

# Günlük akımların tahmini açısından çok tabakalı perseptron ve dalgacık-çok tabakalı perseptron modellerinin performans karşılaştırması

Abdüsselam ALTUNKAYNAK<sup>1</sup> ve Tewodros Assefa NIGUSSIE<sup>2</sup>

<sup>1,2</sup>Istanbul Teknik Üniversitesi, İnşaat Mühendisliği Fakültesi, Hidrolik ve Su Kaynakları Mühendisliği Bölümü, Maslak 34469, İstanbul, Türkiye.

Makale Gönderme Tarihi: 08.10.2015

Makale Kabul Tarihi: 15.06.2016

## Öz

Akarsu akımlarının doğru tahmini su kaynaklarını sürekli ve iyi bir şekilde işletmek için önemlidir. Modellerde ölçülen ham verilerin doğrudan kullanımı, tahmin yanlışlıklarına neden olmaktadır. Modellerin tahmin performansını artırmak için ölçülen verileri spektral bantlara ayırarak, trendleri ve periyodikliği ortadan kaldırmak için Ayrık Dalgacık Dönüşüm (ADD) yaklaşımı kullanılmıştır. Literatürde yapılan çalışmaların birçoğunda günlük akım tahminleri kısa süreli yapılmıştır. Bu çalışmada ADD kullanılarak orjinal veriler bileşenlerine ayrılarak model geliştirilmiştir. Bu çalışmanın amacı günlük akım gözlem verilerini doğru ve uzun süreli tahmin edebilen bir model geliştirmektir. Bu çalışma da, oniki (12) yıllık 02231000 nolu istasyona ait günlük akım gözlem verileri kullanılmıştır. Bunlardan, 7 yılı eğitim verisi geri kalan 5 yıl da tahmin verisi olarak kullanılmıştır. ADD yaklaşımı tarafından ayrıştırılan veriler, 7 güne kadar günlük akımları tahmin etmek için Çok Tabakalı Perseptron (ÇTP) modeline girdi olarak kullanılmıştır. Bu çalışmada ÇTP ve D-ÇTP modellerinin tahmin performansları Hataların karelerinin ortalamalarının karekökü (HKOK), verim katsayısı (VK) ve beceri puanı (BP) parametreleri dikkate alınarak karşılaştırılmıştır. D-ÇTP modellerinin ÇTP modelinden daha iyi tahmin sonuçları ürettiği gözlemlenmiştir.

**Anahtar Kelimeler:** Akım; Ayrık Dalgacık Dönüşümü; Çok Tabakalı Perseptron; Tahmin

<sup>1</sup>Yazışmaların yapılacağı yazar: Abdüsselam Altunkaynak ve Tewodros Assefa Nigussiealtunkay@itu.edu.tr1 ve hiyawtewodros@gmail.com2

## Giriş

Su kaynaklarının uygun yönetimi hidrolojik döngü bileşenlerinin güvenilir bir şekilde tahminlerini gerektirir. En önemli bileşenlerden biri olarak akarsu akımının zamansal ve mekânsal tahminine ihtiyaç vardır. Akarsu akım tahmini; su yapısının planlanması, dizaynı, işletilmesi ve bakımı için kullanılmasının yanında, taşkın uyarı sistemlerinde, taşkın kontrol rezervuarlarının işletilmesinde, akarsu potansiyelinin belirtilmesinde, hidroelektrik enerji üretiminde, kuraklık zamanında evsel ve tarımsal suların dağıtımının yapılmasında kullanılır (Altunkaynak, 2009). Mevsimsel akarsu akım tahmini; ekonomi yönetimi, taşkın önlenmesi ve su kaynakları sistemlerinin çevresel değerlendirilmesi noktasında karar vermek için önemlidir (Shalamu et al., 2010).

Akarsu akımlarının kısa ve uzun periyotlu tahminleri birçok sebepten dolayı su kaynakları yönetiminin önemli bileşenlerindedir. Su kaynakları sistemlerinin optimizasyonu ve gelecekteki su miktarının azalması ve artması durumlarına göre sürdürülebilir planlama yapılması bunlardan birkaçıdır (Adamowski ve Su, 2010).

Viola (2014) yarı-kurak alanlarda, günlük akarsu akımının simüle edilmesi amacıyla kavramsal birleşik bir model önermiştir. Geliştirilen modelin günlük akım verileri doğruluk payı yüksek sonuçlar vermiştir. Bununla birlikte; yağış miktarı, buharlaşma, terleme ve zemin neminin dinamiklerini etkileyen sızma, farklı karakterde etkilenme süresine sahip birbirine paralel çalışan iki doğrusal su haznesi gibi soil bucket bileşenleri bu numerik model için anahtar veriler olarak gerekmektedir. Akarsu akımının tahmini için istatistiksel modeller sıkça kullanılmaktadır. Çoklu doğrusal regresyon (MLR) ve otoregresif hareketli ortalama (ARMA) modelleri muhtemel taşkınları öngörmek için kullanılan en yaygın yöntemlerdir (Adamowski 2008). Akarsu akımlarının tahmini için başka bir takım çalışmalar da mevcuttur. Her ne kadar Kişi (2005)'ye göre yağış, akış, sıcaklık ve buharlaşma gibi hidrolojik ve

hidrometeorolojik değişkenleri de göz önüne alan kapsamlı modeller tanımlanması mümkün olsa da; yönetici, yerel idare amiri, teknik operatörler gibi karar mercilerinin de geçmiş kayıtlara ulaşabileceği geçmiş akım debileri kayıtlarını temel olarak akım çeşitliliklerini simüle eden modeller ekonomik olarak tercih sebebidir.

Anmala et al. (2000) aylık yağış ve sıcaklık verilerini kullanarak yapay sinir ağlarının (YSA) performanslarını, Kansas'taki üç havza üzerinde aylık akım ortalamalarının tahmini için kullanılan ampirik yaklaşımlarla karşılaştırarak test etmiştir. Birçok araştırmacıda akarsu akım tahmini için sadece değişik ölçüm ve bir ile on iki arasında değişen ileri (gelecek) zamanları içeren drenaj alanları girdileri gibi sadece geçmiş akım verilerinden yapay sinir ağları yaklaşımı kullanarak akım tahminleri yapmıştır. İleri zaman dilimi, bu çalışmada, tahmin edilen akım ile bu akımın gerçekleşmesi arasındaki zaman dilimidir.

Bravo et al. (2009) uzun ileri zamanlar için kavramsal hidrolojik modellerin yapay sinir ağları (YSA) modellerinden daha iyi tahmin yetenekleri olduğu sonucuna varmıştır. Bununla birlikte Zealand'ın (1999) çalışması, verimlilik katsayısı sonuçları performans kriteri olarak alındığında YSA'nın Winnipeg akış öngörme sisteminden (WIFFS) ve bir yağış akış modeli olan XXT'nin (X Xianjiang'ı, ikinci X Melezi ve T üst model'i (bir topoğrafya bazlı hidrolojik model temsil eder) daha iyi sonuçlar verdiğini göstermiştir. Fakat YSA'nın hareketsiz olmayan veriler noktasında bazı sınırlamaları mevcuttur (Adamowski 2008). Zealand (1999)' a göre YSA'nın ÇTP yaklaşımı, öğrenilebilir bir fonksiyon olmadığından veya veri seti boyut olarak yetersiz kaldığından tatmin edici bir sonuç vermeyebilir. İlaveten optimum ağ geometrisi ve optimum dahili ağ parametreleri sorunu olduğu için genellikle deneme yanılma yöntemi kullanılarak bulunmalıdır.

