

BİLGİ İŞLEMSEL ZEKA YÖNTEMLERİ İLE HİSSE SENEDİ FİYAT TAHMİNİ: BİST UYGULAMASI¹

Mehmet ÖZÇALICI*, Yücel AYRIÇAY**

Özet

Bu çalışmanın esas amacı bilgi işlemsel zeka yöntemlerinin finansal piyasalarda uygulanmasını sağlamak yoluyla kullanıcının, karmaşık tahmin modeline daha az müdahale ettiği uzman bir sistem tasarlamaktır. Araştırmacılar hisse senedi fiyatlarının teknik analiz değişkenleri ile birlikte önceden tahmin edilmesi ile ilgili çalışmalar yapmışlardır. Yapay sinir ağları hisse senedi fiyat tahmininde başarıyla kullanılan bilgi işlemsel zeka yöntemlerinden bir tanesidir. Yapay sinir ağları ile fiyat tahmini gerçekleştirilirken, hangi değişkenlerin seçileceğine ve ağ mimarisine kullanıcının karar vermesi gerekmektedir. Bu çalışmada söz konusu parametreleri belirleyecek genetik algoritma tabanlı uzman bir sistem tasarlanmıştır. t gününe ilişkin fiyat ve hacim bilgileri kullanmak suretiyle teknik göstergeler hesaplanmıştır. Özellik seçimi ve parametre optimizasyonu genetik algoritma ile eşzamanlı gerçekleştirilmiştir. Uzman sistem $t+1$ gününe ilişkin fiyat tahminlerini gerçekleştirmek için kullanılmıştır. Önerilen uzman sistemin, optimize edilmeyen modele göre daha iyi sonuçlar ortaya çıkardığı belirlenmiştir.

Anahtar Kelimeler: *Bilgi işlemsel zeka, Hisse senedi fiyat tahmini, Genetik algoritmalar, Yapay sinir ağları, Teknik analiz, Özellik seçimi*

STOCK PRICE FORECASTING WITH COMPUTATIONAL INTELLIGENCE TECHNIQUES: ISE APPLICATION

Abstract

The main aim of this study is to design an expert system where the intervene of the user to the complex forecasting system is minimized by employing computational intelligence techniques in financial markets. Researchers are interested in forecasting stock prices by using technical indicators. Artificial neural networks are one of the soft computing techniques that is used for forecasting stock prices. The user of the neural network must decide the size of the hidden layer and must select the optimal feature subset to obtain the best forecasting performance from network. In this study an expert system which is based on genetic algorithms is designed to optimize the parameters of the network. Technical indicators are calculated using price and volume information of day t . Feature selection and parameter optimization is handled simultaneously by using genetic algorithms. Expert system is used to forecast closing prices of day $t+1$. The results indicate that optimized model outperformed the alternative model in terms of statistical performance.

Keywords: *Soft computing, Stock price forecasting, Genetic algorithms, Artificial neural networks, Technical analysis, Feature selection*

¹ Bu çalışma 2015 yılında Kahramanmaraş Sütçü İmam Üniversitesi Sosyal Bilimler Enstitüsünde Mehmet Özçalıcı tarafından hazırlanan “Hisse Senedi Fiyat Tahminlerinde Bilgi İşlemsel Zeka Yöntemleri: Uzman Bir Sistem Aracılığıyla Bist Uygulaması” başlıklı doktora tezinden üretilmiştir.

* Yrd. Doç. Dr., Kilis 7 Aralık Üniversitesi, İktisadi ve İdari Bilimler Fakültesi, KİLİS.

e-posta: mozcatici@kilis.edu.tr

**Doç. Dr., Kahramanmaraş Sütçü İmam Üniversitesi, İktisadi ve İdari Bilimler Fakültesi, KAHRAMANMARAŞ.

e-posta:yucelayricay@hotmail.com

1.GİRİŞ

Hisse senedi fiyatlarını önceden tahmin etmek spekülörler, yatırımcılar ve işadamları için önem taşır. Hisse senedi fiyatlarının ne olacağını önceden tahmin edilmesi sadece spekülatif amaçlı alım satım yapan yatırımcılar için değil aynı zamanda, firma değerinin maksimizasyonunu amaç edinmiş finansal yöneticiler için ve genel olarak da bütün ekonomi için önem arz etmektedir. Ayrıca birçok farklı bilim dalında uzmanlaşan araştırmacılar, uzmanlık alanlarındaki gelişmeleri hisse senedi fiyat tahminlerindeki doğruluk oranını arttırmak için kullanılmaktadırlar. Bilgisayar teknolojisindeki gelişmeler ile birlikte yeni analizler ortaya çıkmış ve söz konusu analizler hisse senetlerinin tahmininde kullanılmaya başlanmıştır.

Etkin piyasalar hipotezi (EPH) 1960larda Eugene Fama'nın tezinden ortaya çıkmıştır ve herhangi bir zamanda hisse senedi fiyatlarının bütün mevcut bilgileri yansıttığını ifade etmektedir. Bu hipoteze göre eğer hisse senetlerinin fiyatları bütün mevcut bilgileri yansıtıyorsa, bir hisse senedinin fiyatı, gerçekte sahip olduğu değeri iyi bir şekilde yansıtır ve hiçbir yatırım stratejisi pazarın üzerinde geri dönüş oranı sağlayamaz (Kirkpatrick ve Dahlquist, 2007: 40). Etkin piyasalar, yanlış değer biçilmiş hisse senetlerini bulmak için var olan rekabetin çok yoğun olduğu piyasalar anlamına gelmektedir. Bu tür piyasalara yeni bir bilgi geldiğinde, yatırımcılar bu bilgiden faydalanmak isteyeceklerdir ve herhangi bir kar fırsatını saf dışı bırakacaklardır (Brealey vd., 2012: 211). Etkin piyasalar hipotezine göre bir piyasa etkin ise, hisse senedi fiyatını tahmin etmeye gerek yoktur çünkü bir sonraki gün hisse senedi fiyatı tamamen rastgele gerçekleşecektir (Fama, 1969). Bu durum nedeniyle, bazı

araştırmacılar teknik indikatörlerle fiyat tahminin geçersiz olacağını savunmaktadırlar.

Hisse senedi fiyatlarını tahmin etmek için başlangıçta geleneksel istatistiksel yöntemler kullanılmıştır. Söz konusu yöntemlerden bazıları AR, MA ve ARIMA gibi zaman serisi modellerini baz alan tahmin çalışmalarıdır. Fakat bu modeller veri seti hakkında istatistiksel varsayımları şart koşmaktadır. Başka bir ifade ile yöntemlerin kullanılabilmesi için veri setinde bazı şartların sağlanması gerekmektedir. Bu nedenle tahmin performansları kısıtlıdır (Hsieh vd, 2011).

Bunun yanı sıra, yapay sinir ağları, genetik algoritmalar, destek vektör makineleri ve bulanık tabanlı ağ çıkarım sistemi gibi bilgi işlemsel zeka yöntemleri (computational intelligence) geliştirilmiş ve bu yöntemler hisse senedi fiyat tahmininde kullanılmaya başlanmıştır. Bilgi işlemsel zeka yöntemleri, geleneksel istatistiksel yöntemlerini yetersiz kılacak kadar karmaşık gerçek hayat problemlerini çözmeye çalışan ve doğadan esinlenen hesaplama yöntemleridir (Chen vd., 2007). Bilgi işlemsel zeka yöntemlerini kullanan çalışmalarda elde edilen başarılar etkin piyasalar hipotezi ile çelişir niteliktedir. Bu tür çalışmalarda, hisse senetlerinin fiyatlarının başarılı bir şekilde tahmin edilebileceği ve etkin piyasalar hipotezinin geçerli olmadığı savunulmaktadır (Atsalakis ve Valavanis, 2009; Atsalakis vd., 2011; Chang vd., 2012).

Bilgi işlemsel zeka yöntemlerinden olan yapay sinir ağları hisse senedi fiyat tahmininde başarılı bir şekilde kullanılmıştır. Fakat yapay sinir ağlarının hisse senedi fiyat tahminindeki performansına karşılık, uygulanmasını zorlaştıran bazı ayrıntıları söz konusudur.

Bu ayrıntılar, özellik seçimi, yapay sinir ağı mimarisine karar verme ve ağı eğitimi gibi hususlardır. Bu ayrıntılar yapay sinir ağlarının performansı ile de yakından ilgilidir.

Yapay sinir ağı modeli ile başarılı bir hisse senedi fiyatı tahmin işlemi gerçekleştirmek için, kullanılacak değişkenlere, yapay sinir ağı mimarisine ve aşırı uyum olumsuzluğunu engelleyecek bir yönteme ihtiyaç duyulmaktadır. Bu olumsuzlukların hepsini ortadan kaldıracak mevcut bir yöntem söz konusu değildir. Bu çalışmanın amacı bilgi işlemsel zeka ailesinin bir üyesi olan genetik algoritmalar ile söz konusu eksiklikleri giderecek uzman bir sistem tasarlamaktır. Genetik algoritma, sezgisel bir optimizasyon yöntemidir (Svanandam ve Deepa, 2008) ve çözüm uzayında yer alan olası bütün çözümlerden en iyisinin seçilmesini sağlar. Söz konusu bu sistemde uygunluk fonksiyonu, aşırı uyum durumunu engelleyecek şekilde tasarlanmıştır. Aynı şekilde yapay sinir ağı ara katmanında yer alan nöron sayısını ve kullanılacak değişken miktarını eşzamanlı belirleyebilecek bir gen tasarlanmıştır. Tasarlanan bu sistem kullanıcının yapay sinir ağları modeline mümkün olduğunca az müdahale ettiği uzman bir sistemdir.

Çalışmada önerilen modelin ne kadar iyi performans gerçekleştirdiğini ortaya çıkarmak için ikinci bir model daha kullanılmıştır. Bu model alternatif model olarak adlandırılmıştır ve bir seçim işlemi uygulanmadan bütün değişkenler modelde girdi olarak kullanılmıştır. Ayrıca ara katmandaki nöron sayısı da 10 tanede sabit tutulmuştur. Fiyat tahmini gerçekleştirildikten sonra, model sonuçlarının ne kadar iyi olduğu istatistiksel performans ölçüleri ile incelenmiştir.

Çalışma toplamda altı bölümden oluşmaktadır. Bu giriş bölümünden sonra ikinci bölümde konu ile ilgili önceki

araştırmalar incelenmiştir. Üçüncü bölümde ise çalışmada kullanılan yöntemler ile önerilen model tanıtılmıştır. Dördüncü bölümde uygulamaya yer verilmiştir. Beşinci bölümde elde edilen analiz sonuçları sunulmuş ve istatistiksel test sonuçlarına yer verilmiştir. Son bölümde ise sonuç ve tartışma yer almaktadır.

2. KONU İLE İLGİLİ ÖNCEKİ ARAŞTIRMALAR

Hisse senedi fiyat tahmini ile ilgili yapılan çalışmalar farklı şekillerde sınıflandırılabilir. Örneğin hisse senedi fiyat tahmini gerçekleştiren çalışmalar olduğu gibi, indeks kapanış fiyatını gerçekleştiren çalışmalar da mevcuttur. Aynı şekilde hisse senedindeki yönün tahmin edildiği çalışmalar (hisse senedinin fiyatı yarın bugünkünden daha yüksek veya düşük olacak gibi) ile hisse senedi fiyatı nokta tahmini gerçekleştiren çalışmalar da mevcuttur. Bu çalışmalardan bazıları şu şekilde özetlenebilir.

Diler (2003)'in yaptığı çalışmada BIST 100 endeksi getirilerinin yönünü bir gün önceden tahmin etmeye çalışılmıştır ve bu amaçla yapay sinir ağları modeli kullanılmıştır. Çalışmada %60,81 oranında fiyat yönü doğru bir şekilde tahmin edebilmiştir.

Tektaş ve Karataş (2004) yılında yayınladıkları çalışmalarında çimento ve gıda sektörlerinde faaliyet gösteren işletmelerin hisse senedi fiyatlarını, yapay sinir ağları ile tahmin etmişlerdir. Çalışmalarında tahmin performansı olarak korelasyon katsayısı kullanılmıştır. Çalışma sonunda yapay sinir ağlarının performansının regresyon yöntemine göre daha yüksek olduğu belirlenmiştir.

