

Yapay Sinir Ağları, Destek Vektör Makineleri ve Box-Jenkins Yöntemleriyle Kentsel İçmesuyu Talebi Tahmini ve Karşılaştırmalı Analizi*

Recep Akdağ^a

Öz: Su talep tahminleri, yatırım planlamalarının yapılmasında, su sistemlerinin tasarımında (arıtma tesisi, depolama, iletim ve dağıtım hatları), mevcut sistemlerin optimal kapasitede işletilmesinde, işletme ve yatırım maliyetlerinin hesaplanması ve kentsel su yönetimi politikalarının (fiyatlandırma politikası, su tasarrufu vb.) belirlenmesi gibi birçok alanda kullanılmaktadır. Bu nedenle gerçeğe yakın bir su talep tahmininin, su sistemlerinin planlanması, tasarımı, işletimi ve yönetiminde anahtar niteliğinde olduğu söylenebilir. Bu çalışmada, Diyarbakır kent merkezi içme suyu talebinin Yapay Sinir Ağları ve zaman serisi analizine dayalı yöntemlerden Winters'in Mevsimsel Üstel Düzeltme ve Box-Jenkins ile tahmin edilmesi ve elde edilen tahminlerin karşılaştırılması amaçlanmıştır. Bu amaçla, öncelikle Diyarbakır kent merkezi su talebini etkileyen değişkenlerle ilgili 2003-2013 yıllarına ait aylık veriler toplanarak analiz edilmiştir. Ardından, bu verilere göre Yapay Sinir Ağları, Winters'in Mevsimsel Üstel Düzeltme ve Box-Jenkins yöntemleriyle içme suyu talep tahmini yapılmıştır. Üç yöntemden elde edilen tahminler, Verimlilik, Ortalama Hata Kareleri, Ortalama Hata Kareleri Kökü, Ortalama Mutlak Yüzde Hata ölçütlerine göre karşılaştırılmıştır. Karşılaştırma sonucunda, Yapay Sinir Ağları'nın tüm performans ölçütlerinde zaman serisi analizine dayalı yöntemlerinden daha iyi tahmin sonuçlarına sahip olduğu görülmüştür.

Anahtar Sözcükler: Su Talebi, Talep Tahmini, Yapay Sinir Ağları

JEL Sınıflandırması: C53, Q21, Q25

Urban Water Demand Forecasting and Comparative Analysis by Artificial Neural Networks, Support Vector Machines and Box-Jenkins Methods

Abstract: Water demand forecasting is currently being used in many fields such as the investment planning, the design of the water systems (treatment plants, storage, transmission and distribution lines), the operation of existing systems at optimal capacity, calculation of operation and investment costs, and determination of urban water management policies (pricing policy, water conservation, etc.). Therefore, it can be said that an accurate water demand forecast has a key role in the planning, design, operation, and management of water systems. In this study, it is aimed to forecast Diyarbakır city centre drinking water demand by using Artificial Neural Networks method and Winters's Seasonal Exponential Smoothing and Box-Jenkins methods based on time series analysis, and to compare forecasts obtained. For this purpose, firstly the data related to the variables affecting the water demand of Diyarbakır city centre for the time interval of 2003 – 2013 has been collected and analyzed. Then, a drinking water demand forecast has been made on the basis of this data by using Artificial Neural Network, Winters's Seasonal Exponential Smoothing, and Box-Jenkins methods. The forecasts obtained from these three methods have been compared according to Productivity, The Mean Square Error, The Root Mean Square Error and The Mean Absolute Percentage Error criteria. In comparison results, it was seen that, in all performance criteria, Artificial Neural Networks method has better forecast results than those methods based on time series analysis.

Keywords: Water Demand, Demand Forecasting, Artificial Neural Networks

JEL Classification: C53, Q21, Q25

^aAssist. Prof., PhD., Mardin Artuklu University, Higher School of Tourism and Hotel Management, Department of Gastronomy and Culinary Art, Mardin, Türkiye, recepakdag@artuklu.edu.tr

1. Giriş

Su talebi, kent sakinlerinin belirli bir zaman diliminde ihtiyaç duyduğu su miktarı olarak tanımlanabilir. Diğer bir ifadeyle su talebinin, bir kente verilen su miktarına eşdeğer olduğu ve su kayıplarını da içerdiği söylenebilir (Billings ve Jones, 2008). Su talebi, her zaman sabit değildir ve birçok değişken tarafından etkilenmektedir. Bu faktörlerin çoğu iklimsel ve sosyo-ekonomik değişkenler olmak üzere iki ana sınıfa ayrılmaktadır. İklimsel değişkenler su talebindeki kısa dönemli mevsimsel değişimleri, sosyo-ekonomik değişkenler ise uzun dönemli etkileri oluşturmaktadır (Adamowski, 2008).

Su talebini etkileyen faktörler için aşağıdaki gibi bir sınıflandırma yapılabilir:

- 1- Birey ve toplumsal özellikler: Su kullanım alışkanlığı, nüfus artış hızı, gelir düzeyi, enflasyon durumu, yapılaşma biçimi, konut büyüklüğü, ticari ve endüstri kuruluşlarının niteliği ve büyüklüğü gibi faktörler.
- 2- Temin edilen suyun özellikleri: Şebeke basıncı, suyun kalitesi, su fiyatı gibi faktörler.
- 3- Dış faktörler: Hava sıcaklığı, nem oranı, yağış sıklığı, iklim değişikliği gibi su tüketimine yön veren faktörler.

Su talep tahmini ise gelecekteki su ihtiyacını öngörmek için kullanılan bir yöntem bilim olarak tanımlanabilir (Froukh, 2001). Su talep tahmini, yatırım planlamalarının yapılmasında, su sistemlerinin tasarımında (arıtma tesisi, depolama, iletim ve dağıtım hatları), mevcut sistemlerin optimal kapasitede işletilmesinde, işletme ve yatırım maliyetlerinin hesaplanması ve kentsel su yönetimi politikalarının (fiyatlandırma politikası, su tasarrufu vb.) belirlenmesi gibi birçok alanda kullanılmaktadır. Gerçeğe yakın bir su talep tahmini, su sistemlerinin planlanması, tasarımı, işletimi ve yönetiminde anahtar niteliğindedir (Jain, Varshney ve Joshi, 2001).

