

Araştırma Makalesi

YAPAY SİNİR AĞLARI İLE TALEP TAHMİNİ: PERAKENDE SEKTÖRÜNDE BİR UYGULAMA*

Muhammed Resul AYDIN¹, Osman YAZICIOĞLU²

¹İstanbul Ticaret Üniversitesi, Fen Bilimleri Enstitüsü, Endüstri Mühendisliği Anabilim Dalı, Küçükyalı, İstanbul, Türkiye, mresulaydin@outlook.com, orcid.org/0000-0002-7891-0480

²İstanbul Ticaret Üniversitesi, Mühendislik Fakültesi, Endüstri Mühendisliği Bölümü, Küçükyalı, İstanbul, Türkiye, oyazicioglu@ticaret.edu.tr, orcid.org/0000-0002-0476-4376

Öz

Bu çalışmada; zaman serisi yöntemlerinden ARIMA ile yapay sinir ağı modellerinin tahmin sonuçları kıyas edilerek, reel değerlere en yakın değerleri sunan model yardımıyla bir süpermarketin kasap reyonu için müşteri talep tahmini yapılması hedeflenmiştir. Çalışmada Ocak 2017- Aralık 2018 döneminde gerçekleşen haftalık satış miktarlarından faydalanılmıştır. Yapılan denemeler neticesinde, haftalık satış miktarları kullanılarak oluşturulan modellerde yapay sinir ağı modelinin optimal sonucu sunduğu görülerek 2019 yılı için haftalık bazda müşteri talep tahminleri yapılmıştır.

Anahtar Kelimeler: *Yapay sinir ağları, ARIMA, talep tahmini, perakende sektörü.*

Research Article

DEMAND FORECASTING WITH ARTIFICIAL NEURAL NETWORK: A CASE STUDY IN RETAILING SECTOR

Abstract

In this study, artificial neural network and ARIMA which is one of the time series models, have been discussed to determine the optimal forecasting model. Research data has been collected from a supermarket's sales period which occurred in January 2017- December 2018. According to the results of the test, artificial neural network is more reliable and consistent to build appropriate model for the year 2019.

Keywords: *Artificial neural network, ARIMA, demand forecasting, retail industry.*

* Bu çalışma, İstanbul Ticaret Üniversitesi Fen Bilimleri Enstitüsü'nde yapılan "Perakende Sektöründe Talep Tahmini" başlıklı yüksek lisans tezinden hazırlanmıştır.

Received / Geliş tarihi: 14.05.2019

Accepted / Kabul tarihi: 28.05.2019

Corresponding Author/ Sorumlu Yazar :

mresulaydin@outlook.com

1. GİRİŞ

Günümüzde meydana gelen sert rekabet ortam ile birlikte, kurumlar doğru adımlar atabilmek için gelecek planlamasına ihtiyaç duymaktadır. Rekabetçi piyasa, ekonomik ve politik dalgalanmalar neticesinde geleceği öngörebilme zorlaşmakta bu sebeple doğru öngörmenin önemi artmaktadır. Bu sebeplerden ötürü birçok kurum ve araştırmacı, tahmin hakkında araştırmalar gerçekleştirmektedirler (Şen ve Kaba, 2009).

Günümüzde, talebi etkileyen etkenlerin çok olması ve bunların birbirleriyle ilişkilerinin karmaşık olması sebebiyle, tecrübe ve sezgi ile yapılan tahminler yetersiz kalmaktadır. Bu sebeple istatistiksel yöntemlerle talep tahmini büyük önem arz etmektedir. Talep tahmin yöntemlerinde kullanılan teknikler, uygulamalı istatistiğin konuları içerisinde yer almaktadır (Kobu, 1994). Artan rekabet neticesinde, perakende sektörü oyuncularını da doğru zamanda, doğru yatırım yapmayı hedeflemektedir. Bu hedeflere paralel olarak firmalar talep tahmin modellerinden faydalanmaktadır.

Araştırmanın örneklemini İstanbul-Ümraniye sınırları içerisinde bulunan bir süpermarket oluşturmaktadır. Sistematik veri toplama yöntemine başvurulmuş 2017-2018 yılları arasında gerçekleşen 104 haftalık satış miktarları örneklem olarak belirlenmiştir.

