

Yapay Sinir Ağları Yöntemi ve Bu Yöntem Kullanılarak Psikiyatrik Tanıların Sınıflanması

Neural Networks and Application on Psychiatry Dataset for Classification Diagnosis

Dr. İlker ETİKAN,^a
Dr. Birgül ELBOZAN CUMURCU,^b
Dr. Feryal ÇAM ÇELİKEL,^b
Dr. Ünal ERKORKMAZ^a

^aBiyoistatistik AD,
^bPsikiyatri AD,
Gaziosmanpaşa Üniversitesi
Tıp Fakültesi, Tokat

Geliş Tarihi/Received: 03.07.2008
Kabul Tarihi/Accepted: 28.12.2008

Yazışma Adresi/Correspondence:
Dr. İlker ETİKAN
Gaziosmanpaşa Üniversitesi
Tıp Fakültesi, Biyoistatistik AD, Tokat,
TÜRKİYE/TURKEY
ietikan@hotmail.com

ÖZET Amaç: Hastalık teşhisi tıp alanındaki en önemli problemlerden biridir. Günümüzde tıbbi teşhis probleminde yaygın kullanılan metotlardan biri, yapay sinir ağlarıdır. Bu çalışmada, psikiyatri hastalarına ilişkin bir veri kümesinin farklı yapay sinir ağları ile modellenmesi gerçekleştirilmiştir. Kullanılan ağ yapıları arasında en iyi sonucu veren çok katmanlı algılayıcı ağları [multi layer perception (MLP)]'nin en yüksek doğruluk veren 5 öğrenme algoritması için teşhis doğruluğu kontrol edilmiş ve gerçek performansları gösterilmiştir. **Gereç ve Yöntemler:** Çalışmamızda, yapay sinir ağları tekniği yardımıyla, çeşitli şikâyetlerle 2008 yılı Ocak-Nisan ayları arasında Gaziosmanpaşa Üniversitesi Araştırma ve Uygulama Hastanesi Psikiyatri Polikliniğine başvuran 196 hastaya ait demografik özellikler, Beck depresyon ölçeği (BDÖ) ve Beck anksiyete ölçeği (BAÖ) puanları kullanılarak tanı sınıflaması yapılmış ve bu tanıların ne kadarının, ilk görüşmede yapılan DSM-IV-TR tanı ölçütlerine göre konulan tanı ile eş değer olduğu saptanmıştır. **Bulgular:** Çalışmamıza dahil edilen 196 kişinin 51 (%26)'i erkek, 145 (%74)'i kadındır. Medeni durumları incelendiğinde 130 (%66.3) kişinin evli olduğu gözlenmiştir. Çalışmaya alınan kişilerin eğitim durumlarına bakıldığında 79 (%40.3)'ünün ilkökul, 67 (%34.2)'sinin ise lise mezunu olduğu gözlenmiştir. Meslek gruplarına bakıldığında ise 97 (%49.5) kişinin ev kadını olduğu saptanmıştır. İlk tanıları değerlendirildiğinde, 93 (%47.4) kişide depresif bozukluk, 52 (%26.5) kişide ise anksiyete bozukluğu belirlenmiştir. **Sonuç:** Bu çalışmanın sonucuna göre, ilk görüşmede depresif bozukluklardan şüpheleniliyorsa, Beck depresyon ölçeği ile mutlaka desteklenmesi gerekmektedir.

Anahtar Kelimeler: Yapay sinir ağları; psikiyatri; depresyon bozuklukları

ABSTRACT Objective: Diagnosis of diseases is among the major problems in medicine. Recently, artificial neural networks are widely used in medical diagnostic problems. In this study, disease dataset was modeled by using various neural networks. Among these networks, the five different learning algorithms of multi-layer perception (MLP), which gives the best results, were tested and the real performances of the algorithms were shown. **Material and Methods:** In this study, by the aid of artificial neural networks methods, demographic characteristic of 196 patients who presented to the Gaziosmanpaşa Hospital from January 2008 to April 2008 with various complaints were recorded and they were given the Beck depression scale and Beck anxiety scale to make a diagnostic classification and to assess how compatible this classification was with the initial diagnosis, which was based on DSM-IV-TR diagnosis criterion. **Results:** Of the participants, 51 (26%) were males and 145 (74%) were females; 130 (63.3%) were married; 79 (40.3%) were primary school and 67 (34.2%) were high school graduates; and 97 (49.5%) were housewives. Ninety-three participants (47.4%) depression and 52 (26.5%) had anxiety disorder. **Conclusion:** Beck depression scale should be used whenever there is a suspicion of depression in the initial assessment.

