

Osteoporoz riskinin yapay sinir ağları yöntemi ile saptanması Determination of osteoporosis risk using by neural networks method

Veysi AKPOLAT

Dicle Üniversitesi Tıp Fakültesi
Biyofizik Anabilim Dalı
DİYARBAKIR

E-posta: vakpolat@dicle.edu.tr

ÖZET

Yapay sinir ağları (YSA), farklı disiplinlerdeki karmaşık problemlerin çözümlenmesinde kabul gören ve uygulamalarda sıklıkla yer alan modelleme araçları haline gelmiştir. Son yıllarda sedanter yaşamın yaygınlaşması, yanlış beslenme alışkanlıkları, obezite, diyabet, kemiklerde mekanik stres etkisi yaratacak aktif yürüyüş egzersizlerinin ihmal edilmesi gibi nedenlerden dolayı osteoporoz gelişme hızı ve oranı da paralel olarak artmıştır. Bayanlarda kemik yoğunluğu ile korelasyonu olduğu düşünülen kilo, boy, menapoz yaşı ve yaş bilgilerine dayalı örüntüler, YSA'lar tarafından sınıflandırmak üzere değerlendirilmiştir. Bu çalışmada açıklanan öğrenme ve sınıflama süreci, bayanlarda kemik yoğunluğunun hangi seviyede olduğunu (Risk var / Risk yok) belirlenmesi amacıyla kullanılmıştır. Sınıflandırma işlemi için farklı YSA mimarisi kullanılmış ve en başarılı mimari saptanmıştır. Kullanılan mimariler; Çok katmanlı algılayıcı (ÇKA), LVQ ve SOM (Self Organizing Map) ağlarıdır. Performans belirleyiciler ve istatistiksel ölçümler ile mimariler değerlendirilmiş ve sonuçlar osteoporoz hastalığının sınıflandırmasında ÇKA mimarisinin en başarılı mimari olduğunu göstermiştir.

Anahtar Kelimeler: Osteoporoz, Yapay sinir ağları, sınıflama

ABSTRACT

Artificial neural networks (ANNs) have become modeling tools that have found extensive acceptance and they have frequently used in applications in many disciplines for solving complex problems. Different ANN structures are valuable models, which are used in the medical field for the development of decision support systems. In this paper, the learning and classification processes are used for determining the level of bone-density (safe / risk of osteoporosis) in woman. In this study, three different structured neural networks were used for classifying of osteoporosis and the most efficient structure was determined. The training network structures were Multilayer perceptron neural network (MLP), Linear Vector Quantization (LVQ) and Self Organizing Map (SOM). Performance indicators and statistical measures were used for evaluating the structures and the results demonstrated that the MLP was the most efficient structure for classifying of osteoporosis.

Key words: Osteoporosis, Artificial neural networks, classification

Geliş Tarihi / Received: 04.01.2008,
Kabul Tarihi / Accepted: 10.01.2008,
Copyright © Dicle Tıp Dergisi 2009

GİRİŞ

Tıbbi karar verme çok yönlü bir işlemdir ve amaç doğru teşhis yapılmasıdır. Bu amaca ulaşmak için uygun verinin bulunması, verinin özelliklerinin çıkarılması ve yeni verinin analizinin yapılması gerekmektedir. Hekimler, karar verme işleminde çeşitli istatistiksel teknikler ile veriyi işlemektedirler. Verinin karmaşıklığı ve boyutunun artması durumunda veri analizi için bilgisayarların kullanımı gerekli olmaktadır. İstatistiksel analizlerin bilgisayar ile yapılmasının yanı sıra bilgisayar destekli veri sınıflama, YSA uygulamaları arasında yer almaktadır. Son zamanlardaki gelişmeler incelendiğinde, tıpta bilgisayar destekli karar verme uygulamalarına yönelik çalışmalarda artış olduğu görülmektedir. Hastalık teşhisleri, veri sınıflama işlemi olarak incelenebilmektedir. Girişlerin belirsiz olması ve değişkenlik göstermesi durumunda, YSA'nın veri sınıflamada başarılı olduğu görülmektedir¹⁻⁵.