Yukarda bahsedilen kısıtları aşmak için başka metodlar araştırılmıştır. Adamowski (2008) ileri

zamanlı bir, iki ve altı gün olacak şekilde günlük akım tahmini noktasında tek başına dalgacık dönüşümünün performansını çoklu doğrusal regresyon yaklaşımı ile birleştirerek (Entegre edilmiş otoregresif hareketli ortalama modeli, ARIMA) ve YSA ile karşılaştırarak incelemiştir. Model sonuçlarına göre, bir ve iki günlük ileri zamanlı nehir taşkınlarının tahmininde, yıldan yıla aynı günde yağış büyüklüğünde önemli bir değişim trendi olmaması, akım ve meteorolojik zaman seviyeleri arasında nispeten dengeli bir faz değişim olması kabulüyle dalgacık tabanlı tahmin modeli çok yüksek bir hassasiyetle kullanılabilir. Bununla birlikte altı günlük hazırlık süresi için en iyi tahmin modeli YSA'dır. Jeong ve Kim (2005), Kore'deki çok amaçlı Daecheong barajının aylık giriş akımını öngörmek için, toplu akım tahmin sistemi'ni (TATS) kullanan bir yağış-akış yöntemi olan Tank'dan daha başarılı bir yağış-akış modeli geliştirmek için iki tip yapay sinir ağı modeli kullanmışlardır: (Tekil sinir ağıları (TSA) ve toplu sinir ağıları (TSA)). Bu sonuçlara göre TSA üç yağış-akış modeli arasından en iyi sonucu vermiştir. Adamowski ve Su (2010) ayrık dalgacık dönüşümü (ADD) ve YSA yöntemlerini birleştirmiş ve birleştirilen bu dalgacık-yapay sinir ağıları modelinin (D-YSA) Kıbrıs'taki iki istasyonda 1 ile 3 günlük ileri zamanlar için verdiği tahmin sonuçlarını, sadece YSA modelinin sonuçlarıyla karşılaştırmak suretiyle performansını ölçmüştür. Sonuçlar D-YSA modelinin YSA'ya göre daha hassas akış tahminleri yaptığını ortaya koymuştur ve sonuç olarak birleştirilmiş D-YSA modellerinin kısa vadeli akım tahmini için gelecek vaad ettiği ifade edilmiştir. Bu sonuçlar aynı zamanda YSA modellerinin yerleşik olmayan işlemlerin tahmini için çok verimli olmadığını göstermiştir. Yukarıda bahsedilen geçmiş çalışmaların özet bilgilerinden, bu çalışmaların aylık veya sezonluk akarsu akım tahmin tekniklerine odaklandıkları söylenebilir. Su kaynaklarındaki (gelecekteki) artma ve azalma durumlarının planlanması ve sistemin optimize edilebilmesi için hem kısa dönem (genelde günlük) hem uzun dönem (aylık, sezonsal ve yıllık) akım tahminlerine ihtiyacımız vardır (Kişi, 2005). Bununla birlikte aylık kullanılabilir su miktarı

(hacmi), ölçülen yağış miktarından (yükseklik-derinlik) çok kolay bir şekilde belirlenebilir. Aylık akış hacimleri uzun vadeli su arzı ve taşkın kontrolü planlaması için yararlı olabilir (Anmala et al., 2002). Dahası kısa vadeli akarsu akış tahmini nehir düzenleme sistemlerinin işletmesi için hayati önem arz etmektedir (Dutta et al., 2011). Bununla birlikte kısa vadeli akım tahmini haznedan bırakılacak suyu önceden azaltmak sureti ile su kaynakları yönetiminin iyileştirilmesine yardımcı olabilir (George et al., 2011). Her ne kadar günlük ölçekte akış tahmini için teknik geliştirme denemeleri olsa da birçoğu çok kısa bir ileri zaman için önerilir. Bunun için uzun ileri zamanlarda günlük akımı tahmin edebilecek yeni modeller geliştirilmelidir. Sonuç olarak şu ana kadar net sonuçlar veren tek bir yöntem geliştirilememiştir.

Su yönetimi problemleriyle daha etkin bir şekilde mücadele edebilmek için, yüksek hassasiyetlerde öngörülerde bulunabilmek ve daha iyi planlama yapabilmek çok önemlidir. Doğru ve güvenilir tahminler, orijinal verilerin bileşenlerine ayrıştırılması suretiyle bizi doğru tahminlere ulaştıramayan verilerden kaçınmakla başarılıdır. Tekil spektrum analizi (TSA), hareketli ortalama (HO) ve ana bileşen analizi (ABA), zaman serileri tahmini noktasında model performansını iyileştiren etkili ön işlem algoritmaları olarak tanımlanır (Gamiz-Fortis et al., 2002; Wu et al., 2009; Wu et al., 2010). Fakat son yıllarda dalgacık analizi, hareketli olmayan zaman serilerini analiz etmede etkili bir yöntem haline gelmiştir. (Dabhi ve Chaudhary, 2014) Özellikle ADD, orijinal verinin bir takım gruplara ayrışması ve periyodikliğin (tekrarın) elenmesinde kullanılmıştır. Böylece kısa ileri zamanlı tahminler için doğruluk artırılmıştır. Bu çalışmanın amacı ileri zaman dilimi 7 güne kadar olan günlük akarsu akımlarının tahmini için iki modelin performansını araştırmaktır:

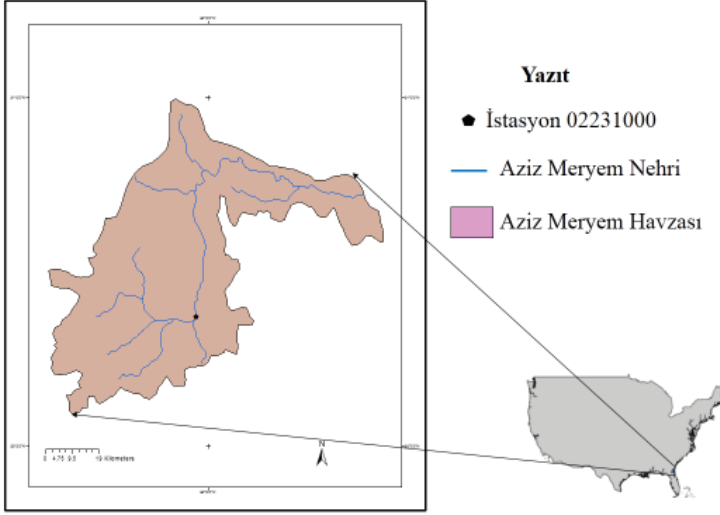
## **Malzemeler ve metotlar**

### **Çalışma alanının tanımı**

Çalışma, Amerika'da rastgele seçilen bir istasyondan alınan günlük akarsu akım verileri kullanılarak yürütülmüştür. Bu istasyon Aziz

Meryem Nehri havzası içinde olup Florida'nın doğu sınırı ile Georgia arasında bulunmakta ve 3.367 km<sup>2</sup>'lik bir alanı kaplamaktadır (Şekil 1). Verilerin toplandığı istasyonun coğrafi koordinatları 30°21'31" K ve 82°04'54" B olup

istasyonun Amerikan Jeolojik Araştırma Enstitüsü (USGS) tarafından kodu 02231000 ile tanımlanmış ve 1.813 km<sup>2</sup>'lik bir drenaj alanına sahiptir ([http://waterdata.usgs.gov/nwis/uv?site\\_no=02231000](http://waterdata.usgs.gov/nwis/uv?site_no=02231000)).




Şekil 1. İstasyon 02231000 ile beraber Aziz Meryem Havzasının haritası

### Veri toplama ve analizi

Ocak 2000 ile Aralık 2011 yılları arasındaki 12 yıllık ölçülmüş günlük akım verileri, USGS'nin internet adresinden elde edilmiştir. 2000'den

önceki ve 2011'den sonra sonraki ölçülmüş verilere ise ulaşamamıştır. Çalışmanın tutarlı olması için 2000 ile 2011 yılları arası kayıtlar seçilmiştir. İstasyonun akım verilerinin zamansal değişimleri Şekil 2'de gösterilmiştir.



