

Yapay Sinir Ağları Kullanılarak Konaklama İşletmelerinde Doluluk Oranı Tahmini: Türkiye'deki Konaklama İşletmeleri Üzerine Bir Deneme

*Occupancy Rate Forecasting in Lodging Properties by Using Artificial Neural Networks:
An Experimental Study of Lodging Properties in Turkey*

Murat ÇUHADAR * - Cengiz KAYACAN **

* Süleyman Demirel Üniversitesi Eğirdir Meslek Yüksekokulu

** Süleyman Demirel Üniversitesi Mimarlık Mühendislik Fakültesi

ÖZ

Yapay sinir ağları, insan beyninin çalışma ilkelerinden hareketle geliştirilmiş bilgisayar programlarıdır. Bu çalışmada, yapay sinir ağı kullanılarak Türkiye'deki bakanlık belgeli konaklama işletmelerindeki, dış turizm talebi ile oluşan doluluk oranları tahmin edilmiştir. Çalışmada Turizm Bakanlığı tarafından yıllık olarak yayınlanan "Konaklama İstatistikleri" bültenlerinden elde edilen "1990 – 2002" yıllarına ait aylık verilerden yararlanılmıştır. Çalışma neticesinde gerçek değerlere çok yakın tahmin değerleri ve çok düşük hata oranları elde edilmiştir. Çalışmanın Türk turizm literatürüne katkısı, konaklama işletmelerinde doluluk oranlarının tahmininde yeni bir yöntemi bir uygulama ile göstermektir. İleriye yönelik yapılacak çalışmalarda, yapay sinir ağları ile farklı değişkenleri kullanarak belirli bir bölge veya il sınırları içerisinde faaliyet gösteren konaklama işletmelerindeki doluluk oranları, yerli ve yabancı konukların konaklama işletmelerindeki harcamaları, turistlerin geceleme sayıları ve ortalama kalış süreleri tahmin edilebilir.

Anahtar sözcükler: Yapay sinir ağları, konaklama işletmeleri, doluluk oranı tahmini

ABSTRACT

Artificial neural networks are the computer programmes which are developed on the basis of the functioning principles of the human brain. The hotel properties that are licensed by the Turkish Tourism Ministry are included in this study. By using artificial neural networks, hotel property occupancy rates that are generated by foreign tourism demand are forecasted. The present study uses annual data that are published yearly by the Turkish Ministry of Tourism and covers the period between 1990 and 2002. The results indicate that forecasted values are very close to real values and these forecasts are accompanied by very low error rates. The contribution of the study to Turkish tourism literature is that it shows how a new method can be applied in forecasting occupancy rates in accommodation establishments. It is proposed that by using artificial neural networks future studies may forecast various other variables such as, domestic and foreign tourist expenditures, average length of stay and number of nights spent. In addition, future studies can forecast occupancy rates of accommodation establishments which operate in a specific city or a region.

Keywords: Artificial neural networks, lodging properties, occupancy rate forecasting

GİRİŞ

Çağdaş toplumlarda, toplumsal olayların gelecekteki eğilimlerini ve gelişme yönlerini tahmin etmek ve bilimsel yöntemlerle ölçmek bir zorunluluktur. Bilimsel temele dayanan yöntemlerle turizmdeki gelişmelerin tahmin edilmesi, yönetici durumunda bulunanların karar almalarını da kolaylaştıran bir olanaktır. Bu sayede, ekonomide esnek gelişme planlarının hazırlanması mümkün olacak ve yatırımcıların tahsis edeceği kaynakların israfının önlenmesi gibi konularda gerekli önlemler zamanında alınabilecektir. Turizm endüstrisi de ülkedeki diğer

ekonomik sektörler gibi güvenilir verilere dayanan doğru tahminlere ihtiyaç duyar. Turizm sektöründe turistik mal ve hizmetlere yönelik talebin etken faktörlere karşı aşırı duyarlı olması, bu sektördeki tahminleri ve talep üzerinde etkili olan faktörlerin analizini daha önemli duruma getirmektedir (İçöz ve Kozak 1998: 281). Otel işletmeleri zaman içinde değişen bir taleple karşı karşıyadır. Talep mevsimlik, aylık, haftalık ve günlük olarak değişim göstermektedir. Ayrıca konaklama talebi ekonomik, sosyal ve siyasi değişkenlere bağlı olarak da değişkenlik göstermektedir (Emeksiz 2002: 20). Geleceğin iyi tahmin edilmesi; geleceğe hazır olmak için gerekli

planlamanın yapılması ve politikaların belirlenip kararların alınmasına temel oluşturmaktadır (Orhunbilge 1999: 1). Athiyaman ve Robertson'a göre; tahmin, planlama yapmanın en temel gereksinimidir (Athiyaman ve Robertson 1992: 8). Otel yönetiminin önemli bir bölümünü oluşturan tahmin ve planlama çalışmaları; işletme amaçlarının olanaklı ve ulaşılabilir olması konularında kararların alınmasını içermektedir (Law 2000: 19).

