ANKARA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

DOKTORA TEZİ

YAPAY ZEKA TABANLI ELEKTROENSEFALOGRAFİ (EEG) BİYOMETRİK KİMLİK TANIMLAMA

Furkan BALCI

ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

ANKARA
2026

Her hakkı saklıdır

ÖZET

Doktora Tezi

YAPAY ZEKA TABANLI ELEKTROENSEFALOGRAFİ (EEG) BİYOMETRİK KİMLİK TANIMLAMA

Furkan BALCI

Ankara Üniversitesi
Fen Bilimleri Enstitüsü
Elektrik-Elektronik Mühendisliği Anabilim Dalı

Danışman: Doç. Dr. Hakkı Alparslan ILGIN

Bu tez çalışmasında, dinlenim durumu EEG işaretleri kullanılarak kapalı-küme, oturumlar arası ve tek kanallı biyometrik kimlik tanımlama problemi ele alınmıştır. Çalışmada Oslo Üniversitesi Uyaran-Seçici Yanıt Modülasyonu veri kümesindeki 111 katılımcıya ait EEG kayıtları incelenmiş, ana deneyler iki oturumu bulunan 42 katılımcının verileri üzerinde yürütülmüştür. EEG kayıtları 4 saniyelik örtüşmesiz pencerelere ayrılmış ve her pencere 4096×1 boyutunda tek kanallı zaman serisi olarak modellenmiştir. İşaret kalitesini artırmak amacıyla Dalgacık Entropisi, Lempel-Ziv Karmaşıklığı ve Kök Ortalama Kare özniteliklerine dayalı Bulanık Çıkarım Sistemi ile gürültü tespiti yapılmış, bozulmuş pencereler Üretken Çekişmeli Ağ tabanlı yeniden yapılandırma yaklaşımıyla iyileştirilmiştir. Kanal–frekans bandı analizleri, özellikle duvarsal ve duvar-artkafa bölgeler ile gama bandı bileşenlerinin biyometrik ayırt edicilik açısından öne çıktığını göstermiştir. Kimlik tanımlama için çok ölçekli Evrişimsel Sinir Ağı, Çift Yönlü Uzun Kısa Süreli Bellek ve Dönüştürücü bileşenlerini birleştiren karma bir model geliştirilmiş, üst değişkenler Diferansiyel Evrim Hiperbantı algoritmasıyla eniyilenmiştir. Ana oturumlar arası protokolde önerilen model yüksek birinci-sıra doğruluk, makro F1 ve dengeli doğruluk değerleri üretmiş, aynı oturum içi ve ters yönlü oturumlar arası protokollerle karşılaştırmalı değerlendirme yapılmıştır. Ayrıca yığınsal eşleşme karakteristiği, ilk-k doğruluk, sınıf bazlı başarım, test süresi, bileşen çıkarma ve tekrarlı deney analizleri kullanılarak modelin kararlılığı incelenmiştir. Kişi düzeyi yumuşak oylama, pencere düzeyindeki sınırlı kararsızlıkları azaltarak karar güvenilirliğini artırmıştır. Sonuçlar, kısa süreli tek kanallı EEG kayıtlarının uygun ön işleme, kanal–bant seçimi, üst değişken eniyilemesi ve derin temsil öğrenme yaklaşımlarıyla biyometrik kimlik tanımlamada etkili biçimde kullanılabileceğini ve düşük donanım gereksinimli EEG biyometrik sistemler için uygulanabilir bir temel oluşturabileceğini deneysel olarak ortaya koymaktadır.

Ağustos 2026, 189 sayfa

Anahtar Kelimeler: Biyometrik, Kimlik Tanımlama, Yapay Zeka, Elektroensefalografi

ABSTRACT

PhD Thesis

ARTIFICIAL INTELLIGENCE-BASED ELECTROENCEPHALOGRAPHY (EEG) BIOMETRIC IDENTIFICATION

Furkan BALCI

Ankara University
Graduate School of Natural and Applied Science
Department of Electrical and Electronics Engineering

Supervisor: Assoc. Prof. Dr. Hakkı Alparslan ILGIN

In this thesis, the problem of closed-set, cross-session, and single-channel biometric identification was addressed using resting-state EEG signals. EEG recordings of 111 participants from the Oslo University Stimulus-Selective Response Modulation dataset were examined, and the main experiments were conducted on data of 42 participants who had two recording sessions. The EEG recordings were divided into non-overlapping 4-second windows, and each window was modeled as a single-channel time series with a size of 4096×1. To improve signal quality, noise detection was performed using a Fuzzy Inference System based on Wavelet Entropy, Lempel-Ziv Complexity, and Root Mean Square features; corrupted windows were then enhanced using a Generative Adversarial Network-based reconstruction approach. Channel–frequency band analyses showed that parietal and parieto-occipital regions, as well as gamma-band components, were particularly prominent in terms of biometric discriminability. For identification, a hybrid model combining multi-scale Convolutional Neural Network, Bidirectional Long Short-Term Memory, and Transformer components was developed, and its hyperparameters were optimized using the Differential Evolution Hyperband algorithm. In the main cross-session protocol, the proposed model achieved high rank-1 accuracy, macro F1 score, and balanced accuracy; comparative evaluations were also conducted using same-session and reverse cross-session protocols. In addition, the model's stability was examined using cumulative match characteristic, top-(k) accuracy, class-wise performance, test duration, ablation, and repeated experiment analyses. Subject-level soft voting improved decision reliability by reducing limited window-level uncertainties. The results experimentally demonstrate that short-duration single-channel EEG recordings can be effectively used for biometric identification when combined with appropriate preprocessing, channel–band selection, hyperparameter optimization, and deep representation learning approaches, and that they can provide an applicable basis for EEG biometric systems with low hardware requirements.

August 2026, 189 pages

Keywords: Biometrics, Identification, Artificial Intelligence, Electroencephalography

TEŞEKKÜR

Doktora eğitimim ve tez çalışmam boyunca akademik gelişimime katkı sağlayan, yol göstericiliği ve özellikle zor zamanlarımda gösterdiği anlayış ve desteğiyle her zaman yanımda olan danışman hocam Sayın Doç. Dr. Hakkı Alparslan ILGIN'a en içten teşekkürlerimi sunarım.

Tez İzleme Komitesi'nde yer alan Sayın Prof. Dr. Ziya TELATAR, Sayın Prof. Dr. Murat Hüsnü SAZLI ve Sayın Doç. Dr. Aykut KALAYCIOĞLU'na tez çalışmamın gelişimine sundukları değerli yönlendirmeleri ve yapıcı değerlendirmeleri için teşekkür ederim.

Bu doktora çalışması, TÜBİTAK 2211-A Genel Yurt İçi Doktora Burs Programı (1649B032005103) kapsamında desteklenmiştir. Sağladığı maddi destek için Türkiye Bilimsel ve Teknolojik Araştırma Kurumu'na (TÜBİTAK) teşekkür ederim.

Bu süreçte gösterdiği sabır, anlayış ve sürekli desteğiyle akademik çalışmalarımı sürdürebilmem için bana güç veren, zor zamanlarda motivasyonumu korumama yardımcı olan kıymetli eşim ve hayat yoldaşım Dr. Hümeyra Şevval BALCI'ya içten teşekkürlerimi sunarım.

Hayatımda çok kıymetli bir yere sahip olan, neşesi, sevgisi ve desteğiyle varlığını hâlâ hissettiğim merhum dayım Erdal BALCI'ya; üzerimdeki emeği, bana kattığı değerler ve unutmayacağım manevi desteği için sonsuz teşekkürlerimi sunarım. Ayrıca yaşamımın her aşamasında sevgileri, sabırları ve anlayışlarıyla yanımda olan, verdikleri manevi destek ve yaptıkları fedakârlıklarla eğitim hayatım boyunca karşılaştığım güçlükleri aşmamda büyük pay sahibi olan annem Hilal BALCI'ya, babam Özer BALCI'ya ve kız kardeşim Naile Özge BALCI'ya gönülden teşekkür ederim.

Başta bilim ve eğitim olmak üzere çağdaş Türkiye'nin gelişimine yön veren düşünceleriyle bizlere yol gösteren, aklı ve bilimi rehber edinmenin önemini vurgulayan Gazi Mustafa Kemal ATATÜRK'e, bizlere özgürce düşünebildiğimiz, araştırabildiğimiz ve bilimsel çalışmalarımızı sürdürebildiğimiz bir Cumhuriyet bıraktığı için sonsuz saygı, minnet ve şükranlarımı sunarım.

Furkan BALCI
Ankara, Ağustos 2026

İÇİNDEKİLER

TEZ ONAY SAYFASI
ETİK ..... **i**
ÖZET ..... **ii**
ABSTRACT ..... **iii**
TEŞEKKÜR ..... **iv**
SİMGELER VE KISALTMALAR DİZİNİ ..... **vii**
ŞEKİLLER DİZİNİ ..... **xii**
ÇİZELGELER DİZİNİ ..... **xiv**
1. GİRİŞ **1**
2. EEG TABANLI BİYOMETRİK KİMLİK TANIMLAMA **5**
2.1 Biyometrik Kimlik Tanımlama ve Doğrulama Kavramları **5**
2.2 Beynin Anatomik Yapısı ve Biyometrik Veri Olarak EEG İşareti **8**
2.3 EEG Frekans Alt Bantları **22**
2.4 EEG Tabanlı Kimlik Tanımlama Çalışmaları **29**
2.5 Literatürdeki Boşluklar ve Çalışmanın Konumlandırılması **37**
3. MATERYAL VE YÖNTEM **43**
3.1 Oslo Üniversitesi USYM Dinlenim Durumu EEG Veri Kümesi **44**
3.2 Veri Ön İşleme, Pencereleme ve Tek Kanallı EEG Temsili **51**
3.3 Birleştirilmiş Üretken Çekişmeli Ağ ve Bulanık Çıkarım Sistemi Tabanlı Gürültü Tespiti ve Giderimi Yaklaşımı **59**
3.3.1 Bulanık çıkarım sistemi tabanlı gürültü tespiti yaklaşımı **61**
3.3.2 Wasserstein üretken çekişmeli ağ tabanlı gürültü giderimi yaklaşımı **68**
3.4 Önerilen Karma ESA–ÇY-UKSB–Dönüştürücü Model Mimarisi **75**
3.4.1 Çok Ölçekli Evrişimsel Öznitelik Çıkarımı **76**
3.4.2 ÇY-UKSB ve Dönüştürücü ile Zamansal Bağlamın Modellenmesi **78**
3.4.3 Olasılıksal Sınıflandırıcı Çıktısı ve Kimlik Karar Düzeneği **80**
3.5 DEHB Tabanlı Üst Değişken Eniyilemesi **82**
3.6 Deneysel Başarım Değerlendirme Ölçütleri **87**
3.6.1 Gürültü tespiti başarım ölçütleri **88**
3.6.2 Gürültü giderimi ve yeniden yapılandırma başarım ölçütleri **89**
3.6.3 Kapalı-küme kimlik tanımlama başarım ölçütleri **92**
3.6.4 Pencere düzeyi ve kişi düzeyi karar ölçütleri **95**
3.6.5 Karar süresi ve işlem zamanı ölçütleri **97**
3.6.6 Tekrarlı deney kararlılığı ve karşılaştırmalı başarım ölçütleri **98**
4. DENEYSEL SONUÇLAR **100**
4.1 Oslo Üniversitesi USYM Dinlenim Durumu EEG Veri Kümesi Senaryoları ve Nüfusbilimsel Analizi **100**
4.1.1 Nüfusbilimsel analiz sonuçları **102**
4.1.2 Deney protokolleri ve veri bölümleme yöntemi **107**
4.2 BÇS–Wasserstein ÜÇA Tabanlı Gürültü Tespiti ve Giderimi Yaklaşımının Başarım Analizi **117**
4.2.1 Çok katılımcılı ve çok kanallı gürültü enjeksiyonu düzeni **117**
4.2.2 BÇS tabanlı gürültü tespit sonuçları **118**
4.2.3 Wasserstein ÜÇA tabanlı yeniden yapılandırma çıktılarının görsel değerlendirilmesi **121**

4.2.4 Yaygın gürültü giderme yöntemleriyle karşılaştırma **123**
4.2.5 Gürültü türüne göre yeniden yapılandırma başarımı **124**
4.2.6 Gürültü gideriminin kapalı-küme kimlik tanımlama başarımına etkisi **125**
4.3 Kanal–Frekans Bandı Seçimi ve Oturumlar Arası Kararlılık Analizi **131**
4.4 Model Eğitim Süreci ve DEHB Tabanlı Üst Değişken Eniyilemesi Sonuçları **142**
4.5 Kapalı-Küme EEG Tabanlı Kimlik Tanımlama Başarım Analizi **147**
4.5.1 Deney protokollerinin karşılaştırılması **148**
4.5.2 Eğitim ve doğrulama davranışının sınıflandırıcı başarımı açısından yorumlanması **150**
4.5.3 Temel yöntemler ve derin öğrenme modelleriyle karşılaştırma **153**
4.5.4 Ana kapalı-küme kimlik tanımlama ölçütleri **154**
4.5.5 KEK eğrisi ve aday sıralama başarısının değerlendirilmesi **155**
4.5.6 Sınıf bazlı hata örüntülerinin analizi **156**
4.5.7 Karar birleştirme yöntemlerinin karşılaştırılması **158**
4.5.8 Test süresi ile başarım arasındaki ilişkinin değerlendirilmesi **159**
4.5.9 Kanal–bant temelli tek kanallı başarıların analizi **161**
4.5.10 Çok ölçekli bant dallarının katkısının değerlendirilmesi **162**
4.5.11 Model bileşenlerine ilişkin çıkarma analizinin yorumlanması **163**
4.5.12 Tekrarlı deneylere göre başarım kararlılığı **165**
4.6 Deneysel Bulguların Tartışılması **165**
5. SONUÇ **172**
KAYNAKLAR **176**
ÖZGEÇMİŞ **186**

SİMGELER DİZİNİ

$A_k(\hat{\mathbf{p}}_m)$: Olasılık vektöründeki en yüksek puanlı ilk k sınıftan oluşan aday kümesi

$\mathcal{B}$: EEG frekans bantları kümesi

$\mathcal{B}_q$: q. kişi düzeyi karar bloğunda bulunan pencere indeksleri kümesi

b : Frekans bandı indeksi

b_{min} : Hiperbant yönteminde kullanılan en küçük kaynak bütçesi

b_{max} : Hiperbant yönteminde kullanılan en büyük kaynak bütçesi

$\mathbf{b}$: Sinir ağı katmanında kullanılan yanlılık vektörü

c : EEG kanal indeksi

$\mathbf{C}$: Karışıklık matrisi

C_r : Diferansiyel evrim çaprazlama oranı

$d_{i,m}^{t,c}$: EEG penceresi için bulanık çıkarım sistemi tarafından üretilen bozulma kararı

$\mathcal{D}_{\text{eğitim}}$: Eğitim veri kümesi

$\mathcal{D}_{\text{doğrulama}}$: Doğrulama veri kümesi

$\mathcal{D}_{\text{test}}$: Test veri kümesi

E_i : i. dalgacık alt bandının enerjisi

E_{toplam} : Dalgacık alt bantlarının toplam enerjisi

f : Frekans değişkeni

f_s : Örnekleme frekansı

F : Diferansiyel evrim ölçekleme katsayısı

$F_{\text{BÇS}}$: Bulanık çıkarım sisteminin karar işlevi

G : Üretken çekişmeli ağın üretici modeli

D : Üretken çekişmeli ağın ayırt edici veya eleştirmen modeli

$\mathbf{H}$: Model tarafından üretilen öznitelik matrisi

i : Birey veya sınıf indeksi

$\mathbb{I}(\cdot)$: Koşul doğru olduğunda 1, aksi durumda 0 değerini alan gösterge işlevi

J : Kanal–bant ayırt edicilik veya amaç işlevi değeri

K : Sınıf sayısı veya dikkat mekanizmasındaki anahtar matrisi; kullanıldığı bağlama göre tanımlanır

K_b : b. frekans bandına karşılık gelen evrişim çekirdeği uzunluğu

L : Sürekli EEG kaydındaki toplam örnek sayısı

$\mathcal{L}$	: Kayıp işlevi
$\mathcal{L}_G$	: Üretici ağın toplam kayıp işlevi
$\mathcal{L}_D$	: Ayırt edici veya eleştirmen ağın kayıp işlevi
$\mathcal{L}_{\text{rec}}$	: Yeniden yapılandırma kaybı
$\mathcal{L}_{\text{spec}}$	: Spektral koruma kaybı
$\mathcal{L}_{\text{id}}$	: Bireye özgü bilginin korunmasına ilişkin kimlik kaybı
m	: EEG pencere indeksi
M	: Toplam EEG penceresi sayısı
M_i	: i. bireye ait EEG penceresi sayısı
M_q	: q. karar bloğunda birleştirilen pencere sayısı
n	: Ayrık zaman veya örnek indeksi
N	: Toplam birey veya sınıf sayısı
N_R	: Bulanık çıkarım sistemindeki toplam kural sayısı
p_i	: i. dalgacık alt bandının normalleştirilmiş enerji oranı
$\hat{p}_{m,i}$	: m. EEG penceresinin i. sınıfa ait olma olasılığı
$\hat{\mathbf{p}}_m$	: m. EEG penceresi için üretilen sınıf olasılıkları vektörü
$\bar{\mathbf{p}}_q$	: q. karar bloğundaki pencerelerin ortalama olasılık vektörü
q	: Kişi düzeyi karar bloğu indeksi
$\mathbf{Q}$	: Dikkat mekanizmasının sorgu matrisi
r	: Kural, deney tekrarı veya dikkat başlığı indeksi; kullanıldığı bağlama göre tanımlanır
R	: Pencere kayma miktarı veya deney tekrar sayısı; kullanıldığı bağlama göre tanımlanır
$\mathbb{R}$	: Gerçel sayılar kümesi
$s[n]$	: Lempel–Ziv karmaşıklığı hesabında kullanılan ikili işaret dizisi
s_r	: r. tekrarlı deneyde elde edilen başarım değeri
$\bar{s}$	: Tekrarlı deneylerde elde edilen ortalama başarım
t	: Kayıt oturumu veya zaman adımı indeksi; kullanıldığı bağlama göre tanımlanır
T_p	: EEG penceresinin saniye cinsinden süresi
T_{karar}	: Kişi düzeyi karar oluşturmak için gerekli işaret süresi
$T_{\text{işlem}}$	: Bir EEG penceresinin ortalama işlem süresi
$\mathbf{V}$	: Dikkat mekanizmasının değer matrisi
$\mathbf{W}$	: Sinir ağı katmanında kullanılan ağırlık matrisi

W	: Bir EEG penceresindeki örnek sayısı
$w_i[k]$	: i. dalgacık alt bandına ait k. dalgacık katsayısı
$x[n]$	: Ayrık zamanlı EEG işaretinin n. örneği
$x^{\text{boz}}[n]$	: Bozulmuş EEG işaretinin n. örneği
$x^{\text{temiz}}[n]$	: Temiz EEG işaretinin n. örneği
$\tilde{x}[n]$	: Yeniden yapılandırılmış EEG işaretinin n. örneği
$\mathbf{x}_{i,m}^{t,c}$	: i. bireyin t. oturumundaki c. kanalından elde edilen m. EEG penceresi
$\hat{\mathbf{x}}_{i,m}^{t,c}$	: Gürültü tespiti ve giderimi sonrasında elde edilen EEG penceresi
$X_i^{t,c}$	: i. bireyin t. oturumunda c. kanaldan alınan sürekli EEG işareti
$X[k]$	: EEG işaretinin ayrık Fourier dönüşümündeki k. frekans bileşeni
y_m	: m. EEG penceresinin gerçek sınıf etiketi
$\hat{y}_m$	: m. EEG penceresi için kestirilen sınıf etiketi
$z_{m,i}$	: m. pencere ve i. sınıf için sınıflandırıcı tarafından üretilen ham çıktı değeri
$\mathbf{z}$	: Üretici ağa verilen gizil gürültü vektörü
α_r	: r. bulanık kuralın ateşleme gücü
α	: Yeniden yapılandırma kaybının ağırlık katsayısı
β	: Spektral koruma kaybının ağırlık katsayısı
δ	: Kimlik koruma kaybının ağırlık katsayısı
Δt	: Ardışık iki EEG örneği arasındaki zaman aralığı
Δf	: Frekans çözünürlüğü
ΔS	: İki yöntem veya deney koşulu arasındaki mutlak başarım farkı
ΔSGO	: Gürültü giderimi sonrasında elde edilen işaret-gürültü oranı iyileşmesi
ϵ	: Sıfıra bölmeyi önlemek ve sayısal kararlılığı sağlamak için kullanılan küçük pozitif sabit
η^2	: Varyans analizine dayalı etki büyüklüğü
η	: Hiperbant yöntemindeki kaynak artırma veya azaltma katsayısı
$\boldsymbol{\lambda}$	: Üst değişken yapılandırma vektörü
$\boldsymbol{\lambda}^*$	: Eniyileme sonucunda seçilen en uygun üst değişken vektörü
μ	: Ortalama değer
$\mu_A(z)$	: z girişinin A bulanık kümesine üyelik derecesi
$\boldsymbol{\mu}_i$	: i. sınıfa ait öznitelik merkez vektörü
ρ	: Oturumlar arasındaki Pearson bağıntı katsayısı

σ	: Standart sapma
σ_s	: Tekrarlı deney başarım değerlerinin standart sapması
$\phi(\cdot)$	: Sinir ağı katmanında kullanılan etkinleştirme işlevi
$\Phi(\cdot)$	: Kimlik koruma kaybında kullanılan öznitelik çıkarım işlevi
ω	: Açısal frekans
$\odot$	: Eleman bazlı çarpma işlemi
$\oplus$	: Vektör veya öznitelik birleştirme işlemi

Kısaltmalar

1B	Bir Boyutlu
ANOVA	Varyans Analizi (Analysis of Variance)
AVB (EDF)	Avrupa Veri Biçimi (European Data Format)
BÇS (FIS)	Bulanık Çıkarım Sistemi (Fuzzy Inference System)
BGVY (BIDS)	Beyin Görüntüleme Veri Yapısı (Brain Imaging Data Structure)
CH	Calinski–Harabasz Dizini
ÇY-UKSB (BiLSTM)	Çift Yönlü Uzun Kısa Süreli Bellek (Bidirectional Long Short-Term Memory)
DB	Davies–Bouldin Dizini
dB	Desibel (Decibel)
DEHB	Diferansiyel Evrim Hiperbantı (Differential Evolution Hyperband)
DEn (WEn)	Dalgacık Entropisi (Wavelet Entropy)
DP (TP)	Doğru Pozitif (True Positive)
DVM (SVM)	Destek Vektör Makinesi (Support Vector Machine)
EEG	Elektroensefalografi (Electroencephalography)
EKDİ	Empirik Kümülatif Dağılım İşlevi
EMG	Elektromiyografi (Electromyography)
EOG	Elektrookülografi (Electrooculography)
ESA (CNN)	Evrişimsel Sinir Ağı (Convolutional Neural Network)
F1	F1 Puanı
GB	Gigabayt (Gigabyte)
GPU	Grafik İşlem Birimi (Graphics Processing Unit)

GSY (PSD)	Güç Spektral Yoğunluğu (Power Spectral Density)
GUP (VEP)	Görsel Uyarılmış Potansiyel (Visual Evoked Potential)
HB	Hiperbant (Hyperband)
Hz	Hertz
ID	Kimlik Tanımlayıcısı (Identifier)
İGO (SNR)	İşaret–Gürültü Oranı (Signal-to-Noise Ratio)
İUP (AEP)	İşitsel Uyarılmış Potansiyel (Auditory Evoked Potential)
k-EYK (k-NN)	k-En Yakın Komşu (k-Nearest Neighbors)
KEK (CMC)	Kümülatif Eşleşme Karakteristiği (Cumulative Match Characteristic)
KOK (RMS)	Kök Ortalama Kare (Root Mean Square)
KOKH (RMSE)	Kök Ortalama Kare Hatası (Root Mean Square Error)
KYB (GRU)	Kapılı Yinelemeli Birim (Gated Recurrent Unit)
LZK	Lempel–Ziv Karmaşıklığı
ms	milisaniye (millisecond)
OİP (ERP)	Olayla İlişkili Potansiyel (Event-Related Potential)
OMH (MAE)	Ortalama Mutlak Hata (Mean Absolute Error)
RAM	Rastgele Erişimli Bellek (Random Access Memory)
RO (RF)	Rastgele Orman (Random Forest)
s	saniye (second)
TSA (RNN)	Tekrarlayan/Yinelemeli Sinir Ağı (Recurrent Neural Network)
UKSB (LSTM)	Uzun Kısa Süreli Bellek (Long Short-Term Memory)
USYM (SRM)	Uyaran-Seçici Yanıt Modülasyonu (Stimulus-Selective Response Modulation)
ÜÇA (GAN)	Üretken Çekişmeli Ağ (Generative Adversarial Network)
Wasserstein ÜÇA-GC (WGAN-GP)	Eğim Cezalı Wasserstein Üretken Çekişmeli Ağ (Wasserstein Generative Adversarial Network with Gradient Penalty)
YN (FN)	Yanlış Negatif (False Negative)
YP (FP)	Yanlış Pozitif (False Positive)
YS	Yığın Standartlaştırması (Batch Normalization)

ŞEKİLLER DİZİNİ

2.1 Biyometrik kimlik tanımlama ve kimlik doğrulama görevlerinin kavramsal karşılaştırması 8
2.2 İnsan beyninin temel kısımlarını gösteren şematik görünüm 9
2.3 EEG işaret oluşumunun kavramsal modeli: beyin kabuğuna ilişkin piramidal sinir popülasyonlarının oluşturduğu eşdeğer iki kutuplu kaynak, hacim iletimi ve elektrot–referans elektrot arasında potansiyel farkının ölçülmesi 19
2.4 Beyin kabuğuna ilişkin loblarla ilişkilendirilmiş EEG elektrot bölgesel dağılımı; uluslararası 10–20 yerleşimi ve 10–10 genişlemesinin üstten görünüşle karşılaştırması 20
2.5 Tez kapsamında değerlendirilen EEG ana frekans bantları ve alt bantları 28
2.6 EEG tabanlı biyometrik kimlik tanımlama literatürünün yöntemsel gelişim çizgisi . 37
3.1 Tez kapsamında önerilen EEG tabanlı biyometrik kimlik tanımlama sisteminin genel iş akışı 43
3.2 EEG-BGVY standardına uygun genel dizin ve dosya yapısının şematik özeti 45
3.3 USYM dinlenim durumu EEG veri kümesinden tez kapsamında kullanılan iki oturumlu kapalı-küme deneysel alt kümenin oluşturulması 47
3.4 Bulanık çıkarım sistemi üyelik işlevi: Dalgacık entropisi 62
3.5 Bulanık çıkarım sistemi üyelik işlevi: Lempel-Ziv karmaşıklığı 64
3.6 Bulanık çıkarım sistemi üyelik işlevi: Kök ortalama kare 65
3.7 Bulanık çıkarım sistemi üyelik işlevi: Çıkış 67
3.8 Önerilen karma ESA–ÇY-UKSB–Dönüştürücü tabanlı tek kanallı EEG biyometrik kimlik tanımlama yaklaşımının genel akışı 86
4.1 USYM dinlenim durumu EEG veri kümesinde cinsiyet dağılımı 103
4.2 Denek yaş dağılımlarının üç boyutlu histogram ile gösterimi 104
4.3 Yaş dağılımının oturum tipine göre karşılaştırılması 105
4.4 İki oturumlu deneklerde oturumlar arası süre dağılımı 106
4.5 Cinsiyete göre iki oturum arasındaki süre dağılımı 107
4.6 Kontrollü deney koşullarında oluşturulan temiz yapay EEG işaretinin zaman bölgesindeki örnek dalga biçimi ve güç spektral yoğunluğu dağılımı 112
4.7 Deneysel kayıt sürecinde elde edilen temiz gerçek EEG işaretinin zaman bölgesindeki örnek dalga biçimi ve güç spektral yoğunluğu dağılımı 113
4.8 EMG ve EOG kaynaklı yapay gürültü bileşenleri eklenmiş yapay EEG işaretinin zaman bölgesindeki örnek dalga biçimi ve güç spektral yoğunluğu dağılımı 114
4.9 EMG ve EOG kaynaklı yapay gürültü bileşenleri eklenmiş gerçek EEG işaretinin zaman bölgesindeki örnek dalga biçimi ve güç spektral yoğunluğu dağılımı 115
4.10 BÇS tabanlı gürültü tespit modülünün yapay ve gerçek EEG senaryolarındaki iki ve üç sınıflı değerlendirme sonuçları 119
4.11 Kontrollü EOG ve EMG bozulmaları eklenen yapay EEG işaretinin Wasserstein ÜÇA ile yeniden yapılandırılması 122
4.12 Rastgele seçilen gürültüye duyarlı kanallarda EOG ve EMG bozulmaları oluşturulan gerçek EEG işaretinin Wasserstein ÜÇA ile yeniden yapılandırılması 123
4.13 Çoklu gürültü eklenmeden önceki örnek ham EEG kaydının zaman bölgesi işareti ve güç spektral yoğunluğu 128
4.14 Örnek ham EEG kaydına çoklu gürültülerin eklenmesinden sonra elde edilen zaman bölgesi işareti ve güç spektral yoğunluğu 128

4.15 En yakın merkez tabanlı ayrışma ölçütüne göre seçilen en önemli 20 kanal–bant çiftinin ilk ve ikinci oturumdaki önem puanları ile oturumlar arası puan tutarlılığının gösterimi 133
4.16 CH/DB bileşik puanı ölçütüne göre seçilen en önemli 20 kanal–bant çiftinin ilk ve ikinci oturumdaki önem puanları ile oturumlar arası puan tutarlılığının gösterimi . . 134
4.17 η^2 ölçütüne göre seçilen en önemli 20 kanal–bant çiftinin ilk ve ikinci oturumdaki önem puanları ile oturumlar arası puan tutarlılığının gösterimi 136
4.18 Sınıflar arası/sınıf içi varyans ölçütüne göre seçilen en önemli 20 kanal–bant çiftinin ilk ve ikinci oturumdaki önem puanları ile oturumlar arası puan tutarlılığının gösterimi 137
4.19 Sınıflar arası/sınıf içi varyans oranı ayrışma ölçütüne göre EEG kanallarının üç boyutlu önem dağılımı 138
4.20 CH/DB bileşik puanı ayrışma ölçütüne göre EEG kanallarının üç boyutlu önem dağılımı 139
4.21 Merkez tabanlı ayrışma ölçütüne göre EEG kanallarının üç boyutlu önem dağılımı 140
4.22 η^2 tabanlı ayrışma ölçütlerine göre EEG kanallarının üç boyutlu önem dağılımı . . . 141
4.23 DEHB tabanlı üst değişken eniyilemesinde doğrulama kaybının değişimi 146
4.24 Önerilen modelin eğitim ve doğrulama kaybı değişimi 152
4.25 Önerilen modelin eğitim ve doğrulama doğruluğu değişimi 152
4.26 Önerilen modelin ana oturumlar arası protokolde KEK eğrisi 156
4.27 Test süresi ile kişi-düzeyi kimlik tanımlama başarısı arasındaki ilişki 160

ÇİZELGELER DİZİNİ

1.1 Tezin problem kapsamı ve temel katkıları 3
2.1 Biyometrik görev türlerinin karşılaştırılması 7
2.2 Beyin bölgelerinin EEG biyometrisi açısından olası katkıları 18
2.3 EEG tabanlı biyometrik kimlik tanımlama literatüründe öne çıkan araştırma hatları 36
2.4 Literatürdeki başlıca boşluklar ve tezin konumlandırılması 41
3.1 USYM dinlenim durumu EEG veri kümesinin tez açısından temel özellikleri 50
3.2 Her pencerenin bozulma içerip içermediğine karar vermek için kullanılan bulanık kural tabanı 68
3.3 DEHB tabanlı üst değişken eniyilemesi için sözde kod 85
4.1 Gürültü giderme yöntemlerinin yapay ve gerçek EEG senaryolarındaki karşılaştırmalı yeniden yapılandırma sonuçları 124
4.2 Önerilen BÇS–Wasserstein ÜÇA yaklaşımının gürültü türüne göre yeniden yapılandırma başarımı 125
4.3 Gürültü giderme ve gürültülü eğitim koşullarının oturumlar arası kapalı-küme kimlik tanımlama başarımına etkisi 129
4.4 DEHB eniyilemesi ile seçilen en iyi üst değişkenler 145
4.5 Deney protokollerine göre kapalı-küme kimlik tanımlama sonuçları 149
4.6 Eğitim ve doğrulama sürecine ilişkin özet sonuçlar 151
4.7 Ana oturumlar arası protokolde model karşılaştırma sonuçları 154
4.8 Önerilen modelin kapalı-küme kimlik tanımlama ölçütlerine göre ana sonuçları ... 155
4.9 Sınıf bazlı en iyi ve en düşük başarım gösteren bireylerin özeti 157
4.10 Farklı karar birleştirme yöntemlerine göre başarım sonuçları 159
4.11 Test süresine göre kişi düzeyi başarım 159
4.12 En yakın merkez tabanlı ölçüte göre öne çıkan kanal–bant çiftlerine dayalı tek kanallı başarılar 162
4.13 İlk 20 kanal–bant çifti içerisinde kanal ve bant gruplarının dağılımı 162
4.14 Çok ölçekli bant dallarına ilişkin bileşen çıkarma sonuçları 163
4.15 Model bileşenlerine ilişkin bileşen çıkarma sonuçları 164
4.16 Tekrarlı deneylere göre başarım kararlılığı 165

1. GİRİŞ

Dijital sistemlerin sağlık, finans, eğitim, savunma, haberleşme ve kişisel veri güvenliği gibi alanlarda yaygınlaşması, güvenilir kimlik tanımlama ve kimlik doğrulama sistemlerine duyulan gereksinimi artırmıştır. Şifre, kart veya anahtar gibi bilgiye ya da nesneye dayalı geleneksel güvenlik düzenekleri; unutulma, paylaşılma, çalınma, yeniden kullanılma ve sosyal mühendislik saldırılarına açıklık gibi sınırlılıklar taşımaktadır. Bu nedenle bireye özgü işlevbilimsel ya da davranışsal özellikleri kullanan biyometrik sistemler, modern güvenlik yaklaşımlarının temel bileşenlerinden biri hâline gelmiştir. Parmak izi, yüz, iris, ses ve damar örüntüsü gibi geleneksel biyometrik özellikler yüksek doğruluk sağlayabilmekle birlikte, bu özelliklerin dış ortamdan gözlemlenebilir, kopyalanabilir veya bazı durumlarda yeniden üretilebilir olması güvenlik ve mahremiyet açısından önemli riskler doğurmaktadır (Campisi ve La Rocca 2014, Fidas ve Lyras 2023, Aldayel vd. 2024).

Elektroensefalografi (EEG) işaretleri, bu noktada geleneksel biyometrik yöntemlere alternatif oluşturan özgün bir biyolojik işaret kaynağı sunmaktadır. EEG işaretleri doğrudan merkezi sinir sistemi etkinliğinden kaynaklanmakta, dışarıdan çıplak gözle gözlemlenememekte, bireyin anlık sinirsel süreçleriyle ilişkili olmakta ve ölçüm sürecinde canlılık bilgisiyle doğal biçimde bağlantı kurmaktadır. Bu özellikler, EEG'yi taklit edilmesi görece zor, gizlilik düzeyi yüksek ve bireye özgü sinirsel örüntülere dayalı bir biyometrik işaret adayı hâline getirmektedir (Campisi ve La Rocca 2014, Zhang vd. 2021, Beyrouthy vd. 2024). Bununla birlikte EEG işaretleri düşük genlikli, gürültüye duyarlı, durağan olmayan ve kayıt koşullarından kolayca etkilenebilen biyolojik işaretlerdir. Elektrot yerleşimi, deri-elektrot empedansı, zihinsel durum, dikkat düzeyi, yorgunluk, kas ve göz hareketleri, çevresel gürültüler ve kayıt cihazı farklılıkları EEG işaretinde oturumlar arası değişkenliğe neden olabilmektedir (Maiorana vd. 2016, Maiorana ve Campisi 2018, Özdenizci vd. 2019).

EEG tabanlı biyometrik sistemlerde iki temel görev öne çıkmaktadır: kimlik tanımlama ve kimlik doğrulama. Kimlik tanımlama, sisteme verilen bir EEG örneğinin kayıtlı bireyler arasından hangi kimliğe ait olduğunu belirleyen bire-çok (1:N) bir eşleştirme problemidir. Kimlik doğrulama ise bireyin iddia ettiği kimliğin doğru olup olmadığını belirleyen bire-bir (1:1) bir kabul/ret problemidir. Bu tezin ana deneysel kapsamı, kapalı-küme EEG tabanlı kimlik tanımlama problemidir. Kapalı-küme senaryoda test örneklerinin sisteme kayıtlı bireylerden birine ait olduğu varsayılmakta ve modelden her EEG penceresini kayıtlı kimliklerden biriyle eşleştirmesi beklenmektedir.

Bu nedenle tezde temel değerlendirme ölçütleri; birinci-sıra doğruluk, ilk-k doğruluk, Kümülatif Eşleşme Karakteristiği (KEK, Cumulative Match Characteristic: CMC), makro F1 puanı ve dengeli doğruluk olarak belirlenmiştir.

EEG biyometrisi alanında erken dönem çalışmaların önemli bir kısmı aynı oturum içi eğitim-test ayrımlarına dayanmıştır. Bu tür değerlendirme yöntemleri, modelin bireye özgü sinirsel örüntüler yerine aynı kayıt oturumuna özgü geçici koşulları öğrenmesine yol açabileceğinden gerçek uygulama başarısını olduğundan yüksek gösterebilir. Bu nedenle son yıllarda oturumlar arası değerlendirme, EEG tabanlı biyometrik sistemlerin güvenilirliği için temel bir ölçüt hâline gelmiştir. Maiorana vd. (2016), EEG işaretlerinin zaman içindeki kalıcılığını farklı kayıt günleri üzerinden incelemiş; Maiorana ve Campisi (2018) ise uzun dönemli EEG biyometrik tanıma başarımını çok oturumlu bir yapı üzerinde değerlendirmiştir. Benzer şekilde Das vd. (2016), görsel uyarılmış potansiyellere dayalı EEG biyometrisinde oturumlar arası kalıcılığı araştırmış; Özdenizci vd. (2019) ise oturuma özgü değişkenliği azaltmak için çekişmeli temsil öğrenme yaklaşımını kullanmıştır. Daha güncel çalışmalarda ise M3CV gibi büyük ölçekli çok denekli ve çok oturumlu veri kümeleri, alan uyarlama, dikkat düzenekleri ve derin öğrenme mimarileriyle birlikte ele alınmaktadır (Huang vd. 2022, Miao vd. 2023, Jin vd. 2024, Liu vd. 2024).

Bu tezde, EEG tabanlı biyometrik kimlik tanımlama problemi tek kanallı, oturumlar arası ve kapalıküme bir deneysel çerçevede ele alınmaktadır. Çalışmada kullanılan Uyaran-Seçici Yanıt Modülasyonu (USYM, Stimulus-Selective Response Modulation: SRM) dinlenim durumu EEG veri kümesi, OpenNeuro ortamında *ds003775* erişim numarası ile sunulan, Beyin Görüntüleme Veri Yapısı (BGVY, Brain Imaging Data Structure: BIDS) uyumlu ve halka açık bir veri kümesidir (Hatlestad-Hall vd. 2022). Veri kümesi 111 sağlıklı katılımcıdan, *BioSemi ActiveTwo* sistemi ile 64 kanallı ve 1024 Hz örnekleme frekansında kaydedilmiş gözler kapalı dinlenim durumu EEG verilerini içermektedir. Katılımcıların 42'si için yaklaşık 2–3 ay sonra ikinci bir kayıt oturumu bulunması, bu tezde önerilen kimlik tanımlama yaklaşımının gerçekçi oturumlar arası koşullarda değerlendirilmesine olanak sağlamaktadır.

Tez kapsamında EEG kayıtları 4 saniyelik örtüşmesiz zaman pencerelerine ayrılmış ve her pencere 4096×1 boyutunda tek kanallı EEG zaman serisi olarak modellenmiştir. Ana deneysel protokolde iki oturumu bulunan 42 katılımcı kayıtlı kullanıcı kümesi olarak ele alınmış, birinci oturum eğitim, ikinci oturum test verisi olarak kullanılmıştır. Aynı oturum içi ve ters yönlü oturumlar arası

protokoller ise karşılaştırma amacıyla değerlendirilmiştir. Önerilen model, tek kanallı EEG pencerelerinden bireye özgü ayırt edici örüntüleri öğrenmek üzere çok ölçekli Evrişimsel Sinir Ağı (ESA, Convolutional Neural Network: CNN), Çift Yönlü Uzun Kısa Süreli Bellek (ÇY-UKSB, Bidirectional Long Short-Term Memory: BiLSTM) ve Dönüştürücü (Transformer) tabanlı dikkat düzeneğini bütünleşik bir yapıda birleştirmektedir. Modelin üst değişkenleri Diferansiyel Evrim Hiperbantı (DEHB, Differential Evolution Hyperband) algoritması ile eniyilenmiş; model çıktısı ise her kayıtlı birey için olasılıksal *softmax* puanları üretecek biçimde tasarlanmıştır.

Bu tezin temel katkıları Çizelge 1.1'de özetlenmiştir. Çalışma, EEG tabanlı biyometrik kimlik tanımlama alanında yalnızca yüksek sınıflandırma doğruluğu elde etmeyi değil, aynı zamanda oturumlar arası genellenebilirlik, tek kanallı uygulanabilirlik, olasılıksal karar üretimi, pencere düzeyi ve kişi düzeyi değerlendirme, kanal–bant katkısı, gürültü/bozulma dayanıklılığı ve üst değişken eniyilemesi gibi bileşenleri birlikte ele alan bütüncül bir yöntemsel çerçeve sunmayı amaçlamaktadır.

Çizelge 1.1 Tezin problem kapsamı ve temel katkıları

Bileşen	**Tez kapsamındaki karşılığı**
Problem tanımı	Kapalı-küme, oturumlar arası, tek kanallı EEG tabanlı biyometrik kimlik tanımlama.
Veri kümesi	USYM dinlenim durumu EEG veri kümesi; 111 katılımcı, iki oturumlu 42 katılımcı, 64 kanal, 1024 Hz.
Deney protokolü	Ana protokolde Oturum 1 eğitim, Oturum 2 test; ek olarak aynı oturum içi ve ters yönlü oturumlar arası karşılaştırmalar.
Model mimarisi	Çok ölçekli ESA, ÇY-UKSB ve Dönüştürücü bileşenlerini birleştiren karma derin öğrenme modeli.
Karar yapısı	Etiket yerine kayıtlı her birey için olasılıksal çıktı üreten *softmax* tabanlı sınıflandırıcı.
Değerlendirme	Birinci-sıra doğruluk, ilk-3/ilk-5 doğruluk, KEK eğrisi, makro F1, dengeli doğruluk, pencere ve kişi düzeyi kararlar.
Eniyileme	DEHB tabanlı üst değişken eniyilemesi.
Ek analizler	Kanal–bant seçimi, test süresi analizi, bileşen çıkarma analizi ve tekrarlı deneylerle kararlılık değerlendirmesi.

Tezin geri kalan bölümleri bu amaç doğrultusunda yapılandırılmıştır. Bölüm 2'de EEG tabanlı biyometrik kimlik tanımlama problemi için gerekli kavramsal ve literatür temeli sunulmaktadır. Bölüm 3'te kullanılan veri kümesi, ön işleme, pencereleme, gürültü tespit/giderim yaklaşımı, önerilen

karma model, DEHB tabanlı üst değişken eniyilemesi ve değerlendirme ölçütleri açıklanmaktadır. Bölüm 4'te deneysel protokoller, nüfusbilimsel analizler, gürültü giderim başarımı, model karşılaştırmaları, kanal–bant analizleri, karar birleştirme sonuçları ve bileşen çıkarma deneyleri sunularak elde edilen bulgular tartışılmaktadır. Bölüm 5'te ise çalışmanın sınırlılıkları değerlendirilmekte ve gelecek çalışmalar için öneriler verilmektedir.

2. EEG TABANLI BİYOMETRİK KİMLİK TANIMLAMA

EEG tabanlı biyometrik kimlik tanımlama, bireylerin merkezi sinir sistemi etkinliğinden kaynaklanan elektriksel örüntüleri kullanarak kimliklendirme veya doğrulama yapılmasını amaçlayan çok disiplinli bir araştırma alanıdır. Bu alan; sinirbilim, biyomedikal işaret işleme, makine öğrenmesi, derin öğrenme, bilgi güvenliği ve insan-bilgisayar etkileşimi gibi farklı disiplinlerin kesişiminde yer almaktadır. EEG'nin yüksek zamansal çözünürlüğe sahip olması, bireye özgü sinirsel salınım örüntüleri içermesi, fizyolojik canlılıkla ilişkili olması ve dışarıdan kolayca gözlemlenememesi, onu geleneksel biyometrik özelliklerden ayıran temel etkenlerdir (Biasiucci vd. 2019, Campisi ve La Rocca 2014, Zhang vd. 2021). Buna karşın, EEG işaretlerinin düşük İşaret-Gürültü Oranına (İGO, Signal-to-Noise Ratio: SNR) sahip olması, oturumlar arası değişkenlik göstermesi, birey içi fizyolojik durum farklılıklarından etkilenmesi ve kayıt sürecinde donanımsal ve çevresel etkilere duyarlı olması, EEG tabanlı biyometrik sistemlerin gerçek dünya uygulamalarına aktarılmasını zorlaştırmaktadır (Maiorana ve Campisi 2018, Fidas ve Lyras 2023, Aldayel vd. 2024).

Bu bölümde, tezin yöntemsel altyapısını oluşturan temel kavramlar açıklanmaktadır. İlk olarak kimlik tanımlama ve kimlik doğrulama problemleri arasındaki farklar ele alınmakta ve bu tezin neden kapalı-küme kimlik tanımlama problemine odaklandığı açıklanmaktadır. Ardından EEG işaretinin biyofiziksel kökeni, beynin anatomik/işlevsel organizasyonu ve elektrot yerleşim sistemleri özetlenmektedir. Daha sonra EEG frekans bantları ve bu bantların biyometrik açıdan önemi tartışılmaktadır. Son olarak literatürdeki EEG tabanlı kimlik tanımlama çalışmaları, deney protokolleri ve güncel boşluklar üzerinden değerlendirilerek bu tezin konumu ortaya konulmaktadır.

2.1 Biyometrik Kimlik Tanımlama ve Doğrulama Kavramları

Biyometrik sistemler, bireylerin fizyolojik ya da davranışsal özelliklerinden yararlanarak kimliklendirme ve erişim denetimi gerçekleştiren güvenlik yaklaşımlarıdır. Parmak izi, yüz, iris, ses, damar örüntüsü ve EEG gibi biyometrik veriler, kişiye özgü olmaları nedeniyle kimlik belirleme süreçlerinde kullanılabilmektedir. Ancak biyometrik sistemlerde kullanılan görev türü, sistemin nasıl karar verdiğini ve hangi ölçütlerle değerlendirileceğini doğrudan belirlemektedir. Bu nedenle kimlik tanımlama, kimlik doğrulama, açık-küme tanıma ve sürekli kimlik doğrulama kavramla-

rının birbirinden açık biçimde ayrılması gerekmektedir (Campisi ve La Rocca 2014, Huang vd. 2022). Kimlik doğrulama bire-bir (1:1) karşılaştırma yapısına sahiptir. Bu görevde kullanıcı sisteme belirli bir kimlik iddiası ile gelir ve sistemin amacı, sunulan biyometrik örneğin iddia edilen kimlikle eşleşip eşleşmediğini belirlemektir. Dolayısıyla kimlik doğrulama sistemleri bir kabul/ret kararı üretir. Örneğin kullanıcı "ben kayıtlı kullanıcı X'im" iddiasında bulunduğunda, sistem kullanıcının EEG örneğini yalnızca X kimliğine ait kayıtlı şablonla karşılaştırır. Elde edilen benzerlik veya güven puanı belirlenen eşik değerinin üzerindeyse iddia kabul edilir; aksi hâlde reddedilir. Bu yapı nedeniyle kimlik doğrulama çalışmalarında yanlış kabul oranı, yanlış ret oranı ve eş hata oranı gibi ölçütler ön plana çıkmaktadır.

Kimlik tanımlama, sisteme sunulan bir biyometrik örneğin kayıtlı kullanıcılar arasından hangi bireye ait olduğunu belirlemeyi amaçlayan bire-çok (1:N) bir eşleştirme problemidir. Bu senaryoda kullanıcı herhangi bir kimlik iddiasında bulunmak zorunda değildir; sistem, verilen biyometrik örneği kayıtlı kimlik havuzundaki tüm bireylerle karşılaştırır ve en olası kimliği seçer. Örneğin EEG tabanlı bir kimlik tanımlama sisteminde, test aşamasında sisteme verilen bir EEG penceresi, kayıtlı bireylerin EEG örüntüleriyle karşılaştırılır ve sistem bu pencerenin hangi kayıtlı bireye ait olduğunu belirlemeye çalışır. Bu nedenle kimlik tanımlama sistemlerinde temel amaç, doğru kimliğin kayıtlı kullanıcılar arasından doğru sırada seçilmesidir.

Kimlik tanımlama problemi kendi içinde kapalı-küme ve açık-küme olmak üzere iki farklı senaryoda ele alınabilir. Kapalı-küme kimlik tanımlama senaryosunda, test örneğinin eğitim aşamasında sisteme kayıtlı bireylerden birine ait olduğu varsayılır. Bu durumda sistemin görevi, bilinmeyen bir kullanıcıyı reddetmek değil, kayıtlı kullanıcılar arasından doğru kimliği seçmektir. Açık-küme senaryoda ise test örneği sisteme kayıtlı olmayan bir bireye ait olabilir. Bu durumda sistemin yalnızca kayıtlı bireyler arasından seçim yapması yeterli değildir; aynı zamanda kayıtlı olmayan kullanıcıları "bilinmeyen" veya "yetkisiz" olarak reddedebilmesi gerekir. Bu nedenle açık-küme tanıma, kapalı-küme tanımlamaya kıyasla daha zorlu ve güvenlik açısından daha gerçekçi bir değerlendirme yapısı sunmaktadır. Bu tezin ana deneysel kurgusu kapalı-küme EEG tabanlı kimlik tanımlama problemine dayanmaktadır. Bu tercihin temel nedeni, çalışmanın öncelikli hedefinin EEG işaretlerinde bireye özgü ve oturumlar arasında korunabilen sinirsel örüntülerin kayıtlı bireyler arasında ne ölçüde ayırt edici olduğunu incelemek olmasıdır. Böylece çalışma, bilinmeyen kullanıcı reddi veya kimlik iddiası doğrulama probleminden ziyade, kayıtlı bireyler arasındaki çok sınıflı EEG tabanlı kimlik ayırt ediciliğine odaklanmaktadır.

Çizelge 2.1 Biyometrik görev türlerinin karşılaştırılması

Görev türü	**Karar yapısı**	**Sistem çıktısı**	**Tipik ölçütler**
Kimlik tanımlama	Bire-çok (1:N) eşleştirme	Kayıtlı kullanıcılar arasından bir kimlik seçimi	Birinci-sıra doğruluk, ilk-k doğruluk, KEK, makro F1, dengeli doğruluk
Kimlik doğrulama	Bire-bir (1:1) karşılaştırma	Kimlik iddiası için kabul veya ret kararı	Yanlış kabul/ret, eş hata, doğru kabul oranları, alıcı işletim karakteristiği, eğri altında kalan alan
Açık-küme tanıma	Kayıtlı kullanıcı seçimi veya bilinmeyen kullanıcı reddi	Kayıtlı kimlik ya da bilinmeyen kullanıcı kararı	Açık-küme doğruluk, reddetme başarımı, yanlış kabul ve yanlış ret oranları
Sürekli kimlik doğrulama	Oturum boyunca tekrarlı veya kesintisiz kontrol	Kullanıcının oturum süresince yetkili kalıp kalmadığına ilişkin karar	Zaman-bağımlı kabul/ret oranları, karar gecikmesi, güven puanı kararlılığı

Kapalı-küme kimlik tanımlama yapısı, modelin EEG işaretinden bireye özgü temsilleri öğrenip öğrenemediğini ve bu temsillerin farklı kayıt oturumlarına aktarılıp aktarılamadığını doğrudan sınaması nedeniyle EEG biyometrisi açısından önemli bir ilk değerlendirme basamağıdır. Özellikle EEG işaretlerinin oturumlar arası değişkenliğe duyarlı olması nedeniyle, aynı oturum içi yüksek doğruluk değerleri tek başına yeterli değildir. Bu nedenle bu tezde temel değerlendirme, birinci oturumdan eğitim ve ikinci oturumdan test yapılan oturumlar arası kapalı-küme protokol üzerinden gerçekleştirilmiştir. Aynı oturum içi ve ters yönlü oturumlar arası protokoller ise modelin oturum etkisine ve kayıt yönüne duyarlılığını karşılaştırmalı olarak incelemek amacıyla kullanılmıştır. Bu tez kapsamında model çıktısının daha sonra aday sıralama, güven puanı ve kişi düzeyi karar birleştirme analizlerinde kullanılabilmesi amaçlanmıştır. Modelin olasılıksal çıktı üretimi, kapalı-küme kimlik tanımlama ölçütleri ve kişi düzeyi karar birleştirme yöntemleri ilerleyen yöntem bölümlerinde ayrıntılı olarak açıklanacaktır. Bu nedenle burada temel vurgu, çalışmanın hangi biyometrik problem türüne odaklandığını ve bu problem türünün doğrulama ya da açık-küme tanıma senaryolarından nasıl ayrıldığını netleştirmektir. Çizelge 2.1 biyometrik sistemlerdeki temel görevleri; karar yapıları, sistem çıktıları ve değerlendirme ölçütleri bakımından özetlemektedir.

Bu kavramsal ayrım doğrultusunda, tezin ana kapsamı kapalı-küme EEG tabanlı kimlik tanımlama olarak sınırlandırılmıştır. Kimlik doğrulama, açık-küme kullanıcı reddi ve sürekli kimlik doğrulama senaryoları ise mevcut model çıktılarının gelecekte genişletilebileceği tamamlayıcı araştırma

yönleri olarak değerlendirilmektedir. Bu yaklaşım, öncelikle EEG işaretindeki bireye özgü ayırt edici bilginin kayıtlı kullanıcılar arasında ne ölçüde kararlı biçimde öğrenilebildiğini ortaya koymayı amaçlamakta; daha sonra bu temel üzerine doğrulama ve açık-küme güvenlik senaryolarının inşa edilebilmesine olanak sağlamaktadır.

Şekil 2.1'de biyometrik kimlik doğrulama ve kimlik tanımlama görevleri kavramsal olarak karşılaştırılmaktadır. Kimlik doğrulama sürecinde kullanıcı önce belirli bir kimlik iddiasında bulunmakta, sistem ise alınan biyometrik örneği yalnızca bu iddiaya ait kayıtlı şablonla karşılaştırarak kabul veya ret kararı üretmektedir. Buna karşılık kimlik tanımlama sürecinde kullanıcının kimliği başlangıçta bilinmemekte; alınan biyometrik örnek veritabanındaki kayıtlı kullanıcılar arasında aranarak en olası kimlik belirlenmektedir. Bu nedenle doğrulama bire-bir (1:1) eşleştirme yapısına, kimlik tanımlama ise bire-çok (1:N) eşleştirme yapısına sahiptir. Bu görselde özetlenen ayrım doğrultusunda, bu tezde sağ tarafta verilen kapalı-küme kimlik tanımlama senaryosu temel alınmıştır.

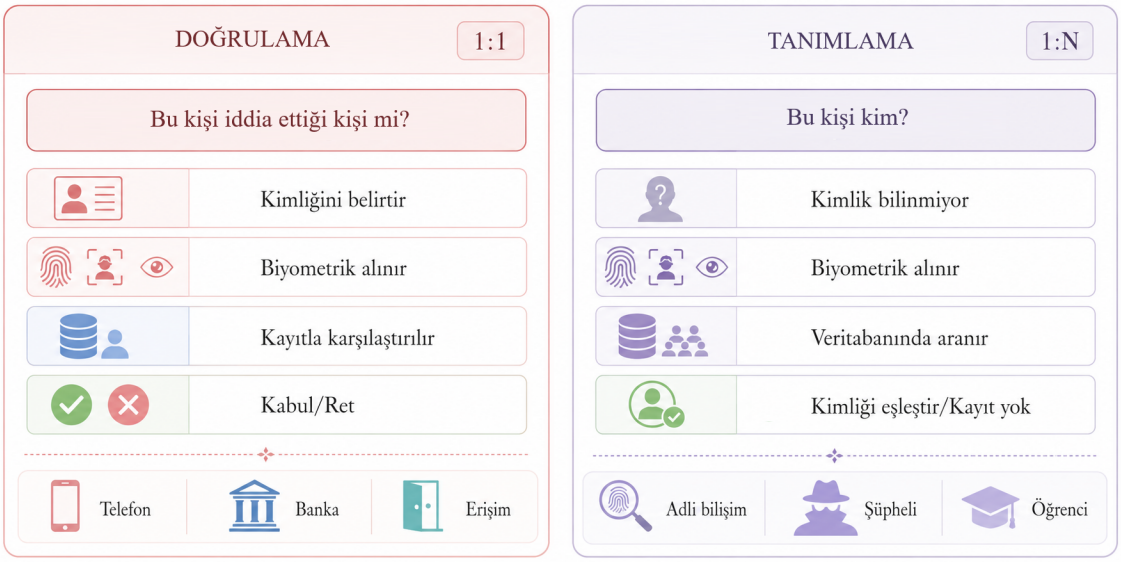

Şekil 2.1 Biyometrik kimlik tanımlama ve kimlik doğrulama görevlerinin kavramsal karşılaştırması

2.2 Beynin Anatomik Yapısı ve Biyometrik Veri Olarak EEG İşareti

EEG tabanlı biyometrik kimlik tanımlama sistemlerinin bilimsel temelini, insan beyninin anatomik organizasyonu ile bu organizasyonun kafa derisi üzerinden ölçülebilen elektriksel etkinliğe nasıl yansıdığı oluşturmaktadır. İnsan beyni; algı, dikkat, bellek, motor kontrol, dil, duygu düzenleme,

karar verme, öğrenme ve bilinç gibi çok sayıda üst düzey işlevi eş zamanlı olarak sürdüren merkezi sinir sisteminin en karmaşık organıdır (Kandel vd. 2021, Blumenfeld 2021, Taner 2021). Erişkin insan beyninde yaklaşık 86 milyar sinir ve buna yakın sayıda sinir-dışı hücre bulunduğu bildirilmiştir (Azevedo vd. 2009). Bu hücresel yapı, birbirinden bağımsız çalışan basit işlem birimlerinden oluşmamakta; aksine beyin kabuğuna ilişkin (kortikal) ve beyin kabuğu altı (subkortikal) bölgeler arasında sürekli bilgi alışverişi sağlayan, çok ölçekli, hiyerarşik ve dinamik bir sinir ağı meydana getirmektedir (Kandel vd. 2021, Blumenfeld 2021). EEG, bu ağın elektriksel etkinliğini milisaniye düzeyinde izleyebilmesi nedeniyle, beynin zamansal dinamiklerini değerlendirmede önemli bir sinir işlevbilimsel ölçüm yöntemidir (Niedermeyer ve Lopes da Silva 2005, Nunez ve Srinivasan 2006, Biasiucci vd. 2019).

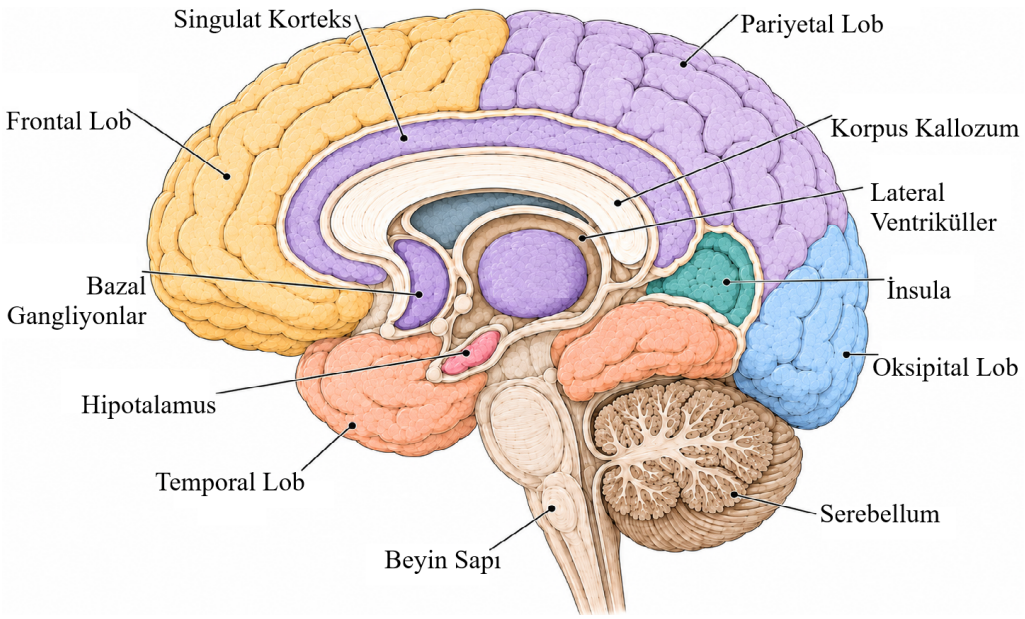

Şekil 2.2 İnsan beyninin temel kısımlarını gösteren şematik görünüm

Biyometrik açıdan EEG işaretini değerli kılan temel özellik, ölçülen işaretin doğrudan merkezi sinir sistemi etkinliğinden kaynaklanmasıdır. Parmak izi, yüz, iris veya ses gibi biyometrik özellikler bedensel ya da davranışsal dışavurumlara dayanırken, EEG işareti bireyin sinirsel işlemleme biçiminden türeyen fizyolojik bir ölçümdür (Kandel vd. 2021, Niedermeyer ve Lopes da Silva 2005, Nunez ve Srinivasan 2006). Bireyler arasında beyin kabuğuna ilişkin yapı biçimi, oluk (sulkus)–kıvrım (girus) yapısı, beyin kabuğuna ilişkin kalınlık, yarımküresel (hemisferik) asimetri, ak madde bağlantısallığı, sinapsla ilişkili organizasyon, talamus-beyin kabuğuna ilişkin etkileşimler ve biliş-

sel işlemleme yöntemleri bakımından doğal farklılıklar bulunmaktadır (Standring 2020, Blumenfeld 2021, Kandel vd. 2021). Bu farklılıklar, EEG işaretinin genlik, zamanlama, bölgesel dağılım, bağlantısallık ve ritmik organizasyon özelliklerine yansıyabilmektedir (Nunez ve Srinivasan 2006, Niedermeyer ve Lopes da Silva 2005, Kandel vd. 2021). Bu nedenle EEG, uygun kayıt koşulları ve doğru analiz yöntemleri altında bireye özgü sinir işlevbilimsel örüntülerin çıkarılabileceği bir biyometrik veri kaynağı olarak değerlendirilmektedir. Bununla birlikte EEG'nin biyometrik amaçla kullanılabilmesi için, işaretin hangi anatomik yapılardan kaynaklandığı, hangi dokulardan geçerek ölçüldüğü ve hangi fizyolojik değişkenlerden etkilendiği ayrıntılı biçimde anlaşılmalıdır (Niedermeyer ve Lopes da Silva 2005, Nunez ve Srinivasan 2006, Blumenfeld 2021).

Makroanatomik açıdan beyin (ensefalon); büyük beyin (serebrum), beyin sapı ile beyincikten (serebellum) oluşmaktadır. Büyük beyin, beynin en büyük bölümünü oluşturur ve sağ-sol yarımkümeler (hemisferler) hâlinde organize olmuştur (Standring 2020, Blumenfeld 2021, Splittgerber 2019, Taner 2021). Şekil 2.2'de beynin temel yarımküre yapısı, nasırlı cisim ve beyin kabuğuna ilişkin loblar şematik olarak gösterilmektedir. Ara beyin (diensefalon) içerisinde yer alan talamus ve hipotalamus, beyin kabuğuna ilişkin etkinliğin düzenlenmesinde kritik görevler üstlenmektedir. Talamus, duyusal bilginin beyin kabuğuna (kortekse) aktarılmasında temel bir ara merkez olmasının yanı sıra, beyin kabuğuna ilişkin ritmik etkinliğin düzenlenmesinde de önemli rol oynamaktadır. Hipotalamus ise özerk (otonom) sinir sistemi, iç denge, hormonal düzenleme ve uyanıklık durumu gibi süreçler üzerinden beyin etkinliğini dolaylı olarak etkileyebilmektedir (Kandel vd. 2021, Blumenfeld 2021, Taner 2021). Beyin sapı; orta beyin (mezensefalon), köprü (pons) ve omurilik soğanı (medulla oblongata) bölümlerinden oluşmakta ve retiküler etkinleştirme sistemi aracılığıyla uyanıklık, dikkat ve genel beyin kabuğuna ilişkin etkinleştirme düzeyinin sürdürülmesinde görev almaktadır (Blumenfeld 2021, Splittgerber 2019, Kandel vd. 2021). Beyincik ise geleneksel olarak motor koordinasyonla ilişkilendirilmekle birlikte, güncel sinirbilim literatüründe bilişsel ve duygusal süreçlerle ilişkili geniş ağların da parçası olarak değerlendirilmektedir (Kandel vd. 2021, Blumenfeld 2021). Kafa derisi EEG'sinde en belirgin kaynak alan büyük beyne ilişkin (serebral) beyin kabuğu olmakla birlikte, beyin kabuğuna ilişkin etkinliğin biçimlenmesinde bu beyin kabuğu altı yapıların düzenleyici etkileri göz ardı edilmemelidir (Kandel vd. 2021, Niedermeyer ve Lopes da Silva 2005, Nunez ve Srinivasan 2006).

Büyük beyin, nasırlı cisim (korpus kallozum) başta olmak üzere birleştirici (komissüral) lif demetleriyle birbirine bağlanan sağ ve sol yarımkürelerden oluşmaktadır. Nasırlı cisim, iki yarımküre

arasında bilgi aktarımı sağlayan en büyük ak madde yoludur ve eşkonumlu (homotopik) beyin kabuğuna ilişkin alanların eşgüdümlü çalışmasında önemli rol oynar. Bunun yanında ön (anterior) birleştirici lif demeti (komissür), arka (posterior) birleştirici lif demeti ve hipokampusa ilişkin (hipokampal) birleştirici lif demeti gibi daha küçük bağlantı yolları da yarımküreler arası iletişime katkıda bulunmaktadır (Standring 2020, Blumenfeld 2021, Splittgerber 2019, Taner 2021).

Sağ ve sol yarımküreler anatomik olarak benzer genel plana sahip olsalar da işlevsel açıdan tam simetrik değildir. Dil işlevleri çoğu bireyde sol yarımküre baskınlığı gösterirken, uzamsal dikkat, yüz tanıma, bazı duygusal işlemleme süreçleri ve bütüncül görsel algı sağ yarımküre ağlarıyla daha güçlü ilişkilendirilebilmektedir. İnsan beyninde birçok işlev, sağ ve sol yarımküreler arasında simetrik olmayan, yanal bir organizasyon göstermektedir (Kandel vd. 2021, Blumenfeld 2021, Taner 2021). Bu yanal organizasyon, EEG kayıtlarında yarımküreler arası genlik farklılıkları, faz ilişkileri, bağlantısallık örüntüleri ve bölgesel etkinlik dağılımları üzerinde bireye özgü farklılıklar oluşturabilir (Niedermeyer ve Lopes da Silva 2005, Nunez ve Srinivasan 2006, Babiloni vd. 2020). Dolayısıyla yarımküresel organizasyon, EEG tabanlı biyometrik sistemlerde yalnızca anatomik bir arka plan bilgisi değil, aynı zamanda potansiyel bir ayırt edici işaret kaynağıdır (La Rocca vd. 2014, Fraschini vd. 2015, Babiloni vd. 2020).

Büyük beyne ilişkin beyin kabuğu, EEG işaretlerinin ana kaynak bölgesi olarak kabul edilmektedir (Niedermeyer ve Lopes da Silva 2005, Nunez ve Srinivasan 2006, Jackson ve Bolger 2014). Beyin kabuğu, beynin dış yüzeyini kaplayan gri madde tabakasıdır ve sinir gövdeleri, dendritler, akson terminalleri, sinapslar, destek hücresine ilişkin hücreler (glial hücreler) ve küçük damarsal (mikrovasküler) yapılardan oluşan yoğun bir doku organizasyonu içerir (Standring 2020, Blumenfeld 2021, Taner 2021). Beyin kabuğu genel olarak altı katmanlı bir yapıya sahiptir. İlk katman daha çok yatay (horizontal) bağlantılar ve apikal dendrit uçlarını içerirken, ikinci ve üçüncü katmanlar beyin kabuğuna ilişkin bağlantılar açısından önemlidir. Dördüncü katman özellikle birincil (primer) duyusal beyin kabuğunda talamusa ilişkin girdilerin sonlandığı granüler tabaka olarak öne çıkar. Beşinci katman büyük piramidal sinirleri ve beyin kabuğu altı yapılara giden çıkışları barındırır. Altıncı katman ise beyin kabuğu-talamusa ilişkin geri projeksiyonlar açısından önemlidir (Kandel vd. 2021, Standring 2020, Blumenfeld 2021, Taner 2021). EEG açısından en kritik hücre gruplarından biri, özellikle üçüncü ve beşinci beyin kabuğuna ilişkin katmanlarda yoğun olarak bulunan piramidal sinirlerdir. Bu sinirlerin apikal dendritlerinin beyin kabuğuna ilişkin yüzeye doğru benzer yönde uzanması, eşzamanlı sinaps sonrası (postsinaptik) potansiyellerin makroskopik elektrik

alanlar oluşturmasına olanak tanımaktadır (Niedermeyer ve Lopes da Silva 2005, Nunez ve Srinivasan 2006, Jackson ve Bolger 2014, Kandel vd. 2021).

EEG'nin oluşumunda tekil eylem potansiyellerinden çok, geniş sinir popülasyonlarının eşzamanlı sinaps sonrası potansiyelleri belirleyicidir. Eylem potansiyelleri kısa süreli ve mekânsal olarak sınırlı olaylar olduğundan, kafa derisi üzerinden ölçülen EEG'ye doğrudan büyük katkı sağlamazlar. Buna karşılık uyarıcı (eksitatör) ve baskılayıcı (inhibitör) sinaps sonrası potansiyeller daha uzun süreli olup, çok sayıda sinirde eşzamanlı gerçekleştiğinde ölçülebilir alan potansiyelleri oluşturabilir (Niedermeyer ve Lopes da Silva 2005, Nunez ve Srinivasan 2006, Jackson ve Bolger 2014, Kandel vd. 2021). Piramidal sinirlerin beyin kabuğuna ilişkin sütunlar boyunca düzenli biçimde hizalanması, sinapsla ilişkili akımların net bir iki kutuplu kaynak (dipol) alanı oluşturmasına katkı sağlar (Nunez ve Srinivasan 2006, Jackson ve Bolger 2014, Kandel vd. 2021). Kıvrım tepesinde yer alan kaynaklar çoğunlukla ışınsal (radyal) yönelimli iki kutuplu kaynak bileşenleri üretirken, oluk duvarlarında yer alan kaynaklar daha çok teğet yönelimli iki kutuplu kaynaklar oluşturabilir (Nunez ve Srinivasan 2006, Blumenfeld 2021, Kajikawa ve Schroeder 2015). Bu nedenle kafa derisi üzerinden kaydedilen EEG'de ölçülen işaret yalnızca sinirsel etkinliğin şiddetine değil, aynı zamanda kaynakların beyin kabuğuna ilişkin yüzeye göre yönelimine, oluk–kıvrım geometrisine ve kaynakların eşzamanlılığına da bağlıdır (Nunez ve Srinivasan 2006, Jackson ve Bolger 2014, Kajikawa ve Schroeder 2015).

Beyin kabuğunun kıvrımlı yapısı EEG biyometrisi açısından özel bir öneme sahiptir. İnsan beyin kabuğu, sınırlı kafatası hacmi içinde geniş bir yüzey alanı sağlayabilmek için kıvrım ve oluklardan oluşan katlanmış bir yapı sergiler (Standring 2020, Blumenfeld 2021, Taner 2021). Bu katlanma örüntüsü bireyler arasında belirli ölçüde değişkenlik gösterir (Standring 2020, Kandel vd. 2021). Oluk derinliği, kıvrım genişliği, beyin kabuğuna ilişkin kalınlık ve gri madde dağılımındaki bireysel farklılıklar, aynı sinirsel olayın kafa derisi üzerinde farklı elektriksel dağılımlar oluşturmasına neden olabilir (Nunez ve Srinivasan 2006, Jackson ve Bolger 2014, Kajikawa ve Schroeder 2015). Dolayısıyla EEG işaretindeki bireysel farklılıklar yalnızca sinirsel etkinlik düzeyindeki farklılıklardan değil, aynı zamanda sinirsel etkinliğin kafa yüzeyine aktarılma biçimini belirleyen anatomik özelliklerden de etkilenmektedir (Nunez ve Srinivasan 2006, Jackson ve Bolger 2014). Bu durum, EEG'nin biyometrik potansiyelini destekleyen bir unsur olarak görülebileceği gibi, aynı bireyden farklı oturumlarda alınan kayıtların karşılaştırılmasında dikkate alınması gereken önemli bir değişkenlik kaynağıdır (Campisi ve La Rocca 2014, Maiorana vd. 2016, Maiorana ve Campisi 2018).

Beyin kabuğu anatomik ve işlevsel özelliklerine göre alınsal (frontal), duvarsal (parietal), şakaksal (temporal) ve artkafasal (oksipital) loblar başta olmak üzere farklı bölgelere ayrılmaktadır. Bu lobların sınırları temel olarak merkezi oluk, yanal (lateral) oluk, duvar-artkafa (parieto-oksipital) oluk ve kalkarin oluk gibi belirgin anatomik işaretlerle tanımlanmaktadır. Bunun yanında adasal (insular) beyin kabuğu, kuşaksı (singulat) beyin kabuğu ve çevresel (limbik) beyin kabuğuna ilişkin alanlar gibi yapılar klasik lob ayrımının dışında veya derininde yer alan önemli beyin kabuğuna ilişkin bileşenlerdir (Standring 2020, Blumenfeld 2021, Taner 2021). EEG işareti kafa derisi üzerinden ölçüldüğü için bu bölgelerin etkinliği doğrudan ve izole biçimde ayrıştırılamasa da, her bölgenin beyin kabuğuna ilişkin ağlar içindeki işlevi EEG'nin bölgesel dağılım ve zamansal özelliklerine katkıda bulunmaktadır (Niedermeyer ve Lopes da Silva 2005, Nunez ve Srinivasan 2006, Babiloni vd. 2020).

Alınsal lob, merkezi oluğun önünde yer almakta ve alın önü (prefrontal) beyin kabuğu, devinim öncesi (premotor) beyin kabuğu, tamamlayıcı (suplementer) motor alan, alınsal göz alanları, göz çukuru-alın bölgesine ilişkin (orbitofrontal) beyin kabuğu ve birincil motor beyin kabuğu gibi alt bölgeleri içermektedir (Standring 2020, Blumenfeld 2021, Taner 2021). Alın önü beyin kabuğu; planlama, karar verme, çalışma belleği, dikkat kontrolü, davranışsal inhibisyon ve hedefe yönelik davranışların düzenlenmesinde kritik rol oynar. Sırt-yan (dorsolateral) alın önü beyin kabuğu bilişsel esneklik ve çalışma belleğiyle, karın-içyan (ventromedial) ve göz çukuru-alın bölgesine ilişkin bölgeler ise ödül değerlendirmesi, sosyal karar verme ve duygu düzenleme ile ilişkilidir (Kandel vd. 2021, Blumenfeld 2021, Taner 2021). Merkez önü (precentral) kıvrımda yer alan birincil motor beyin kabuğu, istemli hareketlerin yürütülmesinde bedensel konum düzenine dayalı (somatotopik) bir organizasyon gösterir. Bu organizasyonda vücudun farklı bölgeleri beyin kabuğuna ilişkin yüzeyde farklı alanlarla temsil edilir (Kandel vd. 2021, Standring 2020, Blumenfeld 2021, Taner 2021). Alınsal lobun bu karmaşık işlevsel yapısı, EEG biyometrisi açısından bireyler arası bilişsel kontrol, motor hazırlık, dikkat düzenleme ve dinlenim hâli organizasyonu farklılıklarının işarete yansıyabileceği anlamına gelmektedir (Cavanagh ve Frank 2014, Arnau-González vd. 2021, Jijomon ve Vinod 2021). Bununla birlikte alınsal elektrotlar göz kırpma, göz hareketi ve alın kası etkinliği gibi elektrookülografi (EOG) ve/veya elektromiyografi (EMG) kaynaklı bozulmalara duyarlı olduğundan, bu bölgeden elde edilen EEG verilerinin biyometrik kullanımı dikkatli ön işleme gerektirmektedir (Niedermeyer ve Lopes da Silva 2005, Muthukumaraswamy 2013, Pion-Tonachini vd. 2019).

Duvarsal lob, merkezi oluğun arkasında ve artkafasal lobun önünde konumlanmakta; birincil bedensel duyusal (somatosensoriyel) beyin kabuğu, üst (superior) duvarsal lobül, alt (inferior) duvarsal lobül, kenar üstü (supramarginal) kıvrım, açısal (angular) kıvrım ve ön kama (precuneus) gibi alt bölgeleri içermektedir (Standring 2020, Blumenfeld 2021, Taner 2021). Merkez arkası (Postcentral) kıvrımda yer alan birincil bedensel duyusal beyin kabuğu, dokunma, basınç, ağrı, sıcaklık ve özduyumsal (proprioseptif) bilgilerin beyin kabuğuna ilişkin temsiline aracılık eder. Bu bölgede de motor beyin kabuğuna benzer biçimde bedensel konum düzenine dayalı bir düzenlenme bulunmaktadır (Kandel vd. 2021, Standring 2020, Blumenfeld 2021, Taner 2021). Üst duvarsal lobül, duyusal-motor bütünleştirme, uzamsal yönelim ve bedenin çevreyle ilişkili temsilinde rol oynar. Alt duvarsal lobül ise dikkat, çoklu duyusal bütünleştirme, beden şeması ve bazı dilsel süreçlerle ilişkilidir (Kandel vd. 2021, Blumenfeld 2021, Taner 2021). Ön kama, özellikle dinlenim hâli ağları, öz-referanslı işlemleme ve bilinçle ilişkili geniş ölçekli ağların önemli bir bileşeni olarak değerlendirilmektedir (Kandel vd. 2021, Blumenfeld 2021). Bu nedenle duvarsal bölge, hem duyusal bütünleştirme hem de dinlenim hâli ağ organizasyonu açısından EEG biyometrisinde önemli bir anatomik kaynak alanı olarak değerlendirilebilir (Fraschini vd. 2015, Wang vd. 2019, Wang vd. 2020). Bu tezde kanal–bant düzeyi analizlerde duvarsal bölgeyi temsil eden P2 ve P4 kanallarının öne çıkması, duvarsal kaynaklı tek kanallı EEG bilgisinin biyometrik ayırt edicilik açısından önemini desteklemektedir.

Şakaksal lob, yanal oluğun altında yer almakta ve üst, orta ve alt şakaksal kıvrımlar ile içyan (medial) şakaksal yapıları içermektedir (Standring 2020, Blumenfeld 2021, Taner 2021). Üst şakaksal kıvrımda birincil işitsel beyin kabuğu yer alır ve işitsel bilginin temel frekans-zaman özelliklerinin işlenmesinde görev alır. Arka üst şakaksal bölgeler ve şakak-duvar (temporo-parietal) bağlantılar dil anlama süreçleri açısından önemlidir (Kandel vd. 2021, Blumenfeld 2021, Taner 2021). İçyan şakaksal lobda hipokampus, iç burunsal (entorhinal) beyin kabuğu, hipokampus çevresi (parahipokampal) kıvrım ve içyan şakaksal lobun önemli bileşenlerinden biri olan amigdala gibi bellek ve duygu ile ilişkili yapılar bulunmaktadır. Hipokampusa ilişkin formasyon olaysal (epizodik) bellek, bağlamsal öğrenme ve mekânsal temsil süreçlerinde temel rol oynar (Kandel vd. 2021, Standring 2020, Blumenfeld 2021, Taner 2021). Kafa derisi EEG'si hipokampusa ilişkin etkinliği doğrudan yüksek uzamsal doğrulukla ölçemese de, içyan şakaksal yapılar ile yeni beyin kabuğuna ilişkin (neokortikal) ağlar arasındaki etkileşimler şakaksal elektrotlarda ölçülen etkinliği etkileyebilir (Niedermeyer ve Lopes da Silva 2005, Nunez ve Srinivasan 2006, Kajikawa ve Schroeder 2015). Şakaksal lob, özellikle uyaran-temelli EEG biyometrisi çalışmalarında olayla ilişkili potansiyeller,

işitsel yanıtlar ve kişiye özgü bilişsel yanıt paternleri açısından önemlidir (Jijomon ve Vinod 2021, Seha ve Hatzinakos 2020, Seha ve Hatzinakos 2021). Ancak şakaksal elektrotların çene, yüz ve boyun kaslarına yakınlığı nedeniyle EMG bozulmalarından etkilenme olasılığı da dikkate alınmalıdır (Niedermeyer ve Lopes da Silva 2005, Muthukumaraswamy 2013, Whitham vd. 2007).

