

T.C.
BOLU ABANT İZZET BAYSAL ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ



**EEG SİNYALLERİ İLE BCI HECELEME SİSTEMLERİNDE
KANAL SEÇME ALGORİTMALARININ TANIMA
PERFORMANSINA ETKİSİNİN İNCELENMESİ**

YÜKSEK LİSANS TEZİ

MURAT ARICAN

BOLU, AĞUSTOS - 2019

T.C.
BOLU ABANT İZZET BAYSAL ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
ELEKTRİK ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM
DALI



EEG SİNYALLERİ İLE BCI HECELEME SİSTEMLERİNDE
KANAL SEÇME ALGORİTMALARININ TANIMA
PERFORMANSINA ETKİSİNİN İNCELENMESİ

YÜKSEK LİSANS TEZİ

MURAT ARICAN

BOLU, AĞUSTOS - 2019

KABUL VE ONAY SAYFASI

Murat ARICAN tarafından hazırlanan “EEG sinyalleri ile BCI Heceleme sistemlerinde kanal seçme algoritmalarının tanıma performansına etkisinin incelenmesi” adlı tez çalışması Elektrik Elektronik Mühendisliği Anabilim Dalı'nda 6.08.2019 tarihinde savunularak Bolu Abant İzzet Baysal Üniversitesi Fen Bilimleri Enstitüsü Yüksek Lisans Tezi olarak kabul edilmiştir.

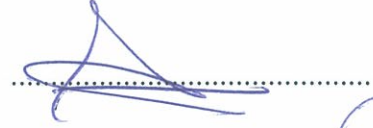
Jüri Üyeleri

Danışman
Prof. Dr. Kemal POLAT
Bolu Abant İzzet Baysal Üniversitesi

Üye
Doç. Dr. Mehmet Recep BOZKURT
Sakarya Üniversitesi

Üye
Dr. Öğr. Üyesi Alper BAYRAK
Bolu Abant İzzet Baysal Üniversitesi

İmza







Prof. Dr. Ömer ÖZYURT 

Fen Bilimleri Enstitüsü Müdürü

ETİK BEYAN

Abant İzzet Baysal Üniversitesi, Fen Bilimleri Enstitüsü Tez Yazım Kurallarına uygun olarak hazırladığım bu tez çalışmada;

- Tez içinde sunduğum verileri, bilgileri ve dokümanları akademik ve etik kurallar çerçevesinde elde ettiğimi,
- Tüm bilgi, belge, değerlendirme ve sonuçları bilimsel etik ve ahlak kurallarına uygun olarak sunduğumu,
- Tez çalışmada yararlandığım eserlerin tümüne uygun atıfta bulunarak kaynak gösterdiğimi,
- Kullanılan verilerde herhangi bir değişiklik yapmadığımı,
- Bu tezde sunduğum çalışmanın özgün olduğunu,

bildirir, aksi bir durumda aleyhime doğabilecek tüm hak kayıplarını kabullendiğimi beyan ederim.

Murat ARICAN



Eşim Ayşe'ye, Oğlum Toprak'a

Anneme ve Babama,

ÖZET

**EEG SİNYALLERİ İLE BCI HECELEME SİSTEMLERİNDE KANAL
SEÇME ALGORİTMALARININ TANIMA PERFORMANSINA
ETKİSİNİN İNCELENMESİ
YÜKSEK LİSANS TEZİ
MURAT ARICAN
BOLU ABANT İZZET BAYSAL ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
ELEKTRİK ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI
(TEZ DANIŞMANI: PROF. DR. KEMAL POLAT)**

BOLU, AĞUSTOS - 2019

Son dönemde devlet destekli yürütülen projelerle engelli bireylerin sosyal katılımları arttırılmaya çalışılmaktadır. Ancak Motor Nöron Hastalığı (MNH), Tam Sürgülü Durum (TSD) gibi bireyi tamamen hareketsiz bırakan nöromusküler hastalıklarda kişilerin iletişim becerileri bile sekteye uğramaktadır. Birkaç on yıllık geçmişi olan ve üstel bir ivmeyle çalışma sayısı artan Beyin Bilgisayar Arayüzleri (BBA), bu tür bozukluklara sahip bireylerin çevreleriyle iletişim kurmalarını sağlamak üzere geliştirilmeye çalışılmaktadır.

Heceleme sistemleri, bir ekranda bulunan harf ve rakamlardan oluşan matris içerisinde, kişinin odaklandığı karakterleri tespit ederek, uygulama aracılığıyla yazıya dönüştüren BBA sistemleridir. Bu kapsamda ekranda bulunan karakterlerin rastgele yanıp sönmeleri ile, kişiye verilen uyaran sonucunda, beyinde meydana gelen elektriksel değişimleri tespit etmeyi amaçlar. Araştırmalar, bireyin karşılaştığı uyaranın, EEG sinyalinde, P300 ismi verilen ve 250 – 500 ms arasında bir genlik oluşmasına neden olduğunu ortaya koymaktadır.

EEG sinyallerinin karmaşık yapısı bu genliğin tespitini oldukça zorlaştırmaktadır. Bu amaçla makine öğrenmesi yöntemleri kullanılarak, BBA'lar aracılığı ile tahmin işlemi gerçekleştirilmektedir. Ancak burada problem, EEG kayıtlarının uzun süreli, tekrarlı ve çok kanallı kayıt edilmesi sonucu oluşan büyük veri ve buna bağlı oluşan işlem maliyetinin yüksek olmasıdır.

Veri miktarını ve işlem maliyetini azaltmak için çeşitli yöntemler önerilmektedir. Bunlardan biri de kullanılan kanal sayısının azaltılmasıdır. Bu amaçla, en iyileme teknikleri, hangi kanalın daha verimli olduğunun matematiksel model ile tasarlanamadığı durumlarda metasezgisel yöntemleri ile devreye girmektedir.

Çalışma, 2005 yılında gerçekleştirilen BBA III Yarışması Veri Kümesi II olarak isimlendirilen veriler üzerinden gerçekleştirilmiştir.

Çalışmada metasezgisel en iyileme yöntemlerinden, genetik algoritma, ikili parçacık sürü en iyilemesi ve ikili yapay arı kolonisi ile kanal seçim işlemleri gerçekleştirilmiştir. Üç algoritma da 20 tekrar ve 30 koşum ile çalıştırılmıştır. Çalışma sonucunda seçilen kanallar, koşumlardaki seçim sayılarına göre 8 kanal, 16 kanal ve ortalama seçim sayısına göre gruplandırılmıştır.

Seçilen kanalların, Destek Vektör Makinesi (DVM), En Küçük Kareler Destek Vektör Makineleri (EKK-DVM) ve Doğrusal Ayırıcı Analizi (DAA) sınıflayıcıları ile tekil ve topluluk yapısı ile performansları incelenmiştir.

Sınıflayıcı performans analizi karmaşıklık matrisi üzerinden doğruluk, hassasiyet, kesinlik, F skor ölçümleri ile değerlendirilmiştir.

Çalışma sonucunda kanal azaltma işleminin tüm sınıflayıcılar için performans artışına neden olduğu gözlenmiştir. Özellikle doğruluk oranı düşük olan verilerde daha yüksek oranda artış olmaktadır. Kanal seçimi sonrası %97'leri geçen doğruluk oranları elde edilmiştir. Elde edilen değerler alanyazın ile paralellik göstermektedir. Metasezgisel en iyileme yöntemleri, BBA sistemlerinde kanal seçim işlemlerinde kullanılarak veri miktarının azalmasını ve buna bağlı olarak işlem maliyetinin düşmesini sağlamaktadır. Ayrıca tahmin performansını arttırmaktadır.



ANAHTAR KELİMELER: Beyin Bilgisayar Arayüzü, P300, Heceleme Sistemi, En İyileme, Genetik Algoritma, İkili Parçacık Sürü En İyilemesi, İkili Yapay Arı Kolonisi

ABSTRACT

INVESTIGATION OF THE EFFECT OF CHANNEL SELECTION ALGORITHMS ON RECOGNITION PERFORMANCE IN SPELLING SYSTEMS FROM EEG SIGNALS

MSC THESIS

MURAT ARICAN

**BOLU ABANT IZZET BAYSAL UNIVERSITY GRADUATE SCHOOL OF
NATURAL AND APPLIED SCIENCES**

**DEPARTMENT OF ELECTRICAL AND ELECTRONICS ENGINEERING
(SUPERVISOR: PROF. DR. KEMAL POLAT)**

BOLU, AUGUST 2019

In recent years, with the help of state-funded projects, it is aimed to increase the social participation of individuals with disabilities. However, even in individuals with neuromuscular diseases such as Amyotrophic Lateral Sclerosis (ALS) and Completely Locked in State (CLIS) that completely immobilize the individual, their communication skills are impaired. With several decades of history and an exponential acceleration, Brain Computer Interfaces are being developed to enable individuals with such disorders to communicate with their environment.

Speller systems are BCI systems which detect characters of the person focused in a matrix consisting of letters and numbers on a screen and convert them into writing through the application. In this context, it aims to detect electrical changes in the brain as a result of the stimulus given to the person by random flashing of the characters on the screen. Research has shown that the stimulus encountered by the individual causes an amplitude of 250 - 500 ms in the EEG signal, called P300.

The complexity of the EEG signals makes it difficult to detect this amplitude. For this purpose, machine learning methods are used for estimating through BCIs. The problem is that large data resulting from long-term, repetitive and multi-channel recording of EEG recordings and the associated processing costs are high.

Various methods are proposed to reduce the amount of data and process cost. One of these is to reduce the number of channels used. For this purpose, optimization techniques come into play with metaheuristic methods in cases where which channel is more efficient cannot be designed with mathematical model.

The study was conducted on the data called BCI III Competition Dataset II held in 2005.

In this study, channels were selected by metaheuristic optimization methods that the genetic algorithm, binary particle swarm optimization and binary artificial bee colony. All three algorithms were run with 20 iterations and 30 repetitions. At the end of the study, the selected channels were grouped according to the number of selections in the repetitions by 8 channels, 16 channels and average number of selections.

The performance of the selected channels in the singular and ensemble structure was investigated by using Support Vector Machine (SVM), Least Squares Support Vector Machine (LS-SVM) and Linear Discriminant Analysis (LDA).

The classifier performance analysis was evaluated with accuracy, sensitivity, precision, F score measurements over the complexity matrix.

As a result of the study, it has been observed that channel reduction causes performance increase for all classifiers. Especially the data with low accuracy rate increases at a higher rate. After the channel selection, accuracy rates exceeding 97% were obtained. The values obtained are in parallel with the literature. This metaheuristic methods are used in channel selection processes in BCI systems, decreasing the amount of data and consequently decreasing the transaction cost and increasing the estimation performance.



KEYWORDS: Brain Computer Interface, P300, Speller Systems, Optimization, Genetic Algorithm, Binary Particle Swarm Optimization, Binary Artificial Bee Colony

İÇİNDEKİLER

Sayfa

| | |
|--|-----------|
| ÖZET..... | v |
| ABSTRACT | vii |
| İÇİNDEKİLER | ix |
| ŞEKİL LİSTESİ..... | xi |
| ÇİZELGE LİSTESİ..... | xiii |
| KISALTMA VE SEMBOLLER LİSTESİ | xiv |
| TEŞEKKÜR | xvi |
| 1. GİRİŞ..... | 1 |
| 1.1 Elektroensefalografi | 2 |
| 1.2 Beyin-Bilgisayar Arayüzü (BBA) | 5 |
| 1.3 P300 – Olay Etkili Potansiyeller | 7 |
| 1.4 Heceleme Sistemleri..... | 8 |
| 1.5 En İyileme Algoritmaları..... | 10 |
| 1.5.1 Biyoloji Tabanlı Algoritmalar | 10 |
| 1.5.2 Sürü Tabanlı Algoritmalar | 11 |
| 1.6 Çalışmanın İçeriği | 11 |
| 2. İLGİLİ ÇALIŞMALAR..... | 13 |
| 3. MATERYAL VE YÖNTEM | 16 |
| 3.1 Veri Kümesi | 16 |
| 3.2 Ön İşleme | 18 |
| 3.2.1 Bölütleme..... | 19 |
| 3.2.1 Filtreleme | 19 |
| 3.2.2 Toplama | 20 |
| 3.2.3 Örnek Azaltma | 21 |
| 3.2.4 Topluluk Kümesinin Oluşturulması..... | 22 |
| 3.2.5 Z Skor Normalizasyonu | 24 |
| 3.3 Kanal Seçimi | 24 |
| 3.3.1 Genetik Algoritma (GA)..... | 26 |
| 3.3.2 İkili Parçacık Sürü En İyileme Algoritması (BPSE) | 28 |
| 3.3.3 İkili Yapay Arı Kolonisi Algoritması (BYAK) | 30 |
| 3.4 Sınıflama Algoritmaları..... | 33 |
| 3.4.1 Destek Vektör Makinesi (DVM) | 35 |
| 3.4.1.1 Doğrusal Ayrılan Veri Kümeleri..... | 36 |
| 3.4.1.2 Doğrusal Olarak Belirli Bir Hatayla Ayrılan Veri Kümeleri .. | 37 |
| 3.4.1.3 Doğrusal Ayrılamayan Veri Kümeleri..... | 38 |
| 3.4.2 En Küçük Kareler Destek Vektör Makinesi (EKK-DVM)..... | 39 |
| 3.4.3 Doğrusal Ayırıcı Analizi (DDA) | 40 |
| 3.4.4 Sınıflayıcı Performans Ölçütleri | 40 |
| 3.4.4.1 Doğruluk | 41 |
| 3.4.4.2 Hassasiyet..... | 41 |

| | | |
|-----------|---|-----------|
| 3.4.4.3 | Kesinlik | 41 |
| 3.4.4.4 | F Skor | 42 |
| 3.4.4.5 | Yanlış Pozitif Oranı | 42 |
| 3.4.4.6 | Güven Aralığı..... | 42 |
| 4. | BULGULAR VE TARTIŞMA | 43 |
| 4.1 | En İyileme ile Kanal Seçimi..... | 43 |
| 4.1.1 | Genetik Algoritma | 43 |
| 4.1.2 | İkili Parçacık Sürü En İyilemesi | 46 |
| 4.1.3 | İkili Yapay Arı Kolonisi | 48 |
| 4.2 | Seçilen Kanalların Performanslarının karşılaştırılması..... | 50 |
| 5. | SONUÇ VE ÖNERİLER | 62 |
| 6. | KAYNAKLAR..... | 64 |
| 7. | ÖZGEÇMİŞ | 70 |



ŞEKİL LİSTESİ

Sayfa

| | |
|--|----|
| Şekil 1.1. CZ kanalına ait örnek bir EEG Sinyali..... | 2 |
| Şekil 1.2. Beyinsel aktivitelere ait işaretlerin edinim yöntemleri..... | 3 |
| Şekil 1.3. 10-20 Elektrot Sistemi 64 Ölçüm kanalının yerleşimi ve isimleri | 3 |
| Şekil 1.4. Beyin bilgisayar arayüzü temel blok diyagramı | 5 |
| Şekil 1.5. BBA uygulamaları çeşitleri için birey kapasitesi ve veri iletim oranı ilişkisi..... | 6 |
| Şekil 1.6. P300 sinyali (Kırmızı: Hedef karakter – Yeşil: Hedef olmayan karakter)..... | 7 |
| Şekil 1.7. Satır – Sütun Paradigması 3. Satır parlama anında | 8 |
| Şekil 1.8. Tek Ekran Paradigması M harfi parlama anında | 9 |
| Şekil 1.9. Bölgesel Tabanlı Paradigma M harfi için a) Birinci ekran: Harfin bulunduğu bölge seçimi b) İkinci ekran: Seçilen bölgenin ardından M harfi için parlama anı | 9 |
| Şekil 1.10. Sezgisel Yöntemler..... | 11 |
| Şekil 3.1. Çalışmaya ait blok diyagram | 16 |
| Şekil 3.2. StimulusCode değişkeninde her bir rakama karşılı gelen satır ve sütunlar | 17 |
| Şekil 3.3. Ön işleme adımı blok şeması..... | 18 |
| Şekil 3.4. 0,1-20 Hz ChebyShev tip 1 bant geçiren filtre frekans cevabı..... | 19 |
| Şekil 3.5. E harfi için 7 numaralı sütunun parlaması sonrası Cz kanalına ait sinyaller | 20 |
| Şekil 3.6. E harfi için 12 numaralı sütunun parlaması sonrası Cz kanalına ait sinyaller | 20 |
| Şekil 3.7. Örnek azaltma işlemi özgün sinyal ve örnek azaltma sonucu elde edilen veri noktaları..... | 21 |
| Şekil 3.8. Topluluk sınıflayıcı yapısı ve çoğunluk oylama..... | 22 |
| Şekil 3.9. Uniform çaprazlama | 26 |
| Şekil 3.10. Genetik algoritma akış şeması | 27 |
| Şekil 3.11. PSE algoritması akış şeması | 29 |
| Şekil 3.12. YAK algoritması akış şeması | 31 |
| Şekil 3.12. YAK algoritması akış şeması (devam)..... | 32 |
| Şekil 3.13. Temel bileşen analizi blok şeması | 34 |
| Şekil 3.14. 10 Katlı ÇD modellemesi | 35 |
| Şekil 3.15. Doğrusal veri kümesi ve ayırıcı düzlem | 36 |
| Şekil 3.16. Doğrusal olmayan veri kümesi ve ayırıcı düzlem | 36 |
| Şekil 3.17. Karmaşıklık Matrisi | 41 |
| Şekil 4.1. GA ile Kullanıcı A ve B için elektrot yerleşimine göre seçilen kanal yoğunlukları..... | 45 |
| Şekil 4.2. BPSE ile Kullanıcı A ve B için elektrot yerleşimine göre seçilen kanal yoğunlukları..... | 46 |
| Şekil 4.3. BYAK ile Kullanıcı A ve B için elektrot yerleşimine göre seçilen kanal yoğunlukları..... | 48 |
| Şekil 4.4. Topluluk yapısı sınıflayıcılara ait θ ayrılık ölçümü..... | 52 |
| Şekil 4.5. Tekil ve topluluk yapısı sınıflayıcıların doğruluk oranları açısından karşılaştırılması..... | 58 |

| | |
|--|----|
| Şekil 4.6. Tekil ve topluluk yapısı sınıflayıcıların F Skor ölçümü açısından karşılaştırılması..... | 59 |
| Şekil 4.7. Kullanıcı A ve B için en iyileme algoritmalarının Doğruluk oranı ile karşılaştırılması..... | 59 |
| Şekil 4.8. Kullanıcı A ve B için en iyileme algoritmalarının F skor ölçümü ile karşılaştırılması..... | 60 |
| Şekil 4.9. Kullanıcı A ve B için topluluk sınıflayıcılar ile en iyileme algoritmalarının doğruluk oranı ile karşılaştırılması | 60 |
| Şekil 4.10. Kullanıcı A ve B için topluluk sınıflayıcılar ile en iyileme algoritmalarının F skor ölçümü ile karşılaştırılması | 61 |



ÇİZELGE LİSTESİ

Sayfa

| | |
|--|----|
| Çizelge 3.1. Veri kümesinde bulunan değişkenler..... | 17 |
| Çizelge 3.2. Veri Kümesinde M hedef karakteri için tek parlamada değişkenlerin durumu..... | 18 |
| Çizelge 3.3. En iyileme algoritmaları için koşum ve tekrar sayıları..... | 24 |
| Çizelge 3.4. Genetik algoritma başlangıç değişkenleri..... | 28 |
| Çizelge 3.5. BPSE Algoritması başlangıç değişkenleri..... | 30 |
| Çizelge 3.6. BYAK algoritması başlangıç değişkenleri | 30 |
| Çizelge 4.1. GA ile kanal seçim sayıları..... | 44 |
| Çizelge 4.2. GA ile ortalamanın üzerinde seçilen kanallar..... | 45 |
| Çizelge 4.3. Kullanıcı A ve B için GA ile en sık seçilen 16 kanal | 45 |
| Çizelge 4.4. BPSE ortalamanın üzerinde seçilen kanallar..... | 46 |
| Çizelge 4.5. BPSE ile kanal seçim sayıları..... | 47 |
| Çizelge 4.6. Kullanıcı A ve B için BPSE ile en sık seçilen 16 kanal | 48 |
| Çizelge 4.7. BYAK ile kanal seçim sayıları | 49 |
| Çizelge 4.8. BYAK ortalamanın üzerinde seçilen kanallar | 50 |
| Çizelge 4.9. Kullanıcı A ve B için BYAK ile en sık seçilen 16 kanal..... | 50 |
| Çizelge 4.10. Topluluk DVM sınıflayıcı için θ ayrılık ölçütleri..... | 51 |
| Çizelge 4.11. Topluluk EKK-DVM sınıflayıcı için θ ayrılık ölçütleri | 51 |
| Çizelge 4.12. Topluluk DAA sınıflayıcı için θ ayrılık ölçütleri | 51 |
| Çizelge 4.13. Kullanıcı A için DVM sınıflayıcı performans ölçümleri..... | 52 |
| Çizelge 4.14. Kullanıcı B için DVM sınıflayıcı performans ölçümleri..... | 53 |
| Çizelge 4.15. Kullanıcı A için Topluluk DVM sınıflayıcı performans ölçümleri..... | 53 |
| Çizelge 4.16. Kullanıcı B için Topluluk DVM sınıflayıcı performans ölçümleri | 54 |
| Çizelge 4.17. Kullanıcı A için EKK-DVM sınıflayıcı performans ölçümleri | 54 |
| Çizelge 4.18. Kullanıcı B için EKK-DVM sınıflayıcı performans ölçümleri | 55 |
| Çizelge 4.19. Kullanıcı A için Topluluk EKK-DVM sınıflayıcı performans ölçümleri..... | 55 |
| Çizelge 4.20. Kullanıcı B için Topluluk EKK-DVM sınıflayıcı performans ölçümleri..... | 56 |
| Çizelge 4.21. Kullanıcı A için DAA sınıflayıcı performans ölçümleri | 56 |
| Çizelge 4.22. Kullanıcı B için DAA sınıflayıcı performans ölçümleri..... | 57 |
| Çizelge 4.23. Kullanıcı A için Topluluk DAA sınıflayıcı performans ölçümleri..... | 57 |
| Çizelge 4.24. Kullanıcı B için Topluluk DAA sınıflayıcı performans ölçümleri..... | 58 |

KISALTMA VE SEMBOLLER LİSTESİ

| | |
|------------------------|--|
| BBA | : Beyin Bilgisayar Arayüzü (Brain Computer Interface – BCI) |
| BMA | : Beyin Makine Arayüzü (Brain Machine Interface – BMI) |
| BYAK | : İkili Yapay Arı Kolonisi (Binary Artificial Bee Colony – BABC) |
| BPSE | : İkili Parçacık Sürü En iyilemesi (Binary Particle Swarn Optimization – BPSO) |
| ÇD | : Çapraz Doğrulama (Cross Validation – CV) |
| DAA | : Doğrusal Ayrıcı Analizi (Linear Discriminant Analysis – LDA) |
| dB | : desiBell |
| DOĞ | : Doğruluk (Accuracy) |
| DPO | : Doğru Pozitif Oranı (True Positive Rate) |
| DVM | : Destek Vektör Makinesi (Support Vector Machine – SVM) |
| ECoG | : Elektrokortigraf |
| EEG | : Elektroensefalograf – Elektroensefalogram |
| EKK-DVM | : En Küçük Kareler Destek Vektör Makinesi (Least Square Support Vector Machine – LS-SVM) |
| ESA | : Evrişimli Sinir Ağı (Convolutional Neural Network – CNN) |
| F | : F skor |
| GA | : Genetik Algoritma (Genetic Algorithm) |
| GA₉₅ | : %95 Güven Aralığı – 95% Confidence Interval |
| GN | : Gerçek Negatif (True Negative) |
| GP | : Gerçek Pozitif (True Positive) |
| HSS | : Hassasiyet (Sensitivity) |
| Hz | : Hertz |
| KSN | : Kesinlik (Precision) |
| MEG | : Magnetoensefalograf |
| MNH | : Motor Nöron Hastalığı (Amiyotrofik Lateral Skleroz – ALS) |
| ms | : milisaniye |
| OİP | : Olay İlişkili Potansiyel (Event Related Potential – ERP) |
| OÜ | : Ortalama Üstü |
| RTF | : Radyal Temelli Fonksiyon (Radial Basis Function – RBF) |
| SS | : Sürgüleme Sendromu (Locked-in Syndrome – LIS) |
| TBA | : Temel Bileşen Analizi (Principal Component Analysis – PCA) |

| | |
|---------------|---|
| TDK | : Türk Dil Kurumu |
| TSD | : Tam Sürgülü Durum (Completely Locked-in State – CLIS) |
| YN | : Yanlış Negatif (False Negative) |
| YP | : Yanlış Pozitif (False Positive) |
| YPO | : Yanlış Pozitif Oranı (False Positive Rate) |
| μ | : Aritmetik ortalama |
| μV | : Mikrovolt (10^{-6} Volt) |
| σ | : Standart Sapma |



TEŐEKKÜR

Yüksek lisans eğitimim ve tez yazım sürecinde;

Değerli bilgilerini ve tecrübesini paylaşan, tez haricinde ulusal ve uluslararası kongrelere bildiri ve uluslararası makale yazma konusunda beni yönlendiren tez danışmanın Prof. Dr. Kemal POLAT'a,

Doğrudan veya dolaylı yardımcı olan mesai arkadaşlarıma, uzun bir aradan sonra yüksek lisans eğitimine başlayarak bizleri cesaretlendiren Berat UZUN'a, eğitim ve tez sürecinde fikir paylaşımları yaptığımız Mehmet Alper AKAY ve Yener YÜZAK'a,

Desteğini sürekli hissettiğim, yoğun çalışma dönemlerinde bana sabır gösteren ve katlanan, bildiri ve makale kabullerinde sevincimi paylaşan, yazım sürecini benden sıkı takip eden eşim Ayşe Kudu ARICAN'a,

Aramıza katılan, zaman zaman klavye ve fareyi ele geçirse de bir gülümsemesiyle evimizi neşe dolduran oğlum Toprak ARICAN'a,

Teşekkür ederim.

1. GİRİŞ

Motor nöron hastalığı (MNH) veya tam sürgülüm durum (TSD) gibi bireyi tamamen hareketsiz bırakan bedensel engellerde, birey hareket etmekte ve çevresiyle iletişim kurmakta zorluklar yaşamaktadır. Bu durumda olan bireylerin hareket etmelerini veya çevreleriyle olan iletişimini sağlamaları amacıyla beyin bilgisayar arayüzleri (BBA) bilgisayar teknolojisinin gelişmesi ile kullanılmaya başlanmıştır.

