

	<p>Tarım Bilimleri Dergisi Tar. Bil. Der.</p> <p>Dergi web sayfası: www.agri.ankara.edu.tr/dergi</p>	<p>Journal of Agricultural Sciences</p> <p>Journal homepage: www.agri.ankara.edu.tr/journal</p>
---	--	---

## Dalgacık-Sinir Ağı Yaklaşımı ile Yağış-Akış Tahmini: Kızılırmak Nehri Örneği

Özlem TERZİ<sup>a</sup>, Melike BARAK<sup>a</sup>

<sup>a</sup> Süleyman Demirel Üniversitesi, Teknoloji Fakültesi, İnşaat Mühendisliği Bölümü, Isparta, TURKEY

### ESER BİLGİSİ

Araştırma Makalesi

Sorumlu Yazar: Özlem TERZİ, E-posta: ozlemterzi@sdu.edu.tr, Tel: +90 (246) 211 80 01

Geliş Tarihi: 12 Aralık 2013, Düzeltmelerin Gelişi: 24 Temmuz 2014, Kabul: 20 Ekim 2014

### ÖZET

Su kaynaklarının planlanmasında önemli bir etmen olan akarsu akımlarının tahmini için dalgacık dönüşüm tekniği (D) ve yapay sinir ağları (YSA) yöntemi kullanılarak modeller geliştirilmiştir. Kızılırmak Nehri'nde bulunan Söğütlühan akım istasyonuna ait akım tahmin modelleri geliştirmek için Sivas meteoroloji istasyonuna ait yağış verileri kullanılmıştır. İlk olarak ölçülmüş orijinal yağış serileri kullanılarak YSA modelleri geliştirilmiştir. Daha sonra, ölçülmüş yağış değerleri dalgacık dönüşümü ile alt serilere ayrılmıştır. Yağış alt serileri ile dalgacık-yapay sinir ağı (D-YSA) modelleri geliştirilmiştir. Geliştirilen modeller ölçülmüş değerlerle kıyaslandığında, dalgacık dönüşümü uygulandıktan sonra elde edilen D-YSA modellerinin, orijinal serilerle elde edilen YSA modellerinden daha iyi performans sergilediği görülmüştür.

Anahtar Kelimeler: Yağış; Akım; Dalgacık dönüşümü; Yapay sinir ağları; Kızılırmak nehri

## Rainfall-Runoff Forecasting with Wavelet-Neural Network Approach: A Case Study of Kızılırmak River

### ARTICLE INFO

Research Article

Corresponding Author: Özlem TERZİ, E-mail: ozlemterzi@sdu.edu.tr, Tel: +90 (246) 211 80 01

Received: 12 December 2013, Received in Revised Form: 24 July 2014, Accepted: 20 October 2014

### ABSTRACT

The models have been developed by using the wavelet transform technique (W) and artificial neural networks (ANN) methods for the forecasting of runoff which is an important factor in the planning of water resources. The rainfall data of Sivas meteorological station were used to develop the runoff forecasting models for Söğütlühan runoff station on Kızılırmak River. Firstly, the ANN models were developed by using the measured original rainfall series. Then, the measured rainfall data was decomposed into sub-series by the wavelet transform. The wavelet-artificial neural network (D-ANN) models were developed by using the rainfall sub-series. When the developed models were compared with the measured values, it was shown that the D-ANN models have better performance than the ANN models obtained with the original rainfall series.

Keywords: Rainfall; Runoff; Wavelet transform; Artificial neural networks; Kızılırmak river

## 1. Giriş

Su miktarının ve kalitesinin kontrolü ve suyun kullanımı için yapılan projelerin planlama, tasarım, inşaat ve işletme aşamalarında, ekonomik ve güvenilir çözümlere varabilmek için su ile ilgili verilerin yeterli doğrulukla elde edilmesi zorunludur. Gelecekteki belli bir tarihte görülebilecek akımın tahmini, taşkın kontrolü maksatlı haznelerin işletilmesi, akarsuyun su potansiyelinin belirlenmesi, kurak dönemlerde elektrik üretiminin, şehir suyu ve sulama suyunun dağıtımının ve akarsularda ulaşımın planlanması açısından önem taşır (Bayazit 1998).

Geçmiş yıllarda, hidrolojik değişkenlerin tahmininde kara-kutu modelleri olarak yapay zeka yöntemleri yaygın olarak kullanılmıştır. Özellikle, insan beyninin bilgi işleme tekniğinden esinlenerek geliştirilen doğrusal olmayan hesaplama yaklaşımı olan yapay sinir ağları (YSA), karmaşık hidrolojik sistemleri modellemek için etkili yöntemlerden biri olarak kabul edilmiştir. YSA yöntemi, hidrolojik değişkenlerin tahmininde yaygın olarak kullanılmasına rağmen, kararlı olmayan verilerin tahmininde yeterince hassas ve güvenilir sonuçlar vermeyebilir. Bu sebeple doğrusal olmayan ilişkiler içeren hidrolojik zaman serilerinin tahmininde, YSA'nın performansını artırmak için veri ön işleme tekniklerinin kullanılması ihtiyacı doğmuştur (Okkan 2013). Bu yöntemlerden biri olan dalgacık dönüşümü, yaklaşık 10–15 yıl önce matematikçiler tarafından ortaya atılmış bir sinyal işleme tekniğidir. Tarihsel gelişim yönünden dalgacık dönüşümü yeni kullanılmaya başlanmış bir yöntem olup, temeli Joseph Fourier'e kadar uzanmaktadır. Fourier dönüşümünün tersine, dalgacık dönüşümü ile her bir zaman aralığında sinyalin hem alçak hem de yüksek frekans bileşenlerini hesaplamak mümkündür. Bu yöntemle, frekansı zamanla değişen sistemlerin analizi ve geçici durum analizleri oldukça hassas bir şekilde yapılmaktadır (Coşkun & Çömlekçi 2007). Dalgacık dönüşüm tekniğinin su kaynakları alanında uygulanışı son derece yenidir. Bilinen ilk çalışma 1993 yılında yağış verileri üzerine Kumar & Foufoula-Georgiou (1993) tarafından yapılan çalışmadır. Bu çalışmada, yağış verileri çok bileşenli analiz ile bileşenlerine ayrılıp her

