

# Kurak bölge aylık yağışlarının Markov zinciri eklenmiş koşullu ileri beslemeli geri yayılım yapay sinir ağları ile tahmini

Ahmad DAHAMSHEH\*, Hafzullah AKSOY

İTÜ Fen Bilimleri Enstitüsü, Hidrolik ve Su Kaynakları Mühendisliği Programı, 34469, Ayazağa, İstanbul

## Özet

*Su kaynaklarının etkin bir şekilde planlanması ve yönetimi için yağışın doğru bir şekilde tahmin edilmesi büyük önem taşımaktadır. Hidrometeorolojik zaman serilerinin tahmini, zaman serisini etkileyen parametrelerin belirsizliğinden dolayı en zor işlerden biridir. Yapay sinir ağlarına dayalı kurak bölge yağış tahmin modelleri literatürde çok sınırlı sayıda bulunmaktadır. Bu çalışmada aylık toplam yağışın tahmini için Markov zincirleri eklenmiş koşullu ileri beslemeli geri yayılım yapay sinir ağları yöntemi kullanılmıştır. Uygulama için Ürdün'ün dağlık bölgesinden Amman meteoroloji istasyonu seçilmiştir. Çalışmada kullanılan veriler homojenlik testlerinden geçirilmiş, kullanılan testlere göre Ürdün'ün bu istasyonunun yağış verilerinin homojen olduğu belirlenmiştir. Bu çalışmada geliştirilen modeller, önceki aylara ait gözlenmiş yağış verilerini kullanarak gelecek ayın yağışının tahmin edilmesi prensibine dayanarak kurulmuştur. Deneme-yanılma yöntemi ile çok sayıda model seçeneği üretilmiştir. Girdi sayısı minimum olacak şekilde önce sadece bir önceki ayın yağışının girdi olarak kullanıldığı model seçeneği ile başlanmış, seçilen girdiler farklı hücre sayıları ile denenmiştir. Hücre sayısı girdi sayısı kadar seçilmiş, ampirik bir düşünce ile girdi sayısının iki katına kadar birer birer artırılmıştır. Periyodikliğin etkisinin görülmesi açısından periyodik bileşen de modellerde girdi olarak kullanılmıştır. Denenen her bir modelin performansı Ortalama Karesel Hata (OKH) ve belirlilik katsayısı ( $R^2$ ) ile ölçülmüştür. Markov zincirleri ile birleştirilmiş koşullu ileri beslemeli geri yayılım yapay sinir ağı modelinin kuru ayların belirlenmesinde, en yüksek yağış ve yağış tahmininde büyük başarı gösterdiği anlaşılmıştır.*

**Anahtar Kelimeler:** *Aylık yağış, kurak bölge, yapay sinir ağları, ileri beslemeli geri yayılım, Markov zinciri, Ürdün.*

\*Yazışmaların yapılacağı yazar: Ahmad DAHAMSHEH. adahamsheh@gmail.com; Tel: (555) 338 77 62.

Bu makale, birinci yazar tarafından İTÜ Fen Bilimleri Enstitüsü, İnşaat Mühendisliği Programı'nda tamamlanmış olan "Kurak bölge aylık yağışlarının Markov zinciri eklenmiş koşullu yapay sinir ağları ile tahmini" adlı doktora tezinden hazırlanmıştır. Makale metni 15.10.2008 tarihinde dergiye ulaştırılmış, 04.11.2008 tarihinde basım kararı alınmıştır. Makale ile ilgili tartışmalar 31.03.2010 tarihine kadar dergiye gönderilmelidir.

## Forecasting monthly precipitation for arid regions using conditional feed-forward backpropagation artificial neural network combined with Markov chain

### Extended abstract

*Understanding, modeling, prediction or forecasting of precipitation has always been important. Precipitation is the driven factor of hydrological cycle and is one of the main sources of water without which the humankind cannot survive. In particular, it becomes the unique source of water in arid regions where surface water courses are generally intermittent or ephemeral in nature. In such regions the main water income is from the groundwater storages that are again fed by precipitation. In such regions, therefore, precipitation becomes much more interesting than runoff to analyze as flow records are generally insufficient in length to obtain accurate estimations. Analysis of precipitation is evident not only because of that reason but also for agricultural and socio-economical activities, for increasing human and environmental demands as well as for planning and management of water resources. Precipitation changes both in time and space and affects on other components of the hydrological cycle; i.e. surface runoff, infiltration, groundwater, seepage, percolation, evaporation, transpiration, etc. Time variation comes from the seasonal climatological changes in the atmosphere whereas spatial change is due to the topographical heterogeneity on the earth surface.*

*Precipitation amount should be predicted accurately for an affective water resources management and planning. Prediction of hydrometeorological time series is difficult because of uncertainty in the parameters which affect the time series. In literature, the applications of artificial neural networks to forecast arid-region precipitation are limited. Forecasting monthly precipitation in arid regions is investigated by means of the conditional feed-forward backpropagation artificial neural network combined with Markov chain. Amman meteorological station from the hilly region in Jordan is selected for application. Various homogeneity tests are used for the*

*data, which is found homogeneous according to the results of the tests.*

*The feed-forward backpropagation artificial neural networks, statistical, and stochastic methods provided negative approximations for some of the low precipitation (dry months) whereas Markov chain forecasts are bounded with zero as the lower limit. Prediction using Markov chain does not generate physically unexplainable results mainly because the forecasts of the feed-forward backpropagation combined with Markov chain method are bounded with the minimum (zero) precipitation.*

*Antecedent monthly precipitation data are used as input to the model to predict the total precipitation in the next month. Selection of the inputs is based on the correlation coefficient. For the station analyzed, it is observed that precipitation in any month was highly correlated to its previous two months and its previous year record. A trial-and-error based construction for various artificial neural networks are tested. A total of 28 combinations of input variables are investigated. It is finally ended with an architecture that uses, as input variables, precipitation in two previous months and the previous year's precipitation of the month to be forecasted. Also a periodical component is added into the input vector to simulate the existing periodicity in the monthly precipitation.*

*Since the sigmoid function is used as the activation function for hidden and output layers, the model input and output are scaled appropriately to fall within the function limit (zero to one). Conditional feed-forward backpropagation artificial neural network combined with Markov chain is trained using the Levenberg-Marquardt training algorithm. After training is over, the weights are used to test the network performance on the test data.*

*In conclusion, it is seen that the conditional model considerably improves the accuracy of the one month ahead precipitation forecasting compared to the unconditional model.*

**Keywords:** *Monthly precipitation, arid region, artificial neural networks, feed-forward backpropagation, Markov chain, Jordan.*

## **Giriş**

Yağış, sıcaklık, basınç, nem ve rüzgar atmosferin en önemli iklim parametrelerinden kabul edilmektedir. İnsanoğlu başlangıçta yağışlı gün ve yağışlı olmayan gün tarifini yapmış, ayrıca sıcak hava ve soğuk hava tanımını ortaya atmıştır. Dünya üzerinde oluşan doğal afetlerin çoğu meteorolojik karakterlidir. Taşkınlar en yaygın görülen meteorolojik doğal afetlerin başında yer almaktadır. Taşkınlar uzun süreli yağıştan kaynaklanabileceği gibi, kısa süreli ve ani yağışlardan da meydana gelebilir.

