68]. Bu çalışmada permütasyon entropisinin, gerçekleşecek nöbetin öncülü olan dinamik geçişleri kestirmede kullanılabilmesi gösterilmiştir.

#### **1.4.2.8. Faz senkronizasyonu**


Faz senkronizasyonu, bir zaman periyodu içerisinde herhangi iki ya da daha fazla sinyalin faz kilitliliğinin derecesi olarak tanımlanmaktadır. Genellikle aynı frekans ve aynı fazdaki periyodik iki sinyale uygulanmakla birlikte, periyodik sinyallerin frekanslarının sayısal ilişkisini (ardışık periyotlar arasında aynı faz açısı v.b.) ortaya çıkarmada da kullanılır [1]. Epilepsi hastalarında interiktal evredeki faz senkronizasyonu üzerine yürütülen çalışmalarda, nöbetlerin %70'inde nöbetten

saatler önce beyin senkronizasyonunun özel durumları gözlemlenmiştir. Bu senkronizasyonlar özellikle 4-15 Hz frekans bantlarında artma ve azalma olarak kendini göstermekle birlikte, bazı arařtırmacılar bu yöntemin epileptik nöbet tahmininde gerçekçi bir yöntem olmadığı ama ileriki çalışmalar için kullanışlı veriler sağlayacağı sonucuna ulaşmıştır [43, 69, 70].



## 2. YAPAY SİNİR AĞLARI

Yapay sinir ağıları biyolojik organizmalardaki öğrenme mekanizmasını taklit eden makine öğrenmesi teknikleridir. Biyolojik organizmalarda sinir sistemleri nöron olarak adlandırılan hücrelerden meydana gelmektedir. Nöronlar, akson ve dendritler üzerinden birbirlerine bağlanmakta, bu bağlantı bölgeleri ise sinaps olarak adlandırılmaktadır. Bu bağlantılar Şekil 2.1.a'da gösterilmektedir. Biyolojik bir sinir hücresinin dendritleri diğer nöronların yeterli sayıda aksonu tarafından uyarıldığında, hücre gövdesinden akson ucuna doğru iletilen bir elektrik sinyali üretilmekte ve diğer sinir hücrelerinin dendritleri sinapslar aracılığıyla uyarılmaktadır. Bu biyolojik mekanizma yapay sinir ağlarında nöron olarak adlandırılan hesaplama birimleri ile gerçekleştirilmektedir. Yapay sinir ağı hücreleri biyolojik organizmalardaki sinaptik bağlantıların gücüne karşılık gelecek şekilde, belirli ağırlıklarla ölçeklendirilerek birbirine bağlanmaktadır. Bir sinir ağı hücresine her bir girdi bir ağırlıkla ölçeklendirilerek aktivasyon fonksiyonuna verilmekte ve ikili bir çıkış elde edilmektedir. Bu mimari Şekil 2.1.b'de gösterilmektedir. Bir yapay sinir ağı, giriş değerlerini giriş hücrelerinden çıkış hücrelerine doğru ağırlıkları ile ölçeklendirerek ve aktivasyon fonksiyonlarından geçirerek yaymakta, girdilerin bir fonksiyonu olarak çıkış değerleri üretmektedir. Öğrenme, nöronları bağlayan ağırlıkların güncellenmesi ile gerçekleştirilmektedir. Biyolojik organizmalarda öğrenme için dış uyaranlara ihtiyaç duyulduğu gibi, yapay sinir ağlarındaki dış uyaran, öğrenilecek işlevin girdi-çıkış çiftlerinin örneklerini içeren eğitim verileri ile sağlanmaktadır. Bu eğitim veri çiftlerinden, çıkış etiketleri hakkında tahmin değeri oluşturması amacıyla girdi gösterimleri sinir ağına giriş olarak verilmektedir. Eğitim verileri, belirli bir giriş için öngörülen çıkışın, eğitim verilerindeki çıkış etiketi ile ne kadar iyi eşleştiğine bağlı olarak sinir ağındaki ağırlıkların doğruluğu hakkında geri bildirim sağlamaktadır. Eğitim sırasında sinir hücreleri arasındaki ağırlıklar tahmin hataları kullanılarak güncellenmektedir. Sinir hücreleri arasındaki ağırlıkların birçok giriş-çıkış çifti kullanılarak adım adım güncellenmesiyle, sinir ağı tarafından hesaplanan fonksiyonun zaman içinde daha doğru sonuç vermesi sağlanmaktadır. Bir sinir ağı yeterli sayıda eğitim örneği ile eğitildiğinde eğitimde kullanılmayan bir örnek için de doğru tahmin değeri üretebilmektedir. Model genellemesi olarak adlandırılan bu özellik makine öğrenmesi modellerinin en önemli yeteneğidir.



Şekil 2.1. Biyolojik sinir hücresi ve yapay sinir modeli

## 2.1. Tek Katmanlı Algılayıcı

En basit sinir ağı olan tek katmanlı algılayıcı (perceptron) tek bir giriş katmanı ve bir çıkış düğümünden meydana gelmektedir. Algılayıcının temel mimarisi Şekil 2.1.b'de verilmektedir. Her eğitim örneğinin  $(\bar{X}, y)$  ile verildiği düşünülüğünde,  $\bar{X} = [x_1, \dots, x_d]$  dizisi  $d$  özneliğin değerini,  $y \in \{-1, +1\}$  ikili sınıf değişkenlerinin gözlenen değerini içermektedir. Giriş katmanı  $\bar{X}$  öznelik dizisindeki değerleri  $\bar{W} = [w_1, \dots, w_d]$  ağırlık değerleri ile ölçeklendirerek bir çıkış düğümüne iletmektedir. Çıkış düğümünde  $\bar{W} \cdot \bar{X} = \sum_{i=1}^d w_i x_i$  doğrusal fonksiyonu hesaplanarak  $\hat{y}$  tahmin değeri Denklem (2.1)'deki gibi elde edilir.

$$\hat{y} = \text{sign}\{\bar{W} \cdot \bar{X}\} = \text{sign}\left\{\sum_{i=1}^d w_i x_i\right\} \quad (2.1)$$

Burada işaret fonksiyonu elde edilen değeri ikili sınıflandırma için uygun olan 1 veya -1 değerlerine dönüştüren aktivasyon fonksiyonudur. Buna bağlı olarak tahmin hatası  $E(\bar{X}) = (y - \hat{y})$ ,  $\{-2, 0, 2\}$  değer kümesindeki elemanlardan biri olarak elde edilmektedir.  $E(\bar{X})$  hata değerinin sıfırdan farklı olduğu durumlarda, sinir ağındaki ağırlıklar hata gradyanı ile ters işaretli olarak güncellenmektedir.

Sinir ağının eğitiminde amaç, tahmin hatasını minimuma indirmektir. Amaç fonksiyonun en küçük kareler formu, öznelik-etiket çiftlerinden oluşan  $D$  veri setindeki tüm eğitim örnekleri için Denklem (2.2)'de verilmektedir. Bu amaç fonksiyonu kayıp fonksiyonu olarak da adlandırılmaktadır.

$$\text{Min}_{\bar{W}} L = \sum_{(\bar{X}, y) \in D} (y - \hat{y})^2 = \sum_{(\bar{X}, y) \in D} (y - \text{sign}\{\bar{W} \cdot \bar{X}\})^2 \quad (2.2)$$

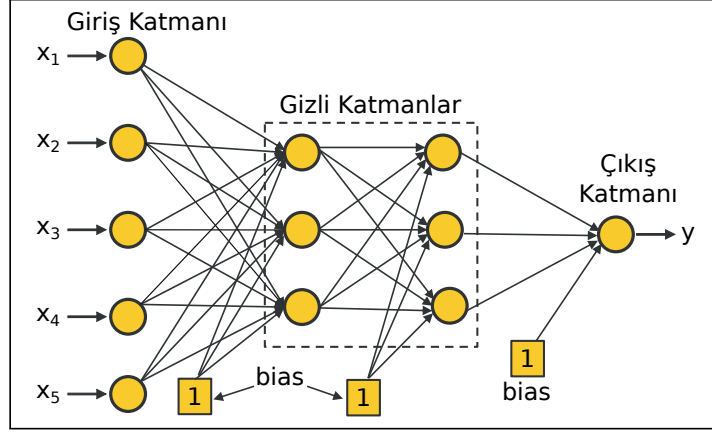
Her ne kadar yukarıdaki amaç fonksiyonu tüm eğitim verileri üzerinde tanımlanmış olsa da, sinir ağlarının eğitiminde  $\hat{y}$  tahmini oluşturulurken her bir veri girişi örneği  $\bar{X}$  ağa birer birer (veya küçük gruplar halinde) verilmekte, ardından  $E(\bar{X}) = (y - \hat{y})$  hata değerinde göre ağırlıklar güncellenmektedir. Bir  $\bar{X}$  girişi için ağırlık vektörü  $\bar{W}$  Denklem (2.3)'deki gibi değişmektedir.  $\alpha$  parametresi sinir ağının öğrenme hızını belirlemektedir. Algılayıcı modelinde tüm eğitim örnekleri rasgele ve birçok kez kullanılarak, yakınsamaya ulaşılan kadar ağırlıklar yinelemeli olarak birçok çevrim ile güncellenmektedir. Rastgele seçilen eğitim noktalarına göre gradyan-azalma güncellemeleri yaparak tahmin değerinin karesel hatasını dolaylı olarak minimize eden algılayıcı modeli, bu haliyle bir stokastik gradyan-azalma yöntemi olarak değerlendirilebilmektedir.

$$\bar{W} \leftarrow \bar{W} + \alpha(y - \hat{y})\bar{X} \quad (2.3)$$

Tek katmanlı algılayıcıda, modelde verilen  $\bar{W} \cdot \bar{X} = 0$  eşitliği doğrusal bir hiper düzlemi tanımlar. Çıkışta doğrusal olmayan aktivasyon fonksiyonunun kullanımı ile model doğrusal olmayan özellik kazanır. Tek katmanlı algılayıcı modeli, verilerin doğrusal olarak ayrılabilir olduğu veri setlerini sınıflandırmada başarılı olsa da doğrusal olarak ayrılamayan veri setlerinin sınıflandırması için daha karmaşık yapılarının kullanımı gerekmektedir.

## 2.2. Çok Katmanlı Sinir Ağları

Çok katmanlı sinir ağları, giriş ve çıkış katmanına ek olarak en az bir veya daha fazla hesaplama katmanı içeren ileri beslemeli ağlardır. Bu hesaplama katmanları, eğitim sırasında yapılan işlemler kullanıcıya açık olmadığından gizli katman olarak da adlandırılmaktadır. Çok katmanlı sinir ağlarının ileri beslemeli olması verinin ardışık katmanlarda yalnızca giriş yönünden çıkış yönüne iletilmesinden kaynaklanmaktadır. Tek katmanlı ağlarda olduğu gibi hem gizli katmanlarda hem de çıkış katmanlarında bias nöronları kullanılabilir. Çok katmanlı sinir ağı mimarisinin basit bir örneği Şekil 2.2.'de verilmektedir. Katmanlardaki düğüm sayısı, söz konusu katmanın boyutluluğunu tanımlamaktadır. Giriş katmanı ile ilk gizli katman arasındaki bağlantıların ağırlıkları  $d \times p_1$  boyutlu bir  $W_1$  matrisi, n'inci gizli katman ile (n+1)'inci gizli katman arasındaki bağlantıların ağırlıkları  $p_n \times p_{n+1}$  boyutlu bir  $W_n$  matrisi, o düğümlü çıkış katmanı için çıkış ağırlıklarının  $p_k \times o$  boyutlu bir  $W_{k+1}$  matrisi ile temsil edildiği düşünüldüğünde,  $d$  boyutlu  $\bar{x}$  giriş vektöründen Denklem (2.4)'de verilen yinelemeli adımlarla çıkış değeri elde edilmektedir. Burada



Şekil 2.2. İki gizli katmanlı ileri beslemeli bir sinir ağının temel mimarisi

$\Phi$  aktivasyon fonksiyonu,  $h_n$ , n'inci katman için düğüm değerleri vektörüdür.

$$\begin{aligned}
 \bar{h}_1 &= \Phi(W_1^T \bar{x}) \\
 \bar{h}_{p+1} &= \Phi(W_{p+1}^T \bar{h}_p) \quad \forall p \in \{1 \dots k-1\} \\
 \bar{o} &= \Phi(W_{k+1}^T \bar{h}_k)
 \end{aligned} \tag{2.4}$$

Tam bağlı bir mimari ile birçok uygulamada iyi bir başarımla elde edilse de, bağlantıların budanarak ağına rafine hale getirilmesi veya bağlantılarda uygulamaya bağlı olarak ortak ağırlıkların kullanılması başarımları arttırmaktadır. Bu ağırlık budama ve paylaşımına örnek olarak, mimarisi değerlendirilen verinin niteliğine uygun olarak oluşturulan evrişimli sinir ağları gösterilebilir. Tasarımda verinin nitelik ve eğilimlerinin göz önünde bulundurulduğu bu yaklaşım eğitimde aşırı uyum riskini de en aza indirmektedir. Sinir ağı tasarımlarında genel bir problem olan aşırı uyum, eğitim verilerinde çok yüksek başarımla gösteren ağına, eğitimde kullanılmayan test verilerinin sınıflandırılmasında yetersiz kalmasına yol açmaktadır. Bu sorun genellikle ağıdaki serbest parametre sayısı eğitim verisi boyutundan görece çok fazla olduğunda ortaya çıkmaktadır. Bunun nedeni ağıdaki çok sayıda parametrenin, eğitim verilerinin bazı özelliklerine aşırı uyum sağlaması, fakat test verilerini sınıflandırmada kullanılacak istatistiksel olarak önemli örüntüleri tanımamasıdır. Dolayısıyla sinir ağındaki düğümlerin sayısının artması aşırı uyumun gerçekleşme olasılığını arttırmaktadır. Aşırı uyumun önüne geçmek amacıyla ağına optimum tasarımının yanı sıra düğümlerde gerçekleştirilen hesaplamaların iyileştirilmesine yönelik yaklaşımlar da tercih edilebilmektedir.

### 2.3. Aktivasyon Fonksiyonu

Aktivasyon fonksiyonları, sinir ağlarında bir sinir düğümü için girdi ve biasların ağırlıklı toplamından çıkıştaki aktivite durumunu belirleyen, sinir ağı tasarımının kritik bileşenlerinden biridir. En temel aktivasyon fonksiyonu olarak birim fonksiyonu  $\Phi(x) = x$  örnek gösterilebilir. Fakat bu fonksiyon doğrusal olduğundan, çıkış düğümlerinde hedef değerinin reel sayı olduğu durumlar dışında kullanılmamaktadır. Çok katmanlı sinir ağlarının karmaşık örnek uzaylarında dahi yüksek bir sınıflandırma başarımına ulaşmalarındaki en önemli etken doğrusal olmayan aktivasyon fonksiyonlarının kullanımınıdır. Yalnızca doğrusal aktivasyon fonksiyonlarının kullanıldığı bir sinir ağı, tek katmanlı bir doğrusal sinir ağından daha iyi modelleme gücü sağlayamamaktadır. Yapay sinir ağlarının farklı katmanlarında işaret, sigmoid, hiperbolik tanjant, düzeltilmiş doğrusal birim, Softmax gibi farklı doğrusal olmayan aktivasyon fonksiyonları kullanılabilir.

Tek katmanlı algılayıcı ağlarında ikili sınıf etiketinin tahmin edilmesinin gerektiği durumlarda tercih edilen, Denklem (2.5) ile verilen işaret aktivasyon fonksiyonu, türevlenebilir olmadığından eğitimde kayıp fonksiyonu içinde kullanılamamaktadır.

$$\Phi(x) = \text{sign}(x) \quad (2.5)$$

Denklem (2.6) ile verilen sigmoid aktivasyon fonksiyonu  $(0, 1)$  aralığında bir değer üretmektedir. Bu nedenle olasılıksal olarak değerlendirilmesi gereken problemler için tahmin çıktılarını oluşturmada kullanılmaktadır. Sigmoid fonksiyonunun en büyük dezavantajı, gradyanlarının çok büyük veya çok küçük değerler için sıfıra yaklaşmasıdır. Bu durum ise eğitimin yavaşlamasına neden olmaktadır.

$$\Phi(x) = \text{sigmoid}(x) = \frac{1}{1 + e^{-x}} \quad (2.6)$$

Denklem (2.7) ile verilen hiperbolik tanjant fonksiyonu dikey ekseninde  $(-1, 1)$  değerleri aralığına ölçeklendirilmiş olması dışında sigmoid fonksiyonuna benzer bir şekle sahiptir. Sinir düğümü çıktısının hem pozitif hem de negatif olması istendiğinde sigmoid yerine hiperbolik tanjant fonksiyonu tercih edilmektedir. Ayrıca sıfır ortalama merkezli değer üretmesi ve daha büyük gradyan oluşturmaya sebebiyle eğitim işlemini hızlandırmaktadır.

$$\Phi(x) = \text{tanh}(x) = \frac{e^{2x} - 1}{e^{2x} + 1} \quad (2.7)$$

Sigmoid ve hiperbolik tanjant fonksiyonları sinir ağlarına doğrusal olmayan özellik

kazandırmak amacıyla kullanılan temel aktivasyon fonksiyonlarıdır. Ancak son yıllarda yarı doğrusal aktivasyon fonksiyonları daha popüler hale gelmiştir. Hinton ve arkadaşları çalışmalarında düzeltilmiş doğrusal birim (ReLU) aktivasyon fonksiyonunun sinir ağı eğitiminde hesaplamaları daha verimli ve hızlı hale getirdiğini gösterene kadar, doğrusal olmayan, türevlenebilir ve simetrik özellikteki aktivasyon fonksiyonlarının sinir ağlarında daha iyi sonuç verdiği düşünülmekteydi [71]. Denklem (2.8) ile verilen ReLU aktivasyon fonksiyonu "0" dışındaki her değer için türevlenebilir olduğundan gradyanlar kolaylıkla elde edilebilmektedir. Ayrıca fonksiyon çok büyük değerlerde doyuma ulaşmadığından, bu değerlerde de gradyanlar hesaplanabilmektedir. Diğer taraftan "0" değeri için türev elde edilemediğinden, uygulamaya göre "0" ya da "1" olarak kabul edilmektedir.

$$\Phi(x) = \text{ReLU}(x) = \max(0, x) \quad (2.8)$$

Düzeltilmiş doğrusal birim (ReLU) fonksiyonunda negatif değerli girdiler dikkate alınmamaktadır. Negatif değerli bir girdi "0" çıkışına neden olduğundan bu değer için hesaplanan gradyan da "0" olmaktadır. Bunun bir problem olduğu durumlarda Denklem (2.9) ile verilen sızan düzeltilmiş doğrusal birim (LReLU) fonksiyonu kullanılmaktadır. Burada  $\alpha$  katsayısı 1'den küçük bir pozitif sayıdır. Yukarıda belirtilen tüm aktivasyon fonksiyonlarının grafiksel gösterimleri Şekil 2.3.'de verilmektedir.

$$\Phi(x) = \text{LReLU}(x) = \max(\alpha x, x) \quad (2.9)$$

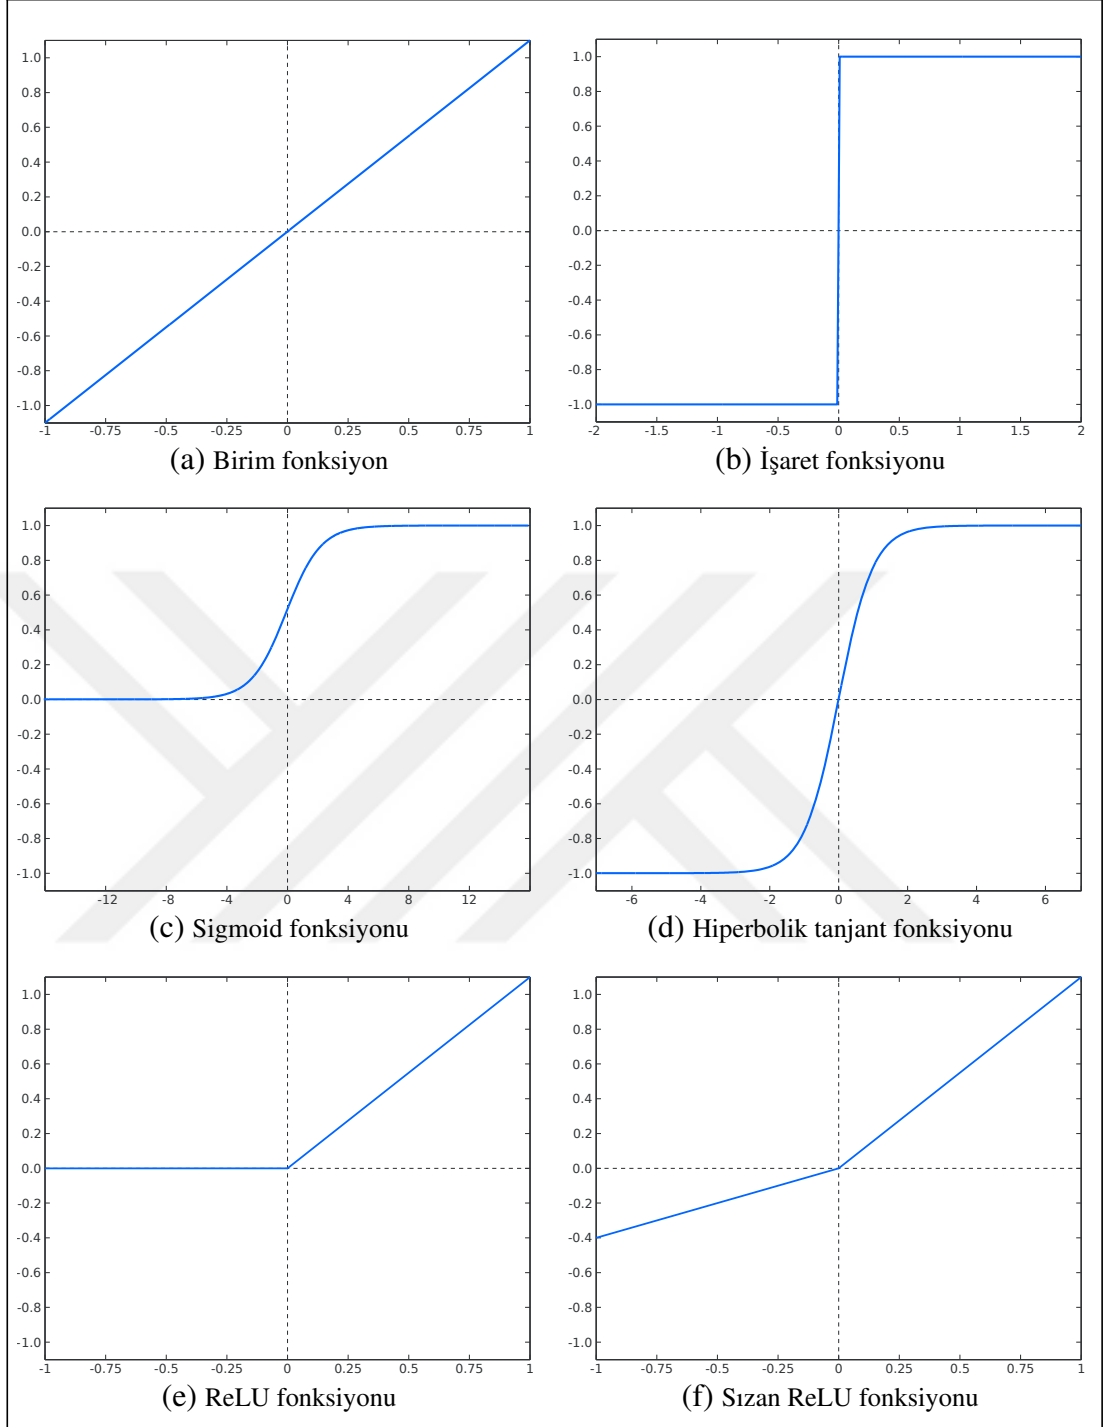
## 2.4. Kayıp Fonksiyonu

Kayıp fonksiyonları, bir sinir ağının eğitim sürecinde sistemin çıktısı ile hedeflenen değer arasındaki hatayı hesaplayan, optimizasyon algoritmaları ile minimize edilmeye çalışılan, türevlenebilir olması gereken matematiksel fonksiyonlardır. Optimizasyon ile çıktı katmanında elde edilen hata için hesaplanan gradyan (türev) ağda geriye doğru yayılarak, ağın parametreleri güncellenmektedir. Yapay sinir ağlarında yaygın olarak kullanılan ortalama karesel hata (L2) kaybı ve çapraz entropi kaybı fonksiyonları aşağıda verilmektedir.

### 2.4.1. Ortalama karesel hata (L2) kaybı

Makine öğrenmesi uygulamalarında en yaygın kullanılan kayıp fonksiyonu ortalama karesel hata fonksiyonudur. L2 kayıp fonksiyonu olarak da bilinen bu kayıp fonksiyonunda her bir örnek için elde edilen hataların karesel ortalaması E,





Şekil 2.3. Çeşitli aktivasyon fonksiyonları

Denklem (2.10)'deki gibi hesaplanmaktadır. Burada  $e_i$ ,  $i$ 'nci çıkış nöronu için hatayı,  $y$ , doğru etiket değerini,  $\hat{y}$ , tahmin değerini ifade etmektedir.

$$E = \frac{1}{n} \sum_{i=1}^n e_i^2, \quad e_i = y_i - \hat{y}_i \quad (2.10)$$

### 2.4.2. Çapraz entropi kaybı

Çapraz entropi kaybı, çoğunlukla regresyon ve sınıflandırma problemlerinde çıkış bir olasılık dağılımı olduğunda kullanılan, ortalama karesel hata kaybına benzer şekilde, iki gösterimin dağılım özelliklerini ölçen bir kayıp fonksiyonudur. Logaritmik kayıp olarak da tanımlanan çapraz entropi kaybı fonksiyonu Denklem (2.11) ile verilmektedir.

$$L(p, y) = - \sum_n y_n \log(p_n), \quad n \in [1, N] \quad (2.11)$$

Burada  $y$  doğru etiket değerini,  $p$  her bir sınıf için elde edilen olasılık değerini ifade etmektedir. Çıktı katmanında toplam  $N$  nöron olduğu durumda  $p, n \in \mathbb{R}^N$  olmaktadır. Her bir sınıfın olasılığı ise Denklem (2.12) ile verilen softmax fonksiyonu kullanılarak hesaplanabilmektedir. Burada  $\hat{p}_n$  ağda önceki katmandan elde edilen normalize edilmemiş çıktı değeridir. Kayıp fonksiyonu içerisindeki normalizasyon yönteminden dolayı, bu kayıp fonksiyonu aynı zamanda softmax kaybı olarak da adlandırılmaktadır.

$$p_n = \frac{\exp(\hat{p}_n)}{\sum_k \exp(\hat{p}_k)}, \quad k \in [1, N] \quad (2.12)$$

Çapraz entropi kaybı kullanılarak ağ parametrelerinin optimize edilmesinin, öngörülen değer (tahmin dağılımı,  $p$ ) ile doğru değer (gerçek dağılım,  $y$ ) arasındaki Kullback-Leibler (KL) mesafesinin en aza indirilmesiyle eşdeğer olması dikkat çekicidir. Tahmin değeri  $p$  ile doğru değer  $y$  arasındaki KL mesafesi, Denklem (2.13)'deki gibi çapraz entropi  $L(\cdot)$  ile entropi  $H(\cdot)$  arasındaki fark olarak ifade edilebilmektedir. Burada entropi sabit bir değer olduğundan, çapraz entropi kaybını minimize etmek, iki dağılım arasındaki KL mesafesini minimize etmeye eşdeğer olmaktadır.

$$KL(p \parallel y) = L(p - y) - H(p) \quad (2.13)$$

Oluşturulan sinir ağı çıkışının iki sınıflı olduğu durumlarda, çapraz entropi kaybı fonksiyonu Denklem (2.14) 'de verilen ikili çarpaz entropi kaybı fonksiyonuna dönüşmektedir. Burada  $N$  örnek sayısı,  $y = [y_1, y_2, \dots, y_N] \in \mathbb{R}^N$  ağın çıkış değeri,  $p = [p_1, p_2, \dots, p_n] \in \mathbb{R}^N$  doğru etiket değeridir.

$$L(p, y) = - \frac{1}{N} \sum_{n=1}^N p_n \log(y_n) + (1 - p_n) \log(1 - y_n) \quad (2.14)$$

## 2.5. Geri-Yayılım Algoritması

Tek katmanlı sinir ağında, eğitim süreci nispeten basittir, çünkü hata ağırlıklarının bir fonksiyonu olarak doğrudan hesaplanabilmektedir. Çok katmanlı sinir ağlarında ise kayıp fonksiyonunun önceki katmanlardaki tüm ağırlıkların karmaşık bir bileşkesi olması bir problem olarak ortaya çıkmaktadır. Bir bileşke fonksiyonunun gradyanı, geri-yayılım algoritması kullanılarak hesaplanabilmektedir. Geri-yayılım algoritması, bir düğümden çıkışa kadar çeşitli yollar üzerindeki yerel gradyanların toplamları olan, hata gradyanlarını hesaplamada diferansiyel analiz zincir kuralını kullanmaktadır. Her ne kadar bu toplamda çok sayıda bileşen olsa da, dinamik programlama kullanılarak verimli bir şekilde hesaplanabilmektedir. Dinamik programlamanın doğrudan bir uygulaması olan geri-yayılım algoritması, sırasıyla ileri yönlü ve geri yönlü evre olmak üzere iki aşamadan meydana gelmektedir. İleri yönlü evrede, farklı düğümlerdeki çıktı değerleri ve yerel türevler hesaplanırken, geri yönlü evrede bu yerel düğümlerdeki değerler ve türevler çıkışa kadar tüm yollar üzerinde biriktirilmektedir.

1. İleri yönlü evre: Bu evrede, bir eğitim örneğinin girdileri ile sinir ağı beslenmektedir. Ağdaki mevcut ağırlıklar kullanılarak katmanlar arasında ileri yönlü olarak düğüm çıktıları elde edilmektedir. Ağın çıkışından elde edilen tahmin değeri eğitim örneğinin etiket değeri ile karşılaştırılarak kayıp fonksiyonunun türevi hesaplanmaktadır. Daha sonra bu kayıp fonksiyonu türevinin geri yönlü evrede tüm katmanlardaki ağırlıklara göre hesaplanması gerekmektedir.

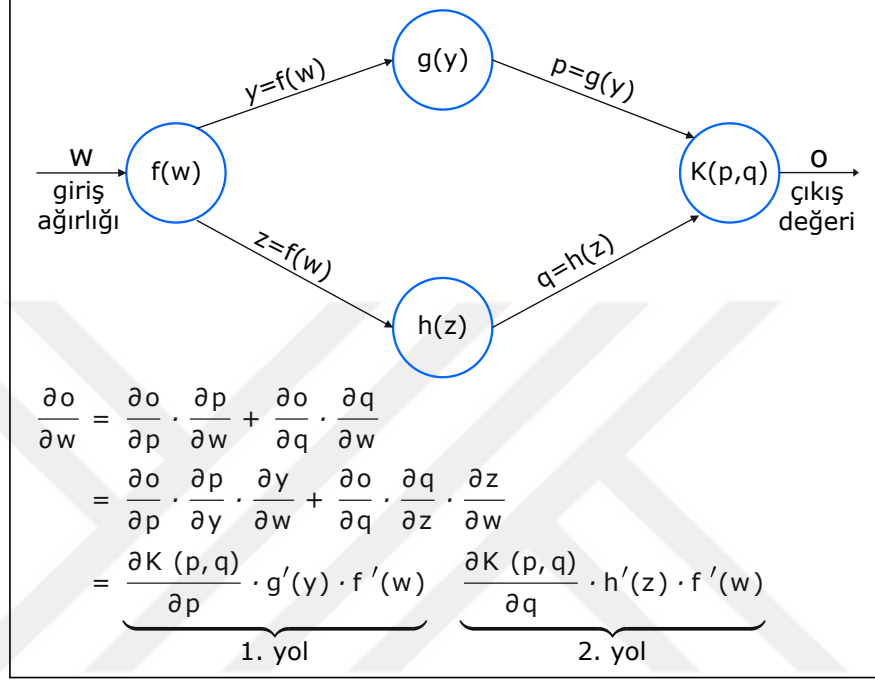
2. Geri yönlü evre: Geri yönlü evrede temel amaç, diferansiyel analiz zincir kuralını kullanarak, ağın önceki katmanlarındaki ağırlıklara bağlı olarak kayıp fonksiyonun gradyanını hesaplamaktır. Bu gradyanlar ise ağın ağırlıklarını güncelleme için kullanılmaktadır. Gradyanlar çıkış düğümünden başlayarak geri yönde elde edildiğinden, bu öğrenme süreci geri yönlü evre olarak adlandırılmaktadır.

