
Makale / Research Paper

Zaman ve Konum Girdileri Kullanılarak Yapay Sinir Ağlarıyla Referans Evapotranspirasyonun Tahmin Edilmesi

Necati AKSU, Kenan UÇAN

*Milli Eğitim Müdürlüğü, Araştırmacı, Yalova /TÜRKİYE, necatiaksu@hotmail.com.tr

** KSÜ, Ziraat Fakültesi, Biyosistem Mühendisliği Bölümü, Kahramanmaraş /TÜRKİYE, ucan@ksu.edu.tr

Geliş/Received: 05.01.2016

Düzeltilme/Revised: 01.04.2016

Kabul/Accepted: 19.04.2016

Özet: Bu çalışmayla; sınırlı su kaynaklarının yönetiminde önem arz eden referans Bitki Su Tüketimi (ET_o)'ın kolay ve ekonomik olarak tahmini amaçlanmıştır. Bu doğrultuda, Yapay Sinir Ağları (YSA)'nın karmaşık sebep-sonuç ilişkilerini çözebilme yeteneğinden yararlanmak suretiyle, temin edilmesi çeşitli zorluklar içeren ve ayrıca yüksek maliyet ve uzun zaman gerektiren birçok meteorolojik girdi yerine, bu girdileri şekillendiren temel doğal veriler kullanılarak ET_o tahmin edilmiştir. Bu kapsamda; zaman, enlem, yükseklik ve denize mesafe gibi konum değişkenleri girdi olarak, FAO PM ET_o değerleri de çıktı olarak kullanılan farklı yapı ve özelliklerde çok sayıda ağ projesi oluşturulmuştur. Bu projeler 6 farklı eğitim algoritması ve farklı yinelemelerle eğitilerek test edilmiş ve tahmin başarısı en yüksek YSA belirlenmiştir. Belirlenen ağın Ortalama Mutlak Hatası (MAE) = 0.24 mm gün⁻¹; Ortalama Mutlak Yüzde Hatası (MAPE) = % 11.9 ve Belirlilik Katsayısı (R²) = 0.98 bulunmuştur.

Anahtar kelimeler: ET_o, referans evapotranspirasyon, YSA.

Estimation of Reference Evapotranspiration with Artificial Neural Networks Using Values of Time and Location

Abstract: In this study, the easy and economic way of prediction of the reference Evapotranspiration (ET_o), an important factor in management of limited water resources, was aimed. Accordingly, Evapotranspiration was predicted with the helping Artificial Neural Networks (ANN) ability in solving the complex cause-and-effect relationships by using basic natural data instead of large amount of real meteorological data that require various difficulties, high costs, and longer durations. In this context, numerous network projects in different structures and features have been generated. In these projects, location variables such as time, latitude, elevation, and distance to sea have been used as input data while FAO PM ET_o has been used as output value. These projects have been tested by the training with 6 different training algorithms and different iterations; ANN with the highest prediction success was identified. On the selected network, Determination Coefficient (R²), the Mean Absolute Percentage Error (MAPE), and the Mean Absolute Error (MAE) between the ANN predictions and the FAO PM ET_o were 0.98, 11.9%, and 0.24 mm day⁻¹, respectively.

Keywords: ET_o, reference evapotranspiration, ANN

Bu makaleye atıf yapmak için

Aksu, N., Uçan, K., "Zaman ve Konum Girdileri Kullanılarak Yapay Sinir Ağlarıyla Referans Evapotranspirasyonun Tahmin Edilmesi", El-Cezerî Fen ve Mühendislik Dergisi 2016, 3(2); 204-221.

How to cite this article

Aksu, N., Uçan, K., "Estimation of Reference Evapotranspiration with Artificial Neural Networks Using Values of Time and Location", El-Cezerî Journal of Science and Engineering, 2016, 3(2); 204-221.

1. Giriş

Hayatının vazgeçilmezlerinden olan ve doğada sınırlı miktarda bulunan tatlı suyun verimli kullanımı çok önemlidir. Tatlı su kullanımında en büyük pay tarımsal sulamaya aittir. Sulamada ideal kullanım ise ihtiyaç duyulan miktarın bilinmesiyle mümkündür. Günümüzde bu miktar yaygın olarak, özellikleri tanımlanan referans bir bitki türü için çeşitli yöntemlerle tahmin edilmekte ve daha sonra belirlenen bitki katsayıları ile de diğer bitkilere uyarlanmaktadır.

Mevcut tahmin yöntemlerinde, birçok iklim verisi gerektiren ve çoğu zaman birbirinden farklı sonuçlar üreten çeşitli eşitlikler kullanılmaktadır. Bu eşitliklerin girdilerini oluşturan iklim verilerinin temin edilmesinde çeşitli zorluklar ve önemli maddi külfet söz konusu olmaktadır. Çoğu zaman, her istasyonda yeterli sayıda ve gerekli tüm iklim parametrelerine ait ölçüm değerleri bulunmamaktadır. Diğer taraftan istasyon verilerinin homojen yapıda olmayan geniş sahalarda için kullanılma zorunluluğu vardır. Bu ve benzeri nedenlerle, sulama ihtiyacının belirlenmesinde daha kolay ve ekonomik yöntemler geliştirilmesi önem arz etmektedir.

Bu çalışmayla; su kaynaklarının planlanması ve yönetimi gibi faaliyetlerin önemli bir parçasını oluşturan sulama ihtiyacının belirlenmesinde kullanılan referans Bitki Su Tüketiminin (ET_o), Yapay Sınır Ağları (YSA) yardımıyla sürekli ölçüm gerektirmeyen 'konum' ve 'zaman' değerleri kullanılarak, tahmin edilmesi hedeflenmiştir.

Geçmişte bu doğrultuda YSA kullanılarak birçok çalışma yapılmış ve başarılı sonuçlar elde edilmiştir. Bu çalışmaların tümünde meteorolojik girdilerin çeşitli birleşimleri kullanılmıştır. *Bu çalışmada ise farklı olarak meteorolojik girdileri şekillendiren temel doğal girdiler (zaman ve konum) kullanılmıştır.*

Bu temel doğal girdilerin ET_o ile ilişkileri konusundaki bazı tespitler şu şekildedir:

(Linacre - 1999), bir bölgeye ait bazı iklim değerlerini kullanarak, o yerin 'enlem, yükseklik ve denize uzaklığı'nı, aynı şekilde bir bölgeye ait 'enlem, yükseklik ve denize uzaklık' değerlerini kullanarak o yerin bazı iklim değerlerini yaklaşık olarak hesaplamıştır. Elde ettiği sonuçlar çerçevesinde; konumdan iklimin veya iklimden konumun tahmininde iklim ve coğrafya arasındaki ampirik ilişkilerin önemli olduğunu, yerel şartlar göz ardı edildiğinde dahi sonuç alınabildiğini, bu tür normatif tahminlerin gerçek gözlemlerle karşılaştırılmasıyla bu ilişkilerin öneminin çok daha iyi kavranabileceğini ifade etmiştir.

(Allen ve ark. - 1998)'a göre; ET_o'ı etkileyen faktörler sadece iklim parametreleridir. Dolayısıyla ET_o; belirli bir konum ve zamanda atmosferin buharlaşma gücünü ifade eden ve hava verilerinden hesaplanan bir iklim parametresidir.

Meteoroloji Genel Müdürlüğü'nün değerlendirmelerine göre; iklim elemanları oluşumlarını etkileyen faktörler ile şekillenirler. Bu faktörler; enlem etkisi, yükseklik etkisi, deniz ve kara etkisi, deniz akıntıları etkisi, yer şekilleri etkisi ve bitki örtüsü etkilerinden oluşur (MGM, 2016a).

Bu bilgiler ışığında; mademki ET_o zaman ve konumun şekillendirdiği bir sonuçtur, o halde zaman ve konum değerlerinden tahmini mümkündür. Bunun için gerekli olan ise oldukça karmaşık olan bu ilişkileri analiz edebilecek uygun bir yöntem kullanmaktır. Bu yöntemlerden biri; yapay zekâ konusunun önemli alt dallarından olan YSA olabilir. YSA'lar, çeşitli alanlarda değişik amaçlarla ve tahmin amaçlı olarak yaygın bir şekilde kullanılmaktadır.

(Kalifa ve ark. - 2012)'a göre; Bir YSA, girdi ve çıktı veri setleri arasında karmaşık ve doğrusal olmayan ilişkileri belirleme yeteneğine sahip, esnek matematiksel bir yapıdır. YSA modelleri,

özellikle süreç karakteristiklerinin fiziksel denklemlerle tanımlanması zor olan problemlerde etkilidir. Ayrıca geleneksel matematiksel eşitliklerle betimlenmesi çok zor olan karmaşık ve doğrusal olmayan problemleri modelleyebildiği tespit edilmiştir. Giriş ve hedef değişkenleri arasındaki ilişkilerin belirgin olmadığı durumlar için bu modeller çok uygundur.

Bütün bu özellikleri göz önünde bulundurularak, bu çalışmada da girdileri ‘zaman, konum ve ETo’ olan YSA’lar kullanılmıştır. Bu doğrultuda giriş verileri zaman ve konum, çıkış verisi ETo olan çok sayıda ağ tasarlanmış, eğitilmiş ve test edilmiştir. Sonuçta, üretilen ağlar arasında test hatası en küçük olan yani genelleme yeteneği en iyi olan ağ belirlenmiştir.

2. Materyal Ve Yöntem

2.1. Materyal

Materyal olarak; ülkemizde bulunan 143 meteoroloji istasyonunun uzun yıllar ortalaması aylık verilerinden FAO PM eşitliğiyle (Eşitlik 1) elde edilen ETo değerleri ile bu istasyonlara ait enlem, yükseklik ve denize uzaklık değerleri kullanılmıştır. YSA yazılımı olarak çeşitli paket programlardan yararlanılmıştır.

