

T.C.
BANDIRMA ONYEDİ EYLÜL ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

YÜKSEK LİSANS TEZİ

**OTİZM SPEKTRUM BOZUKLUĞUNUN FONKSİYONEL MANYETİK
REZONANS GÖRÜNTÜLERİNE DAYALI MAKİNE ÖĞRENMESİ
TEKNİKLERİ İLE TEŞHİSİ**

Muhammed ALİ BAYRAM

Elektrik Elektronik Mühendisliği Anabilim Dalı

Elektrik Elektronik Mühendisliği Programı

TEMMUZ 2023

T.C.
BANDIRMA ONYEDİ EYLÜL ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

YÜKSEK LİSANS TEZİ

**OTİZM SPEKTRUM BOZUKLUĞUNUN FONKSİYONEL MANYETİK
REZONANS GÖRÜNTÜLERİNE DAYALI MAKİNE ÖĞRENMESİ
TEKNİKLERİ İLE TEŞHİSİ**

Muhammed ALİ BAYRAM

DANIŞMAN
Prof. Dr. Feyzullah TEMURTAŞ
II. DANIŞMAN
Doç. Dr. İlyas ÖZER

Elektrik Elektronik Mühendisliği Anabilim Dalı

Elektrik Elektronik Mühendisliği Programı

TEMMUZ 2023

ONAY

Muhammed Ali BAYRAM tarafından hazırlanan “**Otizm Spektrum Bozukluğunun Fonksiyonel Manyetik Rezonans Görüntülerine Dayalı Makine Öğrenmesi Teknikleri ile Teşhisi**” adlı tez çalışması 10/07/2023 tarihinde yapılan sınavla aşağıdaki jüri tarafından oybirliği/oyçokluğu ile Bandırma Onyedü Eylül Üniversitesi Fen Bilimleri Enstitüsü Elektrik Elektronik Mühendisliği Anabilim Dalı’nda YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

Jüri Üyeleri

İmza

Ünvanı, Adı ve Soyadı

(Danışman)

Ünvanı, Adı ve Soyadı

(Üye)

Ünvanı, Adı ve Soyadı

(Üye)

Ünvanı, Adı ve Soyadı

(Üye) (varsa)

Ünvanı, Adı ve Soyadı

(Üye) (varsa)

Bu tezin kabulü, Fen Bilimleri Enstitüsü Yönetim Kurulu’nun .../.../...gün ve .../... sayılı kararı ile onaylanmıştır.

Doç. Dr. Abdullah YEŞİL

Enstitü Müdürü

BANDIRMA ONYEDİ EYLÜL ÜNİVERSİTESİ FEN BİLİMLERİ ENSTİTÜSÜ
YÜKSEK LİSANS TEZİ
ETİK BEYANI

Bandırma Onyedi Eylül Üniversitesi Fen Bilimleri Enstitüsü tez yazım kılavuzuna göre hazırlamış olduğum “**Otizm Spektrum Bozukluğunun Fonksiyonel Manyetik Rezonans Görüntülerine Dayalı Makine Öğrenmesi Teknikleri ile Teşhisi**” adlı tezimin özgün bir çalışma olduğunu, tez hazırlanırken tüm aşamalarda bilimsel etik ilkelerine uygun davrandığımı, tez kapsamında sunulan tüm verileri bilimsel etik ilkelerine uygun elde ettiğimi, tezde faydalandığım tüm eserlere atıf yaptığımı ve kaynaklar kısmında bu eserleri gösterdiğimi beyan ederim. 10/07/2023

Muhammed Ali BAYRAM
İmza

ÖNSÖZ

Beyin hasarları insan yaşamını etkileyen önemli rahatsızlıklardır. Bu hasarlardan bazıları ilaç tedavisi gibi yöntemlerle tamamen giderilebilmektedir. Öte yandan Alzaymır, Parkinson ve Multipl Skleroz ve Otizm Spektrum Bozukluğu (OSB) gibi hastalıklar sonucunda oluşan hasarların bilinen kalıcı bir tedavisi bulunmamaktadır. Bu tip rahatsızlıklarda genellikle hastalığın ilerleyişini yavaşlatmaya yönelik tedaviler uygulanmaktadır. Bu nedenle davranışsal bozukluklar meydana gelmeden önce hastalığın erken evrede teşhisi oldukça önemlidir.

Makine öğrenmesi modellerine dayalı radyomikler, bilgisayar destekli teşhiste oldukça popüler hale gelmiştir ve son yıllarda birçok klinik görevlerde uzmanlarından daha iyi performans göstermiştir. Spesifik olarak, yapay zekaya (artificial intelligence-AI) dayalı radyomik modeller, tıbbi verileri kullanarak OSB gibi klinik görevleri tahmin edebilirler. Manyetoensefalografi (MEG), elektroensefalografi (EEG), pozitron emisyon tomografisi (PET) ve dinlenme durumu fonksiyonel manyetik rezonans görüntüleme (resting-state functional magnetic resonance imaging - rs-fMRI) kullanılan yöntemlerden bazılarıdır. rs-fMRI diğer yöntemlerle kıyaslandığında çok daha iyi uzamsal çözünürlük sağlamaktadır. Bunun yanı sıra beyin fonksiyonları hakkında bir zamansal çözünürlük de sağlamaktadır. Noninvasive olan bu yöntemde kandaki oksijen seviyelerinde meydana gelen hareketlilikler takip edilerek beyindeki aktiviteler değerlendirilir. Bu tez çalışmasında, OSB teşhisi için kullanılan radyomik verilere dayalı yeni bir makine öğrenmesi modeli önerilmiştir.

Bu tez çalışması sırasında, tez konusunun belirlenmesinden başlayarak son aşamaya kadar her konuda benden yardımlarını esirgemeyen danışman hocam Sayın Prof. Dr. Feyzullah TEMURTAŞ'a ve Sayın Doç. Dr. İlyas ÖZER'e şükranlarımı sunarım.

Bu günlere gelmemde büyük emekleri olan annem Adalet, babam Abdullah'a, yoğun çalışma temposunda benden maddi ve manevi desteğini esirgemeyen kardeşlerime teşekkür ederim.

Ayrıca bu tez çalışmasında BAP-21-1003-003 numaralı proje kapsamında verdikleri desteklerden dolayı Bandırma Onyedli Eylül Üniversitesi Bilimsel Araştırma Projeleri Birimi'ne teşekkür ederim.

ÖZET
YÜKSEK LİSANS TEZİ

**OTİZM SPEKTRUM BOZUKLUĞUNUN FONKİSYONEL MANYETİK
REZONANS GÖRÜNTÜLERİNE DAYALI MAKİNE ÖĞRENMESİ
TEKNİKLERİ İLE TEŞHİSİ**

Muhammed ALİ BAYRAM

Bandırma Onyedli Eylül Üniversitesi
Fen Bilimleri Enstitüsü
Elektrik Elektronik Mühendisliği Anabilim Dalı

Danışman: Prof. Dr. Feyzullah TEMURTAŞ
İkinci Danışman: Doç. Dr. İlyas ÖZER
Temmuz 2023, 52 sayfa

Beyin hasarları insan hayatını etkileyen çok ciddi sağlık problemleridir. Bu hasarların bir kısmı ilaç tedavisi gibi yöntemlerle tamamen ortadan kaldırılabilmektedir. Öte yandan OSB gibi hastalıkların neden olduğu hasarların bilinen kalıcı bir tedavisi yoktur. Bu tür rahatsızlıklarda genellikle hastalığın ilerlemesini yavaşlatmaya yönelik tedaviler uygulanmaktadır. Bu nedenle, davranış bozuklukları ortaya çıkmadan önce hastalığın erken evrede teşhis edilmesi önemlidir.

Bu çalışmada, OSB'nin rs-fMRI yoluyla tespit edilmesine yönelik bir çalışma sunulmuştur. rs-fMRI beynin işlevi hakkında hem uzamsal hem de zamansal bilgi sağlamaktadır. Ancak fMRI verileri; örneklerin heterojenliği, farklı tarayıcı cihaz veya parametreler kullanılmasından dolayı ölçümler arasındaki varyansların yüksek olması gibi sebeplerden dolayı oldukça karmaşık verilerdir.

Bu çalışma kapsamında ABIDE I veri setinden elde edilen 871 örnek üzerinde OSB ve sağlıklı bireyler ayırt edilmiştir. Bu doğrultuda iki farklı özellik çıkarım yöntemi geliştirilmiş ve farklı sınıflandırma algoritmaları ile sınıflandırılmıştır. İlk yöntemde sınıflandırma işlemi için uzun kısa süreli bellek ağı (long short-term memory-LSTM), evrimsel sinir ağı (convolutional

neural network-CNN) ve hibrit modeller birlikte kullanılmıştır. Bunların yanı sıra farklı özellik çıkarım yöntemiyle çok katmanlı algılayıcı (multi layer perceptron-MLP), k-en yakın komşuluk algoritması (k-nearest neighbour-k-NN), doğrusal ayırım analizi (linear discriminant analysis-LDA), destek vektör makineleri (support vector machines-SVM) kullanılarak sınıflandırma işlemi gerçekleştirilmiştir. Son olarak öznelik seçiminde beynin hangi bölgelerinin daha etkili olduğuna dair bir değerlendirme sunulmuştur. Elde edilen sonuçlar, fMRI ile OSB tespiti için umut vericidir.

Anahtar kelimeler: Otizm Spektrum Bozukluğu, rs-fMRI, Makine Öğrenmesi



ABSTRACT

M.Sc. THESIS

DIAGNOSIS OF AUTISM SPECTRUM DISORDER WITH MACHINE LEARNING TECHNIQUES BASED ON FUNCTIONAL MAGNETIC RESONANCE IMAGES

Muhammed ALİ BAYRAM

Bandırma Onyedi Eylül University

Graduate School of Natural and Applied Sciences

Department of Electrical and Electronics Engineering

Supervisor: Prof. Dr. Feyzullah TEMURTAŞ

Co-Supervisor: Assoc. Prof. Dr. İlyas ÖZER

July 2023, 52 pages

Brain injuries are very serious health problems that affect people's lives. Some of these injuries can be completely reversed with methods such as medication. On the other hand, there is no known permanent treatment for damage caused by diseases such as Autism Spectrum Disorder (ASD). In such disorders, treatments are usually aimed at slowing down the progression of the disease. Therefore, it is important to diagnose the disease at an early stage before behavioural disorders occur.

In this study, we present a study on the detection of ASD through rs-fMRI. rs-fMRI provides both spatial and temporal information about brain function. However, fMRI data are highly complex due to the heterogeneity of the samples, high variances between measurements due to the use of different scanner devices or parameters.

In this study, ASD and healthy individuals were distinguished on 871 samples obtained from The Autism Brain Imaging Data Exchange I (ABIDE I) dataset. Accordingly, two different feature extraction methods were developed and classified with different classification algorithms. In the first method, long short-term memory network (LSTM), convolutional neural network

(CNN) and hybrid models were used together for classification. In addition, different feature extraction methods such as multilayer perceptron (MLP), k-nearest neighbor algorithm (kNN), linear discriminant analysis (LDA), and support vector machines (SVM) were used for classification. Finally, an evaluation of which regions of the brain are more effective in feature selection is presented. The results obtained are promising for ASD detection on fMRI.

Keywords: Autism Spectrum Disorder, rs-fMRI, Machine Learning

İÇİNDEKİLER

	Sayfa
ÖZET	I
ABSTRACT	III
İÇİNDEKİLER.....	V
ŞEKİL LİSTESİ	VII
TABLO LİSTESİ.....	VIII
GRAFİK LİSTESİ.....	IX
SİMGE VE KISALTMA LİSTESİ	X
1. GİRİŞ.....	1
2. MATERYAL VE YÖNTEMLER	8
2.1 MAKİNE ÖĞRENMESİ MODELLERİ.....	8
2.1.1 Çok Katmanlı Algılayıcı.....	8
2.1.2 k – En Yakın Komşu Algoritması	10
2.1.3 Doğrusal Ayrım Analizi	12
2.1.4 Destek Vektör Makinesi Algoritması.....	14
2.1.5 Evrişimsel Sinir Ağı.....	16
2.1.6 Tekrarlayan Sinir Ağı	17
2.1.7 Uzun Kısa Dönemli Bellek Ağları	19
2.2 SELECTKBEST ÖZELLİK SEÇİMİ	21
2.3 KARARLI KÜMELERİN BOOTSTRAP ANALİZİ (BASC) & ÇOK ÖLÇEKLİ ADIMSAL SEÇİM (MSTEP).....	23
2.4 OTİZM BEYİN GÖRÜNTÜLEME VERİ DEĞİŞİMİ (ABIDE) VERİ SETİ	25
2.5 PERFORMANS DEĞERLENDİRME METRİKLERİ.....	26
3. ÖNERİLEN SINIFLANDIRMA YAKLAŞIMLARI	28
3.1 VERİ ÖN İŞLEME ADIMLARI.....	28

3.2 BAĞLANTI MATRİSİ TABANLI ÖZELLİK ÇIKARMA YÖNTEMİ İLE SINIFLANDIRMA	29
3.3 SIFIR DOLGU TABANLI ÖZELLİK ÇIKARMA YÖNTEMİ İLE SINIFLANDIRMA	32
4. SONUÇLAR.....	34
4.1 BAĞLANTI MATRİSİ TABANLI ÖZELLİK ÇIKARMA YÖNTEMİ İLE ELDE EDİLEN SINIFLANDIRMA SONUÇLARI.....	34
4.2 SIFIR DOLGU TABANLI ÖZELLİK ÇIKARMA YÖNTEMİ İLE ELDE EDİLEN SINIFLANDIRMA SONUÇLARI.....	40
4.2.1 Öznitelik Seçiminde Beyin Bölgelerinin Etkisi.....	41
5. TARTIŞMA.....	45
6. KAYNAKLAR	47
ÖZGEÇMİŞ.....	52

ŞEKİL LİSTESİ

<u>Sekil</u>	<u>Sayfa</u>
Şekil 2-1: Çok katmanlı algılayıcı	10
Şekil 2-2: k-en yakın komşu algoritması	12
Şekil 2-3: Doğrusal diskriminant analizi	14
Şekil 2-4: Destek vektör makinesi	16
Şekil 2-5: Tekrarlayan sinir ağının yapısı	19
Şekil 2-6: Tek bir katman ile standart RNN modül yapısı.	19
Şekil 2-7: Dört etkileşimli katman ile yinelenen LSTM modül yapısı.....	21
Şekil 3-1: Sıfır dolgu tabanlı özellik çıkarma ve sınıflandırma yöntemine ait blok diyagram	33

TABLO LİSTESİ

<u>Tablo</u>	<u>Sayfa</u>
Tablo 3-1: Makine öğrenmesi model parametreleri.....	31
Tablo 4-1: Ortalama sınıflandırma performansları.....	35
Tablo 4-2: Önerilen ilk yöntemin ACC değerlerinin literatürdeki diğer çalışmalarla karşılaştırılması	39
Tablo 4-3: Önerilen ikinci yöntemin farklı özellik sayılarında MLP ile değerlendirilmesi .	40
Tablo 4-4: Önerilen ikinci yöntemin farklı sınıflandırma algoritmaları ile değerlendirilmesi	41
Tablo 4-5: ROI'lerin öznitelik kümesinde yer alma sayıları ve toplam SelectKbest skorları	43

GRAFİK LİSTESİ

<u>Grafik</u>	<u>Sayfa</u>
Grafik 4-1: ACC değerlerinin kat bazında karşılaştırılması	36
Grafik 4-2: ACC değerlerinin kat bazında kutu grafiği gösterimi	36
Grafik 4-3: SENS değerlerinin kat bazında kutu grafiği gösterimi.....	37
Grafik 4-4: SPEC değerlerinin kat bazında kutu grafiği gösterimi	38
Grafik 4-5: Öznitelik kümesindeki sayılarına ve SelectKbest skorlarına göre ROI'lerin değerlendirilmesi	42
Grafik 4-6: Sayı değerine göre ROI'lerin ağaç haritası grafiği	44
Grafik 4-7: SelectKbest değerine göre ROI'lerin ağaç haritası grafiği.....	44

SİMGE VE KISALTMA LİSTESİ

Simgeler

Açıklama

Kisaltmalar

Açıklama

AI	: Yapay Zeka
CNN	: Evrimsel Sinir Ağı
EEG	: Elektroensefalografi
k-NN	: k-En Yakın Komşuluk Algoritması
LDA	: Doğrusal Ayrım Analizi
LSTM	: Uzun Kısa Süreli Bellek Ağı
MEG	: Manyetoensefalografi
ML	: Makine Öğrenimi
MLP	: Çok Katmanlı Algılayıcı
MRI	: Manyetik Rezonans Görüntüleme
OSB	: Otizm Spektrum Bozukluğu
PET	: Pozitron Emisyon Tomografisi
rs-fMRI	: Dinlenme Durumu Fonksiyonel Manyetik Rezonans Görüntüleme
SVM	: Destek Vektör Makinesi
BPTT	: Zaman İçerisinde Geri Yayılım
GRU	: Geçitli Tekrarlayan Birim
TK	: Tipik Kontrol
PCC	: Pearson Korelasyon Katsayısı

1. GİRİŞ

Otizm Spektrum Bozukluğu (OSB), sosyal iletişim zorlukları, tekrarlayan davranışlar ve kısıtlı ilgi alanları ile karakterize karmaşık bir nörogelişimsel durumdur [1] [2]. OSB'nin erken ve doğru teşhisi, zamanında müdahalelerin ve destek sistemlerinin uygulanması ve spektrumdaki bireyler için uzun vadeli sonuçların iyileştirilmesi için çok önemlidir. Son yıllarda, fonksiyonel Manyetik Rezonans Görüntüleme (fMRI) OSB'nin nörobiyolojik temellerini araştırmak için umut verici bir araç olarak ortaya çıkmıştır [3][4].