L kayıp fonksiyonu hesabında  $h_1, h_2, \dots, h_k$  gizli düğüm dizisini bir o çıkışının izlediği,  $h_r$  ile  $h_{r+1}$  gizli düğümleri arasındaki bağlantı ağırlıklarının ise  $w_{(h_r, h_{r+1})}$  olduğu varsayalım.  $h_1$  gizli düğümünden o çıkışına tek bir yol olması durumu için zincir kuralı kullanılarak, bu bağlantı ağırlıklarından herhangi birine göre kayıp fonksiyonunun gradyanı Denklem (2.15)'deki gibi türetilmektedir.

$$\frac{\partial L}{\partial w_{(h_{r-1}, h_r)}} = \frac{\partial L}{\partial o} \cdot \left[ \frac{\partial o}{\partial h_k} \prod_{i=r}^{k-1} \frac{\partial h_{i+1}}{\partial h_i} \right] \frac{\partial h_r}{\partial w_{(h_{r-1}, h_r)}}, \quad \forall r \in 1 \dots k \quad (2.15)$$

Denklem (2.15) ile verilen ifade ağda  $h_1$  düğümü ile o çıkışı arasında tek bir yolun

var olduğu durum için geçerliyken, gerçekte üssel sayıda yol olabilmektedir. Zincir kuralının genelleştirilmiş bir türü olan çok değişkenli zincir kuralı ile birden fazla yolun mevcut olduğu durumlar için gradyan hesaplanmaktadır. Bunun için  $h_1$  düğümü ile o çıkışı arasındaki her bir yol bileşke değere eklenmektedir. Şekil 2.4.'de iki yöllü bir durum için zincir kuralının örneği verilmektedir. Denklem (2.15) ile



Şekil 2.4. Hesaplamalı çizgelerde zincir kuralının gösterimi [72]

verilen ifade,  $h_r$  düğümü ile o çıkışı arasında bir  $P$  kümesi ile verilen yolların olduğu durum için Denklem (2.16)'deki gibi genelleştirilmektedir.

$$\begin{aligned} \frac{\partial L}{\partial w_{(h_{r-1}, h_r)}} &= \frac{\partial L}{\partial o} \cdot \left[ \sum_{[h_r, h_{r+1}, \dots, h_k, o] \in P} \frac{\partial o}{\partial h_k} \prod_{i=r}^{k-1} \frac{\partial h_{i+1}}{\partial h_i} \right] \frac{\partial h_r}{\partial w_{(h_{r-1}, h_r)}} \\ \frac{\partial L}{\partial w_{(h_{r-1}, h_r)}} &= \frac{\partial L}{\partial h_r} \cdot \frac{\partial h_r}{\partial w_{(h_{r-1}, h_r)}} = \Delta(h_r, o) \cdot \frac{\partial h_r}{\partial w_{(h_{r-1}, h_r)}} \end{aligned} \quad (2.16)$$

Denklem (2.16)'de gizli düğüm sayısına bağlı olarak üssel sayıda artan yollar  $\Delta(h_r, o)$  ile toplanmaktadır. Burada bir sinir ağı için oluşturulan hesaplama döngüsel olmayıp, o çıkışına en yakın düğüm  $h_k$  için  $\Delta(h_k, o)$  gradyanı ile başlanarak, geriye doğru gradyanların hesaplanması suretiyle genel çözüm elde edilmektedir.  $\Delta(h_r, o)$  gradyanı için özyineleme, çok değişkenli zincir kuralı kullanılarak Denklem (2.17)'deki gibi türetilebilmektedir. Burada  $h$  düğümü,  $h_r$  düğümünün içinde bulunduğu katmandan sonra gelen katmanda yer aldığından,  $\Delta(h_r, o)$  gradyanının elde edilmesi sırasında,  $\Delta(h, o)$  gradyanı daha önceden hesaplandığından değeri bilinmektedir.

$$\Delta(h_r, o) = \frac{\partial L}{\partial h_r} = \sum_{h:h_r \Rightarrow h} \frac{\partial L}{\partial h} \frac{\partial h}{\partial h_r} = \sum_{h:h_r \Rightarrow h} \Delta(h, o) \frac{\partial h}{\partial h_r} \quad (2.17)$$

$h_r$  ile  $h$  düğümleri arasındaki bağlantı ağırlığının  $w_{(h_r, h)}$ ,  $a_h$ 'in ise  $h$  düğümünde,  $\Phi(\cdot)$  aktivasyon fonksiyonuna girdi olarak verilen değer olduğu varsayıldığında, tek değerli zincir kuralından hareketle,  $\frac{\partial h}{\partial h_r}$  ifadesi Denklem (2.18)'deki gibi türetilmektedir.

$$\frac{\partial h}{\partial h_r} = \frac{\partial h}{\partial a_h} \cdot \frac{\partial a_h}{\partial h_r} = \frac{\partial \Phi(a_h)}{\partial a_h} \cdot w_{(h_r, h)} = \Phi'(a_h) \cdot w_{(h_r, h)} \quad (2.18)$$

Bu  $\frac{\partial h}{\partial h_r}$  değeri çıkış düğümünden başlanarak geri yönde tekrarlı olarak Denklem (2.17)'de kullanılmaktadır. Geri yöndeki bu tekrarlı ifade Denklem (2.19)'deki gibi olmaktadır. Bu şekilde gradyanlar geri yönde sırasıyla biriktirilerek her bir düğüm geri yönde bir kez işlenmektedir.

$$\Delta(h_r, o) = \sum_{h:h_r \Rightarrow h} \Phi'(a_h) \cdot w_{(h_r, h)} \cdot \Delta(h, o) \quad (2.19)$$

Denklem (2.16)'de yer alan  $\frac{\partial h_r}{\partial w_{(h_{r-1}, h_r)}}$  ifadesi ise Denklem (2.20)'de gösterildiği gibi elde edilmektedir.

$$\frac{\partial h_r}{\partial w_{(h_{r-1}, h_r)}} = h_{r-1} \cdot \Phi'(a_{h_r}) \quad (2.20)$$

### 3. EVRİŞİMLİ SİNİR AĞLARI

Evrışimli sinir ağı (CNN) çok sayıda katmandan oluşan, tasarımında biyolojik görsel korteksten ilham alınan bir derin öğrenme tekniğidir. Görsel korteks, görsel alanın belirli bölgelerine duyarlı küçük hücre bölgelerinden oluşmaktadır. Beyinde görsel kortekste farklı nöronlar görüntüdeki farklı özelliklere cevap vermektedir. Örneğin, belirli bir oryantasyona sahip çizgilerin varlığında yalnızca belirli bir grup nöronda aktivasyon gözlenmektedir [73]. Belirli bir nöron grubunun belirli bir göreve sahip olması fikri evrışimli sinir ağlarının temelini oluşturmaktadır.

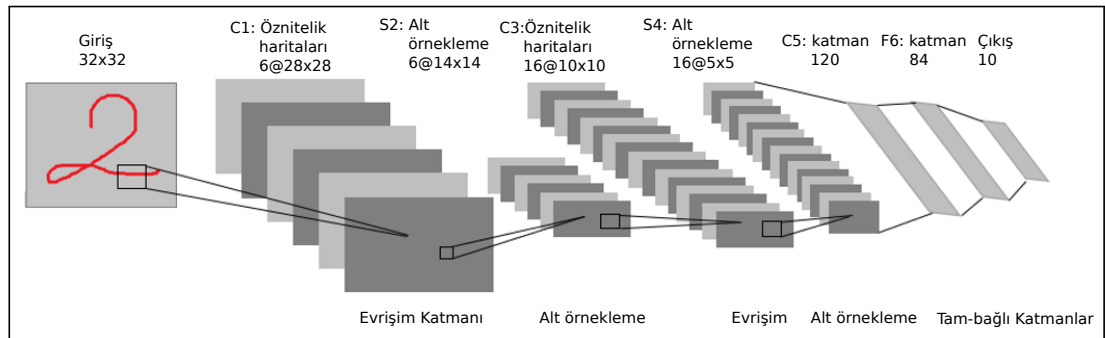
Evrışimli sinir ağları ile görüntü sınıflandırma, nesne algılama, konuşma tanıma, doğal dil işleme ve tıbbi görüntü analizi gibi birçok uygulamada yüksek performans elde edilmiştir. Bu derin öğrenme tekniğinde amaç, görüntü gibi karmaşık yapıdaki girdilerden yerel öznitelikler elde etmek ve bu öznitelikleri bir araya getirerek daha karmaşık gösterimler oluşturmaktır. Bununla birlikte, çok katmanlı mimarisi nedeniyle çok yüksek bir hesaplama gücü gerektirmekte, büyük veri setlerinden oluşan uygulamalarda, ağı eğitimi standart işlemciler ile haftalar sürebilmektedir. Bu nedenle, bu tür derin ağlar genellikle grafik işlem birimleri (GPU) kullanılarak eğitilmektedir.

Temel yapıları itibarıyla evrışimli sinir ağlarında, normalize edilmiş, standart boyutlarda görüntülerin alındığı bir giriş katmanı, bir dizi evrışim ve alt-örnekleme işlemlerinin gerçekleştirildiği ara katmanlar ve tam-bağlı yapıdaki ağdan oluşan bir çıkış katmanı bulunmaktadır. Evrışimli sinir ağı mimarisinin en önemli özelliği bir katmandaki her bir düğümün, önceki katmanda sınırlı bir uzamsal bölgeden girdiler almasıdır [74]. Bu mimarideki görsel sistem, tüm görüntünün küçük bir alt kümesine duyarlı olan, alıcı alan (receptive field) olarak tanımlanan, karmaşık hücre kümelerinden oluşmaktadır. Evrışim işleminde görüntünün tamamının değerlendirilebilmesi amacıyla, bu hücre kümelerine karşılık gelen evrışim çekirdekleri (filtreler) görüntü üzerinde kaydırılmaktadır. Yerel alıcı alan birimleri ile görüntüden yönlü kenarlar, uç noktalar ve köşeler gibi kullanışlı öznitelikler çıkarabilmektedir. Daha sonra, bu temel öznitelikler, üst seviye özniteliklerin elde edilmesi amacıyla sonraki katmanlarda birleştirilmektedir [74]. Her bir filtre bir dizi ağırlık ile tanımlanmaktadır. Bu ağırlıklar işlenen görüntüde filtrenin üzerinde bulunduğu alanda gerçekleştirilen çarpma işleminde çarpan olarak kullanılmakta, çarpımların toplamı ileri beslemeli ağda sonraki katmana aktarılmaktadır. Bu çarpma

işlemi aynı ağırlıklar kullanılarak görüntünün tümünde tekrarlanmaktadır. Bir görüntünün üzerine bir filtre uygulandığında çıktı, filtrenin her bir uzamsal bölgedeki yanıtından oluşan yeni bir görüntü olmaktadır. Bir öznitelik haritası olarak kabul edilen bu görüntüde, giriş görüntüsünün kenar, dikey/yatay çizgi veya köşe gibi öznitelikleri açığa çıkarılmaktadır [74].

### 3.1. Evrişimli Sinir Ağı Modellerinin Gelişimi

Evrişimli sinir ağları temelli ilk model, eğitimde geri yayılımın kullanıldığı LeNet [74] ağıdır. El yazısı rakamlarını (MNIST veriseti) sınıflandırmak için tasarlanan LeNet modeli, daha büyük problemler için ölçeklendirilebilir olmadığından karmaşık problemlerde yüksek başarımler gösterememiştir. Bunun nedenleri, etiketlenmiş veri setlerinin yetersiz büyüklükte olması, yavaş bilgisayarlar ve doğrusal olmayan aktivasyon fonksiyonunun yanlış seçimidir. Bir sinir ağına uygun aktivasyon fonksiyonunun kullanılması, nihai performans üzerinde büyük etkiye sahiptir. Sigmoid veya hiperbolik tanjant gibi doğrusal olmayan bir aktivasyon fonksiyonunun kullanıldığı bir derin sinir ağına, geri-yayılım algoritması kullanılarak yapılan eğitimde gradyanların yok olması problemi baş göstermektedir. Gradyanların yok olması sinir ağının üst katmanlarında parametreleri eğitmeyi ve ayarlamayı zorlaştırmaktadır. Ağıdaki toplam katman sayısı arttıkça bu problem daha da kötüleşmektedir. LeNet5 evrişimli sinir ağı modelinin genel mimarisi Şekil 3.1.'de verilmektedir.



Şekil 3.1. LeNet5 evrişimli sinir ağı modelinin genel mimarisi [74]

ImageNet Büyük Ölçekli Görsel Tanıma Yarışması (ILSVRC) 2012'de önerilen AlexNet [71] evrişimsel sinir ağı modeli, sınıflandırma hatasını %26'dan %15'e indirerek tüm geleneksel yöntemlerden daha yüksek bir performans ortaya koymuştur. AlexNet'in basit bir model olmasına rağmen LeNet modelinden çok daha etkili olması şu nedenlerden kaynaklanmaktadır:

1. Veri seti: Toplam 22.000 kategoriden yaklaşık 15 milyon etiketli örnek içeren büyük bir etiketli veri seti (ImageNet) kullanılmıştır.

2. İşlem gücü: Oluşturulan model yüksek hızlı grafik işlem birimleri (GPU) kullanılarak günler boyunca eğitilmiştir.

3. Aktivasyon fonksiyonu: Modelde düzeltilmiş doğrusal birim (ReLU) aktivasyon fonksiyonu kullanımı ile gradyan yok olması probleminin büyük ölçüde önüne geçilmiştir.

AlexNet modeli yapı olarak beş evrişimli katman, üç birleştirme katmanı, üç tam-bağlı katman ve 1000-çıkışlı softmax sınıflandırıcıdan meydana gelmektedir.

AlexNet mimarisinin geliştirilmiş bir sürümü olarak önerilen ZFNet [75] modeli, ImageNet Büyük Ölçekli Görsel Tanıma Yarışması (ILSVRC) 2013'ün galibi olmuştur. ZFNet modelinde AlexNet'ten farklı olarak ilk katmandaki filtre boyutu  $11 \times 11$ 'den  $7 \times 7$ 'ye düşürülmüş, evrişim çekirdeği kaydırma adımı 4 yerine 2 olarak seçilerek daha belirgin öznitelikler elde edilmiştir.

ILSVRC 2014'te %7,32'lik bir hata oranı ile ikinci olan VGGNet [76] modelinde, sınıflandırma başarımının iyileştirmek amacıyla ağ derinliği arttırılmıştır. Ağ, daha fazla evrişim katmanı eklenerek 19 katmanlı hale getirilmiştir. Ayrıca filtre boyutları küçültülerek  $3 \times 3$  olarak belirlenmiştir. Gruplanmış evrişim katmanları çıkışında yer alan maksimum birleştime katmanlarında,  $2 \times 2$  boyutunda pencere ile maksimum değer seçimi yapılmıştır. Filtre boyutunun küçültülerek ağın derinliğinin arttırılması ile daha yüksek başarımlı sunan bir CNN mimarisi oluşturulmuştur.

Google tarafından geliştirilen 22 katmanlı GoogLeNet [77] modeli 2015 yılında ILSVRC yarışmasında %6,7 hata oranı ile en yüksek başarımlı elde etmiştir. GoogLeNet, ağıdaki parametre sayısının azaltılmasına yardımcı olan başlangıç (inception) birimlerinin kullanımı ile daha önce geliştirilen CNN modellerinden farklı bir mimariye sahiptir. Başlangıç birimleri, bir sonraki katman için tek bir çıkış vektörünün oluşturulduğu, farklı ölçeklerdeki paralel ve seri bağlı evrişim ve birleştirme alt katmanlarından meydana gelmektedir. Fazladan evrişimsel işlemler nedeniyle ek işlemsel karmaşıklığı telafi etmek amacıyla  $3 \times 3$  ve  $5 \times 5$  evrişim katmanlarından önce düşük hesaplama maliyetli  $1 \times 1$  evrişim kullanılmaktadır. Bu özel başlangıç birimleri temelli mimari, GoogLeNet'in AlexNet'ten 12 kat daha az parametreye sahip olmasını sağlamaktadır.

Evrişimli sinir ağlarında katman sayısının arttırılması, ağın doğruluğunu arttıran özelliklerin sayısını da arttırmaktadır. Fakat fazla sayıda katmana sahip bir derin sinir ağında, gradyanların kaybolması problemi bilgi kaybına neden olabilmektedir. Ayrıca



çok fazla sayıda parametreye sahip bir ağın eğitimi için çok yüksek hesaplama gücü gerekecektir. Dolayısıyla ağın derinliği artırılırken bu problemler göz önünde bulundurulmalıdır.

Microsoft 2015 yılında, 152 katmanlı bir CNN ağı olan ResNet [78] modelini önermiştir. Bu modelde önceki evrişim katmanından sonraki katman çıkışına bağlanan rezidü bağlantılar bulunmaktadır. Bu sayede bilgi önceki katmandan bir sonraki katmana taşınmakta ve geri yayılma sırasında, gradyanı dağıtan toplama işlemlerinden dolayı gradyan kolayca iletilmektedir. ResNet ile iyi bir başarımla elde etmek için başlangıç birimleri gibi karmaşık bir mimarinin gerekli olmadığı kanıtlanmıştır. ResNet ağı ile ILSVRC 2015’de, insan hata eşiğinin daha da altında, %3,6’lık bir hata oranı elde edilmiştir. ResNet, sekiz kat daha az derinliğe sahip olan VGGNet ağından daha az parametreye sahiptir.

### **3.2. Evrişimli Sinir Ağı Mimarisi**

Evrişimli sinir ağları, geleneksel sinir ağlarının geri-yayılım, kayıp fonksiyonları gibi bazı genel özelliklerini paylaşmakla birlikte mimari olarak oldukça farklılık göstermektedir. Geleneksel sinir ağlarında giriş ile çıkış katmanı arasında, her nöronun önceki katmandaki tüm nöronlara bağlı olduğu, tam bağlı gizli katmanlar bulunmaktadır. Evrişimli sinir ağları ise yerel alıcı alan, ağırlık paylaşımı ve alt örnekleme olmak üzere üç temel özelliğe sahiptir.

1. Yerel alıcı alan: Geleneksel bir sinir ağında, bir katmandaki her bir nöron önceki katmandaki tüm nöronlara bağlı iken, evrişimli sinir ağlarında her bir gizli birim, yerel alıcı alan adı verilen, girişin yalnızca küçük bir bölgesine bağlanmaktadır. Bu bağlantı evrişim işlemi ile, girdiden çok daha küçük boyutlu ağırlık matrisleri kullanılarak gerçekleştirilmektedir. Yerel alıcı alanla yaklaşımıyla kenar, köşe, bitiş noktaları gibi temel görsel özellikler algılanabilmektedir.

2. Ağırlık paylaşımı: Ağırlık paylaşımı, bir katmandaki tüm alıcı alanlarda aynı filtre ağırlıklarının kullanımınıdır. Evrişim işlemi sırasında, giriş görüntüsü üzerinde kaydırılan evrişim çekirdeğindeki ağırlıklar konuma bağlı olarak değişmemektedir.

3. Alt örnekleme: Alt örnekleme, girişin uzamsal boyutunu düşürerek ağıdaki parametre sayısını azaltmaktadır. Birleştirme katmanları ile gerçekleştirilen alt örnekleme tekniklerinden en çok tercih edileni maksimum birleştirmedir.


Evrişimli sinir ağlarında farklı görevleri olan farklı katman türleri bulunmaktadır. Tipik bir evrişimli sinir ağı temel olarak ardışık olarak bağlanmış evrişim, birleştirme ve tam-bağlı katmanlardan meydana gelmektedir. Ağ üzerinde genellikle birkaç evrişim

katmanından sonra birleştirme katmanı ile uzamsal boyut azaltılmaktadır. Tam bağlı katmanlar ağın sonunda yer alarak, evrişim ve birleştirme katmanlarında elde edilen gösterimlerin sınıflandırıldığı, geleneksel bir yapay sinir ağı gibi çalışmaktadır.

### 3.2.1. Evrişim katmanı

Evrişimli sinir ağlarına adını veren evrişim katmanı, nöron bağlantılarının evrişim işlemi ile sağlandığı özel bir ileri-beslemeli ağ katmanıdır. Bağlantı ağırlıkları evrişim çekirdeği olarak da bilinen bir dizi eğitilebilir filtre ile temsil edilmektedir. Evrişimli katmanın temel görevi, girdi kümesinin yerel bölgelerinde bulunan ve veri kümesi boyunca ortak olan öznitelikleri tespit etmek ve görünümelerini bir öznitelik haritasına eşlemektir. Evrişim işleminde, kayar pencere ile görüntünün tamamına uygulanan katmandaki her bir filtre için bir öznitelik haritası elde edilmektedir. Denklem (3.1)'de evrişim işlemi için transfer fonksiyonu verilmektedir. Burada  $K$  filtre çekirdeğinin  $3 \times 3$  boyutlu olduğu düşünüldüğünde,  $D \times N$  boyutlu bir  $A$  giriş matrisi için  $m$  ve  $n$  değerleri,  $1 < m < D$  ve  $1 < n < N$  aralığında olmaktadır. İki boyutlu bir giriş görüntüsü için, iki boyutlu filtreler ile gerçekleştirilen, evrişim işlemi sonucu elde edilen öznitelik haritaları Şekil 3.2. ile örneklendirilmektedir.

$$F(i,j) = (A * K)(i,j) = \sum_m \sum_n A(i-m, j-n) K(m,n) \quad (3.1)$$



Şekil 3.2. Evrişim katmanlarında gerçekleştirilen evrişim işlemi

Evrişimli sinir ağı mimarisinde, oluşturulan modelin davranışını kontrol etmek amacıyla bazı hiperparametreler kullanılmaktadır. Bu hiperparametrelerin bazıları

çıkışın boyutunu kontrol ederken, bazıları modelin çalışma süresini ve bellek maliyetini ayarlamak için kullanılır. CNN mimarisinde evrişim katmanı için dört önemli hiperparametre aşağıda verilmektedir:

1. Filtre boyutu: Evrişim katmanlarında kullanılan filtre (evrişim çekirdeği) boyutları giriş boyutundan daha küçük herhangi bir boyutta olabilmekle birlikte, uygulamalarda genellikle  $3 \times 3$  ile  $11 \times 11$  arasında seçilmektedir. Filtre boyutu giriş boyutundan bağımsızdır.

2. Filtre sayısı: Evrişim katmanında daha fazla sayıda filtre bulunması, giriş görüntüsünde daha fazla sayıda örüntü türünü tanımayı mümkün kılmaktadır. Diğer yandan daha fazla sayıda ağ parametresi, ağın eğitimini zorlaştırdığından bu sayı uygulamaya yönelik olarak optimum düzeyde seçilmelidir. Genellikle  $256 \times 256$  çözünürlükte görüntülerden oluşan ImageNet [79] veri setinin sınıflandırılmasında kullanılan AlexNet ağının birinci evrişim katmanında,  $11 \times 11$  boyutunda 96 filtre bulunurken, VGGNet ağında  $7 \times 7$  boyutunda 96 filtre bulunmaktadır.

3. Evrişim adımı: Evrişim sırasında filtrenin giriş görüntüsü üzerindeki uzamsal hareketini tanımlayan evrişim adımı, tanımlanan filtre boyutlarıyla uyumlu olarak seçilmektedir. Evrişim katmanında çıktı boyutunu da belirleyen evrişim adımının küçük seçilmesi, yerel alıcı alanların daha fazla üst üste gelmesine neden olurken, büyük seçilmesi ise bazı özniteliklerin gözden kaçmasına neden olabilmektedir.

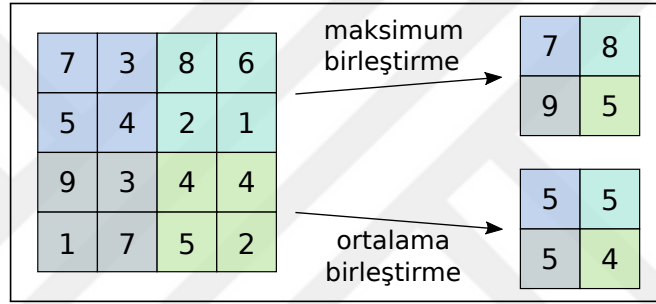
4. Sıfır Doldurma: Bu hiperparametre giriş görüntüsünde sıfır ile doldurulacak piksel sayısını tanımlamaktadır. Sıfır doldurma, çıkışın uzamsal boyutunu kontrol etmek için kullanılmaktadır.

Evrişim katmanındaki her bir filtre  $([A - K + 2P]/S) + 1$  boyutlu bir öznitelik haritası üretmektedir. Burada A giriş görüntüsü boyutunu, K filtre boyutunu, P uygulanan sıfır doldurma sayısını, S evrişim adımını temsil etmektedir.

### 3.2.2. Birleştirme katmanı

Bir CNN mimarisindeki her evrişimli katmanda, önceki katmandan alınan öznitelik haritaları üzerinde bir evrişim işlemi gerçekleştirilir. Ardı ardına gerçekleştirilen evrişim işlemleri ile alıcı alan büyümekte, ilk katmanlarda nesnelere küçük bölümlerinden elde edilen öznitelikler sonraki katmanlarda belirleyici hale gelmektedir. Birleştirme katmanları evrişim katmanı çıktısının boyutlarını azaltmak amacıyla kullanılmaktadır. Birleştirme katmanı kullanılmadan oluşturulan bir evrişimli sinir ağında elde edilen öznitelik sayısı istenmeyen bir şekilde yüksek olabilmektedir. Bu kadar çok sayıda öznitelik ile yapılacak eğitim, çok yüksek bir hesaplama gücü gerektirdiği gibi eğitimde aşırı uyum sorununa da neden

olabilmektedir. Birleştirme katmanının uygulama amacı, uzamsal boyutu ve parametre sayısını azaltmak suretiyle giriş olarak verilen öznitelik haritasını aşağı örneklemektir. Ayrıca evrişimli sinir ağı mimarisinde birbiri ardına gelen evrişim katmanlarından sonra kullanılan birleştirme katmanı ile özniteliklerin uzamsal değişmezliği bir dereceye kadar sağlanmaktadır. Birleştirme katmanında ortalama birleştirme, maksimum birleştirme, L2-norm birleştirme gibi birkaç yöntem bulunmakla birlikte, yerel bölgenin baskın olan özneliğini ortaya çıkaran maksimum birleştirme, uygulamalarda sıklıkla kullanılmaktadır. Bu yöntem hatayı en yüksek yanıtlarla yaymayı sağladığı için özellikle önemlidir çünkü ortalama alma işleminde sıklıkla karşılaşılan gradyanların kaybolması riskini önemli ölçüde azaltır. Denklem (3.3.)’de  $2 \times 2$  pencere ile gerçekleştirilen maksimum ve ortalama birleştirme işlemleri verilmektedir.

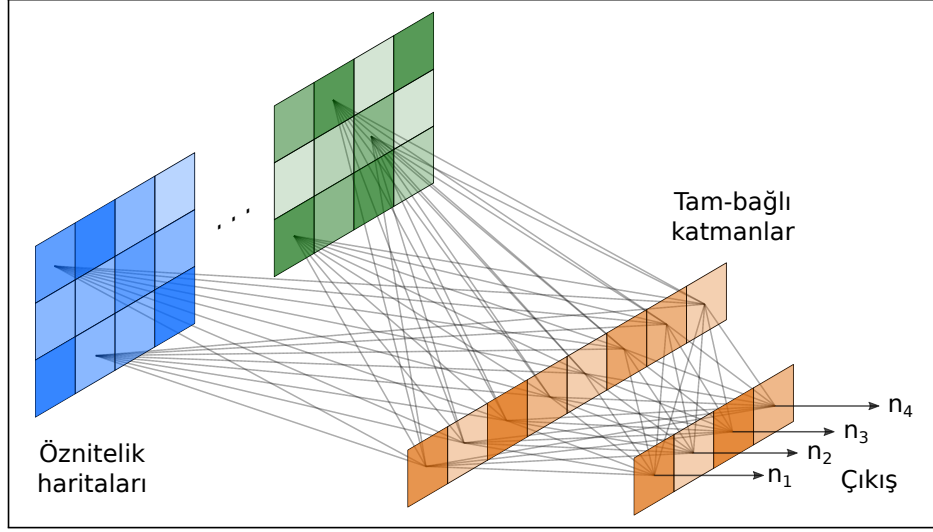


Şekil 3.3. Birleştirme katmanında  $2 \times 2$  pencere ile gerçekleştirilen maksimum ve ortalama birleştirme işlemi

Son birleştirme katmanında indirgenmiş olan öznitelik haritaları genellikle ağ çıkışıdaki tam-bağlı sinir ağına, sınıflandırılmak üzere iletilmektedir [80].

### 3.2.3. Tam-bağlı katman

Evrişimli sinir ağları temelde öznitelik çıkarma ve sınıflandırma olmak üzere iki aşamadan oluşmaktadır. Evrişim ve birleştirme katmanları öznitelik çıkarma aşaması olarak işlev görürken, sınıflandırma aşamasında bir veya daha fazla tam-bağlı katmanı takip eden çıkış katmanı görev almaktadır. Evrişim ve birleştirme süreci, yeterli seviyede öznitelik oluşturuluncaya kadar devam etmektedir. Sonraki aşamada bu öznitelikler kullanılarak bir sonuç değeri elde etmek amacıyla sınıflandırma gerçekleştirilir. Sınıflandırma aşamasında uzamsal alanda elde edilen öznitelikler kullanılarak her sınıf için bir olasılık değeri elde edilmektedir. Sınıflandırma sonucunun elde edildiği bu son katmanda ikili sınıflandırma için sigmoid aktivasyon fonksiyonu kullanılırken, çok sınıflı çıkışlar için softmax aktivasyon fonksiyonu kullanılmaktadır. Şekil 3.4.’de bir evrişim katmanı ile tam-bağlı katman arasındaki bağlantılar gösterilmektedir.



Şekil 3.4. Evrişim katmanı öznitelik haritaları ile tam-bağlı katmanlar arasındaki bağlantılar

### 3.3. Evrişimli Sinir Ağlarının Eğitimi

Derin sinir ağlarında eğitim, ağın yeni bir giriş örneğini bir sınıf etiketine eşlemesini sağlamak amacıyla, etiketli bir veri seti kullanılarak model parametrelerinin elde edilmesi ile gerçekleştirilmektedir. Etiketli veri setleri, her örneğin bir giriş verisi ve doğru sınıf etiketini içerdiği, eğitim örneklerinden meydana gelmektedir. Doğru model parametreleri, ağın yeni örnekler için sınıf etiketlerini doğru bir şekilde öngörmesini sağlamaktadır. Bunun için modelin eğitim veri setinden yeni örneklere genelleştirilmesi gerekmektedir.

Evrişimli sinir ağlarının eğitiminde amaç kayıp fonksiyonu en aza indirmektir. Bunun için kayıp fonksiyonunu minimum değere götürecek bir dizi ağ parametresi aranmaktadır. Gradyan azalma, ağ parametrelerinin değerlerini güncellemek için gerekli gradyanları hesaplayarak hatayı en aza indirmek için kullanılan bir optimizasyon tekniğidir. Derin öğrenme modelleri için en yaygın ve başarılı öğrenme algoritması, hatanın son katmandan ilk katmana doğru geriye yayıldığı gradyan azalma tabanlı geri yayılımdır. Bu öğrenme tekniğinde, bir sinir ağının tüm ağırlıkları rasgele ya da bir olasılık dağılım fonksiyonu kullanılarak ilklendirilmektedir. Verilen bir giriş verisi için ağdan elde edilen çıktı ile beklenen çıkış değeri kullanılarak, bir kayıp fonksiyonu ile hata hesaplanmaktadır.

#### 3.3.1. Gradyan azalma tabanlı optimizasyon

Evrişimli sinir ağlarının eğitilmesi, ağ üzerindeki ağırlıkların güncellenerek, parametre uzayında eğitim verileri ile hesaplanan hatayı minimize edecek optimum

noktanın arandığı bir optimizasyon problemidir. Bu optimizasyon problemlerin çözümünde Stokastik Gradyan Azalma, AdaGrad, AdaDelta, RMSProp, Adam gibi gradyan temelli algoritmalar kullanılmaktadır [81].

Toplu gradyan azalma olarak da bilinen geleneksel gradyan azalma yönteminde hata gradyanı,  $w$  ağırlık değerine göre tüm eğitim seti için hesaplanarak, Denklem (3.2)'de gösterildiği gibi güncellenmektedir. Burada  $\nabla E(w)$ ,  $w$  için hata gradyanı,  $\mu$  gradyan boyunca ilerlenecek adımı tanımlayan öğrenme hızıdır.

$$w = w - \mu \cdot \nabla E(w) \quad (3.2)$$

Öğrenme hızı çok yüksek veya çok düşük seçilmemesi gereken bir hiperparametredir. Yüksek öğrenme hızı optimum değer kaçırılmasına neden olabilirken, çok düşük öğrenme hızı eğitim süresini uzatmaktadır. Derin sinir ağları için kullanılan eğitim setleri genellikle çok yüksek sayıda örnek içerdiğinden, tüm örnekler için toplu olarak hata gradyanının hesaplanması çok büyük bir hafıza gerektirmektedir. Ayrıca bu hata gradyanının hesaplanması çok uzun sürmektedir. Bu problemin önüne geçmek amacıyla stokastik gradyan azalma tekniği kullanılabilir. Bu yöntemde, her adımda eğitim setinden rastgele seçilen bir eğitim örneği için gradyan hesaplanarak ağırlık güncellemeleri Denklem (3.3)'deki gibi güncellendiğinden, eğitim çok daha hızlı gerçekleşmektedir. Burada  $\nabla E(w; x(i); y(i))$ , eğitim setindeki bir  $\{x(i), y(i)\}$  örneği için kayıp fonksiyonunun gradyanıdır. Stokastik gradyan azalma ile yapılan eğitimde ağırlıklarında tek örneğe dayalı güncellemeler yapıldığından çözüm uzayında düzensiz bir hareket gözlenmektedir.

$$w = w - \mu \cdot \nabla E(w; x(i); y(i)) \quad (3.3)$$

Küçük-yığın (mini-batch) gradyan azalma, hem standart hem de stokastik gradyan azalma tekniklerinin bir kombinasyonu olan, derin öğrenme uygulamalarında yaygın olarak kullanılan bir yöntemdir. Bu yöntemde tüm veri seti  $n$  örnekten oluşan küçük yığınlar olarak ayrıştırılarak, ağırlık güncellemelerinin hesabı ve ağırlık güncellemeleri her seferinde bu yığınlardan biri kullanılarak, Denklem (3.4)'deki gibi gerçekleştirilmektedir.

$$w = w - \mu \cdot \nabla E(w; x(i : i + n); y(i + n)) \quad (3.4)$$

Küçük-yığın boyutu uygulamaya bağlı olarak genellikle 50 ile 256 arasında seçilmektedir. Büyük seçilen küçük-yığın boyutu daha doğru gradyanlar sağlamakla birlikte daha yüksek bellek kullanımını gerektirmektedir. Küçük seçilen küçük-yığın

boyutu ise gradyan hesabında büyük bir değişkenliğe neden olduğundan, dengeli bir eğitim için öğrenme hızının küçük seçilmesi gerekmektedir. Bu ise eğitim süresini uzatmaktadır.

