

Yapay Sinir Ağlarını Kullanarak Günlük Yağış Miktarının Tahmini

Kemal SAPLIOĞLU¹

Mesut ÇİMEN²

¹ İnşaat Mühendisliği Bölümü, Süleyman Demirel Üniversitesi, Isparta, Türkiye

² İnşaat Mühendisliği Bölümü, Süleyman Demirel Üniversitesi, Isparta, Türkiye
kemsa@sdu.edu.tr, mesutcim@mmf.sdu.edu.tr

Özet-- Su kaynaklarının kullanılması ve su yapılarının planlanması gibi pek çok konuda analizlerin sağlıklı bir biçimde yapılabilmesi için birçok parametrenin (yağış, akış, sızma, buharlaşma ve terleme v.s) doğru ve uzun süreli ölçümünün yapılabilmesi son derece önemlidir. Yağış verisi ise bu parametrelerin en önemlilerinden bir tanesidir. Geçmişe yönelik yağış verileri ile ilgili sağlıklı ve uzun süreli bilgi iyi bir analiz için büyük önem taşımaktadır. Geçmişe yönelik ölçümü bulunmayan istasyonların verileri aynı havza içerisinde bulunan ve hidrometeorolojik olarak benzer diğer istasyonların verileri ile tahmin edilebilmektedir. Elde edilen sonuçların güvenilirliği açısından tahmin yönteminin doğru seçilmesi önemli olmaktadır. Bir istasyonda mevcut ölçüm verileri yardımıyla, geçmişe yönelik verilerin elde edilip edilemeyeceği veya gelecekte meydana gelebilecek veri eksikliklerinin giderilip giderilemeyeceği irdelenmelidir. Bu çalışmada Yapay Sinir Ağları (YSA) yöntemi kullanılarak yağış tahmini için bir model teklif edilmiştir. Bu yöntem, Amerika Birleşik Devletlerinin Portland bölgesinde bulunan 121, 120, 21 ve 107 nolu yağış gözlem istasyonlarında ölçülmüş günlük yağış verilerine uygulanmıştır. Modelleme, 2000 – 2009 yılları arasında her bir istasyondan alınan 3170 adet günlük yağış verisi için uygulanmıştır. Elde edilen sonuçlar literatürde mevcut olan ağırlıklı ve harmonik ortalama metotlarından elde edilen sonuçlar ile karşılaştırılmıştır.

Anahtar Kelimeler-- Yağış, Yapay Sinir Ağları, Tahmin, Portland

Predicting Of Daily Precipitation Using Artificial Neural Network

Abstract-- For the proper utilization of water resources and properly planned water structures to be built and conducted rightly, it is necessary that many parameters (precipitation, runoff, infiltration, evapotranspiration, etc.) and their influences should be analyzed and examined properly. Precipitation is one of the most important parameters in the hydrology field. The rainfall data is very important for the level of water resources conduct and running. While planning, recorded data has great importance. Data of the ungauged stations may be estimated with those of similar stations hydrometeorologically in the same/similar watershed. Method of forecast is very important from the view point of the reliability of results obtained. It must be investigated, in detail, whether the data in the past is obtained or the lacked data, would be in the future, is completed. In this study a model is proposed for estimating daily rainfall amount by using the artificial neural network (ANN) method. This method has been tested for the daily precipitation data obtained from the precipitation stations of 121, 120, 21 and 107 in Portland province of USA. Number of 3170 data in the years of 2000-2009 belonging to these stations, has been used in this model. Furthermore, this model formed is compared with the commonly used weighted average, and harmonic average methods.

Keywords-- Precipitation, Artificial Neural Network, Prediction, Portland

1. GİRİŞ

Su kaynaklarının doğru kullanılabilmesi ve yapılacak olan su yapılarının doğru projelendirilip doğru yürütülebilmesi için birçok parametrenin (yağış, akış, sızma, buharlaşma, bitki örtüsü, vb) doğru analiz edilip etkisinin iyi bir şekilde irdelenmesi gerekmektedir. Yağış ta bu parametrelerin en önemlilerinden bir tanesidir. Bu

parametrenin doğru bir şekilde ölçümlerinin yapılabilmesi, su kaynaklarının yönetimi ve işletilmesi aşamalarında oldukça önemlidir. Planlama yapılırken planlama yerinin veya ona yakın yerlerin geçmişe yönelik verilerinin elde edilmesi büyük önem taşımaktadır. Ölçüm bulunmayan yerlerde oluşturulacak geçici bir veri toplama sistemi ile birkaç senelik veriler toplanıp aynı havza içerisinde bulunan diğer ölçüm istasyonlarıyla entegrasi

sağlanarak geçmişe yönelik veriler elde edilebilmektedir. Bu nedenle yağış tahmini veya eksik verilerin tamamlanması metodları önemli olmaktadır. Doğru yapılacak bir analiz neticesinde birkaç yıllık ölçüm ile geçmişe yönelik tüm veriler, az bir hata ile tamamlanabilecektir. Ayrıca, geleceğe yönelik herhangi bir sorundan dolayı oluşacak bir veri eksikliği yağış tahmin metodları ile giderilebilecektir. Yağış tahmini modellerini deneysel ve dinamik olmak üzere iki ana başlık altında toplamak mümkündür.

