

Yakut GEVREKÇİ^{1*}
E.Dilşat YEĞENOĞLU²
Yavuz AKBAŞ¹
Meltem SESLİ³

¹ Ege Üniversitesi Ziraat Fakültesi, Zootekni Bölümü,
Biyometri-Genetik ABD, 35100, Bornova-İzmir.

* e-posta: yakut.gevrecki@ege.edu.tr

² Celal Bayar Üniversitesi, Akhisar Meslek Yüksekokulu,
45210, Akhisar-Manisa.

³ Celal Bayar Üniversitesi, Tütün Ekspertiği Yüksekokulu,
45210, Akhisar Manisa.

Yapay Sinir Ağlarının Tarımsal Alanda Kullanımı

Using of Artificial Neural Networks in agricultural research

Alınış (Received): 15.01.2010 Kabul tarihi (Accepted): 26.03.2010

Anahtar Sözcükler:

Yapay Sinir Ağları, genetik, tarım

Key Words:

Artificial Neural Networks, genetics, agriculture

ÖZET

Yapay Sinir Ağları (YSA), biyolojik olarak insan beyninin yaptığı temel işlemleri yazılımlarla gerçekleştiren modellerden oluşmaktadır. Yapay sinir ağlarının en büyük avantajı, az sayıda bilgi ile geleceğe yönelik doğru tahminleme yapılabilir. Bu nedenle tercih edilen bir yöntemdir. Gelişen bilgisayar teknolojisi ile birlikte YSA, biyoloji, genetik, informatik, ekonomi, mühendislik, ziraat gibi birçok alanda kullanılmaya başlanmıştır. Bu çalışmada önce yapay sinir ağları hakkında genel bilgiler verilmiş daha sonra tarımsal alanda kullanımı ilgili yapılan çalışmalar özetlenmiştir.

ABSTRACT


Artificial Neural Networks (ANN), is constructed of the models which operates the basic activities biologically carried out by human brain. The greatest advantage of Artificial Neural Networks is to be able to make future predictions with little information. Therefore it is a preferable method. Through the progressive computer technology ANN has been used in many different areas such as biology, genetics, informatics, economy, engineering and agriculture.

In this study, initially general information is given on Artificial Neural Networks and some studies conducted on its use in agriculture were summarized.

GİRİŞ

Yapay Sinir Ağları (YSA), taklit edilerek geliştirilen ve biyolojik olarak insan beyninin yaptığı temel işlemleri belirli bir yazılımla gerçekleştirmeyi amaçlayan bir mantıksal programlama tekniğidir (Civalek,1998).

Temelinde insanın öğrenme yeteneğini model alan YSA, yapay sinir hücrelerinin farklı şekillerde birbirleri ile bağlanmasından meydana gelmektedir. İnsan beyninde yaklaşık olarak 10^{11} adet sinir hücresi bulunmaktadır. YSA'ndaki işleme elemanları insan beynindeki nöronlara karşılık gelmektedir (Şekil 1).



Şekil 1. Biyolojik nöron.

Dendrit adı verilen yapı, diğer hücrelerden bilgiyi alan nöron girişleri olarak görev yapar. Diğer hücrelere bilgiyi transfer eden eleman aksonlardır. Dolayısıyla aksonlar nöron çıkışları olarak görev yaparlar. Akson ile dendrit arasındaki bağlantı ise sinapslar tarafından gerçekleştirilir (Takcı, 2008).

YSA'ında nöronlar birbirine bağlanarak bir ağ oluşturur. Bu ağ öğrenme, hafızaya alma ve veriler arasındaki ilişkiyi ortaya çıkarma kapasitesine sahiptir (Kayabaş & Yıldırım, 2008). YSA, olaylarla ilgili bilgi toplar, daha sonra hiç görmediği bir olayla karşılaşıncı bu bilgileri kullanarak o olay hakkında karar verir. YSA'nın işleyişinde sinir ağları eğitilerek belirli bir girişe karşılık gelen çıkış elde edilir (Şekil 2).



Şekil 2. Yapay sinir ağlarının işleyiş şeması (Demuth ve ark., 2006).

