T.C.
İSTANBUL ÜNİVERSİTESİ-CERRAHPAŞA
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

YÜKSEK LİSANS TEZİ

EEG SİNYALLERİNİN ZAMAN-FREKANS GÖSTERİMLERİNİN DERİN ÖĞRENME ile ANALİZİ SONUCU ALZHEIMER HASTALIĞININ TESPİTİ

Meral ASLAN DİL

DANIŞMAN
Prof. Dr. Fırat KAÇAR

II. DANIŞMAN
Prof. Dr. Aydın AKAN

Biyomedikal Mühendisliği Anabilim Dalı

Biyomedikal Mühendisliği, Tezli Yüksek Lisans Programı

Kasım, 2024

TEZ KABUL VE ONAYI

Meral ASLAN DİL tarafından, **Prof. Dr. Fırat KAÇAR** danışmanlığında hazırlanan **"EEG SİNYALLERİNİN ZAMAN-FREKANS GÖSTERİMLERİNİN DERİN ÖĞRENME ile ANALİZİ SONUCU ALZHEIMER HASTALIĞININ TESPİTİ"** başlıklı bu çalışma, jürimiz tarafından **06/11/2024** tarihinde yapılan sınav sonucunda **oy birliği** ile başarılı bulunarak **Yüksek Lisans Tezi** olarak kabul edilmiştir.

Tez Jürisi

		İmza	**Sonuç**
DANIŞMAN	Prof. Dr. Fırat KAÇAR İstanbul Üniversitesi-Cerrahpaşa Elektrik Elektronik Mühendisliği Anabilim Dalı		☒ Kabul ☐ Ret
ÜYE	Doç. Dr. Abdurrahim AKGÜNDOĞDU İstanbul Üniversitesi-Cerrahpaşa Elektrik Elektronik Mühendisliği Anabilim Dalı		☒ Kabul ☐ Ret
ÜYE	Dr. Öğr. Üyesi Mustafa KONAL Tekirdağ Namık Kemal Üniversitesi Elektrik Elektronik Mühendisliği Anabilim Dalı		☒ Kabul ☐ Ret

BEYAN

Bu tez çalışmasının kendi çalışmam olduğunu, tezin planlanmasından yazımına kadar bütün aşamalarda etik dışı davranışımın olmadığını, bu tezdeki bütün bilgileri akademik ve bilimsel etik kuralları içinde elde ettiğimi, bu tez çalışmasıyla elde edilmeyen bütün bilgi ve yorumlara kaynak gösterdiğimi ve bu kaynakları da kaynaklar listesine aldığımı, yine bu tezin çalışılması ve yazımı sırasında patent ve telif haklarını ihlal edici bir davranışımın olmadığını ve her türlü hukuki sorumluluğu aldığımı kabul ederim.

Meral ASLAN DİL

(İmza)

Canım oğlum Mahir’e ithaf ediyorum…

BÜTÇE DESTEKLERİ

EEG SİNYALLERİNİN ZAMAN-FREKANS GÖSTERİMLERİNİN DERİN ÖĞRENME ile ANALİZİ SONUCU ALZHEIMER HASTALIĞININ TESPİTİ

Bu tez çalışması için herhangi bir kurumdan bütçe desteği alınmamıştır.

TEŞEKKÜR

Öncelikle iki değerli hocama, tez sürecim ve çalışmalarım boyunca çözüm odaklı, nazik ve anlayışlı tavrıyla rehberlik eden danışmanım Prof. Dr. Fırat KAÇAR'a ve yüksek lisans eğitimim ve tez sürecim boyunca desteğini, yardımlarını ve nezaketini esirgemeyen eş danışmanım Prof. Dr. Aydın AKAN'a sonsuz teşekkürler.

Tez konusunun belirlenmesinde önemli katkıları bulunan, tez çalışmamda kullandığım veri setini sağlayan, tezin deneysel süreçlerinden yazımına kadar birçok konuda sabırla, anlayışla ve özveriyle çok büyük desteği olan Dr. Öğr. Üyesi Özlem Karabiber CURA'ya minnettarım.

Tez sürecim boyunca her zor anımda yanımda olan, yapıcı tutumu ve çözüm odaklı tavrıyla beni motive eden, manevi desteğini hep hissettiğim Şenay ALTUN ERDOĞAN'a ve bana destek olan tüm dostlarıma çok teşekkür ederim.

Hayatım boyunca yanımda olan aileme emekleri için teşekkürlerimi ve minnetlerimi sunarım.

Son olarak sevgi ve anlayışlarıyla bana her zaman güç veren değerli eşim Tuncay ve sevgili oğlum Mahir'e en içten duygularımla teşekkür ederim.

Kasım 2024 **Meral ASLAN DİL**

İÇİNDEKİLER

Sayfa No

TEZ KABUL VE ONAYI ..... **ii**
BEYAN ..... **iii**
BÜTÇE DESTEKLERİ ..... **v**
TEŞEKKÜR ..... **vi**
İÇİNDEKİLER ..... **vii**
ŞEKİL LİSTESİ ..... **x**
TABLO LİSTESİ ..... **xv**
SİMGE VE KISALTMA LİSTESİ ..... **xviii**
ÖZET ..... **xx**
ABSTRACT ..... **xxii**
1. GİRİŞ **1**
1.1. TEZİN AMACI VE KATKILARI 3
2. KAVRAMSAL ÇERÇEVE **4**
2.1. SİNİR SİSTEMİ 4
2.2. BEYNİN TEMEL YAPISI VE İŞLEVLERİ 5
2.3. NÖRONUN YAPISI VE ELEKTRİKSEL SİNYAL OLUŞUMU 6
2.4. DEMANS VE ALZHEIMER HASTALIĞI (AH) 7
2.5. ELEKTROENSEFALOGRAFİ (EEG) 13
2.6. LİTERATÜR TARAMASI 18
3. YÖNTEM **25**
3.1. ÇALIŞMADA KULLANILAN ALZHEIMER DEMANS EEG VERİLERİ 25
3.2. ZAMAN-FREKANS YAKLAŞIMLARI İLE EEG VERİLERİNDEN GÖRÜNTÜLERİN ELDE EDİLMESİ 27
3.2.1. Kısa Zamanlı Fourier Dönüşümü (STFT) 27
3.2.2. Sürekli Dalgacık Dönüşümü (CWT) 28
3.2.2.1. Sürekli Dalgacık Dönüşümü (CWT) Amor, Bump ve Morse 30
3.3. GÖRÜNTÜLERİN CNN İLE EĞİTİLMESİ 33
3.3.1. Derin Öğrenme (Deep Learning - DL) 34

3.3.2. Evrişimli Sinir Ağları (Convolutional Neural Networks - CNN) 34
3.3.3. CNN Katman Türleri 36
3.3.3.1. Konvolüsyon Katmanları (Evrişimsel Katmanlar - Convolutional Layers) 36
3.3.3.2. Havuzlama Katmanları (Pooling Layers) 37
3.3.3.3. Tam Bağlantılı Katmanlar (Fully Connected Layers) 38
3.3.4. Çalışmada Kullanılan CNN Çeşitleri 38
3.3.4.1. ResNet18 Mimarisi ve Modifikasyonları 38
3.3.4.2. AlexNet Mimarisi 44
3.3.4.3. GoogleNet Mimarisi (Inception V1) 44
3.3.4.4. DarkNet Mimarisi 45
3.3.5. Çalışmada Kullanılan Performans Metrikleri 46
3.3.6. Çalışmada Kullanılan Hiper-parametreler 48
3.3.7. ROC Eğrisi (Receiver Operating Characteristic Curve) 50
4. BULGULAR 52
4.1. CNN MİMARİLERİNİN KANAL BAZLI ANALİZ SONUÇLARI 52
4.1.1. CNN Mimarilerinin Ortalama Validasyon ve Test Sonuçları 52
4.1.2. CNN Mimarilerinin Tüm ZF Temsilleri İçin Kanal Bazlı Validasyon ve Test Doğruluk (Accuracy) Sonuçları 57
4.2. CNN MİMARİLERİNİN BEYİN BÖLGESİ BAZLI ANALİZ SONUÇLARI 64
4.2.1. ResNet18 Mimarisinin AH/KG Sınıflandırmasına Etkisi 64
4.2.1.1. ResNet18 Mimarisinin Beyin Bölgeleri Bazlı En İyi Sonuç Veren Kanallara Ait Eğitim İlerlemesi, Validasyon ve Test İçin Karmaşıklık Matrisi ve ROC Eğrisi Görselleri 65
4.2.2. Modifiye ResNet18_1 Mimarisinin AH/KG Sınıflandırmasına Etkisi 73
4.2.2.1. Modifiye ResNet18_1 Mimarisinin Beyin Bölgeleri Bazlı En İyi Sonuç Veren Kanallara Ait Eğitim İlerlemesi, Validasyon ve Test İçin Karmaşıklık Matrisi ve ROC Eğrisi Görselleri 75
4.2.3. Modifiye ResNet18_2 Mimarisinin AH/KG Sınıflandırmasına Etkisi 83
4.2.3.1. Modifiye ResNet18_2 Mimarisinin Beyin Bölgeleri Bazlı En İyi Sonuç Veren Kanallara Ait Eğitim İlerlemesi, Validasyon ve Test İçin Karmaşıklık Matrisi ve ROC Eğrisi Görselleri 84
4.2.4. AlexNet Mimarisinin AH/KG Sınıflandırmasına Etkisi 93
4.2.4.1. AlexNet Mimarisinin Beyin Bölgeleri Bazlı En İyi Sonuç Veren Kanallara Ait Eğitim İlerlemesi, Validasyon ve Test İçin Karmaşıklık Matrisi ve ROC Eğrisi Görselleri 94
4.2.5. GoogleNet Mimarisinin AH/KG Sınıflandırmasına Etkisi 102

4.2.5.1. GoogleNet Mimarisinin Beyin Bölgeleri Bazlı En İyi Sonuç Veren Kanallara Ait Eğitim İlerlemesi, Validasyon ve Test İçin Karmaşıklık Matrisi ve ROC Eğrisi Görselleri *104*

4.2.6. DarkNet Mimarisinin AH/KG Sınıflandırmasına Etkisi 112

4.2.6.1. DarkNet Mimarisinin Beyin Bölgeleri Bazlı En İyi Sonuç Veren Kanallara Ait Eğitim İlerlemesi, Validasyon ve Test İçin Karmaşıklık Matrisi ve ROC Eğrisi Görselleri *113*

4.2.7. Tüm Mimariler İçin En iyi Sonuç Veren Kanalların ROC Eğrisi Değerlendirmesi 121

4.2.8. Tüm Mimariler İçin Beş Beyin Bölgesi Bazlı En İyi Sonuç Veren Kanalların Performans Değerlendirmesi 122

5. TARTIŞMA 125

6. SONUÇ VE ÖNERİLER 129

KAYNAKLAR 132

EKLER 140

İNTİHAL RAPORU İLK SAYFASI 143

ETİK KURUL İZİN YAZISI 144

KURUM İZNİ YAZILARI 145

ÖZGEÇMİŞ 146

ŞEKİL LİSTESİ

Sayfa No

Şekil 2.1: Sinir Sistemi Bölümlerinin Şematik Gösterimi [4].....4

Şekil 2.2: Beynin Lobları [6]. 6

Şekil 2.3: Nöronun Bileşenleri [8]. 7

Şekil 2.4: Dünya Bankası gelir kategorisinde 2005, 2015 ve 2030 yılları için Nörolojik bozuklukların toplam DALY'ler (the Disability-Adjusted Life Year) içindeki yüzdesi [11].... 8

Şekil 2.5: 2015 yılında çeşitli nörolojik bozuklukların, nörolojik bozuklukların tamamına oranı. Tahminler engelliliğe göre düzenlenmiş yaşam yılları (DALYs) (A) ve ölümler (B) içindir [12]. 9

Şekil 2.6: (a) Sağlıklı olan ve (b) Alzheimer hastalığı (AH) olan beynin ve nöronların fizyolojik yapısı [15]. 11

Şekil 2.7: Alzheimer Hastalığı'nın (AH) spektrumu [18].....12

Şekil 2.8: Alzheimer Hastalığı'nın teşhis yöntemleri [17]. 13

Şekil 2.9: Tipik klinik teşhis için normal yetişkin EEG kaydı [21]. 14

Şekil 2.10: İlk kez 1958'de sunulan ve uluslararası olarak kabul edilen 10-20 sistemi [23]. ..15

Şekil 2.11: EEG cihazına ait elektronik devre blok diyagramı [24]. 15

Şekil 2.12: EEG alt bantları [24].....17

Şekil 3.1: Çalışmanın blok diyagramı (AH; Alzheimer Hastalığı, KG; Kontrol Grubu, EEG; Elektroensefalogram, STFT; Kısa Zamanlı Fourier Dönüşümü, CWT; Sürekli Dalgacık Dönüşümü)……25

Şekil 3.2: Elektrot bölgelerine göre beyin kümeleri [29].....27

Şekil 3.3: Zaman alanlı sinyalden zaman-frekans alanlı görüntüye dönüşüm süreci [61].....29

Şekil 3.4: (a) Kontrol deneğinin ve (b) Alzheimer hastasının 5 saniyelik elektroensefalogram segmenti ve ilgili zaman-frekans temsilleri; (c, d) Kısa Zamanlı Fourier Dönüşümü, (e, f) Sürekli Dalgacık Dönüşümü Amor, (g, h) Sürekli Dalgacık Dönüşümü Bump ve (ı, j) Sürekli Dalgacık Dönüşümü Morse. 33

Şekil 3.5: Konvolüsyonel sinir ağı (CNN) mimarisini ve eğitim sürecini genel bir gözden geçirme [73]. 36

Şekil 3.6: Konvolüsyon katmanının işleyişi [74]. 37

Şekil 3.7: Maksimum havuzlama katmanının çalışması [74]. 37

Şekil 3.8: Tam bağlı katmanın çalışması [74]. 38

Şekil 3.9: ResNet18'in ağ yapısı [76]. 40

Şekil 3.10: 5 konvolüsyonel katman ve 3 tam bağlantılı katmandan oluşan AlexNet mimarisi [81]. 44

Şekil 3.11: GoogleNet mimarisi [83]. 45

Şekil 3.12: Inception modülü [84]. 45

Şekil 3.13: Performans metriklerinin karmaşıklık matrisi örneği üzerinde gösterimi. 48

Şekil 3.14: ResNet18 mimarisi CWT Bump yaklaşımı ile P4 Kanalı için Validasyon ROC eğrisi. 51

Şekil 4.1: ResNet18 mimarisi için ZF yaklaşımlarının kanal bazlı validasyon (a) ve test (b) accuracy sonuçlarının grafik gösterimi. 58

Şekil 4.2: Modifiye ResNet18_1 mimarisi için ZF yaklaşımlarının kanal bazlı validasyon (a) ve test (b) accuracy sonuçlarının grafik gösterimi. 59

Şekil 4.3: Modifiye ResNet18_2 mimarisi için ZF yaklaşımlarının kanal bazlı validasyon (a) ve test (b) accuracy sonuçlarının grafik gösterimi. 60

Şekil 4.4: AlexNet mimarisi için ZF yaklaşımlarının kanal bazlı validasyon (a) ve test (b) accuracy sonuçlarının grafik gösterimi. 61

Şekil 4.5: GoogleNet mimarisi için ZF yaklaşımlarının kanal bazlı validasyon (a) ve test (b) accuracy sonuçlarının grafik gösterimi. 62

Şekil 4.6: DarkNet mimarisi için ZF yaklaşımlarının kanal bazlı validasyon (a) ve test (b) accuracy sonuçlarının grafik gösterimi. 63

Şekil 4.7: Beyin Bölgesi Bazlı Resnet18 Validasyon (a) ve Test (b) Sonuçları 65

Şekil 4.8: ResNet18 mimarisinde CWT Bump yaklaşımı için; beyin bölgeleri içinde en iyi sonuç veren kanalların Training Progress görselleri; ön beyin (anterior) bölgesi için; F4 kanalı (a); merkez (central) beyin bölgesi için C3 kanalı (b), sol temporal (temporal left) beyin bölgesi için T5 kanalı (c), sağ temporal (temporal right) beyin bölgesi için T6 kanalı (d) ve arka (posterior) beyin bölgesi için P4 kanalı (e). 68

Şekil 4.9: ResNet18 mimarisinde CWT Bump yaklaşımı için; beyin bölgeleri içinde en iyi sonuç veren kanalların Validasyon ve Test karmaşıklık matrisleri; ön beyin (anterior) bölgesi için; F4 kanalı Validasyon (a) ve Test (b) matrisi; merkez (central) beyin bölgesi için C3

kanalı Validasyon (c) ve Test (d) matrisi, sol temporal (temporal left) beyin bölgesi için T5 kanalı Validasyon (e) ve Test (f) matrisi, sağ temporal (temporal right) beyin bölgesi için T6 kanalı Validasyon (g) ve Test (h) matrisi ve arka (posterior) beyin bölgesi için P4 kanalı Validasyon (i) ve Test (j) matrisi. 70

Şekil 4.10: ResNet18 mimarisinde CWT Bump yaklaşımı için; beyin bölgeleri içinde en iyi sonuç veren kanalların Validasyon ve Test ROC eğrileri; ön beyin (anterior) bölgesi için; F4 kanalı Validasyon (a) ve Test (b) ROC eğrisi; merkez (central) beyin bölgesi için C3 kanalı Validasyon (c) ve Test (d) ROC eğrisi, sol temporal (temporal left) beyin bölgesi için T5 kanalı Validasyon (e) ve Test (f) ROC eğrisi, sağ temporal (temporal right) beyin bölgesi için T6 kanalı Validasyon (g) ve Test (h) ROC eğrisi ve arka (posterior) beyin bölgesi için P4 kanalı Validasyon (i) ve Test (j) ROC eğrisi. 73

Şekil 4.11: Beyin Bölgesi Bazlı Modifiye ResNet18_1 Validasyon (a) ve Test (b) Sonuçları 74

Şekil 4.12: Modifiye ResNet18_1 mimarisinde CWT Bump yaklaşımı için; beyin bölgeleri içinde en iyi sonuç veren kanalların Training Progress görselleri; ön beyin (anterior) bölgesi için; F4 kanalı (a); merkez (central) beyin bölgesi için C3 kanalı (b), sol temporal (temporal left) beyin bölgesi için T5 kanalı (c), sağ temporal (temporal right) beyin bölgesi için F8 kanalı (d) ve arka (posterior) beyin bölgesi için P4 kanalı (e). 77

Şekil 4.13: Modifiye ResNet18_1 mimarisinde CWT Bump yaklaşımı için; beyin bölgeleri içinde en iyi sonuç veren kanalların Validasyon ve Test karmaşıklık matrisleri; ön beyin (anterior) bölgesi için; F4 kanalı Validasyon (a) ve Test (b) matrisi; merkez (central) beyin bölgesi için C3 kanalı Validasyon (c) ve Test (d) matrisi, sol temporal (temporal left) beyin bölgesi için T5 kanalı Validasyon (e) ve Test (f) matrisi, sağ temporal (temporal right) beyin bölgesi için F8 kanalı Validasyon (g) ve Test (h) matrisi ve arka (posterior) beyin bölgesi için P4 kanalı Validasyon (i) ve Test (j) matrisi. 80

Şekil 4.14: Modifiye ResNet18_1 mimarisinde CWT Bump yaklaşımı için; beyin bölgeleri içinde en iyi sonuç veren kanalların Validasyon ve Test ROC eğrileri; ön beyin (anterior) bölgesi için; F4 kanalı Validasyon (a) ve Test (b) ROC eğrisi; merkez (central) beyin bölgesi için C3 kanalı Validasyon (c) ve Test (d) ROC eğrisi, sol temporal (temporal left) beyin bölgesi için T5 kanalı Validasyon (e) ve Test (f) ROC eğrisi, sağ temporal (temporal right) beyin bölgesi için F8 kanalı Validasyon (g) ve Test (h) ROC eğrisi ve arka (posterior) beyin bölgesi için P4 kanalı Validasyon (i) ve Test (j) ROC eğrisi. 82

Şekil 4.15: Beyin Bölgesi Bazlı Modifiye ResNet18_2 Validasyon (a) ve Test (b) Sonuçları 84

Şekil 4.16: Modifiye ResNet18_2 mimarisinde CWT Bump yaklaşımı için; beyin bölgeleri içinde en iyi sonuç veren kanalların Training Progress görselleri; ön beyin (anterior) bölgesi için; F4 kanalı (a); merkez (central) beyin bölgesi için; C3 kanalı (b), sol temporal (temporal left) beyin bölgesi için; T5 kanalı (c), sağ temporal (temporal right) beyin bölgesi için; T6 kanalı (d) ve arka (posterior) beyin bölgesi için; P4 kanalı (e). 87

Şekil 4.17: Modifiye ResNet18_2 mimarisinde CWT Bump yaklaşımı için; beyin bölgeleri içinde en iyi sonuç veren kanalların Validasyon ve Test karmaşıklık matrisleri; ön beyin (anterior) bölgesi için; F4 kanalı Validasyon (a) ve Test (b) matrisi; merkez (central) beyin bölgesi için; C3 kanalı Validasyon (c) ve Test (d) matrisi, sol temporal (temporal left) beyin bölgesi için; T5 kanalı Validasyon (e) ve Test (f) matrisi, sağ temporal (temporal right) beyin

bölgesi için; T6 kanalı Validasyon (g) ve Test (h) matrisi ve arka (posterior) beyin bölgesi için; P4 kanalı Validasyon (i) ve Test (j) matrisi.....89

Şekil 4.18: Modifiye ResNet18_2 mimarisinde CWT Bump yaklaşımı için; beyin bölgeleri içinde en iyi sonuç veren kanalların Validasyon ve Test ROC eğrileri; ön beyin (anterior) bölgesi için; F4 kanalı Validasyon (a) ve Test (b) ROC eğrisi; merkez (central) beyin bölgesi için; C3 kanalı Validasyon (c) ve Test (d) ROC eğrisi, sol temporal (temporal left) beyin bölgesi için; T5 kanalı Validasyon (e) ve Test (f) ROC eğrisi, sağ temporal (temporal right) beyin bölgesi için; T6 kanalı Validasyon (g) ve Test (h) ROC eğrisi ve arka (posterior) beyin bölgesi için; P4 kanalı Validasyon (i) ve Test (j) ROC eğrisi. 92

Şekil 4.19: Beyin Bölgesi Bazlı AlexNet Validasyon (a) ve Test (b) Sonuçları 94

Şekil 4.20: AlexNet mimarisinde CWT Bump yaklaşımı için; beyin bölgeleri içinde en iyi sonuç veren kanalların Training Progress görselleri; ön beyin (anterior) bölgesi için; F4 kanalı (a); merkez (central) beyin bölgesi için; C3 kanalı (b), sol temporal (temporal left) beyin bölgesi için; T5 kanalı (c), sağ temporal (temporal right) beyin bölgesi için; F8 kanalı (d) ve arka (posterior) beyin bölgesi için; P4 kanalı (e). 97

Şekil 4.21: AlexNet mimarisinde CWT Bump yaklaşımı için; beyin bölgeleri içinde en iyi sonuç veren kanalların Validasyon ve Test karmaşıklık matrisleri; ön beyin (anterior) bölgesi için; F4 kanalı Validasyon (a) ve Test (b) matrisi; merkez (central) beyin bölgesi için; C3 kanalı Validasyon (c) ve Test (d) matrisi, sol temporal (temporal left) beyin bölgesi için T5 kanalı Validasyon (e) ve Test (f) matrisi, sağ temporal (temporal right) beyin bölgesi için F8 kanalı Validasyon (g) ve Test (h) matrisi ve arka (posterior) beyin bölgesi için P4 kanalı Validasyon (i) ve Test (j) matrisi.....99

Şekil 4.22: AlexNet mimarisinde CWT Bump yaklaşımı için; beyin bölgeleri içinde en iyi sonuç veren kanalların Validasyon ve Test ROC eğrileri; ön beyin (anterior) bölgesi için; F4 kanalı Validasyon (a) ve Test (b) ROC eğrisi; merkez (central) beyin bölgesi için; C3 kanalı Validasyon (c) ve Test (d) ROC eğrisi, sol temporal (temporal left) beyin bölgesi için; T5 kanalı Validasyon (e) ve Test (f) ROC eğrisi, sağ temporal (temporal right) beyin bölgesi için; F8 kanalı Validasyon (g) ve Test (h) ROC eğrisi ve arka (posterior) beyin bölgesi için; P4 kanalı Validasyon (i) ve Test (j) ROC eğrisi. 102

Şekil 4.23: Beyin Bölgesi Bazlı GoogleNet Validasyon (a) ve Test (b) Sonuçları 103

Şekil 4.24: GoogleNet mimarisinde CWT Bump yaklaşımı için; beyin bölgeleri içinde en iyi sonuç veren kanalların Training Progress görselleri; ön beyin (anterior) bölgesi için; F4 kanalı (a); merkez (central) beyin bölgesi için; C3 kanalı (b), sol temporal (temporal left) beyin bölgesi için; T5 kanalı (c), sağ temporal (temporal right) beyin bölgesi için; T6 kanalı (d) ve arka (posterior) beyin bölgesi için; P4 kanalı (e). 106

Şekil 4.25: GoogleNet mimarisinde CWT Bump yaklaşımı için; beyin bölgeleri içinde en iyi sonuç veren kanalların Validasyon ve Test karmaşıklık matrisleri; ön beyin (anterior) bölgesi için; F4 kanalı Validasyon (a) ve Test (b) matrisi; merkez (central) beyin bölgesi için; C3 kanalı Validasyon (c) ve Test (d) matrisi, sol temporal (temporal left) beyin bölgesi için; T5 kanalı Validasyon (e) ve Test (f) matrisi, sağ temporal (temporal right) beyin bölgesi için; T6 kanalı Validasyon (g) ve Test (h) matrisi ve arka (posterior) beyin bölgesi için; P4 kanalı Validasyon (i) ve Test (j) matrisi.....109

Şekil 4.26: GoogleNet mimarisinde CWT Bump yaklaşımı için; beyin bölgeleri içinde en iyi sonuç veren kanalların Validasyon ve Test ROC eğrileri; ön beyin (anterior) bölgesi için; F4 kanalı Validasyon (a) ve Test (b) ROC eğrisi; merkez (central) beyin bölgesi için; C3 kanalı Validasyon (c) ve Test (d) ROC eğrisi, sol temporal (temporal left) beyin bölgesi için; T5 kanalı Validasyon (e) ve Test (f) ROC eğrisi, sağ temporal (temporal right) beyin bölgesi için; T6 kanalı Validasyon (g) ve Test (h) ROC eğrisi ve arka (posterior) beyin bölgesi için; P4 kanalı Validasyon (i) ve Test (j) ROC eğrisi. 111

Şekil 4.27: Beyin Bölgesi Bazlı DarkNet Validasyon (a) ve Test (b) Sonuçları 113

Şekil 4.28: DarkNet mimarisinde CWT Amor yaklaşımı için; beyin bölgeleri içinde en iyi sonuç veren kanalların Training Progress görselleri; ön beyin (anterior) bölgesi için; F4 kanalı (a); merkez (central) beyin bölgesi için; Cz kanalı (b), sol temporal (temporal left) beyin bölgesi için; F7 kanalı (c), sağ temporal (temporal right) beyin bölgesi için; F8 kanalı (d) ve arka (posterior) beyin bölgesi için; P4 kanalı (e). 116

Şekil 4.29: DarkNet mimarisinde CWT Amor yaklaşımı için; beyin bölgeleri içinde en iyi sonuç veren kanalların Validasyon ve Test karmaşıklık matrisleri; ön beyin (anterior) bölgesi için; F4 kanalı Validasyon (a) ve Test (b) matrisi; merkez (central) beyin bölgesi için; Cz kanalı Validasyon (c) ve Test (d) matrisi, sol temporal (temporal left) beyin bölgesi için; F7 kanalı Validasyon (e) ve Test (f) matrisi, sağ temporal (temporal right) beyin bölgesi için; F8 kanalı Validasyon (g) ve Test (h) matrisi ve arka (posterior) beyin bölgesi için; P4 kanalı Validasyon (i) ve Test (j) matrisi. 118

Şekil 4.30: DarkNet mimarisinde CWT Amor yaklaşımı için; beyin bölgeleri içinde en iyi sonuç veren kanalların Validasyon ve Test ROC eğrileri; ön beyin (anterior) bölgesi için; F4 kanalı Validasyon (a) ve Test (b) ROC eğrisi; merkez (central) beyin bölgesi için; Cz kanalı Validasyon (c) ve Test (d) ROC eğrisi, sol temporal (temporal left) beyin bölgesi için; F7 kanalı Validasyon (e) ve Test (f) ROC eğrisi, sağ temporal (temporal right) beyin bölgesi için; F8 kanalı Validasyon (g) ve Test (h) ROC eğrisi ve arka (posterior) beyin bölgesi için; P4 kanalı Validasyon (i) ve Test (j) ROC eğrisi. 121

TABLO LİSTESİ

Sayfa No

Tablo 2. 1: Nörolojik bozukluklara bağlı olan ölümler, toplam ölümlerin yüzdesi olarak ifade edilmiştir, 2005,2015,2030 [11]. 8

Tablo 3.1: Çalışma kapsamında kullanılan anne dalgacık (mother wavelet) türleri; CWT Morse, CWT Amor ve CWT Bump [64]..... 31

Tablo 3.2: ResNet18 mimarisi katmanları..... 41

Tablo 3.3: Modifiye ResNet18_1 mimarisi katmanları..... 42

Tablo 3.4: Modifiye ResNet18_2 mimarisi katmanları..... 43

Tablo 4.1: ResNet18 mimarisi için ZF yaklaşımlarının ortalama validasyon sonuçları. 54

Tablo 4.2: ResNet18 mimarisi için ZF yaklaşımlarının ortalama test sonuçları. 54

Tablo 4.3: Modifiye ResNet18_1 mimarisi için ZF yaklaşımlarının ortalama validasyon sonuçları. 54

Tablo 4.4: Modifiye ResNet18_1 mimarisi için ZF yaklaşımlarının ortalama test sonuçları. 55

Tablo 4.5: Modifiye ResNet18_2 mimarisi için ZF yaklaşımlarının ortalama validasyon sonuçları. 55

Tablo 4.6: Modifiye ResNet18_2 mimarisi için ZF yaklaşımlarının ortalama test sonuçları. 55

Tablo 4.7: AlexNet mimarisi için ZF yaklaşımlarının ortalama validasyon sonuçları. 55

Tablo 4.8: AlexNet mimarisi için ZF yaklaşımlarının ortalama test sonuçları. 56

Tablo 4.9: GoogleNet mimarisi için ZF yaklaşımlarının ortalama validasyon sonuçları..... 56

Tablo 4.10: GoogleNet mimarisi için ZF yaklaşımlarının ortalama test sonuçları. 56

Tablo 4.11: DarkNet mimarisi için ZF yaklaşımlarının ortalama validasyon sonuçları. 56

Tablo 4.12: DarkNet mimarisi için ZF yaklaşımlarının ortalama test sonuçları. 57

Tablo 4.13: ResNet18 mimarisi için ZF yaklaşımlarının kanal bazlı validasyon ve test accuracy sonuçları. 58

Tablo 4.14: Modifiye ResNet18_1 mimarisi için ZF yaklaşımlarının kanal bazlı validasyon ve test accuracy sonuçları. 59

Tablo 4.15: Modifiye ResNet18_2 mimarisi için ZF yaklaşımlarının kanal bazlı validasyon ve test accuracy sonuçları. 60

Tablo 4.16: AlexNet mimarisi için ZF yaklaşımlarının kanal bazlı validasyon ve test accuracy sonuçları. 61

Tablo 4.17: GoogleNet mimarisi için ZF yaklaşımlarının kanal bazlı validasyon ve test accuracy sonuçları. 62

Tablo 4.18: DarkNet mimarisi için ZF yaklaşımlarının kanal bazlı validasyon ve test accuracy sonuçları. 63

Tablo 4.19: ResNet18 mimarisi için ZF yaklaşımlarının beyin bölgesi bazlı ortalama validasyon sonuçları. 64

Tablo 4.20: ResNet18 mimarisi için ZF yaklaşımlarının beyin bölgesi bazlı ortalama test sonuçları. 64

Tablo 4.21: Modifiye ResNet18_1 mimarisi için ZF yaklaşımlarının beyin bölgesi bazlı ortalama validasyon sonuçları. 74

Tablo 4.22: Modifiye ResNet18_1 mimarisi için ZF yaklaşımlarının beyin bölgesi bazlı ortalama test sonuçları. 74

Tablo 4.23: Modifiye ResNet18_2 mimarisi için ZF yaklaşımlarının beyin bölgesi bazlı ortalama validasyon sonuçları. 83

Tablo 4.24: Modifiye ResNet18_2 mimarisi için ZF yaklaşımlarının beyin bölgesi bazlı ortalama test sonuçları. 83

Tablo 4.25: AlexNet mimarisi için ZF yaklaşımlarının beyin bölgesi bazlı ortalama validasyon sonuçları. 93

Tablo 4.26: AlexNet mimarisi için ZF yaklaşımlarının beyin bölgesi bazlı ortalama test sonuçları. 93

Tablo 4.27: GoogleNet mimarisi için ZF yaklaşımlarının beyin bölgesi bazlı ortalama validasyon sonuçları. 103

Tablo 4.28: GoogleNet mimarisi için ZF yaklaşımlarının beyin bölgesi bazlı ortalama test sonuçları. 103

Tablo 4.29: DarkNet mimarisi için ZF yaklaşımlarının beyin bölgesi bazlı ortalama validasyon sonuçları. 112

Tablo 4.30: DarkNet mimarisi için ZF yaklaşımlarının beyin bölgesi bazlı ortalama test sonuçları. 112

Tablo 4.31: Tüm mimarilerin en iyi ACC değeri veren kanallarının validasyon ve test için hasta-kontrol AUC değerleri 121

Tablo 4.32: Tüm mimarilerin beyin bölgesi bazlı en iyi sonuçlara sahip kanallarının validasyon ACC değerleri, maksimum devir sayıları (max epoch) ve training progress süreleri. 124

Tablo 5.1: Literatürde bulunan diğer benzer çalışmalarla tez kapsamında yapılan çalışmaların katılımcı sayısı, özellik, sınıflandırıcı ve performans tablosu. 128

SİMGE VE KISALTMA LİSTESİ

Simgeler **Açıklama**

Aß : amiloid-beta peptiti
µV : mikro volt
Hz : Hertz

Kısaltmalar **Açıklama**

ACC : Doğruluk (Accuracy)
AH : Alzheimer Hastalığı
BOS : Beyin Omurilik sıvısı
CNN : Evrişimli Sinir Ağı (Convolutional Neural Network)
CWT : Sürekli Dalgacık Dönüşümü (Continuous Wavelet Transform)
CT : Bilgisayarlı Tomografi (BT)
DALYs : Disability-Adjusted Life Years (Engelliliğe Uyarlanmış Yaşam Yılları)
DEHB : Dikkat Eksikliği Hiperaktivite Bozukluğu
DL : Derin Öğrenme (Deep Learning)
DNN : Derin Sinir Ağı (Deep Neural Network)
DWT : Ayrık Dalgacık Dönüşümü (Discrete Wavelet Transform)
EEG : Elektroensefalogram
EMD : Ampirik Mod Ayrıştırma (Empirical Mode Decomposition)
FDR : Yanlış Keşif Oranı (False Discovery Rate)
F1-S : F1-Skoru
FE : Özellik Mühendisliği (Feature Engineering)
FN : Yanlış Negatif (False Negative)
FP : Yanlış Pozitif (False Positive)
KG : Kontrol Grubu (Control Subjects)
LDA : Doğrusal Diskriminant Analizi (Linear Discriminant Analysis)
LWT : Lifting Wavelet Dönüşümü
MCI : Hafif Bilişsel Bozukluk (HBB - Mild Cognitive Impairment)

MEG : Magnetoensefalografi
ML : Makine Öğrenimi (Machine Learning)
MMT : Mini-Mental Test
MR : Manyetik Rezonans
MRG : Manyetik Rezonans Görüntüleme
PET : Pozitron Emisyon Tomografi
PRE : Kesinlik (Precision)
RNN : Tekrarlayan Sinir Ağı (Recurrent Neural Network)
ROC : Alıcı İşletim Karakteristiği (Receiver Operating Characteristic)
SEN : Duyarlılık (Sensitivity)
SPE : Özgüllük (Specivity)
STFT : Kısa Zamanlı Fourier Dönüşümü (Short Time Fourier Transform)
SVM : Destek Vektör Makinesi (Support Vector Machine)
TN : Doğru Negatif (True Negative)
TP : Doğru Pozitif (True Positive)
WHO : Dünya Sağlık Örgütü (World Health Organization)
YSA : Yapay Sinir Ağı
ZF : Zaman-Frekans (Time-Frequency)

ÖZET

YÜKSEK LİSANS TEZİ

EEG SİNYALLERİNİN ZAMAN-FREKANS GÖSTERİMLERİNİN DERİN ÖĞRENME İLE ANALİZİ SONUCU ALZHEIMER HASTALIĞININ TESPİTİ

Meral ASLAN DİL

İstanbul Üniversitesi-Cerrahpaşa

Lisansüstü Eğitim Enstitüsü

Biyomedikal Mühendisliği Anabilim Dalı

Biyomedikal Mühendisliği, Tezli Yüksek Lisans Programı

Danışman : Prof. Dr. Fırat KAÇAR

II. Danışman : Prof. Dr. Aydın AKAN

Alzheimer Hastalığı (AH), nörodejeneratif bir hastalıktır ve demansın en yaygın türüdür. Bilişsel işlevsellikte kayıp, günlük aktivitelerde zorlanma ve hafıza eksikliği gibi semptomlarla kendini gösteren, ilerleyici ve geri dönüşü olmayan bir hastalıktır. Alzheimer hastalığının kesin bir tedavisi olmamakla birlikte, hastalığın erken teşhisi, etkili tedavi ve hastalığın yönetimi açısından önemlidir. Elektroensefalografi (EEG), Alzheimer hastalığının beyin üzerindeki etkilerini araştırmak için en sık tercih edilen klinik araçlardan biridir. EEG verilerinin derin öğrenme mimarilerinden olan Evrişimli Sinir Ağı (CNN) mimarileri ile eğitilerek, Alzheimer hastalığının tespitini yapmaya çalışmak, son zamanlarda üzerinde yoğun şekilde çalışılan konulardan biridir. Bu tez çalışmasında, derin öğrenme mimarileri ve zaman-frekans yaklaşımları kullanılarak Alzheimer hastalarının ve kontrol gönüllülerinin EEG verilerinin sınıflandırılması ile hastalığın erken teşhisi hedeflenmiştir. Bu amaçla, tanısal testlerle erken evre Alzheimer hastalığı teşhisi konmuş 15 Alzheimer hastasının ve 11 sağlıklı kontrol gönüllüsünün EEG sinyalleri incelenmiştir. EEG segmentlerinin, Kısa Zamanlı Fourier

Dönüşümü (STFT) ile spektrogram ve Sürekli Dalgacık Dönüşümü (CWT), Bump, Amor ve Morse dalgacıkları ile skalogram görüntüleri elde edilmiş ve bu görüntüler ResNet18, Modifiye ResNet18_1, Modifiye ResNet18_2, GoogleNet, AlexNet ve DarkNet Evrişimli Sinir Ağı (CNN) mimarileri ile eğitilerek elde edilen sonuçlar değerlendirilmiştir. Tüm mimarilerin sonuçları kanal bazlı ve beyin bölgesi bazlı olarak değerlendirildiğinde en yüksek başarım oranlarının beynin arka (posterior) bölgesinde bulunan P4 kanalından CWT Bump zaman-frekans yaklaşımı ile elde edildiği görülmektedir. En yüksek validasyon ve test doğruluk (ACC) sonucuna sahip olan ResNet18 mimarisinden ve ResNet18'in modifiye edilmesiyle elde edilen daha az katman sayısına ve daha düşük filtre derecesine sahip olan ve en hızlı ve dengeli performans sergileyen Modifiye ResNet18_2 mimarisinden sırasıyla %88,11 ve %80,64 sınıflandırma başarımları elde edilmiştir. İki mimari için kanal bazlı değerlendirmede ise P4 kanallarından sırasıyla %96,90 ve %93,70 validasyon doğruluk (ACC) değerleri kaydedilmiştir. Modifiye ResNet18_2 mimarisi, klasik ResNet18'e kıyasla kısmen daha düşük bir ACC değerine sahip olmasına rağmen, eğitim ilerlemesi sonuçlarına bakıldığında dengeli ve sağlam bir performans sergileyerek aşırı uyum (overfitting) göstermediği görülmektedir. Ayrıca, önerilen mimari, diğer modellere göre eğitim sürecini çok daha hızlı tamamlayarak önemli bir zaman tasarrufu sağlamıştır. Bu bulgular, Alzheimer hastalığının tespitinde Modifiye ResNet18_2 mimarisinin doğruluk ve eğitim verimliliği açısından iyi bir alternatif olduğunu göstermektedir.

Kasım 2024 , 146 sayfa.

Anahtar kelimeler: Alzheimer Hastalığı (AH), Elektroensefalografi (EEG), Evrişimli Sinir Ağı (CNN), Kısa Zamanlı Fourier Dönüşümü (STFT), Sürekli Dalgacık Dönüşümü (CWT), Doğruluk (ACC)

ABSTRACT

M.Sc. THESIS

DETECTION OF ALZHEIMER DISEASE THROUGH DEEP LEARNING ANALYSIS of EEG SİGNALS' TIME-FREQUENCY REPRESENTATIONS

Meral ASLAN DİL

İstanbul University-Cerrahpaşa

Institute of Graduate Studies

Department of Biomedical Engineering

Biomedical Engineering, Master's Thesis Program

Supervisor : Prof. Dr. Fırat KAÇAR

Co-Supervisor: Prof. Dr. Aydın AKAN

Alzheimer Disease (AD) is a neurodegenerative disease and the most common type of dementia. It is a progressive and irreversible disease that characterized by symptoms such as loss of cognitive functionality, difficulty in daily activities and memory deficit. Although there is no definitive treatment for Alzheimer Disease, early diagnosis of the disease is important for effective treatment and management of the disease. Electroencephalography (EEG) is one of the most commonly preferred clinical tools to investigate the effects of Alzheimer Disease on the brain. Trying to detect Alzheimer's disease by training EEG data with Convolutional Neural Network (CNN) architectures, one of the deep learning architectures is one of the research areas that has been intensively studied recently. In this thesis study, early diagnosis of the disease is aimed by classifying the EEG data of Alzheimer's patients and control volunteers using deep learning architectures and time-frequency approaches. For this purpose, EEG signals from 15 patients diagnosed with early-stage Alzheimer's disease through diagnostic tests and 11 healthy control volunteers were analyzed. Spectrogram images of EEG segments were obtained with

Short Time Fourier Transform (STFT) and scalogram images with Continuous Wavelet Transform (CWT), Bump, Amor and Morse wavelets, and these images were trained with ResNet18, Modified ResNet18_1, Modified ResNet18_2, GoogleNet, AlexNet and DarkNet Convolutional Neural Network (CNN) architectures and the results obtained were evaluated. When the results of all architectures are evaluated on a channel based and brain region based, it is seen that the highest performance rates are obtained with the CWT Bump time-frequency approach from the P4 channel located in the posterior region of the brain. Classification achievements of 88.11% and 80.64% were achieved in order for ResNet18, which has the highest validation and test accuracy (ACC) results, and for Modified ResNet18_2, which features fewer layers and lower filter sizes derived from the modification of the ResNet18 architecture, and exhibits the fastest and most balanced performance. For the channel-based evaluation of the two architectures, validation accuracy (ACC) values of 96.90% and 93.70% were recorded from the P4 channels, respectively. Although the modified ResNet18_2 architecture has a little lower ACC value compared to the classical ResNet18, when looking at the training progress results, it is seen that it shows a balanced and robust performance and it does not show overfitting. Additionally, the proposed architecture completed the training process much faster than other models, thereby achieving important time savings. These results show that the Modified ResNet18_2 architecture is a good alternative in terms of accuracy and training efficiency in detecting Alzheimer's disease.

November 2024, 146 pages.

Keywords: Alzheimer Disease (AD), Electroencephalography (EEG), Convolutional Neural Network (CNN), Short Time Fourier Transform (STFT), Continuous Wavelet Transform (CWT), Accuracy (ACC)

1. GİRİŞ

Dünya genelinde yaşam süresinin uzamasının sonucu olarak nüfusun yaş ortalaması artmaktadır. Yaşlılık demansın en büyük risk faktörü olduğu için, günümüzde demans vakaları dünya genelinde artış gösterme eğilimindedir. Demans, bilişsel yeteneklerin kaybıyla karakterize edilir. Alzheimer hastalığı demansın en yaygın türüdür. Alzheimer hastalığının kesin bir tedavisi olmamakla birlikte hastalığın erken tespiti, hastalığın ilerlemesinin geciktirilmesi ve semptomların yönetimi açısından önemlidir.

Elektroensefalografi (EEG), beyindeki nöronların aktiviteleri sonucu ortaya çıkan elektriksel işaretlerin kaydedilmesine dayanan bir yöntemdir. Maliyet, zaman ve uygulanma yöntemleri açısından avantajlı olmasından dolayı EEG, son zamanlarda Alzheimer hastalığının tespitinde sıkça tercih edilen klinik yöntemlerden biridir. AH hastalarının EEG sinyallerindeki en belirgin anormallikler arasında EEG karmaşıklığının azalması, EEG'nin yavaşlaması ve EEG'nin senkronizasyonunda bozukluklar bulunmaktadır [1].

Bu tez kapsamında segmente edilmiş EEG sinyallerinin, STFT ve CWT Amor, Bump ve Morse dönüşümleri ile zaman frekans analizleri yapılarak spektrogram ve skalogram görüntüleri elde edilmiş ve sonrasında bu görüntüler çeşitli CNN mimarileri ile eğitilerek Alzheimer hastalığının tespitinde en doğru yaklaşım elde edilmeye çalışılmıştır.

Bu çalışmada, tanısal testler ve nöro görüntüleme ile erken evre Alzheimer hastalığı teşhisi konmuş 15 AH hastasının ve 11 sağlıklı kontrol gönüllüsünün EEG sinyalleri kullanılmıştır. Sinyaller 19 kanaldan, 200 Hz örnekleme frekansında Philips Alice-6 cihazı kullanılarak kaydedilmiştir. EEG sinyal kayıt işlemi, İzmir Kâtip Çelebi Üniversitesi Tıp Fakültesi Nöroloji Bölümü'nde gerçekleştirilmiştir. Uluslararası 10-20 elektrot sistemi kullanılarak 19 kanaldan (Fp1, F7, T3, T5, O1, O2, T6, T4, F8, Fp2, F3, Fz, F4, C3, Cz, C4, P3, Pz, P4) EEG sinyalleri kaydedilmiştir [2].

Kavramsal çerçeve bölümünde çalışmanın temelini oluşturan sinir sistemi, beynin temel yapısı ve işlevleri, nöron yapısı ve elektriksel sinyal oluşumundan bahsedilmiştir. Demans ve Alzheimer hastalığı detaylıca anlatılarak, Alzheimer hastalığının erken teşhisinin önemi

açıklanmıştır. Beyin tarafından üretilen elektriksel aktiviteyi kaydeden EEG tanıtılarak kullanım alanlarından ve tercih sebebi olan özelliklerinden bahsedilmiştir. Alzheimer hastalığının erken teşhisi amaçlı yapılan çalışmalarda daha önceden tercih edilen yöntemler hakkında bilgi verilerek güncel literatür incelenmiştir.

Yöntem bölümünde tez çalışmasında kullanılan veri seti hakkında bilgi verilerek bu veri setinden elde edilen EEG sinyallerinin spektrogram ve skalogram görüntülerini elde etmek amacıyla kullanılan zaman frekans dönüşümleri olan STFT ve CWT Amor, Bump ve Morse hakkında açıklamalar yapılmış, zaman frekans dönüşümleri uygulanan EEG sinyallerinin her bir dönüşüm için birer örnek olmak üzere skalogram ve spektrogram görüntüleri verilmiştir (Şekil 3.4). Derin öğrenme (DL) ayrıntılı olarak açıklanarak elde edilen görüntülerinin eğitilmesi sonucu en tercih edilebilir yöntemin belirlenebilmesi amacıyla çalışmada kullanılan ResNet18, Modifiye ResNet18_1, Modifiye ResNet18_2, GoogleNet, AlexNet ve DarkNet Evrişimli Sinir Ağı (CNN) mimarileri hakkında detaylı bilgi verilmiştir. Çalışmada kullanılan performans metrikleri, hiperparametreler ve çalışma sonucu elde edilen ROC eğrisi hakkında açıklamalar yapılarak bölüm sonlandırılmıştır.

Bulgular bölümünde, EEG sinyallerinden zaman frekans dönüşümleri uygulanarak elde edilen skalogram ve spektrogram görüntülerinin CNN mimarileri ile eğitilmesi sonucu elde edilen kanal bazlı ortalama validasyon ve test performans metrikleri (PRE, FDR, SPE, SEN, ACC, F1 Skoru) değerlerinin tablo halinde gösterimleri (Tablo 4.1 - 4.12) yer almaktadır. Ardından tüm mimariler için ZF yaklaşımlarının hepsinin bütün kanallar için elde edilen ACC değerlerinin validasyon ve test tablolarına (Tablo 4.13 – 4.18) ve bu sonuçların grafiksel gösterimlerine (Şekil 4.1- 4.6) yer verilmiştir. Sonraki kısımda tüm mimariler için bütün ZF yaklaşımlarının beş beyin bölgesine (ön (anterior), merkez (central), sol temporal (temporal left), sağ temporal (temporal right) ve arka (posterior)) göre ortalama validasyon ve test FDR ve ACC değerlerinin tabloları (Tablo 4.19 – 4.30) ve grafiksel gösterimleri bulunmaktadır. Her mimari için, en iyi sonucun elde edildiği ZF yaklaşımından elde edilen ve beyin bölgeleri içinde en yüksek ACC değerlerine sahip olan kanalların eğitim ilerlemesi (training progress), validasyon ve test karmaşıklık matrisi ve ROC eğrisi görselleri bu bölümde verilmiştir. Son olarak tüm mimariler için beyin bölgesi bazlı en iyi sonuçlara sahip kanalların validasyon ACC değerleri, maksimum devir sayıları (max epoch) ve eğitim ilerlemesi (training progress) süreleri Tablo 4.32'de verilerek mimarilerin doğruluk ve eğitim verimliliği performansları değerlendirilmiştir.

Tartışma bölümünde, elde edilen sonuçlar incelenerek tezde kullanılan zaman-frekans analiz yöntemlerinin ve CNN mimarilerinin kullanılabilirliği ve verimliliği değerlendirilmiş ve mevcut literatür uygulamaları ile karşılaştırılmıştır.

Sonuç ve öneriler bölümünde, önerilen yöntemin, Alzheimer hastalığının erken tespitine katkıları tartışılmış ve gelecek çalışmalar için söz konusu olabilecek iyileştirmelerden ve önerilerden bahsedilmiştir.

1.1. TEZİN AMACI VE KATKILARI

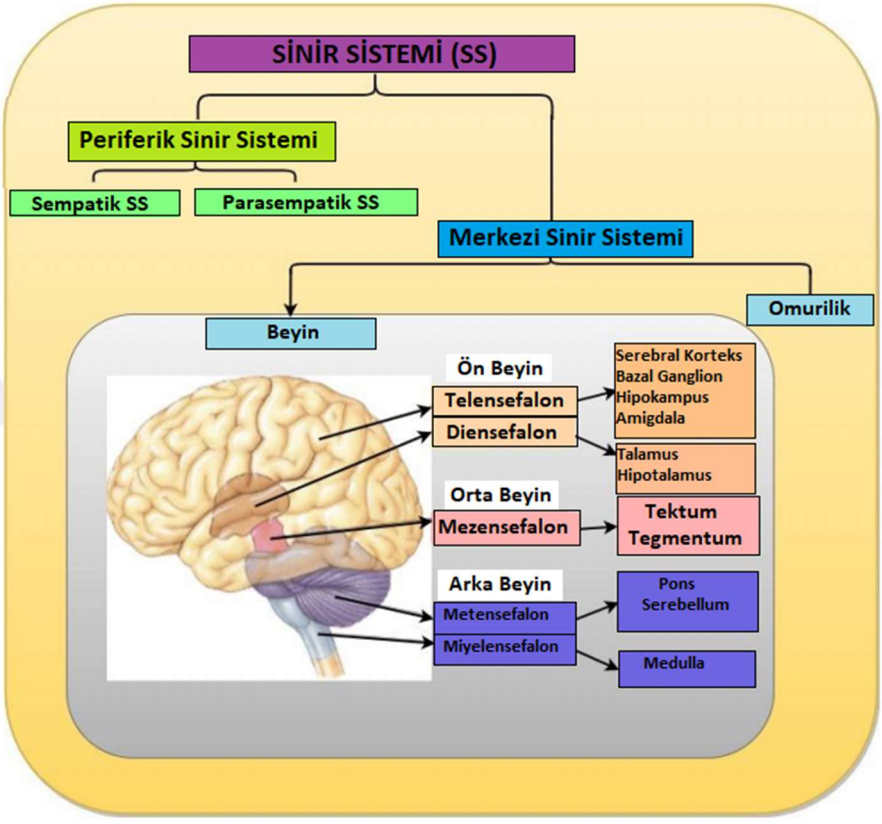
Tez çalışmasının temel amacı, nörodejeneratif hastalıkların en yaygın türü olan Alzheimer hastalığının erken tespiti için EEG verilerinin sınıflandırılmasında dengeli ve hızlı eğitim performansı ve yüksek başarım oranı elde eden en uygulanabilir yaklaşımı tespit etmektir. Bu amaçla Alzheimer hastalarına ve sağlıklı kontrol grubuna ait olan EEG verilerinin STFT ve CWT (Amor, Bump, Morse) zaman-frekans yöntemleri kullanılarak spektrogram ve skalogram görüntüleri elde edilmiştir. Ardından bu görüntüler Resnet18, Modifiye ResNet18_1, Modifiye ResNet18_2, GoogleNet, AlexNet ve DarkNet CNN mimarileri ile eğitilerek doğruluk ve eğitim performansı açısından en iyi sonuç veren yaklaşım belirlenmeye çalışılmıştır. Tezin temel hedefleri aşağıda sıralanmıştır;

- Alzheimer hastalığında etkili tedavinin sağlanması amacıyla hastalığın erken teşhisinin sağlanabilmesi.
- STFT ve CWT yaklaşımları kullanılarak Alzheimer hastalığının teşhisinde hangi zaman-frekans yönteminin daha iyi sonuç verdiğinin belirlenebilmesi.
- EEG verilerinden zaman-frekans yaklaşımları ile elde edilen görüntülerin Resnet18, Modifiye ResNet18_1, Modifiye ResNet18_2, GoogleNet, AlexNet ve DarkNet CNN mimarileri ile eğitimi sonucu Alzheimer hastalığının teşhisinde hangi derin öğrenme mimarisinin daha kullanışlı olduğunun tespit edilebilmesi.
- Yapılan çalışmalar sonucu hangi beyin bölgesinde ve hangi kanaldan Alzheimer hastalığının ayırt edilebilme oranının yüksek olduğunun ortaya çıkarılabilmesi.

2. KAVRAMSAL ÇERÇEVE

2.1. SİNİR SİSTEMİ

Sinir sistemi, vücudun karmaşık aktivitelerini düzenlemekte merkezi bir role sahiptir. Çeşitli bölümleri ve alt sistemleri aracılığıyla bilgi alışverişini sağlar, bu bilgilerin işlenmesini ve uygun tepkilerin üretilmesini yönetir. Bu, duyu organlarından gelen bilgilerin işlenmesi ve kasların ve bezlerin kontrol edilmesi gibi temel işlevleri içerir. Sinir sistemi anatomik açıdan merkezi ve periferik sinir sistemi olarak iki bölüme ayrılır. Merkezi sinir sistemi, beyin ve omurilikten oluşur. Periferik sinir sistemi ise, beyinden ve omurilikten çıkan sinirlerden oluşmaktadır. Sinir sistemi, vücudun sağlıklı ve uyumlu bir şekilde çalışmasını sağlamak için endokrin sistemiyle birlikte çalışır ve çevresel uyaranlara uygun yanıtlar üretir [3].



Şekil 2.1: Sinir Sistemi Bölümlerinin Şematik Gösterimi [4].

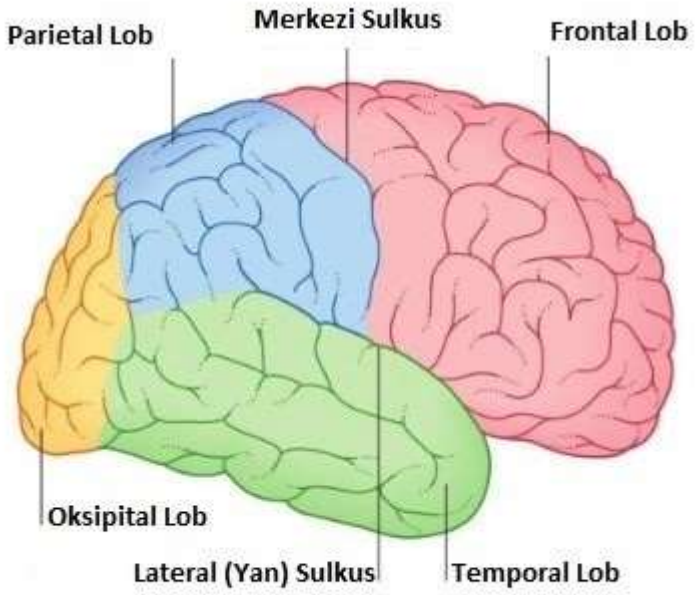
2.2. BEYNİN TEMEL YAPISI VE İŞLEVLERİ

Beyin, merkezi sinir sisteminin en büyük bölümüdür. Ağırlığı 1400-1500 gr olan beyin yaklaşık 100 milyar nöron içerir. Yoğun metabolizmasından dolayı sürekli oksijen ve besin maddelerine gereksinimi olan beyin, vücut ağırlığının yüzde 2'si kadar bir kitleye sahip olmasına rağmen kalp atım hacminin yüzde 15-20'sini alır [5]. Beyin, jelatinimsi bir kütle olup, ardışık üç bağ doku zarıyla kaplanmıştır ve dış kapsül olarak kafatası tarafından korunmaktadır. Beyin, beyin omurilik sıvısı içinde yüzer; bu sıvı, beyni destekler ve başın hızlı hareketlerinde şok emici olarak işlev görür [3].

2.2.1 BEYNİN BÖLÜMLERİ

Beyin her biri farklı işlevleri yerine getiren üç ana bölümden oluşur; ön beyin, orta beyin ve arka beyin. Orta beyin, beynin en küçük bölümü olup işitsel ve görsel bilgileri işlemeye ve hareketi düzenlemeye yardımcı olur. Arka beyin, dengenin korunmasına, duyusal bilgilerin yönlendirilmesine, hareketin ve otonomik işlevlerin düzenlenmesine yardımcı olan beyin bölümüdür. Ön beyin ise beynin akıl yürütmeye ve problem çözmeye yardımcı olan, duyusal bilgiyi işleyen, motor fonksiyonları ve endokrini düzenleyen bölümüdür. Ön beyin, beyin kütlesinin yüzde 75'ini kapsayan serebral korteksi içerir. Serebral korteks, motor fonksiyonların kontrolü, duyusal bilgilerin işlenmesi, düşünme ve problem çözme gibi üst düzey fonksiyonların yürütülmesi görevlerini yerine getirir ve dört önemli loba sahiptir (Şekil 2.2) [4, 6, 7].

- **Frontal Lob:** İstemli hareketlerin motor kontrolü, düşünme, yargılama ve hafıza gibi önemli işlevlerden sorumludur.
- **Parietal Lob:** Duyusal bilgilerin alınması ve işlenmesi gibi her türlü duyusal işlevden sorumludur.
- **Temporal Lob:** İşitme duyusu, denge ve hafıza ile ilgili işlevlerden sorumludur.
- **Oksipital Lob:** Görme duyusu ile ilgili işlevlerden sorumludur [4].

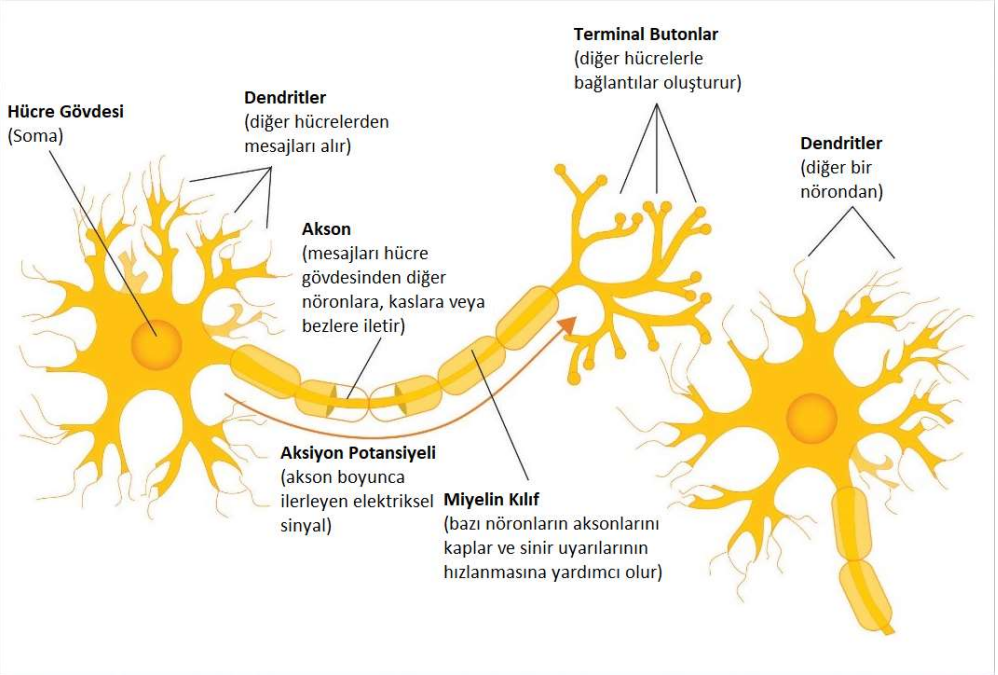


Şekil 2.2: Beynin Lobları [6].

2.3. NÖRONUN YAPISI VE ELEKTRİKSEL SİNYAL OLUŞUMU

Beyinde yaklaşık olarak 100-200 milyar nöron (sinir hücresi) ve çok daha fazla glial hücre bulunmaktadır. Bu hücreler geniş bir çeşitlilik, form ve boyuttadırlar. Bir nöron, uyarıcılara tepki vermek, bu uyarıcının sonucunu diğer sinir hücrelerinin, kas hücrelerinin ve bez hücrelerinin başka kısımlarına hızlı bir şekilde iletmek ve diğer nöronları etkilemek için tasarlanmıştır. Nöronlar o kadar özelleşmiştir ki çoğu nöron kendisini yeniden üretemez ve eğer nöronlar birkaç dakikadan fazla bir süre boyunca oksijen kaynağından mahrum kalırlarsa canlılıklarını kaybedebilirler [3].

Bir nöronun sinir sistemindeki işlevi, bilgiyi almak ve iletmektir. Nöronlar Şekil 2.3'te gösterildiği gibi üç ana bölümden oluşur; hücre gövdesi (soma), dendritler ve akson. Hücre gövdesi (soma); hücrenin çekirdeğini içerir ve hücreyi canlı tutar. Dendritler; diğer hücrelerden bilgi toplar ve bilgiyi hücre gövdesine gönderir. Akson; bilgiyi hücre gövdesinden diğer nöronlara, kaslara veya bezlere iletir [8].



Şekil 2.3: Nöronun Bileşenleri [8].

Nöronlar arası iletişim için aksiyon potansiyelinin oluşması gereklidir. Aksiyon potansiyeli, iyon değişimine dayanan ve aksonun iyonik yapısını hızla değiştirerek elektrik sinyalinin dendritlerden hızlıca geçmesine izin veren fizyolojik bir olaydır. Sinir hücresi dinlenme durumunda, yani herhangi bir uyarım olmadığında, -70 ila -90 milivolt arasında bir potansiyele sahiptir ve hücre polarize durumdadır. Dendritler uyarı aldığında, pozitif yüklü sodyum iyonlarının hücre içine akışı sonucunda iç potansiyel -60 milivolt seviyesine ulaşır ve eşik değer aşılır. Bu durumda, aksiyon potansiyeli oluşumu için süreç devam eder. Ancak eşik değeri aşılmazsa, "ya hep ya hiç" kuralı gereği hücre dinlenme durumuna geri döner. Eşik değer aşıldığında, pozitif yüklü sodyum iyonlarının hücre içine geçişi artar ve iç potansiyel yükselir. Hücre içi potansiyel 20 milivolt olduğunda, hücrenin dinlenme durumuna dönmesi için potasyum kanalları açılır. Pozitif yüklü potasyum iyonlarının hücre dışına çıkmasıyla hücre dinlenme durumuna geri döner. Yeni bir uyarım gelene kadar dinlenme durumunda kalır [9, 10].

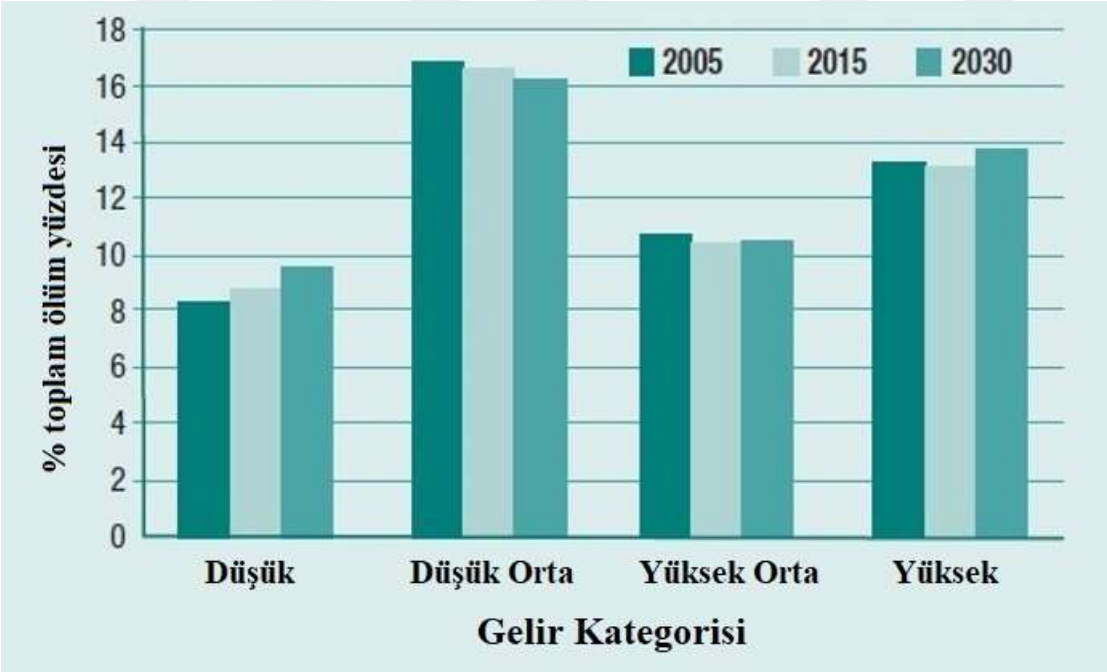
2.4. DEMANS VE ALZHEIMER HASTALIĞI (AH)

Nörolojik bozukluklar, önemli bir ölüm nedenidir ve dünya genelinde toplam ölümlerin %12'sini oluşturur (Tablo 2.1) [11].

Tablo 2. 1: Nörolojik bozukluklara bağlı olan ölümler, toplam ölümlerin yüzdesi olarak ifade edilmiştir, 2005,2015,2030 [11].

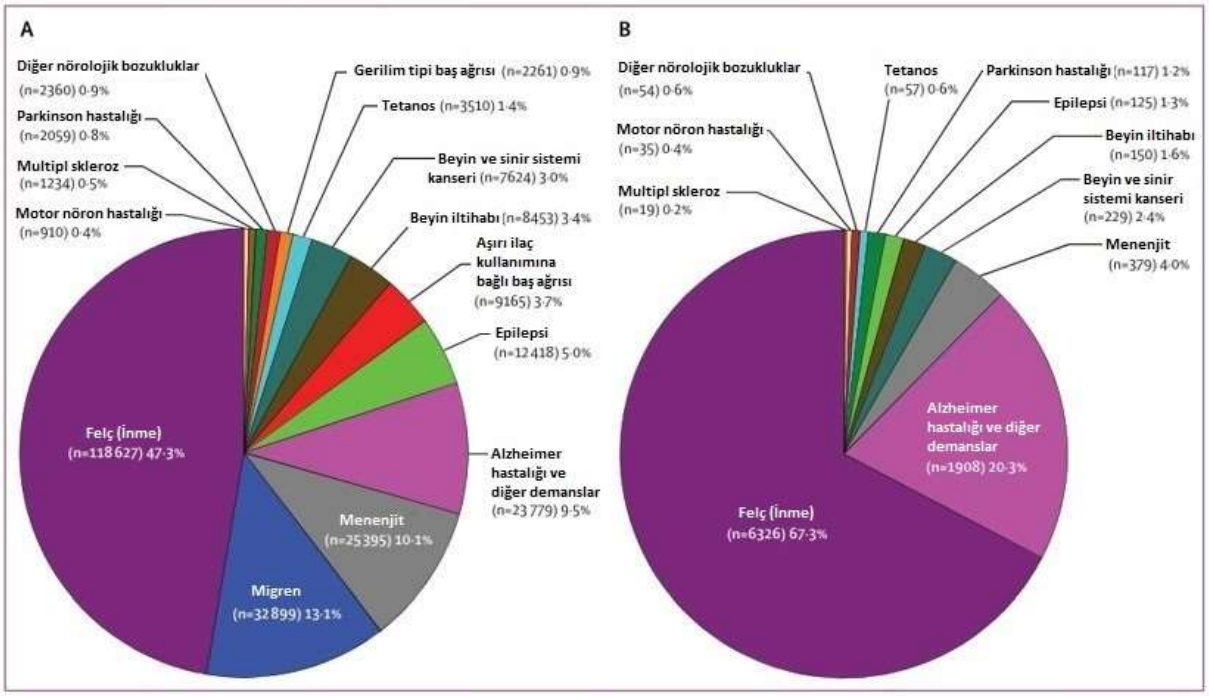
Sebep Kategorisi	2005 (%)	2015 (%)	2030 (%)
Epilepsi	0.22	0.21	0.19
Alzheimer ve diğer demanslar	0.73	0.81	0.92
Parkinson hastalığı	0.18	0.20	0.23
Multipl skleroz	0.03	0.03	0.02
Migren	0.00	0.00	0.00
Beyin damar hastalığı	9.90	10.19	10.63
Çocuk felci	0.00	0.00	0.00
Tetanos	0.33	0.23	0.13
Menenjit	0.26	0.17	0.10
Japon ensefaliti	0.02	0.01	0.01
Toplam	**11.67**	**11.84**	**12.22**

Nörolojik bozukluklar, düşük orta gelirli ülkelerde toplam ölümlerin %16.8'ini oluştururken, yüksek gelirli ülkelerde toplam ölümlerin %13.2'sini oluşturur [11].



Şekil 2.4: Dünya Bankası gelir kategorisinde 2005, 2015 ve 2030 yılları için Nörolojik bozuklukların toplam DALY'ler (the Disability-Adjusted Life Year) içindeki yüzdesi [11].

Dünya çapında genel olarak, DALY'lerde (erken ölüm sebebiyle kaybedilen yaşam yılları ile engellilikle geçirilen yılların toplamı) en büyük orana sahip olan nörolojik bozukluk oranları felç; %47,3, migren; %13,1, Alzheimer hastalığı ve diğer demanslar; %9,5 ve menenjit; %10,1 şeklindedir. Nörolojik nedenlerden kaynaklanan en yaygın üç ölüm sebebi ise felç; %67,4, Alzheimer hastalığı ve diğer demanslar; %20,3 ve menenjit; %4,0 şeklindedir [12].



Şekil 2.5: 2015 yılında çeşitli nörolojik bozuklukların, nörolojik bozuklukların tamamına oranı. Tahminler engelliliğe göre düzenlenmiş yaşam yılları (DALYs) (A) ve ölümler (B) içindir [12].

