

YAPAY SİNİR AĞLARI YÖNTEMİ İLE OTOMOBİL SATIŞ TAHMİNİ

Yrd. Doç. Dr. Meltem KARAATLI
Süleyman Demirel Üniversitesi
İİBF, İşletme Bölümü
meltemkaraatli@sdu.edu.tr

Özlem Ceyda HELVACIOĞLU
Süleyman Demirel Üniversitesi
SBE, İşletme ABD
ozlemhl@hotmail.com

Doç. Dr. Nuri ÖMÜRBEK
Süleyman Demirel Üniversitesi
İİBF, İşletme Bölümü
nuriomurbek@sdu.edu.tr

Gönül TOKGÖZ
Süleyman Demirel Üniversitesi
SBE, İşletme ABD
gonulmavi33@hotmail.com

ÖZET

Talep tahmini tüketicilerin gelecekte ne kadar mal ve hizmet talep edeceklerinin değişkenler yardımıyla tahmin edilmesidir. Talep tahmin metotları kantitatif ve kalitatif yöntemler olmak üzere iki grupta toplanmaktadır. Bu çalışmanın amacı da yeni otomobil satış miktarlarının yapay sinir ağları yöntemiyle önceden tahmin edilerek otomotiv sektörü ile ilgili bir takım politikaların belirlenmesine katkı sağlamaktır. Çalışmada Ocak-2007 ile Haziran-2011 yılları arasındaki aylık veriler kullanılmıştır. Çalışmada bağımsız değişkenler olarak gayri safi yurtiçi hasıla, reel kesim güven endeksi, yatırım harcamaları, tüketim harcamaları, tüketici güven endeksi, dolar kuru ve zaman, bağımlı değişken olarak ise satılan toplam otomobil sayısı alınmıştır.

Anahtar Kelimeler: Talep Tahmini; Otomotiv Sektörü; Yapay Sinir Ağları.

AN ARTIFICIAL NEURAL NETWORK BASED AUTOMOBILE SALES FORECASTING

ABSTRACT

Sales forecasting is a method of predicting the quantity of products or services that consumers may demand in the future by utilizing variables. Sales forecasting methods can be divided in two groups, qualitative and quantitative. The objective of this study is to predict the amount of future automotive sales by using Artificial Neural Networks in order to help decision makers on their policies about the automotive industry. In this study, monthly data between January-2007 and June-2011 has been used. While the total number of automobile sold has been used as dependent variable, the gross domestic product, real sector confidence index, investment spending, consumer spending, consumer confidence index, USD Exchange rate and time have been selected as independent variables.

Keywords: Forecasting; Automotive Sector; Artificial Neural Networks.

1. Giriş

Otomotiv sektörü sanayi; motorlu karayolu taşıtlarının imal edildiği ana sanayi ile bu ana sanayinin belirlediği teknik dokümanlara uygun parça ve sistem üreten yan sanayinin tümünü kapsayan büyük bir sanayi koludur (Türkiye Otomotiv Sektörü Strateji Belgesi ve Eylem Planı, 2011:4). Otomotiv sektörü sanayi dünya çapında sürekli büyüyen sektör konumundadır (İşeri & Karlık, 2009:2155). Günümüzde otomotiv sektörü gelişmiş ve gelişmekte olan ülkeler için anahtar sektör rolündedir. Güçlü bir otomotiv sektörü sanayileşmiş ülkelerin ortak özelliklerinden biri olarak göze çarpmaktadır. Otomotiv sektörünün bu kadar önemli olmasının başlıca nedeni, sektörün diğer sektörlerle yakından ilişkili olmasıdır. Bununla birlikte bu sektör yaptığı üretim ile bazı sektörlerinde verimli bir şekilde işlemlerini sağlamaktadır (Karbuç vd.: 4). Türkiye’de otomotiv sektörünün 50 yıllık bir geçmişi bulunmakla birlikte, üretime 1950’lerin ortalarında sadece montajla başlayan sektör 1996 yılında AB ile Gümrük Birliği Anlaşması sonrasında artan yatırımlarla bugünkü konumuna gelmiştir (Dikmen, 2006:1). Günümüzde sektörde 15 ana firma faaliyet göstermekte ve ülke kalkınmasına önemli katkılarda bulunmaktadır. Ülkemiz dünya ülkelerine oranla hala doymamış pazar konumundadır. Yapılan araştırmalarda Türkiye’de 1000 kişi başına düşen motorlu araç sayısı 165 iken AB ortalaması 473 adet olduğunu göstermektedir. Türkiye’de kişi başına düşen milli gelir düzeyi arttıkça otomobile olan talepte artacaktır. Milli gelirdeki düzelmelerle beraber 2011 yılının ilk çeyreğinde otomobil satışları %76,60’lık bir artış göstermiştir (Otomobil Distribütörleri Derneği, 2011:2). Tablo 1’de yıllara göre toplam otomobil satışları verilmiştir.

Tablo 1: Yıllık Perakende Otomobil Satış Rakamları

Yıllar	Satış Miktarları
2007	357.465 adet
2008	305.998 adet
2009	369.819 adet
2010	509.784 adet
2011	593.519 adet

Kaynak : ODD, Perakende Satış Raporları (2007, 2008, 2009, 2010, 2011)

