

Yatırım Fonları Net Varlık Değerlerinin Yapay Sinir Ağları Yöntemiyle Tahmin Edilmesi*

Forecasting Mutual Fund Net Asset Values Using Artificial Neural Networks

Yrd. Doç. Dr. Veli Akel - Uzm. Fikriye Karacameydan

Öz

Bu çalışmanın amacı, Türkiye'deki yatırım fonlarının net varlık değerlerinin, Yapay Sinir Ağları (YSA) yöntemiyle tahmin edilmesidir. Ocak 2001-Aralık 2008 döneminde, 19 adet A tipi ve 19 adet B tipi olmak üzere toplam 38 adet yatırım fonunun net varlık değerlerinin tahmin edilmesi için 6 adet makro ekonomik değişkenden yararlanılmıştır. Çalışmada yatırım fonu net varlık değeri hem YSA hem de regresyon modeli çerçevesinde öngörülmesi ve her iki yöntem için elde edilen sonuçların öngörü performansları karşılaştırılmıştır. Analiz sonuçları, yatırım fonları net varlık değerlerini tahmin etmek için geliştirilen YSA modellerinin çok düşük hata düzeyinde regresyon yönteminden daha başarılı sonuçlar verdiğini ortaya koymuştur.

Anahtar Kelimeler: Yatırım Fonları, Net Varlık Değeri, YSA, Finansal Tahmin

Abstract

This study aims to forecast net asset values of Turkish mutual funds using Artificial Neural Networks (ANN) method. In order to forecast net asset values of 38 mutual funds (19 A type and 19 B type), 6 macro economic variables are used in the period of January 2001-December 2008. Net asset values of mutual funds have been forecasted within the frame of both ANN and regression model and forecasting performances of the methods have been compared. Analysis results reveal that ANN method is capable of forecasting net asset values of mutual funds at a very low error level and seems to outperform regression method.

Keywords: Mutual Funds, Net Asset Value, Artificial Neural Network, Financial Forecasting

Giriş

Yapay Sinir Ağları (YSA) yöntemi, insan beyninde yer alan biyolojik sinir ağları temel alınarak geliştirilen bir hesaplama yöntemi şeklinde tanımlanmaktadır. YSA, özünde insan beyninin çalışma biçimini taklit eden, basit bir işlem elemanı olan nöronların değişik şekillerde birbirine bağlanmasıyla oluşan bir sistemdir. Her bir nöron diğer nöronlardan veya dışarıdan gelen sinyalleri alır, bunları birleştirir, dönüştürür ve sayısal sonuç ortaya çıkarır (Zhang, vd., 1998, s.37; Indro, vd., 1999, s.374). YSA yöntemi doğrusal olmayan yapılardan ve kendine özgü eğitim sürecinden kaynaklanan avantajlarından dolayı son yıllarda özellikle çözümü zor ve karmaşık olan çok farklı alanlardaki problemlerin çözümünde kullanılmış ve genellikle çok başarılı sonuçlara ulaşılmıştır. Ayrıca, YSA, zaman serilerindeki trend veya yapıyı en iyi tanımlayan bir yöntem olması nedeniyle da tahmin ve öngörü işlemleri için çok uygundur. Sınıflandırmada ve zaman serilerinin öngörülmesinde oldukça başarılı sonuçlar üretebildiği için istatistik, ekonomi ve finans konularında da yoğun bir şekilde kullanılmaktadır (Kaastra ve Boyd, 1996, s.216).

YSA yöntemi, finans biliminin birçok alanında yaygın ve etkin bir şekilde kullanılan bir yöntemdir. Bu alanlar arasında; yatırım fonlarının ve hisse senetlerinin performansının ölçülmesi ve seçimi, döviz kurlarının yönünün belirlenmesi, bir şirketin iflas edip etmeyeceğinin (mali başarısızlık durumunun) tahmin edilmesi, finansal krizlerin öngörülmesi, menkul kıymetlerin gelecekteki fiyatlarının tahmin edilmesi gibi konular sayılabilir. Yapay sinir ağları yönteminin finansal zaman serilerinin tahmin edilmesi konusunda sağladığı en önemli fayda; zaman serisine uygun bir model yapısı aramadan ve serinin doğrusal yapıya

* Bu çalışma, Bozok Üniversitesi Sosyal Bilimler Enstitüsü İşletme ABD Yüksek Lisans programında kabul edilen "Yatırım Fonları Net Varlık Değerlerinin Yapay Sinir Ağları Yöntemiyle Tahmin Edilmesi" başlıklı Yüksek Lisans tezinden uyarlanmıştır.

Yrd. Doç. Dr. Veli Akel, Bozok Üniversitesi İ.İ.B.F. İşletme Bölümü, veliakel@gmail.com

Uzm. Fikriye Karacameydan, Gazi Üniversitesi İ.İ.B.F. Tapu ve Kadastro Yüksek Okulu, fkarcameydan@gazi.edu.tr

sahip olup olmadığı önceden belirlenmeden çözümlene yapıp sonuca ulaşabilmesidir. Bu özellikleri, YSA'yı avantajlı bir konuma getirmektedir. Finansal piyasalarda günlük fiyat hareketleri, dinamik ve dalgalı bir yapıya sahip olduğu için, YSA gibi bilgisayar temelli öğrenme algoritmaları finansal piyasaların yönünü tahmin etmede oldukça uygun yöntemlerdir (Oh, vd., 2006, s.96).

Ekonomideki belirsizlikler nedeniyle ekonomik zaman serilerinin gelecekte göstereceği performans ve davranışı kestirebilmek karar vericiler için oldukça önemlidir. Bu durumda gözlemlenen değerlerden hareketlerle bir zaman serisi için kurulan modelin, serinin gelecekte (bir gün, bir ay veya bir yıl sonraki) alabileceği muhtemel değerleri tahmin edebilecek bir performansa sahip olması beklenir. Başka bir deyişle, modelin tahmin (öngörü-forecasting) performansının yüksek olması beklenir. Literatürdeki birçok ampirik çalışmada, öngörü modeli olarak ekonometrik modeller kullanıldığı gibi son yıllarda YSA modelleri de gösterdikleri yüksek tahmin performansı nedeniyle, ekonometrik modellerle karşılaştırmalı olarak kullanılmaya başlanmıştır. Bunun nedeni YSA modellerinin doğrusal olmayan, mevsimsellik ve trend içeren zaman serilerini tahmin etmede klasik modeller kadar ve onlardan daha üstün performans gösterebilmesidir (Zhang ve Qi, 2005, s.502).

Her ne kadar, finansın birçok farklı alanında kullanılsalar da, YSA modellerinin yatırım fonları üzerinde uygulanmasının sınırlı olduğu gözlenmektedir. YSA modellemesinden yararlanarak yatırım fonları net varlık değerleri ile makro ekonomik değişkenler üzerinde yapılan ve ulaşılabilen üç çalışmadan ikisi Hindistan diğeri ise ABD yatırım fonlarını konu almaktadır. Türkiye'de ise yatırım fonlarına YSA yöntemini uygulayan bir çalışmaya rastlanmamıştır. Bu açıdan çalışmamızın özgün olduğu düşünülmektedir.

Çalışmanın amacı, Ocak 2001-Aralık 2008 döneminde Türkiye'de faaliyet gösteren, verileri kesintiye uğramayan ve 2008 yılı sonu itibarıyla net varlık değeri en yüksek olan A ve B tipi yatırım fonlarının net varlık değerleri ile seçilen makro ekonomik değişkenler arasındaki uzun dönemli ilişkiyi regresyon ve yapay

sinir ağları yöntemi ile tahmin etmek ve her iki yöntem için elde edilen sonuçların tahmin performanslarını karşılaştırmaktır. Analiz sonuçları, incelenen 38 adet yatırım fonunun net varlık değerlerinin, YSA modeli kullanılarak başarılı bir biçimde tahmin edilebileceğini göstermiştir.

Çalışmanın izleyen bölümünde, YSA yönteminin temel özellikleri hakkında genel bilgi verilmiş; YSA yöntemlerinden yararlanarak ekonomik ve finansal tahmin yapan uygulamalı çalışmalar özetlenmiştir. Daha sonraki bölümde araştırma yöntemi ve verilere ilişkin açıklamalar yapılmış izleyen bölümde ise regresyon ve YSA modellerinin uygulama sonuçlarına yer verilmiştir.

Yapay Sinir Ağları

1940'lı yıllardan itibaren çeşitli araştırmalara konu olan ve gelişimini sürdürerek günümüzde birçok alanda kullanılan Yapay Sinir Ağları (YSA), finans alanında 1980'li yılların sonlarından itibaren öngörü, sınıflandırma ve modelleme amacıyla kullanılan bir yöntemdir (Öztemel, 2006, s.29). Yapay sinir ağları, insan beyninin çalışma mekanizmasını taklit ederek beynin, öğrenme, hatırlama ve genelleme yapma yolu ile yeni bilgiler üretebilme gibi yeteneklerini herhangi bir yardım almadan otomatik olarak gerçekleştirmek amacı ile geliştirilen bilgisayar sistemleridir. YSA, ağırlıklandırılmış biçimde, tek yönlü sinyal kanalları ile birbirlerine bağlanmış birçok basit işlem elemanından oluşan, paralel ve dağınık, tek veya çok katmalı bilgi işlem sistemidir (Kamruzzman, vd., 2006, s.3). Başka bir deyişle, yapay sinir ağı dışarıdan gelen girdilere dinamik olarak yanıt oluşturma yoluyla bilgi işleyen, birbiriyle bağlantılı nöronlardan oluşan bir bilgi işlem sistemidir (Sahoo ve Hathy, 2007, s.5).

Yapay sinir hücreleri gerçek sinir hücrelerinin simüle edilmesiyle gerçekleştirilir ve bu hücreler değişik şekillerde birbirine bağlanarak ağı oluştururlar (Kamruzzman, vd., 2006, s.3; Yurtoğlu, 2005, s.14). Gerçek bir sinir hücresindeki nöron, işlem elemanına; dentrit, girdilere; hücre gövdesi, aktivasyon (transfer) fonksiyonuna; aksonlar, yapay nöron çıkışına ve snapslar ise ağırlıklara karşılık gelmektedir. Bir yapay

sinir ağında girdiler, ağırlıklar, toplama fonksiyonu, aktivasyon fonksiyonu ve çıktılar olmak üzere beş temel eleman bulunmaktadır (Öztemel, 2006, s.48-51).

Nöronların aynı doğrultu üzerinde bir araya gelmesiyle katmanlar (girdi, gizli ve çıktı) ve bu birkaç katmanın birleşmesiyle de yapay sinir ağları oluşmaktadır. Sebep sonuç ilişkisine dayalı olarak yapılan tahmin problemlerinde *girdi nöron sayısı* bağımsız değişken sayısına başka bir deyişle probleme etki eden parametre sayısına karşılık gelirken *çıktı nöron sayısı* da bağımlı değişken sayısına karşılık gelmektedir. Gizli katman ve bu katmandaki gizli nöronlar, yapay sinir ağlarının başarısında büyük önem taşımaktadır (Zhang, vd., 1998, s.42). Gizli katman sayısı probleme, veri miktarına ve tasarıma bağlı olarak değişmektedir. Girdi katmanı, gizli katman ve çıktı katmanından oluşan üç katmanlı bir ağ için gizli nöron sayısı girdi katmanındaki nöron sayısının %75'i olarak önermektedirler. Ayrıca uygulamalar göstermiştir ki, toplamda dört katmandan fazlası ağın başarı performansını ters yönde etkilemektedir (Kaastra ve Boyd, 1996, s.225). Dolayısıyla doğrusal olmayan fonksiyonların tasarlanması için *bir gizli katman* yeterli olmaktadır (Panda ve Narasimhan, 2007, s.227-236).

Öngörü amaçlı en yaygın olarak kullanılan YSA tipi, çok katmanlı algılayıcılar (ÇKA). Çok katmanlı YSA, birçok nöronun birbiriyle bağlanarak meydana getirdikleri birkaç katmandan oluşan tipik bir ağıdır. Çok katmanlı YSA'lar, girdi katmanı, çıktı katmanı ve bu iki katman arasında da bir veya birden fazla gizli katman bulunmaktadır. Çok katmanlı YSA'ları karmaşık problemlerin çözümünde, özellikle de tahminlerde kullanılmaktadır. Çünkü bu ağ, yapısında bulunan gizli katmanda yapılan bir dizi işlem ile kendiliğinden doğrusal olmayan bir yapıya dönüşebilme yeteneğine sahiptir (Zhang, vd., 1998, s.37-38).

