

PARKİNSON HASTALIĞININ SES SİNYALLERİ ÜZERİNDEN MAKİNE ÖĞRENMESİ TEKNİKLERİ İLE TANIMLANMASI

Hasan BADEM¹ (ORCID: 0000-0002-4262-8774) *

¹Kahramanmaraş Sütçü İmam Üniversitesi, Mühendislik ve Mimarlık Fakültesi, Bilgisayar Mühendisliği Bölümü

Geliş / Received: 08.02.2019

Kabul / Accepted: 13.05.2019

ÖZ

Parkinson hastalığının en önemli belirtilerinden birisi konuşma bozukluklarıdır. Dolayısıyla, ses sinyallerinden problemi temsil edebilecek özneliklerin çıkarılması ile hastalık sınıflandırılabilir. Makine öğrenmesi teknikleri ile sınıflandırma problemlerinde oldukça başarılı sonuçlar üretmektedir. Bu çalışmada, Parkinson hastalığının ses sinyalleri üzerinden sınıflandırılmasında, KYK, ROS, DVM, NB ve KA makine öğrenmesi tekniklerinin başarımının araştırılması amaçlanmıştır. Bu amaç için literatüre yeni sunulan yüksek boyutlu öznelik ve örnekleme sahip PDC veri seti kullanılmıştır. Gerçekleştirilen deneysel çalışmalarda, oldukça yüksek doğruluk değerleri elde edilmiştir. Ayrıca, kullanılan yöntemler istatistiksel olarak karşılaştırılmıştır. Bu sonuçlara ek olarak, TBA ve DDA boyut indirme tekniklerinin başarıma etkileri analiz edilmiştir.

Anahtar kelimeler: Parkinson hastalığı, makine öğrenmesi, sınıflandırma, karar destek sistemi, boyut indirgeme

IDENTIFICATION OF PARKINSON DISEASE THROUGH THE SPEECH SIGNALS BY USING THE MACHINE LEARNING TECHNIQUES

ABSTRACT

One of the most important symptoms of Parkinson's disease is speech disturbances. Thus, the disease can be classified by extracting the features from the speech signals that may remark the problem. Machine learning techniques produce very successful results in classification problems. In this study, it is aimed to investigate the performance of machine learning techniques including KYK, ROS, DVM, NB and KA in the classification of Parkinson's disease through speech signals. For this purpose, PDC data set with high dimensional features and instances has been used. In the performed experimental studies, high accuracy values have been obtained. Moreover, the competitor methods have been also compared statistically. In addition to these results, the effects of TBA and DDA size reduction techniques have been analyzed.

Keywords: Parkinson's disease, machine learning, classification, decision support system, dimensional reduction

1. GİRİŞ

Son zamanlarda, makine öğrenmesi yöntemleri ham verilerden anlamlı bilgilerin tespit edilmesinde başarılı sonuçlar vermektedir [1]. Bu veri, makine öğrenmesi temelli hastalık tanımlama sistemlerinin de başarılı sonuçlar vereceğini göstermektedir. Nitekim, günümüz tıbbi araştırmalarında makine öğrenmesi temelli

*Corresponding author / Sorumlu yazar. Tel.: +90 344 300 17 04; e-mail / e-posta: hbadem@ksu.edu.tr

H. BADEM

sınıflandırma yöntemlerini hem karar destek sistemlerinde hem de hastalık teşhisinde belirleyici bir rol oynadığı belirtilmektedir [2] [3].

Parkinson daha çok 60 yaş üstü insanlar arasında, Alzheimer hastalığından sonra en yaygın görülen sinirsel hastalıktır [4]. Parkinson hastalığının günümüzdeki imkanlarla tamamen ortadan kaldırılması mümkün değildir. Ancak, hastalığın erken teşhis edilmesi ve iyi bir biçimde izlenmesiyle hastalığın etkileri en aza indirilebilmektedir.

Parkinson hastalığının; hareket yavaşlığı, kas hareketlerini kontrol edememe, ellerde ve ayaklarda titreme ve konuşma bozuklukları gibi karakteristik belirtileri bulunmaktadır [5] [6]. Fakat, bu belirtiler açıkça ortaya çıkmadan erken tanı döneminde teşhis edilebilmesi, hastalığın etkilerinin azaltılması adına oldukça önem taşımaktadır. Hastalığın erkenden teşhis edilebilmesi ve hastalığın gidişatının izlenmesi için konuşma bozukluklarından faydalanılmaktadır. Bu amaç doğrultusunda, hastaların ses kayıtlarının analiz edilmesi akla gelen ilk yaklaşım olacaktır [7] [8]. Böylece hasta hastaneye gelmeden uzaktan izlenebilecektir.

Konuşma bozukluğundan Parkinson hastalığının teşhis edilebilmesi bir takım zorlu süreçleri de beraberinde getirmektedir. Öncelikle ses sinyallerinden elde edilen özniteliklerden hangilerinin problemin doğasını temsil ettiğinin anlaşılması süreci, ileri öznitelik çıkarma yöntemlerinin kullanılmasını gerektirmektedir. Ayrıca, problemi temsil eden öznitelikler çıkartıldıktan sonra, veriyi sınıflandırma sürecinde kullanılacak yöntemlerin doğru seçilmesi de oldukça önem arz etmektedir [4].

