



MAKÜ FEBED  
ISSN Online: 1309-2243  
<http://febed.mehmetakif.edu.tr>

*Mehmet Akif Ersoy Üniversitesi Fen Bilimleri Enstitüsü Dergisi 5 (1): 30-36 (2014)*

**Araştırma Makalesi / Research Paper**

## **Liken planus ve Sedef Deri Hastalıklarının Çok Katmanlı Yapay Sinir Ağı Kullanılarak Sınıflandırılması**

Ahmet ÇİFCİ<sup>1\*</sup>, Muhammer İLKUÇAR<sup>2</sup>, Mehmet Recep BOZKURT<sup>3</sup>, Yılmaz UYAROĞLU<sup>3</sup>

<sup>1</sup>Mehmet Akif Ersoy Üniversitesi, Teknik Bilimler Meslek Yüksekokulu, Elektrik Programı, Burdur

<sup>2</sup>Mehmet Akif Ersoy Üniversitesi, Teknik Bilimler Meslek Yüksekokulu, Bilgisayar Programcılığı Programı, Burdur

<sup>3</sup>Sakarya Üniversitesi, Mühendislik Fakültesi, Elektrik-Elektronik Mühendisliği Bölümü, Sakarya

*Geliş Tarihi (Received): 14.12.2013, Kabul Tarihi (Accepted): 09.02.2014*

✉ *Yazışmalardan Sorumlu Yazar (Corresponding author): acifci@mehmetakif.edu.tr (A. Çifci)*

☎ (0 248) 2134583 📠 (0 248) 2134599

### **ÖZET**

Son yıllarda özellikle bilgisayar teknolojisindeki gelişmeler, mühendislik, astronomi, işletme, ekonomi, finansman, tıp, vb. gibi pek çok disiplinde kendine uygulama alanı bulmuştur. Tıp alanında tıbbi cihazlarda bilgisayar teknolojilerinin kullanılmasıyla, daha hassas, daha hızlı, insandan kaynaklanan hataları minimize eden cihazlar geliştirilmektedir. Bilgisayar teknolojisine paralel olarak problem çözme yöntemleri de geliştirilmiş ve farklı yöntemler bulunmuştur. Bu yöntemlerin tıp alanında uygulanması hekimlerin daha kolay ve daha hızlı teşhis koymasına yardımcı olmaktadır. Bu çalışmada, 140 hastaya ait 33 nitelikten oluşan deri doku örnekleri Yapay Sinir Ağları geri yayımlı öğrenme algoritması yardımıyla sınıflandırılmıştır. Problemin çözümü için MATLAB Neural Network Toolbox kullanılarak hastaların sınıflandırma başarıları irdelenmiştir.

**Anahtar kelimeler:** Yapay sinir ağları, liken planus hastalığı, sedef hastalığı, MATLAB

### **Classification of *Lichen planus* and Psoriasis skin diseases using multi-layer artificial neural network**

#### **Abstract**

In recent years, advances in computer technology have found application areas in many disciplines like engineering, astronomy, economics, finance, medicine. Using computer technologies in medical devices, more sensitive, faster, minimizing human errors devices are being developed. In parallel with developments in computer technology, problem solving methods have also been developed and different methods have been found. Implementation of these methods in medicine helps physicians for easier and faster diagnosis. In this study, skin tissue samples belonging to 140 patients consisted 33 attributes were classified by using Artificial Neural Network back propagation learning algorithm. In order to solve the problem, the patients' classification success was examined using MATLAB Neural Network Toolbox.

**Key words:** Artificial neural network, lichen planus, psoriasis, MATLAB

## 1. Giriş

Deri hastalıkları (dermatolojik rahatsızlıklar), ciltte görülen hastalıklardır ve bunların birçok çeşidi vardır. Dermatolojik rahatsızlıklardan en yaygın olanları Sedef Hastalığı (psoriasis), Akne, Behçet hastalığı, alerji, liken planus vb. sıralanabilir. Gündelik hayatta çok daha farklı dermatolojik hastalıklarla karşılaşabiliriz. Herhangi bir hastalığın belirtilerinden şüphelenildiğinde hemen bir uzmana danışılmalıdır. Unutulmamalıdır ki bir hastalığın tedavisinde en önemli etmenlerden birisi de erken teşhistir (Anonim, 2013a). Şekil 1'de kolun dirsek bölgesinde oluşmuş bir sedef hastalığı resmi görülmektedir.