Şekil 2. İstasyon 02231000'ün akım-zaman değişimi grafikleri

Ortalama, varyans ve çarpıklık parametrelerini içeren istatistiki değerler 02231000 nolu istasyon için ölçülmüş veriler dikkate alınarak hesaplanmıştır. Bu parametreler Tablo 1’de özetlenmiştir. Bu çalışmada veri ön işleme (ADD) yöntemi, ÇTP tahmin metodu ile entegre edilerek araştırılmıştır. ADD yaklaşımı doğru ve güvenilir tahminlere ulaşabilmek için orijinal veriyi bantlara (alt-serilere) ayırmak için kullanılmıştır. ÇTP, tahmin edici bir model kurmak için kullanılmış ve aynı zamanda 7 günlük ileri zamanlı günlük akarsu akımını tahmin edebilmek amacıyla yeni bir teknik geliştirmek üzere ADD ile birleştirilmiştir. Bu yeni yaklaşım birleşimden sonra dalgacık-çok tabakalı perseptron (D-ÇTP) modeli olarak adlandırılmıştır. İlk yedi yıllık veri seti modellerin kalibrasyonu için, geri kalan beş yıllık veri ise modelin günlük akarsu akımını tahmin etme performansını test etmek için kullanılmıştır. Bu yeni yaklaşımın sonuçları ÇTP modelinin sonuçlarıyla karşılaştırılarak değerlendirilmiştir. Modellerin performans karşılaştırmaları, gözlem ve model tahmin sonuçları karşılaştırılarak elde edilen hataların karelerinin ortalamasının karekökü (HKOK) ve verim katsayısı (VK) kullanılarak değerlendirilmiştir. Ayrıca model performansının görsel olarak da araştırılması için gözlemlenen veri ile model tahmin sonuçları grafikleştirilmiştir.

## **Modellerin Tanımlanması**

### **Ayrık Dalgacık Dönüşümü**

Dalgacıklar zaman serilerinin verilen bir zamandaki betimlemesini gösteren ve durgun olmayan değerler içeren zaman serilerini analiz etmek için bunların ilişkilerini veren matematiksel fonksiyonlardır. Dalgacık dönüşümü trend ve periyodikliği (tekrarlanmayı) orijinal veriden ayırır (Misiti et al., 2000). Dalgacık dönüşümünün amacı değişik zaman ölçeklerinde oluşan lokal ve geçici süreksiz olayları bütün ve eksiksiz bir zaman ölçeğinde gösterebilmeyi başarmaktır (Labat et al., 2000). Bu analiz, belirlenen zaman aralığı içinde değişik periyotlardaki bir sinyalin zaman frekans temsilini sağlamaktadır (Daubechies, 1990) ve

verinin fiziksel yapısı hakkında önemli bilgiler vermektedir. Dalgacık analizi, düşük bilgi frekansı için uzun zaman aralığı, yüksek bilgi frekansı için kısa zaman aralığı kullanmaya izin verir ve diğer analiz tekniklerinin kaçırabileceği birtakım eğilimler, kırılma noktaları (ekstrem değerler) ve süreksizlikler gibi bakış açılarını bize gösterir (Adamowski ve Su, 2010). Dalgacık fonksiyonu, değişik çözünürlük düzeylerinde alt seviyelere bölünmüş orijinal verileri parçalara ayırır ve dönüştürür (Tiwari ve Chatterjee, 2010). Dalgacık analizi Fourier serileri taban alınarak, bu serilerin ayrıştırma işlemi sırasındaki zamansal bilgilerin kaybolması başta olmak üzere birtakım dezavantajlarından kaçınmak için geliştirilmiştir ve Fourier dönüşümünün önemli bir türevidir. Çobaner (2013)’e göre, dalgacık dönüşümü, değişik frekanslardaki zaman bölgesi sinyallerinin değişik parçalarını ayrı ayrı hesaplama yeteneğine sahiptir. Diğer bir deyişle, sinyali karşılıklı ortogonal dalgacık kümelerine ayırır. En temel dalgacık fonksiyonu  $\Psi(t)$  ana dalgacık dönüşüm fonksiyonu olarak da adlandırılır ve aşağıda matematiksel ifadesi verilmiştir.

$$\int_{-\infty}^{+\infty} \Psi(t) dt = 0. \quad (1)$$

( $\Psi(t)$ ) dalgacık fonksiyonunun açılması ve daraltılmasıyla  $\Psi_{a,b}(t)$  fonksiyonu aşağıdaki gibi hesaplanabilir:

$$\Psi_{a,b}(t) = |a|^{-\frac{1}{2}} \Psi\left(\frac{t-b}{a}\right) \quad (2)$$

Burada a (ölçek veya frekans parametresi ve genişleme ( $a > 1$ ) veya daralma ( $a < 1$ ) şeklinde yorumlanabilir) ve b (çevirme parametresi, dalgacık dönüşümü fonksiyonunun ötelenmesi olarak yorumlanabilir) gerçel sayılardır. En çok kullanılan iki tip dalgacık dönüşümü, sürekli dalgacık dönüşümü (SDD) ve ayrık dalgacık dönüşümüdür (ADD). Cannas et al. (2006)’a göre  $x(t)$  sinyalinin SD dönüşümü şu şekilde belirlenir.

$$CWT_x^\psi(\tau, s) = \frac{1}{\sqrt{|s|}} \int_{-\infty}^{+\infty} x(t) \psi \left( \frac{t-\tau}{s} \right) dt \quad (3)$$


(3)

s ölçek parametresini,  $\tau$  öteleme parametresini ve ‘\*’ karmaşık eşleniği ifade eder. Cannas et al. (2006) dalgacık formülünü aşağıdaki şekilde modifiye ederek ADD ’ yi elde etmiştir:


$$\psi_{j,k}(t) = \frac{1}{\sqrt{|S_o^j|}} \psi \left( \frac{t - k\tau_o S_o^j}{S_o^j} \right) \quad (4)$$

j ve k tam sayılar,  $S_o > 1$  belirlenmiş genişleme derecesidir.


SDD hesaplamaları yüksek miktarda kaynak ve hesaplama zamanı gerektirirken, ADD için daha az zaman yeterli olmaktadır ve uygulaması SDD’ den daha kolaydır (Adamowski ve Su, 2010). Sonuç olarak bu çalışmayla, istasyon 02231000’den alınan orijinal günlük akış verileri, ADD kullanılarak üç alt seri (üç bant) şeklinde ayrıştırılmıştır (3 alt seriden daha fazla ayrıştırmak tahmin hatalarını azaltmamıştır). Ayrıştırma sonuçları Şekil 3’ de (a-c) 02231000 nolu istasyon için gösterilmiştir. Daha sonra ayrıştırılmış dalgacık katsayıları, ÇTP modeli için girdi olarak kullanılmıştır. Son tahmin değeri her bir serinin tahmin sonuçlarının toplanmasıyla elde edilmiştir.



(a)



(b)



(c)

Şekil 3. İstasyon 02231000 için akım verileri ADD kullanılarak bandlara ayrıştırılan serilerin grafikleri sırasıyla (a) Band-1, (b) Band-2, (c) Band-3.