Ses sinyalleriyle Parkinson hastalığının teşhis edilmesi üzerine literatürde yaygın olarak kullanılan “Oxford Parkinson's Disease Detection (OPD)” [9] ve “Parkinson Speech Dataset with Multiple Types of Sound Recordings (PSD)” [10] isimli iki veri seti bulunmaktadır. OPD veri seti, 23 Parkinson hastası ve 8 sağlıklı denekten alınan sinyallerden 23 öznitelik çıkartılarak oluşturulmuştur [9]. PSD veri seti ise, 20 hastalığa sahip ve 20 sağlıklı bireyden 26 adet öznitelik çıkartılarak paylaşılmıştır [10]. Her iki veri setinin özellikleri incelendiğinde, denek sayısı ve öznitelik sayılarının oldukça sınırlı kaldığı görülmektedir. Bu durum hastalığın teşhis edilebilmesinde arzu edilen başarıların gerçekleşmesinde yetersiz kalabileceği ön görülebilir. Fakat, 2018 yılında 252 denekten 756 adet örneklem ve 753 adet öznitelige sahip dolayısıyla probleme ait geniş veri içeren “Parkinson's Disease Classification (PDC)” [4] veri seti oluşturulmuş ve UCI makine öğrenmesi [11] deposunda paylaşılmıştır. Bu veri seti üzerinden Parkinson hastalığının teşhisinde ve izlenmesinde makine öğrenmesi tekniklerinin hangisinin daha başarılı olduğunun ortaya koyulması büyük bir önem arz etmektedir.

Bu çalışmada sınıflandırma problemlerinin çözümünde son derece hızlı çalışan ve yüksek doğruluk oranlarına sahip olduğu bilenen Destek Vektör Makinesi (Support Vector Machine, DVM), K en Yakın Komşu (K-nearest neighbor-KYK) algoritması, Karar Ağaçları (Decision Tree, KA), Naive Bayes (NB) ve Rastgele Ormanlar sınıflandırıcısı (Random Forest Classifier-ROS) gibi sınıflandırıcıların PDC veri setindeki performansının değerlendirilmesi amaçlanmaktadır. Ayrıca, Temel Bileşen Analizi (Principal component analysis-TBA) ve Doğrusal Diskriminant Analizi (Linear Discriminant Analysis-DDA) boyut indirgeme yöntemlerinin sınıflandırma başarımına etkisinin ortaya koyulması hedeflenmektedir. Bu amacımıza ek olarak da daha hızlı ve yüksek doğruluk oranıyla çalışan en ideal sınıflandırıcıyı tespit ederek Parkinson hastalığının izlenmesi için ileride olası Teletıp uygulamalarına hazırlık yapmaktır. Yapılan simülasyonlarla elde edilen sonuçlara göre basit bir çalışma mantığına sahip olan ve son derece hızlı olan KYK sınıflandırma algoritmasının diğer algoritmalarından daha başarılı olduğu tespit edilmiştir. KYK algoritması mobil uygulamalara bile kolayca entegre edilecek bir sınıflandırıcıdır. Bu açıdan bu tarz bir problemin çözümünde kullanılması ciddi önem arz etmektedir.

Çalışmanın ikinci bölümünde, kullanılan makine öğrenmesi yöntemleri ve karşılaştırma ölçütleri sunulmaktadır. Daha sonra, deneysel sonuçlar verilmektedir. Çalışma sonuç bölümü ile sonlandırılmaktadır.

2. YÖNTEM

Günümüzde birçok disiplinde olduğu gibi tıbbi uygulamalarda da sınıflandırma tekniklerinden faydalanılmaktadır. Her geçen gün insandan alınan tıbbi verilerin artması, bu alanda etkili sınıflandırıcılara ihtiyacı da arttırmaktadır. Sınıflandırma en genel anlamda bir veriyi belirli özelliklerine göre gruplandırma olarak tanımlanabilir. Tıbbi açıdan sınıflandırma işlemi örneğin hastandan alınan görüntü, sinyal v.b. çeşitli verilerden oluşturulan veri seti ile yapılabilmektedir. Veri seti, giriş verisi ve bu girişi verisiyle ilgili olan sınıf etiketlerinden oluşmaktadır. Bu çalışmada deneklerden elde edilen konuşma sinyallerinden çeşitli öznitelikler çıkarılarak giriş verisi elde edilmiştir. Bu giriş verilerine karşılık olarak hastanın Parkinson olup olmadığının belirlendiği bir çıkış verisi (etiket) oluşturulmuştur. Bu girişle çıkış arasındaki ilişki matematiksel bir modelle öğretilmektedir. Bu model girişle çıkış arasındaki ilişkiyi bir kere öğrendiğinde artık modelin daha önce karşılaşmadığı bir durumda bile çalışır hale gelmektedir. Modelin performansı veri setinin doğasına doğrudan bağlıdır. Literatürde değişik amaçlar için birçok sınıflandırıcı ya da model önerilmiştir. Ancak bir veri setinde iyi çalışan bir sınıflandırıcı bir başka veri setinden iyi performans sergileyememektedir. Çünkü bir veri setinin

