

Üç Farklı Yapay Sinir Ağı Yöntemi Kullanılarak Toprak Penetrasyon Direnci Tahmini

İlker ÜNAL¹, Salih SÖZER¹, Önder KABAS¹, Süleyman ÇETİN¹, Mehmet TOPAKCI²

¹Akdeniz Üniversitesi, Teknik Bilimler Meslek Yüksekokulu, Antalya, Türkiye

²Akdeniz Üniversitesi, Ziraat Fakültesi, Tarım Makinaları ve Teknolojileri Mühendisliği Bölümü, Antalya, Türkiye
ilkerunal@akdeniz.edu.tr

Geliş Tarihi (Received): 13.05.2016 Kabul Tarihi (Accepted): 03.08.2016

Özet: Toprak sıkışması, toprağın fiziksel, kimyasal ve biyolojik özelliklerine olumsuz yönde etki ederek bitki gelişimini engelleyen önemli bir problemdir. Bu problemin bitki gelişimine olan etkilerinin belirlenebilmesi için üretim alanının birçok noktasından toprak penetrasyon direnci verilerinin toplanması gerekmektedir. Büyük üretim alanlarından toprak penetrasyon direnci verilerinin toplanması araştırmacılar için zaman alıcı ve yorucu bir uygulamadır. Ayrıca, ölçüm yapılan nokta sayısı ne derecede üretim alanının tamamının değerlendirilmesinde yeterli olacağı belirsizdir. Bu nedenle, çalışma yapılan alanın bütününe değerlendirebilmek için ölçüm yapılmayan noktalara ait toprak penetrasyon direnci verilerinin de tahmin edilmesi gerekmektedir. Matematiksel bir hesaplama ve modelleme yöntemi olan yapay sinir ağları, bilinen minimum test verileri ile bilinmeyen verilerin tahmin edilmesinde kullanılan güncel bir yöntemdir. Çalışmada, 20 ha büyüklüğündeki alanın 1603 farklı noktasından ve 40 cm derinliğinden alınan coğrafik konum ve toprak penetrasyon direnci verileri toplanmıştır. Toplanan 1603 verinin, %24'ü test, geri kalan %76'lık kısım eğitim için kullanılmıştır. Ölçümü yapılmayan noktalara ait direnci değerleri, Matlab içerisindeki Genelleştirilmiş Regresyon Sinir Ağı (Generalised Regression Neural Network, GRNN), Çok Katmanlı Algılayıcı (MLP) ve Radyal Temelli Fonksiyonlar (RBF) yöntemleri kullanılarak tahmin edilmiştir. Bu değerlere ek olarak mutlak hata (MSE), ortalama karekök hatası (RMSE) ve ortalama mutlak hata (MAE) değerleri hesaplanmıştır. Sonuç olarak Radyal Temelli Fonksiyonlar yönteminin gerçek değerlere yakınsama durumunun iyi olduğu tespit edilmiştir.

Anahtar Kelimeler: GRNN, MLP, RBF, toprak penetrasyon direnci, yapay sinir ağları

Soil Penetration Resistance Prediction with Three Different Artificial Neural Networking

Abstract: Soil compaction is a major problem affecting negatively the soil physical, chemical and biological properties and impedes plant root growth. Soil penetration resistance values should be collected from many points of the production area to determine the effects of these problems on plant growth. Soil penetration value collection from large production areas is time-consuming and tedious application for researchers. Also, the number of measurement points to what extent will be sufficient to evaluation on whole production area is not clear. To eliminate this ambiguity, soil penetration values of the unmeasured points should be estimated to evaluate the whole area. Artificial neural networks are one of the most popular mathematical computing and modelling method used to estimate unknown data values with known data values. In this study, we collected 1603 samples of geographical position and soil penetration value from 40 cm depth within the 20 ha field. From the 1603 values, 24% records were selected for testing and the remaining 76% records were used for educating. Soil penetration values of the unmeasured points were estimated using Generalized Regression Neural Network (GRNN), Multi Layer Perceptron (MLP) and Radial Bias Function (RBF) methods in Matlab. In addition to mean squared error (MSE), root mean square error (RMSE) and mean absolute error (MAE) has been also used for evaluation of prediction accuracy on these methods. RBF results showed very good agreement between the predicted and the measured real values of soil resistance.

