

# Kısa vadeli yağış modellemesi için yapay sinir ağları yaklaşımı

Ahmet ÖZTOPAL\*, Zekai ŞEN

İTÜ Fen Bilimleri Enstitüsü, Meteoroloji Mühendisliği Programı, 34469, Ayazağa, İstanbul

## Özet

Yağış kaynaklı doğal afetlerin önlenmesi ile su kaynakları ve havza yönetimi için yağışların ölçümü, modellenmesi ve tahminleri çok önemlidir. Kurulu olan yağış ölçer ağlarının hem zaman hem de uzay değişkenliklerinin yüksek olması sebebiyle, küçük ölçeklerdeki şiddetli yağışların belirlenmesinde çeşitli zorluklar vardır. Mevcut hava tahminlerinin son yıllardaki güvenilir sonuçlarına rağmen, konvektif yağışların zaman ve alan yağış desenleri tam olarak yakalanamamaktadır. Bu sebeple uydulardan elde edilen bilgiler hava tahmin modellerine girdi olarak kullanılmaktadır. Yağış tür ve miktarının uzaktan algılama ile belirlenmesi meteoroloji alanındaki önemli konulardan biridir. Bu amaçla kullanılan cihazlar radar ve uydulardır. Bunlar arasında zaman ve uzay çözünürlüğü en yüksek olan uydu sistemleridir ve bu da onlara önemli bir avantaj sağlamaktadır. Konvektif yapılar için bulut tepe sıcaklığı yağış ile ilişkilendirilebilen anahtar bir parametredir. Buradaki yaklaşım, soğuk tepeli bulutların sıcak tepelilerden daha fazla yağış ürettiklerine dayanmaktadır. Buradan hareketle Arkin, GOES yağış indeksi, ayarlanmış GOES yağış indeksi, Griffith-Woodley, Negri-Adler-Woodley, konvektif-stratiform, güçlendirilmiş konvektif-stratiform, otomatik tahmin edici ve geliştirilmiş otomatik tahmin edici teknikleri gibi ekvator yörüngeli uydu verisini kullanan yöntemler geliştirilmiştir. Tüm bunlar yapılarında doğrusal amprik denklemler içermektedir ve bu denklemlerdeki katsayıların ülkemiz için belirlenmesi zorunluluğu vardır. Buradan hareketle, bu çalışmada 2000 yılı içerisindeki 5-7 Eylül dönemine ait bir konvektif yağışlı olay incelenerek, bir Yapay Sinir Ağı modeli kurulmuştur. Bu model Eylül ayı yağışını gayet iyi tahmin etmiştir.

**Anahtar Kelimeler:** Marmara, yağış, kısa vadeli tahmin, yapay sinir ağları, uzaktan algılama.

\*Yazışmaların yapılacağı yazar: Ahmet ÖZTOPAL. oztopal@itu.edu.tr; Tel: (212) 285 31 27.

Bu makale, birinci yazar tarafından İTÜ Fen Bilimleri Enstitüsü, Meteoroloji Mühendisliği Programı'nda tamamlanmış olan "Uydu ve yer kaynaklı meteorolojik değişkenlerle kısa vadeli yağış modellemesi için yapay sinir ağı yaklaşımı" adlı doktora tezinden hazırlanmıştır. Makale metni 16.03.2007 tarihinde dergiye ulaşmış, 09.11.2007 tarihinde basım kararı alınmıştır. Makale ile ilgili tartışmalar 31.05.2009 tarihine kadar dergiye gönderilmelidir.

## Artificial neural network approach for modeling of the short range precipitation

### Extended abstract

*In order to mitigate with the natural hazards (surface water, floods, etc.) of precipitation origin it is necessary to measure, model and predict the precipitation for water resources and basin management. Due to high spatial and temporal variability of precipitation measurement networks, there are difficulties in determining small scale intensive rainfall events. Currently available weather prediction models yield reliable results, but they cannot catch the spatio-temporal patterns of convective rainfall events. For this reason, the satellite based meteorological information is used as input in weather prediction models.*

*One of the most significant subjects in meteorology domain is the determination of precipitation pattern types and quantities through remote sensing. The instruments used for this purpose are radars and satellites. Satellite systems have the most refined resolution among all these instruments, which provide them significant superiority.*

*For convective structures the cloud top temperature is a key parameter that can be related to precipitation. The basic idea herein is that the cold cloud top temperatures generate more precipitation than hot or warm cloud top temperatures. Keeping this point in mind, first currently available techniques in the literature are explained in detail including Arkin, GOES precipitation index, adjusted GOES precipitation index, Griffith-Woodley, Negri-Adler-Wooley, convective-stratiform, enhanced convective-stratiform, automatic estimator, and advanced automatic estimator techniques. They include empirical equations in their structure and the parameters of these equations must be determined for our country. On the other hand, these methods include linear relationships.*

*In this paper, one convective precipitation event in 2000 is examined each within time period as 5-7 September. These are explained by considering Meteosat 7 infrared channel data for 6-hour total rainfall amounts in such a manner that the data at the upper troposphere vertical levels are transferred to grid points from NCEP/NCAR. The application of*

*the methodology is presented for 26 Marmara region rain gauge stations.*

*On the other hand, as effective methodology Artificial Neural Network (ANN) is used and, it has the analogy such that the inputs are taken from the environment through the neurons and transmitted to the brain. ANNs can be thought as a black box model, which processes inputs and produces convenient outputs for inputs. As a first stage this black box is trained and after training system reaches level of decision for inputs. ANNs have ability of learning, due to their training stages. This is feature that there is not available in any classical method. The ANN model can learn by training similar to a human and it has a non-linear structure. Such a non-linearity provides a distinctive possibility in the domain of artificial intelligence. For the model ANN and its analysis, various statistical criteria are used as detection probability (POD), bias, wrong alarm ratio (FAR), critical success index (CSI), target ratio (HR), and transferring of grid points to station points by using a method called inverse distance square. These statistical criteria are explained in this paper.*

