

YABANCI ZİYARETÇİ SAYISININ TAHMİNİNDE BOX-JENKINS MODELİ, WINTERS YÖNTEMİ VE YAPAY SİNİR AĞLARIYLA ZAMAN SERİSİ ANALİZİ

Arş. Grv. Emrah ÖNDER
İstanbul Üniversitesi
İşletme Fakültesi

Arş. Grv. Özlem HASGÜL
Balıkesir Üniversitesi
Bandırma İktisadi ve İdari Bilimler Fakültesi

Tahminleme turizmde düzenlemelerin yapılmasında büyük öneme sahiptir ve turizm politikalarının oluşturulmasında önemli analitik bir araçtır. Bu çalışmada Türkiye'ye 1986-2007 yılları arasında gelen yabancı turist sayıları kullanılarak 2008-2010 yıllarına ait tahminleme yapılması amaçlanmaktadır.

Bu çalışmada uzun dönemli yabancı ziyaretçi sayısının tahmini için yapay sinir ağlarının kullanılabilirliği ve geleneksel zaman serisi analizi yöntemleri ve Box-Jenkins yönteminin kullanımı ile elde edilen sonuçların Yapay sinir ağları kullanılarak elde edilen sonuçlarla karşılaştırılması amaçlanmıştır. Uygun yöntemin bulunması için Zaman Serilerinin istatistiksel ve teorik alt yapısından yararlanılmış, hata analizleri ve klasik zaman serileri testleri kullanılmıştır. Box-Jenkins modellerinden en iyisinin seçiminde Akaike ve Swartz kriterleri dikkate alınmıştır. Üstel düzgünleştirme ve Box-Jenkins Modelleri zaman serileri tahminlerinde sıklıkla kullanılan iki yöntemdir. Sinir Ağları ise bilgisayar biliminden destek alan yapay zeka tekniğidir.

Anahtar Sözcükler: Yabancı Ziyaretçi Sayısı, Box-Jenkins Modelleri (ARMA, ARIMA), Yapay Sinir Ağları (YSA), Winters Yöntemi, Zaman Serisi Analizi

TIME SERIES ANALYSIS WITH USING BOX-JENKINS MODELS AND ARTIFICIAL NEURAL NETWORK FOR FORECASTING NUMBER OF FOREIGN VISITORS

Forecasting plays a major role in tourism planning and it is an essential analytical tool in tourism policy. This paper focuses on forecasting methods to forecast international tourism arrivals to Turkey for 2008-2010 based on data period 1986-2007.

The study focuses mainly on the applicability of artificial neural network (ANN) model for forecasting number of foreign visitors in long term and comparing the ANN's results with the Traditional Time Series Analysis and Box-Jenkins' model solutions. Time Series statistical theory and methods are used to select an adequate technique, based on residual analysis and classical Time Series test for model adequation. Akaike and Swartz criteria are used to select the best estimated option in Box-Jenkins Models. Exponential smoothing and Box-Jenkins Models are two commonly used statistical time series forecasting techniques. Neural Networks, is an artificial intelligence technique derived from computer science.

Key Words: Number of Foreign Visitors, Box-Jenkins Models, Artificial Neural Networks (ANN), Winters Method, Time Series Analysis

GİRİŞ

Yapay sinir ağları (YSA) günümüzde karşılaşılan problemler için oldukça geniş bir uygulama alanı kazanmıştır. Uygulama alanının çok geniş olmasının yanı sıra, tahmin modelleme ve sınıflandırma gibi bazı alanlarda ağırlıklı olarak kullanılmaktadır. 1950'li yıllarda ortaya çıkmalarına rağmen ancak 1980'li yılların ortalarında genel amaçlı kullanım için yeterli seviyeye gelmişlerdir. Bugün YSA'lar birçok ciddi problem üzerine uygulanmaktadır ve bu problemlerin sayısı giderek artmaktadır. Verideki trend veya yapıyı (desen/ pattern) iyi tanımlayan bir yöntem olmaları dolayısıyla tahmin işlemleri için oldukça uygundur.(Yurtoğlu, 2005:9).

Verilerin eksik ve/veya aşırı sapma göstermesi durumlarında klasik yöntemlerle yapılan tahminlerin sonuçları hatalı veya tutarsız olabilir. YSA ise verilere tamamen bağlı olmayıp, eksik, düzensiz, kısmen hatalı veya gürültülü (erratic) veriyi başarıyla değerlendirebilmektedir. YSA karmaşık ilişkileri öğrenebilir, genellebilir ve bu sayede daha önce hiç karşılaşmadığı sorulara kabul edilebilir bir hata düzeyiyle cevap bulabilir. (Özalp ve Anagün, Cilt 12, Sayı:3-4: 3)

YSA modelleri genellikle doğrusal değildir, sınıflandırmada, desen tanımada, (recognizing patterns), tahmin problemlerinde doğrusal modellere göre daha etkili sonuçlar vermektedir. Zaman serisi analizi için kullanılan istatistik modeller genellikle doğrusaldır. Bu nedenle doğrusal olmayan yapıda

YSA modelinin kullanımı büyük önem kazanmaktadır. (Aslanargün vd., 2007: 29)

Bu çalışmada Türkiye'nin kalkınmasında önemli bir rolü bulunan turizm sektörüne ilişkin yabancı ziyaretçi olarak adlandırılan turizm talebi dikkate alınmıştır. Yabancı ziyaretçi sayısının tahmini probleminde Ocak 1986- Ekim 2007 Dönemi aylık verileri ele alınarak Kasım 2007-Aralık 2010 değerleri tahmin edilmiştir.

Çalışmada öncelikle klasik tahmin yöntemleri olarak adlandırılan yöntemlerle oluşturulan modellere ait hata değerleri (hata kareleri ortalaması) elde edilmiş, en küçük hata değeri elde edilen model seçilmiş ve aynı çalışma yapay sinir ağları kullanılarak ta gerçekleştirilmiş ve tahmin değerleri sunulmuştur.

YSA'nın özellikle doğrusal olmayan ve karmaşık ilişkileri öğrenebilme özelliğinin yabancı ziyaretçi sayısının tahmin edilmesinde kullanılabilirliğinin araştırılması amaçlanmıştır.