YSA ile ilgili yapılan çalışmalar 20. yüzyılın ilk yarısında başlamıştır. Yapay zekâ kavramı, "Makineler düşünebilir mi?" sorusunu araştırıp makine zekâsını tartışmaya açan Alan Mathison Turing tarafından ortaya çıkarılmıştır. YSA modelleri ilk olarak 1943'de, bir sinir hekimi olan McCulloch ile bir matematikçi olan Pitts tarafından uygulanmıştır (Zhang, 2007). İkinci dünya savaşı sırasında "Kripto Analizi" gereksinimleri ile üretilen elektromekanik cihazların sayesinde yapay zekâ kavramları doğmuştur. İlk yapay sinir ağı temelli bilgisayar SNARC, Massachusetts Teknik Üniversitesi'nde Minsky ve Edmonds tarafından 1951'de yapılmıştır (Kayabaş & Yıldırım, 2008). McCulloch ve Pitts, insan beyninin hesaplama kabiliyetine benzeterek, elektrik devreleriyle basit bir sinir ağı modellemişlerdir. Mc Carthy, Minsky, Shannon ve Rochester'le birlikte 1956 yılında Dartmouth'da bir çalışma düzenlemiş ve burada birçok çalışmanın

temelleri atılmakla birlikte, toplantının en önemli özelliği Mc Carthy tarafından önerilen yapay zekâ adı ortaya konmuştur (Miller, 2003). İlk kuram ispatlayan programlardan Logic Theorist (Mantık kuramcısı) ise Newell ve Simon tarafından tanıtılmıştır (Miller, 2003). 1957'de Rosenblatt'ın, beyin işlevlerini modelleyebilmek amacıyla yapılan çalışmaların sonunda ortaya çıkan, tek katmanlı eğitilebilen ve tek çıkışa sahip bir ağ modeli olan "Perceptron"u geliştirmesinden sonra ise YSA ile ilgili çalışmalar hızlanmıştır (Chtioui et al., 1997). 1988'de, Broomhead & Lowe, "Radyal tabanlı fonksiyonlar (RBF)" modelini geliştirmişlerdir. Daha sonra Specht bu ağların daha gelişmiş şekli olan Probabilistik ağlar (PNN) ve Genel Regrasyon Ağlarını (GRNN) geliştirmişlerdir (1988-1991) (Lee et al., 1999).

Gelişen bilgisayar teknolojisi ile çözümü güç ve karmaşık olan problemlerin çözülmesi hızlı bir şekilde sağlanmıştır. Gelişen bu teknoloji ile birlikte YSA, son yıllarda geniş kullanım alanına (biyoloji (Park et al., 2005), genetik (Ruanet et al., 2001; Ruanet et al., 2005; Mancuso & Nicese, 1999, informatik (Arbib, 2003; La Rocca & Perna, 2005), ekonomide fiyat tahminleri ile ekonometride (Kuan & White, 1994; Kaashoek & van Dijk, 2000, Poldaru & Roots, 2005; Poldaru & Roots, 2003), mühendislikte kalite kontrolü (Hu et al. 2003), ziraat (Yang et al., 2003; Kaul et al., 2005; Uno et al., 2005) sahip olmuştur.

Yapay sinir ağları geleneksel işlemcilerin hesaplamalarından farklı şekilde işlem yaparlar. Bir bilgisayarın işlemcisi (CPU) belirli bir algoritma çerçevesinde kendisine verilen görevi adım adım yaparken, her yapay sinir ağı büyük bir problem sadece kendine ait olan küçük bir parçasını doğrusal olmayan bir şekilde işler ve bir sonuç elde eder.

YSA, aşağıda sıralanan özelliklere sahiptir (Öztemel, 2006).

- Doğrusal olmama,
- Öğrenme,
- Genelleme yapma,
- Adaptasyon,
- Veri işleme,
- Hataya karşı duyarlılık ve tolerans gösterme.

YSA, doğrusal olmayan problemlerin çözümünde başarıyla kullanılır. YSA'nın başka bir özelliği de, incelenen problemi öğrenmesidir. Problemin öğrenilmesinden sonra karşılaşmadığı test örneklerini genelleleyebilir. YSA, sonra veri analize başlar. Sinir ağları, birçok hücrenin bağlanmasından oluşmuş ve paralel dağılmış durumdadır. Bir YSA'nın bazı bağlantılarında problem olması, bilgi aktarımını önemli ölçüde etkilemez. Bu nedenle, hataya karşı duyarlılıkları ve hatayı tolere etme yetenekleri son derece yüksektir.

Yapay sinir ağlarının avantajları, matematiksel olarak modellenemeyen karmaşık problemleri modelleme, olayları ve olaylarla ilişkili durumları öğrenme, olaylarda değişiklik olması durumunda yeniden eğitilebilme, pratik ve ucuz olma şeklinde sıralanabilir. Dezavantajları ise, eğitim sürecinin çok uzun zaman gerektirmesi, örneklerin bulunmasının zor olduğu durumlarda sağlıklı sonuç alınamaması ve en iyi sonucu garanti etmemesi olarak sayılabilir (Öztemel, 2003 a,b).

