

Yapay Sinir Ağlarına Genel Bakış

ARTIFICIAL NEURAL NETWORKS: REVIEW

Dr. Ayşe Canan YAZICI,^a Dr. Ersin ÖĞÜŞ,^a Dr. Seyit ANKARALI,^b Dr. Sinan CANAN,^c
Dr. Handan ANKARALI,^d Dr. Zeki AKKUŞ^e

^aBiyostatistik AD, ^cFizyoloji AD, Başkent Üniversitesi Tıp Fakültesi, ANKARA

^bFizyoloji AD, ^dBiyostatistik AD, Mersin Üniversitesi Tıp Fakültesi, MERSİN

^eBiyostatistik AD, Dicle Üniversitesi Tıp Fakültesi, DİYARBAKIR

Özet

Yapay sinir ağları (YSA) çeşitli problemlere çözüm getirmek amacıyla insan beyninin bilgi işleme mekanizmasını taklit ederek geliştirilmiş bilgisayar yazılımlarıdır. İnsan beyni gibi biyolojik bir sinir ağının benzetimiyle oluşturulmuş YSA öğrenme, hafızaya alma ve öğrendiklerini yeni bilgiler üretecek biçimde genelleme, değişkenler arasındaki ilişkileri ortaya koyma yeteneklerine sahiptirler. Birçok alanda başarıyla uygulanan YSA teknolojisi ve istatistiksel yöntemler arasında önemli ilişkiler bulunmaktadır. Bu çalışmada insan beynindeki nöronlar, biyolojik sinir ağı ve YSA'nın genel yapısı tanıtılmış ve ardından YSA'nın istatistiksel yöntemler ile ilişkileri araştırılmıştır. İstatistiksel analiz yöntemi olarak YSA'nın fayda ve sakıncaları tartışılmıştır. Genellikle YSA modellerinin bazı klasik istatistiksel yöntemlerin genelleştirilmiş 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.

Anahtar Kelimeler: Sinir ağları; doğrusal olmayan modeller; sinir; beyin; sınıflandırma

Abstract

Artificial neural networks (ANNs) are computer softwares that were developed by simulating the working mechanism of human brain to accomplish the basic functions of the brain. ANNs have capability to learn, remember and then generalize the data to produce new information, and to detect the relationships between variables. There are considerable relations between the statistical methods and the neural networks. In the present study, biological neural network and neurons of the human brain and the general structure of ANNs were introduced. Then ANNs' relations with the statistical methods were investigated. ANNs' advantages and disadvantages as statistical methods were discussed. Many neural networks methods are considered generalizations of some of the classical statistical techniques. Generally, in statistics ANNs are used as flexible, nonlinear regression and classification models. Many neural network architectures have close links with the nonparametric statistical methods. Results may be obtained by training the feed forward ANNs algorithms with the nonlinear models of many statistical techniques.

Key Words: Neural networks; nonlinear dynamics; neurons; brain; classification

Türkiye Klinikleri J Med Sci 2007, 27:65-71

YSA insan beyninin çalışma mekanizmasını taklit ederek beyin öğrenme, hatırlama, genelleme yapma yolu ile yeni bilgiler üretebilme gibi temel işlevlerini gerçekleştirmek üzere geliştirilen mantıksal yazılımlardır. Aslında YSA'nın tarihçesi modern bilgisayarlardan

daha eskidir ve bu konudaki çalışmalar sinir hücrelerinin bilgi işleyiş mekanizmasının modellenmesi ile başlamıştır. İlk olarak 1943'te nörofizyolog McCulloch ve mantıkçı Pitts ilk sinir ağı modelini geliştirerek birkaç ara bağlantı kurmaya çalıştılar. 1950'li yıllarda hızlı bir gelişim gösteren bilgisayar teknolojisi üzerine çalışan uzmanlar, sinirbilimcilerle temasa geçerek bu konuda çalışmalar yaptılar. Ancak 1969 yılında Minsky ve Papert yazdıkları bir kitapta bu çalışmaların verimsiz olduğunu söyleyince, araştırmacılar uzun yıllar maddi kaynak bulmakta zorlandılar ve bu konudaki çalışmalar durma noktasına geldi. Sınırlı imkanlara rağmen hala bu konuda çalışan az sayıda bilim adamının gayreti ile düzenlenen konferanslar ve bazı endüst-

Geliş Tarihi/Received: 18.11.2005 **Kabul Tarihi/Accepted:** 21.04.2006

Çalışmanın bir bölümü, VIII. Ulusal Biyoistatistik Kongresi (20-22.09.2005)'nde poster olarak sunulmuş ve kongre kitapçığında özeti yayımlanmıştır.