Karaatlı ve arkadaşları (2005) yaptıkları çalışmada BIST endeksinin kapanış fiyatını tahmin etmeye çalışmışlardır.

Yapay sinir ağları ve regresyon yöntemi ile tahminler gerçekleştirilmiştir ve yapay sinir ağlarının regresyon yöntemine göre daha iyi sonuç verdiği ortaya çıkmıştır. Girdi olarak faiz oranları, altın fiyatı, enflasyon oranı, sanayi üretim endeksi, tasarruf mevduatı faiz oranı, Dolar kurunu kullanmışlardır ve aylık tahminler gerçekleştirilmiştir. Performans ölçüsü olarak RMSE (Root Mean Squared Error) kullanılmıştır.

Altay ve Satman (2005) BIST endeksinin nokta tahmini ve yön tahminini gerçekleştirmişlerdir. Çalışmada yöntem olarak yapay sinir ağlarını ve regresyonu kullanmışlardır. Regresyon sonuçları nokta tahmininde yapay sinir ağlarından çok da farklı çıkmadığı raporlanmaktadır. Fakat yön tahmininde ve alım satımda yapay sinir ağları, regresyon analizine göre daha iyi performans gösterdiği belirlenmiştir.

Ince ve Trafalis (2007) yayınladıkları çalışmalarında, hisse senetleri tahmin çalışmasında değişken seçimi üzerinde durmuşlardır. NASDAQ borsasında işlem gören 10 hisse senedi fiyatı, yapay sinir ağları ve destek vektör regresyon (support vector regression) ile tahmin edilmeye çalışılmıştır. 100'den fazla teknik değişken hesaplamışlardır. Çalışmaları sonucunda, uzman bilgisine dayalı sezgisel değişken seçimi yönteminin, PCA ve faktör analizine göre daha iyi sonuç verdiği ortaya çıkmıştır. Güngör ve Tortu (2007) ise çalışmalarında esnek hesaplama yöntemlerini tanıtmışlardır. Doğrusal regresyon ve esnek hesaplama yöntemleri ile bazı hisse senetlerinin fiyatlarını ve BIST 100 endeksini tahmin etmişlerdir. Döviz kuru, faiz oranları ve altın fiyatları gibi temel analiz değişkenleri kullanılmıştır. Çalışmanın sonucunda yüksek belirlilik katsayısı elde ettiklerini raporlamaktadırlar.

Toraman ise (2008) çalışmasında demir-çelik sektöründe faaliyet gösteren iki adet firmaya ilişkin hisse senetleri fiyatlarını tahmin etmiştir. Çalışma sonucunda az hata ile hisse senedi fiyatı doğru bir şekilde tahmin edilebildiği raporlanmaktadır. Yıldız ve arkadaşları (2008) çalışmalarında, yapay sinir ağlarını, BIST 100 endeksini bir gün sonraki yönünü tahmin etmede kullanmışlardır. Girdi olarak en yüksek, en düşük, kapanış fiyatı ve TL-Dolar kuru gibi değişkenler kullanılmıştır. Çıktı değişkeni ise bir gün sonraki indeks yönüdür. 1805 gözlem yapay sinir ağının eğitimi için kullanılırken, 100 adet gözlem ise modelin performansını karşılaştırmak için kullanılmıştır. Çalışmalarında %54,37 oranında doğru tahmin gerçekleştirebilmişlerdir.

Atsalakis ve Valavanis (2009) yılında yaptıkları çalışmada hisse senetlerindeki fiyat değişimlerini kısa dönemli olarak önceden tahmin etmeye çalışmışlardır. Çalışmalarının sonunda, geçmiş fiyat hareketlerinin, gelecekteki fiyat hareketlerini doğrulukla tahmin edebileceği ortaya çıkmıştır.

Hao (2010), kısa dönemli hisse senedi tahminini genetik algoritmalar ve yapay sinir ağları kullanmak suretiyle gerçekleştirmiştir. Ara katmanda 16 adet nöron kullanmışlardır. Tahmin edilen fiyatlar ile gerçek fiyatlar arasındaki korelasyon katsayısı ile tahmin performansı değerlendirilmiştir. Tsai ve Hsiao (2010), çalışmalarında ideal bir hisse senedi fiyat tahmini için özellik seçimi üzerinde durmuşlardır. Yazarlar farklı özellik seçim yöntemlerini kullanmışlar ve modellerin performanslarını karşılaştırmışlardır. Çalışmalarında birden fazla özellik seçim modellerinin, tek bir adet özellik seçimi uygulanan modellere göre daha iyi sonuç verdiğini raporlamaktadırlar.

Cheng ve arkadaşları (2010) yayınladıkları çalışmalarında rough set teori ve genetik algoritma tabanlı bir hisse senedi fiyat tahmin modeli geliştirmişlerdir. Çalışmalarında altı yılı kapsayan Taiwan Stock Exchange Capitalization Weighted Stock Index veri setini kullanmışlardır. Çalışmanın sonucunda, önerdikleri yöntemin, tekbaşına rough set teorisi yöntemi veya genetik algoritma yöntemi ile elde edilen sonuçlardan daha başarılı sonuçlar üretebildiği ve bu sonuçların alım satımında kullanılması sonucu daha yüksek kar elde edilebildiği raporlanmaktadır.

Öz ve arkadaşları (2011) çalışmalarında BIST 30 endeksine dahil olan hisse senetlerinin getirilerini önceden tahmin etmişlerdir. Bir ve iki yıl öncesine ait finansal oranlar kullanılmıştır ve diskriminant analizi yardımıyla hisse senetlerinin getirileri tahmin edilmiştir. Analiz sonuçlarına göre iki yıl öncesine ait oranların kullanıldığı modeldeki başarı oranı daha yüksek çıkmıştır. Kara ve arkadaşları (2011) yılında yayınladıkları çalışmada BIST100 endeksini destek vektör makineleri ve yapay sinir ağları ile tahmin etmişlerdir. 10 adet teknik gösterge kullanılmıştır. Veri seti [-1.0, 1.0] arasında ölçeklendirilmiştir. Çalışmaları sonucunda yapay sinir ağları ortalama %75.74 oranında doğru tahmin gerçekleştirirken, destek vektör makineleri ile %71.52 oranında doğru tahmin gerçekleştirebilmişlerdir. Hisse senedi fiyat tahmininde bilgi işlemsel zeka yöntemleri kullanılırken, yöntemle ilişkin parametrelerin doğru belirlenmesi gerekmektedir. Hsieh vd. (2011) yapay sinir ağları ile gerçekleştirilecek tahminlerde parametrelerin, deney tasarımı ile belirlenmesini önermektedirler. Çalışmalarının sonucunda %84' e kadar doğru yön tahmini gerçekleştirebilmişlerdir.

Adebiyi ve arkadaşları (2012) yayınladıkları çalışmalarında

melezleştirilmiş piyasa göstergeleri ve yapay sinir ağları yardımıyla hisse senedi fiyat tahmini gerçekleştirmişlerdir. Çalışmalarında temel ve teknik analiz göstergelerini kullanmaktadır. Farklı yapay sinir ağı mimarilerini denemişlerdir. Melezleştirilmiş yaklaşımın, sadece teknik analiz göstergelerinin kullanıldığı duruma göre daha iyi sonuç verdiğini raporlamaktadırlar. Yang ve arkadaşları (2012) melez bir yöntemle hisse senedi fiyat tahmini gerçekleştirmişlerdir. Çalışmalarında kullanılan esas yöntem bulanık yapay sinir ağlarıdır ve genetik algoritma tabanlı kural keşfi gerçekleştirilmektedir. Wu ve Lu (2012) yılında yayınladıkları çalışmalarında, Bilgi İşlemsel Zeka Yöntemleri yaklaşımlarını bir araya getirmişlerdir. Çalışmalarında kullandıkları veri seti Taiwan Stock Exchange Capitalization Weighted Stock Index (TAIEX) den oluşmaktadır. Çalışmaları sonucunda melez yöntemlerin daha iyi sonuçlar ürettiği raporlanmaktadır.

Karaca ve Başdemir (2012) ise çalışmalarında 20 adet şirkete ait hisse senetlerinin getirilerini yapay sinir ağları ile önceden tahmin etmeye çalışmışlardır. 21 adet girdi değişkeni kullanmışlardır ve modelin performansı için MSE değerini kullanmışlardır. Girdi olarak firmalara ait finansal oranlar kullanılmıştır. Aygören vd. (2012) BIST 100 endeksinin tahmininde yapay sinir ağları ve Newton nümerik arama modellerinin kullanmışlardır. MSE ve R^2 ile modellerin performansı karşılaştırılmış ve yapay sinir ağlarının daha iyi performans gösterdiği ortaya çıkmıştır. Erdoğan ve Özyürek (2012) BIST 100 endeksinde bulunan beyaz eşya firmalarının günlük fiyatları, yapay sinir ağları kullanmak suretiyle tahmin edilmiştir. Dolar kuru, BIST endeksi ve diğer günlere ait kapanış fiyatları kullanmak suretiyle Cuma gününe ait kapanış fiyatı tahmini gerçekleştirilmiştir.

3. METODOLOJİ

Hisse senedi tahmin yöntemlerinde temel analiz ve teknik analiz değişkenlerini kullanıldığı görülmektedir. Temel analiz değişkenleri, borsa, enflasyon oranı, faiz oranları, başka ülkelerin borsa değerleri gibi değerlerdir (Atsalakis ve Valavanis, 2009). Teknik analiz ise, hisse senedinin geçmiş fiyatlarının (genellikle grafik şeklinde) kaydedilmesi ve bu kayda alınan geçmiş bilgilere bakmak suretiyle, gelecekte olması muhtemel yüksek getirili eğilimlerin tahmin edilmesi ile uğraşan bir bilimdir (Edwards vd., 2007: 4).

Bilgi işlemsel zeka yöntemleri ile (Computational Intelligence), geleneksel istatistiksel ve mühendislik yöntemlerinin çözmekte başarılı olamayacakları işletmecilik ve ekonomi problemlerini çözecek yöntemler geliştirilmeye çalışılmaktadır. Geleneksel yöntemlerde çözüme ulaşabilmek için problemin teorik temellere dayandırılması gerekmektedir. Teorik temellere dayanan çözümler ise çoğunlukla doğrusal ve gerçekçi olmayan varsayımları şart koşmaktadır. Bilgi işlemsel zeka yöntemleri ise insan zihninin bir uzantısı gibi çalışan bilgisayarlaştırılmış sistemlerdir. Bu yöntemler insanın düşünme şeklini, biyolojik sistemleri veya diğer doğal sistemleri taklit etme ve karmaşık hesaplamaları insan zihninden çok daha hızlı gerçekleştirebilme yeteneğine sahiptir. Bu gibi avantajları bilgi işlemsel

zeka yöntemlerini karar verme sürecinde tercih edilebilir hale getirmektedir (Chen vd., 2007).

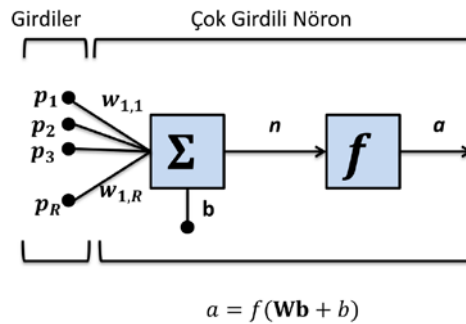
3.1. Yapay Sinir Ağları

Yapay sinir ağlarının en temel ve basit bilgi işleme birimi nöronlardır. Şekil 1'de temel bir nöron modeli görülmektedir.

Basit bir nöronal modelin üç adet özelliği söz konusudur (Haykin, 1999: 32).

- Bir dizi ağırlıklar vardır. Örneğin girdi sinyali p_j nöron k ile w_{kj} ağırlığı ile bağlanmıştır. Başka bir ifade ile girdi sinyali ilgili ağırlıkla çarpılacaktır. Ağırlıkların isimlendirilmesi önemli olmaktadır. Bir ağırlığın indisindeki ilk gösterge nöronu ifade ederken, ikinci gösterge girdiyi ifade etmektedir. Ağırlıklar pozitif olabileceği gibi negatif de olabilmektedir.
- Toplama birimi. Bu birim kendisine gelen sinyallerin toplanmasını sağlar.
- Aktivasyon fonksiyonu. Bir nöronun çıktısının genişliğini sınırlayan fonksiyondur.

