



Karaman İlinde Yapay Sinir Ağları Yaklaşımı Kullanılarak Kuraklığın Tahmini

M. Taghi SATTARI¹ Kadri YÜREKLİ² Ali ÜNLÜKARA³

¹ Tebriz Üni. Ziraat Fak. Su Mühendisliği Bölümü, TEBRİZ, İRAN

² Gaziosmanpaşa Üniversitesi Ziraat Fak. Tar. Yap. ve Sul. Bölümü, TOKAT

³ Erciyes Üniversitesi Seyrani Ziraat Fak. Biyosistem Mühendisliği, KAYSERİ

*Sorumlu Yazar

mtsattar@tabrizu.ac.ir

Özet: Bu çalışmada Yapay Sinir Ağları (YSA) ile Standartlaştırılmış Yağış İndeksinin (SPI) modellenmesi ve geleceğe yönelik kuraklık tahminlerinin yapılması amaçlanmıştır. Karaman meteoroloji istasyonunda 1975-2009 yıllarında ölçülen aylık yağmurlar kullanılarak 3, 6, 9 ve 12 aylık zaman ölçekleri için SPI değerleri hesaplanmıştır. Modellemede İleri Beslemeli Geri Yayımlı Yapay Sinir Ağları (FFBPANN) metodu kullanılmıştır. YSA modeli kurulmasında girdi verisi olarak SPI değerinin belirlenmesinde dikkate alınan yağış verileri ve SPI değerleri kullanılmıştır. Modelin kurulmasından sonra geleceğe yönelik tahminlerde bulunabilmek için farklı zaman dilimlerine ait yağış ve SPI kombinasyonları girdi verisi alınarak ileriye yönelik kuraklık tahminlerinde (SPI) bulunulmuştur. YSA metodu ile tahmin edilen SPI değerleri ve hesaplanan SPI değerleri 1999-2009 dönemi için test edilmiştir. En iyi FFBPANN modeli seçiminde, MSE (Mean Square Error), NMSE (Normalized Mean Square Error), AME (Absolute Mean Error), AMinE (Absolute Minimum Error), AMaxE (Absolute Maximum Error) ve doğrusal korelasyon katsayısı dikkate alınmıştır.

Anahtar Kelimeler: Yapay Sinir Ağları, İleri Beslemeli Geri Yayımlı, SPI, Karaman.

Drought Prediction by Using Artificial Neural Networks Approach in Karaman Province

Abstract: This paper presents a methodology on modeling, namely, artificial neural network (ANN), of the meteorological drought. For this purpose, standardized precipitation index (SPI) values at time scales of 3, 6, 9 and 12 months were calculated using monthly rainfalls measured from 1975 to 2009 in Karaman meteorology station. The feed-forward back-propagation (FFBP) method was employed to train the ANNs in the study. The SPI and monthly rainfall data was taken into consideration to constitute input layer in Feed Forward Back Propagation Artificial Neural Networks (FFBPANN). The SPI values from the ANN were compared with the values calculated from SPI relationship for the period 1999-2009. The FFBPANN performance was evaluated by Mean Square Error (MSE), Normalized Mean Square Error (NMSE), Absolute Mean Error (AME), Absolute Minimum Error (AMinE), Absolute Maximum Error (AMaxE) and Linear Correlation Coefficient (r).

Key Words: Artificial Neural Networks, Feed Forward Back Propagation, SPI, Karaman.

GİRİŞ

Kuraklığın onlarca tanımı bulunmaktadır. Wilhite ve Glantz [10] kuraklık tanımlamalarını; meteorolojik, klimatolojik, atmosferik, tarımsal, hidrolojik ve su yönetimi açısından altı kategoride toplamıştır. Tüm bu bakış açıları kuraklığın belirli bir zaman diliminde yağış eksikliğinden kaynaklanan yetersiz nem durumu olduğunu kabul eder görünmektedir [3].

Kuraklık indeksleri, yağış, kar depozitleri, akış ve diğer su sağlama göstergeleri üzerine kaydedilen binlerce veriyi kapsamlı büyük bir tabloda birleştirmektedir. Bir kuraklık indeksi değeri tipik olarak tek bir sayıdır ve karar vermek için ham verilerden çok daha kullanışlıdır. Her hangi bir zaman diliminde yağışın tarihsel olarak oluşturduğu seyirden ne kadar saptığını ölçen birkaç tane indeks bulunmaktadır. Başlıca indekslerin hiç birisi tüm şartlarda geriye kalan indekslere göre doğal olarak üstün olmamasına rağmen belirli kullanımlar için bazı indeksler diğerlerinden daha iyi uyum göstermektedirler. Örneğin Palmer Kuraklık Şiddet İndeksi kuraklığın

ne zaman kabul edileceğini belirlemek için yaygın şekilde kullanılmaktadır fakat Palmer indeksi düzgün topografyalı geniş alanlarda çalışıldığı zaman iyi uyum sağlamaktadır. Dağlık alanlar ve bunun sonucunda ortaya çıkan karmaşık bölgesel mikroklima alanlarında kar birikintileri ve diğer özgün koşulları hesaba katan Yüzey Suyu Sağlama İndeksi gibi diğer indekslerle Palmer indeksinin desteklenmesi yararlı bulunmaktadır. Su sağlama şartlarının izlenmesinde Standartlaştırılmış Yağış İndeksi (Standardized Precipitation Index veya SPI) kullanılmaktadır [5].

