



HARRAN ÜNİVERSİTESİ MÜHENDİSLİK DERGİSİ

*HARRAN UNIVERSITY JOURNAL of ENGINEERING*

e-ISSN: 2528-8733 (ONLINE)

## Parkinson Hastalığının Tespitinde Ses Sinyalleri Üzerinden Makine Öğrenmesi Algoritmalarının Karşılaştırılması

*Comparison of Machine Learning Algorithms Using Sound Signals in Detection of Parkinson's Disease*

*Yazar(lar) (Author(s)): İbrahim Halil GÖKÇİN<sup>1</sup>*

<sup>1</sup> ORCID ID: 0000-0001-6603-3356

Bu makaleye şu şekilde atıfta bulunabilirsiniz (To cite to this article): "GÖKÇİN İ. H., "Parkinson Hastalığının Tespitinde Ses Sinyalleri Üzerinden Makine Öğrenmesi Algoritmalarının Karşılaştırılması", *Harran Üniversitesi Mühendislik Dergisi*, 8(2): 130-140, (2023).

DOI: 10.46578/humder.1217255



# Parkinson Hastalığının Tespitinde Ses Sinyalleri Üzerinden Makine Öğrenmesi Algoritmalarının Karşılaştırılması

İbrahim Halil GÖKÇİN\*

<sup>1</sup>Harran Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, Haliliye/ŞANLIURFA

## Öz

Parkinson hastalığının belirtilerinden olan konuşma bozukluğu ve yazı yazmada zorlanma gibi semptomlar günümüzde makine öğrenmesi teknikleri kullanılarak değerlendirilebilmektedir. Bu çalışmada da konuşma bozukluklarının değerlendirilmesine yönelik kullanılan makine öğrenmesi algoritmalarının karşılaştırılmasının yapılması amaçlanmıştır. Çalışmada örneklem olarak Cerrahpaşa Tıp Fakültesi Nöroloji kliniğinde 188 Parkinson hastası ve 64 sağlıklı bireyden toplanan verilerle oluşturulmuş olan PCD veri seti kullanılmıştır. Bu çalışmada, Karar Ağaçları, K-En Yakın Komşu, Destek Vektör Makineleri (DVM) kullanılmıştır ve DVM için ise Doğrusal Kernel, Polinomsal Kernel ve RBF Kernel kullanılmıştır. Adaboost Karar Ağaçları, Rastgele Orman, Konvolüsyonel Sinir Ağları, Çok Katmanlı Algılayıcılar ve Derin Boltzmann Makinesi kullanılmıştır. Çalışma sonucunda en iyi sonuçların Konvolüsyonel Sinir Ağları algoritmasından elde edildiği görülmüştür.

## Comparison of Machine Learning Algorithms Using Sound Signals in Detection of Parkinson's Disease

### Abstract

Symptoms such as speech disorder and difficulty in writing, which are the symptoms of Parkinson's disease, can be evaluated using machine learning techniques today. This study aims to compare the machine learning algorithms used for the evaluation of speech disorders. In this study, we are utilizing the PCD dataset, which was created with data collected from 188 individuals with Parkinson's disease and 64 healthy individuals, and was used as a sample in the Neurology Clinic of Cerrahpaşa Medical Faculty. In this study, Decision Trees, K-Nearest Neighbors, and Support Vector Machines (SVM) are used and for SVM, Linear Kernel, Polynomial Kernel, and RBF Kernel are executed. Adaboost Decision Trees, Random Forest, Convolutional Neural Networks, Multilayer Perceptrons, and Deep Boltzmann Machines were used. As a result of the study, it was seen that the best results were obtained from the Convolutional Neural Networks algorithm.

### Makale Bilgisi

Başvuru:10/12/2022  
Kabul:31/08/2023

### Anahtar Kelimeler

Parkinson  
Ses Sinyalleri  
Makine Öğrenmesi

### Keywords

Parkinson's  
Audio Signals  
Machine Learning

## 1. GİRİŞ (INTRODUCTION)

Parkinson hastalığı, dünya nüfusunun 1000'de 1-2'sini etkileyen ve yaşlanmayla birlikte yaygınlığı artan nörolojik bir hastalıktır. Parkinson hastalığının 60 yaş üstü toplam dünya nüfusunun %1'ini etkilediği bilinmektedir. Hastalığın genetik ve çevresel bir takım etkenlere bağlı olduğu düşünülmekle birlikte kesin olarak sebebi bilinmemektedir. Yapılan araştırmalarda %5-10 oranında genetik faktörler saptanırken bazı çevresel faktörlerin de hastalığın oluşumunda katkısı olduğu düşünülmektedir [1].

Tysnes ve Storstein yaptıkları araştırmalarda bu çevresel faktörlerin arasında CO<sub>2</sub>, tarım ilaçları ve ağır metaller gibi zararlı maddelere fazlaca maruz kalmak gibi etkenler bulunmaktadır. Bununla birlikte beyaz

\* İbrahim Halil GÖKÇİN, e-mail:ihgokcin@gmail.com

ırktan olmak, kırsal kesimde yaşamak ve kuyu suyu içmek gibi bazı durumların da Parkinson hastalığının risk faktörleri arasında olduğu belirtilmektedir [2].

