

Yağış verilerinin yapay sinir ağları ve dalgacık dönüşümü yöntemleri ile tahmini

Turgay PARTAL*, Ercan KAHYA, Kerem CİĞİZOĞLU

İTÜ İnşaat Fakültesi, İnşaat Mühendisliği Bölümü, 344696, Ayazağa, İstanbul

Özet

Meteorolojik değişkenlerden birisi olan yağış, su kaynakları açısından çok önemlidir. Yağış, akışı meydana getiren en önemli değişkendir. Kısa süreli aşırı yağışlar önemli taşkınlara neden olmaktadır. Uzun sürelerde yeterli yağışın meydana gelmemesi durumunda kuraklık meydana gelmektedir. Karmaşık bir fiziksel süreç sonucunda meydana gelen yağışın doğru tahmin edilmesi genellikle zordur. Özellikle yersel değişimlerden ve bölgesel özelliklerden oldukça etkilenmesi yağışın tahminini daha zorlaştırmaktadır. Lineer olmayan sistemlerin davranışında başarıyla kullanılabilen bir karakutu modeli olan yapay sinir ağları, böylesine karmaşık değişkenlerin tahmininde başarıyla kullanılmaktadır. Yapay sinir ağlarında tahminin başarısı üzerinde kullanıcının etkileri sınırlıdır ve daha çok girdilere bağlıdır. Yapay sinir ağları yönteminin tahmindeki başarısını arttırmak için dalgacık dönüşümü bu çalışmada kullanılmıştır. Dalgacık dönüşümü, verilerin hem zaman hem de frekans ortamında incelenmesine olanak sağlayan bir yöntemdir. Bu çalışmada Yapay Sinir Ağları (YSA) ve dalgacık dönüşümü yöntemleri ile günlük yağış tahmini yapılmıştır. Bu amaçla Türkiye'ye ait 3 istasyonun günlük meteorolojik verileri kullanılmıştır. YSA yönteminin literatürde en çok kullanılan algoritmalarından, İleri Beslemeli Geriye Yayılmalı Yapay Sinir Ağları (İBGYSA) ve Radyal Tabanlı Yapay Sinir Ağları (RTYSA) yöntemleri yağış tahmini amacıyla kullanılmıştır. Farklı girdi kombinasyonları denenerek her istasyon için en uygun model bulunmaya çalışılmıştır. Sonuçlarda ileri beslemeli geriye yayılmalı yapay sinir ağları algoritmasının kullanıldığı yöntem en iyi performans göstermiştir. Dalgacık dönüşümü-YSA yönteminin tahmin sonuçları çoklu lineer regresyon yönteminin sonuçları ile kıyaslanmış ve performans kriterlerine göre daha iyi olduğu bulunmuştur.

Anahtar Kelimeler: *Yapay Sinir Ağları, dalgacık dönüşümü, tahmin, yağış.*

* Yazışmaların yapılacağı yazar: Turgay PARTAL partalt@itu.edu.tr Tel: 212 285 68 45.

Bu makale, birinci yazar tarafından İTÜ Fen Bilimleri Enstitüsü, Hidrolik ve Su Kaynakları Mühendisliği Programında tamamlanmış olan "Türkiye yağış verilerinin yapay sinir ağları ve dalgacık dönüşümü yöntemleri ile tahmini" adlı doktora tezinden hazırlanmıştır. Makale metni 16.01.2007 tarihinde dergiye ulaşılmış, 22.03.2007 tarihinde basım kararı alınmıştır. Makale ile ilgili tartışmalar 01.02.2009 tarihine kadar dergiye gönderilmelidir.

Estimation of precipitation data using artificial neural networks and wavelet transform

Extended abstract

Forecasting the precipitation which is one of the most important meteorological variables is very important for planning and management of the water resources. Accurate precipitation prediction is one of the most difficult tasks in the meteorology because the complex physical processes involved and the variability of the precipitation is highly dependent on small scale processes and local geography. Especially the daily precipitation forecasting is one of the most challenging works and very important for the flood and drought analyses.

Artificial Neural Networks (ANN) are a useful tool to identify this relation. ANN approach is extensively used in the water resources literature in recently years. Artificial neural networks which is a black-box model, is used successfully in the modeling of non-stationary and complex variables. Black-box models are divided generally as linear and nonlinear and in particular artificial neural networks method is used in the modeling of nonlinear system behavior. The artificial neural networks have some advantages, such as easily applied, not needing much data. However the accuracy of model predictions is very subjective and highly dependent on user's ability, knowledge and understanding of the model. Especially, the input selecting is one of the most important phases in any ANN modeling study. Because of this, wavelet transformation is used for increase of user ability and success of artificial neural networks. The wavelet transform, which can produce a good local representation of the signal in both the time and frequency domains, provides considerable information about the structure of the physical process to be modeled and has positive effects on the ANN modeling ability. Because of these reasons, coupling wavelets with the ANN can provide significant advantages on predicting.

This study aims to predict the daily precipitation data of three belong to Turkish meteorological stations by applying the ANN methods and discrete wavelet transform. For this reason, the original time series were decomposed into a certain number of sub-time series using the wavelet transform. Then,

the suitable sub time series constituted the inputs of the ANN and the resulting model was applied to forecast the original time series. The sub time series decomposed by discrete wavelet transform from the original time series provide detailed information about the data structure and its periodicity. Behavior of each sub-series is different. For the selection of dominant sub-series, the correlation coefficients between the decomposed wavelet sub-series and the observed precipitation time series are computed. The selection of dominant sub-series becomes effective on the output data improving ANN model's performance.

In this study, the wavelet transforms and the ANN has been applied to estimate the daily precipitation. The meteorological data belong to the three station were investigated for this study. These are the daily mean temperature, the daily maximum temperature, the daily minimum temperature, the daily total specific humidity, the daily total evaporation and the daily total precipitation. Each of the meteorological data considered as input for the ANN model was decomposed into the wavelet sub-series by Discrete Wavelet Transform (DWT). Then, ANN configuration is constructed with appropriate wavelet sub series as input and the original precipitation time series as output. So, different wavelet-ANN models were prepared for each station. Precipitation estimation was applied with the two different algorithms of the artificial neural networks. Employment of the Feed Forward Back Propagation (FFBP) in the precipitation estimation is compared with the Radial Basis Function (RBF) performances. The results were also compared with linear regression model. As a result, it was seen that the wavelet-feed forward back propagation method provided the best estimation performance. Results indicate that the wavelet-ANN model estimations were superior to the ones obtained by the multi linear regression model. The wavelet-ANN models have provided a good fit with the observed data, especially for the time series which have zero precipitation in the summer months. It was seen that the ANN-wavelet method provided very successful estimation performance. This study is the first application to the daily precipitation estimations using the wavelet sub-series of the various meteorological variables in the water resources literature. The wavelet-ANN method is especially convenient in variables having non-linear dynamics such as predicting of precipitation data.

Keywords: Artificial Neural Networks, wavelet, precipitation.

Giriş

Meteorolojik değişkenlerin doğru tahmini ve analizi çok önemlidir. Bu meteorolojik değişkenlerden birisi olan yağış, su kaynakları ve su kaynaklarının kullanım alanları açısından çok önemlidir. Yağış, akışı meydana getiren en önemli değişkendir. Kısa süreli aşırı yağışlar önemli taşkınlara neden olmaktadır. Uzun sürelerde yeterli yağışın meydana gelmemesi durumunda kuraklık meydana gelmektedir. Oluşumuna etkiyen mekanizmalar tam olarak çözülemeyen yağışın doğru tahmin edilmesi genellikle zordur. Özellikle günlük ya da saatlik gibi daha küçük zaman ölçeğinde yağışın doğru tahmin edilmesi çok daha önemlidir. Yersel değişimlerden ve bölgesel özelliklerden oldukça etkilenmesi yağışın tahminini daha zorlaştırmaktadır. Sayısal hava tahmin modelleri, yaklaşık çeyrek yüzyıldır, pek çok meteorolojik değişkenin tahmininde sıklıkla kullanılmaktadır. Fizik kanunlarına dayanan Sayısal Hava Tahmin Modelleri, ilk uygulamaya girdikleri günden beri sürekli olarak gelişmiştir. Ancak küçük ölçekli yersel değişimlerden fazlasıyla etkilenen yağışın tahmininde hala istenilen başarıyı yakalayamamıştır.