Stokastik gradyan azalma yönteminde öğrenme hızı gradyan büyüklüğünden bağımsız olarak seçildiğinde bu durum bazı problemlere neden olmaktadır. Gradyan değerinin büyük olduğu durumlarda, yüksek öğrenme hızı büyük adım boyutuna neden olmaktadır. Bu durum çözüm uzayında optimum değer etrafında salınımına neden olduğundan optimum değere ulaşamamaktadır. Gradyan değerinin küçük olması durumunda ise öğrenme hızının büyük seçilmemesi optimum değere yavaş yakınsamaya neden olmaktadır. Karşılaşılabilecek bu problemler, öğrenme hızının uyarlanabilir olarak değiştirildiği bir yaklaşım kullanılarak çözülebilmektedir. AdaGrad uyarlanabilir öğrenme hızının kullanıldığı gradyan azalma yöntemlerinden biridir. Bu yöntemde öğrenme hızı parametresi  $\mu$ , önceki gradyanların karesel toplamının kare köküne bölünerek, Denklem (3.5)'deki gibi uyarlanabilir hale getirilmektedir. Burada  $\nabla_{t,i}$ ,  $w_i$  parametresi için kayıp fonksiyonunun gradyanı  $\nabla_{\tau}$ , iterasyon  $\tau$  için hesaplanan gradyandır.

$$w_{t+1,i} = w_{t,i} - \frac{\mu}{\sqrt{\sum_{\tau=1}^t \nabla_{\tau}^2}} \cdot \nabla_{t,i} = w_{t,i} - \frac{\mu}{\sqrt{G_i}} \cdot \nabla_{t,i} \quad (3.5)$$

AdaGrad yönteminin temel faydası, öğrenme oranının otomatik olarak ayarlanması ve manuel bir ayarlamaya gerek olmamasıdır. Ancak, paydadaki toplamın sürekli artıyor olması öğrenme hızının gitgide zayıflamasına neden olmaktadır. Bu azalan öğrenme hızı ise öğrenmeyi yavaşlatmakta veya tamamen durdurabilmektedir.

Azalan öğrenme hızı problemini aşmak üzere AdaDelta yöntemi önerilmiştir. Bu yöntemde önceki gradyan değerleri sabit bir x sayısı ile sınırlandırılmakta ve bu geçmiş gradyan değerlerinin ortalaması verimlilik için saklanmaktadır. Bir t anındaki  $\text{Avg}(\nabla_t^2)$  ortalama değeri, önceki ortalama değeri ve mevcut gradyana bağlı olarak elde edilmekte ve ağırlık güncellemesi Denklem (3.6)'deki gibi gerçekleştirilmektedir.

$$w_{t+1} = w_t - \frac{\mu}{\sqrt{\text{Avg}(\nabla_t^2)}} \cdot \nabla_t \quad (3.6)$$

AdaGrad yöntemindeki öğrenme hızı probleminin önüne geçen diğer bir yöntem RMSProp algoritmasıdır. Bu yöntemde uyarlanabilir öğrenme hızı üstel ağırlıklı kayar ortalama kullanılarak sağlanmaktadır. Ağırlıkların güncellenmesinde gradyan büyüklüğü yerine gradyanın işareti kullanılmaktadır. RMSProp yönteminde, izin verilen maksimum ve minimum ağırlık güncellemesi sırasıyla  $\nabla_{\max}$  ve  $\nabla_{\min}$  olmak

üzere, güncelleme büyüklüğü tüm ağırlıklar için eşit olacak şekilde ilklendirilmektedir. Her iterasyonda, mevcut ve önceki gradyan değerleri aynı işarete sahipse öğrenme hızı belirli bir oranda arttırılırken, farklı işarete sahipse belirli bir oranda azaltılmaktadır.

Uyarlanabilir Moment Kestirimi (Adam), AdaGrad ve RMSProp'un avantajlarından yararlanan uyarlanabilir bir optimizasyon tekniğidir. Adam optimizasyon algoritması, evrişimli sinir ağlarında diğer gradyan temelli algoritmalara göre daha hızlı yakınsama oranı sunmaktadır [82]. AdaDelta ve RMSProp yöntemlerinde olduğu gibi, Adam yönteminde de önceki karesel gradyanların üssel azalan ortalaması  $v_t$  saklanmaktadır. Bununla birlikte gradyanların ikinci momentlerinin ortalaması  $m_t$  de hesaplanmaktadır. Ortalama ve varyans değerleri olan  $m_t$  ve  $v_t$ , sırasıyla Denklem (3.7) ve Denklem (3.8) ile verilmektedir.

$$m_t = \beta_1 m_{t-1} + (1 - \beta_1)gt \quad (3.7)$$

$$v_t = \beta_2 v_{t-1} + (1 - \beta_2)gt^2 \quad (3.8)$$

Gradyanların ve karesel gradyanların üstel hareketli ortalaması sırasıyla Denklem (3.9) ve Denklem (3.10)'deki gibi güncellenmektedir. Burada  $\beta_1, \beta_2 \in [0, 1]$  hiperparametreleri bu hareketli ortalamaların zayıflama oranlarını kontrol etmektedir.

$$\hat{m}_t = \frac{m_t}{1 - \beta_1^t} \quad (3.9)$$

$$\hat{v}_t = \frac{v_t}{1 - \beta_2^t} \quad (3.10)$$

Adam algoritmasında ağırlık güncellemesi nihai olarak Denklem (3.11)'deki gibi yapılmaktadır.

$$w_{t+1} = w_t - \frac{\mu}{\sqrt{\hat{v}_t}} \cdot \hat{m}_t \quad (3.11)$$

Öğrenme hızının azalması, güncellemelerdeki yüksek varyans ve yavaş yakınsama gibi diğer optimizasyon yöntemlerinin karşılaştığı sorunların üstesinden geldiği Adam algoritması, evrişimli sinir ağları eğitiminde en çok tercih edilen optimizasyon tekniğidir.

### 3.3.2. Evrişimli sinir ağlarının eğitiminde zorluklar

Evrişimli sinir ağlarının eğitiminde gradyanların kaybolması, veri seti büyüklüğü, aşırı uyum ya da yetersiz uyum gibi problemlerle karşılaşılabilir. Sigmoid,



hiperbolik tanjant gibi aktivasyon fonksiyonları içeren bir derin sinir ağında geri-yayılım kullanılarak yapılan eğitimde gradyanların kaybolması problemi görülebilmektedir. Gradyanların kaybolması ağın ilk katmanlarındaki parametrelerin eğitimi ve güncellenmesini zorlaştırmakta, ağdaki katman sayısı arttıkça bu problem daha da kötüleşmektedir. Derin sinir ağlarında geri-yayımların amacı, ağ hatasının en aza indirileceği ve elde edilen çıkış değerinin hedeflenen çıkış değerine daha yakın olmasını sağlayacak şekilde ağ ağırlıklarını güncellemektir. Bu ağırlıkların güncellenmesinde ise gradyan azalma yöntemi kullanılmaktadır. Ağ üzerindeki her ağırlığın ne kadar değişeceğini belirleyen gradyanlar, katmanlar boyunca yayıldıkça küçülmektedir. Gradyan hesabında Denklem (2.6) ile verilen Sigmoid aktivasyon fonksiyonunun türevi Denklem (3.12)'deki gibi elde edilmektedir.

$$\Phi'(x) = \frac{1}{1+e^{-x}} \left(1 - \frac{1}{1+e^{-x}}\right) \quad (3.12)$$

Sigmoid fonksiyonu türevinde çıkış  $[0,0,25]$  aralığında değer aldığından, hatalar her katmanda  $[0,0,25]$  aralığında ölçeklenecektir. Bu durum gradyan boyutunun her katmanda küçülerek en üst katmanlarda sıfırlanmasına ve bu katmanların eğitilememesine neden olmaktadır. Derin sinir ağlarının eğitimi etkileyen bu problem ReLu aktivasyon fonksiyonu kullanılarak aşılmaktadır. ReLu aktivasyon fonksiyonunda türev pozitif değerler için 1 olduğundan, girişlerin ölçeklenmesi problemi meydana gelmemektedir.

Veri setlerinde girdi verileri ile çıktı etiketi arasındaki karmaşık ilişkiyi öğrenebilen derin sinir ağları, bunu çok sayıda parametre ile sağlamaktadır. Çok sayıda parametrenin eğitilmesi ise büyük veri setleri ile mümkün olmaktadır. Bu nedenle eğitim verilerinin boyutu derin sinir ağlarının başarımını etkileyen önemli bir faktördür. Bunun yanında eğitim verilerinin kalitesi de başarımı etkileyen ikinci bir kriterdir. İyi etiketlenmemiş ya da gürültülü veri setleri ile yapılan eğitimde yakınsama için daha fazla veriye ihtiyaç duyulmaktadır.

Bir makine öğrenmesi modelinin eğitim verilerinde olmayan yeni veriler üzerinde de iyi başarımla elde etme yeteneği olarak tanımlanan genelleme, iyi bir derin öğrenme modelinin en önemli amacıdır. Derin öğrenme modellerinin eğitiminde genelleme başarımını olumsuz olarak etkileyen aşırı uyum ve yetersiz uyum problemleri ile karşılaşılabilir. Aşırı uyum, modelin eğitim verilerinde çok iyi başarımla göstermesi fakat eğitim dışında kalan verilere genelleştirilememesidir. Model düşük eğitim hatası elde ederken, düşük test hatası elde edememektedir. Bu durumda, model öğrenme yerine verileri ezberlemektedir. Bir modelin uygun şekilde eğitilmemesi durumunda ortaya çıkan yetersiz uyum problemi ise modelin eğitim verisi

üzerinde dahi başarımı düşüktür. Derin öğrenmede daha sık karşılaşılan aşırı uyum probleminin sebebi genellikle eğitim veri setinin ağda eğitilecek çok sayıda ağırlık için yeterli büyüklükte olmamasıdır. Derin öğrenme modellerinde aşırı uyumu sınırlamak üzere kullanılan birkaç yöntem bulunmaktadır. Bu yöntemler; daha fazla örnek elde ederek ya da mevcut örneklerle ölçekleme ve çevirme gibi işlemler uygulayarak eğitim veri setini büyütme, derin sinir ağını sadeleştirme, kayıp fonksiyona L1 ve L2 düzenleme gibi ceza terimleri ekleme, derin sinir ağlarına seyreltme (dropout) uygulama olarak sıralanabilmektedir.

### 3.3.3. Ağırlık ilklendirme

Bir evrişimli sinir ağının performansı, optimizasyonda gradyan temelli yöntemler kullanıldığından dolayı başlangıç durumuna oldukça bağlıdır. Çözüm uzayında birden fazla yerel minimum olduğunda, konveks olmayan bir çözüm farklı optimal noktalara yakınsayabilir. Bu nedenle bir evrişimli sinir ağına uygulanan ilklendirme yönteminin ağ performansı üzerinde önemli bir etkisi olacaktır.

Ağırlık ilklendirmenin en basit yolu sıfır değerli ağırlıklardan başlayarak bu ağırlıkları eğitim sırasında güncellemektir. Fakat tüm ağırlıklar sıfır olarak ilklendirildiğine, tüm ağırlıklar için kayıp fonksiyonuna göre türev aynı olmaktadır. Bu ardışık iterasyonlar sonunda tüm ağırlıkların aynı değere sahip olmasına yol açacaktır.

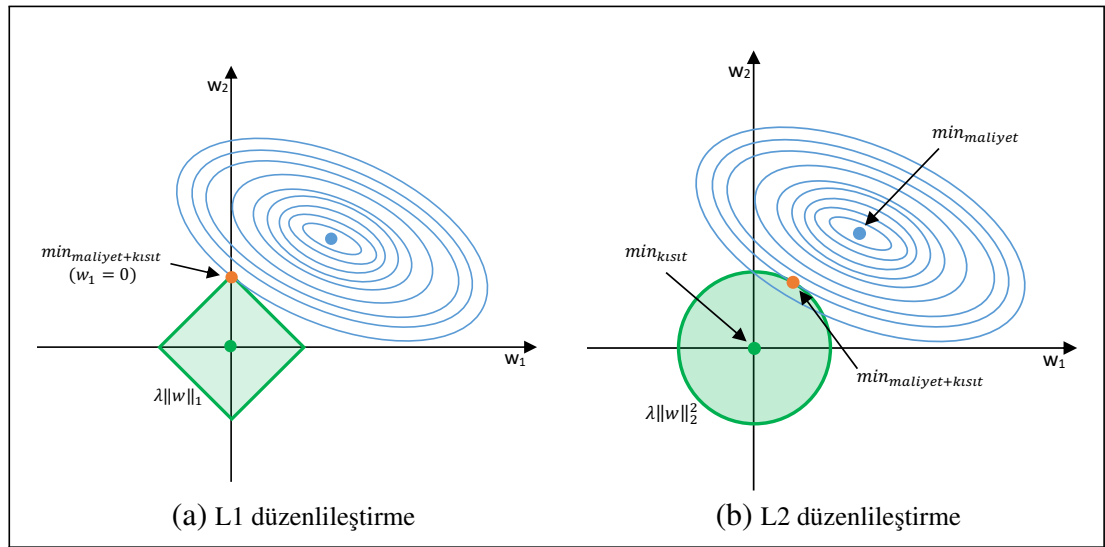
Ağın ağırlıklarının benzersiz olarak ilklendirilmesi için normal dağılıma sahip rastgele değerlerin kullanılması diğer bir yaklaşımdır. Ancak normal dağılıma sahip rastgele değerler ile yapılan ilklendirmede, gradyanların kaybolması ya da aşırı büyümesi gibi problemler ortaya çıkabilmektedir. Xavier ve Yoshua yaptıkları çalışmada, gradyan doygunluk problemiyle başa çıkmak ve sinir ağlarının performansını iyileştirmek için Glorot ilklendirme yöntemini önermiştir [83]. Eğer bir sinir ağında ağırlıklar çok küçük ilklendirilirse hata sinyali ilk katmanlarda yok olmakta, ağırlıklar büyük ilklendirilirse sinyal her katmanda daha da büyüyerek çözümü yerel minimuma götürmektedir. Glorot ilklendirmede her katmandaki ağırlıklar, sinyalin ağ katmanları boyunca kabul edilebilir seviye kalmasına sağlayacak şekilde seçilmektedir. Bunun için her katmandaki ağırlıklar sıfır ortalama ve Eşitlik (3.13)'de verilen  $\text{var}(w)$  varyansına sahip rastsal sayılarla ilklendirilmektedir. Burada  $n_{in}$  ilklendirilen katmanın girişine bağlı hücre sayısı,  $n_{out}$  ilklendirilen katmanın çıkışta bağlandığı hücre sayısıdır.

$$\text{var}(w) = \frac{2}{n_{in} + n_{out}} \quad (3.13)$$

### 3.3.4. Düzenleştirme

Evrişimli sinir ağlarının eğitilmesi sırasında öğrenme verisine aşırı uyumunu sınırlandırmak amacıyla düzenleştirme metotları uygulanmaktadır. Düzenleştirme, öğrenme hatasını azaltma amacı gütmeyen genelleme hatasını azaltmayı amaçlayan, öğrenme algoritmasına yapılan her türlü değişiklik olarak tanımlanmaktadır [84]. Evrişimli sinir ağlarının aşırı uyumunu sınırlandırma üzere birçok düzenleştirme yöntemi önerilmiştir. Bazı yöntemlerde öğrenme modelinde parametreleri sınırlayan veya sıfırlayan kısıtlamalar eklenmektedir. Maksimum norm kısıtlaması yöntemi ile her hücrenin alabileceği ağırlık için bir üst sınır belirlenmekte, seyreltme (dropout) yöntemi ile rastgele seçilen hücreler için çıkış ağırlıkları sıfırlanmaktadır. L2 ve L1 ağırlık zayıflatma kayıp fonksiyonuna ekstra terim eklenmesi ile öğrenme aşamasında düzenliştirmeye neden olmaktadır.

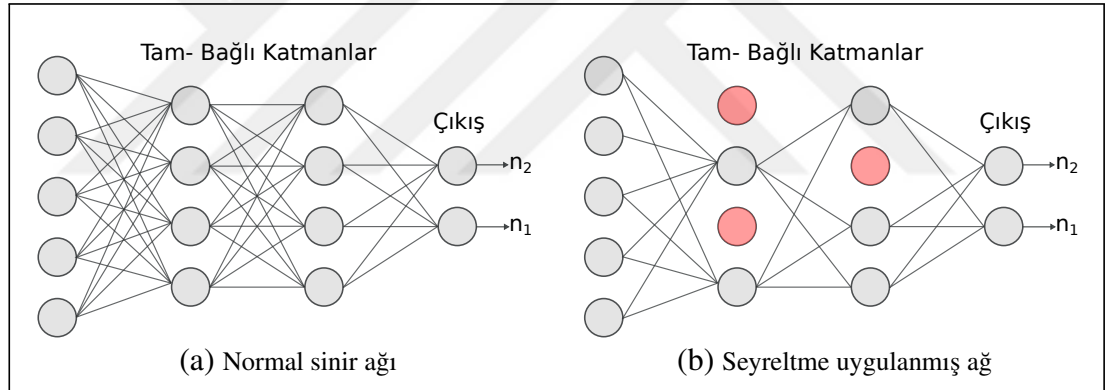
L2 düzenliştirme yönteminde ağ üzerindeki ağırlıkların karelerinin toplamı, kayıp fonksiyonuna belirli oranda ağırlıklandırılarak eklenmektedir. Ağ üzerindeki her  $w$  ağırlığı için kayıp fonksiyonu,  $\frac{1}{2}\lambda w^2$  terimi eklenerek güncellenmektedir. Düzenliştirme gücünü  $\lambda$  katsayısı belirlemektedir. L1 düzenliştirme yönteminde ise ağ üzerindeki ağırlıkların kendisi kayıp fonksiyonuna  $\lambda$  ile ağırlıklandırılarak eklenmektedir. L1 düzenliştirme metodu optimizasyon sırasında bazı öznelik boyutlarının sıfırlanmasına yol açabilmektedir. Belirleyici olmayan özneliklerin etkisinin ortadan kaldırılmasını gerektiren uygulamalarda L1 düzenliştirme metodu daha kullanışlıdır. L1 ve L2 düzenliştirme yöntemlerinin 2 boyutlu öznelik uzayında gösterimi Şekil 3.5.'de verilmektedir.



Şekil 3.5. L1 ve L2 düzenliştirme metotlarının 2 boyutlu öznelik uzayında gösterimi

### 3.3.5. Ağ seyreltme

Evrişimli sinir ağlarında karmaşık öznelikleri ortaya çıkaran evrişim ve birleştirme katmanlarını, bu öznelikleler ile sınıflandırmanın gerçekleştirildiği tam-bağlı katmanlar takip etmektedir. Tam-bağlı katmanlardaki düğümler önceki katmandaki tüm düğümlere bağlı olduğundan aşırı uyum göstermeye yatkın özelliğindedir. Hinton ve arkadaşları aşırı uyum probleminin üstesinden gelmek amacıyla, eğitim sırasında tam-bağlı katmanlardaki bazı düğümlerin bağlantıları ile birlikte, rastgele olarak ağdan çıkarıldığı bir seyreltme (dropout) işlemini önermiştir [71]. Seyreltme uygulanan düğüm için Şekil (3.6.)’de gösterildiği gibi önceki ve sonraki katman bağlantıları kaldırılarak eğitim gerçekleştirilmektedir. Eğitimin her iterasyonunda seyreltme işlemi rastgele olarak farklı düğümlere gerçekleştirildiğinden, kaldırılan bağlantılar mevcut ağırlıkları ile bir sonraki iterasyon için ağa geri yerleştirilmektedir. Test işleminde ise herhangi bir seyreltme işlemi uygulanmamaktadır. Seyreltme işlemi aşırı uyumu büyük ölçüde azaltmakta ve modelin genelleştirilmesini iyileştirmektedir.

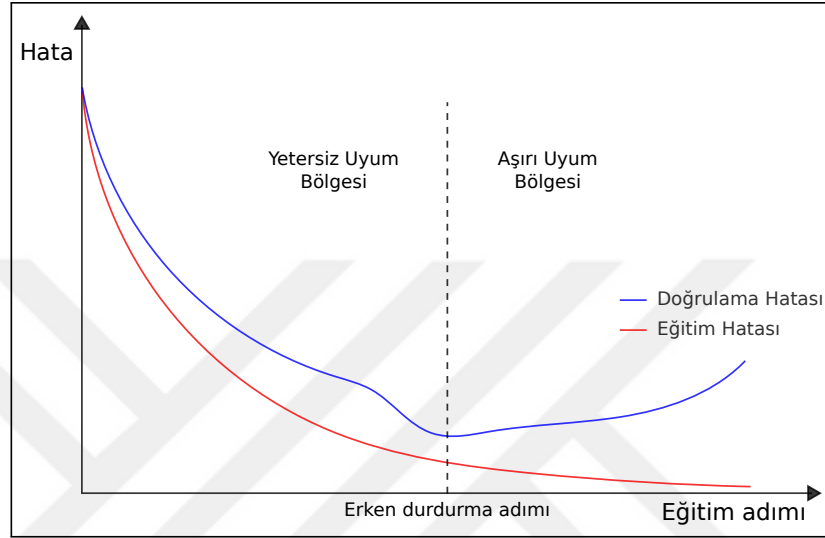


Şekil 3.6. Sinir ağında tam-bağlı katmanlara uygulanan seyreltme işlemi

### 3.3.6. Erken durdurma

Yapay sinir ağlarının gradyan azalma yöntemleri ile eğitiminde, kayıp fonksiyonu eğitim verileri ile optimize edilmektedir. Eğitimde belirli bir adımdan sonra yapay sinir ağı eğitim verilerine aşırı uyum sağlamaya başlamakta, eğitimde kullanılmayan örnekler için genelleştiremez duruma gelmektedir. Bu problemin önüne erken durdurma kullanılarak geçilebilir. Bu yöntemde eğitim verilerinin bir kısmı eğitim dışında bırakılmakta sadece modelin doğrulama hatasını izlemek amacıyla kullanılmaktadır. Eğitim adımları boyunca bir noktadan itibaren eğitim hatası azalmaya devam ederken, doğrulama hatası artmaya başlamaktadır. Erken durdurma ile daha fazla eğitimin Şekil 3.7.’de gösterildiği gibi aşırı uyuma yol açmaya başladığı adımda eğitim sonlandırılmaktadır. Eğitimin sonlandırılacağı adım tespit edildiğinde

ağın eğitiminde birkaç adım ilerlenmiş bulunmaktadır. Ağı tespit edilen adıma geri döndürebilmek amacıyla ağın geçmiş parametrelerinin saklanması, tüm eğitimi tekrarlama zorunluluğunu ortadan kaldırmaktadır. Erken durmanın en önemli avantajı, eğitim prosedürünü önemli ölçüde değiştirmeden sinir ağı eğitimine kolayca eklenebilmesidir. Bu nedenle erken durdurma, diğer düzenleme yöntemleri ile birlikte ve göreceli olarak basit bir şekilde, sıklıkla bir arada kullanılmaktadır.




Şekil 3.7. Erken durdurma ile doğrulama hatasının artmaya başladığı adımda eğitimin sonlandırılması

## 4. MATERYAL VE YÖNTEM

### 4.1. Veri Seti

Tez çalışmasında geliştirilen nöbet tahmin modellerinin başarımını ölçmede kullanılacak veri setinin bazı kriterleri karşılaması gerekmektedir. Bunlardan ilki önerilen yaklaşımdan dolayı veri setinin kafa derisi EEG kayıtlarından oluşması zorunluluğudur. Bununla beraber tahmin modellerinde yetersiz eğitimin önüne geçmek için, kullanılacak veri setindeki EEG kayıtları yeterli uzunlukta olmalı ve yeterli sayıda epileptik nöbeti içermelidir. Bu nedenle tez çalışmasındaki modellerin eğitiminde açık erişilebilir en büyük kaynak olan Boston Çocuk Hastanesi MIT Physionet sEEG veri seti [85, 86] kullanılmıştır.


MIT Physionet sEEG veri seti 23 pediatrik hastanın 844 saatlik sürekli EEG kayıtlarından oluşmaktadır. Bu EEG kayıtları boyunca 182 epilepsi nöbeti meydana gelmiştir. Kafa derisinde elektrot yerleşimleri uluslararası 10-20 sistemi ile yapılmış ve kayıtlar bipolar olarak gerçekleştirilmiştir. Kayıtların çoğunda 22 elektrot kullanılarak toplanan sinyaller 256 Hz ile örneklenmiştir. Kayıtlar genellikle 1 veya 2 saatlik dosyalar halinde olup, dosyalar arasında ortalama 10 saniyelik boşluklar bulunmaktadır. Veri setinde nöbet başlangıç ve bitiş zamanları uzman kişiler tarafından etiketlenmiştir.



Şekil 4.1. Nöbet tahmin aralığı ve nöbet gerçekleşme periyodu tanımlamaları

Veri seti değerlendirmeye alınmadan önce epileptik evre zamanlamaları için bazı kısıt ve tanımlamaların yapılması gerekmektedir. Zhang ve arkadaşları yaptıkları çalışmada iktal evreden önceki 60 dakikalık kaydı preiktal evre olarak tanımlamıştır. İktal evre 3 dakika olarak kabul edilmiş, iktal evreden sonraki 30 dakikalık kayıt postiktal evre olarak alınmıştır [14]. Truong ve arkadaşları yaptıkları çalışmada iktal evreden 4 saat öncesi ve 4 saat sonrasını interiktal evre olarak değerlendirmiştir. Nöbet tahmininde Şekil 4.1.'de verilen SOP (Seizure Occurrence Period) ve SPH

(Seizure Prediction Horizon) tanımlamalarına göre hareket etmiştir [12]. SPH nöbet tahminin yapıldığı aralık olarak tanımlanmaktadır. Bu tanıma göre doğru tahmin için nöbetin SPH'dan sonra gelen, SOP zaman aralığında gerçekleşmesi gerekmektedir. Benzer şekilde SPH içerisinde alınan alarmlardan sonra, SOP zaman aralığında nöbet gerçekleşmezse bu yanlış tahmin olarak değerlendirilmektedir. Truong ve arkadaşlarının yaptıkları çalışmada SPH 5 dakika, SOP 30 dakika olarak kabul edilmiştir. Park ve arkadaşları yaptıkları çalışmada iktal evrenin 1 saat öncesi ve 1 saat sonrasını interiktal evre olarak tanımlamıştır. İktal evreden önceki yarım saatlik periyot preiktal evre olarak belirlenmiş, preiktal evre ile interiktal evre arasındaki yarım saatlik süre ve iktal evre sonrası 1 saatlik süre değerlendirme dışı bırakılmıştır [20].



Şekil 4.2. Tanımlanan epileptik evre zamanlamaları

Bu tez çalışmasında epileptik evre zamanlamaları Şekil 4.2.'de verildiği gibi tanımlanmıştır. Buna göre nöbet başlangıcından önceki 30 dakikalık periyot preiktal evre olarak kabul edilmiştir. Nöbet bitiminden sonraki 10 dakikalık periyot ise postiktal evre olarak tanımlanmıştır. Preiktal evre ile nöbet arasındaki 1 dakikalık zaman dilimi müdahale süresi olarak kabul edilerek eğitim verilerinin dışında tutulmuştur. Nöbet başlangıcından en az bir saat öncesi ve nöbet bitiminden bir saat sonrası interiktal evre olarak belirlenmiştir. Birden fazla nöbetin birbirine yakın olduğu durumlarda, yeterli preiktal veri yoksa takip eden nöbet değerlendirilmemektedir. Minimum preiktal evre uzunluğu 15 dakika olarak belirlenmiştir. Veri setinde, EEG kayıtları boyunca en az üç nöbet geçiren ve en az üç saat interiktal evre bulunan hastalar değerlendirmeye alınmıştır. Bunun nedeni, üç preiktal veya interiktal evreden daha azı kullanılarak yapılan çapraz doğrulama ile eğitimde aşırı uyum probleminin ortaya çıkmasıdır. Tüm bu tanım ve kısıtlamalar dahilinde Tablo 4.1.'de verilen 16 hasta için 77 nöbet ve 466 saatlik interiktal veri değerlendirilmiştir.

#### 4.2. Öznitelik Çıkarımı

EEG zaman serilerinden öznitelik çıkarmada spektral bant gücü, istatistiksel moment ve Hjorth parametreleri ölçümleri kullanılmıştır. Literatürde epileptik nöbet tahmininde kullanılan bu ölçüm yöntemleri, hesaplama maliyetlerinin düşük olması ve yapılan çalışmalarda iyi sonuç vermeleri nedeniyle tercih edilmiştir. Bu bağlamda

Tablo 4.1. Tez çalışmasında test edilen MIT Physionet sEEG veri setindeki hastalar için interiktal veri uzunlukları ve nöbet sayıları.

	İnteriktal Veri Uzunluğu (Saat)	Nöbet Sayısı
Hasta 1	28,6	7
Hasta 2	30,2	3
Hasta 3	30,4	6
Hasta 5	29,8	5
Hasta 7	61,8	3
Hasta 9	61	4
Hasta 10	36,9	7
Hasta 13	22,3	5
Hasta 14	16,4	6
Hasta 16	9,8	5
Hasta 17	16,1	3
Hasta 18	29,9	5
Hasta 19	27	3
Hasta 20	20,4	6
Hasta 21	28,3	4
Hasta 23	17,2	5
Toplam	466,1	77

kayar pencere analizi ile her EEG kanalı için bağımsız olarak öznitelikler çıkarılmıştır. Kayar pencere analizinde giriş işareti sabit uzunluklu parçalara bölünerek bu parçalardan elde edilen ölçümlerle öznitelikler hesaplanmaktadır. Tez çalışmasında pencere süresi 4 saniye olarak belirlenmiştir. Pencereleme ile meydana gelecek spektral sızıntının önüne geçmek amacıyla Hanning pencere fonksiyonu uygulanmıştır. Ayrıca pencere kaydırma %50 örtüşmeli olarak gerçekleştirildiğinden her 2 saniyede bir öznitelik kümesi oluşturulmaktadır.

Klasik EEG analizinde, EEG sinyalleri temel olarak 5 frekans bandına ayrılmaktadır. Bunlar; delta ' $\delta$ ' (0,5-4 Hz), teta ' $\theta$ ' (4-8 Hz), alfa ' $\alpha$ ' (8-13 Hz), beta ' $\beta$ ' (13-30 Hz) ve gama ' $\gamma$ ' (30 Hz ve yukarısı)'dır. Yüksek frekanslı alt bantların epileptik nöbet tahmininde etkili olduğu göz önünde bulundurularak [48], gama bandı  $\gamma - 1$  (30-50 Hz),  $\gamma - 2$  (50-75 Hz),  $\gamma - 3$  (75-100 Hz),  $\gamma - 4$  (100-128 Hz) olmak üzere dört alt banda ayrılmıştır. 57-63 Hz ve 117-123 Hz frekans aralıkları, 60 Hz'deki güç hattı gürültüsünü ve harmonikleri ortadan kaldırmak için spektral güç hesaplamasından çıkarılmıştır.

İstatistiksel momentler zaman serilerinde genliğin dağılımı ve şekli hakkında bilgi vermektedir. Yüksek genlikli nöbet işaretlerinde erken nöbet tespitinde istatistiksel



momentlerin yararlı olabileceği belirtilmiştir [2]. Bu tez çalışmasında EEG zaman serilerinin zaman bölgesi özniteliklerini çıkarmak amacıyla ilk dört istatistiksel moment olan, ortalama, varyans, çarpıklık ve basıklık ölçümleri kullanılmıştır.

Hjorth, işaretlerin istatistiksel özelliklerini ortaya koyan, aktivite, mobilite ve karmaşıklık olmak üzere üç zaman alanı parametresi tanımlamıştır [51]. Yapılan çalışmalarda preiktal evrede EEG işaretinin mobilitesinde ve karmaşıklığında önemli bir artış olduğu sonucuna ulaşılmıştır [19]. Bu nedenle tez çalışmasında EEG sinyallerinin zaman bölgesi özniteliklerini çıkarmak için mobilite ve karmaşıklık ölçümleri de kullanılmıştır.