ÇKA'ların ilk katmanı girdi katmanıdır. Bu katman çözülmesi istenilen probleme ilişkin bilgilerin alınmasını sağlar. Son katmanı ise ağ içinde işlenen bilginin dışarıya iletiği çıktı katmanıdır. Girdi katmanı ile çıktı katmanı arasında ise gizli nöronların yer aldığı en az bir tane gizli katman bulunmaktadır. Gizli katmandaki her nöron, doğrusal olmayan bir transfer

fonksiyonuna sahiptir ve bu fonksiyonlar aracılığıyla elde edilen sonuçlar bir sonraki nöronlara girdi sağlamaktadır (Smith, 2002, s.5). Her bir nöron diğer nöronlarla bağlantılıdır ve bir ağırlık değerine sahiptir. Ağırlıklar, nöronlar arasındaki bağlantıların sayısal değeridir ve bir yapay sinir hücresine gelen bilginin önemi ve hücre üzerindeki etkisini gösterirler. Ayrıca gizli katman ile çıktı katmanındaki nöronların net girdisinin hesaplanmasında kullanılırlar. Dolayısıyla bilgi tüm bu bağlantılar aracılığıyla nöronlara ve katmanlar arasında ağın çıktısına kadar iletilmekte ve ağın dağıtılmış hafızaya sahip olmasına neden olmaktadır (Fausett, 1999, s.3).

Teknik olarak, bir YSA'nın temel özelliği öğrenme yeteneğidir. Öğrenmenin temel felsefesi, kendisine gösterilen gerçekleşmiş bir girdi setindeki yapıyı öğrenerek, bu veri setine karşılık gelebilecek bir çıktı seti belirlemektir. Ağın bunu yapabilmesi için ilgili olayın örnekleri ile eğitilerek genelleme yapabilecek yeteneğe kavuşturulması gerekmektedir. Bu aşamada bir olay ile ilgili örneklerin girdi ve çıktıları arasındaki ilişkinin olayın genelini temsil edecek bilgiler içerdiği kabul edilmektedir (Öztemel, 2006, s.30; Anderson ve McNeill, 1992, s.22-23).

Literatür İncelemesi

Ekonomik ve finansal değişkenlerin modellenmesi ve öngörülmesi ekonomi ve finans için son derece önemlidir. Özellikle son yıllarda zaman serileri alanında kaydedilen gelişmelerden dolayı ekonomik ve finansal modellemelerde ekonometrik yöntemlerin kullanımı giderek artmaktadır. Bunun yanında kendine geniş bir uygulama alanı bulan YSA'ları ekonometrik yöntemlere alternatif ve performansı karşılaştırılabilir bir öngörü yöntemi haline gelmiştir. Sınıflandırmada ve zaman serilerinin öngörülmesinde oldukça başarılı sonuçlar üretebildiği için istatistik, ekonomi ve finans konularında da yoğun bir şekilde kullanılmaktadır (Kaastra ve Boyd, 1996, s.216).

Literatürde finansal değişkenlerin YSA yöntemiyle modellenmesi ve tahmini konusunda birçok çalışma bulunmaktadır (Yao, vd., 1996; Zhang, 2001; Kim, vd., 2004; Dutta, vd., 2006; Panda ve Narasimhan, 2007; Tseng, vd., 2008; Liang, vd., 2009; Quian ve

Rasheed, 2009). Bu çalışmalar ağırlıklı olarak döviz kuru ve hisse senedi fiyatlarının tahmin edilmesini konu almaktadır. Türkiye sermaye piyasalarını dikkate alan çalışmalar da YSA modellemesinin diğer modellere göre daha başarılı sonuçlar ürettiğini ortaya koymaktadır (Yıldız, 2001; Diler, 2003; Benli, 2005; Altay ve Satman, 2005; Karaçor ve Alptekin, 2006; Avcı, 2007; Altan, 2008).

Yatırım fonlarına ilişkin YSA modeliyle tahmin yapan çalışmaların temel sonuçları ise aşağıda özetlenmeye çalışılmıştır. Chiang, Urban ve Baldrige (1996), yatırım fonlarının yılsonu net varlık değerlerini, bazı ekonomik değişkenleri kullanarak geri beslemeli bir

YSA modeli ile tahmin etmişler ve geliştirdikleri YSA modelinin doğrusal ve doğrusal olmayan regresyon analizine göre daha başarılı tahmin performansına sahip olduğunu tespit etmişlerdir. Indro, Jiang, Patuwo ve Zhang (1999), 1993-1995 dönemini kapsayan çalışmada, ABD hisse senedi yatırım fonlarının performansını çok katmanlı ve ileri beslemeli, bir gizli katmandan oluşan bir YSA modeli kullanarak tahmin etmişler ve tahmin sonuçlarını oluşturdukları iki adet doğrusal regresyon model tahminleriyle karşılaştırmışlardır. Yatırım fonları performansını tahmin etmede, YSA modelinin doğrusal modele göre daha başarılı olduğunu tespit etmişlerdir. Analizlerinde hisse senedi yatırım fonları yıllık getiri verilerini kullanarak Jensen alfasını hesaplamışlardır. Karşılaştırma ölçütünü, hata ölçümünü üç sınıfa ayırarak yapmışlar ve ortalama hata, ortalama mutlak hata, standart sapmanın hatası ve ortalama mutlak yüzde hatası olmak üzere dört grupta tanımlamışlardır.

Ray ve Vani (2004), Hindistan yatırım fonlarının gelecekteki net varlık değerlerini YSA modeli kullanarak tahmin etmeye çalışmışlardır. Veri seti olarak, 1999-2004 döneminde Hindistan'da faaliyet gösteren 10 adet yatırım fonunun aylık net varlık değerleri ile 6 adet makro ekonomik değişken kullanmışlardır. Çalışmada, sanayi üretimi, faiz oranı, enflasyon oranı, döviz kuru, para arzı ve hisse senedi piyasası büyüklüğü gibi makro ekonomik değişkenlerde meydana gelen değişimlerin, yatırım fonları net varlık değerleri üzerindeki etkisini, sigmoid aktivasyon fonksiyonundan yararlanarak geri yayılım algoritması ile eğittikle

ri ÇKA modeli kullanarak tahmin etmişlerdir. Ray ve Vani'nin, YSA modelleme tekniği ile yaptıkları tahmin sonucunda ulaştıkları bulgular şu şekilde özetlenebilir (Ray ve Vani, 2004, s.8-10).

Faiz oranı ile yatırım fonu net varlık değerleri arasında negatif bir ilişki vardır. *Enflasyon oranı* ile faiz oranı arasında pozitif bir ilişki vardır ve varlık fiyatlarını olumsuz etkilemektedir. Dolayısıyla enflasyon oranı yüksek olduğunda küçük ve büyük yatırımcılar yatırım fonlarını satma eğiliminde olacaklardır. *Para arzının* yatırım fonu piyasasına etkisi ise belirgin değildir. Bir taraftan, parasal büyümenin enflasyon oranı ile pozitif ilişkisi olduğundan, hisse senedi ve yatırım fonu fiyatlarını olumsuz etkilemektedir. Diğer taraftan, parasal büyüme ekonomiyi uyarmakta, şirket kazançları ve hisse senedi fiyatları dolayısıyla yatırım fonu net varlık değerleri artmaktadır. Ayrıca para arzı ile faiz oranı arasında ters ilişki olduğundan hisse senedi ile yatırım fonu fiyatları üzerinde negatif etki yapmaktadır. *Endeks getirileri* ile yatırım fonlarının net varlık değerleri arasında pozitif ilişki vardır. *Döviz kurları* ve *sanayi üretim endeksi* ile yatırım fonları net varlık değerleri arasında ise ihmal edilebilir düzeyde bir ilişki vardır.

Sahoo ve Hathy (2007)'nin 1980-2000 dönemini kapsayan yaptıkları çalışmalarında, Hindistan yatırım fonları net varlık değerlerini geri yayılım algoritmasıyla eğitilen çok katmanlı YSA modeli ve doğrusal regresyon yöntemi ile tahmin etmişlerdir. Analizde, veriler eğitim, test ve öngörü seti olmak üzere üç setine ayrılmıştır. Verilerin %85'i eğitim seti olarak belirlenmiş, transfer fonksiyonu olarak, lineer ve sigmoid fonksiyonları ve öğrenme kuralı olarak da delta öğrenme kuralı kullanılmıştır. YSA modelinin regresyon analizine göre daha başarılı sonuçlar ürettiğini tespit etmişlerdir (Sahoo ve Hathy, 2007, s.5-15).

Araştırma Yöntemi ve Veri Seti

Çalışmanın amacı doğrultusunda ve literatür incelemesi çerçevesinde yatırım fonları net varlık değerleri üzerinde etkide bulunabilecek makro ekonomik değişkenler 6 adet olarak tespit edilmiştir. Modellerde bağımsız değişken olarak, Aktif Tahvilin Faiz Oranı (ATFAİZ), ABD Doları/TL Kuru (DK), İMKB-100

Endeksi (İMKB100), Para Arzı (M2), Sanayi Üretim Endeksi (SUE) ve Toptan Eşya Fiyat Endeksi (TEFE) kullanılmıştır. Bağımlı değişken olarak 19 adet A tipi ve 19 adet B tipi olmak üzere toplam 38 adet Yatırım Fonu Net Varlık Değeri (NVD) tespit edilmiştir (Tablo 1).

Tüm değişkenlerin aylık değerleri kullanılmış ve Aktif Tahvilin Faiz Oranı hariç, doğrusallığın sağlama-

sında önemli katkısı olmasından dolayı, tüm değişkenlerin doğal logaritmaları alınmıştır (Hamilton, 1994, s.438). Aktif Tahvilin Faiz Oranı değişkeni için oransal değerler söz konusu olduğundan bu değişkenin logaritması alınmamıştır. Analiz dönemi olarak 01.01.2001-31.12.2008 tarihleri arasındaki 8 yıllık (96 ay) bir zaman periyodu seçilmiştir.

Tablo 1. Çalışmada Kullanılan A ve B Tipi Yatırım Fonları

Fon Kodu	A Tipi Yatırım Fonları	Fon Kodu	B Tipi Yatırım Fonları
A1	ACAR YAT. MEN. DEĞ. A.Ş. A TİPİ DEĞİŞ. F.	B1	AKBANK T.A.Ş. B TL. UZUN VAD. TAH. B. F.
A2	AKBANK T.A.Ş. A TİPİ HİSSE SENEDİ F.	B2	ATA YATIRIM MEN. KIYM. A.Ş. B TİPİ LİK. F.
A3	AKBANK T.A.Ş. A TİPİ SABANCI H. İŞTR. F.	B3	FINANSBANK A.Ş. B TİPİ LİKİT FON
A4	ECZACIBAŞI MEN. DEĞ. A.Ş. A TİPİ DEĞ. F.	B4	HSBC BANK A.Ş. B TİPİ LİKİT FON
A5	GLOBAL MEN. DEĞ. A.Ş. A TİPİ DEĞİŞ. FON	B5	İŞ YAT. MEN. DEĞ. A.Ş. B TİPİ DEĞİŞ. FON
A6	İŞ YAT. MEN. DEĞ. A.Ş. A TİPİ DEĞİŞ. FON	B6	T.C. ZİRAAT BANKASI B TİPİ DEĞİŞKEN FON
A7	YKB A.Ş. A TİPİ KOÇ-ALLIANZ SİG. ÖZEL F.	B7	T.C. ZİRAAT BANKASI B TİPİ LİKİT FON
A8	YKB A.Ş. A TİPİ İMKB-100 ENDEKSİ F.	B8	TEB. A.Ş. B TİPİ LİKİT FON
A9	T.C. ZİRAAT BANKASI A TİPİ DEĞİŞ. FON	B9	T.GARANTİ BANK. A.Ş. B TİPİ FLEXİ DEĞİŞ. F.
A10	TEB. YAT. MEN. DEĞ. A.Ş. A TİPİ HİS. S. F.	B10	T. GARANTİ BANKASI A.Ş. B TİPİ LİKİT FON
A11	T. GARANTİ BA. A.Ş. ÖZEL BANK. A T. D. F.	B11	T. GARANTİ BAN. A.Ş. B TİPİ TAH. VE BON. F.
A12	T. GARANTİ BA. A.Ş. ATİPİ İMKB-30 END. F.	B12	T. İŞ BANK. A.Ş. B TİPİ LİKİT FON
A13	T. İŞ BANK. A.Ş. A TİPİ DEĞİŞKEN FON	B13	T. İŞ. BANK. B TİPİ TAHVİL VE BONO FONU
A14	T. İŞ BANK. A.Ş. A TİPİ HİSSE SENEDİ F.	B14	T. VAKIFLAR BANK. T.A.O. B TİPİ DEĞİŞ. F.
A15	T. İŞ BANK. A.Ş. A TİPİ İŞTİRAK F.	B15	T. VAKIFLAR BANK. T.A.O. B TİPİ LİKİT FON
A16	T. İŞ BANK. A.Ş. A TİPİ İMKB-30 END. F.	B16	YAPI VE KREDİ BANK. A.Ş. B TİPİ DEĞİŞ. F.
A17	YAPI KRE. YAT. MEN. DEĞ. A.Ş. A T. D.F.	B17	YAPI VE KREDİ BANK. A.Ş. B TİPİ LİKİT FON
A18	YAPI VE KREDİ BANK. A.Ş. A TİPİ H. S. F.	B18	YAPI KREDİ YAT. MEN DEĞ. A.Ş. B TİPİ LİK.
A19	YAPI VE KREDİ BANK. A.Ş. A TİPİ KAR.F.	B19	YAT. FİNS. MEN. DEĞ. A.Ş. B TİPİ LİKİT FON

Kurulan modelde, farklı tipteki Yatırım Fonu Net Varlık Değeri (NVD) bağımlı değişken, altı adet makro ekonomik değişken de bağımsız değişken olarak belirlenmiştir. Modeldeki makro ekonomik değişkenler, yatırım fonları için gösterge (benchmark veya fon karşılaştırma ölçütü) olarak da kullanılmaktadır.

