T.C.

YILDIZ TEKNİK ÜNİVERSİTESİ

FEN BİLİMLERİ ENSTİTÜSÜ

DERİN ÖĞRENME İLE PARKİNSON HASTALIĞININ SINIFLANDIRILMASI

Pedram KHATAMINO

YÜKSEK LİSANS TEZİ

Elektronik ve Haberleşme Mühendisliği Anabilim Dalı

Elektronik Mühendisliği Programı

Danışman

Dr. Öğr. Üyesi Lale ÖZYILMAZ

Mayıs, 2019

T.C.

YILDIZ TEKNİK ÜNİVERSİTESİ

FEN BİLİMLERİ ENSTİTÜSÜ

DERİN ÖĞRENME İLE PARKİNSON HASTALIĞININ SINIFLANDIRILMASI

Pedram KHATAMINO tarafından hazırlanan tez çalışması 15.05.2019 tarihinde aşağıdaki jüri tarafından Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü Elektronik ve Haberleşme Mühendisliği Anabilim Dalı, Elektronik Mühendisliği Programı **YÜKSEK LİSANS TEZİ** olarak kabul edilmiştir.

Dr. Öğr. Üyesi Lale ÖZYILMAZ

Yıldız Teknik Üniversitesi

Danışman

Jüri Üyeleri

Dr. Öğr. Üyesi Lale ÖZYILMAZ, Danışman
Yıldız Teknik Üniversitesi _____

Dr. Öğr. Üyesi Serkan Kurt, Üye
Yıldız Teknik Üniversitesi _____

Prof. Dr. Mehmet SAĞBAŞ, Üye
Yeni Yüzyıl Üniversitesi _____

Danışmanım Dr. Öğr. Üyesi Lale ÖZYILMAZ sorumluluğunda tarafımca hazırlanan Derin Öğrenme ile Parkinson Hastalığı Sınıflandırılması tezinde internet kaynaklı public kullanıma açık veri setleri kullandığımı, diğer kaynaklardan aldığım bilgileri ana metin ve referanslarda eksiksiz gösterdiğimi, araştırma verilerine ve sonuçlarına ilişkin çarpıtma ve/veya sahtecilik yapmadığımı, çalışmam süresince bilimsel araştırma ve etik ilkelerine uygun davrandığımı beyan ederim. Beyanımın aksinin ispatı halinde her türlü yasal sonucu kabul ederim.

Pedram KHATAMINO

İmza

Aileme

TEŞEKKÜR

Bu çalışma ve araştırma sırasında desteğini esirgemeyen ve değerli bilgilerini benimle paylaşan danışman hocam Dr. Öğr. Üyesi Lale ÖZYILMAZ'a, çalışmanın her aşamasında zaman ayırıp tecrübesi ve değerli bilgilerini bana aktaran Dr. İsmail CANTÜRK'e, hayatımın her döneminde bana inanan ve destek olan çok sevdiğim aileme, araştırma boyunca sürekli motivasyonumu yüksek tutan arkadaşlarım Navid ABEDİASL ve Mahdi NEZHADASAD'a ve çalışmada yardımı olan herkese teşekkür ederim.

Pedram KHATAMINO

İÇİNDEKİLER

SİMGE LİSTESİ VII
KISALTMA LİSTESİ VIII
ŞEKİL LİSTESİ IX
TABLO LİSTESİ X
ÖZET XI
ABSTRACT XIII
1 GİRİŞ 15
1.1 Literatür Özeti 15
1.2 Araştırma Yöntemi 16
1.3 Tezin Amacı 17
1.4 Hipotez 17
2 PARKİNSON HASTALIĞI VE VERİ SETLERİ 18
2.1 Parkinson Hastalığı 18
2.2 Kullanılan Veri Setleri 19
2.2.1 Cerrahpaşa Tıp Fakültesi El Yazısı Veri Seti 19
2.2.2 São Paulo Eyalet Üniversitesi El Yazısı Veri Seti 23
3 DERİN ÖĞRENME VE METODOLOJİ 25
3.1 Derin öğrenme 25
3.2 Eğiticili öğrenme 25
3.3 Sınıflandırma 26
3.4 Theano 26
3.5 Keras 27

3.6 Evrişimsel Sinir Ağları 27
3.6.1 Konvolüsyon katmanı 28
3.6.2 Havuzlama Katmanı 30
3.6.3 Tam Bağlı Katman 30
3.6.4 Doğrultulmuş Lineer Aktivasyon Birimi (ReLU) 31
3.6.5 Softmax 31
3.6.6 Stokastik Gradyan Düşümü 32
3.7 k-Katlamalı Çapraz Doğrulama 32
3.8 Destek Vektör Makinesi (SVM) 34
3.9 Naive Bayes (NB) 36
3.10 Metodoloji 38
3.11 Oluşturulan CNN modeli 44
4 SONUÇ VE ÖNERİLER 48
4.1 Cerrahpaşa Tıp Fakültesi El Yazısı Veri Seti Sonuçları 48
4.1.1 Cerrahpaşa veri seti Sonuçlarının Yorumlanması ve Öneriler 51
4.2 São Paulo Eyalet Üniversitesi El Yazısı Veri Seti Sonuçları 52
Kaynakça 57
Tezden Üretilmiş Yayınlar 60

SİMGE LİSTESİ

Vt	t zamanındaki hız
V	hız
Xt	t zamanındaki X koordinatı
Yt	t zamanındaki Y koordinatı
At	anlık ivme
h^k	k indisli öznitelik haritası
W^k	ağırlık olarak bilinen filter
x	giriş verisi
b_k	eşik değeri
$P(A\|B)$	B olayı önceliği ile A olayının olasılığı
$P(B\|A)$	A olayı önceliği ile B olayının olasılığı
$P(A)$	A olayının olasılığı
$P(B)$	B olayının olasılığı

KISALTMA LİSTESİ

API	Application Programming Interface
CNN	Convolutional Neural Network
CNTK	Microsoft Cognitive Toolkit
DST	Dinamik Spiral Testi
MLP	Multi-layer Perceptron
MSA	Multiple System Atrophy
NB	Naive Bayes
PD	Parkinson Disease
PSP	Progressive Supranuclear Palsy
ReLU	Rectified Linear Activation Unit
SGD	Stochastic Gradient Descent
SST	Statik Spiral Testi
STCP	Stability Test on Certain Point
SVM	Support Vector Machine
YSA	Yapay Sinir Ağları

ŞEKİL LİSTESİ

Şekil 2.1 Hasta ve sağlıklı bireylerin çizimlerinden öznitelik sinyalleri 21
Şekil 2.2 Veri setinden bazı spiral örnekleri 23
Şekil 2.3 Veri setinden bazı labirent örnekleri 23
Şekil 3.1 Rakam tespiti için bir evrişimsel sinir ağı: LeNet-5 mimarisi 28
Şekil 3.2 Sol: giriş verisinde alıcı alan, sağ: konvolüsyon nöronlarının işlevi 29
Şekil 3.3 Maksimum havuzlama işlemi 30
Şekil 3.4 ReLU aktivasyon fonksiyonun şematik görünümü 31
Şekil 3.5 k-atlamalı çapraz doğrulama 34
Şekil 3.6 (a): iki boyutta hiper-düzlem, (b): üç boyutta hiper-düzlem 35
Şekil 3.7 Destek vektörleri 35
Şekil 3.8 Sol: muhtemel hiper-düzlemler, sağ: optimal hiper-düzlem 36
Şekil 3.9 Gauss dağılımı 38
Şekil 3.10 Görsel öznitelik veri ön işleme uygulaması 39
Şekil 3.11 Sinyal tabanlı kare öznitelik veri ön işleme uygulaması 40
Şekil 3.12 SST testinin spiral örnekleri 41
Şekil 3.13 DST testinin spiral örnekleri 41
Şekil 3.14 Veri setinden çıkarılan iki çeşit görüntü 42
Şekil 3.15 Veriye uygulanan ön işleme aşamaları 43
Şekil 3.16 Oluşturulan CNN modeli 47

TABLO LİSTESİ

Tablo 3.1 Oluşturulan CNN modelinin detayları 46
Tablo 4.1 Farklı optimizasyon algoritmaları karşılaştırması 48
Tablo 4.2 SST spiral ve sinyal tabanlı görüntüleri için CNN modeli sonuçları 49
Tablo 4.3 DST spiral ve sinyal tabanlı görüntüleri için CNN modeli sonuçları 49
Tablo 4.4 SST ve DST kombinasyonu veri setinin sonuçları 50
Tablo 4.5 Spiral veri setinin sonuçları 53
Tablo 4.6 Labirent veri setinin sonuçları 54
Tablo 4.7 Spiral veri seti 4-katlamalı çapraz doğrulama Sonuçları 55
Tablo 4.8 Labirent veri seti 4-katlamalı çapraz doğrulama sonuçları 55

ÖZET

DERİN ÖĞRENME İLE PARKİNSON HASTALIĞININ SINIFLANDIRILMASI

Pedram KHATAMINO

Elektronik ve Haberleşme Mühendisliği Anabilim Dalı

Yüksek Lisans Tezi

Danışman: Dr. Öğr. Üyesi Lale ÖZYILMAZ

Parkinson hastalığı modern dünya yaşam tarzı sebebiyle geniş kitlelere yayılmıştır. Bu hastalık ileri yaşlardaki kişilerde daha sık görülmektedir ve kişinin konuşma becerisinin kısıtlanmasına, el hareketlerinde titremeye ve genel olarak hareket ve kas problemlerine sebep olmaktadır. Parkinson hastalığı hasta kişilerin yaşam standartlarını düşürür ve doğal olarak onların ailelerinin de yaşam tarzını etkiler. Dünya genelinde 10 milyonu aşkın Parkinson hastası bulunnmaktadır. Bu kişilerin çoğu fiziksel olarak iyi bir seviyede olmadıkları için noninvazif hastalık teşhisi yöntemleri onlar için daha uygundur. Parkinson alanındaki kliniklerde en yaygın noninvazif yöntemlerinden biri ise el yazısı testidir.

Bu noninvazif yöntemlerle toplanan veri setlerinin genelde makine öğrenmesi ile analiz edilmesi uygun olmaktadır. Bu sebeple Parkinson hastalığı teşhisi literatüründe farklı tekniklerle yapılmış bir çok çalışma bulunmaktadır. Makine öğrenme tekniklerinin ve parametre optimizasyonun belirli bir kuralı olmadığından çoğu zaman deneme yanılma yöntemi ile cevaba ulaşılmaktadır. Bu yüzden farklı yaklaşımlar içeren deneyler, literatürü zenginleştirip geliştirmektedir.

Bu tezde iki farklı veri seti üzerinde çalışmalar yapılmıştır ve genel olarak evrişimsel sinir ağlarının (CNN-Convolutional Neural Network) sınıflandırma işleminde genelleştirme başarısı incelenmiştir. Veri setleri iki farklı ülkede ve farklı şartlarda toplanıldığından, aynı modelin bu iki farklı durumda nasıl performans göstereceği, genelleme becerisi için mantıklı bir parametre olacaktır.

Ayrıca bu araştırmada evrişimsel sinir ağları, destek vektör makinesi (SVM- Support Vector Machine) ve Naive Bayes gibi algoritmalarla karşılaştırılmıştır. Klasikleşmiş makine öğrenmesi algoritmalarının sadeliği ve işlevselliği ile CNN'nin öğrenme kabiliyetini bahsedilen veri setlerinde karşılaştırmak ve araştırmak bu çalışmanın temel amaçlarındandır.

Cerrahpaşa tıp fakültesinde toplanan veri setinden öznitelik görüntüleri çıkartma işlemi geliştirilip farklı sınıflandırıcılarla deneyler yapılmıştır. Yapılan araştırma sonucunda yenilikçi DST'nin (Dinamik Spiral Testi) Parkinson hastalığı teşhisinde önemli rol oynayabileceği görülmüştür. Bu veri setinde verilerin %75'i eğitim ve %25'i test verisi olarak alındığında CNN ağında %88'lik başarı yüzdesi elde edilmiştr.

São Paulo üniversitesi veri setinde ise bu veri setini toplayan ve geliştiren ekibin yayınındaki sonuçlar referans alınarak, bu sonuçları geliştirme yolları araştırılmıştır. SVM ve NB sonuçları birebir karşılaştırıldığında referans çalışmanın sonuçlarından daha başarılı sonuçlar elde edildiği görülmüştür. Ayrıca CNN tabanlı sınıflandırıcı ile spiral ve labirent görüntülerde ortalama %80 başarı sağlanmıştır.

Sonuç olarak bu çalışma, derin öğrenme ile Parkinson hastalığı teşhisinde efektif sonuçlar elde edileceğini desteklemektedir.

Anahtar Kelimeler: Parkinson hastalığı, evrişimsel sinir ağları, derin öğrenme, el yazısı testi

ABSTRACT

Classification of Parkinson's Disease with Deep Learning

Pedram KHATAMINO

Department of Communication and Electronics Engineering

Master Thesis

Advisor: Assist. Prof. Lale ÖZYILMAZ

Parkinson's disease has spread to worldwide due to modern world lifestyle. Parkinson's disease is more common in older people. This disease leads to the limitation of the person's speaking skills, tremors in hand movements and movement and muscle problems in general. Parkinson's disease reduces the standard of living of sick people and naturally affects their families. There are more than 10 million patients with Parkinson's disease worldwide. Because most of these people are not physically at a good level, non-invasive methods are more suitable for them. One of the most common non-invasive methods in clinics in the Parkinson area is the handwriting test.

The data sets collected by these non-invasive methods are generally suitable for analyzing by machine learning techniques. For this reason, there are many studies conducted in the literature of the diagnosis of Parkinson's disease by different techniques. Since there is no specific rule of machine learning techniques and parameter optimization, it is often to use the trial and error approach. Therefore, experiments with different approaches will enrich and improve the literature.

In this thesis, two different datasets have been studied and generalization success in the classification process of convolutional neural networks has been investigated. Since data sets are collected in two different countries and under different conditions, how the same model will perform in these two different situations will be a suitable parameter for the generalization ability.

In addition, this study contains compression of algorithms such as convolutional neural networks, support vector machine and naive bayes. One of the main purposes of this study is to compare the simplicity and functionality of conventional machine learning algorithms to CNN's learning ability in the mentioned datasets.

In the data set collected in Cerrahpaşa Medical Faculty, feature images extraction methods were designed and experiments were performed with different classifiers. As a result of the research, it was seen that innovative DST test could play an important role in the diagnosis of Parkinson's disease. In %75 training and %25 test data range of the data set, CNN model reached to %88 classification accuracy.

In São Paulo University data set, the previous researches on this dataset considered as reference results; which is done by collecting and developing team of this data set. The way of developing these results were researched in this thesis. When the results of SVM and NB were compared, it was found that the results of this study were more successful. In addition, an average %80 classification accuracy was achieved in spiral and meander images with CNN-based classifier.

In conclusion, this study supports effective results in the diagnosis of Parkinson's disease with deep learning.

Keywords: Parkinson’s disease, convolutional neural networks, deep learning, handwriting test

1
GİRİŞ

1.1 Literatür Özeti

Parkinson hastalığı (PD), evrensel bir halk sağlığı sorunudur. Sağlıklı insanlar (kontrol) ve Parkinson hastası olan kişiler arasında sınıflandırma işlemini yapmak için makine öğrenimine dayalı yöntemler kullanılabilir. Derin öğrenme ile Parkinson hastalığı tespit etme ve sınıflandırma literatüründe özellikle son yıllarda birçok farklı ve başarılı çalışmalar ve yöntemler gözlenmektedir. Özellikle bazı araştırmacılar derin öğrenmeyi pratik ve efektif bir şekilde gerçek dünya problemlerinin çözümünde kullanma amacıyla Parkinson hastalığı için noninvazif test yöntemleri ile daha iyi sonuçlar alabilecekleri yöntemleri araştırmaktadırlar. Deride herhangi bir oyuk ve kesik oluşturmayacak veya vücudun herhangi bir uzvuna cerrahi operasyon içermeyen medikal teşhis veya tedavi yöntemlerine noninvazif yöntemler denilmektedir. Parkinson hastalığını değerlendirmek için kullanılan günümüz tekniklerinin çoğu, büyük ölçüde insan uzmanlığına dayanmaktadır [1]. Literatürde önerilen noninvazif yaklaşımlar, yaşlı insanlar için daha uygundur ayrıca uygulanması için uzman bir görevli gerektirmez. Makine öğrenmesi, evrişimsel sinir ağları ve derin öğrenme literatüründeki çalışmalar incelendiğinde araştırmacıların noninvazif yöntemlerle oluşturulan veri setleri üzerinde genellikle yüksek doğruluk oranları ile sınıflandırma yapabildikleri gözlenmiştir. Bu veri setleri genel olarak konuşma bozuklukları, hareket becerilerinde deformasyon ve el yazısı titremesi gibi verilerden oluşmuştur. Yapılan çalışmalarda birçok farklı makine öğrenmesi yöntemi kullanılmıştır [2].