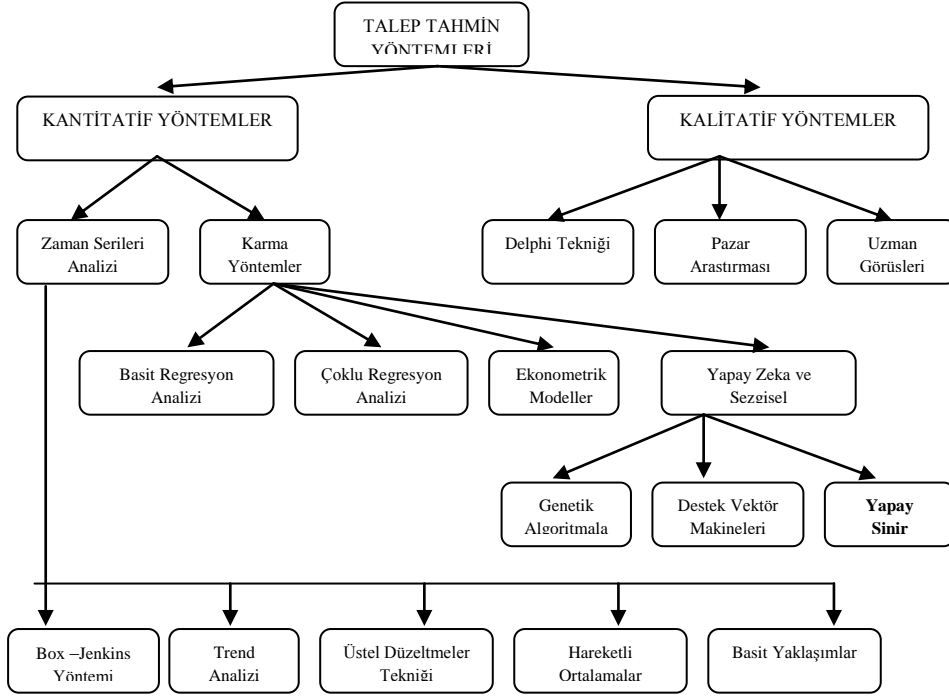
Literatürde otomotiv sektörü üzerine yapay sinir ağları yöntemi ile yapılmış birçok çalışma bulunmaktadır. Alper ve Serdar, çalışmalarında 1996-1999 yılları arasında Türkiye otomobil piyasasının bir görünümünü ortaya koyarak otomobil fiyat fonksiyonu tahmin etmişler ve 2005 yılı itibariyle talep öngörüsü yapmışlardır. Çalışmalarında Panel Veri Analizini kullanmışlardır (Alper & Serdar, 2000:1-38). Kolich, otomobil koltuk konfor algılarını geliştirmek adına nelere dikkat edileceğine yapay sinir ağları ile karar vermiş ve zamanın ve maliyetin azaltılması gerektiğine ulaşmıştır (Kolich, 2003:285-293). Hosoz ve Ertunç, otomobil performansını tahmin edebilmek için yapay sinir ağlarının uygulanabilirliğini çalışmış ve sonuç olarak performansta en etkili faktörün AAC olduğuna karar vermişlerdir (Hosoz & Ertunç, 2006:1574-1587). Rovetta ve arkadaşları otomobil içinde sürücünün güvenliği ve konforu için yeni bir sistem metodolojisi için yapay sinir ağlarını kullanmışlardır (Rovetta vd., 2007:622-630). Chunq ve Lee ise otomobillerde farklı sensörler olduğunu ve bunlardan bir tanesinin de hava sensörü olduğunu belirterek yapay sinir ağları ile

otomobilin zehirli gazlarını algılayıcı bir program geliştirmeye çalışmışlardır (Chunq & Lee, 2008:258-263). Asilkan ve Irmak, ikinci el otomobillerin gelecekteki fiyatlarını yapay sinir ağları yöntemi ile tahmin etmişlerdir (Asilkan & Irmak, 2009:375-391). İşeri ve Karlık, yapay sinir ağları yöntemini kullanarak otomobil fiyatlandırma modeli ortaya koymuşlardır. Önerilen modele göre istikrarlı bir piyasada otomobillerin teknik ve fiziksel özelliklerine göre fiyatlarını tahmin etmişlerdir (İşeri & Karlık, 2009:2155-2160). Chen ve arkadaşları, Taiwan'da hava kirliliğinin en önemli nedeninin otomobillerin çıkardıkları gazlar olduğunu tespit ederek otomobillerin gaz emisyonlarını kontrol altına almak adına yapay sinir ağları ile bir uygulama yapmışlardır (Chen vd., 2009:5811-5817). Wang ve arkadaşları Taiwan'da yeni otomobil satışları için talep tahmininde bulunmuşlardır. Satış tahmini yaparken etkili olan değişkenleri belirleyebilmek adına öncelikle regresyon analiz yapmışlardır. Daha sonra satış tahminlerini elde etmek için adaptif ağ tabanlı bulanık çıkarım sistemi (ANFIS) uygulamışlardır. Elde ettikleri sonuçları yapay sinir ağları ve ARIMA yöntemi ile karşılaştırmışlardır. ANFIS modelinin daha iyi sonuç verdiğini ortaya koymuşlardır (Wang vd., 2011:10587-10593). Subelj ve arkadaşları, YSA ile bir uzman algılama sistemi oluşturularak otomobil kasko dolandırıcılığı tanıma sistemi geliştirilmesi üzerine çalışmışlar (Subelj vd., 2011:1039-1052).

Bu çalışmada da yapay sinir ağları yöntemi ile otomobil satışları tahmin edilmiştir. Otomobil satışını etkileyen değişkenlerin seçimi yapılırken daha çok makro göstergeler üzerinde durulmuştur. Bu bağlamda, gayri safi yurt içi hasıla, döviz kuru fiyatları, tüketici güven endeksi, reel kesim güven endeksi, yatırım harcamaları, tüketim harcamaları ve zaman bağımsız değişkenler olarak belirlenmiştir.

