



**A COMPARISON OF FEATURE SELECTION METHODS FOR DIAGNOSIS
OF PARKINSON'S DISEASE FROM VOCAL MEASUREMENTS**

Ömer ESKİDERE*

Bursa Orhangazi Üniversitesi, Mühendislik Fakültesi, Elektrik Elektronik Mühendisliği Bölümü, BURSA

Received/Geliş: 26.07.2012 Revised/Düzelme: 01.10.2012 Accepted/Kabul: 01.10.2012

ABSTRACT

Parkinson's disease is a neurological disorder which affects the quality of life of the patients and has major social and economical impact. To diagnose the disease, clinical examinations and observations with Unified Parkinson's disease Rating Scale (UPDRS) have been used, but especially on the initial phase of the disease, this method may be insufficient. In this paper, we used biomedical voice measurements obtained from sustained phonation samples for detection of Parkinson's disease. We compared the six different types of feature selection procedures. These are Bhattacharyya, information gain, relief, minimum-redundancy maximum-relevancy (MRMR), t-test, and support vector machine methods based on recursive feature elimination (SVM-RFE). It was found that SVM-RFE gave the best recognition results with the 95.13% classification accuracy for Parkinson's disease dataset.

Keywords: Parkinson's disease, classification, support vector machine, feature selection, SVM-RFE.

**SES ÖLÇÜMLERİNDEN PARKİNSON HASTALIĞININ TEŞHİSİ İÇİN ÖZNETELİK SEÇME
YÖNTEMLERİNİN KARŞILAŞTIRILMASI**

ÖZET

Parkinson hastalığı, hastanın yaşam kalitesini etkileyen, önemli sosyal ve ekonomik etkileri bulunan bir nörolojik bozukluktur. Hastalık teşhisinde klinik gözlem ve değerlendirmeler ile birlikte birleştirilmiş Parkinson hastalığı değerlendirme ölçeği kullanılmakta, ancak özellikle hastalığın başlangıç döneminde bu yöntem yetersiz kalabilmektedir. Bu çalışmada, Parkinson hastalığının teşhisi için sürdürülmüş fonasyon örneklerinden elde edilen biyomedikal ses ölçümleri kullanıldı. Altı farklı öznetelik seçme yöntemi karşılaştırıldı. Bunlar; Bhattacharyya, bilgi kazancı, relief, minimum-artıklık maksimum-ılgililik (MRMR), test ve özyinelemeli öznetelik eksiltme temelli destek vektör makinesi (SVM-RFE) yöntemleridir. Parkinson hasta veri seti için, SVM-RFE öznetelik seçme yöntemi % 95.13 doğru sınıflandırma oranı ile en iyi tanıma sonucunu vermiştir.

Anahtar Sözcükler: Parkinson hastalığı, sınıflandırma, destek vektör makinesi, öznetelik seçme, SVM-RFE.

1. GİRİŞ

Parkinson hastalığı, yavaş ilerleyen nörolojik bir hastalık olup, beyinde dopamin salgılayan hücrelerin hasarı sonucu ortaya çıkar [1, 2]. Ancak bu hasarın nedeni konusunda pek çok hipotez olmasına rağmen, bunların hiçbiri henüz ispatlanamamıştır [3, 4]. Parkinson hastalığının belirtileri

* Corresponding Author/Sorumlu Yazar: e-mail/e-ileti: omer.eskidere@bou.edu.tr, tel: (224) 211 44 07

kademeli olarak ortaya çıktığından dolayı erken teşhisi zordur ve Alzheimer hastalığından sonra ikinci en çok yaygın nörolojik hastalıktır [2, 51].


Parkinson hastaları; istirahat halinde titreme, hareketlerde yavaşlama, kas sertliği ve denge kaybı belirtilerini yaygın olarak gösterir [5, 6]. Bu belirtilere ilave olarak ruhsal değişiklikler, konuşma bozuklukları, uyku bozuklukları ve depresyon belirtileri sıklıkla gözlenir ve bu belirtiler zamanla kötüleşebilir [7, 8]. Konuşma bozuklukları, Parkinson hastaları arasında çok yaygın olup, hastaların yaklaşık % 90'ında bu belirti görülür [9, 10]. Ayrıca bu hastalar, kısık sesle konuşma, donuk konuşma, konuşmaya başlama zorlukları, ses yüksekliğini sürdürmede zorlanma, telaffuz hataları ve acıcılıkta azalma gibi konuşma bozukluğu belirtileri içerebilir [11, 12].

Parkinson hastalarına ait seslerin akustik ölçümleri, hastaya zarar vermeden kolayca yapılabilmektedir. Literatürde, seslerin akustik ölçümüne ait pek çok değişik yöntemler önerilmiştir. Bunlar; hastanın sürdürülmüş hecelerinden temel frekanstaki kısa süreli düzensizlikler, jitter, shimmer gibi akustik ölçümlerin kullanılması [13], ses kısıklığının ölçümü için harmonik gürültü oranı parametresi kullanılması önerilmiştir [14]. Ayrıca Mel frekansı kepsturm katsayıları [15], doğrusal öngörü modelleme [16, 17], işitsel modelleme [18] ve kepstrel tepe önem ölçümleri [19], sesin akustik ölçümlerinde kullanılmıştır. Son zamanlarda disfonik sesin şiddetini belirlemek için doğrusal olmayan dinamiklerden analiz yöntemleri türetilmiştir [20, 21]. Little ve ark., doğrusal olmayan dinamiklerin analizinin ses bozukluklarını belirlemede geçerli bir metot olarak önermektedir [22].

Bu çalışmada sestten Parkinson hastalığı teşhisi için farklı tipte öznelik seçme metotları karşılaştırıldı. Elde edilen sonuçlar literatürdeki son çalışmalar ile karşılaştırıldı. Makalenin taslağı şu şekildedir. Bölüm 2 de önerilen Parkinson hastalığı teşhis sistemi ve kullanılan veri setleri tanımlandı. Bölüm 3'de deneysel sonuçlar verildi ve bulunan sonuçlar literatürdeki çalışmalar ile karşılaştırıldı. Deneylerden elde edilen sonuçlar bölüm 4'de verildi.

