

## TÜRKİYE'YE GELEN TURİST SAYISI TAHMİNİNDE ZAMAN SERİLERİ ANALİZİ VE YAPAY SİNİR AĞLARI YÖNTEMLERİNİN KARŞILAŞTIRILMASI<sup>1</sup>

Şebnem ZORLUTUNA<sup>2</sup>

Hüdaverdi BİRCAN<sup>3</sup>

### Özet

Bu çalışmada, Kültür ve Turizm Bakanlığında elde edilen istatistiklere göre Türkiye geneline yönelik turizm talebinin aylar itibariyle tahmin edilmesinde “Zaman Serileri Analizi” ile “Yapay Sinir Ağları” yöntemlerinin öngörü doğruluklarının karşılaştırılması en yüksek öngörü doğruluğuna sahip modelin belirlenmesi amaçlanmıştır.

Turist talebi ile ilgili yapılan modellemelerde zaman serisi tekniklerinden ARMA (Karma Otoregresif Hareketli Ortalama Süreci) veya ARIMA (Homojen Durağan Olmayan Süreçler) modelleri kullanılarak en uygun model belirlenmeye çalışılmıştır. Zaman Serileri Analizi için E-Views 7 programı kullanılmıştır.

MATLAB 7.9.0(R2009b) programı kullanılarak geliştirilen yapay sinir ağları sistemleri ile performansı en yüksek modelin belirlenmesi amaçlanmıştır. Bu amaç için, ileri beslemeli ağ yapısı, danışmanlı öğrenme stratejisi ve MLP (Multi-Layer Perceptron) modeli ile oluşturulan yapıları eğitmede kullanılan hatayı geriye yayma algoritması ile farklı ağ yapıları kullanılmıştır. Optimum başarı elde etmek için çok sayıda deneme gerçekleştirilmiştir.

Kullanılan yöntemlerin karşılaştırılması sonucunda, yapay sinir ağlarının, zaman serileri analizine göre öngörü doğruluğunun daha yüksek ve gerçek değerlere en yakın sonuçları veren yöntem olduğu görülmüştür.

**Anahtar Sözcükler:** Yapay Sinir Ağları, Zaman Serileri Analizi, Turizm Talep Tahmini.

<sup>1</sup> Bu çalışma, “Türkiye’ye Gelen Turist Sayısı Tahmininde Zaman Serileri Analizi ve Yapay Sinir Ağları Yöntemlerinin Karşılaştırılması” isimli doktora tezinden üretilmiştir

<sup>2</sup> Dr. Öğr.Üyesi, Cumhuriyet Üniversitesi, İktisadi ve İdari Bilimler Fakültesi, Ekonometri Bölümü, Sivas, szorlutuna@cumhuriyet.edu.tr, ORCID: 0000-0001-7683-3832

<sup>3</sup> Prof. Dr., Cumhuriyet Üniversitesi, İktisadi ve İdari Bilimler Fakültesi, İşletme Bölümü, Sivas, hbircan@gmail.com, ORCID: 0000-0002-1868-1161

## **Comparison of Methods of Time Series Analysis and Artificial Neural Networks on Estimation The Number of Tourists Come to Turkey**

### **Abstract**

In this study, it is aimed to determine the model giving the best estimate by compared the prediction accuracy of “Time Series Analysis” and “Artificial Neural Networks” on monthly tourism demand for Turkey according to the Ministry of Culture and Tourism’s statistics.

For the modeling related to the demand of tourist, ARMA or ARIMA models that are time-series techniques was used and the most appropriate model was tried to determine. E-Views 7 program was used for Time Series Analysis.

It is aimed to determine the high-performance model by using Artificial Neural Networks developed by MATLAB 7.0.9(R2009b) programme. For this purpose, Artificial Neural Networks were trained by using backpropagation algorithm it is used for training the structures which are made up of feedforward network structure, supervised learning strategy and MLP model and different network structures. Also it was carried out many experiments to obtain optimal success.

As a result of comparison of the methods used, artificial neural networks have higher predictive accuracy than time series analysis and provide the closest results to real values.

**Keywords:** Artificial Neural Networks, Time Series Analysis, Tourism Demand Forecasting

### **Giriş**

Turizm, başta gelişmekte olan ülkeler olmak üzere, turizm potansiyeline sahip birçok ülkede; istihdama, gelir düzeyine, dış-ıç borç yükünün hafiflemesine, ödemeler dengesine ve sonuçta ülke insanın refah düzeyinin yükselmesine önemli ölçüde katkılar sağlamaktadır.

Turizm, bugün dünya gayrisafi hâsılasının önemli bölümünü oluşturan bir sektör konumundadır. Tüm dünyadaki ekonomik duraklamaya karşın büyümesini devam ettirmekte olan bu dinamik sektör diğer sektörlerin de motor gücü olarak işlev görmektedir.

Dünya pazarında ortaya çıkan değişimlere ve yeni beklentilere her yönüyle cevap verebilecek bir potansiyele sahip olan ülkemizin turizmden gereken faydayı sağlayabilmesi için geleceğe yönelik kararların alınmasında turizm talebi tahminleri oldukça önemlidir.

Zaman serileri analizi ile farklı bileşenlerin etkilerinin oluşturduğu zaman serilerinin bu bileşenlerden nasıl etkilendiği ve gelecekte nasıl etkileneceği belirlenmeye çalışılır. Zaman serilerinin özelliklerini belirlemek ve ileriye görmek amacıyla taşıyan ARIMA(p,d,q) modellerinde temel yaklaşım, ele alınan değişkenin bugünkü değerinin, geçmiş değerlerinin ağırlıklı toplamı ve rassal şokların bileşimi olduğu şeklindedir. Box-Jenkins yöntemi tek değişkenli zaman serilerinin ileriye dönük tahmininde güvenilir tahmin sonuçları veren yaygın uygulama alanı bulunan temel olarak Otoregresyon ve Hareketli Ortalama olmak üzere iki ayrı yöntemin bir kombinasyonunu oluşturmaya çalışır. Bu kombinasyon kısaca ARMA (Auto Regressive Moving Averages) şeklinde ifade edilir. Ancak bu modeller durağan serilerde kullanılabilir. Bu nedenle öncelikle seri fark alma işlemi ile durağan hale getirilmelidir. Fark alma işleminin sayısını belirleyen “entegrasyon indeksi” modele dahil edildiğinde ARIMA (Autoregressive Integrated Moving Average) modelleri oluşur. ARIMA modellerinin çeşitli çalışmalarda kısa ve orta vade öngörü başarısının yüksek olduğu görülmüştür. Ayrıca ARIMA modellerinin öngörü için ek bilgi gerektirmemesi de yaygın kullanım alanı bulmasını sağlamıştır. Bununla beraber, farklı model alternatiflerinden uygununu seçme ve her aşamada seçilen modelin incelenen seriye uygunluğunu denetleme gibi birtakım avantajları vardır.