*By following the methodology explained above, as a result of ANN properties, convenient architecture for total precipitation amount prediction is proposed that constitutes single input, hidden and output layers with 37, 19 and 1 neurons, respectively. Furthermore, this model is used for precipitation prediction by considering each within time period as 5-7 September. The correlation value of ANN model is 0.89 in testing. Moreover, statistical values are calculated as  $POD = 0.61$ ,  $FAR = 0.30$ ,  $CSI = 0.49$ ,  $BIAS = 0.86$  and  $HR = 0.77$ . For this period, rainy events are predicted with success. As it is seen from the descriptions and application results, the cloud top temperature is more related to precipitation by considering low level data of troposphere. Under the light of the proposed prediction model this is the result of key parameter, which reflects the cloud top temperature significant relationship to precipitation. Although other parameters have also significance to lesser degrees the final prediction model take into consideration few of the input variables. In the mean time different combinations of the prediction are investigated throughout the study.*

**Keywords:** Marmara, precipitation, short range, prediction, artificial neural network, remote sensing.

## **Giriş**

Yağışların ölçümü, modellenmesi ve tahminleri yağış kaynaklı doğal afetlerin (sel, taşkın, vb.) önlenmesi ile su kaynakları ve havza yönetimi için çok önemlidir. Yeryüzünde kurulu olan yağış ölçer ağları hem uzay hem de zaman dağılımı olarak büyük değişkenlikler gösterir. Bu değişkenlik küçük ölçeklerde meydana gelen şiddetli yağışların belirlenmesini zorlaştırır. Özellikle yaz aylarında orta enlemlerde görülen konvektif yağışların zaman ve alan yağış desenleri (paternleri), mevcut hava tahmin modelleri ile tam olarak belirlenememektedir (Reudenbach vd., 2001). Son on yıldır daha güvenilir sonuçlar alınmaya başlanmış olmakla beraber, hava tahmin modelleri yine de küçük ölçeklerdeki şiddetli yağışları belirleyememektedir. Bu eksikliği bir ölçüde giderebilmek için son zamanlarda uydular yoluyla yağış bilgisi hava tahmin modellerine giriş verisi olarak kullanılmaktadır.

Yağış tür ve miktarının belirlenmesi konusunda, uzaktan algılama tekniklerinden yararlanma alanında önemli gelişmeler bulunmaktadır (Reudenbach vd., 2001; Boi vd., 2004; Feidas vd., 2005). Bu nedenle hava tahmin modellerini destekleyen uzaktan algılama teknikleri, özellikle konvektif sistemlerin belirlenmesi ve tahmininde son derece önemli katkılar sağlamaktadır. Yer istasyonlarında meydana gelebilecek herhangi bir problemten dolayı veri temininde karşılaşılabilecek aksaklıklara karşı en önemli seçenek uydu görüntüleri olmaktadır (Levizzani vd., 2001).

Çok kararsız bir yapıya sahip olan tropikler arası konverjans alanında (ITCZ: Intertropical Convergence Zone) yapılan çalışmalar, konvektif yapılar için bulut tepe sıcaklığının yağış ile ilişkilendirilebilen anahtar bir parametre olduğunu gösterir (Desbois vd., 1989). Bu nedenle kızılötesi görüntülerden yağış miktarının kestirilmesi için eşik değerlerin belirlenmesine gidilmektedir (Desbois vd., 1989). Konvektif kuleler olarak da adlandırılan kümülünimbüs yapısı güçlü düşey hava hareketleri dolayısıyla bulut tepesinde adeta bir kaynama etkisine sahiptir. Bu nedenle ITCZ alanı içerisinde konvektif ku-

lelerin araştırılması bir anlamda yağışın araştırılmasına karşı gelir.

Ampirik olarak yağışı bulut tepe sıcaklığı ile ilişkilendiren pek çok yöntem geliştirilmiştir. Tüm bu yöntemler soğuk tepeli bulutların sıcak tepelilerden daha fazla yağış ürettikleri temeline dayanır (New vd., 2001; Levizzani vd., 2002). Bunlar arasında Arkin, GOES yağış indeksi, ayarlanmış GOES yağış indeksi, Griffith-Woodley, Negri-Adler-Woodley, konvektif-stratifform, güçlendirilmiş konvektif-stratifform, otomatik tahmin edici ve geliştirilmiş otomatik tahmin edici teknikleri bulunur.

Yukarıda belirtilen yöntemler 1979 ve 1990 yılları arasında geliştirilmiş olmasına rağmen günümüzde de kullanılmaktadır (Adler ve Negri, 1993; Reudenbach vd., 2001; Tarruella ve Jorge, 2003; Boi vd., 2004; Feidas vd., 2005).

## **Çalışma bölgesi ve iklim yapısı**

Türkiye'nin coğrafi bölgeleri arasında Marmara Bölgesi, genel anlamda Akdeniz iklimi etkisi altında olmasına rağmen aynı zamanda karasal, Akdeniz ve Karadeniz iklimleri arasında bir geçiş özelliğine sahiptir. Kışları Akdeniz iklimi kadar ılık, yazları Karadeniz iklimi kadar yağışlı değildir. Karasal iklim kadar kışı soğuk, yazı da kurak geçmemektedir. Bölgenin Karadeniz kıyılarında, özellikle Anadolu kısmında yağışlar fazladır. İç Trakya ise karasal iklimin özelliklerini taşımaktadır, kışlar daha soğuk ve kar yağışlı, yazlar ise daha kuraktır. Uzun yıllar Ocak ayı ortalama sıcaklığı 5°C, Temmuz ayı ortalama sıcaklığı 24°C ve yıllık ortalama sıcaklık 14°C'dir. Ortalama yıllık yağış yaklaşık 600 mm'dir ve yaz yağışlarının yıllık toplam içindeki payı %11'dir. Ayrıca yıllık ortalama bağıl nem ise %73'tür (Şensoy, 2006).