Hidrometeorolojik alanda son yıllarda yapay zeka metodlarının tüm dünyada kullanımı giderek artmaktadır. Lineer olmayan sistemlerin davranışında başarıyla kullanılabilen bir karakutu modeli olan Yapay Sinir Ağları (YSA) özellikle aralarındaki ilişki tam olarak belirlenemeyen değişkenlerin modellenmesinde başarıyla uygulanmaktadır. Dolayısıyla yağışın tahmin edilmesinde yapay sinir ağırları, sayısal hava tahmin modellerine alternatif bir yaklaşım sunmaktadır. YSA, uygulamasındaki kolaylık, fazla veri gerektirmemesi gibi nedenlerle tahmin amacıyla iyi bir yöntemdir.

Yapay sinir ağlarının su kaynaklarında ve değişik meteorolojik olayların tanımlanması, sınıflanması ve tahmininde sıkça karşılaşılan değişik problemlere uygulanması ile ilgili çok sayıda çalışma bulunmaktadır. Literatürde YSA'nın su kaynakları alanında uygulanması ile ilgili geniş kapsamlı bir araştırma Maier ve Dandy (2000) tarafından yapılmıştır. Maier ve Dandy (2000) bu çalışmada YSA ile ilgili 43 makale ayrıntılı

olarak irdelenerek modelleme hakkında geniş bir bilgi verilmiştir. Su kaynakları alanında YSA ile yapılan çok sayıda çalışma bulunmaktadır. En çok nehir akım tahmini üzerinde YSA çalışması bulunmaktadır (Cıgızoğlu, 2003a, b; Cıgızoğlu ve Kişi, 2005; Campolo vd., 1999, Hsu vd., 1995). Yağış-akış modellemesi üzerine (Rajurkar vd., 2002; Cıgızoğlu ve Alp, 2004), buharlaşma tahmininde (Sudheer vd., 2002) ve akarsularda askı malzemesi tahmininde (Cıgızoğlu, 2004a; Cıgızoğlu ve Alp, 2006) YSA modelleri kullanılmıştır.

YSA tekniğinin yağış tahmini üzerine çeşitli uygulamaları yapılmıştır. Hall (1999) Amerika'da 2 yıllık bir zaman serisinde günlük yağış olasılığı için YSA modeli kullanmıştır. Bu çalışmada çeşitli meteorolojik değişkenler ile çalışılmıştır. Çalışmada % 95 olasılıkla yağmur beklenmeyen 436 günün 435 tanesinde yağmur meydana gelmemiştir. Sonuç olarak bu modelin yağış olma olasılığını büyük doğrulukla tahmin ettiği ortaya konulmuştur. Applequist vd., (2002) Amerika'da beş farklı tekniği (YSA, lineer regresyon, diskriminant analizi, lojistik regresyon, diskriminant analizinden geliştirilen farklı bir sınıflama sistemi) kıyaslamıştır. Çalışmada Amerika'da 154 istasyondan elde edilen meteorolojik veriler yardımıyla 24 saatlik yağış tahmini yapılmıştır. Freiwan ve Cıgızoğlu (2005) ileri beslemeli geriye yayılmalı YSA yöntemini kullanarak Ürdün aylık yağışlarını tahmin etmeye çalışmışlardır. Bu çalışmada YSA modelinin test aşamasındaki belirlilik katsayısı 0.45 değerlerine kadar çıkmıştır. Sonuçlar AR(p) modeli ile kıyaslanmış ve YSA modelinin daha iyi olduğu ortaya konmuştur. Ramirez vd., (2005) Sao Paulo'ya yağış tahmini için YSA tekniklerini uygulamışlardır. Başka bir meteorolojik modelden (ETA modeli) elde edilen değişkenler girdi olarak modele sokulmuştur. Sonuçlar çoklu lineer regresyon yöntemi ile kıyaslanmış ve YSA'nın daha iyi sonuçlar verdiği görülmüştür. Kulligowski ve Baros (1998) Amerika'da 2 havzada 6 saatlik yağış tahmininde YSA modeli kullanmışlardır. YSA modelinin lineer regresyon modelinden özellikle aşırı yağışları tahmin etmede çok daha başarılı olduğu bulunmuştur.

Yapay sinir ağları; uygulamasındaki kolaylık, fazla veri gerektirmemesi, veri dağılımlarından etkilenmemesi gibi nedenlerden dolayı da iyi bir yöntemdir. Ancak YSA, simülasyonlarındaki başarılarına rağmen hala bazı belirsizliklere sahiptir. Yöntemin en önemli eksik yanı, olayın fiziksel yönünü göz önüne almamasıdır. Ayrıca, kullanıcının model girdilerini doğru belirlemesi, yöntemin başarısını doğrudan etkilemektedir.

Özellikle son yıllarda, meteorolojik ve hidrolojik değişkenler üzerinde de çeşitli uygulamaları olan dalgacık analizi, verilerin periyodik ve karakteristik yapısının belirlenmesinde kullanılan yeni bir yöntemdir. Dalgacık dönüşümünün kullanılması yapay sinir ağlarının yeteneğini ve başarısını arttırmıştır. Dalgacık dönüşümü, verilerin periyodik yapısının ortaya çıkarılmasını ve böylece yapılan tahmin çalışmasına fiziksel bazı özellikler katılmasını sağlar. Bu çalışmada dalgacık analizi yöntemi, modelin girdi aşamasında yapay sinir ağları yöntemine katılacaktır.

Dalgacık dönüşümünün YSA ile birlikte kullanımını konusunda bazı çalışmalar yapılmıştır. Hidrolojide YSA ve Dalgacık tekniğinin birlikte kullanılması ile ilgili ilk çalışmalardan birisi Wang ve Ding (2003) tarafından yapılmıştır. Bu çalışmada YSA ve dalgacık analizinin kombinasyonundan oluşan yeni bir model önerilmiştir. Orijinal zaman serisi dalgacık dönüşüm tekniği ile alt-zaman (sub-time) serilerine ($W_1, W_2, \dots, W_p, C_p$) ayrıştırılmış, bu serilerin orijinal seri hakkında detaylı bilgi verdiği ve her ayrılmış serinin farklı bir davranışı olduğu belirtilmiştir. Burada W_i detay, C_p ise yaklaşık serisidir. Daha sonra YSA modelinde bu ayrılmış seriler girdi olarak kullanılarak orijinal zaman serisi tahmin edilmeye çalışılmıştır. Yani veriler kendi alt zaman serileri tarafından tahmin edilmeye çalışılmıştır. Bu araştırmacılar, bu yöntemi günlük akım tahmini ve yeraltı suyu seviyesinin tahmini olmak üzere iki ayrı uygulama ile denemişlerdir. Sonuçları ARMA modeli sonuçları ile kıyaslamışlar ve sonuçta ileri sürülen dalgacık-YSA modelinin tahmin edici ve başarılı olduğunu bulmuşlardır. Bir başka çalışmada ise Kim ve Valdes (2003)

Meksika'da kuraklık tahmini yapmak için YSA ve dalgacık tekniğinin karışımı olan melez bir model önermişlerdir. Bu teknikte ayrık dalgacık dönüşümü ile orijinal işaret çeşitli çözünürlük seviyelerinde parçalara ayrılmış ve bu yeni seriler tahmin amacıyla YSA modeline sokulmuştur. Yani veriler kendi dalgacık bileşenleri tarafından tahmin edilmişlerdir.