Doluluk oranı, bir otel işletmesinin temel ürünü olup gelirlerinin önemli bir kısmını oluşturan odalarını satmadaki başarısını ölçer. Doluluk, aynı zamanda otel yönetiminin planlama ve denetim işlevlerini yerine getirmesinde en önemli anahtardır. Planlama çalışmaları dolu oda sayısının ve elde edilecek gelirin tahmin edilmesiyle başlar. Daha sonra doluluğa bağlı olarak tahmini işgören ihtiyacı belirlenir, tahmini ısı ve aydınlatma maliyetleri belirlenir, tahmini kuver sayısı bulunur. Böylece tüm otelin tahmini gelirinin ve maliyetlerinin bulunması kolaylaşır (Emeksiz 2002: 115). Doğru doluluk oranlarının tahmini, otel yöneticilerine, stratejik, taktik ve operasyonel planlamada yardımcı olduğu gibi karar alma süreçlerini de güçlendirmektedir (Law 1998: 234). Otel işletmelerinde doluluk oranları oda doluluk oranı ve yatak doluluk oranı olmak üzere iki şekilde hesaplanır. Oda doluluk oranı; satılan oda sayısının satışa hazır oda sayısına bölünmesiyle, yatak doluluk oranı ise; satılan yatak sayısının satışa hazır yatak sayısına bölünmesiyle elde edilir ve yüzde olarak ifade edilir. Bu oranlar günlük, haftalık, aylık ve yıllık olarak hesaplanırlar (Kozak 1998: 118). Bu çalışmada, doluluk oranı olarak Turizm Bakanlığı tarafından yayınlanan aylık yatak doluluk oranları kullanılmıştır.

Bu çalışmanın amacı, Türkiye'de Kültür ve Turizm Bakanlığı'ndan yatırım ve işletme belgeli konaklama işletmelerinin, dış turizm talebi ile oluşan doluluk oranlarının yapay sinir ağı kullanılarak tahmin edilmesidir. Çalışma, Türkiye'de, yapay sinir ağları kullanılarak genelde turizm, özelde konaklama işletmelerinde doluluk oranının tahmini alanında gerçekleştirilen öncü bir çalışma niteliğindedir. Çalışmanın Türk turizm literatürüne katkısı, konaklama işletmelerinde doluluk oranlarının tahmininde yeni bir yöntemi bir uygulama ile göstermektedir.

YAZIN TARAMASI

Turizm alanında yaygın olarak kullanılan tahmin yöntemleri başlıca iki grupta toplanabilir. Bunlar; kalitatif (niceliksel) yöntemler ve kantitatif (sayısal) yöntemlerdir. Bu yöntemlerin kendi içlerinde sınıflandırılması da aşağıdaki şekilde yapılmaktadır;

1. Niteliksel (Kalitatif) Yöntemler

- Geleneksel anket yöntemi
- Delphi yöntemi
- Çoklu kararlar desteklenmiş model

2. Sayısal (Kantitatif) Yöntemler

- Zaman serileri ve trend analizi
- Bilgisayar sistemleri ve simülasyon yöntemi
- Turist çekme ve talep yaratma modelleri
- Çok değişkenli regresyon analizleri

Bu sınıflama içerisinde, turist çekme ve talep yaratma modelleri ile çok değişkenli regresyon analizleri turistik hareketlerdeki neden-sonuç ilişkilerine bağlı olup, turist akımlarını etkileyen değişkenlerin sayısal olarak açıklanması amacına yöneliktir. Genel olarak sayısal yaklaşımların girdisi, çeşitli zaman aralıklarında toplanmış olan verilerdir. Buna karşılık niteliksel yaklaşımlar, konu ile ilgili uzmanların bilgi ve deneyimlerinden yararlanarak bu alandaki gelişmelerin ne yönde olacağı, ne tür ihtiyaçlar ortaya çıkaracağı gibi konularda yoğunlaşır. Bu yöntemler çoğunlukla, geçmişe yönelik yeterli istatistiksel verilerin bulunmadığı ya da toplanamadığı ya da sayısal yaklaşımların uygulanmadığı durumlarda kullanılır (İçöz ve Kozak 1998: 282 - 283).