Yağış tahmini insanların, hayvanların ve bitkilerin yaşamı için büyük önem taşımaktadır. Yağış miktarının tahmini, taşkın uyarılarının yapılması, taşkın kontrolü, kurak veya sulak dönemlerin tespiti açısından da önemlidir.

Kurak yerlerde ya da az yağış alan bölgelerde yağış özellikle büyük önem taşımaktadır. Ürdün'de bulunan su kaynaklarının en verimli şekilde kullanılması, geleceğe yönelik planların yapılması ve öngörülen yerlerde gerekli önlemlerin alınması için meteorolojik parametrelerin en iyi şekilde tahmini ve analizinin yapılması önemlidir.

Atmosferin birinci tabakasında oluşan yağıştan yararlanma ve zararlarından korunma amacıyla değişik tahmin modelleri kurulmuştur. Bunun için önceleri elle çizilen sinoptik haritalardan yararlanılmıştır. Daha sonra nümerik hesaplardan yararlanarak tahminler yapılmıştır. Teknolojinin gelişmesiyle global ve bölgesel sirkülasyon modelleri hızlı bir şekilde gelişmiştir. Ayrıca stokastik yöntemler de meteorolojik parametrelerin tahmininde kullanılmıştır. Yağışın tahmini için günümüzde çeşitli sayısal hava tahmin modelleri kullanılmaktadır. Ancak, yağışı meydana getiren fiziksel sürecin tam olarak çözülememesi, oluşumunda etkili olan parametrelerin çokluğu, bölgeden bölgeye büyük değişimler göstermesi ve daha pek çok nedenden dolayı hala doğru olarak tahmin edilmesi en zor hidrometeorolojik değişkenlerin başında gelmektedir. Özellikle saatlik ya da günlük gibi daha küçük zaman ölçeğinde yağışın doğru tahmin edilmesi çok daha önemlidir. Bu özellik-

le taşkınların önceden tahmin edilmesinde faydalı olacaktır.

Ürdün yağışları ile ilgili yapılan en eski çalışmalardan bir tanesi Ionides (1939)'a aittir. Çalışmada yıllık maksimum ve minimum yağış ile istasyonların yağış ortalaması hesaplanmıştır. Kullanılan veriler 1931–1939 yıllarını kapsamaktadır. Daha sonra 1952–1962 yıllarını kapsayan veriler kullanılarak yağış değişkenliği 58 istasyon için Al-Shalash (1964) tarafından araştırılmıştır. Shehadeh (1975) 112 istasyon için yıllık yağış miktarının değişkenliğini araştırmış, Ürdün'deki olası maksimum ve minimum yağışları tespit etmiştir. Ürdün yağışlarının kurak ve sulak dönemlerinin süreleri Abdel-Aty (1976) tarafından hesaplanmış, Ürdün yağışının simülasyonu için uygun bir Markov modeli oluşturulmuştur.

Yenilerde Ürdün yağışları ile ilgili Ghanem (1997), Tarawneh (1999, 2000), Bani Domi (2000), Tarawneh ve Kadioğlu (2003), Dahamsheh (2003), Dahamsheh ve Aksoy (2007) çalışmış, Freiwan ve Cıgızoğlu (2005) Amman istasyonunun aylık yağış tahmini için Yapay Sinir Ağlarına (YSA) dayanan bir model geliştirmiştir.

YSA teknolojisi yağış tahmininde sıkça kullanılmıştır (McCullagh vd., 1995; Kuligowski ve Barros, 1997, 1998a-b; Venkatesan vd., 1997; Hall, 1998; Liu ve Lee, 1999; Sahi vd., 2000; Bodri ve Cermak, 2000, 2001; Liu vd., 2001; Chantasut vd., 2004; Kumarasiri ve Sonnadara, 2006; Chattopadhyay, 2007; Kalteh ve Berndtsson, 2007; Coulibaly ve Evora, 2007; Hung vd., 2008).

Bu makaleye esas teşkil eden tez çalışmasında YSA ilk olarak yalın hali ile kullanılmıştır. Daha sonra Markov zincirleri ile birleştirilerek yağış tahminleri yapılmış, bu durumda modeller minimum yağış tahminlerinde (kuru ayların belirlenmesinde) büyük başarı göstermiştir. Aynı zamanda fiziksel anlamı olmayan negatif yağış tahminleri ortadan kalkmıştır. Modellerin performanslarını artırmak için YSA sentetik serilerle güçlendirilmiştir. Buna rağmen modellerden


alınan sonuçların tatmin edici olmadığı görülmüştür. Modellerin tahmin performansları önerilen koşullu YSA mimarileri ile yükseltilmiştir.

Bu çalışmada Ürdün aylık toplam yağışlarının Markov zincirleriyle birleştirilmiş koşullu ileri beslemeli geri yayılım YSA modelleri detaylı bir şekilde tanıtılmıştır.

## Yöntem

### İleri Beslemeli Geri Yayılım Yapay Sinir Ağları (İBGY YSA)

Bu YSA metodunda girdi, gizli ve çıktı tabakası olmak üzere üç farklı birim bulunmaktadır (Şekil 1). Her tabaka bir ya da birden çok nörondan oluşmakta, tabakalar aralarında ağırlık kümeleri ile bağlanmaktadır. Bağlanma şekli ve her kısımdaki nöron sayısı değişebilmektedir. Aynı tabakadaki nöronlar arasında iletişim olmasına izin verilmemektedir. Nöronlar girdiyi ya başlangıç girdilerinden ya da ara bağlantılardan almaktadır.



Şekil 1. İBGY YSA'da girdi, gizli ve çıktı tabakaları

İBGY YSA algoritması iki etaptan oluşmaktadır: (i) çıktı tabakasındaki çıktı bilgi sinyalini hesaplamak için girdi nöronlarındaki dış girdi bilgisini ileriye doğru ileten bir ileriye doğru besleme etabı, (ii) çıktı tabakasındaki hesaplanan ve gözlenen bilgi sinyalleri arasındaki farklara dayanarak bağlantı kuvvetleri üzerinde değişikliklerin yapıldığı bir geriye doğru ilerleme etabı.

Bir eğitim sürecinin başında, bağlantı kuvvetleri rastgele değerler olarak atanmaktadır. Öğrenme algoritması her iterasyonda eğitim başarı ile ta-

mamlanana kadar kuvveti değiştirmektedir. İterasyon süreci bir sonuca vardığında bağlantı kuvvetleri, eğitim sürecinde kullanılan örneklerdeki mevcut bilgiyi elde ederek saklamaktadır.