2. Talep Tahmini

Tüm sektörlerin amacı, piyasa talebini karşılamak; mal ve hizmet üreterek bunları pazara sunabilmektir. Talep, tüketicilerin bir mal veya hizmeti belirli bir fiyat seviyesinden almaya hazır oldukları miktardır (Tekin, 2009:261). Tahmin, bilinmeyen bir parametrenin değerinin, bilinen parametreler kullanılarak, gelecekteki durumun kestirilmesidir. Talep tahmini tüketicilerin gelecekte ne kadar mal ve hizmet talep edeceklerinin değişkenler yardımıyla tahmin edilmesidir. Tahmin metotları, kantitatif ve kalitatif olarak iki ana başlık altında toplanır. Bunlardan kalitatif olan yöntem türleri kişinin düşüncelerine bağlı bir yöntem olup, kantitatif yöntemler ise matematiksel modellere dayanan, yeterli miktarda sayısal verinin mevcut olduğu durumlarda kullanılır. Aşağıdaki şekilde gruplandırma yapılırken çalışmada kullanılan matematiksel modele ulaşılmaya çalışılmıştır.

Şekil 1: Talep Tahmin Yöntemleri

Kaynak: Küçükdeniz, Tarık, <http://www.istanbul.edu.tr/muh/endustri/lojistik/wp-content/uploads/TalepTahminYontemleri.pdf>

Bu çalışmada Türkiye’de satılan toplam otomobil satış rakamları kantitatif yöntemlerden olan yapay sinir ağları yöntemi ile tahmin edilmiştir. Yapay sinir ağları, doğrusal olmayan, çok boyutlu, karmaşık, kesin olmayan, eksik, kusurlu verilerin olması durumunda ve problemin çözümü için özellikle bir matematik modelin ve algoritmanın bulunmaması halinde yaygın olarak kullanılmaktadır. Zaman serileri analizleri, örüntü tanıma, optimizasyon, doğrusal olmayan sistem modelleme, ilişkilendirme veya örüntü eşleştirme gibi bir çok fonksiyonları yerine getirmektedir (Öztemel, 2003:36).

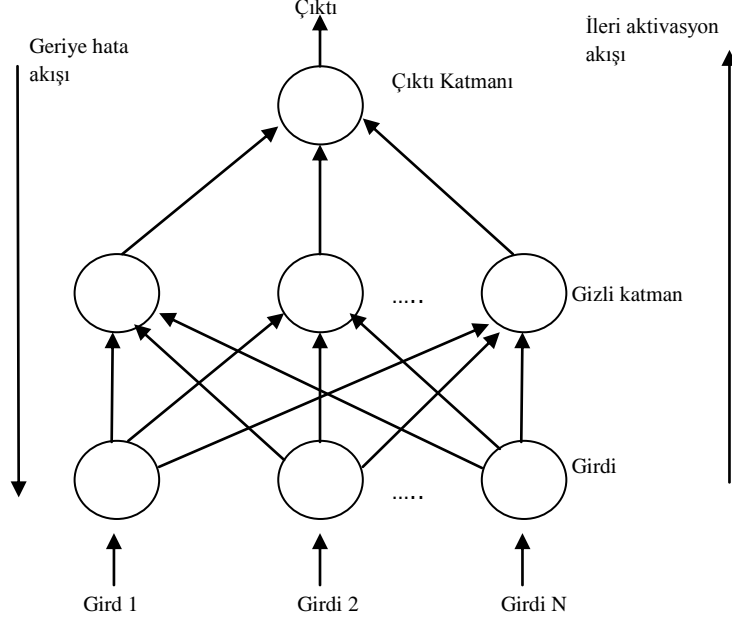
3. Yapay Sinir Ağları

Yapay sinir ağları esnek ve parametrik olmayan modelleme aracıdır (Tang & Chi, 2005:248). Yapay sinir ağları beynin bilişsel öğrenme sürecinin simülasyonu ile geliştirilmiş bir yöntem olarak bilinmektedir. Karmaşık problemlerde oldukça etkili olduğu görülmüştür. Tahminleme, sınıflandırma, kümeleme gibi birçok probleme çözüm bulabilmektedir. Sinir ağlarının en önemli özelliği karmaşık sistemlerin geçmiş bilgilerinden yola çıkarak örnek üzerinde öğrenme yolu ile probleme çözüm getirebilmesidir (Efendigil vd., 2009:6699)

Yapay sinir ağları, paralel olarak bağlanmış basit elemanlardan oluşmuştur. Bu elemanlar biyolojik sinir sistemine benzeyen bir yapıdadır. Ağın fonksiyonunu bu elemanlar arasındaki büyük çaplı bağlantılar oluşturmaktadır. Elemanların birbirleriyle bağlandıkları ağırlık değerlerinin ayarlanarak belirli bir fonksiyonun gerçekleştirilmesi için ağın eğitilmesi sağlanmaktadır. Böylece belirli bir girdiye karşılık ağ bir çıktı üretilmektedir (İşeri & Karlık, 2009:2157).

Yapay sinir ağları yardımıyla birçok probleme çözüm bulunabilmektedir. Her problemin çözümüne dönük farklı ağ yapıları kullanılmaktadır. Hangi problem tipine hangi ağın daha uygun olduğu karar verici tarafından belirlenir. Bu çalışmada ise Çok Katmanlı Algılayıcı Modeli (ÇKA) kullanılmıştır. Çünkü bu ağ yapısı özellikle sınıflandırma, tahminleme gibi problemlerde oldukça sık kullanılmaktadır (Smith & Grupta, 2000:1025).

