

İMKB ENDEKS ÖNGÖRÜSÜ İÇİN İLERİ BESLEMELİ AĞ MİMARİSİNE SAHİP YAPAY SİNİR AĞI MODELLEMESİ

Tolga ULUSOY¹

ÖZET

Bu çalışmada 1997-2000 yılları arasında İstanbul Menkul Kıymetler Borsasında gerçekleşen borsa endeks değerinin tahminine ait bir uygulama yer almaktadır. Ayrıca borsada gerçekleşen fiyatların tahmininde kullanılan nöral ağ sistemleri ve algoritmalarına ait matematiksel yöntemlerden de kısaca bahsedilmiştir. Pazarın yönü tahmin edilirken onüç değişkenli bir *Nöral Ağ Sistemi* kurulmuş ve sistemin *Hatayı Geriye Yayma Algoritması* ile değerlendirilmesi yapılmıştır. Tüm hesaplamalar İMKB Nöral Ağ Simulatörü adı verilen bir programla yapılmıştır.

Anahtar Kelimeler: Borsa Endeksi, İMKB, Yapay Sinir Ağları

JEL Sınıflandırması: C45, D53, G17

ARTIFICIAL NEURAL NETWORK MODELLING TO PREDICT THE ISE INDEX USING FEED FORWARD NETWORK ARCHITECTURE

ABSTRACT

This research is about the application of neural networks in forecasting stock market index in Istanbul Stock Exchange between 1997 – 2000 and it gives a brief expressions on the mathematical methods of neural networks systems and algorithms in forecasting stock market prices. The market direction is being forecasted with a thirteen variable for learning in *Neural Network System* and model is upgraded by the *Back-Propagation Algorithm*. All computations were calculated by a program called *ISE Neural Network Simulator*.

Keywords: Stock Exchange Index, ISE, Artificial Neural Networks

JEL Classification: C45, D53, G17

¹ Yrd.Doç.Dr., Kastamonu Üniversitesi, İktisadi ve İdari Bilimler Fakültesi

1. Giriş

Bir değişkenin gelecekte alacağı değeri önceden tesbit edebilmek, birçok alanda karşılaşılan en önemli problemlerden biridir. Bu alanlardan en çok merak edilenlerin başında gelen para ve sermaye piyasalarında yapılan öngörü çalışmaları ise oldukça fazla önem arz etmektedir. Yapay sinir ağı (YSA) uygulamaları da bu çalışmaların başında gelmektedir. YSA'nın öngörü çalışmalarında bulunurken özellikle geçmişe yönelik verilerin eğitim amaçlı kullanılması ve sonrasında ileriye dönük tahmin yapma kapasitesinin yüksek olması nedeniyle tercih edildiği belirtilmektedir (Cheng, vd.,1997) (Dutta ve Shekhar,1988) (Kryzanowski, vd.,1993) (Lin ve Lin,1993) (Trippi ve DeSieno,1992) (Walczak, 2001).Eğitim için kullanılan verilerin değerlendirilmesi ile en uygun yapay mimari bilgisayar ortamında oluşturularak ileriye yönelik tahminlerin ne olması gerektiği kolaylıkla belirlenebilmektedir. Dünyada yapılmış benzeri çalışmalardan bazılarını şu şekilde sıralamak mümkündür: Mallaris ve Salchenberger (1996) S&P500 endeksi için geçmiş volatilité değerlerini kullanarak gelecekte oluşabilecek volatilité değerlerini öngörmeye çalışmışlardır. S&P500 üzerine yazılmış gelecek (*future*) opsiyonların fiyat tahminleri amacı ile yapılan bir diğer çalışmada ise 1984-1994 arasındaki on yıllık süreç değerlendirilmiş ve gerçeğe yakın tahminler de bulunulmuştur (Hamid ve Iqbal, 2004). Nöral ağların performansının değerlendirilmesi için diğer öngörü yöntemleri ile karşılaştırmalı olarak sunulduğu çalışmalar da mevcuttur. Araştırmacıların özellikle New York Borsası (NYSE) için yaptığı çalışmalar verdiği başarılı sonuçlar ile göze çarpmaktadır (Leigh vd.,2002a,2002b). Ayrıca Gençay (1998) DowJones endeksinin (DJIA) 1897-1988 arasında çok geniş bir süreçte analizini yaparken, bir diğer çalışma ise Cao vd. (1998), 1999-2002 tarihleri arasında tuttıkları veri setine nöral teknikler uygulamışlardır. Aynı çalışmada Shanghai endeksi için öngörülerde bulunan araştırmacılar bu iki endeksi birbirleri ile karşılaştırma olanağı bulmuşlardır.

Beyin ve sinir sistemine bakılacak olursa en karmaşık iletişim sistemlerinden biri olduğu söylenebilir. İnsan beyni en karmaşık hesaplama birimi olarak bilinmektedir. Beynin düşünsel yapısı, kapasitesi, öğrenme ve problem çözme süreçleri; bilim adamlarını bu alanda yeni bilgisayar modellemeleri yapma çalışmalarına itmiştir. Bu modellerden en çok kullanılanlarının başında ise YSA'lar gelmektedir. YSA'lar aklın, zihnin, beynin kendisi olmak için çaba harcayan ve bunu bilgisayarda oluşturulmuş algoritmalar aracılığı ile kendi kendine yapmaya çalışan sistemlerdir (Laske,1992). Temelde YSA modelleri, beynin fonksiyonel yapısının bir kopyası olarak düşünülmektedir. Aynı insan beyninde olduğu gibi, çok iyi eğitilen YSA'ların öğrenme süreçlerinin sonu olmadığı varsayılmaktadır. Sistemin temel amacı, dışarıdan verilen bilgiyi kullanma ve belirli bir hatırlama seviyesine ulaşıldığında daha da ileri bilgi seviyesine ulaşılmasını ve tahmin yapılmasının önünü açmaktır (Ören,1990).

YSA araştırmalarını 2 temel dala ayırmak mümkündür: Biyolojik yapı ve modelleme. Biyolojik kısım, biyolojik sinir ağlarının davranışını ve yapısını tanımlamaya yöneliktir. Modelleme ise, işleyişin ve öğrenilen yapının hesaplamalarla bil-

gisayar programlarına dönüştürülmesidir. YSA'lar biyolojik sinir ağları üzerindeki mevcut bilgiler temel alınarak tasarlanmaktadır (Gökçay,1993). Öte yandan YSA'da hesap birimleri veya düğümler genellikle doğrusal olmayan bir yapı gösterdiğinden modern sayısal devrelerle karşılaştırıldığında yavaş sayılabilmektedir (Trippi,1996).

YSA araştırmalarında öncelikle araştırmaya konu olan matematiksel modellerin yapılabilmesi için sinir hücrelerinin (nöronların) nasıl çalıştığına iyi bilinmesi lazımdır.

Nöron sinir sistemlerini oluşturan sinir hücresidir. Her nöron kendisine bağlı birçok nörona çıktı gönderir. Bir adet çıktı gönderen nöron birden fazla girdi sinyali alabilir. Bu sinyalin alınıp gönderilişi ise nöronları birbirine bağlayan sinaptik bağlarla olmaktadır. Nörona gelen girdi sinyali aktivasyonları bu sinaptik bağlarla oluşturulmuş olan sinaptik ağırlıklarla çarpılmakta ve bir sonraki nörona gönderilmektedir. Burada bahsi geçen *nöron aktivasyonu* ise yapay sinir ağlarında önceden belirlenen bir eşik fonksiyonu hesaplamasıyla gerçekleşmektedir (Adorf,1989).