1.TURİZM VE ÖNEMİ

Turizm sektörü, bir yandan ülkeler için önemli bir gelir kaynağı olması, diğer yandan uluslararası ticaretin gelişmesi ve günümüz insanının yaşam felsefesinin, yaşam standartlarının yükselmesine paralel olarak seyahat etme lehine değişmesi ile önemli gelişmeler kaydetmiştir. Ancak bu gelişmeler gerek ülkeleri gerek işletmeleri artan rekabet nedeni ile yeni arayışlara itmektedir. Bunların başında da sunulan hizmette farklılıklar yaratmak ve gelecekle

ilgili tahminlerde bulunmak gelmektedir.(Turanlı ve Güneren, 2003:1) Doğru tahmin yöneticilere ve yatırımcılara operasyonel taktik ve stratejik kararlarda yardımcı olacaktır. Örneğin operasyonel kararlar işe alma ve çizelgeleme, taktik kararlar tur broşürlerinin hazırlanması, stratejik kararlar otel yatırımları olabilir.(Law ve Au, 1999: 89) Turizm talebinin ölçülmesi aynı zamanda yerel ekonominin refahı için turizm sektörünün katkısına değer biçmede kullanılır.(Uysal ve Sherif, 1999:111) Bu nedenle turizm talebini karşılamaya yönelik alınacak kararlarda talep tahmini büyük önem kazanmaktadır.

Literatürde zaman serilerinde tahminleme amacıyla ilerleyen aşamalarda açıklanan geleneksel yöntemler ve Box-Jenkins yöntemi yaygın olarak kullanılmaktadır. Yapay Sinir Ağları da bu tür problemlerde özellikle son dönemde artan bir şekilde uygulanmaya başlanmıştır. YSA'nın tahminlemede ilk başarılı uygulamalardan biri Lapedes ve Farber'in (1987), (1988) doğrusal olmayan zaman serilerine yönelik çalışmalarıdır.(Zhang vd., 1998: 39)

Turizm alanındaki örneklere ilişkin de Law ve Au'nun (1999) Hong Kong'ta seyahat edecek Japon talebini incelediği çalışma, Uysal ve Sherif'in (1999)'da Kanada'lı turistlerin harcamalarını içeren çalışması, Law'ın (2000) YSA'lı turizm talebinin tahmininde geriyayılım öğrenme ile doğruluğu geliştirme çalışması, Burger vd. (2001)'de Güney Afrika uygulaması, Palmer ve arkadaşlarının turizm

tahmininde zaman serisi için YSA tasarlanması çalışması verilebilir.

Türkiye'de yapılan çalışmalara da Türkiye'ye Yönelik Turizm Talebinin Neural (Sinir) Ağları modelini kullanarak Analizi ile Baldemir ve Bahar'ın (2003) çalışması, Antalya iline yönelik Alman turist talebinin yapay sinir ağları yöntemiyle tahmini ile Güngör ve Çuhadar'ın (2005) çalışması örnek olarak verilebilir.

2.ZAMAN SERİLERİ ANALİZİ

2.1 Üstel Düzgünleştirme Yöntemleri

Üstel düzgünleştirme yöntemleri geçmiş dönem verilerine farklı ağırlıklar veren bir yöntemler topluluğudur. Üstel terimi verilen ağırlıkların veriler eskidikçe üstel bir şekilde azalması anlamını taşımaktadır. En yakın geçmiş verilerin geleceğe etkisi eski dönem verilerinden daha fazladır. Burada uygulama sonucunda diğer yöntemlere göre daha başarılı sonuç veren Winters yönteminin teorisi üzerinde durulacak, diğer üstel düzgünleştirme yöntemlerinin sadece sonuçları belirtilecektir.

2.1.1 Doğrusal ve Mevsimsel Üstel Düzgünleştirme – Winters Yöntemi

Üç denkleme dayanan bu yöntemde her denklem eğilimin üç bileşkeni; durgunluk, doğrusallık ve mevsimselliğe bağlı parametrelerin düzgünleştirilmesinde kullanılmaktadır. Winters yönteminin denklemleri aşağıda verilmektedir :

$$y'_t = \alpha \frac{y_t}{I_{t-L}} + (1-\alpha)(y'_{t-1} + b_{t-1}) \quad (1)$$

$$b_t = \gamma(y'_t - y'_{t-1}) + (1-\gamma)b_{t-1} \quad (2)$$

$$I_t = \beta \frac{y_t}{y'_t} + (1-\beta)I_{t-L} \quad (3)$$

Denklemden L; mevsim uzunluğu (bir yıl içindeki ay veya mevsim sayısı) I; mevsim düzeltme faktörüdür. α, β, γ ise Winters yöntemindeki düzgünleştirme sabitleridir. α ; modelin düzgünleştirme sabiti, β ; mevsim düzgünleştirme sabiti ve γ ; trend düzgünleştirme sabitidir.

Üçüncü denklem gözlem değeri y_t 'nin ilgili dönemin tekli düzgünleştirilmiş değeri y'_t 'ye oranı olduğu için mevsim indeksine benzemektedir. y_t, y'_t 'den büyükse indeks 1'den büyük, aksi halde 1'den küçük çıkacaktır. y_t değerleri mevsimin etkisini taşıırken y'_t değerleri serinin düzgünleştirilmiş değerleri olduğu için mevsimin etkisini taşımazlar.

İkinci denklem trendin düzgünleştirilmesi için kullanılmaktadır. Birinci denklemde ilk terim mevsim indeksi I_{t-L} 'e bölünmektedir. Bunun amacı y_t 'deki mevsim etkisini ortadan kaldırmaktır. y'_t 'yi 1'den büyük bir sayıya bölmek, gözlem değerini (y_t) t-L dönemi mevsim etkisi oranında küçültmektedir. Mevsim indeksi 1'den küçük olduğunda ise tam tersi bir

durum ortaya çıkmaktadır. I_{t-L} 'nin kullanılma nedeni ise I_t 'nin henüz bilinmemesidir.

Winters yöntemiyle tahmin ise aşağıdaki denklem yardımıyla yapılmaktadır.

$$\hat{y}_{t-m} = (y'_t + b_t m) + I_{t-L+m} \quad (4)$$

α, β, γ düzgünleştirme sabitleri seçilirken ise diğer düzgünleştirme yöntemlerinde olduğu gibi tahmin hataları kareleri toplamı veya ortalamasını minimum yapan değerler olmasına dikkat edilmektedir. (Orhunbilge, 1999: 113-114)

2.2 Otoregresif Modeller

Durağan zaman serilerini modellemenin en yaygın yolu Otoregresif Hareketli Ortalama yöntemi, yaygın adıyla Box Jenkins (BJ) yöntemidir. (Gujarati, 2001: 738) Box Jenkins Yöntemi tek değişkenli zaman serilerinde tahminleme için uygun modelin seçilmesi amacıyla literatürde yaygın olarak kullanılmaktadır. (Enders, 1995:95)

y_t 'yi k tane açıklayıcı değişken $x_1, x_2, x_3, \dots, x_k$ ile açıklayabilen regresyon modellerinin tersine, y_t 'nin kendi eski ya da gecikmeli değerleri ve olasılıklı hata terimleri ile açıklanabilmektedir. Amacı, örneklem verilerini türettiği düşünülebilecek bir istatistik modelini belirlemek ve tahmin etmektir. Tahmin edilen bu model kestirim için kullanılacaksa, modelin özellikleri zaman içinde, özellikle de gelecek dönemlerde değişmemelidir. Öyleyse durağan veri gereksiniminin basit nedeni, bu verilerden çıkarsanan herhangi bir modelin de durağan ya da kararlı

olabilmesi, dolayısıyla da kestirim için geçerli bir temel sağlayabilmesi gerektiğidir.(Gujarati, 2001: 738). Box-Jenkins yönteminin en önemli aşaması, otokorelasyon ve kısmi otokorelasyon katsayılarının incelenerek uygun ARMA (p,q), modelinin seçilmesidir. Mekanik olarak belirlenmesi mümkün olmayan bu aşamada araştırmacıların kararı önem kazanmaktadır:

1) Eğer zaman serisi durgun değilse suni otokorelasyonlar model belirlemeye engel olacaktır. Bu nedenle hangi düzeyde uygun ise farklar alınır.