Key Words: Neural networks (computer); psychiatry; depressive disorder

YAPAY SİNİR AĞLARININ TARİHÇESİ

Yapay sinir ağları (YSA) ile ilgili çalışmalar XX. yüzyılın ilk yarısında başlamış ve günümüze kadar büyük bir hızla devam etmiştir. Bu çalışmalarını 1970 öncesi ve sonrası diye iki bölüme ayırmak mümkündür. Zira 1970'li yıllar YSA için bir dönüm noktasını teşkil etmiş, daha önce aşılması imkânsız görünen pek çok problem bu dönemlerde aşılmıştır.¹

İlk YSA modeli 1943 yılında, bir sinir hekimi olan McCulloch ile bir matematikçi olan Pitts tarafından gerçekleştirilmiştir. McCulloch ve Pitts, insan beyninin hesaplama yeteneğinden esinlenerek, elektrik devreleriyle basit bir sinir ağı modellemişlerdir.

1957 yılında Rosenblatt'ın "Perceptron"u geliştirmesinden sonra, YSA ile ilgili çalışmalar hız kazanmıştır. "Perceptron"; beyin işlevlerini modelleyebilmek amacıyla yapılan çalışmalar sonucunda ortaya çıkan tek katmanlı eğitilebilen ve tek çıkışa sahip bir ağ modelidir.²

1988 yılında, Broomhead ve Lowe radyal tabanlı fonksiyonlar [Radial Basis Functions (RBF)] modelini geliştirmiş ve özellikle filtreleme konusunda başarılı sonuçlar elde etmişlerdir. Daha sonra Spect, bu ağların daha gelişmiş şekli olan probabilistik ağlar (PNN) ve genel regresyon ağları (GRNN)'nı geliştirmiştir.³

YSA'lar; insan beyninden esinlenerek, öğrenme sürecinin matematiksel olarak modellenmesinin uğraşı sonucu ortaya çıkmıştır. Bu nedenledir ki, bu konu üzerindeki çalışmalar ilk olarak beyni oluşturan biyolojik üniteler olan nöronların modellenmesi ve bilgisayar sistemlerinde uygulanması ile başlamış, daha sonraları bilgisayar sistemlerinin gelişimine de paralel olarak birçok alanda kullanılır hale gelmiştir.⁴

YAPAY SİNİR AĞLARININ GENEL ÖZELLİKLERİ

YSA'lar, uygulanan ağ modeline göre değişik karakteristik özellikler göstermelerine karşın, temel birkaç ortak özelliğe sahiptirler.

Birinci özellik; YSA'larda sistemin paralellığı ve toplamsal işlevin yapısal olarak dağılımıdır.⁵ YSA'lar birçok nöronun meydana gelir ve bu nö-

ronlar eş zamanlı çalışarak karmaşık işlevleri yerine getirir. Diğer bir deyişle, karmaşık işlevler birçok nöronun eş zamanlı çalışmasıyla meydana getirilir. Süreç içerisinde bu nöronlardan herhangi biri işlevini yitirse dahi sistem güven sınırları içerisinde çalışmasına devam edebilir.

İkinci özellik ise genelleme yeteneği, diğer bir deyişle ağ yapısının, eğitim esnasında kullanılan sayısal bilgilerden eşleştirmeyi betimleyen kaba özellikleri çıkarsaması ve böylelikle eğitim sırasında kullanılmayan girdiler için de, anlamlı yanıtlar üretebilmesidir.⁶ Üçüncü olarak; ağ fonksiyonları doğrusal olmayan olabilmektedir. Yapı üzerinde dağılmış belli tipteki doğrusal olmayan alt birimler özellikle, istenen eşleştirmenin denetim ya da tanımlama işlemlerinde olduğu gibi doğrusal olmayan olması durumunda işlevin doğru biçimde yerine getirilebilmesini matematiksel olarak olası kılarlar.

Dördüncü özellik ise; ortamda tasarlanan YSA'ların donanımsal gerçekleştirilebilirlikleridir. Bu özellik belki de YSA'ların günlük hayatta daha da fazla yaşamımızın içine gireceğinin (girebileceğinin) göstergesidir.

YAPAY SİNİR AĞLARININ KULLANILDIĞI ALANLAR

YSA'ların kullanım alanları;

Psikoloji, istatistik, biyoloji, finansal, askeri, güvenlik, ekonomi, elektronik, bilgisayar bilimleri ve tıp olarak gösterilebilir.

