



**YAPAY ZEKA YÖNTEMLERİ KULLANILARAK YÜRÜYÜŞ
VERİLERİNE DAYALI DEJENERATİF NÖROMÜSKÜLER
HASTALIKLARIN TESPİTİ**

İsmihan Gül ÖZELOĞLU

YÜKSEK LİSANS TEZİ

ELEKTRİK ELEKTRONİK MÜHENDİSLİĞİ ANA BİLİM DALI

**GAZİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

TEMMUZ 2024

ETİK BEYAN

Gazi Üniversitesi Fen Bilimleri Enstitüsü Tez Yazım Kurallarına uygun olarak hazırladığım bu tez çalışmada;

- Tez içinde sunduğum verileri, bilgileri ve dokümanları akademik ve etik kurallar çerçevesinde elde ettiğimi,
 - Tüm bilgi, belge, değerlendirme ve sonuçları bilimsel etik ve ahlak kurallarına uygun olarak sunduğumu,
 - Tez çalışmada yararlandığım eserlerin tümüne uygun atıfta bulunarak kaynak gösterdiğimi,
 - Kullanılan verilerde herhangi bir değişiklik yapmadığımı,
 - Bu tezde sunduğum çalışmanın özgün olduğunu,
- bildirir, aksi bir durumda aleyhime doğabilecek tüm hak kayıplarını kabullendiğimi beyan ederim.

İsmihan Gül ÖZELOĞLU

24/07/2024

YAPAY ZEKA YÖNTEMLERİ KULLANILARAK YÜRÜYÜŞ VERİLERİNE DAYALI DEJENERATİF NÖROMÜSKÜLER HASTALIKLARIN TESPİTİ

(Yüksek Lisans Tezi)

İsmihan Gül ÖZELOĞLU

GAZİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Temmuz 2024

ÖZET

Nörodejeneratif hastalıklar (NDH' ler), sinir hücrelerinin işlevini kademeli olarak kaybetmesi ve ölmesi ile karakterize edilmekte ve dünya genelinde milyonlarca insanı etkilemektedir. Yürüyüş bozuklukları NDH' lerin teşhis edilmesinde gözlemlenen önemli ortak semptomlardan biridir. Bu nedenle, yürüyüş verilerini kullanarak hastaların bir grup NDH arasında hangi NDH' ye sahip olduğunu teşhis etmek hala ele alınması gereken önemli bir zorluktur. Bu çalışmada, Parkinson hastası (PH), Amiyotrofik Lateral Skleroz (ALS) hastası ve Huntington hastası (HH) ile sağlıklı kontrol (SK) gruplarının makine öğrenmesi ve derin öğrenme yöntemleriyle teşhis edilmesini sağlayacak bir karar destek sistemi önerilmiştir. Önerilen yöntemler, toplamda 64 deneğin ayaklarının altında bulunan kuvvet sensörleri kullanılarak kaydedilen dikey yer tepki kuvveti (DYTK) sinyallerini içeren bir yürüyüş veri kümesi üzerinde test edilmiştir. Çalışmada makine öğrenmesi ve derin öğrenme olmak üzere iki yaklaşım ele alınmıştır. Makine öğrenmesi yaklaşımında DYTK sinyallerinin özellik çıkarımı için eğilimden arındırılmış dalgalanma analizi (DFA), dinamik zaman bükme (DTW) ve otokorelasyon (OK) algoritmaları kullanılmıştır. Özelliklerin performansını karşılaştırmak için sınıflandırıcı olarak destek vektör makineleri (DVM), k-en yakın komşular (k-NN) ve yapay sinir ağları (YSA) kullanılmıştır. ALS, PH ve HH sınıflandırmasını ele alan üç sınıflı problemde %93,3 doğruluk oranı elde edilirken, NDH ve SK gruplarının birlikte ele alındığı dört sınıflı problemde %93,5 doğruluk oranı elde edilmiştir. Derin öğrenme yaklaşımında DYTK sinyallerini görüntüye dönüştürmek için yineleme grafiği ve spektrogram yöntemleri kullanılmıştır. DYTK sinyallerinden oluşturulan görüntüleri sınıflandırmak için hibrit bir konvolüsyonel sinir ağı (CNN) oluşturulmuş ve performans karşılaştırma amacıyla transfer öğrenme yöntemleri kullanılmıştır. ALS, PH ve HH ile SK arasındaki dörtlü sınıflandırma probleminde önerilen CNN modeli kullanılarak %96,15 doğruluk oranına ulaşılmış; önceden eğitilmiş VGG16 mimarisi kullanılarak %97,87 doğruluk oranına ulaşılmıştır. Bu sonuçlar, önerilen yöntemlerin NDH' lerin teşhisi amacıyla tasarlanacak gerçek zamanlı yürüyüş analiz sistemleri için kullanılabilirliğini göstermektedir.

Bilim Kodu : 93407

Anahtar Kelimeler : Nörodejeneratif hastalıklar, makine öğrenmesi, eğilimden arındırılmış dalgalanma analizi, dinamik zaman bükme, otokorelasyon, konvolüsyonel sinir ağı, yineleme grafiği, spektrogram

Sayfa Adedi : 76

Danışman : Dr. Öğr. Üyesi Eda AKMAN AYDIN

DETECTION OF DEGENERATIVE NEUROMUSCULAR DISEASES BASED ON GAIT DATA USING ARTIFICIAL INTELLIGENCE METHODS

(M. Sc. Thesis)

İsmihan Gül ÖZELOĞLU

GAZİ UNIVERSITY

GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCES

July 2024

ABSTRACT

Neurodegenerative diseases (NDDs) are characterized by the gradual loss of function and death of nerve cells and affect millions of people worldwide. Gait disturbances are one of the common symptoms observed in the diagnosis of NDDs. Therefore, diagnosing which NDDs patients have among a group of NDDs using gait data is still an important challenge to be addressed. In this study, a decision support system is proposed to diagnose Parkinson's disease (PD), Amyotrophic Lateral Sclerosis (ALS) patients, Huntington's disease (HD) patients and healthy control (HC) groups using machine learning and deep learning methods. The proposed methods were tested on a gait dataset containing vertical ground reaction force (VGRF) signals recorded using force sensors located under the feet of a total of 64 subjects. Two approaches, namely machine learning and deep learning, were considered in the study. In the machine learning approach, detrended fluctuation analysis (DFA), dynamic time warping (DTW) and autocorrelation (AC) algorithms are used for feature extraction of VGRF signals. Support vector machines (SVM), k-nearest neighbors (k-NN) and artificial neural networks (ANN) are used as classifiers to compare the performance of the features. While 93,3% accuracy rate is obtained in the three-class problem addressing ALS, PD and HD classification, 93,5% accuracy rate is obtained in the four-class problem where NDD and HC groups are considered together. In the deep learning approach, recurrence plot and spectrogram methods are used to convert VGRF signals to images. A hybrid convolutional neural network (CNN) is created to classify the images created from VGRF signals and transfer learning methods are used for performance comparison. While 96,15% accuracy rate is achieved by using the proposed CNN model in the quadruple classification problem between ALS, PD, HD and HC; Using the pre-trained VGG16 architecture, 97,87% accuracy rate was achieved. These results show that the proposed methods can be used for real-time gait analysis systems designed for the diagnosis of NDHs.

Science Code : 93407

Key Words : Neurodegenerative diseases, machine learning, detrended fluctuation analysis, dynamic time warping, autocorrelation, convolutional neural network, recurrence plot, spectrogram

Page Number : 76

Supervisor : Asst. Prof. Dr. Eda AKMAN AYDIN

TEŞEKKÜR

Bu çalışmanın gerçekleştirilmesinde, değerli bilgilerini benimle paylaşan, kendisine ne zaman danışsam kıymetli zamanını ayırıp sabırla ve büyük bir ilgiyle bana faydalı olabilmek için elinden gelenin fazlasını sunan, her sorun yaşadığımda yanına çekinmeden gidebildiğim, güler yüzünü ve samimiyetini benden esirgemeyen ve gelecekteki mesleki hayatımda da bana verdiği değerli bilgilerden faydalanacağımı düşündüğüm saygıdeğer danışman hocam Dr. Öğr. Üyesi Eda AKMAN AYDIN' a teşekkürlerimi sunarım.

Çalışmam boyunca benden bir an olsun yardımlarını esirgemeyen, çalışma süresince tüm zorlukları benimle göğüsleyen ve tanıştığımız günden itibaren hayatımın her evresinde bana destek olan canım eşim Alican ÖZELOĞLU' na sonsuz teşekkür ederim. Sen her zaman benim en büyük destekçim oldun; bana olan inancın ise benim en büyük motivasyon kaynağım oldu. Seni çok seviyorum.

Son olarak, hayatım boyunca her konuda ilerlemem için benden desteğini esirgemeyen, çaresiz hissettiğim her an yanımda olan canım annem Sultan GÜRBÜZ ve sevgili aileme çok teşekkür ederim.

İÇİNDEKİLER

	Sayfa
ÖZET	iv
ABSTRACT.....	v
TEŞEKKÜR.....	vi
İÇİNDEKİLER	vii
ÇİZELGELERİN LİSTESİ.....	ix
ŞEKİLLERİN LİSTESİ.....	x
SİMGELER ve KISALTMALAR	xii
1. GİRİŞ.....	1
2. YÖNTEM.....	7
2.1. Nörodejeneratif Hastalıklarda Yürüyüş Veri Kümesi.....	7
2.2. Ön İşleme	8
2.3. NDH' lerin Makine Öğrenmesine Dayalı Teşhisi.....	10
2.3.1. Özellik çıkarma	11
2.3.2. Özellik seçimi.....	16
2.3.3. Sınıflandırma.....	17
2.4. NDH' lerin Derin Öğrenme Tekniklerine Dayalı Teşhisi.....	21
2.4.1. Sinyal-Görüntü Dönüşüm Teknikleri	21
2.4.2. Derin öğrenme.....	25
3. DENEYSEL SONUÇLAR	31
3.1. Makine Öğrenmesine Dayalı Sonuçlar	31
3.1.1. Hastalığa özgü özelliklerin belirlenmesi	32
3.1.2. İkili sınıflandırma sonuçları	35
3.1.3. Çoklu sınıflandırma sonuçları	39

	Sayfa
3.2. Derin Öğrenmeye Dayalı Sonuçlar	41
3.2.1. Önerilen CNN mimarisi sonuçları	41
3.2.2. Transfer öğrenme sonuçları	49
3.2.3. Performans değerlendirme metriklerinin yorumlanması	54
3.3. Yürüyüş Dinamiklerine Dayalı Literatürle Performans Karşılaştırması	56
4. TARTIŞMA	61
5. SONUÇ VE ÖNERİLER	65
KAYNAKLAR	67
ÖZGEÇMİŞ	75

ÇİZELGELERİN LİSTESİ

Çizelge	Sayfa
Çizelge 3.1. DFA katsayılarının F değerleri ve önem seviyeleri (** $\rho < 0.5$, * $\rho < 0.1$)	32
Çizelge 3.2. DTW katsayısının gruplar arası önemli seviyeleri	34
Çizelge 3.3. Yineleme grafiği görüntülerinin eğitildiği CNN mimarisi	43
Çizelge 3.4. Spektrogram görüntülerinin eğitildiği CNN mimarisi.....	44
Çizelge 3.5. Yineleme grafiği ve spektrogram görüntülerinin birlikte kullanıldığı hibrit CNN mimarisi	44
Çizelge 3.6. Önerilen hibrit CNN mimarisinde kullanılan hiperparametre değerleri.....	45
Çizelge 3.7. Önerilen hibrit CNN mimarisi farklı pencere boyutlarındaki ikili ve çoklu sınıflandırma sonuçları.....	45
Çizelge 3.8. Önerilen hibrit CNN mimarisi ile hibrit olmayan CNN mimarilerinin ikili ve çoklu sınıflandırma sonuçları.....	46
Çizelge 3.9. Bu çalışmada kullanılan transfer öğrenme mimarilerinin özellikleri	49
Çizelge 3.10. Transfer öğrenme mimarisinde kullanılan hiperparametre değerleri	50
Çizelge 3.11. Farklı transfer öğrenme modelleri ile yapılan deneylerin çoklu sınıflandırma sonuçları.....	51
Çizelge 3.12. VGG16 transfer öğrenme modeli ile ikili ve çoklu sınıflandırma sonuçları	52
Çizelge 3.13. Tek katmanı dondurulmamış VGG16 transfer öğrenme modeli ile ikili ve çoklu sınıflandırma sonuçları	54
Çizelge 3.14. Bu çalışmada kullanılan mimarilerde dörtlü sınıflandırma performansını değerlendirme metrikleri	54
Çizelge 3.15. Bu çalışmada kullanılan veri kümesini kullanarak NDD tanısı koymak için yürüyüş analizi yapan çalışmaların karşılaştırılması	57

ŞEKİLLERİN LİSTESİ

Şekil	Sayfa
Şekil 2.1. NDH ve SK gruplarının DYTK sinyali adım zaman grafikleri.....	8
Şekil 2.2. DYTK verisinin 10 saniyelik pencereler ile çoğaltılması.....	9
Şekil 2.3. DYTK verisinin 5 saniyelik pencereler ile çoğaltılması.....	10
Şekil 2.4. Makine öğrenmesi yöntemi blok diyagramı	10
Şekil 2.5. YSA' ların genel yapısı	19
Şekil 2.6. Derin öğrenme yöntemi blok diyagramı.....	21
Şekil 2.7. NDH ve SK gruplarının yineleme grafik örnekleri (a) ALS hastası, (b) Huntington hastası, (c) Parkinson hastası, (d) sağlıklı kontrol grubu	23
Şekil 2.8. NDH ve SK gruplarının spektrogram görüntüsü örnekleri (a) ALS hastası, (b) Huntington hastası, (c) Parkinson hastası, (d) sağlıklı kontrol grubu.....	25
Şekil 2.9. Temel CNN mimarisi	26
Şekil 2.10. Konvolüsyonel filtre örneği.....	27
Şekil 3.1. NDH ve SK gruplarının dikey yer tepki kuvveti (DYTK) sinyalleri	31
Şekil 3.2. DFA katsayılarının dağılım grafiği (a) PH-SK, (b) ALS-SK, (c) HH-SK (Kırmızı noktalar NDH' yi, mavi noktalar SK'yı temsil etmektedir.).....	33
Şekil 3.3. NDH' ler ve SK grubu DTW katsayıları arasında Kruskal Wallis test sonucu.....	33
Şekil 3.4. (a) sol ayak ve (b) sağ ayak için NDH ve SK gruplarının ortalama otokorelasyon katsayıları.....	34
Şekil 3.5. NDH-SK grupları ikili sınıflandırma sonuçları (a) her bir özellik ve sınıflandırıcı için sınıflandırma doğrulukları (b) karmaşıklık matrisi.....	35
Şekil 3.6. Özellikler ve özellik kombinasyonları için doğruluk oranları.....	36
Şekil 3.7. Sınıflandırıcılar için doğruluk oranları	37
Şekil 3.8. (a) ALS, (b) PH, (c) HH için DFA, DTW, DFA+DTW ve OK tabanlı özelliklerin karmaşıklık matrisleri.....	38

Şekil	Sayfa
Şekil 3.9. Üç sınıflı (ALS-PH-HH) ve dört sınıflı (ALS-PH-HH ve SK) durumlar için her özellik ve özellik kombinasyonu için sınıflandırıcıların doğruluk oranları.....	40
Şekil 3.10. (a) Üç sınıflı (ALS - PH - HH), (b) dört sınıflı (ALS - PH - HH - SK) vakalar için karmaşıklık matrisleri.....	41
Şekil 3.11. Derin öğrenme hibrit CNN mimarisi.....	42
Şekil 3.12. Yineleme grafiği ve spektrogram görüntülerinin eğitildiği CNN mimarilerinin doğruluk grafikleri	47
Şekil 3.13. Yineleme grafiği ve spektrogram görüntülerinin eğitildiği CNN mimarileri ile hibrit CNN mimarisinin karmaşıklık matrisleri	48
Şekil 3.14. Yineleme grafiği veya spektrogram görüntüsü ile oluşturulan veri kümesinin kullanıldığı transfer öğrenme sinir ağı mimarisi	50
Şekil 3.15. VGG16 transfer öğrenme mimarisi	51
Şekil 3.16. VGG16 transfer öğrenme mimarisinin dörtlü sınıflandırma model doğruluğu ve model kaybı grafikleri.....	53
Şekil 3.17. VGG16 transfer öğrenme mimarisinin dörtlü sınıflandırma karmaşıklık matrisi.....	53

SİMGELER VE KISALTMALAR

Bu çalışmada kullanılmış simgeler ve kısaltmalar, açıklamaları ile birlikte aşağıda sunulmuştur.

Simgeler

Açıklamalar

dk

Dakika

sn

Saniye

Kısaltmalar

Açıklamalar

ALS

Amyotrofik Lateral Skleroz

CNN

Konvolüsyonel sinir ağı

DFA

Eğilimden arındırılmış dalgalanma analizi

DTW

Dinamik zaman bükme

DVM

Destek vektör makineleri

DWT

Ayrık dalgacık dönüşümü

DYTK

Dikey yer tepki kuvveti

HH

Huntington hastalığı

k-NN

k-en yakın komşular

LSTM

Uzun kısa vadeli bellek

NDH

Nörodejeneratif hastalık

NNLS

Negatif olmayan en küçük kareler

OK

Otokorelasyon

PH

Parkinson hastalığı

ReLU

Doğrultulmuş doğrusal birim

RNN

Yinelenen sinir ağı

SA

Sinir ağı

SK

Sağlıklı kontrol

STFT

Kısa zamanlı fourier dönüşümü

YSA

Yapay sinir ağı

1. GİRİŞ

Nörodejeneratif hastalıklar (NDH' ler), merkezi sinir sistemi ve periferik sinir sistemindeki nöronların progresif dejenerasyonu ve ölümüne yol açan, genellikle kronik ve ilerleyici seyir gösteren hastalıklar grubudur [1]. Bu hastalıklar, nöron kaybına bağlı olarak beyinde ve omurilikte işlev bozukluklarına neden olur ve genellikle motor, kognitif ve davranışsal bozukluklarla karakterizedir. NDH' ler, dünya genelinde yaşanan nüfusla birlikte giderek artan bir sağlık sorunu haline gelmektedir [2].

NDH' ler çeşitli klinik ve patolojik özelliklere sahip alt gruplara ayrılabilir. Başlıca NDH' ler arasında Parkinson hastalığı (PH), Amyotrofik Lateral Skleroz (ALS), Huntington hastalığı (HH), Alzheimer hastalığı ve Multipl Skleroz bulunmaktadır. Her bir hastalık, belirli nöron gruplarının dejenerasyonu ile karakterize olup, hastaların yaşam kalitesini ve günlük işlevselliğini önemli ölçüde etkiler. PH motor sistem bozukluklarına neden olan, titreme, rijidite, bradikinezi ve postural instabilite ile karakterizedir [3]. Beyindeki dopamin üreten hücrelerin kaybı temel patolojik sebeptir. ALS hastalarında motor nöronların dejenerasyonu sonucu kas güçsüzlüğü gelişir. Hem üst hem de alt motor nöronların etkilenmesiyle ilerleyici bir seyir izler [4]. HH genetik geçişli olan, istemsiz hareketler, kognitif bozukluklar ve psikiyatrik belirtiler ile seyrederek [5]. Alzheimer hastalığı hafıza kaybı, dil bozuklukları ve kognitif işlevlerde ciddi gerileme ile karakterizedir. Multipl Skleroz ise merkezi sinir sisteminde akson kaybı ile karakterizedir. Klinik spektrumda motor ve duyuşsal bozukluklar, görme problemleri ve kognitif değişiklikler yer alır.

NDH' lerin belirtileri, etkilenen nöron tipine ve beyindeki spesifik bölgelere bağlı olarak değişiklik gösterir. Genellikle erken evrelerde belirsiz ve hafif olan semptomlar, zamanla şiddetlenir ve daha belirgin hale gelir. Tipik belirtiler arasında hareket bozuklukları (titreme, rijidite, denge problemleri), kognitif bozukluklar (hafıza kaybı, dikkat dağınıklığı, karar verme güçlüğü), konuşma ve dil problemleri, davranışsal değişiklikler ve duyuşsal dengesizlikler bulunur. Bu hastalıkların erken dönemde teşhis edilememesi, hastaların yaşam kalitesini olumsuz yönde etkileyen ileri evre semptomların ortaya çıkmasına ve etkili tedavi ve müdahale fırsatlarının kaçırılmasına neden olmaktadır. Erken teşhisin önündeki temel engellerden biri, hastalıkların erken evrelerinde belirtilerin genellikle

belirsiz ve hafif olmasıdır [6]. Bu durum, hastalıkların genellikle ilerlemiş evrelerde, ciddi nörolojik ve kognitif bozukluklar ortaya çıktığında tanınmasına neden olmaktadır. Erken teşhisin yapılamaması, hastalıkların ilerlemesini yavaşlatacak veya durduracak tedavi ve müdahale yöntemlerinin etkinliğini de önemli ölçüde azaltmaktadır.

NDH' lerin teşhisi genellikle klinik değerlendirme, görüntüleme teknikleri ve laboratuvar testlerinin kombinasyonu ile gerçekleştirilir [7]. Nörolojik muayene ve ayrıntılı hasta öyküsü, başlangıç değerlendirmesi için önemlidir. Manyetik rezonans görüntüleme ve pozitron emisyon tomografisi (PET), beyin yapılarındaki dejeneratif değişiklikleri tespit etmekte kullanılır. Kan testleri, genetik testler ve beyin omurilik sıvısı analizi gibi biyomarker çalışmaları, hastalıkların tanısına yardımcı olabilir. NDH hastalık teşhisinde birçok görüntüleme tekniği ve tetkik önemli bir araç olsa da doktorların bu hastalıkların teşhisi konusunda tecrübeleri de teşhiste önemli rol oynamaktadır. Bu nedenle, doktorlara yardımcı olabilecek karar destek sistemlerinin geliştirilmesi önemlidir.

Son yıllarda, makine öğrenmesi ve derin öğrenme tekniklerine dayalı karar destek sistemleri NDH' lerin teşhisinde önemli bir rol oynamaya başlamıştır [8]. Bu yöntemler, büyük veri kümelerinin analiz edilmesi ve karmaşık örüntülere dayalı öngörülerin yapılmasında güçlü araçlar sunmaktadır. Veri analizi ve modelleme algoritmaları, klinik veriler, genetik bilgiler, görüntüleme sonuçları ve biyomarker verileri gibi çeşitli kaynaklardan elde edilen büyük veri setlerini analiz ederek, hastalıkların erken teşhisi ve ilerleme tahmini için modeller geliştirebilir. Bu teknikler, manyetik rezonans görüntüleme ve pozitron emisyon tomografisi taramalarında insan gözünün kaçırabileceği küçük dejeneratif değişiklikleri saptayabilir ve hastalığın evrelerini belirleyebilir. Bu, klinisyenlerin karar destek sistemlerini güçlendirebilir ve daha doğru teşhis konulmasına katkı sağlayabilir.

NDH' ler karmaşık ve heterojen bir grup hastalık olup, etkili teşhis ve tedavi yöntemlerinin geliştirilmesi, bu hastalıkların patofizyolojisinin daha iyi anlaşılmasına bağlıdır. Makine öğrenmesi ve derin öğrenme teknikleri, NDH' lerin teşhisinde ve yönetiminde devrim niteliğinde yenilikler sunmaktadır. Bu teknolojilerin entegrasyonu, daha erken ve daha doğru teşhis konulmasına, hastalıkların ilerlemesinin yavaşlatılmasına ve hastaların yaşam kalitesinin artırılmasına yönelik önemli bir potansiyele sahiptir. NDH' lerin erken dönemde teşhis edilmesi, hastalıkların ilerlemesini yavaşlatmak veya durdurmak,

semptomların şiddetini azaltmak ve hastaların yaşam kalitesini artırmak amacıyla kritik öneme sahiptir. Bu amaç doğrultusunda, hastalıkların erken evrelerinde daha hassas ve doğru teşhis yöntemlerinin geliştirilmesi gerekmektedir. Erken teşhis, hastaların tedaviye daha iyi yanıt vermelerini sağlamakla kalmayıp, aynı zamanda hastalığın seyrini değiştirme potansiyeline sahip koruyucu tedbirlerin alınmasını da mümkün kılmaktadır. Bu bağlamda, NDH'lerin erken dönemde teşhis edilmesi, gelişmiş görüntüleme teknikleri, veri analizleri ve yapay zeka tabanlı yaklaşımlar gibi yenilikçi yöntemlerle mümkün hale gelebilir. Bu yaklaşımlar, hastalıkların ilerlemesini yavaşlatacak veya durduracak etkili stratejilerin geliştirilmesine ve hastaların yaşam kalitesinin artırılmasına yönelik önemli adımlar sağlayacaktır [8].

Yürüyüş, birçok NDH' de belirgin ve yaygın bir semptom olduğu için, son yıllarda araştırmalar, yürüyüş analizi yoluyla NDH'lerin teşhis edilmesine odaklanmıştır. Bu çalışmalarda, dikey yer tepkisi kuvveti (DYTK) sinyallerinin yanı sıra, DYTK' den türetilen adım, duruş ve sallanma aralıkları gibi veriler kullanılmaktadır. Bu verilerden çıkarılan varyans, çarpıklık, basıklık, minimum, maksimum, ortalama, standart sapma, entropi, yaklaşık entropi, bulanık entropi, çapraz bulanık entropi, korelasyon, deterministik öğrenme teorisi, ayırık dalgacık dönüşümü, dalgacık uyumu, metin kümeleme, Lempel-Ziv karmaşıklığı, Teager-kaiser enerji operatörü, gri düzey eş-oluşum matrisi, doğrusal olmayan dinamik özellikler ve benzerlik tabanlı özellikler gibi istatistiksel özellikler, ALS, PH ve HH' yi sağlıklı kontrol (SK) bireylerden ayırt etmek için çeşitli çalışmalarda öznitelik olarak kullanılmıştır [9-24]. Çalışmaların sonuçları, ALS, PH veya HH gibi belirli bir NDH' ye sahip bireylerin, SK bireylerden yürüyüş analizi yoluyla ayırt edilebileceğini göstermiştir. ALS, HH ve PH, SK' den ayrılabilir de yürüyüş sinyallerine dayalı olarak NDH'lerin birbirinden ayrılması hala çözülmesi gereken önemli bir zorluktur. Her NDH' nin kendine özgü semptomları olmasına rağmen, yürüyüş ve denge bozuklukları PH, ALS ve HH' de yaygın olarak gözlemlenen semptomlardan biridir [25]. Bu nedenle, yürüyüş bozuklukları, insanların NDH' ye sahip olduğunu gösteren önemli bir işaret olabilir, ancak yürüyüş analizi kullanılarak kişilerin hangi NDH olduğunu tam olarak belirlemek zordur. NDH'lerin teşhisinde çözülmesi gereken önemli sorunlardan biri, yürüyüş analizinden hastanın hangi NDH' ye sahip olduğunun belirlenip belirlenemeyeceğidir.

Yürüyüş analizi tabanlı ALS, PH ve HH' nin çoklu sınıf sınıflandırması, sınırlı bir şekilde ele alınmış bir problemdir [16, 26]. ALS, PH ve HH' yi sınıflandırmak için Baratin ve ark.