Key words: Artificial neural network, GRNN, MLP, RBF, soil penetration resistance

GİRİŞ

Toprak sıkışması, toprağın fiziksel, kimyasal ve biyolojik yapısını olumsuz etkileyerek bitki gelişimini kısıtlayan ve dolayısıyla ürün verimini azaltan, makine kullanım maliyetlerini artıran önemli bir faktördür. Toprak sıkışmasının olumsuz etkilerinin incelenmesi ve gerekli tedbirlerin alınması için toprak penetrasyon direnç verilerinin belirlenmesi gerekmektedir. Toprak penetrasyon direnç verileri, kök gelişimi ve ürün verimi (Ehlers ve ark., 1983), toprak işleme sistemlerinin etkileri (Abrougui ve ark. 2012), toprak katmanları içerisindeki su içeriği (Cerana ve ark., 2005), hacimsel kütle ve toprak nemi (Díaz ve ark., 2010) gibi özelliklerin penetrasyon direnci ile olan ilişkilerinin belirlenmesinde kullanılmaktadır. Toprak penetrasyon direncinin ölçümünde, hızlı, ekonomik ve kullanım kolaylığı nedeni ile konik penetrometreler tercih edilir (Miller ve ark. 2001). Penetrasyon direncinin mekânsal değişkenliklerden çok fazla etkilenmesinden dolayı yeterli doğrulukta veri elde edilmesi fazla miktarda ölçüm yapmayı gerektirmektedir (Vaz ve ark., 2001).

Günümüzde tarımsal üretim, doğru zamanda, doğru yerde ve doğru şekilde yeni teknolojileri kullanarak, çevreye verilen olumsuz etkileri azaltmayı, sürdürülebilir üretimi sağlamayı, verim ve kazancı artırmayı amaçlayarak, bilgiye dayalı olarak yapılmaktadır (Bongiovanni ve Lowenberg-Deboer, 2004). Tarımsal üretim için gerekli olan tohum, gübre, ilaç gibi girdiler üretim alanlarına gelişigüzel değil, değişken düzeyli olarak uygulanmaktadır. Bu girdilerin değişken düzeyli olarak uygulanabilmesi için üretim yapılan alanın her bir noktasına ait değişkenliklerin önceden ölçülmesi gerekmektedir. Ayrıca, büyük üretim alanlarının her bir noktasından ölçüm yapmak kolay olmadığı için belli noktalardan alınan veriler yardımı ile ölçüm yapılmayan noktaların tahmin edilmesi gerekmektedir. Regresyon analizi, istatistiksel metotlar ve çeşitli enterpolasyon yöntemleri, tahmin işlemlerinde yaygın olarak kullanılmaktadır. Günümüzde tahmin uygulamalarında kullanılan yöntemlerden bir tanesi de yapay sinir ağlarıdır (YSA).

YSA yönteminin temel mimarisi, Rumelhart ve McClelland (1986), Lippmann (1987), tarafından detaylı bir şekilde ele alınmış, 1990 yıllarında, (Hecht 1990, Maren vd., 1990, Zurada 1992, Fausett 1994, Ripley 1996) ile devam ederek doğrusal olmayan

problemlerin çözümünde çoklu değişkenler arasında mükemmel performansı yakalamasından dolayı YSA'ya olan ilgi her geçen gün artmıştır (Önalp ve Arel, 2011).

Yapay sinir ağları başlıca; Sınıflandırma, Modelleme ve Tahmin uygulamaları olmak üzere, pek çok alanda kullanılmaktadır. YSA'lar çok boyutlu, karmaşık, kesin olmayan, eksik, kusurlu, hata olasılığı yüksek sensör verilerinin olması ve problemi çözmek için matematiksel modelin ve algoritmaların bulunmadığı, sadece örneklerin var olduğu durumlarda yaygın olarak kullanıldıkları görülmektedir. YSA, insan beyninin çalışma tarzına benzer bir biçimde, biyolojik nöron hücrelerinin yapısı ve öğrenme karakteristiklerinden esinlenerek geliştirilmiş, birlikte işleyen çok sayıda işleme elemanından (nöron) oluşan bir bilgisayar işleme ve hesaplama sistemi olarak tanımlanabilir (Haykin, 1999).