Günümüze kadar su talep tahmini için regresyon analizi gibi nedensel yöntemler, üstel düzeltme ve Box-Jenkins gibi zaman serileri analizine dayalı yöntemler ile yapay sinir ağları ve bulanık mantık gibi yapay zeka teknikleri ve hibrid modeller kullanılmıştır. Bu konuda yapılan çalışmaların bazıları şöyledir: Jain vd. (2001) regresyon analizi, zaman serisi analizi ve Yapay Sinir Ağları (YSA) tekniklerini kısa dönemli su talep tahmininde uygulamış ve farklı iki hipotez ortaya atarak bu hipotezlerin geçerliliklerini araştırmışlardır. Jain ve Ormsbee (2002) regresyon analizi ve zaman serileri gibi geleneksel yöntemler ile uzman sistemler, yapay sinir ağları gibi zeki tekniklerin kısa dönemli su talep tahmininde kullanımını araştırmışlardır. Liu, Savenije ve Xu (2003) Çin'in Weinan kentinin evsel su talebini tahminlemek üzere tek gizli katmanlı bir YSA modeli geliştirmişlerdir. Modelde girdi değişkenleri olarak su fiyatı, hane geliri ve hane büyüklüğü kullanılmıştır. Bougadis, Adamowski ve Diduch (2005) Kanada'nın Ottawa kenti için kısa dönemli bir su talep tahmini modeli tasarlamışlar ve zaman serileri ile yapay sinir ağı modellerinin performansını karşılaştırmışlardır. Msiza, Nelwamondo ve Marwala (2007) Güney Afrika Cumhuriyeti'nin Gauteng kentinin kısa ve uzun dönemli su talep tahmini için günlük su talebi ve yıllık tahmini nüfus büyüklüklerinin değişken veri olarak kullanıldığı bir YSA modeli geliştirmişlerdir. Adamowski (2008) yaz mevsimindeki günlük su talep tahmini için Çoklu Doğrusal Regresyon (MLR), zaman serisi analizi ve YSA modellerini karşılaştırmalı olarak incelemiştir. Fırat, Yurdusev ve Mermer (2008) ekonomik ve iklim şartları vb. faktörleri dikkate alarak Uyarlamalı Sinirsel Bulanık Mantık (USBM) modeli ile aylık su tüketimini tahmini yapmışlardır. Ghiassi, Zimbra ve Saidane (2008) geleneksel geri yayımlı YSA modelinden farklı olarak dinamik YSA modeli (DAN2)'yi geliştirmişlerdir. Msiza, Nelwamondo ve Marwala (2008) Güney Afrika Cumhuriyeti'nin Gauteng kentinin su talep tahmini için YSA ile Destek Vektör Makineleri (SVMs) yöntemlerini kullanmışlardır. Yurdusev, Fırat, Mermer ve Turan (2009) ileri beslemeli ve radyal tabanlı sinir ağlarının, aylık su tüketim miktarının tahminine uygulanabilirliğini araştırmışlardır. Fırat, Yurdusev ve Turan (2009) aylık su tüketimi tahmininde, Genelleştirilmiş Regresyon Sinir Ağları (GRNN), Geri Bildirimli Sinir Ağları (FFNN) ve Radyal Tabanlı Sinir Ağları (RBNN) gibi çeşitli YSA tekniklerini karşılaştırmışlardır. Adamowski ve Karapataki (2010) Güney Kıbrıs'ın Nicosia kentinin Athalassa ve Public Garden bölgelerinde, çoklu doğrusal regresyon ve farklı öğrenme algoritmalarına sahip üç farklı tipteki çok katmanlı ve geri yayımlı YSA modelleri ile haftalık su talep tahmini yapmışlardır. Herrera, Torgo, Izquierdo ve Perez-Garcia (2010) YSA, Projeksiyon Araştırma Regresyonu (PPR), Çok Değişkenli Uyumlu Regresyon

Uzanımları (MARS), Rastgele Ormanlar (RF) ve Destek Vektör Regresyonu (SVR) tekniklerini saatlik su talep tahminine uygulamışlardır. Adamowski, Chan, Prasher, Zielinski ve Sliusarieva (2012) birleşik kesikli dalgacık dönüşümleri (WA) ile YSA'nın birleşiminden oluşan WA-ANN modelini geliştirmişlerdir. Ajbar ve Ali (2012) Suudi Arabistan'ın Mekke kentinin aylık ve yıllık su talep tahmini için bir sinir ağı modeli geliştirmiş, kısa ve uzun dönemli tahminler elde etmişlerdir. Mohammed ve Ibrahim (2012) kentsel su talep tahmini için dalgacık ve yapay sinir ağı yöntemlerine dayalı "Wavelet-ANN" hibrid modelini geliştirmiş ve ABD'nin Tampa kentine uygulamışlardır. Bennett, Stewart ve Beal (2013) iki ileri beslemeli geri yayımlı ağ ile bir radial tabanlı ağ olmak üzere üç geleneksel YSA ile Avustralya'nın Queensland bölgesindeki konutlar için son kullanım talebini araştırmışlardır.

Bu çalışmanın amacı, Diyarbakır kent merkezi içme suyu talebini YSA, Winters'in Mevsimsel Üstel Düzeltme ve Box-Jenkins yöntemleri ile tahmin etmek ve karşılaştırmalı analizler yapmaktır. Bu amaçla, literatüre dayalı olarak aylık su talep tahmininde kullanılan değişkenlere dair veriler toplanmış ve veri seti oluşturulmuştur. Ardından yöntemlerle dair en uygun modeller belirlenerek aylık su talep tahminleri yapılmıştır. Son olarak, yöntemlerden elde edilen tahminlerin performansı karşılaştırılmış ve en iyi performansa sahip yöntem kullanılarak geleceğe yönelik 2014 Nisan-Aralık dönemi aylık su talep tahminleri yapılmıştır. Çalışmanın izleyen bölümleri şöyle yapılandırılmıştır.

2. Çalışma Alanı

Çalışmanın uygulandığı alan, Türkiye'nin güneydoğusunda bulunan Diyarbakır ili kent merkezidir. İlin kent merkezi, belediye hizmet sınırlarıdır ve bu alanda yaklaşık 1 milyon kişi yaşamaktadır. Diyarbakır'da su hizmetini, Büyükşehir Belediyesi'ne bağlı kuruluş olan Diyarbakır Su ve Kanalizasyon İdaresi Genel Müdürlüğü (DİSKİ) yerine getirmektedir. Kent merkezine içme suyu temini, Dicle Baraj Gölü ve Gözeli Yer Altı Suyu Havzası olmak üzere iki su kaynağından yapılmaktadır. Dicle baraj gölündeki işlenmemiş su, pompa istasyonundaki pompalar yardımıyla, 32,1 km. uzunluğundaki isale hattıyla Hamsu Arıtma Tesisi'ne iletilmektedir. Arıtma Tesisi, günlük 255.000 m³ arıtma kapasitesi ile kentin büyük bir kısmının içme suyu ihtiyacını karşılamaktadır. Örneğin 2013 yılında kente Arıtma Tesisi'nden 66.695.227 m³ su verilmiş ve böylelikle kent merkezinin %93,14'lük su ihtiyacı karşılanmıştır. Gözeli Yer Altı Suyu Havzası'nda ise 16 aktif kuyu bulunmakta ve toplamda ortalama 250 lt/sn, kaynaktan ise maksimum 200 lt/sn su temin edilmektedir. Yine 2013 yılında Gözeli Yer Altı Suyu Havzası'ndan kente %6,86 oranıyla 4.915.553 m³ su temin edilmiştir (DİSKİ, 2014).

Kent merkezinde farklı kapasitelere sahip 10 adet depo bulunmaktadır ve toplam depolama kapasitesi 165.000 m³tür. İçme suyu şebekesi uzunluğu 1.906 km.dir. Şebekenin işletilmesinde, SCADA (Supervisory Control And Data Acquisition) olarak bilinen "Uzaktan Kontrol ve Gözleme Sistemi" ve Coğrafi Bilgi Sistemi (CBS) gibi sistemler kullanılmaktadır. Diyarbakır'daki içme suyu hizmeti sunumunda en önemli problemlerin başında su kaybı gelmektedir. Sisteme verilen su ile izinli tüketim arasındaki fark, %55 civarında olup 2013 yılı sonu itibarıyla %56,9 olarak gerçekleşmiştir. Diğer bir önemli problem ise su kaynaklarının uzak mesafeden temin edilmesi nedeniyle suyun iletimindeki yüksek enerji maliyetidir (DİSKİ, 2014).

3. Veri ve Yöntem

Yapılan literatür incelemesinde, içme suyu talep tahminini etkileyen faktörlerin tahmin dönemine göre farklılık gösterdiği tespit edilmiştir. Örneğin günlük su talep tahmininde kullanılan değişkenler, aylık ve yıllık talep tahmininde kullanılan değişkenlerden farklılık göstermektedir. Buna göre, literatürde aylık içme suyu talep tahmininde en çok kullanılan on faktör belirlenmiştir. Bu faktörler niteliklerine göre Tablo 1'de gösterilmiştir.