Tüm değişkenler için, Ocak 2001-Aralık 2008 dönemine ait aylık veriler kullanılarak oluşturulan yatırım fonu net varlık değeri öngörü modeli aşağıdaki biçimde tanımlanmıştır:

$$NVD_i = f(ATFAİZ, DK, TEFE, İMKB100, M2, SUE, \epsilon_i) \quad (4.1)$$

Burada;

NVD_i : i. Yatırım Fonu Net Varlık Değeri (Bin TL),

ATFAİZ : Aktif Tahvilin Faiz Oranı (%),

DK : ABD Doları/TL Kuru,

TEFE : Toptan Eşya Fiyat Endeksi (1997=100),

İMKB100 : İMKB-100 Endeksi,

M2 : Para Arzı (Bin TL),

SUE : Sanayi Üretim Endeksi (1997=100),

ϵ_i : Hata Terimini göstermektedir.

Tüm bu değişkenlere ait zaman serileri T.C. Merkez Bankası üç aylık bültenlerinden, SPK aylık bültenlerinden, TCMB, TÜİK web adreslerinden elde edilmiştir. Bağımlı ve bağımsız değişkenlere ait Ocak 2001-Aralık 2008 dönemi zaman serisi verileri En Küçük Kareler Yöntemine (EKKY) göre değerlendirilmiştir. Tüm değişkenlerin aylık değerleri kullanılarak aşağıdaki regresyon modeli tahmin edilmeye çalışılmıştır.

$$\ln NVD_i = \beta_0 - \beta_1 \ln ATFAİZ - \beta_2 \ln DK + \beta_3 \ln İMKB100 + \beta_4 \ln M2 + \beta_5 \ln SUE + \beta_6 \ln TEFE + \beta_7 \ln NVD_{i-1} + \epsilon_i \quad (4.2)$$

Çalışmanın amacı oluşturulan modelde değişkenler arasındaki gerçek ilişkiyi bulabilmek ve sahte regresyonla karşılaşmamak olduğundan, tüm değişkenlerin logaritmik birinci sıra farkları alınmış ve modele EKKY yöntemi uygulanmıştır.

Daha sonra regresyon modeli ile yapılan tahminlerin geçerliliğini sağlayan ekonometrik varsayımların varlığı araştırılmıştır. Bu amaçla, modelde hata terimleri

arasında ardışık bağımlılığın olup olmadığını yani otokorelasyon varlığının tespiti için Breusch-Godfrey Testi (BG testi, LM testi) kullanılırken; modelde hata terimi standart sapmasının sabit olup olmadığını yani değişen varyans varlığının tespiti için ise White Testi kullanılmıştır (Gujarati, 2004, s.257; Sevüktekin ve Nargeleçekenler, 2007, s.344; Ertek, 2000, s.240).

Verilerin analizinde E-Views 5.1 programı kullanılarak regresyon modelleri, NeuroSolutions 5.0 programı kullanılarak da YSA modelleri geliştirilmiştir.

Regresyon ve YSA Modellerinin Uygulama Bulguları

Çalışmanın bu bölümünde, 38 adet yatırım fonu net varlık değerlerinin öncelikle regresyon daha sonra da YSA modeli ile öngörülmesine ilişkin bulgular özetlenmiştir.

Serilerin durağan olması etkin ve tutarlı tahminler için gerekli olan bir varsayımdır. Bir zaman serisinde belirli bir zaman sürecinde sürekli artma veya azalma olmuyorsa ve veriler zaman (Sevüktekin ve Nargeleçekenler, 2007, s.229). Verilerin durağan olup olmadığının belirlenmesi amacıyla, ADF testi gerçekleştirilmiş ve sonuçlar Tablo 2'de gösterilmiştir.

Tablo 2. Değişkenlere Ait ADF Birim-Kök Testi Sonuçları

Değişken	ADF (Düzey)		ADF (Birinci Fark)		Değişken	ADF (Düzey)		ADF (Birinci Fark)	
	Gecikme Uzunluğu (k)	ADF İstatistiği	Gecikme Uzunluğu (k)	ADF İstatistiği		Gecikme Uzunluğu (k)	ADF İstatistiği	Gecikme Uzunluğu (k)	ADF İstatistiği
ATFAIZ	4	-3.087*	1	-15.600*	M2	1	-0.695	1	-10.757*
DK	1	-2.887	1	-8.225*	SUE	5	-1.738	4	-5.946*
IMKB100	1	-1.467	1	-11.359*	TEFE	2	-2.695	1	-5.010*
A1	2	-1.778	1	-11.339*	B1	1	-2.804	1	-10.180*
A2	2	-2.487	1	-10.243*	B2	2	-2.424	1	-10.614*
A3	1	-2.320	1	-14.822*	B3	4	-2.892	2	-8.868*
A4	2	-0.457	2	-8.532*	B4	3	-2.634	2	-8.794*
A5	3	-0.975	2	-9.106*	B5	1	-1.943	1	-14.324*
A6	1	-2.882	1	-9.043*	B6	3	-1.409	3	-4.991*
A7	1	-2.459	2	-6.757*	B7	4	-2.020	2	-9.124*
A8	2	-1.538	3	-7.713*	B8	1	-2.958	1	-22.556*
A9	1	-1.812	1	-9.158*	B9	1	-2.737	1	-11.734*
A10	1	-2.538	2	-8.884*	B10	1	-2.461	1	-9.545*
A11	1	0.605	1	-9.904*	B11	4	-2.746	5	-3.211*
A12	1	-2.858	1	-10.189*	B12	2	-2.652	3	-3.330*
A13	2	-2.434	1	-11.086*	B13	3	-1.923	2	-9.171*
A14	1	-2.161	1	-11.642*	B14	3	-2.528	3	-7.267*
A15	1	-1.314	1	-8.117*	B15	3	-2.036	2	-7.778*
A16	1	-1.613	1	-10.620*	B16	1	-1.264	1	-13.303*
A17	2	-1.955	1	-11.034*	B17	3	-2.408	2	-7.751*
A18	1	-2.140	1	-9.4445*	B18	2	-2.613	2	-8.330*
A19	1	-1.715	2	-14.514*	B19	3	-2.437	3	-8.447*

* : 0.05 anlamlılık düzeyinde serinin durağan olduğunu göstermektedir.

Tablo 2'de yer alan test istatistiklerine bakıldığında bağımlı ve bağımsız değişkenlerin birinci farkları alındığında ADF katsayılarının tümünün $\alpha=0.05$ güvenilirlik düzeyinde anlamlı olduğu görülmektedir. Tüm değişkenlerin (ATFAİZ değişkeni hariç) düzeyde durağan olmadıkları ve birinci dereceden farkları alındığında durağan hale geldikleri tespit edilmiştir. Bu nedenle regresyon modelinde kullanılacak değişkenlerin birinci derece farkları dikkate alınarak tahmin yapılmıştır.

Klasik regresyon modeli varsayımları hem bağımlı ve bağımsız serilerin durağan olmasını hem de hataların sıfır ortalama ve sonlu varyansa sahip olmasını gerekli kılmaktadır. O halde durağan olmayan serilerle yapılan regresyon analizi ile sahte regresyon sorunu ortaya çıkabilir. Sahte regresyonda yüksek R^2 değerleri ve anlamlı t-istatistikleri söz konusu iken parametre tahmin sonuçları ekonomik yorum bakımından anlamsızdır. Fakat değişkenler arasında eşbütünleşme varsa değişkenler tek tek incelendiğinde durağan

olamasa bile bu değişkenlerin doğrusal fonksiyonları alındığında serilerin birbirine ait trendi ortadan kaldırarak durağan hale gelmesine ve sahte regresyonun ortadan kalkmasına neden olmaktadır.

Eşbütünleşme, durağan olmayan serilerin doğrusal bileşimlerinden elde edilen hata teriminin durağan olmasıdır. Eşbütünleşme olması için tüm serilerin aynı derecede durağan olması ve bu değişkenlerin doğrusal fonksiyonlarından elde edilen hata teriminin de durağan olması gerekir (Ertek, 2000, s.392). Bu çalışmada kullanılan seriler aynı derecede I(1) durağan ve hata terimlerinin de durağan olmasından dolayı -tahmin sonuçlarında da görüleceği üzere- sahte regresyon söz konusu değildir.

Serilerin durağanlığı belirlendikten sonra regresyon modelinde kullanılan bağımsız değişkenler arasında çoklu doğrusal bağlantı olup olmadığının tespiti için bağımsız değişkenler arasındaki korelasyon katsayıları Tablo 3'de gösterilmiştir.

Tablo 3. Bağımsız Değişkenler Arasındaki Korelasyon Katsayıları

	ATFAİZ	DK	IMKB100	M2	TEFE	SUE
ATFAİZ	1.000	0.526	-0.145	0.063	0.531	0.009
DK	0.526	1.000	-0.434	0.185	0.315	0.081
IMKB100	-0.145	-0.434	1.000	-0.079	0.098	-0.099
M2	0.063	0.185	-0.079	1.000	-0.033	0.130
TEFE	0.531	0.315	0.098	-0.033	1.000	0.073
SUE	0.009	0.081	-0.099	0.130	0.073	1.000

Regresyon modellerinde bağımsız değişkenler arasında önemli bir ilişki bulunmamalıdır. Eğer böyle bir ilişki varsa, söz konusu ilişki "çoklu doğrusal bağlantı" olarak adlandırılmaktadır (Gujarati, 2004, s.342-343). Çoklu doğrusal bağlantının varlığı, bağımsız değiş-

kenler arasındaki korelasyon katsayıları incelenerek araştırılmaktadır. Bağımsız değişkenler arasında yüksek düzeyde (mutlak değeri %80 ve üzerinde bir değer) bir korelasyon katsayısı, çoklu doğrusal bağlantı göstergesidir (Kennedy, 1998, s.288). Tablo 3'de görül-

düğü gibi bağımsız değişkenler arasındaki korelasyon katsayıları %54'ün altında kalmaktadır. Bu nedenle çoklu doğrusal bağlantı sorunu bulunmamaktadır. Bu durumda verilerin analize uygun olduğu tespit edildikten sonra regresyon analizine geçilerek modele EKKY yöntemi uygulanmıştır. Daha sonra regresyon modeli ile yapılan tahminlerin geçerliliğini sağlayan ekonometrik varsayımların varlığı araştırılmıştır.

19 adet A tipi ve 19 adet B tipi yatırım fonunun net varlık değerleri ile 6 adet ekonomik değişken arasındaki ilişkiyi gösteren doğrusal regresyon modelleri tahmin edilmiştir. Tahmin edilen modellerde ekonometrik sorunların var olup olmadığının tespiti amacıyla gerekli testler yapılmıştır. Testlerin sonuçlarına göre ekonometrik sorunlar giderilerek modeller yeniden tahmin edilmiştir. Ayrıca, fonların net varlık değerini tahmin eden modellere yapılan ekonometrik testler (LM ve White testi) sonucunda, bazı modellerde otokorelasyon, bazı modellerde değişen varyans ve bazı modellerde ise her iki sorun birden tespit edilmiştir. Otokorelasyon sorunu olan tüm modellere bağımlı değişkenin gecikmeli değerleri alınarak, değişen varyans sorunu olan modellerde ise Newey-West Değişen Varyans düzeltmesi yapılarak modeller yeniden tahmin edilmiştir. A tipi ve B tipi fonlar için yapılan tahmin sonuçları aşağıdaki tablolarda özetlenmiştir.

