

**TÜRKİYE'YE YÖNELİK DIŞ TURİZM TALEBİNİN MLP, RBF VE TDNN YAPAY SİNİR AĞI
MİMARİLERİ İLE MODELLENMESİ VE TAHMİNİ: KARŞILAŞTIRMALI BİR ANALİZ**

**MODELING AND FORECASTING INBOUND TOURISM DEMAND TO TURKEY BY MLP, RBF AND TDNN
ARTIFICIAL NEURAL NETWORKS: A COMPARATIVE ANALYSIS**

Murat ÇUHADAR¹

ÖZET

Turizm talebi tahminleri, kamu ve özel sektör temsilcilerinin ileriye yönelik planlama çalışmalarında önemli rol oynamaktadır. Bu çalışmanın amacı; Türkiye'ye yönelik aylık dış turizm talebinin, Çok Katmanlı İleri Beslemeli (MLP), Radyal Tabanlı Fonksiyon (RBF) ve Zaman Gecikmeli (TDNN) yapay sinir ağı mimarileri ile modellenmesi ve en yüksek tahmin performansı sağlayan model yardımıyla 2013 yılı tahminlerinin üretilmesidir. Çalışmada Türkiye'ye yönelik dış turizm talebinin ölçüsü olarak gelen toplam yabancı turist sayıları alınmış, Ocak 1987 – Aralık 2012 dönemine ait Türkiye'ye gelen aylık yabancı turist sayısı verilerinden yararlanılmıştır. Verilerin yapay sinir ağları ile modellenmesinde, literatürdeki farklı görüşler dikkate alınarak orijinal seri ve mevsimsel ayrıştırma yöntemi ile elde edilen mevsimsel etkilerden arındırılmış seri olmak üzere iki ayrı veri seti kullanılarak oluşturulan farklı yapay sinir ağı mimarilerinin tahmin performansları incelenmiştir. Yapılan çok sayıda deneme sonucunda on iki gecikmeli veri değerleri kullanılarak geliştirilen [4-5-1] mimarisine

¹ Yrd. Doç. Dr. Süleyman Demirel Üniversitesi, Eğirdir MYO Turizm ve Otelcilik Bölümü, muratcuhadar@sdu.edu.tr.

sahip MLP modelinin en yüksek doğruluğu sağladığı görülmüş, bu model yardımıyla 2013 yılı için Türkiye'ye yönelik aylık dış turizm talebi tahminleri üretilmiştir.

Anahtar Kelimeler: *MLP, RBF, TDNN, Yapay Sinir Ağları, Turizm Talebi Tahmini*

ABSTRACT

Tourism demand forecasting plays important role in public and private sector officials' future planning activities. The aim of this study is modeling inbound tourism demand to Turkey by Feed Forward-Back Propagation (MLP), Radial Basis Function (RBF) and Time Delay (TDNN) artificial neural network architectures and forecasting monthly tourism demand for 2013 via the model providing the highest accuracy. In this study, it is used the total number of foreign tourist arrivals as a measure of inbound tourism demand and monthly foreign tourist arrivals to Turkey in the period of January 1987 – December 2012 were utilized. In the process of modeling the data by ANN's, it is analyzed the forecasting performance of different network architectures constituted by both unprocessed raw data and seasonally adjusted data taking into account of the distinct viewpoints in related studies. As a consequence of several attempts, it has been observed that 12 lagged MLP model which has [4-5-1-] architecture has presented best forecasting performance. By this model it has been produced monthly inbound tourism demand forecasts to Turkey for year 2013.

Key Words: *MLP, RBF, TDNN, Artificial Neural Networks, Tourism Demand Forecasting*

GİRİŞ

Türkiye, tarihi, kültürel ve doğal turizm arz verileri, misafirperverlik geleneği, ılıman iklimi, eşsiz tarihi mekânları, arkeolojik ören yerleri ve gelişmiş altyapısıyla uluslar arası turizmde adından söz ettiren bir ülkedir. Uygarlıklar beşiği olarak bilinen Türkiye, zengin bir tarihî miras ile birlikte, doğal güzelliklerinde sergilendiği bir açık hava müzesi görünümündedir. Sahip olduğu turizm çekicilikleri Türkiye'yi dünyanın en çok tercih edilen turizm destinasyonlarından biri haline getirmiştir. 2012 yılında Türkiye'ye gelen turist sayısı önceki yıla göre %1,04 artış göstererek 31.782.832 kişi olmuştur (Kültür ve Turizm Bakanlığı Sınır Giriş-Çıkış İstatistikleri, 2013: 2). Türkiye İstatistik Kurumu'nun (TÜİK) yayınlamış olduğu istatistiklere göre ise, 2011 yılında 23 milyar 20 milyon 392 bin dolar olan turizm gelirleri, 2012 yılında %1,8 oranında artarak 23 milyar 440 milyon 436 bin dolara (revize edilmiş haliyle 29 milyon 351 bin dolara) yükselmiştir (TÜİK, 2013: 1). Türkiye'de karşılaştırmalı rekabet üstünlüğünün bulunduğu sektörler arasında yer alan turizmin sahip olduğu üstünlükler ve gelişim potansiyeli ile gelecekte daha önemli bir konuma ulaşacağı beklenmektedir. Özellikle Türkiye ekonomisine önemli döviz kaynağı sağlayan turizm, yeni istihdam olanakları yaratmasıyla işsizliğin azaltılmasında, ödemeler dengesinin iyileştirilmesinde önemli bir yere sahiptir (Oskay, 2012: 187). Türkiye'de turizm sektörü, yarattığı doğrudan ve dolaylı etkilerle özel bir önem kazanmış ve ekonominin lokomotif sektörlerinden birisi durumuna gelmiştir. Turizmin ekonomik etkileri ülkemiz açısından değerlendirildiğinde; milli gelire olan katkısının yanında, sağladığı döviz gelirleri ile ödemeler dengesi açığının kapanmasında önemli rol oynayan, geniş kitlelere iş imkânı sağlayarak işsizliğin azaltılmasına katkıda bulunan bir sektör konumuna geldiği görülmektedir. Dünya Seyahat ve Turizm Konseyi tarafından hazırlanan "Seyahat ve Turizmin Ekonomik Etkileri: Türkiye 2012" raporunda; 2011 yılında Türkiye'de turizm sektörünün, doğrudan ve dolaylı olmak üzere 141,8 milyar Türk Lirası gelir ile gayri safi yurtiçi hâsılının % 10,9'unu; doğrudan ve dolaylı 1.939.000 iş imkânı ile toplam istihdamın % 8,1'ini sağladığı belirtilmiştir. Aynı raporda, turizmin doğrudan ve dolaylı olarak istihdam sağladığı kişi sayısının 2012 yılında % 3,4 oranında bir artışla 2 milyonu aşacağı, turizmin dolaylı olarak oluşturacağı ekonomik etkisinin ise % 1,9 artış göstereceği öngörülmüştür (WTTC, 2012: 1). Ancak turizmin sayılan özelliklerinden faydalanabilmek için gerek kamu, gerekse özel sektörde geleceğe yönelik kararların alınmasında turizm talebi tahminlerinin önemi büyüktür.

