

Araştırma Makalesi

**TÜRKİYE’DE PERAKENDE SEKTÖRÜNDE ELEKTRONİK
ÜRÜNLERE OLAN TALEBİN YAPAY SINIR AĞI İLE
MODELENMESİ***

Didem VURAL¹ Emel Şeyma KÜÇÜKAŞÇI² Berk AYVAZ³

¹İstanbul Ticaret Üniversitesi, Fen Bilimleri Enstitüsü, Endüstri Mühendisliği Anabilim Dalı, Küçükyalı,
İstanbul Türkiye, didemvurall@gmail.com, orcid.org/0000-0001-7848-8315

²İstanbul Ticaret Üniversitesi, Mühendislik Fakültesi, Endüstri Mühendisliği Bölümü, Küçükyalı,
İstanbul, Türkiye, eskucukasci@ticaret.edu.tr, orcid.org/0000-0002-4625-3535

³İstanbul Ticaret Üniversitesi, Mühendislik Fakültesi, Endüstri Mühendisliği Bölümü, Küçükyalı,
İstanbul, Türkiye, bayvaz@ticaret.edu.tr, orcid.org/0000-0002-8098-3611

Öz

Şirketlerin rekabet piyasasındaki başarıları geleceklerini tahmin etme yeteneklerine bağlıdır. Bu yüzden talep tahmini şirketlerin kısa ve uzun dönemli hedeflerine ulaşmasında önemli bir rol oynar. Bu çalışmada yapay sinir ağı ile talep tahmin problemi ele alınmıştır. Bu bağlamda Türkiye'nin öncü elektronik perakende şirketlerinden birinin 'notebook' ürün grubu için geçmiş dönemlere ait satış verileri kullanılarak yapay sinir ağı ile gelecek dönemler için satış tahminlemesi yapılmıştır. Uygulama sonucunda yapay sinir ağı kullanılarak yapılan modellemenin tahmin hatalarının incelenmesiyle elde edilen sonuçlara ve değerlendirmelere yer verilmiştir.

Anahtar Kelimeler: *Yapay sinir ağıları, talep tahmini, perakende sektörü, elektronik ürünler.*

Research Article

**FORECASTING THE DEMAND OF ELECTRONIC PRODUCTS BY ARTIFICIAL
NEURAL NETWORKS IN TURKEY RETAIL SECTOR**

Abstract

The success of the companies in the competitive market depends on their capability of predicting their future. Therefore, demand forecasting plays an important role in achieving short and long term goals of companies. In this study, the problem of demand estimation with artificial neural networks is discussed. In this context, prediction of the future sales is performed using an artificial neural networks which takes as an input historical sales data of one of Turkey's leading electronic retail companies 'notebooks' product group sales data by using artificial neural network was carried past eras sales forecasting for future periods. As a result, we report the computational results and evaluations on our artificial neural network model including the forecasting errors.

Keywords: *Artificial neural networks, retail sector, electronic products, demand forecasting.*

* Bu çalışma, İstanbul Ticaret Üniversitesi Fen Bilimleri Enstitüsü'nde yapılan "Türkiye'de Perakende Sektöründe Elektronik Ürünlere Olan Talebin Yapay Sinir Ağı İle Modellenmesi" başlıklı yüksek lisans tezinden hazırlanmıştır.

Received / Geliş tarihi:07.01.2019
Corresponding Author/ Sorumlu Yazar :

Accepted / Kabul tarihi: 15.01.2019
didemvurall@gmail.com

1.GİRİŞ

Talebi tahmin etmenin ve doğruluğunun bir firmanın başarısı ve müşterisinin memnuniyeti ile doğrudan bağlantısı vardır. Talep tahmini yapılmak istenen ürünün değişebilirliği ve talebi etkileyen faktörlerin zaman içerisindeki dinamikliği, talep tahminini ve planlamayı güçleştirmektedir. Talebi tahmin etmenin bu zorluklarına karşılık doğru yapılabilen bir talep tahmini şirketi maksimum kâra taşırken, stratejik hedeflere eldeki kaynaklar ile ulaşmak daha kolay olacaktır.

Literatürde çok farklı talep tahmin yöntemleri bulunmaktadır. (Es,2014) çalışmalarında tahmin yöntemlerini nitel ve nicel tahmin yöntemleri olmak üzere iki gruba ayırmıştır. Nitel tahmin yöntemi, alanında uzman olan kişinin görüş ve deneyimlerine dayanmaktadır. Nicel tahmin yöntemleri ise matematiksel modellere dayanan yöntemlerdir. Bununla birlikte talep tahmin yöntemlerini öznel ve nesnel yöntemler olmak üzere ikiye ayırmak mümkündür (Bolt,1994). Öznel yöntemler, matematiksel verilerden daha çok tecrübenin uygulanmasına, yargılama ve zekâyaya dayanan yöntemlerdir. Nesnel yöntemler ise, istatistiksel ve matematiksel verilere dayanır. İdeal olan yöntem bu iki tip yöntemin birleşimidir (Tekin, 1996).

Son zamanlarda talep tahmininde yapay sinir ağları (YSA) sıkça kullanılmaktadır. Bu çalışma kapsamında YSA ile talep tahmini yapılmıştır. Çalışmamızda Türkiye’nin perakende sektöründe önde gelen bir teknoloji şirketinin satış verilerinden yola çıkarak elektronik ürünler içinde önemli bir yeri olan notebook segmentli ürünler için talep tahmini yapılmıştır.

İkinci bölümde talep tahmini ile ilgili literatür çalışmalarına yer verilmiştir. Üçüncü bölümde, biyolojik ve yapay sinir ağlarına genel bir giriş yapılmış, yapay sinir ağları tanımı, tarihsel gelişim süreci, kullanım alanları, temel yapısı, yapay sinir ağlarının genel özellikleri, öğrenme mekanizması ve çeşitlerinden bahsedilmiştir. Uygulama kapsamında yapılan çalışmalar ayrıntılandırılarak yapay sinir ağları yöntemiyle talep tahmini yapılmış ve hata değerlerine göre sonuçları incelenmiştir. Son bölümde ise uygulama aşamasında elde edilen sonuçlar değerlendirilerek gelecek çalışmalara yön verecek geliştirme önerileri sunulmuştur.

