



## Toprakların Agregat Stabilitesi Değerlerinin Yapay Sinir Ağları ile Tahminlenmesi

Tuğrul YAKUPOĞLU\*, Ayfer Özge ŞİŞMAN, Recep GÜNDOĞAN

Kahramanmaraş Sütçü İmam Üniversitesi, Ziraat Fakültesi, Toprak Bilimi ve Bitki Besleme Bölümü, Kahramanmaraş, TÜRKİYE

Geliş Tarihi/Received: 12.05.2015

Kabul Tarihi/Accepted: 01.07.2015

\*Sorumlu Yazar/Correspondence: yakupoglu@ksu.edu.tr

**Özet:** Tarım alanında yürütülen çalışmalarda tahminleme mühendisliği günümüzde önemli bir noktaya gelmiş ve tahminlemede yapay sinir ağlarının (YSA) kullanımı giderek yaygınlaşmıştır. Bu çalışmada, Kahramanmaraş Sütçü İmam Üniversitesi, Avşar Yerleşkesi'nde bulunan pilot alanda yer alan toprakların, mevsime bağlı olarak değişim gösteren ıslak agregat stabilitesi (WAS) değerlerinin YSA kullanılarak tahminlenebilirliği araştırılmıştır. İstatistiksel değerlendirmelerin sonuçlarına dayanılarak seçilen toprak özellikleri bağımsız değişkenler olarak kullanılmış ve WAS'ı tahminleyen YSA'lar geliştirilmiştir. Ağ eğitiminde on iki farklı öğrenme algoritması kullanılarak gerçeğe en yakın WAS değerlerine ulaşılmaya çalışılmıştır. Eğitimde kullanılan bu farklı geri yayılım algoritmalarının performansları determinasyon katsayısı ( $R^2$ ), hata kareler ortalamasının karekökü (RMSE) ve ortalama mutlak hata yüzdesi (MAPE) kriterleri yardımıyla değerlendirilmiştir. Farklı algoritmaların eğitimi yoluyla oluşturulan YSA'ların  $R^2$  değerleri 0.55-0.99, RMSE değerlerinin % 2.12-11.33 ve MAPE'nin ise % 3.55-20 aralıklarında değişim göstermiştir. Geliştirilen YSA'lar WAS'ı tahminleme gücü bakımından  $R^2$  ölçütü esas alınarak birbirleri ile karşılaştırıldığında, BFGS (BFGS Quasi-Newton geri yayılım algoritması) algoritması ile eğitilen ağ hariç bütün ağların  $R^2$  değerleri 0.97 ve üzerinde bulunmuştur. Diğer taraftan, oluşturulan YSA'lar RMSE kriterine göre değerlendirildiğinde en başarılı ağın esnek geri yayılım algoritması (RP) (% 2.12) ile eğitilen ağ ve en başarısız ağın BFGS (% 11.33) algoritması ile geliştirilen ağ olduğu sonucuna ulaşılmıştır. MAPE göstergesi dikkate alındığında ise, tahminleme gücü en yüksek ağ tek adım sekand geri yayılım algoritması (OSS) (% 3.55) ile eğitilen YSA ve tahminleme gücü en düşük ağ BFGS algoritması (% 20) ile eğitilen YSA olmuştur. Elde edilen bulgular, YSA'ların doğru eğitim algoritması kullanılarak oluşturulduklarında WAS'ı tahminlemede kullanılabileceğine işaret etmektedir.

**Anahtar Kelimeler:** Yapay sinir ağları, toprak, ıslak agregat stabilitesi

## Predicting of Soil Aggregate Stability Values Using Artificial Neural Networks

**Abstract:** In studies conducted in the field of agriculture forecasting engineering today has come to an important point and forecasting of artificial neural networks (ANN) use has become wide spread. In this study, wet aggregate stability (WAS) depending on the seasonal variation has been investigated whether it can be estimated or not using ANN pilot area soils located in, Avşar Campus of Kahramanmaraş Sütçü İmam University. Selected based on the results of the statistical evaluation of soil properties were used as independent variables and predictive ANN's have been developed to WAS. In Network training WAS values that are the closest to the actual have tried to reach by using twelve different learning algorithms. Used in the training of these different Back-propagation algorithms' performances were evaluated using coefficient of determination ( $R^2$ ), the square root of the mean square error (RMSE) and mean absolute percentage error (MAPE).  $R^2$  values 0.55-0.99, RMSE values 2.12-11.33 % and MAPE values 3.55-20% of the created ANNs through education different algorithms has changed in the ranges. ANNs was developed when  $R^2$  was compared with each other on the basis of criteria networks in terms of estimation power to WAS,  $R^2$  values were found above 0.97 of BFGS algorithm with the exception of trained network of all. On the other hand, created ANNs when evaluated according to the criteria of the RMSE has been reached to result that most successful network was developed network with RP's algorithm (12.2%) and the most failed network was developed network with BFGS (11.33%) algorithm. Considering the MAPE indication of the forecasting power, the highest network with OSS algorithm (3.55%) the trained with ANN and forecasting power has been

the lowest trained ANN with BFGS algorithm (20%). The results obtained indicate that when ANN was created using the correct training algorithm can be used in the estimation WAS.

**Keywords:** Artificial neural networks, soil, wet aggregate stability

## 1. Giriş

Toprakların erozyona karşı dirençleri, arazi yönetimi ile birlikte toprakların fiziksel ve kimyasal özellikleriyle yakından ilişkilidir (Lal, 1988; Özdemir, 1991). İyi bir agregatlaşma, toprakta verimin artmasına yardımcı olduğu gibi, toprağın erozyona karşı direncini de artırmaktadır. Strüktürel farklılığa neden olan faktörlerin, toprakların erozyona uğrama eğilimlerini önemli ölçüde etkilediği saptanmıştır (Bryan, 1976; Deneff ve ark., 2001).

Toprakların agregat büyüklük dağılımları ve stabilite ölçümleri toprakların bir kalite göstergesi olarak kabul edilmektedir. Ayrıca agregat stabilitesi ölçümleri toprak agregatlarının bozulmayı oluşturan çevresel etmenlere karşı direncinin belirlenmesinde önemli bir parametre olarak kullanılmaktadır. Agregat stabilitesi değeri erozyona eğilimini belirten önemli bir faktördür. Agregat stabilitesi değerinin artması ile erozyona karşı dayanıklılık artmaktadır.

Topraklardaki agregatlaşmanın varlığı, toprakların su tutma ve havalanma kapasitesi, suyun aktivitesi gibi toprak özellikleri üzerine etkili olurken, toprak erozyonunun mekanizmasının açıklanmasında ise daha çok oluşan bu agregatların stabilitesi değerlendirilmektedir. Toprakların erozyona karşı hassasiyetinin değerlendirilmesinde yaygın olarak ıslak agregat stabilitesi indeksi (WAS) kullanılmaktadır (Kemper ve Rosenau, 1986).