2. YÖNTEM

Şekil 1'de önerilen Parkinson hastalığı sınıflandırma sistemi blok diyagramı görülmektedir. Sistemde ilk olarak Parkinson hastası ve sağlıklı kişilere ait ses ölçümlerini içeren veri setleri belirlenir. Daha sonra bu veri setlerindeki ses ölçüm örnekleri eğitim ve test olmak üzere iki gruba ayrılır. En yüksek sınıflandırma başarımını sağlayacak öznelikleri belirlemek için, öznelik seçme yöntemleri test edilir. Eğitim verisi ile her bir sınıfın modeli, sınıflandırma algoritması kullanılarak oluşturulur. Test verisi kullanılarak konuşmacının Parkinson hastası olup olmadığını anlamak için bir benzerlik skoru hesaplanır.



Şekil 1. Parkinson hastalığı teşhisi blok diyagramı.

2.1. Veri Setleri

Deneylerde iki farklı veri seti kullanıldı. Bunlar; Parkinson hastalığı veri seti (PHV) ve birleştirilmiş Parkinson hastalığı veri setidir (BPHV). Parkinson hastalığı veri seti ve Parkinson

uzaktan gözetleme veri setinin ortak özellikleri (Çizelge 1) kullanılarak Birleştirilmiş Parkinson hastalığı veri seti oluşturuldu. Her bir veri seti aşağıda kısaca tanımlanmaktadır.

2.1.1. Parkinson Hastalığı Veri seti (PHV)

PHV, Little [2] tarafından sağlıklı ve Parkinson hastalarına ait konuşma sinyalleri kaydedilerek Oxford üniversitesi ve ulusal ses ve konuşma merkezi işbirliği ile oluşturulmuştur. Veri seti geniş biyomedikal ölçümler (ses öznitelikleri) içermektedir. Bu ölçümler 23'ü Parkinson hastası olan toplam 31 kişiden, hasta başına altı bazen yedi kayıt alınarak oluşturulmuştur [2, 23].

PHV öznitelikleri şunlardır; ortalama, maksimum ve minimum ses temel frekansı, temel frekandaki düzensizlik ölçümleri (Jitter(%), Jitter (mutlak), Jitter :RAP, Jitter: PPQ ve Jitter: DDP), genlik düzensizlik ölçümleri (Shimmer, Shimmer(dB), Shimmer:APQ3, Shimmer:APQ5, Shimmer: APQ, Shimmer: DDA), sesteki ton bileşenlerinin gürültüye oranının ölçümleri (HNR ve NHR), iki adet doğrusal olmayan dinamik komplekslik ölçümleri (RPDE ve D2), üç adet doğrusal olmayan temel frekans değişimi ölçümleri (PPE, Spread1 ve Spread2) ve üstel kesirli sinyal (DFA) ölçümü içermektedir [2, 50-55]. Ayrıca PHV, Parkinson hastaları için 1, sağlıklı kişiler için 0 olarak tanımlı bir durum sütunu içermektedir. Bu veri setinin hazırlanış amacı; durum sütununa bağlı olarak Parkinson hastalarını sağlıklı kişilerden ayırmaktır.

2.1.2. Parkinson Uzaktan Görüntüleme Veri Seti (PUV)

PUV, A. Tsanas ve M. Little [12] tarafından Parkinson hastalığındaki ilerlemenin tahmini amacıyla oluşturulmuştur. Bu veri setinin tamamı Parkinson hastalarından (42 kişi) oluşmakta ve hasta başına yaklaşık 200 ses kaydı içermektedir. Her bir hasta için sürdürülmüş /a/ ünlü sesi kullanılarak toplam 5875 ses kaydından veri seti oluşturulmaktadır. PUV toplam 26 parametre içermektedir. Bunlar; kişi numarası, yaşı, cinsiyeti, kayıt verisi zaman aralıkları, motor-UPDRS, total-UPDRS ve 16 ses öznitelikleridir.

2.1.3. Birleştirilmiş Parkinson Hastalığı Veri Seti (BPHV)

PHV sınırlı sayıda hastaya ait (23 kişi) içermektedir. Daha geniş bir hasta grubu ile sistemi test etmek için bu veri setindeki ölçümler PUV örneklerindeki benzer ölçümler ile birleştirilerek yeni bir veri seti (BPHV) oluşturulabilir. BPHV aşağıdaki adımlar kullanılarak oluşturulmuştur. İlk olarak, PUV'da her bir kişiye ait 200 kayıttan rastgele 6 kayıt seçildi. Bu şekilde PUV'daki 42 kişiden toplam 252 kayıt oluşturuldu. Buna ilave olarak PHV'den 31 kişiye ait 195 ses kaydı alındı. Daha sonra, PUV ve PHV'den 16 ortak ses özniteliği birleştirilerek BPHV oluşturuldu. Bu ortak 16 öznitelikler; Jitter (%), Jitter (mutlak), Jitter: RAP, Jitter: PPQ, Jitter: DDP, Shimmer, Shimmer (dB), Shimmer: APQ3, Shimmer: APQ5, Shimmer: APQ, Shimmer: DDA, NHR, HNR, RPDE, DFA ve PPE ölçmelerini içermektedir. İki veri setinin ortak özniteliklerinin birleştirilmesiyle oluşturulan yeni veri seti 73 kişiden alınan 447 biyomedikal ses kaydı ölçümlerini içermektedir. Çizelge 1'de PHV, PUV ve BPHV' deki 16 öznitelik parametresi için ortalama ve standart sapma istatistiksel değerleri görülmektedir.

PHV ve PUV ses örnekleri elde edilmesinde farklı veri toplama metodları kullanılmıştır. PHV ses sinyalleri, 44.1 kHz örnekleme frekansı ve 16 bit çözünürlükte, kulaklıkları bir mikrofonun dudaklardan 8 cm uzakta tutularak, ses korunaklı bir kabinde kaydedilmiştir [2]. PUV ses sinyalleri ise, kulaklıkları bir mikrofonun dudaklardan 5 cm uzakta tutularak 24 kHz örnekleme frekansı ve 16 bit çözünürlükte hastanın evinde kaydedilmiştir [12]. Bu veri toplama yöntem farklılıkları BPHV için Parkinson hastalığı teşhis doğruluğunu etkileyebilir.