ÇKA Modeli Rumelhart ve arkadaşları tarafından geliştirilmiştir. Bu modele hata yayma modeli veya geri yayılım modeli (backpropagation network) de denilmektedir (Öztemel, 2003:76). ÇKA modelinde geriye yayılım algoritması kullanılmaktadır. Bu algoritma ara katman içeren yapay sinir ağlarında kullanılan güçlü bir öğrenme algoritmasıdır. Bu algoritma yapay sinir ağlarının karmaşık, doğrusal olmayan ve işlem parametreleri arasındaki ilişkinin öğrenilmesinde kullanılmasını mümkün kılmaktadır (Şen, 2004:107-108). Biyolojik sinir hücresini taklit ederek oluşturulan yapay sinir hücreleri bir araya gelerek 3 katman halinde yapay sinir ağını oluşturmaktadırlar (Palmer vd., 2006:782). Bu katmanlar girdi, çıktı ve ara katmanlardır. Girdi katmanı dışarıdan sağlanan bilgileri alarak ara katmana iletir. Ara katmanda işlenen bilgiler çıktı katmanına gönderilir. Çıktı katmanında girdi katmanından sunulan örnek set için üretilmesi gereken çıktıyı elde ederler (Öztemel, 2003:77). Verileri kendi içinde sınıflandırarak öğrenme sürecini kolaylaştırır. Öğrenme sürecinde doğru çıktılar elde etmek için ağ ağırlıkları ayarlanmalıdır (Werbos, 1998:339). ÇKA ağının öğrenme kuralı en küçük kareler yöntemine dayalı Delta Öğrenme Kuralının genelleştirilmiş halidir. Bu yüzden öğrenme kuralına “Genelleştirilmiş Delta Kuralı” da denmektedir (Öztemel, 2003:77). Geri yayılım algoritmasında kullanılan “delta kuralı” na göre bir nöronun gerçek çıktı değeri ile istenilen çıktı değeri arasındaki farkı azaltmak için giriş bağlantılarını yani ağırlıkları sürekli ayarlama ve geliştirme fikrine dayalı bir kuraldır (Kartalopoulos, 1996:46). Bu kuralda, öğrenme esnasındaki bağlantı ağırlıkları sürekli değiştirilerek, ağırlıklar için optimum değer bulunur. Bu ağ yapısında “Öğretmenli Öğrenme” yöntemi kullanılır. Öğretmenli öğrenmede hedef çıktı değerleriyle ilişkilendirilen her bir vektör, ağın öğrenmesi için ağa sunulur. Ağırlıklar, belirtilen öğrenme kuralına dayanarak düzeltilir (Hamid & Iqbal, 2004:1119). Şekil 2’de ÇKA modeline bir örnek verilmiştir.

Şekil 2: Çok Katmanlı Algılayıcı Modeli

Kaynak: Hamid ve Iqbal, 2004:1118.

4. Otomobil Satış Tahmini Üzerine Bir Uygulama

Bu çalışmada, 2007 yılından 2011 yılına kadar olan yeni otomobil satışına ilişkin aylık veriler dikkate alınarak Türkiye'deki toplam yeni otomobil satış rakamları tahmin edilmiştir.

4.1. Veri

Çalışmada, bağımsız değişkenler için kullanılacak veriler Merkez Bankası'nın web sitesinden (www.tcmb.gov.tr), bağımlı değişken için kullanılacak veriler ise Otomobil Distribütörleri Derneğinden (www.odd.org.tr) alınmıştır. Analizlerde kullanılan değişkenler, sembolleri ile birlikte aşağıda verilmiştir.

GSYH: Gayri safi yurt içi hasıla

RKGE: Reel kesim güven endeksi

YH: Yatırım harcamaları

TH: Tüketim harcamaları

TGE: Tüketici güven endeksi

\$: Dolar

Z: Zaman

OS: Satılan toplam otomobil sayısı

Bu çalışmada, gayri safi yurt içi hasıla (GSYH), reel kesim güven endeksi (RKGE), yatırım harcamaları (YH), tüketim harcamaları (TH), tüketici güven endeksi (TGE), dolar (\$) ve (Z) bağımsız değişkenler ve satılan toplam otomobil sayısı (OS) bağımlı değişken olarak alınmıştır. Bu bağlamda her değişken için 54 adet aylık veri bulunmaktadır. Çalışmada kullanılan veriler Tablo 2’de verilmiştir.