YSA'lar; çok sayıda ve karmaşık yapıdaki özelliklerin birbiri arasındaki ilişkileri açıklamak, bireyleri bu özelliklerinden yararlanarak sınıflamak, belirli özelliklere sahip kişilerin gelecekteki durumunu tahmin etmek amacıyla model geliştirmek, bu modelleri kıyaslamak, veri indirgemek gibi pek çok amaçla kullanılmaktadır.⁷

YSA'ların avantajlarını özetlersek; büyük ve karmaşık yapıdaki veri setleri için çözüm elde etme özelliğine sahip olması, herhangi bir dağılım şartı bulunmaması, çok değişkenli doğrusal olmayan problemlere uygulanabilmesi, bağımlı ve bağımsız değişkenler arasındaki karmaşık doğrusal olmayan ilişkileri tespit edebilmesi, tahmin edici değişkenler arasındaki tüm olası etkileşimleri tespit edebilmesidir.⁸

Bu yöntemin de kendine has bazı dezavantajları vardır. Bunlar; çok büyük veri seti gerektirmesi, veriye uygun modelin belirlenmesinde çok fazla hesaplama işlemi gerektirmesi ve kullanılan bilgisayar programlarının maliyetinin yüksek olmasıdır.⁹

Bu çalışma, YSA tekniği yardımı ile Beck depresyon ölçeği (BDÖ) ve Beck anksiyete ölçeği (BAÖ)'nin skorları kullanılarak bu tanılarının ne kadarının ilk görüşmede yapılan DSM-IV-TR tanı ölçütleri ile eş değer olduklarını araştırmak amacıyla yapılmıştır.

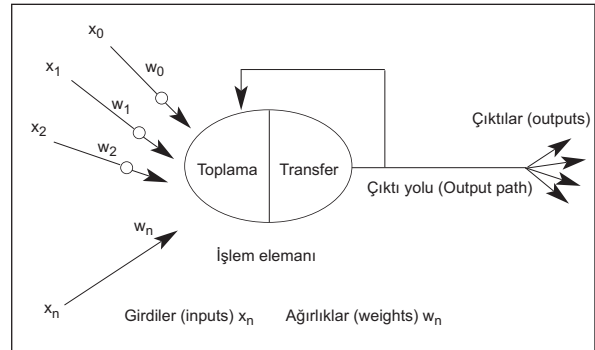
GEREÇ VE YÖNTEMLER

Çalışmamızda, YSA tekniği kullanılarak, çeşitli şikâyetlerle Gaziosmanpaşa Üniversitesi Araştırma ve Uygulama Hastanesi Psikiyatri Polikliniğine başvuran 196 hastaya ait demografik özellikler, BDÖ ve BAÖ skorları kullanılarak tanı sınıflaması yapılmış ve bu tanılarının ne kadarının, ilk görüşmede yapılan DSM-IV-TR tanı ölçütlerine göre konulan tanı ile eş değer olduğu saptanmıştır.^{1,10,11} Birçok klinik deneme modelinde, çok fazla sayıda parametrenin tahmininin gerekmesi, çok fazla sayıda faktörün karşılıklı etkileşimine bağlı olarak tahmin yapılabilmesi amacıyla yeni analitik teknikler geliştirilmiştir. Bu tekniklerden biri de son yıllarda önemi gittikçe artan YSA'lardır. YSA tekniği doğrusal olmayan karmaşık veri setlerini analiz etme özelliği nedeni ile dikkat çekici bir tekniktir (Şekil 1, 2).