Şekil 1'de ayrıca eğim b de görülmektedir. Bu eğim aktivasyon fonksiyonunun net girdisini azaltabilme veya arttırabilme özelliğine sahiptir. Pozitif veya negatif olabilmektedir.



Şekil 1: Tek Katmanlı ve Tek Nöronlu Yapay Sinir Ağı

Matematiksel olarak bir nöron iki adımda, şu şekilde ifade edilebilir.

$$n = w_{1,1}p_1 + w_{1,2}p_2 + \dots + w_{1,R}p_R + b \quad (1)$$

yukarıdaki denklem matris notasyonu ile daha kısa bir şekilde ifade edilebilir. Matris notasyonunda çarpımı

$$n = \mathbf{W}_p \quad (2)$$

$$a = f(\mathbf{W}_p + b) \quad (3)$$

Bu denklemlerde p_1, p_2, \dots, p_n girdi sinyallerini; w_1, w_2, \dots, w_m ise nöronun ağırlıklarını; n girdi sinyallerinin toplamını; b eğimi; f aktivasyon fonksiyonunu ve a nöronun çıktısını temsil etmektedir.

Çok katmanlı sanal nöronlar öğrenme, sınıflandırma, ve tahmin gibi görevleri gerçekleştirmek için kullanılmaktadırlar ve insan beyninin çalışma biçimini taklit eden yapay sinir ağlarıdır. Yapay Sinir ağı modeli neuron olarak adlandırılan işlem birimlerinin bir araya gelmesi ile oluşmaktadır. Her bir nöron diğer nöronlara ağırlıkları içeren bağlantılarla bağlanmış durumdadır. Girdi bağlantısı olmayan nöronlar girdi nöronları olarak adlandırılırken, çıktı bağlantısı olmayan nöronlar çıktı nöronları olarak adlandırılmaktadır. Yapay sinir ağlarında paralel işlem görmek esastır. Girdi nöronları, çıktı nöronları ve bunlar arasındaki ağırlıkları içeren bağlantılar çok katmanlı sanal nöronun mimari yapısını oluşturmaktadır.

Yapay sinir ağlarının denetimli ve denetimsiz öğrenmeyi uygulayan çeşitleri mevcuttur. Eğer çıktı değişkeni biliniyorsa ve yapay sinir ağlarındaki ağırlıklar bu çıktı değişkenine en yakın değerleri üretmek için eğitiliyorsa, denetimli öğrenme söz konusudur. Bu çalışmada denetimli öğrenme uygulanmaktadır. Bunun yanında çıktı değişkeni bilinmiyorsa, veri setinde denetimsiz öğrenme uygulanacaktır. Denetimsiz

ifade etmek için koyu font kullanılmaktadır. Yukarıdaki denklem şu şekilde de ifade edilebilir:

öğrenme kümeleme analizi için idealdir. Denetimsiz öğrenme yöntemini uygulayan yapay sinir ağlarının banka müşterilerini kümeleme konusunda örnek bir uygulama için (Özçalıcı, 2011) kaynağına başvurulabilir.

3.1.1. Yapay Sinir Ağlarının Avantajları ve Dezavantajları

Yapay sinir ağlarının bazı avantaj ve dezavantajlarına Kecman (2001: 12) değinmiştir ve aşağıdaki gibi özetlenebilir:

Yapay sinir ağlarının bazı avantajları;

İnsanların öğrenme şeklini taklit edebilirler ve veri setinden öğrenme sağlanmaktadır. Birçok doğrusal olmayan çok değişkenli problemi çözebilirler. Üzerinde çalışılan problem veya süreç hakkında detaylı bilgiye gereksinim duyulmaz. Gürültülü veri setinden çok etkilenmezler. Paralel yapıdadırlar ve donanımlarda kolaylıkla kullanılabilirler. Farklı nitelikteki problemler aynı yapay sinir ağı modeli ile çözülebilir.

Yapay sinir ağlarının bazı dezavantajları;

Birçok gerçek hayat probleminin çözümü için aşırı uzun eğitim ve öğrenme zamanına ihtiyaç duyulur. Değişkenler arasındaki ilişkiyi açığa çıkarmaz ve süreç hakkındaki bilgimizi arttırmamızı sağlamazlar. Kötü genelleştirmelere eğilimleri vardır (aşırı uyum gibi).

Yapay sinir ağları yapısı veya optimizasyon prosedürü hakkında hiç yok denecek kadar az rehberlik söz konusudur (belirli bir problem için hangi yapının kullanılması gerektiği gibi).

3.2. Genetik Algoritma

Genetik algoritma doğal evrimden esinlenmek suretiyle geliştirilmiş sezgisel optimizasyon yöntemidir. Daha geniş bir kapsamda, genetik algoritma, seçim ve çaprazlama yöntemlerini uygulamak suretiyle arama uzayında yeni noktalar yaratan, anakütle tabanlı optimizasyon algoritmasıdır (Armano vd., 2005).

1960'lardan beri, zor olan optimizasyon problemlerinin çözümü için güçlü algoritma geliştirme çabaları söz konusudur. Bu çabaları ifade etmek için *evrimsel hesaplama* terimi kullanılmaktadır. Bu sınıfın içinde yer alan en çok tanınan algoritmalarından birisi de Holland tarafından literatüre tanıtılan genetik algoritmalarıdır. Genetik algoritmalar, günümüzün en çok bilinen evrimsel hesaplama çeşididir (Gen ve Cheng, 2000: 1).

Genetik algoritmalar John Holland'ın 1975 yılındaki "Adaptation in Natural and Artificial Systems" adlı kitabında ilk kez tanıtılmıştır (Holland, 1992). Holland kitabında GA'ı "güçlü olan hayatta kalır" anlayışına dayalı sezgisel bir metod olarak tanıtmıştır ve ilk tanıtıldığı günden bu güne arama ve optimizasyon problemlerinde faydalı bir şekilde kullanılmaktadır.

Genetik algoritma temelde beş temel bileşenden oluşmaktadır (Michalewicz, 1996):

1. Çözümlerin genetik temsili
2. Başlangıç popülasyonunun oluşturulması
3. Uygunluk fonksiyonunun belirlenmesi
4. Yeniden üretim sürecinde genetik bileşenlerin değiştirilmesi
5. Genetik algoritma problemlerinin değerleri

Genetik algoritma prosedüründe bir grup bireyden oluşan popülasyon söz konusudur. Bu popülasyon, t nesili için $P(t)$ ile temsil edilmektedir. Her bir birey, üzerinde çalışılan problem için aday çözümü temsil etmektedir. Her bir birey uygunluk değeri ile değerlendirilmektedir. Bazı bireyler, genetik işlemler (operasyonlar) yardımıyla yeni bireyler oluşturmak üzere değişikliğe uğramaktadırlar. İki çeşit değişiklik söz konusudur. Bu değişiklikler, tek birey üzerinde değişiklik yapan mutasyon ve iki farklı bireyin farklı parçalarını bir araya getiren çaprazlamadır. $C(t)$ ile isimlendirilen yeni bireyler değerlendirmeye alınmaktadır. Ana popülasyon ve yavruların yer aldığı yeni popülasyondan en iyi bireyler bir araya getirilmek yoluyla yeni bir popülasyon oluşturulmaktadır. Birkaç nesil (yenileme) sonucunda, algoritmanın optimal veya optimale yakın en iyi bireyi tespit etmesi beklenmektedir. Genetik algoritmaların genel yapısı Şekil 2'deki gibidir (Gen ve Cheng, 2000: 1):

Prosedür: Genetik Algoritmalar

Başla

$t = 0;$

Başlangıç $P(t)$ anakütlesinin oluşturulması;

$P(t)$ nin değerlendirilmesi;

while bitirme şartı sağlanmadığı müddetçe **do**

başla

$C(t)$ 'yi elde etmek için $P(t)$ yi çaprazla

$C(t)$ 'nin değerlendirilmesi;

$P(t)$ ve $C(t)$ den $P(t + 1)$ yi oluştur

$t = t + 1;$

bitir

bitir

Şekil 2: Genetik Algoritmaların Temel Presüdüğü

(Kaynak: Gen ve Cheng, 2000: 1)

3.2.1. Genetik Algoritmanın Avantajları ve Kısıtları

Genetik Algoritmanın bazı avantajları ve kısıtları şu şekilde sıralanabilir (Svanandam ve Deepa, 2008: 34):

Genetik Algoritmanın avantajları;

Paralel işlem yapabilme yeteneği, Güvenilirlik (liability), çözüm uzayının geniş olması, Global optimumun keşfedilmesinin kolay olması, büyük ve az anlaşılmiş çözüm uzaylarında işlem yapmanın kolay olması, uygunluk fonksiyonunun değerlendirilmesinde yaşanan zorluklara karşı dayanıklı (robust) olması, yerel optimuma yakalanmaya karşı dirençli olması, büyük çaptaki optimizasyon problemlerinde iyi performans sergilemesi, geniş optimizasyon problemleri için kullanılabilirler.

Genetik Algoritmaların kısıtları (dezavantajları) ise şu şekildedir:

Uygunluk fonksiyonunun belirlenme problemi, popülasyon büyüklüğü, mutasyon oranı, çaprazlama oranı, seçim oranı ve gücü gibi parametrelerin belirlenmesinin zorluğu, probleme özel bilgilerin kolaylıkla yönetilmesinin mümkün olmaması, etkin sonlandırıcının olmaması (Ne zaman durulacağıının tam olarak bilinmemesi),

uygunluk fonksiyonunun çok sayıda değerlendirilmesine ihtiyaç duyulması, yapılandırmanın basit olmaması.

3.3. Önerilen Modelin Tasarımı

Daha önce yapılan araştırmalar incelendiğinde, yapay sinir ağları ile hisse senedi fiyatı tahmini gerçekleştirmek için iki adet çok önemli karar verilmesi gerektiği anlaşılmaktadır. Bunlardan birincisi, tahmin için kullanılacak değişkenlerin belirlenmesidir. Çok fazla sayıda teknik göstergenin hesaplanması mümkündür. Fakat bu değişken havuzundan en başarılı tahmini gerçekleştirecek değişkenlerin seçimi için mevcut bir yöntem söz konusu değildir. İkinci önemli husus ise ara katmanda yer alacak nöron sayısının belirlenmesidir. Literatürdeki çalışmalarda deneme yanılma yoluyla veya bazı kurallara göre ara katmandaki nöron sayısının belirlendiği görülmektedir. Bu çalışmada ise melez bir yöntem sayesinde ara katmanda yer alması gereken nöron sayısı ile birlikte kullanılacak değişkenler genetik algoritmalar yardımıyla belirlenecektir. Bu amaçla özel bir uygunluk fonksiyonu ve özel bir gen tasarlanmıştır.

Yapay sinir ağları ile tahmin gerçekleştirmek için öncelikle yapay sinir ağlarının yapısının belirlenmesi gerekir.

Ayrıca yapay sinir ağlarının, çıktıyı başarılı bir şekilde tahmin etmesini sağlayacak girdi bileşiminin de belirlenmesi gerekir. Bu iki özellik rastgele belirlenebilir. Fakat böyle bir durumda başarı şansının düşük olması beklenir. Bir başka seçenek ise söz konusu özelliklerin, hisse senedi fiyatı tahmini konusunda deneyimli uzmanlar tarafından gerçekleştirilmesidir. Uzmanlar hangi teknik göstergenin, hangi hisse senedi için al veya sat sinyali verdiğini, deneyimlerine ve bilgilerine dayanmak suretiyle belirleyebilirler. Fakat uzman bilgisine başvurmanın zor, imkansız veya maliyetli olduğu durumlar söz konusu olabilir. Uzman bilgisinin her istendiğinde mevcut bulunmadığı da göz önünde bulundurulmalıdır.

Yukarıda yer alan problemlerin çözümü için belirgin bir sayısal yöntem söz konusu değildir. Bu nedenle bu gerçek problemlerin çözülebilmesi için sezgisel optimizasyon yöntemleri kullanılabilir. Sezgisel optimizasyon yöntemleri çözümü zor olan problemler için olası en iyi çözümü bulmayı amaçlayan bilgisayar programlarıdır.