2. LİTERATÜR TARAMASI

Talep, tüketicinin belli bir ürün ya da hizmeti belirlenen bir fiyat karşılığında alabileceği miktardır (Tekin, 1996). Talep tahmini ise, gelecek bir dönemde bir kişi ya da şirketin satın alacağı bir ürünün veya ürünlerin satın alınacağı miktarını tahmin etmektir (Acar, 1989). Talep eş olarak satış olduğu için “talep tahmini” yerine “satış tahmini” de denilebilir.

Literatürde gelecek tahmini ile ilgili birçok çalışma yer almaktadır. Bu yaklaşımları 2 ana başlıkta toplamak mümkün olabilir. Bu başlıkları tahminlerin sayısal ya da sezgisel yaklaşımlarla yapılmasından yola çıkarak niceliksel modeller ve niteliksel

modeller olarak belirleyebiliriz. Niteliksel modeller, şahsi düşünce ve fikirleri de içinde barındırırken niceliksel modeller ise bunun aksine öznellikten uzak istatiki ve matematiksel yaklaşımlar ile problemlere çözüm arayan modellerdir. (Kobu, 1984).

(Matuyama vd, 2008), envanter seviyesinin belli olduğu ancak talebin kesinlik sağlamadığı vakalar için yaptıkları çalışmada iki farklı geribildirim politikasıyla iki farklı tahmin yaklaşımı kullanarak, envanter sistemine periyodik bir açıdan bakmışlardır. (Fildes vd, 2008), çalışmalarında herhangi bir bilgisayar tabanlı tahminlemenin sonuçlarının tahminleme ve planlama uzmanlarının eleştirel ve iyileştirici müdahaleleri ile hata oranının azalıp azalmadığını tespit etmeye çalışmışlar ve sonucun sektöre göre değiştiği kanısına ulaşmışlardır. (Carlson ve Umble, 1980) Amerika’da, standart ve lüks otomobil segmentinde 5 farklı çeşit otomobilin, gelecek beş senelik talep tahminini bulmak için yaptığı çalışmasında, tahminleme yöntemi olarak çoklu regresyon analizini seçmiştir. Çalışmada, benzin fiyatı, benzin kıtlığının piyasaya etkisi, taşıt fiyatları, tüketici gelirleri ve sektördeki işçi grevlerinin talebi etkileyen etkenler olduğunu belirlemişlerdir. (Gavcar vd, 1999) çalışmalarında “Türkiye’de Kullanılan Kağıt- Karton Türlerinin Talep Tahminlerinin Belirlenmesi” konulu araştırmalarında, SEKA kâğıt fabrikasının ürettiği 8 farklı kâğıt ürünün talep tahminini yapmışlardır. Çalışmada çoklu regresyon analizi kullanılmış ve değişkenlerin ilişkisi ise korelasyon analiziyle açıklanmıştır. (ZhoumcMahon vd, 2002), Avustralya su tedarik sisteminin Melbourne şehrindeki altı yıllık, günlük su tüketim verileri ile gelecek su talep tahminini zaman serileri analizi metodu ile açıklamışlardır. (Cahow, 2004) çalışmasında tedavisi evde yapılan kronik hastaların hemşire talebini çoklu regresyon ve Monte Carlo simülasyon yöntemleri ile tahmin etmişlerdir. Çalışmaya göre 2025’e kadar Amerika’da bu hizmete olan ihtiyacın artacağı sonucuna ulaşılmıştır. (Griffiths vd, 2010), çalışmalarında Regresyon modeli ile yerel buğday verimliliği tahmini yaparak belirsiz bazı verileri analiz etmişlerdir. (Sun vd, 2010) gemi turu endüstrisinin, müşteri talep tahmini üzerine çalışmışlardır.

Üretici ve perakendeci birçok satıcı kesin satışını tahmin etmek ister. Özellikle perakendeciler, geçmişe dair satış verileri ile stokları özelinde satış tutarlarını belirlemeyi hedefler. Bu ihtiyacı karşılamak için büyük veri tabanlarını analiz eden yapay sinir ağları kullanılır. (Thall, 1992) Yapay sinir ağları ile talep tahmini yapılırken de diğer matematiksel modellerde olduğu gibi geçmişe ait veriler kullanılır ve parametreler değerlendirilirken en küçük kare hatasına ulaşılmaya çalışılır. Uygun ağırlık değerini bulmak için sinir ağı eğitilir ve en uygunu bulunana kadar sinir ağı bir dizi iterasyona tabii tutulur. (Denton, 1995) Yapay sinir ağları, ideal koşulların olmadığı durumlarda talep tahmininde regresyon yöntemine göre daha sağlıklı sonuçlar sağlar. Regresyona göre daha sağlıklı sonuçların alındığı durumlar şöyle ifade edilir: (Denton, 1995) Matematiksel bir modelde tahmin yapan kişi değişkenler arası ilişkileri anlatan bir fonksiyon yapısını varsayım olarak kabul etmelidir. Yapay sinir ağları böyle bir yapıya ihtiyaç duymaz ve bağımsız değişkenler arasındaki ilişkiyi kendisi öğrenir. Literatürde yapay sinir ağları kullanılarak yapılan birçok tahmin çalışması vardır. Bunlardan ilki hava durumunun tahmin çalışmasıdır. Sonrasında Hu tarafından 1964’te işletmelerde yapılan yapay

sinir ağı modeli çalışması ile model yaygınlaşmıştır. İşletmelerde yapay sinir ağı ile tahmini, öncelikle ekonomi ve finansta uygulanmış ve önemli sonuçlara ulaşılmıştır. 1997 yılında Wong vd. yapay sinir ağı temelli 1988-1995 seneleri arasındaki makalelerinde bir anket ile yapmış oldukları çalışmalarında yapay sinir

ağı uygulamalarının her geçen gün artarak işletme faaliyetlerinde yer aldığını tespit etmişlerdir. Bunun sebebi olarak ise yapay sinir ağlarının her geçen gün gelişen ve değişen teknolojiye hızlı uyum sağlayabiliyor olmalarını göstermişlerdir.