Çalışma alanı olarak seçilen Marmara Bölgesi'ndeki 26 istasyonun isimleri, istasyon kodları ve konumları Tablo 1'den görülebilir. Bu istasyonlardan Şile, Kumköy, Sarıyer, Florya, İTÜ-Maslak, Göztepe, Kartal, Tekirdağ, Çanakkale, Gökçeada, Ayvalık, Burhaniye, Bandırma ve Kocaeli istasyonları deniz yakınındaki istasyon-

lar olup geriye kalanlar ise bölgenin iç kesimlerinde yer almaktadır.

Tablo 1. Çalışmada kullanılan istasyonlar

İSTASYON ADI	İSTASYON KODU	ENLEM (°)	BOYLAM (°)
Edirne	17050	41.67	26.57
Kırklareli	17052	41.73	27.22
Çorlu	17054	41.16	27.82
Tekirdağ	17056	40.98	27.48
Kumköy	17059	41.30	29.00
Sarıyer	17061	41.22	29.12
Göztepe	17062	40.97	29.08
Kocaeli	17066	40.77	29.92
Adapazarı	17069	40.78	30.42
Gökçeada	17110	40.60	26.07
Çanakkale	17112	40.13	26.40
Bandırma	17114	40.33	28.00
Bursa	17116	40.18	29.07
Balıkesir	17152	39.64	27.89
Ayvalık	17175	39.31	26.69
Uzunköprü	17608	41.26	26.69
Şile	17610	41.17	29.60
İpsala	17632	40.92	26.38
Malkara	17634	40.89	26.91
Florya	17636	40.98	28.78
Geyve	17662	40.52	30.30
Gönen	17674	40.11	27.64
Dursunbey	17700	39.58	28.63
Burhaniye	17722	39.50	26.98
Kartal	18118	40.90	29.17
İTÜ-Maslak	-	41.01	29.03

## Veri

Bu çalışmada 2000 yılının Meteosat 7 uydusuna ait saatlik kızılötesi kanalı verileri kullanılmıştır. Uydu verisi Devlet Meteoroloji İşleri (DMİ) tarafından EUMETSAT'tan temin edilmiştir. OpenMTP formatında gelen bu verinin çözümü için özel bir yazılım kullanılmıştır (Mert, 2005). Çalışmanın bir başka veri kaynağı olarak da DMİ Hidroloji Servisi'nden alınan 2000 yılına ait saatlik kayıt eden yağış ölçer (plüviyograf) verileri kullanılmıştır. Atmosferin düşey yapısına ait sıcaklık, bağıl nem, düşey hız değişkeni, jeopotansiyel yükseklik ve rüzgarın u ve v bileşenlerinin düğüm noktalarına aktarılmış gözlem değerleri ise NCEP (National Centers for Environmental Prediction) - NCAR (National Center for Atmospheric Research)'dan sağlan-

mıştır. Bu verinin zaman çözünürlüğü 6 saat, uzay çözünürlüğü ise 2.5°'dir. Geliştirilen bir doğrusal enterpolasyon yazılımı ile uzay çözünürlüğü 0.5°'ye yükseltilmiştir.

## Yapay sinir ağları

Canlıların biyolojik özelliklerinin sanal ortamda taklit edilmesiyle geliştirilen yöntemlerden ilki Yapay Sinir Ağları (YSA)'dır. Beynin zor işlemleri yapabilme, karmaşık örnekleri kavrayabilme ve özellikle ilgili fizik büyüklükleri bilmeden sadece deneme yöntemi ile bazı şeyleri öğrenebilmesi ilgi çeken cazip bir araştırma konusu olmuştur. Duyu organlarımız yardımıyla çevreden aldığımız uyarımlar, vücudumuzdaki sınırlar vasıtasıyla beyne iletilirler ve beyin bu uyarımlar doğrultusunda karar verir. YSA'ların çalışma prensibi de buna dayanmaktadır.

YSA'ları, verilen girdileri işleyerek bu girdilere karşı çıktı üreten bir kara kutu modeli olarak düşünebiliriz. Önce bu kara kutu bir eğitime tabi tutulur ve eğitim aşamasından sonra sistem girdilere karşı karar verebilecek düzeye ulaşır. YSA'lar bir eğitim sürecine sahip olmalarından dolayı öğrenebilme yeteneğine sahiptirler. Bu, geleneksel yöntemlerde olmayan bir özelliktir. Sistem bilgilerin paralel işlenmesi ve hataların minimum yapılarak sinir hücreleri arasındaki bağlantı ağırlıklarının yenilenmesiyle öğrenmektedir. Dolayısıyla öğrenilen bilgi bağlantı ağırlıklarında saklıdır. Diğer bir anlamda, YSA'lar da insanlar gibi deneyerek ya da yaşayarak öğrenmektedirler. Özetle YSA'lar, insan beyninin özelliklerinden olan öğrenme yolu ile yeni bilgiler türetebilme, yeni bilgiler oluşturabilme ve keşfedebilme gibi yetenekleri bilgisayarlara kazandıran sistemlerdir. Ayrıca bu yöntem genelleme yapabilme ve sınırsız sayıda değişkenle çalışabilme gibi başka özelliklere de sahiptir. Tüm bu özelliklerinden dolayı YSA'lar, kontrol, görüntü işleme, sınıflandırma, görüntü ve ses tanıma, modelleme, kalite kontrolü, kestirim ve tahmin (öngörü) hesaplamaları gibi pek çok alanda kullanılmaktadır ve uygulama alanları için bir sınırlama da bulunmamaktadır.