Çizelge 1. Üç veri setinin seçilen öznitelikleri için ortalama ve standart sapma değerleri

Öznitelik Etiketi	Ortalama			Standart Sapma		
	PHV	PUV	BPHV	PHV	PUV	BPHV
MDVP: Jitter (%)	0.006	0.059	0.059	0.004	0.004	0.004
MDVP: Jitter (Mutlak)	4.39e-5	4.07e-5	4.21e-5	3.48e-5	3.09e-5	3.27e-5
MDVP: RAP	0.003	0.003	0.003	0.003	0.002	0.003
MDVP: PPQ	0.003	0.003	0.003	0.003	0.003	0.003
Jitter: DDP	0.010	0.008	0.009	0.009	0.009	0.008
MDVP: Shimmer	0.029	0.032	0.031	0.019	0.024	0.022
MDVP: Shimmer (dB)	0.282	0.289	0.286	0.195	0.208	0.202
Shimmer: APQ3	0.016	0.016	0.016	0.010	0.012	0.011
Shimmer: APQ5	0.018	0.019	0.018	0.012	0.015	0.014
Shimmer: APQ	0.024	0.026	0.025	0.017	0.022	0.020
Shimmer: DDA	0.047	0.048	0.047	0.030	0.035	0.033
NHR	0.025	0.028	0.026	0.040	0.042	0.041
HNR	21.88	22.06	21.98	4.426	4.247	4.321
RPDE	0.498	0.539	0.521	0.104	0.105	0.106
DFA	0.718	0.649	0.679	0.055	0.071	0.073
PPE	0.207	0.213	0.210	0.090	0.090	0.090

Çizelge 2’de BPHV’deki hasta ve sağlıklı kişilerin özniteliklerinin ortalama ve standart sapma değerleri görülmektedir. Hasta ve sağlıklı kişilerin ortalama değerleri farklı olup, Parkinson hastaları için HNR ve DFA öznitelikleri dışında tüm özniteliklerin sağlıklı kişilere göre ortalama değerleri arttığı Çizelge 2’den görülmektedir. Parkinson hastalarının tüm öznitelik değerleri için standart sapma değerleri sağlıklı kişilerden daha fazladır.

Çizelge 2. BPHV için Parkinson hastası ve sağlıklı kişilerin ortalama ve standart sapma değerleri

Öznitelik Etiketi	Ortalama		Standart Sapma	
	Hasta	Sağlıklı	Hasta	Sağlıklı
MDVP: Jitter (%)	0.006	0.004	0.046	0.002
MDVP: Jitter (Mutlak)	4.43e-5	2.33e-5	3.34e-5	1.49e-5
MDVP: RAP	0.003	0.002	0.003	0.001
MDVP: PPQ	0.003	0.002	0.003	9.43e-4
Jitter: DDP	0.009	0.006	0.0081	0.003
MDVP: Shimmer	0.033	0.018	0.022	0.005
MDVP: Shimmer (dB)	0.033	0.163	0.208	0.058
Shimmer: APQ3	0.301	0.009	0.011	0.003
Shimmer: APQ5	0.017	0.010	0.015	0.003
Shimmer: APQ	0.027	0.013	0.021	0.004
Shimmer: DDA	0.049	0.028	0.034	0.010
NHR	0.028	0.011	0.043	0.019
HNR	21.66	24.68	4.307	3.434
RPDE	0.531	0.443	0.104	0.092
DFA	0.678	0.696	0.075	0.051
PPE	0.221	0.123	0.089	0.045

2.2. Öznitelik Seçme

Öznitelik seçme yöntemleri genellikle daha ayırıcı küçük bir alt grup öznitelik seçimi için kullanılır ve bu şekilde sınıflandırma başarımının artırılması amaçlanır. Pek çok öznitelik seçme yöntemi olmasına karşın, bu yöntemler süzgeç, sarıcı ve gömülü yöntemler olmak üzere üç temel grupta incelenebilir [24, 25].

Süzgeç yöntemlerinde, herhangi bir öğrenme algoritması olmadan, bilgi, bağımlılık ve tutarlılık gibi ölçümler kullanılarak öznitelikler seçilir. Bu metodlar sarıcı yöntemlere göre daha az karmaşık ve hızlı olduğundan dolayı, özniteliklerin boyutlarının düşürülmesi ve büyük veri setlerine daha uygundur [25]. MRMR [23], T-test [26], Bhattacharyya [27], relief [28, 29] ve bilgi kazancı [30] en sık kullanılan yöntemlerden bazılarıdır. Sarıcı yöntemlerde ise öznitelikleri değerlendirmek için doğru sınıflandırma oranına bağlı olarak verimliliğin ölçüldüğü bir sınıflandırıcı algoritması kullanılır. Bu yöntemlerde model seçimi ve en iyi alt öznitelik grubu seçimi arasında bir etkileşim vardır ve sarıcı yöntemler, bu etkileşiminin ayarlanmasına bağlı olarak genellikle daha iyi sonuçlar vermektedir. Genetik algoritmalar [27, 33], SVM-RFE [31], Sıralı ileri/Geri seçim [32] sık kullanılan sarıcı yöntemlerden bazılarıdır. Gömülü yöntemlerde ise öznitelik seçme süreci ile öğrenme yöntemi parametre seçimi eşzamanlı olarak gerçekleşmektedir. Bu yöntemde sarıcı yöntemlerde oluşan hesaplama karmaşıklığı azaltılabilmektedir. CART, C4.5 gibi karar ağaçları bu gömülü yöntemlerden bazılarıdır [34, 35].

2.3. Destek Vektör Makinesi (SVM)

Destek vektör makineleri çok çeşitli görevler için uygulanan son zamanların en yaygın sınıflandırıcılarından birisidir. Bu sınıflandırma yöntemi, hastalık teşhisi [2, 36], konuşmacı tanıma [37] ve yazılan sayıyı tanıma [38] gibi değişik alanlarda uygulanmıştır. SVM, Cortes ve Vapnik [38] tarafından önerilmiş olup yapısal risk minimizasyonu prensibini kullanmaktadır. Bu yöntemde, iki sınıf arasındaki birbirine en yakın örneklerin uzaklıklarını maksimize edildiği yüksek bir düzlem araştırılır. Doğrusal olarak ayıramayan veriler için, SVM yardımıyla giriş vektörü yüksek boyutlu bir uzaya doğrusal olmayan bir fonksiyon yardımıyla eşleştirilir. SVM eğitimi ikinci dereceden bir optimizasyon problemi kullanılabilir [38]. Sınıflandırıcı bir çekirdek fonksiyonunu $K(\cdot, \cdot)$ toplamını kullanılarak iki sınıfı modeller ve $f(x)$ ' in değerine bağlı olarak bir sınıf kararı verilir.

$$f(x) = \sum_{i=1}^N \alpha_i y_i K(x, x_i) + d \quad (1)$$

Burada α_i Lagrange çarpanı, y_i istenen çıkışlar ve x_i eğitim verisinden elde edilen destek vektörleridir. Çekirdek fonksiyonu $K(\cdot, \cdot)$, SVM'nin optimizasyonunu sağlayan Mercer şartlarını sağlamak zorundadır. Optimizasyon şartları bir maksimum sınır konseptine bağlıdır. İki sınıfı birbirinden ayıran, bir maksimum sınır yüksek düzlemin optimizasyonu süreci ile bulunur. Doğrusal çekirdek, polinom çekirdek ve radyal temelli çekirdek yaygın olarak kullanılan çekirdek fonksiyonlarıdır.

