



MAKÜ FEBED  
ISSN Online: 1309-2243  
<http://dergipark.ulakbim.gov.tr/makufebed>

Mehmet Akif Ersoy Üniversitesi Fen Bilimleri Enstitüsü Dergisi 6(2): 82-88 (2015)  
*The Journal of Graduate School of Natural and Applied Sciences of Mehmet Akif Ersoy University 6(2): 82-88 (2015)*

**Araştırma Makalesi / Research Paper**

## **Kronik Böbrek Hastalarının Yapay Sinir Ağı ve Radyal Temelli Fonksiyon Ağı ile Teşhisi**

Muhammer İLKUÇAR\*

Mehmet Akif Ersoy Üniversitesi Teknik Bilimler Meslek Yüksekokulu, Burdur

*Geliş Tarihi (Received): 12.12.2015, Kabul Tarihi (Accepted): 31.12.2015*

✉ *Sorumlu Yazar (Corresponding author)\*: [imuammer@mehmetakif.edu.tr](mailto:imuammer@mehmetakif.edu.tr)*

☎ +90 248 2134552 📠 +90 248 2134598

---

### **ÖZ**

Teknolojideki gelişmelerin tıp alanına uygulanması ile sağlık çalışanlarına ve hastalara büyük kolaylıklar sağlamıştır. Sağlık birimlerinde hastaya ait kişisel bilgilerin yanında laboratuvar sonuçları, tanı, teşhis tedavi gibi bilgiler de elektronik olarak kaydedilmektedir. Bu veriler, modern tekniklerle analiz edilerek, hekim ve yöneticilerin hizmetine sunulmalıdır. Yapılan çalışmada, hastaların laboratuvar sonuçları ve kişisel bilgilerine göre kronik böbrek hastası olup olmadığı tespiti yapılmıştır. Bunun için 400 hastanın laboratuvar sonuçlarından elde edilen 24 niteliğe sahip veriler geri yayımlı yapay sinir ağı (YSA) ve radyal temelli fonksiyon ağı (RBFN) ile sınıflandırılarak karşılaştırılmıştır. Sınıflandırma sonucunda YSA ve RBFN performans değerleri sırasıyla 0,0172 ve 1.47585e-27 elde edilmiştir. YSA ile RBFN karşılaştırıldığında ise RBFN daha iyi bir performans göstermiştir.

**Anahtar Kelimeler:** Kronik böbrek hastalığı, sınıflandırma, teşhis, RBFN, YSA

### **Diagnosis Chronic Kidney Disesa with Artificial Neural Network and Radial Basis Function Network**

#### **ABSTRACT**

Health care workers and patients have gained great convenience with the implementation of technological developments in the field of medicine. Besides the personal information of the patient, diagnostic information such as laboratory results and treatments are started to save electronically in health care units in recent decades. The stored data is analyzed with modern techniques and then served to the doctors and managers. In this study, it was carried out that whether the patients are chronic kidney disease or not, according to laboratory results and their personal information. The data obtained from laboratory results of 400 patients which has 24 attributes is classified with artificial neural network (ANN) and radial basis function network (RBFN). Finally, ANN and RBFN classification results performance values are respectively 0.0172 and 1.47585e-27 accurate rates. RBFN results compared with ANN results, RBFN results have a better performance.