Deneysel yaklaşımlar genellikle tarihi bazlı ve aralarında önemli ölçüde korelasyon bulunan verilere dayanan metodlardır. Bunlardan en önemlileri yapay sinir ağları, stokastik modeller, bulanık mantık ve veri tabanlı grup modelleridir [1]. Dinamik yaklaşımlar ise iklimsel şartların ve atmosferde meydana gelen değişimlerin bir araya getirilerek oluşturulan denklem takımlarına dayanmaktadır.

[2] uzun süreli ve yaz aylarında görülen muson yağmurlarının modeli için güçlü bir regresyon tekniği kurmuştur. Bu modeli oluştururken Asya'daki kar yağışını, kuzey batı Avrupa sıcaklık değerlerini, Avrupa'da ve Asya da meydana gelen basınçları, Arap denizinde meydana gelen yüzey sıcaklıklarını ve bir önceki yıl Hint okyanusunda meydana gelen sıcaklık değerlerini kullanmıştır. Sonuç olarak, %4 lerde kalan bir hata payıyla modelini oluşturmuştur. [3] Tayland genelinde çoklu lineer regresyon modeli oluşturmuşlardır. Bu modelde deniz seviyesi, deniz yüzeyi sıcaklığı ve güneysel Elnino titreşim indeksi kullanılmıştır. Model sonucunda %60 lık bir korelasyon elde edilmiştir.

Ülkemizde ve diğer pek çok çalışan tarafından eksik verilerin tamamlanması amacıyla yaygın olarak kullanılan bir yöntem ise ağırlıklı ortalama yöntemidir. Bu yöntemde Denklem 1'de gösterilen formülasyon kullanılmaktadır [4].

$$P_n = \frac{P_1 \frac{N_n}{N_1} + P_2 \frac{N_n}{N_2} \dots P_{(n-1)} \frac{N_n}{N_{n-1}}}{n-1} \quad 1)$$

Burada P günlük yağış miktarını, N yıllık toplam yağış miktarlarını, n ise istasyon sayısını göstermektedir. Eksik verilerin tamamlanabilmesi için kullanılan diğer bir formül ise, yağış verisi tamamlanacak olan istasyonun diğer istasyonlara olan mesafesinin baz alındığı, harmonik ortalama metodudur.

$$P_n = \frac{\sum_{i=1}^{n-1} \frac{P_i}{D_i^2}}{\sum_{i=1}^{n-1} \frac{1}{D_i^2}} \quad (2)$$

Burada D , göz önüne alınan istasyon ile diğer istasyonlar arasındaki mesafeyi gösterir.

Bu çalışmada, eksik yağış verilerinin tahmin edilebilmesi için yapay sinir ağları yöntemi kullanılmıştır. Bu yöntemde gizli tabakadaki nöron sayılarının modele ve dolayısıyla ölçüm sonuçlarına olan etkisi araştırılmıştır. Ayrıca günlük yağış miktarı tahminleri ağırlıklı ve harmonik ortalama yöntemlerine göre de yapılmıştır. Elde edilen model sonuçları ile ölçüm sonuçları karşılaştırılmıştır.

