



TALEP TAHMİNİNİN YAPAY SİNİR AĞLARIYLA MODELENMESİ: YERLİ OTOMOBİL ÖRNEĞİ

ARTIFICIAL NEURAL NETWORK MODELING OF DEMAND FORECAST: CASE OF DOMESTIC CAR

İbrahim Zeki AKYURT *

Özet

Talep tahminleri işletme fonksiyonlarının hemen hepsine etki etmektedir. Şüphesiz ki talep tahminlerinin en önemli etkisi bu fonksiyonlardan üretim ve operasyon üzerine olmaktadır. Kuruluş yeri, kapasite ve işgücü kararları ile üretim planları talep tahminlerine dayanmaktadır. Son yıllarda Türk hükümetinin üretim kararı verdiği yerli otomobile oluşacak talebin tahmin edilmesi de bu anlamda önem kazanmıştır. Seri olarak üretilen %100 yerli otomobilin yıllık üretim adetlerinin ve buna bağlı olarak üretim ve diğer planlarının yapılması tamamen bu talebin doğru tahmin edilmesine bağlıdır. Bu amaç doğrultusunda aylık yerli otomobil satışı serinin özellikleri göz önüne alınarak geleceğe yönelik talep tahmini için en uygun model tercih edilmiştir. Bu çalışmada Ocak 2011 – Eylül 2015 veri döneminde aylık yerli otomobil satış değerleri kullanılarak geri yayılım algoritmasıyla eğitilmiş ileri beslemeli yapay sinir ağı modeli uygulanmıştır. Serinin özellikleri, tahmin performans ölçütleri olarak ise ortalama mutlak yüzde hata (mean absolute percentage error – MAPE) ve ortalama hata kare (mean square error – MSE) değerleri dikkate alınarak iteratif olarak uygun gecikme uzunluğu ve gizli nöron sayısı tespit edilmiştir. Elde edilen bulgular neticesinde; mevsimsel etkilerden arındırılmış yerli otomobil satış serinin kullandığı, gecikme uzunluğunun 2 ve gizli nöron sayısının 7 olduğu olduğu modelin en iyi tahmin sonucunu verdiği saptanmıştır.

Anahtar Kelimeler: Talep tahmini, yerli otomobil, yapay sinir ağları, geri yayılım algoritması
Jel Sınıflaması: M11, C45

Abstract

Demand forecasts influence almost every business function. The most important influence of demand forecasts is on production and operation among these functions. Decisions about industrial location, capacity and labor force, and also production plans are based on demand forecasts. Therefore, the future demand forecast regarding the domestic car gains importance which is decided to be mass-produced %100 domestically by the Turkish government. The determination of yearly production numbers and the other related plans necessitate a successful demand forecasting. In this regard, monthly sales of available domestic cars have been taken into account in order to the most appropriate model has been chosen for the future demand forecasting. This study grounds on the monthly data of domestic car sales between January 2011 and September 2015, and uses an artificial neural network backpropagation algorithm. Taking into account data properties, the mean absolute percentage error (MAPE) and mean square error (MSE) as performance criteria of forecasting, the proper lag length and the number of hidden neurons are determined iteratively. As a result of reached findings, it is concluded that the model with a lag length of 2 and 7 hidden neurons gives the best forecasts, where series of seasonally adjusted domestic car sales are used.

Keywords: Demand forecasting, domestic car, artificial neural networks, backpropagation algorithm.
Jel Classification: M11, C45

* Yrd. Doç. Dr., İstanbul Üniversitesi, İşletme Fakültesi, İstanbul, akyurt@istanbul.edu.tr