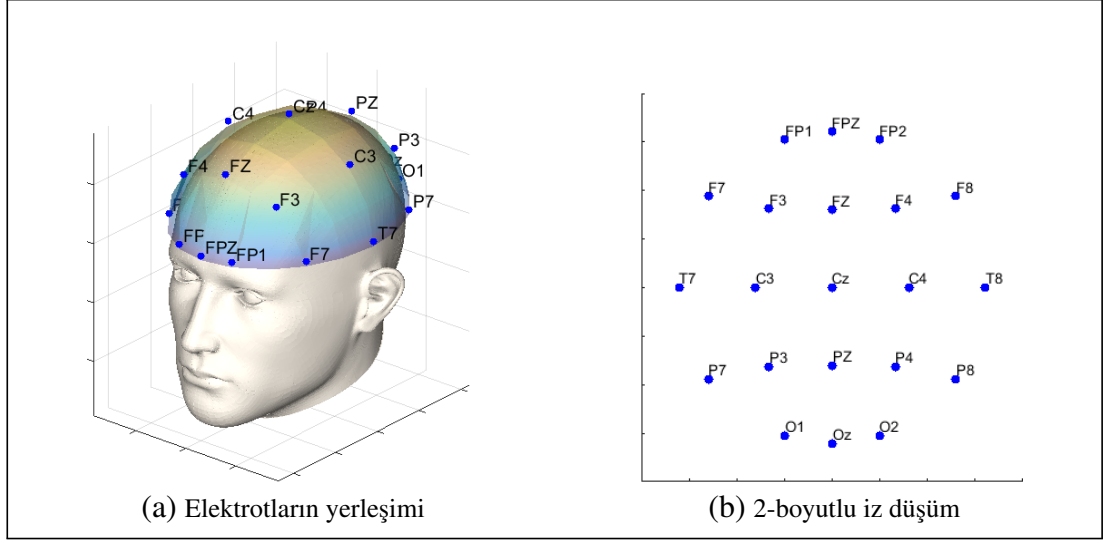
Bu tez çalışmasında;

- $\delta$  (0,5–4 Hz),  $\theta$  (4–8 Hz),  $\alpha$  (8–13 Hz),  $\beta$  (13–30 Hz),  $\gamma - 1$  (30–50 Hz),  $\gamma - 2$  (50–75 Hz),  $\gamma - 3$  (75–100 Hz),  $\gamma - 4$  (100–128 Hz) olmak üzere 8 bant için spektral güç,
- ortalama, varyans, çarpıklık ve basıklık olmak üzere 4 istatistiksel moment,
- mobilite ve karmaşıklık olmak üzere 2 Hjorth parametresi öznitelik olarak çıkarılmaktadır.

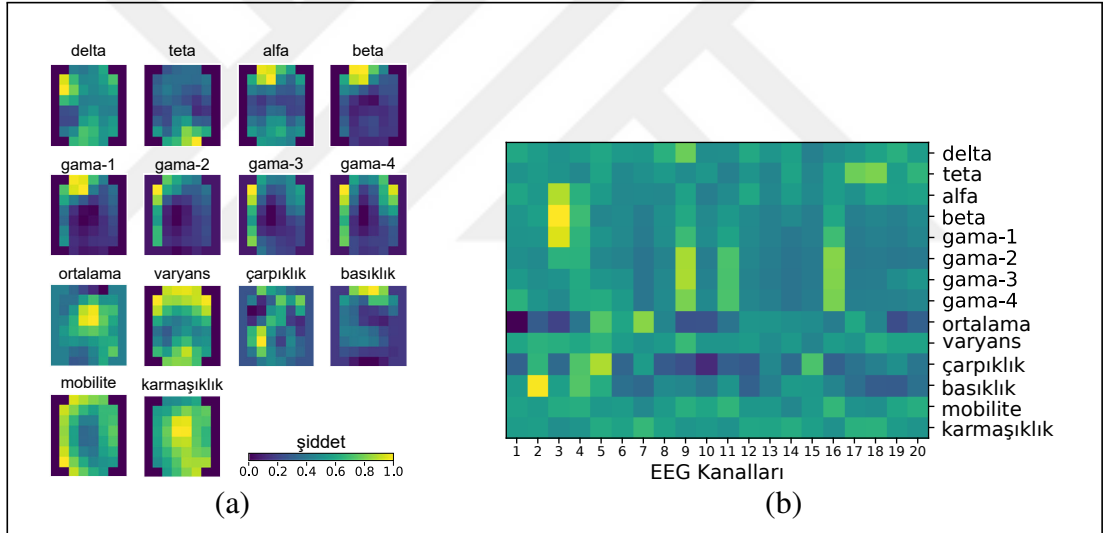
#### **4.3. EEG Zaman Serilerinden Görüntü Oluşturma**

EEG veri analizinde bir öznitelik vektörü oluştururken, elektrot yerleşimine bakılmaksızın verilerin değerlendirilmesi uzamsal ilişkinin göz ardı edilmesine neden olmaktadır. Bashivan ve arkadaşları çalışmalarında EEG verilerinde uzamsal yapının korunması için özniteliklerin 2-boyutlu bir görüntüye dönüştürülmesini, spektral boyutun temsili için ise çoklu renk kanallarının kullanımını önermiştir [87]. EEG elektrotları, kafa derisi üzerinde 3-boyutlu bir uzayda yerleştirilmektedir. 3-boyutlu EEG aktivite haritalarından 2-boyutlu EEG görüntü serilerinin elde edilebilmesi için, 3-boyutlu uzaydan 2-boyutlu yüzeye iz düşüm yapılması gerekmektedir. Bu amaçla, iz düşüm sırasında bitişik elektrotlar arasındaki bağıl mesafeyi koruyabilmek için, haritacılık uygulamalarında kullanılan bir polar iz düşüm yöntemi olan Azimutal Eşuzaklıklı İzdüşüm (Azimuthal Equidistant Projection - AEP) [88] kullanılmıştır. EEG elektrot yerleşimlerinin topoloji-korumalı iz düşümü Şekil 4.3.'de görülmektedir. Bu yöntemde bir dezavantaj olarak, tüm elektrot çiftleri arasındaki nispi mesafeler tam olarak korunmamaktadır, çünkü projeksiyon sadece referans noktası ile her bir noktanın bağıl mesafesini korumayı amaçlar.

Bir 2-boyutlu yüzeye iz düşürülen EEG öznitelikleri, önerilen öğrenme modellerinde kullanım için görüntü formatına dönüştürülmektedir. Bu dönüşümde elde edilen



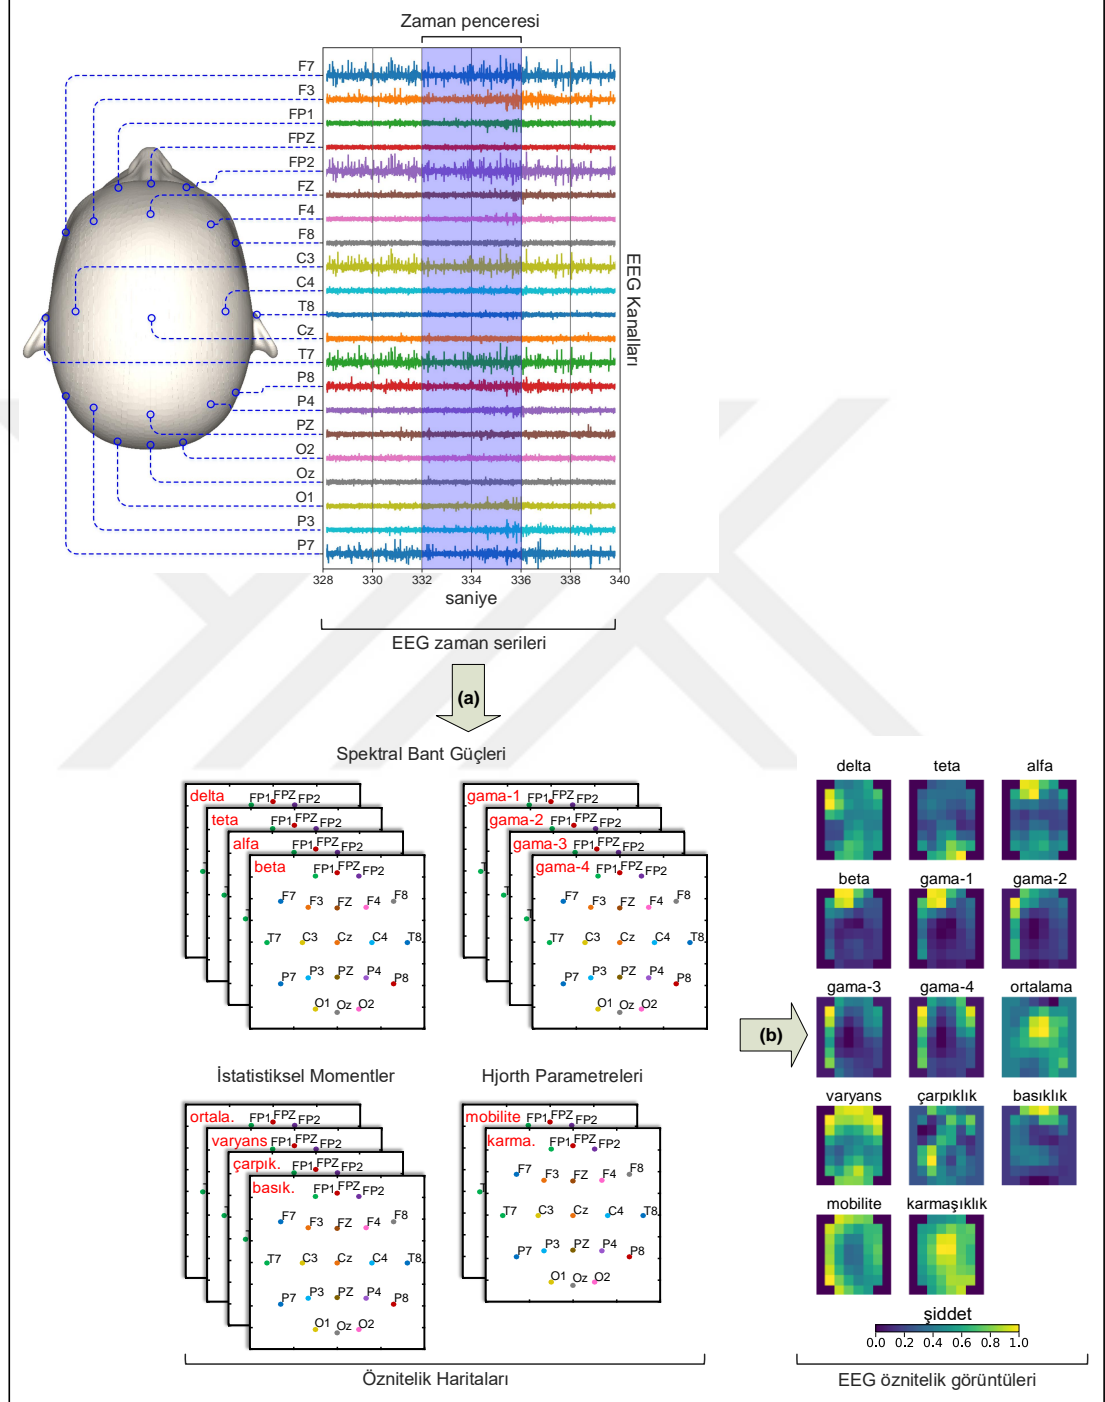
Şekil 4.3. EEG elektrot yerleşimlerinin topoloji-korumalı iz düşümü. (a) Kafa derisi elektrotlarının 3-boyutlu uzaydaki yerleşimi. (b) Elektrot konumlarının Azimutal Eş Uzaklıklı İz Düşümü



Şekil 4.4. Çok kanallı EEG öznitelikleri kullanılarak farklı metotlarla oluşturulan öznitelik görüntülerinin karşılaştırılması. (a) Topoloji-korumalı 2-boyutlu izdüşümden enterpolasyon ile elde edilen öznitelik görüntüsü, (b) topoloji korunmadan elde edilen öznitelik görüntüsü

görüntünün piksel değerleri, bir Clough-Tocher şeması [89] kullanılarak kübik enterpolasyon ile hesaplanmaktadır. Önerilen CNN modeli için giriş görüntüsü çözünürlüğü  $8 \times 8$  olarak seçilmiştir. Elde edilen görüntü, çıkarılan özniteliklerin beyin korteksi üzerindeki uzamsal dağılımını temsil etmektedir. Çok kanallı EEG öznitelikleri kullanılarak farklı metotlarla oluşturulan öznitelik görüntülerinin karşılaştırılması Şekil 4.4.'de verilmektedir. EEG kanallarının topolojisi korunmadan oluşturulacak bir öznitelik görüntüsünün değerlendirilmesinde evrişimli sinir ağı mimarisi kullanımının bir faydası olmayacaktır. Çünkü evrişim işleminde amaç

komşu pikseller arasındaki örüntüleri ortaya çıkarmaktır. Topolojinin korunmadığı durumlarda bu komşuluk ilişkisi kaybolacaktır. EEG zaman serilerinden EEG öznitelik görüntüleri oluşturma yaklaşımları genel hatları ile Şekil 4.5.'de verilmektedir.




Şekil 4.5. EEG zaman serilerinden EEG öznitelik görüntülerinin oluşturulması. (a) Spektral bant gücü, istatistiksel moment ve Hjorth parametreleri özniteliklerinin elde edilmesi (b) Kübik enterpolasyon ile EEG öznitelik görüntülerinin oluşturulması

#### 4.4. Evrişimli Sinir Ağı

Evrişimli sinir ağları çok katmanlı algılayıcıların bir türevi olarak ortaya çıkmıştır. Çok katmanlı algılayıcılarda tüm giriş düğümleri ve katmanlardaki hücre çıkışları bir sonraki katmandaki tüm hücrelere bağlı iken, evrişimli sinir ağlarında katmanlar arası bağlantı evrişim ile sağlanmaktadır. Bu şekilde, evrişimli sinir ağlarında tüm giriş düğümleri arasındaki ilinti tek bir katmanda değerlendirilmek yerine, evrişim çekirdeği büyüklüğünde olacak şekilde, komşu düğümler arasındaki ilinti katmanlar boyunca değerlendirilir. Bu yüzden evrişimli sinir ağları çok daha fazla katmanlı olarak tasarlanmaktadır. Bilgisayarlı görü uygulamalarında yaygın olarak kullanılan evrişimli sinir ağlarının, epileptik nöbet tahmini için kullanıldığı bazı çalışmalar bulunmaktadır [11, 12, 90].

Bu çalışmada CNN mimarisinin tasarımında sistematik olması nedeniyle VGGNet'i [76] temel alan bir yaklaşım takip edilmiştir. Oxford Visual Geometry grubu tarafından geliştirilen derin bir evrişim ağı olan VGGNet, gruplanmış evrişim ve birleştirme(pooling) katmanlarının art arda eklenmesinden meydana gelmektedir. Her evrişim grubunda bir önceki grubun yarısı kadar evrişim katmanı bulunurken, bir önceki katmanın iki katı kadar evrişim filtresi yer almaktadır. Filtre boyutları  $3 \times 3$  olarak alınmakta, birleştirme katmanında  $2 \times 2$  pencerede maksimum olan değer (max-pooling) bir sonraki katmana aktarılmaktadır.

CNN yapılarında, sığ katmanlar genel öznelikleri ortaya çıkarırken, daha derin katmanlar daha ayrıntılı öznelikleri temsil etmektedir. Daha fazla katman ağın öğrenme ve uyum kapasitesini geliştirirken, model boyutunu ve maliyetini de arttırmaktadır. Çoğu zaman daha fazla katman eklenmesi ağın performansını arttırmamakta, hatta gereğinden fazla sayıda katman ve filtre bulunması, eğitim aşamasında aşırı uyum (overfit) sorununa neden olarak sınıflandırma performansını düşürmektedir. Derin bir CNN yapısının optimum olarak nasıl tasarlanacağı halen çok açık olmamakla birlikte, Cao çalışmasında evrişimli sinir ağlarının optimum tasarımı için öğrenme kapasitesi ve öğrenme gereksinimi olmak üzere iki ölçüt tanımlamıştır [91]. Bu ölçütler, derin evrişimli sinir ağı tasarımını kısıtlı bir optimizasyon problemine dönüştürmektedir. Bu problemdeki amaç, bu iki kısıt dahilinde maksimum ağ derinliğine ulaşmaktır. Bu kısıtlardan ilki olan öğrenme kapasitesi katmanın daha karmaşık örüntüleri öğrenme gücünü ölçmektedir ve her katman için belirli bir değer altına düşmemelidir. Diğer bir kısıt olan öğrenme gereksinimi, bir katmandaki evrişim çekirdeğinin ilk katmandaki giriş görüntüsünün ne kadarını kapsadığını, yani alıcı alan büyüklüğünü ölçmektedir ve evrişimli sinir ağının en son katmanında giriş görüntüsünden büyük olmamalıdır. Şekil 4.6.'de



Şekil 4.6. Öğrenme kapasitesinin temsili gösterimi. (a) Öğrenme kapasitesi yeterlidir. (b) Evrişim çekirdeği boyutu yeterli büyüklükte olmadığından öğrenme kapasitesi yetersiz kalmaktadır

verilen örüntü A, örüntü B ve bunların uzamsal ilişkilerine verilen yanıtlar dikkate alındığında, (a) örneğinde karmaşık A ve B örüntüleri saptanabilirken, (b) örneğinde öğrenme kapasitesi yetersiz kalmaktadır. Katmanın kapasitesini arttırmak için evrişim çekirdeği boyutu arttırabileceği gibi görüntü önceki birleştirme (pooling) katmanında aşağı örneklenebilir. Bir evrişim katmanının öğrenme kapasitesini niceliksel olarak ölçmek amacıyla, filtre boyutunun alıcı alan boyutuna oranı olan bir C değeri Denklem (4.1) ile tanımlanmaktadır. Alıcı alan boyutu, bir katmandaki evrişim filtresinin giriş görüntüsünde ne büyüklükte bir filtreye denk düştüğünü gösterir. Her evrişim katmanında öğrenme kapasitesinin düşmemesi için C değerinin minimum bir t değerinden büyük olması gerekmektedir. Bu değer  $t = 1/6$  olarak kabul edilmiştir. Burada l ilgili evrişim yığınının indeksi, k filtre boyutu,  $a_i$  ilgili evrişim yığını içerisinde yer alan evrişim katmanı sayısını vermektedir. Bir evrişim yığını, bir ya da daha fazla evrişim katmanını takip eden bir birleştirme katmanından oluşmaktadır. Alıcı alan boyutu son evrişim katmanında Denklem (4.2)'de verildiği üzere giriş görüntüsü boyutu z'den büyük olmamalıdır.


$$C = \frac{\text{filtre boyutu}}{\text{alıcı alan boyutu}} = \frac{2^l k}{\sum_{i=1}^l 2^{i-1} (k-1) a_i} \geq t, \quad l = 1, 2, \dots, n \quad (4.1)$$

$$\text{alıcı alan boyutu} = \sum_{i=1}^l 2^{i-1} (k-1) a_i \leq z \quad (4.2)$$

#### 4.4.1. Tek-çerçeve CNN modeli

İlk olarak, öğrenme kapasitesi ve öğrenme gereksinimi kısıtlarına uygun olarak,  $8 \times 8$  piksel giriş görüntüleri için bir tek-çerçeve CNN modeli önerilmiştir. Bu CNN modeli, Şekil 4.7.'da gösterildiği gibi iki evrişim yığını ve üç tam-bağlı katmandan oluşmaktadır. İlk evrişim yığını, iki evrişim ve bir maksimum birleştirme katmanı içerirken, ikinci yığın bir evrişim ve bir maksimum birleştirme katmanından meydana

gelmektedir. İlk yığında 16 olarak belirlenirken filtre sayısı (evrişim çekirdekleri) ikinci yığında iki katına çıkarılmaktadır. Evrişim katmanı çıkışlarında ReLu (Rectified Linear Unit – Doğrultulmuş Doğrusal Birim) aktivasyon fonksiyonu kullanılmaktadır. Evrişim çekirdeği büyüklüğü, tüm evrişim katmanlarında 3x3 olarak alınmış, evrişim adımı 1 piksel olarak belirlenmiştir. Maksimum birleştirme katmanlarında 2x2 kayar pencere ile görüntü boyutları yarı yarıya azaltılarak bir sonraki katmana aktarılmaktadır. İlk iki tam bağlı katman 128 hücreden oluşurken, sonuncusu çıkış katmanı olarak 1 hücre içermektedir. İlk iki tam-bağlı katmanda, CNN modelinin eğitimi aşamasında herhangi bir örnek lehine aşırı öğrenmenin önüne geçmek amacıyla, %50 oranında rastgele seyreltme (dropout) işlemi uygulanmaktadır. Bu katmanların çıkışlarında ReLu aktivasyon fonksiyonu uygulanmaktadır. Çıkış katmanında sigmoid aktivasyon fonksiyonunun kullanılmasıyla, 0 ile 1 arasında bir sınıflandırma sonucu elde edilmektedir.




Şekil 4.7. Tek-çerçeve CNN modeli

#### 4.4.2. Çok-çerçeve CNN modeli

Araştırmalar, nöbetlerin epileptik bir ağda zamansal ve uzamsal gelişen süreçlerin bir sonucu olarak ortaya çıktığını göstermektedir [1]. Tek-çerçeve CNN modeli uzamsal alanda çalıştığından, sadece EEG kanalları arasındaki ilinti değerlendirilmektedir. Hem zaman pencereleri hem de EEG kanalları arasındaki ilintiyi değerlendirmek amacıyla, bir çok-çerçeve 3B (3 Boyutlu) CNN modeli önerilmiştir. Beyin aktivitesindeki zamansal ilintiyi değerlendirmek amacıyla, ardışık 16 zaman penceresinden elde edilen öznelik görüntü dizisi 3B CNN modeline giriş olarak verilmektedir. Tek-çerçeve CNN modelinden farklı olarak, 3B CNN modelinde, Şekil 2 4.8.'de gösterildiği gibi üç evrişim yığını bulunmaktadır. İlk evrişim yığın, bir evrişim ve bir maksimum birleştirme katmanı içermektedir. Diğer evrişim yığınlarının yapısı tek-çerçeve CNN modeliyle aynıdır. İlk evrişim yığnında filtre büyüklüğü 3x1x1 olarak alınarak sadece zaman pencereleri arasındaki ilinti değerlendirilmektedir. Bu evrişim yığnındaki evrişim katmanında 8 filtre

bulunmaktadır. Maksimum birleştirme katmanında ise  $2 \times 1 \times 1$  kayar pencere kullanılarak görüntü boyutu  $8 \times 8 \times 8$  piksele düşürülür. Diğer yığınlarda, filtre ve maksimum birleştirme penceresi boyutları, sırasıyla  $3 \times 3 \times 3$  ve  $2 \times 2 \times 2$  olarak belirlenmiştir. 3B CNN modelinde, ilk iki tam bağlı katmandaki hücre sayısı  $256^2$ 'ya yükseltilmiştir.



Şekil 4.8. Çok-çerçeve CNN modeli

#### 4.5. Eğitim

Bu tez çalışmasına hasta-tabanlı bir nöbet tahmin yaklaşımı önerilmiş, oluşturulan modellerde eğitim hastaya özgü olarak gerçekleştirilmiştir. Modellerin doğrulamasında birisi-dışarıda (leave-one-out) çapraz doğrulama kullanılmıştır. Oluşturulan evrişimli sinir ağlarında Glorot ilklendirme ile ağırlık ilklendirilmesi yapılmış, eğitim aşamasında öğrenme verisine aşırı uyumu sınırlandırmak amacıyla tam bağlı katmanlarda %50 oranında rastgele seyreltme uygulanmıştır. Ayrıca, kayıp değer fonksiyonuna ekstra terim eklenmesi ile öğrenme aşamasında düzenlemeye neden olan, L1 ve L2 ağırlık zayıflatma yöntemleri kullanılmıştır. Eğitimde modellerin yakınsaması, model parametrelerinin çapraz-entropi kayıp fonksiyonu kullanılarak optimize edilmesiyle sağlanmıştır. Optimizasyonda daha hızlı yakınsama oranına sahip olması nedeniyle Adam algoritması tercih edilmiştir.

Eğitim aşamasında daha fazla iterasyon, eğitimin doğruluğunu arttırsa da, modelin eğitim verilerine aşırı uyumuna yol açmaktadır. Oluşturulan evrişimli sinir ağı modellerinde aşırı uyumu önlemek amacıyla erken durdurma yöntemi kullanılmıştır. Bu yöntemde, doğrulama setindeki hata artmaya başladığında eğitim durdurulur. Bu amaçla geçmiş iterasyonlardaki ağırlıklar saklanır ve doğrulama hataları izlenir. Doğrulama hatasının artmaya başladığı tespit edildiğinde, en düşük doğrulama hatasının elde edildiği iterasyondaki ağırlıkları geri yüklenir.

Öğrenme algoritmaları dengeli sınıf dağılımlarına veya eşit yanlı sınıflandırma maliyetlerine uygun olarak tasarlanmaktadır. Çalışmada tanımlanan epileptik evre uzunlukları, preiktal evre ile interiktal evre arasında veri büyüklüğü açısından bir

dengelesizliğe neden olmaktadır. Bunun üstesinden gelmek için, eğitim aşamasında interiktal verilere rastgele seçim uygulanarak eğitimde kullanılan preiktal ve interiktal verilerin oranları eşitlenmiştir.

Sınıflandırıcı başarısının sınanması amacıyla veri setinin parçalara ayrılması ve her çevrimde farklı eğitim ve test kümeleri oluşturularak değerlendirilmesi çapraz doğrulama olarak adlandırılmaktadır. Epileptik nöbet tahmininde, literatürde sınıflandırma performansının elde edilmesinde sıklıkla kullanılan k-katlamalı çapraz doğrulama yerine, birisi-dışarıda (leave-one-out) çapraz doğrulamaların kullanılması daha uygundur. Bunun nedeni birisi-dışarıda çapraz doğrulamada, k-katlamalı çapraz doğrulamadan farklı olarak, bir nöbete ilişkin tüm preiktal ve buna bağlı interiktal verinin dışarıda bırakılarak eğitimin gerçekleştirilmesidir. Bu durum test performansının gerçek koşullara daha yakın olmasını sağlamaktadır.

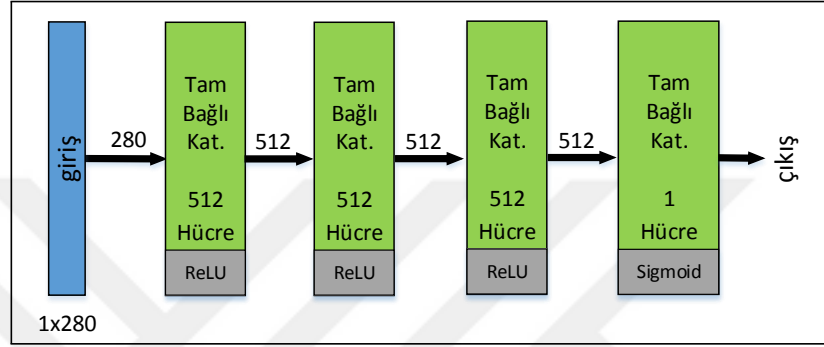
Birisi-dışarıda çapraz doğrulama yönteminde, bir hasta veri seti  $n$  nöbet ve  $t$  saat uzunluğunda interiktal kayıt içeriyorsa, interiktal kayıtların tümü  $n$  parçaya bölünür. Bu interiktal parçaların her biri yaklaşık olarak  $t/n$  saat uzunluktadır ve preiktal kayıtlardan biri ile rastgele eşleştirilir. İlgili hasta veri setinde  $n$  nöbet bulunduğu için dış çevrim  $n$  kez tekrarlanır. Her dış çevrimde bu interiktal-preiktal çiftlerinden biri test için ayrılırken, kalan  $n - 1$  çift eğitim aşamasında değerlendirilir. Bir interiktal-preiktal çift için gerçekleştirilen iç çevrimlerde eğitim için ayrılan  $n - 1$  interiktal-preiktal çifti, 5 parçaya ayrılarak rastgele seçilen verilerin %80'i ile model eğitilirken, geriye kalan %20'si aşırı uyumun önüne geçmek amacıyla doğrulamada kullanılır. Her eğitim aşamasının sonunda, test için ayrılmış interiktal - preiktal çift ile model test edilir. Bu işlem her interiktal - preiktal çifti için 5 kez tekrarlanarak, test sonucu elde edilen değerlerin ortalamaları, standart sapma değerleri ile birlikte tahmin sonuçları olarak verilir.

Test aşamasında interiktal ve preiktal evreler için elde edilen tahmin sonuçları birleştirilerek ilgili hastanın tüm EEG kaydı için bir tahmin grafiği oluşturulmaktadır. Bu grafikte her 2 saniye için değeri 0 ile 1 arasında değişen bir tahmin sonucu bulunmakta, belirlenen eşik seviyesinin üstü nöbet alarmı olarak tanımlanmaktadır. SPH süresi içerisinde alınan bir alarmdan sonra, SOP içerisinde nöbetin gerçekleşmesi durumunda bu alarm doğru tahmin olarak kabul edilirken, bu zaman dilimi içerisinde nöbet gerçekleşmezse alarm yanlış pozitif olarak sınıflandırılmaktadır. Bu çalışmada SPH süresi 1 dakika, SOP ise 30 dakika olarak tanımlanmaktadır. Kısa zamanlı periyotlarda ardı ardına gelen alarmlar yanlış pozitif oranının artmasına neden olabilmektedir. Bu nedenle, sistem tetiklendikten sonra takip eden alarmların yok sayıldığı bir refrakter süre tanımlanmıştır. Bu çalışmada



refrakter süre, SOP uzunluğuyla paralel olarak, 30 dakika olarak belirlenmiştir. Ayrıca tahmin sonuçlarındaki yüksek frekanslı değişiklikler 1 dakikalık nedensel kayar ortalama ile filtrelenmektedir.

Oluşturulan modellerin tahmin performanslarını karşılaştırmak amacıyla, bir çok-katmanlı algılayıcı (MLP) modeli oluşturulmuştur. Bu model 512 hücreli 3 gizli katman ve bir çıkış katmanından oluşmaktadır. Öğrenme verisine aşırı uyumun önüne geçmek için her gizli katmana %50 oranında rastgele seyreltme uygulanmaktadır.




Şekil 4.9. Çok-katmanlı algılayıcı modeli

Bu tez çalışmasında evrişimli sinir ağları ve çok-katmanlı algılayıcı modelleri, Lasagne 0.2 [92] ve Theano 1.0 [93] kütüphaneleri kullanılarak Python 2.7 dili ile gerçekleştirilmiştir. Theano, Montreal Üniversitesi MILA grubu tarafından geliştirilen, çok boyutlu matematiksel ifadeleri etkili bir şekilde tanımlamayı, optimize etmeyi ve hesaplamayı sağlayan bir Python kütüphanesidir. Parallellleştirilebilir işlerde grafik kartı ile hız artışı sağlayabilmekte ve verimli bir şekilde sembolik işlemler yapabilmektedir. Lasagne ise Theano için geliştirilen bir uygulama arayüzüdür. Eğitim işlemi NVIDIA GTX 1060 grafik kartında çalışacak şekilde yapılandırılmıştır.

#### 4.6. Kritik Bölge Isı Haritalarının Oluşturulması

Kritik bölge ısı haritası, görüntüdeki bölgelerin CNN ile sınıflandırmada ne kadar etkili olduğunu göstermektedir. Kritik bölge ısı haritasının elde edilmesinde, veri setindeki her örnek için kapama (occlusion) testi uygulanmaktadır [75]. Bu testte, görüntünün küçük bir bölgesi kapatılır (yani, 0'a eşitlenir) ve daha sonra ağın doğru etiketi tahmin etme eğilimi test edilir. Kapama sonrası elde edilen tahmin değerindeki farklılık o bölgenin CNN ile sınıflandırmada ne kadar etkili olduğunu göstermektedir. Eğer tahmin değerinde önemli bir değişiklik görülüyorsa ilgili bölgenin sınıflandırmada etkili olduğu söylenebilmektedir. Bu işlem, tahmin değeri değişimleriyle oluşturulan bir ısı haritası üretmek amacıyla, görüntünün tümünde kayar pencere ile tekrarlanır. Test sırasında ilgili bölgede görüntünün tüm renk

kanalları aynı anda kapatılmaktadır. Her örnek için kapama testi ile elde edilen ısı haritaları, o örnek için elde edilen nöbet tahmin değerleri ile ağırlıklandırılarak, preiktal ve iktal evreler için ortalama ısı haritaları oluşturulmaktadır.