Tablo 2: Çalışmada Kullanılan Veriler

TARİH	TGE	GSYH	RKGE	YH	\$	TH	OS
01.01.2007	114,46	62650,232	116,3	122,8	141,98	46,447802	13186
01.02.2007	116,23	62650,232	116,31	124,8	139,025	46,447802	17212
01.03.2007	116,21	62650,232	116,32	124,5	140,287	46,447802	24336
01.04.2007	116,41	67759,901	116,33	128	135,528	48,616873	25204
01.05.2007	114,42	67759,901	116,34	121,9	133,186	48,616873	29067
01.06.2007	113,09	67759,901	116,35	115,9	131,52	48,616873	30126
01.07.2007	112,97	77418,855	116,36	110,8	127,597	53,115503	28246
01.08.2007	112,96	77418,855	116,37	128,4	130,828	53,115503	28469
01.09.2007	113,87	77418,855	116,38	106,3	126,131	53,115503	27662
01.10.2007	111,51	73230,485	116,39	107,1	119,659	52,23269	32569
01.11.2007	110,63	73230,485	116,4	103	118,475	52,23269	39643
01.12.2007	108,89	73230,485	116,41	107,3	117,298	52,23269	61745
01.01.2008	110,35	71868,551	116,42	107,7	117,044	53,027017	18588
01.02.2008	110,77	71868,551	116,43	102	118,817	53,027017	21196
01.03.2008	110,02	71868,551	116,44	103,9	123,238	53,027017	34147
01.04.2008	111,81	79787,811	116,45	100,5	129,671	55,702588	30313
01.05.2008	112,4	79787,811	116,46	101,6	124,7	55,702588	31477
01.06.2008	112,72	79787,811	116,47	99,7	122,78	55,702588	28724
01.07.2008	109,28	87464,057	116,48	98,6	120,995	57,816312	25530
01.08.2008	108,93	87464,057	116,49	90,1	117,267	57,816312	26102
01.09.2008	108,66	87464,057	116,5	90,5	122,964	57,816312	27053
01.10.2008	108,01	77724,331	116,51	77,4	147,327	54,721833	19788
01.11.2008	107,53	77724,331	116,52	55,3	158,785	54,721833	17201
01.12.2008	106,19	77724,331	116,53	50,1	153,881	54,721833	25879
01.01.2009	109,32	69308,663	116,54	52,4	158,905	51,466374	13173
01.02.2009	111,74	69308,663	116,55	60	165,236	51,466374	14492
01.03.2009	104,82	69308,663	116,56	47,3	170,454	51,466374	40622
01.04.2009	99,75	76190,633	116,57	52,9	160,415	55,861355	36202
01.05.2009	100,9	76190,633	116,58	66,5	155,176	55,861355	44188
01.06.2009	104,82	76190,633	116,59	66	153,978	55,861355	41019
01.07.2009	107,37	87236,816	116,6	70,4	151,369	59,462952	16637
01.08.2009	107,99	87236,816	116,61	73,6	147,922	59,462952	22537
01.09.2009	108,13	87236,816	116,62	70,5	148,523	59,462952	52162
01.10.2009	113,7	84783,413	116,63	84	146,214	60,132099	13828
01.11.2009	115,19	84783,413	116,64	98,9	148,002	60,132099	17781
01.12.2009	113,19	84783,413	116,65	88,5	149,951	60,132099	57178
01.01.2010	115,11	80626,879	116,66	111,9	146,632	60,90184	12594
01.02.2010	115,06	80626,879	116,67	101,6	150,556	60,90184	20651
01.03.2010	115,63	80626,879	116,68	113,9	152,831	60,90184	33958
01.04.2010	115,92	89048,021	116,69	113,2	148,787	63,486165	36549
01.05.2010	116,2	89048,021	116,7	110,2	153,481	63,486165	40467
01.06.2010	115,53	89048,021	116,71	111,7	157,029	63,486165	42086
01.07.2010	115,86	99061,317	116,72	108,8	153,631	67,604651	41399
01.08.2010	115,5	99061,317	116,73	114,2	150,163	67,604651	42222
01.09.2010	114,82	99061,317	116,74	115,8	148,892	67,604651	42477
01.10.2010	115,23	99180,382	116,75	115,6	141,846	70,43053	47859
01.11.2010	114,34	99180,382	116,76	119,1	142,953	70,43053	50061
01.12.2010	112,91	99180,382	116,77	124,1	151,315	70,43053	99461
01.01.2011	114,6	96130,005	116,78	122,3	155,373	72,900307	29868
01.02.2011	118,84	96130,005	116,79	120,4	158,258	72,900307	39004
01.03.2011	119,99	96130,005	116,8	120,4	157,42	72,900307	54023
01.04.2011	121,66	79787,811	116,81	132,3	144,672	75,203149	53835
01.05.2011	121,96	79787,811	116,82	127,6	156,415	75,203149	56302
01.06.2011	122,75	79787,811	116,83	124	159,401	75,203149	56714

Kaynak: www.odd.org.tr ve www.tcmb.gov.tr

Yapay sinir ağları, istatistiksel yöntemlerin aksine veri seti üzerinde herhangi bir ön varsayıma gerek duymaz (Kaynar & Taştan, 2009:141). Buna rağmen bu çalışmada öncelikle Durbin-Watson test istatistiğine bakılarak hata terimlerinin otokorele olup olmadığı araştırılmıştır. Durbin-Watson test istatistiği 2,428 olarak bulunmuştur. Bu değer 1,5-2,5 arasında olması veriler arasında otokorelasyonun bulunmadığını yani hata terimlerinin rassal olduğunu göstermektedir. Böylece yapılan tahminin güvenilir bir tahmin olduğu söylenilebilir.

Çalışmada toplam 7 bağımsız değişken (GSYH, RKGE, YH, TH, TGE, \$, Z) ve 1 bağımlı değişken (OS) bulunmaktadır. Bağımlı değişkenin tahmininde kullanılacak zaman değişkeninin dışında diğer bağımsız değişkenlerin gelecekteki değerleri bilinmemektedir. Bu sebeple öncelikle bu bağımsız değişkenlerin değerlerinin tahmin edilmesi gerekmektedir. Bu amaçla zaman değişkeni dışındaki tüm bağımsız değişkenler ayrı ayrı olmak üzere zaman değişkeni bağımsız değişken her bağımsız değişken ise bağımlı değişken olarak düşünülüp yapay sinir ağları yöntemi ile tahmin edilmiştir (Hamzaçebi & Kutay, 2004:230). Tüm bağımsız değişkenlerin tahmini yapıldıktan sonra asıl tahmin edilmesi gereken bağımlı değişken satılan toplam otomobil sayısının (OS) tahmini yapılmıştır. Dolayısıyla her bağımsız değişkenin zamana bağlı tahmini yapılırken veri grubu %80'i öğrenme, %20'si test verisi şeklinde rassal olarak gruplandırılmış ve beş farklı veri seti oluşturulmuştur.

Çözüm için MATLAB (7.9.sürüm) paket programı kullanılmıştır. Veriler Matlab programına girilirken normalizasyona tabi tutulmuştur. Kurulan yapay sinir ağının eğitimi için 10000 iterasyon gerçekleştirilmiştir.

4.2. Performans Ölçütleri

Bu çalışmada Tablo 3'te her bağımsız değişkenin tahmininde kullanılan en iyi katman ve nöron sayılarının yer aldığı kurulan modellerin ağ yapıları verilmiştir.