Yapay Sinir Ağları'nın pek çok alanda olduğu gibi meteorolojik alanda da uygulamaları mev-

cuttur. Örneğin gökgürültülü sağnak yağışların tahmini (McCann, 1992), uydu görüntülerinden denizler üzerindeki bulutların sınıflandırılması (Bankert ve Aha, 1996), tornadoların tahmini (Marzban ve Stumpf, 1996), hem karalar hem de denizler üzerindeki bulutların sınıflandırılması (Miller ve Emery, 1997), zarar veren rüzgarların tahmini (Marzban ve Stumpf, 1998), meteorolojik değişkenlerden sıcaklık tahmini (Sönmez ve Şen, 1998), yağış miktarının tahmini (Hall vd., 1999) uzun vadeli muson tahmini (Wu vd., 2001), günlük yağış tahmini (Applequist vd., 2002), genel dolaşım modelleri için bir alt ölçekleme (downscaling) yöntemi (Tatlı, 2004), kısa vadeli yağış tahmini (Feng ve Kitzmiller, 2006), rüzgar hızının alansal tahmini (Öztopal, 2006) vb.

### Yapay sinir hücresi

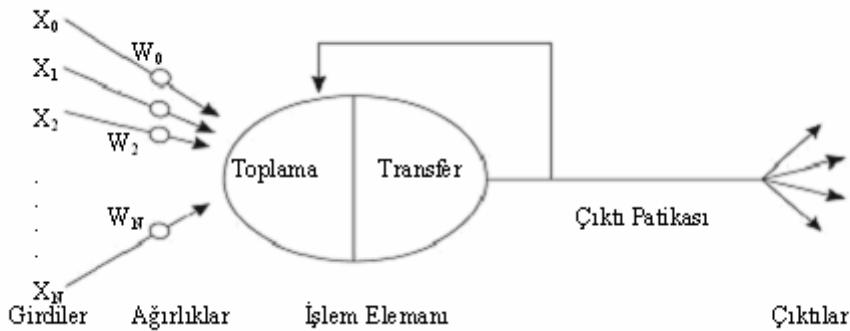
Bir YSA hücresi biyolojik bir sinir hücresine benzetilerek oluşturulmuştur. Bu hücre, biyolojik bir sinir hücresi gibi gelen bilgiyi sahip olduğu eşik değerinin izin verdiği oranda algılar ve işleyerek komşu sinir hücresine aktarır. Bu işlem çıkış sinir hücresine kadar devam eder, buradaki çıkış sinir hücresi de biyolojik anlamda beyindir. Başka bir deyişle YSA hücresi, biyolojik sinir hücresinin şekil ve işlev olarak bir taklididir.

Şekil 1'den görüldüğü üzere her bir  $x_i$  girdisi kendisine karşılık gelen  $w_i$  ağırlık katsayısı ile çarpılır, tüm bu çarpımlar toplanır ve bir transfer (aktivasyon) fonksiyonundan geçirilerek bir çıktı üretilir. Burada başlangıçta girdilere ait olan  $w_i$  ağırlıkları belirlenmelidir, bu rastgele de


olabilir. Ağırlıkların belirlenmesinden sonra girdiler bu ağırlıklar ile çarpılır ve toplama fonksiyonuna gönderilir. Toplama fonksiyonu olarak toplama işlemi seçilebileceği gibi maksimum, minimum, ortalama veya çarpım gibi işlemlerden herhangi biri de seçilebilir. Buradan elde edilen sonuç daha sonra probleme göre seçilen doğru, adım, eşik, sigmoid, hiperbolik tanjant gibi transfer fonksiyonlarından herhangi birinden geçirilerek ilgili sinir hücresinin çıktısı elde edilir.

### Yapay sinir ağlarının genel yapısı

YSA'ların genel yapısına bakıldığında (Şekil 2), sistemin en az 3 tabakadan meydana geldiği görülür. İlk tabaka girdi katmanındır ve son tabaka da çıktı katmanını meydana getirmektedir. Diğer kısım ise gizli tabakadır ve bu tabaka ilgililenen problemin özelliğine göre birden fazla katman içerebilir. Her katman yapay sinir hücrelerine sahiptir ve çıktı tabakası hariç bir katmandaki yapay sinir hücreleri bir sonraki katmanın yapay sinir hücreleriyle ağırlık katsayılarıyla bağlıdır. Girdi (çıkıtı) katmanındaki sinir hücre sayısının girdi (çıkıtı) değişkenleri sayısı kadar olacağı oldukça açıktır. Oysaki gizli tabakadaki sinir hücre sayısının ne olacağı sadece girdiyle ilişkilidir. Literatürde genelde iki çeşit uygulama vardır. İlki  $n$  girdi sayısı olmak üzere  $2n+1$  ve diğeri de  $(n+1)/2$  sayılarıdır. Elbetteki problemin özelliğine göre gizli tabakada daha farklı sayıda sinir hücresi de kullanılabilir. Bu sayının çok olması sistemin çözüme ulaşma hızını azaltacağı unutulmamalıdır. YSA'lar hakkında detaylı bilgi için Haykin (2001) ve Şen (2004)'e bakılabilir.



Şekil 1. Yapay sinirin genel yapısı (Yurtoğlu, 2005)



Şekil 2. YSA'ların genel yapısı (Yurtoğlu, 2005)

### Kullanılan istatistik bilgiler

Bu çalışmada kullanılacak istatistik bilgileri Şekil 3'te düzeni gösterilen farklı dört büyüklüğü (A, B, C ve D) esas alarak tanımlanmıştır. Burada A gözlemin yağmurlu olmaması durumunda tahminin yağmursuz olması yüzdesini yani olasılığını gösterir. Diğer büyüklükler de benzer şekilde tanımlanmıştır. Bu şekildeki büyüklükler esas alınarak Wilks (1995) tarafından aşağıdaki istatistik büyüklükler önerilmiştir.

### Yakalama olasılığı

Yakalama olasılığı, POD (Probability of detection), modelin doğru tahmin ettiği yağışlarının (D) gözlenen tüm yağışlara (B+D) olan oranını ya da başka bir deyişle modelin, gözlenen yağışları doğru yakalama olasılığını gösterir. Buna göre;

$$POD = \frac{D}{B+D} \quad (1)$$

POD değeri 1 ise model tüm yağışlı olayları yakalama başarısına sahiptir.