PARKİNSON HASTALIĞININ SES SİNYALLERİ ÜZERİNDEN MAKİNE ÖĞRENMESİ TEKNİKLERİ İLE TANIMLANMASI

doğasına uygun sınıflandırıcı seçimi için teorik bir yaklaşım söz konusu değildir. Hangi veri setinin hangi sınıflandırıcıyla daha iyi sınıflandırıldığına karar verilmesi, deneme yanılma yöntemiyle gerçekleştirilmektedir. Bu amaçla Parkinson hastalığının ses sinyallerinden sınıflandırması işlemi için 6 farklı sınıflandırıcı önerilmiştir. Bu sınıflandırıcılar karşılaştırılarak en iyi sınıflandırıcı belirlenmiştir. Ayrıca, sınıflandırma problemlerinde, ön işlem olarak veri boyutu indirgenebilmektedir. Bu işlem için 2 farklı yöntemin etkisi ile değerlendirilmiştir.

Bu problemin çözümü için verilerin bir kısmı eğitim verisi olarak bir kısmı ise test verisi olmak üzere gruplandırılmaktadır. Eğitim verisiyle modelin parametreleri optimize edilir. Sonrasında ise eldeki test verisiyle modelin performansı ölçülmektedir. Veri seti genellikle %70'i eğitim % 30'u test verisi olmak üzere iki ayrılmaktadır. Ancak bu durumda veri setinde meydana gelecek dengesiz dağılım, modelin başarısını olduğundan yüksek ya da düşük gösterebilmektedir. Literatürde, bu problemin üstesinden gelmek için modelin performansı, n -kat çapraz doğrulama tekniğiyle ölçülmektedir. Bu yöntemde, veri n eşit parçaya bölünür. Bu parçalardan $n-1$ tanesi modelin eğitiminde geriye kalan tek parça ise test işlemi için kullanılmaktadır. Bu işlem n parça için tekrar edilir. Son olarak her bir testten elde edilen sonuçların ortalaması alınmaktadır.

Problemin çözümünde, kullanılan makine öğrenmesi sınıflandırıcıları, boyut indirgeme yöntemleri ve karşılaştırma ölçütleri sırası ile aşağıdaki alt bölümlerde sunulmaktadır.

2.1. Makine öğrenmesi teknikleri

Bu çalışmada Parkinson hastalığının sınıflandırılması için literatürde sıklıkla kullanılan DVM, ROS, KA, NA ve ROS makine öğrenmesi teknikleri kullanılmıştır. Aşağıda bu yöntemler kısaca açıklanmaktadır.

DVM, farklı sınıflara ait verilerin sınırlarını belirleyen hiperdüzlem kavramına dayanmaktadır. Bir hiperdüzlem farklı sınıf özelliklerine sahip küme elemanlarını birbirinden ayırmaktadır. DVM algoritmasında, verinin doğasına göre kernel fonksiyonlarınca hiperdüzlem de yeniden düzenlenmektedir. Bu sayede DVM sınıfların birbirinden ayrıştırılmasında etkin bir biçimde kullanılmaktadır [12].

KYK algoritması, herhangi bir sınıfa ait elemanlar ile bir veri arasındaki mesafelerin ölçülmesine göre bir sınıfa atama işlemi gerçekleştirilmektedir [13]. KYK yapısı gereği basit ve hızlı bir yöntemdir. Bu nedenle, pek çok sınıflandırma probleminde yaygın olarak kullanılan bir makine öğrenmesi yöntemidir.

KA eğitim verisine göre karar ve yaprak düğümlerinden oluşan bir yapı modellemektedir. Bu model, veri setindeki öznitelikler ile sınıf etiketleri arasındaki ilişkinin öğrenilmesi için oluşturulmaktadır. Dolayısıyla, oluşturulan ağaç yapısına bir test verisi uygulandığında hızlı ve kolay bir şekilde sınıf ataması yapılabilmektedir [14].

NB sınıflandırıcısı, olasılıksal olarak verinin bir sınıfa ait olduğuna karar veren bir makine öğrenmesi yöntemidir. NB'de bir veri özniteliğine göre olasılıksal olarak bir sınıfa atama yapılmaktadır [15].

ROS ise, her ağaç bağımsız olarak örneklenen ve ormandaki tüm ağaçlar için aynı dağılıma sahip rastgele bir vektörün değerlerine bağlı olacak şekilde ağaç tahmin edicilerin bir birleşimidir. Ormanlar için genelleme hatası, ormandaki ağaçların sayısı arttıkça bir sınıra yaklaşmaktadır. Bir ağaç sınıflandırıcı ormanın genelleme hatası, ormandaki her bir ağacın gücüne ve aralarındaki korelasyona bağlıdır [16]. Literatürde, artırma ağaç sınıflandırıcı (boosting) [16] ve toparlama (bagging) ağaç sınıflandırıcısı [17] temelli iki versiyonu yaygın olarak kullanılmaktadır. Bu nedenle deneysel sonuçlarda sunulan ROS1 ve ROS2 sırasıyla bahsi geçen yöntemlere karşılık gelmektedir.

2.2. Boyut indirgeme yöntemleri

Temel bileşen analizi (Principal component analysis-TBA) ve Doğrusal Diskriminant Analizi (Linear Discriminant Analysis-DDA) yöntemleri, veri boyutunu indirgemede sıklıkla kullanılan yöntemlerdir [18].