**Keywords:** Chronic kidney disease, classification, diagnosis, RBFN, YSA

---

## GİRİŞ

Teknolojideki ve bilişim alanındaki gelişmeler, hayatımızın her alanında olduğu gibi, sağlık sektöründe de yoğun ve etkin olarak kullanılmaktadır. Tıptaki pek çok gelişme, teknolojik gelişmelerin sağlık alanına uygulanmasına borçludur. Günümüzde sağlık birimlerinde teknoloji yoğun bir hizmet söz konusudur. Hasta ve sağlık çalışanlarının işini kolaylaştırmaya yönelik, bakım, laboratuvar, yardımcı aparatlar, teşhis, tanı, tedavi, bulgu gibi işlemler için son derece gelişmiş cihazlar kullanılmaktadır. Bunlar genellikle kendi özel yazılımı ve hafızası olan, aynı zamanda birbirleri ile haberleşebilen cihazlardır. Dolayısıyla ortak bir veri tabanı kullanılabilirler. Böylece, hastalardan elde edilmiş kişisel bilgilerin yanında hastaların tetkik, laboratuvar, teşhis, tedavi, alınan ilaçlar ve dozajları vb. verilerinden oluşan bir veri topluluğu oluşacaktır. Bu veriler modern teknikler kullanılarak analizler yapılarak yöneticilerin ve sağlık personelinin hizmetine sunulabilir. Böylece bir hekim, hastasının bilgilerinden elde edilmiş ve analiz edilerek yorumlanıp birtakım sonuçlar çıkartılmış verilere bakarak çok daha hızlı ve isabetli karar verebilme imkanına kavuşacaktır. Dolayısıyla hasta memnuniyetinin de artması beklenir. Belirli bir amaca yönelik elektronik ortamda kaydı tutulmuş, hastalara ait verilerin analiz edilmesi için çok farklı yöntem ve teknikler kullanılmaktadır. Hastaların bazı kişisel bilgileri (yaşı, kilosu, cinsiyeti, vb.) ve laboratuvar, röntgen, ultrason, MR, vb. bilgilerini kullanarak hastanın rahatsızlığına dair tanı koymaya yardımcı olabilecek pek çok çalışma mevcuttur. İkuçar ve ark. (2014) göğüsteki tümörlerin özelliklerinden tümörün iyi huylu veya kötü huylu tümör olup olmadığı sınıflandırması işlemini harmoni öğrenme tabanlı YSA ile gerçekleştirmişler. Delican ve ark. (2011) evrimsel algoritma temelli RBF ağı ile parkinson hastalığı teşhisi yapmışlardır. Rouhani ve Haghighi (2009) SVM ve YSA kullanarak hepatit hastalığı teşhisi yapmışlardır. Afif ve ark. (2013) 3SVM diye adlandırdıkları yeni bir yöntem kullanarak hepatit hastalığı teşhisi yapmışlardır. Tomar ve Agarwal (2015) melez özellik seçimi (hybrid feature selection-HFS) algoritması ile göğüs kanseri, hepatit ve diyabet hastalığı verilerini kullanarak teşhis işlemini yapmışlardır. Abhishek ve ark. (2012) YSA, RBF ve destek vektör makinaları (SVM) gibi farklı yöntemler kullanarak böbrek taşı teşhisi yaparak sonuçları karşılaştırmışlardır. Kumar ve Abhishek (2012) farklı Yapay sinir ağı algoritmaları (LVQ, RBF, iki katmanlı YSA) kullanarak böbrek taşı teşhisi yaparak sonuçları karşılaştırmışlardır. Levey ve ark. (2005) farklı böbrek işlev parametrelerine bakarak kronik böbrek hastalıkları kendi arasında sınıflandırmışlardır (hastaları kendi arasında derecelendirmişler). Tanqi ve ark. (2010) yaş, kilo gibi bilgilerin GFR, Bjornsson - equation vb. (National Kidney Foundation, 2002) fonksiyonlar yardımıyla Çin'deki kronik böbrek

hastalarının "glomerular filtration rate" oranlarını YSA ve RBFN ile çözmüşlerdir. Kronik böbrek hastalarının sınıflandırması ile ilgili literatürde çalışmaya rastlanmamıştır.

Bu çalışmada; Hindistan Apollo Hastanesinde (Soundarapandian, 2015) böbrek rahatsızlığı olan 400 hastanın kişisel bilgi ve laboratuvar sonuçlarından oluşan 24 farklı nitelik bilgisinden elde edilen veriler kullanılarak öğretilmiş RBF ve YSA ile hastanın kronik böbrek hastası olup olmadığı sınıflandırması işlemi gerçekleştirilmiştir. Hastalarla ilgili Tablo-1' de görüldüğü gibi 24 farklı nitelik ölçümü yapılmış ve bu verilere göre hastanın kronik böbrek hastası olup olmadığı teşhisi konularak kaydedilmiştir. Hastalardan elde edilen ve teşhisi konmuş bu veriler makine öğrenme ile ilgili dataların bulunduğu UCI (UCI,2015) web sayfasından alınmıştır. Kronik böbrek hastası teşhisi ile ilgili datalar ilk defa radyal tabanlı fonksiyon ağı (Radial Basis Function Network - RBFN) ve geri beslemeli yapay sinir ağı ile öğretilerek sınıflandırma işlemi gerçekleştirilmiştir.