1.GİRİŞ

Gelecek olayların öngörülmesi becerisine tahmin denmektedir. Bu öngörü, kimi zaman geçmiş verilerin matematiksel olarak analiz edilmesi ile kimi zamansa subjektif yöntemlerle yapılabilmektedir. Bazen de her iki yöntem bir arada, karma yöntemler kullanılarak tahminler yapılabilmektedir. Genel itibariyle bakıldığında, en iyi tahmini veren tek bir yöntemin varlığından her zaman söz edilemez. Bir ürün için gelecek tahmininde kullanılan en iyi yöntem, başka bir ürün için kullanılamaz durumda olabilir. Ayrıca tahmin etmenin ve tahmin sürecinin devamının sağlanmasının hem zaman hem de parasal olarak maliyeti olacağından sınırlarının da iyi çizilmiş olması gerekmektedir. Talep ise piyasada bir ürüne yönelik olarak ortaya çıkan satın alma isteği ve davranışıdır. Talep aynı zamanda satış demektir. Dolayısıyla talep tahmini yerine satış tahmini demek de mümkündür. Başka bir deyişle tahmin, gelecekteki olayları öngörme sanatı ve bilimidir. İşin sanat yönü nitel tahminlerde ortaya çıkar. Nitel tahminlerde, çeşitli sektörlerde uzun yıllar edinilen tecrübelerin sonucunda sezgi yeteneği gelişmiş bir yöneticinin, yönetici grubunun, uzman grubunun ya da tüketici grubunun tahminleri esas alınır. İşin bilim yönünü temsil eden nicel tahminlerde ise geçmişe ya da bugüne ait bazı bilgileri alıp bunları bazı matematiksel modeller yardımıyla geleceğe uyarlamak söz konusu olur. Önemli olan tahmin sanat ve bilimini eş zamanlı ve gerektiği kadar kullanıp en iyi tahmine ulaşmaktır. Bu anlamda tahmin konusunda eklettik çözümlerden söz etmek en doğrusudur. Talepteki yani satış miktarındaki bu değişimler öngörülemediği takdirde pazarda o ürüne yönelen talebin zamanında karşılanamaması söz konusu olabilir. Talep tahminleri, bir işletmenin üretimini, kapasitesinin ve çizelgeleme sistemlerinin belirlenmesinde yardımcı olur. Finansman, pazarlama ve personel planlamasına bir girdi olarak katkıda bulunur. Tahmin tekniği sadece işletmelerdeki ürünler için değil aynı zamanda sıcaklık tahminleri, ekonomik tahminler veya teknolojik tahminler için de kullanılabilir.

Otomobiller günümüzün vazgeçilmez parçalarındandır. Günümüzde hemen herkesin bir veya birkaç aracı vardır ve hayatımızın içerisinde sürekli olarak kullanılmalarıyla karşımıza çıkmaktadır. Ancak bilim dünyası için otomobil sadece bizlerin ki gibi bir taşıma aracı değildir. 20. Yüzyılın içinde iki kez üretim sistemini etkileyen olaylar otomobil sektöründe gelişmiştir. Otomobil rüyası 1800'lü yılların sonunda P&L (Panhard et Levassor)

firması öncülüğünde emek-sanat ağırlıklı üretim ile başlamıştır. Bu üretim türünde tüm ürünler biricik olma özelliğiyle ustaların elinden çıkmaktaydı. 1894 yılına gelindiğinde P&L firması yılda ancak birkaç yüz adetlik üretimle dünyanın en büyük otomobil şirketiydi. 20. yüzyıl ise tam bir otomobil çağı olmuştur. Otomobiller, Henry Ford'un montaj hatlarında yüksek hacimlerde ürettiği T Modeliyle dünyaya yayılmıştır. İkinci dünya savaşının ardından gelen ekonomik buhran dünyayı Toyota Üretim Sistemi ile tanıştırmıştır. Bu bağlamda son iki yüzyıldır lokomotif endüstriler arasında yer alan otomotiv endüstrisi günümüzde önemini hala korumaktadır.