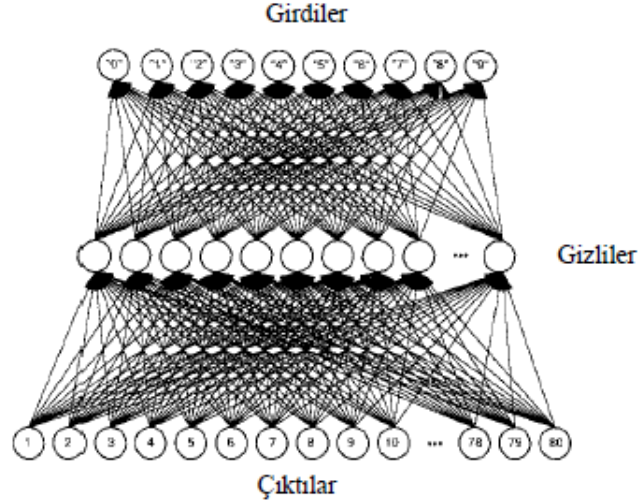
(Hu, 2002), iç turizm talebini ve (Çuhadar vd, 2009), dış turizm talebini tahminlerken; yapay sinir ağı yönteminin diğer geleneksel metotlara göre daha yaklaşık tahminlerde bulunduğunu ortaya koymuşlardır. (İnsel vd, 2010); (Ataseven, 2007; Çelik, 2008; Hajirezaie vd, 2010), yapay sinir ağlarının planlama ve kalite kontrol uygulamalarının performansını belirlemede güvenilir ve hızlı olduğunu söylemişlerdir. (Jones, 2008) hastanelerin ilk yardım departmanlarındaki talep tahmini modellemesi çalışmasında, gizli katmanlı, geri beslemeli yapay sinir ağı modeli oluşturmuştur. (Asilkan, 2009) çalışmasında, ikinci el otomobillerin gelecek fiyatlarını yapay sinir ağı ile tahminlemiştir. Araştırmada, yapay sinir ağı ve zaman serisi analizleri ile elde edilen sonuçlar karşılaştırılarak yorumlanmıştır. Sonuçlara göre yapay sinir ağı sonuçlarının daha başarılı olduğu görülmüştür.

(Aydoğan vd, 2010) İstanbul boğazındaki deniz suyu akıntı hızının, (Shamseldin, 2010) Sudan’daki mavi Nil nehrinin akış hızının, (Sahoo vd, 2009) sıcak su akıntı hızının tahmini üzerine yapay sinir ağı modeli tasarlamışlardır. (Avcı, 2009), IMKB-30 endeksinde seçilmiş birkaç hisse senedinin günlük getirilerinin tahmini üzerine yapay sinir ağı modeli tasarlamış ve başarılı sonuçlara ulaşmışlardır. (Serttaş, 2011) yılında Türkiye’de Perakende sektöründe talebi etkileyen etmenler ve yapay sinir ağıyla talep tahmini uygulaması üzerinde çalışmıştır.

Bu kapsamda, talep tahmininde yapay ağlarının kullanımı içeren bir yöntem kullanılmıştır. Önde gelen bir elektronik firmasının notebook türüne ait gerçek satış verileri kullanılarak ilgili yöntemin başarısı test edilmiştir. Elde edilen sonuçlar satışlarla ilgili tahminlerin etkinliğini ortaya koymaktadır.

3. YAPAY SİNİR AĞLARI

Yapay sinir ağı değişik katmanlarda toplanan yapay sinir hücreleri ve bu hücreler arasındaki bağlantılardan meydana gelir. (Arbib, 2003). Bir yapay sinir ağını meydana getiren sinir hücreleri tam olarak bağlantılarla bağlanabilir ya da bağlantılar seyrek/yerel olarak kurulmuş olabilir. Katmanlar, bünyelerinde bulunan sinir hücrelerinin birbirleriyle bağlantılar vasıtasıyla ilişkilendirilmediği ancak diğer katmanlarla bağlantılı olan sinir hücresi kümeleridir. (Tebo, 1994). Yapay sinir ağlarının yapısı aşağıdaki şekil 1’de gösterilmektedir.



Şekil 3.1. Yapay Sinir Ağı Yapısı (Freeman ve Skapura, 1991)

Bir yapay sinir ağının büyüklüğü iki temel kriter ile ifade edilir: ağ oluşturulan katman sayısı ve gizli birimlerin sayısı (Fuente, 2004).

- Girdi katmanı, yapay sinir ağının problemine ait başlangıç verilerinin (girdilerin) ağa tanıtıldığı katmandır. Bu katmandaki sinir hücreleri sayısı problemin girdi parametrelerinin sayısına eşittir ve her sinir hücresi ilgili girdi ile ilgili veri barındırır (Veelenturf, 1995). Girdi hücrelerinde işlem yapılmaz. (Şahin, 2002).
- Gizli katman, yapay sinir ağının asıl işlendiği katmandır. Bu katmanı kullanıcı görmez. Girdi katmanından ağa alınan verilerin ilgili probleme uygun bir fonksiyonla işlendiği ve sonucun elde edilmesi amacıyla çıktı katmanına iletiildiği katmandır. Ağ içerisinde gizli katman bulunup bulunmayacağı ya da kaç tane bulunacağı ağ tasarımcısının kontrolindedir ve uğraşılan probleme göre belirlenir.
- Çıkış katmanı, girdi katmanından ağa girilen ve gizli katmanda işlenen verilerin ağın yapısına uygun bir fonksiyonla işlendiği ve sonucun sistemin çıktısı olarak sunulduğu katmandır. Girdi katmanındaki ilişkiye benzer şekilde, çıkış katmanındaki sinir hücresi sayısı ağdan beklenen çıktı sayısına eşittir.