bileşen analiz edilmiştir (Partal 2007). Lafreniere & Sharp (2003), Alberta bölgesindeki bir göle gelen nehir akımlarının analizinde dalgacık dönüşümünü kullanmışlardır. Küçük (2004), çalışmasında dalgacık dönüşüm tekniğini kullanarak hidrolojik akım serilerinin tahminini yapmıştır. İki ayrı istasyona ait akarsu akım serilerine ayrıık dalgacık dönüşümü (ADD) uygulayarak bileşenlerine ayırmış ve sürekli dalgacık dönüşümü ve global spektrum yardımı ile ölçüm serilerini analiz etmiştir. Sonuçta, dalgacık dönüşüm tekniğinin akarsu akım modellerinde başarılı sonuçlar elde ettiğini belirtmiştir. Fay & Ringwood (2007), zaman serileri tahmini için bir dalgacık dönüşümü modeli geliştirmişlerdir. Dalgacık analizi ve YSA kullanımının birleştirilmesiyle oluşturulan dalgacık sinir ağı modelleri ile başarılı tahminler yapan birçok çalışma mevcuttur (Gaucherel 2002; Wang & Ding 2003; Coulibaly & Burn 2004; Antil & Tape 2004; Partal 2007). Kişi (2009), Ergene Nehri'nin akımını tahmin etmek için girdi parametresi olarak önceki günlerin akım değerlerini kullanmış ve dalgacık-YSA (D-YSA) modelleri geliştirmiştir. D-YSA modellerinin YSA modellerine göre daha düşük hata değerlerine sahip olduğunu belirtmiştir. Dalgacık dönüşümü, aynı zamanda otoregresif modelleme (Tantane et al 2005) ve regresyon modelleme (Küçük & Ağralıoğlu 2006; Kişi 2010) ile birleştirilerek de kullanılmıştır. Krishna et al (2011), Malaprabha Nehri'nin günlük akım verilerine ait zaman serileri için dalgacık-YSA modeli geliştirmişlerdir. Bu modeli YSA ve otoregresif modellerle kıyaslamışlardır. D-YSA modelinin, test setinde özellikle pik değerlerin tahmininde daha başarılı olduğunu belirtmişlerdir.

Yukarıda verilen literatür incelendiğinde, ülkemizde YSA ve dalgacık dönüşümünün bir arada kullanıldığı yağış-akış tahmin çalışmasına rastlanmamıştır. Bu çalışmanın amacı, günlük akım tahmini için D-YSA modelinin uygulanabilirliğini araştırmaktır. Bu çalışmanın diğer çalışmalardan farkı özellikle uç değerlerin tahmininde yeterince iyi sonuç üretemeyebilen YSA yönteminin başarısını arttırmak ve farklı bir yaklaşım oluşturmak için dalgacık dönüşümünün YSA üzerinde etkisini

araştırmaktır. Çalışma bölgesi olarak Kızılırmak Nehri üzerindeki Söğütluhan istasyonu ele alınmıştır. D-YSA akım modelleri geliştirmek için yağış verileri alt serilere ayrılmış ve etkili alt seriler belirlenmiştir. Geliştirilen D-YSA modelleri, YSA modelleri ile kıyaslanmıştır.

## 2. Materyal ve Yöntem

### 2.1. Çalışma bölgesi ve veriler

Kızılırmak Nehri, Türkiye topraklarından doğarak yine Türkiye topraklarından denize dökülen en uzun akarsudur. Uzunluğu 1355 km'dir. Nehir, İç Anadolu'nun en doğusundaki Sivas ilinde bulunan Kızıldağ'ın güney yamaçlarından doğar ve yay şeklinde biçimlenerek Karadeniz'e boşalır. Nehir üzerinde Elektrik İşleri Etüt İdaresi (EİE)'ne ait 46 adet akım ölçüm istasyonu mevcuttur. Bu istasyonların 12 tanesi halen aktif olup geriye kalan 34 tanesi ise kapatılmıştır. Çalışmada, Sivas iline 18 km uzaklıkta bulunan ve drenaj alanı 6607.6 km<sup>2</sup> olan Söğütluhan (1535) (36° 52' 32" D - 39° 43' 31" K) akım gözlem istasyonunun 1993-2005 yıllarına ait günlük ortalama akım değerleri ile Devlet Meteoroloji İşleri Genel Müdürlüğü'nden temin edilen Sivas (17090) istasyonunda ölçülmüş olan günlük yağış değerleri kullanılmıştır. Sert bir karasal iklim yapısına sahip olan Sivas'ta kış aylarında bol kar yağışı görülür, yazları sıcak ve kurak, ilkbahar ve sonbahar ayları ise yağmurlu geçer. Akım ve meteoroloji gözlem istasyonlarına ait ortalama ( $x_{ort}$ ), standart sapma ( $S_x$ ), çarpıklık ( $C_{sx}$ ), minimum ( $x_{min}$ ) ve maksimum ( $x_{max}$ ) değerler Çizelge 1'de verilmiştir. Modeli eğitmek için verilerin % 80'i (01.10.1993-08.05.2003) ve geriye

kalan % 20'lik kısmı (09.05.2003-30.09.2005) ise modelin geçerliliğini sorgulamak için kullanılmıştır.

### 2.2. Yapay sinir ağları yöntemi

YSA, insan beynindeki sinir hücrelerinden esinlenerek geliştirilen yapay sinir hücrelerinin değişik bağlantı geometrileri ile birbirlerine bağlanarak meydana gelen karmaşık sistemler olarak tanımlanmaktadır. Bilgi işlem süreçleri olarak nitelendirilebilen YSA, verilen girdilere karşı çıktılar üreten bir kara kutuya benzetilebilir (Kohonen 1988). Bir yapay sinir hücresi, girdiler, ağırlıklar, toplam fonksiyonu, aktivasyon fonksiyonu ve çıktı olmak üzere beş ana kısımdan oluşur. Girdiler, diğer hücrelerden ya da dış ortamlardan hücreye giren bilgilerdir. Ağırlıklar, girdi kümesi veya kendinden önceki bir tabakadaki başka bir işlem elemanının bu işlem elemanı üzerindeki etkisini ifade eden değerlerdir. Toplam fonksiyonu girdiler ve ağırlıkların tamamının bu işlem elemanına etkisini hesaplayan bir fonksiyondur. Bu fonksiyon bir hücreye gelen net girdiyi hesaplar. Hücrede toplanan net girdinin tümü (*net*) Eşitlik 1'e göre elde edilir.

$$net = \sum_{i=1}^n w_{ij} x_i + b \quad (1)$$

Burada;  $x_i$  i. sinir hücresinin girdi değeri;  $w_{ij}$ , ağırlık katsayıları;  $n$ , bir hücreye gelen toplam girdi sayısı;  $b$ , eşik değeri ve  $\Sigma$  toplam fonksiyonudur. Aktivasyon fonksiyonu ise toplam fonksiyonundan elde edilen net girdiyi bir işlemden geçirerek hücre çıktısını belirleyen bir fonksiyondur. Genel olarak, çok tabakalı algılayıcı modelinde aktivasyon fonksiyonu  $f(.)$  olarak sigmoid fonksiyonu kullanılmaktadır. Bu

### Çizelge 1- İstasyonlara ait istatistik bilgiler

Table 1- The statistical values of the stations

İstasyon	Değişken	Veri seti	$x_{ort}$	$S_x$	$C_{sx}$	$x_{min}$	$x_{max}$
Sivas (17090)	Yağış (mm)	Eğitim	1.23	3.36	4.72	0	44.2
		Test	0.96	2.84	5.13	0.00	32.10
Söğütluhan (1535)	Akım (m <sup>3</sup> s <sup>-1</sup> )	Eğitim	32.19	47.21	2.71	2.54	298
		Test	21.47	25.11	1.89	2.98	131.00

fonksiyon kullanılarak hesaplanan sinir hücresinin çıktısı Eşitlik 2'deki gibi gösterilmektedir.

$$y_i = f(\text{net}) = \frac{1}{1 + e^{-\text{net}}} \quad (2)$$

Sinir hücresinden elde edilen çıktı dış dünyaya veya başka bir hücreye gönderilir (Öztemel 2003). YSA bağlantılı olan birçok sinir hücresi içerir. Genel olarak, hücreler üç tabaka halinde ve her tabaka içinde paralel olarak bir araya gelerek ağı ortaya çıkarırlar. Girdilerin uygulandığı tabaka girdi tabakası, çıktının elde edildiği tabaka çıktı tabakasıdır. Bu girdi ve çıktı tabakaları arasında gizli tabakalar bulunmaktadır. Çıktıları doğrudan gözlenemediği için bu şekilde adlandırılan gizli tabakalar bir veya daha fazla olabilir (Kartalopoulos 1996).