Artkafasal lob, beynin arka bölümünde yer almakta ve görsel işlemlemenin temel beyin kabuğuna ilişkin merkezlerini içermektedir. Kalkarin oluk çevresinde birincil görsel beyin kabuğu yer alır. Birincil görsel beyin kabuğu, retina kaynaklı bilginin ağtabakasal konum düzenini (retinotopik) büyük ölçüde koruyarak işler. Bu bölgeden sonra V2, V3, V4 ve V5/MT gibi ikincil (sekonder) ve ilişkilendirici görsel alanlar; form, renk, hareket ve görsel bütünleştirme süreçlerinde görev alır (Kandel vd. 2021, Standring 2020, Blumenfeld 2021, Taner 2021). Artkafasal lobun anatomik organizasyonu, özellikle görsel uyarılmış potansiyellerin bölgesel dağılımını anlamada önemlidir (Niedermeyer ve Lopes da Silva 2005, Das vd. 2016, Zhao vd. 2019). Dinlenim hâli ve gözler kapalı kayıt koşullarında arka beyin kabuğuna ilişkin alanların belirgin ritmik etkinlik üretmesi, artkafasal ve duvar-artkafa bölgeleri EEG biyometrisi açısından önemli hâle getirmektedir (Niedermeyer ve Lopes da Silva 2005, Klimesch 1999, Klimesch 2012, Suppiah ve Vinod 2018). Bu bölgeden elde edilen bireysel ritim özellikleri, görsel beyin kabuğunun yapısal ve işlevsel organizasyonundaki bireyler arası farklılıkları yansıtabilir (Thomas vd. 2016, Lin vd. 2024). Lin vd. (2024), taşınabilir EEG cihazı ile yürüttükleri çalışmada bireyler arası beyin dalgası tanıma düzeneklerinde salınımsal (osilatuvar) bileşenlerin ayırt edici rolünü vurgulamıştır. Bu bulgu, düşük donanım gereksinimli EEG biyometrisi açısından bölgesel ve anatomik temelli analizlerin önemini desteklemektedir (Lin vd. 2024).

İnsular beyin kabuğu, yanal oluğun derininde yer alan ve alınsal, şakaksal ve duvarsal örtü (operkulum) tarafından örtülen bir beyin kabuğuna ilişkin bölgedir (Standring 2020, Blumenfeld 2021, Taner 2021). İnsula; içduyum (interosepsiyon), özerk düzenleme, tat, ağrı algısı, duygu farkındalığı ve çoklu duyusal bütünleştirme süreçlerinde rol oynar (Kandel vd. 2021, Blumenfeld 2021, Taner 2021). Kafa derisi EEG'sinde adasal etkinliği doğrudan izole etmek güç olsa da, insulanın alınsal, şakaksal, duvarsal ve çevresel ağlarla güçlü bağlantıları nedeniyle EEG ritimlerinin genel organizasyonuna dolaylı katkısı bulunabilir (Niedermeyer ve Lopes da Silva 2005, Nunez ve Srinivasan 2006, Kandel vd. 2021). Kuşaksı beyin kabuğu ise nasırlı cisimin üzerinde uzanan içyan beyin kabuğuna ilişkin bir yapıdır (Standring 2020, Blumenfeld 2021, Taner 2021). Ön kuşaksı beyin kabuğu hata izleme, çatışma çözümü, dikkat ve motivasyonel süreçlerle; arka kuşaksı

beyin kabuğu ise dinlenim hâli ağları ve öz-referanslı işlemleme ile ilişkilidir (Kandel vd. 2021, Blumenfeld 2021). Bu içyan yapılar kafa derisi üzerinden kaydedilen EEG'de doğrudan sınırlı çözünürlükle temsil edilse de, geniş ölçekli beyin ağlarının düzenlenmesinde önemli olduklarından EEG biyometrisi açısından dolaylı fakat önemli anatomik bileşenlerdir (Nunez ve Srinivasan 2006, Fraschini vd. 2015, Wang vd. 2020).

Çevresel sistem bileşenleri de EEG işaretinin bireysel özelliklerinin şekillenmesinde dolaylı rol oynayabilir. Hipokampus, amigdala, hipokampus çevresi beyin kabuğu, kuşaksı beyin kabuğu ve hipotalamus gibi yapılar; bellek, duygu, motivasyon ve özerk düzenleme süreçleriyle ilişkilidir (Kandel vd. 2021, Standring 2020, Blumenfeld 2021, Taner 2021). Bireylerin duygusal düzenleme biçimleri, dikkat durumları, stres düzeyleri ve bellekle ilişkili işlemleme özellikleri EEG kayıtlarında farklılıklar oluşturabilir (Arnau-González vd. 2021, Wilaiprasitporn vd. 2020). Bu nedenle EEG biyometrisinde ölçülen işaret yalnızca sabit bir anatomik imzanın çıktısı değildir; aynı zamanda bireyin anlık fizyolojik ve bilişsel durumundan da etkilenir (Arnau-González vd. 2021, Kralikova vd. 2022, Wang vd. 2019). Bu durum, EEG'nin biyometrik kullanımında merkezi sinir sistemi kaynaklı zengin ve bireye özgü bilgi taşıması açısından önemli bir avantaj sağlamaktadır (Campisi ve La Rocca 2014, Bidgoly vd. 2020, Zhang vd. 2021). Ancak aynı bireye ait EEG örüntülerinin farklı oturumlarda fizyolojik duruma bağlı olarak değişebilmesi, sistemin kararlılığı açısından önemli bir zorluk oluşturmaktadır (Maiorana vd. 2016, Maiorana ve Campisi 2018, Rahman vd. 2022).

Duyusal-devinimsel (sensörimotor) beyin kabuğu, EEG biyometrisi açısından ayrı bir öneme sahiptir. Merkez önü kıvrımdaki birincil motor beyin kabuğu ve merkez arkası kıvrımdaki birincil bedensel duyusal beyin kabuğu, merkezi oluk çevresinde karşılıklı olarak konumlanır (Standring 2020, Blumenfeld 2021, Taner 2021). Bu bölge, hareket yürütme, hareket hazırlığı, motor imgeleme ve duyusal geri bildirim süreçleriyle ilişkilidir (Kandel vd. 2021, Blumenfeld 2021, Taner 2021). Motor beyin kabuğunda vücut bölümlerinin beyin kabuğuna ilişkin temsili bedensel konum düzenine dayalı olarak düzenlenmiştir ve bu düzen sıklıkla motor homunkulus kavramı ile açıklanmaktadır (Kandel vd. 2021, Standring 2020, Blumenfeld 2021, Taner 2021). Duyusal-devinimsel alanlardan elde edilen EEG örüntüleri, motor görevler, motor imgeleme veya dinlenim hâli ölçümlerinde bireyler arasında farklılık gösterebilir (Pfurtscheller ve Lopes da Silva 1999, Lawhern vd. 2018). Bu nedenle duyusal-devinimsel bölge, özellikle görev-temelli EEG biyometrisi ve beyin-bilgisayar arayüzü tabanlı kimlik tanımlama yaklaşımlarında dikkate alınması gereken önemli bir

anatomik kaynaktır (Lawhern vd. 2018, Campisi ve La Rocca 2014).

Beyin kabuğuna ilişkin alanlar arasındaki bağlantısallık da EEG biyometrisi açısından anatomik düzeyde önemlidir. Beyin, yalnızca bölgesel etkinlik üreten ayrık merkezlerden oluşmaz; aksine kısa ve uzun menzilli bağlantılar aracılığıyla çalışan geniş ölçekli ağlardan oluşur (Kandel vd. 2021, Blumenfeld 2021). Alın-duvar (fronto-parietal) ağlar dikkat ve bilişsel kontrol süreçlerinde, varsayılan kip (default mode) ağı dinlenim hâli ve öz-referanslı işlemlemede, çevresel ağlar duygu ve motivasyonda, duyusal-devinimsel ağlar ise hareket ve beden temsili süreçlerinde öne çıkar (Kandel vd. 2021, Blumenfeld 2021). Bu ağların bireyler arasında bağlantı gücü, zamanlama ve etkileşim biçimi bakımından farklılık göstermesi, EEG işaretinin bağlantısallık temelli biyometrik özellikler taşımasına zemin hazırlamaktadır (La Rocca vd. 2014, Fraschini vd. 2015, Wang vd. 2019, Wang vd. 2020). Bu nedenle EEG tabanlı kimlik tanımlamada yalnızca tek bir kanalın genlik bilgisi değil, kanallar arası ilişki, bölgesel dağılım ve zamanla değişen ağ örüntüleri de potansiyel biyometrik temsil kaynakları olarak değerlendirilebilir (La Rocca vd. 2014, Fraschini vd. 2015, Tian vd. 2023, Wang vd. 2020).

Çizelge 2.2, temel beyin kabuğuna ilişkin ve ilişkili beyin bölgelerinin EEG işaretine ve biyometrik temsil çıkarımına olası katkılarını özetlemektedir. Bu çizelge, beyin kabuğuna ilişkin bölgelerin tek başına kesin kimlik belirleyiciler olarak yorumlanmaması gerektiğini; ancak her bölgenin EEG tabanlı biyometrik sistemlerde farklı türde ayırt edici bilgi sağlayabileceğini göstermektedir (Campisi ve La Rocca 2014, Bidgoly vd. 2020, Zhang vd. 2021). EEG işaretinin kafa derisinden ölçülebilmesi, beyin kabuğuna ilişkin kaynaklardan çıkan elektriksel alanların farklı anatomik katmanlardan geçerek yüzeye ulaşmasıyla mümkündür. Bu katmanlar genel olarak beyin dokusu, beyin omurilik sıvısı, meninksler, kafatası, deri altı dokular ve saçlı deriden oluşmaktadır (Niedermeyer ve Lopes da Silva 2005, Nunez ve Srinivasan 2006, Jackson ve Bolger 2014). Beyin omurilik sıvısı yüksek iletkenliğe sahipken, kafatası görece düşük iletkenlik gösterir. Kafatasının bu düşük iletkenlik özelliği, elektrik alanların zayıflamasına ve uzamsal olarak yayılmasına neden olur (Nunez ve Srinivasan 2006, Jackson ve Bolger 2014, Kajikawa ve Schroeder 2015). Bu nedenle kafa derisi EEG'si, beyin kabuğuna ilişkin kaynakların doğrudan ve keskin bir haritası değildir; kaynakların hacim iletimi yoluyla bulanıklaşmış ve dokuların iletkenlik özelliklerinden etkilenmiş bir yansımasıdır (Niedermeyer ve Lopes da Silva 2005, Nunez ve Srinivasan 2006, Jackson ve Bolger 2014, Kajikawa ve Schroeder 2015).

Çizelge 2.2 Beyin bölgelerinin EEG biyometrisi açısından olası katkıları

Bölge	**Anatomik/EEG açısından öne çıkan özellikler**	**Biyometrik yorum**
Alınsal lob	Alın önü beyin kabuğu, devinim öncesi alanlar, tamamlayıcı motor alan, alınsal göz alanları ve birincil motor beyin kabuğu; dikkat, yürütücü işlevler, karar verme ve motor hazırlık süreçleri	Bilişsel kontrol, dikkat ve motor planlama süreçlerindeki bireysel farklılıkları yansıtabilir; ancak EOG ve alın kası bozulmalarına duyarlıdır.
Duvarsal lob	Birincil bedensel duyusal beyin kabuğu, üst/alt duvarsal lobüller, açısal kıvrım, kenar üstü kıvrım ve ön kama; duyusal bütünleştirme, uzamsal dikkat ve beden temsili	Dinlenim hâli ağları, duyusal-motor bütünleştirme ve bölgesel ayırt edicilik açısından güçlü adaydır; tek kanallı EEG biyometrisinde önemli olabilir.
Şakaksal lob	Birincil işitsel beyin kabuğu, dil ilişkili bölgeler, içyan şakaksal yapılar ve çevresel bağlantılar; işitsel işlemleme, bellek ve duygu ile ilişkili süreçler	Uyaran-temelli veya bellek ilişkili EEG biyometrisinde kişiye özgü yanıt paternleri sağlayabilir; EMG etkilerine dikkat edilmelidir.
Artkafasal lob	Birincil ve ikincil görsel beyin kabukları; kalkarin oluk çevresinde ağtabakasal konum düzenine dayalı organizasyon; arka beyin kabuğuna ilişkin etkinlik	Görsel işlemleme ve arka beyin kabuğuna ilişkin organizasyon üzerinden bireysel farklılıklar taşıyabilir; dinlenim hâli ve görsel uyaran temelli çalışmalarda önemlidir.
İnsula ve kuşaksı beyin kabuğu	İnterosepsiyon, duygu düzenleme, hata izleme, bilişsel kontrol, motivasyon ve özerk süreçlerle ilişkili içyan/derin beyin kabuğuna ilişkin yapılar	Doğrudan kaynak ayrıştırması zor olsa da alınsal-duvarsal-şakaksal ağlar üzerinden EEG ritimlerini ve durum değişkenliğini etkileyebilir.
Duyusal-devinimsel alanlar	Merkez önü ve merkez arkası kıvrımlar; bedensel konum düzenine dayalı motor ve duyusal temsil; hareket, motor imgeleme ve duyusal geri bildirim süreçleri	Motor görevler, motor imgeleme veya dinlenim hâli duyusal-devinimsel örüntüler üzerinden ayırt edici bilgi sağlayabilir.
Talamus ve talamus-beyin kabuğuna ilişkin bağlantılar	Duyusal aktarım, beyin kabuğuna ilişkin etkinleştirme, uyku–uyanıklık düzeni, dikkat düzeyi ve beyin kabuğuna ilişkin ritimlerin düzenlenmesi	EEG'nin genel organizasyonu ve oturumlar arası durum değişkenliği üzerinde belirleyici olabilir.
Çevresel yapılar	Hipokampus, amigdala, hipokampus çevresi beyin kabuğu ve hipotalamus; bellek, duygu, motivasyon ve özerk düzenleme	Bireyin duygusal ve fizyolojik durumuna bağlı EEG farklılıklarını etkileyebilir; biyometrik kararlılık açısından dikkate alınmalıdır.

Hacim iletimi, EEG'nin en önemli avantajlarından ve sınırlılıklarından birini aynı anda oluşturmaktadır. Bir yandan beyin kabuğuna ilişkin elektriksel etkinliğin girişimsel olmayan biçimde ölçülmesini sağlar; diğer yandan farklı beyin kabuğuna ilişkin bölgelerden gelen etkinliklerin kafa derisi düzeyinde üst üste binmesine neden olur (Niedermeyer ve Lopes da Silva 2005, Nunez ve Srinivasan 2006, Jackson ve Bolger 2014, Kajikawa ve Schroeder 2015). Bu nedenle EEG, zamansal çözünürlüğü yüksek bir yöntem olmakla birlikte, uzamsal çözünürlük bakımından sınırlıdır (Niedermeyer ve Lopes da Silva 2005, Nunez ve Srinivasan 2006, Biasiucci vd. 2019). Biyometrik sistemlerde bu durum iki açıdan önemlidir. İlk olarak, tek bir elektrottan ölçülen işaret yalnızca o elektrodun altındaki beyin kabuğuna ilişkin bölgenin etkinliğini değil, daha geniş bir kaynak karışımını temsil edebilir (Nunez ve Srinivasan 2006, Jackson ve Bolger 2014, Kajikawa ve Schroeder 2015). Ek olarak, aynı bireyden farklı oturumlarda alınan EEG kayıtları; elektrot yerleşimindeki küçük değişimler, referanslama farkları, saçlı deri-elektrot arayüzü, empedans değişimleri ve fizyolojik durum farklılıkları nedeniyle farklı bölgesel dağılım ve zamansal özellikler gösterebilir (Niedermeyer ve Lopes da Silva 2005, Maiorana vd. 2016, Maiorana ve Campisi 2018). Bu nedenle EEG biyometrisinde oturumlar arası değerlendirme, modelin gerçekten bireye özgü sinirsel örüntüleri mi yoksa belirli kayıt koşullarına özgü geçici özellikleri mi öğrendiğini ayırt etmek için kritik öneme sahiptir (Maiorana vd. 2016, Maiorana ve Campisi 2018, Özdenizci vd. 2019).

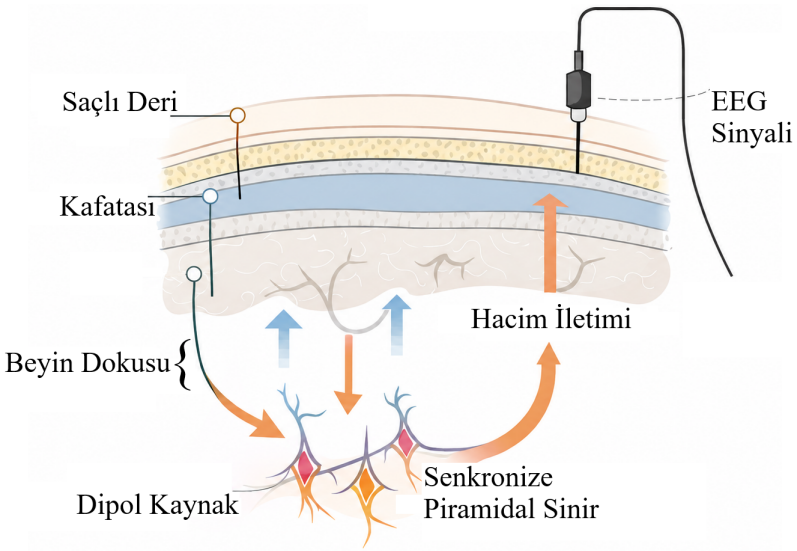

Şekil 2.3 EEG işaret oluşumunun kavramsal modeli: beyin kabuğuna ilişkin piramidal sinir popülasyonlarının oluşturduğu eşdeğer iki kutuplu kaynak, hacim iletimi ve elektrot–referans elektrot arasında potansiyel farkının ölçülmesi

EEG işaretlerinin ölçümünde elektrot yerleşim sistemi, anatomik yorumlama ve çalışmalar arası karşılaştırılabilirlik açısından temel bir bileşendir. Uluslararası 10–20 sistemi ve bu sistemin daha yüksek çözünürlüklü uzantıları olan 10–10 ve 10–5 sistemleri, elektrotların kafa derisi üzerindeki konumlarını standartlaştırmak amacıyla kullanılmaktadır (Niedermeyer ve Lopes da Silva 2005, Acharya vd. 2016). Bu sistemlerde Fp, F, C, P, T ve O gibi harfler elektrotların yaklaşık anatomik bölgelerini temsil eder. Fp alın kutupsal (frontopolar), F alınsal, C merkezi/duyusal-devinimsel, P duvarsal, T şakaksal ve O artkafasal yerleşimleri ifade eder. Tek sayılı dizinler sol yarımküreyi, çift sayılı dizinler sağ yarımküreyi ve "z" eki orta hattı gösterir (Niedermeyer ve Lopes da Silva 2005, Acharya vd. 2016). Bununla birlikte elektrot adlarının anatomik karşılıkları yaklaşık yorumlar sunar; örneğin C elektrotları anatomik olarak ayrı bir merkezi loba değil, merkezi oluk çevresindeki duyusal-devinimsel beyin kabuğuna karşılık gelmektedir (Standring 2020, Blumenfeld 2021, Acharya vd. 2016). Acharya vd. (2016), elektrot pozisyon adlandırmalarının standartlaştırılmasının araştırma amaçlı EEG çalışmalarında tutarlı raporlama için gerekli olduğunu vurgulamıştır.

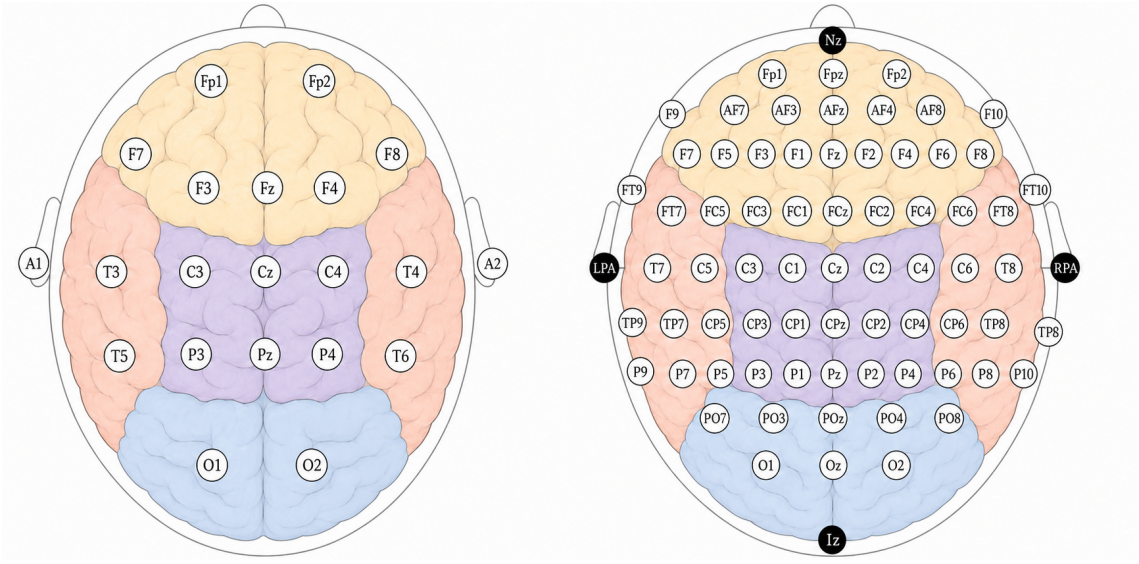

10-20 Sistemi 10-10 Genişlemesi

Şekil 2.4 Beyin kabuğuna ilişkin loblarla ilişkilendirilmiş EEG elektrot bölgesel dağılımı; uluslararası 10–20 yerleşimi ve 10–10 genişlemesinin üstten görünüşle karşılaştırması

Elektrot yerleşim sistemleri, EEG biyometrisi açısından yalnızca teknik bir kayıt ayrıntısı değildir. Hangi kanalların kullanılacağı, tek kanallı ya da çok kanallı temsilin nasıl kurulacağı, kanal seçiminin nasıl yapılacağı ve elektrotların yaklaşık beyin kabuğuna ilişkin karşılıklarının nasıl yorumlanacağı doğrudan bu yerleşim sistemlerine bağlıdır (Alyasseri vd. 2020, Suppiah ve Vinod

2018, Thomas vd. 2016). Alınsal, şakaksal, duvarsal ve artkafasal bölgelerden elde edilen işaretlerin farklı ayırt edicilik düzeyleri göstermesi, elektrot konumunun model tasarımındaki rolünü ortaya koymaktadır (Alyasseri vd. 2020, Jijomon ve Vinod 2021, Suppiah ve Vinod 2018, Lin vd. 2024). Bu tezde tek kanallı EEG temsili temel alındığından, her bir kanalın biyometrik katkısı ayrıca değerlendirilmiş ve kanal düzeyinde ayırt edici örüntüler analiz edilmiştir. Şekil 2.4'te beyin kabuğuna ilişkin loblar ile 10–20 ve 10–10 elektrot yerleşim sistemlerinin ilişkisi görsel olarak özetlenmektedir.

EEG işaretinin biyometrik veri olarak kullanılabilirliği, bireyler arası sinir işlevbilimsel farklılıkların zaman içinde belirli ölçüde korunabilmesine bağlıdır (Maiorana vd. 2016, Maiorana ve Campisi 2018, Uudeberg vd. 2025). Bu farklılıklar bir yandan beyin kabuğuna ilişkin ve beyin kabuğu altı ağların bireye özgü işleyişinden, diğer yandan beyin anatomisinin bireysel özelliklerinden kaynaklanabilir (Kandel vd. 2021, La Rocca vd. 2014, Fraschini vd. 2015). Dinlenim hâli EEG özellikleri, faz ilişkileri, bağlantısallık ölçütleri, entropi ve karmaşıklık göstergeleri gibi birçok EEG ölçütünün bireysel farklılık taşıyabildiği bildirilmiştir (Bidgoly vd. 2020, Zhang vd. 2021, La Rocca vd. 2014, Fraschini vd. 2015). Ancak EEG işareti durağan olmayan bir biyolojik işarettir (Niedermeyer ve Lopes da Silva 2005, Nunez ve Srinivasan 2006). Uyanıklık düzeyi, yorgunluk, dikkat, duygusal durum, göz hareketleri, kas etkinliği, elektrot empedansı, kayıt ortamı ve donanım farklılıkları aynı bireyin farklı oturumlardaki EEG örüntülerini değiştirebilir (Maiorana vd. 2016, Maiorana ve Campisi 2018, Arnau-González vd. 2021, Muthukumaraswamy 2013). Bu nedenle EEG tabanlı biyometrik sistemlerde yalnızca yüksek sınıflandırma doğruluğuna ulaşmak yeterli değildir; modelin farklı oturumlarda, farklı günlerde veya farklı kayıt koşullarında kararlı çalışıp çalışmadığı da gösterilmelidir (Maiorana vd. 2016, Maiorana ve Campisi 2018, Rahman vd. 2022). Rahman vd. (2022), EEG biyometrisinde oturumlar arası değişkenliğin önemli bir problem olduğunu ve oturumdan bağımsız temsil öğrenmenin uygulamaya dönük sistemler için kritik olduğunu vurgulamıştır. Uudeberg vd. (2025) ise tek kanallı EEG ölçütlerinin bir yıllık kararlılığını inceleyerek, EEG tabanlı ölçütlerin bireysel düzeyde kararlılık ve değişkenlik açısından sistematik olarak değerlendirilmesi gerektiğini göstermiştir.

EEG'nin biyometrik kullanımı açısından önemli bir diğer boyut, işaretin canlılıkla doğrudan ilişkili olmasıdır (Campisi ve La Rocca 2014, Bidgoly vd. 2020, Zhang vd. 2021). Parmak izi, yüz veya iris gibi bazı geleneksel biyometrik örnekler dış ortamdan gözlemlenebilir, kopyalanabilir veya sahte örneklerle taklit edilmeye çalışılabilir (Campisi ve La Rocca 2014, Fidas ve Lyras 2023, Aldayel

vd. 2024). EEG ise aktif beyin işlevi gerektiren fizyolojik bir işaret olduğu için, canlılık bilgisini doğal olarak içeren bir yöntem olarak değerlendirilmektedir (Campisi ve La Rocca 2014, Bidgoly vd. 2020, Zhang vd. 2021). Bununla birlikte bu özellik, EEG tabanlı biyometrik sistemlerin tüm güvenlik risklerinden bağımsız olduğu anlamına gelmemektedir (Bidgoly vd. 2020, Fidas ve Lyras 2023, Aldayel vd. 2024). Kayıt cihazı, veri iletim hattı, yazılım arayüzü, model karar eşiği ve kayıt protokolü gibi bileşenler güvenlik açısından ayrıca değerlendirilmelidir (Bidgoly vd. 2020, Fidas ve Lyras 2023, Aldayel vd. 2024). Bu nedenle EEG biyometrisi, hem sinir işlevbilimsel hem de bilgi güvenliği perspektifinden ele alınması gereken bütüncül bir sistem problemidir (Campisi ve La Rocca 2014, Bidgoly vd. 2020, Fidas ve Lyras 2023).

Bu bölümde açıklanan anatomik ve biyofiziksel temeller, tezin yöntemsel kurgusu açısından üç temel sonuca işaret etmektedir. İlki, EEG işareti yalnızca beyin kabuğuna ilişkin yüzeydeki anlık elektriksel etkinliğin basit bir yansıması değil, beyin kabuğuna ilişkin katman organizasyonu, piramidal sinir geometrisi, oluk–kıvrım yapısı, beyin kabuğu altı düzenleyici ağlar, hacim iletimi ve elektrot yerleşimi gibi çok sayıda anatomik ve biyofiziksel etkenin birleşik sonucudur (Niedermeyer ve Lopes da Silva 2005, Nunez ve Srinivasan 2006, Jackson ve Bolger 2014, Kajikawa ve Schroeder 2015, Kandel vd. 2021). Diğeri, elektrot konumu ve anatomik kaynak ilişkisi, EEG biyometrisinde model başarısını doğrudan etkileyebilecek temel tasarım değişkenlerindendir (Acharya vd. 2016, Alyasseri vd. 2020, Suppiah ve Vinod 2018, Lin vd. 2024). Ayrıca, EEG'nin oturumlar arası değişkenliği nedeniyle aynı oturum içi başarı değerleri gerçekçi biyometrik başarımı tek başına temsil etmez (Maiorana vd. 2016, Maiorana ve Campisi 2018, Özdenizci vd. 2019, Rahman vd. 2022). Bu gerekçeler doğrultusunda tezde, tek kanallı EEG pencereleri üzerinden bireye özgü örüntülerin öğrenilmesi, kanal katkılarının incelenmesi ve model başarısının oturumlar arası protokollerle değerlendirilmesi temel yöntemsel yaklaşım olarak benimsenmiştir.

2.3 EEG Frekans Alt Bantları

EEG işareti, beyin kabuğuna ilişkin ve beyin kabuğu altı ağların zaman içinde değişen elektriksel etkinliğin kafa derisi üzerinden ölçülebilen bir yansımasıdır. Önceki alt bölümde açıklandığı üzere bu etkinliğin temel kaynağı, özellikle beyin kabuğuna ilişkin piramidal sinir popülasyonlarında ortaya çıkan eşzamanlı sinaps sonrası potansiyellerdir. Bu potansiyeller, beyin dokusu, beyin omurilik sıvısı, kafatası ve saçlı deri gibi farklı iletkenlik özelliklerine sahip anatomik katmanlardan

geçerek yüzey elektrotları tarafından ölçülebilir hâle gelmektedir. Bu nedenle EEG, tek bir sinirin etkinliğini değil, çok sayıda sinirin uzamsal ve zamansal olarak bütünleşmiş elektriksel çıktısını temsil eder. Bu bütünleşik yapı, EEG'nin zaman alanında dalga biçimi olarak, frekans alanında ise farklı salınımsal bileşenler şeklinde incelenmesine olanak sağlamaktadır (Nunez ve Srinivasan 2006, Jackson ve Bolger 2014, Kajikawa ve Schroeder 2015).

EEG frekans bantları, işaretin farklı zaman ölçeklerinde ortaya çıkan salınımsal bileşenlerini sınıflandırmak için kullanılan temel bir analiz çerçevesidir. Delta, teta, alfa, beta ve gama olarak adlandırılan klasik bantlar, tarihsel olarak klinik EEG gözlemleri, uyku–uyanıklık durumları, dinlenim hâli etkinliği ve görev-temelli beyin yanıtları üzerinden tanımlanmıştır. Bununla birlikte bu bantlar kesin biyolojik sınırları olan ayrık kategoriler değildir. Farklı çalışmalarda bant aralıklarının küçük farklılıklar gösterebilmesi, EEG salınımlarının tek bir anatomik üreteçe ya da tek bir bilişsel işlev alanına indirgenemeyeceğini göstermektedir. Bu nedenle frekans bantları, mutlak sinir işlevbilimsel sınırlar olarak değil, EEG işaretinin spektral yapısını karşılaştırılabilir biçimde incelemeye yarayan pratik ve metodolojik bölütler olarak değerlendirilmelidir (Niedermeyer ve Lopes da Silva 2005, Babiloni vd. 2020).

Frekans bantlarının EEG analizindeki önemi üç temel düzeyde ele alınabilir. Birincisi, farklı frekans aralıkları farklı zaman ölçeklerindeki sinirsel süreçlere duyarlıdır. Düşük frekanslı bileşenler daha yavaş ve geniş ölçekli ağ etkileşimlerini yansıtabilirken, daha yüksek frekanslı bileşenler daha hızlı, yerel ve kısa süreli beyin kabuğuna ilişkin işlemleme süreçleriyle ilişkili olabilir. Diğeri, frekans bileşenlerinin bölgesel dağılımı anatomik açıdan anlamlıdır; örneğin bazı ritmik bileşenler arka beyin kabuğuna ilişkin bölgelerde daha belirgin gözlenirken, bazıları duyusal-devinimsel ya da alınsal alanlarla daha güçlü ilişki gösterebilir. Ayrıca, bireyler arasında spektral güç dağılımı, baskın frekans, bantlar arası oranlar ve kanal–bant etkileşimleri bakımından farklılıklar bulunabilmektedir. Bu özellikler, EEG tabanlı biyometrik kimlik tanımlama çalışmalarında frekans bantlarının yalnızca fizyolojik yorum için değil, aynı zamanda ayırt edici temsil çıkarımı için de önemli olduğunu göstermektedir (Buzsáki ve Draguhn 2004, Zhang vd. 2021, Lin vd. 2024).

Delta bandı, genel olarak EEG spektrumunun en düşük frekanslı bölümünü temsil eder. Klinik ve araştırma literatüründe delta etkinliği çoğunlukla derin uyku, düşük uyarılmışlık düzeyi ve geniş ölçekli beyin kabuğuna ilişkin senkronizasyon süreçleriyle ilişkilendirilmiştir. Bununla birlikte delta etkinliğinin yalnızca uykuya özgü ya da patolojik bir bileşen olarak yorumlanması yeterli değildir.

Uyanıklık durumunda da özellikle dikkat, görev dışı ağların baskılanması, bilişsel yorgunluk ve geniş ölçekli beyin kabuğuna ilişkin düzenleme süreçleriyle ilişkili delta bileşenleri gözlenebilmektedir (Harmony 2013). Bu nedenle delta bandı, EEG işaretinin yavaş zaman ölçekli organizasyonunu değerlendirmek açısından önemlidir.

Bu tez kapsamında delta bandı, geniş bir ana bant olarak değerlendirilmekle birlikte düşük-delta ve yüksek-delta alt bantlarına da ayrılmıştır. Düşük-delta bileşenleri, çok yavaş beyin kabuğuna ilişkin potansiyel değişimleri, kayıt koşullarına bağlı düşük frekanslı dalgalanmalar ve uzun zaman ölçekli sinirsel düzenleme süreçleriyle ilişkili olabilir. Ancak bu aralık, elektrot polarizasyonu, hareket, terleme, yavaş sürüklenme ve süzgeçleme etkilerine de duyarlı olduğundan dikkatli yorumlanmalıdır. Yüksek-delta bileşenleri ise klasik delta aralığının daha kararlı ve EEG analizlerinde daha sık kullanılan bölümünü temsil eder. Biyometrik açıdan delta bandının alt parçalara ayrılması, geniş delta bandı içinde yer alan farklı yavaş zaman ölçeklerinin bireyler arası ayırt ediciliğe katkısını ayrı ayrı incelemeye olanak tanımaktadır.

Teta bandı, delta bandına kıyasla daha hızlı ancak hâlâ düşük frekanslı bir salınım aralığı temsil eder. Teta etkinliği, özellikle alınsal orta hat bölgeleri, ön kuşaksı beyin kabuğu ve hipokampusa ilişkin formasyonla ilişkili ağ dinamikleri bağlamında sıklıkla tartışılmaktadır. Alınsal teta etkinliğinin bilişsel kontrol, hata izleme, dikkat düzenleme ve çalışma belleği süreçleriyle ilişkili olduğu bildirilmiştir (Cavanagh ve Frank 2014). Hipokampusa ilişkin teta ise özellikle bellek kodlama, geri çağırma, bağlamsal işlemleme ve zamansal düzenleme düzenekleriyle ilişkilendirilmektedir (Buzsáki 2002). Kafa derisi EEG'sinde ölçülen teta etkinliği doğrudan tek bir yapıya bağlanamasa da, alınsal, içyan ve şakaksal ağların ortak dinamiklerini yansıtan önemli bir bileşen olarak değerlendirilebilir.

Teta bandının düşük-teta ve yüksek-teta şeklinde alt bölümlere ayrılması, bu bandın homojen olmayan yapısının daha ayrıntılı incelenmesini sağlar. Düşük-teta bileşenleri daha yavaş dikkat ve uyarılmışlık düzenleme süreçleriyle; yüksek-teta bileşenleri ise çalışma belleği, bilişsel kontrol ve görevle ilişkili işlemleme gibi daha seçici süreçlerle ilişkilendirilebilmektedir. EEG biyometrisi açısından bu ayrım önemlidir; çünkü aynı ana bant içinde yer alan farklı alt frekans aralıkları, bireyler arasında farklı düzeylerde kararlılık ve ayırt edicilik gösterebilir. Bu nedenle teta bandının tek bir geniş aralık olarak ele alınması yerine alt bantlar düzeyinde değerlendirilmesi, kişiye özgü spektral örüntülerin daha hassas biçimde yakalanmasına katkı sağlayabilir.

Alfa bandı, EEG literatüründe en yaygın incelenen frekans aralıklarından biridir. Gözler kapalı dinlenim hâlinde özellikle arka beyin kabuğuna ilişkin bölgelerde belirginleşmesi, alfa etkinliğini hem klinik EEG hem de bilişsel sinirbilim açısından temel bir gösterge hâline getirmiştir. Alfa etkinliği geleneksel olarak rahat uyanıklık durumu ile ilişkilendirilmiş olsa da, modern yorumlarda yalnızca pasif bir boşta çalışma ritmi olarak değerlendirilmemektedir. Alfa salınımlarının dikkat seçimi, duyusal bilginin baskılanması, beyin kabuğuna ilişkin inhibisyon ve ilgili/ilgisiz bilgi akışının düzenlenmesi gibi aktif süreçlerde rol oynadığı bildirilmektedir (Klimesch 1999, Klimesch 2012). Bu nedenle alfa bandı, özellikle dinlenim hâli EEG kayıtlarında bireye özgü sinir işlevbilimsel örüntülerin çıkarımı açısından kritik bir banttır.

Alfa bandının bireyler arası farklılık açısından önemli özelliklerinden biri, bireysel alfa frekansı kavramıdır. Her bireyde alfa etkinliğinin tepe frekansı aynı noktada ortaya çıkmayabilir; bu tepe frekansı yaş, bilişsel durum, uyanıklık düzeyi ve bireysel sinir işlevbilimsel organizasyonla ilişkili olarak değişebilir. Bu durum, alfa bandının sabit ve geniş bir aralık olarak kullanılmasının bazı bireysel farklılıkları maskeleyebileceğini göstermektedir. Bu nedenle alfa bandının alfa1, alfa2 ve alfa3 gibi alt bantlara ayrılması, arka ve duvarsal kaynaklı ritmik etkinliğinin daha ayrıntılı biçimde değerlendirilmesine imkân tanır. Biyometrik kimlik tanımlama açısından bu yaklaşım, bireyin baskın alfa organizasyonunu, bant içi güç dağılımını ve kanal-bölgesel dağılım ilişkisini daha duyarlı biçimde yakalamaya yardımcı olabilir.

Mu ritmi, frekans aralığı bakımından alfa bandıyla örtüşmesine rağmen anatomik ve işlevsel açıdan ayrı değerlendirilmesi gereken bir salınım bileşendir. Klasik arka alfa etkinliği daha çok artkafasal ve duvar-artkafa bölgelerde belirginleşirken, mu ritmi duyusal-devinimsel beyin kabuğu çevresinde, özellikle merkezi elektrot bölgelerinde gözlenir. Mu ritminin hareket yürütme, motor imgeleme veya eylem gözlemi sırasında baskılanması, onun duyusal-devinimsel ağlarla ilişkili olduğunu göstermektedir (Pfurtscheller ve Lopes da Silva 1999). Bu nedenle mu ritmini yalnızca alfa bandının bir parçası olarak ele almak, anatomik kaynak ve işlevsel yorum açısından eksik kalabilir. Bu tez kapsamında mu bandının ayrı bir aday bant olarak değerlendirilmesi, duyusal-devinimsel kaynaklı bireye özgü örüntülerin kimlik tanımlama başarımına katkısını ayrıca incelemeye olanak sağlamaktadır.

Beta bandı, genel olarak alfa aralığından daha hızlı salınımsal bileşenleri kapsar ve özellikle duyusal-devinimsel sistem, alınsal beyin kabuğu ve bilişsel kontrol ağlarıyla ilişkilidir. Beta etkinliği mo-

tor hazırlık, hareketin sürdürülmesi, hareket sonrası yeniden senkronizasyon, motor inhibisyon ve mevcut bilişsel ya da duyusal-devinimsel durumun korunması gibi süreçlerle bağlantılı olarak yorumlanmaktadır (Engel ve Fries 2010). Bu yönüyle beta bandı, yalnızca motor sistemin bir göstergesi değil, aynı zamanda beyin kabuğuna ilişkin ağların mevcut durumu koruma ve güncelleme dinamiklerini yansıtan bir frekans aralığı olarak değerlendirilebilir.

Beta bandı da kendi içinde homojen değildir. Düşük-beta, beta1, beta2, beta3 ve yüksek-beta gibi alt aralıklar, farklı anatomik ağlara ve işlevsel durumlara duyarlı olabilir. Düşük-beta ve beta1 bileşenleri duyusal-devinimsel ritimlerle daha yakın ilişki gösterebilirken, daha yüksek beta bileşenleri alınsal bilişsel kontrol, uyanıklık düzeyi, stres, dikkat ve görev yükü gibi durumlarla daha fazla ilişkili olabilir. EEG biyometrisi açısından beta bandının alt bölümlere ayrılması, geniş beta aralığı altında ortalanabilecek bireysel farklılıkların daha ayrıntılı biçimde yakalanmasını sağlar. Özellikle tek kanallı EEG temsillerinde, belirli bir kanalın belirli beta alt bandında yüksek ayırt edicilik göstermesi, geniş bant ortalamasında görünmeyebilecek bölgesel bir biyometrik imzaya işaret edebilir.

Gama bandı, EEG spektrumunun daha yüksek frekanslı bölümünü temsil eder ve genellikle yerel beyin kabuğuna ilişkin işlemleme, hızlı sinirsel senkronizasyon, algısal bütünleştirme, dikkat ve çalışma belleği gibi süreçlerle ilişkilendirilir (Buzsáki ve Draguhn 2004, Fries 2009). Gama etkinliğinin geniş bir frekans aralığını kapsaması, bu bandın tek bir fizyolojik süreçle açıklanmasını güçleştirmektedir. Düşük-gama, orta-gama, yüksek-gama ve daha dar gama alt bölütleri farklı yerel ağ dinamiklerine, farklı bilişsel süreçlere veya farklı ölçüm koşullarına duyarlı olabilir. Bu nedenle gama bandının tek bir geniş bant olarak ele alınması, bant içi heterojenliği artırabilir ve belirli alt frekanslarda ortaya çıkan ayırt edici bilginin zayıflamasına neden olabilir.

Kafa derisi EEG'sinde gama ve özellikle yüksek-gama bileşenlerinin yorumlanması özel dikkat gerektirir. Yüksek frekanslı EEG bileşenleri, sinirsel kaynaklı olabileceği gibi yüz, çene, boyun ve kafa kaslarına ait EMG bozulmalarından da etkilenebilir. Bu nedenle gama aralığındaki biyometrik bulgular yorumlanırken kayıt kalitesi, süzgeçleme, bozulma giderme, elektrot konumu ve deney protokolü birlikte değerlendirilmelidir (Whitham vd. 2007, Muthukumaraswamy 2013). Bununla birlikte uygun örnekleme, ön işleme ve bozulma kontrolü sağlandığında, gama alt bantları bireyler arası ayırt edici bilgi taşıyabilir. Özellikle yüksek frekanslı bileşenlerin daha yerel beyin kabuğuna ilişkin işlemleme süreçleriyle ilişkili olması, gama bandını EEG tabanlı biyometrik kimlik tanım-

lama açısından önemli bir aday frekans alanı hâline getirmektedir.

Geniş bant yaklaşımının temel sınırlılığı, aynı bant içinde yer alan farklı salınımsal bileşenlerin tek bir ortalama ölçüt altında birleştirilmesidir. Örneğin geniş alfa bandında hesaplanan toplam güç, düşük alfa ve yüksek alfa bileşenlerinin farklı işlevsel rollerini ayırt edemeyebilir. Benzer biçimde geniş gama bandı, düşük-gama ile yüksek-gama arasındaki potansiyel kaynak ve bozulma farklılıklarını maskeleyebilir. Bu durum, özellikle biyometrik kimlik tanımlama gibi bireyler arası ince ayrımların hedeflendiği uygulamalarda önemlidir. Çünkü modelin ayırt edici bilgiye ulaşabilmesi, çoğu zaman belirli kanal–bant kombinasyonlarındaki küçük fakat kararlı farklılıkların korunmasına bağlıdır. Alt bant yaklaşımı, bu nedenle EEG işaretinin spektral yapısını daha yüksek çözünürlükle temsil ederek geniş bant ortalamasının maskeleyebileceği bireysel örüntüleri görünür hâle getirebilir (Newson ve Thiagarajan 2019, Babiloni vd. 2020).

EEG tabanlı biyometrik sistemlerde frekans bantlarının kullanımı, yalnızca fizyolojik yorum amacıyla değil, aynı zamanda modelin öğrenebileceği aday temsil uzayını tanımlamak amacıyla da önemlidir. Dinlenim hâli EEG'sinde bireyler arasında spektral güç dağılımları, baskın frekanslar, kanal-bölgesel dağılım ilişkileri ve bantlar arası göreli farklılıklar gözlenebilir. Bu farklılıkların bir kısmı oturumlar arasında kararlılık gösterebilirken, bir kısmı yorgunluk, dikkat, duygu durumu, elektrot empedansı ve kayıt koşulları gibi etkenlere bağlı olarak değişkenlik gösterebilir. Bu nedenle EEG biyometrisinde frekans bantları yalnızca sınıflandırma doğruluğunu artırmak için kullanılan teknik süzgeç aralıkları olarak değil, aynı zamanda bireye özgü ve oturumlar arasında korunabilen sinir işlevbilimsel temsillerin araştırıldığı deneysel bir alan olarak ele alınmalıdır (Bidgoly vd. 2020, Zhang vd. 2021, Lin vd. 2024).

Bu tez kapsamında frekans bantları, önceden tek bir en uygun bant varsayımıyla sınırlandırılmamış; bunun yerine klasik ana bantlar, alt bantlar, mu ritmi ve genişletilmiş gama bölütlerini içeren kapsamlı bir aday bant kümesi oluşturulmuştur. Böylece modelin yalnızca delta, teta, alfa, beta veya gama gibi geniş bantlara verdiği yanıt değil, aynı zamanda bu bantların daha dar frekans alt bölümlerinde taşıdığı ayırt edici bilgi de deneysel olarak değerlendirilebilmiştir. Bu yaklaşım, EEG tabanlı kimlik tanımlama probleminde hangi frekans aralıklarının daha yüksek ayırt edicilik, kararlılık ve oturumlar arası genellenebilirlik sağladığını sistematik biçimde incelemeye olanak tanımaktadır.

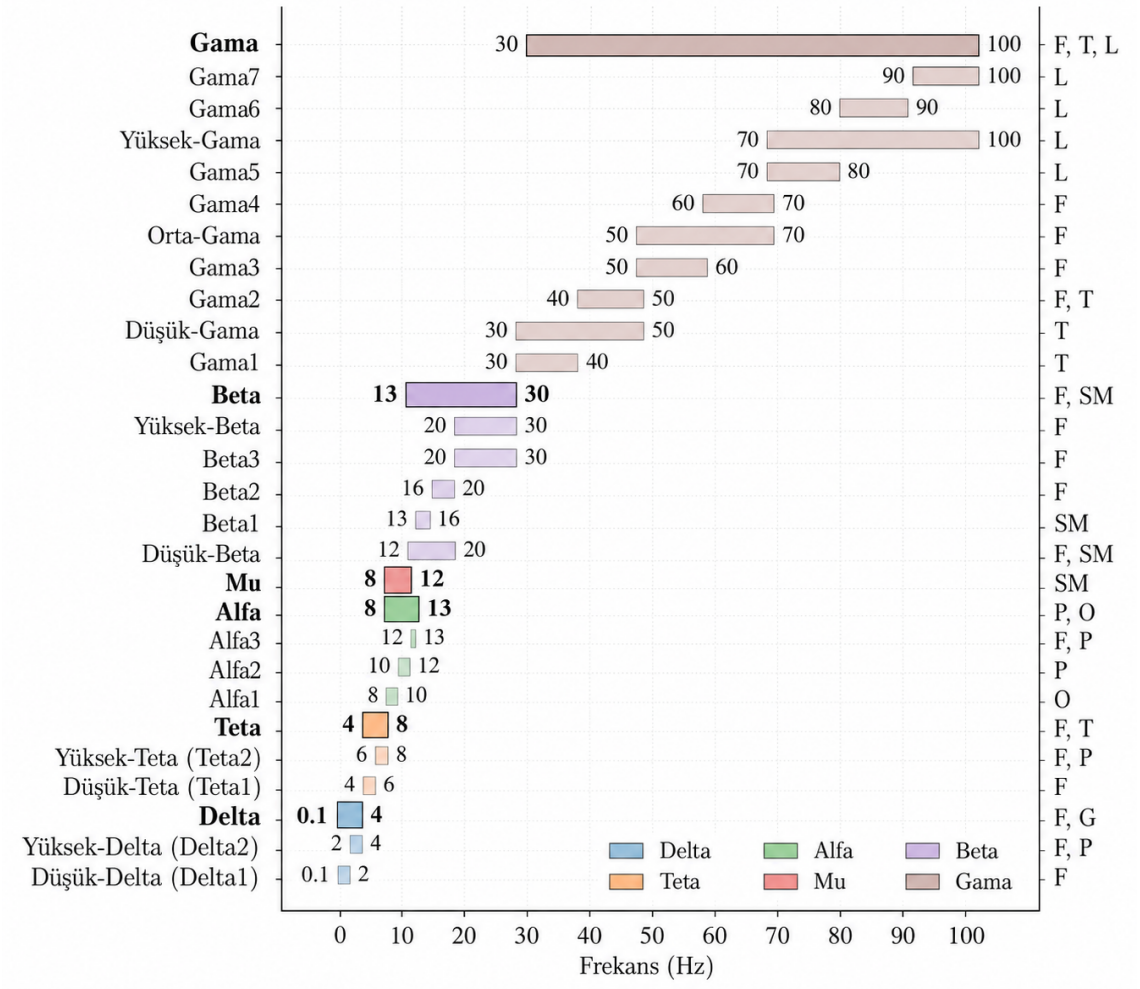

Şekil 2.5 Tez kapsamında değerlendirilen EEG ana frekans bantları ve alt bantları

Bu noktada vurgulanması gereken önemli bir husus, Şekil 2.5'te sunulan bantların fizyolojik olarak birbirinden tamamen bağımsız ya da kesin sınırlarla ayrılmış yapılar olarak yorumlanmaması gerektiğidir. Bant sınırları, tez kapsamında karşılaştırmalı deneylerin yürütülebilmesi için tanımlanmış analiz aralıklarıdır. Gerçek sinirsel osilasyonlar bu sınırların içinde ya da çevresinde bireyden bireye değişebilir; ayrıca farklı frekans bileşenleri arasında etkileşimler, çapraz frekans ilişkileri ve ortak ağ dinamikleri bulunabilir. Buna karşın sabit bant aralıklarının kullanılması, tüm katılımcılar, kanallar ve oturumlar için standart bir değerlendirme çerçevesi sağlamaktadır. Bu da model başarılarının, kanal–bant katkılarının ve oturumlar arası başarım farklarının karşılaştırılabilir biçimde raporlanmasına imkân verir.

Şekil 2.5'te bu tez kapsamında kullanılan ana frekans bantları ve alt bantlar özetlenmektedir. Yatay çubuklar her bir bant ya da alt bandın başlangıç ve bitiş frekanslarını göstermekte; ana bantlar daha belirgin biçimde, alt bantlar ise ana bant ile aynı rengin daha açık tonlarıyla sunulmakta-

dır. Sağ eksende verilen bölge kodları, ilgili bantların literatürde sıklıkla ilişkilendirildiği baskın anatomik/bölgesel dağılım alanları göstermektedir. Burada F alınsal, P duvarsal, O artkafasal, T şakaksal, SM duyusal-devinimsel, G yaygın ve L lokal beyin kabuğuna ilişkin dağılımı ifade etmektedir. Bu görsel, tezde kullanılan frekans aralıklarının yalnızca klasik EEG bantlarını değil, biyometrik ayırt ediciliği daha ayrıntılı incelemek amacıyla tanımlanan dar alt bantları da içerdiğini göstermektedir.

2.4 EEG Tabanlı Kimlik Tanımlama Çalışmaları

EEG tabanlı biyometrik kimlik tanımlama çalışmaları, insan beyninden elde edilen elektriksel etkinliğinin bireyler arasında ayırt edici ve belirli ölçüde tekrarlanabilir özellikler taşıdığı varsayımına dayanmaktadır. Bu alandaki temel araştırma sorusu, bir EEG örneğinin hangi kayıtlı kullanıcıya ait olduğunun güvenilir biçimde belirlenip belirlenemeyeceğidir. Geleneksel biyometrik yaklaşımlar parmak izi, yüz, iris veya ses gibi dışarıdan gözlemlenebilir özellikleri kullanırken, EEG doğrudan merkezi sinir sistemi kaynaklı bir işaret olması nedeniyle farklı bir biyometrik kategori oluşturmaktadır. EEG'nin fizyolojik canlılıkla ilişkili olması, dışarıdan kolayca kopyalanamaması ve bireye özgü sinir işlevbilimsel örüntüler içermesi, bu işareti yüksek güvenlik gerektiren kimlik tanımlama uygulamaları için dikkat çekici hâle getirmiştir (Campisi ve La Rocca 2014, Bidgoly vd. 2020, Zhang vd. 2021). Buna karşın EEG'nin düşük İGO, durağan olmayan yapısı, oturumlar arası değişkenliği ve kayıt koşullarına duyarlılığı, bu alandaki temel zorlukları oluşturmaktadır.

EEG tabanlı biyometrik çalışmaların ilk döneminde araştırmalar çoğunlukla yöntemin uygulanabilirliğini göstermeye odaklanmıştır. Poulos vd. (1999), EEG işaretlerinden çıkarılan parametrik özellikler ve yapay sinir ağlarıyla birey tanıma yapılabileceğini gösteren erken çalışmalardan birini sunmuştur. Paranjape vd. (2001) EEG'nin biyometrik bir özellik olarak kullanılabileceğini tartışmış; Palaniappan ve Mandic (2007) ise beyin elektriksel etkinliğinin kişi tanıma amacıyla makine öğrenmesi çerçevesinde değerlendirilebileceğini göstermiştir. Bu erken çalışmalar, EEG işaretlerinin yalnızca klinik tanı veya beyin-bilgisayar arayüzü uygulamaları için değil, aynı zamanda kişiye özgü örüntülerin çıkarılması açısından da potansiyel taşıdığını ortaya koymuştur. Ancak bu dönemde kullanılan veri kümeleri genellikle sınırlı sayıda katılımcıdan oluşmakta, kayıt protokolleri çoğunlukla aynı oturum veya kısa süreli tekrarlar üzerinden değerlendirilmekte ve başarım ölçütleri gerçekçi biyometrik kullanım senaryolarını tam olarak yansıtmamaktaydı.

Klasik EEG biyometrisi çalışmalarında öznitelik çıkarımı genellikle zaman alanı, frekans alanı, zaman-frekans alanı ve bağlantısallık temelli ölçütler üzerinden gerçekleştirilmiştir. Zaman alanında ortalama, varyans, sıfır geçiş sayısı, Hjorth değişkenleri ve doğrusal olmayan karmaşıklık ölçütleri gibi göstergeler kullanılmıştır. Frekans alanında ise Güç Spektral Yoğunluğu (GSY, Power Spectral Density: PSD), göreli bant gücü, bireysel alfa frekansı, spektral entropi ve bantlar arası oranlar öne çıkmıştır. Zaman-frekans temelli yaklaşımlarda kısa zamanlı Fourier dönüşümü, dalgacık dönüşümü ve dalgacık paket ayrıştırması gibi yöntemlerle EEG işaretinin hem zamansal hem de spektral yapısı birlikte ele alınmıştır (DelPozo-Banos vd. 2015, Thomas ve Vinod 2016, Suppiah ve Vinod 2018). Bu çalışmalar, EEG işaretinin yalnızca ham zaman serisi olarak değil, farklı frekans bantlarında ortaya çıkan bireye özgü ritmik organizasyonlar üzerinden de ayırt edici bilgi taşıyabileceğini göstermiştir.

Spektral özelliklere dayalı çalışmalar, EEG biyometrisinin gelişiminde önemli bir yer tutmaktadır. DelPozo-Banos vd. (2015), EEG biyometrik tanımlama problemini zaman-frekans alanında kapsamlı biçimde inceleyerek farklı frekans bileşenlerinin kimlik ayırt ediciliğe katkı sağlayabileceğini ortaya koymuştur. Thomas ve Vinod (2016), bireysel alfa frekansı ile delta bandı gücünün birlikte kullanılmasının biyometrik tanıma açısından yararlı olabileceğini göstermiştir. Suppiah ve Vinod (2018) ise rahat dinlenim hâlinde tek kanallı EEG kullanarak kimlik tanımlama yapılabileceğini göstermiş ve pratik sistemler için kanal sayısının azaltılmasının önemini vurgulamıştır. Bu çizgi, EEG biyometrisinde çok kanallı ve karmaşık sistemlerin yanı sıra daha düşük maliyetli, daha kısa hazırlık süresi gerektiren ve kullanıcı açısından daha uygulanabilir tek/az kanallı sistemlerin de araştırılması gerektiğini göstermektedir.

EEG işaretlerinin yalnızca tekil kanal özellikleriyle değil, kanallar arası ilişkilerle de bireye özgü bilgi taşıyabileceği düşüncesi, işlevsel bağlantısallık temelli yaklaşımların gelişmesine yol açmıştır. La Rocca vd. (2014), spektral koherens temelli bağlantısallık ölçütlerinin insan beynine özgü ayırt edici örüntüler içerdiğini göstermiştir. Fraschini vd. (2015), dinlenim hâli EEG ağlarında özvektör merkeziliği gibi graf kuramı ölçütlerinin biyometrik tanımlama için kullanılabileceğini sunmuştur. Wang vd. (2020) ise EEG tabanlı beyin bağlantısallık graf yapılarından hareketle *BrainPrint* yaklaşımını önermiştir. Bu tür çalışmalar, EEG biyometrisinin yalnızca kanal düzeyinde lokal güç değişimlerine değil, beyin bölgeleri arasındaki işlevsel etkileşim örüntülerine de dayanabileceğini göstermektedir. Bununla birlikte bağlantısallık temelli yöntemler genellikle çok kanallı kayıt gerektirmekte, hesaplama karmaşıklığını artırmakta ve hacim iletimi, referans seçimi ve sahte

bağlantısallık gibi metodolojik sorunlara karşı dikkatli yorum gerektirmektedir.

Uyaran-temelli EEG biyometrisi, literatürdeki ikinci önemli araştırma hattını oluşturmaktadır. Bu yaklaşımda bireyin belirli görsel, işitsel, bilişsel veya motor uyaranlara verdiği sinirsel yanıtlar kimlik tanımlama amacıyla kullanılır. Görsel uyarılmış potansiyeller ve olayla ilişkili potansiyeller, bireylerin aynı uyarana verdikleri sinir işlevbilimsel yanıtların farklılaşabileceği varsayımıyla değerlendirilmiştir. Palaniappan ve Raveendran (2002), görsel uyarılmış potansiyellerin birey tanımada kullanılabileceğini gösteren erken çalışmalardan birini sunmuştur. Ruiz-Blondet vd. (2016), CEREBRE olarak adlandırdıkları yaklaşımıyla olayla ilişkili potansiyeller üzerinden yüksek doğruluklu kimlik tanımlama yapılabileceğini göstermiştir. Das vd. (2016), görsel uyaranlara dayalı EEG biyometrisinin uzunlamasına değerlendirilmesi gerektiğini vurgulayarak, uyaran-temelli EEG örüntülerinin zaman içindeki kararlılığını incelemiştir. Jijomon ve Vinod (2021), tanıdık isimlere dayalı işitsel uyarılmış potansiyelleri kullanarak az sayıda alınsal elektrotla kişi tanımlama yapılabileceğini göstermiştir.

Uyaran-temelli yaklaşımlar, kontrollü koşullarda yüksek ayırt edicilik sağlayabilmeleri nedeniyle güçlü bir araştırma alanı oluşturmakla birlikte, gerçek kullanım senaryoları açısından bazı sınırlılıklar taşımaktadır. Bu sistemlerde kullanıcıya belirli uyaranların sunulması, kayıt süresinin ve protokol karmaşıklığının artmasına neden olabilir. Ayrıca uyaranlara verilen yanıtlar dikkat, motivasyon, yorgunluk, öğrenme etkisi ve uyarana aşinalık gibi değişkenlerden etkilenebilir. Bu nedenle uyaran-temelli EEG biyometrisi, yüksek güvenlikli ve kontrollü ortamlarda güçlü bir aday yaklaşım olmakla birlikte, sürekli veya düşük etkileşimli kimlik tanımlama senaryolarında dinlenim hâli EEG'ye kıyasla daha fazla kullanıcı katılımı gerektirebilir.

Dinlenim hâli EEG'ye dayalı kimlik tanımlama çalışmaları ise kullanıcının aktif bir görev yapmasını gerektirmemesi nedeniyle pratik biyometrik sistemler açısından özel bir öneme sahiptir. Gözler açık veya gözler kapalı dinlenim kayıtları, bireyin doğal/kendiliğinden beyin kabuğuna ilişkin etkinliğindeki ritmik ve bölgesel dağılım örüntülerin analiz edilmesine olanak tanır. Dinlenim hâli EEG'nin biyometrik kullanımında arka alfa organizasyonu, alınsal-duvarsal güç dağılımları, bireysel frekans özellikleri ve bağlantısallık örüntüleri önemli aday özellikler olarak değerlendirilmiştir (La Rocca vd. 2014, Fraschini vd. 2015, Suppiah ve Vinod 2018, Lin vd. 2024). Lin vd. (2024), taşınabilir EEG cihazı kullanarak insan beyin izi tanımada salınımsal düzeneklerin rolünü incelemiş ve düşük donanım gereksinimli EEG biyometrisinin potansiyelini göstermiştir. Bu tür çalışmalar,

EEG biyometrisinin laboratuvar tipi çok kanallı sistemlerden taşınabilir ve daha uygulanabilir sistemlere doğru evrildiğini göstermektedir.

EEG biyometrisinde uzunlamasına kararlılık ve oturumlar arası genellenebilirlik, literatürde en kritik araştırma problemlerinden biridir. Aynı oturum içinde eğitim ve test bölmelerinin ayrılmasıyla elde edilen yüksek doğruluk değerleri, modelin gerçek biyometrik uygulanabilirliğini tek başına göstermez. Çünkü aynı kayıt oturumundan alınan pencereler; elektrot yerleşimi, empedans koşulları, kayıt ortamı, bireyin fizyolojik durumu ve cihaz kaynaklı özellikler açısından birbirine oldukça benzerdir. Bu nedenle aynı oturum içi başarı, modelin kişiye özgü kararlı sinirsel örüntüleri öğrendiğini değil, aynı oturuma özgü geçici işaret özelliklerini de öğrenmiş olabileceğini gösterebilir. Maiorana vd. (2016), EEG işaretlerinin biyometrik tanımadaki kalıcılığını inceleyerek zaman içinde başarım kaybı olabileceğini göstermiştir. Das vd. (2016), görsel uyaran temelli EEG biyometrisini uzunlamasına değerlendirmiştir. Maiorana ve Campisi (2018), birden fazla oturum ve uzun zaman aralığı içeren değerlendirmelerle EEG biyometrisinin uzunlamasına kullanılabilirliğini tartışmıştır. Bu çalışmalar, EEG tabanlı kimlik tanımlamada oturumlar arası protokollerin zorunlu bir değerlendirme basamağı olduğunu açık biçimde göstermektedir.

Oturumlar arası değişkenliği azaltmak için literatürde farklı yöntemler önerilmiştir. Bir grup çalışma, daha kararlı özniteliklerin seçilmesine odaklanırken; diğerleri derin öğrenme ile oturumdan bağımsız temsil öğrenmeye yönelmiştir. Özdenizci vd. (2019), EEG biyometrisinde çekişmeli öğrenme yaklaşımı kullanarak oturuma özgü değişkenlikten arındırılmış ve kişiye özgü bilgiyi koruyan temsiller öğrenmeyi hedeflemiştir. Plucińska vd. (2023), birden fazla kayıt oturumunun eğitimde kullanılmasının spektral tabanlı biyometrik doğrulama sonuçlarını iyileştirebileceğini göstermiştir. Rahman vd. (2022), EEG ve tuş vuruşu dinamiklerini birlikte kullanan oturumdan bağımsız multimodal bir yaklaşım önermiştir. Usman vd. (2026) ise EEG biyometrisinde ön işleme yoğunluğu ile sinirsel imza korunumu arasındaki dengeye dikkat çekmiş; aşırı katı bozulma temizleme işlemlerinin biyometrik açıdan anlamlı işaret bileşenlerini zayıflatabileceğini tartışmıştır. Bu çizgi, EEG biyometrisinin yalnızca sınıflandırıcı tasarımı değil, veri kalitesi, ön işleme yöntemi, temsil öğrenme yöntemi ve değerlendirme protokolünün birlikte ele alınması gereken bütüncül bir problem olduğunu göstermektedir.

Derin öğrenme yaklaşımları, EEG tabanlı kimlik tanımlama çalışmalarında son yıllarda baskın hâle gelmiştir. Klasik makine öğrenmesi yöntemlerinde özniteliklerin araştırmacı tarafından ön-

ceden tanımlanması gerekirken, derin öğrenme modelleri ham veya az işlenmiş EEG verisinden ayırt edici temsilleri doğrudan öğrenebilme potansiyeline sahiptir. Mao vd. (2017), EEG tabanlı biyometrik tanımlamada derin öğrenme kullanımını erken dönemde ele alan çalışmalardan biridir. Sun vd. (2019), bir boyutlu (1B) ESA ve uzun kısa süreli bellek bileşenlerini birleştirerek EEG tabanlı kullanıcı tanımlama sistemi önermiştir. Wang vd. (2019), farklı insan durumlarında dinamik işlevsel bağlantısallık temsillerini ESA'larıyla birleştirmiştir. Wilaiprasitporn vd. (2020), duygusal EEG verileri üzerinden kişi tanımlama probleminde derin öğrenme yaklaşımının kullanılabileceğini göstermiştir. Maiorana (2020), derin öğrenmenin EEG tabanlı biyometrik tanıma için taşıdığı potansiyeli ve uzunlamasına kullanılabilirliğe ilişkin sınırlılıkları değerlendirmiştir.

ESA tabanlı modeller, EEG işaretindeki lokal zaman örüntülerini, kısa süreli yapı biçimi değişimleri ve kanal/bölgesel dağılım ilişkilerini öğrenebilmesi nedeniyle yaygın olarak kullanılmıştır. Tekrarlayan/Yinelemeli Sinir Ağı (TSA, Recurrent Neural Network: RNN), UKSB ve Kapılı Yinelemeli Birim (KYB, Gated Recurrent Unit: GRU) tabanlı modeller ise EEG pencereleri içindeki sıralı zamansal bağımlılıkları temsil etmek için tercih edilmiştir. ESA-UKSB gibi karma mimariler, evrişimsel katmanların lokal örüntü çıkarma kapasitesi ile tekrarlayan katmanların zamansal bağlam modelleme kapasitesini birleştirmiştir (Sun vd. 2019). Son dönemde Dönüştürücü tabanlı yaklaşımlar, uzun menzilli bağımlılıkları ve zaman-kanal etkileşimlerini modelleyebilme kapasiteleri nedeniyle EEG biyometrisinde de kullanılmaya başlamıştır. Du vd. (2022), şakaksal-uzamsal Dönüştürücü mimarisiyle EEG tabanlı kişi tanımlamada derin dikkat düzeneklerinin kullanılabileceğini göstermiştir. Jin vd. (2024), duygusal EEG'ye dayalı kişi tanımlamada sürekli öğrenme yaklaşımı ve çok alanlı dikkat düzenekleri içeren Dönüştürücü tabanlı bir yapı önermiştir. Pan vd. (2026), otomatik elektrot seçimi, kişi tanımlama ve niyet tanıma bileşenlerini bir araya getiren bütünleşik bir derin öğrenme çerçevesi sunmuştur. Tu vd. (2026) ise *BrainprintNet* ile çok ölçekli zaman evrişimleri, ince bant süzgeçleri ve bantlar arası uzamsal füzyonu birleştirerek EEG tabanlı beyin izi tanıma probleminde çapraz oturum ve çapraz görev genellenebilirliğini artırmayı hedeflemiştir.

Derin öğrenme tabanlı çalışmalar yüksek doğruluk değerleri bildirmekle birlikte, bu başarıların değerlendirme protokolüne güçlü biçimde bağlı olduğu unutulmamalıdır. Özellikle aynı oturumdan rastgele pencere ayrımıyla yapılan eğitim-test bölmeleri, veri sızıntısı riskini artırabilir ve gerçek oturumlar arası başarımı olduğundan yüksek gösterebilir. Ayrıca derin modellerin çok sayıda değişken içermesi, sınırlı sayıda katılımcı ve sınırlı oturum verisiyle eğitildiğinde aşırı öğrenme ris-

kini artırmaktadır. Alsumari vd. (2023), bu sorunu azaltmak amacıyla daha hafif bir ESA mimarisi önermiş ve yalnızca iki kanal ile kısa zaman pencereleri kullanarak hem kimlik tanımlama hem de doğrulama başarımını incelemiştir. Benomar vd. (2022), ResNet, Inception ve EEGNet gibi güncel derin öğrenme mimarilerini BED veri kümesi üzerinde değerlendirerek gerçek zamanlı ve gömülü sistemlere yönelik uygulanabilirliği tartışmıştır. Das vd. (2024), otomatik kodlayıcı ve ESA bileşenlerini birlikte kullanarak çok görevli EEG biyometrik kişi tanımlama yaklaşımı önermiştir. Bu çalışmalar, derin öğrenmede yalnızca doğruluğun değil, model karmaşıklığı, kanal sayısı, pencere uzunluğu, hesaplama yükü ve gerçek zamanlı çalışabilirlik gibi ölçütlerin de dikkate alınması gerektiğini göstermektedir.

Son yıllarda EEG biyometrisi literatüründe üç eğilim özellikle belirginleşmiştir. Birincisi, daha az kanal veya tek kanal kullanarak pratik sistemler geliştirme eğilimidir. Çok kanallı EEG sistemleri yüksek bilgi içeriği sağlasa da, elektrot hazırlık süresi, kullanıcı konforu, maliyet ve gerçek uygulama zorluğu açısından sınırlılıklar taşır. Suppiah ve Vinod (2018), tek kanallı dinlenim hâli EEG'nin biyometrik kimlik tanımlamada kullanılabileceğini göstermiştir. Alyasseri vd. (2020), kanal seçimi problemini karma çiçek tozlaşma algoritması ile ele almıştır. Pan vd. (2026) ise otomatik elektrot seçimini derin öğrenme çerçevesine entegre ederek yalnızca sınırlı sayıda elektrotla yüksek kimlik tanımlama başarısı raporlamıştır.

Bir diğer eğilim, EEG biyometrisinin yalnızca sabit dinlenim koşullarında değil, farklı görev, duygu, bilişsel yük ve çevresel koşullarda da değerlendirilmesidir. Arnau-González vd. (2021), duygulanım durumlarının EEG tabanlı kişi tanımlama üzerindeki etkisini incelemiştir. Wilaiprasitporn vd. (2020), duygusal EEG verileriyle kişi tanımlama yapılabileceğini göstermiştir. Kralikova vd. (2022), artan bilişsel yük altında EEG tabanlı kişi tanımlamayı değerlendirmiştir. Rakshe vd. (2025), duygusal uyarımlı biyometrik doğrulamada EEG kanal kullanımını eniyilemeye etmeye odaklanmıştır. Jamal ve Sabir (2026), farklı duygusal durumlar altında EEG tabanlı biyometrik tanımlamayı derin öğrenme yaklaşımlarıyla incelemiştir. Bu araştırma hattı, EEG biyometrisinin gerçek hayatta sabit ve ideal bir zihinsel durumda çalışmayacağını; duygu, yorgunluk, dikkat, stres ve görev durumu gibi değişkenlerin sistem başarımı üzerinde belirleyici olabileceğini göstermektedir.

EEG biyometrisinde veri kümesi, protokol ve kıyaslama standartlarının geliştirilmesidir. EEG biyometrisi alanında uzun süre sınırlı katılımcılı, tek oturumlu veya kapalı veri kümeleri kullanıl-

mıştır. Ancak son dönemde daha büyük, çok görevli ve çok oturumlu veri kümeleri üzerinden daha gerçekçi değerlendirmeler yapılmaya başlanmıştır. Huang vd. (2022), M3CV veri kümesi ve biyometrik yarışma çerçevesiyle çok katılımcılı, çok oturumlu ve çok görevli EEG biyometrisi için önemli bir kıyaslama ortamı sunmuştur. Mishra vd. (2024), EEG ve el yazısı imza yöntemlerini birleştiren SignEEG v1.0 veri kümesini tanıtmıştır. Suri vd. (2026), BMTEEG veri kümesiyle yeni protokollerin EEG tabanlı biyometrik doğrulama sistemleri üzerindeki etkilerini değerlendirmeyi amaçlayan bir veri kaynağı sunmuştur. Bu tür veri kümeleri, EEG biyometrisinde yalnızca model mimarisinin değil, kayıt protokolü, oturum tasarımı, kullanıcı durumu, cihaz türü ve saldırı/yanıltma senaryolarının da sistematik biçimde incelenmesine olanak sağlamaktadır.

Güncel literatür, EEG tabanlı biyometrik kimlik tanımlamanın artık yalnızca "EEG ile kişi tanınabilir mi?" sorusunu aşarak daha karmaşık araştırma sorularına yöneldiğini göstermektedir. Bu sorular arasında hangi frekans bantlarının daha kararlı olduğu, hangi elektrot bölgelerinin daha yüksek ayırt edicilik sağladığı, tek kanalın hangi koşullarda yeterli olabileceği, modelin farklı oturumlara ne ölçüde genellenebildiği, duygu ve bilişsel durum değişimlerinin kimlik örüntülerini nasıl etkilediği, kullanıcı sayısı arttıkça başarımın nasıl değiştiği ve derin öğrenme modellerinin hangi temsil düzeylerinde bireye özgü bilgi öğrendiği yer almaktadır. Bu nedenle EEG biyometrisi, işaret işleme, sinir işlevbilim, makine öğrenmesi, derin öğrenme, güvenlik ve kullanılabilirlik boyutlarını birlikte içeren çok katmanlı bir araştırma alanı hâline gelmiştir. Çizelge 2.3, EEG tabanlı kimlik tanımlama literatüründe öne çıkan başlıca araştırma hatlarını, kullanılan temsil/yöntem türlerini ve bu hatların tezin işleniş açısından önemini özetlemektedir.

Literatürdeki bu gelişim çizgisi, EEG tabanlı kimlik tanımlamanın üç ana eksende ilerlediğini göstermektedir. Birinci eksen, EEG işaretinden çıkarılan özniteliklerin daha ayırt edici hâle getirilmesidir. Bu kapsamda frekans bantları, zaman-frekans temsilleri, bağlantısallık ölçütleri ve derin temsil öğrenme yöntemleri kullanılmıştır. İkinci eksen, sistemlerin daha pratik ve uygulanabilir hâle getirilmesidir. Bu kapsamda kanal sayısının azaltılması, kısa zaman pencereleriyle çalışılması, taşınabilir cihazlar ve düşük hesaplama maliyetli modeller ön plana çıkmıştır. Üçüncü eksen ise gerçekçi genellenebilirlik değerlendirmesidir. Bu kapsamda farklı oturumlar, farklı günler, farklı görevler, farklı duygu durumları ve farklı kayıt koşulları altında başarımın korunup korunmadığı araştırılmıştır. Şekil 2.6, EEG biyometrisi literatüründe kullanılan yöntemlerin zaman içindeki gelişimini özetlemektedir. Erken dönem çalışmalarda elle çıkarılan öznitelikler ve klasik makine öğrenmesi yöntemleri öne çıkarken, sonraki yıllarda GSY, bant gücü ve zaman-frekans

Çizelge 2.3 EEG tabanlı biyometrik kimlik tanımlama literatüründe öne çıkan araştırma hatları

Araştırma hattı	**Temel yaklaşım**	**Örnek çalışmalar**	**Tez açısından çıkarım**
Erken dönem klasik makine öğrenmesi	Parametrik özellikler, spektral ölçütler, yapay sinir ağları, DVM, k-EYK	Poulos vd. (1999), Paranjape vd. (2001), Palaniappan ve Mandic (2007)	EEG'nin biyometrik potansiyelini göstermiştir; ancak küçük veri kümesi ve sınırlı oturum değerlendirmesi önemli sınırlılıktır.
Spektral ve zaman-frekans temelli yöntemler	Bant gücü, GSY, dalgacık dönüşümü, bireysel alfa frekansı, zaman-frekans özellikleri	DelPozo-Banos vd. (2015), Thomas ve Vinod (2016), Suppiah ve Vinod (2018)	Kanal–bant düzeyi ayırt ediciliğin incelenmesi için güçlü gerekçe sunmaktadır.
İşlevsel bağlantısallık ve graf temelli yaklaşımlar	Koherens, faz ilişkisi, ağ merkeziliği, bağlantısallık grafı	La Rocca vd. (2014), Fraschini vd. (2015), Wang vd. (2020), Tian vd. (2023)	EEG'de bireye özgü bilginin yalnızca lokal güçten değil, bölgeler arası ilişkilerden de gelebileceğini göstermektedir.
Uyaran-temelli beyin izi yaklaşımları	GUP, OİP, İUP, görsel/işitsel uyaranlara verilen bireysel yanıtlar	Ruiz-Blondet vd. (2016), Das vd. (2016), Jijomon ve Vinod (2021)	Kontrollü koşullarda yüksek ayırt edicilik sağlar; ancak kullanıcı etkileşimi ve protokol karmaşıklığı artar.
Derin öğrenme tabanlı yaklaşımlar	ESA, ESA-UKSB, TSA, Dönüştürücü, dikkat düzenekleri, otomatik temsil öğrenme	Sun vd. (2019), Wang vd. (2019), Alsumari vd. (2023), Jin vd. (2024), Pan vd. (2026), Tu vd. (2026)	Ham veya az işlenmiş EEG'den ayırt edici temsil öğrenme olanağı sağlar; ancak protokol tasarımı ve aşırı öğrenme riski kritik önemdedir.
Oturumlar arası ve uzunlamasına değerlendirme	Farklı gün/oturum kayıtları, oturumdan bağımsız özellikler, çekişmeli temsil öğrenme	Maiorana vd. (2016), Maiorana ve Campisi (2018), Özdenizci vd. (2019), Plucińska vd. (2023), Usman vd. (2026)	Gerçekçi biyometrik başarım için aynı oturum içi test yeterli değildir; çapraz oturum değerlendirme zorunludur.
Kanal azaltma ve pratik sistemler	Tek/az kanal, otomatik kanal seçimi, taşınabilir EEG, hesaplama verimliliği	Suppiah ve Vinod (2018), Alyasseri vd. (2020), Pan vd. (2026)	Tek kanallı ve düşük maliyetli EEG biyometrisinin uygulanabilirliğini değerlendirmek için doğrudan motivasyon sağlar.
Duygu, görev ve kullanım koşulu etkileri	Farklı duygu durumları, bilişsel yük, yorgunluk, çevresel değişkenler	Arnau-González vd. (2021), Kralikova vd. (2022), Rakshe vd. (2025), Jamal ve Sabir (2026)	EEG biyometrisinin durağan olmayan doğasını ve zihinsel durum değişkenliğinin önemini ortaya koymaktadır.

temsilleri gibi spektral yaklaşımlar yaygınlaşmıştır. Daha sonra EEG kanalları arasındaki ilişkileri modelleyen bağlantısallık ve graf tabanlı yöntemler literatürde önem kazanmış; derin öğrenme döneminde ise ESA, TSA ve karma mimariler EEG işaretlerinden otomatik temsil öğrenmek için kullanılmaya başlanmıştır. Güncel çalışmalar ise Dönüştürücü tabanlı dikkat düzenekleri, otomatik elektrot/kanal seçimi ve oturumlar arası genellenebilirlik gibi daha gerçekçi değerlendirme sorunlarına odaklanmaktadır. Bu gelişim çizgisi, EEG biyometrisinde öznitelik mühendisliğinden uçtan uca temsil öğrenmeye ve daha güvenilir çapraz oturum değerlendirmelerine doğru belirgin bir yönelim olduğunu göstermektedir.

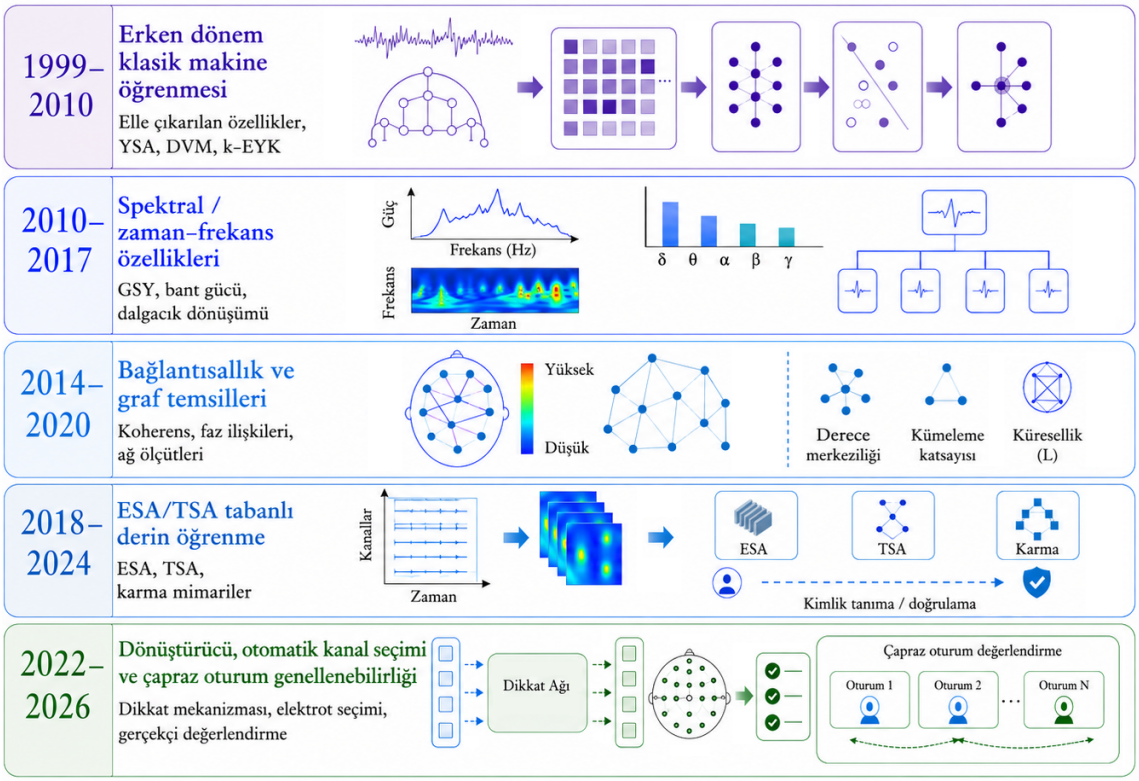

Şekil 2.6 EEG tabanlı biyometrik kimlik tanımlama literatürünün yöntemsel gelişim çizgisi

2.5 Literatürdeki Boşluklar ve Çalışmanın Konumlandırılması

EEG tabanlı biyometrik kimlik tanımlama literatürü, yöntemin uygulanabilirliğini gösteren çok sayıda çalışma içermesine rağmen, alanın gerçek uygulamalara aktarılabilmesi açısından hâlen çözülmesi gereken boşluklar bulunmaktadır. Bu boşluklar yalnızca model doğruluğu ile sınırlı değildir; veri kümesi yapısı, deney protokolü, oturumlar arası genellenebilirlik, kanal sayısı, frekans bandı seçimi, kullanıcı konforu, hesaplama verimliliği, güvenlik ve değerlendirme ölçütleri gibi

çok sayıda bileşeni kapsamaktadır. Dolayısıyla EEG biyometrisinde yüksek sınıflandırma doğruluğu tek başına yeterli bir başarı göstergesi değildir. Bir sistemin biyometrik açıdan anlamlı kabul edilebilmesi için, öğrendiği örüntülerin aynı kişide farklı zamanlarda korunabildiği, farklı kayıt koşullarına belirli ölçüde dayanıklı olduğu ve pratik bir kayıt düzeniyle uygulanabilir olduğu gösterilmelidir. Literatürdeki en önemli boşluklardan biri, aynı oturum içi değerlendirmelerin gerçekçi biyometrik başarımı çoğu zaman olduğundan yüksek göstermesidir. Birçok çalışmada EEG pencereleri aynı kayıt oturumundan rastgele ayrılarak eğitim ve test kümeleri oluşturulmaktadır. Bu durumda eğitim ve test örnekleri aynı elektrot yerleşimine, aynı empedans koşullarına, aynı donanım yapılandırmasına, aynı çevresel gürültü düzeyine ve aynı fizyolojik duruma ait olabilir. Model bu koşullarda yüksek doğruluk elde etse bile, bu başarının ne kadarının bireye özgü kararlı sinirsel örüntülerden, ne kadarının ise oturuma özgü geçici özelliklerden kaynaklandığı belirsiz kalır. Bu nedenle oturumlar arası değerlendirme, EEG biyometrisinde metodolojik olarak merkezi bir gerekliliktir. Maiorana vd. (2016), Das vd. (2016), Maiorana ve Campisi (2018), Özdenizci vd. (2019) ve Plucińska vd. (2023) gerçekleştirdiği çalışmalar bu sorunu açık biçimde göstermiştir. Buna rağmen güncel literatürde hâlâ çok sayıda çalışma, yüksek başarım raporlamasına karşın çapraz oturum veya uzunlamasına protokolleri sınırlı biçimde ele almaktadır. Bu tez, ana deneysel kurgusunu birinci oturumdan eğitim ve ikinci oturumdan test yapılan kapalı-küme kimlik tanımlama protokolü üzerine kurarak bu boşluğa doğrudan odaklanmaktadır.

