

A study on Parkinson's Disease Diagnosis Using Probabilistic Neural Network

M. Serdar Başçıl, Onursal Çetin, Orhan Er, Feyzullah Temurtaş

Bozok University, Department of Electrical and Electronics Engineering, 66200 Yozgat, TURKEY

Abstract: Parkinson s disease (PD) is a neurological illness. It occurs when nerve cells in a part of the brain called the “*substantia nigra*” die or become impaired. These cells are responsible for producing a chemical known as dopamine, which allows messages to be sent to the parts of the brain that coordinate movements. By means of the depletion of dopamine-producing cells, these parts of the brain are unable to function normally. PD affects human movements such as walking, talking, and writing negatively. It is one of the most common movement disorders all around the world and usually affects people over the age of 50. In this study, the probabilistic neural network which was used for Parkinson's disease diagnosis and results of the study were compared with the results of the previous studies reported focusing on Parkinson's disease diagnosis and using same dataset. We obtained the classification accuracy with probabilistic neural network 95%. Probabilistic neural network provide the highest classification accuracy so far and the classification accuracy was obtained via 10-fold cross validation.

Keywords: Parkinson's disease diagnosis, probabilistic neural network, random search method, 10-fold cross validation

Olasılıksal Sinir Ağının(PNN) Parkinson Hastalığının Teşhisinde Kullanılması

Özet: Parkinson hastalığı(PD) nörolojik bir hastalık olup beynin “*substantia nigra*” adı verilen kısmındaki sinir hücrelerinin ölmesi yada hasar görmesi sonucunda oluşur. Bu hücreler, dopamin olarak bilinen ve kişinin hareketlerini koordine eden kimyasal maddenin üretilmesinden sorumludur. Dopamin üreten bu hücrelerin zarar görmesi durumunda, beyin normal fonksiyonlarını yerine getiremez. PD, konuşma, yürüme ve yazma gibi insan hareketlerini olumsuz olarak etkiler. Bu hastalık dünyada en sık görülen hareket bozukluklarından biridir ve genellikle 50 yaş üstü insanları etkiler. Bu çalışmada, PD'nin teşhisi için olasılıksal sinir ağı (Probabilistic Neural Network-PNN) kullanılmıştır. Elde edilen sonuçlar, PD teşhisi üzerinde yapılan ve aynı veri setini kullanan daha önceki çalışma sonuçları ile kıyaslanmıştır. PNN ile yapılan bu çalışmada %95 oranında sınıflandırma doğruluğuna ulaşılmıştır. Şu ana kadar yapılan çalışmalar içerisinde en yüksek sonuca ulaşılmış ve sınıflandırma doğruluğu, rastgele arama(Random Search Method-RSM) ile 10 katlı çapraz doğrulama(10-fold cross validation) yöntemleri kullanılarak elde edilmiştir.

Anahtar Kelimeler: Parkinson hastalık teşhisi, olasılıksal sinir ağı (PNN), rastgele arama yöntemi, 10 katlı çapraz doğrulama yöntemi.

1 Giriş

Parkinson hastalığı(PD), yürüme, konuşma ve yazma gibi hareketleri etkileyen ilerleyici nörolojik bir hastalıktır. Substantia nigra adı verilen beyindeki sinir hücrelerinin kaybı sonucunda ortaya çıkmaktadır. Bu hücreler, beyinden vücudun belirli kısımlarına gönderilen ve vücut hareketlerini düzenleyen dopamine hormonunun üretilmesinden sorumludur. Dopamin üreten bu hücrelerin azalması ya da hasar görmesi sonucunda, beynin bu kısmı normal fonksiyonlarını yerine getiremeyecek duruma gelmektedir. Özel bir durum olarak hastalığı ilk tespit eden Dr. James Parkinson (1755-1824) dur. Hastalığın kliniksel özelliklerini 1817'de kendi ismini taşıyan “An essay on shaking palsy - sallanma felci üzerine bir çalışma” isimli yazısı ile tanımlamıştır. Daha sonra, PD, substantia nigra içindeki Lewy cisminin histopatolojik bulgusu ve dopaminerjik nigrostriatal nöronların dejenerasyonu ile ilişkilendirilmiştir[1,2].

*Corresponding author; Tel.: +(90) 543 431 16 54 , E-mail:serdar.bascil@bozok.eud.tr

Bu hastalık esas olarak istemli bir hareket bozukluğudur. Görülebilen diğer semptomları, kademeli ses incilmesi ve boyama, temizlik gibi hızlı değişim gerektiren hareketlerde kolların kullanım zorluğudur. Aynı zamanda, PD hastalarının %70'inde istirahat halindeyken, örneğin otururken veya televizyon izlerken kol ve bacaklarda bir titreme mevcuttur [2].