Tablo 4 ve 5'de her bir değişken için tahmin edilen katsayı değerleri verilmektedir. Bu katsayıların altındaki parantezlerden ilki ilgili katsayıların olasılık (p) değerini, ikinci parantez içindeki rakamlar ise t istatistik değerlerini ifade etmektedir. Bu modellerin içerdiği denklemlere ait düzeltilmiş R^2 , hata kareleri toplamı (HKT), F istatistik değeri ve Durbin-Watson (DW) d-istatistiği değerlerine yer verilmiştir. Ayrıca modellerin tümünde F değeri anlamlıdır. Modellerdeki katsayılar sıfırdan farklı ve anlamlıdır, yani regresyon modelleri ekonometrik olarak uygun modellerdir.

Tablo 4'de yer alan 19 adet A tipi yatırım fonu regresyon analizi sonuçlarına göre, makro ekonomik değişkenlerin, fonların net varlık değerlerini açıklama kabiliyetleri önemli farklılıklar göstermiştir. Net varlık değeri denklemlerinin düzeltilmiş R^2 ve HKT değerlerine bakıldığında iki modelde başarılı denebilecek sonuçların elde edildiği görülmektedir. En yüksek düzeltilmiş belirlilik katsayısı (R^2) değeri %63.7 olarak gerçekleşirken diğer düzeltilmiş R^2 değerleri %18 ile %49 değerleri arasında gerçekleşmiştir. R^2 değeri en yüksek olan fon %63.7 ile A14 koduyla anılan T.C. İş Bankası A Tipi Hisse Senedi Fonu'dur. Bu fonun HKT ise 0,064'dür. Bu fonun R^2 değerinin %63.7 olması ise yatırım fonu net varlık değerindeki değişmelerin yaklaşık %63.7'sinin analize alınan bağımsız değişkenlerde meydana gelen değişmelerden tarafından açıklandığını, kalan %36.3'ünün ise modele dâhil edilmeyen diğer değişkenlerin veya hata terimi tarafından açıklandığını ifade etmektedir.

Makro ekonomik değişkenlerin, yatırım fonu net varlık değerlerini açıklama güçleri ise fonlara göre farklılık göstermiştir. 19 adet A tipi yatırım fonu için yapılan tahmin modellerine bakıldığında genelde, *A tipi fonların net varlık değerlerinin, İMKB-100 endeksine ve önceki dönem net varlık değerlerine duyarlı olduğu* görülmektedir. Başka bir ifadeyle, β_3 , β_7 ve β_8 katsayıları istatistikî olarak anlamlıdır. Ayrıca, diğer A tipi yatırım fonlarından farklı olarak, A1 koduyla anılan, Acar Yatırım Menkul Değerler A.Ş. A tipi Değişken Fon'unun ATFAİZ ve TEFE'ye ve A17 koduyla anılan Yapı Kredi Yatırım Menkul Değerler A.Ş. A tipi Değişken Fon'unun da DK'ya duyarlı olduğu görülmektedir. Bunun nedeni her iki fon tipinde de fon portföy sepetinde yer alan Hisse Senedi oranı ve sabit getirili menkullerin oranının diğer kıymetlere göre daha yüksek tutulmasıdır.

Tablo 4. A Tipi Fonlar İçin Regresyon Yöntemi Tahmin Sonuçlar

	A1	A2	A3	A4	A5	A6	A7*	A8	A9	A10	A11*	A12*	A13	A14	A15	A16	A17	A18	A19*
β_0 (Sabit terim)	0.0005 (0.902) [0.122]	0.011 (0.679) [0.415]	-0.041 (0.240) [-1.182]	-0.042 (0.156) [-1.430]	-0.081 (0.312) [-1.016]	1.001 (0.731) [0.344]	-0.039 (0.548) [-0.601]	-0.025 (0.409) [-0.828]	-0.019 (0.444) [-0.767]	-0.097 (0.587) [-0.545]	-0.047 (0.036) [-2.123]	-0.003 (0.812) [-0.238]	-0.006 (0.884) [-0.146]	-0.006 (0.131) [-1.522]	-0.001 (0.818) [-0.229]	-0.004 (0.694) [-0.393]	-1.325 (0.518) [-0.521]	0.016 (0.755) [0.312]	-0.012 (0.556) [-0.591]
β_1 (ATFAİZ)	-0.00021 (0.034) [-2.145]	-0.00083 (0.285) [-1.074]	0.00084 (0.400) [0.845]	0.00070 (0.397) [0.849]	0.00175 (0.441) [0.773]	0.00051 (0.763) [-0.302]	0.00025 (0.896) [0.130]	0.00099 (0.254) [-1.147]	0.00032 (0.962) [0.046]	0.00136 (0.557) [0.589]	0.00057 (0.036) [2.125]	0.00004 (0.986) [-0.016]	0.00036 (0.760) [0.305]	0.00007 (0.491) [0.691]	0.00005 (0.834) [-0.210]	0.00002 (0.901) [-0.124]	0.00011 (0.925) [-0.094]	0.00038 (0.798) [-0.256]	-0.00032 (0.363) [-0.914]
β_2 (DK)	-0.065 (0.645) [-0.461]	-0.360 (0.643) [-0.465]	0.127 (0.900) [0.125]	-0.549 (0.509) [-0.662]	1.980 (0.389) [0.865]	-2.838 (0.108) [-1.622]	-2.477 (0.393) [-0.857]	-0.731 (0.402) [-0.841]	-0.347 (0.633) [-0.479]	-2.001 (0.392) [0.589]	0.141 (0.796) [0.258]	0.428 (0.379) [0.883]	-0.485 (0.684) [-0.408]	0.276 (0.059) [1.909]	0.013 (0.959) [0.051]	0.155 (0.646) [0.460]	-3.705 (0.003) [3.012]	-0.440 (0.779) [-0.280]	0.394 (0.470) [0.725]
β_3 (İMKB100)	0.424 (0.000) [7.017]	0.305 (0.356) [0.926]	1.278 (0.003) [3.028]	0.514 (0.135) [1.507]	1.391 (0.138) [1.495]	0.985 (0.173) [1.372]	0.955 (0.022) [2.320]	0.942 (0.010) [2.631]	0.467 (0.115) [1.590]	1.520 (0.121) [1.565]	1.488 (0.015) [2.468]	1.044 (0.000) [14.246]	0.641 (0.185) [1.336]	0.761 (0.000) [12.370]	0.616 (0.000) [5.458]	0.965 (0.000) [6.736]	0.019 (0.000) [0.039]	0.948 (0.123) [1.557]	0.396 (0.009) [2.674]
β_4 (M2)	-0.008 (0.945) [-0.069]	-0.100 (0.874) [-0.158]	0.827 (0.323) [0.993]	0.357 (0.599) [0.527]	1.432 (0.442) [0.772]	0.543 (0.703) [0.381]	0.680 (0.601) [0.523]	-0.169 (0.811) [-0.239]	0.553 (0.338) [0.962]	1.208 (0.524) [0.639]	0.580 (0.041) [2.069]	0.118 (0.545) [0.606]	-0.049 (0.185) [-0.051]	0.100 (0.000) [0.817]	0.407 (0.958) [1.801]	0.144 (0.000) [0.502]	0.143 (0.987) [0.142]	0.649 (0.596) [0.532]	0.509 (0.000) [3.503]
β_5 (SUE)	0.070 (0.411) [0.826]	0.333 (0.454) [0.751]	-0.353 (0.545) [-0.606]	-0.385 (0.416) [-0.816]	-0.810 (0.535) [-0.621]	-0.683 (0.494) [-0.685]	0.921 (0.292) [0.969]	0.391 (0.438) [0.777]	0.144 (0.725) [0.352]	0.097 (0.942) [0.072]	0.113 (0.586) [0.546]	0.335 (0.061) [1.897]	-1.270 (0.070) [-1.830]	0.080 (0.357) [0.924]	-0.068 (0.669) [-0.428]	0.564 (0.006) [2.798]	0.011 (0.987) [0.016]	-1.314 (0.131) [-1.523]	-0.168 (0.660) [-0.441]
β_6 (TEFE)	1.158 (0.000) [3.473]	1.620 (0.439) [0.776]	-1.981 (0.466) [-0.732]	-0.541 (0.805) [-0.247]	-6.070 (0.316) [-1.007]	2.573 (0.579) [0.556]	0.403 (0.943) [0.070]	-2.354 (0.308) [-1.023]	0.500 (0.790) [0.267]	-2.657 (0.667) [-0.431]	-1.414 (0.080) [-1.768]	1.134 (0.294) [1.055]	-2.231 (0.478) [-0.712]	-0.612 (0.074) [-1.803]	-0.394 (0.528) [-0.632]	0.173 (0.826) [0.219]	2.079 (0.526) [0.635]	1.276 (0.748) [0.321]	1.265 (0.254) [1.146]
β_7 (NVDi-1)		-0.427 (0.000) [-4.007]	-0.361 (0.000) [-3.844]	-0.610 (0.000) [-5.910]	-0.660 (0.000) [-6.418]	-0.324 (0.001) [-3.307]	-0.384 (0.014) [-2.494]	-0.390 (0.000) [-3.829]	-0.396 (0.000) [-3.779]	-0.571 (0.000) [-5.432]			-0.663 (0.000) [-6.408]				-0.418 (0.000) [-4.715]	-0.460 (0.000) [-4.210]	-0.437 (0.047) [-2.008]
B_8 (NVDi-2)		-0.249 (0.025) [-2.274]		-0.279 (0.007) [-2.734]	-0.330 (0.001) [-3.205]			-0.192 (0.058) [-1.916]	-0.139 (0.178) [-1.355]	-0.264 (0.011) [-2.580]			-0.258 (0.011) [-2.581]					-0.198 (0.060) [-1.900]	-0.133 (0.417) [-0.814]
Düzeltilmiş R ²	0.495	0.146	0.217	0.295	0.292	0.136	0.144	0.217	0.106	0.292	0.270	0.318	0.347	0.637	0.279	0.375	0.247	0.164	0.155
F istatistiği	16.390 (0.000)	2.971 (0.005)	4.683 (0.000)	5.811 (0.000)	5.758 (0.000)	3.105 (0.005)	3.246 (0.004)	4.197 (0.000)	2.369 (0.023)	5.759 (0.000)	6.810 (0.000)	8.308 (0.000)	7.137 (0.000)	28.609 (0.000)	7.074 (0.000)	10.405 (0.000)	5.373 (0.000)	3.261 (0.002)	3.117 (0.003)
HKT	0.06227	1.544	2.846	1.796	13.570	8.301	17.477	1.974	1.306	14.186	1.141	0.497	3.650	0.064	0.217	0.349	4.146	5.898	0.908
DW	2.207	2.045	2.160	2.116	2.150	2.118	2.189	2.125	2.204	2.139	2.055	2.022	2.185	2.064	1.675	1.960	2.265	2.109	2.114

NVD: Net Varlık Değeri, ATFAİZ: Aktif Tahvilin Faiz Oranı, DK: ABD Doları/TL Kuru, İMKB100: İMKB Ulusal 100 Endeksi, M2: Para Arzı, SUE: Sanayi Üretim Endeksi, TEFE: Toptan Eşya Fiyat Endeksidir.

*İlgili modellerin katsayıları Newey-West değişen varyansa göre düzeltmeyi yansıtmaktadır.

Katsayılar %5 anlamlılık düzeyinde istatistiksel bakımdan önemlidir.

Parantez içindeki rakamların ilki ilgili katsayıların olasılık (p) değerini, köşeli parantez içindeki rakamlar ise t istatistik değerlerini ifade etmektedir.