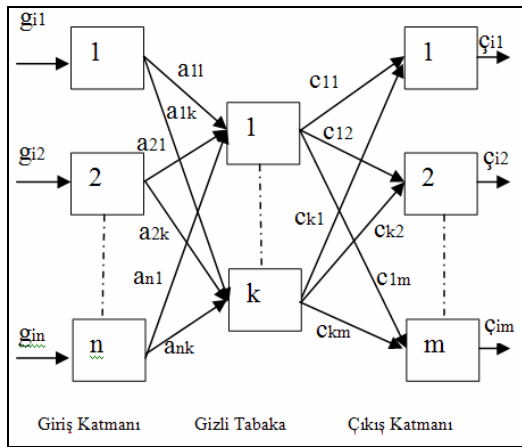
1.1. Yapay Sinir Ağları

YSA modelleri, eldeki verilerden yararlanarak öğrenme, ilişki kurma, sınıflandırma, genelleme ve optimizasyon işlemlerinden birini veya bir kaçını yapmak için kullanılan modellerdir [5]. İnsanoğlu binlerce yıldır insan beyni üzerinde çalışmalar yapmış, modern elektronik cihazların kullanılmaya başlamasıyla birlikte bu çalışmalar hız kazanmıştır. Yapay sinirlerle ilgili ilk çalışma 1943 yılında McCulloch ve arkadaşları [6] tarafından yapılmıştır. Onların çalışmasında elektrik devreleri üzerinde basit yapay sinirler modellenmiştir. 1950'li yıllarda, bilgisayar teknolojisinin devreye girmesiyle birlikte yapay sinir ağlarındaki gelişmeler ivme kazanmıştır. İlk olarak IBM araştırma laboratuvarları öncülüğünde Nathaniel Rocheste basit bir yapay sinir ağı simule etmeye çalışmıştır. İlk denemesi başarısız olmasına karşılık daha sonraki denemelerinde başarı sağlamıştır [7]. 1959 da, Widrow ve Hoff [8] ADALINE ve MADALINE metodlarını geliştirmişlerdir. MADALINE gerçek dünya problemlerine adapte edilen ilk yapay sinir ağı modelidir. Bu model telefon hatlarındaki ekoları engellemek için kullanılmıştır ve halen günümüzde ticari amaçlı kullanılmaktadır. Daha sonra [9] ağ yapılarının günlük hayatta kullandığımız araçlarda kullanılabileceğini belirtmiştir. 1985 yılında Amerikan fizik enstitüsü sinir ağlarının bilgisayarlarda kullanılabileceğini göstermiştir [7]. Bugün yapay sinir ağları mühendisliğin hemen her alanında kullanılmaya ve üzerinde yorumların yapılmasına devam edilmektedir. Günümüzde özellikle şirketler dijital, analog ve görsel olmak üzere 3 tip sinir üzerinde çalışmaktadır.

YSA şebekesi, biri mimarisi (yapısı) diğeri de bu mimarinin işlemlerini sağlayan matematik fonksiyonlar olmak üzere iki kısımda incelenebilir. Genel olarak bir YSA mimarisi giriş, gizli ve çıkış tabakalarındaki sinir hücreleri ile bunlar arasındaki bağlantılardan oluşmaktadır. Gizli hücreler içinde işlemci (aktivasyon fonksiyonu) denen bir iç işleyiş yani tetikleme işlemcisi bulunur. YSA işleyişini de iç ve dış işleyiciler olarak iki matematiksel işlev olarak düşünülebilir. Bir YSA'nın iç işleyişi gizli tabakadaki işlemciler vasıtası ile sağlanmaktadır. Dış işleyişi de ardışık tabaka hücreleri arasındaki bağlantı değerlerinin öncelikle rastgele atanması, daha sonra da çıktı tahmin hatasının geri besleme vb. işlemlerle en küçüklenerek yenilenmesi

sonucunda meydana gelmektedir. Bu matematik işlemler YSA'nın öğrenme, eğitilme, hatırlama ve sürekli yeni bilgileri algılama ile şebeke bağlantılarını yenileme görevlerini üstlenmektedirler [5]

Tüm öğrenme algoritmalarının amacı, girdi ve çıktı verileri arasındaki en uygun ilişkiyi sağlayacak olan bağlantı ağırlıklarının elde edilmesidir. Tek tabakalı algılayıcılara göre iki tabakalı ileri beslemeli ağırlar birçok sınırlandırmayı ortadan kaldırabilmektedir. Fakat, tabakalar arasındaki bağlantı ağırlıklarının nasıl değiştirileceği konusunda sıkıntılar ortaya çıkmaktadır. Bu bağlamda, bu çalışmada da kullanılan geriye yayılma algoritması, gizli tabaka içeren YSA'lar için kullanılabilir güçlü bir öğrenme içerir. Geriye yayılma algoritmasının çalışma esası, alt sistemlerde meydana gelen bir YSA'daki değişimlerin tamamen ve etkili bir şekilde hesaplanabilmesine dayanmaktadır. Bu da YSA'nın karmaşık, doğrusal olmayan ve işlem parametreleri arasındaki ilişkinin öğrenilmesinde kullanılmasını sağlamaktadır. Şekil 1'deki gibi bir topolojiye sahip olan ağ üzerindeki geriye yayılma algoritması adım adım şu şekilde gerçekleşir [5].



Şekil 1: Genel YSA Mimarisi

- Öncelikle YSA'nın topolojik yapısının belirlenmesi için tabakalar (katmanlar) ve her tabakadaki hücre sayısı tespit edilir.
- Daha sonraki aşamada sabit parametrelerin değerleri atanır.
- Tabakalar arasındaki ağırlık bağlantıları belirlenir.
- n ölçüm sayısı olmak üzere atanan bağlantı ağırlıkları kullanılarak her bir giriş vektörü için çıktı vektörü elde edilir.
- Hataların geriye yayılma işlemine çıkış katmanı ile gizli tabaka arasındaki bağlantı ağırlıklarından başlanarak önce a_{ij} değerleri yenilenir
- Ağırlık katsayıları olan a_{ij} değerlerinin yenilebilmesi için öncelikle hata değeri ve hata

değerinin a_{ij} bağlantı ağırlıklarına göre türevlerinin hesaplanması gerekir.