Tablo 1. Aylık İçme Suyu Talep Tahmini İçin Literatürde En Çok Kullanılan Faktörler

Değişken Tanımı	Birimi	Niteliği	Türü
Ortalama Hava Sıcaklığı	(°C)	İklim	Girdi
Ortalama Yağış Miktarı	(kg/m ²)	İklim	Girdi
Ortalama Nisbi Nem	(%)	İklim	Girdi
Kent Merkezi Nüfusu	Kişi	Demografik	Girdi
Ortalama Hane Halkı Büyüklüğü	Kişi	Demografik	Girdi
Tüketici Fiyat Endeksi (TÜFE)	(%)	Ekonomik	Girdi
Kişi Başı Gayri Safi Yurtiçi Hasıla	TL	Sosyo-Ekonomik	Girdi
Su Fiyatı	TL/m ³	Sosyo-Ekonomik	Girdi
Kişi Başına Düşen Su Faturası Tutarı	TL/Kişi	Sosyo-Ekonomik	Girdi
Eğitim Düzeyi (Okuma-Yazma Oranı)	(%)	Sosyo-Ekonomik	Girdi
Su Talebi (Tüketimi)	m ³	Sosyo-Ekonomik	Çıktı

Çalışmada veri seti, Tablo 1’de belirtilen değişkenlere ait 2003-2013 yılları aylık verilerinden oluşmaktadır. Ancak belirtilen değişkenlerden ortalama hane halkı büyüklüğü, kişi başı GSYH ve okuma yazma oranına ait veriler elde edilemediğinden veri setine dahil edilememiştir. Böylelikle veri seti, yedi girdi ve bir çıktı değişkeninden oluşmakta ve her bir değişkene ait on bir yıllık (132 ay) veri bulunmaktadır. Bu yapıyla veri seti, 8 sütun ve 132 satırdan oluşan bir matrise benzetilebilir. Elde edilen verilerin ayrık (anomaly) değerlerinin tespiti aşamasında, Ortalama Yağış Miktarı değişkeninin 2011 yılı Nisan ayı değerinin ayrık değer olduğu tespit edilmiş ve bu aya ait değerler veri setinden çıkarılmıştır. Nihai olarak, veri seti 8 değişkene ait 131 aylık veriden oluşmaktadır.

Çalışmada kullanılan değişkenlere ait verilerin yapısını daha iyi anlamak için verilere dair temel istatistikler olan minimum, maksimum, ortalama ve standart sapma değerleri hesaplanmış ve Tablo 2’de verilmiştir.

Tablo 2. Girdi ve Çıktı Değişkenlerine Ait Temel İstatistikler

Girdi ve Çıktı Değişkenleri	Minimum Değer	Maksimum Değer	Ortalama Değer	Standart Sapma
Ortalama Hava Sıcaklığı (S)	-5,1	32,3	16,0	10,4
Ortalama Yağış Miktarı (Y)	0	160,8	36,3	35,2
Ortalama Nisbi Nem (N)	10,7	87,3	49,6	22,4
Kent Merkezi Nüfusu (NF)	654.116	876.144	764.887	75.753
TÜFE (E)	-1,43	3,27	0,67	0,77
Su Fiyatı (F)	1,21	3,41	2,27	0,64
Abone Başına Düşen Su Faturası Tutarı (FT)	10,1	49,1	25,5	8,3
Su Talebi (ST)	3.647.000	7.684.417	5.107.317	867.508

3.1. Çalışmada Kullanılan Yöntemler


Çalışmada, Yapay Sinir Ağları, Destek Vektör Makineleri ve Box-jenkins yöntemleri kullanılmıştır. Bu bölümde kullanılan yöntemlere dair bilgiler verilmiştir.

3.1.1. Yapay Sinir Ağları

Yapay sinir ağları, biyolojik sinir ağlarından esinlenilerek ortaya çıkarılan ve biyolojik sinir ağlarına benzer bazı performans özellikleri içeren bir bilgi işleme sistemidir (Fausett, 1994). Yapay sinir ağları kavramı beynin çalışma ilkelerinin sayısal bilgisayarlar üzerinde taklit edilmesi fikri ile ortaya çıkmış ve ilk çalışmalar beyni oluşturan biyolojik hücrelerin, ya da literatürdeki ismiyle nöronların matematiksel olarak modellenmesi üzerine yoğunlaşmıştır (Efe ve Kaynak, 2000: 1).

Yapay sinir ağı tasarımının esasını oluşturan bir sinir ağı modeli, matematiksel olarak aşağıda Şekil 1'de gösterilmiştir.

Şekil 1. Yapay Sinir Ağı Modelinin Matematiksel Gösterimi



Kaynak: Haykin, 1999.

Şekil 1'de görülen, x_1, x_2, \dots, x_n giriş verileri; $w_{k1}, w_{k2}, \dots, w_{kn}$ k nöronunun sinaptik ağırlıklarıdır. u_k giriş verilerine göre doğrusal olarak birleştirilmiş çıktıdır. b_k bias, $\varphi(\cdot)$ aktivasyon fonksiyonu ve y_k sinir ağının çıkış sinyalidir. Buradaki bias b_k doğrusal birleştiricisi u_k çıkışını öngörülen şekilde etkiler. Matematiksel olarak bir nöron (k) aşağıdaki eşitliklerdeki gibi tanımlanabilir.

$$u_k = \sum_{j=1}^m w_{kj} x_j \quad (1)$$

$$y_k = \varphi(u_k + b_k)$$

Yapay sinir ağları, beynin bilişsel öğrenme sürecinin benzetimi ile geliştirilmiş bir yöntem olarak bilinmektedir. Karmaşık problemlerde oldukça etkili olduğu görülmüştür. Tahminleme, sınıflandırma, kümeleme gibi birçok probleme çözüm bulabilmektedir. Sinir ağlarının en önemli özelliği, karmaşık sistemlerin geçmiş bilgilerinden yola çıkarak, örnek üzerinde öğrenme yolu ile probleme çözüm getirebilmesi yeteneğidir (Efendigil vd., 2009: 6699). Geleneksel yöntemler, yanlış sonuçların elde edilmesi riski nedeniyle eksik ve/veya aşırı sapma içeren veriler için uygun değildir. Yapay sinir ağı yaklaşımı ise, verilere bağlı olmayıp; eksik, kısmen hatalı veya aşırı sapmalı verileri değerlendirebilir, hatta karmaşık ilişkileri öğrenebilir, genellebilir ve bu sayede daha önce hiç karşılaşmadığı sorulara kabul edilebilir bir hatayla cevap bulabilirler. Bu özellikleri nedeniyle yapay sinir ağları tahminlemede etkili bir yöntem olarak kullanılmaktadır (Özalp ve Anagün, 2003: 30).

3.1.2. Destek Vektör Makineleri (DVM)

Destek vektör makineleri, sınıflandırma ve regresyon analizinde kullanılan, verileri analiz eden ve örneklerden öğrenen denetimli bir öğrenme yöntemidir. DVM, ilk kez, Vladimir Vapnik ve çalışma arkadaşları tarafından COLT-92 (Computational Learning Theory) konferansında önerilmiş olup, günümüzde kullanılan şeklini, Corinna Cortes ve Vladimir Vapnik tarafından 1995 yılında almıştır. 1997 yılında ise, DVM algoritması yine Vapnik ve arkadaşları tarafından regresyon uygulamalarını da kapsayacak şekilde genişletilmiş ve bu tarihten itibaren son on yılda gelişen bilgisayar teknolojisi sayesinde artarak kullanılmaya başlanmıştır (Bilişik, 2011: 788).

