

YALIN SİNİRSEL BULANIK BİR MODEL İLE İMKB 100 ENDEKSİ TAHMİNİ

Yeşim OK*, Mehmet ATAK**, M. Ali AKÇAYOL***

* Endüstri Mühendisliği Bölümü, Mühendislik Fakültesi, Atatürk Üniversitesi, Erzurum

** Endüstri Mühendisliği Bölümü, Mühendislik Fakültesi, Gazi Üniversitesi, Maltepe, Ankara

*** Bilgisayar Mühendisliği Bölümü, Mühendislik Fakültesi, Gazi Üniversitesi, Maltepe, Ankara

yesimok@gazi.edu.tr, matak@gazi.edu.tr, akcayol@gazi.edu.tr

(Geliş/Received: 07.03.2011; Kabul/Accepted: 15.09.2011)

ÖZET

Bu çalışmada, İstanbul Menkul Kıymetler Borsası (İMKB) Ulusal 100 Endeksinin öngörülebilirliği geriye dönük olarak Adaptif Sinirsel Bulanık Çıkarım Sistemi (Adaptive Neuro Fuzzy Inference System - ANFIS) kullanılarak kurulan modeller ile test edilmiştir. Ayrıca endeksin tahmini için kullanılan girdilerin modele katkıları da tahmin performansı esas alınarak değerlendirilmiştir. Başarılı borsa tahmininde en önemli unsur, en az sayıda girdi ve en az karmaşık model ile en iyi sonucun elde edilebilmesidir. Bu bağlamda bu çalışmada çok fazla girdi değişkeni kullanılmasına gerek duyulmadan, İMKB 100 endeksinin ANFIS ile ne derece tutarlı tahmin edilebileceği gösterilmek istenmiştir. Bu amaçla, analiz dönemi olarak yaklaşık dört buçuk yıllık bir süre seçilmiş; iki girdili (dolar kuru ve gecelik faiz oranı) ve üç girdili (dolar kuru, gecelik faiz oranı ve işlem hacmi) olmak üzere iki farklı model kurulmuştur. ANFIS kullanılarak her iki model ile de belirleyicilik katsayısı yüksek olan, dolayısıyla tutarlı tahmin sonuçları elde edilmiştir. Elde edilen deneysel sonuçlar, ANFIS ile yalnızca iki girdi değişkeni kullanılarak, karmaşık bir modele gereksinim duyulmadan, İMKB 100 Endeksinin kısa dönemde öngörülebilir olduğunu göstermiştir.

Anahtar Kelimeler: İMKB 100 Endeksi tahmini, ANFIS, sinirsel bulanık sistemler

A SIMPLE NEURO FUZZY MODEL FOR ISE 100 INDEX PREDICTION

ABSTRACT

In this paper, Istanbul Stock Exchange (ISE) National 100 Index retrospective predictability was tested by using the Adaptive Neuro Fuzzy Inference System (ANFIS). In addition, contribution of the inputs to the model for index forecasting was evaluated on the basis of prediction performance. The most important factor to successful stock market prediction is achieving best results using minimum required input data and the least complex stock market model. In this context, we aim to prove consistent prediction of ISE 100 index without having to use a lot of input variables with ANFIS. For this purpose, about four and a half year period was chosen as the analysis period; two input variables (the exchange rate and repurchasing interest rate) and three input variables (the exchange rate, repurchasing interest rate and trading volume) were established in two different models. Consistent prediction results have been obtained with high predictive factor with both of the models. As a result, that is concluded that the ISE 100 Index has short-term predictability using only two input variables, without the need for a complex model with ANFIS.

Keywords: ISE 100 index prediction, ANFIS, neuro-fuzzy systems

1.GİRİŞ (INTRODUCTION)

Borsa endeksi politik, ekonomik, çevresel ve ticari pek çok faktörden etkilendiği ve endeks değeri dinamik, karmaşık ve doğrusal olmayan bir yapıda olduğu için tahmin edilmesi oldukça karmaşık ve zor bir süreci gerektirir. Hisse senedi fiyat davranışlarının tahminini zorlaştıran yüksek belirsizlik ve oynaklık nedeni ile hisse senedi yatırımları diğer tüm yatırım alanlarından daha fazla risk taşır [1]. İşeri ve arkadaşları [2], İMKB endeksinin gösterdiği davranış biçimi üzerinde yaptıkları bir çalışma neticesinde İMKB endeksinin çok yüksek kaotik bir yapıya sahip olduğu ve bu nedenle uzun dönemli tahmin edilebilirliğinin mümkün olmadığı sonucuna ulaşmışlardır.