Tablo 5. B Tipi Fonlar İçin Regresyon Yöntemi Tahmin Sonuçları

	B1	B2	B3	B4	B5*	B6*	B7	B8	B9	B10	B11	B12*	B13*	B14*	B15	B16	B17*	B18	B19
β_0 (Sabit terim)	-0.071 (0.135) [-1.505]	-0.001 (0.919) [-0.100]	-0.012 (0.824) [-0.223]	-0.009 (0.882) [-0.148]	-0.040 (0.266) [-1.119]	0.018 (0.307) [1.025]	-0.008 (0.808) [-0.243]	0.032 (0.697) [0.390]	-0.008 (0.820) [-0.207]	-0.008 (0.679) [-0.227]	-0.007 (0.019) [-0.414]	-0.007 (0.773) [-2.380]	-0.014 (0.817) [-0.288]	-0.012 (0.841) [-0.231]	-0.011 (0.749) [-0.200]	0.017 (0.320) [0.307]	-0.003 (0.877) [-0.154]	0.031 (0.643) [0.464]	-0.009 (0.792) [-0.263]
β_1 (ATFAİZ)	0.0031 (0.020) [2.358]	-0.0001 (0.729) [-0.346]	0.0008 (0.588) [0.543]	0.0010 (0.588) [0.542]	0.0012 (0.261) [1.130]	-0.0009 (0.162) [-1.409]	0.0008 (0.396) [0.851]	-0.0011 (0.644) [-0.463]	0.00038 (0.665) [0.433]	0.0004 (0.609) [0.512]	-0.0001 (0.000) [-0.410]	0.0006 (0.198) [6.036]	0.0009 (0.198) [1.296]	0.0008 (0.959) [0.055]	0.0008 (0.598) [0.527]	0.0004 (0.759) [0.307]	0.0007 (0.054) [1.952]	-0.0005 (0.785) [-0.272]	0.0011 (0.296) [1.050]
β_2 (DK)	-0.677 (0.622) [-0.493]	0.276 (0.610) [0.511]	-0.440 (0.777) [-0.283]	0.575 (0.761) [0.304]	-2.414 (0.104) [-1.641]	0.120 (0.916) [0.105]	-0.443 (0.664) [-0.435]	1.272 (0.598) [0.528]	-1.040 (0.409) [-0.828]	0.514 (0.663) [0.436]	-2.290 (0.000) [-3.975]	0.233 (0.013) [2.515]	0.880 (0.558) [0.587]	-0.730 (0.641) [-0.468]	1.384 (0.384) [0.874]	-2.245 (0.153) [-1.441]	1.146 (0.128) [1.534]	1.105 (0.567) [0.574]	0.360 (0.735) [0.338]
β_3 (İMKB100)	0.808 (0.143) [1.475]	0.433 (0.048) [1.998]	-0.259 (0.681) [-0.412]	-0.537 (0.484) [-0.702]	0.237 (0.364) [0.911]	1.054 (0.053) [1.956]	-0.437 (0.289) [-1.065]	-0.652 (0.508) [-0.664]	0.851 (0.114) [1.595]	-0.112 (0.822) [-0.225]	0.989 (0.000) [4.044]	-0.046 (0.182) [-1.342]	0.060 (0.808) [0.242]	0.389 (0.477) [0.713]	-0.034 (0.957) [-0.053]	1.069 (0.096) [1.679]	0.072 (0.096) [0.607]	0.255 (0.545) [0.329]	0.097 (0.821) [0.226]
β_4 (M2)	0.559 (0.613) [0.506]	0.055 (0.899) [0.126]	-0.032 (0.979) [-0.026]	-0.033 (0.982) [-0.022]	-0.086 (0.821) [-0.226]	-0.295 (0.231) [-1.205]	-0.120 (0.883) [-0.147]	-0.843 (0.664) [-0.435]	1.272 (0.907) [-0.116]	0.062 (0.595) [0.062]	-0.261 (0.979) [-0.532]	-0.001 (0.979) [-0.025]	0.124 (0.758) [0.308]	-0.246 (0.658) [-0.443]	-0.048 (0.970) [-0.037]	0.164 (0.896) [0.130]	0.202 (0.419) [0.811]	-0.252 (0.871) [-0.162]	-0.059 (0.945) [-0.068]
β_5 (SUE)	-0.554 (0.472) [-0.722]	-0.468 (0.129) [-1.529]	0.673 (0.444) [0.768]	0.781 (0.467) [0.729]	-0.383 (0.359) [-0.986]	-0.262 (0.792) [-0.921]	0.151 (0.376) [0.263]	1.207 (0.406) [0.888]	0.627 (0.871) [0.162]	0.114 (0.823) [0.223]	0.077 (0.465) [0.732]	0.041 (0.655) [0.732]	-0.471 (0.729) [-0.347]	2.318 (0.058) [1.915]	0.052 (0.954) [0.057]	-0.280 (0.753) [-0.315]	-0.183 (0.748) [0.615]	0.676 (0.540) [0.658]	0.404 (0.512) [0.688]
β_6 (TEFE)	-2.954 (0.408) [-0.830]	1.367 (0.341) [0.957]	3.035 (0.456) [0.748]	1.019 (0.837) [0.205]	0.751 (0.717) [0.363]	2.765 (0.119) [1.574]	0.475 (0.858) [0.178]	5.635 (0.374) [0.892]	-0.116 (0.968) [-0.039]	-0.429 (0.876) [-0.155]	5.118 (0.000) [3.791]	-0.537 (0.109) [-1.617]	-1.030 (0.765) [-0.299]	-0.403 (0.939) [-0.075]	0.164 (0.902) [0.122]	-0.280 (0.000) [-0.343]	-0.197 (0.905) [-0.119]	0.228 (0.964) [0.044]	-2.382 (0.400) [-0.845]
β_7 (NVDi-1)	-0.502 (0.000) [-5.104]	-0.549 (0.000) [-5.427]	-0.657 (0.000) [-6.301]	-0.631 (0.000) [-6.093]	-0.439 (0.000) [-3.951]	-0.669 (0.000) [-6.534]	-0.750 (0.000) [-6.768]						-0.654 (0.000) [-4.756]	-0.651 (0.000) [-6.370]	-0.638 (0.000) [-6.070]	-0.307 (0.002) [-3.120]	-0.594 (0.000) [-3.853]	-0.450 (0.000) [-4.267]	-0.620 (0.000) [-5.893]
β_8 (NVDi-2)	-0.247 (0.019) [-2.382]	-0.254 (0.012) [-2.565]	-0.336 (0.001) [-3.224]	-0.322 (0.002) [-3.101]			-0.328 (0.01) [-3.208]	-0.115 (0.288) [-1.067]					-0.336 (0.013) [-2.522]	-0.302 (0.004) [-2.940]	-0.305 (0.005) [-2.863]		-0.280 (0.047) [-2.015]	-0.283 (0.008) [-2.685]	-0.255 (0.017) [-2.432]
Düzeltilmiş R ²	0.232	0.258	0.276	0.268	0.221	0.207	0.289	0.464	0.001	-0.051	0.459	0.598	0.267	0.302	0.275	0.126	0.255	0.138	0.244
F istatistiği	4.486 (0.000)	5.018 (0.000)	5.402 (0.000)	5.231 (0.000)	4.771 (0.000)	5.089 (0.000)	5.691 (0.000)	10.972 (0.000)	1.018 (0.418)	0.073 (0.965)	14.292 (0.000)	24.333 (0.000)	5.204 (0.000)	5.998 (0.000)	5.371 (0.000)	2.926 (0.008)	4.937 (0.000)	2.848 (0.007)	4.719 (0.000)
HKT	4.737	0.749	6.143	9.216	2.020	1.353	2.657	14.872	4.854	4.281	1.019	0.032	9.970	9.625	6.438	6.555	2.168	9.574	2.973
DW	2.117	2.120	2.161	2.128	2.049	2.296	2.179	2.027	2.384	1.969	1.599	1.918	2.109	2.050	2.144	2.061	2.097	2.129	2.084

NVD: Net Varlık Değeri, ATFAİZ: Aktif Tahvilin Faiz Oranı, DK: ABD Doları/TL Kuru, İMKB100: İMKB Ulusal 100 Endeksi, M2: Para Arzı, SUE: Sanayi Üretim Endeksi, TEFE: Toptan Eşya Fiyat Endeksidir.

*İlgili modellerin katsayıları Newey-West değişen varyansa göre düzeltmeyi yansıtmaktadır.

Katsayılar %5 anlamlılık düzeyinde istatistiksel bakımdan önemlidir.

Parantez içindeki rakamların ilki ilgili katsayıların olasılık (p) değerini, köşeli parantez içindeki rakamlar ise t istatistik değerlerini ifade etmektedir.

Tablo 5'e göre, makro ekonomik değişkenlerin, 19 adet B tipi yatırım fonunun net varlık değerlerini açıklama kabiliyetleri önemli farklılıklar göstermiştir. Net varlık değerini tahmin eden denklemlerin düzeltilmiş R² ve HKT değerlerine bakıldığında iki modelde başarılı denebilecek sonuçların elde edildiği görülmektedir. En yüksek düzeltilmiş belirlilik katsayısı (R²) değeri %59.8 civarında gerçekleşirken; en düşük düzeltilmiş R² değeri %-0.05 olarak gerçekleşmiştir. Düzeltilmiş R² değeri en yüksek olan fon %59.8 ile B12 koduyla anılan T.C. İş Bankası B Tipi Likit Fonu'dur ve HKT'si 0.032'dir. R² değerinin %59.8 olması, yatırım fonu net varlık değerindeki değişmelerin yaklaşık %60'ının analize alınan bağımsız değişkenlerde meydana gelen değişmelerden tarafından açıklandığını, kalan %40'ının ise modele dâhil edilmeyen diğer değişken

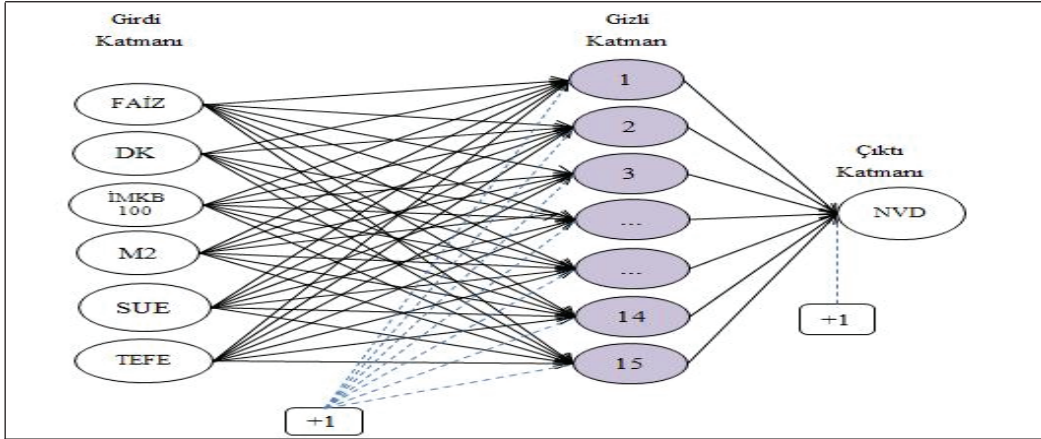
lerin veya hata terimi tarafından açıklandığını ifade etmektedir. Makro ekonomik değişkenlerin, B tipi yatırım fonlarının net varlık değerlerini açıklama güçleri de farklılık göstermiştir. 19 adet B tipi yatırım fonu için yapılan tahmin modellerine bakıldığında, B tipi fonların net varlık değerlerinin, aktif tahvilin faiz oranına, döviz kuruna, TEFE'ye, İMKB-100 endeksine ve önceki dönem net varlık değerlerine duyarlı olduğu görülmektedir. Yani, β_1 , β_2 , β_3 , β_7 , β_6 ve β_8 katsayıları istatistikî olarak anlamlıdır.

YSA modelinin uygulanması aşamasında, 19 adet A tipi ve 19 adet B tipi olmak üzere toplam 38 adet yatırım fonu net varlık değerini tahmin etmek için deneme-yanılma yoluyla onlarca ÇKA modeli geliştirilmiştir. Geliştirilen her model için, veri seti eğitim

ve test seti olmak üzere iki veri setine ayrılmıştır. Veri setinin %70'ini oluşturan ve Ocak 2001-Ağustos 2006 dönemini kapsayan 67 adet veri *eğitim seti* olarak belirlenirken, %30'unu oluşturan ve Eylül 2006-Aralık 2008 dönemini kapsayan 28 adet veri ise *test seti* olarak belirlenmiştir (Zhang, vd., 1998; Ray ve Vani, 2004). Bazı çalışmalarda ise veri seti, eğitim, doğrulama ve test seti olarak üç gruba ayrılmaktadır (Kaastra ve Boyd, 1996; Sahoo ve Hathay, 2007). Test setinin bu tarih aralığında belirlenmesinin nedeni ise dünyada 2007 yılı ortalarında başlayan ve 2008 yılında ise zirvesine ulaşan küresel ekonomik krizin veya mortgage krizinin ve mevsimsel etkilerin geliştirilen YSA modeli tarafından kavranıp kavranamadığını gösterebilmektir.