[16], Ayırık Dalgacık Dönüşümü (DWT), entropi, uyum ve doğrusal sınıflandırma kullanarak %85 doğruluk elde ederken, Zhao ve ark. [26], çift kanallı uzun kısa vadeli bellek (LSTM) tabanlı çoklu özellik çıkarımı kullanarak %95,6 doğruluk elde etmişlerdir. Diğer yandan, SK' yi de içeren bir grupta ALS, PH ve HH' nin sınıflandırılması ele alınması gereken başka bir problemdir [23, 25, 27-28]. SK ve NDH' leri içeren bir grupta dört sınıflı sınıflandırma ile, ALS, PH ve HH' yi SK' den ayırt etmeyi amaçlayan çalışmalarda, Faisal ve ark. [27], CNN tabanlı bir yaklaşım önererek %83 doğruluk elde ederken, Zhao ve ark. [23], temel özellikler, klasik doğrusal olmayan dinamik özellikler, Lempel–Ziv karmaşıklığı ve Rastgele orman algoritmasını kullanarak %86,56 doğruluk elde etmiştir. Derin öğrenme algoritmaları, çoklu sınıf yürüyüş tabanlı NDH sınıflandırmasında artan bir popülerlik kazanmıştır [25, 28]. Derin öğrenme algoritmaları, yürüyüş sinyallerinden ayırt edici yürüyüş özelliklerini otomatik olarak belirlemek için kullanılmıştır. Bu çalışmaların sonuçları, NDH teşhisinde derin öğrenme tabanlı modellerin hem ikili hem de çoklu sınıf verilerini sınıflandırmada başarılı olduğunu göstermektedir [29]. Faisal ve Zhao [23, 27], makine öğrenme ve CNN tabanlı sınıflandırmaları, çıkarılmış özelliklerle kullanmışlardır; ancak bu çalışmalardaki doğruluk oranlarının sınırlı kaldığı görülmektedir. Yürüyüş bozukluğu NDH' lerde yaygın bir semptom olmasına rağmen, yürüyüş deseni bu hastalıklar arasında farklılık gösterebilir [30]. Bu nedenle, NDH' ler, hastalıkların benzersiz yürüyüş ritimlerini tanımlayan ayırt edici özellikler belirlenerek tanımlanabilir.

Bu çalışmada, yürüyüş verilerine dayalı olarak NDH' lerin teşhis edilmesine yönelik bir karar destek sisteminin geliştirilmesi amaçlanmıştır. İkili sınıflandırma ile SK ve NDH' leri ayırt etmenin yanı sıra, çok sınıflı sınıflandırma ile hastaların sahip olduğu NDH türünün de belirlenmesi amaçlanmıştır. Tam yürüyüş döngüsünün yararlı özelliklerini ortaya çıkardığı ve iki ayak arasındaki koordinasyonu nicelendirdiği için, DYTK sinyallerinin kullanılması tercih edilmiştir. Bu kapsamda makine öğrenmesi ve derin öğrenme tekniklerine dayalı iki farklı yöntem uygulanarak, NDH teşhisindeki başarımları değerlendirilmiştir. Bu bağlamda, çalışmanın makine öğrenmesi tekniklerine dayalı kısmında yürüyüş verilerine dayalı olarak NDH' lerin teşhisi için eğilimden arındırılmış dalgalanma analizi (DFA), dinamik zaman bükme (DTW) ve otokorelasyon (OK) metodolojileri ile çıkarılan özelliklerin sonuçları değerlendirilmiştir. Her NDH' ye ait DYTK sinyallerinin kendine benzerlik ve kendine yakınlığını ölçmek için DFA, OK tabanlı özellik çıkarma teknikleri kullanılırken, sağ ve sol ayaktan gelen sinyaller

arasındaki benzerliđi belirlemek için DTW kullanılmıřtır. Bununla birlikte, Relief tabanlı özellik seçimi tekniđi kullanılarak, her NDH için en ayırt edici özelliklerin belirlenmesi amaçlanmıřtır. Sınıflandırma görevi için, destek vektör makineleri (DVM), k-en yakın komřular (k-NN) ve yapay sinir ađları (YSA) kullanılarak sonuçların karřılařtırılabilirliđi sađlanmıřtır. Çalışmanın derin öğrenme tekniklerine dayalı kısmında, NDH'lerin teřhisi için hibrit bir CNN mimarisi geliřtirilmiřtir. Geliřtirilen hibrit CNN modelinin giriřlerinde DYTK sinyallerinin görselleřtirilmesi amacıyla yineleme grafiđi ve spektrogram görüntü dönüřüm tekniklerinden faydalanılmıřtır. Görselleřtirilen verilerin, derin öğrenme modellerinden CNN ve transfer öğrenme yöntemleri kullanılarak ikili ve dörtlü sınıflandırmaları yapılmıřtır. Sonuçlar transfer öğrenme yöntemleri ile karřılařtırılarak performansları deđerlendirilmiřtir. Son olarak, çıkarım yöntemlerinin etkinliđi, aynı veri kümesini kullanan diđer çalışmaların bulguları ile karřılařtırılarak deđerlendirilmiřtir.

Bu çalışma toplamda 5 bölümden oluřmaktadır. İkinci bölümde bu çalışmada kullanılan yöntemler detaylı bir şekilde anlatılmıřtır. Üçüncü bölümde bu çalışmada kullanılan yöntemlerin deneysel sonuçları paylařılmıřtır. Dördüncü bölümde bu çalışmanın sonuçları tartiřılmıř ve literatürdeki benzer çalışmalar ile bu çalışmanın sonuçları karřılařtırılmıřtır. Beřinci bölümde ise çalışmanın sonuçları ve öneriler yer almaktadır.



2. YÖNTEM

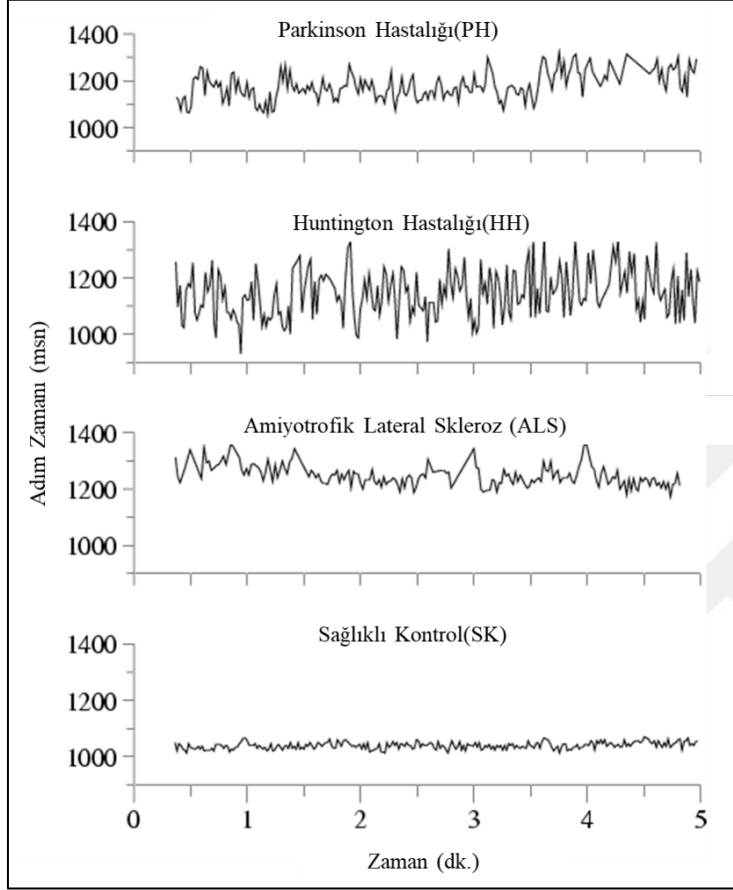
Bu çalışmada, NDH hastalıklarının ikili ve çoklu sınıflandırmaları, makine öğrenmesi ve derin öğrenmeye dayalı yöntemler kullanılarak yapılmıştır. Makine öğrenmesi yöntemlerinde ilk olarak veri kümesi olan DYTK sinyallerine farklı özellik çıkarım yöntemleri uygulanmıştır. Sonrasında özellik seçimi yapılmıştır. Son olarak farklı sınıflandırma yöntemleriyle ikili ve çoklu sınıflandırmalar gerçekleştirilmiştir. Derin öğrenme yöntemlerinde ise DYTK sinyalleri, farklı yöntemler kullanılarak görselleştirilmiştir. Görselleştirilen veriler konvolüsyonel sinir ağı mimarisi ve önceden eğitilmiş transfer öğrenme mimarileri kullanılarak eğitilip sınıflandırılmıştır.

2.1. Nörodejeneratif Hastalıklarda Yürüyüş Veri Kümesi

Bu çalışmada, Hausdorff ve arkadaşları tarafından sağlanan “Nörodejeneratif Hastalıklarda Yürüyüş Veri Kümesi” kullanılmıştır [31]. Veri kümesi, toplamda 64 denekten toplanan kayıtları içermekte olup, 13 ALS, 15 PH, 20 HH ve 16 SK grubundan oluşmaktadır [32]. Veri kümesi, her katılımcıya ait yaş, cinsiyet, boy, kilo, yürüme hızı ve hastalık şiddeti veya süresini gösteren bir gösterge gibi klinik verileri içermektedir. PH tanısı konan bireyler için bu gösterge, daha yüksek bir sayısal değerle daha ileri bir hastalık evresiyle ilişkili olduğu Hohn ve Yahr skoru olarak ortaya çıkarken, HH tanısı olanlar için ise, daha düşük bir sayısal değerle daha büyük işlevsel bozulmayı ifade ettiği toplam işlevsel kapasite ölçüsü kullanılmıştır. ALS olan bireyler için sayısal değer, hastalık teşhisinden bu yana geçen süreyi ay cinsinden yansıtmaktadır. Sağlıklı kontrol grubu için ise, yer tutucu olarak 0 değeri kullanılmıştır. Veri kümesi, SK grubunda 2 erkek ve 14 kadın bireyi içermekte olup, ortalama yaş 39'dur. HH grubunda 6 erkek ve 14 kadın katılımcı bulunmaktadır ve ortalama yaş 46,65' dir. PH grubu, 10 erkek ve 5 kadın bireyden oluşmakta olup, ortalama yaş 66,8' dir. Son olarak, ALS tanısı konan bireyler, 10 erkek ve 3 kadın katılımcıdan oluşmakta olup, ortalama yaş 55,61' dir.

Deneylerde, her denekten 5 dakika boyunca normal hızlarında 77 metre uzunluğunda bir koridorda yürümeleri istenmiştir. Veri kümesi, ham DYTK yürüyüş sinyallerinin ham verilerini ve ham verilerden türetilen zaman serilerini içermektedir. Bu çalışmada, sadece her ayağın altında bulunan kuvvet sensörleri kullanılarak kaydedilen ve ölçülen kuvveti

temsil eden DYTK sinyalleri kullanılmıştır. DYTK sinyalleri, 300Hz örnekleme frekansında kaydedilmiştir. Sırasıyla PH, HH, ALS ve SK gruplarından toplanan DYTK sinyallerinin adım zaman grafikleri Şekil 2.1’ de görülmektedir.



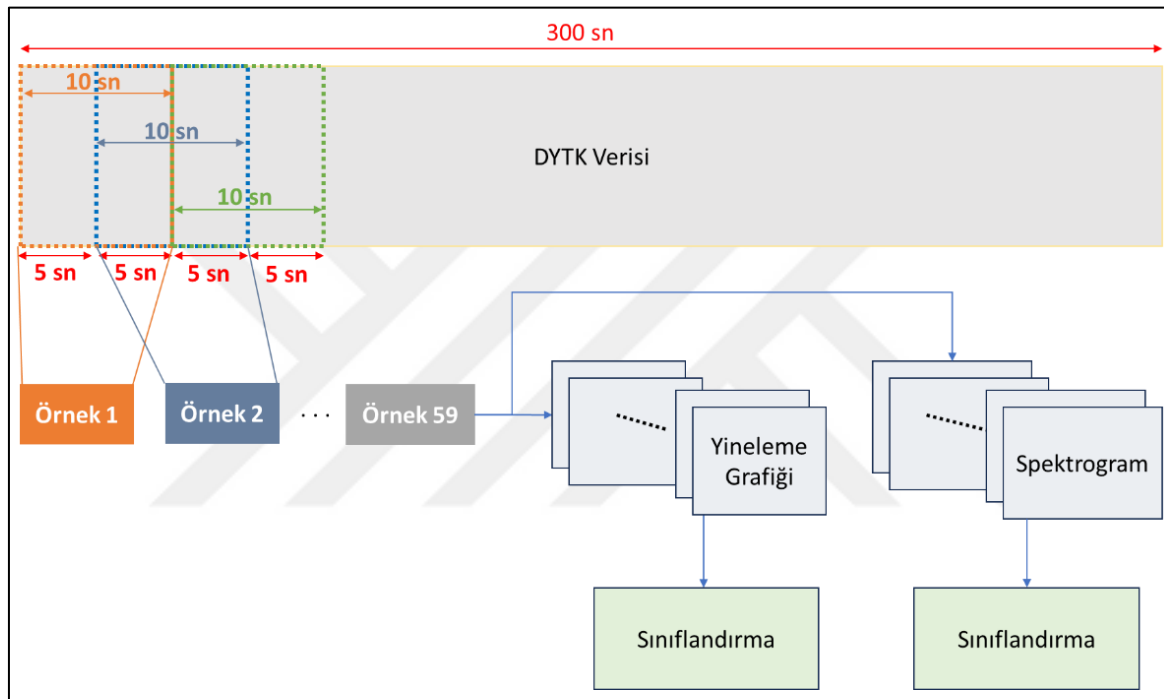
Şekil 2.1. NDH ve SK gruplarının DYTK sinyali adım zaman grafikleri [32]

Şekil 2.1’ de ham DYTK verisinden türetilen adım zaman verilerinin her grupta farklı olduğu görülmektedir. Bu durum NDH’ lerin sağlıklı kontroller gibi periyodik ve düzenli bir şekilde yürüyemediğini göstermektedir.

2.2. Ön İşleme

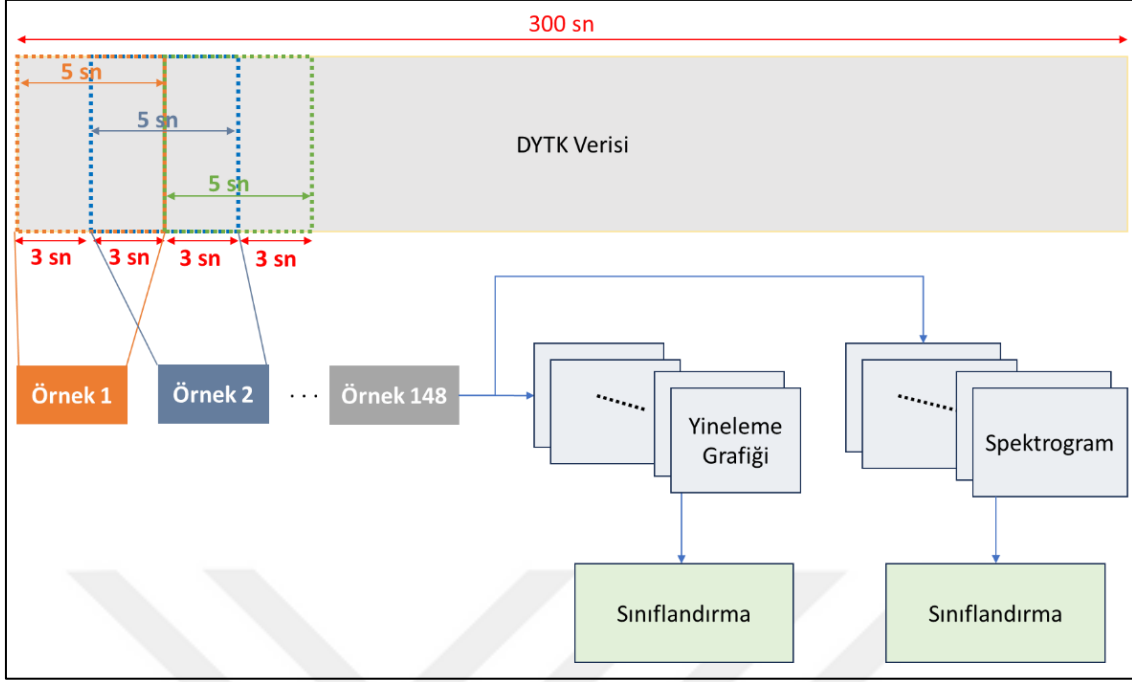
Bu çalışmada, makine öğrenmesi ve derin öğrenme yöntemleri uygulanmadan önce DYTK sinyalleri üzerinde ön işleme aşaması gerçekleştirilmiştir. Ön işleme aşamasında, deney protokolünün başlangıç ve bitişinden kaynaklanan yapaylıkları azaltmak için veri kümesinin ilk ve son 15 saniyesine karşılık gelen veri noktaları çıkarılmıştır [10].

Makine öğrenmesinde, 5 dakikalık sinyal kaydını içeren veri, örtüşmeyen 10 saniyelik aralıklara bölünmüştür. Böylelikle her bir denek için 5 dakikalık DYTK sinyalinden 28 örnek çıkarılmıştır. Derin öğrenmede ise veri kümesindeki örnek sayısı sınıflandırma doğruluğuna etki ettiği için 5 dakikalık sinyal kaydını içeren veri, Şekil 2.2’ de görüldüğü gibi 5 saniyelik örtüşen pencerelerle 10 saniyelik aralıklara bölünmüştür. Böylelikle her bir denek için 5 dakikalık DYTK sinyalinden 59 örnek çıkarılmıştır. Sağ ve sol ayak için ayrı ayrı PH’ de 885, HH’ de 1180, ALS’ de 767, SK’ de ise 944 örnek oluşturulmuştur.



Şekil 2.2. DYTK verisinin 10 saniyelik pencereler ile çoğaltılması

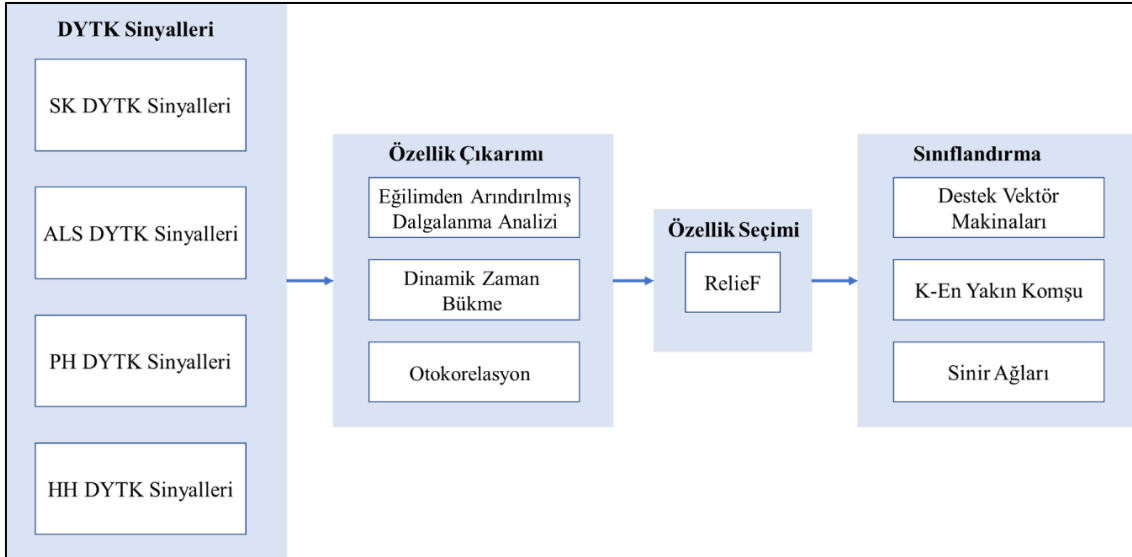
Derin öğrenme için gerekli örnek sayısını daha da arttırabilmek için Şekil 2.2’ de anlatılan veriyi pencerelere ayırma yöntemi Şekil 2.3’ te görüldüğü gibi 3 saniyelik örtüşen pencerelerle 5 saniyelik aralıklar ile tekrar uygulanmıştır. Böylelikle her bir denek için 5 dakikalık DYTK sinyalinden 148 örnek çıkarılmıştır. Sağ ve sol ayak için ayrı ayrı PH’ de 2220, HH’ de 2960, ALS’ de 1924, SK’ de ise 2368 örnek oluşturulmuştur.



Şekil 2.3. DYTK verisinin 5 saniyelik pencereler ile çoğaltılması

2.3. NDH' lerin Makine Öğrenmesine Dayalı Teşhisi

Şekil 2.4' te makine öğrenmesi yöntemi için oluşturulan mimari görülmektedir.



Şekil 2.4. Makine öğrenmesi yöntemi blok diyagramı

Veri kümesindeki SK, ALS, PH, HH olmak üzere 4 farklı gruptan alınan DYTK sinyalleri

ön işleme sonrasında eğilimden arındırılmış dalgalanma analizi (DFA), dinamik zaman bükme (DTW) ve otokorelasyon (OK) tabanlı özellik çıkarım yöntemleri ile her hastalık için özellik vektörleri oluşturulmuştur. Hastalığa özgü ayırt edici özellikleri belirlemek amacıyla Relief özellik seçimi uygulanmıştır. Ön işleme, özellik çıkarımı ve özellik seçimi yapılmış veri kümesi, destek vektör makinaları (DVM), k-en yakın komşu (k-NN) ve yapay sinir ağları (YSA) olmak üzere 3 farklı sınıflandırma yöntemi ile sınıflandırılmıştır.

2.3.1. Özellik çıkarma

Bu çalışmada, DYTK sinyalleri üzerinde özellik çıkarma yöntemlerinin uygulanması MATLAB programı kullanılarak gerçekleştirilmiştir. DYTK sinyalleri 5 dakikalık sinyal kaydını içermektedir. Veri, özellik çıkarma için örtüşmeyen 10 saniyelik aralıklara bölünmüştür.

Bu çalışmada da yürüyüş desenlerindeki içsel değişkenliği ve karmaşıklığı değerlendirmek için DFA yöntemi kullanılmıştır. DFA, zaman serisi verilerinde bulunan fraktal benzeri özellikleri ve uzun menzilli korelasyonları nicelendirmek için kullanılır. DTW, iki zaman serisi arasındaki benzerliği belirlemekte, zamansal bozulmalar veya değişkenlikler mevcut olduğunda bile, ölçüme üstün bir performans gösterir [33]. Özellikle yürüyüş analizinde, DTW' nin yürüyüş döngülerini hizalama ve karşılaştırma konusundaki hassasiyeti, yürüyüş değişkenliğini ve simetrisini değerlendirmeyi sağlar, ayrıca yürüyüş desenlerindeki ince sapmaları ve anormallikleri belirlemeye yardımcı olur [34]. Sağ ve sol ayak arasındaki benzerlik ve simetriyi değerlendirmek için DTW kullanılmıştır. Son olarak, OK zaman serisi verilerindeki periyodiklikleri ve ritmik desenleri nicelendirmek amacıyla kullanılmaktadır. OK, yürüyüş analizinde yürüyüş döngülerinin tutarlılığı ve düzenliliği hakkında bilgi sunar, böylece düzensiz tempo veya adım uzunluğu gibi düzensizliklerin belirlenmesini kolaylaştırır. Bu nedenle, yürüyüş analizinde DYTK sinyallerinden özellik çıkarmak için DFA, DTW ve OK yöntemleri seçilmiştir.

Eğilimden arındırılmış dalgalanma analizi (DFA)

DFA, zaman serisi analizinde uzun menzilli korelasyonların veya fraktal benzeri davranışların varlığını değerlendirmek için kullanılan istatistiksel bir tekniktir. İlk olarak 1994 yılında Peng ve arkadaşları [35] tarafından ortaya konmuştur. Bir zaman serisindeki

dalgalanmaların gözlem penceresinin uzunluğuna göre nasıl ölçeklendiğini inceleyerek serinin içsel korelasyon özelliklerini çıkarır. DFA, verilerin fraktal ve kendi benzer doğasını anlamak amacıyla sıkça kullanılmaktadır. DFA, kardiyoloji [36], finans [37], sinirbilim [38] ve genomik [39] gibi birçok alanda yaygın olarak kullanılmakta olup sırasıyla kalp atış hızı değişkenliği, finansal piyasalardaki dalgalanma, sinirsel aktivite ve DNA dizilerinin analizi için kullanılmaktadır. Buna ek olarak, DFA, yürüyüş ritmi verilerinde uzun menzilli korelasyonları ve fraktal benzeri özellikleri yakalayıp ölçerek özellik çıkarma aracı olarak da kullanılabilir. Yürüyüş ritmi verileri, bir bireyin zaman içindeki yürüme düzenine ilişkin ölçümleri kapsar ve DFA, bu karmaşık sistemin temel dinamiklerine dair bilgiler sağlamaktadır. Bu bağlamda, bireylerin yürüyüş kalıplarında bulunan içsel yapı ve korelasyonları tanımlamak için, yürüyüş ritmi verilerinin DFA tabanlı özellikleri çıkarılır.

Ayrıca DFA, zaman serisi verilerinin önemli özelliklerini yakalamayı amaçlayan bir özellik çıkarma yöntemi olarak iki aşamalı bir prosedürle çalışır: eğilim giderme ve dalgalanma genliği hesaplama [40]. Eğilim giderme aşamasında DFA, zaman serisine gömülü olan deterministik eğilimleri ortadan kaldırmak için, belirlenen boyuttaki örtüşmeyen pencerelerin her birinde yerel eğilimi hesaplar. Genellikle yerel eğilim, doğrusal veya polinomsal uyum gibi yöntemler kullanılarak tahmin edilir. Sonrasında, dalgalanma hesaplama aşamasında, DFA her bir penceredeki verinin ortalama kare dalgalanmasını belirler ve farklı boyutlardaki tüm pencereler arasında ortalama alır. Pencere boyutu ile ortalama kare dalgalanma arasındaki ilişki, zaman serisinin içsel ölçekleme özelliklerini açığa çıkarır [40].

\bar{X} , $X(t)$ zaman serisinin ortalaması olmak üzere, $t=1,2,3,\dots,N$ için, $Y(t)$ serisi;

$$Y(t) = \sum_{i=1}^t [X(i) - \bar{X}] \quad (2.1)$$

Eş. 2.1 kullanılarak hesaplanır. $Y(t)$, $k=1,2,\dots,m$ adet, n adet örneğe sahip parçalara bölünür ($m=N/n$). Her parça için en küçük kareler yöntemiyle, en az doğrusal olmak üzere, çeşitli derecelerden polinomlar oluşturulur. Daha sonra her bir $Y(t)$ değerinden $Y_{k,t}(t)$ değerleri çıkarılarak zaman serileri eğilimlerinden arındırılır. Eğilimden arındırılmış alt zaman serilerinin standart sapması Eş. 2.2' deki gibi ifade edilir [41].

$$F(n) = \left[\frac{1}{nm} \sum_{k=1}^m \sum_{t=(k-1)n+1}^{nk} [Y(t) - Y_{k,n}(t)]^2 \right]^{1/2} \quad (2.2)$$

DFA' da en önemli unsur, dalgalanmaların pencere boyutuna göre nasıl ölçeklendiğini belirten ölçekleme üstelidir (α). DFA yöntemi, alt kümelerdeki örnek adedi(n) ile $F(n)$ arasında $F(n) \approx n^\alpha$ şeklinde bir üssel değişim yasasının varlığına dayanır. $\{\log n, \log F(n)\}$ serisine en küçük kareler yöntemiyle bir doğru uydurulur. Bu doğrunun eğimi α ile gösterilir ve ölçekleme katsayısı olarak adlandırılır. Dalgalanma logaritması ile pencere boyutu logaritması arasındaki doğrusal ilişki genellikle fraktal benzeri davranışı gösterir ve bu ilişkinin eğimi α' ya karşılık gelir [42]. α değeri 0.5 olduğunda, zaman serisi beyaz gürültüye benzer şekilde korelasyonsuz davranış sergiler. α değeri 0.5'in üzerine çıktığında, zaman serisinde sürekliliği gösteren pozitif korelasyonların varlığı anlamına gelir. α değeri 0.5'in altına düştüğünde, zaman serisinde anti-sürekliliği gösteren negatif korelasyonların varlığı anlamına gelir.