Yapay sinir ağları örnekler üzerinde çalışarak çözümü öğrenen yapılardır. Sonraki süreçte ise bunlardan yola çıkarak daha önce karşılaşmadıkları problemler için

benzer şekilde çözüm üretebilirler. (Murray, 2003). Bu öğrenme sürecini iki maddede ele alınabilir (Tebo, 1994):

- Yapay sinir ağının problemlerin geçmiş verileriyle çalıştırılması ve çözüm yaklaşımı oluşturmaya (öğrenme aşaması),
- Eğitim sonrası yapay sinir ağı çıktılarının doğruluğunun değerlendirilmesi ve tutarlılık testi (test aşaması)

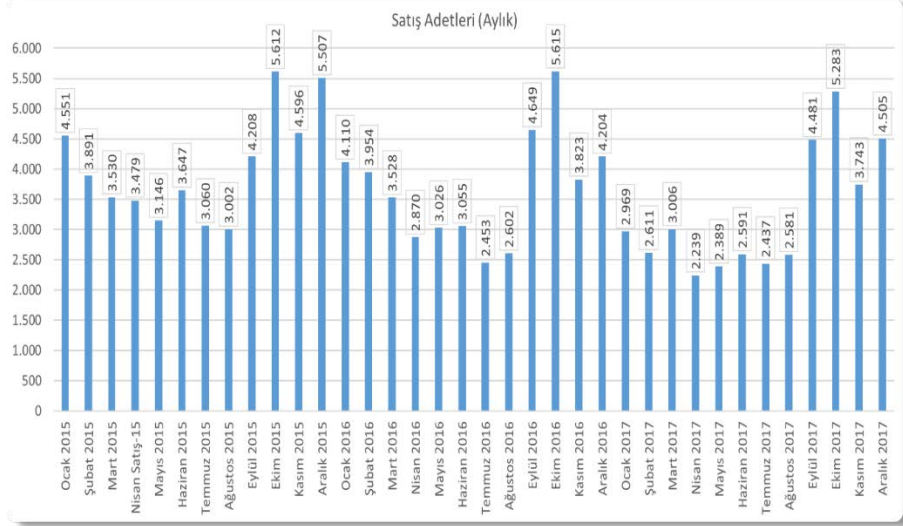
Bir yapay sinir ağında öğrenme, ağın sinir hücreleri arası bağlantı kuvvetlerini, probleme uygun çözümleri üretecek kombinasyona ulaştırmasıdır. (Barghash ve Santarisi, 2004). Yapay sinir ağı modeli tasarımından sonra, problemle ilgili olarak ağı eğitmek ve test etmek için problemin geçmiş verilerine ait birbirinden farklı iki grup oluşturulur. Eğitim ve test grubu ayrımının yapılmasında eğitim sırasında kendini probleme adapte etmeye çalışan yapay sinir ağı modelini, o zamana kadar karşısına hiç çıkmamış koşullarla sınamak ve genelleme yapmak esastır.

Yapay sinir ağı modeli ilk kurulduğunda yapay sinir hücrelerini birbirine bağlayan bağlantılara rassal kuvvetler verilir. Model, eğitim test grubu ile çalıştırılmaya başladığında veri kümelerine ilişkin sonuçlarla ilgili tahminlerde bulunur. Süreç ilerledikçe ağ bağlantı kuvvetlerini her adımda iyileştirir ve eğitim, modelin çıktılarının tutarlı olduğu düşünülen kararlı bir duruma ulaştığı ana kadar devam ettirilir. Kararlı bir hal aldığı düşünülen sistem için eğitim aşamasının tamamlandığı kabul edilir ve test aşamasına geçilir. Eğitime tabi tutulan ağ, daha önce karşılaşmadığı yeni verilerle çalıştırılır ve ürettiği sonuçların performansı değerlendirilir.

4. UYGULAMA

4.1. Yapay Sinir Ağı Mimarisi

Çalışmada talep tahmini yapılırken WEKA programı kullanılmıştır. WEKA’da yapay sinir ağları ile çözüm yoluna başvurulmuş ve Multilayer Perceptron algoritması çalıştırılmıştır. Ocak 2015 – Aralık 2017 yılları arasındaki 3 yıla ait 36 adet satış verisi kullanılarak tüm modeller giriş katmanı, çıkış katmanı ve gizli katmandan oluşmuştur. Girdi katmanı, aylık tarih rakamları olarak bir hücreden, çıktı katmanı ise satış verilerinden meydana gelen bir hücreden oluşmaktadır. Gizli katmanda ise farklı sayıda hücre yer alabilir, çalışmanın devam eden kısmında uygun gizli katman hücre sayısını bulmak adına denemeler yapılmıştır. Yapay sinir ağlarında gizli hücre sayısını bulmak için “geometrik piramit kuralı” yöntemi kullanılır. Bu kurala göre, girdi katmanından çıktı katmanına doğru hücre sayısının azalmasıdır. Bu çalışma kapsamında piramite göre gizli hücre sayısı, girdi hücre sayısının iki katı olan ikiyi geçemez. Ayrıca bu sayı, girdi hücre sayısı ile çıktı hücre sayısının çarpımının karekökünden de az olamaz. Bu koşullarda mevcut çalışmada toplam 500 farklı deneme yapılmıştır.