Yazışma Adresi/Correspondence: Dr. Ayşe Canan YAZICI
Başkent Üniversitesi Tıp Fakültesi,
Biyostatistik AD, ANKARA
aysecanan@yahoo.com

Copyright © 2007 by Türkiye Klinikleri

Türkiye Klinikleri J Med Sci 2007, 27

riyel ve finansal kuruluşlarda başarılı ticari uygulamalar sayesinde 1980'lerin başlarından itibaren YSA çalışmaları yeniden ivme kazandı.^{1,2}

Günümüzde verilerden yola çıkarak tahminde bulunmayı gerektiren finans ve satış sektöründen, çeşitli mühendislik sektörlerine kadar birçok alanda çalışma alanları bulan YSA'nın, tıp alanında da uygulama çalışmaları devam etmektedir. Şu anda tıp alanındaki uygulamalar daha çok insan vücut parçalarının modellenmesi ve taramalardan elde edilen sonuçlardan (ultrason taraması, kardiyogram vb.) hastalıkların tanısının konmasına yöneliktir. Hastalığa nasıl tanı koyduğuna dair özgün bir algoritmaya ihtiyaç duymayan YSA'lar veri örneklerinden öğrenme yoluyla tanı koymaya çalışır.² YSA'nın biyokimyasal analizlerde, genetik alanda yapılan çalışmalarda, kardiyoloji, gastroenteroloji, onkoloji, nöroloji, jinekoloji ve patolojide tahmin ve teşhis amaçlı kullanımı giderek yaygınlaşmaktadır.¹

Üstün özellikleriyle çeşitli avantajlar sunan ve sürekli gelişmekte olan bu teknoloji ile istatistiksel yöntemler arasında önemli ilişkiler söz konusudur. Bu çalışmada YSA'nın genel yapısı ele alınarak istatistiksel yöntemlerle ilişkileri araştırılmıştır.

Biyolojik Sinir Ağları


İnsan beyninin nasıl çalıştığı henüz tam olarak anlaşılabilmiş değildir. Ancak bu konuda beyni oluşturan milyarlarca sinir hücresinin önemli rol oynadıkları bilinmektedir. Beynin çalışması genel olarak 3 aşamadan oluşur:

1. Bilgi girişi,
2. Sentezleme ve karşılaştırma,
3. Bilgi çıkışı ve eylem.

Beynin bu işlevlerini yerine getirebilmesini sağlayan ise temel yapı elemanı olan sinir hücreleri yani nöronlardır. Sinir hücreleri birbirleri ile ilişki halindedirler. Bu sıkı ilişki, sinirsel işlevin temelini oluşturan bilgi akışını sağlar.

Biyolojik sinir ağını oluşturan insan beynindeki nöronlar Şekil 1'de görüldüğü gibi 3 temel bölgeden oluşur:³

1. Çekirdek ve Soma (Hücre gövdesi): Hücrenin gövde kısmında bulunan çekirdek, hücrenin



Şekil 1. Biyolojik sinir hücresinin yapısı.³

temel işlevlerini belirleyen ve DNA molekülü üzerinde kodlanmış halde bulunan genetik bilgiyi içerir. DNA üzerindeki bilgi, hücrenin bulunduğu ortama, ortamdaki değişimlere ve hücrenin iç çevresine bağlı olarak deşifre edilerek, hücre içi olayların meydana gelmesini sağlar. Hücre etkinliklerine ilişkin yapım/yıkım (metabolizma) faaliyetlerinin büyük bir çoğunluğu ise hücre gövdesinde yürütülür. Hücre gövdesi, jel kıvamındaki hücre plazması (sitoplazma) içinde, mitokondri, golgi aygıtı, endoplazmik retikulum gibi birçok hücre organelini de içeren bölümdür.

2. Dendritler ve Akson: Hücre gövdesinden çıkan uzantılardır. Kısa, ağaç dalları biçiminde ve genellikle çok sayıda olan yapılar dendrit adını alır. Diğer hücrelerin aksonlarıyla gelen sinir sinyallerini alarak ait oldukları hücre gövdesine taşırlar. Akson ise uzun ve tek olup, uç kısımlarından genellikle dallanmalar gösterir. Hücre gövdesinde üretilen sinyalleri diğer nöronların dendritlerine taşımakla yükümlüdür.