Tablo 3: Çalışmada Kullanılan Değişkenlerin Tahminlerinde Kullanılan En İyi Ağ Yapıları

DEĞİŞKENLER	Girdi Katmanındaki Nöron Sayısı	Ara Katman Sayısı	Ara Katmanlardaki Nöron Sayıları	Çıktı Katmanındaki Nöron Sayısı
GSYH	1	2	4-6	1
\$	1	2	6-5	1
TH	1	2	3-4	1
YH	1	1	3	1
RKGE	1	1	3	1
TFE	1	1	11	1
OS	7	2	4-3	1

Bu ağ yapılarına karar verilirken tahmin performans ölçümlerine bakılmıştır. Tahmin performans ölçümleri için literatürde en çok 1 numaralı formül RMSE (Hata Kareleri Ortalamasının Karekökü), 2 numaralı formül MAPE (Mutlak Hata Oranları Ortalaması) ve 3 numaralı formül MSE (Hata Kareleri Ortalaması) değerlerine bakılmaktadır (Zhang & Hu, 1998:500, Cho, 2003:328, De Lurgio, 1998:53). Oluşturulan ağlar değerlendirilirken tahmin performans ölçümleri küçük olan ağ tercih edilmiştir. Ölçümlerin istatistiksel ifadesi aşağıda verilmiştir. Böylece en iyi performans gösteren ağ yardımıyla değişkenlerin ileriye yönelik tahmin değerleri elde

edilmiştir. Bu ölçümlere göre Witt ve Witt (2000) MAPE değerleri %10'un altında olan tahmin modellerini "yüksek doğruluk" derecesine sahip, %10 ile %20 arasında olan modelleri ise "doğru tahminler" olarak sınıflandırmıştır. Benzer şekilde Lewis (2002), MAPE değerleri %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 altında olan modelleri ise "yanlış ve hatalı" olarak sınıflandırmıştır (Aktaran, Çuhadar ve Kayacan, 2005:6).

$$RMSE = \sqrt{\frac{\sum (y_t - \hat{y}_t)^2}{T}} \quad (1)$$

$$MAPE = \frac{1}{T} \sum \left| \frac{y_t - \hat{y}_t}{y_t} \right| \times 100 \quad (2)$$

$$MSE = \frac{\sum (y_t - \hat{y}_t)^2}{T} \quad (3)$$

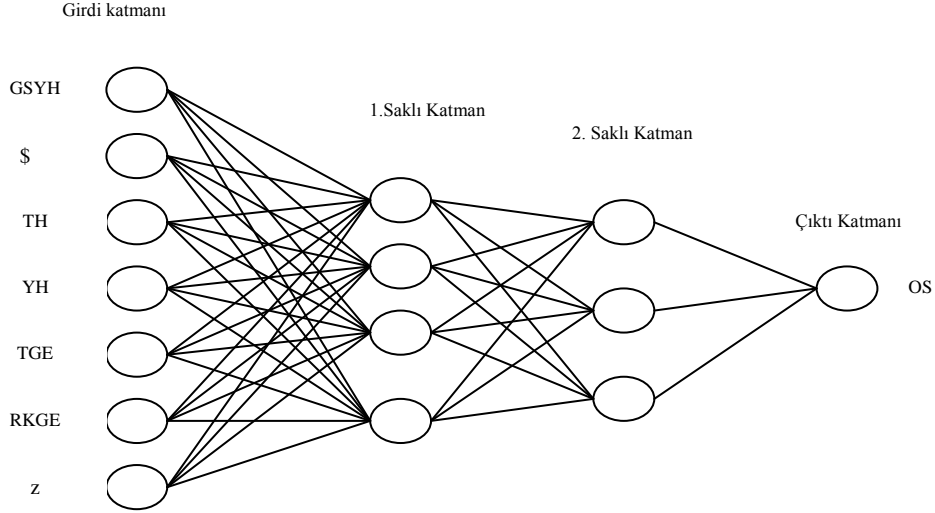
Burada;

y_t = Gerçek gözlem değerleri,

\hat{y}_t = Tahmin edilen değerleri,

T = Tahmin sayısıdır.

Bu çalışmada temel hedef olan bağımlı değişkenin (OS) tahmini veren ağın 4 katmanı bulunmaktadır. Birinci katman yani girdi katmanında 7 nöron (7 bağımsız değişken, GSYH, RKGE, YH, TH, TGE, \$, Z) , ara katman yani saklı katman sayısı 2 olarak belirlenmiştir. İlk saklı katmanda 4 nöron, ikinci saklı katmanda 3 nöron almaktadır. Son çıkış katmanında ise 1 nöron (1 bağımlı değişken, OS) bulunmaktadır. Şekil 3'de bağımlı değişkenin (OS) tahmininde kullanılan ağ yapısı görülmektedir.

Şekil 3: Bağımlı Değişkenin (AS) Tahmininde Kullanılan Ağ Yapısı

Bağımlı değişkenin (OS) tahmininde kullanılan en iyi ağıın belirlenmesinde tahmin performans ölçümlerine bakılmıştı. Belirlenen en iyi ağ yapısına göre bu ölçümlerin değerleri $MSE=0,00003272$, $RMSE=0,00572$, $MAPE=0,1682$ olarak bulunmuştur. Witt ve Witt (2000) MAPE değerleri %10 ile %20 arasında olan modelleri ise “doğru tahminler” olarak sınıflandırmıştı. Bu çalışmada MAPE değeri %16,82 olarak hesaplandığı için tahmin “doğru tahminler” sınıfına girmektedir.

4.3. Bulgular

Çalışmadan elde edilen bulgular Tablo 4’de verilmektedir. Tablo 4’te Temmuz 2011’den Haziran 2012’ye kadar tahmin edilen aylık otomobil satış rakamları görülmektedir.