Turizm alanında yaygın olarak kullanılan istatistiksel tahmin yöntemlerine alternatif olarak son yıllarda yapay sinir ağlarından yararlanılarak tahmin çalışmalarının yapıldığı görülmektedir. Konu ile ilgili literatür taraması neticesinde, gelişmiş ülkelerde yapay sinir ağları kullanılarak turizmde talep, geceleme sayısı, turist harcamaları ve doluluk oranı tahminleri ile ilgili çalışmaların sık yapıldığı fakat Türkiye'de bu konudaki çalışmaların oldukça sınırlı kaldığı görülmektedir. Pattie ve Snyder; Amerika'daki milli parkları ziyaret eden ziyaretçi sayısını (Pattie ve Snyder: 1996), Law ve Au; Hong Kong'a yönelik Japon turizm talebini (Law ve Au: 1999), Law; Hong Kong'da faaliyet gösteren otel işletmelerinin oda doluluk oranlarını (Law: 1998), Uysal ve El Roubi; A.B.D.'yi ziyaret eden Kanada'lı turistlerin gelecekteki turizm harcamalarını (Uysal ve El Roubi: 1999), Law; Hong Kong'u ziyaret eden yabancı turistlerin otel içindeki harcamalarını, (Law: 2000), Burger ve arkadaşları; Durban'a (G. Afrika) yönelik Amerikalı turist talebini (Burger vd. 2001), Law; hata geriye yayma yöntemi ile Hong Kong'u ziyaret edecek Tayvanlı turist sayısını (Law: 2000), Ahmed ve Cross; Avustralya'daki otel işletmelerinde kalacak turistlerin geceleme sayısını (Ahmed ve Cross: 1999), Cho; Hong Kong'a yönelik dış turizm

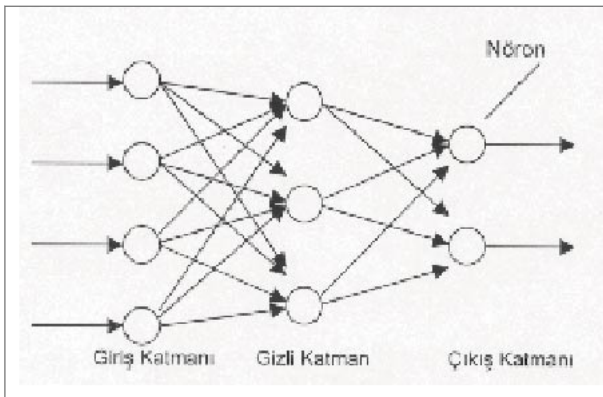
talebini (Cho: 2003), Tsaur, Chiu ve Huang; iş amaçlı seyahat eden ve uluslar arası otellerde konaklayan turistlerin kaldıkları otellerde tekrar konaklama eğilimlerini (Tsaur, Chiu ve Huang: 2002), tahmin etmeye çalışmışlardır.

YAPAY SİNİR AĞLARI

Yapay sinir ağları, insan beyninden esinlenerek geliştirilmiş, ağırlıklı bağlantılar aracılığıyla birbirine bağlanan ve her biri kendi belleğine sahip işlem elemanlarından oluşan paralel ve dağıtılmış bilgi işleme yapılarıdır. Yapay sinir ağları, bir başka deyişle, biyolojik sinir ağlarını taklit eden bilgisayar programlarıdır (Elmas 2003: 23).

Yapay sinir ağının yapısında, nöron (Yapay sinir hücresi), bağlantılar ve öğrenme algoritması olmak üzere üç bileşen bulunur. Nöron, bir yapay sinir ağının temel işlem elemanıdır. Ağ içerisinde yer alan nöronlar, probleme etki eden faktörlere göre bir veya bir den fazla girdi alırlar ve problemden beklenen sonuç sayısı kadar çıktı verirler. Nöronların birbirleriyle bağlantılar aracılığıyla bir araya gelmeleri yapay sinir ağını oluşturmaktadır (Şekil 1). Genel bir yapay sinir ağı sisteminde nöronların aynı doğrultu üzerinde bir araya gelmeleri katmanları oluşturur (Yıldız 2001: 54).

Bir yapay sinir ağında, birbirleriyle bağlantılı sinir hücrelerinin yer aldığı girdi katmanı (input layer), çıktı katmanı (output layer) ve gizli katman (hidden layer) olmak üzere temelde üç katman bulunmaktadır. Girdi katmanı ilk katmandır ve dışarıdan gelen verilerin yapay sinir ağına alınmasını sağlar. Bu veriler istatistikte bağımsız değişkenlere karşılık gelmektedir. Girdi katmanı probleme etki eden parametrelerden oluşmaktadır ve girdi katmanındaki nöron sayısı parametre sayısına göre şekillenmektedir. Son katman çıktı katmanı olarak adlandırılır ve bilgilerin dışarıya iletilmesi işlevini



Şekil 1. Yapay sinir ağı modeli

görür. Çıktı değişkenleri, istatistikte bağımlı değişkenlere karşılık gelir. Modeldeki diğer katmanlar ise girdi katmanı ile çıktı katmanı arasında yer alır ve gizli katman olarak adlandırılır. Gizli katmanda bulunan nöronların dış ortamla bağlantıları yoktur. Yalnızca girdi katmanından gelen sinyalleri alırlar ve çıktı katmanına sinyal gönderirler. Gizli katman ve gizli katman(lar)da yer alacak nöronların sayısının seçimi, kurulan ağın performansı açısından önemlidir (Benli 2002: 19).