2.1.1. FAO PM Eşitliği:

$$ET_o = \frac{0.408\Delta(R_n - G) + \gamma \frac{900}{T + 273} u_2 (e_s - e_a)}{\Delta + \gamma(1 + 0.34u_2)} \quad (1)$$

Eşitlikte;

- ET_o : referans evapotranspirasyon [mm gün⁻¹],
- R_n : bitki yüzeyinde net radyasyon [MJ m⁻² gün⁻¹],
- G : toprak ısı akısı yoğunluğu [MJ m⁻² gün⁻¹],
- T : 2 m yükseklikteki ortalama günlük hava sıcaklığı [°C],
- u² : 2 m yükseklikteki rüzgâr hızı [m s⁻¹],
- e_s : doymuş buhar basıncı [kPa],
- e_a : mevcut buhar basıncı [kPa],
- e_s - e_a : buhar basıncı açığı [kPa],
- Δ : buhar basıncı eğrisi eğimi [kPa °C⁻¹],
- γ : psikrometrik sabit [kPa °C⁻¹].

Eşitlik girdileri:

- Net radyasyon,
Solar radyasyon, ortalama sıcaklık, bağıl nem ve albedo ile hesaplanmaktadır.
 - Toprak ısı akısı yoğunluğu,
Ortalama sıcaklık değişimiyle hesaplanmaktadır.
 - Psikrometrik sabit;
Denizden yüksekliğe bağlı olarak belirlenmektedir.
 - Ortalama sıcaklık;
Doğrudan sıcaklık ölçüm değerlerinin ortalamasıdır.
 - Rüzgâr hızı;
Doğrudan rüzgâr hızı ölçüm değeridir.
 - Buhar basıncı açığı;
Minimum-maksimum sıcaklıklar ve bağıl nem ile hesaplanmaktadır.
 - Buhar basıncı eğrisi eğimi;
Minimum-maksimum sıcaklıklarla belirlenmektedir.
- Ölçülerek elde edilen ve eşitlik girdilerinin belirlenmesinde kullanılan meteorolojik*

büyüklikler:

- Minimum sıcaklık;
Eşitlikte doğrudan yer alan ortalama sıcaklığı belirler. Net radyasyonu, toprak ısı akısı yoğunluğunu, buhar basıncı açığını ve buhar basıncı eğrisinin eğimini etkiler.
- Maksimum sıcaklık;
Eşitlikte doğrudan yer alan ortalama sıcaklığı belirler. Net radyasyonu, toprak ısı akısı yoğunluğunu, buhar basıncı açığını ve buhar basıncı eğrisinin eğimini etkiler.
- Bağıl nem;
Eşitlik girdilerinden buhar basıncı açığını ve net radyasyonu etkiler.
- Rüzgâr hızı;
Eşitlikte doğrudan yer alır.
- Güneşlenme;
Solar radyasyonu, dolayısıyla eşitlikte yer alan net radyasyonu etkiler.
- Solar radyasyon;
Eşitlik girdilerinden net radyasyonu etkiler. Ölçüm değerleri mevcut olmadığında, 'zaman', 'enlem' ve 'güneşlenme' verileri kullanılarak hesaplanır.

2.1.2. Kullanılan YSA yazılımlarının özellikleri:

Tahmin amacıyla veya farklı amaçlarla kullanılabilen ve bilgisayar ortamında çalışan birçok YSA paket programı geliştirilmiştir. Bu çalışmada; tasarım, eğitim ve sorgulama aşamalarının hemen hemen her noktasında sürecin kontrol ve denetimine imkân sağlayan, çeşitli çizelgeler ve grafiklerle süreci ve sonucu değerlendirme olanağı sunan sahasında yetenekli çeşitli yazılımlar kullanılmıştır.

Çoğunda, performansları kanıtlanmış algoritma ve teknikler kullanılmıştır. Seçenek ve parametreler kapsamlı, anlaşılır ve kolay ulaşılabilir olarak düzenlenmiştir.

2.2. Yöntem**2.2.1. Yapay Sinir Ağları***YSA nedir, nasıl çalışır?*

YSA'nın, üzerinde ittifak edilmiş tek bir tanımı yoktur. Geniş ya da dar kapsamlı birçok tanım yapılmıştır. Kapsamlı ve genel kabul gören bir tanım şu şekildedir:

Bir sinir ağı, -deneysel bilgi depolama- ve -kullanım için uygun hale getirme- eğilimine sahip, paralel dağıtılmış basit işlem birimlerinden oluşan, yekpare bir işlemcidir. İki bakımdan beyne benzer;

1. Bilgi, ağ tarafından bir öğrenme süreci yoluyla çevreden kazanılır.
2. Edinilen bilgilerin saklanması için, sinaptik ağırlıklar olarak bilinen nöronlar arası bağlantı kuvvetleri kullanılır (Haykin, 1999).

(Yurtoğlu - 2005)'ya göre; YSA'lar, ağırlık atama yöntemiyle önceki örneklerin girdi ve hedef değişkenleri arasındaki ilişkiyi belirlerler. Diğer bir deyişle, eğitilirler. Bu ilişkiler bir kez belirlendikten sonra, yeni verilerle çalıştırılarak tahminler üretebilir. Eğitilmiş bir ağın performansı, amaçlanan sinyal ve hata kıstası ile ölçülür. Ağı çıktısı, amaçlanan çıktı ile karşılaştırılarak hata değeri elde edilir. Hata değerini azaltacak şekilde ağırlıkların yeniden ayarlanması için 'Geri Yayılım - (Backpropagation)' olarak adlandırılan bir algoritma kullanılır. Bu işlem defalarca tekrarlanarak ağı eğitimi tamamlanır. Bu eğitimlerle, performans ölçümleri bazında en uygun çözüm elde edilmeye çalışılır.

YSA'da eğitim (hata ölçümü ve ağırlıkların güncellenmesi):

Bilindiği üzere, sinir ağlarında eğitimin temel amacı, hata fonksiyonu ile elde edilen değer en aza indirilmesidir. Bu anlamda hata fonksiyonunun değeri, sinir ağının kalite durumunu göstermektedir. Eğitimin şekli; ağ türü, ağ mimarisi, kullanılan fonksiyonlar vb. ağ özelliklerine bağlı olarak farklılık arz etmektedir. Bu çalışmada, bu alanda en çok rağbet edilen çok katmanlı algılayıcı (ÇKA) (Multi Layer Perceptron – MLP) YSA'lar kullanılmıştır. Bu ağlar; girdi katmanı, ara katman veya katmanlar ve çıktı katmanından oluşmaktadır. Her katmanda bir veya daha fazla nöron bulunur ve her katmandaki nöronlar, diğer katmandaki nöronlara paralel olarak bağlıdır.

Bu ağlarda bilgi akışı ileri yönlüdür, diğer bir ifadeyle bu ağlar ileri beslemeli (feed forward) ağlardır. Girdi katmanına sunulan veriler, bağlantı ağırlıkları ile çarpılarak, gizli katman ve çıktı katmanı aktivasyon fonksiyonları ile işlem görür ve çıkışa ulaşır. Çıktı, burada hedef olarak sunulan değerlerle karşılaştırılır ve aradaki fark, hata miktarı olarak hesaplanır. Bulunan hata miktarı, Delta Öğrenme Kuralı ve Gradyan İniş (Gradient Descent) optimizasyon tekniğini uygulayan Geri Yayılım Algoritması ile geri doğru yayılır ve girdi katmanında ağırlıklar değiştirildikten sonra ileri besleme işlemi tekrarlanarak yeni hata miktarı hesaplanır. Ağın eğitimi (denetimli eğitim) olarak tanımlanan bu işlem, çıktı katmanındaki hata, belirlenen değerin altına düşünceye veya hedeflenen yinelemeler tamamlanıncaya kadar sürer. Kullanılan Delta Öğrenme Kuralı, en küçük kareler yöntemidir. Her yinelemede hata iyileşmesi, hatanın miktarına ve öğrenme katsayısına bağlıdır (Rumelhart ve ark., 1986).

Delta Kuralı: Hatayı en aza indirmek için ağırlıkların hata eğimi bulunabilir ve ters yönde hareket edilebilir. Eğer eğim pozitif yönde ise, ağırlıklar negatif yönde değiştirilir. Zira ağırlıkların pozitif yönde değiştirilmesi hatayı arttıracaktır. Eğer eğim negatif yönde ise, hatayı azaltmak için ağırlıklar pozitif yönde değiştirilir. Bu kuralın en güçlü kural olduğu kanıtlanmıştır ve hemen hemen mevcut tüm denetimli öğrenme yöntemlerinin çekirdeğini oluşturmaktadır (Fyfe, 2000).

Kareler Toplamı (Sum-of-Squares): En küçük kareler tekniğinde en küçük yapılmaya çalışılan değerdir. Bu hata değeri, gerçek değerlerle (hedef değer), yapay sinir ağları çıktı değerleri arasındaki kareleri alınmış farkların toplamıdır. Kareler Toplamı, en yaygın kullanılan hata fonksiyonudur. Regresyon problemleri için en uygun fonksiyondur ve sınıflandırma problemleri için de kullanılabilir. (Fyfe, 2000).

Eğitim Algoritmaları: YSA'lar için tek bir en iyi eğitim algoritması yoktur. Dolayısıyla problemin niteliğine göre bir eğitim algoritması seçilmektedir. Bu seçimde, bilinen belli temel kuralların dikkate alınmasının pratik amaçlar için oldukça etkili olduğu tespit edilmiştir.