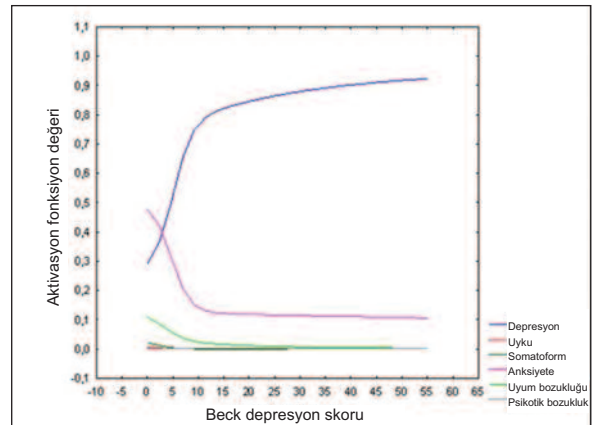
YSA'nın hesaplama ve bilgi işleme gücünü, paralel dağılmış yapısından, öğrenebilme ve genelleme yeteneğinden aldığı söylenebilir. Genelleme, eğitim ya da öğrenme sürecinde karşılaşılmayan girişler için de YSA'nın uygun tepkileri üretmesi olarak tanımlanır. Bu üstün özellikleri, YSA'nın karmaşık problemleri çözebilme yeteneğini gösterir. YSA'nın temel işlem elemanı olan hücre, doğrusal değildir. Dolayısıyla hücrelerin birleşmesinden meydana gelen YSA da doğrusal değildir ve bu özellik bütün ağa yayılmış durumdadır. Bu özelliği ile YSA, doğrusal olmayan karmaşık problemlerin çözümünde en önemli araç olmuştur. YSA'nın arzu edilen davranışı gösterebilmesi için amaca uygun olarak ayarlanması gerekir. Bu, hücreler arasında doğru bağlantıların yapılması ve bağlantıların uygun ağırlıklara sahip olması gerektiğini ifade eder. YSA'nın karmaşık yapısı nede-

niyle bağlantılar ve ağırlıklar önceden ayarlı olarak verilemez ya da tasarlanamaz. Bu nedenle YSA, istenen davranışı gösterecek şekilde ilgilendiği problemten aldığı eğitim örneklerini kullanarak problemi öğrenmelidir. YSA, ilgilendiği problemi öğrendikten sonra eğitim sırasında karşılaşmadığı test örnekleri için de arzu edilen tepkiyi üretebilir. Örneğin; karakter tanıma amacıyla eğitilmiş bir YSA, bozuk karakter girişlerinde de doğru karakterleri verebilir ya da bir sistemin eğitilmiş YSA modeli, eğitim sürecinde verilmeyen giriş sinyalleri için de sistemle aynı davranışı gösterebilir.¹²

YSA, ilgilendiği problemdeki değişikliklere göre ağırlıklarını ayarlar. Yani, belirli bir problemi çözmek amacıyla eğitilen YSA, problemdeki değişimlere göre tekrar eğitilebilir ve değişimler devamlı ise gerçek zamanda da eğitime devam edilebilir. Bu özelliği ile YSA, uyarlamalı örnek tanıma, sinyal işleme, sistem tanılama ve denetim gibi alanlarda etkin olarak kullanılır.¹³



ŞEKİL 1: Basit bir yapay sinir ağı modeli.



ŞEKİL 2: Beck depresyon ölçeğine göre aktivasyon fonksiyon değerleri.

YSA, çok sayıda hücrenin çeşitli şekillerde bağlanmasından oluştuğu için paralel dağılmış bir yapıya sahiptir ve ağır sahip olduğu bilgi, ağdaki bütün bağlantılar üzerine dağılmış durumdadır. Bu nedenle, eğitilmiş bir YSA'nın bazı bağlantılarının hatta bazı hücrelerinin etkisiz hale gelmesi, ağır doğru bilgi üretmesini önemli ölçüde etkilemez. Bu nedenle, geleneksel yöntemlere göre hatayı tolere etme yetenekleri son derece yüksektir.¹⁴

İSTATİSTİKSEL ANALİZ

Veriler Statistica paket programının neural network modülü ile değerlendirilirken, değişik boyutlarda girdi, gizli ve çıktı tabakaları ile çok tabakalı algılayıcı (MLP) ve radial tabanlı fonksiyon (RBF) ağları uygulanmış ve kullanılan veriye en uygun ağ performans değerlerine ve hata miktarlarına bağlı olarak seçilmiştir.

BULGULAR

Bu çalışmada, geriye yayılım algoritması ile eğitilmiş çok tabakalı yapay sinir ağı (GYSA) kullanılmıştır.

GYSA öngörü (prediction) ve sınıflandırma işlemleri uygunluğu ve doğrusal olmayan yapıların analizi için kullanışlı olması nedeni ile sıkça kullanılmaktadır. Günümüzde en yaygın olarak kullanılan yapay sinir ağı modeli geri yayılım algoritmasıdır. Pratik olarak ele alındığında başarılı görünmesine rağmen ciddi eğitim problemleri vardır ve yakınsama işlemi çok yavaştır. Her ne kadar öğrenme katsayısının ve momentum katsayısının iyi optimize edilmesiyle sağlanan bir iyileşme söz konusu olsa da gerçek zamanlı işlemlerde etkisiz kalırlar ve zamanı da iyi kullanamazlar.¹⁵

Radyal tabanlı fonksiyonlar (RTA), yukarıda bahsettiğimiz yönlerden GYA'nın etkileyici bir alternatifi olmuştur. Bu sistemlerin yakınsaması mümkün değildir ve bunun yanında eğitim hızlı ve kolay olabilmektedir.