Toprak korunması ile ilişkili farklı stratejik planların ve yönetim uygulamalarının geliştirilmesinde en önemli aşama toprağa ait bilginin toplanmasıdır. Söz konusu bilgi veri tabanı şeklinde olduğunda sistematikleşmekte ve çeşitli amaçlar için faydalı durumlara dönüştürülebilmektedir. Değişik ölçeklerdeki toprak veri tabanlarına girdi oluşturacak verilerin derlenmesinde en büyük engel doğrudan gözlem ya da ölçüm yapmanın çok zahmetli, zaman alıcı ve pahalı olmasının yanında geleneksel ölçüm yöntemlerinin çoğunun kullanışsız olmasıdır.

Yoder (1936) tarafından geliştirilen ve daha sonra çeşitli bilim adamlarınca modifiye edilen WAS analizi temelde basit ve ucuz bir işlem olmasına karşın, örnek sayısı arttığında ya da örnekleme yapılacak alan büyüklüğü genişlediğinde ekonomik anlamda pahalı bir analize dönüşebilmektedir. Bu durumlarda

WAS'ın tespiti çok fazla zaman almakta ve iş gücü artarak araştırmacıyı usandırıcı bir duruma gelmektedir. Diğer taraftan toprağın yapısal stabilitesi mevsimden mevsime değişmektedir. Bu değişimin temelinde yatan nedenler, başlangıç nem içeriği (Rasiah ve Kay, 1994), ıslanma kuruma döngüleri (Lehrsch ve ark., 1991; Deneff ve ark., 2001), donma çözünme periyotları (Edwards, 1991) ve organik maddenin yıl içerisindeki iklimsel değişikliklere karşı göstermiş olduğu tepki farklılıkları (Six ve ark., 2004; Bronick ve Lal, 2005) şeklinde sıralanabilir.

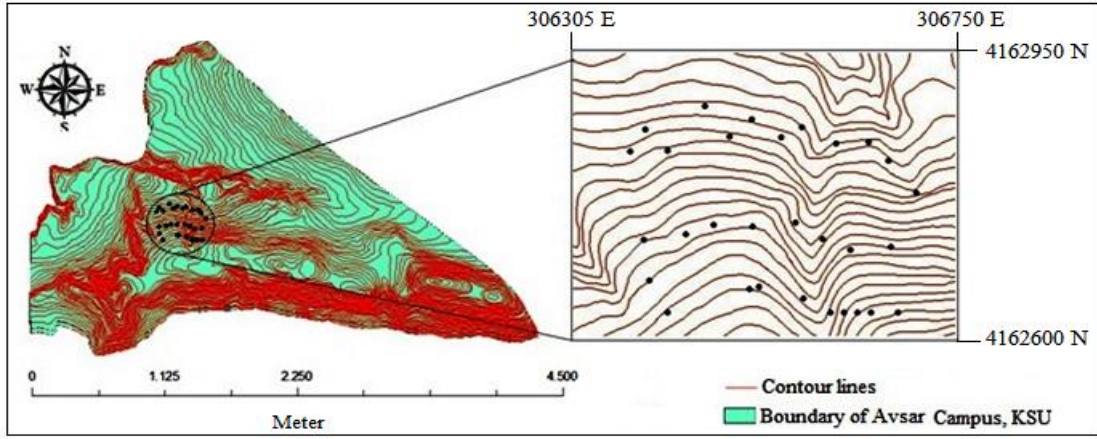
Örnek sayısının çok fazla olması, örnekleme alanının çok büyük olması gibi nedenler ya da dinamik toprak özelliklerinin belirlenmesi söz konusu olduğunda toprak biliminde tahminleme mühendisliğine başvurulmaktadır. Doğrudan ölçüm yapmak yerine elde edilen sonuçlar ve koşullara bağlı olarak değişen kanıtların esas alınmasıyla mantıksal sonuçlar elde etme işlemi "çıkartım yapma" ya da "çıkarsama" olarak tanımlanmaktadır. Günümüze kadar yapılan birçok çalışmada, pedotransfer yaklaşım (PTF), regresyon ağaçları (RT) ve yapay sinir ağları (YSA) yöntemleri kullanılarak birçok toprak özelliğinin tahminlenmesi yoluna gidilmiştir.

Bu çalışmanın amacı, Kahramanmaraş Sütçü İmam Üniversitesi, Avşar Yerleşkesi'nde bulunan pilot alanda, mevsime bağlı olarak değişim gösteren WAS'ın YSA kullanılarak tahminlenebilirliğinin araştırılmasıdır.

## 2. Materyal ve Yöntem

### 2.1. Çalışma sahasının konumu ve genel özellikleri

Kahramanmaraş Sütçü İmam Üniversitesi Erozyon Araştırma Sahası (KSÜ-EAS), International 1909 Spheroid ve European 1950 Datum sistemine göre coğrafik olarak 306305 m-306750 m doğu boylamları ve 4162600 m-4162950 m kuzey enlemleri arasında yer almaktadır. Çalışma alanına ait topoğrafik harita ve örnekleme noktalarının gösterimi Şekil 1'de verilmiştir. Araştırma alanında Orta Miyosen, Pliyosen, yamaç molozları, etek döküntüleri ve genç alüvyonlardan oluşan kuvaterner birimler yer almaktadır. Orta miyosen yaşlı konglomera, çakıl, kum ve kil malzemelerin aralanmasından meydana gelen formasyonun tabakaları 2-3 m kalınlığındadır. Bu formasyonun üzerinde Pliyosen



Şekil 1. Çalışma alanının topoğrafik haritası ve örnekleme noktaları

yaşlı malzemeler yer almaktadır. Pliyosen veya pliyosen sonunda meydana gelen genç tektonizma ile tabakalar yükselerek 15-30° kuzey batı yönünde eğim kazanmışlardır. Birikinti konileri ve vadi tabanlarında ise kuvaterner malzemeler bulunmaktadır (Gündoğan ve ark., 2013).

Akdeniz ikliminin etkisi altında bulunan çalışma alanının yıllık toplam yağış miktarı 710.0 mm olup, yağışların çoğu kış ve ilkbaharda düşmektedir. Yazlar sıcak ve kurak geçmektedir. Yıllık ortalama sıcaklık 16.5 °C olup, en yüksek aylık ortalama sıcaklık temmuz, en düşük aylık ortalama sıcaklık ise ocak ayında izlenmektedir (Anonim, 2015).