YSA'lar tarım sistemi gibi karmaşık sistemlerin matematiksel olarak modellenmesi için uygundur (Hashimoto, 1997). Tarım alanında YSA'lar bitki örtüsü tanıma (Bocco ve ark., 2007), toprak hidrodinamiği (Rubio, 2005), toprak erozyonu (Mas ve ark., 2002), yeraltı su kirliliği (García ve ark., 2010), verim tahmini (Liu ve ark., 2001), tarımsal mekanizasyon modellerinin kılavuz parametrelerinin tahmini (Pinto ve ark., 1999) ve alana özgü parametrelerin belirlenmesi (Braga, 2000) gibi çok geniş bir yelpazede uygulama alanı bulmuştur. Ancak toprağın mekanik özellikleri ile ilgili çok fazla YSA çalışmasına rastlanmamıştır. Holguín ve ark. (2011), farklı derinliklerdeki nem, hacimsel kütle ve statik yük gibi parametreleri kullanarak toprak penetrasyon direncini YSA kullanarak tahmin etmişler ve en iyi tahmin sonuçlarını 20-30 cm derinliklerinde elde ettiklerini bildirmişlerdir. Bayat ve ark. (2008), toprak penetrasyon direnci tahmini için, 2 farklı çalışma alanından topladıkları 381 adet penetrasyon direnci, hacimsel kütle, gravimetrik toprak su içeriği verileri arasındaki ilişkileri iki farklı YSA yöntemi kullanarak karşılaştırmışlardır. Abrougui ve ark. (2012), farklı toprak işleme sistemlerinin toprak penetrasyon direnci üzerindeki etkilerini araştırmak için YSA modellerinden yararlanmışlardır.

Bu çalışmada, üç farklı YSA metodu kullanılarak ölçüm yapılmayan noktalara ait toprak penetrasyon

direnç değerleri, ölçüm yapılan noktalara ait gerçek değerler kullanılarak tahmin edilmiştir. Üç yöntem, istatistiksel olarak birbirleriyle karşılaştırılarak en uygun yapay sinir ağı modeli belirlenmeye çalışılmıştır.


MATERYAL ve YÖNTEM

Deneme Alanı

Penetrasyon direnci toplama çalışmaları Akdeniz Üniversitesi, Ziraat Fakültesi Araştırma ve Uygulama Çiftliğinde yürütülmüştür. Araştırma alanı, Antalya'dan yaklaşık 20 km uzaklıkta olup 30.84 E ve 36.94 N koordinatları arasında yer almaktadır. Toprak tipi killi tın bünyeye sahip olup %41 kum, %26 silt ve %33 kil içermektedir. Organik madde içeriği %1.3' tür. Kütesel yoğunluk ve su içerik değerleri 0-20 cm aralığında sırasıyla 1.32 g/cm³ ve %7.5, 20-40 cm aralığında ise 1.38 g/cm³ ve %8.9 olarak belirlenmiştir.

Veri Toplama

Penetrasyon direnci verileri, kısa bir süre önce buğday hasadı yapılmış olan 20 ha büyüklüğündeki deneme alanından toplanmıştır. Veri toplama işlemi için, Topakçı ve ark. (2010) tarafından geliştirilen ve traktör üç nokta askı sistemine bağlanan yatay penetrometre kullanılmıştır (Şekil 1). Yatay penetrometre Massey Ferguson 3095D dört çeker traktöre bağlanmıştır. Deneme verileri, sıra arası mesafeler 15 m olacak şekilde 13 sıra ve 40 cm derinlikten alınmıştır. Çalışma esnasında bazı noktalarda penetrometre toprak dışarısına alınmıştır. Bu esnada toplanan veriler, veri setinden çıkarılmıştır. Literatürde yapılmış birçok çalışmada toprakların traktör ve bağlı ekipmanlar ile işlenmesi sonucu toprak bünyesine de bağlı olarak 30-60 cm aralığında sert tabakanın oluştuğu belirtilmiştir. Bu sebeple, deneme verileri 40 cm derinlikten toplanmıştır. Traktörün ilerleme hızı GPS verilerine göre ortalama 2.39 km/h olarak belirlenmiştir. Çalışma süresi boyunca bir saniye aralıklarla toplam 1603 noktaya ait toprak penetrasyon direnci verileri kayıt altına alınmıştır.