Dinamik zaman bükme (DTW)

DTW, zaman serisi analizi ve desen tanıma alanında köklü bir teknik olup, zamanlama veya hızdaki farklılıklara rağmen iki dizinin benzerliğini ölçmeyi amaçlar [43]. DTW algoritması, sinyallerin zaman domaininde en yakın elemanlarını hizalamaya çalışarak, bunlar arasındaki kümülatif mesafeleri en aza indirir [33]. Bu minimizasyon, zaman domainindeki sinyaller arasında maksimum benzerliği sağlar. Sonuç olarak DTW yöntemi, iki adet tek boyutlu sinyal arasındaki benzerliği analiz eder ve buna ters orantılı bir uzaklık değeri hesaplar [7]. Böylece birbirine benzeyen sinyaller için küçük bir uzaklık bulunurken, birbirine benzemeyen sinyaller için büyük bir uzaklık değeri bulunur.

DTW, zaman serisi verilerini hizalama ve karşılaştırma konusundaki kullanımıyla tanınsa da aynı zamanda zaman serisinin içsel özelliklerini kapsayan bir özellik çıkarma aracı olarak da işlev görür [44]. Zaman serisi verileri, genellikle sensör okumaları veya konuşma sinyalleri gibi sırayla indekslenen veri noktalarından oluşur. Bu tür veriler, zamanlama, hız ve fazda değişiklikler gösterir ve doğrudan karşılaştırma veya analiz yapmayı zorlaştırır. Öklidyen mesafe gibi geleneksel benzerlik metrikleri, düzensizliklerle dolu zaman serileriyle karşılaşıldığında yetersiz kalabilir [45]. Ancak DTW, iki zaman serisi arasındaki en uygun hizalamayı bularak, karşılık gelen noktalar arasındaki kümülatif mesafeyi

azaltmak için onları esneterek bu zorlukların üstesinden gelir. Bu süreç, iki dizi elemanları arasındaki ikili mesafeleri belirleyen iki boyutlu bir DTW matrisi oluşturur.

Sırasıyla uzunlukları n ve m olan $X = x_1, x_2, \dots, x_n$ ve $Y = y_1, y_2, \dots, y_m$ zaman serisi sinyallerinin benzerliği bulmak için öncelikle $n \times m$ lik bir matris oluşturulur. Bu matrisin i . ve j . elemanları X_i ve Y_j noktaları arasındaki genlik bakımından uzaklık olan $d(X_i, Y_j)$ ' yi verir. Kullanılan uzaklık ölçütü Eş. 2.3' te görülen Öklid uzaklığıdır [46].

$$d(X_i, Y_j) = \sqrt{|X_i^2 - Y_j^2|} \quad (2.3)$$

Bu uzaklık ölçütü, matrisin her bir elemanı arasındaki karşılaştırmayı belirtir. Bu matristeki bükme yolu W , iki sinyal arasındaki optimum benzerliği temsil edecek şekilde seçilir. W ' nin k . elemanı $w_k = (i, j)_k$ şeklinde tanımlanmıştır. $w_1 = (1, 1)$ ve $w_K = (m, n)$ arasındaki diyagonal çizgi ise $W = w_1, w_2, \dots, w_k, \dots, w_K$ şeklinde tanımlanır.

Bükme yolunu en aza indiren optimum eğriltme yolu, Eş. 2.4 ile belirlenebilir [47]. Yol uzunlukları farklı olabileceğinden, son DTW mesafeleri bükme yolu uzunluğu (K) ile normalleştirilir.

$$W(X, Y) = \min \left\{ \sqrt{\sum_{k=1}^K \frac{w_k}{K}} \right\} \quad (2.4)$$

Bükme yolu, Eş. 2.5' te verilen dinamik programlama tekniği kullanılarak bulunabilir.

$$D(i, j) = d(i, j) + \min \left\{ \begin{array}{l} D(i, 1, j) \\ D(i - 1, j - 1) \\ D(i - 1, j) \end{array} \right\} \quad (2.5)$$

DTW aracılığıyla özellik çıkarma, yürüyüş sınıflandırması [34], konuşma tanıma [48], jest tanıma [49], geçici yürüyüş değişikliklerinin değerlendirilmesi [50] ve anomali tespiti [51] gibi birçok alanda geniş bir kullanım alanına sahiptir. Özellikle yürüyüş ritmi verilerinde, DTW, farklı yürüyüş desenleri arasındaki benzerlikleri, zamanlama veya hız değişiklikleri durumlarında bile yakalamak ve ölçmek için güçlü bir araç olarak öne çıkar. Bu çıkarılan

özellikler, makine öğrenimi algoritmaları, sınıflandırıcılar, kümeleme teknikleri veya derin öğrenme algoritmaları tarafından belirli uygulamalarla ilgili desenleri ayırt etmek için kullanılabilir.

DTW' nin yürüyüş ritmi verilerine uygulanmasıyla, yürüyüş desenleri zamanlama, hız veya adım uzunluğundaki değişikliklere rağmen incelenip karşılaştırılabilir [34]. Bu yöntem, sağlık, rehabilitasyon ve biyomekanik gibi alanlarda yürüyüşle ilgili sorunların değerlendirilmesi ve teşhisinde kullanılan bir araç olarak öne çıkabilir. Bu çalışma bağlamında, DTW matrisi, sensör ölçümlerinden elde edilen DYTK sinyallerine DTW uygulanarak oluşturulmuştur.

Otokorelasyon (OK)

Otokorelasyon (OK), bir sinyal ile zaman gecikmeli karşılığı arasındaki benzerliği veya korelasyonu belirten bir ölçüt olarak tanımlanır. OK katsayıları, sinyal işleme ve zaman serisi analizi çalışmalarında geniş bir uygulama alanı bulur. Zaman serisi verilerinin analizinde, periyodik desenlerin ve trendlerin belirlenmesinde kritik bir rol oynar [52]. Tahmin görevlerinde yaygın olarak kullanılarak, tekrarlayan desenlerin yakalanmasını ve verideki zamansal bağımlılıkların anlaşılmasını sağlar. Sinyal işleme alanında ise, konuşma sinyallerinde perde tespiti ve ses ile titreşim verilerinde periyodikliğin belirlenmesi gibi görevlerde yardımcı olur [53]. Ayrıca, OK katsayıları, bireyin yürüme desenindeki zamansal bağımlılıkları ve periyodiklikleri yakalamak ve ölçmek için yürüyüş ritmi verilerinde özellik çıkarımı için önemlidir [54]. Yürüyüş ritmi verileri genellikle bir bireyin yürüme ile ilgili zaman serisi ölçümlerini, örneğin adım aralıkları veya adım uzunluklarını içerir. OK yoluyla çıkarılan özellikler, yürüyüş deseni tanıma, yürüyüş düzenliliğinin değerlendirilmesi veya anomali tespiti gibi çeşitli amaçlar için kullanılabilir. Bu özellikler üzerine makine öğrenimi teknikleri veya istatistiksel analiz yöntemleri uygulanarak bireyin yürümesi ile ilgili değerlendirmeler veya sınıflandırmalar elde edilebilir.

Yürüyüş ritmi verilerinde OK' ye dayalı özellik çıkarımının kullanımı, sağlık hizmetleri, düşme tespiti ve rehabilitasyon izleme gibi çeşitli uygulamalarda önem taşır [55]. Bu yaklaşım, bir bireyin yürüme deseni içerisindeki desenlerin, periyodikliklerin ve düzensizliklerin tanımlanmasını kolaylaştırarak klinik teşhisler veya müdahaleler için

değerli içgörüler sağlar. Araştırmacılar, bireyin yürüme davranışındaki zamansal bağımlılıkları ve ritmik desenleri belirleyen özellikleri çıkarmak için yürüyüş ritmi verilerinde OK katsayılarını kullanmış ve bu özellikleri çeşitli yürüyüş değerlendirme ve analiz uygulamalarında kullanmışlardır [55].

Bu çalışmanın bağlamında, çeşitli k gecikme periyodu için hesaplanan OK katsayıları ρ_k , DYTK sinyallerinden türetilen özellikler olarak kullanılmaktadır. x_t : zaman serisinin t zamanındaki değeri olarak tanımlanırsa, k gecikme periyodundaki otokorelasyon katsayısı Eş. 2.6 kullanılarak belirlenir:

$$\rho_k = \frac{\sum_{t=k+1}^N (x_t - \bar{x})(x_{t-k} - \bar{x})}{\sum_{t=k+1}^N (x_t - \bar{x})^2} \quad (2.6)$$

Bu eşitlikte, ρ_k k gecikme periyodundaki otokorelasyon katsayısı, N zaman serisindeki toplam veri noktası sayısı, x_t zaman serisinin t anındaki değeri, x_{t-k} zaman serisinin $t - k$ gecikme anındaki değeri, \bar{x} zaman serisinin ortalama değeri olarak tanımlanır.

2.3.2. Özellik seçimi

Birçok makine öğrenimi probleminde her girdi nesnesini tanımlayan yüzlerce veya binlerce potansiyel özellik vardır. Öğrenme yöntemlerinin çoğu aşırı öğrenme, gürültülü veri, uzun eğitim süresi gibi çeşitli nedenlerden dolayı yüksek öznelik boyutlarında iyi davranmaz. Bu nedenle bir model eğitilmeden önce özellik seçimi tekniklerinin uygulanması önemlidir. Bunun yanı sıra, özellik seçimi tekniklerini kullanmak, eğitim süresinin ve aşırı öğrenmenin azaltılmasını sağlar. Özellik seçimi ile beraber sistem daha az karmaşık hale gelir, bu nedenle yorumlanması daha kolaylaşır.

Bu çalışmada, veri setindeki en önemli özellikleri belirleyerek modelin performansını artırmak ve hesaplama maliyetini azaltmak için Relief özellik seçim algoritması kullanılmıştır. Relief algoritması, bir model öğrenilmeden önce bir özellik alt kümesi seçimi yöntemi olarak kullanılır. Relief algoritması, özelliklerin sınıflar arasındaki ayırım gücünü değerlendirmeye odaklanır. Bu algoritmanın çalışma prensibi şu şekildedir [56]:

- Her özelliğe bir ağırlık değeri atanır ve başlangıçta bu ağırlıklar sıfır olarak ayarlanır.

- Veri kümesinden rastgele bir örnek seçilir.
- Seçilen örnek için aynı sınıftan en yakın komşu (hit) ve farklı sınıftan en yakın komşu (miss) belirlenir.
- Özelliklerin ağırlıkları, hit ve miss örneklerine olan uzaklıklara göre güncellenir.
- Tüm özellikler için ağırlıklar hesaplandıktan sonra, en yüksek ağırlığa sahip özellikler en önemli olarak değerlendirilir ve öznitelik seçimi yapılır.

2.3.3. Sınıflandırma

Bu çalışmada, NDH' ler, sonuçların karşılaştırılabilirliği sağlamak amacıyla çıkarılan özelliklere dayalı olarak üç farklı sınıflandırıcı kullanılarak sınıflandırılmıştır. Bulguların genelleştirilebilirliğini sağlamak ve özelliklerin etkisini ortaya çıkarmak için üç farklı sınıflandırıcı kullanılmıştır: DVM, k-NN ve YSA. Bu çalışmada kullanılan sınıflandırma algoritmaları MATLAB programı kullanılarak uygulanmıştır. Sınıflandırma parametreleri, her hastalık kategorisi için ayrı ayrı ve birden fazla sınıflandırıcıda titizlikle belirlenmiş ve uygulanmıştır. Sınıflandırıcıların performansını değerlendirmek için 10-kat çapraz doğrulama yaklaşımı uygulanmıştır. DVM hem doğrusal hem de doğrusal olmayan veri kümelerini işlemek için uygun bir sınıflandırıcıdır. Öte yandan, k-NN, sınıflandırma için yakınlık temelli bir yöntem olup genellikle basit ancak etkilidir. YSA ise, karmaşık ilişkileri modellemek için esnek bir yapı sunmaktadır. Bu özellikleri nedeniyle, DVM, k-NN ve YSA, bu çalışmada kullanılacak sınıflandırıcılar olarak seçilmiş ve elde edilen sonuçların kapsamlı ve güvenilir bir şekilde analiz edilmesi ve yorumlanması sağlanmıştır.

Destek vektör makinesi (DVM)

DVM, sınıflandırma ve regresyon görevlerinde kullanılan denetimli bir makine öğrenimi algoritmasıdır. DVM' ler, bir veri kümesini iki veya daha fazla sınıfa bölmeyi amaçlayan sınıflandırma problemleri için uygundur. Bir DVM' nin temel amacı, veriyi farklı sınıflara en iyi şekilde ayıran ve hiperdüzlem ile her sınıfın en yakın veri noktaları arasındaki mesafeyi maksimize eden bir hiperdüzlem bulmaktır. DVM' ler, hem doğrusal hem de doğrusal olmayan sınıflandırma problemlerini etkili bir şekilde ele alma yetenekleri nedeniyle çeşitli uygulamalarda yaygın olarak kullanılmaktadır. Bununla birlikte, hiperparametrelerin (örneğin çekirdek ve düzenleme parametreleri) seçimine karşı hassas

olabilirler ve bu hiperparametrelerin ayarlanması, DVM' lerin pratikte etkili bir şekilde kullanılmasının önemli bir parçasıdır.

DVM' nin temel prensibi, iki sınıf arasında optimum ayırıcı hiperdüzlemi bulmaktır. İki sınıf arasındaki marjı en üst düzeye çıkaran optimum hiperdüzlem, marjdaki vektörlerle, yani destek vektörleriyle tanımlanır [57]. Hiperdüzlem $f(x) = w \cdot x + b$, ağırlık vektörü (w) ve sapma terimi (b) ile tanımlanabilir. Bir test veri vektörünün (x) sınıf etiketi (y), x ' i ağırlık vektörüne (w) yansıtılarak tahmin edilebilir. Hiperdüzlem ile en yakın eğitim noktaları arasındaki mesafeyi en üst düzeye çıkaran optimum çözümü bulmak için, Eş. 2.7' de verilen maliyet fonksiyonunu en aza indirerek ve Eş. 2.8' de verilen kısıtlamaları sağlayarak elde edilebilir. Eş. 2.7 ve 2.8' de, C bir düzenleme parametresidir, ξ_n eğitim hatasının bir ölçüsüdür, z yanlış sınıflandırılmış örneklerin sayısıdır ve y_n n ' inci örnek için sınıf etiketidir [58,59].

$$L(w, \xi) = \frac{1}{2} \|w\|^2 + C \sum_{n=1}^Z \xi_n \quad (2.7)$$

$$\begin{aligned} x_n \cdot w + b &\geq 1 - \xi_n \text{ for } y_n = +1 \\ x_n \cdot w + b &\geq -1 + \xi_n \text{ for } y_n = -1 \\ \xi_n &\geq 0 \forall n, \end{aligned} \quad (2.8)$$

k-en yakın komşu (k-NN) algoritması

k-NN, hem sınıflandırma hem de regresyon görevleri için kullanılan basit ve esnek bir makine öğrenimi algoritmasıdır. k-NN, yeni veri noktalarının tahminlerini, eğitim veri kümesindeki var olan veri noktaları ile veri noktalarına en yakın örneklerin benzerliklerine dayanarak yapar. Tahmin yapılan veri noktasının ' x ' olduğu varsayılırsa, seçilen bir uzaklık ölçüsü, ' x ' ve eğitim veri kümesindeki tüm veri noktaları ' x_i ' arasındaki uzaklık Öklid uzaklığı Eş. 2.9 ile hesaplanır.

$$d(x, x_i) = \sqrt{\sum_{j=1}^n (x_j - x_{ij})^2} \quad (2.9)$$

Bu eşitlikte, $d(x, x_i)$: x ve x_i arasındaki uzaklık, n : özellik sayısı, x_j and x_{ij} : x ve x_i ' nin j . özellik boyutundaki özellik değerleri olarak tanımlanır.

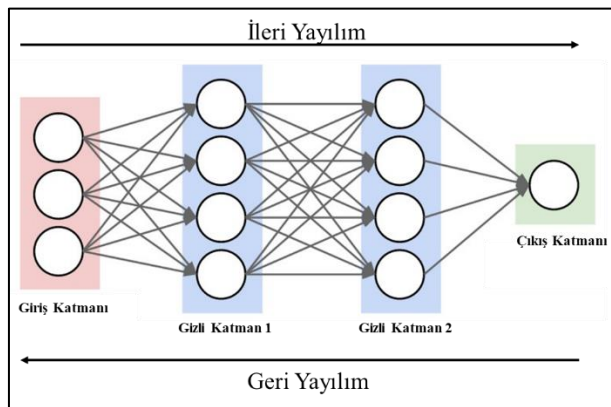
' x ' e en küçük mesafelere sahip ' k ' veri noktaları seçilir. Sınıflandırma için, her bir sınıf etiketinin bu ' k ' komşular arasındaki oluşumları sayılır ve en yüksek sayıya sahip sınıf etiketi, ' x ' için tahmin edilen sınıf olarak atanır. k-NN şu şekilde kullanılabilir:

- Bir uzaklık ölçüsü ve uygun bir ' k ' değeri seçilir.
- Yeni bir veri noktasının sınıfını belirlemek için, ' k ' en yakın komşularına olan uzaklıkları hesaplanır ve bu komşular arasındaki çoğunluk sınıfına dayalı olarak bir sınıf etiketi atanır.

Uzaklık metriğinin seçimi ve ' k ' değeri, k-NN' nin sınıflandırma probleminde performansını etkileyen kritik faktörlerdir. Bu parametrelerin denenerek ve ince ayar yapılarak en iyi sonuçlara ulaşılması gereklidir.

Yapay sinir ağı (YSA)

Yapay sinir ağı, veriyi farklı kategorilere veya sınıflara ayırmak için kullanılan bir sınıflandırma algoritmasıdır. YSA' lar, Şekil 2.5' te görüldüğü gibi birbirine bağlı düğümler veya nöronlardan oluşur ve veri içindeki karmaşık desenleri ve ilişkileri öğrenme yeteneğine sahiptir. Bir sınıflandırma probleminde, bir YSA girdi verisini alır ve onu önceden tanımlanmış birkaç sınıf veya kategori arasından birine atar.



Şekil 2.5. YSA' ların genel yapısı

Sınıflandırma için kullanılan en temel YSA türü, ileri beslemeli YSA' dır. Bu ağ, üç ana türde katmandan oluşur: girdi, gizli ve çıkış katmanları. Girdi katmanı, girdi verisinin özelliklerini veya niteliklerini temsil eder. Gizli katmanlar, girdi verisini ağırlıklı bağlantılar ve aktivasyon fonksiyonları aracılığıyla dönüştüren ara katmanlardır. İleri beslemeli bir ağın birden fazla gizli katmanı olabilir. Çıkış katmanı, tahmin edilen sınıf veya kategoriye karşılık gelen nihai çıktıyı üretir. 'm' sınıflı bir sınıflandırma görevi için, çıkış katmanında 'm' düğüm bulunur ve her biri girdi verisinin bir sınıfa ait olma olasılığını temsil eder. İleri beslemeli YSA için temel matematiksel ifadeler Eş. 2.10 ve Eş. 2.11' deki gibi ifade edilebilir. Her bir gizli katmandaki her bir nöron için:

$$z_j^{(l)} = \sum_{i=1}^{n^{l-1}} w_{ij}^{(l)} a_i^{l-1} + b_j^{(l)} \quad (2.10)$$

$$a_j^{(l)} = f(z_j^{(l)}) \quad (2.11)$$

Eşitliklerde 'l' katman indeksi, 'i' (l-1) katmanındaki nöron indeksi, 'j' l katmanındaki nöron indeksi, 'w' ağırlıklar, 'a' aktivasyon fonksiyonu çıktısı, 'b' bias terimi, 'f' Sigmoid, Doğrultulmuş Doğrusal Birim (ReLU) veya Softmax gibi genellikle doğrusal olmayan bir fonksiyondur.

Sınıflandırma problemindeki çıkış katmanı Softmax aktivasyon fonksiyonu ile Eş. 2.12' deki gibi ifade edilebilir.

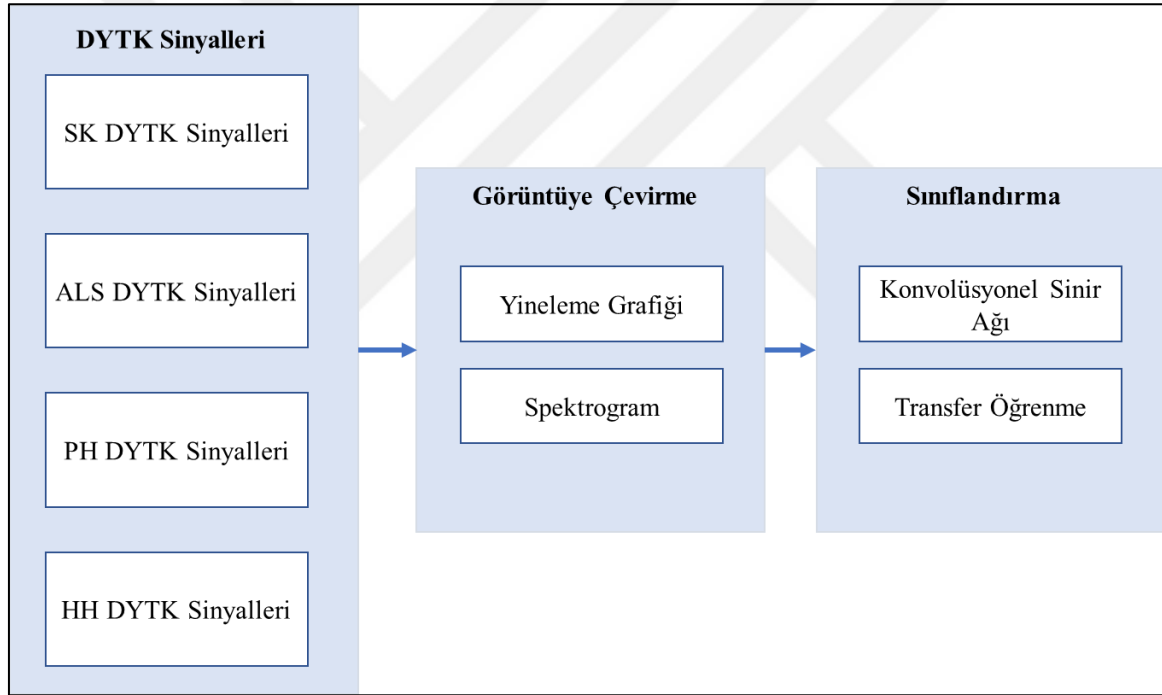
$$a_j^{(L)} = \frac{e^{z_j^{(L)}}}{\sum_{k=1}^m e^{z_k^{(L)}}} \quad (2.12)$$

Eşitlik 2.12' de 'L' çıkış katmanı, 'm' sınıf sayısı (kategori sayısı), 'z' çıkış katmanına giren ağırlıklı girişlerin toplamını ifade etmektedir.

Softmax aktivasyon fonksiyonu, çok sınıflı sınıflandırma problemleri için genellikle çıkış katmanında kullanılan bir fonksiyondur. Ağ etiketli veriler üzerinde eğitilir ve eğitim sırasında ağırlıklarını ve sapmalarını (bias) ayarlayarak bir kayıp fonksiyonunu (örneğin, çapraz-entropi kaybı) en aza indirecek şekilde öğrenir, böylece doğru tahminler yapabilir.

2.4. NDH' lerin Derin Öğrenme Tekniklerine Dayalı Teşhisi

Şekil 2.6' da derin öğrenme yöntemi için oluşturulan mimari görülmektedir. Bu yöntemde DYTK sinyalleri, Bölüm 2.2' de anlatılan şekilde ön işleme aşamasından geçirilmiştir. Ön işleme yapılmış DYTK sinyallerinin görüntüye dönüştürülmesi amacıyla yineleme grafiği ve spektrogram olmak üzere 2 farklı sinyal-görüntü dönüşüm yönteminden faydalanılmıştır. Görüntüye çevrilen veriler ilk olarak konvolüsyonel sinir ağları ile sınıflandırılmıştır. Bu amaçla hibrit bir CNN modeli geliştirilmiştir. Bununla beraber önceden eğitilmiş sinir ağları kullanılarak transfer öğrenme yöntemi ile sınıflandırma işlemleri gerçekleştirilmiştir.



Şekil 2.6. Derin öğrenme yöntemi blok diyagramı

2.4.1. Sinyal-Görüntü Dönüşüm Teknikleri

Derin öğrenme tabanlı sınıflandırma için DYTK sinyalleri görüntüye dönüştürülmüştür. Bu bölümde, çalışmada kullanılan DYTK sinyallerinin yineleme grafiği ve spektrogram görüntüsüne dönüşüm teknikleri anlatılmıştır.

Yineleme grafiđi

Yineleme grafiđi, zaman serisi analizinde kullanılan ve kaotik dinamik sistemlerin davranışını görselleştirmek için geliştirilen bir tekniktir [60]. İlk olarak 1987 yılında Eckmann ve ark. [60] tarafından tanıtılan bu yöntem, bir zaman serisinin kendi geçmişiyle olan ilişkisini iki boyutlu bir matris formunda görselleştirir. Yineleme grafikleri, belirli zaman aralıklarında sistemin durumlarının tekrarlanma modellerini ortaya çıkarır ve bu sayede zaman serisinin dinamik özelliklerini analiz etmeye yardımcı olur.