SPI, her hangi bir zaman dilimi için yağış ihtimaline dayalı bir indekstir. Birçok kuraklık planlayıcısı SPI'nin başarısını kabul etmektedir. Farklı zaman dilimleri için hesaplanabilen SPI kuraklığın erken şekilde uyarısını sağlayabilmekte ve kuraklığın şiddetinin değerlendirilmesine yardımcı olabilmektedir. SPI indeksi Palmer İndeksinden daha az karmaşıktır [5]. Kısıtlı bir yağışın yeraltı suyu, rezervuar depolanması, toprak nemi, kar birikintisi ve akış üzerine neden olduğu etkilerin anlaşılması için McKee, Doesken ve Kleist tarafından

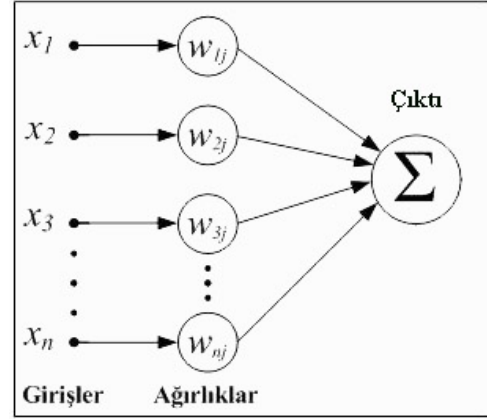
1993 yılında Standartlaştırılmış Yağış İndeksi (SPI) geliştirilmiştir. Çok farklı zaman dilimleri için yağış kısıntısını ölçmek için SPI planlanmıştır. Bu zaman dilimleri farklı su kaynaklarının yarayışlılığı üzerine kuraklığın etkisini yansıtmaktadır. Toprak nem şartları yağış sapmalarına nispeten daha kısa bir zaman aralığında tepki vermektedir. Yeraltı suyu, akım ve rezervuar depolanması ise daha uzun dönemli yağış sapmalarını yansıtmaktadır. Bu nedenle McKee et al. [6] 3, 6, 12, 24 ve 48 aylık zaman dilimleri için SPI hesaplamışlardır. Herhangi bir bölge için SPI hesabı, istenilen dönem için uzun süreli yağış kayıtlarına dayanmaktadır. Bu uzun dönemli kayıtlar bir ihtimal dağılımına uymakta ve sonra normal dağılıma çevrilmektedir. Böylece söz konusu bölge için ortalama SPI sıfır olmaktadır [4]. Pozitif SPI değerleri, medyan yağış değerinden daha büyük yağışları göstermekte ve negatif SPI değerleri medyan yağış değerinden daha düşük yağışları göstermektedir. SPI değerleri normalleştirildiği için daha nemli ve daha kurak iklimler aynı şekilde sunulabilmekte ve nemli dönemler SPI kullanılarak izlenebilmektedir. McKee et al. [6]'de, SPI den kaynaklanan kuraklık yoğunluğunu tanımlamak için sınıflandırma sistemi SPI tablo değerleri şeklinde gösterilmiştir (Çizelge 1). Herhangi bir zaman dilimi için bir kuraklık olayını tanımlama kriterleri de tanımlanmıştır. Herhangi bir SPI zamanında meydana gelen kuraklık, sürekli şekilde negatiftir ve -1.0 veya daha düşük bir yoğunluğa erişmektedir. SPI pozitif olduğunda kuraklık olayı son bulmaktadır. Böylece her bir kuraklık olayı başlangıç ve sonuyla tanımlanan bir süreye sahiptir ve olayın devam ettiği her ay için bir yoğunluğu bulunmaktadır. Bir kuraklık olayı içerisindeki tüm aylar için SPI değerlerinin pozitif toplamı kuraklığın "büyüklüğü" şeklinde ifade edilmektedir [6].

Çizelge 1. SPI Değerleri ve Kuraklık Sınıfı

| SPI Değerleri | Kuraklık Sınıfı | SPI Değerleri | Kuraklık Sınıfı |
|---------------|---------------------|------------------|---------------------|
| 2.0+ | Son derece nemli | -1.0 – -1.49 | Orta derecede kurak |
| 1.5 – 1.99 | Çok nemli | -1.5 – -1.99 | Şiddetli kurak |
| 1.0 – 1.49 | Orta derecede nemli | -2 ve daha düşük | Son derece kurak |
| -0.99 – 0.99 | Normal | | |

Kara kutu deyimi ile yapısal özellikleri ve çalışma tarzları ayrıntılı ve tam olarak ölçülüp değerlendirilemeyen ve dolayısıyla modellenmeleri oldukça güç veya imkansız yakın olabilen sistemler kastedilir. Kara kutu modelleri içinde bulunan Yapay Sinir Ağları yöntemi, olayın nedenini ve fiziğini önemsemeden sadece önceki girdi ve çıktı verisine bağlı olarak çözüm üreten bir yöntemdir. Yapay sinir ağlarının kullanılmasıyla diğer yöntemlere göre önemli üstünlüklere sahip olunabilecek ve farklı durumlar için daha doğru tahminlerde bulunulabilecektir.

Matematiksel açıdan YSA; parametreleri eğitilmiş ve kalibre edilmiş doğrusal olmayan bir fonksiyondur. Geçen yıllarda YSA yöntemi fiziksel sistemlerin kontrolü,