Girdi tabakasındaki sinir hücreleri dış dünyadan aldıkları bilgileri gizli tabakalara, gizli tabakalar da, girdi tabakasından gelen bilgileri işleyerek çıktı tabakasına gönderirler. Çıktı tabakasındaki sinir hücreleri, gizli tabakadan gelen bilgileri işleyerek ağın girdi tabakasından sunulan girdi kümesi için üretmesi gereken çıktıyı üretirler. Yapay sinir ağlarında tek tabakalı algılayıcı modelinin çözüm üretilmediği doğrusal olmayan ilişkiler söz konusu olduğunda çok tabakalı algılayıcılara ihtiyaç vardır (Fausett 1994).

Çok tabakalı algılayıcı ağları eğitici öğrenme stratejisine göre çalışır. Ağın öğrenebilmesi için eğitim seti adı verilen ve örneklerden oluşan bir sete ihtiyaç vardır. Bu eğitim seti içinde her örnek için ağın hem girdiler hem de o girdiler için üretmesi gereken çıktılar belirlenmelidir. Kullanılan öğrenme kuralı, eğitim sırasında ağın ürettiği çıktılar ile üretmesi gereken çıktılar arasındaki farkı ağırlıklara dağıtarak bu farkı en aza indirmektedir (Öztemel 2003).

### 2.3. Dalgacık dönüşümü

Dalgacık, dalganın küçük bir parçası olarak tanımlanabildiğinden, süresi sınırlı bir titreşim işaretidir (Partal 2007). Dalgacık analizinde en çok kullanılan ana dalgacıklar Morlet, Haar, Meksika şapka tipi, Daubechies ve Meyer

dalgacıklardır. Dalgacıklar, veriyi farklı frekans bileşenlerine ayıran ve sonra kendi ölçekleriyle eşleştirilmiş bir çözünürlüğe sahip bileşenler üzerinde çalışan matematiksel fonksiyonlardır. Dalgacık algoritmaları, veriyi farklı ölçek veya çözünürlüklerde işler. Geniş bir pencereden bir işarete bakıldığında, büyük özellikleri fark edilirken, küçük bir pencereden bakılırsa, küçük özellikleri fark edilir. Bu özelliği ilginç ve yararlıdır.

#### 2.3.1. Ayrık dalgacık dönüşümü

Dalgacık katsayılarının ölçek değerinde hesaplanması çok miktarda katsayının oluşmasına ve işlem yüküne neden olduğundan, 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 kullanılan ikili ölçek ve zaman adımıdır. Bu şekilde elde edilen her bir bileşen iki ve ikinin katları olacak şekilde ölçek değerlerine ait zaman serilerini ya da dalgacık katsayılarını verirler. ADD için kullanılan dalgacık fonksiyonu Eşitlik 3'de verilmiştir.

$$\Psi_{m,n}\left(\frac{t-\tau}{S}\right) = S_0^{-m/2} \Psi\left(\frac{t-n\tau_0 S_0}{S_0^m}\right) \quad (3)$$

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 çalışma da 2 olarak alınmıştır.  $\tau_0$ , zaman eksenindeki öteleme aralığı değerini verir ve değeri 1 olarak alınmıştır. Bu değerler literatürde en çok kullanılan değerlere göre alınmıştır. İkinci katları kullanılarak oluşturulan dalgacık fonksiyonu Eşitlik 4'deki şekilde tanımlanabilir.

$$\Psi_{m,n}(t) = 2^{-m/2} \Psi(2^{-m}t - n) \quad (4)$$

Bir  $i$  ayrık adımına sahip  $x(t)$  zaman serisi için ADD Eşitlik 5'deki şekilde verilebilir.


$$W_{m,n} = 2^{-m/2} \sum_{i=0}^{N-1} x_i \psi(2^m i - n) \quad (5)$$

Burada;  $W_{m,n}$ ,  $s$ = ölçek ve  $r$ = zaman değerlerine sahip dalgacık dönüşümü katsayılarıdır. Eşitlikte,  $i=1, \dots, N-1$ ; sonlu değerlere sahip bir zaman serisi ve  $N$ ,  $N= 2M$  şeklinde ifade edilen ikinin katı bir tamsayıdır.  $1 < m < M$  olmak üzere  $2m$  ölçeğinde,  $m= M$  olduğu en geniş ölçekte, tüm zaman serisini kaplayacak yalnızca bir tane dalgacık gerekir. Bir sonraki ölçekte ise  $(2M-1)$  iki adet dalgacık tüm zaman aralığını kapsar ve iki adet katsayı üretilmiş olur. Bu işleme  $m= 1$  olana kadar devam edilir. Bu işlemlerden sonra boyutu  $N= 2M$  olan bir ayrık zaman serisini ifade edecek toplam katsayı sayısı  $1+2+4+\dots+2M-1$  adettir. Böylece ADD ile farklı zaman ve ölçeklerdeki bir zaman serisinin değişimi hakkında bilgi edinilir. Mallat (1989) tarafından önerilen ADD'nin genel çalışma prensibi Şekil 1'de gösterilmiştir. İşaretin frekans bileşenlerine ayrılması, yüksek geçirir ve alçak geçirir filtreleme işlemi ile sağlanır.  $x(q)$  orijinal işaret,  $g(q)$  yüksek geçirir ve  $h(q)$  alçak geçirir filtrelerden geçirilerek bileşenlerine ayrıştırılmış olur. Burada  $k$  filtre seviyesidir (Eşitlik 6 ve 7).

$$y_{yüksek}(k) = \sum_n x(q).g(2k - q) \quad (6)$$

$$y_{alçak}(k) = \sum_n x(q).h(2k - q) \quad (7)$$

Detay bileşenlerinin her birisi ayrı bir zaman serisi olup ait olduğu ölçekte orijinal seri hakkında önemli bilgiler içerir. Bu sayede orijinal serinin yapısının gizli özellikleri, detay bileşenler üzerinden incelenebilir. Detay bileşenlerinin bazıları orijinal serinin özelliklerinin büyük kısmını barındırabilir (Partal 2007).