BBA'lar, bireyden alınan beyinsel aktiviteleri bu uygulama üzerinden harekete veya yazıya dönüştürmektedir. Bu amaçla beyinsel aktiviteleri görsel hale getiren yöntemlerden biri olan elektroensefalogram (EEG) sinyallerini kullanmaktadır. Elde edilen EEG sinyalleri bilgisayarlar aracılığı ile makine öğrenmesi yöntemleri kullanılarak anlamlı bilgi haline getirilirler. EEG sinyal edinimi elektrotlar aracılığı ile gerçekleştirilmektedir ve bu işlem için çok fazla sayıda elektrot kullanılmaktadır.

Elektrot sayısındaki fazlalık, kullanılan elektronik ve bilgisayar donanımın ihtiyaç duyulan kapasitesini arttırmaktadır. Bu durum hem maddi yükün hem de işlem yükünün artmasına neden olmaktadır. Dolayısı ile kullanılan sistemlerin fiziki boyutları artmakta, maliyeti de herkesin ulaşabileceği değerlerin üzerine çıkmaktadır.

Fiziki boyutları ve maliyeti azaltmak üzere kullanılan elektrot sayısında azaltma gerçekleştirilebilir. Bu aşamada temel problem hangi elektrotun daha etkin olduğunun belirlenmesidir. 64 elektrot ile gerçekleştirilen bir kayıta, aktif olan elektrotu deneme yanılma yöntemi ile seçmeye çalışırsak 10^{19} 'dan fazla ihtimalin tek tek sınanması gerekmektedir. Ancak bu durum günümüz şartlarında mümkün değildir.


Bu ve benzeri durumlarda, rastgelelik temeline dayanan en iyileme yöntemleri, denemelerini belirli bir uyum fonksiyonu çerçevesinde gerçekleştirerek, en iyi sonucu elde etmek yerine en iyiye yakın sonuçların elde edilmesini sağlarlar.

Çalışmada, metasezgisel en iyileme algoritmaları aracılığı ile standart 64 kanal EEG elektrot seti içerisinde kişiye göre en aktif elektrotlar seçilecektir. 64 kanal ile kaydedilen sinyaller ve seçilen elektrotlar üzerinden kaydedilen sinyaller, makine

öğrenmesi yöntemleri ile sınıflandırılarak tahmin başarımları karşılaştırılacaktır. Çalışma sonucunda seçilen elektrotların sınıflayıcı başarımına olumlu yönde katkı yapması beklenmektedir.

1.1 Elektroensefalografi

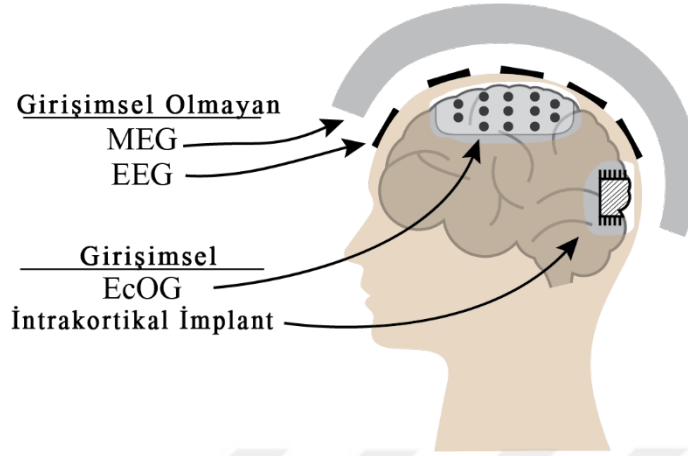
Sinir sistemi, bir ağ üzerinde, birbiri ile eşgüdümlü çalışan bölümlerden oluşmaktadır. Bu sistemin temelinde nöronlar bulunur. Bir insanın beyinde yaklaşık 100 milyar sinir hücresi bulunmaktadır. Tüm sinir sisteminde bulunan nöronlar, kendilerine ulaşan mesajı bir sonraki nörona iletmekle görevlidirler. İletim işlemi, nöron içinde ve dışında bulunan iyonların yer değiştirmesi ile başlar. Bu değişim, akson boyunca bir elektriksel potansiyelin oluşmasına neden olur. Sinir akımı veya akson potansiyeli denilen elektriksel aktivite nöron boyunca devam eder (Morris, 1996). Beyinde bulunan bu sinir hücrelerinin aktiviteleri sırasında oluşan elektriksel işaretler, ilk kez, Berger (1929) tarafından geliştirilen Elektroensefalograf ile kaydedilmiştir (Teplan, 2002). Kaydedilen bu işaretler EEG olarak isimlendirilir ve serebral korteksin çok geniş bir yüzeyi üzerinden elde edilir. Şekilsel olarak oldukça karmaşık bir yapıya sahiptir (Yazgan ve Korürek, 1996). Örnek bir EEG'ye ait grafik Şekil 1.1'de gösterilmektedir (Wolpaw vd., 2004).




Şekil 1.1. CZ kanalına ait örnek bir EEG Sinyali

Beyinsel aktiviteler, EEG'nin yanı sıra, manyetik alan yardımıyla ölçen MEG (magnetoencephalography), elektriksel işaretleri doğrudan beyin yüzeyinden alan ECoG (electrocorticography) ve doğrudan gri maddeye yerleştirilen intrakortikal implantlar ile nöro-görüntüleme modelleri ile kaydedilmektedir (Fouad vd., 2015).

Şekil 1.2’de bu görüntüleme yöntemlerine ait yerleşimler grafiksel olarak gösterilmektedir (Astrand vd., 2014).



Şekil 1.2. Beyinsel aktivitelere ait işaretlerin edinim yöntemleri



Şekil 1.3. 10-20 Elektrot Sistemi 64 Ölçüm kanalının yerleşimi ve isimleri

EEG sinyalleri çok kanallı bir doğaya sahiptir. Bir başka deyişle, bir olaya karşı beynin tek bir noktası cevap oluşturmamaktadır (Garrett vd., 2003). Bu çok kanallı yapının kayıt edilebilmesi için 10-20 elektrot yerleşim sistemi kullanılmaktadır (Gesualdi ve França, 2011; Nicolas-Alonso ve Gomez-Gil, 2012; Niedermeyer vd., 2004; Seeck vd., 2017; Teplan, 2002; Yazgan ve Korürek, 1996). 10-20 elektrot sisteminde Şekil 1.3'de gösterildiği gibi, kafa; burun tarafı nasyon, ense tarafı inyon ve kulaklar preaurikular olarak dört noktayla belirlenmiştir.

Nasyon – inyon arası ve iki preaurikular noktalarının arası ilk adım %10, sonraki adımlar %20 oranla bölümlendirilerek elektrotlar yerleştirilmiştir. Tespit edilen noktanın isimlendirilmesinde beynin ilgili bölgesinin baş harfine (Merkez – C, Temporal – T, Frontal – F, Parietal – P, Occipital – O) beynin sol lobu için tek, sağ lobu için çift rakam eklenerek isimlendirilmiştir. Bu sistem ile uluslararası bir standart sağlanmıştır. Yine Şekil 1.3'de görüldüğü gibi %20'lik adımlar, %10 – %10 olacak şekilde bölümlendirilerek 64 elektrot bağlantısı gerçekleştirilebilmektedir (Acharya vd., 2016; Seeck vd., 2017).

Elektroensefalografi ile EEG kaydı girişimsel-olmayan yöntemle gerçekleştiğinden dolayı, herhangi bir risk olmadan, tüm yaş grupları için kaydedilebilir. Araştırmalarda ve klinik uygulamalarda EEG kullanım alanları ana başlıkları;

- koma ve beyin ölümü takibi,
- kafa yaralanmaları, darbe veya tümör gibi durumlarda beynin hasar olan bölgesinin belirlenmesi,
- uyarılmış potansiyeller,
- bilişsel süreçlerin izlenmesi,
- anestezi durum takibi,
- epilepsi takibi ve nöbet bölgesinin belirlenmesi,
- uyku bozuklukları ve fizyolojisinin incelenmesi,


şeklinde sıralanabilir (Teplan, 2002). Bu çalışma, EEG kullanım alanları arasında bulunan uyarılmış potansiyeller ile çalışan BBA sistemlerini temel almaktadır.

1.2 Beyin-Bilgisayar Arayüzü

İnsan ve bilgisayar arasındaki etkileşim ilk ticari bilgisayar UNIVAC ile 1951 yılında başlamıştır. Bu makinenin kontrolü sadece IBM'in elektrikli daktilosu ile geri bildirimler ise Tektronix osiloskop ile gerçekleşmekteydi (UNIVAC I, 2018). Günümüzde ise modern bilgisayarlar, mobil özellikleri ile klavye ve fare gibi çevresel birimlerle kontrol edilebilmektedir. Bu duruma alternatif olarak İnsan-Bilgisayar arayüzleri son 20 yılda dokunma duyuları (haptics), ses ve 'dik dik' bakış (gaze) ile kullanılacak şekilde geliştirilmiştir (Cabrera, 2009).

Beyin-Bilgisayar Arayüzleri (Brain Computer Interface BCI) veya bir diğer ismiyle Beyin Makine Arayüzleri (BMA – Brain Machine Interface BMI), engelli insanların, EEG sinyalleri üzerinden üretilen kontrol sinyalleri ile kasların ve çevresel sinirlerin müdahalesi olmadan çevreleri ile etkileşime geçmelerini sağlayan sistemlerdir. Kısaca özetlersek BBA sistemleri, harici cihazların veya bilgisayarların sadece bilişsel aktiviteler ile kontrol edilebilmesine olanak vermektedirler (Hochberg vd., 2012).

BBA sistemlerinin temel amacı, MNH, beyin sapı inmesi veya omurilik yaralanması gibi nörolojik nöromusküler bozukluklarla tamamen felç olan veya "kilitli" olan ciddi engelli kişilere iletişim kabiliyeti sağlamaktır (Nicolas-Alonso ve Gomez-Gil, 2012).

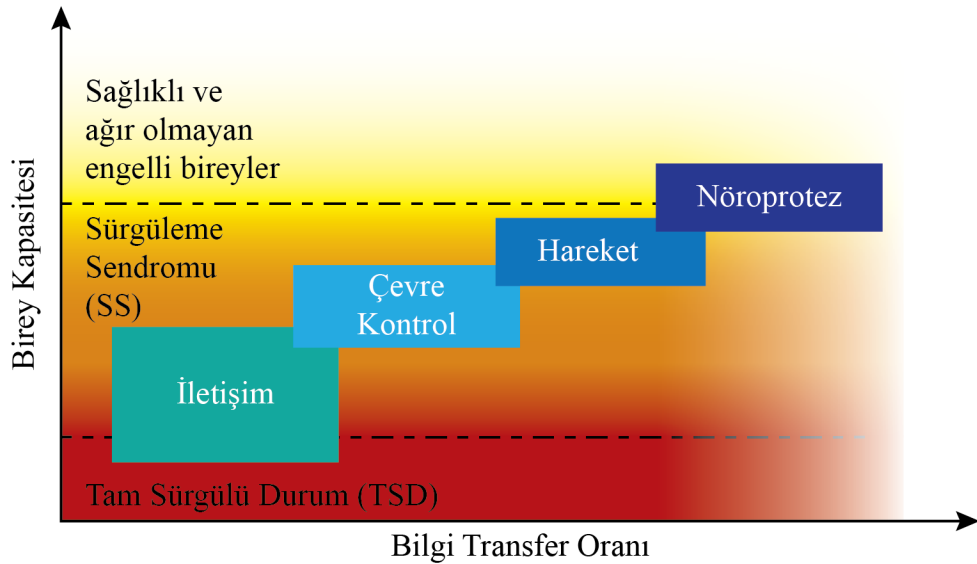


Şekil 1.4. Beyin bilgisayar arayüzü temel blok diyagramı

Şekil 1.4'te görüldüğü gibi tipik olarak bir BBA, bir dizi işlem sonrasında elde edilen EEG örüntülerinin tanımlanmasını sağlayan yapay zekâ sistemleridir (Fouad vd., 2015; Khalid vd., 2009; McFarland ve Wolpaw, 2017). Bu işlemler;

- beyin sinyallerinin yakalanmasıyla sinyal edinimi,
- sinyallerin önışlemesi veya sinyallerin geliştirilmesi (filtreleme, kuvvetlendirme, gürültü giderme vb.),
- sinyallere ait ayırt edici bilgileri tanımlayacak özneliklerin çıkartılması
- sinyallerin sınıflandırılması ve
- sınıflamaya göre sinyalin anlamlandırılıp ilgili cihazın kontrol edilmesidir.

BBA sistemleri bireylerin farklı ihtiyaçlarına yönelik olarak uygulamalar içermektedir. Nicolas ve vd.'nin (2012) yaptıkları çalışma, Chaudhary vd.'nin (2017) çalışması ile revize edilerek, BBA uygulama çeşitleri, Şekil 1.5'te verilen grafik ile gösterilmiştir. Bu grafikte x eksenini BBA sistemi için gereken bilgi aktarım oranını, y eksenini ise bireyin kapasitesini göstermektedir. Şekil 1.5'te görüleceği üzere fiziksel kapasite ile BBA sisteminin çalışma kapasitesi, arasında doğru bir orantı vardır (Kübler ve Birbaumer, 2008).



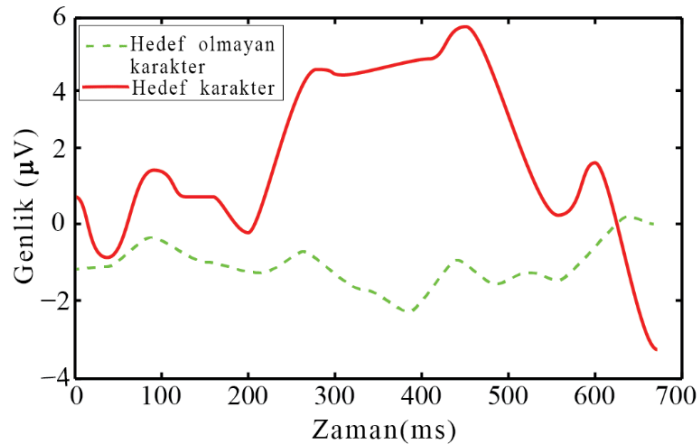
Şekil 1.5. BBA uygulamaları çeşitleri için birey kapasitesi ve veri iletim oranı ilişkisi

Nicolas vd. (2012) TSD olarak isimlendirilen ve bireyin hiçbir şekilde hareket edemediği, hiçbir kas grubunun faaliyet gösteremediği durumlarda BBA sistemlerinin

de kullanılmadığını bildirmiştir. Ancak Chaudhary vd. (2017) yaptıkları çalışmada TSD'li hastalarda Evet/Hayır şeklinde cevap alınabileceğini ortaya koymuşlardır. Sürgüleme Sendromu olarak isimlendirilen, vücudun büyük bölümünde, kas grupları hareketsiz olsa bile, yüz kaslarının bazıları ve göz hareketlerinin sağlandığı durumlarda BBA sistemleri kullanılabilir. BBA sistemleri bu çerçevede, kullanıcıya sağladığı imkânlar açısından sınıflandırıldığında, kişinin;

- çevresiyle iletişim sağlanmasını,
- çevre birimlerini kontrol edebilmesini,
- hareket edebilmesini ve
- nöroprotezleri kontrol edebilmesini sağlamaktadır.

1.3 P300 – Olay Etkili Potansiyeller



Şekil 1.6. P300 sinyali (Kırmızı: Hedef karakter – Yeşil: Hedef olmayan karakter)

EEG işaretlerinin kaydedilmesi çalışmalarında EEG kayıtlarında, ses veya görüntü gibi uyaranlara karşılık bir değişim yani bir yanıt olduğu ve bu değişimin zaman-kilitli olduğu görülmüştür (Davis, 1939; Gesualdi ve Franca, 2011; Jung vd., 2001; Luck, 2005; Sur ve Sinha, 2009). EEG sinyallerinde meydana gelen bu değişim Olay-İlişkili Potansiyel (OİP) olarak isimlendirilmektedir. EEG sinyallerinin karmaşıklığı OİP işaretlerinin bilgisayar ortamında işlenmesini geciktirmiş, ilk işlem Galambos ve Sheatz (1962) tarafından gerçekleştirilmiştir. OİP sinyalleri, uyarana karşı beyinde oluşan elektriksel aktivitenin yönüne göre pozitif (P) veya negatif (N) olarak,

milisaniye (ms) olarak da süresine göre sınıflandırılmıştır. Çalışmada kullanılan P300 sinyali, pozitif yönlü ve 300 ms’de oluşan elektriksel aktiviteyi işaret etmektedir. P300 sinyaline ait örnek Şekil 1.6’da gösterilmiştir. Kırmızı renkli gösterilen sabit çizgi, kullanıcının odaklandığı hedef karaktere ait uyarana karşı oluşan EEG sinyalini, yeşil renkli kesikli çizgi ise hedef olmayan karakter anında oluşan EEG sinyalini göstermektedir. Sinyaller incelendiğinde 250ms – 500ms arasında meydana gelen tepe rahatlıkla seçilmektedir.

1.4 Heceleme Sistemleri

BBA sistemlerinde, en az düşük düzeyde birey kapasitesi gereksinimi olan, engelli bireylerin çevresiyle iletişim kurmasını sağlayan uygulamalar heceleme sistemleridir. Heceleme sistemleri, olay ilişkili potansiyellerden P300 dalgasını temel almaktadır. Burada amaç kullanıcıya sunulan harf tablosu içerisinde kullanıcının odaklandığı harfi tespit etmektir. Heceleme sistemlerinde kullanıcıya sunulan ekran paradigma olarak isimlendirilmektedir. Şekil 1.7’de Satır – Sütun (Tek Ekran) Paradigması (Farwell ve Donchin, 1988; P300 speller paradigm, 2004), Şekil 1.8’de Tek Karakter Paradigması (Cuntai vd., 2004; Pan vd., 2013) ve Şekil 1.9 (a) ve (b)’de Bölge Tabanlı Paradigma görülmektedir (Fazel-Rezai ve Abhari, 2009; Pan vd., 2013).

Satır – sütun paradigmasında, kullanıcının odaklanması istenilen tüm harfler tek bir ekranda gösterilmektedir. Her bir satır ve sütun, her çevrimde birer kez olacak şekilde, rastgele yanıp sönmektedir.



| | | | | | |
|---|---|---|---|---|---|
| A | B | C | D | E | F |
| G | H | I | J | K | L |
| M | N | O | P | Q | R |
| S | T | U | V | W | X |
| Y | Z | 1 | 2 | 3 | 4 |
| 5 | 6 | 7 | 8 | 9 | - |

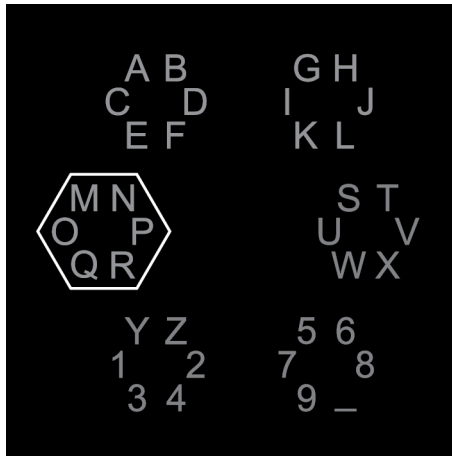
Şekil 1.7. Satır – Sütun Paradigması 3. Satır parlama anında

Tek karakter paradigmasında da satır – sütun paradigmasında olduğu gibi kullanıcının odaklanması istenilen tüm harfler tek bir ekranda gösterilmektedir. Bu harflerin her biri birer kez olacak şekilde, rastgele yanıp sönmektedir.




Şekil 1.8. Tek Karakter Paradigması M harfi parlama anında

Bölgesel tabanlı paradigma ise iki ekrandan oluşmaktadır. Birinci ekranda tüm harfler gruplar halinde ekranda bulunmaktadır. Bu aşamada kullanıcıdan odaklandığı harfin bulunduğu grubun seçimi gerçekleştirilir. Seçimin ardından, grupta bulunan harfler yer alacak şekilde ikinci ekran oluşur ve burada kullanıcının odaklandığı harfin tahmin edilmesi gerçekleştirilir.



(a)



(b)

Şekil 1.9. Bölgesel Tabanlı Paradigma M harfi için a) Birinci ekran: Harfin bulunduğu bölge seçimi b) İkinci ekran: Seçilen bölgenin ardından M harfi için parlama anı

1.5 En İyileme Algoritmaları

En iyileme TDK (2019) tarafından “en uygun duruma getirmek” olarak tanımlanmaktadır. Matematiksel olarak, uyum fonksiyonu tanımlanan bir aralıkta değişkenlerin en iyi değerlerini bulmaktır (Kaya ve Fıđlalı, 2016).

Uyum fonksiyonunda bulunan karar deđiřken türleri en iyileme probleminin türlerini sınıflandırmada kullanılan kıstaslardan bir tanesidir. Eđer deđiřkenler sürekli (reel) deđerler ise sürekli en iyileme problemi, tam sayı ise kesikli en iyileme problemi, sonlu sayıda ayırık deđere sahipse karıřık tam sayı (kombinatoryal) en iyileme problemi, ikili deđere sahipse ikili en iyileme problemi olarak sınıflandırılabilir. En iyileme problemleri uyum fonksiyonundan beklenen sonuçlara göre en küçükleme (minimizasyon) veya en büyükleme (maksimizasyon) problemi olarak iki grupta incelenebilir (Arora, 2016; Kaya ve Fıđlalı, 2016; Rao, 2009).

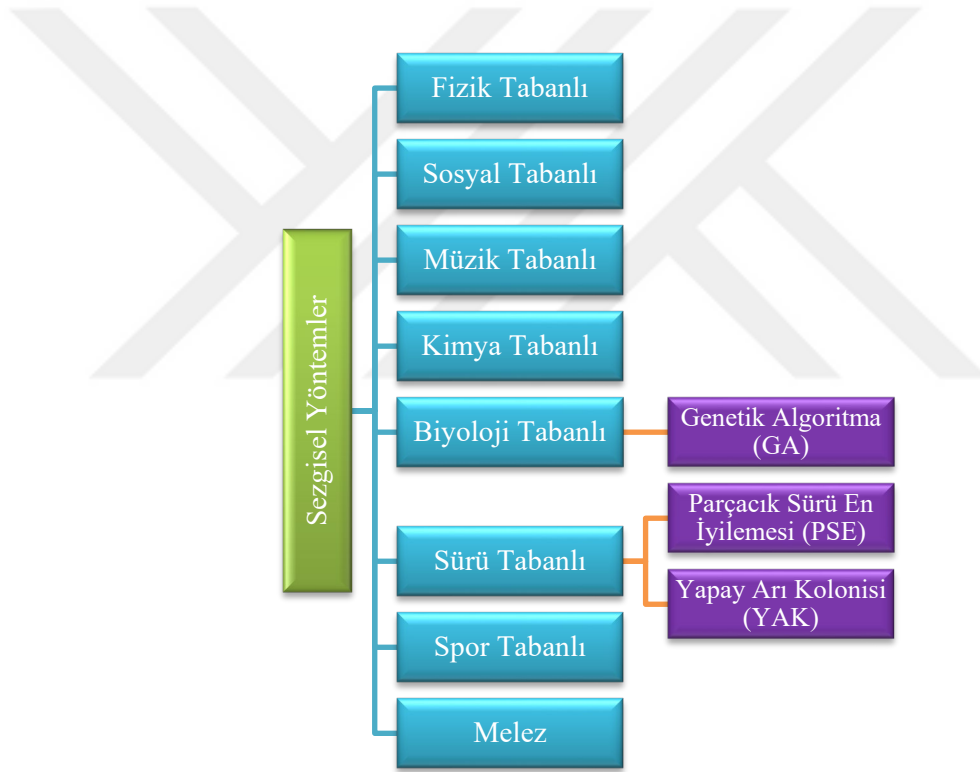
Problemin karmařık olduđu durumlarda en iyi çözümleri bulmak mümkün olamayabilir. Bu durumlarda sezgisel yöntemler kullanılarak en iyiye en yakın sonuçlar elde edilmesi amaçlanır. Sezgisel yöntemler, belirli bir problemi çözmek için kullanılırken, daha geneli kapsayan çözümleri üretmek amacıyla meta sezgisel yöntemler kullanılmaktadır. Meta sezgisel algoritmalar, dođadaki olayların gözlemlenerek ortaya konması ile oluşturulmaktadır. Ancak en iyi yakınsamasının ispatı mümkün deđildir ve kesin çözümleri garanti etmezler. Sezgisel yöntemler Şekil 1.10’da gösterilmiřtir (Akyol ve Alatař, 2012; Bingöl ve Alatař, 2015).

1.5.1 Biyoloji Tabanlı Algoritmalar

İnsan ve benzeri canlıların vücutlarında meydana gelen biyolojik olayları temel alan meta sezgisel en iyileme yöntemleridir. Gen oluşumunu örnek alan Genetik Algoritma, sinir ađlarının çalışmasını model alan Yapay Sinir Ađları ve vücudun savunma mekanizmasını örnek alan Yapay Bađışıklık sistemi gibi farklı türleri bulunmaktadır (Engin ve Döyen, 2004).

1.5.2 Sürü Tabanlı Algoritmalar

Sürü genel anlamda “birlikte yaşayan hayvan topluluğu” olarak tanımlanmaktadır (Türk Dil Kurumu, 2019). Sürülerde bireyler ortak bir amacı gerçekleştirmek üzere ortak bir hareket tarzı benimserler. Bu hareket tarzı bireyler tarafından sürü içerisinde sürekli olarak tekrarlanır. Bu bireysel davranışların yanı sıra sürü içerisinde bilgi paylaşımı da söz konusudur. Parçacık Sürü En İyilemesi, Yapay Arı Kolonisi, Ateş Böceği Algoritması, Karınca Koloni Algoritması sürü tabanlı algoritma örneklerindedir.



Şekil 1.10. Sezgisel Yöntemler

1.6 Çalışmanın İçeriği

Çalışmada, bir beyin bilgisayar ara yüzü olan, satır – sütun paradigması kullanan heceleme sistemi üzerinden kaydedilen EEG sinyalleri aracılığı ile, hedef karakter tespitinde kullanılan P300 dalgalarının makine öğrenmesi yöntemleri ile

tespitinde, EEG elektrotlarının seçiminde en iyileme yöntemlerinin kullanımı ve kullanılan yöntemlerin performansa olan etkilerinin araştırılması amaçlanmıştır.