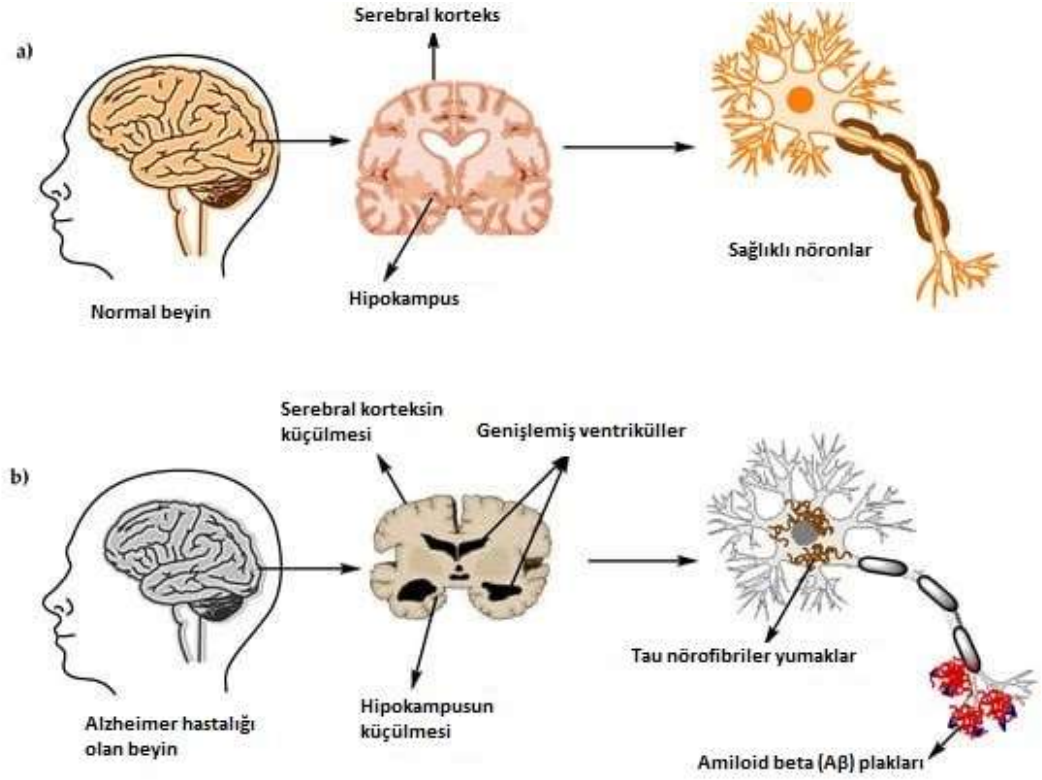
Demans, genellikle beyin hastalığına bağlı olarak gelişen, kronik veya ilerleyici bir yapıya sahip olan bir sendromdur. Bu sendromda, bellek, düşünme, hesaplama, oryantasyon, kavrama, öğrenme kapasitesi, dil ve değerlendirme gibi birçok üst kortikal işlevde bozukluklar oluşur. Bilinç bulanık değildir. Demans, çoğunlukla yaşlı insanları etkiler ve 65 yaşından önce başlayan vakaların oranı sadece %2'dir. Ancak, yaşla birlikte her beş yılda bir demansın yaygınlığı iki katına çıkmaktadır. Demans, ileri yaşlarda engelliliğin ana nedenlerinden biridir [11]. Bu nedenle yaş, demans için en büyük risk faktörlerinden biridir. Diğer bir önemli risk faktörü ise cinsiyettir ve farklı demans türlerinin insidansı kadınlar ve erkekler arasında farklılık göstermektedir. Ayrıca hastalığa yakalanma olasılığı genetik faktörlerle yakından ilişkilidir.

Depresyon da demans için bir başka risk faktörüdür. Demansa neden olan önemli rahatsızlıklar arasında yüksek tansiyon ve diyabet gibi vasküler risk faktörlerinin yanı sıra felç ve kalp hastalıkları da yer almaktadır. Aşırı sigara ve alkol kullanımı gibi yaşam tarzı ile ilgili etkenler de demans olasılığını artıran faktörlerden bazılarıdır [4].

Dünya Sağlık Örgütü (WHO), 2020 yılında 60 yaş ve üzerindeki insan sayısının 1 milyarı geçtiğini ve bu yaş grubunun 2050 yılında 2,1 milyar kişiye ulaşacağını tahmin etmektedir. Bu kişilerin üçte ikisinin düşük ve orta gelirli ülkelerde yaşayacağı öngörülmektedir. Aynı dönemde, 80 yaş ve üzerindeki kişi sayısının 426 milyona ulaşarak üç kat artması beklenmektedir. Toplumlar yaşlandıkça, dünya genelinde demansla mücadele eden insanların sayısının 2019'da 55 milyondan 2050'de 139 milyona yükselmesi öngörülmektedir [13].

Demans, bilişsel yeteneklerde günlük yaşam aktivitelerini engelleyecek kadar ciddi bir düşüşü belirten genel bir terimdir. Alzheimer hastalığı (AH), demansın en yaygın biçimidir. AH, 65 yaş ve üstü demans vakaların %50-75'ini oluşturur ve diğer demans sendromlarına kıyasla en yaygın ölüm nedenidir. 45 yaş civarında, AH geliştirme riski kadınlar için %20, erkekler için %10'dur; ancak 65 yaşından sonra her iki cinsiyet grubu için de bu risk artmaktadır. AH, yavaş başlayan ve davranışsal ve bilişsel işlevlerde ilerleyici bozulma ile seyreden nörodejeneratif bir durumdur. Bu işlevler arasında hafıza, kavrama, düşünme, dikkat, dil ve yargılama yer almaktadır. AH, direkt olarak ölüme sebep olmasa da, diğer komplikasyonlara karşı hassasiyeti önemli ölçüde artırır ve sonuç olarak kişinin ölümüne yol açabilir [4, 14].

Adını Alman psikiyatrist Alois Alzheimer'dan alan Alzheimer hastalığı, yavaş ilerleyen bir nörodejeneratif hastalık olarak tanımlanabilir. Bu hastalık, medial temporal lob ve neokortikal yapılar gibi beyin bölgelerinde hücrelerin arasında bulunan sinaptik boşluklarda amiloid-beta peptitinin (Aβ) birikmesi sonucu oluşan nörotik plaklar ve hücrelerin iç kısmında tau proteinlerinin anormal birikimiyle oluşan nörofibriler demetler ile nitelendirilmiştir [15, 16]. Alois Alzheimer, kişilik değişikliği ve hafıza kaybı yaşayan ilk hasta olan hastanın beynini incelediğinde, amiloid plakların varlığını ve büyük miktarda nöron kaybını gözlemlemiş ve bu durumu beyin korteksinin önemli bir hastalığı olarak tanımlamıştır. Emil Kraepelin, bu sağlık durumunu ilk kez psikiyatri el kitabının 8. baskısında "Alzheimer hastalığı" olarak adlandırmıştır [15].

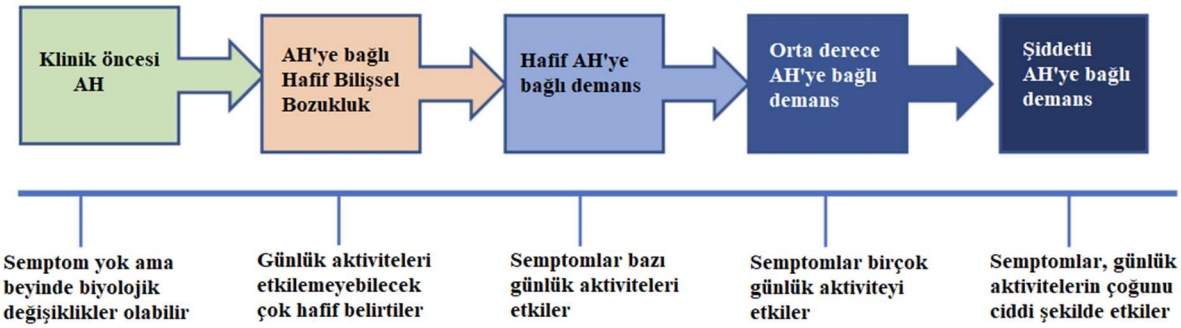


Şekil 2.6: (a) Sağlıklı olan ve (b) Alzheimer hastalığı (AH) olan beynin ve nöronların fizyolojik yapısı [15].

AH çoğunlukla yaşlı bireylerde görülmektedir. Alzheimer hastalığının görülme sıklığı 65 yaşından itibaren her 5 yılda bir yaş artışıyla yaklaşık iki katına çıkmaktadır. Yaş artışıyla birlikte hastalığın görülme oranları önemli ölçüde artar. AH'nin şu an için bir tedavisi yoktur, ancak bazı semptomları hafifletebilecek ve yönetebilecek tedaviler bulunmaktadır. Son yıllarda, özellikle yeni hastalık biyobelirteçlerinin keşfiyle beraber, hastalığın ilerlemesini yavaşlatmayı hedefleyen ilaçların geliştirilmesinde önemli ilerlemeler elde edilmiştir [14]. Bu sebeple Alzheimer hastalığının erken teşhisi hastanın yaşam kalitesinin sürdürülmesi ve hastalığın yönetimi açısından oldukça önemlidir.

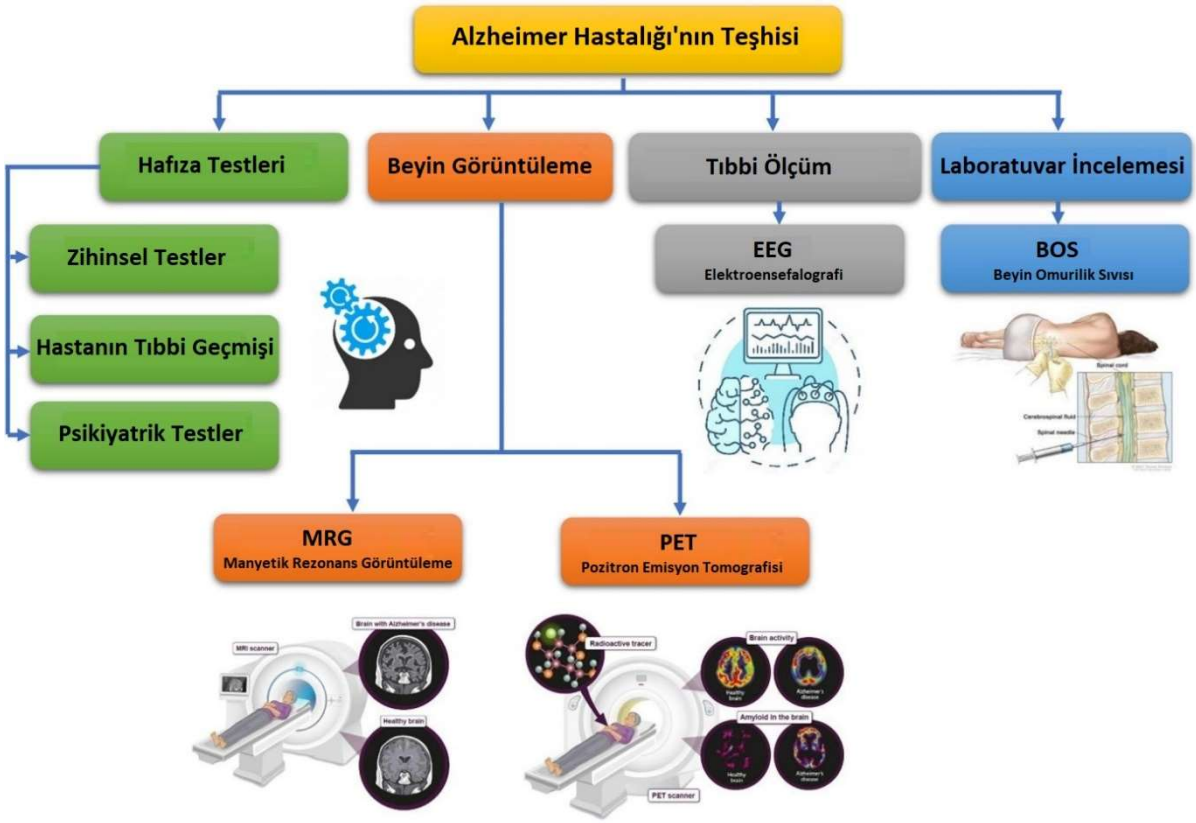
AH üç aşamaya ayrılır: erken aşama AH, hafif aşama AH ve şiddetli aşama AH [3]. Erken aşama AH, bazen hafif bilişsel bozukluk (HBB - Mild Cognitive Impairment (MCI)) olarak adlandırılır ve fark edilebilir bilişsel gerilemenin başlangıcıdır, ancak semptomlar engelleyici değildir ve bireyler kendi başlarına yaşamlarını sürdürebilir. Bu aşamada, bireyler görevleri organize etme, birden fazla işi aynı anda yapma, dil ve hafıza konularında zorluk yaşayabilirler. Hafif aşama AH en yaygın olan aşamadır ve konsantrasyon zorluğu, günlük görevlerde

zorluklar gibi belirtileri içerir. Bu aşamada, bireyler başkalarının yardımına daha fazla bağımlı olabilir ve banyo yapma ve giyinme gibi günlük aktivitelerde desteğe ihtiyaç duyabilirler. Ağır aşama AH, kafa karışıklığı, yanılsama, huzursuzluk ve idrar kaçırma gibi belirtileri içerir [4]. Bu dönemde, bireyler temel ihtiyaçlarını karşılamak için tamamen başkalarına bağımlı hale gelirler [17].



Şekil 2.7: Alzheimer Hastalığı'nın (AH) spektrumu [18]

AH'yi teşhis etmenin kesin bir yolu olmamakla birlikte, çeşitli testler hastalığın teşhisinde yardımcı olabilir. Mini-Mental Durum Testi gibi hafıza testleri, bireyin son zamanlarda yaşadığı olayları hatırlamasını ve geçmiş olayları hatırlayabilme yeteneğini ölçebilir [10]. Manyetik rezonans görüntüleme (MRG) veya pozitron emisyon tomografisi (PET) gibi beyin taramaları, Alzheimer ile ilişkilendirilen beyin anormalliklerini tespit etmek için kullanılabilir [11, 12]. Elektroensefalografi sinyalleri (EEG), beyindeki elektriksel aktiviteyi tespit etmek için kullanılan bir yöntemdir. AH dahil olmak üzere çeşitli tıbbi ve nörolojik durumları teşhis etmekte kullanılır [19]. Ayrıca, omurilik sıvısı analizi ve lomber ponksiyon, beyin omurilik sıvısındaki (BOS) protein seviyelerini belirleyerek Alzheimer hastalığına özgü biyobelirteçlerin tespit edilmesini sağlayabilir [13]. AH belirtileri taşıyan bireylerin, doğru ve zamanında bir teşhis almaları için multidisipliner bir değerlendirme önerilir [14]. Bu şekilde bir değerlendirme genellikle bir nörolog, bir psikolog, bir davranışsal nörolog ve bir geriatri birinci basamak hekiminden oluşan bir ekip tarafından gerçekleştirilir. Hastanın zihinsel durumunu değerlendirmek için Geriatrik Depresyon Ölçeği gibi psikiyatrik testler de uygulanabilir [15]. Ayrıca hastanın bakıcıları, bireyin davranışı hakkında teşhis koymaya yardımcı olabilecek önemli bilgiler sağlayabilir. Şekil 1'de AH'nin teşhis yöntemleri gösterilmektedir [17].



Şekil 2.8: Alzheimer Hastalığı'nın teşhis yöntemleri [17].

2.5. ELEKTROENSEFALOGRAFİ (EEG)

Elektroensefalografi (EEG) sinyalleri, beynin elektriksel aktivitesini temsil eder ve bu sinyaller beyin nörolojik aktivitesinin analizinde sıkça kullanılır. EEG sinyalleri, ilk olarak 1875 yılında Caton tarafından keşfedilmiştir. Sonrasında, 1929 yılında, Hans Berger, galvanometre bağlantılı elektrotları başın üzerine yerleştirerek EEG sinyallerinin varlığını deneysel olarak göstermiştir. O zamandan beri, EEG sinyalleri birçok araştırma alanında kullanılmaktadır [19, 20].

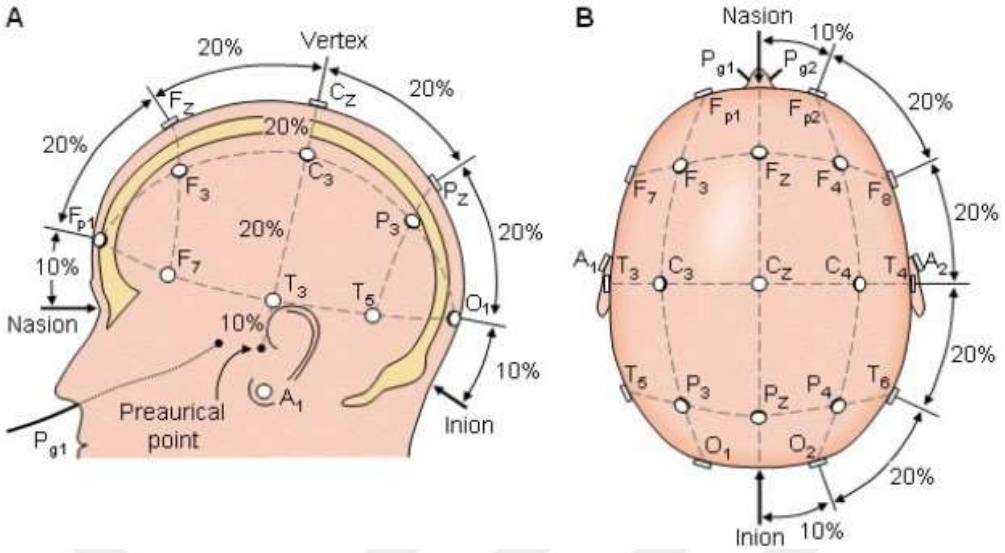
Hans Berger tarafından yapılan ilk insana ait EEG kayıtlarının yayınlanmasından bu yana, EEG sinyallerini kaydetmek ve görüntülemek için kullanılan cihazlar basit galvanometrelerden ve kağıtlardan dijital bilgisayarlara evrilmiştir. Bir nörolog tarafından incelenmesi amacıyla normal bir yetişkinin klinik olarak kaydedilen EEG kaydı, Şekil 2.8'de gösterilmiştir [21].



Şekil 2.9: Tipik klinik teşhis için normal yetişkin EEG kaydı [21].

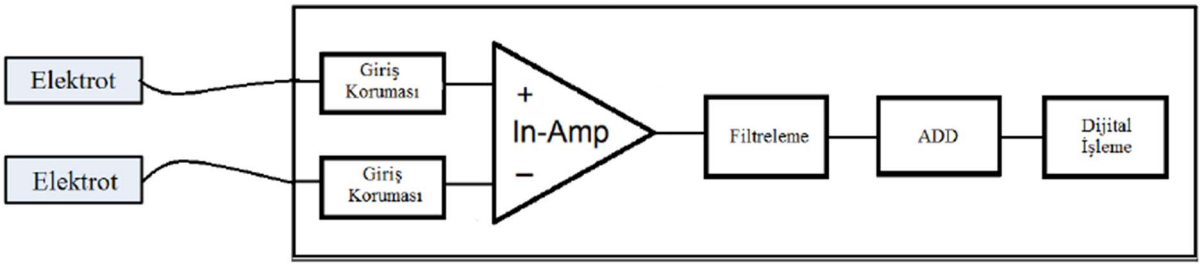
EEG, herhangi bir risk taşımadığı için hastalarda, sağlıklı yetişkinlerde ve çocuklarda yaygın olarak kullanılan bir yöntemdir. EEG tarafından kaydedilen elektriksel aktivite, genellikle serebral korteksteki piramidal hücrelerde toplanmış postsinaptik potansiyellerle ilişkilendirilen hücre dışı akımla oluşur. Kaydedilebilir elektriksel aktiviteyi, yalnızca büyük nöron gruplarındaki senkronize potansiyel değişimleri oluşturabilir. Oluşturulan bu potansiyel, hücre içi ve hücre dışı ortamlar arasındaki elektriksel potansiyel farkından oluşmaktadır. Küçük genliklere sahip elektriksel sinyaller, saçlı deri yüzeyine yerleştirilmiş elektrotlar ile nöron tabakaları arasında deri, kafatası ve çeşitli farklı katmanlar da bulunduğu için yükseltilerek değerlendirilmek amacıyla bilgisayara kaydedilir ve aynı zamanda kâğıda yazdırılır ya da bilgisayar ekranından takip edilir [22].

Kafa derisi yüzeyine elektrotların yerleştirilmesi işlemi için, uluslararası olarak kabul edilen ve 21 elektrotlu olan 10-20 sistemi kullanılır. Bu sistem Şekil-1 de gösterildiği şekilde uygulanmaktadır. Nasion, gözlerle hizalanmış burun üzerindeki noktayı ifade eder. İnion ise kafa derisinin ortasındaki noktayı temsil eder ve aslında kafatasının tabanında yer alan kemik çıkıntıdır. Bu noktalardan diğer parametreler, eksenel ve uzunlamasına düzlemde değerlendirilir [23].



Şekil 2.10: İlk kez 1958'de sunulan ve uluslararası olarak kabul edilen 10-20 sistemi [23].

EEG sinyalleri, belirli bir şekle sahip değildir ve kişinin anlık duyusal ve motor işlevlerine bağlı olarak çeşitli ritim ve şekiller gösterebilir. Elektrotlar aracılığıyla alınan sinyallerin genlikleri oldukça küçük olup mikro volt (μV) derecesindedir. Bu sebeple, sinyaller öncelikle bir kuvvetlendiriciden geçirilerek yeterli genliğe ulaştırılır. Sonrasında, sinyaller genellikle [0,5 – 45] Hz aralığında bir bant geçiren filtreleme (band-pass filtre) işleminden geçirilir. Filtreleme işlemi tamamlandıktan sonra, analog sinyaller dijital hale getirilmek amacıyla bir analog-dijital dönüştürücüden geçirilir. Dijital sinyal bilgisayarlara kaydedildikten sonra, dijital sinyal işleme uygulamalarına hazır hale gelir [24].



Şekil 2.11: EEG cihazına ait elektronik devre blok diyagramı [24].

Bir EEG, geniş frekans bileşenleri içerir. Ancak, fizyolojik ve klinik odak aralığı 0.3 ile 30 Hz aralığında bulunmaktadır. Bu aralık, aşağıdaki gibi yaklaşık olarak birkaç frekans bandında sınıflandırılmıştır:

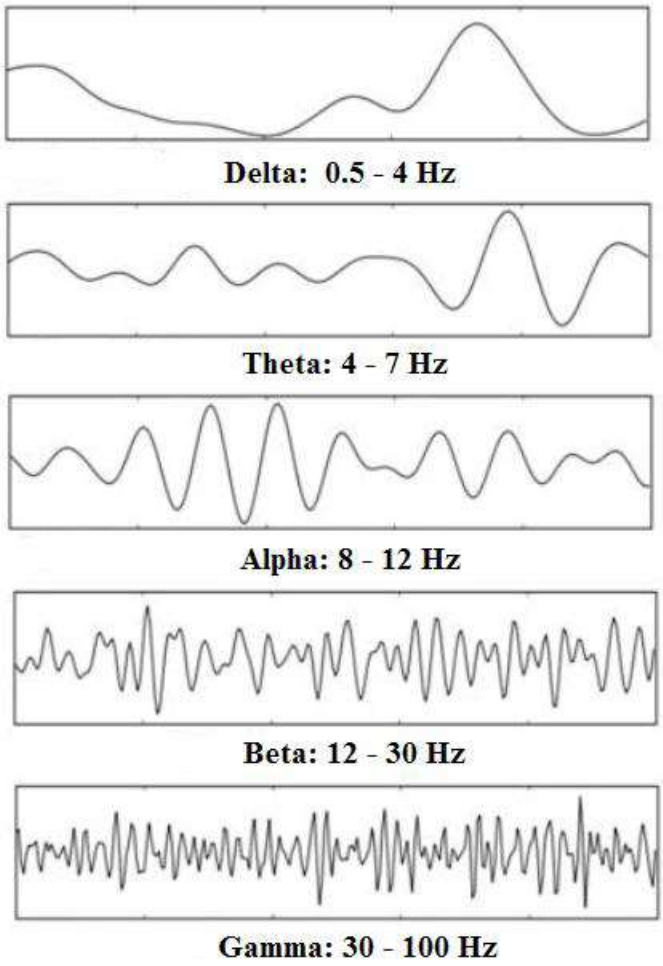
- **Delta (0.5-4 Hz):** Delta ritimleri, normal yetişkinlerin yalnızca derin uyku evrelerinde baskın olan yavaş beyin aktiviteleridir. Aksi halde, patolojileri işaret eder.

- **Teta (4-8 Hz):** Bu EEG frekans bandı, normal bebeklerde ve çocuklarda olduğu gibi yetişkinlerde uykulu olunan durumlarda ve uyku halinde bulunur. Normal uyanık yetişkinlerde yalnızca az miktarda teta ritmi görülür. Uyanık yetişkinlerde yüksek teta aktivitesinin mevcut olması, patolojik ve anormal durumları gösterir.

- **Alfa (8-14 Hz):** Alfa ritimleri, normal yetişkinlerde rahat ve zihinsel olarak aktif olmayan uyanıklık halinde bulunur. Genellikle genlik 50 mV'den azdır ve en çok oksipital bölgede ortaya çıkar. Gözlerin açılması (görsel dikkat) ve düşünme gibi diğer zihinsel girişimlerle Alpha ritimleri baskılanır.

- **Beta (14-30 Hz):** Beta aktivitesi çoğunlukla frontal merkezi bölgede alfa ritimlerine kıyasla daha düşük genliğe sahiptir. Gerilim ve beklenti durumlarında güçlenir.

- **Gama (30 Hz üzeri):** Gama ritimleri yüksek frekans bandında bulunur ve çoğunlukla klinik ilgi alanında yer almadığı için EEG kayıtlarında genellikle filtrelenir [21].



Şekil 2.12: EEG alt bantları [24].

Elektroensefalografi (EEG), epilepsi, şizofreni, anksiyete bozuklukları, majör depresif bozukluk, bipolar bozukluk, dikkat eksikliği hiperaktivite bozukluğu (DEHB), nörogelişimsel bozukluklar, uyku bozuklukları, travmatik beyin yaralanması ve demans gibi çeşitli nörolojik ve psikiyatrik durumların tanısında ve incelenmesinde kullanılabilir. EEG, çeşitli psikiyatrik ve nörogelişimsel bozukluklarla ilişkilendirilen beyin aktivitesinin ve anormalliklerin tespit edilmesine yardımcı olarak teşhis ve tedavi sürecine katkı sağlar. Ancak, kapsamlı bir değerlendirme için çoğunlukla diğer klinik değerlendirmelerle birlikte kullanılır ve bu anlamda nöroloji veya psikiyatri alanındaki uzmanların yorumları oldukça önemlidir [25].

EEG yöntemi gerçek zamanlı bilgiler sunması, beyin dalgalarında AH'ye bağlı olarak gelişen ince değişiklikleri erken tespit edebilmesi, radyasyon içermemesi, uygun maliyetli olması,

invaziv olmaması, erişilebilir ve taşınabilir olması nedeniyle Alzheimer hastalığının teşhis edilmesinde oldukça avantajlı bir yöntemdir. Ayrıca EEG, AH'nin teşhisi konusunda biyobelirteçlerin tespit doğruluğunu artırır, anormal aktiviteyi tespit edebilir ve hastalığının ilerlemesini zaman içerisinde takip edebilir [26, 17].

EEG analizi, Alzheimer hastalığına bağlı beyin dinamikleri hakkında faydalı bilgiler sağlayabilir. Alzheimer hastalığı ile bağlantılı olarak EEG'de ortaya çıkan en belirgin özellikler, EEG'nin yavaşlaması, EEG tutarlılığının düşmesi ve EEG karmaşıklığının azalmasıdır [27, 28].

2.6. LİTERATÜR TARAMASI

Demans, beyindeki yapısal değişikliklerden kaynaklanan en yaygın nörolojik bozukluklardan biridir. Bu durum, kişinin günlük yaşantısını ve aktivitelerini etkileyebilecek bilişsel fonksiyonların bozulmasına yol açar. Bu bilişsel bozukluklar, hafıza kaybı, öğrenme yetisinde azalma, dil, anlama, düşünme, hesaplama ve muhakeme yeteneklerinin kaybı veya azalması gibi durumları kapsar. Alzheimer hastalığı (AH), 65 yaş ve sonrasında görülen tüm demans vakalarının yaklaşık %50-75'ini oluşturan en yaygın demans türüdür ve diğer demans türlerine kıyasla en yaygın ölüm sebebidir. AH ile ilişkilendirilen en belirgin beyin değişiklikleri; nöronların dışında biriken beta-amiloid protein parçası ve nöronların içinde biriken anormal tau proteini formudur [29, 30]. Bu çalışmada, erken evre Alzheimer hastalığı tanısı konmuş bireylerden ve sağlıklı kontrol grubu bireylerinden elde edilen EEG verileri incelenmiştir.

Alzheimer hastalığının teşhisi ve tedaviye yanıtın takibinde elektroensefalografi (EEG), manyetik rezonans görüntüleme (MRG), magnetoensefalografi (MEG) ve bilgisayarlı tomografi (BT) gibi çeşitli tıbbi yöntemler uygulanabilir. EEG, düşük maliyeti ve invaziv olmaması nedeniyle son yıllarda bilim dünyasında büyük ilgi görmüş ve birçok araştırmacı AH hastalarının EEG kayıtlarını analiz ederek EEG aktivitesindeki karmaşıklık, senkronizasyon ve düzenlilik gibi değişiklikleri incelemeye odaklanmıştır [29, 31, 32]. Literatürde, AH'nin teşhisi ve tedavi süreci takibinde EEG kullanılarak gerçekleştirilen ve önemli sonuçlar elde edilen birçok çalışma bulunmaktadır.

Demans hastalarındaki EEG sinyallerinin analizi amacıyla, çeşitli çalışmalarda delta, teta, alfa, beta ve gamma gibi farklı EEG frekans bantlarının toplam gücü, mutlak gücü ve göreceli gücü incelenmiştir [33, 34, 35]. Önceki araştırmalara göre, AH hastaları, sağlıklı olan yaşlı bireylerden delta (≤4 Hz) ve teta (4–8 Hz) frekans bantlarında daha yüksek güç ve daha yüksek

değişkenlik ve alfa (8–13 Hz) frekans bandında daha düşük güç ve frekans yavaşlaması ile farklılık göstermiştir [1].

Çalışmalar incelendiğinde EEG sinyallerini kullanarak beyin karmaşıklığını ölçmek için birçok çalışma yapıldığı görülmektedir. Yaklaşık entropi [31, 32, 34, 36], örnek entropi [32], permütasyon entropisi [32, 36, 37], spektral entropi [38], Tsallis entropisi [32], çok ölçekli entropi [32], Box boyutu [39], dağılım entropisi [40], çok değişkenli çok ölçekli ağırlıklı permütasyon entropisi [41], permütasyon Jaccard mesafesi [37], korelasyon boyutu [42], Higuchi fraktal boyutu [38, 39], Katz'ın fraktal boyutu [39], Lempel-Ziv karmaşıklığı [43, 44] ve Lyapunov üssü [42] gibi çeşitli doğrusal olmayan özellikler AH hastaları ve kontrol grubu deneklerinin (KG) EEG verilerinden hesaplanmıştır. Bu çalışmaların tamamında, AH hastalarının beyin karmaşıklığının kontrol grubuna göre azaldığı tespit edilmiş ve sonuçlar hastalığın tespit ve tedavi süreçleri için umut verici olmuştur.

EEG alt bantlarının ve sinyallerinin çeşitli özelliklerini hesaplamanın yanı sıra, AH hastalarının EEG verilerinin analizi için sürekli dalgacık dönüşümleri (CWT) [45, 46], kısa zamanlı fourier dönüşümü (STFT) [1], ayrık dalgacık dönüşümü (DWT) [35, 47, 48], ampirik mod ayrıştırma (EMD) [29, 48] ve yinelemeli filtreleme ayrıştırması [49] gibi farklı ayrıştırma teknikleri kullanılmıştır.

EEG sinyalleri yapısal olarak karmaşık ve değişkendir, sinyallerin gürültüden etkilenmesi kolaydır. Bu sebeple Alzheimer hastalığının tanısı için orijinal EEG verilerinden değerli bilgileri elde etmek, normal matematiksel istatistik yöntemleriyle zor olabilir. Yapay zeka teknolojisinin gelişmesiyle, giderek daha çok araştırmacı bu teknolojiyi EEG sinyal analizinde kullanmaktadır. Makine öğrenimi, yapay zekanın bir alt kümesidir ve makine öğreniminin birçok klasik algoritması AH teşhisi alanında değerlidir [50]. 2011 yılında Staudinger ve Polikar [38], AH teşhisi için 79'u AH hastası ve 82'si yaşa uygun kontrol grubu bireyi olmak üzere toplam 161 bireyden elde edilen EEG sinyallerini, Hi-guchi fraktal boyutu (HFD), spektral entropi (SE), spektral ağırlık merkezi (SC), spektral düşüş (SR) ve sıfır geçiş oranı (ZCR) yöntemlerini kullanarak analiz etmiştir. İlk etapta t-testi uygulanarak gruplar arasındaki farklılıkları anlamlı kılan özellikleri belirlemek istemişlerdir. Bu özellikler sonrasında bir sinir ağını eğitmek için kullanılmıştır. Elde edilen özelliklerin bir destek vektör makinesi (SVM) ile eğitilmesi sonucu %78'lik bir tanısal doğruluk oranı elde edilmiştir. 2019'da Tavares ve arkadaşları [51] tarafından, AH teşhisi için 19 AH hastasına ve 17 sağlıklı deneğe ait dinlenme

halinde kaydedilen EEG sinyallerinden farklı frekans bantlarının güç spektrum yoğunlukları (PSD) elde edilmiştir. Elde edilen PSD'ler Regresyon, Ağaç, Destek Vektör Makineleri (SVM) ve Topluluk (Ensemble) kategorilerinin altında yer alan sekiz farklı makine öğrenimi algoritmasına input olarak kullanılmış ve ortalama %95,60 (92,86-97,14) değerinde sınıflandırma doğruluk oranı elde edilmiştir. 2017'de Simons ve Aba'solo [43], AH hastalarının EEG verilerindeki elektrot çiftleri arasında bulunan değişiklikleri karakterize etmek için yeni bir doğrusal olmayan sinyal işleme ölçütü olan mesafe bazlı Lempel-Ziv karmaşıklığını (dLZC) tanıtmıştır. Çalışmaları kapsamında 11 AH hastasının ve yaş uyumlu 11 kontrol deneğinin EEG'leri analiz edilerek AH hastalarının dLZC değerlerinin çoğu elektrot çifti için kontrol deneklerine göre daha düşük olduğu tespit edilmiştir. Çalışmada, birey bazlı sınıflandırma için %77,27 ve devir sayısı (epoch) bazlı sınıflandırma için ise %78,25 maksimum tanı doğruluklarına ulaşılmıştır. Bu bulgular AH hastalarına ait EEG verilerinin kontrol grubuna ait verilerden daha az karmaşık olduğunu göstermekle birlikte aynı zamanda hastalardan alınan EEG elektrot çiftlerinde yer alan bilgi zenginliğinin de aynı yaştaki kontrol deneklerinin EEG verilerine göre daha düşük olduğunu göstermektedir. 2019 yılında Tzimourta ve arkadaşları [31], EEG kayıtlarından AH'yi tespit etmek için çeşitli istatistiksel ve spektral özellikleri değerlendirmişlerdir. Bu amaçla 14 AH hastasına (8 hafif AH ve 6 orta düzey AH) ve 10 sağlıklı bireye ait EEG kayıtları analiz edilmiştir. Sonrasında, her bir EEG ritmi (δ, θ, α, β ve γ) için çeşitli istatistiksel ve spektral özellikler hesaplanarak bu özelliklerden Random Forest (Rastgele Orman) sınıflandırıcısını eğitmek ve test etmek için bir özellik vektörü oluşturulmuştur. Sonuçlar incelendiğinde tüm beyin sınıflandırması için %88,79 ile %96,78 aralığında yüksek bir doğruluk oranı elde edilmiştir. 2022'de Cura ve arkadaşları [29], EEG sinyallerini kullanarak Alzheimer hastalığının tespiti ve takibi için çeşitli sinyal işleme yöntemlerini incelemişlerdir. 15 AH hastasının ve 11 kontrol deneğinin EEG segmentlerini sınıflandırmak amacıyla ampirik mod ayrıştırma (EMD), toplu ampirik mod ayrıştırma (EEMD) ve ayrık dalgacık dönüşümü (DWT) yöntemlerini uygulamışlardır. EMD ve EEMD yöntemleri kullanılarak sinyallerden doğal mod fonksiyonları (IMF'ler) elde edilmiştir. 1 dakikalık segment süresi için en yüksek sınıflandırma doğrulukları, EMD (%91.8) ve EEMD (%94.1) yaklaşımları ile temporal/sağ beyin kümesinden elde edilirken; DWT (%95.2) yaklaşımı için en yüksek sınıflandırma doğruluğu temporal/sol beyin kümesinden elde edilmiştir. AH'yi teşhis etmek amacıyla EEG sinyallerini makine öğrenimi algoritmaları kullanımı ile analiz etmek, tarama süresini ve insan müdahalesini azaltır ve bu sayede tanısal sonuçlar daha verimli ve objektif hale gelir [50].

Klasik makine öğrenimi algoritmaları iyi performans elde etmek için çoğunlukla karmaşık özellik mühendisliği (feature engineering - FE) gerektirir. Bu durum araştırmacıların orijinal EEG'yi incelemek ve uygun özellikleri çıkarmak için fazla zaman harcaması gerektiği anlamına gelir. Derin öğrenme makine öğreniminin bir alt kümesidir; özellik mühendisliğinin otomasyonunu gerçekleştirmek için sinir ağı ve gizli katmanlar kullanır. Böylece araştırmacıların zaman ve enerjisinden büyük ölçüde tasarruf sağlar. Ayrıca, yapay olarak seçilen özelliklerin, EEG verilerindeki önemli bilgilerin kaybına neden olma riski vardır. Derin öğrenme algoritması EEG verilerini daha etkin bir şekilde kullanabilir ve algoritmanın sağlamlığını artırabilir. Son yıllarda, AH'yi teşhis etmek amacıyla EEG'yi analiz etmek için derin öğrenme mimarilerini kullanmak umut verici ve önemli bir gelişmedir [50].

Literatür incelemesi yapıldığında, EEG sinyalleri ve derin öğrenmenin kombinasyonu yoluyla AH'yi teşhis etmeye yönelik pek çok çalışma karşımıza çıkmaktadır.

2021 yılında Mazrooei ve arkadaşları [52], EEG beyin sinyalinden hafif evre Alzheimer hastalığının tespiti konusunda yeni bir yöntem önermişlerdir. Önerilen yöntemde, 40 katılımcıdan (10 ağır hasta, 11 hafif hasta ve 19 sağlıklı) gözler açık, gözler kapalı, hatırlama ve uyarılma olmak üzere dört modda, üç kanaldan Pz, Cz ve Fz beyin sinyalleri kaydedilmiştir. Ön işleme sonrasında çeşitli EEG sinyal özellikleri çıkarılmıştır. Çalışmalar, uyarımdan sonra P300 bileşeninin genliğinin ve gecikmesinin artan yaş ve Alzheimer hastalığının evreleri ile birlikte değiştiğini göstermiştir. Ek olarak, hafif evre Alzheimer hastalarında beyin sinyalindeki ilk değişiklikler, alfa bandı aktivitesindeki bir azalma ile ilişkili olarak, beta bandında aktivitenin azalması ve teta bandında aktivitenin artmasıdır. Uygun özellikler Varyans Analizi (ANOVA) yöntemi ile seçildikten sonra katılımcıların özelliklerini sınıflandırmak için doğrusal diskriminant analizi (LDA), Elman sinir ağı ve evrişimli sinir ağları (CNN) kullanılmıştır. Bulgular, üç EEG sinyali içinden Pz kanalının ve dört kayıt adımı içinden uyarım modunun diğerlerinden daha yüksek doğruluk oranına sahip olduğunu göstermiştir. Pz kanalının özellikleri kullanılarak, geri çağırma ve uyarım modlarında LDA'nın doğruluğu %59,4 - %66,4, Elman sinir ağının doğruluğu %92,3 - %94,1 ve CNN'nin doğruluğu %97,5 - %99 oranlarında elde edilmiştir. Sonuçlara göre, doğrusal ve doğrusal olmayan özelliklerin çıkarılması sınıflandırıcıların doğruluğunu arttırmıştır. Ayrıca beyin sinyalinin dinamik doğası nedeniyle evrişimli sinir ağı (CNN), LDA ve Elman sinir ağından daha iyi performans göstermiştir.

2023’te Ravikanti ve Saravanan [53], EEG sinyalinden AH'nin tespiti için bir derin öğrenme stratejisi önermişlerdir. İlk olarak, kullanılacak EEG sinyali geleneksel çevrimiçi veritabanlarından elde edilmiştir ve ardından sinyal, 3 seviyeli Lifting Wavelet Dönüşümü (LWT) ayrıştırmasıyla birçok dalga formuna ayrıştırılmıştır. Ayrıştırılmış sinyalden, zamansal özellikler Tekrarlayan Sinir Ağı (RNN) ile elde edilirken, mekansal özellikler Çok ölçekli genişletilmiş Evrişimli Sinir Ağı (CNN) ile çıkarılmıştır. Daha sonra, ağırlıklı birleştirilmiş özelliklerin elde edilmesi için en uygun ağırlık değerini bulmak amacıyla EWGLO (Enhanced Wild Geese Lemurs Optimizer) algoritması uygulanmıştır. Ortaya çıkan bu ağırlıklı birleştirilmiş özellikler, AH'yi tespit etmek için OTALSTM (Optimized Transformer-based Attention Long Short Term Memory) modelinin kullanıldığı yarı tespit aşamasına uygulanmıştır. Tespit aşamasında, aynı EWGLO kullanılarak tespit sürecinin performansını artırabilmek için parametre optimizasyonu gerçekleştirilmiştir. Tasarlanan model, en etkili sonucu göstermek için çeşitli performans metrikleriyle doğrulanmıştır. Geliştirilen model, doğruluk ve MCC (Matthews Korelasyon Katsayısı) açısından %96 ve %98 yüksek başarı oranlarına ulaşmıştır.

2023 yılında Cura ve arkadaşları [1], AH hastalarına ve sağlıklı kontrol grubuna ait EEG segmentlerini sınıflandırmak için derin öğrenme tabanlı zaman-frekans özellik çıkarımını standart makine öğrenimi (machine learning – ML) algoritmalarıyla birleştiren hibrit bir teknik önermişlerdir. Erken evre AH tanısı konmuş 15 AH hastası ile 11 sağlıklı kontrol gönüllüsüne ait EEG segmentlerinin STFT ve SST yaklaşımları kullanılarak Zaman-Frekans Temsilleri (TFR) elde edildikten sonra dört farklı CNN modeli olan Resnet18, Resnet50, AlexNet ve GoogleNet kullanılarak derin özellik çıkarma işlemi gerçekleştirilmiştir. Sonrasında DT, SVM ve kNN olmak üzere üç ML sınıflandırıcısı, KG ve AH olmak üzere iki grup arasında ayrım yapmak için kullanılmıştır. Deneysel sonuçlara göre, ResNet50 modeli tüm sınıflandırıcılarda diğer CNN modellerini geride bırakarak STFT yaklaşımı için %87,07'ye ve SST yaklaşımı için %81,59'a kadar doğruluk oranına ulaşmıştır. ML algoritmalarından ise SVM sınıflandırıcısı neredeyse tüm beyin kümeleri için hem SST hem de STFT tekniklerinde, diğer sınıflandırıcılardan daha iyi performans göstermiştir. Sonuç olarak STFT yöntemi, SST yöntemini geride bırakarak AH hastalarının ve kontrol bireylerinin EEG segmentlerini sınıflandırmada daha iyi performans göstermiştir.

2023’te Xia ve arkadaşları [50], Alzheimer hastalığının teşhisi için dinlenme halindeki EEG sinyallerinin AH, hafif bilişsel bozukluk (MCI) ve sağlıklı kontrol (KG) olarak sınıflandırılması

amaçlı yeni bir yaklaşım önermişlerdir. Önerileri kapsamında mevcut derin öğrenme modellerinin aşırı öğrenme ve sınırlı veri sorunlarının üstesinden gelmek için, 100 denekten (49 AH, 37 MCI ve 14 KG deneği) elde edilen EEG verilerinin Fourier Dönüşümü (FFT - Fast Fourier Transform) ile ön işlenmesiyle özellik çıkarımı yapıldıktan sonra, tek boyutlu EEG verilerini arttırmak amacıyla örtüşen kayan pencereler kullanılmıştır. Uygun veri seti oluşturulduktan sonra, arttırılmış EEG'yi sınıflandırmak amacıyla çalışmada değiştirilmiş DPCNN (deep pyramid convolutional neural network) kullanılmıştır. Ayrıca, modelin performansı 5 kere 5 katlı çapraz doğrulama ile değerlendirilerek karmaşıklık matrisi elde edilmiştir. Sonuçlara bakıldığında önerilen modelin, AH, MCI ve KG sınıflandırmasındaki ortalama doğruluk değeri %97,10 ve üç sınıflı sınıflandırma modelinin F1 skoru %97,11 oranlarına ulaşarak model başarılı bir performans elde etmiştir.

2022 yılında Park ve arkadaşları [54], tedavide erken teşhisin önemi sebebiyle klinik öncesi AH (pAH) evresinin zamanında tespit edilebilmesi amacıyla bir çalışma önermişlerdir. Bu çalışma için 52 sağlıklı kontrol bireyi ve 39 klinik öncesi AH hastası olmak üzere toplam 91 katılımcının dinlenme durumu elektroensefalografi (EEG) verileri toplanmıştır. Ardından verilerin sınıflandırma işlemi için derin sinir ağları (Deep ConvNet, EEGNet, EEG-TCNet ve basamaklı CRNN) kullanılmış ve katılımcılar arası paradigma içinde ve dışında sınıflandırma yapma işlemi denenerek sınıflandırma doğruluğunun bireysel varyasyonları bulunmuştur. Ayrıca, katılımcılar arasındaki nörofizyolojik benzerlikleri saptamak amacıyla bireyselleştirilmiş bir tanı stratejisi önerilmiş ve bireysel özellikler dikkate alınarak önerilen yeni yaklaşım, elde edilen %98.7–%100 ACC değeriyle tanı performansını yaklaşık %20 oranında arttırarak başarılı bir sonuca ulaşmıştır.

2019'da Bi ve Wang [55], EEG spektral görüntülerinden daha iyi genelleme ve daha soyut özellik çıkarımı yapabilmek amacıyla hibrid özellik haritaları ile diskriminatif konvolüsyonel yüksek dereceli Boltzmann Makineleri temelli yeni bir çoklu görev öğrenme stratejisi yöntemi önermişlerdir. Bu amaçla 4 sağlıklı kontrol grubu bireyi, 4 MCI hastası ve 4 AH hastası olmak üzere toplam 3 gruptan gözler kapalı olacak şekilde dinlenme durumunda elde edilen EEG sinyalleri kullanılmıştır. Sınıflandırma işlemini, orijinal modelleri olan Contractive Slab ve Spike Konvolüsyonel Derin Boltzmann Makinesi (CssCDBM)'nden farklı olarak, etiket katmanının indüklenmesiyle EEG spektral görüntü sınıflandırmasının yapıldığı DCssCDBM modeliyle gerçekleştirmişlerdir. Ardından DCssCDBM'yi aşırı uyumun azaltılması için EEG

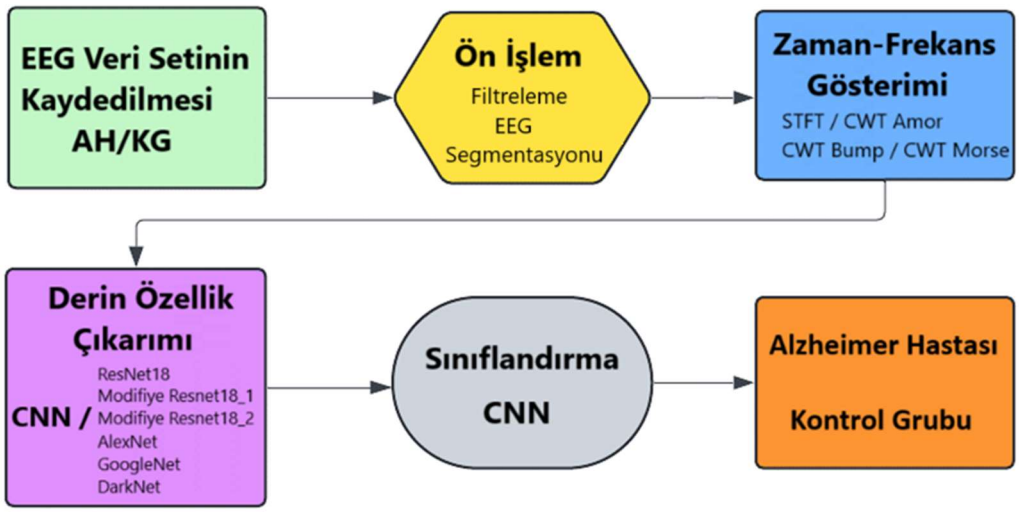
spektral görüntülerine dayalı tanımlama ve doğrulama görevleri aracılığıyla çok görevli öğrenme çerçevesiyle eğitmişler ve %78.33–%95.04 ACC oranında sonuçlar elde etmişlerdir.

2019 yılında Ieracitano ve arkadaşları [56], yaptıkları çalışmada Alzheimer Hastalığı (AH), Hafif Bilişsel Bozukluk (MCI) ve Sağlıklı Kontrol (KG) bireylerinin EEG verilerinin sınıflandırılması için güç spektrumuna (PSD) dayalı özgün bir derin öğrenme yöntemi önermişlerdir. Bu çalışmada sunulan metodoloji, 19 kanaldan elde edilen EEG verilerinin güç spektral yoğunluğunu (PSD) değerlendirerek, bu spektral profilleri 2 boyutlu gri tonlamalı görüntüler (PSD görüntüleri) şeklinde temsil etmekte ve bu görüntülerden gizli özellikleri otomatik olarak çıkarabilen bir Konvolüsyonel Sinir Ağı (CNN) sunmaktadır. Önerilen CNN yöntemi, ikili sınıflandırmada ortalama %89,8 ve üçlü sınıflandırmada ortalama %83,3 doğruluk oranı elde etmiştir.

2024 yılı Şubat ayında Parra ve arkadaşları [18], yayınladıkları çalışmada, Alzheimer hastalığına (AH) sahip bireyleri Orta Dereceli veya İleri Düzey Alzheimer demansı olarak kategorize etmek amacıyla EEG verilerinin analizi için tasarlanmış makine öğrenimi (ML) ve derin öğrenme (DL) yöntemlerini ele almaktadırlar. Çalışma 10 yıllık bir süre zarfında (2011-2022) 5 farklı hastaneden toplanan 668 gönüllüye (kontrol grubu 261 kişi, orta düzeyde Alzheimer hastalığı teşhisi konan 201 kişi ve ileri düzeyde Alzheimer hastalığı teşhisi konan 206 kişi) ait EEG verilerinden oluşan kapsamlı bir veri tabanına dayanmaktadır. CNN modeli 3 evrişimsel katman, bir düzleştirme katmanı ve iki tam bağlı (FC) katman olmak üzere 6 katmandan oluşmaktadır ve EEG verilerini işleyebilmek için 2 boyutlu matris formunda yapılandırılmıştır. Giriş verileri, zamanın bir fonksiyonu olarak nicel değişkenleri içermekte olup, bu veriler 32 kanaldan elde edilen EEG sinyallerinin zaman ve genlik ölçümünü temsil eden bir 2D matris formundadır. Sonuç olarak, Orta Dereceli Alzheimer Demansı (ADM) hastaları ve İleri Alzheimer Demansı (ADA) hastaları için sınıf tabanlı çıktılar elde edilmektedir. Bu modelin yenilikçi yönü, giriş verilerini iki boyutlu bir yapı formatında işleyerek kanallardan elde edilen EEG sinyal örneklerini sınıflandırabilme yeteneğidir. İncelenen yöntemler arasında, CNN (derin öğrenme) yaklaşımı diğerlerinden daha iyi performans göstererek Orta Dereceli Alzheimer Demansı (ADM) hastaları için %97,45 ve İleri Alzheimer Demansı (ADA) hastaları için %97,03'lük bir sınıflandırma doğruluğuna ulaşmıştır.

3. YÖNTEM

Bu tez kapsamında tanısal testler ve nöro görüntüleme ile erken evre Alzheimer hastalığı teşhisi konmuş 15 AH hastasının ve 11 sağlıklı kontrol gönüllüsünün segmente edilmiş EEG sinyallerinden STFT ve CWT Amor, Bump ve Morse dönüşümleri ile zaman frekans analizleri yapılarak spektrogram ve skalogram görüntüleri elde edilmiş ve ardından bu görüntüler ResNet18, Modifiye ResNet18_1, Modifiye ResNet18_2, GoogleNet, AlexNet ve DarkNet Evrişimli Sinir Ağı (CNN) mimarileri ile eğitilerek Alzheimer hastalığının tespitinde en doğru yaklaşım elde edilmeye çalışılmıştır. Aşağıda bulunan blok diyagram (Şekil 3.1) araştırma sürecinin aşamalarını ve uygulanan yöntemleri özetlemektedir.



Şekil 3.1: Çalışmanın blok diyagramı (AH; Alzheimer Hastalığı, KG; Kontrol Grubu, EEG; Elektroensefalogram, STFT; Kısa Zamanlı Fourier Dönüşümü, CWT; Sürekli Dalgacık Dönüşümü).

3.1. ÇALIŞMADA KULLANILAN ALZHEIMER DEMANS EEG VERİLERİ

Bu çalışmada, erken evre Alzheimer hastalığı teşhisi konmuş 15 AH hastasının ve 11 sağlıklı kontrol gönüllüsünün EEG sinyalleri kullanılmıştır. Kullanılan EEG verileri, İzmir Kâtip Çelebi Üniversitesi Tıp Fakültesi Nöroloji Bölümü demans kliniğinde, kapsamlı bir incelemeye tabi tutulan hastalardan elde edilmiştir. Söz konusu hastalara nörogörüntüleme teknikleri ve tanısal testler kullanılarak erken evre Alzheimer hastalığı teşhisi konulmuştur. EEG sinyalleri

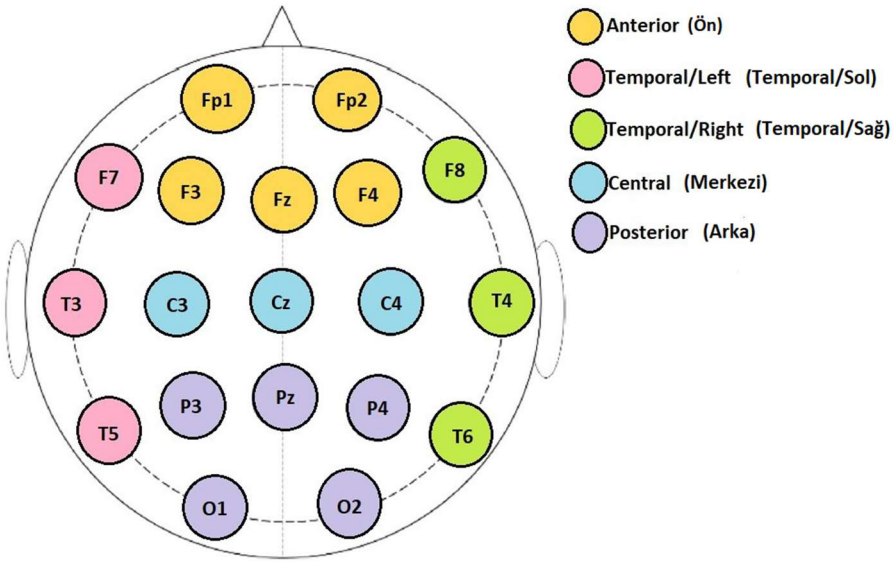
dikkatle kaydedilen toplam 15 AH hastasından 8'i kadın 7'si erkektir ve ortalama Mini-Mental Test (MMT) puanları 30 üzerinden 22 olup ortalama yaşları 64.53±8.47'dir. Kontrol grubu bireylerinin 5'i kadın ve 6'sı erkek olup ortalama yaşları 57.09 ± 5.28'dir. Sinyaller 19 kanaldan, 200 Hz örnekleme frekansında Philips Alice-6 cihazı kullanılarak yaklaşık 30'ar dakika boyunca kaydedilmiştir. Kayıt sırasında standart veri toplama koşulunu sağlaması için hastalara ve kontrol grubuna gözleri kapalı olarak dinlenme durumunu korumaları söylenmiştir. Kayıt sırasında sadece EEG sinyalleri kaydedilmiştir. Diğer fizyolojik sinyaller bu süreçte kayıt altına alınmamıştır [2, 4]. EEG sinyalleri yüzey elektrotlarından, elektrot yerleşimleri Fp1, F7, T3, T5, O1, O2, T6, T4, F8, Fp2, F3, Fz, F4, C3, Cz, C4, P3, Pz, P4 şeklinde olan uluslararası 10-20 elektrot sistemi kullanılarak kaydedilmiştir. Kontrol grubuna ait EEG sinyalleri, aşağıda bulunan şartları sağlayan sağlıklı gönüllülerden alınmıştır;

- Bilişsel süreçler üzerinde etkisi olabilecek herhangi bir ilaç kullanmamak,
- Alkol ve madde bağımlılığı öyküsüne sahip olmamak,
- Herhangi bir psikiyatrik veya nörolojik hastalığı olmamak,
- EEG kayıt gününde kafein içerikli içecekler tüketmemiş olmak.

Bu tez çalışmasında kullanılan EEG sinyalleri için, İzmir Katip Çelebi Üniversitesi Klinik Araştırma Etik Kurulu'ndan 22.10.2020 tarihli ve 83 numaralı etik onay alınmıştır [4].

Önişleme aşamasında, her EEG sinyali, katılımcıların kas hareketleri ve göz kırpma hareketleri gibi etmenleri azaltmak için 0.5–45 Hz aralığında bir tip II Butterworth bant geçiren filtre ile filtrelenmiştir. Ardından filtrelenen EEG sinyalleri, 1000 örnekten oluşan (5 saniye uzunluğunda) ve üst üste gelmeyen pencerelere bölünerek segmente edilmiştir.

Alzheimer Hastalığında farklı kortikal bölgelerin ayrı ayrı değerlendirilmesinin önemi sebebiyle, çalışmamızda beynin beş farklı kümesi ayrı ayrı analiz edilmiştir: Ön (Fp1, F3, Fz, Fp2, F4), Arka (P3, O1, Pz, P4, O2), Merkez (C3, Cz, C4), Temporal/sol (T3, T5, F7) ve Temporal/sağ (T4, T6, F8) (Şekil 3.2). Bu işlem, beynin çeşitli bölgelerindeki farklılıkları tespit etmek amacıyla yapılmıştır ve sonuçların tamamı beş farklı beyin kümesi göz önünde bulundurularak verilmiştir. Beyin kümelerinin ilgili sınıflandırma performanslarını belirlemek için, ilgili EEG kanalları temel alınarak ortalama sınıflandırma performansları hesaplanmıştır [29].



Şekil 3.2: Elektrot bölgelerine göre beyin kümeleri [29].

3.2. ZAMAN-FREKANS YAKLAŞIMLARI İLE EEG VERİLERİNDEN GÖRÜNTÜLERİN ELDE EDİLMESİ

Söz konusu veri setinden elde edilen EEG sinyallerinin 5 saniye süreyle segmente edilmiş formlarından, zaman-frekans dönüşümleri olan STFT ve CWT Amor, Bump ve Morse dönüşümleri kullanılarak spektrogram ve skalogram görüntüleri elde edilmiştir. Elde edilen bu görüntüler Alzheimer Hastalığının erken teşhisinde en doğru yöntemin belirlenebilmesi amacıyla Resnet18, Modifiye ResNet18_1, Modifiye ResNet18_2, GoogleNet, AlexNet ve DarkNet Evrişimli Sinir Ağı (CNN) mimarileri ile eğitilmiş ve elde edilen sonuçlar bulgular bölümünde paylaşılmıştır.

3.2.1. Kısa Zamanlı Fourier Dönüşümü (STFT)

Kısa Zamanlı Fourier Dönüşümü (Short Time Fourier Transform – STFT), zamanla değişen frekans içeriğini yakalamak için durağan olmayan sinyallerin kısa süreli işlenmesine dayanan geleneksel bir yöntemdir. STFT, sinyali kısa süreli ve çoğunlukla örtüşen segmentlere ayırmak için kayan bir pencere kullanır. Kısa süreli segmentlerin Fourier dönüşümleri hesaplanır ve işlem, sinyalin tamamı pencereleme ile kaplanana kadar tekrar edilir. Ortaya çıkan STFT'nin çözünürlüğü, pencere boyutu, pencere türü ve örtüşmenin miktarı gibi analiz parametrelerine bağlı olarak değişkenlik gösterir. STFT'nin büyüklük karesine "Spektrogram" denir ve bir sinyalin enerjisinin zaman-frekans (ZF) düzlemi üzerinde nasıl dağıldığını tahmin etmek için sıklıkla kullanılır [57, 58].

$$X(t,w) = \int_{-\infty}^{\infty} x(T)W(T-t)e^{-j\omega t}\,dT \quad (3.1)$$

Yukarıda bulunan ifadede, $X(t,\ \omega)$; STFT'yi, $x(t)$; analiz edilen sinyali ve $w(t)$; pencere fonksiyonunu temsil etmektedir. Verilen bir $x(t)$ sinyalinin ve seçilen bir $w(t)$ pencere fonksiyonunun STFT hesaplaması, $X(\omega)$ ve $W(\omega)$ Fourier dönüşümleri kullanılarak aşağıdaki gibi formüle edilebilir:

$$X(t,w) = \frac{1}{2\pi}\int_{-\infty}^{\infty} X(\varepsilon)W(w-\varepsilon)e^{j\varepsilon t}\,d\varepsilon \quad (3.2)$$

Sinyalin spektrogramı ise şu şekilde ifade edilir:

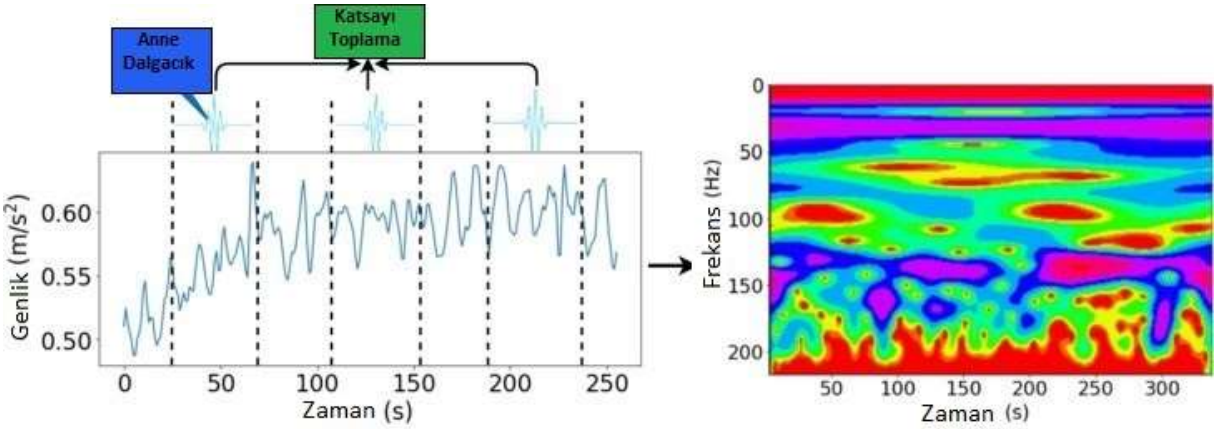
$$S_{SP}(t,w) = |X(t,w)|^2 \quad (3.3)$$

STFT'de zaman ve frekans arasında bir alışveriş söz konusudur. Sinyal analizi, hangi frekansların hangi zamanlarda değiştiği hakkında bilgi verir. Ancak, bu bilgi pencere uzunluğu ile sınırlıdır ve bir kez ayarlandığında tüm frekanslar için aynı kalır [59].

Tez çalışması kapsamında örnekleme frekansı 200 Hz olan EEG sinyalleri 5 sn'lik segment süreleri (1000 örnek) için analiz edilmiştir. Bu EEG segmentlerinin STFT gösterimlerinin elde edilebilmesi için Hamming pencere ve %50 örtüşme kullanılmıştır. Pencere boyutu olarak ise segment boyutunun %25'i (40 örnek) tercih edilmiştir. EEG sinyallerinden STFT kullanılarak 15 AH bireyi için 19 kanaldan 94.267 adet, 11 kontrol grubu bireyi için 19 kanaldan 62.835 adet görüntü elde edilmiştir.

3.2.2. Sürekli Dalgacık Dönüşümü (CWT)

Sürekli Dalgacık Dönüşümü (Continuous Wavelet Transform - CWT), STFT'deki pencere uzunluğu kısıtlamasını aşmak amacıyla önerilmiş bir yöntemdir. Dalgacık dönüşümü, sinyalin içerdiği tüm bilgilere ulaşmak için çözünürlüklerin zaman-frekans düzlemi boyunca değiştiği değişken bir pencere kullanır [59, 60]. Segmentlere ayrılmış veri seti CWT kullanılarak, zaman alanından zaman-frekans alanına dönüşür [61]. Şekil 3.2'de CWT'nin dönüşüm süreci gösterilmektedir.



Şekil 3.3: Zaman alanlı sinyalden zaman-frekans alanlı görüntüye dönüşüm süreci [61].

Sürekli dalgacık dönüşümünün (CWT) denklemi (3.4) aşağıda bulunmaktadır;

$$W(a,b) = \int_{-\infty}^{\infty} x(t)\bar{\varphi}_{a,b}(t)\,dt \tag{3.4}$$

$$\bar{\varphi}_{a,b}(t) = \frac{1}{\sqrt{(a)}}\,\bar{\varphi}\left(\frac{t-b}{a}\right) \tag{3.5}$$

(3.5) denkleminde bulunan φ (t) terimi, dalgacık teorisinde anne dalgacık olarak bilinen bir pencere prototipini temsil etmektedir. $\sqrt{(a)}$ faktörü, enerjinin herhangi bir ölçeğe normalizasyonunu sağlar. Bu analiz, belirli bir anne dalgacık için ölçek değişiklikleri ve t dönüşümleri aracılığıyla x(t) sinyalinin korelasyonunu belirler [59].

Sinyalin skalogramı denklem 3.6'da mevcut olan formülle ifade edildiği gibi CWT'nin mutlak değerinin karesi alınarak hesaplanabilir [62].

$$S_{sc}(a,b) = |W(a,b)|^2 \tag{3.6}$$

Bu tez kapsamında EEG sinyallerinden CWT Amor, CWT Bump ve CWT Morse dönüşümleri kullanılarak, her bir dalgacık dönüşümü için ayrı ayrı olmak üzere; 15 AH hastasından 19 kanaldan 94.267 adet, 11 kontrol grubu bireyinden 19 kanaldan 62.835 adet görüntü elde edilmiştir. AH ve kontrol grubu bireylerinin zaman-frekans yaklaşımlarıyla elde edilen spektrogram ve skalogram görüntüleri, çalışmamızda yer alan derin öğrenme mimarilerinde

input olarak kullanılmış ve AH/KG sınıflandırmasında en uygun yaklaşım belirlenmeye çalışılmıştır.

3.2.2.1. Sürekli Dalgacık Dönüşümü (CWT) Amor, Bump ve Morse

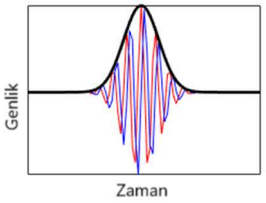
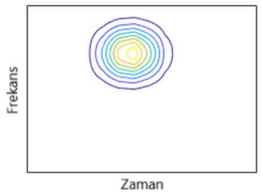
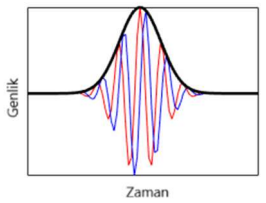
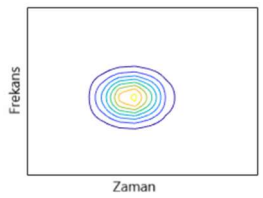
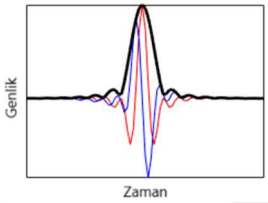
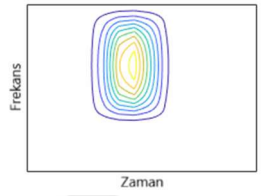
Zaman serilerindeki düşük ve yüksek frekanslardan oluşan bir dalgacık dönüşümü türü olan CWT, özellikle EEG sinyalleri gibi durağan olmayan (non-stationary) sinyallerin ön işleme aşamasında oldukça etkili bir tekniktir. CWT, zaman ve yüksek frekans çözünürlükleri vasıtasıyla zaman-frekans alanında ayrıntılı analiz sağlar [63]. Sürekli dalgacık dönüşümünde (CWT) temel dalgacık olarak kullanılan yapılara anne dalgacık (mother wavelet) denir. Bir sinyalin farklı frekans bileşenlerini incelemeyi amaçlayan dalgacık analizi sürecinde anne dalgacık önemli bir rol oynar. Anne dalgacık, belirli bir şekil ve boyutla tanımlanan bir dalgacık olup, sinyalin çeşitli ölçeklerde nasıl davrandığını anlamayı sağlayarak zaman ve frekans bilgilerini aynı anda temsil edebilir ve bu sayede sinyalin yerel özelliklerini belirlemede etkilidir. Anne dalgacık türleri şekil, uzunluk, frekans içeriği, senkronizasyon, zaman kaydırma ve ölçekleme gibi bazı temel özellikler ile birbirinden ayrılır. Çalışmamızda üç anne dalgacık çeşidi kullanılmıştır (Tablo 3.1). Bu dalgacıklar;

- **Morse Dalgacığı:** Geniş bir frekans aralığında yüksek çözünürlük sağlayarak zaman-frekans özelliklerini ayarlamak için esneklik sunar. Geniş bir parametre kümesi ile tanımlanabilen bu dalgacık, parametreler değiştirilerek istenen çözünürlüklerin elde edilmesine imkan tanır. Spektral analiz ve frekans çözünürlüğünün kritik olduğu durumlarda tercih edilmektedir.

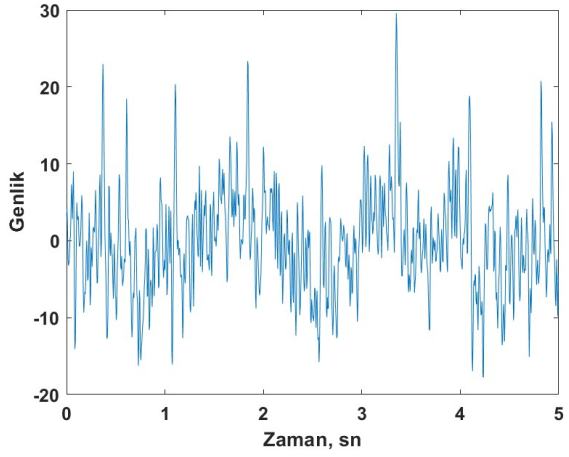
- **Amor (Morlet) Dalgacığı:** Zaman ve frekans çözünürlüğü arasında iyi bir denge sağlamakta olup, bu özelliği onu genel amaçlı analizler için uygun kılar. Zaman-frekans çözünürlüğü dengesinin önemli olduğu genel amaçlı analizlerde yaygın olarak kullanılmaktadır.

- **Bump Dalgacığı:** Zaman çözünürlüğü düşük, ancak frekans çözünürlüğü yüksektir. Bu nedenle, dar frekans bileşenlerinin incelenmesi için idealdir ve bu tür uygulamalarda tercih edilmektedir [59, 61].

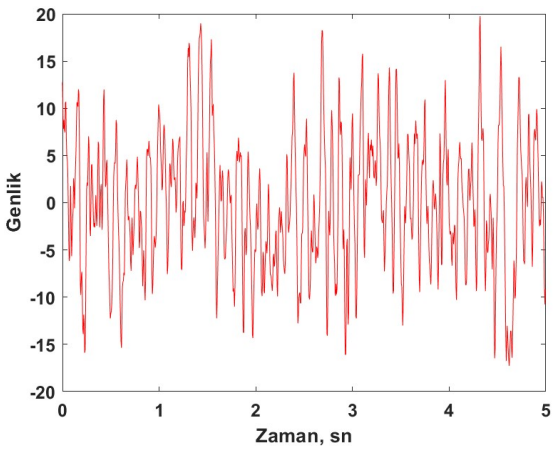
Tablo 3.1: Çalışma kapsamında kullanılan anne dalgacık (mother wavelet) türleri; CWT Morse, CWT Amor ve CWT Bump [64].