Eğitim algoritması, YSA'larda ağ yapısından sonra uygulama başarısını belirleyen en önemli faktördür. Eğitim algoritmasının seçiminde belirleyici de, genellikle ağ yapısıdır. Bu nedenle belirlenen ağ yapısı üzerinde kullanılacak eğitim algoritmasının seçimi, çoğunlukla ağ mimarisine bağlıdır. Eğitim algoritmasının seçimi, bazen tasarım aşamasında ağ yapısının tasarımıyla paralel bazen de önce gerçekleştirilir (Sağiroğlu ve ark., 2003).

Bu çalışmada, YSA mimarisinin belirlenmesinde 6 farklı eğitim algoritması kullanılmıştır. Nihai eğitimler için Levenberg-Marquardt (LM) algoritması seçilmiştir.

Levenberg-Marquardt eğitim algoritması:

Bu algoritma; ileri beslemeli, geri yayımlı, denetimli bir algoritmadır. Öğrenme kuralı; 'Delta Kuralı', 'Widrow-Hoff Kuralı' veya 'En Küçük Kareler (EKK) (Least Mean Squares – LMS) kuralı olarak bilinmektedir.

(Yu ve Wilamowski - 2010)'ye göre; bu algoritma genel olarak diğerlerine göre oldukça hızlı işlem gerçekleştirmekte ve daha iyi sonuç vermektedir. Fakat bellek ihtiyacı ağırlık sayısının karesi ile orantılı olduğundan dolayı oldukça yüksektir. Ayrıca algoritma, hata karelerinin toplamını en aza indirme özelliğiyle tasarlanmış olduğundan dolayı, diğer hata fonksiyonları ile kullanılamamaktadır.

Bu algoritmayı, Kenneth Levenberg ve Donald Marquardt birbirlerinden bağımsız olarak geliştirmişlerdir. Algoritma, doğrusal olmayan bir fonksiyonun minimizasyonu problemine sayısal çözüm sağlamaktadır. Hızlı ve istikrarlı yakınsamaya sahiptir. YSA alanında küçük ve orta boyutlu problemlerin eğitimi için uygundur. En etkili eğitim algoritmalarından biri olarak kabul edilmekte ve sadece ÇKA ağlarda kullanılabilir.

YSA 'da kullanımı öngörülen girdiler:

- Zaman;

Minimum-maksimum sıcaklıkları, bağıl nemi, güneşlenmeyi ve solar radyasyonu etkiler. Zaman-sıcaklık ilişkisine ve dolayısıyla mevsimlere bağlı olarak bağıl nem ve rüzgâr hızı girdilerini de dolaylı olarak etkiler.

- Konum;

- Enlem (minimum-maksimum sıcaklıkları ve solar radyasyonu etkiler),
- Yükseklik (minimum-maksimum sıcaklıkları ve kısmen bağıl nemi etkiler),
- Denize mesafe (bağıl nemi etkiler).

YSA 'da kullanımı öngörülen girdilerin eşitlik girdileri ile ilişkileri

- Zaman (Ay):

'Zaman' da esasen Dünya-Güneş ilişkisi anlamında bir konum değeri ifade etmektedir. Bu anlamda YSA girdilerinin tümü konum değeri olarak tanımlanabilir.

'Zaman' doğrudan eşitlik girdisi değildir. Eşitlik girdilerinden net radyasyonu belirleyen ve ölçüm değeri mevcut olmadığında hesaplanması gereken solar radyasyonun hesabında kullanılan yılın gün sıra sayısıdır. Bu sayı, aylık ortalama günlük solar radyasyonu belirleyen ekstraterrestrial (Dünya dışından gelen) radyasyonun tespitinde kullanılır. Ekstraterrestrial radyasyonun girdilerinden olan; dünya yörüngesi eksantriklik düzeltilmesi, gün batım saati açısı ve solar eğim gün sıra sayısından yararlanılarak tespit edilir.

Ay bazında aylık verilerle yapılacak hesaplamalarda, genel olarak aylık ortalama ekstraterrestrial radyasyonu en iyi temsil eden gün, ayın 15. günüdür ve bu nedenle her ay için gün sıra sayısı olarak bu güne tekabül eden sayı kullanılır (Allen ve ark., 1998).

'Zaman' girdisi, eşitlikte her ne kadar sadece radyasyonun belirlenmesinde kullanılsa da, YSA'da doğrudan veri olarak girilmeyen sıcaklığın etkisini de üstlenmektedir. Ayrıca, 'zaman-bağıl nem' ve 'zaman-rüzgâr hızı' ilişkileri oranında, bu girdilerin etkilerini de üstlenmektedir.

- Enlem:

'Enlem' de doğrudan eşitlik girdisi değildir. 'Zaman' girdisi gibi eşitlik girdilerinden olan net radyasyonun belirlenmesinde kullanılan solar radyasyonun kaynağını teşkil eden ekstraterrestrial radyasyonun hesaplanmasında kullanılmaktadır. Ekstraterrestrial radyasyonun girdilerinden olan solar eğim ve günbatım saati açısını belirler. Yine, solar radyasyonun hesabında kullanılan gündüz saatleri uzunluğunu belirler. Bu özellikleri itibarıyla radyasyonu etkiler. Gündüz saatlerinin uzunluğuna etkisi oranında ayrıca sıcaklık etkisini de üstlenmektedir.

- Yükseklik:

Doğrudan eşitlik girdisi değildir. Eşitlik girdilerinden olan psikrometrik sabitin tespiti için gerekli olan hava basıncı değerinin hesaplanmasında kullanılır. Yükseklik-Buharlaştırma arasındaki ilişki

hakkında sahip olunan genel bilgi; yükseklik arttıkça buharlaşmanın da çok az miktarda arttığı yönündedir.

Şöyle ki; yükseklik arttıkça sıcaklığın azalmasına bağlı olarak, ETo'nun da azalması beklenir. Diğer taraftan yükseklik arttıkça atmosfer basıncının azalmasıyla bu defa ETo'nun artması beklenir. Sonuç olarak bu iki durum hemen hemen birbirini dengeler. Dolayısıyla teorik olarak yüksekliğin ETo üzerinde kayda değer bir etkisi olmadığı söylenebilir.

Bu tespit çerçevesinde, FAO PM eşitliğinde yükseklik değişkeninin ETo sonucuna etkisinin çok küçük olmasına rağmen, YSA'da bu etkinin daha büyük olması beklenebilir. Bu beklentinin nedeni, yükseklik–nem ilişkileri ve yüksekliğin diğer bazı girdileri dolaylı olarak az da olsa etkileyebilme ihtimalidir. Bilindiği üzere yüksek bölgeler genellikle nem kaynaklarından uzak bölgelerdir.

- Denize uzaklık:

Herhangi bir yerin, bulunduğu enlem ve yüksekliği gibi, denize uzaklığının da iklim üzerindeki ve dolayısıyla meteorolojik girdiler üzerindeki etkisi bakımından bir konum bilgisi olduğu değerlendirilmiştir. Ne var ki denize uzaklığın bu etkisi homojen olmayıp önemli ölçüde aradaki topoğrafya vb. faktörlere bağlı olmaktadır. Ancak böyle olmasına rağmen, bu faktörler dikkate alınmadığında dahi denizden uzaklığın nemlilik üzerinde genel bir belirleyiciliğe sahip olduğu aşikârdır.

'Denize uzaklık', eşitlikte doğrudan veya dolaylı olarak yer almamaktadır. Bu çalışmada YSA girdisi olarak kullanılmasının nedeni; yukarıda anlatıldığı üzere 'su kütlelerine yakınlık–nemlilik' ilişkisinin bağıl nem üzerindeki etkisi ve ayrıca minimum sıcaklık değerine, ısı akısını (G) belirleyen birbirini takip eden aylar arasındaki ortalama sıcaklık farkına, ortalama sıcaklığa ve minimum-maksimum sıcaklık farkına etkisi dolayısıyla.

2.2.2. Verilerin Ağa Sunulması

Girdilerin hazırlanması, analiz edilmesi, bölümlenmesi ve ön işlenmesi

'Zaman' ve istasyonların 'enlem', 'yükseklik' ve 'denize uzaklık' değerlerinden oluşan konum bilgileri ile bu istasyonlara ait FAO PM eşitliğiyle elde edilen aylık ortalama ETo değerlerinden oluşan veriler ağa sunulmuştur. Veriler; istasyon yeri sütunu bilgi amaçlı, diğer sütunlar eğitim, doğrulama ve test amaçlı olmak üzere toplam 6 sütun ve 1716 satırdan oluşan bir excel tablosu şeklinde hazırlanmıştır (Şekil 2.1).

	A	B	C	D	E	F
	Zaman (Ay)	Enlem (°)	Yükseklik (m)	Denize uz. (km)	ETo (mm gün ⁻¹)	İstasyon Yeri
1	1	37.00	66	34	1.25	Adana
2	2	37.00	66	34	1.54	Adana
3	3	37.00	66	34	2.31	Adana
4	4	37.00	66	34	3.26	Adana
5	5	37.00	66	34	4.36	Adana
6	6	37.00	66	34	5.47	Adana
8
9

Şekil 2.1. YSA girdi sütunları

Her sütunda ağın eğitim performansını olumsuz yönde etkileyebilecek uç değerlerin bulunduğu veri satırlarının işlem dışı bırakılması amacıyla girdi sütunları, belirlenen aykırılık katsayısı ile analiz edilmiştir. Fazla veri kaybına neden olmayacak ve uç değerlerin ayıklanmasını sağlayabilecek uygun bir aykırılık katsayısı seçilerek yapılan analiz ile 12 veri satırı işlem dışı bırakılmıştır.