SVM, öznitelik seçme işleminde de kullanılmaktadır. Bir çeşit geriye doğru öznitelik eleme şekli olan SVM-RFE [31] öznitelik seçme yöntemi, gen seçimi [39] ve örüntü tanımadada [40, 41] başarıyla uygulanmıştır. Bu yöntem performansı optimize eden öznitelik alt kümesi bulmak için şu şekilde uygulanır. İlk olarak tüm öznitelikler bir amaç fonksiyonuna bağlı olarak derecelendirilir ve en düşük skoru alan özellik veya özellikler öznitelik kümesinden çıkarılır [41, 42]. Bu işlem en yüksek sınıflandırma başarımı elde edilene kadar tekrar edilir. Bu çalışmada SVM-RFE öznitelik seçme yöntemi OSU-SVM [43] kullanılarak oluşturulup doğru sınıflandırma başarımına etkisi incelenmiştir.

2.4. Model Doğrulama ve Parametre Ayarları

Bir sınıflandırıcının başarısını değerlendirmek için pek çok istatistiksel yöntem bulunmaktadır. Bunlardan en çok yaygın olarak kullanılanlardan bazıları k-katlamalı çapraz doğrulama (KKÇ), birini dışarıda bırakarak çapraz doğrulama (BDB) ve önyükleme ile tekrar örnekleme (ÖTÖ) yöntemleridir. KKÇ yönteminde veri eş büyüklükteki k adet gruba ayrılır. k adet grubun her biri, ardışıl yaklaşımla test grubu olarak seçilir ve kalan $k - 1$ grup datası eğitim verisi grubunu oluşturur. Örnek büyüklüğünün k ya eşit olma durumu ise BDB yöntemi olarak isimlendirilir [44]. Bu doğrulama yöntemlerinden farklı olarak, ÖTÖ yönteminde tüm örnekler kullanılarak rastgele olarak verilerin yenilenmesi yapılır [45, 46].

Sakar ve Kursun [23], Parkinson hastalığının teşhisi için bir bireyi dışarıda bırakma [BBDB] yöntemini önermiştir. Yazarlar çalışmalarında ÖTÖ yönteminin eğitim grubu ile büyük oranda örtüşme oluşturduğu ve bu durumun yüksek ve önyargılı sınıflandırma doğruluğu oluşturduklarını rapor etmişlerdir [23]. Bu nedenle BBDB, Parkinson hastalığı veri grubuna uygun bir doğrulama yöntemi olarak önermişlerdir. Bu yöntemde her bir birey birer birer dışarıda bırakılarak sınıflandırıcı eğitilmekte ve dışarıda bırakılan veri grubu örnekleri ile test edilmektedir.

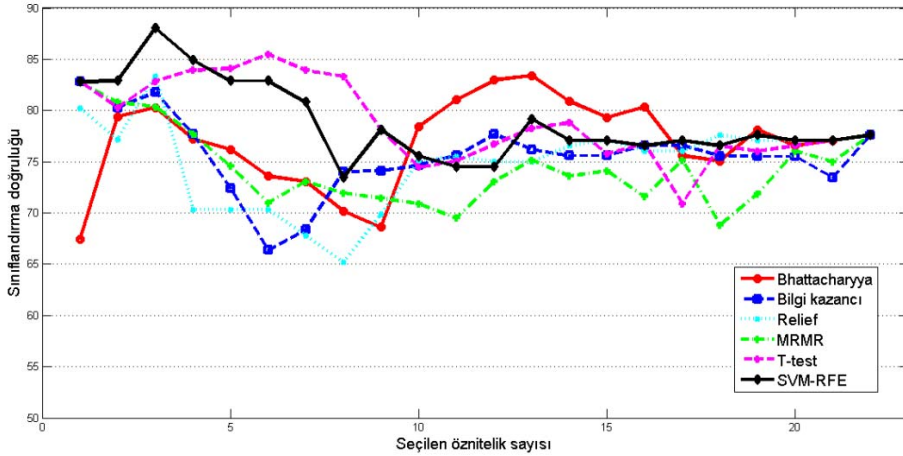
Altı farklı öznelik seçme yöntemi ile öznelikler derecelendirildikten sonra, seçilen özneliklerin sınıflandırma oranlarını bulmak için SVM kullanıldı. SVM sınıflandırıcıları, yüksek performans elde etmek için çekirdek çeşidi, çekirdek parametreleri ve maliyet parametrelerinin ayarlanması gerekir. SVM’de seçilen çekirdeğe göre RBF için genişlik, polinom için ise polinom derecesinin belirlenmesi gerekir. Ayrıca, maliyet parametresi (C), eğitim hatası minimumlaştırılması ve karar sınırının düzgünlüğü arasındaki ödünleşimi belirlemede kullanılır. Bu çalışmada çekirdek tipi olarak RBF seçildi. RBF genişlik parametresi 4, maliyet parametresi 256 olarak seçildi. Tüm öznelikler, öznelik seçme aşaması öncesinde $[0, 1]$ arasına normalize edildi. SVM eğitim ve test uygulamaları *LibSVM* [47] kullanılarak MATLAB yordamında gerçekleştirilmiştir.