Zaman serilerinin yapay sinir ağları ile tahmininde en fazla tercih edilen yöntem geriye yayılım algoritması (GYA) dır. Geriye yayılım algoritması ile eğitilen ağlar danışmanlı öğrenme gerçekleştiren, ileri beslemeli bir YSA’dır. Özellikle, bu çalışmada da olduğu gibi, zaman serilerinin gelecekteki davranışlarını öngörmeye kullanılır. Bunun nedeni geri yayılım algoritması ile oluşturulan ağların doğrusal olmayan modellere uygunluk göstermesi ve bu ağlarda kullanılan öğrenme algoritmasının denetimli olmasıdır. Günlük hayattaki problemlerin çoğu bu modellere uygunluk göstermektedir. Geri Yayılım Algoritması kullanan ağ modellerinde karşılaşılan en büyük zorluk, gizli katman sayısının ve bu katmanlarda yer alacak nöron sayılarının belirlenmesidir. Bu sayıların belirlenmesi için çok geçerli bir yöntem mevcut değildir. Katmanlardaki nöron sayısı genellikle deneme-yanılma yoluyla belirlenir. İstatistiksel yöntemlerin çoğunda verilerde normal dağılım varsayımı ve değişkenlerde varyasyon ve korelasyon varsayımları vardır (Neter vd., 1989). Diğer klasik istatistiksel yöntemlerde olduğu gibi stokastik süreçlerde de teoriden gelen, durağan olma, hataların Gauss (normal) dağılımlı olması ve bünyelerinde periyodiklik olmaması gibi varsayımları vardır (Şen, 2004, 32). Yapay

sinir ağları yaklaşımının klasik istatistiksel yöntemlere göre avantajı, hiçbir temel varsayıma ve veri dağılımı hakkında bir ön bilgiye gerek duymadan başarılı sonuçlar üretmesidir. Yapay sinir ağlarının bazı değişkenlere ait eksik verileri de tolere etme özelliği mevcuttur. Ancak, sinir ağlarının eğitimi için çok sayıda veriye ihtiyaç duyulması ve ağ modelinin oluşturulmasında yaşanan bir takım güçlükler zaman zaman bir dezavantaj olarak görülebilir (Öztemel, 2003).

Gerek turizm gerekse diğer sektörlerde talep tahmininde yapay sinir ağları ve zaman serileri analizi yöntemleri çeşitli çalışmalarda kullanılmıştır.

Chen, (2000), doktora tezinde Turizm ve eğlence sektörüne olan talebi belirlemek için üç tane Amerikan milli parkını örnek seçmiş ve bu parklara gelen ziyaretçi sayıları için talep tahminlerinde bulunmuştur. Çalışmasında ARIMA metodu ile diğer istatistiksel metotlar karşılaştırılmıştır. Sonuç olarak, ARIMA metodunun daha doğru tahminlerde bulunduğu, daha yüksek performans gösterdiği bulunmuştur.

Çuhadar vd. (2009), dış turizm talep tahmini çalışmasında, Hu (2002), iç turizm talep tahmini çalışmasında; diğer geleneksel metotlara nazaran yapay sinir ağları metodunun daha iyi tahminlerde bulunduğunu göstermişlerdir.

Lin vd. (2009), yeni geliştirdikleri bir istatistiksel model ile zaman serisi modelinin tahmin performanslarını karşılaştırmak için Tayland'daki medikal turizm talebi ve yabancı hastalardan elde edilecek gelirleri kullanmışlardır. Araştırma sonuçları göstermiştir ki, geliştirilen yeni model hata üretme olasılığı bakımından, zaman serisi analizi modelinden daha iyi performansa sahiptir.

Kaynar ve Taştan (2009), çalışmalarında Box-Jenkis modelleri ile ileri beslemeli yapay sinir ağlarının bir karşılaştırmasını yapmış ve veri seti olarak aylık ve günlük döviz (YTL/\$) kuru verilerini kullanmışlardır. Elde edilen sonuçlar Yapay sinir ağlarının finansal verilerin tahmininde kullanılabilecek başarılı bir yöntem olduğunu göstermiştir.

Polat ve Temurlenk (2011), çalışmalarında Yapay Sinir Ağlarının makroekonomik zaman serilerinin öngörü modellemesinde kullanımı amacıyla, İmalat Sanayi Üretim Endeksi verilerini kullanmışlardır. Yapay Sinir Ağları metodolojisi ile hesaplanan öngörü değerleri ve İmalat Sanayi Eğilimi sonuçlarının öngördüğü değerler, gerçekleşen değerler ile karşılaştırılmıştır. Karşılaştırma sonucunda Yapay Sinir Ağlarının daha iyi sonuçlar verdiği görülmüştür.

Dolgun vd. (2014), günlük TL bazlı altın kapanış fiyatlarını kullanarak, yapay sinir ağları ve zaman serileri analiz yöntemleri ile kısa vadeli tahminde bulunmuşlar ve yapay sinir ağlarının zamansal verilerin kullanıldığı diğer yöntemlere göre başarılı olduğunu görmüşlerdir.

Özden ve Öztürk (2018), çalışmalarında zaman serileri ve yapay sinir ağları olmak üzere iki farklı yaklaşım kullanılarak Türkiye'deki bir endüstri bölgesi için enerji ihtiyaç tahmini üzerinde çalışmış ve sonuçları test etmişlerdir. Elde edilen sonuçlara göre; zaman serileri yöntemi R değeri 0.93901, yapay sinir ağları yöntemi R değeri 0.9859 elde edilmiştir. Zaman serileri yöntemi veri kısıtlılığı sebebiyle yapay sinir ağlarına göre daha kötü bir tahmin gerçekleştirmiştir.

Bu çalışmada ise, yapay sinir ağı modellerinin farklı mimarileri ile verilerin yapısına uygun zaman serileri analizi yöntemlerinin geçmişe yönelik öngörü doğrulukları karşılaştırılmıştır. Gelecek yıllar için turizm talebini aylar itibariyle tahmin edilebilecek modeller elde edilmiş ve öngörü sonuçlarının değerlendirilmesi neticesinde yapay sinir ağlarının zaman serileri analizine göre öngörü doğruluğunun daha yüksek olduğu ve gerçek değerlere en yakın sonuçları üreten bir yöntem olduğu görülmüştür.

## **I. Araştırma Yöntemi**

### **A. Zaman Serileri Analizi**

Zaman serilerinin analizi, bir serinin özelliklerini özetler ve serinin göze çarpan yapısını ortaya koymaya çalışır. Zaman serileri analizinin ve modellemesinin temel amacı iki noktada özetlenebilir: (1) Tek bir seriye ait gözlemlerin dinamik veya zamana bağlı yapısını anlamaya çalışmak- tek değişkenli zaman serileri analizleri, (2) iki veya daha fazla seri arasında öncelleştirme, geciktirme ve geri-besleme ilişkilerini ortaya koymak çok değişkenli zaman serileri analizleridir (Sevüktekin, Nargeleçekenler, 2005, s.32).

### **1. Otoregressif Modeller ve Hareketli Ortalamalar Yöntemleri (Box-Jenkins Modelleri)**

Bu çalışmada da kullanılan tek değişkenli modellerde, incelenecek değişkenin açıklanması, serinin kendi geçmiş değerleri, cari ve geçmiş dönem rassal artıkların ağırlıklı toplamı kullanılarak yapılmakta ve bu durumda “tek değişkenli zaman serisi modelleme” söz konusu olmaktadır. Tek değişkenli zaman serileri için sık kullanılmayan birçok geleneksel yöntem vardır. Daha yaygın kullanılan ise Otoregressif Modeller ve Hareketli Ortalamalar Yöntemleri (Box-Jenkins Modelleri)dir.

