

YAPAY SINIR AĞLARI İLE BORSA ENDEKSİ TAHMİNİ

Doç. Dr. Birgül Kutlu

Yrd. Doç. Dr. Bertan Badur

Boğaziçi Üniversitesi

Yönetim Bilişim Sistemleri Bölümü

ÖZET

Günümüzde yapay sinir ağları popüler olarak borsa endeks tahmini, iflas tahmini ya da şirket bono sınıflaması gibi bir çok finans problemine uygulanmaktadır. Çalışmalar, hisse senedi endeks değeri tahmini üzerinde olduğu kadar günlük endeks değişim yönü üzerinde de durmaktadır. Bazı uygulamalarda yapay sinir ağlarının veri kalıplarını öğrenmede kısıtlamaları olduğu belirtilmektedir. Yapay sinir ağları seçkin öğrenme yeteneğini sunmakla birlikte karmaşık finansal veri nedeni ile tutarlı olmayan ve tahmin edilemeyen bir performans gösterebilmektedir. Buna ek olarak veri bazen o kadar hacimli olmaktadır ki öğrenme kalıpları çalışmayabilmektedir. Sürekli veri ve büyük çaptaki kayıtların varlığı nedeni ile gereksiz özelliklerin ayıklanması ve verinin boyutlarının azaltılması algoritmanın işlem süresini kısaltmakta ve daha genellenebilir sonuçlar verebilmektedir.

Türkiye'deki yapay sinir ağları çalışmaları genelde finansal başarısızlık ve iflasların tahmini için kullanılmıştır. Yurtdışında borsa endeksi tahmini konusunda çalışmalar olduğu halde Türkiye'de bu tip çalışmaların eksikliği görülmektedir. Bu makaleye konu olan çalışma ile amaçlanan ileri beslemeli yapay sinir ağları yaklaşımı ile İMKB endeksinin tahmin edilebileceğinin gösterilmesidir.

Türkiye Cumhuriyet Merkez Bankası ve diğer borsaların İnternet sitelerinden elde edilen 2 Temmuz 2001 ile 13 Temmuz 2006 tarihleri arasındaki veriler kullanılarak yapılan testler sonucunda İMKB endeks değerinin ileri beslemeli yapay sinir ağları ile de başarılı bir şekilde modellenebileceği görülmüştür.

Anahtar Sözcükler: Yapay sinir ağları, Borsa endeksi tahmini, Türkiye

STOCK MARKET INDEX PREDICTION WITH ARTIFICIAL NEURAL NETWORKS

ABSTRACT

Currently, artificial neural networks are applied to many finance problems such as stock market index prediction, bankruptcy prediction or bond classification. Studies were performed for the prediction of stock index values as well as daily direction of change in the index. In some applications it has been specified that artificial neural networks have limitations for learning the data patterns or that they may perform inconsistently and unpredictable because of the complex financial data used. Continuous data and large scale of records require the removal of unnecessary properties which decreases the data volume, algorithm runtime and help to achieve more general results.

In Turkey artificial neural networks are mostly used in predicting financial failures. There has been no specific research for prediction of Turkish stock market

values. The aim of this paper is to use artificial neural networks to predict Istanbul Stock Exchange (ISE) market index value.

The tests are performed using the data gathered for the period of July 2, 2001 through July 13, 2006 from the websites of Central Bank of Republic of Turkey and foreign stock markets. The results have shown that feed forward artificial neural networks can also be used to model ISE market index value successfully.

Key Words: Artificial neural networks, Stock market index prediction, Turkey

GİRİŞ

Hisse senedi getirilerinin tahmin edilebilirliği konusu, hisse senedi fiyat davranışlarını tam olarak belirleyebilecek herhangi bir yöntem bulunamadığından dolayı, finans çevrelerinde en çok araştırılan konu olarak karşımıza çıkmaktadır. Hisse senedi fiyat davranışlarının tahminini zorlaştıran yüksek belirsizlik ve oynaklık (volatilité) nedeni ile, hisse senedi yatırımları diğer tüm yatırım alanlarından daha fazla risk taşır.

Pratikte geniş uygulama alanı bulan teknik analiz, hisse senetlerinin gelecekte oluşacak fiyatı ile ilgili bilginin hisse senetlerinin geçmiş fiyatında saklı olması ilkesine dayanır (Murphy 1999, Kirkpatrick II ve Dahlgvist 2007). Teknik analiz yaklaşımı hisselerin geçmiş fiyat ve hacim gibi bilgilerine dayanarak bir takım göstergeler geliştirmiş ve bu göstergeleri kullanarak alım ve satım için çeşitli kurallar ortaya koymuştur. Brock ve arkadaşları'nın (1992) öncülüğünde başlayan akademik çalışmalar hareketli ortalamalar ve diğer teknik analiz göstergelerine dayanarak oluşturulan al-sat kurallarının etkinliğini kanıtlamıştır (Kwon ve Kish 2001, Gençay 1998, Gunasekarage ve Power 2001).

Geliştirilen geleneksel yöntemler hisse senedi fiyatlarının doğrusal olmayan ve karmaşık davranışları nedeni ile kısmen başarılı olmuşlardır. Yapay sinir ağları yaklaşımı, hisse senedi fiyat davranışlarının tahmininde göreceli olarak yeni, faal ve umut veren bir alandır. Günümüzde yapay sinir ağları popüler olarak borsa endeks tahmini, iflas tahmini ya da

şirket bono sınıflaması gibi bir çok finans problemine uygulanmaktadır.