Yapay sinir ağları yaklaşımı, hisse senedi fiyat davranışlarının tahmininde göreceli olarak yeni, faal ve umut veren bir alandır. Günümüzde yapay sinir ağları popüler olarak borsa endeks tahmini, iflas tahmini ya da şirket bono sınıflaması gibi birçok finans problemine uygulanmaktadır [3].

Diler [4], geri yayılım ağı algoritması kullanarak İMKB Ulusal 100 endeksinin bir gün sonraki yönünü tahmin etmeye çalışmıştır. YSA modelinin İMKB Ulusal 100 endeksinin bir gün sonraki yönünü %60.81 oranında doğru tahmin edebildiği sonucuna ulaşmıştır. Yumlu ve arkadaşları [5], 12 yıllık finansal veri (ISE endeksi kapanış değeri kümesi, Amerikan Dolar kuru, faiz değerleri) üzerinde yaptıkları araştırma ile YSA modelinin otoregresif modellerden daha iyi performans gösterdiği sonucuna ulaşmışlardır. Altay ve Satman [6], lineer regresyon ve çok katmanlı YSA modellerini kullanarak İMKB 30 ve İMKB 100 endekslerinin getirilerini tahmin etmeye çalışmışlardır. YSA modelleri aylık ve günlük getiriler için lineer regresyondan daha iyi sonuçlar vermese de, bu modellerin endeks getirilerinin yönünü tahmin etmede başarılı olduğu sonucuna ulaşmışlardır.

Benzer bir çalışmada, Karaatlı ve arkadaşları [7], İMKB 100 endeks değerini tahmin etmede regresyon ve çok katmanlı YSA modeli kullanmış; hata kareleri ortalamasının karekökü ölçütüne göre yapılan karşılaştırmada YSA modelinin çok daha başarılı sonuçlar ürettiğini belirlemişlerdir. Karaçor ve Alptekin [8], Şubat 2001'de yaşanan ekonomik krizin öncesi ve sonrasına ilişkin yaptıkları analiz neticesinde öncü göstergelerin yaşanan ekonomik kriz sürecini uygun bir şekilde tahmin ettiğini tespit etmişlerdir. Avcı [9], çok katmanlı YSA modellerinin İMKB Ulusal 100 endeksinin günlük ve seanslık getirilerinin tahmin edilmesinde oldukça etkin bir yöntem olduğu sonucuna ulaşmıştır. Hamzaçebi ve Bayramoğlu [10], krizin yaşanmadığı, ekonomik istikrarın kriz dönemlerine

nispeten iyi olduğu koşullar altında, tek değişkenli ve iki değişkenli YSA modelleri ile İMKB Ulusal 100 Endeksinin gün içi en yüksek ve en düşük değerlerinin öngörüsünün gerçekleştirilebileceğini ortaya koymuşlardır. Yıldız ve arkadaşları [11], endeksin gün içindeki en düşük ve en yüksek değerlerini, kapanış değerini, dolar kurunu ve dönüş oranını girdi olarak aldığı üç katmanlı geriye yayımlı YSA modeli ile İMKB 100 endeksinin yönünü %74.52 doğruluk oranı ile tahmin edebilmişlerdir. Öğüt ve arkadaşları [12], YSA ve destek vektörleri analiz yöntemi ile borsadaki manipülasyonları teşhis edebilen bir sistem geliştirmişlerdir.

Literatürden anlaşılacağı üzere, çalışmaların neredeyse tamamında YSA modellerinin hisse senedi piyasa endekslerinin yönünün ve değerinin tahmin edilmesinde ve finansal kriz dönemlerinin belirlenmesinde oldukça başarılı sonuçlar elde ettiği söylenebilir. Yapay sinir ağları ile bulanık mantık tekniklerinin birlikte kullanıldığı bir yöntem olan ANFIS 'in tahmin etmedeki gücü göz önünde bulundurularak yine finansal tahmin literatüründe ANFIS ile yapılmış birçok tahmin çalışmasına rastlanmaktadır.

Quek [13], ANFIS'i Amerikan borsasında hisse senedi fiyatlarının tahmininde kullanırken, Trinkle [14], ANFIS ve Yapay Sinir Ağlarını (YSA) borsa tahmin yeteneği açısından karşılaştırmış ve her iki yönteminde önemli bir tahmin yetisine sahip olduğu sonucuna ulaşmıştır. Başka bir çalışmada ise Atsalakis ve Valavanis [15], Amerikan ve New York borsaları için bir sonraki günün trendini iyi bir performansla tahmin edebilen sinirsel bulanık bir sistem geliştirmişlerdir. Akbar ve arkadaşlarının [16] Tahran Borsası endeksi tahmini için ANFIS ile kurdukları model, %97,8 gibi yüksek bir tahmin performansı göstermiştir.