YSA yöntemi ile kemik yoğunluğuna ilişkin birçok araştırmalar yapılmıştır. Çalışmaların çoğunluğu tanı ve sınıflama üzerinedir. Bu çalışmalardan bazıları; kemikteki tümörün saptanması için MR görüntülerinin YSA ile analizi⁶, Avrupa Üroloji Derneğinin (EAU) konuya ilişkin bilgilerinin YSA ile kullanımı sonucu gereksiz kemik taramalarının azaltılması⁷, spor yaralanmalarında özellikle bacakta (lower leg) meydana gelen kemik dokusunun zedelenmesine ilişkin elde edilen radiographic tibia görüntülerinin YSA-Bulanık mantık yöntemleri ile sınıflandırılması⁸, bir amerikan ve iki fransız yetişkin üzerinde Lumbarspine T skorlarının klasik yöntemler ile karşılaştırılmasıdır⁹. Bu çalışmada ise bayanlarda korelasyonu olduğu düşünülen çeşitli ölçümlere (kilo, boy, yaş ve menapoz yaşı) dayalı olarak oluşturulan YSA modeli ile bayanların vertebra kesimindeki kemik yoğunluğu seviyesi saptanmaya çalışılmıştır. Vertebra kesiminin özellikle seçilmiş olmasının sebebi, trabeküler yapısından dolayı kemik yoğunluğu azalmasının en erken görüldüğü bölge olmasındandır.

Bir yapay sinir ağı, birbiriyle etkileşim içindeki pek çok yapay nöronun paralel bağlı bir hiyerarşik organizasyonudur¹⁰. Bilgilerin kurallar şeklinde açıklandığı klasik uzman sistemlerin tersine, YSA gösterilen örnekten öğrenerek kendi kurallarını

oluşturur¹¹. Kohonen, YSA'nın uyarlanırlı elemanların yoğun bir şekilde paralel olarak bağlanmasıyla oluşan ve gerçek dünyadaki cisimlerle aynen biyolojik sistemin yaptığı gibi ilişkide bulunabilmeleri için hiyerarşik organizasyonları düzenlenmiş yapılar olduğuna dikkat çekmiştir¹². Farklı disiplinlerdeki problemlerin çözümlenmesinde kullanılabilen YSA için farklı ağ mimarileri ve farklı eğitim algoritmaları geliştirilmiştir.

Bu çalışmada, bayanlarda kemik yoğunluğuna ilişkin osteoporoz hastalığının teşhisi için ÇKA, LVQ ve SOM ağ mimarileri kullanılmıştır. Performans belirleyiciler ve istatistiksel ölçümler ile YSA mimarilerinin değerlendirilmesi yapılmış ve osteoporoz hastalığının teşhisi için en iyi performansı sergileyen mimari yapı belirlenmiştir.

Kemik Mineral Yoğunluğunda Azalma

Kemikler hiç bir şeyden etkilenmeyen cansız madde olmayıp, damarsal ve biyokimyasal faktörlerden, iç salgı ve beslenme değişikliklerinden, enfeksiyonlardan ve travmadan etkilenen canlı dokulardır. Kemik iliğinin ise kan hücrelerini yapmak gibi önemli bir görevi vardır. Kemik başlıca iki kısımdan oluşur. Kemiğin organik çatısı (osteoid doku) ve bu çatı üzerine oturan inorganik tuzlar (Kalsiyum ve Fosfor)¹³.