Şekil 1. Dirsek bölgesinde gümüş-beyaz görünümüne sahip sedef hastalığı (AAD, 2013b).

Sedef hastalığı, immünolojik ve genetik arka planı alan kronik ve karmaşık bir deri hastalığıdır (Shawkatová, 2012). Hastalık dünyadaki insanların %1-3'ünü etkilemektedir (Henseler, 1998; Kurd ve Gelfand, 2009). Bu hastalık üzerinde bulunan kabuklardan dolayı halk arasında sedef hastalığı olarak da bilinmektedir. Hastalığın süresi ve şiddeti kişiden kişiye değişebilmektedir. Henüz hastalığın nedeni kesin olarak bilinmemekle birlikte kalıtsal etkisi olduğu bilinmektedir.



Şekil 2. Ayaklarda görülen liken planus hastalığı (AAD, 2013a)

Görünüşü sedefe benzeyen *Liken planus* adında bir hastalık daha vardır, ancak *Liken planus*'un tedavisi daha zordur (Anonim, 2013b). Liken planus deride morumsu, aşırı kaşıntılı, düz yüzeyli kabarıklıklardan oluşur (AAFP, 2013; AAD, 2013a). *Liken planus* hastalığı derimizin herhangi bir yerinde olabildiği gibi tırnaklar, dudak, ağız içi, diş etleri vb. gibi yerlerde de görülebilmektedir (AAFP, 2013). Şekil 2'de ise ayaklarda oluşmuş bir liken planus hastalığı resmi görülmektedir.

Literatürde çok farklı hastalığın teşhis ve tanısında yardımcı olacak sayısız çalışma vardır. Belirtisi gözle görülebilen ve resmedilebilen bir hastalığın teşhisinde yapay sinir ağları yöntemi başarılı bir şekilde uygulandığı pek çok çalışmaya rastlayabiliriz. Dolayısıyla bu çalışmada da yapay sinir ağları kullanılarak sedef ve *likan planus* deri hastalıklarının teşhisinde yardımcı olacak bir yöntem gerçekleştirilmiştir.

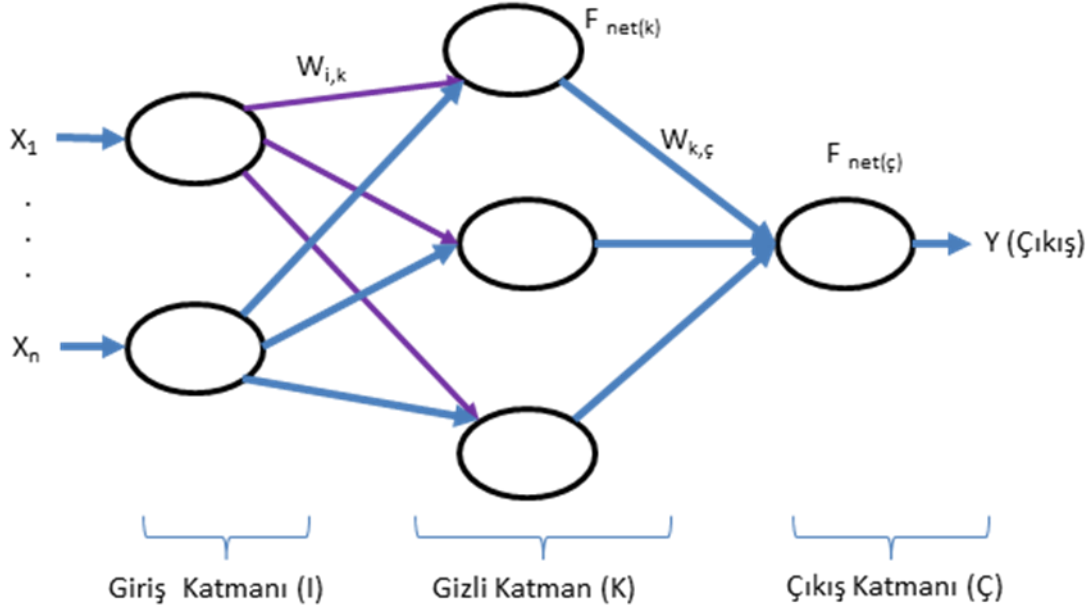
Bu çalışmada yapay sinir ağları ile ilgili kısaca bilgiler verilmiş, yapay sinir ağları kullanılarak deri doku örneklerinin sınıflandırılması ve hastaların sınıflandırma başarısı irdelenmiştir.