Yapay sinir ağları, klasik bilgisayar belleği gibi belirli bilgileri belirli yerlerde saklama yerine öz şeklindeki bilgileri nöronlar arasındaki bağlantılar üzerindeki (rassal sayı olarak) ağırlık değerleri ile ağ üzerinde dağıtarak saklarlar. Belirli bir problemi, programlama yerine direkt olarak mevcut örnekler üzerinden eğitilerek öğrenirler (Baylar vd. 1999: 3). Bir ağda öğrenme kısaca, istenen bir işlevi yerine getirecek şekilde ağırlıkların ayarlanması sürecidir. Temelde öğrenme yöntemleri danışmanlı (supervised) ve danışmansız (unsupervised) olmak üzere iki gruba ayrılmıştır. Danışmanlı öğrenmede, yapay sinir ağı kullanılmadan önce eğitilmelidir. Eğitime işlemi, sinir ağına giriş ve çıkış bilgileri sunmaktan oluşur. Ağ giriş bilgisine göre ürettiği çıkış değerini, istenen değerle karşılaştırarak ağırlıkların değiştirilmesinde kullanılacak bilgiyi elde eder. Girilen değerle istenen değer arasındaki fark hata değeri olarak önceden belirlenen değerden küçük oluncaya kadar eğitime devam edilir. Hata değeri istenen değer altına düştüğünde tüm ağırlıklar sabitlenerek eğitim işlemi sonlandırılır. Danışmansız öğrenmede sistemin doğru çıkış hakkında bilgisi yoktur ve girişlere göre kendi kendisini örnekler. Danışmansız olarak eğitilebilen ağlar, istenen ya da hedef çıkış olmadan giriş bilgilerinin özelliklerine göre ağırlık değerlerini ayarlar (Elmas 2003: 96-149).

İleri Beslemeli (Feed Forward) Yapay Sinir Ağları

İleri beslemeli yapay sinir ağlarında, hücreler katmanlar şeklinde düzenlenir ve bir katmandaki hücrelerin çıkıştan bir sonraki katmana ağırlıklar üzerinden giriş olarak verilir. Giriş katmanı, dış ortamlardan aldığı bilgileri hiçbir değişikliğe uğratmadan orta (gizli) katmandaki hücrelere iletir. Bilgi, orta ve çıkış katmanında işlenerek ağ çıkışı belirlenir (Alataş 2003: 10) Giriş ve çıkış katmanlarındaki nöron sayıları ele alınan problemin gereklerine göre belirlenir, ancak gizli katmandaki (veya katmanlardaki) nöron sayısının optimallik anlamında doğru sayısını veren herhangi bir analitik yöntem şu ana kadar geliştirilememiştir. Dolayısıyla gizli katman sayısındaki ve bu katmanların nöron sayısındaki

belirsizlikleri aşabilmenin tek yolu, deneme yanılma yöntemidir. (Efe ve Kaynak 2000: 13)

Hata Geriye Yayma (Back Propagation) Yöntemi İle Parametre Güncelleme

Yapay sinir ağlarının parametrelerinin güncellenmesi için literatürde en çok kullanılan yöntem hata geriye yayma yöntemidir. Ses tanıma problemlerinden sistem tanılama ve denetimi problemlerine kadar yapay sinir ağları ile çözüm üretilen bir çok alanda başarı ile kullanılan bu yöntem, kuadratik bir maliyet fonksiyonunun zaman içerisinde, ağ parametrelerinin uyarlanması ile minimizasyonu dayandırmaktadır. (Efe ve Kaynak 2000: 15)

Yapay sinir ağları, her türlü bilgiyi işlemek ya da analiz etmek amacıyla kullanılırlar. İş hayatı, finans, endüstri, eğitim ve karışık problemler bilim alanlarında, bulanık veya mevcut yöntemlerle çözülemeyen problemlerin çözümünde, doğrusal olmayan sistemlerde başarıyla uygulanmaktadır (Elmas 2003: 26). Geleneksel yöntemler, yanlış sonuçların elde edilmesi riski nedeniyle eksik ve/veya aşırı sapma içeren veriler için uygun değildir. Yapay sinir ağı yaklaşımı ise, verilere bağlı olmayıp; eksik, kısmen hatalı veya aşırı sapmalı verileri değerlendirebilir, hatta karmaşık ilişkileri öğrenebilir, genellebilir ve bu sayede daha önce hiç karşılaşmadığı sorulara kabul edilebilir bir hatayla cevap bulabilirler. Bu özellikleri nedeniyle yapay sinir ağları tahminlemede etkili bir yöntem olarak kullanılmaktadır (Özalp ve Anagün 2003: 30).