Dalgacık	Özellikler	İsim	Zaman Alanı	Zaman-Frekans Alanı
Genelleştirilmiş Morse Dalgacığı	Zaman ve frekans yayılımını değiştirmek için iki parametreyi değiştirebilir	"morse"		
Analitik Morlet (Gabor-Amor) Dalgacığı	Zaman ve frekansta eşit varyans	"amor"		
Bump Dalgacığı	Zamanda daha geniş varyans, frekansta daha dar varyans	"bump"		

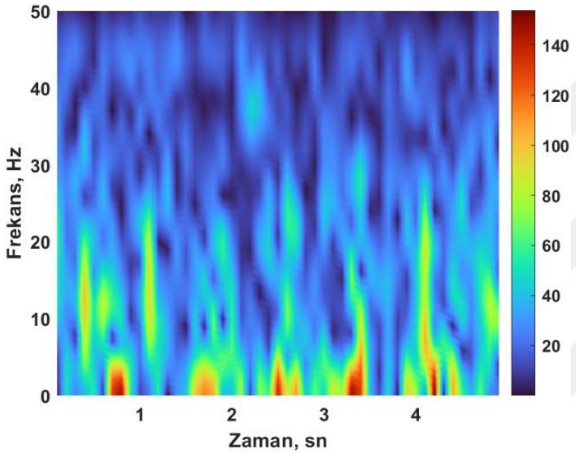
Tez çalışması kapsamında 200 Hz EEG sinyallerinden STFT, CWT Amor, Bump ve Morse zaman-frekans dönüşümleri ile görüntüler elde edilirken; Matlab R2023a programında, turbo renk barı (mavi, yeşil ve kırmızı tonlarının yoğunluklarını içeren) kullanılarak çizdirilen görüntüler, 682 x 540 piksel boyutunda, y ekseninde frekans değeri maksimum 50 Hz olacak şekilde ayarlanmış ve RGB görüntü olarak ".png" formatında kaydedilmiştir. Ardından derin öğrenme mimarilerinin girdi boyutu 224 x 224 piksel olduğu için elde edilen görüntüler, girişte boyutu değiştirilerek mimarilere verilmiştir. Çalışmada turbo renk barı kullanılarak EEG sinyallerinin spektrogram ve skalogram görüntülerinin oluşturulması sonucu bir EEG verisinin belirli frekans bileşenlerinin güç seviyelerinin yorumlanabilir hale getirilerek verinin daha anlaşılır olması amaçlanmıştır. Turbo renk barı, düşük güç değerlerini mavi ile, yüksek güç değerlerini kırmızı ile gösterir. Renkler, sinyalin enerji seviyelerini belirgin bir şekilde göstererek analizin etkinliğini artırır. Kontrol ve AH deneklerinin birer örnek EEG segmenti (sırası ile Şekil 3.4 (a) ve (b)) için STFT, CWT Amor, CWT Bump, ve CWT Morse yöntemleri ile elde edilmiş örnek zaman-frekans görüntüleri Şekil 3.4'te verilmiştir.


Genlik
Zaman, sn

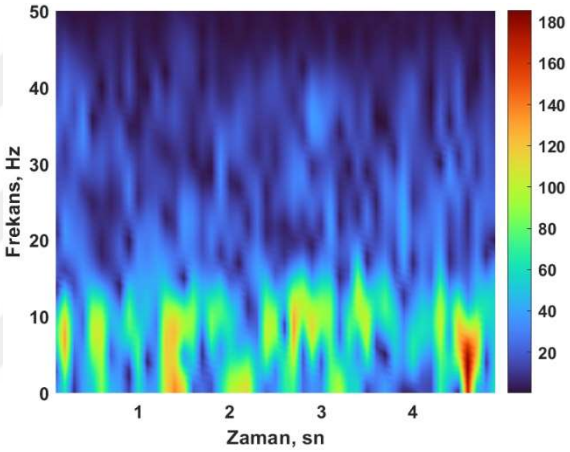
(a)


Genlik
Zaman, sn

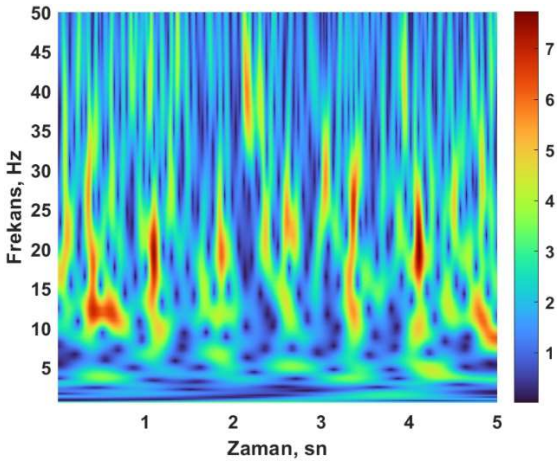
(b)


Frekans, Hz
Zaman, sn

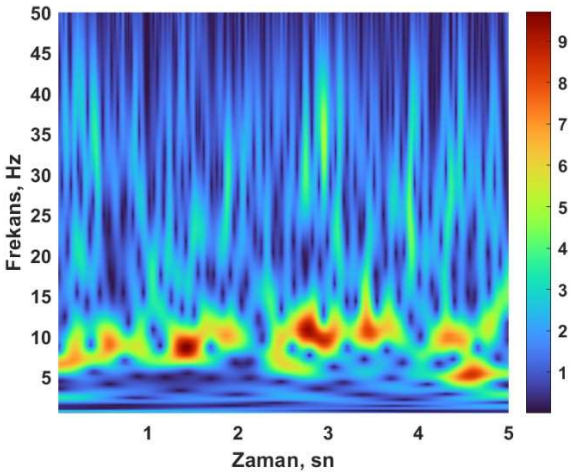
(c)


Frekans, Hz
Zaman, sn

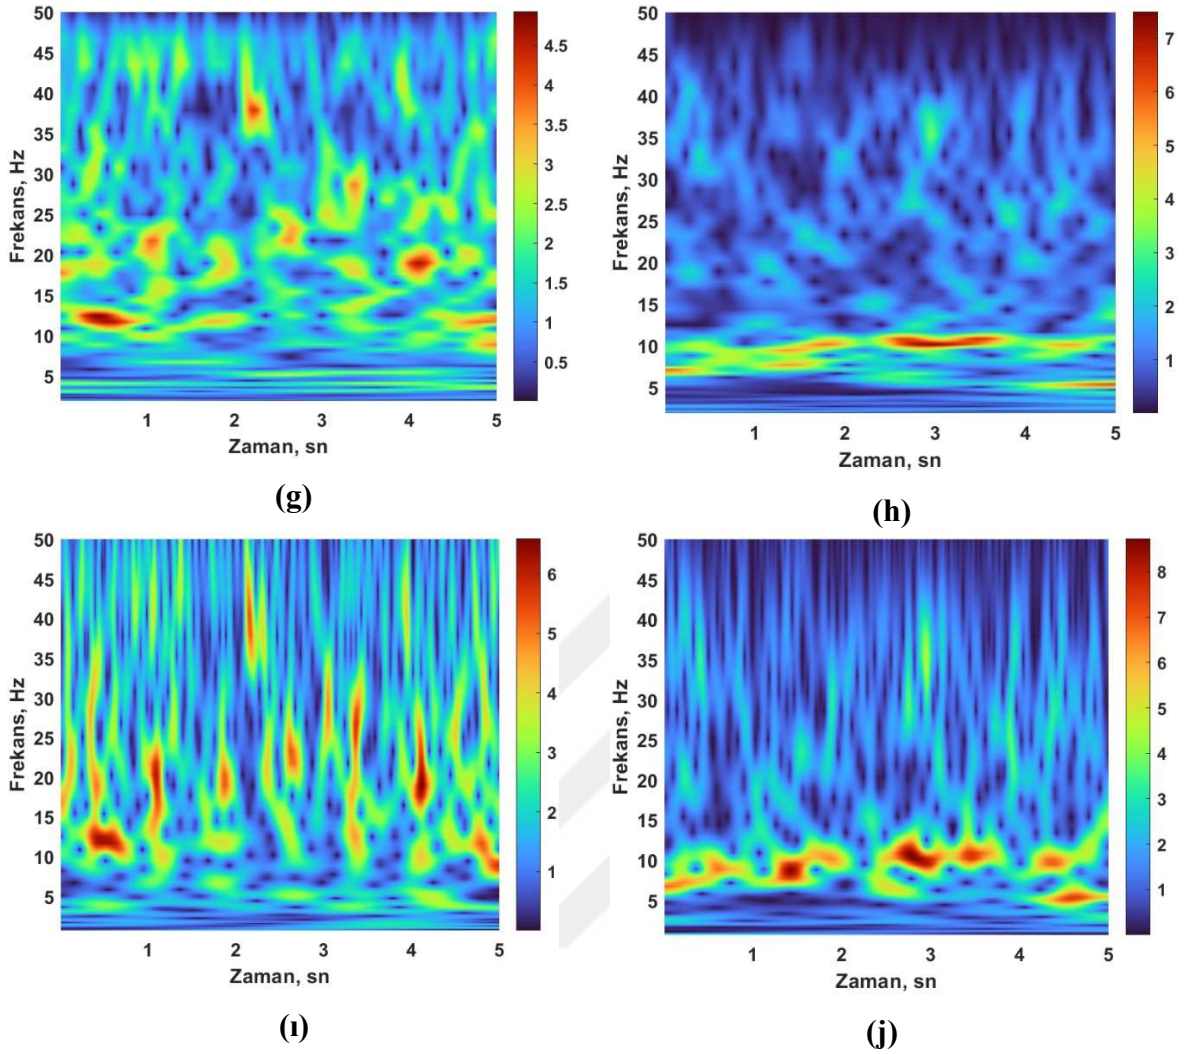
(d)


Frekans, Hz
Zaman, sn

(e)


Frekans, Hz
Zaman, sn

(f)



Şekil 3.4: (a) Kontrol deneğinin ve (b) Alzheimer hastasının 5 saniyelik elektroensefalogram segmenti ve ilgili zaman-frekans temsilleri; (c, d) Kısa Zamanlı Fourier Dönüşümü, (e, f) Sürekli Dalgacık Dönüşümü Amor, (g, h) Sürekli Dalgacık Dönüşümü Bump ve (ı, j) Sürekli Dalgacık Dönüşümü Morse.

3.3. GÖRÜNTÜLERİN CNN İLE EĞİTİLMESİ

Bu tez kapsamında, EEG sinyallerinden, Kısa Zamanlı Fourier Dönüşümü (STFT) ve Sürekli Dalgacık Dönüşümü (CWT) çeşitleri olan CWT Amor, CWT Bump ve CWT Morse zaman-frekans dönüşümleri kullanılarak elde edilen görüntüler, Resnet18, Modifiye ResNet18_1, Modifiye ResNet18_2, GoogleNet, AlexNet ve DarkNet Evrişimli Sinir Ağı (CNN) mimarileri ile eğitilerek Alzheimer Hastalığı'nın (AH) teşhisinde hangi yöntemin daha etkili olduğu belirlenmeye çalışılmıştır.

3.3.1. Derin Öğrenme (Deep Learning - DL)

Klasik makine öğrenimi algoritmaları, iyi bir performansa ulaşabilmek için genellikle karmaşık özellik mühendisliği gerektirir, bu da araştırmacıların orijinal EEG'yi (elektroensefalografi) araştırmak ve uygun özelliklerini seçmek için çok zaman harcaması gerektiği anlamına gelmektedir. Makine öğreniminin bir alt kümesi olarak derin öğrenme, özellik mühendisliğinin otomasyonunu hayata geçirmek için sinir ağları ve gizli katmanlar kullanır ve bu sayede araştırmacıların zaman ve enerjiden büyük ölçüde tasarruf etmelerini sağlar [50, 65].

Derin öğrenme ağları, makine öğrenmede kullanılan basit yapay sinir ağlarının çok katmanlı (üçten fazla), derin ve daha kompleks versiyonları olarak tanımlanabilir. Bu ağlar, giriş verilerinden ilgili özellikleri otomatik olarak çıkarırken kullanıcının özellikleri manuel olarak çıkarması ve seçmesi gerekmez. Derin mimari, sınıflandırma işlemini gerçekleştirirken, tek veya çok boyutlu giriş verileriyle eğitilmek üzere tasarlanmıştır [66].

Geleneksel sinir ağı algoritmalarının mimarisi giriş, çıkış ve gizlenmiş katmanları içerir. Derin öğrenme (DL), ise üçten fazla katmana sahip olan yeni bir sinir ağı yapısıdır ve sınıflandırma ve algılama çalışmalarında geleneksel tekniklere göre daha fazla tercih edilmektedir. Derin öğrenmede özellik çıkarma ve sınıflandırma bölümleri modelin içine gömülür ve giriş verilerinden otomatik olarak en uygun özelliklerin belirlenmesi sağlanır. Derin öğrenmenin, eğitim yöntemlerine göre tekrarlayan sinir ağları (RNN'ler), evrişimli sinir ağları (CNN'ler) ve Uzun Kısa Süreli Hafıza (LSTM) gibi farklı türleri bulunmaktadır [67, 68].

Derin öğrenme çok boyutlu verilerde karmaşık yapıları keşfetmede oldukça yüksek başarıya sahip olduğu için bilim, iş dünyası gibi birçok alanda kullanılabilir. Görüntü tanıma, konuşma tanıma, potansiyel ilaç moleküllerinin aktivitesini tahmin etme, parçacık hızlandırıcı verilerini analiz etme, beyin devrelerini yeniden yapılandırma gibi alanlarda diğer makine öğrenimi tekniklerini geride bırakmıştır. Derin sinir ağları için geliştirilen yeni öğrenme algoritmaları ve mimariler bu alandaki ilerlemeyi daha da hızlandırma potansiyeline sahiptir [69].

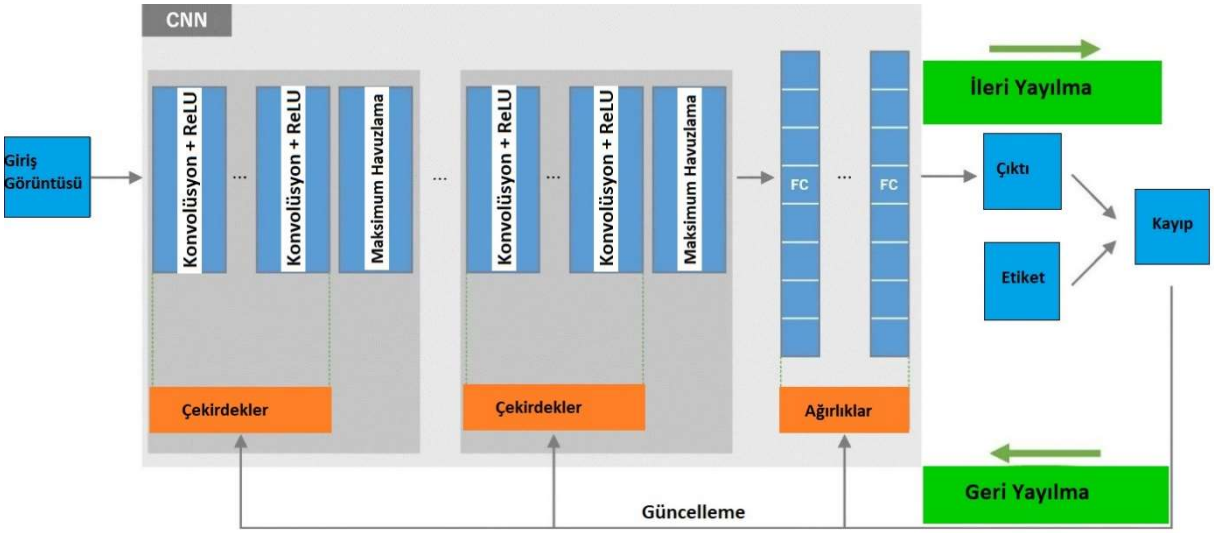
3.3.2. Evrişimli Sinir Ağları (Convolutional Neural Networks - CNN)

Derin öğrenme modelleri, düşük seviyeli özelliklerden yüksek seviyeli özellikler oluşturarak bir özellikler hiyerarşisi öğrenebilen bir tür hesaplama makineleri şeklinde ifade edilebilirler ve böylece özellik inşası sürecini otomatikleştirebilirler. Bu modellerden biri, iyi bilinen evrişimli sinir ağıdır (CNN). CNN, hem doğrusal hem de doğrusal olmayan öğrenilebilir operatörlerden

oluşan birkaç derin işlem katmanı içerir ve dolayısıyla otomatik olarak düşük seviyeli özelliklerden yüksek seviyeli bilgileri öğrenme ve oluşturma yeteneğine sahiptir [70, 71, 72].

Biyolojik görme süreçlerinden esinlenerek tasarlanan bir CNN, ileri beslemeli yapay sinir ağı uygular; burada çok katmanlı algılayıcıların çeşitli türlerini simüle eder ve bireysel nöronlar görsel alandaki örtüşen bölgelere cevap verecek şekilde düzenlenmiştir. Bu nedenle, bu ağlar görüntü ve video tanıma alanında yaygın şekilde uygulanmaktadır. Özellikle, CNN'ler görüntü içeriğini anlama, görüntü tanıma, segmentasyon, tespit ve geri getirme konularında son derece başarılı sonuçlar sunarak etkili bir model sınıfı olduğunu kanıtlamıştır. Başka bir deyişle, uygun düzenlemelerle eğitildiğinde, CNN'ler el yapımı herhangi bir özelliğe ihtiyaç duymadan görsel nesne tanıma görevlerinde üstün performans elde edebilirler [69, 72].

CNN, tipik olarak üç tür katmandan (yapı bloğu) oluşan matematiksel bir yapıdır (Şekil 3.5). Bu katmanlar; konvolüsyon katmanları, havuzlama katmanları (örneğin; maksimum havuzlama) ve tam bağlantılı (Fully Connected - FC) katmanlar olarak adlandırılır. İlk iki katman olan konvolüsyon ve havuzlama katmanları, özellik çıkarma işlemi yapar. Üçüncü katman olan tam bağlantılı katman ise, çıkartılan özellikleri sınıflandırma gibi son çıktılara haritalar. Şekil 3.5'te görüldüğü üzere; bir modelin belirli ağırlıklar (weights) ve çekirdekler (kernels) altında performansı, bir kayıp fonksiyonu kullanılarak eğitim veri setinde ileri yayılım yoluyla hesaplanır ve öğrenilebilir parametreler, yani ağırlıklar (weights) ve çekirdekler (kernels), geriye yayılım ve gradyan inişi optimizasyon algoritması ile kayıp değerine göre güncellenir. CNN mimarilerinde kernel (çekirdek), görüntü işleme ve sinir ağı katmanlarında kullanılan küçük boyutlu bir filtre matrisidir. Kernel, konvolüsyon işlemiyle görüntü üzerinde kayan bir pencere gibi hareket ederek görüntünün belirli özelliklerini (köşeler, kenarlar vb.) çıkarır. Ağırlıklar ise görüntü üzerinde konvolüsyon işlemi sırasında kullanılan kernel matrislerinin değerleridir. ReLU aktivasyon fonksiyonu, doğrusal düzeltilmiş birim (Rectified Linear Unit) anlamına gelmekte olup giriş değeri sıfırdan büyük (pozitif) olduğunda giriş değerini olduğu gibi bırakır; sıfırdan küçük (negatif) olduğu durumlarda ise fonksiyon çıktısını sıfıra eşitler [73].



Şekil 3.5: Konvolüsyonel sinir ağı (CNN) mimarisini ve eğitim sürecini genel bir gözden geçirme [73].

3.3.3. CNN Katman Türleri

Genel olarak, bir CNN, konvolüsyon katmanlarının havuzlama katmanlarıyla sıralandığı ve ardından bazı tam bağlantılı katmanların geldiği hiyerarşik bir sinir ağıdır [74]. Bu bölümde söz konusu 3 katman hakkında bilgi verilecektir.

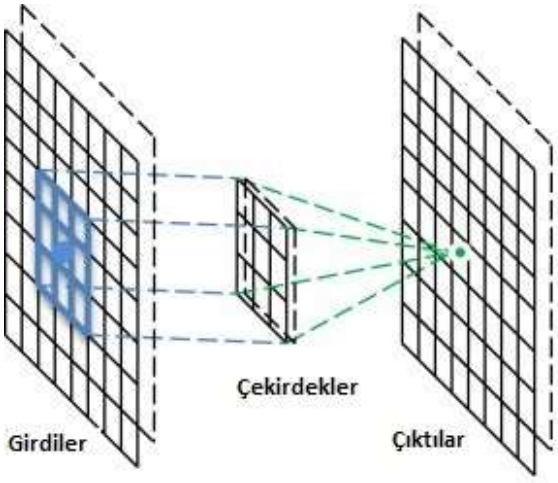
3.3.3.1. Konvolüsyon Katmanları (Evrişimsel Katmanlar - Convolutional Layers)

Konvolüsyon katmanlarında, bir CNN tüm görüntüyü ve aynı zamanda ara özellik haritalarını çeşitli çekirdekler kullanarak konvolüsyon yapar ve Şekil 3.6'da gösterildiği gibi çeşitli özellik haritaları oluşturur. Konvolüsyon işleminin üç temel avantajı vardır [74] :

1) Aynı özellik haritasında bulunan ağırlık paylaşımı mekanizması parametre sayısını azaltır.

2) Yerel bağlantı, komşu pikseller arasındaki korelasyonları öğrenir.

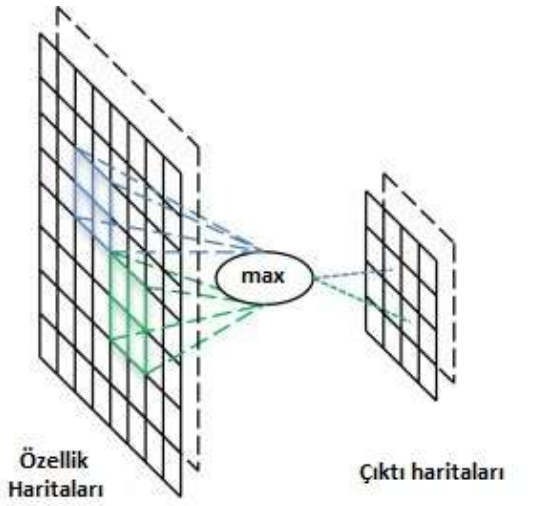
3) Nesnenin konumuna göre değişmezlik sağlar.



Şekil 3.6: Konvolüsyon katmanının işleyişi [74].

3.3.3.2. Havuzlama Katmanları (Pooling Layers)

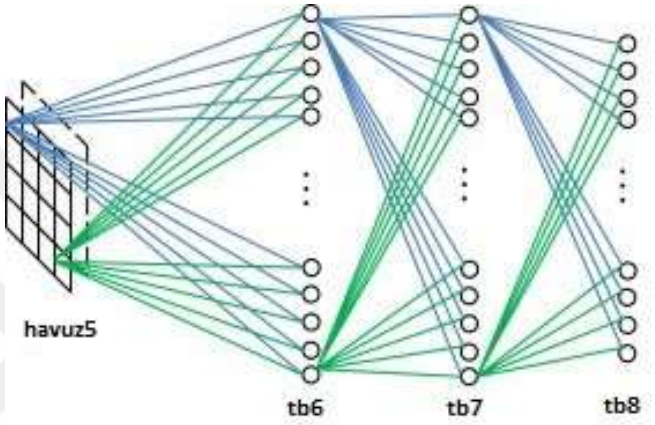
Genel olarak, bir havuzlama katmanı bir konvolüsyon katmanını takip eder ve ağ parametrelerinin ve özellik haritalarının boyutlarını azaltmak için kullanılabilir. Konvolüsyon katmanlarına benzer şekilde, havuzlama katmanları da translasyon invarianttır yani konumu değişse bile aynı sonucu üretir, çünkü hesaplamaları komşu pikselleri dikkate alır. Ortalama havuzlama ve maksimum havuzlama en yaygın kullanılan türleridir. Şekil 3.7'de, bir maksimum havuzlama işlemi için örnek verilmiştir. 8x8 özellik haritaları için çıktı haritaları, 2x2 boyutunda ve 2 birimlik adımlama aralığına sahip bir maksimum havuzlama operatörü ile 4x4'e düşer [74].



Şekil 3.7: Maksimum havuzlama katmanının çalışması [74].

3.3.3.3. Tam Bağlantılı Katmanlar (Fully Connected Layers)

CNN mimarisinde bulunan sinir ağındaki son havuzlama katmanını takip eden tam bağlantılı katmanlar, daha fazla özellik gösterimi için 2 boyutlu özellik haritalarını 1 boyutlu özellik vektörüne dönüştürür (Şekil 3.8). Bir CNN'in parametrelerinin yaklaşık %90'ını içeren tam bağlantılı katmanlar, geleneksel bir sinir ağı gibi çalışır. Sinir ağının önceden tanımlı uzunluğa sahip bir vektöre iletilmesini sağlar. Söz konusu vektör takip işlemleri için bir özellik vektörü olarak kullanılabileceği gibi görüntü sınıflandırması için belirli sayıda kategorilere de iletilebilir [74, 75].



Şekil 3.8: Tam bağlı katmanın çalışması [74].

3.3.4. Çalışmada Kullanılan CNN Çeşitleri

Bu çalışmada, Alzheimer hastalığının (AH) teşhisinde en doğru yöntemin belirlenebilmesi amacıyla EEG sinyallerinden, zaman-frekans dönüşümleri kullanılarak elde edilen görüntüler, ResNet18, Modifiye ResNet18_1, Modifiye ResNet18_2, GoogleNet, AlexNet ve DarkNet Evrişimli Sinir Ağı (CNN) mimarileri ile eğitilmiş ve sonuçlar bulgular bölümünde detaylıca paylaşılmıştır. Bu bölümde çalışmada kullanılan CNN mimarilerinin yapıları ile ilgili bilgiler verilmekte ve her bir mimarinin özellikleri, katmanları ve performansları detaylı bir şekilde açıklanmaktadır.

3.3.4.1. ResNet18 Mimarisi ve Modifikasyonları

2015 yılında önerilen bir derin öğrenme mimarisi olan ResNet, basitliği ve pratik olması sebebiyle ImageNet sınıflandırma yarışmasında birincilik kazanmıştır. Ardından segmentasyon, tespit, tanıma ve diğer alanlarda yaygın şekilde kullanılan birçok metot,

Resnet50 ve Resnet101 mimarileri temel alınarak geliştirilmiştir. ResNet, kısayol bağlantısı (shortcut connection) olarak adlandırılan bir bağlantı yöntemi kullanır. Her katmanın girdi değeri için bir referans (X) alır ve bazı fonksiyonları referans (X) olmadan öğrenmek yerine bir artık fonksiyon (residual function) oluşturmayı öğrenir. Oluşan artık fonksiyonun optimize edilmesi daha kolaydır ve ağın katman sayısını büyük ölçüde arttırabilir. Denklem 1'de gösterildiği gibi, artık blokta iki katman bulunur; burada σ, doğrusal olmayan ReLu fonksiyonunu belirtmektedir [76].

$$F(x) = W_{2\sigma}(W_1 x) \tag{3.7}$$

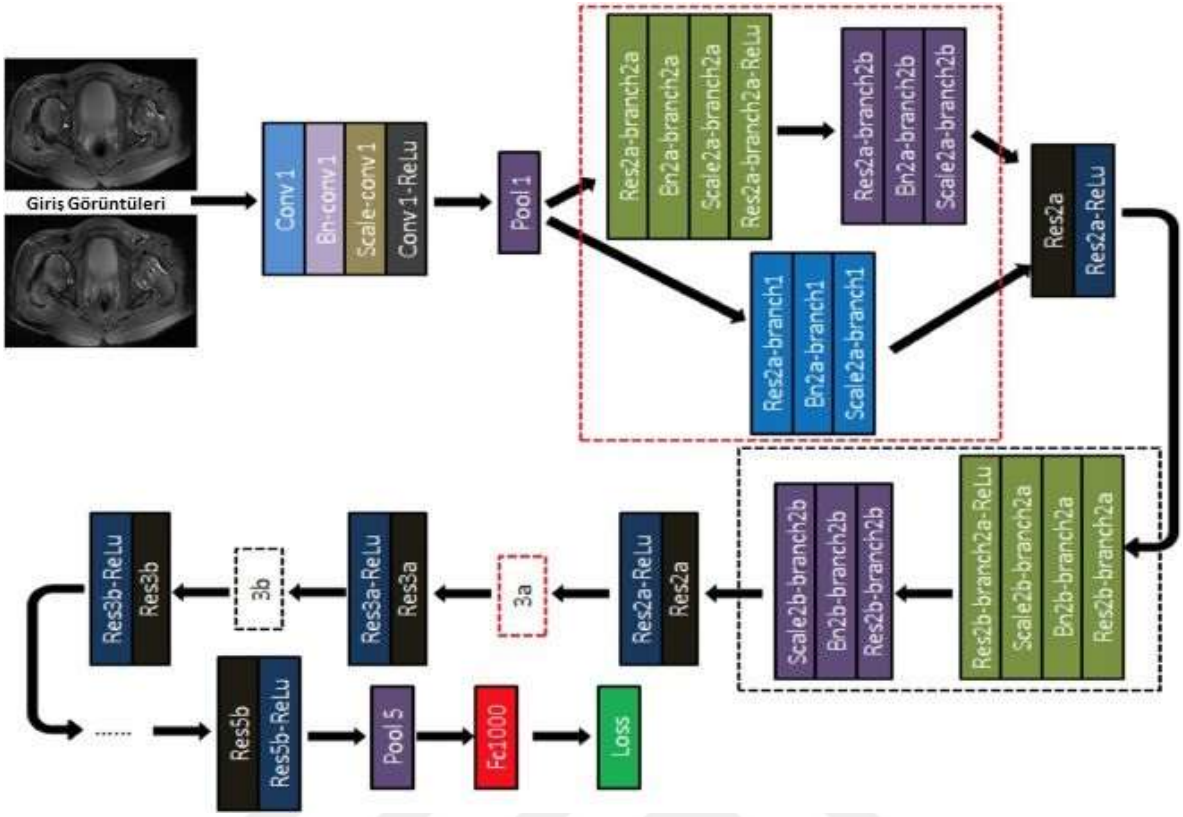
Daha sonra bir kısayol ve ikinci ReLU ile Denklem 2'de gösterilen y çıktısı elde edilir [76].

$$y = f(x, \{W_i\}) + x \tag{3.8}$$

Giriş ve çıkış boyutlarının değiştirilmesi gerektiğinde, Denklem 3'te gösterildiği gibi kısayol sırasında x üzerinde doğrusal bir Ws dönüşümü yapılabilir [76].

$$y = F(x, \{W_i\}) + W_s x \tag{3.9}$$

ResNet18, 17 konvolüsyon katmanı ve 1 tam bağlantılı katman olmak üzere toplam 18 katmandan oluşur. Şekil 3.9'da ResNet18'in ağ yapısı gösterilmiştir [76].



Şekil 3.9: ResNet18'in ağ yapısı [76].

Standart ResNet18 mimarisinin problemimize uygun ikili sınıflandırma sonucunu üretecek mimari katmanları ve ilgili katmanlarının çıkış boyutları Tablo 3.2'de verilmiştir.

Tablo 3.2: ResNet18 mimarisi katmanları

Katman Adı	Çıkış Boyutu	ResNet-18
Conv1	$112x112x64$	$7x7, 64, stride\ 2$
Conv2_x	$56x56x64$	$3x3$ max $pool$, $stride\ 2$ $\begin{Bmatrix} 3x3, 64 \\ 3x3, 64 \end{Bmatrix}$x2
Conv3_x	$28x28x128$	$\begin{Bmatrix} 3x3, 128 \\ 3x3, 128 \end{Bmatrix}$x2
Conv4_x	$14x14x256$	$\begin{Bmatrix} 3x3, 256 \\ 3x3, 256 \end{Bmatrix}$x2
Conv5_x	$7x7x512$	$\begin{Bmatrix} 3x3,512 \\ 3x3, 512 \end{Bmatrix}$x2
Ortalama havuzlama	$1x1x512$	$7x7\ ortalama\ havuz$
Tam bağlantılı katman	2	
Softmax	2	

Orijinal ResNet18 mimarisi birçok çalışmada başarılı sonuçlarla yaygın olarak kullanılmıştır. Ancak, mimarinin daha az eğitim seti ile ikili sınıflandırma problemleri için daha da optimize edilebileceği düşünülmektedir. Bu nedenle, tez kapsamında, iyi bilinen bir CNN mimarisi olan ResNet18 modelinden esinlenerek yeni iki CNN modeli tasarlanmıştır. İlk olarak önerilen ***"Modifiye ResNet18_1"*** modelidir. Bu modelde orijinal model ile aynı sayıda (17 adet) evrişim katmanı (Tablo 3.3, conv1, conv2_x, conv3_x, conv4_x, conv5_x) bulunmaktadır. Ancak her

bir evrişim katmanının filtre sayısı orjinal modele göre düşürülerek sırasıyla 16, 16, 32, 64 ve 128 olacak şekilde ayarlanmıştır. Tablo 3.3'te önerilen Modifiye ResNet18_1 mimarisinin katmanları ve ilgili katmanların çıkış boyutları detaylı olarak verilmiştir.

Tablo 3.3: Modifiye ResNet18_1 mimarisi katmanları

Katman Adı	**Çıkış Boyutu**	**Modifiye ResNet18_1**
Conv1	$112x112x16$	$7x7, 16, stride\ 2$
Conv2_x	$56x56x16$	$3x3\ \max pool\ , stride\ 2$ $\begin{Bmatrix} 3x3, 16 \\ 3x3, 16 \end{Bmatrix}$x2
Conv3_x	$28x28x32$	$\begin{Bmatrix} 3x3, 32 \\ 3x3, 32 \end{Bmatrix}$x2
Conv4_x	$14x14x64$	$\begin{Bmatrix} 3x3, 64 \\ 3x3, 64 \end{Bmatrix}$x2
Conv5_x	$7x7x128$	$\begin{Bmatrix} 3x3,128 \\ 3x3, 128 \end{Bmatrix}$x2
Ortalama havuzlama	$1x1x128$	$7x7\ ortalama\ havuz$
Tam bağlantılı katman	2	
Softmax	2	

İkinci olarak önerilen ***" Modifiye ResNet18_2"*** modelidir ve orjinal modelde 17 adet evrişim katmanı bulunurken (Tablo 3.2, conv1, conv2_x, …) bu modelde sadece 9 evrişim katmanı (Tablo 3.4, conv1, conv2_x, conv3_x) bulunmaktadır. Ayrıca her bir evrişim katmanının filtre sayısı orjinal modele göre düşürülerek sırasıyla 16, 16, ve 32 olacak şekilde ayarlanmıştır. Tablo 3.4'te önerilen Modifiye ResNet18_2 mimarisinin katmanları ve ilgili katmanların çıkış boyutları detaylı olarak verilmiştir. Önerilen bu iki mimarinin de, ResNet-18'den daha az filtre içermesi sebebi ile eğitim maliyetini düşürmesi ve ResNet-18 ile karşılaştırıldığında ikili sınıflandırma probleminin doğruluğunu artırması amaçlanmaktadır.

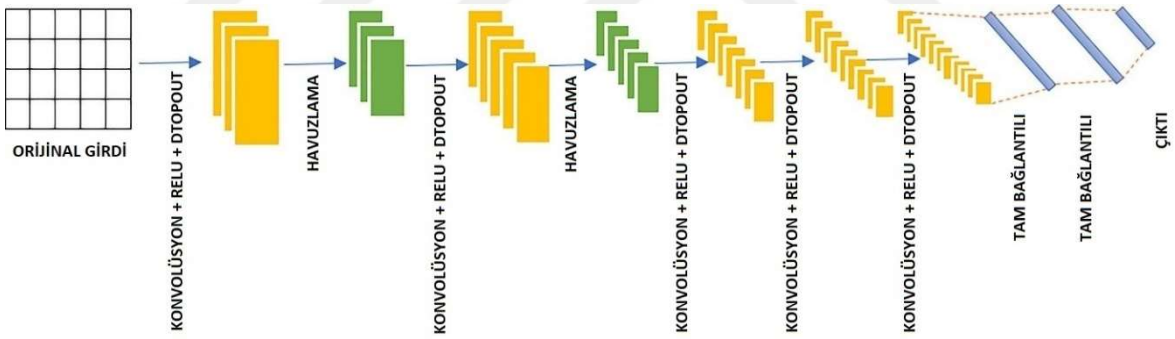
Tablo 3.4: Modifiye ResNet18_2 mimarisi katmanları

Katman Adı	**Çıkış Boyutu**	**Modifiye ResNet18_2**
Conv1	$112x112x16$	$7x7, 16, stride\ 2$
Conv2_x	$56x56x16$	$3x3 \max pool\ , stride\ 2$ $\begin{Bmatrix} 3x3, 16 \\ 3x3, 16 \end{Bmatrix}$x2
Conv3_x	$28x28x32$	$\begin{Bmatrix} 3x3, 32 \\ 3x3, 32 \end{Bmatrix}$x2
Ortalama havuzlama	$1x1x32$	$28x28\ ortalama\ havuz$
Tam bağlantılı katman	2	
Softmax	2	

3.3.4.2. AlexNet Mimarisi

AlexNet mimarisi, son zamanlarda geleneksel biyomedikal problemleri çözmek için önerilen popüler derin öğrenme algoritmalarından biridir. AlexNet, maksimum havuzlama katmanlarına sahip beş adet evrişim katmanı ve üç adet tamamen bağlı katman içerir. AlexNet mimarisinin diğer derin öğrenme modellerine göre avantajları, daha az belleğe ve zamana ihtiyaç duymasıdır [77]. Görüntü sınıflandırma performansı oldukça üstün olan AlexNet, 60 milyon parametre ve 650.000 nöron ile büyük bir ağ yapısına sahiptir [78].

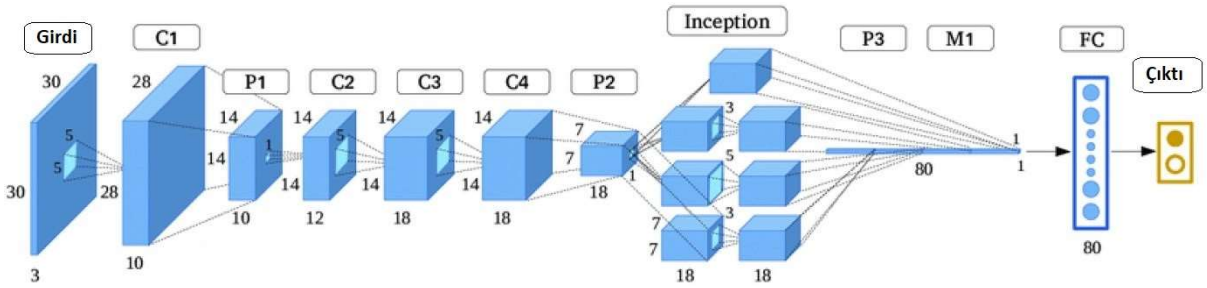
AlexNet CNN modelinin beş evrişimli katmanı, giriş görüntüsünün derin bilgisini çıkarmak için kullanılır. Evrişim katmanındaki filtrelerin sayısı ve boyutu değişiklik gösterir. Derin özelliklerin incelenmesi için filtre, tensör veya görüntü olarak hareket ettirilir. Sonraki girdi, çıkarılan derin özellikleri alır ve burada derin özelliklerin çıkarılmasına devam eder. İki boyutlu özellik matrisini tek boyuta indirgeyen tamamen bağlantılı üç katman, CNN modelinin son katmanını oluşturur. Mimari sonlandırılırken, olasılıksal bir yaklaşıma dayalı olarak sınıf ataması yapan Softmax katmanı kullanılır [79, 80]. Şekil 3.10'da 5 konvolüsyonel katman ve 3 tam bağlantılı katmandan oluşan AlexNet mimarisi gösterilmektedir [81].



Şekil 3.10: 5 konvolüsyonel katman ve 3 tam bağlantılı katmandan oluşan AlexNet mimarisi [81].

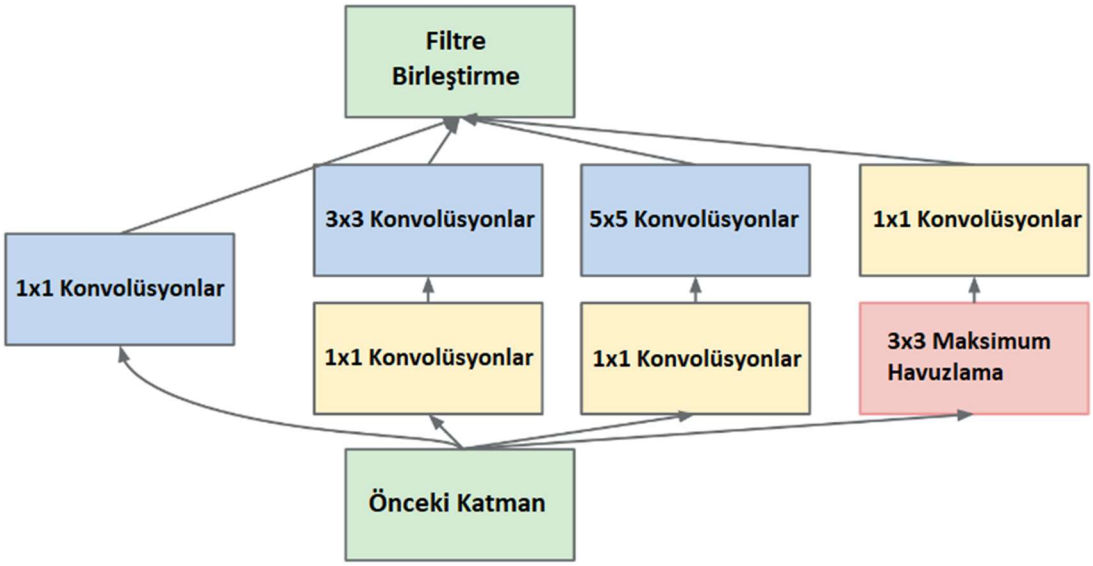
3.3.4.3. GoogleNet Mimarisi (Inception V1)

GoogleNet mimarisi 2014 yılında Google Research tarafından önerilen bir derin öğrenme mimarisidir. Bu mimari, global ortalama havuzlama gibi yöntemleri kullanır. Mimarinin tamamında 22 katman bulunmaktadır (Şekil 3.8). Hesaplama ekonomisi göz önünde bulundurularak tasarlandığı için işlem kapasitesi sınırlı olan bireysel cihazlarda bile kullanılabilir [82, 83].



Şekil 3.11: GoogleNet mimarisi [83].

GoogleNet sadece ardışık konvolüsyon ve havuzlama katmanlarından oluşmaz, aynı zamanda bir nevi ağ içinde ağ anlamına gelen inception mimarisi isimli bir yaklaşım kullanır (Şekil1). Inception modülü ağ içerisindeki bağlantıları atlayarak temel olarak bir mini modül oluşturur ve bu modül ağ boyunca tekrarlanır. GoogleNet, yaklaşık 7 milyon parametre kullanır. Inception modülü, ağda bulunan parametre sayısını önemli bir ölçüde azaltmıştır [84].



Şekil 3.12: Inception modülü [84].

3.3.4.4. DarkNet Mimarisi

Darknet-19, 19 konvolüsyon katmanı, 5 maxpooling katmanı, küresel ortalama havuzlama katmanı ve softmax katmanından oluşan bir konvolüsyonel derin öğrenme mimarisidir [85]. Mimaride genellikle 3 × 3 filtreler kullanılır ve her havuzlama adımından sonra kanal sayısı iki katına çıkar. Network in network (ağ içinde ağ) prensibiyle çalışır. Eğitimi stabilize etmek,

yakınsama hızını artırmak ve modeli düzenli hale getirmek için batch normalization (toplu normalizasyon) işlemi yapar [86]. Mimari, küresel ortalama havuzlama (global average pooling) ve 19 katmanlı 1 × 1 filtreleri kullanır [87].

3.3.5. Çalışmada Kullanılan Performans Metrikleri

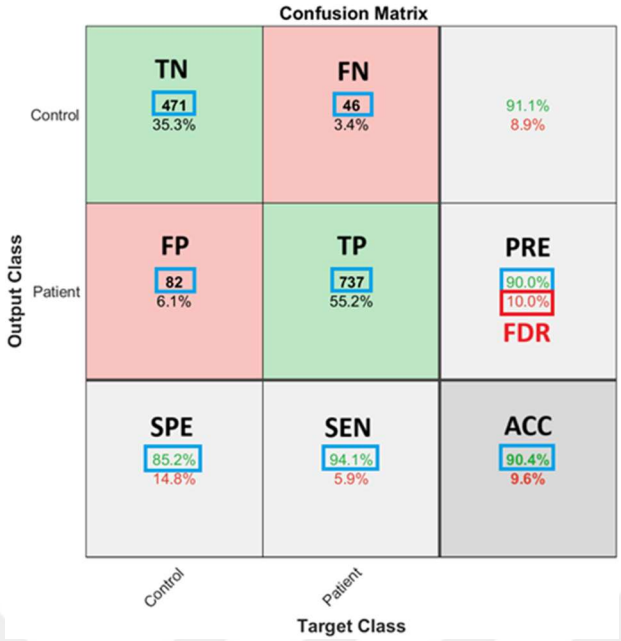
Bu çalışmada, EEG segmentlerinin zaman-frekans temsilleri elde edildikten sonra derin özellik çıkarımı yapılmaktadır. Zaman-frekans temsilleri, Kısa Zaman Fourier Dönüşümü (STFT) ve Sürekli Dalgacık Dönüşümü (CWT) yöntemleriyle elde edilmiştir. Bu temsiller daha sonra altı farklı Convolutional Neural Network (CNN) modeli kullanılarak analiz edilir: ResNet18, Modifiye ResNet18_1, Modifiye ResNet18_2, AlexNet, GoogleNet ve DarkNet. Çalışmada kullanılan derin öğrenme modellerinin görüntüleri doğru bir şekilde sınıflandırma yeteneğini detaylı şekilde değerlendirmek için bazı önemli performans metrikleri kullanılmıştır. İkili sınıflandırmada, sınıflandırıcıların AH/KG sınıflandırma sonuçları doğru pozitif (TP), yanlış pozitif (FP), yanlış negatif (FN) ve doğru negatif (TN) durumlarını içermektedir. Sonuçlar içerisinde performans değerlendirmesi için Denklem 3.10'da doğruluk (ACC-Accuracy), kesinlik (PRE-Precision), duyarlılık (SEN-Sensitivity), özgüllük (SPE-Specificity), yanlış keşif oranı (FDR- False Discovery Rate) ve kesinlik ile duyarlılığın harmonik ortalaması olan F1-Skoru'na (F1-S) yer verilmiştir [29].

$$
\begin{aligned}
ACC &= \frac{TP + TN}{TP + FN + FP + TN} * 100\% \\
SEN &= \frac{TP}{TP + FN} * 100\% \\
SPE &= \frac{TN}{TN + FP} * 100\% \\
PRE &= \frac{TP}{TP + FP} * 100\% \\
FDR &= \frac{FP}{TP + FP} * 100\% \\
F1 - S &= 2 * \frac{PRE * SEN}{PRE + SEN}
\end{aligned}
\tag{3.10}
$$

Formüllerde kullanılan terimlerin tanımları şu şekildedir;

- **TP (Doğru Pozitifler):** Doğru bir şekilde tahmin edilen pozitif vaka sayısı.
- **TN (Doğru Negatifler):** Doğru bir şekilde tahmin edilen negatif vaka sayısı.
- **FP (Yanlış Pozitifler):** Yanlış bir şekilde tahmin edilen pozitif vaka sayısı.
- **FN (Yanlış Negatifler):** Yanlış bir şekilde tahmin edilen negatif vaka sayısı.
- **Doğruluk (Accuracy):** Doğruluk metriği, doğru tahminlerin değerlendirilen toplam örnek sayısına oranını ölçer.
- **Duyarlılık (Sensitivity):** Duyarlılık metriği, doğru bir şekilde sınıflandırılan pozitif örneklerin oranını ölçmek için kullanılır.
- **Özgüllük (Specificity):** Özgüllük metriği, doğru bir şekilde sınıflandırılan negatif örneklerin oranını ölçmek için kullanılır.
- **Kesinlik (Precision):** Kesinlik metriği, pozitif sınıfta toplam tahmin edilen örneklerden doğru bir şekilde tahmin edilen pozitif örneklerin oranını ölçmek için kullanılır [88].

TP'yi, sınıflandırma algoritması tarafından AH sınıfında doğru şekilde tespit edilen AH EEG segmentlerinin sayısı belirtirken; TN'yi, KG sınıfında doğru şekilde tespit edilen KG EEG segmentlerinin sayısı belirtir. Bununla birlikte FP'yi, sınıflandırma algoritması tarafından AH sınıfında yanlış şekilde tespit edilen KG EEG segmentlerinin sayısı belirtirken; FN'yi sınıflandırma algoritması tarafından KG sınıfında yanlış şekilde tespit edilen AH EEG segmentlerinin sayısı belirtir [29].



Şekil 3.13: Performans metriklerinin karmaşıklık matrisi örneği üzerinde gösterimi.

3.3.6. Çalışmada Kullanılan Hiper-parametreler

Çalışmada kullanılan derin öğrenme mimarilerinin eğitilmesinde ve geliştirilmesinde performansı en verimli hale getirmek (optimize etmek) ve en iyi konfigürasyonu belirlemek amacıyla birkaç hiper-parametre dikkatli bir şekilde ayarlanmıştır [89]. Yüksek doğruluk oranına ulaşmak için aşağıda bulunan hiper-parametreler ayarlanıp test edilmiştir;

- **Adam Optimizasyon Algoritması (Adam Solver)**: Çalışmada verimli hesaplamalar yapma yeteneği ve büyük veri setleri ile parametreler için uygunluğu ile bilinen Adam algoritması kullanılmıştır.

- **Mini-Batch Boyutu:** Mini-batch boyutu, modelin iç parametreleri güncellenmeden önce işlenen örneklerin sayısını belirler. Çalışmada kullanılan mimari modellerinde, eğitim verimliliği ve modelin performansını dengeleyen en uygun değeri bulmak için farklı mini batch boyutları denenerek tüm mimariler için mini batch boyutu 64 olarak belirlenmiştir.

- **Maksimum Devir Sayısı (Epoch):** Bir devir (epoch), modelin eğitim süreci boyunca veri kümesinin tamamının bir kez işlenip analiz edilmesini ifade eder. Maksimum devir sayısı, modelin aşırı öğrenme (overfitting) yaşamadan eğitim verilerinden etkili bir

şekilde öğrenim yapabilmesi için yeterli süreyi sağlayacak şekilde her mimari için ayarlanarak değiştirilmiştir. Çalışmamızda kullanılan mimariler için devir sayısı; ResNet18 ve AlexNet mimarileri için; 20 olarak ve Modifiye ResNet 18_1, Modifiye ResNet 18_2, GoogleNet ve DarkNet mimarileri için 10 olarak belirlenmiştir. Devir sayısı belirlenirken; 10 olarak seçilen mimariler için; önce 20 devir ile sonra 10 devir ile deneme çalışmaları yapılmıştır ancak eğitim ve validasyon doğruluğu (accuracy) değerleri arasında iki deneme için çok değişkenlik olmadığı fark edilerek zaman kaybı olmaması adına diğer mimarilerde maksimum devir sayısı 10 olarak seçilmiştir.

- **Öğrenme Hızı** (**Learning Rate)**: Gradyan inişi sırasındaki adım boyutu öğrenme hızı (learning rate) olarak adlandırılan kritik bir hiper-parametre tarafından kontrol edilir. Modelin iyi bir şekilde optimizasyonunu sağlarken dalgalanma ve sapma olmadan uygun bir öğrenme hızı bulmak, birçok değer üzerinde test yapmayı gerektirir. Tez çalışmasında tüm mimariler için; ilk öğrenme hızı (initial learning rate) "4*1e-4" olarak, öğrenme hızı planı (learning rate schedule) parça parça (piecewise) şeklinde, öğrenme hızı düşüş faktörü (learn rate drop factor) "0,5" olarak ve öğrenme hızı düşüş periyodu (learn rate drop period) "2" olarak belirlenmiştir.

- **Karıştırma (Shuffle):** Shuffle terimi genellikle veri kümesinin veya katmanların sırasının rastgele değiştirilmesi anlamında kullanılır. Shuffle, modelin daha iyi genelleme yapabilmesi ve aşırı öğrenmeyi (overfitting) önlemesi konusunda önemlidir. Shuffle içeren bir mimaride eğitim başlamadan ve veri seti parçalara ayrılmadan önce veri seti karıştırılır. Çalışmada yer alan mimarilerin tümünde shuffle kullanılmıştır.

- **Doğrulama Verisi (Validation Data):** Doğrulama verisi, modelin eğitim süreci sırasında, modelin genel performansını değerlendirmek için kullanılan veri kümesidir. Tez çalışmasın kapsamında tüm mimarilerde "validation data, augimdsValidation" şeklinde yer alan bölüm, veri artırma (data augmentation) işlemleri uygulanan doğrulama veri kümesini ifade eder. "augimdsValidation" ifadesi, bir "augmented image datastores" (veri artırma görüntü deposu) nesnesini temsil eder. Yani, doğrulama veri kümesine uygulanan veri artırma teknikleri ile oluşturulmuş bir veri setidir.

- **Doğrulama Frekansı (Validation Frequency):** Doğrulama frekansı, modelin doğrulama verisi üzerinde ne sıklıkla test edileceğini belirler. Tez çalışması kapsamındaki doğrulama frekansı her mimari için 5 olarak belirlenmiş olup her 5

iterasyonda bir validasyon yapılarak doğrulama veri kümesi üzerinde modelin performansının değerlendirilmesi sağlanmıştır.

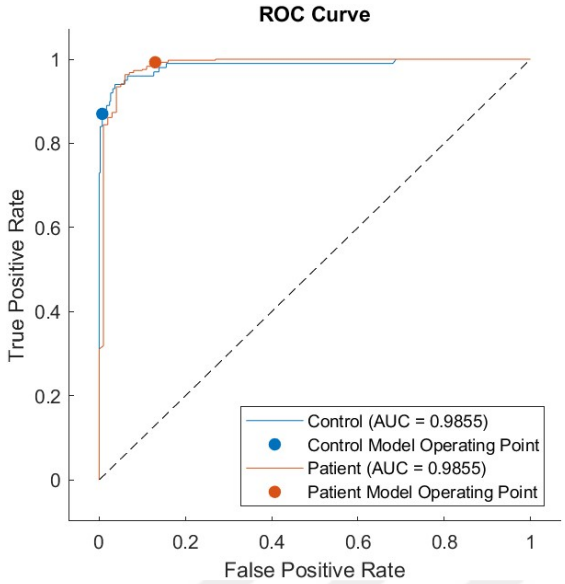
- **L2 Düzenlemesi (L2 Regularization):** Bu teknik, büyük ağırlıkları sınırlayarak (cezalandırarak) modelin daha basit ve daha genelleştirilebilir çözümler üretmesini destekler ve böylece aşırı uyumu önlemeye çalışır. Çalışmada aşırı uyumu (overfitting) önlemek amacıyla modellerin ağırlıklarına 1.0000e-5 değeriyle L2 düzenlemesi uygulanmıştır.

- **Verbose (Ayrıntı):** Verbose (ayrıntı) hiperparametresi, eğitim süreci sırasında ne derece ayrıntılı bilgi gösterileceğini belirleyen bir ayardır. Çalışmada yer alan tüm mimariler için verbose hiper-parametresi "false" şeklinde ayarlanarak eğitim süreçleri sırasında hiçbir bilgi veya çıktı gösterilmeyerek ayrıntı verilmemiştir.

- **Plots:** Plots hiper-parametresi, modelin performansını değerlendirme aşamasında eğitim süreciyle ilgili çeşitli metriklerin görselleştirilmesini sağlayan önemli bir araçtır. Tez kapsamında bulunan tüm CNN çalışmalarında plots parametresi "training progress" şeklinde ayarlanarak çalışma bitiminde "training progress" grafiğinin görselleştirilmesini sağlamıştır.

3.3.7. ROC Eğrisi (Receiver Operating Characteristic Curve)

Receiver Operating Characteristic (ROC-Alıcı işletim karakteristiği) eğrileri, çok çeşitli disiplinlerdeki sınıflandırıcıların performansını değerlendirmek ve karşılaştırmak için yaygın olarak kullanılan değerli bir standarttır [90, 91]. ROC, özellikle iki sınıf içeren sınıflandırma modellerinin başarım oranının ölçülmesi için sıklıkla tercih edilen bir yöntemdir. ROC eğrileri x ekseninde bulunan yanlış pozitif oranı (False Positive Rate - Specificity) ile y ekseninde bulunan doğru pozitif oranı (True Positive Rate - Sensitivity) arasındaki dengeyi gösterir (Şekil 3.14). Eğrinin altında kalan alan AUC (Area Under the Curve) 0 ile 1,0 değerleri arasında değişir ve mükemmel olarak tanımlanan bir sınıflandırıcı, (0, 1)'den geçen bir ROC eğrisine ve 1,0'lık bir AUC'ye sahiptir [91]. AUC, sınıflandırma modellerinin ayırt edici kapasitesinin bir ölçümüdür [92].



Şekil 3.14: ResNet18 mimarisi CWT Bump yaklaşımı ile P4 Kanalı için Validasyon ROC eğrisi.

4. BULGULAR

Bu bölümde, erken evre Alzheimer hastalığı teşhisi konmuş 15 AH hastasının ve 11 sağlıklı kontrol gönüllüsünün EEG verileri, 19 farklı kanaldan incelenmiştir. Alzheimer hastası (AH) bireyler ile kontrol grubunda (KG) bulunan sağlıklı bireylerin EEG sinyallerinden elde edilmiş ayrı ayrı 5sn süreli EEG segmentleri arasında ayırt edici bilgiye ulaşabilmek için Kısa Zamanlı Fourier Dönüşümü (STFT) ve Sürekli Dalgacık Dönüşümü (CWT)'nün üç çeşidi olan Bump, Amor ve Morse yaklaşımları kullanılarak EEG segmentlerinin zaman-frekans gösterimleri elde edilmiştir. Elde edilen görüntüler ResNet18, Modifiye ResNet18_1, Modifiye ResNet18_2, GoogleNet, AlexNet ve DarkNet CNN mimarileri ile eğitilerek hangi zaman-frekans yaklaşımının hangi derin öğrenme mimarisi ile daha etkili sonuç verdiğinin tespiti yapılmaya çalışılmıştır.

4.1. CNN MİMARİLERİNİN KANAL BAZLI ANALİZ SONUÇLARI

4.1.1. CNN Mimarilerinin Ortalama Validasyon ve Test Sonuçları

Tez çalışması kapsamında, 15 AH hastasının ve 11 sağlıklı kontrol gönüllüsünün 19 farklı kanaldan elde edilen EEG segmentlerinin, STFT ve CWT'nin üç çeşidi olan Bump, Amor ve Morse yaklaşımları kullanılarak skalogram ve spektrogram görüntüleri elde edilmiştir. EEG sinyallerinden her bir zaman-frekans yaklaşımında, AH hastaları için toplam 94.267 görüntü elde edilirken, kontrol grubu için 62.835 görüntü elde edilmiştir. Sonrasında, elde edilen bu görüntüler ResNet18, Modifiye ResNet18_1, Modifiye ResNet18_2, GoogleNet, AlexNet ve DarkNet CNN mimarileri ile eğitilmiştir. Aşağıda bulunan tablolarda (Tablo 4.1 – Tablo 4.16) tüm mimarilerin zaman frekans yaklaşımlarının tamamı ile elde edilmiş ve kanal bazlı ortalamaları alınmış performans metrikleri sonuçları yer almaktadır. Tablolarda yer alan sonuçlara göre; tüm mimariler değerlendirildiğinde ortalama validasyon sonuçları içerisinde en yüksek başarım oranı %88,76 PRE, %11,24 FDR, %82,24 SPE, %91.77 SEN, %88,11 ACC ve %90,23 F1-Skoru metrik değerleriyle ResNet18 CNN mimarisi ve CWT Bump zaman-frekans yaklaşımıyla elde edilirken; ortalama test sonuçları içerisinde de en yüksek başarım oranı %89,33 PRE, %10,67 FDR, %83,15 SPE, %91,55 SEN, %88,37 ACC ve %90,42 F1-Skoru metrik değerleriyle yine ResNet18 CNN mimarisi ve CWT Bump zaman-frekans yaklaşımıyla

elde edilmiştir. Diğer mimarilerin elde ettiği en yüksek başarım oranları ise şu şekildedir; Modifiye ResNet18_1 mimarisi için ortalama validasyon sonuçları içinde en yüksek değerler %83,66 PRE, %16,34 FDR, %74,26 SPE, %86,21 SEN, %81,66 ACC ve %84,91 F1-Skoru metrik değerleriyle CWT Bump zaman-frekans yaklaşımıyla elde edilmiştir. Benzer şekilde ortalama test sonuçları içinde en yüksek değerler %83,65 PRE, %16,35 FDR, %74,09 SPE, %86,69 SEN, %81,89 ACC ve %85,14 F1-Skoru metrik değerleriyle CWT Bump zaman-frekans yaklaşımıyla elde edilmiştir.

Modifiye ResNet18_2 mimarisi için ortalama validasyon sonuçları içinde en yüksek değerler %81,21 PRE, %18,79 FDR, %68,56 SPE, %88,19 SEN, %80,64 ACC ve %84,53 F1-Skoru metrik değerleriyle CWT Bump zaman-frekans yaklaşımıyla elde edilirken ortalama test sonuçları içinde en yüksek değerler %81,20 PRE, %18,80 FDR, %68,36 SPE, %88,28 SEN, %80,68 ACC ve %84,58 F1-Skoru metrik değerleriyle CWT Bump zaman-frekans yaklaşımıyla elde edilmiştir.

AlexNet mimarisi için ortalama validasyon sonuçları içinde en yüksek değerler %82,65 PRE, %17,35 FDR, %71,92 SPE, %86,73 SEN, %81,02 ACC ve %84,61 F1-Skoru metrik değerleriyle CWT Bump zaman-frekans yaklaşımıyla elde edilirmiştir. Benzer şekilde ortalama test sonuçları içinde en yüksek değerler %82,41 PRE, %17,59 FDR, %71,23 SPE, %86,93 SEN, %80,93 ACC ve %84,58 F1-Skoru metrik değerleriyle CWT Bump zaman-frekans yaklaşımıyla elde edilmiştir.

GoogleNet mimarisi için ortalama validasyon sonuçları içinde en yüksek değerler %85,44 PRE, %14,56 FDR, %76,36 SPE, %84,75 SEN, %81,79 ACC ve %84,57 F1-Skoru metrik değerleriyle CWT Bump zaman-frekans yaklaşımıyla elde edilirken ortalama test sonuçları içinde en yüksek değerler %85,21 PRE, %14,79 FDR, %76,43 SPE, %84,37 SEN, %81,54 ACC ve %84,27 F1-Skoru metrik değerleriyle CWT Bump zaman-frekans yaklaşımıyla elde edilmiştir.

DarkNet mimarisi için ortalama validasyon sonuçları içinde en yüksek değerler %83,46 PRE, %16,54 FDR, %75,52 SPE, %80,37 SEN, %78,62 ACC ve %78,54 F1-Skoru metrik değerleriyle CWT Bump zaman-frekans yaklaşımıyla elde edilmiştir. Benzer şekilde ortalama test sonuçları içinde en yüksek değerler %83,09 PRE, %16,91 FDR, %74,40 SPE, %80,52 SEN, %78,34 ACC ve %78,25 F1-Skoru metrik değerleriyle CWT Bump zaman-frekans yaklaşımıyla elde edilmiştir.

Performans metrikleri değerleri göz önünde bulundurulduğunda çalışmada yer alan tüm mimariler için en yüksek sınıflandırma başarım oranları CWT Bump zaman-frekans yaklaşımıyla elde edilmiştir.

Tablo 4.1: ResNet18 mimarisi için ZF yaklaşımlarının ortalama validasyon sonuçları.

Resnet18_Validasyon						
ZF Yaklaşımı	**PRE**	**FDR**	**SPE**	**SEN**	**ACC**	**F1-SKORU**
STFT	85,41	14,59	76,82	88,20	83,91	86,77
CWT-Amor	87,78	12,22	80,79	90,04	86,53	88,89
CWT-Bump	88,76	11,24	82,24	91,77	***88,11***	90,23
CWT-Morse	87,77	12,23	80,72	90,05	86,51	88,88

Tablo 4.2: ResNet18 mimarisi için ZF yaklaşımlarının ortalama test sonuçları.

Resnet18_Test						
ZF Yaklaşımı	**PRE**	**FDR**	**SPE**	**SEN**	**ACC**	**F1-SKORU**
STFT	85,69	14,31	77,26	88,62	83,76	87,12
CWT-Amor	87,39	12,61	79,91	90,21	86,37	88,77
CWT-Bump	89,33	10,67	83,15	91,55	***88,37***	90,42
CWT-Morse	87,54	12,46	80,39	90,11	86,43	88,80

Tablo 4.3: Modifiye ResNet18_1 mimarisi için ZF yaklaşımlarının ortalama validasyon sonuçları.

Modifiye ResNet18_1_Validasyon						
ZF Yaklaşımı	**PRE**	**FDR**	**SPE**	**SEN**	**ACC**	**F1-SKORU**
STFT	79,52	20,48	67,23	82,62	76,80	81,03
CWT-Amor	82,12	17,88	71,77	85,12	80,03	83,58
CWT-Bump	83,66	16,34	74,26	86,21	***81,66***	84,91
CWT-Morse	82,94	17,06	73,07	85,21	80,62	84,05

Tablo 4.4: Modifiye ResNet18_1 mimarisi için ZF yaklaşımlarının ortalama test sonuçları.

Modifiye ResNet18_1_Test						
ZF Yaklaşımı	**PRE**	**FDR**	**SPE**	**SEN**	**ACC**	**F1-SKORU**
STFT	79,80	20,20	67,73	82,78	77,07	81,25
CWT-Amor	82,56	17,44	72,32	85,15	80,31	83,83
CWT-Bump	83,65	16,35	74,09	86,69	***81,89***	85,14
CWT-Morse	82,91	17,09	72,95	85,13	80,58	83,99

Tablo 4.5: Modifiye ResNet18_2 mimarisi için ZF yaklaşımlarının ortalama validasyon sonuçları.

Modifiye ResNet18_2_Validasyon						
ZF Yaklaşımı	**PRE**	**FDR**	**SPE**	**SEN**	**ACC**	**F1-SKORU**
STFT	75,79	24,21	57,73	86,07	75,10	80,57
CWT-Amor	79,81	20,19	66,39	86,25	78,64	82,89
CWT-Bump	81,21	18,79	68,56	88,19	***80,64***	84,53
CWT-Morse	80,73	19,27	67,70	86,93	79,70	83,70

Tablo 4.6: Modifiye ResNet18_2 mimarisi için ZF yaklaşımlarının ortalama test sonuçları.

Modifiye ResNet18_2_Test						
ZF Yaklaşımı	**PRE**	**FDR**	**SPE**	**SEN**	**ACC**	**F1-SKORU**
STFT	76,49	23,51	59,12	86,73	75,91	81,25
CWT-Amor	79,79	20,21	66,30	86,59	78,80	83,04
CWT-Bump	81,20	18,80	68,36	88,28	***80,68***	84,58
CWT-Morse	80,03	19,97	66,82	86,36	78,86	83,05

Tablo 4.7: AlexNet mimarisi için ZF yaklaşımlarının ortalama validasyon sonuçları.

AlexNet_Validasyon						
ZF Yaklaşımı	**PRE**	**FDR**	**SPE**	**SEN**	**ACC**	**F1-SKORU**
STFT	79,21	20,79	64,87	84,76	77,35	81,83
CWT-Amor	81,71	18,29	69,64	85,99	79,91	83,75
CWT-Bump	82,65	17,35	71,92	86,73	***81,02***	84,61
CWT-Morse	82,25	17,75	71,36	86,75	80,77	84,42

Tablo 4.8: AlexNet mimarisi için ZF yaklaşımlarının ortalama test sonuçları.

AlexNet_Test						
ZF Yaklaşımı	**PRE**	**FDR**	**SPE**	**SEN**	**ACC**	**F1-SKORU**
STFT	79,14	20,86	65,01	84,87	77,39	81,85
CWT-Amor	82,15	17,85	70,85	86,30	80,44	84,14
CWT-Bump	82,41	17,59	71,23	86,93	***80,93***	84,58
CWT-Morse	82,47	17,53	71,75	86,28	80,74	84,31

Tablo 4.9: GoogleNet mimarisi için ZF yaklaşımlarının ortalama validasyon sonuçları.

GoogleNet_Validasyon						
ZF Yaklaşımı	**PRE**	**FDR**	**SPE**	**SEN**	**ACC**	**F1-SKORU**
STFT	80,67	19,33	67,97	83,72	77,77	81,84
CWT-Amor	83,54	16,46	74,34	83,56	79,73	83,14
CWT-Bump	85,44	14,56	76,36	84,75	***81,79***	84,57
CWT-Morse	81,90	18,10	69,51	86,60	80,03	83,66

Tablo 4.10: GoogleNet mimarisi için ZF yaklaşımlarının ortalama test sonuçları.

GoogleNet_Test						
ZF Yaklaşımı	**PRE**	**FDR**	**SPE**	**SEN**	**ACC**	**F1-SKORU**
STFT	80,81	19,19	68,47	83,44	77,76	81,72
CWT-Amor	83,67	16,33	74,28	84,16	80,11	83,52
CWT-Bump	85,21	14,79	76,43	84,37	***81,54***	84,27
CWT-Morse	81,87	18,13	69,63	86,54	79,98	83,62

Tablo 4.11: DarkNet mimarisi için ZF yaklaşımlarının ortalama validasyon sonuçları.

DarkNet19_Validasyon						
ZF Yaklaşımı	**PRE**	**FDR**	**SPE**	**SEN**	**ACC**	**F1-SKORU**
STFT	79,94	20,06	64,87	85,11	77,58	81,87
CWT-Amor	74,57	25,43	50,39	87,92	72,99	79,70
CWT-Bump	83,46	16,54	75,52	80,37	***78,62***	78,54
CWT-Morse	79,12	20,88	62,05	87,12	77,51	81,36

Tablo 4.12: DarkNet mimarisi için ZF yaklaşımlarının ortalama test sonuçları.

DarkNet19_Test						
ZF Yaklaşımı	**PRE**	**FDR**	**SPE**	**SEN**	**ACC**	**F1-SKORU**
STFT	80,10	19,90	65,91	84,04	77,33	81,47
CWT-Amor	74,32	25,68	49,90	87,96	72,77	79,58
CWT-Bump	83,09	16,91	74,40	80,52	***78,34***	78,25
CWT-Morse	79,24	20,76	62,52	86,93	77,55	81,31

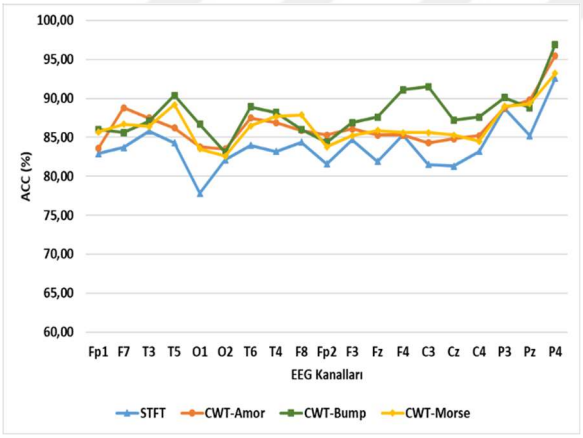
4.1.2. CNN Mimarilerinin Tüm ZF Temsilleri İçin Kanal Bazlı Validasyon ve Test Doğruluk (Accuracy) Sonuçları

Tez çalışması kapsamında 15 AH hastasının ve 11 sağlıklı kontrol gönüllüsünün EEG segmentlerinden, STFT ve CWT'nin üç çeşidi olan Bump, Amor ve Morse yaklaşımları kullanılarak elde edilen görüntüler Resnet18, Modifiye ResNet18_1, Modifiye ResNet18_2, GoogleNet, AlexNet ve DarkNet CNN mimarileri ile eğitilmiştir. Aşağıda bulunan tablolarda (Tablo 4.13 – Tablo 4.18) tüm mimarilerin zaman-frekans yaklaşımlarının tamamı ile elde edilmiş kanal bazlı validasyon ve test accuracy (doğruluk) sonuçları ve sonuçların grafik gösterimleri yer almaktadır.