PD'nin teşhisi genellikle kişinin tıbbi geçmişi ve kliniksel muayenesine bağlıdır. Belirtileri farklı sebeplerden kaynaklanıyor olabilir. Teşhis edilmesi kolay değildir ve kişinin bu duruma sahip olup olmadığını kanıtlayabilecek özel bir test bulunmamaktadır [1]. Ayrıca, bu hastalığa karşı etkili tedavi ve ilaç kullanımı bu güne kadar tam olarak sağlanamamıştır. Hastalığın sebebi olarak, beyin aktivitelerinde çok önemli bir rol üstlenen dopamin hormonunun yetersizliği kabul edilmektedir. Açıkçası bu durumun temel nedeni, nörologların gösterdiği çabalara rağmen insan beyninin fonksiyonel mekanizmasının tam anlamıyla bilinmiyor olmasından ileri gelmektedir. Ancak, PD ile ilgili araştırmalar ve klinik sonuçlarında, bu durumu tanımlamak için bilgisayar teknolojilerinden yeteri kadar istifade edilmediği görülmektedir [3]. Bu sebepten, sağlıklı ve PD hastası olan insanlardan elde edilen veriler kullanılarak, bu hastalığın tanısı ve sınıflandırılması amacıyla, çalışma içerisinde PNN yapısından faydalanılmıştır.

Bu amaçla, Colorado'daki National Centre for Voice and Speech (Ulusal Ses ve Konuşma Merkezi) ile işbirliği içinde olan Oxford Üniversitesi'nden Max Little tarafından kaydedilen veri setinden yararlanılmıştır [4]. Rastgele arama ve 10 katlı çapraz doğrulama(10-fold cross-validation) yöntemleri, PNN'nin doğruluğunu hesaplamak için kullanılmıştır. Elde edilen sonuçlar, PD'nin teşhisi üzerine odaklanan ve aynı veri setini kullanan önceki çalışma sonuçları [5,6] ile kıyaslanmıştır. Dolayısıyla bu çalışma ile hastalık teşhisinde doktorlar için yardımcı olabilecek, makine öğrenmesi tabanlı bir karar destek sistemi sağlanması amaçlanmıştır.

2 Yöntem

2.1 Veri Seti

Bu çalışmada, Max Little tarafından oluşturulan PD veri seti kullanılmıştır [4]. Bu veri seti, 22'si PD hastası olan 31 kişiden elde edilen biyomedikal ses ölçüm dizilerinden oluşmaktadır. Veri setindeki temel amaç, sağlıklı kişileri PD hastası olanlardan ayırabilmektir. Hasta olan kişiler 1, sağlıklı olanlar ise 0 olarak işaretlemiştir.

Bu veri seti ölçümleri **197** örnekten oluşmakta olup her bir örnek **23** belirleyici özellik içermektedir. Bu belirleyici özellikler aşağıdaki görüldüğü gibi sıralanmıştır.

- | | | |
|-----------------------|---|-------------------|
| 1. MDVP:Fo(Hz), | 2. MDVP:Fhi(Hz), | 3. MDVP:Flo(Hz), |
| 4. MDVP:Jitter(%), | 5. MDVP:Jitter(Abs), | 6. MDVP:RAP, |
| 7. MDVP:PPQ, | 8. Jitter:DDP, | 9. MDVP:Shimmer, |
| 10. MDVP:Shimmer(dB), | 11. Shimmer:APQ3, | 12. Shimmer:APQ5, |
| 13. MDVP:APQ, | 14. Shimmer:DDA, | 15. NHR, |
| 16. HNR, | 17. RPDE, | 18. D2, |
| 19. DFA, | 20. Spread1, | 21. Spread2, |
| 22. PPE, | 23. Status (1 - Parkinson, 0 - Sağlıklı). | |