Bu çalışmanın amacı; bir süpermarketten elde edilen veriler yardımıyla yapay sinir ağları ve zaman serisi tahmin yöntemlerinin uygulanması, uygulanan iki modelin geçmişe dönük tahmin doğruluklarının kıyas edilerek en uygun sonuç sağlayan modelin seçilmesi, seçilen bu model yardımıyla gelecek dönem taleplerinin haftalar itibarıyla tahmin edilmesidir. Uygulamada YSA modeli Weka paket programı ile ARIMA modeli ise EViews paket programıyla oluşturulmuştur.

Çalışmadan elde edilen bulguların, küçük ve orta ölçekli yerel perakende firmalarının talep tahmini metodlarından faydalanarak gelişim göstermesine ve gittikçe kızışan rekabet ortamında ayakta kalmasına ve literatüre katkı sunması beklenmektedir.

Talep tahmini, perakende sektöründe talep tahmini, yapay sinir ağları ve ARIMA modelleri ile literatürde mevcut birçok çalışma bulunmaktadır. Kandanand, (2011) çalışmasında Tayland ülkesine ait 1986-2000 yılları arasındaki elektrik tüketim değerlerinden faydalanarak, yapay sinir ağları, ARIMA ve çoklu lineer regresyon ile tahmin modelleri oluşturmuş, oluşturulan modellerin performanslarının kıyaslanması neticesinde en yüksek tahmin performansını yapay sinir ağları modelinin sunduğu sonucunu elde etmişlerdir.. Hamzaçebi ve Kutay, (2004) çalışmalarında yapay sinir ağları yardımıyla uzun dönemli elektrik enerjisi tüketimini tahmin etmişlerdir. Sun vd., (2008) çalışmalarında bir perakende mağazası için yapay sinir ağları yardımıyla en uygun talep modelini belirlemeye çalışmışlardır. Kızılaslan, (2008) çalışmasında geri beslemeli yapay sinir ağları modelleri ile doğalgaz tüketim talebini tahmin etmiştir. Karaatlı vd., (2012) çalışmasında otomobil satış miktarlarını yapay sinir ağları yöntemiyle tahmin etmiş olup, otomotiv sektörü ile alakalı politikaların

belirlenmesine katkı sunmayı hedeflemişlerdir. Solak, (2013) çalışmasında Türkiye için 2012 yılı ile 2020 yılı arasındaki toplam petrol talebini ARIMA modeli ile tahmin etmişlerdir. Es , (2013) çalışmalarında yapay sinir ağları yardımıyla, 2011-2025 yılları arası Türkiye net enerji talebini tahmin etmişlerdir. Wongsathan ve Seedadan, (2006) çalışmalarında ARIMA ve yapay sinir ağları modelleri ile hava kirliliğini tahmin etmişlerdir. Amber ve Khan, (2018) çalışmasında ileri beslemeli yapay sinir ağları yardımıyla kısa dönemli yük tahmininde bulunmuşlardır. Wang vd., (2018) çalışmalarında ARIMA modeli ile Çin Halk Cumhuriyeti'ne ait geçmiş petrol tüketim verilerinden faydalanarak,2017-2030 yılları için tüketim tahmini yapmışlardır. Musaylh vd., (2018)çalışmalarında kısa dönemli elektrik talebi tahmini için ARIMA modelinden de faydalanarak ileriye dönük tahminler sunmuşlardır. Ekmekçi, (2016) çalışmasında 1970-2013 yılları arasındaki verilerden faydalanarak, 2013-2025 yılları arasındaki doğalgaz tüketimini ARIMA modeli ile tahmin etmişlerdir. Ohyver ve Pudjihastuti, (2018) çalışmalarında yapay sinir ağları da olmak üzere çeşitli tahmin metotlarını incelemişlerdir. Donselaar vd., (2016) çalışmalarında promosyon zamanlarında çürüyen besinler için analiz ve talep tahmini sunmuşlardır. Hareketli ortalamalar ile birlikte regresyon analizi ile de talep tahmin modeli oluşturulmuştur. Tanizaki vd., (2019) çalışmalarında makine öğrenmesi ve istatistiksel analiz kullanarak restoranlarda talep tahmini yapmışlardır. Mağaza konumu, hava durumu, grup organizasyonları gibi talebi etkileyen faktörler hesaba katılarak mağazaya özgü bilgiler ile talep tahmin modeli oluşturularak talep tahmini yapmışlardır.