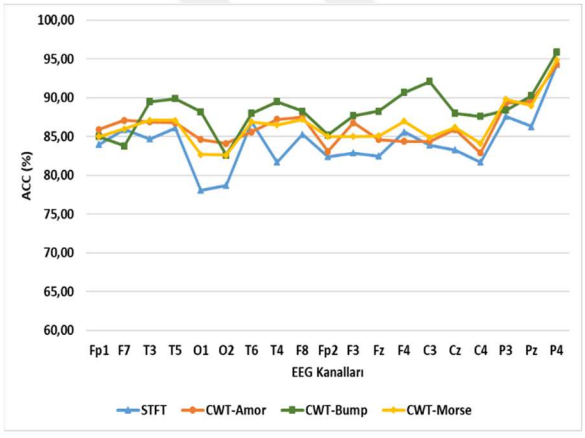
Tablo 4.13: ResNet18 mimarisi için ZF yaklaşımlarının kanal bazlı validasyon ve test accuracy sonuçları.

Resnet18-Validasyon ACC				
	STFT	CWT-Amor	CWT-Bump	CWT-Morse
Fp1	82,90	83,60	86,00	85,70
F7	83,70	88,80	85,60	86,70
T3	85,80	87,50	87,10	86,40
T5	84,30	86,20	90,40	89,20
O1	77,80	83,80	86,70	83,50
O2	82,10	83,50	83,10	82,60
T6	84,00	87,50	88,90	86,50
T4	83,20	86,90	88,20	87,70
F8	84,40	85,90	86,00	87,90
Fp2	81,60	85,30	84,40	83,80
F3	84,70	86,10	86,90	85,20
Fz	81,90	85,30	87,60	85,90
F4	85,30	85,30	91,10	85,60
C3	81,50	84,30	91,50	85,60
Cz	81,30	84,80	87,20	85,30
C4	83,20	85,20	87,60	84,50
P3	88,70	88,80	90,10	89,00
Pz	85,20	89,80	88,80	89,30
P4	92,60	95,50	***96,90***	93,20

Resnet18-Test ACC				
	STFT	CWT-Amor	CWT-Bump	CWT-Morse
Fp1	84,00	85,90	85,00	85,00
F7	85,90	87,10	83,80	86,00
T3	84,70	86,90	89,50	87,10
T5	86,10	86,80	89,90	87,10
O1	78,10	84,60	88,20	82,70
O2	78,70	84,10	82,60	82,60
T6	86,90	85,60	88,00	86,90
T4	81,70	87,20	89,50	86,50
F8	85,30	87,50	88,30	87,20
Fp2	82,40	83,10	85,20	85,00
F3	82,90	86,80	87,70	85,00
Fz	82,50	84,60	88,30	85,10
F4	85,60	84,40	90,70	87,00
C3	83,90	84,40	92,10	84,90
Cz	83,30	85,90	88,00	86,20
C4	81,70	82,90	87,60	84,10
P3	87,60	89,30	88,40	89,80
Pz	86,30	89,60	90,30	89,00
P4	94,30	94,30	***95,90***	94,90



(a)



(b)

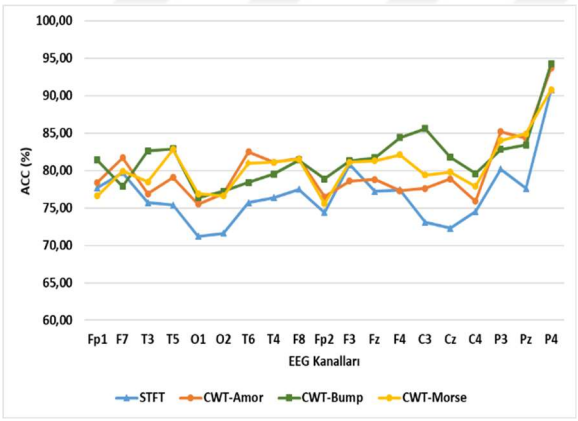
Şekil 4.1: ResNet18 mimarisi için ZF yaklaşımlarının kanal bazlı validasyon (a) ve test (b) accuracy sonuçlarının grafik gösterimi.

Resnet18 mimarisinin kanal bazlı validasyon ve test tablosundan (Tablo 4.13) görüleceği üzere beynin posterior (arka) bölgesinde bulunan P4 kanalı, CWT Bump yaklaşımı ile %96,90 validasyon ve %95,90 test accuracy değerleriyle diğer kanallardan daha iyi sonuç vermiştir.

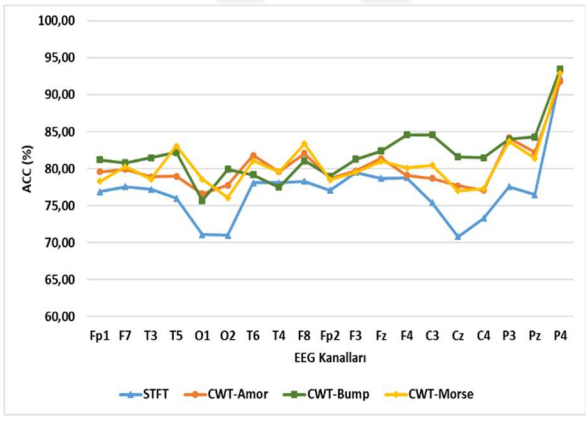
Tablo 4.14: Modifiye ResNet18_1 mimarisi için ZF yaklaşımlarının kanal bazlı validasyon ve test accuracy sonuçları.

Modifiye ResNet18_1 Validasyon ACC				
	STFT	CWT-Amor	CWT-Bump	CWT-Morse
Fp1	77,70	78,40	81,40	76,60
F7	79,70	81,70	77,90	79,90
T3	75,70	76,90	82,60	78,50
T5	75,40	79,10	82,90	82,80
O1	71,20	75,50	76,40	76,90
O2	71,60	76,90	77,20	76,60
T6	75,70	82,50	78,40	81,00
T4	76,40	81,10	79,50	81,10
F8	77,50	81,60	81,40	81,50
Fp2	74,40	76,50	78,90	75,60
F3	80,80	78,60	81,30	81,10
Fz	77,20	78,80	81,70	81,30
F4	77,40	77,30	84,40	82,10
C3	73,10	77,60	85,60	79,40
Cz	72,30	78,90	81,80	79,80
C4	74,50	75,90	79,60	77,90
P3	80,20	85,20	82,80	84,00
Pz	77,60	84,30	83,40	84,90
P4	90,80	93,70	***94,30***	90,80

Modifiye ResNet18_1 Test ACC				
	STFT	CWT-Amor	CWT-Bump	CWT-Morse
Fp1	76,90	79,60	81,20	78,30
F7	77,60	79,90	80,80	80,30
T3	77,20	78,90	81,50	78,60
T5	76,00	79,00	82,20	83,10
O1	71,10	76,60	75,70	78,60
O2	71,00	77,80	79,90	76,10
T6	78,10	81,80	79,20	81,10
T4	78,10	79,60	77,50	79,60
F8	78,30	82,10	81,10	83,40
Fp2	77,10	78,70	79,00	78,50
F3	79,50	79,70	81,30	79,50
Fz	78,70	81,40	82,40	81,00
F4	78,80	79,10	84,60	80,10
C3	75,40	78,70	84,60	80,50
Cz	70,80	77,70	81,60	77,00
C4	73,30	77,10	81,50	77,30
P3	77,60	84,20	84,00	83,70
Pz	76,50	82,20	84,30	81,40
P4	92,40	91,80	***93,50***	92,90



(a)



(b)

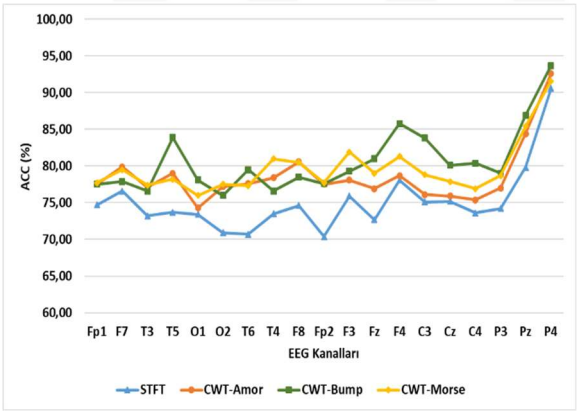
Şekil 4.2: Modifiye ResNet18_1 mimarisi için ZF yaklaşımlarının kanal bazlı validasyon (a) ve test (b) accuracy sonuçlarının grafik gösterimi.

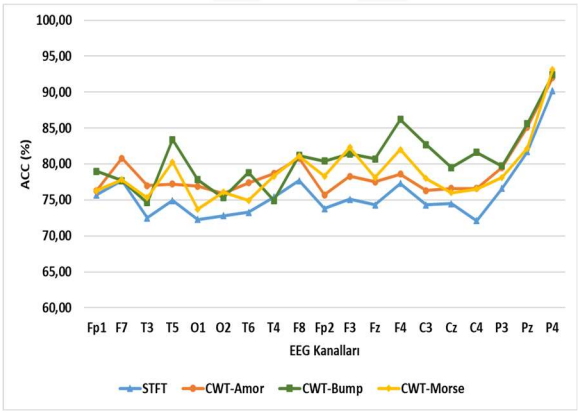
Modifiye ResNet18_1 mimarisinin kanal bazlı validasyon ve test tablosundan (Tablo 4.14) anlaşılacağı üzere beynin posterior (arka) bölgesinde bulunan P4 kanalı, CWT Bump yaklaşımı ile %94,30 validasyon ve %93,50 test accuracy değerleriyle diğer kanallardan daha iyi sonuç vermiştir.

Tablo 4.15: Modifiye ResNet18_2 mimarisi için ZF yaklaşımlarının kanal bazlı validasyon ve test accuracy sonuçları.

Modifiye ResNet18_2 Validasyon ACC				
	STFT	CWT-Amor	CWT-Bump	CWT-Morse
Fp1	74,70	77,50	77,50	77,70
F7	76,60	79,90	77,90	79,50
T3	73,20	77,10	76,60	77,40
T5	73,70	79,00	83,90	78,20
O1	73,40	74,30	78,10	76,00
O2	70,90	77,20	76,00	77,50
T6	70,70	77,60	79,50	77,30
T4	73,50	78,40	76,60	81,00
F8	74,60	80,60	78,50	80,50
Fp2	70,40	77,50	77,60	77,70
F3	75,90	78,10	79,30	81,90
Fz	72,70	76,90	81,00	79,00
F4	78,10	78,70	85,80	81,30
C3	75,10	76,10	83,80	78,80
Cz	75,20	75,90	80,10	77,90
C4	73,60	75,40	80,40	76,90
P3	74,20	77,00	79,00	78,70
Pz	79,80	84,40	86,90	85,40
P4	90,60	92,60	***93,70***	91,60

Modifiye ResNet18_2 Test ACC				
	STFT	CWT-Amor	CWT-Bump	CWT-Morse
Fp1	75,70	76,30	79,00	76,30
F7	77,70	80,80	77,70	77,80
T3	72,50	77,00	74,60	75,30
T5	74,90	77,20	83,40	80,30
O1	72,30	76,90	77,80	73,70
O2	72,80	75,90	75,30	76,10
T6	73,30	77,40	78,80	74,90
T4	75,40	78,70	74,90	78,30
F8	77,70	80,80	81,20	81,10
Fp2	73,80	75,70	80,40	78,30
F3	75,10	78,30	81,40	82,30
Fz	74,30	77,50	80,70	78,10
F4	77,30	78,60	86,20	82,00
C3	74,30	76,30	82,70	78,00
Cz	74,50	76,60	79,50	76,00
C4	72,10	76,60	81,60	76,50
P3	76,60	79,50	79,70	78,10
Pz	81,70	85,10	85,60	82,20
P4	90,20	92,00	92,40	***93,10***





(a) **(b)**

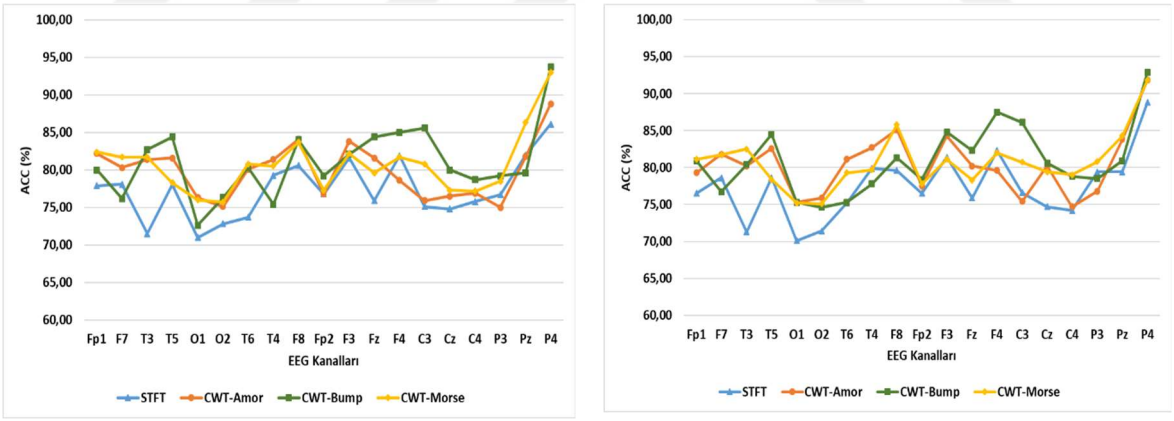
Şekil 4.3: Modifiye ResNet18_2 mimarisi için ZF yaklaşımlarının kanal bazlı validasyon (a) ve test (b) accuracy sonuçlarının grafik gösterimi.

Modifiye ResNet18_2 mimarisinin kanal bazlı validasyon ve test tablosundan (Tablo 4.15) anlaşılacağı üzere beynin posterior (arka) bölgesinde bulunan P4 kanalı, CWT Bump yaklaşımı ile %93,70 validasyon ve CWT Morse yaklaşımı ile %93,10 test accuracy değerleriyle diğer kanallardan daha iyi sonuç vermiştir.

Tablo 4.16: AlexNet mimarisi için ZF yaklaşımlarının kanal bazlı validasyon ve test accuracy sonuçları.

AlexNet-Validasyon ACC				
	STFT	CWT-Amor	CWT-Bump	CWT-Morse
Fp1	77,90	82,20	80,00	82,40
F7	78,10	80,30	76,20	81,70
T3	71,50	81,40	82,70	81,70
T5	78,00	81,60	84,40	78,30
O1	71,00	76,30	72,60	76,00
O2	72,80	75,10	76,30	75,70
T6	73,70	80,10	80,30	80,80
T4	79,30	81,40	75,40	80,50
F8	80,60	84,10	84,00	83,70
Fp2	76,80	76,80	79,20	77,30
F3	81,60	83,80	82,10	82,20
Fz	75,90	81,60	84,40	79,60
F4	81,90	78,60	85,00	81,70
C3	75,10	75,90	85,60	80,80
Cz	74,80	76,50	80,00	77,30
C4	75,80	76,90	78,70	77,20
P3	76,70	75,00	79,20	78,50
Pz	82,00	81,80	79,60	86,30
P4	86,10	88,80	***93,70***	93,00

AlexNet-Test ACC				
	STFT	CWT-Amor	CWT-Bump	CWT-Morse
Fp1	76,50	79,30	80,90	81,10
F7	78,60	81,80	76,70	81,70
T3	71,30	80,20	80,40	82,50
T5	78,60	82,60	84,50	78,40
O1	70,10	75,30	75,30	75,20
O2	71,40	75,90	74,60	75,10
T6	75,20	81,10	75,30	79,30
T4	79,90	82,70	77,80	79,70
F8	79,60	85,10	81,30	85,80
Fp2	76,50	77,50	78,40	77,80
F3	81,40	84,30	84,80	81,10
Fz	75,90	80,20	82,30	78,30
F4	82,30	79,60	87,50	82,00
C3	76,60	75,40	86,10	80,70
Cz	74,70	80,20	80,60	79,40
C4	74,20	74,70	78,80	79,00
P3	79,40	76,80	78,50	80,80
Pz	79,40	83,80	80,90	84,30
P4	88,80	91,80	***92,90***	91,80



(a) **(b)**

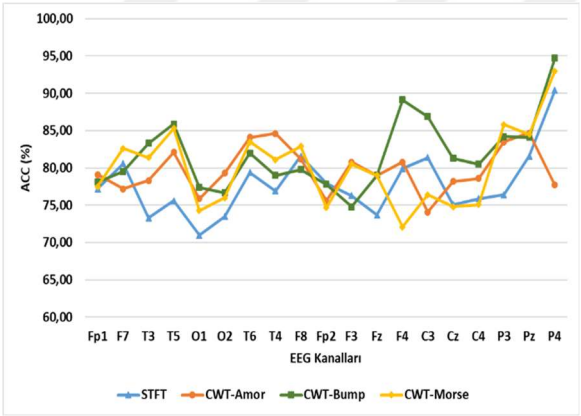
Şekil 4.4: AlexNet mimarisi için ZF yaklaşımlarının kanal bazlı validasyon (a) ve test (b) accuracy sonuçlarının grafik gösterimi.

AlexNet mimarisinin kanal bazlı validasyon ve test tablosundan (Tablo 4.16) anlaşılacağı üzere beynin posterior (arka) bölgesinde bulunan P4 kanalı, CWT Bump yaklaşımı ile %93,70 validasyon ve %92,90 test accuracy değerleriyle diğer kanallardan daha iyi sonuç vermiştir.

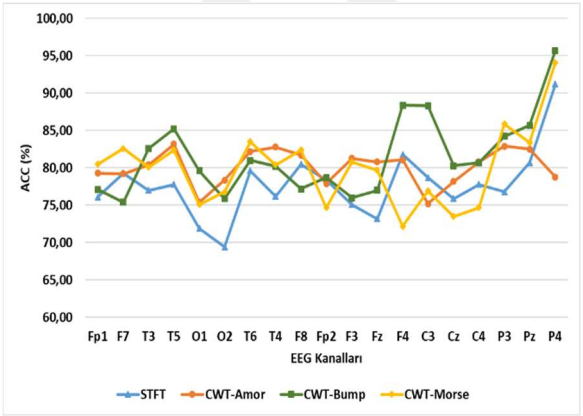
Tablo 4.17: GoogleNet mimarisi için ZF yaklaşımlarının kanal bazlı validasyon ve test accuracy sonuçları.

GoogleNet-Validasyon ACC				
	STFT	CWT-Amor	CWT-Bump	CWT-Morse
Fp1	77,20	79,10	78,10	77,50
F7	80,60	77,20	79,50	82,60
T3	73,30	78,30	83,30	81,40
T5	75,60	82,10	85,90	85,30
O1	71,00	75,90	77,40	74,30
O2	73,50	79,30	76,70	76,00
T6	79,40	84,10	82,00	83,50
T4	76,90	84,60	79,00	81,10
F8	81,60	81,20	79,80	82,90
Fp2	77,90	75,60	77,80	74,70
F3	76,30	80,80	74,80	80,50
Fz	73,70	79,00	79,00	79,00
F4	79,90	80,80	89,10	72,10
C3	81,40	74,10	86,90	76,40
Cz	75,10	78,20	81,30	74,80
C4	75,90	78,60	80,50	75,10
P3	76,40	83,50	84,20	85,80
Pz	81,60	84,70	84,10	84,50
P4	90,40	77,70	***94,70***	93,00

GoogleNet-Test ACC				
	STFT	CWT-Amor	CWT-Bump	CWT-Morse
Fp1	76,10	79,30	77,10	80,50
F7	79,30	79,20	75,40	82,60
T3	77,00	80,40	82,60	80,10
T5	77,80	83,20	85,20	82,40
O1	71,90	75,40	79,60	75,10
O2	69,40	78,40	75,90	76,80
T6	79,60	82,20	81,00	83,50
T4	76,20	82,80	80,20	80,40
F8	80,50	81,70	77,20	82,40
Fp2	78,40	77,90	78,70	74,70
F3	75,10	81,30	76,00	80,80
Fz	73,20	80,80	77,00	79,70
F4	81,80	81,10	88,40	72,20
C3	78,70	75,20	88,30	76,90
Cz	75,90	78,20	80,30	73,50
C4	77,80	80,80	80,70	74,70
P3	76,80	82,90	84,20	85,90
Pz	80,70	82,50	85,70	83,40
P4	91,20	78,80	***95,70***	94,10



(a)



(b)

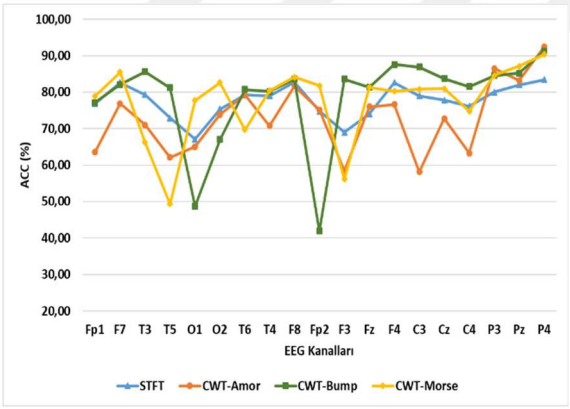
Şekil 4.5: GoogleNet mimarisi için ZF yaklaşımlarının kanal bazlı validasyon (a) ve test (b) accuracy sonuçlarının grafik gösterimi.

GoogleNet mimarisinin kanal bazlı validasyon ve test tablosundan (Tablo 4.17) anlaşılacağı üzere beynin posterior (arka) bölgesinde bulunan P4 kanalı, CWT Bump yaklaşımı ile %94,70 validasyon ve %95,70 test accuracy değerleriyle diğer kanallardan daha iyi sonuç vermiştir.

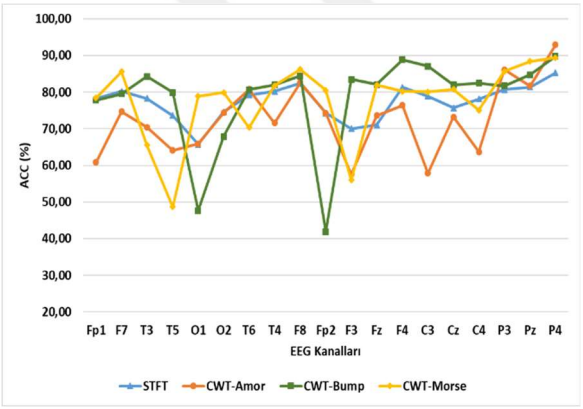
Tablo 4.18: DarkNet mimarisi için ZF yaklaşımlarının kanal bazlı validasyon ve test accuracy sonuçları.

DarkNet-Validasyon ACC				
	STFT	CWT-Amor	CWT-Bump	CWT-Morse
Fp1	76,90	63,60	77,20	78,90
F7	82,60	76,90	82,10	85,50
T3	79,30	71,00	85,60	66,20
T5	72,90	62,10	81,20	49,30
O1	67,10	65,00	48,70	77,70
O2	75,40	73,90	67,00	82,60
T6	79,20	79,20	80,70	69,70
T4	79,00	70,80	80,20	80,40
F8	82,80	81,70	83,60	84,10
Fp2	74,80	75,10	41,90	81,80
F3	69,00	58,50	83,60	56,10
Fz	74,00	76,00	81,40	81,40
F4	82,60	76,60	87,60	80,30
C3	79,00	58,20	86,90	80,80
Cz	77,80	72,80	83,70	81,00
C4	76,20	63,30	81,50	74,80
P3	80,00	86,50	84,50	84,60
Pz	82,00	83,20	85,20	87,10
P4	83,40	***92,40***	91,20	90,40

DarkNet-Test ACC				
	STFT	CWT-Amor	CWT-Bump	CWT-Morse
Fp1	78,30	60,80	77,80	78,40
F7	80,20	74,70	79,50	85,60
T3	78,30	70,40	84,30	65,50
T5	73,60	64,10	79,90	48,70
O1	65,70	65,90	47,70	78,90
O2	74,60	74,40	67,90	79,90
T6	79,20	80,80	80,70	70,30
T4	80,20	71,60	82,00	81,80
F8	82,40	82,60	84,40	86,20
Fp2	74,30	74,30	41,90	80,50
F3	70,00	57,60	83,50	56,00
Fz	71,00	73,60	82,10	81,90
F4	81,30	76,40	88,90	80,20
C3	78,90	57,90	87,10	80,10
Cz	75,70	73,20	82,00	80,80
C4	78,10	63,70	82,50	75,10
P3	80,70	86,10	81,70	85,70
Pz	81,40	81,70	84,70	88,40
P4	85,30	***92,90***	89,80	89,40



(a)



(b)

Şekil 4.6: DarkNet mimarisi için ZF yaklaşımlarının kanal bazlı validasyon (a) ve test (b) accuracy sonuçlarının grafik gösterimi.

DarkNet mimarisinin kanal bazlı validasyon ve test tablosundan (Tablo 4.18) anlaşılacağı üzere beynin posterior (arka) bölgesinde bulunan P4 kanalı, CWT Amor yaklaşımı ile %92,40 validasyon ve %92,90 test accuracy değerleriyle diğer kanallardan daha iyi sonuç vermiştir.

4.2. CNN MİMARİLERİNİN BEYİN BÖLGESİ BAZLI ANALİZ SONUÇLARI

4.2.1. ResNet18 Mimarisinin AH/KG Sınıflandırmasına Etkisi

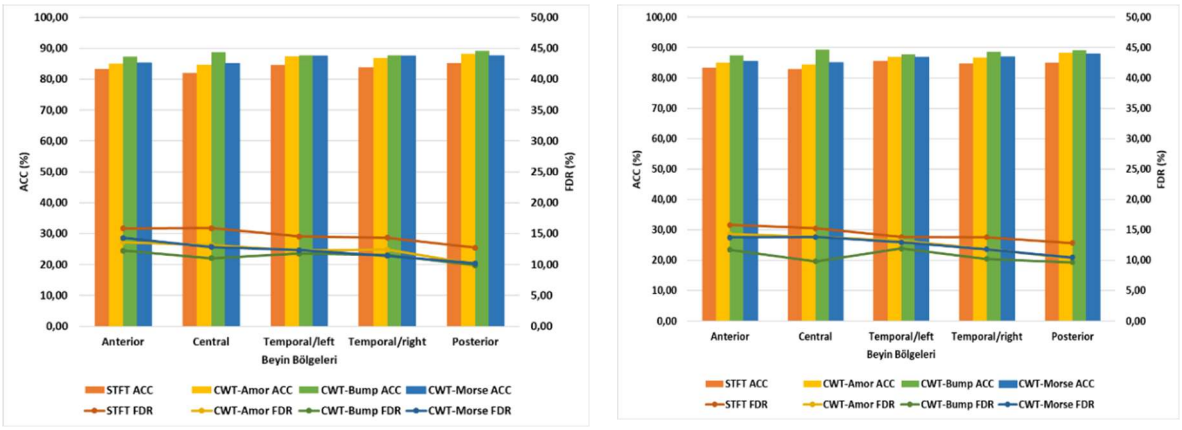
Tez çalışması kapsamında 15 AH hastasının ve 11 sağlıklı kontrol gönüllüsünün 19 farklı kanaldan kaydedilen EEG verilerinin, STFT ve CWT Amor, CWT Bump ve CWT Morse yaklaşımları kullanılarak elde edilen zaman-frekans gösterimlerinin ResNet18 mimarisi ile eğitilmesi sonucu bu derin öğrenme mimarisi için AH'nin teşhisinde uygulanabilecek en uygun zaman-frekans yaklaşımı tespit edilmeye çalışılmıştır. Mimaride görüntülerin %70'i eğitim setine (train), %15'i doğrulama setine (validation) ve kalan %15'i test setine ayrılmış ve eğitim bitiminde her kanal için; eğitim ilerlemesi (training progress) grafiği, validasyon ve test olmak üzere iki adet karmaşıklık matrisi ve iki adet ROC eğrisi elde edilmiştir. Tablo 4.19'da zaman-frekans görüntülerin ResNet18 mimarisi ile eğitimi sonucu elde edilen ortalama validasyon FDR (False Discovery Rate – Yanlış Keşif Oranı) ve ACC (Accuracy – Doğruluk) değerleri ve Şekil 4.7(a)'da bu değerlerin grafiksel gösterimleri tüm beyin kümeleri (ön, arka, merkezi, temporal/sol ve temporal/sağ) için verilmiştir. Burada her beyin kümesine ait kanallar Şekil 3.2'de verilmiş olup ön (Fp1, F3, Fz, Fp2, F4), arka (P3, O1, Pz, P4, O2), merkez (C3, Cz, C4), temporal/sol (T3, T5, F7) ve temporal/sağ (T4, T6, F8) şeklinde tanımlanmıştır. Bu sonuçlara göre; beynin posterior (arka) bölgesinden %89,12 ACC değeriyle CWT-Bump, ResNet18 mimarisi için validasyon sınıflandırma doğruluğu en yüksek olan zaman-frekans yaklaşımıdır.

Tablo 4.19: ResNet18 mimarisi için ZF yaklaşımlarının beyin bölgesi bazlı ortalama validasyon sonuçları.

	STFT		CWT-Amor		CWT-Bump		CWT-Morse	
	FDR	**ACC**	**FDR**	**ACC**	**FDR**	**ACC**	**FDR**	**ACC**
Anterior	15,86	83,28	13,64	85,12	12,26	87,20	14,30	85,24
Central	15,90	82,00	13,17	84,77	11,03	88,77	12,83	85,13
Temporal/left	14,53	84,60	12,30	87,50	11,77	87,70	12,33	87,43
Temporal/right	14,33	83,87	12,40	86,77	11,53	87,70	11,43	87,37
Posterior	12,72	85,28	10,08	88,28	9,86	***89,12***	10,20	87,52

Tablo 4.20: ResNet18 mimarisi için ZF yaklaşımlarının beyin bölgesi bazlı ortalama test sonuçları.

	STFT		CWT-Amor		CWT-Bump		CWT-Morse	
	FDR	**ACC**	**FDR**	**ACC**	**FDR**	**ACC**	**FDR**	**ACC**
Anterior	15,80	83,48	14,28	84,96	11,72	87,38	13,76	85,42
Central	15,27	82,97	13,87	84,40	9,83	***89,23***	13,83	85,07
Temporal/left	13,83	85,57	13,20	86,93	11,90	87,73	12,93	86,73
Temporal/right	13,80	84,63	11,87	86,77	10,20	88,60	11,80	86,87
Posterior	12,84	85,00	10,26	88,38	9,66	89,08	10,46	87,80



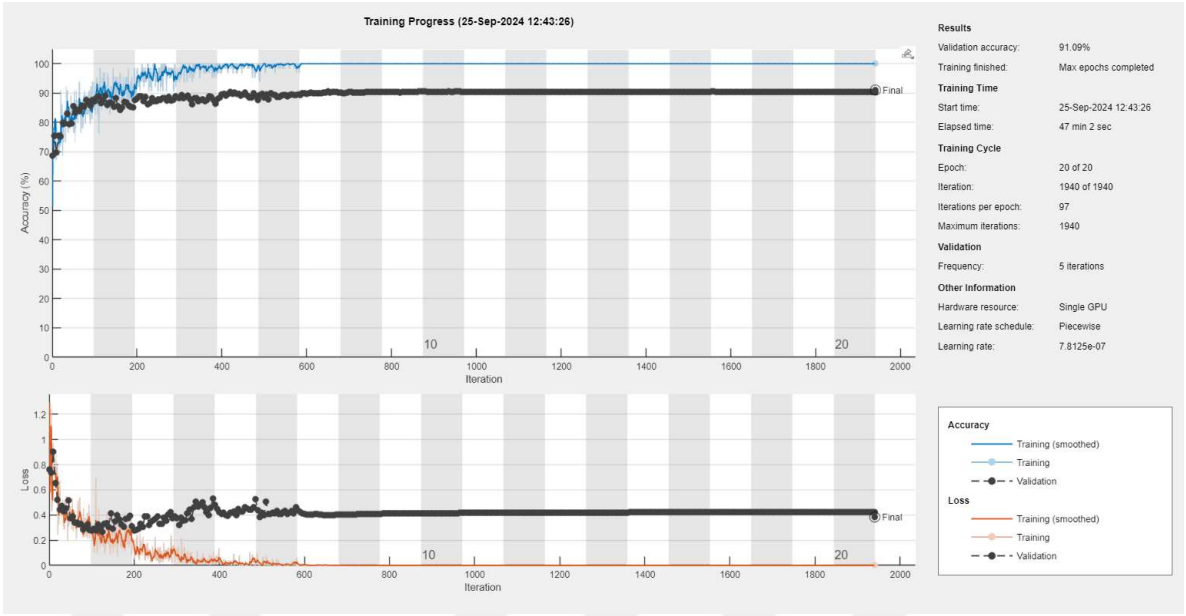
(a) **(b)**

Şekil 4.7: Beyin Bölgesi Bazlı Resnet18 Validasyon (a) ve Test (b) Sonuçları

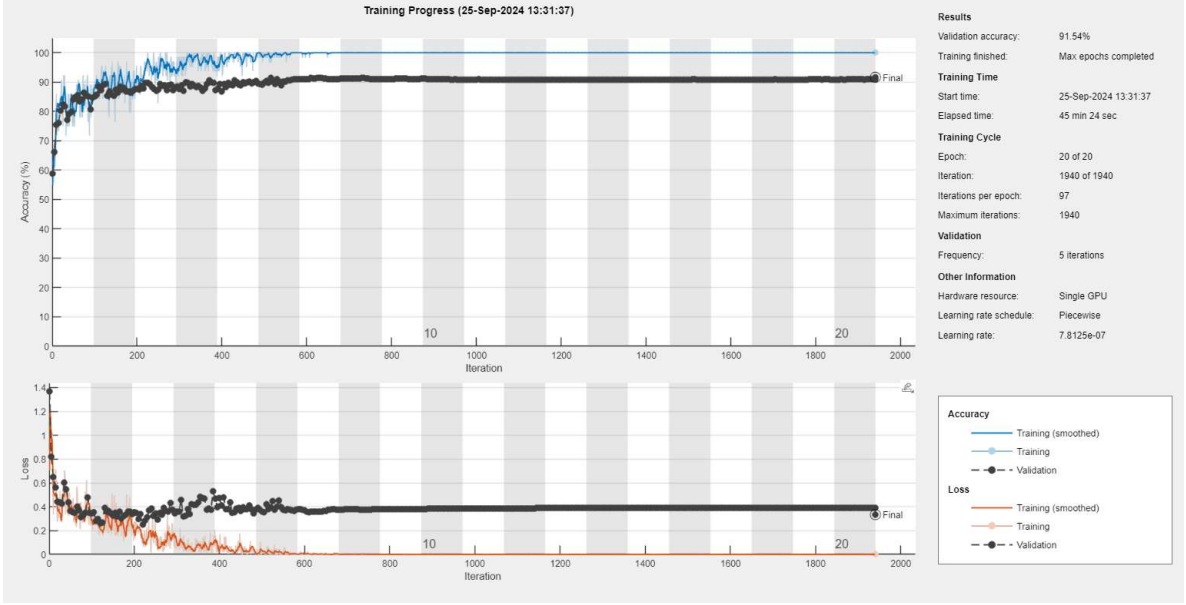
Tablo 4.20'de ResNet18 mimarisi için tüm zaman-frekans yaklaşımlarının beyin bölgesi bazlı test ACC ve FDR değerleri ve Şekil 4.7(b)'de bu değerlerin grafiksel gösterimi verilmiştir. Bu sonuçlara göre; beynin central (merkez) bölgesinden %89,23 ortalama ACC değeriyle CWT-Bump, ResNet18 mimarisi için validasyonda olduğu gibi testte de AH-KG test sınıflandırma doğruluğu en yüksek olan zaman-frekans yaklaşımıdır.

4.2.1.1. ResNet18 Mimarisinin Beyin Bölgeleri Bazlı En İyi Sonuç Veren Kanallara Ait Eğitim İlerlemesi, Validasyon ve Test İçin Karmaşıklık Matrisi ve ROC Eğrisi Görselleri

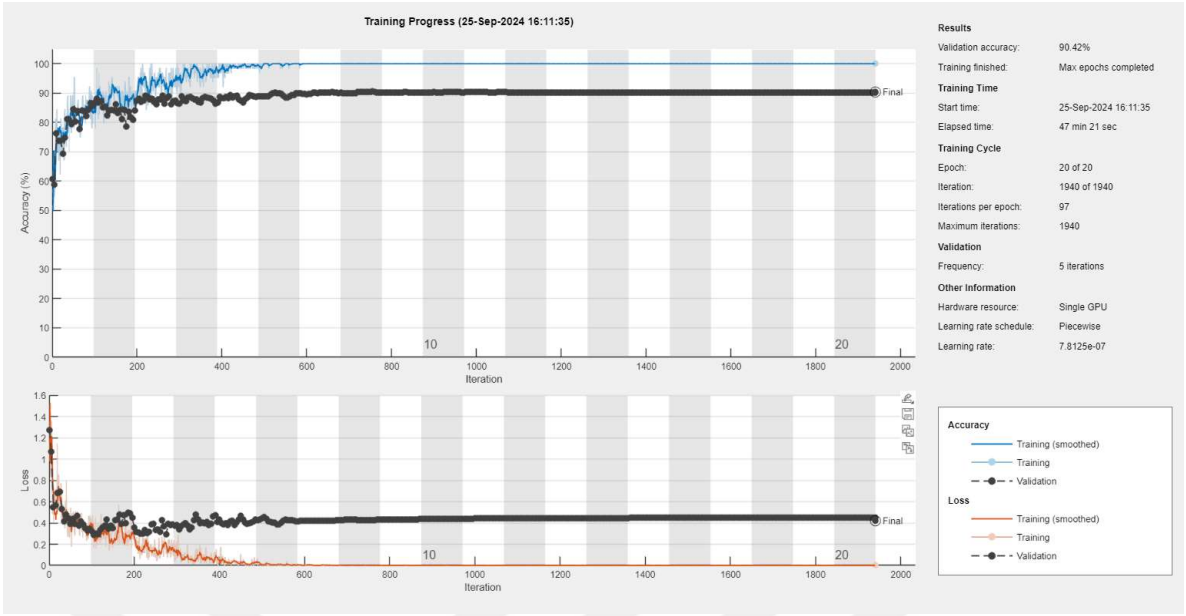
ResNet18 mimarisinin zaman-frekans yaklaşımları içinde validasyon için en iyi sonuç veren kanal CWT Bump yaklaşımı ile beynin posterior bölgesinden 96,90 ACC değerine sahip P4 kanalıdır. Bu bölümde, ResNet18 mimarisi için CWT Bump yaklaşımı ile elde edilen ve beyin bölgeleri içinde en yüksek değerlere sahip kanal sonuçları verilmiştir. Beş beyin bölgesi (ön (anterior) beyin bölgesi için F4 kanalı, merkez (central) beyin bölgesi için C3 kanalı, sol temporal (temporal left) beyin bölgesi için T5 kanalı, sağ temporal (temporal right) beyin bölgesi için T6 kanalı ve arka (posterior) beyin bölgesi için P4 kanalı) bazlı en iyi kanalların eğitim ilerlemesi (training progress), validasyon ve test karmaşıklık matrisi ve ROC eğrisi görselleri aşağıda detaylı şekilde bulunmaktadır (Şekil 4.8, Şekil 4.9, Şekil 4.10).


Training Progress (25-Sep-2024 12:43:26)
Accuracy (%)
Iteration
Loss
Final
10
20
Results
Validation accuracy: 91.09%
Training finished: Max epochs completed
Training Time
Start time: 25-Sep-2024 12:43:26
Elapsed time: 47 min 2 sec
Training Cycle
Epoch: 20 of 20
Iteration: 1940 of 1940
Iterations per epoch: 97
Maximum iterations: 1940
Validation
Frequency: 5 iterations
Other Information
Hardware resource: Single GPU
Learning rate schedule: Piecewise
Learning rate: 7.8125e-07
Accuracy
Training (smoothed)
Training
Validation
Loss
Training (smoothed)
Training
Validation

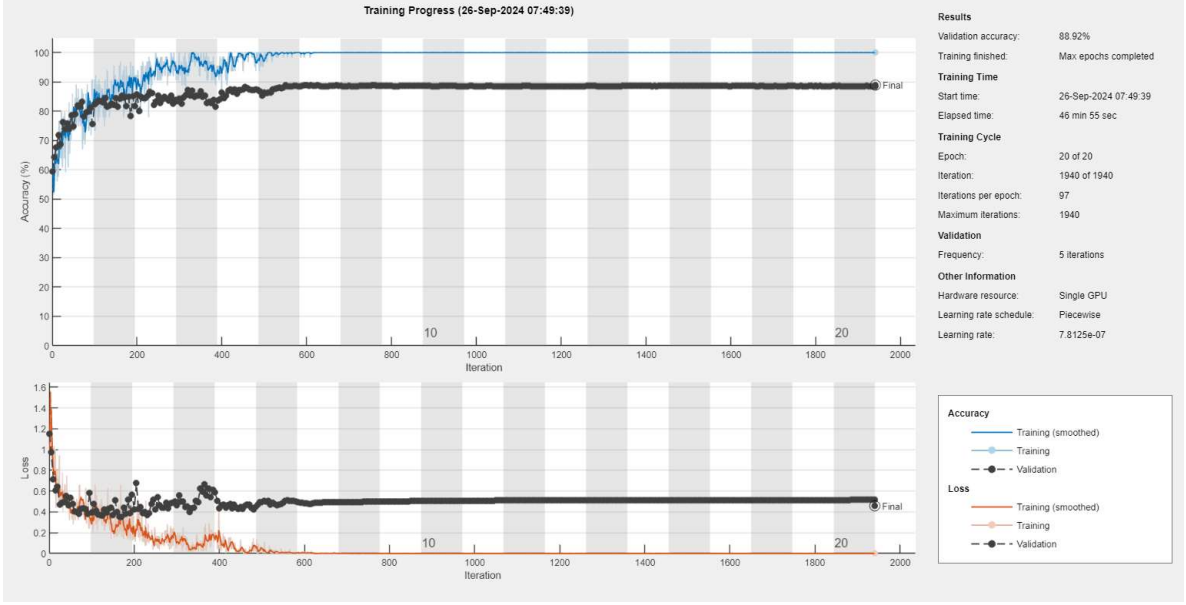
(a)


Training Progress (25-Sep-2024 13:31:37)
Accuracy (%)
Iteration
Loss
Final
10
20
Results
Validation accuracy: 91.54%
Training finished: Max epochs completed
Training Time
Start time: 25-Sep-2024 13:31:37
Elapsed time: 45 min 24 sec
Training Cycle
Epoch: 20 of 20
Iteration: 1940 of 1940
Iterations per epoch: 97
Maximum iterations: 1940
Validation
Frequency: 5 iterations
Other Information
Hardware resource: Single GPU
Learning rate schedule: Piecewise
Learning rate: 7.8125e-07
Accuracy
Training (smoothed)
Training
Validation
Loss
Training (smoothed)
Training
Validation

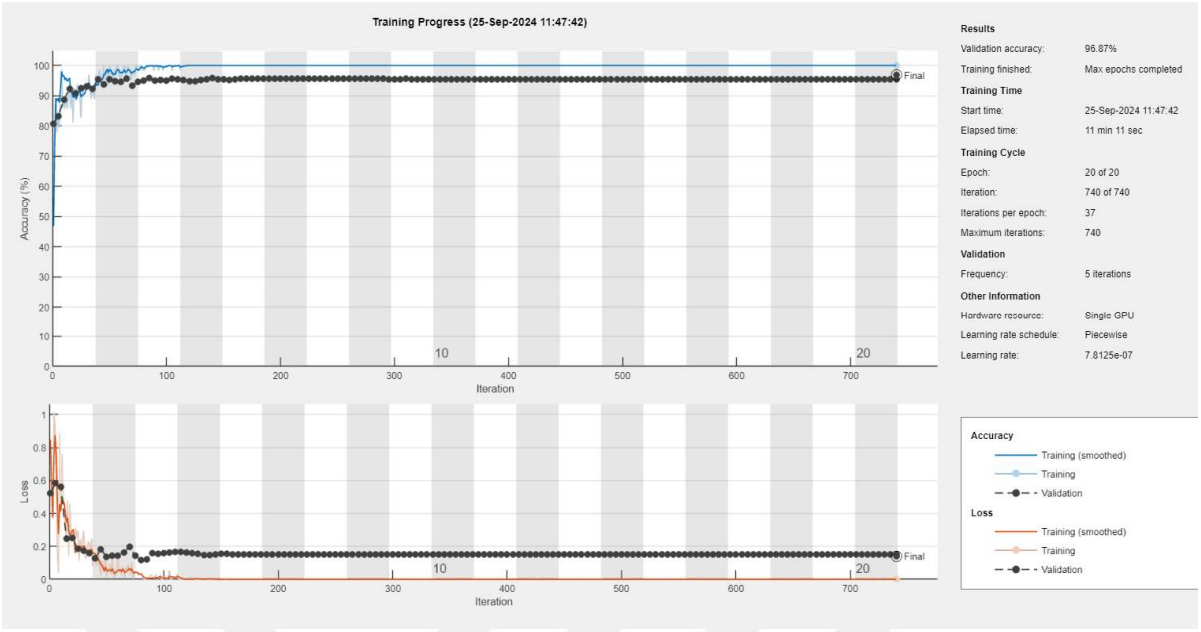
(b)


Training Progress (25-Sep-2024 16:11:35)
Accuracy (%)
Loss
Iteration
Final
10
20
Results
Validation accuracy: 90.42%
Training finished: Max epochs completed
Training Time
Start time: 25-Sep-2024 16:11:35
Elapsed time: 47 min 21 sec
Training Cycle
Epoch: 20 of 20
Iteration: 1940 of 1940
Iterations per epoch: 97
Maximum iterations: 1940
Validation
Frequency: 5 iterations
Other Information
Hardware resource: Single GPU
Learning rate schedule: Piecewise
Learning rate: 7.8125e-07
Accuracy
Training (smoothed)
Training
Validation
Loss
Training (smoothed)
Training
Validation

(c)

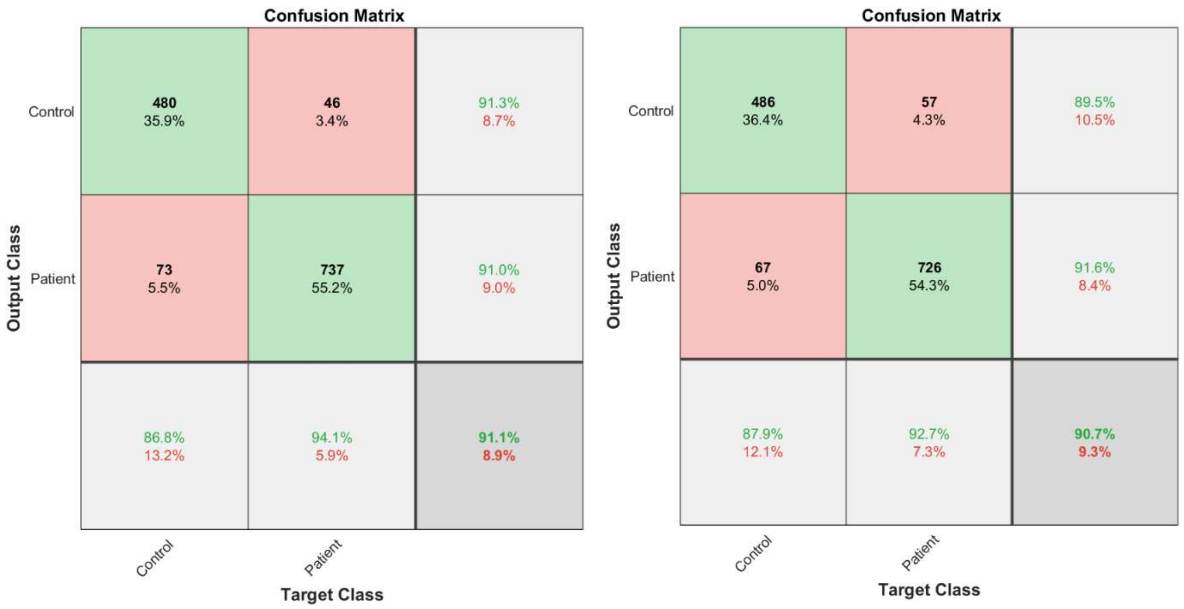

Training Progress (26-Sep-2024 07:49:39)
Accuracy (%)
Loss
Iteration
Final
10
20
Results
Validation accuracy: 88.92%
Training finished: Max epochs completed
Training Time
Start time: 26-Sep-2024 07:49:39
Elapsed time: 46 min 55 sec
Training Cycle
Epoch: 20 of 20
Iteration: 1940 of 1940
Iterations per epoch: 97
Maximum iterations: 1940
Validation
Frequency: 5 iterations
Other Information
Hardware resource: Single GPU
Learning rate schedule: Piecewise
Learning rate: 7.8125e-07
Accuracy
Training (smoothed)
Training
Validation
Loss
Training (smoothed)
Training
Validation

(d)

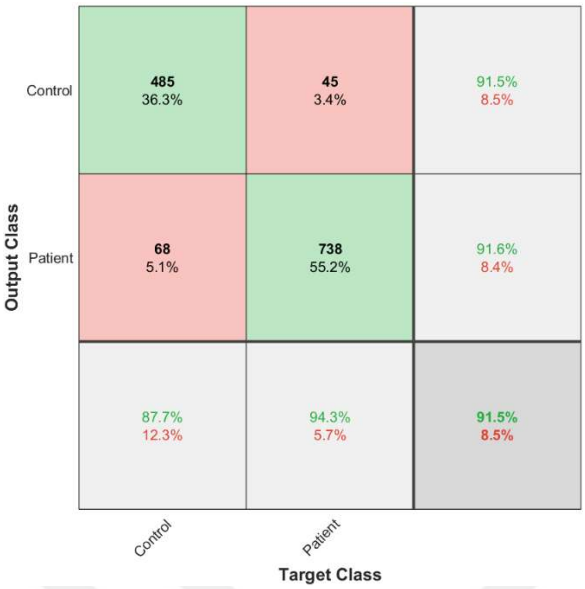


(e)

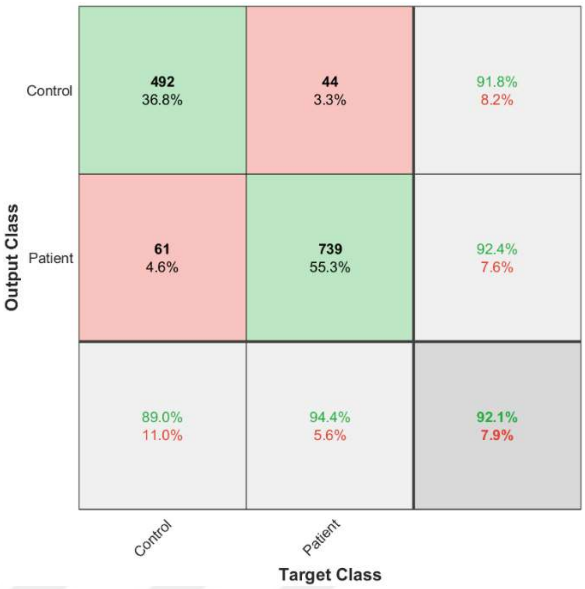
Şekil 4.8: ResNet18 mimarisinde CWT Bump yaklaşımı için; beyin bölgeleri içinde en iyi sonuç veren kanalların Training Progress görselleri; ön beyin (anterior) bölgesi için; F4 kanalı (a); merkez (central) beyin bölgesi için C3 kanalı (b), sol temporal (temporal left) beyin bölgesi için T5 kanalı (c), sağ temporal (temporal right) beyin bölgesi için T6 kanalı (d) ve arka (posterior) beyin bölgesi için P4 kanalı (e).



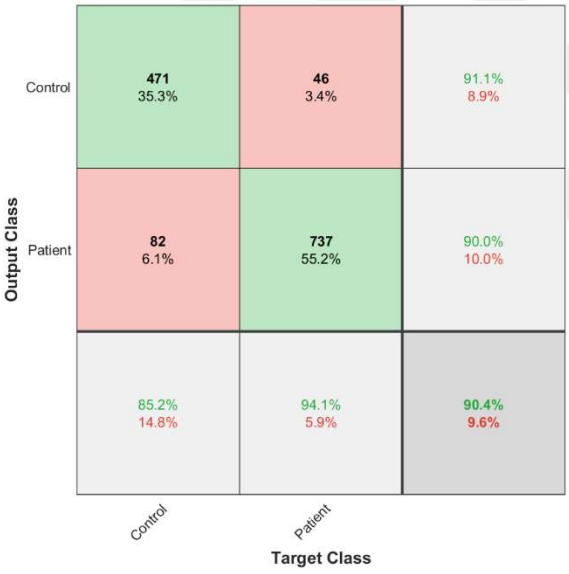
(a) **(b)**


Control
Patient
Output Class
485
36.3%
45
3.4%
91.5%
8.5%
68
5.1%
738
55.2%
91.6%
8.4%
87.7%
12.3%
94.3%
5.7%
91.5%
8.5%
Control
Patient
Target Class

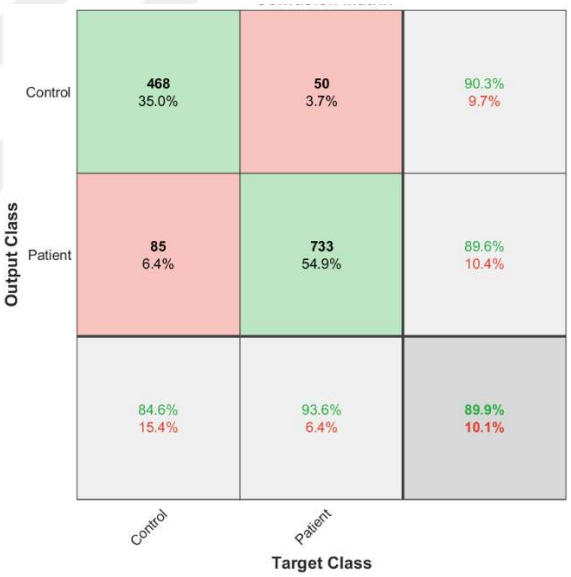
(c)


Control
Patient
Output Class
492
36.8%
44
3.3%
91.8%
8.2%
61
4.6%
739
55.3%
92.4%
7.6%
89.0%
11.0%
94.4%
5.6%
92.1%
7.9%
Control
Patient
Target Class

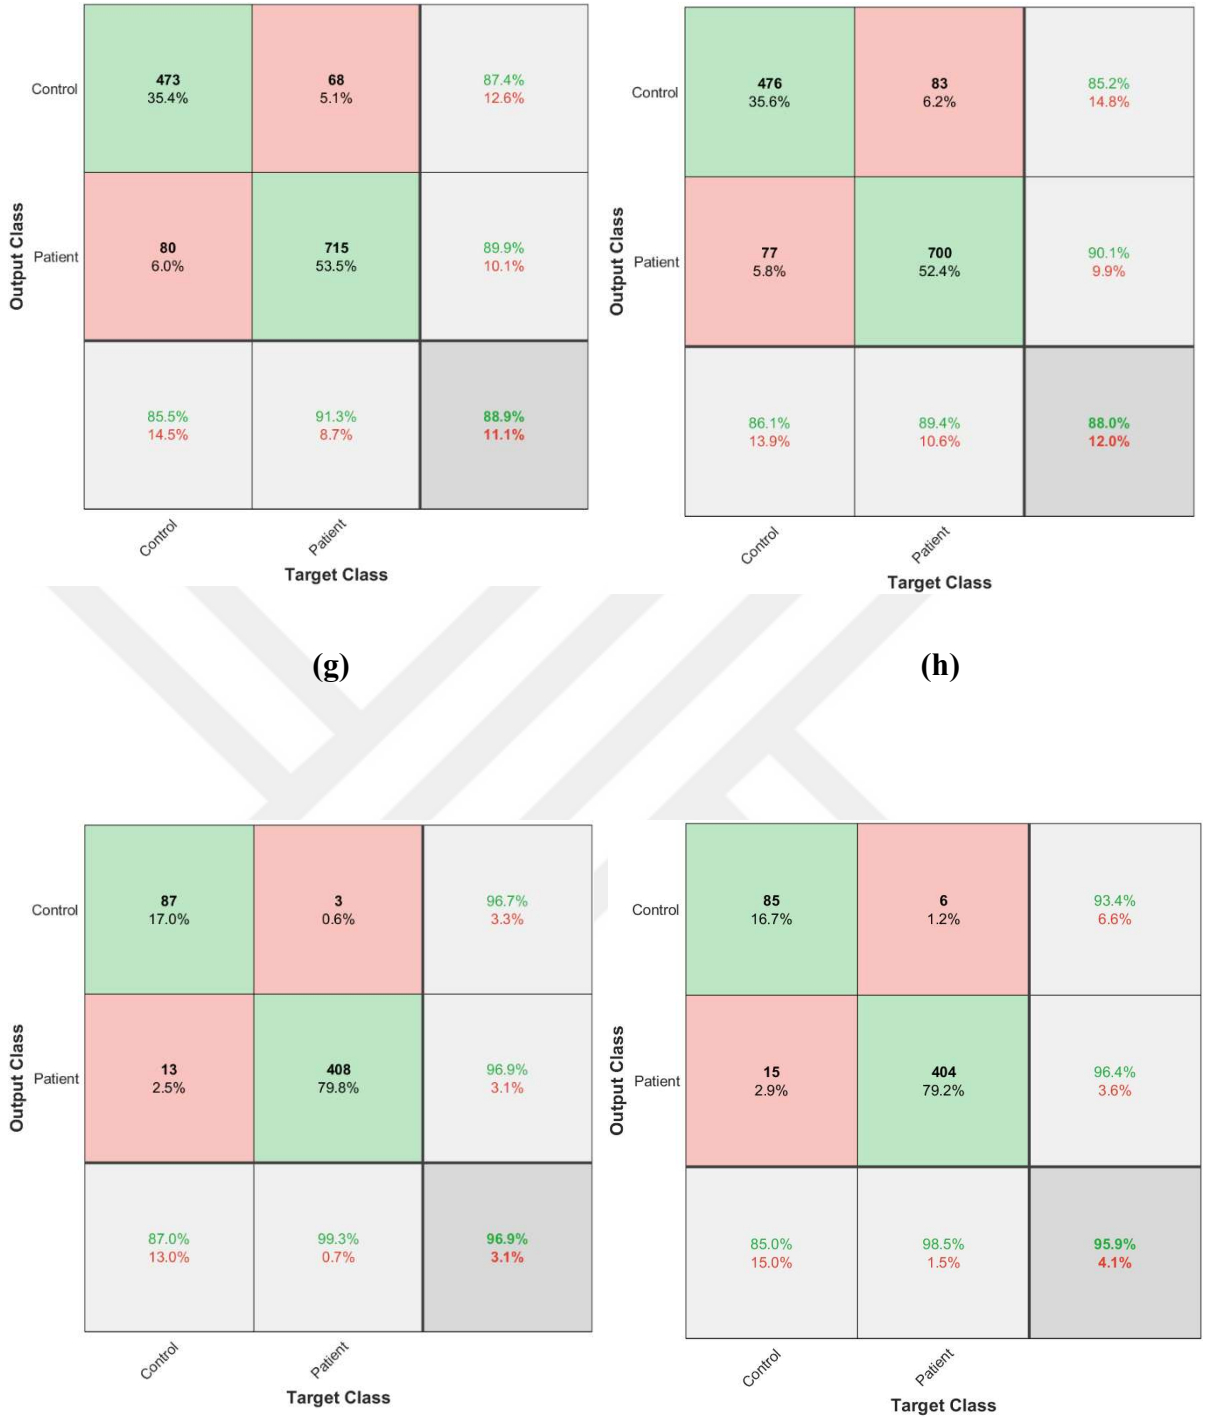
(d)


Control
Patient
Output Class
471
35.3%
46
3.4%
91.1%
8.9%
82
6.1%
737
55.2%
90.0%
10.0%
85.2%
14.8%
94.1%
5.9%
90.4%
9.6%
Control
Patient
Target Class

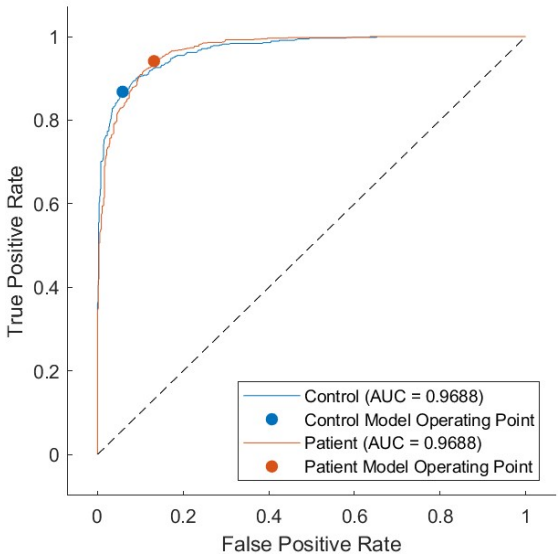
(e)


Control
Patient
Output Class
468
35.0%
50
3.7%
90.3%
9.7%
85
6.4%
733
54.9%
89.6%
10.4%
84.6%
15.4%
93.6%
6.4%
89.9%
10.1%
Control
Patient
Target Class

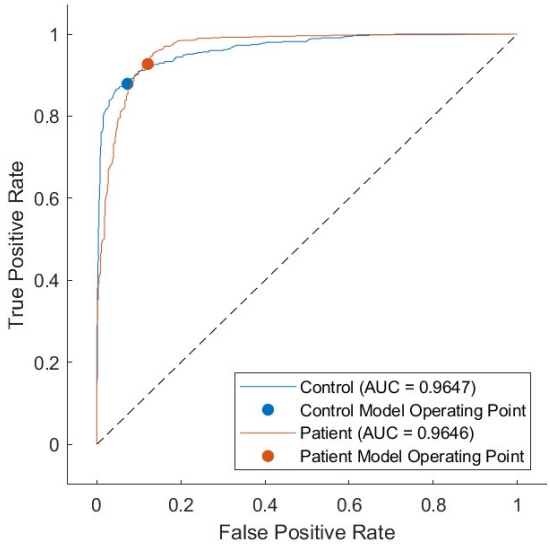
(f)



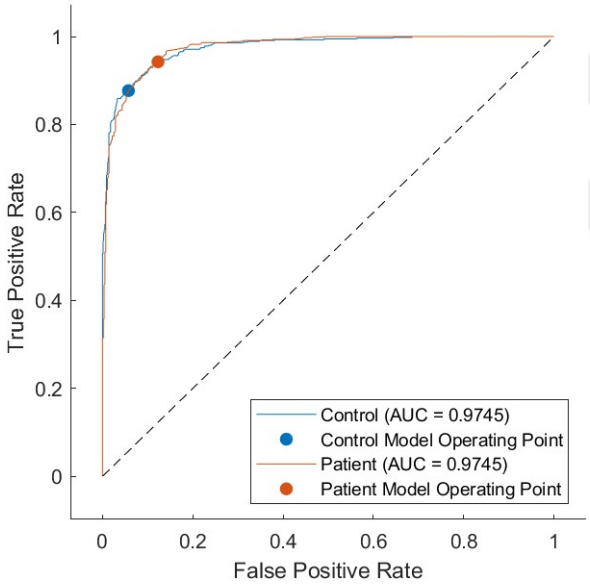
Şekil 4.9: ResNet18 mimarisinde CWT Bump yaklaşımı için; beyin bölgeleri içinde en iyi sonuç veren kanalların Validasyon ve Test karmaşıklık matrisleri; ön beyin (anterior) bölgesi için; F4 kanalı Validasyon (a) ve Test (b) matrisi; merkez (central) beyin bölgesi için C3 kanalı Validasyon (c) ve Test (d) matrisi, sol temporal (temporal left) beyin bölgesi için T5 kanalı Validasyon (e) ve Test (f) matrisi, sağ temporal (temporal right) beyin bölgesi için T6 kanalı Validasyon (g) ve Test (h) matrisi ve arka (posterior) beyin bölgesi için P4 kanalı Validasyon (i) ve Test (j) matrisi.


True Positive Rate
False Positive Rate
Control (AUC = 0.9688)
Control Model Operating Point
Patient (AUC = 0.9688)
Patient Model Operating Point

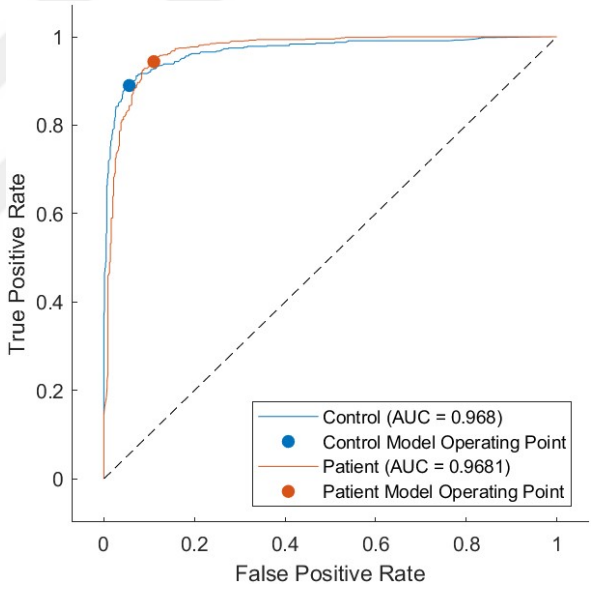
(a)


True Positive Rate
False Positive Rate
Control (AUC = 0.9647)
Control Model Operating Point
Patient (AUC = 0.9646)
Patient Model Operating Point

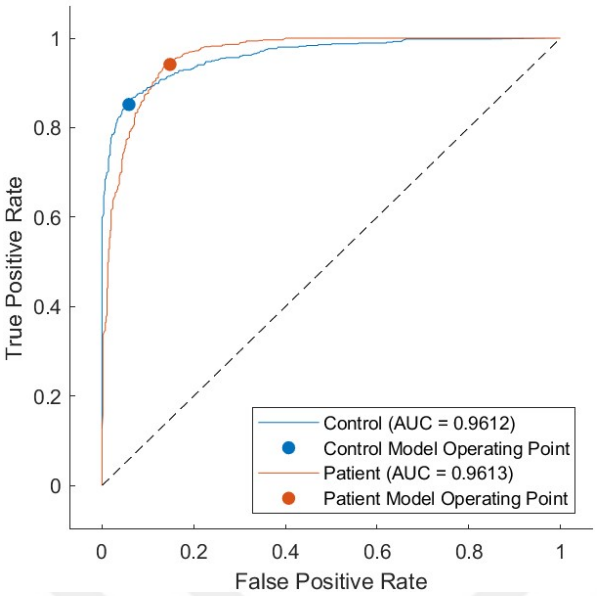
(b)


True Positive Rate
False Positive Rate
Control (AUC = 0.9745)
Control Model Operating Point
Patient (AUC = 0.9745)
Patient Model Operating Point

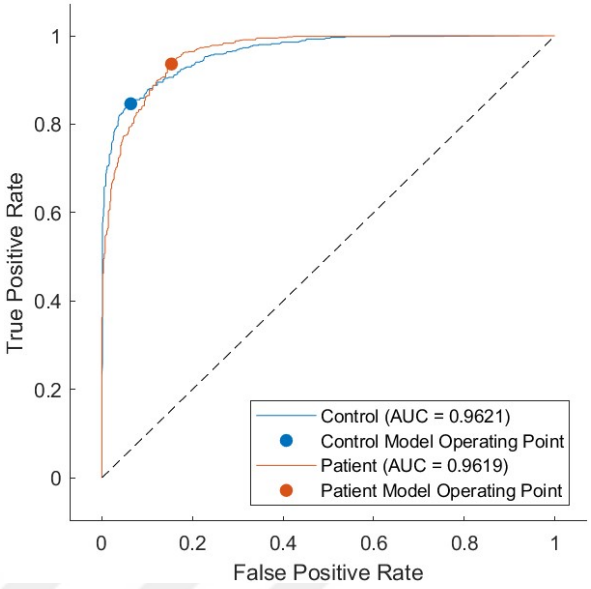
(c)


True Positive Rate
False Positive Rate
Control (AUC = 0.968)
Control Model Operating Point
Patient (AUC = 0.9681)
Patient Model Operating Point

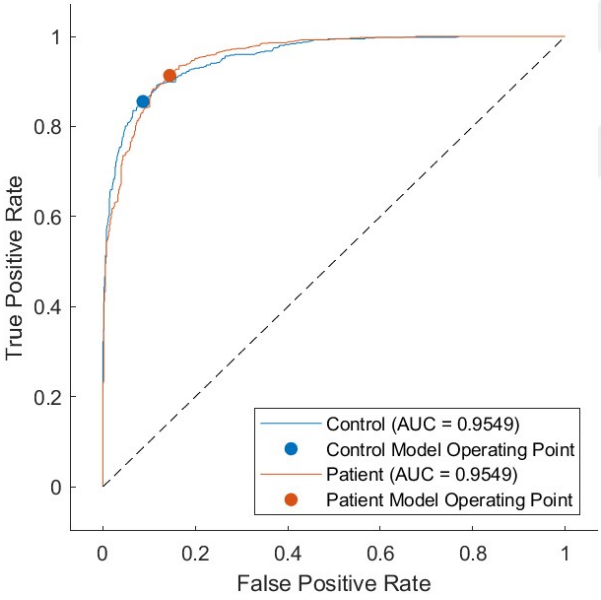
(d)


True Positive Rate
False Positive Rate
Control (AUC = 0.9612)
Control Model Operating Point
Patient (AUC = 0.9613)
Patient Model Operating Point

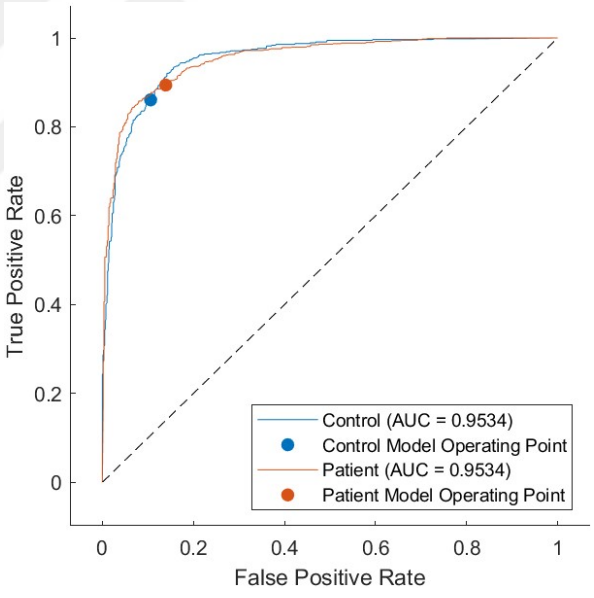
(e)


True Positive Rate
False Positive Rate
Control (AUC = 0.9621)
Control Model Operating Point
Patient (AUC = 0.9619)
Patient Model Operating Point

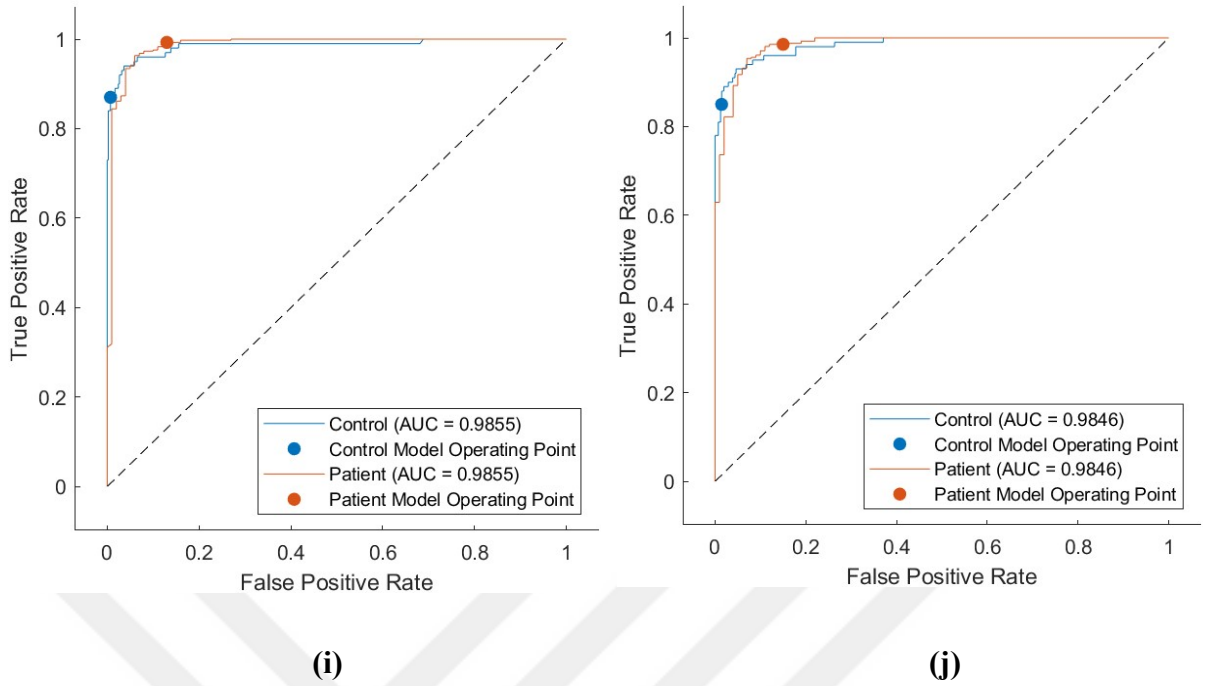
(f)


True Positive Rate
False Positive Rate
Control (AUC = 0.9549)
Control Model Operating Point
Patient (AUC = 0.9549)
Patient Model Operating Point

(g)


True Positive Rate
False Positive Rate
Control (AUC = 0.9534)
Control Model Operating Point
Patient (AUC = 0.9534)
Patient Model Operating Point

(h)



(i) **(j)**

Şekil 4.10: ResNet18 mimarisinde CWT Bump yaklaşımı için; beyin bölgeleri içinde en iyi sonuç veren kanalların Validasyon ve Test ROC eğrileri; ön beyin (anterior) bölgesi için; F4 kanalı Validasyon (a) ve Test (b) ROC eğrisi; merkez (central) beyin bölgesi için C3 kanalı Validasyon (c) ve Test (d) ROC eğrisi, sol temporal (temporal left) beyin bölgesi için T5 kanalı Validasyon (e) ve Test (f) ROC eğrisi, sağ temporal (temporal right) beyin bölgesi için T6 kanalı Validasyon (g) ve Test (h) ROC eğrisi ve arka (posterior) beyin bölgesi için P4 kanalı Validasyon (i) ve Test (j) ROC eğrisi.