Tarımda YSA Kullanımı

Bitkisel üretimde YSA kullanımı

Hem hayvansal hem de bitkisel üretimde uygulanan tanımlama (identification) işlemleri sırasında ve sınıflandırma da (classification) YSA'dan yararlanılmaktadır.

Bireylerin-populasyonların genetik benzerlikleri ile farklılıklarının incelenmesinde DNA temelli teknikler, fenotipik ve biyokimyasal özellikler kullanılmaktadır. DNA temelli teknikler, çevresel faktörlerden etkilenmeden doğrudan genetik yapının incelenmesine olanak vermektedirler. RAPD, ISSR gibi DNA temelli analizlerden ve izozimler gibi biyokimyasal özellikler kullanılarak elde edilen sonuçların değerlendirilmesi fotoğrafların, jellerin ya da taranmış jellerin analizini içermektedirler. Genel olarak, jel elektroforezini takiben, proteinlere özgü boylarla jeller boyanarak, bantlar gözle görünür hale getirilmektedirler. Bantların değerlendirilmesinde nisbi yoğunluk ve nisbi hareketlilik kriterleri kullanılabilir. Nisbi yoğunluk, en az boyanan ile en koyu boyanan bantların jel ve jel fotoğrafları üzerinden değerlendirilmesini, nisbi hareketlilik ise üzerinde çalışılan bandın başlangıç noktasına uzaklığı ile referans olarak kullanılan bandın başlangıç noktasına uzaklığı arasındaki orandan hesaplanmaktadır. Geleneksel olarak bu görüntülerden elde edilen bantların varlığında 1, yokluğunda 0 olarak tanımlanmakta ve bir veri matrisi oluşturulmaktadır. Bir ve sıfır olarak tanımlanmış bu verilere yaygın olarak UPGMA (Unweighted Pair Group Method with Arithmetic Mean) yöntemiyle kümeleme analizi yapılmakta ve örnekler arasındaki ilişkiler ortaya konmaktadır. Elektroforetik sonuçların değerlendirilmesi ve genetik tanımlamanın gerçekleştirilmesi uzun bir çalışmayı gerektirmektedir. Bu nedenle moleküler sonuçların incelenmesinde de YSA'nın kullanımı üzerinde durulmuştur (Mancuso & Nicese, 1999; Ruanet et al., 2001; Ruanet et al., 2005).

Ruanet et al. (2001) Durum buğdayında Gliadin proteinin elektroforetik sonuçlarını YSA ile değerlendirmişlerdir. Yapay sinir ağları aracılığıyla, buğday depo proteinlerinden olan gliadinin allelik

varyantlarını tanıyabilen bir veri bankası üzerinde çalışmışlardır. Her bir buğday çeşidi kendine özgü bir gliadin elektroforetik görünümü oluşturmaktadırlar. Gliadin proteini gibi yüksek varyasyon gösteren proteinler, tohum saflığının belirlenmesi ve karakterizasyonunda moleküler markır olarak kullanılabilirler.

Araştırmacılar, protein bantlarını The One- Dscan 1.3 yazılımı aracılığıyla densitometrik ölçümlerini ve standardizasyonunu gerçekleştirmişlerdir. Densitometri sonucunda elde edilen pik yoğunluğu ile uzunluğu parametrelerinin allelerin tanımlanmasında önemlidir. Optik dansite değerleri YSA için giriş (input) bilgilerini; çeşit ve gliadin lokuslarının allelik durumları ise çıkış (output) bilgilerini oluşturmuştur.

Ruanet et al. (2005), DNA markörlerinin görsel değerlendirilmelerinde olabilecek hataların nedenlerini görüntülerden elde edilen bilgilerin biçimlendirilmesinde (formalizasyonu) ve istatistik programların verilere uygulanması sırasında yapıldığını belirtmektedirler. Bununla beraber, YSA'nın da alternatif olarak görüntülerden karar verme gibi karmaşık sorunların çözümünde rahatlıkla kullanılabilir bir yöntem olduğunu belirtmişlerdir.