3. DENEYSSEL BULGULAR

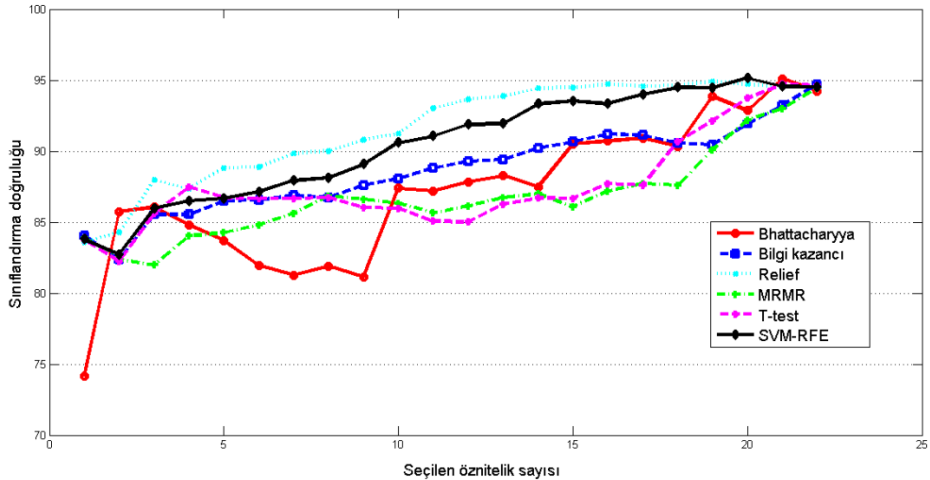
Bu çalışmada ses öznelikleri kullanılarak Parkinson hastalığı teşhisi için önerilen metot (şekil1) PHV ve BPHV isimli iki farklı Parkinson hastalığı veri grubuna uygulanmıştır. Bhattacharyya, bilgi kazancı, Relief, MRMR, T-test ve SVM-RFE öznelik seçme yöntemleri aynı eğitim ve test şartları altında karşılaştırılmıştır.

3.1. PHV Sınıflandırma Deneyleri

PHV’de bulunan özneliklerin tamamı deneylerde kullanılmıştır. Parkinson hastalığının teşhisinde sağlıklı kişiler 0, Parkinson hastalığı ihtimali olan kişiler 1 olarak sınıflandırılmaktadır. Önerilen metodun verimliliğini değerlendirmek için BBDB ve ÖTÖ doğrulama yöntemleri ile deneyler yapılmıştır. ÖTÖ yönteminde deney 200 kez tekrar edilerek, sınıflandırıcının ortalama doğruluğunda istatistiksel olarak güvenilir bir tahmin elde edilmesi amaçlanmıştır [44]. Şekil 2 ve şekil 3’te sırasıyla BBDB ve ÖTÖ doğrulamaları için, seçilen öznelik sayısına bağlı olarak ortalama sınıflandırma doğruluğu (%) gösterilmiştir.



Şekil 2. PHV için altı öznelik seçme algoritmasının karşılaştırılması. Sınıflandırma için BBDB doğrulama yöntemi kullanılmıştır.



Şekil 3. PHV için altı öznelik seçme algoritmasının karşılaştırılması. Sınıflandırma için ÖTÖ doğrulama yöntemi kullanılmıştır.

BBDB doğrulama yöntemi için tüm öznelik seçme yaklaşımları arasında en yüksek başarıyı veren öznelikler hesaplanmıştır. SVM-RFE ile yapılan derecelendirmede en iyi 3 öznelik kullanılarak % 88.02 başarımla elde edilmiştir.

Çizelge 3'de şekil 2 ve şekil 3'deki her bir öznelik seçme yöntem için, en yüksek başarımla değerleri gösterilmiştir. Çizelge 3'den görüleceği üzere ÖTÖ doğrulama yöntemi için sınıflandırma başarımları % 95.14'e kadar çıkmaktadır. ÖTÖ doğrulamada veri gruplarından gelen örneklerin bağımsız olduğu varsayılmakta ve PHV'nin test verilerindeki bazı örnekler, eğitim verilerinde de görülmektedir. Bu nedenle ÖTÖ doğrulama için sınıflandırma başarımları oranları BBDB'ye nazaran daha yüksek çıkmıştır.

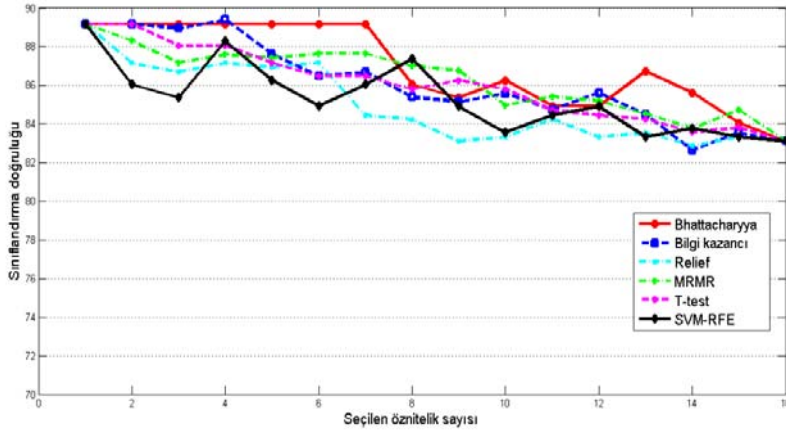
Çizelge 3. Öznitelik seçme yönteminin, en yüksek ortalama doğru sınıflandırma oranları (%). Parantez içindeki sayılar ortalama standart sapmaları göstermektedir.

Öznitelik seçme	BBDB	ÖTÖ
Bhattacharyya	83.40 (28.71)	94.55 (3.02)
Bilgi Kazancı	82.81 (34.26)	94.67 (3.23)
Relief	83.33 (31.96)	94.73 (3.00)
MRMR	82.81 (34.26)	94.46 (3.06)
T-test	85.49 (29.55)	94.61 (3.10)
SVM-RFE	88.02 (25.13)	95.14 (2.81)

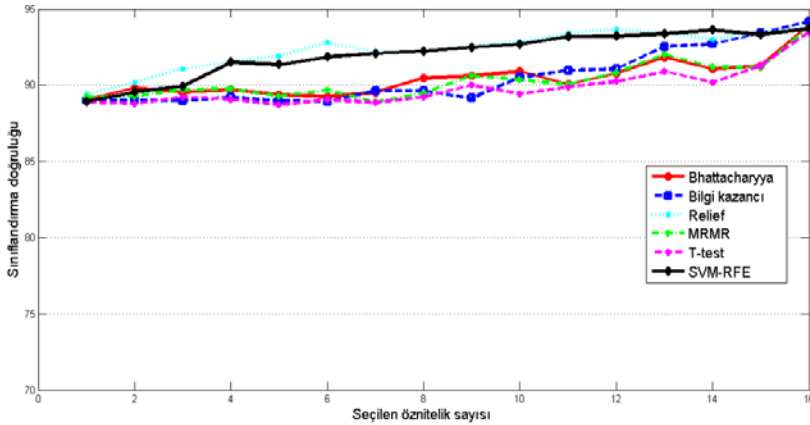
Çizelge 3'den görüleceği üzere Parkinson hastalığının teşhisi için SVM-RFE öznitelik seçme yönteminin kullanılması, diğer yaygın olarak kullanılan 5 öznitelik seçme yöntemine göre daha iyi sınıflandırma başarımı sağlamıştır. SVM-RFE ile hem sınıflandırıcının beslenmesinde kullanılan öznitelik sayısını azaltılıp hem de sınıflandırma doğruluğunda artış sağlanmıştır.