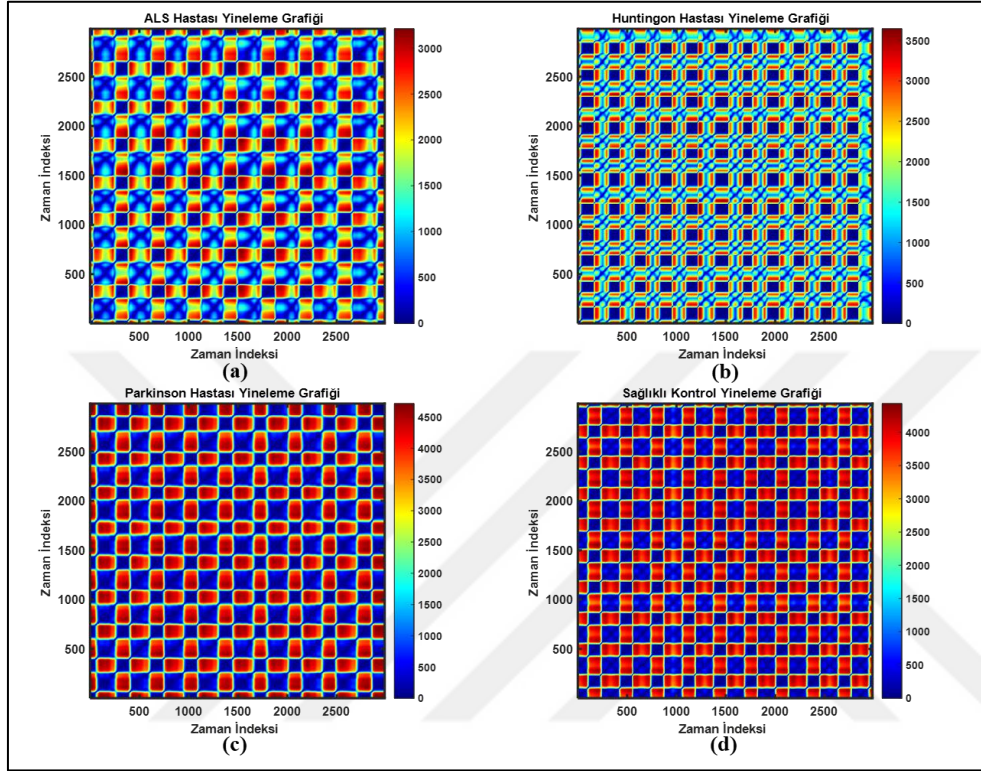
Bir zaman serisinin $x(t)$ olduğu varsayılırsa, bu zaman serisinin her bir veri noktası, belirli bir zaman adımında sistemin durumunu temsil eder. Yineleme grafiđi, zaman serisinin çeşitli zamanlarda kendisiyle ne kadar benzer olduğunu göstermek için Eş. 2.13 kullanılarak oluşturulur [61].

$$R_{i,j} = \theta(\epsilon - \|x(i) - x(j)\|) \quad (2.13)$$

Eşitlik 2.13' de $x(i)$ ve $x(j)$ zaman serisinin i . ve j . zaman adımlarındaki durum vektörleridir. $\|x(i) - x(j)\|$, iki durum vektörü arasındaki mesafeyi ifade eder, mesafe ölçütü olarak genellikle Öklidyen mesafesi kullanılır. ϵ , belirli bir eşik değeridir. θ , adım fonksiyonudur.

Yineleme grafiđinde, $R_{i,j} = 1$ olan noktalar ($\|x(i) - x(j)\| \leq \epsilon$ koşulunu sağlayan noktalar) birer siyah nokta olarak çizilirken, diğer noktalar beyaz olarak bırakılır. Bu grafik, zaman serisindeki tekrarlanan kalıpları ve yapıları görselleştirir. Yineleme grafiđindeki diagonal çizgiler sistemin belirli bir süre boyunca benzer davranışlar sergilediđini gösterir. Bu, zaman serisinde periyodik veya tekrarlanan kalıpların varlığını işaret eder. Dikey ve yatay çizgiler, sistemde bir duraklama veya sabit kalma durumunu gösterir. Kümeleşmeler ise sistem durumlarının belirli alanlarda yoğunlaştığını ve bu bölgelerde sıkça tekrarlanan davranışlar olduğunu belirtir. Yineleme grafikleri, sadece zaman serisinin tekrarlayan yapılarını görselleştirmekle kalmaz, aynı zamanda zaman serisindeki gizli dinamiklerin ve kaotik özelliklerin keşfedilmesini de sağlar. Bu çalışmada kullanılan ALS, PH, HH hastaları ile sağlıklı kontrol grubuna ait sinyallere ilişkin yineleme grafikleri Şekil 2.7' de görülmektedir. Şekiller MATLAB programı kullanılarak

çizdirilmiştir. Şekil 2.7’ de her bir NDH’ nin ve SK’ nin yineleme grafiğindeki desen ve örüntülerin birbirinden farklı olduğu görülmektedir. Bu durum, yineleme grafiği görüntülerinin NDH’ lerin teşhisi için ayırt edici olduğunu göstermektedir.



Şekil 2.7. NDH ve SK gruplarının yineleme grafik örnekleri (a) ALS hastası, (b) Huntingon hastası, (c) Parkinson hastası, (d) sağlıklı kontrol grubu

Spektrogram

Spektrogram, bir sinyalin zamanla değişen frekans içeriğini görselleştirmek için kullanılan bir analiz aracıdır [62]. Bir sinyalin frekans bileşenlerinin zamanla nasıl değiştiğini görselleştirir. Zaman-frekans desenlerini tanımlamak için kullanılır. Zaman ekseninde ilerlerken, sinyalin farklı frekans bileşenlerinin yoğunluğunu renkler veya gri tonlarıyla temsil eden bir grafikdir. Temel olarak, bir sinyalin hem zaman hem de frekans domaininde analiz edilmesini sağlar [62].

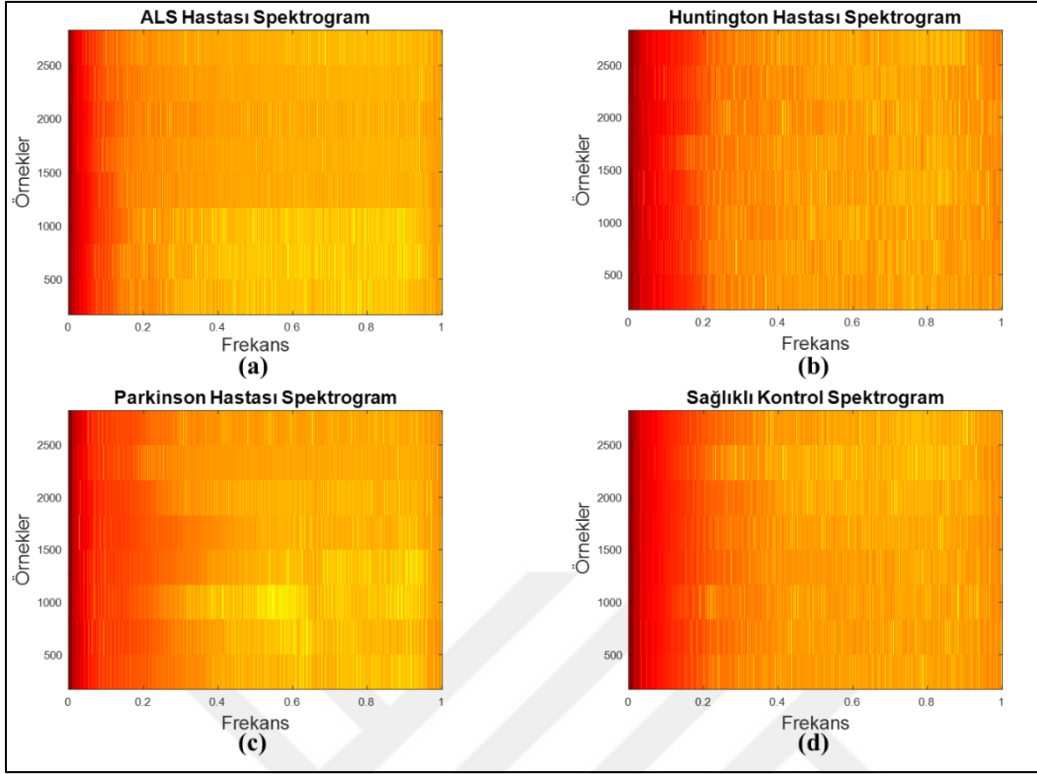
Spektrogram oluşturma süreci, genellikle kısa zamanlı Fourier dönüşümü (STFT) kullanılarak gerçekleştirilir [62]. Bu yöntem, sinyali kısa zaman aralıklarına böler ve her bir zaman dilimi için Fourier dönüşümünü hesaplar. Böylece, sinyalin frekans içeriğinin

zamanla nasıl deđiřtiđi gözlemlenebilir. Spektrogram, matematiksel olarak Eř. 2.14' teki gibi tanımlanabilir [63].

$$S(t, f) = \left| \int_{-\infty}^{\infty} x(\tau) w(\tau - t) e^{j2\pi f \tau} d\tau \right|^2 \quad (2.14)$$

Eřitlik 2.14' te $x(t)$, analiz edilen sinyaldir. $w(t)$, pencere fonksiyonudur. Pencere fonksiyonu $w(t)$ sinyalin kısa bir bölümünü izole eder. Pencere fonksiyonunun genişliđi, zaman çözünürlüđü ile frekans çözünürlüđü arasındaki dengeyi belirler. t zaman, f ise frekans parametresidir. STFT uygulandıktan sonra, sinyalin zaman-frekans düzlemindeki enerji yoğunluđunu görmek için STFT' nin genlik karesi alınır. Genlik karesi alınan sinyal spektrogramı oluşturur. $S(t, f)$, t zamanındaki ve f frekansındaki sinyalin spektrogram deđeridir.

Bu çalışmada kullanılan ALS, PH, HH hastaları ile sađlıklı kontrol grubuna ait sinyallere iliřkin spektrogram görüntülerinin birer örnekleri Őekil 2.8' de görölmektedir. Őekiller MATLAB programı kullanılarak çizdirilmiřtir. Őekil 2.8' e bakıldıđında, HH ve SK' nın düşük frekanslardaki yoğunluđunun ALS ve PH' ye göre daha fazla olduđu görölmektedir. Bunun yanında ALS ve PH' lerin grafiklerinde frekans arttıka homojen bir dađılım olduđu görölmektedir. Bu grafikler, her bir NDH' nin ve SK' nın zamanla deđiřen frekans bilgisinin birbirinden farklı olduđunu ve böylece spektrogram görüntülerinin NDH' lerin teřhisi için ayırt edici olabileceđini göstermektedir.



Şekil 2.8. NDH ve SK gruplarının spektrogram görüntüsü örnekleri (a) ALS hastası, (b) Huntington hastası, (c) Parkinson hastası, (d) sağlıklı kontrol grubu

2.4.2. Derin öğrenme

Derin öğrenme, yapay zeka alanının bir alt dalıdır ve insan beyninden esinlenilerek tasarlanmıştır. Birbirine bağlı katmanlardan oluşur ve katmanlarda nöron ismi verilen işlem birimleri bulunmaktadır. Veri kümeleri üzerinde karmaşık örüntülerin benzerlik ve farklılıklarını öğrenmek ve tahmin yapmak için tasarlanmıştır. Görüntü ve ses tanıma, doğal dil işleme, tıbbi görüntüleme, otomotiv ve finans gibi birçok farklı alanda kullanılmaktadır [64].

Derin öğrenme, genellikle çok katmanlı yapay sinir ağları kullanılarak gerçekleştirilir. Bu yapay sinir ağları, ham veriyi doğrudan işleyerek, kendi içindeki katmanlarda otomatik olarak öğrenmektedir. Oluşturulan yapay sinir ağı, veri kümesi ile beslenerek, veri kümesindeki sınıfların farklılıklarının öğrenilmesini sağlamaktadır. Bu sayede derin öğrenme, veri üzerinden otomatik olarak özellikleri çıkarmaktadır. Geleneksel makine öğrenmesinde genellikle özellik mühendisliği adı verilen süreçle insan müdahalesi

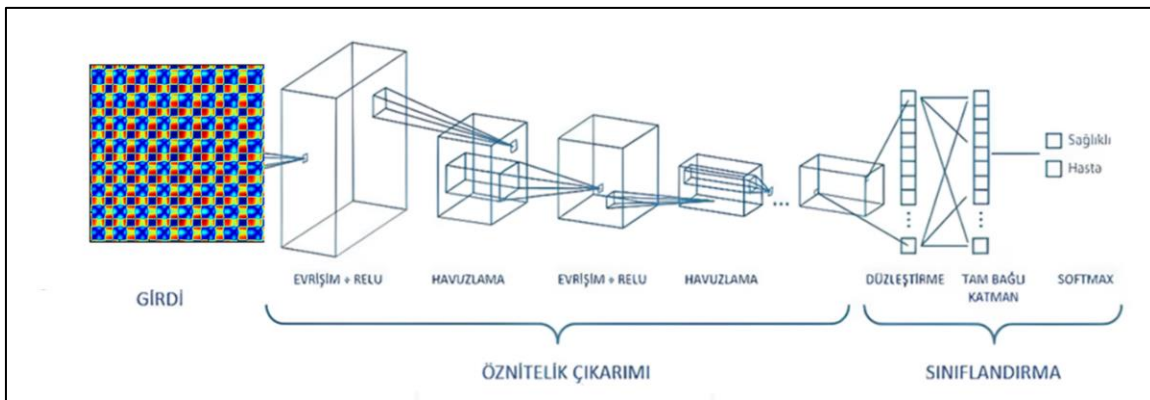
gerekebilir. Ancak derin öğrenme, çok katmanlı yapay sinir ağları aracılığıyla, özellikleri verinin kendisinden öğrenerek daha karmaşık ve soyut özellikleri tanımlayabilir.

Derin öğrenme, çeşitli yöntemler ve mimariler kullanarak uygulanabilmektedir. Yapay sinir ağları, kovolüsyonel sinir ağları, yinelemeli sinir ağları, uzun kısa vadeli bellekler, çekişmeli üretici ağlar ve transformer gibi çeşitli yöntemler, derin öğrenmenin başarısında önemli rol oynamaktadır [65].

Konvolüsyonel sinir ağları

CNN' ler, özellikle görüntü işleme alanında yaygın olarak kullanılan bir derin öğrenme mimarisidir. İlk olarak biyolojik görme sisteminden esinlenerek geliştirilmiştir ve günümüzde, bilgisayarla görme, video analizi, tıbbi görüntüleme ve daha birçok alanda üstün performans sergilemektedir [66]. CNN' ler, özellikle büyük ve karmaşık veri kümelerinde yüksek doğruluk oranlarına ulaşabilir. CNN' ler, veriden otomatik olarak özellikleri öğrenebilir, bu da detaylı öznitelik çıkarma gereksinimini azaltır [67]. Konvolüsyon katmanı, yerel özellikleri yakalayıp veri içerisindeki uzamsal ilişkileri öğrenir. Filtreler, tüm giriş verisi üzerinde paylaşılarak hesaplama maliyetini düşürür ve öğrenme sürecini hızlandırır. Bununla birlikte, CNN' ler büyük veri kümeleri ve yüksek hesaplama gücü gerektirir [68]. Ayrıca, modelin karmaşıklığı, aşırı öğrenme riskini artırabilir ve düzenleme teknikleri (örneğin dropout) gerektirebilir.

Şekil 2.9' da temel bir CNN mimarisi görülmektedir.

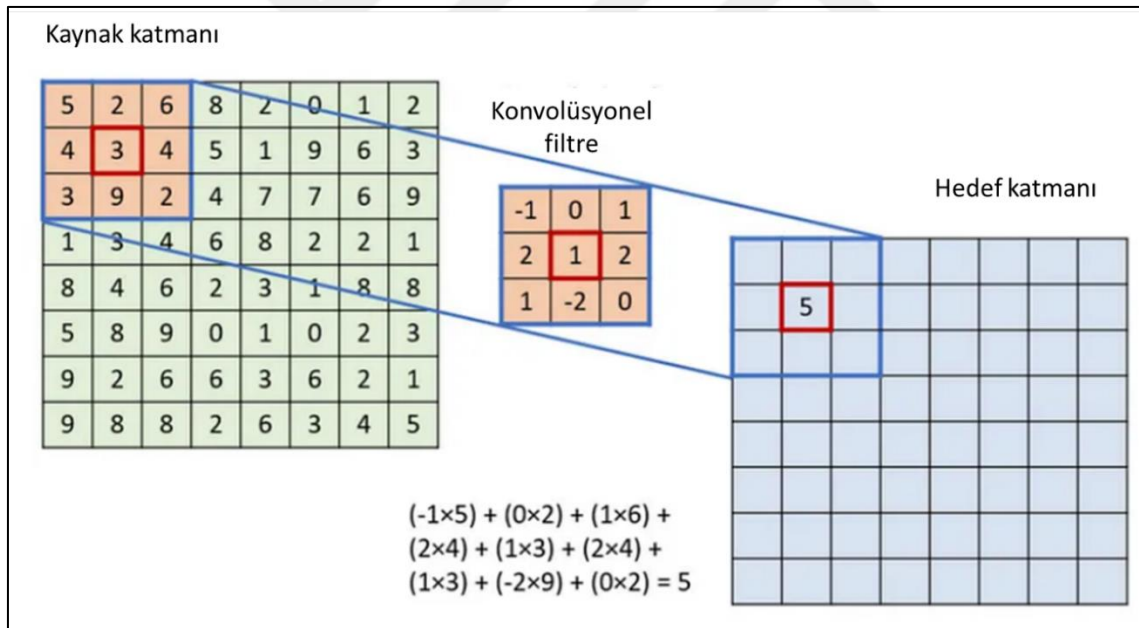


Şekil 2.9. Temel CNN mimarisi

CNN'ler, genellikle üç ana katman türünden oluşur: konvolüsyon katmanları, havuzlama katmanları ve tam bağlantılı katmanlar [69]. Bu katmanlar, sırasıyla veri içindeki özellikleri çıkarma, boyut küçültme ve sınıflandırma işlemlerini gerçekleştirir [69].

Konvolüsyon katmanları

Konvolüsyon katmanlarında giriş verisinin belirli bölgelerini tarayan ve bu bölgelerdeki özellikleri çıkaran filtreler (kernels) kullanılır. Bu işlem, bir giriş görüntüsünün farklı bölgelerindeki yerel özelliklerin yakalanmasını sağlar. Filtre, Şekil 2.10' da görüldüğü gibi giriş görüntüsü üzerinde kayan bir pencere gibi hareket eder ve her konumda konvolüsyonel çarpım işlemi gerçekleştirir. Filtrenin her pozisyonunda elde edilen sonuçlar, bir özellik haritası oluşturur. Birden fazla filtre kullanılarak birden fazla özellik haritası çıkarılabilir.



Şekil 2.10. Konvolüsyonel filtre örneği

Genellikle ReLU gibi doğrusal olmayan aktivasyon fonksiyonları, her bir özellik haritasındaki değerleri doğrusal olmayan bir dönüşüme tabi tutar. Matematiksel olarak, bir konvolüsyon işlemi Eş. 2.15' teki gibi ifade edilir [70].

$$(f * g)(t) = \int_{-\infty}^{\infty} f(\tau)g(t - \tau)d\tau \quad (2.15)$$

Bu eşitlik, f ve g fonksiyonlarının her bir t zaman noktasındaki örtüşmesini ifade eder. Farklı bir deyişle konvolüsyon, iki fonksiyonun çarpımı gibi düşünülebilir ve bu iki fonksiyonun kaydırılarak örtüşmesinin sonucunda yeni bir fonksiyon oluşturur.

Havuzlama katmanları

Havuzlama katmanları özellik haritalarının boyutunu azaltarak hesaplama maliyetini düşürür ve modelin genelleştirme kapasitesini artırır. İki yaygın havuzlama yönteminden maksimum havuzlama (max pooling) her bir alt bölgedeki en yüksek değeri seçerken, ortalama havuzlama (average pooling) her bir alt bölgedeki değerlerin ortalamasını alır. Havuzlama katmanları, genellikle 2x2 veya 3x3 boyutlu filtreler kullanarak giriş verisini küçültür. Örneğin, 2x2 maksimum havuzlama işlemi Eş. 2.16' daki gibi çalışır.

$$Y[i, j] = \max \begin{pmatrix} X[2i, 2j] & X[2i, 2j+1] \\ X[2i+1, 2j] & X[2i+1, 2j+1] \end{pmatrix} \quad (2.16)$$

2x2 maksimum havuzlama işlemi, giriş matrisi üzerinde 2x2 boyutunda bir pencere kaydırarak Eş. 2.16' daki gibi her pencere bölgesindeki maksimum değeri seçer. Bu işlem, veri boyutlarını küçültürken önemli özellikleri korur ve modeli küçük konum değişikliklerine karşı sağlam hale getirir.

Tam bağlantılı katmanlar

Tam bağlantılı katmanlar klasik YSA' lardaki nöron katmanlarına benzer [70]. Bu katmanlar, bir önceki katmandan gelen verileri düzleştirir ve her nöronun tüm giriş verileriyle bağlantılı olduğu bir yapı oluşturur. Başka bir deyişle bu katmanda, birçok kez konvolüsyon ile havuzlama katmanlarından geçen matris halindeki veriler düz bir vektör haline getirilir. Tam bağlantılı katmanlar, genellikle sınıflandırma işleminin gerçekleştirildiği son katmanlardır [70].

Transfer öğrenme modelleri

Transfer öğrenme, yapay zekâ alanında, bir görevde öğrenilen bilgilerin başka bir görevde transfer edilmesi sürecini ifade eder [71]. Bu yaklaşım, özellikle sınırlı veri setlerine sahip

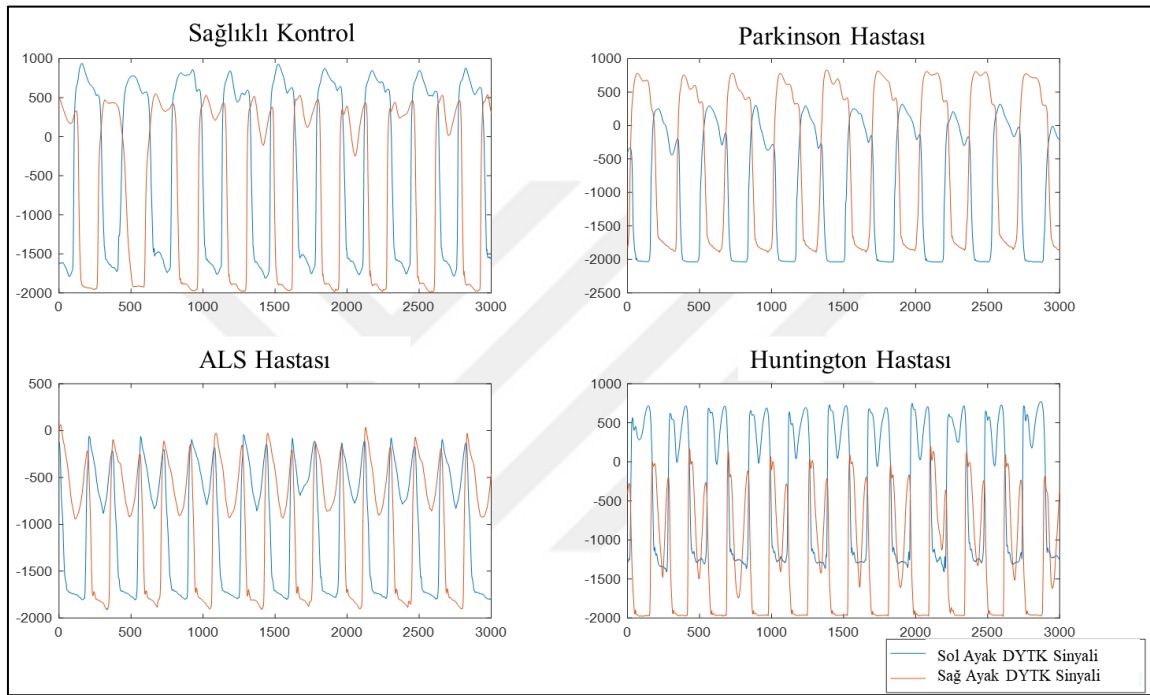
problemlerde önemli avantajlar sunar [71]. Transfer öğrenme, bir makine öğrenme modelinin, bir kaynak görevde eğitim alarak öğrendiği bilgi ve özellikleri, benzer veya ilişkili bir hedef göreve aktararak yeniden kullanmasıdır. Bu yaklaşım, özellikle geniş veri setlerinin elde edilmesinin zor veya maliyetli olduğu durumlarda büyük önem taşır. Transfer öğrenme, özellikle derin öğrenme modellerinde yaygın olarak kullanılır ve mevcut bilgi birikimini kullanarak daha hızlı ve etkili model eğitime olanak tanır. Transfer öğrenme sürecinde kullanılan modeller, genellikle önceden geniş veri setleri üzerinde eğitilmiş derin öğrenme modelleridir. Bu modeller, hedef görevde yeniden eğitilerek veya ince ayar (fine-tuning) yapılarak kullanılır. VGGNet, ResNet, Inception, MobileNet ve BERT gibi modeller, transfer öğrenme süreçlerinde yaygın olarak kullanılmaktadır [71]. Görüntü sınıflandırma görevlerinde yaygın olarak kullanılan VGGNet, derinliği ve basit yapısıyla bilinir. Özellikle, VGG16 ve VGG19 gibi versiyonları, transfer öğrenme süreçlerinde sıkça tercih edilir. Artık ağlar (ResNet), derin ağların eğitiminde karşılaşılan bozulma sorununu çözmek için artık bağlantılar kullanır. ResNet-50 ve ResNet-101 gibi modeller, transfer öğrenme için popüler seçeneklerdir. Inception mimarisi, paralel konvolüsyon katmanları ve farklı filtre boyutları kullanarak daha verimli özellik çıkarımı sağlar. Inception-v3, transfer öğrenme uygulamalarında sıkça kullanılır. Mobil cihazlar ve gömülü sistemler için optimize edilmiş olan MobileNet, düşük hesaplama gereksinimleriyle yüksek performans sunar. Bu model, sınırlı kaynaklara sahip sistemlerde transfer öğrenme için idealdir.

Transfer öğrenme süreci genellikle iki aşamadan oluşur: ön eğitim (pre-training) ve yeniden eğitim (fine-tuning). Ön eğitimde model, geniş ve genellikle genel amaçlı bir veri kümesi üzerinde eğitilir. Örneğin, bir VGGNet modeli, ImageNet gibi büyük bir görüntü veri kümesi üzerinde eğitilebilir. Yeniden eğitimde ise önceden eğitilmiş model, hedef görevin veri kümesi üzerinde yeniden eğitilir. Bu aşamada, modelin son katmanları genellikle hedef görevin gereksinimlerine göre yeniden yapılandırılır ve eğitilir.



3. DENEYSEL SONUÇLAR

Bu çalışmada NDH'lerin DYTK sinyalleri kullanılarak teşhis edilmesi amaçlanmaktadır. SK, PH, ALS ve HH gruplarına yönelik DYTK sinyalleri Şekil 3.1' de gösterilmektedir. Kullanılan yöntemlerin sonuçları makine öğrenmesine dayalı sonuçlar ve derin öğrenmeye dayalı sonuçlar olmak üzere 2 ana başlık altında incelenecektir.



Şekil 3.1. NDH ve SK gruplarının dikey yer tepki kuvveti (DYTK) sinyalleri

3.1. Makine Öğrenmesine Dayalı Sonuçlar

Yürüyüş sırasında DYTK sinyallerinden yararlanılarak, DFA' daki bir sinyal özelliğinin istatistiksel öz-yakınlığı kullanılarak hem sağ ayak hem de sol ayak içindeki ritmik aktiviteler ayrı ayrı belirlenmiştir. Sağ ve sol ayağın DYTK sinyalleri arasındaki benzerliği belirlemek için iki sinyal arasındaki benzerliği belirleme özelliğine sahip DTW özelliği kullanılmıştır. OK katsayıları, verilerdeki rastgeleliğin tespit edilmesi ve DYTK sinyallerinin mevcut ve geçmiş değerleri arasındaki ilişkinin ölçülmesi amacıyla tercih edilmiştir. Bu üç özellik grubunun ayrı ayrı ve özelliklerin birleştirilmesiyle NDH'lerin tanısındaki performansı değerlendirilmiştir.