Veri seti; eğitim, doğrulama ve test olmak üzere 3 bölüme ayrılmıştır. Bu bölümlerden eğitim seti ağın öğrenmesi, doğrulama seti öğrenmenin sonlandırılması gereken aşamanın belirlenmesi ve test seti ağın istenen performansta çıktı üretip-üretmediğinin, diğer bir ifadeyle; sonuçların genelleştirilebilir olup olmadığının kontrolü için kullanılmıştır.

Literatürde; eğitim, doğrulama ve test kümelerinin belirlenmesine yönelik az da olsa öneriler vardır. Birçok araştırmacı [% 80, % 10, % 10] veya [% 70, % 15, % 15] ya da [% 60, % 20, % 20] kuralını temel alan bir yöntem izlemiştir (Hamzaçebi, 2011).

Bu çalışmada da veri satırları; % 70 eğitim, % 15 doğrulama ve % 15 test verisi olacak şekilde bölümlenmiştir. Bölümleme rastgele ve otomatik olarak yapılmıştır. Bölümlemeyle verilerin 1194'ü eğitim, 255'i doğrulama ve 255'i test verisi olarak ayrılmıştır. Girdilerden 'konum' verileri (zaman, enlem, yükseklik ve denize uzaklık) giriş olarak, FAO PM ETo değerleri çıkış (hedef) olarak seçilmiştir.

Esasen doğrulama verileriyle elde edilen başarı, ağ başarısının ortaya konulması bakımından test verileriyle aynı işlevi üstlenmektedir. Tek farklı yönü ise eğitim aşamasında kullanılması ve ağların öğrenmesiyle ezberlemesini de ayırt edici olmasıdır. Hatta doğrulama ile belirlenmiş bir ezberleme durumu söz konusu değilse, eğitimin başarısı dahi ağ performansının bir göstergesi olmaktadır. Diğer bir ifadeyle; mevcut verilerle eğitimde elde edilen başarı seviyesi, girdilerle çıktı arasında var olan ilişkiyi ve seviyesini göstermektedir.

Hazırlama, analiz ve bölümlenmeden sonra veriler, dağılımı düzenli hale getirmek amacıyla belirlenen aktivasyon fonksiyonlarına da bağlı olarak bir ön işleme ile belirli bir aralığa indirgenmişlerdir. Bu işlem, girdi sütunlarının özellikleri belirlenerek ve ölçekleme faktörleri hesaplanarak gerçekleştirilmiştir. Bu kapsamda girdi verilerinden 'zaman', 'enlem', 'yükseklik' ve 'denize uzaklık' giriş değerleri [-1..1] aralığına, hedef ETo değeri ise [0..1] aralığına indirgenmişlerdir. Eğitimin son aşamasında ise “son işleme” denilen bir ters dönüştürme ile sonuçlar tekrar gerçek çıktı değerlerine dönüştürülmüştür. Ön işlenen girdi sütunlarının özellikleri ve hesaplanan ölçekleme faktörleri Çizelge 2.1'de verilmiştir.

Çizelge 2.1. YSA girdi sütunları parametreleri

Parametreler	Veri Sütunları				
	Denize uz. (km)	Yükseklik (m)	Enlem (°)	Zaman (ay)	ETo (mm gün ⁻¹)
Sütun türü	giriş	giriş	giriş	giriş	hedef
Formatı	sayısal	sayısal	sayısal	sayısal	sayısal
Ölçekleme aralığı	[-1..1]	[-1..1]	[-1..1]	[-1..1]	[0..1]
Minimum	0	2	36.1	1	0.29
Maksimum	455	2400	42	12	9.20
Ortalama	106.4	577.5	39.2	6.5	2.85
Standart sapma	111.4	583.7	1.6	3.5	1.81
Ölçekleme faktörü	0.00440	0.00083	0.33727	0.18182	0.11223

2.2.3. Ağ Özelliklerinin Tespiti

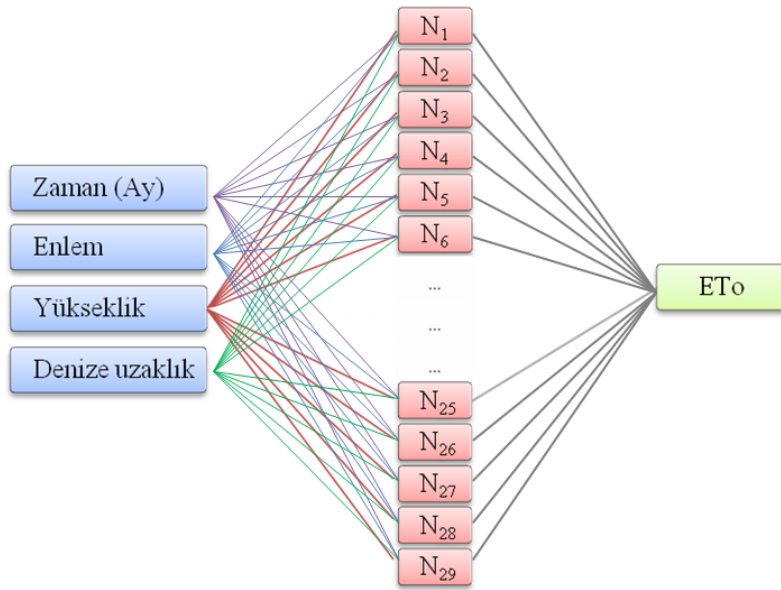
Başlangıç ağırlıklarının ve aktivasyon fonksiyonlarının belirlenmesi

Başlangıç ağırlıklarının seçimi önemlidir. Diğer tüm özellikleri aynı olan fakat belli bir aralıktan seçilen farklı rastgele başlangıç ağırlıkları ile eğitilen ağların performanslarının da çok farklı olabildiği gözlenmiştir. Seçilecek çok büyük veya çok küçük aralıklar, istenmeyen sıçrama veya salınımlara neden olabileceğinden, başlangıç ağırlıkları için uygun bir aralık belirlenmiştir. Bu çerçevede ağırlık aralığı, $[-0.3..+0.3]$ alınmıştır. Her bir eğitim için başlangıç ağırlıkları bu aralıktan rastgele seçimle atanmıştır.

Ağ üzerinde nöronun çıkış değişim aralığını istenilen değerler arasında sınırlayan ve ağın doğrusal olma zorunluluğunu ortadan kaldıran aktivasyon fonksiyonlarının seçimi de oldukça önemlidir. Bu doğrultuda, hem gizli katman ve hem de çıktı katmanı için, yaygın olarak kullanılan “sigmoid” aktivasyon fonksiyonu tercih edilmiştir.

Ağ mimarisinin (gizli katman ve nöron sayılarının) belirlenmesi

(Kaastra ve Boyd - 1996)’a göre; genel olarak problemleri çözmeye tek gizli katmanlı ağlar başarılıdır, nadiren iki gizli katmana ihtiyaç duyulabilir ve daha fazla gizli katmana gerek yoktur. Bu doğrultudaki görüşlere ve bu çalışma kapsamında yapılan denemelere dayanılarak, ağda tek gizli katman kullanılmıştır.



Şekil 2.2. Tasarlanan tek gizli katmanlı 29 nöronlu YSA topolojisi

Gizli katmanlardaki nöron sayılarının tespitine yönelik sabit bir kural olmadığından, deneme ağları üretilerek en uygun nöron sayısı belirlenmeye çalışılmıştır. Bu çerçevede, tasarlanacak ağ için 1'den 30'a kadar nöron kullanılarak ve her biriyle 10 kez olmak üzere 6 farklı eğitim algoritması ile eğitilerek toplam 1800 (30x10x6) adet ağ üretilmiştir. Ağ mimarilerinin belirlenmesinde; Hızlı Yayılım (Quick Propagation), Eşlenik Gradyan İniş (Conjugate Gradient Descent), Quasi-Newton, Sınırlı Bellek Quasi-Newton (Limited Memory Quasi-Newton), Levenberg-Marquardt ve Online Geri Yayılım (Online Back propagation) algoritmaları kullanılmıştır. Her bir eğitimde 500 yineleme uygulanmıştır. 1'den 30'a kadar nörona sahip her ağ için başlangıç ağırlıkları, $[-0.3..0.3]$ aralığından rastgele atanmıştır. Diğer bir ifadeyle; 1'den 30'a kadar nörona sahip ağlardan her birinin eğitiminin başlangıcında 6 algoritma ile 10'ar kez olmak üzere sözü edilen bu aralıktan 60 kez rastgele başlangıç ağırlığı atanmıştır. En iyi olanı belirlemek amacıyla her bir nöron sayısı için mevcut 60 (6x10) grup ağın her algoritma grubundan en iyi 3'er tanesi seçilerek karşılaştırılmıştır. Seçilen bu

180 ağ içerisinde performansı en iyi olanın 29 nöronlu olduğu görülmüştür. Mimari aramayla belirlenen bu sayı, kapsamlı eğitim için nöron sayısı olarak kabul edilmiştir. Kabul edilen nöron sayısı ve katman sayısı ile tasarlanan ağ yapısı şematik olarak Şekil 2.2'de verilmiştir.