Grafik 4.1. Geçmiş Aylara Ait Satış Adetleri

Eğitim verileri ağı sunularak ağı öğrenmesi gerçekleştirilmiş ve bu beş yüz model arasında test verileri için, hata kareleri ortalaması (MSE), ortalama mutlak yüzde, hata (MAPE) ve ortalama mutlak hata (MAE) istatistiksel hata değerlerinden en küçük hata değerini veren YSA modeli seçilmiştir. Çalışma kapsamında ilk olarak çevrim sayısı sabit tutularak öğrenme ve momentum katsayılarının en uygun değerleri seçilmeye çalışılmıştır. Bu yüzden çevrim sayısı 500’ de sabit tutularak öğrenme ve momentum katsayıları değiştirilmiş, en uygun değerler tespit edilmiştir. Hücre sayısı, momentum katsayısı ve öğrenme katsayısındaki değişimler tahmin sonuçlarını doğrudan etkilemektedir. Bu yüzden mümkün olduğunca fazla deneme yapıp sonuçlar karşılaştırılmıştır.

4.2. Yapay Sinir Ağı WEKA Uygulamaları

Çalışma kapsamında ilk olarak öğrenme katsayısını bulabilmek için 0.1-0.9 değerleri arasında deneme yapılmıştır. Sonraki adımda bulunan optimal öğrenme katsayısı dikkate alarak momentum katsayısı 0.1-0.9 değerleri arasında denenmiştir, belirlenen bu optimal aralıklardan hareket ile elde edilen sonuçlar çalışmada değerlendirilmiştir.

4.2.1. Öğrenme ve Momentum Katsayısının Belirlenmesi

Öğrenme katsayısının doğru seçilmesi ağı öğrenme performansında oldukça önem taşımaktadır. Bu katsayı ağı ait öğrenme hızını etkilemektedir. Küçük değerler, ağı öğrenme süresini arttırırken büyük değerler yerel çözümler arasında ağı dolaşmasına neden olmaktadır. Yapılan denemeler ile öğrenme katsayısının optimal değerinin 0.2 - 0.4 arasında olduğu üzerinde yoğunlaşmıştır. Çalışma kapsamında ise 0-1 değerleri arasında tüm öğrenme katsayıları için denemeler yapılmıştır.

Tablo 4.1. Öğrenme Katsayısı ve Momentum Katsayısı için Yapılan Denemeler

Deneme No	Öğrenme Katsayısı	Momentum Katsayısı	37. Ay Tahmin	37. Ay MAE	37. Ay MAPE	37. Ay MSE
1	0,1	0,1	3.108,3	14,8	0,4	304,5
2	0,1	0,2	3.104,7	19,8	0,6	537,8
3	0,1	0,3	3.090,3	30,5	0,9	1.317,1
4	0,1	0,4	3.033,0	53,5	1,5	4.263,7
5	0,1	0,5	2.867,4	105,5	3,0	16.031,3
6	0,1	0,6	2.738,1	146,9	4,0	38.139,1
7	0,1	0,7	3.327,2	128,8	3,8	21.733,0
8	0,1	0,8	2.010,5	731,1	21,4	752.378,2
9	0,1	0,9	2.881,5	369,5	10,1	21.872,2
10	0,2	0,1	2.691,9	48,4	1,4	3.373,9
11	0,2	0,2	2.659,0	65,7	1,8	6.112,5
12	0,2	0,3	2.580,6	89,9	2,5	11.329,7
13	0,2	0,4	2.499,0	115,4	32.774,0	17.607,8
14	0,2	0,5	2.272,7	92,3	2,7	11.676,3
15	0,2	0,6	1.798,0	109,2	3,2	17.111,3
16	0,2	0,7	2.585,0	562,9	15,8	385.209,0
17	0,2	0,8	4.853,9	296,3	9,2	164.088,8
18	0,3	0,1	1.958,6	69,7	1,9	9.124,6
19	0,3	0,2	1.478,2	145,0	4,2	29.653,0
20	0,3	0,3	1.781,6	254,6	7,1	103.505,8
21	0,3	0,4	1.496,0	60,0	1,7	6.211,7
22	0,3	0,5	430,6	140,1	4,1	33.084,2
23	0,3	0,6	-159,3	275,8	8,0	109.177,0
24	0,3	0,7	-1.130,2	623,2	18,7	662.997,5
25	0,3	0,8	3.249,5	575,7	16,2	426.535,5
26	0,4	0,1	1.958,7	92,1	2,6	14.022,6
27	0,4	0,2	1.632,9	87,9	2,6	11.486,1
28	0,4	0,3	1.661,5	235,5	6,8	76.910,8
29	0,4	0,4	1.452,6	257,7	7,1	119.737,4
30	0,4	0,5	2.732,3	150,6	4,4	33.007,2
31	0,4	0,6	1.132,1	521,6	16,1	459.998,3
32	0,4	0,7	2.397,5	825,7	25,9	1.047.372,0
33	0,5	0,1	3.061,9	50,6	1,5	3.251,4
34	0,5	0,2	3.902,1	30,0	0,9	1.204,3
35	0,5	0,3	2.980,6	80,2	2,2	9.726,1

36	0,5	0,4	3.395,2	107,4	2,9	17.411,0
37	0,5	0,5	2.045,5	424,1	12,6	278.874,5
38	0,5	0,8	3.792,5	955,5	25,6	1.181.132,6
39	0,6	0,1	7.163,0	290,4	7,8	141.735,0
40	0,6	0,2	6.602,5	330,6	9,2	191.039,0
41	0,6	0,3	2.332,4	556,9	15,9	538.116,7
42	0,6	0,4	3.355,5	315,1	9,2	135.577,8
43	0,6	0,5	4.376,5	225,8	6,4	82.891,3
44	0,6	0,6	6.021,4	1.110,0	29,9	1.636.862,1
45	0,7	0,1	3.580,4	933,3	24,4	1.164.551,1
46	0,7	0,2	3.704,1	927,3	24,0	1.192.839,2
47	0,7	0,3	3.728,5	933,1	24,4	1.178.912,3

Uygun öğrenme katsayısı belirlendikten sonra bu değer sabit tutularak momentum katsayısı için denemeler yapılmıştır. Momentum katsayısı bir önceki iterasyona ait değişimin belirli bir oranının yeni değişime eklenmesi ile elde edilir. Bu değer in küçüklüğü yerel çözümlerden uzaklaşmayı zorlaştırırken, büyüklüğü ise tek bir çözüme ulaşmayı zorlaştırabilir. Momentum katsayısı öğrenme performansını değiştirmektedir. Momentum katsayısı, ağ yerel çözümlere takılırsa, sıçramayla daha uygun sonuçlar elde edilmesine yardımcı olur. Çok büyük değerler uygun sonuca ulaşırken sorunlar yaşatabilir. Bu değer in 0.6 - 0.8 arasında en optimal olduğu düşünülmektedir. Tablo 4.1.'de bu denemeler yer almaktadır.