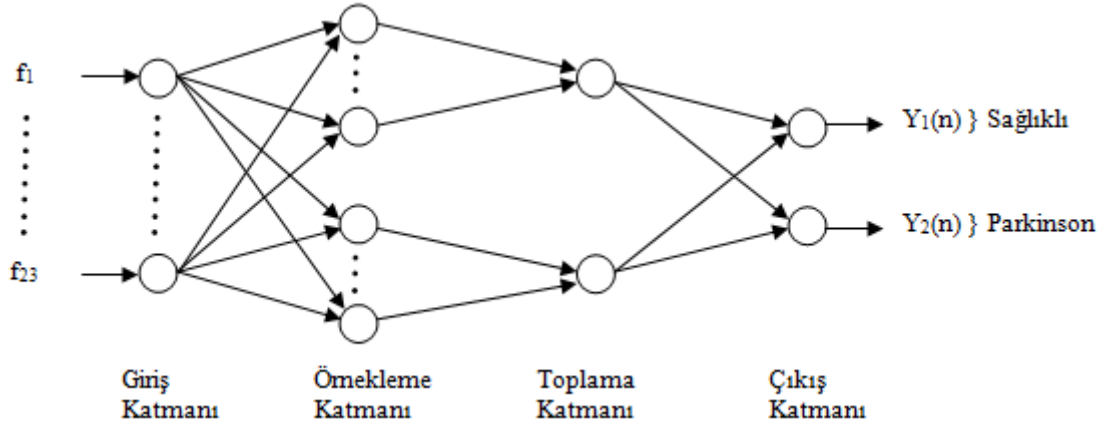
2.2. Literatür İncelemesi

PD hastalığının teşhisi için literatürde çeşitli kliniksel tanılar ve sınıflandırma sistemleri uygulanmıştır. Bunlardan bazıları; L.S. Stephen ve J. Timmis protein/substrat bağlayıcı için enzim genetik programlama (EGP) ve yapay sinir ağları kullanarak yenilikçi bir algoritma geliştirmişlerdir [7], D. Berg, PD hastalığının teşhisi için ultrasonik ses dalgalarını kullanmıştır [8], E. Tolosa ve arkadaşları, PD hastalığı hakkında yanlış bilinen nedenleri araştırarak kliniksel teşhis için bazı testler düzenlemişlerdir [9], H.W. Berendse ve M.M. Ponsen, premotor safhasındaki PD hastalarının teşhisinde koku testi ile dopamin taşıyıcılarının(DAT) görüntülenmesinde kullanılan SPECT yönteminin birleştirilmesi üzerine bir çalışma gerçekleştirmiştir [10], B.Kh. Baziyan ve çalışma grubu, hastalığın erken teşhis edilebilmesi için göz, baş ve el hareketlerinin analizi üzerinde çalışmışlardır [11], A. Jobbagy ve arkadaşları, hastalığın teşhisi için çevre üzerinde etkili olan bir ölçüm sistemi tanımlamışlar [11] ve bundan iki yıl sonra da E. H. Furnee ile birlikte hastalığın erken teşhisi için otomatik hareket değerlendirme tekniği üzerine çalışmışlardır [13], L. Cunningham ve grubu, PD hastası olan 10 kişi ile hastalık taşımayan 10 gönüllü kontrol grubu üzerinde çalışarak bilgisayar tabanlı bir değerlendirme sistemi oluşturmuşlardır [14], R.D. Jones ve arkadaşları, PD hastalığı için izleme performansı ve uygulamalarından, visuoperceptual bileşenleri uzaklaştırmak için bir teknik uygulamışlardır [15], S. Patel ve arkadaşları, PD bulunan hastalarda komplikasyon ve çeşitli semptomları değerlendirebilmek için ivme verileri kullanan pilot bir çalışma oluşturmuşlardır [16], D. Wu ve grubu, beyin elektrotlarını PD hastalarının beynine yerleştirmiş ve doğru bir şekilde titreme başlangıcını önceden kestirebilmek için RBFNN sinir ağı yapısını kullanmışlardır [17], K. Revett ve arkadaşları, hem PD hastası hem de sağlıklı kişilerden kliniksel çalışmalar yoluyla alınan konuşma sinyallerini birleştirerek bu kişilerden bir yada daha fazlasının PD hastası olup olmadığını araştırmışlardır [18], R. Das, hastalığın etkili bir şekilde teşhis edilebilmesi için çeşitli sınıflandırma yöntemleri uygulamış [5] ve M. Ene'de sağlıklı kişiler ile PD hastası olan kişiler arasındaki ayrımı baz alan olasılıksal sinir ağı (PNN) alt yapısından yararlanmıştır [6].

Görüldüğü gibi sınıflandırma sistemleri diğer kliniksel teşhis problemlerinde olduğu gibi PD teşhisi içinde kullanılabilir. Bu çalışmada da PD'nin teşhisi için olasılıksal sinir ağı (PNN) kullanılmış ve önceki çalışmalarda kullanılan aynı veri seti [4] ile daha yüksek bir sınıflandırma doğruluğu elde edilmiştir.