Şekil 1. Yatay penetrometre (Topakçı ve ark., 2010)

Figure 1. Horizontal penetrometer (Topakci et al., 2010)

Yapay sinir ağı modelleri

Yapılan çalışmada tahmin işlemi için üç farklı (GRNN, MLP, RBF) YSA modeli kullanılmıştır. YSA modellerinin tamamı yapay sinir hücrelerinin birbirine bağlanmasıyla oluşan yapılardır. Yapay sinir ağları üç ana katmanda incelenir; Giriş Katmanı, Ara (Gizli) Katmanlar ve Çıkış Katmanı. Ancak her bir katman içerisinde kullanılan matematiksel fonksiyonların farklı olması nedeniyle literatürde farklı sinir ağı modelleri karşımıza çıkmaktadır.

GRNN, Specht (1991) tarafından literatüre katılan, eğitim verisini kullanılarak girdi ve çıktı vektörleri

arasında herhangi bir fonksiyonu tahmin etmeye dayalı bir metottur. Eğitim için ayrılan veri kümesi genişledikçe tahmin hatası sifira inmektedir. Regresyon, herhangi bir bağımsız x değişkeni ve eğitim verisinden, en olası bağımlı y değişkenini tahmin etmeye dayalı bir metottur. Regresyon metodu, ortak kare hatasını en aza indirecek y'yi tahmin etmektedir. GRNN, bir eğitim seti verildiğinde, x ve y'nin ortak olasılık yoğunluk fonksiyonunu tahmin etmeye çalışan bir metottur.

Günümüzde en çok bilinen ve yaygın biçimde kullanılan yapay sinir ağı sınıflandırma yöntemlerinden

bir tanesi de MLP' dir (White, 1990; Almeida, 1997). Genel amaçlı, esnek ve çoklu tabakalar halinde organize edilmiş birimlerden (nöron) oluşan doğrusal olmayan (non-linear) modellerdir. MLP sinir ağı hemen hemen her fonksiyonu tahmin etme/ yaklaşım özelliğine sahip bir ağıdır. Sinir ağının çalıştırılması (öğrenmesi) ağın sonuç değeri ile hedeflenen sonuçlar arasındaki (farkın) hata ölçüsünün minimum yapılması esasına dayanır. Bu değerler çalıştırma (eğitim) aşamasında geriye doğru yayılarak ve yinelemeli biçimde gerçekleştirilir. Algoritma bu nedenle Geri Yayılma Algoritması olarak adlandırılmıştır (Rumelhart, Lippman, 1987).

Radyal Tabanlı Fonksiyon Ağları, 1988 yılında Broomhead ve Lawe tarafından, 1989 yılında Moody ve Darken tarafından çok tabakalı algılayıcılara (MLP) alternatif olarak geliştirilen sinir ağı tipidir (Cheng ve Lee, 2001, Györfi ve ark, 2002). RBF, ileri beslemeli YSA yapılarına benzer şekilde giriş, saklı ve çıkış katmanından oluşur ancak, giriş katmanından saklı katmana dönüşüm, radyal tabanlı aktivasyon fonksiyonları ile doğrusal olmayan sabit bir dönüşümdür. Saklı katmandan çıkış katmanına ise uyarlamalı ve doğrusal bir dönüşüm gerçekleştirilir (Klir ve Yuan, 1995).

Yapay sinir ağlarının performans analizi

Yapay sinir ağı modellerinin performansı, deneme ve doğrulama adımları süresince ortalama karekök hatası (RMSE), kareler toplamı hatası (SSE), ortalama mutlak hata (MAE), ortalama hata karesi (MSE), korelasyon faktörü gibi farklı tekniklerle değerlendirilebilmektedir (Goyal ve Goyal, 2011). Bu çalışmada istatistiksel analiz için MSE, RMSE ve MAE verileri kullanılmıştır.

$$MSE = \sum_{t=1}^N \left(\frac{Y_t - O_t}{T} \right)^2$$


$$RMSE = \sqrt{\frac{1}{T} \left[\sum_{t=1}^N \left(\frac{Y_t - O_t}{Y_t} \right)^2 \right]}$$

$$MAE = \frac{1}{T} \sum_{t=1}^N |Y_t - O_t|$$

Burada, Y_t beklenen çıkış, O_t gözlenen çıkış, T kayıt sayısı ve N örnekleme katmanındaki nöron sayısı olarak kullanılmıştır.