Şekil 1. YSA mimarisinin temel elemanları

mühendislik problemleri, istatistik, su kaynakları yönetimi ve işletmesi, hidroloji gibi bir çok konuda kullanılmıştır. Simüle edilen sinir hücrelerini içeren programlarla nöronlar çeşitli şekillerde birbirlerine bağlanarak bir ağ oluşturulur. Bu ağlar; öğrenme, hafızaya alma ve veriler arasındaki çeşitli ilişkileri ortaya çıkarma kapasitesine sahiptir. Diğer bir ifadeyle YSA'lar, normalde bir insanın düşünme ve gözlemlemeye yönelik doğal yeteneklerini gerektiren problemlere çözüm üretebilmektedir. Biyolojik sistemlerde öğrenme, nöronlar arasındaki sinaptik bağlantıların ayarlanması ile olur. Yani, insan doğumdan itibaren "yaşayarak öğrenme" süreci içerisine girer. Bu süreç içinde beyin sürekli bir gelişme gösterir ve öğrenme gerçekleşir. Aynı durum, YSA için de geçerlidir. Öğrenme, girdi/çıkı verilerinin işlenmesiyle, yani eğitim algoritmasının bu verileri kullanarak bağlantı ağırlıklarını bir yakınsama sağlayana kadar, tekrar tekrar ayarlanmasıyla olur. Bir işlem elemanı, diğer nöronlardan sinyalleri alır, bunları birleştirir, dönüştürür ve sayısal bir sonuç ortaya çıkartır. Genelde, işlem elemanları kabaca gerçek nöronlara karşılık gelir ve bir ağ içinde birbirlerine bağlanır. Bu yapı da sinir ağlarını oluşturmaktadır. Sinirsel hesaplamaların merkezinde dağıtılmış, adaptif ve doğrusal olmayan işlem kavramları vardır. YSA'ların yapısını oluşturan üç ana eleman; temel işlem elemanı olan nöron, girdi ve çıktı yolunu sağlayan bağlantı ve bu bağlantıların sağlamlığını gösteren bağlantı ağırlığıdır (Şekil 1). Temel olarak, tüm YSA'lar benzer bir yapıya sahiptirler. Bu yapıda; bazı nöronlar girdileri almak için, bazı nöronlar ise çıktıları iletmek için dış mekan ile bağlantı halindedir. Geri kalan tüm nöronlar ise gizli tabakalarda yer alır ve sadece ağ içinde bağlantıları vardır. Tipik olarak bir YSA'da çeşitli matematiksel algoritmalarından bir tanesi kullanılarak üretilen çıktıların doğruluk düzeyinin maksimize edilmesi için gerekli olan ağırlık değerleri belirlenmektedir.


YSA'lar önceki örnekleri kullanarak girdi değişkenler ile tahmin edilen değişkenler arasında ki ilişkiyi ortaya çıkarmış, diğer bir deyişle YSA eğitilmiş olur. Bu ilişki, bir kez ortaya çıkartıldıktan sonra, YSA yeni verilerle çalıştırılabilir ve tahminler üretilebilir. Bir ağı performansı, amaçlanan sinyal ve hata kriteri ile ölçülür.

Ağın çıktısı, amaçlanan çıktı ile karşılaştırılarak hata payı elde edilir. Geri Yayılma olarak adlandırılan bir algoritma hata payını azaltacak şekilde ağırlıkları ayarlamak için kullanılır. Bu işlem defalarca tekrar edilerek ağ eğitilir. Eğitime işleminin amacı, performans ölçümleri bazında optimum çözüme ulaşmaktır. YSA'larda, yapay nöronlar basit bir şekilde kümelendirilmektedir. Bu kümelendirme tabakalar halinde yapılmakta ve daha sonra bu tabakalar bir diğerine ilişkilendirilmektedir. Tek tabaka ya da tek eleman içeren bazı başarılı ağlar oluşturulabilmesine rağmen çoğu uygulama en az üç tabaka (girdi tabakası, gizli tabaka ve çıktı tabakası) içeren ağlara ihtiyaç duymaktadır. Girdi tabakası, dışarıdan girdileri alan nöronları içerir ancak bu nöronlar girdi değerleri üzerinde bir işlem uygulamazlar. Sadece girdi değerlerini bir sonraki tabakaya iletir ve bu yüzden de bazı araştırmacılar tarafından girdi tabakası ağların tabaka sayısına dahil edilmezler. Çıktı tabakası ise çıktıları dışarıya ileten nöronları içeren tabakadır. Girdi ve çıktı tabakaları birer tabakadan oluşurken bu iki tabaka arasında birden fazla gizli tabaka bulunabilir. Bu gizli tabakalar çok sayıda nöron içerir ve bu nöronlar tamamen ağ içindeki diğer nöronlarla bağlantılıdır. Çoğu ağ türünde, gizli tabakadaki bir nöron sadece bir önceki tabakanın tüm nöronlarından sinyal alır. Nöron işlemini yaptıktan sonra ise çıktısını bir sonraki tabakanın tüm nöronlarına gönderir. Bu yapı, ağın çıktısı için bir ileri besleme yolu oluşturur. Bir nörondan diğerine olan iletişim hattı, sinir ağları için önemli bir parçadır. Bazı ağlarda, bir nöron aynı tabakadaki başka nöronlara engel oluşturabilir. Bu, yanıl engelleme veya rekabet olarak adlandırılır ve en çok çıktı tabakasında kullanılır. Diğer bir bağlantı şekli ise geri yayılmadır. Geri yayılma, bir tabakanın çıktısının önceki tabakaya gönderilmesidir.

İleri beslemeli geri yayılma mimarisi 1970'li yıllarda geliştirilmiştir. Bu mimarinin geliştirilmesinde birbirlerinden bağımsız olarak birkaç araştırmacının katkıları olmuştur. Asıl katkı ise Rumelhart et al. [9] tarafından yapılmıştır. Ortaya çıkışından sonra, hem etkili hem de çok kullanışlı olması nedeniyle büyük bir popülerite kazanmış olup hala en çok kullanılan ağ türü olarak bilinmektedir. Çok sayıda farklı uygulama alanında kullanılmakta olup en büyük özelliği doğrusal olmayan yapı içeren problemlerde de etkili olabilmesidir. İleri beslemeli geriye yayılım sinir ağında da girdi, gizli ve çıktı birimleri olmak üzere üç farklı birim bulunmaktadır (Şekil 3). Her birimin bağlanma şekli ve her kısımdaki hücre sayısı değişebilmektedir. Aynı kısımdaki hücreler arasında iletişim olmasına izin verilmemektedir. Hücreler girdiyi ya başlangıç girdilerinden ya da ara bağlantılardan alırlar. Geriye doğru hata yayılması iki etaptan oluşmaktadır. Çıktı birimindeki çıktı bilgi sinyalini hesaplamak için girdi hücrelerindeki dış girdi bilgisini ileriye doğru ileten bir ileriye doğru besleme etabı ile çıktı birimindeki hesaplanan ve gözlenen bilgi sinyalleri arasındaki farklara dayanarak bağlantı kuvvetleri üzerinde değişikliklerin yapıldığı bir geriye

doğru ilerleme etabı. Bir eğitim sürecinin başında, bağlantı kuvvetlerine rastgele değerler atanmaktadır. Öğrenme algoritması her iterasyonda eğitim başarıyla tamamlanana kadar kuvveti değiştirmektedir. İterasyon süreci bir sonuca vardığında bağlantı kuvvetleri, eğitim sürecinde kullanılan örneklerdeki mevcut bilgiyi elde eder ve saklar.