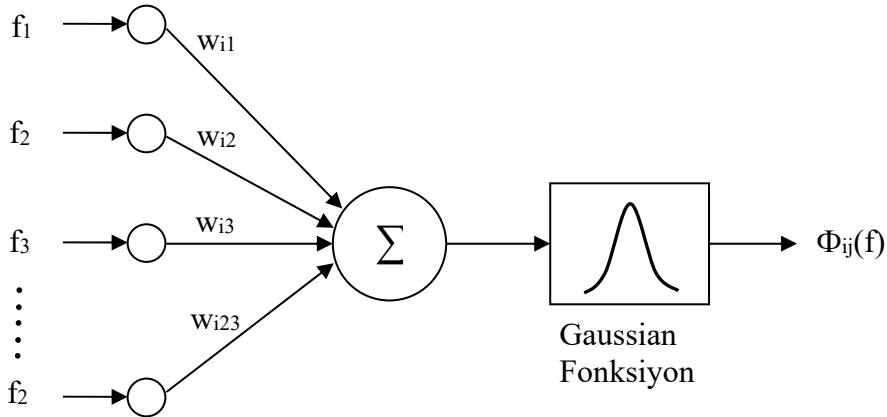
2.3. Olasılıksal Sinir Ağı (PNN) ile Parkinson Hastalığının Teşhis Edilmesi

Olasılıksal sinir ağı (PNN), Donald Specht tarafından geliştirilen olasılık yoğunluk tahmininin (probability density estimation-PDF) bir ağ formülasyonudur[19]. Kazanan hepsini alır mantığına dayalı rekabetçi öğrenme üzerine kurulu bir modeldir. İstatistik bilimi tarafından Bayesian sınıflandırıcısı olarak adlandırılan bir yaklaşım kullanarak sınıflandırma problemleri için genel bir çözüm sağlar. PNN ağında genellikle, Bayes teorisinde gerekli olan PDF yapısını geliştiren Parzen Yaklaşımı (Parzen Estimation) kullanılır. Bu ağın genel yapısı Şekil 1'de görüldüğü gibidir.



Şekil-1 PNN Yapısı

Görüldüğü gibi bu çalışmada giriş, örnekleme, toplama ve çıkış katmanlarını içeren PNN ağ yapısı kullanılmıştır [19-23]. Giriş katmanı herhangi bir hesaplama yapmayıp, sadece tüm örneklerin giriş değerlerini sonraki katmana dağıtmaktadır. Örnekleme katmanındaki tüm nöronlar, eş zamanlı olarak veri setinden gelen 23 boyutlu gerçek giriş değerlerini alır. Radyal temelli ağırlık fonksiyonları bu katmanda bulunmaktadır. Kullanılan bütün radyal temelli ağırlık fonksiyonları aynı tiptedir (Gaussian). Şekil 2, örnekleme katmanını ve giriş örneklerinin sınıflandırılmasını göstermektedir.



Şekil-2 Örnekleme Katmanının Yapısı

Giriş katmanından gelen f örneklerine göre örnekleme katmanındaki f_{ij} nöronlarının çıkışı aşağıdaki gibi hesaplanır.


$$\phi_{ij}(f) = \frac{1}{(2\pi)^{d/2} \sigma^d} \exp \left[-\frac{(f - f_{ij})^T (f - f_{ij})}{2\sigma^2} \right] \quad (1)$$

Burada; d örnekleme vektörünün boyutu, f_{ij} nöron vektörü ve σ , Gaussian fonksiyonunun hassasiyetini kontrol eden düzeltme faktörüdür. Toplama katmanı nöronları da, aşağıda görülen formülasyon doğrultusunda örnekleme katmanından gelen girişleri toplamaktadır.

$$p_{ij}(f) = \frac{1}{(2\pi)^{d/2} \sigma^d} \frac{1}{m} \sum_{j=1}^m \exp \left[-\frac{(f - f_{ij})^T (f - f_{ij})}{2\sigma^2} \right] \quad (2)$$

Burada, m toplam örnek sayısını göstermektedir.

PNN ağının çıkış katmanındaki formülasyonu ise, kazanan hepsini alır mantığına dayalı rekabetçi bir algoritma üzerine kurulmuştur [24]. Bu katman iki giriş nöronuna sahiptir ve Şekil 3'te görüldüğü gibi dijital bir çıkış üretir.