Zaman serilerinin özelliklerini belirlemek ve ileriye görmek amacını taşıyan ARIMA(p,d,q) modellerinde temel yaklaşım, üzerinde durulan değişkenin bugünkü değerinin, geçmiş değerlerinin ağırlıklı toplamı ve rassal şokların bileşimi olduğudur. Serilerin

özelliklerinin belirlenebilmesi için sistematik ve rassal kısım olarak ayrıştırılması gerekir. Bu amaçla ARIMA modellerinin tahmini için Box ve Jenkins (1970) tarafından ortaya konulmuş olan “Box-Jenkins yaklaşımı” kullanılır (Akgül, 2003, s.3).

Gerçek hayatta karşılaştığımız ve çalıştığımız zaman serilerinin birçoğu zaman boyunca değişen belirli bir stokastik sürecin özelliklerini taşıdığından durağan dışıdır. Rassal yürüyüş süreci ise durağan olmayan bir süreçtir. Rassal yürüyüş sürecinin varyansının sonlu olduğu ve durağanlık koşullarının bozulduğu söylenebilir. Dolayısıyla rassal yürüyüş modeli birçok ekonomik modelin gerçekleşmesini tutarlı bir biçimde yansıtmasına rağmen, durağan olmayan bir zaman serisi sürecidir.

Birinci-derece otoregresif sürecin parametresi  $\phi=1$  olarak verildiğinde süreç

$$Y_t = Y_{t-1} + e_t \quad (1)$$

olur. Bu süreç rassal yürüyüş süreci olarak bilinir ve  $e_t$  bu sürecin otokorelasyonsuz rassal kalıntıları gösterir.

Durağan dışı zaman serilerini durağanlaştırmak için serinin bir veya daha fazla farkını alarak bir dönüştürme işlemi uygulanabilir. Böyle bir zaman serisi *entegre* süreç olarak adlandırılmaktadır. Entegre sürecin derecesini tanımlayan  $d$ , zaman serisinin durağanlaştırılması için alınması gereken fark sayısını belirtir. Örneğin bir  $Y_t$  durağan dışı serinin bir kere farkı alındığında

$$\Delta Y_t = Y_t - Y_{t-1} = Y'_t \quad (2)$$

olur. Burada  $Y'_t$  serisi durağan hale gelmiş ise entegre sürecin derecesi  $d=1$  olarak tanımlanır ve  $I(1)$  ile gösterilir.  $Y_t$  serisinin farkı alındıktan sonra  $Y'_t$  serisi hala durağan dışı olmaya devam ediyorsa  $Y'_t$ 'in bir kere veya  $Y_t$ 'in ardı ardına iki kere farkı

$$\begin{aligned} \Delta^2 Y_t &= \Delta(Y'_t) = Y'_t - Y'_{t-1} \\ &= (Y_t - Y_{t-1}) - (Y_{t-1} - Y_{t-2}) \\ &= Y_t - 2Y_{t-1} + Y_{t-2} \end{aligned}$$

veya

$$\Delta^2 Y_t = Y''_t \quad (3)$$

alınır. Burada  $Y''_t$  durağan ise entegre sürecin derecesi  $d=2$  olarak tanımlanır ve  $I(2)$  ile gösterilir. Buna göre denklem (2)

$$Y'_t = Y_t - Y_{t-1} = e_t \quad (4)$$

biçiminde ifade edildiğinde birinci dereceden bir entegre süreç olduğu söylenir ve bu haliyle zaman serisi durağandır. Rassal yürüyüş sürecinin mahiyetini tam olarak bildiğimizden rassal yürüyüş sürecini durağan bir süreç haline kolaylıkla dönüştürebiliriz.

Bir genel sonuç üretecek olursak eğer

$$W_t = \Delta^d Y_t \quad (5)$$

durağan bir seri ise  $Y_t$  d'inci dereceden homojen durağandır diyebiliriz.  $W_t$  gibi bir seriye sahip isek,  $W_t$ 'nin d kere toplamını almakla tekrar  $Y_t$ 'ye dönebiliriz. Dolayısıyla

$$Y_t = \Sigma^d W_t \quad (6)$$

yazabiliriz. Burada  $\Sigma$  toplam alma işlemcisidir.  $\Sigma$  toplam alma işlemcisi  $\Delta$ 'nın tersidir.

$$\Delta Y_t = Y_t - Y_{t-1} = (1-L)Y_t \text{ 'den } \Delta = 1-L \text{ 'dir.}$$

Bu eşitlikten  $\Sigma = \Delta^{-1} = (1-L)^{-1}$  yazabiliriz.

Durağan bir seri  $W_t$  üretebilmek için  $Y_t$  sürecinin farkı alındıktan sonra bir ARMA süreci gibi  $W_t$  ele alınabilir. Eğer  $W_t = \Delta^d Y_t$  ise ve  $W_t$  bir ARMA(p,q) süreci ise bu durumda  $Y_t$  (p,d,q)'uncu dereceden bir entegre otoregresif hareketli ortalama süreci veya basitçe ARIMA(p,d,q) olarak ifade edebiliriz. ARIMA(p,d,q) süreci

$$(1 - \phi_1 L - \phi_2 L^2 - \dots - \phi_p L^p) \Delta^d Y_t = \delta + e_t + \theta_1 e_{t-1} + \theta_2 e_{t-2} + \dots + \theta_q e_{t-q} \quad (7)$$

şeklinde gösterilebilir veya gecikme işlemcisi kullanılarak

$$\Phi(L) \Delta^d Y_t = \delta + \Theta(L) e_t \quad (8)$$

yazılabilir. Burada  $W_t = \Delta^d Y_t$  sürecin ortalaması

$$\mu_w = \frac{\delta}{1 - \phi_1 - \phi_2 - \dots - \phi_p} \quad (9)$$

ile tanımlanır.

Durağan seri  $W_t$  karma bir sürece sahip değil ise örneğin  $W_t$  eğer bir AR(p) süreci ise  $Y_t$  (p,d)'inci dereceden entegre otoregresif süreçtir ve ARI(p,d,0) ile gösterilir;  $W_t$  eğer bir MA(q) ise bu durumda  $Y_t$  (d,q)'uncu dereceden bir entegre hareketli ortalama sürecidir ve IMA(0,d,q) ile gösterilir (Sevüktekin, Nargeleşkenler, 2005, s.159-164).

## 2. Mevsimsel Box-Jenkins Modelleri

Zaman serilerinin çoğunun her yıl düzenli bir seyir izlediği gözlenmektedir. Düzenli aralıklarla meydana gelen değişiklikler, “*mevsimsel değişme*” veya “*mevsimsellik*” olarak adlandırılmaktadır.

Amaç öngörü olduğunda ve güçlü mevsim etkisi taşıyan verilerin öngörüsünün yapılması gerektiğinde, ya mevsimselliğin kontrol edilmesi ya da modellenmesi gerekmektedir.

Mevsimsel olmayan serilerde olduğu gibi mevsimsel seriler için de model oluşturmada başlangıç noktası durağanlık analizinin yapılmasıdır. Bunun nedeni ise mevsimsel modellerde de durağan serilerin gerekli olmasıdır.