## MATERYAL VE METOT


Problemin çözümün için, çok katmanlı ileri beslemeli geri yayımlı yapay sinir ağı (Graupe, 2013) ve radyal tabanlı fonksiyon ağı kullanılmıştır. Her iki yöntemle elde edilen sonuçlar karşılaştırılmıştır.

### Yapay Sinir Ağları

Yapay sinir ağları beyin öğrenme prensiplerine dayanılarak geliştirilmiş biyoloji temelli bir yapay zeka yöntemidir (Suzuki, 2011). Literatürde çok farklı YSA modelleri mevcuttur. Ancak sınıflandırma işlemi için çok katmanlı geri beslemeli YSA başarılı sonuçlar vermektedir. Şekil 1'de çok katmanlı ileri beslemeli geri yayımlı bir yapay sinir ağı yapısı görülmektedir. Şekle göre ağ; giriş, gizli ve çıkış katmanlarından oluşmaktadır.


Giriş katmanı; veri setinin ağa verilmesini sağlar. Bu katmanda herhangi bir hesaplama yapılmaz. Şekle göre ağın giriş veri seti nitelik değeri  $x_1, x_2, \dots, x_i$  şeklinde gösterilmiştir. Veri setinin nitelik sayısı giriş katmanın giriş sayısıdır. Çalışmada 24 nitelik bulunduğu için giriş katmanı giriş sayısı 24'dür. Gizli katman değeri birden çok olabilir. Bir ağda kaç gizli katman olacağı ile ilgili bir formül yoktur. Problemin özelliğine göre gizli katman sayısı artırılabilir. Ancak gizli katman sayısı arttıkça hesaplamaların da artacağı unutulmamalıdır. Literatürde birçok problem bir adet gizli katman ile uygun bir çözüm verebildiği görülmektedir. Ancak farklı sayıdaki gizli katman değerleri kullanılarak farklı ağ yapıları oluşturulup problem çözülerek en uygun ağ yapısı bulunmalıdır. Bir gizli katmandaki

düğüm sayısının ne olacağı ile ilgili kesin bir yöntem yoktur. Ancak başlangıç olarak; giriş veri seti nitelik sayısı, nitelik sayısının iki katı veya yarısı vb. gibi değerler verilerek farklı ağ modelleri kurulup problem çözümlenmelidir. Çıkış katmanı, ağdan elde edilen sonuçların dış ortama aktarma görevi yapar. Gizli katman ile çıkış katmanı arasında ağırlık değerleri olan birer bir bağlantılar vardır. Çıkış katmanının düğüm sayısı ise problemde elde edilecek çıktı sayısına göre değişir. Çalışmada, hastanın kronik böbrek hastası olup olmadığı ile ilgili bir sınıflandırma yapılacağından, çıkış katmanının düğüm sayısı bir adet olması yeterlidir. Tek çıkış değerinden; 1: kronik böbrek hastası; 0: hasta değil; bilgisi elde edilebilir. Giriş katmanı ile gizli katman ve gizli katman ile çıkış katmanı arasındaki düğümler (Şekil 1) birbirine bağlıdır. Her bağlantının bir ağırlık ( $w_{ij}$ ) değeri vardır. Bu ağırlık değerleri değiştirilerek ağırlık öğrenmesi sağlanır. Ağırlık öğrenmesi, daha önce hiç görmediği, bilmediği bir veri için dahi en uygun çıkışın elde edilebileceği ağırlık değerlerinin hesaplanması sürecidir. Bir YSA öğretmek için farklı algoritmalar kullanılabilir (Anthony ve Bartlett, 2009).



Şekil 1. Çok katmanlı ileri beslemeli geri yayımlı yapay sinir ağı yapısı.

Şekil 2'de YSA'nın bir düğüm yapısı görülmektedir.



Şekil 2. YSA bir düğüm yapısı.