Bu kapsamdan Bölüm 2’de alanyazın taraması ile alanda yapılan çalışmalar incelenmiş, Bölüm 3’te kullanılan materyaller ve yöntemler açıklanmıştır. Bölüm 4’te çalışma sırasında elde edilen bulgular aktarılmıştır. Bölüm 5’te elde edilen sonuçlar alanda yapılan çalışmalar ışığında değerlendirilerek çalışma sonlandırılmıştır.



2. İLGİLİ ÇALIŞMALAR

BBA sistemleri, heceleme sistemlerinde kanal seçimi ve çalışmada kullandığımız Wadsworth BCI Dataset (Wolpaw vd., 2004) veri kümesi ile yapılan çalışmalar taranmıştır.

Rakotomamonjy ve Guigue (2008), yarışma kapsamında gerçekleştirdikleri çalışma ile yarışmanın birincisi olmuşlardır. Çalışmalarında EEG sinyalleri üzerinden öznitelik çıkartma yerine EEG sinyallerinde örnek azaltma işlemi uygulamışlardır. Çalışmada öz yinelemeli kanal seçim yöntemi kullanılmış ve kanal sayısı 8'e düşürülmüştür. Sınıflayıcı olarak topluluk yapısında Destek Vektör Makinesi (DVM) kullanmışlardır. Yarışmayı kazanan çalışma önerdiği yöntem ile alanyazında sıklıkla tekrarlanmıştır. Çalışma sonucunda %96,5 doğruluk oranı bildirmişlerdir.

Wang vd. (2010) gerçekleştirdikleri çalışmada, dalgacık dönüşümü ile kanal seçimi gerçekleştirmiş ve 10 kanala düşürmüşler, sınıflama işleminde Fisher mesafesi kullanmışlardır. Çalışma sonucunda %85 bir doğruluk oranı bildirmişlerdir. Aynı veri kümesini kullanan çalışmalar kıyaslandığında oldukça düşük bir orana sahiptir.

Jin vd. (2010) çalışmalarında PSE ile kanal seçim işlemini gerçekleştirmişlerdir. Veri kümesi olarak 4*4'lük Çince telefon klavyesi şeklinde bir paradigma üzerinden kaydedilen 30 kanal EEG verileri kullanılmıştır. Sınıflayıcı olarak Bayes DAA kullanılmıştır. Çalışmada seçilen kanallarda %100 doğruluk oranı bildirilmiştir.

Cecotti ve Gräser (2011) çalışmalarında herhangi bir kanal seçme işlemi gerçekleştirmeden 64 kanal üzerinden sınıflama işlemini evrişimli sinir ağı (ESA) ile gerçekleştirmişlerdir. Çalışma sonucunda %95,5 doğruluk oranı bildirmişlerdir.

BBA'lar üzerine yapılan çalışmalar birkaç on yıl önce başlamış ve günümüze kadar gelen süreçte yüksek bir ivme kazanmıştır. Nörogörüntüleme yöntemleri, öznitelik çıkartımı için sinyal işleme yöntemleri, artifakt yok etme yöntemleri,

sınıflama işlemleri ve BBA uygulamaları alanında devam etmektedir (Nicolas-Alonso ve Gomez-Gil, 2012).

Gonzalez vd. (2014) gerçekleştirdikleri çalışmada ses ile uyarı verilen bir veri kümesi üzerinden P300 sinyallerini tespit etmeyi amaçlamıştır. Bu kapsamda Parçacık Sürü En İyilemesi (PSE) algoritması ile kanal seçimi gerçekleştirmiştir. Seçilen kanallar isim isim verilmeden sadece topolojik çizim olarak aktarılmıştır. Hem standart 64 kanal ile hem de PSE sonucunda belirlenen 5 kanal ile benzer şekilde yaklaşık %95 doğruluk oranı bildirmişlerdir.

Çalışmanın konusu olan kanal (elektrot) seçimi BBA sistemlerinin ilk adımı olan beyinsel aktivitelerin kayıt altına alındığı nörogörüntüleme kısmında bulunmaktadır. Alotaiby vd. (2015) yaptıkları inceleme çalışmasında kanal seçme yöntemlerini farklı BBA uygulamaları için vermiştir. Heceleme sistemleri gibi zihinsel görevler barındıran BBA sistemlerinde sadece filtreleme teknikleri ve sargı (wrapper) tekniklerinden bahsetmektedir. Ancak bu çalışmada, sezgisel yöntemlerden bahsedilmemektedir. Günümüzde, meta sezgisel yöntemleri kullanarak gerçekleştirilen çalışmalar alanyazında yerini almaya başlamıştır.

Xiaofeng vd. (2015) çalışmasında Bagging DVM yöntemini kullanmıştır. Çalışmasında kullanılan kanal sayısı hakkında bilgi yer almamaktadır. Çalışmada asıl odaklanılan nokta veri kümesinde bulunan dengesizlik probleminin çözülerek sınıflama işleminin gerçekleştirilmesidir. Çalışma sonucunda %96,7 doğruluk oranı bildirmişlerdir.

Kee vd. (2015) çalışmasında BBA yarışmasında kullanılan üç ayrı data seti kullanmışlardır. Genetik Algoritma (GA) ile kanal seçimini, Bayes DAA ile de sınıflama işlemini gerçekleştirmişlerdir. Wadsworth BCI Dataset üzerinde gerçekleştirilen kanal seçme işlemleri sonucunda ortalama 22,3 kanal seçilirken doğruluk oranı ortalama %93,6 olarak bildirilmiştir.

Fira ve Goras (2016) da çalışmalarını 64 kanal ve sözlük sıkıştırma algoritması üzerinden çalışmasını gerçekleştirmiştir. Çalışma sonucunda %90 doğruluk oranı bildirmişlerdir.

Londhe ve Ghosh (2016), çalışmalarında Devanagari alfabesi üzerinde çalışan heceleme sistemini kullanmışlardır. Oluşturulan kayıtlar üzerinde Farksal Evrim (FE) algoritması uygulayarak kanal seçim işlemini gerçekleştirmişlerdir. Sınıflayıcı olarak Ağırlıklandırılmış Topluluk Yapılı DVM kullanmışlardır. Ortalama 28.9 kanal seçilen çalışmada %94,2 doğruluk oranı bildirmişlerdir.

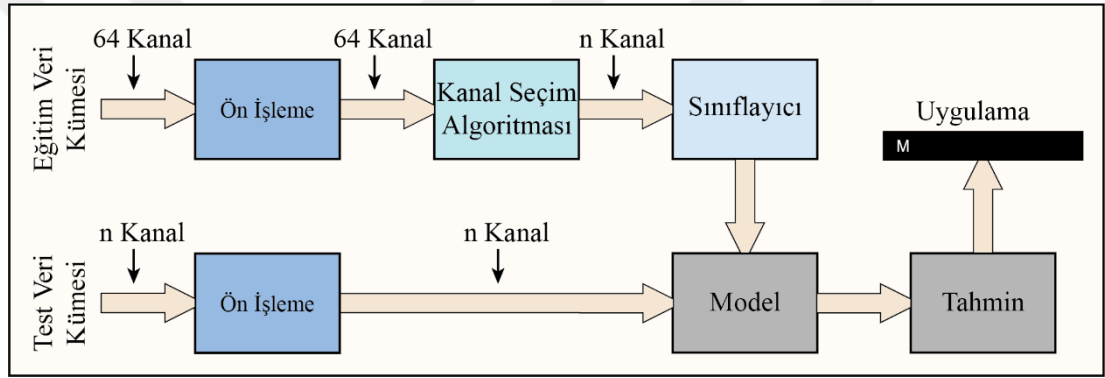
Kundu ve Ari (2017) çalışmalarını 64 kanal üzerinden Temel Bileşen Analizi (TBA) ve ağırlıklandırılmış topluluk yapılı DVM ile gerçekleştirmişlerdir. Çalışma sonucunda %98 doğruluk oranı bildirmişlerdir.

Martínez-Cagigal ve Hornero (2017) gerçekleştirdikleri çalışmada Wadsworth BCI Dataset kullanılmıştır. Çalışmalarında, sezgisel en iyileme algoritmalarından PSE, Arı Algoritması (AA), Yapay Arı Kolonisi (YAK) ve Ateş Böceği Algoritması'na yer vermişlerdir. YAK algoritmasında Kullanıcı A için 25 kanal ile %94, Kullanıcı B için 24 kanal ile %93 doğruluk oranı bildirmişlerdir. PSE algoritmasında ise Kullanıcı A için yine 25 kanal seçilmiş %95 doğruluk oranı, Kullanıcı B içinse 17 kanal ile %92 doğruluk oranı bildirilmiştir. Sınıflayıcı olarak DAA kullanılmıştır.

Kog vd. (2018) çalışmalarını yine 64 kanal üzerinden gerçekleştirmiştir. Sınıflayıcı olarak da, TBA ve ağırlıklandırılmış aşırı öğrenme makinesini kullanmışlardır. En yüksek %98 doğruluk oranı bildirmişlerdir.

3. MATERYAL VE YÖNTEM

Çalışmaya ait blok diyagram Şekil 3.1’de gösterilmiştir. Sisteme 85 harf ve 64 kanal kayıttan oluşan EEG sinyalleri uygulanmıştır. Bu sinyallere öncelikle ön işleme uygulanmış daha sonra en iyileme algoritmaları ile performansı en yüksek olan kanallar tespit edilmiş ve bu kanallar ile sistemin eğitimi gerçekleştirilmiştir. İkinci safhada ise 100 harf ve tespit edilen kanallara göre yeniden oluşturulmuş test veri kümesi ön işlemeden geçirildikten sonra eğitim işlemi sonrasında üretilen modele uygulanmış ve odaklanılan harf tahmini gerçekleştirilmiştir.



Şekil 3.1. Çalışmaya ait blok diyagram

3.1 Veri Kümesi

Çalışmada BCI Competition III Challenge 2004’te Dataset II adı ile kullanılan Wadsworth BCI Dataset (P300 Evoked Potentials) isimli veri kümesi kullanılmıştır (Wolpaw vd., 2004). Veri kümesi, Farwell ve Donchin (1988) tarafından ortaya konan ve Donchin vd. (2000) tarafından geliştirilen paradigma kullanılarak BCI2000 (2018) ile kaydedilen P300 uyarılmış potansiyel kayıtlarından oluşmaktadır.

6*6’lık matris yapısına sahip satır-sütun paradigması kullanılarak (bkz. Şekil 1.7) iki ayrı kullanıcıdan eğitim için 85 farklı karakter ve test için farklı 100 karakter 15 tekrarla kaydedilmiştir. Kayıtlar 240 Hz örnekleme frekansı ile 64 kanal olarak gerçekleştirilmiştir. Kayıt sırasında 0,1 Hz – 60 Hz’lik bant geçiren filtre uygulanmıştır. Yayınlanan veri kümesi; her bir kullanıcı için eğitim ve test verilerinden oluşmaktadır.

Hem eğitim hem de test veri kümelerinin içerisinde; 64 kanal EEG sinyalini barındıran “Signal”, paradigma üzerinde harfin parlama anını gösteren “Flashing” ve hangi karakterin parladığını, satır ve sütun numarasını vererek belirten “StimulusCode” değişkenleri bulunmaktadır. Ayrıca eğitim veri kümesinde hedef karakterleri etiketleyen “StimulusType” ve hedef karakteri gösteren “TargetChar” değişkenleri bulunmaktadır. Veri kümesinde bulunan değişkenler Çizelge 3.1’de verilmiştir.

Çizelge 3.1. Veri kümesinde bulunan değişkenler

| Değişken | Açıklama | Eğitim | Test |
|--------------|--------------------------------------|--------|------|
| Signal | 64 Kanal EEG sinyali | ● | ● |
| Flashing | Parlama durumu | ● | ● |
| StimulusCode | Parlayan satır veya sütun numarası | ● | ● |
| StimulusType | Hedef/hedef olmayan karakter etiketi | ● | ○ |
| TargetChar | Hedef karakter | ● | ○ |

●: Mevcut ○: Mevcut Değil

| | | | | | | |
|-------------|----------|----------|----------|----------|----------|----------|
| | 1 | 2 | 3 | 4 | 5 | 6 |
| | ↓ | ↓ | ↓ | ↓ | ↓ | ↓ |
| 7 → | A | B | C | D | E | F |
| 8 → | G | H | I | J | K | L |
| 9 → | M | N | O | P | Q | R |
| 10 → | S | T | U | V | W | X |
| 11 → | Y | Z | 1 | 2 | 3 | 4 |
| 12 → | 5 | 6 | 7 | 8 | 9 | – |

Şekil 3.2. StimulusCode değişkeninde her bir sayıya karşılık gelen satır ve sütunlar

Test veri kümesinin hedef karakterleri yarışmanın sona ermesinin ardından yayınlamıştır. Paradigmada, rastgele olacak şekilde satırlardan veya sütunlardan biri 100 ms süreyle parladıktan sonra, 75 ms süreyle tüm ekran kararmaktadır. Bir harf için geçen süre $(100 + 75) * 12 = 2100$ ms’dir. 15 tekrarla bu süre 31500 ms’dir. Bir harf için tek bir kanalda 7560 örnek bulunmaktadır.

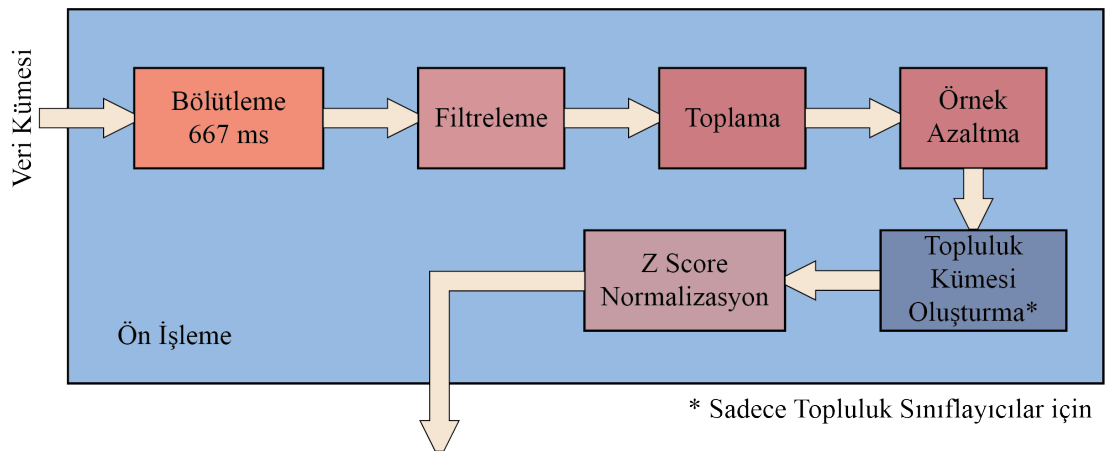
Şekil 3.2’de StimulusCode değişkeninde bulunan sayıların temsil ettiği satır ve sütunlar gösterilmiştir.

Çizelge 3.2. Veri Kümesinde M hedef karakteri için tek parlamada değişkenlerin durumu

| Veri Noktası | 1-24 | 25-42 | 43-66 | 67-84 | 85-108 | 109-126 | 127-150 | 151-168 |
|--------------|---------|---------|---------|---------|---------|---------|---------|---------|
| Flashing | 1 | 0 | 1 | 0 | 1 | 0 | 1 | 0 |
| StimulusCode | 2 | 0 | 9 | 0 | 10 | 0 | 5 | 0 |
| StimulusType | 0 | 0 | 1 | 0 | 0 | 0 | 0 | 0 |
| Veri Noktası | 169-192 | 193-210 | 211-234 | 235-252 | 253-276 | 277-294 | 295-318 | 319-336 |
| Flashing | 1 | 0 | 1 | 0 | 1 | 0 | 1 | 0 |
| StimulusCode | 3 | 0 | 8 | 0 | 12 | 0 | 4 | 0 |
| StimulusType | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 |
| Veri Noktası | 337-360 | 361-378 | 379-402 | 403-420 | 421-444 | 445-462 | 463-486 | 487-504 |
| Flashing | 1 | 0 | 1 | 0 | 1 | 0 | 1 | 0 |
| StimulusCode | 6 | 0 | 11 | 0 | 7 | 0 | 1 | 0 |
| StimulusType | 0 | 0 | 0 | 0 | 0 | 0 | 1 | 0 |

Çizelge 3.2’de ise M hedef harfi için yapılan kayıt sırasında değişkenlerin durumu gösterilmektedir. 100 ms parlama süresine karşılık gelen her bir 24 veri uzunluğunda rastgele bir satır veya sütun parlamaktadır. Bu anlar Flashing değişkeninde 1 ile işaretlenmiştir. Bunu takip eden, her 75 ms sönme süresine karşılık gelen 18 veri uzunluğunda ise Flashing değişkeni 0 ile işaretlenmektedir. Bu işlemler sırasında, örneğin, hedef karakter M olduğunda, Şekil 3.2’de gösterildiği gibi, 1 numaralı sütun ve 9 numaralı satır parladığı anda StimulusType değişkeni 1 ile geri kalan durumlarda 0 ile etiketlenmektedir.

3.2 Ön İşleme



Şekil 3.3. Ön işleme adımı blok şeması

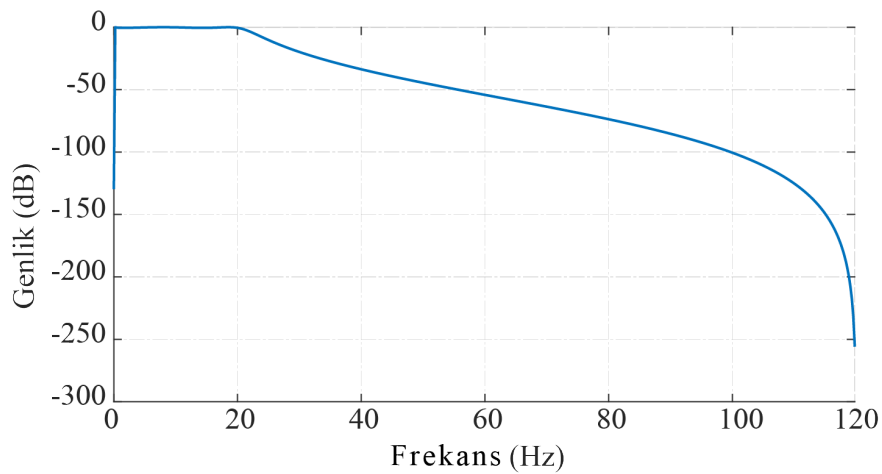
Şekil 3.3'de ön işleme adımlarını gösterir blok diyagram verilmiştir. Veri kümesinden alınan sinyal sırası ile bölütleme, filtreleme, toplama, örnek azaltımı, topluluk kümesi oluşturma (sadece topluluk temelli sınıflayıcılarda bu adım kullanılmaktadır) ve Z-skor normalizasyonudur. Bu işlemlerin ardından eğitim veri kümesi sınıflayıcıya, test veri kümesi ise oluşturulan modellere uygulanmaktadır (Rakotomamonjy ve Guigue, 2008).

3.2.1 Bölütleme

Bölütleme ya da bir başka deyişle pencereleme; EEG sinyali gibi durağan olmayan sinyalleri daha küçük parçalara bölerek durağan kabul edilebilecek sinyaller elde edilmesini sağlar. Bu kapsamda, kaydedilen EEG sinyalleri, her bir parlamayla başlayacak şekilde, ilk parlamanın meydana geldiği andan itibaren 667 ms'lik pencerelere ayrılmıştır. Burada sürenin belirlenmesinde P300 dalgalarının 250-500 ms arasında oluşması temel alınmıştır. Bu sayede, eğer oluşmuş bir P300 dalgası var ise tamamı elde edilen pencere içerisinde yer alacaktır.

Bölütleme sonucunda bir harf için her bir kanalda; 7560 uzunluğuna sahip bir vektör olan verimiz, 180 satır (15 tekrarda 12'şer parlama) ve 160 sütundan oluşan bir matris halini almıştır.


3.2.1 Filtreleme




Şekil 3.4. 0,1-20 Hz Chebyshev tip 1 bant geçiren filtre frekans cevabı

P300 dalgası tüm EEG bandı içerisinde düşük frekanslı bir bileşendir. Bu bileşeni daha net ortaya koyup, diğer bileşenleri uzaklaştırmak amacı ile filtreleme işlemi uygulanır. Bu amaçla, çalışmada, alt kesim frekansı 0,1 Hz, üst kesim frekansı 20 Hz olan Chebyshev tip 1 bant geçiren filtre kullanılmıştır. Kullanılan filtreye ait frekans cevabı Şekil 3.4’de gösterilmiştir.

3.2.2 Toplama



Şekil 3.5. E harfi için 7 numaralı satırın parlaması sonrası Cz kanalına ait sinyaller



Şekil 3.6. E harfi için 12 numaralı satırın parlaması sonrası Cz kanalına ait sinyaller

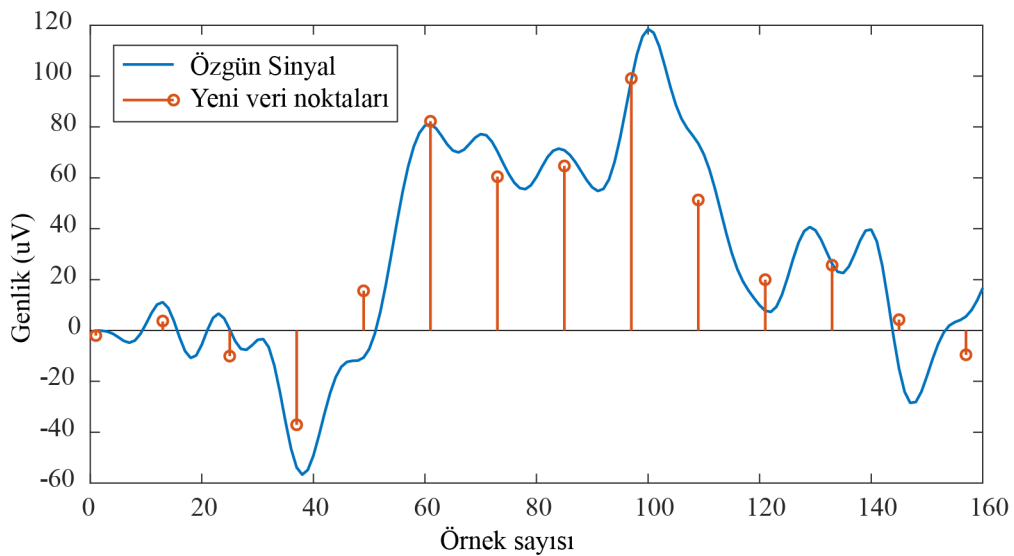
Filtreleme işlemini takiben, P300 dalgasını yükseltmek, diğer bileşenleri zayıflatmak amacı ile toplama işlemi gerçekleştirilmiştir. Burada, on beş tekrar için aynı kanala ait veriler matematiksel olarak toplanmıştır.

Şekil 3.5’de hedef karakterin bulunduğu 7 numaralı satırın, Şekil 3.6’de ise hedef olmayan bir karakterlerin bulunduğu 12 numaralı satırın parlamasını müteakip oluşan beyin aktivitesi, 15 tekrar ve kalın yeşil çizgi ile gösterilen toplam sinyal için ayrı ayrı gösterilmiştir. Her iki şekilde de 15 tekrar sırasında ayırt edici bir formdan söz etmek mümkün değilken, toplam sinyallerinde bu fark açıkça görülmektedir.

3.2.3 Örnek Azaltma

Çalışmada, veri boyutunun azaltılması amacı ile örnek azaltma işlemi (decimation) uygulanmıştır. Örnek azaltma işlemi girişe uygulanan sinyali, belirlenen bir r faktörü ile indirger. Giriş sinyali “x”, çıkış sinyali “y”, indirgeme faktörü “r” ise, çıkışta elde edilen y sinyalinin uzunluğu Denklem 3.1 ile hesaplanır (The MathWorks, Inc., 2019). Örnek azaltma işlemi sırasında verinin değişimi yönünün ve hızının da hesaba katılması amacı ile alçak geçiren filtre uygulanmıştır.

$$uzunluk(y) = yukarıyuvarla\left(\frac{uzunluk(x)}{r}\right) \quad (3.1)$$

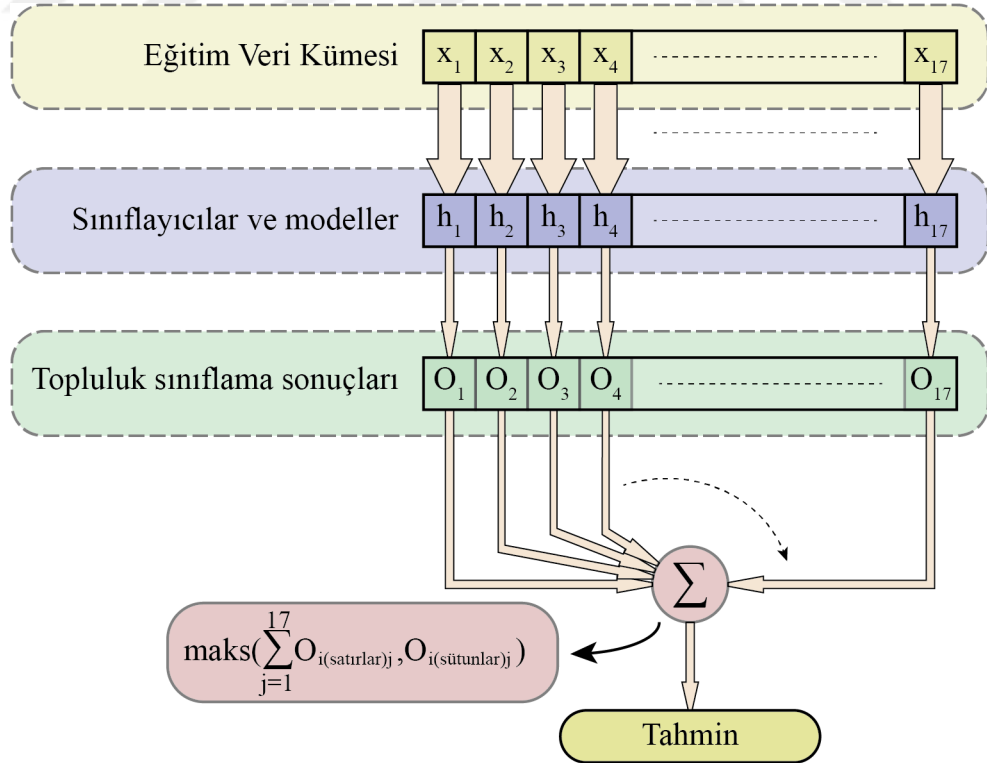


Şekil 3.7. Örnek azaltma işlemi özgün sinyal ve örnek azaltma sonucu elde edilen veri noktaları

667 ms pencere uzunluğu için 160 veri noktasına sahip veri, 14 veri noktasına azaltılmıştır. P300 dalgası, sinyalin zaman uzayındaki şekilsel formuyla ilgilidir. Buna bağlı olarak, örnek azaltma işlemi, sinyal içerisinde örnekler alarak, şekilsel formu hakkında özet bir bilgi elde etmemizi sağlamaktadır. Şekil 3.7’de hedef karakterin bulunduğu 7 numaralı satır için tüm pencereye ait sinyal ve örnek azaltımı sonucunda elde edilmiş sinyal birlikte verilmiştir. Şekilde de görüleceği üzere örnek azaltma işlemi sonucunda elde edilen veri noktaları sinyalin genel formunu vermektedir.