Eğitim algoritmasının ve hata fonksiyonunun belirlenmesi

Ağın başarısı açısından, bir ağın mimarisinin belirlenmesinden sonra en önemli konu eğitim algoritmasının belirlenmesidir. Dolayısıyla bu seçimde azami dikkat gereklidir. Bu çalışmada, ağ özelliklerinin belirlenmesi kapsamında nöron sayısı tespit edilirken aynı zamanda en uygun algoritma da belirlenmiş olmaktadır. Dolayısıyla tekrar bir algoritma araştırmasına gerek duyulmamıştır. Gizli katmandaki nöron sayısını belirlemek amacıyla oluşturulan 1800 adet ağın en iyi 180'i içerisinde genel olarak en başarılı ağların LM algoritmasıyla eğitilen ağlar olduğu görülmüştür. Bu sonuca göre doğal olarak bu algoritma seçilmiştir.

YSA'larda eğitim sürecinin değerlendirilmesi için her yineleme sonunda ağ hatasını hesaplayan bir hata fonksiyonuna ihtiyaç vardır. Eğitim algoritması olarak LM algoritması seçildiğinden ve bu algoritma da sadece Hata Kareleri Toplamını (SSE) en aza indirme yöntemiyle çalıştığından, ayrıca bir hata fonksiyonu belirlenmesine gerek kalmamıştır.

2.2.4. Ağın Eğitimi

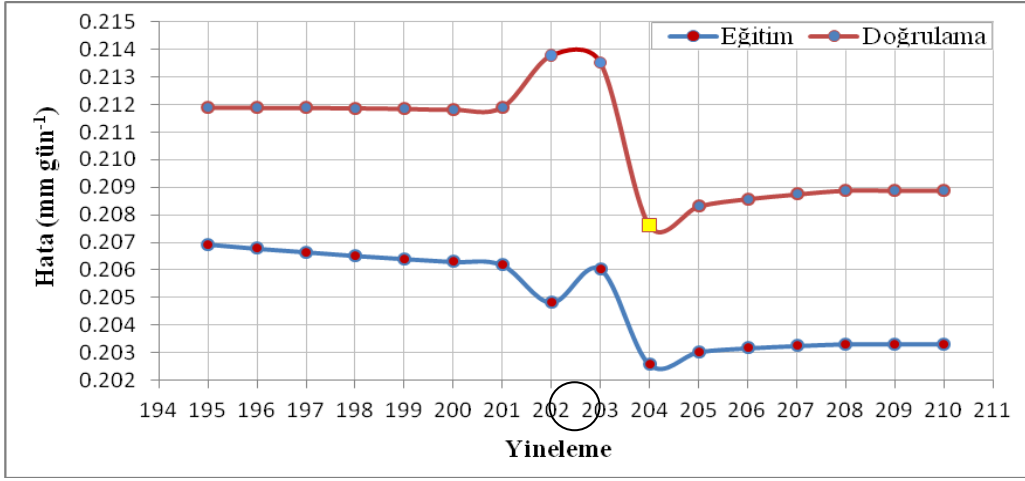
Tasarım aşamasında belirlenen ağ özellikleri (1 gizli katman, gizli katmanda 29 nöron, gizli katmanda ve çıktı katmanında sigmoid aktivasyon fonksiyonu ve LM eğitim algoritması) kullanılarak ve 1000 yineleme öngörülerek, [-0.3..0.3] aralığından rastgele seçilen farklı başlangıç ağırlıklarıyla gerçekleştirilen eğitimlerle 30 adet ağ üretilmiştir. Bu ağlar içerisinden en küçük test hatasına sahip olanı belirlenmiştir. Diğer bir ifadeyle; hedef değerlere en yakın çıktı üreten ağ ağırlıkları tespit edilmiştir. Bu ağ, Çizelge 2.2'de eğitim ve performans özellikleri verilen ağlar içerisinde 16. sıradaki ağdır.

LM algoritması, genelde öngörülen yineleme sayısına ulaşılmadan hata iyileşmesi gerçekleşmeyen yinelemeleri takiben eğitimi sonlandırdığından, daha fazla yinelemeyle daha iyi sonuç alınıp alınamayacağı tereddüdünden kurtulmak amacıyla tüm eğitimlerin hata iyileşmesi kistasıyla tamamlanması hedeflenmiştir. Bu nedenle, algoritmanın çok daha erken sonuca ulaşabilmesine rağmen 1000 yineleme öngörülmüştür. 1000 yineleme sadece çizelgede 11. sırada yer alan ağda gerçekleşmiştir. Bunun dışındaki tüm ağlarda eğitim, hata iyileşmesi kistasına göre tamamlanmıştır. Yani eğitim sürerken ulaşılan minimum bir hata noktasından sonraki yinelemelerde hata artış eğilimine girerek devam ettiğinde eğitimler sonlandırılmıştır. Bu sonlandırma ile minimum hatanın elde edildiği ağırlıklar geri yüklenerek eğitimler sonlandırılmıştır. Tüm yinelemelerin denendiği 11. sıradaki ağ, diğerlerinden daha iyi bir performansla sahip olmadığından dolayı daha fazla sayıda yineleme ile eğitilmesine gerek kalmamıştır. Çizelgede verilen yineleme sayıları, eğitim süresince elde edilen ideal ağ ağırlıklarının geri yüklendiği yinelemelerdir. Örneğin; 11. sıradaki eğitimde 1000 yineleme tamamlanmış ve tüm yinelemeler içerisinde minimum hatayı sağlayan 173. yinelemedeki ağırlıklar geri yüklenmiştir.

Eğitimin bir doğrulama veri seti ile kontrolü

Eğitim sürerken eğitime dâhil edilmeyen bir doğrulama veri seti ile de performans kontrolü yapıldığından, aşırı eğitim ve dolayısıyla ağın ezberlemesi engellenebilmektedir. Eğer doğrulama uygulanmasaydı, eğitim aşamasında ağın eğitildiği veya ezberlediği fark edilemeyecek, ancak eğitim tamamlandıktan sonra test aşamasında anlaşılabilirdi. Ezberleyen bir ağ, sorgulama aşamasında eğitim verileri için hatasız, test verileri için ise tamamen hatalı sonuçlar vermektedir. Ayrıca LM dışındaki algoritmalarda tüm yinelemeler denendikten sonra minimum hatanın sağlandığı ağırlıklara dönüldüğünden, daha büyük yineleme sayılarının seçimi konusunda tereddüt oluşacaktı. Yine, ezberleme riskiyle birlikte zaman kaybı söz konusu olacaktı. Doğrulama

uygulamasının LM eğitim algoritması ile kullanımında bu dezavantajlar söz konusu değildir. Doğrulama kontrolü, tüm algoritmalarda eğitimin manuel olarak durdurulması gereken zamanın tespitine imkân sağlamaktadır.



Şekil 2.3. Ağ performansının en iyi olduğu yineleme

Çizelge 2.2. 29 nöronla eğitilen ağların özellikleri

Eğitim sırası	Yineleme sayısı	Eğitim hatası (mm)	Test hatası (mm)	AIC	Korelasyon	R ²	Durma nedeni
1.	137	0.215547	0.272629	-0.000101	0.989146	0.978410	Hata iyileşmesi yok
2.	64	0.256962	0.263597	-0.000103	0.982548	0.965401	Hata iyileşmesi yok
3.	198	0.225125	0.292402	-0.000101	0.987806	0.975761	Hata iyileşmesi yok
4.	26	0.268059	0.298448	-0.000103	0.981044	0.962447	Hata iyileşmesi yok
5.	68	0.239280	0.299937	-0.000102	0.986004	0.972204	Hata iyileşmesi yok
6.	12	0.339789	0.338337	-0.000106	0.970851	0.942552	Hata iyileşmesi yok
7.	208	0.201537	0.268367	-0.000100	0.990322	0.980738	Hata iyileşmesi yok
8.	3	1.579919	1.506414	-0.000132	0.206519	0.042650	Hata iyileşmesi yok
9.	66	0.249095	0.284446	-0.000102	0.983903	0.968065	Hata iyileşmesi yok
10.	152	0.218457	0.266984	-0.000101	0.988828	0.977781	Hata iyileşmesi yok
11.	173	0.207447	0.251030	-0.000100	0.989791	0.979686	Yinelemeler tamam
12.	153	0.197307	0.247370	-0.000100	0.990689	0.981465	Hata iyileşmesi yok
13.	52	0.252707	0.261404	-0.000103	0.983156	0.966596	Hata iyileşmesi yok
14.	12	0.308318	0.309363	-0.000105	0.975551	0.951700	Hata iyileşmesi yok
15.	196	0.206709	0.283567	-0.000100	0.989896	0.979894	Hata iyileşmesi yok
16.	210	0.202584	0.244140	-0.000100	0.990232	0.980559	Hata iyileşmesi yok
17.	119	0.214043	0.253975	-0.000101	0.988717	0.977561	Hata iyileşmesi yok
18.	26	0.286976	0.294265	-0.000104	0.978275	0.957022	Hata iyileşmesi yok
19.	245	0.195036	0.260227	-0.000099	0.990929	0.981940	Hata iyileşmesi yok
20.	104	0.213803	0.261244	-0.000100	0.988768	0.977662	Hata iyileşmesi yok
21.	31	0.278676	0.303298	-0.000104	0.979573	0.959563	Hata iyileşmesi yok
22.	84	0.244414	0.276600	-0.000102	0.984649	0.969534	Hata iyileşmesi yok
23.	87	0.257209	0.265950	-0.000103	0.982558	0.965420	Hata iyileşmesi yok
24.	242	0.216545	0.260295	-0.000101	0.989153	0.978424	Hata iyileşmesi yok
25.	232	0.206849	0.251424	-0.000100	0.989707	0.979520	Hata iyileşmesi yok
26.	42	0.253256	0.271478	-0.000103	0.983745	0.967754	Hata iyileşmesi yok
27.	82	0.261728	0.281397	-0.000103	0.982395	0.965100	Hata iyileşmesi yok
28.	144	0.205526	0.244386	-0.000100	0.989768	0.979641	Hata iyileşmesi yok
29.	20	0.278479	0.292116	-0.000104	0.979180	0.958793	Hata iyileşmesi yok
30.	64	0.241984	0.295457	-0.000102	0.985531	0.971271	Hata iyileşmesi yok
Minimum		0.195036	0.244140	-0.000132	0.206519	0.042650	
Maksimum		1.579919	1.506414	-0.000099	0.990929	0.981940	
Ortalama		0.284112	0.316685	-0.000103	0.959308	0.939837	

Tüm özellikleri belirlenen ağın eğitiminde hata düşüşü sürerken, minimum hatanın gerçekleştiği 204. yinelemeden sonra hata artış eğilimine girmiş ve 210. yinelemeye kadar iyileşme yönünde bir gelişme olmadığı belirlendikten sonra eğitim otomatik olarak durmuş ve en düşük doğrulama hatasının gerçekleştiği 204. yinelemedeki ağırlıklar geri yüklenmiştir (Şekil 2.3). Diğer bir ifadeyle; eğitim için 1000 yineleme seçilmiş olmasına rağmen, hata iyileşmesi 204. yinelemeye kadar sürdüğünden, 210. yinelemede de artık hata iyileşmesi olmadığı görüldükten sonra en iyi performansın elde edildiği 204. yinelemedeki ağ ağırlıkları geri yüklenerek eğitim sonlandırılmıştır.