Osteoid doku sürekli olarak yıkılıp yenilenen bir dokudur. Kemikte bulunan osteoklastlar (kemik yıkımından sorumlu hücreler) osteoid dokuyu yıkar, osteoblastlar (kemik yapımından sorumlu hücreler) ise yeni osteoid doku yapar. Yeni yapılan osteoid madde yıkılandan az ise kemikte osteoid gittikçe azalmaya başlar ve dolayısıyla inorganik tuzların çökeceği yerlerin de azaldığı görülür. Osteoid madde miktarının kemikte azalması, kemiğin hafiflemesine ve direncinin düşmesine sebep olur. Böylece düşük kemik kitlesi ve kemik dokusunun mikromimari yapısının bozulması sonucu kemik kırılabilirliğinde artış ve kırıklara yatkınlık ile karakterize, sık rastlanan bir iskelet sistemi hastalığı olan osteoporoz meydana gelir¹⁴. Osteoporoz kemikteki osteoid doku kitlesinde meydana gelen azalmadır. Osteoporoz kemiğin trabeküler kısmında belirgindir. Osteoporozda, bu kısma ilişkin direncin iyice azalmış olması erken tanı

açısından oldukça önemlidir. Akpolat, kemik yoğunluğunun saptanmasına yönelik yapmış olduğu çalışmada sadece MLP sinir ağı mimarisini kullanmıştır¹⁵. Bu çalışmada ise birden fazla mimari kullanılarak durum değerlendirilmiştir.

Bayanlara ilişkin kilo, boy, yaş ve menapoz yaşı bilgileri ağın giriş parametreleri olup, ağın eğitim kümesini oluşturmaktadır. Hedeflenen küme bilgisi ise kemik-mineral-yoğunluğudur (birim:g/cm²). Kemik kitlesi çeşitli şekillerde ifade edilebilir. Bu ifadelerden bir tanesi belirli bir iskelet bölgesinden ölçülen kemik-mineral-içeriğidir (KMİ). Bir bölgedeki KMİ' nin bu bölgenin alanına bölünmesiyle elde edilen değer kemik-mineral-yoğunluğu (KMY) olarak adlandırılır. Çalışmada hedeflenen küme içeriğini oluşturan KMY bilgileri için kemik-dansitometre cihazı olarak DEXA Hologic Discovery A (S/N 81053) QDR 4500 serisi kullanılmıştır.

Yapay Sinir Ağları Yöntemi

Osteoporoz/Osteopeni hastalığının teşhisi için ÇKA, LVQ ve SOM YSA mimarileri kullanılmıştır. Bunlardan ÇKA ağı öğreticili öğrenme, LVQ ağı destekleyici öğrenme ve SOM ağı ise öğreticisiz öğrenme stratejisine sahiptirler.

Çok Katmanlı Algılayıcılar (ÇKA): Yapay sinir ağlarında ileri yol yapısındaki ağlara ait parametrelerin güncellenmesi için literatürde sıkça karşılaşılan yöntem olan geriye yayılma algoritması kullanılmıştır. Bu yöntem, kuadratik bir amaç ölçütünün ağ parametrelerinin uyarlanması ile enküçültme-sine dayanmaktadır⁹. Ağ yapısı en az üç katmandan oluşur. Bunlar giriş, gizli ve çıkış katmanlarıdır. Verilen eğitim kümesi için ortalama karesel hata öğrenme performansının ölçütü olarak alınır ve bu amaç ölçütünü enküçültme parametreler belirlenir¹⁵.

LVQ (Linear Vector Quantization) Ağı: Bazı ağ modellerinde, ağa çıktının ne olduğunu vermek mümkün olmamaktadır; fakat, ağın üretmiş olduğu çıktının doğru veya yanlış olduğu belirtilmektedir. Destekleyici öğrenme (reinforcement learning) olarak belirlenen bu yöntemi kullanan modellerin bir tanesi de "doğrusal vektör parçalı" modeli diyebileceğimiz LVQ (Linear Vector Quantization) modelidir¹⁶. Giriş, Kohonen ve çıkış olmak üzere üç katmanlı bir YSA mimarisine sahiptir.