Düğüme gelen veriler ( $x_i$ ) ile bağlantıların ağırlık ( $w_i$ ) çarpımları toplamı alınarak düğümün  $net$  değeri hesaplanır (Denklem 1). Denklemde ve şekildeki eşik (bias) değeri,  $x_i$  giriş değerlerinin 0 olması durumunda, ağırlık 0' takılıp kalmaması için (+1) değeri kadar ötelemek yapar. Eşik değeri normal bir giriş nitelik değeri gibi işleme alınır. Gizli ve çıkış katmanındaki her düğüm için bir eşik değeri olmalıdır.

$$net_k = bias + \sum_{k=0}^K x_i * w_{i,k} \quad (1)$$

Denklem 1' deki gibi her düğümün  $net$  değeri hesaplandıktan sonra düğüm çıkış değerinin [-1,1] veya [0,1] aralığında tutmak için transfer (aktivasyon) fonksiyonundan geçirilmelidir (Denklem 2). Literatürde farklı transfer fonksiyonları (Lineer, Step, Sinüs, Hiperbolik Tanjant, Sigmoid, vb.) mevcuttur. Çok katmanlı YSA' larda genel olarak sigmoid transfer fonksiyonu kullanılır (Denklem 2) (Öztemel, 2012:50-51).

$$f(net_k) = \frac{1}{1 + e^{-net}} \quad (2)$$

Denklem 1 ve 2 kullanılarak ağıdaki tüm düğümlerin çıkış değerleri hesaplanır. Çıkış katmanının düğümlerinin çıkış değeri ( $y_i$ ) ile buradan beklenen değer ( $z_i$ ) farkı hata miktarını ( $E$ ) verir (Denklem 3).

$$E_i = z_i - y_i \quad (3)$$

Beklenen değere göre oluşan hatanın ağırlıklara yansıtılması temeline dayanan öğrenmeye öğretmenli öğrenme ("supervised learning") adı verilir. Hata değerinin değerlendirilmesi ağırlık öğrenmesini, dolayısıyla ağırlık performansını belirler. Performans ölçüsü olarak farklı hesaplamalar kullanılabilir. Literatürde en yaygın olarak kullanılan performans ölçümleri; hataların karelerinin toplamı (SSE) (Denklem 4) ve hataların karelerinin toplamının ortalaması (MSE) (Denklem 5) verilmiştir. Yine ağırlık performans değeri hakkında bilgi sahibi olmak için; eğitilmiş bir ağırlık, eğitim verileri haricinde test verileri uygulanarak, bu test verilerinden ne kadarını doğru tahmin ettiği (regresyon) değerine bakılır.

$$SSE = \sum_{i=0}^n (z_i - y_i)^2 \quad (4)$$

$$MSE = \frac{1}{n} \sum_{i=0}^n (z_i - y_i)^2 \quad (5)$$

Burada önemli olan, eğitim veri setinin tümü için, minimum SSE veya MSE değerini verebilecek ağırlık değerlerinin belirlenmesidir. Bunun için hata miktarları geriye doğru ağırlıklara yansıtılarak ağırlık eğitimi gerçekleştirilir. Çok katmanlı ağlarda geriye doğru yansıtma işlemi için, çıkış düğümü hata miktarından başlayarak

tüm düğümlerin hata miktarları sırasıyla türevi alınarak ağırlıklara yansıtılır (Denklem 6, 7).


$$\delta_k = \sum_{k=0}^K \delta_y * w_{k,y} \quad (6)$$

Hata miktarı ve transfer fonksiyonu türevi giriş-gizli, gizli-çıkış katmanı ağırlık değerlerine yansıtılarak, ağırlık değerleri yeniden hesaplanır ( Denklem 7).