Yeni bir girdi grubu sunulduğunda, ileriye doğru besleme ile YSA'nın bağlantı kuvvetlerindeki öğrenilmiş ve saklanan bilgi sayesinde bir çıktı grubu elde edilmektedir. Bir girdi, bir gizli ve bir çıktı tabakasından oluşan üç birimli bir öğrenme ağı Şekil 1'de gösterilmiştir.

İBGY YSA'nın fiziksel olmayan negatif yağış tahmin etmesi gibi istenmeyen yönleri bulunmaktadır (Cıgızoğlu, 2005a-b). Bunu önlemek amacı ile İBGY YSA modelleri Markov zincirleriyle birleştirilmiştir.

### Markov zincirleri

Sonlu sayıda durumdan birinde bulunabilen (sonlu sayıda değerden birini alabilen) bir rastgele değişkenin zaman içinde ardışık anlarda (veya uzayda ardışık noktalarda) bulunduğu durumların (aldığı değerlerin) birbiri üzerindeki etkisi gözönünde bulundurularak oluşturulan süreç Markov Zinciri olarak adlandırılır. Bir Markov zincirinde ( $n > m$  olmak üzere) değişkenin  $t_m$  anında  $i$  durumunda iken  $t_n$  anında  $j$  durumuna geçme olasılığı;

$$P_{ij}(m, n) = P(X_n = j | X_m = i) \quad n > m \quad (1)$$

ile verilebilir. Markov zinciri homojen ise  $P_{ij}(m, n)$  olasılığı sadece  $t_m$  ve  $t_n$  anları arasında geçen süreye bağlıdır. Homojen bir zincirin  $k$  adımlı geçiş olasılık fonksiyonu;

$$P_{ij}(k) = P(X_{t+k} = j | X_t = i) \quad k > 0 \quad (2)$$

şeklinde tanımlanabilir.  $k=1$  alınırsa Markov zincirinin geçiş olasılıkları  $P_{ij}(1)$  bulunur. Bu olasılıklar kısaca  $P_{ij}$  ile gösterilirse,

$$P_{ij} = P_{ij}(1) = P(X_{t+1} = j | X_t = i) \quad (3)$$

yazılabilir.  $P_{ij}$  olasılıkları  $\mathbf{P}$  geçiş olasılıkları matrisinin elemanları olarak düşünülebilir. Boyutu  $m \times m$  olan bu matris;

$$\mathbf{P} = P_{ij} = \begin{bmatrix} P_{11} & P_{12} & \dots & P_{1m} \\ P_{21} & P_{22} & \dots & P_{2m} \\ \dots & \dots & \dots & \dots \\ \dots & \dots & \dots & \dots \\ P_{m1} & P_{m2} & \dots & P_{mm} \end{bmatrix} \quad (4)$$

şeklinde dir. Matriste bir satır üzerinde bulunan elemanların toplamları 1'e eşittir:

$$\sum_j P_{ij} = 1 \quad (5)$$

Çünkü bu elemanlar  $t$  anında belli bir durumda bulunan sürecin  $t+1$  anında çeşitli durumlara geçme olasılıklarını göstermektedir (Bayazit, 1996).

#### Yağışlı olan ve yağışlı olmayan aylar

Yağışlı olma ve olmama gibi iki durumu olan bir süreçte birinci mertebe Markov zincirinin geçiş olasılıkları matrisi;

$$\mathbf{P} = \begin{bmatrix} P_{11} & P_{10} \\ P_{01} & P_{00} \end{bmatrix} \quad (6)$$

şeklinde oluşturulabilir. (6)'da verilen geçiş olasılıkları matrisinde,

11: yağışlı olan bir ayı yine yağışlı olan bir ayın izlemesi

10: yağışlı olan bir ayı yağışlı olmayan bir ayın izlemesi

01: yağışlı olmayan bir ayı yağışlı olan bir ayın izlemesi

00: yağışlı olmayan bir ayı yine yağışlı olmayan bir ayın izlemesi

geçişlerini,  $\mathbf{P}$  de bu geçişlere karşı gelen olasılıkları göstermektedir. Bu olasılıklar  $n_{11}, n_{10}, n_{01}$  ve  $n_{00}$  yukarıdaki kategorilere giren ay sayıları olmak üzere,

$$P_{11} = \frac{n_{11}}{n_{11} + n_{10}} \quad (7)$$

$$P_{10} = \frac{n_{10}}{n_{11} + n_{10}} \quad (8)$$

$$P_{01} = \frac{n_{01}}{n_{01} + n_{00}} \quad (9)$$


$$P_{00} = \frac{n_{00}}{n_{01} + n_{00}} \quad (10)$$

ile hesaplanır.

İki durumlu Markov zincirlerinde parametre sayısı,  $k$  zincirin mertebesi olmak üzere  $2^k$  kadardır. Buna göre, birinci mertebe Markov zincirinde parametre sayısı 2 ( $P_{11}$  veya  $P_{10}$  ve  $P_{00}$  veya  $P_{01}$ )'dir.

#### Markov zincirleri tahmin algoritması

Herhangi bir ayın öncelikle yağışlı olup olmayacağına Markov zincirleri ile karar verilmektedir (Şekil 2). Eğer Markov zinciri ile aşağıda izah edilen tahmin algoritması sonucunda sözkonusu ayda yağış olmayacağı belirlenmişse, tahmin edilecek bir sonraki aya geçilmektedir. Markov zincirleri ile yağış olacağı tahmin edilen bir ayda ise yağış yüksekliğine İBGY YSA modeli ile karar verilmektedir.



Şekil 2. Markov zincirleri ile birleştirilmiş İBGY YSA modeli

Bu çalışmada tahmin yapılacak ayın yağışlı olup olmadığının tespit edilmesi için (6)'daki 2-durumlu Markov zinciri kullanılmıştır. Markov zincirinin geçiş olasılıkları matrisi eğitimde kullanılan verilerden hesaplanmıştır.

Markov zincirinin tahmin algoritması şu şekildedir: Yağışlı olan ve yağışlı olmayan ayların tahmini için (0.1) aralığında değişen uniform dağılımlı sayılar kullanılmaktadır. Önceki ay yağışsız olmak koşulu ile üretilen uniform sayı, yağışsız bir ayı yine yağışsız bir ayın izlemesi olasılığından büyük ( $u > P_{00}$ ) ise içinde bulunan ay yağışlı olacak, uniform sayı bu olasılıktan küçük veya ona eşit ( $u \leq P_{00}$ ) ise yağışlı olmayan ay gözlenecektir.

Benzer şekilde, önceki ay yağışlı olmak koşulu ile üretilen uniform sayı, yağışlı olan bir ayı yağışsız bir ayın izlemesi olasılığından büyük ( $u > P_{10}$ ) ise, tahmin edilecek ay yağışlı olacak, uniform sayının ( $u \leq P_{10}$ ) olması halinde ise tahmin edilecek ay yağışlı olmayacaktır.