YÖNTEM

Çalışmada, Kültür ve Turizm Bakanlığı tarafından yıllık olarak yayınlanan "Konaklama İstatistikleri" bültenlerinden elde edilen "1990 – 2002" yıllarına ait aylık verilerden yararlanılmıştır. Verilerin gruplandırılmasında "Cross Validation" tekniği uygulanmıştır. Çalışmada kullanılan 144 aylık verinin, % 80'i eğitim, % 20'si de test verisi şeklinde rassal olarak gruplandırılmış ve üç farklı veri seti oluşturulmuştur. Aynı veriler hem test hem de eğitim setinde kullanılmamıştır. Her bir veri seti için ayrı ağ kurulmuştur. Çalışmada test için kullanılan veriler Tablo 1.de gösterilmiştir.

Türkiye'deki konaklama işletmelerinin aylık doluluk oranları (Doluluk); Türkiye'deki bakanlık belgeli konaklama işletmelerinin aylar itibariyle toplam sayısı (Tesis), Türkiye'deki bakanlık belgeli konaklama tesislerindeki aylık yatak sayısı (Yatak), Türkiye'deki bakanlık belgeli konaklama işletmelerinde konaklayan yabancı turistlerin aylık olarak toplam sayısı (K. Turist), Türkiye'deki bakanlık bel-

geli konaklama işletmelerinde konaklayan yabancı turistlerin aylık olarak toplam geceleme sayısı (Geceleme) ve Türkiye'deki bakanlık belgeli konaklama işletmelerinde konaklayan yabancı turistlerin aylık olarak ortalama kalış süresinin (Ort. Kalış) bir fonksiyonu olarak düşünülmüştür (Tablo 1). Modelin fonksiyon olarak ifadesi aşağıdaki gibidir.

$$Dor = f(Tes, Yas, Kos, Ges, Oks)$$

Problemin yapay sinir ağı ile modellenmesinde öncelikle girdi ve çıktı değişkenleri ile giriş ve çıkış katmanlarında yer alacak parametreler belirlenmiştir. Modelde 5 girdi değişkeni (*Tes*, *Yas*, *Kos*, *Ges*, *Oks*) ile bir çıktı değişkeni (*Dor*) bulunmaktadır. Buna göre giriş katmanında yer alan değişkenler şöyledir;

Tes: Türkiye'deki bakanlık belgeli tesislerin aylık olarak sayısı,

Yas: Türkiye'deki bakanlık belgeli konaklama tesislerinin aylık olarak sahip olduğu yatak sayısı,

Kos: Türkiye'deki bakanlık belgeli konaklama işletmelerinde konaklayan yabancı turistlerin aylık olarak toplam sayısı,


Ges: Türkiye'deki bakanlık belgeli konaklama işletmelerinde konaklayan yabancı turistlerin aylık olarak toplam geceleme sayısı,

Oks: Türkiye'deki bakanlık belgeli konaklama işletmelerinde konaklayan yabancı turistlerin aylık olarak ortalama kalış süresi,

YSA modeli çıkış katmanında yer alan değişken ise;

Dor: Türkiye'deki bakanlık belgeli konaklama işletmelerinde konaklayan yabancı turistlerin oluşturduğu aylık doluluk oranı, olarak belirlenmiştir.

Şekil 2, çalışmada kullanılan yapay sinir ağı modelini temsil etmektedir. Modelde bir giriş katmanı, iki gizli katman ve bir çıkış katmanı bulunmaktadır. Giriş katmanında beş, birinci gizli katmanda



Şekil 2. Çalışmada kullanılan doluluk oranı yapay sinir ağı modeli

beş, ikinci gizli katmanda üç, çıkış katmanında ise bir nöron bulunmaktadır. Doluluk oranı yapay sinir ağı modelinin eğitimi, Matlab (Sürüm 6.1) bilgisayar paket programı ile gerçekleştirilmiştir. Çalışmada "İleri sürümlü" yapay sinir ağı modeli kullanılmış, modeldeki parametrelerin güncellenmesi için "Hata geriye yayma" yönteminden yararlanılmıştır. Transfer fonksiyonu olarak "Transfer Sigmoid", eğitim fonksiyonu olarak "Trainlm" seçilmiştir. Performans fonksiyonu olarak ise "MSE" (Hata Kareleri Ortalaması) seçilmiştir. Veriler, Matlab programına girilirken normalizasyona tabi tutulmuş, verilerin 0 ile 1 arasında bir değer alabilmesi için tüm veriler eldeki en büyük sayıdan daha büyük bir sayıya bölünerek elde edilen rakamlar bilgisayara girilmiştir. Kurulan yapay sinir ağının eğitimi için 10000 iterasyon gerçekleştirilmiştir.

BULGULAR

Bu çalışmada, ileri sürümlü yapay sinir ağı ile Türkiye'deki bakanlık belgeli konaklama işletmelerindeki, dış turizm talebi ile oluşan yatak doluluk oranları tahmin edilmiştir. Modelden elde edilen aylık tahmini doluluk oranları ile gerçekleşen doluluk oranları, Tablo 2.'de verilmiştir. Tablodan da görüldüğü gibi yapay sinir ağı modelinden elde edilen tahmin değerleri, gerçek değerlere oldukça yakındır.