**Şekil 1- İşaretin ADD ile bileşenlerine ayrılıp tekrar oluşturulması (S, orijinal işaret; Y, yaklaşıklık bileşeni; AD, detay bileşeni)**

Figure 1- Signal decomposition by DWT (S, original signal; Y, approximatın component; AD, detailed component)

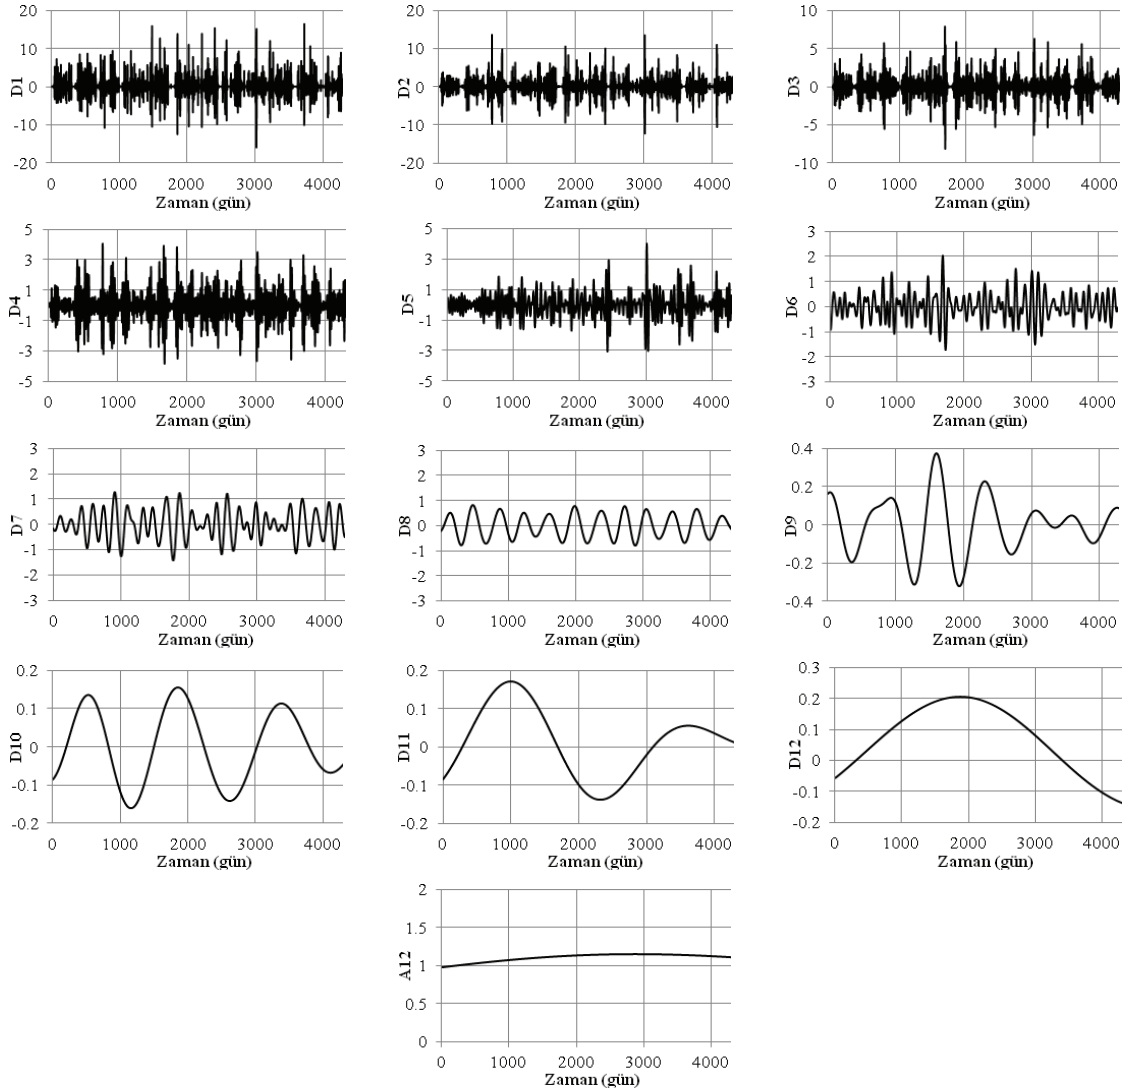
#### 2.4. D-YSA modeli

D-YSA modeli, ADD ve YSA yöntemlerinin uygulanması ile oluşur. D-YSA modeli elde edilebilmesi için ilk olarak, orijinal zaman serisi ADD kullanılarak alt serilere ayrılır. Elde edilen alt serilerin her biri orijinal seri üzerinde farklı davranış gösterir. Daha sonra, elde edilen alt seriler ile model çıktısı arasında korelasyon katsayıları hesaplanır. Korelasyon katsayı değerlerine göre uygun alt seriler belirlenerek D-YSA modelinin girdileri belirlenir.

### 3. Bulgular ve Tartışma

Model performansının belirlenmesinde önemli olan detay bileşeni sayısını, Wang & Ding (2003)  $n$  zaman serisinin uzunluğu olmak şartıyla  $\log(n)$  ile belirlemiştir. Kişi & Partal (2011) akım tahmini için 8 adet, Partal & Kişi (2007) yağış tahmini için 10 adet, Kim & Valdes (2003) kuraklık tahmini için 5 adet ve Krishna et al (2011) akım tahmini için 3 adet detay bileşeni kullanmışlardır. Bu araştırmacıların, verilen zaman serisi için detay bileşeni sayısını belirlemede herhangi bir kural uygulamadığı görülmüştür. Bu çalışmada ise, çeşitli denemelerden sonra, günlük yağış verileri ( $Y_t, Y_{t-1}, Y_{t-2}, Y_{t-3}, Y_{t-4}$ ) ADD kullanılarak 12 adet detay (2-4-8-16-32-64-128-256-512-1024-2048-4096 günlük periyodik bileşenler) ve 1 adet yaklaşıklık bileşenine ayrılmıştır. ADD algoritmalarından, Mallat ayrık dalgacık dönüşümü kullanılarak elde edilen detay ve yaklaşıklık bileşenlerinin toplanmasıyla, orijinal veri tekrar bulunabilir (Mallat 1989). Alt serilerin oluşturulmasında, ayrık dalgacık dönüşüm tekniğinde en çok kullanılan ana dalgacıklardan, Meyer dalgacığının ayrık yaklaşımı (dmey) ve haar kullanılmıştır.  $Y_t$  için, dmey kullanılarak elde edilen 12 adet detay ( $D_{1-12}$ ) bileşeni (2-4-8-16-32-64-128-256-512-1024-2048-4096 günlük ölçek bileşenleri) ve bir adet yaklaşıklık bileşeni (A12) Şekil 2'de verilmiştir.

