

Araştırma Makalesi/Research Article

Yağış Miktarının Yapay Sinir Ağları ile Tahmini

Estimation of Rainfall Amount with Artificial Neural Networks

Ali YILDIRAN¹, Süheyla YEREL KANDEMİR^{2*}

Geliş / Received : 18/10/2018

Revize / Revised : 13/12/2018

Kabul / Accepted : 17/12/2018

Öz- Yağış verilerinin öngörülebilir olması ve doğruya yakın şekilde tahmin edilebilmesi; mühendislik açısından birçok avantaj sağlayacak bir durumdur. Geçmiş yağış verileri yardımıyla bu öngörü işlemi belirli matematiksel denklemler sayesinde yapılabilmektedir. Kara kutu modeli olarak adlandırılan analiz sistemlerinde geçmiş veriler sayesinde oluşturulan modeller yardımıyla eksik veriler ve gelecekteki veriler tahmin edilebilmektedir. Günümüzde gerek alınan verimli sonuçlar gerekse kullanım kolaylığı ve hızı sebebiyle bir kara kutu modeli olan Yapay Sinir Ağları (YSA) bu öngörü modellemelerinde sıkça kullanılmaktadır. Bu çalışmada bir Yapay Sinir Ağı yöntemi olan İleri Beslemeli Geri Yayılım (İBGY) metodu yardımıyla yağış verileri tahmin edilmiştir ve sonuçlar çoklu doğrusal regresyon analizi sonuçları ile karşılaştırılmıştır. Tahmin modelleri hazırlanırken geçmiş yıllara ait yağış, nispi nem ve sıcaklık verileri birlikte kullanılmıştır. Hazırlanan birçok farklı modelden beş tanesi karşılaştırma amacıyla seçilmiştir. Çalışmada en iyi performansı 6 adet giriş verisi bulunan (sıcaklık, iki gün ötelenmiş nispi nem, bir gün ötelenmiş nispi nem, iki gün ötelenmiş yağış, bir gün ötelenmiş yağış) model 5 sergilemiş ve ileri beslemeli geri yayılım sinir ağının, çoklu doğrusal regresyon analizine göre daha başarılı sonuçlar verdiği görülmüştür.

Anahtar Kelimeler- Yağış, nispi nem, kara kutu modeli, yapay sinir ağları

Abstract- Precipitation data are predictable and can be predicted close to true; engineering is a situation that will provide many advantages. With the help of past precipitation data, this prediction can be done with certain mathematical equations. In these analysis systems, which are called the black box model, missing data and future data can be estimated with the help of the models created by the past data. Artificial Neural Networks (ANN) are frequently used in these forecasting models due to the need for efficient results and the ease and speed of use. In this article, rainfall data were estimated using Advanced Feeding Back Propagation Neural Network (AFBPNN). Rainfall, relative humidity and temperature data from past years are used together while forecasting models are being prepared. Of the many different models prepared, five were selected for comparison. The best performance in the study was model 5 exhibited and forward feedback propagation neural network with 6 input data (temperature, two days drift relative humidity, one day drift relative humidity, two days drift rainfall, one day drift rainfall) according to multiple linear regression analysis more successful results.

Keywords- Rainfall, relative humidity, black box model, artificial neural networks

I. GİRİŞ

Dünyamızda canlılığın temel ihtiyaçlarından biri olan su; yaşamı şekillendiren en temel unsurlardan bir tanesidir. Bu yüzden mevcut su kaynaklarını korumak, kontrol altında tutmak ve verimli bir şekilde faydalanmak oldukça önemlidir. Su kaynaklarının mevcut potansiyelinin korunumu ve verimli bir şekilde kullanılması için alınacak stratejik kararlar, hidrolojik model çalışmalarının bir kısmını kapsamaktadır. Hidrolojik modelleme yöntemleri içinde yer alan parametrik modellerde akıma etkileyen tüm karakteristik özellikler, yağış ve iklim koşulları gibi birçok verinin eksiksiz bir şekilde bilinmesi gerekmektedir. Bu kadar verinin kontrolü ve ölçümü zor olduğundan matematiksel bir yaklaşımla tahmin modelleri oluşturan kara kutu modelleri daha az veriyle daha hızlı ve yüksek bir performans sergilemeyi amaçlamaktadır. Kara kutu modellerinin çalışma prensibi mevcut verilere matematiksel bir yaklaşım sergileyerek ileriye dönük tahmin modelleri oluşturup, fazla veri ihtiyacı duymadan tahmin modelleri oluşturmaktır. Bu tahmin modelleri matematiksel denklemler ile kurgulanır