Tahmin sonuçlarının doğruluğunun ölçümünde, *MSE* (Hata Kareleri Ortalaması), *RMSE* (Hata Kareleri Ortalamasının Karekökü) ve *MAPE* (Mutlak Hata Oranları Ortalaması) tekniklerinden yararlanılmıştır. Ölçümlerin istatistiksel ifadesi aşağıda verilmiştir (Cho 2003: 328, De Lurgio 1998: 53).

Tablo 1. Çalışmada kullanılan test verileri

Yıl	Ay	Doluluk (%)	Tesis	Yatak	K. Turist	Geceme	Ort. Kalış
1990	Mart	13,92	743	90582	133970	390793	2,92
1990	Temmuz	49,47	1057	139641	505023	2141608	4,24
1991	Şubat	5,01	721	91729	43314	128657	2,97
1991	Mayıs	18,01	1117	154642	224545	863286	3,84
1991	Ekim	26,51	1020	140876	275017	1157840	4,21
1992	Ağustos	53,27	1306	192087	581662	2892987	4,97
1992	Kasım	13,47	809	113977	136627	436550	3,20
1993	Nisan	28,71	1284	198031	434682	1538853	3,54
1993	Haziran	41,68	1436	217431	512994	2418354	4,71
1993	Aralık	10,87	877	125512	134606	382091	2,84
1994	Ocak	9,77	945	135420	119526	383173	3,21
1994	Temmuz	32,61	1556	241868	451486	2205877	4,89
1994	Eylül	37,16	1564	242874	510927	2444832	4,79
1995	Mart	19,00	1090	168133	238440	750319	3,15
1995	Ağustos	47,61	1662	268788	648708	2944265	4,54
1995	Kasım	20,91	1065	166064	264283	780013	2,95
1996	Mayıs	38,76	1674	276323	668768	2918144	4,36
1996	Temmuz	44,28	1708	280015	747809	3374929	4,51
1997	Ocak	19,74	1226	185594	362845	1135655	3,13
1997	Haziran	46,89	1882	307689	972504	4327917	4,45
1997	Eylül	48,89	1916	312387	1155219	4582134	3,97
1998	Eylül	42,57	1975	321543	950996	4216612	4,43
1998	Aralık	13,61	1334	201679	310468	852649	2,75
1999	Nisan	10,26	1772	303634	328437	945553	2,88
1999	Eylül	25,56	2009	332534	529475	2585032	4,88
2000	Şubat	6,54	1340	213466	218813	632662	2,90
2000	Ağustos	42,68	1911	330824	941042	4416559	4,70
2001	Mayıs	41,03	1892	348107	1026180	4427394	4,30
2001	Ekim	36,87	1809	335759	781660	3837803	4,90

Tablo 2. Gerçekleşen ve tahmin edilen aylık doluluk oranları

Aylar	Gerçekleşen Doluluk Oranları (%)	Tahmin Edilen Doluluk Oranları (%)
Mart	13,92	14,06
Temmuz	49,47	47,70
Şubat	5,01	4,85
Mayıs	18,01	19,09
Ekim	26,51	26,40
Ağustos	53,27	55,33
Kasım	13,47	13,27
Nisan	28,71	26,14
Haziran	41,68	40,14
Aralık	10,87	11,10
Ocak	9,77	10,30
Temmuz	32,61	35,14
Eylül	37,16	38,66
Mart	19,00	16,67
Ağustos	47,61	40,73
Kasım	20,91	19,17
Mayıs	38,76	40,36
Temmuz	44,28	41,57
Ocak	19,74	19,93
Haziran	46,89	47,97
Eylül	48,89	50,93
Eylül	42,57	44,67
Aralık	13,61	13,50
Nisan	10,26	10,72
Eylül	25,56	25,59
Şubat	6,54	7,65
Ağustos	42,68	43,77
Mayıs	41,03	41,77
Ekim	36,87	35,96

$$MSE = \frac{\sum (y_1 - y_2)^2}{n}$$

$$RMSE = \sqrt{\frac{\sum (y_1 - y_2)^2}{n}}$$

$$MAPE = \frac{\sum \left| \frac{y_1 - y_2}{y_1} \right|}{n} * 100 (\%)$$

Burada;

y_1 = Gerçek değerler,

y_2 = Tahmin değerler,

n = Gözlem sayısıdır.