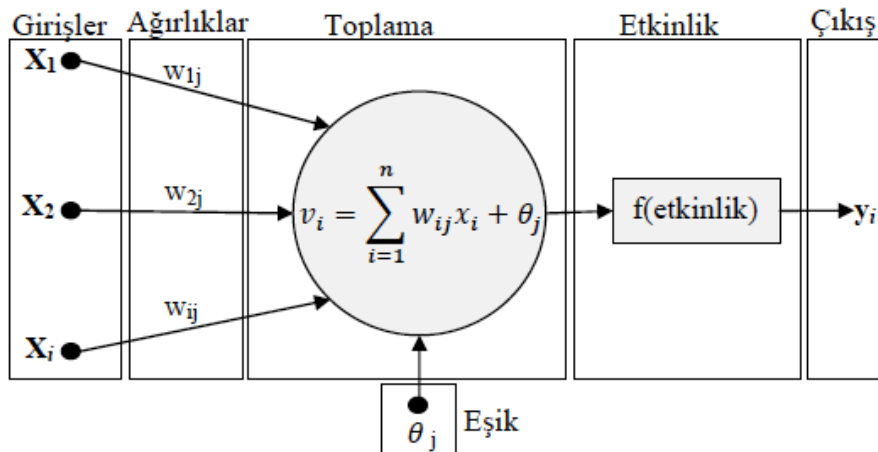
Turizm endüstrisi de, diğer tüm sektörlerde olduğu gibi güvenilir verilere dayanan doğru tahminlere ihtiyaç duymaktadır. Turizm talebinin isabetli ve doğru tahminlenmesi,

turizm faaliyetlerinin planlanması sürecinde, istihdam edilecek işgücü sayısı ve yatak kapasitesinin belirlenmesi alt yapı, konaklama, ulaşım, tutundurma ve benzeri birçok faaliyetin planlanması ve tamamlayıcı diğer sektörlerle koordine edilmesi vb. konularda yol gösterici olacaktır. Makro ölçekte ele alındığında, turistik bölgeler için ve ülke genelinde turizm yatırımlarının ve faaliyetlerin planlanması yaşamsal önem taşımaktadır. Talep tahminleri bir taraftan bu talebe uyumlu alt ve üst yapı yatırımlarının yönlendirilmesi, diğer taraftan da turistik bölgelerin taşıma kapasitelerinin belirlenmesi, bu sayede de toplumsal ve çevresel açıdan turizmin olumsuz etkilerinin giderilmesi için gereklidir (İçöz, 1993: 99). Bu çalışmanın amacı; Türkiye'ye yönelik aylık dış turizm talebinin, Çok Katmanlı İleri Beslemeli (MLP), Radyal Tabanlı Fonksiyon (RBF) ve Zaman Gecikmeli (TDNN) yapay sinir ağı mimarileri ile modellenmesi ve en yüksek tahmin performansı sağlayan model yardımıyla 2013 yılı için aylık dış turizm talebi tahminlerinin üretilmesidir. Yapılan tahminler ile bireylerin, kamu ve özel sektör temsilcilerinin ileriye yönelik turizm planlama çalışmalarında karar almalarını kolaylaştırmak, çalışmanın amaçları arasındadır.

1. YAPAY SİNİR AĞLARI

Yapay sinir ağları, insan beyninin fizyolojisinden yararlanılarak geliştirilmiş, ağırlıklı bağlantılar aracılığıyla birbirine bağlanan ve her biri kendi belleğine sahip işlem elemanlarından oluşan paralel ve dağıtılmış bilgi işleme modelleri, başka bir anlatımla, biyolojik sinir ağlarını taklit eden bilgisayar programlarıdır (Öztemel, 2012: 30). Yapay sinir ağları, yapay sinir hücrelerinin, diğer adıyla “nöronların” bir araya gelmeleri ile oluşmaktadır. Bir yapay sinir hücresi, girişler; ağırlıklar; toplama fonksiyonu; etkinlik fonksiyonu ve çıkış olmak üzere beş ana kısımdan meydana gelmektedir Şekil. 1’de bir yapay sinir hücresi modeli gösterilmektedir.


Şekil 1. Yapay Sinir Hücresi (Nöron)



Kaynak: (Elmas, 2010: 31)

Şekil 1.'de görüldüğü gibi, hücre girişleri (x_1, x_2, \dots, x_i), bağlantılar üzerindeki ağırlıklar ($w_{1j}, w_{2j} \dots w_{ij}$) ile çarpılarak bir toplayıcıya (Σ) uygulanmakta ve elde edilen toplam, etkinlik fonksiyonundan (f) geçirilerek çıktı (y_i) elde edilmektedir. Burada; w_{ij} ağırlıkları; x_i girişleri; θ_j eşik değerini; (y_i) çıkışı; (f) ise etkinlik fonksiyonunu göstermektedir. Genel olarak, sinir hücreleri katmanlar halinde ve her katman içinde paralel biçimde bir araya gelerek yapay sinir ağını meydana getirirler. Şekil. 2'de, bir girdi ve bir çıktı katmanına sahip örnek bir yapay sinir ağı verilmiştir. Girdi katmanı ile çıktı katmanı arasında yer alan katman veya katmanlar gizli katman olarak adlandırılmaktadır.

Şekil 2. Bir Yapay Sinir Ağı



Yapay sinir ağları, belirli bir problemi direkt olarak mevcut örnekler üzerinden eğitilerek öğrenirler. Yapay sinir ağlarında öğrenme kısaca, istenen bir işlevi yerine getirecek şekilde ağırlık değerlerinin ayarlanması sürecidir. (Elmas, 2010: 88, 137). Ağın eğitimi tamamlandıktan sonra öğrenip öğrenmediğini yani performansını ölçmek için yapılan denemelere ise, ağın “test edilmesi” denmektedir. Test etmek için ağın öğrenme sırasında görmediği örneklerden yararlanır. Ağ, eğitim sırasında belirlenen bağlantı ağırlıklarını kullanarak görmediği bu örnekler için çıktılar üretir. Elde edilen çıktılar doğruluk değerleri ağın öğrenmesi hakkında bilgiler verir. Sonuçlar ne kadar iyiye, eğitim performansının da o kadar iyi olduğunu göstermektedir. Eğitimde kullanılan örnek setine “eğitim seti”, test için kullanılan sete ise “test seti” adı verilmektedir (Öztemel, 2012: 56).

Yapay sinir ağlarında parametrelerin güncellenmesi için literatürde en fazla kullanılan yöntem “hata geriye yayma (Back Propagation)” yöntemidir (Wong vd., 2000: 1047; Smith, 2002: 17; Keleşoğlu, ve Ekinci, 2008: 34; Kaynar vd., 2010: 564; Aladağ, 2010: 192; Abdul

Hamid vd., 2011: 32). Denilebilir ki, uygulamada kullanılan yapay sinir ağı modellerinin yüzde doksandan fazlası geri yayılım algoritması ile gerçekleştirilmiştir (Yıldız, 2009: 63). Bunun en büyük nedenleri arasında, öğrenme kapasitesinin yüksek, anlaşılması kolay ve matematiksel olarak ispatlanabilir bir algoritmaya sahip olması sayılabilir (Keleşoğlu ve Ekinci, 2008: 34; Kaynar vd., 2010: 564). Bu algoritma, hataları geriye doğru çıkıştan girişe azaltmaya çalışmasından dolayı geri yayılım ismini almıştır. Ses tanıma problemlerinden, doğrusal olmayan sistem tanılama ve denetim problemlerine kadar yapay sinir ağları ile çözüm üretilen birçok alanda başarı ile kullanılan bu yöntem, kuadratik bir maliyet fonksiyonunun zaman içerisinde ağ parametrelerinin uyarlanması ile minimizasyonuna dayanmaktadır (Efe ve Kaynak, 2000: 15). Geriye yayılım algoritmasında ağırlıklar, aşağıda verilen eşitlikteki hata fonksiyonunun minimize edilmesi ile hesaplanmaktadır:

$$E = \frac{1}{2} \sum_{k=1}^m (y_k - t_k)^2$$

Eşitlikte, y_k ağıın ürettiği çıktıyı, t_k ise gerçek çıktı değerini göstermektedir. Hatayı en aza indirmek için bağlantı ağırlıkları yeniden düzenlenerek güncellenir. Böylece ağıın gerçek çıktı değerlerine en yakın çıktı değerlerini üretmesi amaçlanır (Kaynar vd., 2010: 564). Yapay sinir ağlarında yer alan sinir hücreleri ve bağlantılar, çok değişik biçimlerde bir araya gelebilmektedir. Ağ mimarileri, hücreler arasındaki bağlantıların yönlerine göre veya ağ içindeki işaretlerin akış yönlerine göre birbirlerinden ayrılmaktadır. Günümüzde, belirli amaçlarla ve değişik alanlarda kullanılmaya uygun, çok katmanlı ileri beslemeli yapay sinir ağları, radyal tabanlı fonksiyon ağları, Learning Vector Quantization, Hopfield, Jordan/Elman Ağı, özörgütlemeli harita ağlar, Kohonen vb. birçok yapay sinir ağı modeli geliştirilmiştir. Bu ağ yapıları içerisinde tahmin amaçlı olarak en yaygın kullanım alanı bulan ve bu çalışmada da kullanılan, çok katmanlı ileri beslemeli (MLP), Radyal Tabanlı Fonksiyon (RBF) ve Zaman Gecikmeli (TDNN) yapay sinir ağlarıdır.