$$W_{i,k} = W_{i,k} + \delta_y x_i F(\text{net}_{i,k})' \quad (7)$$

### Radial Temelli Fonksiyon Ağı

RBF ağı yapı ve hesaplama olarak kolay bir ağıdır. RBFN gizli katman transfer fonksiyonu radyal temelli fonksiyon (Denklem 8) olan üç katmanlı bir ağıdır. Şekil 3'te görüldüğü gibi; bir giriş, bir gizli ve bir çıkış katmanından oluşur (Ababaei ve ark., 2012). Tüm katmanlardaki düğümler tam olarak birbirine bağlıdır. Giriş katmanı düğüm sayısı, verinin öz nitelik sayısı kadardır. Çalışmada 24 öz nitelik bulunduğu için giriş katmanı düğüm sayısı 24 adettir. Çıkış katmanı düğüm sayısı problemin özelliğine göre değişir. Çalışmada, hastaların kronik böbrek hastası olup olmadığı sınıflandırması yapılacağından, çıkış katmanı düğüm sayısı bir adettir. Şekil 3'de görüldüğü gibi giriş verileri direk gizli katman düğümlerine bağlanmıştır. Giriş katmanı ile gizli katman arasında ağırlık değerleri yoktur. Ağırlık değerleri sadece gizli katman ile çıkış katmanı arasındadır. Gizli katman çıkış değerleri radyal temelli fonksiyon değeridir (Denklem 9). Denklemde 8'de x giriş vektörü,  $u_i$ , x ile aynı boyutta olan ve veri seti i. nitelik aritmetik ortalaması, K radyal. temelli fonksiyon sayısıdır ( gizli katman düğüm sayısı) ve  $\sigma_i$  veri seti i. nitelik verilerinin standart sapmasıdır (Jang ve ark., 1997).



Şekil 3. K gizli katmandan oluşan RBF ağı yapısı (Ari-sariyawong ve Charoenseang, 2002)

$$C_i=R_i(x)= R_i \left( \frac{\|x-u_i\|}{\sigma_i} \right), i=1,2,\dots,K \quad (8)$$

$R_i(x)$  değeri i. radyal temelli fonksiyon, Denklem 9'daki gaussian fonksiyonun maksimum değerini bulur. Denklem 9 de tipik bir gaussian fonksiyon verilmiştir.

$$R_i(x) = e \left( - \frac{\|x-u_i\|^2}{2\sigma_i^2} \right) \quad (9)$$

RBF ağı çıkış katmanı düğüm ( $y_i$ ) çıkış değeri Denklem 10' daki gibi hesaplanır. Burada  $w_k$ , gizli katman-çıkış katmanı arası ağırlık değeridir.  $R_i(x)$ , gizli katman i. düğüm çıkış değeridir. Çıkış düğüm ağırlık değerlerinin aritmetik ortalaması alınarak çıkış değeri bulunur (Denkle 11).


$$y_i(x) = \sum_{i=1}^K w_k R_i(x) \quad (10)$$

$$y_i(x) = \frac{\sum_{i=1}^K w_k R_i(x)}{\sum_{i=1}^K R_i(x)} \quad (11)$$

RBF ağda gizli katman düğüm sayısı en çok giriş veri seti adedi kadar olabilir. Gizli katmandaki farklı düğüm sayısı ile yapılan hesaplama ayrı bir çözümdür. Görüldüğü gibi RBF ağı parametre ve hesaplama işlemi az olduğundan, hesaplama süresi de kısa olur. Dolayısıyla fazla kaynak kullanmadan, çok hızlı bir şekilde öğretiler. RBF tekniği iyi bir genelleme olanağı, daha az düğüm kullanma ve kısa hesaplama olanağı sunar (Moradkhani ve ark. 2004).

### Kronik Böbrek Hastası Sınıflandırması

Çalışmada 400 hastaya ait Tablo 1'deki gibi hastaların farklı özellik ve tetkik değerlerine göre 24 farklı öz nitelik kullanılarak hastaların kronik böbrek hastası olup olmadığı sınıflandırması işlemi YSA ve RBFN ile ayrı ayrı gerçekleştirilmiştir. Şekil 4'te sistemin YSA ve RBFN makine öğrenme ağ modeli verilmiştir. Problemin çözümü için şekildeki ağ yapısı hem YSA hem de RBF öğrenme için kullanılmaktadır. YSA ve RBFN için farklı gizli katman mimarileri için problem çözülerek bulgular Tablo 2 ve Şekil 5,6 ve 7'de verilmiştir.



**Şekil 4.** Hastaların belirli tetkik sonuçlarına göre kronik böbrek hastası olup olmadığının YSA ve RBF ile sınıflandırma ağı yapısı.