Örneğin Hariharan ve diğ. 2014, bir Parkinson hastalığı konuşma veri setinin sınıflandırılması için özellik ön işleme, özellik azaltma ve seçim yöntemlerinin bir kombinasyonu olan hibrit bir akıllı sistemi tanıtmış ve % 100 sınıflandırma doğruluğuna ulaşmıştır [3]. Her ne kadar, PD tanıma çalışmaları çoğunlukla konuşma sinyalleri veri setleri üzerinde yapılsa da; yeni bir yaklaşım olarak, bazı

araştırmacılar literatürde yaygın olan konuşma veri setleri yerine PD tanıma için el yazısı testi tabanlı veri setleri hazırlamış veya kullanmışlardır. Örnek olarak Pereira, Papa ve diğ. 2016, ImageNet, CIFAR-10 ve LeNet gibi farklı CNN yapılarını kullanarak spiral ve labirent şekillerinden oluşan PD el yazısı veri setinin dinamikleri üzerinde sınıflandırma işlemi yapmış ve genel olarak ortalama %80 doğruluğa ulaşmışlardır [4]. Aynı grup yazar 2018'de bir önceki çalışmalarını geliştirmek amacıyla veri seti testlerini çoğaltıp 6 teste çıkartmışlardır ve aynı zamanda farklı öznitelik çıkartma işlemleri ile veri setinden maksimum verim almayı amaçlamışlardır. Yeni ve farklı bir yaklaşımla tüm testlerin sonuçlarını bir kombinasyon biçiminde PD tanıma için farklı CNN yapılarında değerlendirmişlerdir. Sonuç olarak yapılan çalışmada testlerin bir kombinasyon olarak değerlendirildiğinde doğruluk yüzdesi artmıştır [5]. Moetesum ve diğ. 2018, PD sınıflandırma için el yazısı çizimlerinin dinamik özellikleri yerine sadece görsel özellikleri kullanmıştır. Belirli kelime ve spiral testlerinden oluşan veri seti üzerinde yapılan bu çalışmada, önerilen CNN tabanlı SVM sınıflandırıcı modeli ile %83 doğruluk oranına ulaşılmıştır [6]. Başka bir çalışmada, Drotár ve diğ. 2016, bir PD el yazısı veri setinin kinematik ve basınç özelliklerini analiz etmiş ve farklı sınıflandırıcılarla sonuçlar elde etmişlerdir. Söz konusu çalışmada SVM sınıflandırıcı ile en yüksek doğruluk oranına yani %81.3 'e ulaşılmıştır [7]. Parkinson hastalığı sınıflandırılması için literatür incelendiğinde çoğu çalışmada farklı türde veri setleri kullanılmasına rağmen CNN'lerin genel başarısı görülmektedir. Bu yüksek sınıflandırma doğruluk oranı CNN modellerinin farklı veri setlerinin özniteliklerini otomatik algılayan adaptif yapısını ortaya koymaktadır.

1.2 Araştırma Yöntemi

Bu çalışmada araştırmanın her aşamasında yüksek doğruluk ve optimize sonuçlara ulaştırabilecek yöntemler seçilmiştir. Üzerinde analiz yapılan el yazısı veri setleri İstanbul Üniversitesi Cerrahpaşa Tıp Fakültesi Nöroloji Anabilim Dalından ve Brezilya'nın São Paulo Eyalet Üniversitesinden alınmıştır. Derin öğrenme-evrişimsel sinir ağı yapısının resim sınıflandırma problemlerinde yüksek doğruluk oranı sağlaması yapılan deneylerde görülmüştür. Öte yandan her veri setindeki resimlere özel ön işleme teknikleri ile öznitelik çıkartma yöntemi geliştirilip

uygulanmıştır. Oluşturulan modelin başarısını ölçmek maksadı ile farklı eğitim ve test oranlarıyla elde edilen sonuçlar, birbirleriyle kıyaslanmıştır. Ayrıca São Paulo veri setini toplayan ve geliştiren ekibin çalışma sonuçlarını geliştirme yolları araştırılmıştır.

1.3 Tezin Amacı

Tezin amacı, evrişimsel sinir ağları tabanlı sınıflandırıcı modellerin, resimlerden öznitelik öğrenme yeteneğinden faydalanarak pratik bir medikal hastalık teşhisi işlemine katkı yapmaktır.

1.4 Hipotez

Evrişimsel sinir ağları ile resimlerden ayırt edici öznitelikleri otomatik filtrelerle saptayıp öğrenme sürecinde kullanarak sınıflandırma işlemini gerçekleştirmek bu tezin ana hipotezidir. Ayrıca bu çalışma, evrişimsel sinir ağlarının esnek öğrenme becerisi nedeniyle SVM ve NB sınıflandırıcılarına üstünlük sağlamasını desteklemektedir.

2
PARKİNSON HASTALIĞI VE VERİ SETLERİ

2.1 Parkinson Hastalığı

Parkinson hastalığı, hipotalamus tarafından salgılanan bir nörohormonun (dopamin) azalması ile tetiklenen nörodejeneratif ve sürekli bir hastalıktır. Parkinson, motor (hareket) ve motorla ilgisi olmayan semptomlarla karakterize olan ilerleyici bir nörolojik durumdur. Birçok yaygın semptomun yanı sıra, her kişide bu durumun farklı bireysel semptomları gözlenebilmektedir. Aslında, Parkinson hastalığını benzer klinik semptomlara sahip diğer durumlardan ayırt edebilecek tutarlı, güvenilir bir test yoktur.

Parkinson hastalığı olan kişiler, esasen Parkinsonizm semptomları ve klinik belirtiler ile ilişkilendirilir. Hipokinezi (hareket eksikliği), bradikinezi (hareketin yavaşlığı), sertlik (bilek, omuz ve boyun) ve titreme (dopamin ve asetilkolin gibi nörotransmitterlerin dengesizliği) Parkinsonizm belirtileridir. Parkinsonizm aynı zamanda ilaç ve daha nadir görülen, çoklu beyin damarı tıkanıklığı, progresif süpranükleer felç (PSP) ve çoklu sistem atrofisi (MSA) gibi dejeneratif nedenlerden ortaya çıkabilmektedir [8].

PD semptomları genellikle 50 ve 60 yaşları arasında ortaya çıkmaya başlar, yavaş yavaş gelişir ve sıklıkla bu kişiler tarafından fark edilmez. Genellikle titreme, PD'li kişi veya aile bireylerinin dikkatini çektiği ilk semptomdur [9]. Başlangıçta titreme sadece bir kolda veya bacakta ya da sadece vücudun bir tarafında görülebilir. Titreme çene, dudak ve dili de etkileyebilir. Hastalık ilerledikçe, titreme vücudun her iki tarafına da yayılabilir. Diğer belirtiler arasında depresyon ve yutma, çiğneme ve konuşmada zorluk; idrar sorunları ya da kabızlık; cilt problemleri ve uyku bozuklukları gibi diğer hareket değişiklikleri yer almaktadır. Araştırmalar sonucunda, dünya genelinde neredeyse 10 milyon insan bu zor tıbbi durumla yaşamlarını sürdürmektedir [10, 11]. Genel olarak, PD yaşlı insanların hareketlerinin anormalliğini artırmaktadır. Bu durum, hayati fonksiyonları

etkileyerek hastanın ve ailesinin yaşam kalitesi üzerinde olumsuz sonuçlara neden olmaktadır [12]. Bu hastalık, ilk kez 1817'de İngiliz fizikçi Doktor James Parkinson tarafından “shaking palsy” olarak kamuoyuna tanıtıldı [13].

Günümüzde PD için kesin bir tedavi yoktur, ancak dopaminerjik olarak adlandırılan ilaçlar genellikle kasların sertliğini azaltmaya, hızını ve hareket koordinasyonunu artırmaya ve titremeyi azaltmaya yardımcı olur.

Genelde yaşlı kişilerin fiziksel ve sağlık durumları nedeniyle, Parkinson hastalığını teşhis etmek için noninvazif yöntemler daha uygundur. Bu yöntemlerde genelde kişilere klinik operasyon gereksinimi olmayacak testler yapılır. Oluşturulan veri setleri hastalık teşhisi yöntemleri geliştirme açısından çok yararlı olmaktadırlar. Makine öğrenmesi algoritmaları ile bu tür veri setlerini analiz etmek mümkündür. Bu nedenle, makine öğrenmesinin sınıflandırma yeteneğinden yararlanabilecek konuşma, hareket ve el yazısı veri setleri literatürde mevcuttur. Bu tez çalışmasında ise el yazısı veri setleri incelenmiştir.

2.2 Kullanılan Veri Setleri

Bu çalışma için iki farklı Parkinson el yazısı veri seti üzerinde analiz yapılmıştır. Bunlardan biri İstanbul Üniversitesi Cerrahpaşa Tıp Fakültesi Nöroloji Anabilim Dalı'nda diğeri ise Brezilya'nın São Paulo Eyalet Üniversitesinde toplanan el yazısı testlerinden oluşan veri setleridir. Bu bölümde analiz için kullanılan veri setlerine dair genel bilgiler yer almaktadır.

2.2.1 Cerrahpaşa Tıp Fakültesi El Yazısı Veri Seti

El yazısı (HW- Hand Writing) veri seti İstanbul Üniversitesi Cerrahpaşa Tıp Fakültesi Nöroloji Anabilim Dalı'nda toplanmıştır. Bu veri seti, iki gruba ayrılan bireylerin çizdikleri spiral testlerine ilişkin zaman serisi bilgileri içermektedir. Gruplar şu şekildedir:

- Sağlıklı kişiler (kontrol)
- Parkinson hastaları (PD)

Veri seti, 57 hasta (PD) ve 15 sağlıklı (kontrol) birey olmak üzere 72 bireyden oluşmaktadır. Testler her bir kişiden aynı şekilde alınmıştır (test esnasında

şekillerin içten dışa doğru çizilmesi yönünde hastalara önerilerde bulunulmuştur). Bu testlerin temel amacı, Parkinson hastalarının motor (hareket) aktivitelerini sağlıklı insanlara göre değerlendirmektir. Söz konusu el yazısı veri setinde üç tip el yazısı testi vardır:

- Statik Spiral Testi (SST)
- Dinamik Spiral Testi (DST)
- Belirli Noktada Stabilite Testi (STCP)

Söz konusu veri seti Wacom Cintiq 12WX grafik tablet olarak adlandırılan bir cihaz kullanılarak toplanmıştır. İlk önce, bu cihaz tıbbi olmayan amaçlar için tasarlanmıştır ancak sonradan PD tanıma işlemine uygun hassas ve detaylı kayıt özelliğinin adaptasyonu, veri setini oluşturmak için çok yararlı olmuştur. Tablette çizilen olgunun dijital kalemle sayısallaştırılmış sonuçlarını PC'nin LCD ekranında gösterebilen, C# platformunda geliştirilen bu cihazın yazılımı, çizimlerin zaman serisi bilgilerini tespit edebilmekte ve saklayabilmektedir.

2.2.1.1 Statik Spiral Testi

Veri setinin ilk testi, klinik tanı operasyonlarında çok yaygın olan SST'dir. Bu testte, ilk olarak spiral örneği ekranda belirir, daha sonra hastaların dijital kalemle gördükleri olgudan yola çıkarak tekrar resmetmeleri istenir; daha önceden bahsedilen yazılım, el yazısı çizimlerinin koordinatlarını ve daha spesifik dinamiklerini zaman serisi formatında toplayabilmektedir. Genel olarak Parkinson hastalığının noninvazif tanı literatüründe yaygın olan bu test, hastaların titreme oranını ve motor işlevselliğini değerlendirmek için geliştirilmiştir.

2.2.1.2 Dinamik Spiral Testi

Bu veri seti üzerinde uygulanan ikinci test DST'dir. Bu testte ekrana çıkan spiral olgular sabit olmayıp, belirli zaman aralıklarında ortadan kalkar; bu yüzden hastalar açısından SST'den daha karmaşıktır. DST'nin bu özelliği, doğal olarak Parkinson hastasının spiral olgusunu hatırlamasını zorlaştırır. Gözlemler, çoğu hastanın spiral olgularını geri çizerken tam olarak takip edemediklerini ortaya koymaktadır. Bu

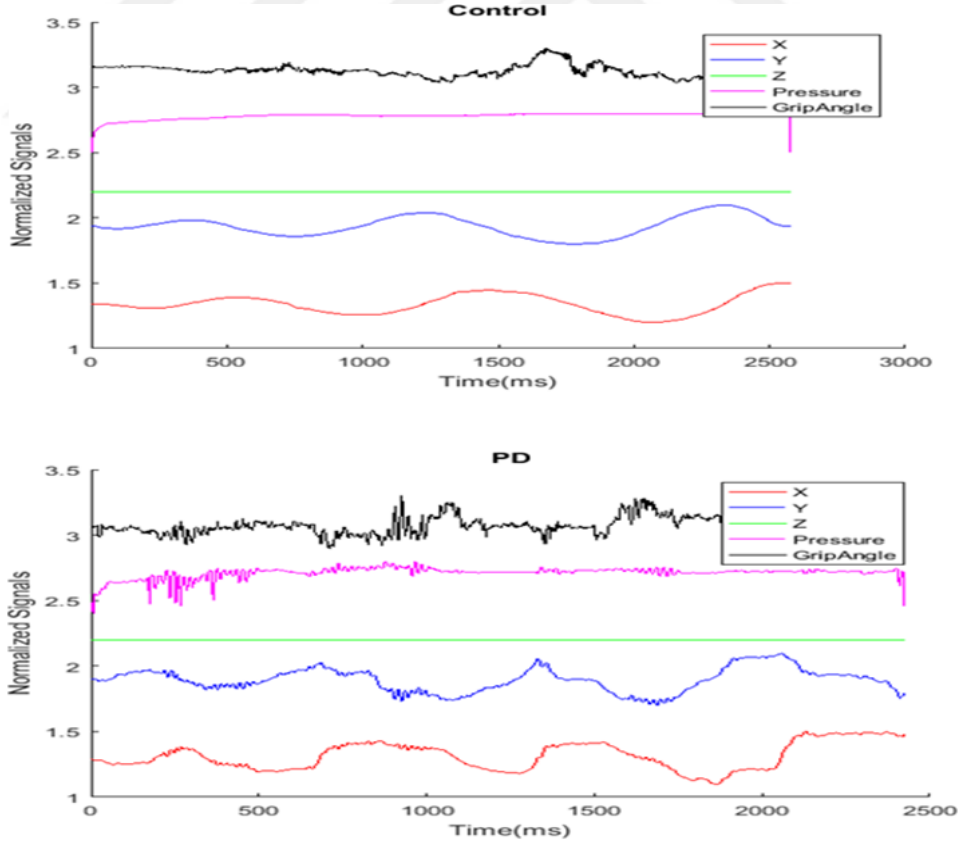
test, hastaların hatırlama ve spiral çizme işlemini aynı zamanda yapmaya çalıştıklarında motor performanslarını değerlendirmeyi amaçlamaktadır.

2.2.1.3 Belirli Noktada Stabilite Testi

Veri setinin son testi STCP'dir. Bu testte ekranda kırmızı bir nokta belirir ve hastaların sadece belirli bir süre için kırmızı noktada kalem tutmaları istenir. Bu testte yine öteki iki testte olduğu gibi hastanın el titremesi seviyesini ölçmek amaçlanmıştır.