## 2. Materyal ve Yöntem

Yapay sinir ağları (YSA), özellikle doksanlı yıllardan sonra çok farklı alanlarda kullanım olanağı bulmuş, biyoloji tabanlı bir yapay zeka metodudur. YSA, beynin keşfedilmiş çalışma ilkesinin matematiksel olarak modellenmesi sonucu ortaya çıkmış bir öğrenme yöntemidir. YSA beyin hücrelerini ve onun bağlantı noktalarının yapay olarak modellenmesi sonucu, yapay zekalı, öğrenebilen makineler geliştirilmesinde kullanılmaktadır. YSA, karakter-örüntü tanıma, tıbbi tanı, karar destek sistemlerinde, tahmin etme, kümeleme vb. gibi problemlerin çözümünde başarılı bir şekilde kullanılmaktadır. Farklı problemlerin çözümü için onlarca farklı yapay sinir ağı geliştirilmiştir.

Tıbbi teşhis problemlerinin çözümünde, çok katmanlı geri yayılım algoritmasına göre öğrenen YSA'lar yaygın olarak başarılı bir şekilde kullanılmaktadır. Ganesan ve arkadaşları (2010), demografik verilere (yaş, cinsiyet, vb.) göre kanser hastalığının tahminini çok katmanlı yapay sinir ağı kullanarak gerçekleştirmişlerdir. Chen ve arkadaşları (2002), geri yayımlı çok katmanlı yapay sinir ağı ile, bir resmin insan derisi olup olmadığını belirleyen bir çalışma yapmışlardır. Jaleel ve ark. (2012), deri resimlerinden deri kanseri tahminini geri yayımlı YSA kullanarak gerçekleştirmişlerdir. Deri resimlerinin ağ girdisi olabilmesi için 2-D dalgaçık dönüşümü tekniği (Louis ve ark., 1997) kullanılmıştır. Kabari ve Bakpo (2009), Niagra tropik bölgesindeki deri hastalığı tanımlamasını %90 başarı ile geri yayımlı yapay sinir ağı ile gerçekleştirmişlerdir.

Şekil 3'te n nöronlu giriş katmanı, üç nöronlu gizli katman ve tek nöronlu çıkış katmanından oluşan bir YSA yapısı görülmektedir.



Şekil 3. Çok katmanlı yapay sinir ağı

Şekil 3'teki çok katmanlı yapay sinir ağında;

$X_1, \dots, X_n$	Giriş veri seti
Y	Çıkış
$E = T - Y$	Hata=Beklenen değer-Gerçekleşen değer
$w_{i,k}$	i ve k nöron arasındaki ağırlık değerleri
$net_i = \sum x_i * w_i$	i. nöronun ağırlık değerleri toplamı
$F_{net} = \frac{1}{1 + e^{-net}}$	Bir nöron eşik fonksiyonu (sigmoid fonksiyon), bir nöron çıkışıdır.

YSA'da giriş katmanı dışındaki tüm katmanlardaki nöronlar birbirine bağlanır. Giriş katmanındaki nöronların görevi, giriş verilerinin her birini gizli katmadaki (ara katmana) her bir nörona ulaştırmaktır.

Çok katmanlı yapay sinir ağlarında ağın öğrenme yöntemi için en yaygın olarak geri yayılım öğrenme kuralı kullanılmaktadır. Böylece çıkıştaki hatanın çıkış nöronundan başlayarak, giriş nöronuna kadar olan tüm ağırlık değerlerine yansıtılarak öğrenme gerçekleştirilir. YSA'da geri yayımlı öğrenme algoritmasında eşik fonksiyonu sürekli ve türevi alınabilir bir fonksiyon olmalıdır. Zira bu yöntemde; çıkış hata değeri, çıkış nöronundan başlayarak geriye doğru eşik fonksiyonun türevi alınarak her nöronun hata değeri hesaplanır, hesaplanan hata değerleri çıkıştan girişe doğru tüm ağırlıklara yansıtılarak yeni ağırlık değerleri elde edilir. Bu işlemler durdurma kriterleri sağlanana kadar tekrarlanarak ağın öğrenmesi gerçekleştirilir.