Farklı hastalardan elde edilmiş 400 adet veri içerisinde eksik olanlar dahil hepsi işleme alınmıştır. YSA ve RBFN yapısı gereği tüm veriler sayısal olarak ifade edilmesi gerektiğinden, eksik olan veriler 0 ile tamamlanmıştır. Tablo 1’de veri setinin nitelik değeri verilmiştir. Buna göre giriş katmanı düğüm sayısı her iki ağı için de 24 adettir. Problemden kullanılan veriler aşağıdaki gibi tasnif edilmiştir:

- 24 farklı öznelik. Sözel öznelikler 0-1 şeklinde sayısal olarak ifade edilmiştir. Her bir nitelik reel sayı veya tamsayıdan oluşmaktadır.
- Toplam 400 farklı hastadan elde edilmiş veri;
  - Eksik veri :244
  - Sağlam veri :156
  - Kronik böbrek hastası :237
  - Kronik böbrek hastası değil :163


Problemin YSA kullanılarak; öğrenme fonksiyonu TRANLM, transfer (aktivasyon fonksiyonu) TANSIG, öğrenme oran: 0,2 ve momentum değeri 0.6 olarak farklı ağı mimarileri için 1000 iterasyon çalıştırılmıştır. Elde edilen sonuçlar Tablo 2’de ve Şekil 5’de verilmiştir. Tabloya göre, performans (MSE) ve regresyon verilerine göre değerlendirme yapıldığında en iyi olarak %0.017 hata ve %99 gibi bir regresyon değeri elde edilmiştir. Bu veri setinde eksik veriler olmasına rağmen çok iyi bir sonuçtur. Tabloya göre bu problem için 24-10-1 mimarisin en uygun mimaridir. Bunun anlamı, daha az hesaplama dolayısıyla daha hızlı olarak sonuç alma imkanı vardır. En kötü sonuç 24-20-1 mimarisinde elde edilmiştir. Hem performans değeri hem de regresyon değeri en düşüktür.

**Tablo 1.** Kullanılan verilerin özellikleri

Öznelik değerleri	
1	Age (yaş)
2	Blood Pressure (kan basıncı-tansiyon)
3	Specific Gravity(idrara yoğunluğu- densite)
4	Albumin(Albumin)
5	Sugar (Şeker)
6	Red Blood Cells(Kırmızı kan hücresi-eritrosit)
7	Pus Cell (iltihap)
8	Pus Cell clumps(iltihap hücresi kümeleşmesi)
9	Bacteria (bakteri)
10	Blood Glucose Random (Kan şekeri)
11	Blood Urea (Kan üre)
12	Serum Creatinine (Serum keratin)
13	Sodium (sodyum)
14	Potassium (Potasyum)
15	Hemoglobin
16	Packed Cell Volume (Hücre hacmi-Heretroksit)
17	White Blood Cell Count (Beyaz kan hücresi - Lokosit sayısı)
18	Red Blood Cell Count (Kırmızı kan hücresi sayısı)
19	Hypertension(Hipertansiyon)
20	Diabetes Mellitus(Diyabet melitis)
21	Coronary Artery Disease(Kroner arter hastalığı)
22	Appetite(İştah durumu)
23	Pedal Edema (Ayak ödemi)
24	Anemia(Anemi-Kansızlık)

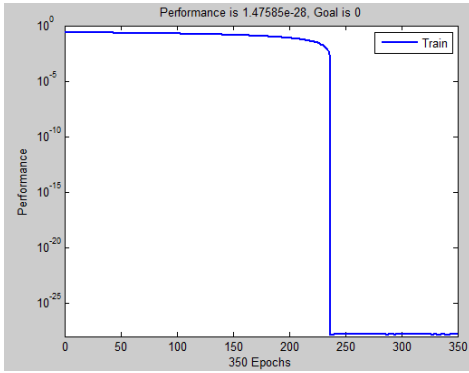
**Tablo 2.** İleri beslemeli geri yayımlı çok katmanlı YSA, ile kronik böbrek hastalığı sınıflandırma sonuçları