4.2.2. Modifiye ResNet18_1 Mimarisinin AH/KG Sınıflandırmasına Etkisi

Bu bölümde ResNet18 mimarisinde olduğu gibi 15 AH hastasının ve 11 sağlıklı kontrol gönüllüsünün 19 farklı kanaldan kaydedilen EEG verilerinin, STFT ve CWT Amor, CWT Bump ve CWT Morse yaklaşımları kullanılarak elde edilen zaman-frekans gösterimlerinin Modifiye ResNet18_1 mimarisi ile eğitilmesi sonucu bu derin öğrenme mimarisi için AH/KG sınıflandırmasında uygulanabilecek en uygun zaman-frekans yaklaşımı tespit edilmeye çalışılmıştır. Mimaride görüntülerin %70'i eğitim setine (train), %15'i doğrulama setine (validation) ve kalan %15'i test setine ayrılarak eğitim bitiminde her kanal için; eğitim ilerlemesi (training progress) grafiği, validasyon ve test olmak üzere iki adet karmaşıklık matrisi ve iki adet ROC eğrisi elde edilmiştir. Tablo 4.21'de Modifiye ResNet18_1 mimarisi için tüm zaman-frekans yaklaşımlarının tüm beyin bölgeleri bazlı ortalama validasyon ACC ve FDR değerleri ve Şekil 4.11(a)'da bu değerlerin grafiksel gösterimleri verilmiştir. Bu sonuçlara göre; beynin posterior (arka) bölgesinden validasyon için ortalama %83,12 ACC değeriyle

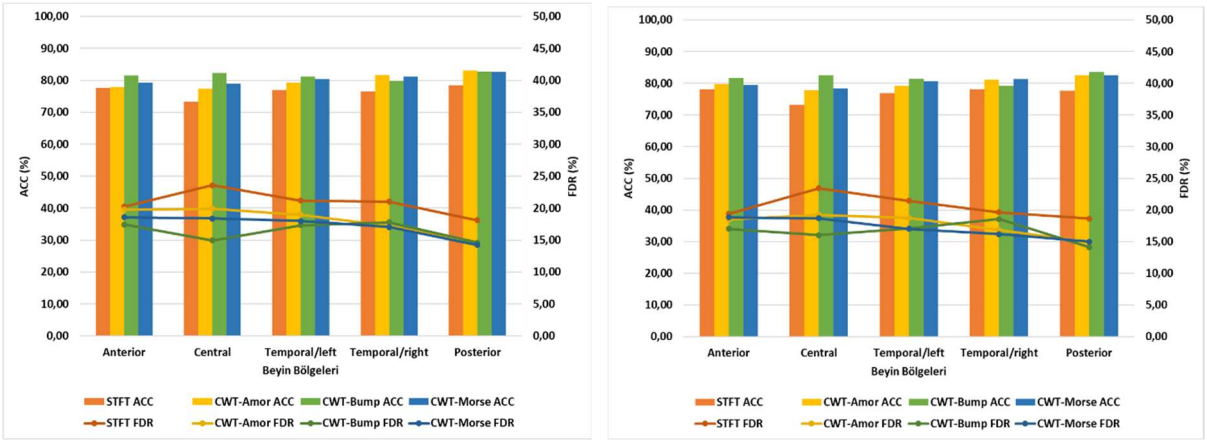
CWT-Amor, Modifiye ResNet18_1 mimarisi için AH-KG sınıflandırma doğruluğu en yüksek olan zaman-frekans yaklaşımıdır.

Tablo 4.21: Modifiye ResNet18_1 mimarisi için ZF yaklaşımlarının beyin bölgesi bazlı ortalama validasyon sonuçları.

	STFT		CWT-Amor		CWT-Bump		CWT-Morse	
	FDR	**ACC**	**FDR**	**ACC**	**FDR**	**ACC**	**FDR**	**ACC**
Anterior	20,24	77,50	19,76	77,92	17,42	81,54	18,58	79,34
Central	23,60	73,30	19,90	77,47	14,97	82,33	18,37	79,03
Temporal/left	21,17	76,93	18,97	79,23	17,33	81,13	18,00	80,40
Temporal/right	21,03	76,53	17,23	81,73	17,80	79,77	17,03	81,20
Posterior	18,12	78,28	14,54	***83,12***	14,60	82,82	14,22	82,64

Tablo 4.22: Modifiye ResNet18_1 mimarisi için ZF yaklaşımlarının beyin bölgesi bazlı ortalama test sonuçları.

	STFT		CWT-Amor		CWT-Bump		CWT-Morse	
	FDR	**ACC**	**FDR**	**ACC**	**FDR**	**ACC**	**FDR**	**ACC**
Anterior	19,40	78,20	18,48	79,70	17,00	81,70	18,84	79,48
Central	23,43	73,17	19,23	77,83	16,03	82,57	18,67	78,27
Temporal/left	21,47	76,93	18,73	79,27	17,07	81,50	17,03	80,67
Temporal/right	19,63	78,17	16,83	81,17	18,57	79,27	16,17	81,37
Posterior	18,64	77,72	14,90	82,52	14,14	***83,48***	15,00	82,54



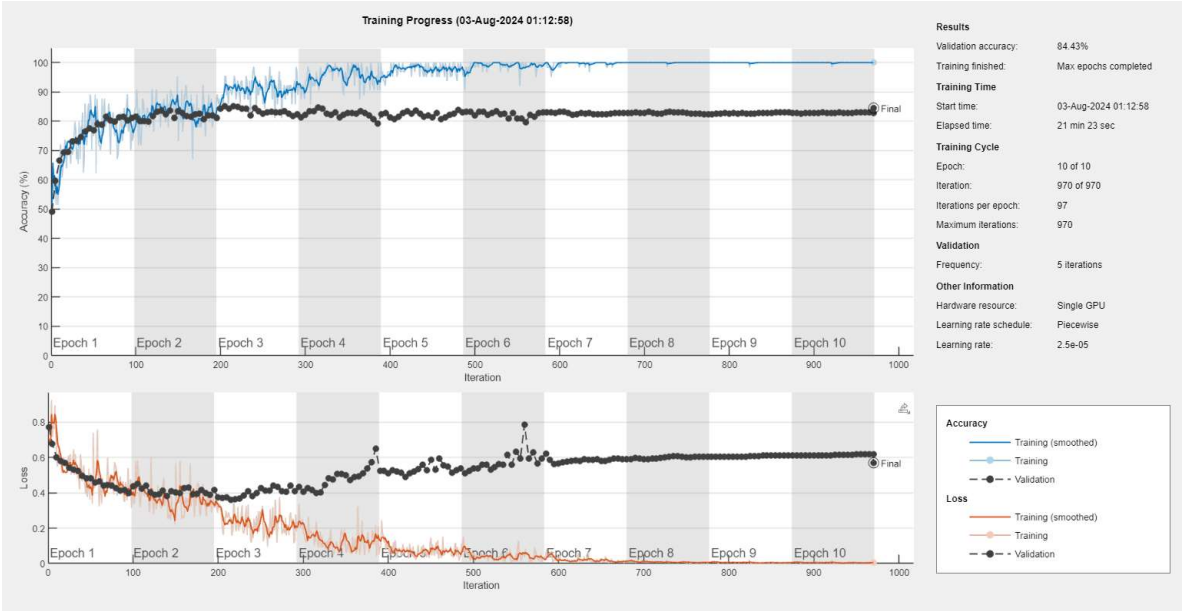
(a) **(b)**

Şekil 4.11: Beyin Bölgesi Bazlı Modifiye ResNet18_1 Validasyon (a) ve Test (b) Sonuçları

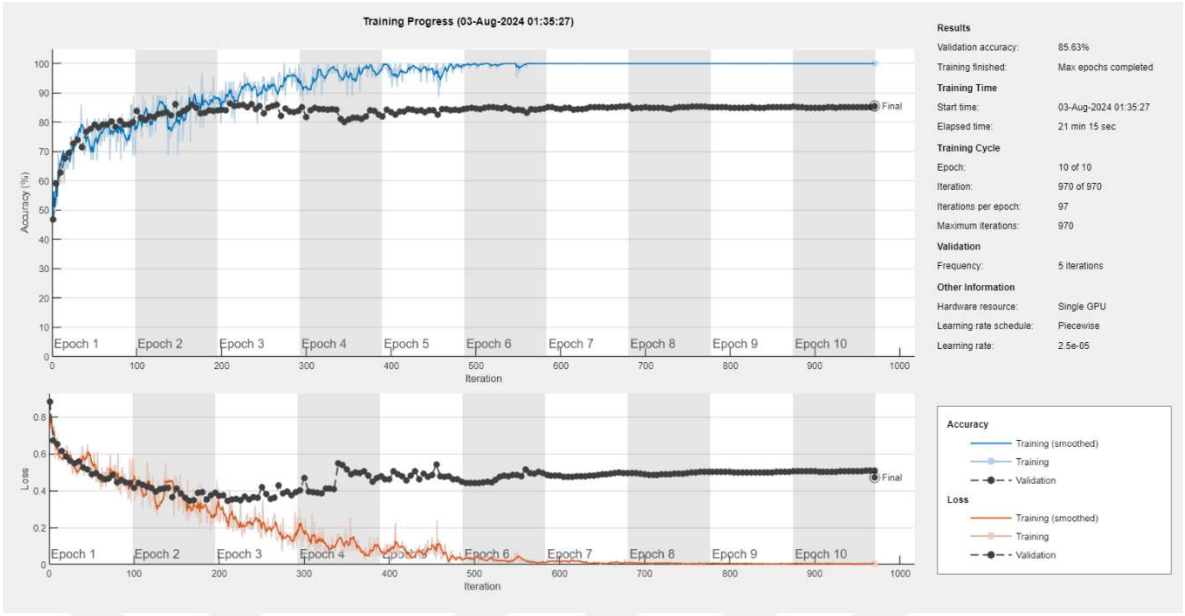
Tablo 4.22'de Modifiye ResNet18_1 mimarisi için tüm zaman-frekans yaklaşımlarının beyin bölgesi bazlı ortalama test ACC ve FDR değerleri ve Şekil 4.11(b)'de bu değerlerin grafiksel gösterimleri verilmiştir. Bu sonuçlara göre; beynin posterior (arka) bölgesinden test için %83,48 ortalama ACC değeriyle CWT-Bump, Modifiye ResNet18_1 mimarisi için AH-KG sınıflandırma doğruluğu en yüksek olan zaman-frekans yaklaşımıdır.

4.2.2.1. Modifiye ResNet18_1 Mimarisinin Beyin Bölgeleri Bazlı En İyi Sonuç Veren Kanallara Ait Eğitim İlerlemesi, Validasyon ve Test İçin Karmaşıklık Matrisi ve ROC Eğrisi Görselleri

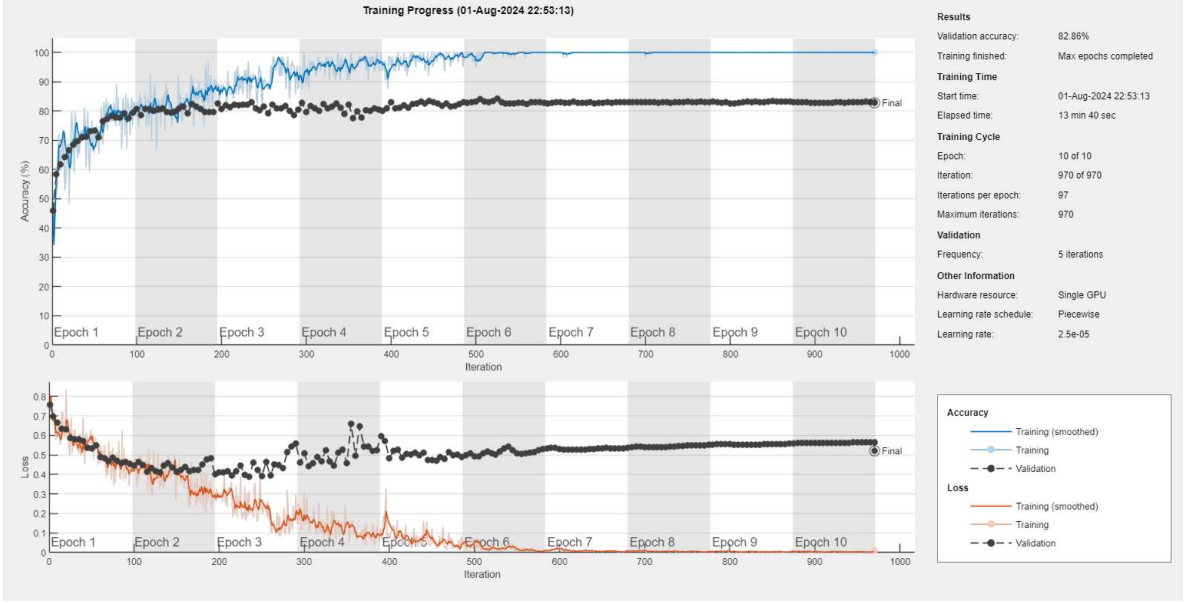
Modifiye ResNet18_1 mimarisinin zaman-frekans yaklaşımları içinde validasyon için en iyi sonuç veren kanal CWT Bump yaklaşımı ile beynin posterior bölgesinden 94,30 ACC değerine sahip P4 kanalıdır. Bu bölümde, Modifiye ResNet18_1 mimarisi için en yüksek kanal değeri CWT Bump yaklaşımıyla elde edildiği için bu yaklaşımından elde edilen ve beyin bölgeleri içinde en yüksek sonuçlara sahip kanal sonuçları verilmiştir. Beş beyin bölgesi (ön (anterior) beyin bölgesi için F4 kanalı, merkez (central) beyin bölgesi için C3 kanalı, sol temporal (temporal left) beyin bölgesi için T5 kanalı, sağ temporal (temporal right) beyin bölgesi için 9. F8 kanalı ve arka (posterior) beyin bölgesi için P4 kanalı) bazlı en iyi kanalların eğitim ilerlemesi (training progress), validasyon ve test karmaşıklık matrisi ve ROC eğrisi görselleri aşağıda detaylı şekilde bulunmaktadır (Şekil 4.12, Şekil 4.13, Şekil 4.14).



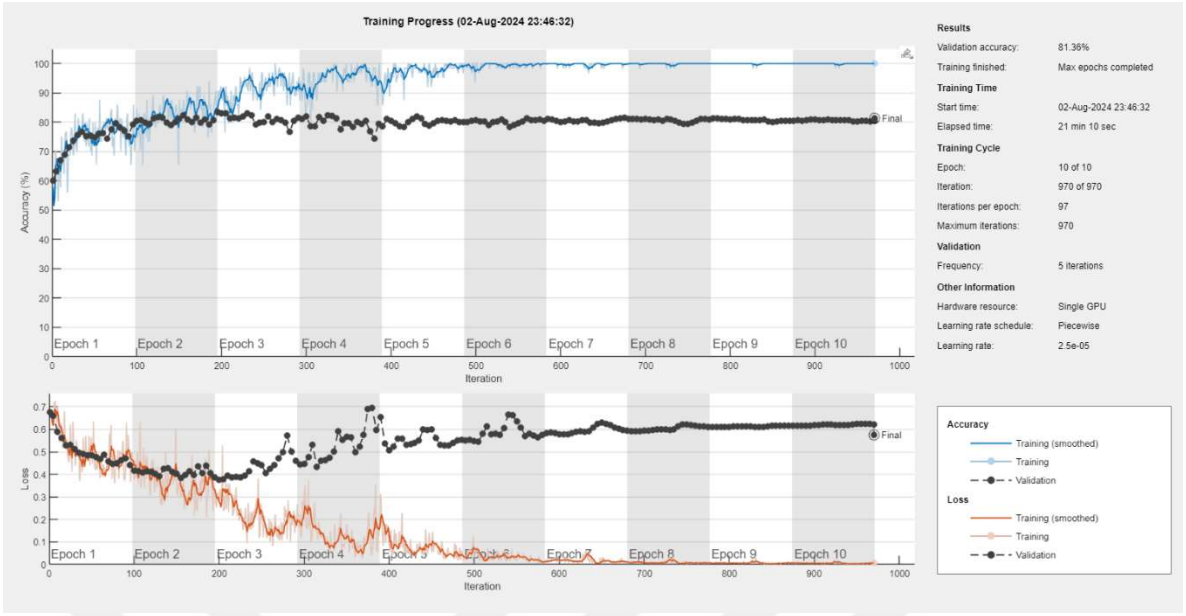
(a)


Training Progress (03-Aug-2024 01:35:27)
Accuracy (%)
Loss
Iteration
Epoch 1
Epoch 2
Epoch 3
Epoch 4
Epoch 5
Epoch 6
Epoch 7
Epoch 8
Epoch 9
Epoch 10
Final
Results
Validation accuracy: 85.63%
Training finished: Max epochs completed
Training Time
Start time: 03-Aug-2024 01:35:27
Elapsed time: 21 min 15 sec
Training Cycle
Epoch: 10 of 10
Iteration: 970 of 970
Iterations per epoch: 97
Maximum iterations: 970
Validation
Frequency: 5 iterations
Other Information
Hardware resource: Single GPU
Learning rate schedule: Piecewise
Learning rate: 2.5e-05
Accuracy
Training (smoothed)
Training
Validation
Loss
Training (smoothed)
Training
Validation

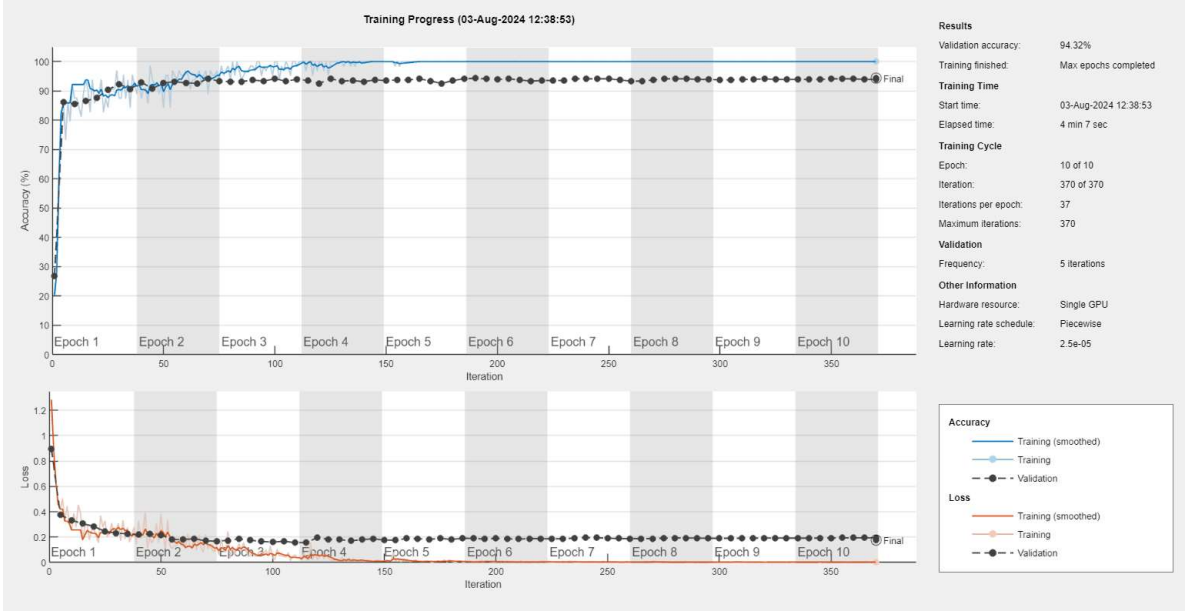
(b)


Training Progress (01-Aug-2024 22:53:13)
Accuracy (%)
Loss
Iteration
Epoch 1
Epoch 2
Epoch 3
Epoch 4
Epoch 5
Epoch 6
Epoch 7
Epoch 8
Epoch 9
Epoch 10
Final
Results
Validation accuracy: 82.86%
Training finished: Max epochs completed
Training Time
Start time: 01-Aug-2024 22:53:13
Elapsed time: 13 min 40 sec
Training Cycle
Epoch: 10 of 10
Iteration: 970 of 970
Iterations per epoch: 97
Maximum iterations: 970
Validation
Frequency: 5 iterations
Other Information
Hardware resource: Single GPU
Learning rate schedule: Piecewise
Learning rate: 2.5e-05
Accuracy
Training (smoothed)
Training
Validation
Loss
Training (smoothed)
Training
Validation

(c)



(d)

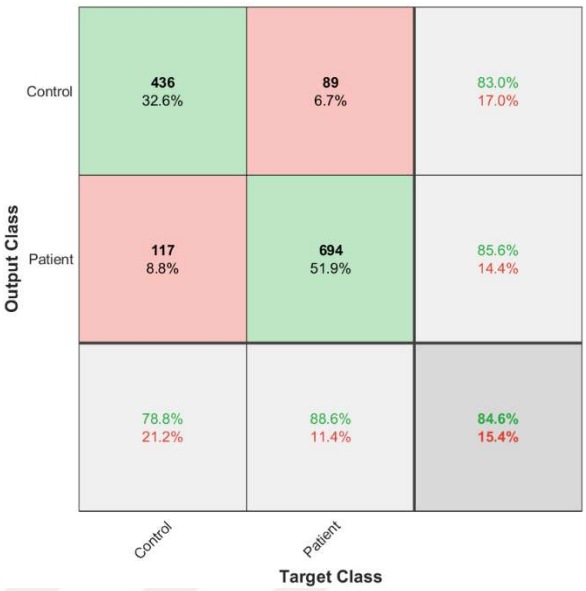


(e)

Şekil 4.12: Modifiye ResNet18_1 mimarisinde CWT Bump yaklaşımı için; beyin bölgeleri içinde en iyi sonuç veren kanalların Training Progress görselleri; ön beyin (anterior) bölgesi için; F4 kanalı (a); merkez (central) beyin bölgesi için C3 kanalı (b), sol temporal (temporal left) beyin bölgesi için T5 kanalı (c), sağ temporal (temporal right) beyin bölgesi için F8 kanalı (d) ve arka (posterior) beyin bölgesi için P4 kanalı (e).


Control
Patient
Output Class
430
32.2%
85
6.4%
83.5%
16.5%
123
9.2%
698
52.2%
85.0%
15.0%
77.8%
22.2%
89.1%
10.9%
84.4%
15.6%
Control
Patient
Target Class

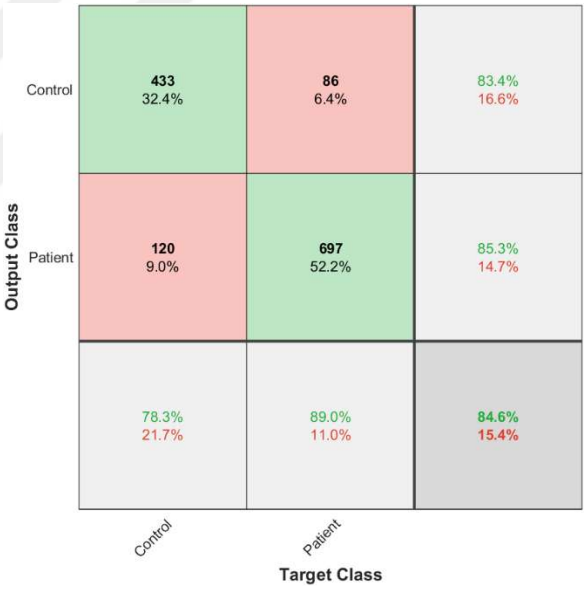
(a)


Control
Patient
Output Class
436
32.6%
89
6.7%
83.0%
17.0%
117
8.8%
694
51.9%
85.6%
14.4%
78.8%
21.2%
88.6%
11.4%
84.6%
15.4%
Control
Patient
Target Class

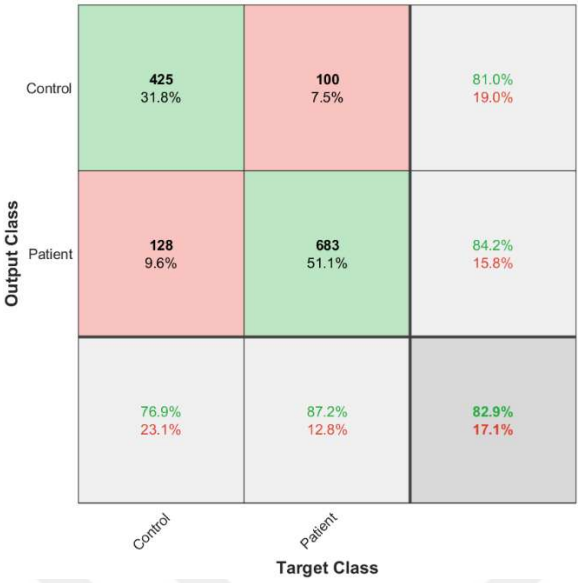
(b)


Control
Patient
Output Class
451
33.8%
91
6.8%
83.2%
16.8%
102
7.6%
692
51.8%
87.2%
12.8%
81.6%
18.4%
88.4%
11.6%
85.6%
14.4%
Control
Patient
Target Class

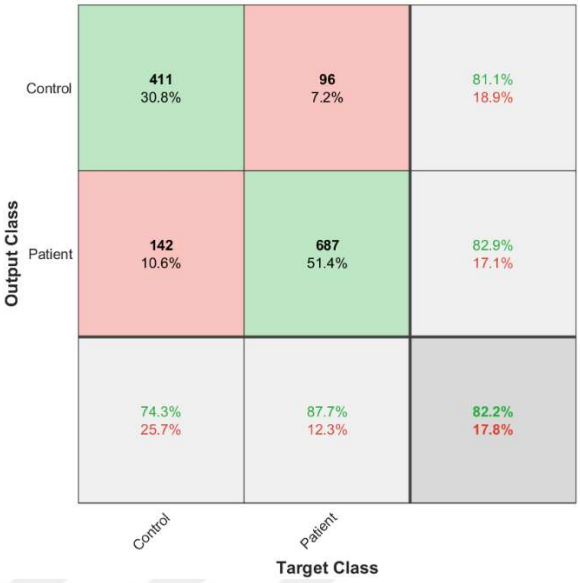
(c)


Control
Patient
Output Class
433
32.4%
86
6.4%
83.4%
16.6%
120
9.0%
697
52.2%
85.3%
14.7%
78.3%
21.7%
89.0%
11.0%
84.6%
15.4%
Control
Patient
Target Class

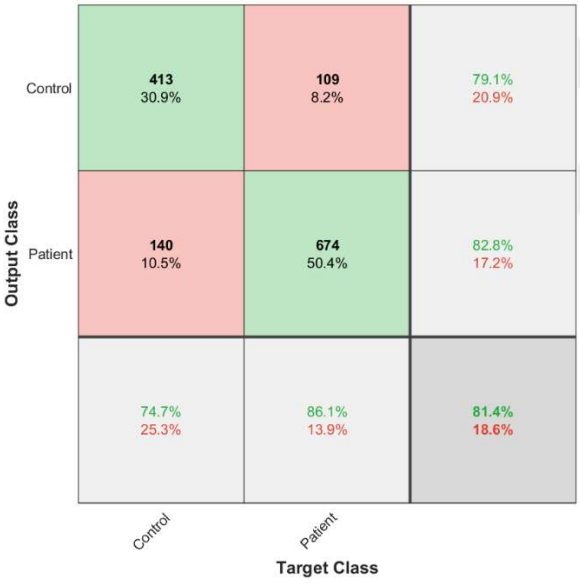
(d)


Control
Patient
Output Class
425
31.8%
100
7.5%
81.0%
19.0%
128
9.6%
683
51.1%
84.2%
15.8%
76.9%
23.1%
87.2%
12.8%
82.9%
17.1%
Control
Patient
Target Class

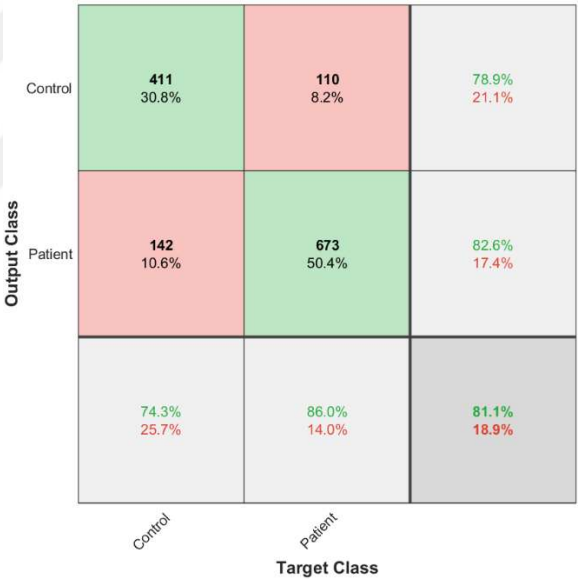
(e)


Control
Patient
Output Class
411
30.8%
96
7.2%
81.1%
18.9%
142
10.6%
687
51.4%
82.9%
17.1%
74.3%
25.7%
87.7%
12.3%
82.2%
17.8%
Control
Patient
Target Class

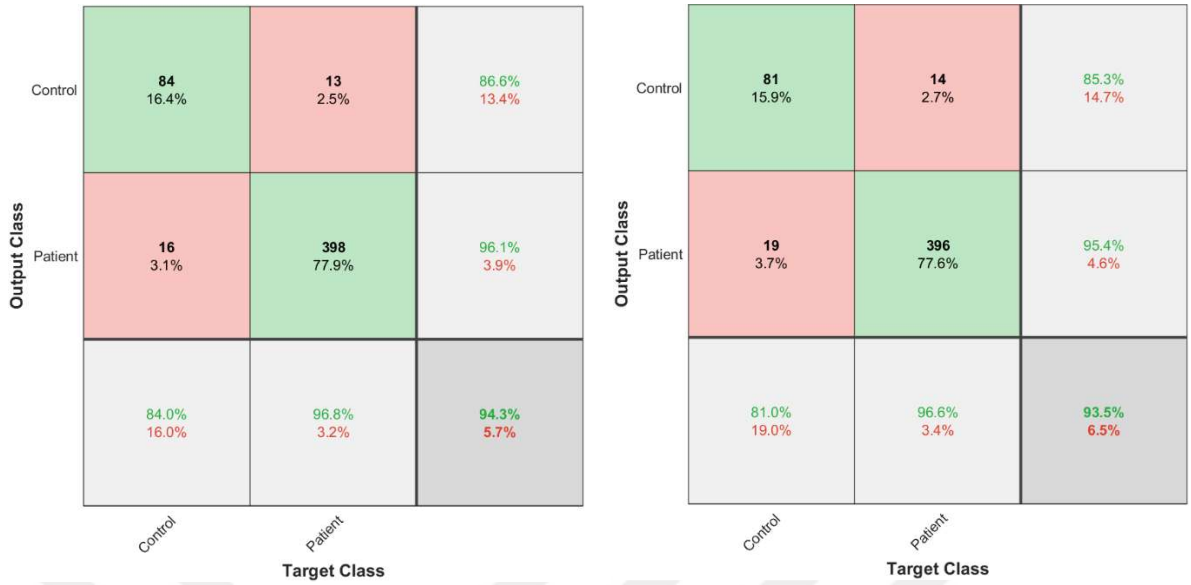
(f)


Control
Patient
Output Class
413
30.9%
109
8.2%
79.1%
20.9%
140
10.5%
674
50.4%
82.8%
17.2%
74.7%
25.3%
86.1%
13.9%
81.4%
18.6%
Control
Patient
Target Class

(g)

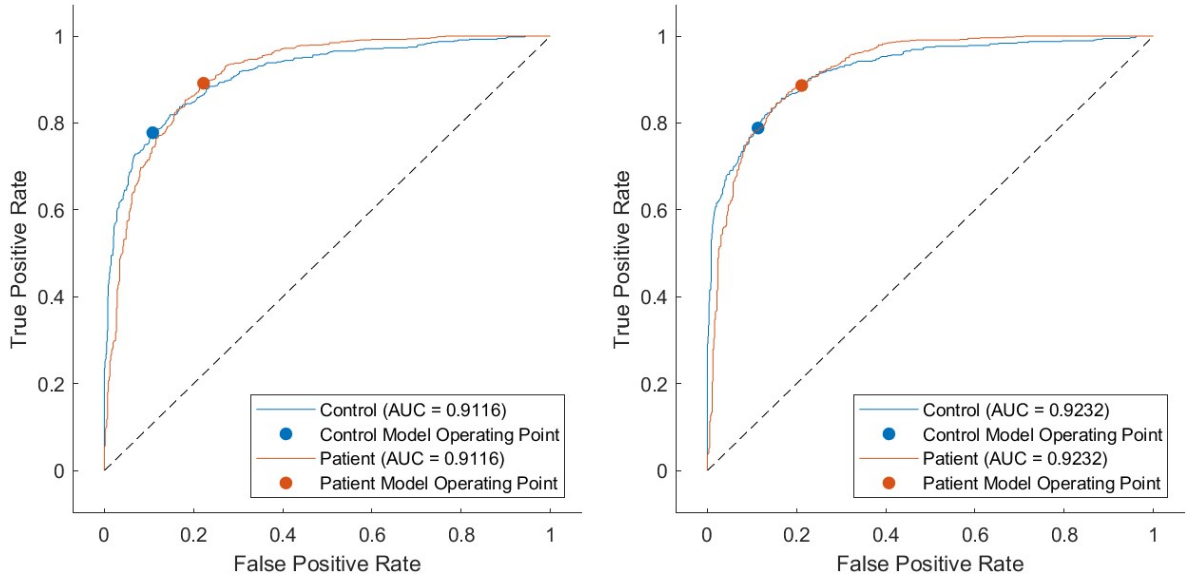

Control
Patient
Output Class
411
30.8%
110
8.2%
78.9%
21.1%
142
10.6%
673
50.4%
82.6%
17.4%
74.3%
25.7%
86.0%
14.0%
81.1%
18.9%
Control
Patient
Target Class

(h)

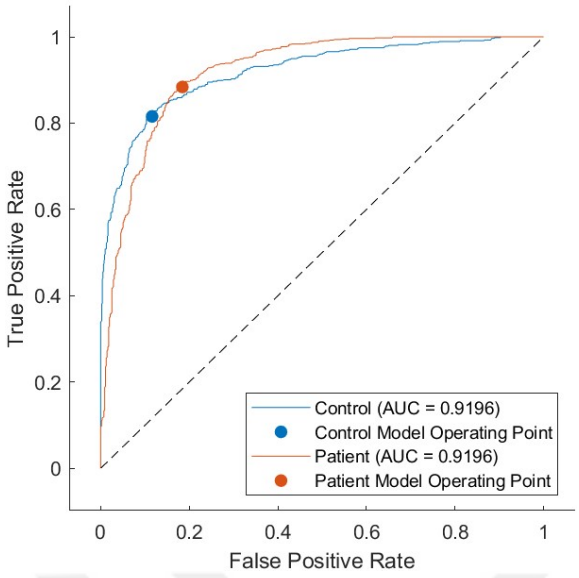


(i) **(j)**

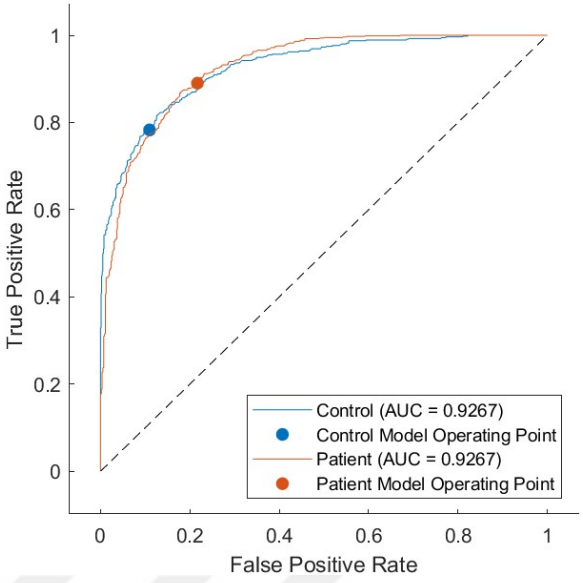
Şekil 4.13: Modifiye ResNet18_1 mimarisinde CWT Bump yaklaşımı için; beyin bölgeleri içinde en iyi sonuç veren kanalların Validasyon ve Test karmaşıklık matrisleri; ön beyin (anterior) bölgesi için; F4 kanalı Validasyon (a) ve Test (b) matrisi; merkez (central) beyin bölgesi için C3 kanalı Validasyon (c) ve Test (d) matrisi, sol temporal (temporal left) beyin bölgesi için T5 kanalı Validasyon (e) ve Test (f) matrisi, sağ temporal (temporal right) beyin bölgesi için F8 kanalı Validasyon (g) ve Test (h) matrisi ve arka (posterior) beyin bölgesi için P4 kanalı Validasyon (i) ve Test (j) matrisi.



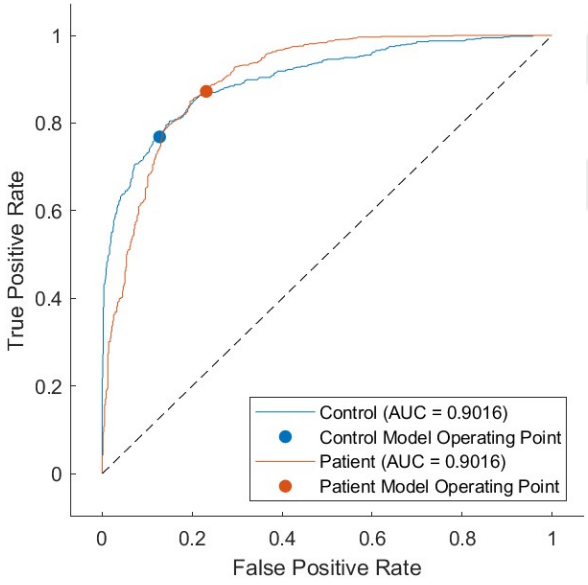
(a) **(b)**


True Positive Rate
False Positive Rate
Control (AUC = 0.9196)
Control Model Operating Point
Patient (AUC = 0.9196)
Patient Model Operating Point

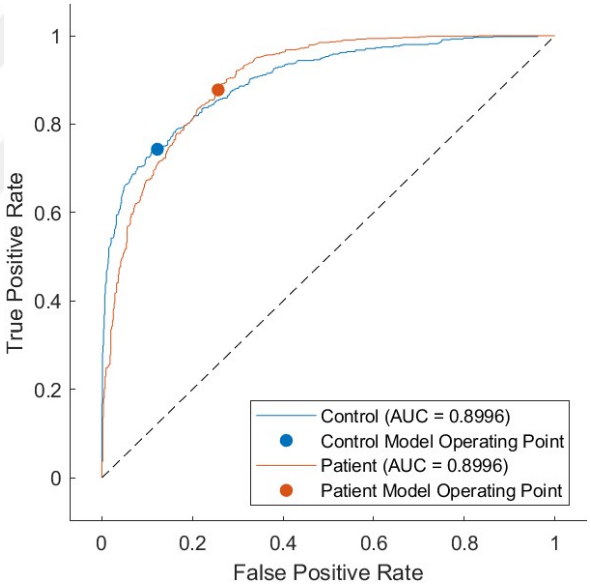
(c)


True Positive Rate
False Positive Rate
Control (AUC = 0.9267)
Control Model Operating Point
Patient (AUC = 0.9267)
Patient Model Operating Point

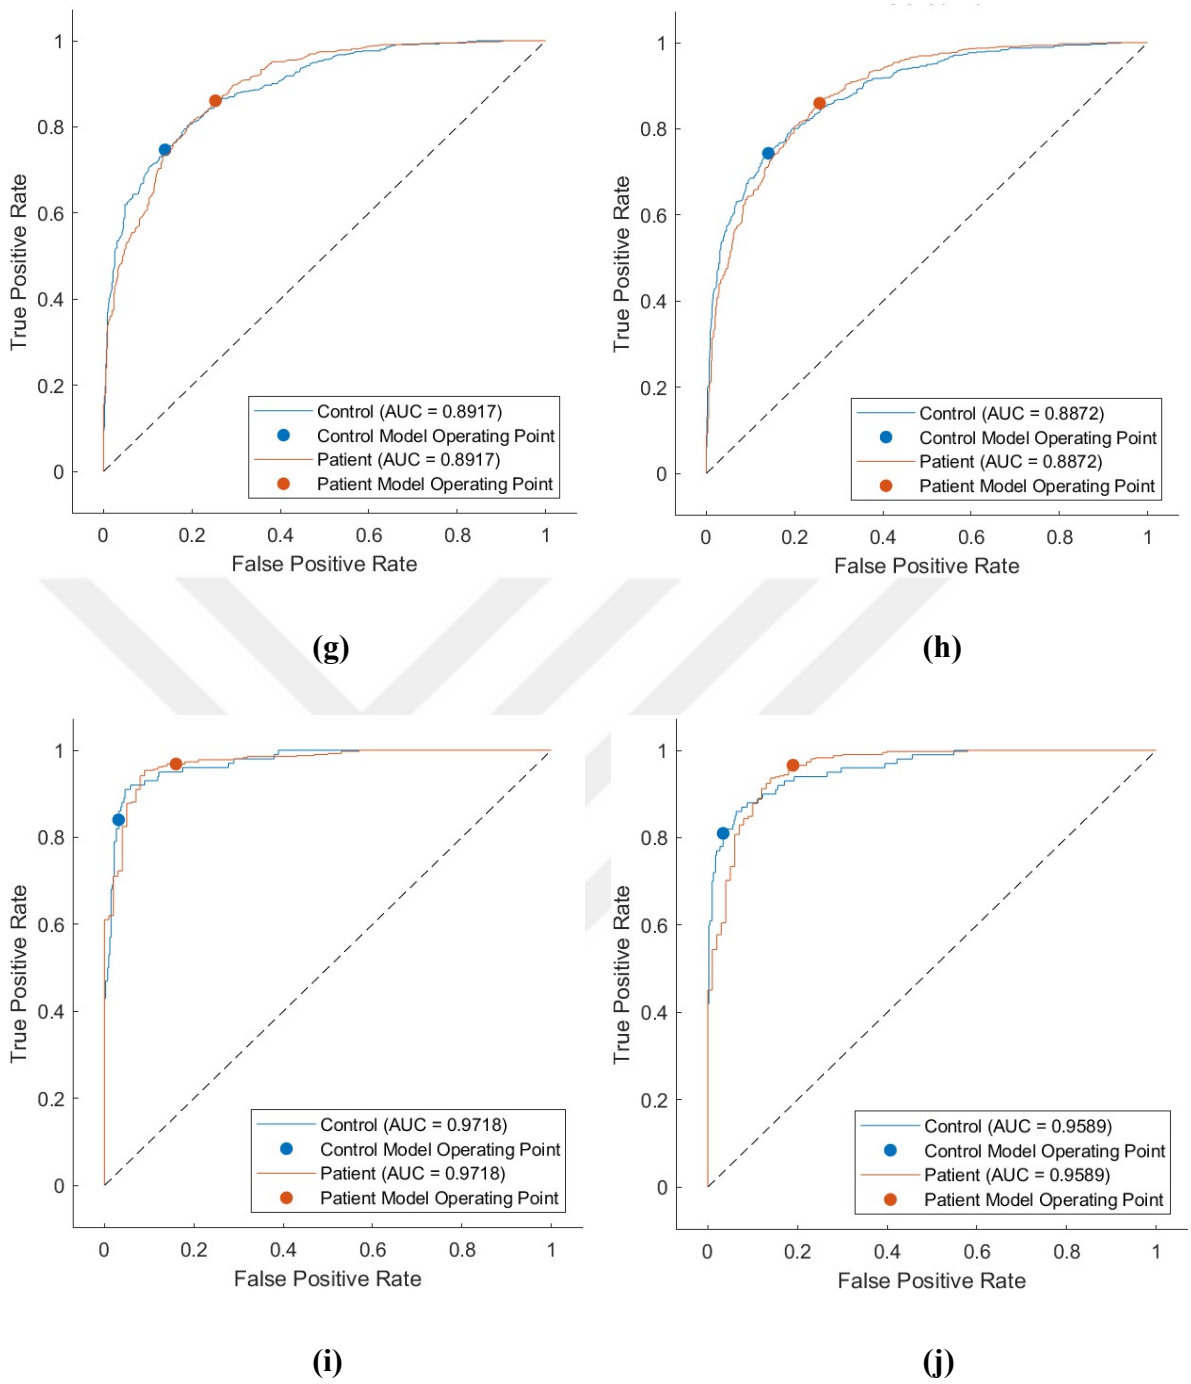
(d)


True Positive Rate
False Positive Rate
Control (AUC = 0.9016)
Control Model Operating Point
Patient (AUC = 0.9016)
Patient Model Operating Point

(e)


True Positive Rate
False Positive Rate
Control (AUC = 0.8996)
Control Model Operating Point
Patient (AUC = 0.8996)
Patient Model Operating Point

(f)



Şekil 4.14: Modifiye ResNet18_1 mimarisinde CWT Bump yaklaşımı için; beyin bölgeleri içinde en iyi sonuç veren kanalların Validasyon ve Test ROC eğrileri; ön beyin (anterior) bölgesi için; F4 kanalı Validasyon (a) ve Test (b) ROC eğrisi; merkez (central) beyin bölgesi için C3 kanalı Validasyon (c) ve Test (d) ROC eğrisi, sol temporal (temporal left) beyin bölgesi için T5 kanalı Validasyon (e) ve Test (f) ROC eğrisi, sağ temporal (temporal right) beyin bölgesi için F8 kanalı Validasyon (g) ve Test (h) ROC eğrisi ve arka (posterior) beyin bölgesi için P4 kanalı Validasyon (i) ve Test (j) ROC eğrisi.

4.2.3. Modifiye ResNet18_2 Mimarisinin AH/KG Sınıflandırmasına Etkisi

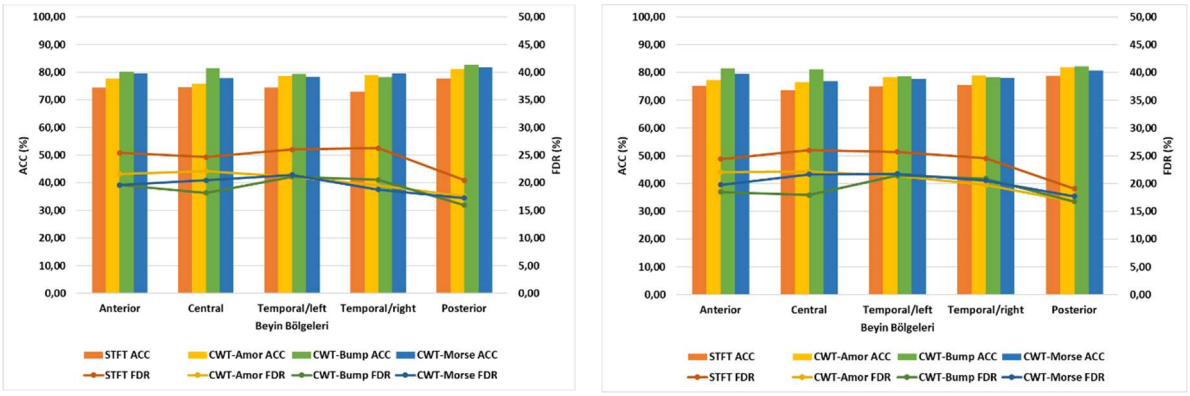
Bu bölümde diğer iki mimaride olduğu gibi 15 AH hastasının ve 11 sağlıklı kontrol gönüllüsünün 19 farklı kanaldan kaydedilen EEG verilerinin, STFT ve CWT Amor, CWT Bump ve CWT Morse yaklaşımları kullanılarak elde edilen zaman-frekans gösterimlerinin Modifiye ResNet18_2 mimarisi ile eğitilmesi sonucu bu derin öğrenme mimarisi için AH/KG sınıflandırmasında uygulanabilecek en uygun zaman-frekans yaklaşımı tespit edilmeye çalışılmıştır. Mimaride görüntülerin %70'i eğitim setine (train), %15'i doğrulama setine (validation) ve kalan %15'i test setine ayrılarak eğitim bitiminde her kanal için; eğitim ilerlemesi (training progress) grafiği, validasyon ve test olmak üzere iki adet karmaşıklık matrisi ve iki adet ROC eğrisi elde edilmiştir. Tablo 4.23'te Modifiye ResNet18_2 mimarisi için tüm zaman-frekans yaklaşımlarının tüm beyin bölgeleri bazlı ortalama validasyon ACC ve FDR değerleri ve Şekil 4.15(a)'da bu değerlerin grafiksel gösterimleri verilmiştir. Bu sonuçlara göre; beynin posterior (arka) bölgesinden validasyon için ortalama %82,74 ACC değeriyle CWT-Bump, Modifiye ResNet18_2 mimarisi için AH-KG sınıflandırma doğruluğu en yüksek olan zaman-frekans yaklaşımıdır.

Tablo 4.23: Modifiye ResNet18_2 mimarisi için ZF yaklaşımlarının beyin bölgesi bazlı ortalama validasyon sonuçları.

	STFT		CWT-Amor		CWT-Bump		CWT-Morse	
	FDR	**ACC**	**FDR**	**ACC**	**FDR**	**ACC**	**FDR**	**ACC**
Anterior	25,40	74,36	21,60	77,74	19,58	80,24	19,58	79,52
Central	24,63	74,63	22,13	75,80	18,20	81,43	20,43	77,87
Temporal/left	26,00	74,50	21,03	78,67	21,10	79,47	21,43	78,37
Temporal/right	26,27	72,93	19,50	78,87	20,53	78,20	18,80	79,60
Posterior	20,44	77,78	17,52	81,10	15,94	***82,74***	17,24	81,84

Tablo 4.24: Modifiye ResNet18_2 mimarisi için ZF yaklaşımlarının beyin bölgesi bazlı ortalama test sonuçları.

	STFT		CWT-Amor		CWT-Bump		CWT-Morse	
	FDR	**ACC**	**FDR**	**ACC**	**FDR**	**ACC**	**FDR**	**ACC**
Anterior	24,44	75,24	22,06	77,28	18,48	81,54	19,78	79,40
Central	26,03	73,63	22,17	76,50	17,93	81,27	21,67	76,83
Temporal/left	25,73	75,03	21,40	78,33	21,47	78,57	21,77	77,80
Temporal/right	24,53	75,47	19,73	78,97	20,90	78,30	20,57	78,10
Posterior	19,10	78,72	16,76	81,88	16,78	***82,16***	17,72	80,64



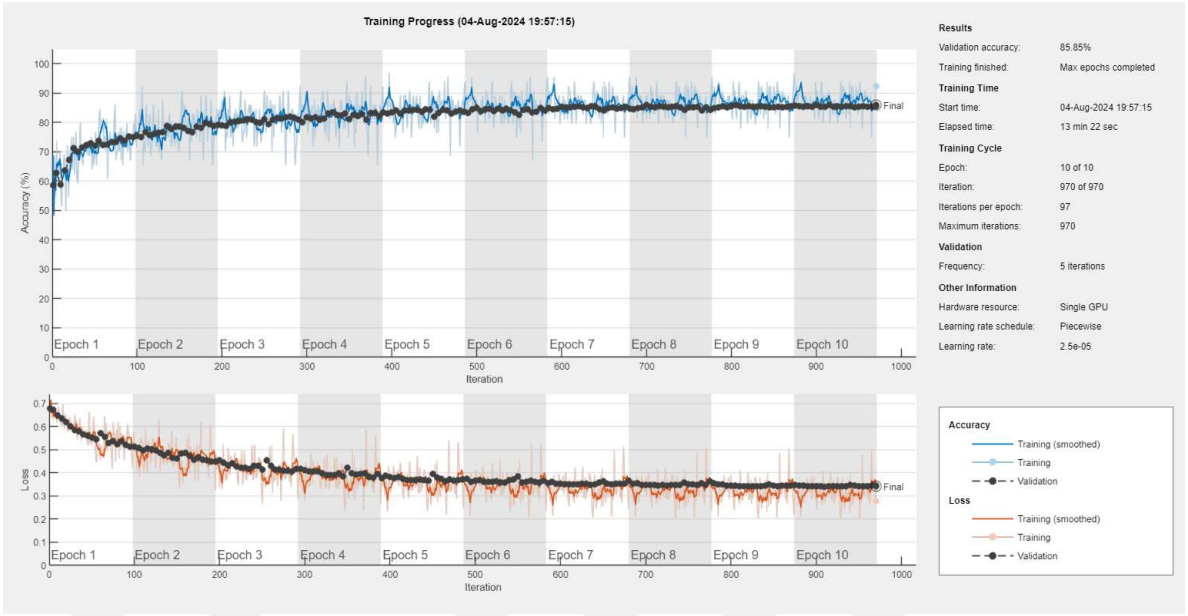
(a) **(b)**

Şekil 4.15: Beyin Bölgesi Bazlı Modifiye ResNet18_2 Validasyon (a) ve Test (b) Sonuçları

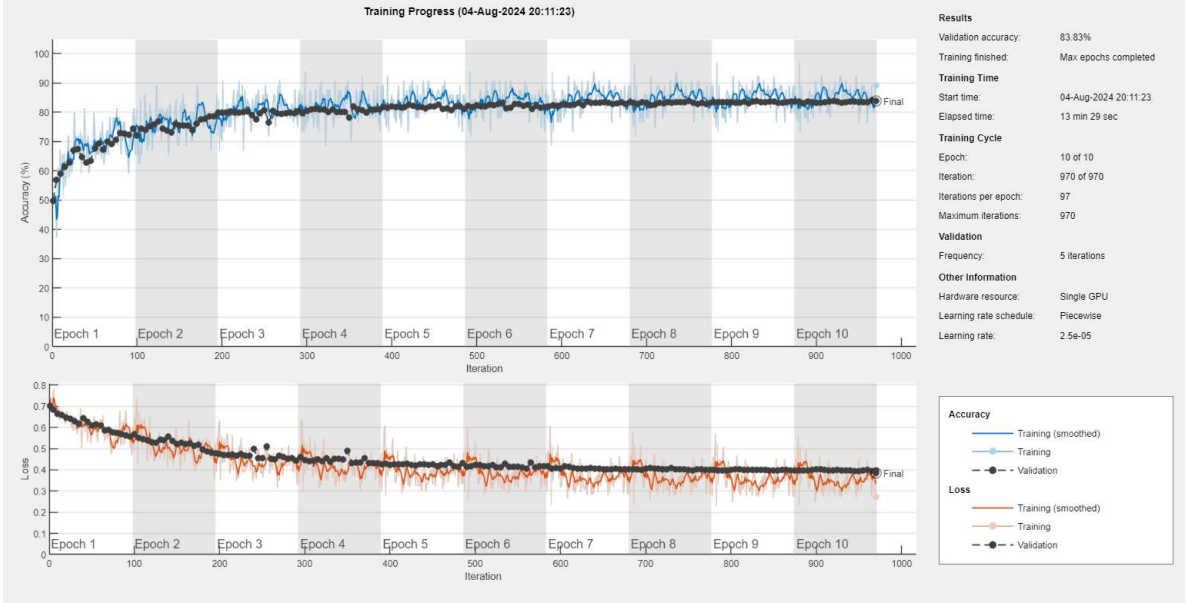
Tablo 4.24'te Modifiye ResNet18_2 mimarisi için tüm zaman-frekans yaklaşımlarının beyin bölgesi bazlı ortalama test ACC ve FDR değerleri ve Şekil 4.15(b)'de bu değerlerin grafiksel gösterimleri verilmiştir. Bu sonuçlara göre; beynin posterior (arka) bölgesinden test için %82,16 ortalama ACC değeriyle CWT-Bump, Modifiye ResNet18_2 mimarisi için AH-KG sınıflandırma doğruluğu en yüksek olan zaman-frekans yaklaşımıdır.

4.2.3.1. Modifiye ResNet18_2 Mimarisinin Beyin Bölgeleri Bazlı En İyi Sonuç Veren Kanallara Ait Eğitim İlerlemesi, Validasyon ve Test İçin Karmaşıklık Matrisi ve ROC Eğrisi Görselleri

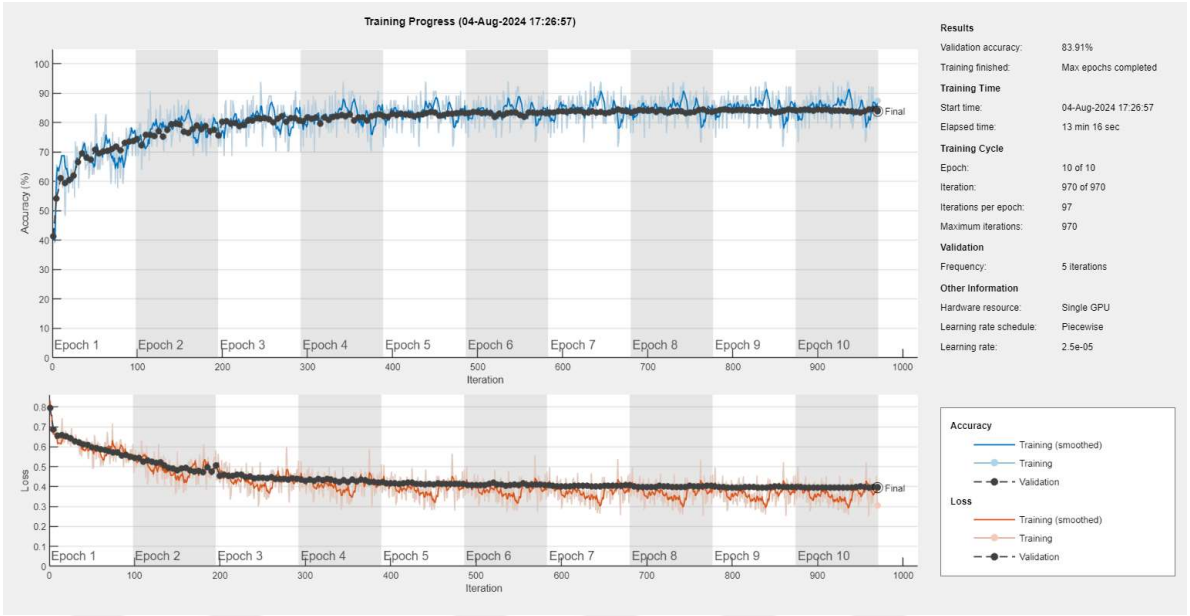
Modifiye ResNet18_2 mimarisinin zaman-frekans yaklaşımları içinde validasyon için en iyi sonuç veren kanal CWT Bump yaklaşımı ile beynin posterior bölgesinden %93,70 ACC değerine sahip P4 kanalıdır. Bu bölümde, Modifiye ResNet18_2 mimarisi için en yüksek kanal değeri CWT Bump yaklaşımıyla elde edildiğinden bu yaklaşımından elde edilen ve beyin bölgeleri içinde en yüksek değerlere sahip kanal sonuçları yer almaktadır. Beş beyin bölgesi (ön (anterior) beyin bölgesi için F4 kanalı, merkez (central) beyin bölgesi için C3 kanalı, sol temporal (temporal left) beyin bölgesi için T5 kanalı, sağ temporal (temporal right) beyin bölgesi için T6 kanalı ve arka (posterior) beyin bölgesi için P4 kanalı) bazlı en iyi sonuçlara sahip kanalların eğitim ilerlemesi (training progress), validasyon ve test karmaşıklık matrisi ve ROC eğrisi görselleri aşağıda detaylı şekilde bulunmaktadır (Şekil 4.16, Şekil 4.17, Şekil 4.18).


Training Progress (04-Aug-2024 19:57:15)
Accuracy (%)
Loss
Iteration
Epoch 1
Epoch 2
Epoch 3
Epoch 4
Epoch 5
Epoch 6
Epoch 7
Epoch 8
Epoch 9
Epoch 10
Final
Results
Validation accuracy: 85.85%
Training finished: Max epochs completed
Training Time
Start time: 04-Aug-2024 19:57:15
Elapsed time: 13 min 22 sec
Training Cycle
Epoch: 10 of 10
Iteration: 970 of 970
Iterations per epoch: 97
Maximum iterations: 970
Validation
Frequency: 5 iterations
Other Information
Hardware resource: Single GPU
Learning rate schedule: Piecewise
Learning rate: 2.5e-05
Accuracy
Training (smoothed)
Training
Validation
Loss
Training (smoothed)
Training
Validation

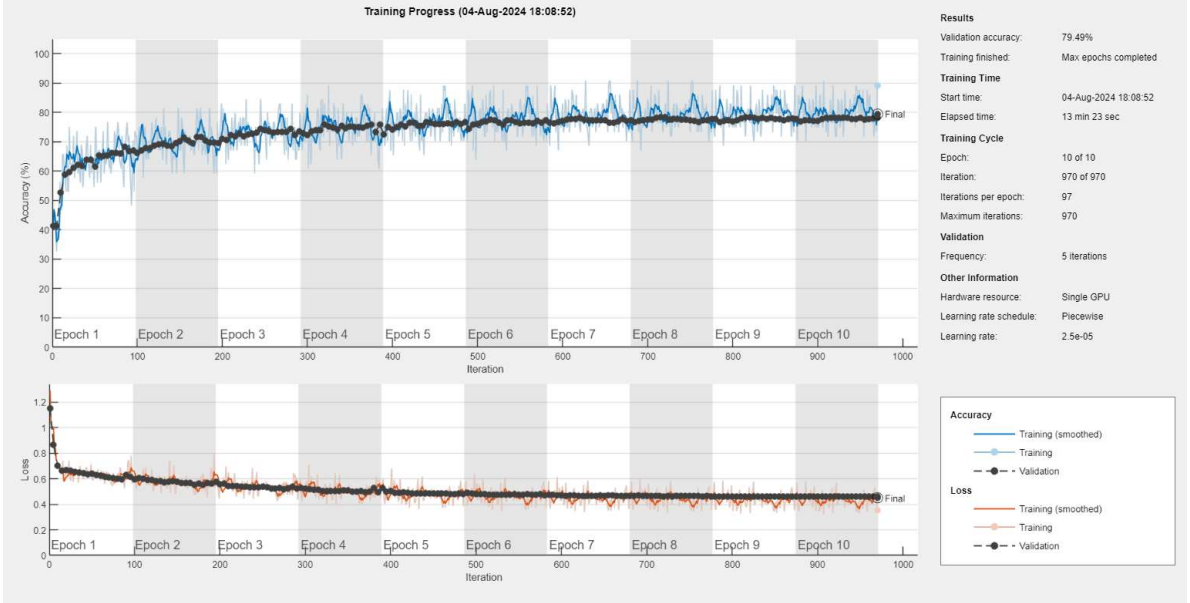
(a)


Training Progress (04-Aug-2024 20:11:23)
Accuracy (%)
Loss
Iteration
Epoch 1
Epoch 2
Epoch 3
Epoch 4
Epoch 5
Epoch 6
Epoch 7
Epoch 8
Epoch 9
Epoch 10
Final
Results
Validation accuracy: 83.83%
Training finished: Max epochs completed
Training Time
Start time: 04-Aug-2024 20:11:23
Elapsed time: 13 min 29 sec
Training Cycle
Epoch: 10 of 10
Iteration: 970 of 970
Iterations per epoch: 97
Maximum iterations: 970
Validation
Frequency: 5 iterations
Other Information
Hardware resource: Single GPU
Learning rate schedule: Piecewise
Learning rate: 2.5e-05
Accuracy
Training (smoothed)
Training
Validation
Loss
Training (smoothed)
Training
Validation

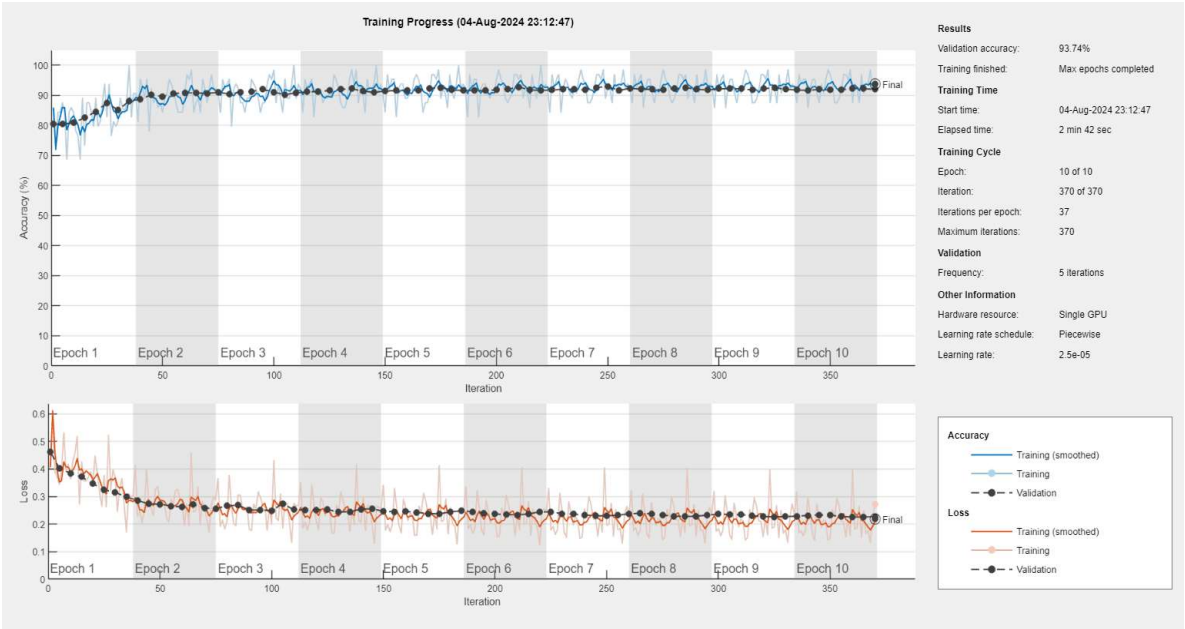
(b)


Training Progress (04-Aug-2024 17:26:57)
Accuracy (%)
Loss
Iteration
Epoch 1
Epoch 2
Epoch 3
Epoch 4
Epoch 5
Epoch 6
Epoch 7
Epoch 8
Epoch 9
Epoch 10
Final
Results
Validation accuracy: 83.91%
Training finished: Max epochs completed
Training Time
Start time: 04-Aug-2024 17:26:57
Elapsed time: 13 min 16 sec
Training Cycle
Epoch: 10 of 10
Iteration: 970 of 970
Iterations per epoch: 97
Maximum iterations: 970
Validation
Frequency: 5 iterations
Other Information
Hardware resource: Single GPU
Learning rate schedule: Piecewise
Learning rate: 2.5e-05
Accuracy
Training (smoothed)
Training
Validation
Loss
Training (smoothed)
Training
Validation

(c)

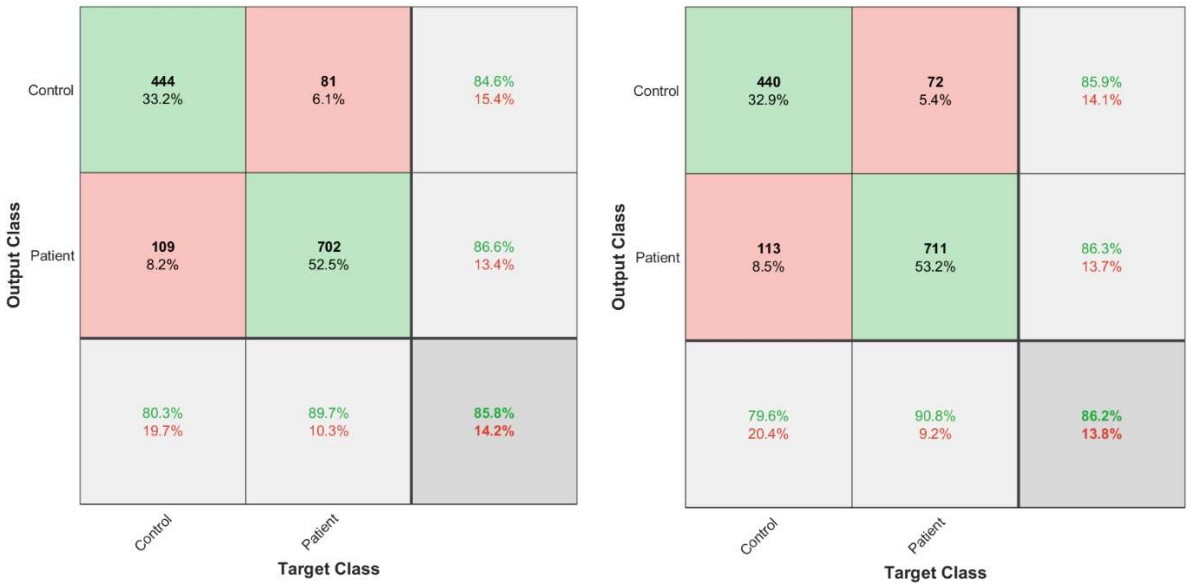

Training Progress (04-Aug-2024 18:08:52)
Accuracy (%)
Loss
Iteration
Epoch 1
Epoch 2
Epoch 3
Epoch 4
Epoch 5
Epoch 6
Epoch 7
Epoch 8
Epoch 9
Epoch 10
Final
Results
Validation accuracy: 79.49%
Training finished: Max epochs completed
Training Time
Start time: 04-Aug-2024 18:08:52
Elapsed time: 13 min 23 sec
Training Cycle
Epoch: 10 of 10
Iteration: 970 of 970
Iterations per epoch: 97
Maximum iterations: 970
Validation
Frequency: 5 iterations
Other Information
Hardware resource: Single GPU
Learning rate schedule: Piecewise
Learning rate: 2.5e-05
Accuracy
Training (smoothed)
Training
Validation
Loss
Training (smoothed)
Training
Validation

(d)



(e)

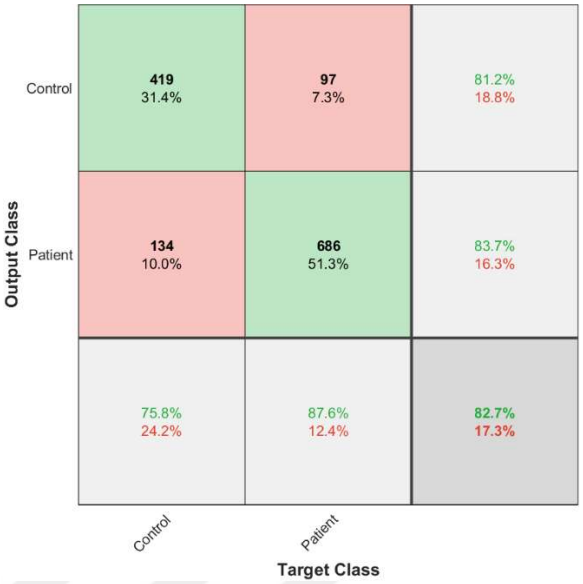
Şekil 4.16: Modifiye ResNet18_2 mimarisinde CWT Bump yaklaşımı için; beyin bölgeleri içinde en iyi sonuç veren kanalların Training Progress görselleri; ön beyin (anterior) bölgesi için; F4 kanalı (a); merkez (central) beyin bölgesi için; C3 kanalı (b), sol temporal (temporal left) beyin bölgesi için; T5 kanalı (c), sağ temporal (temporal right) beyin bölgesi için; T6 kanalı (d) ve arka (posterior) beyin bölgesi için; P4 kanalı (e).



