

Morgan Stanley Capital International Türkiye Endeksinin Yapay Sinir Ağları ile Öngörüsü

Forecasting of Morgan Stanley Capital International Turkey Index with Artificial Neural Networks

Nuray GÜNERİ TOSUNOĞLU¹, Yasemin KESKİN BENLİ²

ÖZET

Zaman serisi analizi ile borsa endeksinin gelecek değerlerini öngörme, finans alanında oldukça ilgi gören bir konudur. Borsa endeks öngörüsü için kullanılan farklı zaman serisi yöntemleri bulunmaktadır. Bu yöntemlerden biri, son yıllarda birçok araştırmada kullanıldığı görülen Yapay Sinir Ağları (YSA)'dır. Yapay sinir ağlarının, diğer zaman serisi yöntemleri ile karşılaştırıldığında, bazı ön koşullar gerektirmemesi ve esnek bir modelleme yapısı olması nedeniyle daha üstün olduğu yapılan çalışmalarla ortaya konulmuştur. Bu çalışmada Morgan Stanley Capital International (MSCI) Türkiye endeksinin aylık değerlerine ilişkin öngörülerin yapay sinir ağları ile elde edilmesi amaçlanmıştır. Çalışmanın verileri Aralık 1987-Ağustos 2008 dönemini kapsamaktadır. Uygulamada, 12 girdi, 11 gizli ve 1 çıktı nöronundan oluşan ileri beslemeli bir ağ modeli kullanılmıştır. Performans ölçütü, hata kareler ortalamasının karekökü olarak seçilmiş ve değeri 0,1131 olarak hesaplanmıştır. Çalışma sonucunda YSA ile endeks değerlerine ilişkin, başarılı öngörüler elde edilmiştir.

Anahtar Kelimeler: Borsa, MSCI Türkiye endeksi, zaman serisi analizi, yapay sinir ağları, öngörü.

ABSTRACT

Forecasting of the stock exchange index future values with time series analysis has a great interest in finance field. There are different methods of time series used for the stock market index forecasting. One of these methods is Artificial Neural Networks (ANN) used in many studies in recent years. Artificial neural networks do not require prior conditions and they have a flexible modeling structure. For this reason, artificial neural networks are superior when compared with other methods of time-series. In this study, we aimed to forecast the Morgan Stanley Capital International (MSCI) Turkey index by artificial neural network. Data period is December 1987-August 2008. We used feed-forward network modeling consisting of 12 input, 11 hidden and 1 output neurons. As performance criteria the root mean square error was selected and its value was calculated as 0.1131. As a result successful predictions were obtained.

Keywords: Stock exchange, MSCI Turkey index, time series analysis, artificial neural networks, forecasting.

1. GİRİŞ

Geçmiş dönem endeks değerlerine dayanarak, endeksin gelecekte alacağı değerleri öngörebilmek, finans alanında oldukça ilgi gören bir konudur. İlgili literatür incelendiğinde, borsa endekslerinde oluşan hareketlerin yönünü kesin olarak modelleyebilecek bir yöntemin olmadığı görülmektedir. Borsa endeksinin tahminini zorlaştıran nedenler yüksek belirsizlik ve oynaklıktır. Bu nedenle borsa yatırımları diğer tüm yatırım alanlarından daha fazla risk taşır (Kutlu ve Badur, 2009:27). Borsa endeks tahmini için kullanılan farklı zaman serisi yöntemleri bulunmaktadır. Bu yöntemlerin uygulanabilmesi için bir takım ön koşulların sağlanması gerekmektedir. Yapay Sinir Ağları (YSA), bu ön koşulları gerektirmemesi ve yapı itibarıyla daha esnek olması sebebiyle son yıllarda öngörü amacıyla yaygın olarak kullanılmaya başlanmıştır. Yapılan çalışmalar, YSA'nın diğer zaman serisi

yöntemlerinden daha başarılı olduğunu göstermiştir. YSA modelleri; hisse senedi piyasa endekslerinin yönünün tahmin edilmesinde, finansal kriz dönemlerinin belirlenmesinde, mali başarısızlıkların öngörülmesinde, enflasyon tahmininde ve erken uyarı sistemlerinin geliştirilmesinde oldukça başarılı sonuçlar sağlamaktadır.