Dmey dalgacığı kullanılarak elde edilen, günlük yağış ( $Y_t, Y_{t-1}, Y_{t-2}, Y_{t-3}, Y_{t-4}$ ) verilerine ait alt seriler ile orijinal akım serisi arasındaki korelasyon katsayıları hesaplanmış ve Çizelge 2'de



**Şekil 2-** Yt için dmey dalgacığı ile elde edilen alt bileşenler

*Figure 2-* Sub-components obtained by dmey wavelet for  $Y_t$

verilmiştir. Bu korelasyon değerleri, akım değerleri üzerinde etkili olan alt bileşenlerin belirlenmesinde önemlidir. Etkili alt bileşenlerin seçiminde sınır değer olarak literatürde farklı korelasyon değerleri kullanılmıştır. Partal & Kişi (2007) ve Partal (2007) korelasyon değeri 0.2'den büyük alt bileşenleri, Tiwari & Chatterjee (2011) ise 0.1'den, Partal &

Cığızoğlu (2008) yaklaşık olarak 0.3'den ve Shiri & Kişi (2010) ise yaklaşık 0.1'den büyük alt bileşenleri seçmiştir. Bu katsayılar incelendiğinde, D7, D8 ve D9 bileşenlerinin literatürde seçilmiş aralıklarda kaldığı görülmektedir. D1 ve D2 bileşenleri genel olarak diğerlerine göre en düşük korelasyon değerlerine sahiptir. En yüksek korelasyon değerine

sahip olduğu için D7 ve D8 bileşenleri, akım tahmininde D-YSA modelinin girdi parametresi olarak kullanılmak üzere seçilmiştir.

Diğer dalgacık türü olan haar dalgacığı kullanılarak elde edilen korelasyon katsayıları ise Çizelge 3’de verilmiştir. Çizelge 3’den görüldüğü üzere, en yüksek korelasyonlar D7, D8 ve D10 bileşenlerinde elde edildiğinden D-YSA modelinde girdi parametreleri olarak kullanılmıştır

Akım tahmin modelleri geliştirmek için, yağışın önceki periyotlarına bağlı olan beş farklı girdi kombinasyonu değerlendirilmiştir. Bu girdi kombinasyonları, (1)  $Y_t$ , (2)  $Y_t, Y_{t-1}$ , (3)  $Y_t, Y_{t-1}, Y_{t-2}$ , (4)  $Y_t, Y_{t-1}, Y_{t-2}, Y_{t-3}$ , (5)  $Y_t, Y_{t-1}, Y_{t-2}, Y_{t-3}, Y_{t-4}$  şeklindedir. YSA ve D-YSA modellerinin performansını değerlendirmek için, ölçülmüş verilerle model sonuçları arasında karekök ortalama hata (KOH), ortalama mutlak hata (OMH) korelasyon katsayısı (R) ve determinasyon katsayısı ( $R^2$ ) değerleri kullanılmıştır. Çalışmada ilk olarak, orijinal yağış verileri kullanılarak YSA modelleri geliştirilmiştir. YSA modelleri geliştirilirken, en küçük kareler yöntemine dayalı geliştirilmiş

Delta öğrenme kuralı çok tabakalı algılayıcı ağı kullanılmıştır. Genelleştirilmiş Delta kuralı, ağı çıktısını hesaplama safhası olan ileri doğru hesaplama ve ağırlıkları değiştirme safhası olan geriye doğru hesaplama safhalarından oluşmaktadır. Öğrenme algoritması olarak Levenberg-Marquardt yöntemi seçilmiştir. Farklı nöron sayıları ( $i= 1, 2, 3, \dots, 15$ ) denenerek akım olayını en iyi temsil eden gizli tabaka nöron sayıları belirlenmiştir. Geliştirilen bu YSA modellerinin eğitim ve test setlerine ait istatistiksel parametreleri Çizelge 4’de verilmiştir. Günlük akımı tahmin etmek için geliştirilen YSA modellerinden  $Y_t, Y_{t-1}, Y_{t-2}, Y_{t-3}$  ve  $Y_{t-4}$  girdilerini kullanan model en iyi performansı göstermiştir. Burada YSA(5,4,1) model yapısı, girdi tabakasında beş, gizli tabakada dört ve çıktı tabakasında ise bir hücre olduğunu göstermektedir. Geliştirilen modeller incelendiğinde, YSA(3,3,1), YSA(4,6,1) ve YSA(5,4,1) modelleri yakın korelasyon değerleri vermiştir. YSA(1,1,1) modeli en büyük hata değerlerine sahiptir. Girdi parametreleri arttıkça modellerin performanslarının da arttığı görülmüştür. Çalışmanın ikinci aşamasında, ADD’nden dmey ve haar dalgacıkları ile elde edilen

### Çizelge 2- Dalgacık bileşenleri (dmey) ile orijinal akım serileri arasındaki korelasyon katsayıları

Table 2- The correlation coefficients between wavelet components (dmey) and original runoff series

ADD bileşenleri	D1	D2	D3	D4	D5	D6	D7	D8	D9	D10	D11	D12	Yaklaşık
$Y_t$	0.000	0.013	0.054	0.042	0.049	0.085	0.313	0.378	0.163	0.063	0.064	0.115	-0.012
$Y_{t-1}$	0.011	0.048	0.07	0.059	0.053	0.085	0.311	0.387	0.161	0.062	0.013	0.088	0.105
$Y_{t-2}$	-0.007	0.029	0.064	0.072	0.055	0.083	0.309	0.394	0.163	0.061	0.013	0.088	0.105
$Y_{t-3}$	-0.004	-0.014	0.035	0.078	0.056	0.081	0.308	0.401	0.163	0.061	0.014	0.089	0.105
$Y_{t-4}$	0.006	-0.033	-0.002	0.078	0.056	0.078	0.306	0.407	0.162	0.058	0.019	0.093	0.091

### Çizelge 3- Dalgacık bileşenleri (haar) ile orijinal akım serileri arasındaki korelasyon katsayıları

Table 3- The correlation coefficients between wavelet components (haar) and original runoff series

ADD bileşenleri	D1	D2	D3	D4	D5	D6	D7	D8	D9	D10	D11	D12	Yaklaşık
$Y_t$	0.003	0.021	0.049	0.042	0.071	0.135	0.393	0.196	0.043	0.253	0.044	0.137	0.005
$Y_{t-1}$	0.024	0.039	0.068	0.055	0.094	0.116	0.393	0.203	0.164	0.253	0.044	0.137	-0.005
$Y_{t-2}$	0.003	0.037	0.045	0.061	0.109	0.116	0.388	0.201	0.168	0.253	0.043	0.137	-0.005
$Y_{t-3}$	-0.007	0.010	0.032	0.055	0.098	0.116	0.389	0.205	0.169	0.253	0.043	0.137	-0.005
$Y_{t-4}$	-0.002	-0.014	0.012	0.055	0.104	0.105	0.385	0.208	0.165	0.253	0.044	0.137	-0.005