2) Otokorelasyon ve kısmi otokorelasyon katsayıları dağılımlarının grafikler yardımıyla incelenmesi gerekmektedir. Otokorelasyon katsayılarının sıfıra üstel olarak yaklaştığı saptanırsa AR modeli, kısmi otokorelasyon katsayıları bu eğilimi gösteriyorsa MA modeli, her ikisi birlikte üstel olarak sıfıra yaklaşıyorsa ARMA modeli söz konusu demektir.

3) Sıfırdan anlamlı bir şekilde farklı olan otokorelasyon katsayılarının saptanması AR ve MA modellerinin derecesinin belirlenmesi için gerekmektedir. ARMA modelinde AR'ın derecesi kısmi otokorelasyon (p), MA'nın derecesi de otokorelasyon katsayılarının (q) sayısı ile belirlenmektedir.(Orhunbilge, 1999: 194)

2.2.1. AR(p) Modelleri (Otoregresif Modeller)

p'nci mertebede otoregresif sürece sahip gözlenen y_t serisi, y_t değerlerinin p dönem geriye doğru

giden ağırlıklı ortalaması ile bozucu terimin toplam değerine eşittir. Bir otoregresif sürece sahip denklem aşağıdaki gibi yazılabilir.(Kutlar, 2000: 25)

$$y_t = m + \alpha_1 y_{t-1} + \alpha_2 y_{t-2} + \dots + \alpha_p y_{t-p} + u_t \quad (5)$$

2.2.2.MA(q) Modelleri (Hareketli Ortalama Modelleri)

Hareketli ortalama modelinde y_t süreci, tamamen cari ve gecikmeli hata terimlerinin ağırlıklı toplamı ile tanımlanır. Burada u hiçbir belirli kalıbı olmayan stokastik bir hata terimidir. Bu hata teriminin zamana göre bağımsız bir dağılım gösterdiği yani bir beyaz gürültü süreci (white noise process) ile ortaya çıktığı kabul edilir.(Tarı, 2002:383) MA(q) modelinde y_t değeri, serinin geriye doğru q dönem geçmiş hata terimlerinin ve ortalamasının doğrusal fonksiyonudur. MA(q) modelleri genel olarak aşağıdaki gibi gösterilebilir:

$$y_t = m + u_t - \theta_1 u_{t-1} + \theta_2 u_{t-2} + \dots + \theta_q u_{t-q} \quad (6)$$

2.2.3.ARMA(p,q) Modelleri (Otoregresif ve Hareketli Ortalama Modeli)

ARMA modelleri en genel durağan stokastik süreç olup, geçmiş gözlemlerin ve geçmiş hata terimlerinin doğrusal bir fonksiyonudur. ARMA (p,q) modelleri genel olarak aşağıdaki gibi gösterilebilir:

$$y_t = m + \alpha_1 y_{t-1} + \dots + \alpha_p y_{t-p} + u_t - \theta_1 u_{t-1} + \theta_2 u_{t-2} + \dots + \theta_q u_{t-q} \quad (7)$$

Durağan olmayan zaman serileri fark alınarak durağanlaştırılır. Zaman serisinin doğrusal bir trendi var ise birinci fark serisi durağan olur. Eğer zaman serisinin eğrisel bir trendi var ise farkların tekrar farkı alınarak ikinci farklar serisi durağanlaştırılır. Bu durumda model, ARIMA (p,d,q) olarak ifade edilir. Burada “d” serinin durağanlaştırma (fark alma) parametresidir.(Hamzaçebi ve Kutay, 2004: 228)

2.2.4.Mevsimsel Box-Jenkins Modelleri

Mevsimsel Box-Jenkins modellerinin istatistiksel analizleri mevsimsel olmayan Box-Jenkins modelleriyle aynı mantıkla yapılmaktadır. Bu mevsimsel modeller mevsimsel otoregresyon (SAR), mevsimsel hareketli ortalama (SMA), ve Mevsimsel otoregresif hareketli ortalama (SARMA) modelleri olmaktadır. Bu modellerin belirlenebilmesi için serininin mutlaka durağan hale getirilmesi, yani fark işlemi ile trendden arındırılmış, mevsimsel fark işlemi ile de mevsimsellikten arındırılmış olması gerekmektedir.(Kadılar, 2005: 222)

3.YAPAY SİNİR AĞLARI

Doğrusal ve polynomial yaklaşım metotları gibi yapay sinir ağları da girdi değişkenleri kümesi, $\{x_i\}$, $i = 1, \dots, k$ ile bir veya birden fazla çıktı değişkeni kümesi, $\{y_j\}$, $j = 1, \dots, k$, arasında ilişki kurar. Yapay sinir ağlarının diğer yaklaşım yöntemlerinden farkı, girdi değişkenlerinin lojistik ya da logsigmoid olarak bilinen özel bir fonksiyona dönüştürüldüğü bir veya

daha fazla gizli katmanın olmasıdır. Gizli katman yaklaşımı ezoteriktir (belli bir gruba hitap eden, özel, gizli) ve doğrusal olmayan süreçlerde etkili bir yol sunar.(McNelis, 2005:21)

Yapay sinir ağının bir gizli tabaka içermesi durumunda fonksiyonel gösterim aşağıdaki gibi olmaktadır:

$$y_k = f_k(\alpha_k + \sum_{j \rightarrow k} w_j f_j(\alpha_j + \sum_{j \rightarrow k} w_{ij} x_j)) \quad (8)$$