Bu çalışmada, YSA modelleme tekniği yardımıyla tarihsel yağış değerlerinden hesaplanan SPI değerleri ve tarihsel yağış verilerini kullanarak geleceğe ilişkin ve farklı zaman dilimlerine ait SPI'ların belirlenmesi ve kurak dönemlerin tahmini amaçlanmıştır.



Şekil 2. Geri yayılım yapısı (Yurtoğlu, 2005)

MATERYAL VE YÖNTEM

SPI İndeksi (Standardized Precipitation Index)

Bu çalışmada Karaman ili merkez istasyonda 1975-2009 yılları arasında ölçülmüş olan 35 yıllık aylık toplam yağmur miktarları kullanılmıştır. SPI indeksi, bir i istasyonunda seçilmiş bir zaman dilimi içindeki yağmur miktarının (X_i) ortalama yağmur miktarından (\bar{X}_i) olan farkının standart sapmaya (σ) bölünmesi ile normalleştirilerek elde edilmektedir (Eşitlik 1). Bu ilişki yağmur verisinin normal dağılım göstermesi durumunda kullanılmaktadır. Ters koşülde seri uygun bir dağılıma uydurularak bu dağılımdan gözlemlere karşılık gelen olasılıkların standart normal dağılımdaki karşılığı olan z-değerleri (SPI) belirlenir. SPI yöntemi, zaman ölçeğinde geniş bir uygulamaya sahip olduğu için kuraklığın kısa ve uzun dönem izlenmesinde daha esnek bir yapıya sahiptir [4, 8]. Bu çalışmada 3, 6, 9 ve 12 aylık zaman ölçekleri için SPI hesaplanmıştır.

$$SPI = \frac{X_i - \bar{X}_i}{\sigma} \quad (1)$$

Yapay Sinir Ağları Modeli

Bu çalışmanın amacı, önce tarihsel veriler kullanarak SPI değerlerinin hesaplanması ve daha sonra YSA modelleme tekniği yardımıyla gözlenmiş tarihsel yağış değerleri ve hesaplanmış SPI değerleri kombinasyonlarını kullanarak geleceğe ilişkin farklı zaman dilimlerine ait SPI'ların tahmin edilmesi ve kurak dönemlerin oluşu konusunda fikir yürütülmesidir. Çalışmada 3, 6, 9 ve 12 aylık SPI hesaplamalarında Karaman iline ait Ocak 1975

ile Aralık 2009 yılları arasında alınan 35 yıllık gözlenmiş yağış verileri kullanılmıştır. YSA modeli eğitim sürecinde Ocak 1975 ile Aralık 1998 yılları arasında 24 yıllık veri kullanılırken elde edilen YSA modelinin testinde Ocak 1999 ile Aralık 2009 yılları arasında kalan 11 yıllık veri kullanılmıştır.

Bu çalışmada YSA modelinin başarılı ve daha kolay tekniklerinden olan ileri beslemeli geri yayılım yöntemi kullanılmıştır. Girdi verilerin eğitiminde momentum eğitim kuralı ve aktivasyon fonksiyonu içinde -1 ile +1 arasında değişmekte olan hiperbolik tanjant fonksiyonu kullanılmıştır. İleri beslemeli geri

yayınımlı (FFBPANN) modelinin sonuçları Edwards and McKee 1997; Redmond 2000'e göre hesaplanan SPI değerleri ile karşılaştırılmıştır. FFBPANN modelinin doğruluğunu tespiti için Hata Kareler Ortalaması (MSE), Normalleştirilmiş Hata Kareler Ortalaması (NMSE), Ortalama Mutlak Hata (MAE), Minimum Mutlak Hata (MinAE), Maksimum Mutlak Hata (MaxAE) ve Doğrusal Korelasyon Katsayısı (r) istatistikleri kullanılmıştır. Modelin oluşumunda ve sonuçların değerlendirilmesinde Excel ortamında bulunan NeuroSolutions 5 yazılımı kullanılmıştır.

Verilerin standartlaştırılması

Çizelge 2. İleriye Yönelik Kuraklık Tahminleri İçin YSA Modelleri Girdi-Çıktı Katmanları ve Sonuçlara İlişkin Korelasyon Katsayısı ve Hatalar