yağış alt serileri girdi parametresi olarak kullanılmış ve D-YSA modelleri geliştirilmiştir. Literatür incelendiğinde Tiwari & Chatterjee (2011), Partal & Küçük (2006), Adamowski & Chan (2011), Partal et al (2008), Kişi (2009) ve Kişi & Partal (2011) çalışmalarında, ADD'nden elde ettikleri alt serileri toplayarak YSA metodunda girdi olarak kullanmışlardır. Wang & Ding (2003) ve Krishna et al (2011) ise, çalışmalarında her bir alt seriyi ayrı girdi parametresi olarak kullanmışlardır. Kişi (2009) çalışmasında alt serilerin tek tek girdi olarak kullanılması durumunda, YSA modelinde girdi sayısı arttıkça, hesaplama süresinin uzamasından dolayı modelin karmaşıklıklaştığını belirtmiştir. Bu çalışmada ise, her iki durum ayrı ayrı değerlendirilmiştir. Bu iki durum ve dalgacık türleri için geliştirilen D-YSA

modellerinin eğitim ve test setlerine ait istatistiksel parametreler Çizelge 5, 6, 7 ve 8'de verilmiştir. Çizelge 5 ve 6'da, dmey dalgacığında elde edilen alt serilerin ayrı ayrı kullanılarak ve toplanarak elde edilen girdiler ile geliştirilen modeller ve Çizelge 7 ve 8'de ise haar dalgacığı kullanılarak geliştirilen D-YSA modelleri sırasıyla verilmiştir. Çizelgeler incelendiğinde, toplanmış yağış alt serilerinin girdi olarak kullanılması ile geliştirilen modeller, genel olarak yağış alt serilerinin ayrı ayrı kullanılması ile geliştirilen modellere göre daha iyi performans göstermişlerdir. Fakat Çizelge 5 ve 6'da dmey ile geliştirilen modeller incelendiğinde, en yüksek R (0.811) ve en düşük OMH (11.350) değerleri, yağış alt serilerinin ayrı ayrı kullanıldığı  $Y_t, Y_{t-1}, Y_{t-2}, Y_{t-3}$  ve  $Y_{t-4}$  girdilerine sahip D-YSA modelinde görülmüştür.

#### Çizelge 4- Orijinal yağış verileri ile geliştirilen YSA modellerine ait parametreler

Table 4- Parameters for the developed ANN models using original rainfall series

İstatistiksel parametreler	Model yapısı	Eğitim seti				Test seti			
		KOH	OMH	R	R <sup>2</sup>	KOH	OMH	R	R <sup>2</sup>
		(m <sup>3</sup> s <sup>-1</sup> )	(m <sup>3</sup> s <sup>-1</sup> )			(m <sup>3</sup> s <sup>-1</sup> )	(m <sup>3</sup> s <sup>-1</sup> )		
$Y_t$	YSA(1,1,1)	49.92	30.03	0.214	0.046	33.46	23.17	0.238	0.057
$Y_t, Y_{t-1}$	YSA(2,9,1)	49.18	29.69	0.269	0.072	32.99	22.87	0.282	0.080
$Y_t, Y_{t-1}, Y_{t-2}$	YSA(3,3,1)	48.63	29.54	0.309	0.096	32.47	22.69	0.328	0.108
$Y_t, Y_{t-1}, Y_{t-2}, Y_{t-3}$	YSA(4,6,1)	47.46	28.93	0.367	0.135	32.59	22.08	0.330	0.109
$Y_t, Y_{t-1}, Y_{t-2}, Y_{t-3}, Y_{t-4}$	YSA(5,4,1)	47.81	29.04	0.353	0.125	32.35	22.01	0.339	0.115

#### Çizelge 5- Yağış alt serilerinin ayrı kullanılması ile geliştirilen D-YSA (dmey) modellerine ait parametreler

Table 5- Parameters for the developed W-ANN (dmey) models using rainfall sub-series separately

İstatistiksel parametreler	Model yapısı	Eğitim seti				Test seti			
		KOH	OMH	R	R <sup>2</sup>	KOH	OMH	R	R <sup>2</sup>
		(m <sup>3</sup> s <sup>-1</sup> )	(m <sup>3</sup> s <sup>-1</sup> )			(m <sup>3</sup> s <sup>-1</sup> )	(m <sup>3</sup> s <sup>-1</sup> )		
$Y_t$ (D <sub>7</sub> ,D <sub>8</sub> )	D-YSA(2,2,1)	42.82	24.93	0.542	0.294	19.848	13.105	0.698	0.487
$Y_t, Y_{t-1}$ (D <sub>7</sub> ,D <sub>8</sub> )	D-YSA(4,7,1)	29.58	15.83	0.814	0.663	28.623	18.054	0.628	0.394
$Y_t, Y_{t-1}, Y_{t-2}$ (D <sub>7</sub> ,D <sub>8</sub> )	D-YSA(6,7,1)	35.04	17.67	0.727	0.529	23.803	15.009	0.546	0.298
$Y_t, Y_{t-1}, Y_{t-2}, Y_{t-3}$ (D <sub>7</sub> ,D <sub>8</sub> )	D-YSA(8,1,1)	43.77	26.31	0.512	0.262	21.877	15.348	0.642	0.412
$Y_t, Y_{t-1}, Y_{t-2}, Y_{t-3}, Y_{t-4}$ (D <sub>7</sub> ,D <sub>8</sub> )	D-YSA(10,10,1)	36.58	20.12	0.696	0.484	16.491	11.350	0.811	0.658



**Çizelge 6- Toplanmış yağış alt serileri ile geliştirilen D-YSA (dmey) modellerine ait parametreler**

Table 6- Parameters for the developed W-ANN (dmey) models using the sum of rainfall sub-series

İstatistiksel parametreler	Model yapısı	Eğitim seti				Test seti			
		KOH ( $m^3 s^{-1}$ )	OMH ( $m^3 s^{-1}$ )	R	R <sup>2</sup>	KOH ( $m^3 s^{-1}$ )	OMH ( $m^3 s^{-1}$ )	R	R <sup>2</sup>
$Y_t$ (D <sub>7</sub> +D <sub>8</sub> +D <sub>9</sub> )	D-YSA(1,1,1)	41.82	25.14	0.576	0.332	18.803	12.882	0.698	0.487
$Y_t, Y_{t-1}$ (D <sub>7</sub> +D <sub>8</sub> +D <sub>9</sub> )	D-YSA(2,8,1)	40.88	24.50	0.597	0.356	18.952	13.219	0.680	0.462
$Y_t, Y_{t-1}, Y_{t-2}$ (D <sub>7</sub> +D <sub>8</sub> )	D-YSA(3,4,1)	39.86	24.92	0.625	0.391	20.504	15.315	0.691	0.478
$Y_t, Y_{t-1}, Y_{t-2}, Y_{t-3}$ (D <sub>7</sub> +D <sub>8</sub> )	D-YSA(4,8,1)	43.10	25.14	0.534	0.285	19.619	13.204	0.678	0.460
$Y_t, Y_{t-1}, Y_{t-2}, Y_{t-3}, Y_{t-4}$ (D <sub>7</sub> +D <sub>8</sub> +D <sub>9</sub> )	D-YSA(5,8,1)	38.79	23.75	0.649	0.421	20.600	14.870	0.655	0.429

Haar dalgacığı ile geliştirilen modellere bakıldığında, en iyi performansa sahip model, D7, D8 ve D10 alt bileşenlerinin toplanması ile elde edilen serinin kullanıldığı  $Y_t, Y_{t-1}, Y_{t-2}$  ve  $Y_{t-3}$  girdilerine sahip olan D-YSA(4,1,1) modelidir (Çizelge 7 ve 8). Bu modelin R değeri 0.680 olarak belirlenmiştir.