TBA, temel bileşenler olarak adlandırılan muhtemel ilişkili değişkenleri, ilişkisiz doğrusal değişkenleri bir dizi değerine dönüştürmek için ortogonal dönüşüm kullanan istatistiksel bir prosedürdür. Ana bileşenlerin sayısı, orijinal değişkenlerin sayısına eşit veya daha azdır. Başka bir ifadeyle, TBA verilerin yaklaşık olarak bulunduğu alt alanı belirlemeye çalışır [19].

DDA, sınıf içi frekansların eşit olmadığı ve performanslarının rastgele oluşturulmuş test verileri üzerinde incelendiği durumu ele alır. Bu yöntem, herhangi bir belirli veri setinde sınıflar arası varyansın sınıf içi varyansa oranını maksimuma çıkarır, böylece maksimum ayrılabilirliği sağlamaktadır [20].

2.3. Karşılaştırma ölçütleri

Doğruluk oranı (accuracy- acc), duyarlılık oranı (sensitivity- sn), özgüllük oranı (specificity- sp), hassasiyet oranı (precision- p), F skoru (f) ve AUC (Area Under Curve-ROC) bir sınıflandırma sistemi ya da modelinin tahmin etme performansını değerlendirmede kullanılan en önemli ölçütlerdir. sn ; pozitif değerlere sahip örneğin

H. BADEM

pozitif olarak tespit edilebilme oranını ifade ederken, sp ; negatif değere sahip bir örneğin negatif olarak tespit edilebilme oranını ifade etmektedir. acc değeri ise toplamda pozitif ve negatif verilerin tespit edilebilme oranı olarak tanımlanmaktadır [21] [22]. p ise, pozitif olarak tahmin edilen verilerde ne kadarının gerçekte pozitif olduğuna göstermektedir. f skoru ise, sn ve p 'nin harmonik ortalamasına karşılık gelmektedir. AUC , veri sınıflandırma yöntemlerinin sınıf etiketlerini doğru olarak tahmin edebilme kabiliyetini ölçmede kullanılan en önemli araçlardan biridir. AUC değeri, ROC eğrisinin altında kalan alana karşılık gelmektedir. Bu ölçütler, aşağıdaki tanımlanan değerler üzerinden hesaplanmaktadır [22].

TP : pozitif etiketli veriyi, pozitif olarak tahmin etme sayısı
 FP : pozitif etiketli veriyi, negatif olarak tahmin etme sayısı
 TN : negatif etiketli veriyi, negatif olarak tahmin etme sayısı
 FN : negatif etiketli veriyi, pozitif olarak tahmin etme sayısı

Bir sınıflandırma modelinin ya da sisteminin acc, sn, sp, p, f ve AUC değerleri aşağıdaki ifadeler üzerinden sırasıyla Eşitlik 1, 2, 3, 4, 5 ve 6 ile hesaplanmaktadır [22].

$$acc = \frac{TP + TN}{TP + FP + TN + FN} \quad (1)$$

$$sn = \frac{TP}{TP + FN} \quad (2)$$

$$sp = \frac{TN}{TN + FP} \quad (3)$$

$$p = \frac{TP}{TP + FP} \quad (4)$$

$$f = 2 * \frac{p * sn}{p + sn} \quad (5)$$

$$AUC = \frac{S_p - n_p (n_p + 1) / 2}{n_p n_n} \quad (6)$$

Eşitlik 6'da S_p ; pozitif olarak tahmin edilen tüm örneklerin toplamı, n_p ; pozitif örneklerin sayısını n_n ; negatif örneklerin sayısını ifade etmektedir [22].

3. DENEYSEL SONUÇLAR ve TARTIŞMA

Bu çalışmada, Parkinson hastalığını ses sinyalleri üzerinden teşhis edilebilmesi için literatürde yaygın olarak kullanılan makine öğrenmesi teknikleri karşılaştırmalı olarak analiz edilmiştir. Ayrıca, en yüksek doğruluk değerini sunan yöntem üzerinden TBA ve DDA boyut indirgeme yöntemlerinin başarıma etkisi değerlendirilmiştir. Deneysel sonuçları elde edebilmek için UCI makine öğrenmesi deposunda 2018 yılında paylaşılmış olan "Parkinson Hastalığı Sınıflandırma" veri seti [11] kullanılmıştır. Makine öğrenmesi yöntemlerini karşılaştırabilmek için 10 kat çapraz doğrulama tekniği ile 30 farklı koşma gerçekleştirilmiştir. Elde edilen sonuçlar, 2.4 GHz Intel i7-4700 işlemcili ve 16 GB RAM belleğe sahip sistem üzerinden elde edilmiştir.

Bu bölümde, öncelikle kullanılan veri setinden bahsedilmekte, daha sonra karşılaştırmalı olarak elde edilen simülasyon sonuçları sunulmaktadır.