Ruanet et al. (2005), biber (*Capsicum*) bitkisinde RAPD, AFLP ve ISSR analizleri sonucu elde edilen bantların görüntüleri üzerinde bant yoğunluklarının tespiti, bantların standardize edilmesi ve bu bantlardan bir veri bankası oluşturma işlemlerini gerçekleştirmişlerdir. Biber bitkisinde genetik polimorfizmin tespitinde, yapay sinir ağlarını oluşturmak için Kendinden Organize Özellik Haritaları (Self Organizing Feature Map, SOFM) yöntemini seçmiş, UPGMA (Unweighted Pair Group Method with Arithmetic Mean) ve SOFM sonuçlarını karşılaştırmışlardır. UPGMA ve SOFM sonucunda elde edilen kümelerin % 90'ın üzerinde benzerlik gösterdiklerini bildirmişlerdir.

Mancuso & Nicese (1999), Akdeniz havzasında yaygın olarak yetişen ve ekonomik bir öneme sahip olan zeytin (*Olea europea*) çeşitlerinin tanımlanmasında YSA'nı kullanmışlardır. Zeytinin, 2600'dan fazla çeşidinin tanımlandığı ve bunların bir kısmının sinonimler (aynı bitkinin birden fazla adla adlandırılması) ya da homonimler (farklı bitkilerin aynı tip olarak adlandırılması) olabileceği belirtilmektedir (Rugee & Lavee, 1992; Barronco et al., 2000). Heterojen ve yüksek bir genetik çeşitlilik göstermesi zeytin çeşitlerinin tanımlanması ve sınıflandırılmasını güçleştirmektedir. Çeşit tanımlanmasında izozimler (Trujillo et al., 1990) ya da RAPD (Ganino et al., 2007), AFLP (Owen et al., 2005), ISSR (Gemmas et al., 2004) gibi DNA temelli tekniklerden yararlanılmaktadır. Mancuso & Nicese (1999) Akdeniz bölgesinde yetişen 10 zeytin çeşidinin

ayrılanmasında BPNN (Backpropagation Sinir Ağları) yöntemini uygulamışlardır. Zeytin yapraklarının görüntüleme analizlerinden elde edilen 17 fillometrik özellik (alan, çap, major aksis uzunluğu, minor aksis uzunluğu vb.) üzerinde BPNN'yi kullanmışlardır. En iyi performansın sağlandığı BPNN yapısı belirlenmiş ve BPNN'lerin filometrik özellikler aracılığıyla etkin bir şekilde zeytin çeşitlerinin ayırlandırılmasında kullanılabileceği bildirilmiştir.

Çoban (2004), yapay sinir ağlarını üzüm (*Vitis vinifera L.*) genotiplerinin tanımlanmasında kullanmıştır. Anadolu'nun çeşitli bölgelerinde yetişen 12 üzüm çeşidinde YSA, ampeleografik veriler üzerine uygulanmıştır. Elde edilen sonuçlar YSA'nın bilinmeyen bir varyetenin tanımlanmasında başarılı bir şekilde kullanılabileceğini göstermiştir. Bununla beraber Antep Razakısı ve Dimişki varyetelerinin sinonim olduğunu, Aydın Razakısı ve Çivril Razakısı varyeteleri arasında da dikkate değer bir benzerlik bulunduğunu, Buca ve Dumanlı Razakısı varyeteleri arasında benzerlik olduğunu, bunların dışındaki varyetelerin ise açık bir şekilde farklı olduğu bildirilmiştir.

Hayvansal üretimde YSA kullanımı

Yapay sinir ağlarından hayvansal üretimde de çeşitli araştırmalarda yararlanılmıştır. Kanatlı üretiminde, etlik piliçlerde asitesin (Roush et al., 1996) ve pulmoner hiper tansiyon sendromunun (Kirby et al., 1997) tahminlenmesinde kullanılmıştır. Aynı zamanda, etlik piliçlerde verimlerinin tahminlenmesinde (Salle et al., 2003; Ajakaiye et al., 2006, Ahmadi et al., 2007), yem hammaddelerinin besin değerlerinin tahminlenmesinde (Ahmadi et al., 2008) yararlanılmıştır. Roush et al. (2006), ise çevre kontrollü kümeste yetiştirilen erkek etlik piliçler (Ross X Ross 308) üzerinde yürüttükleri çalışmada, canlı ağırlıkları günlük olarak belirlemişlerdir. Elde edilen veriler aracılığı ile Gompertz ve yapay sinir ağları modellerini karşılaştırmışlardır.