### Koşullu İBGY YSA

Ürdün'ün bulunduğu iklim kuşağında aylık toplam yağışların yıl boyunca değişimi incelendiğinde yağışların kış aylarından yaz aylarına doğru azaldığı, yaz aylarından sonra kış aylarına doğru arttığı görülmektedir. Buna göre azalan yağışı olan ilkbahar dönemi ve artan yağışı olan sonbahar dönemi arasında yağışsız yaz dönemi mevcuttur. Yıl boyunca böyle bir değişim olan bir süreç için model kurmak zordur. Bu tip süreçlerin modellenmesinde her dönemin ayrı ayrı modellenmesi yoluna gidilebilir. Ancak bu durumda kurulacak model sayısı artacak, her model için ayrı ayrı parametre tahmini gerekecektir. Bu çalışmada bu yönlü bir sınıflandırmaya gidilmeksizin aylık toplam yağış sürecinin yıl boyunca tek bir model ile tanımlanması amaçlanmıştır. Bu yaklaşım doğal olarak model performansını etkileyecek, her bir dönem için model geliştirilmesi durumunda sağlanan performans elde edilemeyecektir.

Bu çalışmada geliştirilen modeller, önceki aylara ait gözlenmiş yağış verilerini kullanarak gelecek ayın yağışının tahmin edilmesi prensibine

dayanarak kurulmuştur. Deneme-yanılma yöntemi ile çok sayıda model seçeneği üretilmiş, bu seçenekler Tablo 1'de verilmiştir. Girdi sayısı minimum olacak şekilde önce sadece bir önceki ayın yağışının girdi olarak kullanıldığı model seçeneği ile başlanmış, seçilen girdiler farklı hücre sayıları ile denenmiştir. Hücre sayısı girdi sayısı kadar seçilmiş, ampirik bir düşünce ile girdi sayısının iki katına kadar birer birer artırılmıştır. Modellere bir önceki yağışın yanında iki ay ve bir yıl önceki yağışlar, ayrıca periyodikliğin etkisinin görülmesi açısından periyodiklik bileşen de girdi olarak katılmıştır.

Tablo 1. Model seçimi

Model No	Girdi	Hücre sayısı	OKH ( $mm^2$ )	R <sup>2</sup>
1	$X_{t-1}$	1	685.3	0.49
2	$X_{t-1}$	2	685.7	0.49
3	$X_{t-1}, P_t$	2	500.8	0.62
4	$X_{t-1}, P_t$	3	497.3	0.63
5	$X_{t-1}, P_t$	4	489.2	0.63
6	$X_{t-1}, X_{t-12}$	2	566.3	0.57
7	$X_{t-1}, X_{t-12}$	3	599.3	0.55
8	$X_{t-1}, X_{t-12}$	4	544.6	0.59
9	$X_{t-1}, X_{t-12}, P_t$	3	489.1	0.63
10	$X_{t-1}, X_{t-12}, P_t$	4	493.6	0.63
11	$X_{t-1}, X_{t-12}, P_t$	5	479.5	0.64
12	$X_{t-1}, X_{t-12}, P_t$	6	480.9	0.64
13	$X_{t-1}, X_{t-2}$	2	527.8	0.60
14	$X_{t-1}, X_{t-2}$	3	504.9	0.62
15	$X_{t-1}, X_{t-2}$	4	497.5	0.63
16	$X_{t-1}, X_{t-2}, P_t$	3	413.4	0.69
17	$X_{t-1}, X_{t-2}, P_t$	4	396.6	0.70
18	$X_{t-1}, X_{t-2}, P_t$	5	414.3	0.69
19	$X_{t-1}, X_{t-2}, P_t$	6	411.9	0.69
20	$X_{t-1}, X_{t-2}, X_{t-12}$	3	448.3	0.66
21	$X_{t-1}, X_{t-2}, X_{t-12}$	4	483.7	0.64
22	$X_{t-1}, X_{t-2}, X_{t-12}$	5	428.1	0.68
23	$X_{t-1}, X_{t-2}, X_{t-12}$	6	426.0	0.68
24	$X_{t-1}, X_{t-2}, X_{t-12}, P_t$	4	940.9	0.39
25	$X_{t-1}, X_{t-2}, X_{t-12}, P_t$	5	407.1	0.69
26	$X_{t-1}, X_{t-2}, X_{t-12}, P_t$	6	383.8	0.71
27	$X_{t-1}, X_{t-2}, X_{t-12}, P_t$	7	401.4	0.70
28	$X_{t-1}, X_{t-2}, X_{t-12}, P_t$	8	449.5	0.66

İBGY YSA'nın özellikle maksimum yağışları tahmin etmede zorlandıkları bilinmektedir (Freiwan ve Cıgızoğlu, 2005; Bodri ve Cermak, 2000, 2001). Modeller tahminlerinde belli bir

eşik maksimum değere kadar çıkmakta, daha büyük değerleri tahmin edememektedir.

Modellerin iyileştirilmesi için yapılan denemeler sonrasında koşullu bir ifadenin model yapısına yerleştirilmesi ile tahminlerin oldukça başarılı olduğu görülmüştür. Ampirik esaslara dayanmakla birlikte bu yaklaşımın modelin performansını geliştirdiği görülmüştür. Bu çalışmada verilen modeller içerdikleri koşullu önermeler dolayısıyla “koşullu ileri beslemeli geri yayılım yapay sinir ağları modelleri” olarak adlandırılmıştır. Koşullu model Şekil 3’teki akış diyagramına sahiptir. Buna göre;

$$x_t = f(x_{t-1}, x_{t-2}, x_{t-12}, p_t) \quad (11)$$

ile tanımlanan modele girdiler girilerek bir tahmin yapılmaktadır. Yapılan tahminin kendisinden önceki iki aya ait ayların yağışlarından büyük olup olmadığı kontrol edilmektedir. Bu iki aya ait yağışlardan herhangi birisinin tahmin edilen değerden büyük ( $x_{t-1} > x_t$  veya  $x_{t-2} > x_t$ ) olması durumunda bu aylara ait yağışlar sıfır alınarak modele sokulmaktadır. Bu durum matematiksel ifadelerle

$$(x_{t-1} > x_t \Rightarrow x_{t-1} = 0) \cap (x_{t-2} > x_t \Rightarrow x_{t-2} = 0) \quad (12)$$