PD hastalığı teşhisi konmuş olan bireylerde dopamin seviyesinde gerçekleşen azalmalar sonucu kasların kontrol edilmesinde sorunlar yaşanmakta ve hareket zorlukları meydana gelmektedir. Hastalığın teşhisi konduktan sonra kesin tedavisi olmamasına karşın hekimler tarafından hastalığın ilerlemesine ve semptomların azaltılmasına yönelik tedavi süreci işletilmektedir [3].

PD hastalığının klinik görünümü ve dopaminerjik tedaviye diğer nörodejeneratif hastalıklara nazaran vermiş olduğu görünür cevapla ayırt edilebilmesi mümkün olmaktadır. Bu nedenle hastalığın önceden teşhis edilmesi tedavi açısından oldukça önemli olmaktadır. Çünkü PD, ilaç tedavisine en fazla yanıt veren nörodejeneratif hastalıktır [4].

Parkinson hastalığının başlıca belirtileri hareket eksikliği ve yavaşlığı, titreme ile eklem bölgelerinde görülen sertliklerdir. Bunlarla birlikte dengede duramama, konuşma ve zihinde bozulmalarla depresif ruh hali yine Parkinson hastalığının belirtileri arasındadır. Bu belirtiler hastaya zamanında tedavi başlatılmadığı sürece zamanla şiddetlenmektedir. Hastalığın ilk belirtilerinin %75 oranında 60 yaşından sonra ortaya çıktığı görülmektedir [2].

Parkinson hastalığının konuşma üzerindeki etkileri arasında kısık ses, konuşmaya başlamada ve sürdürmede sıkıntı yaşama, akıcı konuşmada zorluk ve konuşmanın donuklaşması gibi sorunlar bulunmaktadır [5].

Parkinson hastalığında genellikle hastalığın ilk evrelerinde konuşma bozukluğuna rastlanmamaktadır. Bununla birlikte %50 oranında ilerleyen safhalarda da konuşma bozukluğu yaşamayan hastalar bulunmaktadır. Genel olarak hastalığın karakteristik özelliklerinden dolayı hastaların konuşmalarında sorunlar yaşamaya başladıkları görülmektedir. Parkinson hastalığında meydana gelen konuşma bozukluklarında dopamin eksikliği nedeniyle yüz ve ağız bölgesindeki hareket etme kabiliyetinde azalmalar meydana gelmektedir [6].

Aynı zamanda hastaların nefes alma kapasitesinin düşmesi de konuşma bozukluklarının ana nedenlerindedir. Konuşmada yaşanan bozuklukları genel itibarıyla başlangıcı konuşma tonundaki yumuşama olmaktadır. Bununla birlikte hastalar konuşmalarında vurgu yapmadan monoton bir şekilde konuşmakta, konuşmaları hem yumuşak hem de hızlı tonda olmaktadır. Kimi durumlarda kelimeler arasındaki boşluklar kaybolmakta ve cümlelerin son kelimelerinde tekrarlar olmaktadır. Yavaş ve zayıf tonda konuşmalar da Parkinson hastalarının konuşma karakteristikleri arasındadır [7].

Günümüzde özellikle makine öğrenmesindeki gelişmelerle birlikte ses bozuklukları ve konuşma ölçümleri kapsamında yapılan çalışmalarda artış olmuştur. Özellikle Parkinson gibi konuşma bozukluğu semptomu olan hastalıklar için farklı yöntemler kullanılarak seslerin analizi yöntemiyle sınıflandırma çalışmaları yapılmaktadır. Parkinson hastalığı için yapılan çalışmalara bakıldığında genel olarak çalışmaların makine öğrenmesi metotlarıyla seslerin ve hasta el yazılarının değerlendirilmesi üzerine yoğunlaşmış olduğu görülmektedir. Ses bozukluklarının incelenmesi amacıyla oluşturulan veri setlerinin bir mikrofon vasıtasıyla ses kaydı alınarak yapıldığı görülmektedir. Daha sonra bu ses kayıtları makine öğrenmesinin farklı metotları kullanılarak analiz edilmekte, bu sayede hasta konuşmaları ve sağlıklı insanlar arasındaki ses ve konuşma sınıflandırmaları yapılabilmektedir. Yapılan çalışmalardaki doğruluk oranları çalışmaların hastalık belirtilerinin analiz edilmesinde faydalı olduğunu göstermiştir [8].

Parkinson hastalarının seslerinin analiz edilmesinde literatürde oldukça farklı yöntemler kullanıldığı görülmektedir. Bu yöntemler arasında ses frekanslarındaki düzensizlik, jitter, shimmer, kısıklık ölçümü, Mel frekansı kepsrum ölçümü, doğrusal tahminleme, işitsel modelleme gibi farklı metotlar bulunmaktadır [9].

Parkinson hastalığının kesin bir tedavisi olmamasına rağmen hastalığın erken teşhisi durumunda semptomların ilerlemesi durdurulabilmekte ya da yavaşlatılabilmektedir. Bu nedenle bu tip teşhis yöntemlerinin geliştirilmesi hastalık için oldukça önemlidir.