4.2.2. Çevrim Sayısının Belirlenmesi

Belirli bir deneme sayısından sonra ağın öğrenmesinin sona erdiği düşünülür. Bunun sonucunda ağ artık öğrenemez ve daha uygun bir sonuç elde edilemez. Momentum katsayısı 0.1 ve 0.2 öğrenme katsayısı 0.1 ve 0.5 alınarak en uygun çevrim sayısı bulma denemeleri yapılmıştır. Aşağıdaki Tablo 4.2.'de bu denemeler yer almaktadır. 500 - 2000 arasında çevrim sayıları denenmiş ve en uygun çevrim sayısının 2000 olduğu belirlenmiştir. (Deneme 54)

Tablo 4.2. Uygun Çevrim Sayısının Belirlenmesi için Yapılan Denemeler

Deneme No	Öğrenme Katsayısı	Momentum Katsayısı	Çevrim Sayısı	37. Ay Tahmin	37. Ay MAE	37. Ay MAPE	37. Ay MSE
48	0,1	0,1	500	3.108,3	14,82	0,43	304,54
49	0,1	0,1	750	3.086,4	4,59	0,13	35,25
50	0,1	0,1	1.000	3.094,0	1,49	0,04	3,47
51	0,1	0,1	1.250	3.092,3	0,39	0,01	0,23
52	0,1	0,1	1.500	3.092,5	0,09	0,00	0,01
53	0,1	0,1	1.750	3.092,5	0,02	0,00	0,00
54	0,1	0,1	2.000	3.092,5	0,01	0,00	0,00
55	0,1	0,2	500	3.104,7	19,83	0,58	537,79
56	0,1	0,2	750	3.083,7	6,96	0,20	71,67
57	0,1	0,2	1.000	3.095,8	2,53	0,07	10,94
58	0,1	0,2	1.250	3.091,1	0,96	0,03	1,49
59	0,1	0,2	1.500	3.092,6	0,33	0,01	0,17
60	0,1	0,2	1.750	3.092,2	0,10	0,00	0,02
61	0,1	0,2	2.000	3.092,2	0,03	0,00	0,00
62	0,5	0,2	500	3.902,1	30,04	0,87	1.204,33
63	0,5	0,2	750	3.828,2	15,40	0,42	362,17
64	0,5	0,2	1.000	3.853,1	4,34	0,12	29,70
65	0,5	0,2	1.250	3.857,3	1,80	0,05	4,18
66	0,5	0,2	1.500	3.852,8	0,70	0,02	0,85
67	0,5	0,2	1.750	3.853,3	0,19	0,01	0,05
68	0,5	0,2	2.000	3.853,8	0,10	0,00	0,01

4.2.3. Nöron Sayısının Belirlenmesi

Ağın yapısal niteliklerinden biri de her katmana ait nöron sayısıdır. Bir katmanda yer alacak nöron sayısının olabildiğince az olması uygundur. Nöron sayısının az olması YSA'nın genelleme yeteneğini yükseltmektedir. Gereğinden çok olması ağın verileri ezberlemesine neden olabilmektedir. Zaman serisi tahminlerine ait problemlerde nöron sayısı, gecikme sayısı ile doğrudan bağlantılıdır ve bu sayıyı tespit edebilmek için belirli bir yol yoktur.

4.2.4. Gizli hücre sayısının belirlenmesi

Momentum katsayısı 0.1, öğrenme katsayısı 0.1, çevrim sayısı 2000 alınarak sonrasında nöron sayısı ve gizli hücre sayısının hesaplanmasına geçilmiştir. Gizli hücre sayısı 1' den giriş hücre sayısının iki katı olan 2'ye kadar denemeler


yapılmıştır. En iyi hücre sayısının 2, bu katmanlardaki nöron sayılarının ise sırasıyla 3 ve 4 olduğu belirlenmiştir. Aşağıdaki Tablo 4.3.'te bu denemeler yer almaktadır.