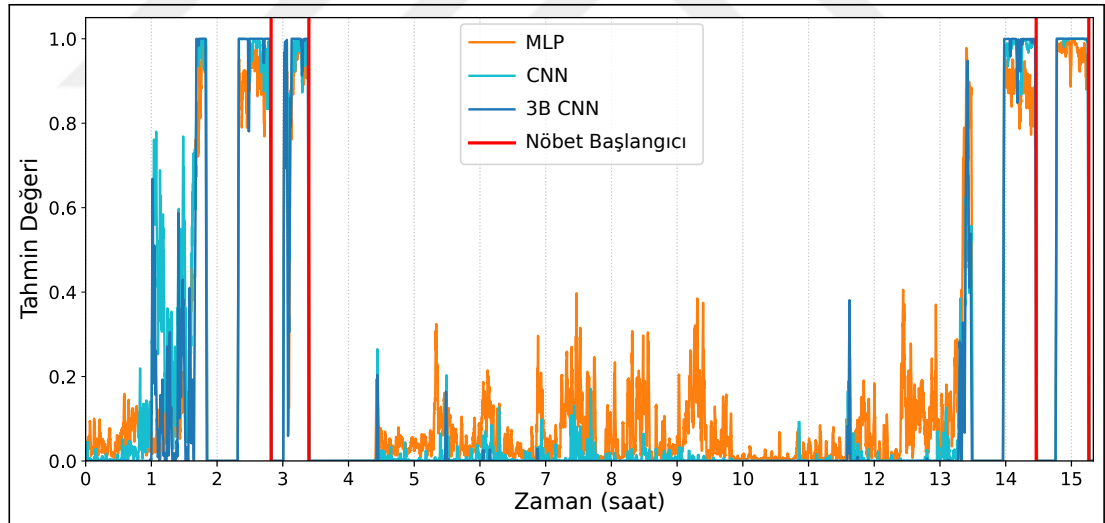


Şekil 4.10. Kritik bölge ısı haritasının oluşturulmasında kullanılan kapama testi. Sol üstte verilen örnek görüntü için kayar pencere ile küçük bir bölge kapatılarak ağın doğru etiketi tahmin etme eğilimi test edilmektedir

## 5. DENEYSEL SONUÇLAR


Tez çalışmasında oluşturulan öğrenme modelleri MIT Physionet sEEG veri setinden 16 hastada, 77 nöbet vakası ile test edilmiştir. Modellerin başarımlarının değerlendirilmesinde beş parametre kullanılmaktadır. Bunlar; duyarlılık ( $S_n$ , doğru tahmin edilen nöbetlerin toplam nöbet sayısına oranı), uyarıdaki zaman oranı ( $\rho_w$ , uyarıda geçen sürenin toplam süreye oranı), yanlış-pozitif oranı (FPR, saat başına yanlış alarm sayısı), eğri altında kalan alan (AUC, işlem karakteristiği eğrisi altında kalan alan) ve p-değeri (şansa göre iyileşmenin önemi).

MIT Physionet sEEG veri setinde Hasta-1 için MLP, CNN ve 3B CNN modelleri ile elde edilen tahmin sonuçları Şekil 5.1.'de verilmektedir. İlgili hasta veri setinde ilk 15 saatlik EEG kaydı için nöbet tahmin sonuçlarının verildiği bu şekilde nöbet başlangıçları kırmızı çizgi ile işaretlenmiştir. Hasta-1'in tahmin değerleri için oluşturulan işlem karakteristiği eğrisi (ROC) Şekil 5.2. ile verilmiştir. Oluşturulan



Şekil 5.1. MLP, CNN ve 3B CNN modelleri ile MIT Physionet sEEG veri setinde Hasta-1 için elde edilen nöbet tahmin değerleri

MLP, CNN ve 3B CNN öğrenme modellerinin MIT Physionet sEEG veri tabanı için nöbet tahmin başarımları sırasıyla Tablo 5.1., Tablo 5.2. ve Tablo 5.3. ile verilmektedir. MLP, CNN ve 3B CNN modelleri, veri setinin tümünde sırasıyla %67,33, %83,12 ve %79,22 duyarlılık yüzdesine ulaşmıştır. Bu duyarlılık değerleri için uyarıdaki zaman oranı, MLP, CNN ve 3B CNN modelleri için sırasıyla %13,5, %12,1 ve %10,7'dir. Buna bağlı olarak yanlış-pozitif değerleri 0,333/saat, 0,238/saat ve 0,202/saat olarak elde edilmiştir. Uygulanan eşikten bağımsız bir ölçüm olan eğri



Şekil 5.2. Hasta-1'in nöbet tahmin değerleri için oluşturulan işlem karakteristiği eğrisi

Tablo 5.1. MLP modelinin MIT Physionet sEEG veri seti için nöbet tahmin başarımı

	$S_n(\%)$	$\rho_w(\%)$	FPR(/h)	AUC	p
Hasta 1	100,0±00,0	11,1±0,6	0,140±0,013	0,920±0,012	<0,001
Hasta 2	66,7±00,0	31,3±2,4	0,729±0,056	0,181±0,030	<b>0,221</b>
Hasta 3	66,7±12,4	11,6±5,0	0,198±0,110	0,808±0,021	0,002
Hasta 5	20,0±15,3	15,1±8,6	0,369±0,220	0,211±0,029	<b>0,546</b>
Hasta 7	66,7±12,4	29,5±3,3	0,631±0,064	0,293±0,027	<b>0,199</b>
Hasta 9	50,0±00,0	23,7±3,5	0,508±0,076	0,295±0,037	<b>0,229</b>
Hasta 10	57,1±06,7	15,5±2,4	0,379±0,061	0,613±0,049	0,012
Hasta 13	60,0±00,0	9,2±0,6	0,179±0,017	0,657±0,010	0,006
Hasta 14	50,0±07,9	13,9±1,8	0,365±0,057	0,397±0,034	0,036
Hasta 16	80,0±00,0	7,0±0,5	0,000±0,000	0,800±0,000	<0,001
Hasta 17	66,7±00,0	1,3±2,0	0,000±0,047	0,667±0,027	<0,001
Hasta 18	60,0±07,5	4,9±2,0	0,100±0,049	0,553±0,037	0,001
Hasta 19	100,0±00,0	10,7±1,8	0,185±0,041	0,938±0,020	0,001
Hasta 20	83,3±07,9	5,5±4,2	0,000±0,069	0,967±0,007	<0,001
Hasta 21	50,0±09,3	16,2±2,4	0,353±0,053	0,371±0,020	<b>0,118</b>
Hasta 23	100,0±07,5	9,3±1,9	0,058±0,043	0,954±0,038	<0,001
Toplam	67,5±05,4	13,5±2,7	0,335±0,061	0,602±0,025	n.a

$p > 0,05$  anlamlılık değerleri koyu ile gösterilmiştir.

altında kalan alan, MLP, CNN ve 3B CNN modelleri için sırasıyla 0,602, 0,776 ve 0,778 olarak hesaplanmıştır. Elde edilen başarımın şansa göre üstünlüğünün istatistiksel bir ölçüsü olan p değerleri tüm modeller için hesaplanmıştır. İstatistiksel

Tablo 5.2. CNN modelinin MIT Physionet sEEG veri seti için nöbet tahmin başarımı

	$S_n(\%)$	$\rho_w(\%)$	FPR(/h)	AUC	p
Hasta 1	100,0±00,0	7,7±0,7	0,035±0,017	0,980±0,009	<0,001
Hasta 2	100,0±00,0	7,9±2,5	0,133±0,053	0,934±0,017	<0,001
Hasta 3	83,3±06,2	17,8±1,9	0,329±0,049	0,753±0,011	0,001
Hasta 5	100,0±07,5	10,5±3,3	0,168±0,076	0,966±0,027	<0,001
Hasta 7	100,0±15,7	19,3±2,9	0,388±0,058	0,720±0,031	0,007
Hasta 9	75,0±00,0	11,4±0,7	0,213±0,015	0,787±0,019	0,005
Hasta 10	42,9±16,5	19,6±6,8	0,514±0,161	0,320±0,017	<b>0,132</b>
Hasta 13	80,0±00,0	11,9±2,2	0,269±0,052	0,648±0,022	0,001
Hasta 14	83,3±15,0	22,5±3,7	0,487±0,084	0,564±0,019	0,002
Hasta 16	80,0±00,0	8,2±1,2	0,000±0,051	0,800±0,018	<0,001
Hasta 17	66,7±00,0	5,2±2,1	0,124±0,029	0,690±0,040	0,007
Hasta 18	40,0±14,9	19,9±9,4	0,434±0,202	0,386±0,037	<b>0,248</b>
Hasta 19	100,0±00,0	4,2±3,1	0,037±0,062	0,975±0,020	<0,001
Hasta 20	100,0±07,9	14,4±1,9	0,147±0,025	0,943±0,008	<0,001
Hasta 21	100,0±00,0	5,6±2,7	0,071±0,053	0,947±0,029	<0,001
Hasta 23	100,0±00,0	7,8±0,9	0,000±0,027	1,000±0,019	<0,001
Toplam	83,1±05,2	12,1±2,9	0,238±0,063	0,776±0,021	n.a

p>0,05 anlamlılık değerleri koyu ile gösterilmiştir.

Tablo 5.3. 3B CNN modelinin MIT Physionet sEEG veri seti için nöbet tahmin başarımı


	$S_n(\%)$	$\rho_w(\%)$	FPR(/h)	AUC	p
Hasta 1	100,0±06,7	10,7±1,2	0,105±0,024	0,965±0,022	<0,001
Hasta 2	100,0±12,4	11,7±3,3	0,232±0,074	0,845±0,059	0,001
Hasta 3	83,3±06,2	19,9±2,2	0,395±0,053	0,731±0,036	0,001
Hasta 5	100,0±07,5	8,3±1,1	0,101±0,030	0,960±0,018	<0,001
Hasta 7	100,0±12,4	19,0±3,9	0,372±0,081	0,752±0,032	0,006
Hasta 9	75,0±00,0	9,7±1,3	0,180±0,030	0,803±0,020	0,003
Hasta 10	28,6±10,9	3,5±7,1	0,081±0,177	0,392±0,038	0,022
Hasta 13	60,0±07,5	9,1±5,0	0,224±0,143	0,625±0,047	0,006
Hasta 14	66,7±12,4	14,9±3,5	0,366±0,067	0,593±0,023	0,005
Hasta 16	80,0±00,0	7,6±2,9	0,000±0,096	0,800±0,045	<0,001
Hasta 17	66,7±12,4	2,7±3,7	0,062±0,059	0,834±0,087	0,002
Hasta 18	40,0±07,5	9,3±5,3	0,167±0,118	0,453±0,040	<b>0,067</b>
Hasta 19	100,0±00,0	12,0±2,4	0,222±0,051	0,914±0,028	0,002
Hasta 20	100,0±08,3	11,7±1,7	0,098±0,037	0,967±0,027	<0,001
Hasta 21	100,0±00,0	11,5±1,2	0,212±0,026	0,841±0,031	<0,001
Hasta 23	100,0±00,0	9,6±0,8	0,058±0,022	0,977±0,017	<0,001
Toplam	79,2±06,5	10,7±2,9	0,202±0,068	0,778±0,036	n.a

p>0,05 anlamlılık değerleri koyu ile gösterilmiştir.

anlamlılık sınırı 0,05 kabul edildiğinde, MLP modelinde 5 hasta için elde edilen başarımın şansa göre üstünlüğü istatistiksel olarak anlamlı değildir. Aynı durum CNN modelinde 2 hasta, 3B CNN modelinde ise 1 hasta için geçerlidir.

## 5.1. Epileptik Evre Sürelerinin Nöbet Tahmin Başarımına Etkisi

Literatürde epileptik evre uzunluklarına dair standart bir tanımlama yoktur. Bunun nedenlerinden biri epileptik evre sürelerinin hastadan hastaya oldukça farklılık göstermesidir. Tez çalışmasında daha önce, preiktal evre uzunluğu 30 dakika, interiktal ve iktal evreler arasındaki uzaklık ise 1 saat olarak tanımlanmıştır. Bu epileptik evre süre tanımlamaları ile yapılan eğitimde çoğu hasta için beklenenden düşük nöbet tahmin başarımı elde edilmiştir. Epileptik evre sürelerinin nöbet tahmin başarımına etkisini ölçmek amacıyla, tüm modeller farklı epileptik evre uzunlukları ile tekrar tekrar eğitilmiştir. Preiktal evre uzunluğu için 30 ve 60 dakika, interiktal-iktal evre uzaklığı için 60, 120 ve 240 dakika olmak üzere Şekil 5.3.'de verildiği gibi 6 farklı epileptik evre zamanlaması için denemeler yapılmıştır.



Şekil 5.3. Farklı epileptik evre süreleri ile yapılan denemeler. Preiktal ve interiktal evre arasındaki gri alanlar eğitim dışı bırakılmıştır

Farklı epileptik evre süreleri ile eğitilmiş modellerin nöbet tahmin başarımları Şekil 5.4.'de AUC değerleri ile verilmiştir. İteriktal ve iktal evre arasındaki uzaklık artışının hastaların çoğu için modellerin tahmin başarımlarında iyileşmeye yol açtığı görülmüştür. Bu gözlemin istatistiksel olarak da doğrulanması için, farklı epileptik evre uzunluklarının birbirine üstünlüğünün önemi, elde edilen AUC değerleri için Wilcoxon işaretli sıralama testi ile hesaplanmıştır. Wilcoxon işaretli sıralama test prosedürü Ek-A'da detaylı olarak verilmiştir. MLP, CNN ve 3B CNN modelleri için anlamlılık değerleri(p-değeri) matrisi, Şekil 5.5.'de verilmiştir. 60 dakikalık ve 120 dakikalık interiktal uzaklığa göre, 240 dakikalık interiktal uzaklık ile elde edilen nöbet tahmin başarımlarının üstünlüğü, 3B CNN modeli için 0,05 anlamlılık düzeyinde istatistiksel olarak anlamlıdır.

## 5.2. Değişken Ağırlıklı Öğrenmenin Nöbet Tahmin Başarımına Etkisi

Çalışmada değerlendirilen hastalar için preiktal evre uzunluğu aynı kabul edilmektedir. Fakat bu süre gerçekte hastadan hastaya farklılık gösterdiğinden, preiktal evre ile interiktal evre iç içe geçmekte ve sınıflandırma başarımı olumsuz etkilenmektedir. Bu tez çalışmasında bu problemin etkilerini azaltmak amacıyla



Şekil 5.4. Oluşturulan modellerin farklı epileptik evre uzunlukları için nöbet tahmin başarımları, AUC değeri ortalamaları ve standart sapmaları ile verilmiştir.  $\leq 0,01$ ,  $\leq 0,05$  ve  $> 0,05$  anlamlılık seviyeleri sırasıyla  $\blacktriangledown$ ,  $\nabla$ , ve  $\triangle$  ile işaretlenmiştir

İÜ: İnteriktal Uzaklık PU: Preiktal Uzunluk								İÜ: İnteriktal Uzaklık PU: Preiktal Uzunluk													
60 Dak.	30 Dak.	1	0,980	0,923	0,989	0,986	0,978	60 Dak.	30 Dak.	1	0,852	0,985	0,953	0,987	0,999						
	60 Dak.	<b>0,023</b>	1	0,070	0,773	0,850	0,803		60 Dak.	60 Dak.	0,163	1	0,719	0,510	0,820	0,971					
120 Dak.	30 Dak.	0,086	0,936	1	0,975	0,960	0,985	120 Dak.	30 Dak.	<b>0,018</b>	0,300	1	0,195	0,751	0,874						
	60 Dak.	<b>0,013</b>	0,244	<b>0,029</b>	1	0,531	0,831		60 Dak.	60 Dak.	0,053	0,510	0,820	1	0,681	0,964					
240 Dak.	30 Dak.	<b>0,016</b>	0,163	<b>0,043</b>	0,490	1	0,777	240 Dak.	30 Dak.	<b>0,016</b>	0,195	0,271	0,339	1	0,847						
	60 Dak.	<b>0,025</b>	0,211	<b>0,017</b>	0,183	0,231	1		60 Dak.	<b>0,000</b>	<b>0,034</b>	0,138	<b>0,042</b>	0,170	1						
	PU	30 Dak.	60 Dak.	30 Dak.	60 Dak.	30 Dak.	60 Dak.		PU	30 Dak.	60 Dak.	30 Dak.	60 Dak.	30 Dak.	60 Dak.						
İÜ		60 Dak.			120 Dak.			240 Dak.			İÜ		60 Dak.			120 Dak.			240 Dak.		

(a) MLP

(b) CNN

İÜ: İnteriktal Uzaklık PU: Preiktal Uzunluk										
60 Dak.	30 Dak.	1	0,489	0,479	0,908	0,999	0,999			
	60 Dak.	0,533	1	0,572	0,943	0,985	0,988			
120 Dak.	30 Dak.	0,541	0,452	1	0,757	0,998	0,995			
	60 Dak.	0,101	0,064	0,259	1	0,954	0,982			
240 Dak.	30 Dak.	<b>0,001</b>	<b>0,018</b>	<b>0,002</b>	0,052	1	0,798			
	60 Dak.	<b>0,001</b>	<b>0,014</b>	<b>0,006</b>	<b>0,021</b>	0,212	1			
	PU	30 Dak.	60 Dak.	30 Dak.	60 Dak.	30 Dak.	60 Dak.			
İÜ		60 Dak.			120 Dak.			240 Dak.		

(c) 3B CNN

Şekil 5.5. Tek taraflı Wilcoxon işaretli sıralama testi ile elde edilen anlamlılık değerleri (p-değeri) matrisi, (a) MLP, (b) CNN, (c) 3B CNN modelleri için farklı epileptik evre uzunluklarının birbirine üstünlüğünü (dikey eksenin yatay eksene üstünlüğü) ortaya koymaktadır. Anlamlılık değerleri <0,05 için kalın olarak işaretlenmiştir

değişken ağırlıklı öğrenme önerilmektedir. Önceki bölümde açıklanan öğrenme aşamasında, tüm örnekler kayıp fonksiyonunda eşit ağırlık ile temsil edilmiştir. Değişken ağırlıklı öğrenmede ise kayıp fonksiyonundaki pozitif (preiktal) örnekler, sabit bir ağırlık yerine zamanla değişen bir ağırlıkla temsil edilmektedir. Bu amaçla, Denklem (2.14)'de verilen ikili çapraz entropi kayıp fonksiyonuna bir  $w_{pos}$  katsayısı eklenerek, Denklem (5.1) ile verilen ağırlıklı çapraz entropi kayıp fonksiyonu elde edilmiştir. Bu katsayının değeri, pozitif örneğin konumuna bağlı olarak belirlenmektedir. Denklem (5.2)'de gösterildiği şekilde preiktal evrenin başlangıcında minimum seviyede olan ağırlık, preiktal evrenin sonunda maksimum değere ulaşır.



Burada  $n_{\text{pos}}$  preiktal evredeki örnek sayısını,  $i_{\text{pos}}$  ilgili örneğin indeksini vermektedir. Bu yöntemle preiktal evrenin başlangıcındaki veriler eğitimde daha az etkili olurken, iktal evreye daha yakın olan veriler daha fazla etkili olmaktadır.

$$E_n = -\frac{1}{n} \sum_{k=1}^n w_{\text{pos}} \cdot t_k \cdot \log(y_k) + (1 - t_k) \log(1 - y_k) \quad (5.1)$$

$$w_{\text{pos}} = \frac{1}{2} + \frac{i_{\text{pos}} - 1}{n_{\text{pos}}}, \quad i_{\text{pos}} = [1, 2, \dots, n_{\text{pos}}] \quad (5.2)$$

240 dakikalık interiktal evre uzaklığı ve 60 dakikalık preiktal evre uzunluğu ile eğitilmiş MLP, CNN ve 3B CNN modellerinin nöbet tahmin başarımları, normal ve değişken ağırlıklı öğrenme için karşılaştırmalı olarak, sırasıyla Tablo 5.4., Tablo 5.5. ve Tablo 5.6. ile verilmiştir. Değişken ağırlıklı öğrenmenin kullanımıyla, yanlış pozitif oranında genel olarak bir miktar azalma elde edilmesine rağmen, aynı zamanda duyarlılıkta da bir azalma gözlenmiştir. Bu sonuç, değişken ağırlıklı öğrenmenin genel nöbet tahmin performansı üzerinde beklenen iyileştirici etkiyi sağlamadığını göstermektedir.

Tablo 5.4. MLP modelinin MIT Physionet sEEG veri seti için değişken ağırlıklı öğrenme ile nöbet tahmin başarımları

	Normal				Değişken Ağırlıklı			
	$S_n(\%)$	FPR(h)	AUC	p	$S_n(\%)$	FPR(h)	AUC	p
Hasta 1	100,0±00,0	0,139±0,000	0,940±0,020	<0,001	100,0±00,0	0,139±0,000	0,910±0,024	<0,001
Hasta 2	100,0±16,7	0,307±0,075	0,872±0,057	0,005	100,0±15,7	0,307±0,079	0,859±0,059	0,007
Hasta 3	100,0±00,0	0,073±0,017	0,963±0,006	<0,001	100,0±00,0	0,110±0,025	0,951±0,007	<0,001
Hasta 5	80,0±07,5	0,208±0,026	0,737±0,038	0,001	80,0±09,4	0,208±0,033	0,765±0,034	0,001
Hasta 7	66,7±22,9	0,624±0,212	0,355±0,038	<b>0,309</b>	66,7±19,2	0,624±0,200	0,342±0,044	<b>0,313</b>
Hasta 9	50,0±00,0	0,000±0,052	0,513±0,013	<0,001	50,0±00,0	0,000±0,045	0,508±0,026	<0,001
Hasta 10	71,4±06,7	0,166±0,052	0,793±0,032	0,001	85,7±05,3	0,083±0,021	0,840±0,024	<0,001
Hasta 13	80,0±00,0	0,199±0,025	0,722±0,024	0,002	80,0±00,0	0,199±0,045	0,681±0,027	0,002
Hasta 14	83,3±12,4	0,212±0,106	0,894±0,026	<0,001	66,7±07,9	0,000±0,079	0,858±0,044	<0,001
Hasta 16	100,0±00,0	0,355±0,084	0,645±0,079	0,001	100,0±07,5	0,355±0,089	0,681±0,096	<0,001
Hasta 17	66,7±00,0	0,254±0,138	0,604±0,060	<b>0,092</b>	66,7±00,0	0,339±0,106	0,604±0,034	<b>0,109</b>
Hasta 18	60,0±07,5	0,568±0,141	0,350±0,034	<b>0,235</b>	40,0±11,5	0,530±0,171	0,335±0,086	<b>1,000</b>
Hasta 19	100,0±00,0	0,148±0,050	0,951±0,025	0,003	100,0±00,0	0,148±0,028	0,926±0,009	0,003
Hasta 20	100,0±00,0	0,157±0,020	0,930±0,016	<0,001	100,0±06,2	0,157±0,020	0,921±0,012	<0,001
Hasta 21	100,0±09,3	0,213±0,035	0,925±0,043	0,003	100,0±11,8	0,213±0,049	0,915±0,032	0,003
Hasta 23	100,0±00,0	0,070±0,033	0,986±0,010	<0,001	100,0±00,0	0,070±0,026	0,972±0,010	<0,001
Toplam	85,7±05,2	0,249±0,067	0,761±0,033		84,4±05,9	0,243±0,063	0,754±0,036	

$p > 0,05$  anlamlılık değerleri koyu ile gösterilmiştir.

### 5.3. Şans Tahmincisine Karşı Test

Önerilen nöbet tahmin yöntemlerinin başarımlarının şanstan daha iyi olup olmadığını anlamak amacıyla elde edilen sonuçlar bir şans tahmincisi ile karşılaştırılmıştır. İki ardışık alarm arasındaki aralığın bir Poisson işlemi olarak, üssel bir dağılım izlediği varsayıldığında,  $\Delta t$  süresi içinde en az bir alarmın rasgele bir şekilde oluşma olasılığı,

Tablo 5.5. CNN modelinin MIT Physionet sEEG veri seti için deęişken aęırlıklı öğrenme ile nöbet tahmin başarımı

	Normal				Deęişken Aęırlıklı			
	S <sub>n</sub> (%)	FPR(h)	AUC	p	S <sub>n</sub> (%)	FPR(h)	AUC	p
Hasta 1	100,0±00,0	0,000±0,000	1,000±0,000	<0,001	100,0±00,0	0,000±0,000	1,000±0,000	<0,001
Hasta 2	100,0±00,0	0,038±0,018	0,974±0,006	<0,001	100,0±00,0	0,038±0,029	0,974±0,012	<0,001
Hasta 3	100,0±06,2	0,110±0,027	0,957±0,010	<0,001	100,0±00,0	0,037±0,030	0,976±0,004	<0,001
Hasta 5	100,0±00,0	0,069±0,062	0,986±0,012	<0,001	100,0±07,5	0,000±0,026	1,000±0,015	<0,001
Hasta 7	100,0±15,7	0,312±0,100	0,857±0,038	0,012	100,0±15,7	0,331±0,105	0,851±0,045	0,014
Hasta 9	100,0±00,0	0,041±0,030	0,990±0,018	<0,001	100,0±00,0	0,082±0,000	0,969±0,013	<0,001
Hasta 10	57,1±09,8	0,580±0,098	0,385±0,046	<b>0,055</b>	28,6±15,8	0,373±0,162	0,325±0,045	<b>0,292</b>
Hasta 13	80,0±00,0	0,463±0,125	0,669±0,058	0,009	80,0±09,4	0,463±0,106	0,669±0,028	0,009
Hasta 14	100,0±00,0	0,000±0,000	1,000±0,000	<0,001	100,0±00,0	0,000±0,000	1,000±0,000	<0,001
Hasta 16	100,0±10,0	0,000±0,084	1,000±0,039	<0,001	80,0±09,4	0,000±0,084	0,929±0,026	<0,001
Hasta 17	66,7±00,0	0,000±0,000	0,667±0,000	0,001	66,7±00,0	0,000±0,040	0,667±0,013	0,001
Hasta 18	60,0±00,0	0,303±0,062	0,471±0,018	<b>0,071</b>	60,0±00,0	0,189±0,071	0,588±0,024	0,031
Hasta 19	100,0±00,0	0,000±0,019	1,000±0,011	<0,001	100,0±00,0	0,037±0,000	0,988±0,006	<0,001
Hasta 20	100,0±07,9	0,157±0,071	0,974±0,006	<0,001	100,0±00,0	0,105±0,030	0,983±0,005	<0,001
Hasta 21	100,0±00,0	0,000±0,000	1,000±0,000	<0,001	100,0±00,0	0,000±0,000	1,000±0,000	<0,001
Hasta 23	100,0±00,0	0,000±0,000	1,000±0,000	<0,001	100,0±00,0	0,000±0,000	1,000±0,000	<0,001
Toplam	90,9±03,1	0,156±0,043	0,871±0,016		87,0±03,6	0,133±0,043	0,870±0,015	

p>0,05 anlamlılık deęerleri koyu ile gösterilmiştir.

Tablo 5.6. 3B CNN modelinin MIT Physionet sEEG veri seti için deęişken aęırlıklı öğrenme ile nöbet tahmin başarımı

	Normal				Deęişken Aęırlıklı			
	S <sub>n</sub> (%)	FPR(h)	AUC	p	S <sub>n</sub> (%)	FPR(h)	AUC	p
Hasta 1	100,00±00,00	0,000±0,026	1,000±0,004	<0,001	100,00±00,00	0,000±0,033	1,000±0,005	<0,001
Hasta 2	100,00±00,00	0,154±0,058	0,949±0,027	0,003	100,00±00,00	0,192±0,053	0,936±0,021	0,005
Hasta 3	100,00±00,00	0,110±0,017	0,957±0,011	<0,001	100,00±00,00	0,146±0,030	0,942±0,012	<0,001
Hasta 5	100,00±07,45	0,139±0,062	0,958±0,019	<0,001	100,00±00,00	0,069±0,052	0,986±0,043	<0,001
Hasta 7	66,67±15,71	0,136±0,056	0,799±0,040	0,031	66,67±16,67	0,078±0,071	0,831±0,035	0,015
Hasta 9	100,00±00,00	0,000±0,023	1,000±0,013	<0,001	100,00±00,00	0,000±0,000	1,000±0,000	<0,001
Hasta 10	42,86±09,82	0,456±0,061	0,348±0,036	<b>0,113</b>	57,14±13,47	0,414±0,149	0,615±0,049	0,025
Hasta 13	80,00±00,00	0,000±0,113	0,881±0,087	<0,001	80,00±00,00	0,199±0,077	0,834±0,072	0,002
Hasta 14	100,00±00,00	0,000±0,000	1,000±0,000	<0,001	100,00±00,00	0,000±0,000	1,000±0,000	<0,001
Hasta 16	80,00±10,00	0,000±0,084	0,929±0,038	<0,001	100,00±14,91	0,000±0,084	1,000±0,144	<0,001
Hasta 17	66,67±12,42	0,000±0,124	0,859±0,039	0,006	66,67±00,00	0,000±0,032	0,830±0,024	0,006
Hasta 18	60,00±00,00	0,000±0,018	0,682±0,023	<0,001	60,00±10,00	0,303±0,080	0,573±0,026	<b>0,062</b>
Hasta 19	100,00±00,00	0,037±0,017	0,963±0,013	<0,001	100,00±00,00	0,148±0,046	0,951±0,015	0,004
Hasta 20	83,33±06,21	0,105±0,039	0,930±0,014	0,001	83,33±00,00	0,105±0,000	0,947±0,017	0,001
Hasta 21	100,00±00,00	0,000±0,020	1,000±0,010	<0,001	100,00±00,00	0,000±0,029	1,000±0,020	<0,001
Hasta 23	100,00±00,00	0,000±0,000	1,000±0,000	<0,001	100,00±00,00	0,000±0,000	1,000±0,000	<0,001
Toplam	85,71±03,85	0,085±0,045	0,891±0,023		88,31±03,44	0,116±0,046	0,903±0,030	

p>0,05 anlamlılık deęerleri koyu ile gösterilmiştir.

t'den baęımsız olarak yaklaşık  $\lambda_w \Delta t$ 'ye eşittir. Burada  $\lambda_w$  Poisson oranı olarak adlandırılmaktadır. Bu bağlamda, şans tahmincisinin S<sub>nc</sub> duyarlılığı, Denklem (5.3)'deki gibi tanımlanmaktadır [94]. Saptama aralığı  $\tau_{w0}$ , nöbet tahmini aralığına (SPH) karşılık gelirken,  $\tau_w$  ise SPH ve nöbet gerçekleşme periyodunun (SOP) toplamına karşılık gelmektedir.

$$S_{nc} = 1 - \exp(-\lambda_w \tau_w + (1 - e^{-\lambda_w \tau_{w0}})) \quad (5.3)$$

Uyarıda harcanan zaman  $\rho_w$  ve bununla bağlantılı olarak uyarı oranı  $r_w$  sırasıyla Denklem (5.4) ve Denklem (5.5) ile verilmektedir.

$$\rho_w = 1 - e^{-\lambda_w \tau_w} \quad (5.4)$$

$$r_w = \lambda_w e^{-\lambda_w \tau_w} \quad (5.5)$$

Gözlemlenen ve şans duyarlılığı arasındaki fark  $\rho_w$  'a bağlıdır ve bu tahmin yeteneğinin belirlenmesi için güçlü bir ölçüdür [94].  $S_n$  duyarlılığı ve  $\rho_w$  uyarıda harcanan zaman oranına sahip bir nöbet tahmin yöntemi için, duyarlılıkta şansın üzerindeki bir iyileşmenin ölçüsü Denklem (5.6) ile verilmektedir.

$$S_n - S_{nc} = S_n - 1 + \exp(-\lambda_w \tau_w + (1 - e^{-\lambda_w \tau_w})) \quad (5.6)$$

Burada  $\lambda_w$  ise Denklem (5.7)'deki gibidir.

$$\lambda_w = -\frac{1}{\tau_w} \ln(1 - \rho_w) \quad (5.7)$$

Önerilen tahmin yönteminin, bir hasta için N nöbetten n'ini doğru bir şekilde tanımladığı varsayıldığında, şansa göre iyileşmenin istatistiksel önemi, Denklem (5.8)'de verildiği gibi tek taraflı p değeri ile değerlendirilmektedir.

$$p = 1 - \sum_{i=0}^{n-1} \binom{N}{i} S_{nc}^i (1 - S_{nc})^{N-i}, \quad \text{for } \frac{n}{N} \geq S_{nc} \quad (5.8)$$

Tez çalışmasında elde edilen duyarlılık değerlerinin istatistiksel önemi her bir hasta için Tablo 5.1., Tablo 5.2., Tablo 5.3., Tablo 5.4., Tablo 5.5., Tablo 5.6. ve Şekil 5.4.'de tek taraflı p değerleri ile verilmiştir.