## 2.2. Örneklemede izlenen yöntem

Çalışma sahasının (KSÜ-EAS) kış mevsiminde gerekli analiz sonuçları Karagöktaş (2014)'tan alınmıştır. Daha sonra arazi üzerinde ilkbahar ve yaz mevsimlerinde aynı noktalardan (n= 30) toprak örnekleme yapılmıştır. Örnekleme noktalarının koordinatları Tablo 1'de sunulmuştur.

Tablo 1. Örnekleme noktalarının koordinatları

No	Koordinat (UTM)		No	Koordinat (UTM)	
	E	N		E	N
1	306662	4162434	16	306550	4162545
2	306622	4162434	17	306592	4162528
3	306602	4162434	18	306651	4162533
4	306582	4162434	19	306689	4162614
5	306562	4162434	20	306648	4162662
6	306522	4162456	21	306619	4162690
7	306457	4162473	22	306571	4162688
8	306442	4162470	23	306489	4162698
9	306322	4162434	24	306413	4162699
10	306295	4162482	25	306321	4162678
11	306286	4162543	26	306266	4162676
12	306349	4162552	27	306288	4162709
13	306390	4162566	28	306377	4162744
14	306447	4162564	29	306446	4162724
15	306511	4162569	30	306520	4162713

Her bir örnekleme noktasından laboratuvar analizlerinde kullanılmak üzere bozulmuş toprak örnekleri alınmıştır. Analize hazırlanan ilkbahar ve yaz mevsimlerine ait örneklerde yalnızca WAS ve WAS'ı tahminleyecek YSA'ya girdi oluşturacak değişkenler belirlenmiştir. Ayrıca önceden alınan kış mevsimi örneklerinde de WAS analizi yapılmıştır.

## 2.3. Toprak analizlerinde izlenen yöntemler

Toprak örneklerinde; parçacık büyüklük dağılımı, Bouyoucos yöntemine göre (Demiralay, 1993); tarla kapasitesi ve solma noktası, basınçlı tabla aleti kullanılarak (Klute, 1986); organik madde içeriği, "Modifiye Walkley-Black" yöntemiyle (Kacar, 1994); toplam tuz kapsamı, saturasyon çamurunda elektriksel iletkenlik (EC) ölçümlerinden sonra ilgili hesaplamalarla (Bayraklı, 1987); kireç (CaCO<sub>3</sub>) kapsamı Scheibler Kalsimetresi ile hacimsel olarak (Kacar, 1994) belirlenmiştir. Islak agregat stabilitesi (WAS) Yoder tipi eleme setinde standart prosedür uygulanarak (Kemper ve Rosenau, 1986) saptanmıştır.

## 2.4. İstatistiksel değerlendirmelerde ve yapay sinir ağlarının geliştirilmesinde izlenen yöntemler

Çalışma sahası topraklarının WAS bakımından farklılıklarının test edilmesinde varyans analizinden yararlanılmıştır. Mevsimlerin ortalama WAS değerlerinin karşılaştırılmasında LSD<sub>0,05</sub> testi kullanılmıştır. Seçilen kalite göstergeleri ile toprakların değerleri WAS arasındaki ilişkileri incelemek için korelasyon testinden faydalanılmıştır (Yurtsever, 1984). WAS ile yüksek korelasyon gösteren bağımsız değişkenlerin WAS üzerine doğrudan ve dolaylı etkileri Path analizi ile belirlenmiştir. Path katsayıları ve % değerleri, bağımsız değişkenlerin

bağımlı değişken üzerine etkilerini değerlendirmede yaygın olarak kullanılan bir istatistiksel enstrümandır (Williams ve ark., 1990; Candemir ve Gülser, 2012). Daha sonra ana veri kümesi (N= 90), veri seti (% 80) ve validasyon seti (% 20) olmak üzere iki alt kümeye bölünmüştür (Lake ve ark., 2009; Shalmani ve ark., 2010). Bu işlemde her bir mevsime ait toprak örneklerinden 6 tanesi rastgele seçilmiş ve validasyon kümesi oluşturulmuştur (N= 18). Kalan toprak örneklerinin tamamına ait analiz sonuçları veri kümesini oluşturmuştur (N= 72). YSA modelleri MATLAB R2012b yazılımı kullanılarak (Arifoğlu, 2012) oluşturulmuştur.

Bu çalışmada öğrenme yöntemi olarak danışmanlı öğrenme (supervised learning) kullanılmıştır. Danışmanlı öğrenme yaklaşımında, mutlaka bir danışmana, yani YSA'ya ne öğrenmesi gerektiğini aktaracak bir yaklaşıma ihtiyaç vardır (Sağiroğlu ve ark., 2003).

Geliştirilen YSA'ların tamamında ileri beslemeli geri yayımlı (Multilayer feed forward back propagation) tekniğinden yararlanılmıştır. YSA uygulamaları, ileri beslemeli bir ağ olan çok katmalı perceptron (MLP) ağı ile yapılmıştır. Bu ağ çeşidi, birçok öğrenme algoritması kullanılarak eğitilebildiğinden dolayı günümüzde yaygın olarak kullanılmaktadır.

Farklı öğrenme algoritmalarında (LM: Levenberg-Marquardt geri yayılım algoritması, CGF: Fletcher-Powell eşlenik gradyan geri yayılım algoritması, GDX: Adaptif öğrenme oranı ile momentumlu gradyan geri yayılım algoritması, BFGS: BFGS Quasi-Newton geri yayılım algoritması, SCG: Dengeli eşlenik gradyan geri yayılım algoritması, RP: Esnek geri yayılım algoritması, GDA: Adaptif öğrenme oranı ile gradyan iniş geri yayılım algoritması, GDM: Momentumlu gradyan iniş geri yayılım algoritması, CPG: Polak-Ribiere eşlenik gradyan geri yayılım algoritması, CGB: Powell-Beale eşlenik gradyan geri yayılım algoritması, OSS: Tek adım sekand geri yayılım algoritması, BR bayesyen düzeltmeye dayalı geri yayılım algoritması) farklı aktivasyon fonksiyonları, katman ve nöron sayılarının kombinasyonları deneyerek WAS tahminlenmeye çalışılmıştır. MATLAB denemeleri sonucunda purelin ve tansig aktivasyon fonksiyonlarına karar verilmiştir. Konuyla ilgili olarak yürütülen birçok çalışmada (Brikundavyi ve ark., 2002; Cıgızoğlu, 2003; Jain ve Indurthy, 2003; Kisi, 2004), çok katmanlı, ileri beslemeli ve geri yayımlı (Multi Layer Feed Forward Back Propagation) ağ mimarisi oluşturularak, rastgele verilerden gelecekle ilgili

yüksek doğrulukta çıkarımlar yapılabileceği bildirilmiştir.