Modelde (6) adet bağımsız değişken olduğu için, girdi katmanında bağımsız değişkenleri temsil eden (6) adet girdi nöronu kullanılmıştır. Çıktı katmanında ise bir bağımlı değişken olduğundan nöron sayısı (1) adet

olarak belirlenmiştir. Değişik sayıda gizli nöronlarla ve gizli katman sayıları ile yapılan denemeler sonunda 9 adet fonda tek katmanlı ağ mimarisi iyi sonuçlar verirken, diğer fonlarda 2, 3 ve 4 katmanlı ağ mimarisinin iyi sonuçlar verdiği gözlemlenmiştir. Bu nedenle gizli katmandaki nöron sayısı fonlara göre değişkenlik göstermiş ve 3-15 adet aralığında belirlenmiştir. Gizli katmanda ve çıktı katmanında aktivasyon fonksiyonu olarak Hiperbolik Tanjant ve Sigmoid fonksiyonları kullanılmıştır. Hem gizli katman hem de çıktı katmanı için eşik değer veya rastsal hata terimi kullanılmıştır. Bu terim Şekil 2'de kesikli çizgilerle gösterilmiştir. Ayrıca ağın başarısını belirleyen öğrenme algoritması yine her fon için farklı belirlenmiştir. Verilen bu parametrelere dayanarak danışmanlı öğrenme tekniği ile eğitilen, çok katmanlı ve ileri beslemeli (feedforward) yapay sinir ağı mimarisi oluşturulmuştur ve modelin genel yapısı Şekil 2'de verilmiştir.



Şekil 1. Geliştirilen YSA Tahmin Modeli

Çok katmanlı bir YSA modelinde; gizli katman sayısı, gizli katmanda yer alacak nöron sayısı, gizli katman ve çıktı katmanındaki aktivasyon fonksiyonları ile öğrenme algoritmaları, öğrenme oranı ve momentum katsayısı gibi parametrelerin belirlenmesi ağın performansı açısından oldukça önemlidir. Fakat bu parametrelerin belirlenmesinde kesin bir yöntem ol-

mamasından dolayı parametreler deneme yanılma yoluyla belirlenmiştir (Kaastra ve Boyd, 1996, s.220-224). Geliştirilen YSA modelleri 1000 döngü (epoch) kullanılarak eğitilmiştir. Denemeler sonucunda en iyi eğitim ve test sonuçlarını veren ağ yapılarına ilişkin parametreler A tipi ve B tipi fonlar için aşağıdaki tablolarda verilmektedir.

Tablo 6. A ve B Tipi Fonlar İçin En Uygun YSA Modellerine İlişkin Parametreler

Model Parametreleri	A1	A2	A3	A4	A5	A6	A7	A8	A9	A10	A11	A12	A13	A14	A15	A16	A17	A18	A19
Girdi Nöronu Sayısı	6	6	6	6	6	6	6	6	6	6	6	6	6	6	6	6	6	6	6
Gizli Katman Sayısı	1	4	3	1	2	2	4	4	4	2	4	4	4	1	3	4	2	1	1
Gizli Katmandaki Nöron Sayısı	3	11	15	3	10	15	10	10	10	8	15	10	15	6	15	10	10	3	4
Gizli Katmandaki Transfer Fonksiyonu	Tan	Tan	Tan	Tan	Tan	Tan	Tan	Tan	Tan	Tan	Tan	Tan	Tan	Tan	Tan	Tan	Tan	Tan	Tan
Öğrenme Algoritması	LM	MO	MO	LM	MO	MO	MO	MO	MO	MO	MO	MO	MO	MO	MO	MO	MO	LM	LM
Çıktı Katmanındaki Nöron Sayısı	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
Çıktı Katmanındaki Transfer Fonksiyonu	Sig	Tan	Tan	Tan	Tan	Tan	Tan	Tan	Tan	Tan	Tan	Tan	Tan	Tan	Tan	Tan	Tan	Tan	Tan
Öğrenme Algoritması	MO	MO	MO	MO	MO	MO	MO	MO	MO	MO	MO	MO	MO	MO	MO	MO	MO	LM	LM
Model Parametreleri	B1	B2	B3	B4	B5	B6	B7	B8	B9	B10	B11	B12	B13	B14	B15	B16	B17	B18	B19
Girdi Nöronu Sayısı	6	6	6	6	6	6	6	6	6	6	6	6	6	6	6	6	6	6	6
Gizli Katman Sayısı	2	4	3	4	4	3	4	4	3	4	1	3	4	1	2	1	2	3	1
Gizli Katmandaki Nöron Sayısı	15	15	15	15	6	15	15	11	14	11	4	15	11	7	15	4	15	10	7
Gizli Katmandaki Transfer Fonksiyonu	Tan	Tan	Tan	Tan	Tan	Tan	Tan	Tan	Tan	Tan	Tan	Tan	Tan	Tan	MO	Tan	MO	Tan	Tan
Öğrenme Algoritması	MO	MO	MO	MO	MO	MO	MO	MO	MO	MO	LM	MO	MO	LM	1	LM	1	MO	LM
Çıktı Katmanındaki Nöron Sayısı	1	1	1	1	1	1	1	1	1	1	1	1	1	1	Tan	1	Tan	1	1
Çıktı Katmanındaki Transfer Fonksiyonu	Tan	Tan	Tan	Tan	Tan	Tan	Tan	Tan	Tan	Tan	Tan	Tan	Tan	Tan	MO	Tan	MO	Tan	Tan
Öğrenme Algoritması	MO	MO	MO	MO	MO	MO	MO	MO	MO	MO	LM	MO	MO	LM	MO	LM	MO	MO	MO

Aktivasyon Fonksiyonları: Sig: Sigmoid Fonksiyonu, Tan: Tanjant Fonksiyonu
 Öğrenme Algoritmaları: MO: Momentum, LM: Levenberg-Marquart (Trainlm)

Geliştirilen ÇKA modellerinin, eğitim ve test aşamasını başarı bir şekilde geçtiği, hatta eğitim dönemi kapsayan zaman periyodunda Türkiye'de Şubat 2001'de yaşanan finansal kriz ile 2008 yılının son çeyreğinde ABD kredi piyasasının çökmesine neden olan ve dünya finansal piyasalarını olumsuz etkileyen küresel ekonomik krizin yatırım fonları net varlık değerleri üzerindeki etkilerini başarılı bir şekilde kavrayabildiği de tespit edilmiştir.

Eğitim ve test aşamasından sonra oluşturulan YSA modelinin iyi bir tahmin edici olup olmadığının göstergesi olarak ÇKA'ların performans ölçümlerinde sıkça kullanılan; R^2 , Hata Kareler Ortalaması (HKO), Hata Kareler Toplamı (HKT) ve Hata Karelerinin Ortalamasının Karekökü (HKOK) gibi performans ölçütleri kullanılmıştır. En uygun ağ yapısı, bu performans ölçütleri dikkate alınarak eğitim ve test aşamasındaki bulguların karşılaştırılması yoluyla elde edilmiştir (Tablo 7 ve 8).

Tablo 7. A Tipi Fonlar İçin Eğitim ve Test Aşaması Performans Göstergeleri

Fon Adı	Eğitim Aşaması Sonrası				Test Aşaması Sonrası			
	R^2	HKT	HKO	HKOK	R^2	HKT	HKO	HKOK
A1	0.93893	0.021498	0.000320	0.017912	0.75898	0.010831	0.000387	0.019667
A2	0.74131	0.820057	0.012239	0.110632	0.55709	0.132794	0.004743	0.068866
A3	0.71731	0.455605	0.006800	0.082462	0.47316	0.513904	0.018354	0.135475
A4	0.63711	0.123956	0.001850	0.043012	0.52812	0.172568	0.006163	0.078505
A5	0.78804	0.135746	0.002026	0.045011	0.57246	0.201485	0.007196	0.084828
A6	0.75327	0.352709	0.005264	0.072555	0.54640	0.463605	0.016557	0.128675
A7	0.74018	0.197293	0.002944	0.054264	0.53108	0.479344	0.017119	0.130841
A8	0.72611	0.193183	0.002883	0.053696	0.61495	0.242742	0.008669	0.093109
A9	0.72344	0.811667	0.012114	0.110065	0.53990	0.066758	0.002384	0.048828
A10	0.75834	0.121987	0.001820	0.042669	0.54289	0.791388	0.028264	0.168118
A11	0.82965	0.793897	0.011849	0.108854	0.74518	0.101136	0.003612	0.060099
A12	0.70545	0.190644	0.005284	0.053342	0.51973	0.393079	0.014039	0.118484
A13	0.60290	0.804814	0.012012	0.109599	0.52401	0.083018	0.002965	0.054451
A14	0.86903	0.771308	0.011512	0.107294	0.72247	0.018029	0.000644	0.025374
A15	0.83107	0.221823	0.003310	0.057539	0.60397	0.269498	0.009625	0.098106
A16	0.82770	0.833302	0.012437	0.111522	0.69938	0.049748	0.001777	0.042151
A17	0.74826	0.946193	0.014122	0.118837	0.53880	0.190898	0.006818	0.082569
A18	0.76803	0.414261	0.006183	0.078632	0.68052	0.104472	0.003731	0.061083
A19	0.86930	0.110294	0.001646	0.040573	0.62789	0.163361	0.005834	0.076382

Örnekleme içi dönemde, A1 koduyla anılan Acar Yatırım Menkul Değerler A.Ş. A Tipi Değişken Fonu'nun net varlık değerini tahmin etmek için geliştirilen çok katmanlı YSA modelinin R^2 değeri %93.89 olurken, HKT değeri ise 0.021498 ile en küçük düzeyde ger-

çekleşmiştir. En düşük R^2 değeri (%60.29) ise A13 koduyla anılan T. İş Bank. A.Ş. A Tipi Değişken Fonuna aittir. Bu modelin HKT değeri ise 0.804814 olarak gerçekleşmiştir.

Tablo 8. B Tipi Fonlar İçin Eğitim ve Test Aşamaları Performans Göstergeleri

Fon Adı	Eğitim Aşaması Sonrası				Test Aşaması Sonrası			
	R^2	HKT	HKO	HKOK	R^2	HKT	HKO	HKOK
B1	0.82390	0.211278	0.003153	0.056155	0.62671	0.043487	0.001553	0.039409
B2	0.77881	0.122055	0.001822	0.042681	0.64736	0.067039	0.002394	0.048931
B3	0.83986	0.018439	0.000275	0.016589	0.51384	0.194974	0.006963	0.083446
B4	0.70781	0.029181	0.000436	0.020869	0.55160	0.471956	0.016856	0.129828
B5	0.75272	0.850604	0.012696	0.112674	0.56964	0.228214	0.008151	0.090280
B6	0.82091	0.822238	0.012272	0.110780	0.62082	0.472146	0.016862	0.129855
B7	0.85697	0.011427	0.000171	0.013059	0.65180	0.200476	0.007165	0.084615
B8	0.80592	0.016300	0.000234	0.015597	0.63187	0.318943	0.011391	0.106727
B9	0.68997	0.260346	0.003886	0.062335	0.59176	0.418524	0.014947	0.122259
B10	0.84452	0.941556	0.014053	0.118545	0.65994	0.123453	0.004409	0.066400
B11	0.93279	0.683211	0.010197	0.100981	0.60628	0.874195	0.031221	0.176694
B12	0.84962	0.441191	0.006585	0.081147	0.77315	0.004047	0.000145	0.012022
B13	0.85696	0.375299	0.005601	0.074843	0.69674	0.196286	0.007012	0.083727
B14	0.98754	0.013847	0.000207	0.014376	0.62103	0.532596	0.019021	0.137917
B15	0.96389	0.007700	0.000115	0.010720	0.68911	0.047913	0.001711	0.041365
B16	0.84390	0.695662	0.010383	0.101897	0.63319	0.19097	0.006823	0.082585
B17	0.75853	0.062772	0.000937	0.030608	0.65285	0.195339	0.006976	0.083524
B18	0.78059	0.113593	0.001695	0.041175	0.65147	0.301825	0.010779	0.103824
B19	0.98921	0.000909	0.000013	0.003684	0.68413	0.552905	0.019747	0.140522

B19 koduyla anılan Yatırım Finansman Menkul Değerler A.Ş. B Tipi Likit Fonu'nun net varlık değerini tahmin etmek için geliştirilen çok katmanlı YSA modelinin örneklem içi dönemde, R^2 değeri %98.92 olurken, HKT değeri ise 0.000909 ile en küçük düzeyde gerçekleşmiştir. En düşük R^2 değeri ise %68.99 ile B9 koduyla anılan Türkiye Garanti Bankası A.Ş. B Tipi Flexi Değişken Fonu tahmin modeline aittir. Ancak bu modelin HKT değeri ise 0.260346 olarak hesaplanmıştır. Genel olarak, bağımsız değişkenlerle fon net varlık değerleri arasında güçlü ve pozitif bir ilişkinin var olduğu görülmektedir. Değişkenler arasındaki bu ilişkinin tüm fonlarda %50'in üzerinde olduğu ve özellikle HKT'nin oldukça düşük düzeyde gerçekleştiği görülmektedir.