Modelleme esnasında varsayımsal olarak oluşturulan yapay nöronlar ise birbirine doğrudan bağlantılarla bağlanmış gibi düşünülen ve bir işlemi gerçekleştirmek için işbirliği yapan matematiksel formül dizilerinden oluşmaktadır. Her işlem elemanı, diğer işlem elemanlarından gelen giriş bilgilerini birleştirmekte ve tek bir çıkış değeri üretmektedir. En temel durumda, işlem elemanı bütün girişlerin ağırlıklı toplamını oluşturmakta ve onun bir eşik değeri ile karşılaştırmasını yapmaktadır. Eğer girişler önceden belirlenmiş bir eşik değerini aşarsa, nöronun çıktısı yüksek bir değere, aksi takdirde düşük bir değere atanmaktadır. İşleme atan herhangi bir nöronun işlem yapamaması durumu sistemin diğer elemanlarını etkilememektedir (Adorf,1989).Yapay olarak işlemlere atanmış nöronlar, basit elemanlar olmalarına rağmen uygun matematiksel hesaplamalarla beynin fiziksel yapısında olduğu gibi bağlanırsa, çok yüksek bir hesaplama gücünün elde edilebileceği belirtilmektedir (Freeman,1991).

YSA'lar ağ içindeki sinyallerin akış yönlerine göre birbirlerinden ayrılmaktadır. Esas olarak 2 temel ağ tipi mevcuttur. Bunlar *ileri beslemeli (feed forward)* ve *geri beslemeli (feed back)* ağlar şeklinde isimlendirilir (Dennis,1997). İleri beslemeli ağlar, ara sinirlerden geçerek giriş katmanından çıkış katmanına doğru bilgi akışının yalnız bir yönde ilerlediği ağlardır.

Giriş tabakası, gizli tabaka ve çıkış tabakası olmak üzere 3 tabakadan oluşurlar. Ağ üzerinde bilgi akışı, giriş tabakasından çıkış tabakasına doğru ilerler. Yani nöronlar arka arkaya beslenirler. Geri beslemeli YSA'lar ise herhangi bir sinirin çıkışından girişine doğru bilgi akışının ilerlediği ağlar olarak tanımlanmaktadır. Bu tür ağ yapısında geri besleme bağlantıları söz konusudur (Yazıcı vd., 2007).

YSA'da en uygun ağırlık setinin belirlenmesi için yapılan ağ hesaplamalarının öğrenme aşamasında, *gözetimli (supervizörlü)* ve *gözetimsiz (supervizörsüz)* öğ-

renme adlı iki tip öğrenme stratejisi söz konusu olmaktadır (Yazıcı vd., 2007). Gözetimsiz öğrenmede; ağırlıklar, girdi-çıkıtı karşılaştırması yapılmadan hesaplanmaktadır. Yapay nöronlar arasındaki sinaptik bağlarda oluşturulan ağırlıklar gözetimli öğrenme de olduğu gibi öğrenmeleri için gerekli olan besleyici sinyalleri almazlar. Gözetimli öğrenmede ise besleyici sinyaller oluşturulmaktadır. Bunun yanında girdi değerleri ile çıkıtı değerleri karşılaştırılmaktadır.

Nöral Sistem uygulamalarında birçok model kullanılmaktadır. Bu çalışmada *Hatayı Geriye Yayıma* (HGY) algoritması kullanılmıştır. HGY algoritması eğitim sırasında getirdiği kolaylıklar nedeniyle tercih edilmektedir. Bu algoritmada, girdilerin sisteme verilmesi ve çıkıtının hesaplanması olarak iki aşama mevcuttur. Hesaplama sonucu elde edilen hata payı geriye doğru tüm katmanlar arasında yayılmaktadır (Moody,1995). Bir sinir ağı, ağıın mimarisi, bir nörondaki aktivasyon fonksiyonu ve eğitim algoritması ile karakterize edildiğinden çok tabakalı sinir ağların eğitimi için genellikle kullanılan eğitim algoritması HGY algoritması olmaktadır. Bu algoritma türevi alınabilir uygun bir aktivasyon fonksiyonu ile herhangi bir ileri beslemeli sinir ağları için kullanılabilir olmaktadır. (Özsoy ve Fırat,2004). Bu çalışmada aktivasyon fonksiyon olarak sigmoid fonksiyon belirlenmiştir.

Girdilerin belirlenmesi, bilgi akışının hangi yöne doğru olacağı adımlarından sonra belirlenen algoritmanın düzgün çalışabilmesi için birbiriyle bağlantılı matematiksel formüller, bir bilgisayar programı yardımıyla birbirine bağlanmıştır. Matematiksel denklemler, beynin işlevsel bütüne yakın fonksiyonlarını yansıtmaktadır. Öngörü yapacak olan simülör, bu formüllerin oluşturduğu hesaplamaların yapılması ve çıkıtının araştırmacıya düzenli verilmesini gerçekleştirmek üzere oluşturulmuştur.

Simülörde *eğitim* ve *test* adında iki aşama mevcuttur. Eğitim aşamasında çıkıtı değerleri programa verilmektedir. Program, normalize edilmiş girdi değerlerini almakta olup, çıkıtı değerini hesaplamakta ve oluşturduğu çıkıtı değerini gerçek değerle karşılaştırıp farkını hata payı olarak vermektedir. Hata payları en aza indirgindikten sonra simülörde öğrenmenin başladığı söylenebilmektedir. Eğitim aşamasının sonunda simülör "*sinaptik ağırlıklar*" matrisi oluşturmaktadır. Bu matris, girdi değerleri arasında mantıksal bağları göstermektedir. YSA'larda bilginin ağıdaki bağlantıların ağırlıklarında belirlendiği varsayımından hareketle, bu işlemler öğrenme sistemin bir bütün olarak istenen bir işlevi yerine getirecek şekilde ağırlıkların ayarlanması sürecini oluşturmaktadırlar(Baklavacı,1994). Test aşamasına geçildiğinde ise çıkıtı değerleri programa verilmemekte, simülör girdi değerleri ve eğitim aşamasında oluşturulan sinaptik ağırlıklar matrisini kullanarak çıkıtı değerlerini hesaplamaya çalışmaktadır.

2. Model

Bu çalışmada İMKB endeksi haftalık kapanış değerlerinin öngörüsü yapılması amacıyla geliştirilen bir YSA modellemesi anlatılacaktır. Bu model ileri beslemeli ağ mimarisine sahip ve gözetimli öğrenme metodu ile öğrenen HGY algoritması kullanılarak oluşturulmuştur. Nöral sistem kurulurken yapılanlar aşamalar halinde

anlatılmıştır. Bu modellemede nöral sinir ağı mimarisi “İMKB Nöral Ağ Simulatörü” adlı bir bilgisayar programıyla desteklenmiştir.¹

İMKB öngörüsü için sırasıyla girdiler belirlenmiştir. Girdilerin hangilerinin simülasyonda yer alacağı belirlenmesi, modele temel teşkil eden kısımdır. Girdi değerlerinin hesaplama katmanlarından geçerek oluşturduğu çıktı değeri ise endeks değerinin kendisi olacaktır.

Öngörü işlemi için belirlenen onüç değişken, 03.01.1997 tarihinden itibaren 2000 yılı sonuna kadar her haftanın son işlem günü için derlenmiştir. Bu değerler iki kısma ayrılmıştır. İlk 180 haftalık kısımda algoritmanın eğitimi için kullanılan veriler yer almaktadır. Tüm bu değerler nöral hesaplama için kullanılacak olan aktivasyon fonksiyonu için normalize edilmiştir. Tüm değişkenler 13x180 boyutunda bir matris gibi düşünülmüş ve satır işlemleri yapılarak programın hesaplamalarda güçlüklerde karşılaşmaması ve fonksiyon işlemlerinden sorunsuz geçebilmesi için [0..1] aralığına indirgenmiştir. Geri kalan ikinci kısımdaki 19 vektörel değer ise eğitim bittikten sonra programın testi için kullanılmıştır.