Asites, özellikle yüksek rakımlı bölgelerde barındırılan etlik piliçlerde yaygın olarak görülen bir hastalık olup, sürülerde ölüm oranını artıran önemli nedenlerden biridir. Roush et al. (1997) etlik piliçlerde asitesin tahminlenmesinde Probabilistic Sinir Ağı (PNN)'ni kullanmışlardır. Kan oksijen düzeyi, vücut ağırlığı, EKG, hematokrit, S dalgası ve kalp atım hızı yapay sinir ağında girdiler olarak değerlendirilmiştir. PNN verilerle uygulandığında sinir ağlarının, % 97 oranında doğru bir şekilde asitesli hayvanları teşhis ettiğini saptamışlardır. Roush et al. (1997), yapay sinir ağları ile oluşturulmuş modellerin asites teşhisini geliştirebileceğini ve elde edilen sonuçlarla asites eğilim göstermeyen hatların seçilip, geliştirilmesinde yararlı olabileceğini belirtmişlerdir.

Yapay sinir ağları kompleks veriler için regresyon analizinin bir alternatifi olarak kullanılabilir. Örneğin, yem hammaddesinde ki aminoasit düzeyi ham protein içeriğine göre değişebilmektedir ve aminoasit düzeyinin belirlenmesi, sonuçlar alınincaya dek geçen süre ile kimyasal analizler nedeniyle pahalı bir analiz türüdür. Yem hammaddesindeki aminoasit düzeyinin tespit edilmesinde doğrusal regresyonu kullanan iki kantitatif yöntem geliştirilmiştir. Bunlardan biri ham protein oranı, diğeri ise yakınlık (proximate) analizidir (Roush et al., 1997). Roush et al. (1997), buğday, soya unu, et kemik unu ve balık ununun aminoasit düzeylerini tahminlemek amacıyla Üç Tabakalı Backpropagation Network (BP3), Genelleştirilmiş Regresyon Sinir Ağı (GRNN) ile Doğrusal Regresyon analizini yöntemlerinin karşılaştırmasını yapmışlardır. Her bir tahminleme yöntemi ile Metiyonin, Lizin, Threonin, Tirozin, Triptofan, Arjinin düzeyleri ve modelin R² değerleri hesaplanmıştır. Doğrusal regresyon ile karşılaştırıldığında, R² belirleme katsayısı değeri GRNN için daha yüksek olarak bulunmuştur.

Roush et al. (2006), etlik piliçlerin gelişiminin incelenmesinde yapay sinir ağlarıyla ilgili çalışmaların az sayıda olmasına rağmen biyolojik gelişimin modellenmesinde regresyon analizine alternatif olarak kullanılabileceğini belirtmektedirler. Yee et al. (1993), siçanlardan elde edilen verilerde regresyon analizi ve backpropagation sinir ağları modelini karşılaştırmışlardır. Her iki modelin de yeterli seviyede vücut ağırlığını tahminleyebildiklerini bildirmişlerdir.

Etlik piliçlerde verim performansının hesaplanması sıcaklık, yemin yapısı, yemden yararlanma, hastalıklar ya da yem yeme alışkanlıkları gibi birçok faktöre bağlıdır. Bu faktörlerin doğrusal olmaması verim performansının doğru bir şekilde tahminlenmesini güçleştirmektedir. Problemin doğrusal olmayan yapısından kaynaklanan sorunlar yapay sinir ağlarının uygulanmasıyla çözülebilmektedir (Ajakaiye et al., 2006). Etlik piliçler, değişimlere karşı çok duyarlı olmaları nedeniyle yem değişikliklerinden kolayca etkilenebilmektedirler. Tahıllar, özellikle de mısır etlik piliç rasyonlarında yoğun bir şekilde kullanılmaktadır. Bununla beraber, gelişmekte olan ülkelerde kimi dönemlerde mısır temininde güçlük yaşanabilmektedir. Mısır oranını düşürebilmek amacıyla rasyonlara başka tahılların ilave edilmesi gerekebilmektedir. Ajakaiye et al. (2006), sorgum ve a-glukanaz enzimi ilave edilmiş mısır ile beslenen etlik piliçlerin verim performanslarını yapay sinir ağları aracılığıyla değerlendirmişlerdir. Farklı oranlarda mısır, toz haline getirilmiş sorgum ve enzim içeren yedi rasyon oluşturulmuştur. Giriş değişkenleri olarak mısır yüzdesi, toz sorgum yüzdesi, enzim yüzdesi seçilmiştir. Hayvanların