Nöronda toplanan net değeri ( $net = \sum x_i * w_i$ ) aktivasyon fonksiyonu yardımıyla çıkışa dönüştürülür. Bu fonksiyon eşik fonksiyonu veya sıkıştırma fonksiyonu olarak da adlandırılmaktadır (Hamzaçebi, 2011). Aktivasyon fonksiyonu kullanılarak nöron çıkış değerleri [0-1] (sigmoid) [-1,1] (hiperbolik tanjant) aralığına çekilmelidir (Zang ve diğ., 1998). Problemin özelliğine göre kullanılacak birçok aktivasyon fonksiyon türü vardır (Öztemel, 2012). Literatürde çok katmanlı geri yayılım algoritması öğrenme kuralına göre çalışan bir ağda, genellikle türevi alınabilir olan, sigmoid ve hiperbolik tanjant aktivasyon fonksiyonları tercih edilmektedir.

Aşağıda verilen geri yayımlı çok katmanlı YSA eğitim algoritmasında 2-12 adımları arasındaki adımlar, minimum hataların karesi toplamı elde edilene kadar veya belirli bir iterasyon değeri kadar tekrarlanarak eğitilir.

1. Başlangıç parametrelerini belirle (öğrenme katsayısı ( $\eta$ ), momentum katsayısı ( $\alpha$ )).
2. [0,1] aralığında rastgele ağırlık değerleri ata.
3. Öğrenme veri setinden bir grup veriyi giriş katmanına gönder.
4. Giriş değeri ile gizli katmana bağlayan ağırlık çarpımları toplamını ( $net_k = \sum x_i * w_{i,k}$ ) hesapla.
5. Gizli katman nöronları çıkış değeri olan ( $F_{net(k)} = 1/(1 + e^{-net})$ ) hesapla. Gizli katmandaki nöronların çıkışı değerleri çıkış katmanı nöronları giriş verisi olacaktır.
6. Çıkış katman nöronları (Ç), ( $net_c = \sum (F_{net(k)} * w_{k,c})$ ) hesapla.
7. Çıkış katman nöronları çıkış değeri olan, ( $Y = F_{net(c)} = 1/(1 + e^{-net})$ ) hesapla.

8. Çıkış Hata Hesapla,  $E = T - Y$ ; (Hata = Beklenen değer – Gerçekleşen değer)  
 9. Hata değerine göre çıkış nöronu aktivasyon fonksiyona göre türevi alınarak çıkış hata oranı hesaplanır.

$$(\delta_c = d / dy F_{net(c)} E = Y(1-Y)E)$$

10. Hata oranını gizli katman ile çıkış katmanı arasındaki ( $W_{k,c}$ ) ağırlıklarına yansıt  
 $W_{k,c(yeni)} = W_{k,c(önceki)} + \eta \delta Y + \alpha \Delta W_{k,c(önceki)}$   
 11. Giriş katmanı ile ara katman arasındaki ( $W_{i,k}$ ) ağırlıklarına yansıt.

$$\delta_k = d / dy F_{net(k)} \sum \delta_c * W_{k,c} =$$

$$F_{net(k)}(1-F_{net(k)}) * \sum \delta_c * W_{k,c}$$

$$W_{i,k(yeni)} = W_{i,k(önceki)} + \eta \delta_k F_{net(k)} + \alpha \Delta W_{i,k(önceki)}$$

12.  $\delta k$  Hataların kareleri toplamını hesapla,

$$E = \frac{1}{2} \sum (T - Y)^2$$

13. Sonlanma kriterleri sağlanmadı ise 2. adıma git (Belirli bir hata değeri, ağırlıklardaki değişim olmadığı veya belirli bir iterasyon sayısı)