2.METODOLOJİ

2.1. Yapay Sinir Ağları (YSA)

Yapay sinir ağları (Artificial Neural Networks- ANN), insan beyninin çalışma prensibinden etkilenilerek, esinlenilerek geliştirilmiş, birbirleri ile paralel çalışan, bilgi alan ve bilgi gönderen bir yapıdan meydana gelmektedir. Problemleri çözme maksadıyla faydalanılan iş elemanları (yapay sinir hücreleri), bir ağ şeklinde birbirlerine bağlanmıştır. Hücreler arasında gerçekleşen bilgi akışı, bağlantı değerleri ve ilişkilerle gösterilmektedir. Sistemin öğrenme kabiliyeti ve zeki davranışı, bağlantı değerlerinin vasıtasıyla sunulmaktadır (Tekin, 2009). Yapay sinir ağları kendi kendine ilerleme, öğrenme ve uyum sağlama kabiliyetine sahiptir (Mo, Wang ve Niu, 2016; Pelusi vd., 2018).Yapay sinir ağları insan beyninin karakteristiklerinden olan, öğrenme yolu ile yeni bilgiler oluşturup, keşfedebilmektedir (Öztemel, 2012). Yapay sinir ağları girdi ve çıktı arasında direk ilişkinin bulunmadığı, açık tanımlamaların bulunmadığı lineer olmayan problemlerde en iyi sonuçları sunmaktadır (Masters, 1993).

Yapay sinir ağları ile sayısız uygulamalar yapılmış ve başarılı sonuçlar elde edilmiştir. Geniş bir uygulama alanına sahip yapay sinir ağları ile yapılan işlem alanları; tahmin, sınıflandırma, veri ilişkilendirme, veri filtreleme, tanıma ve eşleştirme, teşhis, yorumlamadır (Duman, 2006). Yapay sinir ağları ayrıca ses tanıma, parmak izi tanıma, el yazısı tanıma, otomatik araç denetimi gibi alanlarda da uygulanmaktadır (Elmas, 2007).

Yapay sinir hücresi (YSH), insan sinir hücresini taklit edebilmeyi hedefleyen bir yapıdır. Bir yapay sinir hücresi genelde beş ana birimden meydana gelmektedir. Bunlar; girdiler, ağırlıklar, toplama fonksiyonu, aktivasyon fonksiyonu ve çıktı birimleridir. Girdiler ilk olarak sinir hücresine girerek ilgili bağlantı aralıkları ile çarpım işleme tabi tutulurlar, akabinde bir birleştirme fonksiyonu ile birleştirirler ve böylece nöronun net girdisi ortaya çıkar. Net girdi bir aktivasyon ile işlenir. Aktivasyon fonksiyonuna ait çıktı yardımıyla da nöronun net çıktısı belirlenir (Hamzaçebi, 2011).

Yapay sinir ağlarında mevcut olan bağlantıların ağırlık değerlerinin değiştirilmesiyle gerçekleşen işleme “ağın eğitilmesi” denir. Yapay sinir ağlarının eğitim süreci, belirli kurallara bağlı olarak gerçekleşmektedir. Bu kurallar ise öğrenme kuralları olarak isimlendirilmektedir. Ağırlıkların değiştirilme işlemi öğrenme kuralları çerçevesinde gerçekleştirilir. Yapay sinir ağlarında, ağırlıkların doğru değerlere ulaşması neticesinde, örneklerin temsilini gerçekleştirdiği problem konusunda ağın “genelleme” yapabilme yeteneğine ulaşması demektir. Bu yeteneğe ulaşma işlemine ise “ağın öğrenmesi” denmektedir (Es, 2013).



Şekil 1. YSA'ların sınıflandırılması (Hamzaçebi, 2011).

İleri Beslemeli Yapay Sinir Ağları

İleri beslemeli ağlarda, genel olarak işlemci elemanlar katmanlar halinde bulunmaktadır. Akış, girdi katmanından çıktı katmanının doğru tek yönlü bağlantılar yardımıyla iletilir. Katmanlar arası bağlantı sırasında, aynı katman için bağlantı mevcut değildir. Çok katmanlı algılayıcılar (MLP) ve sayısallaştırılmış öğrenme vektörü (LVQ) ağları ileri beslemeli ağlara örnek olarak verilebilir (Saygılı, 2008).