Bu çalışmada, sağlıklı ve hasta kişiler tarafından çizilen resimleri sınıflandırmak için SST ve DST testleri kullanılmıştır, çünkü üçüncü test veri setindeki her bir bireye uygulanmamıştır. Ayrıca, veri setinin tüm ayırt edici özniteliklerini kullanmak adına resimlerin hem dinamik hem de görsel özellikleri sınıflandırma işleminde kullanılmıştır. Veri setinin zaman serisi sinyalleri Şekil 2.1'de gösterilmiştir.

Çizimlerden X, Y ve Z koordinatları, basınç, kavrama açısı ve zaman etiketleri öznitelikleri toplanmıştır.



Şekil 2.1 Hasta ve sağlıklı bireylerin çizimlerinden toplanan öznitelik sinyalleri

Kaydedilmiş kontrol sinyali verisi ile Parkinson hastalığı olan birinin verisi arasındaki farkı bu grafikte görmek mümkündür. Dikkat edilirse kontrol verisi sinyali daha saydam ve akışkandır oysa PD verisinde bazı noktalarda pik değerler bulunmaktadır ki bu noktalara, el titremesinin her öznitelik üzerindeki etkisi olarak bakılabilir. Ayrıca iki grafikte zaman süreleri farklıdır çünkü doğal olarak her birey farklı zamanlarda testi tamamlamıştır.

Isenkul ve diğ. 2014, SST ve DST farklılıklarını betimlemek amacıyla pratik parametreler sunmak için anlık hız ve ivme değerlerini hesaplamayan (2.1) denklemini önermiştir [14]. Bu çalışmada iki nokta arasındaki mesafe, kalemin hareket hızı olarak değerlendirilmiştir. Bahsedilen çalışmada (t) zamanında anlık hız (v) elde etmek için ardışık iki örnek (t ve t + 1 zamanında x ve y koordinatları) arasındaki mesafeyi hesaplamak önerilmiştir.

$$V_t = \sqrt{(x_t - x_{t-1})^2 + (y_t - y_{t-1})^2} \tag{2.1}$$

Hız, hem SST hem de DST testleri için çizim sırasında değişir. Özellikle DST'de spiralin yanıp sönmesi hastalar için daha fazla karışıklığa neden olabilir ve bu nedenle çizim sırasında ani yavaşlamaya veya hızlanmaya yol açar. Örneğin, birey spiral tabletten kısa bir süre sonra kaybolduğunda spiral şeklini hatırlamakta zorlanıyorsa, hız önemli ölçüde değişebilir. Bu nedenle, ivme olarak bilinen hızdaki değişimi inceleyen (2.2) denklemi önerilmiştir. (t) zamanında ivme (A) ardışık iki hız (V) değerinin (t ve t-1 zamanlarında hız değerleri) farkı olarak hesaplanmıştır.

$$A_t = V_t - V_{t-1} \tag{2.2}$$

Analizin bir sonucu olarak, bu veri setinde PD tanımlaması için ivme ayırt edici bir parametre olarak kullanılabilir. Çünkü kontrol grubunda SST ve DST ivme değerleri çoğunlukla benzerdir ancak PD grubunda söz konusu benzerlik görülmemiştir.

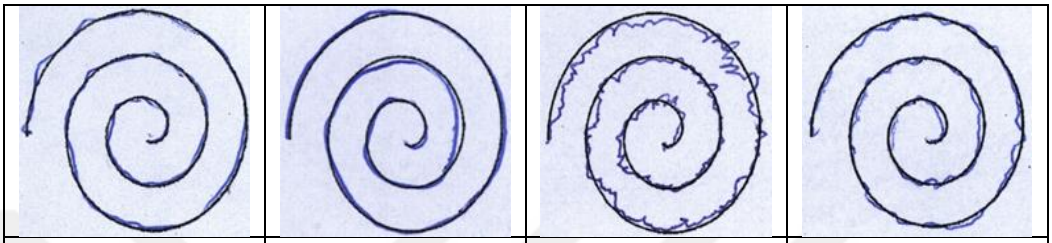
2.2.2 São Paulo Eyalet Üniversitesi El Yazısı Veri Seti

El yazısı testi veri seti Brezilya'nın São Paulo Eyalet Üniversitesi, Botucatu Tıp fakültesinde toplanmıştır. İstanbul'da toplanan Parkinson el yazısı testlerinden farklı olarak bu veri setinde kâğıt formlardaki testler ve normal kalem kullanılmıştır. Veri seti şu şekilde oluşturulmuştur: Bir kâğıt formda hastalardan dört spiral ve dört labirentten (meander) oluşan şekilleri takip edip doldurmaları istenmiştir. Sonraki

aşamada bu çizilen şekiller formdan kesilip "jpg" resim formatında saklanmıştır. Bu veri setindeki bilgiler iki gruptan oluşan bireylerden elde edilmiştir:

- Sağlıklı grup (kontrol)
- Hasta grup (PD)

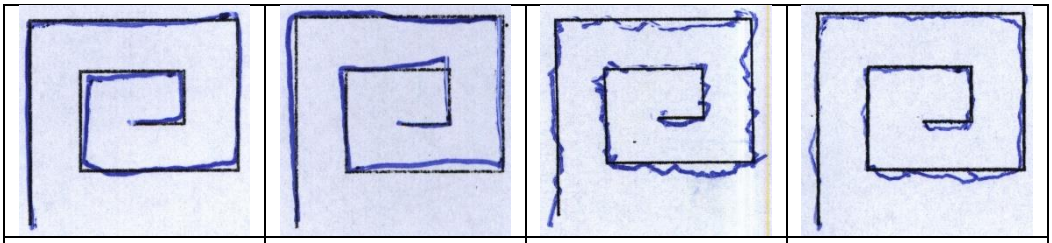
Veri setinden bazı spiral örnekleri Şekil 2.2'de verilmiştir; (a) ve (b) kontrol grubunda olan kişilere ve (c) ve (d) hasta grubunda olan kişilere aittir.



(a) (b) (c) (d)

Şekil 2.1 Veri setinden bazı spiral örnekleri

Veri setinden bazı labirent örnekleri Şekil 2.3'de verilmiştir; (a) ve (b) kontrol grubunda olan kişilere ve (c) ve (d) hasta grubunda olan kişilere aittir.



(a) (b) (c) (d)

Şekil 2.2 Veri setinden bazı labirent örnekleri

Veri seti 18 sağlıklı kişiden (kontrol) ve 74 hastadan (PD) olmak üzere 92 bireyden oluşmaktadır. Aşağıda, her grup hakkında kısa bir açıklama bulunmaktadır:

- Sağlıklı Grup: Yaşları 19 ile 79 arasında değişen (ortalama yaş 44.22 ± 16.53) 6 erkek ve 12 kadın birey. Bu bireyler arasında, 2 tanesi solak ve 16 tanesi sağlaktır.

- Hasta Grubu: Yaşları 38 ile 78 arasında değişen (ortalama yaş 58.75 ± 7.51 yıl) 59 erkek ve 15 kadın birey. Bu bireyler arasında 5 tanesi solak, 69'u sağlaktır.

Toplamda, tüm veri seti iki grupta etiketlenmiş 736 görüntüden oluşmaktadır: 72 görüntü içeren sağlıklı grup ve 296 görüntü içeren hasta grubu, her biri 368 görüntü içeren spiral ve labirent veri setlerinden oluşmaktadır. Her kişi için 4 spiral ve 4 labirent olmak üzere 8 resim bulunmaktadır.

3
DERİN ÖĞRENME VE METODOLOJİ

3.1 Derin Öğrenme

Genel olarak derin öğrenme makine öğrenmesinin bir parçası olarak tanımlanabilir. Derin öğrenme insan beynindeki biyolojik nöronların bilgi işlem kalıpları ve çalışma prensibinden ilham alınarak tasarlanmıştır ayrıca bu yapı biyolojik nöronlar arasındaki bağlantıları ve kompleks etkileşimleri yapay bir şekilde taklit etmeye çalışır. Biyolojik nöronların benzersiz ve bağımsız öğrenme yeteneği nedeniyle her türlü veriye uygulanabilmesi, araştırmacıların bu öğrenme işlemini yapay olarak modelleyip uygulamalarının ana nedenidir. İnsan beyni, derin öğrenmenin referans noktası olduğundan, bu yapı bilgisayarların hesaplama donanımı geliştikçe, gerçek dünya sorunları (kümeleme, sınıflandırma veya regresyon gibi) ile başa çıkmak için daha derin modeller yönünde ilerlemektedir. Derin öğrenme özünde, her bir uygulama için tekil bir yapıya sahip değildir, bunun yerine tüm uygulamalar için genel olarak uygulanabilir bir modeldir [15].

3.2 Eğiticili Öğrenme

Derin öğrenme kavramı, öğrenme mekanizması açısından ele alınırsa üç ana gruba kategorize edilebilir:

- Eğiticili öğrenme (supervised learning)
- Eğiticisiz öğrenme (unsupervised learning)
- Takviyeli öğrenme (reinforcement learning)

Bu çalışmada eğiticili öğrenme kullanılmıştır. Eğer veri seti için açık bir şekilde verilerin etiketlenmesi durumu söz konusu ise çıktının denetlenebilmesi, doğru ya da yanlış olarak sınıflandırılması olanağı oluşacağından, eğiticili öğrenme şeklinde adlandırılmıştır. Eğiticili öğrenmenin çarpıcı özelliği, verinin bir kısmının öğrenmede (eğitim seti), başka bir kısmının eğitimli modeli doğrulamada (çapraz

doğrulama) ve geri kalanının modelin doğruluk yüzdesini test etmede kullanılmasıdır (test seti). Sonuç olarak bu özellik eğiticili öğrenmenin bir tahmin sistemi olarak işlevselliğini sağlar. Modelin yeni veri setlerine genelleme yeteneğini değerlendirmek için tahminlerde doğruluk yüzdesi önemli bir kıstas olarak kabul edilmektedir. Eğiticili öğrenmede, regresyon ve sınıflandırmanın iki temel öğrenme görevi olduğu söylenebilir [15].

3.3 Sınıflandırma

Genelde derin öğrenme mekanizmaları giriş verisi tipine göre kategorize edilmektedir, sonuçta çıktı görevleri boyut azaltma, kümeleme, regresyon, yoğunluk tahmin etme ve sınıflandırma olarak kategorize edilebilir [16]. Sınıflandırma temelde kullanılan veri örneklerinin sınıfını tahmin etme sürecidir. Sınıflandırma ve regresyon problemleri tahmin problemleri olsa da farkları vardır. Sınıflandırma, ayrık bir sınıf etiketini tahmin etme görevidir, regresyon ise sürekli bir miktarın tahmini görevidir. Sınıflandırma problemlerinin birçok farklı türü vardır bu çalışmada ise ikili sınıflandırma (binary classsification) problemi (PD hastası ya sağlıklı) ele alınmıştır.

3.4 Theano

Derin öğrenme platformları oldukça geniş olup birçoğu açık kaynaklıdır ve bu da araştırmacılara ve program geliştiricilere oldukça faydalı olmaktadır. Derin öğrenme faydalı kütüphanelerine örnek olarak Tensorflow, Theano, Keras, DeepLearning4J, Torch, Microsoft Cognitive Toolkit (CNTK) ve Caffe gibi platformlar verilebilir.

Theano, ilk olarak bilimsel araştırmalar için kod derlemesini optimize etmek amacıyla tasarlanmıştır ancak geliştikçe, matematiksel ifadeleri özellikle çok boyutlu dizileri tanımlamaya, optimize etmeye ve değerlendirmeye olanak sağlayan Python kodlama dilinde sayısal bir hesaplama kütüphanesi haline gelmiştir. Montreal üniversitesinde geliştirilen bu açık kaynaklı kütüphane, oluşturulan modelin her katmanında tam kontrolü sağlaması ve esneklik açısından akademik düzeyde araştırmacıların popüler seçeneğidir. Programlama ara yüzü (API-Application Programming Interface) düzeyi çok düşük olduğundan, tam işleyişle bir

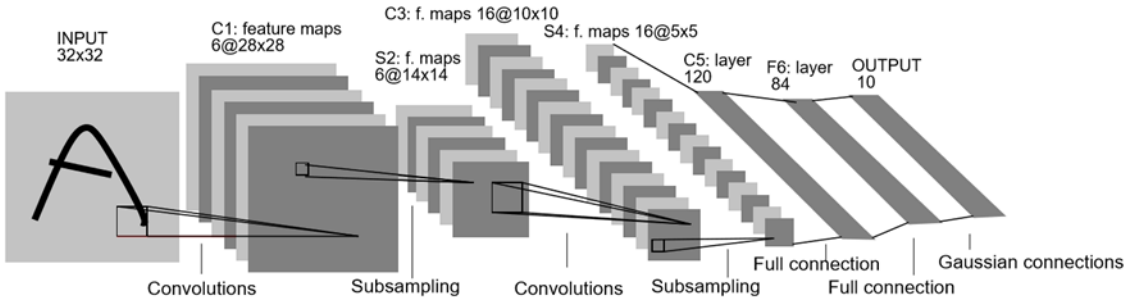
Theano yapısı oluşturmak için diğer yapıların arka planında olan algoritmalara aşina olmak gerekir. Theano NumPy kütüphanesini kullanarak Python 2 veya 3 sürümlerinde cpu veya gpu üzerinde işlem yapılabilir [17].

3.5 Keras

Yapay sinir ağlarında çok popüler bir ara katman (middleware) olan Keras kütüphanesi TensorFlow, Theano ve CNTK ile entegre yüksek seviye bir API sağlar. Derin öğrenme tasarımını kullanıcı dostu, modüler ve genişletilebilir bir ara yüzle seri bir şekilde dizayn etmeye olanak sunar. Aynı zamanda cpu ve gpu'ları destekleyen bir yapıdır ve pythonda bir çok makine öğrenmesi paketlerine entegre edilebilir [18].

3.6 Evrişimsel Sinir Ağları

Evrişimsel Sinir Ağları (CNN) özellikle son yıllarda derin öğrenme araştırmalarının en geniş alanları olan görüntü ve video işleme, görüntü sınıflandırma, nesne tespiti ve segmantasyon'da araştırmacılar tarafından kullanılmaktadır. Görüntüden öznitelik çıkarılması için el ile tasarlanmış filtrelere ihtiyaç duymamaları evrişimsel sinir ağlarını görüntü işleme alanında kullanışlı kılmaktadır ayrıca görüntü dışında ardışık ve birbiriyle ilişkili veri içeren diğer sinyaller üzerinde de kullanılmaktadır [19]. Yapay Sinir Ağları (YSA) gibi evrişimsel sinir ağları da nöronlar, ağırlıklar, kayıp fonksiyonu ve diğer parametrelere sahiptirler. CNN'ler konvolüsyon katmanı, havuzlama katmanı ve tam bağlı katman olarak adlandırılan üç ana katmandan oluşurlar [20]. Şekil 3.1'de verilen model LeNet adı ile tanınan 1988 yılında Yann LeCun tarafından ortaya atılan ilk CNN mimarisidir [21]. Şekilde görüldüğü gibi LeNet art arda dizilmiş birkaç konvolüsyon ve maksimum havuzlama katmanları ve en sonunda MLP'ye (Çok-Katmanlı Perceptron) karşılık gelen tam bağlı katmandan oluşmuştur.