İnsan beyninin öğrenme kapasitesini taklit eden bir mimariye sahip olan yapay sinir ağları modeli bilgisayar üzerine kurulmuştur. Yapay sinir ağının işleme elemanları insan beyninin iç işlevlerini yerine getiren nöronların biyolojik yapısına benzer. Birbirine bağlı bir çok temel doğrusal ya da doğrusal olmayan eleman çoklu katmanlarda paralel olarak işlem yaparlar. Bazı çalışmalarda yapay sinir ağlarının veri desenlerini öğrenmede kısıtlamaları olduğu belirtilmektedir. Yapay sinir ağları seçkin öğrenme yeteneğini sunmakla birlikte karmaşık veri nedeni ile tutarlı olmayan ve tahmin edilemeyen bir performans gösterebilmektedir (Gallant, 1993). Buna ek olarak veri bazen o kadar hacimli olmaktadır ki öğrenme desenleri oluşmayabilmektedir. Sürekli veri ve büyük çaptaki kayıtların varlığı nedeni ile gereksiz özelliklerin ayıklanması ve verinin boyutlarının azaltılması algoritmanın işlem süresini kısaltmakta ve daha genellenebilir sonuçlar verebilmektedir (Dash ve Liu, 1997).

Yapay sinir ağları ile hisse senedi endeksi tahmini çalışmaları yaklaşık 18 yıldır yapılmaktadır. Gerçekleştirilen ilk çalışmalardan biri Kimoto ve arkadaşlarının (1990) Tokyo borsa endeksi üzerinde yaptıkları çalışmadır. Daha sonra Kamijo ve Tanikawa (1990) yineleyen sinir ağlarını, Ahmadi (1990) ise geri-yayılım (backpropagation) ağını kullanmıştır. Yoon ve Swales (1991) hem kantitatif hem de kalitatif verilerle çalışmışlardır. Choi ve

arkadaşları (1995) S&P 500 endeksinin günlük yön değişimini tahmin etmişlerdir. Kohara ve arkadaşları (1997) ise öğrenmeyi daha iyiye götürmek için ön bilgiyi de sisteme girdi olarak sunmuşlardır. Mizuno ve arkadaşları (1998) ise yine yapay sinir ağlarını kullanarak Tokyo borsasının al ve sat sinyallerini %63 doğruluk ile tahmin etmişlerdir.

Tahmin doğruluğunun çok iyi olmaması verinin karmaşık olmasına, ve kullanılan algoritmaların yerel yakınsamalarına bağlanmıştır. Sexton ve arkadaşları (1998) momentum (hız faktörü) kullanımının, eğitim sürecinin rasgele noktalarda yeniden başlatılmasının, ve ağ yapısının yeniden yapılanmasının sorunları çözebileceğini önermişlerdir. İzlenecek yönü ağırlık vektörü için global arama algoritmalarının kullanımı olarak belirtmektedirler.

Bambang ve arkadaşları (2000) Endonezya borsası hisse senetleri için ileri beslemeli (feed forward) ağ ve geri dağılım (back propagation) algoritmasını 4 aylık veri üzerinde kullanmışlardır. Girdi olarak kapanış fiyatı, borsa endeksi, hacim, en yüksek ve en düşük fiyatlar kullanılmıştır. Phua ve arkadaşları (2000) ise yapay sinir ağları ile genetik algoritmayı birlikte Singapur borsası üzerinde kullanmış ve borsa yönünü %81 doğruluk ile tahmin etmişlerdir.

Türkiye’de yapay sinir ağları öncelikle finansal başarısızlığın öngörülmesinde kullanılmıştır (Yıldız, 2001). Son yıllarda hisse senedi endeks yönü tahmini konusunda yapay sinir ağlarının doğrusal ve mantıksal regresyon modellerinden


daha başarılı olduğu belirlenmiştir (Diler, 2003; Altay ve Satman 2005; Şenol ve Özturan, 2008). Yurtdışında borsa endeksi tahmini konusunda çalışmalar olduğu halde Türkiye’de bu tip çalışmaların azlığı görülmektedir. Yumlu ve arkadaşları (2004) 12 yıllık finansal veri (ISE endeksi kapanış değeri kümesi, Amerikan Doları değeri, faiz değerleri) üzerinde yaptıkları araştırma ile yapay sinir ağları modelinin otoregresif modellerden daha iyi performans gösterdiği sonucuna ulaşmışlardır.

Bu makaleye konu olan çalışma ile amaçlanan ileri beslemeli yapay sinir ağları yaklaşımı ile İMKB endeksinin tahmin edilebileceğinin gösterilmesidir.

1. YAPAY SİNİR AĞI YAKLAŞIMI


Deneyimlerden öğrenme prensibi üzerine kurulan yapay öğrenme yaklaşımı yapay zeka çalışmaları için önemli olmuştur. Bu yaklaşım için, yapay sinir ağları gibi, ağı performansını artırmak üzere bağlantı ağırlıklarının kullanıldığı, modeller çok uygundur. Bir yapay sinir ağı nöron adı verilen bir çok işlem biriminden oluşur. Genelde nöronlar katman denilen mantıksal gruplar içinde yer alır. Ağ 3 ya da daha çok katmandan oluşan hiyerarşik bir yapıya sahiptir. Bu ağda 1 girdi, 1 veya daha çok gizli ve 1 çıktı katmanı bulunmaktadır (Şekil 1).

Şekil 1: 1-Girdi, 2-Gizli ve 1-Çıktı Katmanından Oluşan Yapay Sinir Ağı



Girdi katmanında ağa girdi desenlerini veren girdi kümesi yer alır. Girdi katmanı ile sinyalin elde edildiği çıktı katmanı arasında 1 ya da daha çok gizli ara katman vardır. Bir katmandaki her nöron, bir üst katmandaki tüm nöronlara değişik sayısal ağırlıklarla ($w_{i,j}$) bağlıdır (Şekil 2). Ağırlıklar, öncül katmandaki nöronun (u_j), üst katmandaki nöron (u_i) üzerindeki etkisini belirtir. Pozitif ağırlık değerleri pekiştirme, negatif değerler ise engel olma durumunu belirtir (Gallant, 1993).

Şekil 2: Nöronlar arası bağlantı



Ağ üzerindeki her birim alt düzeyden gelen girdi değerini alır ve ağırlıklı toplamları hesaplar. Girdi verileri bağlantı ağırlıkları ile çarpılarak ağ üzerinde ilerler. Ağırlıklar başlangıçta rasgele olarak belirlenir, böylece sistemin başlangıç noktasında kilitlenmemesi sağlanır (Baxter, 2001). Çarpım sonuçları ilk gizli katmanda toplanır. Sonuç bir transfer fonksiyonundan geçirilir, 0 ile 1 arasında değişen örneksel çıktı elde etmek için doğrusal sigmoid fonksiyonu kullanılabilir (Deboeck, 1994). Sinyaller gizli katmanlar arasında ve çıktı katmanına aynı şekilde iletilir.