Radyal tabanlı ağlarının en belirgin özelliği, gizli katmanlardaki işlem birimlerini lineer olmaksızın çıkararak statik Gauss fonksiyonuna sahip olmasıdır. Gauss fonksiyonu, girdi alanının ortalandığı yerinde küçük bir girdi bölgesine cevap verir. Başarılı bir RTA gerçekleştirmek için Gauss fonksiyonu için uygun merkezler bulunmalıdır. Bu işlemler ancak danışmanlı öğrenme yapısında

mümkün olmasına rağmen danışmansız öğrenme yaklaşımı daha tutarlı sonuçlar üretmektedir.¹⁶

Çalışmamıza dahil edilen 196 kişinin 51 (%26)'i erkek, 145 (%74)'i kadındır. Medeni durumları incelendiğinde 130 (%66.3) kişinin evli olduğu gözlenmiştir. Çalışmaya alınan kişilerin eğitim durumlarına bakıldığında 79 (%40.3)'ünün ilköğretim, 67 (%34.2)'sinin ise lise mezunu olduğu saptanmıştır. Meslek gruplarına bakıldığında ise 97 (%49.5) kişinin ev hanımı olduğu gözlemlenmiştir. İlk tanımlara bakıldığında ise 93 (%47.4) kişinin depresif bozukluğa, 52 (%26.5) kişinin ise anksiyete bozukluğuna sahip oldukları görülmüştür (Tablo 1).

TABLO 1: Çalışmada kullanılan değişkenlerin tanımlayıcı bilgileri.

Değişkenler	n	%	
Cinsiyet	Erkek	51	26
	Kadın	145	74
Medeni durum	Bekar	51	26.1
	Boşanmış	6	3.1
	Dul	9	4.6
	Evli	130	66.3
Eğitim durumu	Okur yazar değil	13	6.6
	Okur yazar	8	4.1
	İlköğretim	79	40.3
	Lise	67	34.2
	Üniversite	29	14.8
Meslek	Emekli	9	4.6
	Ev hanımı	97	49.5
	İşçi	6	3.1
	Memur	30	15.3
	İşsiz	8	4.1
	Öğrenci	27	13.8
	Serbest	15	7.7
İlk tanı	Çiftçi	4	2
	Depresif bozukluk	93	47.4
	Anksiyete bozukluğu	52	26.5
	Uyum bozukluğu	16	8.2
	Psikotik bozukluk/şizofreni	12	6.1
	Uyku bozukluğu	7	3.6
	Somatoform bozukluk	16	8.2
	Ortalama	Standart Sapma	
Yaş	35.75	12.21	
Beck depresyon puanı	22.44	12.42	
Beck anksiyete puanı	22.87	13.30	

TABLO 2: Kullanılan ağlara özel bilgiler.

Ağ no	Ağ profili	Eğitime performansı	Sınıflama performansı	Test performansı	Eğitime hatası	Sınıflama hatası	Test hatası
1	MLP 7:21-11-3:1	0.942675	0.00	0.717949	0.459582	0.00	2.363802
2	RBF 6:20-15-3:1	0.668790	0.00	0.765103	0.383907	0.00	0.409120
3	RBF 6:20-23-3:1	0.751592	0.00	0.615385	0.358460	0.00	0.3398019
4	Linear 6:20-3:1	0.808917	0.00	0.717949	0.347218	0.00	0.363405
5	Linear 7:21-3:1	0.808917	0.00	0.717949	0.346530	0.00	0.357491

TABLO 3: Sensitivite analizi 1-5 (yapay sinir ağları).