Girdi değerleri belirlendikten sonra mimari yapı belirlenmiştir. YSA modellerinden faydalanılarak bir algoritma oluşturulmuştur. Burada girdi değerlerinin hangi yolu izleyerek sonuca ulaşacağı ve bunun kâğıt üzerinde izlenme metodunun ne olduğu belirlenmiştir.

Mimari yapı oluştuktan sonra değerler bu mimari yapı içerisinde hesaplamalardan geçirilmiş ve her adımda bu hesaplamaların matematiksel ifadeleri yerleştirilmiştir. Tüm tasarım bittikten sonra nöronlar arası geçişleri hesaplayarak çıktı değerini bize verecek ve öğrenme aşamalarında deneysel ifadeleri hafızasında tutabilecek bir bilgisayar programı ile desteklemesi yapılmıştır.

Tasarım mimari ve programlama aşamaları gibi teknik kısımlardan sonra sırasıyla eğitim ve eğitim boyunca öğrenilenleri test aşamalarına geçilmiştir.

Nöral sistemlerin eğitimi uzun zaman alan ve dikkat edilmesi gereken en kritik noktalardan biridir. Eğitim için gerekli olan girdilerin karakteristikleri iyi belirlenmelidir. Tasarlanan algoritmada girdi olarak belirlediğimiz değerlerin çıktıya ulaşmada etkisinin önceden tahmin edilmesi zor olmaktadır. Fakat nöral sistem algoritmalarında kesin olan girdi yelpazesinin geniş tutulmasının gerekliliğidir. Önceki paragraflarda da belirtildiği üzere; eğitim aşamasında, girdi değerleri ve çıktı değeri olarak sistemin ulaşması gereken değerler verilmektedir. Eğitim aşamasından sonra bir diğer önemli aşama olan test aşaması başlamaktadır. Test aşamasında ise ilk önce eğitim aşamasında verilen değerlerin tamamı tekrar verilmektedir. İki aşama arasında en belirgin fark eğitim aşamasında hedef değer sisteme gösterilmekte fakat test aşamasında girdi değerleri verilirken önceden hesaplanmış hedef değer sisteme ve-

¹ İMKB Neural Network Simulator, Vallaru B. Rao'nun C++ in Neural Networks and Fuzzy Logic adlı eserinde verdiği program görsel uygulaması temel alınarak araştırmacı tarafından kodlanmıştır.

rilmemektedir. Test aşamasında algoritmanın gerçek çıktıya ulaşip ulaşmadığı denetlemesi yapılmaktadır.

2.1. Hatayı Geriye Yayma Algoritmasında Sinaptik Geçişlerin Matematiksel Alt Yapısı

Blum (1992), Freeman ve Sakapura (1989), Jagota (1998), Rao (1993) HGY algoritmasındaki geçişlerin matematiksel alt yapısının beş aşamadan oluştuğunu belirtmektedirler.

i. Bilginin girdi katmanından çıktı katmanına doğru iletilmesi

F fonksiyonu aktivasyon fonksiyonu olmak üzere; ara katmanda bulunan nöron aktivasyonlarının hesaplanması; $[W_1]$, girdi ve ara katmanlar arasında sinaptik ağırlıklar matrisi, \bar{i} ise girdi katmanında oluşturulan vektörler olmak üzere

$$\bar{h} = F(\bar{i}W_1) \quad (1)$$

ara katmanda oluşturulan vektör olmaktadır. Çıktı katmanında nöron aktivasyonu; \bar{o} çıktı katmanında oluşturulan vektör, $[W_2]$ ara katman ve çıktı katmanı arasında sinaptik ağırlıklar matrisi olmak üzere

$$\bar{o} = F(\bar{h}W_2) \quad (2)$$

eşitliğini vermektedir.

ii. Bilginin çıktı katmanından girdi katmanına doğru iletilmesi

Hedef değer ile gözlenen değer arasındaki fark, çıktı katmanında oluşan hata olarak alınır; çıktı katmanında hedeflenen aktivasyon (gerçekte olması gereken değer) t , çıktı katmanında oluşan hataların oluşturduğu matris d , \bar{o} ise çıktı katmanında değerlerin oluşturduğu vektör olmak üzere

$$[d] = \bar{o}(1 - \bar{o})(\bar{o} - t) \quad (3)$$

olmakta öte yandan $[e]$; ara katmanda bulunan nöronların hesaplandığı hataların oluşturduğu matris olmak üzere ara katmanda oluşan hata

$$[e] = \bar{h}(1 - \bar{h})W_2d \quad (4)$$

şeklinde hesaplanmaktadır.

iii. Ara katmanda oluşturulan sinaptik ağırlıkların algoritmaya göre ayarlanması

t zaman değeri olarak alındığında; $t=1$ olarak ifade edilen terim, birinci çevrim olmakta, ΔW_2 ise $[W_2]$ matris değişimi ifade etmektedir. α öğrenme katsayısı ile Θ momentum değeri

$$\Delta W_{2,t} = \alpha \bar{h} \bar{d} + \Theta \Delta W_{2,t-1} \quad (5)$$

eşitliği ile

$$W_{2,t} = W_{2,t-1} + \Delta W_{2,t} \quad (6)$$

toplamına ulaşmaktadır.

iv. Girdi katmanında da oluşturulan sinaptik ağırlıkların algoritmaya göre ayarlanması

Yukarıdaki hesaplama ile bağlantılı olarak algoritmaya göre ayarlama ΔW_1 , W_1 matris değişimi olmak üzere

$$W_1 = W_1 + \Delta W_1 \quad (7)$$

olmaktadır ve bu hesaplama her nöron çıktı katmanı için çıktı katmanı hata vektörü olan \bar{d} için belirtilen tolerans sınırına gelene kadar tekrarlanmaktadır. Birinci ve ikinci aşamaların tekrarlanması ile de bilgi özyinelemeli olarak geri çağrılmaktadır.

v. Çıktı Değerlerinin Hesaplanması

Çıktı değerlerinin hesaplanması için $[M_1]$ ve $[M_2]$ ağırlık matrisleri olarak tanımlanmıştır. $M_2 [i][j]$, ara katmanda bulunan i 'nci nöron ile çıktı katmanında bulunan j 'nci nöron arasında sinaptik ağırlık olarak ifade edilmiştir. x, y, z değerleri sırasıyla; girdi katmanında çıktı değeri, ara katmanda çıktı değeri, çıktı katmanında çıktı değerleridir. $[x_1, x_2, x_3, \dots, x_m]$ girdi vektörü, \bar{P} çıktı katmanında değerlerin oluşturduğu vektör, λ ara katman için öğrenme katsayısı, Θ ara katman için eşik değeri, μ çıktı katmanı için öğrenme katsayısı, e_j çıktı katmanında çıktı değerlerinin hata payları, t_i ara katmanda çıktı değerlerinin hata payları, ve eşik fonksiyon olarak seçilen sigmoid fonksiyon kullanımı altında ara katmanda bulunan j . nöronun çıktı değeri

$$y_j = f \left(\sum_i x_i M_1 [i][j] \right) + \theta_j \quad (8)$$

eşitliği ile ifade edilmekte ve çıktı katmanında bulunan j . nöronun çıktı değeri

$$z_j = f \left(\sum_i y_i M_2 [i][j] \right) + \tau_j \quad (9)$$

olmaktadır. Çıktı katmanında i . nöron çıktısı için beklenen değer ile hesaplanan değer farkı oluşmakta ve bu fark $P_i - z_i$ olarak alındığında çıktı katmanında i . nöron hata payı