Gizli katman sayısındaki ve bu katmanların nöron sayısındaki belirsizlikleri aşabilmenin bir yolunun da deneme yanılma yöntemi olduğu (Arslan ve İnce, 1996) dikkate alınarak gizli katmanda bulunan sinir hücresi sayısı belirlenirken deneme-yanılma metodundan yararlanılmıştır. Bu amaca yönelik olarak gizli katman sayısı önce tek katman olarak seçilmiş ve bu katmandaki nöron sayısı ve aktivasyon fonksiyonu değiştirilerek denenmiştir ve daha sonra gizli katman sayısı artırılarak tahmin sonuçları birbirleriyle kıyaslanmıştır. En iyi tahmin sonuçlarının gözlendiği gizli katman ve bu katmanlardaki nöron sayısına sahip model belirlenmeye çalışılmıştır.

Geliştirilen YSA'ların performans testi için determinasyon katsayısı ( $R^2$ ), hata kareler ortalamasının karekökü (RMSE) ve ortalama mutlak hata yüzdesi (MAPE) istatistiksel terimleri kullanılmıştır (Şenoğlu ve Acıtaş, 2014).

### 3. Bulgular ve Tartışma

#### 3.1. Toprak özellikleri

Çalışma konusu topraklara ait tanımlayıcı istatistikler Tablo 2'de verilmiştir. Adı geçen tablodan da görüleceği üzere ölçülen toprak özellikleri geniş aralıklarda değişmektedir. Örneğin toprakların kil içerikleri % 4.80-25.1 arasında, organik madde konsantrasyonları % 0.22- 4.87 değişmektedir. Toprakların WAS değerleri ise % 22.6-89.0 arasında değişim göstermiştir.

**Tablo 2.** Çalışma konusu topraklara ait tanımlayıcı istatistikler (n= 90)

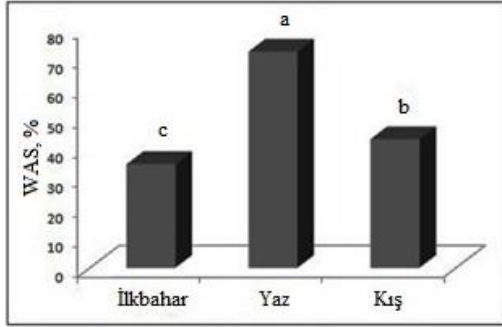
Toprak özelliği	Minimum	Maksimum	Mean	SD
Kil, %	4.80	25.1	20.8	11.2
OM, %	0.22	4.87	2.35	0.96
CaCO <sub>3</sub> , %	0.32	39.2	4.52	5.88
Tuz, g kg <sup>-1</sup>	0.09	2.00	0.85	0.37
TK, %	12.3	45.7	24.6	8.41
DSN, %	5.02	24.0	13.6	4.18
WAS, %	22.6	89.0	48.9	17.4

OM: Organik madde, TK: Tarla kapasitesi, DSN: Daimi solma noktası, WAS: Islak agregat stabilitesi, SD: Standart sapma

#### 3.2. Strüktürel stabilitedeki mevsimsel değişim ve agraget stabilitesi ile bazı toprak özellikleri arasındaki ilişkiler

Varyans analizi sonuçlarına göre toprakların WAS değerleri üzerine mevsimlerin etkisi önemli ( $P<0.001$ ) bulunmuştur. Hesaplanan F değeri istatistiksel anlamda önemli olduğu için WAS üzerine mevsimlerin etkisini karşılaştırmak için LSD<sub>0.05</sub> (least standard deviation) testinden

yararlanılmış ve test sonuçları Şekil 2’de sunulmuştur. Şekil 2’den de görüleceği üzere WAS değerlerinin en yüksek ortalaması yaz mevsimi için hesaplanırken, en düşük WAS ortalama değeri ise ilkbahar mevsimi için hesaplanmıştır.



**Şekil 2.** Mevsimlerin ortalama WAS değerleri (LSD<sub>0,05</sub>= 1.605)

Islak agregat stabilitesi ile bazı toprak özelliklerinin arasındaki ikili ilişkileri inceleyebilmek amacıyla toplam veri kümesi (1 yıllık veriler) kullanılarak bir korelasyon matrisi hazırlanmış ve Tablo 3 olarak sunulmuştur. Söz konusu tablodan da anlaşılacağı üzere WAS değişkeni OM, TK, DSN, kil (P<0.01)

ve CaCO<sub>3</sub> (P<0.05) ile önemli pozitif, tuz ile önemli negatif (P<0.01) ilişkiler vermiştir.

Toprak ile ilgili tahminleme çalışmalarında korelasyonların dikkate alınması gerekmektedir. Öte yandan Candemir ve Gülser (2012) tahminleme üzerine yürüttükleri bir çalışmada, değişkenler arasındaki ilişkileri değerlendirirken Path analizinin korelasyon matrisinden daha yararlı olduğunu açıklamışlardır. YSA’lar oluşturulmadan önce Path analizi yapmak, ilişkileri kontrol etmek için iyi bir yoldur. Bu çalışmada WAS ile önemli ilişkiler tespit edilen değişkenlerin kullanıldığı Path analizi sonuçları Tablo 4’te verilmiştir. Adı geçen tabloya göre, bağımlı değişken WAS üzerine en kuvvetli doğrudan etkiyi TK (% 49.0) yapmıştır. Bağımsız değişkenlerin WAS üzerine doğrudan etkileri bakımından TK > DSN > TUZ > Kil > CaCO<sub>3</sub> > OM şeklinde sıralanmışlardır. Bu sonuçlar seçilen toprak özelliklerinin WAS’ı tahminlemek üzere geliştirilecek olan YSA’nın birer bileşeni olarak kullanılabilmesi anlamına gelmektedir. İklim faktörlerine bağlı olarak toprakların WAS değerlerinde zamana bağımlı olarak oluşan değişim, toprakların nem içeriklerindeki değişim kadar organik madde konsantrasyonundaki değişime de bağlı olarak meydana gelmektedir (Rasiah ve Kay, 1994).