Teorik olarak herhangi bir tahmin fonksiyonu 1 gizli katman ile çözülebilir ancak 2 katman

kullanılırsa çözüme daha kolay ulaşılabilir (Partovi ve Anandrajan, 2002; Carsten ve Thorstein, 1993). Gizli katmandaki nöron sayısı ise genelde deneme ve yanılma yöntemi ile belirlenmektedir (Nehdi, Djebbar ve Khan, 2001b). Yapılan ilk çalışma sonuçlarına göre bu çalışmada tek gizli katman ve bu gizli katman için Neurosolutions yazılımının varsayılan nöron sayısı kullanılmıştır (Egeli et al., 2003).

Bağlantıların girdiden çıktıya doğru tek yönlü olarak geliştiği ağlara ileri beslemeli ağlar denir (Rosenblatt, 1961). Çok katmanlı algı (MLP-Multi Layered Perceptron) ağları ise statik geri dağılım ile eğitilen katmanlı ileri beslemeli ağlardır. Bu ağlar özellikle desen sınıflandırmasını gerektiren uygulamalar için kullanılır. Geri dağılım kullanılırken ağ her girdi deseni ile hedef çıktıyı karşılaştırarak öğrenir, hatayı hesaplar ve bir hata fonksiyonunu ağ üzerinde geriye doğru (çıktıdan girdiye) çalıştırır. Bu tip ağların en önemli avantajı kolay kullanım ve girdi/çıkıtı haritası için yakınsamadır. En önemli dezavantajı ise yavaş öğrenmesi ve öğrenme süreci için çok fazla veri talep etmesidir.

Genel ileri beslemeli (GFF-Generalized Feed Forward) ağlar ise ileri beslemeli ağların genelleştirilmiş halidir. Bu ağlarda bağlantılar bir ya da daha çok katman üzerinden atlama yapılabilir ancak problemin etkin çözümünü sağladığı için tercih edilir (Rumelhart ve diğerleri, 1986). Bu çalışmada da genel leri beslemeli ağ kullanılmıştır.

Öğrenme, ağın serbest parametrelerinin (ağırlık değerleri)

optimal değerlerini bulması işlemidir. MLP ve GFF ağlarında kullanılan denetimli öğrenme modelleri belirli girdi örüntülerine karşılık gelecek çıktı için öğrenmeyi sağlar ve sonucunda ağırlık değerlerindeki değişiklikler aynı düğümlerin daha genel örüntü sınıflarına karşılık olmasını sağlar. Bu modellerde girdi katmanı girdileri ağ üzerinde dağıtır. Bağlantı ağırlık değerleri ile sinyaller değiştirilir. Gizli katmanlar ve çıktı katmanı bir aktivasyon fonksiyonlu işleme elemanları vektörüne sahiptir. Genelde aktivasyon fonksiyonu olarak doğrusal Sigmoid fonksiyonu kullanılır (Bambang et al., 2002). Bu çalışmada da doğrusal Sigmoid fonksiyonu kullanılmıştır.

Girdi birimleri dışındaki her u_i birimi, yeni aktivasyon birimini (u_i), kendisine doğrudan bağlı girdilerin ağırlıklı toplam fonksiyonu olarak hesaplar. Böylece, her işlem biriminin ileriye doğru çıktısı aşağıdaki gibi tanımlanır:

$$S_i = \sum_{j=0}^n w_{i,j} * u_j \quad (1)$$

$$u_i = f(S_i) \text{ öyle ki } f(x) = \frac{1}{1+e^{-x}} \quad (2)$$

Geriye doğru hareket ise hatanın geriye doğru yayılımı ve ağırlık değerlerinin ayarlanmasıdır. Sabit bir adım uzunluğu ile iniş eğilimi (Gradient descent) yöntemi, öğrenme hızı da denir, ağın öğretilmesi için kullanılır ve en fazla 0,1 olması önerilir (Gallant, 1993). Bu çalışmada da öğrenme hızı 0,1 olarak belirlenmiştir. Geri dönüş işlemi her işleme biriminin çıktısı aşağıdaki gibidir:

$$f'(S_i) = u_i * (1 - u_i) \quad (3)$$

Daha sonra ağırlık değerleri aşağıdaki formül ile hesaplanır (ε hata kareleri ortalaması, ρ adım uzunluğu):

$$\delta_i = - \left(\frac{\partial \varepsilon}{\partial S_i} \right) \quad (4)$$

$$w_{i,j}^* = w_{i,j} + \rho \delta_i u_j \quad (5)$$

Öğrenme süreci; a) en küçük kareler yöntemi ile hesaplanan hatanın kabul edilebilir düzeydeki bir seviyeye inmesi, b) önceden belirlenmiş bir yinleme sayısı, c) hatanın artmaya başlaması koşullarından herhangi biri gerçekleşinceye kadar devam eder (Yeh, 1999; Lai ve Serra, 1997; Nehdi, El Chabib ve El Naggar, 2001a; Gallant, 1993; Baxter, 2001; Teh, Wong, Goh ve Jaritngam, 1997).

Hata çok boyutludur ve bir çok lokal minima değerini içerebilir. Adım uzunluğu çok büyük olduğunda da algoritma kararsız olabilir ve yakınsamayabilir. Bu nedenle, bir lokal minimada takılmayı engellemek ve yavaş yakınsamayı önlemek için sisteme 0,1 ile 1 arasında değişen hız faktörü eklenir. Hız faktörü için en çok kullanılan değer 0,5'dir (Yeh, 1998; Yeh, 1999).