Şekil-3 Çıkış Katmanının Yapısı

PNN ağı, sınıflandırma problemleri için uygun olan radyal temelli bir ağ çeşididir. Bu yapıda denetimli öğrenme mantığı kullanılır ve veriler eğitim ve test olmak üzere iki kısma ayrılmıştır. Ağın performansı, eğitim prosedürü ve geri çağırma prosedürleri ile ilişkilidir.

Eğitim prosedürün de, eğitim verileri ağa verilir ve örnekleme katmanı aracılığıyla giriş katmanından çıkış katmanına doğru geçer. PNN ağı, bu eğitim verilerini giriş ve örnekleme katmanı arasındaki ağırlıkları (W_i) belirlemek için aşağıda formüle edildiği gibi belirler.

$$w_{ij} = a_j \quad (3)$$

$$A_j = [a_1, a_2, a_3, \dots, a_k] = W^i = [w_{ij}]_{ixj} \quad i = 1, 2, 3, \dots, p$$

Burada w_{ij}, W_i ağırlıklarının j nci ağırlık değeridir. Sonrasında ağ, örnekleme katmanı ile çıkış katmanı arasındaki ağırlıkları (W_o) aşağıdaki formüle göre şekillendirir.

$$w_{jc} = \begin{cases} 1, & j \text{ nci örnek ve nöron aynı sınıfa ait ise,} \\ 0, & \text{diğer} \end{cases} \quad (4)$$

j nci örnek, c sınıfı ile ilişkili ise (c=1,2,3,...,r) ağırlık değeri 1 olacaktır, aksi durumlarda ise 0 (sıfır) değerini alacaktır.

Geri çağırma prosedüründe, ağa test verileri girilir ve giriş ile örnekleme katmanı arasındaki ağırlıklar, eğitim ve test datasına bağlı olarak Öklit(Euclidean) normu (Ed_j) şeklinde hesaplanır. Bu öklit normu şu şekilde formülize edilmektedir.

$$Ed_j = \sqrt{\sum (w_{ij} - f_i)^2} \quad (5)$$

Burada, w ağırlık vektörü ve f giriş vektörüdür. Örnekleme birimleri olasılıksal vektörleri üretir ve her bir durumun olasılığı hesapladıktan sonra, W_o ağırlığı bu olasılıkları toplama katmanına taşır. Toplama katmanı nöronları, örnekleme katmanından gelen girişleri toplar ve çıkış katmanına aktarır. Çıkış katmanı da, çıkıştaki her bir durumun olasılık yoğunluğunu

karşılaştırmak için “kazanan hepsini alır” tutumunu kullanır. Oluşturduğumuz ağ modelinde kullanılan denklemler (1) ve (2) de verildiği gibidir.

2.4. Performans Değerlendirmesi

2.4.1. Sınıflandırma Doğruluğu

Sınıflandırma doğruluğu [25], PD hastalığının teşhisinde aynı veri setini kullanan çalışmaların[5,6] karşılaştırılması için kullanılmıştır. Yani bu çalışmada elde edilen sonuçlar, önceki çalışmaların sonuçları ile sınıflandırma doğruluğu kullanılarak karşılaştırılmıştır.

Sınıflandırma doğruluğu için kullanılan denklemler (6) ve (7) de verildiği gibidir.

$$classification\ accuracy(N) = \frac{\sum_{i=1}^{|N|} assess(n_i)}{|N|}, \quad n_i \in N \quad (6)$$

$$assess(n) = \begin{cases} 1 & \text{if } classify(n) = nc \\ 0 & \text{otherwise} \end{cases} \quad (7)$$

Burada; N, sınıflandırılan veri öğeleri setini (test set), $n \in N$, nc de n değerinin sınıfını ve $classify(n)$ de n 'nin ağ tarafından belirlenen sınıflandırma sonucunu temsil etmektedir