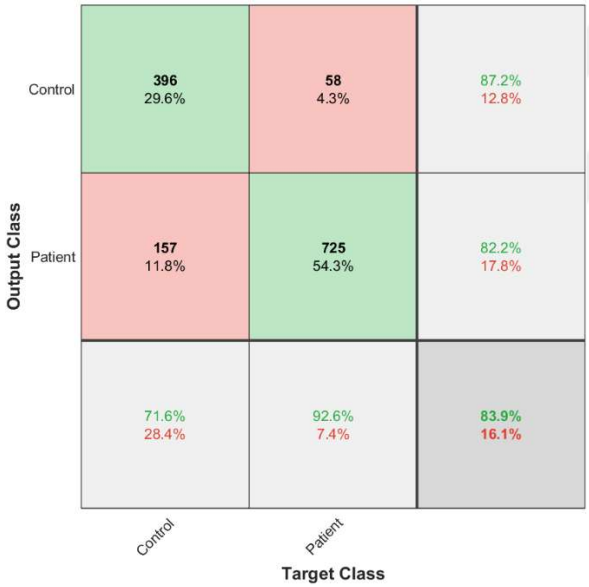
(a) **(b)**


Control
Patient
Output Class
425
31.8%
89
6.7%
82.7%
17.3%
128
9.6%
694
51.9%
84.4%
15.6%
76.9%
23.1%
88.6%
11.4%
83.8%
16.2%
Control
Patient
Target Class

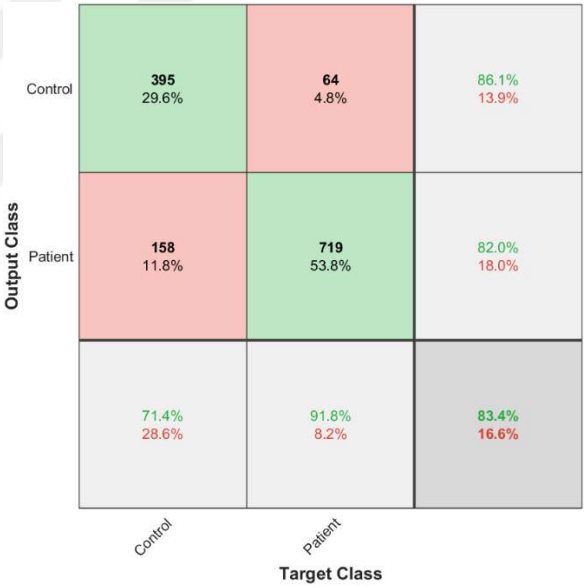
(c)


Control
Patient
Output Class
419
31.4%
97
7.3%
81.2%
18.8%
134
10.0%
686
51.3%
83.7%
16.3%
75.8%
24.2%
87.6%
12.4%
82.7%
17.3%
Control
Patient
Target Class

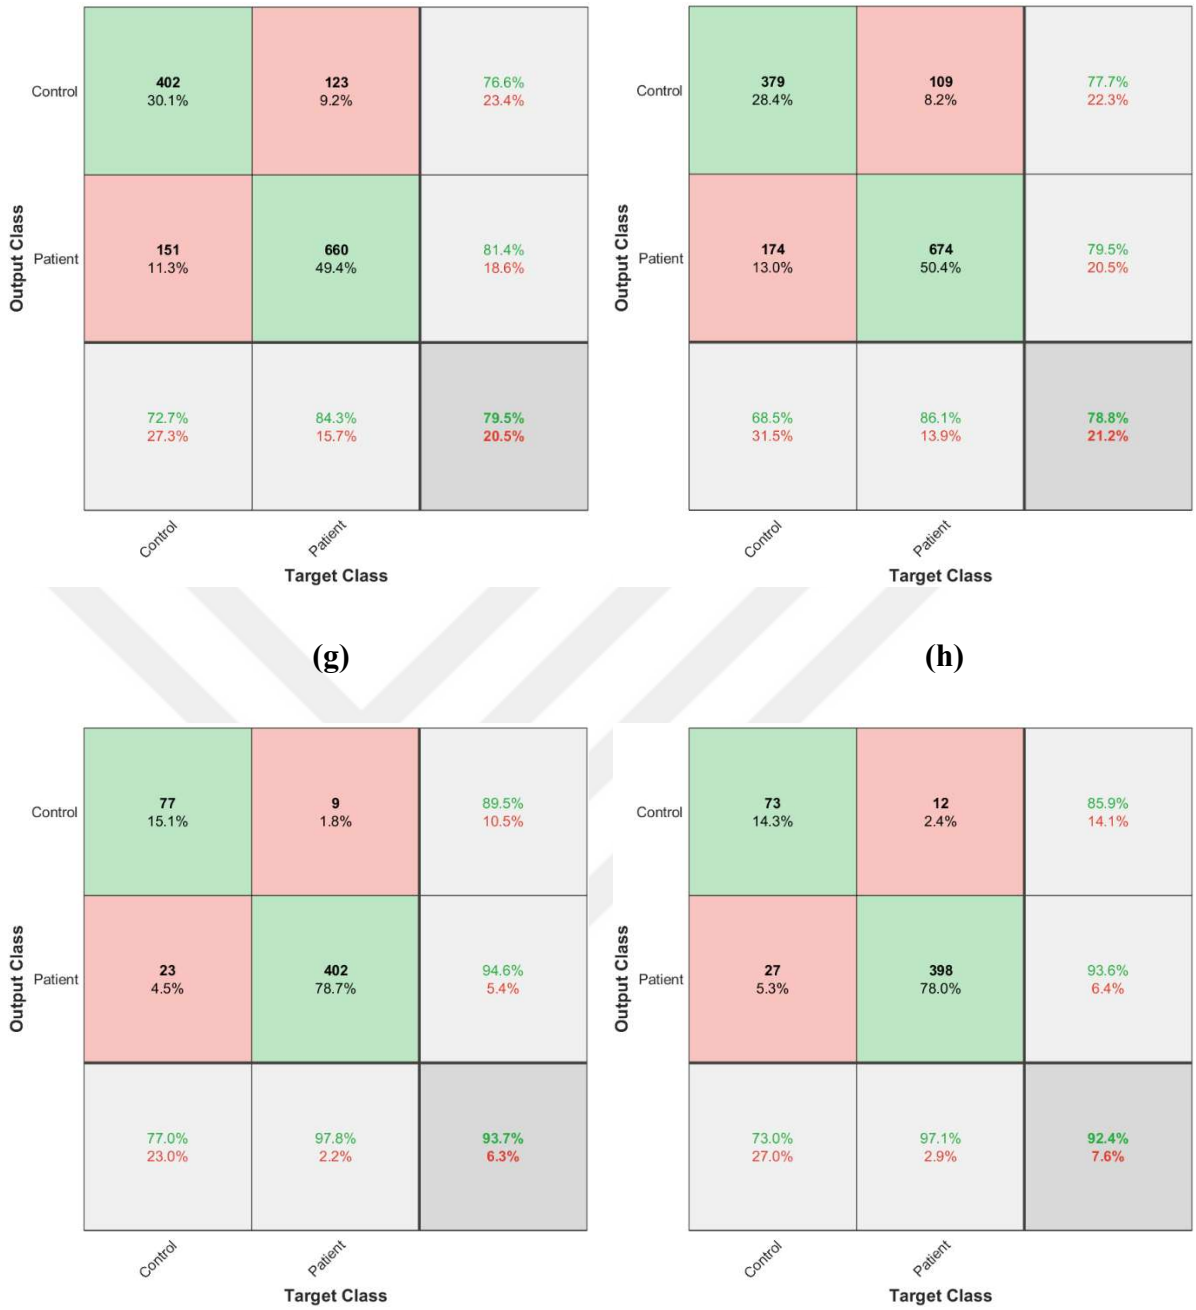
(d)


Control
Patient
Output Class
396
29.6%
58
4.3%
87.2%
12.8%
157
11.8%
725
54.3%
82.2%
17.8%
71.6%
28.4%
92.6%
7.4%
83.9%
16.1%
Control
Patient
Target Class

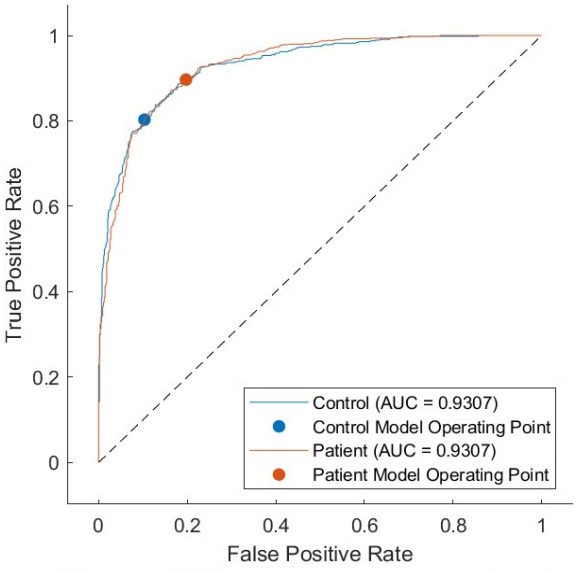
(e)


Control
Patient
Output Class
395
29.6%
64
4.8%
86.1%
13.9%
158
11.8%
719
53.8%
82.0%
18.0%
71.4%
28.6%
91.8%
8.2%
83.4%
16.6%
Control
Patient
Target Class

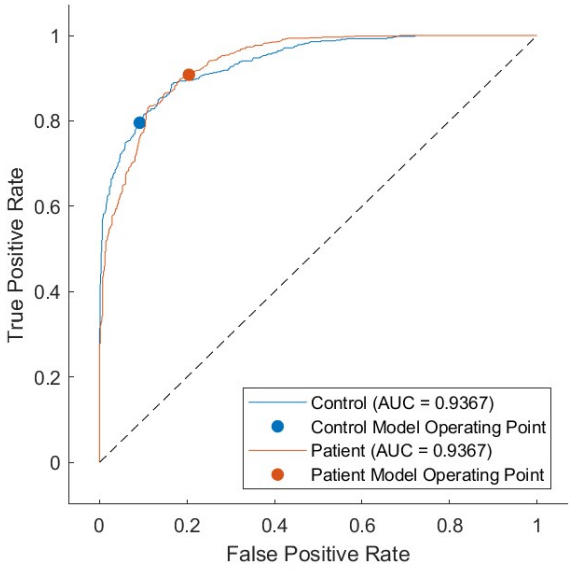
(f)



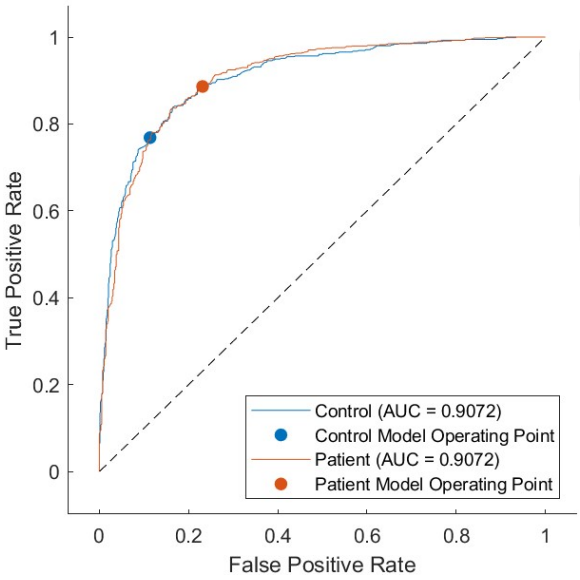
Şekil 4.17: Modifiye ResNet18_2 mimarisinde CWT Bump yaklaşımı için; beyin bölgeleri içinde en iyi sonuç veren kanalların Validasyon ve Test karmaşıklık matrisleri; ön beyin (anterior) bölgesi için; F4 kanalı Validasyon (a) ve Test (b) matrisi; merkez (central) beyin bölgesi için; C3 kanalı Validasyon (c) ve Test (d) matrisi, sol temporal (temporal left) beyin bölgesi için; T5 kanalı Validasyon (e) ve Test (f) matrisi, sağ temporal (temporal right) beyin bölgesi için; T6 kanalı Validasyon (g) ve Test (h) matrisi ve arka (posterior) beyin bölgesi için; P4 kanalı Validasyon (i) ve Test (j) matrisi.


True Positive Rate
False Positive Rate
Control (AUC = 0.9307)
Control Model Operating Point
Patient (AUC = 0.9307)
Patient Model Operating Point

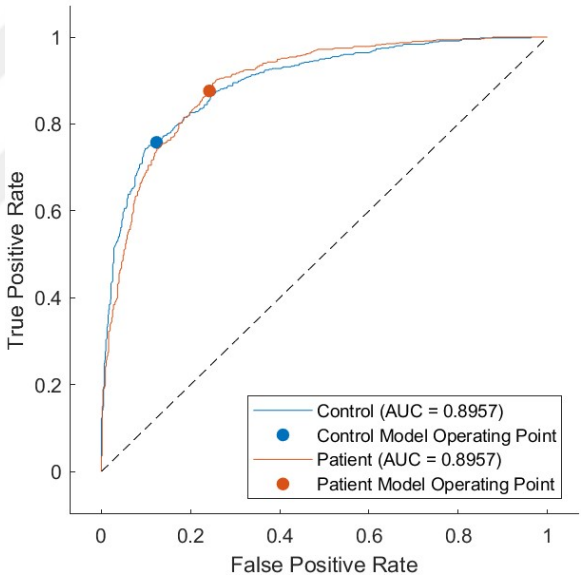
(a)


True Positive Rate
False Positive Rate
Control (AUC = 0.9367)
Control Model Operating Point
Patient (AUC = 0.9367)
Patient Model Operating Point

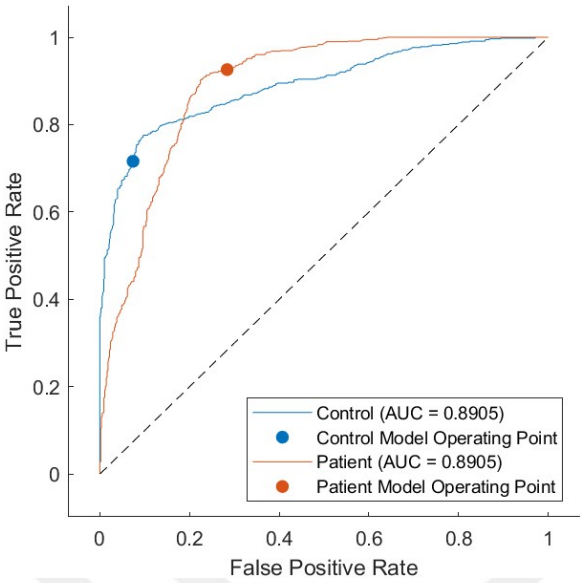
(b)


True Positive Rate
False Positive Rate
Control (AUC = 0.9072)
Control Model Operating Point
Patient (AUC = 0.9072)
Patient Model Operating Point

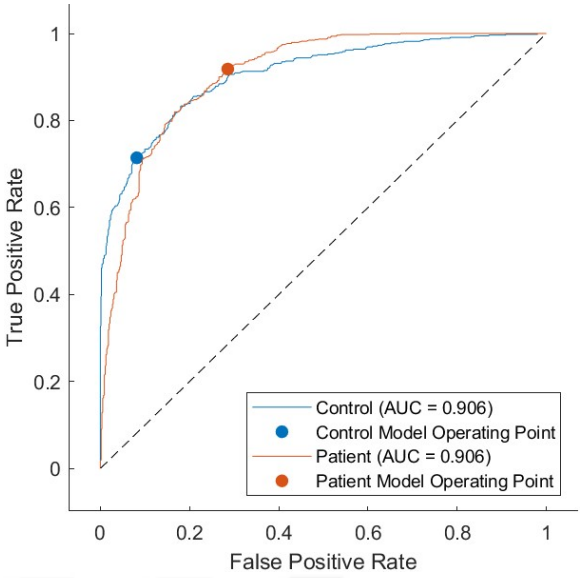
(c)


True Positive Rate
False Positive Rate
Control (AUC = 0.8957)
Control Model Operating Point
Patient (AUC = 0.8957)
Patient Model Operating Point

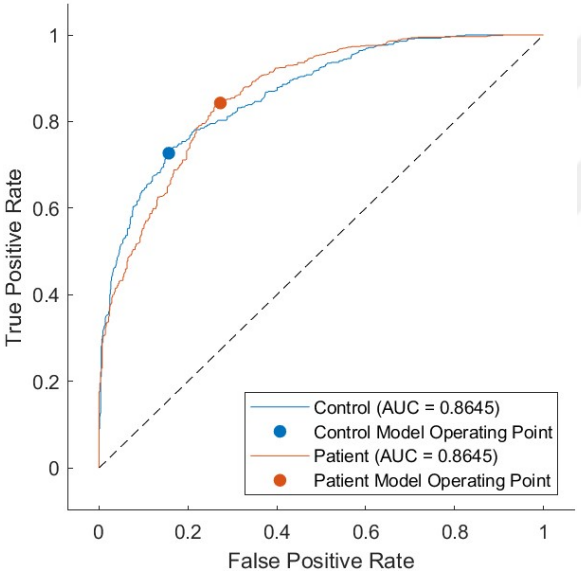
(d)


True Positive Rate
False Positive Rate
Control (AUC = 0.8905)
Control Model Operating Point
Patient (AUC = 0.8905)
Patient Model Operating Point

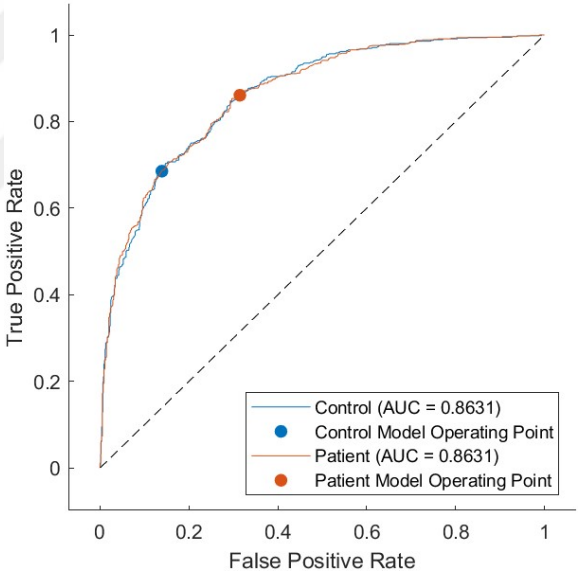
(e)


True Positive Rate
False Positive Rate
Control (AUC = 0.906)
Control Model Operating Point
Patient (AUC = 0.906)
Patient Model Operating Point

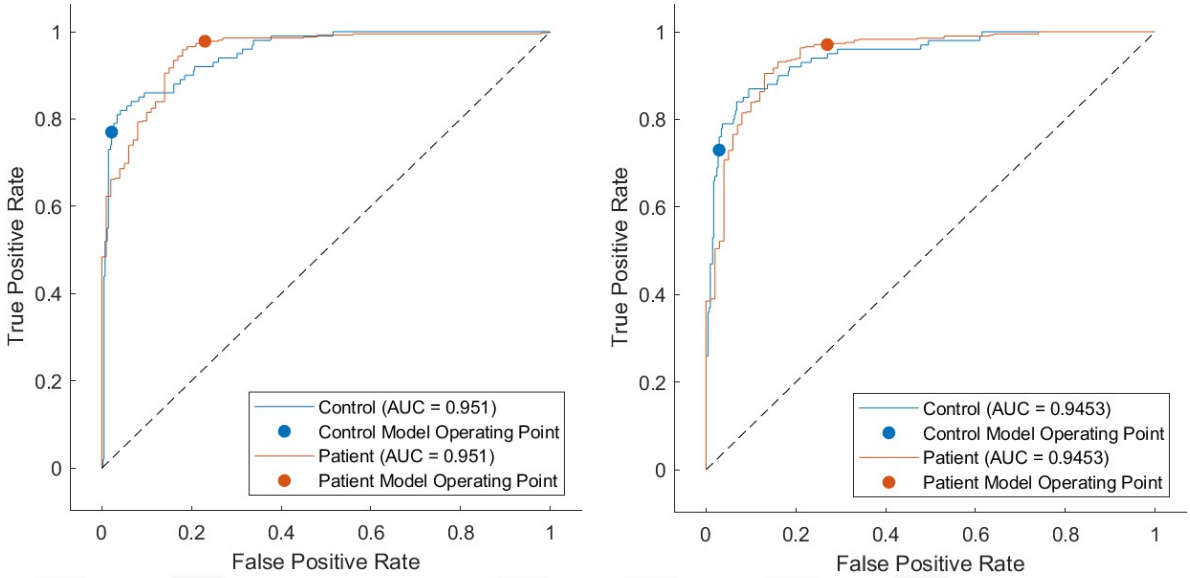
(f)


True Positive Rate
False Positive Rate
Control (AUC = 0.8645)
Control Model Operating Point
Patient (AUC = 0.8645)
Patient Model Operating Point

(g)


True Positive Rate
False Positive Rate
Control (AUC = 0.8631)
Control Model Operating Point
Patient (AUC = 0.8631)
Patient Model Operating Point

(h)



(i) **(j)**

Şekil 4.18: Modifiye ResNet18_2 mimarisinde CWT Bump yaklaşımı için; beyin bölgeleri içinde en iyi sonuç veren kanalların Validasyon ve Test ROC eğrileri; ön beyin (anterior) bölgesi için; F4 kanalı Validasyon (a) ve Test (b) ROC eğrisi; merkez (central) beyin bölgesi için; C3 kanalı Validasyon (c) ve Test (d) ROC eğrisi, sol temporal (temporal left) beyin bölgesi için; T5 kanalı Validasyon (e) ve Test (f) ROC eğrisi, sağ temporal (temporal right) beyin bölgesi için; T6 kanalı Validasyon (g) ve Test (h) ROC eğrisi ve arka (posterior) beyin bölgesi için; P4 kanalı Validasyon (i) ve Test (j) ROC eğrisi.

4.2.4. AlexNet Mimarisinin AH/KG Sınıflandırmasına Etkisi

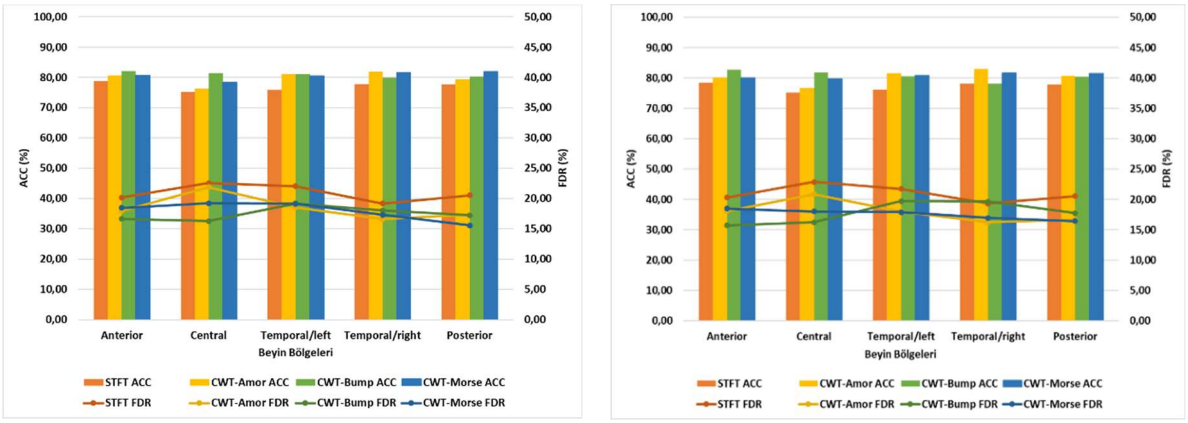
Bu bölümde de ResNet18 mimarilerinde olduğu gibi 15 AH hastasının ve 11 sağlıklı kontrol gönüllüsünün 19 farklı kanaldan kaydedilen EEG verilerinin, STFT ve CWT Amor, CWT Bump ve CWT Morse yaklaşımları kullanılarak elde edilen zaman-frekans gösterimlerinin AlexNet mimarisi ile eğitilmesi sonucu bu derin öğrenme mimarisi için AH/KG sınıflandırmasında uygulanabilecek en uygun zaman-frekans yaklaşımı tespit edilmeye çalışılmıştır. Mimaride görüntülerin %70'i eğitim setine (train), %15'i doğrulama setine (validation) ve kalan %15'i test setine ayrılarak eğitim bitiminde her kanal için; eğitim ilerlemesi (training progress) grafiği, validasyon ve test olmak üzere iki adet karmaşıklık matrisi ve iki adet ROC eğrisi elde edilmiştir. Tablo 4.25'te AlexNet mimarisi için tüm zaman-frekans yaklaşımlarının tüm beyin bölgeleri bazlı validasyon ACC ve FDR değerleri ve Şekil 4.19(a)'da bu değerlerin grafiksel gösterimleri verilmiştir. Bu sonuçlara göre; beynin anterior (ön) bölgesinden %82,14 ACC değeriyle CWT-Bump, AlexNet mimarisi için validasyon AH-KG sınıflandırma doğruluğu en yüksek olan zaman-frekans yaklaşımıdır.

Tablo 4.25: AlexNet mimarisi için ZF yaklaşımlarının beyin bölgesi bazlı ortalama validasyon sonuçları.

	STFT		CWT-Amor		CWT-Bump		CWT-Morse	
	FDR	**ACC**	**FDR**	**ACC**	**FDR**	**ACC**	**FDR**	**ACC**
Anterior	20,18	78,82	18,00	80,60	16,64	***82,14***	18,46	80,64
Central	22,57	75,23	21,87	76,43	16,27	81,43	19,23	78,43
Temporal/left	22,03	75,87	18,57	81,10	19,17	81,10	19,13	80,57
Temporal/right	19,20	77,87	16,60	81,87	18,03	79,90	17,33	81,67
Posterior	20,54	77,72	17,30	79,40	17,22	80,28	15,58	81,90

Tablo 4.26: AlexNet mimarisi için ZF yaklaşımlarının beyin bölgesi bazlı ortalama test sonuçları.

	STFT		CWT-Amor		CWT-Bump		CWT-Morse	
	FDR	**ACC**	**FDR**	**ACC**	**FDR**	**ACC**	**FDR**	**ACC**
Anterior	20,32	78,52	18,10	80,18	15,74	82,78	18,48	80,06
Central	22,90	75,17	20,87	76,77	16,23	81,83	18,00	79,70
Temporal/left	21,73	76,17	18,00	81,53	19,70	80,53	17,90	80,87
Temporal/right	19,33	78,23	16,23	***82,97***	19,63	78,13	16,93	81,60
Posterior	20,56	77,82	16,68	80,72	17,76	80,44	16,44	81,44



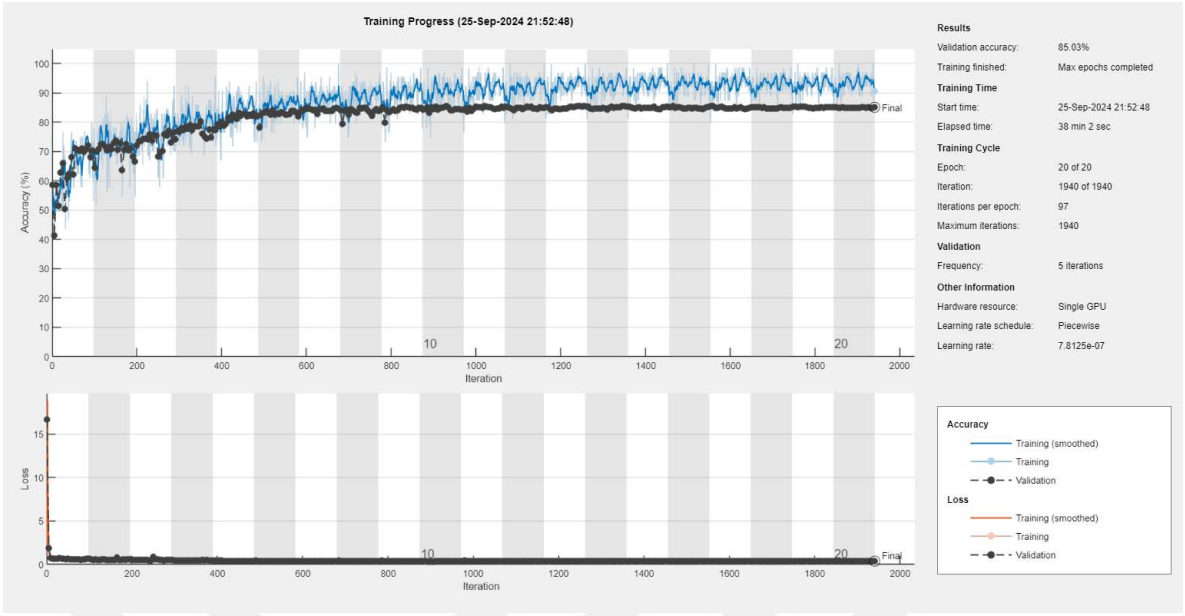
(a) **(b)**

Şekil 4.19: Beyin Bölgesi Bazlı AlexNet Validasyon (a) ve Test (b) Sonuçları

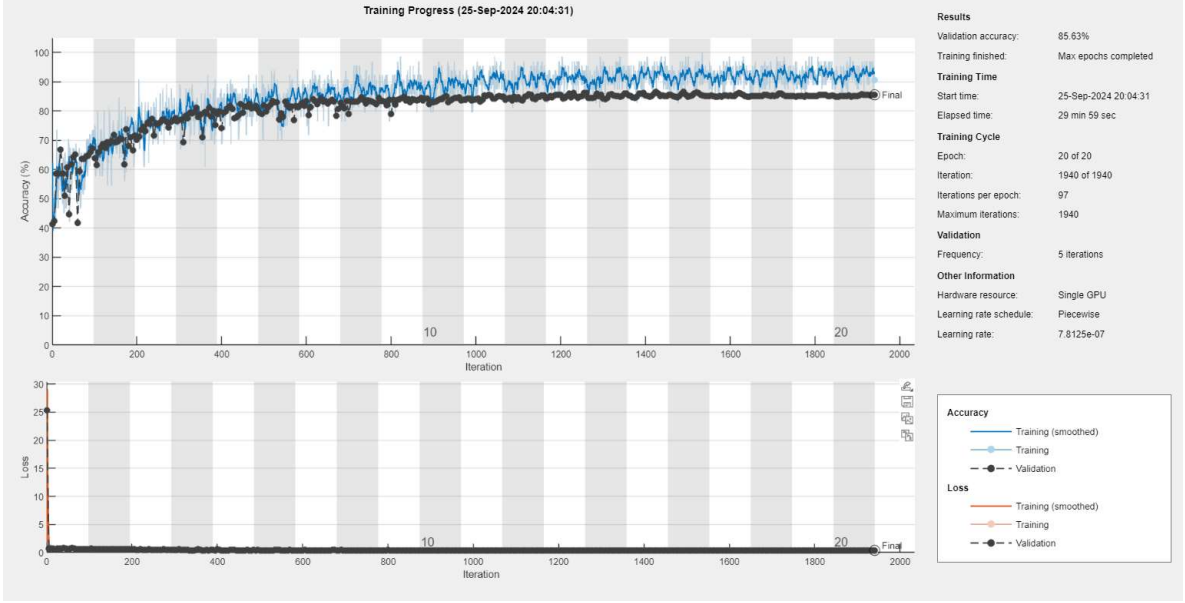
Tablo 4.26'da AlexNet mimarisi için tüm zaman-frekans yaklaşımlarının beyin bölgesi bazlı test ACC ve FDR değerleri ve Şekil 4.19(b)'de bu değerlerin grafiksel gösterimleri verilmiştir. Bu sonuçlara göre; beynin temporal-right (sağ temporal) bölgesinden %82,97 ACC değeriyle CWT-Amor, AlexNet mimarisi için test AH-KG sınıflandırma doğruluğu en yüksek olan zaman-frekans yaklaşımıdır.

4.2.4.1. AlexNet Mimarisinin Beyin Bölgeleri Bazlı En İyi Sonuç Veren Kanallara Ait Eğitim İlerlemesi, Validasyon ve Test İçin Karmaşıklık Matrisi ve ROC Eğrisi Görselleri

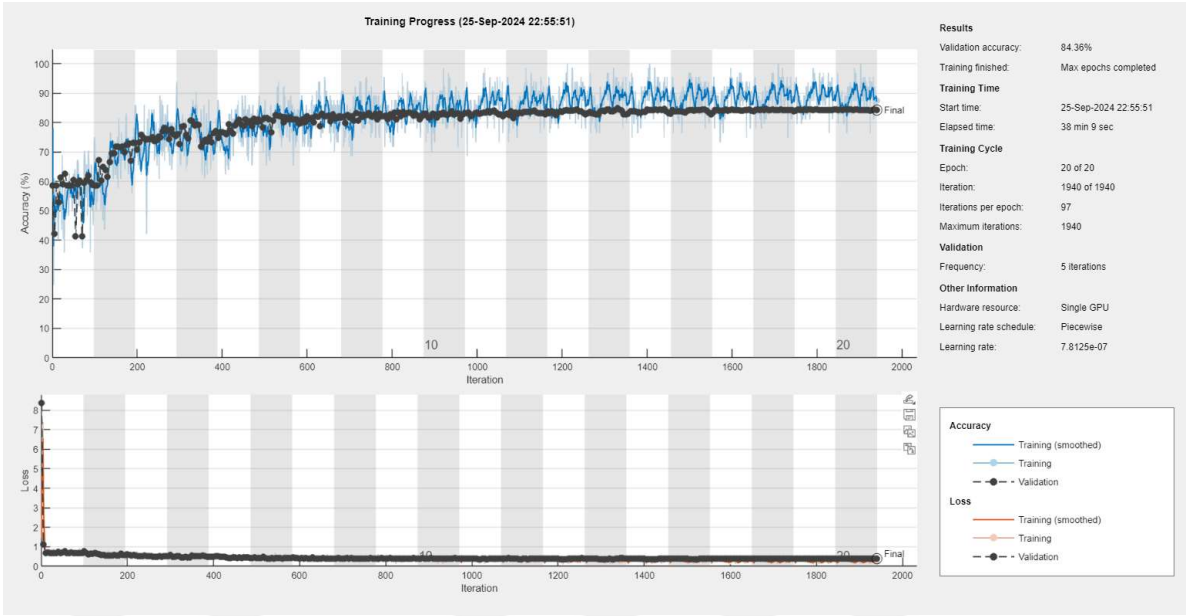
AlexNet mimarisinin zaman-frekans yaklaşımları içinde validasyon için en iyi sonuç veren kanal CWT Bump yaklaşımı ile beynin posterior bölgesinden %93,70 ACC değerine sahip P4 kanalıdır. Bu bölümde, AlexNet mimarisi için en yüksek kanal değeri CWT Bump yaklaşımıyla elde edildiğinden bu yaklaşımından elde edilen ve beyin bölgeleri içinde en yüksek değerlere sahip kanal sonuçları yer almaktadır. Beş beyin bölgesi (ön (anterior) beyin bölgesi için F4 kanalı, merkez (central) beyin bölgesi için C3 kanalı, sol temporal (temporal left) beyin bölgesi için T5 kanalı, sağ temporal (temporal right) beyin bölgesi için F8 kanalı ve arka (posterior) beyin bölgesi için P4 kanalı) bazlı en iyi kanalların eğitim ilerlemesi (training progress), validasyon ve test karmaşıklık matrisi ve ROC eğrisi görselleri aşağıda detaylı şekilde bulunmaktadır (Şekil 4.20, Şekil 4.21, Şekil 4.22).


Training Progress (25-Sep-2024 21:52:48)
Accuracy (%)
Iteration
Loss
Final
Results
Validation accuracy: 85.03%
Training finished: Max epochs completed
Training Time
Start time: 25-Sep-2024 21:52:48
Elapsed time: 38 min 2 sec
Training Cycle
Epoch: 20 of 20
Iteration: 1940 of 1940
Iterations per epoch: 97
Maximum iterations: 1940
Validation
Frequency: 5 iterations
Other Information
Hardware resource: Single GPU
Learning rate schedule: Piecewise
Learning rate: 7.8125e-07
Accuracy
Training (smoothed)
Training
Validation
Loss
Training (smoothed)
Training
Validation

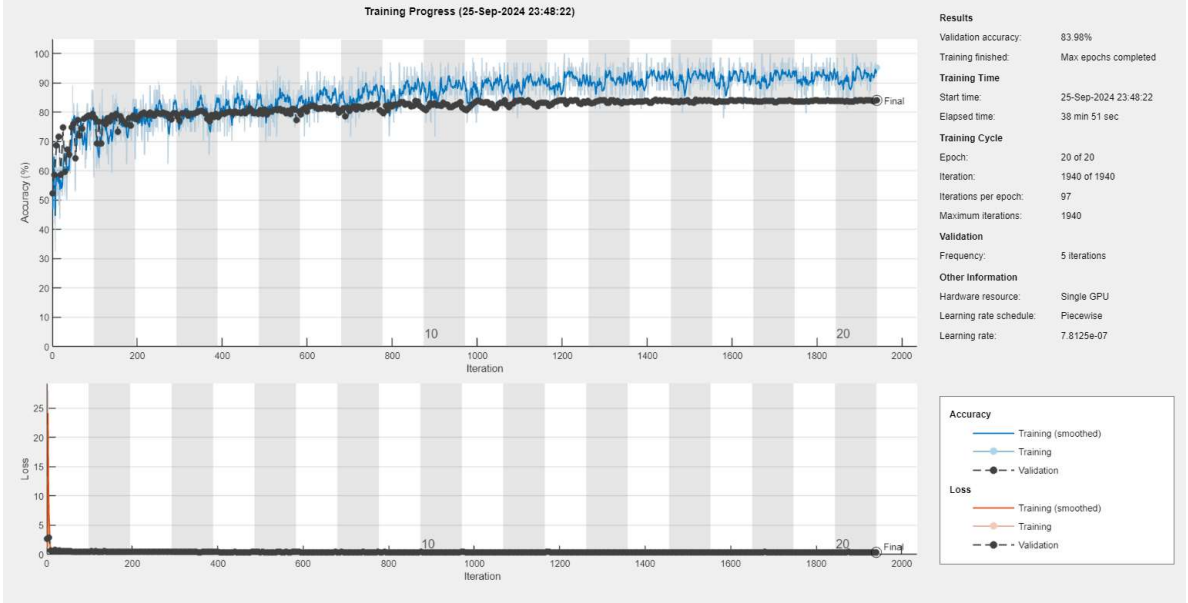
(a)


Training Progress (25-Sep-2024 20:04:31)
Accuracy (%)
Iteration
Loss
Final
Results
Validation accuracy: 85.63%
Training finished: Max epochs completed
Training Time
Start time: 25-Sep-2024 20:04:31
Elapsed time: 29 min 59 sec
Training Cycle
Epoch: 20 of 20
Iteration: 1940 of 1940
Iterations per epoch: 97
Maximum iterations: 1940
Validation
Frequency: 5 iterations
Other Information
Hardware resource: Single GPU
Learning rate schedule: Piecewise
Learning rate: 7.8125e-07
Accuracy
Training (smoothed)
Training
Validation
Loss
Training (smoothed)
Training
Validation

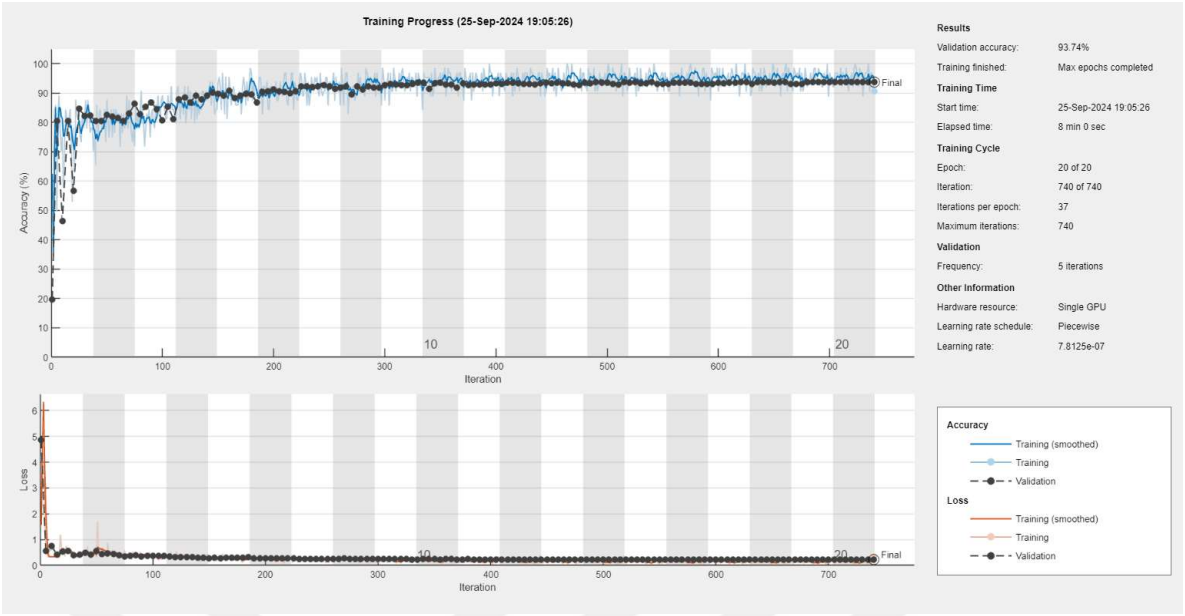
(b)


Training Progress (25-Sep-2024 22:55:51)
Accuracy (%)
Iteration
Loss
Final
Results
Validation accuracy: 84.36%
Training finished: Max epochs completed
Training Time
Start time: 25-Sep-2024 22:55:51
Elapsed time: 38 min 9 sec
Training Cycle
Epoch: 20 of 20
Iteration: 1940 of 1940
Iterations per epoch: 97
Maximum iterations: 1940
Validation
Frequency: 5 iterations
Other Information
Hardware resource: Single GPU
Learning rate schedule: Piecewise
Learning rate: 7.8125e-07
Accuracy
Training (smoothed)
Training
Validation
Loss
Training (smoothed)
Training
Validation

(c)

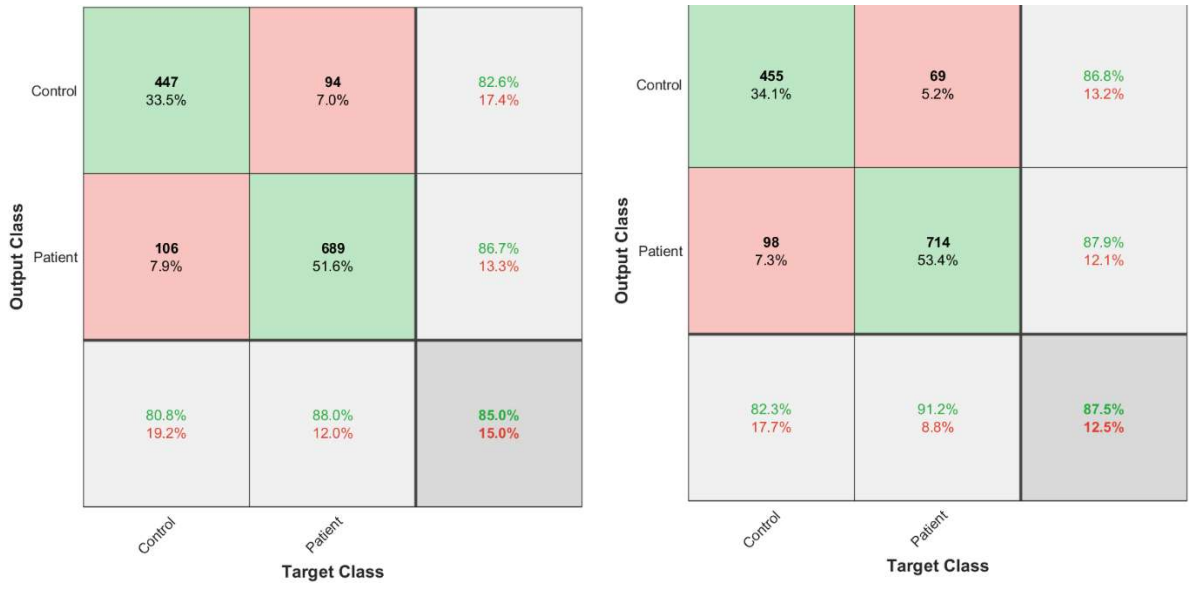

Training Progress (25-Sep-2024 23:48:22)
Accuracy (%)
Iteration
Loss
Final
Results
Validation accuracy: 83.98%
Training finished: Max epochs completed
Training Time
Start time: 25-Sep-2024 23:48:22
Elapsed time: 38 min 51 sec
Training Cycle
Epoch: 20 of 20
Iteration: 1940 of 1940
Iterations per epoch: 97
Maximum iterations: 1940
Validation
Frequency: 5 iterations
Other Information
Hardware resource: Single GPU
Learning rate schedule: Piecewise
Learning rate: 7.8125e-07
Accuracy
Training (smoothed)
Training
Validation
Loss
Training (smoothed)
Training
Validation

(d)



(e)

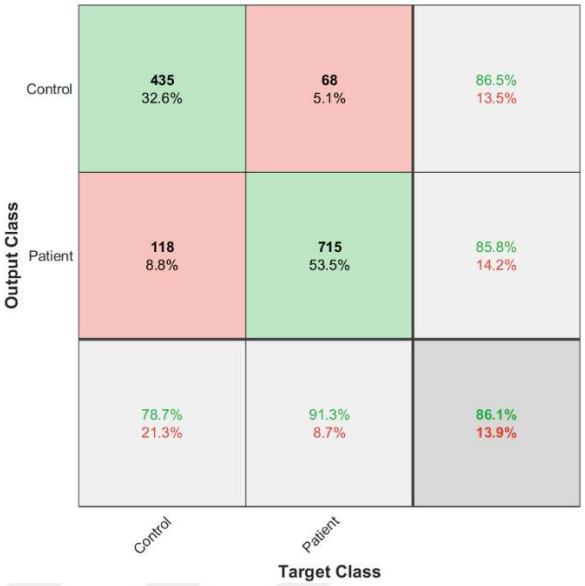
Şekil 4.20: AlexNet mimarisinde CWT Bump yaklaşımı için; beyin bölgeleri içinde en iyi sonuç veren kanalların Training Progress görselleri; ön beyin (anterior) bölgesi için; F4 kanalı (a); merkez (central) beyin bölgesi için; C3 kanalı (b), sol temporal (temporal left) beyin bölgesi için; T5 kanalı (c), sağ temporal (temporal right) beyin bölgesi için; F8 kanalı (d) ve arka (posterior) beyin bölgesi için; P4 kanalı (e).



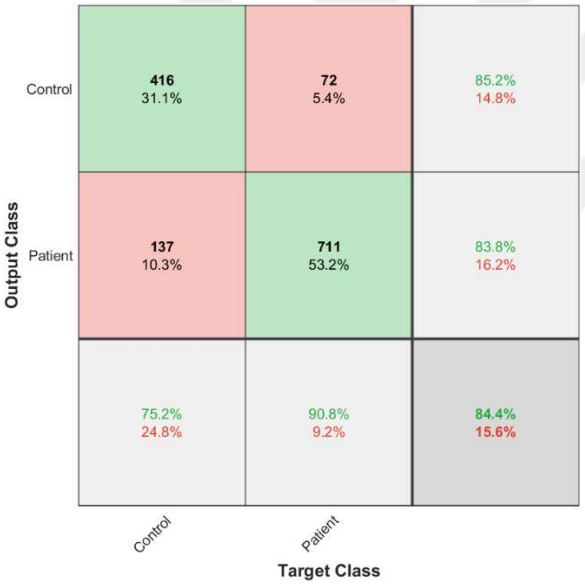
(a) **(b)**


Control
Patient
Output Class
439
32.9%
78
5.8%
84.9%
15.1%
114
8.5%
705
52.8%
86.1%
13.9%
79.4%
20.6%
90.0%
10.0%
85.6%
14.4%
Control
Patient
Target Class

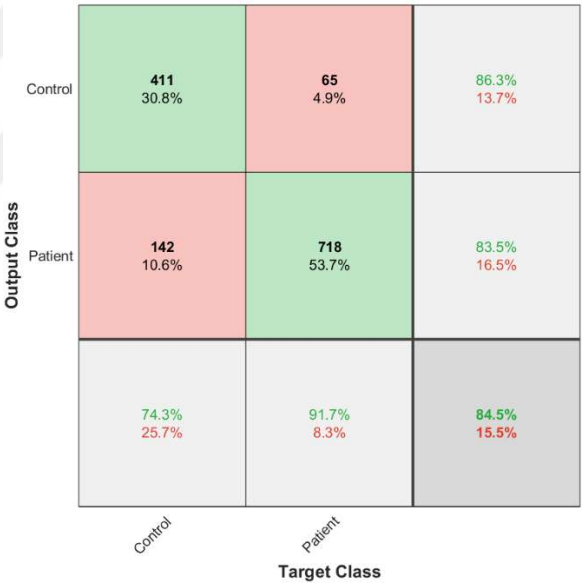
(c)


Control
Patient
Output Class
435
32.6%
68
5.1%
86.5%
13.5%
118
8.8%
715
53.5%
85.8%
14.2%
78.7%
21.3%
91.3%
8.7%
86.1%
13.9%
Control
Patient
Target Class

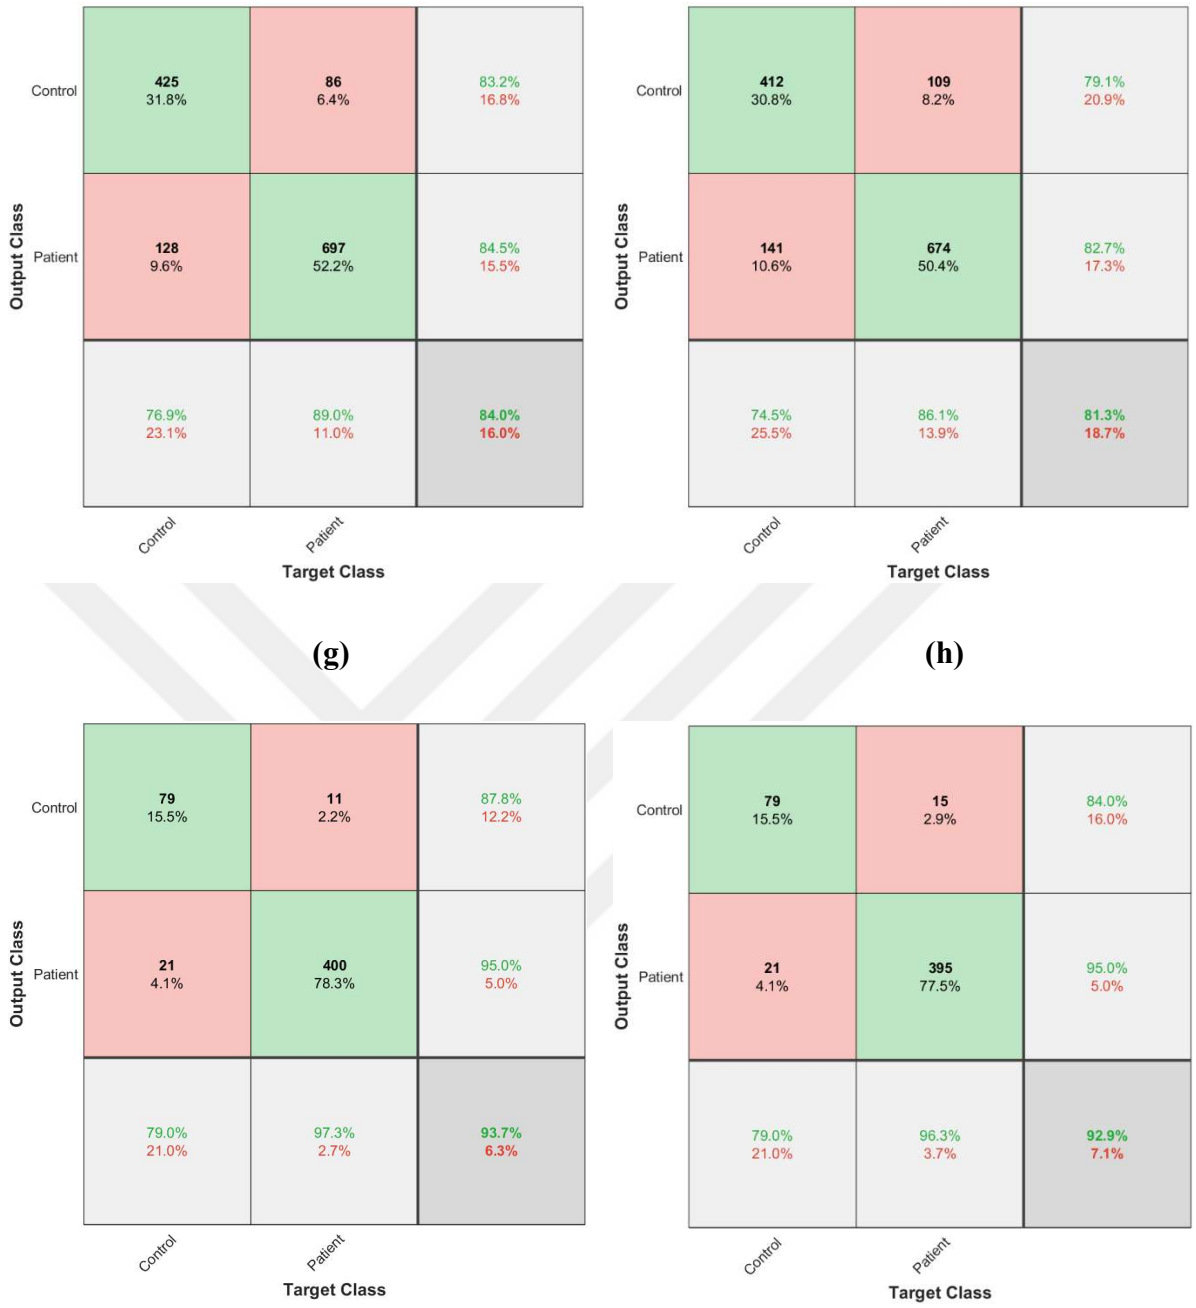
(d)


Control
Patient
Output Class
416
31.1%
72
5.4%
85.2%
14.8%
137
10.3%
711
53.2%
83.8%
16.2%
75.2%
24.8%
90.8%
9.2%
84.4%
15.6%
Control
Patient
Target Class

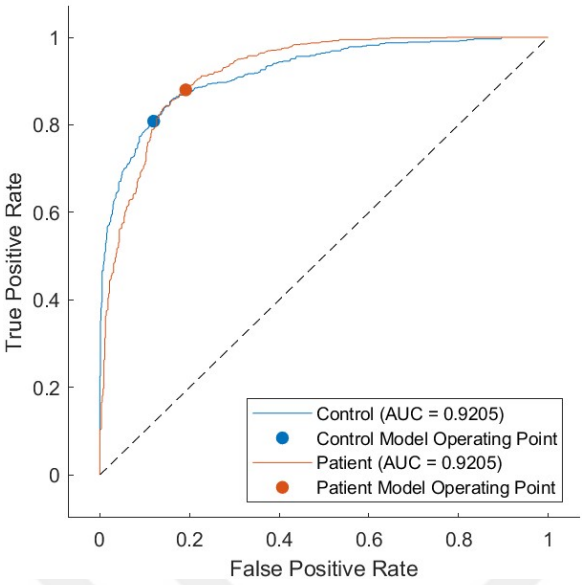
(e)


Control
Patient
Output Class
411
30.8%
65
4.9%
86.3%
13.7%
142
10.6%
718
53.7%
83.5%
16.5%
74.3%
25.7%
91.7%
8.3%
84.5%
15.5%
Control
Patient
Target Class

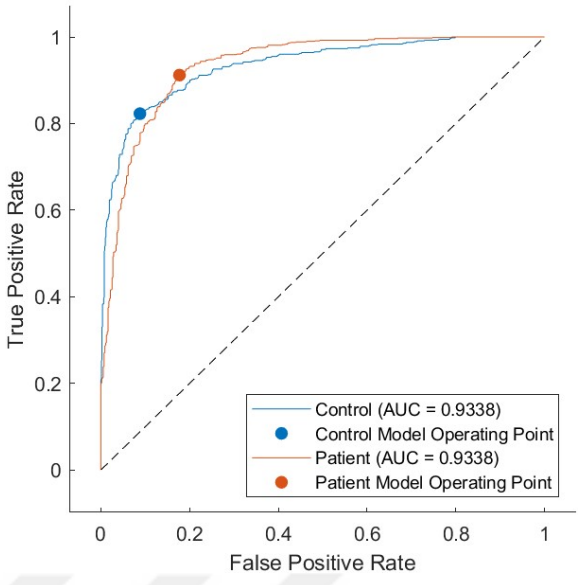
(f)



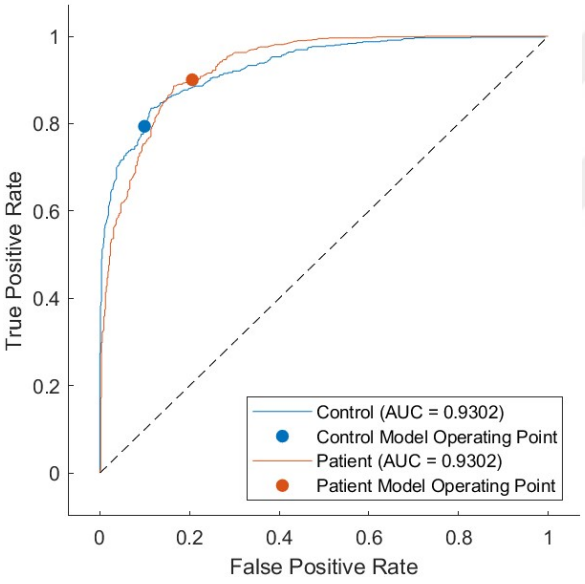
Şekil 4.21: AlexNet mimarisinde CWT Bump yaklaşımı için; beyin bölgeleri içinde en iyi sonuç veren kanalların Validasyon ve Test karmaşıklık matrisleri; ön beyin (anterior) bölgesi için; F4 kanalı Validasyon (a) ve Test (b) matrisi; merkez (central) beyin bölgesi için; C3 kanalı Validasyon (c) ve Test (d) matrisi, sol temporal (temporal left) beyin bölgesi için T5 kanalı Validasyon (e) ve Test (f) matrisi, sağ temporal (temporal right) beyin bölgesi için F8 kanalı Validasyon (g) ve Test (h) matrisi ve arka (posterior) beyin bölgesi için P4 kanalı Validasyon (i) ve Test (j) matrisi.


True Positive Rate
False Positive Rate
Control (AUC = 0.9205)
Control Model Operating Point
Patient (AUC = 0.9205)
Patient Model Operating Point

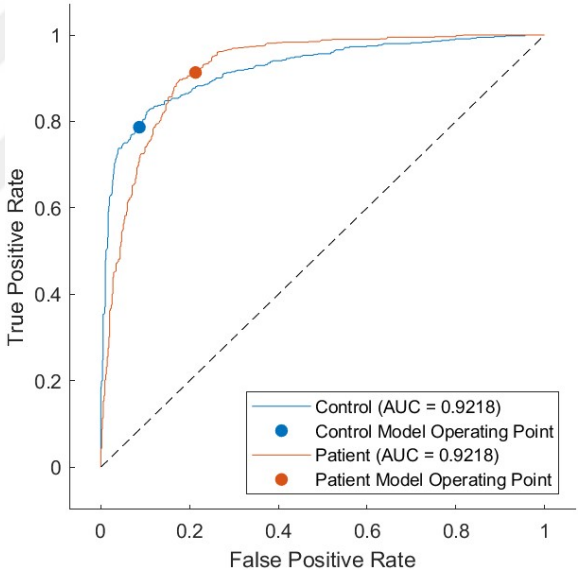
(a)


True Positive Rate
False Positive Rate
Control (AUC = 0.9338)
Control Model Operating Point
Patient (AUC = 0.9338)
Patient Model Operating Point

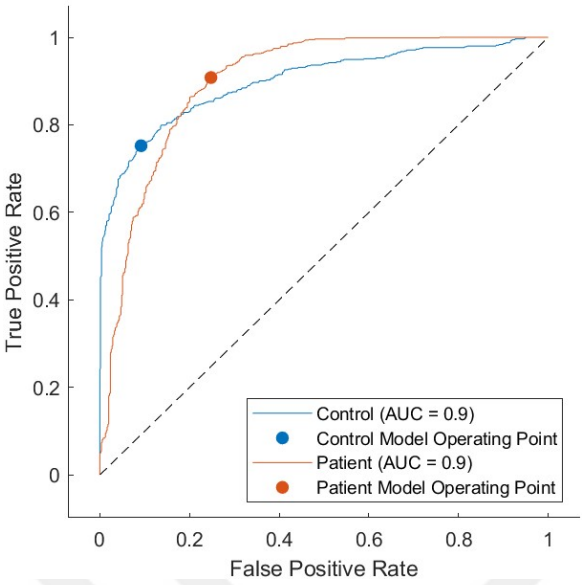
(b)


True Positive Rate
False Positive Rate
Control (AUC = 0.9302)
Control Model Operating Point
Patient (AUC = 0.9302)
Patient Model Operating Point

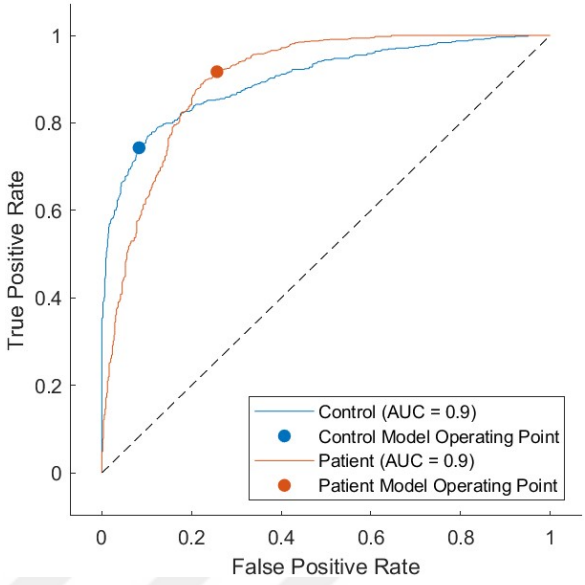
(c)


True Positive Rate
False Positive Rate
Control (AUC = 0.9218)
Control Model Operating Point
Patient (AUC = 0.9218)
Patient Model Operating Point

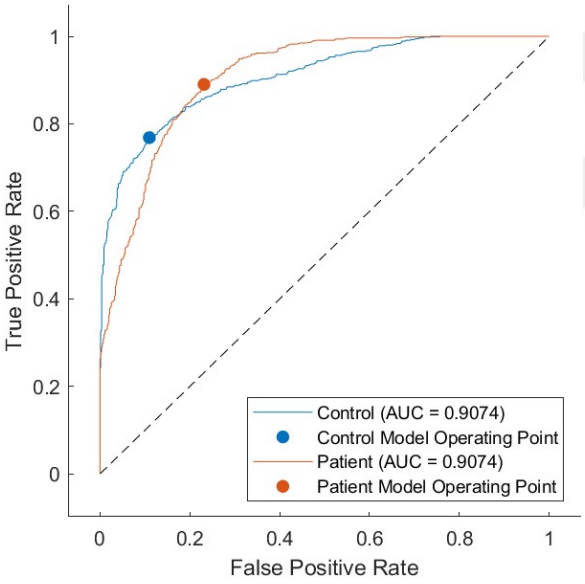
(d)


True Positive Rate
False Positive Rate
Control (AUC = 0.9)
Control Model Operating Point
Patient (AUC = 0.9)
Patient Model Operating Point

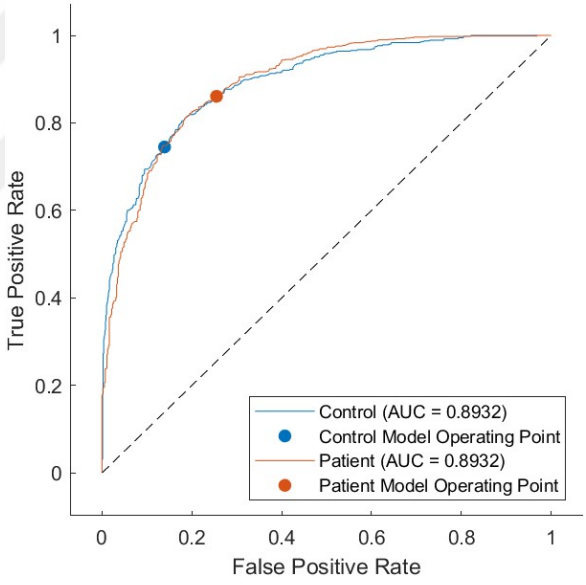
(e)


True Positive Rate
False Positive Rate
Control (AUC = 0.9)
Control Model Operating Point
Patient (AUC = 0.9)
Patient Model Operating Point

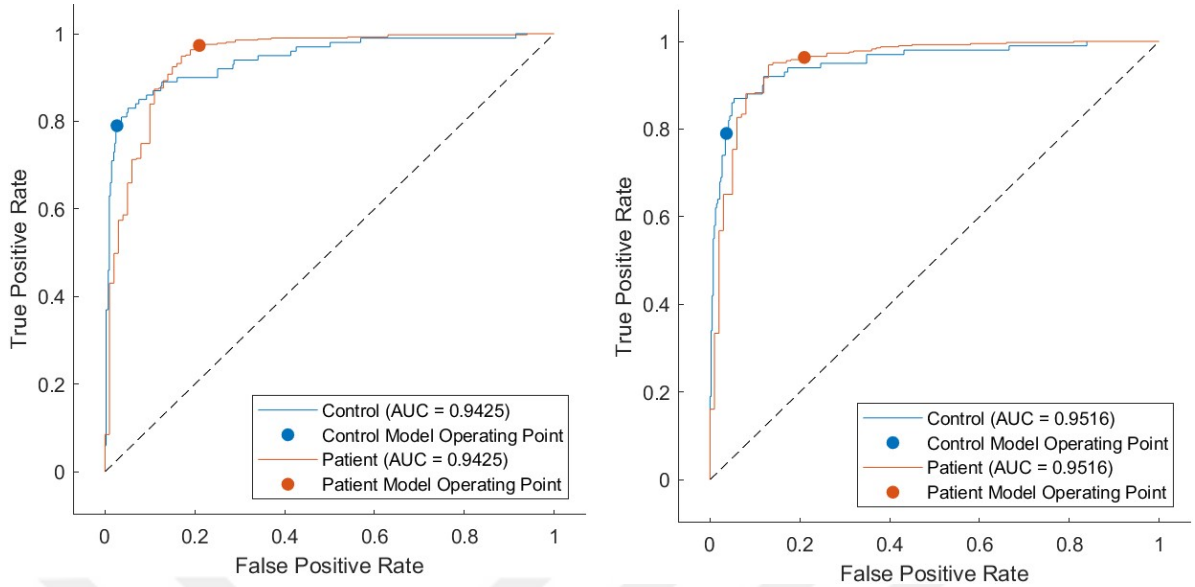
(f)


True Positive Rate
False Positive Rate
Control (AUC = 0.9074)
Control Model Operating Point
Patient (AUC = 0.9074)
Patient Model Operating Point

(g)


True Positive Rate
False Positive Rate
Control (AUC = 0.8932)
Control Model Operating Point
Patient (AUC = 0.8932)
Patient Model Operating Point

(h)



(i) **(j)**

Şekil 4.22: AlexNet mimarisinde CWT Bump yaklaşımı için; beyin bölgeleri içinde en iyi sonuç veren kanalların Validasyon ve Test ROC eğrileri; ön beyin (anterior) bölgesi için; F4 kanalı Validasyon (a) ve Test (b) ROC eğrisi; merkez (central) beyin bölgesi için; C3 kanalı Validasyon (c) ve Test (d) ROC eğrisi, sol temporal (temporal left) beyin bölgesi için; T5 kanalı Validasyon (e) ve Test (f) ROC eğrisi, sağ temporal (temporal right) beyin bölgesi için; F8 kanalı Validasyon (g) ve Test (h) ROC eğrisi ve arka (posterior) beyin bölgesi için; P4 kanalı Validasyon (i) ve Test (j) ROC eğrisi.

4.2.5. GoogleNet Mimarisinin AH/KG Sınıflandırmasına Etkisi

Önerilen diğer dört mimaride olduğu gibi bu bölümde,15 AH hastasının ve 11 sağlıklı kontrol gönüllüsünün 19 farklı kanaldan kaydedilen EEG verilerinin, STFT ve CWT Amor, CWT Bump ve CWT Morse yaklaşımları kullanılarak elde edilen zaman-frekans gösterimlerinin GoogleNet mimarisi ile eğitilmesi sonucu bu derin öğrenme mimarisi için AH/KG sınıflandırmasında uygulanabilecek en uygun zaman-frekans yaklaşımı tespit edilmeye çalışılmıştır. Mimaride görüntülerin %70'i eğitim setine (train), %15'i doğrulama setine (validation) ve kalan %15'i test setine ayrılarak eğitim bitiminde her kanal için; eğitim ilerlemesi (training progress) grafiği, validasyon ve test olmak üzere iki adet karmaşıklık matrisi ve iki adet ROC eğrisi elde edilmiştir. Tablo 4.27'de zaman frekans yaklaşımlarının GoogleNet mimarisi ile eğitimi sonucu elde edilen beyin bölgesi bazlı ortalama validasyon FDR ve ACC değerleri ve Şekil 4.23(a)'da bu değerlere ait grafiksel gösterimler verilmiştir. Bu sonuçlara göre; beynin posterior (arka) bölgesinden %83,42 ACC validasyon değeriyle CWT-

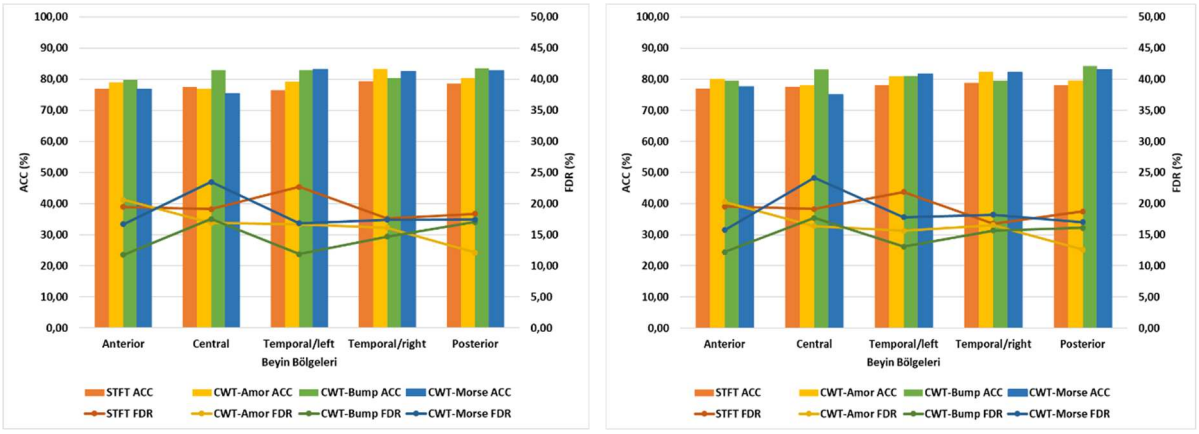
Bump, GoogleNet mimarisi için AH-KG sınıflandırma doğruluğu en yüksek olan zaman-frekans yaklaşımıdır.

Tablo 4.27: GoogleNet mimarisi için ZF yaklaşımlarının beyin bölgesi bazlı ortalama validasyon sonuçları.