Tablo 4.3. Uygun Gizli Hücre Sayısının Belirlenmesi için Yapılan Denemeler

Deneme No	Öğrenme Katsayısı	Momentum Katsayısı	Çevrim Sayısı	Gizli Katman Sayısı	Nöron Sayısı1	Nöron Sayısı2	37. Ay Tahmin	37. Ay MAE	37. Ay MAPE	37. Ay MSE
69	0,1	0,1	2000	1	1	-	3.477	226,5080	6,2945	64496,2688
70	0,1	0,1	2000	1	2	-	1.932	15,2215	0,5052	790,3527
71	0,1	0,1	2000	1	3	-	3.198	0,0001	0,0100	0,0000
72	0,1	0,1	2000	1	4	-	3.196	0,0001	0,0100	0,0000
73	0,1	0,1	2000	1	5	-	2.173	0,0001	0,0010	0,0000
74	0,1	0,1	2000	2	1	1	3.429	223,0734	6,2296	66896,2252
75	0,1	0,1	2000	2	2	1	3.017	2,4522	0,0615	17,3534
76	0,1	0,1	2000	2	3	1	4.054	0,0004	0,0000	0,0000
77	0,1	0,1	2000	2	4	1	3.177	0,0005	0,0000	0,0000
78	0,1	0,1	2000	2	5	1	4.003	0,0186	0,0006	0,0005
79	0,1	0,1	2000	2	1	2	3.509	222,7491	6,2227	65826,6053
80	0,1	0,1	2000	2	2	2	3.679	7,2134	0,1923	88,0237
81	0,1	0,1	2000	2	3	2	4.086	0,0045	0,0001	0,0000
82	0,1	0,1	2000	2	4	2	4.210	0,0002	0,0000	0,0000
83	0,1	0,1	2000	2	5	2	3.810	0,0004	0,0000	0,0000
84	0,1	0,1	2000	2	1	3	3.524	223,7323	6,2426	65571,3727
85	0,1	0,1	2000	2	2	3	3.493	2,2546	0,0604	12,1207
86	0,1	0,1	2000	2	3	3	3.179	0,0002	0,0000	0,0000
87	0,1	0,1	2000	2	4	3	3.729	0,0001	0,0000	0,0000
88	0,1	0,1	2000	2	5	3	4.191	0,0003	0,0000	0,0000
89	0,1	0,1	2000	2	1	4	3.535	225,1875	6,2743	65460,2876
90	0,1	0,1	2000	2	2	4	3.686	3,0401	0,0789	15,1569
91	0,1	0,1	2000	2	3	4	4.148	0,0000	0,0000	0,0000
92	0,1	0,1	2000	2	4	4	3.355	0,0001	0,0000	0,0000
93	0,1	0,1	2000	2	5	4	4.211	0,0003	0,0000	0,0000
94	0,1	0,1	2000	2	1	5	3.533	2226,2482	6,3023	660007,000
95	0,1	0,1	2000	2	2	5	3.696	7,6069	0,1876	237,0560
96	0,1	0,1	2000	2	3	5	4.046	0,0003	0,0000	0,0000
97	0,1	0,1	2000	2	4	5	3.308	0,0002	0,0000	0,0000
98	0,1	0,1	2000	2	5	5	4.177	0,0001	0,0000	0,0000

5.SONUÇ

Tahmin, gelecekte neyin nasıl olacağını öncesinde belirlemeye çalışmaktır. Hemen hemen tüm yönetsel kararlar geleceğe tahminlere dayanmaktadır. Bu sebeple tüm şirketler gelecekte yaşayabileceği belirsiz durumları öncesinde tahmin ederek, bunlara yönelik önlemler ve iyileştirmeler yapmalıdırlar. Bu sebeple uygulamasını yaptığımız şirket probleminin çözümünde bir tahmin aracı olarak yapay sinir ağı kullanılmıştır. Optimal sonuca ait yapay sinir ağına 2 gizli katman ve bu katmanlarda sırasıyla 3 ve 4 nöron yer almaktadır.



Grafik 5.1. Optimal Sonuca Ait Yapay Sinir Ağı Yapısı

Uygulama çalışmamızda, 2015-2017 yılları arasında Türkiye’nin öncü elektronik perakende şirketlerinden birinin ‘notebook’ ürün grubu özelinde satış dataları adet cinsinden verilmiştir. 2015 (Ocak) - 2017 (Aralık) yılları arasındaki 36 adet veriden ilk 24’ü ağı eğitimi için, son 12’si ise ağı test edilmesi için kullanılmıştır. Yapılan tahmin sonucunda MAPE, MAE ve MSE = 0.00 lik bir hatayla tahmin sonucu elde edilmiştir.

İleriye yönelik yapılacak çalışmalarda, zaman serileri ve gri tahminleme gibi farklı yöntemler kullanılarak yapılan tahminler YSA sonuçları ile karşılaştırılabilir.


İlgili makale İstanbul Ticaret Üniversitesi “Türkiye’de Perakende Sektöründe Elektronik Ürüne Olan Talebin Yapay Sinir Ağı İle Modellenmesi” başlıklı Yüksek Lisans tezinden uyarlanarak yayınlanmıştır.

Tablo 5.1. Optimal Sonuç Değerlerini İçeren Tablo

Deneme No	Öğrenme Katsayısı	Momentum Katsayısı	Çevrim Sayısı	Gizli Katman Sayısı	Nöron Sayısı1	Nöron Sayısı2
91	0,1	0,1	2000	2	3	4