Yapay sinir ağı modellerinin örnekleme

Çalışmada, traktöre bağlı yatay penetrometre kullanılarak çalışma yapılan alana ait GPS ve toprak penetrasyon direnç değerleri saniyede bir olacak şekilde elde edilmiştir. Çalışma sonucunda toplamda 13 paralel hat üzerinden 1603 kayıt toplanmıştır (Şekil 2). İlk üç ve son üç paralel hat YSA modelleri içerisinde ekstrapolasyon (EXT1, EXT2) işlemine, ortadaki üç paralel hat ise interpolasyon (INT 1) işlemine tabi tutulmuştur. Burada belirtilen kayıtlar çalışmada test seti için kullanılmış diğer geri kalan kayıtlar ise eğitim ve doğrulama işlemi için kullanılmıştır. Tablo 1'de test ve eğitim veri seti sayıları verilmiştir.



Şekil 2. Veri toplama haritası
Figure 2. Data collection map

Tablo 1. Test ve eğitim veri seti sayıları

Table 1. Numbers of testing and educating datasets

	Test	Eğitim
EXT 1	401	1202
INT 1	361	1242
EXT 2	340	1263

BULGULAR ve TARTIŞMA

Çalışmada, alandan elde edilen gerçek toprak penetrasyon direnç değerleri ile üç farklı yapay sinir ağı modelinden elde edilmiş olan tahmini değerler karşılaştırılmıştır. EXT 1 işlemine ait sonuçlar grafik Şekil 3' de, INT 1 işlemine ait sonuçlar grafik Şekil 4' de ve EXT 2 işlemine ait sonuçlar ise Şekil 5' de verilmiştir. Tüm yöntemlere ait istatistiksel sonuçlar Tablo 2' de verilmiştir.


Tablo 2 içerisinde, her üç istatistiksel yöntem değerlendirildiğinde RBF yönteminin toprak penetrasyon direnç değer tahmininde diğer yöntemlere göre gerçek değerlere daha yakın sonuç verdiği gözlemlenmektedir (MSE:0.1608;

RMSE:0.3717; MAE:0.3682). Çalışma sonucunda MLP yönteminin toprak penetrasyon direnci tahmin işleminde en kötü sonucu verdiği belirlenmiştir (MSE:0.05454; RMSE:0.5004; MAE:1.2860). Literatürde toprak penetrasyon direnci tahmininde her üç yöntemin karşılaştırıldığı bir çalışmaya rastlanmamıştır. Ancak farklı konularda üç yöntemin karşılaştırıldığı çalışmalara rastlanmıştır. Moreno ve ark. (2011) yılında zaman serilerinin tahmin edilmesi amacıyla yaptıkları çalışmada RBF ve MLP yöntemlerinin en iyi sonucu verdiğini GRNN yönteminin ise en kötü sonucu verdiğini bildirmişlerdir. Faris ve ark. (2014), atmosferdeki yüzey ozon tabakasının tahmin edilmesi ile ilgili yaptıkları

Üç Farklı Yapay Sinir Ağı Yöntemi Kullanılarak Toprak Penetrasyon Direnci Tahmini