Bir diğer önemli boşluk, tek kanallı EEG biyometrisinin oturumlar arası kararlılığına ilişkin sınırlı bilgi bulunmasıdır. Çok kanallı EEG sistemleri, daha fazla uzamsal bilgi sağladıkları için genellikle daha yüksek başarım sunmaktadır. Ancak gerçek uygulamalarda çok sayıda elektrot kullanımı hazırlık süresini artırmakta, kullanıcı konforunu azaltmakta, maliyeti yükseltmekte ve sistemin günlük kullanıma aktarılmasını zorlaştırmaktadır. Bu nedenle az kanallı veya tek kanallı EEG biyometrisi, pratik uygulamalar açısından önemli bir araştırma yönüdür. Suppiah ve Vinod (2018) gibi çalışmalar tek kanallı EEG'nin yüksek potansiyel taşıdığını göstermiştir. Bununla birlikte tek kanallı yaklaşımların çoğu, aynı oturum içi veya sınırlı protokollerle değerlendirilmiştir. Tek bir kanalın farklı oturumlarda bireye özgü bilgiyi ne kadar koruyabildiği ve hangi kanal–bant kombinasyonlarının oturumlar arası daha kararlı olduğu hâlen yeterince sistematik biçimde incelenmemiştir. Bu tez, her kanalı ayrı bir tek kanallı giriş olarak ele almakta ve kanal–bant düzeyinde başarım analizi yaparak bu boşluğu hedeflemektedir.

Bir diğer boşluk, frekans bantları ve alt bantların biyometrik ayırt edicilik açısından sistematik bi-

çimde karşılaştırılmamasıdır. EEG biyometrisi çalışmalarında delta, teta, alfa, beta ve gama gibi ana bantlar yaygın biçimde kullanılsa da, bant sınırları ve alt bant ayrımları çoğu zaman çalışma özelinde seçilmekte ve tüm bantların karşılaştırmalı etkisi ayrıntılı biçimde incelenmemektedir. Oysa önceki alt bölümde açıklandığı üzere aynı ana bant içinde farklı alt frekans aralıkları, farklı anatomik işaret üreteçlerine, farklı ağ dinamiklerine ve farklı bireysel kararlılık düzeylerine sahip olabilir. Geniş bant ortalamaları, belirli dar frekans aralıklarında ortaya çıkan kişiye özgü bilgiyi maskeleyebilir. Tu vd. (2026) tarafından önerilen *BrainprintNet* gibi güncel yaklaşımlar, çok ölçekli ve bantlar arası füzyonun EEG tabanlı beyin izi tanımada önemli olduğunu göstermektedir. Bu tezde klasik ana bantların yanında alt bantlar ve genişletilmiş gama bölütleri de deneysel aday bantlar olarak değerlendirilmiş; böylece modelin hangi frekans aralıklarından daha kararlı ve ayırt edici temsiller öğrendiği incelenmiştir.

Derin öğrenme modellerinin mimari tasarımı ile üst değişken seçiminin çoğu çalışmada sınırlı biçimde gerekçelendirilmesi bir diğer boşluğu oluşturmaktadır. EEG tabanlı kimlik tanımlamada ESA, TSA, UKSB, KYB ve Dönüştürücü tabanlı birçok model önerilmiş olsa da, bu modellerin başarısı yalnızca mimari sınıfına değil; pencere uzunluğu, yığın boyutu, öğrenme oranı, katman sayısı, evrişimsel süzgeç sayısı, çekirdek boyutu, seyrelme oranı (dropout), dikkat başlığı sayısı ve düzenlileştirme katsayıları gibi üst değişkenlere de bağlıdır. Özellikle sınırlı veri, yüksek sınıf sayısı ve oturumlar arası değişkenlik koşullarında üst değişken seçimi modelin genellenebilirliğini doğrudan etkiler. Buna rağmen literatürde birçok çalışma, sabit veya deneme-yanılmaya dayalı üst değişkenlerle sonuç raporlamaktadır. Bu tezde karma ESA–ÇY-UKSB–Dönüştürücü mimarisi kullanılmakta ve üst değişkenlerin DEHB tabanlı eniyileme algoritması ile eniyilenmesi hedeflenmektedir. Böylece model başarımının yalnızca mimari seçime değil, kontrollü üst değişken uyumuna da dayalı olarak değerlendirilmesi amaçlanmaktadır.

Bir diğer boşluk, EEG biyometrisinde model çıktılarının çoğunlukla yalnızca nihai sınıf etiketi veya doğruluk değeri üzerinden değerlendirilmesidir. Kapalı-küme kimlik tanımlamada birincisıra doğruluk önemli bir ölçüt olmakla birlikte, tek başına yeterli değildir. Biyometrik sistemlerde aday sıralaması, ilk-k doğruluk, KEK, güven puanı dağılımı ve pencere düzeyi kararların kişi düzeyinde birleştirilmesi gibi analizler sistemin davranışını daha ayrıntılı biçimde ortaya koyar. Özellikle EEG pencerelerinin kısa süreli ve gürültüye duyarlı olması nedeniyle, tek pencere kararları yerine kişi/oturum düzeyinde karar birleştirme yöntemleri daha kararlı sonuçlar sağlayabilir. Bu tez, modelin olasılıksal çıktı üretimini ilerleyen yöntem bölümlerinde ayrıntılandırmakta ve başa-

rımı birinci-sıra doğrulukla sınırlamadan ilk-k doğruluk, KEK ve kişi düzeyi karar birleştirme gibi ölçütlerle değerlendirmeyi amaçlamaktadır.

EEG biyometrisinde ön işleme ve bozulma kontrolünün biyometrik bilgi korunumu açısından yeterince tartışılmaması da önemli bir boşluk oluşturmaktadır. EEG işaretleri göz hareketi, göz kırpma, kas etkinliği, elektrot empedansı, çevresel gürültü ve cihaz kaynaklı etkilerden etkilenir. Geleneksel EEG analizinde bozulmaların mümkün olduğunca temizlenmesi genel bir amaçtır. Ancak biyometrik bağlamda aşırı agresif ön işleme, bireye özgü ve kararlı olabilecek bazı işaret bileşenlerinin de zayıflamasına neden olabilir. Usman vd. (2026), EEG biyometrisinde gürültü azaltma ile sinirsel imza koruma arasında dikkatli bir denge kurulması gerektiğini vurgulamıştır. Bu nedenle EEG biyometrisinde ön işleme yalnızca işaret temizleme adımı değil, aynı zamanda biyometrik temsilin korunmasını etkileyen kritik bir tasarım kararıdır. Bu tezde kullanılan veri ön işleme adımları, tek kanallı ve oturumlar arası değerlendirme hedefiyle uyumlu olarak ele alınmış; modelin aynı oturum koşullarına aşırı uyum göstermemesi için protokol tasarımı ön plana çıkarılmıştır.

Literatürdeki en önemli sorunlardan biri, kapalı-küme kimlik tanımlama, kimlik doğrulama, açık-küme tanıma ve sürekli kimlik doğrulama senaryolarının zaman zaman birbirine karışmasıdır. Bazı çalışmalarda "kimlik doğrulama (authentication)", "kimlik tanımlama (identification)" ve "tanıma/biyometrik tanıma (recognition)" kavramları farklı anlamlarda kullanılmakta; bu durum başarım ölçütlerinin ve deney protokollerinin karşılaştırılmasını zorlaştırmaktadır. Kapalı-küme kimlik tanımlamada sistem, test örneğini kayıtlı sınıflardan birine atar; açık-küme senaryoda ise kayıtlı olmayan kullanıcıyı reddetmesi gerekir. Doğrulamada ise kullanıcı bir kimlik iddiasında bulunur ve sistem bu iddiayı kabul veya reddeder. Bu tez, kapsamını açık biçimde kapalı-küme EEG tabanlı kimlik tanımlama olarak sınırlandırmaktadır. Böylece çalışmanın değerlendirme ölçütleri ve deneysel protokolleri, problem tanımıyla tutarlı hâle getirilmiştir. Kimlik doğrulama, açık-küme reddi ve sürekli doğrulama senaryoları ise mevcut model çıktıları üzerine inşa edilebilecek gelecekteki araştırma yönleri olarak değerlendirilmiştir.

Literatürde aynı anda hem yüksek başarım, hem tek kanallı uygulanabilirlik, hem frekans alt bant analizi, hem de oturumlar arası değerlendirme hedeflerinin sınırlı sayıda çalışmada birlikte ele alınmaktadır. Güncel çalışmaların bir kısmı derin öğrenme ile yüksek doğruluk elde etmekte; bir kısmı kanal sayısını azaltmaya odaklanmakta; bir kısmı ise uzunlamasına değerlendirme yapmaktadır. Ancak bu eksenlerin tümünü aynı deneysel çerçevede bir araya getiren çalışma sayısı sınırlı-

dır. Bu tez, tek kanallı EEG pencereleri üzerinden karma derin öğrenme mimarisi geliştirmesi, alt bantlar ve kanal katkılarını sistematik biçimde incelemesi, DEHB tabanlı üst değişken eniyilemesi kullanması ve temel başarıyı oturumlar arası kapalı-küme protokolde değerlendirmesi bakımından literatürdeki bu kesişim noktasına konumlanmaktadır. Çizelge 2.4, literatürde belirlenen başlıca boşlukları ve bu tezin söz konusu boşluklara nasıl karşılık verdiğini özetlemektedir.

Çizelge 2.4 Literatürdeki başlıca boşluklar ve tezin konumlandırılması

Literatürdeki boşluk	**Mevcut durum**	**Bu tezdeki karşılık**
Oturumlar arası genellenebilirlik	Birçok çalışma aynı oturum içi veya rastgele pencere ayrımıyla yüksek doğruluk raporlamaktadır.	Ana protokol birinci oturumdan eğitim, ikinci oturumdan test şeklinde tanımlanmıştır.
Tek kanallı EEG'nin gerçekçi değerlendirilmesi	Tek/az kanallı çalışmalar vardır; ancak oturumlar arası kararlılık ve kanal–bant katkısı sınırlı incelenmiştir.	Her kanal tek kanallı giriş olarak değerlendirilmiş; kanal–bant düzeyi ayırt edicilik analiz edilmiştir.
Frekans alt bantlarının sistematik etkisi	Ana bantlar yaygın kullanılsa da alt bantların karşılaştırmalı biyometrik katkısı yeterince açık değildir.	Delta, teta, alfa, mu, beta, gama ve alt bantlar kapsamlı aday frekans uzayı olarak ele alınmıştır.
Karma derin öğrenme mimarisi	ESA, TSA ve Dönüştürücü yaklaşımları kullanılmıştır; ancak tek kanallı çapraz oturum bağlamında karma yapıların değerlendirilmesi sınırlıdır.	ESA–ÇY-UKSB–Dönüştürücü bileşenlerini birleştiren karma model kullanılmıştır.
Üst değişken seçimi	Çok sayıda çalışmada üst değişkenler sınırlı arama veya sabit seçimlerle belirlenmektedir.	DEHB tabanlı üst değişken eniyilemesi ile model yapılandırması sistematik hâle getirilmiştir.
Başarımın yalnızca doğrulukla raporlanması	Birinci-sıra doğruluk sık kullanılır; aday sıralama ve kişi düzeyi kararlar daha az incelenir.	Birinci-sıra doğruluk yanında ilk-k, KEK ve kişi düzeyi karar birleştirme analizleri planlanmıştır.
Problem tanımındaki belirsizlik	Kimlik tanımlama, doğrulama ve açık-küme tanıma kavramları bazı çalışmalarda iç içe kullanılmaktadır.	Tez kapsamı açık biçimde kapalı-küme EEG tabanlı kimlik tanımlama olarak sınırlandırılmıştır.

Bu çerçevede tezin literatürdeki konumu üç düzeyde özetlenebilir. Birinci düzey, biyometrik problem tanımıdır. Bu tez, doğrulama veya açık-küme reddi yerine kapalı-küme kimlik tanımlama problemine odaklanmaktadır. Bu tercih, EEG işaretindeki bireye özgü örüntülerin kayıtlı kullanıcılar arasında ne ölçüde ayırt edici olduğunu ölçmeyi amaçlayan temel bir araştırma sorusuna dayanmaktadır. İkinci düzey, veri ve protokol tasarımıdır. Çalışmada iki oturumlu USYM veri alt kümesi

kullanılarak oturumlar arası değerlendirme yapılmakta; böylece aynı oturum içi yüksek doğrulukların ötesinde, modelin farklı kayıt zamanlarına genellenebilirliği sınanmaktadır. Üçüncü düzey ise model ve temsil tasarımıdır. Tek kanallı EEG pencereleri, frekans alt bantları ve karma derin öğrenme mimarisi birlikte ele alınarak hem pratik uygulanabilirlik hem de yüksek ayırt edicilik hedeflenmektedir. Bu tez, literatürdeki çok kanallı ve yüksek doğruluk odaklı yaklaşımlardan farklı olarak, tek kanallı EEG biyometrisinin sınırlarını daha gerçekçi ve sistematik biçimde değerlendirmeyi amaçlamaktadır. Çok kanallı EEG, araştırma ortamında güçlü bir bilgi kaynağı sunmasına rağmen, günlük güvenlik uygulamaları açısından çoğu zaman maliyetli ve zahmetlidir. Tek kanallı yaklaşım ise daha düşük donanım gereksinimi, daha hızlı kurulum, daha yüksek kullanıcı konforu ve daha uygulanabilir sistem tasarımı açısından avantajlıdır. Ancak tek kanallı sistemlerin başarılı olabilmesi için, seçilen kanalın ve frekans içeriğinin gerçekten bireye özgü ve oturumlar arasında korunabilir bilgi taşıması gerekir. Bu nedenle tezde kanal seçimi yalnızca teknik bir boyut olarak değil, EEG biyometrisinin sinir işlevbilimsel ve pratik uygulanabilirlik boyutlarını birleştiren temel bir araştırma sorusu olarak ele alınmaktadır. Ayrıca bu çalışma, frekans alt bantlarını yalnızca ön işleme amacıyla kullanılan süzgeç aralıkları olarak değil, biyometrik temsil uzayının temel bileşenleri olarak değerlendirmektedir. Literatürde birçok çalışma belirli bir bant veya sınırlı sayıda bant üzerinde odaklanırken, bu tezde geniş bir alt bant uzayı deneysel olarak karşılaştırılmaktadır. Bu yaklaşım, EEG işaretinde bireye özgü bilginin hangi frekans ölçeklerinde daha görünür olduğunu ortaya koymaya yardımcı olur. Özellikle duvarsal, artkafasal, alınsal ve duyusal-devinimsel bölgelerden elde edilen tek kanallı işaretlerin farklı frekans alt bantlarında farklı ayırt edicilik gösterebilmesi, kanal–bant düzeyi analizleri tezin ayırt edici yönlerinden biri hâline getirmektedir.

Sonuç olarak bu tez, EEG tabanlı biyometrik kimlik tanımlama literatüründe üç temel boşluğa odaklanmaktadır: oturumlar arası genellenebilirlik, tek kanallı uygulanabilirlik ve frekans alt bantlarının sistematik değerlendirilmesi. Karma ESA–ÇY-UKSB–Dönüştürücü mimarisi ve DEHB tabanlı üst değişken eniyilemesi, bu boşlukları deneysel olarak incelemek için kullanılan yöntemsel araçlardır. Çalışmanın temel katkısı, EEG işaretlerindeki bireye özgü örüntülerin yalnızca aynı oturum içinde değil, farklı oturumlara aktarıldığında da ne ölçüde korunabildiğini tek kanallı ve bant-duyarlı bir modelleme çerçevesiyle ortaya koymaktır. Bu yönüyle tez, EEG biyometrisinin yüksek doğruluklu laboratuvar gösterimlerinden, daha pratik ve oturumlar arası daha güvenilir sistem tasarımlarına geçişine katkı sağlamayı hedeflemektedir.

3. MATERYAL VE YÖNTEM

Bu bölümde, tezde kullanılan veri kümesi, veri hazırlama süreci, önerilen gürültü tespiti ve giderimi yaklaşımı, geliştirilen derin öğrenme mimarisi, üst değişken eniyileme yöntemi ve başarım değerlendirme ölçütleri ayrıntılı olarak açıklanmaktadır. Bulanık çıkarım sistemi (BÇS, Fuzzy Inference System: FIS) ile bozulma tespiti ve Üretken Çekişmeli Ağ (ÜÇA, Generative Adversarial Network: GAN) tabanlı yeniden yapılandırmayı birleştiren özgün bir gürültü giderimi yaklaşımı önerilmiştir. Daha sonra, çok ölçekli evrişimsel öznitelik çıkarımı, çift yönlü UKSB birimleri ve Dönüştürücü tabanlı dikkat düzeneğini bütünleştiren karma model mimarisi sunulmuştur. Modelin genellenebilirliğini artırmak ve en uygun mimari/eğitim değişkenlerini belirlemek amacıyla DEHB tabanlı üst değişken eniyilemesi uygulanmış; son aşamada ise kapalı-küme EEG tabanlı kimlik tanımlama problemine uygun pencere düzeyi ve kişi düzeyi başarım ölçütleri tanımlanmıştır. Bölümün genel iş akışı ve yöntem bileşenleri arasındaki ilişki Şekil 3.1'de şematik olarak özetlenmektedir.

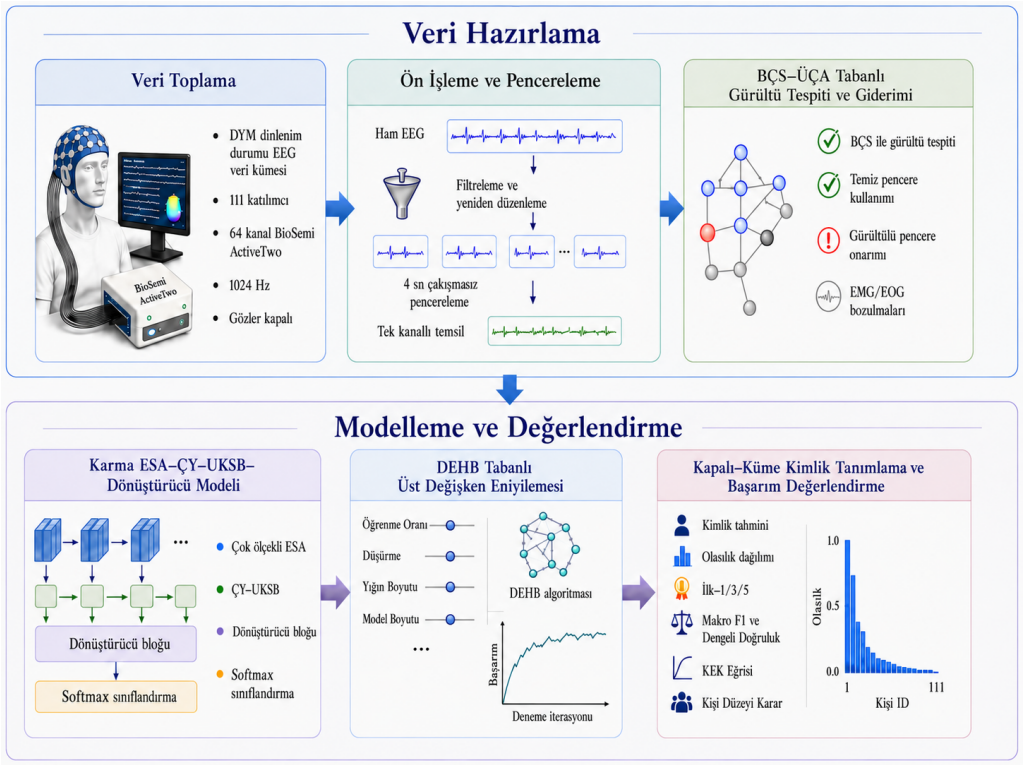

Şekil 3.1 Tez kapsamında önerilen EEG tabanlı biyometrik kimlik tanımlama sisteminin genel iş akışı

3.1 Oslo Üniversitesi USYM Dinlenim Durumu EEG Veri Kümesi

Bu tezde kullanılan EEG verileri, OpenNeuro açık bilim ortamında *ds003775* erişim numarası ile paylaşılan Oslo Üniversitesi USYM Dinlenim Durumu EEG veri kümesinden elde edilmiştir. Veri kümesi, Hatlestad-Hall vd. (2022) tarafından yayımlanan *Data in Brief* makalesi kapsamında tanımlanmış olup, Oslo Üniversitesi Psikoloji Bölümü ve Oslo Üniversite Hastanesi Sinirbilim Bölümü ile ilişkili araştırmacılar tarafından hazırlanmıştır. *OpenNeuro* kayıtlarında veri kümesi, *Stimulus-Selective Response Modulation* projesinden elde edilen dinlenim durumu EEG kayıtlarını içeren açık erişimli bir veri kaynağı olarak sunulmaktadır. Bu nedenle, bu tezde veri kümesi kısaca USYM dinlenim durumu EEG veri kümesi olarak adlandırılmıştır.

Söz konusu veri kümesinin bu tez açısından önemli olmasının başlıca nedeni, EEG tabanlı biyometrik kimlik tanımlama probleminin gerektirdiği çok sayıda sağlıklı katılımcı, standart elektrot yerleşimi, yüksek örnekleme frekansı, dinlenim durumu kayıt koşulu ve çoklu oturum yapısını bir arada sağlamasıdır. EEG tabanlı kimlik tanımlama çalışmalarında yalnızca bireyler arası ayırt ediciliğin değil, aynı bireyin farklı zamanlarda kaydedilen EEG örüntülerinin ne ölçüde kararlı kaldığının da incelenmesi gerekmektedir. USYM veri kümesinde 42 katılımcı için ikinci bir EEG kayıt oturumunun bulunması, bu tezde önerilen modelin oturumlar arası genellenebilirliğini değerlendirmek açısından güçlü bir deneysel temel sunmaktadır.

Veri kümesi, BGVY ve EEG-BGVY uzantısına uygun biçimde düzenlenmiştir. BGVY yapısı, sinir-görüntüleme ve elektrofizyolojik veri kümelerinde dosya adlandırma, dizin hiyerarşisi, üst veri (meta-veri) tanımlama ve veri paylaşım süreçlerini standartlaştırmayı amaçlayan bir yaklaşımdır. EEG-BGVY uzantısı ise EEG kayıtlarının kanal bilgileri, elektrot konumları, olay dosyaları, kayıt değişkenleri ve oturum bilgileriyle birlikte daha sistematik ve yeniden üretilebilir biçimde sunulmasını sağlamaktadır (Pernet vd. 2019). Bu standart yapı sayesinde veri kümesi, yalnızca ham işaret dosyalarından oluşan bir arşiv niteliği taşımamakta; aynı zamanda katılımcı bilgileri, oturum yapısı, kanal üst verileri ve türev ön işleme çıktılarıyla birlikte tekrar analiz edilebilir bir araştırma altyapısı sunmaktadır. Veri kümesinin BGVY dosya yapısının genel şematiği Şekil 3.2'de gösterilmektedir.

Veri kümesi, herhangi bir sinirsel hastalık veya ciddi psikiyatrik rahatsızlık öyküsü bulunmayan 111 sağlıklı bireyden elde edilen dinlenim durumu EEG kayıtlarını içermektedir. Katılımcıların yaş

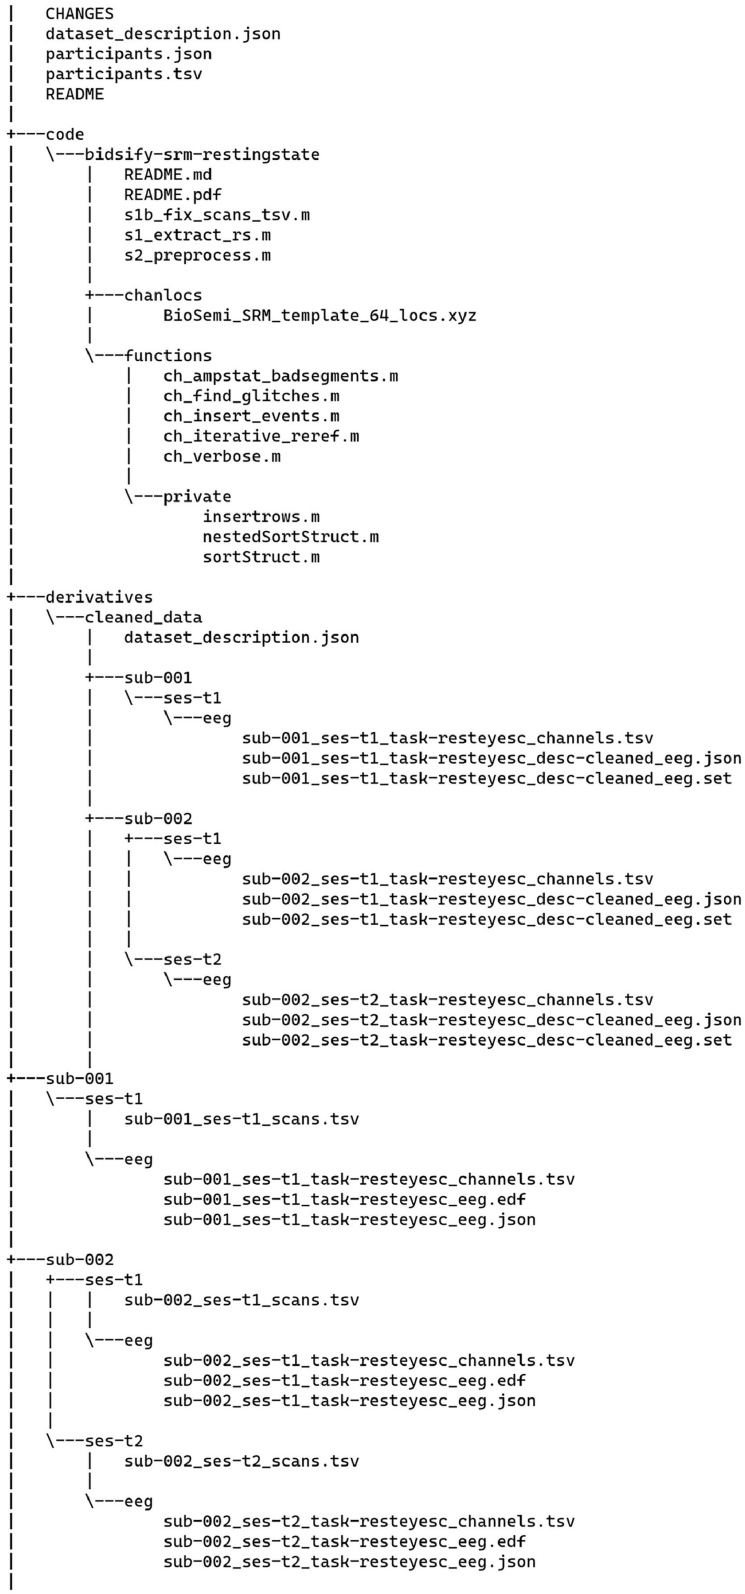

Şekil 3.2 EEG-BGVY standardına uygun genel dizin ve dosya yapısının şematik özeti

aralığı 17–71 arasında değişmekte olup, örneklem geniş bir erişkin yaş dağılımına sahiptir. Tüm katılımcılar çalışmaya gönüllü olarak katılmış ve Helsinki Bildirgesi ilkelerine uygun biçimde bilgilendirilmiş, onam vermiştir. Deneysel protokol, ilgili etik kurul tarafından onaylanmıştır. Veri kümesinin biyometrik araştırmalar açısından en dikkat çekici özelliği, 42 katılımcı için iki ayrı EEG kayıt oturumunun bulunmasıdır. İkinci kayıt oturumu, ilk oturumdan yaklaşık 2–3 ay sonra gerçekleştirilmiştir. Bu çoklu oturum yapısı, aynı bireyden farklı zaman noktalarında elde edilen EEG işaretlerinin zamansal kararlılığını ve birey-içi değişkenliğini değerlendirmeye olanak sağlamaktadır.

Bu tezde veri kümesinin tamamı veri kaynağı olarak tanımlanmakla birlikte, ana deneysel kurgu 42 iki oturumlu katılımcı üzerinden oluşturulmuştur. Bunun nedeni, tezde temel değerlendirme protokolünün kapalı-küme ve oturumlar arası kimlik tanımlama üzerine kurulmuş olmasıdır. Bu kapsamda, 111 katılımcıdan oluşan veri kümesi genel veri havuzunu; iki oturum kaydı bulunan 42 katılımcı ise ana çapraz-oturum deneysel alt kümeyi oluşturmaktadır. İki oturumlu kaydı bulunmayan 69 katılımcı, oturumlar arası ana deney protokolüne dâhil edilmemiştir. Böylece modelin başarımı, aynı kayıt oturumundan rastgele ayrılmış eğitim ve test pencereleri yerine, farklı zamanlarda kaydedilmiş EEG işaretleri üzerinde değerlendirilmiştir. Bu tercih, EEG tabanlı biyometrik kimlik tanımlama sistemlerinin gerçek kullanım senaryolarına daha yakın ve daha zorlu bir biçimde sınanmasına olanak tanımaktadır.

Tez kapsamında kullanılan veri seçim süreci Şekil 3.3'te özetlenmiştir. Buna göre, açık veri kaynağında bulunan 111 katılımcı içerisinden iki oturumlu kayıt yapısına sahip 42 katılımcı seçilmiş; bu katılımcıların birinci oturum kayıtları temel eğitim verisi, ikinci oturum kayıtları ise temel test verisi olarak kullanılmıştır. Ters yönlü oturumlar arası değerlendirme ve aynı oturum içi protokoller ise modelin kayıt yönüne ve oturum etkisine duyarlılığını incelemek amacıyla ayrıca ele alınmıştır.

EEG kayıtları, USYM paradigmasına dayalı daha geniş kapsamlı bir deneysel oturumdan elde edilen dinlenim durumu bölümlerini içermektedir. Ana deneysel çerçeve, duyusal uyaranlara verilen sinirsel yanıtların modülasyonunu ve buna bağlı sinir işlevbilimsel değişimleri incelemeyi amaçlamaktadır. Ancak bu tezde görev tabanlı olayla ilişkili potansiyel kayıtları veya duyusal uyarım yanıtları kullanılmamış; analizler yalnızca dinlenim durumu EEG işaretleri üzerinde gerçekleştirilmiştir. Dinlenim durumu kaydı sırasında katılımcılardan yaklaşık dört dakika boyunca gözleri kapalı biçimde, herhangi bir bilişsel görev yerine getirmeden sessizce oturmaları istenmiştir. Bu kayıt

koşulu, dışsal uyaranlara bağlı zaman-kilitli yanıtları en aza indirerek bireyin doğal/kendiliğinden sinirsel etkinlik örüntülerinin incelenmesine imkân tanımaktadır. Bu yönüyle gözler kapalı dinlenim durumu EEG, görev tasarımına bağlı değişkenleri azaltması ve bireye özgü ritmik örüntüleri görünür kılması nedeniyle EEG tabanlı biyometrik kimlik tanımlama çalışmaları için uygun bir veri kaynağıdır.

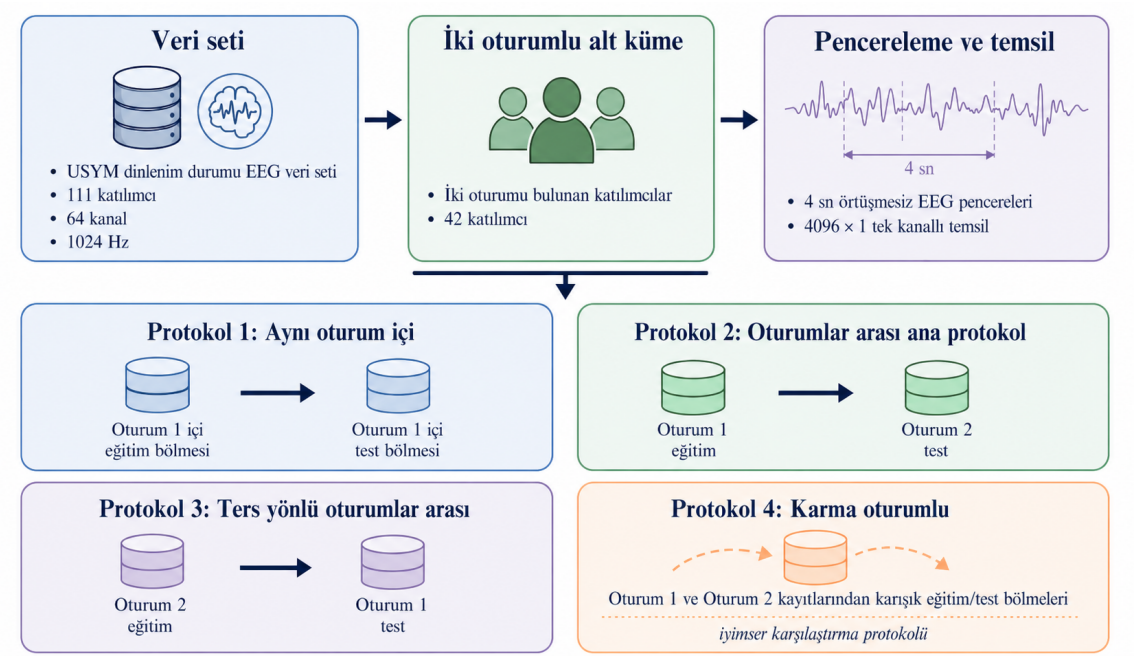

Şekil 3.3 USYM dinlenim durumu EEG veri kümesinden tez kapsamında kullanılan iki oturumlu kapalı-küme deneysel alt kümenin oluşturulması

EEG verileri, BioSemi ActiveTwo EEG sistemi kullanılarak kaydedilmiştir. Kayıtlar 64 kanallı Ag–AgCl elektrot düzeniyle gerçekleştirilmiş olup, elektrot yerleşimi genişletilmiş uluslararası 10–20 sistemiyle uyumludur. İşaretler 1024 Hz örnekleme frekansı ile toplanmıştır. Bu yüksek örnekleme frekansı, hem zaman bölgesinde ayrıntılı dalga biçimi analizleri hem de frekans bölgesinde çoklu bant ve alt bant temelli temsil çıkarımı açısından önemli bir avantaj sağlamaktadır. Kayıtların aynı deneysel ortam, aynı kayıt sistemi ve aynı protokol yapısı altında elde edilmiş olması, cihaz ve laboratuvar kaynaklı sistematik değişkenlikleri azaltmakta; buna karşılık bireyler arası sinir işlevbilimsel farklılıkların daha güvenilir biçimde incelenmesine yardımcı olmaktadır.

Veri kümesinin BGVY yapısı içerisinde her katılımcı *sub-XXX* biçiminde adlandırılmış dizinlerle temsil edilmiştir. Birden fazla oturuma sahip katılımcılar için *ses-t1* ve *ses-t2* oturum dizinleri

kullanılmıştır. Dinlenim durumu gözler kapalı kayıtları dosya adlarında *task-resteyesc* etiketiyle tanımlanmaktadır. Kök dizinde yer alan *dataset_description.json* dosyası veri kümesinin genel tanımını, *participants.tsv* dosyası katılımcı düzeyi bilgileri, kanal dosyaları ise elektrot/kayıt bilgilerini sunmaktadır. Ham EEG verileri Avrupa Veri Biçimi (AVB, European Data Format: EDF) biçiminde saklanmaktadır. AVB biçimi, çok kanallı fizyolojik işaretlerin paylaşımı için yaygın olarak kullanılan bir veri biçimi olup, EEG kayıtlarının farklı yazılım ortamlarında okunmasını kolaylaştırmaktadır.

Bu tezde hem ham EEG verileri hem de veri kümesiyle birlikte sunulan temizlenmiş EEG verileri kullanılmıştır. Bu nedenle deneysel süreç iki paralel veri akışı üzerinden kurgulanmıştır. Birinci veri akışı, ham AVB kayıtlarını temel almıştır. Bu akışta işaretler, tez kapsamında tanımlanan veri ön işleme, pencereleme, tek kanallı temsil çıkarımı ve önerilen BÇS–Wasserstein ÜÇA tabanlı gürültü tespiti/giderimi yaklaşımı ile işlenmiştir. Ham veri akışının kullanılmasındaki amaç, önerilen ön işleme ve gürültü giderme yönteminin gerçek kayıt koşullarında bulunan göz hareketi, kas etkinliği, hat gürültüsü ve kanal kalitesi değişkenlikleri karşısındaki etkisini doğrudan değerlendirmektir.

İkinci veri akışı ise veri kümesi içerisinde */derivatives/cleaned_data/* dizini altında paylaşılan temizlenmiş EEG kayıtlarını temel almıştır. Bu temizlenmiş veri akışı, veri kümesini hazırlayan araştırmacılar tarafından uygulanan otomatik ön işleme hattından geçirilmiş kayıtları içermektedir. Söz konusu türev veriler, ham veri akışında elde edilen sonuçların kalite kontrollü bir referans veri akışı ile karşılaştırılması amacıyla kullanılmıştır. Böylece tez kapsamında önerilen modelin yalnızca ham veri üzerindeki başarımı değil, aynı zamanda önceden temizlenmiş EEG işaretleri üzerindeki başarımı da değerlendirilmiştir. Her iki veri akışında da katılımcı seçimi, oturum ayrımı, sınıf etiketleri, kanal adları ve pencereleme yöntemi aynı tutulmuştur. Bu sayede ham ve temizlenmiş veri sonuçları arasındaki farkların veri bölme yönteminden değil, işaret kalitesi ve ön işleme düzeyinden kaynaklanması sağlanmıştır.

Temizlenmiş türev verilerin kullanılması, EEG biyometrisi açısından iki yönlü bir katkı sağlamaktadır. İlk olarak, otomatik olarak temizlenmiş kayıtlar üzerinde elde edilen başarım, gürültü etkisinin azaltıldığı daha kontrollü bir senaryoyu temsil eder. Ek olarak, ham veri üzerinde geliştirilen ve önerilen gürültü giderme yaklaşımıyla işlenen işaretlerin başarımı, bu temizlenmiş veri akışıyla karşılaştırılarak önerilen yöntemin pratik değeri daha nesnel biçimde değerlendirilebilir. Bununla

birlikte, temizlenmiş türev verilerin otomatik bir ön işleme hattının çıktısı olduğu unutulmamalıdır. Bu tür otomatik temizleme süreçleri, bazı bozulmaları başarıyla azaltırken bazı durumlarda işaretin biyometrik açıdan ayırt edici olabilecek bileşenlerini de etkileyebilir. Bu nedenle tezde ham ve temizlenmiş veri akışlarının birlikte kullanılması, EEG biyometrisi açısından daha kapsamlı ve dengeli bir değerlendirme çerçevesi sunmaktadır.

Veri kümesinde katılımcılara ait yaş, cinsiyet ve bazı sinirsel-psikolojik değerlendirme sonuçları gibi ek üst veriler de bulunmaktadır. Ancak bu tezde söz konusu nüfusbilimsel veya sinirsel-psikolojik bilgiler model girişine dâhil edilmemiştir. Bunun temel nedeni, geliştirilen biyometrik kimlik tanımlama modelinin yalnızca EEG işaretinden bireye özgü sinir işlevbilimsel örüntüleri öğrenmesini sağlamaktır. Nüfusbilimsel değişkenlerin model girişine katılması, sınıflandırma başarısının doğrudan EEG örüntülerinden mi yoksa yaş/cinsiyet gibi ikincil ipuçlarından mı kaynaklandığını yorumlamayı güçleştirebilir. Bu nedenle üst veriler veri kümesini tanımlamak, katılımcı yapısını raporlamak ve veri kaynağının kapsamını açıklamak amacıyla kullanılmış; sınıflandırıcı modelin eğitim veya test girdisi olarak kullanılmamıştır.

Çizelge 3.1, tez kapsamında kullanılan USYM dinlenim durumu EEG veri kümesinin temel özelliklerini özetlemektedir. Bu çizelge, veri kümesinin açık erişim yapısı, katılımcı sayısı, oturum düzeni, kayıt değişkenleri ve tezde kullanılan deneysel alt küme açısından genel bir bakış sunmaktadır. Bu tezde kullanılan ana deneysel protokolde, iki oturumlu 42 katılımcının birinci oturum kayıtları model eğitimi, ikinci oturum kayıtları ise model testi için kullanılmıştır. Böylece modelin daha önce eğitimde gördüğü bireylere ait ancak farklı zamanda kaydedilmiş EEG işaretlerini doğru kimlikle eşleştirme becerisi ölçülmüştür. Bu yapı, kapalı-küme kimlik tanımlama problemine karşılık gelmektedir; çünkü test örneklerinin eğitim aşamasında sisteme kayıtlı olan 42 bireyden birine ait olduğu varsayılmaktadır. Bununla birlikte, test verisinin farklı oturumdan gelmesi nedeniyle problem aynı oturum içi rastgele bölmeye kıyasla daha zorlu ve biyometrik açıdan daha gerçekçi bir değerlendirme sunmaktadır. Ana protokole ek olarak, aynı oturum içi ve ters yönlü oturumlar arası protokoller de değerlendirilmiştir. Aynı oturum içi protokol, modelin aynı kayıt koşulları altındaki ayırt edicilik kapasitesini belirlemek amacıyla kullanılmıştır. Ters yönlü oturumlar arası protokolde ise ikinci oturum eğitim, birinci oturum test verisi olarak kullanılarak model başarısının oturum yönüne duyarlılığı incelenmiştir. Bu karşılaştırmalı yapı sayesinde, önerilen kimlik tanımlama yaklaşımının yalnızca yüksek doğruluk üretip üretmediği değil, aynı zamanda oturum değişkenliği karşısında ne ölçüde kararlı kaldığı da analiz edilmiştir.

Bu veri kümesinin tezdeki kullanımının bazı sınırlılıkları da bulunmaktadır. İlk olarak, veri kümesi sağlıklı bireylerden oluşmaktadır; bu nedenle elde edilen sonuçların sinirsel veya psikiyatrik hastalığı bulunan gruplara doğrudan genellenmesi uygun değildir. Ayrıca, tüm kayıtların aynı veri kaynağından ve benzer laboratuvar koşullarından elde edilmiş olması cihazlar arası, merkezler arası veya farklı EEG sistemleri arası genellenebilirliği değerlendirmeye imkân vermemektedir. Buna ek olarak, iki oturumlu kayıt yalnızca 42 katılımcı için mevcut olduğundan, oturumlar arası ana biyometrik değerlendirme bu alt küme ile sınırlıdır. Bir diğeri ise, kayıt koşulu gözler kapalı dinlenim durumudur; bu nedenle sonuçlar görev tabanlı, gözler açık veya sürekli kullanım senaryolarını doğrudan temsil etmemektedir. Son olarak, temizlenmiş türev veriler otomatik bir ön işleme hattının çıktısı olduğundan, bu veriler üzerinde elde edilen başarım sonuçları kullanılan temizleme yönteminin etkisinden bağımsız yorumlanmamalıdır. Bu sınırlılıklara rağmen USYM dinlenim durumu EEG veri kümesi, tezin hedefleri açısından güçlü bir materyal altyapısı sunmaktadır.

Çizelge 3.1 USYM dinlenim durumu EEG veri kümesinin tez açısından temel özellikleri

Özellik	**Açıklama**
Veri kümesi adı	USYM dinlenim durumu EEG veri kümesi
Açık veri kaynağı	OpenNeuro, *ds003775*
İlgili yayın	Hatlestad-Hall vd. (2022), *Data in Brief*
Veri standardı	EEG-BGVY uyumlu dizin ve üst veri yapısı
Toplam katılımcı sayısı	111 sağlıklı birey
Ana deneysel alt küme	İki oturumlu kaydı bulunan 42 katılımcı
Tek oturumlu katılımcılar	69 katılımcı; ana çapraz-oturum deneyine dâhil edilmemiştir
Oturum aralığı	İkinci kayıt, ilk oturumdan yaklaşık 2–3 ay sonra alınmıştır
Kayıt durumu	Gözler kapalı dinlenim durumu EEG
Yaklaşık kayıt süresi	Yaklaşık 4 dakika
EEG sistemi	BioSemi ActiveTwo
Kanal sayısı	64 EEG kanalı
Elektrot yerleşimi	Genişletilmiş uluslararası 10–20 sistemi
Örnekleme frekansı	1024 Hz
Ham veri biçimi	AVB
Türev veri	*/derivatives/cleaned_data/* altında temizlenmiş EEG kayıtları
Tezde kullanılan veri akışları	Ham EEG veri akışı ve temizlenmiş EEG veri akışı
Model girdisi	Tek kanallı EEG pencereleri
Ana değerlendirme yapısı	Kapalı-küme, oturumlar arası kimlik tanımlama

3.2 Veri Ön İşleme, Pencereleme ve Tek Kanallı EEG Temsili

EEG işaretleri düşük genlikli, durağan olmayan, fizyolojik ve çevresel bozulmalara duyarlı biyolojik işaretlerdir. Bu nedenle EEG tabanlı biyometrik kimlik tanımlama çalışmalarında ham kayıtların doğrudan modele verilmesi çoğu zaman uygun değildir. Elektrot-deri empedansı, göz kırpma ve göz hareketleri, kas etkinliği, hat gürültüsü, düşük frekanslı sürüklenmeler, kayıt ortamı değişkenliği ve kanal kalitesi farklılıkları EEG işaretinin hem zaman bölgesi biçimini hem de frekans bölgesi dağılımını etkileyebilmektedir. Bu durum, özellikle oturumlar arası biyometrik kimlik tanımlama probleminde daha kritik hâle gelmektedir; çünkü modelin aynı bireye ait kararlı sinirsel örüntüleri öğrenmesi beklenirken, geçici kayıt koşullarına özgü yapay örüntüleri öğrenmesi gerçek uygulama başarısını yanıltıcı biçimde artırabilir. Bu nedenle tez kapsamında veri ön işleme, pencereleme ve tek kanallı temsil oluşturma aşamaları, model mimarisinden önce gelen temel yöntemsel bileşenler olarak ele alınmıştır.

Bu tezde deneysel süreç hem ham EEG kayıtları hem de veri kümesiyle birlikte sunulan temizlenmiş EEG kayıtları üzerinden yürütülmüştür. Ham veri akışında AVB biçimindaki sürekli EEG kayıtları temel alınmış; bu kayıtlar tez kapsamında tanımlanan süzgeçleme, pencereleme, tek kanallı temsil çıkarımı ve bozulma tespiti/giderimi adımlarından geçirilmiştir. Temizlenmiş veri akışında ise veri kümesinin */derivatives/cleaned_data/* dizini altında paylaşılan ve veri kümesini hazırlayan araştırmacılar tarafından ön işlemden geçirilmiş türev kayıtlar kullanılmıştır. Böylece önerilen modelin yalnızca ham EEG işaretleri üzerindeki başarımı değil, aynı zamanda önceden temizlenmiş ve kalite kontrolünden geçirilmiş EEG işaretleri üzerindeki başarımı da karşılaştırmalı olarak değerlendirilebilmiştir. Her iki veri akışında da katılımcı seçimi, oturum ayrımı, kanal adları, pencereleme yapısı ve sınıf etiketleri aynı tutulmuştur. Bu tercih, ham ve temizlenmiş veri sonuçları arasındaki farkların veri bölme yönteminden değil, işaret kalitesi ve ön işleme düzeyinden kaynaklanmasını sağlamaktadır.

Ham EEG kayıtlarının ön işleme aşamasında öncelikle kayıtların kanal bütünlüğü, örnekleme frekansı ve oturum bilgileri denetlenmiştir. USYM dinlenim durumu EEG veri kümesinde işaretler 1024 Hz örnekleme frekansı ile kaydedildiğinden, zaman bölgesindeki her örnek yaklaşık 0.9766 ms zaman çözünürlüğüne karşılık gelmektedir. Örnekleme frekansı f_s olmak üzere zaman çözü-

nürlüğü aşağıdaki şekilde ifade edilebilir:

$$\Delta t = \frac{1}{f_s} \tag{3.1}$$

Bu tezde $f_s = 1024$ Hz olduğundan,

$$\Delta t = \frac{1}{1024} \approx 0.0009766 \text{ s} \tag{3.2}$$

olarak hesaplanmaktadır. Bu yüksek zaman çözünürlüğü, EEG işaretindeki hızlı salınımsal değişimlerin ve kısa süreli yapı biçimi örüntülerin korunmasına olanak tanımaktadır. Bununla birlikte biyometrik kimlik tanımlama açısından yalnızca yüksek örnekleme frekansı yeterli değildir; işaretin fizyolojik olarak anlamlı ve karşılaştırılabilir frekans aralığına indirgenmesi de gerekmektedir. Bu nedenle ham veri akışında işaretler öncelikle düşük frekanslı sürüklenmeleri ve yüksek frekanslı istenmeyen bileşenleri azaltacak şekilde bant geçiren süzgeçleme işleminden geçirilmiştir.

Süzgeçleme aşamasında temel amaç, EEG biyometrisi açısından anlamlı salınım bileşenleri korurken, yavaş sürüklenme, elektrot polarizasyonu, hareket kaynaklı düşük frekanslı bozulmalar ve yüksek frekanslı kas/cihaz gürültüsü gibi istenmeyen bileşenleri azaltmaktır. Genel olarak bir ham EEG işareti $x_c[n]$ ile gösterildiğinde, c. kanala ait süzgeçlenmiş işaret $y_c[n]$ doğrusal zamanla değişmeyen bir süzgeç için aşağıdaki evrişim işlemiyle ifade edilebilir:

$$y_c[n] = (h * x_c)[n] = \sum_{k=-\infty}^{\infty} h[k] x_c[n-k] \tag{3.3}$$

Burada $h[k]$ süzgecin dürtü tepkisini, $x_c[n]$ ham EEG işaretini ve $y_c[n]$ süzgeçlenmiş EEG işaretini temsil etmektedir. Frekans bölgesinde aynı işlem,

$$Y_c(e^{j\omega}) = H(e^{j\omega}) X_c(e^{j\omega}) \tag{3.4}$$

şeklinde yazılabilir. Bu ifade, süzgecin frekans tepkisi $H(e^{j\omega})$ aracılığıyla işaretin belirli frekans bileşenlerinin geçirilip belirli bileşenlerinin bastırıldığını göstermektedir. Tez kapsamında kullanılan temel süzgeçleme yaklaşımı, dinlenim durumu EEG işaretinde biyometrik bilgi taşıdığı düşünülen düşük ve orta-yüksek frekans bileşenlerini koruyacak, buna karşılık çok düşük frekanslı sürüklenmeleri ve yüksek frekanslı bozulma etkilerini azaltacak bir bant geçiren süzgeçleme mantığına dayanmaktadır.

Temizlenmiş türev veri akışında, veri kümesini hazırlayan araştırmacılar tarafından uygulanan otomatik ön işleme süreci kullanılmıştır. Bu süreç; yeniden referanslama, hatalı kanal ve bölüt tespiti, düşük frekanslı sürüklenmelerin azaltılması, yüksek frekanslı gürültünün sınırlandırılması, güç hattı gürültüsünün bastırılması ve göz/kas kaynaklı bağımsız bileşenlerin ayıklanması gibi adımları içermektedir. Bu tür işlemler EEG analizinde yaygın olarak kullanılan temel ön işleme basamaklarıyla uyumludur. Özellikle bağımsız bileşen analizi ve bileşen etiketleme yaklaşımları, EEG işaretinden göz ve kas kaynaklı bozulmaların ayrıştırılmasında sıklıkla kullanılmaktadır (Delorme ve Makeig 2004, Delorme vd. 2012, Pion-Tonachini vd. 2019). Bununla birlikte EEG biyometrisi bağlamında ön işleme yalnızca işaret temizleme amacıyla değerlendirilmemelidir. Aşırı agresif temizleme, bazı bozulmaları azaltırken bireye özgü ve kararlı olabilecek bazı işaret bileşenlerini de zayıflatabilir. Bu nedenle bu tezde ham veri akışı ve temizlenmiş veri akışı birlikte değerlendirilmiş; modelin işaret kalitesi değiştiğinde nasıl davrandığı karşılaştırmalı olarak incelenmiştir.

Süzgeçleme aşamasından sonra sürekli EEG kayıtları sabit uzunluklu zaman pencerelerine ayrılmıştır. EEG işareti durağan olmayan bir yapıya sahip olduğundan, uzun süreli kaydın tamamını tek bir giriş örneği olarak kullanmak hem istatistiksel kararlılık hem de model eğitimi açısından uygun değildir. Çok uzun pencereler, farklı fizyolojik durumların ve geçici işaret değişimlerinin aynı örnek içinde karışmasına neden olabilir. Buna karşılık çok kısa pencereler, frekans çözünürlüğünü düşürerek özellikle düşük frekanslı EEG bileşenlerinin güvenilir biçimde temsil edilmesini zorlaştırabilir. Bu nedenle pencere uzunluğu belirlenirken zaman çözünürlüğü ile frekans çözünürlüğü arasındaki denge dikkate alınmıştır. Sabit uzunluklu bir pencere için frekans çözünürlüğü,

$$\Delta f = \frac{f_s}{W} = \frac{1}{T_p} \tag{3.5}$$

şeklinde ifade edilmektedir. Burada W pencere içindeki örnek sayısını ve T_p pencere süresini göstermektedir. Tez kapsamında $T_p = 4$ s ve $f_s = 1024$ Hz olarak seçildiğinden pencere uzunluğu,

$$W = f_s \times T_p = 1024 \times 4 = 4096 \tag{3.6}$$

olarak elde edilmiştir. Bu durumda frekans çözünürlüğü,

$$\Delta f = \frac{1024}{4096} = 0.25 \text{ Hz} \tag{3.7}$$

olmaktadır. Bu değer, delta, teta, alfa, beta ve gama bantlarının yanı sıra alt bantlara dayalı daha ayrıntılı spektral çözümlemelerin yapılabilmesi için uygun bir frekans çözünürlüğü sağlamaktadır. Aynı zamanda 4 saniyelik pencere uzunluğu, pratik bir biyometrik sistem açısından kabul edilebilir kısa karar süresiyle yeterli işaret içeriği arasında dengeli bir seçim sunmaktadır.

Bir bireyin $t.$ oturumunda $c.$ kanaldan elde edilen sürekli EEG işareti aşağıdaki şekilde gösterilebilir:

$$X_i^{t,c} = [x_1, x_2, \ldots, x_L] \tag{3.8}$$

Burada $X_i^{t,c}$, $i.$ bireyin $t.$ oturumunda $c.$ kanaldan elde edilen sürekli EEG işaretini; L ise toplam örnek sayısını ifade etmektedir. Bu işaret sabit uzunluklu pencerelere ayrıldığında, $m.$ zaman penceresi aşağıdaki şekilde tanımlanabilir:

$$x_{i,m}^{t,c} = [x_{1+(m-1)R}, x_{2+(m-1)R}, \ldots, x_{W+(m-1)R}] \tag{3.9}$$

Burada R pencere kayma miktarını göstermektedir. Örtüşmesiz pencereleme durumunda $R = W$ olur. Bu tezde örtüşmesiz pencereleme tercih edilmiştir. Örtüşmesiz pencereleme, aynı kayıt içerisinden türetilen örnekler arasındaki yapay benzerliği ve veri tekrarını azaltması bakımından önemlidir. Özellikle kapalı-küme biyometrik kimlik tanımlama çalışmalarında, yüksek örtüşme oranları eğitim ve test bölmeleri arasında benzer işaret parçalarının bulunma riskini artırabilir. Bu durum aynı oturum içi değerlendirmelerde başarımı olduğundan yüksek gösterebilir. Bu nedenle çalışmada, pencere sayısını artırmak ile örnekler arası bağımsızlığı korumak arasında daha temkinli bir tercih yapılarak 4 saniyelik örtüşmesiz pencereler kullanılmıştır. Sürekli bir işaretten elde edilebilecek pencere sayısı aşağıdaki şekilde hesaplanabilir:

$$M = \left\lfloor \frac{L - W}{R} \right\rfloor + 1 \tag{3.10}$$

Burada M elde edilen toplam pencere sayısını ve L işaret uzunluğunu ifade etmektedir. $\lfloor \cdot \rfloor$ sembolü, elde edilen değerin kendisine eşit veya kendisinden küçük en yakın tam sayıya yuvarlandığını göstermektedir. Böylece, işaretin sonunda tam bir pencere oluşturmaya yeterli uzunlukta olmayan kalan örnekler pencere sayısına dâhil edilmemektedir. Örtüşmesiz pencereleme durumunda adım uzunluğu pencere uzunluğuna eşit olduğundan (R=W), ifade

$$M = \left\lfloor \frac{L - W}{W} \right\rfloor + 1 \tag{3.11}$$

şeklinde sadeleşmektedir. Her oturum yaklaşık 4 dakikalık dinlenim durumu EEG kaydından oluştuğu için, 4 saniyelik pencereleme sonucunda her kanal ve her oturum için yaklaşık 60 pencere elde edilmektedir. Kayıt süresindeki küçük farklılıklar, kalite kontrol adımları ve veri kümesi içindeki işaret uzunluğu farklılıkları nedeniyle gerçek pencere sayısı katılımcı ve oturum bazında küçük değişiklikler gösterebilir. Pencereleme sonrasında her bir EEG penceresi tek kanallı zaman serisi olarak temsil edilmiştir. Bu tezin temel amaçlarından biri, çok kanallı EEG sistemlerinin yanında daha pratik, düşük donanım gereksinimli ve kullanıcı açısından daha uygulanabilir tek kanallı EEG biyometrisinin sınırlarını incelemektir. Bu nedenle 64 kanallı kayıt yapısı korunmakla birlikte, her kanal ayrı bir tek kanallı giriş olarak ele alınmıştır. Böylece modelin her bir kanal üzerinden bireye özgü örüntüleri ne ölçüde öğrenebildiği kanal bazında değerlendirilebilmiştir. Bir pencerenin model girdisi,

$$\mathbf{x}_{i,m}^{t,c} \in \mathbb{R}^{W\times 1} \tag{3.12}$$

şeklinde tanımlanmıştır. Burada $\mathbb{R}$ gerçel sayılar kümesini, $\mathbb{R}^{W\times 1}$ ise W adet gerçel değerli örnekten oluşan sütun vektörü uzayını ifade etmektedir. Bu tezde $W = 4096$ olduğundan her model girdisi,

$$\mathbf{x}_{i,m}^{t,c} \in \mathbb{R}^{4096\times 1} \tag{3.13}$$

boyutundadır. Bu yapı sayesinde aynı model mimarisi her kanal için ayrı ayrı uygulanabilmiş ve kanal bazlı başarı farklılıkları doğrudan karşılaştırılabilmiştir. Ön işleme aşamasında ayrıca genlik ölçekleme ve standartlaştırma işlemleri de değerlendirilmiştir. EEG kanalları arasında mutlak genlik farklılıkları bulunabildiğinden, derin öğrenme modelinin yalnızca ölçek farklarına duyarlı hâle gelmesini önlemek amacıyla eğitim verisinden elde edilen istatistikler kullanılarak standartlaştırma yapılabilir. Bir pencere içindeki örnekler $x[n]$ ile gösterildiğinde standartlaştırılmış işaret,

$$\tilde{x}[n] = \frac{x[n] - \mu_{\text{egitim}}}{\sigma_{\text{egitim}} + \epsilon} \tag{3.14}$$

şeklinde ifade edilebilir. Burada μ_{egitim} ve σ_{egitim} yalnızca eğitim verisinden hesaplanan ortalama ve standart sapmayı, ϵ ise sayısal kararlılık için eklenen küçük bir sabiti göstermektedir. Doğrulama ve test verilerinde aynı eğitim istatistiklerinin kullanılması, test verisine ait dağılım bilgisinin eğitim sürecine sızmasını engeller. Bu durum özellikle oturumlar arası biyometrik değerlendirmede önemlidir; çünkü ikinci oturuma ait istatistiklerin önceden kullanılması model başarısını yapay biçimde artırabilir.

Pencereleme ve tek kanallı temsil oluşturma aşamalarından sonra, kanal ve frekans alt bandı seçimi için önceki tez izleme döneminde geliştirilen istatistiksel ve geometrik ölçütlerden yararlanılmıştır. Kanal seçimi burada yalnızca en yüksek sınıflandırma doğruluğunu veren elektrodu bulma işlemi olarak değil, her bir kanal–bant kombinasyonunun sınıflar arası ayırt edicilik, sınıf içi kompaktlık ve oturumlar arası kararlılık açısından değerlendirilmesi olarak ele alınmıştır. EEG işaretinin yüksek boyutlu ve bireyler arası değişkenliği yüksek yapısı nedeniyle, hangi kanal ve frekans alt bandının biyometrik bilgi taşıdığını belirlemek model yorumlanabilirliği açısından da önemlidir. Bu amaçla merkez tabanlı ayrışma ölçütü, Calinski–Harabasz/Davies–Bouldin bileşik puanı, tek yönlü varyans analizi tabanlı η^2 etki büyüklüğü ve sınıflar arası/sınıf içi varyans oranı kullanılmıştır.

Merkez tabanlı ayrışma yaklaşımı, her bir bireyin belirli bir kanal–bant kombinasyonundaki öznitelik dağılımını sınıf merkezi üzerinden temsil etmektedir. Bir kanal–bant çifti için i. sınıfa ait merkez vektörü,

$$\boldsymbol{\mu}_i = \frac{1}{n_i} \sum_{j=1}^{n_i} \mathbf{x}_{ij} \tag{3.15}$$

şeklinde hesaplanır. Burada $\boldsymbol{\mu}_i$, i. bireye ait sınıf merkezini; n_i, ilgili bireye ait örnek sayısını; $\mathbf{x}_{ij}$ ise i. bireyin j. öznitelik vektörünü göstermektedir. İyi bir kanal–bant kombinasyonunun farklı bireylere ait merkezleri birbirinden uzaklaştırması ve aynı bireye ait örnekleri kendi sınıf merkezi etrafında kompakt tutması beklenir. Bu düşünceye dayalı merkez tabanlı ayrışma ölçütü,

$$J_{\text{merkez}} = \frac{\frac{1}{K(K-1)} \sum_{i \neq j} \|\boldsymbol{\mu}_i - \boldsymbol{\mu}_j\|_2}{\frac{1}{K} \sum_{i=1}^{K} \frac{1}{n_i} \sum_{j=1}^{n_i} \|\mathbf{x}_{ij} - \boldsymbol{\mu}_i\|_2} \tag{3.16}$$

şeklinde tanımlanabilir. Burada K sınıf sayısını göstermektedir. Pay kısmı sınıflar arası ortalama merkez uzaklığını, payda kısmı ise sınıf içi ortalama yayılımı temsil etmektedir. J_{merkez} değerinin yüksek olması, ilgili kanal–bant çiftinin bireyler arasında güçlü bir geometrik ayrışma sağladığını göstermektedir. Bu yaklaşım, en yakın merkez sınıflandırıcıları ve merkez tabanlı örüntü tanıma yöntemleriyle teorik olarak ilişkilidir (Duda vd. 2001, Hastie vd. 2009).

İkinci kanal–bant seçimi yaklaşımı Calinski–Harabasz ve Davies–Bouldin dizinlerinin birlikte kullanıldığı bileşik ayrışma puanıdır. Calinski–Harabasz dizini, sınıflar arası saçılımın sınıf içi saçı-

lıma oranını temel alır ve aşağıdaki şekilde ifade edilir:

$$CH = \frac{\mathrm{Tr}(B)/(K-1)}{\mathrm{Tr}(W)/(N-K)} \tag{3.17}$$

Burada $\mathrm{Tr}(B)$ sınıflar arası saçılım matrisinin izini, $\mathrm{Tr}(W)$ sınıf içi saçılım matrisinin izini ve N toplam örnek sayısını göstermektedir. Yüksek CH değeri, sınıf merkezlerinin birbirinden uzak ve sınıf içi dağılımların kompakt olduğunu göstermektedir (Calinski ve Harabasz 1974). Davies–Bouldin dizini ise her bir sınıfın en benzer diğer sınıfa göre ayrışma düzeyini ölçer:

$$DB = \frac{1}{K}\sum_{i=1}^{K} \max_{j \neq i} \left(\frac{s_i + s_j}{\|\boldsymbol{\mu}_i - \boldsymbol{\mu}_j\|_2} \right) \tag{3.18}$$

Burada s_i, i. sınıfın kendi içindeki ortalama yayılımını temsil etmektedir. Düşük DB değeri, sınıfların birbirinden iyi ayrıldığını ve sınıflar arası örtüşmenin sınırlı olduğunu göstermektedir (Davies ve Bouldin 1979). Bu iki ölçütün birlikte kullanılmasıyla kanal–bant çiftlerine ait bileşik ayrışma puanı,

$$J_{CH/DB} = \frac{CH}{DB} \tag{3.19}$$

şeklinde hesaplanmıştır. Bu ölçüt, yüksek sınıflar arası ayrım ve düşük sınıf içi yayılım hedeflerini birlikte dikkate almaktadır.

Üçüncü yaklaşım, tek yönlü varyans analizi temelinde hesaplanan η^2 etki büyüklüğüdür. Bu ölçüt, belirli bir kanal–bant çiftinde gözlenen toplam varyansın ne kadarının bireyler arası farklılıklardan kaynaklandığını göstermektedir. Toplam kareler toplamı,

$$SS_{\text{toplam}} = \sum_{i=1}^{K}\sum_{j=1}^{n_i}(x_{ij} - \bar{x})^2 \tag{3.20}$$

şeklinde tanımlanır. Gruplar arası kareler toplamı,

$$SS_{\text{grup arasi}} = \sum_{i=1}^{K} n_i(\bar{x}_i - \bar{x})^2 \tag{3.21}$$

ve grup içi kareler toplamı,

$$SS_{\text{grup ici}} = \sum_{i=1}^{K}\sum_{j=1}^{n_i}(x_{ij} - \bar{x}_i)^2 \tag{3.22}$$

olarak ifade edilir. Bu bileşenler arasında,

$$SS_{\text{toplam}} = SS_{\text{grup arasi}} + SS_{\text{grup ici}} \tag{3.23}$$

ilişkisi bulunmaktadır. Buna göre η^2 etki büyüklüğü,

$$\eta^2 = \frac{SS_{\text{grup arasi}}}{SS_{\text{toplam}}} \tag{3.24}$$

şeklinde hesaplanır. η^2 değerinin yüksek olması, ilgili kanal–bant kombinasyonunda gözlenen değişkenliğin büyük bölümünün bireyler arası sistematik farklılıklardan kaynaklandığını göstermektedir. Bu yönüyle η^2, yalnızca istatistiksel anlamlılığı değil, ayırt edici etkinin büyüklüğünü de değerlendiren yorumlanabilir bir ölçüt sunmaktadır (Lakens 2013).

Dördüncü kanal–bant seçimi ölçütü, sınıflar arası/sınıf içi varyans oranıdır. Bu yaklaşım, Fisher ayırt edicilik ölçütüyle ilişkili olup bir özniteliğin sınıflar arasında ne kadar değiştiğini ve aynı sınıf içinde ne kadar kararlı kaldığını birlikte değerlendirir (Fisher 1936, Fukunaga 1990). Bir kanal–bant kombinasyonu için bu oran,

$$J_{\text{var}} = \frac{\sigma^2_{\text{gruplar arasi}}}{\sigma^2_{\text{grup ici}}} \tag{3.25}$$

şeklinde tanımlanabilir. Burada $\sigma^2_{\text{gruplar arasi}}$, sınıf ortalamaları arasındaki varyansı; $\sigma^2_{\text{grup ici}}$ ise her bir sınıfın kendi içindeki varyansını temsil etmektedir. Bu oranın yüksek olması, ilgili kanal–bant çiftinde bireyler arası farklılıkların belirgin, birey içi değişkenliğin ise görece düşük olduğunu göstermektedir. EEG biyometrisi açısından bu özellik, oturumlar arasında korunabilen bireye özgü işaret örüntülerinin belirlenmesi için önemlidir.

Kanal seçimi analizlerinde her bir kanal ve frekans alt bandı için elde edilen önem puanları ilk ve ikinci oturumda ayrı ayrı hesaplanmış, ardından bu puanların oturumlar arası tutarlılığı incelenmiştir. Bu sayede yalnızca birinci oturumda yüksek ayrışma sağlayan kanal–bant çiftleri değil, ikinci oturumda da benzer ayırt ediciliği koruyan daha kararlı adaylar belirlenebilmiştir. Oturumlar arası kararlılık, $t1$ ve $t2$ oturumlarında elde edilen önem puanlarının ilişkisi üzerinden değerlendirilebilir. Bir kanal–bant çifti için ilk oturum puanı $J_{c,b}^{(t1)}$, ikinci oturum puanı $J_{c,b}^{(t2)}$ ile gösterildiğinde,

genel tutarlılık Pearson bağıntısı ile aşağıdaki şekilde hesaplanabilir:

$$\rho = \frac{\sum_{c,b}(J_{c,b}^{(t1)} - \bar{J}^{(t1)})(J_{c,b}^{(t2)} - \bar{J}^{(t2)})}{\sqrt{\sum_{c,b}(J_{c,b}^{(t1)} - \bar{J}^{(t1)})^2}\sqrt{\sum_{c,b}(J_{c,b}^{(t2)} - \bar{J}^{(t2)})^2}} \tag{3.26}$$

Burada c kanal dizinini, b frekans bandı dizinini göstermektedir. Yüksek ρ değeri, kanal–bant önem sıralamasının oturumlar arasında daha tutarlı olduğunu göstermektedir. Böyle bir değerlendirme, EEG biyometrisinde yalnızca en yüksek ayrışma gücüne sahip kanalı değil, aynı zamanda zaman içinde kararlılığını koruyan kanalı seçmek açısından önemlidir.

Sonuç olarak, bu tezde veri ön işleme, pencereleme ve tek kanallı EEG temsili üç aşamalı bir yöntemsel çerçeve olarak tasarlanmıştır. İlk aşamada ham ve temizlenmiş veri akışları ayrı ayrı ele alınarak işaret kalitesinin model başarısına etkisi değerlendirilebilir hâle getirilmiştir. İkinci aşamada EEG kayıtları 4 saniyelik örtüşmesiz pencerelere ayrılmış ve her pencere 4096×1 boyutunda tek kanallı zaman serisi olarak modellenmiştir. Üçüncü aşamada ise merkez tabanlı ayrışma, CH/DB bileşik puanı, ANOVA η^2 etki büyüklüğü ve sınıflar arası/sınıf içi varyans oranı kullanılarak kanal–bant çiftlerinin ayırt ediciliği ve oturumlar arası kararlılığı değerlendirilmiştir. Bu yapı, önerilen karma ESA–ÇY-UKSB–Dönüştürücü modelinin hem ham hem de temizlenmiş EEG verileri üzerinde tek kanallı, bant-duyarlı ve oturumlar arası genellenebilir bir kimlik tanımlama sistemi olarak sınanmasına olanak sağlamaktadır.

3.3 Birleştirilmiş Üretken Çekişmeli Ağ ve Bulanık Çıkarım Sistemi Tabanlı Gürültü Tespiti ve Giderimi Yaklaşımı

Bu tezde sunulan özgün yöntemsel katkılardan biri, EEG işaretlerinde gözlenen fizyolojik ve çevresel bozulmaların pencere düzeyinde otomatik olarak tespit edilmesi ve bozulmuş pencerelerin üretken model tabanlı bir yaklaşımla yeniden yapılandırılmasıdır. EEG işaretleri; göz kırpma, göz hareketi, alın ve yüz kası etkinliği, çene kasılması, elektrot temas değişkenliği, düşük frekanslı sürüklenme ve hat gürültüsü gibi çok sayıda bozulma kaynağından etkilenebilmektedir. Özellikle EOG kaynaklı bozulmalar çoğunlukla düşük frekanslı ve yüksek genlikli değişimler oluştururken, EMG kaynaklı bozulmalar daha düzensiz, geniş bantlı ve yüksek frekans bileşenleri içeren yapılar meydana getirebilmektedir. Bu tür bozulmalar, EEG işaretinin zamansal biçimini, spektral enerji dağılımını ve karmaşıklık yapısını değiştirerek biyometrik kimlik tanımlama modelinin bi-

reye özgü sinirsel örüntüler yerine bozulma kaynaklı geçici yapıları öğrenmesine neden olabilir.

Literatürde EEG bozulma giderimi için bağımsız bileşen analizi, dalgacık tabanlı süzgeçleme, uyarlamalı süzgeçleme, kör kaynak ayrıştırma ve derin öğrenme temelli yaklaşımlar yaygın biçimde kullanılmaktadır. Bu yaklaşımlar birçok durumda etkili olmakla birlikte, EEG biyometrisi açısından iki temel sınırlılık taşımaktadır. Birincisi, bazı yöntemler bozulmuş bölütleri doğrudan dışlamakta ve böylece kısa süreli EEG kayıtlarında kullanılabilir veri miktarını azaltmaktadır. İkincisi, klasik eşikleme veya deterministik karar yapıları, EEG gibi doğal değişkenliği yüksek ve sınır durumları fazla olan biyolojik işaretlerde belirsizliği yeterince temsil edememektedir. Oysa biyometrik kimlik tanımlama probleminde amaç yalnızca işareti temizlemek değil, aynı zamanda bireye özgü sinirsel imzayı mümkün olduğunca koruyarak işaretin model tarafından öğrenilebilir biçimde temsil edilmesini sağlamaktır. Bu nedenle bu tezde, gürültü tespiti ve gürültülü pencere yeniden yapılandırma süreçleri tek bir bütünleşik sistem içerisinde ele alınmıştır.

Önerilen yaklaşım iki temel bileşenden oluşmaktadır. İlk bileşen, EEG pencerelerinin bozulmasız, EOG kaynaklı bozulmuş veya EMG kaynaklı bozulmuş olarak değerlendirilmesini sağlayan BÇS tabanlı karar modülüdür. İkinci bileşen ise bozulmuş olduğu belirlenen pencerelerin Wasserstein ÜÇA tabanlı bir yeniden yapılandırma düzeneğiyle onarılmasıdır. BÇS modülü, işaretin belirsizlik içeren durumlarını keskin eşikler yerine üyelik dereceleriyle temsil etmekte; Wasserstein ÜÇA modülü ise gerçek EEG pencerelerinin dağılımsal özelliklerini öğrenerek bozulmuş pencerenin doğal EEG yapısına daha yakın bir biçimde yeniden oluşturulmasını hedeflemektedir. Böylece önerilen sistem, bozulmuş EEG pencerelerini tamamen atmak yerine, bu pencereleri biyometrik kimlik tanımlama sürecinde kullanılabilir hâle getirmeyi amaçlamaktadır.

Bu bütünleşik yaklaşımda, m. EEG penceresi $\mathbf{x}_{i,m}^{t,c} \in \mathbb{R}^{W\times 1}$ ile gösterilsin. Gürültü tespit modülünün amacı, her pencere için aşağıdaki karar işlevini üretmektir:

$$d_{i,m}^{t,c} = F_{\text{BÇS}}\left(\phi_{DEn}(\mathbf{x}_{i,m}^{t,c}), \phi_{LZK}(\mathbf{x}_{i,m}^{t,c}), \phi_{KOK}(\mathbf{x}_{i,m}^{t,c})\right) \tag{3.27}$$

Burada $F_{\text{BÇS}}(\cdot)$ BÇS'yi; ϕ_{DEn}, ϕ_{LZK} ve ϕ_{KOK} ise sırasıyla Dalgacık Entropisi (DEn, Wavelet Entropy: WEn), Lempel-Ziv Karmaşıklığı (LZK) ve Kök Ortalama Kare (KOK, Root Mean Square: RMS) özniteliklerini ifade etmektedir. $d_{i,m}^{t,c}$ değeri, ilgili pencerenin bozulma durumunu temsil eden bulanık karar çıktısıdır. Bu çıktı, durulaştırma işleminden sonra "bozulmasız", "EOG" veya

"EMG" sınıflarından birine atanır. Bozulmuş olarak işaretlenen pencereler Wasserstein ÜÇA tabanlı yeniden yapılandırma modülüne aktarılırken, bozulmasız pencereler doğrudan sonraki analiz aşamasına geçirilir.

Önerilen bozulma giderme yönteminin temel hedefi, EEG tabanlı kimlik tanımlama sistemlerinde bireylere özgü sinirsel imzaların, ölçüm sürecinde kaçınılmaz olarak ortaya çıkan gürültü ve bozulma etkilerinden mümkün olduğunca arındırılarak daha belirgin, kararlı ve ayırt edici bir temsil hâline getirilmesini sağlamaktır. Bu doğrultuda geliştirilen yaklaşım yalnızca işaretin zamansal ve spektral bütünlüğünü geri kazandırmayı değil, aynı zamanda bu iyileştirmenin üst seviye biyometrik tanıma başarımına olan etkisini de değerlendirmeyi hedeflemektedir. Böylece gürültü giderimi, tez kapsamında bağımsız bir işaret işleme adımı olarak değil, kapalı-küme EEG tabanlı biyometrik kimlik tanımlama sisteminin başarımını doğrudan etkileyen bütünleşik bir yöntemsel bileşen olarak ele alınmıştır.

3.3.1 Bulanık çıkarım sistemi tabanlı gürültü tespiti yaklaşımı

BÇS gürültü tespiti modülü, EEG işaretini sabit uzunluklu zaman pencereleri hâlinde analiz ederek her pencerenin bozulma içerip içermediğini belirlemek amacıyla tasarlanmıştır. Bu modülün temel gerekçesi, EEG işaretlerinde bozulma durumunun çoğu zaman keskin sınırlarla ayrılmamasıdır. Bir pencere tamamen temiz veya tamamen bozulmuş olmayabilir; göz kırpma, kas etkinliği veya geçici genlik artışı gibi olaylar pencerenin yalnızca belirli bir bölümünü etkileyebilir. Bu nedenle klasik eşikleme yöntemleri sınır durumlarda kararsız kararlar üretebilir. Bulanık mantık yaklaşımı ise giriş özniteliklerini "düşük", "orta" ve "yüksek" gibi dilsel değişkenler aracılığıyla temsil ederek belirsiz ve kademeli karar yapısını modellemeye olanak tanımaktadır.

Önerilen BÇS yapısında giriş değişkenleri olarak üç öznitelik kullanılmıştır: DEn, LZK ve KOK. Bu üç öznitelik, EEG penceresinin sırasıyla zaman-frekans enerji dağılımını, yapısal karmaşıklığını ve genlik/enerji düzeyini temsil etmektedir. DEn, bozulmanın işaret enerjisini dalgacık alt bantları arasında nasıl dağıttığını; LZK, işaret örüntüsünün ne ölçüde düzensizleştiğini; KOK ise pencere içindeki genlik artışlarını nicel olarak değerlendirmektedir. DEn, LZK ve KOK birlikte kullanıldığında, hem EOG gibi yüksek genlikli ve düşük frekans baskın bozulmalar hem de EMG gibi daha karmaşık ve geniş bantlı bozulmalar daha güvenilir biçimde ayırt edilebilmektedir.