OSB, dünya çapında milyonlarca bireyi etkileyen oldukça yaygın bir nörogelişimsel bozukluktur. OSB çok çeşitli semptomlar ve şiddet ile karakterize edilir, bu da tanısını ve müteakip tedavisini karmaşık hale getirir. Geleneksel olarak, OSB tanısı davranışsal değerlendirmelere ve klinik gözlemlere dayanmaktadır. Ancak bu yöntemler öznel, zaman alıcıdır ve genellikle tutarsız sonuçlar verir [5]. Sonuç olarak, OSB'nin erken ve doğru tespitine yardımcı olmak için nörogörüntüleme tekniklerinden, özellikle de fMRI'dan yararlanmaya yönelik ilgi giderek artmaktadır.

fMRI, kan oksijenlenme seviyelerindeki değişiklikleri tespit ederek beyin aktivitesinin ölçülmesini sağlayan müdahalesiz bir nörogörüntüleme yöntemidir. Belirli bilişsel süreçlerle ilişkili beyin bölgelerini ve ağlarını inceleyerek, fMRI OSB'nin altında yatan nöral mekanizmalar hakkında değerli bilgiler sağlar [6]. fMRI'nin potansiyeli, nöral biyobelirteçleri tanımlama ve nörotipik bireyler ile OSB'li bireyler arasında ayırım yapma becerisinde yatmaktadır. Bu tür biyobelirteçler, objektif ve güvenilir tanı araçlarının geliştirilmesine yardımcı olarak OSB tanısının doğruluğunu ve etkinliğini artırabilir.

OSB, çok çeşitli klinik tabloları, bilişsel profilleri ve genetik varyasyonları kapsayan oldukça heterojen bir bozukluktur [7][8]. Bu doğal heterojenlik, sağlam fMRI tabanlı tanı modellerinin geliştirilmesinde önemli bir zorluk teşkil etmektedir. Nörogörüntüleme topluluğu, OSB'li bireyleri farklı popülasyonlardaki tipik gelişim gösteren bireylerden ayırt edebilecek tutarlı ve güvenilir biyobelirteçleri belirleme göreviyle karşı karşıyadır.

fMRI görüntülerini elde etmek için dinlenme durumu ve görev tabanlı olmak üzere iki farklı yöntem kullanılır [5]. Belirli görevlerin yokluğunda spontane beyin aktivitesini yakalayan dinlenme durumu işlevsel manyetik rezonans görüntüleme (rs-fMRI), OSB araştırmalarında önem kazanmıştır. Beyin bölgeleri arasındaki işlevsel bağlantı modellerini inceleyerek, rs-fMRI OSB ile ilişkili anormal sinir ağı organizasyonunu belirleyebilir. OSB'li bireylerde fonksiyonel bağlantıdaki değişiklikleri tespit etmek için tohum tabanlı korelasyonlar (seed-based correlations),

bağımsız bileşen analizi ve grafik teorisi gibi çeşitli analitik yaklaşımlar kullanılmıştır. Öte yandan görev tabanlı fMRI ise, görüntü alımı sırasında katılımcılara bilişsel veya sosyal görevlerin uygulanmasını içerir. Bu yaklaşım, OSB'li bireylerde görevle uyarılan beyin aktivasyon modellerinin ve bunların sapmalarının araştırılmasını sağlar. Görev tabanlı fMRI çalışmaları, OSB'deki sosyal ve bilişsel bozuklukların altında yatan belirli sinirsel mekanizmalara ışık tutmak için yüz işleme, duygu tanıma ve zihin teorisi gibi alanları araştırmıştır.

Yukarıda belirtildiği gibi rs-fMRI, belirli görevlerin veya dış uyaranların yokluğunda içsel beyin aktivitesinin incelenmesini sağlayan bir nöro görüntüleme tekniğidir [9]. Serebral kan akışı ve oksijenlenmedeki yerel değişimleri yansıtan kan-oksijen seviyesine bağlı (BOLD) sinyalden yararlanır [6][10]. Bir rs-fMRI taraması sırasında, manyetik rezonans görüntüleme (MRI) tarayıcısı bir dizi işlevsel görüntü elde ederken, katılımcılara gözleri kapalı veya açık olarak hareketsiz kalmaları talimatı verilir. Bu görüntüler, zaman içinde farklı beyin bölgelerindeki BOLD sinyalindeki dalgalanmaları yakalar. Elde edilen rs-fMRI verileri, sinyali bozabilecek hareket artefaktları ve fizyolojik gürültü gibi karıştırıcı faktörleri en aza indirmek için ön işleme tabi tutulur. Ön işleme tipik olarak hareket düzeltme, uzamsal normalleştirme, uzamsal yumuşatma ve zamansal filtreleme gibi adımları içerir.

Önceden işlenmiş rs-fMRI verileri daha sonra beyin içindeki işlevsel bağlantı modellerini araştırmak için çeşitli analitik tekniklere tabi tutulabilir. Fonksiyonel bağlantı, farklı beyin bölgeleri arasındaki senkronize aktivitelerini yansıtan istatistiksel bağımlılıkları ve zamansal korelasyonları ifade eder. rs-fMRI araştırmalarında yaygın olarak kullanılan analitik yaklaşımlar arasında yukarıda da belirtildiği gibi tohum tabanlı korelasyon analizi, bağımsız bileşen analizi ve grafik teorisi tabanlı yaklaşımlar yer almaktadır.

Tohum tabanlı korelasyon analizi, belirli bir beyin bölgesinin "tohum" olarak seçilmesini ve zaman serileri ile diğer beyin voksellerinin veya bölgelerinin zaman serileri arasındaki korelasyonun hesaplanmasını içerir. Bu yaklaşım, seçilen tohum bölgesinin beynin geri kalanıyla işlevsel bağlantısı hakkında bilgi sağlar.

Bağımsız bileşen analizi, rs-fMRI verilerini, her biri beyin bölgeleri arasında farklı bir senkronize aktivite modelini temsil eden uzamsal olarak bağımsız bileşenlere ayırmayı amaçlamaktadır. Bu yaklaşım, beyin içindeki büyük ölçekli işlevsel ağların tanımlanmasına olanak tanır.

Grafik teorisine dayalı yaklaşımlar, beyni birbirine bağlı düğümlerden (beyin bölgeleri) ve kenarlardan (işlevsel bağlantılar) oluşan bir ağ olarak analiz eder. rs-fMRI bağlamında, düğümler tipik olarak anatomik olarak tanımlanmış beyin bölgelerini veya beyin atlaslarından elde edilen

fonksiyonel parselleri temsil eder. Kenarlar, genellikle ilgili fMRI sinyallerinin zaman serilerindeki korelasyon veya tutarlılığın ölçülmesiyle belirlenen düğüm çiftleri arasındaki işlevsel bağlantıları temsil eder. Grafik teorisine dayalı yaklaşımlar, beyin ağının topolojik özelliklerini ölçmemize ve organizasyonunu incelememize olanak tanır. Düğüm derecesi, kümeleme katsayısı ve arasındalık merkeziliği (betweenness centrality) gibi ölçütler, beyin ağının topolojik özelliklerini ölçmek ve organizasyonunu değerlendirmek için hesaplanabilir. Ayrıca grafik teorisine dayalı yaklaşımlar, OSB'nin tespiti ve karakterizasyonunda çeşitli avantajlar sunmaktadır. İlk olarak, bu yaklaşımlar, beyin ağlarının organizasyonunu ölçerek ve bozuklukla ilişkili beyin bölgeleri içindeki ve arasındaki bağlantıdaki belirli bozulmaları tanımlayarak OSB'li bireylerde değişen bağlantı modellerinin karakterizasyonuna izin verir. İkinci olarak, grafik teorisine dayalı analizler, ağ topolojisi, verimlilik, modülerlik ve bağlantı gücü gibi özellikleri değerlendirerek beyin ağlarının karmaşıklığını yakalar ve OSB'li bireylerde nörotipik bireylere kıyasla farklı beyin organizasyonunun kapsamlı bir şekilde anlaşılmasını sağlar. Üçüncü olarak, bu yaklaşımlar, OSB'nin tespiti ve teşhisi için nörogörüntüleme biyobelirteçlerinin yanı sıra OSB popülasyonu içindeki alt tipleri veya farklı fenotipleri belirleme potansiyeline sahiptir ve teşhis ve tedaviye yönelik kişiselleştirilmiş yaklaşımlara yardımcı olur. Ayrıca, graf teorisine dayalı yaklaşımlar, OSB ile ilgili değişiklikleri kapsamlı bir şekilde anlamak ve OSB'deki yapısal, işlevsel ve bağlantı değişiklikleri arasındaki ilişkileri keşfetmek için yapısal MRI, difüzyon MRI veya elektroensefalografi (EEG) gibi diğer nörogörüntüleme yöntemleriyle entegre edilebilir. Grafik teorisine dayalı analizlerin kullanıldığı boylamsal çalışmalar, OSB'li bireylerde beyin bağlantısının gelişimsel yörüngelerinin incelenmesine olanak tanıyarak bozukluğun gelişimsel yönleri ve potansiyel nöroplastisite hakkında içgörü sağlar. Ayrıca, bu yaklaşımlar, müdahalelerin ardından ağ özelliklerindeki değişiklikleri değerlendirerek OSB'li bireyler için tedavi etkilerinin izlenmesinde ve müdahalelerin değerlendirilmesinde kullanılma potansiyeline sahiptir. Bununla birlikte, OSB'nin heterojenliği ve beyin ağlarının karmaşık yapısı nedeniyle bulguların yorumlanmasında dikkatli olunmalıdır ve sağlam ve tekrarlanabilir biyobelirteçler oluşturmak ve OSB'de değişen bağlantı modellerinin klinik sonuçlarını anlamak için daha fazla araştırma yapılması gerekmektedir.

rs-fMRI, beyin işlevsel mimarisini araştırmak ve çeşitli nörolojik ve psikiyatrik bozukluklardaki değişikliklerini anlamak için değerli bir araç olarak ortaya çıkmıştır. Alzheimer hastalığı, şizofreni, depresyon ve OSB gibi durumları incelemek için kullanılmış ve altta yatan nöral mekanizmalar ve potansiyel biyobelirteçler hakkında içgörüler sağlamıştır. Bununla birlikte, rs-fMRI bulgularının doğrudan nedensellik veya belirli sinirsel süreçler hakkında çıkarım

yapmadıkları için dikkatle yorumlanması gerektiğine önem verilmelidir. Teknik öncelikle spontan beyin aktivitesindeki korelasyonları yakalar ve nedensel ilişkiler kurmak ve gözlemlenen bağlantı modellerinin işlevsel önemini aydınlatmak için genellikle ek multimodal yaklaşımlar ve deneysel tasarımlar gereklidir.

Özetle, rs-fMRI dinlenme sırasında içsel beyin aktivitesinin incelenmesine olanak tanıyarak işlevsel bağlantı örüntüleri ve beyin ağı organizasyonu hakkında değerli bilgiler sağlar. Sinirbilim araştırmalarındaki uygulaması, beyin fonksiyonu anlayışımızı ve bunun sağlık ve hastalık üzerindeki etkilerini iletirmek için umut vaat etmektedir.

Makine öğrenimi (machine learning-ML), verilerden öğrenmek için algoritmaların eğitilmesini ve daha sonra bu algoritmaların yeni verilere dayalı tahminler veya sınıflandırmalar yapmak için kullanılmasını içeren bir yapay zeka türüdür [11][12]. Makine öğrenimi, özellikle fMRI verileriyle birleştirildiğinde, OSB'nin teşhisine yardımcı olma konusunda umut vaat etmektedir.

OSB'nin tespiti için fMRI ve ML'nin kullanımını araştıran ve farklı derecelerde başarı elde eden bir dizi çalışma yapılmıştır. OSB tespiti için fMRI ve makine öğrenimini kullanmanın zorluklarından biri, algoritmaları yeterince eğitmek ve test etmek için yeterli örneklem büyüklüğüne sahip büyük veri kümelerine ihtiyaç duyulmasıdır. Ayrıca, sonuçların çalışmalar arasında karşılaştırılabilir olmasını sağlamak için standartlaştırılmış veri işleme ve analiz yöntemlerine de ihtiyaç vardır.

Bu zorluklara rağmen, fMRI ve ML kombinasyonu OSB'nin tespit ve teşhisine yardımcı olma konusunda umut vaat etmektedir ve OSB'li bireyler için daha erken müdahalelere ve daha iyi sonuçlara yol açma potansiyeline sahiptir.

fMRI verilerini analiz etmeye yönelik ağ tabanlı yaklaşımlarda, tüm beyin, bir beyin ağı içindeki düğümler olarak hizmet eden farklı ilgi bölgelerine (ROI'lere) ayrılır. Bu ROI'lerdeki işlevsel faaliyetlerin zaman serisi ölçümleri daha sonra ROI'ler arasındaki bağlantıların gücünü temsil eden çapraz korelasyonu hesaplamak için kullanılır. Bu bağlantılar beyin ağının kenarlarını oluşturur. Beyin ağını temsil etmek için bir bağlantı matrisi kullanılır ve matrisin her bir elemanı, karşılık gelen ROI'lerin zaman serisi ölçümleri arasındaki çapraz korelasyonu belirtir.

Bağlantı matrisi, OSB ve tipik kontrollerin (TK) sınıflandırılması için çeşitli şekillerde kullanılmıştır. [12] olarak atıfta bulunulan çalışmada, tüm çift ROI'ler arasındaki korelasyon değerleri, OSB ve TK bireyleri sınıflandırmak için olasılıksal bir sinir ağı için özellikler olarak kullanılmıştır. Başka bir çalışma [13] OSB için belirteç görevi görebilecek belirli ROI'leri tanımlamak için çocukların beyinlerinin içsel bağlanabilirliğini incelemiştir. Ek olarak, [14] olarak

adlandırılan grup, gri madde içindeki her vokseli bir ROI olarak tanımlamış ve çeşitli beyin hastalıklarını tespit etmek için bağlantı matrisi üzerinde sınıflandırma algoritmasını uygulamıştır. Bağlantı matrisi, beynin işlevsel ve yapısal özelliklerini araştırmak için [15]'te de kullanılmıştır.

Bu çalışmalar, ağ tabanlı yaklaşımlardan elde edilen bağlantı matrisinin OSB'nin sınıflandırılması ve karakterizasyonunun yanı sıra beyin hastalıklarının incelenmesi ve beyin bağlantı modellerinin anlaşılmasındaki faydasını göstermektedir. Bağlantı matrisi, bölgeler arası ilişkilerin değerli bir temsilini sağlar ve beyin ağı içindeki işlevsel ve yapısal özelliklerin daha fazla analizi ve araştırılması için bir temel oluşturabilir.

OSB teşhisi için çeşitli araştırmalarda makine öğrenimi yaklaşımları kullanılmıştır. [16]'daki çalışmada, çift yoğunluklu çift ağaç ayrık dalgacık dönüşümü kullanılarak her deneğin ilgili bölgelerinin (ROI'ler) zaman-frekans alt-bantlarına ayrıştırılmasıyla %75,3'lük bir sınıflandırma doğruluğu elde edildi. Daha sonra özellikler, genelleştirilmiş otoregresif koşullu değişen varyans kullanılarak bu alt bantlardan seçildi. Ancak bu çalışma, Otizm Beyin Görüntüleme Veri Değişimi 1 (ABIDE 1) veri setinde bulunan 1112 kişi içersinden altı farklı beyin görüntüleme merkezine ait 468 kişiyi içermektedir.

Başka bir çalışmada [17], seyrek çoklu görünüm görev merkezli topluluk sınıflandırma yöntemi, her ikisi de ABIDE 1'den elde edilen NYU ve UM1 veri kümeleri için sırasıyla %72,6 ve %71,4 sınıflandırma doğruluğu sağlamıştır. Ancak bu veri kümeleri sırasıyla yalnızca 183 ve 96 denekten oluşmaktadır. Ayrıca, çalışma sonuçları her bir site için ayrı ayrı raporlamıştır. [18] olarak atıfta bulunulan bir başka çalışmada, yalnızca 50 denek içeren USM veri kümesi kullanılarak %96,5 gibi yüksek bir sınıflandırma doğruluğu elde edilmiştir. [19]'da, bağlantı matrisi öğeleri doğrudan ASD teşhisi için makine öğrenimi sınıflandırıcısında kullanıldı. Yöntem iki veri kümesi üzerinde değerlendirildi: 88 özneli ABIDE 1 ve 181 özneli bir Japon veri kümesi, sırasıyla %85.0 ve %71.0 sınıflandırma doğruluğuna ulaştı.

Öte yandan, tüm veri seti yerine sadece bir kliniğin verilerinin kullanılması önemli bir eksiklik olarak göze çarpmaktadır. Tüm ABIDE 1 seti bir arada değerlendirildiğinde, verilerin farklı lokasyonlarda ve farklı ayarlar altında farklı marka cihazlardan elde edildiği görülüyor. Bu durumda sınıflandırma doğruluğunu önemli ölçüde etkileyen bir faktör olarak öne çıkmaktadır. Bu doğrultuda ABIDE 1'deki tüm sitelerden gelen verileri kullanan çalışmalar vardır. Böyle bir çalışma [20], fenotipik bilgileri rs-fMRI zaman serisi verileriyle birleştirerek ABIDE 1 veri setinin tamamı için %70,1'lik bir sınıflandırma doğruluğu elde etti. [21]'de, yığılmış gürültü giderici otomatik kodlayıcıları kullanan derin öğrenmeye dayalı bir yaklaşım, %70.0'lik bir sınıflandırma doğruluğu bildirdi. Ağa girdi, ikili ROI'lerin Pearson korelasyon katsayısıydı (PCC). Deneyler

ayrıca tek site verileri üzerinde yürütüldü ve ortalama %52,0'lik bir sınıflandırma doğruluğuyla sonuçlandı. Başka bir çalışmada [1], makine öğrenimi algoritmalarında log-Öklid ve afin-değişmez Riemann metrikleri altında bağlantı matrisleri kullanılmış ve %71,1'lik bir sınıflandırma doğruluğu elde edilmiştir. Daha yeni bir çalışma [22], OSB teşhisi için tek katmanlı bir algılayıcıyı önceden eğitmek üzere bir otomatik kodlayıcı kullanmış ve ABIDE 1 veri setinin tamamı için %70,1'lik bir sınıflandırma doğruluğu ve bireysel siteler için ortalama %63,0'lık bir doğruluk elde etmiştir.