Bu çalışmada yapay sinir ağlarının iki farklı algoritması (ileri beslemeli geriye yayımlı yapay sinir ağları, radyal tabanlı yapay sinir ağları) ve dalgacık dönüşümü yöntemleri ile Türkiye'de 3 istasyona ait günlük meteorolojik veriler kullanılarak günlük yağış tahmini yapılmıştır. Veriler önce ayrık dalgacık dönüşümü ile alt bileşenlerine ayrılmış, sonra uygun bileşenler seçilerek, YSA modeliyle yağış tahmini yapılmak için kullanılmıştır. Her istasyon için farklı girdi bileşenlerinden oluşan farklı modeller denenmiş ve sonuçta en iyi performansı gösteren modeller belirlenmiştir. Böylece her istasyon için farklı YSA model yapıları oluşturulmuştur. Sonuçlar çoklu lineer regresyon yöntemi ile kıyaslanmış ve YSA modelinin çok daha iyi olduğu ortaya konmuştur.

Veri analizi

Çalışmada değişik iklim bölgeleri üzerinde yer alan ve DMİ Genel Müdürlüğü tarafından işletilen 3 istasyona ait günlük meteorolojik veriler kullanılmıştır. Mevcut veriler seçilirken, kullanılan kara-kutu modellerinin istediği, meteorolojik sistemin davranışını en iyi yansıtabilecek veriler olmasına özen gösterilmiştir. Seçilen veriler ortalama sıcaklık (S_{ort}), maksimum sıcaklık (S_{mak}), minimum sıcaklık (S_{min}), ortalama nem (N), toplam buharlaşma (B) ve toplam yağıştır (Y). Bu veriler 15 yıl uzunluktadır (01.01.1987-31.12.2001). İstasyonlar ile ilgili konum bilgileri Tablo 1'de verildiği gibidir.

Tablo 1. Tahmin amacıyla kullanılan istasyonlar

İstasyon adı	İstasyon numarası	Enlem	Boylam
Edirne	17050	41.4	26.34
İzmir	17220	38.26	27.1
Muş	17204	38.44	41.29

Kullanılan veriler hakkında ön bilgi elde etmek amacıyla, yağış verilerine ait ortalama, maksimum, standart sapma, çarpıklık katsayısı ile lag 1, 2, 3 aralıklı oto korelasyon katsayıları hesaplanarak Tablo 2’de verilmiştir. Ayrıca korelasyon sonuçları YSA yönteminin girdilerinin seçilmesinde kullanılmıştır. Tablo incelendiğinde yağış için en yüksek maksimum değerinin İzmir yağış istasyonunda olduğu görülmektedir. En düşük maksimum değer ise Muş yağış verilerinde olduğu görülmektedir. Ayrıca yağış verilerinin çarpıklık katsayılarının yüksek olduğu görülmektedir. Verilere ait otokorelasyon katsayılarının genelde çok yüksek olmadığı görülmektedir. Tabloya bakarsak, en yüksek oto korelasyon katsayısı Muş istasyonunda (değeri 0.302) görülmektedir. En düşük ise Edirne istasyonuna ait yağış verilerinde (değeri 0.198) görülmektedir. Ancak lag1’den sonraki otokorelasyonların gittikçe azaldığı ve sifıra çok yakın olduğu görülmektedir. Otokorelasyon katsayıları YSA ile yağış tahmininde modelin girdilerinin seçilmesinde önemli ipuçları vermektedir. Bu yüzden çok önemlidir. Bu sonuçlara göre 1 gün önceki yağışların YSA metotlarının girdisi olarak kullanılabilceği sonucu çıkmaktadır. Girdi olarak kullanılması düşünülen verilerin yağış ile olan korelasyon katsayıları da belirlenerek Tablo 3’te gösterilmiştir. Tabloda görüldüğü gibi genel olarak tüm verilerin yağış ile olan korelasyonları istenilen düzeyde değildir. Yağışın en iyi korelasyon gösterdiği verinin nem olduğu görülmektedir. Daha sonra, buharlaşma verileri gelmektedir. En yüksek korelasyon katsayısının Muş istasyonunda bir gün önceki nem ile yağış verileri arasında (değeri 0.37) olduğu görülmek-

tedir. Sıcaklık verilerine bakıldığında da genel olarak maksimum sıcaklık verilerinin korelasyon katsayılarının daha iyi olduğu görülmektedir. Minimum sıcaklık verileri ise yağış ile daha düşük korelasyonlar göstermiştir.

Tablo 2. Günlük yağış verilerinin bazı istatistik parametreleri (x_{ort} , x_{maks} , s_x , c_{sx} , r_1 , r_2 , r_3 sırasıyla ortalama, maksimum, standart sapma, çarpıklık katsayısı, lag1, lag2 ve lag3 oto korelasyon katsayıları)

İstatistik parametreler	Edirne	İzmir	Muş
X_{ort} (mm)	1.5	1.86	2.1
X_{maks} (mm)	91.5	108	77.8
s_x (mm)	5.08	6.85	5.78
c_{sx}	5.78	5.98	4.46
r_1	0.198	0.277	0.302
r_2	0.05	0.098	0.105
r_3	0.024	0.082	0.08

Yöntem

İleri Beslemeli Geriye Yayılmalı Yapay Sinir Ağları (İBGYSA)

Yapay sinir ağıları girdilere karşılık çıktılar üreten bir kara kutu olarak ele alınabilir. Beynin zor işlemleri yapabilme ve kompleks örnekleri kavrayabilme yeteneği ve özellikle ilgili fiziksel ilişkileri bilmeden yalnızca denemeyle bazı şeyleri öğrenebilmesi bilim adamlarına yapay sinir ağıları metodunun geliştirilmesi için ilham vermiştir (Cıgızoğlu, 2004b). Yapay sinir ağıları kendisine verilen örnekler üzerinde kendini eğiterek bir çözüm sistemi geliştirmektedir.

Tablo 3. Yağış verileri ile diğer meteorolojik veriler arasındaki lag 0 ve lag1 korelasyon katsayıları (örneğin, $S_{ort,t}/Y_t$, yağış ve ortalama sıcaklık verileri arasındaki korelasyon katsayısı; $S_{ort,t-1}/Y_t$, t zamana ait yağış verileri ile bir gün önceye ait ortalama sıcaklık verilerinin korelasyon katsayıları)

İstasyon	Ort. sıcaklık		Maks. Sıcaklık		Min. Sıcaklık		Nem		Buharlaşma	
	$S_{ort,t}/Y_t$	$S_{ort,t-1}/Y_t$	$S_{maks,t}/Y_t$	$S_{maks,t-1}/Y_t$	$S_{min,t}/Y_t$	$S_{min,t-1}/Y_t$	N_t/Y_t	N_{t-1}/Y_t	B_t/Y_t	B_{t-1}/Y_t
Edirne	-0.12	-0.08	-0.15	-0.10	-0.04	0.00	0.22	0.31	-0.12	-0.08
İzmir	-0.21	-0.17	-0.23	-0.20	-0.15	-0.12	0.33	0.34	-0.16	-0.15
Muş	-0.17	-0.16	-0.19	-0.19	-0.10	-0.09	0.30	0.37	-0.24	-0.22