Şekil 3.1 Rakam tespiti için bir evrişimsel sinir ağı: LeNet-5 mimarisi [21]

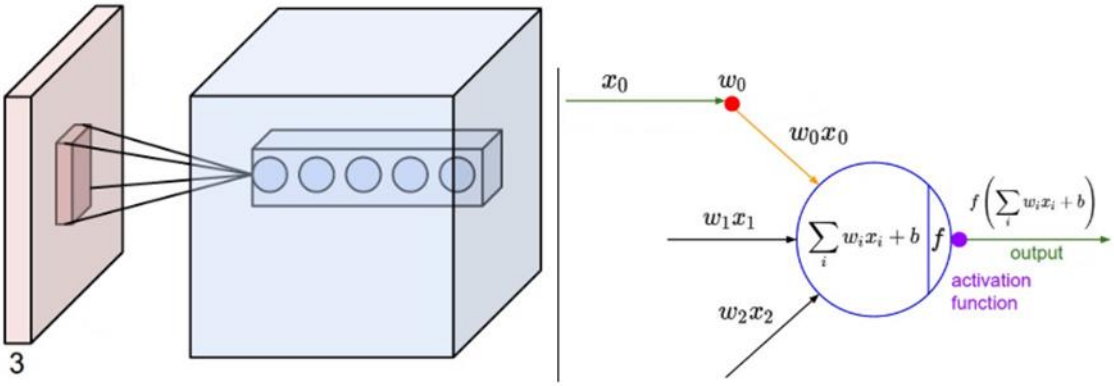
CNN mimarisinin giriş verisi olan görüntü ilk olarak öznitelik haritası oluşturma amacıyla konvolüsyon katmanında konvolüsyon işlemi görür; sonraki aşamada bu öznitelik haritalarının boyutu, havuzlama katmanında daha küçük hale gelir. En sonda yer alan tam bağlı katman, görüntü sınıflandırmasından sorumludur. CNN'e, modelin otomatik olarak saptadığı öznitelikleri hesaplama maliyetini düşürmek hedefiyle küçültüp sınıflandırma işlevselliğini arttırmayı amaçlayan bir yapı olarak fonksiyonel açıdan bakılabilir.

3.6.1 Konvolüsyon Katmanı

Bu katman, görüntüler üzerinde kayan öznitelik çıkarıcı filtreler (kerneller) topluluğu olarak tanımlanabilir. Her filtre, giriş görüntüsü üzerinde konvolüsyon işlemini gerçekleştiren belirli bir matrisi temsil eder. Her filtre farklı öznitelikleri optimize bir şekilde eş zamanlı olarak katmanın giriş görüntüsünden çıkarıp öznitelik haritalarını oluşturur. Adım (stride) parametresi, giriş görüntüsünün üzerindeki filtre matrisinin kayma miktarını belirler. Konvolüsyon katmanın çıktısı öznitelik haritası (feature map) olarak adlandırılır ve en basit matematiksel açılımı ile denklem (3.1)'deki gibi hesaplanır.

$$h_{ij}^{k} = \mathrm{ReLU}\big((W^{k} * x)_{ij} + b_{k}\big) \tag{3.1}$$

Bu denklemde h^k k indisli öznitelik haritasını, W^k ağırlık olarak bilinen filtreyi, x giriş verisini ve b_k ise eşik değerini temsil etmektedir. Daha önce belirtildiği gibi her filtre farklı bir matrisi temsil etmektedir ve resimler içerisinde farklı öznitelikleri ararlar. Konvolüsyon işleminin esas olarak, filtreler ve giriş verisinin yerel bölgeleri arasındaki nokta çarpımı gerçekleştirdiğine dikkat edilmelidir.



Şekil 3.2 Sol: giriş verisinde alıcı alan, sağ: konvolüsyon nöronlarının işlevi [22]

Şekil 3.2'de sol tarafta giriş verisinde aynı alıcı alana (receptive field) bağlı bir nöron grubu, sağ tarafta ise konvolüsyon katmanındaki nöronların işlevi gösteren şemalar verilmiştir.

Sol tarafta örnek giriş görüntüsü kırmızı renkte (RGB görüntü 3 boyutlu) ve ilk konvolüsyon katmanındaki aynı alıcı alana sahip örnek nöron grubu mavi renkle gösterilmiştir. Konvolüsyon katmanındaki her bir nöron, giriş verisinde sadece yerel bir bölgeye, ancak tam derinliğe (yani bütün renk kanallarına) bağlanır. Derinlik boyunca, hepsi girişte aynı bölgeye bakan çoklu nöronlar (bu örnekte 5 nöron) vardır. Sağ tarafta görüldüğü üzere yapay sinir ağlarında olduğu gibi nöronların işlevselliği aynıdır. Nöronlar lineer olmayan girdilerle ağırlıklarının bir nokta çarpımını hesaplarlar, ancak artık giriş verisi ile bağlantıları yerel bağlantı ile sınırlıdır.

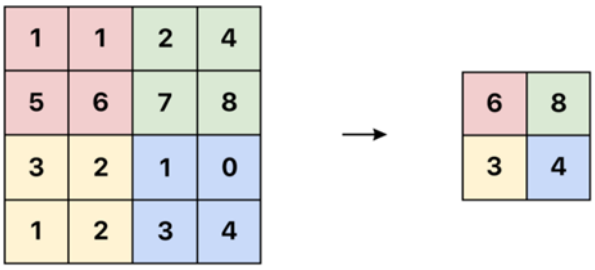
Konvolüsyon katmanının parametreleri, bir dizi öğrenilebilir filtreden oluşur. Her filtre giriş verisiyle karşılaştırılırsa küçük boyutludur (genişlik ve yükseklik açısından), ancak giriş verisinin derinliği boyunca uzanır. İleri geçiş sırasında, her bir filtre girişin genişliği ve yüksekliği boyunca kaydırılıp filtre ve giriş değerinin nokta çarpımı her pozisyonda hesaplanır. Filtreyi, giriş verisinin genişliği ve yüksekliği boyunca kaydırdıkça, bu filtrenin her mekânsal pozisyonda verdiği yanıtlardan oluşan 2 boyutlu bir öznitelik haritası üretilir. Sonuç olarak ağ, görüntüdeki şeklin bir kenarını, bir renkteki leke veya çok özel desenleri gördüklerinde aktif hale gelen filtreleri öğrenecektir. Bu aşamada, her konvolüsyon

katmanında her biri ayrı bir 2 boyutlu öznitelik haritası üreten bir dizi filtreye sahip olunmaktadır. Bu öznitelik haritaları derinlik boyutu boyunca üretilip toplanırsa sonuçta bu katman çıkış verisini tam olarak üretecektir [22].

Yüksek boyutlu görüntülerle uğraşırken tüm nöronları birbirine bağlamak pratik değildir. Bunun yerine, her bir nöron sadece giriş verisinin bir yerel bölgesine bağlanacaktır. Bu bağlantının mekânsal boyutu, nöronun alıcı alanı (receptive field) olarak adlandırılan bir hiperparametredir (eşdeğerde filtre büyüklüğüdür).

3.6.2 Havuzlama Katmanı

Derin öğrenme mimarilerinde konvolüsyon katmanları arasına havuzlama katmanları eklemek yaygın bir yaklaşımdır. Havuzlama katmanı, ağ yapısında parametreleri ve hesaplama yükünü azaltarak ezberlemeyi (overfitting) önler. Bu katmanın amacı, görüntünün karmaşıklığıyla başa çıkmak için öznitelik haritalarının boyutunu azaltmaktır. Havuzlama katmanı yaklaşımları arasında en yaygın olanı maksimum havuzlama katmanıdır. Maksimum havuzlama, iki boyutlu (2D-2Dimensional) bir giriş alanı boyunca hareket eden bir pencere olarak tanımlanabilir. Söz konusu pencerede en büyük değere sahip olan sayı, katmanın çıktısı olarak alınır. Maksimum havuzlama katmanı Şekil 3.3'de gösterilmiştir. Bu çalışmadaki yapıda iki adet maksimum havuzlama katmanı kullanılmıştır.



Şekil 3.3 Maksimum havuzlama işlemi [23]

3.6.3 Tam Bağlı Katman

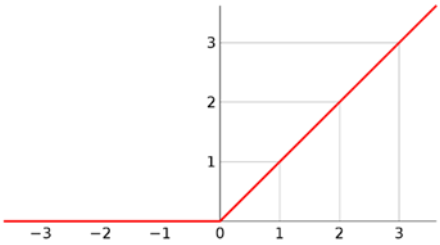
Evrişimsel sinir ağı yapısındaki son katman tam bağlı katmandır. Tam bağlı katmandaki nöronlar, Yapay Sinir Ağlarında olduğu gibi, önceki katmandaki tüm aktivasyonlara tam olarak bağlanırlar. Bu katmanın yapıdaki görevi giriş verisinden

çıkarılan öznitelikleri sınıflandırmaktır. Aslında bu katman, çıktı katmanında Softmax aktivasyon fonksiyonunu kullanan MLP (Çok Katmanlı Perceptron) sınıflandırıcısına eşittir. Tam bağlı ve konvolüsyon katmanları arasındaki fark, konvolüsyon katmanındaki nöronların sadece giriş verisi üzerindeki bir yerel bölgeye bağlanması ayrıca bu katmandaki nöronların çoğunun parametreleri paylaşmasıdır. Bununla birlikte, her iki katmandaki nöronlar nokta çarpımı hesapladığı için fonksiyonel formları aynıdır. Bu katmandaki tüm nöronlar birbirine bağlı olduğundan tam bağlı katman olarak isimlendirilmiştir.

3.6.4 Doğrultulmuş Lineer Aktivasyon Birimi (ReLU)

Aslında ReLU (Rectified Linear Activation Unit) aktivasyon fonksiyonu derin öğrenme modelleri için tasarlanmıştır. Katman çıktısının ayırt edici özelliğini artırır böylece çeşitli verilerle genelleştirilmesini veya uyarlanmasını sağlar. CNN konvolüsyon katmanlarının aktivasyon fonksiyonu olarak ReLU kullanması literatürde çok sıklıkla görülmektedir [20]. $tanh$ Fonksiyonu, makine öğrenmesi modellerinde aktivasyon fonksiyonu olarak çok yaygın bir şekilde kullanılmasına rağmen, eğitim süreleri ReLU kullanılarak birkaç kez azalmaktadır [24]. Denklem (3.2), ReLU fonksiyonun matematiksel açılımını göstermektedir.

$$f(x) = \begin{cases} x & if\ x > 0 \\ 0 & otherwise \end{cases} \tag{3.2}$$



Şekil 3.4 ReLU aktivasyon fonksiyonun şematik görünümü

3.6.5 Softmax

Softmax sınıflandırıcısı, ikili lojistik regresyon sınıflandırıcısının çoklu sınıflara genelleştirilmiş halidir. Kısaca Softmax, istatistiksel bir olayın 'n' farklı olaya göre

olasılık dağılımını hesaplar. Genel olarak, bu fonksiyon, her bir hedef sınıfın tüm olası hedef sınıfları üzerindeki olasılıklarını hesaplar. Daha sonra hesaplanan olasılıklar, verilen girdiler için hedef sınıfın belirlenmesinde yardımcı olmaktadır [25]. Denklem (3.3), verilen giriş değerinin eksponansiyel (e sayısının kuvveti) değerini ve tüm girişlerdeki eksponansiyel değerlerinin toplamını hesaplar. Sonuç olarak bu iki değerin oranı softmax fonksiyonunun çıktısıdır. Burada p her giriş verisinin i indisli eleman ile gösterildiği, bir vektörüdür (bu çalışmada, ikili sınıflandırma yapılması nedeniyle 2 çıkış birimi bulunmaktadır, böylece p'de 2 eleman vardır). Ayrıca, i çıkış biriminin indeksidir, yani $i = 1, 2...$ K.

$$f(p)_i = \frac{e^{p_i}}{\sum_{k=1}^{k} e^{p_k}} \tag{3.3}$$

3.6.6 Stokastik Gradyan Düşümü

Stokastik Gradyan Düşümü (SGD) optimizasyon algoritması, tutarlı bir yakınsamaya sahiptir çünkü parametrelerin güncellemesinin varyansını azaltır. SGD sadece birkaç eğitim setindeki örneği değerlendirerek, maliyet fonksiyonu ve gradyan hesaplama sorunlarının üstesinden gelebilirken aynı zamanda hala yüksek düzeyde yakınsama oranına sahip olabilir. Dolayısıyla, SGD'nin bu özelliği YSA ve derin öğrenme modellerinde kullanım alanını çok yaygın hale getirmektedir.

3.7 k-Katlamalı Çapraz Doğrulama

Çapraz doğrulama, makine öğrenmesi modellerini sınırlı veri örneğinde değerlendirmek için kullanılan bir yeniden örnekleme prosedürüdür.

Prosedür, belirli bir veri örneğinin bölüneceği grup sayısını ifade eden k adlı tek bir parametreye sahiptir. Bu nedenle, prosedür genellikle k-katlamalı çapraz doğrulama olarak adlandırılır. K için belirli bir değer seçildiğinde, örneğin k = 10'un 10 kat çapraz doğrulama olması gibi modellerde referans bir metot olarak kullanılabilir.

Çapraz doğrulama, öncelikle bir makine öğrenme modelinin daha önce görmediği veriler üzerindeki becerisini tahmin etmek için kullanılır. Yani, modelin eğitimi sırasında kullanılmayan veriler üzerinde tahminlerde bulunmak için sınırlı örnekler

kullanıldığında, modelin genel olarak nasıl bir performans göstereceğini tahmin edilir.

k-katlamalı çapraz doğrulama yöntemi ile İncelenen modelin bias-varyans karakteristiğine ulaşmak mümkündür. Veri setine k-katlamalı çapraz doğrulama uygulandığı zaman, modelin kayıp fonksiyonunun hesapladığı k kere farklı hata hesaplanacaktır; ideal durumda bu hatalar sıfır olmalıdır. İncelenen modelin bias değerini kontrol etmek için, tüm hataların ortalaması hesaplanır. Bu değer düşükse, modelin ortalama olarak düşük hata verdiği, aynı zamanda da dolaylı olarak modelin verilerle ilgili eğiliminin yeterince doğru ve uygun olduğu söylenebilir. Aynı şekilde, modelin varyansını kontrol etmek için, tüm hataların standart sapması hesaplanır. Modelin performansı ve genelleme yeteneği açısından bu değerin yüksek olması istenmeyen bir durumdur.

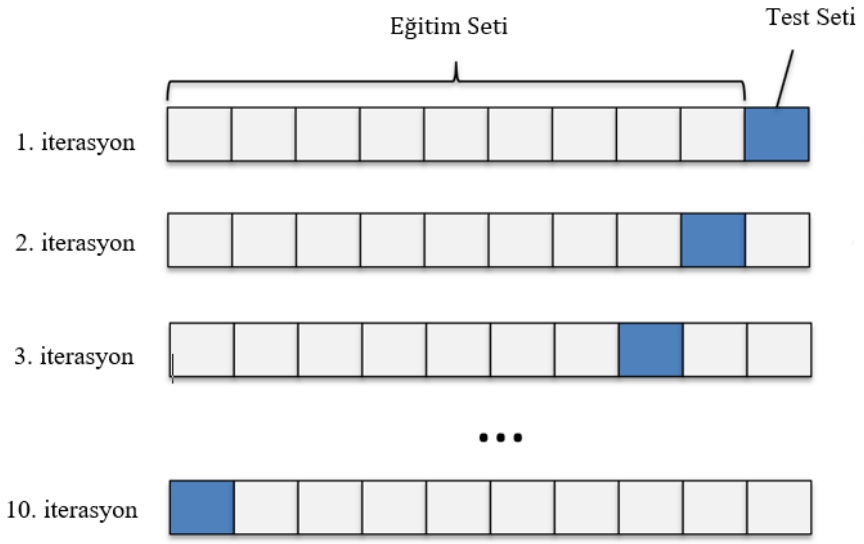
k-katlamalı çapraz doğrulama, genellikle basit bir eğitim / test bölünmesi gibi diğer veri seti bölme yöntemlerinden daha az bias sahip olması ve daha az iyimser tahminde bulunması nedeniyle, model becerisini tahmin etmek için daha anlaşılır ve popüler bir yöntem haline gelmiştir.

Genel prosedür aşağıdaki gibidir:

- Veri setini rastgele karıştır.
- Veri setini k gruba ayır.
- Her benzersiz grup için:
    - Grubu beklemeye al veya test seti olarak kullan.
    - Kalan grupları eğitim verisi olarak al.
    - Modeli eğitim seti ile eğit ve test setinde değerlendir.
    - Değerlendirme puanını koru ve modeli at.
- Model değerlendirme puanlarını kullanarak model becerisini özetle.

Önemli bir nokta olarak, test ve eğitim verisi grubundaki her örnek belirli bir gruba atanır ve eğitim işlemi süresince o grupta kalır. Bu da, bu yöntemin her bir örneği 1 kez test verisi olarak ve k-1 kez eğitim verisi olarak kullandığı anlamına gelmektedir.