3. Bulgular Ve Tartışma

3.1. Ağ İstatistikleri

3.1.1. Eğitim istatistikleri

Eğitimde Ortalama Mutlak Hata (MAE) yaklaşık 0.2 mm bulunmuştur. Ortalama Mutlak Yüzde Hata (MAPE) % 9.6 ve Korelasyon (R) 0.99'dur (Çizelge 3.1).


En küçük hata 0.00 mm, en büyük hata 1.22 mm'dir. Toplam hata sayısının yaklaşık % 53'ü 0.18 mm'nin, % 78'i 0.3 mm'nin, % 95'i 0.5 mm'nin ve % 99'u 0.8 mm'nin altında yer almıştır (Çizelge 3.2, Şekil 3.1).

Çizelge 3.1. YSA eğitim istatistikleri

	Hedef (mm)	Çıktı (mm)	AE (mm)	APE (%)
Ortalama (M)	2.86	2.85	0.203	9.6
Std Sapma	1.85	1.83	0.159	9.0
Minimum	0.29	0.38	0.000	0.0
Maksimum	8.55	8.02	1.218	87.0
Korelasyon	0.9902			
R ²	0.9805			

Çizelge 3.2. YSA eğitim hata dağılımı

Hata aralığı (mm)	Hata sayısı (ad.)	Yığılımlı toplam (ad.)	Yığılımlı toplam (%)
0.00 – 0.06	239	239	20
0.06 – 0.12	191	430	36
0.12 – 0.18	200	630	53
0.18 – 0.24	175	805	67
0.24 – 0.30	128	933	78
0.30 – 0.40	126	1059	89
0.40 – 0.50	78	1137	95
0.50 – 0.60	29	1166	98
0.60 – 0.70	15	1181	99
0.70 – 0.80	5	1186	99
0.80 – 0.90	3	1189	100
0.90 – 1.00	1	1190	100
1.00 – 1.10	2	1192	100
1.10 – 1.22	2	1194	100



Şekil 3.1. YSA eğitim hata dağılımı

3.1.2. Test istatistikleri

Veri bölümlenme aşamasında test için ayrılan 255 adet veri satırı ile test edilen ağda; MAE 0.24 mm, MAPE % 11.9 ve Korelasyon 0.984 bulunmuştur (Çizelge 3.3).

En küçük hata 0.00 mm, en büyük hata 1.10 mm elde edilmiştir. Toplam hata sayısının yaklaşık % 50'si 0.2 mm'nin, % 80'i 0.4 mm'nin, % 91'i 0.5 mm'nin ve % 95'i 0.6 mm'nin altında yer almıştır (Çizelge 3.4, Şekil 3.2).

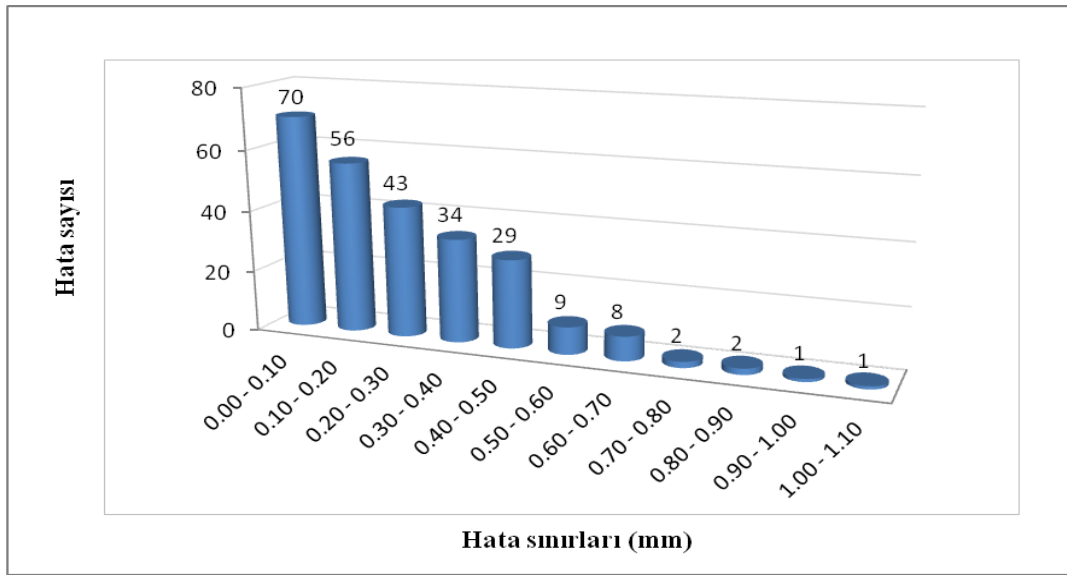
Çizelge 3.3. YSA test istatistikleri

	Hedef (mm)	Çıktı (mm)	AE (mm)	APE (%)
Ortalama (M)	2.76	2.78	0.244	11.9
Std Sapma	1.75	1.74	0.193	12.6
Minimum	0.46	0.48	0.000	00.0
Maksimum	9.20	8.21	1.102	93.3
Korelasyon	0.9842			
R ²	0.9686			

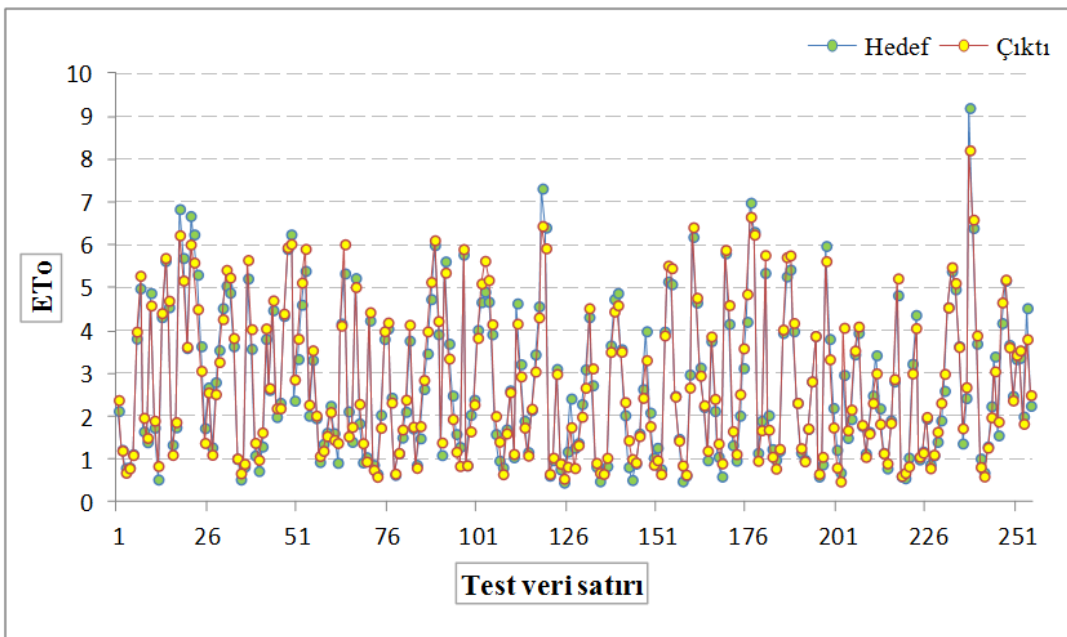
FAO PM eşitliğiyle hesaplanan ETo ve 'zaman-konum' değerleriyle eğitilen YSA'yla tahmin edilen ETo sonuçları; girdilerin tümü için Şekil 3.3'te, örtüşmenin net olarak görülebilmesi bakımından daha az sayıda girdi için Şekil 3.4'te hedef-çıkıtı grafikleriyle ve Şekil 3.5'de saçılım grafiğiyle karşılaştırılmıştır. Grafikler incelendiğinde, test girdilerine ait FAO PM ETo değerleri ile YSA ETo değerlerinin birbirlerine oldukça yakın değerler aldığı görülmektedir. Saçılım grafiğinde ise koordinatları hedef ve çıkıtı değerlerinden oluşan noktaların regresyon doğrusu etrafında kümelenildiği görülmektedir. Bu sonuçlara göre; 'zaman-konum' girdileriyle eğitilen YSA'nın, FAO PM eşitliğiyle hesaplanan ETo'yu tahmin başarısı % 97 olmuştur.