Regresyon problemlerinde, sistem kapasitesi uzay boyutuna bağlı olmayan bir parametre tarafından kontrol edilirken, doğrusal olmayan bir fonksiyon uyarılmış öznelik uzayında bir çekirdekteki (kernel) doğrusal öğrenme makinesi aracılığıyla öğrenir. Regresyon problemlerinde DVM'nin işleyiş sürecinde, Destek Vektör Regresyonu (DVR)'ye başvurulur. DVR'de temel fikir, girdi uzayındaki x 'in doğrusal olmayan yüksek boyutlu öznelik uzayına $\Phi(x)$ 'e dönüştürülmesidir. Bir eğitim seti ile bir girdi ve bir çıktıya sahip olduğumuzu varsayalım: $\{(x_1, y_1); (x_2, y_2) \dots (x_l, y_l)\}$. Eğitim girdilerini, eğitim çıktılarına dönüştürecek bir $f(x)$ fonksiyonu bulmak istiyoruz. Destek vektöründeki regresyonda, gerçek eğitim hedeflerinden y_i en çok sapmaya ε sahip olan fonksiyonu araştırıyoruz. Eğitim girdilerini eğitim çıktılarına dönüştürecek çok çeşitli fonksiyonlar bulabiliriz. Bu fonksiyonlar çekirdek (kernel) fonksiyonlar olarak bilinir. Burada, örnek olarak doğrusal kernel fonksiyonunun denklemi verilebilir:

$$f(x) = \langle w, \Phi(x) \rangle + b \quad (2)$$

Yukarıdaki denklemde b eşik değeridir. b ve sabit w , ampirik risk ve karmaşıklık ifadelerinin toplamının minimize edilmesiyle tahmin edilir. Ampirik risk ve karmaşıklık boyutu aşağıda (4) no'lu denklemde gösterilmiştir.

$$R_{reg} [f] = R_{emp} [f] + \lambda \|w\|^2 = C \sum_{i=1}^Z (f(x_i) - y_i) + \lambda \|w\|^2 \quad (3)$$

Yukarıda denklemde ise ilk terim ampirik riski ikinci terim ise karmaşıklık boyutunu ifade etmektedir. Ayrıca, Z örnek büyüklüğü, $C(\cdot)$ maliyet fonksiyonu ve λ düzenleme sabitidir. $\|w\|$ ise Öklid standardıdır (Cristianini ve Shawe-Taylor, aktaran Msiza vd., 2008: 3-4).

3.1.3. Box-Jenkins Yöntemi

Box-Jenkins yöntemi tek değişkenli bir model olarak, geleceği tahmin etme yöntemlerinden biridir. Kısa dönem tahmininde oldukça başarılı olan bu yöntemin uygulandığı serinin, eşit zaman aralıklarıyla elde edilen gözlem değerlerinden oluşan kesikli ve durağan bir seri olması en önemli varsayımdır.

Box-Jenkins yönteminin ihtiva ettiği modeller; zamana bağlı tesadüfi karakterde olaylar ve bu olaylarla ilgili zaman serilerinin ise stokastik süreç olduğu varsayımına dayalı olarak geliştirilmiştir. Ayrıca iç bağımlılık (otokorelasyon) en etkili biçimde dikkate alınmaktadır. Bu özelliklerinden dolayı Box-Jenkins modelleri doğrusal durağan stokastik modeller olarak nitelendirilmektedir (Bircan ve Karagöz, 2003: 50). Bu yöntemin temel vurgusu, zaman serilerini yalnızca kendi geçmiş değerleri ve stokastik hata terimi ile açıklamaktır. Herhangi bir iktisat kuramına dayanmayan ve " bırakın da veriler kendi adlarına konuşsun" mantığı ile oluşturulan bu modellere kuramsız (atheoric) modeller de denmektedir (Yalta, aktaran Çuhadar, 2014: 8).

Box-Jenkins yöntemine dair modeller, mevsimsel ve mevsimsel olmayan modeller şeklinde ikiye ayrılmaktadır. Mevsimsel olmayan Box-Jenkins modelleri genel olarak ARIMA¹ (p,d,q) şeklinde gösterilir.

Burada p , otoregresyon (AR) modelinin derecesi, d , fark alma işlemi sayısı ve q , hareketli ortalama (MA) modelinin derecesini ifade etmektedir. Mevsimsel Box-Jenkins modelleri ise genellikle $ARIMA(p,d,q)(P,D,Q)_s$ biçiminde gösterilir. Burada P , mevsimsel otoregresyon (SAR) modelinin derecesi, D , mevsimsel fark alma işlemi sayısı, Q , mevsimsel hareketli ortalama (SMA) modelinin derecesi ve s , periyot anlamını taşımaktadır (Kadılar, 2005: 185).

ARIMA modelinin matematiksel denklemi şöyledir:

$$F_t = \phi_1 y_{t-1} + \phi_2 y_{t-2} + \dots + \phi_p y_{t-p} + \Delta^d y_t + \phi_1 \varepsilon_{t-1} + \dots + \phi_q \varepsilon_{t-q} \quad (4)$$

Eşitlik'te; ϕ_p , gecikmeli değerlerin şimdiki değerle olan ilişkisini temsil eden parametreyi, Δ^d , Δ fark alma operatörünü, d fark alma derecesini, ϕ_q , herhangi bir dönemdeki gözlem değeri ile aynı döneme ve geçmiş dönemlere ait hata terimleri arasındaki ilişkiyi gösteren parametreyi, ε_t , hata terimini (sıfır ortalamalı ve sabit varyansa sahip korelasyonsuz tesadüfi değişken) ifade etmektedir.


4. Tahmin Uygulaması ve Karşılaştırma

4.1. Yapay Sinir Ağları İle Tahmin

YSA modelinin geliştirilmesinde, literatürde en çok tercih edilen ileri beslemeli geri yayımlı bir sinir ağı algoritması kullanılmıştır. Bu algoritmanın tercih edilmesinin nedeni, doğrusal ve doğrusal olmayan modellerdeki tahmin başarısı, kullanım kolaylığı ve yakınsama hızının yüksek olmasıdır. YSA ile çok dönemli tahminler yapılırken; tek dönemli iteratif yaklaşım ve birden fazla dönemin aynı anda tahminlemesinin yapıldığı direkt yöntem olmak üzere iki farklı yaklaşım kullanılabilir (Karahana, 2011: 140). Çalışmada, YSA ile tahmin yapılırken dönemler teker teker tahmin edildiği için iteratif yaklaşım benimsenmiştir. Modelin tasarımı, Alyuda Research Inc. tarafından geliştirilen, Alyuda NeuroIntelligence 2.2 paket programıyla yapılmış yine modelin eğitimi, testi ve modelden tahmin üretimi gibi tüm aşamalar bu yazılım ile gerçekleştirilmiştir.

Veri seti; eğitim (training), doğrulama (validation) ve test (test) olmak üzere üç alt sete ayrılmıştır. Eğitim seti, %68'e karşılık gelen 91 ay, doğrulama ve test setleri ise %16'lık dilimler halinde 20 aydan oluşmaktadır. Verilerin belirtilen oranlarda alt setlere atanmasında ise rastgele (random) ve ardışık (sequential) yöntemlerinden, rastgele yöntem tercih edilmiştir. Öğrenme algoritması olarak, Carnegie Mellon Üniversitesi'nden Scott E. Fahlman tarafından geliştirilen ve genel amaçlı kullanılan Hızlı Yayılım (Quick Propagation) tercih edilmiştir. Hızlı Yayılım algoritmasına, diğer öğrenme algoritmalarıyla yapılan denemelerde daha iyi sonuçlar elde edilmesi sonucunda karar verilmiştir. Hızlı Yayılım algoritması, Newton metoduna dayanan ve çok katmanlı sinir ağlarının eğitilmesinde kullanılan sezgisel bir öğrenme algoritmasıdır (Tozkan, 2004: 41). En uygun ağ mimarisini belirlemede ayrıca, gizli ve çıktı katmanları aktivasyon fonksiyonları içinde yaygın kullanım alanı olan sürekli ve doğrusal olmayan lojistik (sigmoid) fonksiyonu tercih edilmiştir.