1.1. Çok Katmanlı İleri Beslemeli Yapay Sinir Ağları (MLP)

Rumelhart, Hinton ve Williams (Rumelhart vd., 1986) tarafından geliştirilen bu modele literatürde çok katmanlı algılayıcı (Multilayer Perceptron-MLP), ileri beslemeli yapay sinir ağı (Feedforward Neural Network-FFNN), geriye yayılım modeli (Back Propagation Network-BPN) ve bazı çalışmalarda ise çok katmanlı ileri beslemeli yapay sinir ağı modeli (Multilayered Feed Forward Neural Networks-MFNN) adı verilmiştir. Bu çalışmada, literatürdeki yaygın kullanıma uygun olarak kısaca MLP olarak anılacaktır. MLP, girdi katmanı, çıktı katmanı ve bu iki katman arasındaki gizli katman(lar)dan oluşan ileri beslemeli

yapıya sahip bir yapay sinir ağı modelidir. Girdi katmanından alınan girişler, girdi katmanı ve gizli katman arasında bulunan bağlantı ağırlıkları ile çarpılıp gizli katmana iletilmektedir. Gizli katmandaki nöronlara gelen girişler toplanarak aynı şekilde gizli katman ile çıktı katmanı arasındaki bağlantı ağırlıkları ile çarpılarak çıktı katmanına iletilir. Çıktı katmanındaki nöronlar da, kendisine gelen bu girişleri toplayarak buna uygun bir çıkış üretirler (Efe ve Kaynak, 2000: 8). MLP modelinin temel amacı, ağın beklenen çıktısı ile ürettiği çıktı arasındaki hatayı en aza indirmektir. Bu ağlara eğitim sırasında hem girdiler hem de o girdilere karşılık üretilmesi gereken (beklenen) çıktılar gösterilir. Örnekler giriş katmanına uygulanır, gizli katmanlarda işlenir ve çıkış katmanından da çıkışlar elde edilir. Kullanılan eğitime algoritmasına göre, ağın çıkışı ile arzu edilen çıkış arasındaki hata tekrar geriye doğru yayılarak hata minimuma düşünceye kadar ağın ağırlıkları değiştirilmektedir.

MLP ağlarının tahmin amaçlı kullanımında, ağ mimarisinin belirlenmesi önemlidir. Ağ mimarisinin belirlenmesi süreci, ağın kaç katmandan oluşacağı, her katmanda kaç sinir hücresi bulunacağı ve etkinlik fonksiyonunun belirlenmesi gibi işlemleri kapsamaktadır. Zaman serilerinin gelecek tahmininde tek gizli katmana sahip ağ mimarileri yeterli olmaktadır (Kaynar vd., 2010: 564; Aladağ, 2010: 191). Ağa sunulacak girdiler, serinin geçmiş gecikmeli değerlerinden $(y_{t-1}, y_{t-3}, y_{t-12}, \dots, y_{t-k})$, çıktısı ise gecikmesiz değerlerinden (y_t) meydana gelmektedir. Çıkış değeri (y_t) ile geçmiş gözlem değerlerinden oluşan girişler arasındaki ilişki aşağıda verilmiştir.

$$y_t = w_0 + \sum_{j=1}^p w_j f \left(w_{0j} + \sum_{i=1}^N v_{ij} y_{t-i} \right) + e_t$$

Eşitlikte, w_j , v_{ij} sinir hücreleri arasındaki ağırlık değerlerini, p gizli sinir hücresi sayısını, f ise gizli katmanda kullanılan etkinlik fonksiyonunu göstermektedir. Uygulamada en fazla kullanılan etkinlik fonksiyonları sigmoid ve hiperbolik tanjant fonksiyonlardır (Kaynar vd., 2010: 565).

Literatürde; ekonomi, finans, pazarlama ve turizm talebi ile ilgili çalışmalarda, ağırlıklı olarak çok katmanlı ileri beslemeli yapay sinir ağı mimarisinin kullanıldığı dikkat çekmektedir (Trippi ve Turban, 1996; Law, 2000; Wong vd., 2000; Burger vd., 2001; Cho, 2003; Zhang, 2004; Palmer vd., 2006). Smith, işletmecilik alanında gerçekleştirilen yapay sinir ağı uygulamalarının yüzde elliden fazlasında ileri beslemeli ve geriye yayılım algoritmali ağ mimarisinin kullanıldığını bildirmiştir. Yazar'a göre, bu mimariye sahip yapay sinir ağlarının işletmecilik alanında sık kullanılmasının nedenleri arasında; sınıflandırma,

tahmin ve modelleme gibi geniş uygulama alanına sahip olmaları ve yapılan çalışmalarda oldukça başarılı sonuçlar vermiş olmaları gelmektedir (Smith, 2002: 4).

1.2. Radyal Tabanlı Fonksiyon Ağları (RBF)

Radyal Tabanlı Fonksiyon ağları da MLP gibi bir giriş katmanı, etkinlik fonksiyonu olarak ağı ismini veren radyal fonksiyonların kullanıldığı tek bir gizli katman ve çıkış katmanı olmak üzere 3 katmanlı mimariden oluşmaktadır. Bir RBF ağının çalışma ilkesi, giriş verisine bağlı olarak gizli katmanda uygun genişlik ve merkez değerlerine sahip radyal tabanlı fonksiyonları belirleyerek, çıkış katmanında bu fonksiyonların ürettiği çıktıların uygun ağırlık değerleriyle doğrusal birleşimlerini oluşturup giriş-çıkış arasındaki ilişkiyi belirleme süreci olarak açıklanabilir. MLP'ye oranla daha kısa zamanda eğitilmesi ve lokal minimumlara takılmaksızın en iyi çözüme yakınsamaları gibi özelliklerinden dolayı RBF ağları tahmin ve fonksiyon yaklaşırma gibi problemlerin çözümünü içeren uygulamalarda MLP'ye alternatif bir sinir ağı olarak kullanılmaya başlanmıştır (Kaynar vd., 2010: 564). Ancak MLP gibi farklı yapısal formlarda olmamaları bir dezavantaj olarak değerlendirilebilmektedir (Sağıroğlu vd., 2003). MLP bir ve birden fazla gizli katmana sahip olabilirken, temel yapıdaki bir RBF ağı sadece tek bir gizli katmana sahiptir.

Radyal tabanlı fonksiyon ağları öğrenme sürecinde danışmansız ve danışmanlı öğrenme olmak üzere karma strateji kullanmakta ve böylece öğrenme süreci iki aşamaya ayrılmaktadır. Danışmansız öğrenme stratejisi ile gerçekleştirilen ilk aşama, girdi verilerine gizli katmanda radyal tabanlı fonksiyon uygulanması sürecidir. Danışmanlı öğrenme stratejisi ile gerçekleştirilen ikinci aşama ise, gizli katmandan elde edilen çıktıları doğrusal dönüşüm uygulanarak ağı çıktıları ile gözlenen çıktılar arasındaki hatayı en küçük yapan ağırlıkların belirlenmesi sürecidir (Türe ve Kurt, 2005: 365). RBF ağlarının eğitimi çok boyutlu uzayda eğri uydurma yaklaşımı olarak görmek mümkündür. Bu nedenle RBF modelinin eğitim performansı, çıktı vektör uzayındaki verilere en uygun yüzeyi bulma problemine dönüşmektedir (Okkan ve Dalkılıç, 2012: 5959). RBF ağlarının temel çalışma prensibi, N-boyutlu uzaydaki verileri farklı sınıflara veya kategorilere ayırıyor olmasıdır. Her kategori bir merkez içermekte ve girişlerin kategorilere ayrılması bu merkezler sayesinde olmaktadır. Sınıflama N-boyutlu giriş vektörü ile merkez vektörü arasındaki Öklid mesafesinin hesaplanmasıyla yapılmaktadır.