Literatür incelendiğinde yaygın olarak kullanılan birkaç tane hazır veri setinin olduğu görülmektedir. Bu veri setlerinden biri Little ve arkadaşları tarafından oluşturulan “Oxford Parkinson's Disease Detection (OPD)” veri seti ve diğeri Şakar ve arkadaşları tarafından oluşturulan “Parkinson Speech Dataset with Multiple Types of Sound Recordings (PSD)” veri setidir. Bu veri setlerinden PSD’de toplam 40 deneğe, OPD’de ise 31 deneğe ait veriler bulunmaktadır. Denek sayılarına bakıldığında bu veri setlerinin oldukça sınırlı olduğu görülmektedir. Ancak Şakar ve arkadaşları tarafından oluşturulan “Parkinson's Disease Classification (PDC)” veri seti toplam 252 deneğe ait 756 veriye sahip olması nedeniyle yapılan çalışmalarda son üç senedir yaygın olarak kullanılmaya başlanmıştır [10] [8].

Diğer veri setleriyle karşılaştırıldığında PDC veri setinin hem örneklem boyutunun büyüklüğü hem de kullanılan sinyal işleme teknikleri nedeniyle Parkinson hastalığına ilişkin daha iyi bir temsil imkânı tanıdığı düşünülmektedir [11].

Parkinson hastalığının konuşma bozukluğu üzerinden makine öğrenmesi yöntemleriyle incelendiği çalışmaların yöntemlerine ve elde edilen sonuçlara kabaca bakıldığında; Little ve arkadaşlarının yaptıkları çalışmada 23 Parkinson hastası ve 8 sağlıklı bireyden oluşturdukları OPD örneklemelerinde sesin dalgalanma, titreşim, ses seviyesi ve uyum özellikleri üzerinde bir ayırım yapmışlar ve çalışmalarında %91,4 oranında bir başarı elde etmişlerdir [8].

Tsanas ve arkadaşları çalışmalarında OPD veri setini kullanmış ve metot olarak kaba küme yöntemini tercih etmişlerdir. Araştırmacılar çalışmalarında verileri farklı algoritmalarla filtreleyerek sınıflandırma yapmış, çalışma sonucunda %90 oranında bir başarı sağlamışlardır. Aynı şekilde OPD veri setini kullanan Das da çalışmasında sinir ağları yöntemini kullanarak %92,9 başarı oranı yakalamışlardır [12].

Şakar ve arkadaşları kendi oluşturdukları Cerrahpaşa Tıp Fakültesinde Nöroloji departmanında tedavi gören 20 Parkinson hastası ve 20 sağlıklı bireyden oluşan toplam 40 denekli veri setleriyle yapmış oldukları çalışmada K-En Yakın Komşuluk ve Destek Vektör Makineleri yöntemlerini kullanarak sınıflandırma yapmışlardır. Bununla birlikte araştırmacılar hem Özetlenmiş Birini Dışarıda Bırakma(ö-BDB) ve Bir Bireyi Dışarıda Bırakma(BBDB) yöntemlerinin de sınıflandırma yöntemi olarak etkisini incelemiş, çalışma sonucunda ö-BDB yönteminde %85 oranında başarı elde etmişlerdir [10].

Şakar ve arkadaşları 2019 yılında veri setlerini geliştirerek bir çalışma daha yapmışlar, bu çalışmalarında toplam 252 denekten oluşan 756 veriyle Naive Bayes, K-En Yakın Komşu (KNN), Rastgele Orman, DVM-RBF, DVM-Çok Katmanlı ve DVM-Doğrusal yöntemleriyle sınıflandırma yapmışlardır. Araştırmacılar bu çalışmalarında toplamda 6 ana öznelik setiyle toplam da 753 öznelik belirlemişlerdir [13].

Badem de Şakar ve arkadaşları tarafından oluşturulan PCD veri setini kullanmış oldukları çalışmasında K-En Yakın Komşu (KNN), Naive Bayes, Destek Vektör Makineleri ve Rastgele Orman makine öğrenmesi tekniklerini kullanmıştır. Bu teknikler üzerinde karşılaştırmalı analiz yapan yazar, sonuç olarak K-En Yakın Komşu yöntemiyle en yüksek doğruluk oranına ulaşmıştır [11] [13].

Bu çalışmanın amacı PCD veri seti kullanılarak makine öğrenme yöntemlerinin performansını değerlendirmektir. Çalışmanın diğer çalışmalardan farkı ise daha fazla makine öğrenmesi tekniği kullanarak bu tekniklerin PCD veri seti üzerindeki başarısını test etmektir.

## 2. MATERYAL VE METOT (MATERIAL AND METHOD)

### 2.1. Veri Seti

Bu çalışmada Şakar ve arkadaşları tarafından kullanılan veri seti kullanılmıştır. Bu veri setinde Cerrahpaşa Tıp Fakültesi Nöroloji Anabilim dalında tedavi görmekte olan yaşları 33-87 arasında değişen, 107 erkek ve 81 kadından oluşan toplam 188 Parkinson hastasından toplanan veriler kullanılmıştır. Çalışmada bu verilerle kontrol grubu olan 23 erkek ve 41 kadından oluşan toplam 64 sağlıklı bireyden toplanan veriler birlikte analiz edilmiştir. Çalışmada kullanılan veri ise 44.1 KHz'e ayarlanan bir mikrofon vasıtasıyla deneklerin üç defa "a" ünlüsünü söyledikleri ses kayıtlarıdır. Veri seti toplamda 252 denekten alınan 756 ses kaydından oluşmaktadır.