İleriye beslemeli geriye yayılmalı yapay sinir ağları (İBGYSA) yöntemi en çok kullanılan YSA yöntemidir. Bu yöntemde girdi, gizli ve çıktı birimleri olmak üzere üç farklı birim bulunmaktadır. Her birim birçok nörondan oluşmakta olup birimler aralarında bağlantı kuvvetleri ile bağlanmaktadır. İBGYSA iki etapta oluşmaktadır. Birincisi, çıktı birimindeki çıktı bilgi sinyali hesaplamak için girdi hücrelerindeki dış girdi bilgisini ileriye doğru ileten bir ileriye doğru besleme etabıdır. İkincisi ise, çıktı biriminde hesaplanan ve gözlenen bilgi sinyalleri arasındaki farklara dayanarak bağlantı kuvvetleri üzerinde değişikliklerin yapıldığı bir geriye doğru ilerleme etabıdır (Cıgızoğlu, 2004b). Bir eğitim sürecinin başında, bağlantı kuvvetleri rasgele değerler olarak atanmaktadır. Öğrenme algoritması her iterasyonda eğitim başarı ile tamamlanana kadar kuvveti değiştirmektedir. Girdi biriminde çok sayıda nöron çıktı biriminde tek nöron bulunmaktadır. Girdi nöronlarında $x_i, i=1, \dots, k$ girdi değerleridir. Girdi değerleri gizli nöronlardaki ilk ara bağlantı ağırlıkları, $w_{ij}, j=1, \dots, h$, ile çarpılmakta, sonuçlar i indeksi boyunca toplanmakta ve gizli birimlerin girdileri olmaktadır.

$$H_j = \sum_{i=1}^k w_{ij} x_i \quad j=1, \dots, h \quad (1)$$

burada H_j j gizli nodunun girdisi, w_{ij} ise i nöronundan j nöronuna doğru olan bağlantı ağırlığıdır. Her gizli nöron bir sigmoid fonksiyonu yardımı ile bir gizli nöron çıktısı, HO_j , oluşturmaktadır. HO_j aşağıdaki şekilde tanımlanmaktadır:

$$HO_j = f(H_j) = \frac{1}{1 + \exp[-(H_j + \theta_j)]} \quad (2)$$

HO_j çıktısı bir sonraki birimin girdisi olmaktadır. Çıktı nöronlarına ulaşan girdi aşağıdaki şekilde bulunmaktadır:

$$IO_n = \sum_{j=1}^h w_{jn} HO_j \quad n=1, \dots, m \quad (3)$$

Bu girdi değerleri daha önce tanımlanan sigmoid fonksiyonu tarafından işlenerek sinir ağı çıktı değerleri elde edilmektedir. Daha son-

raki ağırlık düzenlemesi ya da öğrenme süreci geriye doğru ilerleme algoritması ile sağlanmaktadır. Çıktı değerleri ile hedef değerleri aynı olmayacaktır. Çıktı değerler ile hedef değerler arasında ortalama karesel hata hesaplanır. Geriye doğru ilerleme algoritmasının amacı ortalama kare hatasının iterasyonla en aza indirilmesidir. Bu amaçla ortalama karesel hata yardımıyla hesaplanan hata gradyanları, girdi ağırlıklarına eşit şekilde dağıtılarak girdi ağırlıkları güncellenir ve süreç tekrar başlatılır. Ortalama kare hatasının en aza indirilmesine kadar ya da belirli bir iterasyon sayısında bu işlemler tekrarlanır (Cıgızoğlu, 2004b).

Radyal Tabanlı Yapay Sinir Ağları (RTYSA)

Radyal Tabanlı Fonksiyonlar kavramı yapay sinir ağları literatürüne Broomhead ve Lowe tarafından 1988 yılında sokuldu. Radyal Tabanlı Fonksiyonlara dayalı yapay sinir ağları modeli insan sinir sistemindeki nöronlarda (sinir hücreleri) görülen yerel etki-tepki davranışlarından esinlenilerek oluşturulmuştur. (Poggio ve Girosi, 1990).

Radyal Tabanlı Fonksiyonların teorisi çok değişkenli fonksiyonların enterpolasyonuna dayanmaktadır. Burada amaç $(x^s, y^s)_{s=1}^N$ ifadelerinin enterpolasyonunu yapmaktır. Bu durumda $x^s \in \mathcal{R}^d$ olmalıdır. Bu denklemde F lineer uzayda bir fonksiyon olduğundan yani doğrusal bir fonksiyon olduğundan Radyal Tabanlı Fonksiyonlar yaklaşımında F enterpolasyon fonksiyonu temel bazı fonksiyonların lineer bir kombinasyonudur.

$$F(x) = \sum_{s=1}^N w_s \phi(\|x - x^s\|) + p(x) \quad (4)$$

Bu denklemde $\|\cdot\|$ öklid normu, w_1, \dots, w_N reel sayılar, ϕ gerçek değişkenli bir fonksiyon, $p \in \prod_n^d$ ise en fazla n . derecede olabilen d sayıda değişkeni olan bir polinomdur. Bu enterpolasyon probleminde amaç w_1, \dots, w_N değişkenlerini bulmak ve $p = \sum_{l=1}^D a_l p_j$ polinom

terimini elde etmektir. Bu polinomda \prod_n^d a standart temel ve a_1, \dots, a_D sayıları da reel katsayılarıdır. Enterpolasyon şartları şunlardır:

$$F(x^s) = y^s, \quad s = 1, \dots, N \quad (5)$$

$$\sum_{s=1}^N w_s p_j(x^s) = 0, \quad j = 1, \dots, D \quad (6)$$

Eğer veri noktalarından herhangi birisi için enterpolasyon problemi tek çözümlü ise ϕ fonksiyonu Radyal Tabanlı Fonksiyon olarak tanımlanır. Bu durumlarda denklem (4)'deki polinomun terimleri ihmal edilebilir ve denklem (5) deki terimler ile toplandığında aşağıdaki denklem (7) meydana gelir.

$$\phi w = y \quad (7)$$

Bu denklemde $w = (w_1, \dots, w_N)$, $y = (y_1, \dots, y_N)$, ve ϕ de $N \times N$ bir matristir. Bu matris şöyle tanımlanabilir:

$$\phi = \left(\phi(\|x^k - x^s\|) \right)_{k,s=1, \dots, N} \quad (8)$$

En popüler ve en çok kullanılan Radyal Tabanlı Fonksiyonlar Gauss tabanlı fonksiyonlardır. Bunlar şöyle ifade edilir.

$$\phi(\|x - c\|) = e^{-\|x-c\|/2\sigma^2} \quad (9)$$

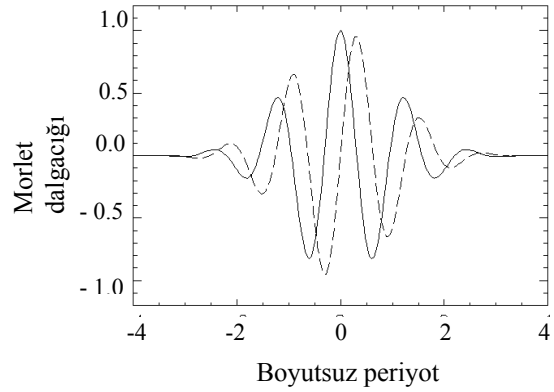
bu fonksiyon $c \in R^d$ merkezinde en yüksek değeri alır ve merkezden uzaklaştıkça değeri küçülür. Radyal Tabanlı Fonksiyonların enterpolasyonunda kesin çözüm her (x^s, y^s) veri noktası için vardır (Cıgızoğlu, 2004b).

Radyal Tabanlı Fonksiyonlar yöntemi üç tabakadan oluşan bir yapay sinir ağları metodudur. Girdi tabakası şebekeye giren verilerin yer aldığı tabakadır. Gizli hücre tabakasında ise nöronlar yer alır. Burada temel fonksiyonların çıktıları hesaplanır. Çıktı tabakasında ise temel fonksiyonlar arasında lineer bir bağıntı veya kombinasyon bulunmaya çalışılır.

Ayrık Dalgacık Dönüşümü (ADD)

Dalgacık (Wavelet) dalganın küçük bir parçası olarak tanımlanabilir. Bu anlamda dalgacık, süresi sınırlı bir titreşim işaretidir (Daubechies, 1996). Şekilde dalgacık olarak adlandırılan ve dalgacık dönüşümünde kullanılan Morlet dalgacık tipi görülmektedir.

Dalgacık analizinde en çok kullanılan ana dalgacıklar Morlet (Şekil 1), Haar, Meksika şapka tipi, Daubechies dalgacıklarıdır. Dalgacıklar, veriyi farklı frekans bileşenlerine ayıran ve sonra kendi ölçekleriyle eşleştirilmiş bir çözünürlüğe sahip bileşenler üzerinde çalışan matematiksel fonksiyonlardır.