Türk otomotiv endüstrisi ise, yerli üretim çalışmalarının başladığı 1960'lı yıllara dayanmasına rağmen kendi markasını oluşturma yolunda sınıfta kalmıştır. Türkiye dünyada 2014 yılı itibarıyla 1.107.445 adetlik üretimi ile 15. büyük otomotiv üreticisi konumundadır ve 400.000 kişinin üzerinde istihdam sağlamaktadır. Buna rağmen otomotiv endüstrisinde halen montaj ağırlıklı üretim devam etmektedir ve orijinal parça üreticisi konumundadır. Dolayısıyla uluslararası markaların kısmen üretim ve montaj işlemleri yapılmaktadır. Fakat ne yazık ki böyle bir tecrübe, henüz kendi markasını yaratma yeteneği sağlayamamıştır. Günümüzde ileri teknoloji üretimi ve katma değeri yüksek ürünlerin varlığı ülkelerin gelişmesinde büyük rol oynamaktadır. İşte bu tecrübe ve bu anlayışla Türk hükümeti, yerli otomobil tasarımı ve üretimini öncelikli stratejileri arasına koymuştur. Bu alanda çalışmalar halen devam etmektedir. Yakın bir gelecekte de yerli otomobilin üretileceği ve pazara sunulacağı düşünülmektedir. Bunun yanı sıra 2014 yılı verilerine göre Türkiye'de 1000 kişiye 173 otomobil düşerken, bu oran ABD'de 918, Avrupa ülkelerinde ise 500-600 aralığındadır. Bu noktadan da bakılınca Türkiye'deki otomobil satışlarının halen geride olduğu ve daha da artacağı görülmektedir. Dolayısıyla Türkiye'de otomotiv sektörü iç pazar için de oldukça cazip hale gelmekte ve henüz pazarın doymadığı görülmektedir. Bu açıdan da yerli otomobilin üretilerek iç pazara sunulması da önem kazanmaktadır. Türkiye'de 2014 yılında 587,331 adet otomobil satılmıştır. Tüketiciler genel anlamda bakıldığında yerli otomobili tercih etmeleri için birçok neden bulunmaktadır. Yerli otomobil beraberinde daha düşük fiyatı, ucuz yedek parça ve ucuz bakım maliyetini getirecektir. Gerek tüketicilerin bu yöndeki tercihleri gerekse devlet araçlarının yerli kullanıma teşvik edilmesi ve sağlanabilecek vergi avantajları durumunda yerli otomobilin Türkiye pazarında büyüyeceği düşünülmektedir.

Otomotiv endüstrisinde, özellikle üretim planlarının yapılabilmesi için uzun dönemli talep tahminlerinin yapılması önem kazanmaktadır. Bunun altında yatan sebep ise karmaşık

ve zor üretim planlarının varlığıdır. Özellikle son yıllarda adından sıkça bahsedilen müşteri odaklı üretim için talep tahminlerinin doğru yapılarak üretim hatlarının buna göre kurulması ve fabrika içerisindeki organizasyonun bu yönde yapılması önem kazanmaktadır. Günümüzde de yerli otomobil için ilk adımı atmış olan Türkiye için yerli otomobile olan talebin ne olacağının tahmin edilmesi bir o kadar gereklidir. Bu doğrultuda bu çalışmada, markası yerli olmamakla birlikte Türkiye’de üretilen ve yerli olarak tanımlanan otomobillerin satış rakamları dikkate alınmıştır. Bu amaç doğrultusunda Ocak 2011 – Eylül 2015 döneminde gerçekleşen aylık yerli otomobil satış büyüklükleri incelenmiştir. Bu zaman serisine yönelik talep tahmini içinse geri yayılım algoritmasıyla eğitilmiş ileri beslemeli yapay sinir ağı modeli kullanılmıştır. Söz konusu modelin performansı ortalama mutlak yüzde hata (mean absolute percentage error – MAPE) ve ortalama hata kare (mean square error – MSE) ile ölçülmüştür. Çalışmanın bundan sonraki bölümünde talep tahminleri, otomotiv sektöründe talep tahminleri ve talep tahminlerinde yapay sinir ağları kullanımı ile ilgili detaylı bir literatür taramasına yer verilmiştir. Sonraki bölümde ise yapay sinir ağları ve kullanılan model ve sonrasında talep tahmini ve performans ölçümlerine yer verilmiştir.

2. LİTERATÜR TARAMASI

Satış tahminleriyle ilgili literatür incelendiğinde özellikle elektrik ve enerji tüketiminin kısa ve uzun vadeli tahminleri ile bunların fiyat tahminleri üzerinde durulduğu görülmektedir (Zachariadis & Kouvaritakis, 2003; Cárdenas vd. 2012; Weron, 2014; Xie & Hong, 2015) Sıklıkla rastlanılan bir diğer alan ise yine enerji ile bağlantılı olarak rüzgar gücü tahminleridir (Silva, 2014; Mangalova & Agafonov 2014). Tahmin yöntemlerini Alho (2014), demografik yapı, Kouwenberg & Zwinkels (2014) konut piyasası, Lima vd. (2014) hidroelektrik santraline su akışı konularında incelemişlerdir. Turanlı & Güneren (2003), turizm sektörü üzerine talep tahmini yapmışlardır. Solak (2013), Türkiye’nin 2012-2020 yılları için petrol talebini ARIMA yöntemi ile tahmin etmiştir. Soysal ve Ömürgönülşen (2010), 2000 ve 2007 yılları arasında Türkiye’ye gelen turist sayısını kullanarak 2008 yılının ilk altı ayı için talep tahmini yapmışlardır. Hareketli Ortalama, Basit Üstel Düzleştirme, Holt ve Winter yöntemlerini uygulamış ve performanslarını karşılaştırmışlardır.