Modelden elde edilen tahmin değerleri ile gerçek değerler üzerinde yapılan ölçümlerde, MSE= 3,6

RMSE= 1,9 MAPE= % 4,7 bulunmuştur. Elde edilen düşük MSE, RMSE ve MAPE değerleri, gerçek doluluk oranları ile yapay sinir ağı modelinden elde edilen tahmin sonuçları arasındaki sapmaların çok küçük olduğunu göstermektedir. Witt ve Witt, MAPE değerleri % 10'un altında olan tahmin modellerini "yüksek doğruluk" derecesine sahip, % 10 ile % 20 arasında olan modelleri ise doğru tahminler olarak sınıflandırmıştır (Witt ve Witt 2000: 25). Benzer şekilde Lewis, MAPE değeri %10'un altında olan modelleri "çok iyi", % 10 ile % 20 arasında olan modelleri "iyi", % 20 ile % 50 arasında olan modelleri "kabul edilebilir" ve % 50'nin üzerinde olan modelleri ise "yanlış ve hatalı" olarak sınıflandırmıştır (Lewis 2002: 509).

SONUÇ VE ÖNERİLER

Yöneticiler örgütsel amaçlara ulaşmak için; insan, para, malzeme, enerji ve donanım gibi sınırlı kaynakları kullanırlar. Bir otel yöneticisinin en önemli görevlerinden birisi de işletme amaçlarına ulaşmak için bu kaynakların nasıl kullanılması gerektiğini planlamaktır. Planlama fonksiyonu işletmenin amaç ve hedeflerine ulaşmasına hizmet etmektedir. Bu nedenle geçmiş bilgilerin incelenmesi, gerçek durumun belirlenmesi ve geleceğe yönelik tahminlerin doğru olarak yapılması büyük önem arzeder (Kozak 1998: 108-109). Bu yönde bilimsel olarak yapılmış çalışmalarla alınacak ve uygulanacak kararların desteklenmesi, amaçların gerçekleştirilmesini kolaylaştıracağı bir gerçektir (Uysal 1985: 35).

Bu çalışma, yapay sinir ağıları kullanılarak Türkiye'deki konaklama işletmelerinde doluluk oranlarının tahmin edilmesinde başlangıç niteliğindedir. Çalışma, yapay sinir ağıları kullanılarak konaklama işletmelerinde doluluk oranlarının tahmin edilebileceğini, dolayısıyla turizm sektöründeki uygulamacılar ve karar verme konumunda olan yöneticilerin, geleceğe yönelik planlama çalışmalarında geleneksel tahmin yöntemlerine alternatif olarak yapay sinir ağılarını kullanabileceklerini ortaya koymaktadır. Çalışmada doluluk oranı tahmininde, beş açıklayıcı değişken kullanılmıştır. Gelecekteki araştırmalarda, daha fazla değişken veya çalışmada kullanılan bu beş değişken dışındaki değişkenleri kullanarak doluluk oranı tahminleri yapılabilir. Örneğin; döviz kurları, kişi başına harcanabilir gelir, ülkeler arası karşılaştırmalı fiyat endeksleri, ortalama konaklama fiyatları, turist gönderen ülkelerdeki GSMH, yapılan tanıtma ve pazarlama harcamaları; doluluk oranlarında ve ülkeye gelen turist sayısının belirlenmesinde önemli rol oynayabilmektedir. İleriye yönelik yapılacak çalışmalarda;

yapay sinir ağları kullanılarak belirli bir bölge veya il sınırları içerisinde (örneğin Antalya ve çevresinde) faaliyet gösteren konaklama işletmelerindeki doluluk oranları, yerli ve yabancı konukların konaklama işletmelerindeki harcamaları, turistlerin geceleme sayıları ve ortalama kalış sürelerine ilişkin tahminler yapılabilir. Sayılan bu tahmin çalışmaları, turizm işletmeleri yöneticilerine ve yerel yönetimlere, ileriye yönelik karar alma ve planlama çalışmalarında yol gösterici olacaktır.