Orijinal serilerle elde edilen YSA modellerinde en iyi performansı gösteren YSA(5,4,1) modelinin performansının D-YSA modellerine bakıldığında arttığı görülmüştür. YSA(5,4,1) modelinin R değeri 0.339 iken, dalgacık dönüşümünden sonra D-YSA(10,10,1) modelinin değeri 0.811'e

yükselmiştir. YSA(5,4,1) ve D-YSA(10,10,1) modelleri için test setine ait saçılma diyagramları ve zaman serisi grafikleri Şekil 3 ve 4'de verilmiştir. Şekil 3 ve 4'den görüldüğü üzere, D-YSA(10,10,1) modeli, YSA(5,4,1) modelinden daha az saçılma göstermektedir. YSA(5,4,1) modelinin düşük değerlerin tahmininde başarılı olmadığı, fakat D-YSA(10,10,1) modelinin düşük gözlemleri daha iyi tahmin ettiği görülmüştür. YSA(5,4,1) modeli  $4.48 m^3 s^{-1}$  akım değerini  $20.13 m^3 s^{-1}$  olarak % 349 yukarıda tahmin ederken, aynı değer D-YSA(10,10,1) modeli ile  $4.34 m^3 s^{-1}$  ile % 3 aşağıda tahmin değeri vermiştir.

**Çizelge 7- Yağış alt serilerinin ayrı kullanılması ile geliştirilen D-YSA (haar) modellerine ait parametreler**

Table 7- Parameters for the developed W-ANN (haar) models using rainfall sub-series separately

İstatistiksel parametreler	Model yapısı	Eğitim seti				Test seti			
		KOH ( $m^3 s^{-1}$ )	OMH ( $m^3 s^{-1}$ )	R	R <sup>2</sup>	KOH ( $m^3 s^{-1}$ )	OMH ( $m^3 s^{-1}$ )	R	R <sup>2</sup>
$Y_t$ (D <sub>7</sub> ,D <sub>10</sub> )	D-YSA(2,2,1)	48.21	30.19	0.323	0.104	22.347	15.807	0.466	0.217
$Y_t, Y_{t-1}$ (D <sub>7</sub> ,D <sub>8</sub> ,D <sub>10</sub> )	D-YSA(6,2,1)	29.75	15.77	0.813	0.661	22.715	15.599	0.531	0.282
$Y_t, Y_{t-1}, Y_{t-2}$ (D <sub>7</sub> ,D <sub>8</sub> ,D <sub>10</sub> )	D-YSA(9,1,1)	44.11	25.26	0.505	0.255	22.671	15.671	0.431	0.186
$Y_t, Y_{t-1}, Y_{t-2}, Y_{t-3}$ (D <sub>7</sub> ,D <sub>8</sub> ,D <sub>10</sub> )	D-YSA(12,2,1)	28.57	13.80	0.828	0.686	22.834	17.828	0.635	0.403
$Y_t, Y_{t-1}, Y_{t-2}, Y_{t-3}, Y_{t-4}$ (D <sub>7</sub> ,D <sub>8</sub> ,D <sub>10</sub> )	D-YSA(15,4,1)	48.38	30.68	0.314	0.099	19.525	14.796	0.665	0.442

**Çizelge 8- Toplanmış yağış alt serileri ile geliştirilen D-YSA (haar) modellerine ait parametreler**

Table 8- Parameters for the developed W-ANN (haar) models using the sum of rainfall sub-series

İstatistiksel parametreler	Model yapısı	Eğitim seti				Test seti			
		KOH ( $m^3 s^{-1}$ )	OMH ( $m^3 s^{-1}$ )	R	R <sup>2</sup>	KOH ( $m^3 s^{-1}$ )	OMH ( $m^3 s^{-1}$ )	R	R <sup>2</sup>
$Y_t$ ( $D_7+D_8+D_{10}$ )	D-YSA(1,5,1)	31.43	17.59	0.787	0.619	24.470	16.960	0.498	0.248
$Y_t, Y_{t-1}$ ( $D_7+D_{10}$ )	D-YSA(2,2,1)	45.75	28.47	0.440	0.194	24.845	17.112	0.554	0.307
$Y_t, Y_{t-1}, Y_{t-2}$ ( $D_7+D_8+D_{10}$ )	D-YSA(3,1,1)	39.51	23.37	0.631	0.398	21.971	15.592	0.490	0.240
$Y_t, Y_{t-1}, Y_{t-2}, Y_{t-3}$ ( $D_7+D_8+D_{10}$ )	D-YSA(4,1,1)	38.64	21.20	0.652	0.425	22.713	16.030	0.680	0.462
$Y_t, Y_{t-1}, Y_{t-2}, Y_{t-3}, Y_{t-4}$ ( $D_7+D_8+D_{10}$ )	D-YSA(5,2,1)	47.67	29.19	0.354	0.125	25.196	19.053	0.458	0.210

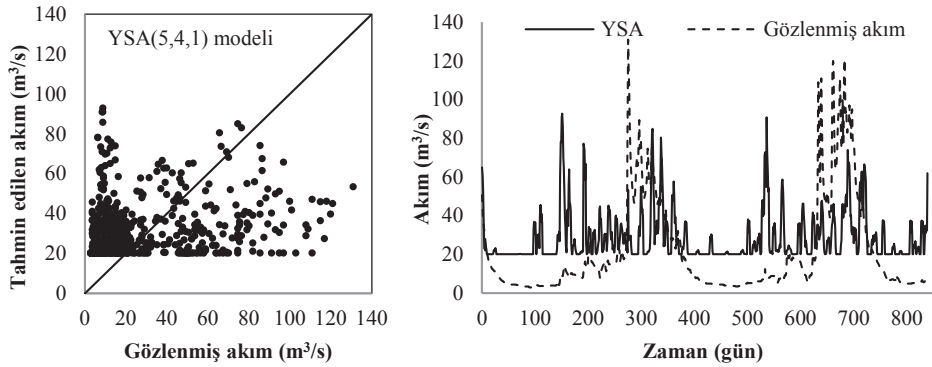
**Şekil 3- YSA(5,4,1) modeline ait saçılma diyagramı ve zaman serisi**