İleri beslemeli sinir ağının giriş katmanında bulunan veriler hiçbir işleme tabi tutulmadan bir sonraki katmana iletilir. Gizli katmandaki işlemci eleman sayısının tayini, sistem veya kullanıcı tarafından uygulanan problemin giriş sayısı ile paralel olarak belirlenebilmektedir. Gizli katmandaki, ara katman sayısı ve ara katmanlarda

bulunan işlemci eleman sayısının belirlenmesi için diğer bir yöntem ise deneme-yanılma yöntemidir (Yüksek, 2007).

2.2. Box-Jenkins Yaklaşımı Ve ARIMA Modelleri

Box-Jenkins metodu, tek değişkene sahip zaman serileri için ileriye dönük tahmininde, tercih uygulanan metotlardan birisidir. Kısa dönem tahmin yöntem bilimine ait bu yeni ve başarılı metodu, kesikli ve durağan zaman serilerinin ileriye dönük tahmin modellerinin oluşturulmasında ve tahminlerin uygulanmasında sistematik yaklaşım sunmaktadır (Mabert ve Radeliffer, 1974). Box-Jenkins metodunun temel felsefesi cimrilik (tutumluluk) üzerine inşa edilmiştir. Cimrilik (az seyrekliğe sahip) felsefesi zaman serisi verilerine ait özellikleri sunan en uygun bir model oluşturmayı öngörür (Sevüktekin ve Nargeleçekenler, 2007). Box-Jenkins zaman serisi analizlerinde ve ön raporlama aşamasında uygulanan genel ARIMA modelleri ile eş anlama sahiptir (Erdoğan, 2006). Box-Jenkins ile ilintili modeller son 20 yıl içerisinde geliştirilmiştir. Box-Jenkins yönteminin önemli varsayımlarından birisi de eşit zaman aralıkları ile ulaşılan gözlem değerlerinden oluşan serinin kesikli ve durağan olmasıdır (Ekmekçi, 2016). Durağan olmayan zaman serilerinin Box-Jenkins metodu ile öngörülmesini sağlamak için birtakım dönüşüm yöntemleri yardımıyla durağan hale getirilmesi gerekmektedir (Kaynar ve Taştan, 2009).

Box-Jenkins Yöntemi ile tahmin dört aşamada meydana gelmektedir (Kaynar ve Taştan, 2009).

1. Model Belirleme: Zaman serisi için uygun Box-Jenkins modelinin belirlendiği aşamadır.
2. Parametre Tahmini: Model belirleme aşamasının akabinde belirlenen model ile ilgili parametrelerin öngörüldüğü aşamadır.
3. Uygunluğun Testi: Modelin veri setine uygunluğunun istatistiksel yöntemler ile teste tabi tutulduğu aşamadır. Bu aşamada modelin uygun bulunması durumunda son aşamaya geçiş yapılır. Aksi takdirde başka modelin tespit edilmesi için ilk aşamaya dönülür.
4. Tahmin: Belirlenen en uygun modelin tahmin için uygulandığı aşama, son aşamadır.

Box-Jenkins Yöntemi Vasıtasıyla Tahmin Edilebilen Zaman Serisi Modelleri; Otoregresif (AR) Modeli, Hareketli Ortalama (MA) Modeli, Otoregresif-Hareketli Ortalama (ARMA) Modeli Ve Otoregresif Bütünleşik Hareketli Ortalama (ARIMA) Modelidir (Kaynar ve Taştan, 2009).

Otoregresif Bütünleşik Hareketli Ortalamalar modeli, zaman serileri temelli sayısal bir model olup; tek veya çok değişkenli olabilmektedir. Talep tahmini çalışmalarında çoğunlukla tek değişkenli Otoregresif Bütünleşik Hareketli Ortalamalar yöntemi kullanılmaktadır (Clark, 2002). Modelin temel işlevi otoregresif süreçler içermesidir. Yani, geçmiş verilerden yararlanarak gelecekle ilgili istatistiksel tahminler yapabilmesi, süreçleri birleştirmesi ve hareketli ortalama süreçlerinin hepsini birlikte

içermesi olarak bilinmektedir (Chung, 2001).

Box ve Jenkins iki modeli birleştirerek Otoregresif Bütünleşik Hareketli Ortalamalar modelini geliştirmiştir. Bu yaklaşım, zaman serilerinin durağan olduğu varsayımına dayanmaktadır. Zaman serilerinin durağan olmaması, belirli bir eğilim içermesi anlamına gelmektedir. Zaman serilerinin durağan olmaması durumunda, zaman serilerinin bir veya daha fazla kere farkının alınması ile durağanlaştırılarak Otoregresif Bütünleşik Hareketli Ortalamalar yapısı oluşturulabilmektedir (Adıyaman, 2007).