Şekil 1 Morlet dalgacığı

Dalgacık katsayılarının ölçek değerinde hesaplanması çok miktarda katsayının oluşmasına ve işlem yüküne neden olduğundan dolayı, katsayıların yalnızca seçilen ölçekler ve zaman diliminde hesaplanması birçok avantaj sağlar. Bu sayede daha az sayıda ancak yine de işaretin frekans-ölçek bilgisinin zaman boyunca değişimini veren katsayılar elde edilmiş olur. Bu katsayılar bir zaman serisi meydana getirirler ve bu zaman serileri çeşitli amaçlar için kullanılabilir.

Ayrık dalgacık dönüşümünde, ikilik ölçek ve zaman adımı kullanılır. Bu şekilde elde edilen her bir bileşen iki ve ikinin katları olacak şekilde ölçek değerlerine ait zaman serilerini ya da dalgacık katsayılarını verirler. Ayrık dalgacık dönüşümü için kullanılan dalgacık fonksiyonu aşağıda verilmiştir.

$$\psi_{m,n}\left(\frac{t-\tau}{s}\right) = s_0^{-m/2} \psi\left(\frac{t-n\tau_0 s_0}{s_0^m}\right) \quad (10)$$

burada m ve n tamsayı olarak dalgacığın sırası ile ölçek ve zaman eksenindeki öteleme parametreleridir. S_0 sabit bir öteleme adımını ifade eder ve bu çalışmada 2 olarak alınmıştır. τ_0 zaman eksenindeki öteleme aralığı değerini verir ve değeri 1 olarak alınmıştır. Bu değerler literatürde en çok kullanılan değerlerine göre alınmıştır. İkinci katları kullanılarak oluşturulan dalgacık fonksiyonu aşağıdaki şekilde tanımlanabilir.

$$\psi_{m,n}(t) = 2^{-m/2} \psi(2^{-m}t - n) \quad (11)$$

Ayrık dalgacık dönüşümünün çok çözünürlüklü analiz (multiresolution analysis, ÇÇA) adlı başka bir şekli daha vardır. Mallat (1989) tarafından önerilen ADD'nin genel çalışma prensibi şöyledir. İşaret ADD yardımıyla bir çeşit filtrelemeden geçirilerek, yaklaşık bileşenine ve detay bileşenine ayrıştırılır. Ardından işlem yaklaşıklık serisinin diğer filtreden geçirilmesiyle devam eder. Her seferinde kalan yaklaşık serisi tekrar, yaklaşık ve detay olmak üzere ayrıştırılabilir. Bileşenlerine ayırma işlemi ardışık tekrar ederek işaret istenilen çözünürlük seviyesinde bileşenlerine ayrılabilir. Sonuçta işaret birçok alt çözünürlük seviyesinde bileşenlerine ayrılmış olur. Bu olaya çok çözünürlüklü analiz adı verilir (Küçük, 2004).

Uygulama

Çalışmada önce, günlük meteorolojik veriler (ortalama sıcaklık, maksimum sıcaklık, minimum sıcaklık, ortalama nem, toplam buharlaşma, toplam yağış) ayrık dalgacık dönüşümü kullanılarak 11 adet detay (2- 4- 8-16-32 – 64 – 128 – 256 – 512 – 1024 - 2048 günlük periyodik bileşenler) ve bir adet yaklaşık bileşenine ayrılmıştır. Mallat (1989) tarafından verilen algoritma yardımıyla orijinal veri (işaret) yaklaşık ve detay bileşenleri (AD) olarak adlandırılan çeşitli serilere ayrılmış olur ve bu serilerin üst üste toplanması ile orijinal veri tekrar elde edilir. Birinci seviyedeki detay bileşeni AD1 olarak adlandırılır ve 2 günlük ölçeğe sahip bileşeni ifade et-

mektedir. Bu bize en yüksek frekanslı değişimleri vermektedir. AD 11 ise en düşük frekansa sahip detay bileşenidir ve 2048 günlük ölçeğe sahiptir.

YSA ile yağış tahmininde istenilen başarılı sonuçların alınması için hangi AD bileşenlerinin seçileceğinin belirlenmesi gerekmektedir. Bu amaçla AD bileşenlerinin her biri ile orijinal yağış arasındaki korelasyonlar hesaplanmıştır. Tablo 4'te İzmir için elde edilen sonuçlar verilmiştir. Tablodan görüleceği gibi sıcaklık, buharlaşma ve nem için AD 8 bileşeni en yüksek korelasyonu göstermektedir. Ortalama sıcaklık için AD8 bileşeni ve orijinal yağış arasındaki korelasyonun değeri -0.221 iken, buharlaşma için korelasyonun değeri -0.181 olarak hesaplanmıştır. Bunun yanında sıcaklık verilerinin AD bileşenleri içerisinde AD 7 ve AD9 bileşenleri de diğer AD bileşenlerinden daha yüksek korelasyon göstermektedir. Yani bu 3 bileşen, AD7, AD8, AD9 (yaklaşık yıllık periyodik bileşenler) burada etkili bileşenler olarak değerlendirilebilir. Buharlaşma için ise AD8 bileşeni için bu değer diğerlerinden önemli derecede yüksek çıkmıştır.

Nem verilerinin AD bileşenleri ile yağış arasındaki korelasyon katsayıları incelenirse, AD8 bileşeni en yüksek korelasyonu göstermektedir. Bunun yanında, AD2, AD3, AD4, AD5, AD6, AD7 bileşenleri de diğerlerinden daha yüksek korelasyon göstermektedir. Bunun yanında Tablo 4'te orijinal yağış verilerinin ADD ile elde edilen AD bileşenlerinin korelasyon katsayılarını göstermektedir. Burada önemli bir nokta vardır. Yağış verilerinin girdileri olarak yağışın AD bileşenlerinin en az bir gün önceki değerleri girdi olarak kullanılabilmesi için, 1 gün önceki AD bileşenleri ile orijinal yağış verileri arasındaki korelasyonlara bakılmalıdır. Buna göre AD3 bileşeni, yani 8 gün ölçekli bileşen en yüksek korelasyonu göstermektedir ($r=0.397$). Bunun yanında AD2, AD4, AD5, AD6, AD7, AD8 bileşenleri de diğerlerinden daha yüksek korelasyon göstermektedir. AD1 bileşeni ise negatif yüksek korelasyon göstermektedir.

Korelasyon tablosundan da faydalanılarak 3 istasyon içinde uygun bileşenler belirlenmiştir.

Tablo 4. İzmir istasyonu için AD bileşenlerinin her birinin ölçülmüş yağış verileri ile olan korelasyon katsayıları

AD bileşenleri	Sıcaklık (ort)	Sıcaklık (maks)	Sıcaklık (min)	Nem	Buharlaştırma	Yağış (önceki gün)
AD 1	-0.078	-0.028	0.012	0.041	-0.018	-0.340
AD 2	-0.030	-0.038	0.075	0.177	-0.030	0.220
AD 3	0.001	-0.033	0.070	0.154	-0.040	0.397
AD 4	-0.002	-0.036	0.038	0.143	-0.048	0.359
AD 5	-0.005	-0.037	0.025	0.116	-0.035	0.276
AD 6	-0.007	-0.041	0.018	0.102	-0.035	0.221
AD 7	-0.144	-0.179	-0.111	0.129	-0.046	0.198
AD 8	-0.221	-0.223	-0.217	0.227	-0.181	0.244
AD 9	-0.117	-0.131	-0.089	0.077	-0.027	0.099
AD 10	-0.025	-0.027	-0.018	0.040	-0.007	0.052
AD 11	-0.014	-0.017	0.003	0.004	0.023	0.026
Yaklaşık	0.021	0.011	0.011	0.025	0.023	0.046

Genel olarak, sıcaklık ve buharlaşma için yaklaşık yıllık bileşenler, nem ve yağış içinse 1 yıldan düşük ölçek seviyesinde bulunan bileşenler seçilmiştir. Buna göre Edirne istasyonunda ortalama ve maksimum sıcaklık için AD2+AD3+AD7, minimum sıcaklık için AD7,

buharlaştırma için AD7+AD8 bileşenleri; Muş ve İzmir içinse sıcaklık ve buharlaşma için AD7+AD8+AD9 bileşenleri seçilmiştir. Yağış ve nem için her 3 istasyonda da aynı bileşenler seçilmiştir. Nem için AD2, AD3, AD4, AD5, AD6 ve AD7, yağış içinse AD2, AD3, AD4, AD5, AD6, AD7 ve AD8 bileşenleri seçilmiştir. Ayrıca yağış bileşenlerinden AD1 ayrı olarak kullanılmıştır.