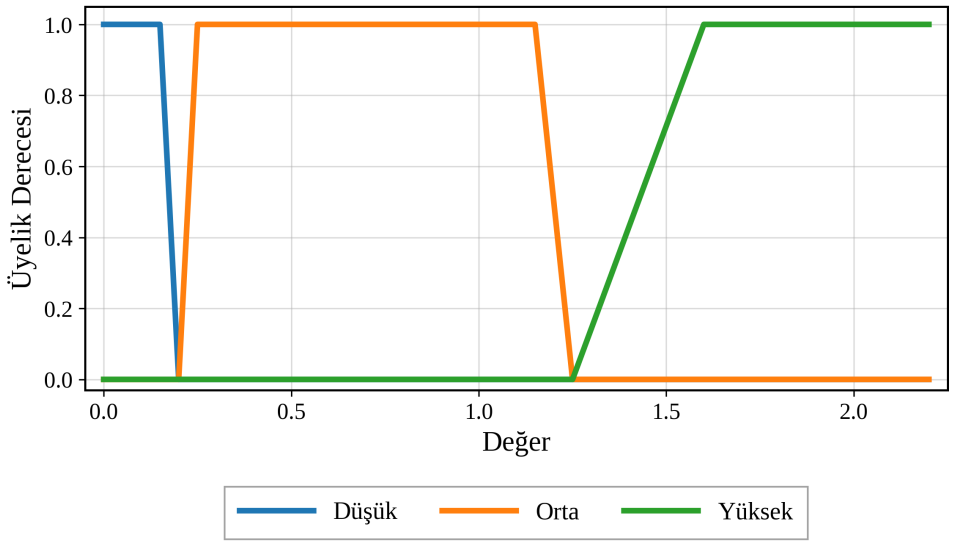

Şekil 3.4 Bulanık çıkarım sistemi üyelik işlevi: Dalgacık entropisi

Bir EEG penceresi $\mathbf{x} = [x_1, x_2, \ldots, x_W]$ ile gösterilsin. DEn hesabında öncelikle pencere ayrık dalgacık dönüşümü ile N farklı alt banda ayrılır. i. dalgacık alt bandına ait katsayılar $\mathbf{w}_i$ ile gösterildiğinde, ilgili alt bandın enerjisi aşağıdaki şekilde hesaplanabilir:

$$E_i = \sum_{k=1}^{M_i} |w_i[k]|^2 \tag{3.28}$$

Burada M_i, i. alt banttaki dalgacık katsayısı sayısını göstermektedir. Toplam enerji,

$$E_{\text{toplam}} = \sum_{j=1}^{N} E_j \tag{3.29}$$

olarak tanımlandığında, i. alt banda ait ölçeklendirilmiş enerji oranı aşağıdaki şekilde elde edilir:

$$p_i = \frac{E_i}{\sum_{j=1}^{N} E_j + \epsilon} \tag{3.30}$$

Burada ϵ, sayısal kararlılık sağlamak amacıyla kullanılan küçük bir pozitif sabittir. Bu enerji dağılımı temel alınarak DEn aşağıdaki gibi tanımlanır:

$$DEn = -\sum_{i=1}^{N} p_i \log_2(p_i + \epsilon) \tag{3.31}$$

DEn değerinin yüksek olması, işaret enerjisinin dalgacık alt bantları arasında daha dağınık ve düzensiz biçimde yayıldığını göstermektedir. EMG kaynaklı kas etkinliği genellikle geniş frekans

bandına yayılan düzensiz enerji artışları oluşturduğundan DEn değerini yükseltebilir. EOG kaynaklı bozulmalar ise daha çok düşük frekans ve yüksek genlik etkisiyle enerji dağılımını değiştirebilir. Bu nedenle DEn, EEG pencerelerinde doğal ritmik yapının bozulup bozulmadığını değerlendirmek için etkili bir öznitelik olarak kullanılmıştır. Şekil 3.4'te USYM veri kümesi kullanılarak üyelik sınırları belirlenen DEn üyelik işlevini paylaşılmıştır.

LZK, bir işaretin algoritmik düzensizliğini ve tekrar etmeyen örüntü yapısını ölçmek için kullanılan doğrusal olmayan bir karmaşıklık ölçütüdür. EEG gibi biyolojik işaretlerde, düzenli ve ritmik örüntüler daha düşük karmaşıklık değerleri üretirken, düzensiz ve rastgeleliğe daha yakın örüntüler daha yüksek karmaşıklık değerleri oluşturabilmektedir. LZK hesabı için sürekli değerli EEG penceresi öncelikle ikili bir diziye dönüştürülür. Bu tezde ikilileştirme işlemi, pencere ortalaması referans alınarak aşağıdaki şekilde ifade edilebilir:

$$s[n] = \begin{cases} 1, & x[n] \geq \bar{x} \\ 0, & x[n] < \bar{x} \end{cases} \tag{3.32}$$

Burada $\bar{x}$, ilgili EEG penceresinin ortalamasını ve $x[n]$, pencere içindeki n. örnek değerini göstermektedir. Elde edilen $s[n]$ ikili dizisi üzerinde Lempel-Ziv ayrıştırması uygulanarak farklı alt dizilerin sayısı $c(W)$ olarak belirlenir. Uzunluğu W olan bir dizi için ölçekleme terimi,

$$b(W) = \frac{W}{\log_2(W)} \tag{3.33}$$

şeklinde tanımlanır. Buna göre ölçeklendirilmiş LZK değeri,

$$LZK = \frac{c(W)}{b(W)} \tag{3.34}$$

olarak hesaplanır. Yüksek LZK değeri, EEG penceresinde tekrar eden örüntülerin azaldığını ve işaretin daha düzensiz bir yapıya dönüştüğünü göstermektedir. EMG kaynaklı kas etkinliği, kısa süreli ve düzensiz yüksek frekanslı bileşenler oluşturduğundan LZK değerinde artışa neden olabilir. EOG kaynaklı bozulmalar ise her zaman LZK değerini EMG kadar artırmayabilir; ancak göz hareketi veya göz kırpmanın pencere içindeki biçimine bağlı olarak işaretin yapısal düzenini değiştirebilir. Bu nedenle LZK, özellikle EMG kaynaklı ve karmaşık bozulmaların tespitinde tamamlayıcı bir gösterge olarak kullanılmıştır. Şekil 3.5'te USYM veri kümesi kullanılarak üyelik sınırları belirlenen LZK üyelik işlevini paylaşılmıştır.

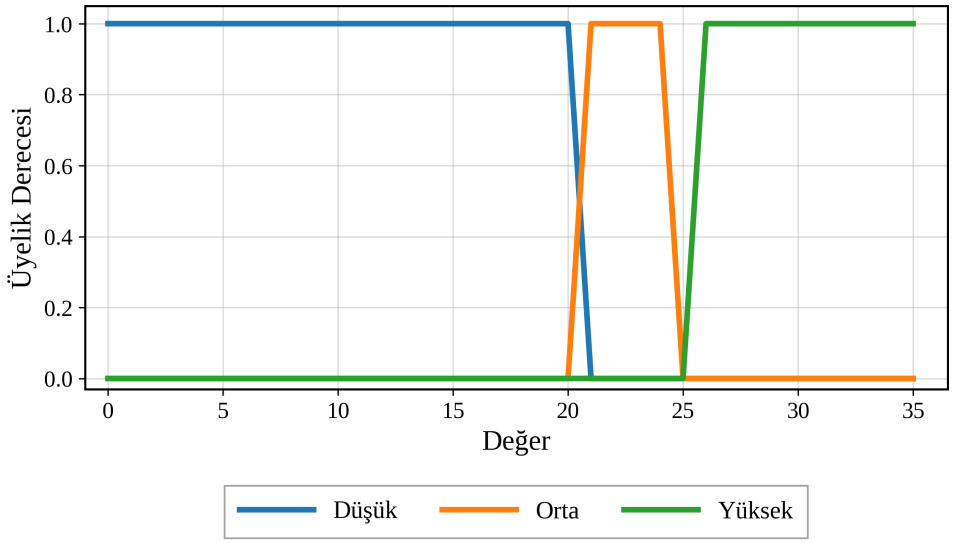

Şekil 3.5 Bulanık çıkarım sistemi üyelik işlevi: Lempel-Ziv karmaşıklığı

KOK, EEG penceresinin ortalama enerji/genlik düzeyini temsil eden temel bir istatistiksel ölçüttür. Özellikle EOG kaynaklı göz kırpma ve göz hareketleri, EEG işaretinde ani ve yüksek genlikli sapmalara neden olabildiğinden KOK değerini belirgin biçimde artırabilir. Benzer şekilde güçlü kas etkinliği de pencere içindeki enerji düzeyini yükseltebilir. Uzunluğu W olan bir EEG penceresi için KOK değeri aşağıdaki şekilde hesaplanır:

$$KOK = \sqrt{\frac{1}{W}\sum_{n=1}^{W} x^2[n]} \tag{3.35}$$

KOK, işaretin faz bilgisi veya örüntü karmaşıklığı hakkında doğrudan bilgi vermese de, genlik temelli bozulmaların tespitinde güçlü ve yorumlanabilir bir ölçüttür. Bu nedenle KOK değeri, özellikle yüksek genlikli EOG bileşenleri ile bazı EMG bozulmalarının belirlenmesinde BÇS girişlerinden biri olarak kullanılmıştır. Şekil 3.6'da USYM veri kümesi kullanılarak üyelik sınırları belirlenen KOK üyelik işlevini paylaşılmıştır. BÇS modülünde giriş değişkenlerinin her biri öncelikle bulanıklaştırma işleminden geçirilmiştir. Bulanıklaştırma, sayısal bir öznitelik değerinin bir veya birden fazla dilsel kümeye belirli üyelik dereceleriyle atanmasıdır. Genel bir giriş değişkeni z için A bulanık kümesine ait üyelik derecesi $\mu_A(z) \in [0, 1]$ aralığında tanımlanır. Tez kapsamında DEn ve LZK için "Düşük", "Orta" ve "Yüksek" olmak üzere üç üyelik işlevi; KOK için ise "Düşük" ve "Yüksek" olmak üzere iki üyelik işlevini kullanılmıştır. Bu yapı, DEn ve LZK özniteliklerinin işaret düzensizliği ve karmaşıklığını daha kademeli biçimde temsil etmesi; KOK özniteliğinin ise daha çok genlik artışı odaklı ikili bir ayırt edicilik sunması nedeniyle tercih edilmiştir.

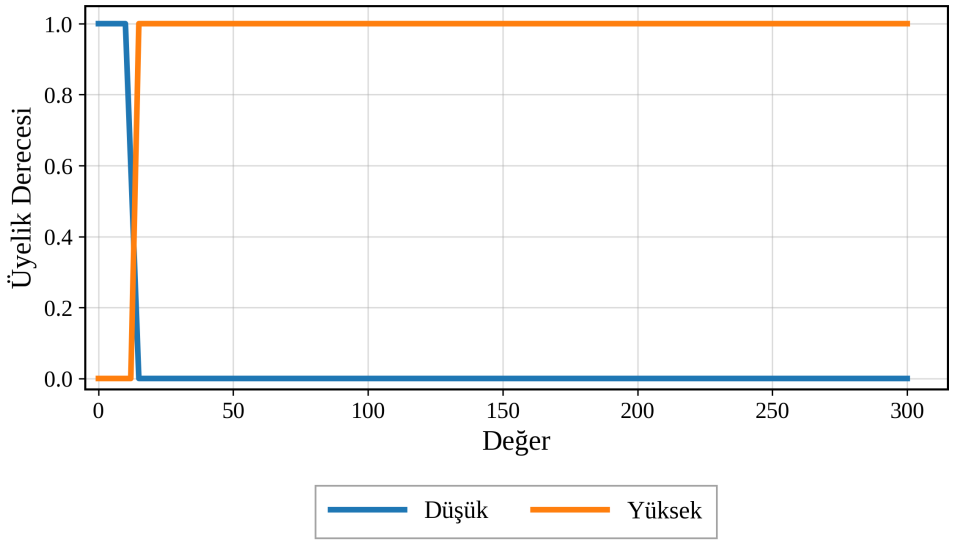

Şekil 3.6 Bulanık çıkarım sistemi üyelik işlevi: Kök ortalama kare

Üçgensel veya yamuksal bir üyelik işlevi kullanıldığında, bir z giriş değeri için üçgensel üyelik derecesi genel olarak aşağıdaki şekilde yazılabilir:

$$\mu_A(z) = \max\left(\min\left(\frac{z-a}{b-a}, \frac{c-z}{c-b}\right), 0\right) \tag{3.36}$$

Burada a, b ve c üyelik işlevinin sırasıyla sol sınırını, tepe noktasını ve sağ sınırını temsil etmektedir. Bu yapı sayesinde bir EEG penceresi, örneğin DEn açısından aynı anda belirli ölçüde "Orta" ve belirli ölçüde "Yüksek" kümelerine ait olabilir. Bu durum, keskin eşikleme yaklaşımlarında kaybolan belirsizlik bilgisinin karar düzneğine aktarılmasını sağlar.

Bulanık kural tabanı, LZK, DEn ve KOK özniteliklerinin üyelik düzeyleri arasındaki ilişkiyi kullanarak her pencere için bozulma sınıfı üretmektedir. Bu çalışmada LZK ve DEn için üçer, KOK için ikişer üyelik düzeyi tanımlandığından toplam kural sayısı, 18 ($N_R = 3 \times 3 \times 2 = 18$) olarak elde edilmiştir. Her bir kural, "Eğer–ise" yapısında tanımlanmıştır. Örneğin LZK ve DEn değerlerinin düşük, KOK değerinin düşük olduğu durumda işaretin bozulmasız olduğu kabul edilirken, LZK ve DEn değerleri düşük olsa bile KOK değerinin yüksek olması pencerenin EOG kaynaklı bozulma içerdiğine işaret etmektedir. Bu durum, EOG bozulmalarının çoğu zaman düşük frekanslı fakat yüksek genlikli yapısıyla uyumludur. Buna karşılık DEn veya LZK değerlerinin yüksek olduğu, özellikle KOK değerinin de yüksek seyrettiği durumlarda pencere çoğunlukla EMG kaynaklı bozulma olarak değerlendirilmiştir. Çünkü EMG bozulmaları işaretin hem enerji dağılımını hem de karmaşıklık yapısını bozarak düzensiz ve geniş bantlı örüntüler oluşturabilmektedir.

Mamdani tipi bulanık çıkarım yapısında, r. kuralın ateşleme gücü giriş üyelik derecelerinin birleşimiyle hesaplanır. Örneğin r. kural için DEn, LZK ve KOK girişlerine ait üyelik dereceleri sırasıyla $\mu_{A_r}(DEn)$, $\mu_{B_r}(LZK)$ ve $\mu_{C_r}(KOK)$ olsun. Bu durumda kural ateşleme gücü aşağıdaki şekilde ifade edilebilir:

$$\alpha_r = \min\left[\mu_{A_r}(DEn), \mu_{B_r}(LZK), \mu_{C_r}(KOK)\right] \tag{3.37}$$

Burada α_r, r. kuralın ilgili EEG penceresi için ne ölçüde etkinleştiğini göstermektedir. Tüm kuralların çıktıları, çıkış üyelik işlevleri üzerinde birleştirilerek toplam bulanık karar kümesi elde edilir. Çıkış değişkeni u ile gösterildiğinde, birleştirilmiş çıkış üyelik işlevi aşağıdaki şekilde yazılabilir:

$$\mu_{\text{cikis}}(u) = \max_{r=1,\ldots,N_R}\left[\min\left(\alpha_r, \mu_{D_r}(u)\right)\right] \tag{3.38}$$

Burada $\mu_{D_r}(u)$, r. kuralın sonuç kısmında tanımlanan çıkış üyelik işlevini temsil etmektedir. Son aşamada bulanık çıkışın tek bir sayısal karar değerine dönüştürülmesi için ağırlık merkezi tabanlı durulaştırma yöntemi kullanılabilir:

$$u^* = \frac{\int u\,\mu_{\text{cikis}}(u)\,du}{\int \mu_{\text{cikis}}(u)\,du} \tag{3.39}$$

Elde edilen u^* değeri, tanımlanan çıkış aralıklarına göre bozulmasız, EOG veya EMG sınıflarından birine atanır. Bu yapı, özellikle sınır durumlarda birden fazla kuralın aynı anda kısmi olarak etkinleşmesine izin vererek, gürültü kararının daha esnek ve bağlama duyarlı biçimde verilmesini sağlar. Şekil 3.7'de USYM veri kümesi kullanılarak üyelik sınırları belirlenen çıkış üyelik işlevi paylaşılmıştır.

Çizelge 3.2'te verilen kural tabanı, DEn, LZK ve KOK özniteliklerinin birlikte yorumlanmasına dayalı bağlama duyarlı bir karar düzeneği sunmaktadır. KOK değerinin yüksek, DEn ve LZK değerlerinin düşük olduğu durumlarda sistem daha çok EOG kaynaklı bozulmaya yönelirken; DEn veya LZK değerlerinin yüksek olduğu durumlarda, özellikle KOK değerinin de yüksek olması hâlinde, sistem EMG kaynaklı bozulma kararına yönelmektedir. Bu yapı, EOG ve EMG bozulmalarının fizyolojik ve spektral karakteristikleriyle uyumludur. Buna karşılık bazı sınır durumlarda tek bir özniteliğin yüksek olması doğrudan bozulma kararı üretmemekte, diğer özniteliklerle birlikte değerlendirilerek karar verilmektedir. Bu durum, BÇS'nin yalnızca tekil eşiklere dayalı değil, öznitelikler arası ilişkiyi de dikkate alan bir karar düzeneği sunduğunu göstermektedir.

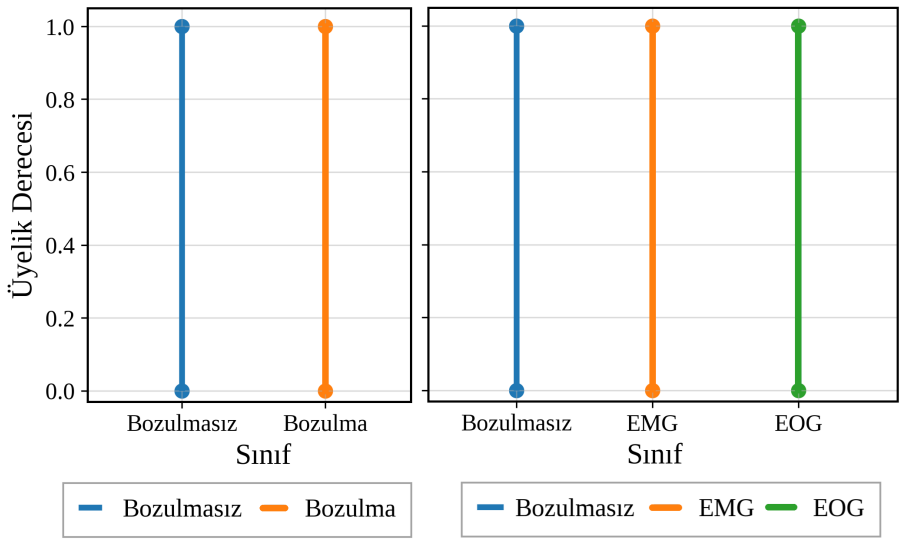

Şekil 3.7 Bulanık çıkarım sistemi üyelik işlevi: Çıkış

BÇS modülünün çıktısı, Wasserstein ÜÇA tabanlı yeniden yapılandırma modülü için bir tetikleyici işlevi görmektedir. Eğer bir pencere bozulmasız olarak sınıflandırılırsa, bu pencere doğrudan sonraki modelleme aşamasına aktarılır. Eğer pencere EOG veya EMG kaynaklı bozulma olarak sınıflandırılırsa, pencere yeniden yapılandırma modülüne gönderilir. Bu durumda genel onarım işlemi aşağıdaki parçalı işlevle ifade edilebilir:

$$\hat{\mathbf{x}}_{i,m}^{t,c} = \begin{cases} \mathbf{x}_{i,m}^{t,c}, & d_{i,m}^{t,c} = \text{bozulmasız} \\ G(\mathbf{z}, \mathbf{q}_{i,m}^{t,c}), & d_{i,m}^{t,c} \in \{\text{EOG}, \text{EMG}\} \end{cases} \tag{3.40}$$

Burada $\hat{\mathbf{x}}_{i,m}^{t,c}$ onarım sonrası EEG penceresini, $G(\cdot)$ üretici ağı, $\mathbf{z}$ gizil gürültü vektörünü ve $\mathbf{q}_{i,m}^{t,c}$ ise pencereye ait koşullandırıcı bilgiyi temsil etmektedir. Böylece BÇS modülü yalnızca sınıflandırıcı bir karar üretmekle kalmamakta, aynı zamanda üretken yeniden yapılandırma sürecinin hangi pencereler üzerinde çalışacağını da belirlemektedir. Bu yapı, gürültü içeren pencerelerin veri kümesinden çıkarılması yerine biyolojik olarak tutarlı biçimde yeniden oluşturulmasını hedeflediğinden, kısa süreli EEG kayıtlarında veri kaybını azaltmakta ve biyometrik kimlik tanımlama modeline daha dengeli bir giriş temsili sunmaktadır.

Çizelge 3.2 Her pencerenin bozulma içerip içermediğine karar vermek için kullanılan bulanık kural tabanı

Kural	**Kural Açıklaması**
R_1	Eğer LZK "Düşük", DEn "Düşük" ve KOK "Düşük" ise "bozulmasız"
R_2	Eğer LZK "Düşük", DEn "Düşük" ve KOK "Yüksek" ise "bozulma" – "EOG"
R_3	Eğer LZK "Düşük", DEn "Orta" ve KOK "Düşük" ise "bozulmasız"
R_4	Eğer LZK "Düşük", DEn "Orta" ve KOK "Yüksek" ise "bozulma" – "EOG"
R_5	Eğer LZK "Düşük", DEn "Yüksek" ve KOK "Düşük" ise "bozulma" – "EMG"
R_6	Eğer LZK "Düşük", DEn "Yüksek" ve KOK "Yüksek" ise "bozulma" – "EMG"
R_7	Eğer LZK "Orta", DEn "Düşük" ve KOK "Düşük" ise "bozulmasız"
R_8	Eğer LZK "Orta", DEn "Düşük" ve KOK "Yüksek" ise "bozulma" – "EOG"
R_9	Eğer LZK "Orta", DEn "Orta" ve KOK "Düşük" ise "bozulmasız"
R_{10}	Eğer LZK "Orta", DEn "Orta" ve KOK "Yüksek" ise "bozulma" – "EOG"
R_{11}	Eğer LZK "Orta", DEn "Yüksek" ve KOK "Düşük" ise "bozulmasız"
R_{12}	Eğer LZK "Orta", DEn "Yüksek" ve KOK "Yüksek" ise "bozulma" – "EMG"
R_{13}	Eğer LZK "Yüksek", DEn "Düşük" ve KOK "Düşük" ise "bozulma" – "EMG"
R_{14}	Eğer LZK "Yüksek", DEn "Düşük" ve KOK "Yüksek" ise "bozulma" – "EMG"
R_{15}	Eğer LZK "Yüksek", DEn "Orta" ve KOK "Düşük" ise "bozulmasız"
R_{16}	Eğer LZK "Yüksek", DEn "Orta" ve KOK "Yüksek" ise "bozulma" – "EMG"
R_{17}	Eğer LZK "Yüksek", DEn "Yüksek" ve KOK "Düşük" ise "bozulma" – "EMG"
R_{18}	Eğer LZK "Yüksek", DEn "Yüksek" ve KOK "Yüksek" ise "bozulma" – "EMG"

3.3.2 Wasserstein üretken çekişmeli ağ tabanlı gürültü giderimi yaklaşımı

BÇS tabanlı gürültü tespit modülü tarafından EOG veya EMG kaynaklı bozulma içerdiği belirlenen EEG pencereleri, bu tezde klasik "tespit et–çıkar" yaklaşımıyla veri kümesinden elenmemiştir. Bunun yerine, bozulmuş pencereler Wasserstein ÜÇA tabanlı bir yeniden yapılandırma modülü aracılığıyla onarılarak sonraki kimlik tanımlama iş akışına geri kazandırılmıştır. Bu tasarım tercihi, özellikle EEG tabanlı biyometrik kimlik tanımlama probleminde önemli bir gerekçeye dayanmaktadır. EEG kayıtları kısa süreli olduğunda veya kişi başına sınırlı sayıda pencere bulunduğunda, bozulmalı pencerelerin doğrudan dışlanması, kullanılabilir örnek sayısını azaltmakta, sınıf dağılımını bozmakta ve bazı bireylerin eğitim/test temsilini zayıflatabilmektedir. Bu durum, özellikle oturumlar arası değerlendirme senaryolarında modelin genellenebilirliğini olumsuz etkileyebilir.

Dolayısıyla burada amaç, bozulmuş pencereleri tamamen devre dışı bırakmak değil, bu pencerelerdeki biyometrik açıdan ayırt edici zamansal ve spektral örüntüleri mümkün olduğunca koruyarak istatistiksel olarak tutarlı bir EEG penceresi yeniden elde etmektir.

Bu kapsamda önerilen üretken model, bozulmuş EEG penceresini yalnızca gürültüden arındırılmış bir işaret olarak değil, aynı zamanda gerçek temiz EEG dağılımıyla uyumlu bir örnek olarak üretmeyi hedeflemektedir. Geleneksel bant sınırlı süzgeçleme, uyarlamalı süzgeçleme veya sert eşikleme yöntemleri belirli frekans bileşenlerini bastırmada etkili olabilse de, EEG penceresindeki zamansal yapı biçimi, bireye özgü ritmik yapı, kısa süreli faz ilişkileri ve alt bant enerji dağılımı gibi özelliklerin aynı anda korunmasını her zaman garanti etmez. Wasserstein ÜÇA yaklaşımı ise temiz EEG pencerelerinin dağılımsal özelliklerini öğrenerek, bozulmuş örnekleri bu dağılıma yaklaştırmaya çalışmaktadır. Böylece gürültü giderimi, yalnızca işaret düzeyinde bozulma bastırma işlemi değil, aynı zamanda temiz EEG örnek uzayına doğru veri güdümlü bir yeniden yapılandırma problemi olarak ele alınmıştır.

ÜÇA, bir üretici ağ G ve bir ayrımcı/eleştirmen ağ D olmak üzere iki temel bileşenden oluşmaktadır. Üretici ağ, gizil değişken uzayından örneklenen $\mathbf{z} \sim P_z$ gürültü vektörünü veya bozulmuş pencereye ait koşul bilgisini kullanarak gerçek veri dağılımına benzer örnekler üretmeye çalışır. Ayrımcı veya eleştirmen ağ ise kendisine verilen örneğin gerçek temiz EEG dağılımından mı yoksa üretici tarafından oluşturulan dağılımdan mı geldiğini ayırt etmeyi amaçlar. Klasik ÜÇA formülasyonunda bu süreç aşağıdaki minimaks problem ile ifade edilmektedir:

$$\min_G \max_D V(D,G) = \mathbb{E}_{\mathbf{x}\sim P_r}[\log D(\mathbf{x})] + \mathbb{E}_{\mathbf{z}\sim P_z}\left[\log\left(1 - D(G(\mathbf{z}))\right)\right] \tag{3.41}$$

Burada P_r, gerçek temiz EEG pencerelerinin dağılımını; P_z, gizil uzay dağılımını; $G(\mathbf{z})$, üretici tarafından oluşturulan örneği ve $D(\cdot)$, ayrımcının gerçeklik olasılığına karşılık gelen çıktısını göstermektedir. Bu yapı kuramsal olarak güçlü olmakla birlikte, klasik ÜÇA eğitiminde Jensen–Shannon ayrışımına dayalı örtük eniyileme nedeniyle eğim (gradyan) doygunluğu, eğitim kararsızlığı ve kip çökmesi (mode collapse) gibi sorunlar ortaya çıkabilmektedir. EEG gibi yüksek değişkenlik içeren ve temiz/bozulmuş dağılımlar arasında karmaşık geçişlerin bulunduğu biyolojik işaretlerde bu sorunlar daha belirgin hâle gelebilmektedir.

Bu nedenle tezde, klasik ÜÇA yapısı yerine Wasserstein uzaklığına dayalı Wasserstein ÜÇA yak-

laşımı tercih edilmiştir. Wasserstein ÜÇA, gerçek veri dağılımı P_r ile üretici dağılımı P_g arasındaki farkı Wasserstein-1 uzaklığı veya Yer Taşıyıcı Mesafesi (Earth Mover's Distance) üzerinden ölçmektedir. Bu uzaklık, bir dağılımı diğerine dönüştürmek için gerekli en düşük taşıma maliyetini ifade eder. Gerçek EEG pencereleri ile üretici tarafından oluşturulan onarılmış pencereler arasındaki dağılımsal uyumun ölçülmesi açısından bu yaklaşım, örnekler arası geometrik yakınlığı dikkate aldığı için yeniden yapılandırma problemlerinde daha anlamlı bir öğrenme işareti sağlayabilmektedir. Wasserstein-1 uzaklığı aşağıdaki şekilde tanımlanır:

$$W(P_r, P_g) = \inf_{\gamma \in \Pi(P_r, P_g)} \mathbb{E}_{(\mathbf{x}, \tilde{\mathbf{x}}) \sim \gamma} \left[\|\mathbf{x} - \tilde{\mathbf{x}}\|_2 \right] \tag{3.42}$$

Burada $\Pi(P_r, P_g)$, marjinal dağılımları sırasıyla P_r ve P_g olan tüm ortak dağılımlar kümesini; γ, bu kümeden seçilen ortak dağılımı; $\mathbf{x}$, gerçek temiz EEG penceresini ve $\tilde{\mathbf{x}}$, üretici tarafından oluşturulan pencereyi temsil etmektedir. Denklem 3.42, üretici dağılımının gerçek temiz EEG dağılımına taşınması için gerekli minimum beklenen maliyeti ifade etmektedir. Burada dikkat edilmesi gereken nokta, $\Pi(P_r, P_g)$ gösteriminin ortak dağılımlar kümesini ifade etmesidir; bu nedenle çarpım sembolü $\prod(P_r, P_g)$ yerine $\Pi(P_r, P_g)$ kullanılmalıdır.

Wasserstein uzaklığının doğrudan hesaplanması pratik olarak zor olduğundan, Wasserstein ÜÇA eğitiminde çoğunlukla Kantorovich–Rubinstein ikili formu kullanılır. Bu forma göre Wasserstein-1 uzaklığı,

$$W(P_r, P_g) = \sup_{\|D\|_L \leq 1} \left[\mathbb{E}_{\mathbf{x} \sim P_r}[D(\mathbf{x})] - \mathbb{E}_{\tilde{\mathbf{x}} \sim P_g}[D(\tilde{\mathbf{x}})] \right] \tag{3.43}$$

şeklinde ifade edilir. Burada D, klasik ÜÇA'daki olasılıksal ayrımcıdan farklı olarak bir eleştirmen işlevi olarak çalışır ve örneklere gerçeklik olasılığı değil, skaler bir uygunluk puanı atar. $\|D\|_L \leq 1$ koşulu, eleştirmenin 1-Lipschitz sürekliliğe sahip olması gerektiğini belirtir. Eleştirmen, gerçek EEG pencerelerine daha yüksek, üretilmiş pencerelere daha düşük puan vermeyi öğrenirken; üretici, ürettiği örneklerin eleştirmen tarafından gerçek EEG örnekleri gibi puanlanmasını sağlamaya çalışır. Bu yapı, klasik ÜÇA'ya kıyasla daha kararlı eğimler sağlayarak üretici dağılımının gerçek veri dağılımına daha düzenli biçimde yaklaşmasına yardımcı olur.

Wasserstein ÜÇA yaklaşımında en kritik noktalardan biri, eleştirmen işlevinin 1-Lipschitz koşulunu sağlamasıdır. İlk Wasserstein ÜÇA formülasyonunda bu koşul ağırlık kırpma yöntemiyle sağlanmaya çalışılmıştır. Ancak ağırlık kırpma, eleştirmenin temsil kapasitesini sınırlayabilmekte ve eniyileme sürecinde istenmeyen davranışlara neden olabilmektedir. Bu nedenle tezde, Lipschitz kı-

sıtı eğim cezası terimiyle sağlanan Wasserstein ÜÇA-GC (WGAN-GP) yaklaşımı benimsenmiştir. Bu yaklaşımda eleştirmen kaybı aşağıdaki şekilde tanımlanabilir:

$$\mathcal{L}_D = \mathbb{E}_{\tilde{\mathbf{x}}\sim P_g}[D(\tilde{\mathbf{x}})] - \mathbb{E}_{\mathbf{x}\sim P_r}[D(\mathbf{x})] + \lambda \mathbb{E}_{\hat{\mathbf{x}}\sim P_{\hat{\mathbf{x}}}}\left[(\|\nabla_{\hat{\mathbf{x}}} D(\hat{\mathbf{x}})\|_2 - 1)^2\right] \tag{3.44}$$

Burada λ, eğim cezasının ağırlığını belirleyen düzenlileştirme katsayısıdır. $\hat{\mathbf{x}}$ ise gerçek ve üretilmiş örnekler arasındaki doğrusal ara örneklerden elde edilir:

$$\hat{\mathbf{x}} = \epsilon \mathbf{x} + (1-\epsilon)\tilde{\mathbf{x}}, \qquad \epsilon \sim U(0,1) \tag{3.45}$$

Denklem 3.44'deki eğim cezası terimi, eleştirmenin girişe göre eğim normunu 1'e yakın tutmayı amaçlamaktadır. Böylece 1-Lipschitz koşulu pratik olarak daha kararlı biçimde sağlanmakta ve eğitim sırasında ortaya çıkabilecek keskin karar yüzeyleri, osilasyonlar ve kararsız yakınsama davranışları azaltılmaktadır. Üretici kaybı ise eleştirmen puanını artırmaya yönelik olarak aşağıdaki şekilde tanımlanır:

$$\mathcal{L}_G^{adv} = -\mathbb{E}_{\tilde{\mathbf{x}}\sim P_g}[D(\tilde{\mathbf{x}})] \tag{3.46}$$

Bu kayıp, üreticinin eleştirmen tarafından daha gerçekçi olarak değerlendirilen EEG pencereleri üretmesini sağlar. Başka bir ifadeyle üretici, yalnızca bozulmuş pencereyi yumuşatmaya veya süzgeçlemeye değil, gerçek temiz EEG dağılımına yakın örnekler üretmeye yönlendirilir.

Bu tezde kullanılan onarım modülü koşullu bir üretken yapı olarak kurgulanmıştır. Çünkü amaç rastgele temiz EEG örnekleri üretmek değil, bozulmuş olarak tespit edilen belirli bir pencereye karşılık gelen onarılmış pencereyi elde etmektir. Bu nedenle üretici yalnızca gizil gürültü vektörü $\mathbf{z}$ ile değil, aynı zamanda bozulmuş pencere ve bağlamsal bilgi vektörü ile koşullandırılmıştır. Bozulmuş EEG penceresi $\mathbf{x}^{boz}$, koşul vektörü $\mathbf{c}$ ve gizil vektör $\mathbf{z}$ ile gösterildiğinde üretici çıktısı aşağıdaki şekilde yazılabilir:

$$\tilde{\mathbf{x}} = G(\mathbf{x}^{boz}, \mathbf{z}, \mathbf{c}) \tag{3.47}$$

Burada $\tilde{\mathbf{x}}$, üretici tarafından oluşturulan onarılmış EEG penceresidir. Koşul vektörü $\mathbf{c}$, BÇS tarafından üretilen bozulma türü bilgisini, kanal bilgisini, pencere düzeyinde özet istatistikleri veya frekans bandı bilgisini içerebilir. Böylece üretici, tüm bozulmuş pencereler için aynı tipte bir düzeltme uygulamak yerine, pencerenin bozulma türüne ve bağlamına duyarlı bir yeniden yapılandırma gerçekleştirmeye yönlendirilir. Koşullu üretim yapısı, onarımın rastgele sentezden ayrılmasını ve bozulmuş pencereye ait korunabilir işaret bileşenlerinin daha fazla dikkate alınmasını sağlar.

Onarım probleminin doğası gereği, yalnızca çekişmeli kayıp kullanmak yeterli değildir. Çekişmeli kayıp, üretilen pencerelerin genel temiz EEG dağılımına benzemesini teşvik eder; ancak üretilen pencerenin özgün bozulmuş pencereyle zamansal olarak ilişkili kalmasını tek başına garanti etmez. Bu nedenle üretici eğitiminde yeniden yapılandırma kaybı da kullanılmıştır. Temiz referans pencere $\mathbf{x}^{temiz}$ ile üretici çıktısı $\tilde{\mathbf{x}}$ arasındaki zamansal yakınlık aşağıdaki L_1 kaybı ile ifade edilebilir:

$$\mathcal{L}_{rec} = \mathbb{E}_{\mathbf{x}^{temiz},\tilde{\mathbf{x}}} \left[\|\mathbf{x}^{temiz} - \tilde{\mathbf{x}}\|_1 \right] \tag{3.48}$$

L_1 kaybı, işaretin örnek düzeyindeki biçimini korumaya yardımcı olur ve L_2 kaybına kıyasla aşırı yumuşatma etkisini azaltabilir. Bununla birlikte EEG işaretinin yalnızca zaman bölgesindeki örnek değerleri değil, frekans bölgesindeki enerji dağılımı da biyometrik açıdan önemlidir. Bu nedenle üretici çıktısının spektral özelliklerini korumak amacıyla ek bir spektral tutarlılık kaybı tanımlanabilir. Kısa zamanlı Fourier dönüşümü veya GSY temelli bir gösterim $\mathcal{S}(\cdot)$ ile gösterildiğinde spektral kayıp,

$$\mathcal{L}_{spec} = \mathbb{E} \left[\left\| \log\left(\mathcal{S}(\mathbf{x}^{temiz}) + \epsilon\right) - \log\left(\mathcal{S}(\tilde{\mathbf{x}}) + \epsilon\right) \right\|_1 \right] \tag{3.49}$$

şeklinde ifade edilebilir. Burada ϵ, logaritmik dönüşümde sayısal kararlılığı sağlamak için kullanılan küçük pozitif sabittir. Spektral kayıp, özellikle EEG biyometrisinde önemli olan delta, teta, alfa, beta ve gama bantlarındaki enerji dağılımının korunmasına katkı sağlar. Bu yapı, üretici ağın yalnızca zaman bölgesi görünümünü değil, aynı zamanda frekans bölgesindeki biyometrik açıdan anlamlı bileşenleri de dikkate almasını sağlar.

Buna ek olarak, onarılmış EEG penceresinin biyometrik kimlik tanımlama açısından ayırt edici temsili koruması da önemlidir. Bu nedenle üretici eğitiminde, önceden eğitilmiş veya eş zamanlı öğrenilen bir temsil çıkarıcı $\Phi(\cdot)$ üzerinden temsil tutarlılığı kaybı tanımlanabilir. Bu kayıp,

$$\mathcal{L}_{id} = \mathbb{E} \left[\left\| \Phi(\mathbf{x}^{temiz}) - \Phi(\tilde{\mathbf{x}}) \right\|_2^2 \right] \tag{3.50}$$

şeklinde yazılabilir. Burada $\Phi(\cdot)$, EEG penceresinden biyometrik açıdan ayırt edici temsil çıkaran bir ara katman veya öznitelik çıkarıcıyı ifade etmektedir. Bu kayıp terimi, onarılmış pencerenin yalnızca temiz işarete benzemesini değil, aynı zamanda kimlik tanımlama açısından önemli olan temsil uzayında da temiz örneğe yakın kalmasını hedeflemektedir. Böylece gürültü giderimi süreci, biyometrik bilgi korunumu ile daha doğrudan ilişkilendirilmiş olur.

Bu bileşenler bir araya getirildiğinde üretici ağ için toplam kayıp işlevi aşağıdaki şekilde tanımlanabilir:

$$\mathcal{L}_G = \mathcal{L}_G^{adv} + \alpha\mathcal{L}_{rec} + \beta\mathcal{L}_{spec} + \delta\mathcal{L}_{id} \tag{3.51}$$

Burada α, β ve δ, sırasıyla yeniden yapılandırma kaybı, spektral tutarlılık kaybı ve biyometrik temsil koruma kaybının katkısını belirleyen ağırlık katsayılarıdır. $\mathcal{L}_G^{adv}$, üretilen pencerelerin temiz EEG dağılımıyla uyumunu; $\mathcal{L}_{rec}$, zaman bölgesi benzerliğini; $\mathcal{L}_{spec}$, frekans bölgesi tutarlılığını; $\mathcal{L}_{id}$ ise biyometrik temsil korunumu hedefini desteklemektedir. Bu çok bileşenli kayıp yapısı, EEG gürültü giderim probleminin yalnızca görsel/zamansal işaret benzerliğiyle sınırlı olmadığını, aynı zamanda spektral ve kimlik ayırt ediciliği açısından da değerlendirilmesi gerektiğini göstermektedir.

Eğitim sürecinde eleştirmen ve üretici ardışık olarak güncellenmektedir. Öncelikle gerçek temiz EEG pencereleri $\mathbf{x}^{temiz}$, bozulmuş pencereler $\mathbf{x}^{boz}$, koşul vektörü $\mathbf{c}$ ve gizil vektör $\mathbf{z}$ kullanılarak üretici çıktısı $\tilde{\mathbf{x}}$ elde edilir. Daha sonra eleştirmen, gerçek temiz pencereler ile üretilmiş pencereleri puanlayarak Denklem 3.44'de verilen kayıp işlevi üzerinden güncellenir. Eleştirmen birkaç adım güncellendikten sonra üretici, Denklem 3.51'de verilen toplam kayıp işlevini en küçükleyecek şekilde eniyilenir. Bu süreç, üretici dağılımı P_g'nin gerçek temiz EEG dağılımı P_r'ye yaklaşmasını ve bozulmuş pencerelerden daha tutarlı onarılmış pencereler elde edilmesini hedeflemektedir.

BÇS ve Wasserstein ÜÇA modüllerinin birlikte çalışması aşağıdaki parçalı karar-onarım işlevi ile özetlenebilir:

$$\hat{\mathbf{x}}_{i,m}^{t,c} = \begin{cases} \mathbf{x}_{i,m}^{t,c}, & F_{\text{BÇS}}(\mathbf{x}_{i,m}^{t,c}) = \text{bozulmasız} \\ G(\mathbf{x}_{i,m}^{t,c}, \mathbf{z}, \mathbf{c}), & F_{\text{BÇS}}(\mathbf{x}_{i,m}^{t,c}) \in \{\text{EOG}, \text{EMG}\} \end{cases} \tag{3.52}$$

Burada $\hat{\mathbf{x}}_{i,m}^{t,c}$, nihai olarak sınıflandırıcı modele aktarılacak EEG penceresini göstermektedir. Eğer pencere BÇS tarafından bozulmasız olarak değerlendirilirse, pencere değiştirilmeden korunur. Eğer pencere EOG veya EMG kaynaklı bozulma olarak işaretlenirse, Wasserstein ÜÇA tabanlı üretici tarafından yeniden yapılandırılır. Böylece önerilen sistemde gürültü tespiti ve gürültü giderimi birbirinden kopuk iki ayrı işlem olarak değil, aynı karar akışı içerisinde birbirini tamamlayan iki modül olarak ele alınmıştır.

Önerilen yeniden yapılandırma yaklaşımında, bozulma tespitinin sert bir veri eleme kararına dönüşmemesi özellikle önemlidir. Çünkü EEG biyometrisinde pencere eleme işlemi, kişi başına dü-

şen örnek sayısının azalmasına, bazı sınıfların diğerlerine göre daha fazla veri kaybetmesine ve oturumlar arası değerlendirmelerde sınıf temsillerinin dengesizleşmesine neden olabilir. Bu durum, modelin belirli bireyler için daha az temsil öğrenmesine ve genel başarımın veri dağılımı kaynaklı biçimde etkilenmesine yol açabilir. Wasserstein ÜÇA tabanlı onarım yöntemi ise bozulmuş pencereleri tamamen dışlamak yerine, bu pencereleri temiz veri dağılımına yaklaştırarak modelin daha dengeli bir eğitim ve test temsiliyle çalışmasına katkıda bulunur. Bu açıdan önerilen yaklaşım, yalnızca işaret kalitesini artıran bir ön işleme adımı değil, aynı zamanda sınıf dağılımını ve pencere düzeyi veri bütünlüğünü koruyan bir biyometrik sistem bileşeni olarak değerlendirilmektedir.

Bu yöntemin önemli bir yönü, onarım sürecinde "kayıpsız geri kazanım" gibi mutlak bir iddia ortaya koymamasıdır. EEG bozulmaları, özellikle güçlü EOG veya EMG bozulmaları söz konusu olduğunda, işaretin bazı bileşenlerini geri döndürülemez biçimde maskeleyebilir. Bu nedenle önerilen yaklaşımın hedefi, bozulmuş pencereyi orijinal temiz işaretin birebir aynısına dönüştürmek değil, biyometrik açıdan anlamlı zamansal ve spektral örüntüleri mümkün olduğunca koruyan, temiz EEG dağılımıyla uyumlu ve sınıflandırıcı model için kullanılabilir bir temsil üretmektir. Bu bakış açısı, EEG gürültü giderimini yalnızca işaret yeniden yapılandırma (rekonstrüksiyon) problemi olmaktan çıkararak, kimlik ayırt ediciliğini koruyan dağılımsal yeniden yapılandırma problemi olarak konumlandırmaktadır.

Sonuç olarak, bu tez kapsamında geliştirilen Wasserstein ÜÇA tabanlı gürültü giderimi yaklaşımı; BÇS tarafından tespit edilen EOG ve EMG kaynaklı bozulmuş EEG pencerelerinin veri kümesinden çıkarılması yerine, koşullu üretici ağ yardımıyla yeniden yapılandırılmasına dayanmaktadır. Wasserstein ÜÇA-GC yapısı, Wasserstein uzaklığı ve eğim cezası aracılığıyla daha kararlı bir çekişmeli eğitim süreci sunarken; yeniden yapılandırma, spektral tutarlılık ve biyometrik temsil koruma kayıpları onarılmış işaretin hem fizyolojik hem de kimlik tanımlama açısından anlamlı özelliklerini korumaya katkıda bulunmaktadır. Bu nedenle önerilen yaklaşım, EEG tabanlı biyometrik kimlik tanımlama sistemlerinde gürültüye dayanıklılığı artırmayı, veri kaybını azaltmayı ve oturumlar arası değerlendirme koşullarında daha kararlı temsil öğrenimini desteklemeyi amaçlayan bütünleşik bir ön işleme ve veri iyileştirme bileşeni olarak değerlendirilmiştir.

3.4 Önerilen Karma ESA–ÇY-UKSB–Dönüştürücü Model Mimarisi

Bu tezde, tek kanallı EEG pencerelerinden bireye özgü ayırt edici örüntülerin öğrenilmesi ve kapalı-küme kimlik tanımlama senaryosunda sınıflandırılması amacıyla karma bir derin öğrenme mimarisi geliştirilmiştir. Önerilen model, ESA, ÇY-UKSB ve Dönüştürücü tabanlı dikkat düzeneğini bütünleşik bir yapı altında birleştirmektedir. Bu nedenle model, metnin devamında karma ESA–ÇY-UKSB–Dönüştürücü modeli olarak adlandırılmıştır. Önceki bölümlerde tanımlandığı üzere, model girdisi i. bireyin t. oturumunda c. kanaldan elde edilen m. tek kanallı EEG penceresidir. USYM veri kümesinde kullanılan pencere süresi 4 saniye, örnekleme frekansı 1024 Hz ve pencere uzunluğu 4096 örnek olduğundan, model girdisi aşağıdaki biçimde ifade edilmektedir:

$$\mathbf{x}_{i,m}^{t,c} \in \mathbb{R}^{W\times 1} \tag{3.53}$$

Bu gösterimde i birey indisini, m pencere indisini, t kayıt oturumunu ve c EEG kanalını göstermektedir. Kapalı-küme kimlik tanımlama senaryosunda iki oturumu bulunan $N = 42$ birey kayıtlı kimlik kümesini oluşturduğundan, modelin çıktı boyutu 42 sınıfa karşılık gelmektedir.

Önerilen mimarinin temel amacı, tek kanallı EEG penceresi içerisindeki kısa süreli yerel örüntüleri, pencere boyunca oluşan ardışıl bağımlılıkları ve uzun menzilli dikkat ilişkilerini birlikte modellemektir. Bu kapsamda ESA bileşeni yerel ve çok ölçekli zamansal örüntüleri çıkarmakta, ÇY-UKSB bileşeni bu örüntülerin ileri ve geri yönlü zamansal bağlamını öğrenmekte, Dönüştürücü bileşeni ise pencere içerisindeki ayırt edici zaman bölgelerini dikkat deüzeneğiyle ağırlıklandırmaktadır. Böylece model, tek bir EEG penceresinden hem yerel hem de bütünsel zamansal bilgi içeren bir biyometrik temsil üretmektedir.

$$\hat{\mathbf{p}}_{i,m}^{t,c} = f_{\Theta}\left(\mathbf{x}_{i,m}^{t,c}\right) \tag{3.54}$$

Burada f_{Θ}, öğrenilebilir değişkenleri Θ ile gösterilen önerilen karma modeli; $\hat{\mathbf{p}}_{i,m}^{t,c}$ ise ilgili EEG penceresi için kayıtlı bireyler üzerinde üretilen olasılık vektörünü ifade etmektedir. Modelin bileşenleri dikkate alındığında bu yapı aşağıdaki şekilde ayrıntılandırılabilir:

$$\hat{\mathbf{p}}_{i,m}^{t,c} = f_{sinif}\left(f_{dikkat}\left(f_{cyuksb}\left(f_{esa}\left(\mathbf{x}_{i,m}^{t,c}\right)\right)\right)\right) \tag{3.55}$$

Bu ifadede f_{esa} çok ölçekli evrişimsel öznitelik çıkarıcıyı, f_{cyuksb} çift yönlü zamansal bağımlılık modelleyiciyi, f_{dikkat} Dönüştürücü tabanlı dikkat bloğunu ve f_{sinif} sınıflandırıcı başlığı göstermek-

tedir. Model çıktısı olan olasılık vektörü aşağıdaki biçimdedir:

$$\hat{\mathbf{p}}_{i,m}^{t,c} = [\hat{p}_{i,m,1}^{t,c}, \hat{p}_{i,m,2}^{t,c}, \ldots, \hat{p}_{i,m,N}^{t,c}] \tag{3.56}$$

Burada $\hat{p}_{i,m,r}^{t,c}$, ilgili EEG penceresinin r. kayıtlı bireye ait olma olasılığını göstermektedir. Ana deneysel senaryoda $N = 42$ olduğundan, her pencere için 42 boyutlu bir olasılık dağılımı elde edilmektedir.

3.4.1 Çok Ölçekli Evrişimsel Öznitelik Çıkarımı

EEG işareti farklı frekans aralıklarında ve farklı zaman ölçeklerinde ortaya çıkan sinirsel salınımları içermektedir. Bu nedenle önerilen modelin ilk aşamasında, tek kanallı EEG penceresinden çok ölçekli yerel örüntüler çıkaran paralel evrişimsel dallar kullanılmıştır. Bu dallar, farklı çekirdek uzunlukları sayesinde EEG işaretinin farklı zamansal çözünürlüklerdeki örüntülerine duyarlı öznitelikler üretmektedir. Bir frekans bandına karşılık gelen yaklaşık evrişim çekirdeği uzunluğu aşağıdaki şekilde tanımlanabilir:

$$K_b = 2 \left\lfloor \frac{f_s}{2f_b} \right\rfloor + 1 \tag{3.57}$$

Burada K_b, b. frekans bandı için kullanılan çekirdek uzunluğunu ve f_b, ilgili bandın temsil edici frekansını göstermektedir. Çekirdek uzunluğunun tek sayı olarak belirlenmesi, zaman ekseninde merkezlenmiş süzgeçleme yapılmasını kolaylaştırmaktadır. Bu çalışmada çok ölçekli ESA bloğu delta, teta, alfa, beta ve gama bantlarını temsil eden paralel dallardan oluşmaktadır:

$$\mathcal{B} = \{\delta, \theta, \alpha, \beta, \gamma\} \tag{3.58}$$

Her bant dalı, giriş EEG penceresi üzerinde tek boyutlu evrişim işlemi uygulayarak ilgili ölçeğe duyarlı öznitelikler üretmektedir. b. bant dalının çıktısı genel olarak şu şekilde ifade edilebilir:

$$\mathbf{h}_b = \phi\left(\mathbf{x}_{i,m}^{t,c} * \mathbf{w}_b + \mathbf{b}_b\right), \quad b \in \mathcal{B} \tag{3.59}$$

Burada $\mathbf{w}_b$ ilgili bant dalına ait öğrenilebilir evrişim çekirdeğini, $\mathbf{b}b$ sapma (bias) terimini ve $\phi(\cdot)$ doğrusal olmayan etkinleştirme işlevini göstermektedir. Her dalda evrişim işleminden sonra yığın standartlaştırması (Batch normalization), etkinleştirme, seyrelme ve havuzlama adımları uygulan-

maktadır. Bu işlem aşağıdaki şekilde özetlenebilir:

$$\mathbf{h}_b = \text{Havuzlama}\left(\text{Seyreltme}\left(\phi\left(\text{YS}\left(\text{Evrişim}_{K_b}\left(\mathbf{x}_{i,m}^{t,c}\right)\right)\right)\right)\right) \tag{3.60}$$

Bu ifadede YS yığın standartlaştırmasını, Evrişim_{K_b} ise K_b çekirdek uzunluğuna sahip tek boyutlu evrişim işlemini göstermektedir. Paralel dallardan elde edilen öznitelikler kanal ekseninde birleştirilerek çok ölçekli temsil oluşturulur:

$$\mathbf{H}_{ESA} = \mathbf{h}_\delta \oplus \mathbf{h}_\theta \oplus \mathbf{h}_\alpha \oplus \mathbf{h}_\beta \oplus \mathbf{h}_\gamma \tag{3.61}$$

Burada $\oplus$, özniteliklerin kanal ekseninde birleştirilmesini göstermektedir. Böylece farklı frekans aralıklarına duyarlı evrişimsel dallardan elde edilen bilgiler tek bir ortak temsil altında toplanmaktadır.

Zaman bölgesindeki çok ölçekli evrişimsel dallara ek olarak, frekans bölgesi bilgisini modele aktarmak amacıyla spektral temsil dalı da kullanılmıştır. Bir EEG penceresinin ayrık Fourier dönüşümü aşağıdaki şekilde ifade edilebilir:

$$X[k] = \sum_{n=0}^{W-1} x[n] \exp\left(-j\frac{2\pi kn}{W}\right), \quad k = 0, 1, \ldots, W-1 \tag{3.62}$$

Burada $X[k]$, k. frekans bileşenini göstermektedir. Spektral dalda büyüklük spektrumu kullanılarak ek bir öznitelik temsili elde edilir:

$$\mathbf{h}_F = \phi\left(|\mathbf{X}| * \mathbf{w}F + \mathbf{b}_F\right) \tag{3.63}$$

Zaman bölgesi dalları ve spektral dal birleştirilerek nihai çok ölçekli öznitelik temsili elde edilir:

$$\mathbf{H}_{\text{co}} = \mathbf{H} * ESA \oplus \mathbf{h}_F \tag{3.64}$$

Burada $\mathbf{H}_{\text{co}}$, çok ölçekli birleşik öznitelik haritasını göstermektedir. Bu yapı, EEG penceresindeki hem zaman bölgesi örüntülerinin hem de frekans bölgesi bileşenlerinin aynı model içerisinde temsil edilmesini sağlamaktadır.

Çok ölçekli dallardan gelen özniteliklerin kimlik tanımlama açısından katkısı aynı düzeyde olma-

yabilir. Bu nedenle birleşik öznitelik haritası üzerinde yeniden ağırlıklandırma düzeneği kullanılmıştır. Birleşik öznitelik haritası $\mathbf{H}_{\text{co}} \in \mathbb{R}^{T' \times C}$ olarak tanımlandığında, her öznitelik kanalı için küresel ortalama havuzlama ile bir kanal tanımlayıcısı hesaplanır:

$$a_c = \frac{1}{T'} \sum_{t=1}^{T'} H_{\text{co}}(t, c), \quad c = 1, 2, \ldots, C \tag{3.65}$$

Burada T' havuzlama sonrası zaman adımı sayısını, C öznitelik kanalı sayısını ve a_c ilgili kanalın özet değerini göstermektedir. Bu kanal tanımlayıcıları kullanılarak öznitelik ağırlıkları elde edilir:

$$\mathbf{s} = \sigma\left(\mathbf{W}_2 \phi\left(\mathbf{W}_1 \mathbf{a}\right)\right) \tag{3.66}$$

Burada $\mathbf{s}$ öğrenilen kanal ağırlıklarını, $\sigma(\cdot)$ sigmoid işlevini, $\mathbf{W}1$ ve $\mathbf{W}2$ ise öğrenilebilir ağırlık matrislerini göstermektedir. Yeniden ağırlıklandırılmış öznitelik haritası şu şekilde elde edilir:

$$\tilde{\mathbf{H}}_{\text{co}}(t, c) = s_c \cdot \mathbf{H}_{\text{co}}(t, c) \tag{3.67}$$

Bu düzenek, modelin kimlik tanımlama açısından daha ayırt edici öznitelik kanallarına daha yüksek ağırlık vermesini, daha az bilgilendirici bileşenlerin etkisini ise azaltmasını sağlamaktadır.

3.4.2 ÇY-UKSB ve Dönüştürücü ile Zamansal Bağlamın Modellenmesi

Çok ölçekli ESA bloğu, EEG penceresinden yerel ve bant ilişkili öznitelikleri çıkarmaktadır. Ancak EEG işaretindeki biyometrik bilgi yalnızca yerel örüntülerle sınırlı değildir; bu örüntülerin pencere içerisindeki ardışıl düzeni de bireye özgü bilgi taşıyabilir. Bu nedenle yeniden ağırlıklandırılmış çok ölçekli öznitelik haritası, önce ÇY-UKSB katmanına aktarılmıştır:

$$\tilde{\mathbf{H}}_{\text{co}} = [\tilde{\mathbf{h}}_1, \tilde{\mathbf{h}}_2, \ldots, \tilde{\mathbf{h}}_{T'}], \quad \tilde{\mathbf{h}}_t \in \mathbb{R}^C \tag{3.68}$$

Burada $\tilde{\mathbf{h}}_t$, t. zaman adımına ait çok ölçekli öznitelik vektörünü göstermektedir. Bu sıralı öznitelik dizisi ÇY-UKSB katmanına aktarılır. UKSB hücresinin temel işleyişi aşağıdaki kapı düzenekleriyle ifade edilebilir:

$$\mathbf{f}_t = \sigma\left(\mathbf{W} * f[\mathbf{h} * t-1, \mathbf{x}_t] + \mathbf{b}_f\right) \tag{3.69}$$

$$\mathbf{i}_t = \sigma\left(\mathbf{W} * i[\mathbf{h} * t-1, \mathbf{x}_t] + \mathbf{b}_i\right) \tag{3.70}$$

$$\tilde{\mathbf{c}}_t = \tanh\left(\mathbf{W} * c[\mathbf{h} * t-1, \mathbf{x}_t] + \mathbf{b}_c\right) \tag{3.71}$$

$$\mathbf{c}_t = \mathbf{f} * t \odot \mathbf{c} * t-1 + \mathbf{i}_t \odot \tilde{\mathbf{c}}_t \tag{3.72}$$

$$\mathbf{o}_t = \sigma\left(\mathbf{W} * o[\mathbf{h} * t-1, \mathbf{x}_t] + \mathbf{b}_o\right) \tag{3.73}$$

$$\mathbf{h}_t = \mathbf{o}_t \odot \tanh\left(\mathbf{c}_t\right) \tag{3.74}$$

Denklemlerde $\mathbf{f}_t$ unutma kapısını, $\mathbf{i}_t$ giriş kapısını, $\mathbf{o}_t$ çıkış kapısını, $\mathbf{c}_t$ hücre durumunu, $\mathbf{h}_t$ ise gizli durum vektörünü göstermektedir. ÇY-UKSB yapısında aynı işlem ileri ve geri zaman yönlerinde ayrı ayrı gerçekleştirilir. Bu nedenle t. zaman adımı için çift yönlü temsil aşağıdaki şekilde elde edilir:

$$\mathbf{h}_t^{CY} = \overrightarrow{\mathbf{h}}_t \oplus \overleftarrow{\mathbf{h}}_t \tag{3.75}$$

Burada $\overrightarrow{\mathbf{h}}_t$ ileri yönlü UKSB çıktısını, $\overleftarrow{\mathbf{h}}_t$ ise geri yönlü UKSB çıktısını göstermektedir. Tüm zaman adımları için elde edilen ÇY-UKSB temsili aşağıdaki şekilde ifade edilir:

$$\mathbf{H}_{CY} = [\mathbf{h}_1^{CY}, \mathbf{h}_2^{CY}, \ldots, \mathbf{h}_{T'}^{CY}] \tag{3.76}$$

ÇY-UKSB çıktısı daha sonra Dönüştürücü tabanlı çok başlıklı öz-dikkat bloğuna aktarılır. Öz-dikkat düzeneğinde sorgu, anahtar ve değer matrisleri şu şekilde hesaplanır:

$$\mathbf{Q} = \mathbf{H}_{CYUKSB}\mathbf{W}^Q, \quad \mathbf{K} = \mathbf{H}_{CYUKSB}\mathbf{W}^K, \quad \mathbf{V} = \mathbf{H}_{CYUKSB}\mathbf{W}^V \tag{3.77}$$

Burada $\mathbf{Q}$, $\mathbf{K}$ ve $\mathbf{V}$ sırasıyla sorgu, anahtar ve değer matrislerini göstermektedir. Ölçeklendirilmiş noktasal çarpım dikkat düzeneği aşağıdaki şekilde tanımlanır:

$$\text{Dikkat}\left(\mathbf{Q}, \mathbf{K}, \mathbf{V}\right) = \text{softmax}\left(\frac{\mathbf{Q}\mathbf{K}^T}{\sqrt{d_k}}\right)\mathbf{V} \tag{3.78}$$

Burada d_k, anahtar vektörlerinin boyutunu göstermektedir. Bu yapı, EEG penceresi içerisindeki zaman adımları arasındaki ilişkileri öğrenmekte ve kimlik tanımlama açısından daha ayırt edici olan zaman bölgelerini daha güçlü temsil etmektedir. Çok başlıklı dikkat düzeneğinde bu işlem birden fazla dikkat başlığı için paralel olarak yürütülür:

$$\text{Baslik}_r = \text{Dikkat}\left(\mathbf{Q}_r, \mathbf{K}_r, \mathbf{V}_r\right), \quad r = 1, 2, \ldots, H \tag{3.79}$$

Başlık çıktıları birleştirilerek nihai dikkat temsili elde edilir:

$$\mathbf{H}_{\text{dikkat}} = \text{Birlestir}\left(\text{baslik}_1, \text{baslik}_2, \ldots, \text{baslik}_H\right) \mathbf{W}^O \tag{3.80}$$

Burada H dikkat başlığı sayısını, $\mathbf{W}^O$ ise çıktı dönüşüm matrisini göstermektedir. Bu yapı, EEG penceresindeki farklı zaman ilişkilerinin ve farklı öznitelik alt uzaylarının eş zamanlı olarak değerlendirilmesine olanak tanımaktadır.

Dönüştürücü bloğu sonrasında elde edilen temsil, sabit boyutlu bir biyometrik vektöre dönüştürülür. Bu amaçla küresel ortalama havuzlama uygulanabilir:

$$\mathbf{g}_{i,m}^{t,c} = \frac{1}{T'} \sum_{t=1}^{T'} \mathbf{H}_{\text{dikkat}}(t) \tag{3.81}$$

Burada $\mathbf{g}_{i,m}^{t,c}$, ilgili tek kanallı EEG penceresini temsil eden sabit boyutlu biyometrik özellik vektörüdür. Bu vektör, sınıflandırıcı başlığına aktarılarak kayıtlı bireyler üzerinde olasılıksal kimlik kararı üretilmektedir.

3.4.3 Olasılıksal Sınıflandırıcı Çıktısı ve Kimlik Karar Düzeneği

Kapalı-küme kimlik tanımlama senaryosunda her birey ayrı bir sınıf olarak tanımlandığından, sınıflandırıcı katmanının çıktı boyutu kayıtlı birey sayısına eşittir. Önerilen modelde $\mathbf{g}_{i,m}^{t,c}$ biyometrik temsil vektörü tam bağlantılı sınıflandırıcı katmanına aktarılır ve ham sınıf puanları elde edilir:

$$\mathbf{z}_{i,m}^{t,c} = \mathbf{W} * s\mathbf{g}_{i,m}^{t,c} + \mathbf{b} * s \tag{3.82}$$

Burada $\mathbf{W}s$ sınıflandırıcı ağırlık matrisini, $\mathbf{b}s$ sapma vektörünü ve $\mathbf{z}_{i,m}^{t,c}$ ham sınıf puanlarını göstermektedir. Ham puan vektörü aşağıdaki biçimdedir:

$$\mathbf{z}_{i,m}^{t,c} = [z_{i,m,1}^{t,c}, z_{i,m,2}^{t,c}, \ldots, z_{i,m,N}^{t,c}], \tag{3.83}$$

Bu ham puanlar *softmax* işlevi ile olasılık dağılımına dönüştürülmektedir:

$$\hat{p}_{i,m,r}^{t,c} = \frac{\exp(z_{i,m,r}^{t,c})}{\sum_{j=1}^{N} \exp(z_{i,m,j}^{t,c})} \tag{3.84}$$

Böylece her EEG penceresi için kayıtlı bireyler üzerinde bir olasılık vektörü elde edilir:

$$\hat{\mathbf{p}}_{i,m}^{t,c} = [\hat{p}_{i,m,1}^{t,c}, \hat{p}_{i,m,2}^{t,c}, \ldots, \hat{p}_{i,m,N}^{t,c}], \quad \sum_{i=1}^{N} \hat{p}_{i,m,r}^{t,c} = 1 \tag{3.85}$$

Pencere düzeyi nihai kimlik kararı, en yüksek olasılığa sahip sınıfın seçilmesiyle verilir:

$$\hat{y}_{i,m}^{t,c} = \arg \max_{i \in 1,2,\ldots,N} \hat{p}_{i,m,r}^{t,c} \tag{3.86}$$

Bu karar düzeneği, kapalı-küme kimlik tanımlama yapısıyla uyumludur; çünkü model her test penceresini kayıtlı bireylerden biriyle eşleştirmektedir. Bununla birlikte, modelin olasılık vektörü üretmesi yalnızca birinci-sıra tahmini değil, aday sıralama başarısını ve kişi düzeyi karar birleştirme yöntemlerini de değerlendirmeye olanak sağlamaktadır.

Modelin eğitiminde kapalı-küme çok sınıflı sınıflandırma yapısına uygun olarak çapraz entropi kaybı kullanılmıştır. Gerçek kimlik etiketi tek-sıcak kodlanmış biçimde $\mathbf{y}_{i,m}$ ile gösterildiğinde, bir EEG penceresi için kayıp değeri şu şekilde hesaplanır:

$$\mathcal{L}_{CE} = -\sum_{i=1}^{N} y_{i,m,r} \log\left(\hat{p}_{i,m,r}^{t,c}\right) \tag{3.87}$$

Burada $y_{i,m,r}$, ilgili pencerenin r. sınıfa ait olup olmadığını gösteren tek-sıcak kodlanmış gerçek etikettir. Gerçek sınıf için bu değer 1, diğer sınıflar için 0 olmaktadır.

Pencere düzeyinde elde edilen olasılık çıktıları, kişi düzeyi karar üretimi için de kullanılabilmektedir. Aynı bireye ait M_i adet test penceresi bulunduğunda, ortalama olasılık vektörü aşağıdaki şekilde hesaplanır:

$$\bar{\mathbf{p}}_i = \frac{1}{M_i} \sum_{m=1}^{M_i} \hat{\mathbf{p}}_{i,m}^{t,c} \tag{3.88}$$

Kişi düzeyi nihai karar ise ortalama olasılık vektörü üzerinden verilir:

$$\hat{y}_i^{birey} = \arg \max_{i \in 1,2,\ldots,N} \bar{p}_{i,r} \tag{3.89}$$

Bu yaklaşım, tek bir EEG penceresinde ortaya çıkabilecek geçici gürültü veya kararsız tahminlerin etkisini azaltmakta ve biyometrik sistemin uygulamaya daha yakın karar davranışını değerlendirmeye olanak sağlamaktadır. Önerilen karma ESA–ÇY-UKSB–Dönüştürücü modeli; çok ölçekli

evrişimsel öznitelik çıkarımı, çift yönlü zamansal bağımlılık modelleme, dikkat temelli uzun menzilli ilişki öğrenme ve olasılıksal sınıflandırıcı çıktı yapısını bir araya getirmektedir. Bu yapı, tek kanallı EEG pencerelerinden bireye özgü ayırt edici temsillerin öğrenilmesini ve bu temsillerin kapalı-küme oturumlar arası kimlik tanımlama probleminde değerlendirilmesini sağlamaktadır.

3.5 DEHB Tabanlı Üst Değişken Eniyilemesi

Derin öğrenme modellerinin başarısı, yalnızca mimari yapıya değil, aynı zamanda üst değişkenlerin uygun biçimde belirlenmesine de bağlıdır. Öğrenme oranı, yığın boyutu, seyrelme oranı, evrişimsel süzgeç sayısı, çekirdek ölçek katsayısı, ÇY-UKSB gizli birim sayısı, Dönüştürücü başlık sayısı, Dönüştürücü katman sayısı, tam bağlantılı katman boyutu ve ağırlık bozunumu gibi üst değişkenler modelin yakınsama davranışını, genellenebilirliğini ve aşırı öğrenmeye karşı dayanıklılığını doğrudan etkilemektedir. EEG tabanlı biyometrik kimlik tanımlama problemi, oturumlar arası değişkenlik ve tek kanallı işaretten ayırt edici bilgi çıkarma gereksinimi nedeniyle üst değişken seçimine özellikle duyarlıdır. Bu nedenle önerilen karma ESA–ÇY-UKSB–Dönüştürücü modelinin üst değişkenleri DEHB algoritması ile eniyilenmiştir.

DEHB, Diferansiyel Evrim ve Hiperbant yaklaşımlarını birleştiren çok bütçeli bir üst değişken eniyileme yöntemidir (Awad vd. 2021). Hiperbant bileşeni, çok sayıda aday yapılandırmayı düşük eğitim bütçelerinde hızlı biçimde sınayarak başarısız adayları erken aşamada elemektedir. Diferansiyel Evrim bileşeni ise başarılı aday yapılandırmalar etrafında yönlendirilmiş bir arama gerçekleştirerek üst değişken uzayının daha verimli keşfedilmesini sağlamaktadır. Bu yapı, her aday modelin tam eğitim bütçesiyle baştan sona eğitilmesini gerektirmediğinden, derin öğrenme modelleri için hesaplama maliyetini azaltan etkili bir eniyileme çerçevesi sunmaktadır.

Bu çalışmada üst değişken eniyileme problemi, doğrulama kaybını en aza indiren üst değişken yapılandırmasının bulunması olarak tanımlanmıştır. EEG örneklerini göstermek için önceki bölümlerde $\mathbf{x}_{i,m}^{t,c}$ kullanıldığından, burada üst değişken vektörü karışıklığı önlemek amacıyla $\boldsymbol{\lambda}$ ile gösterilmiştir. üst değişken arama uzayı Λ olmak üzere, en iyi yapılandırma şu şekilde tanımlanabilir:

$$\lambda^* = \arg\min_{\lambda \in *} \mathcal{J}\left(\lambda; \mathcal{D}_{egitim}, \mathcal{D}_{dogrulama}, b\right) \tag{3.90}$$

Denklem 3.90'da $\boldsymbol{\lambda}^*$ en iyi üst değişken yapılandırmasını, $\boldsymbol{\lambda}$ aday üst değişken vektörünü, Λ üst değişken arama uzayını, $\mathcal{D}$egitim eğitim kümesini, $\mathcal{D}$dogrulama doğrulama kümesini ve b eğitim bütçesini göstermektedir. Burada bütçe, aday modelin kaç eğitim turu veya ne kadar kaynakla değerlendirileceğini ifade etmektedir.

Amaç işlevi, doğrulama kümesi üzerinde hesaplanan kayıp değerine göre tanımlanmıştır:

$$\mathcal{J}\left(\lambda; \mathcal{D}_{egitim}, \mathcal{D}_{dogrulama}, b\right) = \mathcal{L}_{dogrulama}\left(f_{\Theta(\lambda,b)}; \mathcal{D}_{dogrulama}\right) \tag{3.91}$$

Denklem 3.91'de $f_{\Theta(\boldsymbol{\lambda},b)}$, $\boldsymbol{\lambda}$ üst değişken yapılandırması ve b bütçesi altında eğitilen karma ESA–ÇY-UKSB–Dönüştürücü modelini göstermektedir. $\mathcal{L}_{\text{dogrulama}}$ ise modelin doğrulama kümesindeki kayıp değeridir. Bu çalışmada doğrulama kümesi yalnızca eğitim oturumundan ayrılmıştır. Böylece test oturumu, model seçimi ve üst değişken ayarı sürecine dahil edilmemiştir. Bu tercih, oturumlar arası değerlendirmede ikinci oturuma ait bilginin eğitim sürecine sızmasını engellemek açısından önemlidir.

DEHB sürecinde her aday üst değişken yapılandırması bir vektör olarak ele alınır:

$$\lambda_q = [\lambda_{q,1}, \lambda_{q,2}, \ldots, \lambda_{q,D}] \tag{3.92}$$

Denklem 3.92'de $\boldsymbol{\lambda}_q$, q. aday üst değişken yapılandırmasını; D ise eniyilenen üst değişken sayısını göstermektedir. Başlangıçta arama uzayından birden fazla aday yapılandırma seçilir ve bu adaylar düşük eğitim bütçelerinde değerlendirilir. Daha düşük doğrulama kaybı sağlayan adaylar bir sonraki bütçe seviyesine aktarılırken, başarımı düşük adaylar elenir.

Diferansiyel Evrim bileşeninde, aday yapılandırmalar kullanılarak yeni deneme vektörleri oluşturulur. Bunun için aday havuzundan seçilen üç farklı yapılandırma üzerinden mutant vektör şu şekilde elde edilir:

$$\mathbf{v}_q = \lambda_{r_1} + F\left(\lambda_{r_2} - \lambda_{r_3}\right) \tag{3.93}$$

Denklem 3.93'te $\mathbf{v}q$ mutant vektörü, $\boldsymbol{\lambda}r_1$, $\boldsymbol{\lambda}r_2$ ve $\boldsymbol{\lambda}r_3$ aday havuzundan seçilen farklı üst değişken yapılandırmalarını, F ise değişinim (mutasyon) ölçekleme katsayısını göstermektedir. Bu işlem, mevcut aday yapılandırmalar arasındaki farkları kullanarak yeni bir arama yönü oluşturur.

Değişinim sonrasında çaprazlama işlemi uygulanarak deneme vektörü oluşturulur. Deneme vektörünün j. bileşeni aşağıdaki kurala göre belirlenir:

$$u_{q,j} = \begin{cases} v_{q,j}, & \text{eğer } r_j < C_r \text{ veya } j = j_{\text{rastgele}} \\ x_{q,j}, & \text{aksi halde} \end{cases} \tag{3.94}$$

Denklem 3.94'te $u_{q,j}$, deneme vektörünün j. bileşenini; $v_{q,j}$, mutant vektörün j. bileşenini; $\lambda_{q,j}$, mevcut aday yapılandırmanın j. bileşenini göstermektedir. C_r çaprazlama olasılığıdır. r_j rastgele üretilen değeri, j_{rastgele} ise deneme vektörüne en az bir mutant bileşenin aktarılmasını sağlayan rastgele seçilmiş indisi ifade etmektedir.

Deneme vektörü ile mevcut aday yapılandırma aynı bütçe düzeyinde eğitilerek doğrulama kayıpları karşılaştırılır. Daha düşük doğrulama kaybı sağlayan yapılandırma aday havuzunda tutulur:

$$\lambda_q^{\text{yeni}} = \begin{cases} u_q, & \text{eğer } \mathcal{J}(u_q) < \mathcal{J}(\lambda_q) \\ \lambda_q, & \text{aksi halde} \end{cases} \tag{3.95}$$

Denklem 3.95, DEHB algoritmasında seçim adımını göstermektedir. Buna göre yeni üretilen deneme vektörü daha düşük doğrulama kaybı sağlıyorsa mevcut adayın yerini almakta, aksi durumda mevcut aday korunmaktadır. Böylece algoritma, arama uzayında hem yeni bölgeleri keşfetmekte hem de başarılı yapılandırmalar çevresinde daha yoğun bir arama gerçekleştirmektedir.

Hiperbant bileşeni, aday yapılandırmaları farklı bütçe seviyelerinde değerlendirir. Minimum bütçe b_{min}, maksimum bütçe b_{max} ve azaltma katsayısı η ile gösterildiğinde bütçe seviyeleri şu şekilde tanımlanabilir:

$$\mathcal{B}_{HB} = b_{min}, \eta b_{min}, \eta^2 b_{min}, \ldots, b_{maks} \tag{3.96}$$

Her bütçe seviyesinde adaylar doğrulama kaybına göre sıralanır ve yalnızca en başarılı adaylar daha yüksek bütçeye aktarılır. Bu yapı, düşük başarım gösteren yapılandırmaların erken elenmesini, umut vadeden yapılandırmaların ise daha fazla eğitim kaynağıyla değerlendirilmesini sağlar. Bu nedenle DEHB, geniş üst değişken arama uzayına sahip derin öğrenme modelleri için klasik ızgara arama veya rastgele aramaya göre daha verimli bir yaklaşım sunmaktadır. Her bütçe seviyesinde yalnızca en iyi başarım gösteren $1/\eta$ oranındaki adaylar bir sonraki daha yüksek bütçeye aktarılır. Böylece başarısız yapılandırmalar düşük maliyetle elenirken, umut vadeden yapılandırmalar daha

fazla kaynakla değerlendirilir. Bu yapı, özellikle derin öğrenme modellerinde her adayın tam eğitim bütçesiyle eğitilmesinin yüksek maliyetli olduğu durumlarda önemli bir avantaj sağlamaktadır. DEHB algoritmasının bu tezdeki kullanımı Çizelge 3.3'te satır satır özetlenmiştir. Bu sözde kod, Awad vd. (2021) tarafından sunulan DEHB yapısına dayanmakta; ancak EEG tabanlı biyometrik kimlik tanımlama modelinin üst değişken eniyilemesine uyarlanmış biçimde sunulmaktadır.

Çizelge 3.3 DEHB tabanlı üst değişken eniyilemesi için sözde kod

Adım	**Sözde Kod Adımı**
Adım 1	Üst değişken arama uzayı $\mathcal{X}$, minimum bütçe b_{min}, maksimum bütçe b_{max}, azaltma katsayısı η ve maksimum değerlendirme sayısı P tanımlanır.
Adım 2	$\mathcal{X}$ arama uzayından Q adet aday üst değişken yapılandırması rastgele örneklenir.
Adım 3	Her aday yapılandırma, eğitim kümesi üzerinde b_{min} bütçesiyle eğitilir ve doğrulama kaybı hesaplanır.
Adım 4	Toplam değerlendirme sayısı P değerine ulaşılıncaya kadar DEHB döngüsü sürdürülür.
Adım 5	Her bütçe seviyesi için adaylar doğrulama kaybına göre sıralanır ve en iyi $1/\eta$ oranındaki adaylar ebeveyn havuzuna aktarılır.
Adım 6	Ebeveyn havuzundaki her aday için diferansiyel evrim değişinim işlemi uygulanarak mutant vektör $\mathbf{v}_q$ oluşturulur.
Adım 7	Mevcut aday $\mathbf{x}_q$ ve mutant vektör $\mathbf{v}_q$ kullanılarak çaprazlama işlemiyle deneme vektörü $\mathbf{u}_q$ üretilir.
Adım 8	Deneme vektörüyle tanımlanan karma ESA–ÇY-UKSB–Dönüştürücü modeli ilgili bütçede eğitilir ve doğrulama kaybı hesaplanır.
Adım 9	Deneme vektörü mevcut adaydan daha düşük doğrulama kaybı sağlıyorsa aday topluluğunda mevcut adayın yerini alır; aksi hâlde mevcut aday korunur.
Adım 10	Daha yüksek bütçe seviyelerine yalnızca başarılı adaylar aktarılır ve eğitim kaynakları umut vadeden yapılandırmalara ayrılır.
Adım 11	Maksimum değerlendirme sayısına ulaşıldığında, tüm bütçeler genelinde en düşük doğrulama kaybına sahip üst değişken yapılandırması $\mathbf{x}^*$ olarak seçilir.
Adım 12	Seçilen $\mathbf{x}^*$ yapılandırması ile nihai model eğitim kümesi üzerinde yeniden eğitilir ve test oturumunda değerlendirilir.

Bu tezde DEHB, önerilen ESA–ÇY-UKSB–Dönüştürücü modelinin öğrenme sürecini, temsil kapasitesini ve düzenlileştirme düzeyini belirleyen üst değişkenleri birlikte eniyilemek amacıyla kullanılmıştır. Eğitim sürecine ilişkin olarak öğrenme oranı ve yığın boyutu; düzenlileştirmeye ilişkin olarak seyrelme oranı ve ağırlık bozunumu eniyilemeye dâhil edilmiştir. Modelin mimari kapasitesi kapsamında ESA bileşeninin süzgeç sayısı ve çekirdek ölçek katsayısı, ÇY-UKSB bileşeninin gizli birim sayısı ile Dönüştürücü bileşeninin dikkat başlığı ve kodlayıcı katman sayısı değerlendirilmiştir. Sınıflandırıcı başlığında ise yüksek düzeyli temsillerin sınıf olasılıklarına aktarılmasında kullanılan tam bağlantılı katmanın boyutu eniyilenmiştir. Kapalı-küme kimlik tanımlama proble-

mindeki sınıf sayısı veri kümesinde yer alan 42 kayıtlı birey tarafından belirlendiğinden, *softmax* çıktı katmanındaki birim sayısı eniyilenen bir üst değişken olarak ele alınmamıştır. Her aday üst değişken yapılandırması, DEHB'nin çok bütçeli değerlendirme yapısı içinde farklı eğitim bütçelerinde sınanmıştır. Yapılandırmaların karşılaştırılmasında yalnızca eğitim oturumundan ayrılan doğrulama kümesi üzerinde hesaplanan çapraz entropi kaybı kullanılmış; test oturumuna ait veriler model seçimi ve üst değişken eniyilemesi sürecine dâhil edilmemiştir. Böylece modelin öğrenme dinamiği, mimari kapasitesi ve aşırı öğrenmeye karşı düzenlileştirme düzeyi, oturumlar arası değerlendirme tarafsızlığı korunarak birlikte belirlenmiştir.