### Tarafılık

Tarafılık, BIAS, modelin doğru tahmin ettiği yağışsız durumlar (A) hariç olmak üzere, modelin yağış tahmin ettiği tüm zamanların (C+D) gözlenen tüm yağışlı zamanlara (B+D) oranını ya da başka bir deyişle modelin, gözlemlerden daha yüksek ya da gözlemlerden daha düşük tahminlerde bulunmasını ifade eder.

$$BIAS = \frac{C+D}{B+D} \quad (2)$$

BIAS değeri 1'den büyük ise model gözlemlerden daha yüksek tahminlerde, 1'den küçük ise model gözlemlerden daha düşük tahminlerde bulunmaktadır. BIAS 1 ise tahmin sonuçları mükemmeldir.

### Yanlış uyarı oranı

Yanlış uyarı oranı, FAR (False alarm ratio), modelin yağış vermesi durumunda (C ve D), yanlış tahmin edilen yağışların (C), yağışlı ve yağışsız gözlemler toplamına (C+D) olan oranını ya da başka bir deyişle modelin, yanlış uyarı verme olasılığını, ifade eder. Buna göre;

$$FAR = \frac{C}{C+D} \quad (3)$$

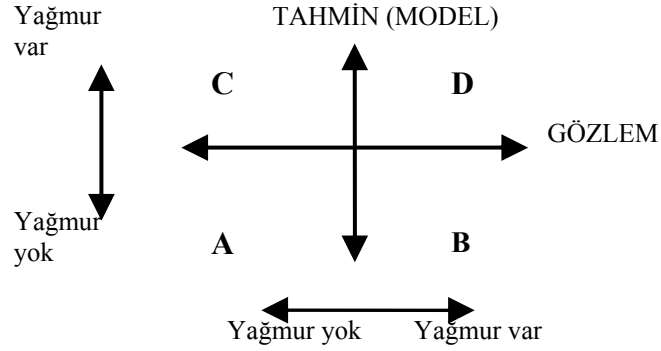
FAR değeri 0 ise bu modelin yanlış yağış uyarısı vermemesi anlamına gelmektedir.

### Kritik başarı indeksi

Kritik başarı indeksi, CSI (Critical succes index), modelin doğru tahmin ettiği yağışlarının (D), modelin doğru olarak yakaladığı yağışsız zamanların dışındaki tüm gözlemlere (B+C+D) olan oranını ya da başka bir deyişle modelin, yağış tahmininde bulunmadığı durumlardaki gözlenen yağışları doğru yakalama olasılığını ifade eder. Buna göre;

$$CSI = \frac{D}{B+C+D} \quad (4)$$

CSI değeri 1 ise model tüm yağışlı olayları yakalama başarısına sahiptir.



Şekil 3. Gözlem – Tahmin yağış ihtimalleri

### İsabet oranı

İsabet oranı, HR (Hit rate), modelin doğru tahmin ettiği yağışlı ve yağışsız zamanların (A+D) tüm gözlemlere (A+B+C+D) olan oranını ya da başka bir deyişle modelin, gözlenen yağışlı ve yağışsız durumları doğru yakalama olasılığını ifade eder. Buna göre;

$$HR = \frac{A + D}{A + B + C + D} \quad (5)$$

HR değeri 1 ise model tüm yağışlı ve yağışsız olayları yakalama başarısına sahiptir.

### Düğüm noktası değerlerinin istasyonlara taşınması


Burada düğüm noktalarındaki NCEP - NCAR verisinin istasyonlara aktarılmasında istatistik yaklaşım olarak “Ters Mesafe Kareleri Yaklaşımı” kullanılmıştır (Davis, 1986). Şekil 4’ten görüldüğü üzere  $g_1$ ,  $g_2$ ,  $g_3$  ve  $g_4$  düğüm noktalarını,  $i$  istasyon noktasını ve  $a$ ,  $b$ ,  $r$ ’ler ise uzaklıkları göstermektedir. Buradan hareketle önce uzunlukları,

$$r_1 = \sqrt{a_1^2 + b_1^2} \quad (6)$$

denklemine göre daha sonra da ilgili meteorolojik değişken ağırlıklı ortalama (ağırlıklar ters mesafe kareleri olmak üzere) yöntemi ile

$$i = \frac{\frac{1}{r_1^2} g_1 + \frac{1}{r_2^2} g_2 + \frac{1}{r_3^2} g_3 + \frac{1}{r_4^2} g_4}{\frac{1}{r_1^2} + \frac{1}{r_2^2} + \frac{1}{r_3^2} + \frac{1}{r_4^2}} \quad (7)$$

denkleminde hesaplanabilir.



Şekil 4. Düğüm noktası yapısı

### YSA mimarisi

Çalışma için kurulan YSA mimarisi Şekil 5’ten görüldüğü üzere giriş, gizli ve çıkış katmanlarına sahiptir. Giriş tabakası 37 yapay sinir hücrelerine sahiptir ve gizli tabakadaki yapay sinir hücreleri sayısı,  $n$  giriş hücre sayısı olmak üzere  $(n+1)/2$  yani 19 olarak alınmıştır.

Toplam hata,  $H$ , eşitliği,


$$H = \sum_{k=1}^L \sum_{j=1}^q (b_{kj} - \zeta_{kj})^2 \quad (8)$$

ile ifade edilir. Burada  $b_{kj}$  gözlem değerleri ve  $\zeta_{kj}$  ise model tahminleridir. Ağırlıkları ayarlamak için hızlı yakınsayan bir yöntem olan Levenberg-Marquardt yöntemi seçilmiştir. Bu metodun matematik ifadesi aşağıda verilmiştir.

$$W_{i,j}^{yeni} = W_{i,j}^{eski} - [J^T J + \mu I]^{-1} J^T H \quad (9)$$

Bu denklemdeki  $J$  hataların ağırlıklara göre türevlerini içeren Jacobian matrisini,  $J^T$  Jacobian matrisinin transpozmesini,  $I$  birim matrisi,  $\mu$  öğrenme oranını göstermektedir.