RBF modellerinde ağıın ürettiği çıktı aşağıdaki eşitlik yardımıyla hesaplanmaktadır.

$$y_i = \sum_{k=1}^N w_{ik} \phi_k(x, c) = \sum_{k=1}^N w_{ik} \phi_k(\|x - c_k\|_2), \quad i = 1, 2, \dots, m$$

Burada, x ağıın girdi vektörünü; $\phi_k(\cdot)$ radyal tabanlı etkinlik fonksiyonunu; c_k girdi vektör uzayının bir alt setinden seçilen radyal tabanlı merkezleri; $\|\cdot\|_2$ girdi vektörünün merkezden ne kadar uzak olduğunun bir ölçütü olan Öklidyen normunu; w_{ik} çıktı katmanındaki ağırlıkları ve N ise gizli katmanda bulunan hücre sayısını göstermektedir. RBF modellerinde etkinlik fonksiyonu olarak birçok fonksiyon tipi kullanılabilir. Doğrusal, Kübik, Gauss, Multi-Kuadratik, Ters Multi-Kuadratik fonksiyonlar bunlardan bazıları olup uygulamada en çok Gauss fonksiyonu tercih edilmiştir. Gauss fonksiyonunun matematiksel yapısı aşağıda verilmiştir.

$$\phi_k(x) = \exp(-\|x - c_k\|_2^2 / 2\sigma^2)$$

Burada, x girdi vektörünü, c_k merkezleri, σ ise standart sapma değerini göstermektedir.

1.3. Zaman Gecikmeli Yapay Sinir Ağları (TDNN)

Zaman gecikmeli yapay sinir ağları (Time Delay Neural Networks-TDNN), Waibel (1989) tarafından ses tanıma problemleri için geliştirilmiş olmasına rağmen aynı zamanda zaman serisi tahmini için de kullanılan bir yapay sinir ağı modelidir. TDNN, çok katmanlı ileri beslemeli bir yapay sinir ağıının girdi katmanına bellek hücreleri yerleştirilerek oluşturulan dinamik bir yapay sinir ağıdır (Kubat ve Kiraz, 2012: 208). TDNN, MLP ağıından farklı olarak iki ek özelliğe sahiptir. Birincisi, nöronların toplam bağlantı sayısını azaltmakta ve öğrenme süresini kısaltmaktadır. İkinci ek özellik ise, zamana bağlı verilerin olası kayıplarına karşın başarılı bir tanıma gerçekleştirmeye yardımcı olur. MLP için kullanılan öğrenme algoritmaları küçük bir değişiklikle zaman gecikmeli sinir ağıının eğitiminde kullanılabilir. Girdi ve gizli katmanlar arasındaki bellek hücrelerinde, sonlu dürtü cevaplı (finite impulse response, FIR) filtreleme kullanılır. Ağ, girdi verisini, bu filtreleme sayesinde zaman gecikmelerini dikkate alarak ardışık biçimde ele alır.

TDNN, ağırlıkların ayarlanması sürecinde çok katmanlı ağlarda kullanılan algoritmaları kullanmaktadır. En çok kullanılan algoritma ise temporal (zamana bağlı) geriye yayılma algoritmasıdır. Ağırlıkların güncellenmesi süreci, gözlenen çıktı ve beklenen çıktı arasındaki karesel hataların toplamını minimum yapmak amacıyla taşımaktadır. Bu süreç, ağ

hatasını minimum yapan ağırlıkları elde edene kadar temporal geriye yayılım algoritmasıyla adım adım devam eder (Türe ve Kurt, 2005: 364).

2. İLGİLİ ÇALIŞMALAR

Turizm talebi tahminlerinde kullanılan tahmin tekniklerine alternatif olarak, yapay sinir ağlarından yararlanılarak tahmin çalışmalarının gerçekleştirildiği görülmektedir. Yapılan literatür incelemesi neticesinde yapay sinir ağları kullanılarak; gelen turist sayısı, oda ve yatak doluluk oranları, turizm gelirleri, turistlerin geceleme sayıları ve turist harcamalarının tahminlerine yönelik çalışmaların yapıldığı tespit edilmiştir. Konuyla ilgili ilk çalışma Pattie ve Snyder tarafından gerçekleştirilmiştir. Yazarlar; Amerika'daki milli parkları ziyaret eden ziyaretçi sayısını, geri yayımlı (back propagation) yapay sinir ağı modelini kullanarak tahmin etmişlerdir. Yaptıkları tahmin doğruluğu ölçümleri neticesinde, yapay sinir ağlarının klasik tahmin yöntemlerine alternatif ve başarılı bir tahmin yöntemi olduğunu belirtmişlerdir (Pattie & Snyder, 1996). Uysal ve El Roubi; çoklu regresyon modeli ve yapay sinir ağı ile Amerika Birleşik Devletlerini ziyaret eden Kanadalı turistlerin yapmış oldukları harcamaları tahmin etmişlerdir. Yazarlar, her iki modelin de birbirine yakın sonuçlar verdiğini tespit etmişlerdir (Uysal & El Roubi, 1999). Cho, 1974 – 2000 yıllarına ait üçer aylık zaman serisi verilerini kullandığı çalışmasında; farklı ülkelerden Hong Kong'a yönelik dış turizm talebini tahmin etmiştir. Yazar, çalışmasında kullandığı Elman yapay sinir ağının, diğer yöntemlere göre bir ülke haricinde tüm ülkelerden gelen turist sayılarının tahmininde, en iyi sonuçları verdiğini belirtmiş ve yapay sinir ağlarının özellikle mevsimsel dalgalanma gösteren, seriler için uygun bir tahmin yöntemi olduğunu ileri sürmüştür (Cho, 2003). Law; geriye yayımlı ileri beslemeli yapay sinir ağı modeli ile hareketli ortalama, çoklu regresyon, mekanik tahmin ve Holt'un çift parametrelili üstel düzleştirme modellerinin, Hong Kong'a gelen Tayvanlı turist sayısını tahmin etme performanslarını karşılaştırmıştır. Yazar; gerçekleşmiş değerler ile ileri beslemeli geri yayımlı yapay sinir ağı modelinden elde edilen tahmin sonuçları arasındaki sapmaların diğer modellerle elde edilen sonuçlara göre daha küçük olduğunu belirtmiştir (Law, 2000). Palmer, Montaño ve Sesé; 1986 – 2000 yıllarına ait üçer aylık zaman serisi verilerini kullanarak, farklı mimarilere sahip ileri beslemeli yapay sinir ağı modellerinin, Baleric Adaları'nın turizm gelirlerini tahmin etme performanslarını karşılaştırmışlardır. Denedikleri toplam 28 farklı yapay sinir ağı modelinin tahmin performanslarını değerlendiren yazarlar, yapay sinir ağlarının; doğrusal olmama, hata toleransı, veriler arasındaki karmaşık ilişkileri modelleyebilme ve istatistiksel varsayımlara gerek duymamaları gibi bir dizi avantaja sahip olduğunu ve bu özellikleri ile turizm zaman serileri için uygun bir tahmin