^{2*}Sorumlu yazar iletişim: syerel@gmail.com

^{1,2*} İnşaat Mühendisliği Bölümü, Mühendislik Fakültesi, Bilecik Şeyh Edebali Üniversitesi, Bilecik, Türkiye

ve başlangıç verilerine göre alınan sonuçlar farklılık gösterir [1-2]. Kara kutu modelleri arasında en çok tercih edilen yapay sinir ağları yıllardan günümüze birçok hidrolojik alanda kendine kullanım yeri bulmuş ve verimli sonuçlar vermiştir. Metodun bu kadar başarılı olmasının altında yatan sebep hızlı ve çok miktarda veriye ihtiyaç duymamasından kaynaklanmaktadır. Bu başarısı sebebiyle de birçok alanda kendine kullanım yeri bulan yapay sinir ağları ile yapılmış bazı çalışmalar aşağıda verilmiştir.


Bodri ve Cermak (1991), 2 yağış gözlem istasyonundan temin ettikleri aylık yağış verileri ile ileri beslemeli geri yayılım sinir ağından yararlanarak modeller geliştirmişlerdir. Toplamda 38 yıllık yağış verilerinden yararlanılan ve bir sonraki yılın yağış değerlerinin tahmin edildiği çalışmada ileri beslemeli geri yayılım sinir ağı başarılı sonuçlar vermiştir [3]. Tokar ve Johnson (1999), YSA yardımıyla günlük akımların; günlük yağış, sıcaklık, ve kar erimesi verileri yardımıyla tahmin edilmesi üzerine bir çalışma yürütmüşlerdir [4]. Applegate vd. (2002); Amerika’ da bulunan toplam 154 istasyondan temin edilen meteorolojik veriler yardımıyla 24 saatlik yağış tahmini yapmıştır. Çalışmada 5 farklı tahmin yöntemi kullanılmış ve en doğru sonuçların YSA ile hazırlanan modeller yardımıyla elde edildiği görülmüştür [5]. (Dergipark_2) Cıgızoğlu, (2005); kurak bölgelerde meydana gelen devre akımlarının tespitinde ileri beslemeli geri yayılım sinir ağı ve genelleştirilmiş regresyon sinir ağını ARMA metotları ile karşılaştırmıştır. En başarılı sonuçları genelleştirilmiş regresyon sinir ağı ile elde etmiştir [6]. Ramirez vd. (2005); yaptığı çalışmada yağış tahmini için YSA yöntemini kullanmıştır. Çalışmada kullanılan veriler ETA modeli ile elde edilmiş ve veriler sinir ağının eğitimi ve tahmin becerisini test etme amaçlı kullanılmıştır. Alınan sonuçlar çoklu doğrusal regresyon analizli sonuçlarıyla karşılaştırılmış ve YSA modellerinin daha iyi sonuçlar verdiği görülmüştür [7]. Partal vd. (2008); Türkiye’ye ait 3 adet yağış gözlem istasyon verileri yardımıyla yağış tahmininde bulunmak için YSA modelleri geliştirmişlerdir. YSA’ nın ileri beslemeli geri yayılım sinir ağı ile radyal tabanlı yapay sinir ağları yöntemlerinin kullanıldığı çalışmada; ileri beslemeli geri yayılım sinir ağı modellerinin gerçek değerlere daha yakın tahminlerde bulunduğu tespit edilmiştir [8]. Aslay ve Özen (2013), bazı meteorolojik parametrelerden faydalanarak bir sonraki yıla ait aylık ortalama toprak sıcaklığını tahmin etmek için yapay sinir ağı ile modelleme yapmışlardır. Modelin tahmin sonuçları regresyon analizi sonuçlarıyla karşılaştırılmış ve ölçülen gerçek değerlere en yakın sonuçları yapay sinir ağı ile hazırlanan modelin verdiği görülmüştür [9]. Gemici vd. (2013), akarsuların yapay zeka teknikleri kullanılarak modellenmesi konusunda bir çalışma yapmışlardır. Sonuç olarak Debinin belirlenmesinde yapay sinir ağları ve bulanık mantık modellerinin oldukça başarılı olduğu, model performanslarının birbirine yakın olduğu görülmüştür [10]. Turhan ve Çağatay, (2016), geçmiş yıllarda ölçülememiş eksik akım verilerinin bulunması için ileri beslemeli geri yayılım sinir ağı yardımıyla modeller oluşturmuşlardır. Önceki yıllara ait aylık akım verilerinden yararlanılarak hazırlanan modeller başarılı sonuçlar vermiş ve bir yapay sinir ağı yöntemi olan ileri beslemeli geri yayılım sinir ağının, eksik akım verilerinin tespitinde verimli bir şekilde kullanılabileceği görülmüştür [11].