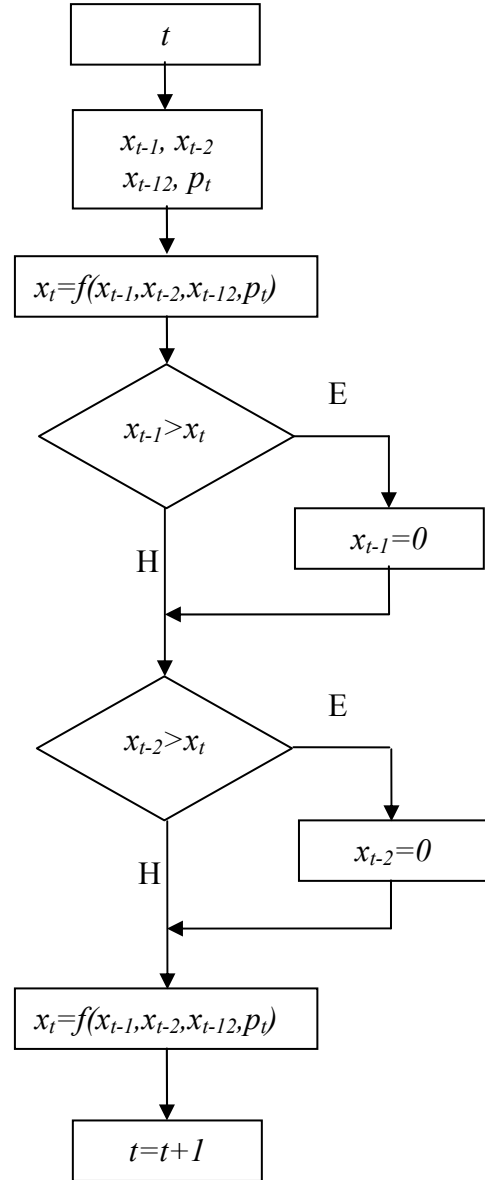
$\forall t$  için

şeklinde yazılabilir.  $x_{t-1}$  ve  $x_{t-2}$ ’ye ait yenilenmiş değerler kullanarak (11) modeli yeniden çalıştırılmakta ve tahmin bir kez tekrarlanmaktadır. Bu tahmin modelin çıktısı olarak kullanılmaktadır.

### Uygulama alanı ve kullanılan veri

Ortadoğu’da yarı kurak ve kurak iklim bölgesinde 90 000 km<sup>2</sup>’nin üzerinde bir alana sahip Ürdün su kıtlığı çekmektedir. Hızlı nüfus artışı, sosyoekonomik gelişme ve su kalitesindeki azalma ülkenin % 90’ından fazlasının yıllık ortalama yağışın 200 mm’den az yağış aldığı ve yağışın % 90’ının buharlaştığı ülkedeki su kıtlığını artırmaktadır. Ülkedeki su ihtiyacının % 73’ü sulama, % 22’si şehirlerde kullanma ve % 5’i endüstri kaynaklıdır. Ülkedeki toplam su ihtiyacı yeraltı ve yüzeysel su kaynaklarından sağla-

nanın iki katı kadardır (Al-Weshah, 2005). Bu nedenle Ürdün’ün önemli şehirlerine içme suyu sağlayan Azraq havzası, yeraltı suyu seviyesinin azalmasıyla kuru hale gelmiştir (Al-Kharabsheh, 2000).




Şekil 3. Koşullu YSA modeli

Ürdün’ün % 80’i kuraktır. Kurak dönemlerde yeraltı suyu kullanılmaktadır. Yeraltı suyunu besleyen tek kaynak yağıştır. Ürdün’ün batısında Ürdün nehri bulunmaktadır. Bu nehir Ürdün ve İsrail tarafından ortaklaşa kullanılmaktadır. Nehrin suyu bölgede bulunan tarım alanlarını sulamaya hizmet etmektedir.

Ürdün genel anlamda, altropikal kuşakta gerçekleşen ve Akdeniz iklim tipi adı altında tanınan bir iklim tipinin alanı içindedir. Ürdün'ün batısında kuzey-güney doğrultusunda uzanan dağlar batıdan gelen akımların iç kısımlara sokulmasını güçleştirir. Bu orografik yapı, dağlık ve iç kesimler arasındaki termik farklılıkları (yağış, sıcaklık ve nemlilik farkları) kuvvetlendirir.

Ürdün'ün yağışı genel olarak Kıbrıs üzerinde yerleşen alçak basınçın soğuk cephe sisteminden meydana gelir. Bu cephe sistemi doğuya doğru hareket edince yağışını Ürdün üzerinde bırakır. Kıbrıs üzerinde yerleşen alçak basınç merkezi ne kadar derinleşirse yağış o kadar artmaktadır. Kutuptan gelen kuzeyli rüzgarlar Türkiye'yi geçerek Kıbrıs üzerinde bulunan alçak basınç merkezinin derinleşmesine sebep olur. Bunun sonucu olarak kar yağışı görülmektedir. Alçak basınç sisteminin Ürdün'ün kuzey ve batı kısmına etkisi büyüktür. Ürdün'ün güney ve doğu kısmı ise atmosferin kararsızlığından etkilenmektedir.

Ürdün üç iklim bölgesinden (dağ, badiye ve vadi) oluşmaktadır. Bu çalışmada Ürdün Meteoroloji İdaresi tarafından işletilen dağlık bölgedeki Amman istasyonuna (Şekil 4) ait sonuçlar sunulmuştur.



Şekil 4. Amman istasyonunun konumu

Amman istasyonuna ait aylık toplam yağış verileri eğitme ve test için keyfi olarak iki kısma ayrılmıştır, verilere ait istatistikler Tablo 2'de verilmiştir. Bunlar ortalama, standart sapma, değişim katsayısı, çarpıklık katsayısı, birinci mertbe otokorelasyon katsayısı, minimum ve maksimum yağış değerleridir. Görüldüğü gibi eğitme aşamasındaki ortalama yağış değeri ile standart sapma test aşamasındaki verilerin ortalama ve standart sapmasından farklı ise de değişim katsayısı her iki aşamada da hemen hemen aynıdır. Yine hem eğitme hem de test aşamasındaki yağış verilerinin çarpıklıkları büyüktür. Ayrıca eğitme aşamasındaki maksimum yağış miktarının test aşamasındaki maksimum yağış miktarından farklı olduğu görülmektedir. Buna karşın birinci mertbe otokorelasyon katsayısı her iki aşamada da hemen hemen aynıdır.

Tablo 2. Amman istasyonu yağış serisinin istatistikleri

Veri	Ort (mm)	Ssap (mm)	$C_v$	$C_s$	$r_1$	Min (mm)	Mak (mm)
Eğitme	23.0	36.4	1.58	2.11	0.38	0	235.2
Test	19.4	29.7	1.53	1.78	0.42	0	140.1
Toplam	22.5	35.7	1.58	2.11	0.39	0	235.2

Markov zincirinin geçiş olasılıkları geliştirilen modelin parametreleri arasındadır. Tablo 2'deki eğitme veri kümesi kullanılarak geçiş olasılıkları hesaplanmış ve Tablo 3'te verilmiştir.