Daha sonra belirlenen bu bileşenler, YSA yöntemlerinde girdi olarak kullanılarak ölçülmüş yağış verileri tahmin edilmeye çalışılmıştır. 01.01.1987- 31.12.1998 arasında yer alan toplam 4383 veri İBGYSA ve RTYSA modellerinin eğitimi ve son 3 yıla ait 1096 veride (01.01.1999-31.12.2001) kurulan modelin test edilmesi amacıyla kullanılmıştır. Tüm veriler kullanılmadan önce 0.1 ile 0.9 arasında ölçeklendirilmiştir. Çalışmada her istasyon için farklı kombinasyonlardan oluşan YSA modelleri ayrı ayrı denenmiş ve sonuçta o istasyon için en iyi sonucu veren YSA modeli Tablo 5'te gösterilmiştir.

Tablo 5. Dalgacık-YSA yöntemleri ve çoklu lineer regresyon yöntemi (ÇLR) ile yağış tahmini sonuçları

Yöntem	İstasyonlar	Yöntem girdileri	Yöntem yapıları	OKH (mm ²)	R ²
Dalgacık-İBGYSA	Edirne	$S_{maks}, N_{t-1}, N_{t-2}, Y_{t-1}, Y_{t-2}, Y_{t-3}, Y_{t-4}, Y_{t-5}, Y_{t-6}$	(10,5,1)	4.48	0.795
	İzmir	$S_{ort}, S_{maks}, N_{t-1}, N_{t-2}, Y_{t-1}, Y_{t-2}, Y_{t-3}, Y_{t-4}, Y_{t-5}, Y_{t-6}, Y_{t-7}$	(12,5,1)	5.60	0.896
	Muş	$S_{ort}, S_{maks}, S_{min}, B, N_{t-1}, N_{t-2}, Y_{t-1}, Y_{t-2}, Y_{t-3}, Y_{t-4}, Y_{t-5}, Y_{t-6}, Y_{t-7}$	(14,5,1)	6.94	0.787
Dalgacık-RTYSA	Edirne	$S_{ort}, S_{maks}, N_{t-1}, N_{t-2}, B, Y_{t-1}, Y_{t-2}, Y_{t-3}, Y_{t-4}, Y_{t-5}, Y_{t-6}$	(12,1, s=0.75)	8.79	0.601
	İzmir	$S_{ort}, S_{maks}, N_{t-1}, N_{t-2}, Y_{t-1}, Y_{t-2}, Y_{t-3}$	(8,1, s=0.85)	24.74	0.534
	Muş	$S_{ort}, S_{maks}, S_{min}, B, N_{t-1}, N_{t-2}, Y_{t-1}, Y_{t-2}, Y_{t-3}, Y_{t-4}, Y_{t-5}, Y_{t-6}, Y_{t-7}, Y_{(AD1)}$	(15,1, s=0.85)	13.38	0.576
ÇLR	Edirne			18.87	0.133
	İzmir			44.49	0.163
	Muş			22.44	0.291

Tablo 6. İzmir istasyonu yağış verileri için eğitim ve test verileri ile tahmin yöntemleri ile elde edilen sonuçların istatistik karşılaştırmaları

Dalgacık-İBGYSA yöntemi ile İzmir	İzmir için istatistik parametreler		
	μ_x	σ_x	C_{sx}
Eğitim veri	1.86	6.85	5.98
Test veri	1.03	3.98	6.37
D-BGYSA tahmin	1.04	4.01	6.22
D-RTYSA tahmin	0.98	3.35	4.95
ÇLR tahmin	1.80	4.37	0.87

Dalgacık-İBGYSA yöntemi ile İzmir istasyonu için yapılan denemelerde en iyi sonucu 12 girdili (S_{ort} , S_{maks} , N , N_{t-1} , N_{t-2} , Y_{t-1} , Y_{t-2} , Y_{t-3} , Y_{t-4} , Y_{t-5} , Y_{t-6} , Y_{t-7}), ara tabakada 5 hücre ve çıktı tabakasında 1 hücre bulunan model (12, 5,1) vermiştir. Burada t zaman olmak üzere, 2 gün öncesine kadarki nem ve 7 gün öncesine kadarki yağışlar girdi olarak kullanılmıştır. Bu modelin ortalama kare hatası (OKH) 5.60 mm^2 ve belirlilik katsayısı (R^2) ise 0.896 olarak bulunmuştur. Aynı istasyon için, dalgacık-RTYSA yönteminde en iyi sonucu 8 girdili (S_{ort} , S_{maks} , N , N_{t-1} , N_{t-2} , B , Y_{t-1} , Y_{t-2} , Y_{t-3}), model (8,1; $s=0.85$) vermiştir. Bu modelin ortalama kare hatası 24.74 mm^2 ve belirlilik katsayısı ise 0.534 olarak bulunmuştur. Burada s , radyal tabanlı fonksiyonun yayılma parametresidir. Bu istasyonlar için çoklu lineer regresyon analizi (ÇLR) de yaparak sonuçları dalgacık-YSA metotlarının sonuçları ile kıyaslanmıştır (Tablo 5). İzmir istasyonu için ÇLR analizi sonucunda OKH 44.49 mm^2 ve belirlilik katsayısı 0.163 bulunmuştur. Sonuç olarak tüm istasyonlar için dalgacık-İBGYSA ve dalgacık-RTYSA yöntemi karşılaştırma kriterleri açısından ÇLR'den çok daha iyi sonuçlar vermiştir. Performans kriterlerine göre en iyi başarı dalgacık-İBGYSA yönteminde elde edilmiştir. Sonuçlar göstermiştir ki dalgacık dönüşümü ve YSA yönteminin birlikte kullanılması tahmin başarısını oldukça arttırmıştır.

İzmir istasyonunda elde edilen tahmin sonuçlarının eğitim ve test verilerinin dağılımına ne kadar uyduğunu görebilmek amacıyla bazı istatistik parametrelerinin (ortalama, standart sapma