Ağın girdi katmanında, ağa sunulan yedi bağımsız değişkene ait yedi adet girdi işlemci elemanı, çıktı katmanında ise bağımlı değişkene ait bir adet çıktı işlemci elemanı bulunmaktadır. Gizli katman sayısı ve gizli katmanda yer alacak nöron sayısının belirlenmesi için yapılan denemeler sonucunda iki gizli katman kullanımına karar verilmiştir. Ayrıca tüm denemelerde TÜFE değişkeninin çıktı değişkeni üzerinde etkisinin %0-1 düzeyinde çok düşük olduğu görülmüştür. Bu nedenle TÜFE değişkeninin, girdi değişkenlerinden çıkarılmasına karar verilerek denemelere altı girdi değişkeni ile devam edilmiştir. Gizli katmanlardaki işlemci sayısının tespit edilmesi amacıyla yukarıda belirtilen yöntemle birçok deneme yapılmış ve nihayetinde birinci gizli katmanda altı, ikinci gizli katmanda üç işlemci eleman kullanımının en uygun ağ mimarisini oluşturacağı sonucuna varılmıştır. Böylelikle en uygun ağ mimarisi Şekil 2'de görüldüğü gibi [6-6-3-1] olarak belirlenmiştir.

Şekil 2. İçme Suyu Talep Tahmini İçin Tasarlanan YSA Mimarisi

En uygun YSA mimarisinin oluşturulmasından sonra modelin eğitim ve test aşamalarına geçilmiştir. Ağın eğitimi aşamasında, ağın ürettiği tahminlenen değer ile gözlem değerleri arasındaki farktan oluşan sapma veya hataların minimum olduğu esnada ağın yeterince öğrendiği varsayılmaktadır. Eğitim aşamasında ağ, 619. iterasyonda öğrenmeyi tamamlamış, diğer bir ifadeyle en iyi öğrenmeyi sağlamıştır. Test aşamasında ise eğitim, doğrulama, test ve tüm veri setinin performans değerleri elde edilmiştir. Performans değerlendirme sonuçları Tablo 3'te verilmiştir.


Tablo 3. YSA Veri Setleri Performans Değerlendirme Sonuçları

	Mutlak Hata (Absolute Error)			
	Eğitim Seti	Doğrulama Seti	Test Seti	Tüm Veri Seti
Ortalama	138.625	225.629	295.313	175.830
Standart Sapma	108.864	212.682	226.359	162.610
Minimum Değer	2.040	140	35.003	140
Maksimum Değer	454.323	781.617	785.141	785.141
Korelasyon Katsayısı	0,978	0,957	0,878	0,961
Determinasyon Katsayısı (R ²)	0,954	0,894	0,735	0,916

Tablo 3'te görüldüğü gibi, eğitim, doğrulama ve test setleri içinde ortalama mutlak hata değeri, en düşük eğitim setinde yer almakta, bunu doğrulama seti ve test seti takip etmektedir. Minimum mutlak hata değeri ise sırasıyla doğrulama seti, eğitim seti ve test setinde yer almaktadır. Maksimum mutlak hata ise sırasıyla, test seti, doğrulama ve eğitim setindedir. Korelasyon katsayılarına bakıldığında ise eğitim ve doğrulama setlerinde %95'in üzerinde bir korelasyon değeri görülmektedir. Test setinin korelasyon değeri %88 olmakla beraber tüm veri setinin korelasyon değeri %96 ile yüksek seviyededir. Korelasyon değerleri, su talebine ait gözlem değerleri ile elde edilen tahmin değerleri arasında pozitif yönde güçlü bir ilişkinin olduğunu göstermektedir. Ayrıca tüm veri setine ait determinasyon katsayısı (R²) de %91,6 ile tahmin edilen değerlerdeki değişkenliğin, gözlem değerlerindeki değişkenlikle açıklanabileceğini göstermektedir. YSA modelinin oluşturulması, modelin eğitimi ve test aşamalarında girdi değişkenlerinin 2003-2013 değerlerine

göre her bir aya ait tahmin değerleri elde edilmiştir. Elde edilen talep tahmini değerleri ile gözlem değerlerine ait zaman grafiği Şekil 3'te verilmiştir.

Şekil 3. Gözlenen Talep ve YSA ile Tahminlenen Talep Grafiği



Şekil 3 incelendiğinde, özellikle 2005 yılının yarısından 2011 yılının yarısına kadar YSA modeli ile elde edilen tahmin değerlerinin gözlem değerlerine oldukça yakın olduğu, diğer yıllarda ise belirgin sapmaların olduğu görülmektedir.


4.2. Destek Vektör Makineleri ile Tahmin

DVM ile tahmin, regresyon analizlerinde kullanılan Destek Vektör Regresyonu ile yapılmıştır. DVR'de bağımlı değişken ile birden fazla bağımsız değişken arasındaki doğrusal olmayan ilişkiler modellenmektedir. DVR ile tahmin uygulaması STATISTICA Version 12 paket programı ile yapılmıştır. Paket programa öncelikle veriler yüklenmiş, ardından bağımlı ve bağımsız değişkenler tanımlanmıştır. Programın varsayılan değerlerine göre, veri setinin %75'i eğitim, %25'i test örnekleri rastgele (random) olarak ikiye ayrılmıştır. Kernel tipi, doğrusal (linear), polinomial, Radial Basis Function (RBF) ve sigmoid olmak üzere tüm kernel fonksiyonları tek tek denenmiş ve en iyi sonucu RBF'nin verdiği görülmüştür. Bu nedenle kernel tipi olarak RBF seçilmiştir. RBF parametrelerinin (C ve γ) optimize edilmesinde ve aynı zamanda aşırı öğrenmenin (overfitting) önlenmesi için çapraz geçerlilik (cross-validation) yöntemi uygulanmıştır. 10 kat (v-fold) çapraz geçleme yapılarak en uygun C parametresi 1-10 aralığında aranmıştır. Bu işlemler sonucunda elde edilen modele dair bilgiler aşağıdaki Tablo 4'te verilmiştir.

Tablo 4. DVM Modeline Dair Bilgiler

SVM Type	Regression (C=10,000, epsilon=0,100)
Kernel Type	Radial Basis Function (gamma=0,143)
Number of Support Vectors	48 (35 bounded)

En uygun DVM modelinin elde edilmesinin ardından su talebi değişkenlerine ait gözlem değerlerinden tahminler üretilmiştir. Elde edilen talep tahmin değerleri ile gözlem değerleri Şekil 4'te verilmiştir.

Şekil 4. Gözlenen Talep ve DVM ile Tahminlenen Talep Grafiği

Şekil 4'te DVM ile tahminlenen talep ile gözlenen talebe ait grafik incelendiğinde, tahminlenen talebin özellikle yaz ve kış pik değerlerinde gözlenen talepten sapma gösterdiği, 2003-2005 yılların dışında diğer dönemlerde gözlenen talebe yaklaştığı söylenebilir.

4.3. Box-Jenkins Yöntemi ile Tahmin

Box-Jenkins yöntemine dair ARIMA modelleri, daha önce belirtildiği gibi yalnızca durağan olan serilere uygulanabilmektedir. Su talebi serisinin trend ve mevsimsellik içermesi nedeniyle öncelikle durağan hale getirilmesi gerekmektedir. Durağanlığın sınanması için literatürde sık başvurulan Genişletilmiş Dickey-Fuller (Augmented Dickey-Fuller: ADF) testi uygulanmıştır. ADF test sonuçları aşağıda Tablo 5'te verilmiştir.