### Uygulama

Tahmin edilecek aydan ( $X_t$ ) bir ve iki önceki aylar ( $X_{t-1}$ ,  $X_{t-2}$ ) ile tahmin edilecek ayın bir önceki yılı ( $X_{t-12}$ ) ait gözlenmiş yağışını periyodiklik bileşen ( $P_t$ ) ile birlikte girdi olarak kabul eden 28 model seçeneği denenmiş, modeller ortalama karesel hata ve belirlilik katsayısı performans kriterine göre değerlendirilmiştir (Tablo 1).

Bu çalışmada gizli ve çıktı tabakalarında aktivasyon fonksiyonu olarak sigmoid kullanılmıştır. Kullanılan aktivasyon fonksiyonunun özelliğinden dolayı, veri setleri ağa verilmeden önce her bir giriş ve çıkış değerleri 0 ile 1 arasında normalize edilmiştir.



Tablo 3. Amman istasyonuna ait 2 durumlu Markov zinciri geçiş olasılıkları

Ay	P <sub>11</sub>	P <sub>00</sub>
Ocak	1.000	-
Şubat	1.000	-
Mart	0.986	-
Nisan	0.931	0.000
Mayıs	0.647	0.600
Haziran	0.065	0.963
Temmuz	0.000	0.986
Ağustos	0.000	1.000
Eylül	-	0.918
Ekim	0.667	0.239
Kasım	0.964	0.056
Aralık	1.000	0.000

Amman istasyonu için yapılan denemeler sonucunda en iyi model çıktısının ara tabakadaki hücre sayısının 6 olması durumunda elde edildiği belirlenmiştir. Böylece bu istasyon için kurulan Tablo 1'deki 26 no'lu modelin mimarisi (4,6,1)'dir.

Model çıktılarının gözlenen verilere benzerliklerine karar vermek için değişik performans kriterleri kullanılmıştır. Sayısal performans kriteri olarak Ortalama Karesel Hata (OKH) ve belirlilik katsayısı ( $R^2$ )'nin yanısıra gözlenen ve tahmin edilen yağışlar arasında çizilen saçılma diyagramlarına uydurulan doğruların eğimleri ve başlangıç değerleri de irdelenmiştir.

Bunun yanında tahmin edilen yağışlar ile gözlenen yağışlar arasındaki fark herhangi bir  $i$  ayı için;

$$(Hata)_i = (Tahmin)_i - (Gözlem)_i, i=1, \dots, N_a \quad (13)$$

şeklinde hesaplanmış, bu çalışmada "kalıntı" olarak adlandırılmıştır.

Kalıntı değerinin  $j$  ayı için ortalaması;

$$\overline{Hata}_j = \frac{1}{N_y} \sum_{k=0}^{N_y-1} Hata_{j+12k}, j=1, \dots, 12 \quad (14)$$

olarak elde edilmiştir. (13) ve (14)'te,  $N_a$  test süresindeki toplam ay sayısını,  $N_y$  de yıl sayısını göstermektedir.

(13) ile hesaplanan hatanın mutlak değerinin aylık ortalaması da modellerin performans değerlendirilmesinde kullanılmıştır. Mutlak hata herhangi bir ay için;

$$|Hata|_i = |Hata_i| \quad (15)$$

şeklinde hesaplandıktan sonra, mutlak hatanın  $j$  ayı için ortalaması;

$$\overline{|Hata|}_j = \frac{1}{N_y} \sum_{k=0}^{N_y-1} |Hata|_{j+12k} \quad (16)$$

ile belirlenmiştir. (14) ve (16) ile hesaplanan hata kriterleri yağışların her ay için ortalamasına bölünmek suretiyle;