Bu çalışmanın amacı yukarıda değinilen kısıtlar için melez bir yöntemi tanıtmaktır. Çalışmada, genetik algoritma, yapay sinir ağının ara katmanında yer alan nöron sayısını ve girdi bileşimini eş zamanlı optimize etmek için kullanılacaktır. Genetik algoritmalarda her bir aday birey bir gen ile temsil edilmektedir. Çalışma için tasarlanan özel gen yardımıyla farklı nitelikte olmasına rağmen her iki özelliğin de eş zamanlı optimizasyonu gerçekleştirilebilmektedir. Değişken seçimi problemlerinde kaç adet değişkenin seçileceğine karar vermek gerekmektedir. Farklı sayılarda değişken tercih edilmesi farklı sonuçların alınmasına neden olabilir. Bu çalışma için tasarlanan özel gen, optimal değişken sayısını da belirleyebilmektedir.

3.3.1. Genetik Algoritma Parametreleri

Çalışmada genetik algoritmalar, yapay sinir ağlarının yapısını optimize etmek ve değişken seçimini gerçekleştirmek için eş zamanlı kullanılacaktır. Genetik algoritma özel bir problem çeşidi olan hisse senedi fiyatı tahmin problemine uygulanacaktır. Genetik algoritmanın söz konusu problemi çözebilmesi için uygun bir gen tasarımının ve uygunluk fonksiyonunun varolması gerekmektedir. Ayrıca bazı parametrelerin belirlenmesi gerekmektedir.

Çalışmada MATLAB yazılımı kullanılmıştır. Çalışmada kullanılan genetik algoritmaya ilişkin parametreler ise şu şekildedir:

- Başlangıç popülasyonu :
gacreationlinearfeasible.
Çalışmanın genetik algoritmaları açıklayan bölümünde genetik algoritmaların rastgele değerlerden oluşan bir başlangıç anakütlesi ile başladığı açıklanmıştı. Bu çalışmada bazı alt ve üst sınırlar söz konusudur. Bu nedenle bu sınırlar dahilinde bir anakütle oluşturmak için farklı bir yerleşik fonksiyon olan gacreationlinear feasible tercih edilmiştir.
- Çaprazlama fonksiyonu :
crossoverintermediate
- Çaprazlama oranı : 0.8
- Elit Değeri : 2
- Mutasyon fonksiyonu =
mutationadaptfeasible
- Seçim fonksiyonu =
selectionstochunif.

- Nesil (Generation) sayısı = 100. Diğer koşullar nedeniyle genetik algoritmanın çalışması durdurulmadığı müddetçe 100 nesil çalışmaya devam edecektir.
- Fonksiyon toleransı : 1e-6. Bu değerden daha iyi bir değer elde edilemediğinde genetik algoritma durmaktadır.

3.3.1.1. Kromozom Tasarımı

Bu çalışmada hisse senedi fiyatının önceden tahmin edilebilmesi için yapay sinir ağlarından faydalanılacaktır. Tek

katmanlı bir yapay sinir ağında gizli katmanda yer alması gereken nöron sayısının ve seçilecek değişkenlerin belirlenmesi gerekmektedir. Bu çalışmada bu iki özellik genetik algoritma yardımıyla eş zamanlı optimize edilecektir.

Çalışmada kullanılan koromozom iki kısımdan oluşmaktadır. İlk kısım yapay sinir ağının ara katmanında yer alması gereken nöron sayısını temsil ederken, kromozomun geri kalan kısmı başlangıçtaki değişken kümesinde değişkenlerin seçilme durumunu temsil edecektir.

n	f_1	f_2	f_3	f_4	f_5
-----	-------	-------	-------	-------	-------

n : Ara katmanda kullanılması gereken değişken sayısı
 f_n : seçilen değişkenlerin indisleri

Şekil 3: Çalışmada Kullanılan Gen Tasarımı

Şekil 3 'de çalışmada kullanılan kromozom tasarımı görülmektedir. Kromozomun ilk kısmı olan ve n sembolüyle gösterilen kısım ara katmanda yer alacak nöron sayısını temsil etmektedir. Ara katmanda yer alan nöron sayısının belirli bir sınır dahilinde olması gerekmektedir. Fazla sayıda nöronun kullanılması veya az sayıda nöronun kullanılması, iyi sonuçların alınmasını engelleyebileceği gibi, bilgisayarı cevap vermeyecek bir durumda bırakabilir. Bu nedenle de ara katmandaki nöron sayısının en az 2 en fazla 30 değerinin alınmasını sağlayacak kısıtlama getirilmiştir. Koromozomun geri kalan kısmında yer alan ve f_k ile gösterilen kısım ise 1 veya 0 değerini almaktadır. f_k değerinin bir olması durumunda aday değişken sıralamasında k . sırada yer alan değişken modelde kullanılacaktır. Değerin sıfır olması durumunda ise k . sırada yer alan değişken analizde kullanılmayacaktır.

Değişken seçimi probleminde kaç adet değişkenin seçilmesi gerektiği önem

arz etmektedir. Araştırmacı kaç adet değişken kullanacağını belirlemesi gerekmektedir. Örneğin, bir problem çözüldükten, biraraya getirilen değişken havuzundan en iyi sonucu verecek X adet değişkenin seçilmesi gerekir gibi bir noktaya varılmış olabilir. Fakat söz konusu X değerinin neye göre belirleneceği problemi ortaya çıkmaktadır. Her ne kadar genetik algoritma, X adet en iyi değişkeni seçecek şekilde programlanabilse de, X değerinin belirlenmesi önemli problemleri de beraberinde getirmektedir. Örneğin $X+2$ veya $X-2$ adet değişken seçilmesi durumunda sistemin performansı nasıl değişecektir? Performans artabiliyorsa, X 'den farklı sayıdaki değişkenlerin kullanılmasında fayda olacaktır. Önerilen modelde yer alan gen tasarımı bu problemi ortadan kaldırmaktadır. Özel olarak bu çalışma için tasarlanan gen yardımıyla, kaç adet hangi değişkenin kullanılması gerektiği genetik algoritma tarafından belirlenebilmektedir.

Başka bir ifadeyle en iyi değişkenler seçilirken, değişken sayısı da genetik algoritma ile optimize edilmektedir. Değişken seçimi serbest bırakıldığı için, uygun olduğu durumda bütün değişkenler de hiçbir özellik seçimine maruz kalmadan girdi olarak kullanılabilir.

3.3.1.2. Uygunluk Fonksiyonu

Çalışmanın uygunluk fonksiyonun şu şekildedir. Eğitim amacı ile kullanılacak veri seti 800'ün katları olacak şekilde belirlenmiştir. Bunun nedeni söz konusu 800 adet gözlemden ilk 640 adedinin yapay sinir ağının eğitimi için, geri kalan 160 adedi ise test amacıyla kullanılacak olmasıdır. Uygunluk fonksiyonu ilk önce veri setini 800'ün katlarına ayırmaktadır. Her bir katmandaki ilk 640 adet gözlemi eğitim için kullanmakta ve kalan 160 adet gözlemden model test edilmektedir. Test aşamasındaki MSE değeri hata oranını oluşturmaktadır. Sadece bir tek eğitim setinin değil de birden fazla alt grubun kullanılmasının sebebi, yapay sinir ağları anlatılırken değinilen aşırı uyum probleminin engellenmeye çalışılmasıdır.

Uygunluk fonksiyonu ilk önce eğitim için gelen eğitim setini 800'er gözlemden oluşacak şekilde sıralı setlere ayırmaktadır. Genetik algoritmalar önceden tasarlanmış genin uygun kurallar çerçevesinde değişikliğe uğratmak suretiyle uygunluk fonksiyonunu minimum yapmaya çalışır.

Çalışmada eğitim amacı ile kullanılacak veri ayrı alt kümeler ayrıldıktan sonra her bir küme yeni bir ayırma tabi tutulmaktadır. Bu ayırma ilk 640 adet gözlem eğitim amacı ile son 160 gözlem ise test amacı ile kullanılmaktadır. O iterasyondaki gen ile yapay sinir ağı modeli her bir set için ayrı ayrı oluşturulmaktadır. Her bir setteki model, setteki test veri setinde denenmektedir.

Erişilen hata oranı bir toplama eklenmektedir. Sonuçta elde edilen toplam hata oranı set sayısına bölünmektedir. Başka bir ifade ile erişilen test hatalarının aritmetik ortalaması alınmaktadır. Önerilen model Şekil 4'de yer almaktadır.

MSE (Mean Squared Error) nin uygunluk fonksiyonunda kullanılmasının esas nedeni ise yapay sinir ağlarında Levenberg-Marquardt algoritmasının kullanılması ve bu algoritmanın da Jacobian hesaplamaları kullanmasıdır. Jacobian hesaplamalarında performansın mean veya sum of squared errors olduğu varsayılmaktadır. Levenberg-Marquardt eğitim algoritması sonuca ulaşma özellikleri diğer eğitim algoritmalarına göre daha iyidir (Ngia ve Sjöberg, 2000). Bu nedenle bu çalışmada Levenberg-Marquardt algoritması kullanılmıştır.

4. UYGULAMA

4.1. Veri Seti

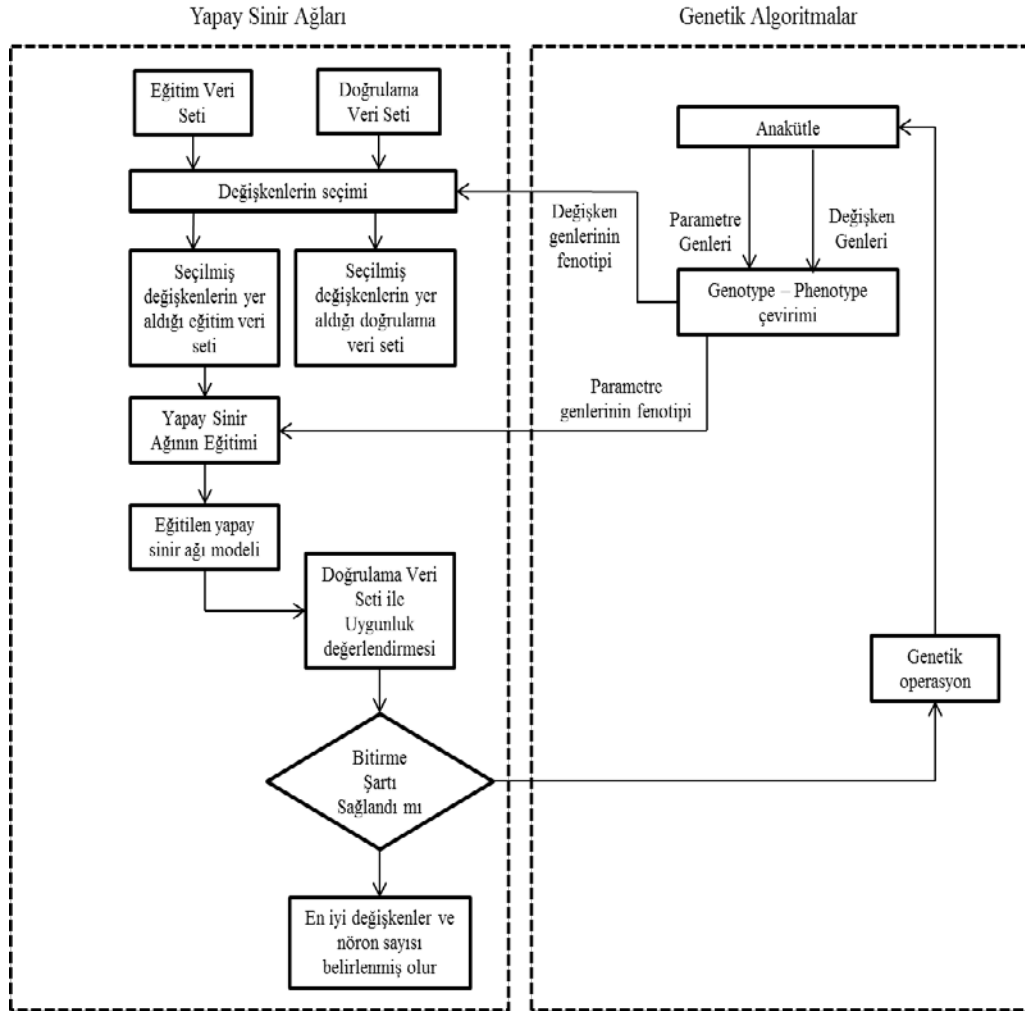
Çalışmada 2012 yılında BIST 30 endeksine dahil olan firmaların hisse senetlerine ilişkin veriler kullanılmıştır. Çalışmada sadece bir adet hisse senedi kullanılmamıştır. Bunun yerine BIST30 endeksine dahil olan 30 adet hisse senedi kullanılmıştır. Bir adet hisse senedi üzerinde önerilen modelin başarılı (veya başarısız) olması tesadüfi etkenler neticesinde oluşmuş olabilir. Başka bir ifade ile, modelin bir adet hisse senedi üzerinde başarılı olması sonucun genelleştirilmesini sağlamaz. Modelin başarısının genelleştirilebilmesi için farklı endüstrilerdeki, farklı özelliklere sahip hisse senetleri üzerinde de başarılı sonuçlar vermesi gerekmektedir. 30 adet farklı hisse senedi üzerinde modelin ne kadar iyi performans sergilediğinin hesaplanması, modelin dayanıklı (robust) olduğunun bir göstergesi niteliğinde olacaktır.