Bir çalışma [23], yukarıda belirtilen çalışmalarda görüldüğü gibi, makine öğrenimine dayalı OSB teşhisinin daha küçük örneklem boyutlarıyla daha yüksek sınıflandırma doğruluğu sağlama eğiliminde olduğunu göstermiştir. Bu tür makine öğrenimine dayalı çalışmalarda örnek boyutu arttıkça sınıflandırma doğruluğu azalma eğilimindedir. Bu gözlem, tüm ABIDE 1 veri setini kullanarak OSB'yi yüksek doğrulukla teşhis edebilen ayırt edici özelliklere ihtiyaç olduğunu göstermektedir.

Bir başka çalışmada bir beyin ağının Laplas Matrisinin (Laplacian Matrix) özdeğerlerini yeni özellikler olarak kullanarak OSB teşhis etmek için yeni bir yaklaşım önerilmiştir. Beyin korteksi, önceki bir çalışmaya [24] dayanan bir parselasyon şeması kullanılarak başlangıçta 264 ilgi bölgesine (ROI) bölünmüştür. Bu ROI'lerin zaman serisi ölçümleri bir bağlantı matrisi oluşturmak için çıkarılır. Makine öğrenimi algoritmalarına uygun özellikler oluşturmak için, bağlantı matrisinin Laplas matrisinden 264 özdeğer çıkarılmıştır. ABIDE 1 veri setindeki 871 örnek kullanılarak gerçekleştirilen sınıflandırmada %77,7'lik bir başarımla elde edilmiştir.

Yukarıdaki bölümlerde de belirtildiği gibi OSB'nin heterojen doğası fMRI verileri üzerinden sınıflandırma yapmayı oldukça zorlu hale getirmektedir. Bunun yanı sıra ABIDE 1 veri setinin farklı kliniklerden, farklı cihaz parametreleriyle elde edilmiş olması da süreci daha zorlu hale getirmektedir. Ayrıca fMRI verileri esasında zaman serisi şeklinde tanımlanmış olan voksel bilgilerinden oluşmaktadır. Bu da 4 boyutlu bir verinin oluşmasına neden olmaktadır. ABIDE 1 veri seti içerisindeki farklı kliniklerden elde edilen veriler de farklı boyut değerlerine sahiptir. Öte yandan birçok ML modeli sabit boyutlu girdilere ihtiyaç duymaktadır.

Literatürdeki çalışmalarda elde edilen başarımları artırmak için bu çalışmada OSB'nin rs-fMRI verileri üzerinden tespitinde iki farklı yaklaşım sunulmaktadır. Her iki yaklaşımda da ABIDE 1 veri setine bir dizi ön işleme adımı uygulanmıştır. İlk yaklaşımda BASC beyin atlası kullanılarak zaman serisi ölçümleri gerçekleştirilmiş sonrasında Pearson korelasyon katsayısı (PCC) ile bağlantı matrisi elde edilmiş ve derin öğrenme modelleri ile sınıflandırma işlemleri gerçekleştirilmiştir. PCC uygulamak veriler üzerindeki zaman bilgilerinin büyük ölçüde

kaybolmasına neden olmaktadır. Bu durumunda sınıflandırma performansını olumsuz etkilediği değerlendirilmektedir. Bu doğrultuda ikinci yaklaşımda zaman serisi özellikleri çıkarıldıktan sonra PCC kullanarak bağlantı matrisi elde etmek yerine sıfır dolgu (zero-padding) işlemi uygulanmıştır. Birçok makine öğrenimi modeli, verimli hesaplama ve uyumluluk için sabit girdi boyutları gerektirir. Sıfır dolgu, veri kümesindeki en uzun dizinin uzunluğuyla eşleşecek şekilde daha kısa dizileri sıfırlarla doldurarak zaman serisi verilerinin uzunluğunu standartlaştırmanıza olanak tanır. Bu, tüm girdi dizilerinin aynı boyutlara sahip olmasını sağlayarak toplu işlemeyi kolaylaştırır ve genel eğitim ve çıkarım hattını basitleştirir. Ayrıca zaman serisi verileri genellikle bir zaman adımıdaki değerlerin önceki değerlerden etkilendiği zamansal bağımlılıklar sergiler. Sıfır dolgu, dolgulu dizilerin başında ve/veya sonunda yeterli bağlama sahip olmasını sağlayarak modelin zamansal bağımlılıkları daha etkili bir şekilde yakalamasına olanak tanır. Sıfır dolgu, makine öğrenimi modellerinin genelleme kabiliyetini artırabilir. Bunlara ilave olarak daha kısa zaman serilerini sıfırlarla doldurarak, model doldurulmuş bölgeleri göz ardı etmeyi öğrenir ve eksik verileri etkili bir şekilde ele almayı öğrenir. Bu, test verileri farklı uzunluklarda diziler içerdiğinde veya gerçek zamanlı veriler dinamik veri toplama nedeniyle değişen uzunluklara sahip olabildiğinde faydalı olabilir. [25] Değişken uzunluktaki zaman serisi verileriyle uğraşırken, fazla verilerin kesilmesi veya atılması bilgi kaybına neden olabilir. Sıfır dolgu, boşlukları sıfırlarla doldururken tüm orijinal veri noktalarını korumanıza olanak tanır. Doldurulan sıfırlar anlamlı bilgiler aktarmasa da, orijinal veri noktalarının göreceli konumlarının korunmasına yardımcı olarak zaman serisinin genel yapısını korur ve potansiyel olarak değerli bilgi kaybını en aza indirir [26]. Tüm bu sayılan sebeplerin önerilen ikinci modelin OSB sınıflandırmasında belirgin şekilde daha iyi bir sonuç vermesine neden olduğu değerlendirilmektedir. Önerilen ikinci modelde sıfır dolgu işleminden sonra düzleştirme işlemi uygulanarak veriler vektör formuna dönüştürülmüştür. Vektör formuna dönüştürülen veriler üzerinden boyutsallığı azaltmak amacıyla bir özellik seçim işlemi uygulanmıştır. Ayrıca seçilen özellikler incelenerek hangi ROI'lerin TK ve OSB'li bireylerde daha ayırt edici olabileceği konusunda bir değerlendirme sunulmuştur.

2. MATERYAL VE YÖNTEMLER

2.1 MAKİNE ÖĞRENMESİ MODELLERİ

Makine öğrenmesi, bilgisayarların verilerden otomatik olarak öğrenmesini ve açıkça programlanmadan akıllı kararlar veya tahminler yapmasını sağlayan algoritmalar ve modeller geliştirmeyi amaçlayan, bilgisayar bilimi, istatistik ve yapay zekanın kesiştiği disiplinler arası bir alandır. Sistemlerin görevleri gerçekleştirmek ve deneyim yoluyla performanslarını geliştirmek için kullandıkları algoritmaların ve istatistiksel modellerin incelenmesi makine öğrenmesi kapsamında ele alınmaktadır.

Makine öğrenimi özünde, bilgisayarların kalıpları tanımlamasına, anlamlı içgörüler çıkarmasına ve davranışlarını verilere dayalı olarak uyarlamasına olanak tanıyan matematiksel ve hesaplamalı tekniklerin geliştirilmesi gibi konuları içerir. Bu, modellerin yeni, daha önce görülmemiş veriler üzerinde genelleme yapmak ve tahminler veya kararlar almak için örnekler veya gözlemler üzerinde eğitildiği, veriye dayalı bir öğrenme süreci aracılığıyla elde edilir.

Bu bölümde tez çalışması kapsamında kullanılan makine öğrenmesi algoritmaları tanıtılmaktadır.

2.1.1 Çok Katmanlı Algılayıcı

Çok Katmanlı Algılayıcı (Multilayer Perceptron-MLP), makine öğreniminde yaygın olarak kullanılan popüler bir sinir ağı mimarisidir. Nöronlar veya birimler olarak adlandırılan, birbirine bağlı düğümlerden oluşan çoklu katmanlardan oluşan ileri beslemeli bir sinir ağıdır. MLP, denetimli öğrenme adı verilen bir süreç aracılığıyla verilerdeki karmaşık örüntüleri ve ilişkileri öğrenme becerisiyle bilinir.

Bir MLP'nin mimarisi tipik olarak bir giriş katmanı, bir veya daha fazla gizli katman ve bir çıkış katmanından oluşur. Her katman, hesaplama yapan ve bir sonraki katmana bilgi ileten birden fazla nörondan oluşur. Nöronlar arasındaki bağlantılar ağırlıklı bağlantılarla temsil edilir ve her nöron, girdilerinin ağırlıklı toplamına bir aktivasyon fonksiyonu uygular.

MLP'ye girdiyi $(n \times 1)$ boyutlarında x olarak gösterelim; burada n , girdi özelliklerinin sayısını temsil eder. MLP'nin giriş katmanı, giriş değerlerini herhangi bir işleme tabi tutmadan ilk gizli katmana aktarır.

Gizli katmanlardaki her nöron, z_j olarak gösterilen girdilerinin ağırlıklı bir toplamını hesaplar; burada j , gizli katmandaki nöronun indeksini temsil eder. Ağırlıklı toplam şu şekilde verilir:

$$z_j = \sum(w_{ij} * a_{i-1}) + b_j \quad (1)$$

Burada, w_{ij} bir önceki katmandaki nöron i ile mevcut katmandaki nöron j arasındaki bağlantının ağırlığını, a_{i-1} bir önceki katmandaki nöron i 'nin aktivasyon değerini ve b_j nöron j ile ilişkili bias terimini temsil eder.

Ağırlıklı toplamı hesapladıktan sonra nöron, ağırlıklı olmayan bir özellik katmak için $f(z_j)$ olarak gösterilen bir aktivasyon fonksiyonu uygular. MLP'lerde kullanılan yaygın aktivasyon fonksiyonları arasında sigmoid fonksiyonu, $\tanh$ fonksiyonu veya düzeltilmiş doğrusal birim (ReLU) fonksiyonu bulunur.

MLP'nin çıktı katmanı da benzer bir hesaplama gerçekleştirir. Çıktı katmanındaki her nöron, z_k olarak gösterilen girdilerinin ağırlıklı toplamını hesaplar; burada k , çıktı katmanındaki nöronun indeksini temsil eder. Ağırlıklı toplam şu şekilde verilir:

$$z_k = \sum(w_{jk} * a_{j-1}) + b_k \quad (2)$$

Benzer şekilde, çıkış nöronu MLP'nin nihai çıktısını üretmek için $g(z_k)$ olarak gösterilen bir aktivasyon fonksiyonu uygular.

Bir MLP'nin eğitim süreci iki ana adımdan oluşur: ileri yayılma ve geri yayılma. İleri yayılımda, girdi verileri ağ üzerinden beslenir ve çıktılar hesaplanır. Tahmin edilen çıktılar daha sonra hatayı ölçmek için gerçek hedef değerlerle karşılaştırılır.


Geriye yayılma algoritması daha sonra hatayı en aza indirmek için MLP'nin ağırlıklarını ve önyargılarını güncellemek için kullanılır. Hatanın çıkış katmanından gizli katmanlara yayılmasını ve hata gradyanlarına dayalı olarak yol boyunca ağırlıkların ve önyargıların ayarlanmasını içerir.

Ağırlıklar ve önyargılar, tipik olarak gradyan inişi veya varyantlarından biri olan bir optimizasyon algoritması kullanılarak güncellenir; burada amaç, hata fonksiyonunu en aza indiren

optimum deęerleri bulmaktır. Bu sre, yakınsama veya nceden tanımlanmıř bir durdurma kriteri karřılanana kadar yinelenir.

MLP'lerin gc, girdi zellikleri ve hedef deęiřkenler arasındaki karmařık doęrusal olmayan iliřkileri ęrenme yeteneklerinde yatmaktadır. MLP'ler oklu katmanlar ve doęrusal olmayan aktivasyon fonksiyonları kullanarak verilerdeki karmařık rntleri yakalayabilir ve sınıflandırma, regresyon ve rnt tanıma gibi grevlerde mkemmel olmalarını saęlar.

Sonc olarak, MLP, verilerdeki karmařık rntleri ęrenmek iin oklu katmanlardan ve doęrusal olmayan aktivasyon iřlevlerinden yararlanan ok ynl bir sinir aęı mimarisidir. MLP'ler, aęırlıkları ve nyargıları yinelemeli olarak ayarlayarak hatayı en aza indirmek ve doęru tahminler yapmak iin parametrelerini optimize eder. řekil 2-1'de bir MLP modelinin temel yapısı grlmektedir.



řekil 2-1: ok katmanlı algılayıcı

2.1.2 k – En Yakın Komřu Algoritması

k-en yakın komřu (k-NN) algoritması, makine ęreniminde kullanılan popler bir parametrik olmayan sınıflandırma ve regresyon yntemidir. Benzer veri noktalarının aynı sınıfa ait olma veya benzer ıktı deęerlerine sahip olma eęiliminde olduęu ilkesine dayanarak alıřır. k-NN algoritması, belirli bir veri noktasına en yakın k komřuyu bularak ve veri noktasının sınıfını

veya deęerini belirlemek iin bu bilgileri kullanarak tahminlerde bulunur. Őekil 2-2’de k-NN’de sınıflandırma işleminin nasıl gerekleřtirildięi gsterilmektedir.

N veri noktasından oluřan bir D veri kmesine sahip olduęumuz bir sınıflandırma senaryosunu ele alalım. Her veri noktası d boyutunda bir zellik vektr x_i olarak temsil edilir, burada i 1 ile N arasında deęiřir. Ek olarak, her veri noktası bir sınıf etiketi y_i ile iliřkilendirilir.

k-NN algoritması, x olarak gsterilen hedef veri noktası ile veri kmesindeki dięer tm veri noktaları arasındaki mesafeyi hesaplayarak bařlar. Bu durumda, mesafe metrięi olarak kosins mesafesini kullanabiliriz.

İki veri noktası x_i ve x_j arasındaki kosins mesafesi řu řekilde hesaplanabilir:

$$d(x_i, x_j) = 1 - \cos(\theta) \quad (3)$$

Burada θ iki zellik vektr x_i ve x_j arasındaki aıdır. Kosins mesafesi 0 ile 2 arasında deęiřir; 0 mkemmel benzerlięi, 2 ise tamamen benzemezlięi gsterir.

Uzaklıklar hesaplandıktan sonra, k-NN algoritması en kk uzaklıklara gre hedef veri noktasına en yakın k komřuyu seer. K deęeri kullanıcı tarafından tanımlanan bir parametredir.

Sınıflandırma durumunda, algoritma hedef veri noktasının sınıfını k en yakın komřu arasında oy okluęuyla belirler. Her komřunun sınıf etiketi karara katkıda bulunur ve komřular arasında en yksek sayıya sahip sınıf hedef veri noktasına atanır.

Regresyon durumunda algoritma, k en yakın komřunun ıktı deęerlerinin ortalamasına veya aęırlıklı ortalamasına dayalı olarak hedef veri noktasının deęerini tahmin eder. Tahmin edilen deęer řu řekilde hesaplanabilir:

$$\hat{y} = (1/k) * \sum y_i \quad (4)$$


Burada, $\hat{y}$ hedef veri noktası iin tahmin edilen deęeri ve y_i i ’inci komřunun ıkıř deęerini temsil eder.

k-NN algoritmasında k parametresinin seimi ok nemlidir. Daha kk bir k deęeri, algoritmanın verilerdeki grlty yakaladıęı ařırı uyuma yol aabilirken, daha byk bir k deęeri ařırı yumuřatmaya ve yerel rntlerin kaybına neden olabilir.

k-NN algoritması basit ve sezgiseldir, nk benzer rneklerin muhtemelen benzer ıktılara sahip olacaęı fikrine dayanır. Ancak, k-NN algoritmasının verilerin mesafenin anlamlı olduęu bir zellik uzayında bulunduęunu varsaydıęına dikkat etmek nemlidir. Bu nedenle, doęru

mesafe hesaplamalarını sağlamak için verilerin uygun şekilde ön işleme tabi tutulması ve özelliklerin normalleştirilmesi çok önemlidir.

Sonuç olarak, k-en yakın komşu (k-NN) algoritması, sınıflandırma ve regresyon görevleri için kullanılan parametrik olmayan bir yöntemdir. Algoritma, kosinüs mesafesi hesaplamalarına dayalı olarak bir hedef veri noktasına en yakın k komşuyu bularak, komşuların sınıflarının veya çıktı değerlerinin çoğunluk oyuna veya ortalamasına dayalı tahminler yapar. k-NN algoritması ile doğru sonuçlar elde etmek için k parametresinin doğru seçilmesi ve verilerin uygun şekilde ön işleme tabi tutulması şarttır.



Şekil 2-2: k-en yakın komşu algoritması

2.1.3 Doğrusal Ayrım Analizi

Doğrusal ayrım analizi (LDA), iki veya daha fazla veri sınıfını maksimum düzeyde ayıran özelliklerin doğrusal bir kombinasyonunu bulmak için kullanılan bir sınıflandırma algoritmasıdır. Sınıflar arası dağılımın sınıf içi dağılıma oranını maksimize ederek sınıflar arasında optimum ayırım yapan bir karar sınırı belirlemeyi amaçlar. Şekil 2-3'te LDA algoritmasında sınıflar arasında ayırım işleminin nasıl gerçekleştirildiği gösterilmektedir.

Her biri C sınıftan birine ait N örnek içeren bir veri kümesi düşünelim. Verileri, her x_i satırının d boyutlu bir özellik vektörü olduğu ve i 'nin 1 ile N arasında değiştiği bir X matrisi olarak temsil ediyoruz. Ek olarak, her bir örneğin gerçek sınıf üyeliğini gösteren sınıf etiketlerimiz y vardır.

LDA'nın amacı, sınıflar arasındaki ayırt edici bilgiyi korurken d boyutlu özellik vektörlerini daha düşük boyutlu bir uzaya yansıtmaktır. Bu, Fisher'ın ayırım oranını en üst düzeye çıkaran bir projeksiyon vektörü w bulunarak elde edilir.