Öğrenme süreci tamamlandığında ağırlık değerleri belirlenmiş olan ağ öğrenme işlemi için kullanılan veri dışında kalan veri kümesi üzerinde test edilir. Böylece ağı öğrenme kümesi verisine büyük ölçüde benzeyen örüntüler için doğru yanıtlar üreteceğinin geçerliliği sağlanır. Genelme yapılmak istendiğinde ağ yeterli büyüklükteki

giriş veri kümesi ile eğitilmelidir (Nagendra, 1998). Öğrenme kümesinin test kümesine oranı değişik çalışmalarda 9:1 ile 5:5 arasında değişmektedir (Yeh, 1998; Yeh, 1999; Kasperkiewicz, Raez, Dubrawski, 1995; Baxter, 2001; Carsten ve Thorstein, 1993; Nehdi ve diğerleri, 2001b). Bu çalışmada 9:1 oranı kullanılmaktadır. Algoritmanın performansını iyileştirmek amacı ile ağ üzerinde birden fazla öğrenme ve test işlemi gerçekleştirilmelidir (Tanner, 2005). Bu nedenle çalışma kapsamında 10 adet öğrenme ve 10 adet test işlemi gerçekleştirilecektir.

Öğretilen ağı doğruluk oranı karar verme katsayısı R^2 (Belirlilik Katsayısı) ile ölçülür. Bağımsız değişkenlerin ölçülen bağımlı değişkenler üzerindeki etkisini ölçen R^2 değerinin yüksek olması tahmin ilişkisinin iyi olduğunu gösterir.

2. YÖNTEM

2.1 Borsa Endeks Değeri Tahmini Sistem Modelleri

Bu çalışma ile amaçlanan ileri beslemeli yapay sinir ağlarının bir gün sonraki İMKB endeksinin tahmini için etkin olarak kullanılabileceğini göstermektir. Çalışmada denetimli öğrenme modelleri kullanılmıştır.

Borsa endeksi tahminlemesinde bir önceki günün endeks değerinin yanında Amerikan Doları kuru ve gecelik faiz oranı gibi ekonomik değişkenler de önemlidir. Haftanın günleri ve dış borsaların da etkili olabileceği düşünülmektedir. Bu çalışmada kullanılan girdi değişkenleri şunlardır:

- Önceki günün endeks değeri (ÖE)
- Önceki günün Amerikan Doları değeri (ÖUSD)
- Önceki günün gecelik faiz değeri (ÖON)
- Haftanın günlerini belirten 5 kukla değişken (P, S, Ç, PE, C): Değişken değerleri 1 ya da 0 olarak alınmıştır. Örnek olarak Pazartesi günü için P değeri 1 ve S, Ç, PE, C değerleri ise 0 olarak kullanılmıştır.
- Önceki günün Fransa (F), Almanya (A), İngiltere (İ),

NASDAQ (N), DOW JONES (DJ), S&P500 (SP), Brezilya (B) ve Japonya (J) borsa endeks değerleri

Yumlu ve arkadaşlarının (2004) çalışmasında kullanılan önceki günün borsa endeks, Amerikan Doları ve gecelik faiz değerleri değişken olarak alınmıştır. Ek olarak bu çalışmaya haftanın günlerini belirten 5 kukla değer ile çeşitli yabancı ülkelere ait 8 adet borsa endeks değerleri değişken olarak eklenmiştir.

Bu değişkenler kullanılarak 3 değişik model (M1, M2, M3) tanımlanmıştır

Model 1, M1 : = f_{Model1} (ÖE, ÖUSD, ÖON)

Model 2, M2 : = f_{Model2} (ÖE, ÖUSD, ÖON, P, S, Ç, PE, C)

Model 3, M3 : = f_{Model3} (ÖE, ÖUSD, ÖON, P, S, Ç, PE, C, F, A, İ, N, DJ, SP, B, J)

2.2 Veri Kümesi

Veri olarak öncelikle Türkiye Cumhuriyet Merkez Bankası ve diğer borsaların İnternet sitelerinden 2.7.2001 ile 13.7.2006 tarihleri arasındaki toplam 1270 işgününe ait değerler alınmıştır.

Öğrenme kümesinin test kümesine oranı 9:1 olarak belirlenmiştir. Böylece ilk 1143 günlük veri öğrenme, son 127 günlük veri ise test örnekleri olarak alınmıştır. Kullanılan Neuro Solutions* yazılımının kendi iç normalizasyonu olduğu için veriler her hangi bir normalizasyondan geçirilmemiştir. Test, 3 model üzerinde de gerçekleştirilmiştir. Test

verilerinin tahmini endeks değerleri ile gerçek endeks değerleri karşılaştırılarak elde edilen sonuçlar R^2 ile değerlendirilmiştir.

2.3 Ağ Parametreleri

Modeller için ileri beslemeli yapay sinir ağı tek gizli katman ile uygulanmıştır. Gizli katmandaki nöron sayısı için Neuro Solutions yazılımındaki varsayılan değer kullanılmıştır. Kullanılan ağ parametreleri şunlardır:

- Hız faktörü: 0,5
- Durma kriteri: En küçük kareler yöntemiyle bulunan hata = 0,005
- Başlangıç ağırlıkları: Rasgele
- Öğrenme hızı: 0,1

* NeuroSolutions (www.neurosolutions.com) yazılımı 03N301 no'lu Boğaziçi Üniversitesi Bilimsel Araştırma Projesi kapsamında satın alınmıştır.

- Aktivasyon fonksiyonu:
Doğrusal Sigmoid

2.4 Test Sonuçları

Bu çalışmada 3 model Neuro Solutions yazılımı ile test edilmiştir. Modellerin performansı test veri kümesinin R^2 değeri ile ölçülmüştür.

Başlangıç ağırlık değerlerinin rasgele olması nedeni ile her bir model için 10 adet öğrenme ve bunlara karşılık gelen 10 adet test yapılmıştır. Bu testlerin R^2 değerleri ve bu değerlerin her model için ortalamaları Tablo 1'de verilmektedir.