Eğitim sürecinde girdilerin sınıflara ayrılması, en yakın komşu (nearest neighbour) kuralına göre gerçekleştirilir. Girdi vektörü ile referans vektörleri arasındaki en kısa mesafe aranmakta ve girdi vektörünün en kısa mesafede bulunan vektör grubuna ait olduğu varsayılmaktadır. Mesafenin hesabı için öklid (euclid) uzaklık bağıntısı kullanılır. Ağın ağırlıkları değiştirilerek, girdileri doğru sınıfa ayıracak referans vektörleri saptanır. Çıktı değerlerinin belirlenmesinde "kazanan her şey alır" (winner takes all) stratejisi uygulanır. Girdi vektörüne en yakın olan vektör, kazanan vektör olarak adlandırılır. Kazanan vektör doğru sınıfın üyesi ise ilgili ağırlıklar girdi vektörüne biraz daha yaklaştırılır. Kazanan vektör yanlış sınıfın üyesi ise ağırlık vektörü girdi vektöründen uzaklaştırılır¹⁶.

SOM Ağları: Öğreticisiz öğrenme stratejisine sahip olup, sınıflandırma problemleri için kullanılır. Yapısal olarak diğer ağlara göre farklılık gösterir. Çıktı katmanı 2 boyutlu bir düzlemi göstermektedir. Nöronlar bu düzlem üzerine dağılmış vektörleri gösterir. Öğrenme işlemi üç bölümden oluşur; yarışma (Competition), işbirliği (Cooperation) ve sinaptik adaptasyon (Synaptic Adaptation). Yarışma sürecinde, kazanan nöron saptanır, işbirliği sürecinde kazanan nöron ile işbirliği yapılacak nöronlar saptanır ve sinaptik adaptasyon sürecinde ise ağırlıklar güncellenir. Ağırlıkların güncellenme süreci sırasıyla özdüzenleme (self-organizing) ve yakınsama (convergence) fazlarından oluşur. Birinci fazda ağırlık vektörlerin kaba değerler ile topolojik dağılım sürecidir (en az 1000 iterasyon). İkinci faz ise özellik haritasının daha hassas şekilde dağılımı sürecidir (iterasyon sayısı, YSA'da bulunan nöron sayısının 500 katı olmalıdır)¹⁷.

Kemik Mineral Yoğunluğunun Saptanması için Gerçeklenen Öğrenme Düzenegi

Kemik yoğunluğunun sınıflandırılması için bu çalışmada kullanılan parametreler; kilo (K), boy (B), yaş (Y) ve menapoz yaşıdır (MY). Korelasyonu olduğu düşüncesiyle dikkate alınan bu parametreler, bu çalışma için temel teşkil etmektedir. Bu parametrelerin oluşturduğu veri kümesinin değer aralıkları; kilo (34-161 Kg), boy (1.37-1.80 m), yaş (20-96), menapoz yaşı (henüz girmemiş-67). Toplam

765 bayandan alınan bilgiler (K, B, Y ve MY) ağı giriş kümesini, DEXA cihazı ile ölçülen KMY verileri ise ağı hedeflenen çıkış kümesini oluşturmaktadır. Ölçülen KMY verileri ve değer aralığı Tablo 1' de