YSA ağı mimarisi	Regresyon	MSE
<b>24-10-1</b>	<b>0,994</b>	<b>0,0172</b>
24-20-1	0,932	0,0859
24-30-1	0,969	0,0237
24-40-1	0,962	0,0716
24-50-1	0,961	0,0764




**Şekil 5.** İleri beslemeli geri yayımlı çok katmanlı YSA, ile kronik böbrek hastalığı sınıflandırma performansı.

Geliştirilen sistem RBF ağı, normal dağılım eğrisi aralığı olan, spread 1.0 ve spread 8.0 parametreleri için ayrı ayrı çalıştırılarak sonuçlar Şekil 6 ve 7’de gösterilmiştir. Şekillere göre RBFN performans değeri birbirine çok yakın ancak YSA’ya göre çok daha iyidir. Grafiklerden de görüldüğü gibi spread değeri arttıkça gizli katman düğüm sayısı artmakta, ancak performans değerinde dikkate değer bir değişim söz konusu olmamaktadır. RBF ağlarında farklı gizli katman düğüm sayısı farklı bir çözümdür. Dolayısıyla en az düğüm sayısı ile kabul edilebilir çözüme gidilmesi, daha az hesaplama olacağından, daha hızlı çalışacaktır. Daha az hesaplama daha az kaynak kullanımı demektir. Dolayısıyla daha düşük sistemlerde dahi çalışma imkanı bulacaktır. Bu yönüyle YSA’ya göre tercih sebebidir. RBF ağlarda gizli katman düğüm sayısı giriş seti veri sayısına yaklaştığında tekrar çözüm bozulduğu gözlenmiştir. RBF ağlar geri yayımlı YSA ile karşılaştırıldığında, bu problem için, RBFN ve YSA’ya göre çok daha iyi bir performans sahiptir. RBFN hesaplamaları kolay ve çok az parametre kullandığı için hesaplama işlemleri kolay ve hızlıdır. RBFN ağları yapı olarak YSA ağlara göre daha basittir.



Şekil 6. RBF ağının spread 1.0 için performans grafiği.



Şekil 7. RBF ağının spread 8.0 için performans grafiği

## SONUÇLAR ÖNERİLER

Çalışmada 400 farklı hastadan elde edilmiş kişisel bilgi, tanı, tetkik ve laboratuvar sonuç (UCI,2015) verileri ileri

beslemeli geri yayımlı çok katmanlı YSA ve RBF ağı makine öğrenme yöntemleri kullanılarak hastaların kronik böbrek hastası olup olmadığı sınıflandırması yapılmıştır. Her iki yöntem ile de çok iyi performans değerleri elde edilmiştir (Tablo 2 ve Şekil 5, 6 ve 7). RBF ağlar ileri beslemeli geri yayımlı YSA ile karşılaştırıldığında RBF ağı YSA’ya göre, bu problem için, çok daha iyi bir performansa sahiptir. Öte yandan RBF ağı YSA’ya göre hesaplama işlemleri daha kolay, daha kısa, ağ yapısı daha sadedi ve daha az kaynak kullanır. Bu durum YSA göre daha düşük kapasiteli cihazlarda çalışma imkanı sağlayacağından tercih sebebi olacaktır. Dolayısıyla uygulamalarda performanslar arasında dikkate değer bir fark yok ise RBF ağı tercih edilebilir.