YSA ile finansal öngörü konusunda yapılmış çok sayıda çalışma bulunmaktadır. Malliaris ve Salchenberger (1996) gelecek volatilité değerlerinin öngörüsünde; Phua vd. (2000) Singapur borsasının yönünün tahmininde; Kim vd. (2004a), Kore'de finansal kriz modellemesinde; Kim vd. (2004 b) ekonomik krizlerin bir tahmin edicisi olarak erken uyarı sistemlerinin eğitilmesinde; Samanta ve Bordoloi (2005), Hindistan hisse senedi piyasası getirisinin tahmininde; Cao vd. (2005), Shanghai hisse senedi endeks getirisinin tahmininde; Huang vd. (2007), döviz kurunun, hisse

¹ Yrd. Doç. Dr., Gazi Üniversitesi, Ticaret ve Turizm Eğitim Fakültesi, Bilgisayar Uygulamaları Eğitimi Bölümü, nguner@gazi.edu.tr

² Doç. Dr., Gazi Üniversitesi, Endüstriyel Sanatlar Eğitim Fakültesi, İşletme Eğitimi Bölümü, ykeskin@gazi.edu.tr

senedi piyasa endeksinin ve ekonomik büyümenin tahmininde yapay sinir ağlarını kullanmışlardır. Bu çalışmaların bazılarında farklı zaman serisi modelleri ile karşılaştırılan yapay sinir ağlarının çok daha başarılı bir şekilde öngörüler verdiği ortaya konulmuştur.

YSA modellerinin Türkiye'deki uygulamaları da benzer sonuçlar vermiştir. Yıldız (2001) ve Benli (2002), finansal başarısızlığı öngörmede; Tektaş ve Karataş (2004), hisse senedi fiyatı tahmininde; Benli (2005), bankalarda mali başarısızlıkların öngörülmesinde; Avcı ve Çinko (2008), Avrupa Topluluğu'nun 5 yeni üyesi ve biri aday ülkeden oluşan, 6 gelişmekte olan ülkenin borsalarındaki günlük endeks getirilerinin tahmininde; Erilli vd. (2010), enflasyon öngörüsünde yapay sinir ağlarını başarılı bir şekilde uygulamışlardır. İMKB endeks değerinin öngörüsü üzerine de pek çok farklı çalışma yapılmıştır. Bu çalışmalar yapay sinir ağları ile yapılan öngörülerin başarısını ortaya koymuştur (Diler (2003), Altay ve Satman (2005), Karaatlı vd. (2005), Avcı (2007), Hamzaçebi ve Bayramoğlu (2007), Akel ve Bayramoğlu (2008), Kutlu ve Badur (2009), Ulusoy (2010)).

Bu çalışmada Morgan Stanley Capital International (MSCI) Türkiye endeksinin yapay sinir ağı ile öngörüsü yapılmıştır. MSCI endeksi, gelişmiş ve gelişmekte olan 49 ülkeye ilişkin hisse senedi performanslarını izleyen bir endekstir. Veriler, MSCI'nın resmi web sitesinden alınan, Aralık 1987-Ağustos 2008 dönemine ilişkin aylık Türkiye endeks değerleridir. Endeks hareketlerinin yönünü belirleyecek kesin bir model olmadığından, bu konuda yapılan her çalışma, endeks hakkında yeni bir bilgi sunacağından


önem taşımaktadır. Ayrıca, literatürde Türkiye için yer alan diğer endeks öngörülerinden farklı olarak bu çalışmada öngörüler MSCI endeks değerleri üzerinden elde edilmeye çalışılmıştır.