3.2.4 Topluluk Kümesinin Oluşturulması

Sınıflayıcı başarımını artırmak için kullanılan yöntemlerden bir tanesidir. Tüm veri kümesi içerisinde yeni veri alt kümeleri elde edilmesi prensibine dayanmaktadır. Her alt küme sınıflayıcı ile eğitilerek her küme için bir model oluşturulur. Tüm modellerin sonuçları birleştirilerek nihai karar verilir. Topluluk algoritmalarının başarısı iki değişken ile ölçülebilir. Bunlardan birincisi doğruluk (accuracy), ikincisi ise ayrıklıktır (diversity) (Kuncheva ve Whitaker, 2003; Tang vd., 2006).



Şekil 3.8. Topluluk sınıflayıcı yapısı ve çoğunluk oylama

Çalışmada, Şekil 3.8’de verilen model kullanılarak, 85 harften oluşan eğitim veri kümesinin beşer harfli bloklara ayrılması sonucu 17 alt veri kümesi elde edilmiştir. 17 ayrı modelden elde edilen tahmin sonuçları çoğunluk oylaması sonucu nihai sonuçlar elde edilmiştir. Şekilde alt küme x ile $(\{x_1, x_2, \dots, x_{17}\})$, bu alt kümeye ait sınıflayıcı ise h ile $(\{h_1, h_2, \dots, h_{17}\})$ ifade edilmiştir.

Topluluk yapısının ayrıklık oranının hesaplanmasında ikili olmayan ayrıklık ölçümlerinden zorluk (difficulty) θ ölçümü olarak isimlendirilen ayrıklık ölçüm yöntemi kullanılmıştır. Bu yöntem Hansen ve Salamon’un (1990) çalışmalarından ortaya çıkmıştır. V ile tanımlanan ayırık bir veri seti içerisinde örnek seçilen her bir alt küme için Denklem 3.2 ile hesaplanan V_i değerlerinin varyansının (Denklem 3.3) hesaplanması ile bulunur. Zorluk θ ölçümünde ölçülen değer ne kadar küçükse ayrıklık o kadar yüksektir. İdealde sıfır olması beklenirken gerçekte mümkün değildir.

$$V_i = \frac{L - l_i}{L} \quad (3.2)$$

$$\theta = \frac{1}{N - 1} \sum_{i=1}^N |V_i - \mu|^2 \quad (3.3)$$

Burada L grup yapısını oluşturan sınıflayıcı sayısı, l_i sınıflayıcıların eğitim veri kümesini sınıflandırması sonucunda oluşan ağırlıklardır. Denklem 3.3’te N topluluk sayısı, μ ise V_i ’lerin aritmetik ortalamasıdır. Denklem 3.4’te O matrisi topluluk sınıflayıcılara ait tahmin uzayıdır. O_{ij} matrisinde, sütunlar her bir sınıflayıcıyı, satırlar ise o sınıflayıcıya ait gözlem sonuçlarını temsil etmektedir. O_{ij} matrisi sınıflayıcı tahmini doğru ise 1, yanlış ise -1 ile işaretlenmiştir. w_j her bir sınıflayıcının ağırlığı olup çalışmada tüm h_j sınıflayıcıları için $1/L$ olarak eşit seçilmiştir (Kuncheva ve Whitaker, 2003; Tang vd., 2006).

$$O_{ij} = \begin{cases} 1, & x_i \text{ alt veri kümesi için } h_j \text{ sınıflayıcı sonucu doğru ise} \\ -1, & \text{diğer durumlarda} \end{cases}$$

$$l_i = L \sum_{O_{ij}=-1} w_j \quad (3.4)$$

Topluluk yapısı ile elde edilen 17 adet tahmin sonucu çoğunluk oylama yöntemi kullanılarak Denklem 3.5 ile birleştirilmektedir. Satır – sütun paradigmasında her bir harf için, bir satıra ait bir de sütuna ait tahmin bulunması gerektiğinden satırlar ve sütunlar kendi içlerinde ayrı olarak değerlendirilmiştir. Burada T, tahmin edilen sonucu göstermektedir (Kim vd., 2003).

$$T_{i-Satır}, T_{i-Sütun} = \max \sum_{j=1}^{17} O_{i(satırlar)j}, O_{i(sütunlar)j} \quad (3.5)$$

3.2.5 Z Skor Normalizasyonu

Normalizasyon, veri kümesi üzerinde aynı nitelikte olan verileri, bir düzen içerisinde, birbirine benzer hale getirmeye yarar. Z skor normalizasyon yöntemi, Denklem 3.6'yı kullanarak, veri kümesindeki değerler arası mesafeyi azaltılarak, uç değerlerin ortadan kaldırılmasını sağlar. Bu sayede uç verilerin sisteme olan etkisinin azaltılması amaçlanmıştır (Kundu ve Ari, 2017).

$$\acute{x} = \frac{x_i - \mu_i}{\sigma_i} \quad (3.6)$$

Burada, \acute{x} normalize edilmiş veriyi, x_i özgün veriyi, μ_i özgün verinin aritmetik ortalamasını ve σ_i ise özgün verinin standart sapmasını vermektedir.

Çizelge 3.3. En iyileme algoritmaları için koşum ve tekrar sayıları

| Değişken | Değer |
|------------------|-------|
| Koşum sayısı | 30 |
| Tekrar sayısı | 20 |
| Boyut (B) | 64 |
| Çözüm sayısı (N) | 30 |

3.3 Kanal Seçimi

Çalışmada 3 ayrı en iyileme algoritması ile kanal seçim işlemi gerçekleştirilmiştir. Bu bölümde, Genetik Algoritma, İkili Parçacık Sürü En İyilemesi

ve İkili Yapay Arı Kolonisi algoritmalarının çalışmada kullanılan değişken değerleri (Çizelge 3.3), muhtemel çözümleri içeren kümenin oluşturulması, uyum fonksiyonu ve çaprazlama yöntemi verilmiştir. Tüm en iyileme algoritmaları 30 koşumda 20 tekrar ile çalıştırılmıştır.

Çalışmada kullanılan her üç en iyileme algoritması da rastgelelik (stokastik) yapısı üzerine kurulmuştur. Başlangıç aşamalarında verilen muhtemel çözümü içeren matrisler (X_m) Denklem 3.7 kullanılarak oluşturulmuştur. Burada *rastgele* fonksiyonu 0 ile 1 arasında sürekli bir değer üretirken, *yuvarla* fonksiyonu bu değeri 0,5'ten aşağı ise aşağı, büyük ise 1'e yuvarlamaktadır ve i ise muhtemel çözüm satırını göstermektedir (Kıran, 2014).

$$X_{mi} = \text{yuvarla}(\text{rastgele}[0,1]) \quad m = 1,2,3, \dots, N \text{ ve } i = 1,2,3, \dots, B \quad (3.7)$$

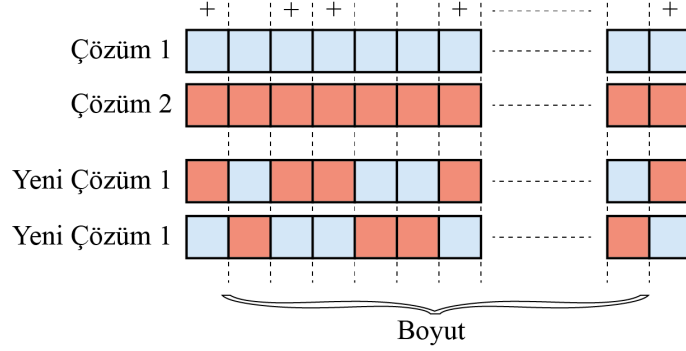
Her üç en iyileme algoritmasında da uyum fonksiyonu olarak Denklem 3.8'de verilen F skor fonksiyonu (f) kullanılmıştır (Goutte ve Gaussier, 2005). F skor, dengesiz veri kümelerinde ortaya çıkabilecek hatalı ölçümlerin önüne geçebilecek bir ölçüm yöntemidir. Kullandığımız veri kümesi de dengesiz bir dağılıma (oran 1/5) sahiptir. F skor, duyarlılık ve kesinliği birlikte işleme alarak hem gerçekte pozitif iken negatif yapılan tahminleri hem de gerçekte negatif iken pozitif yapılan hatalı tahminleri dikkate almaktadır. Duyarlılık ve keskinlik ile ilgili detaylı bilgi Bölüm 3.4'te verilmiştir.

$$f = 2 * \frac{\text{Hassasiyet} * \text{Keskinlik}}{\text{Hassasiyet} + \text{Keskinlik}} \quad (3.8)$$

Algoritmalarda olası çözümler içerisinde seçim yapılması aşamasında rulet tekerleği yöntemi kullanılmıştır. Bu yöntemde Denklem 3.9 kullanılarak uyum fonksiyonları aracılığı ile tüm olası çözümlerin olasılığı hesaplanmış ve bu olasılıklar tüm olası çözümler için kümülatif toplam olarak sıralanmıştır. Rastgele 0 ile 1 arasında üretilen bir değer kümülatif toplam içerisinde hangi çözüme karşılık geliyorsa o çözüm algoritma tarafından seçilmektedir (Holland, 1975).

$$P_i = \frac{f_{uyum(i)}}{\sum f_{uyum}} \quad (3.9)$$

Algoritmelerde gerçekleştirilen çaprazlama işlemlerinde uniform çaprazlama tercih edilmiştir. Bu çaprazlama yönteminde, olası çözümlerde rastgele seçilen boyutlar, rastgele bir düzende yer değiştirilmektedir. Böylelikle yeni çözüm kümeleri üretilmektedir. Çaprazlama Şekil 3.9’da gösterilmiştir (Kıran, 2014).

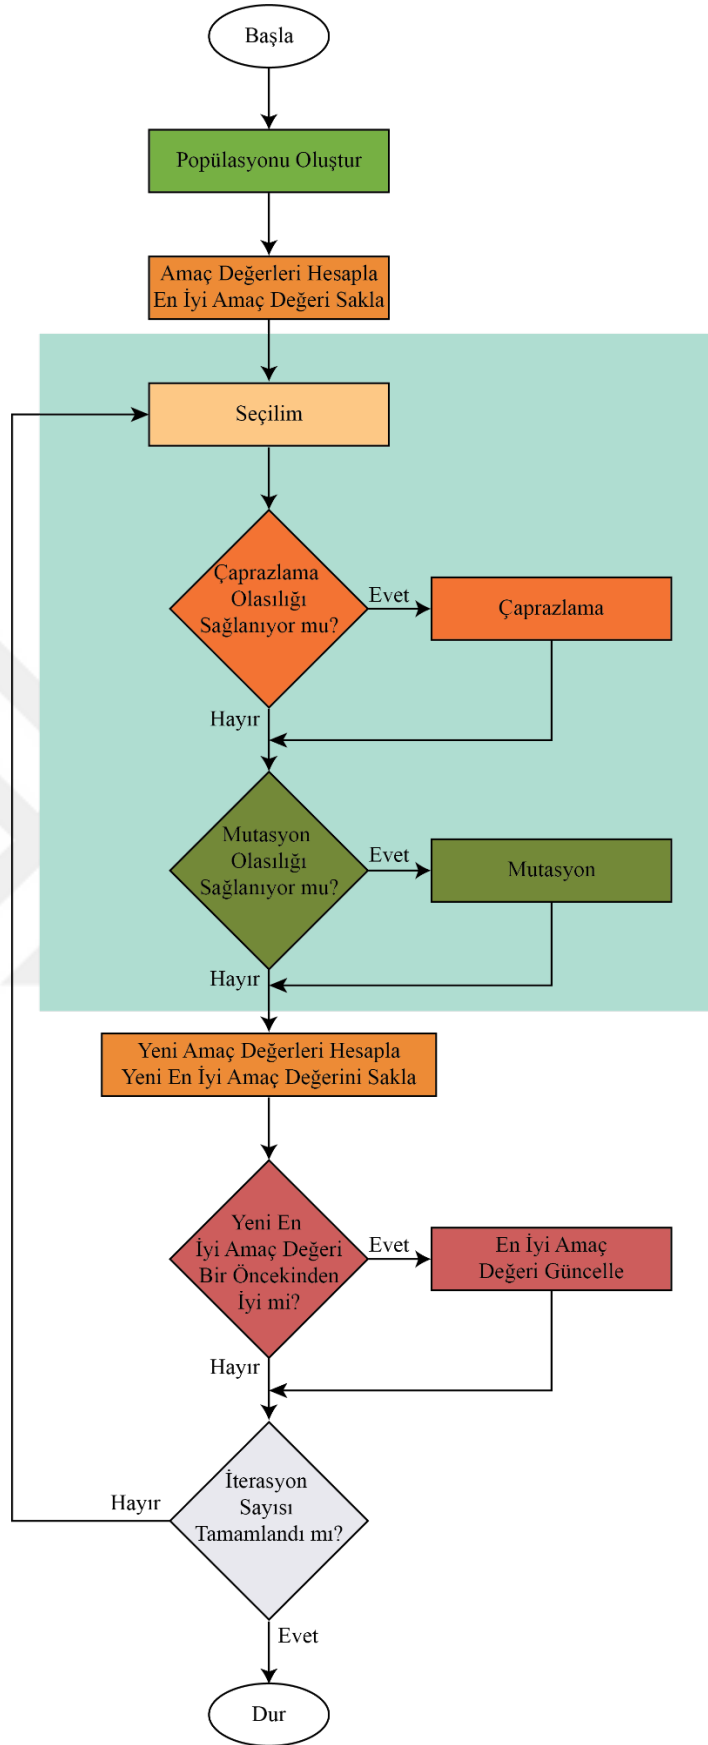


Şekil 3.9. Uniform çaprazlama

3.3.1 Genetik Algoritma (GA)

Genetik Algoritma 1975 yılında Holland tarafından tanımlanmıştır. Darwin’in doğal seçim ve evrim teorisini temel alan algoritma Şekil 3.10’da verilen akış diyagramında görüleceği üzere dört aşamadan oluşmaktadır. Bunlar sırasıyla; popülasyonun oluşturulması, doğal seçim, çaprazlama ve mutasyondur (İşçi ve Korukoğlu, 2003; Yüksel vd., 2016). Genetik algoritmada problemin boyutu gen, her bir olası çözüm ise kromozom olarak tanımlanmaktadır. Dolayısı ile 30 kromozomun her biri 64 gene sahiptir. Bu değişkenlere ek olarak algoritmanın çalışması için gerekli olan ve çalışmada kullanılan çaprazlama olasılığı ve mutasyon olasılığı değerleri Çizelge 3.4’te verilmiştir.

Popülasyonun oluşturulmasının ardından her bir olası çözümün uyum fonksiyonu hesaplanmıştır. İkinci aşamada, rulet tekerleği yöntemi ile seçilen kromozomlar ile ara popülasyon oluşturulmuştur. Üçüncü aşamada çaprazlama olasılığı sağlanıyor ise, ikili olarak çaprazlanarak yeni bir ara popülasyon oluşturulmuştur. Bu işlemler küresel arama işlemidir. Yerel bazda ise her bir yeni kromozomun geni mutasyon olasılığı sağlanıyor ise $Gen = NOT(Gen)$ fonksiyonu ile mutasyona tabi tutulmaktadır. Bu aşamada yeni popülasyon oluşturulmuş ve yeni uyum fonksiyonları hesaplanmıştır.



Şekil 3.10. Genetik algoritma akış şeması

Çizelge 3.4. Genetik algoritma başlangıç değişkenleri

| Değişken | Değer |
|----------------------|-------|
| Çaprazlama Olasılığı | 0,95 |
| Mutasyon olasılığı | 0,005 |

3.3.2 İkili Parçacık Sürü En İyileme Algoritması (BPSE)

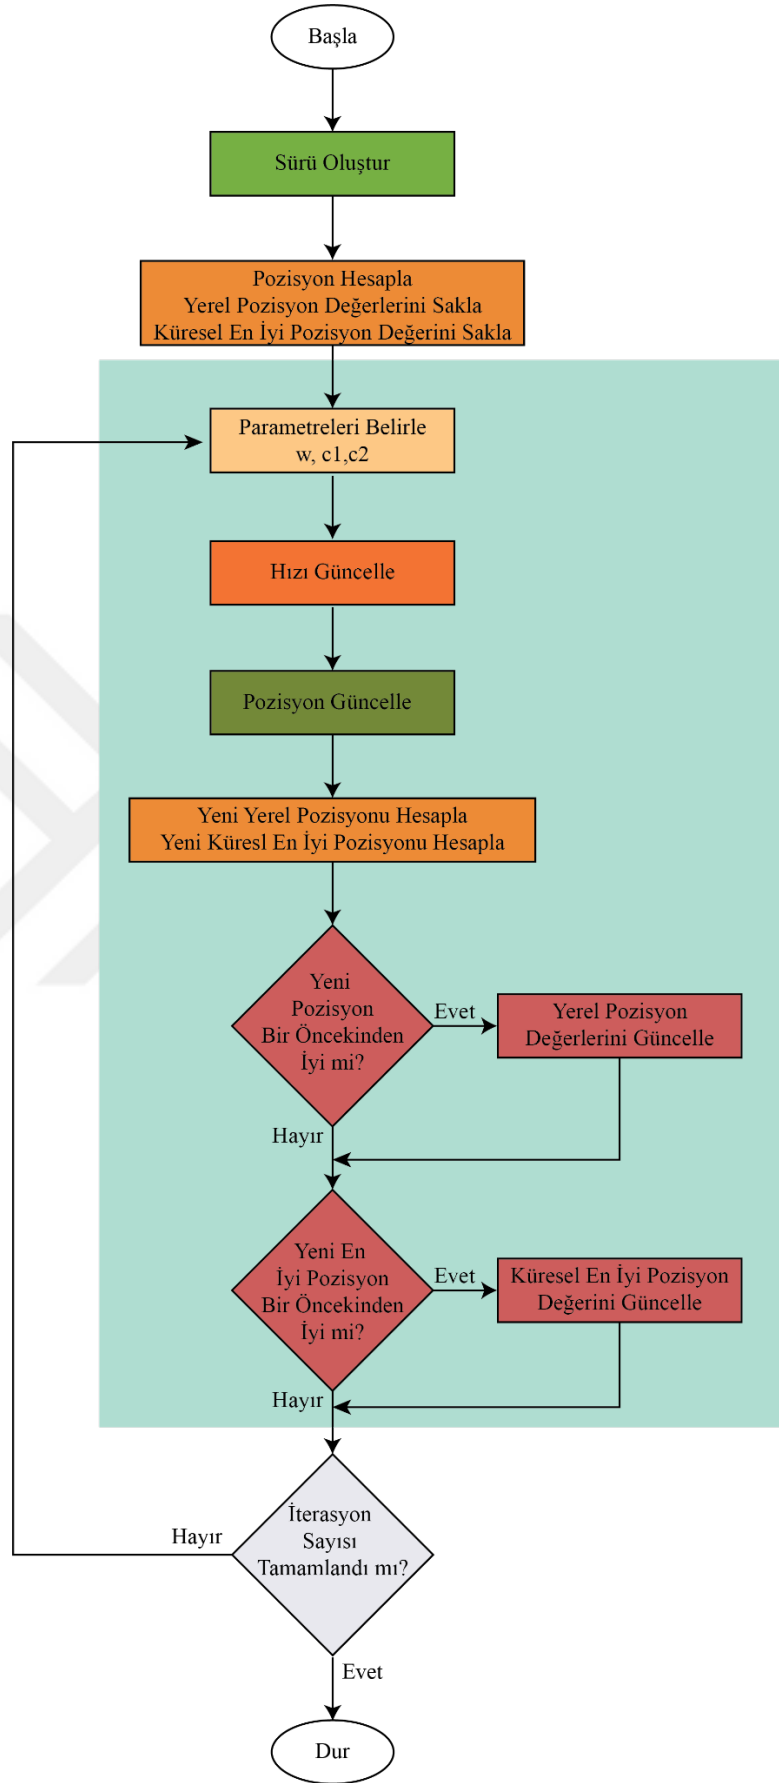
BPSE sürü tabanlı bir en iyileme algoritmasıdır. Kennedy ve Eberhart (1995) tarafından kuş ve balık sürülerinin yiyecek bulma hareketleri incelenerek ortaya çıkartılmıştır. Sürü içerisinde olan bireylerin sosyal iletişimleri üzerinden çalışmaktadır. Genetik algortmadaki kromozom parça, popülasyon ise sürü olarak isimlendirilmektedir. BPSE'ye ait akış diyagramı Şekil 3.11'de verilmiştir. Sürüde bulunan parçalar mevcut konumunu, sürünün en iyi konumuna sahip parçaya göre güncellemektedir. Parça, mevcut pozisyonunu Denklem 3.10'da verilen eşitlik ile güncellemektedir. Burada ω atalet hızı, V_i^t önceki hız güncellemesini, c_1 ve c_2 sırasıyla bireysel ve sosyal öğrenme katsayılarını, φ_1 ve φ_2 0 ve 1 arasında rastgele bir değeri, p_{eniyi} sürünün en iyi değerini, g_{eniyi} parçacığın en iyi konum değerini, X_i^t parçacığın mevcut konumunu ifade etmektedir. Kullanılan katsayılar Çizelge 3.5'te verilmiştir (Kıran, 2014).

$$V_i^{(t+1)} = \omega V_i^t + C_1 \varphi_1 (p_{eniyi} - X_i^t) + C_2 \varphi_2 (g_{eniyi} - X_i^t) \quad (3.10)$$

Standart PSO algoritmasından farklı olarak her parçacık sürekli değerler yerine 1 ve 0'lerden oluşmaktadır. Bu nedenle hız değerinin hesaplanmasının ardından bu değerler ikili bir karşılığa dönüştürülmesi gerekmektedir. Bu amaçla Denklem 3.11'de verilen Sigmoid fonksiyonu hesaplanmıştır. Ardından Denklem 3.12 kullanılarak parçacığın ilgili boyutunun 1 veya 0 olarak güncellenmesi sağlanmıştır. Burada τ , 0 ve 1 arasında üretilmiş rastgele bir değişkendir (Mirjalili ve Lewis, 2013).

$$S = \frac{1}{1 + e^{-\tau}} \quad (3.11)$$

$$X_i^{t+1} = \begin{cases} 1 & \tau < S \\ 0 & \text{Diğer durumlar} \end{cases} \quad (3.12)$$



Şekil 3.11. PSE algoritması akış şeması

Çizelge 3.5. BPSE Algoritması başlangıç değişkenleri

| Değişken | Değer |
|----------------|------------------|
| ω | Denklem 3.13 ile |
| c_1 ve c_2 | Denklem 3.14 ile |

Denklem 3.13'te (Sengupta vd., 2018) $\omega_{min} = 0,4$ ve $\omega_{maks} = 0,9$ olarak alınmıştır.

$$w_i = \omega_{min} + (\omega_{maks} - \omega_{min}) * (1 - \frac{Tekrar_i}{Tekrar}) \quad (3.13)$$

$$1 > w_i > \frac{(c_1 + c_2)}{2} - 1 > 0 \quad (3.14)$$


3.3.3 İkili Yapay Arı Kolonisi Algoritması (BYAK)

YAK algoritması Karaboğa (2005) tarafından tanımlanmıştır. Sürü zekasına dayanan, arıların besin kaynaklarına ait bilgileri kovandaki diğer arılar ile paylaşmasını temel alan bir en iyileme algoritmasıdır. Algoritmada, olası çözümler besin olarak isimlendirilmektedir. Başlangıç fazında besin sayısı ve problemin boyutuna ek olarak arama sınırı, görevli ve gözcü arı sayısı değişkenleri tanımlanır. Çalışmada kullanılan değişkenler ve değerleri Çizelge 3.6'da verilmiştir. Arama sınırının belirlenmesinde Karaboğa ve Akay (2009) tarafından önerilen Denklem 3.15 kullanılmıştır.