tekniki olduğunu ileri sürmüşlerdir (Palmer, Montaño & Sesé, 2005). Kon ve Turner; 1985 – 2001 dönemine ait çeyrek yıllık zaman serisi verilerini kullanarak, yapay sinir ağları, temel yapısal model (Basic Structural Model) ve Holt-Winters'ın mevsimsel üstel düzleştirme yöntemlerinin, altı farklı ülkeden (Avustralya, Çin, Hindistan, Japonya, İngiltere ve Amerika Birleşik Devletleri) Singapur'a gelen ziyaretçi sayılarını tahmin performanslarını karşılaştırmışlardır. Yazarlar; Temel Yapısal Model sonuçlarının oldukça başarılı olduğunu, bununla birlikte verilerin yapısına uygun yapılandırılmış yapay sinir ağı modellerinin çalışmada kullanılan diğer yöntemlerle elde edilen modellere göre daha başarılı sonuçlar verdiğini belirtmişlerdir (Kon ve Turner, 2005). Fernandes ve Teixeira, Ocak 1987 – Aralık 2005 yıllarına ait zaman serisini kullanarak Güney Portekiz'deki otel işletmelerinde konaklayan turistlerin geceleme sayılarını, geri yayımlı yapay sinir ağı modelleri ile tahmin etmişlerdir (Fernandes & Teixeira, 2008). Türkiye'de yapılan çalışmalar incelendiğinde, bu alanda ilk çalışmanın Baldemir ve Bahar tarafından gerçekleştirildiği görülmektedir. Yazarlar, ileri beslemeli geri yayımlı yapay sinir ağı, hareketli ortalama, çoklu regresyon ve "saflık modeli" olarak adlandırdıkları mekanik tahmin yöntemlerinin, beş ülkeden Türkiye'ye gelen turist sayılarını tahmin performanslarını karşılaştırmışlardır. Çalışmada 1984 – 1999 yıllarına ait yıllık verilerden yararlanılmış ve toplam 16 gözlem arasında ilk 13 gözlem tahmin, son 3 gözlem ise modellerin tahmin performanslarını test etmek için kullanılmıştır. Yazarlar; Türkiye'ye yönelik turizm talebini tahminlerinde, anılan modeller arasında, geri yayımlı yapay sinir ağı modelinin daha başarılı sonuçlar verdiğini belirtmişlerdir (Baldemir ve Bahar, 2003). Çuhadar ve Kayacan; 1990 – 2002 yıllarına ait aylık zaman serisi verilerini kullanarak farklı katman ve nöron sayılarına sahip ileri beslemeli geriye yayımlı yapay sinir ağı modellerinin, Türkiye'deki Turizm Bakanlığı belgeli konaklama işletmelerinin aylık doluluk oranlarını tahmin etme doğruluklarını karşılaştırmışlardır. Yazarlar, [5-5-3-1] düzenine sahip iki gizli katmanlı yapay sinir ağı modelinin, denenen diğer modellere göre en yüksek tahmin doğruluğunu sağlayan model olduğunu tespit etmişlerdir (Çuhadar ve Kayacan, 2005). Güngör ve Çuhadar; 1991–2004 dönemine ait aylık zaman serisi verilerini kullanarak, ileri beslemeli geriye yayımlı yapay sinir ağı ile doğrusal ve doğrusal olmayan çoklu regresyon modellerinin, Antalya'ya gelen Alman turist sayılarını tahmin etme başarılarını karşılaştırmışlardır. Modellerin tahmin başarılarını değerlendiren yazarlar, en yüksek tahmin doğruluğu sağlayan [5-7-1] düzenindeki sahip yapay sinir ağı modeli ile 2005 ve 2006 yılları için aylar itibarıyla Antalya iline yönelik Alman turist talebi tahminleri yapmışlardır (Güngör ve Çuhadar, 2005). Önder ve Hasgül, uzun dönemli yabancı ziyaretçi sayısının tahmini için, zaman serisi analizi yöntemleri ile elde edilen sonuçları yapay sinir ağları kullanılarak elde

edilen sonuçlarla karşılaştırmışlardır. Yapılan analizler neticesinde mevsimsel üstel düzleştirme (Holt-Winters) modelinin ürettiği hata değerinin diğer yöntemlere göre daha düşük olduğu sonucunu elde eden yazarlar, yapay sinir ağlarının ürettiği hata değerinin daha yüksek çıkmasına karşın yine de yabancı ziyaretçi sayısının tahmininde geleneksel yöntemlere alternatif olarak kullanabileceğini bildirmişlerdir (Önder ve Hasgöl, 2009). Aladağ, 1977 – 2008 yıllarına ait Türkiye’ye gelen yıllık yabancı turist sayılarını kullandığı çalışmada, uyarlamalı öğrenme kurallı geri yayılım, momentum güncellemeli geri yayılım, elastik (resilient) geri yayılım, Quasi-Newton geri yayılım ve Levenberg-Marquardt geri yayılım olmak üzere beş farklı öğrenme algoritmasının tahmin performanslarını, hata kareleri ortalamasının karekökü (HKOK) istatistiği yardımıyla karşılaştırmıştır. Yazar, yapmış olduğu analizler neticesinde, (9-7-1) mimarisine sahip elastik geri yayılım algoritmasının en küçük hata değeri verdiği sonucuna varmıştır (Aladağ, 2010).

3. VERİ VE YÖNTEM

Çalışmada kullanılan veriler, Ocak 1987 – Aralık 2012 periyodunda Türkiye’ye gelen aylık yabancı turist sayılarıdır. Veriler, Kültür ve Turizm Bakanlığı tarafından yayımlanan sınır giriş-çıkış istatistikleri bültenlerinden temin edilmiştir. Verilere ait zaman grafiği, şekil. 3’de verilmiştir. Zaman grafiği incelendiğinde serinin artan bir trend ile birlikte mevsimsel dalgalanmaların etkisinde olduğu gözlenmektedir. Dalgalanma, birbirini izleyen yılların nisan aylarından itibaren artmaya başlayarak Temmuz ve Ağustos aylarında en yüksek, Ocak aylarında en düşük değere ulaşması şeklinde meydana gelmektedir.

Şekil 3: Türkiye’ye Gelen Yabancı Turistler Serisi Zaman Grafiği (Ocak 1987 – Aralık 2012)



Yapay sinir ağları ile mevsimsel zaman serilerinin modellenmesi ve tahmini üzerine yapılan çalışmalarda, Pattie ve Snyder (1996), Nelson vd. (1999), Zhang ve Qi (2005), Palmer, Montaño ve Sesé (2005), Kon ve Turner (2005), Zhang ve Kline (2007) gibi yazarlar yapay sinir ağlarının mevsimsel zaman serilerini modellemede başarısız olduğunu ve iyi bir tahmin elde edebilmek için verilerin mevsimsel etkilerden arındırılması gerektiğini savunmuşlardır. Diğer taraftan, Sharda ve Patil (1992), Franses ve Draisma (1997), Alon vd. (2001) ve Hamzaçebi (2008) gibi yazarlar ise yapay sinir ağlarının verilerdeki mevsimsel örüntüleri modelleyebildiğini, bu nedenle verilerin mevsimsellikten arındırılmasına gerek olmadığını ileri sürmüşlerdir. Yapay sinir ağları ile gerçekleştirilen zaman serisi tahminlerinde üzerinde uzlaşa sağlanamamış diğer bir konu ise girdi katmanında kullanılacak nöron sayılarıdır. Sebep-sonuç ilişkisine dayalı bir tahmin probleminde bağımsız değişkenler girdi nöronu olarak kullanılmaktadır. Ancak, zaman serisi tahminlerinde uygun girdi nöronu bileşimini belirlemek kolay değildir. Girdi nöronu sayısı, seri değerlerinin geçmiş gözlem değerleri ile olan ilişkisini gösterdiğinden, bu ilişkinin kaç dönem geçmiş değeri kapsayacağını belirlenmesi önemlidir. Literatürde bu konuya ilişkin farklı görüşlerin olduğu dikkat çekmektedir. Bazı yazarlar, girdi katmanında yer alacak işlem elemanı sayısının, Box-Jenkins metodolojisinde olduğu gibi otoregresif sürecin (AR) derecesine eşit olarak alınmasını önermiştir. Buna karşın bazı yazarlar, bu metodolojide yer alan hareketli ortalama (MA) modellerinin otoregresif terim içermediğini ayrıca Box-Jenkins modellerinin doğrusal olduğunu ve dolayısıyla doğrusal olmayan veri yapıları için uygun olmayacağını ifade etmiştir (Hamzaçebi, 2011: 71; Kaynar vd., 2010: 564). Hamzaçebi'ye göre ise, kullanılan modelde giriş ve çıkış nöronu sayısı serinin mevsimsellik parametresine eşit alınırsa, örneğin aylık zaman serileri için on iki, üçer aylık seriler için dört olarak alınırsa yapay sinir ağları başarılı tahminlerde bulunabilmektedir (Hamzaçebi, 2011: 103). Verilerin MLP, RBF ve TDNN ile modellenmesinde, önceki çalışmalardaki deneyimler dikkate alınarak orijinal seri ve mevsimsel ayrıştırma yöntemi ile elde edilen mevsimsel etkilerden arındırılmış seri olmak üzere iki ayrı veri seti kullanılarak oluşturulan farklı ağ mimarilerinin tahmin performansları incelenmiştir. Kullanılan 312 aylık verinin 1987-2009 dönemine ait 264'ü eğitim, 2010-2011 dönemine ait 24'ü ise test verisi şeklinde gruplandırılmıştır. 2012 yılına ait değerler, en iyi performansı gösterecek model yardımıyla üretilecek tahminlerde girdi setinde yer alacağından dolayı kullanılmamıştır. Literatürde yer alan hemen tüm çalışmalarda olduğu gibi bu çalışmada da tahmini hesaplanacak verilerin gecikmeli değerleri, yapay sinir ağı modelleri için girdi olarak kullanılmıştır. Girdi katmanında, Hamzaçebi'nin aylık seriler için önerdiği 12