#### 5.4. Epileptik EEG'de Kritik Bölgelerin Belirlenmesi

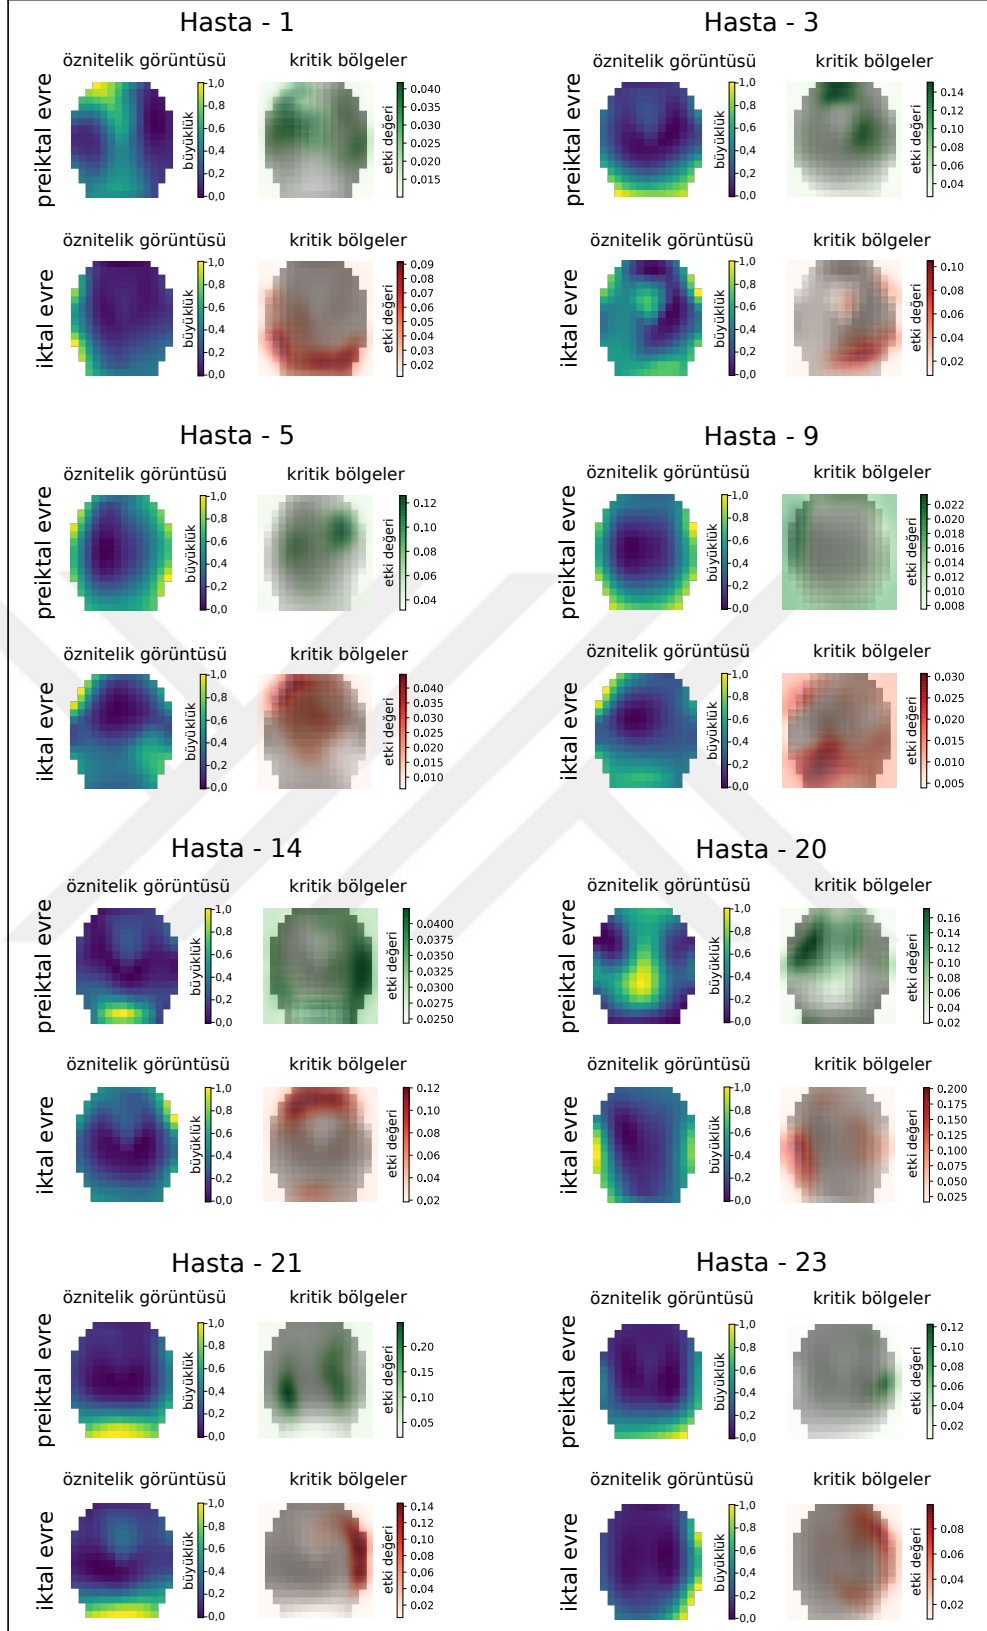
Epilepsi, beyinde nöbetlerin başladığı yere ve nasıl yayıldığına bağlı olarak iki alt tipe ayrılabilir. Birincil genelleşmiş epilepside nöbetler beynin tamamını kapsayan yaygın bir elektrik boşalmasıyla başlarken, odaksal epilepside nöbetler beynin sınırlı bir bölgesinde elektriksel boşalmayla başlamaktadır. Ayrıca odaksal epilepsi beyinde nöbetin yayıldığı bölgeye göre temporal, frontal, oksipital ve parietal lob epilepsisi olarak sınıflandırılmaktadır. Nöbetlerin klinik ortaya çıkışı, hangi beyin bölgelerinin nöbetten etkilendiğine, yani semptomatik bölgeye bağlı olarak çeşitli biçimlerde. Genelleşmiş epilepsi terimi yaygın olarak kullanılmasına rağmen, yakın dönemde

yapılan çalışmalarda genelleşmiş görünen epilepsilerde de yayılımın çok hızlı gerçekleştiği bir odak noktasının bulunmuş olması [95, 96], genelleşme kavramının sorgulanabilir olduğunu göstermektedir.

Epileptik beyin bölgelerini kesin olarak tanımlamak için belirli bir terminoloji kullanılmaktadır. Epileptojenik bölge, tekrar eden nöbetlere neden olan beyin korteksi alanıdır. Bu beyin bölgesinin cerrahi olarak çıkarılması, hastada nöbetin kalıcı olarak engellenmesi için yeterli olmaktadır. Fakat günümüzde mevcut tekniklerden hiçbiri ile bu bölge tam olarak tanımlanamamaktadır. Bu nedenle, epileptik cerrahi operasyonları için birkaç teknik birleştirilerek gerçek epileptojenik bölge için belirli bir tahmin oluşturulmaktadır. Nöbet başlangıç bölgesi, iktal EEG kayıtlarına bağlı olarak nöbetin klinik olarak meydana geldiği beyin korteksi alanıdır [97].

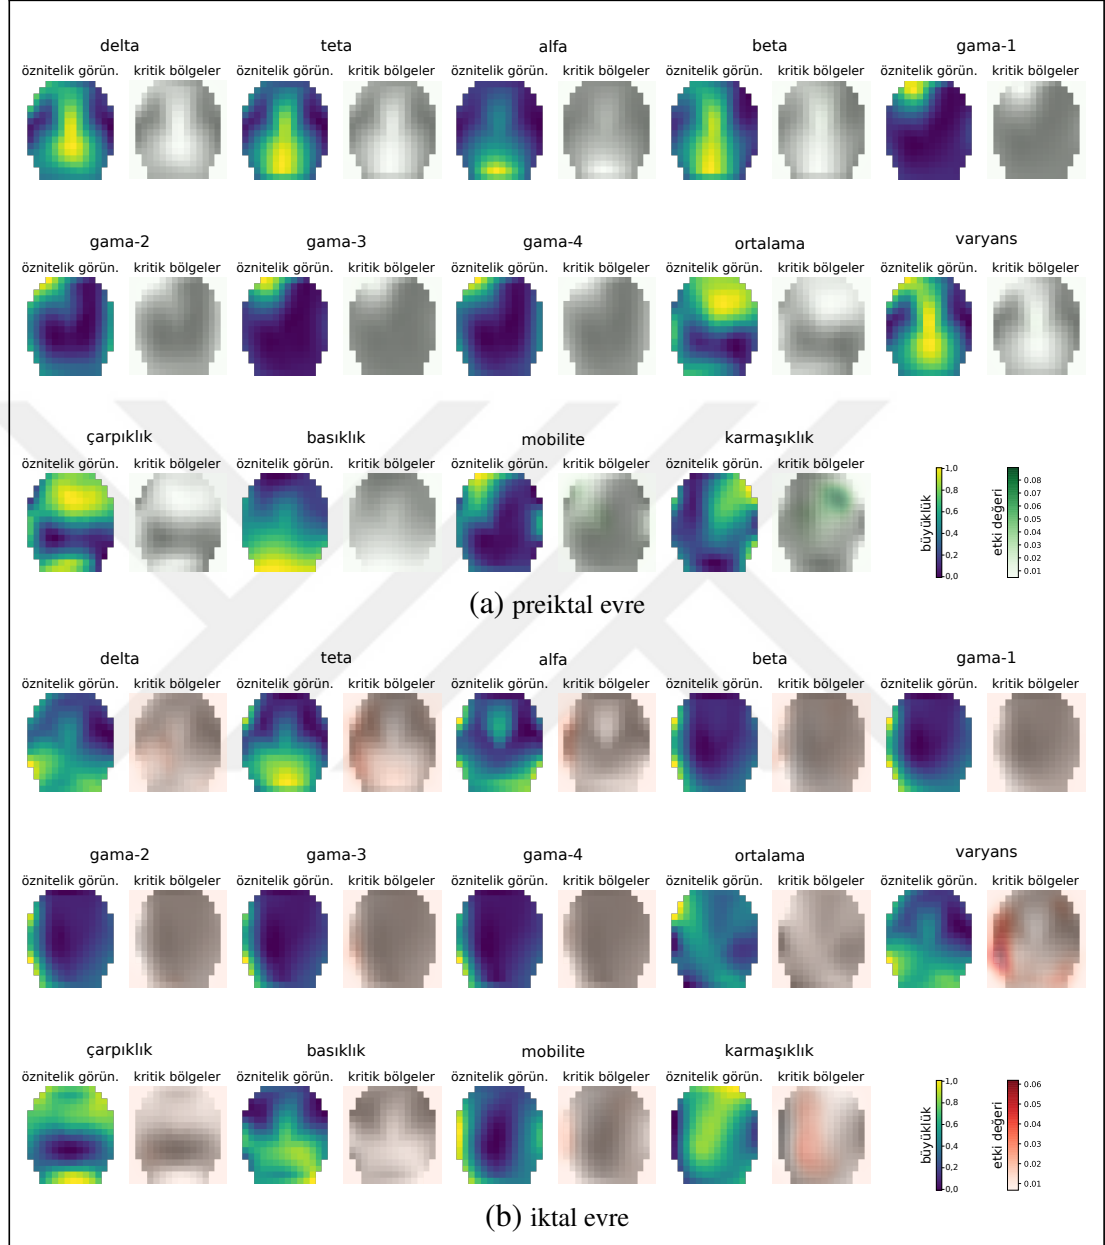
Tez çalışmasında nöbet tahmini için oluşturulan eğitim modelinin aynı zamanda epileptojenik bölge tespitine uygulanabilirliği araştırılmıştır. Bu amaçla evrişimli sinir ağlarında görüntüdeki kritik bölgelerin tespiti için önerilen kapama testi kullanılarak, elde edilen EEG öznitelik görüntüleri için kritik bölge ısı haritaları oluşturulmuştur. Epileptojenik bölge için preiktal evre, nöbet başlangıç bölgesi için ise iktal evredeki örneklerle MIT Physionet sEEG veri setinden toplam 8 hasta için kritik bölge analizi yapılmıştır. Sınırlı sayıda hastadan elde edilen sonuçlar, preiktal ve iktal evredeki örnekler için elde edilen kritik bölgelerin, Şekil 5.6.'daki gibi farklılaştığını ortaya koymaktadır. Bu durum nöbetin beyin korteksinde epileptojenik bölgeden nöbet başlangıç bölgesine doğru yayıldığı hipotezini destekler niteliktedir. Öznitelik görüntüleri, preiktal ve iktal kayıtlar boyunca uzamsal alanda 14 öznitelik için ortalamaları temsil etmektedir. Kritik bölge ısı haritaları ise öznitelik görüntülerindeki bölgelerin evrişimli sinir ağı ile sınıflandırmada ne kadar etkili olduğunu göstermektedir.

Epileptik nöbetin gelişiminde, çıkarılan özniteliklerdeki değişimi araştırmak amacıyla öznitelik tabanlı kapama testi gerçekleştirilmiştir. Bunun için klasik kapama testinden farklı olarak, her örnek için elde edilen 14 öznitelik görüntüsüne ayrı ayrı kapama testi uygulanmıştır. İlgili öznitelik görüntüsünde kayar pencereye denk gelen bölge sifıra eşitlenirken diğer öznitelik görüntülerine dokunulmamıştır. Bu sayede her bir öznitelik evrişimli sinir ağları ile sınıflandırmada ne kadar etkili olduğu ortaya çıkarılmıştır. MIT Physionet sEEG veri setinden Hasta-1 için gerçekleştirilen öznitelik tabanlı kritik bölge analizi sonuçları Şekil 5.7.'de görülmektedir. Aynı veri setinde Hasta-3, Hasta-5, Hasta-9, Hasta-14, Hasta-20, Hasta-21 ve Hasta-23 için gerçekleştirilen öznitelik tabanlı kritik bölge analizi sonuçları ise Ek-B'de verilmektedir. Elde edilen sonuçlar preiktal evre için mobilite ve karmaşıklık



Şekil 5.6. MIT Physionet sEEG veri setinden 8 hasta için preiktal ve ictal evre örneklerinden elde edilen kritik bölge ısı haritaları. Öznitelik görüntüleri, ilgili hastadaki tüm preiktal ve ictal kayıtlar boyunca 14 özniteliliğin ortalamasını temsil eder. Kritik bölge ısı haritaları, görüntüdeki bölgelerin CNN ile sınıflandırmada ne kadar etkili olduğunu göstermektedir

özniteliklerinin, iktal evre için mobilite ve karmaşıklık özniteliklerine ek olarak spektral bant gücü ve varyans özniteliklerinin, evrişimli sinir ağları ile sınıflandırmada daha belirleyici olduğunu göstermektedir.



Şekil 5.7. MIT Physionet sEEG veri setinde Hasta-1 için öznitelik tabanlı kritik bölgesi haritaları

## 6. TARTIŞMA

Son zamanlarda epileptik nöbet tahminine yönelik yapılan çalışmalarda birçok farklı yaklaşım önerilmiştir. Bu tez çalışmasında önerilen yöntemin başarımı, aynı MIT Physionet sEEG veri setinin kullanıldığı, en yeni nöbet tahmin çalışmaları ile birlikte Tablo 6.1.'de sunulmaktadır. Burada başarımları verilen çalışmalardan her biri, tanımlanan zaman kısıtlamaları ve yaklaşıma bağlı olarak seçilen sınırlı bir veri seti ile test edildiğinden, hangi yaklaşımın daha iyi olduğunu belirlemek zordur. Ayrıca, önerilen yöntemin ne kadar genelleştirilebilir olduğu da performansı etkileyen önemli bir kriterdir. Zhang ve Parhi çalışmalarında hastaya özel olarak seçilen ve sıralanan spektral güç özniteliklerinin kullanıldığı hasta tabanlı bir nöbet tahmin yaklaşımı önermiştir [14]. İlgili çalışmada MIT Physionet sEEG veri setinden 17 hasta ile yapılan testlerde, hastaya özgü öznitelik mühendisliği ile, %98,68 gibi yüksek bir duyarlılık ve 0,046/saat yanlış pozitif değerine ulaşılmıştır. Bununla birlikte, özniteliklerin hastaya özel bir şekilde seçildiği ve sıralandığı bu yöntem, yeni bir hastanın verisine uygulandığında öznitelik mühendisliği için yeterli bilgi ve uzmanlık gerektirmektedir.

Epileptik EEG veri setleri çoğunlukla sınırlı sayıda nöbet içermektedir. Tez çalışmasında kullanılan MIT Physionet sEEG veri setinde, 23 hastanın 844 saatlik EEG kaydı boyunca toplam 182 nöbet meydana gelmektedir. Ayrıca, bazı hasta veri setlerinde eğitim için kullanılacak sadece 3 nöbet bulunmaktadır. Epileptik nöbet tahmininde sınırlı sayıda nöbet ile yapılan bir eğitimde, eğitim verilerine aşırı uyum problemi ortaya çıkmaktadır. Önerilen bir modelin eğitiminde birisi-dışarıda çapraz doğrulama kullanılması, bu modelin nöbet tahmin başarımının gerçek şartlara benzer koşullar altında belirlenmesini mümkün kılmaktadır. Tsiouris ve arkadaşları yaptıkları çalışmada sınıflandırmada LSTM ağlarının kullanıldığı bir nöbet tahmin modeli önermiştir [23]. Eğitim aşamasında birisi-dışarıda çapraz doğrulamanın kullanılmadığı bu çalışmada, %99,84 gibi çok yüksek bir duyarlılık ve 0,02/saat yanlış pozitif değeri elde edilmiştir. Eğitimde birisi-dışarıda çapraz doğrulama kullanılmaması, test edilecek nöbet verisine ilişkin preiktal ve interiktal verilerin bir kısmının eğitim aşamasında kullanılmasına neden olmaktadır. Her ne kadar standart çapraz doğrulama aynı verinin hem eğitim hem test için kullanılmasını engellese de, eğitim ve test aşamasında kullanılan verilerin zamansal ilintisinin fazla olması modelin sınıflandırma başarımını oldukça arttırmaktadır.

Tablo 6.1. MIT Physionet sEEG veri seti için bu tez çalışmasında önerilen yöntemin ve diğer epileptik nöbet tahmin çalışmalarının başarımları

Çalışma	Veri Seti	Öznitelikler	Sınıflandırıcı	Nöbet sayısı	Hasta Sayısı	FPR(/h)	$S_n$ (%)	İnteriktal uzaklık (dakika)	Preiktal uzunluk (dakika)	Toplam interiktal süre (saat)
Zandi ve ark. [13]	MIT	Sıfır geçişleri, Benzerlik indeksi	-	18	3	0,165	83,81	60	40	-
Zhang ve Parhi [14]	MIT	Mutlak/göreceli spektral güç	SVM	78	17	0,046	98,68	60	60	-
Myers ve ark. [98]	MIT	Faz/genlik kilitleme değeri	-	31	10	0,17	77	-	60	31
Cho ve ark. [16]	MIT	Faz kilitleme değeri	SVM	65	21	-	82,44	30	5	<10,83
Chu ve ark. [10]	MIT	Fourier dönüşümü katsayıları, PSD	-	125	13	0,392	83,33	-	86	<434,6
Alotaiby ve ark. [15]	MIT	Ortak uzamsal örüntü istatistikleri	LDA	170	24	0,47 0,4 0,39	81 87 89	-	60 90 120	<982,9
Truong ve ark. [12]	MIT	STFT spektral görüntüleri	CNN	64	13	0,16	81,2	240	30	209
Khan ve ark. [11]	MIT	Wavelet dönüşümü katsayıları	CNN	18	15	0,147	87,8	-	10	<70,5
Tsiouris ve ark. [23]	MIT	İstatistiksel momentler, Sıfır geçişleri, Wavelet dönüşümü katsayıları, PSD	LSTM	185	24	0,11 0,06 0,03 0,02	99,28 99,38 99,63 99,84	-	15 30 60 120	<979,9
Bu çalışma	MIT	Spektral güç, İstatistiksel momentler, Hjorth parametreleri	3B CNN	77	16	0,292 0,186 0,096	86,84 87,01 85,71	60 120 240	60 60 60	466,1 419,4 353,5



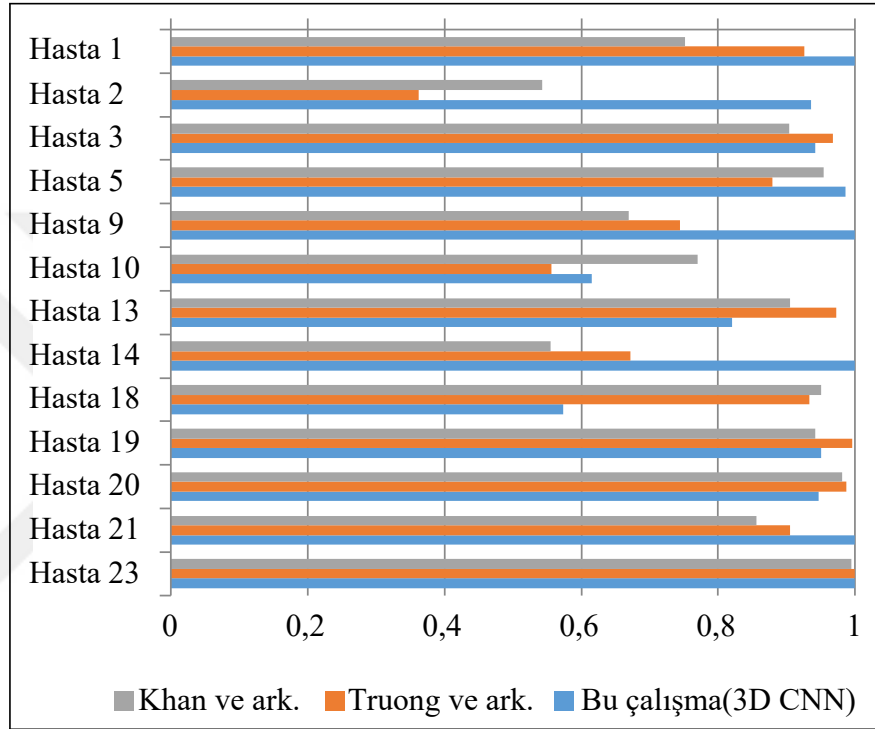
Bunun nedeni epileptik EEG işaretlerinde karakteristik değişimin pencere süresine kıyasla yavaş gerçekleşmesidir. Dolayısıyla epileptik EEG veri setinde, ardışık pencerelerden çıkarılacak öznitelikler arasındaki benzerlik fazla olduğundan, bunlardan birinin eğitimde kullanılması diğerinin testi sırasında yüksek başarımla elde edilmesini sağlayacaktır. Doğru başarımla değerleri elde edilebilmesi için epileptik EEG işaretleri gibi örneklerin birbiriyle zamansal ilintisinin bulunduğu veri setlerinin eğitiminde, birisi-dışarıda çapraz doğrulama benzeri yöntemlerin kullanılması gerekmektedir.

Bu tez çalışmasında epileptik nöbet tahmininde, çok kanallı EEG sinyallerinden elde edilen çok boyutlu görüntü serilerinin bir 3B CNN modeli ile sınıflandırıldığı bir yöntem kullanılmıştır. EEG verilerinden üretilen özniteliklerin görüntü olarak ele alınmasında, Bashivan ve arkadaşlarının, EEG verileriyle zihinsel yük tespiti üzerine yaptıkları çalışmada önerdikleri yaklaşım temel alınmıştır [87]. Bu çalışmada EEG aktiviteleri, uzamsal bilgilerin görmezden gelindiği standart EEG analiz tekniklerinin aksine, topolojinin korunduğu çok spektrumlu görüntü dizilerine dönüştürülmüştür. Daha sonra, görüntü dizilerinden gürbüz gösterimler elde etmek amacıyla, modern video sınıflandırma tekniklerinden ilham alınarak, bir derin evrişimli sinir ağı ile eğitim gerçekleştirilmiştir. Önerilen yaklaşım, EEG'nin uzamsal, spektral ve zamansal yapısını korumak için tasarlandığından; bu, her boyuttaki değişim ve bozulmalardan daha az etkilenen özniteliklerin elde edilmesini mümkün kılmaktadır.

Tez çalışmasında MIT Physionet sEEG veri setinden 16 hasta ile yapılan testlerde, önerilen 3B CNN modelinde %85,7 duyarlılık ve 0,096/saat yanlış pozitif oranı, %10,5 uyarıda harcanan zaman oranı ile elde edilmiştir. Tablo 5.1., Tablo 5.2. ve Tablo 5.3. önerilen CNN ve 3B CNN modellerinde, MLP modeline kıyasla daha düşük bir uyarıda geçen süre ve daha düşük bir FPR oranı ile daha yüksek duyarlılık elde edildiğini ortaya koymaktadır. Önerilen modellerin eğitimi sırasında, test verilerinin performansının gerçek koşullara benzer olmasını sağlamak amacıyla birisi-dışarıda çapraz doğrulama kullanılmıştır. Bu çalışmanın hiçbir aşamasında hastaya özel bir öznitelik mühendisliği gerçekleştirilmemiştir.

Bu tez çalışmasında önerilen yaklaşıma benzer olarak, Truong ve arkadaşları çalışmalarında EEG işaretlerinin hem zaman hem de frekans karakteristiğinin değerlendirilmesi amacıyla, öznitelik çıkarımında kısa zamanlı Fourier dönüşümünün (STFT) kullanıldığı, CNN tabanlı bir nöbet tahmin modeli önermiştir [12]. Epileptik evre uzunlukları ve çapraz doğrulama yöntemi açısından bu tez çalışmasıyla benzerlik taşıyan bu çalışmada, aynı veri setinden 13 hasta ile yapılan testlerde %81,2 duyarlılık ve 0,16/saat yanlış pozitif oranı değeri elde edilmiştir. Khan ve arkadaşları

nöbet tahmin çalışmalarında benzer bir yaklaşımla, ham EEG sinyallerinden dalgacık dönüşümü ile elde edilen özniteliklerin bir CNN'e girdi olarak verildiği bir yöntem önermiştir [11]. Bu çalışmada MIT Physionet sEEG veri setinden 15 hasta ile yapılan testlerde %87,8 duyarlılık ve 0,147/saat yanlış pozitif oranı elde edilmiştir. Bu nöbet tahmin yöntemlerinin başarımlarının doğrudan karşılaştırmak amacıyla, bu çalışmalarda değerlendirilen her bir hasta için elde edilen AUC değerleri Şekil 6.1.'de karşılaştırmalı olarak verilmiştir. Tez çalışmasında oluşturulan nöbet tahmin



Şekil 6.1. Khan ve ark., Truong ve ark. ve bu tez çalışmasında MIT Physionet sEEG veri setindeki hastalar için nöbet tahmininde elde edilen AUC değerleri karşılaştırması

modellerinde farklı epileptik evre zamanlamaları ile yapılan denemeler, epileptik evre uzunluklarının uygun belirlenmesinin, nöbet tahmin başarımını etkileyen önemli bir faktör olduğunu göstermiştir. Oluşturulan her iki modelde de en iyi AUC değerleri, Şekil 5.4.'de görüldüğü gibi, 60 dakika preiktal evre uzunluğu ve 240 dakika interiktal-iktal evre uzaklığı ile elde edilmiştir. İnteriktal ile iktal evre arasındaki mesafedeki artış nöbet tahmini performansını olumlu yönde etkilese de, diğer taraftan değerlendirilen toplam interiktal evre süresinde bir azalmaya neden olmaktadır. Tablo 6.2., değerlendirilen toplam interiktal veri süresinin, belirlenen interiktal-iktal evre uzaklığına göre değişimini göstermektedir.

Tez çalışmasında, farklı hastalar için sabit uzunluklu preiktal evre tanımlamasının nöbet tahmin başarımında oluşturacağı olumsuz etkiyi azaltmak amacıyla, değişken

Tablo 6.2. MIT Physionet sEEG veri setindeki hastalar için interiktal-iktal evre uzaklığına bağlı olarak toplam interiktal veri uzunluğunun değişimi

İteriktal-İktal Evre Uzaklığı	İteriktal Veri Uzunluğu (Saat)		
	60 Dakika	120 Dakika	240 Dakika
Hasta 1	28,6	22,6	14,4
Hasta 2	30,2	28,0	26,0
Hasta 3	30,4	29,4	27,4
Hasta 5	29,8	22,5	14,4
Hasta 7	61,8	57,3	51,3
Hasta 9	61,0	56,0	48,6
Hasta 10	36,9	31,6	24,2
Hasta 13	22,3	20,0	15,1
Hasta 14	16,4	10,7	4,7
Hasta 16	9,8	7,6	5,6
Hasta 17	16,1	15,1	11,8
Hasta 18	29,9	29,0	26,4
Hasta 19	27,0	27,0	27,0
Hasta 20	20,4	20,0	19,1
Hasta 21	28,3	26,4	23,4
Hasta 23	17,2	16,2	14,2
Toplam	466,1	419,4	353,5

ağırlıklı öğrenme yöntemi önerilmiştir. Değişken ağırlıklı öğrenmenin tahmin başarımı üzerindeki etkisi, MLP, CNN ve 3B CNN modeli için sırasıyla Tablo 5.4., Tablo 5.5. ve Tablo 5.6.'de verilmiştir. Genel yanlış pozitif oranında bir miktar iyileşme görülmesine rağmen duyarlılık değerlerindeki azalma, değişken ağırlıklı öğrenmenin toplam nöbet tahmin başarımını istenilen seviyede etkilemediğini göstermiştir.

Çalışmada önerilen yöntemlerin başarımının şanstan daha iyi olup olmadığını anlamak amacıyla, elde edilen sonuçlar Poisson tabanlı bir şans tahmincisi ile de karşılaştırılmıştır. Tablo 5.5. ve Tablo 5.6.'de sabit ağırlıklı öğrenme ile elde edilen sonuçlar, CNN modelinin Hasta-10 ve Hasta-18 dışındaki tüm hastalar için, 3B CNN modelinin ise Hasta-10 hariç tüm hastalar için şansa üstünlüğünün, 0,05 anlamlılık seviyesinde istatistiksel olarak anlamlı olduğunu göstermektedir.

Tez çalışmasının asıl amacı epileptik nöbet tespiti olsa da çalışmada oluşturulan CNN modelinin epileptojenik bölge tespitine uygulanabilirliği araştırılmış, kapama testi kullanılarak EEG öznitelik görüntüleri için kritik bölge ısı haritaları oluşturulmuştur. MIT Physionet sEEG veri setinden toplam 8 hasta için gerçekleştirilen kapama testinde, oluşturulan kritik bölge ısı haritalarının preiktal ve iktal evre örneklerinde

farklılaştığı görülmüştür. Aynı hastada farklı preiktal ve iktal evre verileri için 5-parçalı çapraz doğrulama ile elde edilen kritik bölge ısı haritalarında, preiktal ve iktal evreler için kortekste farklı bölgelerin daha etkili olduğu ortaya çıkmıştır. Elde edilen bu sonuç nöbetin beyin korteksinde epileptojenik bölgeden nöbet başlangıç bölgesine doğru yayıldığı hipotezini desteklemektedir. İktal evre öznitelik görüntüleri ile elde edilen kritik bölge ısı haritaları arasında belirli bir korelasyon gözlenmiştir. İktal evre öznitelik görüntülerinde, ortalama gücün fazla olduğu beyin bölgeleri ile ısı haritalarındaki kritik bölgeler genellikle uyuşmaktadır. Bu durum nöbetin gerçekleştiği iktal evre için, kortekste EEG işareti gücünün fazla olduğu bölgenin kritik olduğu sonucunu ortaya koymaktadır. Fakat aynı korelasyon preiktal evreler için geçerli değildir. Preiktal evreler için elde edilen ısı haritalarında kritik bölge, ilgili evrenin öznitelik görüntülerinde ortalama gücün yüksek olduğu bölgeden genellikle farklı bir beyin bölgesini göstermektedir.

Epileptik nöbetin gelişiminin, çıkarılan özniteliklerle ne kadar iyi temsil edildiğini araştırmak amacıyla öznitelik tabanlı kapama testi gerçekleştirilmiş, kullanılan 14 öznitelik için herbiri için kritik bölge ısı haritaları elde edilmiştir. Elde edilen sonuçlar, preiktal evre için mobilite ve karmaşıklık özniteliklerinin etkili olduğunu göstermektedir. İktal evrede ise mobilite ve karmaşıklığa ek olarak, spektral bant gücü ve varyans öznitelikleri de etkili olmaktadır. Bu durum, iktal evre için öznitelik görüntülerindeki ortalama güç ile kritik bölge ısı haritaları arasındaki korelasyonun nedeni olarak gösterilebilir. Ayrıca nöbet tahmin uygulamalarında, preiktal evre tespiti için mobilite ve karmaşıklık özniteliklerinin kullanılmasının yeterli olabileceği sonucu da ortaya çıkmaktadır.

## 7. SONUÇLAR VE ÖNERİLER

Bu tez çalışmasında, çok kanallı EEG sinyallerinden elde edilen özniteliklerin çok boyutlu bir görüntü serisi olarak değerlendirildiği, evrişimli sinir ağı (CNN) tabanlı, hastaya özgü bir nöbet tahmin yöntemi sunulmaktadır. EEG işaretlerinin frekans ve zaman bölgesi özniteliklerini ortaya çıkarmak için spektral bant gücü, istatistiksel moment ve Hjorth parametreleri kullanılmaktadır. Önerilen 3B (3 Boyutlu) CNN modeli, MIT Physionet kafa derisi EEG veri setinde, 16 hasta ile yapılan testlerde %85,7 duyarlılık ve 0,096/saat yanlış pozitif oranına, %10,5 uyarıda geçen zaman oranı ile ulaşmıştır. Sonuçlar, bu çalışmada önerilen nöbet tahmin yaklaşımının, benzer koşullar altında, en modern yaklaşımlara yakın bir performans sergilediğini göstermektedir. Önerilen yöntem, eğitim aşamasında hastaya özel bir mühendislik uygulanmadığı için genelleştirilebilir niteliktedir. Bununla birlikte, MIT Physionet kafa derisi EEG veri seti çoğunlukla pediatrik hastalardan oluştuğundan, yöntemin genel başarımını belirlemek için farklı yaş gruplarından, farklı klinik şartlar altında daha fazla deneyle kapsamlı testler gerçekleştirilmesi gerekmektedir.