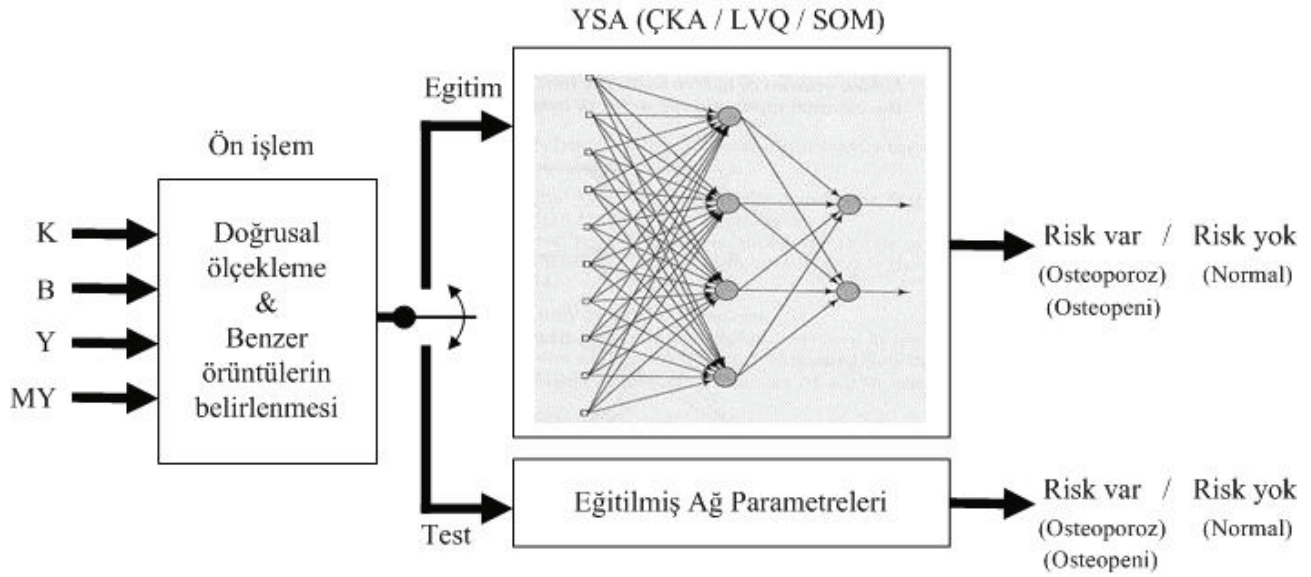
gösterilmiştir. Tabloda görüldüğü üzere, 0.940 değeri eşik seviyesi olarak dikkate alınmıştır. Eşik seviyesinin üzerinde olanlar normal (risk yok), altında olanlar ise hasta (risk var) olarak değerlendirilmiştir

Tablo 1. Kemik mineral yoğunluğunun değer aralığı

KYM değer aralığı	Tanı
$KMY > 0.940$	Normal (Risk yok)
$0.939 > KMY > 0.770$	Osteopeni (Risk var)
$0.769 > KMY$	Osteoporoz (Risk var)

Kemik yoğunluğunun sınıflandırılması için gerçekleştirilen öğrenme düzeneği Şekil 1'de gösterilmiştir. Şekilde görüldüğü üzere, ağı çıkışında iki farklı sınıf bulunmaktadır. Elde edilen sonuca göre bireyin risk durumu saptanmış olur. Eğitim ve test aşamaları öncesinde ön-işlem gerçekleştirilir. Ön-işlem

akışında yer alan doğrusal ölçekleme ile veriler [0 1] aralığında normalize edilir. YSA girişine uygulanacak örüntülerin değer aralığı ile aktivasyon fonksiyonlarına ilişkin değer aralığının birbirini desteklemelidir. Bu desteğin sağlanması için normalize işlemi gerçekleştirilmiştir.



Şekil 1. Kemik yoğunluğunun sınıflandırılması için gerçekleştirilen öğrenme düzeneği

Kemik yoğunluğunun sınıflandırılması için gerçekleştirilen öğrenme düzeneği Şekil 1'de gösterilmiştir. Şekilde görüldüğü üzere, ağı çıkışında elde edilen sonuca göre bireyin risk durumu saptanmış olur. Eğitim ve test aşamaları öncesinde ön-işlem gerçekleştirilir. Ön-işlem

akışında yer alan doğrusal ölçekleme ile veriler [0 1] aralığında normalize edilir. YSA girişine uygulanacak örüntülerin değer aralığı, ağıda kullanılan aktivasyon fonksiyonlarına ilişkin değer aralığı birbirini desteklemelidir. Bu desteğin sağlanması için normalize işlemi gerçekleştirilmiştir.