Yaptığımız bu çalışmada Sakarya Havzasında yer alan Eskişehir iline ait 2007-2017 yılları arası ölçülmüş günlük yağış verileri kullanılmış ve tahminleme için modeller hazırlanmıştır. Yapay sinir ağları ve çoklu doğrusal regresyon analizi ile hazırlanan model sonuçları karşılaştırılmış ve yapay sinir ağlarının daha başarılı sonuçlar verdiği görülmüştür.

II. MATERYAL VE YÖNTEM

A. İleri Beslemeli Geri Yayılım Sinir Ağları

Yapay Sinir Ağları (YSA) insan beyni esas alınarak geliştirilmiş, birbirleri ile ağırlık bağlantı ilişkisi bulunan elemanların bir araya gelmesiyle oluşturulmuş paralel ve karmaşık bilgi işleme yapıları olarak adlandırılmaktadır. Ağ yapısının en ayırıcı özelliği, tecrübe odaklı öğrenebilme yeteneğine sahip olmasıdır. Önceki verilerden hareketle bunu başarabilen ağın öğrenme yolu ile yeni bilgiler elde etme ve oluşturabilme gibi fonksiyonel özellikleri sayesinde özellikle tahmin modellemelerinde sıklıkla kullanılan bir yapı haline gelmiştir [12]. Yapay sinir ağı hücre yapısı Şekil 1’de verilmiştir.




Şekil 1. Yapay sinir ağı katman yapısı

Yapay sinir ağları 1940'lı yılların başında gelişmeye başlamıştır. Günümüzde ise birçok alanda kullanılmaktadır. Ağın tarihsel gelişim süreci incelendiğinde birçok farklı model ve algoritmaya uyumluluğu göze çarpmaktadır. Yapılan ilk çalışmalarda yapay sinir ağları; tek katmanlı algılayıcılar ve perceptron adı verilen algılama modelleri kullanılarak hazırlanmıştır. İlerleyen zaman zarfında ise çok katmanlı modelleri tercih edilmiştir [13].

En basit haliyle yapay sinir ağları bir nöron ağı, bu ağı birbiriyle ilişkilendiren ağırlık değerleri ve bu değerler kullanılarak oluşturulan toplama fonksiyonlarından oluşan bir yapıdır. Bir yapay sinir ağı modeli olan ileri beslemeli geri yayılım ağında ilk önce bu ağırlık ilişkileriyle geliştirilmiş toplama fonksiyonlarından değerler elde edilir ve sonuç kısmına kadar belirli işlemlerden geçer. Bu işlemlerin ardından gerçek değerler bulunan değer karşılaştırılır hata miktarına göre alınan sonuç eğer istenenden yüksek bir hata değerine sahipse geri dönülerek ağırlık düzeltmeleri yapılır. Yani kısaca ağ ileri doğru ilerler ve hatayı düzeltmek için başa döner [14].