Mevsimsellik özelliği taşıdığından durağan olmayan seriler için fark alma işlemi, aylık verilerde  $\Delta_{12}Y_t = Y_t - Y_{t-12}$  ve üçer aylık verilerde  $\Delta_4Y_t = Y_t - Y_{t-4}$  olacak şekilde yapılır. Yapılan fark alma işlemi sonucu elde edilen seriler ise “*mevsimsel olarak düzeltilmiş seriler*” olarak adlandırılmakta ve “*mevsimsel fark*”, gözlem değeri ile bir yıl önceki mevsime karşı gelen değeri arasındaki fark olarak ifade edilmektedir. Değişkenlerin logaritmik dönüşüme tabi seriler olarak kullanılmaları durumunda ise mevsimsel farklar, değişkenlerin büyüme oranlarının ölçüsü olarak kabul edilmektedir. Üçer aylık mevsim etkisi taşıyan, aynı zamanda trende sahip olduğu saptanan bir serinin  $\Delta Y_t = Y_t - Y_{t-1}$  olacak şekilde ilk farkı alındığında seride muhtemelen trend etkisi ortadan kalkacaktır. Ancak seride mevsimselliğin devam etmesi durumunda,

$$\Delta_4(Y_t - Y_{t-1}) = (Y_t - Y_{t-1}) - (Y_{t-4} - Y_{t-5}) = \Delta\Delta_4Y_t \quad (10)$$

olacak şekilde, yani ilk farkın mevsimsel farkı alınarak elde edilen yeni seride mevsim etkisinin de ortadan kalktığı görülecektir (Akgül, 2003, s.177-183).

### 3. Birim Kök Testleri

Rassal yürüyüş süreci durağan dışı bir zaman serisi örneğidir.

$$Y_t = \phi_1 Y_{t-1} + e_t \quad (11)$$

Denklem (11)'deki AR(1) süreci

$$Y_t - \phi_1 Y_{t-1} = e_t$$

veya

$$(1 - \phi_1 L)Y_t = e_t \quad (12)$$

gibi tanımlanabilir. Denklem (11) için karakteristik denklem  $1 - \phi_1 L = 0$ 'ın kökü mutlak değerce birim değerinden büyük olmalıdır ki seri durağan olsun. Denklem yalnızca tek bir köke sahiptir. Bu kök değeri  $L = 1/\phi_1$  olacaktır ve dolayısıyla durağanlık için  $-1 < \phi_1 < 1$  olması gerekecektir. Buna göre  $Y_t$ 'in durağanlık testi için hipotezler

$$H_0: |\phi_1| \geq 1 \quad (\text{durağan dışılık için})$$

$$H_1: |\phi_1| < 1 \quad (\text{durağanlık için})$$



olarak kurulmaktadır. Burada  $\phi_1 = 1$  olması durumunda, yani eğer  $H_0$  hipotezi doğru ise, denklem (11) durağan dışı olmasının yanında bir rassal yürüyüş süreci  $Y_t = Y_{t-1} + e_t$  olacaktır.  $\phi_1$ 'in bu birim değeri birim kök problemi olarak bilinmektedir. Başka bir ifade ile birim kök durağan dışılığı açıklamanın diğer bir yoludur.

Bir zaman serisinin durağan dışılığını belirlemek için kullanılan Standart Dickey-Fuller testi hata terimlerinin bağımsız ve aynı şekilde dağılımlarının varsayımı üzerine kurulmuştur. Hata terimi bazen farklı varyans şeklinde veya seri korelasyon şeklinde dağılmış olabildiğinden iki farklı yaklaşımla DF testi biraz değiştirilmiştir. Bunlardan biri parametrik yaklaşım olarak bilinen çoğaltılmış DF testidir (augmented DF test). İkincisi nonparametrik olan Phillips-Perron testidir (Kutlar, 2005, s.307-308).

## **B. Yapay Sinir Ağları**

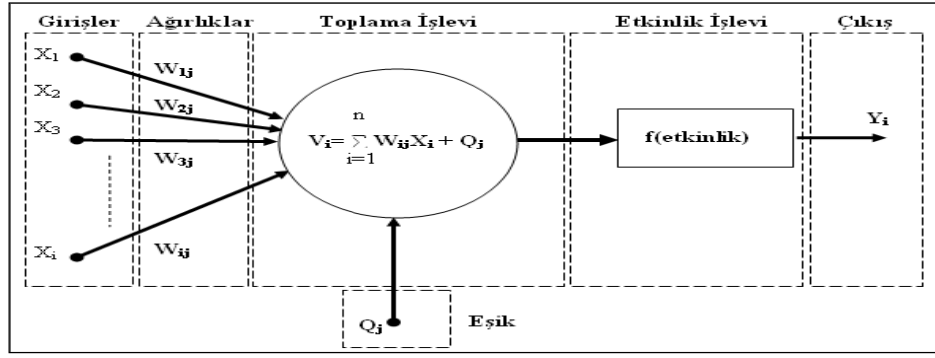
Genel olarak yapay sinir ağları (YSA), beynin bir işlevi nasıl gerçekleştirdiğini modellemek için tasarlanan bir sistem olarak tanımlanabilir.

YSA, bir sisteme ilişkin tek veya çoklu parametrelerle tanımlanan giriş verileri ile sistemin yine tek veya çoklu parametrelerle tanımlanabilen çıkışları arasında ilişki kurabilmektedir. Böylece, çıkış değerleri bilinmeyen tanımlanmış sistem girişlerine uygun çıkışlar üretebilir (Sağiroğlu vd., 2003, s.24).

Yapay sinir ağları, normal dağılıma uymayan, belirsiz, eksik bilgileri işleyebilen en güçlü problem çözme tekniğidir denilebilir (Öztemel, 2006, s.29-35).

### **1. Yapay Sinir Hücresi ve Elemanları**

Yapay sinir hücreleri yapısal olarak biyolojik sinir hücrelerine benzer. Yapay sinir ağlarını oluşturmak için yapay nöronlar da aralarında bağ kurarlar. Girdiler, Ağırlıklar, Toplama fonksiyonu, Aktivasyon fonksiyonu ve Çıktılar olmak üzere bir yapay sinir hücresi beş bölümden oluşmaktadır (<http://www.ahmetkakici.com/yapay-sinir-aglari/yapay-sinir-aglari-nin-mimarisi-ve-yapi-elemanlari/>, erişim tarihi: 14.03.2010).



Şekil 1. Yapay Bir Sinir (düğüm)

Kaynak (Elmas, 2007)

Bir yapay sinir ağı genelde birden fazla katmandan ve yapay sinir hücresinden oluşur. Genellikle ilk katman giriş katmanı son katman ise Çıkış katmanıdır. Aradaki diğer katmanlar ise gizli katman ya da ara katman olarak adlandırılırlar. Bir ağda birden fazla gizli katman olabilir (Freeman, Skapura, 1991).