Optimizasyon problemini formüle etmek için sınıflar arası dağılım matrisi SB ve sınıf içi dağılım matrisi SW tanımlanır. Sınıflar arası dağılım matrisi sınıf ortalamaları arasındaki yayılımı ölçerken, sınıf içi dağılım matrisi her bir sınıf içindeki yayılımı ölçer.

$$SB = (\sum_c (\mu_c - m)(\mu_c - m)^T) \quad (5)$$

Burada c sınıf sayısı, μ_c c sınıfının ortalama vektörü ve m genel ortalama vektörüdür.

$$SB = (\sum_c \sum_{i:y_i=c} (x_i - \mu_c)(x_i - \mu_c)^T) \quad (6)$$

Burada $\sum_{i:y_i=c}$, c sınıfına ait tüm x_i örnekleri üzerindeki toplamı gösterir. Fisher'ın diskriminant oranı şu şekilde verilir:

$$J(w) = w^T SB w / w^T SW w \quad (7)$$

Burada SW sınıf içi dağılım matrisidir.

Optimum projeksiyon vektörünü w bulmak için genelleştirilmiş özdeğer problemini çözeriz:


$$SB w = \lambda SW w \quad (8)$$

burada λ , w ile ilişkili özdeğeri temsil eder. Çözüm bize k en ayırt edici projeksiyon vektörlerini verir ($k \leq c - 1$), burada c sınıf sayısıdır.

Son olarak, yeni verileri sınıflandırmak için, x veri noktasını k projeksiyon vektörleri tarafından yayılan doğrusal alt uzaya yansıtır ve en yakın ortalamaya sahip sınıfa atarız.

Özetle, LDA, sınıflar arası dağılımın sınıf içi dağılıma oranını maksimize ederek sınıflar arasındaki ayrımı maksimize eden doğrusal bir projeksiyon bulmaya çalışır. Bunu, sınıflandırma

için kullanılabilecek projeksiyon vektörleri veren genelleştirilmiş bir özdeğer problemini çözerek gerçekleştirir.



Şekil 2-3: Doğrusal diskriminant analizi

2.1.4 Destek Vektör Makinesi Algoritması

SVM algoritması, sınıflandırma ve regresyon görevleri için kullanılan popüler bir denetimli öğrenme algoritmasıdır. Yüksek boyutlu bir özellik uzayında sınıfları maksimum düzeyde ayıran optimum bir hiper düzlem bulmayı amaçlar. Şekil 2-4'te SVM modelindeki sınıflar arası ayırımın nasıl gerçekleştirildiği gösterilmektedir.

d boyutlu özellik vektörlerine sahip N örnekten oluşan bir veri kümemizin olduğu ikili bir sınıflandırma problemini ele alalım. SVM algoritması, $w^T x + b = 0$ ile tanımlanan bir hiper düzlem bulmayı amaçlar; burada w hiper düzlemin normal vektörü ve b yanlılık terimidir.

SVM'nin ana fikri, hiper düzlem ile destek vektörleri olarak adlandırılan her bir sınıfın en yakın veri noktaları arasındaki mesafe olan marjı maksimize eden hiper düzlemi bulmaktır. Destek vektörlerini x_i ve bunlara karşılık gelen sınıf etiketlerini y_i olarak gösteriyoruz, burada $y_i \in \{-1, +1\}$.

Optimizasyon problemini formüle etmek için SVM, bazı yanlış sınıflandırma hatalarına izin vermek için ξ_i gevşek değişkenler kavramını ortaya koyar. Amaç fonksiyonu şu şekilde verilir:

$$\text{Minimize etme: } \frac{1}{2}w^T w + C \sum_i \xi_i \quad (9)$$

$$\text{Amaç fonksiyonu: } y_i(w^T x_i + b) \geq 1 - \xi_i \quad (10)$$

Burada ilk terim, marj maksimizasyonu ile yanlış sınıflandırma arasındaki dengeyi kontrol etmek için düzenlilik parametresini temsil eder ve C yanlış sınıflandırmalar için cezayı belirleyen bir hiper parametredir.

Eşitsizlik kısıtı, hiper düzlemin veri noktalarını doğru bir şekilde ayırmasını sağlayarak en az 1'lik bir marja izin verir. ξ_i gevşek değişkenleri yanlış sınıflandırma derecesini ölçer.

Optimizasyon probleminin çözülmesi, ikinci dereceden bir programlama probleminin çözülmesine yol açan ikili bir forma dönüştürülmesini içerir. Çözüm, destek vektörleriyle ilişkili Lagrange çarpanlarını α_i verir; burada $\alpha_i \geq 0$ 'dır.


Yeni veri noktalarını sınıflandırmak için karar fonksiyonu şu şekilde verilir:

$$y = \text{sign}(\sum_i \alpha_i y_i (x_i^T x) + b) \quad (11)$$

Burada toplam sadece destek vektörleri üzerinden alınır. İşaret fonksiyonu, sınıf etiketini karar fonksiyonunun işaretine göre atar.

Ayrıca SVM, çekirdek fonksiyonları kullanılarak doğrusal olarak ayıramayan verileri işlemek için genişletilebilir. Çekirdek fonksiyonu, orijinal özellik uzayının, verilerin bir hiper düzlemle ayrılabilir hale geldiği daha yüksek boyutlu bir uzaya eşlenmesini sağlar. Yaygın çekirdek fonksiyonları arasında doğrusal, polinom, radyal bazlı fonksiyon ve sigmoid bulunur.

Özetle, SVM algoritması sınıflar arasındaki marjı maksimize eden optimal bir hiper düzlem bulmaya çalışır. Yanlış sınıflandırmalara izin vermek için gevşek değişkenlerle bir optimizasyon problemi formüle eder ve bunu Lagrange çarpanları kullanarak çözer. Karar fonksiyonu daha sonra hiper düzleme olan işaretli mesafeye dayalı olarak yeni veri noktalarını sınıflandırmak için kullanılır. Kernel fonksiyonları doğrusal olmayan ayrılabilir verileri işlemek için kullanılabilir.



Şekil 2-4: Destek vektör makinesi

2.1.5 Evrişimsel Sinir Ağı

Evrişimsel Sinir Ağı (convolutional neural network-CNN), özellikle görüntü ve video tanıma görevlerinde etkili olan bir derin öğrenme algoritmasıdır [27][28]. Konvolüsyon kavramından yararlanarak giriş verilerinden ilgili özellikleri otomatik olarak öğrenmek ve çıkarmak için tasarlanmıştır.

Bir CNN, konvolüsyonel katmanlar, havuzlama katmanları ve tam bağlı katmanlar dahil olmak üzere birden fazla katmandan oluşur. CNN'lerin temel bileşeni olan evrişimsel katmana odaklanalım.

Bir konvolüsyonel katmanda, giriş verileri bir dizi öğrenilebilir filtre (kernel veya ağırlık olarak da adlandırılır) ile konvolüsyonlanır. Her filtre girdiden belirli özellikleri çıkarır. Konvolüsyon işlemi aşağıdaki gibi tanımlanır:

$$Y[i,j]=\sum m\sum nX[i+m,j+n]\cdot K[m,n] \quad (12)$$

Bu denklemde:

- $Y[i, j]$ özellik haritasında (i, j) konumundaki çıktıyı temsil eder.
- $X[i+m, j+n]$ giriş özellik haritasında $(i+m, j+n)$ konumundaki giriş değerlerini ifade eder.
- $K[m, n]$, (m, n) konumundaki filtre ağırlıklarını ifade eder.

Konvolüsyon işlemi, filtrenin giriş özellik haritası üzerinde kaydırılmasını, filtre ile karşılık gelen giriş değerleri arasında eleman bazında çarpma işleminin gerçekleştirilmesini ve çıkış değerini elde etmek için sonuçların toplanmasını içerir.

Doğrusal olmama özelliğini devreye sokmak ve ağırlık karmaşık örüntüleri öğrenme kapasitesini artırmak için genellikle konvolüsyon işleminden sonra doğrusal olmayan bir aktivasyon fonksiyonu uygulanır. Rectified Linear Unit (ReLU) yaygın olarak kullanılan bir aktivasyon fonksiyonudur ve şu şekilde tanımlanır:

$$f(x) = \max(0, x) \quad (13)$$

Konvolüsyonel katmandan sonra, özellik haritalarını küçültmek ve hesaplama karmaşıklığını azaltmak için genellikle havuzlama katmanları kullanılır. Maksimum havuzlama gibi havuzlama işlemleri, özellik haritasının küçük dikdörtgen bölgelerini alır ve her bölge içinde yalnızca maksimum değeri korur. Bu aşağı örnekleme, bazı uzamsal bilgileri atarken en önemli özelliklerin çıkarılmasına yardımcı olur.

Son evrimsel veya havuzlama katmanının çıktısı genellikle düzleştirilir ve bir veya daha fazla tam bağlantılı katmandan geçirilir. Bu katmanlar, öğrenilen özelliklere dayalı olarak üst düzey muhakeme ve sınıflandırma gerçekleştirir. Son tam bağlı katmanın çıktısı, sınıf olasılıklarını elde etmek için bir softmax aktivasyon fonksiyonuna beslenir.

CNN'in tamamı, çapraz entropi kaybı gibi seçilen bir kayıp fonksiyonunu en aza indirmek için geriye yayılma ve gradyan inişi kullanılarak eğitilir. Bu optimizasyon süreci, ağırlık kalıpları tanıma ve doğru tahminler yapma yeteneğini geliştirmek için filtre ağırlıklarını ayarlar.

Genel olarak, bir CNN'in mimarisi ve matematiksel formülasyonu, karmaşık girdi verilerinden anlamlı özellikleri otomatik olarak öğrenmesini ve çıkarmasını sağlayarak onu görüntü sınıflandırma, nesne algılama ve görüntü segmentasyonu gibi görevler için güçlü bir algoritma haline getirir.

2.1.6 Tekrarlayan Sinir Ağı

Tekrarlayan Sinir Ağı (recurrent neural network-RNN), zaman serileri veya doğal dil dizileri gibi sıralı verileri işlemek için tasarlanmış bir tür derin öğrenme algoritmasıdır. İleri beslemeli sinir ağlarının aksine, RNN'lerin geri besleme bağlantıları vardır, bu da dizideki önceki adımlardan gelen bilgileri korumalarına ve kullanmalarına olanak tanır [29][30].

RNN'lerin arkasındaki temel fikir, ağ dizideki her bir ögeyi işlerken bilgileri depolayan ve güncelleyen gizli durumlar kavramıdır. Algoritmayı açıklamak için Elman RNN olarak da bilinen basit bir RNN birimini ele alalım.

Her zaman adımında t , RNN birimi bir girdi vektörü x_t ve bir önceki adımdan bir gizli durum vektörü h_{t-1} alır. Gizli durum, ağın geçmiş bilgi hafızasını yakalar. RNN birimi daha sonra aşağıdaki denklemleri kullanarak yeni bir gizli durum h_t hesaplar:

$$h_t = f(W_{hh} \cdot h_{t-1} + W_{xh} \cdot x_t + b_h) \quad (14)$$

Bu denklemde:

- W_{hh} bir önceki adımdaki gizli durumu mevcut gizli duruma bağlayan ağırlık matrisini temsil eder.
- W_{xh} giriş vektörünü mevcut gizli duruma bağlayan ağırlık matrisini temsil eder.
- b_h gizli durum için önyargı vektörüdür.
- $f(\cdot)$ girdilerin doğrusal kombinasyonuna eleman bazında uygulanan bir aktivasyon fonksiyonudur.

Gizli durum h_t , RNN biriminin çıktısı olarak hizmet eder ve aynı zamanda bir sonraki zaman adımına girdi olarak geri beslenir ve ağın dizideki önceki adımlar hakkında bilgi tutmasına izin verir.


Çok adımlı tahmin veya diziden diziye görevler için, gizli durum ek katmanlar tarafından daha fazla işlenebilir veya diğer RNN birimlerine beslenebilir.

Eğitim sırasında RNN, tekrarlayan mimariler için standart geri yayılım algoritmasının bir uzantısı olan zaman içinde geri yayılım (Backpropagation through time-BPTT) kullanılarak optimize edilir. BPTT, ortalama karesel hata veya çapraz entropi kaybı gibi seçilen bir kayıp fonksiyonunu en aza indirmek için gradyanları hesaplar ve RNN'nin ağırlıklarını ve önyargılarını günceller.


RNN'ler, geriye yayılma sırasında gradyanların aşırı derecede küçük veya büyük hale geldiği kaybolan veya patlayan gradyan probleminden muzdariptir. Bu sorunu hafifletmek için,

LSTM ve Geçitli Tekrarlayan Birim (GRU) gibi varyantlar tanıtılmıştır. Bu varyantlar, ağ üzerinden bilgi akışını kontrol eden ve daha uzun diziler boyunca ilgili bilgilerin daha iyi korunmasına ve kullanılmasına olanak tanıyan geçit mekanizmaları içerir.

RNN'ler doğal dil işleme, konuşma tanıma, makine çevirisi ve zaman serisi analizi gibi çeşitli uygulamalarda yaygın olarak kullanılmaktadır; burada girdi verilerinin sırası ve bağlamı doğru tahminler veya sınıflandırmalar için çok önemlidir. Şekil 2-5 ve Şekil 2-6'da sırasıyla RNN ağının genel yapısı ve standart RNN modülünün iç yapısı görülmektedir.



Şekil 2-5: Tekrarlayan sinir ağının yapısı



Şekil 2-6: Tek bir katman ile standart RNN modül yapısı.

2.1.7 Uzun Kısa Dönemli Bellek Ağları

Uzun kısa dönemli bellek (long short-term memory-LSTM) ağı, kaybolan ve patlayan gradyan probleminin üstesinden gelmek ve sıralı verilerdeki uzun vadeli bağımlılıkları etkili bir şekilde yakalamak için tasarlanmış bir tür RNN'dir.

LSTM'ler, bilgileri zaman içinde seçici olarak tutmak ve unutmak için bellek hücreleri ve geçit mekanizmaları sunar. Temel fikir, ağın bilgiyi ne zaman depolayacağını, ne zaman güncelleyeceğini ve ne zaman geri alacağını öğrenmesine izin vermektir.

LSTM algoritmasını ve denklemlerini inceleyelim.

Her zaman adımında t , bir LSTM birimi, geleneksel bir RNN'ye benzer şekilde, bir önceki adımdan bir girdi vektörü x_t ve bir gizli durum vektörü h_{t-1} alır. Ayrıca, uzun vadeli bellek bilgilerini saklamak ve güncellemek için bir hücre durum vektörü C_{t-1} tutar.

LSTM birimi üç ana kapıdan oluşur:

1. Unutma kapısı f_t unutulacak önceki hücre durumu bilgisinin miktarını kontrol eder ve aşağıdaki gibi hesaplanır:

$$f_t = \sigma(W_{xf} \cdot x_t + W_{hf} \cdot h_{t-1} + b_f) \quad (14)$$

Bu denklemde:

- W_{xf} giriş vektörünü unutma kapısına bağlayan ağırlık matrisini temsil eder.
- W_{hf} bir önceki adımdaki gizli durumu unutma kapısına bağlayan ağırlık matrisini temsil eder.
- b_f unutma kapısı için önyargı vektörüdür.
- $\sigma(\cdot)$ sigmoid aktivasyon fonksiyonudur.

2. Giriş kapısı i_t hücre durumunda depolanacak yeni bilgi miktarını belirler ve aşağıdaki gibi hesaplanır:

$$i_t = \sigma(W_{xi} \cdot x_t + W_{hi} \cdot h_{t-1} + b_i) \quad (15)$$

3. Çıkış kapısı o_t hücre durumundan çıkarılacak bilgi miktarını kontrol eder ve aşağıdaki şekilde hesaplanır:

$$o_t = \sigma(W_{xo} \cdot x_t + W_{ho} \cdot h_{t-1} + b_o) \quad (16)$$

Bu denklemlerde W_{xi} , W_{hi} , W_{xo} , W_{ho} , b_i , b_o ve b_f her bir kapıya özgü ağırlık matrisleri ve yanlılık vektörleridir.

LSTM birimi ayrıca bir hiperbolik tanjant aktivasyon fonksiyonu kullanarak bir aday hücre durumu güncellemesi $\tilde{C}_t$ hesaplar:

$$\tilde{C}_t = \tanh \tanh (W_{xc} \cdot x_t + W_{hc} \cdot h_{t-1} + b_c) \quad (17)$$

Nihai hücre durumu $\tilde{C}_t$ daha sonra unutma kapısı, giriş kapısı ve aday hücre durumu güncellemesi kullanılarak aşağıdaki gibi güncellenir:

$$C_t = f_t \odot C_{t-1} + i_t \odot \tilde{C}_t \quad (18)$$


Bu denklemde $\odot$ eleman bazında çarpımı ifade eder.

Son olarak, gizli durum h_t güncellenmiş hücre durumuna çıkış kapısı uygulanarak hesaplanır:

$$h_t = o_t \odot \tanh \tanh (C_t) \quad (19)$$

Eğitim sırasında LSTM ağı, geleneksel RNN'lere benzer şekilde BPTT kullanılarak optimize edilir. Gradyanlar hesaplanır ve ağı ağırlıklarını ve önyargılarını güncellemek için kullanılır.

LSTM'ler, doğru modelleme ve tahminler için uzun vadeli bağımlılıkları yakalamanın çok önemli olduğu konuşma tanıma, makine çevirisi, duygu analizi ve zaman serisi tahmini gibi çeşitli görevlere başarıyla uygulanmıştır. Şekil 2-7'de LSTM modülünün iç yapısı görülmektedir.



Şekil 2-7: Dört etkileşimli katman ile yinelenen LSTM modül yapısı.

2.2 SELECTKBEST ÖZELLİK SEÇİMİ

SelectKBest özellik seçimi yöntemi, makine öğreniminde daha büyük bir girdi değişkenleri kümesinden en alakalı özelliklerin bir alt kümesini tanımlamak için kullanılan bir tekniktir. Bu

yöntem, özellik uzayının boyutluluğunu azaltarak model performansını, yorumlanabilirliği ve hesaplama verimliliğini artırmayı amaçlamaktadır.

SelectKBest, hedef değişkene bireysel katkılarını göz önünde bulundurarak her bir özelliğin önemini veya alaka düzeyini bağımsız olarak değerlendirmek için istatistiksel ölçümlere dayalı olarak çalışır. Özellikle, X_i olarak gösterilen her bir özellik ile y olarak gösterilen hedef değişken arasındaki ilişkinin gücünü belirlemek için tek değişkenli istatistiksel testler kullanır.