Yağış miktarının 6 saat öncesinden tahmin edilebilmesi için çıkış değişkeni  $t$  zamanına ait yağış miktarı olup giriş değişkenlerinin zamanı  $t-6$  ve bulut tepe sıcaklığı ise  $t$  ile  $t-6$  zaman aralığındaki minimum sıcaklık olarak alınmıştır.



Şekil 5. Çalışmada kullanılan YSA mimarisi

## 5-7 Eylül 2000 dönemi analiz ve uygulaması

Şekil 6'dan görüldüğü gibi 6 Eylül 2000, 06:00 GMT itibarıyla, tüm Türkiye bölünmüş iki alçak basınç merkezinin etkisi altında bulunmaktadır. Bunlardan ilki Türkiye'nin kuzeybatısına yerleşmiş olup, diğer merkez Basra Körfezi üzerinden Türkiye'nin Güneydoğu ve Doğu'suna doğru uzanmaktadır. Çalışma bölgesi olan Marmara Bölgesi'nin ilk alçak basınç merkezinin etkisi altında bulunduğu söylenebilir. Diğer taraftan Şekil 7'de görüldüğü üzere bu merkez zaman içerisinde kuzeydoğuda Kırım Yarımadası'na doğru hareket etmektedir. Ayrıca Şekil 6'da Karadeniz üzerinde merkezlenmiş olan alçak basınç merkezinin yukarısında, 500 mb seviyesinde alçak merkez ve oluk gözlenmektedir. Bu yapı yerdeki sistemin soğuk karakterli olduğunu göstermektedir. Çünkü soğuk karakterli alçak basınç alanlarında sıcaklık alanı ile basınç alanı arasında pozitif ilişki mevcuttur (Blueistein, 1993; Saucier, 2003.). Dolayısı ile Marmara Bölgesi soğuk adveksiyonun etkisi altındadır. Ayrıca 6 Eylül 2000, 00:00 GMT itibarıyla çalışma bölgesinde bir soğuk cephe geçişi kaydedilmiştir. Bu yapı yer istasyonlarında gözlenen sağnak yağışları açıklamaktadır.




Şekil 6. 1000 mb ve 500 mb sinoptik kartı (6 Eylül 2000, 00:00 GMT)



Daha önce verilen YSA mimarisine eldeki 300 adet verinin yaklaşık %75'i yani 220 tanesi eğitim ve geri kalan 80 tanesi de tahmin amaçlı olarak programa sokulmuştur.

Yukarıda açıklanan meteorolojik yapıya bağlı olarak oluşan yağışların meteorolojik değişkenler ile olan ilişkisi Tablo 2'de gösterilmiştir. Burada, sıcaklık değişkeni tüm seviyelerde yağış ile ilişkisiz bulunmaktadır. Jeopotansiyel yükseklikler 1000 mb ve 850 mb seviyelerinde sırasıyla -0.25 ve -0.15 korelasyona sahipken diğer seviyelerde çok düşük ve hatta ilişki 0'a yakındır. Düşey hız değişkeni tüm seviyelerde sırasıyla -0.36, -0.14, -0.21, -0.14, -0.19 ve -0.28 korelasyon değerlerine sahiptir. Rüzgarın v bileşeni

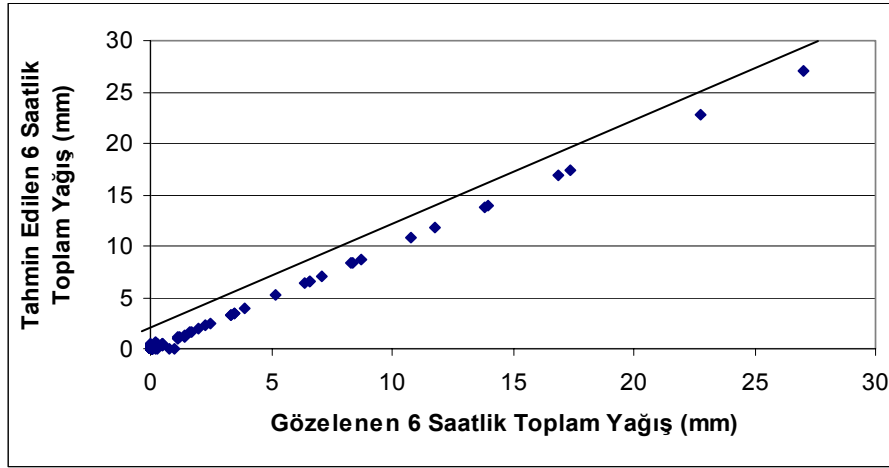
ni incelenecek olursa 925 ve 600 mb seviyelerinde ihmal edilecek kadar küçük bir ilişki mevcutken diğer seviyelerdeki korelasyon değerleri 0.11, 0.11, 0.35 ve 0.43'tür. Rüzgarın u bileşeninde ise 1000 ve 500 mb seviyelerindeki 0 korelasyona karşın diğer seviyelerde 0.13, 0.19, 0.14 ve 0.18 korelasyon değerleri görülmektedir. Diğer bir değişken olan bağıl nem ise 1000 ve 925 mb seviyelerinde yağış ile bir ilişkiye sahip değilken geriye kalan seviyelerde 0.14, 0.30, 0.44 ve 0.33'lük pozitif ilişkiye sahiptir. Bulut tepe sıcaklığının yağış ile olan ilişkisi -0.52 ile en yüksek korelasyona sahiptir. İşte bu sebeple yağışın korelasyon sıralamasında en fazla bulut tepe sıcaklığından etkilendiği anlaşılır.