Tablo 5. Genişletilmiş Dickey-Fuller Testi Sonuçları

	t-İstatistiği	Olasılık*
Genişletilmiş Dickey-Fuller test istatistiği	-0.082220	0.9479
Test kritik değerleri		
1% düzey	-3.486064	
5% düzey	-2.885863	
10% düzey	-2.579818	


*MacKinnon (1996) tek taraflı p değerleri

Tablo 5'te görüldüğü gibi, ADF test istatistiği değeri (0.082220) mutlak değerce, test kritik değerlerinden (3.486064, 2.885863 ve 2.579818) küçük olduğu için serinin durağan olmadığı anlaşılmaktadır. Durağanlığın sağlanması için 1 kez mevsimsel fark ($D=1$) ve 1 kez de mevsimsel olmayan fark ($d=1$) alınmıştır. ADF testi ve durağanlık analizlerinden elde edilen sonuçlara göre, serinin mevsimsel ve mevsimsel olmayan otoregresyon (AR) ve hareketli ortalama (MA) modellerinin dereceleri belirlenmiştir. Durağanlığın sağlanmasıyla birlikte AR ve MA modellerinin derecelerine göre, literatürde Çarpımsal-Mevsimsel ARIMA modeli olarak tanımlanan ARIMA (1,1,2)(1,1,3)₁₂ modeli elde edilmiştir. Ancak modelin uygunluğuna tam olarak karar verebilmek için model artıklarının (residuals) rassal olup olmadığı ve aralarında otokorelasyon olup olmadığı araştırılmalıdır. Bu amaçla, elde edilen modelin artıklarına ait otokorelasyon ve kısmi otokorelasyon fonksiyonlarına ait grafik Şekil 5'te verilmiştir.

Şekil 5. ARIMA Modeline Ait Artıkların Otokorelasyon ve Kısmi Otokorelasyon Grafiği

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob	
		1	-0.023	-0.023	0.0651	0.799
		2	0.014	0.013	0.0881	0.957
		3	-0.030	-0.029	0.1988	0.978
		4	0.005	0.004	0.2020	0.995
		5	0.002	0.003	0.2024	0.999
		6	-0.053	-0.054	0.5566	0.997
		7	-0.011	-0.013	0.5717	0.999
		8	-0.149	-0.148	3.4394	0.904
		9	0.094	0.086	4.5892	0.869
		10	0.030	0.037	4.7048	0.910
		11	0.032	0.023	4.8374	0.939
		12	0.009	0.014	4.8485	0.963
		13	-0.121	-0.127	6.8475	0.910
		14	0.175	0.165	11.036	0.683
		15	-0.032	-0.025	11.179	0.740
		16	0.081	0.061	12.096	0.737
		17	0.021	0.067	12.158	0.790
		18	0.050	0.046	12.518	0.819
		19	-0.020	-0.019	12.577	0.860
		20	0.041	0.049	12.819	0.885
		21	-0.027	-0.063	12.924	0.911
		22	-0.030	0.048	13.060	0.931
		23	-0.002	-0.027	13.060	0.951
		24	0.002	0.028	13.061	0.965
		25	0.136	0.146	15.885	0.918
		26	-0.045	-0.073	16.193	0.931
		27	-0.097	-0.083	17.664	0.913
		28	-0.002	-0.026	17.664	0.934
		29	-0.032	-0.042	17.825	0.948
		30	0.043	0.051	18.122	0.957
		31	-0.025	-0.022	18.226	0.967
		32	-0.063	-0.097	18.891	0.968
		33	-0.016	0.041	18.932	0.976
		34	0.003	-0.102	18.934	0.983
		35	0.250	0.282	29.645	0.724
		36	0.008	-0.009	29.656	0.763

Şekil 5'te korelasyon katsayılarının %95 güven sınırları içerisinde kaldığı, sadece birinin (35. ay) bu sınırlar dışına çıktığı görülmektedir. Buna göre, model artıklarının bağımsız dağıldığı ve bu nedenle belirlenen modelin uygunluğunun sağlandığı söylenebilir. Ancak, model uygunluğunun testi için ayrıca literatürde oldukça sık kullanılan Ljung-Box (LB) Q istatistiğinden de yararlanılabilir. Ljung-Box Q istatistiğinde, model artıkları arasında otokorelasyon olup olmadığına dair, tüm otokorelasyon katsayılarının aynı anda sıfır olduğu hipotezi test edilir. Bu teste göre, mevsimsel modeller için K gecikmesindeki Q değeri, K-p-q-P-Q serbestlik derecesinde X^2 (ki-kare) tablo değerinden küçük ise tüm oto korelasyon katsayılarının sıfır olduğu hipotezi kabul edilir (Saygılı, 2008: 24). Şekil 5'te görüldüğü gibi örneğin K=18 için Q değeri, 12,518'dir. K-p-q-P-Q serbestlik derecesinde (18-1-2-1-3=11) X^2 tablo değeri ise 19,675'dir. X^2 tablo değeri Q'dan büyük olduğu için model artıklarının tesadüfi dağıldığı sonuca varılabilir. Ljung-Box Q istatistiğinden elde edilen sonuçlar, model artıklarının tesadüfi dağıldığını ve modelin uygun olduğunu göstermiştir. ARIMA (1,1,2)(1,1,3)₁₂ modelinin uygunluğunun test edilmesinin ardından SPSS 18.0 paket programıyla su talebi değişkeni gözlem değerlerinden tahminler üretilmiştir. Elde edilen talep tahmin değerleri ile gözlem değerleri Şekil 6'da verilmiştir.

Şekil 6. Gözlenen Talep ve ARIMA Modeli ile Tahminlenen Talep Grafiği

Şekil 6’da görüldüğü gibi, ARIMA modeli ile tahminlenen talep değerlerinin ilk on üç ayına ait değerler bulunmamaktadır. Bunun nedeni, zaman serisinin birinci farkı ve mevsimsel farkının alınması sonucu bu aylara ait değerlerin hesaplanmamasıdır. Ayrıca, 2009-2013 yılları arasındaki beş yılda ARIMA modeli ile elde edilen tahmin değerlerinin gözlem değerlerine olan yakınlığının diğer yıllara göre daha fazla, yani daha az sapmaya sahip olduğu söylenebilir.

4.4. Karşılaştırma Ölçütleri

Tahminlerin performans değerlendirilmesi ile ilgili literatürde birçok ölçüt kullanılmaktadır. Uygulamada, tahmin çalışmalarında en çok kullanılan ölçütlerden Verimlilik Katsayısı (E), Hata Kareleri Ortalaması (MSE), Hata Kareleri Ortalaması Kökü (RMSE), Ortalama Mutlak Yüzde Hata (MAPE), Korelasyon Katsayısı (CORR) ve Determinasyon Katsayısı (R^2) kullanılmıştır. Bu ölçütlerden Verimlilik Katsayısı (E) aşağıdaki eşitliklerle hesaplanır. Eşitliklerde $x(t)$, tahmin değerlerini $f(t)$ ise gözlenen değerlerini ifade etmektedir.

$$E = \frac{E_1 - E_2}{E_1}$$

$$E_1 = \sum_{i=1}^N \left(f(t) - \overline{f(t)} \right)^2 \quad (5)$$

$$E_2 = \sum_{i=1}^N \left(x(t) - f(t) \right)^2$$

Tahminlerin performans ölçümünde Verimlilik Katsayısı (E), bir modelin tahmin gücünü değerlendirmede kullanılmaktadır. Hesaplanan E değeri 1 ise tahminlenen değerlerin gözlenen değerlere mükemmel derecede uyum gösterdiğine, E değeri 0 ise model tahminlerinin, gözlenen değerlerin ortalaması kadar doğrulukta olduğuna işaret etmektedir (Adamovski vd., 2012). Tahmin çalışmalarında genellikle Verimlilik Katsayısı (E)’nin yüksek değerde olması beklenir.