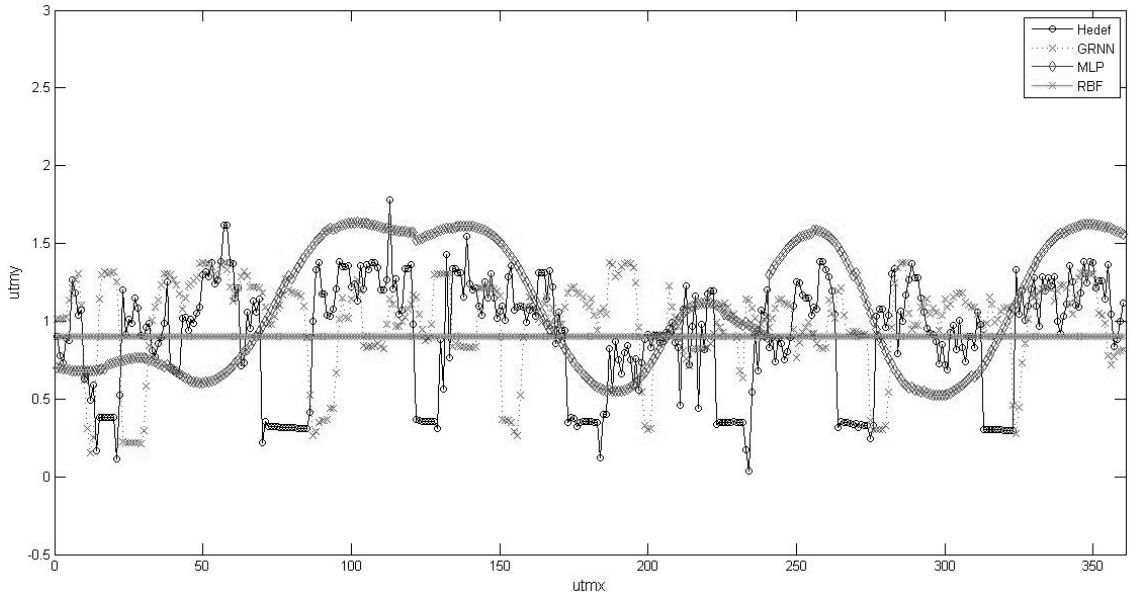
çalışmalarında MLP yönteminin RBF yöntemine göre sonuçlarının kötü olduğunu bildirmişlerdir. Diğer taraftan Kandirmaz ve ark. (2014) Türkiye'nin aylık güneşlenme sürelerinin tahmin edilmesine yönelik

yaptıkları çalışmada, GRNN ve MLP yöntemlerinin RBF yöntemine göre daha iyi sonuç verdiklerini bildirmişlerdir.