Çalışmanın ikinci bölümünde yapay sinir ağları açıklanmıştır. Üçüncü bölümde yapay sinir ağları ile zaman serilerinde öngörü konusu ele alınmıştır. Dördüncü bölümde MSCI Türkiye endeks değerlerinin aylık verileri üzerinden yapay sinir ağları ile öngörü uygulaması yapılmıştır. Beşinci bölümde ise, analizden elde edilen sonuçlara ilişkin tartışma yer almıştır.

2. YAPAY SİNİR AĞLARI

Yapay sinir ağları, insan beyninin özelliklerinden olan öğrenme yolu ile yeni bilgiler türetebilme ve keşfedebilme gibi yetenekleri herhangi bir yardım almadan kendiliğinden gerçekleştirmek amacı ile biyolojik sinir ağlarından esinlenilerek geliştirilen bilgisayar sistemleridir (Fausett, 1994:3; Öztemel, 2003:30). İnsan beynine benzer şekilde öğrenme, ilişkilendirme, sınıflandırma, genelleme, özellik belirleme ve optimizasyon gibi konularda uygulanmaktadır. Yapay sinir ağları örneklerden elde ettikleri bilgiler ile kendi deneyimlerini oluşturur ve daha sonra benzer kararları verirler.

Yapay sinir ağı modeli birbirleriyle bağlantılı olan nöronların bulunduğu katmanlardan oluşmaktadır. Temelde bu katmanlar; giriş katmanı, gizli katman ve çıktı katmanı olmak üzere üç tanedir. Ağın kaç katmandan oluştuğu ve bu katmanlarda yer alacak nöron sayıları, ağın mimarisi olarak adlandırılmaktadır. Yapay sinir ağının mimarisi, ağın performansını etkilemektedir.



Şekil 1:Yapay Sinir Ağı Modeli (Kaynak: Kurup ve Dudani, 2002:571)

Basit bir yapay sinir ağı modeli Şekil 1'de verilmiştir. İlk katman girdi değişkenlerinden oluşan giriş katmanıdır. Son katman çıktılarının yer aldığı çıktı katmanıdır. Arada bulunan gizli katman ise dış ortama bağlantısı olmayan nöronlardan oluşur ve bu nöronlar girdi katmanındaki sinyalleri çıktı katmanına gönderirler. Ağın çıktı değeri, girdilerin ağırlıklandırılmış toplamının bir aktivasyon fonksiyonundan geçmesi ile hesaplanmaktadır. Aktivasyon fonksiyonunun seçimi oldukça önemlidir. Yaygın olarak kullanılan fonksiyon tipleri, doğrusal, rampa, eşik ve sigmoid fonksiyonlarıdır (Güneri ve Apaydın, 2004:174).

İşleyiş şekillerine göre yapay sinir ağları, ileri beslemeli ve geri beslemeli ağlar olmak üzere ikiye ayrılırlar. İleri beslemeli yapay sinir ağlarında sinyaller sadece tek bir yönde, girdi katmanından çıktı katmanına doğru yönelir. Geri beslemeli ağlarda bir tür geri besleme işlemi vardır. Bu ağ yapılarında sinyalin yönü girdi katmanından çıktı katmanına doğrudur. Ancak aynı zamanda, bir katman üzerinde yer alan nöronlar, kendisinden, katmandaki diğer nöronlardan ya da diğer katmanlardaki nöronlardan sinyal alabilmektedir (Elmas, 2003:63, Güneri ve Apaydın, 2004:175). Zaman serilerinde en yaygın kullanılan yapay sinir ağı türü üç tabaklı ileri beslemeli modeldir. Tek değişkenli zaman serileri için ağın girdileri geçmiş veya gecikmeli değişkenler, çıktısı ise tahmin değeridir (Eğrioğlu ve Aladağ 2005:2)