Süreç, istatistiksel önemine göre her bir özelliğe $S(X_i, y)$ olarak gösterilen bir puan atayarak başlar. Verilerin niteliğine ve spesifik araştırma sorusuna bağlı olarak $\chi^2(X_i, y)$ olarak gösterilen ki-kare istatistiği, $F(X_i, y)$ olarak gösterilen ANOVA F-değeri veya $I(X_i; y)$ olarak gösterilen karşılıklı bilgi gibi çeşitli puanlama fonksiyonları kullanılabilir.

Örneğin, ki-kare testi kategorik özellikler ile kategorik bir hedef değişken arasındaki bağımsızlığı değerlendirir. Ki-kare puanlama fonksiyonu kullanılarak X_i özelliği için puan şu şekilde hesaplanabilir:

$$S(X_i, y) = \chi^2(X_i, y) \quad (20)$$

Benzer şekilde, ANOVA F-değeri, X_i özelliği kategorik ve y hedef değişkeni sürekli olduğunda farklı gruplar arasındaki ortalamalardaki farklılıkları değerlendirir. ANOVA puanlama fonksiyonu kullanılarak X_i özelliği için puan şu şekilde hesaplanabilir:

$$S(X_i, y) = F(X_i, y) \quad (21)$$

Karşılıklı bilgi, X_i özelliği ile y hedef değişkeninin paylaştığı bilgi miktarını ölçer. Aralarındaki bağımlılığı ölçer. Karşılıklı bilgi puanlama fonksiyonu kullanılarak X_i özelliği için puan şu şekilde hesaplanabilir:

$$S(X_i, y) = I(X_i; y) \quad (22)$$

Tüm özellikler için puanlar hesaplandıktan sonra, SelectKBest yöntemi en yüksek puanlara sahip en iyi K özelliği seçer; burada K , kullanıcı tarafından belirlenen veya çapraz doğrulama teknikleriyle belirlenen önceden belirlenmiş bir sayıdır. Seçilen özellikler, daha sonra makine öğrenimi modelleri oluşturmak veya daha fazla analiz yapmak için girdi olarak kullanılacak $X_{selected}$ olarak gösterilen indirgenmiş bir özellik alt kümesi oluşturur.

Matematiksel olarak, en iyi K özelliklerinin seçimi şu şekilde gösterilebilir:

$$X_{selected} = \{X_i \mid S(X_i, y) \geq T\} \quad (23)$$

Burada T , kullanıcı tanımlı değere göre veya optimizasyon yoluyla belirlenen bir eşiği temsil eder.

Bu yaklaşımın arkasındaki mantık, daha küçük bir yüksek derecede ilgili özellikler kümesinin, gereksiz veya ilgisiz özellikleri atarken doğru tahminler veya çıkarımlar yapmak için gereken temel bilgileri yakalayabileceği varsayımında yatmaktadır. SelectKBest, daha az bilgilendirici özellikleri eleyerek sadece modelin yorumlanabilirliğini artırmakla kalmaz, aynı zamanda hesaplama karmaşıklığını azalttığı ve potansiyel olarak modelin genelleme yeteneğini geliştirdiği için boyutsallık lanetini de hafifletir.

SelectKBest'in özelliklerin alaka düzeyinin bağımsız olarak değerlendirilebileceği varsayımıyla çalıştığını belirtmek önemlidir. Bu varsayım birçok durumda doğru olsa da, özellik etkileşimlerinin veya bağımlılıklarının var olabileceği ve bunların birlikte değerlendirilmesinin daha doğru sonuçlar verebileceği senaryolar vardır. Bu gibi durumlarda, özyinelemeli özellik eleme veya gömülü özellik seçme teknikleri gibi alternatif özellik seçme yöntemleri daha uygun olabilir.

Sonuç olarak, SelectKBest özellik seçimi yöntemi, makine öğrenimi araştırmalarında değerli bir araçtır ve daha büyük bir kümeden en bilgilendirici özelliklerin bir alt kümesinin belirlenmesini sağlar. İstatistiksel ölçütler kullanarak, ilgili bilgileri korurken özellik boyutluluğunun azaltılmasını kolaylaştırır ve sonuçta model performansını ve yorumlanabilirliği artırır.

2.3 KARARLI KÜMELERİN BOOTSTRAP ANALİZİ (BASC) & ÇOK ÖLÇEKLİ ADIMSAL SEÇİM (MSTEP)

Bootstrap Analysis of Stable Clusters (BASC), nörogörüntüleme çalışmalarında kümeleme analizi için kullanılan sağlam ve veri odaklı bir yöntemdir [31]. Beyin görüntüleme verilerinde, özellikle fonksiyonel manyetik rezonans görüntüleme (fMRI) veya diğer görüntüleme modaliteleri bağlamında, kararlı ve güvenilir kümeleri belirleme zorluğunu ele alır.

BASC algoritması, farklı iterasyonlar boyunca kümelerin kararlılığını tahmin etmek için bir yeniden örnekleme tekniği olan bootstrapping kavramından yararlanır. Orijinal veri kümesini değiştirerek rastgele örnekleyerek birden fazla bootstrap örneği oluşturmayı içerir. Her bir

bootstrap örneği için, yeniden örneklenen verilerdeki kümeleri tanımlamak üzere bir kümeleme algoritması uygulanır.

BASC, bu işlemi birçok kez tekrarlayarak küme çözümlerinin bir dağılımını oluşturur. Her bir kümenin kararlılığı, bootstrap örneklerinde görünme oranı değerlendirilerek değerlendirilir. Önyükleme yinelemelerinin yüksek bir yüzdesinde tutarlı bir şekilde görünen kümeler kararlı ve güvenilir olarak kabul edilir.

BASC analizinin sonucu, veri kümesi boyunca tutarlı örüntüler sergileyen beyin bölgelerini temsil eden, ilişkili uzamsal haritalarıyla birlikte bir dizi kararlı kümedir. Bu kararlı kümeler, beynin işlevsel organizasyonu hakkında değerli bilgiler sağlayabilir ve sonraki analizler veya yorumlar için daha fazla kullanılabilir.

Öte yandan, çok ölçekli kademeli seçim, istatistiksel modelleme ve makine öğreniminde özellik seçimi için kullanılan bir stratejidir. Genellikle bir modelin tahmin performansına önemli ölçüde katkıda bulunan en ilgili özellikleri veya değişkenleri belirlemek için kullanılır.

Çok ölçekli kademeli seçim yöntemi, önemlerine göre kademeli olarak özellik ekleyerek veya kaldırarak kademeli bir şekilde çalışır. Bir dizi aday özellik ile başlar ve en uygun özellik alt kümesini belirlemek için bir dizi adımı iteratif olarak gerçekleştirir.

Süreç, tipik olarak sadece bir tane olmak üzere az sayıda özelliğe sahip bir modelin uydurulmasıyla başlar. Her bir özelliğin önemi, istatistiksel anlamlılık, bilgi kazancı veya tahmin hatası gibi uygun bir kriter kullanılarak değerlendirilir. En yüksek öneme sahip özellik seçilir ve modele dahil edilir.

Sonraki adımlarda, ek özellikler birer birer eklenir ve model performansındaki iyileşme değerlendirilir. Yeni bir özelliği dahil etme kararı, modelin tahmin yeteneğinde önemli bir gelişme sağlayıp sağlamadığına dayanır.

Tersine, dahil edilmeleri performansa önemli ölçüde katkıda bulunmuyorsa veya gereksiz karmaşıklık yaratıyorsa özellikler modelden çıkarılabilir.

Bu aşamalı seçim süreci, önceden belirlenmiş sayıda özelliğe ulaşma, istenen düzeyde model performansına ulaşma veya belirli istatistiksel kriterleri karşılama gibi bir durdurma kriteri karşılanana kadar devam eder.

Yöntemin çok ölçekli yönü, birden fazla ölçeğin veya özellik dahil etme veya hariç tutma seviyesinin dikkate alınmasını ifade eder. Hem küresel hem de yerel optimumu göz önünde bulundurarak özellik alt kümelerinin esnek bir şekilde keşfedilmesine olanak tanır.

Araştırmacılar, çok ölçekli kademeli seçimi kullanarak, tahmin performansı ve model karmaşıklığı arasında en iyi dengeyi sunan özelliklerin bir alt kümesini belirleyebilirler. Bu

yaklaşım, istatistiksel modelleme ve makine öğrenimi görevlerinde yorumlanabilirliği artırabilir, aşırı uyumu azaltabilir ve genellemeyi geliştirebilir.

Sonuç olarak, Kararlı Kümelerin Önyükleme Analizi (BASC), kararlılığı tahmin etmek için önyüklemeden yararlanarak nörogörüntüleme verilerindeki güvenilir kümeleri belirlemeye yönelik bir yöntemdir. Çok ölçekli kademeli seçim, özellikleri önemlerine göre kademeli olarak ekleyen veya kaldıran bir özellik seçim stratejisidir. Bu yöntemler, karmaşık verileri analiz etmek ve anlamlı örüntüler çıkarmak için değerli araçlar sağlayarak nörogörüntüleme araştırmalarının ve istatistiksel modellemenin ilerlemesine katkıda bulunur.

2.4 OTİZM BEYİN GÖRÜNTÜLEME VERİ DEĞİŞİMİ (ABIDE) VERİ SETİ

Otizm Beyin Görüntüleme Veri Değişimi anlamına gelen ABIDE veri seti, OSB araştırmalarını kolaylaştırmak için tasarlanmış, kamuya açık bir nörogörüntüleme veri setidir [19]. OSB'li ve TK grubundaki bireylerden elde edilen dinlenme durumu fonksiyonel manyetik rezonans görüntüleme (fMRI) verilerinin yanı sıra demografik ve klinik bilgilerden oluşmaktadır.

ABIDE veri setinin temel amacı, araştırmacıların OSB'nin nöral temellerini araştırmak için kullanabilecekleri geniş ve çeşitli bir beyin görüntüleme verisi seti sağlamaktır. Veri seti, dünya çapında birden fazla görüntüleme bölgesinden gelen verileri içermekte ve bulguların genellenebilirliğini ve değişkenliğini artırmaktadır. Araştırmacıların OSB'li bireylerde beyin bağlantı modellerini ve işlevsel ağları incelemelerine ve bunları TK bireylerinkiyle karşılaştırarak potansiyel farklılıklara ve benzerliklere ışık tutmalarına olanak tanır.

ABIDE veri seti, geniş bir yaş aralığını kapsayan hem çocuklardan hem de yetişkinlerden elde edilen verileri kapsamakta ve böylece OSB'nin gelişimsel yönlerinin araştırılmasına olanak sağlamaktadır. Çeşitli OSB şiddet düzeylerine sahip bireyleri içermekte ve beyin bağlantı kalıpları ile klinik özellikler veya davranışsal fenotipler arasındaki potansiyel ilişkilerin araştırılmasına olanak sağlamaktadır.

Veri tutarlılığını ve kalitesini sağlamak için ABIDE veri setine titiz ön işleme ve kalite kontrol prosedürleri uygulanmıştır. Bu prosedürler, karıştırıcı faktörleri en aza indirmek ve görüntüleme bölgeleri arasında veri bütünlüğünü sağlamak için diğerlerinin yanı sıra artefaktların giderilmesini, hareket düzeltmesini ve uzamsal normalleştirmeyi içerir.

ABIDE veri seti, fMRI verilerine ek olarak yaş, cinsiyet ve el becerisi gibi demografik bilgilerin yanı sıra Otizm Tanısal Gözlem Çizelgesi (ADOS) ve Otizm Tanısal Görüşme-Gözden Geçirilmiş (ADI-R) gibi OSB ile ilgili klinik ölçümleri ve tanısal değerlendirmeleri de

içermektedir. Bu zengin klinik bilgi koleksiyonu, araştırmacıların nörogörüntüleme bulguları ile OSB'nin çeşitli klinik ve davranışsal özellikleri arasındaki ilişkileri keşfetmelerine olanak sağlamaktadır.

ABIDE veri setini açık erişime sunarak, OSB alanındaki araştırmacılar arasında veri paylaşımını ve işbirliğini teşvik etmektedir. Farklı analitik yaklaşımların uygulanmasını, bulguların bağımsız örneklerde doğrulanmasını ve OSB'nin nöral temeline ilişkin yeni anlayışların geliştirilmesini teşvik etmektedir.

ABIDE veri seti, iki farklı gruptan oluşan toplam 1112 deneğin rs-fMRI beyin görüntülerini, fenotipik bilgilerini ve yapısal MRI (T1 ağırlıklı) taramalarını kapsamaktadır: 539 OSB'li birey ve 573 TK. Bu veri seti, 17 farklı kurumdan toplanan verilerin bir araya getirildiği ve bilimsel araştırma amacıyla erişilebilir hale getirildiği ortak bir çalışmadır. ABIDE 1 veri seti üzerinde çalışmalar yürütmek, deneklerin heterojenliği, veri seti içindeki büyük çeşitlilik ve belirli veri alt kümelerinin bulunmaması nedeniyle zorluklar içermektedir. ABIDE 1 veri setine, bu alanda faaliyet gösteren kuruluşlar tarafından yönetilen çeşitli web siteleri aracılığıyla erişilebilmektedir. Bununla birlikte, bu web siteleri ayrı topluluklar tarafından bağımsız olarak yönetildiğinden, farklı sitelerdeki verilerdeki tutarsızlıklar önemli bir endişe kaynağıdır. Metodolojik tutarlılığı sağlamak amacıyla, çalışmamız ABIDE 1 veri setinden seçilen 871 örnekten oluşan bir alt küme odaklanmıştır [21][22][23]. Bu alt küme içerisinde 403 deneğe OSB tanısı konulurken, 468 denek TK olarak kategorize edilmiştir.

2.5 PERFORMANS DEĞERLENDİRME METRİKLERİ

Çalışmamızda kullanılan rs-fMRI görüntüleri iki ayrı sınıftan oluşmaktadır; bunlar OSB tanısı almış hastalar ve kontrol grubudur. Bu nedenle ikili bir sınıflandırma işlemi gerçekleştirilmiştir. Modellerin performansını değerlendirmek için birkaç farklı metrik kullanılmıştır. Bu çalışmada kullanılan performans değerlendirme ölçütleri 10 kat çapraz doğrulama, sınıflandırma doğruluğu (ACC), duyarlılık (SENS) ve özgüllük (SPEC) analizleridir.

ABIDE I veri seti üzerindeki testler 10 kat çapraz doğrulama yöntemi kullanılarak gerçekleştirilmiştir. Bu işlemin temel amacı her bir verinin hem eğitim hem de test için kullanılmasıdır.

Sınıflandırma doğruluğunu hesaplamak için kullanılan formüller şu şekilde ifade edilebilir; burada n test veri seti, "cn" n değerinin sınıfı, Estimate (n)n sınıflandırma işleminin sonucu ve k veri setindeki toplam grup sayısıdır.

$$Accuracy(N) = \frac{\sum_{i=1}^{|N|} estimate(n_i)}{|N|}, \quad n_i \in N \quad (24)$$

$$Estimate(n) = \begin{cases} 1, & \text{if } estimate(n) = cn \\ 0, & \text{otherwise} \end{cases} \quad (25)$$

$$Classification Accuracy(ML) = \frac{\sum_{i=1}^{|k|} Accuracy(N_i)}{|k|} \quad (26)$$

ACC tek başına sınıflandırma sürecinin performans değerlendirmesini yapmak için yeterli bilgi sağlamayabilir. Bu nedenle, SENS ve SPEC gibi ek değerlendirmeler nihai performansın değerlendirilmesine yardımcı olabilir. Burada SENS terimi doğru tahmin edilen pozitif sınıfların oranı hakkında bilgi verirken, SPEC terimi doğru tahmin edilen negatif sınıflar hakkında bilgi verir.

Burada doğru pozitif (TP), OSB tanısı konulması gerekirken OSB kararı verilenler, doğru negatif (TN), kontrol kararı verilmesi gerekirken doğru negatif olanlar (TN), yanlış pozitif (FP), kontrol örneği olması gerekirken OSB kararı verilenler ve yanlış negatif (FN) OSB tanısı konulması gerekirken yanlışlıkla kontrol kararı verilenler de dahil olmak üzere SENS ve SPEC değerleri aşağıdaki gibi ifade edilebilir. Duyarlılık ve özgüllük aşağıdaki gibi ifade edilebilir:

$$Sensitivity = \frac{TP}{TP + FN} \quad (27)$$

$$Specificity = \frac{TN}{TN + FP} \quad (28)$$

3. ÖNERİLEN SINIFLANDIRMA YAKLAŞIMLARI

Bilindiği üzere, bir ağ düğümler ve kenarlardan oluşur. Karmaşık düğüm ve kenarları tespit etmek zor olduğundan, beyini temsil eden bir ağ oluşturmak oldukça zordur [32][33]. Düğüm ve kenarların yanlış tanımlanması durumunda, analizi oldukça zor bir ağla uğraşmak gerekebilir [34]. Bir ağı tanımlamak için en yaygın olarak kullanılan iki yöntem, ROI tabanlı [23] ve voksel tabanlı [35] parçalama şemalarıdır. Voksel tabanlı yaklaşımda, her bir voksel MRI verilerinde bir düğüm olarak tanımlanır ve vokseller arasındaki bağlantılar birer kenar olarak ifade edilir [36]. Bu yaklaşımda, ROI'lerin beyin fonksiyonu üzerinde ana etkiye sahip olmadığı düşünülmez [31]. Ayrıca, ROI parçalama şemalarında, insan beyninin verileri birkaç farklı ROI'ye bölünür. Bu durumda tüm ROI'ler düğüm olarak tanımlanır ve aralarında bağlantılar bulunur. Bu bağlantılara uç nokta adı verilir. ROI'ler anatomik, fonksiyonel veya gelişimsel şekillerde ifade edilebilir. Örneğin, anatomik ifadeyle ROI'ler beyin hipokampus, perirhinal korteks, fissür, pons gibi çeşitli anatomik bölgelerine karşılık gelir [36].

Bu çalışmada, çok ölçekli fonksiyonel beyin parselleri kullanıldı. Beyin parselleri, BASC adı verilen kararlı kümelerin bootstrap analizi yöntemiyle oluşturuldu [31]. Ölçekler, MSTEPS adı verilen veri tabanlı bir yöntem kullanılarak seçildi [37].