## KAYNAKLAR

- Ababaei, B., Sohrabi, T., Mirzaei, F. (2012). Assessment of radial basis and generalized regression neural networks in Daily reservoir inflow simulation. *Elixir Comp. Sci. & Engg.* 42: 6074-6077.
- Abhishek, B., Thakur, G.S.M., Gupta, D. (2012). Proposing Efficient Neural Network Training Model for Kidney Stone Diagnosis. *(IJCSIT) International Journal of Computer Science and Information Technologies*, 3 (3):3900-3904.
- Afif, M.H., Hedar, A-R., Hamid, T.H.A., Mahdy, Y.B. (2013). SS-SVM (3SVM): A New Classification Method for Hepatitis Disease Diagnosis. *(IJACSA) International Journal of Advanced Computer Science and Applications*, 4(2):53-58.
- Anthony, M., Bartlett, P.L. (2009). *Neural Network Learning: Theoretical Foundation*. Cambridge University Press.
- Arisariyawong, S. A., Charoenseang, S. (2002). Dynamic self-organized learning for optimizing the complexity growth of radial basis function neural networks. *Industrial Technology. IEEE ICIT'02. IEEE International Conference*.
- Delican, Y. , Özyılmaz, L., Yıldırım, T. (2011). Evolutionary Algorithms Based RBF Neural Networks For Parkinson s Disease Diagnosis. *ELECO 2011 7<sup>th</sup> International Conference on Electrical and Electronics Engineering*, 1-4 December, Bursa, TURKEY.
- Graupe, D. (2013). *Principles of Artificial Neural Networks: 3rd Edition (Advanced Series in Circuits & Systems) (Advanced Series in Circuits and Systems)* . World Scientific Publishing Company; 3rd edition edition.
- İlkuçar, M., Işık, A.H., Çifci, A. (2014). Classification of Breast Cancer Data with Harmony Search and Back Propagation Based Artificial Neural Network. *IEEE, 2014 22 nd Signal Processing and Communications Applications Conference (SIU)*, 23-25 April 2014.
- Jang, J-S.R., Sun, C.-T., Mizutani, E.,(1997), *Neuro-Fuzzy and Soft Computing: A Computational Approach to Learning and Machine Intelligence*. Prentice Hall; 1 edition (September 26, 1997), ISBN-13: 978-0132610667
- Kumar, K., Abhishek, B. (2012). Artificial Neural Networks for Diagnosis of Kidney Stones Disease. *I.J. Information Technology and Computer Science*, 2012, 7, 20-25 Published Online July 2012 in MECS (<http://www.mecspress.org/>) DOI: 10.5815/ijitcs.2012.07.03

- Levey, A.S., Eckardt, K.U., Tsukamoto, Y., Levin, A., Coresh, J., Rossert, J., de Zeeuw, D., Hostetter, T.H. Lameire, N., Eknoyan, G. (2005). Definition and classification of chronic kidney disease: A position statement from Kidney Disease: Improving Global Outcomes (KDIGO). *Kidney International*, 67: 2089–2100.
- Moradkhani, H., Hsu, K., Gupta, H.V., Sorooshian, S. (2004). Improved streamflow forecasting using self-organizing radial basis function artificial neural networks. *Journal of Hydrology*, 295(1–4):246–262.
- National Kidney Foundation (2002). KJDOQI clinical practice guidelines for chronic kidney disease: evaluation, classification, and stratification. *Am J Kidney Dis*, volume 39, SI-266, doi: 10.1053/ajkd.2002.30943
- Öztemel, E. (2012). *Yapay Sinir Ağları*. Papatya Yayıncılık, 3. Basım Nisan 2012.
- Soundarapandian, P. (2015). Senior Consultant Nephrologist, Apollo Hospitals, Karaikudi, Tamilnadu, India.
- Suzuki, K. (2011). *Artificial Neural Networks - Methodological Advances and Biomedical Applications*. Published by In-Tech Janeza Trdine 9, 51000 Rijeka, Croatia. Copyright 2011 InTech.
- Tanqi L., Liu Xun L., Ningshan L., Xiaoming W. (2010). Application of radial basis function neural network to estimate glomerular filtration rate in Chinese patients with chronic kidney disease, 2010 International Conference on Computer Application and System Modeling (ICCASM 2010)
- Rouhani, M., Haghghi, M.M. (2009). The Diagnosis of Hepatitis diseases by Support Vector Machines and Artificial Neural Networks. *International Association of Computer Science and Information Technology - Spring Conference 2009*.
- Tomar, D., Agarwal, S. (2015). Hybrid Feature Selection Based Weighted Least Squares Twin Support Vector Machine Approach for Diagnosing Breast Cancer, Hepatitis, and Diabetes. *Advances in Artificial Neural Systems Volume 2015*, Article ID 265637, 10 pages <http://dx.doi.org/10.1155/2015/265637>
- UCI (2015). [https://archive.ics.uci.edu/ml/datasets/Chronic\\_Kidney\\_Disease](https://archive.ics.uci.edu/ml/datasets/Chronic_Kidney_Disease). (Erişim tarihi: 17/09/2015).
-