| Girdi katman hücreleri | GKS* | Çıktı katman | MSE | NMSE | AME | AMinE | AMaxE | r |
|--|----------|-------------------|--------------|--------------|--------------|---------------|--------------|--------------|
| R(t), R(t-1), SPI3(t), SPI3(t-1), SPI3(t-2), SPI3(t-3), SPI3(t-4), SPI3(t-12) | 1 | SPI3(t+1) | 0,185 | 0,228 | 0,349 | 0,0014 | 1,164 | 0,88 |
| R(t), R(t-1), SPI3(t), SPI3(t-1), SPI3(t-2), SPI3(t-3), SPI3(t-4), SPI3(t-12) | 1 | SPI3(t+2) | 0,418 | 0,517 | 0,538 | 0,0211 | 1,687 | 0,72 |
| R(t), R(t-1), SPI3(t), SPI3(t-1), SPI3(t-2), SPI3(t-3), SPI3(t-4), SPI3(t-12) | 1 | SPI3(t+3) | 0,590 | 0,742 | 0,626 | 0,0023 | 1,971 | 0,55 |
| R(t), R(t-1), SPI6(t), SPI6(t-1), SPI6(t-2), SPI6(t-3), SPI6(t-4), SPI6(t-12) | 2 | SPI6(t+1) | 0,090 | 0,108 | 0,251 | 0,0049 | 0,658 | 0,95 |
| R(t), R(t-1), SPI6(t), SPI6(t-1), SPI6(t-2), SPI6(t-3), SPI6(t-4), SPI6(t-12) | 3 | SPI6(t+2) | 0,271 | 0,330 | 0,440 | 0,0001 | 1,066 | 0,829 |
| R(t), R(t-1), SPI6(t), SPI6(t-1), SPI6(t-2), SPI6(t-3), SPI6(t-4), SPI6(t-12) | 3 | SPI6(t+3) | 0,364 | 0,442 | 0,513 | 0,01585 | 1,235 | 0,773 |
| R(t), R(t-1), SPI6(t), SPI6(t-1), SPI6(t-2), SPI6(t-3), SPI6(t-4), SPI6(t-12) | 1 | SPI6(t+4) | 0,461 | 0,561 | 0,568 | 0,0026 | 1,749 | 0,679 |
| R(t), R(t-1), SPI6(t), SPI6(t-1), SPI6(t-2), SPI6(t-3), SPI6(t-4), SPI6(t-12) | 2 | SPI6(t+5) | 0,519 | 0,632 | 0,600 | 0,0130 | 1,617 | 0,651 |
| R(t), R(t-1), SPI6(t), SPI6(t-1), SPI6(t-2), SPI6(t-3), SPI6(t-4), SPI6(t-12) | 5 | SPI6(t+6) | 0,565 | 0,703 | 0,655 | 0,0229 | 1,758 | 0,582 |
| R(t), R(t-1), SPI9(t), SPI9(t-1), SPI9(t-2), SPI9(t-3), SPI9(t-4), SPI9(t-12) | 1 | SPI9(t+1) | 0,095 | 0,112 | 0,258 | 0,0049 | 0,765 | 0,946 |
| R(t), R(t-1), SPI9(t), SPI9(t-1), SPI9(t-2), SPI9(t-3), SPI9(t-4), SPI9(t-12) | 1 | SPI9(t+2) | 0,279 | 0,326 | 0,425 | 0,0109 | 1,699 | 0,835 |
| R(t), R(t-1), SPI9(t), SPI9(t-1), SPI9(t-2), SPI9(t-3), SPI9(t-4), SPI9(t-12) | 4 | SPI9(t+3) | 0,485 | 0,568 | 0,571 | 0,0145 | 1,671 | 0,713 |
| R(t), R(t-1), SPI9(t), SPI9(t-1), SPI9(t-2), SPI9(t-3), SPI9(t-4), SPI9(t-12) | 3 | SPI9(t+4) | 0,623 | 0,731 | 0,647 | 0,0175 | 2,158 | 0,562 |
| R(t), R(t-1), SPI9(t), SPI9(t-1), SPI9(t-2), SPI9(t-3), SPI9(t-4), SPI9(t-12) | 3 | SPI9(t+5) | 0,640 | 0,754 | 0,654 | 0,0111 | 2,000 | 0,554 |
| R(t), R(t-1), SPI9(t), SPI9(t-1), SPI9(t-2), SPI9(t-3), SPI9(t-4), SPI9(t-12) | 1 | SPI9(t+6) | 0,640 | 0,774 | 0,665 | 0,0037 | 1,843 | 0,518 |
| R(t), R(t-1), SPI9(t), SPI9(t-1), SPI9(t-2), SPI9(t-3), SPI9(t-4), SPI9(t-12) | 4 | SPI9(t+7) | 0,660 | 0,813 | 0,652 | 0,0042 | 2,460 | 0,462 |
| R(t), R(t-1), SPI9(t), SPI9(t-1), SPI9(t-2), SPI9(t-3), SPI9(t-4), SPI9(t-12) | 2 | SPI9(t+8) | 0,774 | 0,964 | 0,707 | 0,0293 | 2,362 | 0,323 |
| R(t), R(t-1), SPI9(t), SPI9(t-1), SPI9(t-2), SPI9(t-3), SPI9(t-4), SPI9(t-12) | 5 | SPI9(t+9) | 0,811 | 1,009 | 0,720 | 0,0064 | 2,444 | 0,243 |
| R(t), R(t-1), SPI12(t), SPI12(t-1), SPI12(t-2), SPI12(t-3), SPI12(t-4), SPI12(t-12) | 1 | SPI12(t+1) | 0,086 | 0,099 | 0,239 | 0,0031 | 0,760 | 0,953 |
| R(t), R(t-1), SPI12(t), SPI12(t-1), SPI12(t-2), SPI12(t-3), SPI12(t-4), SPI12(t-12) | 1 | SPI12(t+2) | 0,218 | 0,250 | 0,379 | 0,0011 | 1,193 | 0,872 |
| R(t), R(t-1), SPI12(t), SPI12(t-1), SPI12(t-2), SPI12(t-3), SPI12(t-4), SPI12(t-12) | 1 | SPI12(t+3) | 0,306 | 0,352 | 0,466 | 0,0075 | 1,401 | 0,813 |
| R(t), R(t-1), SPI12(t), SPI12(t-1), SPI12(t-2), SPI12(t-3), SPI12(t-4), SPI12(t-12) | 2 | SPI12(t+4) | 0,411 | 0,475 | 0,530 | 0,0058 | 1,453 | 0,733 |
| R(t), R(t-1), SPI12(t), SPI12(t-1), SPI12(t-2), SPI12(t-3), SPI12(t-4), SPI12(t-12) | 2 | SPI12(t+5) | 0,517 | 0,599 | 0,584 | 0,0070 | 1,890 | 0,649 |
| R(t), R(t-1), SPI12(t), SPI12(t-1), SPI12(t-2), SPI12(t-3), SPI12(t-4), SPI12(t-12) | 1 | SPI12(t+6) | 0,552 | 0,643 | 0,597 | 0,0031 | 1,900 | 0,610 |
| R(t), R(t-1), SPI12(t), SPI12(t-1), SPI12(t-2), SPI12(t-3), SPI12(t-4), SPI12(t-12) | 4 | SPI12(t+7) | 0,600 | 0,704 | 0,626 | 0,0061 | 1,810 | 0,590 |
| R(t), R(t-1), SPI12(t), SPI12(t-1), SPI12(t-2), SPI12(t-3), SPI12(t-4), SPI12(t-12) | 4 | SPI12(t+8) | 0,643 | 0,760 | 0,664 | 0,0161 | 1,890 | 0,544 |
| R(t), R(t-1), SPI12(t), SPI12(t-1), SPI12(t-2), SPI12(t-3), SPI12(t-4), SPI12(t-12) | 5 | SPI12(t+9) | 0,691 | 0,824 | 0,688 | 0,0254 | 1,716 | 0,453 |
| R(t), R(t-1), SPI12(t), SPI12(t-1), SPI12(t-2), SPI12(t-3), SPI12(t-4), SPI12(t-12) | 2 | SPI12(t+10) | 0,717 | 0,861 | 0,696 | 0,0037 | 2,030 | 0,437 |
| R(t), R(t-1), SPI12(t), SPI12(t-1), SPI12(t-2), SPI12(t-3), SPI12(t-4), SPI12(t-12) | 2 | SPI12(t+11) | 0,769 | 0,943 | 0,724 | 0,0307 | 2,390 | 0,355 |
| R(t), R(t-1), SPI12(t), SPI12(t-1), SPI12(t-2), SPI12(t-3), SPI12(t-4), SPI12(t-12) | 3 | SPI12(t+12) | 0,910 | 1,119 | 0,799 | 0,0051 | 2,684 | 0,168 |