3.1. Parkinson Hastalığı Sınıflandırma veri seti

Parkinson Hastalığı Sınıflandırma (Parkinson's Disease Classification -PDC) veri setinin geliştirilme amacı, bireylerin konuşma bozuklukları üzerinden hastalığın tespit edilebilmesidir [4]. Bu amaç için bireylerin ses sinyalleri üzerinden çeşitli öznelik çıkarma teknikleri ile kullanılarak veri seti oluşturulmuştur. PDC veri seti 2018 yılında UCI Makine öğrenmesi [11] deposundan paylaşılmıştır. Literatürde ses sinyalleri üzerinden Parkinson hastalığının teşhis edilebilmesi için birkaç veri seti daha bulunmaktadır. PDC diğer veri setleri ile karşılaştırıldığında, denek sayısının görece fazla olması ve detaylı sinyal işleme teknikleri ile problemi daha iyi temsil edebilecek özneliklerine sahip olması avantaj sunmaktadır. PDC veri seti İstanbul Üniversitesi, Cerrahpaşa Tıp fakültesi, Nöroloji kliniğine başvuran hastalar üzerinden oluşturulmuştur [4].

PARKİNSON HASTALIĞININ SES SİNYALLERİ ÜZERİNDEN MAKİNE ÖĞRENMESİ TEKNİKLERİ İLE TANIMLANMASI

PDC veri seti oluşturulurken 107’si erkek 81’i kadın olmak üzere toplamda 188 adet hasta denek kullanılmıştır. Bu hasta deneklere ek olarak 64 adet sağlıklı bireylerden veri de elde edilmiştir. Dolayısı ile toplamda 252 adet deneye ait veri PDC veri setinde kullanılmıştır. Deneklerin veri toplama sürecini 3 defa tekrar etmeleri sağlanmıştır. Elde edilen kayıtlardan, Zaman-Frekans Öznitelikleri (Time-Frequency Features), Mel Frekans Kepstrum Katsayıları (Mel Frequency Cepstral Coefficients), Dalgacık Dönüşümü (Wavelet Transform) temelli öznitelikler, Ses Kıvrımları (Vocal Fold) öznitelikleri ve Ayarlanabilir Q-faktor Dalgacık Dönüşümü (Tunable Q-factor wavelet transform) öz nitelikleri sinyal işleme algoritmaları ile elde edilmiştir. PDC veri seti, kullanılan bu öz nitelik çıkarma yöntemleri ile toplamda 753 adet öznitelik ve 756 örneklemden oluşturulmuştur [4].

3.2. Simülasyon Sonuçları

Parkinson hastalığının teşhis edilebilmesi için, PDC veri seti üzerinden KYK, ROS1, ROS2, DVM, NB ve KA sınıflandırıcıları 10 kat çapraz doğrulama tekniği ile 30 farklı koşma gerçekleştirilmiştir. Gerçekleştirilen bu simülasyonlardan, 30 farklı koşmanın *acc, sn, sp, p, f* ve *AUC* değerleri kaydedilmiştir. Bu değerlerin ortalama ve standart sapmaları Tablo 1 ve Tablo 2’de verilmiştir.

Tablo 1 incelendiğinde; 91,83 ile en yüksek ortalama doğruluk değerine KYK algoritması sahipken, daha sonra ROS1 sınıflandırıcısı ile ortalama 89,12 doğruluk değeri elde edilmiştir. ROS2, DVM, NB ve KA yöntemleri sırasıyla 87,64; 86,99; 79,66 ve 79,21 ortalama doğruluk değerleri elde edilmiştir. Doğruluk değerleri incelendiğinde, KYK ve ROS1 algoritmaları arasında KYK algoritmasının lehine nispeten bir fark varken diğer yöntemler ile KYK arasında KYK algoritmasının lehine önemli bir fark olduğu görülmektedir. Aynı zamanda, KYK algoritması, KA ve NB yöntemlerine göre oldukça üstün bir doğruluk değeri elde ettiği Tablo 1’de görülmektedir. *sn* açısından Tablo 1 incelendiğinde, Parkinson hastalığına sahip bireyleri doğru olarak tespit edebilme başarımı, doğruluk değerine benzer şekilde KYK algoritmasının lehine çıktığı görülmektedir. Fakat, Parkinson hastalığı bulunmayan bireylerin doğru olarak tespit edilebilmesini ROS1 sınıflandırıcısının KYK, ROS2 ve DVM’e göre nispeten KA ve NB yöntemlerine göre görece daha başarılı olduğu *sp* değerlerinden anlaşılmaktadır.

Tablo 1. KYK, ROS1, ROS2, DVM, NB ve KA sınıflandırıcılarının 30 koşmadaki *acc, sn, sp* ölçütlerinin ortalama ve standart sapma değerleri

	<i>acc</i>		<i>sn</i>		<i>sp</i>	
	Ortalama	Standart Sapma	Ortalama	Standart Sapma	Ortalama	Standart Sapma
KYK	91,83	0,55	90,59	4,29	92,12	1,27
ROS1	89,12	0,72	66,52	2,04	96,84	0,66
ROS2	87,64	0,57	61,26	1,79	96,63	0,50
DVM	86,99	0,64	63,96	1,89	94,95	0,57
NB	79,66	0,45	66,66	1,03	84,16	0,49
KA	79,21	1,58	60,63	3,59	85,76	1,33

Tablo 2. KYK, ROS1, ROS2, DVM, NB ve KA sınıflandırıcılarının 30 koşmadaki *p, f, AUC* ölçütlerinin ortalama ve standart sapma değerleri