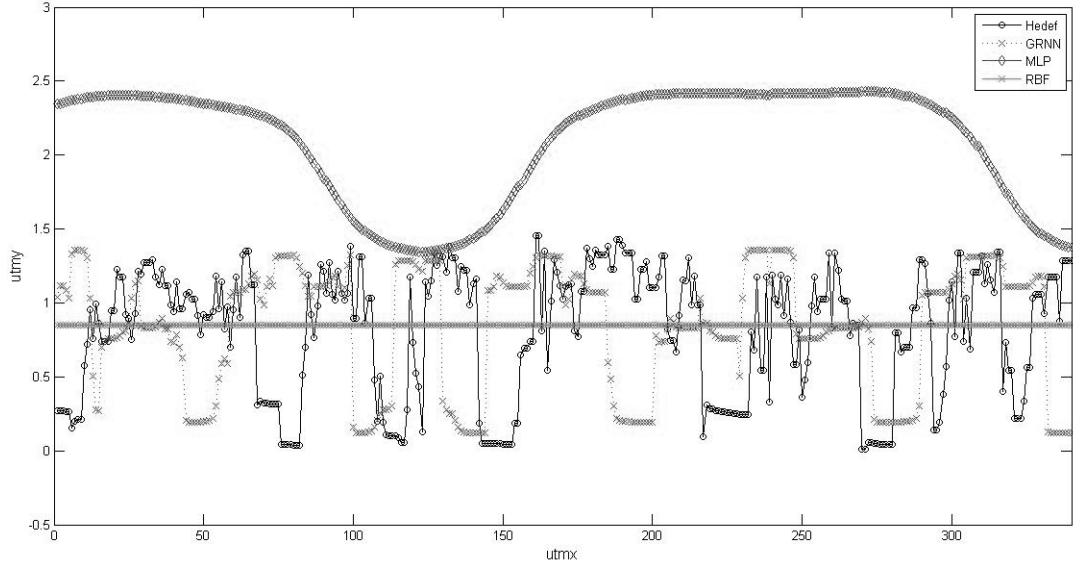
Şekil 3. EXT 1 işlemine ait sonuçlar

Figure 3. EXT 1 process results



Şekil 4. INT 1 işlemine ait sonuçlar

Figure 4. INT 1 process results



Şekil 5. EXT 2 işleme ait sonuçlar
Figure 5. EXT 2 process results

Tablo 2. Enterpolasyon ve interpolasyon işlemlerine ait istatistiksel sonuçlar

Table 2. Statistical results of extrapolation and interpolation process

		EXT 1	INT 1	EXT 2
GRNN($\sigma=1$)	MSE	0.2506	0.2443	0.4092
	RMSE	0.5006	0.4943	0.6397
	MAE	0.372	0.4007	0.5136
MLP	MSE	0.5454	0.2504	1.9789
	RMSE	0.7385	0.5004	1.4067
	MAE	0.6111	0.4128	1.2860
RBF($\sigma=0.82$)	MSE	0.1608	0.1382	0.1894
	RMSE	0.4010	0.3717	0.4352
	MAE	0.3104	0.3121	0.3682

SONUÇ

Bu çalışmada, üç farklı YSA yöntemi kullanılarak toprak penetrasyon direnç değerleri tahmin edilmeye çalışılmış ve sonuçlar karşılaştırılmıştır. Çalışma ile ilgili gerçek değerler deneme alanının her noktasından bir saniye aralıklarla toplanmıştır. Toplanan verilerin bir kısmı sinir ağıni eğitmek için diğer kısmı ise eğitmek

ve doğrulamak için kullanılmıştır. Gerçek veriler ile tahmin edilen veriler arasındaki en iyi ilişki RBF yönteminde tespit edilmiştir. Özellikle sıkıcı ve uzun süreli çalışma gerektiren penetrasyon direnci ölçümlerinde ölçülmeyen noktaların tahmin edilmesinde bu yöntemin kullanılmasının araştırmacılar için kolaylık sağlayacağı düşünülmektedir.

LİTERATÜR LİSTESİ

Abrougui K, Chehaibi S, Louvet JN, Hannachi C and Destain MF (2012). Soil Structure and the Effect of Tillage Systems. Bulletin UASVM Agriculture, 69: 11-16.
Bayat H, Neyshabouri MR, Hajabbasi MA, Mahboubi AA, Mosaddeghi MR (2008). Comparing neural networks, linear and nonlinear regression techniques to model penetration resistance. Turkish Journal of Agricultural Forestry, 32: 1-9.

Bocco M, Obando G, Sayago S and Willington E (2007). Neural network models for land cover classification from satellite images. Agric. Téc., 67(4): 414-421.
Bongiovanni R and Lowenberg-Deboer J (2004). Precision Agriculture and Sustainability. Precision Agriculture, 5(4): 359-387.
Braga RP (2000). Predicting the spatial pattern of grain yield under water limiting conditions. University of Florida, PhD thesis, Florida.