3.2. BPHV Sınıflandırma Deneyleri

BPHV kullanılarak BBDB ve ÖTÖ doğrulama yöntemleri ile Bölüm 3.1'de yapılan deneyler tekrarlanmıştır. Öznitelik seçme yöntemlerinin sırasıyla BBDB ve ÖTÖ doğrulamada ortalama sınıflandırma doğrulukları (%) şekil 4 ve şekil 5'te gösterilmiştir.



Şekil 4. BPHV için altı öznitelik seçme algoritmasının karşılaştırılması. Sınıflandırma için BBDB doğrulama yöntemi kullanılmıştır.



Şekil 5. BPHV için altı öznelik seçme algoritmasının karşılaştırılması. Sınıflandırma için ÖTÖ doğrulama yöntemi kullanılmıştır.

Şekil 4 ve 5'ten görüleceği üzere BBDB doğrulama ve ÖTÖ yöntemi kullanılarak yapılan deneylerde altı öznelik seçme algoritması birbirine yakın sonuçlar vermektedir. En yüksek başarımlar BBDB ve ÖTÖ doğrulama yöntemleri için sırasıyla % 89.41 ve % 94.11 ile bilgi kazancı öznelik seçme yöntemi ile elde edilmiştir.

BPHV deneyleri iki sınırlama altında yapılmıştır. Birinci sınırlama, BPHV örnekleri iki farklı veri toplama yöntemi (Bölüm 2.1.3) kullanılan PHV ve PUV örneklerinden türetilmiştir. İkinci sınırlama BPHV örnekleri toplamda 73 kişiye ait, 399 Parkinson hastası örnekleri ve 48 sağlıklı kişi örneklerinden oluşmaktadır. Bu nedenle BPHV sınıf örnekleri sayısında bir dengesizlik içermektedir. Sınıflardaki örneklerin dengesiz dağılımı durumunda genellikle öğrenme algoritmalarında çoğunluk sınıfına doğru bir önyargı oluşmaktadır. SVM sınıflandırıcı için LibSVM'de dengesiz veri grupları için w_i ağırlıklandırma parametresi kullanılması önerilmektedir. Ancak BPHV ile yaptığımız deneylerde bu parametrenin değiştirilmesi ile tanıma başarımının fazla etkilenmediği görülmüştür. Medikal teşhis veri grupları gibi dengesiz veri gruplarının sınıflandırılmasında [48, 49] da belirtilen yöntemler de önerilmiştir.

3.3. Önceki Çalışmalar ile Karşılaştırma

Bu bölümde literatürde BPHV ile ilgili çalışmalar bulunmadığından dolayı sadece PHV örnekleri için bu çalışma ile daha önce yapılan çalışmalar karşılaştırılacaktır. Ene [50], çalışmasında olasılıksal sinir ağı (PNN) Parkinson hastalığının teşhisinde sınıflandırıcı olarak kullanmıştır. Little ve ark. [2], SVM sınıflandırıcı ve süzgeç temelli ilişkisiz ölçme (STİÖ) ile öznelikleri seçerek PHV deki hasta ve normal kişileri sınıflandırmıştır. Sakar ve Kursun [23] çalışmalarında, BBDB doğrulama yöntemi ve karşılıklı bilgi temelli bir öznelik seçme yöntemi (MRMR) ile seçilen öznelikleri kullanmışlardır. Diğer bir çalışmada [51], bir sinir ağı temelli sınıflandırıcı (NN) Parkinson hastalarını ayırmak için kullanılmıştır ve % 92.9 doğru sınıflandırma başarımı elde edildiği rapor edilmiştir. Çağlar ve arkadaşları [52], dilsel kuvvetli adaptif sinir-bulanık sınıflayıcıyı (ANFC+LH), PHV örnekleri için uygulamıştır. Bu yöntem aynı zamanda veri setinden öznelik seçimi için kullanılarak % 94.72 test başarı oranı elde edilmiştir. Başka bir çalışmada Polat [53], bulanık c-ortalama (FCM) öznelik ağırlıklandırma yöntemini önermiştir. Yazar çalışmada ağırlıklandırılmış Parkinson hasta veri grubu için k-NN sınıflandırma algoritması kullanarak değişik k değerleri için % 97.93'e varan başarı oranları elde etmiştir. Luukkka [54] ise benzerlik sınıflandırıcı (SC) ve bulanık entropi (FE) öznelik seçme yöntemleri

ile % 85.03 başarı oranı elde etmiştir. Kihel ve Benyettou [55], yapay bağışıklık sistem uygulaması (AIS) ve klon öznelik seçme için % 92.70 başarıma ulaşmıştır. Daha önceki çalışmalarda öznelik seçme ve sınıflandırma yöntemleri ile elde edilen sonuçlar bu çalışma sonuçları ile karşılaştırma amaçlı Çizelge 4’de gösterilmiştir.