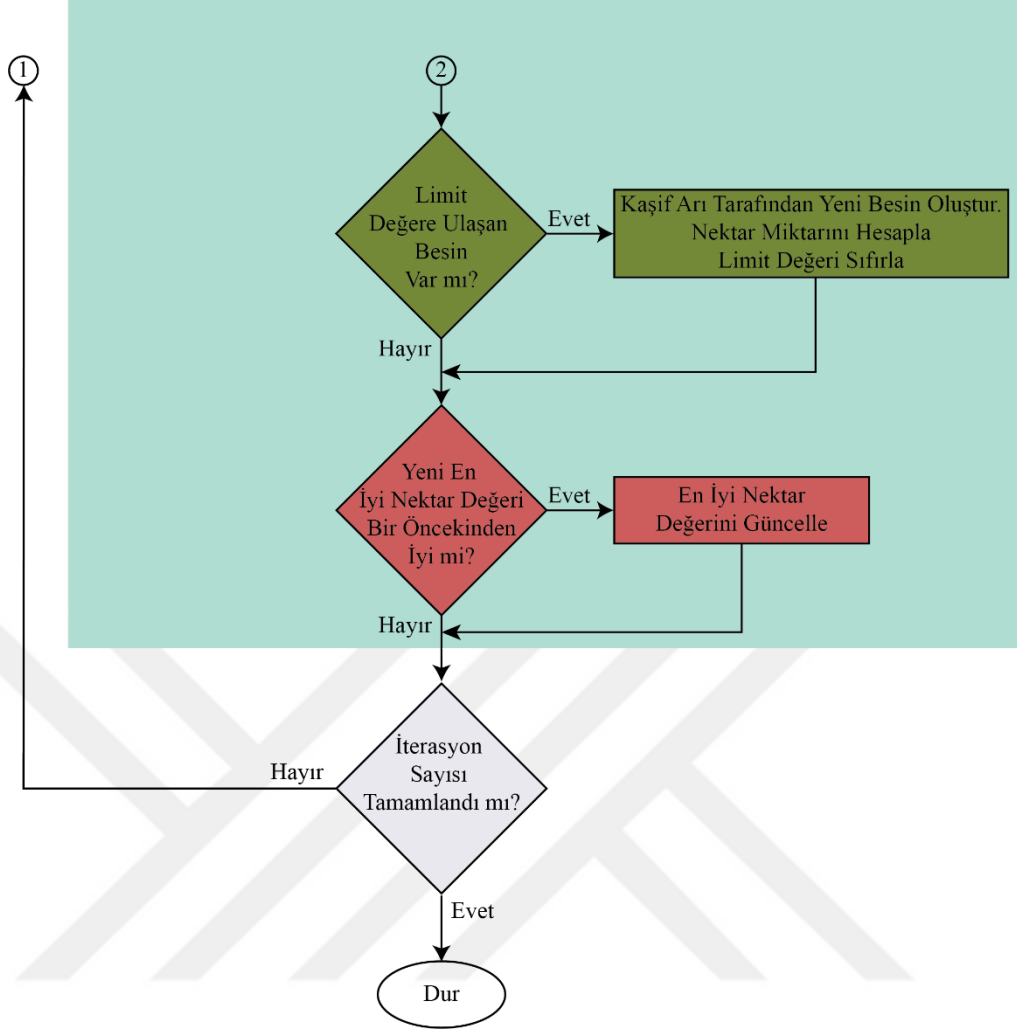
$$Arama\ Sınırı = Besin\ Sayısı * Boyut \quad (3.15)$$

Çizelge 3.6. BYAK algoritması başlangıç değişkenleri

| Değişken | Değer |
|--------------|-------|
| Arama sınırı | 1920 |
| Görevli arı | 30 |
| Gözcü arı | 30 |



Şekil 3.12. YAK algoritması akış şeması



Şekil 3.12. YAK algoritması akış şeması (devam)

YAK algoritması, başlangıç aşaması, görevli arı aşaması, gözcü arı aşaması ve kâşif arı aşaması olmak üzere dört aşamadan oluşmaktadır. Algoritmaya ait akış şeması Şekil 3.12’de verilmiştir.

Başlangıç aşamasında, diğer algoritmalarda olduğu gibi, belirlenen besin sayısı ve problemin boyutuna göre besinler ikilik düzende oluşturulur. Görevli arı aşamasında, her görevli arı bir besin kaynağı üzerinde çalışma yapar ve komşuluklarda besinlerin nektar oranlarını uyum fonksiyonu aracılığı ile araştırırlar.

Yeni besinlerin türetilmesi sırasında ikili sisteme uygun genel YAK formundan farklı olarak aritmetik operatörler yerine mantıksal operatörler Denklem 3.16’da verildiği şekliyle kullanılmıştır. Mantık operatörlerinin çıkışları yine ikili düzende olduğundan dolayı, yapılandırma sonuçlarında herhangi ek bir işlem yapılmasına gerek kalmamıştır.

$$V_i^j = X_i^j \oplus [\varphi(X_i^j \oplus X_k^j)] \quad (3.16)$$

Besinin rastgele bir komşuluğunda uniform seçilen boyutlar arasında yapılandırma işlemi gerçekleştirilmektedir. Burada X_i^j , i . besinin j . boyutunu, X_k^j , k . komşuluktaki besinin j . boyutunu göstermektedir. Denklemden $i \neq k$ 'dır. Yine denklemden \oplus , “Özel Veya” operatörünü gösterirken, φ ise rastgele bir olasılıkla ($p_{\text{değil}}=0,5$) çalışan “Değil” operatörüdür. Komşuluklarda kaliteli besin arama işlemi limit değere ulaşana kadar veya daha kaliteli bir besin bulana kadar devam etmiş ve ardından bir diğer besine geçilmiştir (Kıran, 2014).

Tüm besinlerin tamamlanmasının ardından üçüncü aşama olan gözcü arı fazına geçilmektedir. Görevli arılar tarafından paylaşılan nektar bilgileri alan gözcü arılar rület tekerleği yöntemi ile bir besine giderler. Her bir gözcü arı, gittiği besini, limit değerler içerisinde geliştirmeye çalışır. Eğer uyum fonksiyonu değerlerinde bir gelişim var ise arama limiti sıfırlanarak o çözüm saklanır. Tüm gözcü arıların geliştirme işlemleri sonucunda en iyi uyum fonksiyonu değerine sahip besin problemin en iyi çözümü olarak saklanır. Dördüncü ve son aşama kâşif arı aşamasıdır. Bir kâşif arı, arama limitine ulaşan, hiç gelişmeyen, besin yerine yeni besin bulmakla görevlidir.


3.4 Sınıflama Algoritmaları

Sınıflama, bir veri uzayında bulunan bir verinin daha önceden tanımlanmış gruplardan hangisine dahil olduğunu bulma işlemidir. Burada her bir grup sınıf, sınıf ismi ise etiket olarak isimlendirilmektedir. Alanyazında sınıflama problemlerinin çözümünden çok fazla sayıda algoritma bulunmaktadır. Çalışmada Destek Vektör Makinesi (DVM), En Küçük Kareler Destek Vektör Makinesi (EKK-DVM) ve Doğrusal Ayırıcı Analizi (DAA) olmak üzere üç ayrı sınıflayıcı kullanılmıştır. Burada amaç optimizasyon algoritmalarının farklı sınıflayıcılar için ortaya koydukları performansları da karşılaştırabilmektir. Bu bölümde, üç sınıflayıcı detaylı olarak incelenmiştir. Ancak üç sınıflayıcı için ortak gerçekleştirilen işlemler bulunmaktadır.

Sınıflayıcılar, performans farklılığını görmek üzere, üretilen tek bir model ve topluluk yapısı ile üretilen 17 model ile sınıflandırma işlemleri gerçekleştirilmiştir. DVM ve DAA sınıflayıcılarda Temel Bileşen Analizi (TBA) uygulanmıştır. Sınıflama

geçerliğinin artırılması amacıyla her bir modelin üretilmesinde 10 Katlı Çapraz Doğrulama (ÇD) uygulanmıştır. Topluluk yapısının oluşturulması Bölüm 3.2.4'te detaylı olarak aktarılmıştır.

TBA temelde bir veri azaltma yöntemidir. Birbiri ile korelasyon içerisinde olan verileri birleştirerek, aralarında korelasyon olmayan bir boyuta taşınmasını sağlar. Bir veri kümesine TBA uygulandığı zaman aslında olan veri değişikliği değil veriye bakış açısının değişmesidir. TBA sonucu hesaplanan yeni görüntünün tamamının işleme sokulması yerine, tüm kümeyi temsil edecek bir bölümü yeni veri kümesi olarak sınıflayıcıya uygulanmaktadır. TBA işlemine ait blok şema Şekil 3.13'te verilmiştir (Sangün, 2007; Yazar vd., 2009).



Şekil 3.13. Temel bileşen analizi blok şeması

Girişte bulunan veri kümesi X olmak üzere Denklem 3.16 ile kovaryans matrisi hesaplanır.


$$C = X^T X \quad (3.16)$$

C kare bir matris, $W \neq 0$ olan bir sütun vektör ve λ bir skaler olmak üzere $CW = \lambda W$ eşitliği sağlanıyorsa, W vektörü C matrisinin özvektörü, λ ise C matrisinin özdeğeridir. Özdeğerler ve özvektörlerin bulunmasını takiben üçüncü adımda özvektörlerden hangilerinin kullanılacağı tespit edilir. Özdeğerler birikimli olarak toplandıktan sonra çalışmada bu toplamın %99'unu temsil eden Özvektörler seçilmiştir. W_r seçilen özvektörlerden oluşan yeni özvektör matrisidir. Son adımda ise Denklem 3.17 ile yeni veri kümesi \tilde{X} elde edilir.

$$\tilde{X} = XW_r \quad (3.17)$$

ÇD, veri kümesinin birden fazla parçaya bölünmesi suretiyle elde edilen farklı eğitim ve test veri kümeleri ile sınıflama sonucunda elde edilen başarımın artmasını hedefler. Çalışmada ÇD 10 katlamalı olarak çalıştırılmıştır. Şekil 3.14'te görüleceği

üzere veri kümesi 10 parçaya bölündükten sonra sırasıyla bir küme test, geri kalan 9 küme eğitim kümesi olarak belirlenmiştir. 10 defa yapılan çalışmanın ardından elde edilen sınıflama sonuçlarının ortalaması hesaplanarak nihai sonuç elde edilir (Alpaydın, 2014).

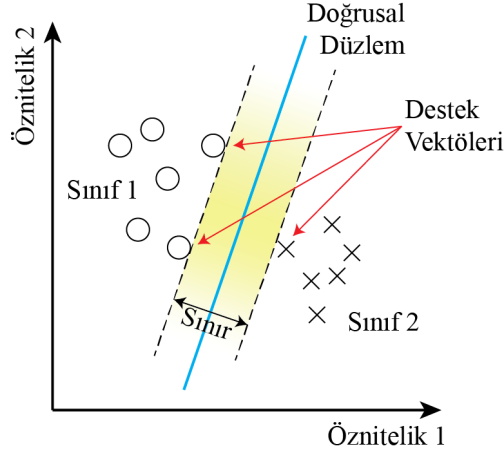


Şekil 3.14. 10 Katlı ÇD modellemesi


3.4.1 Destek Vektör Makinesi (DVM)

DVM'nin temelleri 1963 yılında Vapnik ve Chervonenkis tarafından atılmış, gelişimi 1995 yılında Vapnik, Boser ve Guyon tarafından gerçekleştirilmiştir. İstatistiksel öğrenmeye dayalı danışmalı öğrenme yöntemidir. Çıkış noktası iki sınıflı verilerin birbirinden ayrılmasıdır. Bu amaçla bir ayırıcı düzlem tespit edilir (Ayhan ve Erdoğan, 2014; Kavzoğlu ve Çölkesen, 2010; Yang, 2010).

DVM'lerde veri kümesini ikiye bölecek sonsuz ayırıcı düzlem doğrusaldır. Veri kümesi Şekil 3.15'te görüleceği üzere doğrusal bir içeriğe sahipse doğrudan ayırıcı düzlemin doğrusal fonksiyonu yazılabilirken, eğer veri kümesi Şekil 3.16'da olduğu gibi doğrusal değilse öncelikle çekirdek fonksiyonu ile giriş verisi doğrusal bir yapıya dönüştürülerek doğrusal bir ayırıcı düzlem tespit edilebilir.



Şekil 3.15. Doğrusal veri kümesi ve ayırıcı düzlem



Şekil 3.16. Doğrusal olmayan veri kümesi ve ayırıcı düzlem

3.4.1.1 Doğrusal Ayrılan Veri Kümeleri

DVM sınıflandırmada temel amaç veriyi hatasız bir şekilde doğrusal olarak ikiye ayırabilmektir (Ayhan ve Erdoğan, 2014; Kavzoğlu ve Çölkesen, 2010). n tane ögesi bulunan bir veri kümesi için;

$$(x_1, y_1), \dots, (x_n, y_n), \quad x \in R^d, x \in \{+1, -1\} \quad (3.18)$$

eğitim verileri w ve w_0 katsayıları ile Denklem 3.19'da verilen eşitlik ile sağlanacak ayırıcı düzlem ile ayrılabilir.

$$D(x) = (w \times x) + w_0 \quad (3.19)$$

Ayırıcı düzlem eşitlik 3.20 ile verilen şartları yerine getirmelidir.

$$D(x_i) = \begin{cases} (w \times x) + w_0 \geq +1, & \text{eğer } y_i = +1 \\ (w \times x) + w_0 \leq -1, & \text{eğer } y_i = -1 \end{cases} \quad i = 1, 2, \dots, n \quad (3.20)$$

Denklem 3.20'nin bileştirilmesi ile Denklem 3.21 elde edilir.

$$y_i[(w \times x_i) + w_0] \geq +1, \quad i = 1, 2, \dots, n \quad (3.21)$$

Ayrırcı düzlem ile en yakın ver noktası arasındaki uzaklık sınır olarak isimlendirilir ve Γ ile gösterilir. Sınır değeri ne kadar büyük ise sınıflayıcı o kadar iyi genelleme yapar. Denklem 3.22 ile verilen koşul tüm eğitim örnekleri için sağlanmalıdır.

$$\frac{y_k \times D(x_k)}{\|w\|} \geq \Gamma, \quad k = 1, 2, \dots, n \text{ ve } y_k \in \{-1, +1\} \quad (3.22)$$

En iyi ayrırcı değer için sağlanması gereken şart Γ sınır değerini en yüksek olacak şekilde ayarlamaktır. Çünkü w ağırlığı sonsuz sayıda değer alabilmektedir. Sınır üzerinde bulunan veri noktaları destek vektörü olarak isimlendirilir.

3.4.1.2 Doğrusal Olarak Belirli Bir Hatayla Ayrılan Veri Kümeleri

Eğitim verilerinin her zaman hatasız olarak doğrusal bir ayrırcı ile ayrılması mümkün olmamaktadır. Bu durumlarda verinin en az sayıda veride hata olacak şekilde ayrılma işlemi gerçekleştirilir. Ancak gerçekleşen bu durum Denklem 3.21'de verilen şartın yerine getirilmesini engelleyecektir. Yani bazı veriler ayırım bölgesinin içine düşecek veya sınıf etiketi diğer bölgede kalacaktır. Ayırma işleminin gerçekleşebilmesi için n tane ξ pozitif gevşek değişkeni tanımlanır ve Denklem 3.23'teki halini alır (Ayhan ve Erdoğan, 2014; Kavzoğlu ve Çölkesen, 2010).

$$y_i[(w \times x_i) + w_0] \geq +1 - \xi_i, \quad i = 1, 2, \dots, n \quad (3.23)$$

Burada ξ_i sınırdan olan minimum sapma miktarıdır ve ayrılmazlık durumu için $0 < \xi_i < 1$, yanlış sınıflandırma için $1 < \xi_i < 0$ olur. Denklem 3.24'ün en küçük değerini alması ayrılamaz örnek sayısını da en küçük değerine getirir.

$$Q(\xi) = \sum_{i=1}^n \xi_i^p \quad (3.24)$$

Burada $p = 1$ olarak ve Denklem 3.23 aracılığı ile Denklem 3.25'te verilen esnek sınır ayırıcı düzlemi bulunur. Burada c sabiti, sınıflandırılmayacak verilerin cezalandırma oranıdır. Küçük c değeri sınıflanmayacak veri noktalarını kolaylıkla belirlerken, büyük c değeri sınıflanmayacak veri noktalarının daha az tercih edilmesine neden olur.

$$S_k = \{(w \times x) + w_0: \|w\|^2 \leq c_k\} \quad (3.25)$$

En iyi esnek sınır Denklem 3.26 ve 3.27 kullanılarak bulunur. Denklem 3.28'de görüleceği üzere ayırıcı düzlem karar fonksiyonu, doğrusal olarak ayrılabilir veri kümeleri ile benzerdir.

$$Q(a) = \sum_{i=1}^n a_i - \frac{1}{2} \sum_{i,j=1}^n a_i a_j y_i y_j (x_i \times x_j) \quad (3.26)$$

$$\sum_{i=1}^n a_i y_i = 0, \quad 0 \leq a_i \leq \frac{c}{n}, \quad i = 1, 2, \dots, n \quad (3.27)$$

$$D(x) = \sum_{i=1}^n a_i^* y_i (x \times x_i) + w_0^* \quad (3.28)$$

3.4.1.3 Doğrusal Ayrılamayan Veri Kümeleri

Doğrusal olmayan veri kümelerinin doğrusal ayırıcı düzlemi ile çalıştırılması mümkün değildir. Bu nedenle doğrusal olmayan veri uzayının, doğrusal bir veri uzayına dönüştürülmesi gerekmektedir. Bu amaçla çekirdek fonksiyonları kullanılır. Alanyazında çok sayıda çekirdek fonksiyonu bulunmakla birlikte çalışmada Radyal Temelli Fonksiyon (RTF) kullanılmıştır. RTF, Denklem 3.29'de verilmiştir. RTF çekirdeği σ parametresi ile çalışmaktadır. Küçük σ değeri, karar sınırının dar olmasına dolayısı ile karar bölgesinin genişlemesine neden olur. Büyük σ değeri ise karar sınırını genişletir. Bu durum veri noktaları etrafında karar sınırı noktaları oluşturur (Alpaydın, 2014; Ayhan ve Erdoğan, 2014).

$$K_{YTF}(x, x') = e^{-\frac{\|x-x'\|^2}{2\sigma^2}} \quad (3.29)$$

Veri uzayının taşınmasının ardından yapılan işlemler doğrusal DVM işlemleridir.

3.4.2 En Küçük Kareler Destek Vektör Makinesi (EKK-DVM)

En küçük kareler destek vektör makinesi (EKK-DVM) standart DVM algoritmasının bir çeşit iyileştirmesidir. Algoritmanın karmaşıklığı düşüktür ve algoritmanın yakınsama hızı artmıştır. Çalışmada kullanılan EKK-DVM modeli, Suykens vd. (2001) tarafından geliştirilmiştir. EKK-DVM yönteminde, DVM’de kullanılan ayırıcı düzlem ve destek vektörleri arasındaki marj yerine bir yaklaşım hatası kullanılır. EKK-DVM için hata en iyilemesi Denklem 3.30 ile sağlanmaktadır (Ceryan, 2016; Suykens vd., 2001). Burada $y_k = W^T \phi(x_k) + b + e_k$ olmak üzere, modele sunulan eğitim veri seti $k = 1, 2, \dots, N$ için $\{x_k, y_k\}$ ’dir.

$$\min. J(W, e) = \frac{1}{2} W^T W + \frac{\gamma}{2} \sum_{k=1}^N e_k^2 \quad y_k - \hat{y}_k = e_k \quad (3.30)$$

Denklem 3.30’da e_k hata terimini, W ağırlıkları, $\phi(x_k)$ girdi uzayını çok boyutlu bir uzaya taşıyan çekirdek fonksiyonu, b sabit (bias) terimi ve γ düzenleme faktörünü ifade etmektedir. EKK-DVM’de Denklem 3.31’de verilen Lagrange çarpanları ile en iyileme problemi çözülmüştür.

$$L(W, b, e, \alpha) = J(W, e) - \sum_{k=1}^N \alpha_k (W^T \phi(x_k) + b + e_k - y_k) \quad (3.31)$$

Burada α_k Lagrange sabitlerini ifade etmektedir. y_k ’nin birinci dereceden kısmi türevi ile W ağırlıkları ve e_k hata terimi yok edilerek Denklem 3.32 elde edilebilir. Burada $K(x_k, x)$ çekirdek fonksiyonunu göstermektedir.

$$\hat{y}_k = \sum_{k=1}^N \alpha_k K(x_k, x) + b \quad (3.32)$$

Çalışmada çekirdek fonksiyonu olarak YTF çekirdeği kullanılmıştır. EKK-DVM sınıflayıcı olarak Brabenter vd. tarafından geliştirilen EKK-DVM Toolbox sürüm 1.8 kullanılmıştır (De Brabanter vd., 2010). LS-SVM’ye ait düzenleme faktörü (γ) ve yarıçap fonksiyon genişliği (σ) değişkenleri program üzerinden optimize edilmiştir.

3.4.3 Doğrusal Ayırıcı Analizi (DAA)

DAA yöntemi, sınıflar arasında (verileri en iyi şekilde tanımlayanlardan ziyade) en iyi ayırım yapan vektörleri arar. Bir başka ifadeyle, verilerin tanımlandığı bir dizi bağımsız özellik göz önüne alındığında, DAA, istenen sınıflar arasındaki en büyük ortalama farklılıkları veren doğrusal bir kombinasyonu oluşturur (Ye vd., 2009).

İlk kez Fisher tarafından geliştirilmiştir (Sayad, 2018). Fisher Denklem 3.34'te verilen skor fonksiyonunu tanımlar. Bu eşitlikte problem, skoru maksimum yapacak katsayıları bulmaktır.

$$Z = \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_n x_n \quad (3.33)$$

$$S(\beta) = \frac{\beta^T \mu_1 + \beta^T \mu_2}{\beta^T C \beta} \quad (3.34)$$

$$S(\beta) = \frac{\bar{Z}_1 - \bar{Z}_2}{\text{Gruplardaki } Z \text{ varyansı}} \quad (3.35)$$

$$\beta = C^{-1}(\mu_1 - \mu_2) \quad (3.36)$$

$$C = \frac{1}{n_1 - n_2} (n_1 C_1 - n_2 C_2) \quad (3.37)$$

Burada β model katsayılarını, C kovaryans matrislerini, μ_1, μ_2 ortalama vektörleri göstermektedir.

3.4.4 Sınıflayıcı Performans Ölçütleri

Kullanılan her üç sınıflayıcının performansı Şekil 3.17'de verilen iki sınıflı bir karmaşıklık matrisi ile ölçülmüştür. Kullanılan veri kümesinde hedef karakterler "1" ve hedef olmayan karakterler "-1" ile işaretlenmiştir. "1" ile işaretlenen etiketler pozitif sınıfa, "-1" ile işaretlenen etiketler negatif sınıfa karşılık gelmektedir. Karmaşıklık matrisinde satırlar toplamı gerçek değerleri gösterirken, sütunlar tahmin edilen değerleri göstermektedir. Hem gerçek sınıf hem de tahmin edilen sınıf pozitif

ise Gerçek Pozitif (GP), gerçek sınıf pozitif iken tahmin negatif ise Yanlış Negatif (YN), gerçek sınıf negatif iken tahmin edilen sınıf pozitif ise Yanlış Pozitif (YP), hem gerçek sınıf hem de tahmin edilen sınıf negatif ise Gerçek Negatif (GN)'tir

| | | Gerçek | |
|--------|---|--------|----|
| | | + | - |
| Tahmin | + | GP | YP |
| | - | YN | GN |

Şekil 3.17. Karmaşıklık Matrisi

Şekil 3.17'de verilen karmaşıklık matrisi kullanılarak; Doğruluk (DOĞ), Hassasiyet (HSS), Kesinlik (KSN), F Skor (F), Yanlış Pozitif Oranı (YPO) hesaplanmıştır. Bu ölçümlere ek olarak sınıflayıcı güven aralığı hesaplanmıştır (Alpaydın, 2014).

3.4.4.1 Doğruluk

Sınıflayıcının doğru tahmin yapma oranını verir. Denklem 3.38 ile hesaplanır.

$$DOĞ = \frac{GP + GN}{GP + YP + YN + GN} \quad (3.38)$$

3.4.4.2 Hassasiyet

Gerçekte pozitif olan verilerinin, pozitif tahmin edilme sıklığını ölçer. Doğru Pozitif Oranı (DPO) olarak da isimlendirilir. Denklem 3.39 ile hesaplanır.

$$HSS = \frac{GP}{GP + YN} \quad (3.39)$$

3.4.4.3 Kesinlik

Pozitif olarak tahmin edilen verilerin, gerçekte pozitif olma oranını ölçer. Denklem 3.40 ile hesaplanır.

$$KSN = \frac{GP}{GP + YP} \quad (3.40)$$

3.4.4.4 F Skor

F Skor Hassasiyet ve Kesinliğin harmonik ortalamasıdır. Dengesiz veri dağılımı bulunan veri kümelerinde Doğruluk ölçümünde meydana gelen hatayı göstermek amaçlı kullanılmıştır. Denklem 3.41 ile hesaplanır (Goutte ve Gaussier, 2005).

$$F \text{ Skor} = 2 * \frac{HSS * KSN}{HSS + KSN} \quad (3.41)$$

3.4.4.5 Yanlış Pozitif Oranı

Gerçekte negatif olan verinin, pozitif tahmin edilme oranını veren ölçümdür. Denklem 3.42 ile hesaplanır.

$$YPO = \frac{YP}{YP + GN} \quad (3.41)$$

3.4.4.6 Güven Aralığı

Bir sınıflayıcı performans ölçümü olan doğruluk oranını güven aralığı ile vermek, performans hakkında daha gerçekçi bilgiler sağlayacaktır. Güven aralığında ilk bölüm, modelden beklenecek doğruluk oranının alt ve üst sınırı, ikinci bölüm ise model performansının bu aralık içine girme olasılığıdır. Sınıflandırma hatası ile güven aralığının (GA_{95}) tespiti Denklem 3.42 ile gerçekleştirilir (Brownlee, 2019).

$$GA_{95} = Hata \pm C \sqrt{\frac{Hata*(1-Hata)}{n}} \quad (3.42)$$

Burada *Hata* Denklem 3.43 ile hesaplanan hata oranını, *C* güven aralığı için belirlenen olasılığı, *n* ise toplam gözlem sayısını ifade etmektedir. Çalışma %95 güven aralığı için gerçekleştirilmiş olup *Z* çizelgesine göre *C* sabiti 1,96 alınmıştır.

$$Hata \text{ Oranı} = \frac{YP + YN}{GP + YP + YN + GN} \quad (3.43)$$

4. BULGULAR VE TARTIŞMA

Çalışma sonucunda elde edilen bulgular iki bölümde incelenmiştir. Bölüm 4.1’de GA, BPSO ve BABC ile seçilen kanallar ile ilgili bilgi verilirken, Bölüm 4.2’de seçilen kanalların sınıflama performansları karşılaştırılmıştır.

4.1 En İyileme ile Kanal Seçimi

Her bir en iyileme algoritması için 3 adet veri alt kümesi elde edilmiştir. İlk olarak seçimi yapılan kanalların seçim sayısı, ortalama seçim sayısı ile karşılaştırılmış ve $Seçim_{Kanal(i)} \geq \mu_{Seçim}$ ($i = 1, 2, \dots, 64$) koşulunu sağlayan kanallar belirlenmiştir. Bu koşulda $Seçim_{Kanal(i)}$ herhangi bir kanalın seçilme sayısını, $\mu_{Seçim}$ ise seçilen kanal sayısının ortalamasını belirtmektedir. İkinci ve üçüncü alt küme olarak ise daha az sayıda kanalın performansını izleyebilmek amacı ile en sık seçilen 8 kanal ve 16 kanal ile sınıflama yapılmıştır. Bu aşamada sekizinci ve on altıncı sırada eşit sayıda seçilmiş kanal bulunması halinde uyum fonksiyon değeri yüksek olan çözümün bulunduğu kanal tercih edilmiştir. Seçilen kanalların yoğunluğunu gösteren şekiller ICA EEGLAB Toolbox (Delorme ve Makeig, 2004) aracılığı ile oluşturulmuştur. Topografi çizimlerinde, maviden kırmızıya verilen ölçekte sırasıyla az seçilenden çok seçilene doğru bir renklendirme vardır.