Ön-işlemin ikinci aşamasında ise normal (risk yok) ve hasta (riski var) örüntüler karşılaştırılır ve birbirlerine benzerlik oranı %95 ve üzeri olan örüntüler kümeden çıkarılır. Böylelikle birbirine benzer olup, farklı kümelerde yer alan örüntüler değerlendirilmeye katılmaz. Bu işlemin ardından, uygulama için 229 (risk yok: 48, risk var: 181) örüntünün belirgin bir farklılığa sahip olduğu görülmüştür. 229 örüntünün 172 tanesi (risk yok: 35, risk var: 137) ağın eğitim sürecinde, geriye kalan 57 (risk yok: 13, risk var: 44) örüntü ağın test sürecinde kullanılmıştır.

Bu çalışmada öğreticili ve destekleyici öğrenme stratejilerine sahip ağlardan sırasıyla ÇKA ve LVQ kullanılmıştır. Ağın çıkış vektörü [0 1] olması durumunda "normal", [1 0] olması durumunda ise "hasta" olarak tanımlanmıştır. Öğreticisiz öğrenme stratejisine sahip ağlar için hedeflenen çıkış kümesi kullanılmaz. Sadece ağın giriş parametreleri (K, B, Y ve MY) dikkate alınarak, verinin uzaydaki dağılımına göre sınıflandırma işlemi gerçekleştirir. Bu çalışmada, öğreticisiz öğrenme stratejisine sahip ağlardan SOM ağı kullanılmıştır.

Ağların Eğitim ve Test Performansları

Osteoporoz/Osteopeni hastalığının teşhisi için üç farklı YSA mimarisi kullanılmıştır. Her mimarinin parametreleri deneysel olarak belirlenmiştir. En iyi sonucu veren mimariler kendi içerisinde karşılaştırılmıştır. Farklı mimarilerdeki ağların performanslarının karşılaştırılmasında, eğitim sürecindeki doğru saptama sayısı, test sürecindeki doğru saptama sayısı ve eğitimdeki merkezi işlemci zamanları incelenmiştir.

ÇKA uygulama sonuçları: Ağın parametreleri deneysel olarak belirlenmiştir. Momentum (0.1, 0.3, 0.5, 0.7 ve 0.9) ve gizli katmandaki nöron sayısının (10,15,20,...50) değişimine göre ağın çıkışında saptanan doğru örüntü sayıları saptanmıştır. En fazla doğru örüntüyü saptayan ağın momentum değeri 0.9 ve gizli katman nöron sayısı 20 dir. En fazla doğruyu saptayan ÇKA mimarisi 4-20-2 olup, eğitim süresince iterasyonun artması ile ortalama karesel hatanın azaldığı saptanmıştır.

Eğitim aşamasının diğer parametre değerleri: gizli katman için öğrenme katsayısı 0.9, çıkış katmanı için

öğrenme katsayısı 0.7 ve kabul edilebilir ortalama karesel hata 0.01' dir. Tüm katmanlarda sigmoid fonksiyonu kullanılmıştır. Yapılan eğitim işlemlerinde, adım sayısının artırılmasıyla ağın performansının artmadığı saptanmıştır. Ağın ezberleme sürecine girmeden eğitimin sonlandırılması amacıyla 500 adımda eğitim süreci sınırlandırılmıştır. En fazla doğruyu saptayan mimari ile elde edilen başarı oranı: Eğitim sürecinde doğru saptanan örüntü sayısı 160/172 (risk yok : 27/35, risk var : 133/137), test sürecinde doğru saptanan örüntü sayısı 49/57 (risk yok : 8/13, risk var : 41/44).