Çizelge 4. PHV örnekleri için farklı öznelik seçme ve sınıflandırma yöntemleri ile elde edilen başarı oranları

Yazar	Sınıflandırıcı+Öznelik seçme (Doğrulama)	Doğruluk
Ene [50]	PNN (%70 eğitim, %30 test)	80.92
Das [51]	NN (%65 eğitim, %35 test)	92.9
Çağlar ve ark. [52]	ANFC+LH (%50 eğitim, %50 test)	94.72
Luukka [54]	SC+FE (%50 eğitim, %50 test)	85.03
Kihel ve Benyettou [55]	AIS+ Klon (-)	92.70
Little ve ark. [2]	SVM+ STİÖ (ÖTÖ)	91.40
Sakar ve Kursun [23]	SVM+MRMR (BBDB)	81.53
Sakar ve Kursun [23]	SVM+MRMR (ÖTÖ)	92.75
Bu çalışmada	SVM+SVM-RFE (BBDB)	88.02
	SVM+SVM-RFE (ÖTÖ)	95.14

4. SONUÇLAR

Bu çalışmada biyomedikal ses parametreleri kullanılarak Parkinson hastalığının teşhisinde iki Parkinson hastalığı veri grubu (PHV ve BPHV) üzerinde test yapılmıştır. Bu amaçla SVM sınıflandırıcı altı farklı öznelik seçme yöntemi ile beslenmiş ve en ideal öznelik seçme yöntemi bulunması amaçlanmıştır. PHV örnekleri için SVM-RFE öznelik seçme yönteminin en yüksek başarıyı verdiği gözlenmiştir. Bu öznelik seçme yöntemi için BBDB doğrulamada % 88.02, ÖTÖ doğrulama için %95.14 ortalama sınıflandırma doğruluğu bulunmuştur. Bu deneyler sonunda elde edilen sonuçlar, önerilen ses örneklerinden Parkinson hastalığı teşhis yönteminin literatürdeki diğer çalışmalar ile kıyaslanabilir olduğunu göstermiştir.

REFERENCES / KAYNAKLAR

- [1] Barker R.A., S.B. Dunnett. “Functional integration of neural grafts in Parkinson’s disease”, Nature Neuroscience, Vol. 2, pp. 1047 – 1048, 1999.
- [2] Little M. A., P. E. McSharry, E. J. Hunter, L. O. Ramig. “Suitability of dysphonia measurements for telemonitoring of Parkinson’s disease”, IEEE Trans. Biomed. Eng., Vol. 56(4), pp. 1015-1022, 2009.
- [3] Paul S., et al. “A semantically enabled formalism for the knowledge management of Parkinson’s disease”, Medical Informatics and the Internet in Medicine, Vol. 31 (2), pp. 101–120, 2006.
- [4] Murakami K., et al. “Dietary glycemc index is inversely associated with the risk of Parkinson’s disease: A case–control study in Japan”, Vol. 26(5): 515-21, 2010.
- [5] Hou I-G.G., E.C .Lai. “Non-motor symptoms of Parkinson’s disease”, International Journal of Gerontology, Vol. 1, pp. 53-64, 2007.
- [6] Jankovic J., “Parkinson’s disease: clinical features and diagnosis”, J. Neurol. Neurosurg. Psychiatry, Vol. 79, pp. 368–376, 2008.
- [7] McDonald W.M., I.H. Richard, M.R. DeLong. “Prevalence, etiology, and treatment of depression in Parkinson’s disease”, Biol. Psychiatry, Vol. 54, pp. 363–375, 2003.

- [8] Carod-Artal F.J., S. Ziolkowski, M.H. Mourao, P. Martinez-Martin. "Anxiety and depression: Main determinants of health-related quality of life in Brazilian patients with Parkinson's disease", *Parkinsonism Related Disorder*, Vol. 14(2), pp. 102–108, 2008.
- [9] Ramig L.O., C. Fox, S. Sapir, "Parkinson's disease: Speech and voice disorders and their treatment with the Lee Silverman Voice Treatment", *Seminars in Speech and Language*, Vol. 25(2), pp. 169-180, 2004.
- [10] Ho A. K., R. Iansek, C. Marigliani, J. L. Bradshaw, S. Gates, "Speech impairment in a large sample of patients with Parkinson's disease", *Behav. Neurol.*, Vol. 11, pp. 131–137, 1998.
- [11] Sachin S., G. Shukla, V. Goyal, S. Singh, V. Aggarwal, Gureshkumar, M. Behari, "Clinical speech impairment in Parkinson's disease, progressive supranuclear palsy, and multiple system atrophy". *Neurol India*, 56:122-6, 2008.
- [12] Tsanas A., M.A. Little, P.E. McSharry, L.O. Ramig. "Accurate telemonitoring of Parkinson's disease progression by non-invasive speech tests", *IEEE Transactions on Biomedical Engineering*, Vol. 57, pp. 884-893, 2010.
- [13] Umapathy et al. "Discrimination of pathological Voices Using a Time-Frequency Approach", *IEEE Transactions on Biomedical Engineering*, Vol. 52(3), pp. 421-430, 2005.
- [14] Yumoto E., W. Gould, T. Baer. "Harmonics-to-noise ratio as an index of the degree of hoarseness", *J. Acoust. Soc. Am.*, Vol. 71, pp. 1544–1549, 1982.
- [15] Lorente J., I. Godino and P. Gomez-Vilda. "Automatic detection of voice impairments by means of short-term cepstral parameters and neural network based detectors", *IEEE Trans. Biomed. Eng.*, Vol. 51(2), pp. 380–384, 2004.
- [16] Parsa V., D. G. Jamieson. "Acoustic discrimination of pathological voice: Sustained vowels versus continuous speech", *J. Speech, Language Hear. Res.*, Vol. 44, pp. 327–339, 2001.
- [17] Eskenazi L., D. G. Childers, D. M. Hicks. "Acoustics correlates of vocal quality", *J. Speech Hear. Res.*, Vol. 33, pp. 298–306, 1990.
- [18] Shrivastav R., "The use of an auditory model in predicting perceptual ratings of breathy voice quality", *Journal of Voice*, vol. 17, no. 4, pp. 502–512, 2003.
- [19] Heman-Ackah Y. D., et al. "Cepstral peak prominence: A more reliable measure of dysphonia", *Ann Otol., Rhinol., Laryngol.*, Vol. 112(4), pp. 324–329, 2003.
- [20] Williams G.P., *Chaos Theory Tamed*, London, UK: Taylor & Francis, 1997.
- [21] Lee, et al., "Perturbation and nonlinear dynamic analysis of acoustic phonatory signal in Parkinsonian patients receiving deep brain stimulation", *Journal of Communication Disorders*, Vol. 41, pp. 485–500, 2008.
- [22] Little M.A., P.E. McSharry, S.J. Roberts D.A.E. Costello, I.M. Moroz, "Exploiting Nonlinear Recurrence and Fractal Scaling Properties for Voice Disorder Detection", *BioMedical Engineering OnLine*, 6:23, 2007.
- [23] Sakar C. O., O. Kursun, "Telediagnosis of Parkinson's Disease Using Measurements of Dysphonia", *Journal of Medical Systems*, Vol. 34(4), pp. 591-599 2010.
- [24] Kohavi R., G. H. John. "Wrappers for Feature Subset Selection", *Artificial Intelligence*, Vol. 97, Issue 1-2, pp. 273 – 324, 1997.
- [25] Guyon I., A. Elisseeff, "An Introduction to Variable and Feature Selection" *JMLR*, 3(Mar): pp. 1157-1182, 2003.
- [26] Ding C.H.Q. "Analysis of gene expression profiles: class discovery and leaf ordering", In *RECOMB*. ACM Press, New York, USA, pp. 127–136, 2002.
- [27] Gunal S., R. Edizkan, O. N. Gerek, D. G. Ece " Feature Selection for Power Quality Event Classification", *IEEE 16th Signal Processing and Communications Applications Conference*, 2008.