Bu veri setindeki veriler bazı öznelik gruplarına bölünmüştür. Bu gruplar temel olarak Temel Özellikler (Baseline Features), Zaman Frekansı Özellikleri (Time Frequency Features), Mel Frekans Cepstral Katsayıları (MFCC), Dalgacık Özellikleri (Wavelet features) ve Vokal Kıvrım Özelliklerinden (Vocal Fold Features) oluşmaktadır. Oluşturulan veri gruplarına ilişkin bilgiler Tablo 1'de gösterilmiştir.

**Tablo 1.** Veri Özellik Grupları ve Öznelik Sayıları ve açıklamaları

Veri Özellik Grupları			Öznelik Sayısı
Temel	Titreşim varyantları	Jitter varyantları, vokal kordların salınımlı modelinde meydana gelen kararsızlıkları yakalamak için kullanılır ve bu özellik alt kümesi, temel frekanstaki döngüden döngüye değişiklikleri nicelendirir.	5
	Parıltı varyantları	Parıltı varyantları da vokal kordların salınım modelinin kararsızlıklarını yakalamak için kullanılır, ancak bu sefer bu özellik alt kümesi, genlikteki döngüden döngüye değişiklikleri nicelleştirir.	6
	Temel frekans parametreleri	Vokal kord titreşim frekansı. Ortalama, ortanca, standart sapma, minimum ve maksimum değerler kullanılır.	5
	Uyum parametreleri	Ses tellerinin tam kapanmaması nedeniyle konuşma patolojilerinde artan gürültü bileşenleri oluşur. Özellik olarak, sinyal bilgisinin gürültüye oranını ölçen Harmonik Gürültü Oranı ve Gürültü Harmonik Oranı parametreleri kullanılır.	2
	Tekrarlama Periyodu Yoğunluk Entropisi (RPDE)	RPDE, vokal kordların stabil vokal kord salınımlarını sürdürme yeteneği hakkında bilgi verir ve F0'dan sapmaları nicelendirir.	1
	Eğilimsiz	DFA, türbülanslı gürültünün stokastik kendi	1


	Dalgalanma Analizi (DFA)	kendine benzerliğini ölçer.	
	Perde Periyodu Entropisi (PPE)	PPE, logaritmik ölçek kullanarak temel frekans F0'ın bozulmuş kontrolünü ölçer.	1
Mel Frekans Cepstral Coefficients MFCC	MFCC'ler	MFCC'ler, ses yolundaki PD etkilerini vokal kordlardan ayrı olarak yakalamak için kullanılır.	84
Zaman Frekansı	Yoğunluk Parametreleri	Yoğunluk, dB cinsinden konuşma sinyalinin gücü ile ilgilidir. Ortalama, minimum ve maksimum yoğunluk değerleri kullanılır.	3
	Formant Frekansları	Ses yolu tarafından yükseltile frekanslar, ilk dört formant özellik olarak kullanılır.	4
	Bant genişliği	Formant frekansları arasındaki frekans aralığı, ilk dört bant genişliği öznitelikler olarak kullanılmıştır.	4
Vokal Kıvrım	Glottis Bölümü (GQ)	GQ, glottisin açılma ve kapanma süreleri hakkında bilgi verir. Glottis hareketlerindeki periyodikliğin bir ölçüsüdür.	3
	Glottal - Gürültü Uyarma (GNE)	GNE, konuşma sinyalindeki eksik vokal kord kapanmasının neden olduğu türbülanslı gürültünün boyutunu ölçer.	6
	Vokal Kıvrım Uyarma Oranı (VFER)	VFER, doğrusal olmayan enerji ve entropi kavramlarını kullanarak patolojik ses teli titreşimi nedeniyle üretilen gürültü miktarını nicelleştirir.	7
	Ampirik Mod Ayırıştırma (EMD)	EMD, uyarlanabilir temel fonksiyonları kullanarak bir konuşma sinyalini temel sinyal bileşenlerine ayırıştırır ve bu bileşenlerden elde edilen enerji/entropi değerleri gürültüyü ölçmek için kullanılır.	6
Dalga	F0 ile ilgili dalgacık dönüşümü (WT) özellikleri	WT özellikleri, F0'daki sapmaları ölçer.	182

Sakar ve arkadaşları tarafından oluşturulan PDC veri setinde toplam 753 adet öznitelik ve 756 örneklem bulunmaktadır.

## 2.2. Yöntem

Bu çalışmada sınıflandırma yöntemi olarak Destek Vektör Makinelerinin (SVM)radial, polinomsal, radial tabanlı çekirdek fonksiyonları, K-En Yakın Komşu (KNN), Karar Ağaçları, Adaboostla Karar Ağaçları ve Rastgele Orman, algoritmaları kullanılmıştır. Bununla birlikte Konvolüsyonel Sinir Ağları (CNN), Çok Katmanlı Algılayıcılar (MLP), Derin Boltzmann Makineleri ayrı ayrı denenmiştir. Çalışma kapsamında uygulanan sınıflandırma yöntemlerine kısaca bakacak olursak;

**Karar Ağaçları Algoritması:** Bu algoritma genel olarak bir ağacın yapısını temel alarak dallar, düğümler ve yapraklar şeklinde oluşturulan bir algoritmadır. Bu algoritmada ana amaç düğümlerde sorulan sorulara verilen cevaplara göre en son yaprağa en kısa yoldan ulaşmaktır [14]. Örnek bir karar ağacı modeli Şekil 1'de gösterilmiştir.