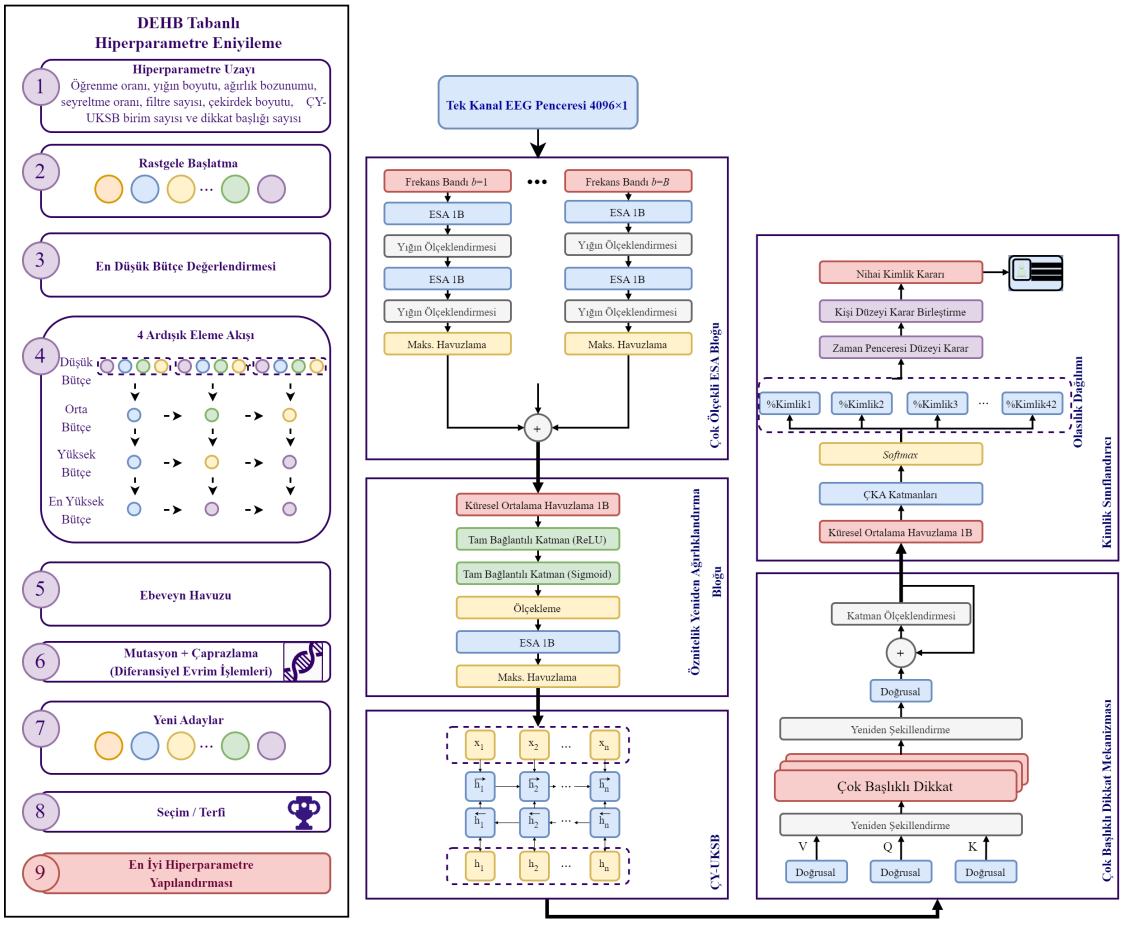

Şekil 3.8 Önerilen karma ESA–ÇY-UKSB–Dönüştürücü tabanlı tek kanallı EEG biyometrik kimlik tanımlama yaklaşımının genel akışı

Şekil 3.8'de, bu tez izleme döneminde önerilen genel yöntemsel akış sunulmaktadır. Görselde DEHB tabanlı üst değişken eniyileme süreci, tek kanallı EEG penceresinin frekans ve zaman böl-

gesi temsillerine ayrılması, çok ölçekli evrişimsel öznitelik çıkarımı, öznitelik yeniden ağırlıklandırma, ÇY-UKSB tabanlı zamansal bağımlılık modelleme, çok başlıklı dikkat düzeneği ve kapalı-küme kimlik sınıflandırıcı aşamaları birlikte gösterilmektedir. Ayrıca model çıktısında elde edilen olasılık dağılımının zaman penceresi düzeyi karar, kişi düzeyi karar birleştirme ve nihai kimlik kararı aşamalarında nasıl kullanıldığı da özetlenmektedir. Bu yapı, önerilen modelin yalnızca sınıflandırıcı mimarisini değil, aynı zamanda üst değişken eniyilemesi ve karar verme sürecini de bütüncül biçimde ortaya koymaktadır.

3.6 Deneysel Başarım Değerlendirme Ölçütleri

Bu tezde önerilen EEG tabanlı biyometrik kimlik tanımlama sisteminin başarımı, yalnızca sınıflandırma doğruluğu üzerinden değil, sistemin tüm yöntemsel bileşenlerini kapsayacak şekilde çok boyutlu olarak değerlendirilmiştir. Değerlendirme süreci genel iş akışı; ham ve temizlenmiş EEG verilerinin işlenmesi, gürültü/bozulma tespiti, üretken model tabanlı gürültü giderimi, tek kanallı EEG temsili, kapalı-küme kimlik tanımlama, kanal–bant analizi ve model bileşeni karşılaştırmalarından oluşmaktadır. Bu nedenle başarım değerlendirme ölçütleri de iki ana grupta ele alınmıştır. Birinci grup, gürültü tespiti ve gürültü giderimi aşamasında kullanılan işaret kalitesi ve yeniden yapılandırma ölçütlerini kapsamaktadır. İkinci grup ise kapalı-küme EEG tabanlı kimlik tanımlama problemine yönelik sınıflandırma, aday sıralama, kişi düzeyi karar ve kararlılık ölçütlerini içermektedir.

EEG tabanlı biyometrik sistemlerde değerlendirme ölçütlerinin problem tanımıyla uyumlu olması kritik öneme sahiptir. Çünkü EEG işareti düşük genlikli, gürültüye duyarlı, durağan olmayan ve oturumlar arası değişkenlik gösteren bir biyolojik işarettir. Bu nedenle yalnızca genel doğruluk değerinin raporlanması, önerilen sistemin gerçek başarımını yeterli düzeyde açıklamaz. Özellikle bu tezde hem ham EEG verisi hem de temizlenmiş türev EEG verisi kullanıldığından, gürültü giderme yönteminin işaret düzeyindeki etkisi ile nihai kimlik tanımlama başarısına etkisi birlikte değerlendirilmelidir. Bu yaklaşım, gürültü giderme modülünün yalnızca işaret biçimini düzeltip düzeltmediğini değil, aynı zamanda biyometrik açıdan ayırt edici bilginin korunmasına katkı sağlayıp sağlamadığını da incelemeye olanak tanımaktadır.

Bu kapsamda deneysel başarım değerlendirme süreci, birbirini tamamlayan beş düzeyde yapılan-

dırılmıştır. Birinci düzeyde, gürültü tespit modülünün bozulmuş ve bozulmamış EEG pencerelerini ayırt etme başarısı değerlendirilmiştir. İkinci düzeyde, ÜÇA tabanlı gürültü giderme modülü tarafından yeniden yapılandırılan EEG pencerelerinin temiz referans işaretlerle zaman ve frekans bölgelerindeki benzerliği incelenmiştir. Üçüncü düzeyde, önerilen karma ESA–ÇY-UKSB–Dönüştürücü modelinin kapalı-küme kimlik tanımlama başarısı temel sınıflandırma ölçütleri kullanılarak değerlendirilmiştir. Dördüncü düzeyde, pencere düzeyinde elde edilen tahminlerin kişi düzeyinde birleştirilmesinde kullanılan karar bütünleştirme yaklaşımlarının sistem başarımı üzerindeki etkisi analiz edilmiştir. Beşinci düzeyde ise farklı test süreleri, kanal–bant kombinasyonları, karşılaştırmalı deneyler, model bileşeni çıkarma çalışmaları ve tekrarlı çalıştırmalar üzerinden önerilen sistemin genellenebilirliği, kararlılığı ve bileşen katkıları incelenmiştir.

3.6.1 Gürültü tespiti başarım ölçütleri

BÇS tabanlı gürültü tespit modülü iki farklı sınıflandırma düzeninde değerlendirilmiştir. İki sınıflı değerlendirmede EEG pencereleri bozulmasız ve bozulmalı; üç sınıflı değerlendirmede ise bozulmasız, EOG kaynaklı bozulmuş ve EMG kaynaklı bozulmuş olarak sınıflandırılmıştır. Her iki durumda da sınıflandırma sonuçları karışıklık matrisi üzerinden incelenmiştir. Gerçek sınıfı a, tahmin edilen sınıfı b olan örneklerin sayısı,

$$C^g_{a,b} = \sum_{m=1}^{M} \mathbb{I}\left(y^g_m = a\right) \mathbb{I}\left(\hat{y}^g_m = b\right) \tag{3.97}$$

şeklinde tanımlanmıştır. Burada y^g_m, m. EEG penceresinin gerçek gürültü sınıfını; $\hat{y}^g_m$, BÇS tarafından üretilen sınıf tahminini; M ise değerlendirilen toplam pencere sayısını göstermektedir. Gürültü tespit doğruluğu,

$$D_g = \frac{\sum_{a=1}^{K_g} C^g_{a,a}}{\sum_{a=1}^{K_g} \sum_{b=1}^{K_g} C^g_{a,b}} \tag{3.98}$$

ile hesaplanmıştır. Burada K_g, gürültü tespit problemindeki sınıf sayısıdır ve iki sınıflı değerlendirmede $K_g = 2$, üç sınıflı değerlendirmede $K_g = 3$ olmaktadır.

İki sınıflı değerlendirmede bozulmalı pencereler pozitif sınıf olarak kabul edilmiştir. Buna göre doğru pozitif, yanlış pozitif ve yanlış negatif sayıları sırasıyla DP, YP ve YN ile gösterildiğinde

duyarlılık,

$$Duyarlilik_g = \frac{DP}{DP + YN + \epsilon} \tag{3.99}$$

kesinlik,

$$Kesinlik_g = \frac{DP}{DP + YP + \epsilon} \tag{3.100}$$

ve F1 puanı,

$$F1_g = \frac{2 \cdot Kesinlik_g \cdot Duyarlilik_g}{Kesinlik_g + Duyarlilik_g + \epsilon} \tag{3.101}$$

şeklinde hesaplanmıştır. Burada ϵ, paydanın sıfır olmasını önlemek amacıyla kullanılan küçük pozitif sabittir. Duyarlılık, bozulmalı pencerelerin ne kadarının doğru biçimde yakalandığını; kesinlik ise bozulmalı olarak işaretlenen pencerelerin ne kadarının gerçekten bozulmalı olduğunu göstermektedir. Üç sınıflı değerlendirmede aynı ölçütler her sınıf için bire-karşı-diğerleri yaklaşımıyla hesaplanmış ve sınıflar birlikte değerlendirilmiştir. Böylece BÇS modülünün hem bozulma varlığını belirleme hem de EOG ile EMG kaynaklı bozulmaları birbirinden ayırma başarısı incelenmiştir.

3.6.2 Gürültü giderimi ve yeniden yapılandırma başarım ölçütleri

Gürültü giderimi aşamasında amaç, bozulmuş EEG penceresinden temiz EEG işaretine mümkün olduğunca yakın, biyometrik açıdan anlamlı ve spektral olarak tutarlı bir pencere elde etmektir. Bu nedenle yeniden yapılandırma başarısı hem zaman bölgesi hem frekans bölgesi hem de nihai kimlik tanımlama başarımı üzerinden değerlendirilmiştir. Temiz referans işaret $x[n]$, bozulmuş işaret $x^{boz}[n]$, yeniden yapılandırılmış/onarılan işaret ise $\tilde{x}[n]$ ile gösterilsin. Burada $n = 1, 2, \ldots, W$, pencere içerisindeki örnek dizinini; W, pencere uzunluğunu göstermektedir.

Gürültü giderme başarımını değerlendirmek için kullanılan temel ölçütlerden biri Ortalama Mutlak Hata'dır (OMH, Mean Absolute Error: MAE). OMH, temiz referans işaret ile yeniden yapılandırılmış işaret arasındaki genlik düzeyi ortalama mutlak farkı gösterir:

$$OMH = \frac{1}{W} \sum_{n=1}^{W} |x[n] - \tilde{x}[n]| \tag{3.102}$$

OMH değerinin düşük olması, yeniden yapılandırılmış işaretin genlik düzeyinde temiz referans işarete daha yakın olduğunu göstermektedir. Bu ölçüt, örnek düzeyindeki mutlak hatayı doğrudan değerlendirdiği için gürültü giderme modülünün işaret biçimini ne ölçüde koruduğunu yorumlamak açısından kullanılmıştır.

Kök Ortalama Kare Hata (KOKH), temiz referans işaret ile onarılmış işaret arasındaki karesel farkların ortalama karekökü olarak tanımlanır:

$$KOKH = \sqrt{\frac{1}{W}\sum_{n=1}^{W}\left(x[n] - \tilde{x}[n]\right)^2} \tag{3.103}$$

KOKH, büyük genlikli hatalara OMH'ye göre daha duyarlıdır. Bu nedenle EOG veya EMG kaynaklı yüksek genlikli bozulmaların giderilmesinden sonra kalan büyük hataları değerlendirmek için yararlıdır. Düşük KOKH değeri, onarılmış işaretin temiz referans işarete zaman bölgesinde daha yakın olduğunu göstermektedir.

Gürültü giderme yöntemlerinin değerlendirilmesinde kullanılan bir diğer temel ölçüt İGO. Temiz işaretin enerjisi ile hata işaretinin enerjisi oranı kullanılarak yeniden yapılandırma sonrası İGO aşağıdaki şekilde hesaplanabilir:

$$GO_{sonra} = 10\log_{10}\left(\frac{\sum_{n=1}^{W} x^2[n]}{\sum_{n=1}^{W}\left(x[n] - \tilde{x}[n]\right)^2 + \epsilon}\right) \tag{3.104}$$

Benzer şekilde, gürültülü işaret için başlangıç İGO değeri,

$$GO_{once} = 10\log_{10}\left(\frac{\sum_{n=1}^{W} x^2[n]}{\sum_{n=1}^{W}\left(x[n] - x^{boz}[n]\right)^2 + \epsilon}\right) \tag{3.105}$$

olarak hesaplanabilir. Gürültü giderme işleminin sağladığı İGO iyileşmesi ise,

$$\Delta GO = GO_{sonra} - GO_{once} \tag{3.106}$$

şeklinde ifade edilir. $\Delta GO > 0$ olması, onarım işlemi sonrasında işaretin temiz referansa göre daha yüksek İGO'ya ulaştığını göstermektedir. İGO, özellikle yapay olarak eklenmiş EOG ve EMG bozulmalarının bulunduğu deneylerde, gürültü giderme yönteminin etkinliğini nicel olarak değerlendirmek için kullanılmıştır.

Temiz ve onarılmış işaret arasındaki doğrusal benzerliği ölçmek için Pearson bağıntı katsayısı hesaplanabilir:

$$\rho = \frac{\sum_{n=1}^{W} (x[n] - \bar{x})\,(\tilde{x}[n] - \bar{\tilde{x}})}{\sqrt{\sum_{n=1}^{W} (x[n] - \bar{x})^2}\sqrt{\sum_{n=1}^{W} (\tilde{x}[n] - \bar{\tilde{x}})^2} + \epsilon} \tag{3.107}$$

Burada $\bar{x}$ ve $\bar{\tilde{x}}$, sırasıyla temiz ve onarılmış işaretlerin ortalama değerlerini göstermektedir. Bağıntı katsayısının 1'e yakın olması, onarılmış işaretin temiz referans işaret ile yüksek derecede benzer zamansal örüntüye sahip olduğunu göstermektedir. EEG biyometrisi açısından bu ölçüt önemlidir; çünkü kimlik ayırt edici bazı örüntüler yalnızca genlik düzeyinde değil, işaretin zamansal biçimi ve dalga yapısı içerisinde de taşınabilir.

Yeniden yapılandırma başarısının frekans bölgesinde değerlendirilmesi için GSY temelli ölçütler kullanılmıştır. Temiz işaretin GSY $GSY_x(f)$, onarılmış işaretin GSY ise $GSY_{\tilde{x}}(f)$ ile gösterilsin. Ölçeklendirilmiş GSY farkı aşağıdaki şekilde tanımlanabilir:

$$D_{GSY} = \frac{\sum_f |GSY_x(f) - GSY_{\tilde{x}}(f)|}{\sum_f GSY_x(f) + \epsilon} \tag{3.108}$$

D_{GSY} değerinin düşük olması, onarılmış işaretin frekans bölgesinde temiz işarete daha yakın olduğunu göstermektedir. EEG tabanlı biyometrik kimlik tanımlama probleminde frekans bantları ve alt bantlar önemli ayırt edici bilgi taşıdığı için, gürültü giderme yönteminin yalnızca zaman bölgesinde değil, GSY dağılımı açısından da değerlendirilmesi gerekmektedir.

GSY benzerliği alternatif olarak kosinüs benzerliği ile de ifade edilebilir:

$$Benzerlik_{GSY} = \frac{\sum_f GSY_x(f) GSY_{\tilde{x}}(f)}{\sqrt{\sum_f GSY_x^2(f)}\sqrt{\sum_f GSY_{\tilde{x}}^2(f)} + \epsilon} \tag{3.109}$$

Bu değerin 1'e yaklaşması, temiz ve onarılmış işaretlerin spektral dağılımlarının yüksek düzeyde benzer olduğunu göstermektedir. Özellikle alfa, beta ve gama gibi biyometrik ayırt edicilik açısından önemli olabilecek frekans aralıklarının korunması, gürültü giderme modülünün sınıflandırma başarısına katkısı açısından önemlidir.

Belirli bir EEG frekans bandındaki enerji korunumu ayrıca bant gücü farkı ile değerlendirilebilir. B ilgili frekans bandını temsil etmek üzere, temiz ve onarılmış işaretler arasındaki ölçeklendirilmiş

bant gücü farkı,

$$D_B = \frac{\left|\sum_{f\in B} GSY_x(f) - \sum_{f\in B} GSY_{\tilde{x}}(f)\right|}{\sum_{f\in B} GSY_x(f) + \epsilon} \tag{3.110}$$

şeklinde hesaplanır. Bu ölçüt, gürültü giderme işleminin belirli bantlardaki enerji yapısını ne ölçüde koruduğunu gösterir. Örneğin EMG kaynaklı bozulmalar daha çok yüksek frekans bileşenlerini etkileyebileceğinden, beta ve gama aralıklarındaki bant gücü farklarının ayrıca değerlendirilmesi anlamlıdır. EOG kaynaklı bozulmalar ise düşük frekanslı bileşenleri etkileyebileceğinden delta ve teta bantlarındaki değişimlerin izlenmesi gereklidir.

Gürültü giderme yönteminin biyometrik açıdan etkisini değerlendirmek için işaret düzeyi ölçütlere ek olarak sınıflandırma sonrası başarım değişimi de hesaplanmıştır. Gürültülü veri üzerindeki kimlik tanımlama başarısı S_{boz}, onarılmış veri üzerindeki başarı S_{onar}, temiz referans veri üzerindeki başarı ise S_{temiz} ile gösterilsin. Gürültü giderme sonrası başarım kazanımı,

$$\Delta S_{onarim} = S_{onar} - S_{boz} \tag{3.111}$$

şeklinde hesaplanabilir. Temiz referansa göre başarım açığı ise,

$$A_{temiz} = S_{temiz} - S_{onar} \tag{3.112}$$

olarak tanımlanır. ΔS_{onarim} değerinin pozitif olması, gürültü giderme işleminin sınıflandırma başarısını artırdığını; A_{temiz} değerinin düşük olması ise onarılmış işaretin temiz veriyle elde edilen başarıma yaklaştığını göstermektedir. Bu değerlendirme, gürültü giderme modülünün yalnızca işaret kalitesi açısından değil, nihai biyometrik karar başarısı açısından da etkisini ortaya koymaktadır.

3.6.3 Kapalı-küme kimlik tanımlama başarım ölçütleri

Kapalı-küme kimlik tanımlama probleminde test kümesi aşağıdaki şekilde tanımlanabilir:

$$\mathcal{D}_{test} = \{(\mathbf{x}_m, y_m)\}_{m=1}^{M} \tag{3.113}$$

Burada $\mathcal{D}_{test}$ test kümesini, $\mathbf{x}_m$ m. test EEG örneğini, y_m bu örneğe ait gerçek kimlik etiketini ve M test kümesindeki toplam EEG penceresi sayısını göstermektedir. Kapalı-küme senaryoda her

gerçek etiket, kayıtlı kimlik kümesi içerisinde yer almaktadır:

$$y_m \in \mathcal{Y}, \qquad \mathcal{Y} = \{\mathrm{ID}_1, \mathrm{ID}_2, \ldots, \mathrm{ID}_N\} \tag{3.114}$$

Denklem 3.114'nde N, kapalı-küme deneydeki toplam kayıtlı birey sayısını göstermektedir. USYM veri kümesinin iki oturumlu alt kümesi kullanıldığında bu çalışmada $N = 42$ olarak tanımlanmıştır. Model, her test EEG örneği için kayıtlı bireyler üzerinde bir olasılık vektörü üretmektedir:

$$\hat{\mathbf{p}}_m = [\hat{p}_{m,1}, \hat{p}_{m,2}, \ldots, \hat{p}_{m,N}] \tag{3.115}$$

Burada $\hat{p}_{m,i}$, m. test EEG örneğinin i. kayıtlı bireye ait olma olasılığını göstermektedir. *Softmax* işlevi kullanıldığında,

$$\hat{p}_{m,i} = \frac{\exp(z_{m,i})}{\sum_{j=1}^{N} \exp(z_{m,j})} \tag{3.116}$$

şeklinde hesaplanır. Burada $z_{m,i}$, modelin i. sınıf için ürettiği ham çıktı değeridir. Pencere düzeyi nihai kimlik tahmini, en yüksek olasılığa sahip sınıfın seçilmesiyle elde edilir:

$$\hat{y}_m = \underset{i \in \{1,2,\ldots,N\}}{\arg\max} \; \hat{p}_{m,i} \tag{3.117}$$

Birinci-sıra doğruluk, modelin en yüksek olasılık verdiği kimlik etiketinin gerçek kimlik etiketiyle eşleşme oranını göstermektedir:

$$D_{\text{İlk-1}} = \frac{1}{M} \sum_{m=1}^{M} \mathbb{I}(\hat{y}_m = y_m) \tag{3.118}$$

İlk-k doğruluk ise gerçek kimliğin model tarafından en yüksek olasılık verilen ilk k aday içerisinde yer alıp almadığını gösterir. m. test örneği için en yüksek olasılık verilen ilk k aday kümesi $A_k(\hat{\mathbf{p}}_m)$ ile gösterildiğinde,

$$D_{\text{İlk-k}} = \frac{1}{M} \sum_{m=1}^{M} \mathbb{I}\left(y_m \in A_k(\hat{\mathbf{p}}_m)\right) \tag{3.119}$$

şeklinde hesaplanır. Bu tezde ilk-3 ve ilk-5 doğruluk değerleri raporlanmıştır. Bu ölçütler, modelin doğru kimliği yalnızca birinci sırada seçme başarısını değil, aynı zamanda doğru kimliği üst adaylar arasında konumlandırma kapasitesini de göstermektedir.

KEK eğrisi, doğru kimliğin model aday sıralamasında ilk k sıra içerisinde bulunma oranını farklı

k değerleri için gösterir. Gerçek kimliğin m. örnekteki sırası $r_m(y_m)$ ile gösterildiğinde,

$$KEK(k) = \frac{1}{M} \sum_{m=1}^{M} \mathbb{I}\left(r_m(y_m) \leq k\right) \tag{3.120}$$

şeklinde hesaplanır. $KEK(1)$ değeri birinci-sıra doğruluk ile aynıdır. KEK eğrisi, modelin aday sıralama başarısını görsel olarak değerlendirmek için kullanılmıştır. Eğrinin düşük k değerlerinde hızlı biçimde 1'e yaklaşması, modelin doğru kimliği üst sıralarda kararlı biçimde konumlandırdığını göstermektedir.

Çok sınıflı kapalı-küme değerlendirmede karışıklık matrisi, modelin hangi kimlikleri birbirine karıştırdığını göstermek için kullanılmıştır. Gerçek kimliği ID_i, tahmin edilen kimliği ID_j olan örneklerin sayısı,

$$C_{i,j} = \sum_{m=1}^{M} \mathbb{I}(y_m = \text{ID}_i)\mathbb{I}(\hat{y}_m = \text{ID}_j) \tag{3.121}$$

şeklinde tanımlanır. Karışıklık matrisinin köşegen elemanları doğru sınıflandırmaları, köşegen dışı elemanları ise hatalı sınıflandırmaları göstermektedir. Bu matris, genel doğruluk değerinin ötesinde, birey bazlı hata örüntülerinin ve olası kimlik karışmalarının incelenmesine olanak tanımaktadır.

Karışıklık matrisi üzerinden i. sınıf için doğru pozitif, yanlış pozitif ve yanlış negatif değerleri,

$$DP_i = C_{i,i} \tag{3.122}$$

$$YP_i = \sum_{\substack{a=1 \\ a \neq i}}^{N} C_{a,i} \tag{3.123}$$

$$YN_i = \sum_{\substack{b=1 \\ b \neq i}}^{N} C_{i,b} \tag{3.124}$$

şeklinde hesaplanır. Buna göre sınıf bazlı kesinlik,

$$Kesinlik_i = \frac{DP_i}{DP_i + YP_i + \epsilon} \tag{3.125}$$

sınıf bazlı duyarlılık,

$$Duyarlilik_i = \frac{DP_i}{DP_i + YN_i + \epsilon} \tag{3.126}$$

ve sınıf bazlı F1 puanı,

$$F1_i = \frac{2 \cdot Kesinlik_i \cdot Duyarlilik_i}{Kesinlik_i + Duyarlilik_i + \epsilon} \tag{3.127}$$

şeklinde tanımlanır. Makro F1 puanı, tüm sınıflara ait F1 değerlerinin aritmetik ortalamasıdır:

$$Makro\ F1 = \frac{1}{N} \sum_{i=1}^{N} F1_i \tag{3.128}$$

Makro F1 puanında her sınıf eşit ağırlıkla değerlendirilir. Bu nedenle bazı bireylerin daha fazla pencereye sahip olması veya bazı bireylerin diğerlerinden daha kolay tanınması genel sonucu tek başına baskılamaz.

Dengeli doğruluk, sınıf bazlı duyarlılık değerlerinin ortalaması olarak hesaplanır:

$$D_{\text{Dengeli}} = \frac{1}{N} \sum_{i=1}^{N} Duyarlilik_i \tag{3.129}$$

Dengeli doğruluk, her bireyin tanınma başarısını eşit ağırlıkla dikkate aldığı için EEG tabanlı kimlik tanımlama çalışmalarında genel doğruluğa ek olarak raporlanması gereken önemli bir ölçüttür. Özellikle sınıflar arasında pencere sayısı, işaret kalitesi veya oturumlar arası değişkenlik açısından farklılıklar bulunduğunda, dengeli doğruluk model başarımını daha adil biçimde yorumlamaya yardımcı olur.

3.6.4 Pencere düzeyi ve kişi düzeyi karar ölçütleri

Bu tezde EEG kayıtları kısa zaman pencerelerine ayrıldığından, başarım değerlendirmesi hem pencere düzeyinde hem de kişi düzeyinde yapılmıştır. Pencere düzeyi değerlendirmede her EEG penceresi bağımsız bir test örneği olarak kabul edilmiştir. Kişi düzeyi değerlendirmede ise aynı bireye ait birden fazla pencerenin olasılık çıktıları birleştirilerek tek bir nihai kimlik kararı üretilmiştir. Bu yapı, gerçek biyometrik uygulamalarda kullanıcının birkaç saniyelik EEG kaydından elde edilen çoklu pencerelerle daha kararlı karar verilmesine olanak tanımaktadır.

Bir test bireyine ait karar bloğu,

$$\mathcal{B}_q = \{m_1, m_2, \ldots, m_{M_q}\} \tag{3.130}$$

ile gösterilsin. Burada $\mathcal{B}_q$, q. kişi düzeyi karar için kullanılan pencere dizinlerini; M_q, bu karar için kullanılan pencere sayısını ifade etmektedir. Yumuşak oylama yaklaşımında, aynı karar bloğundaki pencerelere ait olasılık vektörleri ortalanır:

$$\bar{\mathbf{p}}_q = \frac{1}{M_q} \sum_{m \in \mathcal{B}_q} \hat{\mathbf{p}}_m \tag{3.131}$$

Kişi düzeyi nihai karar,

$$\hat{y}_q^{soft} = \underset{i \in \{1,2,\ldots,N\}}{\arg\max}\ \bar{p}_{q,i} \tag{3.132}$$

şeklinde elde edilir. Yumuşak oylama, tüm sınıf olasılıklarını dikkate aldığı için tek pencere kararlarında ortaya çıkabilecek geçici kararsızlıkları azaltabilir.

Çoğunluk oylaması yaklaşımında her pencerenin nihai sınıf etiketi dikkate alınır ve en sık tahmin edilen sınıf kişi düzeyi karar olarak seçilir:

$$\hat{y}_q^{maj} = \underset{i \in \{1,2,\ldots,N\}}{\arg\max} \sum_{m \in \mathcal{B}_q} \mathbb{I}(\hat{y}_m = \mathrm{ID}_i) \tag{3.133}$$

Maksimum güven puanı yaklaşımında ise karar bloğu içerisindeki tüm pencereler ve tüm sınıflar arasında en yüksek olasılık değerine sahip sınıf seçilir:

$$(m^*, i^*) = \underset{m \in \mathcal{B}_q,\ i \in \{1,2,\ldots,N\}}{\arg\max}\ \hat{p}_{m,i} \tag{3.134}$$

$$\hat{y}_q^{max} = \mathrm{ID}_{i^*} \tag{3.135}$$

Bu üç karar birleştirme yönteminin birlikte değerlendirilmesi, kişi düzeyi biyometrik karar düzeneğinin model başarısına etkisini karşılaştırmalı biçimde incelemeye olanak sağlamaktadır.

Kişi düzeyi karar doğruluğu, kişi düzeyi tahminlerin gerçek kimliklerle eşleşme oranı olarak hesaplanır:

$$D_{\text{kişi}} = \frac{1}{Q} \sum_{q=1}^{Q} \mathbb{I}(\hat{y}_q = y_q) \tag{3.136}$$

Burada Q, kişi düzeyi karar sayısını; $\hat{y}_q$, seçilen karar birleştirme yöntemine göre elde edilen nihai kimlik tahminini; y_q, gerçek kimliği göstermektedir. Benzer biçimde kişi düzeyi ilk-k, makro F1 ve dengeli doğruluk değerleri de kişi düzeyi kararlar üzerinden hesaplanmıştır.

3.6.5 Karar süresi ve işlem zamanı ölçütleri

Biyometrik sistemlerin pratik kullanılabilirliği açısından yalnızca doğruluk değeri yeterli değildir. Sistemin ne kadar kısa EEG kaydıyla güvenilir karar verebildiği ve işlem süresinin uygulanabilir düzeyde olup olmadığı da değerlendirilmelidir. Bu nedenle tezde karar süresi ve işlem zamanı analizleri de başarım değerlendirme kapsamına alınmıştır.

Örtüşmesiz pencereleme durumunda, kişi düzeyi karar için kullanılan toplam EEG süresi aşağıdaki şekilde hesaplanır:

$$T_{\text{karar}} = M_q \cdot T_p \tag{3.137}$$

Burada T_{karar}, kişi düzeyi karar için kullanılan toplam EEG süresini göstermektedir. Bu tezde temel pencere uzunluğu 4 saniye olarak belirlenmiştir. Dolayısıyla tek pencere ile karar verildiğinde $T_{\text{karar}} = 4$ saniyedir. Pencere sayısı arttıkça karar için gereken EEG süresi de artmaktadır.

Örtüşmeli veya farklı kayma miktarı kullanılan pencereleme koşullarında karar süresi, pencere uzunluğu W, pencere kayma miktarı R ve örnekleme frekansı f_s ile aşağıdaki şekilde ifade edilebilir:

$$T_{\text{karar}} = \frac{W + (M_q - 1)R}{f_s} \tag{3.138}$$

Örtüşmesiz durumda $R = W$ olduğundan Denklem 3.138, Denklem 3.137 ile uyumlu hâle gelir. Bu ölçüt, sistemin kısa kayıt süreleri ile ne ölçüde başarılı olduğunu ve karar süresi arttıkça başarımın nasıl değiştiğini incelemek için kullanılmıştır.

İşlem zamanı analizi için bir EEG penceresinin model tarafından sınıflandırılması için gereken ortalama süre,

$$T_{\text{işlem}} = \frac{1}{M} \sum_{m=1}^{M} t_m \tag{3.139}$$

şeklinde hesaplanabilir. Burada t_m, $m.$ pencerenin ön işleme, model çıkarımı veya sınıflandırma aşamasında harcanan işlem süresini göstermektedir. Eğer sistem uçtan uca değerlendiriliyorsa toplam işlem süresi,

$$T_{\text{toplam}} = T_{\text{ön-işleme}} + T_{\text{gürültü}} + T_{\text{model}} + T_{\text{karar}} \tag{3.140}$$

şeklinde ifade edilebilir. Burada $T_{\text{ön-işleme}}$ veri hazırlama süresini, $T_{\text{gürültü}}$ gürültü tespiti ve giderimi süresini, T_{model} model çıkarım süresini ve T_{karar} karar birleştirme süresini temsil etmektedir. Böylece sistemin yalnızca doğruluk açısından değil, hesaplama verimliliği açısından da değerlendirilmesi sağlanmıştır.

3.6.6 Tekrarlı deney kararlılığı ve karşılaştırmalı başarım ölçütleri

Derin öğrenme modellerinde ağırlık başlangıçları, veri sıralaması, yığın örnekleme ve eniyileme sürecindeki stokastik etkiler nedeniyle tek bir çalıştırma sonucu modelin genel başarımını tek başına temsil etmeyebilir. Bu nedenle tezde başarım ölçütleri tekrarlı deneyler üzerinden ortalama ve standart sapma değerleriyle raporlanmıştır. Bir başarım ölçütü için r. çalıştırmada elde edilen değer s_r, toplam çalıştırma sayısı R olmak üzere ortalama başarım,

$$\bar{s} = \frac{1}{R} \sum_{r=1}^{R} s_r \tag{3.141}$$

ve standart sapma,

$$\sigma_s = \sqrt{\frac{1}{R-1} \sum_{r=1}^{R} (s_r - \bar{s})^2} \tag{3.142}$$

şeklinde hesaplanmıştır. Sonuçlar $\bar{s} \pm \sigma_s$ biçiminde raporlanmıştır. Ortalama değer modelin beklenen başarımını, standart sapma ise farklı çalıştırmalar arasındaki kararlılığı göstermektedir. Düşük standart sapma, elde edilen başarının tek bir rastlantısal çalıştırmaya özgü olmadığını ve modelin tekrarlanabilir başarım sunduğunu göstermektedir.

Model karşılaştırmalarında önerilen yöntemin temel yöntemlere göre sağladığı başarım farkı da hesaplanabilir. Önerilen modelin başarısı $S_{\text{önerilen}}$, karşılaştırma yönteminin başarısı S_{temel} ile gösterildiğinde mutlak başarım farkı,

$$\Delta S = S_{\text{önerilen}} - S_{\text{temel}} \tag{3.143}$$

şeklinde tanımlanır. Göreli iyileşme ise,

$$I_{\text{göreli}} = \frac{S_{\text{önerilen}} - S_{\text{temel}}}{S_{\text{temel}} + \epsilon} \times 100 \tag{3.144}$$

olarak hesaplanabilir. Bu ölçütler, önerilen ESA–ÇY-UKSB–Dönüştürücü modelinin GSY tabanlı klasik makine öğrenmesi yöntemleri, EEGNet, ShallowConvNet veya diğer derin öğrenme yaklaşımlarıyla karşılaştırılmasında yorumlayıcı bir katkı sağlamaktadır.

Kanal–bant analizlerinde de aynı sınıflandırma ölçütleri kullanılmıştır. Bir kanal c ve frekans bandı b için pencere düzeyi birinci-sıra doğruluk,

$$D_{\text{İlk-1}}^{(c,b)} = \frac{1}{M} \sum_{m=1}^{M} \mathbb{I}\left(\hat{y}_m^{(c,b)} = y_m\right) \tag{3.145}$$

şeklinde hesaplanabilir. Benzer şekilde $Makro\ F1^{(c,b)}$, $D_{\text{Dengeli}}^{(c,b)}$ ve $D_{\text{İlk-k}}^{(c,b)}$ değerleri de hesaplanarak kanal–bant düzeyinde karşılaştırma yapılmıştır. Bu analiz, modelin hangi elektrot bölgelerinden ve hangi frekans alt bantlarından daha yüksek ayırt edici bilgi elde ettiğini belirlemek amacıyla kullanılmıştır.

Bileşen çıkarma deneylerinde ise tam modelin başarısı ile belirli bir bileşeni çıkarılmış model varyantının başarısı karşılaştırılmıştır. Tam modelin başarımı S_{tam}, v. model varyantının başarımı S_v ile gösterildiğinde ilgili bileşenin katkı farkı,

$$\Delta S_v = S_{\text{tam}} - S_v \tag{3.146}$$

şeklinde hesaplanabilir. ΔS_v değerinin yüksek olması, çıkarılan bileşenin model başarısına daha güçlü katkı sunduğunu göstermektedir. Bu analiz, çok ölçekli evrişimsel bant dalları, ÇY-UKSB bileşeni, Dönüştürücü bileşeni ve sınıflandırıcı yapısının EEG tabanlı kimlik tanımlama başarımına katkısını ayrı ayrı değerlendirmek için kullanılmıştır.

4. DENEYSEL SONUÇLAR

Bu bölümde, tez kapsamında geliştirilen EEG tabanlı biyometrik kimlik tanımlama sistemine ilişkin deneysel bulgular, veri kümesinin yapısal özelliklerinden bütünleşik sistem başarımına uzanan sistematik bir çerçevede sunulmaktadır. İlk olarak, Oslo Üniversitesi USYM dinlenim durumu EEG veri kümesinin katılımcı özellikleri, oturum yapısı ve veri bölümleme protokolleri incelenmektedir. Ardından, BÇS–Wasserstein ÜÇA tabanlı gürültü tespit ve giderim yaklaşımı; bozulma tespiti, yeniden yapılandırma doğruluğu ve zaman–frekans bütünlüğünün korunması açısından değerlendirilmektedir. Sonraki aşamada kanal–frekans bandı kombinasyonlarının biyometrik ayırt ediciliği ve oturumlar arası kararlılığı analiz edilmekte; önerilen ESA–ÇY-UKSB–Dönüştürücü modelinin eğitim/doğrulama davranışı ve DEHB ile belirlenen üst değişkenleri sunulmaktadır. Kimlik tanımlama başarımı; deney protokolleri, temel sınıflandırıcılar, aday sıralama ölçütleri, kanal–bant başarımları, çok ölçekli bant dalları ve bileşen çıkarma deneyleri bakımından incelenmektedir. Çalışmadaki tüm süreçler Python 3.11.9 kullanılarak yürütülmüştür. Derin öğrenme modellerinde PyTorch 2.5.1, sayısal hesaplamalarda NumPy 1.26.4 ve SciPy 1.13.1, makine öğrenmesi ve başarım değerlendirmesinde scikit-learn 1.5.2, veri düzenlemede pandas 2.2.3 ve görselleştirmede Matplotlib 3.9.2 kullanılmıştır. Hesaplamalar Windows 11 işletim sistemi altında, 12. Nesil Intel Core i7-12700H işlemci, NVIDIA GeForce RTX 3060 GPU ve 16 GB RAM bulunan bir sistemde gerçekleştirilmiştir. Derin öğrenme modelleri, üst değişken eniyilemesi ve testler PyTorch'un CUDA 12.1 destekli GPU hızlandırma altyapısı kullanılarak yürütülmüştür.

4.1 Oslo Üniversitesi USYM Dinlenim Durumu EEG Veri Kümesi Senaryoları ve Nüfusbilimsel Analizi

Oslo Üniversitesi USYM dinlenim durumu EEG veri kümesi, bu tezde önerilen EEG tabanlı biyometrik kimlik tanımlama sisteminin deneysel olarak değerlendirilmesi için temel veri kaynağı olarak kullanılmıştır. Veri kümesinin tercih edilmesindeki temel gerekçe, sağlıklı bireylerden standartlaştırılmış kayıt koşulları altında elde edilmiş dinlenim durumu EEG kayıtlarını içermesi, geniş katılımcı sayısına sahip olması, iki oturumlu bir alt küme sunması ve BGVY uyumlu açık erişimli bir yapı sağlamasıdır. Bu özellikler, EEG biyometrisi açısından özellikle üç kritik deneysel ihtiyacı karşılamaktadır: bireyler arası ayırt edici EEG örüntülerinin incelenmesi, oturumlar arası

genellenebilirliğin sınanması ve tek kanallı EEG temsillerinin pratik biyometrik sistemler açısından değerlendirilmesi.

Deneysel sonuçların doğru yorumlanabilmesi için, kullanılan veri kümesinin yalnızca kayıt sayısı veya kanal sayısı bakımından değil, aynı zamanda katılımcı profili, oturum yapısı, yaş/cinsiyet dağılımı ve kayıtlar arasındaki zaman aralığı bakımından da ayrıntılı biçimde incelenmesi gerekmektedir. EEG işaretleri; yaşa bağlı sinir işlevbilimsel değişimler, cinsiyete bağlı olası fizyolojik farklılıklar, bireysel beyin ritmi varyasyonları, kayıt oturumları arasındaki zaman farkı, elektrot yerleşimindeki küçük değişiklikler ve katılımcının kayıt sırasındaki fizyolojik durumu gibi çok sayıda etkene duyarlıdır. Bu nedenle, EEG tabanlı biyometrik kimlik tanımlama çalışmalarında model başarısı yalnızca sınıflandırıcı mimarisi veya öznitelik çıkarım yöntemiyle açıklanamaz; veri kümesinin yapısı ve nüfusbilimsel özellikleri de sonuçların güvenilirliği, genellenebilirliği ve yeniden üretilebilirliği üzerinde belirleyici rol oynar.

Bu alt bölümde, USYM veri kümesinin deneysel analizlerde nasıl kullanıldığı ve hangi alt senaryolar üzerinden değerlendirildiği açıklanmaktadır. İlk olarak veri kümesinin katılımcı sayısı, tek oturumlu ve iki oturumlu alt kümeleri, cinsiyet dağılımı, yaş profili ve iki oturum arasındaki süre dağılımı incelenmiştir. Ardından, tez kapsamında önerilen BÇS–Wasserstein ÜÇA tabanlı gürültü tespit ve giderim yaklaşımının değerlendirilmesine temel oluşturan yapay ve gerçek EEG senaryoları tanımlanmıştır. Böylece, izleyen alt bölümlerde raporlanacak gürültü giderim başarımı, model eğitim süreci, üst değişken eniyilemesi ve kapalı-küme kimlik tanımlama sonuçları için deneysel bağlam oluşturulmuştur.

USYM veri kümesi toplam $N = 111$ katılımcıdan oluşmaktadır. Bu katılımcıların $N = 69$'u yalnızca tek oturuma, $N = 42$'si ise iki ayrı kayıt oturumuna sahiptir. Tezin ana oturumlar arası kimlik tanımlama deneyleri, yalnızca iki oturumu bulunan 42 katılımcı üzerinde gerçekleştirilmiştir. Bunun nedeni, oturumlar arası değerlendirme protokolünde modelin bir oturumdan öğrenip farklı bir oturumda test edilmesinin gerekli olmasıdır. Tek oturumu bulunan 69 katılımcı ise ana kapalı-küme oturumlar arası deneylere doğrudan dâhil edilmemiş; ancak veri kümesinin genel nüfusbilimsel yapısını ve ileride açık-küme veya kayıtlı olmayan kullanıcı senaryoları için kullanılabilecek potansiyel alt kümeyi temsil etmesi bakımından analiz edilmiştir.

Bu tezde deneysel değerlendirme üç ana veri kullanım düzeyi üzerinden kurgulanmıştır. Birinci dü-

zey, tüm veri kümesinin nüfusbilimsel ve yapısal tanımlanmasını kapsamaktadır. Bu düzeyde 111 katılımcının tamamı yaş, cinsiyet ve oturum yapısı açısından incelenmiştir. İkinci düzey, iki oturumlu 42 katılımcının kapalı-küme oturumlar arası kimlik tanımlama deneylerinde kullanılmasıdır. Bu düzeyde birinci oturum eğitim, ikinci oturum test verisi olarak ele alınmış; ayrıca ters yönlü oturumlar arası değerlendirmeyle ikinci oturumdan eğitim ve birinci oturumdan test yapılan karşılaştırmalı bir senaryo oluşturulmuştur. Üçüncü düzey ise gürültü tespit ve giderim yaklaşımının değerlendirilmesi için yapay EEG ve gerçek EEG işaretleri üzerinde kontrollü gürültü enjeksiyon senaryolarının oluşturulmasıdır. Bu üç düzeyli deneysel kurgu, hem veri kümesinin doğal yapısını hem de önerilen yöntem bileşenlerinin kontrollü koşullardaki davranışını değerlendirmeye olanak sağlamaktadır.

Dinlenim durumu EEG kayıtları, dış uyaranlara bağlı olay-zamanlı cevaplardan bağımsız olarak beynin doğal/kendiliğinden etkinliğini yansıttığı için EEG biyometrisi açısından önemli bir veri türüdür. Gözler kapalı dinlenim durumu koşulunda özellikle arka alfa ritimleri, düşük frekanslı salınımlar, bireye özgü spektral eğilimler ve zamansal düzenlilik ölçütleri daha doğal koşullarda gözlemlenebilir. Bununla birlikte dinlenim durumu EEG işaretleri dikkat düzeyi, uyanıklık, yorgunluk, göz kırpma, göz hareketi, kas etkinliği, elektrot empedansı ve kayıt ortamı gibi etkenlerden etkilenmektedir. Bu özellik, veri kümesini biyometrik açıdan değerli kılarken aynı zamanda gerçekçi bir zorluk da oluşturmaktadır. Dolayısıyla USYM veri kümesi üzerinde kurgulanan deneysel senaryolar, EEG tabanlı kimlik tanımlama sisteminin yalnızca ideal koşullarda değil, oturumlar arası değişkenlik ve fizyolojik bozulma etkileri altında da değerlendirilmesine olanak tanır.

4.1.1 Nüfusbilimsel analiz sonuçları

Bu tez kapsamında kullanılan USYM dinlenim durumu EEG veri kümesinde yer alan katılımcıların nüfusbilimsel profili; cinsiyet, yaş ve oturum yapısı bakımından incelenmiştir. Nüfusbilimsel analiz, yalnızca veri kümesini betimlemek amacıyla yapılmamış; aynı zamanda sınıflandırma sonuçlarının yorumlanmasında dikkate alınması gereken potansiyel karıştırıcı değişkenleri belirlemek için de kullanılmıştır. EEG ritimlerinin yaşla birlikte değişebilmesi, bazı frekans bantlarında bireyler arası farklılıkların yaşa duyarlı olabilmesi ve örneklemdeki cinsiyet dengesizliğinin modelin genellenebilirliğini etkileyebilmesi nedeniyle, deneysel sonuçlar nüfusbilimsel bağlamdan bağımsız değerlendirilmemelidir.

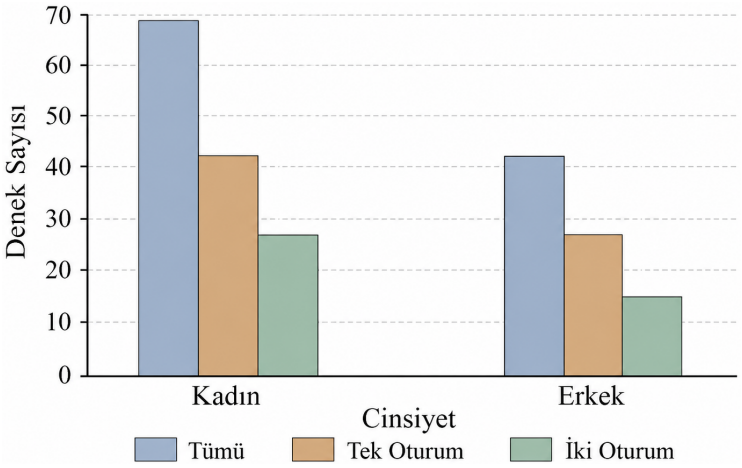

Şekil 4.1 USYM dinlenim durumu EEG veri kümesinde cinsiyet dağılımı

Cinsiyet dağılımı incelendiğinde, tüm veri kümesinde kadın katılımcı sayısının erkek katılımcı sayısından yüksek olduğu görülmektedir. Toplam 111 katılımcının 69'u kadın, 42'si erkektir. Bu dağılım tek oturumlu ve iki oturumlu alt kümelerde de benzer biçimde korunmaktadır. Tek oturumlu alt kümede 42 kadın ve 27 erkek katılımcı bulunurken, iki oturumlu alt kümede 27 kadın ve 15 erkek katılımcı yer almaktadır. Bu yapı, veri kümesinde kadın katılımcıların daha yüksek oranda temsil edildiğini göstermektedir. Bununla birlikte, her iki cinsiyetin hem tek oturumlu hem de iki oturumlu alt kümelerde temsil edilmesi, cinsiyet dağılımının yalnızca belirli bir oturum yapısına özgü olmadığını göstermektedir. Cinsiyet dağılımındaki bu dengesizlik, model sonuçlarının yorumlanmasında göz önünde bulundurulması gereken bir veri kümesi özelliğidir. EEG işaretlerinde cinsiyete bağlı olası farklılıkların etkisi bu tezin ana araştırma konusu olmamakla birlikte, biyometrik sistemlerde örneklem dengesizliği modelin belirli alt gruplar üzerinde daha yüksek veya daha düşük başarım göstermesine neden olabilir. Bu nedenle, ana sınıflandırma sonuçları genel başarım üzerinden raporlanırken, tartışma bölümünde veri kümesinin nüfusbilimsel dengesizliği olası bir sınırlılık olarak değerlendirilmelidir. Şekil 4.1'de USYM veri kümesindeki cinsiyet dağılımı tüm katılımcılar, tek oturumlu katılımcılar ve iki oturumlu katılımcılar için karşılaştırmalı olarak sunulmaktadır.

Yaş dağılımı açısından veri kümesi geniş bir aralıkta katılımcı içermektedir. Bu durum, EEG biyometrisi açısından iki yönlü bir katkı sunmaktadır. Birincisi, geniş yaş aralığı veri kümesinin farklı yaş gruplarını temsil etmesini sağlayarak modelin yalnızca dar bir yaş grubuna özgü örüntüler üzerinden değerlendirilmesini engellemektedir. İkincisi, yaşın EEG spektral özellikleri üzerindeki etkisi nedeniyle, geniş yaş aralığı aynı zamanda modelin yaşa bağlı fizyolojik değişkenlik altında

nasıl davrandığını dolaylı olarak sınama olanağı sunmaktadır. Şekil 4.2'de verilen üç boyutlu histogram, tüm veri kümesi, tek oturumlu alt küme ve iki oturumlu alt küme için yaş frekanslarını karşılaştırmalı olarak göstermektedir. Üç boyutlu yaş dağılımı incelendiğinde, yaşların genç yetişkinlikten ileri yetişkinlik dönemine kadar uzandığı ve örneklemin özellikle genç–orta yaş aralığında yoğunlaştığı görülmektedir. Tek oturumlu katılımcılar görece daha düşük yaşlara doğru yoğunlaşırken, iki oturumlu katılımcıların yaş dağılımı daha ileri yaşlara doğru kaymaktadır. Bu bulgu, ana oturumlar arası deneylerde kullanılan 42 kişilik alt kümenin tüm veri kümesini yaş bakımından birebir temsil etmediğini göstermektedir. Dolayısıyla oturumlar arası kimlik tanımlama sonuçları yorumlanırken, iki oturumlu alt kümenin yaş yapısının genel veri kümesinden bir miktar farklılaşabileceği dikkate alınmalıdır.

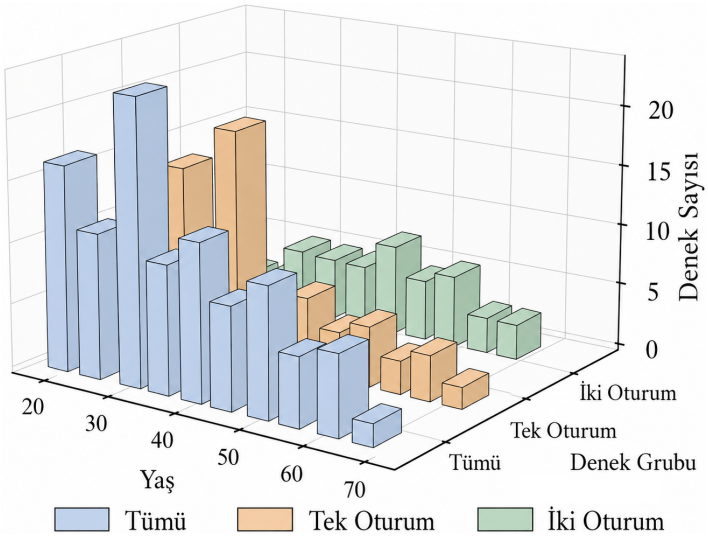

Şekil 4.2 Denek yaş dağılımlarının üç boyutlu histogram ile gösterimi

Yaş dağılımının merkezi eğilim ve yayılım özellikleri Şekil 4.3'te notch'lu kutu grafikleriyle ayrıntılı olarak verilmiştir. Tüm veri kümesinde medyan yaş 35 olarak hesaplanırken, tek oturumlu grupta medyan yaş 32'ye düşmekte, iki oturumlu grupta ise 39,5'e yükselmektedir. Ortalama yaş değerleri de benzer bir eğilim göstermektedir. Tüm veri kümesi için ortalama yaş 37,6, tek oturumlu grup için 35,8 ve iki oturumlu grup için 40,6 olarak raporlanmıştır. Bu sonuçlar, iki oturumlu alt kümenin tek oturumlu alt kümeye kıyasla daha yüksek yaş ortalamasına sahip olduğunu göstermektedir. Bu yaş farklılığı, oturumlar arası değerlendirme açısından önemlidir. Çünkü iki oturumlu alt küme, bu tezin ana kapalı-küme deneylerinde kullanılan temel katılımcı grubudur. Eğer iki oturumlu katılımcılar yaş bakımından tüm veri kümesinden farklılaşıyorsa, elde edilen oturumlar arası başarım değerleri bu alt kümenin nüfusbilimsel yapısıyla birlikte yorumlanmalıdır.

Bununla birlikte, yaş dağılımlarının tamamen ayrışmadığı ve belirli ölçüde örtüştüğü görülmektedir. Bu durum, yaş değişkeninin deneysel sonuçları tek başına belirleyen bir etken olarak değil, olası bir karıştırıcı değişken olarak dikkate alınması gerektiğini göstermektedir.

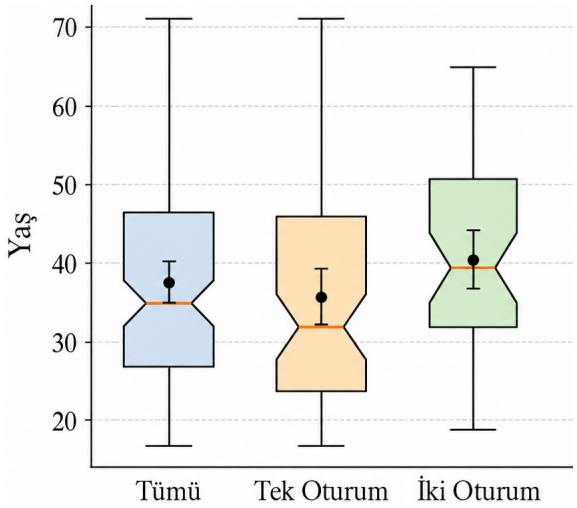

Şekil 4.3 Yaş dağılımının oturum tipine göre karşılaştırılması

İki oturumlu katılımcılar için oturumlar arasındaki süre dağılımı, EEG biyometrisinde zamansal kararlılığın değerlendirilmesi açısından ayrıca önem taşımaktadır. Aynı bireyden farklı zamanlarda alınan EEG kayıtları; elektrot yerleşimindeki küçük farklılıklar, empedans değişimleri, katılımcının fizyolojik durumu, dikkat/yorgunluk düzeyi ve kayıt koşullarındaki küçük değişimler nedeniyle farklılık gösterebilir. Bu nedenle iki oturum arasındaki zaman aralığı, oturumlar arası biyometrik genellenebilirliği etkileyebilecek temel değişkenlerden biridir.

Şekil 4.4'te iki oturumlu katılımcılar için oturumlar arasındaki süre dağılımı histogram ve empirik kümülatif dağılım işlevi (EKDİ) ile gösterilmektedir. Histogram ve EKDİ birlikte incelendiğinde, oturumlar arası sürelerin tek bir dar aralıkta yoğunlaşmadığı, bunun yerine farklı zaman ölçeklerini temsil eden bir dağılım yapısı sergilediği görülmektedir. Bazı katılımcılarda iki kayıt oturumu arasındaki süre birkaç ay düzeyindeyken, bazı katılımcılarda bu aralık yaklaşık bir yıla yaklaşmaktadır. Bu yapı, veri kümesinin yalnızca kısa süreli tekrar kayıt senaryosunu değil, daha uzun aralıklı yeniden kayıt koşullarını da kısmen temsil ettiğini göstermektedir. Bu dağılımın biyometrik açıdan önemi, modelin yalnızca aynı gün veya kısa aralıklı tekrar kayıt koşullarına değil, daha uzun zaman aralıklarında korunabilen bireye özgü örüntülere de dayanıp dayanmadığını değerlendirme olanağı sunmasıdır. Medyan, ortalama ve çeyrekler arası aralık gibi istatistikler, oturum aralığı değişkeninin simetrik veya normal dağılıma yakın bir yapı göstermediğini düşündürmek-

tedir. Bu nedenle oturumlar arası süre değişkeni, sonuçların yorumlanmasında basit bir ortalama değerle sınırlı kalmadan dağılım yapısıyla birlikte ele alınmalıdır.

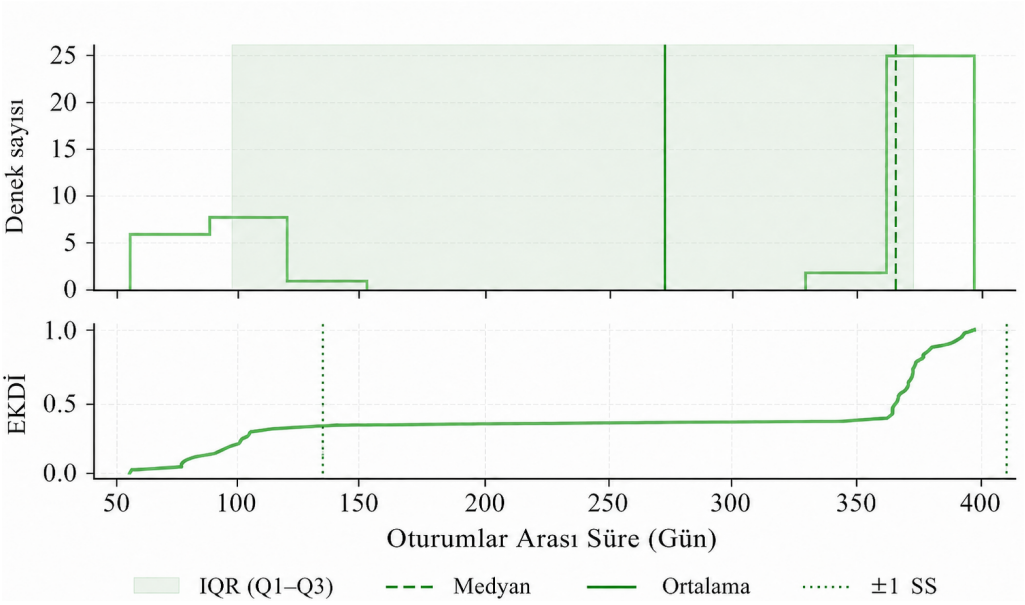

Şekil 4.4 İki oturumlu deneklerde oturumlar arası süre dağılımı

Oturumlar arası sürenin cinsiyete göre değişip değişmediği Şekil 4.5'te keman–kutu görselleştirmesiyle incelenmiştir. Kadın ve erkek katılımcılar için dağılımların büyük ölçüde örtüştüğü görülmektedir. Bu durum, iki oturum arasındaki sürenin cinsiyete bağlı belirgin bir sistematik farklılık göstermediğini düşündürmektedir. Her iki cinsiyet grubunda da kısa ve uzun aralıklı tekrar kayıtların bulunması, oturum aralığı değişkeninin daha çok katılımcı erişilebilirliği, yeniden çağırma planı ve operasyonel kayıt takvimi gibi etkenlerle ilişkili olabileceğini göstermektedir. Bu bulgu, ana sınıflandırma deneyleri açısından olumlu bir sonuçtur. Çünkü eğer oturumlar arası süre yalnızca belirli bir cinsiyet grubunda sistematik olarak daha uzun veya daha kısa olsaydı, oturumlar arası başarım sonuçlarının yorumlanmasında cinsiyet ve zaman aralığı etkilerinin ayrıştırılması daha güç hâle gelebilirdi. Mevcut dağılımda ise cinsiyet grupları arasında belirgin bir oturum aralığı ayrışması gözlenmediğinden, oturumlar arası değişkenliğin daha çok kayıt zamanı ve fizyolojik durum gibi bireysel/operasyonel değişkenlerle ilişkili olduğu değerlendirilebilir.

Nüfusbilimsel bulgular birlikte değerlendirildiğinde, USYM veri kümesinin EEG biyometrisi açısından zengin fakat belirli sınırlılıklar taşıyan bir örneklem sunduğu görülmektedir. Veri kümesi toplam 111 katılımcı içermesi bakımından dinlenim durumu EEG tabanlı biyometrik çalışmalar için güçlü bir örneklem sağlamakta; ancak ana oturumlar arası deneyler yalnızca iki oturumu bu-

lunan 42 katılımcı üzerinde yürütülebilmektedir. Cinsiyet dağılımında kadın katılımcıların daha yüksek oranda temsil edilmesi ve iki oturumlu alt kümenin yaş ortalamasının daha yüksek olması, sonuçların yorumlanmasında dikkate alınması gereken nüfusbilimsel özelliklerdir. Buna karşılık oturumlar arası sürenin farklı zaman aralıklarını kapsaması, modelin hem kısa hem de daha uzun aralıklı yeniden kayıt koşullarındaki kararlılığını sınamak açısından avantaj sağlamaktadır. Bu nedenle bu analiz, izleyen sınıflandırıcı başarım sonuçlarının yalnızca sayısal başarı değerleriyle değil, veri kümesinin yapısal bağlamı içinde yorumlanması gerektiğini göstermektedir.

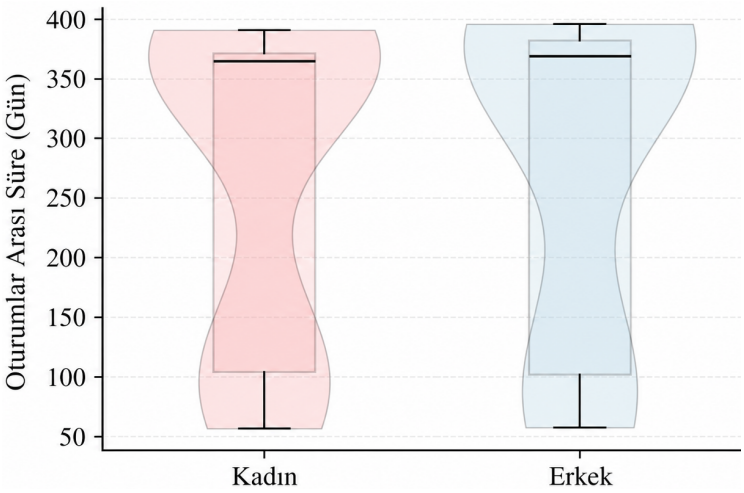

Şekil 4.5 Cinsiyete göre iki oturum arasındaki süre dağılımı

4.1.2 Deney protokolleri ve veri bölümleme yöntemi

Tez kapsamında deneysel değerlendirme, kapalı-küme EEG tabanlı kimlik tanımlama problemi ve gürültüye dayanıklı işaret iyileştirme hedefleri doğrultusunda yapılandırılmıştır. Bu nedenle veri bölümleme yöntemi iki ana amaç etrafında düzenlenmiştir. Birinci amaç, iki oturumlu katılımcılar üzerinde oturumlar arası kimlik tanımlama başarısını gerçekçi biçimde değerlendirmektir. İkinci amaç ise BÇS–Wasserstein ÜÇA tabanlı gürültü tespit ve giderim yaklaşımının hem kontrollü yapay işaretler hem de gerçek EEG işaretleri üzerinde nasıl davrandığını incelemektir. Bu iki amaç, deneysel sonuçlar bölümünün genel akışını da belirlemektedir.

Kapalı-küme kimlik tanımlama deneylerinde ana değerlendirme, iki oturumu bulunan 42 katılımcı üzerinden yapılmıştır. Bu deneysel kurguda her katılımcı kayıtlı bir kimlik sınıfı olarak ele alınmış ve modelin görevi her test EEG penceresini bu 42 kayıtlı bireyden biriyle eşleştirmek olarak tanımlanmıştır. Ana protokolde birinci oturum eğitim, ikinci oturum test verisi olarak kullanılmıştır.

Bu yapı, aynı bireye ait farklı zamanda kaydedilmiş EEG işaretleri üzerinden modelin oturumlar arası genellenebilirliğini değerlendirmeye olanak sağlamaktadır. Aynı oturum içi protokol, modelin idealize edilmiş ve daha kolay bir senaryodaki başarısını görmek için; ters yönlü oturumlar arası protokol ise eğitim ve test oturumlarının yön değiştirmesine karşı model kararlılığını incelemek için kullanılmıştır.

Gürültü tespit ve giderim yaklaşımının değerlendirilmesi için ise veri gerçekçiliği ve kontrol düzeyi bakımından birbirini tamamlayan iki deney senaryosu oluşturulmuştur. Birinci senaryoda, istatistiksel özellikleri kontrollü biçimde tanımlanan yapay EEG referans işaretleri kullanılmıştır. Bu senaryoda temiz referans işaret bilindiği için, gürültü enjeksiyonu sonrasında elde edilen bozulmuş işaret ile yeniden yapılandırılmış işaret arasındaki fark nicel olarak değerlendirilebilmiştir. Böylece önerilen yöntemin yeniden yapılandırma doğruluğu, İGO, OMH, KOKH ve spektral benzerlik gibi ölçütlerle daha kontrollü biçimde analiz edilebilmiştir.

İkinci senaryoda, gerçek deney koşullarında kaydedilmiş EEG işaretleri temel alınmıştır. Bu işaretler, ölçüm sürecine özgü doğal değişkenlikleri, fizyolojik dalgalanmaları ve gerçek EEG'nin karmaşık istatistiksel yapısını içermektedir. Bu nedenle gerçek EEG üzerine kontrollü biçimde EMG ve EOG bileşenlerinin eklenmesi, önerilen yöntemin yalnızca idealize edilmiş yapay işaretlerde değil, gerçek EEG işaret yapısı altında da sınanmasına olanak sağlamıştır. Bu iki senaryonun birlikte kullanılması, gürültü giderme yaklaşımının hem kontrollü koşullardaki temel işaret işleme başarısını hem de gerçekçi biyometrik uygulamalara aktarılabilirliğini değerlendirmek açısından önemlidir.

Gürültü enjeksiyon sürecinde kullanılan genel model, temiz işaret üzerine farklı istatistiksel ve fizyolojik karakteristiklere sahip bozulma bileşenlerinin eklenmesine dayanmaktadır. Birinci senaryoda referans olarak kullanılan temiz yapay EEG işareti $x_{sen}[m]$, ikinci senaryoda kullanılan temiz gerçek EEG işareti ise $x_{ger}[m]$ ile gösterilmiştir. Bu işaretlere eklenen toplam gürültü $n[m]$, Gauss dağılımlı elektronik/ölçümsel gürültü, EMG kaynaklı kas etkinliği bileşeni ve EOG kaynaklı göz hareketi/göz kırpma bileşenlerinin toplamı olarak modellenmiştir. Toplam gürültü modeli aşağıdaki şekilde ifade edilmiştir:

$$n[m] = A_{gauss}\mathcal{N}(0, \sigma^2) + n_{EMG}[m] + n_{EOG}[m] \tag{4.1}$$

Burada $\mathcal{N}(0, \sigma^2)$, ortalaması sıfır ve varyansı σ^2 olan Gauss dağılımlı rastgele süreci; A_{gauss}, Gauss gürültüsünün genlik katsayısını; $n_{EMG}[m]$, EMG kaynaklı kas etkinliği bozulmasını; $n_{EOG}[m]$ ise göz hareketi ve göz kırpma kaynaklı EOG bozulmasını temsil etmektedir. Gauss gürültüsü, ölçüm zincirinde oluşabilecek elektronik ve rastgele bozulmaları temsil etmek için kullanılmıştır. EMG ve EOG bileşenleri ise EEG kayıtlarında yaygın olarak gözlenen fizyolojik bozulmaları modellemek amacıyla dâhil edilmiştir. Bu yapı, tek bir gürültü türüne dayalı basitleştirilmiş bir senaryo yerine, gerçek kayıt koşullarında karşılaşılabilecek birleşik bozulma yapısını daha iyi temsil etmektedir.

EMG kaynaklı gürültü, yüz, çene, alın ve boyun kasları gibi kafa derisine yakın kas gruplarından kaynaklanan eylem potansiyellerinin EEG elektrotlarına yansımasıyla oluşmaktadır. Bu tür bozulmalar genellikle düzensiz, kısa süreli, geniş bantlı ve yüksek frekans içeriği zengin bileşenler üretmektedir. Özellikle beta ve gama aralıklarına doğru uzanan yüksek frekanslı enerji artışları, EEG biyometrisinde kullanılan spektral öznitelikleri ve kanal–bant analizlerini doğrudan etkileyebilir. Bu çalışmada EMG kaynaklı bozulmalar aşağıdaki sembolik model ile temsil edilmiştir:

$$n_{EMG}[m] = \sum_{i=1}^{N} A_i e^{-\frac{m-m_i}{\tau_i}} u[m - m_i] \tag{4.2}$$

Burada N, işareti etkileyen kas etkinliği benzeri potansiyel bileşen sayısını; A_i, i. bileşenin genlik katsayısını; m_i, ilgili bileşenin başlangıç zamanını; τ_i, sönümleme sabitini ve $u[m]$, birim basamak işlevini göstermektedir. Bu model, kas etkinliği kaynaklı bozulmaların ani başlangıçlı ve sönümlenen yapısını temsil etmektedir. EMG bileşenlerinin yüksek frekans içeriği nedeniyle, bu bozulmalar özellikle yüksek beta ve gama bantlarındaki biyometrik ayırt edici bilginin değerlendirilmesini zorlaştırabilir.

EOG bozulmaları ise göz kırpma ve göz hareketleri sırasında kornea–retina potansiyelindeki değişimlerin EEG elektrotlarına yansıması sonucu oluşmaktadır. EOG bozulmaları çoğunlukla düşük frekanslı ve yüksek genlikli dalgalanmalar biçiminde gözlenir. Göz kırpma olayları kısa süreli fakat yüksek genlikli sapmalar oluştururken, göz hareketleri daha uzun süreli bazal kaymalara neden olabilir. Bu nedenle EOG bileşenleri, özellikle delta ve teta gibi düşük frekans bantlarının enerji dağılımını bozabilir ve zaman bölgesi istatistiklerini etkileyebilir. Bu çalışmada EOG gürültüsü, göz kırpma olaylarını Gauss benzeri darbelerle, göz hareketlerini ise adım işlevleriyle temsil eden

karma bir yapı olarak aşağıdaki şekilde modellenmiştir:

$$n_{EOG}[m] = \sum_{j=1}^{N_{yonelim}} B_j \exp\left(-\frac{(m-m_j)^2}{2\sigma^2_{yonelim}}\right) + \sum_{k=1}^{N_{goz\ hareketi}} D_k u[m-d_k] \qquad (4.3)$$

Burada B_j, j. göz kırpma bileşeninin genliğini; $\sigma^2_{yonelim}$, ilgili bileşenin zamansal genişliğini; m_j, göz kırpma olayının merkez zamanını; D_k, göz hareketine bağlı adım bileşeninin genliğini ve d_k, ilgili göz hareketi olayının başlangıç zamanını göstermektedir. Bu yapı, EOG bozulmalarının hem ani yüksek genlikli kırpma etkilerini hem de daha yavaş değişimli göz hareketi kaynaklı sapmalarını birlikte temsil etmektedir.

Yapay ve gerçek EEG işaretleri için kullanılan temiz referans örnekleri, zaman ve frekans bölgelerindeki temel özellikleriyle birlikte Şekil 4.6 ve Şekil 4.7'de sunulmuştur. Bu gösterimlerin temel amacı, kontrollü deneylerde kullanılmak üzere oluşturulan yapay EEG işaretinin zamansal dalga biçimi ve spektral enerji dağılımı bakımından gerçek EEG işaretleriyle benzerlik gösterip göstermediğini incelemektir. Birinci deney senaryosunda kullanılan temiz yapay EEG işaretinin zaman bölgesindeki örnek dalga biçimi ve aynı işaretin güç spektral yoğunluğu dağılımı Şekil 4.6'da verilmiştir. İkinci deney senaryosuna temel oluşturan ve deneysel kayıt sürecinde elde edilen temiz gerçek EEG işaretinin zaman bölgesindeki örnek görünümü ve bu işarete ait güç spektral yoğunluğu dağılımı Şekil 4.7'de sunulmuştur.

Zaman bölgesindeki gösterimler, işaretlerin genlik değişimlerini, salınım sürekliliğini, kısa süreli dalgalanmalarını ve durağan olmayan yapılarını karşılaştırmaya olanak sağlamaktadır. Frekans bölgesindeki gösterimler ise işaret enerjisinin farklı frekans bileşenlerine nasıl dağıldığını, düşük ve orta frekans bölgelerindeki baskınlık düzeylerini ve yapay işaretin EEG'ye özgü spektral yapıyı ne ölçüde yansıttığını incelemek amacıyla kullanılmıştır. Böylece yapay EEG işaretinin yalnızca görsel olarak dalgalı bir işaret üretmesi değil, aynı zamanda gerçek EEG işaretlerinde gözlenen zamansal ve spektral özelliklere yaklaşması da değerlendirilmiştir.

Şekil 4.6'da sunulan temiz yapay EEG işareti, tekdüze veya tamamen düzenli bir salınım yerine, zaman içerisinde genliği ve salınım örüntüsü değişen bir yapı sergilemektedir. Bu özellik, gerçek EEG işaretlerinin durağan olmayan yapısını yaklaşık olarak temsil edebilmek açısından önemlidir. Kontrollü biçimde oluşturulan işaretin ani ve fizyolojik açıdan açıklanması güç genlik sıçramaları içermemesi, daha sonraki aşamada eklenecek EMG ve EOG kaynaklı bozulmaların etkisinin daha

açık biçimde izlenmesine olanak sağlamaktadır. Dolayısıyla bu işaret, gürültü enjeksiyonu öncesindeki temiz başlangıç durumunu temsil eden bir referans olarak kullanılmıştır.

Şekil 4.6'da verilen güç spektral yoğunluğu dağılımı, yapay EEG işaretindeki toplam enerjinin frekans ekseni boyunca nasıl dağıldığını göstermektedir. Spektral gösterim, yapay işaretin yalnızca zaman bölgesindeki görünümüyle değil, EEG biyometrisi açısından önemli olan frekans içeriği bakımından da değerlendirilmesini sağlamaktadır. Özellikle düşük ve orta frekans bölgelerinde gözlenen enerji dağılımı, yapay işaretin gerçek EEG işaretlerine benzer temel salınım özellikleri içerecek biçimde oluşturulduğunu göstermektedir. Bununla birlikte bu spektral yapının gerçek EEG'deki tüm bireysel, fizyolojik ve ölçümsel değişkenlikleri eksiksiz biçimde temsil ettiği ileri sürülmemektedir.

Şekil 4.7'de sunulan gerçek EEG işareti, yapay EEG işaretine kıyasla daha karmaşık ve düzensiz bir zamansal yapı sergilemektedir. Bu karmaşıklık; merkezi sinir sistemi etkinliğinin doğal değişkenliğinin yanı sıra katılımcının fizyolojik durumu, elektrot–deri etkileşimi ve kayıt koşullarından kaynaklanabilecek küçük değişimleri de yansıtmaktadır. Gerçek EEG işaretindeki kısa süreli genlik değişimleri ve düzensiz salınım örüntüleri, uygulamaya yakın koşullarda gürültü tespit ve giderim yöntemlerinin karşılaşacağı işaret yapısını temsil etmektedir. Bu nedenle gerçek EEG örneği, önerilen yaklaşımın idealize edilmiş işaretlerin ötesindeki dayanıklılığının değerlendirilmesi açısından temel referans niteliğindedir.

Şekil 4.7'de gösterilen güç spektral yoğunluğu dağılımı, gerçek EEG işaretinin farklı frekans bileşenlerinde taşıdığı enerji miktarını ortaya koymaktadır. Yapay işarete kıyasla daha düzensiz bir spektral görünüm sergilenmesi, gerçek EEG kayıtlarının fizyolojik ve ölçümsel değişkenlik içeren karmaşık yapısıyla uyumludur. Bu spektral dağılım, daha sonraki gürültü enjeksiyonu ve yeniden yapılandırma aşamalarında işaretin frekans içeriğinin ne ölçüde değiştiğini değerlendirebilmek için temiz referans olarak kullanılmıştır. Özellikle EEG biyometrisinde ayırt edici bilgi taşıyabilecek bant içi enerji örüntülerinin korunması gerektiğinden, gerçek işarete ait bu dağılım yeniden yapılandırma başarımının yorumlanmasında önemli bir karşılaştırma temeli oluşturmaktadır.

Temiz yapay ve gerçek EEG örnekleri birlikte değerlendirildiğinde, her iki işaret türünün de zaman içerisinde değişen, dalgalı ve durağan olmayan bir yapı taşıdığı görülmektedir. Yapay EEG işaretinin düşük ve orta frekans bileşenleri içermesi ve enerjisinin belirli bir frekans bölgesinde tek

bir keskin bileşen üzerinde toplanmaması, kontrollü gürültü enjeksiyon deneyleri için uygun bir başlangıç işareti oluşturduğunu göstermektedir. Buna karşılık gerçek EEG işareti, fizyolojik süreçlerden ve kayıt koşullarından kaynaklanan daha yüksek düzeyde zamansal ve spektral değişkenlik içermektedir. Bu farklılık, yapay ve gerçek EEG senaryolarının birbirinin yerine geçen değil, birbirini tamamlayan iki deneysel değerlendirme düzeyi olarak ele alınmasını gerektirmektedir.

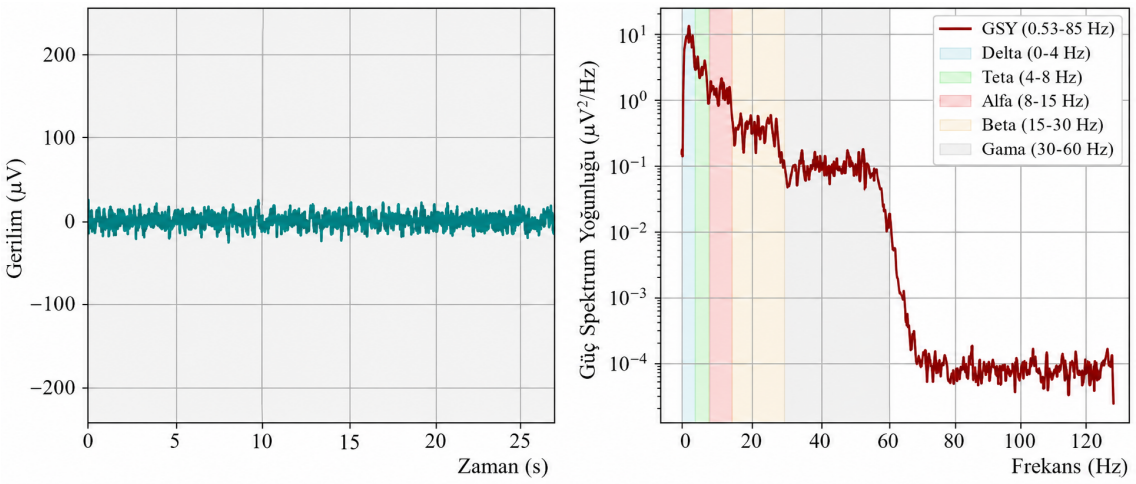

Şekil 4.6 Kontrollü deney koşullarında oluşturulan temiz yapay EEG işaretinin zaman bölgesindeki örnek dalga biçimi ve güç spektral yoğunluğu dağılımı

Yapay EEG senaryosu, temiz referans işaretin ve eklenen bozulma bileşenlerinin önceden bilinmesi nedeniyle yöntemin temel gürültü tespit ve yeniden yapılandırma kapasitesinin kontrollü koşullarda değerlendirilmesini sağlamaktadır. Gerçek EEG senaryosu ise doğal fizyolojik değişkenliği ve ölçüm sürecine özgü düzensizlikleri içerdiğinden, önerilen yaklaşımın uygulamaya daha yakın veri yapıları üzerindeki dayanıklılığının sınanmasına olanak vermektedir. Dolayısıyla yapay işaretin gerçek EEG işaretini tüm ayrıntılarıyla taklit etmesi beklenmemekte; bunun yerine gerçek EEG'ye özgü temel zamansal ve spektral özellikleri kontrollü bir deney ortamında yaklaşık olarak temsil etmesi amaçlanmaktadır.

Gürültü enjeksiyonu sonrasında elde edilen bozulmuş işaret örnekleri, yapay EEG senaryosu için Şekil 4.8'de; gerçek EEG senaryosu için ise Şekil 4.9'da sunulmuştur. Bu şekiller, EMG ve EOG kaynaklı bozulma bileşenlerinin temiz referans işaretlerin zaman bölgesindeki dalga biçimini ve frekans bölgesindeki enerji dağılımını nasıl değiştirdiğini karşılaştırmalı olarak ortaya koymaktadır.

Zaman bölgesinde EMG kaynaklı bozulmaların düzensiz ve kısa süreli genlik değişimleri meydana getirmesi, EOG kaynaklı bozulmaların ise daha yüksek genlikli ve görece yavaş değişen sapmalara yol açması beklenmektedir. Bu etkiler, işaretin taban çizgisinde değişimlere, yerel genlik artışlarına ve özgün EEG salınımlarının kısmen örtülmesine neden olabilmektedir. Frekans bölgesinde ise EOG bileşenleri ağırlıklı olarak düşük frekanslardaki enerji yoğunluğunu değiştirirken, EMG bileşenleri daha geniş bir frekans aralığında ve özellikle yüksek frekans bölgelerinde ek enerji oluşmasına yol açmaktadır. Bu nedenle zaman ve frekans bölgesindeki gösterimlerin birlikte değerlendirilmesi, bozulmanın yalnızca görünür genlik etkisini değil, EEG'nin biyometrik bilgi taşıyan spektral yapısı üzerindeki etkisini de incelemeyi mümkün kılmaktadır.