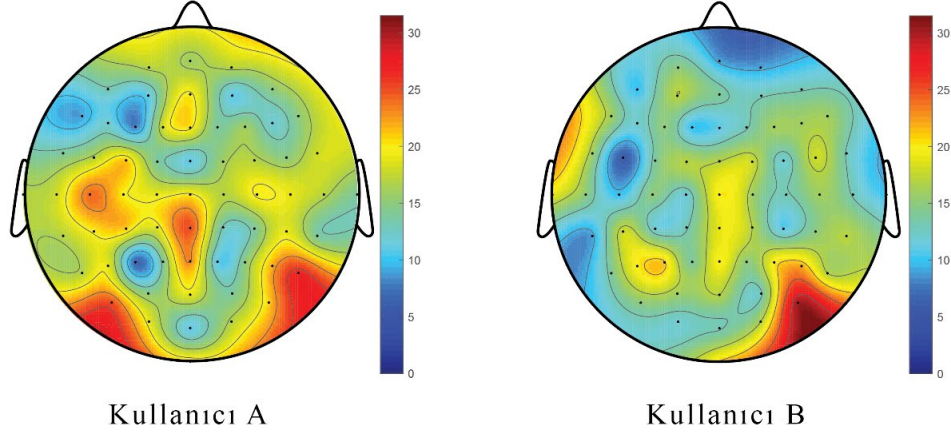
4.1.1 Genetik Algoritma

Çizelge 4.1’de 20 tekrar ve 30 koşum sonrasında GA sonucu sırası ile seçilen kanalların seçilme sayıları verilmiştir. Kanal seçilme sayılarına göre, Kullanıcı A için ortalama ($\mu_{SeçimA}$) bir kanal 16,73 defa seçilirken, Kullanıcı B için ortalama ($\mu_{SeçimB}$) 15,04 defa bir kanal seçilmiştir.

Şekil 4.1’de Kullanıcı A ve Kullanıcı B için seçilen kanalların yoğunluğu EEG elektrot yerleşimine göre verilmiştir. Görüleceği üzere Kullanıcı B için 30 defa seçilen PO8 kanalı ve Kullanıcı A için 25 defa seçilen CPz sık seçilen kanallardır.

Çizelge 4.1. GA ile kanal seçim sayıları

| Kanal No | Kanal Adı | Seçilme Sayısı | | Kanal No | Kanal Adı | Seçilme Sayısı | |
|----------|-----------|----------------|-------------|----------|-----------|----------------|-------------|
| | | Kullanıcı A | Kullanıcı B | | | Kullanıcı A | Kullanıcı B |
| 1 | FC5 | 17 | 6 | 33 | F1 | 18 | 10 |
| 2 | FC3 | 21 | 14 | 34 | Fz | 20 | 11 |
| 3 | FC1 | 14 | 17 | 35 | F2 | 14 | 13 |
| 4 | FCz | 11 | 17 | 36 | F4 | 16 | 16 |
| 5 | FC2 | 16 | 18 | 37 | F6 | 12 | 16 |
| 6 | FC4 | 17 | 12 | 38 | F8 | 15 | 16 |
| 7 | FC6 | 15 | 18 | 39 | FT7 | 14 | 16 |
| 8 | C5 | 24 | 10 | 40 | FT8 | 18 | 13 |
| 9 | C3 | 20 | 15 | 41 | T7 | 18 | 15 |
| 10 | C1 | 19 | 12 | 42 | T8 | 17 | 13 |
| 11 | Cz | 20 | 20 | 43 | T9 | 17 | 19 |
| 12 | C2 | 17 | 16 | 44 | T10 | 14 | 10 |
| 13 | C4 | 20 | 13 | 45 | TP7 | 17 | 9 |
| 14 | C6 | 19 | 16 | 46 | TP8 | 14 | 17 |
| 15 | CP5 | 20 | 18 | 47 | P7 | 17 | 14 |
| 16 | CP3 | 21 | 12 | 48 | P5 | 19 | 20 |
| 17 | CP1 | 19 | 13 | 49 | P3 | 7 | 21 |
| 18 | CPz | 25 | 19 | 50 | P1 | 14 | 14 |
| 19 | CP2 | 13 | 17 | 51 | Pz | 23 | 20 |
| 20 | CP4 | 14 | 11 | 52 | P2 | 11 | 15 |
| 21 | CP6 | 19 | 15 | 53 | P4 | 15 | 20 |
| 22 | Fp1 | 17 | 15 | 54 | P6 | 22 | 22 |
| 23 | Fpz | 16 | 9 | 55 | P8 | 27 | 17 |
| 24 | Fp2 | 17 | 9 | 56 | PO7 | 25 | 15 |
| 25 | AF7 | 13 | 10 | 57 | PO3 | 15 | 16 |
| 26 | AF3 | 11 | 17 | 58 | POz | 19 | 17 |
| 27 | AFz | 20 | 14 | 59 | PO4 | 14 | 13 |
| 28 | AF4 | 11 | 13 | 60 | PO8 | 21 | 30 |
| 29 | AF8 | 15 | 13 | 61 | O1 | 19 | 12 |
| 30 | F7 | 9 | 16 | 62 | Oz | 11 | 13 |
| 31 | F5 | 12 | 12 | 63 | O2 | 17 | 17 |
| 32 | F3 | 8 | 15 | 64 | Iz | 21 | 21 |



Şekil 4.1. GA ile Kullanıcı A ve B için elektrot yerleşimine göre seçilen kanal yoğunlukları

Kullanıcı A için ortalamanın üstünde seçilen kanal sayısı ($SeçimA_{Kanal(i)} \geq \mu_{SeçimA}$) 36 ve Kullanıcı B için ortalamanın üstünde seçilen kanal sayısı ($SeçimB_{Kanal(i)} \geq \mu_{SeçimB}$) 29 olarak gerçekleşmiştir. Seçilen bu kanallar Çizelge 4.2’de verilmiştir.

Çizelge 4.2. GA ile ortalamanın üzerinde seçilen kanallar

| | Kullanıcı A | Kullanıcı B |
|------------------|--------------------------------|----------------------------|
| Seçilen Kanallar | FC5 – FC3 – FC4 – C5 – C3 | FC1 – FCz – FC2 – FC6 – Cz |
| | C1 – Cz – C2 – C4 – C6 | C2 – C6 – CP5 – CPz – CP2 |
| | CP5 – CP3 – CP1 – CPz – CP6 | AF3 – F7 – F4 – F6 – F8 |
| | FP1 – FP2 – AFz – F1 – Fz | FT7 – T9 – TP8 – P5 – P3 |
| | FT8 – T7 – T8 – T9 – TP7 | Pz – P4 – P6 – P8 – PO3 |
| | P7 – P5 – Pz – P6 – P8 | POz – PO8 – O2 – Iz |
| | PO7 – POz – PO8 – O1 – O2 – Iz | |

Çizelge 4.3’te en sık seçilen 8 ve 16 kanal seçilme sayısına göre sıralı olarak verilmiştir. Sınıflayıcılarda, Çizelge 4.2’de belirtilen kanallar ortalama üstü (OÜ ekiyle), Çizelge 4.3’te verilen kanallar ise ilk sekizi (8 ekiyle), tamamı da (16 ekiyle) kullanılmıştır.


Çizelge 4.3. Kullanıcı A ve B için GA ile en sık seçilen 16 kanal

| Kullanıcı | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 | 10 | 11 | 12 | 13 | 14 | 15 | 16 |
|-----------|-----|-----|-----|----|----|----|-----|-----|-----|----|-----|-----|-----|-----|-----|-----|
| A | P8 | CPz | PO7 | C5 | Pz | P6 | FC3 | CP3 | PO8 | C3 | Cz | C4 | CP5 | AFz | Fz | CP1 |
| B | PO8 | P6 | P3 | Iz | Cz | P5 | Pz | P4 | CPz | T9 | FC2 | FC6 | CP5 | P8 | FC1 | O2 |

4.1.2 İkili Parçacık Sürü En İyilemesi

Çizelge 4.3'te 20 tekrar ve 30 koşum sonrasında BPSE sonucu, kanalların seçilme sayıları verilmiştir. Kanal seçilme sayılarına göre, Kullanıcı A için ortalama ($\mu_{SeçimA}$) bir kanal 16,546 defa seçilirken, Kullanıcı B için ortalama ($\mu_{SeçimB}$) 14,344 defa bir kanal seçilmiştir.

Şekil 4.2'de Kullanıcı A ve Kullanıcı B için seçilen kanalların yoğunluğu EEG elektrot yerleşimine göre verilmiştir. Şekilde maviden kırmızıya verilen ölçekte sırasıyla az seçilenden çok seçilene doğru bir renklendirme vardır.



Şekil 4.2. BPSE ile Kullanıcı A ve B için elektrot yerleşimine göre seçilen kanal yoğunlukları

Kullanıcı A için ortalamanın üstünde seçilen kanal sayısı ($SeçimA_{Kanal(i)} \geq \mu_{SeçimA}$) 29 ve Kullanıcı B için ortalamanın üstünde seçilen kanal sayısı ($SeçimB_{Kanal(i)} \geq \mu_{SeçimB}$) 29 olarak gerçekleşmiştir. Seçilen bu kanallar Çizelge 4.4'te verilmiştir.

Çizelge 4.4. BPSE ortalamasının üzerinde seçilen kanallar

| | Kullanıcı A | Kullanıcı B |
|------------------|---|--|
| Seçilen Kanallar | FC3 – C5 – C3 – C1 – Cz C4 – CP5 – CP3 – CP1 – CPz CP6 – AFz – AF4 – F1 – Fz F4 – T9 – TP7 – P7 – P5 P1 – Pz – P8 – PO7 – PO3 PO8 – O1 – Oz – Iz | FC3 – FCz – FC6 – C3 – C1 Cz – C6 – CP1 – CPz – CP2 CP6 – F3 – F2 – F4 – FT7 T7 – T8 – T9 – P5 – Pz P2 – P4 – P6 – P8 – PO3 PO4 – PO8 – O2 – Iz |

Çizelge 4.5. BPSE ile kanal seçim sayıları

| Kanal No | Kanal Adı | Seçilme Sayısı | | Kanal No | Kanal Adı | Seçilme Sayısı | |
|----------|-----------|----------------|-------------|----------|-----------|----------------|-------------|
| | | Kullanıcı A | Kullanıcı B | | | Kullanıcı A | Kullanıcı B |
| 1 | FC5 | 16 | 5 | 33 | F1 | 19 | 4 |
| 2 | FC3 | 24 | 20 | 34 | Fz | 18 | 11 |
| 3 | FC1 | 15 | 14 | 35 | F2 | 10 | 18 |
| 4 | FCz | 13 | 17 | 36 | F4 | 17 | 18 |
| 5 | FC2 | 16 | 8 | 37 | F6 | 8 | 13 |
| 6 | FC4 | 15 | 3 | 38 | F8 | 10 | 10 |
| 7 | FC6 | 16 | 17 | 39 | FT7 | 12 | 17 |
| 8 | C5 | 23 | 10 | 40 | FT8 | 13 | 5 |
| 9 | C3 | 28 | 21 | 41 | T7 | 11 | 18 |
| 10 | C1 | 26 | 15 | 42 | T8 | 16 | 18 |
| 11 | Cz | 29 | 28 | 43 | T9 | 24 | 24 |
| 12 | C2 | 14 | 14 | 44 | T10 | 12 | 7 |
| 13 | C4 | 21 | 12 | 45 | TP7 | 20 | 7 |
| 14 | C6 | 16 | 19 | 46 | TP8 | 14 | 13 |
| 15 | CP5 | 23 | 14 | 47 | P7 | 24 | 5 |
| 16 | CP3 | 19 | 8 | 48 | P5 | 27 | 19 |
| 17 | CP1 | 20 | 17 | 49 | P3 | 5 | 13 |
| 18 | CPz | 25 | 22 | 50 | P1 | 17 | 12 |
| 19 | CP2 | 12 | 16 | 51 | Pz | 30 | 27 |
| 20 | CP4 | 12 | 6 | 52 | P2 | 15 | 21 |
| 21 | CP6 | 19 | 17 | 53 | P4 | 11 | 21 |
| 22 | Fp1 | 6 | 14 | 54 | P6 | 12 | 18 |
| 23 | Fpz | 14 | 11 | 55 | P8 | 26 | 26 |
| 24 | Fp2 | 9 | 10 | 56 | PO7 | 29 | 13 |
| 25 | AF7 | 7 | 7 | 57 | PO3 | 17 | 22 |
| 26 | AF3 | 3 | 12 | 58 | POz | 7 | 14 |
| 27 | AFz | 19 | 10 | 59 | PO4 | 15 | 20 |
| 28 | AF4 | 17 | 11 | 60 | PO8 | 21 | 30 |
| 29 | AF8 | 16 | 2 | 61 | O1 | 25 | 6 |
| 30 | F7 | 13 | 10 | 62 | Oz | 19 | 13 |
| 31 | F5 | 5 | 11 | 63 | O2 | 12 | 19 |
| 32 | F3 | 12 | 15 | 64 | lz | 20 | 20 |

Çizelge 4.6’da en sık seçilen 8 ve 16 kanal seçilme sayısına göre sıralı olarak verilmiştir.


Çizelge 4.6. Kullanıcı A ve B için BPSE ile en sık seçilen 16 kanal

| Kullanıcı | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 | 10 | 11 | 12 | 13 | 14 | 15 | 16 |
|-----------|-----|----|-----|----|----|-----|-----|-----|----|-----|-----|-----|----|-----|----|-----|
| A | Pz | Cz | PO7 | C3 | P5 | C1 | P8 | CPz | O1 | FC3 | T9 | P7 | C5 | CP5 | C4 | PO8 |
| B | PO8 | Cz | Pz | P8 | T9 | CPz | PO3 | C3 | P2 | P4 | FC3 | PO4 | Iz | C6 | P5 | O2 |

4.1.3 İkili Yapay Arı Kolonisi

Çizelge 4.7’de 20 tekrar ve 30 koşum sonrasında BYAK sonucu sırası ile seçilen kanalların seçilme sayıları verilmiştir. Kanal seçilme sayılarına göre, Kullanıcı A için ortalama ($\mu_{SeçimA}$) bir kanal 16,531 defa seçilirken, Kullanıcı B için ortalama ($\mu_{SeçimB}$) 14,281 defa bir kanal seçilmiştir.

Şekil 4.3’te Kullanıcı A ve Kullanıcı B için seçilen kanalların yoğunluğu EEG elektrot yerleşimine göre verilmiştir.



Şekil 4.3. BYAK ile Kullanıcı A ve B için elektrot yerleşimine göre seçilen kanal yoğunlukları

Kullanıcı A için ortalamanın üstünde seçilen kanal sayısı ($SeçimA_{Kanal(i)} \geq \mu_{SeçimA}$) 31 ve Kullanıcı B için ortalamanın üstünde seçilen kanal sayısı ($SeçimB_{Kanal(i)} \geq \mu_{SeçimB}$) 30 olarak gerçekleşmiştir. Seçilen bu kanallar Çizelge 4.8’de verilmiştir.

Çizelge 4.7. BYAK ile kanal seçim sayıları

| Kanal No | Kanal Adı | Seçilme Sayısı | | Kanal No | Kanal Adı | Seçilme Sayısı | |
|----------|-----------|----------------|-------------|----------|-----------|----------------|-------------|
| | | Kullanıcı A | Kullanıcı B | | | Kullanıcı A | Kullanıcı B |
| 1 | FC5 | 17 | 5 | 33 | F1 | 18 | 6 |
| 2 | FC3 | 21 | 19 | 34 | Fz | 14 | 13 |
| 3 | FC1 | 18 | 12 | 35 | F2 | 7 | 14 |
| 4 | FCz | 17 | 18 | 36 | F4 | 16 | 16 |
| 5 | FC2 | 22 | 14 | 37 | F6 | 7 | 17 |
| 6 | FC4 | 11 | 3 | 38 | F8 | 10 | 11 |
| 7 | FC6 | 12 | 19 | 39 | FT7 | 14 | 12 |
| 8 | C5 | 28 | 7 | 40 | FT8 | 14 | 3 |
| 9 | C3 | 25 | 22 | 41 | T7 | 17 | 18 |
| 10 | C1 | 17 | 18 | 42 | T8 | 17 | 13 |
| 11 | Cz | 24 | 27 | 43 | T9 | 17 | 20 |
| 12 | C2 | 5 | 19 | 44 | T10 | 11 | 4 |
| 13 | C4 | 21 | 11 | 45 | TP7 | 18 | 7 |
| 14 | C6 | 24 | 14 | 46 | TP8 | 12 | 16 |
| 15 | CP5 | 18 | 14 | 47 | P7 | 25 | 4 |
| 16 | CP3 | 21 | 13 | 48 | P5 | 25 | 15 |
| 17 | CP1 | 15 | 12 | 49 | P3 | 10 | 5 |
| 18 | CPz | 24 | 20 | 50 | P1 | 18 | 13 |
| 19 | CP2 | 15 | 15 | 51 | Pz | 25 | 23 |
| 20 | CP4 | 14 | 6 | 52 | P2 | 14 | 18 |
| 21 | CP6 | 16 | 12 | 53 | P4 | 11 | 22 |
| 22 | Fp1 | 12 | 12 | 54 | P6 | 18 | 23 |
| 23 | Fpz | 13 | 10 | 55 | P8 | 29 | 21 |
| 24 | Fp2 | 13 | 13 | 56 | PO7 | 30 | 18 |
| 25 | AF7 | 9 | 15 | 57 | PO3 | 16 | 23 |
| 26 | AF3 | 5 | 18 | 58 | POz | 9 | 17 |
| 27 | AFz | 15 | 6 | 59 | PO4 | 17 | 14 |
| 28 | AF4 | 15 | 10 | 60 | PO8 | 21 | 30 |
| 29 | AF8 | 11 | 10 | 61 | O1 | 29 | 9 |
| 30 | F7 | 16 | 10 | 62 | Oz | 23 | 15 |
| 31 | F5 | 7 | 14 | 63 | O2 | 19 | 15 |
| 32 | F3 | 10 | 17 | 64 | Iz | 16 | 24 |

Çizelge 4.8. BYAK ortalamının üzerinde seçilen kanallar

| | Kullanıcı A | Kullanıcı B |
|------------------|--------------------------------|---------------------------|
| Seçilen Kanallar | FC5 – FC3 – FC1 – FCz – FC2 | FC3 – FCz – FC6 – C3 – C1 |
| | C5 – C3 – C1 – Cz – C4 | Cz – C2 – CPz – CP2 – AF7 |
| | C6 – CP5 – CP3 – CPz – F1 | AF3 – F3 – F4 – F6 – T7 |
| | T7 – T8 – T9 – TP7 – P7 | T9 – TP8 – P5 – Pz – P2 |
| | P5 – P1 – Pz – P6 – P8 | P4 – P6 – P8 – PO7 – PO3 |
| | PO7 – PO4 – PO8 – O1 – Oz – O2 | POz – PO8 – Oz – O2 – Iz |

Çizelge 4.9’de en sık seçilen 8 ve 16 kanal seçilme sayısına göre sıralı olarak verilmiştir.

Çizelge 4.9. Kullanıcı A ve B için BYAK ile en sık seçilen 16 kanal

| Kullanıcı | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 | 10 | 11 | 12 | 13 | 14 | 15 | 16 |
|-----------|-----|----|----|----|----|-----|----|----|----|-----|-----|-----|-----|----|-----|-----|
| A | PO7 | P8 | O1 | C5 | C3 | P7 | P5 | Pz | Cz | C6 | CPz | Oz | FC2 | C4 | FC3 | PO8 |
| B | PO8 | Cz | Iz | Pz | P6 | PO3 | C3 | P4 | P8 | CPz | T9 | FC3 | FC6 | C2 | P2 | PO7 |

4.2 Seçilen Kanalların Performanslarının karşılaştırılması

Bu bölümde sınıflama performansları incelenmiştir. Öncelikle 64 kanal ile gerçekleştirilen sınıflama işlemlerine ait çizelgeler, daha sonra da sırası ile GA, BPSE ve BYAK algoritmaları sonucunda ortalamanın üstünde seçilen kanallar, sekiz kanal ve 16 kanal ile gerçekleştirilen sınıflama işlemlerine ait çizelgelere yer verilmiştir. Sınıflayıcı performanslarının ölçümünde Doğruluk (DOĞ), Kesinlik (KSN), Hassasiyet (HSS), F Skor, Yanlış Pozitif Oranı (YPO) ölçümleri karmaşıklık matrisi üzerinden hesaplanmıştır. Sınıflayıcılara ait hata oranları da hesaplanmıştır. Bu kriterlere ek olarak, topluluk yapısının ayrıklık oranı Zorluk ölçümü ile gerçekleştirilmiştir. Doğruluk oranları özet şekilde kutu grafiği ile de verilmiştir.

Sınıflayıcı olarak, DVM, EKK-DVM, DAA, Topluluk DVM, Topluluk EKK-DVM ve Topluluk DAA kullanılmıştır. Sınıflayıcılara ait tüm veriler Kullanıcı A ve Kullanıcı B için test veri kümesi ile hesaplanmıştır.

Topluluk yapısı ile 17 model ile gerçekleştirilen sınıflayıcıların θ ayrıklık ölçümleri DVM sınıflayıcı için Çizelge 4.10’da, EKK-DVM sınıflayıcı için Çizelge 4.11’de ve DAA sınıflayıcı için Çizelge 4.12’de verilmiştir.

Çizelge 4.10. Topluluk DVM sınıflayıcı için θ ayrılık ölçütleri

| Algoritma | Kanal Sayısı | θ | |
|-----------|--------------|-------------|-------------|
| | | Kullanıcı A | Kullanıcı B |
| GA | 64 | 0,018 | 0,010 |
| | 8 | 0,034 | 0,038 |
| | 16 | 0,033 | 0,027 |
| BPSE | 36 / 29 | 0,023 | 0,020 |
| | 8 | 0,039 | 0,043 |
| | 16 | 0,035 | 0,031 |
| BYAK | 29 / 29 | 0,028 | 0,021 |
| | 8 | 0,033 | 0,040 |
| | 16 | 0,032 | 0,031 |
| | 31 / 30 | 0,026 | 0,019 |

Çizelge 4.11. Topluluk EKK-DVM sınıflayıcı için θ ayrılık ölçütleri


| Algoritma | Kanal Sayısı | θ | |
|-----------|--------------|-------------|-------------|
| | | Kullanıcı A | Kullanıcı B |
| GA | 64 | 0,015 | 0,004 |
| | 8 | 0,033 | 0,031 |
| | 16 | 0,041 | 0,022 |
| BPSE | 36 / 29 | 0,023 | 0,015 |
| | 8 | 0,025 | 0,037 |
| | 16 | 0,037 | 0,029 |
| BYAK | 29 / 29 | 0,025 | 0,012 |
| | 8 | 0,024 | 0,038 |
| | 16 | 0,021 | 0,028 |
| | 31 / 30 | 0,019 | 0,018 |

Çizelge 4.12. Topluluk DAA sınıflayıcı için θ ayrılık ölçütleri

| Algoritma | Kanal Sayısı | θ | |
|-----------|--------------|-------------|-------------|
| | | Kullanıcı A | Kullanıcı B |
| GA | 64 | 0,051 | 0,037 |
| | 8 | 0,063 | 0,071 |
| | 16 | 0,068 | 0,059 |
| BPSE | 36 / 29 | 0,053 | 0,050 |
| | 8 | 0,067 | 0,073 |
| | 16 | 0,068 | 0,066 |
| BYAK | 29 / 29 | 0,059 | 0,560 |
| | 8 | 0,061 | 0,073 |
| | 16 | 0,064 | 0,069 |
| | 31 / 30 | 0,059 | 0,053 |

Topluluk yapısı sınıflayıcıların ayrılık oranları ile doğruluk oranları grafiksel olarak Şekil 4.4'te verilmiştir. Şekilde düşük ayrılık, yüksek doğruluk oranı kırmızı

nokta ile belirtilen Kullanıcı A'ya ait Yapay Arı Kolonisi ile gerçekleştirilen Topluluk EKK-DVM sınıflayıcı gösterilmektedir.



Şekil 4.4. Topluluk yapısı sınıflayıcılara ait θ ayrılık ölçümü

Çizelge 4.13'te Kullanıcı A'ya ait DVM sınıflayıcı ile gerçekleştirilen sınıflandırma işlemine ait ölçümler verilmiştir. %90,333 doğruluk oranı ve 0,770 F skor değeri ile BPSE algoritması sonucu seçilen 16 kanal ile gerçekleştirilen sınıflama en iyi sonucu vermiştir. Bu sonucu, %90,000 doğruluk oranı ve 0,768 F skor değeri ile GA sonucu seçilen 36 kanal sınıflama takip etmektedir.

Çizelge 4.13. Kullanıcı A için DVM sınıflayıcı performans ölçümleri

| Algoritma | Kanal Sayısı | % DOĞ | KSN | HSS | Fskor | YPO | GA ₉₅ |
|-----------|--------------|--------|-------|-------|-------|-------|------------------|
| GA | 64 | 88,167 | 0,585 | 0,995 | 0,737 | 0,141 | 0,118±0,018 |
| | 8 | 83,583 | 0,504 | 0,940 | 0,656 | 0,185 | 0,164±0,021 |
| | 16 | 87,833 | 0,579 | 0,985 | 0,730 | 0,143 | 0,122±0,018 |
| | 36 | 90,000 | 0,626 | 0,995 | 0,768 | 0,119 | 0,100±0,017 |
| BPSE | 8 | 86,833 | 0,563 | 0,945 | 0,705 | 0,147 | 0,132±0,019 |
| | 16 | 90,333 | 0,638 | 0,970 | 0,770 | 0,110 | 0,097±0,017 |
| BYAK | 29 | 89,417 | 0,614 | 0,985 | 0,756 | 0,124 | 0,106±0,017 |
| | 8 | 82,000 | 0,479 | 0,935 | 0,634 | 0,203 | 0,180±0,022 |
| | 16 | 87,250 | 0,569 | 0,975 | 0,718 | 0,148 | 0,128±0,019 |
| | 31 | 88,500 | 0,593 | 0,985 | 0,741 | 0,135 | 0,115±0,018 |

Çizelge 4.14'te Kullanıcı B'ye ait DVM sınıflayıcı ile gerçekleştirilen sınıflandırma işlemine ait ölçümler verilmiştir. %78,000 doğruluk oranı ve 0,601 F skor değeri ile GA sonucu seçilen 16 kanal ile gerçekleştirilen sınıflama en iyi sonucu vermiştir. Bu sonucu, %77,833 doğruluk oranı ve 0,599 F skor değeri ile BPSE sonucu seçilen 16 kanal sınıflama takip etmektedir.