### Çok Tabakalı Perseptron

Yapay sinir ağları (YSA), ağırlıklı sinaptik bileşimlerle birbirine bağlı basit işleme unsurlarının (düğüm noktası) birleşiminden oluşan bilgi işleme sistemleridir ve esnek model yapılarından ötürü karmaşık veya doğrusal olmayan işlemlerdeki değişkenlerin tahmininde kullanılırlar (Muller ve Reinhardt, 1991). Düğüm noktalarının belirli bir düzene göre organizasyonu yapay sinir ağlarının yapısını oluşturur. Bu düğüm noktaları genellikle giriş tabakasından çıkış tabakasına bir bilgi akışı sağlayacak şekilde tabakalar halinde düzenlenir

(Altunkaynak, 2007). ANN'nin topolojisi, aşağıdaki tabaka sayısını, her tabakadaki düğüm noktasını, düğüm noktaları arasındaki birleşimin türünü ve tüm yapıyı kapsar (Pereira Filho ve dos Santos, 2006). ANN modellerinin oluşturulmasındaki adımlar ADD tarafından sırasıyla aşağıdaki şekilde özetlenmiştir:

- 1 - Girdi değişkenlerinin seçimi
- 2 - ANN çeşidinin seçimi
- 3 - Veri seçimi ve ön işleme
- 4 - ANN kalibrasyonu
- 5 - ANN'nin test edilmesi (tahmin süreci) ve performans değerlendirilmesi

Yapay sinir ağlarını ana konsepti, 1958 yılında Rosenblatt tarafından ileriye doğru olan tek tabaka beslemeli ağ olan Perseptron olarak tanımlanmıştır. Çok tabakalı perseptronun genel özellikleri şunlardır:

- 1 - İç katmanlarda harici bilgi paylaşan bir girdi tabakası
- 2 - Entegre edici ve şekil oluşturan etkinleştirme fonksiyonu vasıtasıyla girdi sinyalini işleyen saklı tabakalar
- 3 - Karşı şekilleri toplayıp birleştiren bir çıktı tabakası (Pereira Filho ve dos Santos, 2006).

Yapay sinir ağları yaklaşımları hidrolojik işlemlerin modellenmesinde çok başarılı olmuş ve bu sayede popülerlikleri artmıştır. Son zamanlarda yapay sinir ağlarının türlü mühendislik projeleri ve bunların su kaynakları uygulamalarının problem çözümlerinde kullanımı, güçleri ve doğrusal olmayan sistem girdilerini eşleştirebilmeleri sayesinde artmaktadır (Çobaner et al., 2008). Yapay sinir ağları, birçok hidrolojik durumun zaman serileri ile modellenmesinde başarılı bir şekilde kullanılmıştır (Cheng et al., 2005). ANN'ler hidrolojik işlemlerde dahil birçok uygulamada yararlanılmak suretiyle takdir kazanmıştır (Altunkaynak, 2014). ANN'nin; doğrusal olmayışı, paralelliği, hata toleransı, kendini geliştirme ve yenileştirme yetenekleri gibi bilgi

işleme nitelikleri onu cazip bir yöntem haline getirmiştir (Seçkin, 2009). ANN'lerin iki tip tahmin işleyişi mevcuttur: Çok tabakalı perseptron (ÇTP) ve dairesel tabanlı modelleme fonksiyonu (RBF). ÇTP yaklaşımını doğal işleyişleri açısından sevimli kılan karmaşık doğrusal olmayan etkileşimlerin üstesinden gelebilme yapısına sahip olmasıdır (Altunkaynak 2013). Altunkaynak (2013)' a göre ÇTP, girdi tabakası ile saklı tabaka arasında ve saklı tabaka ile çıktı tabakası arasında ağırlık katsayılarına sahiptir. Altunkaynak (2013) bu katsayıların tespitinde genetik algoritmayı bir optimizasyon tekniği olarak, ağırlık katsayılarını modelin tahmin hatalarını küçültmek için model parametresi olarak kullanmıştır. ÇTP modelinin kuruluşu, uygun sayıda nöron seçimi ve deneme verileri kullanan bağlantı ağırlıklarının optimizasyonunu gerektirmektedir. Saklı tabakaların ve saklı tabakaların içindeki nöronların sayısı, ağırlık katsayılarının uzamasından kaçınmak için az tutulmalıdır. Genellikle 3 ile 7 arasındaki nöron adedi verimli bir çalışma için yeterlidir (Altunkaynak, 2007). Tansig, logsig ve pureline gibi ANN modellerini geliştirmek için bir takım aktivasyon fonksiyonları kullanılmaktadır. Bir fonksiyonun diğerine tercihi noktasında bir tavsiyeye sahip değiliz. Fakat genelde üç alternatifte test edilmiş, en az tahmin hatası vereni, girdi ve çıktı tabakaları için uygun aktivasyon fonksiyonu olarak seçilmiştir. ÇTP' nin avantajlarından bir tanesi, doğrusallık, normal dağılım ve tüm değişkenlerin aynı sonlu değişimleri vermesi gibi bir takım kısıtlayıcı kabulleri içermemesidir (Altunkaynak, 2007; Altunkaynak ve Strom, 2009; Altunkaynak ve Aydın, 2012; Altunkaynak, 2013). İlaveten, bu yöntemin girdi ve çıktı değişkenlerini doğrusal olmayan bir şekilde birbirine bağlama özelliği olduğundan, çok karmaşık hesaplamaları başarmak için bir nöron ağı kullanılarak çoklu çıktı oluşturmada kullanılabilir (Altunkaynak ve Storm, 2009). ÇTP hidrolojik modellemede ANN'nin en çok kullanılan türü (Wang et al, 2006) olup ve diğer türlerden daha iyi sonuçlar verdiği tespit edilmiştir (Mutlu et al., 2008; Seçkin et al., 2013). Bundan ve yukarıda bahsedilen avantajlarından dolayı çalışmamızda bu



yaklaşım kullanılmıştır. Altunkaynak ve Storm (2009), tarafından yapılan çalışmada, m girdi nöronlarını,  $(x_1, x_2, \dots, x_m)$ , r gizli katman nöronlarını  $(h_1, h_2, \dots, h_r)$  ve p çıktı nöronlarını  $(z_1, z_2, \dots, z_p)$  içeren bir model kabulü yapılmak suretiyle bir ÇTP modelini tanımlamak için aşağıdaki matematiksel ifade verilmiştir:

$$h_j = f\left(\sum_{i=1}^m x_i w_{ij} + \alpha_j\right) \quad (5)$$

ve

$$z_k = g\left(\sum_{j=1}^r h_j \theta_{kj} + \beta_k\right) \quad (6)$$

$f(\cdot)$  ve  $g(\cdot)$  aktivasyon fonksiyonları,  $\alpha_j$   $h_j$  nöronunun açısını,  $\beta_k$  da nöron  $z_k$ ' nin açısıdır.  $w_{ij}$ ,  $x_i$  nöronundan  $h_j$  nöronuna olan bağlantının ağırlığını ve  $\theta_{kj}$ ,  $h_j$  nöronundan  $z_k$  nöronuna olan bağlantının ağırlığını verir. İ, j, ve k harfleri sırasıyla girdi, saklı ve çıktı tabakalarını temsil eden endekslerdir. Çok tabakalı perseptron modeli bir takım yöntemler kullanılarak bağlantıların ağırlığını (doğruluğunu) belirlemek için test edilebilir. Bu çalışmada back-propagation algoritması kullanılmıştır (Rumelhart et al., 1986). Bu algoritma iki fazdan oluşmaktadır: İleri besleme fazı ve geri yayılım fazı. İleri besleme fazında, girdiler çıktılara elde etmek için çıktı tabakasına ilerlemektedir. Daha sonra hata hesaplanarak hata tekrar girdi tabakasına iletilecek ve ağırlık katsayıları düzeltilmektedir. Bu işlem hedeflenen hata değeri elde edilene kadar devam edecektir (Negnevitsky, 2005). Böylece hata değeri çok düşecektir. İşte tam da bu yüzden geri yayımlı deneme algoritması bu çalışma için seçilmiştir.