Burada y_k çıktı değerlerini gösterirken, f_k çıktı tabakası transfer fonksiyonunu göstermektedir. α_k çıktı tabakasına ait sapma değerini, w_j çıktı tabakasına ait ağırlıkları, f_j ve α_j sırasıyla gizli tabakaya ait transfer fonksiyonu ve sapma değerini x_i girdi değerleri ve w_{ij} ise, i girdi elemanını j gizli elemanına bağlayan ağırlığı temsil etmektedir. İki gizli tabaka olması durumunda ise bu fonksiyonel gösterim aşağıda verildiği şekilde olacaktır.(Yurtoğlu, 2005: 23)

$$y_l = f_l(\alpha_k + \sum_{j \rightarrow k} w_j f_k(\alpha_k + \sum_{j \rightarrow k} w_{jk} f_j(\alpha_j + \sum_{j \rightarrow k} w_{ij} x_j))) \quad (9)$$

YSA'nın ürettiği çıktılar, ağ içerisinde birbirine paralel bağlantılar aracılığıyla dağıtılmaktadır. Ancak ağın ürettiği çıktuların değerleri çok yüksek değerler olmakta ve ağın eğitilebilmesini engellemektedir. Bu nedenle transfer (aktivasyon) fonksiyonları aracılığıyla bu değerler belirli bir aralıkta normalleştirilerek ağın eğitiminin yapılabilmesi sağlanmaktadır.(Bayramoğlu, 2007: 103)

Bu çalışma için transfer fonksiyonu olarak çok yaygın bir şekilde kullanılan sigmoid fonksiyon seçilmiştir.

Bir sinir ağı, uygulanan girdi kümelerinin istenilen çıktı kümesini üretebileceği şekilde şekillendirilmektedir. Var olan bağlantıların ağırlıklandırılması için farklı yöntemler bulunmaktadır. Öncelikli bilgilerin kullanılmasıyla ağırlıkların açık bir şekilde belirlenmesi bir yol, bazı öğrenme kurallarıyla ağırlıkların değişmesi ve öğrenme desenleriyle ağırlıkların beslendiği 'eğitme' diğer yoldur. (Krose ve Smagt, 1996: 18)

Bu çalışmada eğitimi yapay sinir ağlarında yaygın olarak kullanılan "geri yayılım algoritması" kullanılmıştır. Geri yayılım algoritmasında çıktı düğümlerinde hata olarak gösterilir. Bu hatalar çeşitli aktif ağırlıkların değiştirilmesini sağlayabilecek biçimde ağ üzerinden geri yayılır. Burada birbirlerini çok karmaşık bir biçimde etkileyen çok sayıda hacim kontrolü mevcuttur. Bir dizi ileri ve geri geçişin ardından ağırlıklar kademeli olarak ağırlık az çok istenen biçimde davranmasını sağlayacak şekilde ayarlanır. (Whitby, 2005: 72)

Geril yayılım algoritmasında, kullanılan Delta kuralı ile bağlantıların ayarlanmasının matematik gösterimi şu şekilde özetlenebilir: Delta kuralı, ilgili bağlantı ağırlığının ayarlanması için gerekli olan düzeltme miktarını formüllemektedir. Buna göre, nöron (i) ve nöron (j) arasındaki bağıntı için düzeltme miktarı şu şekilde hesaplanmaktadır. (Yurtoğlu, 2005: 33)

Ağırlık düzeltme miktarı=
 $\Delta_{ij}(n)$

$\Delta_{ij}(n) = \text{Öğrenme oranı}$
parametresi * Yerel değişim (gradient)
* Nöron(j) için girdi sinyali

$$\Delta_{ij}(n) = \eta * \delta_j(n) * Y_i(n) \quad (10)$$

4.UYGULAMA VE SONUÇLAR

Bu çalışmada Microsoft Excel, SPSS ve QNet 97 programları kullanılmıştır. Geçmiş yıllara ait yabancı ziyaretçi sayıları Türkiye Seyahat Acentaları Birliği'nden elde edilmiştir. 1986 Ocak -2007 Ekim dönemleri arası 262 aylık değere sahip veri seti kullanılmıştır.

4.1 Zaman Serisi Analizi Modelleri

Bu çalışmada yabancı ziyaretçi sayısının tahmini amacıyla öncelikli olarak Box-Jenkins Modelleri ile tahmin amaç olarak ele alınsa da klasik zaman serisi analizi yöntemleri olarak adlandırılan yöntemlerle sonuçlar elde edilmiştir. Aşağıda verilerin analizinde kullanılan yöntemler belirtilmektedir.

- Ayrıştırma Yöntemleri (Doğrusal, 2. Derece, Üstel)
- Üstel Düzgünleştirme (Tekli Basit Üstel Düzgünleştirme, Doğrusal Hareketli Ortalamalar, Brown'un Tek Parametrelili Doğrusal Üstel D. Y. (alfa=0,1), Brown'un Tek Parametrelili Doğrusal Üstel D. Y. (alfa=0,2), Holt'un İki Parametrelili Doğrusal Üstel D. Y., Doğrusal Olmayan Üstel Düzgünleştirme Yöntemi (Brown'un İkinci Derece Ü.D.Y), Doğrusal ve Mevsimsel Üstel Düzgünleştirme – Winters Yöntemi)
- Box-Jenkins yöntemleri kullanılmıştır. Bu yöntemlerin tamamının kullanılmasındaki amaç Box- Jenkins

yöntemleri ile kurulan modellerde hata değeri açısından elde edilecek farklılığın gözlenmesidir.

Bu yöntemlerin geçerliliği anlamlılık derecelerine bakılarak kontrol edilmiştir ve aralarında en düşük hata değerini veren model

belirlenmeye çalışılmıştır. Aşağıda verilen tabloda MS Excel, SPSS ve programları kullanılarak oluşturulan modeller ve MS Excel programı ile hesaplanan hata kareleri ortalaması değerleri sunulmuştur.

4.1.1. Ayırıştırma Yöntemleri

Tablo 1. Ayırıştırma Yöntemlerine Ait Hata Kareleri

	e^2	e^2 / Dönem Sayısı
Dogrusal	64.490.010	246.145
2. Derece	58.744.741	224.217
Üstel	62.204.001	237.420

262 dönemden oluşan (1986 Ocak - 2007 Ekim) zaman serisine ayırıştırma yöntemi uygulandığında 2. derece trend fonksiyonunun hata karesi ortalamasının en düşük değere

sahip olduğu görülmektedir. Ancak Türkiye'ye gelen yabancı turist sayıları aylara göre büyük değişim göstermektedir.

Tablo 2. Mevsim İndeksi

Aylar	Mevsim İndeksi	Aylar	Mevsim İndeksi
Ocak	39	Temmuz	162
Şubat	44	Ağustos	170
Mart	61	Eylül	148
Nisan	85	Ekim	122
Mayıs	122	Kasım	65
Haziran	129	Aralık	54

Türkiye'ye gelen yabancı turist sayısı özellikle ağustos ayı olmak üzere yaz aylarında artış, kış aylarında ise azalış gösterdiği saptanmaktadır. Bu veriler doğrultusunda Türkiye'de yaz turizminin önem arz ettiği söylenebilir.