Çizelge 4.14. Kullanıcı B için DVM sınıflayıcı performans ölçümleri

| Algoritma | Kanal Sayısı | % DOĞ | KSN | HSS | FSkor | YPO | GA ₉₅ |
|-----------|--------------|---------------|--------------|--------------|--------------|--------------|--------------------|
| GA | 64 | 60,083 | 0,293 | 0,990 | 0,453 | 0,477 | 0,399±0,028 |
| | 8 | 76,500 | 0,414 | 0,990 | 0,584 | 0,280 | 0,235±0,024 |
| | 16 | 78,000 | 0,431 | 0,995 | 0,601 | 0,263 | 0,220±0,023 |
| BPSE | 29 | 74,250 | 0,393 | 0,995 | 0,563 | 0,308 | 0,258±0,025 |
| | 8 | 77,083 | 0,420 | 0,990 | 0,590 | 0,273 | 0,229±0,024 |
| | 16 | 77,833 | 0,429 | 0,995 | 0,599 | 0,265 | 0,222±0,024 |
| BYAK | 29 | 75,417 | 0,403 | 0,990 | 0,573 | 0,293 | 0,246±0,024 |
| | 8 | 77,167 | 0,421 | 0,990 | 0,591 | 0,272 | 0,228±0,024 |
| | 16 | 77,000 | 0,420 | 0,995 | 0,591 | 0,275 | 0,230±0,024 |
| | 30 | 76,750 | 0,417 | 0,990 | 0,587 | 0,277 | 0,233±0,024 |

Çizelge 4.15'te Kullanıcı A'ya ait Topluluk DVM sınıflayıcı ile gerçekleştirilen sınıflandırma işlemine ait ölçümler verilmiştir. %95,583 doğruluk oranı ve 0,873 F skor değeri ile BPSE algoritması sonucu seçilen 16 kanal ile gerçekleştirilen sınıflama en iyi sonucu vermiştir. Bu sonucu, %95,500 doğruluk oranı ve 0,73 F skor değeri ile BYAK sonucu seçilen 16 kanal sınıflama takip etmektedir.

Çizelge 4.15. Kullanıcı A için Topluluk DVM sınıflayıcı performans ölçümleri

| Algoritma | Kanal Sayısı | % DOĞ | KSN | HSS | FSkor | YPO | GA ₉₅ |
|-----------|--------------|---------------|--------------|--------------|--------------|--------------|--------------------|
| GA | 64 | 92,750 | 0,729 | 0,900 | 0,805 | 0,067 | 0,073±0,015 |
| | 8 | 95,167 | 0,826 | 0,900 | 0,861 | 0,038 | 0,048±0,012 |
| | 16 | 95,000 | 0,815 | 0,905 | 0,858 | 0,041 | 0,050±0,012 |
| | 36 | 95,167 | 0,806 | 0,935 | 0,866 | 0,045 | 0,048±0,012 |
| BPSE | 8 | 95,500 | 0,841 | 0,900 | 0,870 | 0,034 | 0,045±0,012 |
| | 16 | 95,583 | 0,839 | 0,910 | 0,873 | 0,035 | 0,044±0,012 |
| | 29 | 95,000 | 0,804 | 0,925 | 0,860 | 0,045 | 0,050±0,012 |
| BYAK | 8 | 94,583 | 0,817 | 0,870 | 0,843 | 0,039 | 0,054±0,013 |
| | 16 | 95,500 | 0,826 | 0,925 | 0,873 | 0,039 | 0,045±0,012 |
| | 31 | 95,083 | 0,795 | 0,950 | 0,866 | 0,049 | 0,049±0,012 |

Çizelge 4.16’da Kullanıcı B için topluluk DVM sınıflayıcı sonuçları verilmiştir. %88,167 doğruluk oranı ve 0,731 F skor değeri ile BPSE algoritması sonucu seçilen 8 kanal ile gerçekleştirilen sınıflama en iyi sonucu vermiştir. Bu sonucu, %87,500 doğruluk oranı ve 0,713 F skor değeri ile GA sonucu seçilen 8 kanal sınıflama ve %87,333 doğruluk oranı ve 0,711 F skor değeri ile BYAK sonucu seçilen 8 kanal sınıflama takip etmektedir.

Çizelge 4.16. Kullanıcı B için Topluluk DVM sınıflayıcı performans ölçümleri

| Algoritma | Kanal Sayısı | % DOĞ | KSN | HSS | Fskor | YPO | GA ₉₅ |
|-----------|--------------|---------------|--------------|--------------|--------------|--------------|--------------------|
| GA | 64 | 75,917 | 0,403 | 0,930 | 0,563 | 0,275 | 0,241±0,024 |
| | 8 | 87,500 | 0,578 | 0,930 | 0,713 | 0,136 | 0,125±0,019 |
| | 16 | 84,167 | 0,514 | 0,950 | 0,667 | 0,180 | 0,158±0,021 |
| | 29 | 79,333 | 0,444 | 0,950 | 0,605 | 0,238 | 0,207±0,023 |
| BPSE | 8 | 88,167 | 0,588 | 0,965 | 0,731 | 0,135 | 0,118±0,018 |
| | 16 | 85,000 | 0,528 | 0,955 | 0,680 | 0,171 | 0,150±0,020 |
| | 29 | 81,750 | 0,476 | 0,940 | 0,632 | 0,207 | 0,183±0,022 |
| BYAK | 8 | 87,333 | 0,574 | 0,935 | 0,711 | 0,139 | 0,127±0,019 |
| | 16 | 83,667 | 0,505 | 0,955 | 0,661 | 0,187 | 0,163±0,021 |
| | 30 | 79,167 | 0,442 | 0,950 | 0,603 | 0,240 | 0,208±0,023 |

Çizelge 4.17’de Kullanıcı A için EKK-DVM sınıflama ölçümleri verilmiştir. %93,917 doğruluk oranı ve 0,846 F skor değeri ile GA algoritması sonucu seçilen 36 kanal ile gerçekleştirilen sınıflama en iyi sonucu vermiştir. Bu sonucu, %93,500 doğruluk oranı ve sırasıyla 0,837 ve 0,836 F skor değerleri ile BPSE sonucu seçilen 29 kanal ve BYAK sonucu seçilen 31 kanal sınıflama takip etmektedir.

Çizelge 4.17. Kullanıcı A için EKK-DVM sınıflayıcı performans ölçümleri

| Algoritma | Kanal Sayısı | % DOĞ | KSN | HSS | Fskor | YPO | GA ₉₅ |
|-----------|--------------|---------------|--------------|--------------|--------------|--------------|--------------------|
| GA | 64 | 91,583 | 0,664 | 1,000 | 0,798 | 0,101 | 0,084±0,016 |
| | 8 | 88,667 | 0,598 | 0,980 | 0,742 | 0,132 | 0,113±0,018 |
| | 16 | 91,167 | 0,655 | 0,995 | 0,790 | 0,105 | 0,088±0,016 |
| | 36 | 93,917 | 0,733 | 1,000 | 0,846 | 0,073 | 0,061±0,014 |
| BPSE | 8 | 88,083 | 0,585 | 0,980 | 0,733 | 0,139 | 0,119±0,018 |
| | 16 | 87,333 | 0,569 | 0,990 | 0,723 | 0,150 | 0,127±0,019 |
| | 29 | 93,500 | 0,719 | 1,000 | 0,837 | 0,078 | 0,065±0,014 |
| BYAK | 8 | 78,917 | 0,438 | 0,935 | 0,596 | 0,240 | 0,211±0,023 |
| | 16 | 87,083 | 0,565 | 0,975 | 0,716 | 0,105 | 0,129±0,019 |
| | 31 | 93,500 | 0,721 | 0,995 | 0,836 | 0,077 | 0,065±0,014 |

Çizelge 4.18’de kullanıcı B’ye ait EKK-DVM sınıflama ölçümleri verilmiştir. En yüksek doğruluk oranları %81,250 ile BPSE algoritmasına ait 16 ve 29 kanal ile gerçekleştirilen sınıflama işlemi ile gerçekleşmiştir. Her iki sınıflama işleminde F skor oranı sırasıyla 0,635 ve 0,638 olarak hesaplanmıştır. Bu sonucu, %80,333 doğruluk oranı ve 0,624 F skor değeri ile BYAK sonucu seçilen 16 kanal takip etmektedir.

Çizelge 4.18. Kullanıcı B için EKK-DVM sınıflayıcı performans ölçümleri

| Algoritma | Kanal Sayısı | % DOĞ | KSN | HSS | FSkor | YPO | GA ₉₅ |
|-----------|--------------|---------------|--------------|--------------|--------------|--------------|--------------------|
| GA | 64 | 70,250 | 0,358 | 0,985 | 0,525 | 0,354 | 0,298±0,026 |
| | 8 | 74,917 | 0,398 | 0,985 | 0,567 | 0,298 | 0,251±0,025 |
| | 16 | 79,167 | 0,444 | 0,985 | 0,612 | 0,247 | 0,208±0,023 |
| | 29 | 79,583 | 0,449 | 0,985 | 0,617 | 0,242 | 0,204±0,023 |
| BPSE | 8 | 74,750 | 0,396 | 0,980 | 0,564 | 0,299 | 0,253±0,025 |
| | 16 | 81,250 | 0,470 | 0,975 | 0,634 | 0,220 | 0,188±0,022 |
| | 29 | 81,250 | 0,470 | 0,990 | 0,638 | 0,223 | 0,188±0,022 |
| BYAK | 8 | 79,917 | 0,453 | 0,980 | 0,619 | 0,237 | 0,201±0,023 |
| | 16 | 80,333 | 0,458 | 0,980 | 0,624 | 0,232 | 0,197±0,022 |
| | 30 | 79,167 | 0,444 | 0,990 | 0,613 | 0,248 | 0,208±0,023 |

Çizelge 4.19’da Kullanıcı A’ya ait Topluluk EKK-DVM ile gerçekleştirilmiş sınıflamalara ait ölçümler verilmiştir. %96,250 doğruluk oranı ve 0,892 F skor değeri ile BYAK algoritması sonucu seçilen 8 kanal ile gerçekleştirilen sınıflama en iyi sonucu vermiştir. Bu sonucu, %95,500 doğruluk oranı ve 0,871 F skor değerleri ile BPSE sonucu seçilen 16 kanal sınıflama takip etmektedir.

Çizelge 4.19. Kullanıcı A için Topluluk EKK-DVM sınıflayıcı performans ölçümleri

| Algoritma | Kanal Sayısı | % DOĞ | KSN | HSS | FSkor | YPO | GA ₉₅ |
|-----------|--------------|---------------|--------------|--------------|--------------|--------------|--------------------|
| GA | 64 | 89,083 | 0,624 | 0,870 | 0,727 | 0,105 | 0,109±0,018 |
| | 8 | 94,917 | 0,812 | 0,905 | 0,856 | 0,042 | 0,051±0,012 |
| | 16 | 94,750 | 0,804 | 0,905 | 0,852 | 0,044 | 0,053±0,013 |
| | 36 | 94,583 | 0,800 | 0,900 | 0,847 | 0,045 | 0,054±0,013 |
| BPSE | 8 | 94,000 | 0,776 | 0,900 | 0,833 | 0,052 | 0,060±0,013 |
| | 16 | 95,500 | 0,835 | 0,910 | 0,871 | 0,036 | 0,045±0,012 |
| | 29 | 93,500 | 0,752 | 0,910 | 0,824 | 0,060 | 0,065±0,014 |
| BYAK | 8 | 96,250 | 0,860 | 0,925 | 0,892 | 0,030 | 0,038±0,011 |
| | 16 | 92,917 | 0,731 | 0,910 | 0,811 | 0,067 | 0,071±0,015 |
| | 31 | 92,833 | 0,724 | 0,920 | 0,811 | 0,070 | 0,072±0,015 |

Çizelge 4.20’de Kullanıcı B’ye ait topluluk EKK-DVM ile gerçekleştirilmiş sınıflandırma işlemine ait performans ölçümleri verilmiştir. Çizelgede en yüksek doğruluk oranı %93,583 ile GA sonucu seçilmiş 8 kanala aittir. Bu sonucu %93,417 doğruluk oranını ile BPSE sonucu seçilmiş 8 kanal sınıflama takip etmektedir. İki sınıflamaya ait 0,829 ve 0,827 F skor değerleri çizelgenin en yüksek değerleridir.

Çizelge 4.21’de Kullanıcı A’ya ait DAA sınıflayıcı ölçümleri verilmiştir. Çizelgede en yüksek doğruluk oranı %94,583 ile BPSE sonucu seçilmiş 29 kanala aittir. Bu sonucu, %94,083 doğruluk oranı ile GA sonucu seçilen 36 kanal takip etmektedir. Yine bu iki sınıflayıcıya ait 0,860 ve 0,849 F skor değerleri çizelgenin en yüksek değerleri olarak görülmektedir.

Çizelge 4.20. Kullanıcı B için Topluluk EKK-DVM sınıflayıcı performans ölçümleri

| Algoritma | Kanal Sayısı | % DOĞ | KSN | HSS | Fskor | YPO | GA ₉₅ |
|-----------|--------------|---------------|--------------|--------------|--------------|--------------|--------------------|
| GA | 64 | 74,667 | 0,380 | 0,825 | 0,521 | 0,269 | 0,253±0,025 |
| | 8 | 93,583 | 0,745 | 0,935 | 0,829 | 0,064 | 0,064±0,014 |
| | 16 | 91,917 | 0,689 | 0,940 | 0,795 | 0,085 | 0,081±0,015 |
| BPSE | 29 | 85,667 | 0,542 | 0,910 | 0,679 | 0,154 | 0,143±0,020 |
| | 8 | 93,417 | 0,735 | 0,945 | 0,827 | 0,068 | 0,066±0,014 |
| | 16 | 89,417 | 0,621 | 0,935 | 0,747 | 0,114 | 0,106±0,017 |
| BYAK | 29 | 84,500 | 0,520 | 0,915 | 0,663 | 0,169 | 0,155±0,020 |
| | 8 | 90,667 | 0,656 | 0,925 | 0,768 | 0,097 | 0,093±0,016 |
| | 16 | 90,083 | 0,636 | 0,945 | 0,761 | 0,108 | 0,099±0,017 |
| | 30 | 91,333 | 0,668 | 0,955 | 0,786 | 0,095 | 0,087±0,016 |

Çizelge 4.21. Kullanıcı A için DAA sınıflayıcı performans ölçümleri

| Algoritma | Kanal Sayısı | % DOĞ | KSN | HSS | Fskor | YPO | GA ₉₅ |
|-----------|--------------|---------------|--------------|--------------|--------------|--------------|--------------------|
| GA | 64 | 91,417 | 0,662 | 0,990 | 0,794 | 0,101 | 0,086±0,016 |
| | 8 | 89,500 | 0,622 | 0,945 | 0,750 | 0,115 | 0,105±0,017 |
| | 16 | 89,833 | 0,623 | 0,990 | 0,764 | 0,120 | 0,102±0,017 |
| | 36 | 94,083 | 0,740 | 0,995 | 0,849 | 0,070 | 0,059±0,013 |
| BPSE | 8 | 87,250 | 0,569 | 0,965 | 0,716 | 0,146 | 0,128±0,019 |
| | 16 | 92,583 | 0,695 | 0,990 | 0,816 | 0,087 | 0,074±0,015 |
| | 29 | 94,583 | 0,755 | 1,000 | 0,860 | 0,065 | 0,054±0,013 |
| BYAK | 8 | 89,000 | 0,607 | 0,965 | 0,745 | 0,125 | 0,110±0,018 |
| | 16 | 90,417 | 0,637 | 0,990 | 0,775 | 0,113 | 0,096±0,017 |
| | 31 | 91,583 | 0,664 | 1,000 | 0,798 | 0,101 | 0,084±0,016 |

Çizelge 4.22’de Kullanıcı B’ye ait DAA sınıflayıcıya ait performans ölçümleri verilmiştir. %86,750 doğruluk oranı ve 0,715 F skor değeri ile BPSE algoritması sonucu seçilen 8 kanal ile gerçekleştirilen sınıflama en iyi sonucu vermiştir. Bu sonucu, %86,583 doğruluk oranı ve 0,713 F skor değerleri ile BYAK sonucu seçilen 30 kanal sınıflama takip etmektedir.

Çizelge 4.23’te Kullanıcı A’ya ait topluluk DAA sınıflayıcıya ait performans ölçümleri verilmiştir. %97,250 doğruluk oranı ve 0,919 F skor değeri ile BPSE algoritması sonucu seçilen 29 kanal ile gerçekleştirilen sınıflama en iyi sonucu vermiştir. Bu sonucu, %97,167 doğruluk oranı ve 0,918 F skor değerleri ile BYAK sonucu seçilen 31 kanal sınıflama takip etmektedir.

Çizelge 4.22. Kullanıcı B için DAA sınıflayıcı performans ölçümleri

| Algoritma | Kanal Sayısı | % DOĞ | KSN | HSS | Fskor | YPO | GA ₉₅ |
|-----------|--------------|---------------|--------------|--------------|--------------|--------------|--------------------|
| GA | 64 | 78,583 | 0,436 | 0,975 | 0,603 | 0,252 | 0,214±0,023 |
| | 8 | 84,500 | 0,518 | 0,990 | 0,680 | 0,184 | 0,155±0,020 |
| | 16 | 84,917 | 0,525 | 0,995 | 0,687 | 0,180 | 0,151±0,020 |
| | 29 | 85,250 | 0,531 | 0,995 | 0,692 | 0,176 | 0,148±0,020 |
| BPSE | 8 | 86,750 | 0,557 | 0,995 | 0,715 | 0,158 | 0,133±0,019 |
| | 16 | 85,833 | 0,541 | 0,995 | 0,701 | 0,169 | 0,142±0,020 |
| | 29 | 85,500 | 0,535 | 1,000 | 0,697 | 0,174 | 0,145±0,020 |
| BYAK | 8 | 85,667 | 0,538 | 1,000 | 0,699 | 0,172 | 0,143±0,020 |
| | 16 | 85,250 | 0,531 | 1,000 | 0,693 | 0,177 | 0,148±0,020 |
| | 30 | 86,583 | 0,554 | 1,000 | 0,713 | 0,161 | 0,134±0,019 |


Çizelge 4.23. Kullanıcı A için Topluluk DAA sınıflayıcı performans ölçümleri

| Algoritma | Kanal Sayısı | % DOĞ | KSN | HSS | Fskor | YPO | GA ₉₅ |
|-----------|--------------|---------------|--------------|--------------|--------------|--------------|--------------------|
| GA | 64 | 95,667 | 0,843 | 0,910 | 0,875 | 0,034 | 0,043±0,012 |
| | 8 | 96,000 | 0,869 | 0,895 | 0,882 | 0,027 | 0,040±0,011 |
| | 16 | 96,333 | 0,879 | 0,905 | 0,892 | 0,025 | 0,037±0,011 |
| | 36 | 96,833 | 0,893 | 0,920 | 0,906 | 0,022 | 0,032±0,010 |
| BPSE | 8 | 96,417 | 0,872 | 0,920 | 0,895 | 0,027 | 0,036±0,011 |
| | 16 | 97,000 | 0,898 | 0,925 | 0,911 | 0,021 | 0,030±0,010 |
| | 29 | 97,250 | 0,900 | 0,940 | 0,919 | 0,021 | 0,028±0,009 |
| BYAK | 8 | 95,750 | 0,850 | 0,905 | 0,877 | 0,032 | 0,043±0,011 |
| | 16 | 96,833 | 0,893 | 0,920 | 0,906 | 0,022 | 0,032±0,010 |
| | 31 | 97,167 | 0,888 | 0,950 | 0,918 | 0,024 | 0,028±0,009 |

Çizelge 4.24'te Kullanıcı B'ye ait topluluk DAA sınıflayıcıya ait performans ölçümleri verilmiştir. %96,750 doğruluk oranı ve 0,910 F skor değeri ile BPSE algoritması sonucu seçilen 8 kanal ile gerçekleştirilen sınıflama en iyi sonucu vermiştir. Bu sonucu, %96,500 doğruluk oranı ve 0,900 F skor değerleri ile GA sonucu seçilen 8 kanal sınıflama takip etmektedir.

Çizelge 4.24. Kullanıcı B için Topluluk DAA sınıflayıcı performans ölçümleri

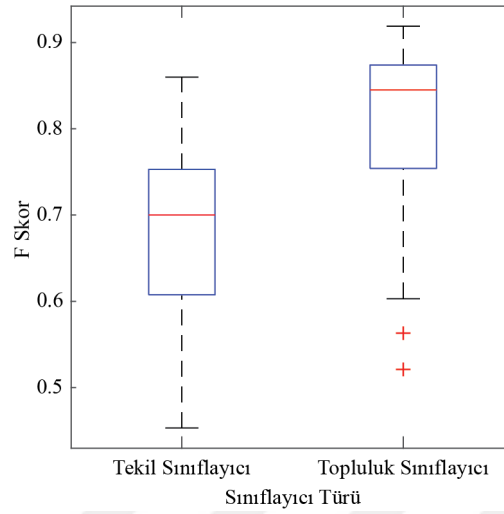
| Algoritma | Kanal Sayısı | % DOĞ | KSN | HSS | Fskor | YPO | GA ₉₅ |
|-----------|--------------|--------|-------|-------|-------|-------|------------------|
| GA | 64 | 91,583 | 0,681 | 0,930 | 0,786 | 0,087 | 0,084±0,016 |
| | 8 | 96,500 | 0,856 | 0,950 | 0,900 | 0,032 | 0,035±0,010 |
| | 16 | 95,083 | 0,793 | 0,955 | 0,866 | 0,050 | 0,049±0,012 |
| BPSE | 29 | 94,917 | 0,798 | 0,930 | 0,859 | 0,047 | 0,051±0,012 |
| | 8 | 96,750 | 0,848 | 0,980 | 0,910 | 0,035 | 0,033±0,010 |
| | 16 | 94,167 | 0,764 | 0,940 | 0,843 | 0,058 | 0,058±0,013 |
| BYAK | 29 | 93,750 | 0,739 | 0,965 | 0,837 | 0,068 | 0,063±0,014 |
| | 8 | 96,333 | 0,845 | 0,955 | 0,897 | 0,035 | 0,037±0,011 |
| | 16 | 96,083 | 0,826 | 0,970 | 0,892 | 0,041 | 0,039±0,011 |
| | 30 | 94,500 | 0,779 | 0,935 | 0,850 | 0,053 | 0,055±0,013 |




Şekil 4.5. Tekil ve topluluk yapısı sınıflayıcıların doğruluk oranları açısından karşılaştırılması

Şekil 4.5 ve Şekil 4.6'da topluluk yapısı sınıflayıcılar ile tekil sınıflayıcıların karşılaştırılması verilmektedir. Gerek bu bölümde verilen çizelgeler gerekse de verilen iki şekil incelendiğinde topluluk yapısı sınıflayıcıların tek bir sınıflayıcıya göre oldukça üstün olduğu görülmektedir. 64 kanal ile gerçekleştirilen sınıflamalara ait uç

değerleri göz ardı ettiğimizde ortalama %95'e varan bir doğruluk oranı Şekil 4.5'te verilen kutu çizimlerinde açıkça görülmektedir.




Şekil 4.6. Tekil ve topluluk yapısı sınıflayıcıların F Skor ölçümü açısından karşılaştırılması



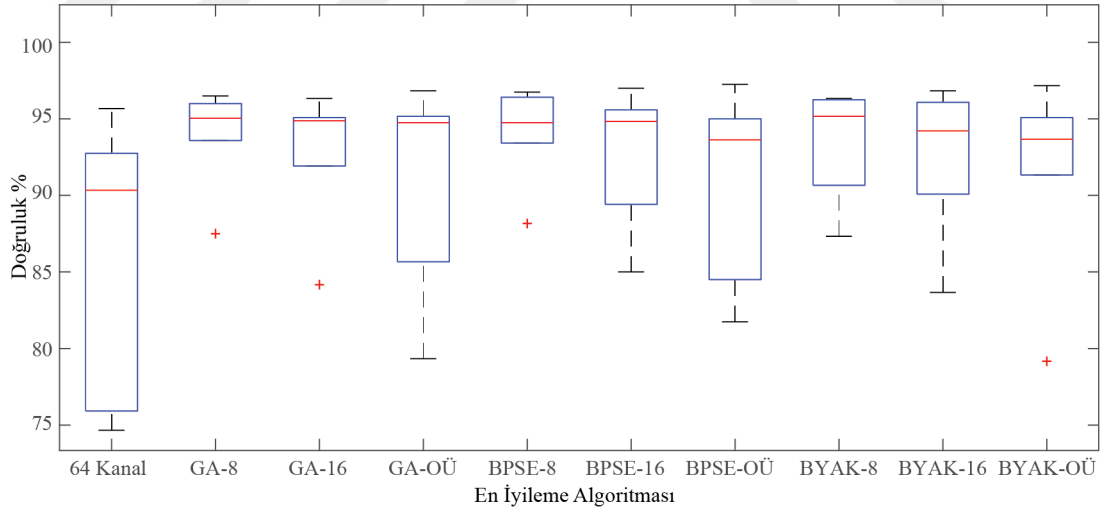
Şekil 4.7. Kullanıcı A ve B için en iyileme algoritmalarının Doğruluk oranı ile karşılaştırılması

Tüm kanal seçimleri ile yapılan tekil sınıflama sonucu elde edilen doğruluk oranları Şekil 4.7'de, F skor değerleri ise Şekil 4.8'te verilen bir kutu grafiği ile özetlenmiştir. Her iki şekilde de kanal seçim algoritmalarının BYAK ile seçilen 8 kanal dışında sınıflama performansını arttırdığı görülmektedir. Sınıflama işlemleri sonucunda doğruluk oranları ve F skor değerleri paralellik göstermektedir.