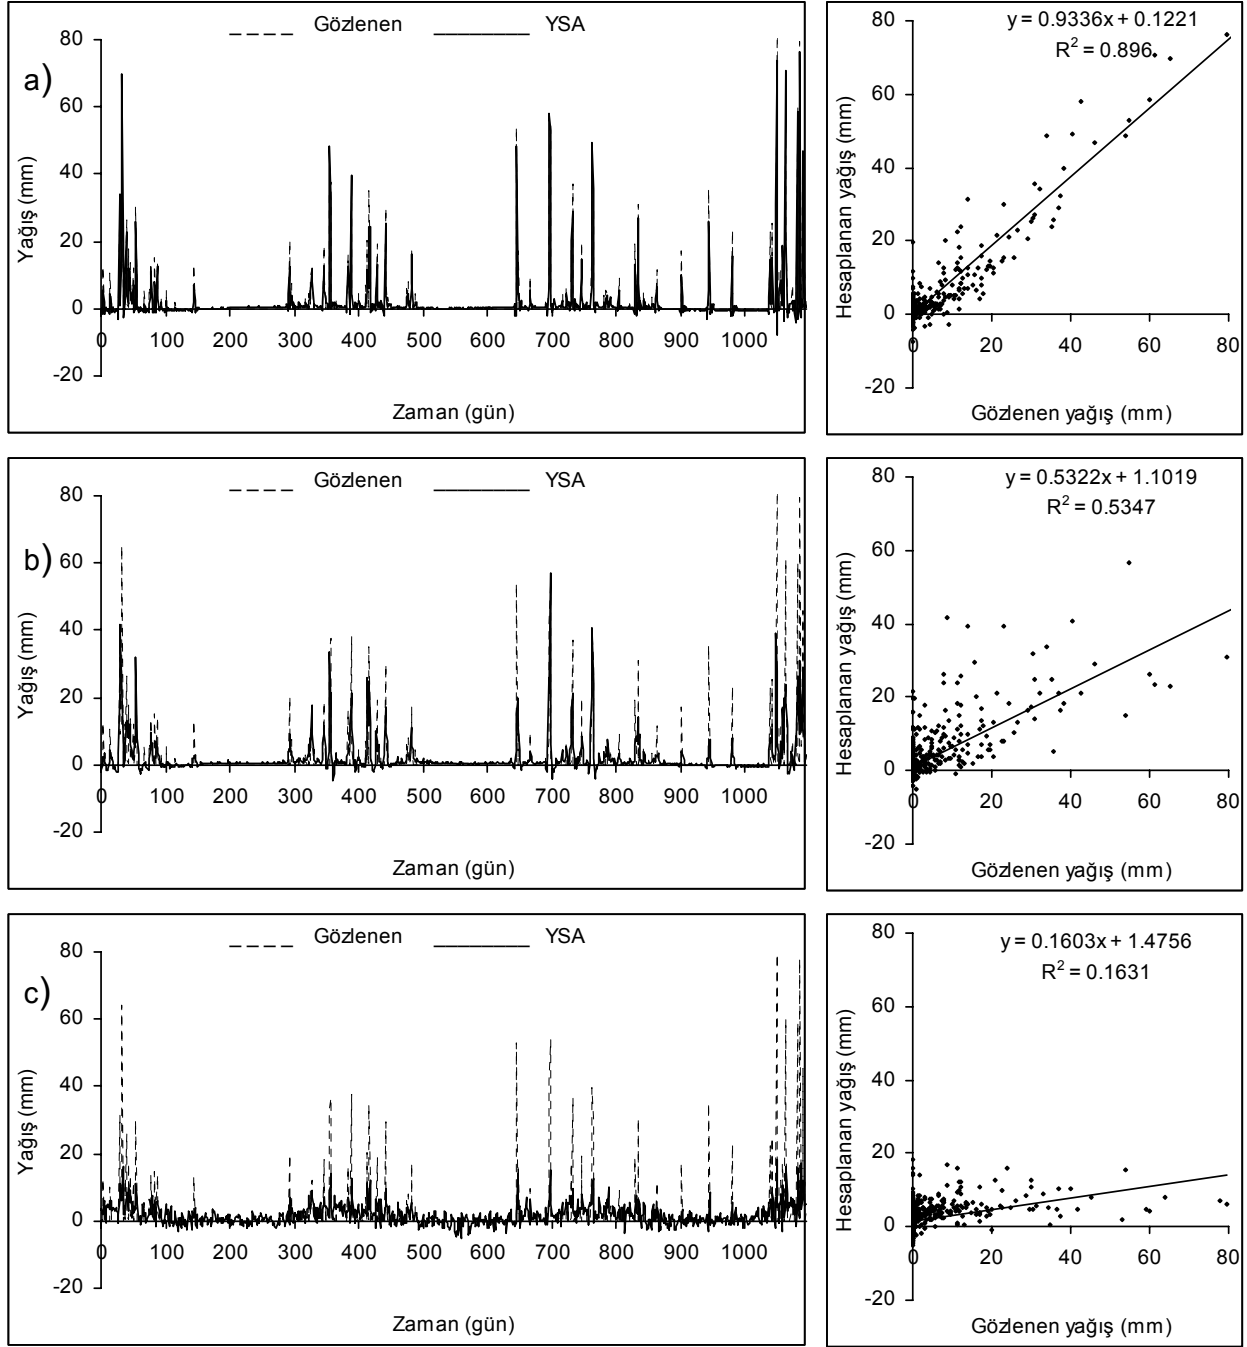
ve çarpıklık katsayısı) karşılaştırılması yapılmıştır. Görüldüğü gibi, İzmir istasyonu yağış verileri için, eğitim verilerinin ortalaması 1.86 mm, standart sapması 6.85 ve çarpıklık katsayısı ise 5.98'dir. Verilerin oldukça çarpık olduğu bulunmuştur. Test verilerinde çarpıklık katsayısı 6.37 bulunmuştur. Tahmin yöntemlerine bakarsak, Dalgacık-İBGYSA (D-İBGYSA) yönteminde elde edilen tahmin verilerinin çarpıklık katsayısının 6.22 olduğu ve eğitim ve test verilerine oldukça yakın olduğu görülmektedir. Yani bu yöntemin verilerin dağılımını da en iyi yakaladığı söylenebilir. Dalgacık-RTYSA için bu değer 4.95, ÇLR için ise 0.87 olarak bulunmuştur. Tablo göstermektedir ki ÇLR yöntemi verilerin ortalamasını iyi yakalamasına rağmen, çarpıklığını yakalayamamıştır ve oldukça düşük çarpıklık katsayısı göstermiştir.

Ayrıca, test aşamasında tahmin edilen yağışlarla gözlenen yağış verilerinin gidişat ve saçılma diyagramları Şekil 2'de İzmir istasyonu için verilmiştir. Bu grafiklere bakıldığında dalgacık-İBGYSA yöntemi ve dalgacık-RTYSA yöntemi tahmin sonuçları ile gözlenen verilerin gidişatlarının çok benzer olduğu görülmektedir.

Özellikle pik yağışların dalgacık-İBGYSA yöntemi tarafından daha başarılı tahmin edildiği görülmektedir. Bu sonuçlar da göstermiştir ki dalgacık-YSA yöntemi ile günlük yağış tahmini başarıyla yapılmıştır. Dalgacık dönüşümü YSA yöntemiyle birlikte tahmin amacıyla başarıyla uygulanabilir.

Sonuçlar

Hidrometeorolojik verilerin tahmini su kaynakları sahasındaki çalışmalar için önemlidir. Yağış tahmini su kaynakları mühendisliği açısından çok önemlidir. Ancak yağış, tahmin edilmesi zor bir değişkendir. Bu çalışmada, tahmin edilmesi zor değişkenlerin modellenmesinde başarılı bir yöntem olan yapay sinir ağları, günlük yağış tahmini için uygulanmış ve başarılı sonuçlar elde edilmiştir. Yöntemin başarısını arttırmak ve yağış tahmininde farklı bir yaklaşım getirmek için dalgacık dönüşümü yapay sinir ağları ile birlikte kullanılmıştır ve çok başarılı sonuçlar alınmıştır.



Şekil 2. İzmir istasyonu yağış verileri için a) dalgacık-İBGYSA, b) dalgacık-RTYSA ve c) ÇLR yöntemlerinin tahmin sonuçları-test aşaması için

Ayrıca, çoklu lineer regresyon yöntemiyle de yağış tahmini yapılarak, sonuçların kıyaslanması amaçlanmıştır.

Çalışmada yağış tahmini yapmak için Türkiye’de 3 farklı bölgeden 3 istasyon seçilmiştir. Tahmin için kullanılmak üzere seçilen veriler ortalama sıcaklık, maksimum sıcaklık, mini-

mum sıcaklık, ortalama nem, toplam buharlaşma ve toplam yağıştır.