Tablo 4: Tahmini ve Gerçekleşen Aylık Otomobil Satış Rakamları

Zaman	Tahmini Satış Rakamları	Gerçekleşen Satış Rakamları
01.07.2011	40.329	43.518
01.08.2011	40.569	38.875
01.09.2011	41.798	39.964
01.10.2011	60.120	47.508
01.11.2011	82.038	44.951
01.12.2011	94.306	88.957
01.01.2012	30.460	21.077
01.02.2012	42.678	29.189
01.03.2012	51.629	47.270

01.04.2012	55.892	-----
01.05.2012	57.329	-----
01.06.2012	52.292	-----

Tablo 4 ve Şekil 4 incelendiğinde Temmuz 2011, Ağustos 2011, Eylül 2011, Aralık 2011, Ocak 2012, Şubat 2012 ve Mart 2012 aylarının gerçeğe yakın olduğu görülmektedir. Ancak Ekim 2011 ve Kasım 2011 aylarında ise sapma görülmektedir.

Şekil 4: Gerçek Değerler ile Yapay Sinir Ağları Yöntemi İle Bulunan Tahmini Değerleri Karşılaştıran Grafik



Çalışmada 2003, 2004, 2005 ve 2006 yılları dikkate alınmamıştı. Ancak bu yıllar ve daha sonraki yıllarda Ekim, Kasım ve Aralık aylarındaki otomobil satış rakamları Tablo 5'te görülmektedir.

Tablo 5: 2003-2011 Yıllarında Ekim, Kasım ve Aralık Aylarında Gerçekleşen Otomobil Satış Rakamları

	2003-OS	2004-OS	2005-OS	2006-OS	2007-OS	2008-OS	2009-OS	2010-OS	2011-OS
EKİM	30623	34305	34957	21237	27662	27053	52162	47859	39.964
KASIM	25859	30548	37747	30477	32569	19788	13828	50061	47.508
ARALIK	51602	50183	65439	46351	39643	17201	17781	99461	44.951

Tablo 5 incelendiğinde 2008 ve 2009 yılları dışında diğer yıllarda Ekim ayından sonraki Kasım ve Aralık aylarında genellikle talep artışları görülmektedir. 2008 ve 2009 yıllarında ise Ekim ayına göre Kasım ve Aralık ayında ciddi düşüşler yaşanmaktadır. Bunun nedeni ise 2007 yılında Amerika'da başlayıp 2008 yılında Avrupa'ya yayılan ekonomik kriz gösterilebilir. Türkiye 2004 yılında yüzde 9,4 büyüme, 2005'te yüzde 8,4, 2006'da yüzde 6,9 ve 2007'de de yüzde 4,7 büyüme gösteren ülke ekonomisi

küresel krizin etkisinin hissedilmeye başlandığı 2008'in son çeyreğinde bozulmaya başlamış ve yıl toplamında yüzde 0,7'de kalmıştır. 2009 yılında ekonomideki toplam daralma yüzde 4,7 olmuştur (<http://www.cnnturk.com>). Yine Tablo 5'e bakıldığında genel itibariyle otomobil satışları özellikle Aralık ayında önceki aylar arasındaki artışa göre daha yüksek oranda artışlar göstermektedir. Bunun nedeni olarak da otomobil firmalarının yeni yıla girileceğinden dolayı ellerindeki otomobil stoklarını eritmek için müşteriye cazip gelebilecek kampanyalar düzenliyor olmaları ve müşterilerin de bu kampanyaları beklemeleri gösterilebilir.

5. Sonuç

Bu çalışmada Yapay Sinir Ağları yöntemi kullanılarak Türkiye'de yeni otomobil satış rakamları tahmin edilmiştir. Çalışmada Ocak-2007 ile Haziran-2011 yılları arasındaki aylık veriler dikkate alınmıştır. Çalışmada otomobil satışını etkileyen değişkenler gayri safi yurtiçi hasıla, reel kesim güven endeksi, tüketici güven endeksi, yatırım harcamaları, tüketim harcamaları, tüketici fiyat endeksi araç alım satımı, dolar ve zaman olarak belirlenmiştir. Çalışmada MAPE değeri %16,82 çıktığından yapılan tahmin "doğru tahminler" sınıfına girmektedir. Yapılan tahminler gerçek değerlerle karşılaştırıldığında genelde tahmin edilen ve gerçekleşen değerlerin birbirlerine yakın olduğu görülmektedir. Ancak Ekim ve Kasım aylarında tahmin ile gerçekleşen değerler arasında farkın fazla olduğu görülmektedir. Bunun nedeni de kış aylarına girilmesi ve müşterilerin firmaların Aralık ayında yapacakları kampanyaları beklemeleri şeklinde açıklanabilir. Gerçekten de yılsonunda Aralık ayında firmalar çok cazip kampanyalar düzenlemekte ve satışlar artmaktadır.

Gelecekteki araştırmalarda daha farklı sayıda ve türde değişkenler kullanılarak otomobil satış rakamları tahmin edilebilir. Örneğin; otomobil satış fiyatlarından, vergi oranlarından, otomobil segmentlerinden, benzin fiyatlarından, mevsimsel değişikliklerden yararlanılarak farklı çalışmalar yapılabilir. Yine gelecekte otomobil firmaları bazında daha ayrıntılı çalışmalar yapılarak otomotiv firmalarına Türkiye pazarı açısından faydalı bilgiler sağlanabilir.

Bu çalışma otomotiv sektörü yöneticileri için ileriye yönelik karar alma ve planlama çalışmalarında yardımcı birer kaynak olarak kullanılabilirler.

Kaynakça

- Alper, E., & Mumcu, A. S. (2000). *Türkiye'de otomobil talebinin tahmini*. İstanbul: Boğaziçi Üniversitesi, Ekonomi Bölümü, Ekonomi ve Ekonometri Merkezi.
- Asilkan, Ö., & Sezgin, I. (2009). İkinci el otomobillerin gelecekteki fiyatlarının yapay sinir ağları ile tahmin edilmesi. *Süleyman Demirel Üniversitesi İktisadi İdari Bilimler Fakültesi Dergisi*, 14(2), 375-391.
- Chen, H. W., Yang, H. H., & Wang, Y. S. (2009). Automobile gross emitter screening with remote sensing data using objective-oriented neural network. *Science of Total Environment*, 407, 5811-5817.
- Cho, V. (2003). A comparison of three different approaches to tourist arrival forecasting. *Tourism Management*, 24: 323-330.