**Tablo 3.** Bazı toprak özellikleri ile WAS arasındaki korelasyonlara ait katsayılar

	Kil	OM	CaCO <sub>3</sub>	TK	DSN	TUZ
WAS	0.267**	0.542**	0.170*	0.859**	0.750**	-0.306**
Kil		0.593**	0.802**	0.445**	0.709**	0.469**
OM			0.448**	0.643**	0.768**	0.155
CaCO <sub>3</sub>				0.293**	0.543**	0.496**
TK					0.873**	-0.171*
DSN						0.097

OM: Organik madde, TK: Tarla kapasitesi, DSN: Daimi solma noktası, TUZ: Toplam tuz içeriği, WAS: Islak agregat stabilitesi

**Tablo 4.** WAS ve bazı toprak özellikleri arasındaki doğrudan ve dolaylı path payları

	Doğrudan path yüzdeleri, %	Dolaylı path yüzdeleri, %					
		Kil	OM	CaCO <sub>3</sub>	TK	DSN	TUZ
Kil	27.79	-	0.71	5.22	25.08	33.03	8.17
OM	1.30	17.27	-	3.04	38.02	37.54	2.83
CaCO <sub>3</sub>	8.12	27.96	0.71	-	20.68	31.71	10.82
TK	49.00	10.74	0.69	1.65	-	35.33	2.59
DSN	38.29	16.20	0.78	2.89	40.45	-	1.39
TUZ	36.25	27.14	0.41	6.68	20.10	9.42	-

OM: Organik madde, TK: Tarla kapasitesi, DSN: Daimi solma noktası, TUZ: Toplam tuz içeriği, WAS: Islak agregat stabilitesi

### 3.3. YSA ile WAS’ın tahminlenmesi

İstatistiksel değerlendirme sonuçlarına dayanılarak ve seçilen toprak özellikleri kullanılarak WAS’ı tahminlemek üzere yapay sinir ağları geliştirilmiştir. On iki farklı öğrenme algoritması (BFGS, CGP, CGB, GDM, SCG, GDX, LM, BR, RP, CGF, GDA ve OSS)

kullanılarak en doğru sonuç elde edilmeye çalışılmıştır. Uygulama sonucunda elde edilen çıkış değeri ile gerçek değerler arasındaki fark en aza indirilmeye çalışılmıştır. Bu çıkışlar arasındaki farka göre ağırlık değerleri yeniden hesaplanarak ağa uygulanmıştır. Bu işlem istenilen çıkışlar elde edilinceye kadar tekrarlanmıştır. Ağın tahminlediği

sonuç değerleri, deneysel sonuçlarla ile karşılaştırılmıştır. Eğitimde kullanılan 12 farklı geri yayılım algoritmasının performansları karşılaştırılmıştır.


Ağ yapısı oluşturulurken, ölçülen organik madde (OM), kireç ( $\text{CaCO}_3$ ), tuz (TUZ), daimi solma noktası (DSN), tarla kapasitesi (TK), kil içeriği (KİL) ve mevsimler (ilkbahar: 1; kış: 2; yaz: 3) ağa giriş parametreleri, WAS değerleri ise çıkış değişkeni olarak tanıtılmıştır. Bu parametrelere göre yapay sinir ağında çeşitli sayıda gizli katman ve bu katmandaki nöron sayıları ve bu nöronlar için farklı aktivasyon fonksiyonları denenmiştir. Bu denemeler sonucunda en iyi ağ eğitimi 7-4-10-1 dizilimi mimari yapı ile elde edilmiştir. Söz konusu mimari yapı Şekil 3'te sunulmuştur.

Şekil 3'te verilen ağda ilk gizli katmanda aktivasyonu olarak hiperbolik tanjant aktivasyon fonksiyonu olan "tansig", ikinci gizli katman ve çıkış katmanında ise lineer aktivasyon fonksiyonu olan "purelin" kullanılmıştır. Ağ performansının seçilen ölçütlere göre değerlendirildiği aşamada en

yüksek ağ eğitim başarısı bu fonksiyonlar ile elde edilmiştir. Ağırlık değerleri başlangıçta programın atadığı değerler üzerinden başlatılıp kullanılan geri yayılım algoritmasının yapısına bağlı olarak yeniden düzenlemiştir.

Eğitim aşamasında en küçük hata düzeyine ulaşılmaya çalışılmış ancak eğitim setinin mutlak hatasının minimum olması her zaman eğitimin doğru olduğu anlamına gelmediği, öğrenmeden çok ezberleme noktasına gelmiş olabileceği göz önünde bulundurulmuştur. Bunun önüne geçebilmek için test verileri ayrılmış ağın performansı değerlendirilmiştir. Çalışmada kullanılan tüm modellerin tahmin performansları MAPE istatistiksel enstrümanı yardımıyla değerlendirilmiştir.

Farklı eğitim algoritmaları ile geliştirilen yapay sinir ağlarının eğitim ve tahminleme aşamalarına ait olan istatistiksel değerler Tablo 5 olarak sunulmuştur. Adı geçen tabloya göre öğrenme aşamasında en iyi performansı BR algoritması göstermiştir ( $R= 0.99$ ;  $MSE= 4.29$ ). Öğrenme başarısının en düşük olduğu algoritma ise BFGS algoritması ( $R= 0.69$ ;  $MSE= 154.93$ ) olmuştur.



Şekil 3. Oluşturulan yapay sinir ağın mimari yapısı

Tablo 5. Farklı eğitim algoritmaları ile geliştirilen yapay sinir ağlarının eğitim ve tahminleme aşamalarına ait bazı istatistiksel değerler

Kullanılan algoritma	ANN öğrenme aşaması		ANN tahminleme aşaması		
	MSE	R	$R^2$	RMSE	MAPE, %
BFGS	154.93	0.69	0.55	11.33	20
CGP	15.26	0.98	0.97	2.81	4.86
CGB	15.3	0.98	0.97	2.68	4.69
GDM	19.13	0.97	0.97	2.97	4.56
GDA	11.84	0.98	0.98	2.61	3.87
SCG	8.39	0.98	0.97	2.69	3.86
GDX	14.95	0.98	0.98	2.25	3.82
LM	8.65	0.98	0.98	2.33	3.81
BR	4.29	0.99	0.97	2.81	3.78
RP	8.46	0.98	0.99	2.12	3.67
CGF	8.63	0.98	0.98	2.7	3.64
OSS	9.99	0.98	0.98	2.27	3.55