$$e_i = z_i (1 - z_i) (P_i - z_i) \quad (10)$$

ara katmanda i . nöron hata payı ise

$$t_i = y_i (1 - y_i) (\sum_j M_2 [i][j] e_j) \quad (11)$$

olmaktadır. Hesaplamalarda sinaptik ağırlık ayarlamalarının da yapılması gerektiğinden ara katmanda bulunan i. nöron ile çıktı katmanında bulunan j. nöron arasında bulunan sinaptik ağırlığın ayarlanması

$$\Delta M_2 [i][j] = \mu y_i e_j \quad (12)$$

girdi katmanında bulunan i. nöron ile ara katmanda bulunan j. nöron arasında bulunan sinaptik ağırlığın ayarlanması

$$\Delta M_1 [i][j] = \lambda x_i t_j \quad (13)$$

eşitlikleri ile yapılmaktadır. Eşik değeri ayarlamaları ise bir gereklilik olarak ortaya çıkmaktadır. Çıktı katmanında bulunan j. nöron için eşik değeri ayarlaması

$$\Delta \tau_j = \mu e_j \quad (14)$$

ara katmanda bulunan j. nöron için eşik değeri ayarlaması

$$\Delta \theta_j = \lambda e_j \quad (15)$$

şeklinde olmaktadır.

2.1.1. Ağ Yapısının Belirlenmesi

Öncelikli olarak YSA'lar için kabul görmüş gerekliliklerin İMKB endeks öngörüsü için kurulan ağ yapısında nasıl yer alacakları konusu, ağ yapısı tasarımının başlangıç noktasını oluşturmaktadır.

1.*Girdi katmanında kullanılacak nöronların sayısı*: Bir modelde hangi sayıda girdi varsa, aynı sayıda nöron kullanılmalıdır. Araştırmada öngörü için onüç adet girdi belirlenmiş bu nedenle ağ yapısının girdi katmanının sayıca aynı nöron bağlantısıyla oluşturulacağı söylenebilir.

2.*Kullanılacak ara katmanların sayısı*: Hata paylarının hesaplanışında ve algoritmanın çeşidine göre değişiklik göstermektedir. Algoritmada; denemeler sonucunda elde edilen çıktıların birbirine oldukça yakın değerler alması nedeniyle, bir ara katmanlı hesaplama yeterli bulunmuştur.

3.*Her ara katmanda kullanılacak nöronların sayısı*: Denemelere göre değişiklik göstermekle beraber; gözlem sonucunda, girdi katmanında bulunan nöron sayısının dörtte biri oranında nöron kullanılması yeterli görülmüştür.

4.*Çıktı katmanında kullanılacak nöron sayısı*: Ulaşılması gereken hedef değer tahmin değeri yani İMKB endeks değeri olacağına göre bu değer bir olmalıdır.

5.*Beta sabitinin tesbiti*: Öğrenme sabiti olarak da adlandırılır. Her geçişte nöronun ağırlıklarının değişiminin etkisini ölçer. Program esnasında verilmektedir.

6. *Momentum parametresi ile Alfa ve Bozucu etken (noise factor) tesbiti:* Momentum geçişlerde bir önceki ağırlık değişimlerinin bir sonraki geçişte hesaplanan ağırlıkları ne kadar etkilediğini gösterir. Bozucu etken ise dışarıdan bir etki sonucunu programın ne kadar sapmaya uğradığını ölçmek için belirlenir. Program esnasında bozucu etken için 0 değeri verilmiştir (Giles ve Steve, 1997).

7. *Nöron çıktılarının tesbitinde kullanılacak aktivasyon fonksiyonlarının tesbiti:* Nöral Sistemlerin finans sektörüne uygulamalarında Sigmoid fonksiyon sağlıklı sonuçlar ürettiği için algoritmada bu fonksiyonun özelliklerinden faydalanılmıştır.

2.1.2. Sigmoid Fonsiyonun Kullanımı ve Bir Yapay Nöron Üzerinde Örneklem

HGY ağlarının finans uygulamalarında çoğunlukla sigmoid fonksiyon kullanılmaktadır. Sigmoid fonksiyon, yakınsama şartını ve verilen geniş bir değer grubunu [0..1] değerleri arasına sıkıştırılmaktadır. Kullanımları ise şu şekilde özetlemek mümkündür.

HGY ağında öncelikle ilk katmana on üç elemandan oluşan bir giriş vektörü uygulanmaktadır. Daha sonra giriş ve birinci katman ağırlıkları yardımıyla birinci katmanda her birimin aldığı toplam giriş belirlenmektedir. Civelek (1999), her birimin, giriş değerini lineer olmayan sigmoid fonksiyondan geçirerek bir sonraki katmana göndereceği çıkışı belirlediğini belirtmektedir.


$$y = \frac{1}{1 - e^{-(I-\Theta)}} \quad (16)$$

Birbirine karmaşık şekilde bağlanmış nöronların oluşturduğu bir nöron ağında giriş vektörünü $\bar{X} = [x_1, \dots, x_{13}]$ olarak adlandırılabilir. \bar{X} vektörünün yukarıda belirtildiği üzere $\bar{W} = [w_1, \dots, w_{13}]$ katman ağırlıkları ile çarpılması sonucunda $[x_1 \cdot w_1, \dots, x_{13} \cdot w_{13}]$ çarpım vektörü oluşmaktadır. Bu bloğun tüm elemanları toplandığında, oluşan toplam bloğunun biyolojik nöronun anlatılanlar gözden geçirildiğinde hücre gövdesine denk geldiği söylenebilir. Toplanan tüm bu değerler ile bir nörondaki toplam potansiyel (I) belirlenmektedir.

$$I = \sum_{i=1}^h \bar{X}_i \bar{W}_i \quad (17)$$

Nöronun çıkış sinyali I seviyesidir denilebilir fakat bu değer bir sonraki nörona aktarılması gereken çıkış sinyalinin sigmoid fonksiyondan geçirilmesi ile aktiflik kazanmaktadır.

Şekil 1: Yapay Nöron Hesaplama Modeli



Sigmoid fonksiyonun I sinyali Y sinyaline deęiřtirme amalarından bir tanesi de I toplam blokunun bozulmalarını elimine ederek [0...1] aralıęında kalmasını saęlamaktır (Simpson, 1991).

3. Girdi Deęerlerinin Belirlenmesi

Girdi deęerleri İMKB endeks deęerine etki eden deęerler arasından seilmiřtir. İlk iki veri grubu olan İMKB100-yüksek ve İMKB100-düşük kalemleri 1997 yılından itibaren her haftanın kapanıř verileridir. Amerikan Doları kalemi ise borsa endeks deęerine etki eden veri kalemleri arasında düşünölmüş ve algoritmanın eęitilmesi için girilecek veriler arasında faiz oranları üzerinde önemle durulmuřtur. Bu kalemlerde yine hafta sonu kapanıř deęerleri ile yüksek düşük ayırımına gidilmiřtir. Burada döviz kalemleri için yüksek düşük ayırımına gidilmesi ise veri yelpazesinin geniş tutulması, saęlıklı öngörüsü yapılması beklenen İMKB100 endeksi için hazırlanan YSA modelinin saęlıklı alıřması için gerekli görölmüřtür. Bu alanda yapılan bazı alıřmalar hisse senedini en çok etkileyen araçların başında döviz kurunun geldięini göstermektedir (Özdemir, 1996). Yurt dıřı borsaların da İMKB100 endeks deęerine etkisini ölçmek amacıyla S&P500 ve NYSE haftalık kapanıř deęerlerine yer verilmiřtir.