Ayırıştırma yöntemi kullanılarak seçilen 2. derece trend fonksiyonu mevsim indeksi ile düzeltildiğinde, hata kareleri ortalamasında dikkate değer bir azalış göstermektedir.

4.1.2 Üstel Düzgünleştirme Yöntemleri

Tablo 3. Üstel Düzgünleştirme Yöntemleri

		e^2	$e^2/$ Dönem Sayısı
Tekli (Basit) Ü.D.	(alfa=0,1)	61.526.448	235.734
	(alfa=0,5)	39.640.687	151.880
	(alfa=0,9)	21.652.236	82.959
Doğrusal Hareketli Ortalamalar		14.968.311	58.242
Brown'un Tek Parametrelili Doğrusal Üstel Düzgünleştirme Yönt. (alfa=0,1)		62.207.771	239.261
Brown'un Tek Parametrelili Doğrusal Üstel Düzgünleştirme Yönt. (alfa=0,2)		59.795.891	229.984
Holt'un İki Parametrelili Doğrusal Üstel Düzgünleştirme Yönt.		16.681.760	64.161
(Doğrusal Olmayan Üstel Düzgünleştirme) Brown'un İkinci Derece Ü.D.Y.		14.608.101	56.185
Doğrusal ve Mevsimsel Üstel Düzgünleştirme Yönt. – Winters Yönt. *En İyi Yöntem		2.113.887	8.068


Veriler Üstel düzgünleştirme yöntemlerinden olan Doğrusal ve Mevsimsel Üstel Düzgünleştirme – Winters Yöntemi ile analiz edildiğinde hata karelerinin minimum değer verdiği saptanmıştır. İterasyonla

α, β, γ değerlerinin $\alpha = 0,7$, $\beta = 0,9$, $\gamma = 0,01$ olduğu saptanmıştır.

4.1.3 Box-Jenkins Yöntemleri

Verilerin otoregresif modeller ile analizinden önce durağanlığına bakıldığında durağan olmadığı gözlenmektedir.


Şekil 1. Verilere Ait Korelogram



Birinci farklar alındığında (1. fark ve mevsimlik 1. fark) durağanlığın büyük ölçüde sağlandığı

söylenebilir. Birinci farklara ilişkin korelogram aşağıdaki şekilde verilmektedir.

Şekil 2. Birinci Farklar Alındığında Ortaya Çıkan Korelogram



Tüm model kombinasyonları denendikten sonra uygun olan modelin seçimine karar verilmiştir. Kullanılan model kombinasyonları ve

bu modellerde elde edilen hata kareleri ortalaması değerleri aşağıdaki tabloda verilmektedir.

Tablo 4. Otoregresif Modeller ve Modellere Ait AIC ve BIC deęerleri

Arıma	Sarıma	$\sum e^2$	$\sum e^2$ / Dönem Sayısı	Prob	Akaike's Information Criterion (AIC)	Schwarz's Bayesian Criterion (BIC)
(1,1,0)	(0,1,0)	2.651.927	10.650	AR(1)=0,001	3019	3026
(0,1,1)	(0,1,0)	2.678.417	10.756	MA(1)=0,007	3021	3028
(1,1,1)	(0,1,0)	2.620.027	10.522	AR(1)=0,001 MA(1)=0,039	3018	3028
(0,1,0)	(1,1,0)	2.660.108	10.683	SAR(1)=0,002	3020	3027
(0,1,0)	(0,1,1)	2.627.478	10.552	SMA(1)=0,001	3016	3023
(0,1,0)	(1,1,1)	2.997.657	12.038	SAR(1)=0,001 SMA(1)=0,676	3016	3027
(1,1,0)	(1,1,0)	2.567.048	10.309	AR(1)=0,003 SAR(1)=0,005	3013	3023
(0,1,1)	(1,1,0)	2.596.238	10.426	MA(1)=0,016 SAR(1)=0,005	3015	3025
(1,1,0)	(0,1,1)	2.546.858	10.228	AR(1)=0,007 SMA(1)=0,001	3011	3021
(0,1,1)	(0,1,1)	2.576.138	10.345	MA(1)=0,034 SMA(1)=0,001	3012	3023
(1,1,1)	(1,1,0)	2.539.939	10.200	AR(1)=0,004 MA(1)=0,072 SAR(1)=0,006	3012	3026
(1,1,1)	(0,1,1)	2.520.292	10.121	AR(1)=0,007 MA(1)=0,081 SMA(1)=0,001	3010	3024
(1,1,1)	(1,1,1)	3.010.882	12.091	AR(1)=0,005 MA(1)=0,065 SAR(1)=0,795 SMA(1)=0,338	3011	3029
(1,1,0)	(1,1,1)	3.094.463	12.427	AR(1)=0,015 SAR(1)=0,575 SMA(1)=0,200	3012	3026
(0,1,1)	(1,1,1)	3.152.885	12.662	MA(1)=0,055 SAR(1)=0,554 SMA(1)=0,171	3014	3028


Ortalama hata karesi, anlamlılık yüzdeleri, AIC ve BIC deęerleri incelendięinde ARİMA

(1,1,0), SARİMA(0,1,1) modelinin otoregresif modeller içinde en uygunu olduęuna karar verilebilir.

ARİMA (1,1,0),
SARİMA(0,1,1) modelinin
kullanılabilmesi için $\beta_1 + \beta_2 \leq 1$
olmalıdır.

0,172 + 0,230 ≤ 1 (model
uygun)
Hatalar ortalaması otokorelasyonu
olmamalıdır. Aşağıda gösterilen
korelogram baz alınarak modelin
geçerliliği söylenebilir.

Şekil 3. Modelin Hatalarına Ait Korelogram



Bu sonuçlar içinde hata kareleri ortalaması ve anlamlılık yüzdelere bakıldığında ARIMA:1,1,0 - SARIMA:0,1,1 [Prob: AR(1)=0,007 SMA(1)=0,001] modelinin, otoregresif modeller içinde en uygunu olduğuna karar verilebilir.

4.2 Yapay Sinir Ağı Modeli

Yabancı ziyaretçi sayısının tahmini problemi için kurulan yapay sinir ağı modelinde bağımlı değişken yabancı ziyaretçi sayısıdır ve modelin çıktı değeri olarak değerlendirilmiştir. Açıklayıcı değişken ve modelin girdileri olarak ta;

- 1) Zaman serisini temsil etmesi amacıyla gözlem değerleri için sıra numarası,

- 2) Mevsimsellik etkisinin dikkate alınabilmesini sağlamak için gözlem değerlerine ilişkin ay numarası seçilmiştir.