Ağdaki bağlantıların ağırlıklarında depolanan bilginin istenen bir işlevi yerine getirecek biçimde ayarlanması, yapay sinir ağlarında öğrenme süreci olarak bilinir. Diğer bir ifadeyle, başlangıçta rasgele olarak belirlenen ağın ağırlık değerleri, öğrenme süreci sonunda ayarlanarak çıktılar elde edilir. Öğrenme için kullanılan farklı algoritmalar vardır. Temel olarak bu öğrenme algoritmaları danışmanlı ve danışmansız olarak iki gruba ayrılır. Danışmansız öğrenmede, girdi değişkenlerine karşılık çıktı değişkenleri belirtilmez. Ağırlıklar ağ tarafından kendiliğinden ayarlanır. Danışmanlı öğrenmede ise girdi değişkenlerine karşılık çıktı değişkenleri de ağa bilgi olarak yüklenir. Ağ, bağlantı ağırlıklarını düzenlerken, ağ çıktısı ile hedef çıktı arasındaki fark en küçük olacak biçimde ayarlama yapar. Danışmanlı öğrenmeyi kullanan sinir ağları için en yaygın olan öğrenme algoritması geri yayılım algoritmasıdır. Ağın en iyi performansı gösterbilmesi için, geri yayılım algoritmasında kullanılan öğrenme parametresinin seçimi önemlidir (Güneri ve Apaydın, 2004:175). Zaman serilerinde genellikle danışmanlı öğrenim algoritmalarından geri yayılım algoritması tercih edilmektedir.

Yapay sinir ağlarında, ağın veriler arasındaki ilişkiyi ne kadar iyi öğrendiğini belirlemek için kullanılan ölçüt, performans ölçütü olarak adlandırılır. En çok kullanılan performans ölçütleri, hata kareler ortalaması, hata kareler ortalamasının karekökü, normalleştirilmiş hata kareler ortalaması, mutlak hata ortalaması ve ortalama mutlak hata yüzdesidir (Günay vd., 2007:131).

Yapay sinir ağları ile ilgili teorik ayrıntılar için Fauset (1994) ve Elmas (2003)'e bakılabilir.

3. YAPAY SİNİR AĞLARI İLE ZAMAN SERİLERİNDE ÖNGÖRÜ

Zaman serilerinde YSA ile öngörü altı adımlık bir süreçte aşağıdaki gibi tanımlanabilir (Günay vd., 2007:131):

Adım 1. Verinin ön işlenmesi

İlk olarak veriler,

$$x'_i = \frac{x_i - \text{Min}(x_i)}{\text{Max}(x_i) - \text{Min}(x_i)} \quad (1)$$

dönüşümü ile [0,1] aralığına dönüştürülür. Burada x_i , girdi değerlerini göstermektedir.

Adım 2. Veri organizasyonu

Verilerin eğitim, geçerlilik ve test setlerine ayrımı gerçekleştirilir. Bu setlerin veri setinin yüzde kaçını kapsadığı tespit edilir.

Adım 3. Modelleme

Bu adımda, uygulamada kullanılacak olan YSA modeli oluşturulur. Model oluşturulurken, girdi, gizli ve çıktı tabakası sayısı, bu tabakalarda yer alacak nöron sayısı, aktivasyon fonksiyonu, öğrenme algoritması, öğrenme algoritmasına ilişkin parametreler ve performans ölçütü belirlenir.

YSA'nın girdi değerlerini gecikmeli zaman serileri oluşturmaktadır. X_t zaman serisi için girdi değerleri oluşturulurken, girdi tabakasındaki nöron sayısı m olmak üzere, m tane gecikmeli zaman serisi $X_{t-1}, X_{t-2}, \dots, X_{t-m}$ biçiminde oluşturulur.

Girdi ve gizli tabakalarında yer alacak nöron sayısının seçimi için farklı yaklaşımlar bulunmaktadır (Günay vd., 2007:126-127). Tüm bu yaklaşımlardan ortaya çıkan net bir kural olmadığından literatürde genellikle deneme yanılma yolu tercih edilmektedir.

Adım 4. En iyi ağırlık değerlerinin hesaplanması

YSA modeli belirlenirken Adım 3'te seçilen öğrenme algoritmasının eğitim seti üzerinde uygulanması ile en iyi ağırlık değerleri bulunur. Bu değerlerin kullanılması ile YSA modelinin çıktı değerleri hesaplanır.