Bilgi İşlemsel Zeka Yöntemleri İle Hisse Senedi Fiyat Tahmini: Bist Uygulaması

BIST endeksleri farklı zaman dilimlerinde farklı firmaları kapsamaktadır. 2012 yılı ilk çeyreğinde BIST 30 endeksine dahil olan firmalar bu çalışmada göz önünde bulundurulmuştur. 15 yıldan fazla süreyi kapsayan veri seti elde edilmiştir. Firmalara ait olan açılış fiyatı, en yüksek fiyat, en düşük fiyat, kapanış fiyatı ve işlem hacmi verileri, BIST Satış ve Pazarlama Müdürlüğünden temin edilmiştir. Tablo 1 'de, çalışmada

kullanılan 30 adet hisse senedinin ismi ve kısaltmaları yer almaktadır.

2012 yılı ilk çeyreğinde BIST 30 endeksine dahil edilen firmalara ait ulaşılabilen bütün fiyat ve hacim bilgileri kullanılmıştır. Hisse senetlerinin borsaya kote olma zamanları birbirlerinden farklılık göstermektedir. Bu nedenle her bir hisse senedi için farklı sayıda veriye ulaşılmıştır. Tablo 1'de, hisse senetlerine ilişkin ulaşılabilen gün sayısı da yer almaktadır.



Şekil 4: Uzman Sistemin Detaylı Şeması

Borsa İstanbul 'da tipik bir iş gününde iki farklı seans yapılmaktadır. Her bir gün için, resmi tatillerin olduğu zamanlar hariç, iki adet açılış, kapanış, en düşük, en yüksek ve işlem hacmi verisi bulunmaktadır. Her seans ayrı bir gözlem niteliğinde değerlendirilmiş ve her seansın kapanış fiyatı ayrı ayrı tahmin edilmeye çalışılmıştır.

4.2. Tahminde Kullanılacak Değişkenler

Bu çalışmada, tahmin sürecinde kullanıldığında en iyi sonuçları vermesi beklenen değişkenler (optimal nöron sayısı ile eş zamanlı olarak) genetik algoritmalar tarafından belirlenecektir. Bu nedenle başlangıçta mümkün olduğunca çok sayıda

teknik analiz göstergesi bir araya getirilmeye çalışılmıştır.

Hisse senedi fiyatını tahmin modelinde kullanılmak için belirlenen aday değişkenler Tablo 2 'deki gibidir. Tabloda altı adet fiyat değişkeni, kapanış fiyatına ait 6 adet fiyat ve hacim bilgisi ve hesaplanabilen 47 adet teknik gösterge olmak üzere toplam 53 adet değişken görülebilmektedir.

4.3. Alternatif Model

Performans karşılaştırma amacıyla geliştirilen model, bir tane gizli katmanı olan ileri beslemeli yapay sinir ağından oluşmaktadır. Bu modelde ara katmanda bir adet gizli katman bulunmaktadır ve gizli katmanda 10 adet nöron kullanılmıştır

Tablo 1: Çalışmada Kullanılan Hisse Senetlerinin Kodları ve İsimleri

Sıra	Kod	Hisse Senedi İsimleri	Eğitim Hacmi	Eğitim Başlangıç
01	AKBNK	Akbankası A.Ş.	6400	01/07/1999
02	AKSA	AKSA Akrilik Kimya Sanayi A.Ş.	6400	15/06/1999
03	ARCLK	Arçelik A.Ş.	6400	02/07/1999
04	ASYAB	Asya Katılım Bankası A.Ş.	2400	23/07/2007
05	BIMAS	Birleşik Mağazalar A.Ş.	3200	20/12/2005
06	DOHOL	Doğan Yayın Holding A.Ş.	6400	15/07/1999
07	EKGYO	Emlak Konut Gayrimenkul Yatırım Ortaklığı A.Ş.	692	27/12/2010
08	ENKAI	Enka İnşaat ve Sanayi A.Ş.	4800	27/09/2002
09	EREGL	Ereğli Demir ve Çelik Fabrikaları T.A.Ş.	7200	26/03/1998
10	GARAN	T. Garanti Bankası A.Ş.	6400	02/07/1999
11	HALKB	Türkiye Halk Bankası A.Ş.	2400	23/07/2007
12	IHLAS	İhlas Holding A.Ş.	6400	04/12/1998
13	ISCTR	T. İş Bankası A.Ş.	6400	16/09/1999
14	KCHOL	Koç Holding A.Ş.	4000	05/08/2004
15	KOZAL	Koza Altın İşletmeleri A.Ş.	800	04/10/2010
16	KRDMD	Kardemir Karabük Demir Çelik Sanayi ve Ticaret A.Ş.	6400	13/07/1999
17	MGROS	Migros Türk T.A.Ş.	5600	15/09/1999
18	PETKM	Petkim PetroKimya Holding A.Ş.	6400	18/06/1999
19	SAHOL	Hacı Ömer Sabancı Holding A.Ş.	7200	28/07/1998
20	SISE	T. Şişe ve Cam Fabrikaları A.Ş.	7200	08/06/1998
21	SNGYO	Sinpaş Gayrimenkul Yatırım Ortaklığı A.Ş.	2400	23/07/2007
22	TCELL	Turkcell İletişim Hizmetleri A.Ş.	5600	09/02/2001
23	THYAO	Türk Hava Yolları A.O.	7200	13/03/1998
24	TKFEN	Tekfen Holding	1600	02/03/2009
25	TOASO	Tofaş Türk Otomobil Fabrikası A.Ş.	6400	01/07/1999
26	TTKOM	Türk Telekomünikasyon A.Ş.	1600	02/03/2009
27	TTRAK	Türk Traktör ve Ziraat Makineleri A.Ş.	3200	20/12/2005
28	TUPRS	Türkiye Petrol Rafineleri A.Ş.	6400	03/06/1999
29	VAKBN	Türkiye Vakıflar Bankası T.A.O.	3200	26/04/2006
30	YKBNK	Yapı ve Kredi Bankası A.Ş.	6400	18/06/1999

- Eğitim süresinin bitiş tarihi her bir hisse senedi için 08/05/2012'dir.
- Test süresinin başlangıç ve bitiş tarihleri her bir hisse senedi için sırasıyla 09/05/2012 – 31/08/2012'dir.
- EKGYO kodlu senet için yeterli sayıda gözlem bulunmadığından 640/160 kuralı geçerli olmamıştır.

Tablo 1: Çalışmada Kullanılan Hisse Senetlerinin Kodları ve İsimleri

Sıra	Kod	Hisse Senedi İsimleri	Eğitim Hacmi	Eğitim Başlangıç
01	AKBNK	Akbankası A.Ş.	6400	01/07/1999
02	AKSA	AKSA Akrilik Kimya Sanayi A.Ş.	6400	15/06/1999
03	ARCLK	Arçelik A.Ş.	6400	02/07/1999
04	ASYAB	Asya Katılım Bankası A.Ş.	2400	23/07/2007
05	BIMAS	Birleşik Mağazalar A.Ş.	3200	20/12/2005
06	DOHOL	Doğan Yayın Holding A.Ş.	6400	15/07/1999
07	EKGYO	Emlak Konut Gayrimenkul Yatırım Ortaklığı A.Ş.	692	27/12/2010
08	ENKAI	Enka İnşaat ve Sanayi A.Ş.	4800	27/09/2002
09	EREGL	Ereğli Demir ve Çelik Fabrikaları T.A.Ş.	7200	26/03/1998
10	GARAN	T. Garanti Bankası A.Ş.	6400	02/07/1999
11	HALKB	Türkiye Halk Bankası A.Ş.	2400	23/07/2007
12	IHLAS	İhlas Holding A.Ş.	6400	04/12/1998
13	ISCTR	T. İş Bankası A.Ş.	6400	16/09/1999
14	KCHOL	Koç Holding A.Ş.	4000	05/08/2004
15	KOZAL	Koza Altın İşletmeleri A.Ş.	800	04/10/2010
16	KRDMD	Kardemir Karabük Demir Çelik Sanayi ve Ticaret A.Ş.	6400	13/07/1999
17	MGROS	Migros Türk T.A.Ş.	5600	15/09/1999
18	PETKM	Petkim PetroKimya Holding A.Ş.	6400	18/06/1999
19	SAHOL	Hacı Ömer Sabancı Holding A.Ş.	7200	28/07/1998
20	SISE	T. Şişe ve Cam Fabrikaları A.Ş.	7200	08/06/1998
21	SNGYO	Sinpaş Gayrimenkul Yatırım Ortaklığı A.Ş.	2400	23/07/2007
22	TCELL	Turkcell İletişim Hizmetleri A.Ş.	5600	09/02/2001
23	THYAO	Türk Hava Yolları A.O.	7200	13/03/1998
24	TKFEN	Tekfen Holding	1600	02/03/2009
25	TOASO	Tofaş Türk Otomobil Fabrikası A.Ş.	6400	01/07/1999
26	TTKOM	Türk Telekomünikasyon A.Ş.	1600	02/03/2009
27	TTRAK	Türk Traktör ve Ziraat Makineleri A.Ş.	3200	20/12/2005
28	TUPRS	Türkiye Petrol Rafineleri A.Ş.	6400	03/06/1999
29	VAKBN	Türkiye Vakıflar Bankası T.A.O.	3200	26/04/2006
30	YKBNK	Yapı ve Kredi Bankası A.Ş.	6400	18/06/1999

- Eğitim süresinin bitiş tarihi her bir hisse senedi için 08/05/2012'dir.
- Test süresinin başlangıç ve bitiş tarihleri her bir hisse senedi için sırasıyla 09/05/2012 – 31/08/2012'dir.
- EKGYO kodlu senet için yeterli sayıda gözlem bulunmadığından 640/160 kuralı geçerli olmamıştır.

Alternatif modelde değişken seçimi gerçekleştirilmesi söz konusu değildir. Bu nedenle hesaplanabilen 53 adet değişken bu modelde girdi olarak kullanılmıştır.

5. BULGULAR

5.1. Optimal Nöron Sayıları ve Değişkenler

Çalışmada ilk olarak her bir hisse senedi tahmin performansını en yüksek yapan gen elemanlarına yer verilmiştir. Genetik algoritmalar yardımıyla her bir hisse senedinin uygunluk fonksiyonunu minimum yapan ara katmandaki nöron sayısı ve kullanılması gereken değişken

sayısı Tablo 3 'teki gibidir. Tabloda her bir hisse senedi için genetik algoritmalarla belirlenen nöron sayıları ve optimal değişken sayıları yer almaktadır. Buna ek olarak optimal değişken indeksleri de yer almaktadır.

Tablo 3'ten de açıkça görüldüğü üzere her bir hisse senedi için minimum uygunluk değerinin hesaplanmasına olanak sağlayan ara katmandaki nöron sayısı ve optimal değişken sayısı birbirlerinden farklıdır. Belirli bir standart söz konusu değildir. Ara katmandaki nöron sayısı [2-21] arasında değişirken, optimal değişken sayısı [14-29] arasında değişmektedir.