	<i>p</i>		<i>f</i>		<i>AUC</i>	
	Ortalama	Standart Sapma	Ortalama	Standart Sapma	Ortalama	Standart Sapma
KYK	80,58	2,75	84,24	1,54	0,9121	0,0200
ROS1	87,80	2,41	75,07	1,76	0,8147	0,0175
ROS2	86,17	1,84	70,97	1,47	0,7879	0,0161
DVM	81,13	2,12	70,78	1,73	0,7929	0,0148
NB	58,98	0,97	61,95	0,83	0,7515	0,0115
KA	59,31	2,92	59,12	3,16	0,7300	0,0270

Tablo 3. KYK, ROS1, ROS2, DVM, NB ve KA sınıflandırıcılarının karşılaştırmalı istatistiksel Mann Whitney U Testi sonuçları

Karşılaştırma	Ortalama Fark	Z	p	Anlamlılık
				($p \leq 0,05$)
KYK-ROS1	2,7078	-6,653	0,000	KYK
KYK-ROS2	4,1906	-6,653	0,000	KYK
KYK-DVM	4,8406	-6,653	0,000	KYK
KYK-NB	12,1703	-6,654	0,000	KYK
KYK-KA	12,6187	-6,653	0,000	KYK
ROS1-ROS2	1,4828	-5,892	0,000	ROS1
ROS1-DVM	2,1329	-6,461	0,000	ROS1
ROS1-NB	9,4625	-6,654	0,000	ROS1
ROS1-KA	9,9109	-6,653	0,000	ROS1
ROS2-DVM	0,6501	-3,800	0,000	ROS2
ROS2-NB	7,9797	-6,654	0,000	ROS2
ROS2-KA	8,4281	-6,653	0,000	ROS2
DVM-NB	7,3296	-6,654	0,000	DVM
DVM-KA	7,7780	-6,653	0,000	DVM
NB-KA	0,4484	-1,005	0,315	-

Parkinson hastalığına sahip olduğu tahmin edilen bireylerin gerçekte ne kadarının hastalığa sahip olduğunu gösteren p ölçütüdür. Tablo 2 bu açıdan incelendiğinde; ROS1 sınıflandırıcısı, ROS2, KYK ve DVM sınıflandırıcılarından az bir farkla daha başarıyla, KA ve NB yöntemlerine göre yöntemleri üstün bir başarı elde ettiği görülmektedir. f açısından Tablo 2 değerlendirildiğinde ise, KYK sınıflandırıcısı, rakiplerine göre üstün bir başarı elde etmiştir. Bu veriye paralel olarak, sınıflandırma algoritmalarının başarılarını karşılaştırmada en önemli ölçütlerden olan AUC değerlerinde de KYK algoritması, üstün bir başarı elde ettiği görülmektedir.

Karşılaştırma ölçütleri genel olarak değerlendirildiğinde, KYK algoritması rakip algoritmalara göre üstünlük sağladığı anlaşılmaktadır. Fakat, bu verinin anlamlı olabilmesi için istatistiksel analiz ile desteklenmesi gerekmektedir. Parkinson hastalığının teşhis edilebilmesinde kullanılan KYK, DVM, KA ve NB makine öğrenmesi tekniklerini istatistiksel olarak karşılaştırabilmek için acc değerleri üzerinden Mann Whitney-U testi kullanılmış ve karşılaştırma sonuçları Tablo 3'te verilmiştir.

İstatistiksel karşılaştırma için Tablo 3 incelendiğinde, KYK algoritması ile ROS1, ROS2, DVM, KA ve NB algoritmaları arasında KYK'nin lehine istatistiksel anlamlı farkın olduğu görülmektedir ($p \leq 0,05$). Aynı zamanda, ROS1 algoritması ile ROS2, DVM, KA ve NB algoritmaları arasında, ROS1'in lehine anlamlı bir fark vardır ($p \leq 0,05$). Benzer veri ROS2 ve DVM için de geçerlidir. Fakat, KA ve NB algoritmaları arasında herhangi bir anlamlı farkın olmadığı da Tablo 3'ten anlaşılmaktadır ($p > 0,05$). Dolayısıyla, Parkinson hastalığının ses sinyalleri üzerinden teşhis edilebilmesinde, makine öğrenmesi algoritmalarından KYK sınıflandırıcı, diğer makine öğrenmesi yöntemlerine göre daha başarılı olduğu anlaşılmaktadır.

PDC veri seti 753 öznitelik ile yüksek boyutlu bir veriye sahiptir. Yüksek boyutlu verilerin sınıflandırılmasında, literatürde genellikle TBA ve DDA vb. boyut indirgeme tekniklerinden yararlanıldığı görülmektedir. Bu nedenle, Parkinson hastalığının teşhis edilebilmesindeki etkilerinin incelenmesi gerekmektedir. Elde edilen deneysel sonuçlarda ve istatistiksel analizde, KYK sınıflandırıcısının diğer yöntemlerden daha başarılı olduğu görülmektedir. Bu nedenle, bahsi geçen boyut indirgeme yöntemlerinin sınıflandırma üzerindeki etkisini gözlemlemek üzere KYK yöntemi kullanılmıştır. TBA ve DDA yöntemleriyle veri boyutunu sırasıyla %50, %25, %10, %5, %2 ve %1'e düşürdükten sonra KYK sınıflandırıcı ile elde edilen doğruluk değerleri Tablo 4'de sunulmuştur. Tablo 4 incelendiğinde, veri boyutunun indirgenmesi sınıflandırma başarımını düşürdüğü görülmektedir. Bu bulgu, veri setinin içerdiği öznitelikler, problemin doğasını iyi temsil ettiğini göstermektedir. Bu açıdan Parkinson hastalığının teşhisinde, çıkartılan özniteliklerin kayıpsız kullanılması gerektiği sonucuna ulaşılabilir.