ARIMA modelleri, durağan olmayan fakat fark alma işlemi neticesinde durağan hale getirilmiş serilerde kullanılan modellerdir. İlk başta durağan olmayan lakin fark alma işlemi neticesinde durağan hale gelmiş serilere kullanılan modeller “durağan olmayan doğrusal stokastik modeller” şeklinde isimlendirilmektedir. Bu modeller d dereceden fark uygulanmış serilere kullanılan, değişkenin t-dönemine ait değerinin belirli bir sayıdaki geri dönem değerleri ile aynı döneme ait hata teriminin doğrusal fonksiyonu şeklinde belirtildiği AR dönemidir. Değişkenin t- dönemindeki değerinin mevcut dönemdeki hata terimi ve belirli sayıda geri dönem hata terimlerinin doğrusal fonksiyonu olarak belirtildiği MA modellerinin bir araya gelmesidir. Modellerin genel olarak ARIMA (p, d, q) şeklindedir. Burada belirtilen p ve q harfleri sırasıyla Otoregresif (AR) Modelin ve Hareketli Ortalama (MA) Modelinin derecesi, d ise fark alma derecesi anlamına gelmektedir (Kaynar ve Taştan, 2009).

$$Z_t = \Phi_1 Z_{t-1} + \Phi_2 Z_{t-2} + \dots + \Phi_p Z_{t-p} + \delta + a_t - \Theta_1 a_{t-1} - \Theta_2 a_{t-2} - \dots - \Theta_q a_{t-q}$$

Eşitlikte; $Z_t, Z_{t-1}, \dots, Z_{t-p}$ d dereceden farkı alınmış gözlem değerlerini, $\Phi_1, \Phi_2, \dots, \Phi_p$ d dereceden farkı alınmış gözlem değerleri için katsayıları, δ sabit değeri, $a_t, a_{t-1}, \dots, a_{t-q}$ hata terimlerini ve $\Theta_1, \Theta_2, \dots, \Theta_q$ hata terimleri ile ilgili katsayıları göstermektedir (Yükçü ve Gönen, 2009).

3. BULGULAR

Bu çalışmada bir süpermarketin kasap reyonuna ait talepler incelenmiştir. Kasap reyonu ise dana, kuzu ve tavuk olmak üzere 3 farklı et türüne göre incelenmiştir. 3 farklı et türüne olan talepler ve tahminler ayrı incelenip ayrı olarak analiz edilmiştir. 3 farklı et ürünü için yapay sinir ağları modelleri ve zaman serisi analizlerinden olan ARIMA modelleri ile tahmin modelleri oluşturulmuştur. Oluşturulan tahmin modellerinin doğruluğunun analizi için çıktı performansları karşılaştırılmış ayrıca MAPE ve MSE değerleri ile birlikte kıyas edilerek uygun model hakkında hüküm verilmiştir. Analizler sırasında yapay sinir ağları modelleri için WEKA 3.8 programından ve ARIMA modelleri için ise EViews 10 SV programından faydalanılmıştır.


Çalışmada bir marketin kasap reyonuna ait 3 farklı et ürünü (dana, kuzu, tavuk) için talep tahmin çalışması hedeflenmiştir. Bu talep tahmin çalışması için ilgili kasap reyonuna ait 01.01.2017 tarihinden 31.12.2018 tarihine kadar olan verilerden

faýdalanılmıştır. Ürün siparişlerinin haftalık verilmesinden dolayı bu veriler haftalık olarak çekilmiş ve haftalık bazda talep tahmin çıktıları alınmıştır.


Çalışmada, yapay sinir ağları ile oluşturulan tüm modeller, çok katmanlı algılayıcı modellerden ileri beslemeli geri yayılım ağı ile kurulmuştur. ARIMA modeli ile oluşturulan tahmin modelleri ise dana eti için AR (2), kuzu eti için ARMA (4,2), tavuk eti için ise ARMA (2,4) modeli ile tahmin modelleri oluşturulmuştur.

Aşağıdaki verilen grafiklerde yapay sinir ağı ve ARIMA modelleri ile dana, kuzu, tavuk etlerine ait eğitim ve tahmin grafikleri gösterilmiş ardından tahmin hatalarının doğruluk ölçütleri kıyaslanmıştır.