Dalgacık dönüşümü kullanılarak YSA yöntemleri ile yağış tahmini yapmak amacıyla, önce meteorolojik veriler ayrı dalgacık dönüşümü kullanılarak periyodik bileşenlerine ayrılmıştır. Her bir bileşen ayrı bir zaman serisidir. Bileşen-

lerden AD8 yaklaşık yıllık bileşendir ve orjinal verinin yaklaşık 1 yıllık periyodik değişimini gösterir. Yağış verilerinin AD1 ve AD2 bileşenleri orijinal veri ile en yakın uyumu gösteren bileşenlerdir. Bu çalışmada hedeflenen en iyi ve doğrulukla yağış tahmini yapmaktır. Bu yüzden verilerin AD bileşenleri ile tahmin edilmesi amaçlanan orijinal yağış verilerinin arasındaki korelasyon katsayılarına bakarak hangi bileşenlerin seçileceğine karar verilmiştir.

Çalışmada her değişken için uygun AD bileşenlerinin toplanması ile elde edilen yeni toplanmış seriler, YSA yönteminde girdi olarak kullanılmıştır. Örneğin, İzmir istasyonunda ortalama sıcaklık verilerinin AD bileşenleri içinden, AD7+AD8+AD9 toplanmış bileşeni elde edilerek girdi olarak kullanılmıştır.

Günlük yağış tahminini, 3 istasyonda günlük meteorolojik verilerin uygun toplanmış AD bileşenlerinin girdi olarak kullanılmasıyla İBGYSA ve RTYSA yöntemleri ile yapılmıştır. Sonuçlarda Dalgacık dönüşümü-YSA yöntemi ile günlük yağış tahmini çok başarıyla yapılmıştır. Performans kriterleri açısından en iyi başarı dalgacık-İBGYSA yönteminde elde edilmiştir. Dalgacık-İBGYSA yönteminde belirlilik katsayısı değerleri genelde 0.70-0.90 aralığında bulunmuştur. Dalgacık-RTYSA yöntemi de ÇLR yönteminden çok daha başarılı sonuçlar göstermiştir. Gözlenen yağış verileri ile Dalgacık-İBGYSA yöntemi ile tahmin edilen değerlerin gidişatlarına bakıldığında oldukça benzer olduğu görülmektedir. Özellikle yaz aylarındaki yağışsız dönem ve günlük yağışların piklerinin Dalgacık-İBGYSA yöntemleri tarafından çok başarılı tahmin edildiği görülmüştür.

Dalgacık analizinin kullanılması ile YSA yöntemi üzerinde uygulayıcının yeteneği ve modelin başarısına olan etkisi arttırılmıştır. YSA gibi yöntemlerle yapılan günlük yağış tahmini çalışmalarında, tahmin yönteminin çıktıları ve gözlenen değerler arasındaki korelasyonun 0.70 civarında olması halinde tahmin yönteminin başarılı olduğu kabul edilmiştir. Bu çalışmada ise, tahmin değerleri ve gözlenen değerler arasındaki korelasyon 0.90 mertebelerine kadar yüksel-

miştir. Dalgacık-YSA gibi modeller, fiziksel hava tahmin modellerinin uygulanmasının zor olduğu ya da mümkün olmadığı durumlar için iyi bir alternatiftir. Bu yüzden YSA gibi kapalı-kutu tahmin modelleriyle fiziksel modellerin birbirini tamamladığı söylenebilir. Sonuç olarak Dalgacık dönüşümü ve YSA yöntemlerinin yağış tahmini için kullanılabilir olduğu ortaya konmuştur.

Kaynaklar

- Applequist, S., Gahrs, G.E., Pfeffer, R.L., (2002). Comparison of methodologies for probabilistic quantitative precipitation forecasting, *American Meteorological Society*, **17**, 783-799.
- Broomhead, D., Lowe, D., (1988). Multivariable functional interpolation and adaptive networks, *Complex Systems*, **2**, 6, 568-576.
- Campolo, M., Andreussi, P., Soldati, A., (1999). River flood forecasting with a neural network model, *Water Resources Research*, **35**, 4, 1191-1197.
- Cigizoglu, H.K., (2003a). Incorporation of ARMA models into flow forecasting by artificial neural networks, *Environmentrics*, **14**, 4, 417-427.
- Cigizoglu, H.K., (2003b). Estimation, forecasting and extrapolation of flow data by artificial neural networks, *Hydrological Sciences Journal*, **48**, 3, 349-361.
- Cigizoglu, H.K., (2004a). Estimation and forecasting of daily suspended sediment data by multi layer perceptrons, *Advances in Water Resources*, **27**, 185-195.
- Cığızoğlu, H.K., (2004b). Yapay sinir ağları ve zaman serileri analizinde kullanımı, *IV. Ulusal Hidroloji Kongresi*, İstanbul Teknik Üniversitesi, İnşaat Fakültesi. 21-25 Haziran 2004.
- Cigizoglu, H.K., Alp, M., (2004). Rainfall-Runoff modelling using three Neural Network methods, *Artificial Intelligence and Soft Computing-ICAISC 2004 Lecture Notes in Artificial Intelligence*, 3070, 166-171.
- Cigizoglu, H.K., Kisi, O., (2005). Flow Prediction by three Back Propagation Techniques using k-fold Partitioning of Neural Network Training Data., *Nordic Hydrology*, **36**, 1, 1-16.
- Cigizoglu, H.K., Alp, M., (2006). Generalized Regression Neural Network in modeling river sediment yield, *Advances in Engineering Software*, **37**, 2, 63-68.
- Daubechies, I., (1996). Where do wavelets come from?- A personal point of view, *Proceedings of the IEEE*, **84**, 4.

- Freiwan M., Cigizoglu H.K., (2005). Prediction of total monthly rainfall in Jordan using feed forward backpropagation method, *Fresenius Environmental Bulletin*, **14**, 2, 142-151.
- Hall, T., (1999). Precipitation forecasting using a neural network, *Weather Forecasting*, **14**, 338-345.
- Hsu, K., Gupta, H.V. Sorooshian, S., (1995). Artificial neural network modelling of the rainfall runoff process, *Water Resources Research*, **31**, 2517-2530.
- Kim, T.W., Valdes J.B. (2003). Nonlinear model for drought forecasting based on a conjunction of wavelet transforms and neural Networks, *Journal of Hydrologic Engineering, ASCE*, **6**, 319.
- Küçük, M., (2004). Dalgacık dönüşüm tekniği kullanılarak akım serilerinin modellenmesi. Doktora tezi, İTÜ Fen Bilimleri Enstitüsü.
- Kulligowski, R.J., Barros A.P., (1998). Localized precipitation from a numerical weather prediction model using Artificial Neural Networks, *Weather and Forecasting*, **13**, 1195-1205.
- Maier, H.R., Dandy, G.C., (2000). Neural networks for the prediction and forecasting of water resources variables: a review of modeling issues and applications, *Environmental Modeling and Software*, **15**, 101-124.
- Mallat, S., G., (1989). A theory for multiresolution signal decomposition: The wavelet representation, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, **11**, 7, 674-693.
- Poggio, T. Girosi, F., (1990). Regularization algorithms for learning that are equivalent to multilayer networks, *Science*, 2247, 978-982.
- Ramirez, M.C.V., Velho, H.F.C., Ferreira, N.J., (2005). Artificial neural network technique for rainfall forecasting applied to the Sao Paulo region, *Journal of Hydrology*, **301**, 146-162.
- Rajurkar, M. P., Kothiyari, U. C. Chaube, U. C. (2002). Artificial neural networks for daily rainfall-runoff modeling, *Hydrological Science Journal*, **47**, 6, 865-877.
- Sudheer, K.P, Gosain, A.K., Ramasastri, K.S., (2002). A data-driven algorithm for constructing artificial neural network rainfall-runoff models, *Hydrological Processes*, **16**, 1325-1330.
- Wang, D., Ding, J., (2003). Wavelet network model and its application to the prediction of hydrology, *Nature and Science*, **1**, 67-71.