PARKİNSON HASTALIĞININ SES SİNYALLERİ ÜZERİNDEN MAKİNE ÖĞRENMESİ TEKNİKLERİ İLE TANIMLANMASI

Tablo 4. TBA ve DDA ile farklı oranlarda boyutu azaltılan veri setinin sınıflandırılmasında en başarılı yöntem olan KYK yönteminin 30 farklı koşmadaki *acc* ölçütlerinin ortalama ve standart sapma değerleri

Oran	Öznitelik sayısı	TBA ile boyut indirgeme <i>acc</i>		DDA ile boyut indirgeme <i>acc</i>	
		Ortalama	Standart Sapma	Ortalama	Standart Sapma
%100	753	91,83	0,55	91,83	0,55
%50	377	74.92	1.08	67.24	2.12
%25	189	77.24	1.21	67.29	1.95
%10	76	85.89	1.23	67.36	1.90
%5	38	87.83	1.19	67.34	2.16
%2	16	85.09	1.50	67.20	2.23
%1	8	84.46	1.46	67.04	2.17

Tablo 5. KYK, DVM, KA ve NB sınıflandırıcılarının literatürle karşılaştırılması

Yöntem	PDC	PDC [4]	OPD [23]	PSD [23]
DVM	86,99	86	85,780	65,450
KYK	91,83	85	-	-
KA	79,21	85	84,371	64,520
NB	79,66	83	69,644	59,890
Satırların Ortalaması	84,42	84,75	79,931	63,286

3.3. Literatürde kullanılan diğer Parkinson hastalığı çalışmaları ile karşılaştırma

Son birkaç yılda ses sinyallerinden Parkinson hastalığının teşhis edilmesi üzerine literatürde OPD ve PSD veri setleri kullanılmaktadır. Ayrıca, bu çalışmada kullanılan PDC veri seti ise bağışçılar tarafından bir araştırma makalesinde kullanılmıştır. Bu nedenle, elde edilen sonuçlar mevcut literatürdeki diğer çalışmalarla karşılaştırılması önem arz etmektedir.

OPD ve PSD veri setleri üzerinden Parkinson hastalığının sınıflandırılmasında, 10 kat çapraz doğrula tekniği ile makine öğrenmesi tekniklerinin kullanıldığı [23] çalışmanın sonuçları ve bir denek dışında bırakma çapraz doğrulama tekniği ile PCD veri setinin bağışçılarının yayınladığı [4] çalışmanın sonuçları karşılaştırmalı olarak Tablo 5’de sunulmuştur.

Tablo 5 incelendiğinde, Parkinson hastalığının sınıflandırılmasında kullanılan veri setlerinden PDC veri setinin ortalamada tüm sınıflandırıcılarda daha iyi sonuç verdiği görülmektedir. Bu veri, problemin PDC veri setinde daha iyi temsil ettiği anlaşılmaktadır. Aynı zamanda, tüm veri setleri ve sınıflandırıcılar üzerinden Tablo 5 değerlendirildiğinde; PDC veri seti üzerinden sınıflandırma başarımında %91,83 doğruluk değeri ile KYK yöntemi en yüksek değere sahip olduğu görülmektedir.

4. SONUÇ

Bu çalışmada, Parkinson hastalığının ses sinyalleri üzerinden sınıflandırılmasında makine öğrenmesi tekniklerinin başarımının karşılaştırmalı olarak analiz edilmesi amaçlanmıştır. Bu amaç için literatüre 2018 yılında sunulan yüksek boyutlu öznitelige ve örnekleme sahip PDC veri seti kullanılarak, KYK , ROS, DVM, KA ve NB sınıflandırıcıları ile hastalık teşhisi gerçekleştirilmiştir. Elde edilen deneysel sonuçlar, KYK yönteminin istatistiksel olarak diğer yöntemlerden daha başarılı olduğunu ortaya çıkarmıştır. Ayrıca, yüksek boyutlu verilerin sınıflandırılmasında, boyut indirgeme yöntemleri de ön işlem olarak uygulanmaktadır. Bu çalışmada kullanılan veri setinde TBA ve DDA ile farklı oranlarda indirgenmiş ve KYK ile sınıflandırılmıştır. Fakat, elde edilen sonuçlar göre boyut indirgeme yöntemlerinin Parkinson hastalığının sınıflandırılmasında faydalı sonuçlar üretmediğini göstermektedir.