	STFT		CWT-Amor		CWT-Bump		CWT-Morse	
	FDR	ACC	FDR	ACC	FDR	ACC	FDR	ACC
Anterior	19,46	77,00	20,62	79,06	11,78	79,76	16,68	76,76
Central	19,10	77,47	16,90	76,97	17,53	82,90	23,50	75,43
Temporal/left	22,70	76,50	16,63	79,20	11,90	82,90	16,87	83,10
Temporal/right	17,60	79,30	16,13	83,30	14,70	80,27	17,40	82,50
Posterior	18,36	78,58	12,14	80,22	17,06	***83,42***	17,44	82,72

Tablo 4.28: GoogleNet mimarisi için ZF yaklaşımlarının beyin bölgesi bazlı ortalama test sonuçları.

	STFT		CWT-Amor		CWT-Bump		CWT-Morse	
	FDR	ACC	FDR	ACC	FDR	ACC	FDR	ACC
Anterior	19,52	76,92	20,28	80,08	12,22	79,44	15,74	77,58
Central	19,13	77,47	16,40	78,07	17,70	83,10	24,13	75,03
Temporal/left	21,87	78,03	15,63	80,93	13,10	81,07	17,80	81,70
Temporal/right	16,77	78,77	16,53	82,23	15,67	79,47	18,23	82,10
Posterior	18,74	78,00	12,62	79,60	16,12	***84,22***	17,04	83,06



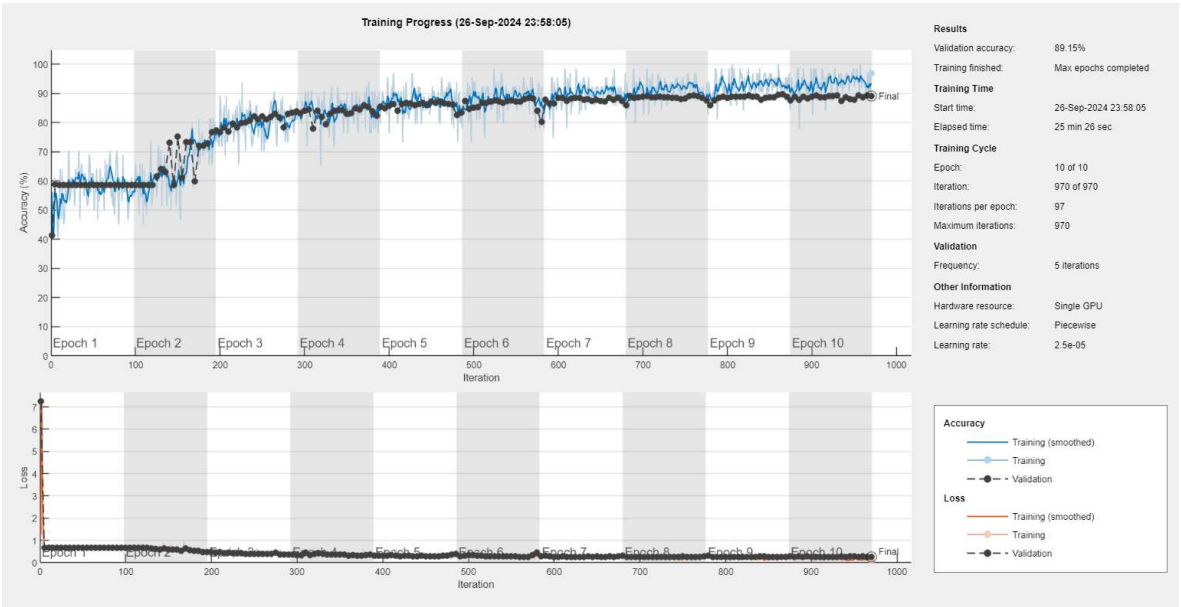
(a) **(b)**

Şekil 4.23: Beyin Bölgesi Bazlı GoogleNet Validasyon (a) ve Test (b) Sonuçları

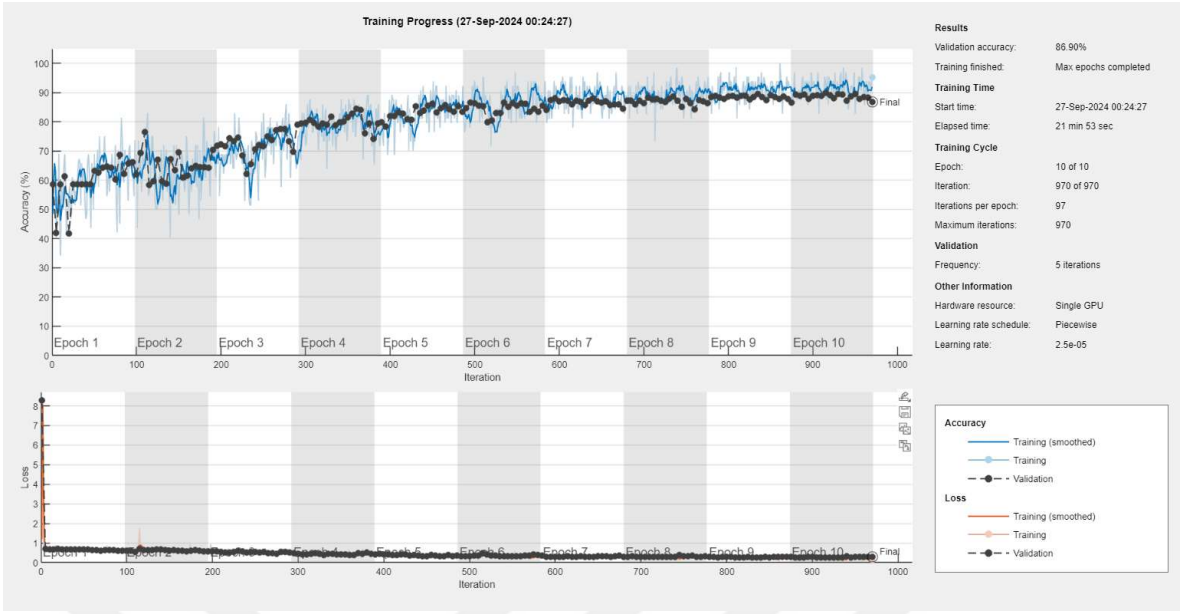
Tablo 4.28'de zaman frekans yaklaşımlarının GoogleNet mimarisi ile eğitimi sonucu elde edilen tüm beyin kümeleri için ortalama test FDR ve ACC değerleri ve Şekil 4.23(b)'de bu değerlere ait grafiksel gösterim verilmiştir. Bu sonuçlara göre; beynin posterior (arka) bölgesinden %84,22 ACC test değeriyle CWT-Bump, GoogleNet mimarisi için AH-KG sınıflandırma doğruluğu en yüksek olan zaman-frekans yaklaşımıdır.

4.2.5.1. GoogleNet Mimarisinin Beyin Bölgeleri Bazlı En İyi Sonuç Veren Kanallara Ait Eğitim İlerlemesi, Validasyon ve Test İçin Karmaşıklık Matrisi ve ROC Eğrisi Görselleri

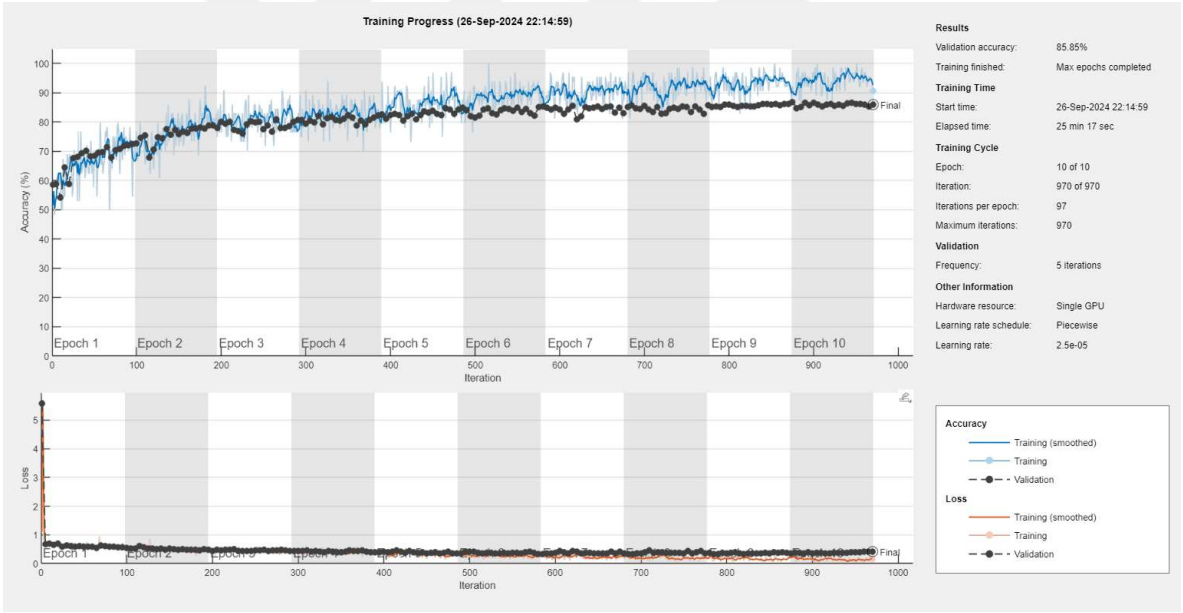
GoogleNet mimarisinin zaman-frekans yaklaşımları içinde validasyon için en iyi sonuç veren kanal CWT Bump yaklaşımı ile beynin posterior bölgesinden %94,70 ACC değerine sahip P4 kanalıdır. Bu bölümde, GoogleNet mimarisi için en yüksek kanal değeri CWT Bump yaklaşımıyla elde edildiğinden bu yaklaşımından elde edilen ve beyin bölgeleri içinde en yüksek sonuçlara sahip kanal sonuçları yer almaktadır. Beş beyin bölgesi (ön (anterior) beyin bölgesi için F4 kanalı, merkez (central) beyin bölgesi için C3 kanalı, sol temporal (temporal left) beyin bölgesi için T5 kanalı, sağ temporal (temporal right) beyin bölgesi için T6 kanalı ve arka (posterior) beyin bölgesi için P4 kanalı) bazlı en iyi kanalların eğitim ilerlemesi (training progress), validasyon ve test karmaşıklık matrisi ve ROC eğrisi görselleri aşağıda detaylı şekilde bulunmaktadır (Şekil 4.24, Şekil 4.25, Şekil 4.26).



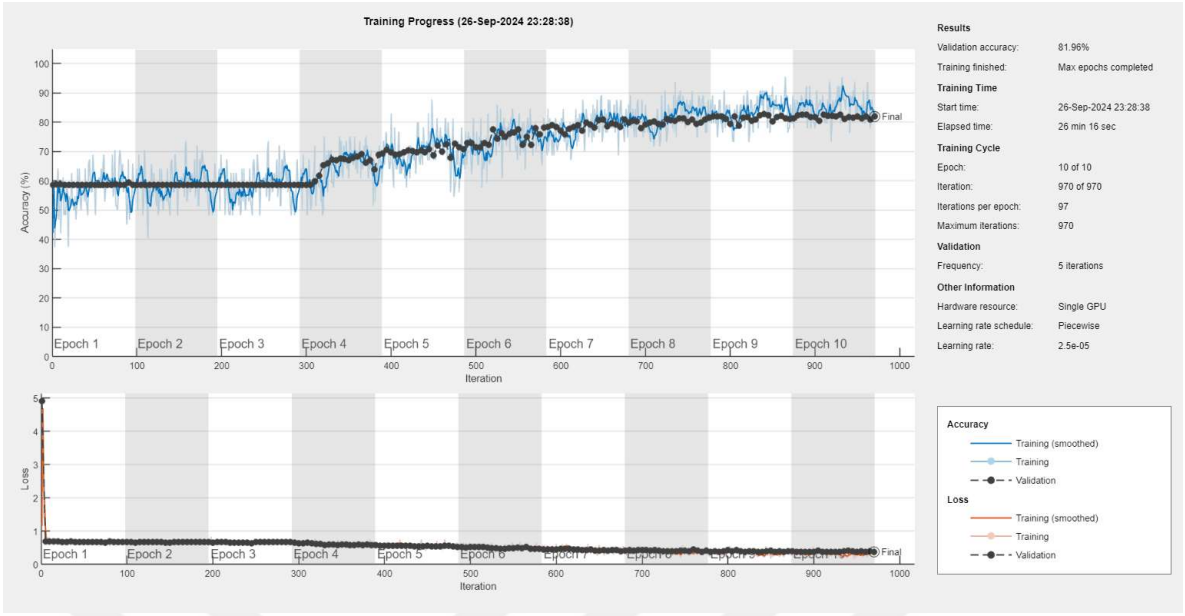
(a)


Training Progress (27-Sep-2024 00:24:27)
Accuracy (%)
Epoch 1
Epoch 2
Epoch 3
Epoch 4
Epoch 5
Epoch 6
Epoch 7
Epoch 8
Epoch 9
Epoch 10
Final
Iteration
Loss
Results
Validation accuracy: 86.90%
Training finished: Max epochs completed
Training Time
Start time: 27-Sep-2024 00:24:27
Elapsed time: 21 min 53 sec
Training Cycle
Epoch: 10 of 10
Iteration: 970 of 970
Iterations per epoch: 97
Maximum iterations: 970
Validation
Frequency: 5 iterations
Other Information
Hardware resource: Single GPU
Learning rate schedule: Piecewise
Learning rate: 2.5e-05
Accuracy
Training (smoothed)
Training
Validation
Loss
Training (smoothed)
Training
Validation

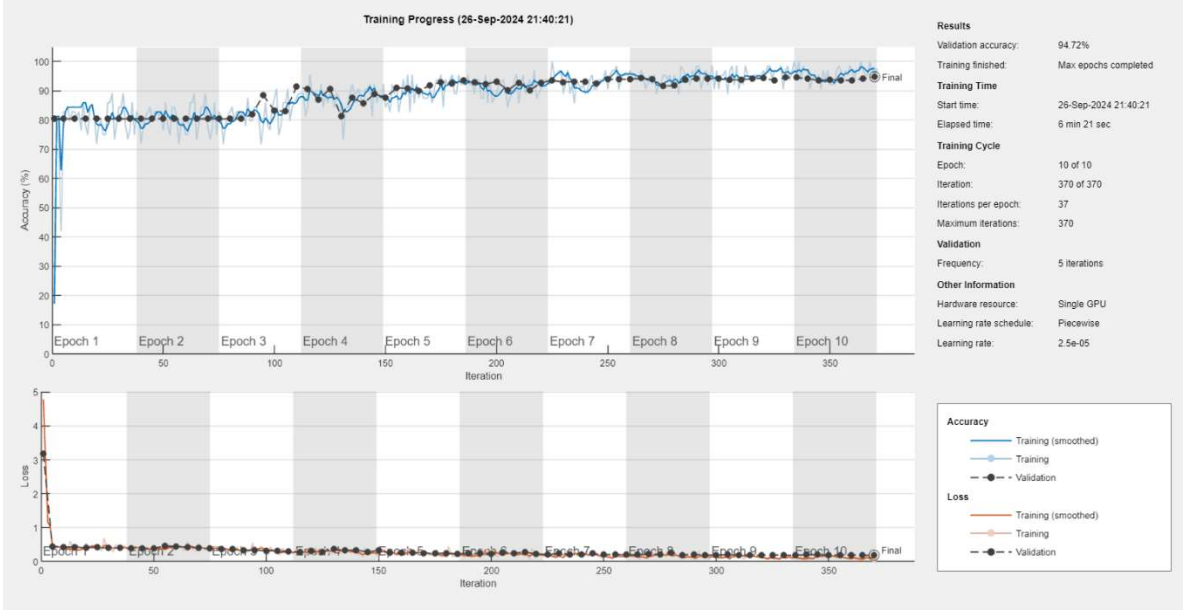
(b)


Training Progress (26-Sep-2024 22:14:59)
Accuracy (%)
Epoch 1
Epoch 2
Epoch 3
Epoch 4
Epoch 5
Epoch 6
Epoch 7
Epoch 8
Epoch 9
Epoch 10
Final
Iteration
Loss
Results
Validation accuracy: 85.85%
Training finished: Max epochs completed
Training Time
Start time: 26-Sep-2024 22:14:59
Elapsed time: 25 min 17 sec
Training Cycle
Epoch: 10 of 10
Iteration: 970 of 970
Iterations per epoch: 97
Maximum iterations: 970
Validation
Frequency: 5 iterations
Other Information
Hardware resource: Single GPU
Learning rate schedule: Piecewise
Learning rate: 2.5e-05
Accuracy
Training (smoothed)
Training
Validation
Loss
Training (smoothed)
Training
Validation

(c)

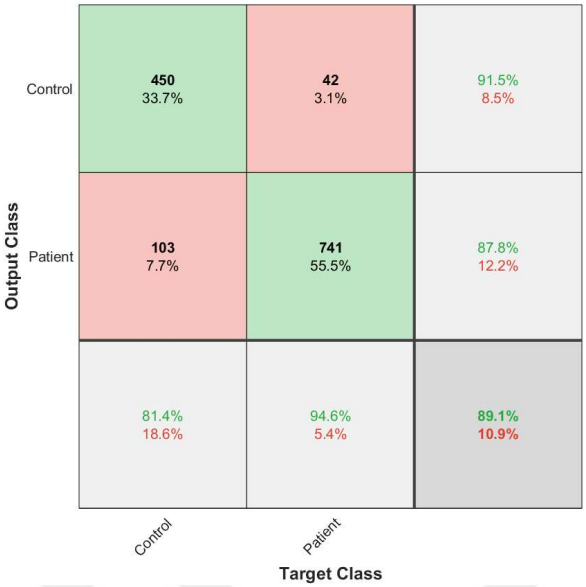


(d)

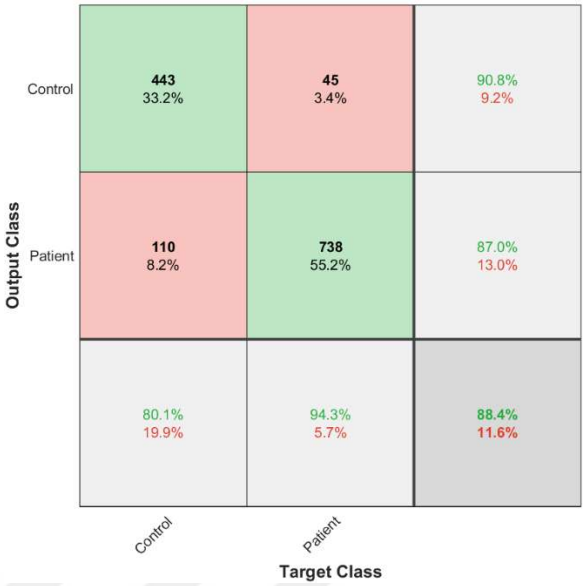


(e)

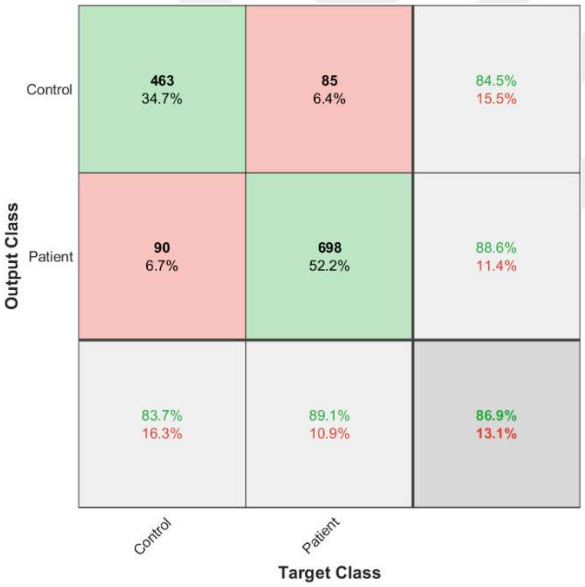
Şekil 4.24: GoogleNet mimarisinde CWT Bump yaklaşımı için; beyin bölgeleri içinde en iyi sonuç veren kanalların Training Progress görselleri; ön beyin (anterior) bölgesi için; F4 kanalı (a); merkez (central) beyin bölgesi için; C3 kanalı (b), sol temporal (temporal left) beyin bölgesi için; T5 kanalı (c), sağ temporal (temporal right) beyin bölgesi için; T6 kanalı (d) ve arka (posterior) beyin bölgesi için; P4 kanalı (e).


Control
Patient
Output Class
450
33.7%
42
3.1%
91.5%
8.5%
103
7.7%
741
55.5%
87.8%
12.2%
81.4%
18.6%
94.6%
5.4%
89.1%
10.9%
Control
Patient
Target Class

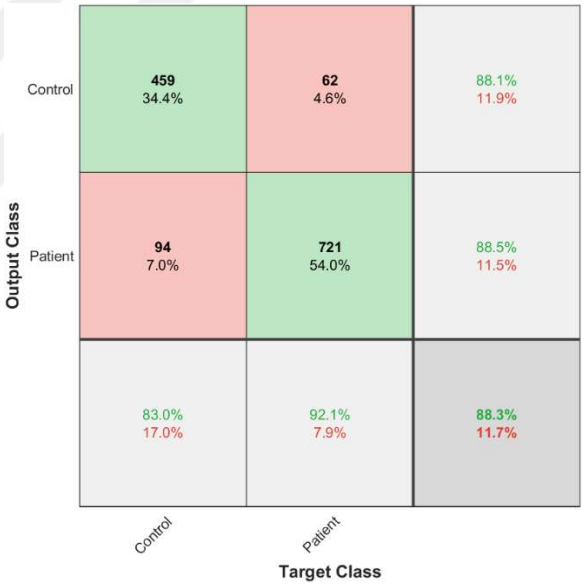
(a)


Control
Patient
Output Class
443
33.2%
45
3.4%
90.8%
9.2%
110
8.2%
738
55.2%
87.0%
13.0%
80.1%
19.9%
94.3%
5.7%
88.4%
11.6%
Control
Patient
Target Class

(b)


Control
Patient
Output Class
463
34.7%
85
6.4%
84.5%
15.5%
90
6.7%
698
52.2%
88.6%
11.4%
83.7%
16.3%
89.1%
10.9%
86.9%
13.1%
Control
Patient
Target Class

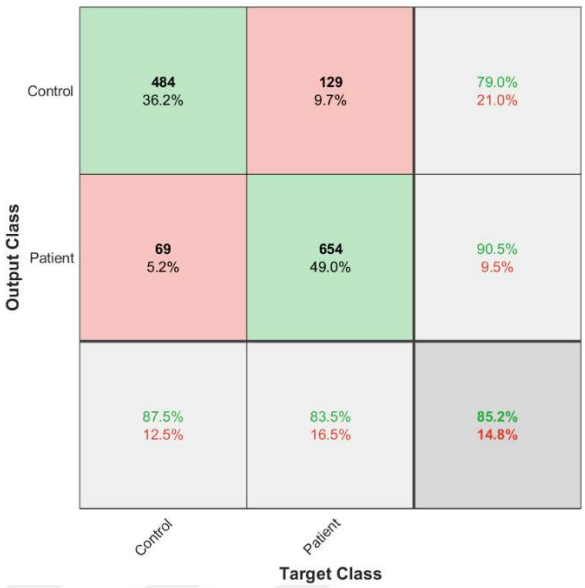
(c)


Control
Patient
Output Class
459
34.4%
62
4.6%
88.1%
11.9%
94
7.0%
721
54.0%
88.5%
11.5%
83.0%
17.0%
92.1%
7.9%
88.3%
11.7%
Control
Patient
Target Class

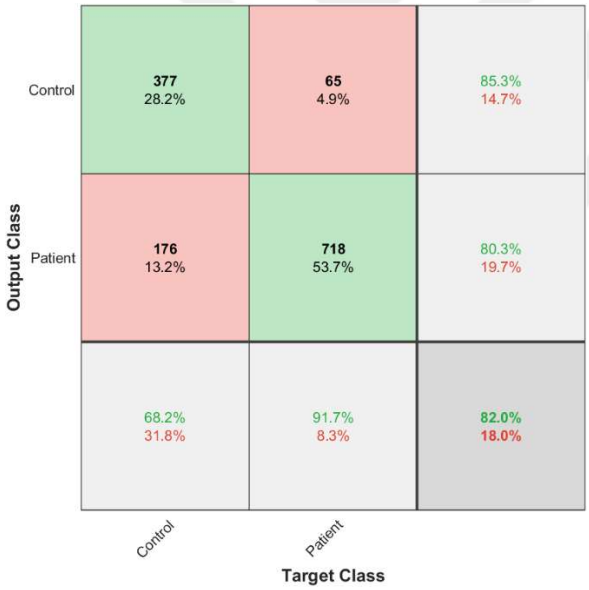
(d)


Control
Patient
Output Class
465
34.8%
101
7.6%
82.2%
17.8%
88
6.6%
682
51.0%
88.6%
11.4%
84.1%
15.9%
87.1%
12.9%
85.9%
14.1%
Control
Patient
Target Class

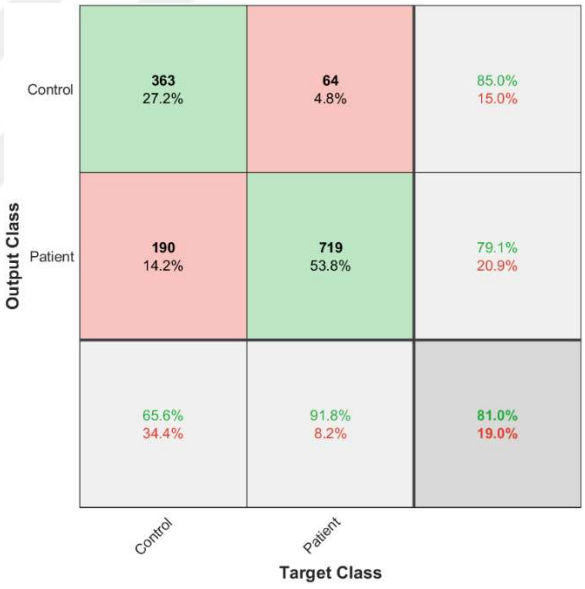
(e)


Control
Patient
Output Class
484
36.2%
129
9.7%
79.0%
21.0%
69
5.2%
654
49.0%
90.5%
9.5%
87.5%
12.5%
83.5%
16.5%
85.2%
14.8%
Control
Patient
Target Class

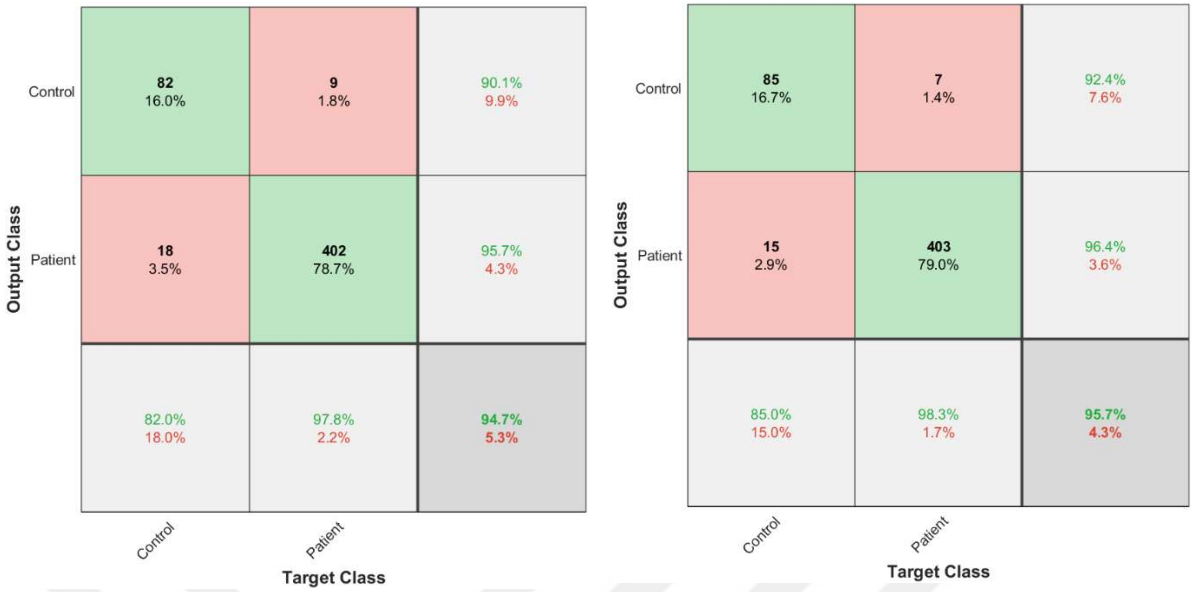
(f)


Control
Patient
Output Class
377
28.2%
65
4.9%
85.3%
14.7%
176
13.2%
718
53.7%
80.3%
19.7%
68.2%
31.8%
91.7%
8.3%
82.0%
18.0%
Control
Patient
Target Class

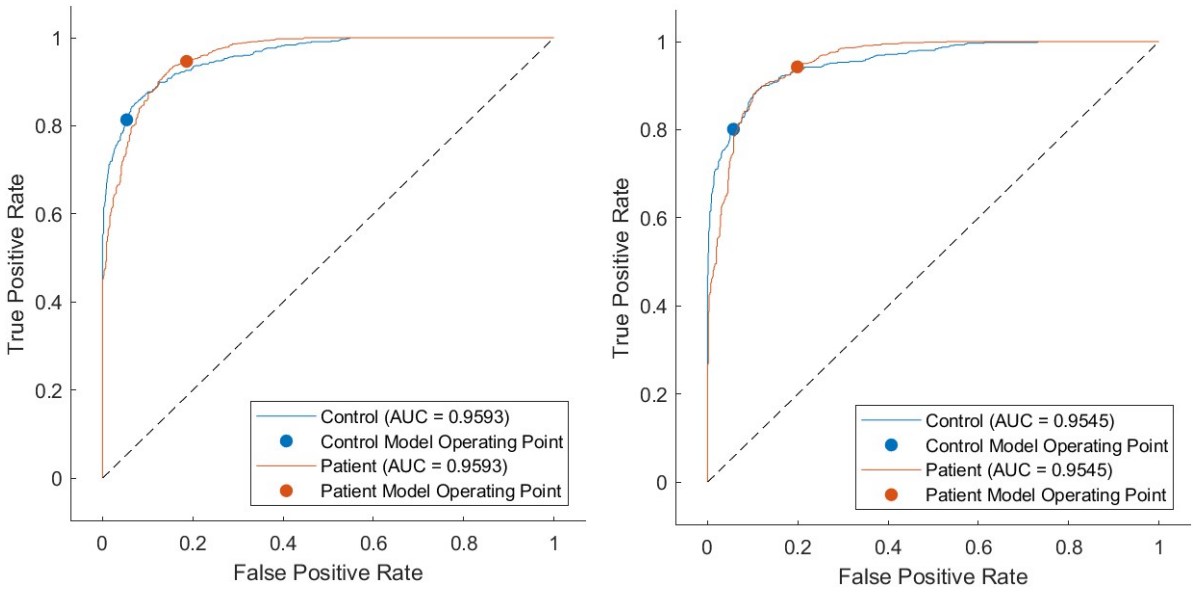
(g)

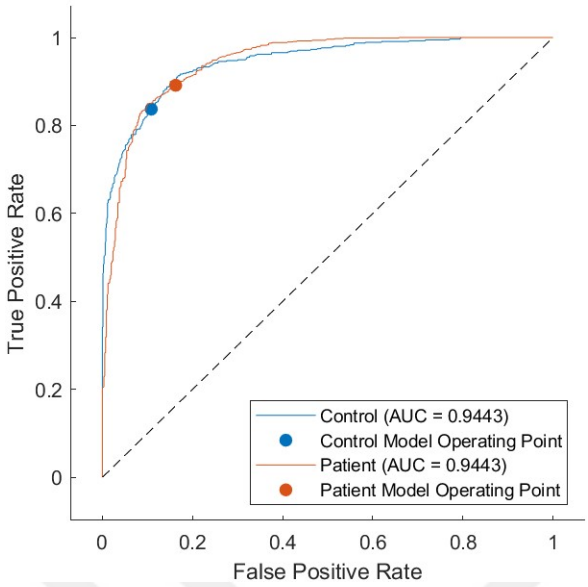

Control
Patient
Output Class
363
27.2%
64
4.8%
85.0%
15.0%
190
14.2%
719
53.8%
79.1%
20.9%
65.6%
34.4%
91.8%
8.2%
81.0%
19.0%
Control
Patient
Target Class

(h)

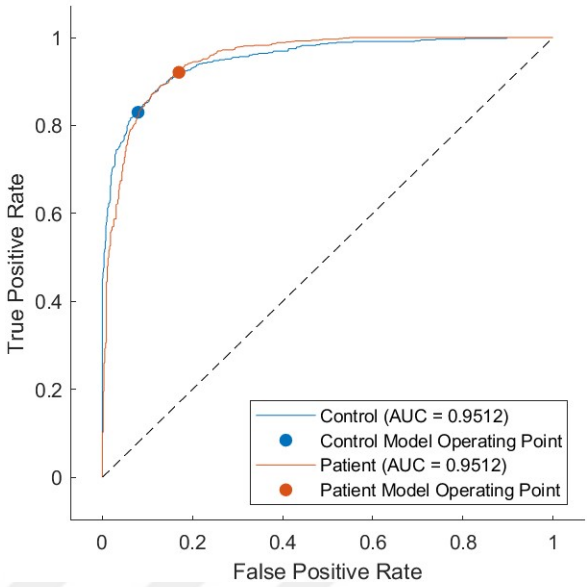


Şekil 4.25: GoogleNet mimarisinde CWT Bump yaklaşımı için; beyin bölgeleri içinde en iyi sonuç veren kanalların Validasyon ve Test karmaşıklık matrisleri; ön beyin (anterior) bölgesi için; F4 kanalı Validasyon (a) ve Test (b) matrisi; merkez (central) beyin bölgesi için; C3 kanalı Validasyon (c) ve Test (d) matrisi, sol temporal (temporal left) beyin bölgesi için; T5 kanalı Validasyon (e) ve Test (f) matrisi, sağ temporal (temporal right) beyin bölgesi için; T6 kanalı Validasyon (g) ve Test (h) matrisi ve arka (posterior) beyin bölgesi için; P4 kanalı Validasyon (i) ve Test (j) matrisi.

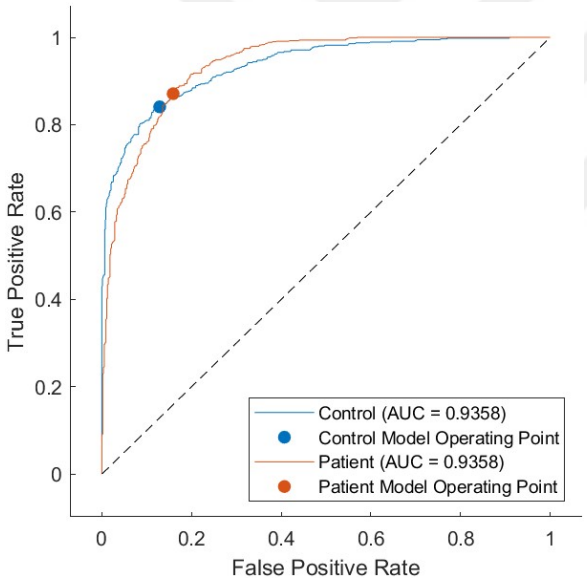



True Positive Rate
False Positive Rate
Control (AUC = 0.9443)
Control Model Operating Point
Patient (AUC = 0.9443)
Patient Model Operating Point

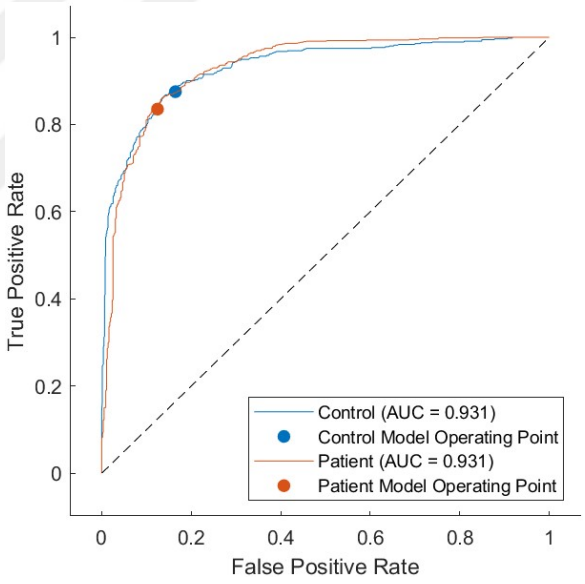
(c)


True Positive Rate
False Positive Rate
Control (AUC = 0.9512)
Control Model Operating Point
Patient (AUC = 0.9512)
Patient Model Operating Point

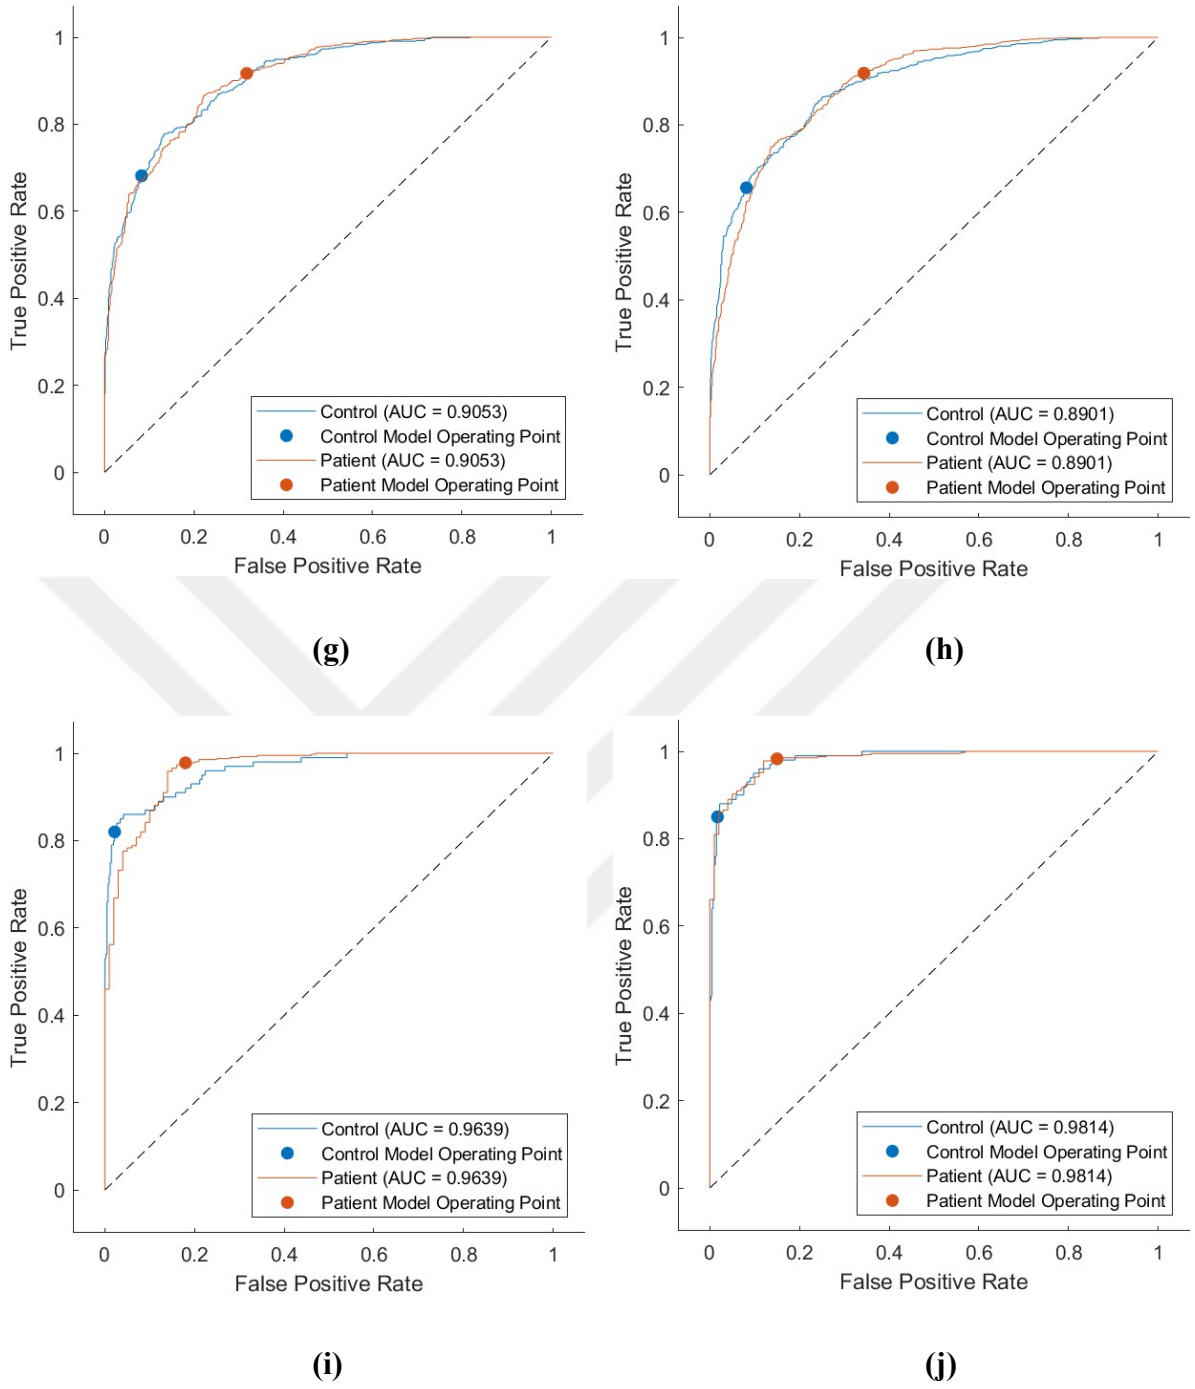
(d)


True Positive Rate
False Positive Rate
Control (AUC = 0.9358)
Control Model Operating Point
Patient (AUC = 0.9358)
Patient Model Operating Point

(e)


True Positive Rate
False Positive Rate
Control (AUC = 0.931)
Control Model Operating Point
Patient (AUC = 0.931)
Patient Model Operating Point

(f)



Şekil 4.26: GoogleNet mimarisinde CWT Bump yaklaşımı için; beyin bölgeleri içinde en iyi sonuç veren kanalların Validasyon ve Test ROC eğrileri; ön beyin (anterior) bölgesi için; F4 kanalı Validasyon (a) ve Test (b) ROC eğrisi; merkez (central) beyin bölgesi için; C3 kanalı Validasyon (c) ve Test (d) ROC eğrisi, sol temporal (temporal left) beyin bölgesi için; T5 kanalı Validasyon (e) ve Test (f) ROC eğrisi, sağ temporal (temporal right) beyin bölgesi için; T6 kanalı Validasyon (g) ve Test (h) ROC eğrisi ve arka (posterior) beyin bölgesi için; P4 kanalı Validasyon (i) ve Test (j) ROC eğrisi.

4.2.6. DarkNet Mimarisinin AH/KG Sınıflandırmasına Etkisi

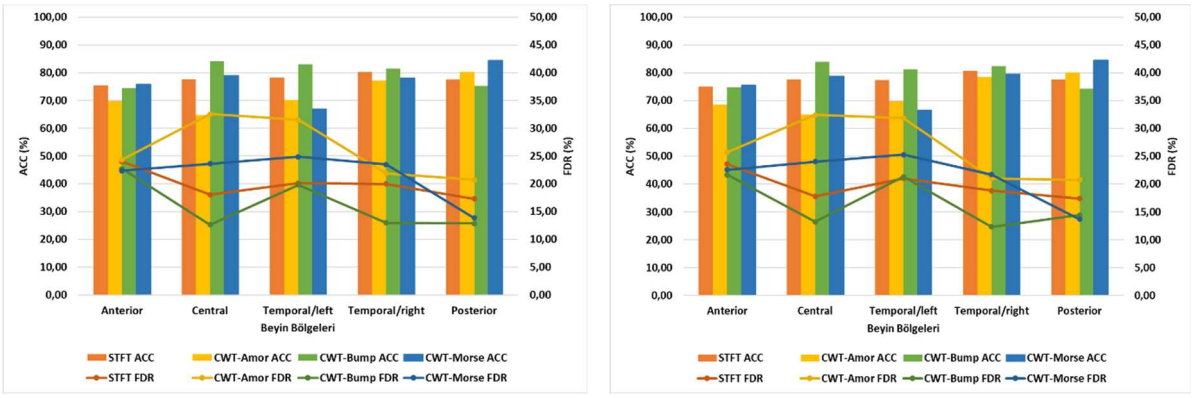
Bu bölümde önceki bölümlerde bulunan diğer mimari modellerinde uygulandığı gibi, 15 AH hastasının ve 11 sağlıklı kontrol gönüllüsünün 19 farklı kanaldan kaydedilen EEG verilerinin, STFT ve CWT Amor, CWT Bump ve CWT Morse yaklaşımları kullanılarak elde edilen zaman-frekans gösterimlerinin DarkNet mimarisi ile eğitilmesi sonucu bu derin öğrenme mimarisi için AH/KG sınıflandırmasında uygulanabilecek en uygun zaman-frekans yaklaşımı tespit edilmeye çalışılmıştır. Mimaride görüntülerin %70'i eğitim setine (train), %15'i doğrulama setine (validation) ve kalan %15'i test setine ayrılarak ayrılarak eğitim bitiminde her kanal için; eğitim ilerlemesi (training progress) grafiği, validasyon ve test olmak üzere iki adet karmaşıklık matrisi ve iki adet ROC eğrisi elde edilmiştir. Tablo 4.29'da DarkNet mimarisi için tüm zaman-frekans yaklaşımlarının tüm beyin bölgeleri bazlı ortalama validasyon ACC ve FDR değerleri ve Şekil 4.27(a)'da bu değerlerin grafiksel gösterimleri verilmiştir. Bu sonuçlara göre; beynin posterior (arka) bölgesinden validasyon için ortalama %84,48 ACC değeriyle CWT-Morse, DarkNet mimarisi için validasyon AH-KG sınıflandırma doğruluğu en yüksek olan zaman-frekans yaklaşımıdır.

Tablo 4.29: DarkNet mimarisi için ZF yaklaşımlarının beyin bölgesi bazlı ortalama validasyon sonuçları.

	STFT		CWT-Amor		CWT-Bump		CWT-Morse	
	FDR	**ACC**	**FDR**	**ACC**	**FDR**	**ACC**	**FDR**	**ACC**
Anterior	24,02	75,46	24,34	69,96	22,72	74,34	22,34	75,70
Central	18,03	77,67	32,53	64,77	12,63	84,03	23,63	78,87
Temporal/left	20,10	78,27	31,50	70,00	19,83	82,97	24,87	67,00
Temporal/right	20,00	80,33	21,87	77,23	13,00	81,50	23,47	78,07
Posterior	17,32	77,58	20,74	80,20	12,86	75,32	13,84	***84,48***

Tablo 4.30: DarkNet mimarisi için ZF yaklaşımlarının beyin bölgesi bazlı ortalama test sonuçları.

	STFT		CWT-Amor		CWT-Bump		CWT-Morse	
	FDR	**ACC**	**FDR**	**ACC**	**FDR**	**ACC**	**FDR**	**ACC**
Anterior	23,60	74,98	25,70	68,54	21,68	74,84	22,58	75,40
Central	17,80	77,57	32,43	64,93	13,23	83,87	24,03	78,67
Temporal/left	21,03	77,37	31,80	69,73	21,33	81,23	25,27	66,60
Temporal/right	18,83	80,60	21,00	78,33	12,33	82,37	21,70	79,43
Posterior	17,42	77,54	20,74	80,20	14,44	74,36	13,72	***84,46***



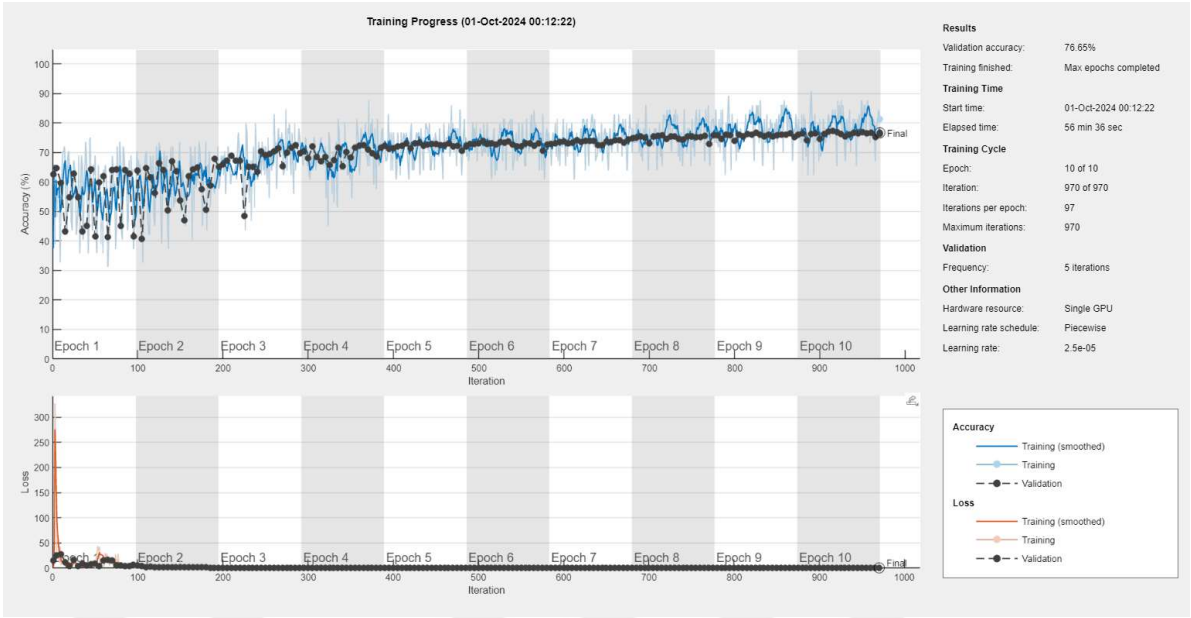
(a) **(b)**

Şekil 4.27: Beyin Bölgesi Bazlı DarkNet Validasyon (a) ve Test (b) Sonuçları

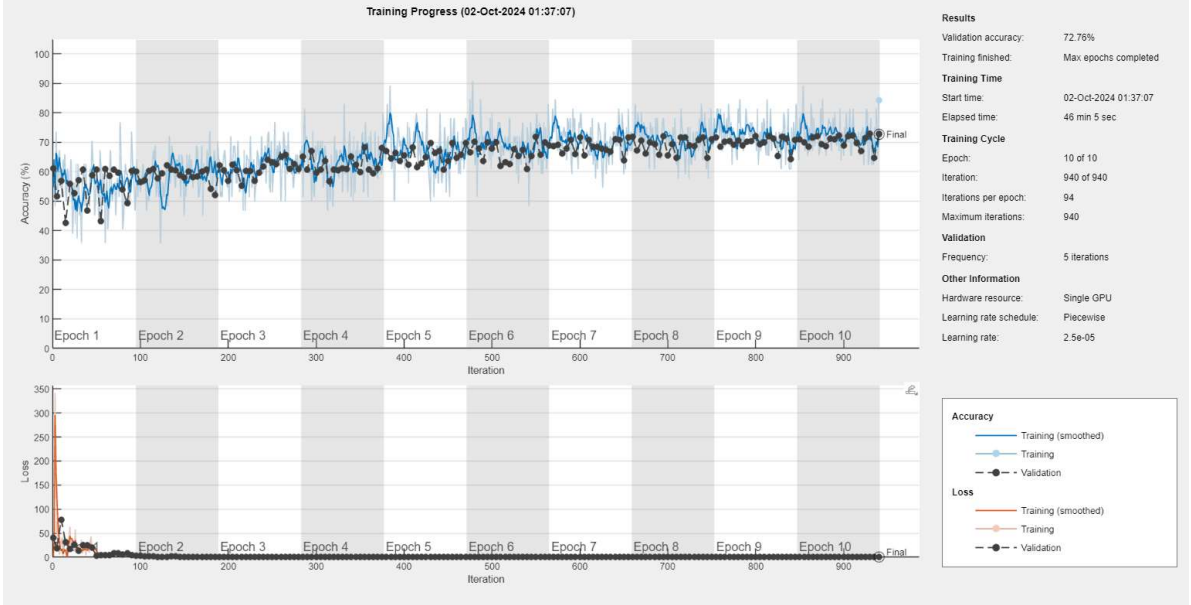
Şekil 4.27(b)'de DarkNet mimarisi için tüm zaman-frekans yaklaşımlarının beyin bölgesi bazlı ortalama test ACC ve FDR değerlerinin grafiksel gösterimi verilmiştir. Bu sonuçlara göre; beynin beynin posterior (arka) bölgesinden %84,46 ortalama test ACC değeriyle CWT-Morse, DarkNet mimarisi için validasyonda olduğu gibi testte de AH-KG sınıflandırma doğruluğu en yüksek olan zaman-frekans yaklaşımıdır.

4.2.6.1. DarkNet Mimarisinin Beyin Bölgeleri Bazlı En İyi Sonuç Veren Kanallara Ait Eğitim İlerlemesi, Validasyon ve Test İçin Karmaşıklık Matrisi ve ROC Eğrisi Görselleri

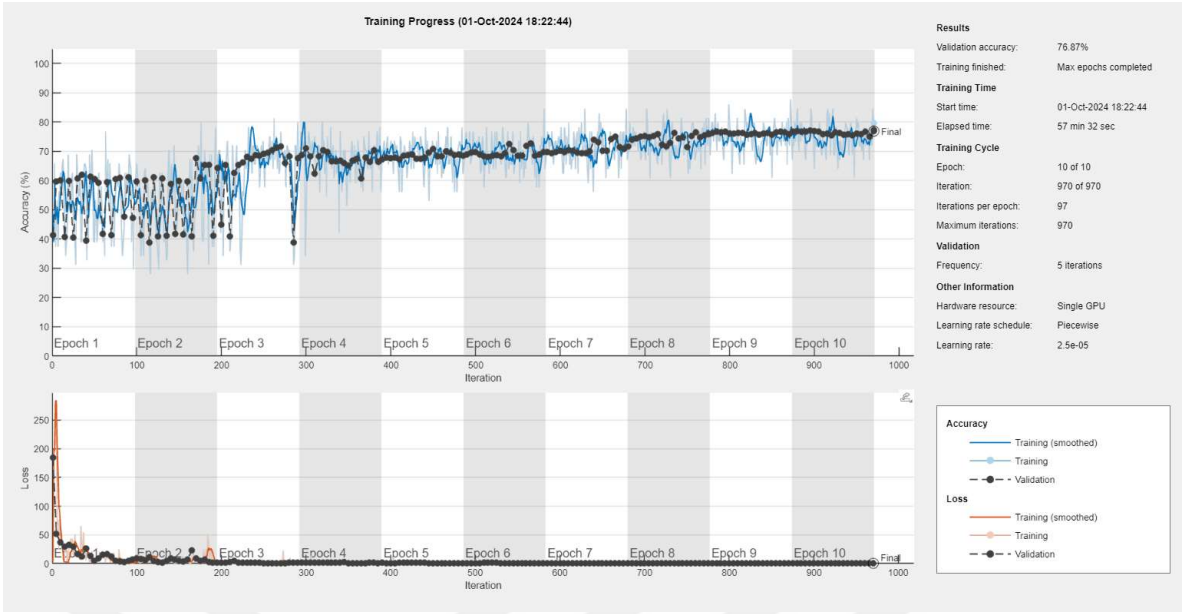
DarkNet mimarisinin zaman-frekans yaklaşımları içinde validasyon için en iyi sonuç veren kanal CWT Amor yaklaşımı ile beynin posterior bölgesinden %92,4 ACC değerine sahip P4 kanalıdır. Bu bölümde, DarkNet mimarisi için en yüksek kanal değeri CWT Amor yaklaşımıyla elde edildiğinden bu yaklaşımından elde edilen ve beyin bölgeleri içinde en yüksek sonuçlara sahip kanal sonuçları yer almaktadır. Beş beyin bölgesi (ön (anterior) beyin bölgesi için F4 kanalı, merkez (central) beyin bölgesi için Cz kanalı, sol temporal (temporal left) beyin bölgesi için F7 kanalı, sağ temporal (temporal right) beyin bölgesi için F8 kanalı ve arka (posterior) beyin bölgesi için P4 kanalı) bazlı en iyi kanalların eğitim ilerlemesi (training progress), validasyon ve test karmaşıklık matrisi ve ROC eğrisi görselleri aşağıda detaylı şekilde bulunmaktadır (Şekil 4.28, Şekil 4.29, Şekil 4.30).


Training Progress (01-Oct-2024 00:12:22)
Accuracy (%)
Epoch 1
Epoch 2
Epoch 3
Epoch 4
Epoch 5
Epoch 6
Epoch 7
Epoch 8
Epoch 9
Epoch 10
Final
Iteration
Loss
Results
Validation accuracy: 76.65%
Training finished: Max epochs completed
Training Time
Start time: 01-Oct-2024 00:12:22
Elapsed time: 56 min 36 sec
Training Cycle
Epoch: 10 of 10
Iteration: 970 of 970
Iterations per epoch: 97
Maximum iterations: 970
Validation
Frequency: 5 iterations
Other Information
Hardware resource: Single GPU
Learning rate schedule: Piecewise
Learning rate: 2.5e-05
Accuracy
Training (smoothed)
Training
Validation
Loss
Training (smoothed)
Training
Validation

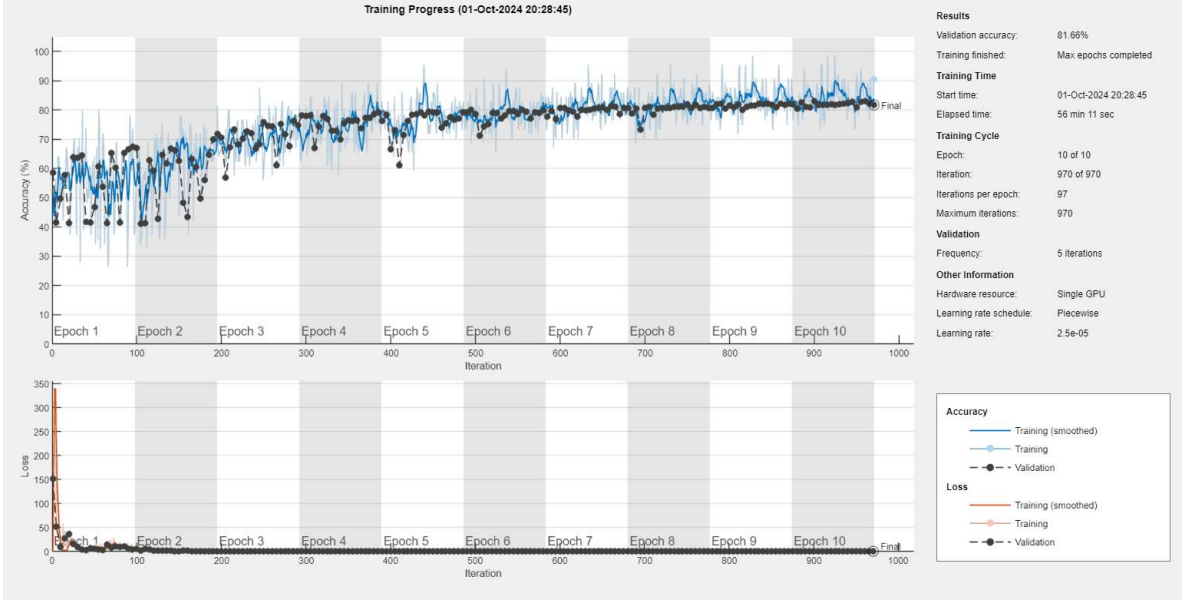
(a)


Training Progress (02-Oct-2024 01:37:07)
Accuracy (%)
Epoch 1
Epoch 2
Epoch 3
Epoch 4
Epoch 5
Epoch 6
Epoch 7
Epoch 8
Epoch 9
Epoch 10
Final
Iteration
Loss
Results
Validation accuracy: 72.76%
Training finished: Max epochs completed
Training Time
Start time: 02-Oct-2024 01:37:07
Elapsed time: 46 min 5 sec
Training Cycle
Epoch: 10 of 10
Iteration: 940 of 940
Iterations per epoch: 94
Maximum iterations: 940
Validation
Frequency: 5 iterations
Other Information
Hardware resource: Single GPU
Learning rate schedule: Piecewise
Learning rate: 2.5e-05
Accuracy
Training (smoothed)
Training
Validation
Loss
Training (smoothed)
Training
Validation

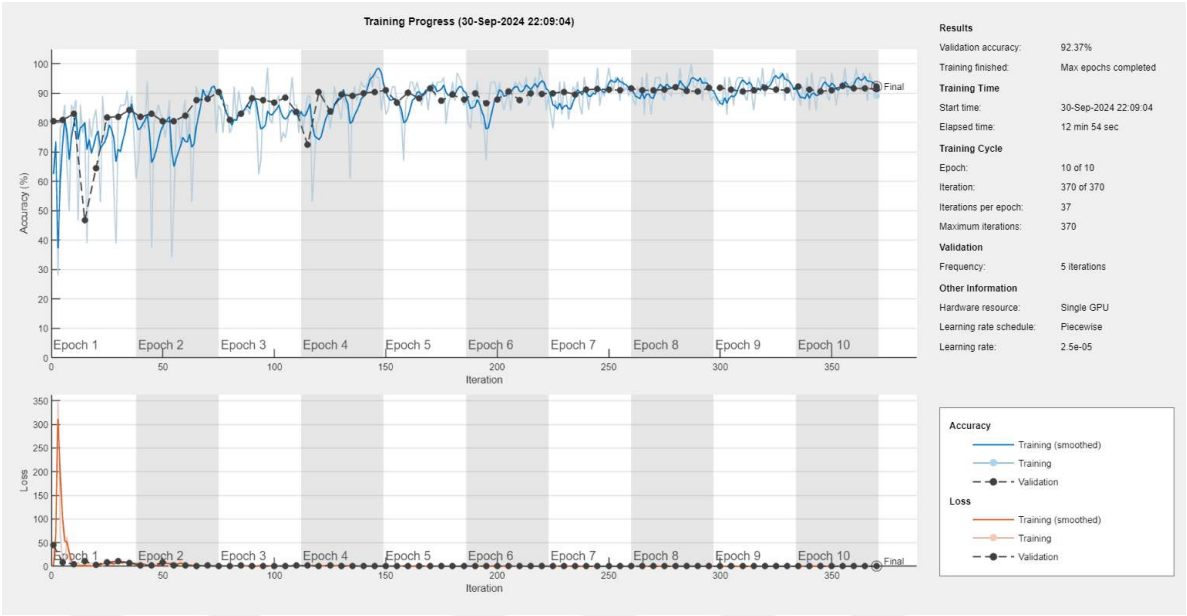
(b)


Training Progress (01-Oct-2024 18:22:44)
Accuracy (%)
Loss
Iteration
Epoch 1
Epoch 2
Epoch 3
Epoch 4
Epoch 5
Epoch 6
Epoch 7
Epoch 8
Epoch 9
Epoch 10
Final
Results
Validation accuracy: 76.87%
Training finished: Max epochs completed
Training Time
Start time: 01-Oct-2024 18:22:44
Elapsed time: 57 min 32 sec
Training Cycle
Epoch: 10 of 10
Iteration: 970 of 970
Iterations per epoch: 97
Maximum iterations: 970
Validation
Frequency: 5 iterations
Other Information
Hardware resource: Single GPU
Learning rate schedule: Piecewise
Learning rate: 2.5e-05
Accuracy
Training (smoothed)
Training
Validation
Loss
Training (smoothed)
Training
Validation

(c)


Training Progress (01-Oct-2024 20:28:45)
Accuracy (%)
Loss
Iteration
Epoch 1
Epoch 2
Epoch 3
Epoch 4
Epoch 5
Epoch 6
Epoch 7
Epoch 8
Epoch 9
Epoch 10
Final
Results
Validation accuracy: 81.66%
Training finished: Max epochs completed
Training Time
Start time: 01-Oct-2024 20:28:45
Elapsed time: 56 min 11 sec
Training Cycle
Epoch: 10 of 10
Iteration: 970 of 970
Iterations per epoch: 97
Maximum iterations: 970
Validation
Frequency: 5 iterations
Other Information
Hardware resource: Single GPU
Learning rate schedule: Piecewise
Learning rate: 2.5e-05
Accuracy
Training (smoothed)
Training
Validation
Loss
Training (smoothed)
Training
Validation

(d)

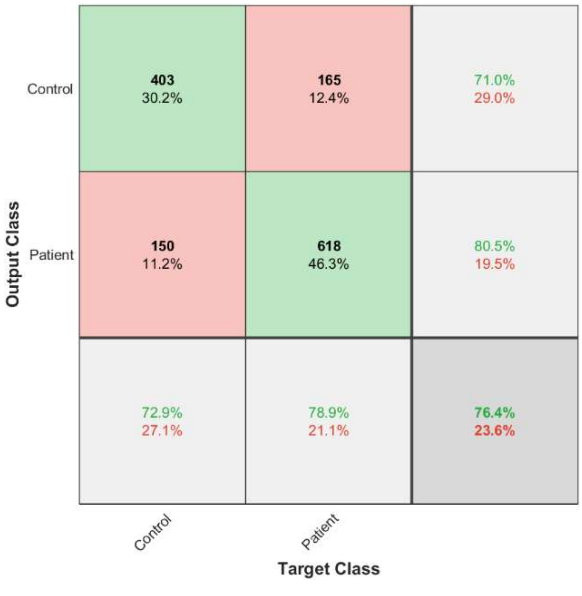


(e)

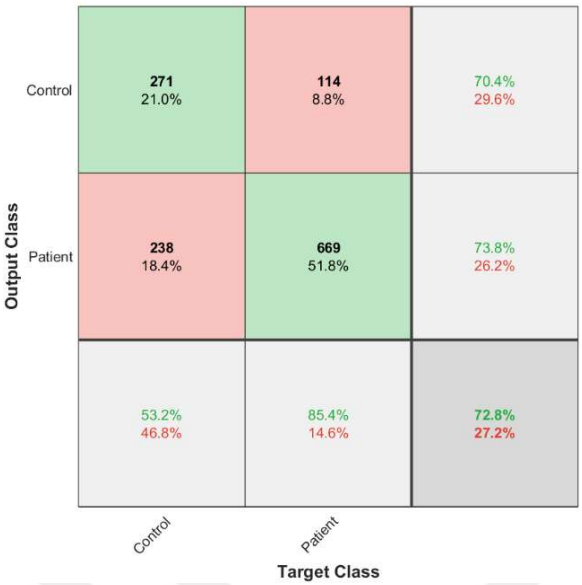
Şekil 4.28: DarkNet mimarisinde CWT Amor yaklaşımı için; beyin bölgeleri içinde en iyi sonuç veren kanalların Training Progress görselleri; ön beyin (anterior) bölgesi için; F4 kanalı (a); merkez (central) beyin bölgesi için; Cz kanalı (b), sol temporal (temporal left) beyin bölgesi için; F7 kanalı (c), sağ temporal (temporal right) beyin bölgesi için; F8 kanalı (d) ve arka (posterior) beyin bölgesi için; P4 kanalı (e).