### **Dalgacık-Çok Tabakalı Perseptron Modelleri**

Birçok araştırmacı, akım verileri tahmininin doğruluğunun, çoklu perseptron ile dalgacık dönüşümü modellerinin birleştirilmesiyle arttığını fark etmişlerdir. Yakın zamanda birçok araştırmacı birleştirilmiş D-ÇTP modellerini kullanmışlardır (Kim ve Valdes, 2003; Kucuk et al., 2009; Webster ve Hoyos, 2004; Nourani et al., 2009; Ozger, 2010). Bu çalışmalarda, ADD

yardımla akım verileri alt seriler halinde bileşenlerine ayrılmıştır. İki yaklaşımın birleşiminin amacı

1 - Ayrık dalgacık dönüşümleri kullanılarak akımın verilerini alt serilere ayırmak

2 - Günlük akarsu akım alt serilerini çoklu-tabaka perseptron yaklaşımı kullanarak art arda tahmin etmektir. Günlük akım tahmini için kullanılan birleştirilmiş D-ÇTP yaklaşımında üç adım uygulanmıştır. Bu adımlar aşağıdaki şekilde özetlenmiştir:

1 - Ortalama dalgacık spektrumundan elde edilen önemli spektral bantlar incelenmiş ve alt serilere ayrılmıştır,

2 - Her alt seri ayrı ayrı çok-tabakalı perseptron kullanılarak modellenmiştir,

3 - Son adım olarak, tahmin edilen alt serilerin yeniden yapılandırılmasından sonra ilgili günlük akım verileri elde edilmiştir. Başka bir ifade ile orjinal akım zaman serilerinin verileri ADD kullanılarak yeniden elde edilebilir. Birleştirilmiş D-ÇTP yaklaşımının kullanıma amacı, iki geçmiş değerden yedi günlük ileri zamanlı günlük akım tahmini yapabilmektir. İleri tarihli akım verileri modelin çıktısı olarak, geçmiş iki günlük akım verisi ise girdi olarak alınmıştır. Modelin matematiksel formunu oluşturmak için çok-tabakalı perseptron kullanılmış ve böylece girdi ve çıktı arasındaki ilişki kurulmuştur.

### **Performans değerlendirme Kıstası**

Literatürde bir dizi model performans kıstası mevcuttur. Nash-Sutcliffe verimlilik katsayısı (Nash ve Sutcliffe,1970), mutabakat endeksi (Willmott, 1981)), istikrarlı model verimliliği (Gupta et al., 1999), performans üstünlük istatistiği (Wang ve Melesse, 2005), logaritmik değişken dönüşümü (Parker et al., 2007), Pearson'un korelasyon ve kararlılık katsayısı, mutlak ortalama hata ve hataların karelerinin ortalamasının karekökü (HKOK) kriterleri bunlardan bir kaçıdır. Bununla birlikte, en çok kullanılan hata ölçüleri, HKOK ve verimlilik katsayısıdır (Solomatine ve Dulal, 2003). Bunun için yukarıda bahsedilen modellerin



*Günlük akımların tahmini açısından çok tabakalı perseptron ve dalgacık-çok tabakalı perseptron modellerinin performans karşılaştırması*

performansları HKOK ve Nash-Sutcliffe verimlilik katsayısı (VK) ölçüleri kullanılarak değerlendirilmiştir. Bu ölçüler aşağıdaki gibi tanımlanmıştır.:

$$HKOK = \sqrt{\frac{1}{n} \sum_{i=1}^n (A_{pi} - A_{oi})^2} \quad (7)$$

$$VK = \left[ 1 - \frac{\sum_{i=1}^n (A_{pi} - A_{oi})^2}{\sum_{i=1}^n (A_{oi} - A_a)^2} \right] \quad (8)$$

Burada n toplam gözlem sayısı,  $A_{pi}$ ,  $A_{oi}$  ve  $A_a$  ise sırasıyla tahmin edilen günlük akım verisi, gözlem verisi ve ortalama günlük akım verisidir. Her model için HKOK ve VK değerleri sırasıyla Denklem (7) ve (8) kullanılarak hesaplanır. Bu çalışmada oluşturulan D-ÇTP modelinin sonuçlarının doğruluğunu test etmek için, beceri puanı parametresi (BP), son zamanlarda değerlendirme kistası olarak kullanıldığından (Altunkaynak, 2014) ayrıca tüm ileri zaman 'lar için hesaplanmıştır. BP parametresi, bir eksi tahmin edilen değerlerin hatalarının karelerinin

ortalamasının (HKO) gözlemlenen değerlerin hatalarının karelerinin ortalamasına oranıdır.

Matematiksel olarak aşağıdaki şekilde ifade edilir:

$$BP = \left[ 1 - \frac{HKO_P}{HKO_R} \right] \quad (9)$$

HKO<sub>P</sub> D-ÇTP model sonuçlarının hatalarının karelerinin ortalaması, HKO<sub>R</sub> ise ÇTP modelinin hatalarının karelerinin ortalamasını temsil etmektedir ve bu değer referans değeri olarak kabul edilmiştir.

Bu kıstas simüle edilen verilerin ölçülen değerler ile kıyaslandığındaki doğruluğu açısından model değerlendirilmesini kolaylaştırmak için kullanılmıştır. Literatürde bu kıstasın bildirilen farklı aralıktaki değerleri ve bu değerlere karşılık gelen performans seviyeleri mevcuttur. Bununla birlikte 0,5'ten büyük (BP) değerleri genellikle kabul edilebilir performans değerleri olarak görülür (Mariasi 2007). Bu çalışmada en yüksek VK ve BP, en düşük HKOK değeri veren model, günlük akım verisini tahmin eden en iyi model olarak seçilmiştir.

## Sonuçlar ve Tartışma

Malzemeler ve metotlar bölümünde de işaret edildiği üzere ÇTP ve D-ÇTP modelleri Amerika'daki bir istasyon için ileri (gelecek) zamanlı 7 günlük akım miktarının tahmini için geliştirilmiştir. Daha sonra bu modellerin şimdiki günlük akarsu akımlarını (zaman adım t de) iki önceki günlük akım değerinden (zaman akımı t-2 ve t-1) elde edilen yedi günlük ileri zamanlı tahmin edebilme performansları test edilmiştir. Bu çalışmada Ocak 2000 'den Aralık 2011'e kadar ki günlük akarsu akım verileri

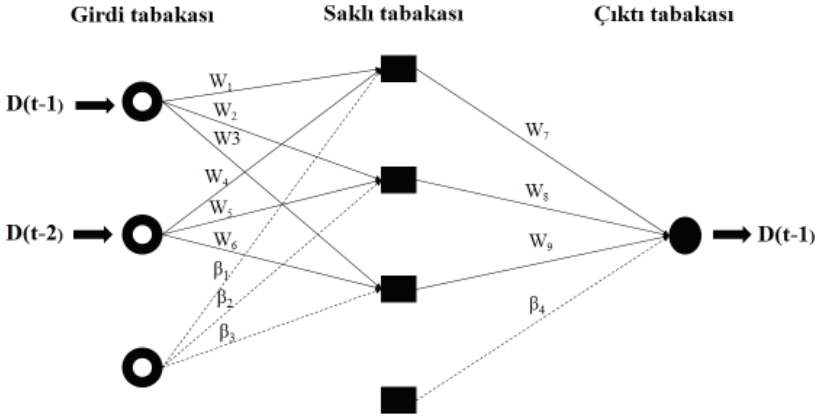
kullanılmıştır. 2555 adet akım verisi barındıran yedi yıllık veri seti kalibrasyonu için, 1825 adet akım verisi içeren beş yıllık veri setinde 02231000 nolu istasyon için tahmin yapmada kullanılmıştır. İstasyonun akarsu akım değerleri Şekil 2' de gösterilmiştir. Ölçülmüş günlük akım verileri Şekil 3' de (a-c) gösterildiği üzere ADD kullanılarak üç farklı spektral banda (alt serilere) ayrılmıştır. Orijinal verinin ortalama, varyans ve çarpıklık parametreleri, istasyonun ölçülmüş verilerinin yapısını incelemek üzere belirlenmiştir. Bu istatistiki parametrelerin değerleri Tablo 1 de verilmiştir.