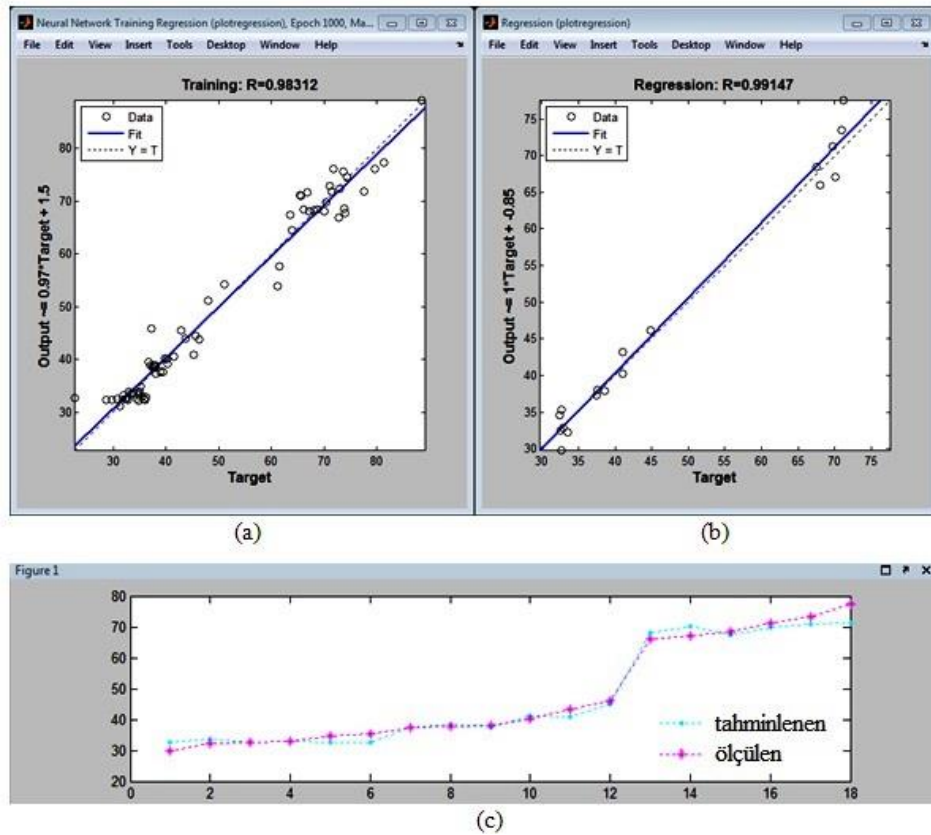
Geliştirilen YSA'lar tahminleme gücü bakımından  $R^2$  ölçütü esas alınarak birbirleri ile karşılaştırıldığında BFGS ile eğitilen ağ hariç bütün ağların  $R^2$  değerleri 0.97 ve üzerinde bulunmuştur.  $R^2$  değerleri 0.95-1 arasında iken başarı yüksek kabul edilmektedir (Ekici ve Aksoy, 1993; Turhan ve Gökçen, 2013). Ancak bu gibi çalışmalarda  $R^2$ 'nin değerlendirme ölçütü olarak kullanılması hatalı bir yaklaşım olabilmektedir. Çünkü YSA'lar için hesaplanan  $R^2$  değerlerinin birbirine çok yakın çıkması, hangi ağın tahminlemede daha başarılı olduğunun tartışılmasına olanak vermemektedir. MAPE göstergesi dikkate alındığında, WAS'ı tahminlemede en başarılı ağ OSS algoritması (% 3.55) ile eğitilen ağ olmuş, bunu küçük farklılıklarla CGF (% 3.64) ve RP (% 3.67) algoritmaları ile eğitilen ANN'ler izlemiştir. BFGS algoritması ile eğitilen ağ, MAPE kriterine göre de tahminlemede başarısızdır (Tablo 5).

MAPE ölçütü, tahminleme hatalarını yüzde olarak ifade etmektedir ve bu nedenle farklı birim değerlere sahip çalışmalar için geliştirilen modellerin karşılaştırılmasında ortaya çıkabilecek dezavantajları ortadan kaldırmaktadır. MAPE'nin bu özellikleri onun diğer değerlendirme

istatistiklerine göre üstünlüğü olarak kabul edilmektedir. MAPE değerleri % 10'un altında olan tahmin modelleri "yüksek doğruluk" derecesine, % 10 ile % 20 arasında olan modeller ise doğru tahminler olarak sınıflandırmaktadır (Witt ve Witt, 1992). Benzer şekilde Lewis (1982), MAPE değeri % 10'un altında olan modelleri tahminlemede "çok iyi", % 10-20 arasında olan modelleri "iyi", % 20-50 arasında olan modelleri "kabul edilebilir" ve % 50'nin üzerinde olan modelleri ise "yanlış ve hatalı" modeller olarak sınıflandırmıştır.

WAS'ı tahminlemek üzere geliştirilen YSA'lar RMSE kriterine göre değerlendirildiğinde en başarılı ağ RP algoritması (% 2.12) ile eğitilen ağdır. İkinci sırada GDX algoritması (% 2.25) ile eğitilen ağ gelmektedir. En başarısız ağ BFGS (% 11.33) algoritması ile geliştirilen YSA'dır. RMSE değeri düşüğe geliştirilen ağın tahminleme başarısının arttığı (McBratney ve ark., 2000; Effati ve ark., 2013) bildirilmiştir.

OSS algoritması kullanılarak gerçekleştirilen ağ eğitime ait öğrenme regresyon grafiği ve geliştirilen ağın performans grafiği MATLAB ekran görüntüleri olarak Şekil 4'te sunulmuştur.



Şekil 4. OSS algoritması için program ekran görüntüleri (a: öğrenme regresyon grafiği, b: tahminleme regresyon grafiği, c: ölçülen ve OSS algoritması kullanılarak tahminlenen WAS değerleri arasındaki ilişki grafiği)

WAS'ı tahminlemede en başarılı ağ, OSS eğitim algoritması ile geliştirilen YSA olduğu için Şekil 4'te ayrıca çalışma konusu toprakların ölçülen ve tahminlenen WAS değerleri arasındaki ilişki grafiği de sunulmuştur. Söz konusu şekilde görüldüğü üzere öğrenme (training) grafiğinde gösterildiği gibi 1000 (epochs) iterasyonda öğrenme durdurulmuştur. Bu eğitimde sistemin öğrenmedeki MSE değeri 9.99 seviyesine kadar düşmüştür ve R değeri 0.98 olarak hesaplanmıştır. Bu sonuçlar öğrenmenin iyi olduğunun bir göstergesidir. Ağın tahminleme gücünü hesaplamada kullanılan MAPE ve RMSE kriterleri program tarafından sırasıyla % 3.55 ve % 2.27 şeklinde hesaplanmıştır. Bu algoritma ile eğitilen ağın tahminleme gücü yüksektir. Bu ölçütlere göre de eğitilen ağ WAS'ı tahminlemede başarılıdır. Şekil 4c'nin incelenmesinden de anlaşılacağı üzere her bir toprak örneğinin ölçülen ve OSS algoritması ile eğitilen YSA yardımıyla tahminlenen WAS değerleri çok küçük sapmalar olmakla birlikte örtüşmektedir.

Zhao ve ark. (2009), toprağın tekstür dağılımını yüksek çözünürlüklü haritalardan faydalanarak tahminlemek için yaptıkları çalışmalarında, YSA'lardan faydalanmışlardır. YSA uygulamasında çok katmanlı ileri beslemeli geri yayımlı ağ modellerinde LM ve RP eğitim algoritmalarının performansını karşılaştırmışlardır. Ağın mimari yapısı tek gizli katman kullanarak bu gizli katmandaki nöron sayısını deneme yanılma yoluyla belirlemişlerdir. LM algoritmasının RP algoritmasından daha iyi tahminlediği sonucuna varmışlardır. Yürütülen bu çalışmada da farklı eğitim algoritmaları ile WAS'ı tahminlemek üzere geliştirilen YSA'ların tahminleme güçleri farklı bulunmuştur.