gecikmeli veri deęerleri ($y_{t-12}, y_{t-24}, y_{t-36}, \dots$) ıkıř katmanında ise gecikmesiz veri deęerleri (y_t) kullanılmıřtır. Yöntemin uygulanması Matlab 7.10.0 (R2010a) yazılımının yapay sinir aęları modülü (nntool) ierisinde yer alan Feed-Forward backprop (MLP), Radial-Basis (RBF) ve Feed-Forward Time-delay (TDNN) fonksiyonları ile gerekleřtirilmiřtir. Kurulan modellerin eęitim ařamasında hızlı yakınsayabilmesi ve performansının arttırılması aısından, tüm veriler $\frac{x_0 - x_{min}}{x_{max} - x_{min}}$ baęıntısıyla sıfır ile bir arasında öleklendirilerek aęa sunulmuřtur. Bu eřitlikte x_0 = orijinal veri, x_{min} = veri seti ierisinde yer alan en kçük sayı, x_{max} = veri seti ierisinde yer alan en byk sayıyı ifade etmektedir. alıřma kapsamında oluřturulan tüm modeller  katmanlı mimariye sahiptir. Aęın ęrenme srecinin durdurma kriteri olarak her bir deneme iin 5000 iterasyon belirlenmiřtir. alıřmada, MLP modelleri iin girdi katmanında 12 gecikmelerdeki nron sayıları, gizli katmanında farklı nron (1-7) sayılarındaki modeller geliřtirilmiř, gizli katmandaki nron sayısının belirlenmesinde kesin bir kural olmaması nedeniyle farklı nron sayısı alternatifleri denenmiřtir. RBF modelleri iin, gizli katmandaki nron sayıları birden yirmiye kadar arttırılarak yirmi ayrı model denenmiř, gizli katmandaki radyal fonksiyonların merkezi veri setlerinden seilerek belirlenmiřtir. Gizli katmandaki iřlem elemanlarının aktivasyon fonksiyonu olarak normalize radyal temelli fonksiyon seilmiřtir. TDNN modelleri iin giriř gecikme vektr [012] olarak alınmiřtır. Daha sonra test iin ayrılan veriler ile kurulan tüm modeller test edilmiřtir. Test iřlemi sonucunda bulunan tahmin deęerleri, gerek deęerlerle karřılařtırılarak, MLP, RBF ve TDNN'den elde edilen modellerinin tahmin doęrulukları "Ortalama Mutlak Yzde Hata" (MAPE) istatistięi ile deęerlendirilmiřtir. MAPE istatistięinin tahmin hatalarını yzde olarak ifade etmesi nedeni ile tek bařına da bir anlamının olması, muhtelif istatistiklere gre stnlę olarak kabul edilmektedir. Matematiksel ifadesi;

$$MAPE = \frac{\sum_{t=1}^n \frac{|e_t|}{y_t}}{n} 100(\%)$$

Bu eřitlikte: $e_t = y_t - \hat{y}_t$ olmak zere,

y_t = t dnemindeki gerek deęeri,

\hat{y}_t = t dnemi iin hesaplanan tahmin deęerini,

n = tahmin yapılan dnem sayısını,

e_t = t dnemindeki tahmin hatasını ifade etmektedir.

4. BULGULAR

MLP, RBF ve TDNN ağ yapıları ile gerçekleştirilen çok sayıda deneme sonucunda, genel olarak orijinal veri değerleri ile oluşturulan yapay sinir ağı modellerinin, mevsimsel etkilerden arındırılmış veri değerleri ile kurulan modellere göre daha iyi sonuçlar verdiği görülmüştür. Elde edilen bulgular, verilerin mevsimsellikten arındırılması işleminin verilerin sahip olduğu örüntüyü ortadan kaldırdığını ve yapay sinir ağlarının doğrusal olmayan kalıpları modelleyebildiği görüşünü destekler nitelikte olmuştur. Farklı mimarilere sahip yapay sinir ağı modelleri ile yapılan denemelerden elde edilen en yüksek tahmin performansları, Tablo 1.'de özetlenmiştir.

Tablo 1. Denenen Modellerin Tahmin Performansları

MODEL	Girdi Katmanındaki Nöron Sayısı	Gizli Katmandaki Nöron Sayısı	MAPE (%)
MLP	3	3	5,06
MLP	4	5	2,64
MLP	2	7	3,9
RBF	2	15	5,58
RBF	3	13	4,2
RBF	4	10	3,37
TDNN	3	3	5,76
TDNN	4	5	4,03
TDNN	2	7	5,14

Tablo 1. İncelendiğinde, çalışma kapsamında denenen MLP, RBF ve TDNN modellerinin hemen hepsinin oldukça başarılı tahminler ürettiği ve tüm modellerin MAPE değerlerinin küçük olduğu dikkat çekmektedir. Literatürde MAPE değeri %10'un altında olan modeller "çok iyi", %10 ile %20 arasında olan modeller "iyi", %20 ile %50 arasında olan modeller "kabul edilebilir" ve %50'nin üzerinde olan modeller ise "yanlış ve hatalı" olarak sınıflandırılmaktadır (Lewis, 1982; Martin & Witt, 1989; Witt & Witt, 1992). En yüksek tahmin doğruluğuna sahip MLP, RBF ve TDNN modellerinin 2011 yılı için ürettikleri tahmin değerleri Tablo 2.'de verilmiştir.