*Tablo 1: Araştırma istasyonu verileri kullanılarak hesaplanan istatistiki parametreler.*

İstasyon 02231000		
Ortalama (m <sup>3</sup> s <sup>-1</sup> )	Varyans (m <sup>6</sup> s <sup>-2</sup> )	Çarpıklık sayısı
12.28	1180.74	8.36

Malzemeler ve metotlar bölümünde bahsedildiği üzere ÇTP modelinin en iyi mimarisini belirlemek üzere, değişik sayıdaki saklı tabaka ve saklı tabakanın içerisindeki nöronlar test edilmiştir. Bundan dolayı en iyi mimariyi belirlemek için bu çalışmada, Şekil 4’te de gösterildiği üzere en düşük tahmin hatasını veren mimari yapı üç nöronlu bir saklı tabaka olarak

tespit edilmiştir. İlaveten tansig, logsig , ve pureline aktivasyon fonksiyonları test edildikten sonra; tansig ve pureline fonksiyonları seçilmiş, saklı ve çıktı tabakaları için aktivasyon fonksiyonu olarak, sırasıyla kullanılmıştır. Bu fonksiyonlar en düşük tahmin hatası veren fonksiyonlar olduğu için seçilmiştir.



Şekil 4. ÇTP modelinin mimari yapısı.

Önceden de ifade edildiği üzere bu modellerin performansı HKOK ve VK kıstasları kullanılarak nicel olarak değerlendirilmiştir. Bu hesaplamaların sonuçları Tablo 2 de verilmiştir. Tablodan da görüleceği üzere istasyon 02231000 için ÇTP ve D-ÇTP (1. Gün için gelecek zamanlı) modelleri kullanılarak yapılan günlük akım tahminlerinin HKOK’leri sırasıyla  $6.79 \text{ m}^3 \text{ s}^{-1}$  ve  $3.47 \text{ m}^3 \text{ s}^{-1}$  dir. D-ÇTP modelinin tahmin

sonuçlarının ÇTP modelinin sonuçlarına göre daha iyi olduğu tespit edilmiştir. İstasyon 02231000’in ÇTP ve D-ÇTP modellerine göre VK değerleri (birinci gün için), sırasıyla 0,956 ve 0,988 olarak bulunmuştur (Tablo 2). Bu istatistik değerleri bu iki modelin tahmin sonuçlarıyla gözlemlenen veriler arasında güçlü bir uyum olduğunu göstermektedir.

Tablo 2: ÇTP ve D-ÇTP modellerinin performans HKOK ve VK değerlerine göre karşılaştırması


Gelecek zaman (günler)	Kıstaslar	İstasyon 02231000	
		ÇTP	D-ÇTP
1	HKOK ( $\text{m}^3/\text{s}$ )	6.790	3.47
	VK	0.956	0.988
2	HKOK ( $\text{m}^3/\text{s}$ )	14.173	7.253

*Günlük akımların tahmini açısından çok tabakalı perseptron ve dalgacık-çok tabakalı perseptron modellerinin performans karşılaştırması*

	VK	0.778	0.942
3	HKOK (m <sup>3</sup> /s)	19.583	9.786
	VK	0.638	0.910
4	RMSE (m <sup>3</sup> /s)	23.507	10.995
	VK	0.479	0.886
5	HKOK (m <sup>3</sup> /s)	26.233	14.425
	VK	0.351	0.804
6	HKOK (m <sup>3</sup> /s)	27.960	14.880
	VK	0.263	0.791
7	HKOK (m <sup>3</sup> /s)	28.841	18.139
	VK	0.216	0.690

Model sonuçlarının olumlu olarak değerlendirilmesi için elde edilmesi gereken belirli bir VK değeri üzerinde bir mutabakat yoktur. Fakat Donigan et al. (2003)'e göre VK'nin 0,65 – 0,75 arasındaki değerleri uygun, 0,75 – 0,85 arası iyi ve 0,85'in üzeri çok iyi model performansı vermesi açısından seçilmiştir. Bundan dolayı birinci gün için iki modelin VK değerleri, modellerin çok iyi tahmin sonuçları verdiğini göstermektedir. Bununla birlikte D-ÇTP modelinin VK değerleri ÇTP modelininkinden daha yüksektir. Ek olarak D-ÇTP modelinin HKOK değerleri ÇTP modelininkinden küçüktür. Diğer gelecek

zamanlar (2-7) için HKOK ve VK değerleri Tablo 2'de sunulmuştur. Bu tablodan görüleceği üzere, her ileri zaman için D-ÇTP modelinin HKOK değerleri yalnız ÇTP modelinden daha düşük, VK değerleri ise daha yüksektir. Sonuç olarak her ileri zaman için W-MP modelinin performansının ÇTP modeline göre daha iyi olduğu söylenebilir. Yalnız ÇTP ve D-ÇTP modeline göre tahmin edilen günlük akım verileri ile ölçülmüş akım verileri (birinci gün için) karşılaştırılmış ve kusursuz model doğrusu üzerinde işlenmiş (1:1 doğrusu) Şekil 5 (a) ve 5 (b) de gösterilmiştir.




Şekil 5. ÇTP (a) ve D-ÇTP (b) modelleri tarafından tahmin edilen ve gözlemlenen akım verilerinin karşılaştırması.

Şekil 5 (a) ve 5 (b) sırasıyla ÇTP ve D-ÇTP model tahminleri ile gözlem verileri arasında uyum olduğunu çok net bir şekilde göstermektedir. Bundan başka orijinal verilerin zaman serilerinin grafiği ve ÇTP ve D-ÇTP

modelleri tarafından yedinci gün için tahmin edilen sonuçlar Şekil 6 (a) ve 6 (b) de gösterilmiştir. İstasyon 02231000' daki gözlem ve ÇTP modeli tahmin sonuçları arasında güçlü bir uyum görülmüştür (Şekil 6a).

*Günlük akımların tahmini açısından çok tabakalı perseptron ve dalgacık-çok tabakalı perseptron modellerinin performans karşılaştırması*



*Şekil 6. İstasyon 02231000 için ÇTP (a) ve D-ÇTP (b) yaklaşımları kullanılarak tahmin edilen ve gözlemlenen günlük akımların zaman serileri.*

İlaveten Şekil 6 da görüldüğü üzere 02231000 nolu istasyonda D-ÇTP modelinin tahmin sonuçları, gözlem verilerini yakından takip etmektedir. Ancak ÇTP modeli (Şekil 6a) istasyon 02231000 için öngörülenin üzerinde tahmin sonuçları vermiştir. Denklem (9) kullanılarak hesaplanan BP sonuçları Tablo 3 de gösterilmiştir. Bu tablodan da görüleceği üzere

D-ÇTP modeliyle istasyon 02231000' da birinci gün için BP parametreleri 0,740 bulunmuştur. D-ÇTP modeli dördüncü gününe kadar BP değeri yükselebilmektedir. Bu da D-ÇTP modelinin dördüncü günden yedinci güne kadar olan zaman diliminde günlük akım tahminlerinde ilk dört günlük tahmine göre iyi işlemediğini göstermektedir. Şekil 6' da da D-ÇTP modelinin

gözlem verilerine çok yakın değerler verdiği görülmüştür. Özetle D-ÇTP modelinin dalgacık dönüşümü kullanarak günlük akım verilerini çok iyi tahmin ettiği gözlemlenmiştir. Benzer olarak

bir saklı tabakalı ve bu saklı tabakada üç ileri beslemeli çok tabakalı perseptron'un günlük akım verileri için doğru tahminler yaptığı tespit edilmiştir.