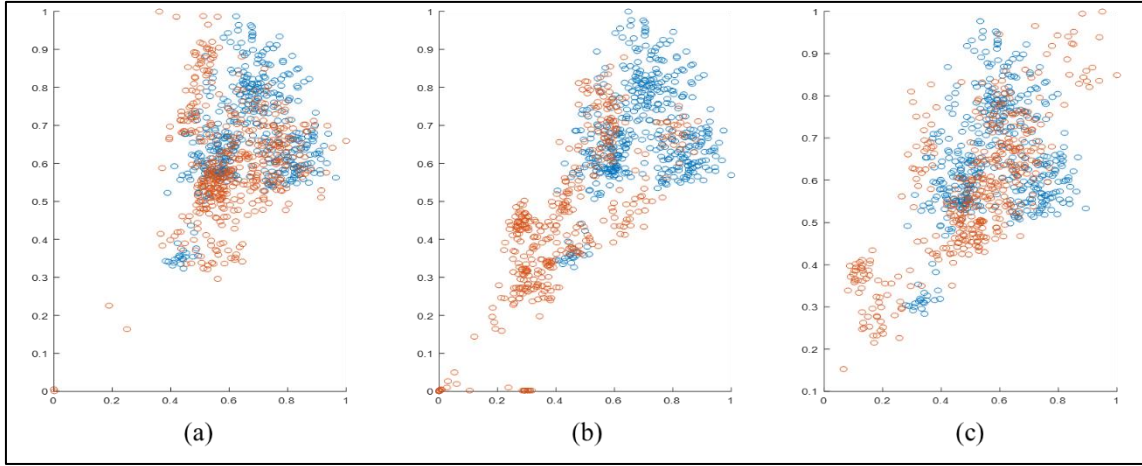
3.1.1. Hastalığa özgü özelliklerin belirlenmesi

DFA, NDH' lerin teşhisinde zaman alanı analizi yapmak için kullanılan bir özellik çıkarma yöntemidir. Sağ ve sol ayaktan kaydedilen DYTK sinyallerinden iki ayrı DFA katsayısı elde edilmiştir. DFA katsayılarının sınıflar arasında anlamlı bir ayırt edici özellik olup olmadığını belirlemek için iki yönlü ANOVA testi uygulanmıştır. Çift yönlü ANOVA testinde iki bağımsız değişkenin bir bağımlı değişkenle ilişkisi analiz edilmektedir. Bu analizde bağımsız değişkenlerin bağımlı değişkenlere tekil olarak etkilerinin yanı sıra birlikte etkilerinin de olup olmadığı da incelenebilmektedir. Bu yöntem, gruplar arasındaki farkların ve faktörlerin etkileşimlerinin istatistiksel olarak anlamlı olup olmadığını belirlemek için kullanılmaktadır. Buna göre, DYTK sinyallerinden hesaplanan DFA katsayılarının NDH' ler arasında farklılık gösterdiği görülmüştür ($F=306.0$, $p<.01$). Hastalıklar arasında DFA katsayılarının F değerleri ve anlamlılık düzeyleri Çizelge 3.1' de verilmiştir.

Çizelge 3.1. DFA katsayılarının F değerleri ve önem seviyeleri (** $p<0.5$, * $p<0.1$)


	ALS	HH	PH
SK	942.66*	81.52*	55.65*
ALS		384.24*	511.94*
HH			3.88**

Ayrıca NDH 'ler kümesine SK grubu da eklendiğinde DFA katsayılarının bu dört grup arasında anlamlı düzeyde farklılaştığı görülmektedir ($F=341.11$, $p<.01$). DFA katsayılarının SK ve ALS ($F=942.66$, $p<.01$), HH ($F=81.52$, $p<.01$) ve PH ($F=55.65$, $p<.01$) hastalıkları için her birinde anlamlı bir fark gösterdiği de görülmektedir. PH' ye karşı SK, ALS' ye karşı SK ve HH' ye karşı SK' ya ilişkin dağılım grafikleri sırasıyla Şekil 3.2' de gösterilmektedir. Şekil 3.2' de NDH' ler ve sağlıklı gruplara ait DFA katsayılarının dağılımları karşılaştırıldığında, ALS hastalarının verilerinin SK grubundan en iyi ayırt edilebildiği görülmektedir.



Şekil 3.2. DFA katsayılarının dağılım grafiği (a) PH-SK, (b) ALS-SK, (c) HH-SK (Kırmızı noktalar NDH' yi, mavi noktalar SK' yı temsil etmektedir.)

Bu çalışmada, DTW, sağ ve sol ayak sinyalleri arasındaki benzerliği belirlemek amacıyla kullanılmıştır. Şekil 3.3' te her bir durum için DTW kullanılarak belirlenen mesafe metrikleri gösterilmektedir. Şekil 3.3' te görüldüğü gibi DTW katsayıları NDH' ler ve SK' lar arasında farklılık göstermektedir.



Şekil 3.3. NDH' ler ve SK grubu DTW katsayıları arasında Kruskal Wallis test sonucu

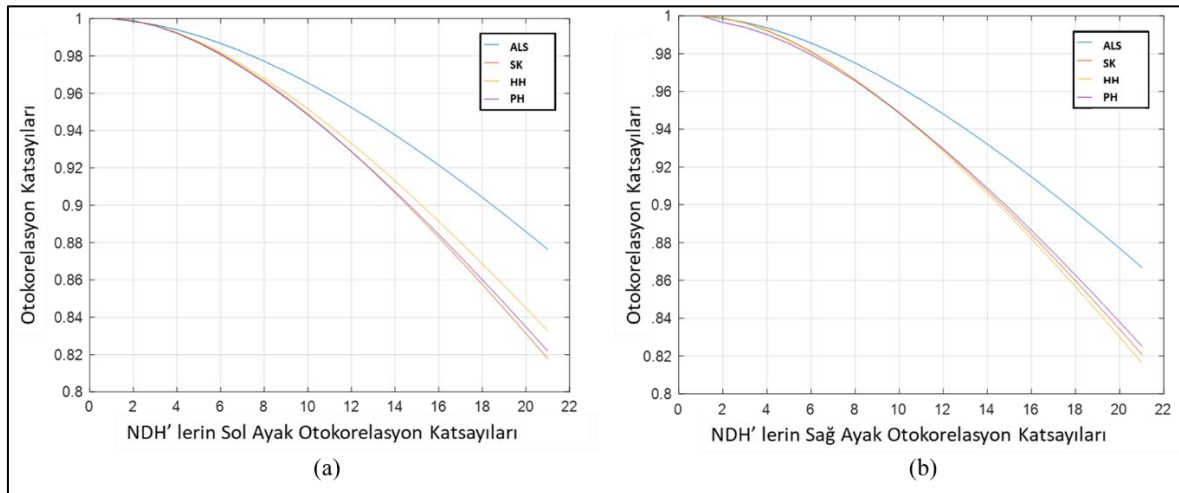
Sınıflar arasındaki DTW metriği farkının istatistiksel olarak anlamlı olup olmadığını değerlendirmek için Kruskal Wallis testi uygulandı. Kruskal Wallis testi iki ya da daha çok örneklem ortalamasının birbirinden anlamlı bir farklılık gösterip göstermediğinin test

edilmesinde kullanılmaktadır. Bu test, tek yönlü ANOVA analizinin parametrik olmayan karşılığıdır. Kruskal Wallis testi sonuçları, DWT metriğinin NDH sınıflandırması için istatistiksel olarak anlamlı bir parametre olduğuna işaret etmektedir. Hastalık sınıfları arasındaki ikili karşılaştırmalarda Mann-Whitney-U Testi de uygulanmaktadır. Bu test, benzer dağılımdan gelen iki bağımsız örneklemin arasındaki ortalama farkını incelemek ve örneklemeler arasında fark olup olmadığını belirlemek için kullanılmaktadır. DTW metriğinin hastalık sınıflarına göre ikili karşılaştırması Çizelge 3.2’ de verilmiştir. Buna göre DTW metriğinin tüm NDH’ ler ile SK grubu arasında istatistiksel olarak anlamlı bir özellik olduğu görülmektedir.

Çizelge 3.2. DTW katsayısının gruplar arası önemli seviyeleri

	HH	PH	SK
ALS	-20,4888 $\rho = 2,71e-93$	-15,5136 $\rho = 2,80e-54$	-12,3659 $\rho = 3,99e-35$
HH		-5.8929 $\rho = 3,79e-09$	6.8323 $\rho = 8,35e-12$
PH			7.0091 $\rho = 2,39e-12$

Bu çalışmada OK katsayıları DYTK sinyallerinin ardışık iki zaman aralığı arasındaki korelasyonun derecesini tanımlamaktadır. Şekil 3.4, (a) sol ve (b) sağ ayak için ortalama OK katsayılarını göstermektedir.




Şekil 3.4. (a) sol ayak ve (b) sağ ayak için NDH ve SK gruplarının ortalama otokorelasyon katsayıları

Şekil 3.4' e göre, OK tabanlı özellikler ALS için en yüksek değerlere sahiptir ve ALS' li denekler için en belirgin şekilde farklı olanlardır. Aksine, PH' li hastalar için OK temelli özelliklerin en düşük değerlere sahip olduğu görülmektedir.


3.1.2. İkili sınıflandırma sonuçları

Bu çalışmada ikili sınıflandırma iki alt deneyden oluşmaktadır. İlk deneyde NDH' lerin ve sağlıklı kontrol grubunun sınıflandırılmasına odaklanılmıştır. İkinci deneyde her hastalık grubunun (ALS, HH ve PH), SK grubundan ayırma performansı ayrı ayrı değerlendirilmiştir. Şekil 3.5' te her bir özellik seti için doğruluk oranları ve NDH' lerin SK gruplarına karşı karmaşıklık matrisi verilmiştir. Sonuçlara göre özellikler tek tek kullanıldığında en yüksek başarı oranı %91,4 ile OK tabanlı özelliklerde elde edilirken, tüm özelliklerin bir arada kullanılmasıyla %98,9 doğruluk oranına ulaşılmıştır. DTW tabanlı özelliğin tek başına NDH' nin varlığını teşhis etme kapasitesine sahip olmadığı gözlemlenmiştir.



Şekil 3.5. NDH-SK grupları ikili sınıflandırma sonuçları (a) her bir özellik ve sınıflandırıcı için sınıflandırma doğrulukları (b) karmaşıklık matrisi

Şekil 3.6' da her hastalık için ayrı ayrı özellikler ve özellik kombinasyonlarının doğruluk oranları verilmektedir. Doğruluk oranları genel olarak daha yüksek performansa sahip olan DVM sınıflandırıcısı üzerinden değerlendirilmiştir.



Şekil 3.6. Özellikler ve özellik kombinasyonları için doğruluk oranları


Şekil 3.6' ya göre DFA katsayıları ALS, PH ve HH hastalıklarının sırasıyla %92,9, %75,4 ve %81,9 doğrulukla tespit edilmesini sağlamıştır. ALS tanısı koymada DFA katsayılarının önemli bir ayırt ediciliğe sahip olduğu söylenebilir. Öte yandan DTW özelliğinin tek başına kullanıldığında NDH' leri tespit etme performansı sınırlı kalmaktadır. DTW, ALS için %65,4, HH için %67,1 ve PH tanısı için en yüksek performans olan %69,1'e ulaştığı görülmektedir. Ancak DTW' nin DFA ve AC ile birleştirildiğinde, NDH' leri tespit etme doğruluğunu önemli ölçüde arttırdığı görülmektedir. DFA katsayıları DTW ile birleştirildiğinde sınıflandırma doğruluğu ALS için %98,2'ye, PH için %87,5'e, HH için %95,7' ye çıkmıştır. Bu özellik kombinasyonu özellikle HH teşhisinde önemli bir artış sağlamıştır.

Öte yandan DTW, OK ile birleştirildiğinde PH tanısında %94,8'e varan doğruluk oranlarına ulaşabildiği görülmüştür. OK katsayılarının NDH tanısındaki performansı incelendiğinde ise OK katsayılarının tek başına ALS, PH ve HH hastalıklarını sırasıyla %93,6, %84,9 ve %92,4 doğrulukla tespit edebildiği görülmektedir. OK özellikleri ayrı ayrı kullanıldığında HH teşhisinde DFA ve DTW' den daha yüksek doğruluk oranları sağlamıştır.

Tüm özelliklerin etkilerini tek tek inceledikten sonra tüm özellikler bir araya getirilerek ve

özellik seçme algoritması kullanılarak performans değerlendirilmiştir. NDH tanısı koymak için DFA, DTW ve OK birlikte kullanılarak oluşturulan özellik vektörü kullanıldığında ALS, PH ve HH için sırasıyla %98,8, %97,4 ve %98 doğruluk oranlarına ulaşılmıştır. Sonuçlara göre tüm özelliklerin bir arada kullanılmasının özellikle PH (%97,4) için doğruluk oranını önemli ölçüde artırdığı söylenebilir.

Şekil 3.7’ de görüldüğü gibi üç farklı sınıflandırma yöntemi kullanılarak yapılan deneylerde doğruluk oranları her bir özellik ve özellik kombinasyonları için birbirine yakındır. Bu grafik, her bir özellik ve özellik kombinasyonunun sınıflandırma yönteminden bağımsız olarak NDH’ lerdeki ayırt ediciliğe etkisini göstermektedir. Aynı özellik kullanılıp, farklı sınıflandırma yöntemleri kullanılarak sınıflandırma yapıldığında birbirine yakın doğruluk oranları elde edilmektedir.

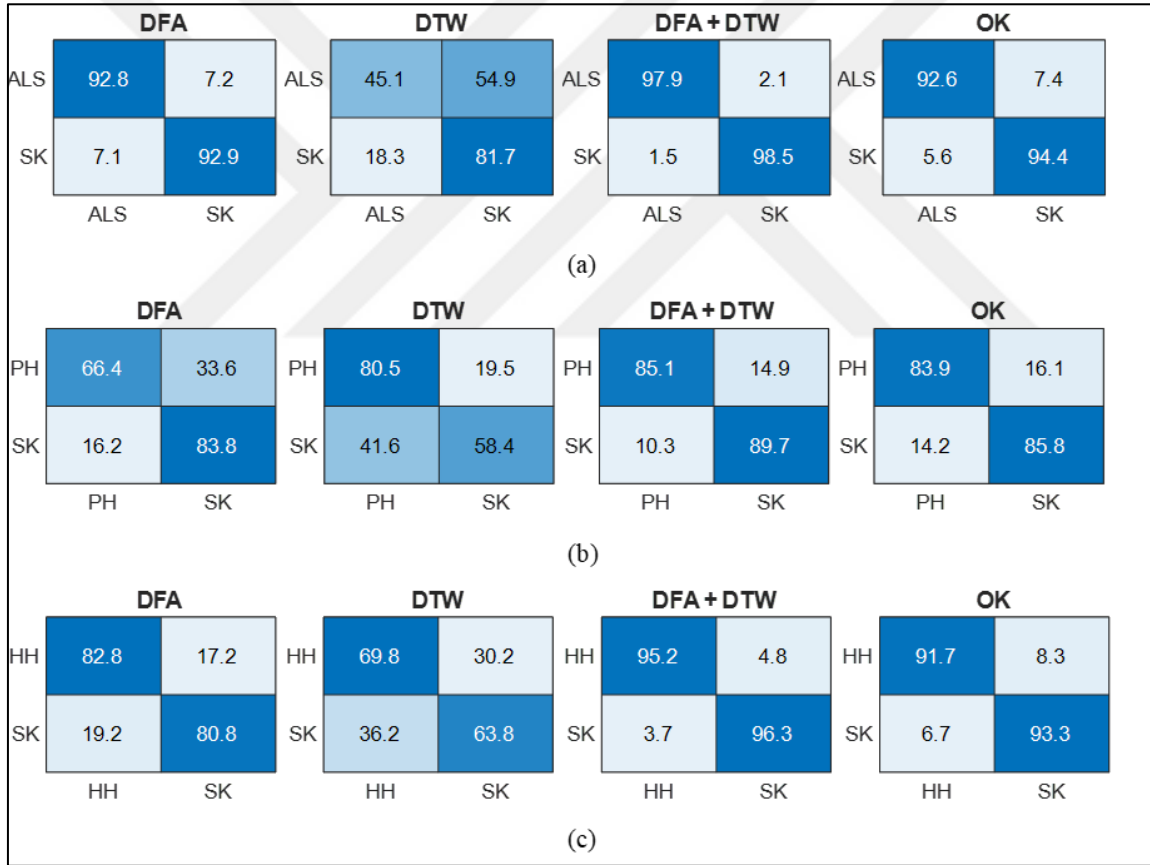


Şekil 3.7. Sınıflandırıcılar için doğruluk oranları

Son olarak özellik seçiminin doğruluk oranlarına etkisini incelendiğinde, bu aşamada özellik seçme yöntemi olarak filtre tabanlı özellik seçme tekniği olan Relief algoritması kullanılmıştır. DFA ve DTW özelliklerinin tüm NDH hastalıkları için seçilen özellikler

arasında yer aldığını belirtmek gerekir. Özellik seçimi ile yapılan sınıflandırma sonuçları değerlendirildiğinde ALS, PH ve HH için %99,3, %97,3 ve %98,2 doğruluk oranlarına ulaşıldığı görülmektedir. Sonuçlara göre özellik seçiminin ALS ve HH teşhisinde başarıyı arttırdığı söylenebilir. Her ne kadar PH için tüm özniteliklerin kullanılmasına eşit bir doğruluk oranı sağlasa da seçilen özniteliklerin kullanılmasının sınıflandırıcı karmaşıklığı ve işlem maliyetleri üzerindeki etkileri dikkate alındığında öznitelik seçiminin PH tanısı için de etkili olduğu söylenebilir.

Şekil 3.8.a-c' de sırasıyla ALS, PH ve HH için DFA, DTW, DFA-DTW kombinasyonu ve OK tabanlı özellikler için karmaşıklık matrisleri verilmiştir.



Şekil 3.8. (a) ALS, (b) PH, (c) HH için DFA, DTW, DFA+DTW ve OK tabanlı özelliklerin karmaşıklık matrisleri


Şekil 3.8' e göre NDH' lerin ve SK sınıflarının doğruluk oranları özellikle ALS ve HH için dengelidir. DFA ve DTW kombinasyonunun, her iki özelliğin ayrı ayrı kullanılmasından daha iyi performans gösterdiği görüldü. Özellik kombinasyonunun etkisi en açık şekilde PH' nin sonuçlarında görülmektedir. DFA kullanılması durumunda sınıf doğrulukları

arasında bir dengesizlik vardır, yani SK %83,8 doğrulukla sınıflandırılırken PH %66,4 doğrulukla sınıflandırılır. Ancak DFA katsayıları DTW ile birleştirildiğinde her iki sınıfın doğruluk oranları dengelendiği görülmektedir (SK ve PH için %89,7 ve %85,1).

3.1.3. Çoklu sınıflandırma sonuçları

Gerçek hayat senaryolarına göre tedavilerin uygun şekilde planlanabilmesi için hastaların hangi NDH' ye sahip olduğunun belirlenmesi önemlidir. Bu nedenle klinik uygulamalara daha yakın bir karar destek sistemi geliştirmek için çok sınıflı NDH sınıflandırmasının ele alınması gerekmektedir. Bu çalışmada çok sınıflı sınıflandırma problemini iki açıdan ele alınmıştır. İlk olarak üç sınıflı bir sınıflandırma ile tüm NDH hastalarını içeren bir gruptan PH, ALS ve HH hastalarını ayırmış, sonrasında dört sınıflı bir sınıflandırma ile, NDH' ler arasına SK grubunu da ekleyerek katılımcıları ALS, PH ve HH hastaları ile birlikte SK gruplarına sınıflandırılmıştır.

Şekil 3.9' da her bir özellik ve özellik kombinasyonunun sınıflandırma performansları hem üç hem de dört sınıflı durumlar için karşılaştırmalı olarak verilmektedir. Üç sınıflı durum için DFA, DTW ve OK katsayıları kullanılarak sırasıyla %73,1, %56,9 ve %74,3 doğruluklara ulaşıldığı görülmektedir. OK katsayıları, her üç hastalık türü için diğer özelliklere göre daha üstün doğruluk sağladı. İkili sınıflandırmaya benzer şekilde, DFA katsayıları ve DTW kombinasyonunun, OK katsayılarıyla (%86,2) elde edilen sonuçlardan daha iyi performans gösterdiği görülmektedir.

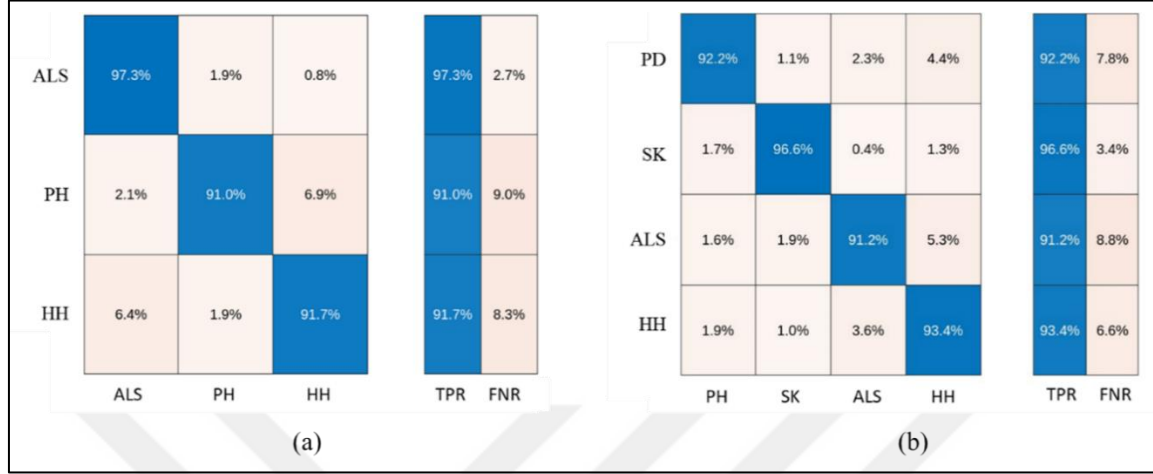


Şekil 3.9. Üç sınıflı (ALS-PH-HH) ve dört sınıflı (ALS-PH-HH ve SK) durumlar için her özellik ve özellik kombinasyonu için sınıflandırıcıların doğruluk oranları

Tüm özellikler bir arada kullanıldığında doğruluk oranı %93,3 olarak belirlenmiş ancak özellik seçimi yapılması durumunda bu oranın %93,4'e çıktığı görülmektedir. Öznitelik seçiminin doğruluk oranları üzerinde önemli bir etkisi olmasa da sınıflandırıcı karmaşıklığı ve işlem maliyetleri açısından etkili olacağı düşünülmektedir. Dört sınıflı durum dikkate alındığında doğruluk oranları DFA, DTW ve OK için sırasıyla %64,4, %45,2 ve %67,2'dir. Sonuçlara göre özelliklerin tek tek doğruluk oranları üzerinde üç sınıflı durumla aynı etkiye sahip olduğu söylenebilir; ancak doğruluk oranları üç sınıflı duruma göre önemli ölçüde daha düşüktür. Ancak tüm özelliklerin bir arada kullanılması durumunda üç sınıflı durumdakiyle hemen hemen aynı doğruluk oranlarına (%93,2) ulaşılması sağlanmıştır. Farklı NDH'leri ayırt etmek için etkisi yüksek özellik kombinasyonlarının kullanılmasının özellikle çok sınıflı sınıflandırma problemlerinde sınıflandırma başarısını arttırdığı söylenebilir.

Şekil 3.10' da çok sınıflı sınıflandırma durumlarına ilişkin karmaşıklık matrisleri görülmektedir. Üç sınıflı olguda ise üç hastalık arasında ALS, PH ve HH hastalıklarının doğru tanı oranları sırasıyla %97,3, %91 ve %91,7 olarak belirlendi. Dört sınıflı olguda SK olguları dört sınıf arasında en yüksek doğruluk oranıyla (%96,6) belirlenirken, ALS, PH ve HH tanı oranları sırasıyla %92,2, %91,2 ve %93,4 oldu. PH'ye yanlışlıkla HH tanısı konma oranı %6,9 iken, HH hastalarına %6,4 oranında ALS tanısı konuldu. Üç sınıflı

vakada PH ile HH ve HH ile ALS hastalıkları arasındaki bu hata oranlarının dört sınıflı vakada da gözlemlendiği görülmektedir.



Şekil 3.10. (a) Üç sınıflı (ALS - PH - HH), (b) dört sınıflı (ALS - PH - HH - SK) vakalar için karmaşıklık matrisleri

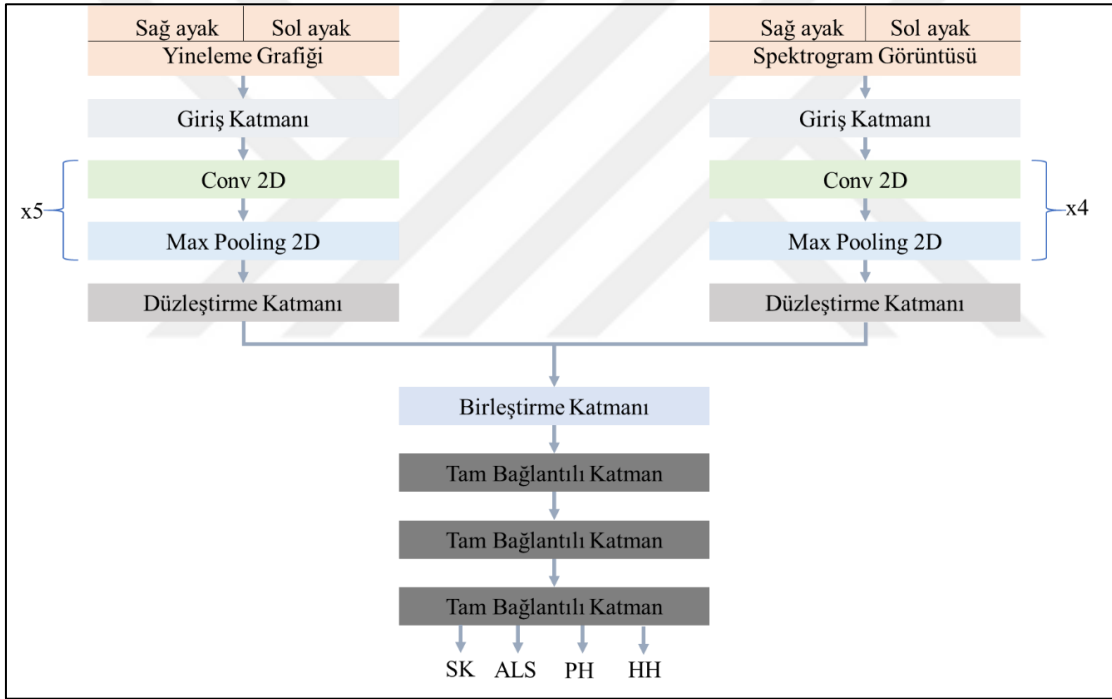
3.2. Derin Öğrenmeye Dayalı Sonuçlar

Bu çalışmada, derin öğrenme tekniklerine dayalı sonuçlar, özgün CNN mimarisi sonuçları ve transfer öğrenme mimarisi sonuçları olarak 2 ayrı başlık altında incelenecektir.