Tablo 1: YSA Belirlilik Katsayısı (R^2) Değerleri

Model	R^2										Ort.
	1	2	3	4	5	6	7	8	9	10	
M1	0,96	0,69	0,92	0,90	0,96	0,96	0,95	0,96	0,95	0,96	0,92
M2	0,95	0,85	0,94	0,60	0,94	0,79	0,89	0,90	0,94	0,94	0,87
M3	0,86	0,85	0,93	0,75	0,72	0,86	0,89	0,94	0,88	0,46	0,81

Tablo 1'den de görüleceği gibi en iyi sonucu 0,96 ile M1 modeli vermektedir. Önceki günün borsa endeksi, Amerikan Doları ve gecelik

faiz değerlerini girdi olarak alan M1 modeline ait test periyodu gerçek ve tahmin değerleri grafiği ise Şekil 3'de görülmektedir.

Şekil 3: Model 1'e ait Test Periyodu Gerçek ve Tahmin Değerleri Grafiği



2.5 Hareketli Ortalama Yöntemi ile Kıyaslama

Yapay sinir ağları modelinin performansı basit hareketli ortalamalar yöntemi ile kıyaslanmıştır. Bu kıyaslamada basit hareketli

ortalamalar yöntemi referans olarak kabul edilmiştir. Hareketli ortalama yöntemi, borsadaki fiyat hareketlerinin yakın geçmişteki fiyatların aritmetik ortalaması ile tahmin edilebileceği ilkesine

dayanmaktadır. Buna göre, q günlük hareketli ortalama ($HO(q)$) formülü aşığıdaki şekilde hesaplanmaktadır:

$$HO(q) = (\sum_{t=0}^q p_t) / (q+1) \quad (6)$$

Bu formülde p_t , t zamanındaki fiyatı göstermektedir. Hareketli ortalamalara dayanarak yapılacak bir yön tahmini için $n > m$ olduğunda, $HO(m) > HO(n)$ ise yön yukarıya doğru, değil ise yön aşığıya doğrudur (Deboeck, 1994). Bu çalışmada m değeri 10, n değeri ise 40 olarak alınmıştır.

Yapay Sinir Ağları (ANN) yöntemini kullanan M1 modelinin yön tahmini ile hareketli ortalamalar kuralına göre elde edilen tahmin değerlerinin test kümesi üzerindeki doğruluk oranları Tablo 2’de gösterilmiştir.

Tablo 2: Yön Tahminlerinin Karşılaştırılması

	Doğru	Yanlış	Doğruluk oranı
ANN (M1)	70	57	%55,1
HO Kuralı	64	63	%50,4

Tablo 2’deki her iki yöntemin endeksin fiyat hareketinin yönünü doğru tahmin etme oranları karşılaştırıldığında yapay sinir ağlarının basit hareketli ortalama yöntemine göre biraz daha iyi sonuç verdiği görülmektedir. %55,1’lik doğruluk oranı, Altay ve Satman’ın (2005) İMKB’de elde ettikleri %57,8 lik doğruluk oranına yakındır. İki oran arasındaki %2,7’lik fark kullanılan veri kümesine ait dönemlerin farklılığı ile açıklanabilir.

SONUÇ

Bu çalışmada İstanbul Borsası 100 Endeksi tahmini için ileri beslemeli

yapay sinir ağlarına dayalı bir model geliştirmek amaçlanmıştır.

Elde edilen bulgular ışığında aşığıdakiler söylenebilir:

- Bir önceki günün endeks, Amerikan Doları ve gecelik faiz değerlerinin değişken olarak kullanıldığı M1 modelinde belirlenen dönem için en yüksek R^2 değerine ulaşılmıştır.
- Sonuç R^2 değerleri İMKB endeks değerinin ileri beslemeli yapay sinir ağları ile de başarılı bir şekilde modellenebileceğini göstermiştir.
- Haftanın günlerinin endeks tahmini üzerindeki etkisinin belirgin olmadığı düşünülmektedir.
- Dış borsaların endeks tahmini üzerinde olumlu bir etkisi görülmemiştir.
- Endeksin yönünü tahmin etmekte yapay sinir ağları basit hareketli ortalamalar yöntemine göre biraz daha iyi performans göstermiştir.

Bu sonuçlara göre yapay sinir ağlarının kullanımının ümit verici olduğu gözlenmiştir. Bu çalışmanın kısıtı sadece belirli bir dönem içinde bu çalışmanın yapılmış olmasıdır, bu çalışmanın diğer dönemler ve diğer borsalar için de uygulanması iyi olacaktır. Ayrıca hareketli ortalamalar dışında lojistik, doğrusal ve doğrusal olmayan regresyon modelleri ile de kıyaslanması önerilmektedir.

TEŞEKKÜR

Yazarlar, 03N301 no’lu projeye verdiği destek için Boğaziçi Üniversitesi Bilimsel Araştırma

Projeleri Koordinatörlüğü'ne teşekkür etmektedirler.

KAYNAKÇA

AHMADI, H., 1990, "Testability of the Arbitrage Pricing Theory by Neural Networks", *Proceedings of the International Conference on Neural Networks*, s:385-393.

ALTAY, E., SATMAN, M. H., 2005, "Stock Market Forecasting: Artificial Neural Networks and Linear Regression Comparison in an Emerging Market", *Journal of Financial Management and Analysis*, Vol:18, No:2, s:18-33.

BAMBANG, B., WIDODO, R.J., SUTALAKSANA, I.Z., SINGGİH, M., 2002, "Indonesia Stock Market Prediction (SMGR/GGRM), Using Time Series Neural Networks", *Proceedings of the Sixth AEESEAP Triennial Conference*, Kuta, Bali, Indonesia, August 23 – 25.

BAXTER, C.W., 2001, "Modelling Heuristics from Literature", *CIV E 729 Course Notes*, Dept. of Civil and Environmental Engineering, University of Alberta, Edmonton, Canada, www.civil.ualberta.ca/courses/cive729/lectures/lecture5.ppt, retrieved on 2004.

BROCK, W., LAKONISHOC, J., LE BARON, B., 1992, "Simple Technical Trading Rules and the Stochastic Properties of the Stock Returns", *The Journal of Finance*, Vol:XLVII, No:5, s:1731-1764.