Fiyat hacim eğilimi isimli değişken ile denge işlem hacmi isimli değişkenin

hiçbir hisse senedinde önerilen model tarafından tercih edilmemiştir.

Tablo 2: Çalışmada Kullanılan Değişkenler

Sıra No	Değişken İsmi	Sıra No	Değişken İsmi
01	Bugünkü kapanış – Bir gün önceki kapanış	28	Momentum en yüksek fiyat
02	Bir gün önceki kapanış	29	Momentum en düşük fiyat
03	Bir gün önceki en yüksek fiyat	30	Momentum kapanış fiyatı
04	Bir gün önceki en düşük fiyat	31	Chaikin Dalgalanma
05	Bir gün önceki açılış fiyatı	32	Hızlandırılmış stochastik %K
06	Bir gün önceki işlem hacmi	33	Hızlandırılmış stochastik %D
07	Kapanış fiyatının 5 günlük basit hareketli ortalaması	34	Yavaşlatılmış stochastik %K
08	Kapanış fiyatının 6 günlük basit hareketli ortalaması	35	Yavaşlatılmış stochastik %D
09	Kapanış fiyatının 10 günlük basit hareketli ortalaması	36	William's %R
10	Kapanış fiyatının 20 günlük basit hareketli ortalaması	37	Negatif hacim indeksi
11	Kapanış fiyatının 5 günlük üssel hareketli ortalaması	38	Pozitif hacim indeksi
12	Kapanış fiyatının 6 günlük üssel hareketli ortalaması	39	Görelî güç indeksi
13	Kapanış fiyatının 10 günlük üssel hareketli ortalaması	40	Toplama/Dağıtım Çizgisi
14	Kapanış fiyatının 20 günlük üssel hareketli ortalaması	41	Bollinger orta band
15	Kapanış fiyatının 5 günlük üçgensel hareketli ortalaması	42	Bollinger üst band
16	Kapanış fiyatının 6 günlük üçgensel hareketli ortalaması	43	Bollinger alt band
17	Kapanış fiyatının 10 günlük üçgensel hareketli ortalaması	44	En yüksek yüksek değer
18	Kapanış fiyatının 20 günlük üçgensel hareketli ortalaması	45	En düşük düşük değer
19	Toplama/Dağıtım Salınımı	46	Medyan Fiyat
20	Chaikin Salınımı	47	Denge işlem hacmi
21	Hareketli Ortalamaların Birleşmesi Ayrılması göstergesi	48	Fiyat değişim oranı
22	21'in 9 günlük hareketli ortalaması	49	Fiyat hacim eğilimi
23	Açılış fiyatı ivme	50	Tipik fiyat
24	En yüksek fiyat ivme	51	Hacim değişim oranı
25	En düşük fiyat ivme	52	Ağırlıklı kapanış fiyatı
26	Kapanış fiyatı ivme	53	William's Toplama Dağıtım
27	Momentum açılış fiyatı		

Tablo 2: Çalışmada Kullanılan Değişkenler

Sıra No	Değişken İsmi	Sıra No	Değişken İsmi
01	Bugünkü kapanış – Bir gün önceki kapanış	28	Momentum en yüksek fiyat
02	Bir gün önceki kapanış	29	Momentum en düşük fiyat
03	Bir gün önceki en yüksek fiyat	30	Momentum kapanış fiyatı
04	Bir gün önceki en düşük fiyat	31	Chaikin Dalgalanma
05	Bir gün önceki açılış fiyatı	32	Hızlandırılmış stokastik %K
06	Bir gün önceki işlem hacmi	33	Hızlandırılmış stokastik %D
07	Kapanış fiyatının 5 günlük basit hareketli ortalaması	34	Yavaşlatılmış stokastik %K
08	Kapanış fiyatının 6 günlük basit hareketli ortalaması	35	Yavaşlatılmış stokastik %D
09	Kapanış fiyatının 10 günlük basit hareketli ortalaması	36	William's %R
10	Kapanış fiyatının 20 günlük basit hareketli ortalaması	37	Negatif hacim indeksi
11	Kapanış fiyatının 5 günlük üssel hareketli ortalaması	38	Pozitif hacim indeksi
12	Kapanış fiyatının 6 günlük üssel hareketli ortalaması	39	Görelî güç indeksi
13	Kapanış fiyatının 10 günlük üssel hareketli ortalaması	40	Toplama/Dağıtım Çizgisi
14	Kapanış fiyatının 20 günlük üssel hareketli ortalaması	41	Bollinger orta band
15	Kapanış fiyatının 5 günlük üçgen hareketli ortalaması	42	Bollinger üst band
16	Kapanış fiyatının 6 günlük üçgen hareketli ortalaması	43	Bollinger alt band
17	Kapanış fiyatının 10 günlük üçgen hareketli ortalaması	44	En yüksek yüksek değer
18	Kapanış fiyatının 20 günlük üçgen hareketli ortalaması	45	En düşük düşük değer
19	Toplama/Dağıtım Salınımı	46	Medyan Fiyat
20	Chaikin Salınımı	47	Denge işlem hacmi
21	Hareketli Ortalamaların Birleşmesi Ayrılması göstergesi	48	Fiyat değişim oranı
22	21'in 9 günlük hareketli ortalaması	49	Fiyat hacim eğilimi
23	Açılış fiyatı ivme	50	Tipik fiyat
24	En yüksek fiyat ivme	51	Hacim değişim oranı
25	En düşük fiyat ivme	52	Ağırlıklı kapanış fiyatı
26	Kapanış fiyatı ivme	53	William's Toplama Dağıtım
27	Momentum açılış fiyatı		

En sık tercih edilen değişkenler ise 6 günlük üçgen hareketli ortalama (24), William 's %R (22) ve 5 günlük üçgen hareketli ortalama (20) olmuştur.

5.2. Gerçek Değerler ile Tahmin Edilen Değerlerin Karşılaştırılması

Şekil 5'de TUPRS adlı hisse senedinin test süresince tahmin ettiği fiyatlar yer almaktadır. 30 adet hisse senedinin fiyat tahminleri grafik halinde gösterilebilir fakat çalışmanın hacmini arttırmaktan kaçınmak adına burada sadece bir adet hisse senedi için hazırlanan grafik sunulmuştur. Söz konusu hisse senedine ilişkin test aşamasındaki optimal ve alternatif modelin tahmin ettiği değerler ve gerçek fiyat ile modelin tahmin ettiği fiyat arasındaki farkın mutlak değeri Şekil 5'de yer almaktadır.

Şekil 5 iki bölümden oluşmaktadır. Yukarıdaki bölümde optimal ve alternatif modelin tahmin ettiği fiyatlar ile gerçek

fiyatlar gösterilmektedir. Şeklin alt tarafında ise hisse senedinin gerçek fiyatı ile tahmin edilen fiyatı arasındaki farkın mutlak değeri yer almaktadır. Alt tarafta yer alan hata grafiğinde ise hata çizgisinin alt taraftaki eksene yakın olması, yapılan tahminin doğruluğunu göstermektedir. Yatay eksenden uzaklaştıkça modelin tahmin ettiği fiyatlar ile gerçek fiyat arasındaki fark artmaktadır.

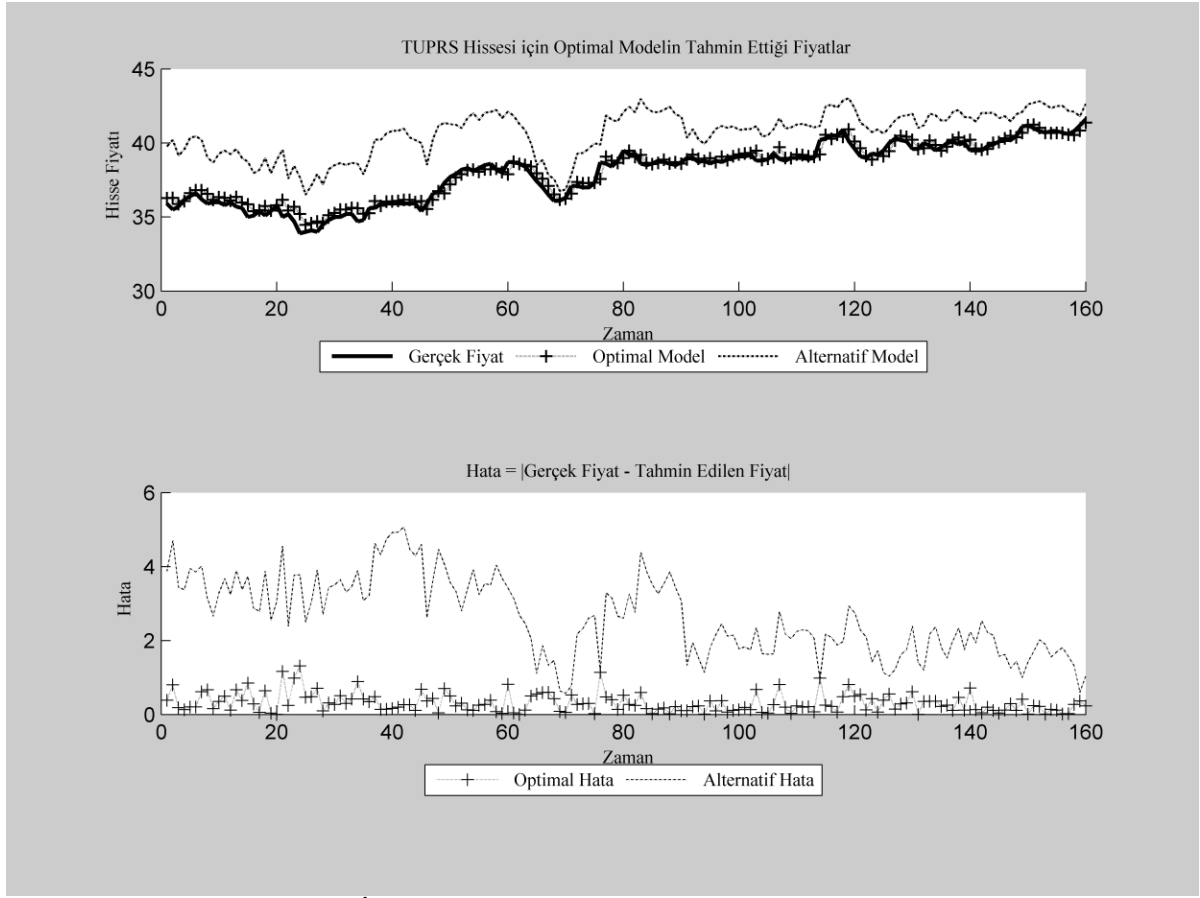
Şekil 5'in alt bölümünde yer alan hata değerlerinden optimal hata ile alternatif hatanın birbirlerinden farklı olduğunu ve optimal hatanın alt tarafta yer alan eksene oldukça yakın olduğu görülmektedir. Böylelikle optimal modelin gerçekleştirdiği tahminler, alternatif modelin gerçekleştirdiği tahminlere göre gerçeğe daha yakındır yorumunun yapılması mümkündür.