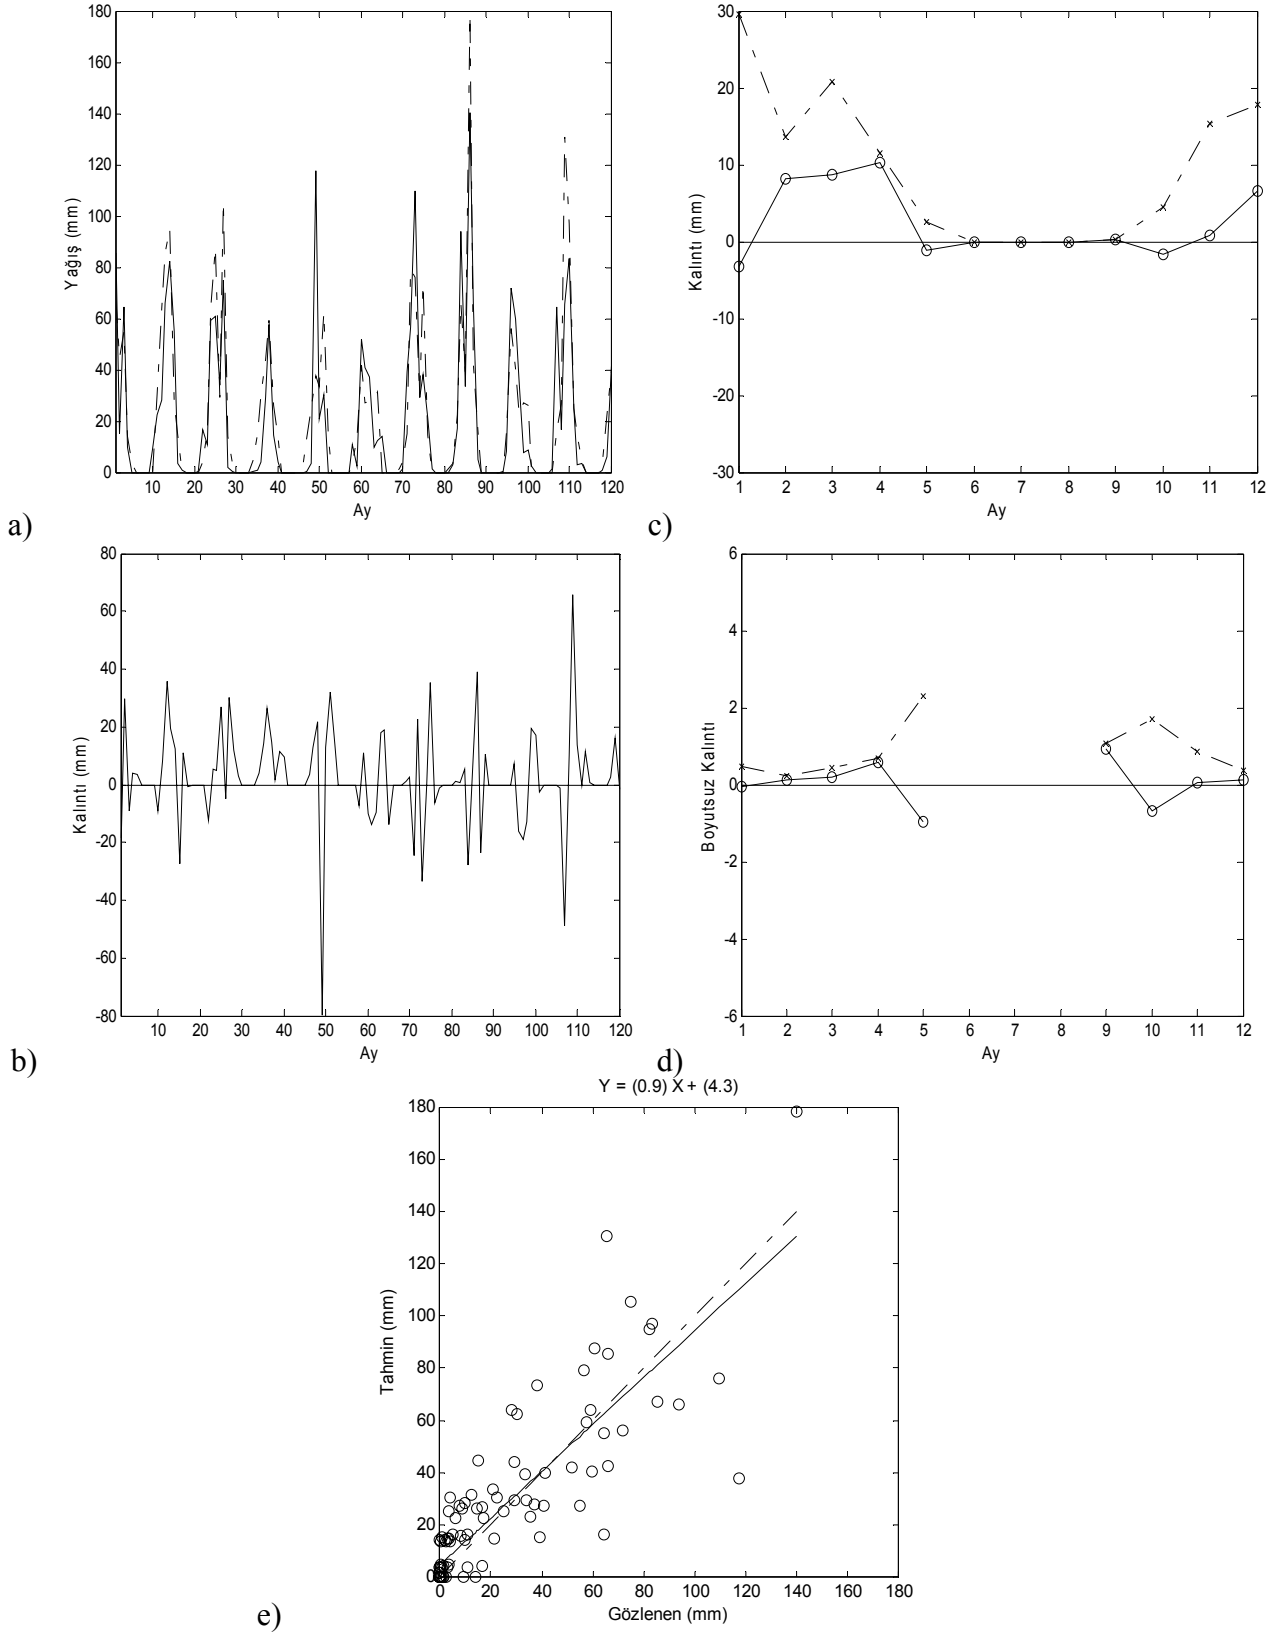
$$OH_j = \frac{\overline{Hata}_j}{(Ort\ yagis)_j} \quad (17)$$

$$OMH_j = \frac{\overline{|Hata|}_j}{(Ort\ yagis)_j} \quad (18)$$

şeklinde boyutsuz hale getirilmiştir.

Amman istasyonu için kurulan modelin test aşamasındaki ortalama karesel hatası  $273.8 \text{ mm}^2$  ve belirlilik katsayısı 0.73 olarak hesaplanırken en yüksek yağış miktarı 178.9 mm (gözlenen 140.1 mm), en düşük yağış miktarı 0 mm (gözlenen 0 mm) tahmin edilmiştir. Bu modelde kuru aylar oranı % 40 (gözlenen % 38) hesaplanmıştır. Bu model Markov zincirleri içerdiğinden kuru ay oranı tahmininde yüksek performans göstermektedir.

Markov zincirleriyle birleştirilmiş koşullu ileri beslemeli geri yayılım (MC-kİBGY) YSA modeline ait Şekil 5'teki sonuçlar incelendiğinde modelin yüksek ve düşük yağış miktarlarını tahminde büyük bir başarı gösterdiği anlaşılmaktadır (Şekil 5a). Aylık hatalar (Şekil 5b)



Şekil 5. Amman istasyonuna ait MC-KİBGY YSA sonuçları

a) Gözlenen (düz) ve tahmin edilen (kesikli) yağış b) Tahmin edilen ve gözlenen yağış arasındaki fark c) Aylık ortalama hata (düz), aylık ortalama mutlak hata (kesikli) d) Boyutsuz aylık ortalama hata (düz), boyutsuz aylık ortalama mutlak hata (kesikli) e) saçılma diyagramı

incelendiğinde bir kaç ay dışında hataların küçük olduğu görülmektedir. Ortalama hatalardan (Şekil 5c), tahmin edilen yağış miktarlarının gözlenen yağış miktarlarından daha büyük tahmin edildiği, yaz aylarında ise tahmin edilen yağış miktarlarının gözlenen yağış miktarlarına eşit olduğu görülmektedir. Ortalama mutlak hata (Şekil 5c) incelendiğinde ise kış aylarında yapılan tahminlerdeki hataların daha yüksek olduğu anlaşılmaktadır. Boyutsuz hata değerleri (Şekil 5d) incelendiğinde de yapılan hataların aylık ortalama yağış miktarlarına oranlarının düşük olduğu gözlenmiştir. Tahmin edilen ve gözlenen yağış miktarlarının 45°'lik doğru etrafında saçılma diyagramı incelendiğinde hem yüksek hem düşük yağışların fazla saçılmadığı, en uygun doğrunun 1:1 doğrusuna yaklaştığı görülmektedir (Şekil 5e).

## Sonuçlar

Kurak bölge aylık yağışlarının tahmininde YSA modellerinin literatürde mevcut yalın şekilleri ile kullanılması mümkün görülmemektedir. YSA modellerinin Markov zinciri ile birleştirilmesi ve hatta sentetik veriler kullanılarak eğitilmesi bile model performansını önemli derecede artırmamıştır. Ancak koşullu modelin çok başarılı bir performans gösterdiği görülmüştür. Tahmin edilen sonuçlar incelendiğinde  $OKH$ 'nin düştüğü,  $R^2$ 'nin arttığı anlaşılmıştır. Saçılma diyagramındaki doğru denklemine eğimin 1'e yaklaştığı, başlangıç değerinin de 0'a inme eğilimi gösterdiği görülmüştür. Tahminlerde, test süresindeki en büyük aylık yağışın yakalandığı, hatta aşılabildiği sonucuna ulaşılmıştır. Sonuç olarak Markov zinciri ile birleştirilmiş koşullu İBGY YSA modeli Ürdün gibi kurak bölge aylık yağışlarının tahmininde rahatça kullanılabilir.