İleri Beslemeli Geri Yayılım sinir ağında bir adet giriş bir adet çıkış katmanı ve en az bir adet gizli katman bulunur. Gizli katman sayısı; veri sayısına ve verilerin birbirleri ile olan korelasyon ilişkisine göre ya da deneme yanıtı yolu ile belirlenmektedir. Öğrenme işlemi sırasında ağ boyunca ilerleyen ileri doğru tarama yapılır ve birbirini takip eden bir düğüm sırasının çıktısı hesaplanarak çıkış katmanına aktarılır. Burada istenen değerler ile çıkış katmanına aktarılmış olan değerler karşılaştırılır. Daha sonra bu iki değer arasındaki hata oranını azaltmak için ağ başa döner ve katman elemanları arasındaki ağırlık değerlerini düzenleyerek işlemi tekrarlar. Kısaca ağ yapısındaki temel amaç çıkış katman değerleri ile istenen sonuç değerleri arasındaki hatanın en aza indirilmesidir [15-16].

Bu sebeple ağ hücreleri arasında ağırlık değerlerinin iyi belirlenmesi gerekir. Ağırlıklı giriş değerlerinin toplamı olarak bulunan net fonksiyon ile giriş verilerinin bu hücre üzerindeki etkileri ifade edilmektedir. Bu net girdiler aktivasyon fonksiyonu adı verilen fonksiyonlar yardımıyla çıkış katmanına aktarılmaktadır. En yaygın olarak kullanılan sigmoid aktivasyon fonksiyonudur [17]. Fonksiyon grafiği Şekil 2'de verilmiştir.



Şekil 2. Sigmoid fonksiyon grafiği

Yapay sinir ağlarında; işlemi sürekli ileri doğru taşıyan ve değerleri çıktılar haline dönüştüren ve bulunan sonuçların hata miktarlarının azaltılması için işlemi geriye doğru tekrar yenileyen iki adet ağ yapısı bulunmaktadır. Bu mekanizma ağ ne kadar iyi eğitilirse o kadar verimli sonuçlar verir [18].

$$f_k = f_2 \{ \sum_{j=1}^n [f_1 (\sum_{i=1}^m a_i y_{ij} + b_j)] y_{jk} + b_k \} \quad (1)$$

Burada a_i ağın girdilerini, y_{ij} giriş katmanı ile gizli katman arasındaki ağırlık değerlerini, b_j giriş katmanı ile gizli katman arasındaki eşik (bias) değerlerini, f_1 giriş katmanı ile gizli katman arasındaki aktivasyon fonksiyonunu, f_2 çıkış katmanı ile gizli katman arasındaki aktivasyon fonksiyonunu, j gizli katmana ait hücre sayısını, m giriş katmanındaki hücre sayısını, n çıkış katmanındaki hücre sayısını, y_{jk} çıkış katmanı ile gizli katman arasındaki ağırlıkları, b_k çıkış katmanı ile gizli katman arasındaki eşik (bias) terimlerini ifade etmektedir [19].

$$A_{ij}^y = A_{ij}^e - \eta \frac{\partial T_a}{\partial A_{ij}} \quad (2)$$

Ağın katmanlar arasındaki ağırlık değerlerinin güncellendiği bu denklemde ise A_{ij}^y ağın yeniden güncellendiği ağırlık değerlerini, A_{ij}^e ağın bir önceki ağırlık değerlerini, η öğrenme oranını ve $\partial T_a \setminus \partial A_{ij}$ ağın yaptığı hatanın eğimini ifade etmektedir [19-20].

B. Çoklu Doğrusal Regresyon

İki farklı değişken sayı arasındaki doğrusal ilişkiyi en basit ifadeyle $y = a + bx + c$ şeklinde ifade etmek mümkündür. Veri sayısı arttıkça değişken sayısı da artacağından denklem aşağıdaki hale gelecektir. Bağımsız değişken 'x' birden fazla olursa y değerleri çoklu doğrusal regresyon denklemleri denklem (3) ile hesaplanabilmektedir.

$$y_i = a + n_1X_1 + n_2X_2 + \dots + n_nX_n + e_i \quad (3)$$

Burada; a sabit (constant) katsayısı, n_1, n_2, \dots ve n_n ise regresyon katsayılarıdır. n_i ($i = 1, 2, 3, 4$) katsayıları bağlı oldukları bağımsız değişken olan 'y_i' değerini değiştirme etkilerini, e_i değeri ise hata terimini belirtmektedir [21-22].