MSE, RMSE ve MAPE ölçütlerinin hesaplanabilmesi için öncelikle elde edilen tahmin değerleri $x(t)$ ile gözlenen değerler $f(t)$ arasındaki fark miktarı $e(t)$ ile fark yüzdesi $p(t)$ ’nin hesaplanması gerekmektedir.

$$e(t) = x(t) - f(t)$$

$$p(t) = e(t) / x(t)$$

$$MSE = \frac{1}{n} \sum [e(t)]^2$$

(6)

$$RMSE = \sqrt{\frac{1}{n} \sum [e(t)]^2}$$

$$MAPE = \frac{1}{n} \sum |p(t)| \times 100(\%)$$

MSE, hata karelerinin ortalaması olarak hesaplanmaktadır ve talep tahminlerinin performans ölçümünde sıklıkla kullanılan bir ölçüttür. RMSE ise MSE'nin karekökü alınarak elde edilmektedir. Genellikle, MSE ve RMSE'nin ise düşük değerlerde olması beklenmektedir. MAPE ise fark miktarının $e(t)$, tahmin miktarına $x(t)$ oranlanmasıyla elde edilen tahminin fark yüzdesi $p(t)$ 'nin ortalaması olarak hesaplanmaktadır. MAPE değeri %10'un altında olan modeller "çok iyi", %10 ile %20 arasında olan modeller "iyi", %20 ile %50 arasında olan modeller "kabul edilebilir" ve %50'nin üzerinde olan modeller ise "yanlış ve hatalı" olarak sınıflandırılmaktadır (Witt ve Witt, aktaran Çuhadar 2006: 157).

5. Bulgular

YSA, Destek Vektör Makineleri ve Box-Jenkins olmak üzere üç yöntem tarafından üretilen tahminlere göre belirtilen performans ölçütlerinin değerleri hesaplanmıştır. Bu performans ölçütlerine göre üç yöntemin sonuçları karşılaştırılmış ve elde edilen bulgular Tablo 6'da verilmiştir.

Tablo 6. Performans Ölçütlerine Göre Üç Yöntemin Karşılaştırılması

Performans Ölçütü	Uygulanan Yöntem		
	YSA	DVM	ARIMA (1,1,2) (1,1,3) ₁₂
Verimlilik (E)	0,92378	0,88855	0,89350
Ortalama Hata Kareleri (MSE)	57.358.296.063	83.528.495.027	79.363.673.123
Ortalama Hata Kareleri Kökü (RMSE)	239.496	289.013	281.716
Ortalama Mutlak Yüzde Hata (MAPE)	%3,61	%4,67	%4,32
Korelasyon Katsayısı (CORR)	0,96130	0,94265	0,94540
Determinasyon Katsayısı (R ²)	0,92409	0,88859	0,89378

Tablo 6'da görüldüğü gibi, tüm performans ölçütlerinde DVM yöntemi ile ARIMA modelinden elde edilen sonuçlar birbirine yakın değerlerdir. Bunun yanında, ARIMA modeline ait performans değerlerinin DVM yönteminden daha iyi olduğu görülmektedir. YSA modeli performans sonuçları diğer iki yöntemle karşılaştırıldığında, YSA modeli tüm performans ölçütlerinde önemli farklar ile gerçeğe daha yakın tahminler üretmiş ve böylelikle en iyi performansı göstermiştir. Ayrıca tahminlerin performansı, daha önce verilen grafiklere (Şekil 3, Şekil 4, Şekil 6) göre karşılaştırıldığında; diğer yöntemlere göre YSA ile elde edilen tahminlerin gözlenen talebe daha çok yaklaştığı görülmektedir. Bu durum, performans ölçütlerine göre yapılan karşılaştırma sonuçlarını doğrular niteliktedir.

Performans ölçütleri ve grafiklerde görüldüğü gibi en iyi performansı YSA modeli sağlamıştır. Bu sonuçlara göre, modeller içinde en iyi performansı gösteren YSA modeli ile 2014 yılının Nisan-Aralık dönemine ait dokuz aylık su talep tahminleri üretilmiştir. Bunun için 2003-2013 yılları arasındaki girdi değişkenleri gözlem değerleri üzerinde yapılan çeşitli hesaplamalar (ortalama değer, eğilim analizi vb.) ile 2014 Nisan-Aralık dönemi girdi değişkenlerine ait değerler elde edilmiştir. Sonrasında, bu değerler ağa sunulmuş ve 2014 yılı Nisan-Aralık dönemi dokuz aylık su talep tahmini değerleri elde edilmiştir. Elde edilen tahmin değerleri Tablo 7'deki gibidir.

Tablo 7. YSA Modeli Tarafından Üretilen Su Talebi Tahmin Değerleri

Yıl-Ay	Tahminlenen Su Talebi (m ³)
2014-4	5.597.426
2014-5	6.169.853
2014-6	7.009.954
2014-7	7.492.794
2014-8	7.608.861
2014-9	6.854.532
2014-10	6.272.692
2014-11	5.599.695
2014-12	5.311.596

6. Sonuç

Bu çalışmada, Diyarbakır kent merkezi içme suyu talebinin YSA ile tahmin edilmesi ve DVM ve Box-Jenkins yöntemleri ile karşılaştırılması amaçlanmıştır. Çalışmada aylık su talebini etkileyen değişkenlere göre YSA modeli oluşturulmuş ve tahminler elde edilmiştir. YSA tahmin modelinde, su talebine etki eden faktörler ile su talebi arasındaki çok güçlü bir ilişkinin olduğu ve su talebini etkileyen değişkenlerdeki değişimin su talebindeki değişime neden olduğu sonucuna varılmıştır. Ayrıca modelin tahmin tutarlılığının ve verimliliğinin yüksek, elde edilen tahminlerdeki hata oranının ise oldukça düşük olduğu görülmüştür. Çalışmada, ayrıca DVM ve Box-Jenkins yöntemlerinden de tahminler üretilmiş ve YSA ile elde edilen tahminlerle karşılaştırılmıştır. Her üç yöntemden elde edilen tahminlerin performansı karşılaştırıldığında, YSA'nın DVM ve Box-Jenkins'e göre daha iyi sonuçlar ürettiği, daha iyi tahmin başarısına sahip olduğu görülmüştür. Bu sonuç, literatürde Jain vd. (2001), Bougadis vd. (2005), Msiza vd. (2008) ve Adamowski (2008)'nin çalışmalarıyla da desteklenmektedir.

Sonuç olarak, günümüzde özellikle kentsel su talebinin karşılanmasında sıkıntıların arttığı bir dönemde, su talep tahmin modellerinin geliştirilmesi ve gerçek değerlere yakın sonuçlar elde edilmesi oldukça sevindiricidir. Bu anlamda YSA tekniğinin su talep modellerinin oluşturulmasında ve tahminler elde edilmesinde başarıyla uygulanabileceği görülmektedir. Böylelikle su talebinin gerçeğe yakın tahmin edilmesi başta kent sakinlerine, su temin etmekle yükümlü yerel yönetim kuruluşlarına ve kent yöneticilerine doğrudan ve dolaylı katkılar sağlayacaktır. Özellikle bu ve benzeri çalışmaların, su hizmetini yerine getiren kuruluşlara; su tüketim karakteristiklerinin tespit edilmesinde, su talep ve hizmetlerinin optimal olarak karşılanmasında, ilgili yatırım planlamalarının yapılmasında, su sistemlerinin tasarımında (arıtma tesisi, depolama, iletim ve dağıtım hatları), mevcut sistemlerin optimal kapasitede işletilmesinde, işletme ve yatırım maliyetlerinin hesaplanması ve kentsel su yönetimi politikalarının belirlenmesinde önemli faydalar sağlaması beklenmektedir.

Son Notlar

* Bu çalışma, Akdağ, Recep (2014). "Yapay Sinir Ağları Yöntemiyle Diyarbakır İli Kent Merkezi İçme Suyu Talep Tahmini Uygulaması" adlı doktora tezinden türetilmiştir.