### 3. Bulgular

Bu çalışmada 140 hastaya ait 33 nitelikten oluşan deri doku örnekleri (ics, 2013), "nntool" MATLAB komutu ile çalıştırılan toolbox yardımıyla sınıflandırılmıştır. Veriler 70 sedef hastası ve 70 liken planus hastasına ait deri örnekleridir ve 33 nitelikten oluşmaktadır. Bu 33 niteliğin, 11 tanesi klinik nitelikleri (örneğin; cilt kızarıklığı, ciltte pullanma, kaşıntı gibi.), geri kalan 22 nitelik ise histopatolojik nitelikleri (örneğin; melanin tutamama, kabarcıklı derinin fibröz dejenerasyonu, deri kalınlaşması gibi.) oluşturmaktadır. Her bir nitelik 0, 1, 2, 3 değerlerinden birini almaktadır. Histopatolojik nitelikler, mikroskop altında deri örneklerinin analiziyle elde edilmiştir. Niteliklerin özellikleri aşağıdaki gibidir (ICS, 2013):

#### Klinik Nitelikler

- 1 → erythema – cilt kızarıklığı  
 2 → scaling – ciltte pullanma  
 3 → definite borders – kesin sınırlar  
 4 → itching - kaşıntı  
 5 → koebner phenomenon – Köbner olayı (doku bozulması)  
 6 → polygonal papules – çokgen papüller  
 7 → follicular papules – foliküler papüller  
 8 → oral mucosal involvement – ağızsız mukozal tutulum  
 9 → knee and elbow involvement – diz ve dirsek tutulumu  
 10 → scalp involvement – kafatası derisi tutulumu  
 11 → family history – aile öyküsü

#### Histopatolojik Nitelikler

- 12 → melanin incontinence – melanin tutamama (melanin kaçırma)  
 13 → eosinophils in the infiltrate – sızmadaki eozinofil

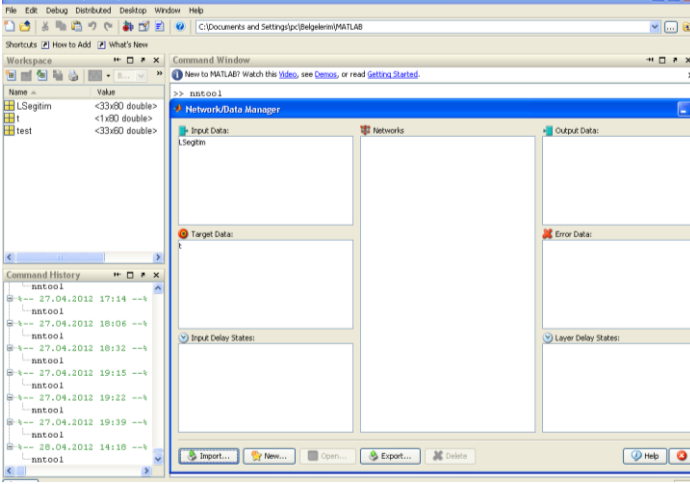
- 14 → PNL infiltrate – PNL sızması  
 15 → fibrosis of the papillary dermis – kabarcıklı derinin fibröz dejenerasyonu  
 16 → exocytosis - eksositoz  
 17 → acanthosis – akantoz (insan üstderisindeki malpighi katmanının kalınlaşması)  
 18 → hyperkeratosis – hiperkeratoz (ayak tabanında izlenen deri kalınlaşması)  
 19 → parakeratosis – parakeratoz (üstderi hücrelerinin olgunlaşma ve farklılaşma sürecinde ortaya çıkan bozukluk)  
 20 → clubbing of the rete ridges – rete çıkıntılarının çomaklaşması  
 21 → elongation of the rete ridges – rete çıkıntılarının uzaması  
 22 → thinning of the suprapapillary epidermis – yüksek kabarcıklı üstderinin incelenmesi  
 23 → spongiform pustule – sponjiyöz çıbanı (deri şarbonu)  
 24 → munro microabscess – munro mikroapsesi  
 25 → focal hypergranulosis – fokal hipergranüloz  
 26 → disappearance of the granular layer – pürüzlü katmanın yok olması  
 27 → vacuolization and damage of basal layer – temel katmanın kofullaşması ve zedelenmesi  
 28 → spongiosis - sponjiyöz  
 29 → saw-tooth appearance of retes – retenin testere dişi görünümünde olması  
 30 → follicular horn plug – foliküler boynuz tıkaçı  
 31 → perifollicular parakeratosis – perifoliküler parakeratoz  
 32 → inflammatory mononuclear infiltrate – iltihaplı mononükleer sızması  
 33 → band-like infiltrate – bant şeklinde sızma

Her iki hastalıktan 40'ar olmak üzere toplam 80 hasta eğitim ve her iki hastalıktan 30'ar olmak üzere 60 hasta ise test verisi olarak belirlenmiştir.