Figure 3- Scatter plot and time series for ANN(5,4,1) model


**Şekil 4- D-YSA(10,10,1) modeline ait saçılma diyagramı ve zaman serisi**

Figure 4- Scatter plot and time series for W-ANN(10,10,1) model

#### 4. Sonuçlar

Bu çalışmada, Kızılırmak Nehri'nde bulunan Söğütluhan istasyonunun akım tahmini için YSA ve D-YSA modelleri geliştirilmiştir. D-YSA modeli geliştirmek için, ölçülmüş yağış değerleri ( $Y_t, Y_{t-1}, Y_{t-2}, Y_{t-3}, Y_{t-4}$ ) haar ve dmev dalgacıkları ile 12 adet detay ve bir yaklaşıklık bileşenine ayrılmıştır. Alt bileşenler ile ölçülmüş akım değerleri arasındaki korelasyon ilişkileri incelendikten sonra, yağış üzerinde etkili olan alt bileşenlerin ayrı ayrı ve toplanıp girdi olarak kullanılması ile çeşitli D-YSA modelleri geliştirilmiştir. Bu modeller içerisinde toplanmış seriler ile elde edilen D-YSA modellerinin, genel olarak alt serilerin ayrı ayrı kullanılması ile elde edilen modellere göre daha iyi sonuçlar verdiği görülmüştür. Dalgacık türlerinden dmev dalgacığı ile geliştirilen modellerde, haar dalgacığına göre daha başarılı sonuçlar elde edilmiştir. Geliştirilen D-YSA modelleri ele alındığında ise, dmev dalgacığı kullanılarak ve alt serilerin toplanmadan değerlendirildiği  $Y_t, Y_{t-1}, Y_{t-2}, Y_{t-3}, Y_{t-4}$  girdili D-YSA(10,10,1) modelinin en iyi sonucu verdiği ve tüm D-YSA modellerinin sonuçlarının YSA model sonuçlarına göre daha iyi olduğu görülmüştür. Sonuç olarak, dalgacık dönüşümü tekniğinin YSA yönteminin performansını arttırdığı ve dalgacık-sinir ağı yönteminin akım tahmininde kullanılabilir olduğu ortaya koyulmuştur.

#### Kaynaklar

Adamowski J & Chan H F (2011). A wavelet neural network conjunction model for groundwater level forecasting. *Journal of Hydrology* **407**: 28-40

Antcil F & Tape D G (2004). An exploration of artificial neural network rainfall runoff forecasting combined with wavelet decomposition. *Journal of Environmental Engineering and Science* **3**: 121-129

Bayazit M (1998). Hidrolojik Modeller. İTÜ İnşaat Fakültesi Matbaası, İstanbul

Coulbaly P & Burn D H (2004). Wavelet analysis of variability in annual Canadian Streamflows. *Water Resources Research* **47**: 1-14

Coşkun Ö & Çömlekçi S (2007). Wavelet teorisinin medikal alana uygulanması üzerine bir ön çalışma. *Akademik Bilişim '07 - IX. Akademik Bilişim*

*Konferansı*, 31 Ocak - 2 Şubat 2007, Dumlupınar Üniversitesi, Kütahya, s. 317-320

Fausett L (1994). Fundamentals of neural networks: Architectures, algorithms, and applications. Prentice Hall, New Jersey

Fay D & Ringwood J V (2007). A wavelet transfer model for time-series forecasting. *International Journal of Bifurcation and Chaos* **17**(10): 3691-3696

Gauchere C (2002). Use of wavelet transform for temporal characterisation of remote watersheds. *Journal of Hydrology* **269**: 101-121

Kartalopoulos S V (1996). Understanding neural networks and fuzzy logic: basic concepts and applications. IEEE Press, New York

Kim T & Valdes J B (2003). Nonlinear model for drought forecasting based on a conjunction of wavelet transforms and neural networks. *Journal of Hydrologic Engineering* **8**(6): 319-328

Kişi Ö (2009). Neural network and wavelet conjunction model for intermittent streamflow forecasting. *Journal of Hydrologic Engineering* **14**(8): 773-782

Kişi Ö (2010). Wavelet regression model for short-term streamflow forecasting. *Journal of Hydrology* **389**(3-4): 344-353

Kişi Ö & Partal T (2011). Wavelet and neuro-fuzzy conjunction model for streamflow forecasting. *Hydrology Research* **42**(6): 447-456

Kohonen T (1988). An introduction to neural computing. *Neural Networks*, **1**: 3-6

Krishna B, Satyaji Rao Y R & Nayak P C (2011). Time series modeling of river flow using wavelet neural networks. *Journal of Water Resource and Protection* **3**: 50-59

Kumar P & Foufoula-Georgiou E (1993). A multicomponent decomposition of spatial rainfall fields 2. Self-similarity in fluctuations. *Water Resources Research* **29**(8): 2533-2544

Küçük M (2004). Dalgacık dönüşüm tekniği kullanarak akım serilerinin modellenmesi. Doktora Tezi, İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü, İstanbul

Küçük M & Ağralıoğlu N (2006). Dalgacık dönüşüm tekniği kullanılarak hidrolojik akım serilerinin modellenmesi. İstanbul Teknik Üniversitesi *Dergisi-Mühendislik* **5**(2): 69-80

Lafreniere M & Sharp M (2003). Wavelet analysis of inter-annual variability in the runoff regimes of

- Glacial and Nival Stream Catchments, Bow Lake, Alberta. *Hydrological Processes* **17**: 1093–1118
- 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
- Okkan U (2013). Wavelet neural network model for reservoir inflow prediction. *Scientia Iranica* **19**(6): 1445-1455
- Öztemel E (2003). Yapay sinir ağları. Papatya Yayıncılık, İstanbul
- Partal T (2007). Türkiye yağış miktarlarının yapay sinir ağları ve dalgacık dönüşümü yöntemleri ile tahmini. Doktora tezi, İTÜ Fen Bilimleri Enstitüsü, İstanbul
- Partal T & Küçük M (2006). Long-term trend analysis using discrete wavelet components of annual precipitations measurements in Marmara Region (Turkey). *Physical Chemistry Earth* **31**: 1189-1200
- Partal T & Kişi Ö (2007). Wavelet and neuro-fuzzy conjunction model for precipitation forecasting. *Journal of Hydrology* **342**: 199-212
- Partal T & Cıgızoğlu H K (2008). Estimation and forecasting of daily suspended sediment data using wavelet-neural networks. *Journal of Hydrology* **358**: 317-331
- Partal T, Kahya E & Cıgızoğlu K (2008). Yağış verilerinin yapay sinir ağları ve dalgacık dönüşümü yöntemleri ile tahmini. İstanbul Teknik Üniversitesi Dergisi-Mühendislik **7**(3): 73-85
- Tantane S, Patamatammakul S, Oki T, Sriboonlue V & Prempre T (2005). Coupled wavelet-autoregressive model for annual rainfall prediction. *Journal of Environmental Hydrology* **13**(18): 1-8
- Tiwari M K & Chatterjee C (2011). A new wavelet-bootstrap-ANN hybrid model for daily discharge forecasting. *Journal of Hydroinformatics* **13**(3): 500-519
- Wang W & Ding J (2003). Wavelet network model and its application to the prediction of hydrology. *Nature and Science* **1**(1): 67-71