- YSA'nın vermiş olduğu çıkış değerleri ile beklenen değerler kullanılarak toplam hata değeri hesaplanır.
- Her bir ağırlık katsayısının yenilenebilmesi için hata bağıntıları, bulunan ağırlıklarına göre tekrar türevleri alınması gereklidir.

YSA'nın hidroloji alanında da pek çok uygulaması vardır. Özellikle yağış -akış modellemelerinde pek çok başarılı örneği karşımıza çıkmaktadır [10-12]. Ayrıca su kalitesi parametrelerinin belirlenmesinde [13], buharlaşma miktarının tespitinde [15] ve son yıllarda da sediment miktarı tahmininde [15, 16, 17] sıklıkla kullanılmaya başlanmıştır.

2. ÇALIŞMA ALANI VE METOD

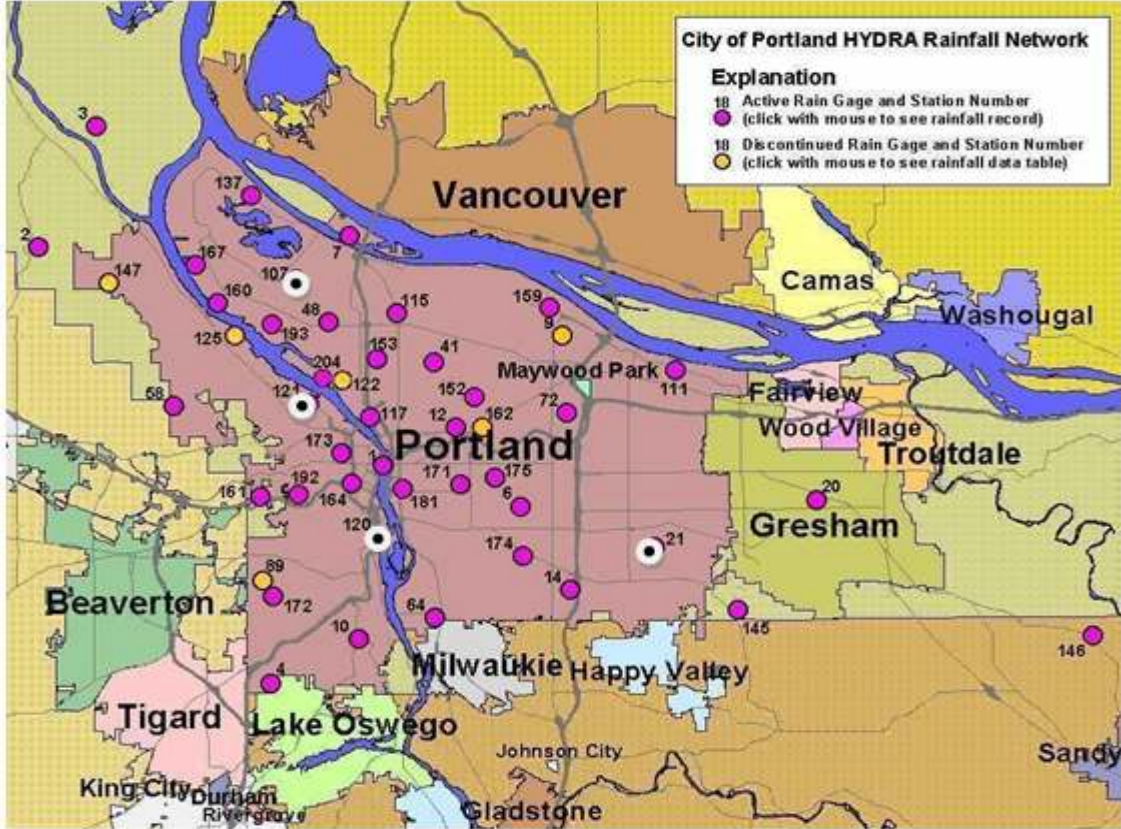
Çalışma alanı olarak Amerika Birleşik Devletlerinin Oregon Eyaletinin Portland şehri seçilmiştir. Bu bölgede seçilen yağış ölçüm istasyonları Şekil 2'de gösterilmiştir [18]. Seçilen bu istasyonların hidrolojik olarak benzer özellikler taşıdığına karar verilmiştir. İstasyonlarla ilgili detaylı bilgi aşağıda sıralanmıştır:

- 21 nolu Holgate Raingage 4507 SE. 136th Ave. İstasyonu: $45^{\circ}29'43''$ kuzey ve $122^{\circ}30'20''$ batı koordinatlarında, deniz seviyesinden 73 m yükseklikte, 107 nolu istasyona olan mesafesi $D=20,413$ km.
- 120 nolu Thomas Raingage 4026 SW. Macadam Ave: $45^{\circ}29'24$ kuzey ve $122^{\circ}40'30''$ batı koordinatlarında, deniz seviyesinden 12 m yükseklikte, 107 nolu istasyona olan mesafesi $D=12,671$ km.
- 121 nolu Yean Raingage 3395 NW. Yeon İstasyonu: $45^{\circ}32'43''$ kuzey ve $122^{\circ}42'16''$ batı koordinatlarında, deniz seviyesinden 8 m yükseklikte, 107 nolu istasyona olan mesafesi 6,14 km.
- 107 nolu Colubia IPS Raingage 5001 N. Columbia Blvd. İstasyonu: $45^{\circ}35'57''$ kuzey ve $122^{\circ}43'18''$ batı koordinatlarında, deniz seviyesinden 10 m yükseklikte.

Çalışmada, bu dört istasyona ait 9 Haziran 2000 ile 11 Şubat 2009 tarihleri arasında ölçülmüş 3170' şer adet veri değerlendirilmiştir. Bu verilerden ilk 2536' sı eğitim, son 634 tanesi de test için ayrılmıştır. Veriler değerlendirilmeye başlamadan önce 0-1 aralığında normalize edilmiştir. Şekil 1'de gösterilen YSA mimarisinin giriş katmanı 21, 120 ve 121 nolu yağış ölçüm istasyonlarından alınan eğitim verilerinden meydana gelmiştir. Çıkış katmanı ise 107 nolu istasyondan alınan ve eğitim için ayrılan verilerden oluşmuştur. Modelde tek gizli tabaka kullanılmış olup bu

gizli tabakadaki nöron sayıları 1 den 11'e kadar artırılarak farklı modeller kurulmuştur. Oluşturulan modeller için aktivasyon fonksiyonu olarak logaritmik sigmoid fonksiyonu kullanılmış ve bu fonksiyon ileri beslemeli geriye yayımlı öğrenme yöntemiyle eğitilerek Şekil 1' de görülen ağırlık parametreleri elde edilmiştir. Bu işlem sonunda, eğitim serisi için günlük yağış miktarları tahmin edilmiştir. Ayrıca modeli test etmek için ayrılan 21, 120 ve 121 nolu istasyonlarına ait 634'er adet

veri, eğitilmiş olan modele girdi olarak konularak 107 nolu istasyona ait sonuçlar tahmin edilmeye çalışılmıştır. Elde edilen sonuçlar hem eğitimin ölçülmüş çıktı değerleri ile hem de test için ayrılmış verilerin ölçülmüş çıktı değerleri ile kıyaslanmıştır. Ayrıca bu kıyaslama, ağırlıklı ve harmonik ortalama metotları için de yapılmıştır.



Şekil 2. Çalışma Alanı ve Yağış İstasyonlarının Yerleşimi

3. BULGULAR

21, 120 ve 121 nolu istasyonlara ait günlük yağış verileri girdi olarak, 107 nolu istasyona ait verilerin de çıktı olarak kullanıldığı 11 adet YSA modeli oluşturulmuş ve bu modellerden elde edilen sonuçlar hem eğitim verileri ve hem de test verileri için irdelenmiştir. Bunun yanı sıra, literatürde sıklıkla kullanılan ağırlıklı ve harmonik ortalama metotları kullanılarak hem eğitim için ayrılan veriler ve hem de test için ayrılan veriler değerlendirilmiştir.

Modellerin sonuçları ile ölçülmüş değerler arasındaki kıyaslamaları yapabilmek için, verimlilik katsayısı ve ortalama karesel hata gibi istatistiksel büyüklükler kullanılmıştır. E_i , (verimlilik katsayısı) [19] tarafından teklif edilmiş ve birçok hidrolojik tahmin modelinin doğruluğunu ölçmek için kullanılan bir yöntemdir

(Denklem 3). Verimlilik katsayısı $-∞$ ile 1 arasında

değerler alırken, katsayının 1'e yakın olması modelin iyi tahmin yaptığına işaret eder.

$$E_i = 1 - \frac{\sum (X_0 - X_p)^2}{\sum (X_0 - \bar{X})^2} \quad (3)$$

Burada X_0 gözlenmiş yağış verilerini, X_p tahmin edilen yağış verilerini ve \bar{X} ise gözlenmiş verilerin eğitim ve test için ayrı ayrı ortalama değerini göstermektedir.