2.4.2. Tahmin Değerlerinin Doğrulama Yöntemi

Çalışma içerisinde PNN ağının doğruluğunu hesaplamak amacıyla, 10 katlı çapraz doğrulama (10-fold cross-validation) tekniği kullanılmıştır. k-kat çapraz doğrulama tekniğinde [20,21,23,26,27], tüm veri seti rastgele bir birini dışlayan farklı ve hemen hemen eşit büyüklükteki k kadar alt kümeye ayrılır. Sınıflandırma algoritması k-kez eğitilir ve test edilir. Her defasında kümelerden biri test verisi olarak alınır ve geri kalan küme verileri eğitim için kullanılır. Böylece, her eğitim-test yapılandırması için k-farklı test sonucu elde edilir[28,29]. Bu sonuçların ortalaması algoritmanın test doğruluğu olmaktadır. Eğer sinir ağı probleme yönelik eğitim setini öğrenmişse, sonuç için genelleme yapacaktır. Yani, bu şekilde eğitilmiş bir ağ eğitimsiz test verileri için bile aynı sonuçları verebilir. Ayrıca sinir ağı eğitim setini ezberlerse, genellemesi düşmeye başlar ve eğitimsiz test setleri için bile ağın performansı geliştirilemez [29]. k-kat çapraz doğrulama tekniği, sinir ağı yapılarının nasıl iyi bir genelleme yapabileceğini göstermektedir [30].

3. Sonuçlar

Aynı PD hastalığı verilerini kullanan çalışmalar ve bu çalışma tarafından elde edilen sınıflandırma doğrulukları Tablo 1’de görüldüğü gibidir.

Tablo-1 PD hastalığının teşhisi için yapılan çalışmalar, kullanılan yöntemler ve erişilen sınıflandırma doğrulukları

Çalışmalar	Uygulanan Yöntemler	Sınıflandırma Doğrulukları (%)
M. Ene (2008)	PNN(TV, IS)	79.78
	PNN(TV, MCS)	80.92
	PNN(TV, HS)	81.28

R. Das (2009)	Neural Network (TV, LM)	92.90
	DMNeural(TV)	84.30
	Regression(TV)	88.60
	Decision tree(TV)	84.30
Bu çalışma	PNN(TV)	89.14
	PNN (10xFC, RSM)	95.00

Tablo 1’den görüldüğü gibi M. Ene, sınıflandırma sürecinde düzeltme faktörüne bağlı olarak geleneksel doğrulama (traditional validation-TV) yöntemi dahilinde, artımlı arama (incremental search-IS), Monte Carlo arama (Monte Carlo search-MCS) ve karma arama (hybrid search-HS) gibi 3 farklı yöntemi PNN ile birleştirmiştir. Geleneksel doğrulama yöntemi kullandığı için veri setini eğitim ve test olarak ikiye ayırmış ve verilerin %70’ini eğitim için geri kalan %30’luk kısmında test için kullanmıştır. Sonuç olarak %79 ile %81 arasında değişen sınıflandırma doğrulukları elde etmiştir.

R. Daş, PD hastalığının teşhisi için SAS tabanlı bir yazılım kullanmıştır. Tablo 1’de görüldüğü gibi dört farklı sınıflandırıcı seçmiştir. Veri seti, rasgele eğitim ve test setlerine ayrılmıştır. Verinin %65’lik kısmı eğitim için geri kalan kısmı da test için kullanılmıştır. Ayrıca, her sınıflandırıcının belirleyici parametreleri M. Ene’nin sisteminde kullandığı gibi TV yöntemi kullanılarak belirlenmiştir. Sinir ağını (Neural Network-NN), geri yayımlı öğrenme algoritması üzerine kurmuş ve tek gizli katmanlı sinir ağı yapısını, Levenberg–Marquardt (LM) algoritması ile birleştirmiştir. Başlangıç ağırlıkları rastgele seçilmiştir. Regresyon yönteminde lojik yayımdan faydalanmıştır. Ayrıca, DMNeural and Decision tree yöntemleri için varsayılan değerleri kullanmıştır [5].

Bu çalışmada ise PNN yapısı iki kısımda uygulanmıştır. Birinci aşamada, diğer çalışmalarda olduğu gibi TV yöntemi ile veri setinin %70’lik kısmı eğitim için ayrılmış geri kalan %30’luk kısmı da test verileri olarak seçilmiştir. İkinci aşamada ise, TV yöntemi yerine, 10 katlı çapraz doğrulama tekniği kullanılmıştır. Bu tekniğin kullanılmasıyla veri seti el ile eğitim ve test olmak üzere iki ayrı kısma ayrılmamıştır. Çünkü, 10 katlı çapraz doğrulama tekniği bu işlemin programsal olarak yapılmasını sağlamaktadır. Ayrıca, ağı düzeltme faktörü de uygun olan aralıklar içinde programsal olarak rastgele tek tek(Random Search Method-RSM) taranmıştır.