Çizelge 3.4. YSA test hata dağılımı

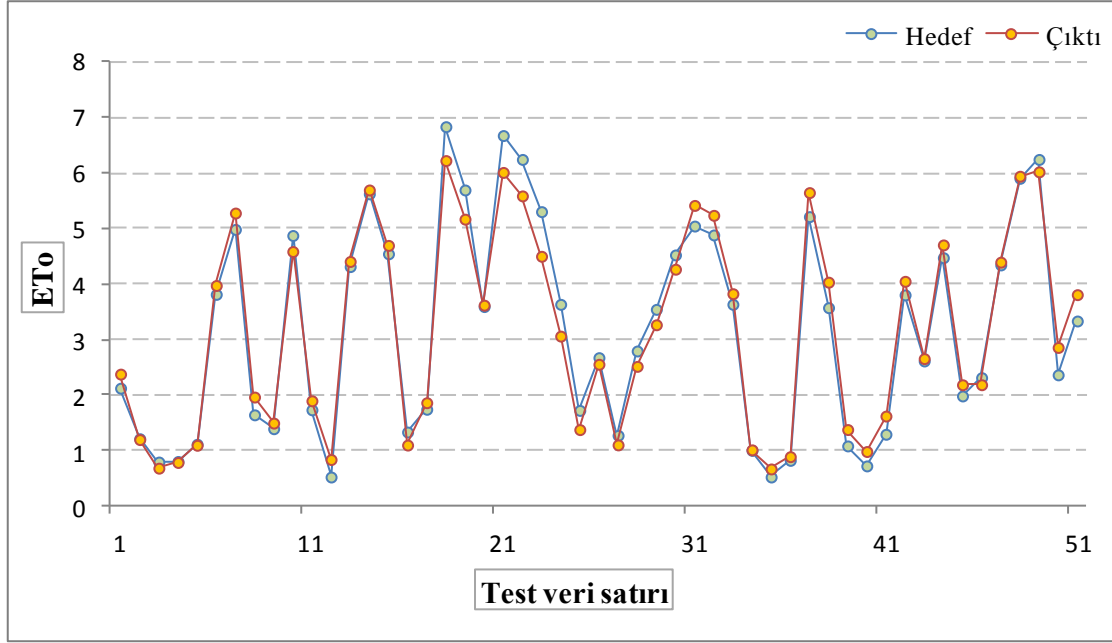
Hata aralığı (mm)	Hata sayısı (ad.)	Yığışimli toplam (ad.)	Yığışimli toplam (%)
0.00 – 0.10	70	70	27
0.10 – 0.20	56	126	49
0.20 – 0.30	43	169	66
0.30 – 0.40	34	203	80
0.40 – 0.50	29	232	91
0.50 – 0.60	9	241	95
0.60 – 0.70	8	249	98
0.70 – 0.80	2	251	98
0.80 – 0.90	2	253	99
0.90 – 1.00	1	254	100
1.00 – 1.10	1	255	100



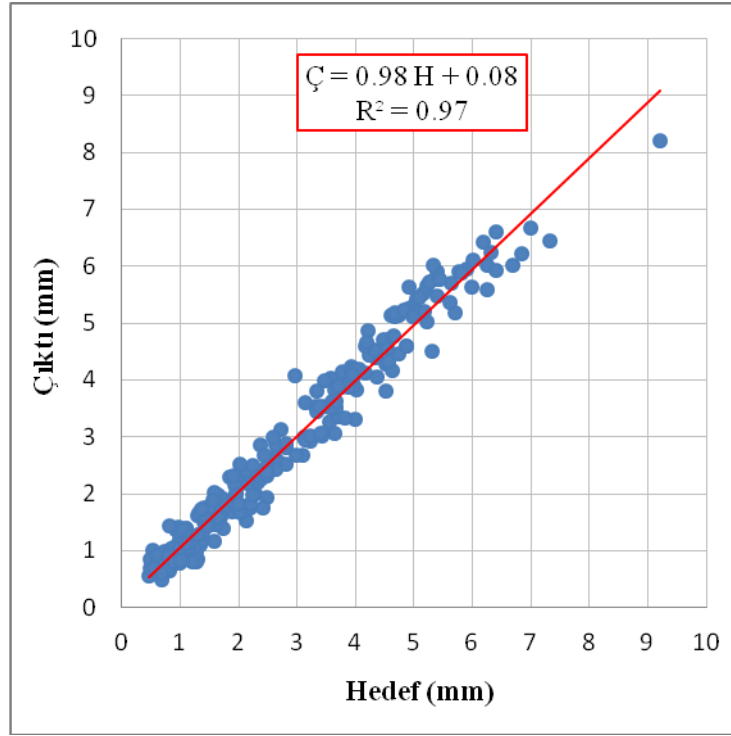
Şekil 3.2. YSA test hata dağılımı



Şekil 3.3. YSA test verileri hedef – çıktı grafiği



Şekil 3.4. YSA test verileri hedef – çıktı grafiği (ilk 51 satır veri için)



Şekil 3.5. YSA test verileri hedef – çıktı saçılımı

3.2. Sonuçların Değerlendirilmesi

3.2.1. Girdi önemi

Girdi Önemi, her bir girdi sütununun, sonuca izafi etki oranını ifade etmektedir. Diğer bir ifadeyle; eğitimin başarısı ne olursa olsun, tüm girdilerin toplam % 100 olan ‘girdi önemi’ içerisinde herhangi bir girdinin, ağ bağlantı ağırlıkları vasıtasıyla eğitime katkı oranını ifade etmektedir. Dolayısıyla girdi önemi, ağın performansını yansıtmamakta, elde edilen performansa göre herhangi bir girdinin eğitime ve dolayısıyla sonuca katkısını ortaya koymaktadır.

Girdi önemi grafiğinden, ETO'nun şekillenmesinde en büyük etkinin, yaklaşık % 85 oran ile 'zaman' girdisine ait olduğu görülmektedir. 'Zaman'ı sırasıyla; 'yükseklik', 'enlem' ve 'denize uzaklık' girdileri takip etmektedir (Şekil 3.6). Yapılan eğitim çalışmalarının çoğunda sıralama genel olarak bu şekilde gerçekleşmiştir. Oranların da hemen hemen bu değerler civarında olduğu görülmüştür.

Girdi önemi oranları yorumlandığında; 'zaman'ın sonuca etkisi yaklaşık % 85'tir ve % 5 'enlem' etkisiyle birlikte toplam % 90 olmaktadır. Kalan % 10'luk kısmı, 'yükseklik' ve 'denize uzaklık' karşılamaktadır. Toplamı % 100 olan girdi önemi, R^2 değeri referans alındığında, tahminde isabet edilen % 97'lik kısma aittir. Kalan % 3'lük hata oranını belirleyen dört durum söz konusu olabilir.

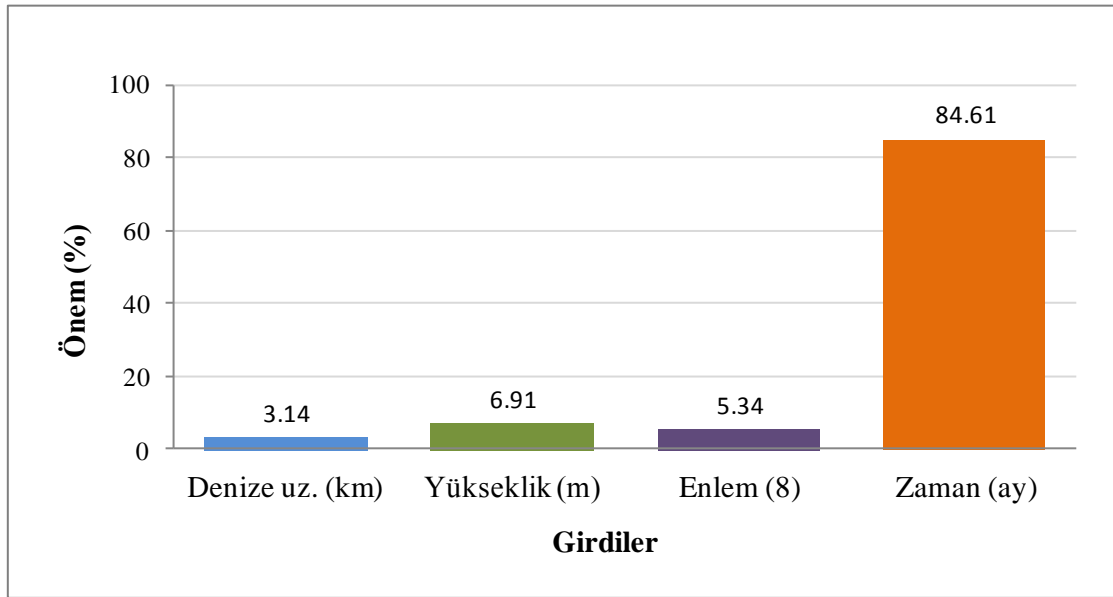
Bunlar:

1 – YSA'nın performansı. Belirlenen ağdan daha iyi bir ağ elde edebilme ihtimali her zaman vardır.

2 – Meteorolojik değerler hatalı ölçülmüş veya kaydedilmiş olabilir. Bu durum, YSA'da referans alınan ETO değerlerinin hatalı hesaplanmasına neden olur. Hatalı referans da YSA'yı yanıltacaktır.

3 – Çeşit olarak ilave girdi veya girdilere ihtiyaç vardır. Kullanılan girdiler dışında kısmi de olsa ETO'a etki eden faktörler mevcuttur.