Talebin yapay sinir ağı ile tahmini de birçok çalışmaya konu olmuştur. Law & Au (1999); Chen vd. (2012), turizm sektöründe turist talebini yapay sinir ağı ile tahmin etmişlerdir. Tsai vd. (2009), kısa dönemli tren yolcuları talebini, yapay sinir ağı ile tahmin etmiş ve performansını MSE ve MAPE değerleriyle ölçmüşlerdir. Chang vd. (2011); Al-Saba & El-Amin (1999); Jaramillo-Morán vd. (2013), elektriğe olan talebi, yapay sinir ağı ile tahmin etmişlerdir. Hamzaçebi & Kutay (2004) yaptıkları çalışmada elektrik enerjisi talep tahmininde yapay sinir ağı yöntemi ile regresyon ve Box-Jenkins yöntemlerini karşılaştırmışlardır.

Nishikawa & Shimizu (1982), Japon otomotiv endüstrisinin net otomobil satışlarını tahmin etmiştir. Kleyner & Sandborn (2005), otomotiv garanti sürecine yönelik bir tahmin yöntemi geliştirmişlerdir. Sa-ngasoongsong vd. (2012), otomotiv endüstrisinde 6-24 aylık tahminleri vektör hata düzeltme modeli ile yapmış ve sonuçları klasik zaman serisi modelleriyle karşılaştırmışlardır. Karşılaştırmada RMSE ve MAPE değerlerini kullanmışlardır. Yıldız & Ustaoglu (2012), Türkiye'deki elektrikli otomobil üretimi ve ekonomik üretim miktarı üzerine çalışmışlardır. Karaatlı vd. (2012), Türkiye'deki Ocak 2007 ve Haziran 2011 yılları arasındaki aylık otomobil satışları verisini kullanarak, farklı bağımsız değişkenlerle, gelecek döneme ait satış tahmini yapılmıştır. Ramirez vd. (2014), otomotiv sektöründe birinci düzey tedarikçilere yönelik simülasyon temelli bir model geliştirmişlerdir. do Rego & Mesquita (2015), altı yıllık talep verisini kullanarak otomobil yedek parçalarına olan talep tahminini simülasyon yardımıyla modelleyerek stok politikası geliştirmişlerdir. Gansterer, M. (2015), farklı tahmin modelleri ile bütünleşik üretim planını modellemiştir.


3. VERİ KÜMESİ VE AMPİRİK BULGULAR

Çalışmanın ampirik kısmında Ocak 2011 – Eylül 2015 dönemi için Türkiye'deki yerli otomobil satışına ilişkin aylık gözlemler incelenerek toplam yerli otomobil satış büyüklükleri tahmin edilmiştir. Bu amaç doğrultusunda; Otomotiv Distribütörleri Derneği'nin raporlarından elde edilen veriler kullanılarak talep tahmin yöntemlerinden biri olan yapay sinir ağı (YSA) uygulanmıştır.

YSA, nöroloji, matematik, istatistik, fizik, bilgisayar bilimi ve mühendislik disiplinlerinin içerisinde kendine yer bulmuş olup; insanlar tarafından gerçekleştirilen öğrenme, kümeleme ve optimizasyon gibi konularda başarılı sonuçlar sunan bir yöntemdir

(Öztemel, 2006). YSA, beyin ve onun çalışma prensiplerini taklit eden makine öğrenme araçlarıdır. YSA modelleri, geleneksel parametrik modellere göre birtakım avantajlara sahiptir. YSA; normallik, durağanlık gibi kısıtlayıcı parametrik varsayımlara dayanmamakta olup parametrik modellerin aksine veri kümesindeki yapısal değişikliklere uyum sağlayabilmekte ve esneklerdir (Darrat & Zhong, 2000). Söz konusu avantajlar göz önünde alındığında; bu çalışmada mevsimsel etkiler altında kalan veri kümesinin modellenmesinde YSA kullanılmıştır. Bilindiği üzere; birçok iktisadi zaman serisi, mevsimsel etkilerin altında bulunmaktadır. Mevsimsel hareketlerde dönemler, nispeten düzenli ve periyodik bir salınım göstermektedir. Literatürde yer alan ampirik çalışmaların bir kısmı seriyi mevsimsellikten arındırarak YSA kullanılmasını önerirken bir kısmı ise orijinal gözlem düzeyleri ile çalışılabileceğini ortaya koymuştur(Benkachcha vd. 2015, Crone & Dhawan 2007, Zhang & Qi 2005, Claveria vd. 2015). Dolayısıyla çalışmada iki durum için de YSA modeli tahmin edilmiştir.