3.2.1. Önerilen CNN mimarisi sonuçları

Şekil 3.11' de bu çalışmada kullanılan hibrit konvolüsyonel sinir ağı mimarisi görülmektedir. Giriş verileri konvolüsyonel sinir ağlarına verilirken, aynı deneğin aynı örneğinin yinleme grafiği ve spektrogram görüntülerinin aynı anda verilmesi sağlanmıştır. Yinleme grafikleri 5 adet konvolüsyon-havuzlama katmanı bulunan konvolüsyonel sinir ağına girdi olarak verilirken, spektrogram görüntüleri 4 adet konvolüsyon-havuzlama katmanı bulunan konvolüsyonel sinir ağına girdi olarak verilmiştir. Bunun sebebi; oluşturulan yinleme grafikleri 300x150 boyutundayken, spektrogram görüntüleri 300x40 boyutundadır, yani yinleme grafiği görüntülerinin boyutları spektrogram görüntülerine göre daha büyüktür. Bu sebeple yinleme grafiği görüntüleri, 5 katmanlı konvolüsyonel sinir ağından, spektrogram görüntüleri ise 4 katmanlı konvolüsyonel sinir ağından geçirilerek boyutları yeteri kadar küçültülmüştür. Daha fazla havuzlama katmanı kullanılarak görüntü boyutları iyice küçültüldüğünde ise görüntü çözünürlüğü çok fazla

düştüğü için otomatik özellik çıkarımı anlamlı şekilde gerçekleşmemektedir. Farklı konvolüsyon ve havuzlama katmanlarından geçirilen yineleme grafiği ve spektrogram görüntülerinin matris halindeki son formları, düzleştirme katmanlarından geçirilerek düz bir vektör haline getirilmiştir. Ardından düzleştirilen vektörler birleştirme katmanında birleştirilerek hibrit yapı oluşturulmuştur. Birleştirme katmanından sonra 3 adet tam bağlantılı katman kullanılmıştır. Bu tam bağlantılı katmanlardan ilk ikisi, boyutu 3.424 olan birleştirme katmanını küçültmek için kullanılmıştır. Üçüncü tam bağlantılı katmanda ise sınıf sayısı olan 4 adet düğüm bulunmaktadır. Bu katman, bir önceki tam bağlantılı katmandan gelen ve boyutu 64 olan düz bir vektörün boyutunu 4' e düşürerek çıkış katmanı görevi görmüştür.



Şekil 3.11. Derin öğrenme hibrit CNN mimarisi

Çizelge 3.3' te görüldüğü gibi, boyutu 300x150 olan yineleme grafiği görüntüleri giriş katmanından geçirildikten sonra, boyutu 3x3 olan 128 adet filtre kullanılarak konvolüsyon katmanından geçirilmiştir. Ardından boyutu 2x2 olan filtreler kullanılarak maksimum havuzlama işlemi gerçekleştirilmiştir. Bu aşamalar, konvolüsyon katmanındaki filtre sayısı sırasıyla 64' e, ardından 32' ye düşürülerek tekrarlanmıştır. Konvolüsyon katmanlarında ileri besleme aşamasında linear aktivasyon fonksiyonu, geri besleme aşamasında ikili sınıflandırma için "binary-crossentropy" kayıp fonksiyonu, çoklu sınıflandırma için

“categorical-crossentropy” kayıp fonksiyonu kullanılmıştır. Yineleme grafiği görüntülerinin eğitildiği konvolüsyon katmanı 5 adet olduğu için toplam parametre sayısı 139.712’ dir.

Çizelge 3.3. Yineleme grafiği görüntülerinin eğitildiği CNN mimarisi

Katman	Filtre sayısı	Filtre boyutu	Aktivasyon fonksiyonu	Çıkış boyutu	Parametre sayısı
Giriş	-	-	-	300x150x1	0
Konvolüsyon	128	3x3	linear	300x150x128	1280
Maksimum havuzlama	-	2x2	-	150x75x128	0
Konvolüsyon	64	3x3	linear	150x75x64	73792
Maksimum havuzlama	-	2x2	-	75x38x64	0
Konvolüsyon	64	3x3	linear	75x38x64	36928
Maksimum havuzlama	-	2x2	-	38x19x64	0
Konvolüsyon	32	3x3	linear	38x19x64	18464
Maksimum havuzlama	-	2x2	-	19x10x32	0
Konvolüsyon	32	3x3	linear	19x10x32	9248
Maksimum havuzlama	-	2x2	-	10x5x32	0
Düzleştirme	-	-	-	1600	0

Çizelge 3.4’ te görüldüğü gibi, boyutu 300x40 olan spektrogram görüntüleri de aynı şekilde giriş katmanından geçirildikten sonra, boyutu 3x3 olan 128 adet filtre kullanılarak konvolüsyon katmanından geçirilmiştir. Ardından boyutu 2x2 olan filtreler kullanılarak maksimum havuzlama işlemi gerçekleştirilmiştir. Bu aşamalar, konvolüsyon katmanındaki filtre sayısı sırasıyla 64’ e, ardından 32’ ye düşürülerek tekrarlanmıştır. Fakat yineleme grafiği görüntüleri 32 adet 3x3 filtre bulunduran konvolüsyon katmanından ve ardındaki havuzlama katmanından iki kez geçerken, spektrogram görüntüleri bir kez geçirilmiştir. Bunun sebebi, boyutu zaten küçük olan spektrogram görüntülerinin boyutunun daha fazla küçültülmesine ihtiyaç duyulmamasıdır. Aynı şekilde spektrogram görüntüleri için de konvolüsyon katmanlarında ileri besleme aşamasında linear aktivasyon fonksiyonu, geri besleme aşamasında ikili sınıflandırma için “binary-crossentropy” kayıp fonksiyonu, çoklu sınıflandırma için “categorical-crossentropy” kayıp fonksiyonu kullanılmıştır. Spektrogram görüntüleri ise 4 adet konvolüsyon ve havuzlama katmanından geçirildiği için toplam parametre sayısı 130.464’ tür.

Çizelge 3.4. Spektrogram görüntülerinin eğitildiği CNN mimarisi

Katman	Filtre sayısı	Filtre boyutu	Aktivasyon fonksiyonu	Çıkış boyutu	Parametre sayısı
Giriş	-	-	-	300x40x1	0
Konvolüsyon	128	3x3	linear	300x40x128	1280
Maksimum havuzlama	-	2x2	-	150x20x128	0
Konvolüsyon	64	3x3	linear	150x20x64	73792
Maksimum havuzlama	-	2x2	-	75x10x64	0
Konvolüsyon	64	3x3	linear	75x10x64	36928
Maksimum havuzlama	-	2x2	-	38x5x64	0
Konvolüsyon	32	3x3	linear	38x5x32	18464
Maksimum havuzlama	-	2x2	-	19x3x32	0
Düzleştirme	-	-	-	1824	0

Çizelge 3.5’ te görüldüğü gibi, düzleştirme katmanlarından gelen veriler birleştirme katmanında birleştirildikten sonra düz vektörün boyutu 3424’ ten 64’ e düşürülmüştür. Çıkış katmanında linear aktivasyonu yerine, daha iyi performans sağladığı bilinen softmax aktivasyonu kullanılmıştır. Ağırlıkların güncellenmesinde kullanılan optimizer ise “Adam optimizer” olarak seçilmiştir. Hibrit modelin sonucunda toplam parametre sayısı 493.796’ ya ulaşmıştır.

Çizelge 3.5. Yineleme grafiği ve spektrogram görüntülerinin birlikte kullanıldığı hibrit CNN mimarisi

Katman	Aktivasyon fonksiyonu	Çıkış boyutu	Parametre sayısı
Birleştirme	-	3424	0
Tam bağlantılı	linear	64	219200
Tam bağlantılı	linear	64	4160
Tam bağlantılı	softmax	4	260

Şekil 3.11’ de önerilen CNN mimarisi ile yapılan deneyler için Çizelge 3.6’ da görülen hiperparametreler uygulanmıştır. Gerçekleştirilen deneylerin sonuçları Çizelge 3.7’ de ve Çizelge 3.8’ de sunulmuştur.

Çizelge 3.6. Önerilen hibrit CNN mimarisinde kullanılan hiperparametre değerleri

Hiperparametreler	İkili sınıflandırmalar	Çoklu sınıflandırmalar
Epoch	30 veya 100	
Batch size	16	
Öğrenme oranı	0,001	
Kayıp Fonksiyonu	Binary crossentropy	Categorical crossentropy
Optimize edici	Adam	

Pencere boyutunun ve örnek sayısının doğruluk üzerindeki etkisini görmek için yineleme grafiği ve spektrogram görüntülerinin hibrit olarak kullanıldığı mimari 10 sn ve 5 sn' lik pencere boyutlarındaki örneklerle eğitilmiştir. Çizelge 3.7' de görüldüğü gibi dörtlü sınıflandırmada 10 sn' lik pencere boyutunda %94,62 doğruluk oranı elde edilirken, 5 sn' lik pencere boyutunda %94,47 doğruluk oranı elde edilmiştir.

Çizelge 3.7. Önerilen hibrit CNN mimarisi farklı pencere boyutlarındaki ikili ve çoklu sınıflandırma sonuçları

Sınıf Grubu	Yöntem	Pencere Boyutu (sn)	Epoch Sayısı	Eğitim Doğruluğu (%)	Validasyon Doğruluğu (%)
ALS – SK	Yineleme grafiği ve spektrogram hibrit	10 (Şekil 2.2)	30	99,55	98,81
HH – SK				99,88	96,17
PH – SK				99,72	97,22
ALS – PH – HH – SK				99,19	94,62
ALS – SK		5 (Şekil 2.3)		100	99,63
HH – SK				99,23	97,71
PH – SK				98,70	96,93
ALS – PH – HH – SK				98,77	94,47

ALS-SK ve HH-SK ikili sınıflandırma sonuçlarında 5 sn' lik pencere ile yapılan deneylerin sonuçları 10 sn' lik pencere ile yapılan deneylere göre daha yüksek olurken, PH-SK sınıflandırmasında 10 sn' lik pencere ile yapılan deneyin 5 sn' lik pencere ile yapılan deneye göre daha yüksek sonuç elde edildiği görülmüştür. Dörtlü ve ikili sınıflandırma sonuçlarının tümü göz önüne alındığında doğruluk oranları arasındaki farkların ortalama olarak %1 seviyesinde olduğu görülmüştür. Sonuç olarak pencere boyutundaki değişikliklerin doğruluk oranlarına çok büyük bir etkisi olmadığı gözlemlenmiştir. Yine de pencere boyutu küçültüldükçe veri sayısı arttığı için ve konvolüsyonel sinir ağlarında veri

sayısının fazla olması pozitif etki oluşturduğu için derin öğrenmede gerçekleştirilen diğer deneylerde 5 sn' lik pencere boyutundaki veriler kullanılmıştır.

Hibrit mimarinin doğruluk oranı üzerindeki etkisini görmek için, yineleme grafiği ve spektrogram görüntüleri ayrı ayrı ve hibrit mimariler ile sınıflandırılmıştır. Bu deneylerde epoch parametresi 100 olarak seçilmiştir, diğer hiperparametreler için Çizelge 3.6' te görülen değerler kullanılmıştır. İkili ve dörtlü sınıflandırma deneyleri sadece yineleme grafiği, sadece spektrogram görüntüleri ve yineleme grafiği – spektrogram görüntüleri hibrit mimari olmak üzere 3 ayrı kategoride gerçekleştirilmiş ve sonuçları Çizelge 3.8' de sunulmuştur.

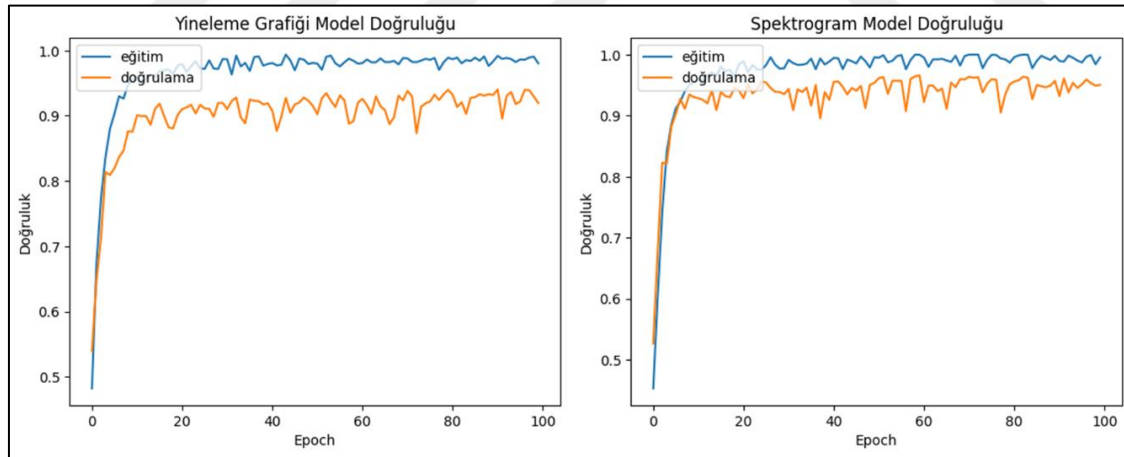
Çizelge 3.8. Önerilen hibrit CNN mimarisi ile hibrit olmayan CNN mimarilerinin ikili ve çoklu sınıflandırma sonuçları

Sınıf Grubu	Yöntem	Pencere Boyutu (sn)	Epoch Sayısı	Eğitim Doğruluğu (%)	Validasyon Doğruluğu (%)
ALS – SK	Yineleme grafiği	5 (Şekil 2.6)	100	100	98,76
HH – SK				100	97,52
PH – SK				100	99,19
ALS – PH – HH – SK				97,68	94,19
ALS – SK	Spektrogram			100	99,75
HH – SK				100	97,42
PH – SK				100	98,73
ALS – PH – HH – SK				97,40	95,75
ALS – SK	Yineleme grafiği ve spektrogram hibrit			100	99,63
HH – SK				99,23	97,71
PH – SK				98,70	96,93
ALS – PH – HH – SK				98,88	96,15

Dörtlü sınıflandırmada yineleme grafiğinin kullanıldığı deneyde %94,19 ve spektrogram görüntülerinin kullanıldığı deneyde %95,75 doğruluk oranına ulaşılırken, hibrit mimarinin %96,15 doğruluk oranı ile en başarılı sonucu verdiği görülmüştür. Bunun yanı sıra, ALS – SK ikili sınıflandırmasında en yüksek doğruluk oranına (%99,75) spektrogram görüntü verileriyle, HH – SK ikili sınıflandırmasında en yüksek doğruluk oranına (%97,71) hibrit mimari ile, PH – SK ikili sınıflandırmasında ise en yüksek doğruluk oranına (%99,19) yineleme grafiği verileriyle ulaşılmıştır. Çizelge 3.8' de görüldüğü gibi hibrit olmayan mimarilerde ikili sınıflandırmalar ile dörtlü sınıflandırma arasındaki doğruluk oranı farkı,

hibrit mimariye göre daha yüksek olmuştur. Yineleme grafiği verilerinin kullanıldığı deneyde ikili sınıflandırma deneylerinin ortalama doğruluk oranının %98,49 olduğu ve dörtlü sınıflandırma sonucu (%94,19) ile farkın %4,3 olduğu görülmüştür. Hibrit mimaride ise ikili sınıflandırma sonuçlarının ortalamasının %98.09 olduğu ve dörtlü sınıflandırma sonucu (%96,15) ile farkın %1,94 olduğu görülmüştür. Aynı hesaplamalar spektrogram görüntü verileri ile yapılan deney sonuçlarına uygulandığında da benzer bir durum olduğu görülmektedir. Sınıf sayısı arttıkça hibrit mimarinin, hibrit olmayan mimarilere göre daha kararlı sonuçlar üretmeye başladığı gözlemlenmiştir.

Şekil 3.12’ de yineleme grafiği ve spektrogram görüntüleri kullanılarak önerilen CNN mimarilerinde gerçekleştirilen dörtlü sınıflandırmaların doğruluk grafikleri görülmektedir. Şekil 3.12’ ye bakıldığında hem yineleme grafiği görüntülerinin hem de spektrogram görüntülerinin eğitim ve doğrulama doğruluğunun birbirine tutarlı şekilde ilerlediği görülmektedir. Bu durum eğitim sırasında herhangi bir ezberleme olmadığını göstermektedir. Eğitim sırasında aşırı öğrenme (overfitting) durumu olmadığı için, herhangi bir sönümleme (dropout) mekanizması kullanılmamıştır.



Şekil 3.12. Yineleme grafiği ve spektrogram görüntülerinin eğitildiği CNN mimarilerinin doğruluk grafikleri

Şekil 3.13’ te ise spektrogram görüntüleri ve yineleme grafiği görüntüleri kullanılarak önerilen CNN mimarilerinde gerçekleştirilen dörtlü sınıflandırmalar ile yineleme grafiği ve spektrogram görüntülerinin birlikte kullanıldığı önerilen hibrit CNN mimarisinde gerçekleştirilen dörtlü sınıflandırmanın karmaşıklık matrisleri bulunmaktadır.

Spektrogram (%)					Yineleme Grafiği (%)				
ALS	98.1	0	0.8	1.1	ALS	94.5	1.9	1.7	1.9
SK	0	96.8	2.3	0.9	SK	0.2	95.9	3.2	0.7
HH	1.1	0.2	95.9	2.8	HH	1.7	2	90.8	5.5
PH	2	0.2	1.7	96.1	PH	0.5	3.5	1.3	94.7
	ALS	SK	HH	PH		ALS	SK	HH	PH

Spektrogram-Yineleme Grafiği Hibrit Model (%)				
ALS	98.2	0.3	1.2	0.3
SK	0.2	97.8	1.1	0.9
HH	0.7	2.1	96.1	1.1
PH	0.5	0.7	3	95.8
	ALS	SK	HH	PH

Şekil 3.13. Yineleme grafiği ve spektrogram görüntülerinin eğitildiği CNN mimarileri ile hibrit CNN mimarisinin karmaşıklık matrisleri

Spektrogram görüntüleri kullanılarak gerçekleştirilen dörtlü sınıflandırmada en yüksek ALS' li (%98,1) bireyler ayırt edilmiştir. Bu durum spektrogram görüntülerinin ALS' li bireylerde daha fazla ayırt ediciliğe sahip olduğunu göstermektedir. Çizelge 3.8' de de görüleceği gibi ALS-SK sınıflandırmasının doğruluk oranı (%99,75) diğer ikili sınıflandırmalara göre daha yüksektir.

Yineleme grafiği görüntüleri kullanılarak gerçekleştirilen dörtlü sınıflandırmada ise hasta grupları arasında en yüksek PH' li (%94,7) bireyler ayırt edilmiştir. Bu durum yineleme grafiği görüntülerinin PH' li bireylerde daha fazla ayırt ediciliğe sahip olduğunu göstermektedir. Çizelge 3.8' de de görüleceği gibi PH-SK sınıflandırmasının doğruluk oranı (%99,19) diğer ikili sınıflandırmalara göre daha yüksektir.

Yineleme grafiği ve spektrogram görüntülerinin birlikte kullanıldığı hibrit CNN mimarisinin karmaşıklık matrisine bakıldığında, ALS' li (%98,2) bireylerin diğer gruplara göre daha fazla ayırt edildiği görülmektedir. Çizelge 3.8' de de görüleceği gibi hibrit

modeldeki ALS-SK sınıflandırmasının doğruluk oranı (%99,63) diğer ikili sınıflandırmalara göre daha yüksektir.

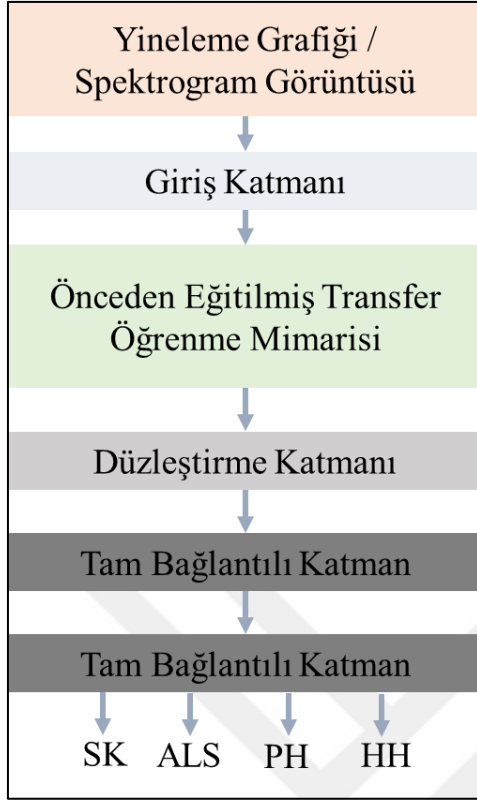
3.2.2. Transfer öğrenme sonuçları

Bu çalışmada VGG16, VGG19, Inception V3, Xception ve MobileNet transfer öğrenme modelleri kullanılmıştır. Bu çalışmada kullanılan transfer öğrenme mimarilerinin özellikleri Çizelge 3.9’ da bulunmaktadır.

Çizelge 3.9. Bu çalışmada kullanılan transfer öğrenme mimarilerinin özellikleri

Model	Orjinal giriş boyutu	Katman sayısı	Parametre sayısı
VGG16	224x224x3	16	~138 Milyon
VGG19	224x224x3	19	~143 Milyon
Inception V3	299x299x3	48	~24 Milyon
Xception	299x299x3	71	~23 Milyon
MobileNet	224x224x3	28	~4 Milyon

Çalışmada kullanılan transfer öğrenme yönteminin blok diyagramı Şekil 3.14’ te verilmiştir. Şekil 3.14’ te görülen mimaride önceden eğitilmiş VGG16, VGG19, Inception V3, Xception ve MobileNet modelleri kullanılmıştır. Transfer öğrenme modeli olarak kullanılan mimariler “imagenet” veri kümesi ile önceden eğitilmiştir. Önceden eğitilmiş transfer öğrenme modellerinin giriş katmanları, çalışmada kullanılan yineleme grafiği ve spektrogram görüntülerinin boyutlarına göre güncellenmiştir. İkili sınıflandırmalar için çıkış katmanlarının boyutu 2; dörtlü sınıflandırmalar için çıkış katmanlarının boyutu 4 olarak güncellenmiştir.



Şekil 3.14. Yineleme grafiği veya spektrogram görüntüsü ile oluşturulan veri kümesinin kullanıldığı transfer öğrenme sinir ağı mimarisi

Tüm transfer öğrenme deneylerinde kullanılan hiperparametreler Çizelge 3.10' daki gibidir. Transfer öğrenmede en iyi sonuçlara VGG16 modelinde ulaşılmıştır.

Çizelge 3.10. Transfer öğrenme mimarisinde kullanılan hiperparametre değerleri

Hiperparametreler	İkili sınıflandırmalar	Çoklu sınıflandırmalar
Epoch	100	
Batch size	16	
Öğrenme oranı	0,001	
Kayıp Fonksiyonu	Binary crossentropy	Categorical crossentropy
Optimize edici	Adam	

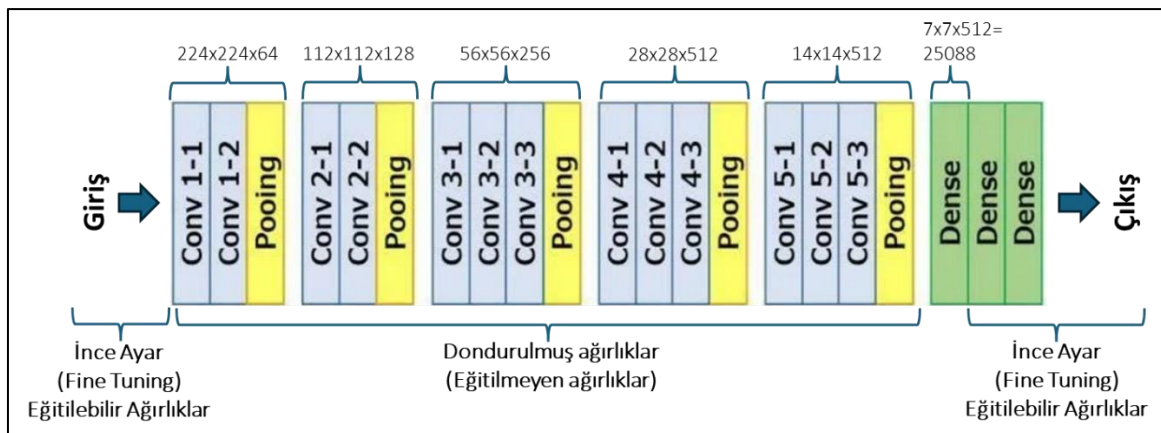
Farklı transfer öğrenme mimarilerinin sonuçlarını karşılaştırmak için dörtlü sınıflandırma deneyleri yapılmıştır. Bu deneylerde de Çizelge 3.10' da görülen hiperparametreler kullanılmıştır. Çizelge 3.11' de sunulan sonuçlarda görüldüğü gibi hem yineleme grafiği hem de spektrogram görüntü verileri kullanılarak yapılan deneylerde en yüksek sınıflandırma sonucuna VGG16 transfer öğrenme mimarisi ulaşmıştır.

Çizelge 3.11. Farklı transfer öğrenme modelleri ile yapılan deneylerin çoklu sınıflandırma sonuçları

Sınıf Grubu	Yöntem	Pencere Boyutu (sn)	Eğitim Doğruluğu (%)	Validasyon Doğruluğu (%)
VGG16	Yineleme grafiği	5 (Şekil 2.6)	99,11	95,53
VGG19			99,54	94,25
Inception V3			99,72	92,02
Xception			99,83	92,41
MobileNet			99,96	93,69
VGG16	Spektrogram	5 (Şekil 2.6)	99,12	97,87
VGG19			96,99	94,53
MobileNet			100	95,92

Yineleme grafiği verileriyle yapılan deneylerde VGG16 mimarisinin doğruluk oranına (%95,53) en yakın sonuca %94,25 ile VGG19 transfer öğrenme mimarisi ulaşmıştır. Spektrogram görüntü verileriyle yapılan deneylerde ise VGG16 mimarisinin doğruluk oranına (%97,87) en yakın sonuca %95,92 ile MobileNet transfer öğrenme mimarisi ulaşmıştır. En iyi dördü sınıflandırma sonuçlarına VGG16 mimarisi ile ulaşıldığı için VGG16 mimarisi kullanılarak ikili sınıflandırmalar da gerçekleştirilmiştir.

VGG16 transfer öğrenme süreçlerinde sıkça tercih edilen bir mimaridir. Giriş ve çıkış katmanları özelleştirilebilirken konvolüsyon katmanlarındaki ağırlıklar genelde dondurulur. Toplam parametre sayısı 138.423.208' dir. Şekil 3.15' te görülen VGG16 mimarisi toplam 16 katmandan oluşmaktadır.



Şekil 3.15. VGG16 transfer öğrenme mimarisi


VGG16 transfer öğrenme mimarisi ile yapılan deneylerin sonuçları Çizelge 3.12’ de sunulmuştur. Çizelge 3.12’ deki deneylerde VGG16 modelinin ağırlıkları dondurulmuştur.