Shalmani ve ark. (2010), yürüttükleri bir çalışmada, geometrik ortalama çapı, YSA ve PTF ile tahminlemişler ve her iki tahminleme yönteminin başarısını karşılaştırmışlardır. Araştırmacılar adı geçen modellerin girdi kümelerini CaCO<sub>3</sub>, % kil, % silt, % kum, hacim ağırlığı, dane yoğunluğu, penetrasyon direnci, pH, elektriksel iletkenlik ve organik karbon parametrelerinin farklı kombinasyonlarından oluşturmuşlardır. Modellerin performanslarını ölçmede R<sup>2</sup> ve RMSE'yi kullanan araştırmacılar YSA'nın tahminlemede PTF modelden daha başarılı olduğu sonucuna ulaşmışlardır. Bu çalışmada da toprakların yapısal stabilitesini ölçmede kullanılan ölçütlerden biri tahminlenmeye çalışılmış ve verilen literatürle benzer şekilde, YSA'lar ile strüktürel stabilitenin tahminlenebileceği ortaya konulmuştur.

#### 4. Sonuçlar

Yürütülen bu çalışmanın sonucunda, araştırmaya konu olan alanın topraklarına ait WAS değerlerinin mevsimden mevsime değiştiği tespit edilmiştir. WAS ortalama değerleri yaz mevsiminde en yüksek ilkbaharda ise en düşük bulunmuştur. Temel toprak analizleri ile kolayca elde edilen toprak özelliklerinin girdi olarak kullanıldığı YSA'lar ile WAS'ın tahminlenebileceği sonucuna ulaşılmıştır. WAS değerlerini tahminlerken WAS ile yüksek korelasyon gösteren bağımsız değişkenlerin WAS üzerine doğrudan ve dolaylı etkilerinin Path analizi ile belirlenmesi, gerek eğitilen ağın öğrenme başarısı, gerekse araştırmacıya zaman kazandırması bakımından önemlidir.

Toprak nem sabiteleri, organik madde, kil içeriği, tuz içeriği ve kireç içeriğinin WAS'ı tahminleyen YSA'larda kullanılabileceği belirlenmiştir. Özellikle mevsimsellikten etkilenen değişkenleri tahminleyen ağlar eğitilirken girdi olarak mevsimlerin kullanılmasının tahminleme gücünü yükseltebileceği sonucuna ulaşılmıştır. YSA'nın mimari yapısı belirlenirken çeşitli sayıda gizli katman ve bu katmandaki nöron sayıları ve bu nöronlar için farklı aktivasyon fonksiyonları denenebilmektedir. Bu çalışmada, 7-4-10-1 dizilimi mimari yapının WAS'ı tahminleme gücünün denenen diğer mimari yapılardan daha yüksek olduğu gözlenmiştir. Eğitim aşamasında 1000 iterasyon daha fazla döngü yapınca ağın öğrenmeden çok ezberleyeceği MATLAB programında izlenmiştir. Diğer taraftan, aynı mimari yapı ile farklı eğitim algoritmalarının kullanılması ile geliştirilen YSA'nın WAS tahminleme gücünün yükseltilebileceği bulgusu ele edilmiştir.

Çalışma alanında WAS'ı tahminlemede en başarılı eğitim algoritması R<sup>2</sup> ve RMSE kriterlerine göre RP bulunurken MAPE istatistiksel kriterine göre ise OSS olarak gözlenmiştir. Bu sonuç, bir YSA'nın tahminleme performansının, ölçüt olarak kullanılan istatistiksel enstrümana göre farklılık arz edebileceğine işaret etmektedir. Özellikle dört mevsimin yaşandığı ülkemizde ve yine özellikle küresel ısınmanın sonucu olarak meydana gelen iklim değişikliği neticesinde sık sık WAS'ın ölçümüne gerek duyulmaktadır. WAS'ın laboratuvar şartlarında ölçümü, örnek sayısının çok fazla olması ya da çalışılan alanın çok büyük olması durumunda zahmetli, usandırıcı, zaman alıcı ve pahalı olabilmektedir. Bunun yerine kolay ölçülen toprak özellikleri ile oluşturulan veri kümelerinin girdi olarak kullanılması yoluna gidilerek WAS'ın tahminlenmesinde YSA'lar büyük kolaylık sağlayabilir. Konunun daha



derinlemesine anlaşılabilmesi için girdi veri seti ve validasyon setinin farklı yıllara ait ölçümlerden hazırlandığı çalışmaların yürütülmesine ihtiyaç duyulmaktadır.

## Teşekkür

Bu çalışma, 2012-2-13M kodlu Münferit Bilimsel Araştırma Projesi kapsamında elde edilen veriler kullanılarak yapılmıştır. Söz konusu projeyi finansal olarak destekleyen Kahramanmaraş Sütçü İmam Üniversitesi Rektörlüğü'ne teşekkür ederiz.