Şekil 2. WEKA programında Yapay Sinir Ağlarında Dana Eti Talep Tahmini

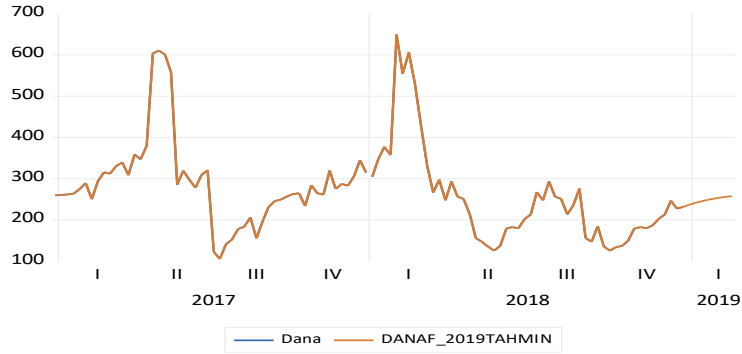


Şekil 3. WEKA programında Yapay Sinir Ağları ile Kuzu Eti Talep Tahmini




Şekil 4. WEKA programında Yapay Sinir Ağları ile Tavuk Eti Talep Tahmini


Yukarıda şekillerde, gerçekleşen dana, kuzu ve tavuk eti taleplerinin yapay sinir ağları ile tahmin grafiği incelendiğinde; gerçekleşen et talepleri ile yapay sinir ağı modeli vasıtasıyla yapılan tahmin değerlerinin yakınlığı görülmektedir.



Şekil 5. EViews Programında ARIMA ile Dana Eti Talep Tahmini



Şekil 6. EViews Programında ARIMA ile Kuzu Eti Talep Tahmini



Şekil 7. EViews Programında ARIMA ile Tavuk Eti Talep Tahmini

Dana, kuzu ve tavuk et taleplerinin değerleri ile ARIMA modelleri ile yapılan tahminlerin grafikleri incelenebilmektedir.

Tablo 1: YSA ve ARIMA Modellerinin Dana Eti Tahmin Hatasının Doğruluk Ölçütleri Karşılaştırması

TAHMİN ÇEŞİDİ	MAE	MAPE
YSA	9.876	4.0819
ARIMA	25.391	15.7521

Tablo 2: YSA ve ARIMA Modellerinin Kuzu Eti Tahmin Hatasının Doğruluk Ölçütleri Karşılaştırması

TAHMİN ÇEŞİDİ	MAE	MAPE
YSA	0.4341	2.539
ARIMA	5.8383	29.280

Tablo 3: YSA ve ARIMA Modellerinin Tavuk Eti Tahmin Hatasının Doğruluk Ölçütleri Karşılaştırması

TAHMİN ÇEŞİDİ	MAE	MAPE
YSA	28.6527	0.8231
ARIMA	48.26224	10.3951

İlgili yazıda, araştırmacılar MAPE değerinin %10'nun altında seyreden tahminlerin “yüksek doğruluk” seviyesinde, %10 ile %20 arasında seyreden modellerin “doğruluk” seviyesinde sınıflandırmışlardır (S.F. Witt ve C. Witt, 1992). Ayrıca Lewis, MAPE değeri %20 ile %50 arasında seyreden modelleri “kabul edilebilir” seviyede, son olarak ise %50 üzerinde MAPE değeri sunan modellerin ise “yanlış ve hatalı” olarak sınıflandırmıştır (Lewis, 1982; Çuhadar vd., 2009).

Uygulamalar neticesinde, yukarıdaki tabloların incelenmesiyle birlikte, yapay sinir ağı modellerinin ARIMA modellerinin tümünden daha az tahmin hatası gerçekleştirdiği saptanmıştır. Yukarıdaki tablolarda bulunan değerler kıyas edilerek, yapay sinir ağı modelleri ile kurulan tahmin modellerinin geçerli ve güvenilir olduğu sonucuna varılmıştır.

4. SONUÇ VE ÖNERİLER

Yapay sinir ağları ve ARIMA yöntemleri, son dönemlerde tahmin modellerinde en sık kullanılan yöntemlerden birisidir. Yapılan işlemler neticesinde yapay sinir ağı modellerinin, üç et türü de dâhil olmak üzere, zaman serisi yöntemlerinden ARIMA modeline göre daha az tahmin hatası yaptığı ve daha iyi sonuçlar sunduğu görülmektedir. Bu nedenden ötürü, çalışma yapılan firmaya yapay sinir ağları ile talep tahmin modelleri kurması önerilmiştir. Bu çalışma sonunda perakende sektöründe bulunan bir firma için önceki dönem verileri ile ileriki dönemlere ait talep tahminlerinin ne değerler olabileceği görülmektedir.