Parkinson hastalığının önemli belirtilerinden biriside, el ayak hareketlerindeki bozukluklardır. Bu veri doğrultusunda, hastalardan ses sinyalleri ile yazı veya şekil çizibilme yeteneklerinin beraber test edilebilmesi,

H. BADEM

doğru teşhis yapabilmeye başarımın artabileceğini ön görülebilir. Ayrıca, Parkinson hastalığının ses sinyalleri üzerinden, sınıflandırılmasında günümüzde popülerliği artan önemli yapay zekâ yaklaşımları olan derin öğrenme, uç öğrenme vb. tekniklerin performansının araştırılması gelecek çalışmalar açısından önemli olduğu düşünülmektedir.

KAYNAKLAR

- [1] BAŞTÜRK, A., BAŞTÜRK, N. S., QURBANOV, O. , “A Comparative Performance Analysis Of Various Classifiers For Fingerprint Recognition,” Ömer Halisdemir Üniversitesi Mühendislik Bilimleri Dergisi,, 7(2), 504-513, 2018.
- [2] LUNDBERG, S. M. , NAIR, B., VAVILALA, M. S., HORIBE, M., EISSES, M. J., ADAMS, T., LEE, S. I., “Explainable Machine-Learning Predictions For The Prevention Of Hypoxaemia During Surgery.”,Nature Biomedical Engineering, 2(10), 749, 2018.
- [3] DEO. R. C., “Machine Learning in Medicine,” Circulation, 132(20), 1920-30., 2015.
- [4] SAKAR C., SERBES, G. , GUNDUZ, A. , TUNC, H. , NIZAM, H., SAKAR, B., TUTUNCU M., AYDIN T., ISENKUL M., APAPAYDIN H. “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, 74, 255-263, 2019.
- [5] CAKMUR R., “Parkinson Hastalığı Ve Medikal Tedavisi” Klinik Gelişim, 53-58., 2011.
- [6] ERTAN S., “Parkinson Hastalığının Klinik Özellikleri,” Cerahpaşa Tıp Fakültesi Sürekli Tıp Eğitimi Sempozyum Dizisi, 42, 249-254, 2005.
- [7] GÜRÜLER H., “A Novel Diagnosis System For Parkinson’s Disease Using Complex-Valued Artificial Neural Network With K-Means Clustering Feature Weighting Method,” Neural Computing and Applications, 28(7), 1657–1666, 2017.
- [8] PEKER M., “A Decision Support System To Improve Medical Diagnosis Using A Combination Of K-Medoids Clustering Based Attribute Weighting And DVM.”, Journal of Medical Systems, 40(116), 2016.
- [9] LITTLE M. A., MCSHARRY P. E., ROBERT S. J., CESTELLO D.A., MOROZ I. M., “Exploiting Nonlinear Recurrence And Fractal Scaling Properties For Voice Disorder Detection,” Biomed. Eng., 6(23), 2007.
- [10] SAKAR B. E., ISENKUL M. E., SAKAR C. O., SERTBAS A., GURGEN F., DELİL S., APAYDİN H. KURSUN O., “Collection and Analysis of a Parkinson Speech Dataset with Multiple Types of Sound Recordings,” IEEE Journal of Biomedical and Health Informatics, 17(14), 828-834, 2013.
- [11] DUA D. , KARRA TANISKIDOU E., “UCI Machine Learning Repository. Irvine, CA: University of California, School of Information and Computer Science.” 2017. [Çevrimiçi]. Available: <http://archive.ics.uci.edu/ml>.
- [12] SMOLA A. J. SCHÖLKOPF B., “A Tutorial On Support Vector Regression,” Statistics and Computing, 14(3) 199–222, 2004.
- [13] COVER T. HART P., “Nearest Neighbor Pattern Classification.”, IEEE Transactions On Information Theory, 13(1), 21-27, 1967.
- [14] QUINLAN J., “Induction Of Decision Trees,” Machine Learning, 1(1) 81–106., 1986.
- [15] RISH I., “An empirical study of the naive Bayes classifier,” IJCAI 2001 workshop on empirical methods in artificial intelligence, New York, 2001.
- [16] BREIMAN L., “Random forests,” Machine learning, 45(1),5-32., 2001.
- [17] BREIMAN L., “Bagging predictors,” Machine learning, 24(2), 123-140., 1996.
- [18] BALAKRISHNAMA S., GANAPATHIRAJU A., “Linear discriminant analysis-a brief tutorial” Institute for Signal and information Processing,18,1-8, 1998.
- [19] WOLD S., ESBENSEN K., GELADI P. “Principal component analysis” Chemometrics and intelligent laboratory systems, 2(1-3), 37-52, 1987.
- [20] LI M., YUAN B., “D-LDA: A statistical linear discriminant analysis for image matrix” Pattern Recognition Letters, 26(5), 527-532, 2005.
- [21] TING. K., “Sensitivity and Specificity” Encyclopedia of Machine Learning, Boston, MA, Springer, 2011.
- [22] HOSSIN M., SULAIMAN N., “A Review On Evaluation Metrics For Data Classification Evaluations.”, International Journal of Data Mining & Knowledge Management Process., 5(2), 2015.
- [23] CALİSKAN A., BADEM H., BASTURK A., YUKSEL M. E., “Diagnosis Of The Parkinson Disease By Using Deep Neural Network Classifier.” Istanbul University-Journal of Electrical & Electronics Engineering, 17(2), 3311-3319, 2017.