Tablo 5.2. Gelecek 6 Aylık Tahmin Değerlerini İçeren Tablo

Ay	Tahmin
37*	4.148
38*	2.901
39*	5.214
40*	4.765
41*	3.285
42*	4.209



Grafik 5.2. Gelecek 6 Aya Ait Tahminleri İçeren Grafik

KAYNAKLAR

- Acar, N.**, (1989), Üretim Planlaması Yöntem ve Uygulamaları, Yeniçag, Ankara.
- Arbib, M.A.**, (2003), The handbook of brain theory and neural networks, second edition. Massachusetts Institute of Technology. USA.
- Asilkan, Ö. ve Irmak, S.**, (2009), “İkinci El Otomobillerin Gelecekteki Fiyatlarının Yapay Sinir Ağları ile Tahmin Edilmesi”, Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi, 14(2) 2009: 375-391.
- Ataseven, B.**, (2007), Satış öngörü modellemesi olarak YSA’nın kullanımı: PETK_M’de Uygulanması, Yüksek Lisans Tezi, Celal Bayar Üniversitesi Sosyal Bilimler Enstitüsü, Manisa.
- Avcı, E.**, (2009), “Yapay Sinir Ağları Modelleri İle Hisse Senedi Getiri Tahminleri”, Marmara Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi, 26(1) 2009: 443-461.
- Aydoğan, B., Ayat, B., Öztürk, M., N.; Çevik, Ö. E., Yüksel, Y.**, (2010), Current velocity forecasting in straits with artificial neural networks, a case study: Strait of Istanbul, Ocean Engineering, 37 (2010) 443– 453.
- Barghash, M.A. ve Santarisi, N.S.**, (2004), “Pattern recognition of control charts using artificial neural networks – analysing the effect of the training parameters”, Journal of Intelligent Manufacturing, 15, 635-644.
- Bolt, G.**, (1994), Market and sales forecasting : a total approach, Kogan Page,Londra
- Cahow, E. E.**, (2004), Forecast of demand for chronic care nursing home services: 20052025, Doktora Tezi, Brandeis University, Waltham Massachusetts, USA.
- Carlson, RL and Umble, M.**, (1980),”Statistical demand functions for automobiles and their use for forecasting in an energy crisis” The Journal of Business, 53,2-10.
- Çelik, B.**, (2008), YSA Metodolojisi ile Zaman Serisi Analizi: Teori ve Uygulama, Yüksek Lisans Tezi, Marmara Üniversitesi Sosyal Bilimler Enstitüsü, İstanbul.
- Çuhadar, M., Güngör, İ. ve Göksu, A.**, (2009), “Turizm Talebinin Yapay Sinir Ağları ile Tahmini ve Zaman Serisi Yöntemleri ile Karşılaştırmalı Analizi: Antalya İline Yönelik Bir Uygulama”, Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi, 14(1) 2009: 99-114.
- Denton, J. W.**, (1995), How good are neural networks for casual forecasting The Journal of Business Forecasting Methods&Systems, 14, p.17

Es, H., (2013), Yapay Sinir Ağları ile Türkiye Net Enerji Talep Tahmini, Gazi Üniversitesi, Fen Bilimleri Enstitüsü, Endüstri Mühendisliği Ana Bilim Dalı, Yüksek Lisans Tezi,.

Fildes, R., (2006), The forecasting journals and their contribution to forecasting research: Citation analysis and expert opinion”, International Journal of Forecasting, 22(3):415– 432.

Freeman, J.A. ve Skapura, D.M., (1991), Neural networks algorithms, applications, and programming techniques. Addison-Wesley Publishing Company. USA.

Fuente, D.A., (2004), Artificial neural networks, the tutorial. Universidad Politecnica de Madrid. Erişim Adresi: <http://www.gc.ssr.upm.es/inves/neural/ann1/anntutorial.html>. Erişim tarihi: Şubat 2005.

Gavcar, E., Sen, S., ve Aytekin, A., (1999), “Türkiye’de Kullanılan Kağıt- Karton Türlerinin Talep Tahminlerinin Belirlenmesi”, Tr. Journal of Agriculture and Forestry, TÜBİTAK, 23. 203-211.

Griffiths, W. E., Newton, L. S. and O’Donnell, C. J., (2010), “Predictive densities for models with stochastic regressors and inequality constraints: Forecasting local-area wheat yield”, International Journal of Forecasting, 26 (2010) 397–412.

Hajirezaie, M., Hussein, S., Barfouroush, A., and Karimi, B., (2010), “Modeling and evaluating the strategic effects of improvement programs on the manufacturing performance using neural Networks”, African Journal of Business Management, 4(4): 414-424.

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

İnsel, A., Sualp, M. N., ve Karakaş, M., (2010), A comparative analysis of the ARMA and neural network models: A case Turkish economy, İktisat İşletme ve Finans, 25(290)2010: 35-64.

Jones, S., S., (2008), Measuring, Modeling, and Forecasting Demand in The Emergency Department, Doktora Tezi, The University of Utah, USA.

Kobu B., (1984), Üretim yönetimi. İ.Ü. İşletme Fakültesi, İstanbul.

Matuyama, K., Sumita, T. ve Wakayama, D., (2009), “Periodic forecast and feedback to maintain target inventory level”, International Journal of Production Economics, 118(1):298-304.

Murray, G., (2003), Artificial neural networks. Erişim adresi <http://www.swin.edu.au/bioscieleceng/ciscp/anns.html>. Erişim tarihi: Ocak 2005.

Sahoo, G.B., Schladow, S.G. and Reuter, J.E. (2009), “Forecasting stream water temperature using regression analysis, artificial neural network, and chaotic non-linear dynamic models”, *Journal of Hydrology*, 378 (2009) 325–342.

Serttaş, Z., (2011), Türkiye’ de Perakende Sektöründe Talebi Etkileyen Etmenler ve Yapay Sinir Ağlarıyla Talep Tahmini Uygulaması, Yıldız Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Endüstri Mühendisliği, Yüksek Lisans Tezi.

Shamseldin, A. Y., (2010), “Artificial neural network model for river flow forecasting in a developing country”, *Journal of Hydro informatics*, 12 (1): 2235.

Sun, X., Gauri, D. and Webster, S., (2010), “Forecasting for cruise line revenue management”, *Journal of Revenue and Pricing Management*, 10(4),306-324.

Şahin, Ş.Ö., (2002), Yapay sinir ağları yardımı ile dinamik bir senaryo analizi, Yüksek Lisans Tezi, İ.T.Ü. Fen Bilimleri Enstitüsü, İstanbul.

Tebo, A., (1994), Artificial neural networks: a developing science. Erişim adresi : http://www.spie.org/app/publications/magazines/oerarchive/september/neural_net.html. Erişim Tarihi: Ocak 2005.

Tekin, M., (1996), Üretim Yönetimi, Arı Ofset Matbaacılık, Konya.

Thall, N., (1992), Neural Forecasts: A Retail Sales Booster, *Discount Merchandiser*, 32, p. 41.

Veelenturf, L.P.J., (1995), Analysis and applications of artificial neural networks. Prentice Hall International (UK) Limited. United Kingdom.

Wong, B., K., Bodnovich, T. A., Selvi, Y., (1997), Neural network applications in business: A review and analysis of the literature (1988-95), *Decision Support Systems* 19 (1997): 301-320.

Zhoucmahon, S.L, Walton, T.A and Lewis, A (2002), Forecasting operational demand for an urban water supply zone. *Journal of Hydrology*, 259(1): 189-202.