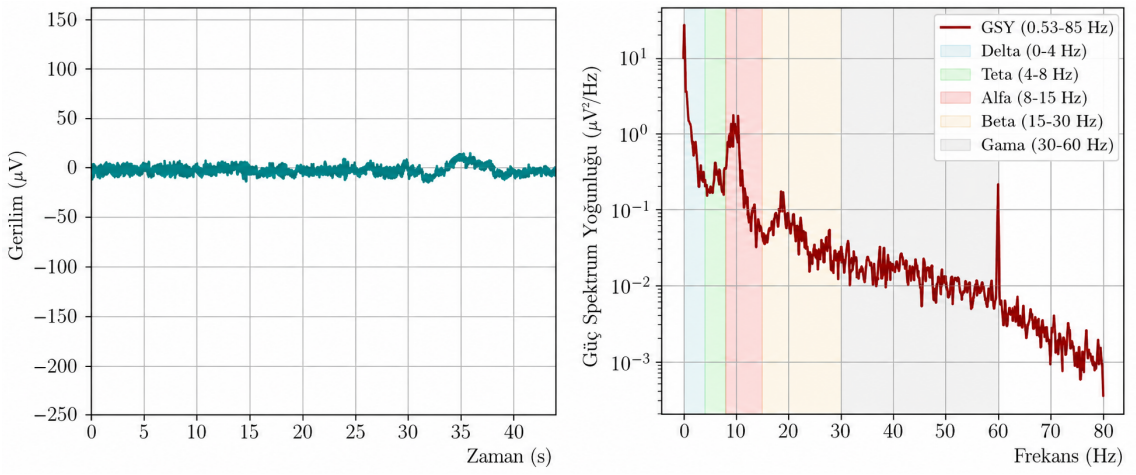

Şekil 4.7 Deneysel kayıt sürecinde elde edilen temiz gerçek EEG işaretinin zaman bölgesindeki örnek dalga biçimi ve güç spektral yoğunluğu dağılımı

Şekil 4.8'de, temiz yapay EEG işaretine EMG ve EOG bileşenlerinin eklenmesi sonucunda ortaya çıkan zamansal bozulmalar gösterilmektedir. Gürültü enjeksiyonu sonrasında işaretin genlik aralığının değişmesi, belirli zaman bölgelerinde ani veya yavaş gelişen sapmaların oluşması ve temiz referans işaretin özgün salınım yapısının kısmen örtülmesi beklenen sonuçlardır. Kontrollü yapay senaryoda temiz işaret ve eklenen gürültü bileşenleri bilindiğinden, gözlenen bu değişimlerin daha sonraki yeniden yapılandırma aşamasında ne ölçüde giderildiği doğrudan değerlendirilebilmektedir.

Şekil 4.8'de verilen güç spektral yoğunluğu dağılımı, gürültü enjeksiyonunun yapay EEG işaretinin frekans içeriğinde meydana getirdiği değişimleri göstermektedir. EOG kaynaklı düşük frekanslı bileşenlerin spektrumun alt bölgelerinde enerji artışı oluşturması, EMG kaynaklı geniş bantlı

bileşenlerin ise daha yüksek frekans bölgelerine yayılan bir enerji artışına neden olması beklenmektedir. Bu spektral değişimler, temiz yapay EEG işaretine ait Şekil 4.6 ile karşılaştırıldığında, bozulma bileşenlerinin bant içi enerji dağılımını ne ölçüde değiştirdiğinin görsel olarak değerlendirilmesine olanak sağlamaktadır.

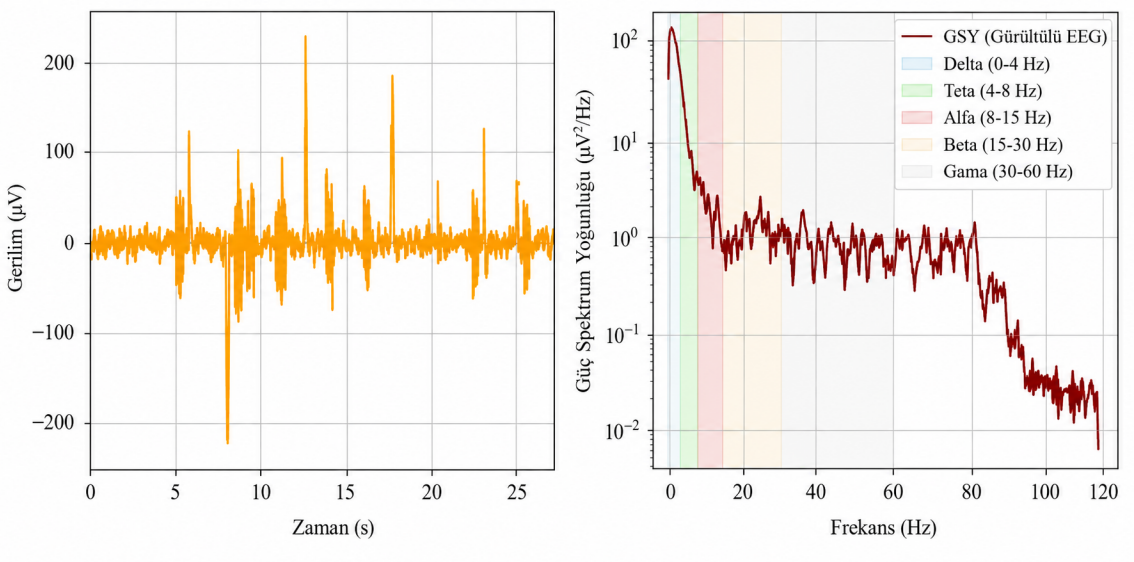

Şekil 4.8 EMG ve EOG kaynaklı yapay gürültü bileşenleri eklenmiş yapay EEG işaretinin zaman bölgesindeki örnek dalga biçimi ve güç spektral yoğunluğu dağılımı

Şekil 4.9'da, gerçek EEG işaretinin doğal zamansal değişkenliği ile kontrollü olarak eklenen EMG ve EOG bileşenlerinin birlikte oluşturduğu bozulmuş işaret yapısı sunulmuştur. Gerçek EEG işaretinin başlangıçta da karmaşık ve durağan olmayan bir yapıya sahip olması, eklenen bozulmaların ayrıştırılmasını yapay EEG senaryosuna göre daha güç hâle getirmektedir. Bu durum, önerilen gürültü tespit ve giderim yaklaşımının yalnızca açık biçimde ayrışan yapay bozulmalara karşı değil, doğal EEG değişkenliğiyle örtüşebilen bozulma örüntülerine karşı da sınanmasını sağlamaktadır.

Şekil 4.9'daki güç spektral yoğunluğu dağılımı, gerçek EEG işaretinin doğal spektral yapısı üzerine eklenen EMG ve EOG bileşenlerinin meydana getirdiği değişimleri göstermektedir. Gerçek EEG işaretinde frekans bileşenleri başlangıçta da değişken bir dağılıma sahip olduğundan, gürültü kaynaklı enerji artışları yapay işaret senaryosundaki kadar belirgin biçimde ayrışmayabilir. Bununla birlikte düşük frekans bölgelerindeki olağan dışı enerji yoğunlaşmaları EOG etkisine, yüksek frekans bölgelerindeki geniş bantlı artışlar ise EMG etkisine ilişkin göstergeler sunmaktadır. Bu karmaşık spektral yapı, yeniden yapılandırma yönteminin gerçekçi EEG koşullarındaki başarımının değerlendirilmesi açısından daha zorlayıcı bir sınama ortamı oluşturmaktadır.

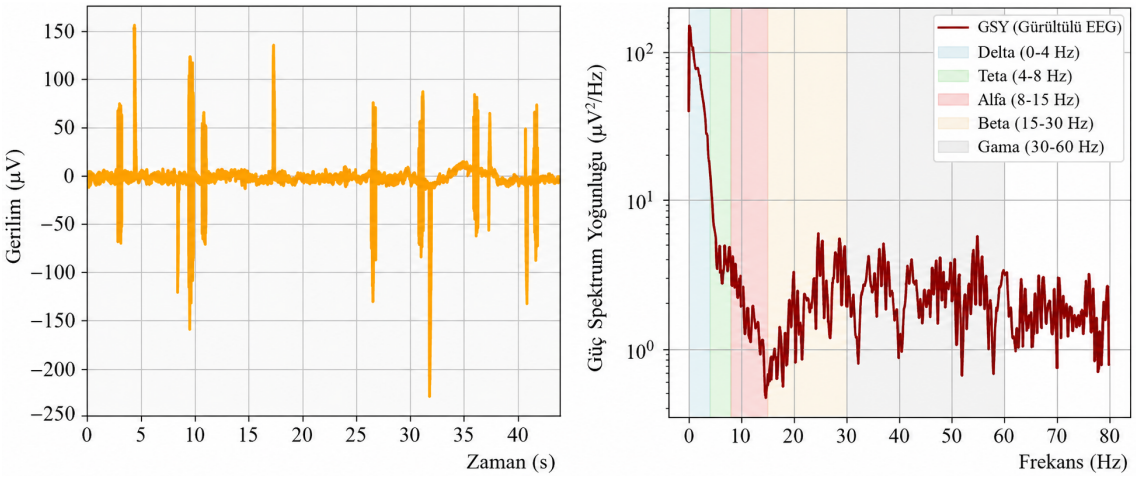

Şekil 4.9 EMG ve EOG kaynaklı yapay gürültü bileşenleri eklenmiş gerçek EEG işaretinin zaman bölgesindeki örnek dalga biçimi ve güç spektral yoğunluğu dağılımı

EMG ve EOG bileşenleriyle oluşturulan bozulmuş işaretler birlikte incelendiğinde, bu iki gürültü türünün EEG işareti üzerinde birbirinden farklı fakat kimi durumlarda örtüşebilen etkiler oluşturduğu görülmektedir. EMG kaynaklı bozulmalar, kas etkinliğinin düzensiz ve geniş bantlı yapısı nedeniyle özellikle orta ve yüksek frekans bölgelerindeki spektral yoğunluğu artırmaktadır. Bu durum, beta ve gama bantlarında bireye özgü biyometrik bilgi taşıyabilecek sinirsel örüntülerin kas etkinliği kaynaklı bileşenlerle karışmasına neden olabilmektedir. Dolayısıyla yüksek frekans bölgelerinde gözlenen her enerji artışının doğrudan sinirsel etkinlik veya biyometrik ayırt edicilik göstergesi olarak yorumlanması uygun değildir.

EOG kaynaklı bozulmalar ise çoğunlukla yüksek genlikli, düşük frekanslı ve görece yavaş değişen yapıları nedeniyle işaretin taban çizgisinde kaymalara, genlik dağılımında belirgin değişimlere ve düşük frekans bandı enerjisinde artışlara yol açmaktadır. Bu etkiler özellikle delta ve teta bantlarında hesaplanan güç, enerji ve karmaşıklık temelli özniteliklerin güvenilirliğini azaltabilir. Ayrıca yüksek genlikli göz kırpma bileşenleri, zaman bölgesindeki hesaplanan KOK, değişinti, çarpıklık ve basıklık gibi istatistiksel ölçütleri de önemli ölçüde etkileyebilir. Bu nedenle bozulma tespitinin yalnızca tek bir zaman veya frekans bölgesi göstergesine dayandırılmaması, birbirini tamamlayan özniteliklerin birlikte kullanılması önem taşımaktadır.

Yapay ve gerçek EEG senaryolarının birlikte kullanılması, önerilen BÇS–Wasserstein ÜÇA tabanlı gürültü tespit ve giderim yaklaşımının farklı veri gerçekçiliği düzeylerinde sistematik olarak

değerlendirilmesine olanak sağlamaktadır. Yapay EEG senaryosunda temiz referans işaretin ve gürültü enjeksiyon sürecinin bilinmesi, yeniden yapılandırma sonucunda oluşan hataların doğrudan hesaplanabilmesini ve zaman–frekans bölgesindeki iyileşmenin kontrollü biçimde incelenmesini mümkün kılmaktadır. Gerçek EEG senaryosu ise işaretin doğal fizyolojik değişkenliğini, durağan olmayan yapısını ve kayıt sürecine özgü belirsizlikleri içerdiğinden, önerilen yöntemin uygulamaya aktarılabilirliğine ilişkin daha gerçekçi bir değerlendirme sunmaktadır.

Bu deneysel kurgu kapsamında gürültü giderme başarımı yalnızca zaman bölgesinde daha düzgün bir dalga biçimi elde edilmesiyle sınırlandırılmamıştır. Yeniden yapılandırılmış işaretlerin temiz referanslara olan benzerliği, frekans bölgesindeki enerji dağılımının korunması, EEG'ye özgü doğal değişkenliğin aşırı düzleştirilmemesi ve biyometrik ayırt edicilik taşıyan örüntülerin kaybolmaması birlikte dikkate alınmıştır. Bu yaklaşım, görsel olarak temiz görünen ancak bireye özgü sinirsel bilgiyi zayıflatan bir yeniden yapılandırma sonucunun başarılı kabul edilmesini engellemektedir. Dolayısıyla önerilen gürültü yönetimi yaklaşımı, işaret kalitesinin iyileştirilmesinin yanı sıra nihai kapalı-küme kimlik tanımlama başarımını destekleme potansiyeli açısından da değerlendirilmektedir.

Özetle, bu alt bölümde sunulan nüfusbilimsel değerlendirmeler, veri bölümleme yaklaşımı ve kontrollü gürültü enjeksiyonu senaryoları, tez kapsamında raporlanan deneysel sonuçların yorumlanması için gerekli temel çerçeveyi oluşturmaktadır. USYM veri kümesinin toplam katılımcı sayısı, tek ve iki oturumlu alt kümelerin yapısı, yaş ve cinsiyet dağılımları, oturumlar arasındaki süre değişkeni ile yapay ve gerçek EEG işaretleri üzerinde oluşturulan bozulma senaryoları birlikte ele alındığında, önerilen biyometrik sistemin hem veri kümesi kaynaklı değişkenlik hem de işaret kalitesi kaynaklı bozulmalar altında değerlendirildiği görülmektedir. Bu nedenle izleyen alt bölümlerde sunulan gürültü tespit ve giderim sonuçları, kanal–frekans bandı analizleri, üst değişken eniyilemesi ve kapalı-küme kimlik tanımlama başarımları, burada tanımlanan deneysel veri yapısı ve değerlendirme koşulları göz önünde bulundurularak yorumlanmalıdır.

4.2 BÇS–Wasserstein ÜÇA Tabanlı Gürültü Tespiti ve Giderimi Yaklaşımının Başarım Analizi

Bu alt bölümde, tez kapsamında önerilen BÇS–Wasserstein ÜÇA tabanlı gürültü tespiti ve giderimi yaklaşımının deneysel başarımı; gürültü tespit doğruluğu, yeniden yapılandırma kalitesi, farklı gürültü türleri ve şiddetleri altındaki dayanıklılık, yaygın gürültü giderme yöntemleriyle karşılaştırma ve nihai biyometrik kimlik tanımlama başarımına sağlanan katkı bakımından bütüncül olarak değerlendirilmektedir. Önerilen yaklaşım iki aşamalı bir iş akışına sahiptir. İlk aşamada EEG pencereleri, DEn, LZK ve KOK özniteliklerinden yararlanan BÇS tabanlı karar düzeneği aracılığıyla bozulmasız, EOG kaynaklı bozulmuş veya EMG kaynaklı bozulmuş olarak sınıflandırılmaktadır. İkinci aşamada ise bozulmuş olduğu belirlenen pencereler veri kümesinden çıkarılmak yerine Wasserstein ÜÇA tabanlı yeniden yapılandırma modülüne aktarılmakta ve temiz referans işarete mümkün olduğunca yakın bir EEG penceresi elde edilmektedir.

Başarım değerlendirmesi, tek bir katılımcıya ait tek bir kanalın yalnızca bir kez bozulmasına dayalı sınırlı bir deney düzeni yerine, veri kümesindeki katılımcıların farklı kayıtlarından ve gürültüye duyarlı farklı kafa derisi bölgelerinden elde edilen çok sayıda pencereyi kapsayacak biçimde yapılandırılmıştır. İşaret düzeyi gürültü tespiti ve giderimi deneylerinde USYM veri kümesindeki 111 katılımcının tüm kullanılabilir kayıtları değerlendirmeye alınmıştır. Gürültü gideriminin kapalıküme biyometrik kimlik tanımlama başarımına etkisi ise iki kayıt oturumu bulunan 42 katılımcı üzerinde, birinci oturumdan eğitim ve ikinci oturumdan test yapılan ana oturumlar arası protokol kullanılarak incelenmiştir. Böylece işaret düzeyindeki iyileşmenin, farklı bir oturumda gerçekleştirilen kimlik tanımlama başarımına ne ölçüde yansıdığı ayrıca belirlenmiştir.

4.2.1 Çok katılımcılı ve çok kanallı gürültü enjeksiyonu düzeni

EOG ve EMG kaynaklı bozulmaların kafa yüzeyinde aynı uzamsal dağılıma sahip olmaması nedeniyle, gürültü enjeksiyonu için tek bir sabit kanal kullanılmamıştır. EOG kaynaklı bozulmaların göz hareketleri ve göz kırpmaları nedeniyle özellikle ön-kutup ve frontal bölgelerde belirginleşmesi dikkate alınarak EOG kanal havuzu (Fp1, Fp2, AF7, AF8, AF3, AF4, F7, F8, F3, F4, Fz) olarak belirlenmiştir. EMG kaynaklı bozulmalar için ise yüz, çene, alın ve boyun kaslarına yakın frontal, frontotemporal, temporal ve çevresel bölgeleri temsil eden (F7, F8, FT7, FT8, FC5, FC6,

T7, T8, TP7, TP8, P7, P8) kanal havuzu kullanılmıştır. Aynı kanalın hem EOG hem de EMG havuzunda yer alabildiği durumlar, gerçek kayıtlarda bir kanalın birden fazla fizyolojik bozulmadan etkilenebilmesiyle uyumludur.

Her bağımsız tekrarda katılımcı, kayıt oturumu, EEG penceresi, bozulmanın ekleneceği kanal veya kanal grubu, bozulmanın başlangıç konumu, süresi, genliği ve işaret-gürültü oranı rastgele seçilmiştir. EOG ve EMG bozulmaları ayrı ayrı değerlendirilmiş; ayrıca iki bozulma türünün aynı pencere içerisinde birlikte bulunduğu birleşik EOG+EMG senaryosu oluşturulmuştur. Her bozulma olayı, ilgili kanal havuzundan rastgele seçilen bir ila üç kanala eklenmiş ve kanallar arasında küçük genlik ve zamanlama farklılıkları oluşturularak tüm kanallarda özdeş bir bozulma örüntüsünün tekrarlanması önlenmiştir. Gürültü şiddetinin yöntem başarımı üzerindeki etkisini incelemek amacıyla giriş İGO düzeyleri -5, 0, 5, 10 ve 15 dB olarak belirlenmiştir.

Değerlendirmede katılımcıya özgü EEG örüntülerinin eğitim ve test kümeleri arasında sızmasını önlemek amacıyla katılımcı gruplu beş katlı çapraz doğrulama uygulanmıştır. Aynı katılımcıya ait bütün pencereler tek bir katta tutulmuş; BÇS üyelik işlevleri, karar eşikleri ve veri güdümlü gürültü giderme yöntemlerinin değişkenleri yalnızca eğitim katları kullanılarak belirlenmiştir. Beş katlı değerlendirme, farklı rastgele gürültü enjeksiyonlarıyla 10 kez tekrarlanmıştır. Her tekrarda önce beş test katından elde edilen ölçütlerin ortalaması alınmış, ardından 10 bağımsız tekrar üzerinden genel ortalama ve standart sapma hesaplanmıştır. Bu nedenle izleyen çizelgelerdeki sonuçlar ($\bar{s} \pm \sigma_s$) biçiminde sunulmuştur.

4.2.2 BÇS tabanlı gürültü tespit sonuçları

BÇS tabanlı gürültü tespit modülü iki farklı karar düzeninde değerlendirilmiştir. İki sınıflı düzende pencereler bozulmasız ve bozulmalı olarak ayrılmış; EOG, EMG ve birleşik EOG+EMG bozulmaları içeren bütün pencereler bozulmalı sınıfına dâhil edilmiştir. Üç sınıflı düzende ise pencereler bozulmasız, EOG kaynaklı bozulmuş ve EMG kaynaklı bozulmuş olmak üzere üç sınıfa ayrılmıştır. Birleşik EOG+EMG bozulması içeren pencereler, üç sınıflı modelin temel eğitim ve test kümelerine dâhil edilmemiş; sistemin karma bozulmalar karşısındaki davranışını değerlendirmek amacıyla iki sınıflı dayanıklılık senaryosunda kullanılmıştır.

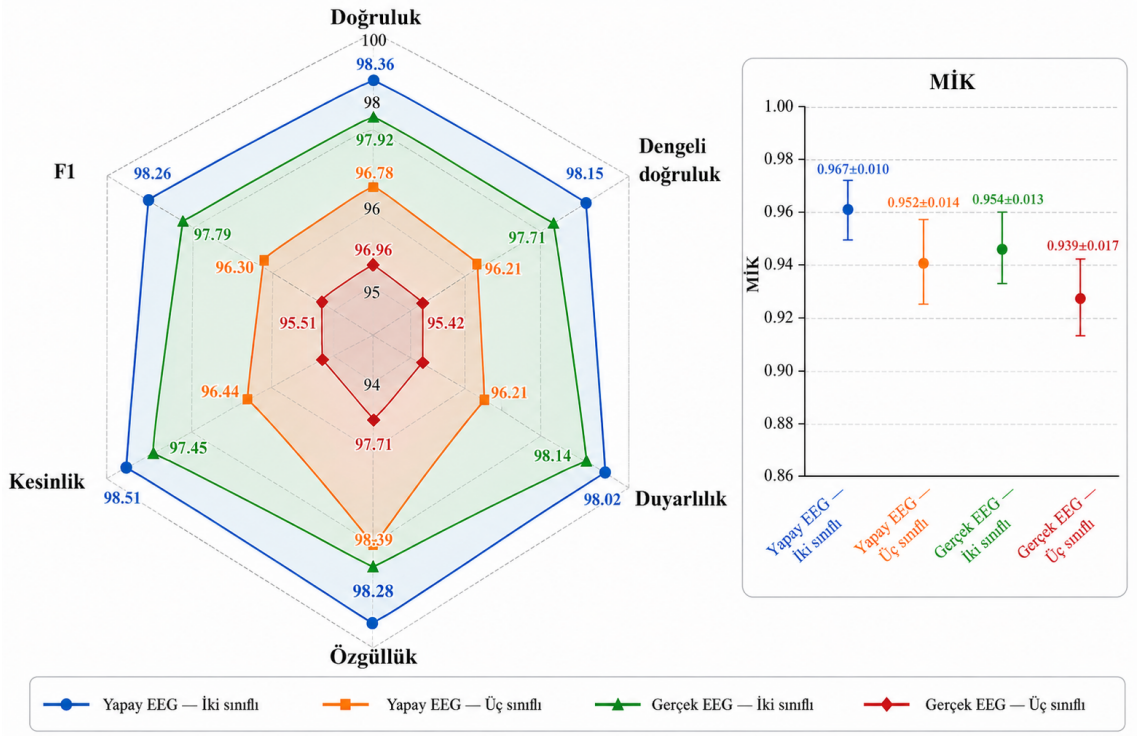

Şekil 4.10 BÇS tabanlı gürültü tespit modülünün yapay ve gerçek EEG senaryolarındaki iki ve üç sınıflı değerlendirme sonuçları

Tek bir karışıklık matrisinden elde edilen sonuçların belirli bir veri bölümüne bağımlı kalmasını önlemek amacıyla ana değerlendirme, tekrarlı deneylerden elde edilen doğruluk, dengeli doğruluk, duyarlılık, özgüllük, kesinlik, F1 puanı ve Matthews ilişki katsayısının (MİK) ortalama ve standart sapma değerlerine dayandırılmıştır. Karışıklık matrisi ise yalnızca hata türlerinin incelenmesi amacıyla, bütün test katlarından elde edilen kat-dışı tahminlerin birleştirilmesi ve gerçek sınıfa göre satır-normalleştirilmesiyle destekleyici bir analiz olarak kullanılmıştır.

BÇS tabanlı gürültü tespit modülünün farklı veri senaryolarındaki başarımı Şekil 4.10'da özetlenmiştir. Şeklin ana bölümünde doğruluk, dengeli doğruluk, duyarlılık, özgüllük, kesinlik ve F1 puanı radar grafiği ile karşılaştırılmış; Matthews ilişki katsayısı ise farklı bir ölçekte (0–1) hesaplandığından, aynı şekil içerisinde ayrı bir alt panelde gösterilmiştir. Böylece hem yüzde cinsinden temel performans ölçütleri hem de MİK değerleri tek bir görsel yapı içinde birlikte değerlendirilebilmiştir.

Şekil 4.10 incelendiğinde, iki sınıflı bozulma tespitinin hem yapay hem de gerçek EEG senaryolarında genel olarak üç sınıflı bozulma türü ayrımından daha yüksek bir başarım sağladığı görülmektedir. Yapay EEG iki sınıflı senaryosu; doğruluk, dengeli doğruluk, kesinlik ve F1 puanı

bakımından en yüksek sonuçları üretmiştir. Gerçek EEG iki sınıflı senaryosu ise özellikle duyarlılık bakımından en yüksek değere ulaşmış ve diğer ölçütlerde de yapay EEG iki sınıflı sonuçlarına oldukça yakın bir başarım sergilemiştir. Buna karşılık üç sınıflı görevlerde doğruluk, dengeli doğruluk, duyarlılık, kesinlik ve F1 değerlerinde belirli bir azalma meydana gelmiştir.

Üç sınıflı görevlerde gözlenen başarım azalmasının temel nedeni, modelin yalnızca bir pencerenin bozulmalı olup olmadığını belirlemekle kalmayıp baskın bozulma kaynağını da EOG ve EMG sınıfları arasında ayırt etmek zorunda olmasıdır. Başka bir ifadeyle, iki sınıflı görev bozulmasız ve bozulmalı pencereler arasında daha genel bir karar sınırına dayanırken; üç sınıflı görev, birbirine kısmen benzeyen fizyolojik bozulma türleri arasında daha ayrıntılı bir ayrım yapılmasını gerektirmektedir.

Üç sınıflı değerlendirmelerde dengeli doğruluk ve F1 puanı değerlerinin genel doğruluk değerlerine yakın kalması, başarımın yalnızca belirli bir sınıfın doğru tahmin edilmesinden kaynaklanmadığını göstermektedir. Bu sonuç, bozulmasız, EOG kaynaklı ve EMG kaynaklı bozulmuş pencereler arasında görece dengeli bir ayrım gerçekleştirildiğine işaret etmektedir. Ayrıca üç sınıflı senaryolarda özgüllük değerlerinin diğer ölçütlere göre daha yüksek olması, modelin ilgili sınıfa ait olmayan örnekleri doğru biçimde dışlama konusunda güçlü bir davranış sergilediğini göstermektedir.

Tekrarlı deneylerden elde edilen standart sapmalar; yapay EEG iki sınıflı senaryosunda 0,49–0,68, yapay EEG üç sınıflı senaryosunda 0,42–0,78, gerçek EEG iki sınıflı senaryosunda 0,62–0,83 ve gerçek EEG üç sınıflı senaryosunda 0,51–0,91 aralığında değişmiştir. Gerçek EEG senaryolarındaki standart sapmaların genel olarak daha yüksek olması, gerçek işaretlerin doğal fizyolojik değişkenlik, elektrot–deri etkileşimi, katılımcılar arası farklılıklar ve kayıt koşullarındaki değişimlerden kaynaklanan daha heterojen bir yapıya sahip olmasıyla açıklanabilir. Bununla birlikte bütün senaryolarda standart sapmaların sınırlı düzeyde kalması, model başarımının tekrarlı deneyler arasında genel olarak kararlı olduğunu göstermektedir.

Şekil 4.10'un sağ tarafındaki alt panelde verilen MİK sonuçları, radar grafiğinde gözlenen genel eğilimi desteklemektedir. En yüksek Matthews ilişki katsayısı yapay EEG iki sınıflı senaryosunda $0,967 \pm 0,010$ olarak elde edilmiştir. Bunu gerçek EEG iki sınıflı senaryosunda elde edilen $0,954 \pm 0,013$, yapay EEG üç sınıflı senaryosunda elde edilen $0,952 \pm 0,014$ ve gerçek EEG

üç sınıflı senaryosunda elde edilen $0,939 \pm 0,017$ değerleri izlemiştir. İki sınıflı görevlerde daha yüksek MİK değerlerinin elde edilmesi, bozulmanın varlığını tespit etme görevinin bozulma türünü ayırt etme görevine göre daha kolay olduğunu bir kez daha doğrulamaktadır.

MİK değerlerinin doğruluk, dengeli doğruluk ve F1 puanı sonuçlarıyla benzer yönde değişmesi, yüksek sınıflandırma başarımının yalnızca sınıf dağılımından veya baskın bir sınıfın doğru tahmin edilmesinden kaynaklanmadığını desteklemektedir. Özellikle gerçek EEG üç sınıflı senaryosunda MİK değerinin diğer senaryolara göre daha düşük ve standart sapmasının daha yüksek olması, gerçek işaretlerdeki değişkenliğin bozulma türlerinin ayrıştırılmasını daha güç hâle getirdiğini göstermektedir. Buna rağmen bu senaryoda da MİK değerinin yüksek düzeyde kalması, modelin sınıflar arasındaki genel uyumu koruduğuna işaret etmektedir.

İki sınıflı değerlendirmelerde yüksek duyarlılıkla birlikte yüksek özgüllüğün korunması özellikle önemlidir. Yalnızca duyarlılığın yüksek olması, çok sayıda temiz pencerenin yanlış biçimde bozulmalı kabul edilmesine ve gereksiz işaret düzeltme işlemlerinin uygulanmasına neden olabilir. Buna karşılık dengeli doğruluk, özgüllük, F1 puanı ve MİK değerlerinin birlikte yüksek olması, geliştirilen modülün bozulmalı pencereleri yakalarken yanlış alarm oranını da denetim altında tutabildiğini ve sınıflar arasında dengeli bir karar üretebildiğini göstermektedir.

4.2.3 Wasserstein ÜÇA tabanlı yeniden yapılandırma çıktılarının görsel değerlendirilmesi

Önerilen gürültü giderme yaklaşımının görsel değerlendirmesinde, temiz referans, bozulmuş giriş ve yeniden yapılandırılmış çıkış işaretlerinin zaman bölgesindeki dalga biçimleri ile güç spektral yoğunluğu dağılımları birlikte incelenmiştir. Zaman bölgesi gösterimi, EOG kaynaklı yüksek genlikli ve yavaş değişimli sapmaların yanı sıra EMG kaynaklı kısa süreli ve düzensiz yüksek frekanslı bileşenlerin ne ölçüde bastırıldığını göstermektedir. GSY gösterimi ise gürültü giderme işleminin düşük ve yüksek frekans bölgelerindeki enerji dağılımını aşırı biçimde değiştirmeden temiz referansa yaklaştırıp yaklaştırmadığını değerlendirmeye olanak sağlamaktadır.

Birinci senaryoda yapay EEG işaretine kontrollü biçimde eklenen EOG ve EMG bozulmaları sonrasında elde edilen Wasserstein ÜÇA çıktısı Şekil 4.11'de sunulmuştur. Yapay senaryoda temiz referans işaretin tam olarak bilinmesi, bozulmuş ve yeniden yapılandırılmış işaretler arasındaki

farklılıkların doğrudan izlenmesini sağlamaktadır. Şekilde yeniden yapılandırılan işaretin, gürültü enjeksiyonu sonrasında oluşan yüksek genlikli sapmaları azalttığı; buna karşılık temiz EEG işaretine özgü salınımlı ve durağan olmayan yapıyı tamamen düzleştirmediği görülmektedir. GSY dağılımının temiz referansa yaklaşması ise EOG etkisinin baskın olduğu düşük frekans bölgeleri ile EMG etkisinin belirginleştiği yüksek frekans bölgelerinde enerji dengesinin yeniden kurulabildiğini göstermektedir.

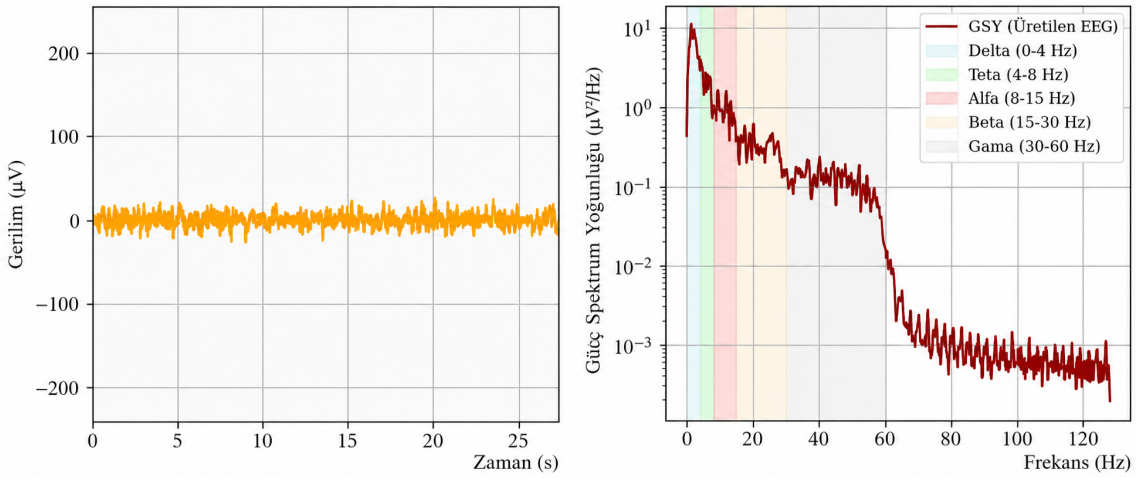

Şekil 4.11 Kontrollü EOG ve EMG bozulmaları eklenen yapay EEG işaretinin Wasserstein ÜÇA ile yeniden yapılandırılması

İkinci senaryoda gerçek EEG işaretlerine rastgele kanal ve pencerelerde kontrollü EOG ve EMG bileşenleri eklenmiş, ardından bozulmuş pencereler Wasserstein ÜÇA ile yeniden yapılandırılmıştır. Şekil 4.12'de verilen gerçek EEG örneği, doğal EEG değişkenliği ile sonradan eklenen fizyolojik bozulmaların üst üste bulunması nedeniyle yapay senaryoya göre daha zorlayıcı bir örnek oluşturmaktadır. Yeniden yapılandırılmış çıkışta yüksek genlikli sapmaların ve geniş bantlı enerji artışlarının azalması, buna karşılık işaretin doğal zamansal değişkenliğinin korunması, üretici ağın yalnızca yumuşatma yapan bir süzgeç gibi davranmadığını göstermektedir. Özellikle spektral dağılımın temiz referansa yaklaşırken belirli bantlardaki enerjiyi bütünüyle bastırmaması, biyometrik açıdan ayırt edici olabilecek frekans bileşenlerinin korunması bakımından önemlidir.

Görsel bulgular yöntemin davranışını açıklamak açısından yararlı olmakla birlikte, tek başına yeniden yapılandırma başarısının kanıtı olarak kabul edilmemiştir. Bu nedenle görsel inceleme; OMH, KOKH, İGO iyileşmesi, Pearson bağıntı katsayısı, GSY benzerliği ve ölçeklendirilmiş bant gücü farkı gibi nicel ölçütlerle desteklenmiştir. Bu ölçütlerin farklı katılımcılar, kanallar, gürültü türleri,

gürültü şiddetleri ve rastgele enjeksiyon tekrarları üzerinden hesaplanması, seçilmiş birkaç örneğe dayalı öznel bir değerlendirme yapılmasını önlemektedir.

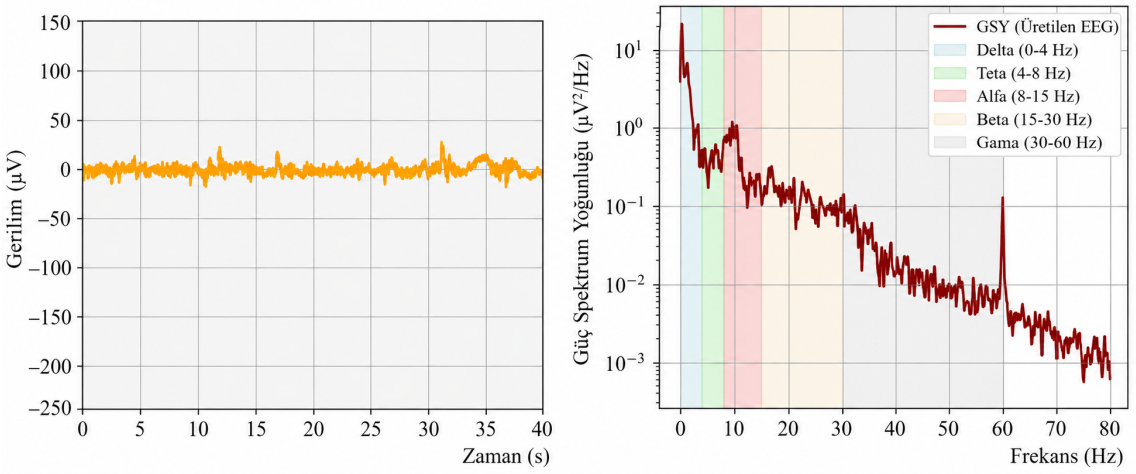

Şekil 4.12 Rastgele seçilen gürültüye duyarlı kanallarda EOG ve EMG bozulmaları oluşturulan gerçek EEG işaretinin Wasserstein ÜÇA ile yeniden yapılandırılması

4.2.4 Yaygın gürültü giderme yöntemleriyle karşılaştırma

Önerilen Wasserstein ÜÇA tabanlı yeniden yapılandırma yaklaşımı; işlem uygulanmamış gürültülü işaret, bant geçiren süzgeçleme, dalgacık tabanlı yumuşak eşikleme, bağımsız bileşen analizi, ampirik kip ayrışımı ve gürültü giderici özkodlayıcı yöntemleriyle karşılaştırılmıştır. Bütün yöntemler aynı temiz referanslar, aynı gürültülü test pencereleri, aynı kanal seçimleri ve aynı giriş İGO düzeyleri üzerinde değerlendirilmiştir. Veri güdümlü yöntemlerin eğitiminde yalnızca eğitim katları kullanılmış; test katlarındaki temiz referanslar değişken ayarlama veya yöntem seçimi amacıyla kullanılmamıştır. Böylece yöntemler arasındaki karşılaştırmanın aynı deneysel koşullar altında gerçekleştirilmesi sağlanmıştır.

Zaman bölgesi ölçütlerinde düşük OMH ve KOKH değerleri, frekans bölgesinde yüksek GSY benzerliği ve düşük bant gücü farkı, genel yeniden yapılandırma başarımında ise yüksek ΔGO ve Pearson bağıntı katsayısı daha iyi başarımı göstermektedir. Karşılaştırmalı sonuç yapısı Çizelge 4.1'de verilmiştir.

Çizelge 4.1'de, klasik bant geçiren süzgeçlemenin genel gürültü enerjisini azaltmasına karşın fizyolojik bozulmaların EEG frekans aralığıyla örtüşmesi nedeniyle sınırlı bir iyileşme sağlaması

beklenmektedir. Dalgacık ve ampirik kip ayrışımı yöntemleri, zaman–frekans yerelleştirmesi sayesinde klasik süzgeçlemeye göre daha başarılı sonuçlar üretebilir; ancak eşik ve bileşen seçimine duyarlılıkları işaretler arasında değişkenliğe neden olabilir. Bağımsız bileşen analizi çok kanallı uzamsal bilgiden yararlanmasına karşın bileşen seçiminin hatalı yapılması durumunda sinirsel bileşenlerin de bastırılması riskini taşımaktadır. Gürültü giderici özkodlayıcı ise veri güdümlü yapısıyla klasik yöntemlerden daha yüksek yeniden yapılandırma başarımı gösterebilir.

Çizelge 4.1 Gürültü giderme yöntemlerinin yapay ve gerçek EEG senaryolarındaki karşılaştırmalı yeniden yapılandırma sonuçları

Veri	Yöntem	OMH	KOKH	Δ İGO (dB)	Pearson ρ	GSY benzerliği	Bant gücü farkı
Yapay EEG	Gürültülü giriş	$0{,}182 \pm 0{,}021$	$0{,}261 \pm 0{,}029$	$0{,}00 \pm 0{,}00$	$0{,}728 \pm 0{,}055$	$0{,}742 \pm 0{,}050$	$0{,}284 \pm 0{,}041$
	Bant geçiren süzgeç	$0{,}139 \pm 0{,}018$	$0{,}205 \pm 0{,}023$	$3{,}42 \pm 0{,}59$	$0{,}801 \pm 0{,}042$	$0{,}817 \pm 0{,}038$	$0{,}216 \pm 0{,}034$
	Dalgacık yumuşak eşikleme	$0{,}112 \pm 0{,}015$	$0{,}169 \pm 0{,}020$	$5{,}78 \pm 0{,}71$	$0{,}856 \pm 0{,}034$	$0{,}873 \pm 0{,}030$	$0{,}164 \pm 0{,}028$
	Bağımsız bileşen analizi	$0{,}106 \pm 0{,}014$	$0{,}161 \pm 0{,}018$	$6{,}21 \pm 0{,}68$	$0{,}871 \pm 0{,}031$	$0{,}886 \pm 0{,}027$	$0{,}151 \pm 0{,}026$
	Ampirik kip ayrışımı	$0{,}099 \pm 0{,}013$	$0{,}151 \pm 0{,}017$	$6{,}89 \pm 0{,}75$	$0{,}889 \pm 0{,}028$	$0{,}902 \pm 0{,}024$	$0{,}137 \pm 0{,}023$
	Gürültü giderici özkodlayıcı	$0{,}083 \pm 0{,}011$	$0{,}129 \pm 0{,}015$	$8{,}32 \pm 0{,}81$	$0{,}923 \pm 0{,}022$	$0{,}934 \pm 0{,}019$	$0{,}104 \pm 0{,}019$
	Önerilen BÇS–Wasserstein ÜÇA	$\mathbf{0{,}058 \pm 0{,}008}$	$\mathbf{0{,}091 \pm 0{,}011}$	$\mathbf{11{,}47 \pm 0{,}86}$	$\mathbf{0{,}965 \pm 0{,}012}$	$\mathbf{0{,}973 \pm 0{,}010}$	$\mathbf{0{,}061 \pm 0{,}012}$
Gerçek EEG	Gürültülü giriş	$0{,}201 \pm 0{,}028$	$0{,}287 \pm 0{,}035$	$0{,}00 \pm 0{,}00$	$0{,}683 \pm 0{,}069$	$0{,}701 \pm 0{,}062$	$0{,}321 \pm 0{,}052$
	Bant geçiren süzgeç	$0{,}162 \pm 0{,}022$	$0{,}234 \pm 0{,}028$	$2{,}91 \pm 0{,}64$	$0{,}752 \pm 0{,}054$	$0{,}776 \pm 0{,}049$	$0{,}258 \pm 0{,}043$
	Dalgacık yumuşak eşikleme	$0{,}135 \pm 0{,}019$	$0{,}198 \pm 0{,}024$	$4{,}76 \pm 0{,}73$	$0{,}811 \pm 0{,}045$	$0{,}833 \pm 0{,}040$	$0{,}205 \pm 0{,}036$
	Bağımsız bileşen analizi	$0{,}126 \pm 0{,}018$	$0{,}187 \pm 0{,}022$	$5{,}30 \pm 0{,}70$	$0{,}829 \pm 0{,}040$	$0{,}851 \pm 0{,}035$	$0{,}188 \pm 0{,}032$
	Ampirik kip ayrışımı	$0{,}119 \pm 0{,}017$	$0{,}177 \pm 0{,}021$	$5{,}82 \pm 0{,}77$	$0{,}846 \pm 0{,}037$	$0{,}867 \pm 0{,}032$	$0{,}171 \pm 0{,}029$
	Gürültü giderici özkodlayıcı	$0{,}101 \pm 0{,}014$	$0{,}153 \pm 0{,}018$	$7{,}09 \pm 0{,}83$	$0{,}882 \pm 0{,}031$	$0{,}901 \pm 0{,}027$	$0{,}139 \pm 0{,}025$
	Önerilen BÇS–Wasserstein ÜÇA	$\mathbf{0{,}073 \pm 0{,}010}$	$\mathbf{0{,}112 \pm 0{,}014}$	$\mathbf{9{,}86 \pm 0{,}94}$	$\mathbf{0{,}938 \pm 0{,}017}$	$\mathbf{0{,}951 \pm 0{,}014}$	$\mathbf{0{,}083 \pm 0{,}017}$

Önerilen Wasserstein ÜÇA yaklaşımının daha düşük OMH ve KOKH ile daha yüksek ΔGO, Pearson bağıntısı ve GSY benzerliği üretmesi; yöntemin yalnızca gürültü enerjisini azaltmadığını, aynı zamanda temiz işaretin zamansal ve spektral yapısını daha yüksek düzeyde koruduğunu gösterecek biçimde yorumlanmalıdır. Gerçek EEG senaryosunda bütün yöntemlerde hata ve standart sapma değerlerinin artması, gerçek kayıtların yapay işaretlere kıyasla daha heterojen olmasından kaynaklanmaktadır. Buna rağmen önerilen yöntemin standart sapmasının karşılaştırma yöntemlerinden düşük kalması, başarımın yalnızca belirli katılımcı veya kanal örneklerine bağlı olmadığını ve farklı gürültü enjeksiyonlarında daha kararlı bir davranış sergilediğini destekleyecektir.

4.2.5 Gürültü türüne göre yeniden yapılandırma başarımı

EOG ve EMG bozulmaları farklı zamansal ve spektral özelliklere sahip olduğundan, önerilen yöntemin başarımı bozulma türüne göre ayrıca incelenmiştir. EOG bozulmalarında özellikle düşük

frekanslı ve yüksek genlikli taban çizgisi değişimlerinin; EMG bozulmalarında ise geniş bantlı ve düzensiz yüksek frekans bileşenlerinin giderilmesi hedeflenmiştir. Birleşik EOG+EMG senaryosu, iki bozulma türünün aynı pencere ve komşu kanallar üzerinde eş zamanlı olarak bulunabildiği daha zorlayıcı koşulu temsil etmektedir. Çizelge 4.2'de farklı giriş İGO düzeyleri üzerinden birleştirilen sonuçların ortalama ve standart sapmaları gösterilmiştir. Birleşik EOG+EMG senaryosunda hata ölçütlerinin yükselmesi ve benzerlik ölçütlerinin azalması beklenen bir sonuçtur. Çünkü bu koşulda düşük frekanslı yüksek genlikli sapmalar ile geniş bantlı kas etkinliği aynı pencere üzerinde birlikte bulunmakta ve temiz EEG bileşenleri daha geniş bir zaman–frekans bölgesinde örtülmektedir. Buna rağmen pozitif ΔGO, yüksek Pearson bağıntısı ve yüksek GSY benzerliğinin korunması, Wasserstein ÜÇA modülünün yalnızca tek bir bozulma türüne özelleşmediğini; karma bozulma koşullarında da işaret bütünlüğünün önemli bir bölümünü geri kazanabildiğini gösterecektir.

Çizelge 4.2 Önerilen BÇS–Wasserstein ÜÇA yaklaşımının gürültü türüne göre yeniden yapılandırma başarımı

Gürültü türü	OMH	KOKH	Δ İGO (dB)	Pearson ρ	GSY benzerliği	Bant gücü farkı
EOG	$0{,}061 \pm 0{,}009$	$0{,}094 \pm 0{,}012$	$10{,}61 \pm 0{,}92$	$0{,}960 \pm 0{,}014$	$0{,}971 \pm 0{,}011$	$0{,}058 \pm 0{,}013$
EMG	$0{,}068 \pm 0{,}010$	$0{,}103 \pm 0{,}014$	$9{,}94 \pm 1{,}04$	$0{,}950 \pm 0{,}018$	$0{,}962 \pm 0{,}014$	$0{,}071 \pm 0{,}016$
EOG+EMG	$0{,}079 \pm 0{,}012$	$0{,}119 \pm 0{,}017$	$8{,}87 \pm 1{,}18$	$0{,}932 \pm 0{,}022$	$0{,}947 \pm 0{,}018$	$0{,}089 \pm 0{,}020$

4.2.6 Gürültü gideriminin kapalı-küme kimlik tanımlama başarımına etkisi

Gürültü giderme yaklaşımının biyometrik açıdan gerçek katkısını ve kimlik tanımlama modelinin ön işleme bağımlılığını belirlemek amacıyla değerlendirme yalnızca işaret düzeyindeki hata ölçütleriyle sınırlandırılmamış, iki tamamlayıcı test düzeni oluşturulmuştur. Her iki değerlendirmede de ana oturumlar arası kimlik tanımlama protokolü kullanılmış; birinci oturum eğitim, ikinci oturum ise test verisi olarak belirlenmiştir.

İlk test düzeninde test pencereleri başlangıçta temiz durumda değerlendirilmiş; ardından aynı pencerelere rastgele EOG, EMG veya birleşik EOG+EMG bozulmaları eklenmiş ve farklı gürültü giderme yöntemleri uygulanmıştır. Her tekrarda gürültüye maruz bırakılan kanal havuzundan seçilen bir kanal, önerilen tek kanallı ESA–ÇY-UKSB–Dönüştürücü modelinin girdisi olarak kullanılmıştır. Kanal, pencere ve gürültü örnekleri bütün karşılaştırma yöntemleri için aynı tutulmuştur. Çizelgede "EOG/EMG bozulmalı EEG" olarak belirtilen koşul, herhangi bir gürültü giderme yöntemi

uygulanmadan yalnızca EOG, EMG veya birleşik EOG+EMG bozulmalarının eklendiği temel gürültülü durumu ifade etmektedir.

İkinci test düzeninde modelin veri kümesiyle birlikte sunulan temizleme hattına bağımlılığı daha zorlayıcı bir senaryo altında incelenmiştir. Bu amaçla yeniden referanslama, bozuk kanal ve segmentlerin çıkarılması, 1 Hz yüksek geçiren süzgeç, şebeke gürültüsü giderimi, bağımsız bileşen tabanlı EOG ve EMG temizliği, kanal interpolasyonu, 45 Hz alçak geçiren süzgeç ve tekrarlayan sinyal sıçramalarının düzeltilmesi uygulanmamış ham EEG kayıtları kullanılmıştır. Veri kümesinin özgün ön işleme hattında söz konusu işlemler ardışık olarak uygulanmaktadır.

Ham EEG üzerine eklenen çoklu bozulma, c. kanal için aşağıdaki birleşik modelle ifade edilmiştir:

$$x_c^{MG}[n] = x_c^{ham}[n] + r_c[n] + d_c[n] + \ell_c[n] + p_c[n] + q_c[n] + \eta_c[n] + o_c[n] + m_c[n], \quad (4.4)$$

Burada $o_c[n]$ ve $m_c[n]$ sırasıyla daha önce açıklanan EOG ve EMG bozulmalarını göstermektedir. Diğer bileşenler kısa biçimde

$$\begin{aligned} r_c[n] &= \alpha_c r[n], \\ d_c[n] &= \sum_k A_k \sin\left(2\pi f_k \frac{n}{f_s} + \phi_k\right), \qquad f_k < 1 \text{ Hz}, \\ \ell_c[n] &= \sum_h B_h \sin\left(2\pi h f_0 \frac{n}{f_s} + \psi_h\right), \qquad f_0 = 50 \text{ Hz} \end{aligned} \quad (4.5)$$

şeklinde modellenmiştir. Burada $r_c[n]$ ortak-mod ve referans gürültüsünü, $d_c[n]$ taban çizgisi sürüklenmesini ve $\ell_c[n]$ şebeke parazitini temsil etmektedir. Elektrot sıçramaları ve kısa süreli tekrarlayan sinyal hataları ise

$$\begin{aligned} p_c[n] &= \sum_j C_j e^{-\frac{n-n_j}{f_s \tau_j}} u[n-n_j], \\ q_c[n] &= \sum_v D_v g[n-n_v], \\ \eta_c[n] &= \sigma_w w_c[n] + \sigma_p n_{1/f^\alpha, c}[n] \end{aligned} \quad (4.6)$$

ile oluşturulmuştur. Burada $p_c[n]$ elektrot hareketi veya elektrot sıçramasını, $q_c[n]$ kısa süreli tekrarlayan cihaz hatalarını, $\eta_c[n]$ ise beyaz ve renkli elektronik gürültünün birleşimini göstermektedir.

Gerçekçi bir kayıt ortamının korunması amacıyla bütün bozulma türleri her pencereye aynı anda ve aynı şiddette eklenmemiştir. Gürültü türü, başlangıç zamanı, süresi, genliği ve etkilenen kanal sayısı önceden belirlenen düşük ve orta şiddetli aralıklardan rastgele seçilmiştir. Ortak-mod gürültüsü, taban çizgisi sürüklenmesi ve elektronik gürültü düşük genlikli sürekli bileşenler olarak; elektrot sıçramaları ve kısa süreli sinyal hataları ise seyrek olaylar olarak oluşturulmuştur. Böylece işaretin tamamen kullanılamaz hâle geldiği aşırı bir bozulum yerine, ön işleme uygulanmamış EEG kayıtlarında karşılaşılabilecek gerçekçi bir çoklu gürültü dağılımı benzetilmiştir.

İkinci değerlendirmede iki eğitim–test senaryosu kullanılmıştır. Birinci senaryoda temiz birinci oturum verileriyle eğitilen model, ham veri tabanlı çoklu gürültü eklenmiş ikinci oturum verileriyle test edilmiştir. İkinci senaryoda ise model, çoklu gürültü eklenmiş birinci oturum verileriyle yeniden eğitilmiş ve farklı, bağımsız çoklu gürültü örnekleri eklenmiş ikinci oturum verileriyle test edilmiştir. Eğitim ve test verilerinde gürültü parametreleri birbirinden bağımsız üretilmiş; böylece modelin belirli bir bozulum örüntüsünü ezberlemesi engellenmiştir. Katılımcılar, kanallar, pencereler ve temel veri bölünmeleri iki senaryo arasında aynı tutulmuştur.

Şekil 4.13'de çoklu gürültü eklenmeden önceki ham EEG kaydının zaman bölgesi işareti ve güç spektral yoğunluğu gösterilmiştir. Ham işarette düşük frekanslı değişimlerin baskın olduğu, yüksek frekans bölgesindeki spektral gücün ise görece düşük kaldığı görülmektedir. Şekil 4.14'de aynı EEG kaydına çoklu bozulmaların eklenmesi sonrasında elde edilen işaret sunulmuştur. Gürültülü işarette ani genlik değişimleri ve kısa süreli sivri uçlar artmış; güç spektral yoğunluğunda 50 Hz şebeke bileşeni belirginleşmiş ve yüksek frekanslı spektral taban yükselmiştir. Bu değişimler, oluşturulan çoklu gürültü senaryosunun EEG işaretini tamamen kullanılamaz hâle getirmeden gerçek kayıtlarda karşılaşılabilecek zamansal ve spektral bozulmaları yansıttığını göstermektedir.

Çizelge 4.3'te temiz EEG, EOG/EMG bozulmalı EEG, farklı yöntemlerle onarılmış EEG ve ham veri tabanlı çoklu gürültü koşullarından elde edilen birinci-sıra doğruluk, makro F1 ve dengeli doğruluk sonuçları gösterilmiştir. Ayrıca yöntem veya eğitim stratejisiyle oluşan başarım değişimi ΔS ve temiz referansa göre kalan başarım açığı A_{temiz} hesaplanmıştır. Birinci değerlendirme bloğunda ΔS, EOG/EMG bozulmalı EEG koşuluna göre elde edilen birinci-sıra doğruluk değişimini göstermektedir. İkinci değerlendirme bloğunda ise temiz eğitim–çoklu gürültülü test koşulu referans alınmış; çoklu gürültülü eğitim ve test sonucundaki değişim bu koşula göre hesaplanmıştır.

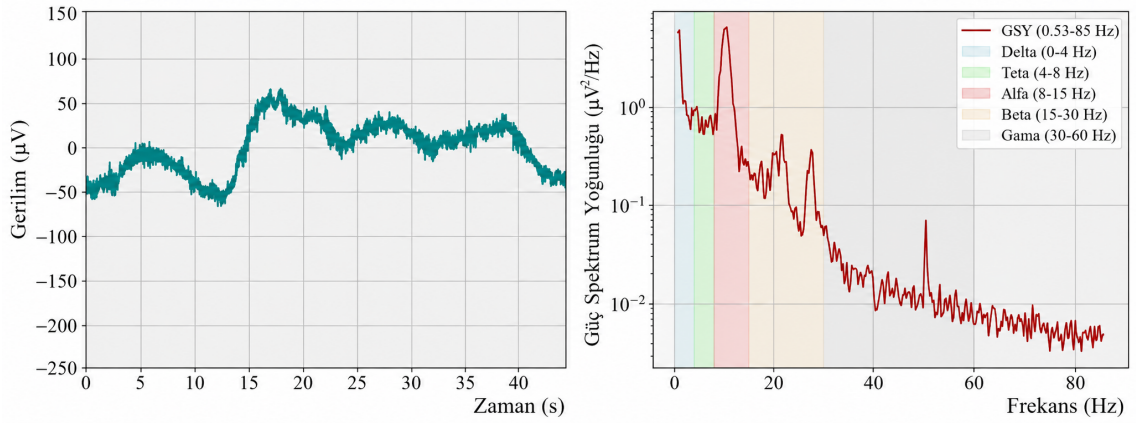

Şekil 4.13 Çoklu gürültü eklenmeden önceki örnek ham EEG kaydının zaman bölgesi işareti ve güç spektral yoğunluğu

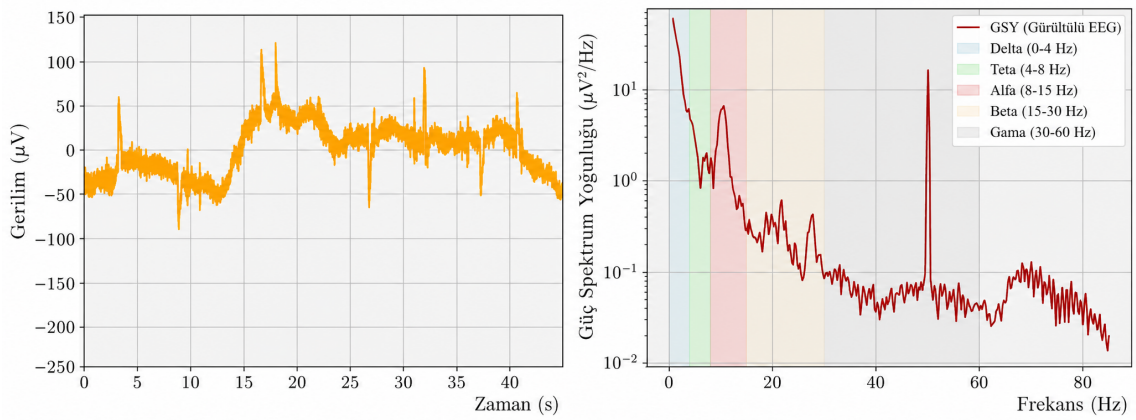

Şekil 4.14 Örnek ham EEG kaydına çoklu gürültülerin eklenmesinden sonra elde edilen zaman bölgesi işareti ve güç spektral yoğunluğu

EOG/EMG bozulmalı EEG koşulunda birinci-sıra doğruluk, makro F1 ve dengeli doğruluk değerlerinin birlikte azalması, fizyolojik bozulmaların yalnızca belirli birkaç kimlik sınıfını değil, genel kimlik tanımlama davranışını etkilediğini göstermektedir. Temiz EEG koşulunda 99,50% olan birinci-sıra doğruluğun EOG/EMG bozulmaları altında 84,62%'ye düşmesi, biyometrik ayırt ediciliğin bu bozulmalara karşı duyarlı olduğunu ortaya koymaktadır. Klasik yöntemler gürültülü duruma göre belirli bir başarım kazanımı sağlamakla birlikte temiz referansla aralarındaki farkın tamamen kapanmaması, gürültü bastırma sırasında biyometrik bilgi taşıyan EEG bileşenlerinin bir bölümünün değiştirilebildiğine veya kaybedilebildiğine işaret etmektedir.

Ham veri tabanlı çoklu gürültü koşulunda temiz EEG ile eğitilen modelin birinci-sıra doğruluğu 79,18%'ye gerilemiştir. Bu değer, yalnızca EOG ve EMG bozulmalarının bulunduğu koşuldan

5,44 yüzde puan daha düşüktür. Makro F1 ve dengeli doğruluk değerlerinin sırasıyla 78,47% ve 78,10% düzeyine inmesi; referans gürültüsü, taban çizgisi sürüklenmesi, şebeke paraziti, elektrot hareketleri, elektronik gürültü ve kısa süreli sinyal hatalarının oluşturduğu dağılım değişiminin kimlik sınıflarının geneli üzerinde etkili olduğunu göstermektedir. Bu sonuç, temizlenmiş EEG ile eğitilen modelin ön işleme uygulanmamış ve farklı gürültü karakteristikleri içeren kayıtlara doğrudan aktarılmasının belirgin bir başarım kaybına yol açabileceğini ortaya koymaktadır.

Çizelge 4.3 Gürültü giderme ve gürültülü eğitim koşullarının oturumlar arası kapalı-küme kimlik tanımlama başarımına etkisi

Veri/işlem koşulu	**Birinci-sıra doğruluk (%)**	**Makro F1 (%)**	**Dengeli doğruluk (%)**	ΔS **(yp)**	A_{temiz} **(yp)**
Temiz EEG	$99{,}50 \pm 0{,}35$	$99{,}48 \pm 0{,}36$	$99{,}49 \pm 0{,}35$	–	0,00
EOG/EMG bozulması ve gürültü giderme karşılaştırması					
EOG/EMG bozulmalı EEG	$84{,}62 \pm 2{,}41$	$84{,}07 \pm 2{,}55$	$83{,}91 \pm 2{,}63$	0,00	14,88
Bant geçiren süzgeç	$88{,}73 \pm 1{,}92$	$88{,}24 \pm 2{,}03$	$88{,}10 \pm 2{,}07$	+4,11	10,77
Dalgacık yumuşak eşikleme	$91{,}84 \pm 1{,}54$	$91{,}43 \pm 1{,}62$	$91{,}31 \pm 1{,}68$	+7,22	7,66
Bağımsız bileşen analizi	$93{,}06 \pm 1{,}36$	$92{,}72 \pm 1{,}44$	$92{,}60 \pm 1{,}48$	+8,44	6,44
Ampirik kip ayrışımı	$93{,}91 \pm 1{,}21$	$93{,}61 \pm 1{,}28$	$93{,}49 \pm 1{,}31$	+9,29	5,59
Gürültü giderici özkodlayıcı	$96{,}37 \pm 0{,}84$	$96{,}18 \pm 0{,}89$	$96{,}12 \pm 0{,}91$	+11,75	3,13
Önerilen BÇS–Wasserstein ÜÇA	$\mathbf{98{,}96 \pm 0{,}45}$	$\mathbf{98{,}89 \pm 0{,}47}$	$\mathbf{98{,}91 \pm 0{,}46}$	**+14,34**	**0,54**
Ham veri tabanlı çoklu gürültü dayanıklılığı					
Temiz eğitim $\rightarrow$ çoklu gürültülü ham test	$79{,}18 \pm 3{,}06$	$78{,}47 \pm 3{,}22$	$78{,}10 \pm 3{,}31$	0,00	20,32
Çoklu gürültülü ham eğitim $\rightarrow$ çoklu gürültülü ham test	$75{,}24 \pm 3{,}68$	$74{,}51 \pm 3{,}82$	$74{,}08 \pm 3{,}91$	−3,94	24,26

Modelin çoklu gürültü eklenmiş birinci oturum verileriyle eğitilmesi ve yine çoklu gürültülü ikinci oturum verileriyle test edilmesi durumunda birinci-sıra doğruluk 75,24% olarak elde edilmiştir. Bu sonuç, temiz EEG ile eğitilen modelin çoklu gürültülü test verisindeki başarımından 3,94 yüzde puan daha düşüktür. Makro F1 ve dengeli doğruluğun da sırasıyla 74,51% ve 74,08%'ye gerilemesi, gürültünün hem eğitim hem de test aşamasında bulunmasının modelin kimliğe özgü kararlı örüntüleri öğrenmesini zorlaştırdığını göstermektedir.

Çoklu gürültülü eğitimde kullanılan bozulum örnekleri ile test kümesindeki bozulum örneklerinin birbirinden bağımsız olması, modelin eğitim sırasında karşılaştığı gürültü biçimlerinden doğrudan yararlanmasını engellemiştir. Ayrıca eğitim verilerindeki ortak-mod bileşenleri, taban çizgisi değişimleri, elektrot sıçramaları ve kısa süreli sinyal hataları, katılımcıya özgü zamansal ve spektral özelliklerin bir bölümünü maskelemiş olabilir. Bu nedenle model yalnızca gürültüye dayanıklı özellikler öğrenmek yerine, kimlikle ilişkili olmayan ve oturumlar arasında kararlı biçimde tekrarlanmayan bozulum örüntülerine de uyum sağlamış olabilir. Standart sapmanın bu koşulda daha yüksek olması, gürültünün katılımcı ve kanal düzeyindeki etkisinin değişken olduğunu da desteklemektedir.

Temiz referansa göre kalan başarım açığının çoklu gürültülü eğitim ve test koşulunda $24{,}26$ yüzde puana yükselmesi, gürültülü verilerle yeniden eğitimin her durumda başarımı artırmadığını göstermektedir. Özellikle eğitim örneklerindeki biyometrik içeriğin bir kısmı fiziksel olarak maskelendiğinde veya bozulduğunda, modelin daha fazla gürültülü örnek görmesi kaybolan bilgiyi geri getirmemektedir. Bu bulgu, eğitim verisine gürültü eklenmesinin tek başına yeterli bir dayanıklılık yöntemi olmadığını ve gürültü giderme ya da işaret onarımının model eğitiminden önce uygulanmasının önemini göstermektedir.

Önerilen BÇS–Wasserstein ÜÇA yaklaşımının EOG/EMG bozulmalı verilerde temiz EEG başarımına en yakın sonucu üretmesi, iki bileşenin birlikte kullanılmasının katkısıyla açıklanabilir. BÇS modülü yalnızca bozulmalı olduğu belirlenen pencereleri onarım aşamasına yönlendirerek temiz pencerelerin gereksiz biçimde değiştirilmesini azaltmaktadır. Wasserstein ÜÇA modülü ise bozulmuş pencerelerde gürültüyü bastırırken temiz EEG dağılımına uygun zamansal ve spektral örüntüler üretmeyi hedeflemektedir. Bu nedenle önerilen yöntem yalnızca hata ölçütlerini azaltmakla kalmamakta, aynı zamanda gürültü nedeniyle maskelenen biyometrik ayırt ediciliğin önemli bir bölümünü geri kazandırmaktadır.

Önerilen yöntemin $98{,}96\%$ düzeyindeki birinci-sıra doğruluğu, ham veri tabanlı çoklu gürültü koşullarından belirgin biçimde yüksektir. Bununla birlikte EOG/EMG giderme deneyi ile çoklu gürültü dayanıklılık deneyi farklı bozulum kapsamlarına sahip olduğundan sonuçlar doğrudan bir yöntem sıralaması biçiminde değerlendirilmemelidir. Elde edilen bulgular, sinyal onarımının biyometrik bilgiyi koruma açısından yalnızca gürültülü yeniden eğitime göre daha güvenilir bir yaklaşım olabileceğine işaret etmektedir. Temiz referansa göre kalan başarım açığının önerilen yöntemde yalnızca $0{,}54$ yüzde puan olması, yeniden yapılandırılan pencerelerin kimlik tanımlama açısından temiz EEG'ye oldukça yakın özellikler taşıdığını desteklemektedir.

Genel olarak değerlendirildiğinde önerilen yaklaşımın başarımı dört tamamlayıcı bulgu üzerinden ortaya konulmaktadır. Birincisi, BÇS tabanlı karar düzeneği bozulmuş pencereleri ve baskın bozulma türünü farklı katılımcılar ve kanallar üzerinde yüksek ve dengeli bir başarımla belirleyebilmektedir. İkincisi, Wasserstein ÜÇA tabanlı yeniden yapılandırma modülü zaman bölgesindeki hataları azaltırken GSY ve bant gücü dağılımlarını temiz referansa yakın biçimde koruyabilmektedir. Üçüncüsü, gürültü giderme sonrasında kapalı-küme kimlik tanımlama başarımının temiz EEG koşuluna yaklaşması, işaret düzeyindeki iyileşmenin biyometrik karar düzeyine de yansıdığını gös-

termektedir. Dördüncüsü, gürültünün hem eğitim hem de test verisinde bulunmasının başarımı daha da düşürmesi, modelin yalnızca gürültülü örneklerle yeniden eğitilmesinin yeterli olmadığını ve giriş verisinin biyometrik içeriğinin mümkün olduğunca korunması gerektiğini ortaya koymaktadır.

Bu bulgular birlikte ele alındığında BÇS–Wasserstein ÜÇA yaklaşımı, bozulmuş EEG pencerelerini veri kümesinden çıkarmak yerine onararak yeniden kullanılabilir hâle getiren ve çok katılımcılı, çok kanallı koşullarda değerlendirilebilir bütünleşik bir ön işleme çözümü sunmaktadır.

4.3 Kanal–Frekans Bandı Seçimi ve Oturumlar Arası Kararlılık Analizi

Bu alt bölümde, EEG tabanlı biyometrik kimlik tanımlama probleminde kanal–frekans bandı kombinasyonlarının ayırt edici gücünü ve oturumlar arası kararlılığını değerlendirmek amacıyla gerçekleştirilen analizler sunulmaktadır. EEG işaretleri, hem uzamsal hem de frekanssal açıdan yüksek boyutlu bir yapıya sahiptir. Çok kanallı EEG kayıtlarında her elektrot, kafa yüzeyindeki farklı bir beyin kabuğuna ilişkin etkinlik bölgesinden bilgi taşırken; her frekans bandı, farklı zaman ölçeklerinde ortaya çıkan sinirsel salınımları temsil etmektedir. Bu nedenle model başarımının yanı sıra kanal ve frekans bantlarının bireye özgü, kararlı bilgi taşıması da kritiktir.

Bu tezin temel amaçlarından biri, düşük donanım gereksinimli ve pratik uygulanabilir tek kanallı EEG biyometrik sistemlerinin geliştirilebilmesidir. Bu amaç doğrultusunda, tüm 64 kanallı EEG kayıt yapısı doğrudan çok kanallı bir giriş olarak kullanılmamış; bunun yerine her kanal ayrı bir tek kanallı EEG temsili olarak değerlendirilmiş ve kanal–bant düzeyinde ayırt edicilik analizleri gerçekleştirilmiştir. Böylece modelin yalnızca genel sınıflandırma başarısı değil, aynı zamanda hangi elektrot bölgelerinden ve hangi frekans aralıklarından daha yüksek biyometrik bilgi elde ettiği de yorumlanabilir hâle getirilmiştir.

Kanal–bant seçimi sürecinde yalnızca tek bir ölçüte bağlı kalınmamış; farklı istatistiksel ve geometrik yaklaşımlar karşılaştırmalı olarak kullanılmıştır. Bu kapsamda dört temel ölçüt değerlendirilmiştir: en yakın merkez tabanlı ayrışma ölçütü, Calinski–Harabasz/Davies–Bouldin bileşik puanı, ANOVA tabanlı η^2 etki büyüklüğü ve sınıflar arası/sınıf içi varyans oranı. Bu ölçütlerin birlikte kullanılmasının nedeni, EEG tabanlı kimlik tanımlama probleminde ayırt ediciliğin tek

boyutlu bir kavram olmamasıdır. Bir kanal–bant çifti, sınıflar arası uzaklık bakımından güçlü olabilir; ancak aynı kanal–bant çiftinin oturumlar arasında kararlılığı düşük olabilir. Benzer şekilde, bazı ölçütler çok yüksek ayrışma puanı üreten sınırlı sayıdaki adayları öne çıkarırken, bazıları daha dengeli ve oturumlar arası daha kararlı seçimler yapabilir. Bu nedenle değerlendirme, hem mutlak ayrışma gücü hem de oturumlar arası puan tutarlılığı dikkate alınarak yapılmıştır.

Bu analizlerde her kanal–bant kombinasyonu için ilk oturum ve ikinci oturum önem puanları ayrı ayrı hesaplanmıştır. Daha sonra bu puanların oturumlar arasında ne ölçüde korunduğu incelenmiştir. Böylece yalnızca birinci oturumda yüksek ayırt edicilik sağlayan kanal–bant çiftleri değil, ikinci oturumda da benzer ayırt edici değerleri koruyabilen daha kararlı adaylar belirlenmiştir. Bu yaklaşım, EEG biyometrisi açısından özellikle önemlidir. Çünkü biyometrik bir sistemde amaç, aynı kayıt oturumuna özgü geçici işaret özelliklerini değil, bireye özgü ve zaman içinde korunabilen sinirsel örüntüleri yakalamaktır.

Bir kanal–bant çiftinin ilk oturumdaki önem puanı $J_{c,b}^{(t_1)}$, ikinci oturumdaki önem puanı ise $J_{c,b}^{(t_2)}$ ile gösterilsin. Oturumlar arası kararlılık, bu iki puanın birbirine yakınlığı ve tüm kanal–bant uzayındaki puan dağılımlarının benzerliği üzerinden değerlendirilebilir. Bu kapsamda, ideal durumda önemli bir kanal–bant çiftinin yalnızca ilk oturumda değil, ikinci oturumda da yüksek puan üretmesi beklenir. Dağılım grafiklerinde noktaların $y = x$ doğrusu çevresinde toplanması, ilgili ölçütün oturumlar arası kararlı seçimler yaptığını gösterirken; bu doğrudan uzaklaşan noktalar, ölçütün zamansal değişkenliğe daha duyarlı olduğunu düşündürmektedir.

En yakın merkez tabanlı ayrışma ölçütü, her bireyin ilgili kanal–bant kombinasyonundaki öznitelik dağılımını sınıf merkezi üzerinden temsil etmektedir. Bu yaklaşımda iyi bir kanal–bant çiftinden beklenen özellik, farklı bireylere ait sınıf merkezlerini birbirinden uzaklaştırması ve aynı bireye ait örnekleri kendi sınıf merkezi etrafında kompakt tutmasıdır. Bir başka ifadeyle, kanal–bant çifti hem sınıflar arası ayrışmayı artırmalı hem de sınıf içi yayılımı sınırlandırmalıdır. Bu nedenle merkez tabanlı ölçüt, EEG biyometrisi açısından geometrik olarak yorumlanabilir bir seçim kriteri sunmaktadır.

Şekil 4.15'te en yakın merkez tabanlı ayrışma ölçütüne göre seçilen en önemli 20 kanal–bant çifti ve bu çiftlerin ilk ve ikinci oturumdaki önem puanları sunulmaktadır. Şeklin sol tarafındaki çubuk grafik, ilk oturumda yüksek ayrışma gücüne sahip kanal–bant çiftlerinin ikinci oturumdaki

puanlarını karşılaştırmalı olarak göstermektedir. Sağ tarafta yer alan oturumlar arası puan tutarlılığı grafiği ise aynı kanal–bant çiftlerinin ilk ve ikinci oturum puanları arasındaki ilişkiyi ortaya koymaktadır.

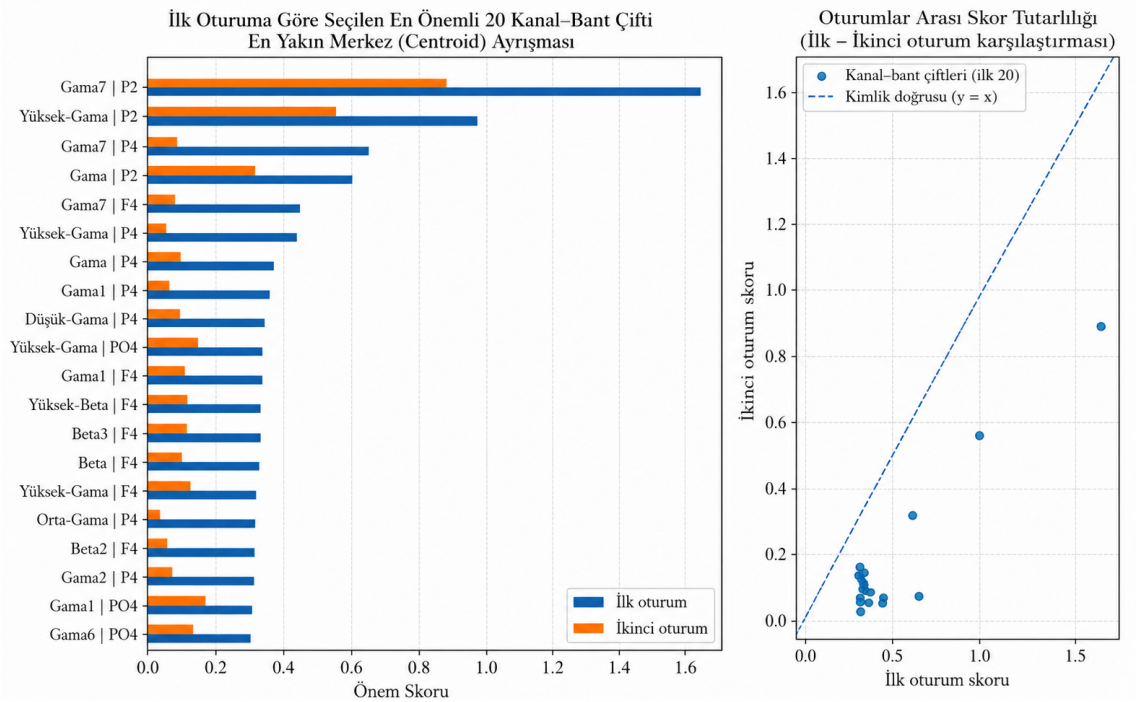

Şekil 4.15 En yakın merkez tabanlı ayrışma ölçütüne göre seçilen en önemli 20 kanal–bant çiftinin ilk ve ikinci oturumdaki önem puanları ile oturumlar arası puan tutarlılığının gösterimi

Şekil 4.15 incelendiğinde, merkez tabanlı ayrışma ölçütünün görece dengeli ve tekdüze bir kanal–bant dağılımı sunduğu görülmektedir. Özellikle gama, yüksek gama ve yüksek beta bantlarının P2, P4, F4 ve PO4 elektrotlarıyla birlikte öne çıkması, bu frekans bantlarında elde edilen özniteliklerin bireyler arasında tutarlı geometrik uzaklık ilişkileri oluşturduğunu düşündürmektedir. Bu durum, yüksek frekanslı EEG bileşenlerinin bireysel sinirsel örüntüleri temsil etmede güçlü katkı sunduğunu göstermektedir.

Şeklin sağ tarafındaki oturumlar arası dağılım grafiğinde noktaların büyük ölçüde $y = x$ kimlik doğrusu çevresinde yer alması, merkez tabanlı ölçütün zamansal değişkenliğe karşı görece kararlı olduğunu göstermektedir. Başka bir ifadeyle, ilk oturumda yüksek puan alan birçok kanal–bant çifti ikinci oturumda da benzer düzeyde yüksek puan üretmiştir. Bu bulgu, merkez tabanlı yaklaşımın yalnızca mutlak ayrışma gücünü değil, sınıflar arası geometrik ilişkilerin oturumlar arasında korunmasını da başarılı biçimde yansıttığını göstermektedir. Dolayısıyla merkez tabanlı ölçüt, tek

kanallı EEG biyometrisi için hem yorumlanabilir hem de oturumlar arası kararlılığı yüksek bir kanal–bant seçim yaklaşımı sunmaktadır.

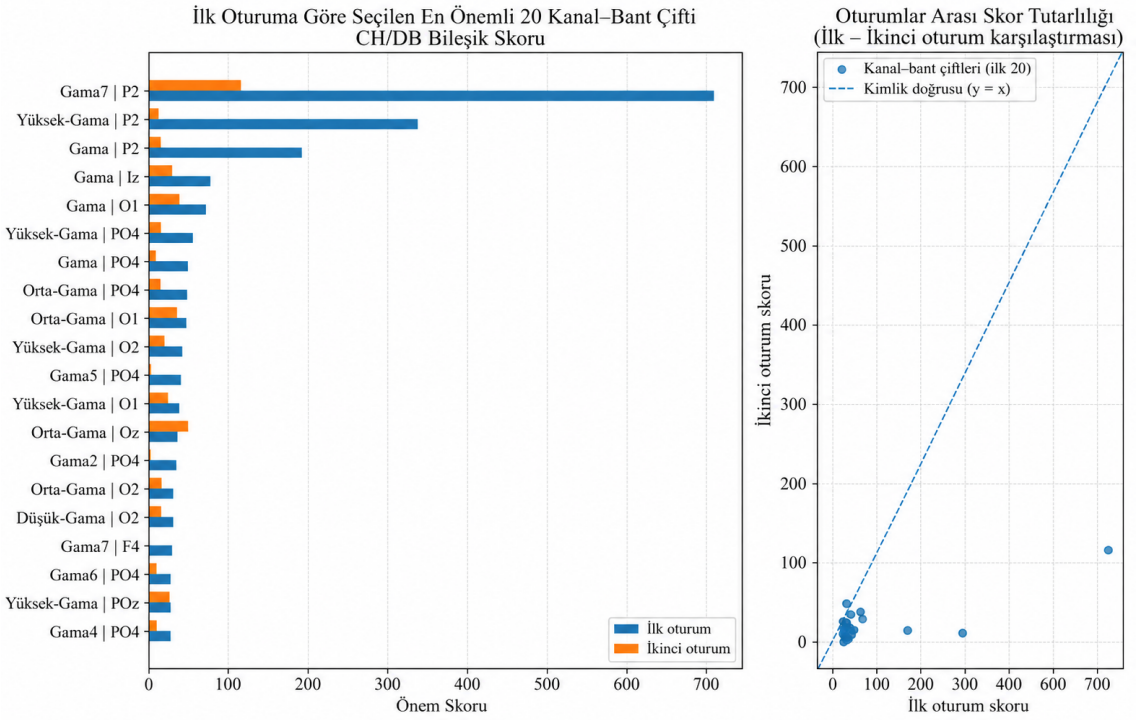

Şekil 4.16 CH/DB bileşik puanı ölçütüne göre seçilen en önemli 20 kanal–bant çiftinin ilk ve ikinci oturumdaki önem puanları ile oturumlar arası puan tutarlılığının gösterimi

İkinci ölçüt olarak kullanılan CH/DB bileşik puanı, Calinski–Harabasz dizininin Davies–Bouldin dizinine oranlanmasıyla elde edilen birleşik bir ayrışma ölçütüdür. Calinski–Harabasz dizini, sınıflar arası saçılımın sınıf içi saçılıma oranını artırmayı hedeflerken; Davies–Bouldin dizini sınıflar arası benzerlik ve sınıf içi yayılımı dikkate alan bir ayrışma ölçütüdür. Bu iki ölçütün birlikte kullanılması, yüksek sınıflar arası ayrım ve düşük sınıf içi yayılım hedeflerini aynı anda değerlendirmeye olanak tanımaktadır.