Bu tez çalışması kapsamında OSB tespiti için iki ayrı sınıflandırma yaklaşımı önerilmiştir. İlk yöntem bağlantı matrisi tabanlı özellik çıkarmayı ve sınıflandırmayı esas almaktadır. İkinci yöntemde ise sıfır dolgu tabanlı bir özellik çıkarma ve sınıflandırma yaklaşımı önerilmiştir. Her iki yöntemde de ilk olarak veriler üzerinde ön işleme adımları uygulanmıştır. Veri ön işleme adımları önerilen her iki model için de aynıdır.

Bu bölümde ilk olarak veri ön işleme adımları anlatılmaktadır. Sonrasında ise OSB tespiti için önerilen yöntemler tanıtılmaktadır.

3.1 VERİ ÖN İŞLEME ADIMLARI

Veri ön işleme adımlarında Nielsen, Jared A. ve ark. önerdiği yöntemler kullanılmıştır [38]. İlk olarak, kesitler arasındaki çekim süresi farklılıklarını düzeltmek için kesit zamanlaması düzeltilmesi uygulandı. Ardından, her bir hacmi ilk hacme hizalayarak hareket artefaktlarını hesaba katmak için yeniden hizalama ve yeniden dilimleme düzeltilmesi yapıldı. Daha sonra BOLD görüntülerini MPRAGE anatomik sekansına kaydetmek için ortak kayıt (coregistration) yapıldı.

MPRAGE görüntüsü MNI şablon beynine normalleştirildi ve normalleştirme dönüşümü ortak kayıt BOLD görüntülerine de uygulandı. MPRAGE görüntüsünün segmentasyonu gri madde, beyaz madde ve beyin omurilik sıvısı (BOS) bileşenlerini tanımlamak için gerçekleştirilmiştir.

Verilere 0,001-0,1 Hz aralığında voksel bazında bir bant geçiren filtre uygulanarak düşük frekanslı kaymalar giderilirken nöral bilgilerin dahil edilmesi sağlanmıştır. Ek olarak, veri setinde mevcut olan nispeten kısa zaman serileri göz önünde bulundurularak düşük frekansların katkısını daha da ortadan kaldırmak için doğrusal bir eğilimsizleştirme (detrend) gerçekleştirilmiştir.

Ortalama zaman serileri, BOLD görüntülerine uygulanan maskelerle tanımlanan belirli ilgi bölgelerinden (ROI'ler) çıkarılmıştır. Bu ROI'ler CSF, beyaz madde ve kafa derisi ve yüz yumuşak dokularından oluşan bir maske içeriyordu. Voksel bazında regresyon kullanılarak gerçekleştirilmiş ve BOS, beyaz madde, yumuşak doku ve yeniden hizalama adımından elde edilen 6 hareket parametresi regresör olarak kullanılmıştır.

Kök-ortalama-kare yer değiştirmesi olan hacimler ve belirlenen eşikleri aşan DVARS kaldırılarak hareket artefaktlarını gidermek için hareket fırçalama uygulandı. Kalan hacimler daha ileri analiz için birleştirildi. Tutulan hacimlerin sayısı otizm ve tipik gelişim gösteren gruplar arasında farklılık göstermiştir.

Hiçbir uzamsal yumuşatma yapılmamış ve ne global ortalama sinyal ne de gri madde zaman akışları voksel bazında verilerden regresyona tabi tutulmuştur. Bu ön işleme yaklaşımı, sonraki analizler için ilgili sinirsel bilgileri korurken, hareket ve fizyolojik gürültü gibi çeşitli artefaktları ve karıştırıcı faktörleri ele almayı amaçlamıştır.

3.2 BAĞLANTI MATRİSİ TABANLI ÖZELLİK ÇIKARMA YÖNTEMİ İLE SINIFLANDIRMA

Bu tez çalışması kapsamında önerilen ilk yaklaşımda rs-fMRI verileri ön işleme adımına tabi tutulduktan sonra BASC beyin atlası kullanılarak zaman serisi özellikleri çıkarılmaktadır. Bu yöntemde MSTEP değeri 122 olarak kullanılmıştır. Beyin ağının elde edilmesinde sonra ise korelasyon değerleri çıkarılarak bağlantı matrisi oluşturulmaktadır. Nihai olarak elde edilen bağlantı matrisi farklı makine öğrenmesi modelleri ile sınıflandırılmak suretiyle OSB ve kontrol grubu ayrımı gerçekleştirilmektedir.

Beyin ağındaki bir kenar, iki düğüm arasındaki temel bir bağlantı anlamına gelir. Bir çift ROI arasındaki bir kenar genellikle Pearson korelasyon katsayısı (PCC) ile ağırlıklandırılır. Bu

işlem için rs-fMRI ölçümlerinden elde edilen beyin ağının zaman serileri kullanılır. PCC r_{xy} aşağıdaki gibi hesaplanır:

$$r_{xy} = \frac{\sum_{b=1}^s (x_b - x_m)(y_b - y_m)}{\sqrt{\sum_{b=1}^s (x_b - x_m)^2} \sqrt{\sum_{b=1}^s (y_b - y_m)^2}} \quad (29)$$

Burada x ve y zaman serileri, s uzunluk, x_b ve y_b zaman serilerinin b -inci bileşenleri, x_m ve y_m ise x ve y zaman serilerinin ortalamalarıdır. Bu çalışmada, ABIDE 1 veri setinin ön işlemden geçirilmiş hali kullanılmıştır. Ön işleme aşamalarına ilişkin detaylı bilgiler Bölüm 3.1’de verilmiştir.

Bu tez çalışması kapsamında OSB tespiti için önerilen bu ilk metotta standart RNN, LSTM, CNN ve bunlar dahil olmak üzere 7 farklı makine öğrenmesi modeli kullanılmıştır. Yukarıdaki bölümlerde anlatılan şekilde toplam 7381 özellik elde edilmiştir. Özellikler makine öğrenmesi modellerine uygulanırken 61x121 boyutlarına yeniden boyutlandırılarak uygulanmıştır.

Önerilen CNN modeli, 4 öğrenilebilir katmandan oluşmaktadır. İlk katman, 32 filtreden oluşan ve 3x3 boyutlarında bir konvolüsyon katmanını içermektedir. Bu katmanda ReLU aktivasyon fonksiyonu kullanılmıştır. Ardından, 0.2 değerine sahip bir bırakma (dropout) katmanı yer almaktadır. Bırakma katmanından sonra, 2x2 boyutlarında bir max-pooling katmanı bulunmaktadır. Bu katmanlardan sonra, sırasıyla bir konvolüsyon katmanı, bir bırakma katmanı ve bir max-pooling katmanı daha yer almaktadır. Bu katmanlar, ilk katmanlardaki özellik değerlerine sahiptir. Bu katmanların çıktısı, 150 düğümden oluşan tam bağlantılı bir katmana giriş olarak uygulanır. Tam bağlantılı katmanın aktivasyon fonksiyonu sigmoiddir. Bu aşamadan sonra, değeri 0.2 olan bir bırakma katmanı daha bulunmaktadır. Son aşamada ise, 1 düğümden oluşan ve sigmoid aktivasyon fonksiyonuna sahip tam bağlantılı bir katman yer almaktadır.

CNN-RNN modelinde yukarıda verilen CNN modelinden farklı olarak 150 düğümden oluşan tam bağlı katman yerine zamansal bağımlılıkları algılamak için 150 düğümden oluşan bir RNN katmanı bulunmaktadır. Diğer tüm değerler CNN modeli ile aynıdır. CNN-BiRNN modelinde ayrıca RNN katmanı yerine bir BiRNN katmanı bulunmaktadır.

RNN ve LSTM modellerinin ilk katmanları sırasıyla 150 birimden oluşan RNN ve LSTM katmanlarıdır. RNN ve LSTM katmanlarının aktivasyon fonksiyonu Ölçekli Üstel Doğrusal Birimdir (SELU). λ ve α sabit değerleri ile SELU fonksiyonu şu şekilde ifade edilebilir:

$$selu(x) = \lambda \begin{cases} x & \text{if } x > 0 \\ \alpha e^x - \alpha & \text{if } x \leq 0 \end{cases} \quad (30)$$

Bu katmandan sonra 0,2'lik bir bırakma katmanı bulunmaktadır. Son katman ise 1 düğümden oluşan tam bağlı bir katman içermektedir. Modellerin detaylı parametreleri Tablo 3-1'de verilmiştir.


Tablo 3-1: Makine öğrenmesi model parametreleri

	CNN	CNN-RNN	RNN	LSTM
1. Katman	Konvolüsyonel Katman Filtre Sayısı: 32, Filtre Boyutu: 3x3 Aktivasyon: ReLU	Konvolüsyonel Katman Filtre Sayısı: 32, Filtre Boyutu: 3x3 Aktivasyon: ReLU	RNN Katman Düğüm Sayısı: 150 Aktivasyon: SELU	LSTM Katman Düğüm Sayısı: 150 Aktivasyon: SELU
2. Katman	Dropout Katman Değer:0.2	Dropout Katman Değer:0.2	Dropout Katman Değer:0.2	Dropout Katman Değer:0.2
3. Katman	Max-pooling Boyut: 2x2	Max-pooling Boyut: 2x2	Tam Bağlı Katman Düğüm Sayısı: 1 Aktivasyon: Sigmoid	Tam Bağlı Katman Düğüm Sayısı: 1 Aktivasyon: Sigmoid
4. Katman	Konvolüsyonel Katman Filtre Sayısı: 32, Filtre Boyutu: 3x3 Aktivasyon: ReLU	Konvolüsyonel Katman Filtre Sayısı: 32, Filtre Boyutu: 3x3 Aktivasyon: ReLU		
5. Katman	Dropout Katman Değer:0.2	Dropout Katman Değer:0.2		
6. Katman	Max-pooling Katman Boyut: 2x2	Max-pooling Katman Boyut: 2x2		
7. Katman	Tam Bağlı Katman Düğüm Sayısı: 150 Aktivasyon: Sigmoid	RNN Katman Düğüm Sayısı: 150 Aktivasyon: SELU		
8. Katman	Dropout Katman Değer:0.2	Dropout Katman Değer:0.2		
9. Katman	Tam Bağlı Katman Düğüm Sayısı: 1 Aktivasyon: Sigmoid	Tam Bağlı Katman Düğüm Sayısı: 1 Aktivasyon: Sigmoid		

3.3 SIFIR DOLGU TABANLI ÖZELLİK ÇIKARMA YÖNTEMİ İLE SINIFLANDIRMA

Bağlantı matrisi yöntemi ile elde edilen özellikler kullanılarak yapılan sınıflandırma işleminin yanı sıra sıfır dolgu tabanlı yöntem önerilmiştir. ABIDE 1 veri setindeki rs-fMRI görüntüleri farklı uzunluklardaki zaman serilerinden oluşmaktadır. Bölüm 3.1’de tarif edilen ön işleme adımları zaman serisi içerisindeki her bir ayrı MRI görüntüsünün boyutunu sabit bir boyuta ayarlamaktadır. Fakat zaman serilerinin uzunlukları farklı olmaya devam etmektedir. Bu durumda ML modellerine uygulanmalarını zorlaştırmaktadır. Bu problemin üstesinden gelmek için tüm rs-fMRI görüntüleri en uzun zaman serisiyle aynı boyutta olacak şekilde sıfır ile doldurulmuşlardır. Bu işlem için en uzun zaman serisinden daha kısa olan tüm rs-fMRI verilerinin son kısmına sıfır eklenmiştir. Sıfır dolgu işlemi ön işleme ve BASC beyin atlası uyguladıktan sonra oluşan zaman serisine yapılmıştır. Burada MSTEP değeri 444 olarak seçilmiştir. Dolayısıyla zaman serisi içerisindeki her bir ayrı MRI görüntüsü için 444 özellik elde edilmektedir. En uzun zaman serisinin değeri ise 316’dır. Bu nedenle her bir rs-fMRI görüntüsü için 444×316 boyutlarında bir veri elde edilmektedir. Her bir rs-fMRI verisinin sahip olduğu bu boyutu azaltabilmek için matris formatındaki veri üzerinde önce düzleştirme işlemi uygulanmış sonrasında özellik seçimi yapılmıştır. Düzleştirme işleminin sonucunda 140304 özellikten oluşan bir vektör oluşturulmuştur. Özellik seçimi için SelectKBest algoritması uygulanmıştır. Burada n pozitif bir tam sayı olmak üzere her defasında $n \times 444$ özellik seçilerek sınıflandırma işlemi gerçekleştirilmiştir.

Özellik çıkarma işlemi yukarıda belirtilen şekilde tamamlandıktan sonra elde edilen özellikler. Farklı makine öğrenmesi modellerine uygulanarak sınıflandırma işlemi gerçekleştirilmiştir. Son yıllarda derin öğrenme modelleri birçok çalışmada geleneksel makine öğrenmesi modellerine kıyasla daha yüksek başarımlar ortaya koymaktadır. Fakat hesaplama maliyetleri ve buna bağlı olarak eğitim süreleri geleneksel makine öğrenmesi algoritmalarına kıyasla oldukça yüksektir. Bu nedenle çalışmanın bu kısmında kNN, MLP, LDA ve SVM gibi daha geleneksel algoritmalar tercih edilmiştir.



Şekil 3-1: Sıfır dolgu tabanlı özellik çıkarma ve sınıflandırma yöntemine ait blok diyagram

Bu tez çalışması kapsamında kullanılan MLP modeli 2 gizli katmandan oluşmaktadır. Her katmanda 100 nöron yer alır. Aktivasyon fonksiyonu olarak *tanh* tercih edilmiştir. Model maksimum 10 Bin iterasyon olacak şekilde eğitilmiştir. Ayrıca optimizasyon algoritması olarak Adam kullanılmıştır. kNN algoritmasında ise k değeri 13 ve uzaklık algoritması olarak ta kosinüs kullanılmıştır. SVM algoritmasında çekirdek olarak radyal tabanlı fonksiyon kullanılmıştır. LDA algoritmasında da tekil değer ayrışımı yöntemi kullanılmıştır. Şekil 3-1’de önerilen yöntemle ilişkin blok diyagram görülmektedir.

4. SONUÇLAR

OSB'nin erken teşhisi, hastalığın ilerlemesini kontrol altında tutmak için çok önemlidir. Öte yandan, günümüzdeki tanı yöntemleri hastalığın neden olduğu davranış bozukluklarını gözlemlemeye dayanmaktadır. Bu aşamada hastalık çoktan kalıcı, geri dönüşü olmayan hasarlara neden olmuştur. Bu açıdan OSB'nin davranış bozukluklarını takip etmek yerine tıbbi görüntüleme teknikleri kullanılarak erken evrede teşhis edilmesi çok önemlidir [3][4]. Bu çalışmada, rs-fMRI verileri üzerinde OSB tespiti üzerine bir çalışma sunulmuştur. rs-fMRI, MEG, PET ve EEG gibi birçok teknikle karşılaştırıldığında çok daha iyi uzamsal çözünürlük ve kabul edilebilir bir zamansal çözünürlük sağlar.

Bu bölümde bu tez çalışması kapsamında önerilen iki ayrı yöntemle elde edilen sonuçlar paylaşılmaktadır. Sağlıklı bir karşılaştırma yapmak amacıyla, ABIDE I veri setindeki 871 örnek kullanılmıştır [22][23][24][39]. Bu örneklerin 403'ü OSB tanısı almış hastalarla ilişkilendirilirken, geriye kalan 468 örnek kontrol grubunu oluşturmaktadır.

4.1 BAĞLANTI MATRİSİ TABANLI ÖZELLİK ÇIKARMA YÖNTEMİ İLE ELDE EDİLEN SINIFLANDIRMA SONUÇLARI


Tablo 4-1'de, 10 kat çapraz doğrulama testleriyle elde edilen ortalama sınıflandırma performansları sunulmaktadır. Sınıflandırma sonuçlarına göre en yüksek performans değeri %74,74 ile RNN tarafından elde edilmiştir. Benzer şekilde, SENS değerinde en iyi skor %72,95 ile yine RNN tarafından elde edilmiştir. SPEC değeri açısından ise en iyi skor LSTM modeline aittir ve %81,41 olarak gerçekleşmiştir. Genel olarak RNN ve LSTM tabanlı modellerin sınıflandırma performanslarının birbirine çok yakın olduğu gözlenmektedir. Bununla birlikte, CNN tabanlı modellerin performansı diğer modellere göre oldukça düşüktür. CNN, CNN-RNN ve CNN-BiRNN modelleri için sırasıyla %70,26, %67,28 ve %67,51 sınıflandırma başarısı elde edilmiştir. CNN'ler uzamsal bağımlılıkları yakalama konusunda başarılı olsa da, RNN tabanlı ağlar zamansal bağımlılıkları yakalama konusunda daha iyi performans gösterir [36]. Bu çalışmada kullanılan beyin ağı bağlamında, zamansal bağımlılıkların önemli ölçüde daha belirgin olduğu değerlendirilebilir. Ayrıca, sınıflandırma performansı açısından tüm LSTM ve RNN modellerinin birbirine yakın performans sergilediği görülmektedir. Yukarıdaki bölümlerde belirtildiği gibi, LSTM aslında standart bir RNN modelinin özel bir türüdür. Standart RNN modellerinin uzun dönemli bağımlılıkları yakalama konusundaki dezavantajlarını ortadan kaldırmada başarılıdır.

Elde edilen sonuçlara göre, uzun dönemli bağımlılıkların sınıflandırma performansını büyük ölçüde etkilemediği değerlendirilebilir. Ayrıca, BiRNN ve BiLSTM modellerinin sınıflandırma performansını çok fazla değiştirmedeği, ancak SENS ve SPEC değerlerini etkilediği görülmektedir.