gram cinsinden son ağırlıkları ise çıkış değişkenidir. Değişkenleri test etmek için "Doğrusal Çoklu Katmanlı Perceptron Sinir Ağı", "Çoklu Katmanlı Perceptron Sinir Ağı", "Genelleştirilmiş İleri Besleme Sinir Ağı" ve "Genelleştirilmiş Regresyon Sinir Ağı" analizleri uygulanmıştır. "Genelleştirilmiş İleri Besleme" ağ modelinin en iyi performansı gösterdiğini ve yapay sinir ağlarının, oluşturulan deneme rasyonlarıyla beslenen hayvanların son ağırlığını tahminlemeyi öğrendiğini bildirmişlerdir. "Genelleştirilmiş İleri Besleme" ile elde edilen sonuçlarda etlik piliçlerin % 35 sorgum tozu ve % 1 enzim ilavesiyle yedi haftada 1,8 kg standart canlı ağırlığa yaklaştıklarını belirtmişlerdir.

Benzer şekilde, Ahmadi et al. (2008) "Group Method of Data Handling Type Neural Network (GMDH-Type NN)" kullanarak kanatlı tüy ve sakatat unlarının gerçek metabolik enerjilerini saptayan bir tahmin modeli geliştirmişlerdir. Tüy ve sakatat unlarının gerçek metabolik enerjileri; eter ekstrakt, kül ve ham protein içeriğine dayanarak tahminlemede GMDH-Type NN kullanılmıştır. Oluşturulan modelin tüy ve sakatat unlarında gerçek metabolik enerjiyi tahminlemede başarılı olduğu bildirilmiştir.

Yapay sinir ağları modelleri sadece kanatlı yetiştiriciliği çalışmalarında değil süt sığırcılığı alanında da kullanılmaktadır. Buna bir örnek olarak Heald et al. (2000), tarafından geliştirilen ve mastitise neden olan mikroorganizmaları ayırmayı sağlayan yapay sinir ağı modeli gösterilebilir.

KAYNAKLAR

- Ajakaiye, A. S., A. B. Adeyemo, Osofisan A.O, and A.P.A Olowu 2006. Analysis of poultry birds production performance using artificial neural networks. *Asian Journal of Information Technology*, 5(5) : 522-527.
- Ahmadi, H., M. Mottaghitab, and N., Nariman-Zadeh 2007. *Group Method of Data Handling-Type Neural Network Prediction of Broiler Performance Based on Dietary Metabolizable Energy, Methionine, and Lysine. J. App.Poult. Res.*,
- Arbib, M 2003. *The handbook of brain theory and neural networks*, MIT Press, Cambridge, MA.
- Barranco, D., A. Cimato, P. Fiorino, L. Rallo, A. Touzani, C. Castañeda, F. Serafin and I. Trujillo 2000. *World Catalogue of olive varieties*, 360 pp. Consejo Oleícola Internacional, Madrid, España.
- Chtioui, Y., D. Bertrand, M. F. Devaux, D. Barba 1997. Comparison of Multilayer perceptron and probabilistic neural networks in artificial vision: Application to the Discrimination of Seeds. *J Chemom.*, 11:111-29.
- Civalek, Ö 1998. Nöro-Fuzzy Tekniği ile Dikdörtgen Plakların Analizi. III. Ulusal Hesaplamalı Mekaniğin Konferansı, 16-18 Kasım, İstanbul, s: 518-524.
- Çoban, H 2004. Application of an artificial neural network (ANN) for the identification of grapevine (*Vitis vinifera* L.) genotypes. *Asian Journal of plant Sciences*. 3 (30):340-343.
- "Üç Katmanlı İleri Besleme Sinir Ağı modeli" Paquet et al., (2000), tarafından peynirin üretimi boyunca çökeleğin pH'ını tahminlemek amacıyla kullanılmıştır. Grezsiak et al. (2003) ise süt verimini tahmin etmede YSA'ndan yararlanmışlardır. Fernandez et al. (2007), gelecek haftanın süt veriminin tahminlenmesinde şimdiki ve geçmiş süt verim verilerinden yararlanmışlardır. Laktasyon sayısı, yavrulama sayısı, canlı ağırlıklar değerlendirilerek 35 adet *Muciano-Granadina* süt keçisinde; rasyon, süt üretimi, laktasyon dönemi, doğum ile ilk günler arasında geçen süre, analizde modele alınmıştır. En önemli değişkenlerin şimdiki ve önceki süt verimleri, ilk süt kontrolü ve rasyon olduğunu belirlemişlerdir. Yapay sinir ağlarının, haftalık süt veriminin tahmin edilmesinde uygun bir yöntem olduğunu bildirmişlerdir.