Talebi dışarıdan etkileyen faktörlerin tespiti ve eklenmesinin ardından ARIMA ve yapay sinir ağları ile birlikte melez bir model ile daha iyi tahmin sonuçlarının alınacağı düşünülmektedir.

KAYNAKÇA

Adıyaman, F., (2007),“Talep Tahmininde Yapay Sinir Ağlarının Kullanılması”, Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü, İstanbul.

Amber, K.P., ve Khan, M.S., (2018), Intelligent Techniques for Forecasting Electricity Consumption of Buildings. Energy, 157, 886-893.

Chung, S., (2001), "Demand Modeling and Analysis for the Management of Underground Infrastructure Systems". Doktora Tezi. Purdue University. USA.

Çuhadar, M., Güngör, İ., Göksu, A., (2009). Turizm Talebinin Yapay Sinir Ağları ile Tahmini ve Zaman Serisi Yöntemleri ile Karşılaştırmalı Analizi: Antalya İline Yönelik Bir Uygulama. Süleyman Demirel İktisadi ve İdari Bilimler Fakültesi Dergisi, 14 (1): 99-114.

Dizdar, E.N., Koçar, O., (2016), Determination of Precautions Against Occupational Accidents Using Artificial Neural Networks, 8th Conference on Safety and Helath, 8-11 May, 2016, İstanbul.

Donselaar, K.H., Peters, J., Jong, A., Broekmeulen, R.A.C.M., (2016), Analysis and Forecasting of Demand During Promotions for Perishable Items. International Journal of Production Economics, 172, 65-75.

Duman N., (2006), "Yapay Sinir Ağları ve Bir Uygulama", Yüksek Lisans Tezi, Cumhuriyet Üniversitesi Sosyal Bilimler Enstitüsü, Sivas.

Ekmekçi, H., (2006), "Türkiye'deki Doğalgaz Kullanımının ARIMA Metodu ile İstatistiksel Analizi, Yüksek Lisans Tezi, Karabük Üniversitesi, Karabük, 2006.

Elmas Ç., (2007), "Yapay Zekâ Uygulamaları", Seçkin Yayıncılık, Ankara, 25.

Erdoğan, E., (2006), "Zaman Serilerinde ARIMA Modelleri", Yüksek Lisans Tezi, Muğla Üniversitesi Fen Bilimleri Enstitüsü, Muğla, 8-42.

Es, H. A., (2013), "Yapay Sinir Ağları ile Türkiye Net Enerji Talep Tahmini", Yüksek Lisans Tezi, Gazi Üniversitesi Fen Bilimleri Enstitüsü, Ankara.

Gilbert, D., (1996), Retail Marketing Management, Pearson Education Limited, Great Britain.

Hamzaçebi, C., (2011), "Yapay Sinir Ağları: Tahmin Amaçlı Kullanımı Matlab ve Neurosolutions Uygulamalı", Ekin Yayınevi, Bursa, 1-105.

Hamzaçebi, C., Kutay, F., (2004), Yapay Sinir Ağları ile Türkiye Elektrik Enerjisi Tüketiminin 2010 Yılına Kadar Tahmini. Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Derneği, 19(3), 227-233.

Hu, C., (2002), Advanced Tourism Demand Forecasting: ANN and Box-Jenkins Modelling, Doktora Tezi, Purdue University, MI, USA.

Kandananond, K., (2011), Forecasting Electricity Demand in Thailand with an Artificial Neural Network Approach. Energies, 4(8), 1246-1257.

Karaatlı, M., Helvacıoğlu, Ö.C., Ömürbek, N., Tokgöz, G., (2012), Yapay Sinir Ağları ile Otomobil Satış Tahmini. Uluslar arası Yönetim İktisat ve İşletme Dergisi, 8(17), 87-100.

Karahan, M., (2011), İstatistiksel Tahin Yöntemleri: Yapay Sinir Ağları Metodu ile Ürün Talep Tahmini Uygulaması, Doktora Tezi, Selçuk Üniversitesi Sosyal Bilimler Enstitüsü, Konya.