Bu yaklaşım, veri setini rastgele olarak yaklaşık eşit büyüklükteki k adet gruba bölmeyi içermektedir. İlk grup bir doğrulama (validation) seti olarak kabul edilir ve model kalan k - 1 adet grupla eğitim işlemini gerçekleştirir [26].



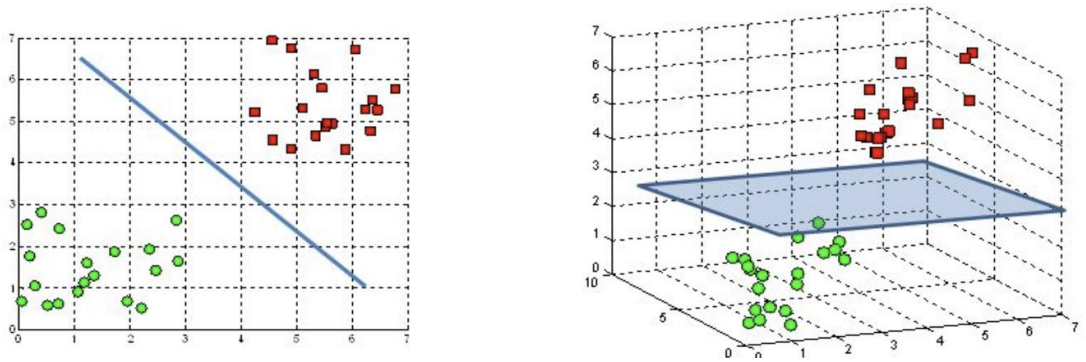
Şekil 3.5 k-atlamalı çapraz doğrulama [27]

3.8 Destek Vektör Makinesi (SVM)

Destek Vektör Makinesi (SVM) sınıflandırma ve regresyon problemleri için kullanılabilecek eğiticili bir makine öğrenme algoritmasıdır. Ancak, çoğunlukla sınıflandırma problemlerinde kullanılır. Bu algoritmada, her bir veri örneği n-boyutlu uzayda (n, verinin sahip olduğu özniteliklerin sayısıdır) bir nokta olarak düşünülebilir, her özniteliğin değeri verinin bir koordinat değeridir. Bu algoritmada iki sınıfı çok iyi ayıran hiper-düzlemi bularak sınıflandırma işlemi gerçekleştirilir. Başka bir deyişle, etiketli eğitim verileri (eğiticili öğrenme) sınıflandırıcıya verildiğinde, algoritma yeni örnekleri kategorize eden en uygun hiper-düzlemi oluşturur.

Hiper-düzlemler, verileri bulundukları noktalar itibariyle sınıflandıran karar sınırlarıdır. Ayrıca, hiper-düzlemin boyutu, özniteliklerin sayısına bağlıdır. Şekil 3.6 temsili şemada olduğu gibi giriş özniteliklerinin sayısı 2 ise, hiper düzlem sadece bir

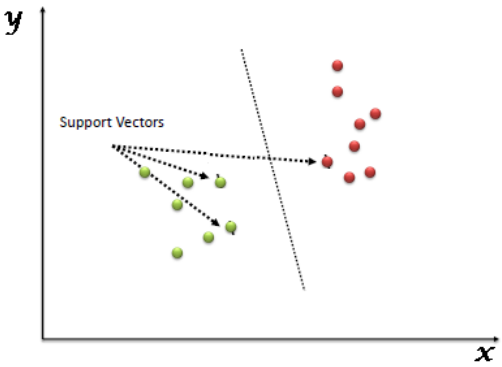
çizgidir. Giriş özelliklerinin sayısı 3 ise, hiper düzlem iki boyutlu bir düzlem haline gelir. Özelliklerin sayısı 3'ü aştığında hiper-düzlemi hayal etmek zorlaşır [28].



(a) (b)

Şekil 3.6 (a): iki boyutta hiper-düzlem, (b): üç boyutta hiper-düzlem [29]

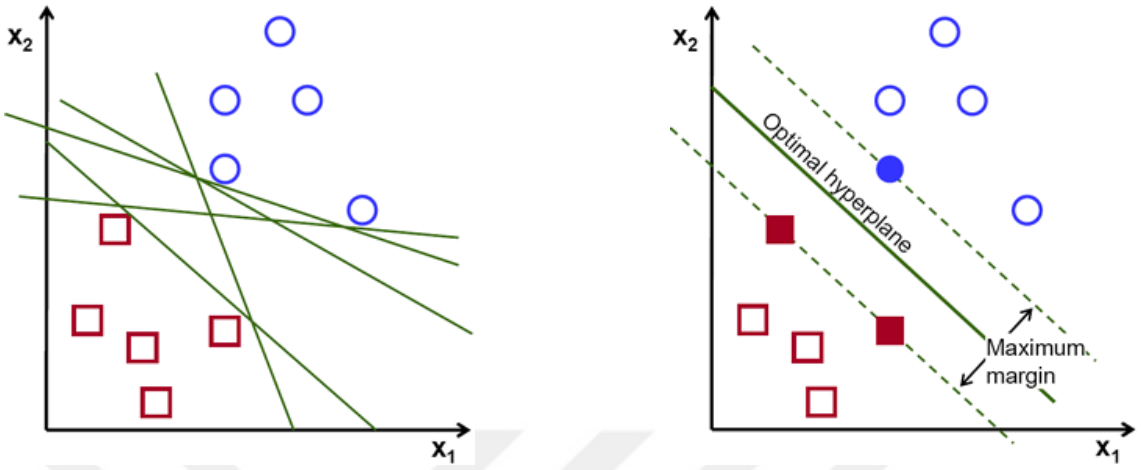
Destek Vektörleri, bireysel gözlemin koordinatlarıdır. Bir başka deyişle destek vektörleri, hiper-düzleme daha yakın olan ve hiper-düzlemin konumunu ve yönünü etkileyen veri noktalarıdır. Bu algoritmada destek vektörleri kullanılarak, sınıflandırıcının marjini maksimize edilir. Bu pratik husus aslında SVM'i oluşturan ve ona adını veren konudur.



Şekil 3.7 Destek vektörleri [30]

Burada dikkat edilmesi gereken önemli nokta, doğru hiper-düzlemin nasıl tespit edildiğidir. Şekil 3.8'de oluğu gibi iki veri noktası sınıfını ayırmak için seçilebilecek birçok olası hiper-düzlem vardır. Amaç maksimum marjinli bir hiper-düzlemi

bulmak, yani her iki sınıfın veri noktaları arasındaki maksimum mesafeyi bulmaktır. Marjin mesafesinin maksimize edilmesi, bazı kolaylıklar sağlayarak gelecekteki veri noktalarının daha güvenle sınıflandırılmasını sağlar.



Şekil 3.8 Sol: muhtemel hiper-düzlemler, sağ: en uygun hiper-düzlem [29]

SVM'in yapay sinir ağlarına kıyasla, sınırlı sayıda örnekle daha yüksek hız ve daha iyi performans sağlaması şeklinde iki ana avantajı bulunmaktadır.

3.9 Naive Bayes (NB)

Naive Bayes bir istatistiksel sınıflandırma yöntemidir bir başka deyişle NB algoritması sınıflandırma işleminde olayların olasılığını karşılaştırıp en yüksek olma olasılık şartını göz önünde bulundurur. NB sınıflandırıcısı, öznitelikler arasındaki bağımsızlık varsayımlarına sahip Bayes teoremine dayanmaktadır. NB modeli karmaşık parametre tahmini yapmadığından özellikle büyük veri setleri için yararlıdır. Sadeliğine rağmen, NB sınıflandırıcısı genellikle şaşırtıcı derecede iyi sonuç verir ve sıklıkla daha karmaşık sınıflandırma yöntemlerinden daha iyi performans gösterdiğinden yaygın olarak kullanılır [31].

Bayes teoreminin temel denklemi, (3.4)'de verilmiştir:

$$P(A|B) = \frac{P(B|A)P(A)}{P(B)} \tag{3.4}$$

$P(A|B)$: B olayının gerçekleştiği durumda A olayının meydana gelme olasılığı

$P(B|A)$: A olayının gerçekleştiği durumda B olayının meydana gelme olasılığı

$P(A)$: A olayının olma olasılığı

$P(B)$: B olayının olma olasılığı

Resimlerin piksel değerleri her resmin özniteliği olarak görülebilir. Bu algoritma öznitelikleri birbirinden bağımsız olarak varsayacağından, bu hesaplama türü görüntülerin ayırt edici özniteliklerini yansıtacaktır.

NB algoritması iki varsayımda bulunmaktadır:

- Öznitelikler birbirinden bağımsızdır
- Bütün özniteliklerin çıktı üzerinde aynı derecede etkisi vardır

Bu varsayımlar her zaman doğru olmamasına rağmen bu sınıflandırıcı genelde sınıflandırma konusunda şaşırtıcı derecede yüksek doğruluk performansı sergilemektedir.

Bayes teoremi, $P(y|X)$ olasılığını $P(X|y)$, $P(y)$ ve $P(X)$ olasılıklarından hesaplamaktadır. Naive Bayes sınıflandırıcısı, bir özniteliğin (x_i) değerinin belirli bir sınıf (y) üzerindeki etkisinin, diğer öznitelik değerlerinden bağımsız olduğunu varsayar. Bu varsayıma sınıf şartlı bağımsızlık denir. Temel Bayes teoremi makine öğrenmesi sınıflandırıcı operasyonuna uyarlandığında ise formüldeki terimler şu hali almaktadır:

$$P(y|X) = \frac{P(X|y)P(y)}{P(X)} \tag{3.5}$$

y Değişkeni sınıf değeri olarak düşünülürse bu çalışmada hasta ya da sağlıklı olarak alınabilir; yani öznitelikler sağlıklı ya da hastaya ait olduklarını temsil eder. X değişkeni ise öznitelikleri temsil eder ve $X = (x_1, x_2, x_3, \dots, x_n)$ şeklinde yazılabilir. Her görüntünün pikseli kadar özniteliği vardır. Her x_i bir özniteliği temsil eder. X Değeri yerine koyulduğunda ve denklem zincir kuralı ile genişletildiğinde aşağıdaki formül elde edilecektir:

$$P(y|x_1, x_2, \dots, x_n) = \frac{P(x_1|y)P(x_2|y) \dots P(x_n|y)P(y)}{P(x_1)P(x_2) \dots P(x_n)} \tag{3.6}$$

Şimdi, veri setindeki her bir öznitelik değeri denklemde yerine koyulup sonuç üretilebilir. Veri setindeki tüm girişler için, denklemdeki payda değişmez. Bu nedenle, payda çıkarılabilir ve orantılılık getirilebilir.

$$P(y|x_1, x_2, \dots, x_n) \propto P(y) \prod_{i=1}^{n} P(x_i|y) \tag{3.7}$$

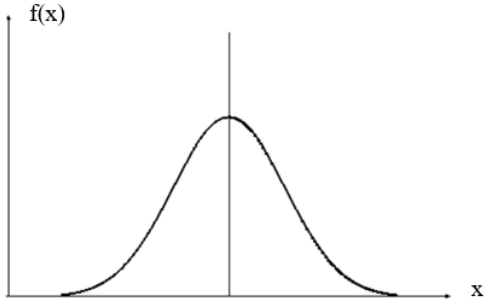
Bu tez çalışmasında, sınıf değişkeninin (y) hasta veya sağlıklı olmak üzere sadece iki sonucu vardır. Sınıflandırmanın çok değişkenli olabileceği durumlar olabilir. Bu nedenle, y sınıfı maksimum olasılıkla bulunmalıdır. Sonuç olarak (3.8) elde edilir.

$$y = arg \max_{y} P(y) \prod_{i=1}^{n} P(x_i|y) \tag{3.8}$$

Naive Bayes sınıflandırıcının üç ana türü vardır:

- Multinomial Naive Bayes
- Bernoulli Naive Bayes
- Gaussian Naive Bayes

Öznitelikler sürekli bir değer aldıklarında ve ayrık olmadıklarında, bu değerlerin bir Gauss dağılımından örneklendiği varsayılabilir. İşte bu varsayım Gaussian Naive Bayes'in temelini oluşturmaktadır.



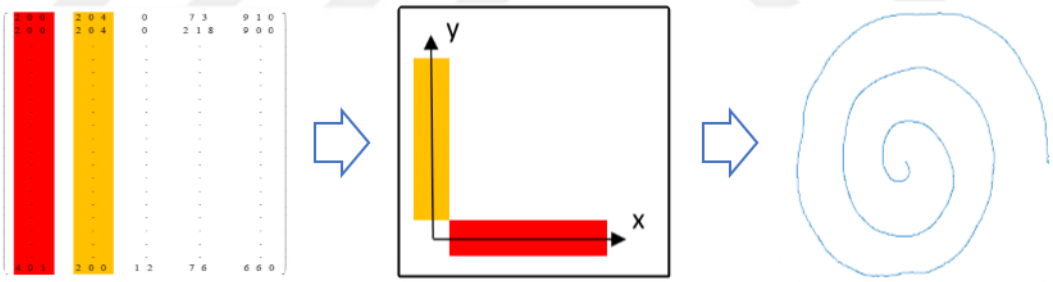
Şekil 3.9 Gauss dağılımı [32]

3.10 Metodoloji

Üzerinde analiz yapılan veri setleri farklı yöntemlerle toplanmıştır bu yüzden inceleme sürecinde farklı ön işleme prosedürleri kullanılmıştır. İlk olarak Cerrahpaşa tıp fakültesinde toplanan veri setine uygulanan ön işleme işlemleri

açıklanacaktır. Söz konusu veri seti küçük zaman aralıklarında kişinin elinde bulundurduğu dijital kalemin x, y, z eksenine ait değerlerin, tablete kalem ile uygulamış olduğu basıncın ve kalem tutuş açısına ait bilgilerin zaman serileri halinden oluşmaktadır. Yani her birey için satır sayısı çizdiği spiral zamanına bağlı olan ve 5 öznitelik sütunundan oluşan veri seti belirlenmiştir. Bu veri setine CNN tabanlı derin öğrenme yaklaşımı ile sınıflandırma işlemini yapmak için iki farklı yol izlenmiştir:

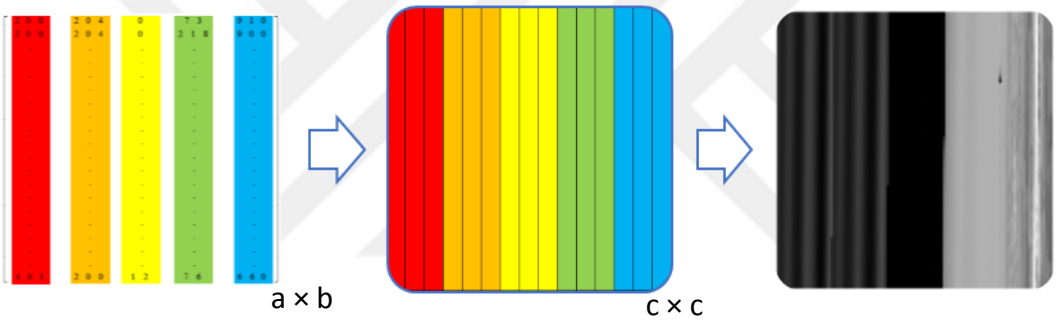
İlk olarak veri setinin ilk iki özniteliği olan X ve Y eksen değerleri (iki boyut koordinatları) kullanılmıştır. Belirli her örnekleme zamanında spirallerin (X,Y) ikilisini MATLAB ortamında çizdirerek aslında kişilerin çizmiş olduğu spirallerin görüntüsü elde edilmiştir. Sonradan çizdirilen olgular "png" formatında kaydedilmiştir. Elde edilen çizimler hiçbir gürültüye sahip olmamaları sebebiyle CNN yapısına doğrudan giriş verisi olarak kullanılmıştır. Literatürde çoğu veri setinde bulunan çizim verileri sadece görsel öznitelikleri içermektedir. Bu yapılan işlemin amacı oluşturulan CNN modelinin veri setinin anlamlı en az sayıda özniteliğine yani görsel özelliklere vereceği doğruluk yüzdesini belirlemektir.