Preiktal evre süresinin sabit uzunlukta belirlenmesinin, tahmin performansı üzerindeki olumsuz etkilerini azaltmak amacıyla, değişken ağırlıklı öğrenme önerilmiştir. Değişken ağırlıklı öğrenmede, preiktal örneklerin eğitim aşamasında, zamandaki konuma göre artan bir ağırlıkla kayıp fonksiyonunda temsil edildiği bir yaklaşım benimsenmiştir. Böylece, interiktal evreye yakın veriler ağırlık optimizasyonunda daha az etkili iken, iktal evreye yakın örnekler daha fazla etkili olmaktadır. Fakat bu yaklaşımla, nöbet tahmin başarımında beklenen iyileşme elde edilememiştir. Bu sonuç, iktal evreye yakın olan preiktal evre verileri için, gelmekte olan nöbete dair daha çok bilgi içereceği önermesinin doğru olmadığını göstermektedir. İleride yapılacak nöbet tahmin çalışmalarında, değişken ağırlıklı öğrenme ile bir hasta için farklı ağırlık fonksiyonunun denenmesi ve hastaya uygun preiktal ağırlık dağılımının bulunması durumunda, nöbet tahmin başarımının artacağı öngörülmektedir.

Farklı zamanlamalarla yapılan denemeler, epileptik evre sürelerinin hastaya uygun olarak belirlenmesinin, nöbet tahmin başarısını etkileyen önemli bir kriter olduğunu ortaya koymaktadır. Ayrıca, bu denemelerle elde edilen sonuçlar, interiktal evre ile iktal evre arasındaki uzaklık artışının nöbet tahmin performansını olumlu yönde etkilediğini göstermektedir. Bununla ilgili olarak, bazı preiktal aktivitelerin nöbet

başlamadan birkaç saat önce ortaya çıkmaya başladığı sonucuna da ulaştırmaktadır. Dolayısıyla nöbet tahmininde, EEG işaretlerini sabit uzunluklu epileptik evrelere ayırarak sınıflandırmak yerine, sürekli bir nöbet olasılığı tahmini sağlayan bir yaklaşımın kullanılması, daha genelleştirilebilir nöbet tahmin modellerinin oluşturulmasını mümkün kılacaktır.

EEG öznitelik görüntülerinden kapama testi ile oluşturulan kritik bölge ısı haritaları, önerilen CNN modeli ile yapılan sınıflandırma için, preiktal ve iktal evrelerde beyin farklı bölgelerinin kritik olduğunu ortaya koymaktadır. Bu yaklaşımın, beyin korteksinde epileptojenik bölge tespiti için faydalı olabileceği düşünülmektedir. Ayrıca preiktal ve iktal evrede bu kritik bölgelerin farklılaşması, nöbetin beyin korteksinde belirli bir bölgeden başlayarak, klinik olarak ortaya çıktığı bölgeye doğru yayıldığı hipotezini de destekler niteliktedir. Epileptik öznitelik görüntülerine uygulanan, öznitelik tabanlı kapama testi ile hangi özneliğin preiktal ve iktal evre tespitinde etkili olduğu ortaya çıkarılmaya çalışılmıştır. Buna göre mobilite ve komplekslik öznitelikleri, preiktal evre için belirleyici ölçümlerdir. Dolayısıyla geliştirilecek yeni bir nöbet tahmin metodunda, mobilite ve karmaşıklık özniteliklerinin kullanımı ile kabul edilebilir bir başarıml elde edileceği düşünülmektedir.

## KAYNAKLAR

- [1] Yadollahpour A., Jalilifar M., Seizure Prediction Methods: A Review of the Current Predicting Techniques, *Biomedical and Pharmacology Journal*, 2015, **7**(1), 153–162.
- [2] Carney P. R., Myers S., Geyer J. D., Seizure Prediction: Methods, *Epilepsy & Behavior*, 2011, **22**(1), 94–101.
- [3] Spencer S., Huh L., Outcomes of Epilepsy Surgery in Adults and Children, *The Lancet Neurology*, 2008, **7**(6), 525–537.
- [4] Freestone D. R., Karoly P. J., Cook M. J., A Forward-looking Review of Seizure Prediction, *Current Opinion in Neurology*, 2017, **30**(2), 167–173.
- [5] Dumanis S. B., French J. A., Bernard C., Worrell G. A., Fureman B. E., Seizure Forecasting from Idea to Reality. Outcomes of the My Seizure Gauge Epilepsy Innovation Institute Workshop, *eNeuro*, 2017, **4**(6), 1–5.
- [6] Baud M. O., Rao V. R., Gauging Seizure Risk, *Neurology*, 2018, **91**(21), 967–973.
- [7] Kuhlmann L., Lehnertz K., Richardson M. P., Schelter B., Zaveri H. P., Seizure Prediction—ready for a New Era, *Nature Reviews Neurology*, 2018, **14**(10), 618–630.
- [8] Stacey W. C., Seizure Prediction Is Possible—Now Let’s Make It Practical, *EBioMedicine*, 2018, **27**(1), 1–2.
- [9] Bandarabadi M., Teixeira C. A., Rasekhi J., Dourado A., Epileptic Seizure Prediction Using Relative Spectral Power Features, *Clinical Neurophysiology*, 2015, **126**(2), 237–248.
- [10] Chu H., Chung C. K., Jeong W., Cho K.-H., Predicting Epileptic Seizures from Scalp EEG Based on Attractor State Analysis, *Computer Methods and Programs in Biomedicine*, 2017, **143**(1), 75–87.
- [11] Khan H., Marcuse L., Fields M., Swann K., Yener B., Focal Onset Seizure Prediction Using Convolutional Networks, *IEEE Transactions on Biomedical Engineering*, 2017, **65**(9), 2109–2118.
- [12] Truong N. D., Nguyen A. D., Kuhlmann L., Bonyadi M. R., Yang J., Ippolito S., Kavehei O., Convolutional Neural Networks for Seizure Prediction Using Intracranial and Scalp Electroencephalogram, *Neural Networks*, 2018, **105**(1), 104–111.

- [13] Zandi A. S., Tafreshi R., Javidan M., Dumont G. A., Predicting Epileptic Seizures in Scalp EEG Based on a Variational Bayesian Gaussian Mixture Model of Zero-crossing Intervals, *IEEE Transactions on Biomedical Engineering*, 2013, **60**(5), 1401–1413.
- [14] Zhang Z., Parhi K. K., Low-complexity Seizure Prediction from iEEG/sEEG Using Spectral Power and Ratios of Spectral Power, *IEEE Transactions on Biomedical Circuits and Systems*, 2015, **10**(3), 693–706.
- [15] Alotaiby T. N., Alshebeili S. A., Alotaibi F. M., Alrshoud S. R., Epileptic Seizure Prediction Using CSP and LDA for Scalp EEG Signals, *Computational Intelligence and Neuroscience*, 2017, **2017**(1), 1–11.
- [16] Cho D., Min B., Kim J., Lee B., EEG-based Prediction of Epileptic Seizures Using Phase Synchronization Elicited from Noise-assisted Multivariate Empirical Mode Decomposition, *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2016, **25**(8), 1309–1318.
- [17] Cook M. J., O’Brien T. J., Berkovic S. F., Murphy M., Morokoff A., Fabinyi G., D’Souza W., Yerra R., Archer J., Litewka L., Prediction of Seizure Likelihood with a Long-term, Implanted Seizure Advisory System in Patients with Drug-resistant Epilepsy: a First-in-man Study, *The Lancet Neurology*, 2013, **12**(6), 563–571.
- [18] Kiral-Kornek I., Roy S., Nurse E., Mashford B., Karoly P., Carroll T., Payne D., Saha S., Baldassano S., O’Brien T., Epileptic Seizure Prediction Using Big Data and Deep Learning: Toward a Mobile System, *EBioMedicine*, 2018, **27**(1), 103–111.
- [19] Mormann F., Kreuz T., Rieke C., Andrzejak R. G., Kraskov A., David P., Elger C. E., Lehnertz K., On the Predictability of Epileptic Seizures, *Clinical Neurophysiology*, 2005, **116**(3), 569–587.
- [20] Park Y., Luo L., Parhi K. K., Netoff T., Seizure Prediction with Spectral Power of EEG Using Cost-sensitive Support Vector Machines, *Epilepsia*, 2011, **52**(10), 1761–1770.
- [21] Chisci L., Mavino A., Perferi G., Sciandrone M., Anile C., Colicchio G., Fuggetta F., Real-time Epileptic Seizure Prediction Using AR Models and Support Vector Machines, *IEEE Transactions on Biomedical Engineering*, 2010, **57**(5), 1124–1132.
- [22] Litt B., Esteller R., Echaz J., D’Alessandro M., Shor R., Henry T., Pennell P., Epstein C., Bakay R., Dichter M., Epileptic Seizures May Begin Hours in Advance of Clinical Onset: a Report of Five Patients, *Neuron*, 2001, **30**(1), 51–64.



- [23] Tsiouris K. M., Pezoulas V. C., Zervakis M., Konitsiotis S., Koutsouris D. D., Fotiadis D. I., A Long Short-Term Memory Deep Learning Network for the Prediction of Epileptic Seizures Using EEG Signals, *Computers in Biology and Medicine*, 2018, **99**(1), 24–37.
- [24] Iasemidis L. D., Shiau D.-S., Chaovalitwongse W., Sackellares J. C., Pardalos P. M., Principe J. C., Carney P. R., Prasad A., Veeramani B., Tsakalis K., Adaptive Epileptic Seizure Prediction System, *IEEE Transactions on Biomedical Engineering*, 2003, **50**(5), 616–627.
- [25] Lehnertz K., Elger C. E., Can Epileptic Seizures Be Predicted? Evidence from Nonlinear Time Series Analysis of Brain Electrical Activity, *Physical Review Letters*, 1998, **80**(22), 5019–5022.
- [26] Le Van Quyen M., Soss J., Navarro V., Robertson R., Chavez M., Baulac M., Martinerie J., Preictal State Identification by Synchronization Changes in Long-term Intracranial EEG Recordings, *Clinical Neurophysiology*, 2005, **116**(3), 559–568.
- [27] Kuhlmann L., Freestone D., Lai A., Burkitt A. N., Fuller K., Grayden D. B., Seiderer L., Vogrin S., Mareels I. M., Cook M. J., Patient-specific Bivariate-synchrony-based Seizure Prediction for Short Prediction Horizons, *Epilepsy Research*, 2010, **91**(2-3), 214–231.
- [28] Al Ghayab H. R., Li Y., Siuly S., Abdulla S., A Feature Extraction Technique Based on Tunable Q-factor Wavelet Transform for Brain Signal Classification, *Journal of Neuroscience Methods*, 2019, **312**(1), 43–52.
- [29] Fei K., Wang W., Yang Q., Tang S., Chaos Feature Study in Fractional Fourier Domain for Preictal Prediction of Epileptic Seizure, *Neurocomputing*, 2017, **249**(1), 290–298.
- [30] Shiao H.-T., Cherkassky V., Lee J., Veber B., Patterson E. E., Brinkmann B. H., Worrell G. A., SVM-based System for Prediction of Epileptic Seizures from iEEG Signal, *IEEE Transactions on Biomedical Engineering*, 2016, **64**(5), 1011–1022.
- [31] Behnam M., Pourghassem H., Real-time Seizure Prediction Using RLS Filtering and Interpolated Histogram Feature Based on Hybrid Optimization Algorithm of Bayesian Classifier and Hunting Search, *Computer Methods and Programs in Biomedicine*, 2016, **132**(1), 115–136.
- [32] Özcan A. R., Ertürk S., Epileptic Seizure Prediction with Recurrent Convolutional Neural Networks, *25th Signal Processing and Communications Applications Conference (SIU)*, Antalya, Türkiye, 15 – 18 Mayıs 2017.
- [33] Angeles D., Proposal for Revised Clinical and Electroencephalographic Classification of Epileptic Seizures, *Epilepsia*, 1981, **22**(4), 489–501.

- [34] Panayiotopoulos C. P., Typical Absence Seizures and Related Epileptic Syndromes: Assessment of Current State and Directions for Future Research, *Epilepsia*, 2008, **49**(12), 2131–2139.
- [35] Henry J. C., Electroencephalography: Basic Principles, Clinical Applications, and Related Fields, *Neurology*, 2006, **67**(11), 2092–2092.
- [36] Malmivuo P., Malmivuo J., Plonsey R., *Bioelectromagnetism: Principles and Applications of Bioelectric and Biomagnetic Fields*, 1st ed., Oxford University Press, USA, 1995.
- [37] Varsavsky A., Mareels I., Cook M., *Epileptic Seizures and the EEG: Measurement, Models, Detection and Prediction*, 1st ed., CRC Press, USA, 2016.
- [38] Brodbeck V., Spinelli L., Lascano A. M., Wissmeier M., Vargas M.-I., Vulliemoz S., Pollo C., Schaller K., Michel C. M., Seeck M., Electroencephalographic Source Imaging: a Prospective Study of 152 Operated Epileptic Patients, *Brain*, 2011, **134**(10), 2887–2897.
- [39] Rasekhi J., Mollaei M. R. K., Bandarabadi M., Teixeira C. A., Dourado A., Preprocessing Effects of 22 Linear Univariate Features on the Performance of Seizure Prediction Methods, *Journal of Neuroscience Methods*, 2013, **217**(1-2), 9–16.
- [40] Mormann F., Andrzejak R. G., Elger C. E., Lehnertz K., Seizure Prediction: the Long and Winding Road, *Brain*, 2006, **130**(2), 314–333.
- [41] Salant Y, Gath I, Henriksen O, Prediction of Epileptic Seizures from Two-channel EEG, *Medical and Biological Engineering and Computing*, 1998, **36**(5), 549–556.
- [42] Schelter B., Winterhalder M., Maiwald T., Brandt A., Schad A., Schulze-Bonhage A., Timmer J., Testing Statistical Significance of Multivariate Time Series Analysis Techniques for Epileptic Seizure Prediction, *Chaos: An Interdisciplinary Journal of Nonlinear Science*, 2006, **16**(1), 1–10.
- [43] Le Van Quyen M., Martinerie J., Navarro V., Boon P., D’Havé M., Adam C., Renault B., Varela F., Baulac M., Anticipation of Epileptic Seizures from Standard EEG Recordings, *The Lancet*, 2001, **357**(9251), 183–188.
- [44] Lehnertz K., Mormann F., Kreuz T., Andrzejak R. G., Rieke C., David P., Elger C. E., Seizure Prediction by Nonlinear EEG Analysis, *IEEE Engineering in Medicine and Biology Magazine*, 2003, **22**(1), 57–63.

- [45] Teixeira C. A., Direito B., Bandarabadi M., Le Van Quyen M., Valderrama M., Schelter B., Schulze-Bonhage A., Navarro V., Sales F., Dourado A., Epileptic Seizure Predictors Based on Computational Intelligence Techniques: A Comparative Study with 278 Patients, *Computer Methods and Programs in Biomedicine*, 2014, **114**(3), 324–336.
- [46] Petrosian A., Prokhorov D., Homan R., Dasheiff R., Wunsch II D., Recurrent Neural Network Based Prediction of Epileptic Seizures in Intra-and Extracranial EEG, *Neurocomputing*, 2000, **30**(1-4), 201–218.
- [47] Bandarabadi M., Teixeira C. A., Sales F., Dourado A., Wepilet, Optimal Orthogonal Wavelets for Epileptic Seizure Prediction with One Single Surface Channel, *Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, Boston, MA, USA, 30 Ağustos – 3 Eylül 2011.
- [48] Netoff T., Park Y., Parhi K., Seizure Prediction Using Cost-sensitive Support Vector Machine, *Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, Boston, MA, USA, 2 – 6 Eylül 2009.
- [49] Kaplan D. T., Glass L., Direct Test for Determinism in a Time Series, *Physical Review Letters*, 1992, **68**(4), 427–430.
- [50] Duckrow R. B., Spencer S. S., Regional Coherence and the Transfer of Ictal Activity During Seizure Onset in the Medial Temporal Lobe, *Electroencephalography and Clinical Neurophysiology*, 1992, **82**(6), 415–422.
- [51] Hjorth B., EEG Analysis Based on Time Domain Properties, *Electroencephalography and Clinical Neurophysiology*, 1970, **29**(3), 306–310.
- [52] Quiroga R. Q., Kreuz T., Grassberger P., Event Synchronization: a Simple and Fast Method to Measure Synchronicity and Time Delay Patterns, *Physical Review E*, 2002, **66**(4), 1–9.
- [53] Williamson J. R., Bliss D. W., Browne D. W., Narayanan J. T., Seizure Prediction Using EEG Spatiotemporal Correlation Structure, *Epilepsy & Behavior*, 2012, **25**(2), 230–238.
- [54] Guo L., Rivero D., Dorado J., Rabunal J. R., Pazos A., Automatic Epileptic Seizure Detection in EEGs Based on Line Length Feature and Artificial Neural Networks, *Journal of Neuroscience Methods*, 2010, **191**(1), 101–109.
- [55] Esteller R., Echaz J., Tcheng T, Litt B., Pless B., Line Length: An Efficient Feature for Seizure Onset Detection, *23rd Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, İstanbul, Türkiye, 25 – 28 Ekim 2001.

- [56] Esteller R, Echauz J, Tcheng T, Comparison of Line Length Feature Before and After Brain Electrical Stimulation in Epileptic Patients, *26th Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, San Francisco, CA, USA, 1 – 5 Eylül 2004.
- [57] Feldwisch-Drentrup H., Schelter B., Jachan M., Nawrath J., Timmer J., Schulze-Bonhage A., Joining the Benefits: Combining Epileptic Seizure Prediction Methods, *Epilepsia*, 2010, **51**(8), 1598–1606.
- [58] Osorio I., Frei M. G., Wilkinson S. B., Real-time Automated Detection and Quantitative Analysis of Seizures and Short-term Prediction of Clinical Onset, *Epilepsia*, 1998, **39**(6), 615–627.
- [59] Rieke C., Sternickel K., Andrzejak R. G., Elger C. E., David P., Lehnertz K., Measuring Nonstationarity by Analyzing the Loss of Recurrence in Dynamical Systems, *Physical Review Letters*, 2002, **88**(24), 1–4.
- [60] Silva F. L. de, Computer-assisted EEG diagnosis: pattern recognition and brain mapping, *Electroencephalography: Basic Principles, Clinical Applications and Related Fields*, 1998, **4**(1), 1164–1189.
- [61] Rosenblum M. G., Pikovsky A. S., Kurths J., From Phase to Lag Synchronization in Coupled Chaotic Oscillators, *Physical Review Letters*, 1997, **78**(22), 4193–4196.
- [62] Schindler K., Leung H., Elger C. E., Lehnertz K., Assessing Seizure Dynamics by Analysing the Correlation Structure of Multichannel Intracranial EEG, *Brain*, 2006, **130**(1), 65–77.
- [63] Übeyli E. D., Lyapunov Exponents/probabilistic Neural Networks for Analysis of EEG Signals, *Expert Systems with Applications*, 2010, **37**(2), 985–992.
- [64] Maiwald T., Winterhalder M., Aschenbrenner-Scheibe R., Voss H. U., Schulze-Bonhage A., Timmer J., Comparison of Three Nonlinear Seizure Prediction Methods by Means of the Seizure Prediction Characteristic, *Physica D: Nonlinear Phenomena*, 2004, **194**(3-4), 357–368.
- [65] Pijn J. P. M., Velis D. N., Van Der Heyden M. J., DeGoede J., Van Veelen C. W., Da Silva F. H. L., Nonlinear Dynamics of Epileptic Seizures on Basis of Intracranial EEG Recordings, *Brain Topography*, 1997, **9**(4), 249–270.
- [66] Blanco S., Garay A., Coulombie D., Comparison of Frequency Bands Using Spectral Entropy for Epileptic Seizure Prediction, *ISRN Neurology*, 2013, **2013**(1), 1–5.
- [67] Drongelen W. van, Nayak S., Frim D. M., Kohrman M. H., Towle V. L., Lee H. C., McGee A. B., Chico M. S., Hecox K. E., Seizure Anticipation in Pediatric Epilepsy: Use of Kolmogorov Entropy, *Pediatric Neurology*, 2003, **29**(3), 207–213.

- [68] Li X., Ouyang G., Richards D. A., Predictability Analysis of Absence Seizures with Permutation Entropy, *Epilepsy Research*, 2007, **77**(1), 70–74.
- [69] Le Van Quyen M., Soss J., Navarro V., Robertson R., Chavez M., Baulac M., Martinerie J., Preictal State Identification by Synchronization Changes in Long-term Intracranial EEG Recordings, *Clinical Neurophysiology*, 2005, **116**(3), 559–568.
- [70] Aarabi A, Fazel-Rezai R, Aghakhani Y, EEG Seizure Prediction: Measures and Challenges, *Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, Boston, MA, USA, 2 – 6 Eylül 2009.
- [71] Krizhevsky A., Sutskever I., Hinton G. E., Imagenet Classification with Deep Convolutional Neural Networks, *Advances in Neural Information Processing Systems*, Tahoe, NV, USA, 3 – 8 Aralık 2012.
- [72] Aggarwal C. C., *Neural Networks and Deep Learning*, 1st ed., Springer, Germany, 2018.
- [73] Wani M. A., Bhat F. A., Afzal S., Khan A. I., *Advances in Deep Learning*, 1st ed., Springer, Germany, 2020.
- [74] LeCun Y., Bottou L., Bengio Y., Haffner P., Gradient-based Learning Applied to Document Recognition, *Proceedings of the IEEE*, 1998, **86**(11), 2278–2324.
- [75] Zeiler M. D., Fergus R., Visualizing and Understanding Convolutional Networks, *European Conference on Computer Vision*, Zurich, Switzerland, 5 – 12 Eylül 2014.
- [76] Simonyan K., Zisserman A., Very Deep Convolutional Networks for Large-Scale Image Recognition, *ArXiv Preprint*, 2014, arXiv:1409.1556.
- [77] Szegedy C., Liu W., Jia Y., Sermanet P., Reed S., Anguelov D., Erhan D., Vanhoucke V., Rabinovich A., Going Deeper with Convolutions, *28th IEEE Conference on Computer Vision and Pattern Recognition*, Boston, MA, USA, 7 – 12 Haziran 2015.
- [78] He K., Zhang X., Ren S., Sun J., Deep Residual Learning for Image Recognition, *29th IEEE Conference on Computer Vision and Pattern Recognition*, Las Vegas, NV, USA, 27 – 30 Haziran 2016.
- [79] Deng J., Dong W., Socher R., Li L.-J., Li K., Fei-Fei L., Imagenet: A Large-scale Hierarchical Image Database, *22nd IEEE Conference on Computer Vision and Pattern Recognition*, Miami, FL, USA, 20 – 25 Haziran 2012.
- [80] Witten I. H., Frank E., Hall M. A., Pal C. J., *Data Mining: Practical Machine Learning Tools and Techniques*, 2nd ed., Morgan Kaufmann, USA, 2016.

- [81] Ruder S., An Overview of Gradient Descent Optimization Algorithms, *ArXiv Preprint*, 2016, arXiv:1609.04747.
- [82] Kingma D. P., Ba J., Adam: A Method for Stochastic Optimization, *ArXiv Preprint*, 2014, arXiv:1412.6980.
- [83] Glorot X., Bengio Y., Understanding the Difficulty of Training Deep Feedforward Neural Networks, *Thirteenth International Conference on Artificial Intelligence and Statistics*, Sardinia, Italy, 13 – 15 May 2010.
- [84] Goodfellow I., Bengio Y., Courville A., *Deep Learning*, 1st ed., MIT Press, USA, 2016.
- [85] Goldberger A. L., Amaral L. A., Glass L., Hausdorff J. M., Ivanov P. C., Mark R. G., Mietus J. E., Moody G. B., Peng C.-K., Stanley H. E., PhysioBank, PhysioToolkit, and PhysioNet: Components of a New Research Resource for Complex Physiologic Signals, *Circulation*, 2000, **101**(23), 215–220.
- [86] Shoeb A. H., Application of Machine Learning to Epileptic Seizure Onset Detection and Treatment, PhD thesis, Massachusetts Institute of Technology, Health Sciences and Technology, Boston, USA, 2009.
- [87] Bashivan P., Rish I., Yeasin M., Codella N., Learning Representations from EEG with Deep Recurrent-Convolutional Neural Networks, *ArXiv Preprint*, 2015, arXiv:1511.06448.
- [88] Snyder J. P., *Map Projections—A Working Manual*, 1st ed., US Government Printing Office, USA, 2012.
- [89] Alfeld P., A Trivariate Clough—Tocher Scheme for Tetrahedral Data, *Computer Aided Geometric Design*, 1984, **1**(2), 169–181.
- [90] Mirowski P. W., LeCun Y., Madhavan D., Kuzniecky R., Comparing SVM and Convolutional Networks for Epileptic Seizure Prediction from Intracranial EEG, *IEEE Workshop on Machine Learning for Signal Processing*, Cancun, Mexico, 16 – 19 Ekim 2008.
- [91] Cao X., A Practical Theory for Designing Very Deep Convolutional Neural Networks, *Ottawa University*, 1-6, 2015,
- [92] Dieleman S., Schlüter J., Raffel C., Olson E., Sønderby S. K., Nouri D., Maturana D., Thoma M., Battenberg E., Kelly J., Lasagne: First Release, *Zenodo*, DOI:10.5281/zenodo.27878.
- [93] Al-Rfou R., Alain G., Almahairi A., Angermueller C., Bahdanau D., Ballas N., Bastien F., Bayer J., Belikov A., Belopolsky A., Theano: A Python Framework for Fast Computation of Mathematical Expressions, *ArXiv Preprint*, 2016, arXiv:1605.02688.

- [94] Snyder D. E., Echauz J., Grimes D. B., Litt B., The Statistics of a Practical Seizure Warning System, *Journal of Neural Engineering*, 2008, **5**(4), 392–401.
- [95] Lüders H. O., Turnbull J., Kaffashi F., Are the Dichotomies Generalized Versus Focal Epilepsies and Idiopathic Versus Symptomatic Epilepsies Still Valid in Modern Epileptology? *Epilepsia*, 2009, **50**(6), 1336–1343.
- [96] Pati S., Cole A. J., How Focal Is Generalized Epilepsy: A Distinction with a Difference, *Epilepsy & Behavior*, 2014, **34**(1), 127–128.
- [97] Rosenow F., Lüders H., Presurgical Evaluation of Epilepsy, *Brain*, 2001, **124**(9), 1683–1700.
- [98] Myers M. H., Padmanabha A., Hossain G., De Jongh Curry A. L., Blaha C. D., Seizure Prediction and Detection via Phase and Amplitude Lock Values, *Frontiers in Human Neuroscience*, 2016, **10**(8), 1–9.
- [99] Gibbons J. D., Chakraborti S., *Nonparametric Statistical Inference*, 5th ed., Chapman and Hall, UK, 2010.
- [100] Wilcoxon F., Wilcox R. A., *Some Rapid Approximate Statistical Procedures*, 5th ed., Lederle Laboratories, USA, 1964.



**EKLER**



## Ek-A


### Wilcoxon İşaretli Sıralama Testi

Wilcoxon işaretli sıralama testi, iki ilişkili örnek grubunu karşılaştırmak için kullanılan, parametrik olmayan bir istatistiksel hipotez testidir [99]. Bu test, eşleştirilmiş örneklem t-testinin parametrik olmayan eşdeğeridir. Parametrik ve parametrik olmayan teknikler arasındaki temel fark, parametrik tekniklerde verilerin normal dağılım gibi bir dağılımı izlediğinin varsayılmasıdır. Veri sayısının az olduğu ya da yeterli veri olsa da dağılımın anormal olduğu durumlarda t-testi koşulları sağlanamadığından, Wilcoxon işaretli sıralama testi gibi parametrik olmayan testler tercih edilmektedir. Pek çok parametrik olmayan testte olduğu gibi, Wilcoxon işaretli sıralama testi de rankları temel almaktadır. Verilerin eşleştirilmesi, iki örnek grubundaki değerlerin doğal olarak bağlantılı olduğu ve genellikle birden fazla kez yapılan ölçümle elde edildiği anlamına gelmektedir. Örneğin, bir veri setinde her hasta için iki farklı sınıflandırma denemesi için elde edilen duyarlılık değeri birbiriyle eşleştirilmektedir. Bu duyarlılık değerleri aynı hastalara ait olduğu için birbirinden bağımsız değildir. Burada elde edilen duyarlılık değerleri için iki sınıflandırma denemesi arasındaki farka odaklanılmakta ve iki deneme arasında anlamlı bir fark olup olmadığı incelenmektedir.  $N$  örnek çifti büyüklüğü,  $x_{1,i}$  ve  $x_{2,i}$   $i = 1, \dots, N$  için örnek çiftleri olmak üzere, Wilcoxon işaretli sıralama testi aşağıdaki adımlardan oluşmaktadır.

1.  $N$  örnek çiftinden her biri için fark değeri  $D_i = (x_{2,i} - x_{1,i})$  ve bu değerlerin mutlak değeri  $|D_i| = |x_{2,i} - x_{1,i}|$  hesaplanır.
2. Örnek çiftlerinden varsa fark değerleri  $(x_{2,i} - x_{1,i}) = 0$  olan örnekler çıkarılarak  $N_r$  azaltılmış örnek çifti grubu elde edilir.
3.  $N_r$  örnek çifti fark değerleri mutlak büyüklükleri  $|D_i|$  göre sıralanarak, en küçük değer 1 en büyük değer  $N_r$  olacak şekilde  $R_i$  etiketleri atanır. Eğer iki ya da daha fazla örnek çifti için  $|D_i|$  değeri birbirine eşitse, bu örneklerin etiket değerlerinin ortalaması alınarak her birine bu ortalama etiket değeri atanır.
4. Her örnek çifti için belirlenen etiket değeri  $R_i$ , bulunan farkın işaret değeri  $S_i = \text{sign}(x_{2,i} - x_{1,i})$  ile çarpılarak, işaretli rank değerleri elde edilir.  $R_i^{(+)}$  pozitif rank değerlerini,  $R_i^{(-)}$  negatif rank değerlerini ifade etmektedir.
5. Wilcoxon test istatistik değeri  $W$ , Denklem (1)'deki gibi pozitif rank değerlerinin toplamı olarak hesaplanır.

$$W = \sum_{i=1}^{N_r} R_i^{(+)} \quad (1)$$

6. Burada hipotez testleri;
  - Sıfır hipotezi ( $H_0$ ): örnek çiftleri arasındaki fark, sıfıra yakın simetrik bir dağılım izlemektedir.
  - Alternatif hipotez ( $H_1$ ): örnek çiftleri arasındaki fark, sıfıra yakın simetrik bir dağılım izlememektedir.
7. Wilcoxon test istatistik değeri  $W$ , minimum 0 (tüm fark değerlerinin negatif



Şekil A.1. Wilcoxon işaretli sıralama testinde hipotez kabul ve hipotez reddetme bölgeleri

olduğu durum) ile maksimum  $N_r(N_r + 1)/2$  (tüm fark değerlerinin pozitif olduğu durum) değerleri arasında olacaktır. Sıfır hipotezinin doğru kabul edildiği durum için, test istatistik değeri  $W$ 'nin ortalama değer  $\mu_W = N_r(N_r + 1)/4$ 'ye yakın olması beklenmektedir.