Tablo 4-1: Ortalama sınıflandırma performansları

METHOD	ACC	SENS	SPEC
RNN	74.74	72.95	76.28
BiRNN	74.51	68.73	79.49
LSTM	74.4	66.25	81.41
BiLSTM	74.51	72.21	76.5
CNN	70.26	66.01	73.93
CNN-RNN	67.28	57.57	75.64
CNN-BiRNN	67.51	65.51	69.23


Grafik 4-1 ve 4-2'de görüldüğü gibi, RNN, BiRNN, LSTM ve BiLSTM modellerinin sınıflandırma performansları birbirine çok yakındır. Ancak, RNN ve BiLSTM modellerinin SENS değerleri diğer modellere göre önemli ölçüde daha yüksektir. Grafik 4-3'te, 4 farklı modelin SENS değerlerinin kutu grafiği gösterimi görülebilir. Bu grafikte, hastalık teşhisi konulması gereken bir kişiye yanlışlıkla sağlıklı denilmesi durumunda SENS değerinin düşeceği anlaşılabılır. Yani, yanlış negatif (FN) değerinin azalması, hastalığın neden olabileceği kalıcı vücut hasarlarının erken aşamada önlenmesi açısından daha kritik bir öneme sahiptir. Grafik 4-1'de, ACC değerlerinin kat bazında karşılaştırılması gösterilmektedir. Ayrıca, Grafik 4-2'de RNN, BiRNN, LSTM ve BiLSTM modellerinden elde edilen ACC değerlerinin kutu grafiği gösterimi görülebilir. Sonuçlar değerlendirildiğinde, RNN modelinin daha istikrarlı sonuçlar verdiği gözlenmektedir. Grafik 4-2'de verilen değerler incelendiğinde, RNN ve BiLSTM modellerinin SENS değerlerinin benzer bir davranış sergilediği görülmektedir. Ancak RNN modelinde SENS için elde edilen tepe değerlerinin daha iyi olduğu görülmektedir. Sonuç olarak, kullanılan mevcut özellikler için uzun dönemli bağımlılıkların performans üzerinde önemli bir etkiye sahip olmadığı değerlendirilebilir.



Grafik 4-1: ACC değerlerinin kat bazında karşılaştırılması




Grafik 4-2: ACC değerlerinin kat bazında kutu grafiği gösterimi



Grafik 4-3: SENS değerlerinin kat bazında kutu grafiği gösterimi

Grafik 4-4, dört model için SPEC değerlerinin karşılaştırmasını göstermektedir. Ortalama SPEC değerinde en yüksek performans LSTM modeline aittir. RNN, LSTM ve BiLSTM modellerinde her bir kat bazında birbirine yakın değerler elde edilmiştir. BiRNN modelinde ise en düşük ve en yüksek değerler diğer modellere göre daha geniş bir aralıkta gerçekleşmiştir. Ayrıca tüm modellerin SPEC değerleri SENS değerlerinden daha yüksektir. Bunun sebebinin makine öğrenmesi modellerinin genel olarak çoğunluk sınıfına yatkın olmasından kaynaklandığı düşünülmektedir.



Grafik 4-4: SPEC değerlerinin kat bazında kutu grafiği gösterimi

Son olarak, önerdiğimiz ilk modeli literatürdeki diğer çalışmalarla karşılaştırıyoruz. Tablo 4-2, bu çalışmada kullanılan modellerin literatürdeki diğer çalışmalarla karşılaştırılmasını göstermektedir. ABIDE 1 veri setinde toplam 1112 örneklem bulunmaktadır. Ancak veri setinin tamamını kullanmak yerine belirli kriterler doğrultusunda farklı sayıda örnek kullanılarak çalışmalar gerçekleştirilmiştir. Ayrıca kullanılan özellikler ve sınıflandırma yöntemleri de farklılık gösterebilmektedir. Sağlıklı bir karşılaştırma yapabilmek için yukarıda bahsedilen bölümleri Tablo 4-2'de listeliyoruz. Bunlara ek olarak, OSB çalışmalarında farklı doğrulama yöntemleri de kullanılabilir. Ayrıca, OSB çalışmalarında farklı doğrulama yöntemleri de kullanılabilir. Tablo 4-2'de gösterilen çalışmaların tamamında 10 kat çapraz doğrulama yöntemi kullanılmıştır. Tablo 4-2'de sunulan sonuçlar incelendiğinde, en yüksek performans değerinin power atlası ve derin sinir ağı kullanılarak yapılan çalışmada elde edildiği görülmektedir [43]. Bu çalışmada, önceden işlenmiş verilere bir power beyin atlası uygulanmış ve ardından PCC (Pearson korelasyon katsayısı) kullanılarak korelasyon matrisleri oluşturulmuştur. Bu yöntemle elde edilen performans değeri %79,2 olarak kaydedilmiştir [43]. Tablo 4-2'de verilen en düşük performans değeri ise Abraham ve arkadaşları tarafından yapılan çalışmada elde edilmiştir[23]. Bu çalışmada, OSB tespiti için birden fazla beyin atlası kullanılmıştır [23]. Sonuç olarak, %66,8'lik bir performans değerine ulaşılmıştır [23]. Bu çalışmada ise, Tablo 4-2'de verilen sonuçlar arasında

en yüksek ikinci performans değeri, 61x121 boyutlarında toplam 7381 özellik kullanılarak elde edilmiştir. Bu sonuçlar, RNN tabanlı ağların zamansal korelasyonları yakalama konusundaki başarısını doğrulamaktadır. [43]'de elde edilen performans değeri bu çalışmadan daha yüksektir. Ancak burada performansı etkileyen ana faktörün, sınıflandırma algoritması yerine çıkarılan özellikler olduğu değerlendirilmektedir.

Tablo 4-2: Önerilen ilk yöntemin ACC değerlerinin literatürdeki diğer çalışmalarla karşılaştırılması

Çalışmalar	Özellikler	Sınıflandırma Yöntemi	Örnek Sayısı	Acc. (%)
[21]	Harvard-Oxford Atlas / Riemannian ve Korelasyon matrisi	Lojistik Regresyon - l_2	871	71.7
[40]	Craddock 200 Atlas / Fenotipik Veriler	LSTM	1100	70.1
[39]	Craddock 200 Atlas / PCC	Denoising Otoenkoder, Derin Sinir Ağı	1035	70.0
[22]	Çoklu Atlas (Harvard-Oxford, Structural, Yeo Functional, Craddock 200 etc.)	SVM- l_2	871	66.8
[41]	Çoklu Atlas (Harvard-Oxford, Craddock 200, Craddock 400, Dosenbach 160, Eickhoff-Zilles vb.)	3D CNN	774	73.3
[23]	Harvard-Oxford Atlas / PCC	CNN	871	69.5
[42]	Power Atlas / PCC, Sıralı Özellik Seçme	LDA	871	77.7
[43]	Power Atlas / PCC	Derin Sinir Ağı	871	79.2
[44]	Craddock 200, PCC, F-skor özellik seçme	Yığılmış Denoising Otoenkoder	1035	70.9
Bu Çalışma İlk Yöntem	BASC Atlas, MSTEPS	Standart RNN	871	74.7
Bu Çalışma İlk Yöntem	BASC Atlas, MSTEPS	BiRNN	871	74.5
Bu Çalışma İlk Yöntem	BASC Atlas, MSTEPS	LSTM	871	74.4
Bu Çalışma İlk Yöntem	BASC Atlas, MSTEPS	BiLSTM	871	74.5

4.2 SIFIR DOLGU TABANLI ÖZELLİK ÇIKARMA YÖNTEMİ İLE ELDE EDİLEN SINIFLANDIRMA SONUÇLARI

Bu bölümde sıfır dolgu tabanlı özellik çıkarma yöntemiyle elde edilen sonuçlar verilmektedir. Tablo 4-3’de farklı n değerleri için sınıflandırma işleminin MLP modeli ile elde edilen sonuçları görülmektedir. En yüksek ACC değeri $n=9$ ($9 \times 444 = 3996$ özellik) durumu için gerçekleşmiştir. SENS, F-Score ve AUC içinde en yüksek skorlar bu özellik sayısında gerçekleşmiştir. Diğer özellik sayıları içinde birbirine oldukça yakın değerler elde edilmiştir. Aynı zamanda sonuçlar Bölüm 4.1’de verilen skorlara göre de belirgin şekilde daha iyidir. En düşük sonuçlar $n=4$ durumu için gerçekleşmiştir. Buradaki başarımlar değeri %92,08 olarak hesaplanmıştır.

Tablo 4-3: Önerilen ikinci yöntemin farklı özellik sayılarında MLP ile değerlendirilmesi

	ACC	SPEC	SENS	PREC	F-SCORE	AUC
n=4	92.08	90.60	93.80	89.57	91.64	0.922
n=5	94.26	94.02	94.54	93.15	93.84	0.943
n=6	93.23	92.74	93.80	91.75	92.76	0.933
n=7	93.57	92.74	94.54	91.81	93.15	0.936
n=8	93.57	93.38	93.80	92.42	93.10	0.936
n=9	94.72	93.80	95.78	93.01	94.38	0.948
n=10	94.37	94.66	94.04	93.81	93.93	0.944
n=11	94.14	92.95	95.53	92.11	93.79	0.943
n=12	94.14	94.02	94.29	93.14	93.71	0.942
n=13	94.26	93.59	95.04	92.74	93.87	0.943
n=14	93.69	92.52	95.04	91.63	93.30	0.938
n=15	94.03	93.80	94.29	92.91	93.60	0.940

Tablo 4-4’te sıfır dolgu ve özellik seçme yöntemi ile oluşturulan özelliklerin farklı sınıflandırma algoritması yapılan testleri görülmektedir. SPEC ve PREC için en yüksek skorlar SVM modeline aittir. Diğer metriklerde ise en yüksek performanslar MLP modeli gerçekleşmiştir. Öte yandan KNN ve LDA modellerinin performansları bunların bir miktar gerisindedir. Fakat literatürdeki diğer çalışmalarla kıyaslandığında buradaki sonuçların da kabul edilebilir değerlerde olduğunu göstermektedir. Bu doğrultuda başarımdaki temel artışın özellik çıkarma yönteminden kaynaklandığı değerlendirilmektedir.

Tablo 4-4: Önerilen ikinci yöntemin farklı sınıflandırma algoritmaları ile değerlendirilmesi


	ACC	SPEC	SENS	PREC	F-SCORE	AUC
MLP	94.72	93.80	95.78	93.01	94.38	0.948
KNN	84.85	85.90	83.62	83.62	83.62	0.848
LDA	86.34	87.18	85.36	85.15	85.25	0.863
SVM	93.23	95.51	90.57	94.56	92.52	0.930

Sıfır dolgu işlemi doğal dil işleme gibi farklı zaman serisi uzunluklarına sahip problemlerde sıklıkla uygulanmaktadır. Değişken uzunluktaki zaman serisi verileriyle çalışırken, sıfır dolgu yöntemi bilgi kaybını en aza indirmek için kullanışlı bir yaklaşımdır. Bu yöntem, modelin doldurulmuş bölgeleri göz ardı etmeyi öğrenmesine yardımcı olur ve eksik veya eksik verileri etkili bir şekilde ele almasını sağlar. Sıfır dolgu, zaman serisindeki boşlukları sıfırlarla doldurarak tüm orijinal veri noktalarını korur. Bu şekilde, orijinal veri noktalarının göreceli konumları ve zaman serisinin genel yapısı korunur. Sıfırlar anlamlı bilgiler taşımaz, ancak zaman serisindeki eğilimleri ve desenleri anlamak için orijinal verilere dayanan modeller için önemli bir bileşendir. Bu yöntem, test verilerinin farklı uzunluklarda dizilere sahip olduğu durumlarda veya gerçek zamanlı verilerin dinamik olarak değişen uzunluklara sahip olduğu durumlarda faydalı olabilir. Örneğin, bir modelin bir zaman serisini işlerken, veri noktalarının eksik olduğu veya verinin tam olarak toplanamadığı durumlarla karşılaşılabilir. Bu durumda sıfır dolgu kullanarak, model eksik verilerle başa çıkabilir ve zaman serisindeki desenleri tanımlayabilir. Bu kabiliyetlerin Tablo 4-3'te görüleceği gibi önerilen modelin literatürdeki diğer modellere kıyasla belirgin bir iyileşme sağlamasına neden olduğu değerlendirilmektedir.

4.2.1 Öznitelik Seçiminde Beyin Bölgelerinin Etkisi

Çalışmanın son bölümünde farklı ROI'lerin öznitelik seçiminde ne kadar etkili olduğu değerlendirilmiştir. Bu işlem için nihai öznitelik kümesine farklı ROI'lerin kaç kez dahil olduğu ve özellik seçimi sırasında almış oldukları toplam SelectKBest skorları dikkate alınmıştır. Grafik 4-5'te beynin farklı ROI bölgeleri almış oldukları SelectKBest skorlarına göre azalan sırada dizilmişlerdir. Grafik üzerinde sol eksen toplam puan değerini sağ eksen ise ilgili ROI bölgesinin öznitelik kümesine kaç kez dahil olduğunu göstermektedir. Grafikteki veriler incelendiğinde bazı ROI bölgelerinin diğer kısımlara göre özellik seçimi sırasında daha etkili olduğunu göstermektedir. Bölüm 2.2'de belirtildiği gibi SelectKBest, hedef değişkene olan bireysel

katkılarını göz önünde bulundurarak her bir özelliğin önemini veya alaka düzeyini bağımsız olarak değerlendirmek için istatistiksel ölçümlere dayalı olarak çalışmaktadır. Özellikle, her bir özellik ile hedef değişken arasındaki ilişkinin gücünü belirlemek için tek değişkenli istatistiksel testler kullanır. Buradan hareketle bazı ROI'lerin TK ve OSB'li bireyler arasında daha fazla ayırt ediciliğe sahip olduğu değerlendirilebilir.



Grafik 4-5: Öznitelik kümesindeki sayılara ve SelectKbest skorlarına göre ROI'lerin değerlendirilmesi

Tablo 4.5'de bu çalışma kapsamında kullanılan toplam 444 ROI bölgesinden SelectKBest özellik seçimi sonucunda skor ve sayı bazında en yüksek değere sahip olan 87 tanesinin sonuçları görülmektedir. Skor bazında en yüksek değerler 208, 389, 336 ve 119. ROI'lere aittir. Bu bölgeler için skorlar sırasıyla 126,32, 126,04, 124,69 ve 120,16 olarak gerçekleşmiştir. Öznitelik kümesinde ilgili bölgelerin kaç kez dahil olduğuna göre yapılan incelemede de yine aynı bölgelerin yüksek sayılara sahip olduğu görülmektedir. 336. ROI öznitelik kümesinde 22 kez, 389. ROI 20 kez ve 208 ile 119. ROI'ler 19 kez dahil olmuştur.

Grafik 4-6 ve Grafik 4-7'de de sırasıyla öznitelik kümesindeki sayı ve SelectKBest skor değerine ROI'lerin ağaç haritası grafikleri görülmektedir. Her iki grafik bir arada incelendiğinde bazı ROI'lerin OSB için diğer bölgelere kıyasla daha ayırt edici olduğu değerlendirilmektedir.

Tablo 4-5: ROI'lerin öznitelik kümesinde yer alma sayıları ve toplam SelectKbest skorları

Region	Count	Score	Region	Count	Score	Region	Count	Score
208	19	126.32	21	14	91.32	116	12	81.21
389	20	126.04	431	13	91.02	246	11	80.40
336	22	124.69	302	14	90.53	105	11	80.24
119	19	120.16	343	15	90.25	18	11	80.14
185	16	110.51	194	13	88.78	309	12	80.08
183	17	110.33	440	15	88.43	268	12	79.99
410	17	109.83	228	14	88.13	120	12	79.27
197	15	108.86	318	12	87.83	342	12	79.16
315	16	108.49	212	14	87.31	4	13	78.63
38	16	106.70	64	13	87.09	91	12	78.46
160	17	105.74	412	14	87.05	283	12	78.16
217	15	104.02	32	12	86.82	348	12	78.13
411	16	102.35	213	14	86.68	55	13	78.01
437	15	101.54	93	14	86.14	292	13	77.64
224	16	101.49	345	13	86.08	380	11	77.62
324	14	99.27	298	14	85.19	353	13	77.14
144	15	98.78	39	13	85.11	214	11	77.11
320	15	97.23	112	12	84.99	314	13	77.04
70	16	96.83	335	12	84.81	78	14	76.96
316	16	96.40	204	14	84.65	423	12	76.51
405	14	96.07	76	10	84.65	121	12	75.95
328	15	95.38	329	13	84.58	311	12	75.91
421	14	93.52	312	12	84.27	135	12	75.83
184	15	93.27	333	13	84.26	63	11	75.21
376	16	93.26	159	12	84.15	303	11	74.86
188	13	93.03	114	10	83.61	61	12	74.64
97	12	92.91	262	14	83.58	129	11	74.46
181	13	91.90	434	11	83.14	418	11	74.10
308	15	91.58	60	11	81.37	368	11	74.08

5. TARTIŞMA

Literatürdeki çalışmalarda elde edilen başarımları artırmak için bu çalışmada OSB'nin rs-fMRI verileri üzerinden tespitinde iki farklı yaklaşım sunulmaktadır. Her iki yaklaşımda da ABIDE 1 veri setine bir dizi ön işleme adımı uygulanmıştır. İlk yaklaşımda BASC beyin atlası kullanılarak zaman serisi ölçümleri gerçekleştirilmiş sonrasında PCC ile bağlantı matrisi elde edilmiş ve derin öğrenme modelleri ile sınıflandırma işlemleri gerçekleştirilmiştir. PCC uygulamak veriler üzerindeki zaman bilgilerinin büyük ölçüde kaybolmasına neden olmaktadır. Bu durumda sınıflandırma performansını olumsuz etkilediği değerlendirilmektedir. Bu doğrultuda ikinci yaklaşımda zaman serisi özellikleri çıkarıldıktan sonra PCC kullanarak bağlantı matrisi elde etmek yerine sıfır dolgu (zero-padding) işlemi uygulanmıştır.

Birçok makine öğrenimi modeli, verimli hesaplama ve uyumluluk için sabit girdi boyutları gerektirir. Sıfır dolgu, veri kümesindeki en uzun dizinin uzunluğuyla eşleşecek şekilde daha kısa dizileri sıfırlarla doldurarak zaman serisi verilerinin uzunluğunu standartlaştırmanıza olanak tanır. Bu, tüm girdi dizilerinin aynı boyutlara sahip olmasını sağlayarak toplu işlemeyi kolaylaştırır ve genel eğitim ve çıkarım hattını basitleştirir. Ayrıca zaman serisi verileri genellikle bir zaman adımındaki değerlerin önceki değerlerden etkilendiği zamansal bağımlılıklar sergiler. Sıfır dolgu, dolgulu dizilerin başında ve/veya sonunda yeterli bağlama sahip olmasını sağlayarak modelin zamansal bağımlılıkları daha etkili bir şekilde yakalamasına olanak tanır.