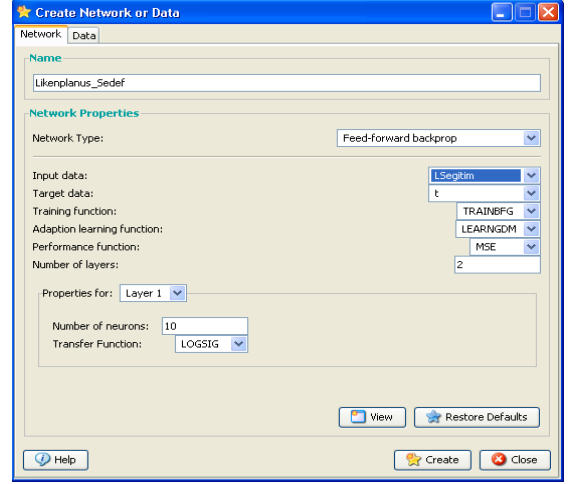
Şekil 4'te görüldüğü üzere, "LSegitim" giriş verisi, "t" ise hedef veri olarak ifade edilmiştir. "t" hedef verisi liken planus hastaları için 40 adet 0, sedef hastaları için ise 40 adet 1 verisini içermektedir. Eğitim için yeni bir ağ oluşturmak için "New..." butonuna basılır.

Şekil 5'ten de anlaşılacağı üzere, öğrenme algoritması olarak ileri beslemeli geri yayılım ağ seçilmiştir. Eğitim fonksiyonu olarak tüm fonksiyonlar denenmiş ve TRAINBFG fonksiyonu ile daha yüksek doğruluk elde edildiğinden TRAINBFG fonksiyonu seçilmiştir.

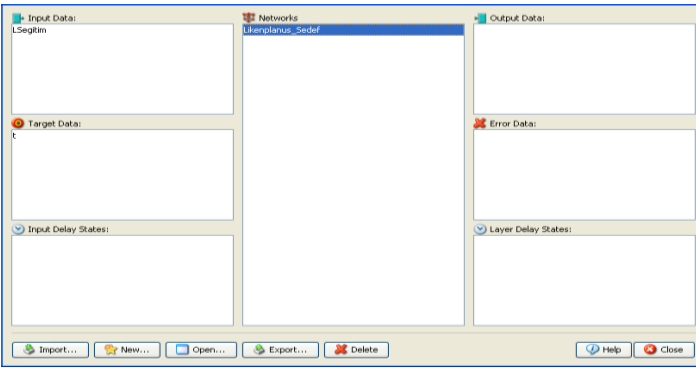
Şekil 6'da oluşturulan ağa çift tıklanır veya "Open..." butonuna basılırsa oluşturulan "Likenplanus\_Sedef" ağı açılmış olur. Şekil 7'de görülebileceği gibi "Train" sekmesine tıklanır.




Şekil 4. MATLAB nntool ekran görüntüsü



Şekil 5. Oluşturulan ağıın özellikleri



Şekil 6. Oluşturulan Likenplanus\_Sedef ağı



Şekil 7. Ağıın eğitimi

Giriş ve hedef verileri seçildikten sonra "Train Network" butonuna basılarak Şekil 8'deki eğitim grafiği elde edilir. (Eğitim parametrelerinde herhangi bir değişiklik yapılmamıştır.)

Toolbox'ın "Import..." butonuna basılarak "test" verisi, giriş verisi olarak yüklenmiştir. "Likenplanus\_Sedef" ağı tekrar açılmış ve bu sefer "Simulate" sekmesi tıklanmıştır.