III. ÇALIŞMA ALANI

A. Yağış Gözlem İstasyonu

Çalışmada kullanılan yağış verileri 17126 no'lu yağış gözlem istasyonundan temin edilmiştir. İstasyon; Yenidoğan Mahallesi, Buluş Sokak Odunpazarı/Eskişehir'de bulunan Meteoroloji III. Bölge Müdürlüğü binası yanında ölçüm yapmaktadır. $39^\circ 76'56''$ enleminde ve $30^\circ 55'02''$ boylamında yer alan istasyonun bulunduğu rakım 801m ve rasat türü mm'dir.



Şekil 3. Yağış verilerinin temin edildiği yağış gözlem istasyonunun konumu

B. Bölge Bilgileri

Eskişehir ili İç Anadolu bölgesinde yer almaktadır. Genel olarak karasal iklim bölgeye hakimdir. Eskişehir ilinin de içinde yer aldığı Sakarya Havzası toplamda 58.160 km^2 drenaj alanına sahip ve Türkiye yüzölçümünün yaklaşık olarak %7,5 gibi bir kısmını kaplamaktadır. Havzaya senelik olarak $31.057 \text{ milyar m}^3$ yağış düşmektedir [23].



Şekil 4. Çalışmada kullanılan verilerin temin edildiği istasyonun yer aldığı Sakarya Havzasının harita üzerindeki yeri

IV. BULGULAR VE TARTIŞMA

Çalışmada kullanılan veriler Meteoroloji 3. Bölge Müdürlüğüne ait 17126 numaralı yağış gözlem istasyonundan temin edilmiştir. Veriler 2007-2017 yılları arası mm cinsinden gözlemlenmiş 4018 adet günlük yağış, nispi nem ve sıcaklık değerlerinden seçilmiştir.

Veriler sigmoid aktivasyon fonksiyonunun çalışma prensibinden ötürü normalize edilmiştir.

$$Y_{\text{normalize}} = (Y_{\text{veri}} - Y_{\text{max}}) / (Y_{\text{min}} - Y_{\text{max}}) \quad (4)$$

Burada Y_{veri} seçilen n adet veriyi göstermektedir. Y_{max} ($\text{max} = 1, 2, \dots, n$) veri değerleri içindeki en büyük değeri, Y_{min} ($\text{min} = 1, 2, \dots, n$) veri değerleri içindeki en küçük değeri ve $Y_{\text{normalize}}$ ise verinin normalize edilmiş halini göstermektedir [24].

Normalize işleminin ardından modellerin giriş katmanlarındaki veri sayılarının belirlenmesine geçilmiştir. Mevcut yağış, nispi nem ve sıcaklık verileri birbirleri ile olan anlamlı ilişkilerini kaybetmeyecek düzeyde ötelenerek farklı giriş katmanı değer senaryoları hazırlanmıştır. Veriler arasında korelasyon ilişkisi Tablo 1.'de verilmiştir.

Tablo 1. Modellerde kullanılan verilerin korelasyon ilişkileri

Veriler	S	N	Y	N-1	N-2	Y-1	Y-2	Y-3	Y-4
S	1	0,69	0,57	0,41	0,23	0,40	0,21	0,13	-0,17
N		1	0,78	0,86	0,77	0,60	0,49	0,33	0,24
Y			1	0,56	0,41	0,88	0,71	0,65	0,59
N-1				1	0,80	0,55	0,39	0,27	0,22
N-2					1	0,47	0,3	0,21	0,14
Y-1						1	0,84	0,70	0,63
Y-2							1	0,82	0,72
Y-3								1	0,88
Y-4									1

Tabloda S sıcaklık, N nispi nem, Y yağış verilerini temsil etmektedir. -1, -2, -3 ve -4 ise ötelenen gün sayısını belirtmektedir. Tablo incelendiğinde en yüksek korelasyon değerlerini kendi içinde ötelenen veri değerleri verdiği görülmektedir. Farklı verilerde ise en yüksek korelasyon ilişkisi yağış ve nem verileri arasındadır.

Hazırlanan bu senaryolardan karşılaştırma yapmak amacıyla 5 tanesi seçilmiş ve Tablo 2.'de giriş ve çıkış katman yapısı gösterilmiştir. Giriş katmanları hazırlanırken veriler arasındaki korelasyon ilişkisi göz önüne alınmıştır.