Şekil 4.16'te CH/DB bileşik puanına göre seçilen en önemli 20 kanal–bant çifti verilmiştir. Bu ölçüt, özellikle ayrışma gücü çok yüksek olan belirli kanal–bant çiftlerini öne çıkarma eğilimindedir. Şekilde görüldüğü üzere, gama7 | P2 ve yüksek gama | P2 kombinasyonları ilk oturumda belirgin biçimde yüksek puanlar üretmiştir. Bu sonuç, P2 elektrodunun yüksek frekans bileşenleriyle birlikte bireyler arası ayrımı güçlendiren önemli bir bölge olduğunu göstermektedir.

Bununla birlikte, Şekil 4.16'te ikinci oturum puanlarının bazı kanal–bant çiftlerinde ilk oturuma

göre belirgin biçimde düştüğü görülmektedir. Sağ taraftaki oturumlar arası dağılım grafiğinde bazı noktaların $y = x$ doğrusundan uzaklaşması, CH/DB ölçütünün yüksek ayrışma gücü sağlamakla birlikte zamansal değişkenliğe daha duyarlı olabileceğini düşündürmektedir. Bu durum, CH ve DB dizinlerinin doğrudan dağılım geometrisine, sınıf içi yayılıma ve örnekler arası uzaklıklara bağlı olmasıyla ilişkilendirilebilir. EEG işaretindeki oturumlar arası fizyolojik değişkenlik, elektrot yerleşimindeki küçük farklılıklar veya işaret kalitesi değişimleri, bu ölçütte daha belirgin puan farklılıklarına yol açabilmektedir.

Bu nedenle CH/DB bileşik puanı, güçlü ayrıştırıcı adayların belirlenmesi açısından yararlı bir ölçüt olmakla birlikte, tek başına kanal seçimi için yeterli görülmemelidir. Özellikle oturumlar arası biyometrik kimlik tanımlama hedeflendiğinde, bir kanal–bant çiftinin yalnızca ilk oturumda çok yüksek ayrışma sağlaması değil, bu ayrışma gücünü ikinci oturumda da koruyabilmesi beklenmektedir. Bu açıdan CH/DB sonuçları, yüksek başarım potansiyeli taşıyan adayları ortaya koyarken, bu adayların merkez tabanlı ölçüt veya varyans oranı gibi daha kararlılık odaklı ölçütlerle birlikte değerlendirilmesi gerektiğini göstermektedir.

Üçüncü olarak ANOVA tabanlı η^2 etki büyüklüğü kullanılmıştır. η^2 ölçütü, belirli bir kanal–bant kombinasyonunda gözlenen toplam varyansın ne kadarının bireyler arası farklılıklardan kaynaklandığını göstermektedir. Bu yönüyle η^2, kanal–bant çiftinin bireye özgü ayırt edici bilgi taşıma düzeyini istatistiksel etki büyüklüğü üzerinden değerlendirmektedir. Ancak bu ölçüt, sınıf merkezleri arasındaki geometrik uzaklık ilişkilerini veya örneklerin çok boyutlu dağılım yapısını doğrudan dikkate almamaktadır. Bu nedenle η^2 sonuçlarının daha temkinli ve istatistiksel etki odaklı yorumlanması gerekmektedir.

Şekil 4.17'te η^2 ölçütüne göre seçilen en önemli 20 kanal–bant çifti verilmiştir. Sonuçlar incelendiğinde, gama ve yüksek gama bantlarının P2, P4 ve PO4 elektrotlarıyla birlikte öne çıktığı görülmektedir. Bu bulgu, merkez tabanlı ve CH/DB temelli analizlerle genel olarak uyumludur. Dolayısıyla farklı ölçütlerin, özellikle arka ve duvar-artkafa bölgelerdeki yüksek frekanslı bileşenlerin biyometrik açıdan önemli olduğunu ortak biçimde işaret ettiği söylenebilir.

η^2 temelli sonuçlarda ilk ve ikinci oturum puanlarının genel eğilim açısından benzerlik göstermesi, bu ölçütün oturumlar arası tutarlılık bakımından dengeli bir yapı sunduğunu göstermektedir. Bununla birlikte, mutlak puan değerlerinin merkez tabanlı ve sınıflar arası/sınıf içi varyans oranı yön-

temlerine kıyasla daha dar bir aralıkta kaldığı dikkat çekmektedir. Bu durum, η^2 ölçütünün ayrışma derecesini daha temkinli biçimde ifade ettiğini göstermektedir. Başka bir ifadeyle η^2, yüksek frekans bantlarındaki seçiciliği başarıyla yansıtsa da, kanal–bant çiftleri arasındaki farkları geometrik ölçütler kadar keskin biçimde büyütmemektedir.

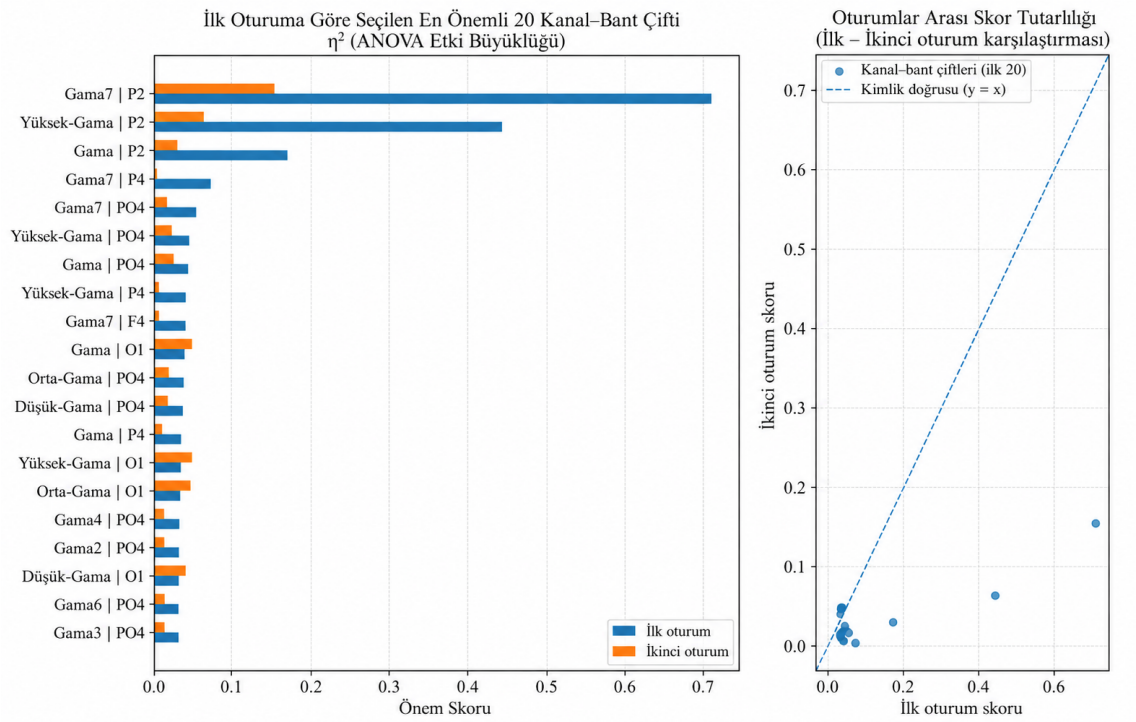

Şekil 4.17 η^2 ölçütüne göre seçilen en önemli 20 kanal–bant çiftinin ilk ve ikinci oturumdaki önem puanları ile oturumlar arası puan tutarlılığının gösterimi

Bu özellik, η^2 ölçütünü özellikle tamamlayıcı bir analiz aracı hâline getirmektedir. Çünkü çok yüksek ayrışma puanları üreten fakat oturumlar arası değişkenliğe duyarlı ölçütlerin yanında, η^2 daha istatistiksel ve dengeli bir bakış açısı sunmaktadır. Bu nedenle η^2 sonuçları, kanal–bant çiftlerinin yalnızca sınıflandırıcı başarımına olası katkısını değil, bireyler arası varyansa dayalı genel etki büyüklüğünü de değerlendirmek için kullanılmıştır.

Dördüncü ölçüt olarak sınıflar arası/sınıf içi varyans oranı kullanılmıştır. Bu ölçüt, Fisher tipi ayırt edicilik yaklaşımıyla ilişkili olup, bireyler arası değişkenliğin yüksek ve birey içi değişkenliğin düşük olduğu kanal–bant çiftlerini öne çıkarmaktadır. EEG biyometrisi açısından bu yaklaşım son derece anlamlıdır. Çünkü ideal bir biyometrik EEG özelliği, farklı bireyler arasında belirgin biçimde değişirken aynı birey içinde ve farklı oturumlarda olabildiğince kararlı kalmalıdır.

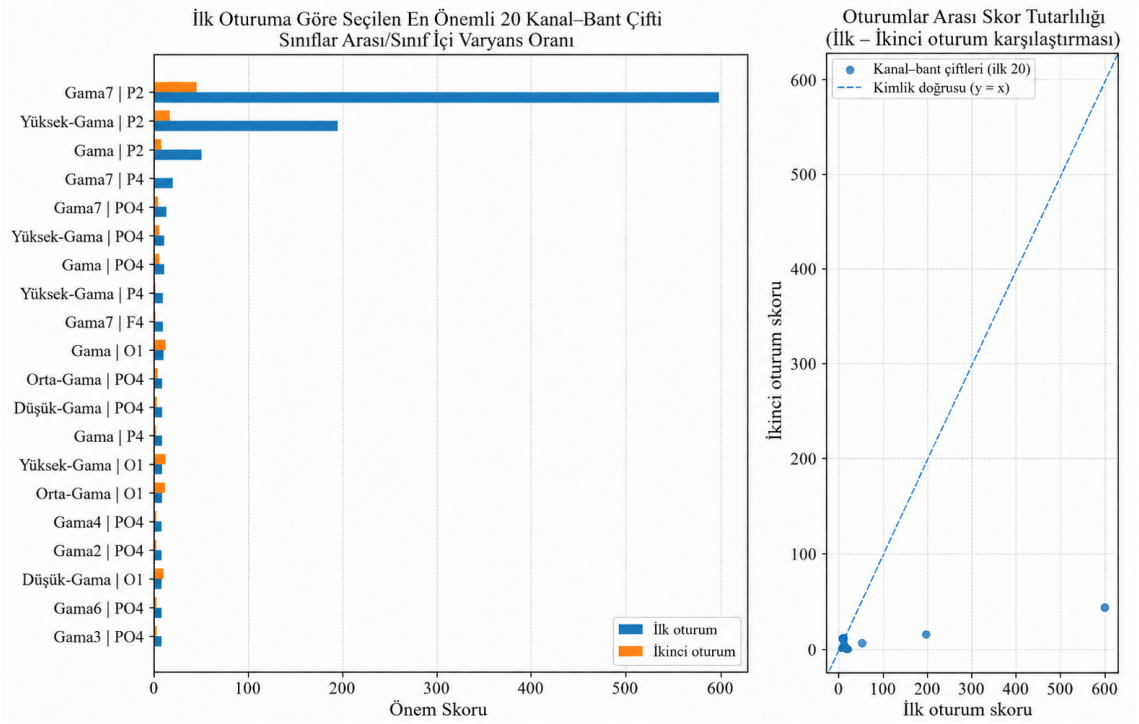

Şekil 4.18 Sınıflar arası/sınıf içi varyans ölçütüne göre seçilen en önemli 20 kanal–bant çiftinin ilk ve ikinci oturumdaki önem puanları ile oturumlar arası puan tutarlılığının gösterimi

Şekil 4.18'da sınıflar arası/sınıf içi varyans oranına göre seçilen en önemli 20 kanal–bant çifti sunulmaktadır. İlk oturum sonuçlarında öne çıkan kanal–bant çiftlerinin büyük ölçüde gama ve yüksek gama bantlarında yoğunlaştığı; elektrot düzeyinde ise P2, P4, PO4, O1 ve F4 bölgelerinin belirgin katkı sunduğu görülmektedir. Bu bulgu, yüksek frekanslı EEG bileşenlerinin bireyler arası ayrımı güçlendirdiğini ve özellikle arka-duvarsal bölgelerin biyometrik bilgi taşıma açısından önemli olduğunu desteklemektedir.

Şekil 4.18'daki oturumlar arası tutarlılık grafiği, seçilen kanal–bant çiftlerinin büyük bölümünün $y = x$ doğrusu çevresinde konumlandığını göstermektedir. Bu durum, sınıflar arası/sınıf içi varyans oranı ile seçilen özniteliklerin yalnızca belirli bir kayıt anına özgü olmadığını; farklı kayıt zamanlarında da benzer ayrıştırıcı yapılarını koruyabildiğini göstermektedir. Dolayısıyla bu ölçüt, hem bireyler arası ayrımı hem de birey içi kararlılığı birlikte değerlendirdiği için oturumlar arası EEG biyometrisi açısından güçlü bir seçim kriteri sunmaktadır.

Dört yöntem birlikte değerlendirildiğinde, kanal–bant seçimi sonuçlarının belirli ortak eğilimler gösterdiği görülmektedir. İlk olarak, P2, P4, PO4, O1, O2 ve F4 elektrotları farklı ölçütlerde tekrar tekrar öne çıkmaktadır. Bu durum, ayırt edici EEG bilgisinin özellikle duvarsal, duvar-artkafa ve

artkafasal bölgelerde yoğunlaştığını göstermektedir. İkinci olarak, gama ve yüksek gama bantları farklı seçim ölçütlerinde baskın biçimde temsil edilmiştir. Bu bulgu, yüksek frekanslı EEG bileşenlerinin bireye özgü sinirsel imzalar açısından düşük frekans bantlarına kıyasla daha güçlü ayırt edici bilgi taşıyabileceğini düşündürmektedir. Üçüncü olarak, merkez tabanlı ayrışma ve sınıflar arası/sınıf içi varyans oranı yöntemleri, hem ayrışma gücü hem de oturumlar arası kararlılık açısından daha dengeli sonuçlar üretmiştir. Buna karşılık CH/DB bileşik puanı, çok güçlü ayrıştırıcı adayları belirlemede etkili olmakla birlikte zamansal değişkenliğe daha duyarlı bir yapı sergilemiştir.

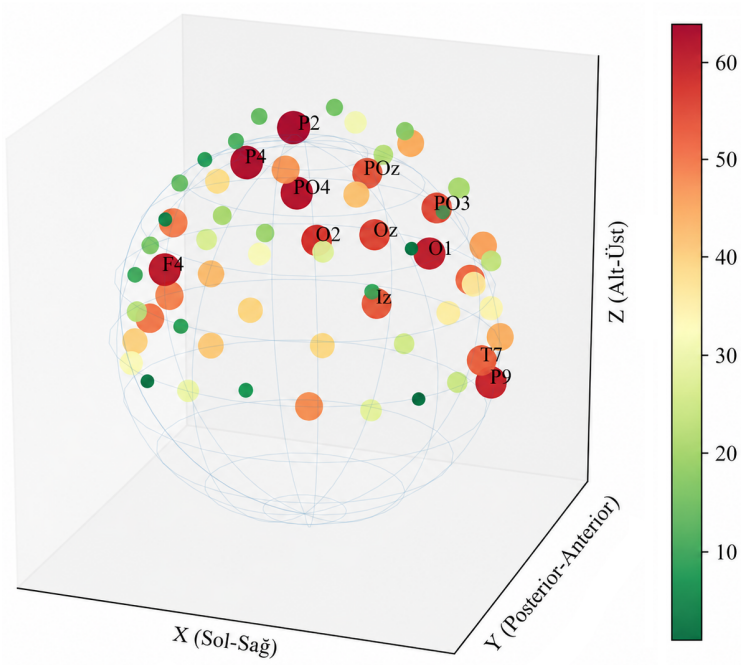

Şekil 4.19 Sınıflar arası/sınıf içi varyans oranı ayrışma ölçütüne göre EEG kanallarının üç boyutlu önem dağılımı

Elde edilen kanal dağılımı, sinir işlevbilimsel açıdan da anlamlıdır. Duvarsal ve duvar-artkafa bölgeler; görsel-uzamsal işlemleme, dikkat yönelimi, duyusal bütünleştirme ve algısal organizasyon gibi süreçlerle ilişkilendirilmektedir. Bu süreçler bireyler arasında farklı bilişsel yöntemler, algısal eğilimler ve sinirsel organizasyon biçimleri gösterebilir. Dolayısıyla bu bölgelerden elde edilen dinlenim durumu EEG işaretlerinin biyometrik kimlik tanımlama açısından ayırt edici bilgi içermesi beklenebilir. Özellikle gözler kapalı dinlenim durumunda arka bölgelerdeki ritmik etkinliğinin belirginleşmesi, bu elektrotların öne çıkmasını destekleyen bir diğer etken olarak değerlendirilebilir.

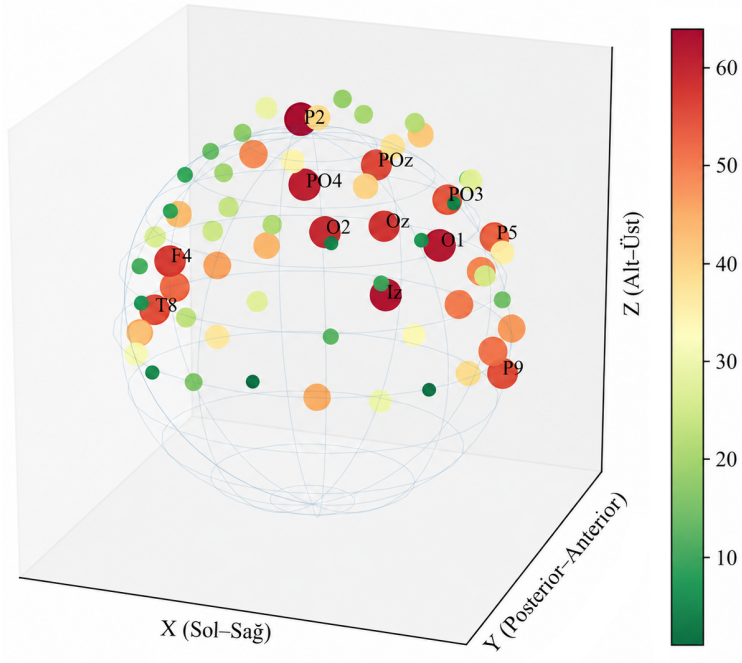

Şekil 4.20 CH/DB bileşik puanı ayrışma ölçütüne göre EEG kanallarının üç boyutlu önem dağılımı

Frekans bantları açısından bakıldığında, gama ve yüksek gama bantlarının baskınlığı, bireylere özgü beyin kabuğuna ilişkin mikro-dinamiklerin yüksek frekanslı sinirsel eşzamanlama üzerinden temsil edilebileceğini düşündürmektedir. Gama bandı etkinliği; yerel sinirsel topluluklar arasındaki zamanlama, dikkat, algısal bağlanma ve bilgi bütünleştirme süreçleriyle ilişkilendirilmektedir. Yüksek gama bileşenleri ise daha kısa zaman ölçeklerinde gerçekleşen yerel beyin kabuğuna ilişkin işlemlemeye duyarlı olabilir. Bu nedenle yüksek frekans bantlarının EEG tabanlı kimlik tanımlama probleminde ayırt edici çıkması, bireylerin beyin kabuğuna ilişkin mikrodevre organizasyonlarındaki farklılıkların EEG işaretine yansımasıyla açıklanabilir. Bununla birlikte, yüksek frekans bantlarının EMG gibi kas kaynaklı bozulmalara daha duyarlı olabileceği de unutulmamalıdır. Bu nedenle yüksek frekans bantlarına dayalı biyometrik yorumlar, gürültü tespit ve giderim süreciyle birlikte değerlendirilmelidir.

Kanal–bant seçim analizlerinin ikinci aşamasında, farklı ölçütlere göre elde edilen elektrot önem dağılımları üç boyutlu kafa yüzeyi görselleştirmeleriyle incelenmiştir. Bu görselleştirmelerde elektrot önemleri nokta boyutu ve renk ölçeğiyle temsil edilmiştir. Daha büyük ve kırmızıya yaklaşan elektrotlar daha yüksek ayırt ediciliği gösterirken, daha küçük ve yeşil tonlardaki elektrotlar daha düşük göreli öneme karşılık gelmektedir. Bu görseller, kanal öneminin yalnızca liste grafik üzerinden değil, kafa yüzeyi üzerindeki uzamsal dağılım bakımından da yorumlanmasını sağlamaktadır.

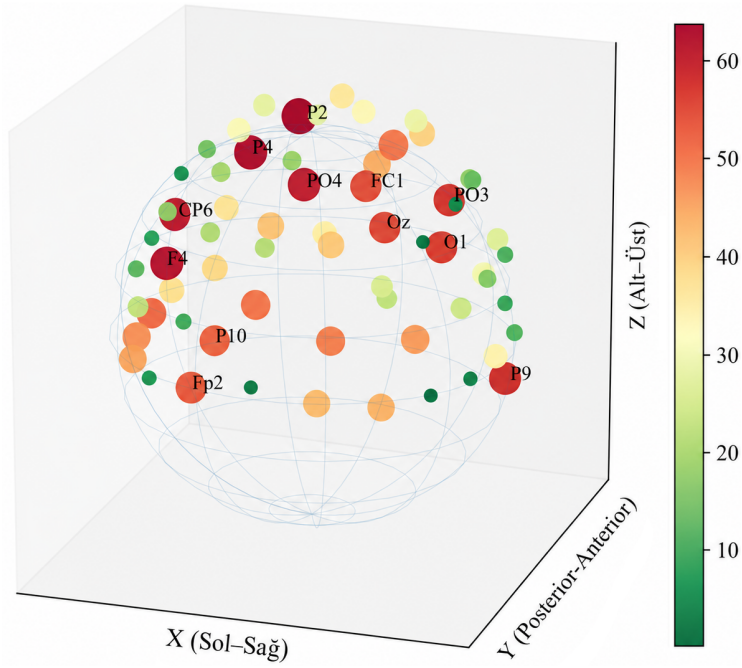

Şekil 4.21 Merkez tabanlı ayrışma ölçütüne göre EEG kanallarının üç boyutlu önem dağılımı

Şekil 4.19 sınıflar arası/sınıf içi varyans oranına göre EEG kanallarının üç boyutlu önem dağılımını göstermektedir. Görsel incelendiğinde, yüksek önem değerlerinin özellikle arka ve duvarsal bölgelerde yoğunlaştığı görülmektedir. Bu sonuç, Şekil 4.18'da elde edilen kanal–bant sıralamalarıyla uyumludur. Özellikle P2, P4, PO4 ve artkafasal bölgeye yakın elektrotların yüksek göreli önem değerleri üretmesi, sınıflar arası varyansı yüksek ve sınıf içi varyansı düşük olan EEG bileşenlerinin kafa yüzeyinde belirli bölgelerde kümelendiğini göstermektedir.

Şekil 4.20'de CH/DB bileşik puanı ayrışma ölçütüne göre elektrot önem dağılımı verilmiştir. Bu görselde de arka ve duvarsal bölgelerin belirgin biçimde öne çıktığı görülmektedir. Bununla birlikte CH/DB ölçütünün bazı elektrotlarda daha keskin önem farklılıkları ürettiği dikkat çekmektedir. Bu durum, CH/DB ölçütünün yüksek ayrışma gücüne sahip belirli kanal adaylarını güçlü biçimde vurgulama eğilimiyle uyumludur. Ancak önceki kanal–bant analizinde görüldüğü gibi, bu yüksek ayrışma değerleri oturumlar arası kararlılık açısından ayrıca değerlendirilmelidir.

Şekil 4.21'da merkez tabanlı ayrışma ölçütüne göre elektrot önem dağılımı sunulmaktadır. Merkez tabanlı görselleştirmede, elektrot önemlerinin daha dengeli bir uzamsal dağılım sergilediği; ancak yine arka-duvarsal bölgelerin baskınlığını koruduğu görülmektedir. Bu bulgu, merkez tabanlı yaklaşımın tekil aşırı puanlara dayalı seçim yapmak yerine, sınıflar arası geometrik ilişkilerin daha genel ve kararlı bir temsilini sunduğunu desteklemektedir.

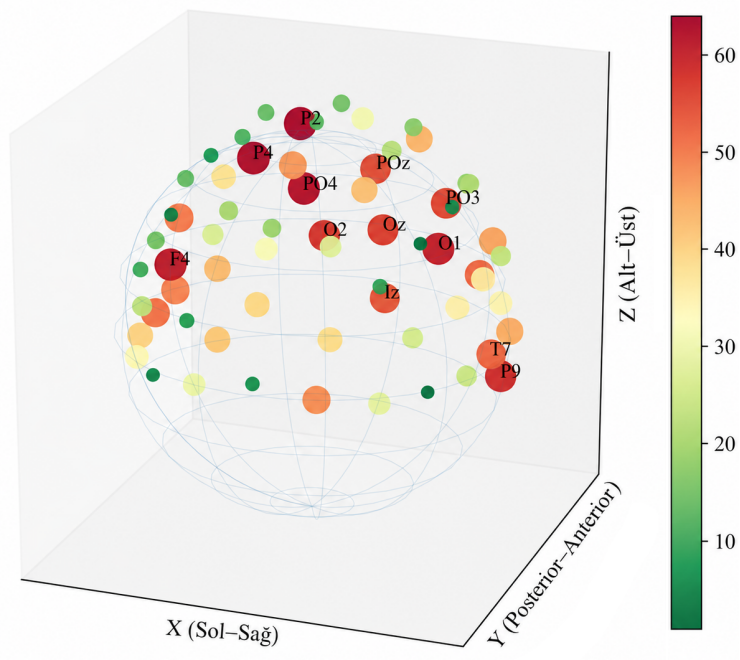

Şekil 4.22 η^2 tabanlı ayrışma ölçütlerine göre EEG kanallarının üç boyutlu önem dağılımı

Şekil 4.22'de η^2 tabanlı ayrışma ölçütüne göre EEG kanallarının üç boyutlu önem dağılımı gösterilmektedir. Bu ölçütte elektrot önemlerinin daha temkinli bir aralıkta dağıldığı, ancak genel bölgesel dağılım eğilimin diğer yöntemlerle uyumlu olduğu görülmektedir. Özellikle duvarsal ve duvar-artkafa bölgelerin tekrar öne çıkması, bu bölgelerin yöntemden bağımsız olarak biyometrik bilgi taşıdığını göstermektedir. η^2 ölçütünün daha dar puan aralığı üretmesi, uzamsal haritada daha yumuşak geçişler oluşmasına neden olmakta; bu da ölçütün ayrışmayı daha istatistiksel ve dengeli bir biçimde temsil ettiğini düşündürmektedir.

Üç boyutlu elektrot önem haritaları birlikte değerlendirildiğinde, farklı ayrışma ölçütlerinin ayrıntı düzeyinde farklılıklar göstermesine rağmen genel uzamsal eğilim bakımından tutarlı sonuçlar ürettiği görülmektedir. Tüm yöntemlerde ayırt edici bilginin özellikle arka kafa, duvarsal ve duvar-artkafa bölgelerde yoğunlaştığı gözlenmiştir. Bu tutarlılık, kanal seçimi sonuçlarının belirli bir ölçüte özgü rastlantısal bir bulgu olmadığını; farklı istatistiksel ve geometrik ölçütler tarafından desteklenen daha genel bir EEG biyometrik örüntüsüne işaret ettiğini göstermektedir.

Bu analizlerin model geliştirme sürecine iki temel katkısı olmuştur. İlk olarak, kanal–bant sonuçları tek kanallı EEG biyometrik sistemleri için hangi elektrot bölgelerinin daha yüksek önceliğe sahip olabileceğini ortaya koymuştur. Özellikle P2, P4, PO4 ve artkafasal bölgeye yakın elektrotların tekrarlı biçimde öne çıkması, sonraki sınıflandırıcı başarım analizlerinde bu kanalların ayrı ayrı

değerlendirilmesine zemin hazırlamıştır. İkinci olarak, frekans bantları açısından gama ve yüksek gama bileşenlerinin baskın katkısı, önerilen çok ölçekli ESA yapısında yüksek frekans bileşenlerini temsil eden dalların önemini desteklemiştir. Böylece kanal–bant seçimi analizi, yalnızca sonuçların yorumlanmasına değil, model mimarisinin frekans duyarlı tasarımının gerekçelendirilmesine de katkı sunmuştur.

Sonuç olarak, kanal–frekans bandı seçimi ve oturumlar arası kararlılık analizi, EEG tabanlı biyometrik kimlik tanımlama probleminde ayırt edici bilginin belirli kanal ve frekans bileşenlerinde yoğunlaştığını göstermektedir. Farklı ölçütlerin ortak biçimde arka-duvarsal elektrotları ve yüksek frekans bantlarını öne çıkarması, bu bölgelerin ve bantların bireye özgü sinirsel imzalar açısından önemli olduğunu desteklemektedir. Merkez tabanlı ayrışma ve sınıflar arası/sınıf içi varyans oranı, oturumlar arası kararlılık açısından daha dengeli sonuçlar sunarken; CH/DB bileşik puanı yüksek ayrışma gücüne sahip fakat zamansal değişkenliğe daha duyarlı adayları belirlemiştir. η^2 ölçütü ise bireyler arası etki büyüklüğünü daha temkinli ve istatistiksel olarak yorumlanabilir biçimde ortaya koymuştur. Bu nedenle tez kapsamında kanal seçimi tek bir ölçütün sonucuna indirgenmemiş; farklı ayrışma ölçütlerinin ortak ve ayrışan bulguları birlikte değerlendirilerek daha güvenilir bir kanal–bant yorumlama çerçevesi oluşturulmuştur.

4.4 Model Eğitim Süreci ve DEHB Tabanlı Üst Değişken Eniyilemesi Sonuçları

Bu alt bölümde, tez kapsamında geliştirilen karma ESA–ÇY-UKSB–Dönüştürücü modelinin eğitim sürecine ilişkin temel bulgular ve DEHB tabanlı üst değişken eniyilemesi sonucunda elde edilen en iyi model yapılandırması sunulmaktadır. Önceki yöntem bölümünde önerilen modelin mimari bileşenleri ve DEHB algoritmasının çalışma ilkesi ayrıntılı olarak açıklandığından, burada algoritmanın kuramsal denklemleri tekrar verilmemiş; bunun yerine eniyileme sürecinin deneysel çıktıları, seçilen üst değişkenlerin model davranışı açısından anlamı ve doğrulama kaybındaki değişimin yorumlanması üzerinde durulmuştur.

Önerilen model, tek kanallı EEG pencerelerinden bireye özgü ve oturumlar arasında korunabilen ayırt edici örüntüleri öğrenmek üzere tasarlanmıştır. Modelin girişini 4 saniyelik örtüşmesiz EEG pencereleri oluşturmakta; her pencere 4096×1 boyutunda tek kanallı zaman serisi olarak temsil edilmektedir. Ana deneysel kurgu, iki oturumu bulunan 42 katılımcıya dayalı kapalı-küme kimlik

tanımlama senaryosu olduğundan, modelin çıktı katmanı 42 kayıtlı birey için olasılıksal sınıf puanları üretmektedir. Bu yapı, modelin yalnızca nihai kimlik etiketi üretmesini değil; aynı zamanda aday sıralama, ilk-k doğruluk, KEK ve kişi düzeyi karar birleştirme gibi ölçütlerin hesaplanmasına da olanak sağlamaktadır.

Derin öğrenme tabanlı EEG biyometrik modellerinde üst değişken seçimi, model başarımını doğrudan etkileyen kritik bir aşamadır. EEG işaretlerinin düşük genlikli, durağan olmayan, gürültüye duyarlı ve oturumlar arası değişkenlik gösteren yapısı nedeniyle, model kapasitesi ile düzenlileştirme düzeyi arasında dikkatli bir denge kurulmalıdır. Çok yüksek kapasiteli modeller eğitim verisindeki oturuma özgü geçici örüntüleri veya gürültü bileşenlerini öğrenme eğilimi gösterebilirken, yetersiz kapasiteli modeller bireye özgü ince zamansal ve spektral örüntüleri ayırt etmekte zorlanabilir. Bu nedenle üst değişken eniyilemesi yalnızca doğrulama doğruluğunu artırmaya yönelik teknik bir adım olarak değil, modelin oturumlar arası genellenebilirliğini destekleyen temel bir yöntemsel bileşen olarak ele alınmıştır.

Bu çalışmada üst değişken eniyilemesi için DEHB algoritması kullanılmıştır. DEHB'nin tercih edilmesindeki temel gerekçe, geniş üst değişken uzaylarında hesaplama maliyetini kontrol altında tutarken, umut vadeden aday yapılandırmalar etrafında aramayı yoğunlaştırabilmesidir. Bu süreçte öğrenme oranı, yığın boyutu, seyrelme oranı, ESA süzgeç sayısı, çekirdek ölçek katsayısı, ÇY-UKSB gizli birim sayısı, Dönüştürücü başlık sayısı, Dönüştürücü katman sayısı, tam bağlantılı katman boyutu ve ağırlık bozunumu gibi modelin öğrenme dinamiğini ve genellenebilirliğini etkileyen üst değişkenler birlikte değerlendirilmiştir. Eniyileme ölçütü olarak, eğitim oturumundan ayrılan doğrulama kümesinde elde edilen doğrulama kaybı temel alınmıştır. Böylece seçilen yapılandırmanın yalnızca eğitim verisine uyum sağlaması değil, eğitim sürecinde doğrudan görülmeyen doğrulama örnekleri üzerinde de düşük hata üretmesi hedeflenmiştir.

Modelin eğitim sürecinde toplam 120 eğitim turu tanımlanmış ve doğrulama başarımını izleyen erken durdurma yöntemi kullanılmıştır. Erken durdurma için sabır değeri 15 eğitim turu olarak belirlenmiştir. En iyi doğrulama başarımı 91. eğitim turu civarında elde edilmiştir. Bu durum, modelin bu noktaya kadar eğitim verisinden ayırt edici temsilleri etkili biçimde öğrendiğini; bu noktadan sonra ise ek eğitim turlarının doğrulama başarımına sınırlı katkı sunduğunu göstermektedir. Eğitim sürecinin sonunda en düşük eğitim kaybı $0{,}0068 \pm 0{,}0014$, en düşük doğrulama kaybı ise $0{,}0149 \pm 0{,}0032$ olarak elde edilmiştir. Eğitim kaybı ile doğrulama kaybı arasındaki farkın sınırlı

düzeyde kalması, modelin eğitim verisine aşırı uyum göstermeden doğrulama verisinde de kararlı bir öğrenme davranışı sergilediğini düşündürmektedir.

Doğruluk değerleri açısından değerlendirildiğinde, modelin en yüksek eğitim doğruluğu $\%99{,}86 \pm 0{,}12$, en yüksek doğrulama doğruluğu ise $\%99{,}52 \pm 0{,}35$ olarak elde edilmiştir. Eğitim ve doğrulama doğrulukları arasındaki yaklaşık 0,34 yüzde puanlık fark, modelin eğitim verisindeki yüksek başarıyı doğrulama verisine büyük ölçüde aktarabildiğini göstermektedir. Bu sonuç, önerilen ESA–ÇY-UKSB–Dönüştürücü mimarisinin tek kanallı EEG pencerelerinden bireye özgü örüntüleri öğrenebildiğini ve bu öğrenmenin eğitim bölmesine aşırı özgülenmediğini desteklemektedir. Eğitim süresi $38{,}6 \pm 2{,}4$ dakika olarak ölçülmüştür. Bu süre, modelin yüksek doğruluk düzeyine ulaşmasına rağmen pratik hesaplama maliyeti açısından uygulanabilir bir eğitim süreci sunduğunu göstermektedir.

DEHB eniyilemesi sonucunda seçilen en iyi üst değişkenler Çizelge 4.4'te verilmiştir. Seçilen yapılandırmada öğrenme oranı 3×10^{-4}, yığın boyutu 64 ve seyrelme oranı 0,30 olarak belirlenmiştir. Öğrenme oranının bu düzeyde seçilmesi, modelin kararlı biçimde yakınsamasını sağlarken ani ve dengesiz ağırlık güncellemelerinden kaçınılmasına katkı sunmaktadır. Yığın boyutunun 64 olması, eğim tahmininde kararlılık ile bellek kullanımı arasında dengeli bir tercih sağlamaktadır. Seyrelme oranının 0,30 olarak belirlenmesi ise modelin yüksek temsil kapasitesine rağmen aşırı öğrenme eğilimini sınırlandırmaya yönelik önemli bir düzenlileştirme bileşeni olarak değerlendirilebilir.

Mimari kapasite açısından incelendiğinde, ESA süzgeç sayısının 64 olarak seçilmesi, tek kanallı EEG penceresinden farklı zaman ölçeklerinde yeterli sayıda yerel örüntü çıkarılmasına olanak tanımaktadır. Çekirdek ölçek katsayısının 1,0 olarak belirlenmesi, yöntem bölümünde tanımlanan frekans-duyarlı çekirdek yapısının doğrudan korunması anlamına gelmektedir. ÇY-UKSB gizli birim sayısının 128 olması, pencere içerisindeki ileri ve geri yönlü zamansal bağımlılıkların yeterli kapasiteyle temsil edilmesini sağlamaktadır. Dönüştürücü başlık sayısının 4 ve katman sayısının 2 olarak seçilmesi ise uzun menzilli dikkat ilişkilerinin modellenmesi için yeterli bir yapı sunarken, model karmaşıklığının aşırı artmasını engellemektedir. Bu durum, EEG gibi sınırlı uzunlukta ve gürültüye duyarlı işaretlerde temsil kapasitesi ile genellenebilirlik arasında dengeli bir yapı kurulduğunu göstermektedir.

Tam bağlantılı katman boyutunun 128 olarak seçilmesi, Dönüştürücü sonrası elde edilen yüksek

düzeyli temsilin sınıflandırıcı başlığına yeterli bilgi yoğunluğuyla aktarılmasını sağlamaktadır. Ağırlık bozunumu değerinin 1×10^{-5} düzeyinde seçilmesi ise model değişkenlerinin büyümesini sınırlandırarak daha düzgün karar yüzeyleri oluşturulmasına katkıda bulunmaktadır. Bu düzenlileştirme etkisi, özellikle oturumlar arası değerlendirme açısından önemlidir; çünkü modelin yalnızca birinci oturuma özgü geçici kayıt koşullarını öğrenmesi yerine, bireye özgü daha kararlı EEG temsillerine yönelmesi beklenmektedir.

Çizelge 4.4 DEHB eniyilemesi ile seçilen en iyi üst değişkenler

Üst Değişken / Ölçüt	**Seçilen Değer**
Öğrenme oranı	3×10^{-4}
Yığın boyutu	64
Seyrelme oranı	0,30
ESA süzgeç sayısı	64
Çekirdek ölçek katsayısı	1,0
ÇY-UKSB gizli birim sayısı	128
Dönüştürücü başlık sayısı	4
Dönüştürücü katman sayısı	2
Tam bağlantılı katman boyutu	128
Ağırlık bozunumu	1×10^{-5}
En iyi doğrulama kaybı	0,0149 $\pm$ 0,0032
En iyi doğrulama doğruluğu	%99,52 $\pm$ 0,35
Toplam değerlendirilen aday yapılandırma sayısı	96
Toplam eniyileme süresi	11,8 saat

Çizelge 4.4'teki sonuçlar, DEHB eniyilemesinin önerilen karma model için yüksek doğrulama başarımı sağlayan dengeli bir yapılandırma belirlediğini göstermektedir. En iyi doğrulama kaybının $0{,}0149 \pm 0{,}0032$, en iyi doğrulama doğruluğunun ise $\%99{,}52 \pm 0{,}35$ olarak elde edilmesi, seçilen üst değişkenlerin modelin doğrulama verisi üzerinde güçlü bir ayırt edicilik sağladığını göstermektedir. Bununla birlikte, bu sonuçlar doğrudan nihai test başarımı olarak yorumlanmamıştır. Doğrulama sonuçları, üst değişken seçimi için kullanılmış; modelin asıl genellenebilirliği ise izleyen bölümde sunulan ana oturumlar arası test protokolü, ters yönlü protokol, model karşılaştırmaları ve kişi düzeyi karar birleştirme analizleri ile değerlendirilmiştir.

DEHB eniyileme sürecindeki doğrulama kaybı değişimi Şekil 4.23'de gösterilmiştir. Grafikte yatay eksen değerlendirilen aday üst değişken yapılandırmalarını, dikey eksen ise o ana kadar elde edilen en iyi doğrulama kaybını göstermektedir. Bu gösterim, eniyileme sürecinin yalnızca ulaştığı son değeri değil, arama süreci boyunca doğrulama kaybında meydana gelen iyileşmenin seyrini de

ortaya koymaktadır.

Şekil 4.23'de görüldüğü üzere, eniyileme sürecinin başlangıcında doğrulama kaybı yaklaşık 0,215 düzeyindeyken, süreç sonunda 0,0149 değerine kadar düşmüştür. Eğrinin ilk değerlendirmelerde hızlı biçimde azalması, DEHB algoritmasının uygun olmayan aday yapılandırmaları erken aşamada eleyebildiğini ve daha başarılı yapılandırmalara doğru yöneldiğini göstermektedir. Bu aşamada öğrenme oranı, model kapasitesi, düzenlileştirme düzeyi veya dikkat yapısı uygun olmayan adayların doğrulama kaybı yüksek kalmış; bu adaylar daha yüksek kaynak bütçelerine taşınmadan elenmiştir. Hesaplama maliyeti umut vadeden yapılandırmalara yönlendirilmiştir.

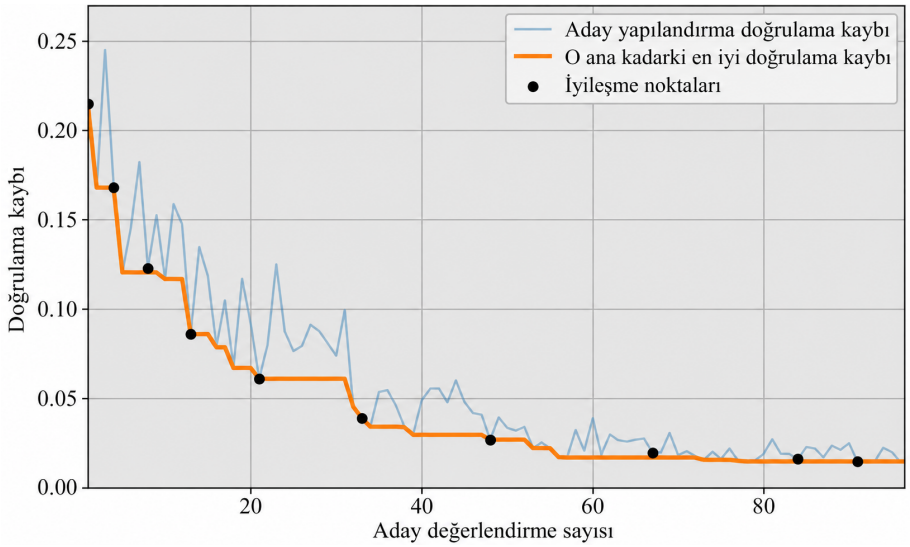

Şekil 4.23 DEHB tabanlı üst değişken eniyilemesinde doğrulama kaybının değişimi

Eniyileme sürecinin ilerleyen bölümünde doğrulama kaybındaki düşüş daha sınırlı ve kademeli hâle gelmiştir. Bu durum, arama sürecinin başlangıçtaki kaba ayrıştırma aşamasından daha ince bir ayarlama aşamasına geçtiğini düşündürmektedir. Başka bir ifadeyle, DEHB başlangıçta doğrulama kaybını belirgin biçimde düşüren temel üst değişken bölgelerini bulmuş; daha sonra bu bölgeler içinde daha küçük fakat anlamlı iyileştirmeler sağlayan adayları değerlendirmiştir. Eğrinin son bölümünde plato davranışına yaklaşması, doğrulama kaybı açısından en uygun bölgeye büyük ölçüde ulaşıldığını ve kalan aday değerlendirmelerin sınırlı ek kazanç ürettiğini göstermektedir.

DEHB sürecinde toplam 96 aday üst değişken yapılandırmasının değerlendirilmiş olması, model yapılandırmasının yalnızca manuel deneme-yanılma yaklaşımıyla değil, sistematik bir arama süre-

ciyle belirlendiğini göstermektedir. Toplam eniyileme süresinin 11,8 saat olması, önerilen karma modelin karmaşıklığı dikkate alındığında makul bir hesaplama maliyetine işaret etmektedir. Bu bulgu, DEHB tabanlı eniyilemenin yalnızca başarım açısından değil, hesaplama verimliliği açısından da uygun bir seçenek olduğunu göstermektedir.

Seçilen üst değişkenlerin birlikte değerlendirilmesi, modelin üç temel gereksinimi karşıladığını göstermektedir. İlk olarak, 64 ESA süzgeci ve çok ölçekli çekirdek yapısı tek kanallı EEG penceresinden yerel zamansal örüntülerin çıkarılmasını desteklemektedir. İkinci olarak, 128 gizli birimli ÇY-UKSB katmanı pencere içindeki ileri ve geri yönlü bağımlılıkları modelleyerek EEG işaretinin ardışıl yapısını temsil etmektedir. Üçüncü olarak, 4 başlıklı ve 2 katmanlı Dönüştürücü bileşeni, pencere içerisindeki uzun menzilli ilişkileri dikkat düzeneğiyle ağırlıklandırarak sınıflandırıcıya daha seçici bir temsil sunmaktadır. Bu üç bileşenin DEHB tarafından seçilen düzenlileştirme ve öğrenme değişkenleriyle birlikte kullanılması, yüksek doğrulama doğruluğu ve düşük doğrulama kaybı ile sonuçlanmıştır.

Sonuç olarak, model eğitim süreci ve DEHB tabanlı üst değişken eniyilemesi birlikte değerlendirildiğinde, önerilen karma ESA–ÇY-UKSB–Dönüştürücü modelinin tek kanallı EEG tabanlı kapalı-küme kimlik tanımlama problemi için kararlı ve yüksek başarımlı bir yapılandırmaya ulaştığı görülmektedir. DEHB eniyilemesi, modelin kapasite, düzenlileştirme, öğrenme hızı ve dikkat yapısı bakımından dengeli bir üst değişken kombinasyonu seçmesini sağlamıştır. Bu bölümde elde edilen doğrulama temelli bulgular, izleyen "Kapalı-Küme EEG Tabanlı Kimlik Tanımlama Başarım Analizi" bölümünde sunulacak test protokolleri, model karşılaştırmaları, aday sıralama başarımı, kişi düzeyi karar birleştirme ve kanal–bant analizleri için temel oluşturmaktadır.

4.5 Kapalı-Küme EEG Tabanlı Kimlik Tanımlama Başarım Analizi

Bu alt bölümde, önerilen ESA–ÇY-UKSB–Dönüştürücü tabanlı tek kanallı EEG biyometrik kimlik tanımlama modelinin kapalı-küme deneysel senaryolardaki başarımı ayrıntılı olarak değerlendirilmektedir. Analiz, yalnızca genel doğruluk değerinin raporlanmasına dayandırılmamış; deney protokolleri, eğitim-doğrulama davranışı, model karşılaştırmaları, aday sıralama başarısı, sınıf bazlı hata yapısı, kişi düzeyi karar birleştirme, test süresi etkisi, kanal–bant düzeyi ayırt edicilik, bant dalı katkıları, mimari bileşen çıkarma deneyleri ve tekrarlı deney kararlılığı birlikte ele alınmıştır.

Bu yaklaşımın temel amacı, önerilen modelin yüksek doğruluk değerine nasıl ulaştığını, bu başarının hangi bileşenlerden beslendiğini ve elde edilen başarımın oturumlar arası EEG değişkenliği altında ne ölçüde korunduğunu açıklamaktır.

Kapalı-küme kimlik tanımlama senaryosunda test aşamasında sisteme sunulan her EEG penceresinin eğitim aşamasında kayıtlı bireylerden birine ait olduğu varsayılmıştır. Bu nedenle modelden beklenen temel davranış, her test penceresi için kayıtlı bireyler kümesi içerisinden doğru kimlik etiketini seçmesidir. Ancak EEG biyometrisinde bu problem, klasik görüntü veya parmak izi biyometrisine kıyasla daha zorlu bir yapı sergilemektedir. EEG işaretleri düşük genlikli, durağan olmayan, fizyolojik durumdan etkilenen ve oturumlar arasında değişkenlik gösterebilen biyolojik işaretlerdir. Bu nedenle aynı bireye ait iki farklı oturum arasında gözlenen işaret farklılıkları, farklı bireylere ait örüntüler arasındaki ayrımı zorlaştırabilir. Bu bağlamda, önerilen modelin değerlendirilmesinde yalnızca aynı oturum içi başarı değil, oturumlar arası genellenebilirlik temel ölçüt olarak ele alınmıştır.

4.5.1 Deney protokollerinin karşılaştırılması

Önerilen modelin farklı deneysel koşullara duyarlılığını incelemek amacıyla dört ayrı protokol tanımlanmıştır. Bu protokoller, EEG tabanlı biyometrik kimlik tanımlama sistemlerinin karşılaşabileceği farklı zorluk düzeylerini temsil etmektedir. Aynı oturum içi protokol, modelin kayıt koşulları büyük ölçüde benzer olduğunda ulaşabileceği üst sınır başarımı göstermektedir. Ana oturumlar arası protokol ise bir oturumdan öğrenilen bireye özgü EEG örüntülerinin farklı bir oturumda ne ölçüde tanınabildiğini değerlendirdiği için çalışmanın en kritik ve gerçekçi senaryosudur. Ters yönlü oturumlar arası protokol, modelin başarısının belirli bir oturum yönüne bağımlı olup olmadığını göstermektedir. Karışık oturum protokolü ise her iki oturumdan örneklerin eğitim ve test süreçlerine dâhil edildiği daha heterojen bir karşılaştırma ortamı sağlamaktadır.

Çizelge 4.5'de verilen sonuçlar, deney protokolleri arasında başarımın genel olarak yüksek düzeyde korunduğunu, ancak protokolün zorluk derecesine bağlı olarak sınırlı farklılıklar oluştuğunu göstermektedir. Aynı oturum içi protokolde birinci-sıra doğruluğun $\%99{,}70 \pm 0{,}28$ olması beklenen bir sonuçtur; çünkü eğitim ve test örnekleri aynı kayıt oturumundan elde edildiğinde elektrot yerleşimi, empedans koşulları, katılımcının fizyolojik durumu ve kayıt ortamına ilişkin değişken-

ler daha benzerdir. Bu nedenle aynı oturum içi sonuç, modelin idealize edilmiş koşullardaki üst sınır başarımını temsil etmektedir.

Çizelge 4.5 Deney protokollerine göre kapalı-küme kimlik tanımlama sonuçları

Protokol 1: Aynı oturum içi protokol		
Eğitim verisi	**Test verisi**	**Sonuçlar**
Oturum 1 içi eğitim bölmesi	Oturum 1 içi test bölmesi	Birinci-sıra doğruluk: %99,70 ± 0,28 İlk-3 doğruluk: %99,84 ± 0,18 Makro F1 puanı: %99,68 ± 0,30

Protokol 2: Ana oturumlar arası protokol		
Eğitim verisi	**Test verisi**	**Sonuçlar**
Oturum 1	Oturum 2	Birinci-sıra doğruluk: %99,50 ± 0,35 İlk-3 doğruluk: %100,00 ± 0,00 Makro F1 puanı: %99,48 ± 0,37

Protokol 3: Ters yönlü oturumlar arası protokol		
Eğitim verisi	**Test verisi**	**Sonuçlar**
Oturum 2	Oturum 1	Birinci-sıra doğruluk: %99,42 ± 0,39 İlk-3 doğruluk: %100,00 ± 0,00 Makro F1 puanı: %99,40 ± 0,41

Protokol 4: Karışık oturum protokolü		
Eğitim verisi	**Test verisi**	**Sonuçlar**
Oturum 1 ve Oturum 2 karışık eğitim bölmesi	Oturum 1 ve Oturum 2 karışık test bölmesi	Birinci-sıra doğruluk: %98,23 ± 0,74 İlk-3 doğruluk: %99,18 ± 0,43 Makro F1 puanı: %98,16 ± 0,79

Ana oturumlar arası protokolde birinci-sıra doğruluğun %99,50 ± 0,35 olarak elde edilmesi, aynı oturum içi protokole göre yalnızca 0,20 yüzde puanlık sınırlı bir azalmaya karşılık gelmektedir. EEG biyometrisi açısından bu farkın oldukça küçük olması önemlidir. Çünkü oturumlar arası protokolde model, eğitim sırasında görmediği bir kayıt oturumundaki EEG pencerelerini sınıflandırmaktadır. Bu durumda kayıtlar arası zaman farkı, elektrot konumundaki küçük değişiklikler, katılımcının dikkat ve uyanıklık düzeyi, fizyolojik durum ve İGO gibi etkenler model başarısını düşürebilir. Buna rağmen başarımın büyük ölçüde korunması, önerilen modelin oturuma özgü geçici örüntüler yerine bireye özgü ve zamansal olarak daha kararlı EEG temsillerini öğrenebildiğini göstermektedir.

Ters yönlü oturumlar arası protokolde birinci-sıra doğruluğun %99,42 ± 0,39 düzeyinde kalması, model başarısının eğitim için özellikle birinci oturumun kullanılmasına bağımlı olmadığını göstermektedir. Ana protokol ile ters yönlü protokol arasındaki 0,08 yüzde puanlık fark, oturum yönünün

model üzerinde belirgin bir sapma oluşturmadığını düşündürmektedir. Bu bulgu, EEG biyometrisi açısından değerlidir; çünkü gerçek uygulamalarda kayıtların hangi oturumun daha temiz, daha kararlı veya daha ayırt edici olacağını önceden bilmek her zaman mümkün değildir. Modelin her iki yönde de yüksek başarı üretmesi, öğrenilen temsilin oturum sırasından ziyade bireye özgü EEG karakteristiklerine dayandığını desteklemektedir.

Karışık oturum protokolünde birinci-sıra doğruluğun $\%98{,}23 \pm 0{,}74$ düzeyine düşmesi dikkat çekicidir. İlk bakışta, iki oturumdan örneklerin birlikte kullanıldığı karışık protokolün daha yüksek başarı üretmesi beklenebilir. Ancak bu protokolde eğitim ve test bölmeleri daha heterojen bir veri dağılımı içermekte, aynı sınıfa ait örnekler arasında oturum kaynaklı varyasyon daha karmaşık biçimde dağılmaktadır. Bu durum karar sınırlarının öğrenilmesini zorlaştırabilir. Ayrıca karışık protokolde pencere düzeyi ayrıştırma yöntemi, oturumlar arası protokoldeki kadar açık bir eğitim-test ayrımı sunmadığından, sınıf içi varyansın modele yansıma biçimi değişebilir. Dolayısıyla karışık protokoldeki düşüş, modelin zayıflığından çok, protokolün veri dağılımını daha heterojen hâle getirmesiyle açıklanabilir.

Bu dört protokol birlikte değerlendirildiğinde, önerilen modelin en önemli başarısının ana oturumlar arası protokolde yüksek başarımını koruması olduğu görülmektedir. Aynı oturum içi başarı modelin öğrenme kapasitesini, ana ve ters yönlü oturumlar arası başarılar genellenebilirliğini, karışık oturum protokolü ise heterojen dağılım koşullarındaki davranışını göstermektedir. Bu nedenle izleyen analizlerde ana değerlendirme protokolü olarak Oturum 1 eğitim–Oturum 2 test yapısındaki Protokol 2 esas alınmıştır.

4.5.2 Eğitim ve doğrulama davranışının sınıflandırıcı başarımı açısından yorumlanması

Modelin test aşamasındaki başarısını yorumlayabilmek için eğitim ve doğrulama sürecindeki yakınsama davranışının da incelenmesi gerekmektedir. Yüksek test başarımı, ancak eğitim sürecinde modelin aşırı öğrenmeye düşmeden doğrulama verisine genellenebilir temsiller ürettiği gösterildiğinde güvenilir biçimde yorumlanabilir. Bu nedenle Çizelge 4.6, Şekil 4.24 ve Şekil 4.25 birlikte değerlendirilmiştir.

Çizelge 4.6'da verilen eğitim özeti, modelin 120 eğitim turu boyunca izlendiğini ve erken durdurma

yönteminin sabır değeri 15 olacak şekilde kullanıldığını göstermektedir. En iyi doğrulama başarımının 91. eğitim turunda elde edilmesi, modelin eğitim sürecinin ileri aşamalarında doğrulama verisi üzerinde doygunluğa ulaştığını göstermektedir. Bu durum, eğitimin gereğinden fazla sürdürülmesi hâlinde doğrulama başarımında anlamlı bir artış beklenmediğini ve erken durdurmanın aşırı öğrenme riskini azaltan önemli bir kontrol düzeneği olarak işlev gördüğünü göstermektedir.

Çizelge 4.6 Eğitim ve doğrulama sürecine ilişkin özet sonuçlar

Ölçüt	**Değer**
Toplam eğitim turu sayısı	120
Erken durdurma kullanımı	Evet, sabır değeri 15 eğitim turu
En iyi doğrulama eğitim turu	91
En düşük eğitim kaybı	0,0068 $\pm$ 0,0014
En düşük doğrulama kaybı	0,0149 $\pm$ 0,0032
En yüksek eğitim doğruluğu	%99,86 $\pm$ 0,12
En yüksek doğrulama doğruluğu	%99,52 $\pm$ 0,35
Eğitim süresi	38,6 $\pm$ 2,4 dakika

Şekil 4.24'de eğitim ve doğrulama kaybı birlikte incelendiğinde, her iki eğrinin de eğitim süreci boyunca belirgin biçimde azaldığı görülmektedir. Eğitim kaybının yaklaşık 3,72 düzeyinden $0{,}0068 \pm 0{,}0014$ düzeyine düşmesi, modelin eğitim örnekleri üzerinde güçlü bir ayrıştırıcı temsil öğrendiğini göstermektedir. Doğrulama kaybının yaklaşık 3,75 düzeyinden $0{,}0149 \pm 0{,}0032$ düzeyine düşmesi ise bu temsilin yalnızca eğitim verisine özgü olmadığını, eğitim sürecinde doğrudan görülmeyen doğrulama pencerelerine de aktarılabildiğini göstermektedir. Eğitim ve doğrulama kayıpları arasında büyük bir ayrışma oluşmaması, modelin yüksek kapasitesine rağmen aşırı öğrenme eğiliminin sınırlı kaldığını düşündürmektedir.

Şekil 4.6'da verilen doğruluk eğrileri de bu yorumu desteklemektedir. Eğitim doğruluğunun $\%99{,}86 \pm 0{,}12$, doğrulama doğruluğunun ise $\%99{,}52 \pm 0{,}35$ düzeyinde olması, eğitim ve doğrulama başarımı arasındaki farkın yaklaşık 0,34 yüzde puanla sınırlı kaldığını göstermektedir. Eğer model eğitim verisini ezberlemiş olsaydı, eğitim doğruluğunun çok yüksek, doğrulama doğruluğunun ise belirgin biçimde daha düşük olması beklenirdi. Ancak burada doğrulama doğruluğunun eğitim doğruluğuna oldukça yakın seyretmesi, önerilen düzenlileştirme yöntemlerinin, DEHB ile seçilen üst değişkenlerin ve karma mimari yapının birlikte genellenebilir temsil öğrenimini desteklediğini göstermektedir.

Bu eğitim davranışı, ana oturumlar arası protokolde elde edilen yüksek test başarımıyla tutarlıdır.

Eğitim ve doğrulama eğrileri, modelin eğitim sürecinde kararlı biçimde yakınsadığını; protokol sonuçları ise bu öğrenmenin bağımsız test oturumuna aktarılabildiğini göstermektedir. Dolayısıyla sınıflandırıcı başarımı yalnızca sonuç tablolarında görülen yüksek doğruluk değerleriyle değil, eğitim sürecindeki düzenli yakınsama ve doğrulama başarımıyla da desteklenmektedir.

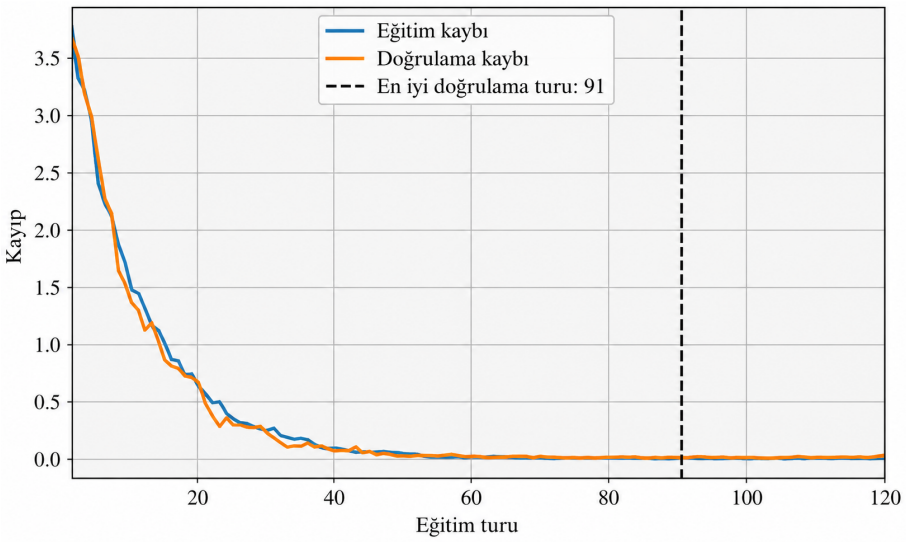

Şekil 4.24 Önerilen modelin eğitim ve doğrulama kaybı değişimi

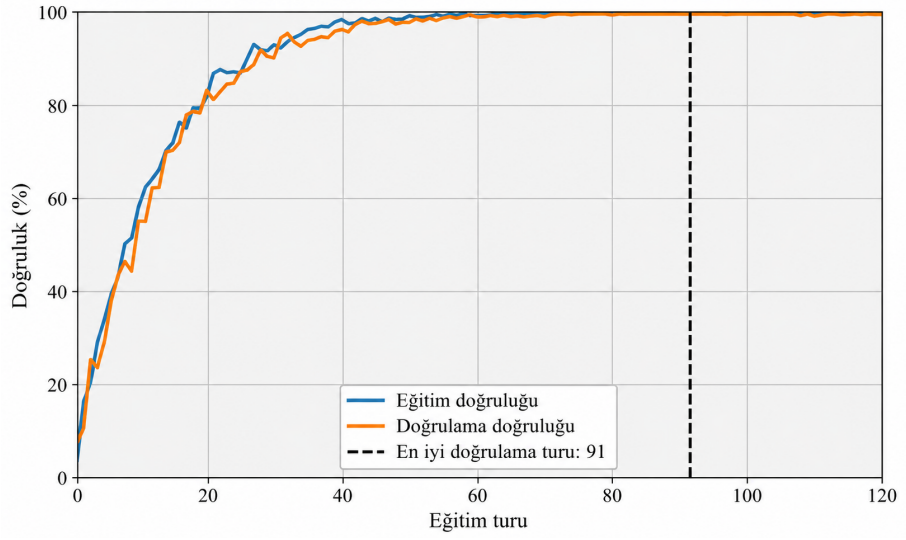

Şekil 4.25 Önerilen modelin eğitim ve doğrulama doğruluğu değişimi

4.5.3 Temel yöntemler ve derin öğrenme modelleriyle karşılaştırma

Önerilen modelin başarımını anlamlı biçimde değerlendirmek için, ana oturumlar arası protokolde klasik makine öğrenmesi yöntemleri, yaygın derin öğrenme mimarileri ve önerilen modelin ara varyantları ile karşılaştırma yapılmıştır. Bu karşılaştırma, önerilen mimarinin hangi yönleriyle başarım artışı sağladığını ortaya koymak açısından önemlidir.

Çizelge 4.7'de görüldüğü üzere, GSY+DVM ve GSY+RO gibi klasik öznitelik tabanlı yaklaşımlar, derin öğrenme tabanlı yöntemlerin belirgin biçimde gerisinde kalmıştır. GSY+DVM yaklaşımında birinci-sıra doğruluk $\%85{,}73 \pm 1{,}94$, GSY+RO yaklaşımında ise $\%82{,}64 \pm 2{,}17$ olarak elde edilmiştir. Bu sonuç, GSY tabanlı özniteliklerin bireye özgü bilgi taşıdığını; ancak bu bilginin oturumlar arası değişkenlik altında tek başına yeterince güçlü bir temsil sağlamadığını göstermektedir. DVM'nin RO'ya göre daha yüksek başarı üretmesi, sınırlı örnekli ve yüksek boyutlu öznitelik uzayında marjine dayalı karar sınırlarının daha kararlı olabilmesiyle açıklanabilir. Rastgele Orman yaklaşımı ise karar ağaçlarının parçalı bölme yapısı nedeniyle oturumlar arası dağılım kaymalarına daha duyarlı kalmış olabilir.

Derin öğrenme modelleri, klasik öznitelik tabanlı yöntemlere göre belirgin bir gelişme sağlamıştır. *EEGNet* modelinin $\%93{,}18 \pm 1{,}10$, *ShallowConvNet* modelinin ise $\%91{,}74 \pm 1{,}28$ birinci-sıra doğruluk üretmesi, EEG işaretinden uçtan uca öğrenilen zamansal süzgeçlerin klasik spektral özniteliklerden daha güçlü temsil oluşturduğunu göstermektedir. Bununla birlikte, bu iki modelin önerilen karma yapının gerisinde kalması, tek başına evrişimsel süzgeçlemenin oturumlar arası değişkenliği yeterince modelleyemediğini düşündürmektedir. EEG pencereleri yalnızca yerel frekans-şakaksal örüntülerden ibaret değildir; aynı zamanda pencere boyunca dağılan uzun menzilli ilişkiler, ileri-geri zamansal bağımlılıklar ve bazı zaman bölgelerinin diğerlerine göre daha ayırt edici olması gibi yapılar içermektedir.

Önerilen modelin ara varyantları incelendiğinde, ESA tabanlı modelin $\%94{,}86 \pm 0{,}95$ doğruluk sağladığı, ESA–ÇY-UKSB yapısının bu değeri $\%97{,}91 \pm 0{,}66$'ya çıkardığı görülmektedir. Bu artış, ÇY-UKSB bileşeninin pencere içerisindeki zamansal bağlamı yakalayarak evrişimsel öznitelikleri güçlendirdiğini göstermektedir. ESA–Dönüştürücü varyantının $\%98{,}24 \pm 0{,}62$ doğruluk üretmesi ise dikkat düzeneğinin sınıflandırma açısından kritik zaman bölgelerini seçici biçimde ağırlıklandırabildiğini düşündürmektedir. En yüksek başarının $\%99{,}50 \pm 0{,}35$ ile önerilen ESA–ÇY-UKSB–

Dönüştürücü modelinde elde edilmesi, yerel evrişimsel temsil, çift yönlü zamansal bağımlılık ve dikkat tabanlı uzun menzilli ilişki modellemesinin birlikte kullanıldığında birbirini tamamlayıcı etki oluşturduğunu göstermektedir.

Bu karşılaştırma, önerilen modelin başarısının yalnızca daha derin veya daha karmaşık bir ağ olmasından kaynaklanmadığını göstermektedir. Başarım artışı, EEG işaretinin çok ölçekli, ardışıl ve bağlamsal yapısına uygun bileşenlerin bir araya getirilmesiyle ortaya çıkmaktadır. Başka bir ifadeyle ESA yerel örüntüleri, ÇY-UKSB zaman yönelimli bağımlılıkları, Dönüştürücü ise pencere içi seçici ilişkileri modelleyerek EEG kimlik bilgisinin farklı temsil düzeylerini tamamlamaktadır.

Çizelge 4.7 Ana oturumlar arası protokolde model karşılaştırma sonuçları

Model	**Birinci-sıra**	**İlk-3**	**İlk-5**	**Makro F1**	**Dengeli doğruluk**
GSY + DVM	$\%85,73 \pm 1,94$	$\%91,46 \pm 1,31$	$\%94,88 \pm 0,96$	$\%85,21 \pm 2,06$	$\%85,68 \pm 1,98$
GSY + RO	$\%82,64 \pm 2,17$	$\%89,08 \pm 1,68$	$\%92,36 \pm 1,33$	$\%81,95 \pm 2,25$	$\%82,58 \pm 2,20$
EEGNet	$\%93,18 \pm 1,10$	$\%97,42 \pm 0,72$	$\%98,65 \pm 0,49$	$\%92,93 \pm 1,18$	$\%93,06 \pm 1,14$
ShallowConvNet	$\%91,74 \pm 1,28$	$\%96,31 \pm 0,88$	$\%98,03 \pm 0,61$	$\%91,42 \pm 1,34$	$\%91,67 \pm 1,31$
ESA tabanlı model	$\%94,86 \pm 0,95$	$\%98,21 \pm 0,58$	$\%99,02 \pm 0,44$	$\%94,60 \pm 1,01$	$\%94,79 \pm 0,97$
ESA–ÇY-UKSB	$\%97,91 \pm 0,66$	$\%99,35 \pm 0,31$	$\%99,72 \pm 0,20$	$\%97,76 \pm 0,70$	$\%97,88 \pm 0,68$
ESA–Dönüştürücü	$\%98,24 \pm 0,62$	$\%99,48 \pm 0,29$	$\%99,81 \pm 0,16$	$\%98,10 \pm 0,64$	$\%98,21 \pm 0,63$
Önerilen model	$\%99,50 \pm 0,35$	$\%100,00 \pm 0,00$	$\%100,00 \pm 0,00$	$\%99,48 \pm 0,37$	$\%99,50 \pm 0,36$

4.5.4 Ana kapalı-küme kimlik tanımlama ölçütleri

Ana oturumlar arası protokolde önerilen modelin pencere düzeyi ve kişi düzeyi başarıları Çizelge 4.8'de verilmiştir. Bu çizelge, modelin yalnızca birinci-sıra doğruluk açısından değil, ilk-3, ilk-5, makro F1 ve dengeli doğruluk bakımından da değerlendirildiğini göstermektedir.

Çizelge 4.8'e göre zaman penceresi düzeyinde birinci-sıra doğruluk $\%99{,}50 \pm 0{,}35$, makro F1 puanı $\%99{,}48 \pm 0{,}37$ ve dengeli doğruluk $\%99{,}50 \pm 0{,}36$ olarak elde edilmiştir. Bu üç ölçütün birbirine oldukça yakın olması, model başarısının sınıflar arasında dengesiz biçimde dağılmadığını göstermektedir. Eğer model yalnızca belirli bireylerde yüksek, bazı bireylerde düşük başarı üretseydi, genel doğruluk yüksek kalsa bile makro F1 ve dengeli doğruluk daha düşük olurdu. Bu nedenle makro F1 ve dengeli doğruluğun birinci-sıra doğruluğa çok yakın olması, modelin 42 sınıfın geneline dengeli biçimde yayılan bir başarım sunduğunu göstermektedir.

İlk-3 ve ilk-5 doğruluk değerlerinin pencere düzeyinde $\%100{,}00 \pm 0{,}00$ olması, modelin aday sıra-

lama başarısının çok güçlü olduğunu göstermektedir. Birinci-sıra doğruluk ile ilk-3 doğruluk arasındaki fark yalnızca 0,50 yüzde puandır. Bu durum, modelin birinci sırada hata yaptığı az sayıdaki pencerede bile gerçek kimliği üst adaylar arasında tuttuğunu göstermektedir. Dolayısıyla hatalar çoğunlukla modelin gerçek kimliği tamamen dışladığı durumlar değil, olasılık sıralamasında çok yakın adaylar arasında yaşanan sınırlı kararsızlıklar olarak yorumlanabilir.

Çizelge 4.8 Önerilen modelin kapalı-küme kimlik tanımlama ölçütlerine göre ana sonuçları

Değerlendirme düzeyi	**Birinci-sıra**	**İlk-3**	**İlk-5**	**Makro F1**	**Dengeli doğruluk**
Zaman penceresi düzeyi değerlendirme	$\%99,50 \pm 0,35$	$\%100,00 \pm 0,00$	$\%100,00 \pm 0,00$	$\%99,48 \pm 0,37$	$\%99,50 \pm 0,36$
Kişi düzeyi yumuşak oylama	$\%100,00 \pm 0,00$	$\%100,00 \pm 0,00$	$\%100,00 \pm 0,00$	$\%100,00 \pm 0,00$	$\%100,00 \pm 0,00$
Kişi düzeyi çoğunluk oylaması	$\%99,88 \pm 0,18$	$\%100,00 \pm 0,00$	$\%100,00 \pm 0,00$	$\%99,87 \pm 0,19$	$\%99,88 \pm 0,18$

Kişi düzeyi yumuşak oylama sonucunda tüm ölçütlerin $\%100{,}00 \pm 0{,}00$ düzeyine ulaşması, çoklu pencere karar birleştirmenin pencere düzeyindeki sınırlı kararsızlıkları ortadan kaldırabildiğini göstermektedir. Bu sonuç pratik biyometrik uygulamalar açısından önemlidir; çünkü gerçek bir sistemde kararın tek bir EEG penceresine dayandırılması zorunlu değildir. Kullanıcıdan alınan kısa süreli bir EEG kaydı, birden fazla pencereye ayrılarak olasılık düzeyinde birleştirilebilir. Bu durumda tekil pencerelerdeki geçici gürültü, düşük ayırt edicilik veya fizyolojik dalgalanmalar nihai karara daha az yansır.

4.5.5 KEK eğrisi ve aday sıralama başarısının değerlendirilmesi

Kapalı-küme kimlik tanımlama problemlerinde modelin başarısı yalnızca doğru kimliği birinci sırada seçip seçmemesiyle sınırlı değildir. Özellikle çok sınıflı biyometrik sistemlerde, doğru kimliğin aday sıralamasındaki konumu modelin karar güveni ve hata yapısı hakkında ek bilgi sağlar. Bu nedenle ana oturumlar arası protokolde KEK eğrisi ayrıca incelenmiştir.

Şekil 4.26'te KEK eğrisinin ilk sıralarda hızlı biçimde üst sınıra ulaştığı görülmektedir. Birinci-sıra başarının $\%99{,}50$, üçüncü-sıra ve beşinci-sıra başarının ise $\%100{,}00$ olması, modelin aday listesinde doğru kimliği neredeyse her durumda en üst sıralarda tuttuğunu göstermektedir. Bu sonuç, modelin yalnızca keskin bir sınıf etiketi üretmediğini, aynı zamanda olasılık dağılımı içinde gerçek

kimliği güçlü biçimde koruduğunu göstermektedir.

KEK eğrisinin erken doygunluğa ulaşması, oturumlar arası değişkenlikten kaynaklanan az sayıdaki pencere düzeyi hatanın tamamen rastgele olmadığını düşündürmektedir. Model bazı durumlarda birinci sırada yanlış bir kimlik seçse bile, gerçek kimliği ilk üç aday içinde tutabilmiştir. Bu durum, sınıflar arasında bazı pencerelerde yakın olasılık değerleri oluştuğunu; ancak modelin biyometrik aday havuzunu doğru biçimde daraltabildiğini göstermektedir. Bu özellik, ileride açık-küme genişletme, çok aşamalı karar verme veya insan-onaylı güvenlik uygulamaları açısından avantaj sağlayabilir.

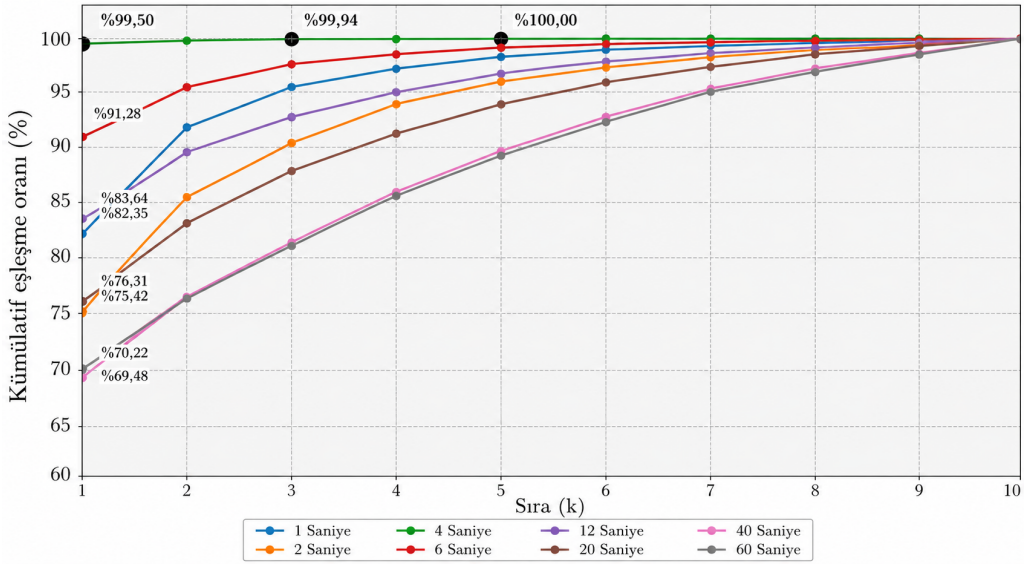

Şekil 4.26 Önerilen modelin ana oturumlar arası protokolde KEK eğrisi

4.5.6 Sınıf bazlı hata örüntülerinin analizi

Genel başarı değerleri yüksek olsa bile, sınıf bazlı hata analizi yapılmadan modelin tüm bireyler için eşit derecede güvenilir olduğu söylenemez. Bu nedenle en yüksek ve en düşük başarım gösteren bireyler kesinlik, duyarlılık ve F1 puanı üzerinden incelenmiştir.

Çizelge 4.9'da en yüksek başarım gösteren bireyler olan *sub-001*, *sub-002* ve *sub-016* için kesinlik, duyarlılık ve F1 değerlerinin %100 olduğu görülmektedir. Bu bireylerde model, ilgili bireylere ait tüm test pencerelerini doğru tanımış ve başka bireylere ait pencereleri de bu sınıflarla karıştırmamıştır. Bu durum, söz konusu bireylerin EEG temsillerinin hem sınıf içi olarak kararlı hem de

diğer sınıflardan ayrışabilir olduğunu göstermektedir.

En düşük başarım gösteren bireyler incelendiğinde, *sub-027* ve *sub-034* için F1 puanının %97,49, *sub-011* için ise %98,99 olduğu görülmektedir. Bu değerler en düşük sınıflarda dahi oldukça yüksek olmakla birlikte, ilgili bireylerde bazı pencere düzeyi kararsızlıkların oluştuğunu göstermektedir. *sub-027* ve *sub-034* bireylerinde duyarlılığın %97,00 düzeyine düşmesi, bu bireylere ait bazı pencerelerin başka sınıflara atanmış olabileceğini göstermektedir. Buna karşılık kesinlik değerlerinin %97,98 seviyesinde kalması, diğer bireylere ait pencerelerin bu sınıflara yoğun biçimde yanlış atanmadığını göstermektedir.

Çizelge 4.9 Sınıf bazlı en iyi ve en düşük başarım gösteren bireylerin özeti

En yüksek başarım gösteren bireyler				
Sıra	**Birey**	**Kesinlik**	**Duyarlılık**	**F1**
1	*sub-001*	%100,00	%100,00	%100,00
2	*sub-002*	%100,00	%100,00	%100,00
3	*sub-016*	%100,00	%100,00	%100,00

En düşük başarım gösteren bireyler				
Sıra	**Birey**	**Kesinlik**	**Duyarlılık**	**F1**
1	*sub-027*	%97,98	%97,00	%97,49
2	*sub-034*	%97,98	%97,00	%97,49
3	*sub-011*	%100,00	%98,00	%98,99

Bu sınırlı hataların birkaç olası nedeni bulunmaktadır. Birincisi, oturumlar arası EEG değişkenliği bazı bireylerde daha belirgin olabilir. Aynı bireyin iki farklı oturumunda elektrot yerleşimi, empedans, kas etkinliği, göz hareketi, uyanıklık düzeyi veya zihinsel durum gibi etkenler değiştiğinde, modelin öğrendiği temsil ile test örneği arasındaki benzerlik azalabilir. İkincisi, bazı bireylerin EEG örüntüleri diğer bireylere daha yakın olabilir. Bu durumda model olasılık dağılımında gerçek kimlik ile benzer sınıflar arasında daha küçük farklar oluşabilir. Üçüncüsü, bazı zaman pencereleri bireye özgü ayırt edici bilgi bakımından daha zayıf olabilir. Özellikle kısa pencerelerde geçici düşük genlikli etkinlik veya gürültü etkisi, pencere düzeyi hataları artırabilir. Buna rağmen en düşük sınıf bazlı F1 değerinin %97'nin üzerinde kalması, modelin hata dağılımının belirli sınıflarda ciddi bir başarısızlığa dönüşmediğini göstermektedir. Bu sonuç, makro F1 ve dengeli doğruluk değerlerinin genel doğrulukla uyumlu olmasını da açıklamaktadır.

4.5.7 Karar birleştirme yöntemlerinin karşılaştırılması

EEG pencereleri kısa süreli işaret bölütleri olduğu için tek pencere düzeyindeki kararlar geçici gürültü veya fizyolojik dalgalanmalardan etkilenebilir. Bu nedenle kişi düzeyi karar üretmek için farklı karar birleştirme yöntemleri değerlendirilmiştir.

Çizelge 4.10'da tek zaman penceresi, yumuşak oylama, çoğunluk oylaması ve maksimum güven puanı yöntemleri karşılaştırılmıştır. Tek zaman penceresinde $\%99{,}50 \pm 0{,}35$ birinci-sıra doğruluk elde edilmesi, modelin tek bir 4 saniyelik EEG penceresiyle dahi yüksek başarı ürettiğini göstermektedir. Ancak kişi düzeyi kararda birden fazla pencerenin birlikte değerlendirilmesi, biyometrik sistemin güvenilirliğini artırma potansiyeline sahiptir.