Literatürde birçok YSA modeli bulunmakta olup; bu çalışmada geri yayılım algoritmasıyla eğitilmiş ileri beslemeli YSA modeli kullanılmıştır. Bu modelde girdi (input) katmanı, gizli (hidden) katman ve çıktı (output) katmanı bulunmaktadır. Denetimli öğrenme ile girdiler ve bunlara karşılık gelen çıktılar ağa öğretilmektedir. Bu modelle gözlenen çıktı değeri ile ağın tahmin ettiği çıktı değeri arasındaki hataların kareleri toplamının en küçüklenmesi hedeflenmektedir. Bu hatayı en küçüklemek içinse gizli katmandaki ağırlıklar iteratif olarak yeniden düzenlenerek en iyi sonuç ortaya konulmaktadır (Satman,2010). k sinir hücresi için YSA'nın yapısı, Şekil 1'de gösterilmiştir.



Şekil 1: Yapay Sinir Ağı Modelinin Yapısı

Kaynak: Simon Haykin, *Neural Networks A Comprehensive Foundation, Second Edition*, Prentice Hall International, Inc., Upper Saddle River, NJ, 1999, s.11.

Şekil 1 incelendiğinde; yapay sinir hücresine dışarıdan alınan bilgiyi gösteren girdilerin, çıktıya dönüşümünü görülmektedir. Bu çalışmanın girdilerini, Ocak 2011- Eylül 2015 dönemindeki aylık yerli otomobil satışına ait büyüklükler oluşturmaktadır. Hatırlanacağı üzere; bu seri mevsimsel dalgalanmaları barındırmaktadır. Bunun için geri yayılım algoritmasıyla eğitilmiş ileri beslemeli YSA modeli tahmin edilmeden önce hareketli ortalamalar yöntemi kullanılarak seri, mevsimsel etkilerden arındırılmıştır. Böylelikle orijinal gözlem değerlerine sahip seri ve mevsimsel etkilerden arındırılmış seri için iki YSA modeli tahmin edilmiştir. Bu modeller için uygun gecikme uzunluğu ve gizli nöron sayısı iteratif olarak tespit edilmiştir. Bu aşamada modellerin tahmin performanslarının değerlendirilmesi için MAPE ve MSE değerleri kullanılmıştır. Ayrıca söz konusu modellerin tahminin de aktivasyon fonksiyonu olarak sigmoid fonksiyonu kullanılmış olup; analizler, R programında yapılmıştır.

Tablo 1: Eğitim Sonuçları

Veri Kümesi	Gizli Nöron Sayısı	MSE	MAPE
Gözlenmiş	7	6,914E-03	10,09
Mevsimsellikten Arındırılmış	7	8,609E-04	7,25

Tablo 1 incelendiğinde; iterasyonlar neticesinde her iki model için de gecikme uzunluğunun 2 ve gizli nöron sayısının 7 olduğu görülmektedir. Çalışmanın veri kapsamı dâhilinde otomobil satışına ait büyüklüklerin tahminin mevsimsellikten arındırılmış veri kümesi kullanılarak yapılması gerektiği sonucuna ulaşılmıştır. Dolayısıyla talep tahminiyle ilgili yapılacak olan çalışmalarda araştırmacıların mevsimsellikten arındırılmış veri kümesini kullanarak geri yayılım algoritmasıyla eğitilmiş ileri beslemeli yapay sinir ağı modelini kullanması iyi bir araç olacaktır.