Adım 5. Performans ölçütünün hesaplanması

Bu adımda YSA modelinin test setine ilişkin öngörüler elde edilir. Test setinin öngörülerini ile test setindeki verilerin arasındaki farka dayalı olarak, seçilen performans ölçütü hesaplanır.

Adım 6. Öngörü

Son olarak, Adım 4'te bulunan en iyi ağırlık değerleri kullanılarak gelecek için öngörü değerleri elde edilir.

4. UYGULAMA

Çalışmanın verileri MSCI Türkiye endeks değerlerinin aylık verileridir. Veriler Aralık 1987-Ağustos 2008 dönemini kapsamaktadır. YSA ile zaman serisi uygulaması 3.bölümde verilen algoritma ile gerçekleştirilmiştir. Analiz için Neural Connection paket programı kullanılmıştır. Algoritma adımları aşağıdaki gibidir:

Adım 1. İlk önce veriler (1) eşitliği ile [0,1] aralığına dönüştürülmüştür. Analiz sonunda [0,1] aralığına dönüştürülmüş veriler gerçek veri olarak değerlendirilerek bu değerler üzerinden yorum yapılacaktır.

Adım 2. Veri setindeki toplam veri sayısı 237'dir. Veri setinin ilk %80'lik kısmı eğitim, sonraki %10'u geçerlilik ve son %10'luk kısmı ise test seti olarak belirlenmiştir. Buna göre 189 veri eğitim, 24 veri geçerlilik ve 24 veri de test için kullanılmıştır.

Adım 3. Model tek girdi tabakası, tek gizli tabaka ve tek çıktı tabakasından oluşan ileri beslemeli bir ağıdır. Aktivasyon fonksiyonu sigmoid fonksiyonu olarak seçilmiştir. Öğrenme algoritması geri yayılım algoritmasıdır ve öğrenme oranı 0,9'dur. Performans ölçütü, Hata Kareler Ortalamasının Karekökü (HKOK) olarak belirlenmiştir. HKOK,

$$HKOK = \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n}} \quad (2)$$

eşitliği ile tanımlanır. Burada y_i , gerçek değerler; \hat{y}_i , ağdan elde edilen çıktı değerleri ve n veri sayısıdır.

Bu adımda, tabakalarda yer alacak nöron sayıları da tespit edilmektedir. Çıktı tabakasından bir nöron yer almaktadır. Çalışmada aylık veriler bulunduğu için 12 gecikmeli zaman serisinin kullanılması uygun bulunmuştur. Buna göre girdi tabakasından yer alacak nöronların sayısı 12 olarak belirlenmiştir. Gizli tabakadaki nöron sayısının seçimi için, nöron sayısının 1 ile 12 arasında değiştiği 12 durum değerlendirilmiştir. Uygulama yapılarak, test setinden elde edilen HKOK değerleri hesaplanmıştır. Mimari yapılar ve test setinden hesaplanan HKOK değerleri Tablo 1'de verilmiştir. Minimum HKOK değerine sahip model mimari

yapıyı oluşturacaktır. Tablo 1'de görülen mimari yapıda, ilk değer girdi tabakasındaki nöron sayısı, ikinci değer gizli tabakadaki nöron sayısı, üçüncü değer ise çıktı tabakasındaki nöron sayısıdır. Minimum HKOK değeri 0,113184 olup, buna sahip olan mimari yapının 12-11-1 olduğu görülmüştür. Buna göre, girdi tabakasından 12 nöron, gizli tabakadan 11 nöron ve çıktı tabakasından 1 nöron bulunacaktır.