Ortalama karesel hata (OKH) ise verimlilik katsayısında olduğu gibi karesel olarak hataları göz önüne almaktadır. Ortalama karesel hatanın sifıra yakın değerler alması, modelin iyi tahmin yaptığını ifade eder. Bu istatistiksel büyüklük hataların karesel olarak alınmasından dolayı,

karesel olarak hata aramayan pek çok hata analizinden daha sağlıklı sonuçlar vermektedir.

$$OKH = \frac{\sum (X_0 - X_p)^2}{N} \quad (4)$$

Oluşturulan modellerin istatistiksel hata sonuçları, eğitim ve test serileri için Tablo 1’ de verilmiştir. Elde edilen E_i katsayılarına bakıldığında eğitim verileri için 11 nöronlu YSA modeli ve test için ayrılan modellerde ise 4 nöronlu YSA modelinin diğer modellere göre daha iyi sonuçlar verdiği gözlemlenmiştir. Bulunan ortalama karesel hata sonuçlarına bakıldığında ise eğitim verileri için yine 11 nöronlu YSA modelinin ve test için ayrılan modellerde ise yine 4 nöronlu YSA modelinin diğer modellere göre daha iyi sonuçlar verdiği gözlemlenmiştir. YSA modelleri, eğitim serileri için girdiler ile çıktı arasında bağlantılar kurduktan sonra, girdi değişkenlerin test verilerinden çıktının tahmini test değerlerini elde etmektedir. Dolayısıyla, 4 nöronlu YSA modeli, test verileri için en iyi hata kriterlerine sahip olduğu için, bu çalışmada YSA modelleri içerisinde en uygun model olarak ele alınmıştır.

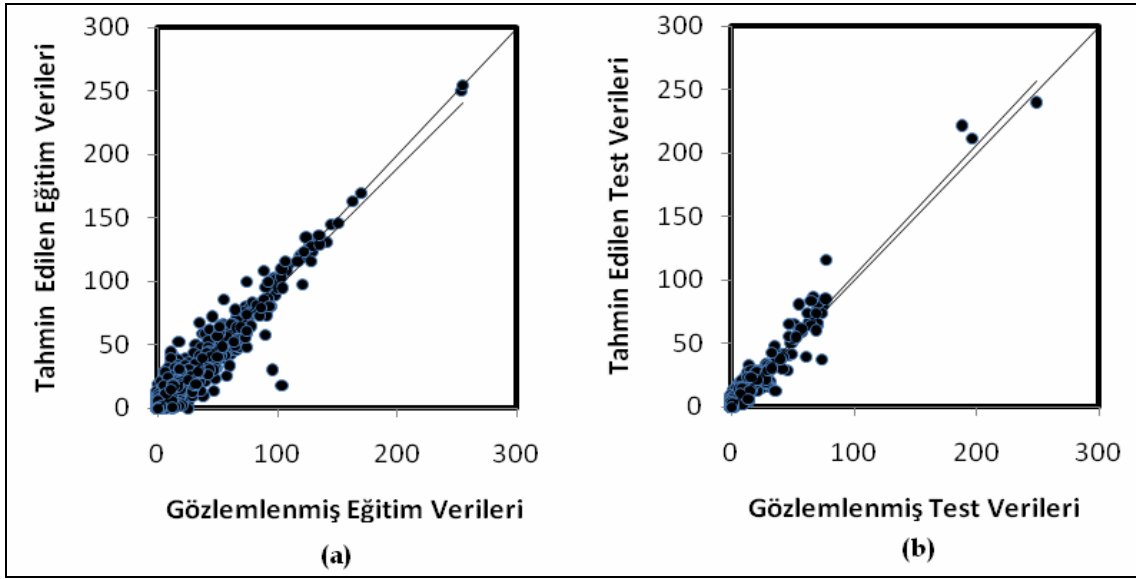
Tablo 1. YSA Modelleri ile Ağırlıklı ve Harmonik Ortalama Metotlarından Elde Edilen Eğitim ve Test Sonuçlarının Karşılaştırılması

Yöntem	Eğitim		Test	
	E_i	OKH	E_i	OKH
Ağırlıklı ortalama	0,902	44,8	0,941	25,3
Harmonik ortalama	0,905	43,724	0,912	37,96
YSA - 1 Nöron	0,918	37,4	0,939	26,3
YSA - 2 Nöron	0,918	37,4	0,939	26,3
YSA - 3 Nöron	0,922	35,9	0,947	23,0
YSA - 4 Nöron	0,926	33,8	0,950	21,8
YSA - 5 Nöron	0,935	29,7	0,91	38,7
YSA - 6 Nöron	0,932	31,2	0,926	32,0
YSA - 7 Nöron	0,938	28,4	0,908	39,8
YSA - 8 Nöron	0,939	27,9	0,942	25,1
YSA - 9 Nöron	0,937	28,9	0,929	30,8
YSA - 10 Nöron	0,94	27,4	0,907	40,1
YSA - 11 Nöron	0,942	26,55	0,94	25,98


4 nöronlu YSA hesaplamaları sonucunda, verilerin hem eğitim ve hem de test verisi için tahmin edilen değerleri ile ölçüm değerlerinden elde edilen saçılma diyagramı Şekil 3’ te çizilmiştir. Bu grafiklerde, ölçülmüş günlük yağış verileri ile tahmin değerleri arasındaki ilişkiyi daha iyi görebilmek için 45° lik bir doğru da şekil üzerinde çizilmiştir. 45° lik doğruyla çakışmanın özellikle test verileri için elde edilmesi, oluşturulan modelin sağlamlığını göstermesi bakımından önemlidir.