Şekil 7. 1000 mb ve 500 mb sinoptik kartı (7 Eylül 2000, 00:00 GMT)

Tablo 2. Meteorolojik değişkenlerin yağış miktarı ile olan ilişki katsayıları

Meteorolojik Değişkenler	Seviyeler					
	1000 mb	925 mb	850 mb	700 mb	600 mb	500 mb
Sıcaklık	0.00	0.01	-0.02	0.06	0.01	0.07
Jeopotansiyel Yükseklik	-0.25	-0.01	-0.15	-0.04	-0.01	-0.01
Düşey Hız Değişkeni	-0.36	-0.14	-0.21	-0.14	-0.19	-0.28
Rüzgarın v Bileşeni	0.11	0.06	0.11	0.35	0.03	0.43
Rüzgarın u Bileşeni	0.05	0.13	0.19	0.14	0.18	-0.02
Bağıl Nem	0.02	0.04	0.14	0.30	0.44	0.33
Bulut Tepe Sıcaklığı			-0.52			



Şekil 8. Modelin eğitim aşamasındaki başarısı



Şekil 9. Modelin tahmin aşamasındaki başarısı

Şekil 8 ve 9 model ve tahmin değerlerinin birbirine göre saçılma diyagramlarını göstermektedir. Bu diyagramların özelliği model ve tahmin arasındaki uyumun nasıl olduğunu göstermesidir. Eğer saçılma noktaları 45° lik doğrunun etrafında rastgele biçimde dağılırlarsa model yağış olayını ortalama olarak o kadar iyi tahmin etmektedir. Örneğin Şekil 8'deki noktaların tümü nerede ise bu 45° lik diyagramın üzerine düşmektedir. Bu modelin yağışı çok iyi ve tarafsız olarak tahmin ettiğini göstermektedir. Ancak Şekil 9'da her ne kadar ortalama olarak 45°lik doğru etrafında saçılma olmuyorsa da bir bakıma model yağış değerlerini az öngörmektedir yani model taraflıdır. Eğitim aşamasında YSA modeli 1.0 ve tahmin aşamasında ise 0.89 korelasyon değerlerine sahiptir.

Bu yağışlı günler için eğitim aşamasındaki modelin gerçekleşen tüm yağışlar içerisinde yakaladığı yağışların ölçüsü olan yakalama olasılığı, POD, 0.61'dir. Yağış olmadığı halde modelin yağış verdiği oranı temsil eden yanlış uyarı oranı, FAR, ise 0.27 olarak hesaplanmıştır. Modelin doğru yakaladığı yağışların gözlenen yağışlar ile modelin verdiği yağışların toplamına oranını ifade eden kritik başarı indeksi, CSI, 0.50'dir. Taraflılık, BIAS, 0.83 ve modelin toplamdaki başarı oranı olan isabet oranı, HR, ise 0.84'tür. Tahmin aşamasına gelindiğinde beklendiği gibi korelasyonda bir düşüş görülmektedir. Yukarıda verilen istatistik değerlere göre POD=0.61; FAR=0.30; CSI=0.49; BIAS=0.86 ve HR=0.77 olmaktadır. Sonuç olarak elde edilen tüm istatistiksel değerler bu zaman dilimi içe-

risinde kabul edilebilir sınırlar içerisinde kalmaktadır.

## Sonuçlar ve öneriler

Yeryüzünde kurulu olan yağış ölçer ağlarının hem zaman hem de uzay dağılımının büyük değişkenlikler göstermesi nedeniyle, küçük ölçeklerdeki şiddetli yağışların tahmini zordur ve hava tahmin modelleri de bu zorluk nedeniyle küçük ölçeklerdeki sağnak yağışları yakalayamamaktadır. Günümüzde bu sorunu ortadan kaldırmak için en uygun teknik zaman ve uzay çözünürlüğü yüksek olan uydu teknolojisidir. Uydulardan elde edilen bilgiler hava tahmin modellerinde girdi olarak kullanılmaktadır.

Bu çalışmada 2000 yılı içerisindeki 5-7 Eylül döneminde gözlenen bir konvektif yağışlı olay incelenmiştir. Bu zaman aralığındaki Meteosat 7'nin kızılötesi kanal verisi, çalışma istasyonlarındaki 6 saatlik toplam yağış verisi ve NCEP/NCAR'ın düğüm noktalarına aktarılmış troposferin düşey seviye verileri kullanılmıştır. Geliştirilen bir Yapay Sinir Ağları (YSA) modeli ile de yağış miktarı tahmin edilmeye ve bu modelin başarısı ölçülmeye çalışılmıştır.

Uygulama bölümünde anlatılanlar doğrultusunda görülmektedir ki, bulut tepe sıcaklığı yağış ile troposferin düşey seviye verilerine nazaran daha yüksek oranda ilişkilidir. Bu da, daha önce ifade edilen, konvektif yapılar için bulut tepe sıcaklığının yağış ile anlamlı bir ilişkiye sahip anahtar bir parametre olmasının bir sonucudur. Yapılan örnek uygulamanın sonucunda, modelin başarılı olduğu görülmektedir. Bu durum hesaplanan istatistik değerlerin modelin hem eğitim hem de tahmin aşamaları için kabul edilebilir seviyede olmasından anlaşılmaktadır.

Bir modelin yağışı belirleyebilmesinin yanında aynı zamanda yağışın olmayacağını da tahmin edebilmesinin önemli olması dolayısıyla, yapılan bu çalışmada yağışın olmadığı ve olduğu durumların ayıklanması yapılmayıp, aksine yağışlı ve yağışsız tüm veriler sisteme sokulmuştur. Kurulan bu YSA mimarisinin başarısız kaldığı durumlarda bu tür ayrımlara gidilerek sonuçlar iyileştirilebilir. Ayrıca bu çalışmada kul-

lanılan düğüm noktası verilerinin çözünürlüğü 2.5° yerine daha yüksek olarak alındığı takdirde, buradan gelecek troposferin düşey seviye verilerinin yağış ile olan ilişkisinin yükseltilebileceği görülebilir. Verinin düğüm noktalarından istasyonlara taşınması için bu çalışmada kullanılan ters mesafe kareleri yaklaşımı ilgili değişkenin istasyona aktarılmasındaki ayarlamayı ifade eden bir takım sabit değerler ile geliştirilmesine ihtiyaç vardır. Çalışma alanı içerisindeki istasyon sıklığı ne kadar fazla ise model de o kadar başarılı olacaktır. Buradan hareketle sonraki çalışmalar için istasyon sıklığı arttırılmalıdır.