*GKS: Gizli Katman Sayısı

Yapay sinir ağı çalışmalarında ağı eğitmeden önce girdi ve çıktı verileri üzerinde yapılan ön işlemler ağı performansının artmasına neden olmaktadır. Eğitmeden önce girdi ve çıktı verileri standartlaştırılarak belirli miktarlar arasında değişmesi sağlanır. Bu çalışmada kullandığımız aktivasyon fonksiyonun hiperbolik tanjant (-1/+1) olduğundan dolayı veriler +1 ile -1 arasında standartlaştırılmıştır. Standartlaştırmada eşitlik (2) kullanılmıştır (Ochoa-Rivera et al. 2002).

$$Z = \frac{2 \times (X_i - X_{\min})}{(X_{\max} - X_{\min})} - 1 \quad (2)$$


Burada Z standartlaştırılmış veriler olarak +1 ile -1 arasında değişmektedir. X_{\min} ve X_{\max} kullanılan veri setinin minimum ve maksimum değerleridir. Model simüle edildikten sonra ters işlem yapılarak orijinal SPI değerleri bulunmuş olur [2].

SONUÇLAR VE TARTIŞMA

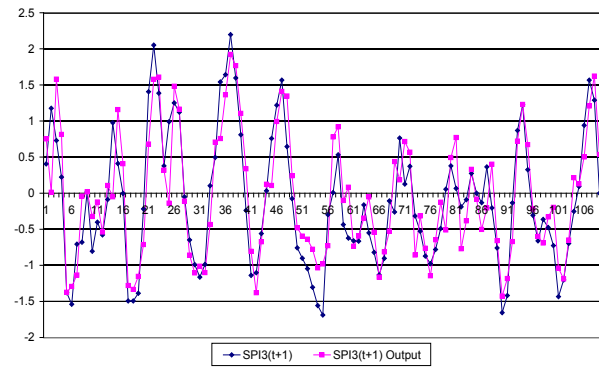
Karaman ilindeki kurak sınıflarını SPI' e göre tahmin etmek amacıyla elde edilen kümülatif yağmur ve α_k serilerinin normal dağılıma uygunluğu, Jargua-Bera testine göre [7] test edilmiş ve sonuçlar Karaman ili için elde edilen kümülatif yağmur ve α_k değerlerinin normal dağılıma sahip olduğunu göstermiştir. Buna göre Karaman ilinin 1975-2009 yılları için SPI indekslerinden kuraklık sınıfları, doğrudan indeks ilişkilerinden belirlenmiştir.

SPI değerleri 3, 6, 9 ve 12 aylık zaman dilimleri esas alınarak hesaplanmıştır. Elde edilen söz konusu SPI değerleri ve gözlenmiş yağmur verileri kullanılarak YSA yöntemiyle aynı zaman dilimlerine ait geleceğe ilişkin SPI değerleri tahmin edilmiştir. YSA modelinin kurulumunda çeşitli girdi hücreleri denenmiştir. Çalışmada kullanılan katmanlar ve elde edilen sonuçlar Çizelge 2'de verilmiştir. Çizelge 2'de girdi katman hücreleri sütununda R simgesi ile yağış, SPI ile Standartlaştırılmış Yağış İndeksi belirtilirken t alt indeksleri (cari ay) ve indis önündeki rakamlar ile hesaplamının yapıldığı zaman belirtilmektedir. Örneğin Çizelge 2 de 1.satırda (t+1) zaman dilimi için SPI3 miktarının tahmini amaçlanmıştır (çıkı tabakası). Çizelge 2 den de görüleceği gibi R(t) ve R(t-1) cari ay ve bir önceki aya ait yağış verileri ile SPI3(t), SPI3(t-1), SPI3(t-2), SPI3(t-3), SPI3(t-4) ve SPI3(t-12) cari ay, 1 ay öncesi, 2 ay öncesi, 3 ay öncesi, 4 ay öncesi ve 12 ay öncesi için hesaplanmış SPI3 değerleri kombinasyonu girdi tabakasının hücreleri olarak dikkate alınmıştır. En iyi ağ mimarisi Çizelge 2 de kalın fontlarla işaretlenen ağlardır.