• Modelin Tanımlanması

Yabancı ziyaretçi sayısının tahmini için kurulan model girdi ve modelin iki girdi nöronu bulunacak ve çıktı değeri de bir nöronla temsil edilmiştir. Girdi değerleri bir katmanı, çıktı değerleri bir katmanı oluşturmuş ve arada gizli katman olduğu için üç katmanlı bir model kurulmuştur.

Yapılan denemeler sonucunda gizli katman nöron sayısı için farklı nöron sayılarının kullanımındaki hata değerleri karşılaştırıldığında en uygun değer 5 olduğu sonucuna varılmıştır.

Modele ilişkin bir görünüm aşağıdaki şekilde verilmiştir.

Şekil 4. YSA Modeli



Modelde transfer fonksiyonu olarak sigmoid fonksiyon seçildiği için öncelikle programın verilerin ağa girmeden önce (0-1) arasında değer alması için normalleştirilmesi sağlanmıştır. Girdi ve çıktı verileri değerlendirilmeden önce normalizasyon işlemine tabi tutulmuştur. Elde edilen çıktı değeri için normalizasyon işlemi tersine çevrilmektedir.

• Ağın Eğitilmesi

Yapay sinir ağı modelinin eğitilmesi için literatürde sıkça kullanılan geriyayılım algoritması seçilmiştir. Bunun için veriler eğitim ve test verileri olarak ikiye ayrılmış, verilerin rassal olarak seçilen % 20'lik kısmı (52 adet) test verisi olarak değerlendirilmiştir.

Ağın yapısına ilişkin algoritmanın atamadığı değerlerin belirlenmesi için farklı faktörlerin farklı seviyelerine ilişkin deneme çalışmaları yapılmıştır. Deneme

sonuçlarına göre aşağıdaki sonuçlar elde edilmiştir:

1) Öğrenme oranı: program tarafından belirlenmekte ve değişime izin verilmemektedir. Program 0.01 ile 0.03 arasındaki değerleri kullanmaktadır ve 0.034 değerini uygun görmüştür.

2) Momentum terimi: Yerel en iyiye takılmayı engelleyen momentum terimi için denemeler yapılmış programın atadığı 0.8 değeri uygun görülmüştür.

3) İterasyon sayısı: Çok farklı iterasyon sayıları için denemeler yapılmış 100.000 iterasyonun üzerinde hatanın genellikle çok büyük değişim göstermediği belirlenmiştir. O nedenle 100.000 iterasyon uygun görülmüştür.

Programda uygun modelin belirlenmesi için hata değeri ve dolayısı ile üretilen değerler ile hedefi değerler arasındaki sapma önem


kazanmaktadır. Program hata değeri olarak RMS (Root Mean Square) değerlerini aşağıda verildiği şekilde hesaplamaktadır:

$$\text{RMS Error} = \sqrt{\frac{\sum (T(P,K) - X(P,O,K))^2}{PT * KT}} \quad (7)$$

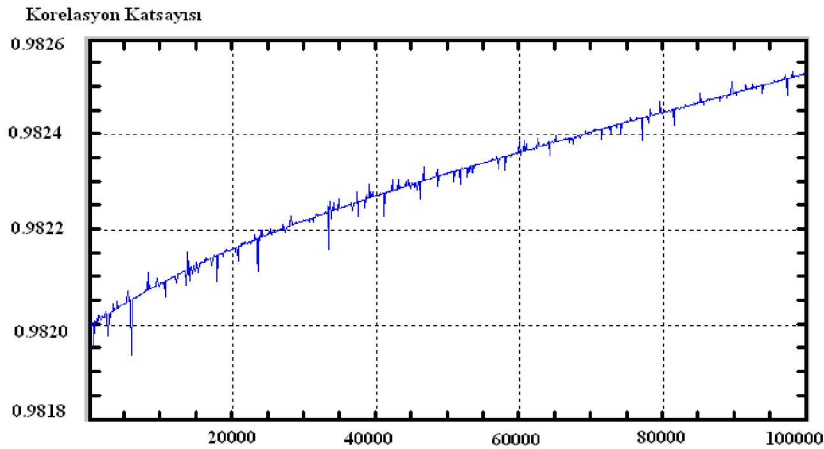
Burada X, girdi vektörü, T hedef vektör, P, P.girdi deseni, K, K. Çıktı düğümüdür. PT desenlerin toplam sayısı ve KT çıktı düğümlerinin toplam sayısıdır. RMS hatası her bir iterasyon sonrası hesaplanmaktadır ve ağ çıktısındaki hatanın standart sapmasına eşittir. (www.qnetv2k.com)

Eğitim seti için iterasyon sayısına göre hatanın ve korelasyon katsayısının değişimine ait grafik Şekil 5. ve Şekil 6'da verilmiştir. Bu grafiğe göre hata 0,0252'den düşüş eğilimi göstermiş ve 100.000 iterasyon noktasında 0,0248'e yaklaşmıştır. Korelasyon katsayısı ise; 0,9820'den 0,9825'e artış göstermiştir. Rakamsal olarak çok büyük bir farklılık gibi görünmese bile eğimin yönü ve hata grafiklerinin 100000 iterasyon noktasında iterasyon sayısına bağlı olarak paralelleşme göstermesi eğitim seti için uygun parametrelerin kullanıldığını göstermektedir.

Şekil 5. Eğitim Seti Hata Değerleri



Şekil 6. Eğitim Seti Korelasyon Katsayısı Değerleri




- **Ağın Test Edilmesi**

Qnet programı kullanıcının tercihine göre eğitim işlemi ayrı olarak veya test işlemiyle aynı anda yürütebilmektedir ve kullanıcının süreç daha tamamlanmadan hata ve korelasyon katsayısı değerlerini görmesine izin vermektedir.


Test seti için iterasyon sayısına göre hatanın ve korelasyon katsayısının değişimine ait grafik

Şekil 7. ve Şekil 8’te verilmiştir. Şekil 7’de görüldüğü gibi hata değeri 0,0207’den itibaren düşüş göstermiş ve 100.000 iterasyon noktasında 0,0203’e yaklaşmıştır. Korelasyon katsayısı ise; 0,9886’dan 0,9889’a artış göstermiştir. Elde edilen bu değerler sonucunda ağın öğrenmiş olduğu ve modelin kullanılabilirliği sonucuna varılmıştır.

Şekil 7. Test Seti Hata Değerleri



Şekil 8. Test Seti Korelasyon Katsayısı Değerleri




Yapılan çalışmada eğitme setinin değerlendirilmesi sonucu kurulan modelin bulduğu değerler, test seti için bulunan değerler ve hedef değerlerin görsel olarak

karşılaştırılabildiği grafik Şekil 9’da görülmektedir. Elde edilen grafiğe göre ağın türettiği değerler hedef değerler ile karşılaştırıldığında hedef değerlere oldukça yaklaştığı

görülmektedir. Grafik desen değişimini vermektedir. numarasına göre hedef/çıktı değerinin

Şekil 9. Desenler İçin Hedef ve Çıktı Değerler



Modelde düğümler arasındaki bağlantılarda kullanılan sonuç olarak

belirlenen ağırlık değerleri aşağıdaki tabloda verilmiştir.