Tablo 1: Belirlenen Girdi Deęerleri

03/01/1997 tarihinden başlamak üzere	Bir tahmin için kullanılan deęer sayısı
İMKB 100 Yüksek (TL) (İMKB100Y)	1
İMKB100 Düşük (TL) (İMKB100D)	1
AMERİKAN DOLARI Yüksek (TL) (ABD\$ Y)	1
AMERİKAN DOLARI Düşük (TL) (ABD\$ D)	1
AMERİKAN DOLARI Kapanıř (TL) (ABD\$ K)	1
TCMB Gecelik Faiz Oranı (%) (TCMBGF)	1
1 AY VADELİ FAİZ ORANI (%) (F1)	1
3 AY VADELİ FAİZ ORANI (%) (F3)	1
6 AY VADELİ FAİZ ORANI (%) (F6)	1
12 AY VADELİ FAİZ ORANI (%) (F12)	1
S&P500 Haftalık Kapanıř (\$) (SP500)	1
NYSE Haftalık Kapanıř (\$) (NYSE)	1
Londra Altın Borsası Altın Kapanıř (ons/\$) (AB)	1

Siyasi beklentiler ve politik gelişmelerin etkisi kadar olmasa da bu endekslerin de etkisinin varolduęu bilinmektedir (Bökesoy, 1994).

Altın borsası için Londra Altın Borsası verilerinin girilmesi İstanbul Altın Borsası ile yapılan karşılařtırma sonucunda gösterdięi benzerlik ve simülasyonun ileri aşamalarında programa göstereceęi uyum neticesinde derecelendirilerek gerekleştirilmiřtir.

Tüm bu değerler için ortak özellikler belirlenmiştir. Birinci özellik, öngörü işleminin bilgisayar programı desteğinde yapılacağından hareketle, bu değerlerin eğitim aşamasına gelinceye kadar birçok hesaplamalardan geçeceği ve bu hesaplamalar sonunda tüm kalemlerin [0..1] aralığında dağılımının yapılacağıdır (Rao, 1993). İkinci özellik, eğitim aşamasından sonra test aşamasında ve ileri aşamalar için deneme yapacak olan araştırmacıların çalışmalarında, belirlenen 13 girdi değerine kolaylıkla ulaşabilmelerinin amaçlanmış olmasıdır.

3.1. Girdi Değerlerinin Normalizasyonu

Girdiler için bilgisayarda *input.dat* adlı bir tablo oluşturulmuştur. Bu tablo içerisinde tüm sayısal ifadeler aşağıda örneği verilmiş olan formatta yerleştirilmiştir.

Tablo 2: Belirlenen Girdi Değerleri - Örnek Tablo

TARİH	DOLAR			İMKB100
	YÜKSEK	DÜŞÜK	KAPANŞ				
01.03.1997	109050	109050	109050	1035.00
01.10.1997	110920	110920	110920	1153.00
..

Tabloda, bu değerlerin programda kullanılabilmesi için bir takım hesaplamalardan geçeceği daha önce belirtilmişti. Çıktı değerlerinin aktivasyon fonksiyonunun bir sonucu olacağı hesaba katılırsa, çıktının [0...1] aralığında kalması gerekmektedir ki normalizasyon işleminin yapılmasının gerekliliği buradan da anlaşılmaktadır. Çünkü kullanılan aktivasyon fonksiyon çıktı genişliği hangi değer verilirse verilsin bu aralıkta kaldığı durumda hesaplamalar basitleşmektedir. Bu işlemlerin bir gereği olarak girdi değerleri 13x199 boyutunda bir matris gibi düşünülmüştür.

İlk olarak İMKB100 kapanış sütununda değerler bir adım yukarı kaydırılmıştır. Bunun yapılmasındaki amaç şudur: Algoritmaya 03.01.1997 tarihinde gerçekleşmiş olan kapanış değerleri verilmiştir. İstenen çıktı değeri ise 10.01.1997 tarihli endeks değeridir. Bu çıktı son satırda olacağından gerekli düzenlemeler bu doğrultuda yapılmıştır.

Sütun işlemi yapıldıktan sonra normalizasyon işleminde, aynı satır üzerinde bulunan her haftanın değerleri ile son sütunda bulunan kapanış değerleri, ilgili haftada bulunan en büyük değere bölünmüştür.

Tablo 3: Belirlenen Normalizasyon Değerleri - Örnek Tablo

	A	B	C	Q	R
I	1.DEĞER	2.DEĞER	3.DEĞER	14.DEĞER	
II	128260	127970	1585	1505	04/04/1997
III	1	0,997739	0,999532	0,011734	

Burada oluşturulan 199 satırlık giriş dosyasının bir satırı örnek amacıyla Tablo 3’de görülebilir. II Nolu satır da A-P arasında değerler 04.04.1997 tarihinde gerçekleşmiş piyasa değerleridir. Q sütununda bulunan 1505 değeri ise 11.04.1997 tarihinde gerçekleşmiş olan İMKB100 haftalık kapanış değeridir. Normalizasyon işleminde sırasıyla II-A hücreleri o satırda en yüksek değer kabul edilerek tüm hücreler bu değere bölünmüş ve III nolu satır elde edilmiştir. III nolu satır virgülden sonra 6 basamak ilerletilerek başka hiçbir değişiklik yapılmadan öngörü yapılacak değerler içindeki yerini alması sağlanmıştır.

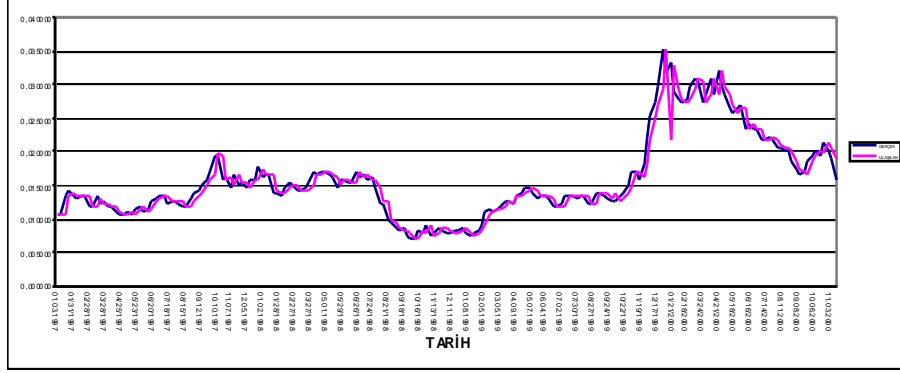
Yapılan işlemler sonrası normalize edilen veriler, *input.dat* dosyasından programın bu verileri eğitim aşamasında alması için *training.dat* adlı bir diğer dosyaya alınmıştır.