Tablo 2. Yapay sinir ağı için hazırlanan modellerin verileri

MODELLER	Giriş Katmanı	Çıkış Katmanı
1	S, N, Y-1	$Y_{\text{çıkış}}$
2	S, N, Y-1, Y-2	$Y_{\text{çıkış}}$
3	S, N, N-1, Y-1, Y-2	$Y_{\text{çıkış}}$
4	S, N, N-1, N-2, Y-1	$Y_{\text{çıkış}}$
5	S, N, N-1, N-2, Y-1, Y-2	$Y_{\text{çıkış}}$
6	N-1, N-2, Y-1, Y-2, Y-3	$Y_{\text{çıkış}}$
7	N-1, N-2, Y-1, Y-2, Y-3, Y-4	$Y_{\text{çıkış}}$

Aynı giriş katmanı ve çıkış katmanı verileri; çoklu doğrusal regresyon analizi ile matematiksel bir denklem haline getirilmiştir. 3, 4, 5 ve 6 bilinmeyenli olarak hazırlanan denklemler Tablo 3.'de verilmiştir.

Tablo 3. Çoklu Doğrusal Regresyon analizi sonucu elde edilmiş model denklemleri


MODELLER	DENKLEMLER
1	$-5,258 + 0,076x_1 + 0,746x_2 + 0,156x_3$
2	$-5,260 + 0,076x_1 + 0,726x_2 + 0,153x_3 + 0,0175x_4$
3	$-5,692 + 0,0757 x_1 + 0,625x_2 + 0,197x_3 + 0,0132x_4 + 0,014x_5$
4	$-5,690 + 0,0755x_1 + 0,613x_2 + 0,031x_3 + 0,140x_4 - 0,0147x_5$
5	$-5,26 + 0,0745x_1 + 0,618x_2 + 0,0334x_3 + 0,135x_4 - 0,0187x_5 + 0,0332x_6$
6	$-4,017 + 0,125x_1 + 0,81x_2 + 0,028x_3 + 0,040x_4 + 0,042x_5$
7	$-4,33 + 0,174x_1 + 0,554x_2 + 0,0139x_3 + 0,045x_4 + 0,077x_5 + 0,1232x_6$


Çalışmada 4018 adet verinin 3214 tanesi ağların eğitimi, 804 tanesi ise test amacıyla kullanılmıştır. Yapay sinir ağlarının ve Çoklu doğrusal regresyon analizinin karşılaştırıldığı 5 modelin gerçek değerlerle olan ilişkisi ortalama karesel hata (OKH) ve R^2 değerlerine bakılarak değerlendirilmiştir. R^2 değeri 1'e ne kadar çok yaklaşırsa alınan sonuçlar doğruya o kadar yakın demektir. Benzer şekilde OKH değerleri 0'a yaklaştığında gerçeğe daha yakın değerler elde edilmektedir. Alınan sonuçlar Tablo 4.'de verilmiştir.

Tablo 4. Yapay Sinir Ağları ve Çoklu Doğrusal Regresyon analizi ile elde edilen verilerin R^2 ve ortalama karesel hata (OKH) değerleri

MODELLER	ÇDR		YSA	
	R^2	OKH	R^2	OKH
1	0,32	68,16	0,53	49,78
2	0,36	65,21	0,64	45,90
3	0,41	59,81	0,68	39,44
4	0,39	62,22	0,60	42,88
5	0,47	51,71	0,75	35,84
6	0,51	44,51	0,84	30,03
7	0,62	40,11	0,92	24,76