## 2. Yapay Sinir Ağlarının Sınıflandırılması

Genelde YSA'lar, birbirleri ile bağlantılı işlemci birimlerden veya nöronlardan (neurons) oluşurlar. Nöronlar arasındaki bağlantılar ağın yapısını belirler. Öğrenme algoritması istenilen hedefe ulaşmak için bağlantı ağırlıklarının nasıl değiştirileceğini belirler. Kullanılan öğrenme kuralı, ağın ağırlıklarını hatayı minimize edecek şekilde günceller. YSA'lar yapılarına ve öğrenme algoritmalarına göre ileri beslemeli (feedforward) ve geri beslemeli (feedback) ağlar şeklinde sınıflandırılırlar. (Sağiroğlu vd., 2003, s.42-43). Eldeki veri ile ağın çıktısı arasındaki farka dayalı olarak ağırlıkların güncellenmesini gerçekleştiren Geri Yayılım algoritması en yaygın kullanılan öğrenme algoritmasıdır. Geri yayılım algoritmasında kullanılan öğrenme parametresi optimal sonuca yaklaşılmada önemli rol oynar (Erilli, vd., 2010).

## 3. Yapay Sinir Ağlarında Öğrenme Kuralları

Yapay sinir ağlarının mimarisi gibi ağın eğitilmesinde yani ağın öğrenmesinde kullanılacak yöntem de çok önemlidir.

Eğitim sırasındaki amaç bulunması gereken doğru sonuçlara en yakın çıktıyı üretebilmektir. Çıktı ile hedef değerler arasındaki fark *hatadır*. Ağ bu hatayı kabul edilebilir sınırlar arasına indirebilmek için işlemi sürekli olarak tekrarlar (Keleşoğlu vd., 2005).

## II. Uygulama


### A. Zaman Serisi Analizi İle Türkiye'ye Gelen Turist Sayısının Tahmini

Uygulamada, turizm talebinin ölçüsü olarak geçmiş yıllarda ülkemize gelmiş aylık bazda toplam turist sayılarından yararlanılmıştır. Bu veriler Kültür ve Turizm Bakanlığında elde edilen 1984–2008 dönemlerine ait aylık verilerdir. Turist sayısı ile ilgili yapılan modellemelerde zaman serisi tekniklerinden olan ARMA veya ARIMA modelleri kullanılmaktadır. Buradaki testler ve modellemelerde E-Views 7 bilgisayar paket programı kullanılmıştır. Aşağıda bu serinin kısaltılmış hali ve adı verilmektedir.

**TURK:** Türkiye'ye gelen toplam turist sayısının aylık değerleri

**DTURK:** Türkiye'ye gelen toplam turist sayısı serisinin farkı alınmış hali ( $TURK_t - TURK_{t-1}$ )

Aşağıdaki Şekil 2 TURK serisinin 1984–2008 yılları arasındaki aylık veri setini göstermektedir. Serinin mevsimsel etki taşıdığı ve artan bir nitelikte olduğu görülmektedir. Serinin birinci farkı alınmış durumu ise Şekil 3'de gösterilmektedir.



Şekil 2. TURK Serisi

Şekil 3. DTURK Serisi

TURK serisinin durağanlığını gösteren Tablo 1 ise farklı bir açıklamaya yer vermektedir. Augmented Dickey-Fuller ve Phillips-Perron testi sonuçları yer almaktadır. Tablodaki değerlerin nasıl okunacağı alttaki bilgidan anlaşılmaktadır. Tabloda %1, %5 ve %10 için MacKinnon kritik değerleri verilmektedir. Yine tabloda serinin normal ve birinci farkı alınmış değerlerinde birim kökün olup olmadığı ele alınmıştır. Tabloda t değeri birim kök için bilgisayar programınca otomatik seçilmiş gecikme değerini vermektedir. Tabloda görüleceği gibi, TURK serisinin Augmented Dickey-Fuller testine göre normal serinin birim kök ihtiva ettiği ve durağan olmadığı, farkı alınmış serinin ise durağan olduğu görülmektedir.

Tablo 1'de verilen ADF testi sonucuna göre,  $\tau$  istatistiği olan 1,39 Mac Kinnon kritik değerinden (-3,45; -2,87; -2,57) daha büyük olduğundan TURK serisi için birim kökün olduğu hipotezi reddedilemez. Yani seri durağan değildir. Birinci farkı alınmış serinin ise  $\tau$  istatistiği

olan -4,65 tüm önem seviyelerinde Mac Kinnon kritik değerinden küçük olduğundan birim kökün olduğu hipotezi reddedilerek, DTURK serisinin birinci dereceden durağan olduğu sonucuna varılır.

Benzer şekilde Phillips-Perron testine göre de normal serinin %1 ve %5 anlamlık düzeylerinde kritik değerleri -3,45 ve -2,87 normal serinin test istatistiği olan -2,80'den küçük olduğundan durağan olmadığı görülürken, serinin birinci farkının test istatistiği olan -8,32 tüm önem seviyelerindeki kritik değerlerden küçük olduğundan durağan olduğu yine Tablo 1'de görülmektedir. O halde ARMA(p,q) tahmini için serinin durağan hale getirilmesi gerekmektedir.

**Tablo 1. Birim Kök Testi**

Seri	ADF test istatistiği		t	PP test istatistiği	
	Normal	Birinci Fark		Normal	Birinci Fark
TURK	1.395896	-4.654118***	12	-2.799522*	-8.324013***

\*\*\* %1; \*\* %5 ve \* %10 anlamlılık düzeyini göstermektedir.

Tablo 2'de ARIMA(p,d,q) serisi şeklinde modellenmiştir. d değeri serinin farkının mertebesini göstermektedir.

**Tablo 2. DTURK Tahmini**


Bağımlı değişken: DTURK				
Değişken	Katsayı	Standart Hata	t-istatistiği	p
AR(1)	-0.260805	0.057615	-4.526653	0.0000
SAR(12)	1.102078	0.007505	146.8498	0.0000
MA(4)	-0.141560	0.058832	-2.406194	0.0167
SMA(12)	-0.640177	0.050369	-12.70978	0.0000
R <sup>2</sup>	0.922170	Mean dependent var		3751.789
Düzeltilmiş R <sup>2</sup>	0.921376	S.D. dependent var		322301.7
Regresyon std. hatası	90373.41	Akaike bilgi kriteri		25.67462
HKO	2.40E+12	Schwarz kriteri		25.72425
Log likelihood	-3821.518	Durbin-Watson istatistiği		1.998237

LS(DERIV=AA) DTURK AR(1) SAR(12) MA(4) SMA(12)

Tablo 2'den tahmin denkleminde bakıldığında modelin bir gecikmeli otoregresif (AR) değişkeni ve dört gecikmeli hareketli ortalama (MA) değişkeni yer almaktadır. Hem otoregresif hemde hareketli ortalama dmevsimsel değişkenlerinin 12 gecikme için anlamlı olarak modelde yer aldıkları gözlemlenmektedir. Modelin tüm tahmin değişkenleri, MA (%5) hariç diğerleri %1 anlamlılık düzeyinde anlamlı görülmektedir. Modelin bir başka ifadesi;

DTURK=0+[AR(1)=-0.2608047052,SAR(12)=1.10207771,MA(4)=-0.1415602099, SMA(12)=-0.6401772819,BACKCAST=1984M01] şeklindedir.


Şekil 4 DTURK serisinin tahmini sonucu kalıntı değerler, gerçek ve tahmin değerlerine yer vermektedir.



Şekil 4. DTURK Serisinin Kalıntı, Gerçek ve Tahmin Grafiği

Şekil 4'ten modele ait kalıntılar arasındaki otokorelasyonun önemli olmadığını kalıntı serisinin rassal bir süreçte sahip olduğunu ve seçilen modelin uygun olduğunu anlamak mümkündür.