4. Eğitim ve Test

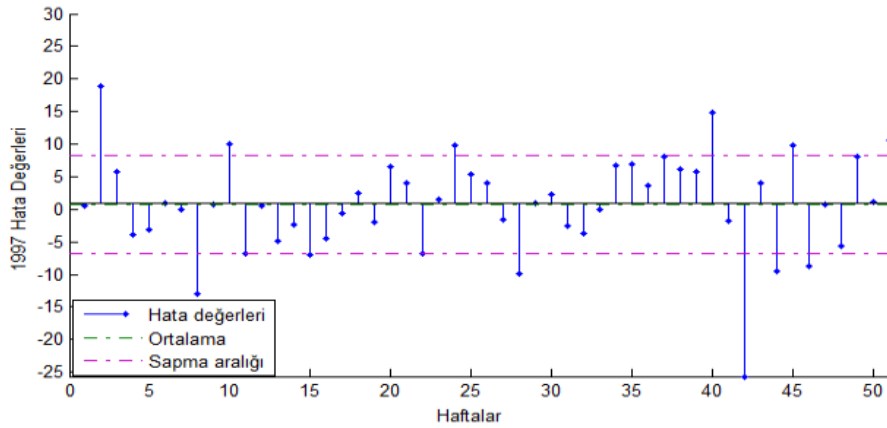
Algoritma için mimari yapı belirlendikten sonra programlama aşamasına geçilmiş ve HGY algoritması için bu alanda yapılmış olan uygulamalardan faydalanılmıştır. HGY algoritması için gerekli olan matematiksel ifadeler kullanılmıştır. Simulator; belirlenen mimari yapı içerisinde, ilk girdi olarak eğitim için haftalık veri paketlerini vektörler gibi düşünerek sırasıyla almış ve bu verileri nöronlar arası sinaptik geçişlerle hesaplanmış ve bir sonraki haftanın endeks değerine ulaşılmaya çalışılmıştır. Program; hesapladığı değeri, ulaşmasını istediğimiz değerle karşılaştırmış ve bir hata payı ile çıktı olarak vermiştir. Bu hata payını hesaplarken bir ağırlık matrisi oluşturmuştur. Eğitim aşamasında, en az hata payının verilmeye başladığı aşamadan itibaren simülasyonun ağırlık matrisini kullanmasının önü açılmıştır. “İlk öğrenme” aşamasından sonraki test aşamasında kullanılmak üzere oluşturulması gereken sinaptik ağırlıklar matrisinin yapılandırılması amacıyla gerekli kısımlarda matris satır ve sütun değerlerini değiştirmesi sağlanmıştır. İlk 180 değer verilmesi ve eğitim aşamasının bitmesinden sonra simülatör, bir sinaptik ağırlıklar matrisi belirlemiştir. (Sinaptik Ağırlıklar Matrisi girdi katmanı ile ara katman arasında oluşturulduğunda w_1 ara katmanla çıktı katmanı arasında oluşturulduğunda w_2 adını almaktadır.) Test aşamasında ise bu sinaptik ağırlıklar matrisi ve girdi değerleri verilerek programın en az hata payı ile endeks öngörüsü yapması amaçlanmıştır. Önceki sayılarda da belirtildiği üzere eğitim aşamasında programın ulaşması gereken değer verilmiştir. Fakat test aşamasında programa ulaşması gereken değer olan bir sonraki haftanın endeks değeri verilmemiş hata payına bakılarak ve bir başka dosyada karşılaştırması yapılarak endeks değerine ne ölçüde yaklaştığı denetlenmiştir. Bütün bu matematiksel denklemleri simülatörün hesaplaması sağlanmıştır.

5. Hesaplamalara Ait Sayısal Değerlendirmeler

Eğitim aşamasında ve takip eden test aşamalarında nöral sistemin sert inişlerin ve çıkışların yaşandığı Türk hisse senedi piyasasında oldukça başarılı sonuçlar verdiği söylenebilir. Oluşturduğumuz ağ mimarisi ve simülasyon, bu tekniğin Türk Finans Dünyası için kullanılabilir olduğunun bir göstergesidir.

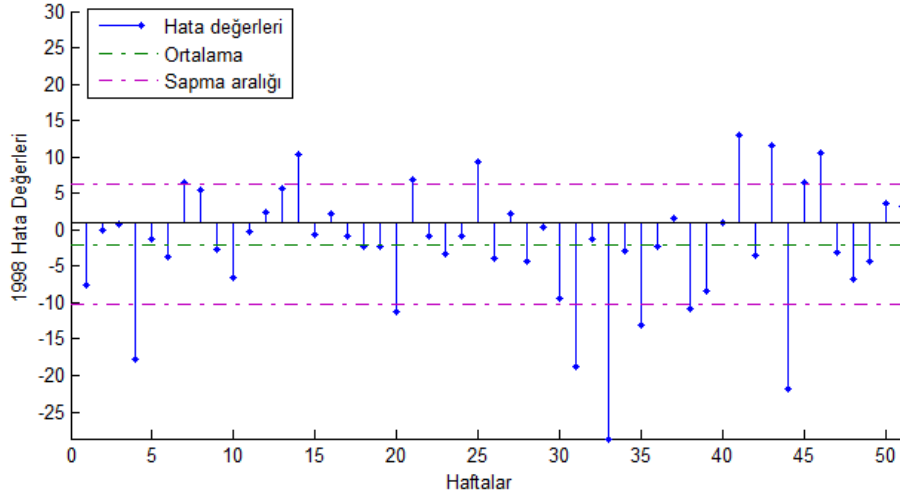
Grafik 1: Oluşan Değerler ile Öngörülerin Karşılaştırma Grafiği

Öngörü sonuçları değerlendirilirken bazı noktalar üzerinde şunları söylemek mümkündür: Öngörü öncesi piyasa faiz oranları incelendiğinde 12 aylık ve gecelik faiz değerlerinde 2000 yılının ikinci yarısı için şaşırtıcı birtakım gelişmeler olduğu söylenebilir. Bu tarihlerde gecelik faiz oranları aşırı artışlar ve ani azalış eğilimi göstermekte bunun yanında 1 aylık 3 aylık ve 6 aylık faiz oranlarında da ani düşüşler tesbit edilmektedir. Bundan hareketle istikrar arzermeyen verilerin öngörüsü sonuçlarının beklenenden farklı çıkaracağı söylenebilir. Nitekim eğitim aşamasında programın bu tarihlerde tahmin yapmakta zorlandığı fakat en sağlıklı öngörülerin yine bu zaman diliminde meydana geldiği görülmüştür. Buradan borsayı etkileyen sayısal göstergelerin dışında güçlü bir siyasi veya politik baskı olabileceği fikrinden hareketle sapmaların yaşandığı tarihler için basında yer alan haberler ile ağ performansının ilişkilendirilerek değerlendirilmelerin yapılması gerekmektedir.

Grafik 2: 1997 Haftalar Bazında Hata Payları

1997 yılı için 03.01.97 tarihinden başlamak üzere 26.12.97 tarihi dahil 52 hafta için öngörü yapılmıştır. 17.10.97 gününde program haftalık endeks sonucunu %18.94 hata ile bulmuştur. Bu tarihte ise İMKB endeksi %25'lik rekor bir çıkış yapmış ve endeks 1194'ten 1503'lere ulaşmıştır. 28.02.97 tarihinde %13.07 lik bir öngörü hatasına rastlanmaktadır. Bu tarihte ise endeks % 12 civarında hızlı bir düşüş yaşamış ve 1600'lerden 1400'lere gerilemiştir.14.03.97 tarihine bakılacak olursa simulasyon sonucu %10.01'lik bir hata gerçekleştirmiştir. Bu tarihte ise borsa bir hafta içerisinde %10 luk bir yükseliş yaşamıştır. Bu yıla ait son ve önemli sapmalara ise 10.10.97 ve 24.10.97 tarihlerinde rastlanmıştır. Burada borsa ilk önce %21 lik bir artış hemen ardından da %17 lik bir düşüş gerçekleştirmiştir. Simulasyonun bu artış ve azalışlara verdiği hatalar ise sırasıyla %14.74 ile %25.64 seviyesindedir.


Grafik 3: 1998 Haftalar Bazında Hata Payları



1998 yılı için 02.01.98 tarihi ile 25.12.98 tarihi arasında 51 hafta için öngörü yapılmıştır. 23.01.98 tarihinde program haftalık endeks sonucunu %17.85 hata ile bulmuştur. Aynı gün, İMKB endeksi %15'lik bir düşüş yaşamış ve endeks 3547'ten 2986'ya gerilemiştir. 03.04.98 tarihinde %10.26'lık bir öngörü hatasına rastlanmaktadır. Aynı tarihte endeks % 13 civarında hızlı bir çıkış yaşamış ve 3645'den 4120'ye ulaşmıştır. 07.08.98 tarihine bakılacak olursa simulasyon sonucu %18.75'lik bir hata gerçekleştirmiş paralelinde borsa bir hafta içerisinde %14'lük bir düşüş yaşamıştır. Bu yıla ait diğer önemli sapmalara ise 21.08.98, 25.09.98, 16.10.98, 30.10.98, 06.11.98 tarihlerinde rastlanmaktadır. Bu tarihlerde ise simulasyon hataları sırasıyla %28.66 , %10.90 , %12.96 , %11.52 , % 21.88 şeklindedir. Açıkça görülmektedir öngörü sonuçları bu tarihlerde oldukça yüksek sapmalara uğramıştır. Bu tarihlere ait piyasa sonuçlarını özetlenmesi yararlı olacaktır.