Benzer şekilde, ağırlıklı ortalama ve harmonik ortalama yöntemlerinde elde edilen saçılma grafikleri de, sırasıyla Şekil 4 ve Şekil 5’ te verilmiştir. Bu şekiller incelendiğinde, harmonik ortalama yönteminden elde edilen sonuçların 45° lik doğru etrafında, ağırlıklı ortalama yöntemine göre, daha az değiştiği görülmektedir. Bu sonuç, birbirine yakın ve hidrometeorolojik olarak benzer yağış gözlem istasyonlarındaki eksik verinin, harmonik ortalama tahmin edilmesinin ağırlıklı ortalamaya göre daha iyi sonuçlar verdiği, özellikle çalışma havzasında, söylenebilir.

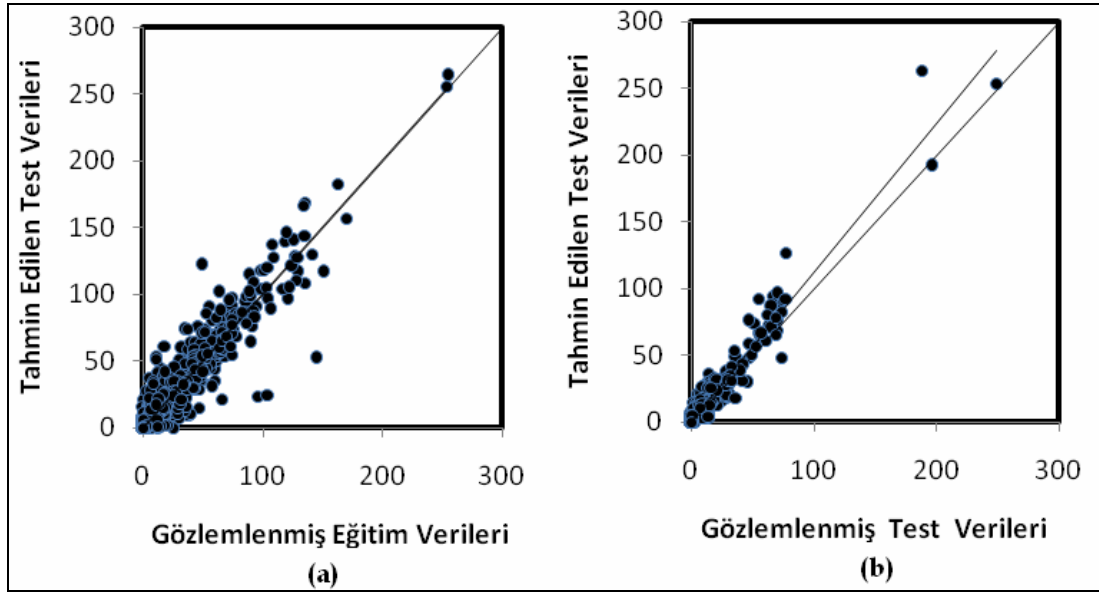
Bununla birlikte, ağırlıklı ortalama ve harmonik ortalama metotlarıyla, ayrı ayrı olarak hem eğitim ve hem de test verileri için hesaplar yapılmıştır. Dolayısıyla, hata değerlerini sadece eğitim yada sadece test verileri için yapmak çok fazla anlamlı olmamaktadır. Bu nedenle, bu iki modelde gözlenmiş bütün verilerin hata değerlerinin göz önüne alınması uygun olacaktır. Böylece, 3170 ‘şer adet veri göz önüne alındığında, ağırlıklı ortalama metodunun E_i ‘si 0.91, OKH ı 40.9 olarak ve harmonik ortalama metodunun E_i ‘si 0.91, OKH ı 42.6 olarak elde edilmektedir. Bu hata değerleri ile 4 nöronlu YSA modelinin hata değerlerini ve saçılma diyagramlarını ele aldığımızda, 4 nöronlu YSA modelinin daha iyi günlük yağışları tahmin edebildiğini ifade edebiliriz.