3. Sinapslar: Akson ve dendritlerin veri iletişimi amacıyla bir araya geldikleri birleşim yerlerine sinaps adı verilir. Sinapslar, bir hücrede üretilen sinyalleri, yapısına ve biyofiziksel özelliklerle

rine bağlı olarak sonraki hücreye iletirler. Genel olarak bir sinir hücresi, gövde ve dendritleri aracılığıyla sinyalleri alır. Bu sinyaller akson vasıtasıyla, hücre içindeki genel duruma ve gelen tüm sinyallerin toplam etkisine göre diğer bir hücreye aktarılır.


Kısacası, Şekil 2’de görüldüğü gibi nöronlar kendi aralarında bağlantılar kurarak, elektrik devrelerine benzer yollarla iletişim sağlayıp, beyin işlevlerinin ortaya çıkmasını sağlayan ana elementlerdir. Bu sistem bir bütün olarak, bir sinir bilimcinin bile hayal edebileceğinin çok ötesinde bir karmaşıklığa sahiptir.^{4,5}

Biyolojik sistemlerde öğrenme, nöronlar arasındaki sinaptik bağlantılar ile olur. İnsan beyni doğumdan itibaren sürekli bir öğrenme süreci içindedir. Beyin sürekli bir gelişme gösterir. Bu gelişim sadece yeni beyin hücrelerinin oluşumuyla değil, özellikle nöron arasındaki bağlantı ya da diğer bir ifadeyle sinaps sayısının artmasıyla meydana gelir.⁶

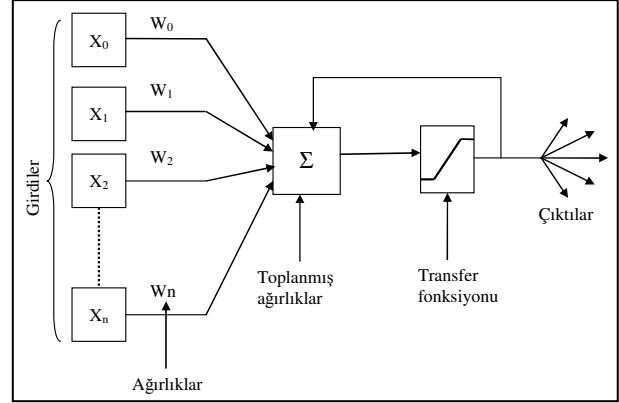
Aksonların yeni dalları oluşur ve bu dallar yeni dendritlerle bağlantı kurar. Böylece öğrenme gerçekleşir. Nöronlar arasındaki bağlantılar arttıkça, beyin daha ayrıntılı işlemler yapabilir ve daha çok öğrenmiş olur.²

YSA

YSA algoritmaları, canlı organizmada bulunan biyolojik sinir yapısı modellenerek oluşturulmuşlardır. Taklit edilen yapay sinir hücreleri birbirleriyle çeşitli şekillerde bağlanarak YSA’yı oluştururlar ve genellikle katmanlar şeklinde düzenlenirler. Bu ağlar öğrenme, hafızaya alma, hatırlama, sonuç çıkarma yeteneğine sahiptirler. YSA hesap-



Şekil 2. Sinir hücrelerinin bağlantılarının basitleştirilmiş şematik yapısı.⁴



Şekil 3. Yapay sinir hücresi modeli. X_i , giriş değerleri; w_i , bağlantı ağırlığıdır.

lamalarının gücü, toplam işlem yükünü paylaşan işlem elemanlarının yani nöronların birbirleri arasındaki yoğun bağlantıdan kaynaklanmaktadır.⁷

Matematiksel olarak modellenmiş bir biyolojik nöron Şekil 3’te görülmektedir. Bu nöronlar McCulloch-Pitts nöronu olarak bilinirler. Birbirleriyle bağlanarak ağı oluştururlar. Bir nöron diğer nörondan sinyalleri alır, bunları birleştirir, dönüştürür ve sayısal bir sonuç ortaya çıkarır. Her bir nöron şiddetine göre gelen sinyali ya söndürür ya da iletir. Giriş değerlerinin her biri bir bağlantı ağırlığıyla çarpılır. Nöronlar giriş bilgilerini ağırlıklandırdıktan sonra, doğrusal olarak toplar ve eşik bu bilgiyi doğrusal veya doğrusal olmayan bir fonksiyonda işleyerek çıktı bilgisine dönüştürür. Bu çıktıyı hücreye bağlantısı olan diğer nöronlar giriş bilgileri olarak alırlar.⁸ YSA’da en uygun ağırlık setinin belirlenmesi için yapılan ağ hesaplamaları 2 aşamadan oluşur:

1. Öğrenme: Ağlar örneklerle eğitilirler. İki öğrenme stratejisi söz konusudur:

a. Danışmanlı öğrenme: Ağa giriş-çıkış vektörleri şeklinde ayrıntılı eğitim örnekleri verilmektedir. Örneğe ait hem giriş hem de çıkış değerleri ağa sunulur ve her iterasyonda örneğe ait çıkış değerleri ile ağın çıkış değerleri karşılaştırılarak ağın hatası hesaplanır. Bu hata minimum olana kadar ağ, nöronlar arasındaki ağırlıkları düzelterek iterasyona devam eder. YSA’da en yaygın öğrenme biçimidir.

b. Danışmansız öğrenme: Ağa sadece giriş veri grubu sunulur ve bu veri grubuna uyumlu bir çıkış değeri üretecek şekilde ağın kendisinin uygun ağırlıkları düzenlemesi istenir.²

2. Hatırlama (Test etme): Ağın öğrenmesi sonucu elde edilen ağırlık grubu kullanılarak ağa benzer bir probleme ait giriş değerleri verilir ve bu probleme çözüm getirmesi istenir. YSA, ağın kullanıldığı veri setine göre sınıflandırılabilir. Temel olarak veriler kalitatif (kategorik) ve kantitatif (sayısal) olmak üzere 2 ana gruba ayrılır. Kalitatif veriler ile çalışan ağlar ister danışmanlı ister danışmansız öğrenme kullansın, sınıflandırma ağları olarak bilinirler. Kantitatif veriler kullanan, danışmanlı eğitim almış YSA ise genellikle regresyon analizi amaçlıdır.⁹

YSA, yapısal olarak da sınıflandırılabilir. Yapısal olarak YSA, bilginin akış yönüne bağlı olarak, nöronlar arasındaki bağlantıların yapısı bakımından ileri beslemeli ve geri beslemeli olmak üzere 2 ana grupta toplanır.

1. İleri beslemeli ağlar: Ara sınırlardan geçerek giriş katından çıkış katına doğru bilgi akışının yalnız bir yönde ilerlediği ağlardır. Giriş tabakası, gizli tabaka ve çıkış tabakası olmak üzere 3 tabakadan oluşurlar. Ağ üzerinde bilgi akışı giriş tabakasından çıkış tabakasına doğru ilerler. Yani nöronlar arka arkaya beslenirler.

2. Geri beslemeli YSA: Herhangi bir sinirin çıkışından girişine doğru bilgi akışının ilerlediği ağlardır. Bu tür ağ yapısında geri besleme bağlantıları söz konusudur.¹⁰

Ayrıca hem ileri besleme hem de geri yayılma olarak tanımlanabilecek ağ yapıları da mevcuttur. Tüm YSA modelleri içinde en çok kullanılan ağlar geri yayılma ile eğitilen çok tabakalı ileri beslemeli ağlar (Back Propagation Network), radial tabanlı ağlar, Hopfield ve Kohonen sayılabilir.² Geri yayılmalı YSA hem kullanışlı hem de güvenilir olmasından dolayı en çok kullanılan ağ türüdür. En önemli özelliği kestirim (prediction) ve sınıflandırma işlemleri için oldukça uygun olması ve doğrusal olmayan yapı içeren modellerde oldukça kullanışlı olmasıdır.⁸ Bu tip ağların kullanıldığı birkaç çalışma şöyle özetlenebilir. Acil servise

başvuran hasta sayısı üzerine atmosferik değişimlerin etkisi araştırılmak istenmiş ve etkiler ileri beslemeli geri yayılmalı YSA algoritması ile incelenmiştir. Elde edilen sonuçlar değerlendirildiğinde YSA'nın başarısı %80 olarak bulunmuştur.¹⁰ Bir başka çalışmada ise ratlarda 3 uyku-uyanıklık döngüsüne ait elektrofizyolojik kayıtlar yardımıyla bu evrelerin sınıflandırması yapılmış ve kullanılan ağın başarı oranı yaklaşık %95 bulunmuştur.^{11,12} Yine EEG dalga kayıtlarının girdi verisi olarak kullanıldığı bir diğer çalışmada ileri beslemeli geri yayılmalı YSA modeli kullanılmış ve EEG paternine göre denekler uyanık-tetikte, uykulu-uyuşuk ve uykuda olarak sınıflandırılmıştır. Sınıflama başarısı %94-%96 arasında bulunmuştur.^{13,14}