Tablo 2. Modellerin 2011 Yılına Ait Tahmin Değerleri

AY	GÖZLENEN (2011)	MLP	RBF	TDNN
1	975723	923909	961676	901673
2	1079505	1051761	1117363	1011940
3	1617782	1593438	1509856	1506506

4	2290722	2223092	2186614	2066006
5	3283125	3391809	3161405	3343930
6	3780637	3689893	3808668	3853125
7	4597475	4550154	4668123	4509035
8	4076783	4115377	4489916	3875888
9	3923546	3803614	3964342	3845729
10	3039754	3014806	3149364	2939489
11	1596295	1639589	1645868	1584795
12	1194729	1256194	1200508	1179094
	MAPE(%)	2,64	3,37	4,03

Tablo 1. ve 2.'de görüldüğü gibi, denenen modeller içerisinde en başarılı tahmin performansı sergileyen yapay sinir ağı modeli, [4:5:1] mimarisine sahip MLP modeli olmuştur. Türkiye'ye yönelik dış turizm talebinin tahmini amacıyla oluşturulan yapay sinir ağı modelinde; bir giriş katmanı, bir gizli katman ve bir çıkış katmanı bulunmaktadır. Giriş katmanında 4, gizli katmanında 5 ve çıkış katmanında ise 1 nöron bulunmaktadır. Modele ait % 2,64 MAPE değeri, gerçekleşmiş değerler ile elde edilen tahmin sonuçları arasındaki sapmaların çok küçük olduğunu göstermektedir. Geliştirilen modele ait parametreler Tablo 3'te verilmiştir.

Tablo 3. Geliştirilen Modelin Parametreleri

Parametre	Parametre Bilgileri
Girdi Katmanındaki Nöron Sayısı	: 4
Gizli Katman Sayısı	: 1
Gizli Katmandaki Nöron Sayısı	: 5
Çıktı Katmanındaki Nöron Sayısı	: 1
Transfer Fonksiyonu	: Logarimik-Sigmoid
Ağırlıkların Güncellenmesi	: Feed Forward Back Propagation
Eğitim Fonksiyonu	: Levenberg - Marquardt

Yapılan değerlendirmeler neticesinde en yüksek tahmin doğruluğunu sağlayan [4:5:1] mimarisine sahip MLP modeli kullanılarak 2013 yılı için aylık dış turizm tahminleri üretilmiştir. Türkiye'ye yönelik dış turizm talebi tahminlerinin üretilmesi amacıyla, model geliştirme aşamasında kullanılmayan 2012 yılı gözlem değerleri modelin çıkış katmanında yer alan seri değerlerine eklenmiş ve her bir giriş seti 12 gecikmeli seri değerleri eklenerek güncellenmiştir. Elde edilen tahmin değerleri Tablo 4'te verilmiştir.

Tablo 4. 2013 Yılı İçin Türkiye'ye Yönelik Aylık Dış Turizm Talebi Tahminleri

AYLAR (2013)	TAHMİN DEĞERLERİ
Ocak	998.471
Şubat	1.113.742
Mart	1.546.289
Nisan	2.306.193
Mayıs	3.560.075
Haziran	4.129.773
Temmuz	5.196.980
Ağustos	5.069.954
Eylül	4.280.680
Ekim	3.430.534
Kasım	1.750.649
Aralık	1.364.197

5. SONUÇ VE ÖNERİLER

Turizm talebi tahminleri, bireylerin, kamu be özel sektör temsilcilerinin ve hükümetlerin ileriye yönelik olarak yapacakları planlama çalışmalarında gereksinim duydukları önemli bir faktördür. Fiyatlandırma, tanıtım ve diğer pazarlama fonksiyonlarının planlanması ile kaynakların doğru yerlere yönlendirilmesi açısından ileriye yönelik doğru ve güvenilir talep tahminleri turizm sektörü için büyük önem arz etmektedir. Güvenilir ve doğru talep tahminleri başta konaklama, ulaştırma ve seyahat olmak üzere turizm sektörü ile ilgili bütün faaliyetlerin etkili bir şekilde planlanabilmesi için gereklidir. Bu çalışmada, Türkiye'ye yönelik aylık dış turizm talebinin, Çok Katmanlı İleri Beslemeli (MLP), Radyal Tabanlı Fonksiyon (RBF) ve Zaman Gecikmeli (TDNN) yapay sinir ağı mimarileri ile modellenmesi ve en yüksek tahmin performansı sağlayan model yardımıyla 2013 yılı için aylık dış turizm talebi tahminlerinin üretilmesi amaçlanmıştır. Yapılan çok sayıda deneme sonucunda, en yüksek tahmin performansı sergileyen modelin 12 gecikmeli seri değerleri kullanılarak oluşturulan [4-5-1] mimarisine sahip MLP modeli olduğu görülmüş ve bu model yardımıyla 2013 yılı için aylık olarak Türkiye'ye yönelik dış turizm talebi tahminleri üretilmiştir. Çalışmanın, gerek doğal güzellikleri gerekse kültür mirasıyla zengin turizm değerlerine sahip olan Türkiye'ye yönelik turizm talebini, yapay zekâ metodolojileri ile modelleyen ve ileriye yönelik aylık tahminler üreten sınırlı sayıda çalışmadan bir tanesi olduğu söylenebilir. Yapay sinir ağları veriler arasındaki doğrusal olmayan ilişkileri öğrenip genelleme

yapabilmekte ve bu sayede başarılı tahminler üretebilmektedirler. Literatürdeki çalışmalardan elde edilen sonuçlar dikkate alındığında yapay sinir ağı modellerinin oldukça başarılı sonuçlar verdiği görülmektedir.

İleriye yönelik yapılacak çalışmalar için; destek vektörleri (Support Vector Machines), kaba setler (Rough Sets) yaklaşımı, bulanık mantık, genetik algoritmalar ve adaptif yapay sinir ağı - bulanık mantık (ANFIS) gibi diğer yapay zeka uygulamaları ile Türkiye'ye veya belirli bir bölgeye yönelik iç ve dış turizm talebi; belirli bir bölge veya il sınırları içerisinde faaliyet gösteren konaklama işletmelerindeki doluluk oranları; yerli ve yabancı konukların konaklama işletmelerindeki geceleme sayıları ve ortalama kalış sürelerine ilişkin tahmin çalışmaları önerilebilir. Türkiye'de yapay zekâ yöntemleri ile turizm talebinin tahminlenmesi çalışmalarının sınırlı sayıda olduğu göz önünde bulundurulduğunda, önerilen çalışmaların literatüre ve turizm sektöründeki uygulamacılar ile karar verme konumunda olan yöneticilerin geleceğe yönelik planlama çalışmalarına önemli katkılar sağlayacağı söylenebilir.

KAYNAKÇA

Abdul Hamid, N, Nawi, N.M, Ghazali, R. ve Mohd S.N.M. (2011). Accelerating Learning Performance of Back Propagation Algorithm by Using Adaptive Gain Together with Adaptive Momentum and Adaptive Learning Rate on Classification Problems. *International Journal of Software Engineering and Its Applications*,. 5 (4): 31-44.

Aladağ, Ç.H. (2010) “Farklı Öğrenme Aalgoritmalarıyla Türkiye’ye Gelen Yabancı Turist Sayısının Tahmini” I. Disiplinlerarası Turizm Araştırmaları Kongresi, 27-30 Mayıs 2010, Nevşehir.

Alon, I, Qi, M. ve Sadowski, R.J. (2001): Forecasting Aggregate Retail Sales: A Comparison Of Artificial Neural Networks and Traditional Methods. *Journal of Retailing and Consumer Services* 8 (3): 147–156.

Baldemir, E. ve Bahar, O. (2003). Türkiye’ye Yönelik Turizm Talebinin Neural (Sinir) Ağları Modelini Kullanarak Analizi. *Gazi Üniversitesi Ticaret ve Turizm Eğitim Fakültesi Dergisi*, (2): 152-169.

Burger, C.J.S.C., Dohnal, M., Kathrada, M. ve Law, R. (2001). A Practitioners Guide to Time-Series Methods For Tourism Demand Forecasting - A Case Study Of Durban, South Africa. *Tourism Management*, 22 (4): 403-409.

Cho, V. (2003). A Comparison of Three Different Approaches To Tourist Arrival Forecasting. *Tourism Management*, 24(3): 323-330.

Çuhadar, M. ve Kayacan, C. (2005). Yapay Sinir Ağları Kullanılarak Konaklama İşletmelerinde Doluluk Oranı Tahmini: Türkiye'deki Konaklama İşletmeleri Üzerine Bir Deneme. *Anatolia Turizm Araştırmaları Dergisi*, 16 (1): 121-126.