YSA modeliyle tahmin edilen ve hesaplanan SPI değerleri arasında regresyon kurulmuş ve korelasyon katsayısı (r) belirlenmiştir. Bir ay sonraki dönem için YSA modeliyle tahmin edilen 3 aylık SPI değeri ile hesaplanan SPI3 arasında kuvvetli pozitif bir ilişki (r=0.88) belirlenmiş (Şekil 3) ve her iki veri serisinin uyumu Şekil 4'de gösterilmiştir. Çizelge 2'den de görüldüğü gibi YSA modeli 1 ay ve 2 ay sonrası için SPI3 değerini




Şekil 3. Hesaplanan ve YSA ile tahmin edilen 3 aylık SPI değerleri arasındaki ilişki



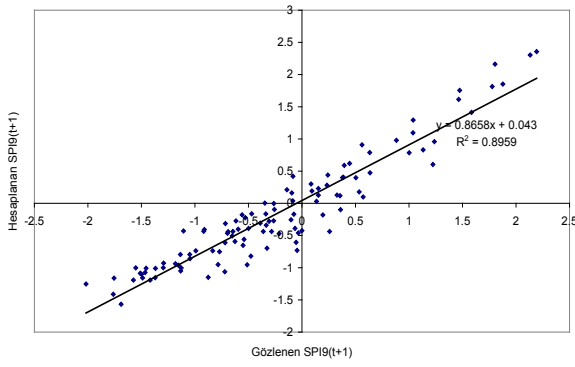
Şekil 4. Hesaplanan ve YSA ile tahmin edilen 3 aylık SPI değerleri arasındaki ilişki



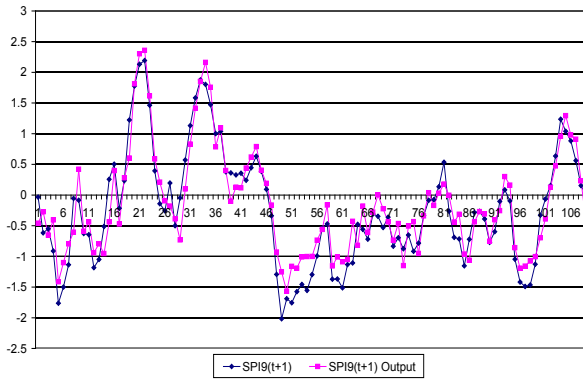
Şekil 5. Hesaplanan ve YSA ile tahmin edilen 6 aylık SPI değerleri arasındaki ilişki




Şekil 6. Hesaplanan ve YSA ile tahmin edilen 6 aylık SPI değerleri arasındaki ilişki



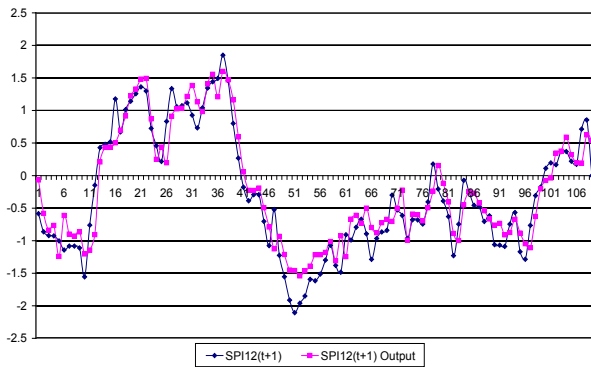
Şekil 7. Hesaplanan ve YSA ile tahmin edilen 9 aylık SPI değerleri arasındaki ilişki



Şekil 8. Hesaplanan ve YSA ile tahmin edilen 9 aylık SPI değerleri arasındaki ilişki



Şekil 9. Hesaplanan ve YSA ile tahmin edilen 12 aylık SPI değerleri arasındaki ilişki



Şekil 10. Hesaplanan ve YSA ile tahmin edilen 12 aylık SPI değerleri arasındaki ilişki

kuvvetli şekilde tahmin ederken 3 ay sonrası için tahmin gücü giderek azalmış ve orta kuvvette tahmin yapabilmıştır ($r=0.55$).

YSA modeliyle 1 ay sonrası dönemin 6 aylık SPI değeri çok kuvvetli şekilde ($r=0.95$) tahmin edilmiş (Şekil 5) ve her iki veri serisinin uyumu Şekil 6'da gösterilmiştir. Çizelge 2'den de görülebileceği gibi bir ay sonraki dönem ($t+1$) için korelasyon katsayısı 0.95 iken ilerleyen her ay için giderek azalmış ve 6 ay sonrası için 0.582 değerine kadar düşmüştür. SPI6 için YSA modeliyle 3 ay sonrasına kadar kuvvetli derecede tahmin yapabileme imkanı bulunmaktadır.

Korelasyon katsayısı 1 ay sonrası 9 aylık SPI için $r=0.95$ olarak belirlenmiş (Şekil 7) ve her iki veri serisinin uyumu Şekil 8'de gösterilmiştir. YSA modeli ile 1 ay ve 9 ay sonrası için tahmin edilen SPI9 değerleri ile hesaplanan SPI9 değerleri arasındaki korelasyon katsayıları 0.95-0.243 arasında değişmektedir (Çizelge 2). YSA modeliyle SPI9 için 3 ay sonrasına kadar kuvvetli tahmin yapabileme imkanı bulunmaktadır.

YSA ile 1 ay sonrası SPI12 için $r=0.95$ olarak belirlenmiş (Şekil 9) ve her iki veri serisinin uyumu Şekil 10'da gösterilmiştir. Çizelge 2'de 1 ay sonrası ve 12 ay sonrası için SPI12 değerleri korelasyon katsayıları 0.95-0.17 değerleri arasında değişmektedir. YSA modeli ile 4 ay sonrasına kadar kuvvetli tahmin yapabileme imkanı bulunmaktadır.