CARSTEN, P., THORSTEIN R., 1993, "Jetnet 3.0: A Versatile Artificial Neural Network Package", www.thep.lu.se/pub/Preprints/93/lu-

tp-93-29.ps.gz, retrieved on 2004, Sweden.

CHOI, J. H., LEE M. K., RHEE, M. W., 1995, "Trading S&P 500 Stock Index Futures Using a Neural Network", *The Proceedings of the Third Annual International Conference on Artificial Intelligence Applications on Wall Street*, R. S. Freedman, ed., s:63-72.

DASH, M., LIU, H., 1997, "Feature Selection Methods for Classifications", *Intelligent Data Analysis: An International Journal*, Vol:1, No:3, s:131-156.

DEBOECK, G. J., 1994, *Trading on the Edge*, John Wiley & Sons Inc., New York.

DİLER, A. İ., 2003, "İMKB Ulusal 100 Endeksinin Yönünün Yapay Sinir Ağları: Hata Geriye Yayıma Yöntemi ile Tahmin Edilmesi", *İMKB Dergisi*, No:7, s:65-81.

EGELİ, B., ÖZTURAN, M., & BADUR, B., 2003, *Stock Market Prediction Using Artificial Neural Networks*, *Proceedings of the 3rd Hawaii International Conference on Business, Hawaii, USA*.

GALLANT, S.I., 1993, *Neural Network Learning and Expert Systems*, MIT Press, Cambridge.

GENÇAY, R., 1998, "The Predictability of Security Returns with Simple Technical Trading Rules", *Journal of Empirical Finance*, Vol:5, s:347-359.

GUNASEKARAGE, A, POWER, D. M. 2001, "The Profitability of Moving Average Trading Rules in South Asian Stock Markets", *Emerging Markets Review*, Vol:2, s:17-33.

- KAMIJO, K., TANIGAWA, T., 1990, "Stock Price Pattern Recognition: A Recurrent Neural Network Approach", *Proceedings of the International Joint Conference on Neural Networks*, s:215-221.
- KASPERKIEWICZ, J., RAEZ, J., DUBRAWski, A., 1995, "HPC Strength Prediction Using Artificial Neural Network", *Journal of Computing in Civil Engineering*, Vol:9, No:4, s:279-284.
- KIMOTO, T., ASAKAWA, K., YODA, M., TAKEOKA, M., 1990, "Stock Market Prediction System with Modular Neural Network", *Proceedings of the International Joint Conference on Neural Networks*, s:1-6.
- KIRKPATRICK II, DAHLQUIST, J. R., 2007, **Technical Analysis : The Complete Resource for Financial Market Technicians**, Imprint Upper Saddle River, N.J. : FT Press Financial Times.
- KOHARA, K., ISHIKAWA, T., FUKUHARA, Y., NAKAMURA, Y., 1997, "Stock Price Prediction Using Prior Knowledge and Neural Networks", *International Journal of Intelligent Systems in Accounting, Finance and Management*, Vol:6, No:1, s:11-22.
- KWON, K., KISH, R. J., 2001, "A Comparative Study of Technical Trading Strategies and Return Predictability: An Extension of Brock, Lakonishok, LeBaron (1992) Using NYSE and NASDAQ Indices", *The Quarterly Review of Economics and Finance*, Vol:42, s:611-631.
- LAI, S., SERRA, M., 1997, "Concrete Strength Prediction by Means of Neural Network", *Construction and Building Materials*, Vol:11, No:2, s:93-98.
- MIZUNO, H., KOSAKA, M., YAJIMA, H., KOMODA N., 1998, "Application of Neural Network to Technical Analysis of Stock Market Prediction", *Studies in Informatic and Control*, Vol:7, No:3, s:111-120.
- MURPHY, J.J, 1999, **Technical Analysis of the Financial Markets: A Comprehensive Guide to Trading Methods and Applications**, Imprint New York: New York Institute of Finance..
- NAGENDRA, S., 1998, "Practical Aspects of Using Neural Networks: Necessary Preliminary Specifications", *GE Research and Development Center Technical Paper*.
- NEHDI, M., EL CHABIB, H., EL NAGGAR, H., 2001a, "Predicting Performance of Self-Compacting Concrete Mixtures Using Artificial Neural Networks", *ACI Materials Journal*, Vol:98, No:5, s:394-401.
- NEHDI, M., DJEBBAR, Y., KHAN, A., 2001b, "Neural Network Model for Preformed-Foam Cellular Concrete", *ACI Materials Journal*, Vol:98, No:5, s:402-410.
- PARTOVI, F.Y., ANANDRAJAN, M., 2002, "Classifying Inventory Using an Artificial Neural Network Approach", *Computers and Industrial Engineering*, Vol:41, s:389-404.
- PHUA, P.K.H., MING, D., LIN, W., 2000, "Neural Network With Genetic

Algorithms For Stocks Prediction”, **Fifth Conference of the Association of Asian-Pacific Operations Research Societies Proceedings**, 5th - 7th July, Singapore.

ROSENBLATT, F., 1961, **Principles of Neurodynamics: Perceptrons and the Theory of Brain Mechanisms**, Spartan Press, Washington DC.

RUMELHART, D.E., HINTON, G.E., WILLIAMS, R.J., 1986, “*Learning Internal Representations by Error Propagation*”, **Parallel Distributed Processing: Explorations in the Microstructures of Cognition**, Rumelhart DE., McClelland, J.L. (eds.), Vol:1, s:318-362. MIT Press, Cambridge.

SEXTON, R. S., DORSEY, R. E., JOHNSON, J. D., 1998, “*Toward Global Optimization of Neural Networks: A Comparison of the Genetic Algorithm and Backpropagation*”, **Decision Support Systems**, Vol:2, s:171-185.

ŞENOL, D., ÖZTURAN, M., 2008, “*Stock Price Direction Prediction Using Artificial Neural Network Approach: The Case of Turkey*”, **Journal of Artificial Intelligence**, Vol:1, No:2.

TANNER, C., 2005, “*Accelerating Artificial Neural Network Learning via Weight Predictions*”, www.cs.ucla.edu/~ctanner/papers/01_Accelerating_NN_Learning_04_2005.pdf, retrieved on 2009.