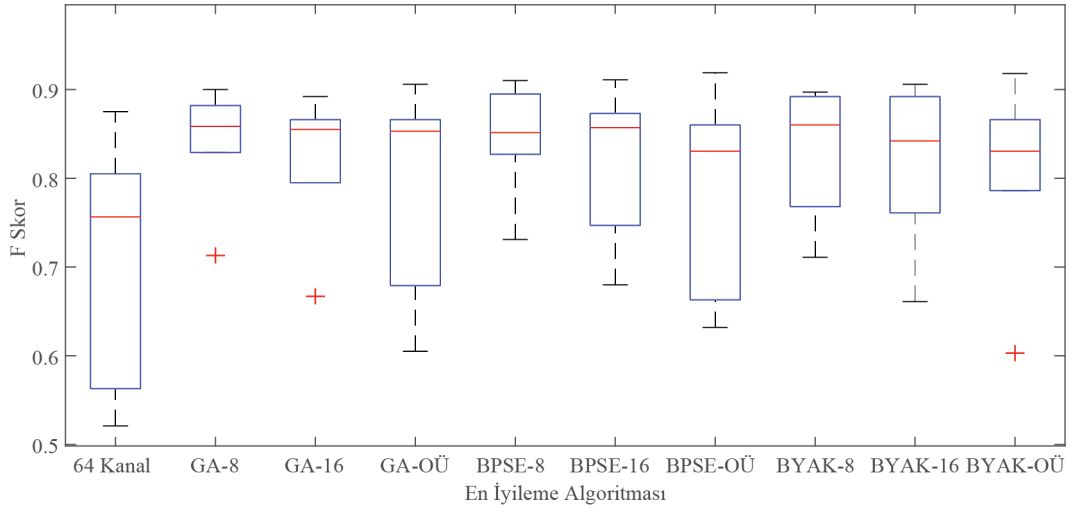


Şekil 4.8. Kullanıcı A ve B için en iyileme algoritmalarının F skor ölçümü ile karşılaştırılması

Tüm kanal seçimleri ile yapılan topluluk sınıflama sonucu elde edilen doğruluk oranları Şekil 4.9’da verilirken, F skor değerleri Şekil 4.10’da kutu grafiği ile özetlenmiştir. Her iki şekilde de kanal seçim algoritmalarının sınıflama performansını arttırdığı görülmektedir. Sınıflama işlemleri sonucunda doğruluk oranları ve F skor değerleri paralellik göstermektedir.



Şekil 4.9. Kullanıcı A ve B için topluluk sınıflayıcılar ile en iyileme algoritmalarının doğruluk oranı ile karşılaştırılması



Şekil 4.10. Kullanıcı A ve B için topluluk sınıflayıcılar ile en iyileme algoritmalarının F skor ölçümü ile karşılaştırılması

5. SONUÇ VE ÖNERİLER

EEG sinyallerinin yapısal olarak karmaşıklığının, gürültüye açık olmasının ve kullanıcıların anlık odaklanma durumlarının, sınıflayıcı performansına doğrudan ve negatif bir etki yaptığı görülmüştür. Buna bağlı olarak, tekil olarak gerçekleştirilen sınıflama işleminin performansının düşük olduğu gözlenmiştir. Tüm sınıflandırma işlemlerinin ortalaması incelendiğinde tek model ile tasarlanan sistemde en düşük doğruluk oranı %60 ile gerçekleşirken (Kullanıcı B), topluluk yapısında aynı veri %76 olarak gerçekleşmiştir. Tekil model 64 kanal için ortalama %80 doğruluk oranı sağlamaktadır. Topluluk yapısı ve çoğunluk oylama ile gerçekleştirilen modelde bu oran ortalama %87'ye yaklaşmıştır.

Sınıflandırma öncesi uygulanan kanal seçme algoritmaları da sistem performansına tüm seçimlerde olumlu katkı sağlamıştır. Özellikle kanal seçme algoritması topluluk yapısı sınıflayıcı ile birleştirildiğinde %97,25 (Kullanıcı A – Topluluk DAA sınıflayıcı ve BPSE 29 kanal) doğruluk oranı sağlanmıştır.

Özellikle kanal seçme algoritmaları sonucunda seçilen ve 8'e düşürülen kanal sayıları da yadsınamaz bir performans artışına sebep olmuştur. 64 kanal için ortalama %86 olan doğruluk oranı GA ve BPSE ile %94, BYAK ile %93,5 oranlarına çıkmıştır. 8 Kanal ile gerçekleştirilen sınıflamalarda her üç algortmada da doğruluk oranı hem 16 kanaldan hem de ortalama üstü kanal sayısından daha iyi bir performans sağlamıştır.

Her iki kullanıcı ve her üç kanal seçim yöntemi en sık seçilen 16 kanal ele alınarak incelendiğinde Cz, CPz, Pz, P8 ve PO8 kanallarının altışar kez seçildiği görülmektedir. Bu durum beynin arka merkez bölgesinin ve arka sağ yarım küresinin, özellikle parietal ve parietal-okipital bölgenin, daha aktif kullanıldığını göstermektedir. Bununla birlikte FC3 ve C3 kanalları da beşer kez seçilmiştir. Bu durum yine merkez bölgenin aktivitesine işaret etmektedir. Ancak her iki kullanıcı için seçilen kanalların farklı olması kişisel farklılıkların beynin aktif olan bölgesini etkilediğini göstermektedir. Dolayısı ile herkes için ortak bir elektrot setinden bahsetmek mümkün olmayacaktır. Böyle bir set tesadüfi olarak bazı kullanıcılarda

başarım artışı sağlarken, bazı kullanıcılarda tam tersi başarımla düşüşüne neden olabilecektir. Kullanıcılara ait daha fazla demografik bilgi bu yorumlarına daha kesin yapılmasına olanak sağlayacaktır. Örneğin; kullanıcılara ait, sağ el veya sol el kullanımına ait bilgi bulunmamaktadır. Bu nedenle beynin sağ veya sol yarım küresinin daha aktif olmasına, el kullanımının etkisinin olup olmadığı konusunda yorum yapmamıza engel olmaktadır.

Elde edilen bu bulgular Bölüm 2’de detaylı verilen alanyazın ile kıyaslandığında paralellik göstermektedir. Alanyazınla benzer şekilde kanal seçimi performansına olumlu etki sağlarken, sınıflayıcı olarak kullanılan DAA’da performansı olumlu yönde arttırmıştır. Bu kapsamda ilerleyen çalışmalarda DAA’nın türevi olan Bayes DAA da sınıflayıcı olarak incelenebilir.

Bölüm 4.2’de verilen kutu grafiklerde de görüldüğü üzere kanal seçimi sonucu elde edilen sonuçların doğruluk oranı aralığının daha az olduğu, yani sonuçların daha kararlı olduğu görülmektedir.

Yapılan çalışmadan elde edilen bulgular, gelecekte tasarlanacak sistemler için iyi bir temel oluşturacaktır.

Gelecek çalışmalarda kurulacak bir deney düzeneği ile gerçekleştirilecek çevrimiçi kayıtlar ile sistem güncellenmesi gerçekleştirilebilir. Yine farklı derin öğrenme modelleri ve sinir ağları vasıtası ile sistem performans ve kararlılığı üzerine çalışmalar gerçekleştirilebilir. Sinyal üzerinde yapılacak ön işleme basamaklarında güncelleme yapılabilir. Özellikle topluluk yapısı daha derinlemesine incelenerek tek sınıflayıcı bir yapı yerine birden farklı sınıflayıcı modelinin bulunduğu bir sistem tasarlanabilir. Böylece çeşitlilik artırılarak çeşitlilik/doğruluk oranı gelişebilir.

Kanal seçimi algoritması ile kişiye özel BBA sistemi tasarlanarak, performans artışı sağlanırken maliyet azaltımı sağlanabilir.

Tüm bu çalışma ışığında, son birkaç on yılda hızlı bir gelişim gösteren BBA sistemleri, engelli bireylerin sosyal katılımını artıracak, düşük maliyetli, yüksek performanslı sistemler haline gelecektir.

6. KAYNAKLAR

- Acharya JN, Hani A, Cheek J, Thirumala P, ve Tsuchida TN (2016) "American Clinical Neurophysiology Society Guideline 2: Guidelines for Standard Electrode Position Nomenclature", *Journal Of Clinical Neurophysiology*, 33 (4): 308–311.
- Akyol S ve Alataş B (2012) "Güncel Sürü Zekâsı Optimizasyon Algoritmaları", *Nevşehir Üniversitesi Fen Bilimleri Enstitü Dergisi*, 1: 36–50.
- Alotaiby T, El-Samie FEA, Alshebeili SA, ve Ahmad I (2015) "A Review of Channel Selection Algorithms for EEG Signal Processing", *EURASIP Journal on Advances in Signal Processing*, 2015 (1): 66.
- Alpaydın E (2014) *Introduction to Machine Learning*, 3. Baskı, The MIT Press, Massachusetts.
- Arora JS (2016) *Introduction to Optimum Design*, 4. Baskı, Academic Press is an imprint of Elsevier, Iowa City.
- Astrand E, Wardak C, ve Ben Hamed S (2014) "Selective Visual Attention to Drive Cognitive Brain–Machine Interfaces: From Concepts to Neurofeedback and Rehabilitation Applications", *Frontiers in Systems Neuroscience*, 8 (144): 1–16.
- Ayhan S ve Erdoğan Ş (2014) "Destek Vektör Makineleriyle Sınıflandırma Problemlerinin Çözümü İçin Çekirdek Fonksiyonu Seçimi", *Eskişehir Osmangazi Üniversitesi İibf Dergisi*, 9 (1): 175–198.
- Berger H (1929) "Über Das Elektrenkephalogramm Des Menschen", *Archiv Für Psychiatrie Und Nervenkrankheiten*, 87 (1): 527–570.
- Bingöl H ve Alataş B (2015) "Metasezgisel Optimizasyon Tekniklerine Spor Tabanlı Yeni Bir Yaklaşım: Lig Şampiyonası Algoritması", *Fırat Üniv. Fen Bilimleri Dergisi*, 27 (1): 1–11.
- How to Report Classifier Performance with Confidence Intervals, <https://machinelearningmastery.com/report-classifier-performance-confidence-intervals/>, 5 Şubat 2019.
- Cabrera AR (2009) *Feature Extraction and Classification for Brain-Computer Interfaces*, 1. Baskı, Aalborg University, Aalborg.
- Cecotti H ve Graser A (2011) "Convolutional Neural Networks for P300 Detection with Application to Brain-Computer Interfaces", *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 33 (3): 433–445.

- Ceryan N (2016) "En Küçük Kareler Destek Vektör Makineleri (LS-SVM) Kullanarak Kaya Malzemesi Tanjant Elastisite Modülünün Tahmini", *Bulletin For Earth Sciences*, 37 (2): 121–138.
- Chaudhary U, Xia B, Silvoni S, Cohen LG, ve Birbaumer N (2017) "Brain–Computer Interface–Based Communication in the Completely Locked-In State", *PLoS Biology*, 15 (1): 1–25.
- Cuntai G, Thulasidas M, ve Jiankang W (2004) "High Performance P300 Speller for Brain-Computer Interface", *IEEE International Workshop on Biomedical Circuits and Systems*, 2004, 1-3/Aralık/2004, Singapore.
- Davis PA (1939) "Effects Of Acoustic Stimuli On The Waking Human Brain", *Journal of Neurophysiology*, 2 (6): 494–499.
- De Brabanter K, Ojeda F, Alzate C, De Brabanter J, Pelckmans K, Moor B De, Vandewalle J, Suykens JAK, ve Karsmakers P (2010) "LS-SVMlab Toolbox User's Guide Version 1.8", : ESAT-SISTA, K.U.Leuven (Leuven, Belgium).
- Delorme A ve Makeig S (2004) "No TEEGLAB: An Open Source Toolbox for Analysis of Single-Trial EEG Dynamics Including Independent Component Analysis Itle", *Journal of Neuroscience Methods*, 134: 9–21.
- Decimation, The MathWorks, Inc., <https://www.mathworks.com/help/signal/ref/decimate.html>, 25 Haziran 2019.
- Donchin E, Spencer KM, ve Wijesinghe R (2000) "The Mental Prosthesis: Assessing the Speed of a P300-Based Brain-Computer Interface", *IEEE Transactions on Rehabilitation Engineering*, 8 (2): 174–179.
- Engin O ve Döylen A (2004) "Artificial Immune Systems and Applications in Industrial Problems", 17 (1): 71–84.
- Farwell LA ve Donchin E (1988) "Talking off the Top of Your Head: Toward a Mental Prosthesis Utilizing Event-Related Brain Potentials", *Electroencephalography and Clinical Neurophysiology*, 70 (6): 510–523.
- Fazel-Rezai R ve Abhari K (2009) "A Region-Based P300 Speller for Brain-Computer Interface", *Canadian Journal of Electrical and Computer Engineering*, 34 (3): 81–85.
- Fira M ve Goras L (2016) "On Compressed Sensing for EEG Signals - Validation with P300 Speller Paradigm", *2016 International Conference on Communications (COMM)*, 6-11/Haziran/2016, Bucharest.
- Fouad MM, Amin KM, El-Bendary N, ve Hassanien AE (2015) *Brain Computer Interface: A Review, Brain-Computer Interfaces: Current Trends and Applications*, Springer International Publishing, Cham.
- Galambos R ve Sheatz GC (1962) "An Electroencephalography Study of Classical Conditioning", *American Journal of Physiology*, 203 (1): 173–184.

- Garrett D, Peterson DA, Anderson CW, ve Thaut MH (2003) "Comparison of Linear, Nonlinear, and Feature Selection Methods for EEG Signal Classification", IEEE Transactions on Neural Systems and Rehabilitation Engineering, 11 (2): 141–144.
- Gesualdi A da R ve França AI (2011) "Event-Related Brain Potentials (ERP): An Overview", Neurociência Da Linguagem, 7 (2): 24–42.
- Gonzalez A, Nambu I, Hokari H, ve Wada Y (2014) "EEG Channel Selection Using Particle Swarm Optimization for the Classification of Auditory Event-Related Potentials", The Scientific World Journal, 2014: 1–11.
- Goutte C ve Gaussier E (2005) "A Probabilistic Interpretation of Precision, Recall and F-Score, with Implication for Evaluation", ECIR 2005: Advances in Information Retrieval, 21-23/Mart/2005, Berlin, Heidelberg.
- Hansen LK ve Salamon P (1990) "Neural Network Ensembles", IEEE Transactions on Pattern Analysis and Machine Intelligence, 12 (10): 993–1001.
- Hochberg LR, Bacher D, Jarosiewicz B, Masse NY, Simeral JD, Vogel J, Haddadin S, Liu J, Cash SS, van der Smagt P, ve Donoghue JP (2012) "Reach and Grasp by People with Tetraplegia Using a Neurally Controlled Robotic Arm", Nature, 485: 372–377.
- Holland JH (1975) Adaptation in Natural and Artificial Systems, 1. Baskı, University of Michigan Press, Ann Arbor.
- İşçi Ö ve Korukoğlu S (2003) "Genetik Algoritma Yaklaşımı ve Yöneylem Araştırmasında Bir Uygulama", Yönetim ve Ekonomi: Celal Bayar Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi, 10 (2): 191–208.
- Jin J, Allison BZ, Brunner C, Wang B, Wang X, Zhang J, Neuper C, ve Pfurtscheller G (2010) "P300 Chinese Input System Based on Bayesian LDA", Biomedizinische Technik/Biomedical Engineering, 55 (1): 5–18.
- Jung T-P, Makeig S, Westerfield M, Townsend J, Courchesne E, ve Sejnowski T (2001) "Analysis and Visualization of Single-trial Event-related Potentials", 14: 166–185.
- Karaboga D (2005) "An Idea Based On Honey Bee Swarm For Numerical Optimization", Technical Report,.
- Karaboga D ve Akay B (2009) "A Comparative Study of Artificial Bee Colony Algorithm", Applied Mathematics and Computation, 214 (1): 108–132.
- Kavzoğlu T ve Çölkesen İ (2010) "Destek Vektör Makineleri İle Uydu Görüntülerinin Sınıflandırılmasında Kernel Fonksiyonlarının Etkilerinin İncelenmesi", Harita Dergisi, 144: 73–82.
- Kaya S ve Fiğlalı N (2016) "Çok Amaçlı Optimizasyon Problemlerinde Pareto Optimal Kullanımı", Social Sciences Research Journal, 5 (2): 9–18.

- Kee C-Y, Ponnambalam SG, ve Loo C-K (2015) "Multi-Objective Genetic Algorithm as Channel Selection Method for P300 and Motor Imagery Data Set", *Neurocomputing*, 161: 120–131.
- Kennedy J ve Eberhart R (1995) "Particle Swarm Optimization", *Proceedings of ICNN'95 - International Conference on Neural Networks*, 27 Kasım - 1 Aralık/1995, Perth.
- Khalid MB, Rao NI, Rizwan-i-Haque I, Munir S, ve Tahir F (2009) "Towards a Brain Computer Interface Using Wavelet Transform with Averaged and Time Segmented Adapted Wavelets", 2009 2nd International Conference on Computer, Control and Communication, 17-18/Şubat/2009, Karachi.
- Kim H-C, Pang S, Je H-M, Kim D, ve Yang Bang S (2003) "Constructing Support Vector Machine Ensemble", *Pattern Recognition*, 36 (12): 2757–2767.
- Kıran MS (2014) Optimizasyon Problemlerinin Çözümü İçin Yapay Arı Kolonisi Algoritması Tabanlı Yeni Yaklaşımlar, Doktora Tezi, Selçuk Üniversitesi Fen Bilimleri Enstitüsü, Konya.
- Kong W, Guo S, Long Y, Peng Y, Zeng H, Zhang X, ve Zhang J (2018) "Weighted Extreme Learning Machine for P300 Detection with Application to Brain Computer Interface", *Journal of Ambient Intelligence and Humanized Computing*, (Doi: 10.1007/s12652-018-0840-1).
- Kübler A ve Birbaumer N (2008) "Brain-Computer Interfaces and Communication in Paralysis: Extinction of Goal Directed Thinking in Completely Paralyzed Patients?", *Clinical Neurophysiology: Official Journal of the International Federation of Clinical Neurophysiology*, 119 (11): 2658–2666.
- Kuncheva LI ve Whitaker CJ (2003) "Measures of Diversity in Classifier Ensembles and Their Relationship with the Ensemble Accuracy", *Machine Learning*, 51: 181–207.
- Kundu S ve Ari S (2017) "Score Normalization of Ensemble SVMs for Brain-Computer Interface P300 Speller", 2017 8th International Conference on Computing, Communication and Networking Technologies (ICCCNT), 3-5/Temmuz/2017, IIT Delhi.
- Londhe ND ve Ghosh S (2016) "Binary DE-Based Channel Selection and Weighted Ensemble of SVM Classification for Novel Brain-Computer Interface Using Devanagari Script-Based P300 Speller Paradigm AU - Chaurasiya, Rahul Kumar", *International Journal of Human-Computer Interaction*, 32 (11): 861–877.
- Luck SJ (2005) *An Introduction to the Event-Related Potential Technique*, 1. Baskı, MIT Press, Cambridge Massachusetts.
- Martínez-Cagigal V ve Hornero R (2017) "Selección de Canales En Sistemas BCI Basados En Potenciales P300 Mediante Inteligencia de Enjambre", *Revista Iberoamericana de Automática e Informática Industrial RIAI*, 14 (4): 372–383.

- McFarland DJ ve Wolpaw JR (2017) "EEG-Based Brain-Computer Interfaces", *Current Opinion in Biomedical Engineering*, 4: 194-200.
- Mirjalili S ve Lewis A (2013) "S-Shaped versus V-Shaped Transfer Functions for Binary Particle Swarm Optimization", *Swarm and Evolutionary Computation*, 9: 1-14.
- Morris CG (1996) *Understanding Psychology*, 3. Baskı, Prentice Hall, New Jersey.
- Nicolas-Alonso LF ve Gomez-Gil J (2012) "Brain Computer Interfaces, a Review", *Sensors (Basel, Switzerland)*, 12 (2): 1211-1279.
- Niedermeyer E, Da Silva FL, Niedermeyer E, ve Lopes Da Silva FH (2004) *Electroencephalography : Basic Principles, Clinical Applications, and Related Fields*, Wolters Kluwer, Philadelphia.
- Optimizasyon, Türk Dil Kurumu, <http://sozluk.gov.tr/>, 25 Haziran 2019.
- P300 Speller Paradigm, <http://www.bbc.de/competition/ii/>, 3 Şubat 2018.
- Pan J, Li Y, Gu Z, ve Yu Z (2013) "A Comparison Study of Two P300 Speller Paradigms for Brain-Computer Interface", *Cognitive Neurodynamics*, 7 (6): 523-529.
- Rakotomamonjy A ve Guigue V (2008) "BCI Competition III: Dataset II- Ensemble of SVMs for BCI P300 Speller", *IEEE Transactions on Biomedical Engineering*, 55 (3): 1147-1154.
- Rao SS (2009) *Engineering Optimization - Theory and Practice*, 4. Baskı, John Wiley & Sons, Inc., New Jersey.
- Sangün L (2007) *Temel Bileşenler Analizi, Ayırma Analizi, Kümeleme Analizleri Ve Ekolojik Verilere Uygulanması Üzerine Bir Araştırma*, Doktora Tezi, Çukurova Üniversitesi Fen Bilimleri Enstitüsü, Adana.
- Saed Sayad, *Linear Discriminant Analysis*, <http://www.saedsayad.com/lda.htm>, 5 Mayıs 2019.
- Schalk Lab, BCI2000, <http://www.schalklab.org/research/bci2000>, 3 Şubat 2018.
- Seeck M, Koessler L, Bast T, Leijten F, Michel C, Baumgartner C, He B, ve Beniczky S (2017) "The Standardized EEG Electrode Array of the IFCN", *Clinical Neurophysiology*, 128 (10): 2070-2077.
- Sengupta S, Basak S, ve Peters R (2018) "Particle Swarm Optimization: A Survey of Historical and Recent Developments with Hybridization Perspectives", *Machine Learning and Knowledge Extraction*, 1 (1): 157-191.
- Sur S ve Sinha VK (2009) "Event-Related Potential: An Overview", *Industrial Psychiatry Journal*, 18 (1): 70-73.

- Suykens JAK, Vandewalle J, ve De Moor B (2001) "Optimal Control by Least Squares Support Vector Machines", *Neural Networks*, 14 (1): 23–35.
- Sürü, Türk Dil Kurumu, <http://sozluk.gov.tr/>, 25 Haziran 2019.
- Tang EK, Suganthan PN, ve Yao X (2006) "An Analysis of Diversity Measures", *Machine Learning*, 65 (1): 247–271.
- Teplan M (2002) "Fundamental of EEG Measurement", *Measurement Science Review*, 2 (2): 1–11.
- U.S. Census Bureau, UNIVAC I, https://www.census.gov/history/www/innovations/technology/univac_i.html, 4 Temmuz 2018.
- Wang P, Shen J-Z, ve Shi J-H (2010) "P300 Detection Algorithm Based on Fisher Distance", *I.J.Modern Education and Computer Science*, 2: 9–17.
- Xiaofeng S, Guoqiang X, Furao S, ve Jinxi Z (2015) "Solving the Data Imbalance Problem of P300 Detection via Random Under-Sampling Bagging SVMs", *2015 International Joint Conference on Neural Networks (IJCNN)*, 11-16/Haziran/2015, Killarney.
- Yang ZR (2010) *Machine Learning Approaches to Bioinformatics*, 1. Baskı, World Scientific Publishing Co Pte Ltd, Singapore.
- Yazar I, Yavuz HS, ve Çay MA (2009) "Temel Bileşen Analizi Yönteminin Ve Bazı Klasik Ve Robust Uyarlamalarının Yüz Tanıma Uygulamaları", *Eskişehir Osmangazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 22 (1): 49–63.
- Yazgan E ve Korürek M (1996) *Tıp Elektronikliği*, 1. Baskı, İTÜ, İstanbul.
- Ye F, Shi Z, ve Shi Z (2009) "A Comparative Study of PCA, LDA and Kernel LDA for Image Classification", *2009 International Symposium on Ubiquitous Virtual Reality*, 8-11/Temmuz/2009, Gwangju.
- Yüksel H, Çalışkan F, ve Dayık M (2016) "Genetik Algoritmaların Tasarım Sürecinde Kullanılması", *Teknik Bilimler Dergisi*, 6 (2): 21–27.

7. ÖZGEÇMİŞ

Adı Soyadı : Murat ARICAN

Doğum Yeri ve Tarihi : 15/07/1983

Lisans Üniversite : Gazi Üniversitesi
Teknik Eğitim Fakültesi
Elektronik Öğretmenliği

Bolu Abant İzzet Baysal Üniversitesi
Mühendislik Mimarlık Fakültesi
Elektrik – Elektronik Mühendisliği

Elektronik posta : muratarican@gmail.com

İletişim Adresi : İzzet Baysal Cd. Özcan Sokak. Ceylankent
Sitesi B Blok 34/2 Merkez Bolu

Yayın Listesi :

Makale

Arıcan M ve Polat K (2019) “Pairwise and Variance Based Signal Compression Algorithm (PVBSC) in The P300 Based Speller Systems Using EEG Signals”, Computer Methods and Programs in Biomedicine, 176:149-157

Bildiri

Arıcan M ve Polat K (2019) “Comparison of The Performances of Selected EEG Electrodes With Optimization Algorithms in P300 Based Speller Systems”, 5th The Scientific Meeting on Electrical-Electronics & Biomedical Engineering & Computer Science EBBT’2019, 24-26 Nisan 2019, İstanbul.

Arıcan M ve Polat K (2018) “Neighborhood Based EEG Compression Method on P300 Speller Systems”, 4th The Scientific Meeting on Electrical-Electronics & Biomedical Engineering & Computer Science EBBT’2018, 18-19 Nisan 2018, İstanbul.

Arıcan M ve Polat K (2018) “A Novel Fetal ECG Signal Compression Method: Variance and Neighboring Based Data Compression”, 26th Signal Processing and Communications Applications Conference (SIU 2018), 2-5 Mayıs 2018, İzmir.

Avcı K, Arıcan M ve Polat K (2018) “Machine Learning Based Classification of Violin and Viola Instrument Sounds for The Same Notes”, 26th Signal Processing and Communications Applications Conference (SIU 2018), 2-5 Mayıs 2018, İzmir.

Arıcan M, Ünal Y ve Polat K (2018) “Usage of Different Machine Learning Algorithms in The Classification of Epileptic Seizure Based on EEG Signals Without Feature Extraction”, 4th International Conference on Engineering and Natural Sciences (ICENS 2019), 2-6 Mayıs 2018, Kyiv.

Arıcan M, Cömert Z, Kocamaz AF ve Polat K (2018) “Analysis of Fetal Heart Rate Signal Based on Neighborhood-Based Variance Compression Method”, International Conference on Artificial Intelligence and Data Processing'18 (IDAP 2018), 28-30 Eylül 2018, Malatya.