- Chunq, Y. W., & Lee, S. C. (2008). A selective aqs system with artificial neural network in automobile. *Sensor and Actuators*, 130, 258-263.
- Çuhadar, M., & Kayacan, C. (2005). Yapay sinir ağları kullanılarak konaklama işletmelerinde doluluk oranı tahmini: Türkiye'deki konaklama işletmeleri üzerine bir deneme. *Anatolia: Turizm Araştırmaları Dergisi*, 16(1), 24-30.
- De Lurgio, A. S. (1998). *Forecasting principles and applications*. Singapore: Irwin McGraw-Hill.
- Dikmen, I. (2006). *Otomotiv sektörü ve rekabet değerlendirme*. Erişim Tarihi: 10.12.2011, http://www.kalder.org.tr/genel/15kongre/sunumlar/isik_dikmen.doc
- Efendigil, T., Önüt, S., & Kahraman, C. (2009). A decision support system for demand forecasting with artificial neural networks and neuro-fuzzy models: A comparative analysis. *Expert Systems with Applications*, 36, 6697-6707.
- Hamid, S., A. & Iqbal, Z. (2004). Using neural networks for forecasting volatility of s&p 500 index futures prices, *Journal of Business Research*, 57, 1116-1125.
- Hamzaçebi, C., & Kutay, F. (2004). Yapay sinir ağları ile Türkiye elektrik enerjisi tüketiminin 2010 yılına kadar tahmini. *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 19(3), 227-233.
- Hosoz, M., & Ertunç, H.M. (2006). Artificial neural network analysis of an automobile air conditioning system. *Energy Conversion and Management*, 47, 1574-1587.
- Erişim Tarihi: 26.05.2012,
<http://www.cnnturk.com/2010/ekonomi/03/31/iste.son.10.yilin.buyume.rakamlari/570273.0/index.html>
- İşeri, A., & Karlık, B. (2009). An artificial neural network approach on automobile pricing. *Expert Systems with Applications*, 36, 2155-2160.
- Karbuç, F., Silahçı, & Çalışkan, E., *Otomotiv sektör raporu*. İstanbul Ticaret Odası Ekonomi ve Sosyal Araştırmalar Şubesi. Erişim Tarihi: 10.12.2011, <http://www.ito.org.tr/Dokuman/Sektor/1-69.pdf>
- Kartalopoulos, S. V. (1996). *Understanding neural network and fuzzy logic*. Newyork: IEEE Press.
- Kaynar, O., & Taştan, S. (2009). Zaman serileri tahmininde arıma-mlp melez modeli. *Atatürk Üniversitesi İktisadi ve İdari Bilimler Dergisi*, 23 (3), 141-149.
- Kolich, M. (2003). Predicting automobile seat comfort using a neural network, *International Journal of Industrial Ergonomics*, 33(4), 285-293.
- Küçükdeniz, T., Erişim Tarihi: 10.03.2012, <http://www.istanbul.edu.tr/muh/endustri/lojistik/wp-content/uploads/TalepTahminYontemleri.pdf>
- Merkez Bankası. Erişim Tarihi: 11.02.2012, www.tcmb.gov.tr
- Otomobil Distribütörleri Derneği. *Pazar değerlendirme* (2011). Erişim Tarihi: 10.12.2011, www.odd.org.tr

- Otomobil Distribütörleri Derneği. *Perakende satış raporları*. Erişim Tarihi: 10.12.2011, www.odd.org.tr
- Öztemel, E. (2003). *Yapay sinir ağları*. İstanbul: Papatya Yayınları.
- Palmer, A., Montano, J. J., & Sese, A. (2006). Designing an artificial neural network for forecasting tourism time series. *Tourism Management*, 27, 781-790.
- Rovetta, A., Zocchi, C, Giusti, Alessandro, Adami, A., & Scramellini F. (2007). Methodology of evaluating safety in automobiles using intelligent sensor architecture and neural Networks. *Sensor and Actuators*, 134, 622-630.
- Smith, K., & Gupta, J. N. D. (2000). Neural networks in business: techniques and applications for the operations researcher. *Computers & Operations Research*, 27, 1023-1044.
- Subelj, Lovro, Furlan, Stefan, & Bajec, Makro (2011). An expert system for detecting automobile insurance fraud using social network analysis. *Expert Systems with Applications*, 38, 1039-1052.
- Şen, Z. (2004). *Yapay sinir ağları ilkeleri*. İstanbul: Su Vakfı Yayınları.
- Tang, T. C., & Chi, L. C. (2005). Neural networks analysis in business failure prediction of chinese importers: a between-countries approach. *Expert Systems with Applications*, 29, 244–255.
- TC. Sanayi ve Ticaret Bakanlığı Sanayi Genel Müdürlüğü (2011). *Türkiye otomotiv sektörü strateji belgesi ve eylem planı 2011-2014*. Erişim Tarihi: 11.02.2012, http://www.alomaliye.com/2011/turkiye_otomotiv_sektoru.htm
- Tekin, M. (2009). *Üretim yönetimi*. Konya: Günay Ofset.
- Wang, F. K., Chang, K. K., & Tzeng, C. W. (2011). Using adaptive network-based fuzzy inference system to forecast automobile sales. *Expert Systems with Applications*, 38, 10587–10593.
- Werbos, P. J. (1998). Generalization of backpropagation with application to a recurrent gas market models. *Neural Network*, 339-356.
- Zhang, G., & Hu, M. Y. (1998). Neural network forecasting of the british pound/US Dollar exchange rate, *Omega International journal of Management Science*, 26(4), 495-506.