Tablo 1: Test Seti için YSA Modelinden Hesaplanan HKOK Değerleri

Mimari Yapı	Test Seti için HKOK
12-1-1	0,123896
12-2-1	0,117649
12-3-1	0,116588
12-4-1	0,118572
12-5-1	0,118570
12-6-1	0,116282
12-7-1	0,115838
12-8-1	0,146651
12-9-1	0,155082
12-10-1	0,169035
12-11-1	0,113184
12-12-1	0,124969

Adım 4. Oluşturulan mimari yapıya göre YSA'nın eğitimi gerçekleştirilmiş ve en iyi ağırlık değerleri elde edilmiştir.

Adım 5. Test setine ilişkin öngörüler elde edilerek performans ölçütü hesaplanmıştır. HKOK değeri test seti için 0,113184, eğitim seti için 0,043196 ve geçerlilik seti için ise 0,077323 olarak bulunmuştur.

Adım 6. Adım 4'te elde edilen en iyi ağırlık değerlerinin kullanılması ile test setine ilişkin öngörüler hesaplanmıştır. Sonuçların incelenebilmesi için, test setinde yer alan son oniki verinin (Eylül 2007-Ağustos 2008 dönemi) gerçek değerleri ile YSA'dan elde edilen öngörülerini Tablo 2'de verilmiştir. Tüm test setinin gerçek değerleri ile öngörü değerlerine ilişkin grafiği ise Şekil 2'de görülmektedir.


Tablo 2 ve Şekil 2 beraber incelendiğinde, yapay sinir ağı ile elde edilen öngörülerin, gerçek endeks değerlerine yakın olduğu görülebilir. Yapay sinir ağlarının öngörü problemlerinde başarılı sonuçlar verdiği bu çalışma ile desteklenmiştir.

5. SONUÇ

Bu çalışmada MSCI Türkiye endeksinin yapay sinir ağı ile öngörüsü yapılarak değerlendirilmesi amaçlanmıştır. Çalışma sonucunda elde edilen bulgular ve performans ölçütü olan HKOK değerinin 0,1131 olarak bulunmuş olması, endeks değerlerinin yapay sinir ağları ile başarılı bir şekilde öngörülebildiğini göstermiştir.

Tablo 2: Test Setinin Eylül 2007-Ağustos 2008 Dönemine İlişkin Gerçek Değerleri ile YSA Öngörü Değerleri

Dönem	Gerçek Değerler	YSA Öngörü Değerleri
Eyl.2007	0,8941	0,6852
Eki.2007	1,0000	0,8141
Kas.2007	0,9205	0,8829
Ara.2007	0,9487	0,8178
Oca.2008	0,7137	0,8671
Şub.2008	0,7213	0,6313
Mar.2008	0,5640	0,6458
Nis.2008	0,6610	0,4842
May.2008	0,6232	0,5731
Haz.2008	0,5396	0,5552
Tem.2008	0,7058	0,4900
Ağu.2008	0,6339	0,6397

**Şekil 2:** Test Setine ilişkin YSA Öngörü Değerlerinin Gerçek Değerler ile Birlikte Grafiği (— Gerçek, - - - Öngörü)

Tablo 2 ve Şekil 2 incelendiğinde, gerçek endeks değerleri ile yapay sinir ağı modelinden elde edilen öngörü değerleri arasındaki sapmanın az olduğu görülmektedir. Eğitim seti üzerinden öğrenmeyi gerçekleştirerek en iyi ağırlık değerlerini elde eden ağın, özellikle kırılma noktalarında bu hareketliliği iyi algıladığı gözlenmektedir.

Şekil 2'de, Ekim 2007'ye kadar genel olarak borsada bir artışın olduğu görülmektedir. Ekim 2007'den sonra Aralık 2007'ye kadar değişkenlik gösteren borsa, bu tarihten sonra ani bir düşüş yaşamıştır. Şubat 2008 ve Nisan 2008'de bir önceki aya göre artışlar olmasına karşın Haziran 2008'de, borsanın, incelenen dönem aralığında en düşük seviyeyi gördüğü gözlenmiştir. Borsa endeksi, Temmuz 2008'de yeniden üst seviyelere ulaşmıştır. Söz konusu bu noktalarda yapay sinir ağının, artış ve azalışları başarılı bir biçimde öngördüğü görülmektedir. Araştırmanın test setini oluşturan dönemde MSCI Türkiye endeksinde yaşanan düşüşe, Amerika Birleşik Devletleri konut piyasasında başlayıp büyük bir hızla Avrupa'ya yayılarak genişleyen ve "2008 ekonomik krizi" olarak