	Cins	Yaş	Medeni durum	Eğitim	Meslek	Beck depresyon ölçeği	Beck anksiyete ölçeği
Oran1	1.219125	0.968420	1.416582	1.234878	1.283850	1.847124	1.037660
Rank1	5.000000	7.000000	2.000000	4.000000	3.000000	1.000000	6.000000
Oran2	1.027801		1.074536	1.119001	1.198792	1.114723	0.997619
Rank2	5.000000		4.000000	2.000000	1.000000	3.000000	6.000000
Oran3	1.053678		1.209967	1.433773	1.499986	1.187911	1.041400
Rank3	5.000000		3.000000	2.000000	1.000000	4.000000	6.000000
Oran4	1.025165		1.011946	1.008785	1.017358	1.303175	1.053236
Rank4	3.000000		5.000000	6.000000	4.000000	1.000000	2.000000
Oran5	1.018774	1.006567	1.013916	1.011858	1.023589	1.300695	1.053042
Rank5	4.000000	7.000000	5.000000	6.000000	3.000000	1.000000	2.000000

TARTIŞMA

Hastalık teşhisi tıp alanındaki en önemli problemlerden biridir. Genellikle YSA modellerinin bazı klasik istatistiksel yöntemlerin geliştirilmiş hali olduğu görülmüştür. İstatistikte YSA'nın en sık kullanımı doğrusal olmayan regresyon analizi veya sınıflandırma amaçlıdır. Bunların yanı sıra YSA algoritmalarının parametrik olmayan istatistiksel yöntemlerle de yakın ilişkisi vardır. Doğrusal olmayan modellerde kullanılan pek çok istatistiksel yöntem ile ileri beslemeli YSA algoritmaları eğitilerek sonuç üretilebilmektedir. YSA'nın tıpta uygulamaları daha oldukça yenidir. 2005 yılında Çolak ve ark.nın "Aterosklerozun tahmini için bir yapay sinir ağı (Ankara Tıp Fakültesi Mecmuası, 2005;58:159-62)" adlı çalışmalarında YSA'ların aterosklerozun tahmin edilmesinde yararlı olabileceği sonucuna varmışlardır. Diğer YSA modelleri için yapılan çalışmalar daha çok mühendislik alanında kullanılmıştır.

Bu çalışmada, psikiyatrik veri kümesinin YSA yapıları ile modellenmesi gerçekleştirilmiştir. Kul-

lanılan ağ yapıları arasında en doğru sonucu veren MLP'nin en yüksek doğruluk veren 5 öğrenme algoritması için testlerin doğruluğu kontrol edilmiştir. Tablo 2'de verilen eğitim ve test sonuçlarının başarı yüzdelere bakıldığında en başarılı öğrenme algoritmasının MLP olduğu düşünülmektedir. Yine aynı şekilde test performanslarına bakıldığında MLP'nin RBF'lerden daha yüksek yüzdeye sahip olduğu gözlenmiştir. Ayrıca, yapılan hassasiyet (sensitivite) analiz sonuçları da Tablo 3'te, Model 1'e ait sınıflama istatistikleri ise Tablo 4'te görülmektedir.

Yapılan YSA analizi sonucunda Model 1'e göre, depresif bozukluğu olan 93 kişinin 91 (%97.85)'inde doğru tespit edildiğini göstermektedir. Bunun dışında anksiyete bozukluğu olan 52 kişinin 41 (%78.85)'inde ve diğer bozukluklar başlığı altında toplanan (uyum bozukluğu, psikotik bozukluk, uyku bozukluğu ve somatoform bozukluğu) 51 kişinin (bu grupların bu başlık altında toplanma sebebi denek sayısının azlığı nedeniyledir) 44 (%86.27)'ünde doğru tespit edilmiştir.

Bunun dışında yapılan YSA analizleri matris notasyonunda depresif bozuklukların %91'ini,

TABLO 4: Model 1'e ait sınıflama istatistikleri.

	Tanı1.		Tanı1.		Tanı1.		Tanı1.		Tanı1.		Tanı1.		Tanı1.		Tanı1.
	Tanı1	Anksiyete	Diğer	Tanı1	Anksiyete	Diğer	Tanı1	Anksiyete	Diğer	Tanı1.	Anksiyete	Diğer	Tanı1.	Anksiyete	Diğer
	Depr.1	Boz.1	Boz.1	Depr.2	Boz.2	Boz.2	Depr.3	Boz.3	Boz.3	Depr.4	Boz.4	Boz.4	Depr.5	Boz.5.	Boz.5
Toplam	93.00000	52.00000	51.00000	93.00000	52.00000	51.00000	93.00000	52.00000	51.00000	93.00000	52.00000	51.00000	93.00000	52.00000	51.00000
Doğru	91.00000	41.00000	44.00000	81.00000	7.00000	39.00000	80.00000	24.00000	38.00000	86.00000	29.00000	40.00000	86.00000	30.00000	39.00000
Yanlış	2.00000	11.00000	7.00000	12.00000	45.00000	12.00000	13.00000	28.00000	13.00000	7.00000	23.00000	11.00000	7.00000	22.00000	12.00000
Şüpheli	0.00000	0.00000	0.00000	0.00000	0.00000	0.00000	0.00000	0.00000	0.00000	0.00000	0.00000	0.00000	0.00000	0.00000	0.00000
Doğru (%)	94.84846	78.84615	86.27451	87.09677	13.46154	76.47059	86.02151	46.15385	74.80980	82.47312	55.76923	78.43137	92.47312	57.69231	76.47059
Yanlış (%)	2.15054	21.15385	13.72549	12.90323	86.53846	23.52941	13.97849	53.84615	25.49020	7.52688	44.23077	21.56863	7.52688	42.30769	23.52941
Şüpheli (%)	0.00000	0.00000	0.00000	0.00000	0.00000	0.00000	0.00000	0.00000	0.00000	0.00000	0.00000	0.00000	0.00000	0.00000	0.00000