4.SONUÇ

Bu çalışma, otomotiv sektöründe 2023 yılı için hedeflenen 4 milyon üretim, 3 milyon ihracat ve 75 milyar dolar ihracat gelirin ulaşabilmek için stratejik öneme sahip yerli otomobil talebini modellemek amacıyla gerçekleştirilmiştir. Bu amaç doğrultusunda; Otomotiv Distribütörleri Derneği'nin raporlarından hareketle elde edilen ve Ocak 2011 – Eylül 2015 dönemini kapsayan aylık yerli otomobil satış değerleri incelenmiştir. Bu veri kullanılarak popüler talep tahmin yöntemlerinden biri olan yapay sinir ağı (YSA) uygulanmıştır. Bu süreçte; gözlenen çıktı değeri ile ağı tahmin ettiği çıktı değeri arasındaki hataların kareleri toplamının en küçüklenmesi amacıyla geri yayılım algoritmasıyla eğitilmiş

ileri beslemeli YSA modeli tercih edilmiştir. Ocak 2011 – Eylül 2015 dönemi için aylık yerli otomobil satış değerleri incelendiğinde; serinin mevsimsel etkilerin altında olduğu gözlenmiştir. Bu nedenle model, hem orijinal gözlem değerleri hem mevsimsellikten arındırılmış seri için tahmin edilmiştir. Elde edilen bulgular; veri dönemi için otomobil satışına ait değerlerin tahminin mevsimsellikten arındırılmış serinin kullanılarak yapılması gerektiğini göstermiştir. Bu nedenle; talep tahminiyle ilgili yapılacak olan çalışmalarda araştırmacıların mevsimsellikten arındırılmış seriyi dikkate alarak geri yayılım algoritmasıyla eğitilmiş ileri beslemeli yapay sinir ağları modelini kullanmasının tahmin performansı açısından iyi bir araç olacağı düşünülmektedir.

KAYNAKÇA

Al-Saba, T., & El-Amin, I. (1999). Artificial neural networks as applied to long-term demand forecasting. *Artificial Intelligence in Engineering*, 13(2), 189-197.

Alho, J. M. (2014). Forecasting demographic forecasts. *International Journal of Forecasting*, 30(4), 1128-1135.

Benkachcha.S, Benhra.j & El Hassani.H. (2015). Seasonal Time Series Forecasting Models based on Artificial Neural Network, *International Journal of Computer Applications* (0975 – 8887), Volume 116 ,No. 20, pp.1-14.

Cárdenas, J. J., Romeral, L., Garcia, A., & Andrade, F. (2012). Load forecasting framework of electricity consumptions for an Intelligent Energy Management System in the user-side. *Expert Systems with Applications*,39(5), 5557-5565

Chang, P. C., Fan, C. Y., & Lin, J. J. (2011). Monthly electricity demand forecasting based on a weighted evolving fuzzy neural network approach. *International Journal of Electrical Power & Energy Systems*, 33(1), 17-27.

Chen, C. F., Lai, M. C., & Yeh, C. C. (2012). Forecasting tourism demand based on empirical mode decomposition and neural network. *Knowledge-Based Systems*, 26, 281-287.

Clavería González, Ó., Monte Moreno, E., & Torra Porras, S. (2015). Effects of removing the trend and the seasonal component on the forecasting performance of artificial neural network techniques. IREA–Working Papers, 2015, IR15/003.

Crone, S. F., & Dhawan, R. (2007). Forecasting seasonal time series with neural networks: a sensitivity analysis of architecture parameters. In *Neural Networks, 2007. IJCNN 2007. International Joint Conference on* (pp. 2099-2104). IEEE.

Darrat, A. F., & Zhong, M. (2000). On Testing the Random-Walk Hypothesis: A Model-Comparison Approach. *Financial Review*, 35(3), 105-124.

do Rego, J. R., & de Mesquita, M. A. (2015). Demand forecasting and inventory control: A simulation study on automotive spare parts. *International Journal of Production Economics*, 161, 1-16.

Gansterer, M. (2015). Aggregate planning and forecasting in make-to-order production systems. *International Journal of Production Economics*, 170, 521-528.

Hamzaçebi, C., & Kutay, F. (2004). Yapay Sinir Ağları İle Türkiye Elektrik Enerjisi Tüketiminin 2010 Yılına Kadar Tahmini. *Gazi Üniversitesi Mühendislik-Mimarlık Fakültesi Dergisi*, 19(3).

Haykin, S. (1999). *Neural Networks A Comprehensive Foundation*, Second Edition, Prentice Hall International, Inc., Upper Saddle River, NJ.