## Kaynaklar

- Adler, R.F. ve Negri, A.J., (1993). Estimation of monthly rainfall over Japan and surrounding waters from a combination of low-orbit microwave and geosynchronous IR data, *Journal of Applied Meteorology*, **32**, 335-356.
- Applequist, S., Gahrs, G.E. ve Pfeffer, R.L., (2002). Comparison of methodologies for probabilistic quantitative precipitation forecasting, *American Meteorological Society*, **17**, 783-799.
- Bankert, R.L. ve Aha, D.W., (1996). Improvement to a neural network cloud classifier, *Journal of Applied Meteorology*, **35**, 2036-2039.
- Bluestein, H.B., (1993). *Synoptic-dynamic meteorology in midlatitudes*, Oxford University Press, Oxford.
- Boi, P., Marrocu, M. ve Giachetti, A., (2004). Rainfall estimation from infrared data using an improved version of the Auto-Estimator Technique, *International Journal of Remote Sensing*, **25**, 4657-4673.
- Davis, J., (1986). *Statistic and data analysis in geology*, John Wiley & Sons, Inc., New York.
- Desbois, M., Kayiranga, T. ve Gnamien, B., (1989). Diurnal cycle of convective cloudiness over tropical Africa observed from Meteosat: Geographic characterization and interannual variations, *Ann. Geophys.*, **7**, 395-404.
- Feidas, H., Lagouvardos, K., Kotroni, V. ve Cartalis, C., (2005). Application of three satellite techniques in support of precipitation forecasts of a NWP model, *International Journal of Remote Sensing*, **26**, 5393-5417.
- Feng, Y. ve Kitzmiller, D.H., (2006). A short range quantitative precipitation forecast algorithm using back-propagation neural network approach, *Advance in Atmosheric Sciences*, **23**, 405-414.

- Hall, T., Brooks, H.E. ve Doswell C.A., (1999). Precipitation forecasting using a neural network, *Weather Forecasting*, **14**, 338-345.
- Haykin, S., (2001). *Kalman filtering and neural networks*, Wiley, New York.
- Levizzani, V., Schmetz, J., Lutz, H., Kerkmann, J., Alberoni, P.P. ve Cervino, M., (2001). Precipitation estimations from geostationary orbit and prospects for Meteosat second generation, *Meteorological Applications*, **8**, 23-41.
- Levizzani, V., Amorati, R. ve Meneguzzo, F., (2002). A review of satellite-based rainfall estimation methods. *MUSIC*, [www.isao.bo.cnr.it/meteosat/papers/MUSIC-Rep-Sat-Precip-6.1.pdf](http://www.isao.bo.cnr.it/meteosat/papers/MUSIC-Rep-Sat-Precip-6.1.pdf).
- Marzban, C. ve Stumpf, G.J., (1996). A neural network for tornado prediction based on Doppler radar-derived attributes, *Journal of Applied Meteorology*, **35**, 617-626.
- Marzban, C. ve Stumpf, G.J., (1998). A neural network for damaging wind prediction, *Weather Forecasting*, **13**, 151-163.
- McCann, D.W., (1992). A neural network short-term forecast of significant thunderstorms, *Weather Forecasting*, **7**, 525-534.
- Mert, İ., (2005). *OpenMTP kodlu Meteosat 7 uydu verisinin çözüm ve görüntüleme proramı*, Devlet Meteoroloji İşleri Genel Müdürlüğü, Ankara.
- Miller, S.W. ve Emery, W.J., (1997). An automated neural network cloud classifier for use over land and ocean surface, *Journal of Applied Meteorology*, **36**, 1346-1362.
- New, M., Todd, M., Hulme, M. ve Jones, P., (2001). Precipitation measurements and trends in the twentieth century. *International Journal of Climatology*, **21**, 1899-1922.
- Öztopal, A., (2006). Artificial neural network approach to spatial estimation of wind velocity data, *Energy Conversion and Management*, **47**, 4, 395-406.
- Reudenbach, C., Heinemann, G., Heuel, E., Bendix, J. ve Winiger, M., (2001). Investigation of summertime convective rainfall in Western Europe based on a synergy of remote sensing data and numerical models, *Meteorology and Atmospheric Physics*, **76**, 23-41.
- Saucier, W.J., (2003). *Principle of meteorological analysis*, Dover Publications.
- Sönmez, İ. ve Şen, Z., (1998). Artificial neural network approach for natural atmospheric event dynamics and application in meteorology, *2<sup>nd</sup> International Symposium on Intelligent Manufacturing Systems – IMS'98*, **1**, 325-332, Sakarya.
- Şen, Z., (2004). *Yapay sinir ağları ilkeleri*, Su Vakfı Yayınları, İstanbul.
- Şensoy, S., (2006), Türkiye iklimi, Klimatoloji Şube Müdürlüğü, DMI, Ankara, [www.meteor.gov.tr](http://www.meteor.gov.tr)
- Tatlı, H., (2004). New statistical downscaling methods and applications of Turkey, *Doktora Tezi*, İTÜ Fen Bilimleri Enstitüsü, İstanbul.
- Tarruella, R. ve Jorge, J., (2003). Comparison of three infrared satellite techniques to estimate accumulated rainfall over the Iberian Peninsula, *International Journal of Climatology*, **23**, 1757-1769.
- Wilks, D.S., (1995). *Statistical methods in atmospheric sciences*, New York: Academic Press.
- Wu, X., Hongxing, C., Flitman, A., Fengying, W. ve Guolin, F., (2001). Forecasting monsoon precipitation using artificial neural networks, *Adv. Atmos. Sci.*, **18**, 951-958.
- Yurtoğlu, H., (2005). Yapay sinir ağları metodolojisi ile öngörü modellemesi: Bazı makroekonomik değişkenler için Türkiye örneği, *Uzmanlık Tezi*, DPT, Ankara.