adlandırılan krizin neden olduğu söylenebilir. Ayrıca Türkiye'de bu dönemde AKP'nin kapatma davası gibi bazı siyasi gelişmelerin de yaşanmış olmasının, bu düşüşün etkilerinden biri olduğu düşünülebilir. Temmuz 2008'de kapatma davasının sonuçlanması ile birlikte borsanın yeniden yükseldiği Şekil 2'de de görülmektedir.

Yapay sinir ağları, zaman serisi analizinde, diğer tekniklerle kıyaslandığında daha iyi ve etkin sonuçlar vermektedir. Bu sebeple finansal öngörü alanında kullanımı giderek yaygınlaşmaktadır. Bu çalışmada kullanılan veriler aylıktır. Bundan sonra yapılacak çalışmalarda veriler haftalık veya günlük çalışılarak daha hassas sonuçlara ulaşılabilir. Bunun yanı sıra son yıllarda zaman serisi analizlerinde tercih edilmeye başlanan melez yöntemlerle, aynı veriler üzerinde öngörülerde bulunarak yöntemsel karşılaştırmalar yapılabilir. Ayrıca yapay sinir ağları modelinden elde edilen öngörüler ile ne derece karlılık elde edilebileceği sorusu da araştırma konusu olarak önerilebilir.