Jaramillo-Morán, M. A., González-Romera, E., & Carmona-Fernández, D. (2013). Monthly electric demand forecasting with neural filters. *International Journal of Electrical Power & Energy Systems*, 49, 253-263.

Karaatlı, M., Helvacıoğlu, Ö. C., Ömürbek, N., & Tokgöz, G. (2012). Yapay Sinir Ağları Yöntemi İle Otomobil Satış Tahmini. *Uluslararası Yönetim İktisat ve İşletme Dergisi*, 8(17), 87-100.

Kleyner, A., & Sandborn, P. (2005). A warranty forecasting model based on piecewise statistical distributions and stochastic simulation. *Reliability Engineering & System Safety*, 88(3), 207-214.

Kouwenberg, R., & Zwinkels, R. (2014). Forecasting the US housing market. *International Journal of Forecasting*, 30(3), 415-425.

Law, R., & Au, N. (1999). A neural network model to forecast Japanese demand for travel to Hong Kong. *Tourism Management*, 20(1), 89-97.

Lima, L. M., Popova, E., & Damien, P. (2014). Modeling and forecasting of Brazilian reservoir inflows via dynamic linear models. *International Journal of Forecasting*, 30(3), 464-476.

Mangalova, E., & Agafonov, E. (2014). Wind power forecasting using the k-nearest neighbors algorithm. *International Journal of Forecasting*, 30(2), 402-406.

Nishikawa, T., & Shimizu, S. (1982). Identification and forecasting in management systems using the GMDH method. *Applied Mathematical Modelling*, 6(1), 7-15.

Ramírez-Granados, M., Hernández, J. E., & Lyons, A. C. (2014). A Discrete-event Simulation Model for Supporting the First-tier Supplier Decision-Making in a UK's Automotive Industry. *Journal of applied research and technology*, 12(5), 860-870.

Sa-ngasoongsong, A., Bukkapatnam, S. T., Kim, J., Iyer, P. S., & Suresh, R. P. (2012). Multi-step sales forecasting in automotive industry based on structural relationship identification. *International Journal of Production Economics*, 140(2), 875-887.

Satman, M. H. (2010). *İstatistik ve Ekonometri Uygulamaları ile R*, İstanbul, Türkmen Kitapevi.

Silva, L. (2014). A feature engineering approach to wind power forecasting: GEFCom 2012. *International Journal of Forecasting*, 30(2), 395-401.

Solak, A. O. (2013). Türkiye'nin Toplam Petrol Talebi ve Ulaştırma Sektörü Petrol Talebinin Arıma Modeli İle Tahmin Edilmesi. *Süleyman Demirel Üniversitesi İktisadi Ve İdari Bilimler Fakültesi Dergisi*, 18(3).

Soysal, M., & Ömürgönülşen, M. (2010). Türk Turizm Sektöründe Talep Tahmini Üzerine Bir Uygulama. *Anatolia: Turizm Araştırmaları Dergisi*, 21(1), 128-136.

Tsai, T. H., Lee, C. K., & Wei, C. H. (2009). Neural network based temporal feature models for short-term railway passenger demand forecasting. *Expert Systems with Applications*, 36(2), 3728-3736.

Turanlı, M. & Güneren, E. (2003). Turizm Sektöründe Talep Tahmin Modellemesi. *İstanbul Ticaret Üniversitesi Dergisi* 2(3): 1-13.

Weron, R. (2014). Electricity price forecasting: A review of the state-of-the-art with a look into the future. *International Journal of Forecasting*, 30(4), 1030-1081.

Xie, J., & Hong, T. (2015). GEFCom2014 probabilistic electric load forecasting: An integrated solution with forecast combination and residual simulation. *International Journal of Forecasting*.

Yıldız, B., & Ustaoglu, M. (2012). Optimal Production Model for EVs Manufacturing Process in Turkey: A Comparable Case of EMQ/JIT Production Models for EVs' Battery Production. *Procedia-Social and Behavioral Sciences*, 58, 1482-1490

Zachariadis, T., & Kouvaritakis, N. (2003). Long-term outlook of energy use and CO₂ emissions from transport in Central and Eastern Europe. *Energy policy*, 31(8), 759-773.

Zhang, G. Peter & Qi, M. (2005). Neural network forecasting for seasonal and trend time series, *European Journal of Operational Research*, 160, 501–514.