- Cerana J, Wilson M, Pozzolo O, De Battista JJ, Rivarola S, and Díaz E (2005). Relaciones mate-máticas entre la resistencia mecánica a la pene-tración y el contenido hídrico en un Vertisol. *Estudios de la Zona no Saturada del Suelo*, 7: 159-163.
- Cheng CB, Lee ES (2001) Fuzzy Regression With Radial Basis Function Network. *Fuzzy Sets and Systems*, 119: 291-301.
- Díaz CG, Osinaga R and Arzeno J (2010). Resistencia a la penetración, humedad del suelo y densidad aparente como indicadores de calidad de suelos en parcelas de largo plazo. XXII Congreso Argentino de la Ciencia del Suelo, Rosario, Argentina.
- Ehlers W, Köpke U, Hesse F and Bohm W (1983). Penetration resistance and root growth of oats in tilled and untilled loess soil. *Soil Tillage Res.*, 3: 261-275.
- Fausett LV (1994). *Fundamentals neural Networks: Architecture, algorithms, and applications*, Englewood Cliffs, New Jersey, 1-449.
- García I, Rodríguez JG, López F and Tenorio YM (2010). Transporte de contaminantes en aguas subterráneas mediante redes neuronales artificiales. *Inf. Tecnol*, 21(5):79-86.
- Goyal S and Goyal G K (2011). Cascade and feed-forward backpropagation artificial neural network models for prediction of sensory quality of instant coffee flavoured sterilized drink. *Can. J. Artif. In-tell. Machine Learn. Pattern Recog.* 2(6):78 - 82.
- Györfi L, Kohler M, Krzyak A, Walk H (2002). *Distribution Free Theory of Nonparametric Regression*, Springer-Verlag, New York.
- Hashimoto Y (1997). Application artificial neural network and genetic algorithms to agricultural systems. *Computer and Electronics in Agriculture*, 18: 71-72.
- Haykin S (1999). *Neural networks: a comprehensive foundation*. 2nd edition. Prentice Hall, 1-842.
- Hecht NR, (1990). *Neurocomputing*. Addison-Weseley, MA, 147-153.
- Holguín NJV, Salcedo LOG, Will ALE (2011). Prediction of soils penetration strength using artificial neural networks. *Acta Agronómica*, 60(3): 251-260.
- Hossam F, Mouhammd A and Ali R (2013). Artificial Neural Networks for Surface Ozone Prediction: Models and Analysis. *Pol. J. Environ. Stud.*, 23(2): 341-348
- Kandirmaz HM, Kaba K ve Avcı M (2014). Estimation Of Monthly Sunshine Duration In Turkey Using Artificial Neural Networks. *International Journal of Photoenergy*, 2014: 1-9.
- Klir GJ and Yuan B (1995). *Fuzzy Sets and Fuzzy Logic: Theory and Application*. Prentice Hall International Inc., New Jersey.
- Lippmann RP (1987). An introduction to computing with neural nets. *IEEE ASSP Mug.*, 4: 22.
- Liu J, Goering CE and Tian L (2001). Neural network for setting target corn yields. *Trans. ASAE*, 44(3): 705-713.
- Maren A, Harston C and Pap R (1990). *Handbook of neural computing applications*, Academic Press, McClelland, 1-483.
- Mas JF, Puig H, Palacio JL, Sosa A (2002). Modelado del proceso de deforestación en una región del sureste de México. *Memorias del II Seminario Latinoamericano de Geografía Física*, pp. 24-27, Maracaibo, Venezuela.
- Miller RE, Hazard J and Howes J (2001) Precision, Accuracy, and Efficiency of Four Tools for Measuring Soil Bulk Density or Strength. *USDA Forest Service Pacific Northwest Research Station Gen. Tech Report PNW-RP-532*, April 2001.
- Montana Moreno JJ, Palmer Pol A, Munoz Garcia P (2011). Artificial neural networks applied to forecasting time series. *Psicothema*, 23(2): 322-329.
- Önalp A ve Arel E (2011). Geoteknik Mühendisliğinde Yapay Sinir Ağı Uygulamaları ve Bir Örnek: Zemin Profilinin Tahmin Edilmesi. *İTÜ Mühendislik Dergisi*, d: 3-14.
- Pinto FAC, Reid JF, Zang Q and Noguchi N (1999). Guidance parameter determination using artificial neural network classifier. *ASAE Paper No. 993004*, St. Joseph, Michigan.
- Ripley BD (1996). *Pattern recognition and neural networks*. Cambridge University Press, Cambridge, 1-416.
- Rubio C (2005) *Hidrodinámica de los suelos de un área de montaña media mediterránea sometida a cambios de uso y cubierta*. Universidad Autónoma de Barcelona, PhD thesis, Barcelona.
- Rumelhart DE and McClelland JL (1986). *Parallel Distributed Processing: Explorations in the Microstructure of Cognition*. MIT Press, Cambridge, 1-567.
- Topakci M, Unal I, Canakci M Celik HK, Karayel D (2010). Design of a Horizontal Penetrometer for Measuring On-the-Go Soil Resistance. *Sensors*, 10: 9337-9348.
- Vaz CMP, Luis HB and Hopmans JW (2001). Contribution of water content and bulk density to field soil penetration resistance as measured by a combined cone penetrometer-TDR probe. *Soil Till. Res*, 60: 35-42.
- Zurada JM (1992). *Introduction to artificial neural systems*. West Publishing Company, St. Paul, 1-758.