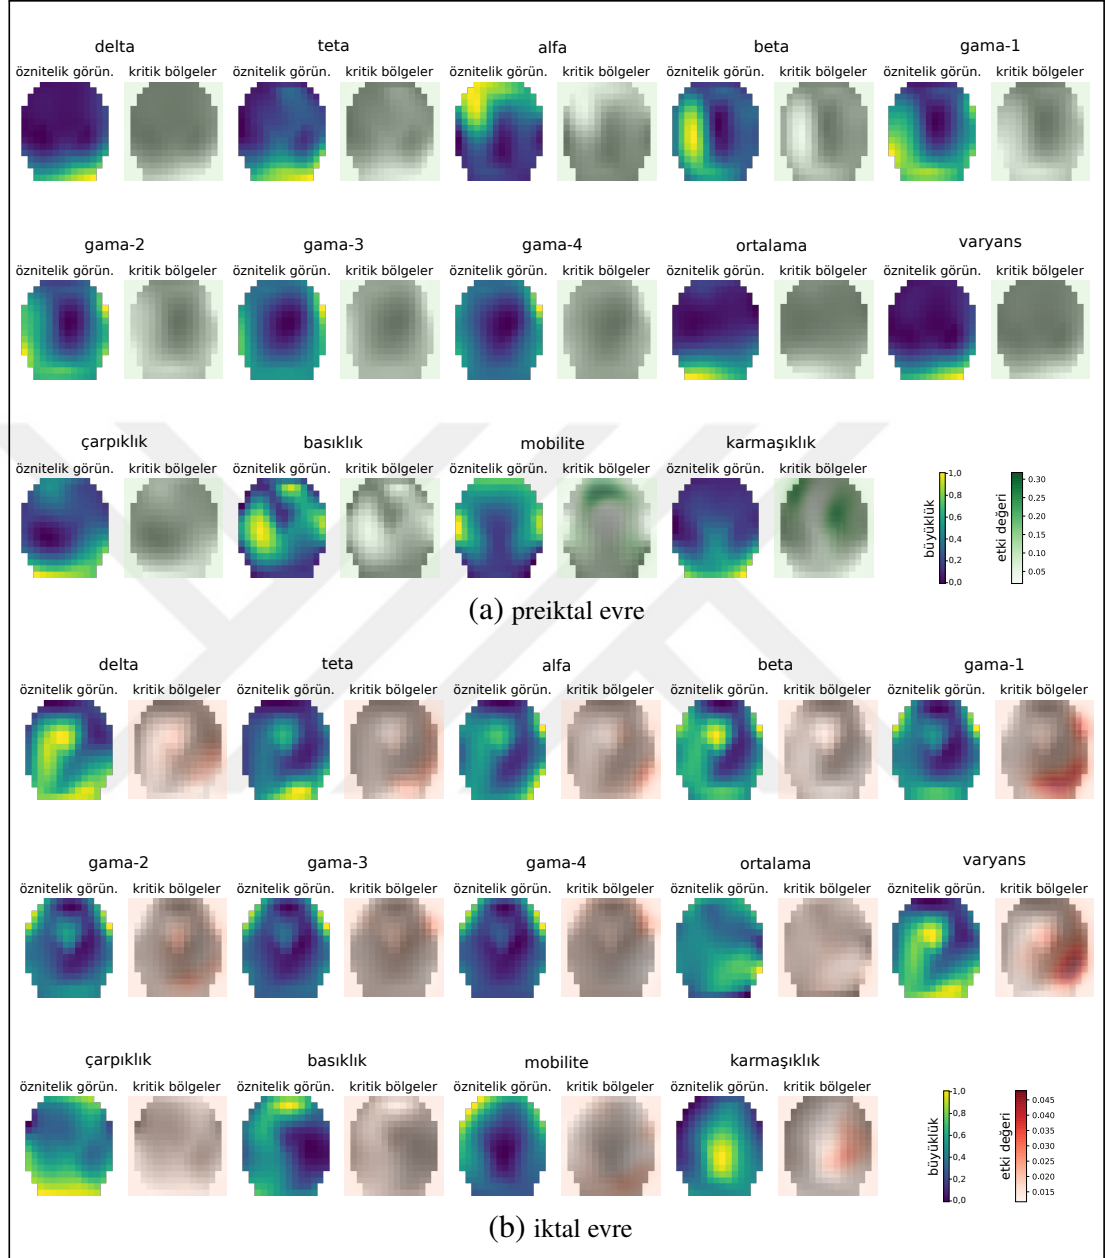
Test istatistik değeri  $W$ 'nin tek ve çift-tarafli testlerde  $N_r \leq 20$  örnek için üst ve alt kritik değerleri Tablo A.1.'de verilmektedir. Çift-tarafli testte hesaplanan  $W$  değeri Şekil A.1..a'daki gibi üst kritik değerden büyük eşit ya da alt kritik değerden küçük eşitse sıfır hipotezi reddedilmektedir. Alt tek-tarafli bir test için hesaplanan  $W$  değeri Şekil A.1..b'deki gibi alt kritik değerden küçük veya eşitse sıfır hipotezi reddedilirken, üst tek-tarafli bir test için hesaplanan  $W$  değeri Şekil A.1..c'deki gibi üst kritik değerden büyük veya eşitse sıfır hipotezi reddedilmektedir.

Tablo A.1. Wilcoxon işaretli sıralama testinde, istatistik değeri  $W$  için alt ve üst kritik değerler [100]

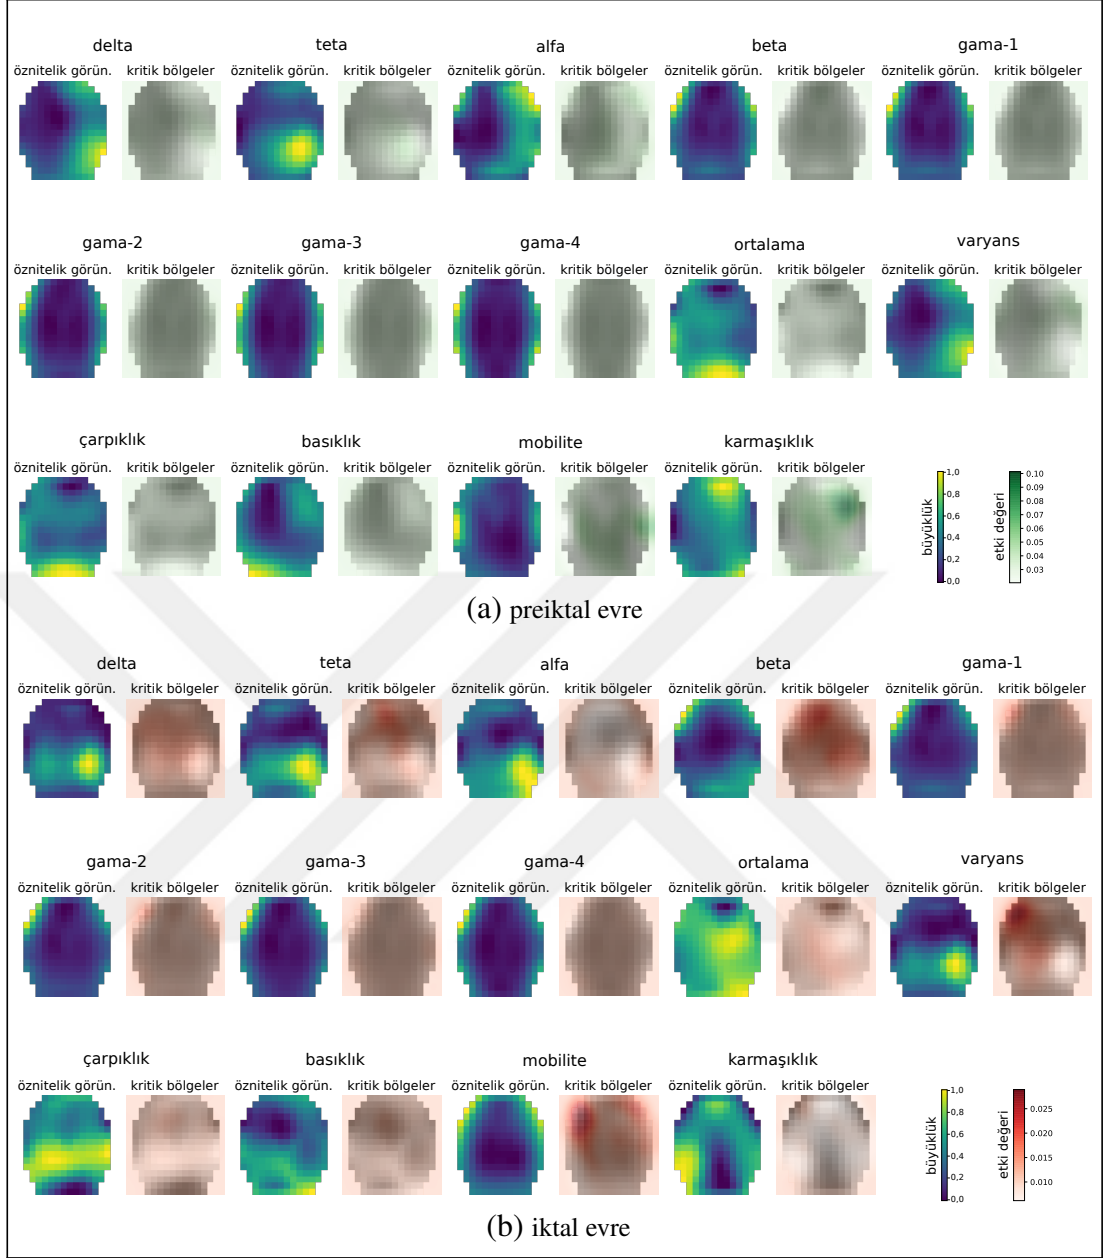
Tek-Tarafli	$\alpha = ,05$	$\alpha = ,025$	$\alpha = ,01$	$\alpha = ,005$
Çift-Tarafli	$\alpha = ,10$	$\alpha = ,05$	$\alpha = ,02$	$\alpha = ,01$
n	(Alt Değer / Üst Değer)			
5	0 / 15	— / —	— / —	— / —
6	2 / 19	0 / 21	— / —	— / —
7	3 / 25	2 / 26	0 / 28	— / —
8	5 / 31	3 / 33	1 / 35	0 / 36
9	8 / 37	5 / 4	3 / 42	1 / 44
10	10 / 45	8 / 47	5 / 5	3 / 52
11	13 / 53	10 / 56	7 / 59	5 / 61
12	17 / 61	13 / 65	10 / 68	7 / 71
13	21 / 7	17 / 74	12 / 79	10 / 81
14	25 / 8	21 / 84	16 / 89	13 / 92
15	30 / 9	25 / 95	19 / 101	16 / 104
16	35 / 101	29 / 107	23 / 113	19 / 117
17	41 / 112	34 / 119	27 / 126	23 / 13
18	47 / 124	40 / 131	32 / 139	27 / 144
19	53 / 137	46 / 144	37 / 153	32 / 158
20	60 / 15	52 / 158	43 / 167	37 / 173

## Ek-B

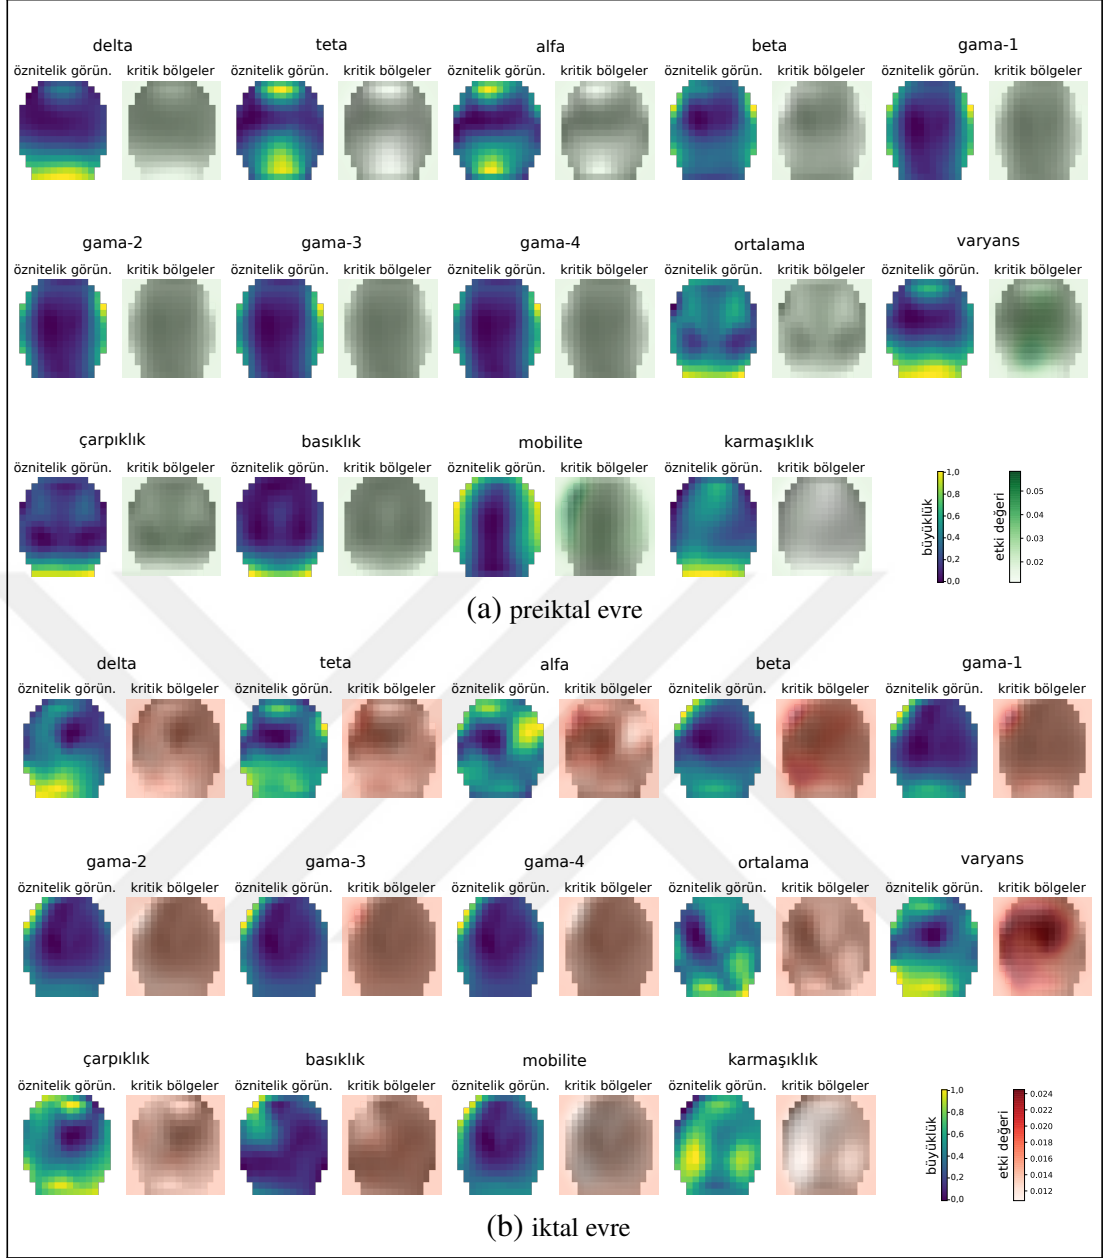
### Öznitelik Tabanlı Kritik Bölge Analizi



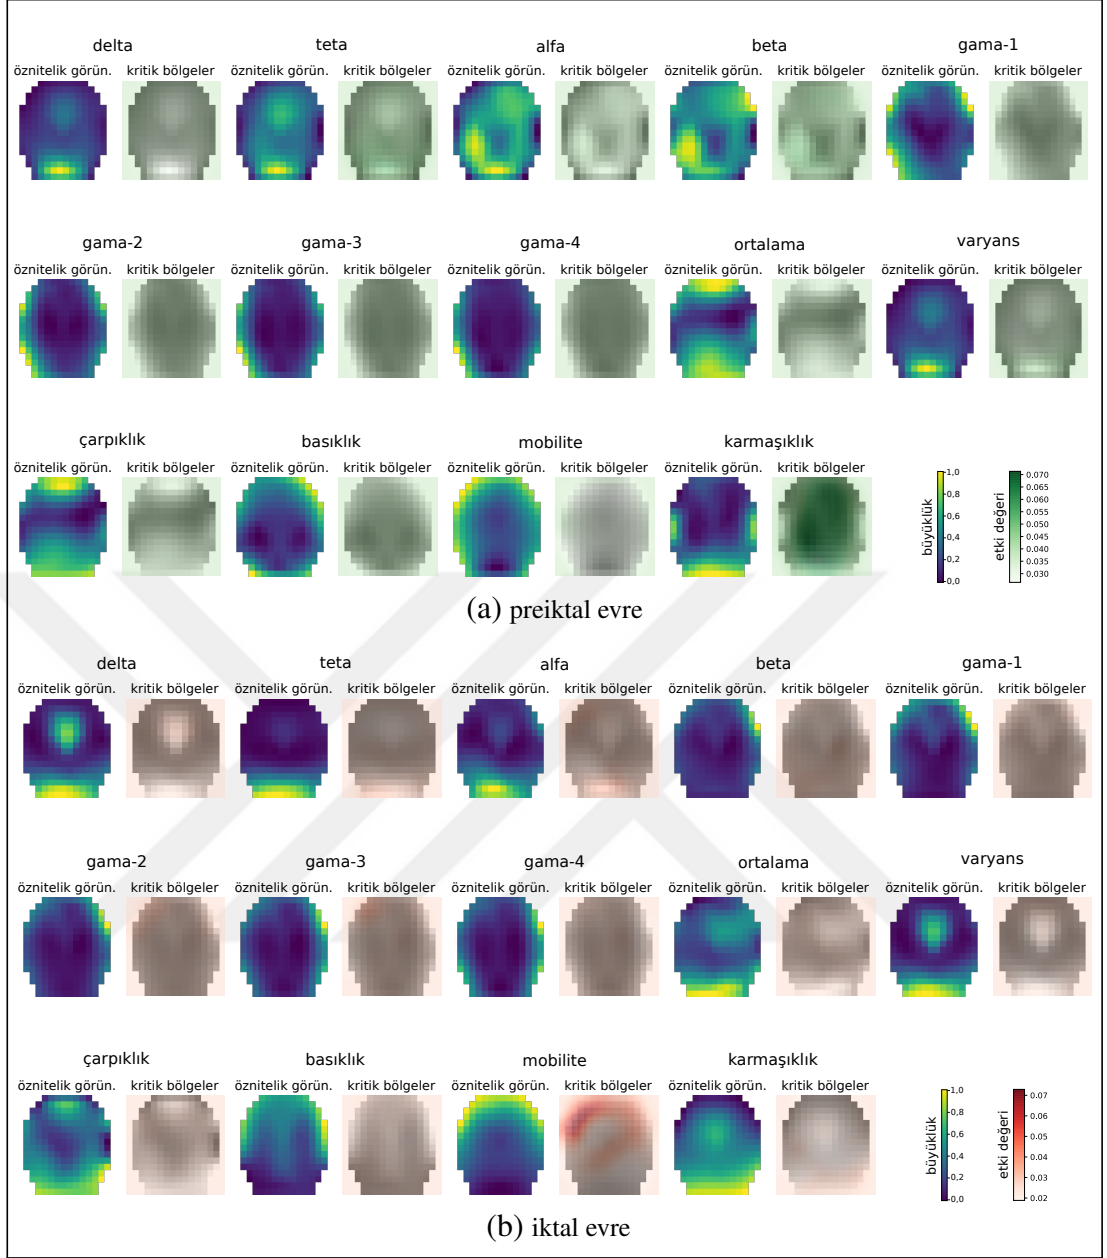
Şekil B.1. MIT Physionet sEEG veri setinde Hasta-3 için öznitelik tabanlı kritik bölge ısı haritaları



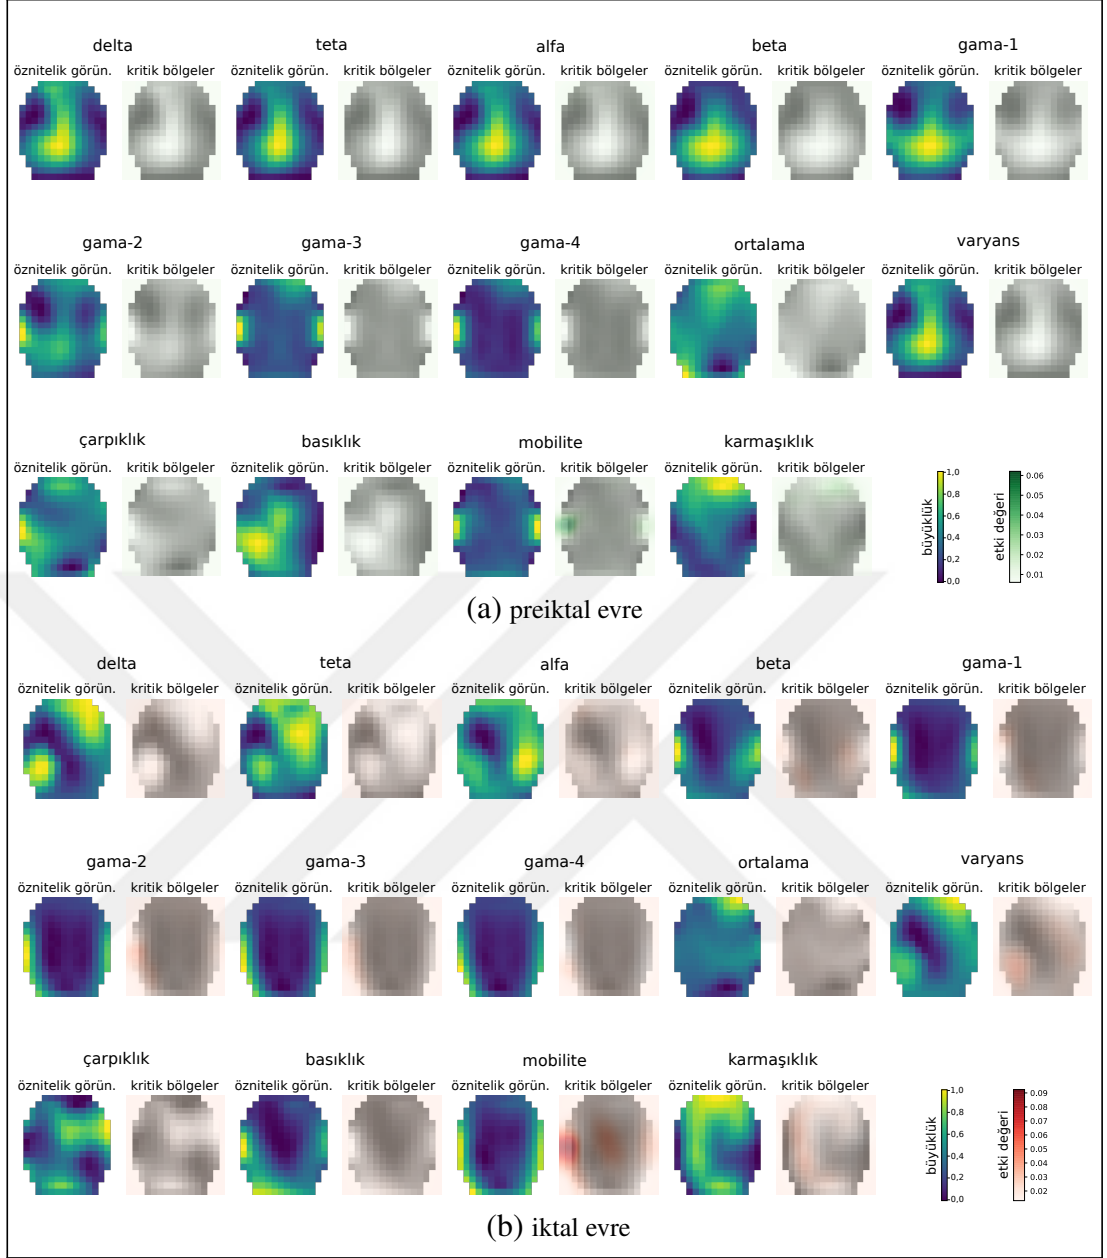
Şekil B.2. MIT Physionet sEEG veri setinde Hasta-5 için öznelik tabanlı kritik bölge 1s1 haritaları



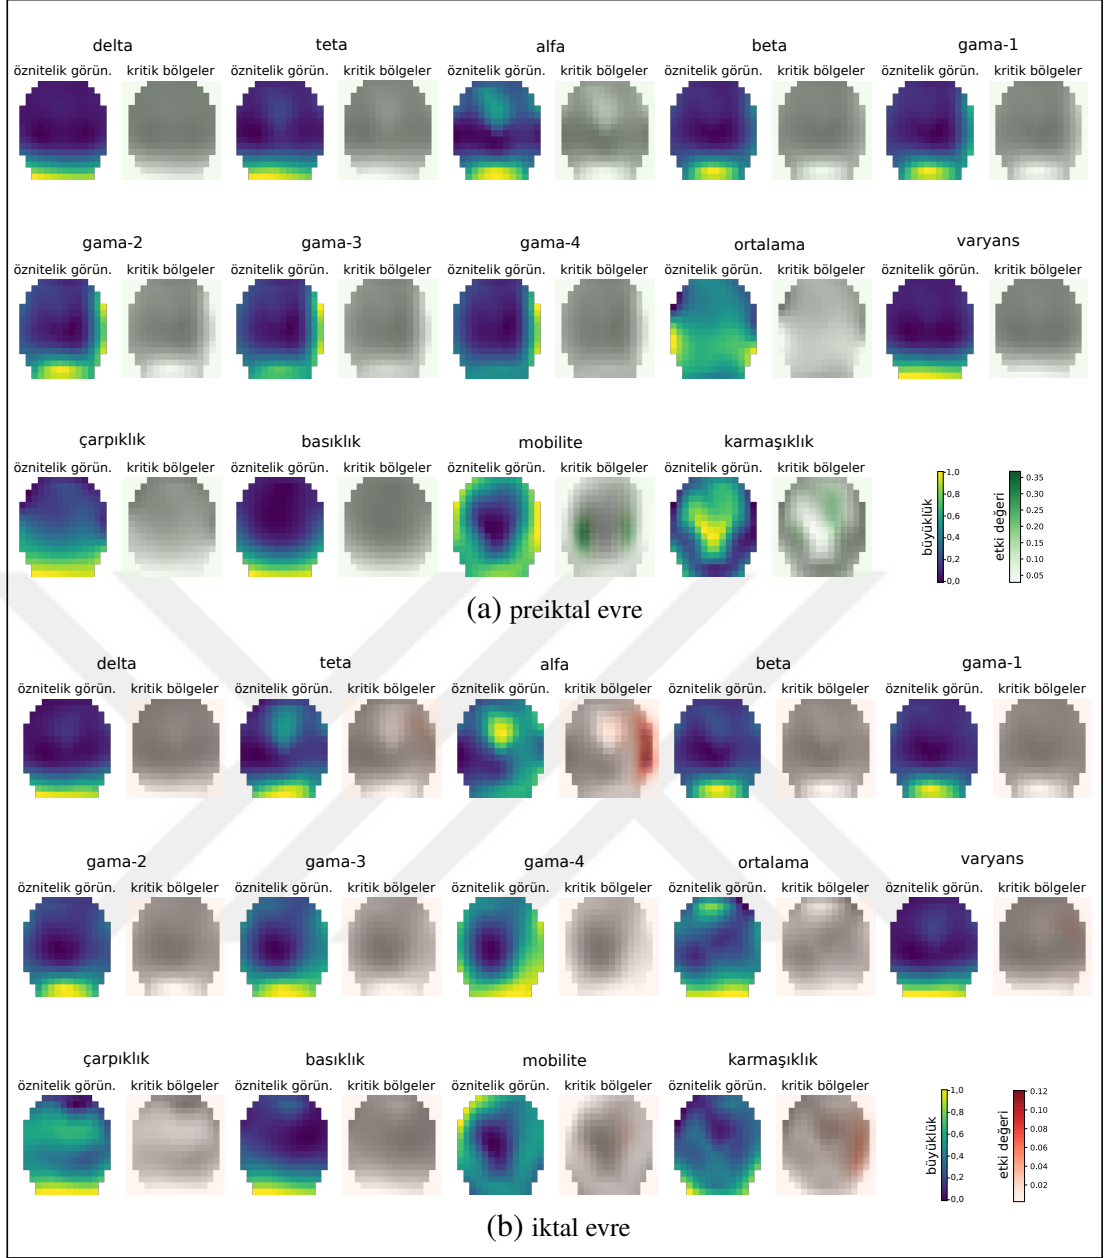
Şekil B.3. MIT Physionet sEEG veri setinde Hasta-9 için öznelik tabanlı kritik bölge 1s1 haritaları



Şekil B.4. MIT Physionet sEEG veri setinde Hasta-14 için öznitelik tabanlı kritik bölge ısı haritaları

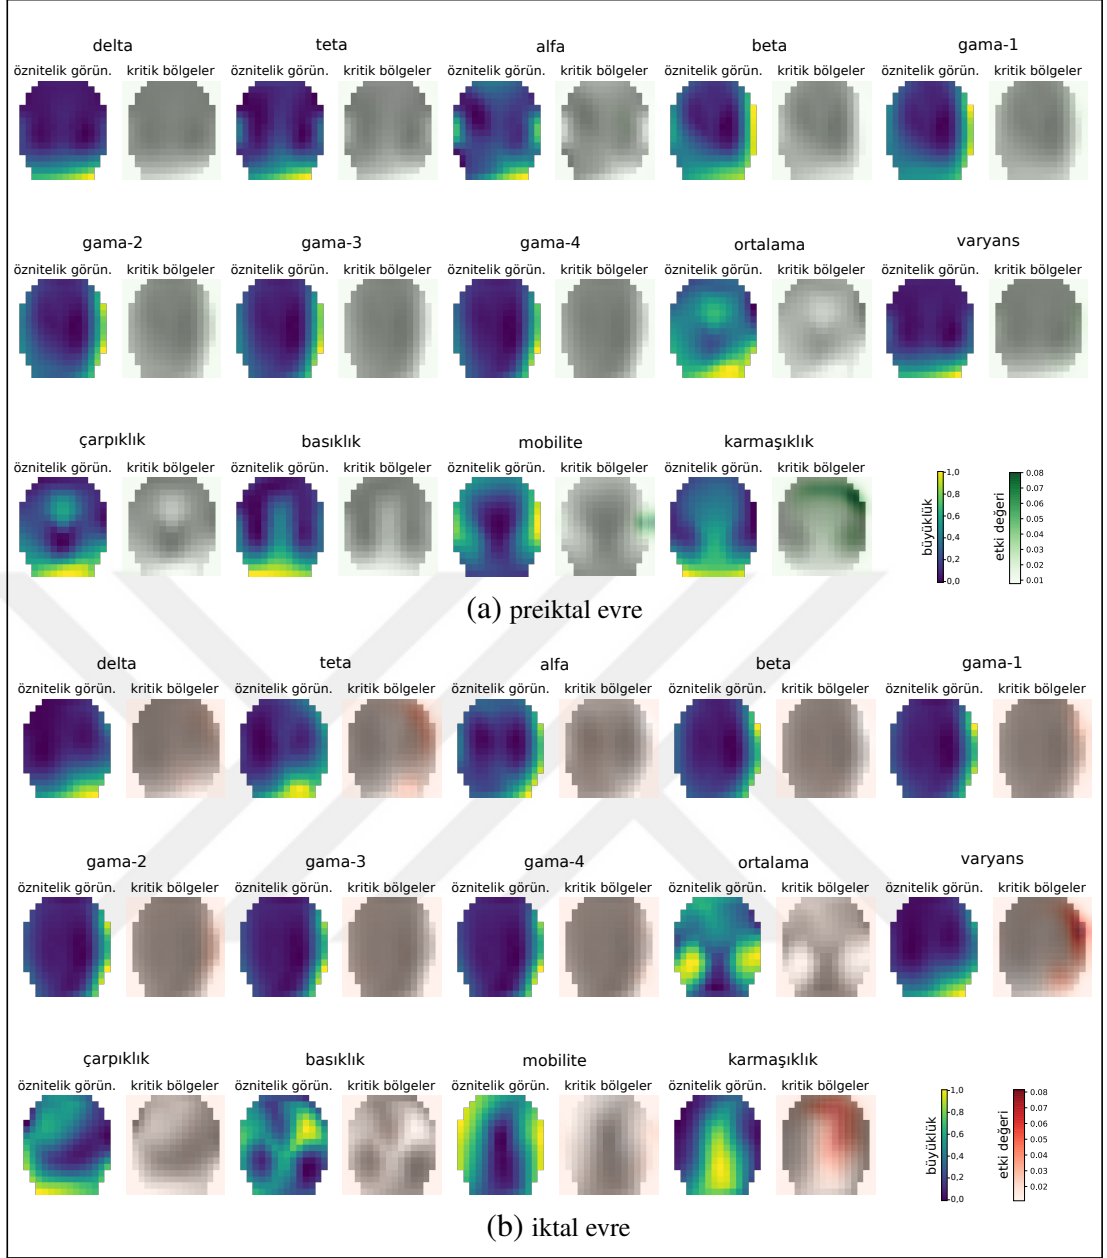


Şekil B.5. MIT Physionet sEEG veri setinde Hasta-20 için öznelik tabanlı kritik bölge 1s1 haritaları



Şekil B.6. MIT Physionet sEEG veri setinde Hasta-21 için öznelik tabanlı kritik bölge ısı haritaları





Şekil B.7. MIT Physionet sEEG veri setinde Hasta-23 için öznelik tabanlı kritik bölge 1s1 haritaları

## KİŞİSEL YAYIN VE ESERLER

- [1] **Özcan AR.**, Ertürk S., Seizure Prediction in Scalp EEG Using 3D Convolutional Neural Networks with an Image-Based Approach, *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2019, **27**(11), 2284-2293.
- [2] **Özcan AR.**, Ertürk S., Epileptic Seizure Prediction with Recurrent Convolutional Neural Networks, *25th Signal Processing and Communications Applications Conference (SIU)*, Antalya, Turkey, 15-18 May 2017.



## ÖZGEÇMİŞ

1986 yılında Trabzon'da doğdu. 2004 yılında girdiği Yıldız Teknik Üniversitesi Elektronik ve Haberleşme Mühendisliği Bölümü'nden 2009 yılında mezun oldu. 2010 yılında başladığı Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü Elektronik Tezli Yüksek Lisans Programı'nı 2013 yılında tamamladı. 2013 yılından bu yana Kocaeli Üniversitesi Fen Bilimleri Enstitüsü Elektronik ve Haberleşme Mühendisliği programında doktora eğitimine devam etmektedir.

2010-2014 yılları arasında TÜBİTAK BİLGEM Ulusal Elektronik ve Kriptoloji Araştırma Enstitüsü'nde Araştırmacı olarak çalıştı. 2016-2017 yılları arasında TÜBİTAK BİLGEM Kamu Sertifikasyon Merkezi'nde Danışman olarak görev aldı. 2014 yılından itibaren Bursa Teknik Üniversitesi Mekatronik Mühendisliği bölümünde Araştırma Görevlisi olarak görev yapmaktadır.