Şekil 3.10 Görsel öznitelik veri ön işleme uygulaması

Şekil 3.10'da görüldüğü gibi veri seti ilk haliyle her birey için bir n×5 matrisi olarak düşünülebilir. Veri setinde her örnekleme zamanı için (X,Y) koordinatları mevcut olduğundan, bu iki değeri birbirine orantılı olarak x ve y eksenlerine yerleştirip birey tarafından çizilen şekil elde edilmiştir.

İkinci yöntem olarak veri setinin tüm özniteliklerinden tek bir öznitelik görüntüsü çıkartma işlemi gerçekleştirilmiştir. Bu yöntemle, görsel olmayan diğer özniteliklerin doğruluk yüzdesine katkıları incelenmiştir. Daha öncede belirtildiği gibi her kişinin verisi n satırdan (test süresi) ve 5 sütundan (x, y, z, basınç ve açı) oluşmaktadır. Verileri CNN yapısına giriş verisi olarak uygun hale getirmek için öncelikle verilere standart yeniden ölçeklendirme ve normalizasyon işlemleri uygulanmıştır. Bu noktada dikkat edilmesi gereken husus her kişinin testi tamamlama süresi farklı olacağından her kişinin verisinin satır sayısının farklı olmasıdır. Bu nedenle veri setini kare matris haline getirmek suretiyle CNN yapısına uygun giriş verisi elde edilmiştir. Son adım olarak söz edilen kare matrisler MATLAB ortamında çizdirilmiştir. Sonuç olarak bu yöntemle sinyal tabanlı öznitelik resimleri elde edilmiştir.

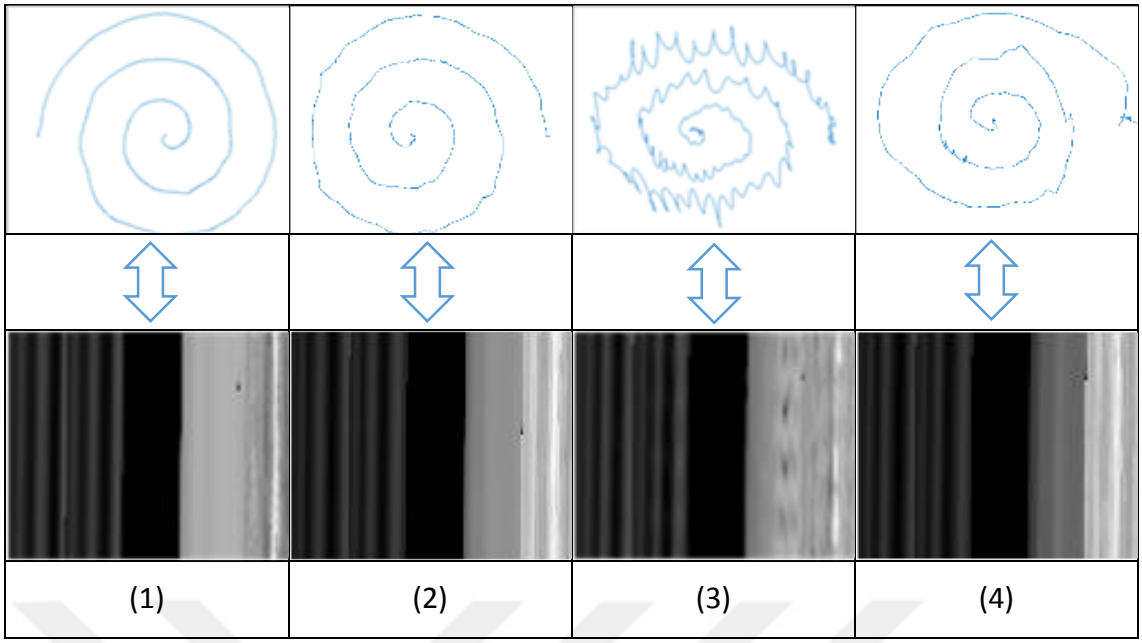


Şekil 3.11 Sinyal tabanlı kare öznitelik veri ön işleme uygulaması

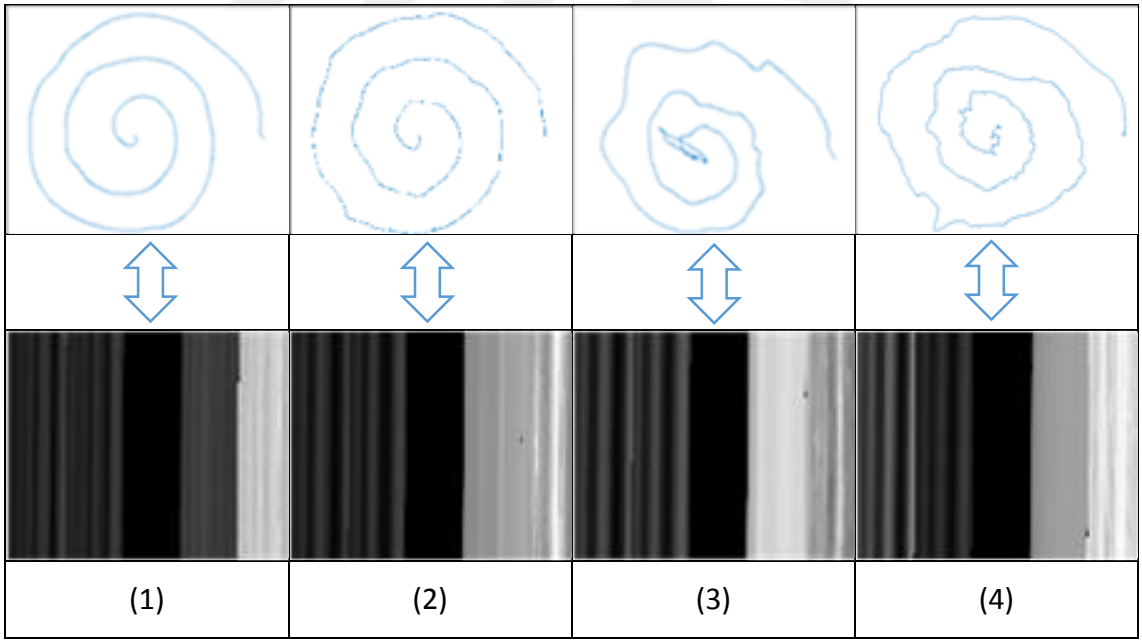
Veri setinin a satırdan ve b sütundan oluştuğu düşünülerek kare matris oluşturma amacıyla c değeri $c = \sqrt{a \times b}$ şeklinde hesaplanmıştır. Her öznitelik sütunu Şekil 3.11'deki renkler gibi kare matrise yerleştirilmiştir. Daha sonra elde edilen matris çizdirilmiştir.

Şekil 3.12'de SST testlerine ait kontrol ve hasta gruplarından bazı spiral örnekleri ve aşağılarında aynı veriye ait öznitelik görüntüleri sunulmuştur, (1) ve (2) kontrol grubuna, (3) ve (4) ise PD hastalarına aittir.

Şekil 3.12 SST testinin spiral örnekleri



Şekil 3.13'de DST testlerine ait kontrol ve hasta gruplarından bazı spiral örnekleri ve aşağılarında aynı veriye ait öznitelik görüntüleri sunulmuştur, (1) ve (2) kontrol grubuna, (3) ve (4) ise PD hastalarına aittir.



Şekil 3.13 DST testinin spiral örnekleri

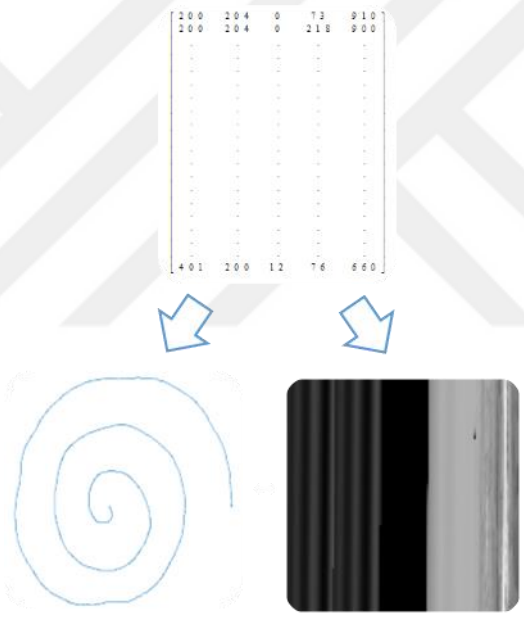
Aynı kişilerin verilerinin tamamı kullanılarak sinyal tabanlı normalize edilmiş kare öznitelik görüntüleri her spiralin altında sunulmuştur. Hem SST hem de DST veri setleri, 57 PD hastası ve 15 kontrol grubu örneği olan 72 görüntüden oluşmaktadır.

CNN modelinin performansı 128 * 128 piksel görüntü çözünürlüğü kullanılarak üç farklı eğitim ve test seti yüzdesiyle değerlendirilmiştir.

Eğitim için verilerin % 90, % 75 ve% 50'si ve test için verilerin sırasıyla % 10, % 25 ve % 50'si kullanılmıştır. Elde edilen sonuçlar ile kullanılan yapının SST ve DST arasındaki farkları yansıtmakta ne kadar başarılı olduğu ortaya konulmuştur.

Veri seti iki farklı yaklaşımla incelenmiştir:

- x ve y değerlerini kullanılarak üretilen spiraller CNN giriş verisi olarak kullanılmıştır.
- tüm özniteliklerden oluşturulan sinyal tabanlı kare görüntüleri CNN giriş verisi olarak kullanılmıştır.



Şekil 3.14 Veri setinden çıkarılan iki çeşit görüntü

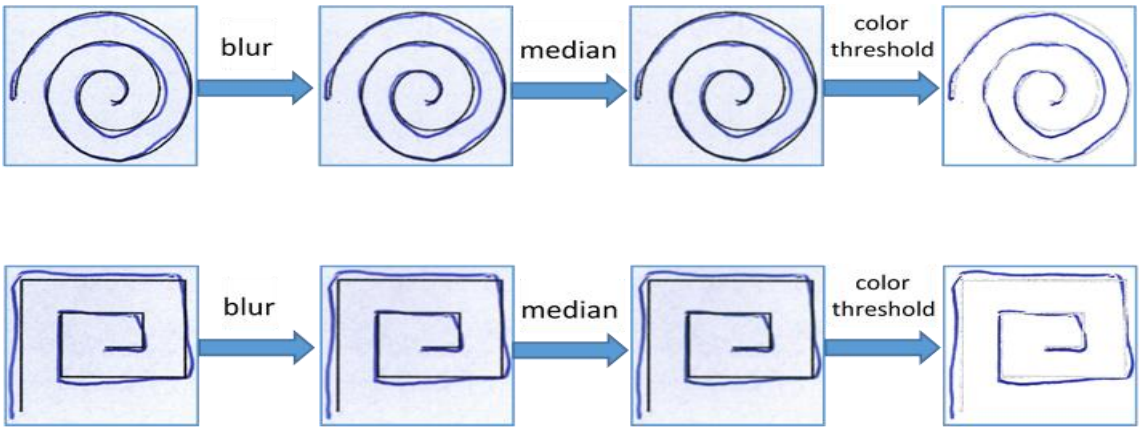
Bu çalışmada incelenen ikinci veri seti Brezilya'nın São Paulo Eyalet Üniversitesinde toplanmıştır. Bu veri seti kâğıt formlardaki resimlerin kırpılıp jpg resim formatında kaydedilmesi suretiyle oluşturulmuştur.

Veri setinin üzerinde sınıflandırma işlemi, ön işleme evresinin etkisini görmek açısından farklı bir yaklaşımla gerçekleştirilmiştir. Veri setindeki görüntüleri analiz

etmek için iki farklı yöntem izlenmiştir. İlk olarak resimler veri setinde bulunduğu orijinal halleriyle sınıflandırılmış, daha sonra da ön işleme ile elde edilen resimler sınıflandırılmıştır.

Yukarıda belirtildiği gibi ilk önce resimler hiçbir ön işleme yapılmadan sadece boyut yeniden ayarlama işleminden sonra CNN yapısına giriş verisi olarak verilmiştir. Bu yaklaşımda CNN modelinin ön işleme yapılmamış görüntülerin ayırt edici özniteliklerini ne düzeyde saptayıp sınıflandırma işlemini gerçekleştireceğini görmek amaçlanmıştır. Kâğıt formlardan tarama ve kırpma işlemleri sırasında doğal olarak görüntülerde az da olsa gürültü oluşması mümkündür. Aynı şekilde resimlerdeki düzgün siyah spiral ve labirent olgularına rağmen CNN yapısındaki öğrenebilir filtrelerin mavi renkteki bireylerin çizmiş olduğu olguları saptayıp ayırt edici özellikleri otomatik olarak bulmaları beklenmektedir.

İkinci yaklaşım olarak görüntülerden sadece bireylerin çizmiş olduğu olguları çıkartıp CNN yapısına giriş verisi olarak kullanmak amaçlanmıştır. Veri seti kâğıt formlardan resimlerin kesilip jpg formatında kaydedilmesiyle oluşturulmuştur. Sadece çizilen spiralleri ayıklamak adına bir dizi ön işlemler yapılmıştır. Resimler ilk önce blur filtre işleminden geçirilmiş, bulanıklaşan resimler daha sonra medyan filtreden geçirilerek en sonunda renk eşiği (threshold) işlemi uygulanmış ve sonra çizilen spiraller elde edilmiştir.



Şekil 3.15 Veriye uygulanan ön işleme aşamaları

Şekil 3.15'deki bu üç aşamalı ön işleme süreci oluşturulurken veri seti üzerinde yapılan önceki çalışmadan [33] esinlenilmiştir. "Gaussian smoothing" olarak da bilinen blur filtre görüntüyü bulanıklaştırarak gürültü ve detayı önler. Medyan filtre de görüntü piksellerinin ortalama değerleriyle ani yükselmeleri ve gürültüyü azaltmayı amaçlar. Son olarak belirli bir renk eşik değeriyle çizilen şekil oluşturulur.

3.11 Oluşturulan CNN Modeli

Bu tez çalışmasında CNN tabanlı sınıflandırıcı, SVM ve NB sınıflandırıcıları kullanılmıştır. Bunun yanında oluşturulan sınıflandırıcı modelleri, farklı eğitim ve test yüzdeleri ile eğitilip, test edilmiştir. Ayrıca farklı model performans ölçme yöntemleriyle modellerin performansları ölçülüp, karşılaştırılmıştır. SVM ve NB gibi makine öğrenmesinin temel algoritmalarını daha güncel ve yenilikçi öğrenme prensibine sahip olan CNN'le karşılaştırarak sonuçlardaki farklılıklar incelenmiştir. CNN yapısının ana katmanları ve işleyiş tarzı önceki bölümlerde anlatılmıştır. Bu tez çalışmasında incelenen veri setlerine uygun bir CNN modeli, denemeler ve araştırmalar sonucunda oluşturulmaya çalışılmıştır.

Modelin optimizasyon algoritması olarak yapılan denemeler sonucunda SGD seçilmiştir. Öğrenme oranı 0.001 olarak seçildiğinde çoğu zaman eğitim süreci yerel minimumlara takılmamış ve aynı zamanda kabul edilir bir hızda gerçekleşmiştir. Makine öğrenmesi ile Parkinson hastalığı teşhisi literatüründeki çalışmalar incelendiğinde çoğu veri setinde varılan başarılı sınıflandırma sonuçları görülmüştür. Bu nedenle Cerrahpaşa tıp fakültesi ve São Paulo üniversitesi el yazısı veri setleri daha önceden CNN yapısıyla incelenmediğinden, yüksek başarı sonuçları hedeflenmiştir. Klasikleşmiş makine öğrenmesi algoritmalarının sadeliği ve işlevselliği ile CNN'nin öğrenme kabiliyetini bahsedilen veri setlerinde karşılaştırmak ve araştırmak, bu çalışmanın temel amaçlarındandır. Ancak CNN'i oluştururken kullanılan yöntemler yüksek seviyeli API derin öğrenme kütüphaneleri içermeleri sebebiyle klasikleşmiş yöntemlerden kullanım açısından daha avantajlı konumdadırlar.