Şekil 3. YSA – 4 Nöron Modeline Göre Saçılım Diyagramları (a) Eğitim; (b) Test



Şekil 4. Ağırlıklı Ortalama Metoduna Göre Saçılım Diyagramları (a) Eğitim; (b) Test



Şekil 5. Harmonik Ortalama Metoduna Göre Saçılım Diyagramları a) Eğitim b) Test

4. SONUÇLAR

Bu çalışmada, bir yağış sırasında ölçümü yapılamamış veya yeni kurulmuş bir istasyonun geçmişe yönelik yağış verilerinin tamamlanabilmesi için Yapay Sinir Ağları metodu kullanılarak modeller oluşturulmuştur. Oluşturulan bu modeller, literatürde yağış miktarlarının tahmininde sıklıkla kullanılan ağırlıklı ortalama ve harmonik ortalama metotları ile karşılaştırılmıştır. Hesaplamalar sonucunda, 4 nöronlu YSA modelinin en küçük hata değerlerini vermesi ve uygun saçılım diyagramını oluşturması açısından diğer iki standart hesap yöntemine göre daha üstün olduğu bulunmuştur. Harmonik ortalama yönteminin de, göz önüne alınan havzadaki günlük yağış tahminlerini ağırlıklı ortalama yöntemine göre daha iyi tahmin ettiği görülmüştür. Hidrometeorolojik olarak benzer ve birbirine yakın istasyonlarda harmonik ortalama metodunun da kullanılabilir olduğu görülmüştür. Eksik yağış verilerinin hesaplanmasında, YSA modellerinin diğer yöntemlere göre daha üstün olacağı ifade edilebilir.

KAYNAKLAR

- [1] Zaw, W., T., and Naing, T., T., “Empirical Statistical Modeling of Rainfall Prediction over Myanmar”, Proceedings of World Academy of Science, Engineering and Technology Volume 36 December, 2070-3740, 2008.
- [2] Sen, N., “New forecast models for Indian south-west Monsoon season Rainfall”, in Current Science, vol. 84, No. 10, May, pp.1290-1291, 2003.
- [3] Singhratna, N., Rajagopalan, B., Clark, M., Kumar K. K., “Seasonal Forecasting of Thailand Summer

Monsoon Rainfall”, in International Journal of Climatology, Vol. 25, Issue 5, American Meteorological Society, , pp. 649-664, 2005.

- [4] Bayazıt, M., Hidroloji, İstanbul Teknik Üniversitesi İnşaat Fakültesi Matbaası, 1995.
- [5] Şen, Z., Yapay Sinir Ağları İlkeleri, Su Vakfı Yayınları, 2004.
- [6] McCulloch, S. W., and Pitts, H. W., “A Logical Calculus of the Ideas Immanent in Neural Net”, Bulletin of Mathematical Biophysics, Volume 5. 1943.
- [7] Wang, W., Stochasticity, Nonlinearity and Forecasting of Streamflow Processes PhD Thesis, 2006.
- [8] Widrow, Bernard, and Hoff, Marcian, “Adaptive Switching Circuit”, 1960 IRE WESCON Convention Record, Part 4. 1960.
- [9] Hopfield, J., “Neural Networks and Physical Systems with Emergent Collective Computational Abilities”, Proceedings of the National Academy of Sciences, Volume 79. 1982.
- [10] Fernando, D.A.K., Jayawardena, A.W., “Runoff forecasting using RBF Networks with OLS algorithm”, Journal of Hydrologic Engineering 3 (3). 203-209. 1998.
- [11] Cigizoglu, H.K., Alp, M., Rainfall runoff modelling using three neural network methods. Lecture Notes in Artificial Intelligence (Lecture Notes in Computer Science). Springer-Verlag, pp. 166-171. 2004.

- [12] Tokar, A.S., Johnson, P.A., “Rainfall-runoff modelling using artificial neural Networks”, Journal of Hydrological Engineering, ASCE 5(2), 180-189, 1999.
- [13] Newham, L.T.H., Norton, J.P., Prosser, I.P., Croke, B.F.W., Jakeman, A.J., “Sensitivity analysis for assesing the behaviour of a landscape- based sediment soruce and transport model. Enviromental Modelling and Software”, 18 (8-9), 741-751, 2003.
- [14] Keskin, M.E., Terzi, Ö., “Artificial Neural Network Models of Daily Pan Evaporation”, Journal of Hydrologic Engineering, 11(1), 65-70. 2006.
- [15] Cığızoğlu, H.K., “Estimation and forecasting of daily suspended sediment data by multi-layer perceptrons”, Advances in Water Resources 27, 185-195. 2004.
- [16] Kişi, Ö., “Multi-layer perceptrons with Levenberg-Marquardt training algorithm for suspended sediment concentration prediction and estimation”, Hydrological Sciences Journal, 49(6), 1025-1040. 2004.
- [17] Agarwal, A., Singh, R.D., Mishra, S.K., Bhunya, P.K., “ANN-based sediment yield models for Vamsadhara riverbasin” (India). Water S.A. 31(1), 95-100. 2005.
- [18] http://or.water.usgs.gov/non-usgs/bes/raingage_info/clickmap.html 12/12/2009
- [19] Nash, J. E. and J. V. Sutcliffe , “River flow forecasting through conceptual models” part I — A discussion of principles, Journal of Hydrology, 10 (3), 282–290, 1970.