Şekil 9'da görüldüğü gibi giriş olarak "test" verisi seçilmiş, çıkış olarak "test\_outputs" yazılmıştır. "Simulate Network" butonuna basılarak test verileri simüle edilmiş ve Şekil 10'da görüldüğü gibi toolbox'ın çıkış verileri kısmına atılmıştır.

"Test\_outputs"a çift tıklanarak test çıktıları Şekil 11'de görüldüğü gibi gözlenebilir.

60 adet test verisi için ağıın bulduğu değerler aşağıdaki gibidir:

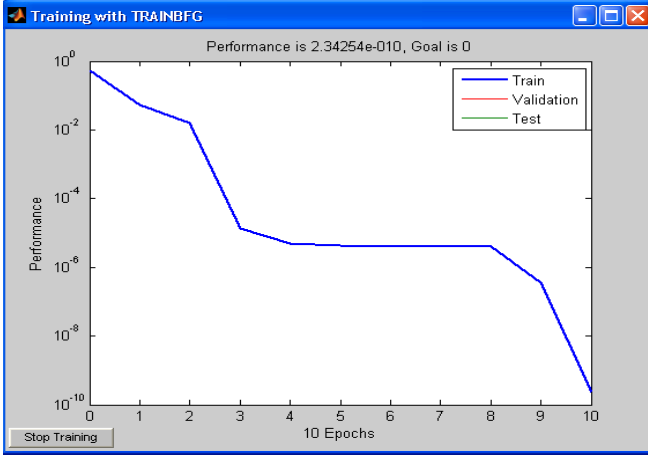
1.1883e-005	1.7854e-005	2.0365e-005	2.1544e-005
2.151e-005	1.8417e-005	1.7472e-005	3.4562e-005
1.8821e-005	4.3552e-005	1.9629e-005	1.916e-005
2.4266e-005	3.0994e-005	9.8725e-006	1.1841e-005
2.307e-005	1.8247e-005	2.8359e-005	1.498e-005
1.7603e-005	1.5568e-005	1.903e-005	1.8795e-005
1.7729e-005	1.1778e-005	2.4047e-005	1.0597e-005
2.0732e-005	8.438e-006	1 1 1 1 1 1 1 1 1 1 1 1 1 1 1	1 1 1 1 1 1 1 1 1 1 1 1 1 1 1
1 1 1 1 1 1 1 1 1 1 1 1 1 1 1	1 1 1 1 1 1 1 1 1 1 1 1 1 1 1		

Test için kullanılan (60 adet) gerçek veriler aşağıdaki gibidir:

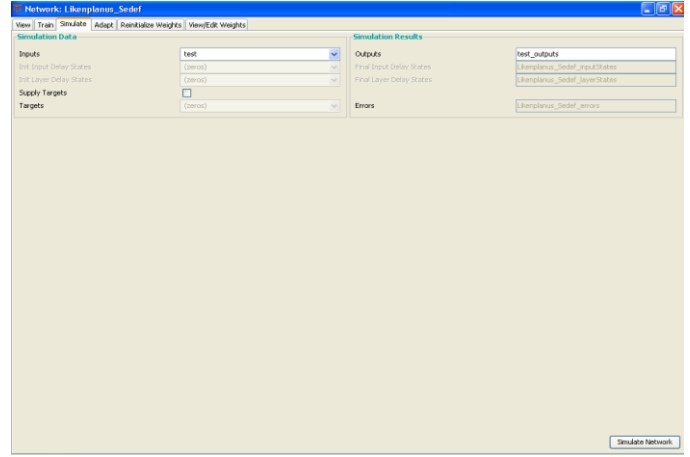
0 0
1 1

Kurulan ağı, sıfıra yakın hatayla ilk 30 hastanın liken planus, sonraki 30 hastanın da sedef hastası olduğunu tahmin etmiştir.







Şekil 8. Yapay sinir ağı eğitim grafiği



Şekil 9. Simülasyon ekran görüntüsü



Şekil 10. Test çıktıları için ağ yönetim ekranı



Şekil 11. Simülasyon sonucu elde edilen test çıktıları

#### 4. Sonuçlar

Yapay sinir ağları matematiksel olarak formülasyonu kurulamayan veya çözümü mümkün olmayan problemlerin çözümünde gün geçtikçe artan bir ivmeyle çeşitli bilim dallarında uygulanmaktadır. Özellikle tıp alanında teşhis ve tahmine dayalı çalışmalar gün geçtikçe artmaktadır. Bazı tıbbi teşhisler doktor tecrübesine dayanmaktadır. Bu durumlarda doktorlara yardımcı olmak ve bazı hastalıkların teşhisini kolaylaştırmak amacıyla yapay sinir ağı ile çeşitli çözümler sunulmaktadır.