TABLO 5: Tanı (1,2,3,4,5) elde edilen sonuçlar ile gözlenen sonuçların karşılaştırılması (confusion matrix).

Tahmin	Gözlenen		
	Depresif bozukluk	anksiyete bozukluğu	Diğer bozukluklar
Depresif bozukluk 1	91.00000	3.00000	2.00000
Anksiyete bozukluğu 1	0.00000	41.00000	5.00000
Diğer bozukluklar 1	2.00000	8.00000	44.00000
Depresif bozukluk 2	81.00000	29.00000	11.00000
Anksiyete bozukluğu 2	3.00000	7.00000	1.00000
Diğer bozukluklar 2	9.00000	16.00000	39.00000
Depresif bozukluk 3	80.00000	15.00000	6.00000
Anksiyete bozukluğu 3	3.00000	24.00000	7.00000
Diğer bozukluklar 3	10.00000	13.00000	38.00000
Depresif bozukluk 4	86.00000	8.00000	6.00000
Anksiyete bozukluğu 4	2.00000	29.00000	5.00000
Diğer bozukluklar 4	5.00000	15.00000	40.00000
Depresif bozukluk 5	86.00000	8.00000	5.00000
Anksiyete bozukluğu 5	1.00000	30.00000	7.00000
Diğer bozukluklar 5	6.00000	14.00000	39.00000

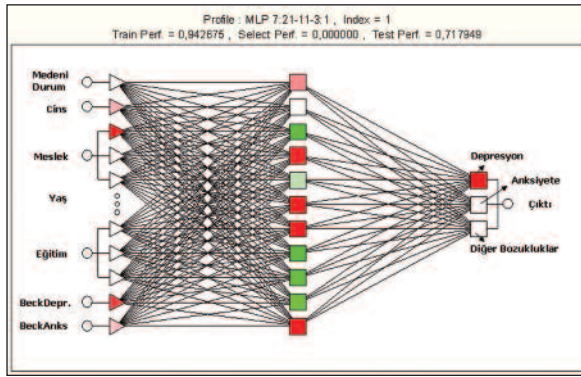
anksiyete bozukluklarının %41'ini ve diğer bozuklukların ise %44'ünün doğru tespit edildiğini göstermektedir. MLP ve RBF olmak üzere iki tip ileri beslemeli ağ yapısı kullanılmış ve en iyi performansın MLP'ye ait olduğu görülmüştür (Tablo 5).

Böylece, literatürde MLP için belirtilen, RBF'den daha yüksek performansa sahip olduğuna dair sonuçlar burada da görülmektedir. Chien-Cheng Lee ve ark.nın yapmış oldukları çalışmada ise RBF modelinin MLP'ye nazaran daha iyi sonuçlar verdiği ortaya konmuştur.³

Psikiyatride BDÖ tanı koymak amacıyla, hastayla yüz yüze görüşmenin yanı sıra kullanılan bir

ölçek olup, özellikle depresif bozuklukların tahmininde ve depresif semptomların şiddetini değerlendirmekte kullanılan en yaygın ölçektir. Özer ve ark.nın yapmış oldukları çalışmada da maddeler sürekli depresyon ölçeğinde benzer bir faktör yapısı sergilemişlerdir. İki faktörlü analizler ile ortaya çıkan bu tablonun, durumsal ve sürekli depresyon ölçeklerinin orijinal çalışmada (Spielberger, 2005) ortaya çıkanla önemli ölçüde örtüştüğü sonucuna varılmıştır.¹⁵

Bu çalışmanın sonucuna göre, ilk görüşmede depresif bozukluklardan şüpheleniliyorsa BDÖ ile mutlaka desteklenmesi gerektiği görülmektedir.