Korelasyon katsayılarına göre hesaplanan ve YSA ile tahmin edilen sonuçlar arasında 3, 6 ve 9 aylık zaman ölçekli SPI değerlerinin tahmininde 3 ay sonrasına kadar kuvvetli bir uyum bulunurken 12 aylık zaman ölçekli SPI değerlerinin tahmini için ise 4 ay sonrasına kadar kuvvetli bir uyum bulunmaktadır. İleriye yönelik 1-3 ay sonrası için SPI tahmininde dikkate alınan zaman dilimi arttıkça YSA ile daha doğru tahmin yapılabilmektedir. Örneğin 3 ay sonrası SPI3, SPI6, SPI9 ve SPI12 için korelasyon katsayıları sırasıyla 0.55, 0.773, 0.713 ve 0.813 olarak belirlenmiştir. En iyi sonuçlar $t+1$ dönemine aittir. Yani 1 ay sonrası için SPI3 tahmini kuvvetli, SPI6, SPI9 ve SPI12 tahmini ise çok kuvvetli bir ilişkiyle sonuçlanmıştır. Hata terimleri açısından SPI tahminleri için Hata Kareler Ortalaması (MSE), Normalleştirilmiş MSE (NMSE), Ortalama Mutlak Hata (MAE), Minimum Mutlak Hata (MinAE), Maksimum Mutlak Hata (MakAE) sonuçlar Çizelge 3'de verilmiştir. İleriye yönelik tahminlerde tahmin zamanı sabit kalmak kaydıyla SPI zaman dilimleri açısından tüm hata terimlerinde (MakAE hariç) en düşük değerlere 12 aylık zaman dilimi sahip olmuştur. Zaman dilimi 9 ay için hata terimleri 6 aylık zaman dilimi için hata terimlerinden bir miktar daha büyük çıkmış dolayısıyla 6 aylık tahminler daha hassas şekilde yapılmıştır. Ancak genel bir değerlendirme yapıldığında zaman dilimi aralığı arttıkça hata terimleri azalmış, korelasyon katsayısı artmış ve dolayısıyla daha isabetli tahminler yapılmıştır.

Çizelge 2'den de anlaşıldığı üzere aynı zaman ölçekli SPI lar için ileriye dönük tahmin yaparken, tahmin zaman

Çizelge 3. Çizelge 2 Çizelgede Verilen En İyi Ağ Mimarısına Göre Hesaplanan SPI ile YSA Modelleriyle Tahmin Edilen SPI Sonuçları Arasında Ortaya Çıkan Hatalar

| Zaman Dilimi | MSE | NMSE | MAE | MinAE | MakAE | r |
|---------------|-------|--------|-------|--------|-------|-------|
| 3 ay (SPI3) | 0.185 | 0.2277 | 0.348 | 0.001 | 1.164 | 0.883 |
| 6 ay (SPI6) | 0.090 | 0.1084 | 0.251 | 0.005 | 0.658 | 0.947 |
| 9 ay (SPI9) | 0.095 | 0.1116 | 0.258 | 0.005 | 0.765 | 0.947 |
| 12 ay (SPI12) | 0.086 | 0.0987 | 0.239 | 0.0031 | 0.76 | 0.953 |

arttıkça YSA modelinin tahmin yeteneğinin zayıfladığı görülmektedir. Örneğin SPI3 için (t+1), (t+2) ve (t+3) zaman dilimlerine ait korelasyon katsayıları ($r=0,88 > 0,72 > 0,55$) artan zamanla birlikte azalmıştır. Aynı şekilde Çizelge 2'nin son satırına baktığımızda anlaşıldığı üzere SPI12 (t+12) en kötü sonucu vermişken ($r=0,168$) halbuki SPI12 (t+1) tahmininde model daha iyi sonuç vermiştir ($r=0,953$). Bir başka değişle model uzak dönemler için SPI değerlerini tahmin etmede zorluk çekmektedir. Bu ise uzak ve yakın zamanlar arasında yağış serileri arasında olan korelasyonların az olmasından kaynaklanmakta olup bu doğal bir sürecin sonucudur.

KAYNAKLAR

- [1] Anonymous, 2010. Devlet Meteoroloji İşleri Genel Müdürlüğü, Ankara.
- [2] Demuth, H., and Beale, M (2001). Neural network toolbox for use with MATLAB. User Guide, V. 4.0, MathWorks, Inc., MA. www.mathworks.com.
- [3] Dracup J.A., Lee K.S., Paulson E.G., 1980. Large-scale drought/floods and monsoon circulation. Mon. Wea. Rev., 108, 1197.
- [4] Edwards D.C. and McKee T.B., 1997. Characteristics of 20th Century Drought in the United States at Multiple Time Scales. Climatology Report Number 97-2, Colorado State University, Fort Collins, CO.
- [5] Hayes M.J., 2010. Drought Indices. <http://www.drought.unl.edu/whatis/indices.htm>
- [6] McKee T.B., Doesken N.J., Kleist J., 1993. The Relationship of Drought Frequency and Duration to Time Scales. Eighth Conference on Applied Climatology, 17-22 January, Anaheim, California.
- [7] Ochoa-Rivera, J., Garcia-Bartual, R., and Andreu, J. (2002). Multivariate synthetic streamflow generation using a hybrid model based on artificial neural networks. Hydrol. Earth Sys. Sci., 6(4), 627-640.
- [8] Redmond K.T., 2000. Integrated climate monitoring for drought detection. Drought: A Global Assessment, edited by Wilhite, DA, Routledge, London.
- [9] Rumelhart, D. E., G. E. Hinton and R. J. Williams. (1986). Learning internal representation by error

propagation. In: Rumelhart, D.E., McClelland, J.L. (Eds.), *Paralel Distributed Processing*.

- [10] Wilhite D.A., Glantz M.H., 1985. Understanding the drought phenomenon: The role of definitions. *Water International*, 10: 111-120.
- [11] Yurtoglu, H. (2005). Yapay Sinir Ağları Metodolojisi ile Öngörü Modellemesi. *Ekonomik Modeller ve Stratejik Araştırmalar Genel Müdürlüğü Yayınları*.