Tablo 7 ve 8'deki sonuçlar birlikte değerlendirildiğinde, geliştirilen ağların eğitim ve test aşamalarındaki hata paylarının oldukça düşük olduğu ve hatta sifıra yaklaştığı görülmektedir. Başka bir ifadeyle, örneklem içi (in-sample) ve örneklem dışı (out-of-sample) dönemde çok katmanlı YSA modellerinin oldukça başarılı performans gösterdiği ifade edilebilir.

Modellerin oluşturulması sırasında değişkenlerin mevsimsel etkiden arındırılmamasına ve kukla değişkenler kullanılmamasına rağmen, yapay sinir ağı modelleri oldukça başarılı performans göstermişlerdir. Genel olarak geliştirilen yapay sinir ağı modellerinin, 2001'de Türkiye'de yaşanan ekonomik krizle

2007 yılı ortalarında ABD'de ortaya çıkan ve ilerleyen dönemlerde tüm dünya ekonomilerini olumsuz olarak etkileyen küresel ekonomik krizin A tipi yatırım fonu net varlık değerleri üzerindeki etkilerini iyi bir şekilde kavradığı tespit edilmiştir.

YSA modellerinin A tipi fon kapsamında yer alan değişken, hisse senedi ve ulusal endeks fonlarında daha başarılı sonuçlar ürettiği görülmektedir. YSA modellerinin B tipi fon kapsamında yer alan tüm fon türlerinde (değişken, tahvil ve bono fonları ve likit fonlar) A tipi fonlara göre daha başarılı sonuçlar verdiğini görülmektedir.

Tüm bu bilgiler birleştirildiğinde, geliştirilen YSA modellerinin eğitim ve test aşamalarını başarıyla tamamlamış olmalarından dolayı öngörü için kullanılabilmesinin mümkün olduğu sonucuna ulaşılmaktadır.

Öngörü Modellerinin Karşılaştırılması

Ekonomideki belirsizlikler nedeniyle ekonomik zaman serilerinin gelecekte göstereceği performans ve davranışı kestirebilmek karar vericiler için oldukça önemlidir. Bu durumda gözlemlenen değerlerden hareketlerle bir zaman serisi için kurulan modelin serinin gelecekte (bir gün, bir ay veya bir yıl sonraki) alabileceği muhtemel değerleri tahmin edebilecek bir performansla sahip olması beklenir. Başka bir deyişle, modelin öngörü performansının yüksek olması beklenir. Öngörü modellemesi birçok alanda olduğu gibi finans alanı için de büyük önem taşımakta ve yaygın biçimde kullanılmaktadır.

Literatürdeki birçok ampirik çalışmada, öngörü modeli olarak ekonometrik modeller kullanıldığı gibi son yıllarda YSA modelleri de gösterdikleri yüksek tahmin performansı nedeniyle, ekonometrik modellerle karşılaştırmalı olarak kullanılmaya başlanmıştır. Bunun bir nedeni YSA modellerinin doğrusal olmayan, mevsimsellik ve trend içeren zaman serilerini tahmin etmede klasik modeller kadar ve onlardan daha üstün performans gösterebilmesidir (Zhang ve Qi, 2005, s.502). Diğer nedeni ise Box-Jenkins, ARI-MA, hareketli ortalama ve doğrusal model gibi ge-

leneksel ekonometrik yöntemlerle modelleme yapılırken verilerin durağanlaştırılması gibi bazı sınırlamalar yapılmasından dolayı bilgi kaybının olmasıdır. Ancak, YSA modellemesinde ise bu sakıncalar yoktur (Abraham, vd., 2004, s.1-17).

Geliştirilen YSA modellerinin iyi bir öngörü başarısı sergileyip sergilemediğinin tespit edilebilmesi için öngörü performans ölçütlerinin kullanılması gerekmektedir. YSA modellerinin öngörü başarısını ölçmek için kullanılacak birçok ölçüt vardır. Ancak bu ölçüt analizin konusu ve amacı dikkate alınarak belirlenmelidir. Bu ölçme işlemi için en çok kullanılan öngörü doğruluk ölçütleri aşağıdaki gibidir (Gujarati, 2004, s.77 ; Zhang, vd., 1998, s.51):

$$- \text{Ortalama Mutlak Hata (MAE, MAD)} = \sum |e_t|/N, \quad (1.3)$$

$$- \text{Hata Kareleri Toplamı (SSE)} = \sum (e_t)^2, \quad (1.4)$$

$$- \text{Ortalama Hata Kareler (MSE)} = \sum (e_t)^2/N, \quad (1.5)$$

$$- \text{Karekök Ortalama Hata Kareler (RMSE)} = \sqrt{\text{MSE}}, \quad (1.6)$$

$$- \text{Ortalama Mutlak Yüzde Hata (MAPE)} = (1/N) \sum |e_t/y_t| (100), \quad (1.7)$$

Burada; e_t , kestirim hatasını; y_t , t dönemi gözlem değerini; N ise hata terimleri sayısını ifade etmektedir.

Bu öngörü doğruluk ölçütleri içinde en yaygın şekilde kullanılanı MSE'dir. Bu ölçütün önemli bir özelliği, öngörü hatasının varyans toplamalarına ayrıştırılabilesidir. Bu özellik, MSE ölçütünün sadece gerçekleşme ve öngörülere ait birleşik dağılımın ikinci momentine bağlı olduğunu göstermektedir. Bununla beraber, gerçek dağılımla ilgili tam bilgi sağlayamadığı da belirtilmelidir (Zhang, vd., 1998, s.52). Bu çalışmada, hata kareler toplamı, hata kareler ortalaması ve karekök ortalama hata kareler performans ölçütleri ile R^2 değeri hesaplanmıştır. Çalışmanın bu kısmında, 19 adet A tipi ve 19 adet B tipinden olmak üzere toplam 38 adet yatırım fonu net varlık değerlerini tahmin etmek için kurulan YSA modellerinden elde edilen öngörü sonuçları ile regresyon analizinden elde edilen öngörü sonuçları Tablo 9 ve Tablo 10'da karşılaştırmalı olarak sunulmaktadır.

Tablo 9. A Tipi Fonlar İçin Öngörü Doğruluk Ölçütleri

Fon Adı	REGRESYON				YSA			
	R ²	HKT	HKO	HKOK	R ²	HKT	HKO	HKOK
A1	0.4954	0.062260	0.000655	0.025600	0.7589	0.010831	0.000387	0.019667
A2	0.1465	1.554470	0.016363	0.127917	0.5570	0.132794	0.004743	0.068866
A3	0.2176	2.846315	0.029961	0.173093	0.4731	0.513904	0.018354	0.135475
A4	0.2955	1.796698	0.018913	0.137523	0.5281	0.172568	0.006163	0.078505
A5	0.2923	13.570610	0.142849	0.377953	0.5724	0.201485	0.007196	0.084828
A6	0.1365	8.301429	0.087383	0.295607	0.5464	0.463605	0.016557	0.128675
A7	0.1443	17.477820	0.183977	0.428925	0.5310	0.479344	0.017119	0.130841
A8	0.2176	1.974319	0.020782	0.144161	0.6149	0.242742	0.008669	0.093109
A9	0.1067	1.306475	0.013752	0.117270	0.5399	0.066758	0.002384	0.048828
A10	0.2921	14.186400	0.149331	0.386433	0.5428	0.791388	0.028264	0.168118
A11	0.2701	1.141232	0.012013	0.109604	0.7451	0.101136	0.003612	0.060099
A12	0.3187	0.497608	0.005238	0.072374	0.5197	0.393079	0.014039	0.118484
A13	0.3476	3.650804	0.038430	0.196034	0.5240	0.083018	0.002965	0.054451
A14	0.6378	0.064504	0.000679	0.026057	0.7224	0.018029	0.000644	0.025374
A15	0.2791	0.217329	0.002288	0.047830	0.6039	0.269498	0.009625	0.098106
A16	0.3756	0.349756	0.003682	0.060677	0.6993	0.049748	0.001777	0.042151
A17	0.2478	4.146853	0.043651	0.208928	0.5388	0.190898	0.006818	0.082569
A18	0.1645	5.898520	0.062090	0.249178	0.6805	0.104472	0.003731	0.061083
A19	0.1556	0.908664	0.009565	0.097800	0.6278	0.163361	0.005834	0.076382

A tipi yatırım fonu net varlık değerini tahmin etmede kullandığımız öngörü tekniklerinin performans karşılaştırması yapıldığında, YSA tekniğinin regresyon yöntemine göre daha iyi performans gösterdiği görülmektedir. Özellikle R² ve HKT değerleri incelendiğinde YSA tekniğinin performans üstünlüğü göze çarpmaktadır. A9 koduyla anılan Ziraat Bankası A tipi Değişken Fon'u regresyon yönteminde %10.67 ile en düşük düzeltilmiş R² değerine sahip iken YSA tekniği ile elde edilen tahmin modelinde %53.99 ile yüksek bir değere sahip olmuştur. Bu fonun HKT iki yöntem açısından karşılaştırıldığında, regresyon modeli değeri 1.306475 iken YSA modeli HKT'nin 0.066758 değeri ile oldukça düşük ve sıfıra yakın bir düzeyde

çıkacağı görülmektedir. Regresyon yönteminde, A7 koduyla anılan YKB A.Ş. A Tipi Koç Allianz Sigorta Özel Fonu ile A10 koduyla anılan TEB Yatırım Menkul Değerler A.Ş. A Tipi Hisse Senedi Fonu'nun net varlık değerlerini tahmin eden modeller için HKT değerleri 17.477820 ve 14.186400 ile en yüksek düzeyde gerçekleşmiştir. Bu değerler, YSA modelinde ise oldukça düşük (0.479344 ve 0.791388) düzeylerde gerçekleşmiştir. Bu iki yatırım fonunun net varlık değerini tahmin eden iki farklı tahmin yönteminden hesaplanan değerler, iki farklı tahmin yöntemi için HKT değerleri arasındaki farkın büyüklüğünü gösteren en çarpıcı modellerdir.

Tablo 10. B Tipi Fonlar İçin Öngörü Doğruluk Ölçütleri

Fon Adı	REGRESYON				YSA			
	R ²	HKT	HKO	HKOK	R ²	HKT	HKO	HKOK
B1	0.2323	4.737949	0.049873	0.22323	0.62671	0.043487	0.001553	0.039409
B2	0.2589	0.749197	0.007886	0.088805	0.64736	0.067039	0.002394	0.048931
B3	0.2765	6.143969	0.064673	0.254310	0.51384	0.194974	0.006963	0.083446
B4	0.2684	9.216522	0.097016	0.311474	0.55160	0.471956	0.016856	0.129828
B5	0.2212	2.020510	0.021269	0.145837	0.56964	0.228214	0.008151	0.090280
B6	0.2075	1.353457	0.014247	0.119360	0.62082	0.472146	0.016862	0.129855
B7	0.2899	2.657104	0.027970	0.167241	0.65180	0.200476	0.007165	0.084615
B8	0.4645	14.872900	0.156557	0.395673	0.63187	0.318943	0.011391	0.106727
B9	0.0012	4.854910	0.051104	0.226063	0.59176	0.418524	0.014947	0.122259
B10	-0.0512	4.281274	0.045066	0.212288	0.65994	0.123453	0.004409	0.066400
B11	0.4599	1.019974	0.010737	0.103617	0.60628	0.874195	0.031221	0.176694
B12	0.5987	0.032106	0.000338	0.018384	0.77315	0.004047	0.000145	0.012022
B13	0.2678	0.970831	0.104956	0.323969	0.69674	0.196286	0.007012	0.083727
B14	0.3023	9.625767	0.101324	0.318314	0.62103	0.532596	0.019021	0.137917
B15	0.2758	6.438327	0.067772	0.260330	0.68911	0.047913	0.001711	0.041365
B16	0.1268	6.555857	0.069009	0.262696	0.63319	0.19097	0.006823	0.082585
B17	0.2555	2.168015	0.022821	0.151067	0.65285	0.195339	0.006976	0.083524
B18	0.1389	9.574163	0.100781	0.317460	0.65147	0.301825	0.010779	0.103824
B19	0.2445	2.973399	0.031299	0.176915	0.68413	0.552905	0.019747	0.140522

B tipi yatırım fonu net varlık değerini tahmin etmede kullandığımız öngörü yöntemlerinin performans karşılaştırması yapılan Tablo 8'e göre, YSA tekniğinin regresyon yöntemine göre daha iyi performans gösterdiği görülmektedir. R² ve HKT değerleri incelendiğinde YSA tekniğinin performans üstünlüğü göze çarpmaktadır. B10 koduyla anılan Garanti Bankası A.Ş. B Tipi Likit Fon'u regresyon yönteminde %-0.0512 ile en düşük ve neredeyse hiçbir ilişkinin olmadığını gösteren bir R² değerine sahip iken YSA tekniği ile elde edilen tahmin modelinde %65.99 ile çok yüksek ve pozitif bir değere sahip olmuştur. Bu fonun HKT iki yöntem açısından karşılaştırıldığında, regresyon modeli değeri 4.281274 iken YSA modeli HKT'nin 0.123453 değeri ile oldukça düşük ve sifıra yakın bir düzeyde çıktığı görülmektedir.