Şekil 1. Örnek Karar Ağacı Algoritması [14].

Bu çalışmada SkLearn kütüphanesi içerisindeki “DecisionTreeClassifier” modeli kullanılmış ve max\_features parametresi “100” olarak belirlenmiştir.

**Adaboost Karar Ağaçları:** Bu algoritma temel olarak zayıf algoritmaların eğitilmesi prensibine dayanan ve zayıf algoritmaların bir araya getirilmesi sonucu güçlü bir model oluşturmayı hedefleyen bir algoritmadır. 1997 yılında Freund ve Shapire tarafından geliştirilen bu algoritmada, daha önceden oluşturulmuş algoritmaların birleştirilmesiyle öğrenme açısından en güçlü sonucun ortaya çıkarılması amaçlanmaktadır [15]. Bu çalışmada SkLearn kütüphanesi içerisindeki “AdaBoostClassifier” modeli kullanılmış ve bütün parametreler programın sunduğu varsayılan değerlerde tutulmuştur.

**Rastgele Orman Algoritması:** Rastgele orman algoritmasında tek bir ağaç oluşturmak yerine oluşturulan birçok ağacın eğitilmesiyle oluşan kararların birleştirilmesi ve bu sayede birden fazla sınıflandırıcıdan doğan oylar ile veriyi yeniden sınıflandıran bir öğrenme modelidir. Rastgele orman algoritmaları özellikle dengesiz veri setlerinde dengeleme yapılabilmesi nedeniyle büyük veri tabanlarında yaygın olarak tercih edilen bir algoritmadır [16]. Bu çalışmada SkLearn kütüphanesi içerisindeki “RandomForestClassifier” modeli kullanılmış ve n\_estimators parametresi “100” olarak belirlenmiştir.


**Destek Vektör Makineleri:** Bu yöntemde iki farklı sınıfa ait verileri en ideal şekilde birbirinden ayırmak amaçlanmaktadır. Ayırma işlemi doğrusal ya da doğrusal olmayan biçiminde yapılabilmektedir. Destek Vektör Makineleri algoritmasında eğitim veri seti üzerinden belirlenen yöntem test veri setine de uygulanarak veri setinin en az hatayla sınıflandırılması hedeflenmektedir [14]. Destek vektör makineleriyle doğrusal, polinomsal, radyal ve sigmoid gibi çekirdek fonksiyonlarına göre sınıflandırma yapılabilmekte olup [17], bu çalışmada doğrusal, polinomsal ve radyal tabanlı çekirdek fonksiyonlarının performansları ölçülmüştür. Bu çalışmada SkLearn kütüphanesi içerisindeki SVM modeli kullanılmıştır. Linear Kernel SVM için C değeri 1 olarak belirlenmiştir. Polinomsal Kernel SVM için C değeri 1, derece değeri 3 olarak belirlenmiştir. RBF Kernel SVM için C değeri 1 olarak belirlenmiştir.

**K-En Yakın Komşuluk(K-Eyk):** K-Eyk modeli ise daha çok düşük boyutlu öznitelik vektörlerinde etkili olan ve oldukça basit bir modeldir. Bu algoritmada bir k komşu belirlenmektedir. Belirlenen k komşu, tanıma yapılacak öznitelik vektörüne en yakın komşudur. K-Eyk algoritmasında k değeriyle birlikte uzaklığın hangi yöntemle hesaplandığı da önemli bir unsurdur. Bu algoritmada farklı uzaklık hesaplama yöntemleri kullanılarak da karşılaştırma yapılabilmektedir [18]. Bu çalışmada SkLearn kütüphanesi

içerisindeki “KNeighborsClassifier” modeli kullanılmış ve `n_neighbor` parametresi “5” olarak belirlenmiştir.

**Konvolüsyonel Sinir Ağları (CNN):** Lecun vd. tarafından 1998 yılında geliştirilen bu algoritma temel olarak görüntü analizleri için kullanılmaktadır. Algoritmanın amacı filtreleme yoluyla görüntünün özneliklerinin belirginleştirilerek sınıflandırma yapılmasıdır. Farklı katmanlara sahip olan sinir ağında nihai olarak sınıflandırıcı katmanda sonuç elde edilmektedir [19]. Bu projede kullanılan CNN algoritması verileri 1D (1 boyutlu) olarak işlemektedir. Girdi verileri orijinal olarak modele 2 boyutlu bir şekilde aktarılır birinci boyut örnek sayısını ve ikinci boyut özellik sayısını temsil eder. Yeniden şekillendirme ve modeli eğitime işlemi esnasında, iki boyuttan tek boyuta optimize edilir. Modelin ilk katmanı, 1D (1 boyutlu) girdi verileri gerektiren bir 1D (1 boyutlu) katman olduğu için bu işlem gereklidir. Bu algoritma uygulanırken transfer öğrenimi(Transfer Learning) kullanılmamıştır. Transfer öğrenimi, bir görev üzerinde eğitilmiş bir modelin ilgili ikinci bir görev için yeniden amaçlandırılarak kullanıldığı bir tekniktir. Bu genellikle önceden eğitilmiş modelin alt katmanlarını sabit özellik çıkarıcılar olarak kullanıldığında uygulanır. Bu çalışmada CNN modeli için Keras kütüphanesi içerisindeki “layers” metodları kullanılmıştır. Derleyici optimizasyonları için “adam” modeli kullanılmış olup, kayıp veri restore etme metodu için “SparseCategoricalCrossentropy” sınıfından yararlanılmıştır.