Kaynar, O. Ve Taştan, S., (2009)“Zaman Serisi Analizinde MLP Yapay Sinir Ağları ve ARIMA Modelinin Karşılaştırılması”, Erciyes Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi, (33),161-172

Kızılaslan, R., (2008), Kısa ve Orta Vadeli İstanbul Doğalgaz Tüketiminin Yapay Sinir Algoritmaları ile Tahmin Edilmesi. Fatih Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, İstanbul.

Kobu, B., (1994), Üretim Yönetimi, Avcıol Basım-Yayım,8. Baskı, İstanbul.

Kaufmann, M., (1993), Practical Neural Network Recipes in C++, Masters T.

Lewis, Colin D., (1982), Industrial and Business Forecasting Methods. Butterworths Publishing: London, 1982, S.40.

Mo, H., Wang, J ve Niu,H., (2016), Exponent Back Propagation Neural Network Forecasting for Financial Cross-Correlation Relationship. Expert Systems With Applications, 53, 106-116.

Musaylı, M.S. Deo, R.C., Adamowski, J.F., Li, Y., (2018), Short-Term Electricity Demand Forecasting with MARS, SVR and ARIMA Models Using Aggregated Demand Data in Queensland, Australia. Advanced Engineering Informatics, 35, 1-16.

Ohyver, M., Pudjihastuti, H., (2018), Arima Model for Forecasting the Price of Medium Quality Rice to Anticipate Price Fluctuations. Procedia Computer Science, 135, 707-711.

Öztemel, E., (2012), Yapay Sinir Ağları, 2. Baskı, Papatya Yayıncılık, İstanbul.

Pelusi, D., Mascella, R., Talini, L., Nayak, J., Naik, B. ve Abraham, A. (2018), Neural Network And Fuzzy System For The Tuning Of Gravitational Search Algorithm Parameters. Expert Systems With Applications, 102, 234-244.

Saygılı, Y. S., (2008), İstatistiksel Yöntemlerle Yapay Sinir Ağları Uygulamalarının Karşılaştırılması: Millî Savunma Bakanlığı Bütçesinin Öngörülenmesi, Yüksek Lisans Tezi, Kara Harp Okulu Savunma Bilimleri Enstitüsü, Ankara.

Sevüktekin, M., ve Nargeleçekenler, M., (2007), Ekonometrik Zaman Serileri Analizi Eviews Uygulamalı, 2. Baskı, Nobel Yayın Dağıtım, Ankara.

Solak, A.O., (2013), Türkiye'nin Toplam Petrol Talebi ve Ulaştırma Sektörü Petrol Talebinin ARIMA Modeli ile Tahmin Edilmesi. Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi, 18(3), 131-142.

Sun, Z., Choi, T., Au, K., Yu, Y., (2008), Sales Forecasting Using Extreme Learning Machine with Applications in Fashion Retailing. Decision Support Systems, 46 (1), 411-419.

Şen, A.B. ve Kaba, G. (2009), Öncü Göstergeler Kullanımının Tahmin Doğruluğuna Etkisi: Türk Otomotiv Pazarı Üzerine Bir Araştırma. Marmara Üniversitesi İ.İ.B.F. Dergisi, 28, 2, 397-411.

Tanizaki, T., Hoshino, T., Shimmura, T., Takenaka, T., (2019), Demand Forecasting in Restaurants Using Machine Learning and Statistical Analysis. Procedia CIRP, 79, 679-683.

Tekin, M., (2009), Üretim Yönetimi Cilt 1, 6. Baskı, Günay Ofset, Konya.

Wang, Q., Li, S., Li, R., (2018), China's Dependency on Foreign Oil Will Exceed 80% by 2030: Developing a Novel NMGM-ARIMA to Forecast China's Foreign Oil Dependence from Two Dimensions. Energy, 163, 151-167.

Witt, S.F., ve Witt, C., (1992), Modeling Forecasting Demand in Tourism. Academic Press: London, S. 137.

Wongsathan, R., ve Seedadan, I., (2016), A Hybrid ARIMA and Neural Networks Model for PM-10 Pollution Estimation: The Case of Chiang Mai City Moat Area. Procedia Computer Science, 86, 273-276.

Yüksek, A. G., (2007), Hava Kirliliği Tahmininde Yapay Sinir Ağları ve Çoklu Regresyon, Doktora Tezi, Cumhuriyet Üniversitesi Sosyal Bilimler Enstitüsü, Sivas.