Şekil 5 ise durağan hale getirilmiş Türkiye verilerinin 12 aylık öngörüsü yapılmaktadır. Serilerin öngöründe mevsimsel etkisi görülmektedir.



Şekil 5. DTURK Serisinin Öngörüsü

## B. Yapay Sinir Ağları İle Türkiye'ye Gelen Turist Sayısının Tahmini

Burada da zaman serileri analizinde kullanılan verilerden yararlanılarak yapay sinir ağları ile modeller kurulmuştur.

Uygulamada kullanılan yapay sinir ağı modeli ileri beslemeli geri yayılım yapay sinir ağıdır. Öğretmenli öğrenme kuralını kullanan İleri Beslemeli Geri Yayılım yapay sinir ağının tercih edilmesinin sebebi, öngörü çalışmalarında en çok kullanılan yöntem olması ve hem doğrusal hem de doğrusal olmayan yapıların modellenmesinde gösterdiği öngörü başarısıdır. Ayrıca kullanım kolaylığı da diğer bir tercih sebebidir. Bu çalışma MATLAB 7.9.0.(R2009b) uygulama programında yapılan bir kodlama üzerinde gerçekleştirilmiştir.

### 1. Aralık Sayısının Belirlenmesi

Burada öncelikle eldeki veriler kullanılarak t+1 anındaki verilerin tahmini için kaç ay öncesine ait verilere ihtiyaç olduğu belirlenmiştir.


Model olarak giriş, çıkış ve bir tek gizli tabaka içeren 3 tabakalı YSA kullanılmıştır. İlk olarak aralık sayısı (L) 1 alınmış ve t+1 anındaki verilerin öngörülmesi için t=0 anındaki veriler kullanılmıştır. Giriş verileri olarak t=0, çıkış verileri olarak da t+1 anındaki veriler bulunarak model eğitilmiştir. Aynı işlem L= 2, 3,...,13 için tekrarlanmıştır. Tablo 3 yapılan bu işlemleri göstermektedir.

Bu denemelerde modelin başarısını gözlemlemek için MSE, Deneme Sayısı ve R<sup>2</sup> değerleri not edilmiştir. Burada MSE değerinin 0 noktasına, R<sup>2</sup> değerinin ise 1 noktasına yakınsaması önemsenmektedir. Daha az deneme sayısında MSE ve R<sup>2</sup> için daha iyi sonuç elde edilen model ise eğitimin hızlı olması açısından önemsenir.

**Tablo 3. Gelecek Dönem Verilerinin Tahmini İçin Kaç Dönem Öncesinin Verilerine İhtiyaç Olduğunun Belirlenmesi**


Model	Deneme Sayısı	MSE	R <sup>2</sup>
[1,20,1]	70	0,2068	0,962322
[2,20,1]	52	0,33873	0,773995
[3,20,1]	57	0,19562	0,981922
[4,20,1]	54	0,097602	0,955272
[5,20,1]	56	0,11807	0,988294
[6,20,1]	55	0,19278	0,886705
[7,20,1]	52	0,070929	0,990324
<b>[8,20,1]</b>	<b>79</b>	<b>0,028235</b>	<b>0,991996</b>
[9,20,1]	60	0,15746	0,957521
[10,20,1]	53	0,13937	0,934393

[11,20,1]	57	0,19207	0,947877
[12,20,1]	55	0,22632	0,822123




Şekil 6. Eğitim Verilerine Ait Grafik

$$R^2 = 0,9920$$




Şekil 7. Test Verilerine Ait Grafik

$$R^2 = 0,8283$$



Şekil 8. Modele Ait Eğitim, Test ve Doğrulama Değerleri Performans Grafiği



Şekil 9. Aralık Sayısı ile MSE'nin Değişimi

Şekil 9'da görüldüğü gibi 8'inci aralığa ulaşıldığında hata kareler ortalaması en düşük değere ulaşmakta ve daha sonraki aralık sayılarında artmaya devam etmektedir. Hata kareler ortalamasının 8'inci aralıkta en düşük değere sahip olmasından elde edilen sonuç, t+1 ayında Türkiye'ye gelen turist sayısını tahmin edebilmek için 8 ay öncesine ait olan değerlerin her birinin tahmin için kullanılması gerektiğidir.

## 2. Öğrenme Oranının ve Gizli Katmandaki Sinir Sayısının Ağ Üzerindeki Etkisinin Belirlenmesi

Öğrenme oranı ağ performansı üzerinde önemli bir etkiye sahiptir. Öğrenme oranı (katsayısı) ağırlıkların değişim miktarını belirlemektedir (Öztemel, 2006, s.99).


Gizli katmandaki sinir sayılarının artırılması simülasyon sırasında hem hafıza hem de CPU'nun yükünü artırmaktadır. Fakat öğrenme işlemi daha hassas tamamlanmaktadır. Gizli

katman sinir sayısının az miktarda alınması ağın hatırlama yeteneğini olumsuz yönde etkilemektedir (Elmas, 2007, s.131).


Belirlenen tek katmanlı model üzerinde her defasında gizli katmandaki nöron sayısını ve öğrenme oranını değiştirilerek model yeniden çalıştırılmış ve Tablo 4'teki sonuçlar elde edilmiştir.

**Tablo 4. Tek Katmanlı Eğitim Algoritması Sonuçları**

Model	Öğrenme Oranı	Deneme Sayısı	MSE	R <sup>2</sup>
[8,5,1]	0,01	66	0,104	0,987698
[8,10,1]	0,01	56	0,053932	0,973952
[8,20,1]	0,01	54	0,039865	0,991877
[8,30,1]	0,01	57	0,11374	0,981189
[8,5,1]	0,05	62	0,0481	0,987241
[8,10,1]	0,05	56	0,095262	0,924559
[8,20,1]	0,05	56	0,059561	0,988553
[8,30,1]	0,05	53	0,13381	0,958343
[8,5,1]	0,1	62	0,62722	0,987161
[8,10,1]	0,1	59	0,043991	0,989468
[8,20,1]	0,1	55	0,14843	0,910364
[8,30,1]	0,1	58	0,082223	0,992255
[8,5,1]	0,5	56	0,053107	0,973577
<b>[8,10,1]</b>	<b>0,5</b>	<b>68</b>	<b>0,029519</b>	<b>0,995166</b>
[8,20,1]	0,5	55	0,050292	0,991259
[8,30,1]	0,5	58	0,13412	0,990045




Şekil 10. Eğitim Verilerine Ait Grafik



Şekil 11. Test Verilerine Ait Grafik

$$R^2 = 0,9952$$

$$R^2 = 0,9323$$





Şekil 12. Tek Katmanlı Modele Ait Eğitim, Test ve Doğrulama Değerleri Performans Grafiği



İki katmanlı modelde öğrenme oranını ve gizli katmanlardaki nöron sayılarını değiştirilerek elde edilen sonuçlar Tablo 5’te özet olarak verilmiştir.