## Kaynaklar

- Anonim, 2015. T.C. Orman ve Su İşleri Bakanlığı, Meteoroloji Genel Müdürlüğü. <http://www.mgm.gov.tr/> (Erişim tarihi: 30.06.2015).
- Arifoğlu, U., 2012. Matlab 7.14 Simulink-Mühendislik Uygulamalar. ISBN:6051066202, Alfa Yayınları.
- Arslan, A., İnce, R., 1996. The neural network approximation to the size effect in fracture of cementitious materials. *Engineering Fracture Mechanics*, 54(2): 249-261.
- Bayraklı, F., 1987. Toprak ve Bitki Analizleri. Ondokuz Mayıs Üniversitesi Yayınları, Yayın No: 17, Samsun.
- Brikundavyi, S., Labib, R., Trung, H.T., Rousselle, J., 2002. Performance of neural networks in daily streamflow forecasting. *Journal of Hydrologic Engineering*, 7(5): 392-398.
- Bronick, C.J., Lal, R., 2005. Soil structure and management: A review. *Geoderma*, 124: 3-22.
- Bryan, R.B., 1976. Considerations on soil erodibility indices and sheetwash. *Catena*, 3: 99-111.
- Candemir, F., Gülser, C., 2012. Influencing factors and prediction of hydraulic conductivity in fine-textured alkaline soils. *Arid Land Research and Management*, 26(1): 15-31.
- Cıgızoğlu, H.K., 2003. Estimation, forecasting and extrapolation of flow data by artificial neural Networks. *Hydrological Sciences Journal*, 48(3): 349-361.
- Demiralay, İ., 1993. Toprak Fiziksel Analizleri. Atatürk Üniversitesi Ziraat Fakültesi Yayınları, No: 143, Erzurum.
- Denef, K., Six, J., Bossuyt, H., Frey, S.D., Elliott, E.T., Merckx, R., Paustian, K., 2001. Influence of dry-wet cycles on the interrelationship between aggregate, particulate organic matter, and microbial community dynamics. *Soil Biology and Biochemistry*, 33(12-13): 1599-1611.
- Edwards, L.M., 1991. The effect of alternate freezing and thawing on aggregate stability and aggregate size distribution of some Prince Edward Island soils. *Journal of Soil Science*, 42(2): 193-204.
- Effati, M., Bahrami, H.A., Darvishi, B.A., Azizi, R., 2013. Assessment and mapping of soil particle size distribution using satellite images analysis and artificial neural networks in Hur Al-Azim Lagoon, Iran. *International Journal of Agriculture: Research and Review*, 3(1): 44-55.
- Ekici, B.B., Aksoy, U.T., 1993. Prediction of building energy consumption by using artificial neural networks. *Advances in Engineering Software*, 40: 356-362.
- Gündoğan, R., Yılmaz, K., Demirkıran, A.R., Yakupoğlu, T., 2013. Kahramanmaraş Sütçü İmam Üniversitesi Avşar Kampüsü topraklarının özellikleri, oluşumu, sınıflandırılması ve kullanımı. *III. Ulusal Toprak ve Su Kaynakları Kongresi, Bildiriler Kitabı*, 22-24 Ekim, Tokat, s. 238-245.
- Jain, A., Indurthy, S.K.V.P., 2003. Comparative analysis of event-based rainfall-runoff modeling techniques deterministic, statistical, and artificial neural networks. *Journal of Hydrologic Engineering*, 8(2): 93-98.
- Kacar, B., 1994. Bitki ve Toprağın Kimyasal Analizleri: Toprak Analizleri III. Ankara Üniversitesi Ziraat Fakültesi Yayınları, Eğitim Araştırma ve Geliştirme Fonu, No: 3, Ankara.
- Karagöktaş, D., 2014. Kahramanmaraş Sütçü İmam Üniversitesi Avşar Yerleşkesi içerisinde pilot alanda yayılım gösteren toprakların erozyona duyarlılıklarının belirlenmesi. Yüksek lisans tezi, Kahramanmaraş Sütçü İmam Üniversitesi, Fen Bilimleri Enstitüsü, Toprak Bilimi ve Bitki Besleme Anabilim Dalı, Kahramanmaraş.
- Kemper, W.D., Rosenau, R.C., 1986. Aggregate stability and size distribution, in Klute, A. (ed.): *Methods of Soil Analysis: Part I. 2nd edn.*, ASA, Madison, WI, USA, pp. 425-442.
- Kisi, O., 2004. River flow modeling using artificial neural networks. *Journal of Hydrologic Engineering*, 9(1): 60-63.
- Klute, A., 1986. Water retention: Laboratory methods. In Klute A. (ed.): *Methods of soil analysis: Part I, 2nd ed.*, Agronomy Monograph., Vol. 9, ASA, SSSA, Madison, WI, USA, pp. 635-662.
- Lake, H.R., Akbarzadeh, A., Mehrjardi, R.T., 2009. Development of pedo transfer functions (PTFs) to predict soil physico-chemical and hydrological characteristics in southern coastal zones of the Caspian Sea. *Journal Ecology and the Natural Environment*, 1(7): 160-172.
- Lal, R., 1988. *Soil Erosion Research Methods*. Soil and Water Conservation Society, p: 141-153.
- Lehrsch, G.A., Sojka, R.E., Carter, D.L., Jolley, P.M., 1991. Freezing effects on aggregate stability affected by texture, mineralogy, and organic matter. *Soil Science Society of America Journal*, 55(5): 1401-1406.
- Lewis, C.D., 1982. *Industrial and Business Forecasting Methods*. Londra: Butterworths Publishing, 40 p.
- McBratney, A.B., Odeh, I.O.A., Bishop, T.F.A., Dunbar, M.S., Shatar, T.M., 2000. An overview of pedometric techniques for use in soil survey. *Geoderma*, 97: 293-327.
- Özdemir, N., 1991. Toprağa karıştırılan organik artıkların toprağın bazı özellikleri ile yapısal

- dayanıklılık ve erozyona karşı duyarlılığı üzerine etkileri. Doktora tezi, Atatürk Üniversitesi, Fen Bilimleri Enstitüsü, Erzurum.
- Rasiah, V., Kay, B.D., 1994. Characterizing changes in aggregate stability subsequent to the introduction of forages. *Soil Science Society of America Journal*, 58(3): 935-942.
- Sağiroğlu, Ş., Beşdok, E., Erler, M., 2003. Mühendislikte Yapay Zeka Uygulamaları I: Yapay Sinir Ağları, ISBN: 975-95948-5-4, Ufuk Yayıncılık, Kayseri.
- Shalmani, A.A., Shahrestani, M.S., Asadi, H., Bagheri, F., 2010. Comparison of regression pedotransfer functions and artificial neural networks for soil aggregate stability simulation. *World Applied Sciences Journal*, 8(9): 1065-1072.
- Six, J., Elliott, E.T., Paustian, K., 2004. Soil macro aggregate turnover and micro aggregate formation: A mechanism for c sequestration under no-tillage agriculture. *Soil Biology and Biochemistry*, 32(14): 2099-2103.
- Şenoğlu, B., Acıtaş, Ş., 2014. İstatistiksel Deney Tasarımı Sabit Etkili Modeller. ISBN:6051330433, Nobel Yayın Dağıtım.
- Turhan, C., Gökçen, G., Kazanasmaz, Z.T., 2013. Yapay sinir ağları ile İzmir'deki çok katlı binaların toplam enerji tüketimlerinin tahmin edilmesi. 11. *Ulusal Tesisat Mühendisliği Kongresi ve Teskon+Şodex Fuarı Bildirileri*, 17-20 Nisan, İzmir, 134: 61-68.
- Williams, W.A., Jones, M.B., Demment, M.W., 1990. A concise table for path analysis statistics. *Agronomy Journal*, 82: 1022-1029.
- Witt, S.F., Witt, C.A., 1992. Modeling and Forecasting Demand in Tourism. Londra: Academic Press.
- Yoder, R.E., 1936. A direct method of aggregate analysis of soils and a study of the physical nature of erosion losses. *Agronomy Journal*, 28(5): 337-351.
- Yurtsever, N., 1984. Deneysel İstatistik Metotları. Köy Hizmetleri Genel Müdürlüğü Yayınları, Genel Yayın No: 121, Ankara.
- Zhao, Z., Chowb, T.L., Reesb, H.W., Yanga, Q., Xingb, Z., Menga, F.R., 2009. Predict soil texture distributions using an artificial neural network model. *Computers and Electronics in Agriculture*, 65: 36-48.