- [28] Kira K., L. A. Rendell. "A practical approach to feature selection. In *A Practical Approach to Feature Selection*", pp. 249–256, 1992.
- [29] Kononenko I. "Estimating attributes: Analysis and extensions of RELIEF", In *European Conference on Machine Learning*, pp. 171–182, 1994.
- [30] Raileanu L. E., K. Stoffel. *Theoretical comparison between the gini index and information gain criteria*. Univeristy of Neuchatel, 2000.
- [31] Guyon I., J. Weston, S. Barnhill, V. Vapnik, "Gene selection for cancer classification using support vector machines", *Machine Learning*, Vol. 46, pp. 389–422. 2002.
- [32] Kittler J. "Pattern Recognition and Signal Processing, chapter Feature set search algorithms", pp. 41–60, 1978.
- [33] Li L., D. Umbach, P. Terry, J. Taylor. "Applications of the GA/KNN method to SELDI proteomics data", *Bioinformatics*, Vol. 20(10), pp. 1638–1640, 2004.
- [34] Geurts P., M. Fillet, D. de Seny, M.-A. Meuwis, M. Malaise, M.-P. Merville, and L. Wehenkel, "Proteomic mass spectra classification using decision tree based ensemble methods" *Bioinformatics*, Vol. 21(15) pp. 3138–3145, 2005.
- [35] Wu B., T. Abbott, D. Fishman, W. McMurray, G. Mor, K. Stone, D. Ward, K. Williams, H. Zhao, "Comparison of statistical methods for classification of ovarian cancer using mass spectometry data", *Bioinformatics*, vol. 19(13), pp.1636–1643, 2003.
- [36] Güven A., K. Polat, S. Kara, S. Güneş. "The Effect of Generalized Discriminate Analysis (GDA) to the Classification of Optic Nerve Disease from VEP Signals", *Computers in Biology and medicine*, Vol.38(1), pp. 62 – 68, January 2008.
- [37] Campbell W., D. Sturim, D. Reynolds, A. Solomonoff, "SVM based speaker verification using a GMM supervector kernel and NAP variability compensation", in *ICASSP*, 2006.
- [38] Cortes C., V. Vapnik, *Mach. Learn.* 20 pp. 273–297, 1995.
- [39] Zhou X., David P. Tuck, "MSVM-RFE: extensions of SVM-RFE for multiclass gene selection on DNA microarray data", *Vol. 23(9)*, pp 1106–1114, 2007.
- [40] Parimala R., R. Nallaswamy, "Classification of Spam Data Using SVM-RFE", *Advances in Computational Sciences and Technology*, Vol. 3(1), pp. 67–76, 2010.
- [41] Masotti, M. "Exploring ranklets performances in mammographic mass classification using recursive feature elimination", In: *Proceedings of the 16th IEEE International Workshop on Machine Learning for Signal Processing*, pp. 265–270, 2006.
- [42] Youn E.S. "Feature selection and discriminant analysis in data mining", *Phd thesis*, pp. 24-25, 2004.
- [43] Liu Q.A. Sung, Z. Chen, J. Xu, "Feature mining and pattern classification for steganalysis of LSB matching steganography in grayscale images", *Pattern Recognition*, Vol. 41(1), pp. 56-66, 2008.
- [44] Kohavi R. "A study of cross-validation and bootstrap for accuracy estimation and model selection", In: C.S. Mellish, Editor, *Proceedings IJCAI-95Montreal*, pp. 1137–1143, 1995.
- [45] Efron B., G. Gong. "A leisure look at the bootstrap, the jackknife and cross-validation", *The American Statistician*, Vol. 37(1) pp. 36–48, 1983.
- [46] Molinaro A.M., R. Simon, R.M. Pfeiffer. "Prediction error estimation: a comparison of resampling methods", *Bioinformatics*, Vol. 21 pp. 3301-3307, 2005.
- [47] Chang C., C. Lin. "LIBSVM: a library for support vector machines", 2001
- [48] Japkowicz N. "The Class Imbalance Problem: Significance and Strategies", In *Proceedings of the 2000 International Conference on Artificial Intelligence: Special Track on Inductive Learning*, Las Vegas, Nevada, 2000.
- [49] Wu G., E. Chang. "Class-Boundary Alignment for Imbalanced Dataset Learning" In *ICML 2003 Workshop on Learning from Imbalanced Data Sets II*, Washington, DC, 2003.

- [50] Ene M. “Neural network-based approach to discriminate healthy people from those with Parkinson's disease”, *Annals of the University of Craiova, Math. Comp. Sci. Ser.* Vol. 35, pp. 112-116, 2008.
- [51] Das R. “A comparison of multiple classification methods for diagnosis of Parkinson disease”, *Expert Systems with Applications*, Vol. 37(2), pp. 1568-1572, 2010.
- [52] Caglar M.F., Cetisli B., I.B. Toprak, “Automatic recognition of Parkinson’s disease from sustained phonation tests using ANN and Adaptive Neuro-Fuzzy Classifier”, *SDU Journal of Engineering and Design*, vol. 1(2), pp. 59-64, 2010.
- [53] Polat K. “Classification of Parkinson’s disease using feature weighting method on the basis of fuzzy C-means clustering”, *International Journal of Systems Science*, Vol. 43(4), pp. 597–609, April 2012.
- [54] Luukka P. “Feature selection using fuzzy entropy measures with similarity classifier”, *Expert Systems with Applications*, Vol. 38, pp. 4600-4007, 2011.
- [55] Kihel B. K., Mohamed Benyettou “Parkinson’s Disease Recognition Using Artificial Immune System”, *Journal of Software Engineering and Applications*, Vol. 4, pp. 391-395, 2011.