Tablo 3: 1'den 7 güne kadarki gelecek zamanlı beceri puanı (BP) açısından D-ÇTP modelinin performansı

Gelecek zaman (günler)	Kıstaslar	İstasyon 02231000
		D-ÇTP
1	BP	0.740
2	BP	0.738
3	BP	0.750
4	BP	0.781
5	BP	0.698
6	BP	0.717
7	BP	0.604

## Sonuçlar

Günlük akım verilerinin tahmininde yeni bir yöntem geliştirmek için ADD tekniği ile ÇTP yöntemi ile birleştirilmiştir. 02231000 nolu istasyonda akım zaman serisi dalgacık dönüşümü kullanılarak spektral bantlara ayrıştırılmıştır. ÇTP ve D-ÇTP modelleri kullanarak, istasyon 02231000 için günlük akım salınımlarını öngörebilmek için tahmin modelleri geliştirilmiştir. 12 yıllık (2000' den 2011' e) 4880 adet veriden oluşan günlük akım verileri bu çalışmada kullanılmıştır. Daha sonra modellerin performansları, güncel günlük akım verilerinin tahmini için önceki akım verisinden günün akımlarına ait 1, 2, 3, 4, 5, 6 ve 7 gün içeren gelecek için akım tahmini yapılarak test edilmiştir. Modellerin kurulumu için gözlem

verileri iki gruba ayrılmıştır. 12 yıllık gözlem verilerinin 2555 adeti içeren ilk yedi yılı kalibrasyon için, 1825 veri adetini içeren beş yılı ise modelin test edilmesi için kullanılmıştır. Çalışma istasyonumuzda D-ÇTP modelinin günlük akımları oldukça iyi tahmin ettiği görülmüştür. Performans HKOK, VK ve BP kullanılarak nicel olarak değerlendirilmiştir. D-ÇTP modeli her artan gün (adım) için ÇTP modeline göre daha iyi tahmin performansı sergilemiştir. Bu çalışmada en basit ÇTP modellerinden biri olan üç tabakalı perseptron modeli kullanılmış ve günlük akım verileri için doğru tahminler yapmıştır. D-ÇTP modelinin ise uzun gelecek zamanlı günlük akım verisinin tahmininde çok daha iyi olduğu ve yukarıda belirtilen performans göstergelerine göre daha güvenilir olduğu tespit etmiştir.

## Kaynaklar

- Adamowski, J. (2008). "Development of a short-term river flood forecasting method for snowmelt driven floods based on wavelet and cross-wavelet analysis." *J. of Hydrol.*, 353: 247–266.
- Adamowski J., and Sun, K. (2010). "Development of a coupled wavelet transform and neural network method for flow forecasting of non-perennial rivers in semi-arid watersheds." *J. of Hydrol.*, 390: 85–91.
- Altunkaynak, A. (2007). "Forecasting surface water level fluctuations of Lake Van by artificial neural networks." *Wat. Res. Manag.*, 21: 399–408.
- Altunkaynak, A. (2009). "Streamflow estimation using optimal regional dependency function." *Hydrol. Proce.*, 23: 3525–3533.
- Altunkaynak, A. (2013). "Prediction of significant wave height using genomultilayer perceptron." *Oce. Eng.*, 58: 144–153.
- Altunkaynak, A. (2014). "Predicting Water Level Fluctuations in Lake Michigan-Huron Using Wavelet-Expert System Methods." *Wat. Res. Manag.*, 28 (8): 2293-2314.
- Altunkaynak, A. and Aydın, A. (2012). "Prediction of temperature variation within a snowpack in open areas and under different canopy covers." *Hydrol. Proce.*, 26: 4015-4028.
- Altunkaynak, A. and Strom, K.B. (2009). "A predictive model for reach morphology classification in mountain streams using multilayer perceptron methods." *Wat. Resour. Resea.* 45, W12501. <<http://onlinelibrary.wiley.com/doi/10.1029/2009WR008055>> (Jul. 02, 2013).
- Annala, J., Zhang, B., and Govindaraju, R.S. (2002). "Closure to discussion on Comparison of ANNs and other empirical approaches for modeling runoff" by V.K. Minocha and M.B. Sonnen." *ASCE J. of Wat. Res. Plan. and Manag.*, 128: 381-382.
- Annala, J., Zhang, B., R.S. and Govindaraju, R.S. (2000). "Comparison of neural network models with other approaches for rainfall-runoff modeling of watersheds." *ASCE J. of Wat. Res. Plan. and Manag.*, 126: 156-166.
- Bravo, J.M., Paz A.R., Collischonn, W., Uvo, C.B., Pedrollo, O.C. and Chou, S.C. (2009). "Incorporating Forecasts of Rainfall in Two Hydrologic Models Used for Medium-Range Streamflow Forecasting." *J. of Hydrol. Eng.*, 14:435-445.
- Cannas, B., Fanni, A., Sias, G., Tronei, S. and Zedda, M.K. (2006). "River flow forecasting using neural networks and wavelet analysis." *Proc. European Geosciences Union. EUG* (2005), Vienna, Austria, vol.7, 24-29.
- Cheng, C.T., Chau, K.W., Sun, Y.G., and Lin, J.Y. (2005). "Long-term prediction of discharges in Manwan Reservoir using artificial neural network models." *Lecture Notes in Computer Science* 3498, 1040–1045.
- Çobaner, M. (2013). "Reference evapotranspiration based on Class A pan evaporation via wavelet regression technique." *Irrig. Sci.*, 31: 119-134.
- Çobaner, M., Haktanir, T. and Kisi, O. (2008). "Prediction of Hydropower Energy Using ANN for the Feasibility of Hydropower Plant Installation to an Existing Irrigation Dam". *Wat. Res. Manag.*, 22 (6):757-774.
- Dabhi, V.K., Chaudhary S. (2014). "Hybrid Wavelet-Postfix-GP Model for Rainfall Prediction of Anand Region of India." *Advances in Artificial Intelligence*, 2014:1-11. <<http://www.hindawi.com/journals/aai/2014/717803/>> (Jan. 25, 2015).
- Daubechies, I. (1990). "The Wavelet Transform, time–frequency localization and signal analysis." *IEEE Trans. on Info. Theor.*, 36(5): 6–7. <[http://ece.ut.ac.ir/Classpages/F83/ImageProcessing/Papers/Wavelets/ieee\\_00057199\\_WaveletsDaubechies.pdf](http://ece.ut.ac.ir/Classpages/F83/ImageProcessing/Papers/Wavelets/ieee_00057199_WaveletsDaubechies.pdf)> (28 Jun. 28, 2013).
- Donigan, A.S., and Love, J.T. (2003). "Sediment Calibration Procedures and Guidelines for Watershed Modeling." In WEF TMDL 2003 Specialty Conference, WEF-CDROM: Chicago, IL, USA, 2003.