LVQ uygulama sonuçları: Ağın parametre sayısı deneysel olarak belirlenmiştir. Öğrenme katsayısının (0.01, 0.02,..., 0.29, 0.3) değişimine göre ağın çıkışında saptanan doğru örüntü sayıları saptanmıştır. En fazla doğru örüntüyü saptayan ağın öğrenme katsayısı 0.03 olduğu saptanmıştır. Kabul edilebilir ortalama hata 0.0001. Kohonen ve çıkış katmanı arasındaki başlangıç ağırlık katsayıları olarak hedeflenen küme alınmıştır. Giriş ve Kohonen katmanları arasındaki başlangıç ağırlık katsayıları [-0.5 +0.5] aralığında rasgele alınmıştır. Kohonen katmanında yer alan nöron sayısı, olarak örnek sayısı alınmıştır. En fazla doğruyu saptayan öğrenme katsayısı ile elde edilen başarı oranı: Eğitim sürecinde doğru saptanan örüntü sayısı 137/172 (risk yok : 17/35, risk var : 120/137), test sürecinde doğru saptanan örüntü sayısı 41/57 (risk yok : 5/13, risk var : 36/44).

SOM uygulama sonuçları: Ağ parametreleri deneysel olarak saptanmıştır. Ağırlıkların güncellenmesinde, özdüzenleme fazı için 1000 iterasyon, yakınsama fazında 5x5 için 12500 ve 10x10 için 50000 iterasyon yapılmıştır. Diğer parametre değerleri; $\sigma_0=3$, $\eta_0=0.9$, ve $\tau_1=1000/\log\sigma_0$ ve $\tau_2=1000$ Topolojik olarak 5x5 ve 10x10 mimarileri denenmiş olup, elde edilen sonuç şekil 2' de gösterilmiştir.


Şekil 2' de kazanan nöronların simgeledikleri sınıflar görülmektedir. Risk içeren, risk içeren/içermeyen, risk içermeyen ve eğitim boyunca hiç kazanmamış nöronların bulunduğu sınıflar olmak üzere dört farklı sınıf olduğu görülmüştür. 10x10 mimarisi için elde edilen başarı oranı: eğitim sürecinde doğru saptanan örüntü sayısı 84/172 (risk yok: 10/35,

risk var: 74/137), test sürecinde doğru saptanan örüntü sayısı 37/57 (risk yok: 6/13, risk var: 31/44). İşlemci süresi 26 saat 35 dk.

5x5 mimarisi için ise elde edilen başarı oranı: eğitim sürecinde doğru saptanan örüntü sayısı 69/172 (risk yok: 7/35, risk var: 62/137), test sürecinde doğru saptanan örüntü sayısı 29/57 (risk yok : 3/13, risk var : 26/44). İşlemci süresi 2 saat 50 dk. Her iki yapının karşılaştırılması durumunda, 10x10 mimarisinin daha

yüksek bir başarı oranına sahip olduğu görülmektedir. Fakat süre açısından daha uzun bir sürede eğitimi tamamlamıştır.

Yapılan uygulamalar sonucunda, farklı mimarilerin sağladıkları doğru sınıflandırma yüzdeleri Tablo 2' de gösterilmiştir. ÇKA' nın kullanılan giriş kümesi için en yüksek doğru sınıflandırma oranına sahip olduğu görülmektedir. Süre açısından LVQ ise daha kısa bir sürede eğitimi gerçekleştirdiği görülmüştür.



Şekil 2. Topolojik olarak 10x10 ve 5x5 mimarilerinin eğitimi sonunda kazanan nöronların simgeledikleri sınıflar.

Tablo 2. Ağ modellerinin eğitim ve test yüzdeleri

Mimariler	Doğru Sınıflandırma		
	Eğitim (%)	Test (%)	Eğitim süresi
ÇKA	93.03	85.97	24 dk.
LVQ	79.65	71.93	13 dk.
SOM	48.83	64.91	26 saat 35 dk

SONUÇLAR

Yapay sinir ağı kilo, boy, toplam gebelik sayısı, menapoz yaşı ve protez diş sayısı bilgilerine dayalı oluşturulan veri kümesinin analizinde öğrenme ve saptama mekanizması olarak kullanılmıştır. Yapılan çalışmada ağın eğitiminde kullanılan eğitim örüntülerinin artmasıyla, öğrenmenin ilerlediği ve başarının arttığı görülmüştür. Örüntü saptama başarısının artması, doğru ilişkilendirme

yapıldığı şeklinde yorumlanabilir. Kullanılan saptama yöntemi belirsizlik içeren model sorununa çare olarak görülebilir.