**Çok Katmanlı Algılayıcılar (MLP) :** Çok katmanlı algılayıcılar algoritması tespit ve tahmin amacıyla kullanılmakta olan ve parametrik olmayan bir algoritmadır [20]. Çok katmanlı algılayıcıların mimarisi bir girdi katmanı, bir veya daha fazla ara katman ve çıktı katmanından oluşmaktadır. Şekil 2’de örnek bir Çok Katmanlı Algılayıcı mimarisi gösterilmiştir. Bu algoritmada sonuçlar girdi katmanından gelen her bir çıktının ağırlıkları ile çarpımlarının toplanmasıyla elde edilmektedir [21]. Bu çalışmada SkLearn kütüphanesi içerisindeki “MLPClassifier” modeli kullanılmış ve activation türü “relu”, solver türü “adam”, `batch_size` türü “auto” ve momentum değeri “0.9” olarak belirlenmiştir.




Şekil 2. Örnek Çok Katmanlı Algılayıcı Algoritması [21].

**Derin Boltzmann Makineleri:** Boltzmann makineleri metodunda veri seti üzerindeki olasılıkların öğrenilmesi amaçlanmaktadır. Bu algoritmada gizli ve görünür olmak üzere iki katman bulunmakta olup katmanlardaki her bir düğüm bir nöronu temsil etmektedir. Düğümlerde yapılan hesaplamalar diğer katmanda yer alan başka bir düğüme iletilmektedir. Hesaplamalar görünür katmanda yapılır ve gizli katmana rastgele olarak iletilir [19]. Bu çalışmada TensorFlow Kütüphanesi içerisindeki BBRBM” modelinden yararlanılmıştır. Numpy formatındaki veri Tensor formatına çevirilmiş ve modelde kullanılmış ve `shuffle_batch` parametresi 128 olarak belirlenmiştir.



Bir Boltzmann Makinesi modeli örneği Şekil 3'te gösterilmiştir.



Şekil 3. Örnek BoltzmannMakineleri Algoritması [19].

Çalışma Python yazılımı kullanılarak yapılmış olup çalışmada scikit-learn ve TensorFlow kütüphaneleri kullanılmıştır.

### 3. BULGULAR

Çalışma sonucunda elde edilen bulgular Tablo 2'de gösterilmiştir.

Tablo 2. Uygulanan Algoritma ve Sonuçları

	Doğruluk	Kesinlik	Duyarlılık
Karar Ağaçları	0.822	0.873	0.881
K-En Yakın Komşu	0.836	0.856	0.927
Destek Vektör Makineleri (Doğrusal Kernel)	0.809	0.836	0.907
Destek Vektör Makineleri (Polinomsal Kernel)	0.816	0.811	0.963
Destek Vektör Makineleri (RBF Kernel)	0.822	0.803	0.991
Adaboost Karar Ağaçları	0.822	0.828	0.944
Rastgele Orman	0.855	0.840	0.981
	Doğruluk	Kesinlik	Duyarlılık
Karar Ağaçları	0.868	0.907	0.907
K-En Yakın Komşu	0.875	0.873	0.963
Destek Vektör Makineleri (Doğrusal Kernel)	0.829	0.858	0.907
Destek Vektör Makineleri (Polinomsal Kernel)	0.855	0.846	0.972
Destek Vektör Makineleri (RBF Kernel)	0.829	0.819	0.972
Adaboost Karar Ağaçları	0.888	0.902	0.944
Rastgele Orman	0.862	0.858	0.963

Konvolüsyonel Sinir Ağları (CNN)	0.895	0.925	0.941
Çok Katmanlı Algılayıcılar (MLP)	0.822	0.818	0.992
Derin Boltzmann Makinesi	0.803	0.806	0.983