Tablo 5. Ağ Ağırlık Değerleri

Katman	Düğüm	Bağlantı	Ağırlık	Delta Ağırlığı
2	1	1	-371.175	-0.000022
2	1	2	-382.167	-0.000016
2	2	1	-880.394	-0.000031
2	2	2	155.269	-0.000008
2	3	1	398.325	0.000006
2	3	2	913.923	0.000002
2	4	1	234.638	0.000003
2	4	2	1.005.414	-0.000001
2	5	1	-924.661	0.000010
2	5	2	-328.043	-0.000011
3	1	1	-318.727	0.000004
3	1	2	-138.414	0.000004
3	1	3	1.035.821	0.000012
3	1	4	-1.077.315	-0.000007
3	1	5	256.576	0.000008

Programın çalıştırılması sonucu elde edilen korelasyon katsayısı ve hata değerleri aşağıdaki tabloda verilmiştir. Eğitim seti ve test

seti için bulunan RMS Hatası ve Korelasyon katsayısı değerleri arasında çok büyük bir fark gözlenmemiştir. Bu durum da modelin

test sonuçlarının tutarlı olduğunu göstermektedir.

Tablo7. Hata ve Korelasyon Katsayısı değerleri


	RMS Hatası	Korelasyon Katsayısı
Eğitim seti	0,024840	0,982529
Test seti	0,020300	0,988955

• Tahmin Etme

Kurulan yapay sinir ağı modelinin tahminleme amacıyla kullanılmasında Kasım 2007'den

Aralık 2010 kadar 38 desen dikkate alınmıştır. Desen numarasına göre çıktı düğümünde elde edilen değerler aşağıda Şekil 10'da görülebilir.

Şekil 10. Deneme Sırasına Göre Ağ Çıktı Değerleri



4.3 Model Hata Sonuçlarının Karşılaştırılması

Yapay sinir ağı modeli test seti için elde edilen çıktı değerleri zaman serisi analizinin yapıldığı formülasyona tabi tutulduğunda elde edilen hata değeri **10.580** olarak elde

edilmiştir. Bu sonuca göre yabancı ziyaretçi sayısının tahmininde yapay sinir ağlarının kullanımının klasik zaman serisi analiz yöntemleri ile tahmine alternatif olabileceği sonucuna varılmaktadır.

Tablo 6.En Düşük Hata Karesi Ortalamasına Sahip Üç Yöntem

Yöntemler	e ² /Dönem sayısı
Doğrusal ve Mevsimsel Üstel Düzgünleştirme Yönt. – Winters Yöntemi	8.068
Box-Jenkins Yöntemi AR(1)=0,007 SMA(1)=0,001 AIC= 3011, BIC=3021	10.228
Yapay Sinir Ağı Modeli (3 katman, 52 rassal eğitim verisi, orta katman noron sayısı:5, öğrenme oranı: 0,034, momentum terimi: 0.8)	10.580

4.4.Tahmin Değerleri

Doğrusal ve Mevsimsel Üstel Düzgünleştirme Yöntemlerinden Winters Yöntemi, Box Jenkins ARİMA (1,1,0), SARİMA (0,1,1) modelinin YSA Modelinin ürettiği tahmin değerleri aşağıdaki tabloda verilmiştir. Bu değerler incelendiğinde her üç modelde tahmin değerleri arasında fark olsa da Nisan, Mayıs, Haziran ayları için yaklaşık tahmin

değerlerinin üretildiği, Ocak, Şubat ayları için de en farklı tahmin değerlerinin üretildiği görülmektedir. Tahmin değerlerinin büyük bir kısmında Winters ve YSA Modelinin ürettiği değerler daha küçüktür. Bu modellere göre 2008, 2009 ve 2010 yıllarına ait Türkiye'ye gelen aylık turist zaman serisi tahminleri aşağıda belirtilmektedir.


Tablo7. Yabancı Ziyaretçi Sayısı Tahmin Değerleri

Tahmin Dönemi	Winters Yöntemi	Otoregresif Model	YSA Modeli
	*1000	*1000	*1000
Kas.07	1.207	1.408	1.401
Ara.07	1.005	1.291	989
Oca.08	788	1.088	673
Şub.08	864	1.138	962
Mar.08	1.244	1.450	1.390
Nis.08	1.676	1.867	1.989
May.08	2.496	2.601	2.675
Haz.08	2.843	3.061	3.220
Tem.08	3.578	3.885	3.456
Ağu.08	3.290	3.651	3.345
Eyl.08	2.760	3.069	2.869
Eki.08	2.282	2.454	2.148
Kas.08	1.275	1.704	1.500
Ara.08	1.061	1.588	1.083
Oca.09	832	1.385	768

Şub.09	912	1.434	1.105
Mar.09	1.312	1.746	1.598
Nis.09	1.769	2.164	2.259
May.09	2.632	2.898	2.954
Haz.09	2.998	3.357	3.443
Tem.09	3.772	4.182	3.616
Ağu.09	3.468	3.948	3.468
Eyl.09	2.908	3.366	2.970
Eki.09	2.404	2.751	2.236
Kas.09	1.343	2.001	1.584
Ara.09	1.117	1.884	1.166
Oca.10	876	1.681	876
Şub.10	960	1.731	1.263
Mar.10	1.381	2.043	1.820
Nis.10	1.861	2.460	2.529
May.10	2.768	3.194	3.206
Haz.10	3.153	3.654	3.627
Tem.10	3.965	4.479	3.742
Ağu.10	3.645	4.245	3.564
Eyl.10	3.056	3.662	3.046
Eki.10	2.526	3.048	2.302
Kas.10	1.411	2.298	1.651
Ara.10	1.173	2.181	1.237