Biyolojik ve YSA'nın Temel Farkları

YSA, temel olarak biyolojik sinir sistemini örnek alsa da canlı sistemin ileri düzeyde karmaşıklığı, canlıdaki etkinlik ve kapasitede bir sinir ağı tasarımına şu anda izin vermemektedir. Canlı sistemlerde hücreler, hücre uzantıları ve bunlar arasındaki bağlantılar çok dinamik ve değişken bir yapılanma gösterirler. Canlı bir hücrenin hem yapısal hem de biyokimyasal olarak geçirdiği değişiklikleri hesaplayabilmek oldukça karmaşık bir işlem dizisi gerektirir. Ayrıca biyolojik sinir ağları her öğrenmeden sonra hem yapısal hem de kimyasal birtakım değişiklikler göstererek adapte olma özelliğine sahiptirler. Bunun yanı sıra, veri iletişim noktaları olan sinapsların ileri düzeyde uyarlanabilir yapılar olması, bir tek sinapsın bile veri iletişimini modellemeyi güçleştirmektedir. Sinapslar, geçirdikleri verinin tipi ve karşı hücrede uyandırdıkları yanıtı göre bir dizi düzenleme işlevini de gerçekleştirirler.

Tüm bunlarla birlikte, canlılardaki sinir sistemi sadece nöronlardan kurulmamıştır; sinir sisteminde sinir hücrelerinin yaklaşık 50 katı kadar sayıya ulaşabilen ara hücreler (glia hücreleri) de bulunur ve bunların sinir sisteminin bilgi-işlem süreçlerindeki rolleri halen tartışmalıdır.

Tüm bu koşullar göz önüne alındığında en gelişmiş sinir ağları bile canlılardaki sinir sisteminin, sadece bilimsel olarak bilinen kısmına dair kaba bir model/benzetim olarak kabul edilebilir.

YSA ve İstatistiksel Yöntemler

YSA uygulamalarında istatistiksel bağlantıların büyük önemi vardır. İstatistikte doğrusal olmayan modeller için kullanılan yöntemler bazı YSA algoritmalarını eğitmek için kullanılmaktadır. YSA terminolojisinde istatistiksel çıkarımın anlamı, ham veriden genelleme yapmayı öğrenmektir. YSA ve istatistiksel yöntemler arasında önemli bir kesişim kümesi vardır. Örneğin en küçük kareler yöntemi YSA modellerinde de sıklıkla kullanılmaktadır. Bununla beraber model geliştirmede YSA ile istatistikte kullanılan yaklaşımlar tamamen farklı olabilir. Değişik eğitime kriterleri, değişik istatistiksel özelliklere sahip farklı tahmin yöntemleridir. Örneğin aritmetik ortalama, basit bir geri yayılma ağ ile kolayca hesaplanabilir. Bunun için, aritmetik ortalama formülünün ağ içinde kullanılması yeterlidir. Sonuçta hesaplanma şekli ne olursa olsun çıktı olarak aritmetik ortalama elde edilir. YSA'nın klasik ve modern istatistiksel yöntemlere ek olarak kullanımı gittikçe yaygınlaşmaktadır.^{11,15,16}

İleri beslemeli YSA sınıflama modellerinin ve doğrusal olmayan regresyonun bir alt sınıfı haline gelmiştir. Tahmin problemleri için oluşturulan bir YSA, doğrusal olmayan regresyon modeli olarak eğitilebilir ve sonuç üretebilir. Doğrusal olmayan modellere ait pek çok istatistiksel teorisi ileri beslemeli YSA'ya doğrudan uygulanmaktadır. Levenberg-Marquardt ve eşlenik gradient gibi doğrusal olmayan modellerde kullanılan algoritmalar ileri beslemeli YSA'yı eğitmek için kullanılmaktadır. Pek çok ileri beslemeli YSA yöntemi istatistiksel yöntemlerle çok benzemektedir, hatta ağlar söz konusu yöntemlerle eğitilmekte ve aynı amaçla kullanılmaktadır.¹⁶⁻²⁰

Örneğin:

– Gizli tabakası olmayan ileri beslemeli YSA, temel olarak geliştirilmiş doğrusal modellere karşılık gelirler.