## Kaynaklar

Abdel-Aty, S.H., (1976). On the distribution of rainfall sequences with application to actual data, *Dirasat-Natural Sciences*, **3**, 15-26.

Al-Kharabsheh, A., (2000). Ground-water modeling and long-term management of the Azraq basin as an example of arid area conditions (Jordan), *Journal of Arid Environment*, **44**, 2, 143-153.

Al-Shalash, A., (1964). Rainfall atlas of the Hashemite Kingdom of Jordan, Publication of the University of Jordan, Amman.

Bani Domi, M., (2000). Analysis of unusual atmospheric conditions which caused two successive khamassine and snow storms that affected Jordan between 15-18 March 1998, *Abhath Alyarmouk*, **18**, 2(A), 385-409.

Bayazit, M., (1996). İnşaat mühendisliğinde olasılık yöntemleri, İTÜ İnşaat Fakültesi Matbaası, İstanbul.

Bodri, L. ve Cermak, V., (2000). Prediction of extreme precipitation using a neural network: application to summer flood occurrence in Moravia, *Advances in Engineering Software*, **31**, 311-321.

Bodri, L. ve Cermak, V., (2001). Neural network prediction of monthly precipitation: Application to summer flood occurrence in two regions of central europe, *Studia Geophysica et Geodaetica*, **45**, 155-167.

Chantasut, N., Charoenjit, C. ve Tanprasert, C., (2004). Predictive mining of rainfall predictions using artificial neural networks for Chao Phraya River, *Proceeding, 4<sup>th</sup> International Conference of the Asian Federation of Information Technology in Agriculture and the 2<sup>nd</sup> World Congress on Computers in Agriculture and Natural Resources*, August 9-12, 2004, 117-122, Bangkok, Thailand.

Chattopadhyay, S., (2007). Feed forward Artificial Neural Network model to predict the average summer-monsoon rainfall in India, *Acta Geophysica*, **55**, 3, 369-382.

Cıgızoğlu, H.K., (2005a). Generalized regression neural network in monthly flow forecasting, *Civil Engineering and Environmental Systems*, **22**, 2, 71-84.

Cıgızoğlu, H.K., (2005b). Application of generalized regression neural networks to intermittent flow forecasting and estimation, *Journal of Hydrologic Engineering*, **10**, 4, 336-341.

Coulibaly, P. ve Evora, N.D., (2007). Comparison of neural network methods for infilling missing daily weather records, *Journal of Hydrology*, **341**, 27-41.

Dahamsheh, A., (2003). Monitoring meteorological drought in Jordan, *Yüksek Lisans Tezi*, İTÜ, Institute of Science and Technology, İstanbul.

Dahamsheh, A. ve Aksoy, H., (2007). Structural characteristics of annual precipitation data in Jordan, *Theoretical and Applied Climatology*, **88**, 201-212.

Freiwan, M. ve Cıgızoğlu, H.K., (2005). Prediction of total monthly rainfall in Jordan using feed

- forward backpropagation method, *Fresenius Environmental Bulletin*, **14**, 2, 142-151.
- Ghanem, A., (1997). Analysis of decadal rainfall in Jordan, *Dirasat-Natural and Engineering Science*, **24**, 1, 179-201.
- Hall, T., (1998). Precipitation forecasting using a neural network, *Waether and Forecasting*, **14**.
- Hung, N.Q., Babel, M.S., Wesakul, S. ve Tripathi, N.K., (2008). An artificial neural network model for rainfall forecasting in Bangkok, Thailand, *Hydrology and Earth System Sciences Discussion*, **5**, 183-218.
- Ionides, M.G., (1939). The water resources of trans Jordan and their development, London.
- Kalteh, A.M. ve berndtsson, R., (2007). Interpolating monthly precipitation by self-organizing map (SOM) and multilayer perceptron (MLP), *Hydrological Sciences–Journal–des Sciences Hydrologiques*, **52**, 2.
- Kuligowski, R.J. ve Barros, A.P., (1997). Experiments in short-term precipitation forecasting using Aartificial neural Networks, *Monthly Weather Review*, **126**.
- Kuligowski, R.J. ve Barros, A.P., (1998a). Localized precipitation forecasts from a numerical weather prediction model using artificial neural networks, *Weather and forecasting*, **13**.
- Kuligowski, R.J. ve Barros, A.P., (1998b). Using artificial neural networks to estimate missing rainfall data, *Journal of the American Water Resources Association*, **34**, 6.
- Kumarasiri, A.D. ve Sonnadara, D.U.J., (2006). Rainfall forecasting: An artificial neural network approach, *Proceedings of the Technical Sessions*, **22**, 1-13, Institute of Physics, Sri Lanka.
- Liu, H., Chandrasekar, V. ve Xu, G., (2001). An adaptive neural network scheme for radar rainfall estimation from WSR-88D observations, *Journal of Applied Meteorology*, **40**.
- Liu, J.N.K. ve Lee, R.S.T., (1999). Rainfall forecasting from multiple point sources using neural networks, *Proceedings, 1999 IEEE International Conference on Systems, Man, and Cybernetics*, **3**, 429-434, Piscataway, NJ, IEEE Service Center.
- McCullagh, J., Bluff, K. ve Ebert, E., (1995). A neural network model for rainfall estimation, 2<sup>nd</sup> New Zealand Two-Stream International Conference on Artificial Neural Networks and Expert Systems.
- Sahai, A.K., Somon, M.K. ve Satyan, V., (2000). All India summer monsoon rainfall prediction using an artificial neural network, *Climate Dynamics*, **16**, 291-302.
- Shehadeh, N., (1976). The variability of rainfall in Jordan, *Dirasat-Humanities*, **3**, 67-84.
- Tarawneh, S., (1999). Drought analysis of desert and badia of Jordan, *Abhath Alyarmouk, Basic Science and Engineering*, **2**, 117-145.
- Tarawneh, S., (2000). Drought analysis of selected rainfall in Jordan, *Dirasat-Engineering Science*, **2**, 117-145.
- Tarawneh, Q., Kadioğlu, M., (2003). An analysis of precipitation climatology in Jordan, *Theoretical and Applied Climatology*, **74**, 123-136.
- 
- Al-Weshah, R.A., (2005). Jordan's water resources: Technical perspective, ([http://www.wstaggc.org/cludes/GWC\\_4th/doc/w6.htm](http://www.wstaggc.org/cludes/GWC_4th/doc/w6.htm), last visited on March 16, 2005).