KAYNAKLAR

- Akel, V. ve Bayramoğlu, M.F. (2008) “Kriz Dönemlerinde Yapay Sinir Ağları İle Finansal Öngöründe Bulunma: İMKB 100 Endeksi Örneği” International Symposium on International Capital Flows and Emerging Markets, 24-27 Nisan, Balıkesir.
- Altay, E. ve Satman, M.H. (2005) “Stock Market Forecasting: Artificial Neural Networks and Linear Regression Comparison in aAn Emerging Market” *Journal of Financial Management and Analysis*, 18(2):18-33.
- Avcı, E. (2007) “Forecasting Daily AndSessional Returns of The ISE-100 Index With Neural Network Models” *Doğuş Üniversitesi Dergisi*, 8(2):128-142.
- Avcı, E. ve Çinko, M. (2008) “Endeks Getirilerinin Yapay Sinir Ağları Modelleri İle Tahmin Edilmesi: Gelişmekte Olan Avrupa Borsaları Uygulaması” *İktisat, İşletme ve Finans Dergisi*, 23(266):114-137.
- Benli, Y.K. (2002) “Finansal Başarısızlığın Tahmininde Yapay Sinir Ağı Kullanımı ve İMKB’de Uygulama” *Muhasebe Bilim Dünyası Dergisi*, 4(4):17-30.
- Benli, Y.K. (2005) “Bankalarda Mali Başarısızlığın Öngörülmesi Lojistik Regresyon Ve Yapay Sinir Ağı Karşılaştırması” *Gazi Üniversitesi Endüstriyel Sanatlar Eğitim Fakültesi Dergisi*, 16:31-46.
- Cao, Q., Leggio K.B. ve 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*, 32(10):2499-2512
- Diler, A.İ. (2003) “İMKB Ulusal 100 Endeksinin Yönünün Yapay Sinir Ağları: Hata Geriye Yayma Yöntemi İle Tahmin Edilmesi” *İMKB Dergisi*, 7(25-26):66-81.
- Eğrioğlu, E. ve Aladağ, Ç.H. (2005) “Yapay Sinir Ağları ve Arıma Modellerin Melez Yaklaşımı ile Zaman Serilerinde Öngörü” İstanbul Üniversitesi VII. Ulusal Ekonometri ve İstatistik Sempozyumu, 26-27 Mayıs, İstanbul.
- Elmas, Ç. (2003) *Yapay Sinir Ağları (Kuram, Mimari, Eğitim, Uygulama)* Ankara, Seçkin Yayınları.
- Erilli, N.A., Eğrioğlu, E., Yolcu, U., Aladağ, Ç.H. ve Uslu, V.R. (2010) “Türkiye’de Enflasyonun İleri ve Geri Beslemeli Yapay Sinir Ağlarının Melez Yaklaşımı İle Öngörüsü” *Doğuş Üniversitesi Dergisi*, 11(1):42-55.
- Fausett, L. (1994) *Fundamentals of Neural Networks: Architectures, Algorithmsand Applications*, USA, Prentice Hall.
- Günay, S., Eğrioğlu, E. ve Aladağ, H. (2007) *Tek Değişkenli Zaman Serileri Analizine Giriş*, Ankara, Hacettepe Üniversitesi Yayınları.
- Güneri, N. ve Apaydın, A. (2004) “Öğrenci Başarılarının Sınıflandırılmasında Lojistik Regresyon Analizi ve Sinir Ağları Yaklaşımı” *Ticaret ve Turizm Eğitim Fakültesi Dergisi*, 1:170-188.
- Hamzaçebi, C. ve Bayramoğlu, M.F. (2007) “Yapay Sinir Ağları ile İMKB 100 Endeksinin Tahmini” Dokuz Eylül Üniversitesi 27. Yöneylem Araştırması ve Endüstri Mühendisliği Ulusal Kongresi, Temmuz 2-4 , İzmir.
- Huang, W., Lai, K.K., Nakamori, Y., Wang, S. ve Yu, L. (2007) “Neural Networks in Finance and Economics Forecasting” *International Journal of Information Technology & Decision Making*, 6(1):113-140.
- Karaatlı, 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.
- Kim, T.Y., Hwang, C. ve Lee, J. (2004a) “Korean Economic Condition Indicator Using a Neural Network Trained on the 1997 Crisis” *Journal of Data Science*, 2(4):371-381.
- Kim, T.Y., Oh, K.J., Sohn, I. ve Hwang, C. (2004b) “Usefulness of Artificial Neural Networks for Early Warning System of Economic Crisis” *Expert Systems With Applications*, 26(4):583-590.
- Kurup, P.U. ve Dudani, N.K.,(2002) “Neural Networks For Profiling Stres History of Clays From Pcpt Data” *Journal of Geotechnical&Geoenvironmental Engineering*, 128(7):569-580.
- Kutlu, B. ve Badur, B. (2009) “Yapay Sinir Ağları ile Borsa Endeksi Tahmini” *Yönetim*, 20(63):25-40.
- Malliaris, M. ve Salchenberger, L. (1996) “Using Neural Networks to Forecast The S&P100 Implied Volatility” *Neurocomputing*, 10(2):183-195.
- Öztemel, E. (2003) *Yapay Sinir Ağları*, İstanbul, Papatya Yayınları.
- Phua, P.K.H., Ming, D. ve Lin, W. (2000) “Neural Network With Genetic Algorithms for Stocks Prediction” Fifth Conference of The Association of Asian-Pacific Operations Research Societies Proceedings, 5-7 July, Singapore.

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.

Samanta, G.P. ve Bordoloi, S. (2005) “Predicting Stock Market- An Application of Artificial Neural Network Technique Through Genetic Algorithm” *Finance India*, 19(1):173-188.

Ulusoy, T. (2010) “İMKB Endeks Öngörüsü İçin İleri Beslemeli Ağ Mimarisine Sahip Yapay Sinir Ağı Modellemesi” *Uluslararası İktisadi Ve İdari İncelemeler Dergisi*, 2(5):21-40.

Yıldız, B. (2001) “Finansal Başarısızlığın Öngörülmesinde Yapay Sinir Ağı Kullanımı ve Halka Açık Şirketlerde Ampirik Bir Uygulama” *İMKB Dergisi*, 17:51-67.