Şekil 11. Yabancı Ziyaretçi Sayılarına Ait Tahmin Değerleri

Yabancı Ziyaretçi Sayıları Tahmin Değerleri



Sonuç

Çalışmada kullanılan yöntemlerin hata değerleri ve anlamlılık katsayıları incelendiğinde Doğrusal ve Mevsimsel Üstel Düzgünleştirme Yöntemlerinden Winters Yöntemi, Box-Jenkins modellerinin ve YSA modellerinin yabancı ziyaretçi sayısının tahmininde kullanılmasının uygun olduğu görülmektedir. Çalışmada Doğrusal ve Mevsimsel Üstel Düzgünleştirme Yöntemlerinden Winters Yöntemi Modelinin ürettiği hata değerinin daha düşük olduğu görülmektedir. Yapay Sinir Ağlarının ürettiği hata değerinin daha yüksek çıkmasına karşın yine de yabancı ziyaretçi sayısının tahmininde klasik yöntemlere alternatif olarak kullanılabileceği söylenebilmektedir ancak tahmin edebilme yeteneğinin kuvvetli olabilmesi için modelin temsil yeteneğinin azalmasına neden olan ilk yıllara ilişkin verilerin dikkate alınmaması önerilebilir. Ayrıca aylara ilişkin verilerin girdi değişkeni olarak yer almasındansa, geçmiş yıllara ilişkin değerlerin girdi olarak kullanılması, mevsim değişkeninin ya da farklı değişkenlerin modele katılması önerilebilir. Box-Jenkins Modelleri ve Yapay Sinir Ağları kullanılabilir. Sonuç olarak, hem yatırımların yönlendirilmesi hem de politikaların belirlenmesi amacıyla Türkiye'ye gelecek yabancı ziyaretçi sayısının tahmininde zaman serisi analizleri karar vericiye yol gösterici olmak için yardımcı araçlardan olabilmektedir.

KAYNAKÇA

ALFONSO, Palmer., JUAN JOSE, Montano., ALBERT, Sese., 2006,

“Designing an artificial neural network for forecasting tourism time series”, **Tourism Management**, Vol:27,781-790

ASLANARGUN, Atilla., MAMMADOV, Mammadagha., YAZICI, Berna., YOLACAN Senay., January 2007, “Comparison of ARIMA, neural networks and hybrid models in time series: tourist arrival forecasting”, **Journal of Statistical Computation and Simulation**, Volume 77, Issue 1 , pages 29 – 53

BALDEMİR, Ercan., BAHAR, Ozan., 2003, “Türkiye'ye yönelik turizm talebinin Neural (Sinir) Ağları modelini kullanarak analizi”, **Ticaret Ve Turizm Eğitim Fakültesi Dergisi**, Sayı:2

BAYRAMOĞLU, Mehmet Fatih., 2007, “Finansal Endekslerin Öngörüsünde Yapay Sinir Ağı Modellerinin Kullanılması: İMKB Ulusal 100 Endeksinin Gün İçi En Yüksek Ve En Düşük Değerlerinin Öngörüsü Üzerine Bir Uygulama”, Zonguldak Karaelmas Üniversitesi, Sosyal Bilimler Enstitüsü, Yüksek Lisans Tezi, 233s.

BURGER, C.J.S.C., DOHNAL, M., KATHRADA, M., LAW, R., 2001, “Practitioners guide to time-series methods for tourism demand forecasting a case study of Durban, South Africa”, **Tourism Management**, Vol:22, 403-409

Coşkun HAMZAÇEBİ, Fevzi KUTAY, Yapay Sinir Ağları ile Türkiye Elektrik Enerjisi Tüketiminin 2010 Yılına Kadar Tahmini, Gazi Üniversitesi Mühendislik Mimarlık

Fakültesi Dergisi, Cilt 19, No 3, 227-233, 2004

ENDERS, Walter., 1995, **Applied Econometric Time Series**, Wiley Series in Probability and Mathematical Statistics, John Wiley & Sons, Inc., s:95-433.

GUJARATI, Damodar N., 2001, **Temel Ekonometri**, Çevirenler: Ümit Şenesen, Gülay Günlük Şenesen, Literatür Yayıncılık, İstanbul, 849s.

GÜNGÖR, İbrahim., ÇUHADAR, Murat., (2005), “Antalya İline Yönelik Alman Turist Talebinin Yapay Sinir Ağları Yöntemiyle Tahmini”, **Ticaret ve Turizm Eğitim Fakültesi Dergisi**, Sayı:1

KADILAR, Cem., 2005, **SPSS Uygulamalı Zaman Serileri Analizine Giriş**, Bizim Büro Basımevi, s:299

KROSE, Ben., SMAGT, Patrick Van Der, November 1996, **An introduction to Neural Networks**, Eighth edition, The University of Amsterdam. p. 129

KUTLAR, Aziz., 2000, **Ekonometrik Zaman Serileri Teori ve Uygulama**, Gazi Kitabevi, Ankara, s:332.

LAW, Rob., AU, Norman., 1999, “A neural network model to forecast Japanese demand for travel to Hong Kong” , **Tourism Management** Vol:20, 89-97

LAW, Rob., 2000, “Back-propagation learning in improving the accuracy of neural network-based tourism demand forecasting”, **Tourism Management**, Vol:21, 331-340

MCNELIS, Paul D., 2005, **Neural Networks in Finance: Gaining Predictive Edge in the Market** Elsevier Academic Press, USA, s:242

ORHUNBİLGE, Neyran., 1999, **Zaman Serileri Analizi Tahmin ve Fiyat İndeksleri**, İşletme Fakültesi Yayın No:277, İstanbul, s:290.

ÖZALP, Alperen., ve ANAGÜN A. S., “Sektörel Hisse Senedi Fiyat Tahmininde Yapay Sinir Ağı Yaklaşımı ve Klasik Tahminleme Yöntemleriyle Karşılaştırılması”, **Endüstri Mühendisliği Dergisi**, Cilt 12, Sayı 3-4, Sayfa (2-17)

TARI, Recep., 2002, **Ekonometri**, Alfa Basım Yayım Dağıtım Ltd. Şti., s:407.

TURANLI, Münevver., ve GÜNEREN, Elif., Haziran 2003, “Turizm Sektöründe Talep Tahmin Modellemesi”, **İstanbul Ticaret Üniversitesi Dergisi**, Sayı 3

UYSAL, Muzaffer., EL ROUBI, M. Sherif., 1999, “Artificial Neural Networks versus Multiple Regression in Tourism Demand Analysis”, **Journal of Travel Research**, Vol. 38, No. 2, 111-118 SAGE Publications

WHITBY, Blay., 2005, **A Beginner's Guide: Artificial Intelligence**, Çeviren: Çiğdem Karabağlı, İletişim Yayıncılık, s:179

YURTOĞLU, Hasan., Şubat, 2005, “Yapay Sinir Ağları Metodolojisi ile Öngörü Modellemesi: Bazı Makroekonomik Değişkenler İçin Türkiye Örneği”, **Ekonomik Modeller ve Stratejik Araştırmalar Genel Müdürlüğü**, Yayın No: DPT 2683,

ZHANG, Guoqiang., PATUWO, B. Eddy., Y. HU, Michael.,1998, "Forecasting with artificial neural networks": *The state of the art, International Journal of Forecasting* Vol:14, 35–62

www.tursab.org.tr (Türkiye Seyahat Acentaları Birliđi)

<http://www.qnetv2k.com/Qnet2000Manual/html/qnet99kn.htm> Vesta Services, Inc. Eriřim:18.03.2008