– Doğrusal transfer fonksiyonlu ileri beslemeli YSA modeli çoklu veya çok değişkenli doğrusal regresyon modeline karşılık gelmektedir.

– Lojistik transfer fonksiyonlu ileri beslemeli YSA modeli lojistik regresyon modeline karşılık gelmektedir.

– Eşik transfer fonksiyonlu ileri beslemeli YSA modeli doğrusal ayırma (diskriminant) fonksiyonudur.

– Bir gizli tabakası bulunan ileri beslemeli YSA izdüşüm regresyon analizi (Projection Pursuit Regression) ile ilişkilidir.

– Olasılıkçı YSA temel ayırma analizine karşılık gelmektedir.

– Hebbian öğrenme, temel bileşenler analizi ile yakından ilişkilidir.² Çok tabakalı ileri beslemeli YSA modellerinin de istatistiksel yöntemlerde karşılıkları vardır.

– Tek çıktılı birçok tabakalı ileri beslemeli YSA modeli doğrusal olmayan regresyon analizidir.

– Gizli nöronları bulunan birçok tabakalı ileri beslemeli YSA modeli temel olarak izdüşüm pursuit regresyon modeli ile aynıdır. Ancak sadece çok tabakalı ileri beslemeli YSA önceden belirlenmiş bir transfer fonksiyonu kullanır fakat izdüşüm pursuit regresyon modeli daha esnek bir doğrusal olmayan fonksiyon kullanır.^{1,12,13,17,21-23}

Geri beslemeli YSA, daha çok optimizasyon problemlerinde kullanılırlar. En popüler geri beslemeli ağ tiplerinden biri Kohonen ağlarıdır. Kullanımı zor ancak çok güçlüdür. Uyarlamalı vektör ölçümü için Kohonen ağları, k ortalamalı kümeleme analizine çok benzemektedir. Kohonen kendi kendini organize edebilen haritaları, temel eğriler ve yüzeylere ayrı bir yaklaşımdır.^{24,25}

Geri yayılma YSA, özellikle zaman serileri analizinde yaygın bir biçimde kullanılmaktadır. Geri yayılım algoritmasının yeni olmadığı, aslında bilinen bir istatistiksel yöntem olan stokastik yaklaşım olduğu ileri sürülmektedir.^{26,27}

Genel olarak danışmanlı öğrenme ile eğitilen YSA regresyon analizi ve ayırma analizi amacıyla kullanılmaktadır. Danışmansız öğrenme ile eğitilen YSA, sınıflama (cluster) analizi ve veri indirgeme de kullanılmaktadırlar.^{12,13,28-30}

YSA ile klasik istatistiksel yöntemler arasındaki en temel farklılık istatistiksel yöntemlerin, modele alınacak değişkenlerin yapısı hakkında bilgiye gereksinim duyması ve birtakım varsayımlar

ları göz önüne almasıdır. YSA ise değişkenlerin yapısı hakkında bilgi istemez ve önşart gerektirmez. Yani istatistiksel yaklaşımlar, varsayılan bir modele dayanır ancak YSA veriye dayanır.⁹

Hipertansiyonun risk faktörleri ile ilgili yapılan bir çalışmada, lojistik regresyon, esnek ayırma analizi (flexible discriminant analysis) ve YSA karşılaştırılabilir olarak kullanılmış ve YSA'nın tanı başarısının en iyi olduğu sonucuna ulaşılmıştır.^{31,32}

İstatistiksel Analiz Yöntemi Olarak YSA'nın Avantajları

YSA doğrusal değildir. Bu özelliği nedeniyle her alana uygulanabilir. Herhangi bir sürekli fonksiyona ve türevlerine de yakınsama yeteneğine sahiptir ve bu yönüyle evrensel fonksiyon yakınsayıcı yöntem olarak tanımlanmaktadır. YSA'nın özellikle doğrusal olmayan zaman serilerinde gösterdiği başarı, bir tahmin aracı olarak tercih edilmesini sağlamıştır.