Tablo 1’den görüldüğü üzere, geleneksel doğrulama yöntemleri içerisinde en iyi performans, LM algoritması ile birleştirilmiş sinir ağı yapısını kullanan R.Daş tarafından elde edilmiştir. Sonraki en yüksek sınıflandırma doğruluğuna PNN kullanan bu çalışma ile ulaşılmış ve Regresyon yöntemine yakın bir sonuç elde edilmiştir. M.Ene’nin elde ettiği doğruluk değerleri bu ve R.Daş’ın sonuçlarından oldukça geride kalmıştır. Tablo 1’in geneline bakıldığında, 10 katlı çapraz doğrulama tekniğini ve rasgele arama yöntemini kullandığımız PNN ağ yapısının şu ana kadarki çalışmalar içerisinde en iyi sınıflandırma doğruluğuna (%95) ulaştığı açıkça görülmektedir.

4. Değerlendirme ve Öneriler

PD hastalığının teşhisine yönelik farklı sınıflandırma teknikleri kullanılan birkaç çalışmanın varolduğu görülmektedir. Bu çalışmalarda, aynı veri setini kullanan farklı sinir ağı yapıları uygulanmıştır. Çalışmalarda aynı veri setinin kullanılması, elde edilen sınıflandırma sonuçlarının doğru bir şekilde kıyaslanabilmesini mümkün kılmaktadır. Yani, 23 farklı belirleyici özelliğe sahip olan veri setini kullanan sinir ağlarının başarımlarını karşılaştırılabilmektedir.

Elde edilen sonuçlar özetlenecek olursa:

- PD hastalığının teşhisinde kullanılan tüm sinir ağı yapıları başarılı olmuştur,
- En iyi sınıflandırma doğruluğu, rastgele arama yöntemini kullanan PNN ağ yapısıdır,
- Rastgele arama yöntemi, geleneksel doğrulama yönteminden daha başarılı bir sonuç sağlamaktadır,
- k-katlı çapraz doğrulama yöntemi sınıflandırma doğruluklarının ortalamasını aldığından daha verimli bir sonuç sağlamaktadır.

Sonuç olarak bu çalışma ile elde edilen yapı, PD hastalığının teşhisi için bir karar destek sistemi sağlayabilmesi açısından, doktorlara kendi kararlarında yardımcı olabilecektir.

References (Referanslar)

1. Parkinson's UK, <http://www.parkinsons.org.uk/about-parkinsons/what-is-parkinsons.aspx> (son erişim tarihi: 30 Temmuz 2012)
2. L. Nhaeed and T. Britton, Parkinson's Disease-clinical features, pathophysiology and genetics, Hospital Pharmacist, Vol.11, No.1, (2004), 9-14.
3. S. Date, S., T. Tashiro, K. Nozaki, H. Nakamura, S. Sakoda, S. Shimojo, A Grid-ready clinical database for Parkinson's disease research and diagnosis, Twentieth IEEE International Symposium on Computer-Based Medical Systems (CBMS'07), Maribor, Slovenia, (2007), 483-488.
4. M. A. Little, P. E. McSharry, E. J. Hunter, J. Spielman, L. O. Ramig, Suitability of dysphonia measurements for telemonitoring of Parkinson's disease, IEEE Transactions on Biomedical Engineering, Vol.56, No.4, (2009), 1015-1022.
5. R. Das, A comparison of multiple classification methods for diagnosis of Parkinson disease, Expert System with Applications, Vol.37, No.2, (2010), 1568-1572.
6. M. Ene, 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, (2008), 112-116.
7. L. S. Stephen, J. Timmis, An immune network inspired evolutionary algorithm for the diagnosis of Parkinson's disease, BioSystems, Vol.94, No.1-2, (2008), 34-46.
8. D. Berg, Ultrasound in the (premotor) diagnosis of Parkinson's disease, Parkinsonism & Related Disorders, Vol.13, No.3, (2007), 429-433.
9. E. Tolosa, G. Wenning, W. Poewe, The diagnosis of Parkinson's disease, The Lancet Neurology, Vol.5, (2006), 75-86.
10. H. W. Berendse, M. M. Ponsen, Diagnosing premotor Parkinson's disease using a two-step approach combining olfactory testing and DAT SPECT imaging, Parkinsonism & Related Disorders, Vol.15, No.3, (2009), 26-30.