TEH, C. I., WONG, K. S., GOH, A. T. C., JARITNGAM, S., 1997, “*Prediction of Pile Capacity Using Neural Networks*”, **Journal of**

Computing in Civil Engineering, Vol:11, No:2, s:129-138.

YEH, I.C., 1998, “*Modeling of Strength of High-Performance Concrete Using Artificial Neural Networks*”, **Cement and Concrete Research**, Vol:28, No:12, s:1797-1808.

YEH, I.C., 1999, “*Design of High-Performance Concrete Mixture Using Neural Networks and Nonlinear Programming*”, **Journal of Computing in Civil Engineering**, Vol:13, No:1, s:36-42.

YILDIZ, B., 2001, “*Finansal Başarısızlığın Öngörülmesinde Yapay Sinir Ağı Kullanımı ve Halka Açık Şirketlerde Ampirik Bir Uygulama*”, **İMKB Dergisi**, Vol:5, No:17.

YOON, Y., SWALES, G., 1991, “*Predicting Stock Price Performance: A Neural Network Approach*”, **Proceedings of the 24th Annual Hawaii International Conference on System Sciences**, s:156-162.

YUMLU, S., GÜRGEN, F., OKAY, N., 2004, “*A Comparison of Global, Recurrent and Smoothed-Piecewise Neural Models for Istanbul Stock Exchange Prediction*”, **Pattern Recognition Letters**, Vol:26, s:2903-2103.

EK: Test Periyodu Değerleri

	100 Endeks Bugün	100 Endeks Yarın	100 Endeks YSA	n=40 ORT.	m=10 ORT.	YSA	HO	GERÇEK
1	44076,91	42622,90	44124,57	38673,85	41639,60	1	1	0
2	42622,90	43645,23	42879,05	38861,24	41918,16	1	1	1
3	43645,23	44465,68	43752,57	39069,51	42304,91	1	1	1
4	44465,68	43851,42	44459,59	39289,78	42772,41	0	1	0
5	43851,42	44434,54	43930,26	39504,71	43091,01	1	1	1
6	44434,54	45746,17	44432,76	39711,09	43398,22	0	1	1
7	45746,17	45784,09	45563,06	39932,05	43800,59	0	1	1
8	45784,09	45315,15	45595,73	40157,66	44188,46	0	1	0
9	45315,15	44891,25	45191,62	40375,00	44357,09	0	1	0
10	44891,25	44590,22	44826,33	40559,90	44483,33	0	1	0
11	44590,22	45250,66	44566,92	40722,44	44534,67	0	1	1
12	45250,66	44841,03	45136,05	40896,28	44797,44	0	1	0
13	44841,03	44228,02	44783,05	41052,97	44917,02	0	1	0
14	44228,02	44855,61	44254,79	41180,40	44893,26	1	1	1
15	44855,61	44652,96	44795,62	41328,84	44993,67	0	1	0
16	44652,96	43842,68	44620,98	41484,13	45015,52	0	1	0
17	43842,68	44117,47	43922,72	41615,50	44825,17	1	1	1
18	44117,47	44772,93	44159,52	41781,03	44658,51	1	1	1
19	44772,93	44046,29	44724,37	41945,30	44604,28	0	1	0
20	44046,29	43507,51	44098,18	42102,92	44519,79	1	1	0
21	43507,51	43803,98	43633,89	42243,84	44411,52	1	1	1
22	43803,98	45361,34	43889,37	42398,15	44266,85	1	1	1
23	45361,34	46244,32	45231,43	42589,27	44318,88	0	1	1
24	46244,32	46689,01	45992,34	42796,37	44520,51	0	1	1
25	46689,01	46710,93	46119,72	43020,36	44703,85	0	1	1
26	46710,93	46265,39	46119,72	43232,88	44909,65	0	1	0
27	46265,39	46553,57	46010,49	43430,68	45151,92	0	1	1
28	46553,57	46838,10	46119,72	43621,54	45395,53	0	1	1
29	46838,10	47728,50	46119,72	43814,01	45602,04	0	1	1
30	47728,50	47015,88	46119,72	44031,83	45970,27	0	1	0
31	47015,88	47492,97	46119,72	44226,72	46321,10	0	1	1
32	47492,97	46890,80	46119,72	44418,11	46690,00	0	1	0
33	46890,80	46366,23	46119,72	44595,94	46842,95	0	1	0
34	46366,23	45997,07	46097,39	44760,33	46855,14	0	1	0
35	45997,07	43889,75	45779,27	44893,62	46785,94	0	1	0
36	43889,75	42340,43	43963,29	44956,80	46503,83	1	1	0
37	42340,43	42863,37	42608,20	44972,25	46111,33	1	1	1
38	42863,37	42521,94	43081,47	44996,20	45742,31	1	1	0
39	42521,94	44345,95	42782,25	44968,53	45310,69	1	1	1
40	44345,95	42906,72	44356,42	44986,46	44972,44	1	0	0
41	42906,72	43236,71	43117,02	44957,20	44561,52	1	0	1
42	43236,71	44051,34	43400,53	44972,55	44135,90	1	0	1
43	44051,34	44688,12	44102,54	44982,70	43851,95	1	0	1