1. Öğrenme yeteneği sayesinde bilinen örnekleri kullanarak daha önce karşılaşılmamış durumlarda genelleme yapabilmektedir. Yani hatalı veya kayıp veriler için çözüm üretebilmektedir. Eksik bilgileri de işleyerek sonuca varabilir.

2. Sınırsız sayıda değişken ve parametre ile kolaylıkla çalışılabilmektedir. YSA, doğrusal olmayan, çok boyutlu, hatalı veya eksik gözlem içeren, grup içi varyansın büyük olduğu ve özellikle problemin çözümünde kesin bir matematiksel modelin veya algoritmanın bulunmadığı verilerin analizinde önemli bir araç haline gelmiştir.

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

4. Değişken uzayı karmaşık ve verinin dağılımı bilinen istatistiksel dağılımlardan farklıysa, istatistiksel sınıflama yöntemlerinden daha güvenilir sonuçlar verirler. Mesela klasik parametrik istatistiksel

sınıflandırma yöntemleri öklit, 'maximum likelihood' ve 'mahalanobis' uzaklığı sınıflandırıcılarını kullanırlar. Bu yaklaşımlar, sınıflandırılmış veriler için çok değişkenli normal dağılım varsayımına gerek duyarlar. Değişken uzayındaki her bir özelliğin çok değişkenli normal dağılım gösterdiği varsayılır. Ancak veriler bu varsayımı sağlamıyor olabilir. Bu durumda dağılımdan bağımsız YSA'nın kullanımı önerilir. Sınıflama amacıyla kullanılan, danışmanlı öğrenme ile eğitilen YSA, yine sınıflama amacıyla kullanılan k tane en yakın komşu algoritmasına benzer ancak YSA'dan elde edilen sonuçların daha güvenilir olduğu görülmüştür.^{2,11,15,20,28-30}

İstatistiksel Analiz Yöntemi Olarak YSA'nın Dezavantajları

1. Sınır ağlarının eğitilmesine ve test edilebilmesine yetecek genişlikte veri setine ihtiyaç duyulmaktadır.

2. Uygun ağ yapısının belirlenmesi genellikle deneme yanılma yöntemiyle gerçekleştirilmektedir.

3. Gizli katmandaki nöron sayısı, bir tanıma işleminin doğruluğunu ve eğitim hızını etkilemektedir. Örneğin karmaşık ilişkiler gizli tabakada nöron sayısı az olduğunda bulunamamaktadır ancak sayının çok büyük olması da hesaplama yükünü çok fazla arttırmaktadır.

4. Basit olarak görülebilecek modelleme yapılarına rağmen zaman zaman uygulaması zor ve karmaşık olabilmektedir.

5. Diğer birçok tahmin yöntemi gibi bir model oluşturamaz ve parametre tahminlerini vermez.²⁰

6. Hatalı öğrenme meyili vardır (overfitting).¹⁰

Sonuç

Pek çok YSA modelinin bazı klasik istatistiksel yöntemlerin genelleştirilmiş hali olduğu görülmüştür. İstatistikte doğrusal olmayan modellerde kullanılan yöntemler ile ileri beslemeli YSA algoritmaları eğitilerek sonuç üretilebilmektedir. İstatistikte YSA genellikle esnek olarak doğrusal olmayan regresyon analizi veya sınıflandırma modelleri olarak kullanılmaktadırlar. Pek çok YSA algoritmasının parametrik olmayan istatistiksel yöntemlerle yakın ilişkisi vardır. Özellikle değişken uzayı karmaşık ve verinin dağılımı, bilinen istatis-

tiksel dağılımlardan farklıysa YSA bir istatistiksel analiz yöntemi olarak kullanılabilir.^{2,32}