Efe, Ö. ve Kaynak, O. (2000). *Yapay Sinir Ağları ve Uygulamaları*. İstanbul: Boğaziçi Üniversitesi Yayınevi.

Önder, E. ve Hasgül, Ö. (2009). Yabancı Ziyaretçi Sayısının Tahmininde Box Jenkins Modeli, Winters Yöntemi ve Yapay Sinir Ağlarıyla Zaman Serisi Analizi. *İstanbul Üniversitesi İşletme İktisadi Enstitüsü Yönetim Dergisi*, 20 (62): 62-83.

Elmas, Ç. (2010). *Yapay Zekâ Uygulamaları (Yapay Sinir Ağı, Bulanık Mantık, Genetik Algoritma)*. Ankara: Seçkin Yayıncılık.

Fernandes, P. ve Teixeira, J. (2008). “Applying The Artificial Neural Network Methodology For Forecasting The Tourism Time Series”, 5th International Scientific Conference Business and Management”, 16-17 May 2008, Vilnius, Lithuania.

Franses, P.H. ve Draisma, G. (1997). Recognizing Changing Seasonal Patterns Using Artificial Neural Networks. *Journal of Econometrics*, (82): 273-280

Güngör, İ. ve Çuhadar, M. (2005). Antalya İline Yönelik Alman Turist Talebinin Yapay Sinir Ağları Yöntemiyle Tahmini. *Gazi Üniversitesi Ticaret ve Turizm Eğitim Fakültesi Dergisi*, 2005 (1): 84-99.

Hamzaçebi, C. (2008). Improving Artificial Neural Networks' Performance in Seasonal Time Series Forecasting. *Information Sciences*, 178(23): 4550-4559.

Hamzaçebi, C. (2011). *Yapay Sinir Ağları: Tahmin Amaçlı Kullanımı. Matlab ve Neuroslutions Uygulamalı*. Bursa: Ekin Yayınevi.

İçöz, O. (1993). Turizm Sektöründe Plan ve Planlamanın Önemi, *Turizm Yıllığı 1993*, Ankara: Türkiye Kalkınma Bankası Yayını.

Kaynar, O., Taştan, S. ve Demirkoparan, F. (2010). Ham Petrol Fiyatlarının Yapay Sinir Ağları İle Tahmini, *Ege Akademik Bakış*, 10 (2): 559-573.

Keleşoğlu, Ö ve Ekinci, C. (2008). Silis Dumanı Katkılı Betonların Çarpma Dayanımının Yapay Sinir Ağı İle Belirlenmesi. *e-Journal of New World Sciences Academy (Natural And Applied Sciences)*, 3 (1): 30-38.

Kon, C. S. ve Turner, L. W. (2005). Neural Network Forecasting of Tourism Demand. *Tourism Economics*, 11 (3): 301-328.

Kubat, C. ve Kiraz, A. (2012). Yapay Zeka Kullanılarak Sanal Laboratuar Tasarımında Çekme Testinin Modellenmesi, *Gazi Üniv. Müh. Mim. Fak. Dergisi*, 27(1): 205-210.

Kültür ve Turizm Bakanlığı (2013). Giriş-Çıkış Yapan Yabancı ve Vatandaşlar Bülteni, Sayı: 12, Aralık, 2012, (23.01.2013).

Law, R. (2000). Back-Propagation Learning in Improving The Accuracy Of Neural Network-Based Tourism Demand Forecasting. *Tourism Management*, 21 (4): 331-340.

Lewis, C. D. (1982). *Industrial and Business Forecasting Methods: A Practical Guide to Exponential Smoothing and Curve Fitting*. London: Butterworth Scientific.

Martin, C.A. ve Witt, S.F. (1989). Forecasting Tourism Demand: A Comparison Of The Accuracy Of Several Quantitative Methods. *International Journal of Forecasting*, 5(1): 7-19.

Nelson, M., Hill, T., Remus, T. ve O'connor, M. (1999). Time Series Forecasting using NN's: Should Data be Deseasonalized First. *Journal of Forecasting*, (18): 359-367.

Okkan, U. ve Dalkılıç, H.Y. (2012). Radyal Tabanlı Yapay Sinir Ağları ile Kemer Barajı Aylık Akımlarının Modellenmesi, 23(2): 5957-5966

Oskay, C. (2012). Mersin Turizminin Türkiye Ekonomisindeki Yeri ve Önemi. *Çukurova Üniversitesi, Sosyal Bilimler Enstitüsü Dergisi*, 21(2): 185-202.

- Öztemel, E. (2012). *Yapay Sinir Ağları*. İstanbul: Papatya Yayıncılık Eğitim.
- Palmer, A., Montaña J.J. ve Sesé, A. (2005). Designing An Artificial Neural Network For Forecasting Tourism Time Series. *Tourism Management*, 26 (1): 1-10.
- Pattie, D.C. ve Snyder, J. (1996). Using a Neural Network to Forecast Visitor Behavior. *Annals of Tourism Research*, 23 (1): 151-164.
- Rumelhart, D.E., Hinton, G.E. & Williams, R.J. (1986). Learning Representations By Back-Propagating Errors, *Nature*, (323): 533 – 536.
- Sağiroğlu, Beşdok, E ve Erler, M. (2003). Mühendislikte Yapay Zeka Uygulamaları - I: Yapay Sinir Ağları, Ufuk Yayıncılık, Kayseri.
- Sharda, R. ve Patil, R.B. (1992). Connectionist Approach to Time Series Prediction: An Empirical Test. *Journal of Intelligent Manufacturing*, (3): 317-323.
- Smith, A.K. (2002). *Neural Networks for Business: An Introduction*, SMITH, A.K. & GUPTA, J. (der.) *Neural Networks in Business: Techniques and Applications*: 1-24. Hershey: Idea Group Publishing.
- Trippi, R.R. ve Turban, E. (1996). *Neural Networks in Finance And Investing: Using Artificial Intelligence to Improve Real-World Performance*. (Revised Edition), IRWIN Professional Publishing.
- Türkiye İstatistik Kurumu, (2013). Haber Bülteni, Turizm İstatistikleri Revize Sonuçları, 2001-2012 (14 Şubat 2013).
- Türe, M. ve Kurt, İ. (2005). Hepatit A Virüs Enfeksiyonunun İleriye Yönelik Tahmin Edilmesinde Dört Farklı Zaman Serisi Yönteminin Karşılaştırılması, VIII. Ulusal Biyoistatistik Kongresi, Bursa.
- Uysal, M. ve El Roubi, S. (1999). Artificial Neural Network Versus Multiple Regression in Tourism Demand Analysis. *Journal of Travel Research*, 38 (2): 111-118
- Waibel, A. (1989). Modular Construction of Time-Delay Neural Networks for Speech Recognition, *Neural Computation*, (1) 39-46
- Witt, S. F. ve Witt C. (1992). *Modeling and Forecasting Demand in Tourism*. London: Academic Press.
- Wong, B. K., Jiang, L. ve Lam, J. (2000). A Bibliography of Neural Network Business Application Research: 1994-1998. *Computers and Operations Research*, 27 (11): 1045-1076.
- World Travel & Tourism Council - WTTC (2012): *Travel & Tourism Economic Impact 2012 Turkey*.
- Yıldız, B. (2009). *Finansal Analizde Yapay Zeka*. Ankara: Detay Yayıncılık.

Zhang, G.P. (2004). Business Forecasting with Artificial Neural Networks: An Overview. İçinde, Zhang, G.P. (der.) *Neural Networks in Business Forecasting*: 1-22. Hershey: Idea Group Publishing.

Zhang, G.P. and Qi, M. (2005). Neural Network Forecasting For Seasonal And Trend, *European Journal of Operational Research*, 160 (2): 501-514.

Zhang, G.P. and Kline, D.M. (2007). Quarterly Time-Series Forecasting With Neural Networks. *IEEE Transactions On Neural Networks*, 18 (6): 1800-1814