**Tablo 5. İki Katmanlı Eğitim Algoritması Sonuçları**

Model	Öğrenme Oranı	Deneme Sayısı	MSE	R <sup>2</sup>
[8,5,5,1]	0,01	55	0,03783	0,976519
[8,5,10,1]	0,01	58	0,06321	0,986148
[8,5,20,1]	0,01	57	0,052095	0,8855
[8,5,30,1]	0,01	56	0,053035	0,972334
[8,5,30,1]	0,5	54	0,060693	0,943871
[8,10,5,1]	0,5	58	0,043968	0,980516
<b>[8,10,10,1]</b>	<b>0,5</b>	<b>71</b>	<b>0,019435</b>	<b>0,99642</b>
[8,10,20,1]	0,5	57	0,1081	0,973518
[8,10,30,1]	0,5	57	0,058732	0,935108
[8,20,5,1]	0,5	59	0,17029	0,894386
[8,20,10,1]	0,5	61	0,12795	0,859014
[8,20,20,1]	0,5	53	0,10449	0,925175
[8,20,30,1]	0,5	54	0,039138	0,906913
[8,30,5,1]	0,5	59	0,1222	0,987241
[8,30,10,1]	0,5	60	0,13957	0,989766
[8,30,20,1]	0,5	55	0,091843	0,981328
[8,30,30,1]	0,5	61	0,10139	0,970796





Şekil 13. Eğitim Verilerine Ait Grafik

Şekil 14. Test Verilerine Ait Grafik

$$R^2 = 0,9011$$

$$R^2 = 0,9964$$




Şekil 15. Doğrulama Verilerine Ait Grafik

Şekil 16. Tüm Verilerine Ait Grafik

$$R^2 = 0,9693$$

$$R^2 = 0,9844$$



Şekil 17. İki Katmanlı Modele Ait Eğitim, Test ve Doğrulama Değerleri Performans Grafiği

### 3. Momentum Teriminin Ağ Üzerindeki Etkisinin Belirlenmesi

Hesaplamalara momentum teriminin ilave edilmesinin ağ performansı üzerinde etkili olduğu gözlenmiştir. Momentum teriminin hesaplama katmanına katılması adım sayısında ve toplam ağ hatasında bir düşüş meydana getirmektedir (Elmas, 2007, s. 131).

Momentum katsayısı bir önceki iterasyondaki değişimin belirli bir oranının yeni değişim miktarına eklenmesi olarak görülmektedir.

Tek ve iki katmanlı ağlar üzerinde yapılan denemeler sonucunda tek katmanlı; [8,10,1], iki katmanlı; [8,10,10,1] modelinin en uygun modeller olduğuna karar verilerek bu modeller üzerinde farklı momentum terimleri denenmiş ve sonuçlar Tablo 6'da ve 7'de verilmiştir.

**Tablo 6. Tek Katmanlı Eğitim Algoritması Sonuçları**

Model	Öğrenme Oranı	Momentum Terimi	Devir	MSE	R <sup>2</sup>
[8,10,1]	0,5	0,1	68	0,029519	0,99036
[8,10,1]	0,5	0,5	57	0,53098	0,97757
[8,10,1]	0,5	0,6	57	0,039362	0,98750
[8,10,1]	0,5	0,8	60	0,40336	0,98800
[8,10,1]	0,5	0,9	57	0,40497	0,98283

**Tablo 7. İki Katmanlı Eğitim Algoritması Sonuçları**

Model	Öğrenme Oranı	Momentum Terimi	Devir	MSE	R <sup>2</sup>
[8,10,10,1]	0,5	0,1	71	0,019435	0,99642
[8,10,10,1]	0,5	0,5	55	0,04413	0,98161
[8,10,10,1]	0,5	0,6	55	0,036958	0,98907
[8,10,10,1]	0,5	0,8	59	0,041417	0,97127
[8,10,10,1]	0,5	0,9	55	0,030105	0,98188

Yukarıdaki tablolar incelenerek final modelin iki katmanlı [8,10,10,1], öğrenme oranı 0,5 ve momentum terimi 0,1 olan model olduğuna karar verilmiştir.

### **Sonuç ve Öneriler**

Turizm dünyada en hızlı gelişen ve büyüyen sektörlerin başında yer almaktadır. Bugün dünya gayrisafi hâsılasının önemli bölümünü oluşturan turizm sektörü tüm dünyadaki ekonomik duraklamaya karşın büyümesini devam ettirmekte ve diğer sektörlerin de motor gücü olarak işlev görmektedir. Turizm, milli gelire olan katkısı yanında, sağladığı döviz geliri ile ödemeler dengesi açığının kapanmasında da önemli rol oynamaktadır. Geniş kitlelere iş imkânı sağlamanın bir sonucu olarak istihdamın en yoğun olduğu sektörlerden biri olma avantajına sahip olan sektör, aynı zamanda ülke için etkin bir pazarlama ve reklam aracı olma özelliğini de sürdürmektedir.

Turizm talebi tahmininde kullanılacak yöntemlerden biri olan zaman serileri analizi, bir olaya ait geçmişteki verilerin incelenmesi ve belirli eğilimlerin ortaya çıkarılarak ileriye yönelik öngörü modellerine göre tahminlerin yapılması temeline dayanmaktadır. Bu yöntemin amacı, geçmiş gözlem değerlerindeki veri kalıplarını kullanarak istatistiksel modeller oluşturmak ve bu modellerle geleceği tahmin etmektir.

Zaman serisi yöntemlerinden Box-Jenkins yöntemi, tek değişkenli zaman serilerinin ileriye dönük tahmininde güvenilir tahmin sonuçları veren yaygın uygulama alanı bulunan Otoresyasyon ve Hareketli Ortalama yöntemlerinin bir kombinasyonu oluşturulmaya çalışılan bir yöntemdir.

Bu çalışmada 1984-2009 yılları arasında Türkiye'ye gelen aylık turist sayısı verileri kullanılarak zaman serisi yöntemlerinden "Box-Jenkins (ARIMA)" yöntemi ile kurulan ve  $R^2$  değeri 0,9222 bulunan model,

$$DTURK=0+[AR(1)=-0.2608047052,SAR(12)=1.10207771,MA(4)=-0.1415602099, SMA(12)=-0.6401772819,BACKCAST=1984M01]$$

şeklindedir.

Geçmişteki tecrübeler doğrultusunda eğitime, öğrenme ve genelleme gibi yetenekleri taklit eden yapay sinir ağları, karmaşık ve yapısı belli olmayan problemlerin çözümü için geliştirilerek kullanılmıştır. İnsan beynindeki nöron modellemesini temel alan yapay sinir ağları, veri analizinde yaygın olarak kullanılmaktadır (Yüksek, 2007).

Zaman serilerinin yapay sinir ağları ile tahmin edilmesinde geriye yayılım algoritması en çok kullanılan yöntemdir. Geriye yayılım algoritması ile eğitilen ağlar öğretmenli öğrenme gerçekleştiren, ileri beslemeli bir YSA'dır. Bunun nedeni geri yayılım algoritması ile oluşturulan ağların doğrusal olmayan modellere uygunluk göstermesi ve bu ağlarda kullanılan öğrenme algoritmasının denetimli olmasıdır.

Yapay sinir ağı modellerinden, Geri Yayılma Algoritmasının eğitilmesi; modelin içerisinde var olan parametrelerin iteratif yöntemle değiştirilerek en uygun değerlerin bulunması ile ağırlık vektörünün oluşturulması şeklindedir (Yüksek, 2007).