Tabloda verilen değerlerden doğruluk değerleri doğru bir sınıflandırma yapılmış olan veri sayısı ile toplam veri sayısının oranıdır. Dolayısıyla Parkinson ve sağlıklı bireylerin hangi oranda doğru tahmin edilebildiğini göstermektedir. Çalışma sonucunda elde edilen doğruluk oranlarına bakıldığında bütün algoritmalarda %80 üzeri bir başarı elde edilmiş olduğu, en yüksek başarı oranının ise 0,895 oranla Konvolüsyonel Sinir Ağları (CNN) algoritmasıyla elde edilmiş olduğu görülmektedir. Kesinlik oranı ise Parkinson hasta örneklerinin oranlamasını göstermektedir. Yani Parkinson hastası olarak tahmin edilmiş olan örneklerden kaçının gerçek Parkinson hastası olduğunun bir oranıdır. Çalışma sonucunda tüm algoritmalarda yine %80 üzerinde bir başarı oranı olduğu, en yüksek oran ise 0,925 oranla Konvolüsyonel Sinir Ağları (CNN)'nda elde edilmiş olduğu görülmektedir. Duyarlık oranı ise sağlıklı bireyler için elde edilen bir orandır. Toplam veri kümesi içerisinde sağlıklı olarak tahmin edilen hastaların oranının göstermektedir. Çalışmada karar ağaçları haricinde tüm algoritmalarda %90 üzerinde bir oran elde edilmiş olup en yüksek oran 0,992 oranla Çok Katmanlı Algılayıcılar (MLP) algoritmasında elde edilmiştir.

Badem, bu çalışmada kullanılan aynı veri setiyle Karar Ağaçları, Naive Bayes, K-En Yakın Komşu, Rastgele Orman ve Destek Vektör Makineleri algoritmalarını kullanarak yapmış olduğu çalışmada en iyi performansı K- En Yakın Komşu algoritmasından elde etmiştir. Bizim çalışmamızda her ne kadar K- En Yakın Komşu algoritmasından da iyi sonuçlar elde edilmiş olsa da Rastgele Orman algoritmasının diğerlerine nazaran daha iyi bir performansa sahip olduğu görülmektedir.

Şakar ve arkadaşları ise yine aynı veri setiyle yapmış oldukları çalışmada farklı öznelikler üzerinde farklı sonuçlar elde etmişlerdir. Yazarlar, temel özneliklerde K- En Yakın Komşu algoritmasında, MFCC özneliğinde Destek Vektör Makinelerinde (RBF Kernel), dalga özneliklerinde Çok Katmanlı Algılayıcı algoritmasında, bant genişliği özneliğinde K- En Yakın Komşu algoritmasında, yoğunluk özneliğinde K- En Yakın Komşu ve Rastgele Orman Algoritmalarında ve son olarak Vokal Kıvrım özneliğinde Rastgele Orman algoritmasında en yüksek doğruluk oranına ulaşmışlardır.

## 5. SONUÇ (CONCLUSION)

Parkinson hastalığının belirtilerinden olan konuşma bozukluğu ve yazı yazmada zorlanma gibi semptomlar günümüzde makine öğrenmesi teknikleri kullanılarak değerlendirilebilmektedir. Bu çalışmada da konuşma bozukluklarının değerlendirilmesine yönelik kullanılan makine öğrenmesi algoritmalarının karşılaştırılmasının yapılması amaçlanmıştır. Ayrıca çalışmada daha önce yapılmış çalışmalardan daha fazla algoritma kullanılarak literatüre katkı sağlanması hedeflenmiş, bu kapsamda makine öğrenmesi algoritmalarından Karar Ağaçları, K-En Yakın Komşu, Destek Vektör Makineleri (Doğrusal Kernel), Destek Vektör Makineleri (Polinomsal Kernel), Destek Vektör Makineleri (RBF Kernel), Adaboost Karar Ağaçları, Rastgele Orman, Konvolüsyonel Sinir Ağları, Çok Katmanlı Algılayıcılar ve Derin Boltzmann Makinesi kullanılmıştır. Çalışma sonucunda en iyi sonuçların Konvolüsyonel Sinir Ağları algoritmasından elde edildiği görülmüştür.

Parkinson gibi ses ve görüntü gibi özellikli belirtileri olan hastalıkların teşhisinde makine öğrenmesi tekniklerinin oldukça önemli olduğu ve yaygın olarak kullanıldığı bilinmektedir. Ancak yapılacak çalışmalar için esas teşkil edecek veri setlerinin ve örneklem sayılarının artırılmasının çalışma sayılarının artmasında fayda sağlayacağı değerlendirilmektedir. Bununla birlikte hem ses hem de el yazısı veri setlerinin birlikte ele alınarak incelemeler yapılmasının karşılaştırmalı analizlere imkân tanınması açısından fayda sağlayacağı değerlendirilmektedir.

## TEŞEKKÜR (ACKNOWLEDGMENTS)

## ÇIKAR ÇATIŞMASI (CONFLICT OF INTEREST)

Makale yazarları aralarında herhangi bir çıkar çatışması olmadığını beyan ederler.