En yüksek sapmanın yaşandığı 21.08.97 tarihinde borsa %20 düşmüştür. 25.9.97 tarihinde ise %17 gibi bir düşüşle karşılaşmıştır. Diğer tarihlerde ise endeks ard arda olmak üzere %14 yükseliş ve %16 düşüş yaşamış, tekrar %17 gerilemiş ve sonunda geri kalan haftalarda %10'luk ve %11 lik yükselişlere sahne olmuştur. Dünya ortalamasına bakıldığında bu salınımların anormal düzeyde kabul edilmekte olduğu ortadadır.


Grafik 4: 1999 Haftalar Bazında Hata Payları



1999 yılı öngörüsü 04.01.99 tarihi başlangıç, 24.12.99 tarihi bitiş kabul edilerek 51 hafta için hesaplanmıştır. 05.02.1999 tarihinde program haftalık endeks sonucunu %10.04 hata ile bulmuştur. Hemen ardından 12.02.99 tarihinde sapma %16.65 olarak gerçekleşmiştir. Bu tarihlere ise İMKB endeksi %25'lik rekor bir çıkış yapmış ve endeks 3088'den 3890'a yükselmiştir. 18.06.99 tarihinde %10.59'luk bir öngörü hatasına rastlanmaktadır. Bu tarihte ise endeks % 8 civarında hızlı bir düşüş yaşamış ve 5321'den 4860'e gerilemiştir. 20.08.99 tarihine bakılacak olursa simülasyon sonucu %10.67'lik bir hata gerçekleştirmiştir. Bu tarihte ise borsa bir hafta içerisinde %8 lik bir gerileme yaşamıştır. Bu yıla diğer bir önemli sapmaya ise 03.09.99 tarihinde rastlıyoruz. Bu tarihte endeksin %16 lık bir değişimine karşılık hata payı %12.87 olmuştur. Kasım ve Aralık aylarında ise 4 büyük sapma oluşmuştur. Bunlar 05.11.99 ve 26.11.99 ile 03.12.99 ve 10.12.99 tarihlerinde gerçekleşmiştir. Bu tarihlerde ise şaşırtıcı olan borsa endeksinin sırasıyla %16, %19, %17, %21, %15 lik artışlar kaydetmesidir. Simülasyonun bu artış ve azalışlara verdiği hatalar ise sırasıyla %13.26, %12.58, %16.98, %13.05 seviyesinde olmuştur.

2000 yılında 07.01.2000 - 17.11.2000 tarihleri arasında 45 hafta için değerlendirme yapılmıştır. Öngörü için seçilen tarih aralığında en sağlıklı öngörünün bu yılda olduğu bulunmuştur. 07.01.2000 tarihinde program haftalık endeks sonucunu %17.20 hata ile bulmuştur. Bu tarihte ise İMKB endeksi %20'lik bir artış yaşamış ve endeks 15.837'den 19.110'a yükselmiştir. 14.01.2000 tarihinde %11.08'lik bir öngörü hatasına rastlanmaktadır. İndeks değeri ise % 9 civarında hızlı bir iniş yaşamış ve 19.110'den 17.258'ye gerilemiştir.

Grafik 5: 2000 Haftalar Bazında Hata Payları



21.01.2000 ve 28.01.2000 tarihlerine bakılacak olursa simülasyon sonucu %33.85'lik ve %14.36'lık bir hata gerçekleştirmiştir. Bu tarihte ise borsa bir hafta içerisinde ilk önce %5'lik bir artış ardından da %11'lik bir düşüş yaşamıştır. Tüm simülasyon içinde en yüksek sapmanın bu ay içerisinde yaşanması ise üzerinde durulması gereken noktadır çünkü bu tarihte piyasa otoriteleri tarafından gerçekte ciddi bir düşüş yaşanması bekleniyordu. Programın bunu bir önceki seansta tahmin etmiş olması bu araştırmada en ilgi çekiçi kısımlardan biri olmuştur. Bu yıla ait diğer önemli sapmalara ise 24.03, 21.04, 09.06 ve 17.11 tarihlerinde rastlanmaktadır. Bu tarihlerde ise simülasyon hataları sırasıyla %12.17, %10.25, %13.72, şeklindedir. Açıkça görülmektedir öngörü sonuçlarına yılın bu tarihlerde bir önceki yıla göre en az hatalarla ulaşılmıştır. Yine bu yıla ait siyasi ve politik gelişmeler ışığında bir analiz yapılacak olursa ocak ayı içinde endekste ard arda 2 gün boyunca %7.11 ve %5.36 değer artışı meydana gelmiştir. Bunda kar realizasyonu amacıyla borsada meydana gelen satışların da hemen alıcılar tarafından karşılanıyor olmasının payı büyüktür.

Simulasyon 2000 yılının 11. ayı içerisinde en olumsuz sonuçları vermiştir. Bunun sebebi araştırıldığında basında yine ekonomik ve siyasi birçok olumsuz habere rastlamak mümkündür. 08.11.2000 tarihinde açıklanan yüksek enflasyon rakamlarının düşüşe neden olduğu, söylentiler ve banka operasyonlarının yarattığı tedirginliklerin en üst noktaya ulaşması ile borsa değerinin % 2.67 düşüş yaşaması söylenilebilir. Borsa yeniden Kasım ayı içerisinde son bir yılın en sert düşüşünü yaşamış ve %7.13 gerilemiştir. Siyasi ve politik kararsızlıkların bu çalışmada nöral sistem tarafından algılanması beklenmemekle birlikte olumsuz sapmaların oluşması normal karşılanmıştır.

6. Sonuç

1997-2000 yılları arasında İstanbul Menkul Kıymetler Borsası'nda gerçekleşen borsa endeks değerinin tahminine ait YSA uygulamasında; girdi değerleri ile tahmin edilen çıktı değerleri karşılaştırıldığında, borsada gerçekleşen fiyatların tahmininde kullanılan nöral ağ sistemleri ve algoritmalarına ait matematiksel alt yapının daha da geliştirilerek sağlıklı sonuçlar alınması mümkün görülmektedir.

Hesaplamalara ait sayısal değerlendirilmelere bakıldığında, seçilen tüm girdi değerlerinin, İMKB100 endeks öngörüsüne aynı ölçüde etkide bulunduğu sonucuna varılmıştır.

Türkiye'de siyasi ve politik gelişmeler tüm sermaye piyasası araçlarına etki eden faktörlerin başında gelmektedir..

Bu çalışmada aşırı artış ve azalış olmayan ve siyasi etkilerin olmadığı günlerde daha başarılı çıktı değerleri verdiği söylenebilir. Simulasyon sonucu 1997 yılında %5.48, 1998 yılında %6.05, 1999 yılında %5.34, 2000 yılında ise % 6.62 hata ortalamaları vermiştir. Simulasyonun oldukça mükemmel sonuçlar verdiği rakamsal olarak gözüke de aslında sinaptik ağırlıklar matrisinde haftalık bazda sayısal tekrarlamalar nedeniyle eğitim aşamasında algoritmanın bir ezberleme ve kendini tekrar etme durumunda olduğundan bahsedilebilir. Fakat genel hata sonuçlarının %0.5-%33 arasında salınım göstermesi bu simulasyonun kısmende olsa başarıya ulaştığının bir göstergesi olmaktadır. Araştırmanın başında hata paylarının %40'ın altında olmasının beklentisi ile çalışmanın son kısımlarında elde edilen veriler karşılaştırıldığında "endeks değerinin bir sonraki işlem gününde ne olması" gerektiğinden çok "yüzde kaç olasılıkla ne olması gerektiği" sonucunu yakalamanın literatüre daha fazla katkı sağlayacağı sonucuna varılmıştır.