Turizm verilerimizi kullanarak yapay sinir ağlarını geri yayılma algoritması ile eğitmemiz sonucunda oluşturulan modele göre;

Türkiye'ye gelen aylık turist sayısı verileri için üretilen  $R^2$  değerleri; eğitim verilerinde 0,9964, test verilerinde 0,9011, doğrulama verilerinde 0,9844 ve tüm verilerde 0,9693 bulunmuştur.

İki yöntemin karşılaştırılması için yapılan analizlerin sonuçları incelendiğinde YSA ile elde edilen  $R^2$  değerleri, zaman serisi ile elde edilen  $R^2$  değerlerinden oldukça yüksektir. Buna göre yapay sinir ağları ile zaman serileri analizine göre çok daha başarılı sonuçlar elde edilmiştir.

Diğer klasik istatistiksel yöntemlerde olduğu gibi stokastik süreçlerde de teoriden gelen, durağan olma, hataların normal dağılımlı olması ve bünyelerinde periyodiklik olmaması gibi kabulleri vardır (Şen, 2004, 32).

Yapay sinir ağları ise hiçbir temel varsayıma ve veri dağılımı hakkında bir ön bilgiye gerek duymadan başarılı sonuçlar üretmektedir. Bu eğitim algoritmaları klasik programlama algoritmalarına göre daha esnektir. Veri setinin doğrusal olup olmaması ile ilgili yapılar bu algoritmaları etkilemez. Veri seti içerisinde çeşitli sebepler dolayısıyla oluşan verilerdeki eksik değerler bile tolere edilebilir. Yapay sinir ağları algoritmaları, klasik istatistiksel yöntemler kadar kuralcı değildir. Bu algoritmalarındaki birçok fonksiyon ve bu fonksiyonlara ait parametreler değiştirilebilir.

İstatistiksel yöntemler çözüme ilişkin anlaşılır parametreler üretirken, yapay sinir ağlarında bağlantı ağırlıklarını yorumlama imkânı bulunamadığından elde edilen sonuçlarda modelin bir kapalı kutu olarak kaldığı göz ardı edilmemelidir. Yapay sinir ağlarının daha iyi sonuçlar vermesi nedeniyle, geleneksel yöntemlere alternatif olarak kullanılabilmesi söylenebilir.

Yapılan bu çalışmada belirlenen modelin yapacağı tahminler ile hazırlanan turistik gelişme planları için temel oluşturmak, turizm işletmecilerinin planlama yapmalarına ve karar almalarına yardımcı olmak ve Türkiye turizm literatürüne katkı sağlamak, amaçlanmaktadır.

### Kaynaklar

- Akgül I., 2003 “Zaman Serilerinin Analizi ve ARIMA Modelleri”, Der Yayınları, İstanbul.
- Aygören, H., Sarıtaş, H., Moralı, T. (2012), İMKB 100 Endeksinin Yapay Sinir Ağları ve Newton Nümerik Arama Modelleri ile Tahmini, Uluslararası Alanya İşletme Fakültesi Dergisi, C:4, S:1, s.73-88.
- Chen, Jui-Chi (2000). *Forecasting Method Applications to Recreation and Tourism Demand*, Doktora Tezi, North Carolina State University, USA.
- Çuhadar, M., Güngör, İ., Göksu, A. (2009). Turizm Talebinin Yapay Sinir Ağları İle Tahmini Ve Zaman Serisi Yöntemleri İle Karşılaştırmalı Analizi: Antalya İline Yönelik Bir Uygulama. Süleyman Demirel Üniversitesi, İktisadi ve İdari Bilimler Fakültesi Dergisi, C.14, S.1 s.99-114.
- Dolgun, Ö., Saraçbaşı, O., Yeniler, A. (2014), Zaman Serisi Verilerinin Yapay Sinir Ağları Yaklaşımı İle Çözümlemesi: Altın Fiyatının Tahmini, Conference: XVI. Ulusal Biyoistatistik Kongresi, Antalya, Türkiye.
- Elmas Ç., “Yapay Zeka Uygulamaları- Yapay Zeka, Bulanık Mantık, Genetik Algoritma”, (2007). Seçkin Yayınevi, Ankara.
- Erilli, N.A., Eğrioğlu, E., Yolcu, U., Aladağ, Ç.H., Uslu, V.R. (2010), Türkiye’de Enflasyonun İleri ve Geri Beslemeli Yapay Sinir Ağlarının Melez Yaklaşımı ile Öngörüsü, Doğu Üniversitesi Dergisi, Cilt:11, Sayı:1, s. 42-55.
- Freeman J., Skapura D., (1991). “Neural Network Algorithms, Applications and Programming techniques”, Addison-wesley publishing Company.
- Kaynar, O., Taştan, S.,(2009). Zaman Serisi Analizinde MLP Yapay Sinir Ağları Ve Arıma Modellerinin Karşılaştırılması. Erciyes Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi, Sayı: 33, s.161-172.
- Kutlar A. (2005), “Uygulamalı Ekonometri”, Nobel Yayın Dağıtım, Ankara.
- Keleşoğlu, Ö., Ekinci, C.E., Fırat, A., (2005). “The Using Artificial Neural Network in Insulation Computations”, Journal of Engineering and Natural Sciences.

- Lın Chin-Tsai, Lee In-Fun And Huang Ya-Ling (2009). Forecasting Thailand's medical tourism demand and revenue from foreign patients, *The Journal of Grey System*, 369-376.
- Neter, J., Wasserman, W., Kutner, M.H., (1989). *Applied Linear Regression Models*, Irwin, Homewood, IL.
- Öztemel, Ercan., (2006). “Yapay Sinir Ağları”, İstanbul: Papatya Yayıncılık.
- Özden, S., Öztürk A.,(2018). Yapay Sinir Ağları ve Zaman Serileri Yöntemi ile Bir Endüstri Alanının (İvedik OSB) Elektrik Enerjisi İhtiyaç Tahmini çalışmalarında, *Bilişim Teknolojileri Dergisi*, Cilt: 11, Sayı: 3, s.255-261.
- Polat, Ö., Temurlenk, S., (2011). Yapay Sinir Ağları Metodolojisi İle Makroekonomik Zaman Serilerinde Öngörü Modellemesi, *Dicle Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi* Yıl:1, C:1 S:2, (98-106).
- Sağiroğlu, Ş., Beşdok, E., Eler, M., (2003). “Mühendislikte Yapay Zeka Uygulamaları- I Yapay Sinir Ağları”, *Ufuk Yayıncılık*.
- Sevüktekin M., Nargeleçen M., (2005). “Zaman Serileri Analizi”, Nobel Yayın Dağıtım, Ankara.
- Şen, Zekai., (2004). “Yapay Sinir Ağları İlkeleri”, İstanbul: Su vakfı Yayınları.
- Yüksek, A.Gürkan., (2007). “Hava Kirliliği Tahmininde Çoklu Regresyon Analizi ve Yapay Sinir Ağları Yönteminin Karşılaştırılması”, Sivas Cumhuriyet Üniversitesi, Yayınlanmamış Doktora Tezi, Sosyal Bilimler Enstitüsü, Sivas.
- İnternet Kaynağı: <http://www.ahmetkakici.com/yapay-sinir-aglari/yapay-sinir-aglarinin-mimarisi-ve-yapi-elemanlari/>, erişim tarihi: 14.03.2010