Tablo 3: Optimal Nöron, Değişken Sayısı ve İndisleri

S No.	H.S. Kod	n^*	m^{**}	Optimal Değişkenlerin İndisleri
01	AKBNK	2	19	3 4 8 9 10 11 19 20 23 24 28 29 32 39 42 44 48 50 51
02	AKSA	2	19	2 7 9 11 13 15 16 18 26 27 30 31 32 33 35 37 39 50 52
03	ARCLK	2	22	4 7 8 10 12 13 14 15 16 17 19 21 28 29 31 32 36 39 41 44 46 50
04	ASYAB	4	18	3 4 9 10 11 16 19 22 23 24 28 29 36 39 41 42 44 51
05	BIMAS	2	22	1 4 10 11 13 16 17 21 22 24 25 26 28 29 31 33 36 37 39 41 44 48
06	DOHOL	2	22	1 3 7 9 12 13 14 15 16 17 18 23 24 26 27 30 33 35 39 50 51 52
07	EKGYO	2	18	1 2 3 4 6 7 11 16 17 26 27 34 36 38 40 41 50 51
08	ENKAI	12	22	2 3 4 8 15 16 19 25 26 27 28 29 31 32 36 39 41 42 43 45 50 51
09	EREGL	2	26	4 5 6 7 11 17 18 20 21 22 23 24 25 27 29 30 31 32 34 35 36 39 41 46 48 53
10	GARAN	2	24	1 4 5 6 7 9 15 16 17 23 25 26 29 31 32 35 39 41 42 43 44 50 51 52
11	HALKB	3	22	2 4 5 7 8 9 10 12 13 14 17 18 22 23 26 27 28 30 34 35 36 46
12	IHLAS	2	14	13 15 16 25 26 28 32 35 37 39 43 50 51 53
13	ISCTR	2	21	2 4 7 8 10 12 13 15 16 20 23 24 33 34 35 36 42 43 48 51 53
14	KCHOL	2	16	1 5 10 14 19 25 26 28 30 31 35 36 37 39 42 46
15	KOZAL	17	26	2 3 5 7 8 12 15 19 21 24 25 26 27 29 31 32 33 34 35 40 41 42 46 48 51 53
16	KRDMD	21	29	4 6 8 11 13 14 15 16 18 22 23 24 26 27 28 30 31 33 35 36 37 38 39 41 44 45 51 52 53
17	MGROS	3	29	1 3 6 9 11 15 16 18 20 21 22 24 25 29 32 33 34 36 38 39 40 41 42 43 44 45 46 48 53
18	PETKM	2	25	1 4 5 6 7 11 12 13 15 16 18 20 23 28 29 30 31 33 36 39 42 46 48 51 52
19	SAHOL	8	23	1 2 9 10 12 14 15 16 17 18 21 27 31 33 35 36 41 43 44 45 48 50 51
20	SISE	3	18	1 2 5 7 14 15 16 17 18 21 22 27 29 30 32 36 41 42
21	SNGYO	8	24	1 4 5 9 12 14 15 16 18 20 23 31 32 33 34 36 39 41 42 44 46 50 51 52
22	TCELL	7	27	1 2 5 8 9 10 12 13 14 15 16 17 18 19 23 25 28 30 33 34 36 39 41 43 46 50 51
23	THYAO	2	20	1 4 5 11 13 15 16 17 21 27 28 29 31 35 41 45 46 50 52 53
24	TKFEN	2	15	4 7 9 13 16 17 29 30 32 39 43 44 46 50 51
25	TOASO	2	24	1 4 6 7 8 9 14 16 17 18 19 22 24 27 28 29 32 33 35 36 43 44 45 51
26	TTKOM	9	23	1 2 4 5 6 8 9 10 14 16 18 19 22 25 28 30 36 42 43 44 48 50 51
27	TTRAK	2	22	1 3 10 13 15 16 17 18 21 22 24 25 26 35 36 39 41 42 43 46 48 52
28	TUPRS	2	25	1 3 8 10 11 15 16 17 22 25 26 28 29 30 33 35 36 39 42 43 44 45 51 52 53
29	VAKBN	2	20	1 2 3 4 7 11 12 15 16 19 23 25 29 30 36 41 43 46 50 53
30	YKBNK	2	22	3 5 8 9 10 12 15 17 18 27 29 31 32 33 36 41 43 44 45 46 52 53

n^* : Optimal Nöron Sayısı


m^{**} : Optimal Değişken Sayısı



Şekil 5: TUPRS Hisse Senedine İlişkin Tahmin Edilen ve Gerçek Fiyatlar

Optimal model kurulduktan ve test sürecine ilişkin tahminler gerçekleştirildikten sonra test sürecindeki gerçek fiyatlar ve optimal modelin tahmin ettiği fiyatlar dağılım grafiğinde gösterilebilir ve böylelikle modelin gerçek fiyatlara ne kadar yakın tahminler gerçekleştirdiği belirlenebilir. Şekil 6 'da YKBNK kodlu hisse senedine ilişkin dağılım grafiği görülmektedir. Söz konusu

şekil iki bölümden oluşmaktadır. Üstteki bölümde yatay ekseninde gerçek fiyatların ve dikey ekseninde tahmin edilen fiyatların yer aldığı dağılım grafiği yer almaktadır. Alttaki bölümde ise gerçek fiyat ile tahmin edilen fiyat arasındaki farka ilişkin grafik yer almaktadır. Alttaki grafikte fark değerlerinin yer aldığı band ne kadar dar ise yapılan tahminin de o derecede iyi olduğunu söylemek mümkündür.



Şekil 6: YKBNK Hisse Senedi Dağılım Grafiği

5.3. İstatistiksel Tahmin Sonuçları

Tablo 4 'te modellerin test süresi boyunca gerçekleştirdikleri istatistiksel performans ölçülerine ilişkin değerler yer almaktadır. Bu değerler tahmin performansının ne kadar iyi olduğuna ilişkin ipucu sağlamaktadır. Söz konusu istatistiksel değerler MSE (Mean Squared Error), MAPE (Mean Absolute Percentage Error) ve RMSE (Root Mean Squared Error)'dir. Bu değerler tahmin edilen fiyat ile gerçek fiyat arasındaki farklılığı ölçmektedir. Bu değerler ne kadar düşük olursa, tahmin performansının da o kadar yüksek olduğunu söylemek mümkündür.

Çalışmada modelin eğitim aşamasında ulaştığı MSE değeri ve test aşamasında ulaşılan MSE değerleri tablodaki gibidir. Ayrıca tahminlerin başarı oranının sergilenmesinde kullanılacak bir diğer yöntem olan MAPE değerlerine de

yer verilmiştir. Böylelikle tahmin performansı istatistiksel açıdan değerlendirmeye tabi tutulmuştur.

Hesaplanan bu sonuçların istatistiksel açıdan anlamlı farklılık sergileyip sergilemediğini belirleyebilmek için parametrik olmayan testler uygulanmıştır. Aynı veri setine farklı modeller uygulandığı için bağımsız örneklem Mann-Whitney U-test uygulanmıştır ve sonuçlar Tablo 5'deki gibidir.

Hesaplanan bu sonuçların istatistiksel açıdan anlamlı farklılık sergileyip sergilemediğini belirleyebilmek için parametrik olmayan testler uygulanmıştır. Aynı veri setine farklı modeller uygulandığı için bağımsız örneklem Mann-Whitney U-test uygulanmıştır ve sonuçlar Tablo 5'deki gibidir.

Tablo 4: Optimal ve Alternatif Modele İlişkin İstatistiksel Performans Ölçüleri

S.No.	H.S. Kod	Optimal Model			Alternatif Model		
		MSE	MAPE	RMSE	MSE	MAPE	RMSE
01	AKBNK	0,00997	1,240997	0,099849	0,205059	6,018329	0,452835
02	AKSA	0,00194	0,752879	0,044041	0,009388	1,902846	0,096892
03	ARCLK	0,080745	2,280142	0,284157	0,734879	8,425655	0,857251
04	ASYAB	0,000512	0,997145	0,022628	0,005943	3,808676	0,077092
05	BIMAS	11,49382	4,233498	3,390254	709,414	34,36783	26,63483
06	DOHOL	0,000171	1,334503	0,013092	0,015739	15,60186	0,125456
07	EKGYO	0,001926	1,466913	0,043885	0,001136	1,154167	0,033708
08	ENKAI	0,009767	1,449384	0,098829	1,237661	20,14124	1,112502
09	EREGL	0,720199	41,51146	0,848646	0,202517	19,56548	0,450019
10	GARAN	0,005638	0,860085	0,075085	0,03925	2,174918	0,198116
11	HALKB	0,398078	3,224232	0,630934	5,141034	12,34718	2,267385
12	IHLAS	0,000184	0,990611	0,013576	0,00178	3,147492	0,042195
13	ISCTR	0,00415	1,174479	0,064423	0,424399	13,53362	0,651459
14	KCHOL	0,008051	1,018812	0,089726	0,095958	4,348664	0,309771
15	KOZAL	43,53137	18,58276	6,597831	27,13975	13,30233	5,209583
16	KRDMD	0,00418	4,189589	0,064652	0,013909	7,51957	0,117936
17	MGROS	0,461636	2,862772	0,679438	1,946148	6,476073	1,395044
18	PETKM	0,000593	0,925029	0,024348	0,003725	2,611894	0,061031
19	SAHOL	0,011737	1,103926	0,108336	0,849044	10,62317	0,921436
20	SISE	0,00417	1,925791	0,064573	0,025628	4,724715	0,160086
21	SNGYO	0,001012	2,102722	0,031805	0,002302	3,347003	0,047981
22	TCELL	0,015873	1,020815	0,125989	0,150201	3,855795	0,387558
23	THYAO	0,005194	1,821031	0,07207	0,032241	5,39299	0,179557
24	TKFEN	0,006699	0,968037	0,081848	0,057268	2,989639	0,239307
25	TOASO	0,008523	0,98932	0,092319	0,238636	4,846484	0,488504
26	TTKOM	0,020007	1,483258	0,141447	0,268341	6,373689	0,518016
27	TTRAK	0,176715	1,071371	0,420374	5,594116	6,834706	2,365188
28	TUPRS	0,163102	0,832367	0,403859	8,074939	7,047745	2,841644
29	VAKBN	0,002254	1,07575	0,047481	0,049678	6,063567	0,222886
30	YKBNK	0,002484	1,127738	0,04984	0,145328	7,726103	0,381219

Üç farklı istatistiksel performans ölçüsü söz konusudur ve iki modele ilişkin elde edilen değerler arasında anlamlı bir farklılık olup olmadığını test etmek için üç farklı hipotez kurulmuştur. Bu hipotezler şu şekildedir;

- H1: Optimal ve alternatif modelin mse değerleri arasında anlamlı bir farklılık yoktur
- H2: Optimal ve alternatif modelin mape değerleri arasında anlamlı bir farklılık yoktur
- H3: Optimal ve alternatif modelin rmse değerleri arasında anlamlı bir farklılık yoktur

MSE değerleri dikkate alındığında, optimal modele ilişkin ortalama sırası (ort_sıra = 23,57), alternatif modele ilişkin ortalama sırasından (ort_sıra=37,43)

istatistiksel açıdan farklı olduğu görülmektedir (U=242, p<0.01). Başka bir ifade ile optimal modelin ürettiği sonuçlar, alternatif modelin ürettiği mse değerlerine göre daha düşüktür. Bu bulgu optimal modelin istatistiksel açıdan daha düşük MSE değeri ürettiğinin istatistiksel kanıtıdır.

Optimal modelin ürettiği MAPE değerlerine ilişkin ortalama sırası (ort_sıra = 18,80), alternatif modelin ürettiği ortalama sırasından (ort_sıra=42,20) istatistiksel açıdan farklıdır (U=99, p<0.01). Başka bir ifade ile optimal modelin ürettiği mape değerleri, alternatif modelin ürettiği MAPE değerlerine göre daha düşüktür. Bu bulgu optimal modelin istatistiksel açıdan daha düşük mape değeri ürettiğinin istatistiksel kanıtıdır.

Tablo 5: Hipotez Testi Sonuçları

Sıfır Hipotezi	Mean Rank (Optimal)	Mean Rank (Alternatif)	Test İstatistiği	Asymptotic Sig (2-sided)	Karar
H1	23,57	37,43	242	0,002	H_0 ret
H2	18,80	42,20	99	0,000	H_0 ret
H3	23,57	37,43	242	0,002	H_0 ret

Optimal modelin ürettiği RMSE değerlerine ilişkin ortalama sırası (ort_sıra=23,57), alternatif modelin ürettiği ortalama sırasından (ort_sıra = 37,43) istatistiksel açıdan farklıdır (U=242, $p<0.02$). Başka bir ifade ile optimal modelin ürettiği rmse değerleri, alternatif modelin ürettiği RMSE değerlerine göre daha düşüktür. Bu da optimal modelin istatistiksel açıdan daha düşük RMSE değeri ürettiğinin istatistiksel kanıtıdır.

Yukarıdaki ifadelerden görüldüğü gibi istatistiksel performans ölçüleri optimal modelde, alternatif modele göre daha düşük düzeydedir ve bu durum optimal modelde gerçeğe daha yakın tahminlerin gerçekleştirildiğini kanıtlamaktadır.