SONUÇ

Yapay sinir ağlarından diğer birçok alanda olduğu gibi tarımsal araştırmalarda da yararlanılabilmektedir. Girdi ve çıktılar arasındaki karmaşık ilişkilerin modellenmesinde uygun bir yöntem olarak göze çarpmaktadır. Yapay sinir ağı modellerinin, öğrenebilme yeteneğine sahip bir model olması da sınıflandırma ve tahminleme işlemlerinin başarıyla kullanılmasına neden olmaktadır. Ayrıca, yapay sinir ağları; öğrenme, karar verebilme ve kolay adapte olabilme yeteneği sayesinde karmaşık yapıya sahip problemlerin çözümünde de kullanılabilmektedirler.

Demuth, H., Beale, M., Hagan, M 2006. *"Neural Network Toolbox, for use with MATLAB", "User Guide Version 5"*.

Fernández C., E. Soria, P. Sánchez-Seiquer, L. Gómez-Chova, R. Magdalena, J. D. Martín-Guerrero, M. J. Navarro and A. J. Serrano 2007. *Weekly milk prediction on dairy goats using neural networks. Neural Computing & Applications*. 16: 373-381.

Ganino, T., D. Beghé, S. Valenti, R. Nisi and A. Fabbri 2007. A RAPD and SSR markers for characterization and identification of ancient cultivars of *Olea europaea* L. in the Emilia region, Northern Italy. *Genet. Resour. Crop Evol.*, 54., pp. 1531-1540.

Gemas V.J.V., M.C. Almadanin, R. Tenreiro, A. Martins and P. Feveireiro 2004. Genetic diversity in the Olive tree (*Olea europaea* L. subsp. *europaea*) cultivated in Portugal revealed by RAPD and ISSR markers. *Genet. Resour. Crop Evol.* 51: 501-511.

Grzesiak, W. R. Lacroix, J. Wojcik and P. Błaszczuk 2003. A comparison of neural network and multiple regression predictions for 305-day lactation yield using partial lactation records. *Can. J. Anim. Sci.*, 83 (2): 307-310.

Heald, C.W., T. Kim, W.M. Sischo, J.B. Cooper and D.R. Wolfgang 2000. A computerized mastitis decision aid using farm-based records: an artificial neural network approach. *J. Dairy Sci.* 83 (2000), pp. 711-722.