11. B. Kh. Baziyan, L. A. Chigaleichik, E. L. Teslenko, D. R. Lachinova, Analysis of trajectories of eye, head, and hand movements for early diagnosis of Parkinson's disease, *Bulletin of Experimental Biology and Medicine*, Vol.143, No.5, (2007), 553-555.
12. A. Jobbagy, E. H. Furnee, P. Harcos, M. Tarczy, Early detection of Parkinson's disease through automatic movement evaluation, *IEEE Engineering in Medicine and Biology Magazine*, Vol.17, No.2, (1998), 81-88.
13. A. Jobbagy, L. Komjathi, E. H. Furnee, P. Harcos, P., Movement Analysis of Parkinsonians, *Proceedings of Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, Vol.2, No.2, (2000), 821-824.
14. L. Cunningham, C. Nugent, G. Moore, D. Finlay, D. Craig, Identifying fine movement difficulties in Parkinson's disease using a computer assessment tool, *Proceedings of the 9th International Conference on Information Technology and Applications in Biomedicine-ITAB 2009*, Larnaca, Cyprus, (2009), 1-4.
15. R. D. Jones, I. M. Donaldson, N. B. Sharman, A technique for removal of the visuoperceptual component from tracking performance and its application to Parkinson's disease, *IEEE Transactions on Biomedical Engineering*, Vol.43, No.10, (1996), 1001-1010.
16. S. Patel, K. Lorincz, R. Hughes, N. Huggins, J. Growdon, D. Standaert, M. Akay, J. Dy, M. Welsh, P. Bonato, Monitoring motor fluctuations in patients with Parkinson's disease using wearable sensors, *IEEE Transactions on Information Technology in Biomedicine*, Vol.13, No.6, (2009), 864-873,.
17. D. Wu, K. Warwick, Z. Ma, J. G. Burgess, S. Pan, T. Z. Aziz, Prediction of Parkinson's disease tremor onset using radial basis function neural networks, *Expert Systems with Applications*, Vol.37, No.4, (2010), 2923-2928.
18. K. Revett, F. Gorunescu, A. B. M. Salem, Feature selection in Parkinson's disease: A rough sets approach, *Proceeding of the International Multiconference on Computer Science and Information Technology*, (2009), 425-428.
19. D. F. Specht, Probabilistic neural networks, *Neural Networks*, Vol.3, (1990), 109-118.
20. A. Gulbag, F. Temurtas, I. Yusubov, Quantitative discrimination of the binary gas mixtures using a combinational structure of the probabilistic and multilayer neural networks, *Sens. Actuators B: Chem.*, Vol.131, (2007), 196-204.
21. F. Temurtas, A comparative study on thyroid disease diagnosis using neural networks, *Expert Systems with Applications*, Vol.36, No.1, (2009), 944-949.
22. O. Er, C. Sertkaya, F. Temurtas, A. C. Tanrikulu, A comparative study on chronic obstructive pulmonary and pneumonia diseases diagnosis using neural networks and artificial immune system, *Journal of Medical Systems*, Vol.33, No.66, (2009), 485-492.
23. H. Temurtas, N. Yumusak, F. Temurtas, A comparative study on diabetes disease diagnosis using neural networks, *Expert Systems with Applications*, Vol.36, No.4, (2009), 8610-8615.

24. J. D. Wu, P. H. Chiang, Y. W. Chang, Y. J. Shiao, An expert system for fault diagnosis in internal combustion engines using probability neural network, *Expert Systems with Applications*, Vol.34, No.4, (2008), 2704-2713.
25. A. Watkins, AIRS: A resource limited artificial immune classifier, Master Thesis, Mississippi State University, 2001.
26. M. S. Bascil, F. Temurtas, A study on hepatitis disease diagnosis using multilayer neural network with levenberg marquardt training algorithm, *Journal of Medical Systems*, Vol.35, No.3, (2011), 433-436.
27. U. M. Fayyad, G. Piatetsky-Shapiro, P. Smyth, R. G. R. Uthurusamy, *Advances in knowledge discovery and data mining*, The MIT Press, Menlo Park, 1996.
28. D. Delen, G. Walker, A. Kadam, Predicting breast cancer survivability: A comparison of three data mining methods, *Artificial Intelligence in Medicine*, Vol.34, No.2, (2005), 113–127,.
29. M. S. Bascil, H. Oztekin, A Study on Hepatitis Disease Diagnosis Using Probabilistic Neural Network, *Journal of Medical Systems*, Vol.36, No.3, (2012), 1603-1606.
30. A. Gulbag, F. Temurtas, A study on quantitative classification of binary gas mixture using neural networks and adaptive neuro fuzzy inference systems, *Sensors and Actuators B*, Vol. 115, No.1, (2006), 252–262.