Çizelge 3.12. VGG16 transfer öğrenme modeli ile ikili ve çoklu sınıflandırma sonuçları

Sınıf Grubu	Yöntem	Pencere Boyutu (sn)	Eğitim Doğruluğu (%)	Validasyon Doğruluğu (%)
ALS – SK	Yineleme grafiği	5 (Şekil 2.3)	100	99,50
HH – SK			99,80	97,12
PH – SK			99,42	98,84
ALS – PH – HH – SK			99,11	95,53
ALS – SK	Spektrogram		99,94	99,87
HH – SK			98,21	98,01
PH – SK			97,29	97,12
ALS – PH – HH – SK			99,12	97,87

Dörtlü sınıflandırmada, spektrogram görüntüleri kullanılarak VGG16 transfer öğrenme modeli ile elde edilen doğruluk oranı (%97,87), önerilen CNN mimarisi ile elde edilen en yüksek doğruluk oranı (%96,15) ile karşılaştırıldığında, VGG16 transfer öğrenme modeli ile daha yüksek doğruluk sonucuna ulaşıldığı görülmektedir. Mimarilerde bulunan parametre sayılarına bakıldığında ise, VGG16 mimarisinde bulunan parametrelerin önerilen CNN mimarisinde bulunan parametrelerden yaklaşık 280 kat fazla olduğu görülmektedir. Çok daha az parametre ile oluşturulmuş CNN modeli ve VGG16 mimarisiyle gerçekleştirilen eğitimlerin doğruluk oranları arasında %2’ den daha az fark bulunmaktadır. İkili sınıflandırmalarda ise, önerilen CNN mimarisi ile elde edilen sonuçlar (Çizelge 3.7 ve Çizelge 3.8) ve VGG16 transfer öğrenme mimarisi ile elde edilen sonuçlar karşılaştırıldığında, birbirine yakın doğruluk oranları elde edildiği görülmüştür.

Şekil 3.16’ da spektrogram görüntüleri kullanılarak VGG16 mimarisinde gerçekleştirilen dörtlü sınıflandırmanın doğruluk ve kayıp grafikleri görülmektedir. Şekil 3.16’ ya bakıldığında eğitim ve doğrulama doğruluğunun birbirine tutarlı şekilde ilerlediği görülmektedir. Bu durum VGG16 transfer öğrenme mimarisi kullanılarak yapılan eğitimde herhangi bir ezberleme olmadığını göstermektedir. Aynı şekilde kayıp fonksiyonunda da eğitim ve doğrulama kaybı arasında tutarlı bir ilerleyiş vardır.



Şekil 3.16. VGG16 transfer öğrenme mimarisinin dörtlü sınıflandırma model doğruluğu ve model kaybı grafikleri

Şekil 3.17' de ise spektrogram görüntüleri kullanılarak VGG16 mimarisinde gerçekleştirilen dörtlü sınıflandırmanın karmaşıklık matrisi bulunmaktadır.

VGG16 Dörtlü Sınıflandırma				
ALS	98.7	0	1	0.3
SK	0.2	98.2	0.2	1.4
HH	0.7	1.5	95.8	2
PH	1.2	0.5	2.4	95.9
	ALS	SK	HH	PH

Şekil 3.17. VGG16 transfer öğrenme mimarisinin dörtlü sınıflandırma karmaşıklık matrisi

Spektrogram görüntüleri kullanılarak gerçekleştirilen dörtlü sınıflandırmada en yüksek ALS' li (%98,7) bireyler ayırt edilmiştir. Bu durum bölüm 3.2.1' de anlatıldığı gibi spektrogram görüntülerinin ALS' li bireylerde daha fazla ayırt ediciliğe sahip olduğunu kanıtlamaktadır. Çizelge 3.12' de de görüleceği gibi VGG16 mimarisinde gerçekleştirilen eğitimlerde ALS-SK sınıflandırmasının doğruluk oranı (%99,87) diğer ikili sınıflandırmalara göre daha yüksektir.

VGG16 transfer öğrenme mimarisinin bir konvolüsyon katmanı (Conv 5-1 katmanı) dondurulmadan deneyler tekrar edilmiştir ve Çizelge 3.13' teki sınıflandırma sonuçlarına ulaşılmıştır.

Çizelge 3.13. Tek katmanı dondurulmamış VGG16 transfer öğrenme modeli ile ikili ve çoklu sınıflandırma sonuçları

Sınıf Grubu	Yöntem	Pencere Boyutu (sn)	Eğitim Doğruluğu (%)	Validasyon Doğruluğu (%)
ALS – SK	Yineleme grafiği	5 (Şekil 2.3)	100	99,75
HH – SK			100	98,90
PH – SK			99,05	99,19
ALS – PH – HH – SK			99,86	96,76
ALS – SK	Spektrogram		100	99,75
HH – SK			100	99
PH – SK			100	99,87
ALS – PH – HH – SK			99,50	97,21

Dörtlü sınıflandırmada spektrogram görüntüleriyle elde edilen %97,87' lik sınıflandırma sonucu konvolüsyon katmanı dondurulmamış VGG16 mimarisiyle geçilememiş olsa da yineleme grafiği kullanılarak elde edilen dörtlü sınıflandırma sonucunun %95,53' ten %96,76' ya yükseldiği görülmüştür.

3.2.3. Performans değerlendirme metriklerinin yorumlanması

Çizelge 3.14' te görülen sonuçlar, bu çalışmada kullanılan derin öğrenme mimarileri dörtlü sınıflandırma problemi üzerindeki istatistiksel performans metriklerini sunmaktadır.

Çizelge 3.14. Bu çalışmada kullanılan mimarilerde dörtlü sınıflandırma performansını değerlendirme metrikleri

Mimari	Yöntem	F1 Skoru (%)	Kesinlik (%)	Duyarlılık (%)	ROC-AUC Skoru (%)
CNN	Spektrogram	96,64	96,61	96,69	97,77
CNN	Yineleme grafiği	94,11	94,30	93,96	95,95
Hibrit CNN	Spektrogram-Yineleme grafiği	96,99	97	96,98	97,96
VGG16	Spektrogram	97,09	97,02	97,16	98,08

Bu metrikler, modellerin sınıflandırma görevlerindeki doğruluğunu ve güvenilirliğini değerlendirmek için kullanılır.

F1 skoru, bir modelin doğruluğunu ve hassasiyetini dengeleyen bir ölçüttür. Yüksek F1 skoru, modelin hem doğru pozitifleri yakalamada hem de yanlış pozitiflerden kaçınmada iyi performans gösterdiğini ifade etmektedir. Çizelge 3.14' teki verilere göre, en yüksek F1 skoru %97,09 ile VGG16 mimarisiyle elde edilmiştir; bu da bu modelin en iyi genel performansa sahip olduğunu göstermektedir. Hibrit CNN mimarisi %96,99 ile VGG16 mimarisinin F1 skoru sonucuna çok yakın bir değere sahipken, en düşük F1 skoru ise %94,11 ile yineleme grafiği görüntüleri kullanılarak eğitilen CNN mimarisine aittir, bu da bu modelin diğer yöntemlere göre daha düşük bir genel performans sergilediğini göstermektedir.

Kesinlik, modelin doğru pozitif tahminlerinin tüm pozitif tahminlere oranını ölçer. Yüksek bir kesinlik, modelin yanlış pozitif sayısını azaltmada iyi olduğunu göstermektedir. Çizelge 3.14' te, VGG16 mimarisi ile gerçekleştirilen dörtlü sınıflandırma %97,02 kesinlik ile en yüksek değeri elde etmiştir, bu da modelin yanlış pozitif tahminlerden kaçınmada oldukça etkili olduğunu göstermektedir. Hibrit CNN mimarisi %97 kesinlik ile VGG16 mimarisinde benzer bir performans sergilerken, yineleme grafiği görüntüleri kullanılarak eğitilen CNN mimarisi %94,30 ile daha düşük performans sergilemektedir.

Duyarlılık, modelin doğru pozitif tahminlerinin tüm gerçek pozitiflere oranını ifade eder ve modelin yanlış negatifleri en aza indirme yeteneğini ölçer. VGG16 mimarisi %97,16 duyarlılık oranı ile en yüksek performansı sergilemiştir, bu da modelin gerçek pozitifleri yakalama konusunda başarılı olduğunu göstermektedir. Hibrit CNN mimarisi %96,98 duyarlılık sonucuna ulaşırken spektrogram görüntüleriyle eğitilen CNN mimarisi %96,69 ve yineleme grafiği görüntüleriyle eğitilen CNN mimarisi %93,96 duyarlılık sonucuyla daha düşük değerler sunmaktadır.

ROC-AUC skoru, bir modelin sınıflandırma yeteneğinin genel bir ölçüsüdür ve modelin pozitif ve negatif sınıfları ne kadar iyi ayırt edebildiğini göstermektedir. Yüksek bir ROC-AUC skoru, modelin tüm sınıflandırma eşiklerinde genel olarak iyi performans gösterdiğini ifade etmektedir. Çizelge 3.14' teki en yüksek ROC-AUC skoru %98,08 ile VGG16 mimarisinde aittir, bu da modelin pozitif ve negatif sınıfları ayırt etmede iyi

olduğunu gösterir. Hibrit CNN mimarisi (%97,96) ve spektrogram görüntüleriyle eğitilen CNN mimarisi (%97,77) ROC-AUC skoru sonucunda VGG16 mimarisine yakın performans sergilerken, yineleme grafiği görüntüleriyle eğitilen CNN mimarisi %95,95 ile en düşük ROC-AUC skoruna sahiptir.

Performans değerlendirme metriklerinin sonuçları Çizelge 3.8 ve Çizelge 3.12' deki dörtlü sınıflandırma validasyon doğruluğu sonuçlarıyla tutarlıdır.

3.3. Yürüyüş Dinamiklerine Dayalı Literatürle Performans Karşılaştırması

Çizelge 3.15' te bu çalışmada kullanılan veri kümesi kullanılarak yürüyüş analizi yapılan çalışmaların ikili, üçlü ve dörtlü sınıflandırma sonuçları, çalışmalarda kullanılan sinyaller, özellik çıkarım ve sınıflandırma yöntemleri ve doğruluk oranları açısından karşılaştırmalı olarak sunulmaktadır. Çizelge 3.15' ten de görülebileceği gibi, çalışmaların önemli bir kısmı NDH' lerin ikili sınıflandırılması sorununu ele almıştır. İkili sınıflandırmada %100 sınıflandırma başarısı elde edilen çalışmaların önemli bir kısmında DYTK sinyallerinden belirlenen, sağ ve sol ayak için ayrı ayrı hesaplanan adım aralığı, salınım aralığı, duruş aralığı, çift destek aralığı gibi birçok sinyalin birlikte kullanılarak çıkarılan özelliklerin kullanıldığı görülmektedir. Yalnızca DYTK sinyallerinin kullanıldığı çalışmaların [11, 22, 24] ise her bir NDH için %100 sınıflandırma doğruluğuna ulaşamadığı görülmüştür. Bu çalışmada makine öğrenmesi yöntemleri kullanılarak ikili sınıflandırmanın yani ALS, PH ve HH bozukluklarının tanısının başarısı sırasıyla %98,8, %97,4 ve %98 olarak belirlenirken, derin öğrenme yöntemleri kullanılarak bu oranlar sırasıyla %99,87, %99,87 ve %99 olarak belirlenmiştir. Makine öğrenmesine dayalı yöntemde ham DYTK sinyalleri ile PH tanısının konulmasında özelliklerin bir arada kullanılması durumunda literatüre göre daha başarılı sonuçlar gözlenmiştir [11, 12, 14, 15, 16, 17, 22, 23, 72]. Derin öğrenmeye dayalı yöntemde ise ALS, PH, HH tanısı için ikili sınıflandırma yapan çalışmalara göre daha yüksek doğruluk oranları elde edilmiştir [12, 14, 15, 16, 17, 21, 22, 23, 26, 27, 72].

Çizelge 3.15. Bu çalışmada kullanılan veri kümesini kullanarak NDD tanısı koymak için yürüyüş analizi yapan çalışmaların karşılaştırılması

Çalışma	Kullanılan Veri	Yöntem	Sınıflandırma	Sınıflandırma Doğruluğu (%)					
				İkili Sınıflandırma				Çoklu Sınıflandırma	
				ALS - SK	PH - SK	HH - SK	NDH - SK	ALS-PH-HH	ALS-PH-HH-SK
Daliri ve ark. [12]	Adm. Ar, Slnm. Ar, Drş. Ar, ÇD. Ar	İstatiksel özellikler (minimum, maximum ortalama, standart sapma)	DVM	96,79	89,33	90,28	90,63	-	-
Zeng ve ark. [13]	Slnm. Ar, Drş. Ar,	Deterministik öğrenme teorisi	Yarıçapsal tabanlı fonksiyon SA	93,1	100	100	93,75	-	-
Amin ve ark. [14]	Adm. Ar, Slnm. Ar, Drş. Ar, ÇD. Ar	İstatiksel özellikler (ortalama, standart sapma, varyans, çarpıklık, basıklık), entropi, enerji, korelasyon	Doğrusal diskriminant analizi	85	89	93	85	-	-
Ye ve ark. [15]	Adm. Ar, Drş. Ar, ÇD. Ar		Uyarlamalı ağ tabanlı bulanık çıkarım sistemi	93,1	90,32	94,44	90,63	-	-
Klomsae ve ark. [17]	Adm. Ar-L	Metin kümeleme	Bulanık k-NN	96,88	96,43	97,22	98,44	-	-
Xia ve ark. [18]	Adm. Ar, Drş. Ar, ÇD. Ar	İstatiksel özellikler, Lempel-Ziv karmaşıklığı, bulanık entropi, Teager-Kaiser enerji	DVM	96,55	100	100	96,83	-	-
Saljuqi ve ark. [19]	Adm. Ar, Slnm. Ar, Drş. Ar, ÇD. Ar	Statik özellikler	Elman RNN	100	100	100	-	-	-
Pham ve ark. [20]	Adm. Ar-R	Gri seviye eş oluşum matrisi, bulanık yineleme grafiklerinden çıkarılan özellikler	Least Squares DVM	100	100	100	-	-	-
Ghaderyan ve ark. [21]	Adm. Ar, Slnm. Ar, Drş. Ar	Benzerlik özellikleri	Sparse Non-Negative Least Squares Coding	97	98	95	91	-	-
Yılmaz [63]	Adm. Ar, Slnm. Ar, Drş. Ar,	Durum uzayı vektörleri	kNN	89,7	93,5	94,3	90,50	-	-
S.A. B. V. ve ark. [73]	Adm. Ar, Slnm. Ar, Drş. Ar,	Triblock CNN ve derin tekrarlı kantifikasyon analizi	Multi DVM	100	100	100	99,96	-	-
Setiawan ve ark. [11]	DYTK	Dalgacık tutarlılığı + PCA		99,89	92,58	100	-	-	-
Elden [22]	DYTK	Reconstructed Phase Space özellikleri, Yineleme grafiği özellikleri	DVM	86,21	90,32	80,56	92,19	-	-
Beyrami [24]	DYTK	Ortalama, standart sapma, çarpıklık, basıklık, entropi	NNLS	100	99,78	99,90	99,57	-	-

Çizelge 3.15. (devam) Bu çalışmada kullanılan veri kümesini kullanarak NDD tanısı koymak için yürüyüş analizi yapan çalışmaların karşılaştırılması

Çalışma	Kullanılan Veri	Yöntem	Sınıflandırma	Sınıflandırma Doğruluğu (%)					
				İkili Sınıflandırma				Çoklu Sınıflandırma	
				ALS - SK	PH - SK	HH - SK	NDH - SK	ALS-PH-HH	ALS-PH-HH-SK
Zhao ve ark. [26]	DYTK, Adm. Ar, Slnm. Ar, Drş. Ar, ÇD. Ar		Çift kanallı LSTM tabanlı çoklu özellik çıkarma	97,43	97,33	94,96	96,42	95,67	-
Baratin ve ark. [16]	Adm. Ar	DWT, entropi, coherence	Doğrusal sınıflandırma	86,2	87,1	86,10	80,40	85	-
Fraivan ve ark. [10]	DYTK	Statik özellikler (karekök ortalama, varyans, basıklık, çarpıklık)	Ada güçlendirme, Karar ağacı	-	-	-	-	-	99,17 93,13
Setiawan ve ark. [25]	DYTK	Zaman-frekans spektrogramı	CNN	100	97,42	100	98,44	-	98,55
Zhao ve ark. [23]	DYTK, Adm. Ar, Slnm. Ar, Sta.Int,	Temel özellikler, Klasik doğrusal olmayan dinamik özellikler, Lempel-Ziv karmaşıklığı	Rastgele Orman algoritması	95,72	91,68	91,71	92,87	-	86,56
Lin ve ark. [28]	DYTK	Yineleme grafiği	CNN	100	100	97,56	98,93	-	93,9
Faisal ve ark. [27]	DYTK	Ham DYTK, DYTK + özellikler	CNN	92 100	81 94	79 97	78 96	-	73 83
Bu çalışma	DYTK	DFA+DTW+OK	DVM	99,6	97,2	98,1	97,2	93,3	93,5
		Yineleme grafiği	CNN	98,76	99,19	97,52	-	-	94,19
		Spektrogram	CNN	99,75	98,73	97,42	-	-	95,75
		Yineleme grafiği, spektrogram	Hibrit CNN	99,63	96,93	97,71	-	-	96,15
		Yineleme grafiği	VGG16 Transfer Öğrenme	99,75	99,19	98,90	-	-	96,76
		Spektrogram	VGG16 Transfer öğrenme	99,87	99,87	99	-	96,65	97,87

(Adım Aralığı: Adm. Ar; Salınım Aralığı: Slnm. Ar; Duruş Aralığı: Drş. Ar; Çift Destek Aralığı: ÇD. Ar)

Her hastalık ve sağlıklı grup için ikili sınıflandırma performansları değerlendirilse de çalışmanın asıl konusu hastanın bu NDH gruplarından hangisine ait olduğunun belirlenmesidir. NDH'lerin çok sınıflı sınıflandırması nadiren ele alınan bir sorundur ve buna odaklanan daha az çalışma vardır [10, 16, 23, 25, 26, 27, 28]. ALS, PH ve HH' nin sınıflandırılmasına yönelik üç sınıflı problemde Baratin ve ark. [16] adım aralığı sinyallerinde DWT, entropi ve tutarlılık yöntemlerini kullanarak %85 doğruluk elde etmiştir. Zhao ve ark. [26], DYTK sinyalleri ile adım aralığı, salınım aralığı, duruş aralığı,

çift destek aralığı gibi zaman alanı verilerinin kombinasyonu üzerinde çift kanallı LSTM tabanlı çoklu özellik çıkarma yöntemini kullanarak %95,67 doğruluk elde etmiştir. Bu çalışmanın makine öğrenmesine dayalı kısmında DTW, DFA ve OK tabanlı özelliklerin kombinasyonu yalnızca DYTK sinyallerini kullanarak %93,3 doğruluk oranına ulaşırken, derin öğrenmeye dayalı kısmında yalnızca DYTK sinyalleri kullanılarak oluşturulan görüntüler VGG16 mimarisinde eğitilip %96,65 doğruluk oranına ulaşılmıştır. Böylelikle ham DYTK verilerinden türetilen adım aralığı, salınım aralığı, duruş aralığı, çift destek aralığı gibi zaman alanı verileri kullanılmadan literatürdeki diğer çalışmalara göre daha yüksek doğruluk oranına ulaşılmıştır [16, 26].

Son olarak NDH' ler ve SK gruplarının birlikte ele alındığı dört sınıf için yapılan çalışmaların sonuçları incelenmiştir. Zhao ve ark. [23] temel özellikleri, klasik doğrusal olmayan dinamik özellikleri ve Lempel-Ziv karmaşıklığa dayalı özellikleri ve rastgele orman sınıflandırmasını kullanarak %86,56 doğruluk oranına ulaşmıştır. CNN tabanlı sınıflandırmanın kullanıldığı çalışmalarda doğruluk oranlarının daha yüksek olduğu görülmüştür. Lin ve ark. [28], DYTK sinyallerini yineleme grafiği görüntülerine dönüştürerek transfer öğrenme mimarilerinden AlexNet ile sınıflandırırken (%93,9), Setiawan ve ark. [25] sürekli dalgacık dönüşümü tabanlı skalogram ve CNN kullanarak %98,55 doğruluk elde etmiştir. Öte yandan Frawian ve ark. [10] istatistiksel özellikleri ve topluluk sınıflandırıcılarını kullanarak dörtlü sınıflandırmada %99,17 doğruluk oranına ulaşmıştır. Aynı özellikler karar ağaçları sınıflandırıcısında sınıflandırıldığında başarının %93,13' te kaldığı gösterilmiş ve sonuçlar topluluk öğrenmenin etkisine işaret etmiştir [10].

Her hastalığın kendine özgü ritimleri olabileceğinden, tüm hastalıkların teşhisinde ortak tek bir özelliği genellemek yerine, hastalığa özgü kalıpları ve parametreleri belirlemek önemlidir. Bu çalışmada DFA, ALS tanısı için çok yüksek doğruluk oranları sağlarken, OK' nin, HH için daha yüksek doğruluk oranları sağladığı görülmüştür. Öte yandan, PH' yi %90'ın üzerinde doğrulukla teşhis etmek için önerilen üç özelliğin birlikte kullanılması gerektiği görülmüştür. Elde edilen tüm bu doğruluk oranları, özellik çıkarma aşamasında yapılan özellik analiziyle de tutarlıdır. Bu nedenle birçok çalışmada yapıldığı gibi tüm NDH' leri aynı özellik veya özellik grubu kullanılarak sınıflandırmak yerine, her NDH için hastalığa özgü özellik gruplarının belirlenmesinin önemi ortaya konmuştur. Makine öğrenmesine dayalı yöntemde çok sınıflı sınıflandırmada, özellikler tek tek kullanıldığında

doğruluk oranlarının sınırlı kaldığı; ancak her hastalık tanısı için etkili olan özelliklerin bir arada kullanılmasının NDH' lerin çok sınıflı hastalık teşhisinde doğruluk oranlarını arttırdığı görülmüştür.

Bu çalışmada makine öğrenmesine dayalı yaklaşımda DYTK sinyallerinden elde edilen DTW, DFA ve OK tabanlı özelliklerin kombinasyonunu kullanarak %93,5 teşhis doğruluğu elde edilmiştir.

Derin öğrenmeye dayalı yaklaşımda DYTK sinyalleri yineleme grafiği görüntülerine dönüştürülüp CNN modelinde eğitilerek %94,14; transfer öğrenme mimarilerinden VGG16 modelinde eğitilerek %96,76 doğruluk oranına ulaşılmıştır. Yineleme grafiği görüntülerinin eğitildiği her iki modelde de Lin ve ark. [28] çalışmasında elde edilen sonuçtan (%93,9) daha yüksek sonuçlar elde edilmiştir. Bunun yanı sıra DYTK sinyallerinin spektrogram görüntüleri oluşturularak deneyler tekrarlanmıştır. Spektrogram görüntülerinin eğitildiği CNN modelinde %95,75 doğruluk oranı elde edilirken, VGG16 modelinde %97,87 doğruluk oranı elde edilmiştir. Ayrıca hem yineleme grafiği hem de spektrogram görüntülerinin birlikte kullanıldığı hibrit CNN modelinin sonucu (%96,15) literatürde bulunan benzer çalışmalara göre daha yüksektir [23, 27, 28].

Derin öğrenmeye dayalı yöntemde spektrogram görüntüleri ALS tanısı için yüksek doğruluk oranı sağlarken, yineleme grafiği görüntüleri PH' ler için yüksek doğruluk oranı sağlamıştır. Tüm NDH grupları incelendiğinde, spektrogram görüntülerinin NDH' ler üzerindeki ayırt ediciliğinin yineleme grafiğine göre daha yüksek olduğu gözlemlenmiştir. Ayrıca çoklu sınıflandırmalarda yineleme grafiği ve spektrogram görüntülerinin birlikte kullanıldığı hibrit yapının doğruluk oranını artırmaya yönelik etkisi, sadece yineleme grafiği veya sadece spektrogram görüntülerinin kullanıldığı mimarilere göre daha yüksektir. Bu durum, görüntüye dönüştürme yöntemlerinin bir arada kullanılmasının NDH' lerin çok sınıflı hastalık teşhisinde doğruluk oranlarını arttırdığını göstermektedir.

4. TARTIŞMA

Her ne kadar önceki çalışmalar hem derin öğrenme hem de geleneksel makine öğrenimi yaklaşımlarıyla yüksek doğruluk elde etmiş olsa da, klinik ortamda NDH'lerin teşhisini desteklemek için klinik olarak açıklanabilir özellikler sağlamaya yönelik nadir araştırmalar yapılmıştır. Bölüm 3' teki Çizelge 3.15 incelendiğinde bazı çalışmalarda kullanılan yöntemlerin tüm hastalık gruplarını yüksek doğrulukla ayırt edebilme yeteneğine sahip olduğu görülse de [19,20,73], diğer çalışmalarda ise seçilen yöntemlerin belirli bir NDH için üstün doğruluk gösterdiği görülmektedir [11,22]. Bu nedenle, hastalığa özgü özelliklerin belirlenmesi ikili sınıflandırma için önemlidir. Özniteliklerin bir araya getirilmesi ise NDH'lerin çok sınıflı teşhisinde önemlidir.

Bu çalışmanın makine öğrenmesine dayalı yaklaşımında farklı özellik çıkarım yöntemlerinin farklı NDH'ler için tespit doğrulukları üzerinde etkili olduğu, dolayısıyla hastalığa özgü özelliklerin belirlenmesinin tanı doğruluğu üzerinde önemli bir etkiye sahip olacağı ortaya konulmuştur.

DFA, bir sinyalin kendine benzer doğasına sahip uzun menzilli korelasyonların varlığını ölçmek için kullanılan bir tekniktir. DFA katsayısı, sinyalin kendine benzerlik parametresini (ölçekleme üssü) belirtir. 0,5 ile 1 arasındaki bir ölçeklendirme üssü büyük dalgalanmaları muhtemelen büyük dalgalanmaların takip edeceği, küçük dalgalanmaları ise muhtemelen küçük dalgalanmaların takip edeceği anlamına gelir. Ölçekleme üssünün 0,5'ten 1'e artması, sinyalin daha kalıcı olduğunu gösterir [74]. Şekil 3.2' deki dağılım grafiklerinde görüldüğü gibi SK'lerde her iki ayağın DFA katsayıları 0,5-1 arasında dağılım göstermektedir. Bu sonuç, DYTK sinyallerinin, NDH'li deneklerle karşılaştırıldığında SK deneklerin ayaklarında daha kalıcı bir eğilim sergilediğini göstermektedir. Öte yandan ALS'li bireyin her iki ayağındaki DFA katsayılarının dağılımlarının 0-0,5 aralığında olduğu görülmektedir, bu da DYTK sinyalinde uzun menzilli kalıcı olmayan eğilim anlamına gelmektedir. Bu durum ALS'li bireylerin uzun süreli yürüyüş ritimlerinde tutarsızlıklar olabileceğini göstermektedir. PH'li bireyler için ise DFA katsayılarının 0,5-0,6 aralığında yoğunlaştığı ve öz benzerliğin sağ ve sol ayak için farklı dağılımlara sahip olabileceği söylenebilir. HH açısından katsayıların 0-1 aralığında dağıldığı ancak sağ ve sol ayak DFA katsayılarının yani kendine benzerlik

indekslerinin birbiriyle uyumlu olduğu görülmektedir. Bu durum sınıflandırma sonuçlarına da yansımaktadır. DFA katsayıları ALS ve SK grupları arasında oldukça yüksek bir sınıflandırma başarısı sağlarken (%92,6), HH (%81,9) ve PH (%75,4) için doğruluğun sınırlı olduğu görülmüştür.