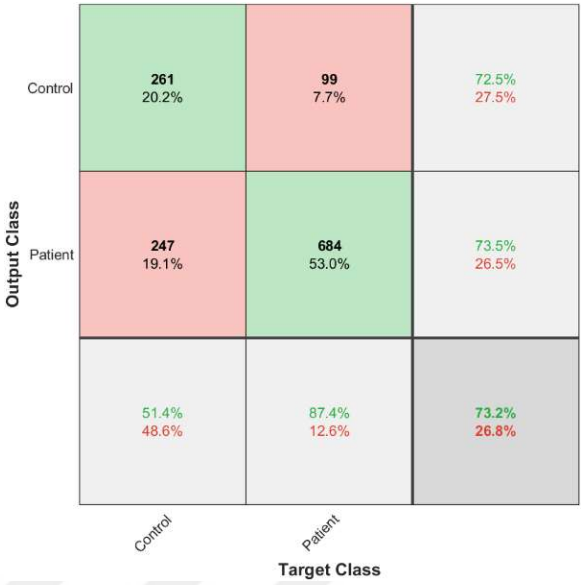
(a)



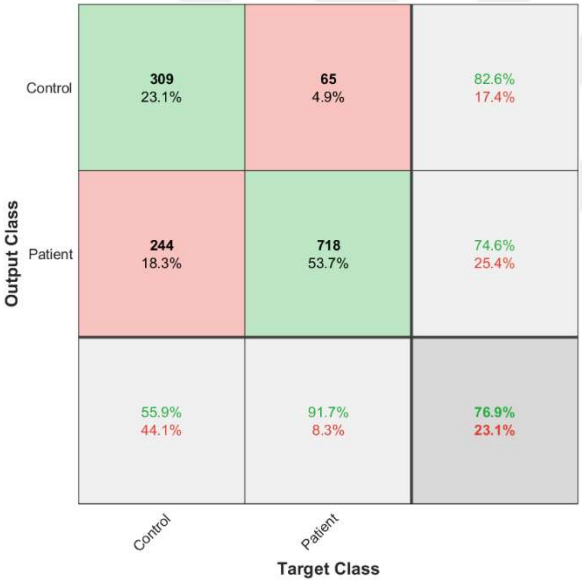
(b)


Control
Patient
Output Class
271
21.0%
114
8.8%
70.4%
29.6%
238
18.4%
669
51.8%
73.8%
26.2%
53.2%
46.8%
85.4%
14.6%
72.8%
27.2%
Control
Patient
Target Class

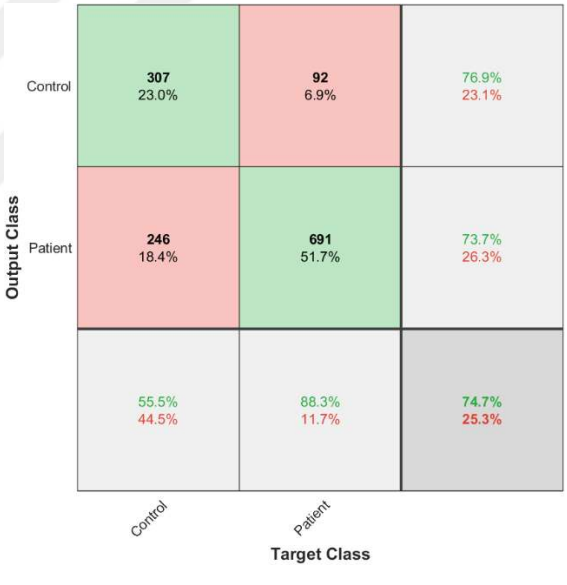
(c)


Control
Patient
Output Class
261
20.2%
99
7.7%
72.5%
27.5%
247
19.1%
684
53.0%
73.5%
26.5%
51.4%
48.6%
87.4%
12.6%
73.2%
26.8%
Control
Patient
Target Class

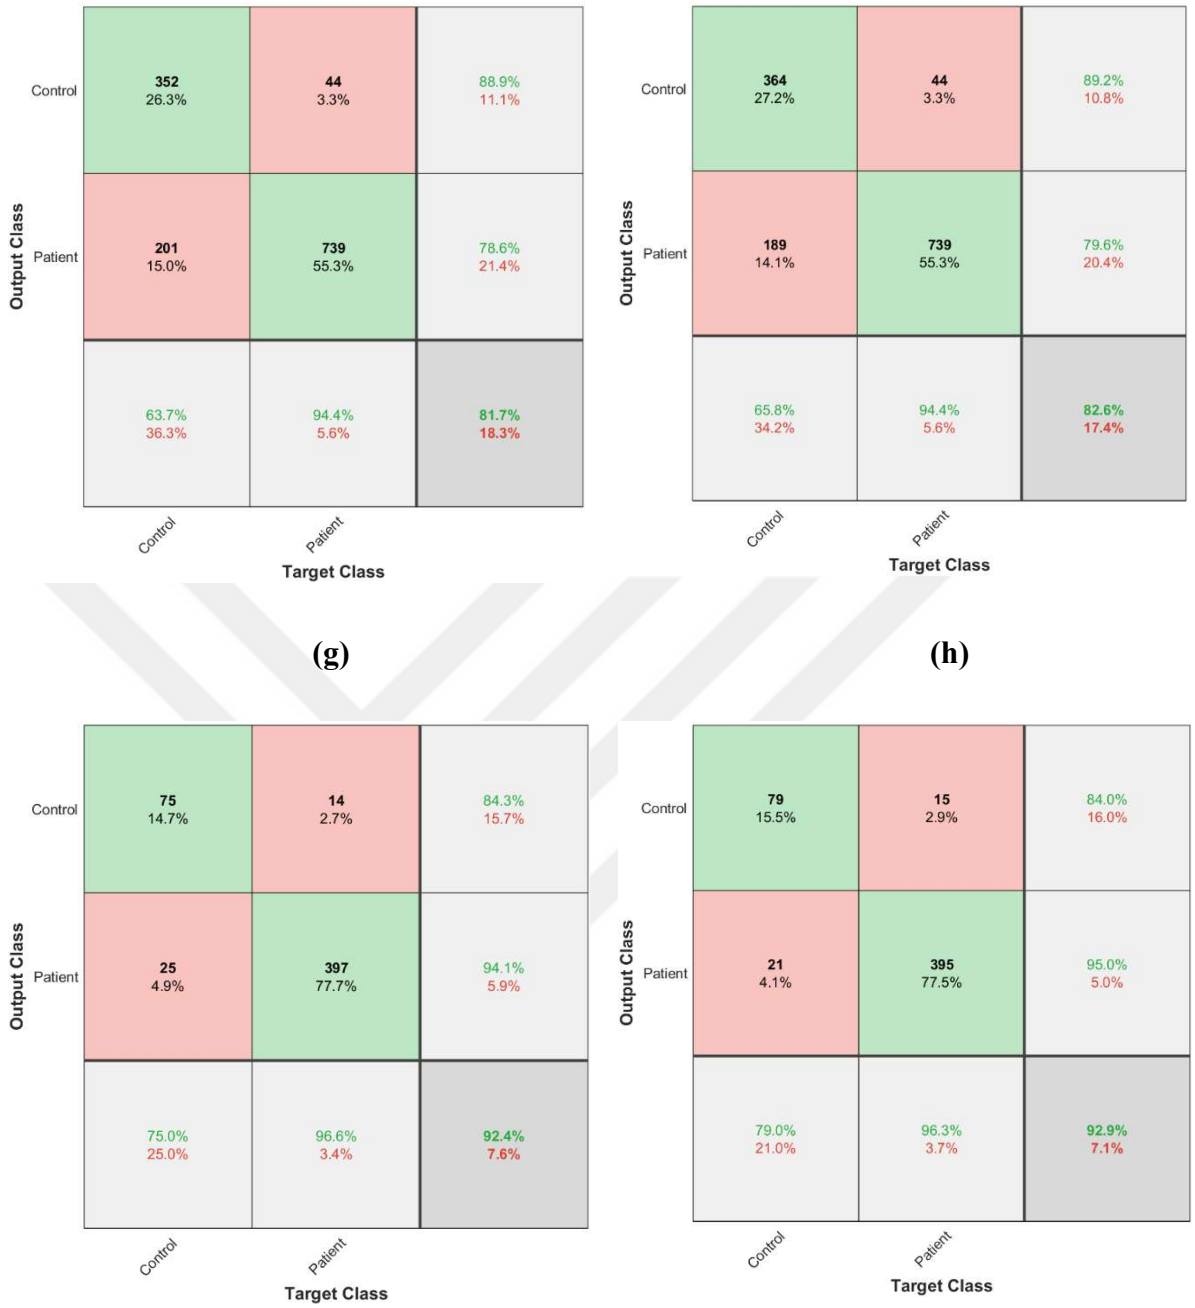
(d)


Control
Patient
Output Class
309
23.1%
65
4.9%
82.6%
17.4%
244
18.3%
718
53.7%
74.6%
25.4%
55.9%
44.1%
91.7%
8.3%
76.9%
23.1%
Control
Patient
Target Class

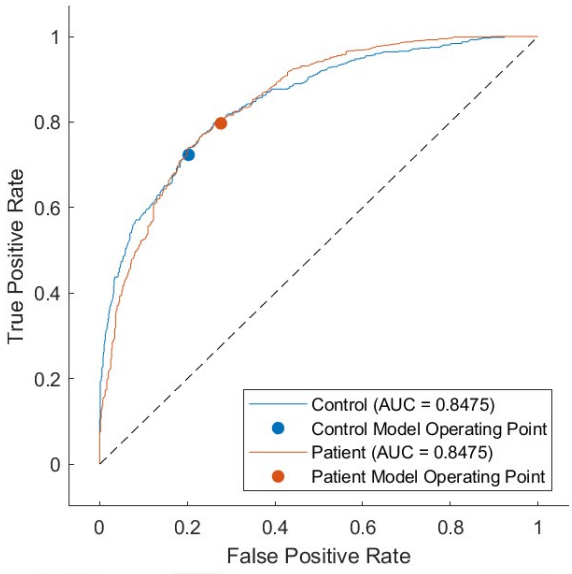
(e)


Control
Patient
Output Class
307
23.0%
92
6.9%
76.9%
23.1%
246
18.4%
691
51.7%
73.7%
26.3%
55.5%
44.5%
88.3%
11.7%
74.7%
25.3%
Control
Patient
Target Class

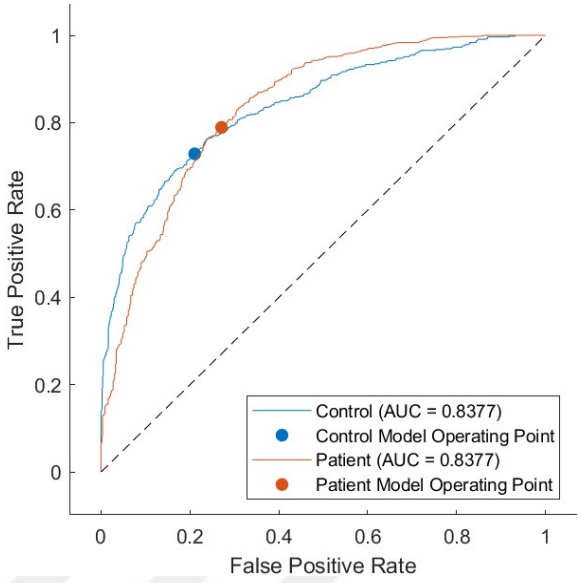
(f)



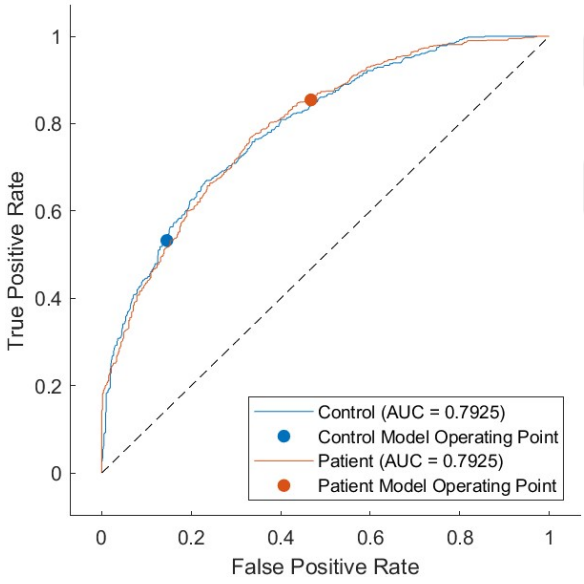
Şekil 4.29: DarkNet mimarisinde CWT Amor yaklaşımı için; beyin bölgeleri içinde en iyi sonuç veren kanalların Validasyon ve Test karmaşıklık matrisleri; ön beyin (anterior) bölgesi için; F4 kanalı Validasyon (a) ve Test (b) matrisi; merkez (central) beyin bölgesi için; Cz kanalı Validasyon (c) ve Test (d) matrisi, sol temporal (temporal left) beyin bölgesi için; F7 kanalı Validasyon (e) ve Test (f) matrisi, sağ temporal (temporal right) beyin bölgesi için; F8 kanalı Validasyon (g) ve Test (h) matrisi ve arka (posterior) beyin bölgesi için; P4 kanalı Validasyon (i) ve Test (j) matrisi.


True Positive Rate
False Positive Rate
Control (AUC = 0.8475)
Control Model Operating Point
Patient (AUC = 0.8475)
Patient Model Operating Point

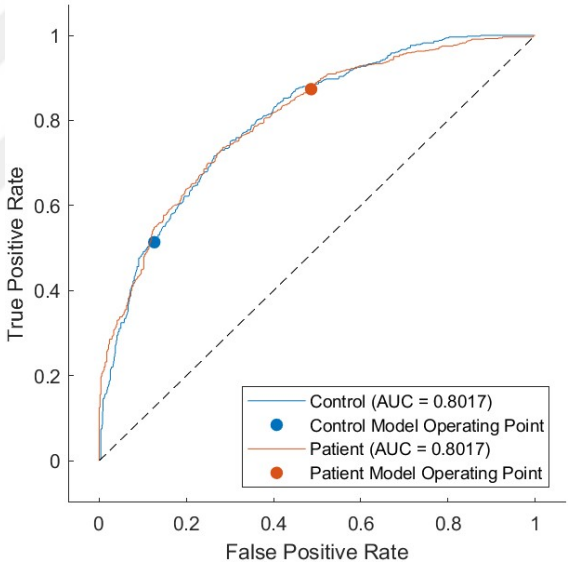
(a)


True Positive Rate
False Positive Rate
Control (AUC = 0.8377)
Control Model Operating Point
Patient (AUC = 0.8377)
Patient Model Operating Point

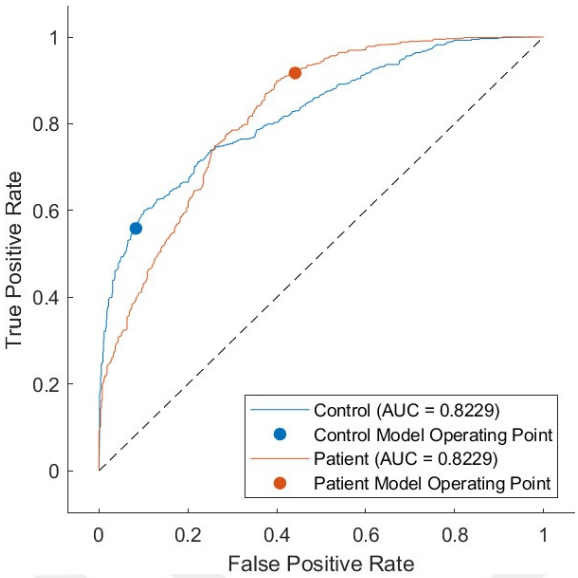
(b)


True Positive Rate
False Positive Rate
Control (AUC = 0.7925)
Control Model Operating Point
Patient (AUC = 0.7925)
Patient Model Operating Point

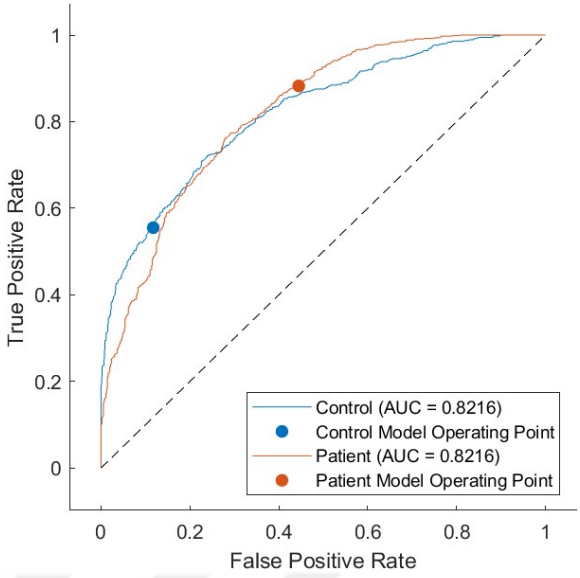
(c)


True Positive Rate
False Positive Rate
Control (AUC = 0.8017)
Control Model Operating Point
Patient (AUC = 0.8017)
Patient Model Operating Point

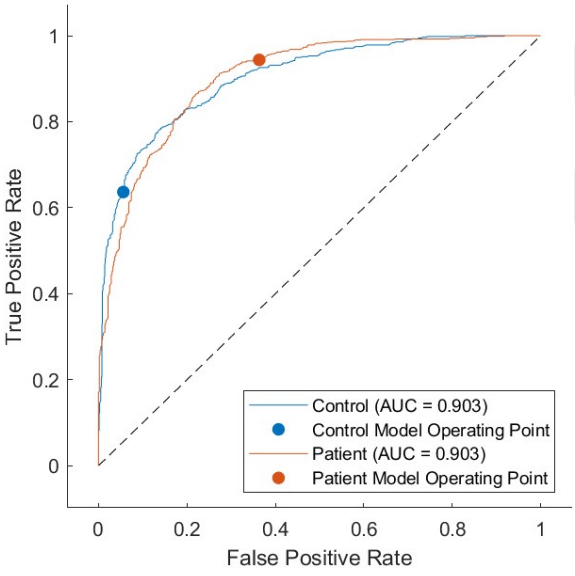
(d)


True Positive Rate
False Positive Rate
Control (AUC = 0.8229)
Control Model Operating Point
Patient (AUC = 0.8229)
Patient Model Operating Point

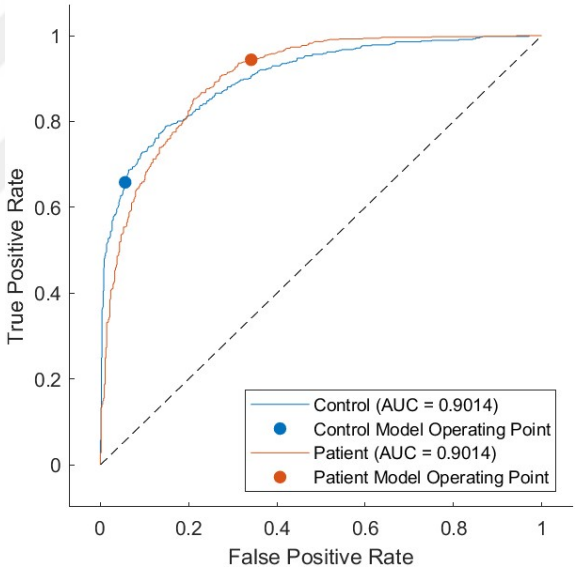
(e)


True Positive Rate
False Positive Rate
Control (AUC = 0.8216)
Control Model Operating Point
Patient (AUC = 0.8216)
Patient Model Operating Point

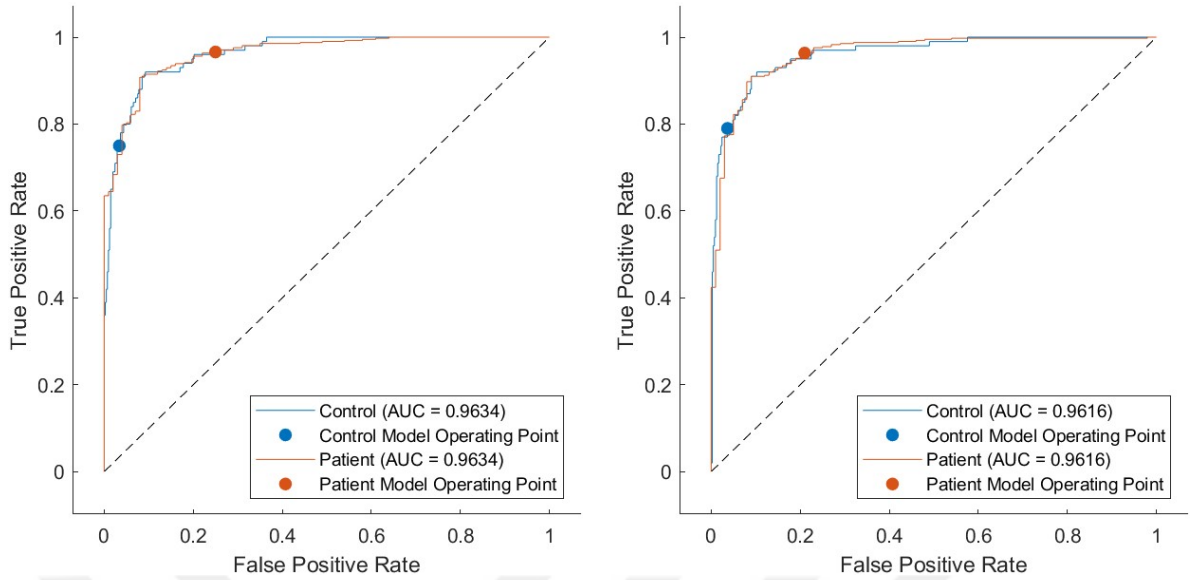
(f)


True Positive Rate
False Positive Rate
Control (AUC = 0.903)
Control Model Operating Point
Patient (AUC = 0.903)
Patient Model Operating Point

(g)


True Positive Rate
False Positive Rate
Control (AUC = 0.9014)
Control Model Operating Point
Patient (AUC = 0.9014)
Patient Model Operating Point

(h)



(i) (j)

Şekil 4.30: DarkNet mimarisinde CWT Amor yaklaşımı için; beyin bölgeleri içinde en iyi sonuç veren kanalların Validasyon ve Test ROC eğrileri; ön beyin (anterior) bölgesi için; F4 kanalı Validasyon (a) ve Test (b) ROC eğrisi; merkez (central) beyin bölgesi için; Cz kanalı Validasyon (c) ve Test (d) ROC eğrisi, sol temporal (temporal left) beyin bölgesi için; F7 kanalı Validasyon (e) ve Test (f) ROC eğrisi, sağ temporal (temporal right) beyin bölgesi için; F8 kanalı Validasyon (g) ve Test (h) ROC eğrisi ve arka (posterior) beyin bölgesi için; P4 kanalı Validasyon (i) ve Test (j) ROC eğrisi.

4.2.7. Tüm Mimariler İçin En iyi Sonuç Veren Kanalların ROC Eğrisi Değerlendirmesi

Aşağıda bulunan tabloda (Tablo 4.32) çalışmada kullanılan bütün mimarilerin en iyi sonuç veren kanallarının validasyon ve test ROC eğrisi grafiklerinden elde edilen hasta ve kontrol deneklerine ait AUC değerleri yer almaktadır. Elde edilen sonuçlara göre; ResNet18 mimarisi CWT Bump yaklaşımıyla beynin posterior bölgesinde bulunan P4 kanalından validasyonda 0,9855 AUC değeri ve testte 0,9846 AUC değeriyle diğerlerinden daha yüksek başarım elde etmiştir.

Tablo 4.31: Tüm mimarilerin en iyi ACC değeri veren kanallarının validasyon ve test için hasta-kontrol AUC değerleri

			Validasyon	Test
CNN Mimarisi	**ZF Yaklaşımı**	**Kanal İsmi**	**AUC Hasta-Kontrol**	**AUC Hasta-Kontrol**
ResNet18	CWT Bump	P4	***0,9855***	***0,9846***
Modifiye ResNet18_1	CWT Bump	P4	0,9718	0,9589
Modifiye ResNet18_2	CWT Bump	P4	0,9510	0,9453
AlexNet	CWT Bump	P4	0,9425	0,9516
GoogleNet	CWT Bump	P4	0,9639	0,9814
DarkNet	CWT Amor	P4	0,9634	0,9616

4.2.8. Tüm Mimariler İçin Beş Beyin Bölgesi Bazlı En İyi Sonuç Veren Kanalların Performans Değerlendirmesi

Aşağıda tüm mimariler için en iyi sonuç veren zaman-frekans yaklaşımlarının beş beyin bölgesi bazlı en yüksek başarım elde edilen kanallar için eğitim ilerlemesi (training progress) grafikleri değerlendirilerek oluşturulmuş ve ACC değerleri, maksimum devir sayıları (max epoch) ve eğitim sürelerinin yer aldığı Tablo 4.32 bulunmaktadır. Bu sonuçlar incelendiğinde en yüksek sınıflandırma doğruluğu değerlerine (validasyon doğruluğu) sahip mimari CWT Bump yaklaşımıyla ResNet18 (%96,87) mimarisidir. Ardından sırasıyla; GoogleNet (%94,72), Modifiye ResNet18_1 (%94,32), Modifiye ResNet18_2 (%93,74), AlexNet (%93,74) ve DarkNet (%92,37) mimarileri gelmektedir. Ancak eğitim süresi baz alındığında Modifiye ResNet18_2 mimarisinin seçimi ile, ResNet18 mimarisi ve diğer tüm mimarilerden çok daha hızlı bir şekilde eğitim sürecini tamamlayarak zamandan oldukça tasarruf edilebileceği görülmektedir. Alzheimer hastalığının teşhis ve tedavi sürecinde erken tanının büyük önemi sebebiyle, AH-KG sınıflandırmasında zaman tasarrufu oldukça değerlidir. Ayrıca Modifiye ResNet18_2 mimarisinin sınıflandırma doğruluğu da diğer mimarilere göre çok düşük değildir.

Eğitim ilerlemesi görselleri incelendiğinde aşırı uyum değerlendirmesi açısından; Modifiye ResNet18_2 mimarisinde eğitim ve validasyon arasındaki makasın açılmadığı, senkronizasyonun diğer mimarilere kıyasla en iyi durumda olduğu ve dolayısıyla çalışmanın aşırı uyuma eğilim göstermediği görülmektedir. DarkNet mimarisinde de eğitim ve validasyon senkronizasyonu sağlanmış olup aradaki makas açılmamıştır. Bu durum, modelin eğitim sürecinin genel olarak dengeli ve istikrarlı bir şekilde ilerlediğini ve modelin aşırı uyuma gitmediğini göstermektedir. AlexNet ve GoogleNet mimarilerinde eğitim ve validasyon arasında çok az bir açıklık olduğu görülmekte ve bu durum modellerin genel performanslarının iyi olduğunu göstermektedir. Bu mimariler için aşırı uyum olasılığı düşüktür ancak tamamen ortadan kalkmamıştır. ResNet18 ve Modifiye ResNet18_2 mimarilerinde ise eğitim ve validasyon senkronizasyonu arasında belirgin fark olduğu yani makasın oldukça açık olduğu görülmektedir. Bu sebeple bu mimari modellerinin aşırı uyuma gitme olasılıkları yüksektir.

Eğitim ilerlemesi görselleri maksimum devir sayıları (max epoch) dikkate alınarak zaman açısından değerlendirildiğinde; eğitimi en hızlı tamamlayan mimarinin Modifiye ResNet18_2 olduğu ve eğitimi en uzun sürede tamamlayan mimarinin ise DarkNet olduğu görülmektedir. DarkNet mimarisi eğitimi en uzun sürede tamamlamasıyla birlikte tüm mimariler içinde en

düşük ACC değerine sahiptir. Modifiye ResNet18_2 mimarisinden sonra sırasıyla eğitimi en hızlı tamamlayan mimariler; AlexNet, Modifiye ResNet18_1, ResNet18 ve GoogleNet olarak sıralanmaktadır. Bu bulgular, çalışmada kullanılan mimarilerin eğitim süreleri ve performansları arasındaki ilişkiyi anlamada önemli bir katkıya sahiptir.

Tüm mimarilerin eğitim ilerlemesi görselleri dikkate alındığında eğitim (training) ve validasyon arasındaki senkronizasyonun en yüksek seviyede Modifiye ResNet18_2 mimarisinde elde edildiği gözlemlenmiştir. Bu değerlendirme Modifiye ResNet18_2'nin genel performansının diğer mimarilere kıyasla daha dengeli ve tutarlı olduğunu ve bu sebeple aşırı öğrenme (overfitting) riskinin daha düşük olabileceğini göstermektedir. Ayrıca tüm mimariler arasında en hızlı eğitim sürecini yine Modifiye ResNet18_2 mimarisi tamamlanmıştır. Modifiye ResNet18_2 mimarisi, ResNet18 ile kıyaslandığında elde edilen ACC değerinden (%96,90) nispeten daha düşük bir ACC değerine (%93,70) sahip olsa da, eğitim ve validasyon süreçleri arasındaki senkronizasyonun yüksek olması ve modelin daha dengeli bir performans sunması, ayrıca eğitim sürecini diğer mimarilere kıyasla en kısa sürede tamamlanması onu AH-KG sınıflandırmasında daha güvenilir ve tutarlı bir model kılmaktadır. Bu sebeple, Modifiye ResNet18_2 mimarisi, uygulama açısından daha uygun ve tercih edilebilir bir alternatif olarak öne çıkmaktadır.

Tablo 4.32: Tüm mimarilerin beyin bölgesi bazlı en iyi sonuçlara sahip kanallarının validasyon ACC değerleri, maksimum devir sayıları (max epoch) ve training progress süreleri.

				Training Progress		
Beyin Bölgesi	**Mimari İsmi**	**ZF Yaklaşımı**	**Kanal**	**ACC**	**Max Epoch**	**Süre**
Anterior (Ön)	ResNet18	CWT Bump	F4	91,09	20	47 dk 2 sn
	Modifiye ResNet18_1	CWT Bump	F4	84,43	10	21 dk 23 sn
	Modifiye ResNet18_2	CWT Bump	F4	85,85	10	13 dk 22 sn
	AlexNet	CWT Bump	F4	85,03	20	38 dk 2 sn
	GoogleNet	CWT Bump	F4	89,15	10	25 dk 26 sn
	DarkNet	CWT Amor	F4	76,65	10	56 dk 36 sn
Central (Merkez)	ResNet18	CWT Bump	C3	91,54	20	45 dk 24 sn
	Modifiye ResNet18_1	CWT Bump	C3	85,63	10	21 dk 15 sn
	Modifiye ResNet18_2	CWT Bump	C3	83,83	10	13 dk 29 sn
	AlexNet	CWT Bump	C3	85,63	20	29 dk 59 sn
	GoogleNet	CWT Bump	C3	86,90	10	21 dk 53 sn
	DarkNet	CWT Amor	Cz	72,76	10	46 dk 5 sn
Temporal Left (Temporal Sol)	ResNet18	CWT Bump	T5	90,42	20	47 dk 21 sn
	Modifiye ResNet18_1	CWT Bump	T5	82,86	10	13 dk 40 sn
	Modifiye ResNet18_2	CWT Bump	T5	83,91	10	13 dk 16 sn
	AlexNet	CWT Bump	T5	84,36	20	38 dk 9 sn
	GoogleNet	CWT Bump	T5	85,85	10	25 dk 17 sn
	DarkNet	CWT Amor	F7	76,87	10	57 dk 32 sn
Temporal Right (Temporal Sağ)	ResNet18	CWT Bump	T6	88,92	20	46 dk 55 sn
	Modifiye ResNet18_1	CWT Bump	F8	81,36	10	21 dk 10 sn
	Modifiye ResNet18_2	CWT Bump	T6	79,49	10	13 dk 23 sn
	AlexNet	CWT Bump	F8	83,98	20	38 dk 51 sn
	GoogleNet	CWT Bump	T6	81,96	10	26 dk 16 sn
	DarkNet	CWT Amor	F8	81,66	10	56 dk 11 sn
Posterior (Arka)	ResNet18	CWT Bump	P4	96,87	20	11 dk 11 sn
	Modifiye ResNet18_1	CWT Bump	P4	94,32	10	4 dk 7 sn
	Modifiye ResNet18_2	CWT Bump	P4	93,74	10	2 dk 42 sn
	AlexNet	CWT Bump	P4	93,74	20	8 dk 0 sn
	GoogleNet	CWT Bump	P4	94,72	10	6 dk 21 sn
	DarkNet	CWT Amor	P4	92,37	10	12 dk 54 sn

5. TARTIŞMA

Demansın en yaygın türü olan Alzheimer hastalığı, beyin hücrelerinin dejenerasyonu ve ölümüyle karakterize edilen ilerleyici bir nörodejeneratif hastalıktır. Genel olarak zihinsel işlevlerde azalma, hafıza kaybı, konuşma problemleri, günlük işlerde zorlanma ve davranışsal değişikliklerle başlar. Hastalık ilerledikçe, günlük yaşam rutinlerini yerine getirmek zorlaşır ve bağımsız yaşama yeteneği kaybedilebilir.

Alzheimer hastalığının şu an için bilinen kesin bir tedavisi yoktur, ancak bazı semptomları hafifletebilecek ve hastalığın ilerlemesini yavaşlatabilecek bazı tedavi yöntemleri bulunmaktadır. Bu sebeple Alzheimer hastalığının erken teşhisi hastanın yaşam kalitesinin sürdürülmesi ve hastalığın yönetimi açısından oldukça önemlidir.

Son zamanlarda düşük maliyetli olması, kolay uygulanabilir olması, gerçek zamanlı bilgiler sunması ve invazif olmaması gibi avantajlarından dolayı EEG uygulaması, Alzheimer hastalığının teşhisinde sıkça tercih edilen klinik araçlardan biri olmuştur. Literatür incelemesinden de anlaşılacağı üzere Alzheimer hastalığının tespitinde, EEG verilerinin zaman-frekans temsillerinin derin öğrenme mimarileri ile eğitimi sonucu oldukça başarılı sonuçlar elde edilmiştir. Sürekli güncellenen teknolojik gelişmelerle birlikte Alzheimer hastalığının teşhis ve tedavisinde yüksek başarım oranlarına sahip umut verici çalışmaların artması beklenmektedir.

EEG verilerinin zaman frekans temsillerinin derin öğrenme mimarileri ile analizi nörodejeneratif hastalıkların teşhis ve tedavisinde önemli bir potansiyele sahiptir. Derin öğrenme mimarileri, uzun iterasyon süreleri nedeniyle sınıflandırma aşamasında uzun zaman alabilir ancak bu dezavantajına rağmen klasik makine öğrenme algoritmalarına göre karmaşık problemler ve büyük veri kümeleri için ham verilerden otomatik olarak özellik çıkarma yeteneğiyle EEG verilerinden Alzheimer hastalığının teşhisi konusunda son zamanlarda yoğun olarak tercih edilmektedir. Derin ağlar tarafından yapılan otomatik özellik çıkarımı, manuel özellik çıkarımına umut verici bir alternatiftir.

Tavares ve arkadaşları [51], EEG'nin farklı frekans bantlarının güç spektral yoğunluğunu (PSD) sekiz farklı makine öğrenimi algoritmasına input olarak kullanarak %95,60'lık bir ortalama sınıflandırma doğruluk oranı elde etmişlerdir. Tzimourta ve arkadaşları [31], Alzheimer hastalığını (AH) tespit etmek amacıyla EEG kayıtlarındaki çeşitli istatistiksel ve spektral özellikleri inceleyerek bu özelliklerden Random Forest (Rastgele Orman) sınıflandırıcısını eğitmek ve test etmek için bir özellik vektörü oluşturmuşlar ve çalışmaları sonucunda tüm beyin sınıflandırması için %88,79-%96,78 aralığında doğruluk oranına ulaşmışlardır. Ancak klasik makine öğrenimi algoritmaları iyi performans elde etmek için çoğunlukla karmaşık özellik mühendisliği (FE) gerektirir. Bu durum araştırmacıların orijinal EEG'yi incelemek ve uygun özellikleri çıkarmak için önemli bir zaman harcaması gerektiği anlamına gelir. Makine öğreniminin bir alt kümesi olan derin öğrenme, özellik mühendisliğinin otomasyonunu gerçekleştirmek için sinir ağı ve gizli katmanlar kullanarak zaman ve enerjiden büyük ölçüde tasarruf sağlar. Ayrıca, yapay olarak seçilen özelliklerin, EEG verilerindeki önemli bilgilerin kaybına sebep olma riski vardır. Derin öğrenme algoritması EEG verilerini daha etkin bir şekilde kullanabilir ve algoritmanın sağlamlığını artırabilir. Bu sebeplerden dolayı bu tez çalışmasında derin öğrenme mimarileri kullanılmıştır.

Bu çalışmada erken evre AH hastalarına ve sağlıklı kontrol grubuna ait EEG segmentlerinin, Kısa Zamanlı Fourier Dönüşümü (STFT) ve Sürekli Dalgacık Dönüşümü (CWT)'nün üç çeşidi olan Bump, Amor ve Morse ile spektrogram ve skalogram görüntüleri elde edilmiştir. Elde edilen görüntüler Resnet18, Modifiye ResNet18_1, Modifiye ResNet18_2, AlexNet, GoogleNet ve DarkNet Evrişimli Sinir Ağı (CNN) mimarileri ile eğitilerek hangi CNN mimarisinin hangi zaman-frekans yaklaşımı ile daha iyi ve etkili sonuç verdiğinin tespiti yapılmaya çalışılmıştır. Tüm mimarilerin ortalama validasyon ve test sonuçları değerlendirildiğinde (Tablo 4.1 – Tablo 4.16), en yüksek sınıflandırma başarım oranlarının CWT Bump zaman-frekans yaklaşımıyla elde edildiği gözlemlenmektedir. ResNet18 mimarisi, kanal bazlı değerlendirmede ortalama validasyon için %88,11 ACC ve %90,23 F1 Skoru değerleriyle CWT Bump yaklaşımıyla diğer zaman-frekans yaklaşımlarını geride bırakarak en yüksek başarım oranını elde etmiştir. Kanal bazlı değerlendirmede ortalama test için de %88,37 ACC ve %90,42 F1 Skoru değerleriyle CWT Bump ResNet18 mimarisi için diğer zaman frekans yaklaşımlarından daha iyi sonuç vermiştir. Resnet18'in kanal bazlı validasyon ve test sonuçlarına göre; beynin posterior (arka) bölgesinde bulunan P4 kanalından CWT Bump yaklaşımı ile %96,90 validasyon ve %95,90 test değerleriyle diğer kanallardan daha iyi sonuç

elde edilmiştir. Tablo 4.32'de yer alan ve eğitim ilerlemesi grafiklerinden elde edilen sonuçlar incelendiğinde, mimarilerin kanal bazlı validasyon doğruluk (ACC) değerlerine göre en yüksekten başlayarak oluşturulan sıralama şu şekildedir; ResNet18 (%96,87), GoogleNet (%94,72), Modifiye ResNet18_1 (%94,32), Modifiye ResNet18_2 (%93,74), AlexNet (%93,74) ve DarkNet (%92,37).

Ancak klasik ResNet18 mimarisinin modifiye edilmesiyle elde edilen Modifiye ResNet18_2 mimarisi, ResNet18 ile kıyaslandığında elde edilen ACC değerinden (%96,90) nispeten daha düşük bir ACC değerine (%93,70) sahip olsa da, Modifiye ResNet18_2 mimarisinin sonuçları incelendiğinde; eğitim ilerlemesi (training progress) grafiklerine göre mimari aşırı uyum (overfitting) göstermeden başarılı bir şekilde sonuçlanmış ve zamanlama olarak da diğer mimarilerden çok daha hızlı sonuç vermiştir. Erken teşhisin hayati önem taşıdığı Alzheimer hastalığı için, zamanlama ve dengeli performans açısından diğer mimarilerden daha iyi sonuçlara sahip olan Modifiye ResNet18_2 mimarisi, AH-KG sınıflandırmasında daha güvenilir ve tutarlı bir model olarak öne çıkmakta ve uygulama açısından daha uygun ve tercih edilebilir bir alternatif olmaktadır.

Tez çalışması kapsamında elde edilen tüm sonuçlar, EEG verilerini kullanarak AH teşhisi yapmak amaçlı yapılan en güncel çalışmaların bulgularıyla karşılaştırılmıştır. Tablo 5.1'de, çalışmalar ve deneysel sonuçları hakkında bir takım bilgiler yer almaktadır. Bu yaklaşımlar, makine öğrenmesi tabanlı yöntemleri [29, 31, 43, 51], derin öğrenme tabanlı [18, 50, 54, 55, 56] ve hibrit olarak önerilen (makine öğrenmesi ve derin öğrenme tabanlı) yöntemleri [1, 52] içermektedir. Tüm yayınlarda kullanılan veri setleri EEG veri setleri olmasına rağmen, çeşitli çalışmalarda kullanılan AH hastası ve KG sayıları farklılık göstermektedir. Tez çalışmasında bazı çalışmalarda [38, 56] kullanılan veri setinden daha az veri seti kullanılsa bile daha iyi sonuç elde edilmiştir. Makine öğrenmesi yöntemlerini kullanan bazı çalışmalar [31, 51], önerilen yöntemden daha yüksek doğruluk değerleri sağlamıştır. Ancak, çok sayıda özelliğin hesaplanması zaman alıcı ve yorucu bir süreçtir. Tez çalışması kapsamında elde edilen sonuçlar derin öğrenme tabanlı yaklaşımlarla karşılaştırıldığında [18, 50, 54], neredeyse benzer ya da biraz daha düşük başarı elde ettiği görülmektedir. Tez çalışması kapsamında önerilen Modifiye ResNet18_2 modeli, hızlı, tutarlı ve etkili analiz ve yüksek AH tespit başarısı sağlama açısından umut vericidir.

Tablo 5.1: Literatürde bulunan diğer benzer çalışmalarla tez kapsamında yapılan çalışmaların katılımcı sayısı, özellik, sınıflandırıcı ve performans tablosu.

Referans	Katılımcı Sayısı	Özellik	Sınıflandırıcı	Performans(%)
[31]	14 AH / 10 KG	İstatistiksel ve spektral	Makine Öğrenme (ML)	%88,79 - %96,78 ACC
[29]	15 AH / 11 KG	EMD, EEMD ve DWT tabanlı özellikler	Makine Öğrenme (ML)	%91.8 - %95.2 ACC
[38]	79 AH / 82 KG	Higuchi fraktal boyutu ve spektral entropi	Makine Öğrenme (ML)	%66 - %78 ACC
[51]	19 AH / 17 KG	PSD (Güç spektral yoğunluğu)	Makine Öğrenme (ML)	%92,86 - %97,14 ACC
[43]	11 AH / 11 KG	Lempel-Ziv complexity	Makine Öğrenme (ML)	%77.27 - %78.25 ACC
[52]	11 HBB(MCI) / 10 AH / 19 KG	Varyans Analizi (ANOVA) (istatistiksel)	ML+RNN+CNN (EEG+ERP)	%59,4 - %66,4, %92,3 - %94,1, %97,5 -%99
[1]	15 AH / 11 KG	STFT ve SST tabanlı TFR	ML+CNN	%79.56 - %92.96 ACC
[50]	49 AH / 37 MCI / 14 KG	FFT + örtüşen kayan pencere segmentasyonu	DPCNN	%97,10 ACC
[54]	39 AH / 52 KG	Zaman alanı (Time Domain)	CNN	%98.7 - %100 ACC
[55]	4 AH / 4 MCI / 4 KG	Spektral görüntüler	CNN	%78.33 - %95.04 ACC
[18]	201 Orta Düzey AH / 206 İleri Düzey AH / 261 KG	CNN	CNN	%97,45 ODAH ACC %97,03 İDAH ACC
[56]	63 AH / 63 MCI / 63 KG	EEG'nin PSD'si	CNN	%81.41 - %92.95 ACC
Önerilen Çalışma	15 AH / 11 KG	STFT, CWT Amor, CWT Bump, CWT Morse.	CNN / ResNet18, Modifiye ResNet18_1, Modifiye ResNet18_2, AlexNet, GoogleNet, DarkNet.	%83.10 - %96,90 ACC %76,40 - %94,30 ACC %76,00 - %93,70 ACC %72,60 - %93,70 ACC %74,80 - %94,70 ACC %58,20 - %92,40 ACC

6. SONUÇ VE ÖNERİLER

Bu çalışma kapsamında, derin öğrenme mimarileri ve zaman-frekans yaklaşımlarıyla Alzheimer hastalarının ve sağlıklı kontrol grubu gönüllülerinin EEG verileri sınıflandırılarak Alzheimer hastalığının erken tespiti hedeflenmiştir. Bu amaç doğrultusunda tanısal testler ve nöro görüntüleme teknikleri ile erken evre Alzheimer hastalığı teşhisi konmuş 15 AH hastasının ve 11 sağlıklı kontrol gönüllüsünün EEG sinyalleri kullanılmıştır. 19 kanaldan, 200 Hz örnekleme frekansında Philips Alice-6 cihazı kullanılarak kaydedilen EEG sinyallerinin kayıt işlemi, İzmir Kâtip Çelebi Üniversitesi Tıp Fakültesi Nöroloji Bölümü'nde gerçekleştirilmiştir.

Alzheimer hastalığı demansın en yaygın türüdür ve etkili tedavi için erken teşhis oldukça önem arz etmektedir. Bu sebeple son zamanlarda maliyet, uygulanabilirlik ve gerçek zamanlı bilgiler sunması gibi avantajlarından dolayı EEG yöntemi, Alzheimer hastalığının teşhisinde sıkça tercih edilen klinik araçlardan biri olmuştur.

Tez çalışması kapsamında, Alzheimer hastalığının teşhisinde en doğru sınıflandırma yöntemini tespit etmek amacıyla Alzheimer hastalarının ve sağlıklı kontrol grubu gönüllülerinin veri setinden elde edilen EEG sinyallerinin skalogram ve spektrogram görüntüleri, STFT ve CWT Amor, Bump ve Morse zaman-frekans dönüşümleri kullanılarak elde edilmiştir. Skalogram ve spektrogram görüntüleri input olarak Resnet18, Modifiye ResNet18_1, Modifiye ResNet18_2, GoogleNet, AlexNet ve DarkNet Evrişimli Sinir Ağı (CNN) mimarilerinde kullanılmış ve elde edilen performans metriklerinden en doğru sınıflandırma yöntemi belirlenmeye çalışılmıştır.

Tez çalışması kapsamında gerçekleştirilen tüm adımlar Matlab R2023a programı kullanılarak elde edilmiştir. AH ve kontrol grubuna ait EEG verilerinden, STFT ve CWT Amor, Bump ve Morse zaman-frekans dönüşümleri kullanılarak, her bir dönüşüm için AH hastaları için toplam 94.267 görüntü elde edilirken, kontrol grubu için 62.835 görüntü elde edilmiştir. Bu görüntülerin derin öğrenme mimarileri ile eğitimleri sonucu her bir kanal için elde edilen eğitim ilerlemesi (training progress) sonuçları “png” formatında, validasyon ve test karmaşıklık matrisi ve ROC eğrisi sonuçları ise “png ve Matlab” formatında kaydedilmiştir.

EEG verilerinden zaman-frekans yaklaşımları ile elde edilen görüntülerin konvolüsyonel derin öğrenme mimarilerinde input olarak kullanılması sonucu elde edilen kanal bazlı ve beyin bölgesi bazlı performans metriklerinin ve grafiklerin sonuçları değerlendirildiğinde; ResNet18 mimarisi CWT Bump zaman-frekans yaklaşımıyla kanal bazlı değerlendirmede ortalama validasyon (Tablo 4.1) için %88,76 PRE, %11,24 FDR, %82,24 SPE, %91,77 SEN, %88,11 ACC ve %90,23 F1 Skoru değerleriyle en yüksek başarım oranı elde etmiştir. Kanal bazlı değerlendirmede ortalama test (Tablo 4.2) için ise %89,33 PRE, %10,67 FDR, %83,15 SPE, %91,55 SEN, %88,37 ACC ve %90,42 F1 Skoru değerleriyle ResNet18 mimarisi CWT Bump yaklaşımıyla yine en yüksek sonuca ulaşmıştır. Resnet18'in kanal bazlı validasyon ve test tablosundan (Tablo 4.13) görüleceği üzere beynin posterior (arka) bölgesinde bulunan P4 kanalı CWT Bump yaklaşımı ile %96,90 validasyon ve %95,90 test değerleriyle diğer kanallardan daha iyi sonuç vermiştir. Tablo 4.32'de bulunan verilerden anlaşılacağı üzere, eğitim ilerlemesi grafiklerinden elde edilen validasyon doğruluk (ACC) değerlerine göre mimarilerin en yüksekten en düşüğe sıralaması şu şekildedir: ResNet18 (%96,87), GoogleNet (%94,72), Modifiye ResNet18_1 (%94,32), Modifiye ResNet18_2 (%93,74), AlexNet (%93,74) ve DarkNet (%92,37).

Çalışma kapsamında ResNet18 mimarisi modifiye edilerek daha az katman sayısına ve daha düşük filtre derecelerine sahip yeni bir mimari tasarlanmıştır (Modifiye ResNet18_2). Bu mimariye ait sonuçlar değerlendirildiğinde P4 kanalı ve CWT Bump yaklaşımı için en yüksek sınıflandırma doğruluğuna (%93,70 ACC) ulaşıldığı görülmektedir (Tablo 4.15). Modifiye ResNet18_2 mimarisi CWT Bump zaman-frekans yaklaşımıyla kanal bazlı değerlendirmede ortalama validasyon (Tablo 4.5) için %81,21 PRE, %18,79 FDR, %68,56 SPE, %88,19 SEN %80,64 ACC ve %84,53 F1 Skoru değerleriyle en yüksek başarım oranı elde ederken, ortalama test (Tablo 4.6) için ise %81,20 PRE, %18,80 FDR, %68,36 SPE, %88,28 SEN, %80,68 ACC ve %84,58 F1 Skoru değerleriyle en yüksek sonuca ulaşmıştır. Beyin bölgeleri bazlı ortalama validasyon ACC ve FDR değerleri (Şekil 4.15(a ve b)) değerlendirildiğinde beynin posterior (arka) bölgesinden CWT-Bump yaklaşımı ile daha yüksek sınıflandırma doğruluğu elde edilmiş olduğu dikkat çekmektedir. Yine Tablo 4.32 incelendiğinde Modifiye ResNet18_2 mimarisinin eğitim ve sınıflandırma sürecinin klasik mimarilere göre çok daha hızlı olduğu görülmektedir. Ayrıca Şekil 4.16, Şekil 4.17 ve Şekil 4.18 incelendiğinde eğitim sürecinde diğer mimarilere kıyasla aşırı öğrenme (overfitting) durumu gerçekleşmeden başarılı eğitim ve validasyon

doğrulukları sağlamış olduğu hem karmaşıklık matrislerinden hem de ROC eğrisi grafiklerinden görülmektedir.

Klasik ResNet18 mimarisinin modifikasyonu ile elde edilen Modifiye ResNet18_2 mimarisi, ResNet18 ile karşılaştırıldığında %96,90 olan ACC değerine kıyasla %93,70 oranında nispeten daha düşük bir ACC değerine sahip olmasına rağmen, eğitim ilerlemesi (training progress) sonuçları incelendiğinde aşırı uyum (overfitting) göstermeden dengeli ve başarılı bir performans sergilediği gözlemlenmektedir. Ayrıca, diğer mimarilere kıyasla eğitim sürecini daha hızlı tamamlayarak önemli bir zaman tasarrufu sağlamıştır.

Alzheimer hastalığı için erken teşhisin kritik öneme sahip olduğu göz önüne alındığında, Modifiye ResNet18_2 mimarisinin zamanlama ve dengeli performans açısından diğer mimarilerden daha iyi sonuçlar sunması, onu AH-KG sınıflandırmasında daha güvenilir ve tutarlı bir model olarak öne çıkarmaktadır. Dolayısıyla, bu mimari, uygulama bağlamında daha uygun ve tercih edilebilir bir alternatif olmaktadır.

Sonuç olarak bu çalışma, AH ve kontrol grubuna ait EEG segmentlerini sınıflandırmak için EEG verilerinin CWT Bump zaman-frekans yaklaşımıyla elde edilen skalogram görüntülerinin ResNet18 mimarisinin modifiye edilmesi ile elde edilen Modifiye ResNet18_2 derin öğrenme mimarisine input olarak kullanımına yönelik bir teknik sunmaktadır. Elde edilen sonuçlar değerlendirildiğinde, Modifiye ResNet18_2 algoritmasının, zaman-frekans özelliklerini etkili bir şekilde çıkarabildiği, EEG verilerinden anlamlı örüntüler tespit edebildiği, zaman ve performans dikkate alındığında eğitim sürecinin diğer mimarilere göre çok daha hızlı, dengeli ve başarılı bir performans sergilediği gözlemlenmiştir. Bu bulgular, AH (Alzheimer Hastalığı) ve kontrol grubu arasındaki EEG farklılıklarının tespiti ve sınıflandırılması konusunda umut vericidir. Çalışmanın doğruluğunu ve genellenebilirliğini artırmak adına daha fazla AH hastası ve kontrol grubu deneğinden kayıtlar alınarak veri setinin boyutu arttırılabilir. Farklı hastalık evrelerinden (erken, orta, ileri) elde edilen EEG verileri ile modelin performansı test edilebilir. Ayrıca, geliştirilen modelin diğer nörodejeneratif hastalıkların teşhisinde de uygulanabilirliği araştırılarak modelin klinik uygulamalardaki etkinliği artırılabilir ve çeşitli nörodejeneratif hastalıklar üzerindeki başarı oranları değerlendirilebilir.

KAYNAKLAR

[1]. Karabiber Cura, Ö., Türe, H.S., Akan, A., 2024, Detection of Alzheimer's Dementia by Using Deep Time–Frequency Feature Extraction, *ELECTRICA*, 24 (1), 109-118.

[2]. Sen, S.Y., Karabiber Cura, Ö., Akan, A., 2023, Classification of Dementia EEG Signals by Using Time-Frequency Images for Deep Learning, *2023 Innovations in Intelligent Systems and Applications Conference (ASYU)*, 11-13 Ekim 2023 Sivas, Türkiye, IEEE.

[3]. Mai, J. K., Paxinos, G., 2012, *The human nervous system*, Elsevier Academic Press, Amsterdam.

[4]. Karabiber Cura, Ö., 2021, *Evaluation of Some Neurological Disorders by the Analysis of EEG Signals*, Doktora, İzmir Kâtip Çelebi Üniversitesi Fen Bilimleri Enstitüsü.

[5]. Yıldırım M., 2022, *Sağlık Yüksek Okulları için Resimli İnsan Anatomisi,* 10. Baskı, Nobel Tıp Kitapevleri, İstanbul.

[6]. Mtui E., Gruener, G., Dockery, P., 2021, *Fitzgerald's Clinical Neuroanatomy and Neuroscience*, 8th edition, Elsevier, Philadelphia.

[7]. Noback, C. R., Ruggiero D.A., Strominger N.L., Demarest R.J., 2005, *The Human Nervous System: Structure and Function*, 6th ed., Humana Press, Springer Science & Business Media.

[8]. Stangor, C., Walinga J., 2014, *Introduction to Psychology*, https://opentextbc.ca/introductiontopsychology/chapter/3-1-the-neuron-is-the-building-block-of-the-nervous-system/, [Ziyaret tarihi: 4 Mart 2024]

[9]. Saymaz, A., 2020, *Mutluluk Eğitiminin EEG Sinyalleri Üzerine Etkisinin Makine Öğrenmesi Yöntemleriyle Değerlendirilmesi*, Yüksek Lisans, İstanbul Üniversitesi Cerrahpaşa Biyomedikal Mühendisliği ABD.

[10]. Lotte, F., 2008, *Study of Electroencephalographic Signal Processing and Classification Techniques towards the use of Brain-Computer Interfaces in Virtual Reality Applications,* Doctorate, l'Institut National des Sciences Appliquées de Rennes

[11]. Organization, W., H., 2006, *Neurological disorders: public health challenges*. Geneva: World Health Organization.

[12]. Feigin V.L., Abajobir A.A., Abate K.H., Abd-Allah F., Abdulle A.M., et al., 2017, Global, regional, and national burden of neurological disorders during 1990–2015: a systematic analysis for the Global Burden of Disease Study 2015, *The Lancet Neurology*, 16 (11), 877-897.

[13]. Long, S., Benoist, C., Weidner, W., 2023, *World Alzheimer Report 2023: Reducing dementia risk: never too early, never too late*, London, England: Alzheimer's Disease International.

[14]. Kumar, A., Sidhu, J., Lui, F., Tsao, J.W., 2024, *Alzheimer Disease*, http://www.ncbi.nlm.nih.gov/books/NBK499922/, [Ziyaret tarihi: 14 Mart 2024].

[15]. Breijyeh Z., Karaman, R., 2020, Comprehensive Review on Alzheimer's Disease: Causes and Treatment, *Molecules*, 25 (24), 5789.

[16]. Chen, Z.Y., Zhang, Y., 2022, Animal models of Alzheimer's disease: Applications, evaluation, and perspectives, *Zoological Research*, 43 (6), 1026-1040.

[17]. Nour M., Senturk, U., Polat, K., 2024, A novel hybrid model in the diagnosis and classification of Alzheimer's disease using EEG signals: Deep ensemble learning (DEL) approach, *Biomedical Signal Processing and Control*, 89, 105751.

[18]. Roncero-Parra, C., Parreño-Torres, A., Sánchez-Reolid, R., Mateo-Sotos, J., Borja, A.L., 2024, Inter-hospital moderate and advanced Alzheimer's disease detection through convolutional neural networks, *Heliyon*, 10 (4), e26298.

[19]. Peker, M., Sen, B., Delen, D., 2016, A Novel Method for Automated Diagnosis of Epilepsy Using Complex-Valued Classifiers, *IEEE Journal of Biomedical and Health Informatics*, 20 (1), 108-118.

[20]. Nishad A., Pachori R.B., 2024, Classification of epileptic electroencephalogram signals using tunable-Q wavelet transform based filter-bank, *Journal of Ambient Intelligence and Humanized Computing*, 15 (1), 877-891.

[21]. Adeli, H., Zhou, Z., Dadmehr, N., 2003, Analysis of EEG records in an epileptic patient using wavelet transform, *Journal of Neuroscience Methods*, 123 (1), 69-87.

[22]. Eskikurt G., 2016, *Görsel Çalışma Belleğinin Beyin Elektriksel Aktivitesinin Zaman-Frekans Analizi ile Değerlendirilmesi*, Doktora, İstanbul Üniversitesi, Sağlık Bilimleri Enstitüsü, Sinir Bilimi ABD.

[23]. Zahra, A., Kanwal, N., Ur-Rehman, N., Ehsan, S., McDonald-Maier, K.D., 2017, Seizure Detection from EEG signals using Multivariate Empirical Mode Decomposition, *Computers in Biology and Medicine*, 88, 132-141.

[24]. Kotan, S., 2019, *EEG Sinyalleri İşlenerek Multipl Skleroz Hastalığının Tespiti ve Sınıflandırılması,* Doktora, İstanbul Üniversitesi Cerrahpaşa, Lisansüstü Eğitim Enstitüsü, Biyomedikal Mühendisliği ABD.

[25]. Rahul, J., Sharma, D., Sharma, L.D., Nanda, U., Sarkar, A.K., 2024, A systematic review of EEG based automated schizophrenia classification through machine learning and deep learning, *Frontiers in Human Neuroscience*, 18, 1347082.

[26]. Rossini, P.M., Di Iorio, R., Vecchio, F., Anfossi, M., Babiloni, C., Bozzali, M., Bruni, A.C., Cappa, S.F., Escudero, J., Fraga, F.J., Giannakopoulos, P., Guntekin, B., Logroscino, G., Marra, C., Miraglia, F., Panza, F., Tecchio, F., Pascual-Leone, A.,

Dubois, B., 2023, Early diagnosis of Alzheimer's disease: the role of biomarkers including advanced EEG signal analysis. Report from the IFCN-sponsored panel of experts, *Clinical Neurophysiology*, 131 (6), 1287-1310.

[27]. Pineda, A.M., Ramos, F.M., Betting, L.E., Campanharo, A.S.L.O., 2020, Quantile graphs for EEG-based diagnosis of Alzheimer's disease, *PloS ONE*, 15 (6), e0231169.

[28]. Locatelli, T., Cursi, M., Liberati, D., Franceschi, M., Comi, G., 1998, EEG coherence in Alzheimer's disease, *Electroencephalography and Clinical Neurophysiology*, 106 (3), 229-237.

[29]. Karabiber Cura, Ö., Akan, A., Yılmaz, G.C., Türe, H.S., 2022, Detection of Alzheimer's Dementia by Using Signal Decomposition and Machine Learning Methods, *International Journal of Neural Systems*, 32 (09), 2250042.

[30]. Ortiz, A., Munilla, J., Górriz, J. M., Ramírez, J., 2016, Ensembles of Deep Learning Architectures for the Early Diagnosis of the Alzheimer's Disease, *International Journal of Neural Systems*, 26 (07), 1650025.

[31]. Tzimourta K.D., Giannakeas, N., Tzallas, A.T., Astrakas, L.G., Afrantou, T., Ioannidis, P., Grigoriadis, N., Angelidis, P., Tsalikakis, D.G., Tsipouras, M.G., 2019, EEG Window Length Evaluation for the Detection of Alzheimer's Disease over Different Brain Regions, *Brain Sciences*, 9 (4), 81.

[32]. Tzimourta, K.D., Afrantou, T., Ioannidis, P., Karatzikou, M., Tzallas, A.T., Giannakeas, N., Astrakas, L.G., Angelidis, P., Glavas, E., Grigoriadis, N., Tsalikakis, D.G., Tsipouras, M.G., 2019, Analysis of electroencephalographic signals complexity regarding Alzheimer's Disease, *Computers & Electrical Engineering*, 76, 198-212.

[33]. Miraglia F., Vecchio, F., Marra, C., Quaranta, D., Alù, F., Peroni, B., Granata, G., Judica, E., Cotelli, M., Rossini, P.M., 2020, Small World Index in Default Mode Network Predicts Progression from Mild Cognitive Impairment to Dementia, *International Journal of Neural Systems*, 30 (02), 2050004.

[34]. Abásolo, D., Hornero, R., Espino, P., Poza, J., Sánchez, C.I., De La Rosa R., 2005, Analysis of regularity in the EEG background activity of Alzheimer's disease patients with Approximate Entropy, *Clinical Neurophysiology*, 116 (8), 1826-1834.

[35]. Puri, D.V., Nalbalwar, S.L., Nandgaonkar, A.B., Gawande, J.P., Wagh, A., 2023, Automatic detection of Alzheimer's disease from EEG signals using low-complexity orthogonal wavelet filter banks, *Biomedical Signal Processing and Control*, 81, 104439.

[36]. Tylová, L., Kukal, J., Hubata-Vacek, V., Vyšata, O., 2018, Unbiased estimation of permutation entropy in EEG analysis for Alzheimer's disease classification, *Biomedical Signal Processing and Control*, 39, 424-430.

[37]. Mammone, N., Ieracitano, C., Adeli, H., Bramanti, A., Morabito, F.C., 2018, Permutation Jaccard Distance-Based Hierarchical Clustering to Estimate EEG Network Density Modifications in MCI Subjects, *IEEE Transactions on Neural Networks and Learning Systems*, 29 (10), 5122-5135.

[38]. Staudinger, T., Polikar, R., 2011, Analysis of complexity based EEG features for the diagnosis of Alzheimer's disease, *33rd Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, 30 August - 3 September 2011 Boston, Massachusetts USA, IEEE, 2033-2036.

[39]. Amezquita-Sanchez, J.P., Mammone, N., Morabito, F.C., Marino, S., Adeli, H., 2019, A novel methodology for automated differential diagnosis of mild cognitive impairment and the Alzheimer's disease using EEG signals, *Journal of Neuroscience Methods*, 322, 88-95.

[40]. Amezquita-Sanchez, J.P., Mammone, N., Morabito, F.C., Adeli, H., 2021, A New dispersion entropy and fuzzy logic system methodology for automated classification of dementia stages using electroencephalograms, *Clinical Neurology and Neurosurgery*, 201, 106446.

[41]. Deng, B., Cai, L., Li, S., Wang, R., Yu, H., Chen, Y., Wang, J., 2017, Multivariate multi-scale weighted permutation entropy analysis of EEG complexity for Alzheimer's disease, *Cognitive Neurodynamics*, 11 (3), 217-231.

[42]. Jeong, J., Kim, S.Y., Han, S.H., 1998, Non-linear dynamical analysis of the EEG in Alzheimer's disease with optimal embedding dimension, *Electroencephalography and Clinical Neurophysiology*, 106 (3), 220-228.

[43]. Simons, S., Abásolo, D., 2017, Distance-Based Lempel–Ziv Complexity for the Analysis of Electroencephalograms in Patients with Alzheimer's Disease, *Entropy*, 19 (3), 129.

[44]. Abásolo, D., Hornero, R., Gómez, C., García, M., López, M., 2006, Analysis of EEG background activity in Alzheimer's disease patients with Lempel–Ziv complexity and central tendency measure, *Medical Engineering & Physics*, 28 (4), 315-322.

[45]. Ieracitano, C., Mammone, N., Hussain, A., Morabito, F.C., 2020, A novel multi-modal machine learning based approach for automatic classification of EEG recordings in dementia, *Neural Networks*, 123, 176-190.

[46]. Durongbhan, P., Zhao, Y., Chen, L., Zis, P., De Marco, M., Unwin, Z.C., Venneri, A., He, X., Li, S., Zhao, Y., Blackburn, D.J., Sarrigiannis, P.G., 2019, A Dementia Classification Framework Using Frequency and Time-Frequency Features Based on EEG Signals, *IEEE Transactions on Neural Systems and Rehabilitation Engineering,* 27 (5), 826-835.

[47]. Kulkarni N.N., Bairagi, V.K., 2017, Extracting Salient Features for EEG-based Diagnosis of Alzheimer's Disease Using Support Vector Machine Classifier, *IETE Journal of Research*, 63 (1), 11-22.

[48]. Safi, M.S., Safi, S.M.M., 2021, Early detection of Alzheimer's disease from EEG signals using Hjorth parameters, *Biomedical Signal Processing and Control*, 65, 102338.

[49]. Sharma, N., Kolekar, M.H., Jha, K., 2020, Iterative Filtering Decomposition Based Early Dementia Diagnosis Using EEG With Cognitive Tests, *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 28 (9), 1890-1898.

[50]. Xia, W., Zhang, R., Zhang, X., Usman, M., 2023, A novel method for diagnosing Alzheimer's disease using deep pyramid CNN based on EEG signals, *Heliyon*, 9 (4), e14858.

[51]. Tavares, G., San-Martin, R., Ianof, J.N., Anghinah, R., Fraga, F.J., 2019, Improvement in the automatic classification of Alzheimer's disease using EEG after feature selection, *2019 IEEE International Conference on Systems, Man and Cybernetics (SMC)*, 6-9 October 2019 Bari, Italy, IEEE, 1264-1269.

[52]. Mazrooei Rad, E., Azarnoosh, M., Ghoshuni, M., Khalilzadeh, M.M., 2021, Diagnosis of mild Alzheimer's disease by EEG and ERP signals using linear and nonlinear classifiers, *Biomedical Signal Processing and Control*, 70, 103049.

[53]. Ravikanti, D. K., Saravanan, S., 2023, EEGAlzheimer'sNet: Development of transformer-based attention long short term memory network for detecting Alzheimer disease using EEG signal, *Biomedical Signal Processing and Control*, 86 (C), 105318.

[54]. Park, J., Jang, S., Gwak, J., Kim, B.C., Lee, J.J., Choi, K.Y., Lee, K.H., Jun, S.C., Jang, G.J., Ahn, S., 2022, Individualized diagnosis of preclinical Alzheimer's Disease using deep neural networks, *Expert Systems with Applications*, 210, 118511.

[55]. Bi, X., Wang, H., 2019, Early Alzheimer's disease diagnosis based on EEG spectral images using deep learning, *Neural Networks*, 114, 119-135.

[56]. Ieracitano, C., Mammone, N., Bramanti, A., Hussain, A., Morabito, F.C., A Convolutional Neural Network approach for classification of dementia stages based on 2D-spectral representation of EEG recordings, *Neurocomputing*, 323, 96-107.

[57]. Karabiber Cura, Ö., Akan, A., 2021, Classification of Epileptic EEG Signals Using Synchrosqueezing Transform and Machine Learning, *International Journal of Neural Systems*, 31 (05), 2150005.

[58]. Tzallas, A.T., Tsipouras, M.G., Fotiadis, D.I., 2009, Epileptic Seizure Detection in EEGs Using Time-Frequency Analysis, *IEEE Transactions on Information Technology in Biomedicine*, 13 (5), 703-710.

[59]. Varanis, M., Silva, A.L., Balthazar, J.M., Pederiva, R., 2021, A Tutorial Review on Time-Frequency Analysis of Non-Stationary Vibration Signals with Nonlinear Dynamics Applications, *Brazilian Journal of Physics,* 51 (3), 859-877.

[60]. Addison, P.S., 2002, *The Illustrated Wavelet Transform Handbook: Introductory Theory and Applications in Science, Engineering, Medicine and Finance*, 1st Edition, CRC Press, Boca Raton, Florida, ABD.

[61]. Islam, M.N., Sulaiman, N., Bari, B.S., Rashid, M., Mustafa, M., 2022, A hybrid scheme for AEP based hearing deficiency diagnosis: CWT and convoluted k-nearest neighbour (CKNN) pipeline, *Neuroscience Informatics*, 2 (1), 100037.

[62]. Barzan, H., Moca, V.V., Ichim, A.M., Muresan, R.C., 2021, Fractional Superlets, *2020 28th European Signal Processing Conference (EUSIPCO)*, 18-21 January 2021 Amsterdam, Netherlands, IEEE, 2220-2224.

[63]. Mahendra Kumar, J.L., Rashid, M., Musa, R.M., Mohd Razman, M.A., Sulaiman, N., Jailani, R., P.P. Abdul Majeed, A., 2021, The classification of EEG-based wink signals: A CWT-Transfer Learning pipeline, *ICT Express*, 7 (4), 421-425.

[64]. https://www.mathworks.com/help/wavelet/gs/choose-a-wavelet.html, [Ziyaret tarihi: 10 Ağustos 2024].

[65]. Rivera, M.J., Teruel, M.A., Maté, A., Trujillo, J., 2022, Diagnosis and prognosis of mental disorders by means of EEG and deep learning: a systematic mapping study, *Artificial Intelligence Review*, 55 (2), 1209-1251.

[66]. Özdemir, M.A., Kısa, D.H., Guren, O., Akan, A., 2022, Hand gesture classification using time–frequency images and transfer learning based on CNN, *Biomedical Signal Processing and Control*, 77, 103787.

[67]. Değirmenci, M., Özdemir, M.A., İzci, E., Akan, A., 2022, Arrhythmic Heartbeat Classification Using 2D Convolutional Neural Networks, *IRBM*, 43 (5), 422-433.

[68]. Yıldırım, Ö., Pławiak, P., Tan, R.S., Acharya, U.R., 2018, Arrhythmia detection using deep convolutional neural network with long duration ECG signals, *Computers in Biology and Medicine*, 102, 411-420.

[69]. LeCun, Y., Bengio, Y., Hinton, G., 2015, Deep learning, *Nature*, 521 (7553), 436-444.

[70]. LeCun, Y., Bottou, L., Bengio, Y., Haffner, P., 1998, Gradient-based learning applied to document recognition, *Proceedings of the IEEE,* 86 (11), 2278-2324.

[71]. LeCun, Y., Huang, F.J., Bottou, L., 2004, Learning methods for generic object recognition with invariance to pose and lighting, *Proceedings of the 2004 IEEE Computer Society Conference on Computer Vision and Pattern Recognition, CVPR 2004*, 27 June – 2 July 2004 Washington, DC, USA, IEEE, 97-104.

[72]. Gao, X.W., Hui, R., Tian, Z., 2017, Classification of CT brain images based on deep learning networks, *Computer Methods and Programs in Biomedicine*, 138, 49-56.

[73]. Yamashita, R., Nishio, M., Do, R.K.G., Togashi, K., 2018, Convolutional neural networks: an overview and application in radiology, *Insights Imaging*, 9 (4), 611-629.

[74]. Guo, Y., Liu, Y., Oerlemans, A., Lao, S., Wu, S., Lew, M.S., 2016, Deep learning for visual understanding: A review, *Neurocomputing*, 187, 27-48.

[75]. Girshick, R., Donahue, J., Darrell, T., Malik, J., 2014, Rich feature hierarchies for accurate object detection and semantic segmentation, *2014 IEEE Conference on Computer Vision and Pattern Recognition*, 23-28 June 2014 Columbus, OH, USA, IEEE, 580-587.

[76]. Liu, Y., She, G., Chen, S., 2021, Magnetic resonance image diagnosis of femoral head necrosis based on ResNet18 network, *Computer Methods and Programs in Biomedicine*, 208, 106254.

[77]. Xu, Y., Wang, Y., Razmjooy, N., 2022, Lung cancer diagnosis in CT images based on Alexnet optimized by modified Bowerbird optimization algorithm, *Biomedical Signal Processing and Control*, 77, 103791.

[78]. Lu, S., Lu, Z., Zhang, Y.D., 2019, Pathological brain detection based on AlexNet and transfer learning, *Journal of Computational Science*, 30, 41-47.

[79]. Krizhevsky, A., Sutskever, I., Hinton, G.E., 2017, ImageNet classification with deep convolutional neural networks, *Communications of the ACM*, 60 (6), 84-90.

[80]. Siuly, S., Khare, S.K., Kabir, E., Sadiq, M.T., Wang, H., 2024, An efficient Parkinson's disease detection framework: Leveraging time-frequency representation and AlexNet convolutional neural network, *Computers in Biology and Medicine*, 174, 108462.

[81]. Chaki, J., Woźniak, M., 2023, Deep learning for neurodegenerative disorder (2016 to 2022): A systematic review, *Biomedical Signal Processing and Control*, 80 (1), 104223.

[82]. Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Erhan, D., Vanhoucke, V., Rabinovich, A., 2015, Going deeper with convolutions, *2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 07-12 June 2015 Boston, MA, USA, IEEE, 1-9.

[83]. Barber, F.B.N., Oueslati, A.E., 2024, Human exons and introns classification using pre-trained Resnet-50 and GoogleNet models and 13-layers CNN model, *Journal of Genetic Engineering and Biotechnology*, 22 (1), 100359.

[84]. Bezdan, T., Džakula, N.B., 2019, Convolutional Neural Network Layers and Architectures, *Sinteza 2019 - International Scientific Conference On Information Technology And Data Related Research*, 2019 Novi Sad, Serbia, Singidunum University, 445-451.

[85]. Pavlov, V.A., Galeeva, M.A., 2019, Detection and recognition of objects on aerial photographs using convolutional neural networks, *Journal of Physics: Conference Series*, 1326 (1), 012038.

[86]. Redmon, J., Farhadi, A., 2017, YOLO9000: Better, Faster, Stronger, *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 21-26 July 2017 Honolulu, HI, USA, IEEE, 6517-6525.

[87]. Baygın, M., Yaman, O., Barua, P.D., Doğan, S., Tuncer, T., Acharya, U.R., 2022, Exemplar Darknet19 feature generation technique for automated kidney stone detection with coronal CT images, *Artificial Intelligence in Medicine*, 127, 102274.

[88]. Hossin, M., Sulaiman, M.N., 2015, A Review on Evaluation Metrics for Data Classification Evaluations, *International Journal of Data Mining & Knowledge Management Process (IJDKP)*, 5 (2), 01-11.

[89]. Yu, T., Zhu, H., 2020, Hyper-Parameter Optimization: A Review of Algorithms and Applications, *arXiv preprint arXiv:2003.05689.*

[90]. Gneiting, T., Vogel, P., 2018, Receiver Operating Characteristic (ROC) Curves, *arXiv preprint arXiv:1809.04808.*

[91]. Berrar, D., Flach, P., 2011, Caveats and pitfalls of ROC analysis in clinical microarray research (and how to avoid them), *Briefings in Bioinformatics*, 13 (1), 83-97.

[92]. Jiménez-Valverde, A., 2011, Insights into the area under the receiver operating characteristic curve (AUC) as a discrimination measure in species distribution modelling, *Global Ecology and Biogeography*, 21 (4), 498-507.

İNTİHAL RAPORU İLK SAYFASI

Meral ASLAN DİL

ORİJİNALLİK RAPORU

%7	%5	%5	%4
BENZERLİK ENDEKSİ	İNTERNET KAYNAKLARI	YAYINLAR	ÖĞRENCİ ÖDEVLERİ

BİRİNCİL KAYNAKLAR

1	Submitted to The Scientific & Technological Research Council of Turkey (TUBITAK) Öğrenci Ödevi	%2
2	acikbilim.yok.gov.tr İnternet Kaynağı	%1
3	www.openaccess.hacettepe.edu.tr:8080 İnternet Kaynağı	%1
4	Ozlem Karabiber Cura, Gulce Cosku Yilmaz, Hatice Sabiha Ture, Aydin Akan. "Classification of Dementia EEG Based on Sub-bands Using Time-Frequency Approaches", 2022 30th Signal Processing and Communications Applications Conference (SIU), 2022 Yayın	%1
5	Lingling Tong, Zhimin Lv. "Improved diffusion mapping combined with procrustes analysis for capturing local-global data structures in industrial process monitoring", Journal of the Taiwan Institute of Chemical Engineers, 2024 Yayın	<%1

ETİK KURUL İZİN YAZISI

Uyarı: Canlı denekler üzerinde yapılan tüm araştırmalar için Etik Kurul Belgesi alınması zorunludur.

☒ **Etik Kurul izni gerekmektedir.**

☐ **Etik Kurul izni gerekmemektedir.**

Meral ASLAN DİL
(İmza)

KURUM İZNİ YAZILARI

Uyarı: Canlı ve cansız deneklerle yapılan tüm çalışmalar için kurum izin belgelerinin eklenmesi zorunludur. Gizlilik ve mahremiyet içeren durumlarda kurum adı kapatılmalıdır.

☐ **Kurum izni gerekmektedir.**

☒ **Kurum izni gerekmemektedir.**

Meral ASLAN DİL
(İmza)