## KAYNAKÇA (REFERENCES)

- [1] O. B. Tysnes ve A. Storstein, Epidemiology of Parkinson's Disease, cilt 124, no. 8, pp. 901-905, 2017.
- [2] F. Çevik ve Z. H. Kilimci, Derin Öğrenme Yöntemleri ve Kelime Yerleştirme Modelleri Kullanılarak Parkinson Hastalığının Duygu Analiziyle Değerlendirilmesi, cilt 27, no. 2, pp. 151-161, 2020.
- [3] J. Jankovic, Parkinson's disease: clinical features and diagnosis, *Journal of neurology, neurosurgery & psychiatry*, cilt 79, no. 4, pp. 368-376, 2008.
- [4] R. Çakmur, Parkinson hastalığı ve medikal tedavisi, *Klinik Gelişim Dergisi*, pp. 53-58, 2011.
- [5] S. Fahn, Description of Parkinson's Disease as a Clinical Syndrome, *Annals of the New York Academy of Sciences*, cilt 991, no. 1, pp. 1-14, 2003.
- [6] Ş. Torun, Parkinson'lularda konuşma fonksiyonunun subjektif ve objektif (elektrolaringografik) yöntemlerle incelenmesi,, *Uzmanlık Tezi, Anadolu Üniversitesi Tıp Fakültesi, Nöroloji Anabilim Dalı, Eskişehir*, 1991.
- [7] S. Özekmekçi, H. Apaydın, S. Oğuz ve İ. Zileli, Parkinson Hastalığı Hasta ve Yakınları İçin El Kitabı, İstanbul: Bayçınar Tıbbi Yayıncılık ve Reklam Hiz. Tic. Ltd. Şti, 2013.
- [8] M. A. Little, P. E. McSharry, E. J. Hunter, J. Spielman ve L. O. Ramig, Suitability of Dysphonia Measurements for Telemonitoring of Parkinson's Disease, *IEEE Transactions on Biomedical Engineering*, cilt 56, no. 4, pp. 1015-1022, 2009.
- [9] Ö. Bizal, Makine Öğrenmesi Teknikleriyle Parkinson Hastalığının Belirlenmesi, 2014.
- [10] B. E. Şakar, M. E. Isenkul, C. O. Şakar, A. Sertbas, F. Gürgen, S. Delil ve O. Kurşun, Collection and analysis of a Parkinson speech dataset with multiple types of sound recordings, *IEEE Journal of Biomedical and Health Informatics*, cilt 17, no. 4, pp. 828-834, 2013.
- [11] H. Badem, Parkinson Hastalığının Ses Sinyalleri Üzerinden Makine Öğrenmesi Teknikleri ile Tanımlanması, *Ömer Halisdemir Üniversitesi Mühendislik Bilimleri Dergisi*, cilt 8, no. 2, pp. 630-637, 2019.
- [12] A. Tsanas, M. A. Little, P. E. McSharry ve L. O. Raming, Accurate telemonitoring of Parkinson's disease progression by noninvasive speech tests, *IEEE transactions on biomedical engineering*, cilt 57, no. 4, pp. 884-893, 2010.
- [13] C. Sakar, G. Serbes, H. Tunç, A. Gündüz, H. Nizam, B. Sakar, M. Tütüncü, T. Aydın, M. İsenkul ve H. Apaydın, "A Comparative Analysis Of Speech Signal Processing Algorithms For Parkinson's Disease Classification And The Use Of The Tunable Q-Factor Wavelet Transform, *Applied Soft Computing*, cilt 74, pp. 255-263, 2019.
- [14] S. Esmer, M. K. Uçar, İ. Çil ve M. R. Bozkurt, Parkinson Hastalığı Teşhisi İçin Makine Öğrenmesi Tabanlı Yeni Bir Yöntem, *Düzce Üniversitesi Bilim ve Teknoloji Dergisi*, cilt 8, no. 3, pp. 1877-

1893, 2020.

- [15] Ü. Varanyurt, A. Deveci, M. F. Esen ve O. Veranyurt, Makine Öğrenmesi Teknikleriyle Hastalık Sınıflandırması: Random Forest, K-Nearest Neighbour ve Adaboost Algoritmaları Uygulaması, *Uluslararası Sağlık Yönetimi ve Stratejileri Araştırma Dergisi*, cilt 6, no. 2, pp. 275-286, 2020.
- [16] H. Nizam, Sosyal Medyada Makine Öğrenmesi İle Duygu Analizinde Dengeli ve Dengesiz Veri Setlerinin Performanslarının Karşılaştırılması, *XIX Türkiye'de İnternet Konferansı*, cilt 1, no. 6, 2014.
- [17] S. Ayhan ve Ş. Erdoğan, Destek vektör makineleriyle sınıflandırma problemlerinin çözümü için çekirdek fonksiyonu seçimi, *Eskişehir Osmangazi Üniversitesi İktisadi ve İdari Bilimler Dergisi*, cilt 9, no. 1, pp. 175-201, 2014.
- [18] B. Başer, M. Yangın ve E. S. Sarıdaş, Makine Öğrenmesi Teknikleriyle Diyabet Hastalığının Sınıflandırılması, *Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, cilt 25, no. 1, pp. 112-120, 2021.
- [19] F. Doğan ve İ. Türkoğlu, Derin Öğrenme Modelleri ve Uygulama Alanlarına İlişkin Bir Derleme, *Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi*, cilt 10, no. 2, pp. 409-445, 2019.
- [20] U. Orhan, M. Hekim ve M. Özer, EEG İşaretlerinin Çok-Katmanlı Algılayıcı Yapay Sinir Ağı Modeli ile Sınıflandırılmasında Ayrıklaştırma Yaklaşımı, *In Biomedical Engineering Meeting (BIYOMUT)*, 2010.
- [21] K. Tekeli ve R. Aşlıyan, Çok Katmanlı Algılayıcı, K-NN ve C4. 5 Metotlarıyla İstenmeyen E-postaların Tespiti, *Adnan Menderes Üniversitesi*, 2016.