- Dutta, D., Welsh, W., Vaze, J., Kim, S., and Nicholls, D. (2011). "Improvement in short-term streamflow forecasting using an integrated modelling framework." *19th International Congress on Modelling and Simulation*, Perth, Australia, 12–16 December 2011. <<http://www.mssanz.org.au/modsim2011/14/dutta.pdf>> (Jan. 24, 2015).
- Gamiz-Frotis, S. R., Pozo-Vazquez, D., Esteban-Parra, M.J., and Castro-Diez, Y. (2002). "Spectral characteristics and predictability of the NAO assessed through Singular Spectral Analysis." *J. of Geoph. Resea.*, 107: 1-15.
- George, B.A., Adams, R., Ryu, D., Western, A.W., Simon, P., and Nawarathna, B. (2011). "An Assessment of Potential Operational Benefits of Short-term Stream Flow Forecasting in the Broken Catchment, Victoria." *Proc. of the 34<sup>th</sup> World Congress of the Int. Assoc. for Hydro- Environment Research and Engineering*, Brisbane, Australia. 26 June-1 July 2011. <<http://search.informit.com.au/documentSummary;dn=348282794182161.res=IELENG>> (Jan. 24, 2015).
- Gupta, H. V., Sorooshian, S., and Yapo, P.O. (1999). "Status of automatic calibration for hydrologic models: Comparison with multilevel expert calibration." *J. of Hydrol. Eng.*, 4: 135-143.
- Jeong, D.I. and Kim, Y.O. (2005). "Rainfall-runoff models using artificial neural networks for ensemble streamflow prediction." *Hydrol. Proc.*, 19: 3819–3835.
- Kim, T. and Valdes, J.B. (2003). "Nonlinear model for drought forecasting based on a conjunction of wavelet transforms and neural networks." *J. of Hydrol. Eng.*, 8: 319-328.
- Kişi, Ö. 2005. Daily River Flow Forecasting Using Artificial Neural Networks and Auto-Regressive Models. *Turkish J. of Eng. and Env. Sci.*, 29: 9 – 20.
- Kuçuk, M., Kahya, E., Cengiz, T.M. and Karaca, M. (2009). "North Atlantic Oscillation influences on Turkish lake levels." *Hydrol. Proc.*, 23: 893-906.
- Labat, D., Ababou, R. and Mangin A. (2000). "Rainfall–runoff relationships for karstic springs. Part II: continuous wavelet and discrete orthogonal multi-resolution analyses." *J. of Hydrol.*, 238: 149–178.
- Misiti, M., Misiti, Y., Oppenheim, G. and Poggi, J.M. (2000). "Wavelet Toolbox User's Guide, The Math Works." <[http://mathworks.com/help/pdf\\_doc/wavelet/wavelet\\_ug.pdf](http://mathworks.com/help/pdf_doc/wavelet/wavelet_ug.pdf)> (Sept. 28, 2013).
- Moriasi, D.N., Arnold, J.G., Van Liew M.W., Bingner, R.L., Harmel, R.D., and Veith, T.L. (2007). "Model evaluation guidelines for systematic quantification of accuracy in watershed simulations." *Am. Soc. of Ag. and Biol. Eng.*, 50: 885–900.
- Muller, B. and Reinhardt, J. (1991). "Neural Networks – An Introduction." Springer-Verlag, Berlin. <<http://books.google.com.tr/books?id=EFUzMYjOXk8C&printsec=frontcover&hl=tr&source=gbgsesummary&cad=0#v=onepage&q&f=false>> (Jun. 30, 2013).
- Mutlu, E., Chaubey, I., and Hexmoor, H. (2008). "Comparison of artificial neural network models for hydrologic predictions at multiple gauging stations in an agricultural watershed." *Hydrol. Proce.*, 22:5097–5106.
- Nash, J.E. and Sutcliffe, J.V. (1970). "River flow forecasting through conceptual models: Part I. A discussion of principle." *J. of Hydrol.*, 10: 282-290.
- Negnevitsky, M. (2005). "Artificial intelligence: a guide to intelligent systems." 2<sup>nd</sup> ed. Britain: Addison-Wesley.
- Nourani, V., Komasi, M. and Mano, A. (2009). "A Multivariate ANN-Wavelet Approach for Rainfall–Runoff Modeling." *Wat. Res. Manag.*, 23:2877–2894.
- Özger, M. (2010). "Significant wave height forecasting using wavelet-fuzzy logic approach." *Oc. Eng.*, 37:1443-1451.
- Parker, R., Arnold, J.G., Barrett, M., Burns, L., Carrubba, L., Crawford, C., Neitsch, S.L., Snyder, N.J., Srinivasan, R., and Williams, W.M. (2007). "Evaluation of three watershed-scale pesticide fate and transport

- models." *J. of Am. Wat. Res. Assoc.*, 43:1424-1443.
- Pereira-Filho, A.J. and dos Santos, C.C. (2006). "Modelling a densely urbanized watershed with an artificial neural network, weather radar and telemetric data." *J. of Hydrol.*, 317: 31-48.
- Rosenblatt, F. (1958). "The Perceptron: A Probabilistic Model for Information Storage and Organization in the Brain." Cornell Aeronautical Laboratory, Psychological Review, 65: 386-408.
- Rumelhart, D.E., Hinton, G.E. and Williams, R.J. (1986). "Learning representations by back-propagating errors." *Nature*, 323: 533-536.
- Seçkin, G., Akoz, M.S., Çobaner, M. and Haktanir, T. (2009). "Application of ANN techniques for estimating backwater through bridge constrictions in Mississippi River basin." *Adv. in Eng. Softw.*, 40: 1039-1046.
- Seçkin, N., Çobaner, M., Yurtal, R. and Haktanir, T. (2013). "Flood Flow at Ungauged Sites: the Case of East Mediterranean River Basin, Turkey." *Wat. Res. Manag.*, 27: 2103-2124.
- Shalamu, A.J., King, P.E. and Thomas, C.P. (2010). "Application of Partial Least-Squares Regression in Seasonal Streamflow Forecasting." *J. of Hydrol. Eng.*, 15: 612-623.
- Solomatine, D.P. and Dulal K.N. (2003). "Model trees as an alternative to neural networks in rainfall-runoff modeling." *Hydrol. Sci. Journ.*, 48: 399-411.
- Tiwari, M.K. and Chatterjee, C. (2010). "Development of an accurate and reliable hourly flood forecasting model using wavelet-bootstrap-ANN (WBANN) hybrid approach." *J. of Hydrol.*, 394: 458-470.
- United States Geological Survey (USGS). <<http://waterdata.usgs.gov>>. (Jun. 21, 2013).
- Viola, F., Pumo, D. and Noto, L.V. (2014). "EHSM: a conceptual ecohydrological model for daily streamflow simulation." *Hydrol. Proc.*, 28: 3361-3372.
- Wang, W., van Gelder, P.H.A.J.M., Vrijling, J.K. and Ma, J. (2006). "Forecasting Daily Streamflow Using Hybrid ANN Models." *J. of Hydrol.*, 324: 383-399.
- Wang, X., Melesse, A.M. (2005). "Evaluation of the SWAT model's snowmelt hydrology in a northwestern Minnesota watershed." *Trans. ASAE*. 48(4): 1359-1376.
- Webster, P.J. and Hoyos, C. (2004). "Prediction of monsoon rainfall and river discharge on 15-30-day time scales." <<http://dx.doi.org/10.1175/BAMS-85-11-1745>> (Sept. 24, 2013).
- Willmott, C. J. (1981). "On the validation of models." *Physic. Geog.*, 2: 184-194.
- Wu, C.L., Chau, K.W., and Fan C. (2010). "Prediction of Rainfall Time Series Using Modular Artificial Neural Networks Coupled with Data Pre-processing Techniques." *J. of Hydrol.*, 389: 146-167.
- Wu, C.L., Chau, K.W., and Li, Y.S. (2009). "Predicting monthly streamflow using data-driven models coupled with data pre-processing techniques." *Wat. Reso. Resea.*, 45:1-23.
- Zealand, C.M., Burn, D.H. and Simonovic, S.P. (1999). "Short term streamflow forecasting using artificial neural networks." *J. of Hydrol.*, 214: 32-48.

**Performance comparison of multilayer perceptron and wavelet-multilayer perceptron models in terms of daily streamflow prediction**

**Extended abstract**

*Accurate streamflow prediction is important for sustainable water resources management. Direct use of observed data in developing prediction models has resulted in inaccuracies and predictions are with short lead times. DWT was used to decompose the observed data into components with the objective of enhancing the prediction accuracy and prediction lead times. The decomposed data were used as input into multilayer perceptron (MP) to develop a new approach for predicting daily streamflow for lead times up to 7 days. The new approach was called Wavelet-Multilayer Perceptron (W-MP). Twelve years of approved daily streamflow data were obtained from Station 02231000, USA. Seven years of data were used for calibration and the remaining 5 years of data were used for prediction. The new approach was compared to the stand-alone MP model by taking root mean squared error, coefficient of efficiency and skill score into consideration. The results showed that the W-MP model performed better than the stand-alone MP model and the prediction accuracy increased with the use of decomposed signals up to prediction lead time of 4 days. This indicates that the W-MP model can predict daily streamflow better than MP with extended lead time.*

**Keywords:** Prediction, Multilayer Perceptron, Wavelet Transform, Streamflow