Kaynaklar

ADORF, H.M. (1989), Connectionism and Neural Networks: Knowledge Based Systems in Astronomy A.Heck ve F. Murtagh (Ed), Berlin: Springer-Verlag.

BAKLAVACI, S. (1984), Analysis of Learning Algorithms in Neural Networks. Msc Theses ITU Institute of Science and Technology, İstanbul.

BLUM, A.(1992), Neural Networks in C++. New York: John Wiley and Sons Inc.

BÖKESÖY, A. (1994), Interdependency Between IMKB and NYSE. (MBA Theses) Bilkent University Department of Management, Ankara.

CAO Q., LEGGIO K.B., SCHNIEDERJANS M. J. (2005), “A Comparison Between Fama and French’s Model and Artificial Neural Networks in Predicting the Chinese Stock Market”. Computers&Operations Research, Vol 32, 2499-2512

CHENG, W., MCCLAIN, B.W. and C. KELLY (1997), Artificial Neural Networks Make Their Mark As A Powerful Tool For Investors, Review Of Business, 4-9.

CİVELEK, Ö. (1999), “Dairesel Plakların Nöro Fuzzy Tekniği ile Analizi” Dokuz Eylül Üniversitesi Mühendislik Fakültesi Fen ve Mühendislik Dergisi Cilt 1 Sayı 2.

DENNIS, S. ve DEVIN, Mc. A. (1997), Introduction to Neural Networks and Brainwave Simulator. The University of Queensland School of Psychology. Internet Adresi; <http://www.itee.uq.edu.au/~cogs2010/cmc/chapters/IntroBrainWave>, Erişim Tarihi: 05.05.2008.

DUTTA, S. and SHEKHAR, S. (1988), Bond-Rating: A Non-Conservative Application of Neural Networks. Proceedings of the IEEE International Conference on Neural Networks 2,443-450.

FREEMAN, J. ve SAKAPURA, D. (1989), Neural Networks Algorithms Applications and Programming Techniques. Sydney: Addison Wesley Publishing.

GENÇAY, R. (1998), “The Predictability of Security Returns with Simple Technical Trading”, Journal of Empirical Finance, Vol 5, Issue 4, 347-359.

GILES C.L., LAWRENCE S., TSOI A.C. (1997), "Rule Inference For Financial Prediction Using Recurrent Neural Networks," Proceedings of the IEEE/IAFE Conf. on Computational Intelligence for Financial Engineering, 253, IEEE.

GÖKÇAY, M. M. (1993), Yapay Sinir Ağları ve Uygulamaları (Yayınlanamamış Yüksek Lisans Tezi). İstanbul Üniversitesi, İstanbul.

HAMİD S. A., IQBAL Z. (2004), “Using Neural Networks for Forecasting Volatility of S&P500 Index Future Prices”, Journal of Business Research, Vol 57, Issue 10, 1116-1125.

JAGOTA, A. (1998), Neural Computing Surveys, NCS Journal Volume 1 Internet Adresi; <http://www.icsi.berkeley.edu/~jagota/NCS/>, Erişim Tarihi: 06.08.2009.

KELLEY, M. (1998), "Cells&SCI Back to Basics Part I", Paraplegia News Articles, PN Magazine, New York.

KRYZANOWSKI, L., GALLER, M. and D. WRIGHT (1993), Using Artificial Neural Network to Pick Stocks. Financial Analysts Journal, 21-27.

LASKE, O. (1992), "A Conversation With Marvin Minsky", AI Magazine Vol 13 No:13.

LEIGH, W., PURVIS, R., RAGUSA, J.M. (2002a), Forecasting the NYSE Composite Index With Technical Analysis, Pattern Recognizer, Neural Network, and Genetic Algorithm: A Case Study In Romantic Decision Support, Decision Support Systems, Vol 32, Issue 4, 361-377.

LEIGHT, W., PAZ, M., PURVIS, R. (2002b), An Analysis of a Hybrid Neural Network and Pattern Recognition Technique for Predicting Short Term Increases In The NYSE Composite Index, Omega, Vol 30, Issue 2, 69-76.

LIN, F.C. and LIN, M. (1993), Analysis of Financial Data Using Neural Nets. AI Expert ,36-41.

MALLARIS M., SALCHENBERGER, L. (1996), Using Neural Networks to Forecast the S&P100 Implied Volatility, Neurocomputing, Vol 10, Issue 2, 83-195.

MOODY, J. (1995), Economic Forecasting: Challenges and Neural Network Solutions" Computer Science Department Graduate Institute Portland. Internet Erişimi, <http://neural.cse.ogi.edu; cd pub/neural/papers>, Erişim Tarihi: 04.03.2009.

ORR, G. (1994), "Computation In The Brain " Neural Networks Willamette University Salem Oregon Lecture Notes: No:1, Internet Erişimi; <http://www.willamette.edu/~gorr/classes/cs449/intro.html>, Erişim Tarihi: 16.03.2009.

ÖREN, T. (1990), Advances in Artificial Intelligence in Software Engineering. Vol I, New York: JAI Press Inc.

ÖZDEMİR, Ş. (1996), Hisse Senedi Fiyatlarını Etkileyen Değişkenlerin İstatiksel Analizi" (Yayınlanmamış Yüksek Lisans Tezi) Marmara Üniversitesi, İstanbul.

ÖZSOY, İ., FIRAT, M. (2004), "Kirişsiz Döşemeli Betonarme Bir Binada Oluşan Yatay Deplasmanın Yapay Sinir Ağları ile Tahmini", DEÜ Mühendislik Fakültesi Fen ve Mühendislik Dergisi, Cilt 6, Sayı 1 ,51-63.

RAO, V. VE RAO, H. V. (1993), C++ in Neural Networks and Fuzzy Logic, New York: MIS Press.

SIMPSON, P. K. (1991), Neural Network Paradigm, AGARD, 179,2 (1-33).

SUNGUR, M. (1995), Hesaplama Yönuyle Yapay Sinir Ağları: Öğrenme ve Eniyileme” Mühendis Gözüyle Yapay Sinir Ağları. ODTU-TUBITAK Elekt. Mühendisleri Odası IEEE Türkiye Şubesi Bilg. Kolu Yayını.

TRIPPI, R. R. (1996), Neural Networks in Finance and Investing. Irwin Professional Publishing.

TRIPPI, R. and DESIENO, D. Trading Equity Index Futures With a Neural Network, Journal of Portfolio Management, 27–33.

ULUSOY, T. (2001), Yapay Sinir Ağları Kullanılarak İstanbul Menkul Kıymetler Borsası İndeks Öngörüsü. Yayınlanmamış Yüksek Lisans Tezi. Başkent Üniversitesi, Sosyal Bilimler Enstitüsü.

WALCZAK, S. (2001), An empirical analysis of data requirements for financial forecasting with neural networks. Journal of Management Information Systems 17 4, 203–222

YAZICI, C. A., ÖĞÜŞ, E., ANKARALI, S., CANAN, S., ANKARALI, H., ve ZEKİ AKKUŞ (2007), “Yapay Sinir Ağlarına Genel Bakış”, (der.), Türkiye Klinikleri J. Med Sci 27:65-71.