Yine, B8 koduyla anılan TEB A.Ş. B Tipi Likit Fon ile B14 koduyla anılan Vakıflar Bankası B Tipi Değişken Fonu'nun net varlık değerlerini tahmin eden regresyon modelleri için HKT değerleri 14.872900 ve 9.625767 ile en yüksek düzeyde gerçekleşmiştir. Bu değerler, YSA modelinde ise oldukça düşük olan 0.318943 ve 0.532596 düzeylerinde gerçekleşmiştir.

Bu iki yatırım fonunun net varlık değerini tahmin eden iki farklı tahmin yönteminden hesaplanan değerler, iki farklı tahmin yöntemi için HKT değerleri arasındaki farkın büyüklüğünü gösteren en çarpıcı modellerdir.

Diğer A ve B tipi yatırım fonları net varlık değerlerini tahmin eden çok katmanlı YSA modellerinin de regresyon yöntemine göre HKT'nin oldukça minimum düzeye çekildiği görülmektedir.

A tipi ve B tipi yatırım fonlarının net varlık değerlerini tahmin etmek için oluşturulan regresyon ve YSA modellerden hesaplanan performans ölçütleri karşılaştırıldığında, YSA performans göstergelerinin daha iyi sonuçlar verdiği görülmektedir. Ayrıca YSA yönteminin B tipi yatırım fonları için daha etkin sonuçlar verdiği de görülmektedir. Bağımsız değişkenlerdeki değişmelerin bağımlı değişken üzerindeki etkilerini açıklayan, düzeltilmiş R² değerlerinin daha yüksek gerçekleştiği ve en önemli ve en çok kullanılan performans ölçütü olan HKT'nin regresyon yöntemine göre oldukça düşük sifıra yakın düzeylerde gerçekleştiği görülmektedir.

Literatür incelemesinde yer alan tüm çalışmalar YSA'ların, regresyon analizine göre daha başarılı sonuçlar verdiğini ortaya koymaktadır. Bu çalışmada geliştirilen YSA modellerinden elde edilen bulguların, geliştirilen regresyon modellerinden elde edilen bulgulara göre daha başarılı olması, YSA'ları üzerine daha önce yapılan çalışmalarla paralel sonuçların elde edildiğini göstermektedir. Çalışma sonucunda elde edilen bulgular, Türkiye'deki yatırım fonları net varlık değerlerinin ulusal ve uluslararası piyasalarda meydana gelen gelişmelerden doğrudan etkilendiğini göstermektedir.

Sonuç

Bu çalışmada, doğrusal olmayan tahmin modellerinden biri olan YSA modelleme tekniğinden yararlanarak, Ocak 2001-Aralık 2008 döneminde Türkiye'de faaliyet gösteren 19 adet A ve 19 adet B tipi olmak üzere toplam 38 adet yatırım fonunun net varlık değerlerinin regresyon ve YSA modelleri ile tahmin edilmesi amaçlanmıştır. Geliştirilen YSA modelleri hem kendi içinde değerlendirilmiş hem de doğrusal regresyon analizi yapılarak performans karşılaştırmaları yapılmıştır.

Geliştirilen YSA modelleri, kendi içlerinde tutarlı bir yapı ve iyi bir öngörü performansı göstermişlerdir. Regresyon modeli ile yapılan öngörü karşılaştırmasında ise YSA tekniğinin bu yönetime göre daha iyi bir performans gösterdiği sonucuna varılmıştır. Ayrıca, örneklem içi ve örneklem dışı dönemde ortaya çıkan finansal krizlerin tahmini konusunda YSA yönteminin regresyon yöntemine göre daha başarılı olduğu en dikkat çekici noktadır. Ayrıca, bu çalışmanın sonuçlarının literatürle uyumlu olduğu da tespit edilmiştir.

Regresyon analizi ile yapılan öngörülerin gerçek değerlerden büyük sapmalar göstermesi ve mevsimsel etkilerin yapay sinir ağlarına yansıtılmamış olmasına rağmen ağın daha iyi öngörü performansı göstermesi, finansal değişkenler için doğrusal olmayan modellemenin yani yapay sinir ağları yönteminin daha etkili olduğu biçiminde bir genelleme yapılabilmesine neden olmaktadır.

Dünya genelinde yatırım fonlarına ilişkin tahminlerde YSA modellerini kullanan çalışma sayısı oldukça azdır. Türkiye yatırım fonları üzerinde YSA modellerini kullanan çalışma sayısı ise birkaç tanedir ve bu çalışmalar sınırlı sayıda yatırım fonu üzerinde yapılmıştır. Bu çalışmada, YSA modelinin yatırım fonları portföy büyüklüklerinin tahmininde kullanılmasının ve analize dâhil edilen yatırım fonu sayısı ve çeşidinin fazla olmasının çalışmaya özgünlük kattığı düşünülmektedir.

Bu çalışmadan hareketle yatırım fonları üzerine ileride yapılabilecek yeni araştırma konuları olarak şunlar önerilebilir. Yatırım fonu net varlık değerini etkileyen makro ekonomik değişken sepeti genişletilirken çalışılan yatırım fonu türü sınırlı tutulabilir. Başka bir ifadeyle Türkiye'deki belli bir yatırım fonu türü için benzer bir analiz yapılabilir. Türkiye yatırım fonu net varlık değerinin, daha uzun bir dönem için diğer ekonometrik modellerle YSA yöntemi karşılaştırmalı olarak analizi de bir diğer bir çalışma konusu olabilir.

Kaynakça

- Abraham, A., Yuehui C., BO Y. ve Jiwen D. (2004).** Time-Series Forecasting Using Flexible Neural Tree Model, *Information Sciences*, (174):1-17.
- Altan, Ş. (2008).** Döviz Kuru Öngörü Performansı İçin Alternatif Bir Yaklaşım: YSA, *Gazi Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 10(2):141-160.
- Altay, E. ve M. H. S. (2005).** Stock Market Forecasting: Artificial Neural Networks and Linear Regression Comparison in an Emerging Market, *Journal of Financial Management and Analysis*, 18(2):18-33.
- Anderson, D. ve George M. (1992).** Artificial Neural Networks Technology, *Kaman Science Corporation*, New York, USA.
- Avcı, E. (2007).** Forecasting Daily and Sessional Returns of the ISE-100 Index with Neural Networks Models, *Doğuş Üniversitesi Dergisi*, 8(2):128-142.

- Benli, Yasemin K. (2005).** Bankalarda Mali Başarı-sızlığın Öngörülmesi Lojistik Regresyon ve Yapay Sinir Ağı Karşılaştırması, *Gazi Üniversitesi Endüstriyel Sanatlar Eğitim Fakültesi Dergisi*, (16):31-46.
- Chiang W.C., T. L. Urban ve G. W. Baldrige (1996).** A Neural Network Approach to Mutual Fund Net Asset Value Forecasting, *Omega, International Journal of Management Science*, 24(2):205-215.
- Diler, A. İ. (2003).** İMKB Ulusal-100 Endeksinin Yönünün Yapay Sinir Ağları Hata Geriye Yayıma Yöntemi ile Tahmin Edilmesi, *İMKB Dergisi*, 25(26):65-81.
- Dutta, G., Pankaj J., Arnab K. ve Lha N. M. (2006).** Artificial Neural Network Models for Forecasting Stock Price Index in the Bombay Stock Exchange, *Journal of Emerging Market Finance*, 5(3):49-61.
- Ertek, T.(2000).** *Ekonometriye Giriş*, Genişletilmiş 2. Baskı, İstanbul: Beta Yayın Dağıtım.
- Fausett, L.(1994).** *Fundamentals of Neural Networks*, USA: Prentice Hall.
- Gujarati, D. N. (2004).** *Basic Econometrics*, New York: McGraw-Hill, Inc, 4. Edition.
- Hamilton, J. D. (1994).** *Time Series Analysis*, New Jersey: Princeton University Press.
- Indro, D. C., C. X. Jianga, B. E. Patuwo ve G. P. Zhang (1999).** Prediction Mutual Fund Performance Using Artificial Neural Networks, *Omega, International Journal of Management Science*, 27(3):373-380.
- Kaastra, I. ve Milton B. (1996).** Designing a Neural Network for Forecasting Financial and Economic Time Series, *Neurocomputing*, (10):215-236.
- Kamruzzman, J., Rezaul K. B. ve Ruhul A. S. (2006).** *Artificial Neural Networks in Finance and Manufacturing*, USA: Idea Group Publishing.
- Karaçor, Z. ve Alptekin, V. (2006).** Finansal Krizlerin Önceden Tahmin Yoluyla Değerlendirilmesi: Türkiye Örneği, *Yönetim ve Ekonomi*, 13(2):237-256.
- Kennedy, P. (1998).** *A Guide to Econometrics*, U.S: The MIT Press, 4. Ed.
- Kim, T. Y., Kyong J. Oh, Insuk S. ve Changha H. (2004).** Usefulness of Artificial Neural Networks for Early Warning System of Economic Crisis, *Expert Systems with Applications*, (26):583-590.
- Liang, X., H. Zhang, J. Xiao ve Y. Chen (2009).** Improving Option Price Forecasts with Neural Networks and Support Vector Regressions, *Neurocomputing*, (72):3055-3065.
- Oh, K. J., Kim, T. Y., Kim, C. (2006).** An Early Warning System for Detection of Financial Crisis Using Financial Market Volatility, *Expert Systems*, 23(2):83-98.
- Öztemel, E. (2006).** *Yapay Sinir Ağları*, İstanbul: Papatya Yayıncılık, 2. Basım.
- Panda, C. ve V. N. (2007).** Forecasting Exchange Rate Better with Artificial Neural Network, *Journal of Policy Modeling*, 29(2):227-236.
- Quian, B. ve Khaled R. (2009).** Foreign Exchange Market Prediction with Multiple Classifiers, *Journal of Forecasting*, (29):271-284.
- Ray, P. ve Vina V. (2004).** Neural Network Models for Forecasting Mutual Fund Net Asset Value, *Working Paper*.
- Sahoo, P. K. ve Priti R. H. (2007).** Prediction of Mutual Funds: Use of Neural Network Technique, *The IUP Journal of Applied Finance*, (13):11.
- Sevüktekin, M.ve Mehmet N. (2007).** *Ekonometrik Zaman Serileri Analizi, EViews Uygulamalı, Geliştirilmiş 2. Baskı*, Ankara: Nobel Yayın Dağıtım.

- Smith, K. A. (2002).** *Neural Networks for Business: An Introduction*, Neural Networks in Business: Techniques and Applications, Idea Group Publishing, USA, /http://books.google.com, Erişim Tarihi: 31.03.2009.
- Tseng, Chih-H., Sheng-Tzong C., Yi-Hsien W. ve Jin-Tang P. (2008).** Artificial Neural Network Model of the Hybrid EGARCH Volatility of the Taiwan Stock Index Option Prices, *Physica A: Statistical Mechanics and Its Applications*, 387(13):3192-3200.
- Yao, J., Hean-Lee P. ve Teo J. (1996).** Foreign Exchange Rates Forecasting with Neural Networks, ICONIP'96 (*International Conference on Neural Information Processing*), Hong Kong, September. 24(27):754-759.
- Yıldız, B. (2001).** Finansal Başarısızlığın Öngörülmesinde Yapay Sinir Ağı Kullanımı ve Halka Açık Şirketlerde Ampirik Bir Uygulama, *İMKB Dergisi*, 5(17):51-67.
- Yurtoğlu, H. (2005).** Yapay Sinir Ağları Metodolojisi ile Öngörü Modellemesi: Bazı Makroekonomik Değişkenler İçin Türkiye Örneği, DPT Uzmanlık Tezi, Ankara.
- Zhang, G., B. Eddy P. ve Michael Y. Hu (1998).** Forecasting with Artificial Neural Networks: The State of the Art, *International Journal of Forecasting*, (14):35-62.
- Zhang, G. P. (2001).** An Investigation of Neural Networks for Linear Time-Series Forecasting, *Computers & Operations Research*, 28:1183-1202.
- Zhang, G. P. ve Min Qi (2005).** Neural Network Forecasting for Seasonal and Trend Time Series, *European Journal of Operational Research*, 160:501-514.