ŞEKİL 3: Girdi tabakası 7 değişken 1 çıktı tabakası (3 ünite) olan çok tabakalı algılayıcının grafiksel gösterimi.

Beck depresyona ek olarak kişilerin eğitim durumu, medeni durumu ve mesleği de bu sınıflamada etkilidir (Şekil 3).

Bunun yanı sıra, anksiyete bozuklukları (%78.85) ve diğer bozukluklar [psikotik bozukluk,

somatoform bozukluk, uyku bozukluğu ve uyum bozukluğu) (%86.27) depresif bozukluklardan daha az yüzdeye sahip olması nedeni ile, sınıflamada BDÖ depresyon kadar etkili değildir. Bir ön çalışma olmasına rağmen, bulguların çok net bir şekilde hem sürekli hem de durumsal depresyonun “eutimik” ve “distimik” boyutlarını sergilediği görülmektedir. Bundan sonraki çalışmalarda, klinik manidarlık ölçütlerinin tanımlanabilmesi için hem örneklem sayısının artırılması, hem de depresyon tanısı almış bireylerin oluşturduğu grupların da ölçeğim geçerlilik sınamaları için dikkate alınması önemli olacaktır.

Bu çalışma, araştırma ve klinik çalışmalarda depresyon duygulanımın, “durumsallık-süreklilik” boyutlarını gözeterak anlaşılmasına ve araştırılmasına katkıda bulunabilecek bir araç olarak düşünülebilir.

KAYNAKLAR

1. Freedman R. Diagnostic and statistical manual of mental disorders. 4th ed. Text Revision (DSM-IV-TR), Washington DC: APA; 2000. p. 1-943.
2. Chtioui Y, Bertrand D, Devaux MF, Barba D. Comparison of Multilayer perceptron and probabilistic neural networks in artificial vision. Application to the Discrimination of Seeds. J Chemom 1997;11:111-29.
3. Lee CC, Chung PC, Tsai JR, Chang CI. Robust radial basis function neural networks. Systems, Man, and Cybernetics, Part B: Cybernetics, IEEE Transactions on. IEEE Xplore 1999; 29(6):674-85.
4. Efe MÖ, Kaynak O. [Artificial Neural Networks and Applications]. 1st ed. İstanbul: Boğaziçi University Publishing; 2000. p.1-141.
5. Perna C, Giordano F. The Hidden Layer Size in Feed-Forward Neural Networks: A Statistical Point of View. Rome: University of Rome; 2001. LIX: p.217-27.
6. Reber R, Perrig WJ. Perception without awareness, psychology of. In: Baltes PB, Smelser NJ, eds. The International Encyclopedia of the Social and Behavioral Sciences. Amsterdam: Elsevier; 2001. p.11215-8.
7. Öztemel E. [Artificial Neural Networks]. 1st ed. İstanbul: Papatya Yayıncılık; 2003. p.29.
8. Öztemel E. [Artificial Neural Networks]. 1st ed. İstanbul: Papatya Yayıncılık; 2003. p.36.
9. Öztemel E. [Artificial Neural Networks]. 1st ed. İstanbul: Papatya Yayıncılık; 2003. p.40.
10. Beck AT. An inventory for measuring depression. Arch Gen Psychiatry 1961;4:561-71.
11. Beck AT, Epstein N, Brown G. An inventory for measuring clinical anxiety: Psychometric properties. J Consult Clin Psychol 1988;50: 893-97.
12. Elmas Ç. [Artificial Neural Networks (Theory, Architecture, Education, Application)]. 1st ed. Ankara: Seçkin Yayıncılık; 2003. p.1-192.
13. Guenther FH. Neural Networks: Biological models and applications. The International Encyclopedia of the Social and Behavioral Sciences. Boston, Oxford: Elsevier Science; 2001. p.1-7.
14. Haykin S. Neural Networks. 1st ed. New Jersey: Macmillan Collage Printing Company; 1994. p.41.
15. Özer AK, Özer S. [Stately-continuous depression scale infrastructure of the factorial]. Dogus University J 2006;7(2): 210-7.
16. Yazıcı AC, Ögüş E, Ankaralı S, Canan S, Ankaralı H, Akkuş Z. [Artificial neural networks: review]. Türkiye Klinikleri J Med Sci 2007;27(1):65-71.