6.SONUÇ VE TARTIŞMA

Hisse senetleri bireysel ve kurumsal yatırımcıların sahip oldukları fazla fonları değerlendirmek için kullandıkları yatırım araçlarından biridir. Yatırımcıların ortak bir amacı vardır ve bu amaç piyasa ortalamasının üzerinde kar elde etmektir. Hisse senedi fiyatlarının önceden tahmin edilebilmesi piyasanın üzerinde getiri sağlayabilir. Hisse senetleri fiyat tahmini konusunda yapılan çalışmalardan anlaşılmaktadır ki, geçmiş fiyat hareketlerinden yola çıkmak suretiyle, hisse senedi fiyatını önceden tahmin edilebilirliği konusunda henüz fikir birliği söz konusu değildir. Hisse senedi fiyatlarının önceki fiyatlardan tamamen bağımsız olduğunu savunanlar olduğu gibi, hisse senedi fiyatlarının geçmişteki fiyatlardan yola çıkarak tahmin

edilebileceğini savunanlar da literatüre değerli çalışmalar sunmuşlardır. Bu araştırma ikinci gruptaki çalışmalarını destekler niteliktedir. Bu çalışmaya göre de bilgi işlemsel zeka teknikleri kullanılmak suretiyle belirli bir dereceye kadar hisse senedi fiyatının bir gün sonraki fiyatını önceden tahmin etmek mümkündür.

Çalışmanın esas amacı bilgi işlemsel zeka yöntemlerinin finansal piyasalarda uygulanmasını sağlamak yoluyla kullanıcının, karmaşık tahmin modeline daha az müdahale ettiği uzman bir sistem tasarlamaktır. Model, kullanıcının yerine karar verebildiği için uzman olarak adlandırılmaktadır. Çalışmada önerilen modelde, yapay sinir ağları için gerekli parametrelerden bazıları, bilgi işlemsel zeka yöntemlerinden biri olan genetik algoritmalar ile birlikte optimize edilmektedir. Böylelikle kullanıcı fiyatlar henüz gerçekleşmeden, bir sonraki güne ilişkin tahmin fiyatlarını elde edebilmektedir.

Önerilen yöntem tamamen bilgisayar tabanlı olduğu için tarafsız bir şekilde değerlendirme söz konusudur. Başka bir ifade ile kişilere ait yanlı olma problemi elenmiş olmaktadır. Uzman diye tabir edilen kişiler karar verirken, geçmişteki deneyimlerinin ve kişisel özelliklerinin (riskten kaçınma veya riski üstlenme gibi) etkisinde kalmak suretiyle yanlı kararlar verebilirler. Bu durum yanılgılara ve dolayısıyla yanlış kararlara da neden olabilir. Çalışmada önerilen sistemde böyle bir durum söz konusu değildir.

Çalışma bulguları incelendiğinde başlangıçta her bir hisse senedi için hesaplanmış olan 53 adet teknik göstergenin iki tanesinin hiçbir hisse senedi tahmin modelinde tercih edilmediği görülmektedir. Bu teknik göstergeler fiyat-hacim eğilimi ve denge işlem hacmidir. En sık tercih edilen gösterge ise kapanış fiyatının 6 günlük üçgensel hareketli ortalamasıdır. Bu göstergeyi, William's %R değeri ve kapanış fiyatının 5 günlük üçgensel hareketli ortalaması takip etmektedir.

Bu çalışmada elde edilen sonuçlar her ne kadar başarılı olsa da, hisse senedi fiyatlarının önceki fiyatların bir sonucu olduğu ortaya çıkmaz. Başka bir ifade ile

önceki fiyatlar ile sonraki fiyatlar arasında bir neden sonuç ilişkisi olduğu sonucuna varılamaz. Önerilen uzman sistem ile birlikte, yapay sinir ağlarının performansını etkileyecek önemli parametrelerin genetik algoritma ile belirlenmesi sağlanmaktadır ve hisse senedi fiyatlarının önceden belirli bir düzeye kadar doğru bir şekilde tahmin edilebileceği sonucu ortaya çıkmaktadır.

Sonraki çalışmalarda yapay sinir ağlarına ilişkin diğer paramatereler (eğitim fonksiyonu, aktivasyon fonksiyonu, ara katman sayısı gibi) de optimizasyon setine dahil edilebilir ve bu daha geniş bir şekilde fiyat tahmini incelenebilir.

KAYNAKÇA

- Adebiyi, A., Ayo, C., Adebiyi, M. ve Otokiti, S. (2012). "Stock Price Prediction Using Neural Network with Hybridized Market Indicators", **Journal of Emerging Trends in Computing and Information Sciences**, 3/1, 1-9.
- Altay, E. ve Satman, M.H. (2005). "Stock Market Forecasting: Artificial Neural Network and Linear Regression Compariosn in an Emergin Market", **Journal of Financial Management and Analysis**, 18/2, 18-33.
- Armano, G., Marchesi, M. ve Murru, A. (2005). "A Hybrid Genetic-Neural Architecture for Stock Indexes Forecasting", **Information Sciences**, 170, 3-33.
- Atsalakis, G.S., Dimitrakakis, E.M. ve Zopounidis, C.D. (2011). "Elliot Wave Theory and Neuro-Fuzzy Systems, in Stock Market Prediction: The WASP System", **Expert Systems with Applications**, 38/8, 9196-9206.
- Atsalakis, G.S. ve Valavanis, K.P. (2009). "Forecasting Stock Market Short-Term Trends Using a Neuro-Fuzzy Based Methodology", **Expert Systems with Applications**, 36/7, 10696-10707.
- Aygören, H., Saritaş, H. ve Moralı, T. (2012). "İMKB100 Endeksinin Yapay Sinir Ağları ve Network Nümerik Arama Modelleri ile Tahmini", **Uluslararası Alanya İşletme Fakültesi Dergisi**, 4/1, 73-88.
- Brealey, R.A., Myers, S.C. ve Marcus, A.J. (2012). **Fundamentals of Corporate Finance**, 7. Baskı, McGrawHill, New York.
- Chang, P.C., Wang, D.D. ve Zhou, C.L. (2012). "A Novel Model by Evolving Partially Connected Neural Network for Stock Price Trend Forecasting", **Expert Systems with Applications**, 39/1, 611-620.
- Chen, S.H., Wang, P.P. ve Kuo, T.W. (2007). **Computational Intelligence in Economics and Finance**, Springer, Berlin.

- Cheng, C.H., Chen, T.L. ve Wei, L.Y. (2010). “A Hybrid Model Based on Rough Sets Theory and Genetic Algorithms for Stock Price Forecasting”, **Information Sciences**, 180/9, 1610-1629.
- Diler, A.İ. (2003). “İMKB Ulusal-100 Endeksinin Yönünün Yapay Sinir Ağları Hata Geriye Yayma Yöntemi ile Tahmin Edilmesi”, **İstanbul Menkul Kıymetler Borsası Dergisi**, 7/(25-26), 65-82.
- Edwards, R.D., Magee, J. ve Bassetti, W.H.C. (2007). **Technical Analysis of Stock Trends**, 9. Bası, Taylor & Francis, New York.
- Erdoğan, E. ve Özyürek, H. (2012). “Yapay Sinir Ağları ile Fiyat Tahminlemesi”, **Sosyal ve Beşeri Bilimler Dergisi**, 4/1, 85-92.
- Fama, E. (1969). “Efficient Capital Markets: A Review of Theory and Empirical Work”, **The Journal of Finance**, 25/2, 383-417.
- Gen, M. ve Cheng, R., (2000). **Genetic Algorithms and Engineering Optimization**, Wiley & Sons, New York, 511s.
- Güngör, B. ve Tortu, A. (2007). **Esnek Hesaplama Teknikleri ile Hisse Senedi Fiyat Tahminleri**, İmaj Yayıncılık, Ankara.
- Hao, H.N. (2010). “Short-Term Forecasting of Stock Price Based on Genetic-Neural Network”, **Sixth International Conference on Natural Computation**, 1838-1841.
- Haykin, S. (1999). **Neural Networks: A Comprehensive Foundation**, Pearson Education, Delhi.
- Holland, J.H. (1992). **Adaptation in Natural and Artificial Systems**, THE MIT Press, London.
- Hsieh, L.F., Hsieh, S.C. ve Tai, P.H. (2011). “Enhanced Stock Price Variation Prediction via DOE and BPNN-based Optimization”, **Expert Systems with Applications**, 38/11, 14178-14184.
- Ince, T. ve Trafalis, T.B. (2007). “Kernel Principle Component Analysis and Support Vector Machines for Stock Price Prediction”, **IIE Transactions**, 39, 629-637.
- Kara, Y., Boyacıoğlu, M.A. ve Baykan, Ö.K. (2011). “Predicting Direction of Stock Price Index Movement Using Artificial Neural Networks and Support Vector Machines: The Sample of the Istanbul Stock Exchange”, **Expert Systems with Applications**, 38/5, 5311-5319.
- Karaathı, M., Güngör, İ., Demir, Y. ve Kalaycı, Ş. (2005). “Hisse Senedi Fiyat Hareketlerinin Yapay Sinir Ağları Yöntemi ile Tahmin Edilmesi”, **Balıkesir Üniversitesi Bandırma İktisadi ve İdari Bilimler Fakültesi Akademik Fener Dergisi**, 2/1, 22-48.
- Karaca, S.S. ve Başdemir, H.N. (2012). “The Applicability of Artificial Neural Network Method upon Prediction of Rate of Stock Return: Example of 2008 Financial Crisis”, **Journal of Applied Economic Sciences**, 7/2, 131-140.
- Kecman, V. (2001). **Learning and Soft Computing**, The MIT Press, London.
- Kirkpatrick, C.D. ve Dahlquist, J.R. (2007). **Technical Analysis: The Complete Resource for Financial Market Technicians**, FT Press, New Jersey.
- Michalewicz, Z. (1996). **Genetic Algorithms + Data Structures = Evolution Programs**. Springer, Berlin.
- Ngia, L.S. ve Sjöberg, J. (2000). “Efficient Training of Neural Nets for Nonlinear Adaptive Filtering Using a Recursive Levenberg-Marquardt Algorithm”, **IEEE Transactions on Signal Processing**, 48/7, 1915-1927.

- Öz, B., Ayriçay, Y. ve Kalkan, G. (2011). “Finansal Oranlarla Hisse Senedi Getirilerinin Tahmini: IMKB 30 Endeksi Hisse Senetleri Üzerine Diskriminant Analizi ile Bir Uygulama”, **Anadolu Üniversitesi Sosyal Bilimler Dergisi**, 11/3, 51-64.
- Özçalıcı, M. (2011). “Özdüzenleyici Haritalarla Banka Müşterilerinin Bölümlendirilmesi”, Yüksek Lisans Tezi, Gaziantep Üniversitesi Sosyal Bilimler Enstitüsü, Gaziantep, 2011.
- Svanandam, S.N. ve Deepa, S.N. (2008). **Introduction to Genetic Algorithms**, Springer, New York.
- Tektaş, A. ve Karataş, A. (2004). “Yapay Sinir Ağları ve Finans Alanına Uygulanması: Hisse Senedi Fiyat Tahminlemesi”, **Atatürk Üniversitesi İktisadi ve İdari Bilimler Dergisi**, 18/(3-4), 337-349.
- Toraman, C. (2008). “Demir-Çelik Sektöründe Yapay Sinir ağları ile Hisse Senedi Fiyat Tahmini: Erdemir A.Ş. ve Kardemir A.Ş. Üzerine Bir Tahmin”, **Muhasebe ve Finansman Dergisi**, 39, 44-57.
- Tsai, C.F. ve Hsiao, Y.C. (2010). “Combining Multiple Feature Selection Methods for Stock Prediction: Union, Intersection and Multi-intersection Approaches”, **Decision Support Systems**, 50/1, 258-269.
- Wu, J.Y. ve Lu, C.L., (2012). “Computational Intelligence Approaches for Stock Price Forecasting”, **International Symposium on Computer, Consumer and Control**, ss. 52-55.
- Yang, K., Wi, M. ve Lin, J., (2012). “The Application of Fuzzy Neural Network in Stock Price Forecasting Basad on Genetic Algorithm Discovering Fuzzy Rules”, **8th International Conference on Natural Computation**, ss. 470-474.
- Yıldız, B., Yalama, A. ve Coskun, M. (2008). “Forecasting the Istanbul Stock Exchange National 100 Index Using an Artificial Neural Network”, **World Academy of Science, Engineering and Technology**, 46, 36-39