44	44688,12	44426,27	44651,28	44988,26	43684,14	0	0	0
45	44426,27	44399,44	44425,63	45002,63	43527,06	0	0	0
46	44399,44	44328,80	44402,51	45001,75	43578,03	1	0	0
47	44328,80	44531,22	44341,64	44966,32	43776,87	1	0	1
48	44531,22	43273,94	44516,07	44935,00	43943,65	0	0	0
49	43273,94	42710,46	43432,61	44883,97	44018,85	1	0	0
50	42710,46	41742,09	42956,08	44829,45	43855,30	1	0	0
51	41742,09	42507,02	42034,47	44758,25	43738,84	1	0	1
52	42507,02	42941,70	42767,94	44689,65	43665,87	1	0	1
53	42941,70	42911,32	43146,31	44642,17	43554,91	1	0	0
54	42911,32	44028,40	43120,79	44609,25	43377,23	1	0	1
55	44028,40	44070,94	44082,77	44588,57	43337,44	1	0	1
56	44070,94	44088,59	44119,43	44574,02	43304,59	1	0	1
57	44088,59	43710,59	44134,64	44580,17	43280,57	1	0	0
58	43710,59	44284,17	43808,90	44570,00	43198,51	1	0	1
59	44284,17	43099,34	44303,18	44557,78	43299,53	1	0	0
60	43099,34	42890,29	43282,15	44534,11	43338,42	1	0	0
61	42890,29	42505,02	43103,55	44518,68	43453,24	1	0	0
62	42505,02	41919,25	42766,02	44486,20	43453,04	1	0	0
63	41919,25	42212,03	42204,34	44400,15	43350,79	1	0	1
64	42212,03	41860,66	42485,08	44299,34	43280,86	1	0	0
65	41860,66	42864,85	42148,16	44178,63	43064,09	1	0	1
66	42864,85	43732,47	43082,69	44082,48	42943,48	1	0	1
67	43732,47	43872,79	43827,75	44019,16	42907,87	1	0	1
68	43872,79	45075,89	43948,67	43952,14	42924,09	1	0	1
69	45075,89	45278,39	44985,44	43908,08	43003,26	0	0	1
70	45278,39	45352,51	45159,95	43846,83	43221,16	0	0	1
71	45352,51	44745,54	45223,82	43805,25	43467,39	0	0	0
72	44745,54	43752,02	44700,76	43736,56	43691,44	0	0	0
73	43752,02	43880,43	43844,60	43658,09	43874,72	1	1	1
74	43880,43	44030,35	44040,79	43595,95	44041,56	1	1	1
75	44030,35	44413,62	44169,98	43546,78	44258,52	1	1	1
76	44413,62	44647,82	44500,26	43559,87	44413,40	1	1	1
77	44647,82	44251,44	44702,08	43617,56	44504,94	1	1	0
78	44251,44	44212,76	44360,50	43652,26	44542,80	1	1	0
79	44212,76	44712,89	44327,17	43694,53	44456,49	1	1	1
80	44712,89	44563,26	44758,16	43703,71	44399,94	1	1	0
81	44563,26	43598,99	44629,21	43745,12	44321,01	1	1	0
82	43598,99	43713,19	43798,26	43754,18	44206,36	1	1	1
83	43713,19	41970,80	43896,67	43745,72	44202,48	1	1	0
84	41970,80	40268,68	42323,96	43677,79	44011,51	1	1	0
85	40268,68	41044,06	40691,85	43573,85	43635,35	1	1	1
86	41044,06	40439,24	41435,34	43489,96	43298,39	1	0	0
87	40439,24	39643,68	40855,39	43392,73	42877,53	1	0	0
88	39643,68	36351,06	40092,55	43270,54	42416,76	1	0	0
89	36351,06	37235,49	36935,35	43097,47	41630,59	1	0	1
90	37235,49	36100,70	37783,40	42960,59	40882,85	1	0	0

91	36100,70	36730,24	36695,28	42819,56	40036,59	1	0	1
92	36730,24	38593,47	37298,93	42675,14	39349,71	1	0	1
93	38593,47	38908,60	39085,53	42566,43	38837,74	1	0	1
94	38908,60	37860,80	39387,70	42466,36	38531,52	1	0	0
95	37860,80	38132,21	38383,00	42312,17	38290,73	1	0	1
96	38132,21	38395,24	38643,24	42163,70	37999,55	1	0	1
97	38395,24	39285,80	38895,46	42021,37	37795,15	1	0	1
98	39285,80	37964,03	39749,39	41910,75	37759,36	1	0	0
99	37964,03	37464,43	38481,98	41752,75	37920,66	1	0	0
100	37464,43	36709,55	38002,93	41611,87	37943,55	1	0	0
101	36709,55	35338,66	37279,09	41457,36	38004,44	1	0	0
102	35338,66	34802,58	35473,25	41278,20	37865,28	1	0	0
103	34802,58	34330,32	34959,22	41100,28	37486,19	1	0	0
104	34330,32	32384,42	34506,38	40903,24	37028,36	1	0	0
105	32384,42	32899,74	32640,51	40666,33	36480,72	1	0	1
106	32899,74	33627,40	33134,64	40417,20	35957,48	1	0	1
107	33627,40	34048,04	33832,37	40164,58	35480,69	1	0	1
108	34048,04	34807,73	34235,71	39918,96	34956,92	1	0	1
109	34807,73	34601,40	34964,16	39662,25	34641,29	1	0	0
110	34601,40	33762,00	34766,31	39395,33	34354,98	1	0	0
111	33762,00	34228,99	33961,44	39105,57	34060,23	1	0	1
112	34228,99	33132,30	34409,22	38842,65	33949,26	1	0	0
113	33132,30	31950,56	33357,63	38577,16	33782,23	1	0	0
114	31950,56	32470,42	31629,59	38278,91	33544,26	0	0	1
115	32470,42	33207,10	32098,83	37989,92	33552,86	0	0	1
116	33207,10	34031,08	32797,65	37709,75	33583,59	0	0	1
117	34031,08	35453,31	33587,74	37444,33	33623,96	0	0	1
118	35453,31	35456,47	34951,47	37224,38	33764,49	0	0	1
119	35456,47	36481,23	34954,50	37005,47	33829,36	0	0	1
120	36481,23	35385,02	35937,12	36799,68	34017,35	0	0	0
121	35385,02	35698,74	34885,99	36570,23	34179,65	0	0	1
122	35698,74	36202,23	35186,81	36372,72	34326,62	0	0	1
123	36202,23	36148,39	35669,59	36184,95	34633,62	0	0	0
124	36148,39	35955,80	35617,97	36039,39	35053,40	0	0	0
125	35955,80	35815,54	35433,30	35931,56	35401,94	0	0	0
126	35815,54	35010,46	35298,81	35800,85	35662,78	0	0	0
127	35010,46	33831,69	34526,84	35665,13	35760,72	0	1	0
						Dođru Yön	70	64
						Yüzde	0,551	0,504