4 – İlk üç maddede sayılanlardan biri, ikisi veya her üçü etkili olabilir. Hata mevcut olduğu müddetçe en az biri etkilidir.



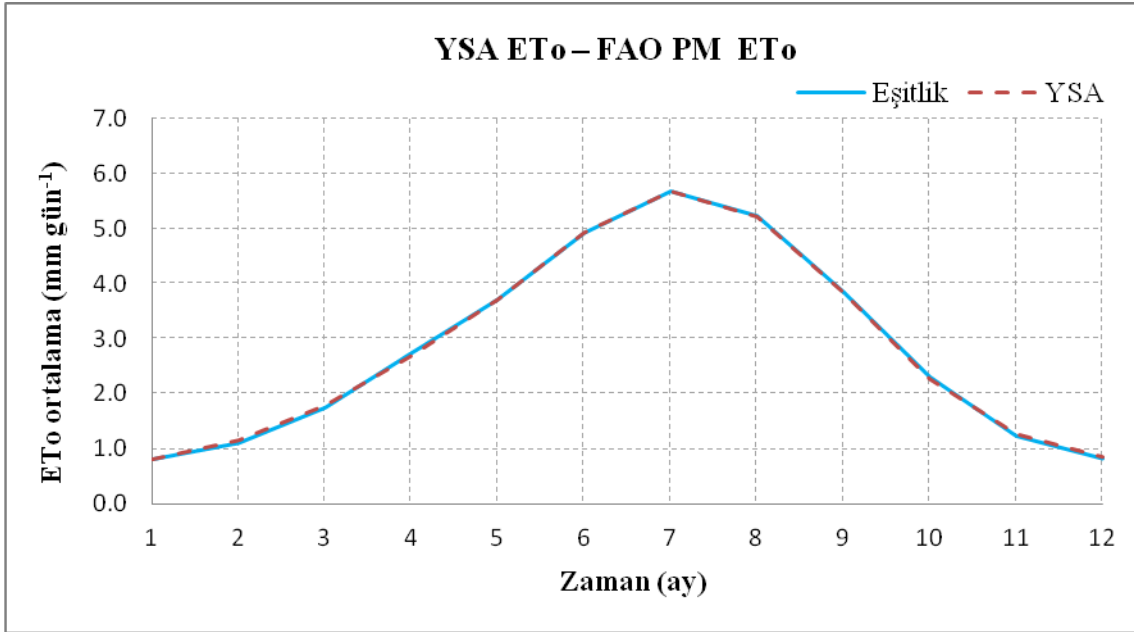
Şekil 3.6. YSA girdi önemi dağılımı

3.2.2. Tahmin yöntemlerine ait sonuçların karşılaştırılması

Münferit olarak değerlendirildiğinde, verileri kullanılan istasyonların bir kısmında FAO PM eşitliği ve YSA'yla ay bazında tahmin edilen ETO değerlerinin çok az sapmayla da olsa birbirinden farklı bulunmasına rağmen toplu değerlendirmede her iki yöntemle tahmin edilen tüm istasyonlara ait ortalama aylık ETO değerlerinin birbirine eşit olduğu görülmektedir (Şekil 3.7).

Bir YSA'nın eğitimi; tüm girdiler için hedef (çıkış) değerleriyle ağ çıktılarının farkının minimum olmasını sağlayan ağ bağlantı ağırlıklarının belirlenmesi olduğuna göre, konumuzda da ağın eğitimiyle, tüm girdiler için hedef gösterilen FAO PM ETO değerleriyle YSA çıktılarının birbirine eşit veya en yakın olmasını sağlayan, yani hata değerlerini ve dolayısıyla toplam hata değerini

minimum yapan ağ bağlantı ağırlıkları belirlenmiş olmaktadır. Eğitim süreci, eğitim algoritmasının hata fonksiyonu ile denetlendiğinden, eğitimin tamamlanmasından sonra eğitimin başarısına bağlı olarak, bu fonksiyonla sıfır veya sıfıra yakın bulunan hata değeri ağın toplam hatası olmaktadır. Toplam hata minimize edilirken, bazı aykırı giriş değerlerinin varlığı, sayıca az da olsa ortalama hatanın oldukça üzerinde münferit hataların oluşmasına neden olmaktadır. Eğer sistem, söz konusu bu hataların daha küçük çıkmasını sağlayacak şekilde ağırlıkları güncelleyecek olsa bu defa da toplam hata değeri büyüyebilecektir. Diğer bir ifadeyle; sistem, toplam hatayı minimize etme prensibiyle çalıştığından, ağ bağlantı ağırlıkları bu sonucu sağlayacak şekilde güncellenmekte ve dolayısıyla aykırı tekil hatalara engel olunamamaktadır. Bu durum, verilerin dağılımına ve problemlerin doğrusal olmayışına rağmen ağın tüm veriler için doğru sonuç üretme zorunluluğundan kaynaklanmaktadır. Özetle, iyi eğitilmiş bir YSA'da toplam hata ve dolayısıyla ortalama hata minimuma indirgenmiş olmaktadır. Tekil aykırı hatalar ise veri setinin durumuna ve ağ performansına göre değerler almaktadır.



Şekil 3.7. Tüm veriler (eğitim, doğrulama, test) için FAO PM eşitliği ve YSA ile tahmin edilen aylık ortalama ETo sonuçlarının karşılaştırılması

4. Sonuç

Sonuç itibariyle; ETo, 'zaman-konum' girdileri kullanılan YSA'yla kabul edilebilir hata oranı ile tahmin edilebilmektedir. YSA'nın test hatası ortalaması, milimetrenin dörtte birinden daha küçük bulunmuştur. Test hatalarının % 90'ından fazlası 0.5 mm'nin altında yer almıştır. Hedef değerler ile tahmin (çıktı) değerleri arasındaki Korelasyon; eğitimde 0.990, testte 0.984 hesaplanmıştır.

Ağların eğitiminde hedef olarak FAO PM ETo değerleri referans alındığından, elde edilen YSA'nın uygulamadaki randımanı, FAO PM ETo'nun randımanı ile aynı olacaktır. Zira aradaki fark ihmal edilebilecek kadar küçüktür. Örneğin; ortalama hata olarak bulunan 0.24 mm su yüksekliği, günlük tüketimi 12 mm olan herhangi bir bitkinin su ihtiyacının sadece % 2'sine tekabül etmektedir. Maksimum hata dikkate alındığında dahi bu örnek için oran % 10'u geçmemektedir. Diğer yandan maksimum hata, test verilerinin sadece % 0.4'ü için gerçekleşmiştir.

Özet olarak, zaman-konum ve YSA ile uygulamada güvenle kullanılabilir bir yöntem elde edilmiştir.

Kaynaklar

- [1] Linacre, E. 1999. Geography and Climate, www-das.uwyo.edu/~geerts/cwx/notes/chap16/geo_clim.html (01.01.2016).
- [2] Allen, R. G., Pereira, L. S., Raes, D., Smith, M. 1998. Crop evapotranspiration, Guidelines for computing crop water requirements, Irrigation and Drainage paper No. 56, FAO, 300p.
- [3] MGM, 2016. İklimi Meydana Getiren Elemanlar, İklim, Meteoroloji Genel Müdürlüğü, 1998-2016, <http://www.mgm.gov.tr/iklim/iklim.aspx?k=B> (01.01.2016)
- [4] Kalifa, E. A., Abd-el Hady Rady, R. M., Alhayawei, S. A. 2012. Estimation of Evaporation Losses from Lake Nasser: Neural Network based Modeling versus Multivariate Linear Regression, Journal of Applied Sciences Research, Vol. 8 Issue 5, p2785.
- [5] Haykin, S. 1999. Neural Networks: A Comprehensive Foundation. (2nd ed.), Pearson Education, Inc. Pearson Prentice Hall, ISBN 81-7808-300-0, McMaster University, Hamilton, Ontario, Canada.
- [6] Yurtoğlu, H. 2005. Yapay Sinir Ağları Metodolojisi ile Öngörü Modellemesi: Bazı Makroekonomik Değişkenler İçin Türkiye Örneği, DPT – Uzmanlık Tezleri, Yayın No: Dpt: 2683, Ekonomik Modeller ve Stratejik Araştırmalar Genel Müdürlüğü.
- [7] Rumelhart, D. E., Hinton, G. E., Williams, R. J. 1986. Learning Internal Representations by Error Propagation, To be Published in D. E. Rumelhart & J. L. McClelland (Eds.), Parallel Distributed Processing: Explorations in the Microstructure of Cognition. Vol. 1: Foundations, Cambridge, MA: Bradford Books/MIT Press.
- [8] Fyfe, C. 2000. Artificial Neural Networks and Information Theory, Department of Computing and Information Systems, The University of Paisley.
- [9] Sağıroğlu, S., Beşdok, E., Eler, M. 2003. Mühendislikte Yapay Zeka Uygulamaları-1: Yapay Sinir Ağları, ISBN: 975-95948-5-4, Ufuk Yayıncılık, Kayseri.
- [10] Yu, H., Wilamowski, B. M. 2010. Levenberg-Marquardt Training, Auburn University. http://www.eng.auburn.edu/~wilambm/pap/2011/K10149_C012.pdf (01.01.2016).
- [11] Hamzaçebi, C. 2011. Yapay Sinir Ağları Tahmin Amaçlı Kullanımı Matlab ve Neurosolutions Uygulamalı, ISBN: 978-605-5431-82-2, EKİN Basım Yayın Dağıtım, Bursa.
- [12] Kaastra, I., Boyd, M. 1996. Designing A Neural Network For Forecasting Financial and Econometric Time Series, Neurocomputing, 10:215-236, Elsevier Journals.