Sıfır dolgu, makine öğrenimi modellerinin genelleme kabiliyetini artırabilir. Bunlara ilave olarak daha kısa zaman serilerini sıfırlarla doldurarak, model doldurulmuş bölgeleri göz ardı etmeyi öğrenir ve eksik verileri etkili bir şekilde ele almayı öğrenir. Bu, test verileri farklı uzunluklarda diziler içerdiğinde veya gerçek zamanlı veriler dinamik veri toplama nedeniyle değişen uzunluklara sahip olabildiğinde faydalı olabilir [25].

Değişken uzunluktaki zaman serisi verileriyle uğraşırken, fazla verilerin kesilmesi veya atılması bilgi kaybına neden olabilir. Sıfır dolgu, boşlukları sıfırlarla doldururken tüm orijinal veri noktalarını korumanıza olanak tanır. Doldurulan sıfırlar anlamlı bilgiler aktarmasa da, orijinal veri noktalarının göreceli konumlarının korunmasına yardımcı olarak zaman serisinin genel yapısını korur ve potansiyel olarak değerli bilgi kaybını en aza indirir [26]. Tüm bu sayılan sebeplerin önerilen ikinci modelin OSB sınıflandırmasında belirgin şekilde daha iyi bir sonuç vermesine neden olduğu değerlendirilmektedir. Önerilen ikinci modelde sıfır dolgu işleminden sonra düzleştirme işlemi uygulanarak veriler vektör formuna dönüştürülmüştür. Vektör formuna dönüştürülen veriler üzerinden boyutsallığı azaltmak amacıyla bir özellik seçim işlemi

uygulanmıştır. Ayrıca seçilen özellikler incelenerek hangi ROI'lerin TK ve OSB'li bireylerde daha ayırt edici olabileceği konusunda bir değerlendirme sunulmuştur.

Sonuç olarak, bu tez çalışması kapsamında rs-fMRI verilerinden OSB'nin tespiti için iki farklı özellik çıkarma yöntemi önerilmiştir. rs-fMRI verilerinden OSB tespiti için literatürde önerilen farklı özellik çıkarma yöntemleri olsa da bunlar arasından genel kabul görmüş bir yöntem bulunmamaktadır. Önerilen her iki yöntemde farklı ML algoritmaları ile test edilmiştir. Sıfır dolgu tabanlı yaklaşım önerilen ilk modele ve literatürdeki diğer çalışmalara kıyasla sınıflandırma performansında belirgin bir iyileşme sağlamıştır. Sıfır dolgu yöntemi, değişken uzunluktaki zaman serisi verileriyle çalışırken bilgi kaybını minimize etmek için kullanışlı bir yaklaşımdır. Bu yöntem, eksik verileri etkili bir şekilde ele alır ve modelin doldurulmuş bölgeleri göz ardı etmesine yardımcı olur. Sıfır dolgu, zaman serisindeki boşlukları sıfırlarla doldurarak orijinal veri noktalarını korur ve zaman serisinin genel yapısını korur. Sıfırlar anlamlı bilgiler taşımaz, ancak orijinal verilere dayanan modeller için eğilimleri ve desenleri anlamak için önemlidir. Bu yöntem, farklı uzunluklarda dizilere sahip test verileri veya dinamik olarak değişen uzunluklara sahip gerçek zamanlı verilerle karşılaşıldığında faydalı olabilir. Sıfır dolgu kullanarak, model eksik verilerle başa çıkabilir ve zaman serisindeki desenleri tanımlayabilir.

Çalışma kapsamında ayrıca SelectKBest özellik seçimi algoritmasından elde edilen sonuçlara göre hangi ROI'lerin TK ve OSB'li bireyleri ayırt etmede daha başarılı olabileceğine dair bir değerlendirme sunulmuştur. Elde edilen sonuçların rs-fMRI verileri ile OSB tespiti için oldukça ümit vericidir.

6. KAYNAKLAR

- [1] M. Langen, S. Durston, W. G. Staal, S. J. M. C. Palmen, and H. van Engeland, "Caudate Nucleus Is Enlarged in High-Functioning Medication-Naive Subjects with Autism," *Biol. Psychiatry*, vol. 62, no. 3, pp. 262–266, Aug. 2007, doi: 10.1016/j.biopsych.2006.09.040.
- [2] E. Fernell, Eriksson, and C. Gillberg, "Early diagnosis of autism and impact on prognosis: a narrative review," *Clin. Epidemiol.*, vol. 5, no. 1, p. 33, Feb. 2013, doi: 10.2147/CLEP.S41714.
- [3] B. E. Yerys and B. F. Pennington, "How do we establish a biological marker for a behaviorally defined disorder? Autism as a test case," *Autism Res.*, vol. 4, no. 4, pp. 239–241, Aug. 2011, doi: 10.1002/aur.204.
- [4] M. Plitt, K. Barnes, and A. M. Clinical, "Functional connectivity classification of autism identifies highly predictive brain features but falls short of biomarker standards," *Elsevier*, Accessed: Aug. 07, 2023. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S2213158214001983>.
- [5] M. A. Aghdam, A. Sharifi, and M. M. Pedram, "Diagnosis of Autism Spectrum Disorders in Young Children Based on Resting-State Functional Magnetic Resonance Imaging Data Using Convolutional Neural Networks," *J. Digit. Imaging*, vol. 32, no. 6, pp. 899–918, Dec. 2019, doi: 10.1007/s10278-019-00196-1.
- [6] B. Crosson *et al.*, "Functional imaging and related techniques: An introduction for rehabilitation researchers," *J. Rehabil. Res. Dev.*, vol. 47, no. 2, p. vii, 2010, doi: 10.1682/JRRD.2010.02.0017.
- [7] D. G. Amaral, C. M. Schumann, and C. W. Nordahl, "Neuroanatomy of autism," *Trends Neurosci.*, vol. 31, no. 3, pp. 137–145, Mar. 2008, doi: 10.1016/j.tins.2007.12.005.
- [8] S. J. Blumberg, M. D. Bramlett, M. D. Kogan, L. A. Schieve, J. R. Jones, and M. C. Lu, "Changes in prevalence of parent-reported autism spectrum disorder in school-aged U.S. children: 2007 to 2011-2012," *Natl. Health Stat. Report.*, no. 65, 2013.
- [9] Y. Kong, J. Gao, Y. Xu, Y. Pan, J. Wang, and J. Liu, "Classification of autism spectrum disorder by combining brain connectivity and deep neural network classifier," *Neurocomputing*, vol. 324, pp. 63–68, Jan. 2019, doi: 10.1016/j.neucom.2018.04.080.
- [10] S. Sarraf, J. S. preprint arXiv:1602.02225, and undefined 2016, "Functional brain imaging: A comprehensive survey," *arxiv.orgS Sarraf, J SunarXiv Prepr. arXiv1602.02225, 2016•arxiv.org*, 2016, Accessed: Aug. 07, 2023. [Online]. Available:

<https://arxiv.org/abs/1602.02225>.

- [11] C. M. Bishop, *Pattern Recognition and Machine Learning* Springer-Verlag New York. Inc. Secaucus, NJ, USA. 2006.
- [12] A. L. Samuel, “Some Studies in Machine Learning Using the Game of Checkers,” *IBM J. Res. Dev.*, vol. 3, no. 3, pp. 210–229, Jul. 1959, doi: 10.1147/rd.33.0210.
- [13] T. Hastie, R. Tibshirani, and J. Friedman, “Assessment and Selection,” in *The Business of Giving*, Palgrave Macmillan, 2009.
- [14] M. UÇAR and E. UÇAR, “Computer-Aided Detection of Lung Nodules in Chest X-Rays using Deep Convolutional Neural Networks,” *Sak. Univ. J. Comput. Inf. Sci.*, vol. 2, no. 1, pp. 1–8, Apr. 2019, doi: 10.35377/saucis.02.01.538249.
- [15] Y. ALAKOÇ, V. AKDOĞAN, M. KORKMAZ, and O. ER, “Osteoporoz Ön Tanısının Olasılıksal Sinir Ağları (OSA) Yardımıyla Gerçekleştirilmesi,” *Sak. Univ. J. Comput. Inf. Sci.*, vol. 1, no. 3, pp. 1–6, Dec. 2018, doi: 10.35377/saucis.01.03.496066.
- [16] E. ERDEM and T. AYDİN, “Detection of Pneumonia with a Novel CNN-based Approach,” *Sak. Univ. J. Comput. Inf. Sci.*, vol. 4, no. 1, pp. 26–34, Apr. 2021, doi: 10.35377/saucis.04.01.787030.
- [17] D. B. Aydın and O. Er, “A new proposal for early stage diagnosis of urinary tract infection using computers aid systems,” *Sak. Univ. J. Comput. Inf. Sci.*, vol. 1, no. 1, pp. 1–9, 2018, Accessed: Aug. 07, 2023. [Online]. Available: <https://dergipark.org.tr/en/download/article-file/479145>.
- [18] G. ÖZEN, R. SULTANOV, Y. ÖZEN, and Z. YILMAZ GÜNEŞ, “A Convolutional Neural Network Based on Raw Single Channel EEG for Automatic Sleep Staging,” *Sak. Univ. J. Comput. Inf. Sci.*, vol. 3, no. 2, pp. 149–158, Aug. 2020, doi: 10.35377/saucis.03.02.731628.
- [19] A. Di Martino *et al.*, “The autism brain imaging data exchange: towards a large-scale evaluation of the intrinsic brain architecture in autism,” *Mol. Psychiatry*, vol. 19, no. 6, pp. 659–667, Jun. 2014, doi: 10.1038/mp.2013.78.
- [20] K. C. Turner, L. Frost, D. Linsensardt, J. R. McIlroy, and R.-A. Müller, “Atypically diffuse functional connectivity between caudate nuclei and cerebral cortex in autism,” *Behav. Brain Funct.*, vol. 2, no. 1, p. 34, Dec. 2006, doi: 10.1186/1744-9081-2-34.
- [21] E. Wong, J. S. Anderson, B. A. Zielinski, and P. T. Fletcher, “Riemannian Regression and Classification Models of Brain Networks Applied to Autism,” in *Connectomics in neuroImaging: second international workshop, CNI 2018, held in conjunction with MICCAI 2018, Granada, Spain, September 20, 2018: proceedings. CNI (Workshop) (2nd :*

- 2018 : Granada, Spain), vol. 11083, NIH Public Access, 2018, pp. 78–87.
- [22] A. Abraham *et al.*, “Deriving reproducible biomarkers from multi-site resting-state data: An Autism-based example,” *Neuroimage*, vol. 147, pp. 736–745, Feb. 2017, doi: 10.1016/j.neuroimage.2016.10.045.
 - [23] S. Parisot *et al.*, “Spectral Graph Convolutions for Population-based Disease Prediction,” *Lect. Notes Comput. Sci. (including Subser. Lect. Notes Artif. Intell. Lect. Notes Bioinformatics)*, vol. 10435 LNCS, pp. 177–185, Mar. 2017, doi: 10.1007/978-3-319-66179-7_21/FIGURES/2.
 - [24] J. Wang *et al.*, “Parcellation-dependent small-world brain functional networks: A resting-state fMRI study,” *Hum. Brain Mapp.*, vol. 30, no. 5, pp. 1511–1523, May 2009, doi: 10.1002/hbm.20623.
 - [25] Z. Che, S. Purushotham, K. Cho, D. Sontag, and Y. Liu, “Recurrent Neural Networks for Multivariate Time Series with Missing Values,” *Sci. Rep.*, vol. 8, no. 1, p. 6085, Apr. 2018, doi: 10.1038/s41598-018-24271-9.
 - [26] A. Lopez-del Rio, M. Martin, A. Perera-Lluna, and R. Saidi, “Effect of sequence padding on the performance of deep learning models in archaeal protein functional prediction,” *Sci. Rep.*, vol. 10, no. 1, p. 14634, Sep. 2020, doi: 10.1038/s41598-020-71450-8.
 - [27] A. T. KABAKUŞ, “A Comparison of the State-of-the-Art Deep Learning Platforms: An Experimental Study,” *Sak. Univ. J. Comput. Inf. Sci.*, vol. 3, no. 3, pp. 169–182, Dec. 2020, doi: 10.35377/saucis.03.03.776573.
 - [28] Y. Lecun, L. Bottou, Y. Bengio, and P. Ha, “Gradient-Based Learning Applied to Document Recognition 1 Introduction,” *Most*, pp. 1–75, 1998.
 - [29] Z. Ozer, “The effect of normalization on the classification of traffic comments,” Karabuk University, 2019.
 - [30] A. A. MÜNGEN, İ. AYGÜN, and M. KAYA, “Finding the Relationship Between News and Social Media Users’ Emotions in the COVID-19 Process,” *Sak. Univ. J. Comput. Inf. Sci.*, vol. 3, no. 3, pp. 250–263, Dec. 2020, doi: 10.35377/saucis.03.03.830867.
 - [31] P. Bellec, P. Rosa-Neto, O. C. Lyttelton, H. Benali, and A. C. Evans, “Multi-level bootstrap analysis of stable clusters in resting-state fMRI,” *Neuroimage*, vol. 51, no. 3, pp. 1126–1139, Jul. 2010, doi: 10.1016/j.neuroimage.2010.02.082.
 - [32] C. Chakraborty and A. Joseph, “Staff Working Paper No. 674 Machine learning at central banks,” 2017. Accessed: Jan. 27, 2021. [Online]. Available: www.bankofengland.co.uk/research/Pages/workingpapers/default.aspx.

- [33] A. Zalesky *et al.*, “Whole-brain anatomical networks: Does the choice of nodes matter?,” *Neuroimage*, vol. 50, no. 3, pp. 970–983, Apr. 2010, doi: 10.1016/j.neuroimage.2009.12.027.
- [34] M. Jenkinson, P. Bannister, M. Brady, and S. Smith, “Improved Optimization for the Robust and Accurate Linear Registration and Motion Correction of Brain Images,” *Neuroimage*, vol. 17, no. 2, pp. 825–841, Oct. 2002, doi: 10.1006/nimg.2002.1132.
- [35] Z. Long, X. Duan, D. Mantini, and H. Chen, “Alteration of functional connectivity in autism spectrum disorder: effect of age and anatomical distance,” *Sci. Reports* 2016 61, vol. 6, no. 1, pp. 1–8, May 2016, doi: 10.1038/srep26527.
- [36] P. Fransson, U. Åden, M. Blennow, and H. Lagercrantz, “The Functional Architecture of the Infant Brain as Revealed by Resting-State fMRI,” *Cereb. Cortex*, vol. 21, no. 1, pp. 145–154, Jan. 2011, doi: 10.1093/cercor/bhq071.
- [37] P. Bellec, “Mining the Hierarchy of Resting-State Brain Networks: Selection of Representative Clusters in a Multiscale Structure,” in *2013 International Workshop on Pattern Recognition in Neuroimaging*, Jun. 2013, pp. 54–57, doi: 10.1109/PRNI.2013.23.
- [38] J. A. Nielsen *et al.*, “Multisite functional connectivity MRI classification of autism: ABIDE results,” *Front. Hum. Neurosci.*, vol. 7, no. SEP, Sep. 2013, doi: 10.3389/fnhum.2013.00599.
- [39] A. S. Heinsfeld, A. R. Franco, R. C. Craddock, A. Buchweitz, and F. Meneguzzi, “Identification of autism spectrum disorder using deep learning and the ABIDE dataset,” *NeuroImage Clin.*, vol. 17, pp. 16–23, Jan. 2018, doi: 10.1016/J.NICL.2017.08.017.
- [40] N. C. Dvornek, P. Ventola, and J. S. Duncan, “Combining phenotypic and resting-state fMRI data for autism classification with recurrent neural networks,” in *2018 IEEE 15th International Symposium on Biomedical Imaging (ISBI 2018)*, Apr. 2018, vol. 2018-April, pp. 725–728, doi: 10.1109/ISBI.2018.8363676.
- [41] M. Khosla, K. Jamison, A. Kuceyeski, and M. Sabuncu, “3D Convolutional Neural Networks for Classification of Functional Connectomes,” *Lect. Notes Comput. Sci. (including Subser. Lect. Notes Artif. Intell. Lect. Notes Bioinformatics)*, vol. 11045 LNCS, pp. 137–145, Jun. 2018, doi: 10.1007/978-3-030-00889-5_16/COVER.
- [42] S. Mostafa, L. Tang, and F.-X. Wu, “Diagnosis of Autism Spectrum Disorder Based on Eigenvalues of Brain Networks,” *IEEE Access*, vol. 7, pp. 128474–128486, 2019, doi: 10.1109/ACCESS.2019.2940198.
- [43] W. Yin, S. Mostafa, and F. Wu, “Diagnosis of Autism Spectrum Disorder Based on

- Functional Brain Networks with Deep Learning,” *J. Comput. Biol.*, vol. 28, no. 2, pp. 146–165, Feb. 2021, doi: 10.1089/cmb.2020.0252.
- [44] J. Zhang, F. Feng, T. Han, X. Gong, and F. Duan, “Detection of Autism Spectrum Disorder using fMRI Functional Connectivity with Feature Selection and Deep Learning,” *Cognit. Comput.*, vol. 15, no. 4, pp. 1106–1117, Jul. 2023, doi: 10.1007/s12559-021-09981-z.



ÖZGEÇMİŞ

Kişisel Bilgiler		
Adı Soyadı		
Doğum Yeri		
Doğum Tarihi		
Uyruğu		
Telefon		
E-Posta Adresi		
Web Adresi		

Eğitim Bilgileri	
Lisans	
Üniversite	
Fakülte	
Bölümü	
Mezuniyet Yılı	

Yüksek Lisans	
Üniversite	
Enstitü Adı	
Anabilim Dalı	
Programı	

Makale ve Bildiriler