DTW' de minimum mesafe, iki zamanlı alan sinyalleri arasındaki maksimum benzerlik anlamına gelir. Bu çalışmada, hastaların sağ ve sol ayak hareketlerinin ürettiği sinyaller arasındaki uyumu belirlemek için DTW katsayıları kullanılmıştır. Şekil 3.3' te görüldüğü gibi DTW katsayısının ortalaması PH için maksimum, ALS için minimumdur. Bu durum PH grubunda sağ ve sol ayak DYTK sinyallerinin birbirinden daha farklı olduğunu, ALS hastalarında ise sağ ve sol ayak DYTK sinyallerinin uyumlu olduğunu göstermektedir. Bu sonuçlar aynı zamanda DTW tabanlı özelliklerin sınıflandırma sonucuna da yansımaktadır; burada DTW özellikleri PH' yi en yüksek başarıyla (%69,1) ayırt ederken, ALS hastaları için en düşük başarıyı gösterdiği görülmektedir (%65,4).

Şekil 3.4' e göre, OK tabanlı özellikler ALS için en yüksek değerlere sahiptir ve ALS' li denekler için en belirgin şekilde farklılık göstermektedir. Aksine, PH' de OK temelli özelliklerin en düşük değerlere sahip olduğu görülmektedir. Bu, daha yüksek gecikmelerde, DYTK sinyallerinin ALS hastalarında PH grubuna göre daha periyodik bir eğilim sergilediğini gösterebilir. Bunun dışında sol ayaktaki farkların sağ ayağa göre daha düşük gecikmelerde bile daha fazla olduğu söylenebilir. HH ve ALS hastalarında, daha yüksek gecikmelerde sağ ve sol ayak OK katsayılarındaki değişikliklerin farklı olduğu, yani sol ayak OK katsayılarının sağa göre daha yüksek olduğu görülmektedir. Bu durum HH ve ALS hastalarında sağ ve sol ayak DYTK sinyallerinin periyodikliklerinin farklı olabileceğini göstermektedir ve bu durum sağ ve sol ayak sinyallerinin benzerliğini ölçen DTW katsayılarının sonuçlarıyla tutarlıdır. OK tabanlı özellikteki bu değişiklik, ALS (%93,6) ve HH (%92,4) gruplarında PH (%84,9) grubuna göre daha yüksek doğruluk elde edildiğinin göstergesidir.

DFA katsayılarının ayrı ayrı kullanılmasıyla karşılaştırıldığında, minimum özellik boyutuna sahip olan DFA ve DTW tabanlı özelliklerin birleştirilmesinin, tüm NDH gruplarında doğruluğu artırdığı; ancak en iyi iyileşmenin HH' de (%95,7) görüldüğü sonucuna varılmaktadır. Sonuçlar PH' de (%97,4) yüksek tanı performansı elde etmek için tüm özelliklerin bir arada kullanılması gerektiğini ortaya koymaktadır. Aynı zamanda

özelliik kombinasyonunun çok sınıflı NDH' lerin teşhisinde doğruluęu artırdığı söylenebilir.

Bu çalışmanın derin öğrenmeye dayalı yaklaşımında farklı sinyal-görüntü dönüşüm yöntemlerinin farklı NDH' ler için tespit doğrulukları üzerinde etkili olduęu ortaya koyulmuştur.

Çizelge 3.8' deki sınıflandırma sonuçlarına bakıldığında spektrogram görüntüleri ALS hastalarını en yüksek başarıyla ayırt ederken (%99,75), HH için en düşük başarıyı gösterdiği görülmektedir (%97,42). Yineleme grafięi görüntüleri ise PH' yi en yüksek başarıyla (%99,19) ayırt ederken, HH' ler için en düşük başarıyı sunmaktadır (%97,52). İki görüntüye dönüşüm yönteminin de HH' ler üzerindeki ayırt edicilięinin dięer NDH gruplarına göre daha düşük olduęu görülmektedir. Şekil 3.13' teki karmaşıklık matrisleri incelendiğinde de spektrogram görüntülerinin ALS hastaları üzerindeki ayırt edicilięinin en yüksek, HH' ler üzerindeki ayırt edicilięinin en düşük olduęu söylenebilir. Yineleme grafięinin ise PH' ler üzerindeki ayırt edicilięinin en yüksek, HH' ler üzerindeki ayırt edicilięinin en düşük olduęu söylenebilir. Hem yineleme grafięinin hem de spektrogram görüntülerinin birlikte kullanıldığı hibrit mimari, görüntülerin tek başına kullanıldığı mimarilere göre HH' leri daha iyi ayırt ederken (%97,71), PH' lerin ayırt edicilięini düşürmüştür (%96,93). Sonuç olarak iki görüntüye dönüşüm yönteminin hibrit bir modelde birlikte kullanılması HH tanısı için etkiliyken, sadece yineleme grafięi görüntülerinin CNN mimarisinde kullanılması PH tanısı için daha etkilidir. İkili sınıflandırmalarda ALS hastalığı hem yineleme grafięi hem de spektrogram görüntülerinin ayrı ayrı kullanıldığı mimarilerde yüksek doğruluk oranlarıyla teşhis edilirken, benzer şekilde iki sinyal-görüntü dönüşüm yönteminin birlikte kullanıldığı hibrit mimaride de ALS hastalığı teşhisi yüksek doğruluk oranına ulaşılmıştır (%99,63).



5. SONUÇ VE ÖNERİLER

Yürüyüş verilerinden elde edilen DYTK sinyalleri, NDH' lerin teşhisi için önemli bir belirteçtir. Hem NDH' lerin varlığının belirlenmesi hem de hastalıkların çok sınıflı teşhisi açısından önemli bilgiler içermektedir. Ancak her nöromüsküler hastalık tipinin belirlenmesinde yürüyüş verilerinden hastalığa özgü ayırt edici özelliklerin belirlenmesi çok önemlidir. Bu çalışmada her hastalığın ayırt edici özelliklerinin farklı olabileceği ortaya konmuş, PH, HH ve ALS tanısında hastalığa özgü özelliklerin belirlenmesi ve birlikte kullanılmasıyla yüksek doğruluk oranlarına ulaşılmıştır. Yapılan deneyler ışığında DYTK sinyalinden elde edilen özellikler arasında AD hastalığı için en anlamlı özellikler DFA katsayıları olurken, HH için AC katsayıları daha yüksek doğruluk oranları sağlamıştır. Öte yandan PH' nin %90' ın üzerinde doğrulukla teşhis edilebilmesi için DFA, DTW ve OK tabanlı özelliklerin birlikte kullanılması gerektiği ortaya konmuştur. Ayrıca nöromüsküler hastalıkları birbirinden ayırmak, sağlıklı ve bireysel hasta gruplarını birbirinden ayırmaktan daha karmaşık bir sorundur çünkü yürüyüş ritimleri tüm bu hastalıklar için ortak bir belirteçtir. Bu nedenle, çok sınıflı sınıflandırma ile hastalıkların teşhisinde, daha yüksek teşhis performansı elde etmek için gelişmiş hastalık ayırt etme yeteneklerine sahip hastalığa özgü özelliklerin kullanılması gerekmektedir.

DYTK sinyali NDH teşhisinde yaygın olarak kullanılan bir tanı verisidir [10-11, 22-28]. Bu nedenle, DYTK tabanlı özelliklerin çıkarılması ve bir karar destek sisteminin oluşturulması, NDH' lerin tanı ve tedavisinde doktorlara anlamlı bir etki sağlayacaktır. NDH' lerin erken tanısı, hastalıkların tedavi süreçlerinin başarılı bir şekilde yönetilmesi açısından oldukça önemlidir. Bu nedenle hastaların yürüme ritimlerini uzun süre izleyebilecek giyilebilir sistemlerin ve hastalık tanısına ışık tutabilecek yazılımların geliştirilmesi önemli bir ihtiyaçtır. Günlük izleme ve yürüyüş analiz sistemleri, insan yürüyüşünü gözlemlemek için uygun ve etkili yöntemler sunmakta, hareket sırasında duruş kontrol mekanizmalarını analiz etmek için ayrıntılı veriler sağlamakta ve teşhis ve tedaviler için klinik kanıtları desteklemektedir [75-77]. Bu çalışmada, sınırlı sayıda özelliğe sahip makine öğrenmesi yöntemleri ve derin öğrenme yöntemlerine dayalı hibrit CNN ve transfer öğrenme mimarileri kullanılarak yüksek sınıflandırma doğruluğu sağlayan bir yöntem önerilmektedir. Çalışmada önerilen yöntemler, özellikle giyilebilir sistemlerde gömülü kullanıma uygun güçlü bir özelliktir [78].

NDH' lerin tanısının erken konulması da hastalıkların tedavi süreçlerinin başarılı bir şekilde yönetilmesi açısından oldukça önemlidir. Bu çalışmada, DYTK sinyallerinden oluşturulan yineleme grafiği ve spektrogram görüntüleri hibrit CNN model ve VGG16 transfer öğrenme modeli kullanılarak eğitilmiş, yüksek sınıflandırma doğruluğuna ulaşılmıştır. Yapılan deneylerde kullanılan hibrit CNN mimarisi ve VGG16 transfer öğrenme mimarisi, ALS hastalığının tanısı için en başarılı sonuca ulaşmıştır. Tek başına spektrogram görüntülerinin kullanımı tek başına yineleme grafiği görüntülerinin kullanımına göre daha yüksek doğrulama sonucu sağlarken, iki görüntüye dönüşüm yönteminin birlikte kullanıldığı hibrit mimaride daha da yüksek doğruluk oranına ulaşılmıştır. Önerilen hibrit CNN modeli VGG16 transfer öğrenme mimarisine göre daha basit yapıdadır. Hibrit CNN mimarisi ve VGG16 mimarisi arasındaki parametre sayısı farkı (~138.500.000) fazla olmasına rağmen, ulaştıkları doğruluk oranları ve diğer istatistiksel metriklerin sonuçları arasındaki fark çok azdır. Günümüzde daha düşük işlem gücü gerektiren modellere ihtiyaç duyulduğu için, önerilen hibrit CNN modelinin gerçek zamanlı giyilebilir sistemlerde daha kullanışlı olacağı düşünülmektedir.

KAYNAKLAR

1. Dugger, B. N., and Dickson, D. W. (2017). Pathology of neurodegenerative Diseases. *Cold Spring Harbor Perspectives in Biology*, 9(7), a028035.
2. Hou, Y., Dan, X., Babbar, M., Wei, Y., Hasselbalch, S. G., Croteau, D. L., and Bohr, V. A. (2019). Ageing as a risk factor for neurodegenerative disease. *Nature Reviews Neurology*, 15(10), 565-581.
3. Benatru, I., Vaugoyeau, M., and Azulay, J. P. (2008). Postural disorders in Parkinson's disease. *Neurophysiologie Clinique/Clinical Neurophysiology*, 38(6), 459-465.
4. Masrori, P., and Van Damme, P. (2020). Amyotrophic lateral sclerosis: a clinical review. *European Journal of Neurology*, 27(10), 1918-1929.
5. Parsons, M. P., and Raymond, L. A. (2023). *Neurobiology of Brain Disorders*. United States of America: Academic Press, 275-292.
6. Lima, A. A., Mridha, M. F., Das, S. C., Kabir, M. M., Islam, M. R., and Watanobe, Y. (2022). A comprehensive survey on the detection, classification, and challenges of neurological disorders. *Biology*, 11(3), 469.
7. Pathak, N., Vimal, S. K., Tandon, I., Agrawal, L., Hongyi, C., and Bhattacharyya, S. (2021). Neurodegenerative disorders of alzheimer, parkinsonism, amyotrophic lateral sclerosis and multiple sclerosis: an early diagnostic approach for precision treatment. *Metabolic Brain Disease*, 37, 1-38.
8. Khan, P., Kader, M. F., Islam, S. R., Rahman, A. B., Kamal, M. S., Toha, M. U., and Kwak, K. S. (2021). Machine learning and deep learning approaches for brain disease diagnosis: principles and recent advances. *IEEE Access*, 9, 37622-37655.
9. Negi, P. C., Negi, S., and Sharma, N. (2022, November). *Gait analysis-based identification of neurodegenerative diseases using machine learning techniques*. International Conference on Advances in Computing, Communication and Materials (ICACCM), Dehradun, 1-6.
10. Fraiwan, L., and Hassanin, O. (2021). Computer-aided identification of degenerative neuromuscular diseases based on gait dynamics and ensemble decision tree classifiers. *Plos One*, 16(6), e0252380.
11. Setiawan, F., Liu, A. B., and Lin, C. W. (2022). Development of neuro-degenerative diseases' gait classification algorithm using convolutional neural network and wavelet coherence spectrogram of gait synchronization. *IEEE Access*, 10, 38137-38153.
12. Daliri, M. R. (2012). Automatic diagnosis of neuro-degenerative diseases using gait dynamics. *Measurement*, 45(7), 1729-1734.
13. Zeng, W., and Wang, C. (2015). Classification of neurodegenerative diseases using gait dynamics via deterministic learning. *Information Sciences*, 317, 246-258.

14. Amin, S., and Singhal, A. (2017, October). *Identification and classification of neuro-degenerative diseases using feature selection through PCA-LD*. 4th IEEE Uttar Pradesh section international conference on electrical, computer and electronics (UPCON), Mathura, 578-586.
15. Ye, Q., Xia, Y., and Yao, Z. (2018). Classification of Gait Patterns in Patients with Neurodegenerative Disease Using Adaptive Neuro-Fuzzy Inference System. *Computational and Mathematical Methods in Medicine*, 2018(1), 9831252.
16. Baratin, E., Sugavaneswaran, L., Umopathy, K., Ioana, C., and Krishnan, S. (2015). Wavelet-based characterization of gait signal for neurological abnormalities. *Gait and Posture*, 41(2), 634-639.
17. Klomsae, A., Auephanwiriyaikul, S., and Theera-Umpon, N. (2018). String Grammar Unsupervised Possibilistic Fuzzy C-Medians for Gait Pattern Classification in Patients with Neurodegenerative Diseases. *Computational Intelligence and Neuroscience*, 2018(1), 1869565.
18. Xia, Y., Gao, Q., and Ye, Q. (2015). Classification of gait rhythm signals between patients with neuro-degenerative diseases and normal subjects: Experiments with statistical features and different classification models. *Biomedical Signal Processing and Control*, 18, 254-262.
19. Saljuqi, M., and Ghaderyan, P. (2023). Combining homomorphic filtering and recurrent neural network in gait signal analysis for neurodegenerative diseases detection. *Biocybernetics and Biomedical Engineering*, 43(2), 476-493.
20. Pham, T. D. (2017). Texture classification and visualization of time series of gait dynamics in patients with neuro-degenerative diseases. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 26(1), 188-196.
21. Ghaderyan, P., and Beyrami, S. M. G. (2020). Neurodegenerative diseases detection using distance metrics and sparse coding: A new perspective on gait symmetric features. *Computers in Biology and Medicine*, 120, 103736.
22. Elden, R. H., Al-Atabany, W., and Ghoneim, V. F. (2018, December). *Gait variability analysis in neurodegenerative diseases using nonlinear dynamical modelling*. 9th Cairo International Biomedical Engineering Conference (CIBEC), Cairo, 41-44.
23. Zhao, H., Xie, J., Chen, Y., Cao, J., Liao, W. H., and Cao, H. (2024). Diagnosis of neurodegenerative diseases with a refined Lempel–Ziv complexity. *Cognitive Neurodynamics*, 18(3), 1153-1166.
24. Beyrami, S. M. G., and Ghaderyan, P. (2020). A robust, cost-effective and non-invasive computer-aided method for diagnosis three types of neurodegenerative diseases with gait signal analysis. *Measurement*, 156, 107579.
25. Setiawan, F., and Lin, C. W. (2021). Identification of neurodegenerative diseases based on vertical ground reaction force classification using time–frequency spectrogram and deep learning neural network features. *Brain Sciences*, 11(7), 902.

26. Zhao, A., Qi, L., Dong, J., and Yu, H. (2018). Dual channel LSTM based multi-feature extraction in gait for diagnosis of Neurodegenerative diseases. *Knowledge-Based Systems*, 145, 91-97.
27. Faisal, M. A. A., Chowdhury, M. E., Mahbub, Z. B., Pedersen, S., Ahmed, M. U., Khandakar, A., and AbdulMoniem, M. (2023). NDDNet: A deep learning model for predicting neurodegenerative diseases from gait pattern. *Applied Intelligence*, 53(17), 20034-20046.
28. Lin, C. W., Wen, T. C., and Setiawan, F. (2020). Evaluation of vertical ground reaction forces pattern visualization in neurodegenerative diseases identification using deep learning and recurrence plot image feature extraction. *Sensors*, 20(14), 3857.
29. Guo, Y., Yang, J., Liu, Y., Chen, X., and Yang, G. Z. (2022). Detection and assessment of Parkinson's disease based on gait analysis: A survey. *Frontiers in Aging Neuroscience*, 14, 916971.
30. Moon, Y., Sung, J., An, R., Hernandez, M. E., and Sosnoff, J. J. (2016). Gait variability in people with neurological disorders: A systematic review and meta-analysis. *Human Movement Science*, 47, 197-208.
31. İnternet: PhysioNet: Gait in Neurodegenerative Disease Database. URL: <https://physionet.org/content/gaitnidd/1.0.0/> , Son Erişim Tarihi: 23.04.2024.
32. Hausdorff, J. M., Lertratanakul, A., Cudkowicz, M. E., Peterson, A. L., Kaliton, D., and Goldberger, A. L. (2000). Dynamic markers of altered gait rhythm in amyotrophic lateral sclerosis. *Journal of Applied Physiology*, 88(6), 2045-2053.
33. Akman Aydın, E. (2019, August). *Dynamic Time Warping Based Feature Extraction for Motor Imagery-Near Infrared Spectroscopy Signals*. 8th International Conference on Advanced Technologies (ICAT'19), Sarajevo, 298-303.
34. Switonski, A., Josinski, H., and Wojciechowski, K. (2019). Dynamic time warping in classification and selection of motion capture data. *Multidimensional Systems and Signal Processing*, 30, 1437-1468.
35. Peng, C. K., Buldyrev, S. V., Havlin, S., Simons, M., Stanley, H. E., and Goldberger, A. L. (1994). Mosaic organization of DNA nucleotides. *Physical Review e*, 49(2), 1685.
36. Hardstone, R., Poil, S. S., Schiavone, G., Jansen, R., Nikulin, V. V., Mansvelder, H. D., and Linkenkaer-Hansen, K. (2012). Detrended fluctuation analysis: a scale-free view on neuronal oscillations. *Frontiers in Physiology*, 3, 450.
37. Thompson, J. R., and Wilson, J. R. (2016). Multifractal detrended fluctuation analysis: Practical applications to financial time series. *Mathematics and Computers in Simulation*, 126, 63-88.

38. Kumar, S., Gu, L., Ghosh, N., and Mohanty, S. K. (2013, February). Multifractal detrended fluctuation analysis of optogenetic modulation of neural activity. *Optogenetics: Optical Methods for Cellular Control*, 8586, 8-13.
39. Linhares, R. R. (2023). Fractional poisson process: Long-range dependence in DNA sequences. *Model Assisted Statistics and Applications*, 18(1), 33-43.
40. Berthelot, B., Grivel, E., Legrand, P., and Giremus, A. (2021). Definition of the fluctuation function in the detrended fluctuation analysis and its variants. *The European Physical Journal B*, 94, 1-20.
41. Beran, J. (2017). *Statistics for long-memory processes*. New York: Routledge, 1-315.
42. Peng, C. K., Havlin, S., Stanley, H. E., and Goldberger, A. L. (1995). Quantification of scaling exponents and crossover phenomena in nonstationary heartbeat time series. *Chaos: An Interdisciplinary Journal of Nonlinear Science*, 5(1), 82-87.
43. Deng, H., Chen, W., Shen, Q., Ma, A. J., Yuen, P. C., and Feng, G. (2020). Invariant subspace learning for time series data based on dynamic time warping distance. *Pattern Recognition*, 102, 107210.
44. Senin, P. (2008). Dynamic time warping algorithm review. *Information and Computer Science Department University of Hawaii at Manoa Honolulu*, 855(1-23), 40.
45. Lahreche, A., and Boucheham, B. (2021). A comparison study of dynamic time warping's variants for time series classification. *International Journal of Informatics and Applied Mathematics*, 4(1), 56-71.
46. Keogh E. J. and Pazzani, M. J. (2001). *Derivative dynamic time warping*. Proceedings of the 2001 SIAM International Conference on Data Mining, Chicago, 1-11.
47. Belkhouja, T., Yan, Y., and Doppa, J. R. (2022). Dynamic time warping based adversarial framework for time-series domain. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 45(6), 7353-7366.
48. Permanasari, Y., Harahap, E. H., and Ali, E. P. (2019, November). Speech recognition using dynamic time warping (DTW). *Journal of Physics: Conference Series*, 1366(1), 012091.
49. Kowdiki, M., and Khaparde, A. (2021). Automatic hand gesture recognition using hybrid meta-heuristic-based feature selection and classification with dynamic time warping. *Computer Science Review*, 39, 100320.
50. Wang, X., Kyrarini, M., Ristić-Durrant, D., Spranger, M., and Gräser, A. (2016, May). *Monitoring of gait performance using dynamic time warping on IMU-sensor data*. 2016 IEEE International Symposium on Medical Measurements and Applications (MeMeA), Benevento, 1-6.

51. Diab, D. M., AsSadhan, B., Binsalleeh, H., Lambbotharan, S., Kyriakopoulos, K. G., and Ghafir, I. (2019, August). *Anomaly detection using dynamic time warping*. 2019 IEEE International Conference on Computational Science and Engineering (CSE) and IEEE International Conference on Embedded and Ubiquitous Computing (EUC), New York, 193-198.
52. Breitenbach, T., Wilkusz, B., Rasbach, L., and Jahnke, P. (2023). On a method for detecting periods and repeating patterns in time series data with autocorrelation and function approximation. *Pattern Recognition*, 138, 109355.
53. Sukhostat, L., and Imamverdiyev, Y. (2015). A comparative analysis of pitch detection methods under the influence of different noise conditions. *Journal of Voice*, 29(4), 410-417.
54. Alkhatib, R., Corbier, C., El Badaoui, M., Moslem, B., and Diab, M. O. (2015, August). *Sensors' Ground Reaction Force behavior for both Normal and Parkinson subjects-A qualitative study*. 2015 37th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC), Milan, 4186-4189.
55. Saadeh, W., Altaf, M. A. B., and Butt, S. A. (2017, October). *A wearable neuro-degenerative diseases detection system based on gait Dynamics*. 2017 IFIP/IEEE International Conference on Very Large Scale Integration (VLSI-SoC), Abu Dhabi, 1-6
56. Robnik-Šikonja, M., and Kononenko, I. (2003). Theoretical and empirical analysis of ReliefF and RReliefF. *Machine Learning*, 53, 23-69.
57. Zhang, D., Gong, E., Wu, W., Lin, J., Zhou, W., and Hong, B. (2012, August). *Spoken sentences decoding based on intracranial high gamma response using dynamic time warping*. 2012 Annual International Conference of the IEEE Engineering in Medicine and Biology, San Diego, 3292-3295
58. Naseer, N., and Hong, K. S. (2015). fNIRS-based brain-computer interfaces: a review. *Frontiers in Human Neuroscience*, 9, 3.
59. Hong, K. S., Khan, M. J., and Hong, M. J. (2018). Feature extraction and classification methods for hybrid fNIRS-EEG brain-computer interfaces. *Frontiers in Human Neuroscience*, 12, 246.
60. Marwan, N., Romano, M. C., Thiel, M., and Kurths, J. (2007). Recurrence plots for the analysis of complex systems. *Physics Reports*, 438(5-6), 237-329.
61. Mathunjwa, B. M., Lin, Y. T., Lin, C. H., Abbod, M. F., Sadrawi, M., and Shieh, J. S. (2022). ECG recurrence plot-based arrhythmia classification using two-dimensional deep residual CNN features. *Sensors*, 22(4), 1660.
62. Jablonski, A., and Dziejch, K. (2022). Intelligent spectrogram—A tool for analysis of complex non-stationary signals. *Mechanical Systems and Signal Processing*, 167, 108554.

63. Bruni, V., Tartaglione, M., and Vitulano, D. (2021). A pde-based analysis of the spectrogram image for instantaneous frequency estimation. *Mathematics*, 9(3), 247.
64. Sarker, I. H. (2021). Deep learning: a comprehensive overview on techniques, taxonomy, applications and research directions. *SN Computer Science*, 2(6), 420.
65. Ahmed, S. F., Alam, M. S. B., Hassan, M., Rozbu, M. R., Ishtiak, T., Rafa, N., and Gandomi, A. H. (2023). Deep learning modelling techniques: current progress, applications, advantages, and challenges. *Artificial Intelligence Review*, 56(11), 13521-13617.
66. Li, Z., Liu, F., Yang, W., Peng, S., and Zhou, J. (2021). A survey of convolutional neural networks: analysis, applications, and prospects. *IEEE Transactions on Neural Networks and Learning Systems*, 33(12), 6999-7019.
67. Shaheen, F., Verma, B., and Asafuddoula, M. (2016, November). *Impact of automatic feature extraction in deep learning architecture*. 2016 International conference on digital image computing: techniques and applications (DICTA), Gold Coast, 1-8.
68. Alzubaidi, L., Zhang, J., Humaidi, A. J., Al-Dujaili, A., Duan, Y., Al-Shamma, O., and Farhan, L. (2021). Review of deep learning: concepts, CNN architectures, challenges, applications, future directions. *Journal of Big Data*, 8, 1-74.
69. Khan, A., Sohail, A., Zahoor, U., and Qureshi, A. S. (2020). A survey of the recent architectures of deep convolutional neural networks. *Artificial Intelligence Review*, 53, 5455-5516.
70. Traore, B. B., Kamsu-Foguem, B., and Tangara, F. (2018). Deep convolution neural network for image recognition. *Ecological Informatics*, 48, 257-268.
71. Ribani, R., and Marengoni, M. (2019, October). *A survey of transfer learning for convolutional neural networks*. 2019 32nd SIBGRAPI conference on graphics, patterns and images tutorials (SIBGRAPI-T), Rio de Janeiro, 47-57
72. Yilmaz, D. (2020). Evaluation of gait behavior with state space vectors for classification of neurodegenerative diseases. *EJONS International Journal on Mathematic, Engineering and Natural Sciences*, 4(14), 1-12.
73. V. B. S. A and P. R. M. (2022). *Diagnosis of Neurodegenerative Diseases by Gait Analysis using Triblock CNN and Deep RQA Techniques*. 2022 International Conference on Automation, Computing and Renewable Systems (ICACRS), Pudukkottai, 762-770.
74. Lee, J. S., Yang, B. H., Lee, J. H., Choi, J. H., Choi, I. G., and Kim, S. B. (2007). Detrended fluctuation analysis of resting EEG in depressed outpatients and healthy controls. *Clinical Neurophysiology*, 118(11), 2489-2496.
75. Meurisse, G. M., Dierick, F., Schepens, B., and Bastien, G. J. (2016). Determination of the vertical ground reaction forces acting upon individual limbs during healthy and clinical gait. *Gait and Posture*, 43, 245-250.

76. Liu, X., Zhao, C., Zheng, B., Guo, Q., Duan, X., Wulamu, A., and Zhang, D. (2021). Wearable devices for gait analysis in intelligent healthcare. *Frontiers in Computer Science*, 3, 661676.
77. Deb, R., An, S., Bhat, G., Shill, H., and Ogras, U. Y. (2022). A systematic survey of research trends in technology usage for Parkinson's disease. *Sensors*, 22(15), 5491.
78. Özeoğlu, İ. G., and Aydın, E. A. (2024). Combining features on vertical ground reaction force signal analysis for multiclass diagnosing neurodegenerative diseases. *International Journal of Medical Informatics*, 191, 105542.







Gazili olmak ayrıcalıktır