- Hu, Y.H. and Hwang, J.N 2003. Handbook of neural network signal processing, Academic Press, London.
- Kaashoek, J.F., and H.K. van Dijk 2000. Neural Networks as econometric tool. Econometric Institute Rapport EI2000-31A. Economic Institute, Erasmus University Rotterdam. Rotterdam, 29 pp.
- Kaul, M., R.L. Hill and C. Walthall 2005. Artificial neural networks for corn and soybean yield prediction. Agriculture Systems, 85(1), 1-18.
- Kayabaş, İ. ve H. Yıldırım 2008. Yapay sinir ağlarının uzaktan eğitimde destek için kullanımı. Anadolu Üniversitesi 8th International Educational Technology Conference. 542-545.
- Kuan, C.M. and H. White 1994. Artificial neural networks: An econometric perspective. Econometric Reviews., 13, 1-92.
- Kominakis, A.P., Abas, Z., Maltaris, I., and Rogdakis, E 2002. A preliminary study of the application of artificial neural networks to prediction of milk yield in dairy sheep. Computers and Electronics in Agriculture., 35(1), 35-48.
- Kirby, Y. K., R. W. McNew, J. D. Kirby, and R. F. Wideman 1997. Evaluation of logistic versus linear regression models for predicting pulmonary hypertension syndrome (ascites) using cold exposure or pulmonary artery clamp models in broilers. Poul. Sci., 76:392-399.
- La Rocca, M. and C. Perna. 2005. Variable selection in neural network regression models with dependent data: a subsampling approach. Computational Statistics & Data Analysis., 48(2), 415-429.
- Lee, C.C, P.C. Chung, J.R. Tsai, C.I. Chang. 1999. Robust. Radial basis function neural networks. Systems, Man, and Cybernetics, Part B: Cybernetics, IEEE Transactions on. IEEE Xplore 1999; 29(6):674-85.
- Miller, J 2003. Evolving developmental programs for adaptation, morphogenesis, and self-repair. W. Banzhaf, J. Ziegler and T. Christaller, Editors, Proceedings of the European congress of artificial life, ECAL. pp. 256-265.
- Mancuso, S. and F.P. Nicese 1999. Identifying olive (*Olea europaea*) cultivars using artificial neural networks. J. Am. Soc. Hort. Sci., 124, pp. 527-531.
- Owen, C.A, E.C. Bitar, G. Banilas, S.E Hajjar, V. Sellianakis, U. Aksoy, S. Hepaksoy, R. Chamoun, S.N Talhook, I. Metzidakis, P. Hatzopoulos, P. Kalaitzis 2005. AFLP reveals structural details of genetic diversity within cultivated olive germplasm from the Eastern Mediterranean. Theor. Appl. Genet., 110: 1169-1176.
- Öztemel, E 2006. Yapay Sinir Ağları, Papatya Yayıncılık, İstanbul, Eylül 2006.
- Öztemel, E 2003 a. Artificial Neural Networks. 1st ed. Papatya Yayıncılık, İstanbul. s.36.
- Öztemel, E 2003 b. Artificial Neural Networks. 1st ed. Papatya Yayıncılık, İstanbul. s.40.
- Park, J. and M. Schlag-Rey 2005. Frames of reference for saccadic command, tested by saccade collision in the supplementary eye field. J. Neurophysiol., 95, 159-170.
- Paquet, J., C. Lacroix and J. Thibault 2000. Modeling of pH and Acidity for Industrial Cheese Production. J. Dairy Sci., 83 (11): 2393-2409.
- Poldaru, R., J. Roots, and A. H. Vira 2005. Artificial neural network as an alternative to multiple regression analysis for estimating the parameters for econometric models. Agronomy Research., 3(2), 177-187.
- Poldaru, R., and J. Roots 2003. The estimation of the econometric model of grain yield in Estonian Counties using neural Networks. VAGOS. 57(10): 124-130.
- Roush, W.B., Y.K. Kirby and T.L. Cravener and R.F. Wideman. 1996. Artificial neural network prediction of ascites in broilers. Poul. Sci., 75 (12):1479-1487
- Roush, W.B., T.L. Cravener, Y.K. Kirby and R.F. Wideman 1997. Probabilistic neural network prediction of ascites in broilers based on minimally invasive physiological factors. Poul. Sci., 76 (11):1513-1516.
- Roush, W.B., W.A Dozier and S.L. Branton 2006. Comparison of gompertz and neural network models of broiler growth. Poul. Sci., 85 (4): 794-797.
- Ruanet, V.V., A.M. Kudryavtsev and S.Y. Dadashev 2001. The use of artificial neural networks for automatic analysis and genetic identification of gliadin electrophoretic spectra in durum wheat. Russ. J. Genet., 37(10): 1435-1437.
- Ruanet V.V., E.Z. Kochieva and N.N Ryzhova 2005. Kohonen network study of the results of RAPD and ISSR analyses of genomic polymorphism in the genus *Capsicum* L. Russ. J. Genet., 4: 202-210.
- Rugini, E. and S. Lavee 1992. Olive in: Biotechnology of perennial fruit crops, Eds. Hammerchlag FA and Litz RE. CAB International, pp. 371-382.
- Salle, C.T.P, A.S. Guahyba, V.B. Wald, A.B. Silva, F.O. Salle and V.P. Nascimento 2003. Use of artificial neural networks to estimate production parameters of broilers breeders in the production phase. Br. Poul. Sci., 44 (2): 211-217.
- Takci, H 2008. GYTE, Bilgisayar Mühendisliği Bölümü, BİL 482-BİL 606 Yapay Sinir Ağları Ders Sunumu. <http://www.bilmuh.gyte.edu.tr/BIL482/>.
- Trujillo, I., L. Rallo, E.A. Carbonell and M.J. Asins 1990. Isoenzymatic variability of olive cultivars according to their origin. Acta. Hort., 286: 137-140.
- Uno, Y., S.O. Prasher, R. Lacroix, P.K Goel, Y. Karimi, A. Viau, R.M Patel 2005. Artificial neural networks to predict corn yield from Compact Airbone Spectrographic Imager data. Computers and Electronics in Agriculture. 47(2), 149-161.
- Yang, C.C., S.O. Prasher, J.A Landry and H.S Ramaswamy 2003. Development of a herbicide application map using artificial neural Networks and fuzzy logic. Agricultural Systems 76(2), 561-574.
- Yee, D., M.G Prior and L.Z Florence 1993. Development of predictive models of laboratory animal growth using artificial neural networks. Oxford Journals., 9 (5): 517-522.
- Zhang, G.P 2007. A neural network ensemble method with jittered training data for time series forecasting. Information Sciences. 177: 5329-5346.