Bu çalışmada, 140 hastaya ait 33 nitelikten oluşan deri doku örnekleri yardımıyla, yapay sinir ağları kullanılarak sedef ve liken planus deri hastalıklarının teşhisinde yardımcı olacak bir yöntem gerçekleştirilmiştir. Her iki hastalıktan 40'ar olmak üzere toplam 80 hasta eğitim ve her iki hastalıktan 30'ar olmak üzere 60 hasta ise test verisi olarak belirlenmiştir. Gerçek verilerle elde edilen veriler arasındaki korelasyon katsayısı (0.98) %98'dir. YSA modelinin üretmiş olduğu sonuçların gerçeğe en kuvvetli biçimde yakınsadığı gösterilmiştir.

#### Kaynaklar

- AAD (2013a), <http://www.aad.org/dermatology-a-to-z/diseases-and-treatments/i---l/lichen-planus/signs-symptoms>, Erişim Tarihi: 10.05.2013.
- AAD (2013b) [http://www.aad.org/skin-conditions/dermatology-a-to-z/guttate-psoriasis#](http://www.aad.org/skin-conditions/dermatology-a-to-z/guttate-psoriasis#.UbjoQiRrOM8). Erişim Tarihi: 12.10.2013.
- AAFP (2013) <http://www.aafp.org/afp/2011/0701/p53.html> Erişim Tarihi: 08.10.2013.
- Anonim (2013a), <http://tr.wikipedia.org/wiki/Dermatoloji>, Erişim Tarihi: 15.09.2013.
- Anonim (2013b) <http://www.hemensaglik.com/makale/sedef-hastaliginin-belirtileri>, 10.09.2013.
- Chen, L., Zhou J., Liu, Z., Chen, W. & Xiong, G. (2002). A skin detector based on neural network. IEEE 2002 International Conference on Communications, Circuits and Systems and West Sino Expositions, Vol. 1, 615–619.
- Ganesan, N., Venkatesh K., Rama A. & Malathi Palani, A. (2010). Application of neural networks in diagnosing cancer disease using demographics data. *International Journal of Computer Applications*, 1 (26), 81–97.
- Hamzaçebi, Ç. (2011). Yapay Sinir Ağları. Ekin Yayınevi, s:46.

- Henseler, T. (1998). The genetics of psoriasis. *Arch Dermatol Res*, 290:463–476.
- ICS (2013) <http://archive.ics.uci.edu/ml/datasets/Dermatology>. Erişim Tarihi: 08.04.2013
- Jaleel A., Salim S. & Aswin R. B. (2012). Artificial neural network based detection of skin cancer. *International Journal of Advanced Research in Electrical, Electronics and Instrumentation Engineering*, 1 (3):200–205.
- Kabari, L.G. & Bakpo, F.S. (2009). Diagnosing skin diseases using an artificial neural network. 2nd International Conference on Adaptive Science & Technology, 187–191.
- Kurd S.K. & Gelfand J.M. (2009). The prevalence of previously diagnosed and undiagnosed psoriasis in US adults: results from NHANES 2003–2004. *J Am Acad Dermatol* 60:218–224.
- Louis A.K., Maass D. & Rieder A. (1997). *Wavelets Theory and Applications*. John Wiley & Sons.
- Öztemel, E., (2012). *Yapay Sinir Ağları*. Papatya Yayıncılık, s:51.
- Shawkatová I., Javor J., Párnická Z., Kozub P., Žilínková M., Frey P., Ferenčík S. & Buc M. (2012). HLA-C, DRB1 and DQB1 alleles involved in genetic predisposition to psoriasis vulgaris in the Slovak population. *Folia Microbiologica*, 58:319–324.
- Zang, G., Patuwo, B.E. & Hu, M.Y. (1998). Forecasting with artificial neural networks: The state of the art. *International Journal of Forecasting*, 14:35–62.
-