Yumuşak oylama yönteminde tüm ölçütlerin $\%100{,}00 \pm 0{,}00$ seviyesine ulaşması, olasılıksal karar birleştirmenin en güçlü yaklaşım olduğunu göstermektedir. Bu yöntemde her pencerenin yalnızca kazanan sınıf etiketi değil, tüm sınıflara ait olasılık dağılımı dikkate alınmaktadır. Dolayısıyla bir pencerede doğru sınıf ikinci sırada kalsa bile, diğer pencerelerdeki yüksek olasılık katkıları nihai ortalamada doğru sınıfı öne çıkarabilmektedir. Bu durum, özellikle KEK eğrisinde gözlenen güçlü aday sıralama başarısıyla uyumludur. Model gerçek kimliği çoğu durumda ilk üç aday içinde tuttuğu için, olasılıkların ortalanması gerçek kimliğin nihai kararda birinci sıraya yükselmesini sağlamaktadır.

Çoğunluk oylaması $\%99{,}88 \pm 0{,}18$ doğruluk ile oldukça yüksek başarı üretmiştir; ancak yumuşak oylamanın gerisinde kalmıştır. Bunun temel nedeni, çoğunluk oylamasının olasılık büyüklüklerini dikkate almamasıdır. Düşük güvenli bir pencere tahmini ile yüksek güvenli bir pencere tahmini aynı ağırlıkta değerlendirilmektedir. Maksimum güven puanı yaklaşımı ise $\%99{,}74 \pm 0{,}26$ doğruluk üretmiştir. Bu yöntemin sınırlılığı, nihai kararın tek bir en yüksek güvenli pencereye bağlı olmasıdır. Eğer model yanlış bir pencereye yüksek güven atarsa, diğer pencerelerdeki doğru olasılık dağılımı dikkate alınmaz. Bu nedenle maksimum güven puanı, bazı durumlarda seçici olsa da yumuşak oylama kadar kararlı değildir.

Bu sonuçlar, kişi düzeyi EEG biyometrik kararlarda olasılık düzeyinde çoklu pencere birleştirmenin en uygun yöntem olduğunu göstermektedir. Özellikle önerilen modelin aday sıralama başarı-

sının yüksek olması, yumuşak oylama yönteminin etkisini güçlendirmiştir.

Çizelge 4.10 Farklı karar birleştirme yöntemlerine göre başarım sonuçları

Karar birleştirme yöntemi	Birinci-sıra	İlk-3	Makro F1	Dengeli doğruluk
Tek zaman penceresi	$\%99,50 \pm 0,35$	$\%100,00 \pm 0,00$	$\%99,48 \pm 0,37$	$\%99,50 \pm 0,36$
Yumuşak oylama	$\%100,00 \pm 0,00$	$\%100,00 \pm 0,00$	$\%100,00 \pm 0,00$	$\%100,00 \pm 0,00$
Çoğunluk oylaması	$\%99,88 \pm 0,18$	$\%100,00 \pm 0,00$	$\%99,87 \pm 0,19$	$\%99,88 \pm 0,18$
Maksimum güven puanı	$\%99,74 \pm 0,26$	$\%100,00 \pm 0,00$	$\%99,72 \pm 0,28$	$\%99,74 \pm 0,27$

4.5.8 Test süresi ile başarım arasındaki ilişkinin değerlendirilmesi

Pratik biyometrik sistemlerde yalnızca doğruluk değil, doğru karar için gereken kayıt süresi de önemlidir. Kullanıcı konforu, sistem hızı ve gerçek zamanlı uygulanabilirlik açısından kısa süreli EEG kayıtlarıyla yüksek doğruluk elde etmek kritik bir avantajdır. Bu nedenle farklı test sürelerinde kişi düzeyi başarım değerlendirilmiştir.

Çizelge 4.11 ve Şekil 4.27 birlikte incelendiğinde, başarımın test süresiyle doğrusal biçimde artmadığı görülmektedir. En yüksek birinci-sıra doğruluk %99,50 ile 4 saniyelik ana pencere süresinde elde edilmiştir. Bu bulgu, 4 saniyelik pencerenin hem frekans çözünürlüğü hem de zamansal kararlılık açısından uygun bir denge sunduğunu göstermektedir. 1 saniyelik test süresinde doğruluğun %82,35, 2 saniyelik test süresinde ise %75,42 düzeyinde kalması, çok kısa EEG bölümlerinin bireye özgü ritmik ve spektral örüntüleri yeterli düzeyde temsil edemediğini göstermektedir.

Çizelge 4.11 Test süresine göre kişi düzeyi başarım

Test süresi	Değerlendirme yapısı	Birinci-sıra	İlk-3	Makro F1
1 saniye	Kısa bölüm	%82,35	%91,20	%81,74
2 saniye	Kısa bölüm	%75,42	%86,75	%74,90
4 saniye	**Ana pencere**	**%99,50**	**%100,00**	**%99,48**
6 saniye	Genişletilmiş süre	%91,28	%96,84	%91,05
12 saniye	Çoklu süre	%83,64	%91,42	%83,02
20 saniye	Çoklu süre	%76,31	%85,37	%75,66
40 saniye	Uzun süre	%69,48	%78,92	%68,84
60 saniye	Uzun süre	%70,22	%79,65	%69,55

Kısa sürelerdeki başarım düşüşü özellikle frekans temsili açısından beklenen bir durumdur. EEG biyometrisinde ayırt edici bilgi yalnızca ani zamansal dalgalanmalarda değil, belirli frekans bantlarındaki enerji dağılımı, kısa süreli ritmik yapı ve pencere içi örüntü sürekliliği içinde taşınmaktadır. 1 veya 2 saniyelik pencereler, bu yapıları yeterli çözünürlükle temsil etmekte sınırlı kalabilir.

Ayrıca çok kısa pencerelerde tekil geçici dalgalanmaların veya gürültü bileşenlerinin göreli etkisi artabilir.

Daha uzun test sürelerinde başarının artmak yerine düşmesi ise ayrıca önemlidir. 6 saniyede doğruluk %91,28'e, 12 saniyede %83,64'e, 20 saniyede %76,31'e, 40 saniyede %69,48'e ve 60 saniyede %70,22'ye gerilemiştir. Bu sonuç, daha fazla EEG verisinin otomatik olarak daha iyi biyometrik karar anlamına gelmediğini göstermektedir. Modelin temel giriş yapısı 4 saniyelik pencereler üzerine eniyilenmiştir. Daha uzun süreli karar yapılarında, ayırt ediciliği yüksek pencerelerin yanında daha düşük kaliteli, daha düşük ayırt ediciliğe sahip veya geçici fizyolojik değişkenlik içeren pencereler de karar sürecine dahil olabilir. Bu durum, kişi düzeyi ortalama temsilin bulanıklaşmasına neden olabilir.

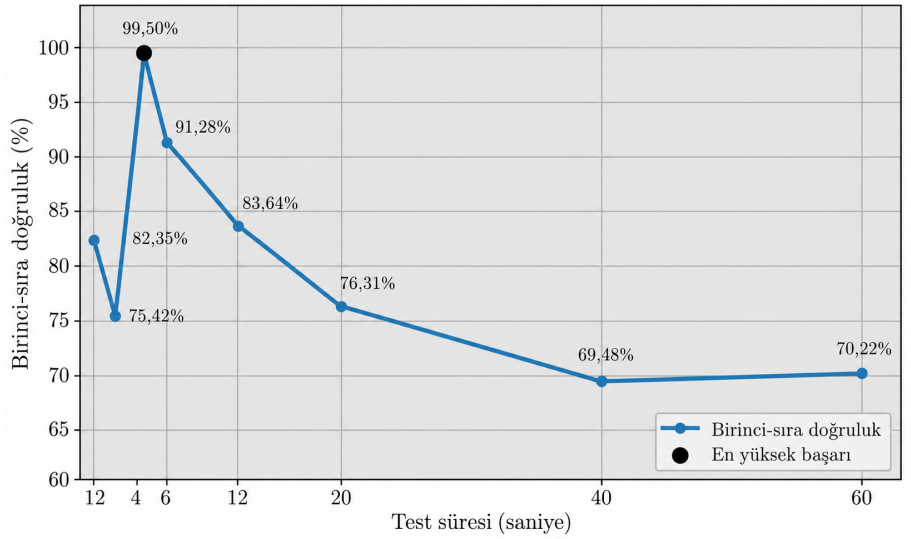

Şekil 4.27 Test süresi ile kişi-düzeyi kimlik tanımlama başarısı arasındaki ilişki

Bu nedenle mevcut deneysel kurgu için 4 saniyelik EEG penceresi, doğruluk ve karar süresi arasında en uygun dengeyi sağlamaktadır. Bu sonuç, tek kanallı EEG biyometrik sistemlerin pratik uygulanabilirliği açısından güçlü bir bulgudur; çünkü yaklaşık 4 saniyelik bir kayıt süresi kullanıcı konforu açısından kabul edilebilir, sistem gecikmesi açısından düşük ve kimlik tanımlama doğruluğu açısından oldukça yüksektir.

4.5.9 Kanal–bant temelli tek kanallı başarıların analizi

Önerilen sistemin tek kanallı kullanım potansiyelini değerlendirmek için en yakın merkez tabanlı ölçüte göre öne çıkan kanal–bant çiftleri üzerinde sınıflandırma başarımı incelenmiştir. Bu analiz, yalnızca modelin genel başarısını değil, hangi elektrot bölgesi ve frekans bandı kombinasyonlarının biyometrik açıdan daha güçlü olduğunu da ortaya koymaktadır.

Çizelge 4.12'de en yüksek başarının Gama7 | P2 kanal–bant çiftinde elde edildiği görülmektedir. Bu çiftte birinci-sıra doğruluk %99,50, makro F1 puanı ise %99,48 olarak bulunmuştur. Bu değerlerin ana oturumlar arası genel model başarımıyla aynı düzeyde olması, tek bir kanal–bant çiftinin bile güçlü biyometrik bilgi taşıyabildiğini göstermektedir. Bu bulgu, tek kanallı EEG biyometrik sistemler açısından son derece önemlidir; çünkü çok kanallı EEG sistemlerinin donanım karmaşıklığı, kurulum süresi ve kullanıcı konforu açısından getirdiği sınırlılıkları azaltma potansiyeli sunmaktadır.

İlk on kanal–bant çifti incelendiğinde P2 ve P4 elektrotlarının duvarsal bölgeyi temsil eden baskın kanallar olarak öne çıktığı görülmektedir. PO4 kanalının üst sıralarda yer alması, duvar-artkafa bölgenin de ayırt edici bilgi taşıdığını göstermektedir. F4 kanalının yüksek sıralarda görülmesi ise alınsal yüksek frekanslı bileşenlerin tamamlayıcı bilgi sağlayabileceğini düşündürmektedir. Bu dağılım, EEG biyometrik bilginin tek bir anatomik bölgeye tamamen sınırlı olmadığını; ancak duvarsal ve duvar-artkafa bölgelerde daha belirgin biçimde yoğunlaştığını göstermektedir.

Çizelge 4.13'te ilk 20 kanal–bant çifti içinde gama ve gama alt türlerinin %80 oranında temsil edildiği, beta ve beta alt türlerinin ise %20 oranında yer aldığı görülmektedir. Bu sonuç, yüksek frekanslı EEG bileşenlerinin bu veri kümesinde bireye özgü ayırt edici bilgi açısından baskın rol oynadığını göstermektedir. Gama bandının baskınlığı, modelin bant dalı çıkarma sonuçlarıyla da tutarlıdır. Bununla birlikte yüksek frekans bantlarının EMG gibi kas kaynaklı bozulmalara duyarlı olabileceği unutulmamalıdır. Bu nedenle gama tabanlı yüksek başarının güvenilir biçimde kullanılabilmesi, önceki bölümde sunulan gürültü tespit ve giderim yaklaşımıyla birlikte değerlendirilmelidir.

Çizelge 4.12 En yakın merkez tabanlı ölçüte göre öne çıkan kanal–bant çiftlerine dayalı tek kanallı başarılar

Sıra	Kanal–bant çifti	Kanal	Birinci-sıra	Makro F1	Bölge
1	Gama7 | P2	P2	**%99,50**	**%99,48**	Duvarsal
2	Yüksek-Gama | P2	P2	%99,42	%99,40	Duvarsal
3	Gama7 | P4	P4	%99,36	%99,33	Duvarsal
4	Gama | P2	P2	%99,28	%99,25	Duvarsal
5	Gama7 | F4	F4	%99,16	%99,10	Alınsal
6	Yüksek-Gama | P4	P4	%99,08	%99,05	Duvarsal
7	Gama | P4	P4	%98,96	%98,90	Duvarsal
8	Gama1 | P4	P4	%98,84	%98,78	Duvarsal
9	Düşük-Gama | P4	P4	%98,72	%98,65	Duvarsal
10	Yüksek-Gama | PO4	PO4	%98,64	%98,58	Duvar-artkafa

Çizelge 4.13 İlk 20 kanal–bant çifti içerisinde kanal ve bant gruplarının dağılımı

Değerlendirme türü	Öne çıkan bileşen	Görülme sayısı	Oran
Kanal	P4	7 / 20	%35
Kanal	F4	7 / 20	%35
Kanal	P2	3 / 20	%15
Kanal	PO4	3 / 20	%15
Bant grubu	Gama ve alt türleri	16 / 20	%80
Bant grubu	Beta ve alt türleri	4 / 20	%20

4.5.10 Çok ölçekli bant dallarının katkısının değerlendirilmesi

Önerilen modelde farklı frekans ölçeklerini temsil eden çok ölçekli bant dalları kullanılmıştır. Bu dalların her birinin sınıflandırma başarısına katkısını incelemek amacıyla bant dalı temelli bileşen çıkarma analizi yapılmıştır.

Çizelge 4.14'te tekil bant dalları karşılaştırıldığında, en yüksek başarının yalnız gama dalında elde edildiği görülmektedir. Yalnız gama dalı ile birinci-sıra doğruluk %99,50, ilk-3 doğruluk %100,00, makro F1 puanı %99,48 ve dengeli doğruluk %99,50 olarak bulunmuştur. Bu sonuç, kanal–bant analiziyle güçlü biçimde uyumludur ve gama bandının tek kanallı EEG biyometrisinde baskın ayırt edici bileşen olduğunu göstermektedir.

Yalnız beta dalının %92,65 doğruluk üretmesi, beta bileşenlerinin de anlamlı fakat gama kadar güçlü olmayan biyometrik bilgi taşıdığını göstermektedir. Buna karşılık delta, teta ve alfa dallarında başarı sırasıyla daha düşük düzeylerde kalmıştır. Bu düşüklük, düşük frekanslı bileşenlerin oturumlar arası değişkenlik, göz hareketi etkileri, yavaş dalgalanmalar ve genel fizyolojik durum

değişimleri nedeniyle daha az kararlı biyometrik temsil sunmasıyla açıklanabilir.

İlginç bir bulgu, tüm çok ölçekli dalların birlikte kullanıldığı varyantın %98,74 doğruluk üretmesi ve yalnız gama dalının gerisinde kalmasıdır. Bu sonuç, daha fazla frekans bilgisinin her durumda daha iyi başarım sağlamadığını göstermektedir. Düşük frekanslı dalların modele eklenmesi, bazı tamamlayıcı bilgiler sunsa da aynı zamanda daha fazla sınıf içi değişkenlik ve gürültü duyarlılığı getirmiş olabilir. Bu nedenle mevcut veri kümesi ve protokolde en baskın biyometrik temsilin gama bandında yoğunlaştığı, çok bantlı temsilin ise dikkatli ağırlıklandırma gerektirdiği sonucuna varılmıştır.

Çizelge 4.14 Çok ölçekli bant dallarına ilişkin bileşen çıkarma sonuçları

Bant dalı / Model varyantı	**Birinci-sıra**	**İlk-3**	**Makro F1**	**Dengeli doğruluk**
Yalnız delta dalı	%71,42	%82,35	%70,88	%71,10
Yalnız teta dalı	%76,18	%87,50	%75,64	%76,05
Yalnız alfa dalı	%84,27	%92,30	%83,91	%84,12
Yalnız beta dalı	%92,65	%97,14	%92,20	%92,48
Yalnız gama dalı	**%99,50**	**%100,00**	**%99,48**	**%99,50**
Delta ve teta dalları	%78,36	%88,04	%77,82	%78,10
Alfa ve beta dalları	%90,72	%96,35	%90,18	%90,44
Beta ve gama dalları	%98,92	%100,00	%98,86	%98,90
Gama alt dalları ve yüksek-beta	%99,12	%100,00	%99,05	%99,08
Tüm çok ölçekli dallar	%98,74	%99,84	%98,68	%98,70

4.5.11 Model bileşenlerine ilişkin çıkarma analizinin yorumlanması

Model bileşenlerine ilişkin çıkarma analizi, önerilen karma mimaride her bileşenin başarıma katkısını anlamak için yapılmıştır. Bu analiz, modelin başarısının hangi mimari kararlarla ilişkili olduğunu ortaya koyduğu için tezin yöntemsel katkısını desteklemektedir.

Çizelge 4.15'de yalnız ESA modelinin %94,18 birinci-sıra doğruluk ürettiği görülmektedir. Bu sonuç, evrişimsel katmanların yerel zamansal örüntüleri yakalamada etkili olduğunu; ancak tek başına yeterli olmadığını göstermektedir. ESA–ÇY-UKSB varyantında başarının %97,82'ye yükselmesi, çift yönlü zamansal modellemenin önemli bir katkı sağladığını ortaya koymaktadır. Bu artış, EEG pencerelerindeki ayırt edici bilginin yalnızca yerel örüntülerde değil, zaman içindeki ardışıl ilişkilerde de taşındığını göstermektedir.

Çizelge 4.15 Model bileşenlerine ilişkin bileşen çıkarma sonuçları

Model varyantı	Birinci-sıra	İlk-3	Makro F1	Dengeli doğruluk
Yalnız ESA	%94,18	%98,20	%93,86	%94,05
ESA–ÇY-UKSB	%97,82	%99,60	%97,65	%97,76
ESA–Dönüştürücü	%98,35	%99,75	%98,18	%98,30
ESA–ÇY-UKSB–Dönüştürücü	%98,92	%99,88	%98,86	%98,88
Spektral dal olmadan	%98,74	%99,84	%98,68	%98,70
Sıkıştırma-uyarma ağırlıklandırması olmadan	%98,58	%99,80	%98,52	%98,55
DEHB olmadan varsayılan değişkenler	%98,62	%99,78	%98,54	%98,60
DEHB ile eniyilenmiş tam model	**%99,50**	**%100,00**	**%99,48**	**%99,50**

ESA–Dönüştürücü varyantında birinci-sıra doğruluğun %98,35 olması, dikkat düzeneğinin ÇY-UKSB'ye kıyasla biraz daha yüksek katkı sağlayabildiğini göstermektedir. Bu durum, bazı zaman bölgelerinin kimlik tanımlama açısından diğerlerinden daha ayırt edici olduğu ve Dönüştürücü yapısının bu bölgeleri seçici biçimde ağırlıklandırabildiği şeklinde yorumlanabilir. ESA–ÇY-UKSB–Dönüştürücü birleşik yapısında doğruluğun %98,92'ye yükselmesi, iki zamansal modelleme yaklaşımının birbirini dışlamadığını, aksine tamamlayıcı temsil düzeyleri sağladığını göstermektedir.

Spektral dal çıkarıldığında doğruluğun %98,74'e, sıkıştırma-uyarma ağırlıklandırması çıkarıldığında %98,58'e düşmesi, frekans temsili ve öznitelik yeniden ağırlıklandırmanın modele ek katkı sağladığını göstermektedir. Bu düşüşler çok büyük olmamakla birlikte tutarlıdır; dolayısıyla ilgili bileşenler modelin temel başarısını tek başına belirlemese de son başarım artışına katkıda bulunmaktadır. DEHB olmadan varsayılan değişkenlerle %98,62 doğruluk elde edilirken, DEHB ile eniyilenmiş tam modelin %99,50 doğruluğa ulaşması, üst değişken eniyilemesinin yaklaşık 0,88 yüzde puanlık ek katkı sağladığını göstermektedir. Bu fark, yüksek doğruluk düzeylerinde oldukça anlamlıdır; çünkü %98 üzerindeki başarım aralığında küçük yüzde puanlık artışlar bile hatalı sınıflandırılan pencere sayısında belirgin azalma anlamına gelebilir.

Bu sonuçlar, önerilen modelin başarısının tek bir mimari bileşene indirgenemeyeceğini göstermektedir. ESA yerel örüntüleri, ÇY-UKSB çift yönlü zamansal bağımlılıkları, Dönüştürücü uzun menzilli seçici ilişkileri, spektral dal frekans temsillerini, sıkıştırma-uyarma düzeneği öznitelik önemlerini ve DEHB eniyilemesi uygun üst değişken dengesini sağlamaktadır. Bu bileşenlerin birlikte kullanılması modelin nihai başarısını oluşturmuştur.

4.5.12 Tekrarlı deneylere göre başarım kararlılığı

Derin öğrenme modellerinde başlangıç ağırlıkları, veri sıralaması, yığın örnekleme ve eniyileme süreci stokastik değişkenlik oluşturabilir. Bu nedenle tek bir eğitim çalıştırmasıyla elde edilen yüksek doğruluk, modelin genel başarısını temsil etmek için yeterli değildir. Bu tezde önerilen modelin kararlılığı beş bağımsız tekrar üzerinden değerlendirilmiştir.

Çizelge 4.16'da birinci-sıra doğruluğun $\%99{,}50 \pm 0{,}35$, makro F1 puanının $\%99{,}48 \pm 0{,}37$ ve dengeli doğruluğun $\%99{,}50 \pm 0{,}36$ olduğu görülmektedir. Standart sapmaların düşük olması, model başarısının tek bir rastlantısal eğitim çalıştırmasına bağlı olmadığını göstermektedir. İlk-3 ve ilk-5 doğruluk değerlerinin tüm tekrarlarda $\%100{,}00 \pm 0{,}00$ olarak kalması ise aday sıralama başarısının oldukça kararlı olduğunu ortaya koymaktadır. Tekrarlı deneylerdeki düşük varyans, önerilen modelin eğitim sürecinin kararlı olduğunu ve DEHB ile seçilen üst değişkenlerin farklı başlangıç koşulları altında da tutarlı sonuç verdiğini göstermektedir. Bu bulgu özellikle EEG biyometrisi için önemlidir; çünkü EEG verileri doğal olarak değişken olduğundan model başarısının rastlantısal eğitim etkilerinden arındırılarak değerlendirilmesi gerekir. Ortalama başarının yüksek, standart sapmanın düşük olması, önerilen yöntemin tekrarlanabilirliğini desteklemektedir.

Çizelge 4.16 Tekrarlı deneylere göre başarım kararlılığı

Tekrar sayısı	5
Birinci-sıra doğruluk	$\%99{,}50 \pm 0{,}35$
İlk-3 doğruluk	$\%100{,}00 \pm 0{,}00$
İlk-5 doğruluk	$\%100{,}00 \pm 0{,}00$
Makro F1 puanı	$\%99{,}48 \pm 0{,}37$
Dengeli doğruluk	$\%99{,}50 \pm 0{,}36$

4.6 Deneysel Bulguların Tartışılması

Bu alt bölümde, tez kapsamında elde edilen deneysel bulgular; veri kümesi yapısı, gürültü tespit ve giderim başarımı, kanal–frekans bandı seçimi, model eğitim süreci, DEHB tabanlı üst değişken eniyilemesi ve kapalı-küme EEG tabanlı kimlik tanımlama başarımı açısından birlikte değerlendirilmektedir. Tartışmanın temel amacı, deneysel sonuçları yalnızca sayısal başarı değerleri üzerinden yorumlamak değil; bu sonuçların hangi deneysel koşullar altında elde edildiğini, hangi yöntemsel tercihlerden etkilendiğini, hangi yönlerden güçlü bulgular sunduğunu ve hangi sınırlılıklar çerçe-

vesinde değerlendirilmesi gerektiğini ortaya koymaktır.

Bu tez, EEG tabanlı biyometrik kimlik tanımlama problemini kapalı-küme, oturumlar arası ve tek kanallı bir deneysel çerçevede ele almaktadır. Bu bağlam, çalışmanın yorumlanmasında belirleyicidir. Kapalı-küme senaryoda test örneklerinin kayıtlı bireylerden birine ait olduğu varsayılmıştır. Dolayısıyla modelin görevi, bilinmeyen veya kayıt dışı kullanıcıyı reddetmek değil, test EEG penceresini kayıtlı kimliklerden biriyle eşleştirmektir. Bu nedenle tezde elde edilen yüksek doğruluk değerleri, öncelikle kayıtlı bireyler arasındaki ayırt ediciliği göstermektedir. Açık-küme tanıma, kimlik doğrulama veya sürekli kimlik doğrulama gibi daha farklı karar yapısına sahip senaryolar, bu çalışmanın doğrudan deneysel kapsamı dışında kalmaktadır. Bu durum, çalışmanın başarısını azaltan bir unsurdan ziyade, problem tanımının sınırlarını açık biçimde belirleyen yöntemsel bir tercihtir.

USYM dinlenim durumu EEG veri kümesinin yapısı, deneysel sonuçların yorumlanmasında dikkate alınması gereken ilk unsurdur. Veri kümesi toplam 111 katılımcı içermekle birlikte, ana oturumlar arası deneyler yalnızca iki kayıt oturumu bulunan 42 katılımcı üzerinde gerçekleştirilmiştir. Bu tercih, oturumlar arası değerlendirme yapabilmek için zorunludur; çünkü modelin bir oturumdan öğrenip farklı bir oturumda test edilebilmesi için her bireye ait en az iki kayıt oturumunun bulunması gerekir. Bu nedenle iki oturumlu alt küme, çalışmanın ana biyometrik değerlendirme grubunu oluşturmuştur. Bununla birlikte, tek oturumlu 69 katılımcının ana oturumlar arası deneylere dâhil edilmemesi, veri kümesinin tamamının sınıflandırma deneylerinde kullanılmadığı anlamına gelmektedir. Bu durum, sonuçların yorumlanmasında göz önünde bulundurulması gereken bir sınırlılıktır.

Veri kümesinin nüfusbilimsel yapısı da sonuçların değerlendirilmesinde önemlidir. EEG işaretleri yaş, cinsiyet, fizyolojik durum, dikkat düzeyi, yorgunluk, kayıt anındaki uyanıklık düzeyi, elektrot yerleşimi ve oturumlar arasındaki zaman farkı gibi birçok değişkenden etkilenebilmektedir. Bu nedenle model başarısı yalnızca sınıflandırıcı mimarisinin gücüyle açıklanamaz. İki oturumlu alt kümenin yaş dağılımı, cinsiyet dağılımı ve oturumlar arası süre yapısı, elde edilen oturumlar arası başarım değerlerinin yorumlanmasında arka plan değişkenleri olarak dikkate alınmalıdır. Tez kapsamında bu nüfusbilimsel değişkenlerin ayrıca incelenmesi, deneysel sonuçların daha şeffaf ve bağlam içinde değerlendirilmesini sağlamaktadır.

Gürültü tespit ve giderim yaklaşımı açısından değerlendirildiğinde, BÇS–Wasserstein ÜÇA tabanlı yapının çalışmaya iki yönlü katkı sunduğu görülmektedir. Birinci katkı, bozulmuş EEG pencerelerinin tespit edilmesidir. İkinci katkı ise bozulmuş pencerelerin doğrudan atılması yerine yeniden yapılandırılarak kullanılabilir hâle getirilmesidir. EEG biyometrisinde bu ayrım önemlidir. Kısa süreli EEG kayıtlarında çok sayıda pencerenin bozulma nedeniyle dışlanması, kullanılabilir veri miktarını azaltabilir. Buna karşılık bozulmuş pencerelerin kontrolsüz biçimde sınıflandırıcıya verilmesi, modelin biyometrik bilgi yerine bozulma örüntülerinden etkilenmesine neden olabilir. Bu nedenle önerilen yaklaşım, veri kaybını azaltma ile işaret kalitesini koruma arasında bir denge kurmayı hedeflemektedir.

BÇS modülünde DEn, LZK ve KOK özniteliklerinin birlikte kullanılması, bozulma tespitine yorumlanabilir bir yapı kazandırmıştır. KOK, yüksek genlikli bozulmalara duyarlı bir enerji göstergesi olarak değerlendirilebilirken; DEn, işaret enerjisinin alt bantlar arasındaki dağılımını; LZK ise işaretin karmaşıklık düzeyini temsil etmektedir. Bu özniteliklerin birlikte kullanılması, tek bir eşik değerine dayalı karar yapısına kıyasla daha esnek bir bozulma tespit süreci sağlamaktadır. Bununla birlikte BÇS tabanlı karar yapısının başarısı, tanımlanan üyelik işlevleri, kural tabanı ve seçilen özniteliklerin temsil gücüyle sınırlıdır. Bu nedenle farklı veri kümeleri, farklı bozulma yoğunlukları veya farklı kayıt cihazları kullanıldığında bu yapıların yeniden ayarlanması gerekebilir.

Gürültü giderimi sonuçları, Wasserstein ÜÇA tabanlı yeniden yapılandırmanın zaman ve frekans bölgesinde işaret bütünlüğünü koruma potansiyeli taşıdığını göstermektedir. Ancak burada dikkat edilmesi gereken nokta, gürültü giderme başarısının yalnızca işaretin daha düzgün görünmesiyle değerlendirilmemesidir. EEG biyometrisinde önemli olan, gürültü giderme işleminden sonra bireye özgü zamansal ve spektral örüntülerin korunup korunmadığıdır. Yeniden yapılandırma işlemi aşırı düzleştirme yaparsa, bozulmaları azaltırken biyometrik açıdan ayırt edici bilgiyi de zayıflatabilir. Bu nedenle tez kapsamında gürültü giderim yaklaşımının hem işaret kalitesi hem de sınıflandırma hattına olası katkısı bakımından değerlendirilmesi yerinde bir yaklaşımdır.

Kanal–frekans bandı analizleri, çalışmanın tek kanallı EEG biyometrisi açısından önemli bulgularından birini oluşturmaktadır. Farklı ayrışma ölçütleriyle yapılan değerlendirmelerde özellikle duvarsal, duvar-artkafa ve bazı alınsal bölgelerin öne çıkması, biyometrik bilginin tüm elektrotlara eşit biçimde dağılmadığını göstermektedir. P2, P4, PO4 ve F4 gibi kanalların farklı analizlerde tekrar tekrar yüksek önem değerleri üretmesi, bu bölgelerin tek kanallı EEG kimlik tanımlama

açısından dikkate değer adaylar olduğunu göstermektedir. Bununla birlikte bu bulgu, yalnızca bu kanalların her veri kümesinde veya her kayıt protokolünde en iyi sonucu vereceği anlamına gelmez. Elektrot önemleri veri kümesine, kayıt koşullarına, ön işleme yöntemine, frekans bandı tanımlarına ve kullanılan sınıflandırıcıya bağlı olarak değişebilir.

Frekans bandı düzeyinde gama ve yüksek gama bileşenlerinin öne çıkması, yüksek frekanslı bileşenlerin daha hızlı ve yerel sinirsel dinamikleri yansıtması ve bireyler arası mikro-düzey farklılıklara duyarlı olmasıyla ilişkilendirilebilir. Nitekim dinlenim durumu EEG biyometrisi çalışmalarında da gama bandının yüksek ayırt edicilik sağlayabildiği bildirilmiştir (Fraschini vd. 2015, Monsy ve Vinod 2020). Bununla birlikte gama bandının EMG kaynaklı bozulmalara duyarlılığı nedeniyle sonuçlar gürültü giderim süreciyle birlikte değerlendirilmelidir.

Model eğitim süreci ve DEHB tabanlı üst değişken eniyilemesi, önerilen modelin yüksek başarısının rastgele bir model yapılandırmasından kaynaklanmadığını göstermektedir. DEHB sürecinde öğrenme oranı, yığın boyutu, seyrelme oranı, evrişimsel süzgeç sayısı, ÇY-UKSB gizli birim sayısı, Dönüştürücü başlık ve katman sayısı, tam bağlantılı katman boyutu ve ağırlık bozunumu gibi birçok üst değişkenin birlikte değerlendirilmesi, modelin kapasite ve düzenlileştirme dengesinin sistematik biçimde kurulmasına katkı sağlamıştır. Bu durum EEG gibi düşük genlikli, gürültülü ve sınırlı örnekli biyolojik işaretlerde özellikle önemlidir. Çok yüksek kapasiteli modeller eğitim verisine aşırı uyum gösterebilirken, yetersiz kapasiteli modeller bireye özgü ince örüntüleri yakalayamayabilir.

Eğitim ve doğrulama eğrileri, modelin eğitim süreci boyunca kararlı biçimde yakınsadığını göstermektedir. Eğitim kaybı ile doğrulama kaybının birlikte azalması, modelin yalnızca eğitim örneklerini ezberlemediğini; doğrulama verisine aktarılabilen temsiller öğrenebildiğini göstermektedir. Eğitim doğruluğu ile doğrulama doğruluğu arasındaki farkın sınırlı kalması da aşırı öğrenme eğiliminin kontrol altında olduğunu düşündürmektedir. Bununla birlikte doğrulama başarımı, nihai test başarımı yerine geçmez. Doğrulama sonuçları model seçimi ve üst değişken eniyilemesi için kullanılmış; modelin asıl genellenebilirliği oturumlar arası test protokolleriyle değerlendirilmiştir. Bu ayrım, deneysel sonuçların tarafsız yorumlanması açısından önemlidir.

Kapalı-küme kimlik tanımlama sonuçları, önerilen ESA–ÇY-UKSB–Dönüştürücü modelinin oturumlar arası değerlendirme koşullarında yüksek başarım sunduğunu göstermektedir. Aynı oturum

içi protokolde elde edilen başarının ana oturumlar arası protokole göre yalnızca sınırlı düzeyde yüksek olması, modelin yalnızca aynı oturuma özgü geçici kayıt koşullarını öğrenmediğini düşündürmektedir. Ters yönlü oturumlar arası protokolde başarının ana protokole yakın kalması da model başarımının belirli bir oturum yönüne güçlü biçimde bağımlı olmadığını göstermektedir. Bu bulgular, modelin oturumlar arasında korunabilen bireye özgü EEG örüntülerinden yararlanabildiğini desteklemektedir.

Bununla birlikte karışık oturum protokolünde başarının daha düşük olması, protokol yapısının başarım üzerinde etkili olabileceğini göstermektedir. Karışık protokol ilk bakışta daha kolay bir senaryo gibi görünse de, eğitim ve test bölmelerinde farklı oturumlara ait örneklerin birlikte yer alması sınıf içi dağılımı daha heterojen hâle getirebilir. Bu durum karar sınırlarının öğrenilmesini zorlaştırabilir. Dolayısıyla karışık protokoldeki başarım düşüşü, doğrudan modelin başarısızlığı olarak değil, veri dağılımının farklı bir biçimde yapılandırılmasının sonucu olarak değerlendirilmelidir.

Model karşılaştırmaları, önerilen karma yapının klasik öznitelik tabanlı yöntemlere ve yaygın derin öğrenme modellerine göre daha yüksek başarı ürettiğini göstermektedir. GSY+DVM ve GSY+RO gibi klasik yaklaşımlar, frekans bölgesi özniteliklerinin bireye özgü bilgi taşıdığını göstermiş; ancak bu öznitelikler oturumlar arası değişkenliği karşılamada sınırlı kalmıştır. *EEGNet* ve *ShallowConvNet* gibi derin öğrenme modelleri klasik yöntemlere göre daha yüksek başarı üretmiş, fakat önerilen karma modelin gerisinde kalmıştır. Bu durum, tek başına evrişimsel süzgeçlerin EEG penceresi içindeki uzun menzilli ilişkileri ve çift yönlü zamansal bağlamı temsil etmekte sınırlı kalabileceğini düşündürmektedir.

Bileşen çıkarma analizleri, önerilen modelin başarısının tek bir bileşene bağlı olmadığını göstermektedir. ESA bileşeni yerel zamansal örüntüleri yakalarken, ÇY-UKSB pencere içindeki ileri ve geri yönlü bağımlılıkları modellemekte, Dönüştürücü ise dikkat düzeneğiyle ayırt edici zaman bölgelerini daha seçici biçimde ağırlıklandırmaktadır. Bu bileşenler birlikte kullanıldığında daha yüksek başarı elde edilmesi, EEG işaretinin çok ölçekli, ardışıl ve bağlamsal yapısının karma mimariyle daha etkili temsil edildiğini göstermektedir. Ancak bileşen çıkarma sonuçları, her bileşenin katkısının veri kümesi ve deney protokolüne bağlı olarak değişebileceğini de düşündürmektedir. Bu nedenle farklı veri kümelerinde benzer çıkarma analizlerinin tekrarlanması, bileşen katkılarının genellenebilirliğini değerlendirmek açısından önemlidir.

KEK eğrisi ve ilk-k doğruluk sonuçları, modelin yalnızca birinci-sıra tahmin başarısının değil, aday sıralama davranışının da güçlü olduğunu göstermektedir. İlk-3 ve ilk-5 doğruluk değerlerinin yüksek olması, modelin bazı pencerelerde birinci sırada hata yapsa bile gerçek kimliği üst adaylar arasında tuttuğunu göstermektedir. Bu bulgu, modelin olasılık dağılımının anlamlı bir sıralama ürettiğini düşündürmektedir. Bu özellik, kişi düzeyi karar birleştirme açısından da önemlidir; çünkü yumuşak oylama gibi yöntemler, tekil pencere kararlarından ziyade olasılık dağılımlarının birlikte değerlendirilmesine dayanır.

Kişi düzeyi karar birleştirme sonuçları, yumuşak oylamanın çoğunluk oylaması ve maksimum güven puanı yöntemlerine göre daha kararlı sonuçlar verdiğini göstermektedir. Bunun nedeni, yumuşak oylamanın her pencerenin tüm sınıflara ait olasılık bilgisini kullanmasıdır. Çoğunluk oylaması yalnızca en yüksek olasılıklı sınıf etiketini dikkate aldığından, düşük güvenli ve yüksek güvenli kararları eşit ağırlıkta değerlendirir. Maksimum güven puanı yaklaşımı ise tek bir pencereye aşırı bağımlı olabilir. Bu nedenle yumuşak oylamanın daha yüksek başarı üretmesi beklenen ve yöntemsel olarak açıklanabilir bir sonuçtur. Ancak gerçek zamanlı uygulamalarda yumuşak oylama için birden fazla pencereye ihtiyaç duyulacağından, karar süresi ve kullanıcı konforu birlikte değerlendirilmelidir.

Test süresi analizi, 4 saniyelik pencerenin bu çalışma için uygun bir denge sunduğunu göstermektedir. EEG durağan olmayan bir işaret olmakla birlikte, kısa zaman bölütlerinde yaklaşık durağan (quasi-stationary) kabul edilebilmekte; 4 saniyelik pencerelerin bu açıdan uygun bir zaman ölçeği sağlayabildiği bildirilmektedir (Góngora vd. 2022, Ng vd. 2022). Ayrıca farklı EEG sınıflandırma çalışmalarında da 4 saniyelik pencerelerle yüksek başarım elde edilmiştir (Alawee vd. 2023, Hasan vd. 2025). Bu nedenle elde edilen sonuç, hem kısa dönemli işaret kararlılığı hem de yeterli spektral temsil açısından literatürle uyumludur.

Tekrarlı deney sonuçları, model başarısının tek bir rastlantısal eğitim çalıştırmasına bağlı olmadığını göstermektedir. Beş bağımsız tekrar sonucunda düşük standart sapmalarla yüksek başarım elde edilmesi, önerilen modelin eğitim başlangıç koşullarına ve stokastik eniyileme etkilerine karşı kararlı olduğunu göstermektedir. Bu bulgu, özellikle derin öğrenme modellerinde önemlidir. Çünkü tek bir çalıştırmada elde edilen yüksek doğruluk, tekrarlı deneylerle desteklenmediğinde modelin genel başarısını temsil etmeyebilir. Bu tezde tekrarlı deneylerin raporlanması, deneysel güvenilirlik açısından olumlu bir yaklaşımdır.

Genel olarak değerlendirildiğinde, tez EEG tabanlı biyometrik kimlik tanımlama alanında üç temel eksene katkı sunmaktadır. Birincisi, oturumlar arası kapalı-küme değerlendirme ile modelin aynı oturum içi başarıya bağımlı kalmadan farklı kayıt oturumlarında da yüksek başarım üretip üretmediği sınanmıştır. İkincisi, tek kanallı EEG temsilleri ve kanal–bant analizleri sayesinde pratik uygulanabilirliği daha yüksek sistem tasarımlarına yönelik bulgular elde edilmiştir. Üçüncüsü, gürültü giderimi, DEHB tabanlı üst değişken eniyilemesi, kişi düzeyi karar birleştirme, test süresi analizi ve bileşen çıkarma deneyleriyle model yalnızca tek bir doğruluk değeri üzerinden değil, çok boyutlu bir değerlendirme çerçevesiyle incelenmiştir.

Bununla birlikte sonuçlar belirli sınırlılıklar içinde yorumlanmalıdır. Çalışma kapalı-küme kimlik tanımlama problemine odaklanmıştır; bu nedenle kayıtlı olmayan kullanıcı reddi, kimlik iddiasının kabul/ret biçiminde değerlendirilmesi ve sürekli kimlik doğrulama gibi senaryolar bu çalışmanın doğrudan kapsamı dışındadır. Ana oturumlar arası deneyler iki oturumlu 42 katılımcıyla sınırlıdır. Veri kümesi gözler kapalı dinlenim durumu kayıtlarından oluşmaktadır; bu nedenle sonuçlar gözler açık, görev temelli, taşınabilir cihaz veya gerçek zamanlı kullanım koşullarına doğrudan genellenemez. Ayrıca gürültü giderim deneylerinde yapay olarak modellenmiş EMG ve EOG bozulmalarının kullanılması, kontrollü değerlendirme açısından avantaj sağlasa da gerçek dünyadaki karmaşık bozulma yapılarını tam olarak temsil etmeyebilir.

Bu sınırlılıklar, çalışmanın bulgularını geçersiz kılmamakta; aksine gelecekte yapılması gereken tamamlayıcı araştırma yönlerini göstermektedir. Tez kapsamında elde edilen sonuçlar, tek kanallı EEG işaretlerinden oturumlar arası kapalı-küme kimlik tanımlama için güçlü ve kararlı temsiller öğrenilebileceğini göstermektedir. Ancak bu bulguların daha geniş, çok oturumlu, farklı cihazlarla kaydedilmiş, farklı nüfusbilimsel özelliklere sahip ve farklı kayıt protokollerini içeren veri kümelerinde doğrulanması gerekmektedir.

5. SONUÇ

Bu tezde, EEG tabanlı biyometrik kimlik tanımlama problemi kapalı-küme, oturumlar arası ve tek kanallı bir deneysel çerçevede ele alınmıştır. Çalışmanın temel amacı, dinlenim durumu EEG işaretlerinden bireye özgü ve oturumlar arasında korunabilen ayırt edici örüntüleri öğrenebilen, kısa süreli ve tek kanallı EEG pencereleriyle yüksek doğruluk üretebilen, olasılıksal çıktı sağlayan ve farklı başarım ölçütleriyle kapsamlı biçimde değerlendirilebilen bir biyometrik kimlik tanımlama yaklaşımı geliştirmektir. Bu amaç doğrultusunda USYM dinlenim durumu EEG veri kümesi kullanılmış; veri kümesinin nüfusbilimsel yapısı incelenmiş, gürültü tespiti ve giderimi için BÇS–Wasserstein ÜÇA tabanlı bir yaklaşım önerilmiş, kanal–frekans bandı düzeyinde ayırt edicilik analizleri yapılmış, ESA–ÇY-UKSB–Dönüştürücü tabanlı karma bir derin öğrenme modeli geliştirilmiş ve modelin üst değişkenleri DEHB algoritması ile eniyilenmiştir.

Tez kapsamında kullanılan USYM veri kümesi toplam 111 katılımcıdan oluşmakta, ana oturumlar arası kimlik tanımlama deneyleri ise iki oturumlu 42 katılımcı üzerinde yürütülmektedir. Bu yapı, modelin yalnızca aynı oturum içindeki örüntüleri değil, farklı kayıt oturumlarında korunabilen bireye özgü EEG bileşenlerini de öğrenip öğrenemediğini değerlendirmeye olanak sağlamıştır. EEG kayıtları 4 saniyelik örtüşmesiz pencerelere ayrılmış ve her pencere 4096×1 boyutunda tek kanallı zaman serisi olarak modele sunulmuştur. Bu yaklaşım, çok kanallı EEG sistemlerine kıyasla daha pratik, daha düşük donanım gereksinimli ve kullanıcı açısından daha uygulanabilir bir biyometrik sistem tasarımına yönelik deneysel temel sağlamıştır.

Önerilen BÇS–Wasserstein ÜÇA tabanlı gürültü tespiti ve giderimi yaklaşımı, EEG biyometrik sistemlerinde işaret kalitesinin korunması amacıyla geliştirilmiştir. BÇS modülü, DEn, LZK ve KOK öznitelikleri üzerinden EEG pencerelerinin bozulmasız, EOG kaynaklı bozulmuş veya EMG kaynaklı bozulmuş olup olmadığını belirlemeye çalışmıştır. Wasserstein ÜÇA tabanlı yeniden yapılandırma bileşeni ise bozulmuş pencerelerin doğrudan dışlanması yerine işaret bütünlüğünü koruyacak biçimde onarılmasını hedeflemiştir. Deneysel sonuçlar, bu yaklaşımın hem yapay EEG hem de gerçek EEG üzerine eklenen kontrollü bozulma senaryolarında işlevsel olduğunu göstermiştir. Böylece tezde, EEG biyometrik sistemlerinde gürültü yönetiminin yalnızca klasik süzgeçleme veya veri dışlama yaklaşımıyla değil, tespit ve yeniden yapılandırmayı birleştiren bütünleşik bir çerçeveyle ele alınabileceği gösterilmiştir.

Kanal–frekans bandı seçimi ve oturumlar arası kararlılık analizleri, tek kanallı EEG biyometrik sistemler açısından önemli sonuçlar ortaya koymuştur. Farklı ayrışma ölçütleri birlikte değerlendirildiğinde, duvarsal ve duvar-artkafa bölgelerin, özellikle P2, P4 ve PO4 kanallarının, yüksek ayırt edicilik sunduğu görülmüştür. Frekans bölgesinde ise gama ve yüksek gama bileşenleri öne çıkmıştır. En yüksek tek kanallı başarının Gama7 | P2 kanal–bant çiftinde elde edilmesi, belirli kanal–bant kombinasyonlarının tek başına güçlü biyometrik bilgi taşıyabildiğini göstermiştir. Bu sonuç, düşük elektrot sayısına sahip EEG biyometrik sistemlerin geliştirilebilmesi açısından önemli bir bulgudur.

Tez kapsamında geliştirilen ESA–ÇY-UKSB–Dönüştürücü modeli, EEG işaretinin çok ölçekli, zamansal ve bağlamsal yapısını birlikte modellemek üzere tasarlanmıştır. Çok ölçekli ESA bileşeni yerel ve frekans duyarlı örüntüleri; ÇY-UKSB bileşeni ileri ve geri yönlü zamansal bağımlılıkları; Dönüştürücü bileşeni ise dikkat düzeneği aracılığıyla uzun menzilli ilişkileri temsil etmiştir. DEHB tabanlı üst değişken eniyilemesi ile modelin öğrenme oranı, yığın boyutu, seyrelme oranı, evrişimsel kapasitesi, ÇY-UKSB boyutu, Dönüştürücü başlık ve katman sayısı gibi temel üst değişkenleri sistematik biçimde belirlenmiştir. Eğitim ve doğrulama sonuçları, modelin kararlı biçimde yakınsadığını ve doğrulama verisine yüksek başarıyla genellenebildiğini göstermiştir.

Kapalı-küme kimlik tanımlama deneylerinde önerilen model, ana oturumlar arası protokolde yüksek birinci-sıra doğruluk, ilk-k doğruluk, makro F1 ve dengeli doğruluk değerleri üretmiştir. Aynı oturum içi, ana oturumlar arası ve ters yönlü oturumlar arası protokoller birlikte değerlendirildiğinde, modelin başarısının oturum yönüne güçlü biçimde bağımlı olmadığı ve oturumlar arası değişkenliğe rağmen yüksek düzeyde korunduğu görülmüştür. Model karşılaştırmaları, önerilen karma yapının klasik GSY tabanlı makine öğrenmesi yöntemlerine, yaygın derin öğrenme modellerine ve ara karma varyantlara göre daha yüksek başarı sağladığını göstermiştir.

Aday sıralama başarımı açısından KEK eğrisi ve ilk-k doğruluk sonuçları, modelin gerçek kimliği yalnızca birinci sırada değil, üst adaylar arasında da güvenilir biçimde tuttuğunu göstermiştir. Kişi düzeyi karar birleştirme deneylerinde yumuşak oylama yöntemi en yüksek başarıyı sağlamış ve pencere düzeyindeki sınırlı kararsızlıkların olasılıksal birleştirme ile azaltılabileceğini göstermiştir. Test süresi analizinde ise 4 saniyelik EEG penceresinin doğruluk ve karar süresi açısından uygun bir denge sunduğu görülmüştür. Daha kısa pencereler yeterli zamansal/frekanssal temsil sağlayamazken, daha uzun sürelerin her zaman daha yüksek başarı üretmediği belirlenmiştir.

Bant dalı ve model bileşeni çıkarma analizleri, önerilen modelin başarısının tek bir bileşene bağlı olmadığını ortaya koymuştur. Gama bandı, tekil bant dalları içinde en yüksek başarıyı üretmiş; ESA, ÇY-UKSB ve Dönüştürücü bileşenlerinin birlikte kullanımı ise model başarısını artırmıştır. Spektral temsil, öznitelik yeniden ağırlıklandırma ve DEHB tabanlı üst değişken eniyilemesi de nihai başarıma ek katkı sağlamıştır. Tekrarlı deneyler sonucunda düşük standart sapmalarla yüksek başarı elde edilmesi, modelin kararlı ve yeniden üretilebilir sonuçlar sunduğunu göstermiştir.

Bu tezin başlıca sonuçları şu şekilde özetlenebilir: Birincisi, tek kanallı dinlenim durumu EEG pencereleri, uygun kanal–bant seçimi ve güçlü temsil öğrenme mimarisiyle kapalı-küme kimlik tanımlama için yüksek düzeyde ayırt edici bilgi taşıyabilmektedir. İkincisi, oturumlar arası değerlendirme koşullarında yüksek başarının korunabilmesi, bireye özgü EEG örüntülerinin belirli ölçüde zamansal kararlılık gösterdiğini desteklemektedir. Üçüncüsü, EEG biyometrik sistemlerinde gürültü tespiti/giderimi, kanal–bant seçimi, üst değişken eniyilemesi, karar birleştirme ve test süresi seçimi gibi bileşenler birlikte ele alındığında daha güvenilir bir değerlendirme çerçevesi oluşturulabilmektedir.

Bununla birlikte çalışma belirli sınırlılıklar içermektedir. İlk olarak deneysel kapsam kapalı-küme kimlik tanımlama ile sınırlandırılmıştır. Bu nedenle kayıtlı olmayan kullanıcı reddi, kimlik doğrulama ve sürekli kimlik doğrulama senaryoları ayrıca ele alınmalıdır. İkinci olarak ana oturumlar arası değerlendirme iki oturumlu 42 katılımcı ile sınırlıdır. Daha geniş, çok oturumlu ve uzun dönemli veri kümelerinde dış doğrulama yapılması gerekmektedir. Üçüncü olarak kayıtlar gözler kapalı dinlenim durumu EEG verilerinden oluşmaktadır; görev temelli, gözler açık, taşınabilir cihaz veya gerçek zamanlı kullanım senaryoları bu çalışmanın doğrudan kapsamı dışındadır. Dördüncü olarak yüksek frekanslı bileşenlerde elde edilen ayırt edicilik, EMG bozulma duyarlılığı nedeniyle dikkatli yorumlanmalıdır.

Gelecek çalışmalarda, önerilen modelin açık-küme tanıma ve kimlik doğrulama senaryolarına genişletilmesi önemli bir araştırma yönü olarak değerlendirilmektedir. Modelin olasılıksal çıktı üretmesi, eşik tabanlı kabul/ret kararları, güven puanı kalibrasyonu ve bilinmeyen kullanıcı reddi için uygun bir temel sunmaktadır. Ayrıca modelin farklı EEG veri kümelerinde, farklı cihazlarda, farklı elektrot yerleşimlerinde ve farklı kayıt protokollerinde sınanması, yöntemin genellenebilirliğini değerlendirmek açısından gereklidir. Alan uyarlama, öz-denetimli ön eğitim, oturumdan bağımsız temsil öğrenme ve transfer öğrenme yaklaşımları bu kapsamda kullanılabilir.

Gelecekte yapılabilecek bir diğer çalışma, tek kanallı veya az kanallı taşınabilir EEG biyometrik sistemlerin geliştirilmesidir. Bu tezde elde edilen kanal–bant bulguları, belirli elektrot bölgeleri ve frekans bileşenlerinin yüksek ayırt edicilik sunduğunu göstermektedir. Bu bulgular, düşük maliyetli, hızlı kurulabilen ve kullanıcı konforunu artıran EEG biyometrik sistemlerin tasarlanmasına katkı sağlayabilir. Ancak taşınabilir cihazlarda elektrot temas kararlılığı, çevresel gürültü, hareket bozulmaları ve gerçek zamanlı işlem yükü gibi etkenlerin ayrıca değerlendirilmesi gerekmektedir.

Sonuç olarak bu tez, EEG tabanlı biyometrik kimlik tanımlama alanında kapalı-küme, oturumlar arası ve tek kanallı bir deneysel çerçevede bütüncül bir yaklaşım sunmuştur. Önerilen BÇS–Wasserstein ÜÇA tabanlı gürültü tespit ve giderim modülü, kanal–bant analizleri, DEHB ile eniyilenmiş ESA–ÇY-UKSB–Dönüştürücü modeli, kişi düzeyi karar birleştirme ve tekrarlı deneylerle kararlılık değerlendirmesi birlikte ele alındığında, EEG işaretlerinin kısa süreli ve tek kanallı kayıtlarla yüksek doğruluklu biyometrik kimlik tanımlama için kullanılabileceği gösterilmiştir. Bu bulgular, EEG biyometrisinin daha pratik, daha düşük donanım gereksinimli ve oturumlar arası daha güvenilir sistem tasarımlarına doğru geliştirilebileceğini göstermektedir.

KAYNAKLAR

Aboy, M., Hornero, R., Abásolo, D. ve Álvarez, D. 2006. Interpretation of the Lempel-Ziv complexity measure in the context of biomedical signal analysis. IEEE Transactions on Biomedical Engineering, 53(11), 2282–2288.

Acharya, J. N., Hani, A. J., Cheek, J., Thirumala, P. ve Tsuchida, T. N. 2016. American Clinical Neurophysiology Society Guideline 2: Guidelines for standard electrode position nomenclature. Journal of Clinical Neurophysiology, 33(4), 308–311. https://doi:10.1097/WNP.0000000000000316.

Adler, J. ve Lunz, S. 2018. Banach Wasserstein GAN. Advances in Neural Information Processing Systems, 31.

Alawee, W. H., Basem, A. ve Al-Haddad, L. A. 2023. Advancing biomedical engineering: Leveraging Hjorth features for electroencephalography signal analysis. Journal of Electrical Bioimpedance, 14(1), 66–72.

Aldayel, M., Alsedairy, N., Al-Nafjan, A. ve Alsenan, S. 2024. Systematic review of brain–computer interface-based user authentication system: Trends, challenges, and directions. IEEE Access, 12, 96848–96861. https://doi.org/10.1109/ACCESS.2024.3421264

Alsumari, W., Hussain, M., Alshehri, L. ve Aboalsamh, H. A. 2023. EEG-based person identification and authentication using deep convolutional neural network. Axioms, 12(1), 74. https://doi:10.3390/axioms12010074.

Alyasseri, Z. A. A., Khader, A. T., Al-Betar, M. A. ve Alomari, O. A. 2020. Person identification using EEG channel selection with hybrid flower pollination algorithm. Pattern Recognition, 105, 107393. https://doi:10.1016/j.patcog.2020.107393.

Arjovsky, M., Chintala, S. ve Bottou, L. 2017. Wasserstein generative adversarial networks. Proceedings of the 34th International Conference on Machine Learning, 70, 214–223.

Arnau-González, P., Arevalillo-Herráez, M., Katsigiannis, S. ve Ramzan, N. 2021. On the influence of affect in EEG-based subject identification. IEEE Transactions on Affective Computing, 12(2), 391–401. https://doi:10.1109/TAFFC.2018.2877986.

Awad, N., Mallik, N. ve Hutter, F. 2021. DEHB: Evolutionary Hyperband for scalable, robust and efficient hyperparameter optimization. Proceedings of the Thirtieth International Joint Conference on Artificial Intelligence, 2147–2153.

Azevedo, F. A., Carvalho, L. R., Grinberg, L. T., Farfel, J. M., Ferretti, R. E., Leite, R. E., Jacob Filho, W., Lent, R. ve Herculano-Houzel, S. 2009. Equal numbers of neuronal and nonneuronal cells make the human brain an isometrically scaled-up primate brain. Journal of Comparative Neurology, 513(5), 532–541. https://doi:10.1002/cne.21974.

Babiloni, C., Barry, R. J., Başar, E., Blinowska, K. J., Cichocki, A., Drinkenburg, W. H. I. M., Klimesch, W., Knight, R. T., Lopes da Silva, F., Nunez, P., Oostenveld, R., Jeong, J., Pascual-Marqui, R., Valdes-Sosa, P., Hallett, M. ve International Federation of Clinical Neurophysiology EEG Research Workgroup. 2020. Recommendations on frequency and topographic analysis of resting state EEG rhythms. Part 1: Applications in clinical research studies. Clinical Neurophysiology, 131(1), 285–307. https://doi.org/10.1016/j.clinph.2019.06.234.

Benomar, M., Cao, S., Vishwanath, M., Vo, K. ve Cao, H. 2022. Investigation of EEG-based biometric identification using state-of-the-art neural architectures on a real-time Raspberry Pi-based system. Sensors, 22(23), 9547. https://doi:10.3390/s22239547.

Beyrouthy, T., Mostafa, N., Roshdy, A., Karar, A. S. ve Alkork, S. 2024. Review of EEG-based biometrics in 5G-IoT: Current trends and future prospects. Applied Sciences, 14(2), 534. https://doi.org/10.3390/app14020534

Biasiucci, A., Franceschiello, B. ve Murray, M. M. 2019. Electroencephalography. Current Biology, 29(3), R80–R85. https://doi:10.1016/j.cub.2018.11.052.

Bidgoly, A. J., Bidgoly, H. J. ve Arezoumand, Z. 2020. A survey on methods and challenges in EEG based authentication. Computers & Security, 93, 101788. https://doi:10.1016/j.cose.2020.101788.

Blumenfeld, H. 2021. Neuroanatomy Through Clinical Cases. 3rd ed. Oxford University Press, New York.

Buzsáki, G. 2002. Theta oscillations in the hippocampus. Neuron, 33(3), 325–340.

Buzsáki, G. ve Draguhn, A. 2004. Neuronal oscillations in cortical networks. Science, 304, 1926–1929.

Buzsáki, G. ve Wang, X.-J. 2012. Mechanisms of gamma oscillations. Annual Review of Neuroscience, 35, 203–225.

Calinski, T. ve Harabasz, J. 1974. A dendrite method for cluster analysis. Communications in Statistics, 3(1), 1–27. doi:10.1080/03610927408827101.

Campisi, P. ve La Rocca, D. 2014. Brain waves for automatic biometric-based user recognition. IEEE Transactions on Information Forensics and Security, 9(5), 782–800. https://doi.org/10.1109/TIFS.2014.2308640

Cavanagh, J. F. ve Frank, M. J. 2014. Frontal theta as a mechanism for cognitive control. Trends in Cognitive Sciences, 18, 414–421.

Das, B. B., Ram, S. K., Babu, K. S., Mohapatra, R. K. ve Mohanty, S. P. 2024. Person identification using autoencoder-CNN approach with multitask-based EEG biometric. Multimedia Tools and Applications, 83, 83205–83225. https://doi:10.1007/s11042-024-18693-z.

Das, R., Maiorana, E. ve Campisi, P. 2016. EEG biometrics using visual stimuli: A longitudinal study. IEEE Signal Processing Letters, 23(3), 341–345. https://doi.org/10.1109/LSP.2016.2516043

Davies, D. L. ve Bouldin, D. W. 1979. A cluster separation measure. IEEE Transactions on Pattern Analysis and Machine Intelligence, PAMI-1(2), 224–227. doi:10.1109/TPAMI.1979.4766909.

Delorme, A. ve Makeig, S. 2004. EEGLAB: An open source toolbox for analysis of single-trial EEG dynamics including independent component analysis. Journal of Neuroscience Methods, 134(1), 9–21. doi:10.1016/j.jneumeth.2003.10.009.

Delorme, A., Palmer, J., Onton, J., Oostenveld, R. ve Makeig, S. 2012. Independent EEG sources are dipolar. PLoS ONE, 7(2), e30135. doi:10.1371/journal.pone.0030135.

DelPozo-Banos, M., Travieso, C. M., Weidemann, C. T. ve Alonso, J. B. 2015. EEG biometric identification: A thorough exploration of the time-frequency domain. Journal of Neural Engineering, 12(5), 056019. https://doi:10.1088/1741-2560/12/5/056019.

Du, Y., Xu, Y., Wang, X., Liu, L. ve Ma, P. 2022. EEG temporal-spatial transformer for person identification. Scientific Reports, 12, 14378. https://doi:10.1038/s41598-022-18502-3.

Duda, R. O., Hart, P. E. ve Stork, D. G. 2001. Pattern Classification. 2nd ed. Wiley, New York.

Engel, A. K. ve Fries, P. 2010. Beta-band oscillations–signalling the status quo? Current Opinion in Neurobiology, 20, 156–165.

Fawcett, T. 2006. An introduction to ROC analysis. Pattern Recognition Letters, 27(8), 861–874. https://doi.org/10.1016/j.patrec.2005.10.010

Fidas, C. A. ve Lyras, D. 2023. A review of EEG-based user authentication: Trends and future research directions. IEEE Access, 11, 22917–22934. https://doi.org/10.1109/ACCESS.2023.3253026

Fisher, R. A. 1936. The use of multiple measurements in taxonomic problems. Annals of Eugenics, 7(2), 179–188. doi:10.1111/j.1469-1809.1936.tb02137.x.

Fraschini, M., Hillebrand, A., Demuru, M., Didaci, L. ve Marcialis, G. L. 2015. An EEG-based biometric system using eigenvector centrality in resting state brain networks. IEEE Signal Processing Letters, 22(6), 666–670. https://doi:10.1109/LSP.2014.2367091.

Fries, P. 2009. Neuronal gamma-band synchronization as a fundamental process in cortical computation. Annual Review of Neuroscience, 32, 209–224.

Fukunaga, K. 1990. Introduction to Statistical Pattern Recognition. 2nd ed. Academic Press, San Diego.

Góngora, L., Paglialonga, A., Mastropietro, A., Rizzo, G. ve Barbieri, R. 2022. A novel approach for segment-length selection based on stationarity to perform effective connectivity analysis applied to resting-state EEG signals. Sensors, 22(13), 4747.

Goodfellow, I., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., Courville, A. ve Bengio, Y. 2014. Generative adversarial nets. Advances in Neural Information Processing Systems, 27.

Gulrajani, I., Ahmed, F., Arjovsky, M., Dumoulin, V. ve Courville, A. 2017. Improved training of Wasserstein GANs. Advances in Neural Information Processing Systems, 30.

Harmony, T. 2013. The functional significance of delta oscillations in cognitive processing. Frontiers in Integrative Neuroscience, 7, 83.

Hasan, M. M., Islam, M. N., Sulaiman, N., Hossain, M. M. ve Mendes, J. M. 2025. Real-time EEG signal analysis for microsleep detection: Hyper-Opt-ANN as a key solution. IEEE Access, 13, 66354–66372.

Hastie, T., Tibshirani, R. ve Friedman, J. 2009. The Elements of Statistical Learning: Data Mining, Inference, and Prediction. 2nd ed. Springer, New York.

Hatlestad-Hall, C., Rygvold, T. W. ve Andersson, S. 2022. BIDS-structured resting-state electroencephalography (EEG) data extracted from an experimental paradigm. Data in Brief, 45, 108647. https://doi.org/10.1016/j.dib.2022.108647.

Huang, G., Hu, Z., Chen, W., Zhang, S., Liang, Z., Li, L., Zhang, L. ve Zhang, Z. 2022. M3CV: A multi-subject, multi-session, and multi-task database for EEG-based biometrics challenge. NeuroImage, 264, 119666. https://doi.org/10.1016/j.neuroimage.2022.119666

Isola, P., Zhu, J.-Y., Zhou, T. ve Efros, A. A. 2017. Image-to-image translation with conditional adversarial networks. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 1125–1134.

Jackson, A. F. ve Bolger, D. J. 2014. The neurophysiological bases of EEG and EEG measurement: A review for the rest of us. Psychophysiology, 51(11), 1061–1071.

Jain, A. K., Ross, A. ve Prabhakar, S. 2004. An introduction to biometric recognition. IEEE Transactions on Circuits and Systems for Video Technology, 14(1), 4–20. https://doi.org/10.1109/TCSVT.2003.818349

Jamal, Z. A. ve Sabir, A. T. 2026. Biometric identification under different emotions via EEG: A deep learning approach. Information, 17(3), 305. https://doi:10.3390/info17030305.

Jensen, O. ve Colgin, L. L. 2007. Cross-frequency coupling between neuronal oscillations. Trends in Cognitive Sciences, 11(7), 267–269.

Jijomon, C. M. ve Vinod, A. P. 2021. Person-identification using familiar-name auditory evo-

ked potentials from frontal EEG electrodes. Biomedical Signal Processing and Control, 68, 102739. https://doi:10.1016/j.bspc.2021.102739.

Jin, X., Yang, X., Kong, W., Zhu, L., Tang, J., Peng, Y., Ding, Y. ve Zhao, Q. 2024. TSFAN: Tensorized spatial-frequency attention network with domain adaptation for cross-session EEG-based biometric recognition. Journal of Neural Engineering, 21(4), 046005. https://doi.org/10.1088/1741-2552/ad5761

Kajikawa, Y. ve Schroeder, C. E. 2015. Generation of field potentials and modulation of their dynamics through volume integration of cortical activity. Journal of Neurophysiology, 113(1), 339–351. https://doi:10.1152/jn.00914.2013.

Kandel, E. R., Koester, J. D., Mack, S. H. ve Siegelbaum, S. A. 2021. Principles of Neural Science. 6th ed. McGraw Hill, New York.

Klimesch, W. 1999. EEG alpha and theta oscillations reflect cognitive and memory performance. Brain Research Reviews, 29, 169–195.

Klimesch, W. 2012. Alpha-band oscillations, attention, and controlled access to stored information. Trends in Cognitive Sciences, 16, 606–617.

Kralikova, I., Kukal, J., Janca, R., Kudlacek, J. ve Vyšata, O. 2022. EEG-based person identification during escalating cognitive load. Sensors, 22(19), 7154. https://doi:10.3390/s22197154.

La Rocca, D., Campisi, P., Vegso, B., Cserti, P., Kozmann, G., Babiloni, F. ve De Vico Fallani, F. 2014. Human brain distinctiveness based on EEG spectral coherence connectivity. IEEE Transactions on Biomedical Engineering, 61(9), 2406–2412. https://doi:10.1109/TBME.2014.2317889.

Lachaux, J.-P., Axmacher, N., Mormann, F., Halgren, E. ve Crone, N. E. 2012. High-frequency neural activity and human cognition: Past, present and possible future of intracranial EEG research. Progress in Neurobiology, 98(3), 279–301.

Lakens, D. 2013. Calculating and reporting effect sizes to facilitate cumulative science: A practical primer for t-tests and ANOVAs. Frontiers in Psychology, 4, 863. doi:10.3389/fpsyg.2013.00863.

Lawhern, V. J., Solon, A. J., Waytowich, N. R., Gordon, S. M., Hung, C. P. ve Lance, B. J. 2018. EEGNet: A compact convolutional neural network for EEG-based brain–computer interfaces. Journal of Neural Engineering, 15(5), 056013.

Lempel, A. ve Ziv, J. 1976. On the complexity of finite sequences. IEEE Transactions on Information Theory, 22(1), 75–81.

Lin, Y., Huang, S., Mao, J., Li, M., Haihambo, N., Wang, F., Liang, Y., Chen, W. ve Han, C. 2024. The neural oscillatory mechanism underlying human brain fingerprint recognition using a

portable EEG acquisition device. NeuroImage, 294, 120637. https://doi:10.1016/j.neuroimage.2024.120637.

Liu, H., Jin, X., Liu, D., Kong, W., Tang, J. ve Peng, Y. 2024. Affective EEG-based cross-session person identification using hierarchical graph embedding. Cognitive Neurodynamics, 18, 2897–2908. https://doi.org/10.1007/s11571-024-10132-x

Maiorana, E. 2020. Deep learning for EEG-based biometric recognition. Neurocomputing, 410, 374–386. https://doi:10.1016/j.neucom.2020.06.055.

Maiorana, E. ve Campisi, P. 2018. Longitudinal evaluation of EEG-based biometric recognition. IEEE Transactions on Information Forensics and Security, 13(5), 1123–1138. https://doi.org/10.1109/TIFS.2017.2778010

Maiorana, E., La Rocca, D. ve Campisi, P. 2016. On the permanence of EEG signals for biometric recognition. IEEE Transactions on Information Forensics and Security, 11(1), 163–175. https://doi.org/10.1109/TIFS.2015.2481870

Makeig, S., Debener, S., Onton, J. ve Delorme, A. 2004. Mining event-related brain dynamics. Trends in Cognitive Sciences, 8(5), 204–210.

Mamdani, E.H. ve Assilian, S. 1975. An experiment in linguistic synthesis with a fuzzy logic controller. International Journal of Man-Machine Studies, 7(1), 1–13.

Mao, Z., Yao, W. X. ve Huang, Y. 2017. EEG-based biometric identification with deep learning. Proceedings of the 8th International IEEE/EMBS Conference on Neural Engineering, 609–612.

Miao, Y., Yang, L., Zhang, L., Liu, W. ve Zheng, W.-L. 2023. MLDA: Multi-loss domain adaptor for cross-session and cross-emotion EEG-based individual identification. IEEE Journal of Biomedical and Health Informatics, 27(12), 5767–5778.

Mirza, M. ve Osindero, S. 2014. Conditional generative adversarial nets. arXiv preprint, arXiv:1411.1784.

Mishra, A. R., Kumar, R., Gupta, V., Prabhu, S., Upadhyay, R., Chhipa, P. C. ve diğerleri. 2024. SignEEG v1.0: Multimodal dataset with electroencephalography and hand-written signature for biometric systems. Scientific Data, 11, 718. https://doi:10.1038/s41597-024-03546-z.

Monsy, J. C. ve Vinod, A. P. 2020. EEG-based biometric identification using frequency-weighted power feature. IET Biometrics, 9, 251–258.

Muthukumaraswamy, S. D. 2013. High-frequency brain activity and muscle artifacts in MEG/EEG: A review and recommendations. Frontiers in Human Neuroscience, 7, 138.

Newson, J. J. ve Thiagarajan, T. C. 2019. EEG frequency bands in psychiatric disorders: A review of resting state studies. Frontiers in Human Neuroscience, 12, 521.

https://doi.org/10.3389/fnhum.2018.00521

Ng, M. C., Jing, J. ve Westover, M. B. 2022. A primer on EEG spectrograms. Journal of Clinical Neurophysiology, 39(3), 177–183.

Niedermeyer, E. ve Lopes da Silva, F. H. 2005. Electroencephalography: Basic Principles, Clinical Applications, and Related Fields. Lippincott Williams & Wilkins.

Nunez, P. L. ve Srinivasan, R. 2006. Electric Fields of the Brain: The Neurophysics of EEG. Oxford University Press.

Oppenheim, A. V. ve Schafer, R. W. 2010. Discrete-Time Signal Processing. 3rd ed. Pearson, New Jersey.

Özdenizci, O., Wang, Y., Koike-Akino, T. ve Erdogmus, D. 2019. Adversarial deep learning in EEG biometrics. IEEE Signal Processing Letters, 26(5), 710–714. https://doi.org/10.1109/LSP.2019.2906826

Palaniappan, R. ve Mandic, D. P. 2007. Biometrics from brain electrical activity: A machine learning approach. IEEE Transactions on Pattern Analysis and Machine Intelligence, 29(4), 738–742. https://doi:10.1109/TPAMI.2007.1013.

Palaniappan, R. ve Raveendran, P. 2002. Individual identification technique using visual evoked potential signals. Electronics Letters, 38(25), 1634–1635. https://doi:10.1049/el:20021104.

Palva, S. ve Palva, J. M. 2007. New vistas for alpha-frequency band oscillations. Trends in Neurosciences, 30(4), 150–158.

Pan, Y., Dong, J. ve Zhang, J. 2026. Efficient EEG-based person identification: A unified framework from automatic electrode selection to intent recognition. Sensors, 26(2), 687. https://doi:10.3390/s26020687.

Paranjape, R. B., Mahovsky, J., Benedicenti, L. ve Koles, Z. 2001. The electroencephalogram as a biometric. Proceedings of the Canadian Conference on Electrical and Computer Engineering, 2, 1363–1366. https://doi:10.1109/CCECE.2001.933649.

Pascual, S., Bonafonte, A. ve Serrà, J. 2017. SEGAN: Speech enhancement generative adversarial network. Proceedings of Interspeech, 3642–3646.

Pernet, C. R., Appelhoff, S., Gorgolewski, K. J., Flandin, G., Phillips, C., Delorme, A. ve Oostenveld, R. 2019. EEG-BIDS, an extension to the Brain Imaging Data Structure for electroencephalography. Scientific Data, 6, 103. https://doi.org/10.1038/s41597-019-0104-8

Pfurtscheller, G. ve Lopes da Silva, F. H. 1999. Event-related EEG/MEG synchronization and desynchronization: Basic principles. Clinical Neurophysiology, 110, 1842–1857.

Pion-Tonachini, L., Kreutz-Delgado, K. ve Makeig, S. 2019. ICLabel: An automated electroencephalographic independent component classifier, dataset, and website. NeuroImage, 198, 181–197. doi:10.1016/j.neuroimage.2019.05.026.

Plucińska, R., Jędrzejewski, K., Malinowska, U. ve Rogala, J. 2023. Leveraging multiple distinct EEG training sessions for improvement of spectral-based biometric verification results. Sensors, 23(4), 2057. https://doi:10.3390/s23042057.

Poulos, M., Rangoussi, M., Chrissikopoulos, V. ve Evangelou, A. 1999. Person identification based on parametric processing of the EEG. Proceedings of the 6th IEEE International Conference on Electronics, Circuits and Systems, 283–286. https://doi:10.1109/ICECS.1999.813403.

Powers, D. M. W. 2011. Evaluation: From precision, recall and F-measure to ROC, informedness, markedness and correlation. Journal of Machine Learning Technologies, 2(1), 37–63.

Rahman, A., Chowdhury, M. E. H., Khandakar, A., Tahir, A. M., Ibtehaz, N., Hossain, M. S., Kiranyaz, S., Malik, J., Monawwar, H. ve Kadir, M. A. 2022. Robust biometric system using session invariant multimodal EEG and keystroke dynamics by the ensemble of self-ONNs. Computers in Biology and Medicine, 142, 105238. https://doi.org/10.1016/j.compbiomed.2022.105238

Rakshe, C., Thomas, C. B., Kalathe, M., Sreeraj, V. S., Venkatasubramanian, G., Kumar, D., Prince, A. A. ve Ronickom, J. F. A. 2025. Fine-tuning EEG channel utilization for emotionally stimulated biometric authentication. IEEE Access, 13, 27537–27549. https://doi:10.1109/ACCESS.2025.3539502.

Rosso, O.A., Blanco, S., Yordanova, J., Kolev, V., Figliola, A., Schürmann, M. ve Başar, E. 2001. Wavelet entropy: A new tool for analysis of short duration brain electrical signals. Journal of Neuroscience Methods, 105(1), 65–75.

Ruiz-Blondet, M. V., Jin, Z. ve Laszlo, S. 2016. CEREBRE: A novel method for very high accuracy event-related potential biometric identification. IEEE Transactions on Information Forensics and Security, 11(7), 1614–1623. https://doi:10.1109/TIFS.2016.2543524.

Schirrmeister, R. T., Springenberg, J. T., Fiederer, L. D. J., Glasstetter, M., Eggensperger, K., Tangermann, M., Hutter, F., Burgard, W. ve Ball, T. 2017. Deep learning with convolutional neural networks for EEG decoding and visualization. Human Brain Mapping, 38(11), 5391–5420.

Seha, S. N. A. ve Hatzinakos, D. 2020. EEG-based human recognition using steady-state auditory evoked potentials. IEEE Transactions on Information Forensics and Security, 15, 4158–4171.

Seha, S. N. A. ve Hatzinakos, D. 2021. EEG-based biometric recognition using auditory steady-state responses across sessions. Proceedings of the European Signal Processing Conference (EUSIPCO).

Sokolova, M. ve Lapalme, G. 2009. A systematic analysis of performance measures for classification tasks. Information Processing & Management, 45(4), 427–437. https://doi.org/10.1016/j.ipm.2009.03.002

Splittgerber, R. 2019. Snell's Clinical Neuroanatomy. 8th ed. Wolters Kluwer, Philadelphia.

Standring, S. 2020. Gray's Anatomy: The Anatomical Basis of Clinical Practice. 42nd ed. Elsevier, London.

Stoica, P. ve Moses, R. L. 2005. Spectral Analysis of Signals. Prentice Hall, New Jersey.

Sun, Y., Lo, F. P.-W. ve Lo, B. 2019. EEG-based user identification system using 1D-convolutional long short-term memory neural networks. Expert Systems with Applications, 125, 259–267. https://doi:10.1016/j.eswa.2019.01.080.

Suppiah, R. ve Vinod, A. P. 2018. Biometric identification using single channel EEG during relaxed resting state. IET Biometrics, 7(4), 342–348. https://doi:10.1049/iet-bmt.2017.0142.

Suri, A., Wani, M. A., Jabin, S., Khan, M., Sherwani, K. I. K., Sardar, M. ve Salman, M. 2026. BMT_EEG: A novel EEG dataset for evaluating the effects of new protocols on biometric authentication systems. TechRxiv. https://doi:10.36227/techrxiv.176739740.03451854.

Taner, D. 2021. Fonksiyonel Nöroanatomi. ODTÜ Yayıncılık, Ankara.

Thomas, K. P., Vinod, A. P. ve Robinson, N. 2016. Utilizing individual alpha frequency and delta band power in EEG based biometric recognition. Proceedings of the IEEE International Conference on Systems, Man, and Cybernetics, 770–773. https://doi:10.1109/SMC.2016.7844987.

Tian, W., Li, M. ve Hu, D. 2023. Multi-band functional connectivity features fusion using multi-stream GCN for EEG biometric identification. Proceedings of the International Conference on Autonomous Unmanned Systems, 3196–3203. https://doi:10.1007/978-981-99-0479-2_294.

Tu, Y., Li, S., Chen, X. ve Wu, D. 2026. BrainprintNet: A multiscale cross-band fusion network for EEG-based brainprint recognition. IEEE Transactions on Information Forensics and Security, 21, 2757–2768. https://doi:10.1109/TIFS.2026.3672000.

Usman, M., Sultan, N., Nasim, A., Ayaz, B., Fatima, J. ve Nosheen, F. 2026. Balancing noise reduction and neural signature preservation in EEG biometrics. Scientific Reports, 16, 6674. https://doi:10.1038/s41598-026-36840-4.

Uudeberg, T., Päeske, L., Hinrikus, H., Lass, J., Põld, T. ve Bachmann, M. 2025. Individual stability of single-channel EEG measures over one year in healthy adults. Scientific Reports, 15(1), 28426. https://doi:10.1038/s41598-025-13614-y.

Wang, M., El-Fiqi, H., Hu, J. ve Abbass, H. A. 2019. Convolutional neural networks using dynamic

functional connectivity for EEG-based person identification in diverse human states. IEEE Transactions on Information Forensics and Security, 14(12), 3259–3272. https://doi:10.1109/TIFS.2019.2916403.

Wang, M., Hu, J. ve Abbass, H. A. 2020. BrainPrint: EEG biometric identification based on analyzing brain connectivity graphs. Pattern Recognition, 105, 107381. https://doi:10.1016/j.patcog.2020.107381.

Welch, P. 1967. The use of fast Fourier transform for the estimation of power spectra: A method based on time averaging over short, modified periodograms. IEEE Transactions on Audio and Electroacoustics, 15(2), 70–73. https://doi.org/10.1109/TAU.1967.1161901

Whitham, E. M., Lewis, T., Pope, K. J., Fitzgibbon, S. P., Clark, C. R., Loveless, S., Broberg, M., Wallace, A., DeLosAngeles, D. ve Willoughby, J. O. 2007. Scalp electrical recording during paralysis: Quantitative evidence that EEG frequencies above 20 Hz are contaminated by EMG. Clinical Neurophysiology, 118, 1877–1888.

Wilaiprasitporn, T., Ditthapron, A., Matchaparn, K., Tongbuasirilai, T., Banluesombatkul, N. ve Chuangsuwanich, E. 2020. Affective EEG-based person identification using the deep learning approach. IEEE Transactions on Cognitive and Developmental Systems, 12(3), 486–496.

Zadeh, L.A. 1965. Fuzzy sets. Information and Control, 8(3), 338–353.

Zhang, S., Sun, L., Mao, X., Hu, C. ve Liu, P. 2021. Review on EEG-based authentication technology. Computational Intelligence and Neuroscience, 2021, 5229576. https://doi:10.1155/2021/5229576.

Zhao, Z., Chu, H., Zheng, C., Ge, Z., Hu, B. ve Zhang, Y. 2019. EEG-based biometric identification using code-modulated visual evoked potentials. IEEE Transactions on Information Forensics and Security, 14(4), 857–870.

Zhao, Z., Zhou, N., Zhang, L., Yan, H., Xu, Y. ve Zhang, Y. 2021. EEG-based biometric identification using visual evoked potentials: Online and practical considerations. Expert Systems with Applications, 177, 114976.