KAYNAKLAR

- Papik K, Molnar B, Schaefer R, Dombovari Z, Tulassay Z, Feher J. Application of neural Networks in medicine-a review. *Med Sci Mon* 1998;4:538-46.
- Haykin S. Learning processes; single-layer perceptrons; multilayer perceptrons. *Neural Networks A Comprehensive Foundation*. 2nd ed. USA: Prentice Hall International Inc; 1999. p.14-68.
- Felten DL, Jozefowicz RF. Neurons and their properties. *Netter's Atlas of Human Neuroscience*. USA: Icon Learning, hard learning problem; making neurons. *An Introduction to Neural Computing*. 1st ed. London: Chapman and Hall; 1990. p.1-130.
- Baylar A, Emiroğlu ME, Arslan A. Geriye Yayılma Yapay Sinir Ağı Kullanarak Yanal Su Alma Yapısına Yönelecek Olan Sürüntü Maddesi Oranının Bulunması. *Dokuz Eylül Üniversitesi Mühendislik Fakültesi Fen ve Mühendislik Dergisi* 1999;1:1-12.
- Durmuş HK, Meriç C. Makine mühendisliğinde yapay sinir ağlarının (YSA) kullanımı. *Mühendis ve Makine* 2005;46:47-56.
- Bibi H, Nutman A, Shoseyov D, et al. Prediction of emergency department visits for respiratory symptoms. *CHEST* 2002;122:1627-32.
- Ripley BD. Statistical decision theory; linear discriminant analysis. *Pattern Recognition and Neural Networks*. 1st ed. Cambridge: Cambridge University Press; 1996. p.65-120.
- Sinha RK, Agrawal NK, Ray AK. A power spectrum based backpropagation artificial neural network model for classification of sleep-wake stages in rats. *OJHAS* 2003;1:1-8.
- Gaudart J, Giusiano B, Huiart L. Comparison of the Performance of Multi-Layer Perceptron and Linear Regression for Epidemiological Data. *CSDA* 2004;44:547-70.
- Kiyimik MK, Akin M, Subasi A. Automatic recognition of alertness level by using wavelet transform and artificial neural network. *J Neurosci Methods* 2004;139:231-40.
- Balkin SD, Ord JK. Automatic neural network modeling for univariate time series. *IJF* 200;16:509-15.
- Ripley BD. Statistical aspects of neural networks. In: *Barndorff-Nielsen OE, Jensen JL, eds. Networks and Chaos-Statistical and Probabilistic Aspects*. 1st ed. London: Chapman and Hall; 1993. p.40-123.
- Cheng B, Titterton DM. Neural networks: A review from a statistical perspective (with discussion). *Statistical Science* 1994;9:2-54.
- Schumacher M, Rossner, R, Vach W. Neural networks and logistic regression: Part I. *CSDA* 1996;21:661-82.
- Stern HS. Neural networks in applied statistics (with discussion). *Technometrics* 1996;38:205-20.
- Warner B, Misra M. Understanding neural networks at statistical tools. *American Statistician* 1996;50:84-293.
- Kumar A, Rao VR, Soni H. An empirical comparison of neural network and logistic regression models. *Market Lett* 1995;6:251-63.
- Liu W, Hwang MI, Chen D. Sovereign debt service capacity estimation by logistic regression and neural networks. *MBR* 2000;8:51-7.
- Yoon Y, Swaler G, Margavio TM. A comparison of discriminant analysis versus artificial neural networks. *JORS* 1993;44:51-60.
- Flanagan JA. Self-organisation in Kohonen's SOM. *Neural Netw* 1996;9:1185-97.
- Nour MA, Madley GR. Heuristic and optimization approaches to extending the Kohonen self organizing algorithm. *EJOR* 1996;93:428-48.
- Lai TL, Wong SP-S. Stochastic neural networks with applications to nonlinear time series. *JASA* 2001;96:968-81.
- Nottingham QJ, Cook DF. Local linear regression for estimating time series data. *CSDA* 2001;37:209-17.
- Balakrishnan PV, Cooper MC, Jacob VS, Lewis PA. A study of the classification capabilities of neural networks using unsupervised learning: A comparison with K-means clustering. *Psychometrika* 1994;59:505-25.
- Mangiameli P, Chen SK, West D. A comparison of SOM neural network and hierarchical clustering methods. *EJOR* 1996;93:402-17.
- Kuo RJ, Ho LM, Hu CM. Cluster analysis in industrial market segmentation through artificial neural network. *CIE* 2002;42:391-9.
- Arulampalam G, Bouzerdoum A. A generalized feedforward neural network architecture for classification and regression. *Neural Netw* 2003;16:561-8.
- Türe M, Kurt İ, Yavuz E, Kürüm T. Hipertansiyonun tahmini için çoklu tahmin modellerinin karşılaştırılması (Sinir ağları, lojistik regresyon ve esnek ayırma analizleri), *Anadolu Kardiyoloji Dergisi* 2005;5:24-8.