CNN yapısında parametreleri belirleme alanında belli bir yöntem bulunmadığından, yapılan denemelerle elde edilen sonuçlardan yola çıkarak parametreler seçilmiştir.

Bu parametrelerden biri adım parametresidir. Adım (stride), giriş matrisinde kaydırılan piksel sayısıdır. Adım 1 olduğunda, filtreler bir seferde 1 piksel kayıp işlem yaparlar. Adım 2 olduğunda, filtreler her seferinde 2 piksel hareket edip işlem yaparlar. Önerilen modelde, konvolüsyon katmanında adım bir seçilmişken havuzlama katmanında adım ikidir. Oluşturulan model, iki konvolüsyon katmanı ve iki havuzlama katmanından oluşmaktadır.

CNN modeli oluştururken dikkat edilmesi gereken bir başka konu görüntüyü filtrelerin çapına uygun hale getirmektir. Bazen filtre çapı giriş görüntüsüne tam olarak uymayabilir. Bu durumda iki seçenekten biri seçilmelidir. İlk yöntem, sıfır-doldurma (zero-padding) yöntemiyle resmin kenarlarını doldurup filtreye uygun hale getirmektir. İkinci yöntem, filtrenin sığmadığı görüntünün bir bölümünü bırakmaktır. Bu yönteme görüntünün yalnızca geçerli kısmını tutan geçerli-dolgu (valid-padding) adı verilir. Oluşturulan modelde geçerli dolgu kullanılmıştır.

CNN'ni işlem yükü açısından bu kadar işlevsel hale getiren en önemli katman belki de havuzlama katmanıdır. Havuzlama bölümü, mekânsal havuzlama aracılıyla her özellik haritasının boyutsallığını azaltan ancak önemli bilgileri koruyan alt örnekleme olarak da adlandırılır. Mekânsal havuzlama farklı türlerde olabilir:

- Maksimum havuzlama (Max Pooling)
- Ortalama havuzlama (Average Pooling)
- Toplam havuzlama (Sum Pooling)

Maksimum havuzlama, özellik haritasındaki en büyük değeri almaktadır. Ortalama havuzlamada en büyük değer üzerinden ortalama değer hesaplanır. Özellik haritasındaki tüm değerlerin toplamı, toplam havuzlama olarak adlandırılır. Bu çalışmada maksimum havuzlama kullanılmıştır.

Son olarak çıkarılan özellik haritaları matrisleri düzleştirme (flatten) işleminden sonra vektör halinde sınıflandırma işlemi için tam bağlı katmana verilir. Tam bağlı katmanda öznitelikler kombinasyonu sayesinde öğrenme modeli oluşur. Öğrenme sürecinde oluşan hataları göz önünde bulunduran SGD optimizasyon algoritması, parametreleri öğrenme oranı hızıyla güncelleyip eğitimin emin ve uygun adımlarla istenilen hedefe doğru yol almasını sağlamaktadır. Modelin kayıp fonksiyonu

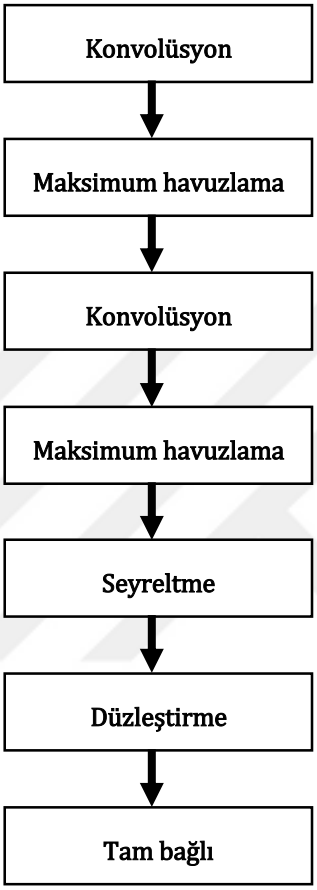
(categorical_crossentropy), İkili sınıflandırma işlemine uygun olması kıstası temel alınarak seçilmiştir. Sınıflandırma işleminin gerçekleştiği tam bağlı katmanın son aktivasyon fonksiyonu olan Softmax ile son çıktıya yani hasta ya da sağlıklı sonucuna ulaşılmaktadır. CNN'nin işleyiş tarzı, bahsedilen konular itibariyle parametrelerin ağ boyunca giderek azaltılıp sadeleştirme yoluna gidilmesi olarak açıklanabilir.

Tablo 3.1 Oluşturulan CNN modelinin detayları

Katman (türü)	Çıktı	Şekil	Parametre
Conv2d_1 (Conv2D)	None	(32, 128, 1)	102432
Max_pooling2d_1 (MaxPooling2D)	None	(32, 26, 1)	0
Conv2d_2 (Conv2D)	None	(64, 26, 1)	51264
Max_pooling2d_2 (MaxPooling2D)	None	(64, 6, 1)	0
Dropout_1 (Dropout)	None	(64, 6, 1)	0
Flatten_1 (Flatten)	None	(384)	0
Dense_1 (Dense)	None	(256)	98560
Dropout_2 (Dropout)	None	(256)	0
Dense_2 (Dense)	None	(512)	131584
Dropout_3 (Dropout)	None	(512)	0
Dense_3 (Dense)	None	(2)	1026

Python programında bulunan modelin detaylı özeti, Tablo 3.1'de verilmiştir. Görüldüğü gibi konvolüsyon katmanında oluşan öznitelik haritaları, maksimum havuzlama katmanınca boyutu indirgenip ileri konvolüsyon katmanına aktarılmaktadır. Bu boyut azaltma doğal olarak öğrenilebilir parametre sayısını da etkilemekte ve azaltmaktadır. İlk konvolüsyon katmanında 5×5 boyutunda 32

filtre kullanılmıştır. İkinci konvolüsyon katmanında ise aynı boyutta 64 filtre kullanılmıştır. Tam bağlı katman ise ilk katmanında 256 nöron, ikinci katmanında 512 nöron ve son katmanında ikili sınıflandırma yapıldığı için iki nöron olan bir MLP (Multi-layer perceptron) olarak görülebilir. İşleyiş prensibi, katmanlarının detayları ve anlatılan CNN modelinin bloklarla temsili Şekil 3.16'de gösterilmiştir.



Şekil 3.16 Oluşturulan CNN modeli

4
SONUÇ VE ÖNERİLER

4.1 Cerrahpaşa Tıp Fakültesi El Yazısı Veri Seti Sonuçları

Bu bölümde, PD tanımlama için oluşturulan CNN tabanlı sınıflandırıcı modelinin deney sonuçları sunulmaktadır. Buna ek olarak farklı model performans değerlendirme yöntemlerinin sonuçları göz önüne alınarak sınıflandırma model parametrelerinin optimize değerlerine ulaşılmaya çalışılmıştır. Bu çalışmada yapılan deneylerde tüm veri setlerindeki resimler gri skala (tek kanal – grayscale) görüntülere çevrilip, analiz yapılmıştır çünkü resimlerin renklerinin sınıflandırma işleminde etkisi bulunmamaktadır ve sadece modele ek olarak bir hesaplama yükü doğuracaktır. Veri setinin bir bölümünde test edilen farklı optimizasyon algoritmalarının karşılaştırılması Tablo 4.1'de verilmiştir. Genel olarak aynı öğrenme oranına sahip optimizasyon algoritmaları aynı sınıflandırma doğruluğunu oluşturmuştur. Ancak SGD algoritması öteki algoritmalardan daha iyi sonuç verdiği için modelin optimizasyon algoritması olarak seçilmiştir.

Tablo 4.1 Farklı optimizasyon algoritmaları karşılaştırması

	%80 / %20 (Eğitim / Test)	
Optimizasyon Algoritması	**Öğrenme oranı**	**Doğruluk (Ortalama Değer)**
SGD	0,001	%86
Adam	0,001	%79
Adadelta	0,001	%79
RMSprop	0,001	%79

Tablo 4.2 ve Tablo 4.3, spiraller ve çıkarılan öznitelik görüntülerinin farklı eğitim ve test oranları kullanılarak, CNN modelinin sınıflandırma doğruluklarını vermektedir. Spiral satırında görüldüğü gibi veri setinin (X ve Y) görsel özellikleri kullanılarak elde edilen spirallerin modele uygulanmasıyla kabul edilebilir doğruluk yüzdesine ulaşılmıştır. Benzer şekilde, farklı sonuçları karşılaştırmak için modele giriş verisi olarak, çıkarılan 5 öznitelik tabanlı görüntü veri seti uygulanmıştır. Temel olarak, daha az özellik kullanarak yüksek sınıflandırma doğruluğu elde etmek amaçlanmıştır. Aşağıdaki tablolar görüntü öznitelikleri ile tüm sinyallerden oluşan resimler arasında olan farkların, doğruluk yüzdelerine nasıl yansıdığını göstermektedir.

Tablo 4.2 SST spiral ve sinyal tabanlı görüntüleri için CNN modeli sonuçları

	SST (128*128 görüntü çözünürlüğü)		
	%50 / %50 (Eğitim / Test)	%75 / %25 (Eğitim / Test)	%90 / %10 (Eğitim / Test)
Spiral	%77,78	%79,78	%87,50
Öznitelik görüntüsü	%70,00	%80,56	%82,00

Tablo 4.3 DST spiral ve sinyal tabanlı görüntüleri için CNN modeli sonuçları

	DST (128*128 görüntü çözünürlüğü)		
	%50 / %50 (Eğitim / Test)	%75 / %25 (Eğitim / Test)	%90 / %10 (Eğitim / Test)
Spiral	%80,56	%88,89	%100
Öznitelik görüntüsü	%90,28	%88,77	%93,33

Tablo 4.2 ve Tablo 4.3'deki değerler incelendiğinde tüm DST verilerinin doğruluk seviyelerinin SST'lerden yüksek olduğu görülmektedir. Bu yüzden DST testinin ayırt edici özelliğinin SST'lerden daha iyi olduğu sonucuna varılmaktadır. Bu çalışmanın temel amaçlarından biri, yeni DST testinin yararlılığını CNN yapısı aracılığı ile kanıtlamaktır. Yapılan deneylerde 128 piksel görüntü çözünürlüğü kullanılmıştır; ayrıca PD tanıma literatüründeki çalışmalar incelendiğinde, yaygın bir şekilde verilerin % 75'inin eğitim ve % 25'inin test için kullanıldığı belirlenmiştir. Cerrahpaşa veri seti üzerinde de bahsedilen orandaki eğitim ve test sürecinden çıkan sonuç % 88 civarındadır; bu da literatürdeki çalışmalar baz alındığında kabul edilebilir bir sonuç olarak görülmektedir. Buradan, oluşturulan CNN yapısının veri setindeki iki gruba ait ayırt edici öznitelikleri öğrenebildiği sonucuna varılmaktadır.

Öznitelik görüntülerin doğruluk seviyeleri, spiral doğrulukları ile benzerdir bu nedenle öznitelik görüntülerinin, veri setindeki görsel ayırt edici özellikleri yansıtabildiği söylenebilir. Metodoloji bölümünde de belirtilen, veri setinin tüm öznitelik sinyallerini temsil eden bir öznitelik görüntüsü oluşturma çalışması başarılı olmuştur. Ayrıca, veri setinin üçüncü özniteliğinin (Z yönü) sınıflandırma doğruluğu üzerinde diğerlerinden daha az etkiye sahip olduğu belirlenmiştir.

Tablo 4.4 SST ve DST kombinasyonu veri setinin sonuçları

Sınıflandırıcılar	**(SST & DST)**	
	Spiral	**Öznitelik Görüntüsü**
NB (%75Eğitim %25Test)	%75	%63
NB 10 fold	%82,81 (+/- %6,54)	%69,05 (+/- %12,36)
SVM (%75Eğitim %25Test)	%52	%47
SVM 10 fold	%65,43 (+/- %7,87)	%56,38 (+/- %10,56)
CNN (%75Eğitim %25Test)	%72	%76
CNN 10 fold	%79,76 (+/- %6,91)	%79,33 (+/- %11,24)

Cerrahpaşa el yazısı veri setinin SST ve DST testlerinin beraber kullanıldığı bu bölümde, farklı sınıflandırıcıların performansları karşılaştırılmıştır. Tüm sınıflandırıcılarda ilk olarak veri setinin %75'i eğitim ve kalan %25'i test için kullanılmıştır. Yapılan denemelerde bu eğitim ve test setlerinin rastgele bir şekilde oluşmasına dikkat edilmiştir. İkinci olarak yaygın bir model performansı ölçme yöntemi olan k-katlamalı çapraz doğrulama yöntemi ile veri seti test ve eğitim setlerine ayrılıp test işlemi yapılmıştır.

Spiral görüntülerde NB sınıflandırıcısı en başarılı yapı olmuştur. Yapılan denemeler sonucunda spiral görüntülerde NB sınıflandırıcısının ve CNN yapısının birbirine oldukça yakın doğruluk yüzdeleri verdikleri görülmüştür. Buradan görüntülerin sadece görsel öznitelikleri göz önüne alındığı takdirde, NB ve CNN'nin ayırt edici öznitelikleri saptamakta hemen hemen aynı oranda başarılı oldukları sonucu çıkarılabilir. Ayrıca CNN, çıkarılan öznitelik görüntüleri üzerinde de %76 gibi yüksek doğruluk yüzdesi sağlarken NB bunu yapamamaktadır; bu da CNN yapısının adaptif ve esnek öğrenmede daha başarılı olduğunu ortaya koymaktadır. Oluşturulan öznitelik görüntülerinde en başarılı yapı CNN olmuştur. SVM sınıflandırıcısının bu veri setine uygun olmadığı görülmüştür.

Tablo 4.4'deki CNN 10 fold satırında ortalama değerler birbirine yakındır bu da CNN'nin; spiral ve öznitelik görüntülerde aynı başarı yüzdelerine yakınsayacak şekilde öğrenme işlemini gerçekleştirmiş olduğunu göstermektedir. Buradan CNN'nin genelleştirme yeteneğinin daha yüksek olduğu kanısına varılabilir bu nedenle adaptif modeller gerektiren problemlerde CNN'i tercih etmek daha avantajlı olabilir.

4.1.1 Cerrahpaşa Veri Seti Sonuçlarının Yorumlanması ve Öneriler

Sonuç olarak, el yazısı çizimlerinden PD tanıma problemine bir CNN mimarisi ve farklı sınıflandırıcılar önerilmiştir. Temel olarak, tez çalışmasının başlıca amaçlarından biri söz konusu veri setinin ham hali göz önünde bulundurarak uygun ön işleme yöntemleri ile Parkinson hastalığı sınıflandırma işlemini gerçekleştirmektir. CNN'nin, spirallerin ayırt edici özelliklerini öğrendiği gibi

öznitelik görüntülerinin de ayırt edici özelliklerini öğrenebildiği açıktır. Bu veri seti üzerinde yapılan çalışmalar veri setinin hem görsel özniteliklerini hem de dijital kalem ile toplanan verilerini sınıflandırma işleminde kullanma yönünde olmuştur. Önerilen ve test edilen sınıflandırıcılar, farklı model performans ölçme teknikleri ile test edilmiştir.

Aslında, oluşturulan CNN modeli çıkarılmış öznitelik resimleri sınıflandırmaya etkili bir şekilde yanıt vermektedir, çünkü doğruluk yüzdeleri (spiraller ve çıkarılmış öznitelik resimleri) birbirine yakındır, ancak NB sınıflandırıcısı spirallere uygun görünse de öznitelik resimlerinde CNN kadar yüksek başarı sağlamamıştır. Genelleştirilmiş bir yapı elde etmek adına, veri setinin iki özniteliği (x, y) ile yapılan sınıflandırma işlemi ve tüm öznitelikler ile yapılan sınıflandırma işlemi karşılaştırılmıştır.

Ayrıca, CNN modelinin sınıflandırma sonuçları, DST analiz bölümünde SST'den daha yüksek bir doğrulukla sonuçlanmıştır. Bu değer, literatür çalışmalarının sonuçlarının kapsamına yakın olduğundan yapılan işlemin pratikliğini göstermektedir.

Sonuç olarak, bu çalışma, hastanelerde PD tanıma tıbbı testleri için klasik SST testi kadar DST testinin de kullanılabileceğini ortaya koymaktadır.