KAYNAKÇA

- Alataş, B. (2003). Sinirsel Ağlar, www.firat.edu.tr/akademik/fakulteler/muhendislik/bilgisayar/balatas/Sinirselaglar.pdf
- Athiyaman, A., Robertson, R.W. (1992). Time Series Forecasting Techniques: Short-Term Planning in Tourism, *International Journal of Contemporary Hospitality Management*, 4 (4): 8-11.
- Baylar, A., Emiroğlu, M.E., Arslan A. (1999). Geriye Yayılma Yapay Sinir Ağı Kullanılarak Yanal Su Alma Yapısına Yönelcek Olan Sürüntü Maddesi Oranının Bulunması, *Dokuz Eylül Üniversitesi Fen ve Mühendislik Dergisi*, 1 (2): 1-12.
- Benli, Y. (2002). Finansal Başarısızlığın Tahmininde Yapay Sinir Ağı Kullanımı ve İMKB'de Bir Uygulama, *Muhasebe Bilim Dünyası Dergisi*, 4 (4): 17-30.
- Burger, M., D., 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.
- Carey, G. ve Raw, L. (2002). Modeling and Forecasting Tourism Demand for Arrivals with Stochastic Nonstationary Seasonality and Intervention, *Tourism Management*, 23 (5): 499-510.
- Cho, V. (2003). A comparison of Three Different Approaches to Tourist Arrival Forecasting, *Tourism Management*, 24 (3): 323-330.
- De Lurgio, A. S. (1998). Forecasting Principles and Applications, Irwin Mc Graw-Hill: Singapore
- Elmas, Ç. (2003). Yapay Sinir Ağları (Kuram, Mimari, Eğitim, Uygulama). Ankara: Seçkin Yayıncılık.
- Efe, Ö. ve Kaynak, O. (2000). *Yapay Sinir Ağları ve Uygulamaları*. İstanbul: Boğaziçi Üniversitesi Yayını No: 696.
- Emeksiz, M. (2002). *Beş Yıldızlı Otel İşletmeleri için Getiri Yönetimi Uygulama Modeli*. Eskişehir: Anadolu Üniversitesi Yayınları, No: 1337.
- İçöz, O. ve Kozak, M. (1998). *Turizm Ekonomisi*. Ankara: Turhan Kitabevi.
- Kozak, S. (1998). *Otel İşletmelerinde Önbüro Yönetimi*. Eskişehir: Anadolu Üniversitesi Yayınları, No: 868.
- Keiser, J.R. (1989). *Principles and Practises of Management in the Hospitality Industry*. New York: Van Nostrand Reinhold.
- Law, R. ve Au, N. (1999). A Neural Network Model to Forecast Japanese Demand for Travel to Hong Kong, *Tourism Management*, 20 (1): 89-97.
- Law, R. (2000). Back-propagation Learning in Improving the accuracy Of Neural Network-based Tourism Demand Forecasting, *Tourism Management*, 21 (4): 331-340.
- Law, R. (2000). Demand for Hotel Spending by Visitors to Hong Kong: A Study of Various Forecasting Techniques, *Journal of Hospitality & Leisure Marketing*, 6 (4): 17-29.
- Law, R. (1998). Room Occupancy Rate: A Neural Network Approach, *International Journal of Contemporary Hospitality Management*, 10 (6): 234-239.
- Lewis, C.D. (1982). *Industrial and Business Forecasting Methods*. Londra: Butterworths Publishing.
- Orhunbilge, N. (1999). *Zaman Serileri Analizi Tahmin ve Fiyat Endeksleri*. İstanbul: Avcıol Basım Yayın.
- Özalp, A. ve Anagün, S. (2003). Yapay Sinir Ağı Performansına Etki Eden Faktörlerin Analizinde Taguchi Yöntemi: Hisse Senedi Fiyat Tahmini Uygulaması, *İstatistik Araştırma Dergisi*, 2 (1): 29-45.
- Pattie, D. C., Snyder, J. (1996). Using a Neural Network To Forecast Visitor Behavior, *Annals of Tourism Research*, 23 (1): 151-164.
- Shamsuddin, A. ve James, C. (1999). A Tourist Growth Model to Predict Accommodation Nights Spent in Australian Hotel Industry, *Annual Colloquium of the Spatial Information Research Centre*, University of Otago, Dunedin, New Zealand, December 13-15th.
- Sheng-Hshiang, T., Yi-Chang, C. ve Chung-Huei, H. (2002). Determinants of Guest Loyalty to International Tourist Hotels - A Neural Network Approach, *Tourism Management*, 23 (4): 397-405.
- Turizm Bakanlığı (2004). Turizm ve Konaklama İstatistikleri. Ankara: Araştırma ve Değerlendirme Daire Başkanlığı.
- Uysal, M. (1985). Turizmde Talep Projeksiyon Modelleri ve Özellikleri, *Turizm Yıllığı*, T.C. Turizm Bankası A.Ş.: Ankara.
- 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.
- Witt, S.F. ve Witt, C.A. (1992). *Modeling and Forecasting Demand in Tourism*. Londra: Academic Press.
- Yıldız, B. (2001). Finansal Başarısızlığın Öngörülmesinde Yapay Sinir Ağı Kullanımı ve Halka Açık Şirketlerde Ampirik Bir Uygulama, *İMKB Dergisi*, 5 (17): 51-67.

Gönderilme tarihi : Ocak 2004
Birinci düzeltme : Mayıs 2004
İkinci düzeltme : Temmuz 2004
Kabul : Eylül 2004

Okutman Murat Çuhadar, Süleyman Demirel Üniversitesi Eğirdir Meslek Yüksekokulu. Turizm ve Otel İşletmeciliği Programı, Eğirdir, Isparta.

Yrd. Doç. Dr. Cengiz Kayacan, Süleyman Demirel Üniversitesi Mimarlık Mühendislik Fakültesi Tekstil Mühendisliği Bölümü, Isparta.

E-posta: mcuhadar@sdu.edu.tr

E-postal: kayacan@mmf.sdu.edu.tr