Kaynaklar

- Adamowski, J. F. (2008). Peak Daily Water Demand Forecast Modeling Using Artificial Neural Networks. *Journal of Water Resources Planning And Management*. 134 (2), 119-128.
- Adamowski, J., & Karapataki, C. (2010). Comparison of Multivariate Regression and Artificial Neural Networks for Peak Urban Water-Demand Forecasting: Evaluation of Different ANN Learning Algorithms. *Journal of Hydrologic Engineering*. 15 (10), 729-743.
- Adamowski, J., Chan, H. F., Prasher, S. O., Zielinki, B. O., Sliusarieva, A. (2012). Comparison of Multiple Linear and Nonlinear Regression, Autoregressive Integrated Moving Average, Artificial Neural Network, And Wavelet Artificial Neural Network Methods for Urban Water Demand Forecasting in Montreal, Canada. *Water Resources Research*. 48, 1-14.
- Ajbar, A. H., & Ali, E. (2012). Water Demand Prediction for Touristic Mecca City in Saudi Arabia Using Neural Networks. *International Journal of Engineering and Applied Sciences*. 6, 342-346.
- Bennett, C., Stewart, R. A., Beal, C. D. (2013). ANN-Based Residential Water End-Use Demand Forecasting Model. *Expert Systems with Applications*. 40, 1014–1023.
- Bilişik, M. T. (2011). Destek Vektör Makinesi, Çoklu Regresyon ve Doğrusal Olmayan Programlama ile Perakendecilik Sektöründe Gelir Yönetimi İçin Dinamik Fiyatlandırma. İstanbul: XI Üretim Araştırmaları Sempozyumu.
- Billings, R. B., & Jones, C. V. (2008). *Forecasting Urban Water Demand*. Denver: American Water Works Association.
- Bircan, H., & Karagöz, Y. (2003). Box-Jenkins Modelleri ile Aylık Döviz Kuru Tahmini Üzerine Bir Uygulama. *Kocaeli Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*. 6 (2), 49-62.
- Bougadis, J., Adamowski, K., & Diduch, R. (2005). Short-Term Municipal Water Demand Forecasting. *Hydrological Processes*. 19, 137–148.
- Çuhadar, M. (2006). Turizm Sektöründe Talep Tahmini İçin Yapay Sinir Ağları Kullanımı ve Diğer Yöntemlerle Karşılaştırmalı Analizi (Antalya İlinin Dış Turizm Talebinde Uygulama).Yayınlanmamış Doktora Tezi. Isparta: Süleyman Demirel Ü. Sosyal Bilimler Enstitüsü.
- Çuhadar, M. (2014). Muğla İline Yönelik Dış Turizm Talebinin Modellenmesi ve 2012-2013 Yılları İçin Tahminlenmesi. *International Journal of Economic and Administrative Studies*. 6 (12), 1-22.
- DİSKİ (2014). 2013 Yılı Faaliyet Raporu, Diyarbakır.
- Efe, Ö., & Kaynak, O. (2000). *Yapay Sinir Ağları ve Uygulamaları*. İstanbul: Boğaziçi Üniversitesi Yayınevi.
- Efendigil, T., Önüt, S., & Kahraman, C. (2009). A Decision Support System for Demand Forecasting with Artificial Neural Networks and Neuro-Fuzzy Models: A Comparative Analysis. *Expert Systems with Applications*. 36, 6697-6707.
- Fausett, L. (1994). *Fundamentals of Neural Networks: Architectures, Algorithms and Applications*. New Jersey: Prentice Hall.
- Fırat, M., Yurdusev, M. A., & Mermer, M. (2008). Uyarlamalı Sinirsel Bulanık Mantık Yaklaşımı ile Aylık Su Tüketiminin Tahmini. *Gazi Üniv. Müh. Mim. Fak. Dergisi*. 23 (2), 449-457.
- Fırat, M., Yurdusev, M. A., & Turan, M. E. (2009). Evaluation of Artificial Neural Network Techniques for Municipal Water Consumption Modeling. *Water Resource Management*. 23, 617-632.
- Froukh, M. L. (2001). Decision-Support System for Domestic Water Demand Forecasting and Management. *Water Resources Management*. 15, 363–382.

- Ghiassi, M., Zimbra, D. K., & Saidane, H. (2008). Urban Water Demand Forecasting with a Dynamic Artificial Neural Network Model. *Journal of Water Resources Planning and Management*. 134 (2), 138-146.
- Haykin, S. (1999). *Neural Networks A Comprehensive Foundation*. (2 nd Edition). New Jersey: Prentice Hall.
- Herrera, M., Torgo, L., Izquierdo, J., Perez-Garcia, R. (2010). Predictive Models for Forecasting Hourly Urban Water Demand. *Journal of Hidrology*. 141-150.
- Jain, A., & Ormsbee, L. E. (2002). Short-Term Water Demand Forecast Modeling Techniques-Conventional Methods Versus AI. *American Water Works Association Journal*. 94 (7), 64-72.
- Jain, A., Varshney, A. K., & Joshi, U. C. (2001). Short-Term Water Demand Forecast Modelling at IIT Kanpur Using Artificial Neural Networks. *Water Resources Management*. 15, 299-321.
- Kadılar, C. (2005). *SPSS Uygulamalı Zaman Serileri Analizine Giriş*. Ankara: Bizim Büro Basımevi.
- Karahan, M. (2011). *İstatistiksel Tahmin Yöntemleri: Yapay Sinir Ağları Metodu ile Ürün Talep Tahmini Uygulaması*. Yayınlanmamış Doktora Tezi. Konya: Selçuk Ü. Sosyal Bilimler Enstitüsü.
- Liu, J., Savenije, H. H. G., & Xu, J. (2003). Forecast of Water Demand in Weinan City in China Using WDF-ANN Model. *Physics and Chemistry of the Earth*. 28, 219-224.
- Mohammed, J. R., & Ibrahim, H. M. (2012). Hybrid Wavelet Artificial Neural Network Model for Municipal Water Demand Forecasting. *ARPN Journal of Engineering and Applied Sciences*. 7 (8), 1047-1065.
- Msiza, I. S., Nelwamondo, F. V., & Marwala, T. (2007). Water Demand Forecasting Using Multi-layer Perceptron and Radial Basis Functions. *Proceedings of International Joint Conference on Neural Networks*, Orlando, Florida, USA. August, 12-17.
- Msiza, I. S., Nelwamondo, F. V., & Marwala, T. (2008). Water Demand Prediction Using Artificial Neural Networks and Support Vector Regression. *Journal of Computers*. 3 (11), 1-8.
- Özalp, A., & Anagün, A. S. (2003). Yapay Sinir Ağı Performansına Etki Eden Faktörlerin Analizinde Taguchi Yöntemi: Hisse Senedi Fiyat Tahmini Uygulaması. *İstatistik Araştırma Dergisi*. 2 (1), 29-45.
- Karahan, M. (2011). *İstatistiksel Tahmin Yöntemleri: Yapay Sinir Ağları Metodu ile Ürün Talep Tahmini Uygulaması*. Yayınlanmamış Doktora Tezi. Konya: Selçuk Ü. Sosyal Bilimler Enstitüsü.
- Saygılı, Y. S. (2008). *İstatistiksel Yöntemlerle Yapay Sinir Ağları Uygulamalarının Karşılaştırılması: Milli Savunma Bakanlığı Bütçesinin Öngörülmesi*. Yayınlanmamış Yüksek Lisans Tezi. Ankara: Kara Harp Okulu Savunma Bilimleri Enstitüsü.
- Tozkan, S. (2004). *Yapay Sinir Ağları*. Fırat Ün. Mühendislik Fak. Elektrik-Elektronik Müh. Bölümü. <http://www.hasanbalik.com/projeler/bitirme/24.pdf>, (Erişim Tarihi: 16 Temmuz 2014).
- Yıldız, B. (2001). Finansal Başarısızlığın Öngörülmesinde Yapay Sinir Ağı Kullanımı ve Halka Açık Şirketlerde Ampirik Bir Uygulama. *İMKB Dergisi*. 5 (17), 51-67.
- Yurdusev, M. A., Firat, M., Mermer, M., Turan, M. E. (2009). Water Use Prediction by Radial and Feed-forward Neural Nets. *Water Management*. 162 (3), 179-188.