Korelasyon değerleri göz önüne alınarak hazırlanan modellerde 1. modelin R^2 ve OKH değerlerine bakıldığında her iki analiz metodunda da en kötü sonuçları vermiştir. 2. model birbiriyle ilişkisi biraz daha fazla olan yeni verilerin modele eklenmesiyle 1. modele göre daha yüksek R^2 ve daha düşük OKH değerine sahip olmuştur. 3. modelde ana veri ile korelasyon değeri düşük olan nem verisi korelasyon değeri yüksek yağış verisi ile değiştirdiğinde ise giriş katman sayıları aynı olmasına rağmen 4. modelden daha iyi sonuçlar elde edilmiştir. 6. ve 7. modelde ise korelasyon ilişkisi en yüksek olan ötelenmiş yağış değerleri ağırlıkta kullanıldığından yüksek R^2 değerleri elde edilmiştir ve en başarılı sonuçlar 7. Modelden alınmıştır. R^2 değerleri çoklu doğrusal regresyon analizinde 0,62 değerine ulaşmışken yapay sinir ağları ile yapılan modelleme 0,92 R^2 değerine ulaşmıştır. Yapay sinir ağları ve çoklu doğrusal regresyon analizi ile hazırlanmış 7 adet model arasından en iyi sonuçları vermiş olan Model 7'nin grafikleri Şekil 5 ve Şekil 6'da verilmiştir.

**Şekil 5.** YSA Model 7 saçılım diyagramı



Şekil 6. ÇDR Model 7 saçılım diyagramı

V. SONUÇLAR

Yapılan çalışma sonucunda sıcaklık, nispi nem ve önceki yağış değerlerinden yararlanarak eksik verilerin tahmin edilebilmesi için yapay sinir ağları ve çoklu doğrusal regresyon analiz yöntemleri kullanılmıştır. Analiz tahmin modelleri oluşturulurken birbirleriyle düşük korelasyon ve yüksek korelasyon ilişkisi olan veriler beraber kullanılmış ve korelasyon değeri düşük olan veriler her iki tahmin metodunu da doğru sonuçlar vermekten uzaklaştırmıştır. Model 7, hazırlanan modeller arasında en başarılı sonuçları veren model olmuştur. Ağın eğitildiği veri sayısı ve verilerin birbirleri ile olan anlamlı ilişkisi modellerin sonuçlarının doğruluğunu büyük ölçüde etkilemiştir. Yapay sinir ağlarının ileri beslemeli geri yayılım algoritması ile elde edilen tüm model sonuçları çoklu doğrusal regresyon analizi sonuçlarına göre daha başarılı olmuştur. Buradan da yüksek miktardaki ve birbirleriyle kısmen ilişkili verilerle hazırlanan tahmin modellerinde yapay sinir ağlarının çoklu doğrusal regresyon analizine göre daha başarılı sonuçlar verdiği anlaşılmıştır.

KAYNAKLAR

- [1] Bayazıt, M., *Hidrolojik Modeller Ders Kitabı*, İTÜ İnşaat Fakültesi Matbaası (Baskı 1), İstanbul, 1998.
- [2] Cıgızoğlu, H. K., "Incorporation of ARMA models into flow forecasting by artificial neural networks," *Environmetrics*, vol. 14(4), pp. 417- 427, 2003.
- [3] Bodri L., Cermak, V., "Prediction of Extreme Precipitation using a Neural Network Application to Summer Flood Occurrence in Moravia," *Advances in Engineering Software*, vol. 31, pp. 311-321, 1991.
- [4] Tokar A. S. ve Johnson P. A., "Rainfallrunoff Modelling Using Artificial Neural Networks," *Journal of Hydrologic Engineering*, vol. 4, no. 3, pp. 232- 239, 1999.
- [5] Applequist, S., Gahrs, G. E., Pfeffer, R. L., "Comparison of Methodologies for Probabilistic Quantitative Precipitation Forecasting," *American Meteorological Society*, vol. 17, pp. 783-799, 2002.
- [6] Cıgızoğlu, H. K., "Application of the Generalized Regression Neural Networks to Intermittent Flow Forecasting and Estimation," *ASCE Journal Of Hydrologic Engineering*, vol. 10, no. 4, pp. 336, 2005.
- [7] Ramirez, M. C. V., Velho, H. F. C., Ferreira, N. J., "Artificial neural network technique for rainfall forecasting applied to the Sao Paulo region," *Journal of Hydrology*, vol. 301, pp. 146-162, 2005.
- [8] Partal, T., Kahya, E., Cıgızoğlu, K., "Yağış Verilerinin Yapay Sinir Ağları ve Dalgacık Dönüşümü Yöntemleri İle Tahmini," *İstanbul Teknik Üniversitesi Dergisi*, vol. 7, no. 3, pp. 73-86, 2008.
- [9] Aslay, F., Özen, Ü., "Meteorolojik Parametreler Kullanılarak Yapay Sinir Ağları ile Toprak Sıcaklığının Tahmini," *Politeknik Dergisi*, vol. 16, no. 4, pp. 139-145, 2013.
- [10] Gemici, E., Ardıçlıoğlu, M., Kocabaş, F., "Akarsularda Debinin Yapay Zeka Yöntemleri ile Modellenmesi," *Erciyes Üniversitesi Fen bilimleri Enstitüsü Fen Bilimleri Dergisi*, vol. 29 (2), pp. 135-143, 2013.
- [11] Turhan, E. ve Çağatay, H. Ö., "Eksik Akım Verilerinin Tahmin Modelinin Oluşturulmasında Yapay Sinir Ağlarının Kullanımı: Asi Nehri Demirköprü Akım Gözlem İstasyon Örneği," *Çukurova Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, vol. 31, pp. 93-106, 2016.