Farklı mimarilere sahip üç ağ modeli kurulmuştur. Bunlar; ÇKA, LVQ ve SOM ağlarıdır. En iyi sınıflandırmaya sahip yapı eğitim için % 93.03 ve test için %85.97 yüzdeleriyle ÇKA mimarisidir. Birbirine benzeyen örüntülerin değerlendirilebilmesi için giriş parametre sayısının artırılması gerekmektedir.

Bu yöntemin geliştirilmesi ve başarı oranının artırılması ile, a) risk altında olan grubu sürekli ve daha az maliyetli olarak izleyebilme, b) meydana geldiğinde tedavi maliyeti çok yüksek değerlere ulaşan bu klinik tablonun oluşma riskini önceden saptama, c) risk altındaki insan popülasyonuna koruyucu sağlık hizmetleri sunarak en ucuz maliyetle hastalığın oluşumunu, mevcut ise ilerlemesini önleme imkanı olacaktır.

KAYNAKLAR

1. Tafeit E, Reibnegger G. Artificial Neural Networks in Laboratory Medicine and Medical Outcome Prediction. *Clin Chem Lab Med* 1991;37: 845-53.
2. Güler I, Übeyli ED. Detection of Ophthalmic Artery Stenosis by Least-Mean Squares Backpropagation Neural Network. *Comput Biol Med* 2003;33:333-43.
3. Übeyli ED, Güler I. Neural Network Analysis of Internal Carotid Arterial Doppler Signals: Predictions of Stenosis and Occlusion, *Expert Systems with Applications* 2003;25:1-13.
4. Güler I, Übeyli ED. ECG Beat Classifier Designed by Combined Neural Network Model. *Pattern Recognition* 2005; 38:199-208.
5. Güler I, Übeyli ED. Çok Katmanlı Perseptron Sinir Ağları ile Diyabet Hastalığının Teşhisi, *J Fac Eng Arch Gazi Univ* 2006; 21: 319-26.
6. Frangi AF, Egmont-Petersen M, et al. Bone tumor segmentation from MR perfusion images with neural networks using multi-scale pharmacokinetic features. *Image Vision Computing* 2001; 19: 679-90.
7. Lynn N, et al. Use of artificial Neural Network together with EAU guidelines to reduce unnecessary bone scans, *Eur Urol Supplements* 2003; 2: 77.
8. John RI, et al. Neuro-fuzzy clustering of radiographic tibia image data using type 2 fuzzy sets. *Information Sci* 2000;125: 65-82.
9. Levasseur R, et al. The absorptiometry T score: influence of selection of the reference population and related considerations for everyday practice, *Joint Bone Spine* 2003; 70: 290-3.
10. Zurada JM, *Introduction To Artificial Neural Networks*, West Publishing Com., 1992: 120-5.
11. Rojas R. *Neural Networks, A Systematic Introduction*, Springer, Germany, 1996: 66-72.
12. Kohonen T. *Content Addressable Memories*, Springer-Verlag, New York, 1980: 12-20.
13. Kumar, Cofran, Robbins, *Basic Pathology*, first edition, W.B.Saunders Company, 1999: 20-6.
14. Marcus R, Feldman D, Kelsey J. *Osteoporosis*, 1st. edition, Academic Press, San Diego, 1996: 13-45.
15. Akpolat V, Özerdem MS, Çelik MS. Kemik Yoğunluğunun Yapay Sinir Ağları ile Saptanması, 17. Ulusal Biyofizik Kongresi, İzmir, 7-9 Eylül 2005
16. Öztemel E. *Yapay Sinir Ağları*, Papatya yayıncılık, İstanbul, 2003: 45-60.
17. Haykin S. *Neural Networks, A Comprehensive Foundation*, Upper Saddle River, N.J.: Prentice Hall, 1999: 112-8.