Gelecek çalışmalarla ilgili olarak, veri seti üzerinde LeNet veya ImageNet gibi farklı derin öğrenme mimarileri kullanılabilir. Ek olarak, görüntüler yerine veri setinin sinyallerini analiz etmek için tek boyutlu CNN ile farklı sınıflandırıcıları kullanmak düşünülebilir.

4.2 São Paulo Eyalet Üniversitesi El Yazısı Veri Seti Sonuçları

São Paulo Eyalet Üniversitesi el yazısı veri seti üzerinde yapılan önceki referans çalışmada [33], 3 örüntü tanıma tekniği ile sınıflandırma işlemi yapılmıştır. Bu sınıflandırıcılar OPF (Optimum Path Forest) ve SVM (Support Vector Machine) ve NB'den (Naive Bayes) oluşmaktadır. Ayrıca söz konusu çalışmada veri setindeki görüntülerden farklı öznitelikler oluşturmak için çizilen şekillerle şablon şekiller arasındaki farklar nokta nokta hesaplanarak karşılaştırılmıştır. Bu farklardan oluşturulan özniteliklerle yeni veri seti oluşturulmuştur. Şablon şekiller ve el yazısı

çizimler veri setinde iç içe geçmiş bir durumda olduğundan, bu görüntüleri bir birinden ayırma ön işlemi yapılmıştır. Metodoloji bölümünde bahsedilen ve bu tez çalışmasında kullanılan ön işleme tekniği referans çalışması ile benzerdir. Dolayısıyla yapılan araştırma ve çalışmanın sonuçlarının kabul edilebilir bir seviyede olduğunu, referans çalışmasının sonuçlarıyla karşılaştırarak belirlemek mümkündür. Ancak benzerliklere rağmen araştırmayı genişleterek bu tez çalışmasında görüntüler hem CNN de kullanılmıştır hem de veri seti NB ve SVM sınıflandırıcılarında test edilmiştir. Ayrıca görüntülerin önişleme öncesi ve sonrası doğruluk yüzdelerini içeren tablolar oluşturulmuştur.

Pythondaki makine öğrenmesi scikit-learn kütüphanesinden yararlanılarak SVM ve NB sınıflandırıcıları oluşturulmuştur. Verileri bu kütüphanenin giriş verisi olarak uygun hale getirme amacıyla görüntüler öncelikle yeniden boyutlandırılmış ardından bir dizi (array) halinde sınıflandırıcıya girdi olarak verilmiştir. Sınıflandırma işlemine ön işleme evresinin ne kadar etkisi olduğunu saptama adına görüntülerdeki şeklin ön işlem görmüş ve görmemiş hali sınıflandırıcıya giriş verisi olarak verilmiştir. Buna bağlı olarak modellerin doğruluk yüzdesi üzerinden ön işlemenin ne kadar etkisi olduğunu saptamak mümkündür.

Tablo 4.5 Spiral veri setinin sonuçları

Sınıflandırıcılar (%75Eğitim %25Test)	**Spiral**		
	Orijinal	**Sadece çizim**	
		Yapılan çalışma	Önceki Referans Çalışma
NB	%0,61	%0,71	%65,88 $\pm$ 4,57
SVM	%0,66	%0,68	%51,22 $\pm$ 2,91
CNN	%0,84	%0,84	-

Tablo 4.6 Labirent veri setinin sonuçları

Sınıflandırıcılar (%75Eğitim %25Test)	**Labirent**		
	Orijinal	**Sadece çizim**	
		Yapılan çalışma	Önceki Referans Çalışma
NB	%0,60	%0,72	%50,28 ± 4,18
SVM	%0,58	%0,70	%66,37 ± 4,01
CNN	%0,75	%0,79	-

Yapılan eğitim ve test işleminde verilerin %25'i test ve %75'i eğitim için kullanılmıştır. Ön işleme uygulanan görüntülerin doğruluk yüzdesinin daha fazla olduğu görülmüştür. Bu da uygulanan ön işleme yönteminin görüntülerin ayırt edici özniteliklerinin ortaya çıkartmakta başarılı olduğunu göstermektedir.

Bu pozitif doğruluk artışları birbirinden farklı olmaktadır. Örneğin spiral görüntülerinde SVM'de ön işleme tekniği doğruluk yüzdesinde %2'lik bir iyileştirme sağlarken bu yüzde NB sınıflandırıcısında %10 civarındadır. Ayrıca oluşturulan CNN modelinde ön işleme evresinin bir etkisi olmadığı görülmektedir yani CNN mimarisi ön işlem görmüş ve görmemiş spiral görüntülerin ayırt edici özniteliklerini öğrenebilir filtreler sayesinde öğrenebilmektedir.

Labirent görüntülerinde ise ön işleme evresi SVM ve NB sınıflandırıcılarının doğruluk yüzdelerine yaklaşık %12 gibi bir artış sağlamıştır. CNN yapısında ise %4'lük bir artış olmuştur. Tablo 4.5 ve 4.6 incelenirse CNN'nin, spiral ve labirentlerde daha yüksek bir başarı oranına sahip olduğu görülmektedir. Bu da CNN'nin adaptif ve öğrenebilir yapısını ortaya koymaktadır.

Önceki referans çalışmasının sonuçları ile bu çalışmada elde edilen yüzdeler karşılaştırıldığında bir iyileştirme ve daha yüksek başarı elde edildiği

gözlenmektedir. Bu karşılaştırmada en yüksek farkın labirent bölümünde NB sınıflandırıcısında olduğu açıktır.

Tablo 4.7 Spiral veri seti 4-katlamalı çapraz doğrulama Sonuçları

Sınıflandırıcılar (4-Katlamalı Çapraz Doğrulama)	**Spiral**		
	Orijinal	**Sadece çizim**	
		Yapılan çalışma	Önceki Referans Çalışma
NB	%70,92 (+/- %3,01)	%75,00 (+/- %2,77)	%64,23 ± 7,11
SVM	%73,91 (+/- %3,44)	%75,27 (+/- %4,31)	%50,16 ± 1,71
CNN	%80,16 (+/- %2,22)	%80,43 (+/- %3,69)	-

Tablo 4.8 Labirent veri seti 4-katlamalı çapraz doğrulama sonuçları

Sınıflandırıcılar (4-Katlamalı Çapraz Doğrulama)	**Labirent**		
	Orijinal	**Sadece çizim**	
		Yapılan çalışma	Önceki Referans Çalışma
NB	%52,99 (+/- %4,94)	%76,36 (+/- %1,94)	%59,20 ± 4,78
SVM	%62,23 (+/- %3,20)	%71,47 (+/- %5,06)	%66,72 ± 5,33
CNN	%80,43 (+/- %1,33)	%80,43 (+/- %1,72)	-

Deneylerin bu bölümünde Tablo 4.7 ve 4.8'de verildiği gibi veri seti 4-katlamalı çapraz doğrulama metodu ile test edilmiştir. 4-katlamalı olmasının sebebi ise referans çalışmadaki işlemin bu oran üzerinden yapılmasıdır. 4-katlamalı çapraz

doğrulama test yönteminde ise yine ön işleme operasyonun doğruluk üzerinde başarısı görülmektedir. Tablolardaki 4-katlamalı çapraz doğrulama değerleri, bir fonksiyonun farklı girdilerle 4 kez çalıştırılıp sonuçların ortalamasının alınması ile bulunmuştur.

Spiral bölümünde referans alınan çalışmada SVM ve NB sınıflandırma doğruluk yüzdeleri %14'lük bir fark içerirken; yapılan çalışmada bu iki sınıflandırıcının doğruluk yüzdeleri hemen hemen aynı oranda artmışlardır ki bu da tez çalışmasında yapılan ön işleme işleminin önceki referans çalışmasına kıyasla geliştirildiğini göstermektedir.

Labirent görüntülerinde yapılan denemeler sonucunda CNN yapısında bu ortalamaların birbirine yakın olduğu görülmüştür. NB sınıflandırıcısının SVM den daha başarılı olduğunu söylemek mümkündür.

Yine önceki tablolarda olduğu gibi k-katlamalı çapraz doğrulama yönteminde de önceki yapılan çalışmaya nazaran doğruluk yüzdelerinde gelişme gözlenmektedir. CNN yine en yüksek yüzdeye sahiptir. Burada dikkat çekici bir husus da CNN için belirli bir iterasyonda (20 iterasyon) ve sonuçlardan ortalama alındığında spiral ve labirent görüntülerde hemen hemen aynı doğruluk yüzdelerine ulaşılmasıdır.

Sonuç olarak SVM, NB ve CNN'nin öznitelik çıkartma işlemindeki farklılıklar, sınıflandırma sonuçlarına da yansımıştır. Bu çalışmada farklı sınıflandırma algoritmalarının karşılaştırılması, incelenen veri setlerinin tüm özniteliklerinin kullanılması, DST testinin yüksek ayırt edici özelliği, CNN'nin adaptif yapısı, referans çalışmanın sonuçlarının geliştirilmesi, veriye özel ön işleme tasarlanması, ön işlemenin sınıflandırmaya olan etkisi, farklı performans değerlendirme yöntemleri ile modellerin test edilmesi gibi konular ele alınmıştır.

Ancak tez çalışmasındaki en önemli hususlardan biri Parkinson hastalığı teşhisi için gelecekte otomatik bir sistem oluşturma noktasında literatüre önemli bir katkı sağlamak olmuştur.

Kaynakça

[1] C.-W. Cho, W.-H. Chao, S.-H. Lin, and Y.-Y. J. E. S. w. a. Chen, "A vision-based analysis system for gait recognition in patients with Parkinson's disease," 36, no. 3, pp. 7033-7039, 2009.

[2] B. E. Sakar et al., "Collection and analysis of a Parkinson speech dataset with multiple types of sound recordings," 17, no. 4, pp. 828-834, 2013.

[3] M. Hariharan, K. Polat, R. J. C. m. Sindhu, and p. i. biomedicine, "A new hybrid intelligent system for accurate detection of Parkinson's disease," 113, no. 3, pp. 904-913, 2014.

[4] C. R. Pereira, S. A. Weber, C. Hook, G. H. Rosa, and J. P. Papa, "Deep Learning-Aided Parkinson," in 2016 29th SIBGRAPI Conference on Graphics, Patterns and Images (SIBGRAPI), 2016, pp. 340-346: IEEE.

[5] C. R. Pereira et al., "Handwritten dynamics assessment through convolutional neural networks: An application to Parkinson's disease identification," 87, pp. 67-77, 2018.

[6] M. Moetesum, I. Siddiqi, N. Vincent, and F. J. P. R. L. Cloppet, "Assessing visual attributes of handwriting for prediction of neurological disorders—A case study on Parkinson's disease," 2018.

[7] P. Drotár, J. Mekyska, I. Rektorová, L. Masarová, Z. Smékal, and M. J. A. i. i. M. Faundez-Zanuy, "Evaluation of handwriting kinematics and pressure for differential diagnosis of Parkinson's disease," 67, pp. 39-46, 2016.

[8] S. Bind et al., "A survey of machine learning based approaches for Parkinson disease prediction," 6, no. 2, pp. 1648-1655, 2015.

[9] M. Shahbakhi, D. T. Far, E. J. J. o. B. S. Tahami, and Engineering, "Speech analysis for diagnosis of parkinson's disease using genetic algorithm and support vector machine," 7, no. 4, pp. 147-156, 2014.

[10] M. F. J. N. r. n. Beal, "Experimental models of Parkinson's disease," 2, no. 5, p. 325, 2001.

[11] L. Naranjo, C. J. Pérez, J. Martín, Y. J. C. m. Campos-Roca, and p. i. biomedicine, "A two-stage variable selection and classification approach for Parkinson's disease detection by using voice recording replications," 142, pp. 147-156, 2017.

[12] B. E. Maki and W. E. J. N. c. McIlroy, "Change-in-support balance reactions in older persons: an emerging research area of clinical importance," 23, no. 3, pp. 751-783, 2005.

[13] J. J. T. J. o. n. Parkinson and c. neurosciences, "An essay on the shaking palsy," 14, no. 2, pp. 223-236, 2002.

[14] M. Isenkul, B. Sakar, and O. Kursun, "Improved spiral test using digitized graphics tablet for monitoring Parkinson's disease," in Proc. of the Int'l Conf. on e-Health and Telemedicine, 2014, pp. 171-5.

[15] W. G. Hatcher and W. Yu, "A Survey of Deep Learning: Platforms, Applications and Emerging Research Trends," IEEE Access, 6, pp. 24411-24432, 2018.

[16] Z. Fadlullah et al., "State-of-the-art deep learning: Evolving machine intelligence toward tomorrow's intelligent network traffic control systems," 19, no. 4, pp. 2432-2455, 2017.

[17] Theano. (2017, Nov 21). Theano at a Glance. Available: http://deeplearning.net/software/theano/introduction.html

[18] Keras. (2018). Why use Keras? Available: https://keras.io/why-use-keras/

[19] L. Bottou et al., "Comparison of classifier methods: a case study in handwritten digit recognition," in Pattern Recognition, 1994. 2-Conference B: Computer Vision & Image Processing., Proceedings of the 12th IAPR International. Conference on, 1994, 2, pp. 77-82: IEEE.

[20] I. Goodfellow, Y. Bengio, A. Courville, and Y. Bengio, Deep learning. MIT press Cambridge, 2016.

[21] Y. Le Cun et al., "Handwritten digit recognition: Applications of neural network chips and automatic learning," 27, no. 11, pp. 41-46, 1989.

[22] Stanford University. (2018). CS231n: Convolutional Neural Networks for Visual Recognition. Available: http://cs231n.github.io/convolutional-networks/

[23] Nick Bourdakos. (2018). Understanding Capsule Networks—AI's Alluring New Architecture. Available: https://medium.freecodecamp.org/understanding-capsule-networks-ais-alluring-new-architecture-bdb228173ddc

[24] A. Krizhevsky, I. Sutskever, and G. E. Hinton, "Imagenet classification with deep convolutional neural networks," in Advances in neural information processing systems, 2012, pp. 1097-1105.

[25] Saimadhu Polamuri. (2017). DIFFERENCE BETWEEN SOFTMAX FUNCTION AND SIGMOID FUNCTION. Available: http://dataaspirant.com/2017/03/07/difference-between-softmax-function-and-sigmoid-function/

[26] C. Bergmeir, R. J. Hyndman, B. J. C. S. Koo, and D. Analysis, "A note on the validity of cross-validation for evaluating autoregressive time series prediction," 120, pp. 70-83, 2018.

[27] J. Brownlee. (2018, May 23). A Gentle Introduction to k-fold Cross-Validation. Available: https://machinelearningmastery.com/k-fold-cross-validation/

[28] S. Rueping, "SVM classifier estimation from group probabilities," in Proceedings of the 27th international conference on machine learning (ICML-10), 2010, pp. 911-918.

[29] R. Gandhi. (2018,). Support Vector Machine—Introduction to Machine Learning Algorithms. Available: https://towardsdatascience.com/support-vector-machine-introduction-to-machine-learning-algorithms-934a444fca47

[30] S. Ray. (2017,). Understanding Support Vector Machine algorithm from examples (along with code). Available: https://www.analyticsvidhya.com/blog/2017/09/understaing-support-vector-machine-example-code/

[31] I. Rish, "An empirical study of the naive Bayes classifier," in IJCAI 2001 workshop on empirical methods in artificial intelligence, 2001, 3, no. 22, pp. 41-46: IBM New York.

[32] R. Gandhi. (2018,). Naive Bayes Classifier. Available: https://towardsdatascience.com/naive-bayes-classifier-81d512f50a7c

[33] C. R. Pereira et al., "A new computer vision-based approach to aid the diagnosis of Parkinson's disease," 136, pp. 79-88, 2016.

Tezden Üretilmiş Yayınlar

İletişim Bilgisi: pedram.khatamino@gmail.com

Konferans Bildirisi

1. Pedram KHATAMINO, İsmail CANTÜRK, Lale ÖZYILMAZ - A Deep Learning-CNN Based System for Medical Diagnosis: An Application on Parkinson's Disease Handwriting Drawings (6th International Conference on Control Engineering & Information Technology – CEIT 2018)