- [12] Uğur, A., Kınacı, A. C., "Yapay Zeka Teknikleri ve Yapay Sinir Ağları Kullanılarak Web Sayfalarının Sınıflandırılması," *XI. "Türkiye'de İnternet" Konferansı Bildirileri, TOBB Ekonomi ve Teknoloji Üniversitesi*, pp. 363-367, Ankara. 21-23 Aralık 2006.
- [13] Ülker, M., Civalek, Ö., "Yapay Sinir Ağları ile Eksenel Yüklü Kolonların Burkulma Analizi," *Turkish J. Eng. Env. Sci.*, vol. 26, pp. 117-125, 2002.
- [14] Yerdelen, C., "Mevsimlik Kar Erimesinin Yapay Sinir Ağları Yöntemi ile Tahmin Edilmesi," *Sakarya Üniversitesi Mühendislik ve Mimarlık Fakültesi Dergisi*, vol. 21, pp. 3-4, 2006.
- [15] Civalek, Ö., Plak ve Kabukların Nöro-Fuzzy Tekniği ile Lineer ve Non-Lineer Statik-Dinamik Analizi, Yüksek Lisans Tezi, Fırat Üniversitesi, Elazığ, 1998.
- [16] Keleşoğlu Ö., Fırat A., "İç Basınç Altında İnce Cidarlı Kabukların Yapay Sinir Ağları ile Çözümü," *Şileyman Demirel Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, vol. 10, no. 3, pp. 447-451, 2006.
- [17] Öztemel, E., *Yapay Sinir Ağları*, Papatya Yayıncılık (Baskı:1), İstanbul, 2003.
- [18] Şen Z., *Yapay Sinir Ağları İlkeleri*, Su Vakfı Yayınları (Baskı: 1), İstanbul, 2004.
- [19] Kişi Ö., "Yapay Sinir Ağları ve Regresyon Teknikleri ile Filyos Çayı Akımlarının Tahmini," *IV.Hidroloji Kongresi*, pp. 347-353, İstanbul, 23-25 Haziran 2004.
- [20] Gümüş, V., Kavşut, M. E., Yenigün, K., "Yağış Akış İlişkisinin Modellenmesinde YSA Kullanımının Değerlendirilmesi: Orta Fırat Havzası Uygulaması," *Bilimde Modern Yöntemler Sempozyumu*, pp. 14-16, Ekim 2010.
- [21] Özdamar, K., *SPSS ile Biyoistatistik*, Kaan Kitabevi (Baskı:1), Eskişehir, 2001.
- [22] Demir, P., S. Aral, S., "Kars İli Süt Sanayi İşletmelerinde Üretim ve Sanayi Entegrasyonunun Ekonomik ve Sosyo-Ekonomik Analizi," *Kafkas Üniversitesi Veterinerlik Fakültesi Dergisi*, vol. 16, no. 4, pp. 585-592, 2010.
- [23] <http://www.dsi.gov.tr/toprak-ve-su-kaynaklari/> (Erişim: Mayıs 2017).
- [24] Arı, A., Berberler, B. E., "Yapay Sinir Ağları ile Tahmin ve Sınıflandırma Problemlerinin Çözümü İçin Arayüz Tasarımı," *ACTA INFOLOGICA*, vol 1 no, 2, pp. 55-73, 2017.