Yine ANFIS ile kurdukları modelde Boyacıoğlu ve Acar [17], İMKB 100 endeksinin aylık getirisini tahmin etmek amacıyla çok sayıda girdi değişkeni kullanmışlardır. 1990 ile 2008 yılları arasındaki aylık makro ekonomik göstergelerin (altın satış fiyatı, dolar kuru, mevduat faiz oranları, tüketici fiyat endeksi, sanayi üretim endeksi, Hazine faiz oranları) yanı sıra yurtdışındaki bazı borsaların (Dow Jones, DAX, BOVESPA) kapanış fiyatları da İMKB ile bu borsalar arasında pozitif bir korelasyon olduğu varsayımıyla söz konusu çalışmada modele girdi olarak alınmıştır. Bu çalışmanın sonucunda İMKB 100 endeksinin aylık getirisi % 98,3 doğruluk oranıyla tahmin edilmiş ve ANFIS'in borsa endeks tahmini için uygun bir yöntem olduğu sonucuna ulaşılmıştır.

Ancak, Atsalakis ve Valavanis'in 100'den fazla çalışmada kullanılan borsa tahmin tekniklerini

inceledikleri literatür çalışmasında [18] vardıkları sonuç; başarılı borsa tahminindeki ana fikrin en az sayıda girdi ve en az karmaşık model ile en iyi sonucu elde edilebilmesi olduğudur. Bu bağlamda bu çalışmada çok fazla girdi değişkeni kullanılmasına gerek duyulmadan, İMKB 100 endeksinin ANFIS ile ne derecede tutarlı tahmin edilebileceği gösterilmek istenmiştir.

2.METOD (METHOD)

2.1.Sinirsel Bulanık Sistemler (Neuro Fuzzy Systems)

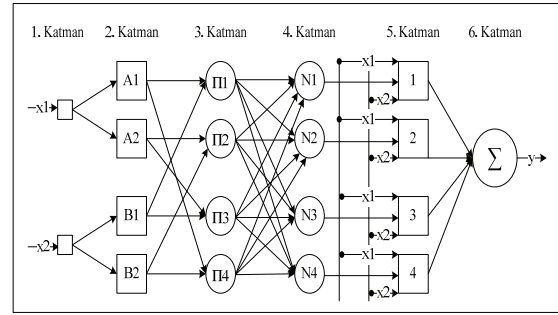
Sinirsel uyarlanırlar öğrenme teknikleri, bulanık modelleme prosedürü için veri setini kullanarak ilgili sistemi “öğrenen” bir model geliştirmeyi sağlar. Sinirsel - bulanık sistemlerin amacı her iki yaklaşımın faydalarını toplayıp, bir araya getirmektir. Sinirsel bulanık sistemlerde sinir ağlarının esneklik, hız ve uyarlanabilirlik gibi özelliklerinin bulanık sisteme eklenme durumu söz konusudur [19]. Özet olarak sinirsel bulanık sistemler aşağıdaki avantajlara sahiptir:

- ✓ Öğrenme yeteneği
- ✓ Kesin olmayan girdi ve sistem çıktılarının dilsel ifade edilebilirliği
- ✓ Uyarlanabilirlik
- ✓ Bilgiyi eşzamanlı işleme yeteneği

Hesaplama zamanı, performans seviyesi veya kural tabanının anlamlılığı kriterleri esas alındığında sinirsel bulanık yöntemler birbirlerine göre üstünlük sağlayabilmektedir [20]. ANFIS son yıllarda geliştirilen sinirsel bulanık sistemler arasında en çok bilinenidir. Sugeno benzeri bulanık sistem içerir ve geri yayımlı öğrenme algoritması kullanır.

2.2. ANFIS - Uyarlanabilir Sinirsel Bulanık Çıkarım Sistemi (Adaptive Neuro Fuzzy Inference System)

ANFIS, Jang tarafından (1993) Takagi - Sugeno bulanık modeli [21] esas alınarak geliştirilmiştir [22]. ANFIS girdi/ çıktı veri setini YSA 'ndaki geri yayımlı algoritmayı tek başına ya da en küçük kareler yöntemi ile birlikte kullanarak üyelik fonksiyonu parametrelerini düzenleyerek bir bulanık çıkarım sistemi oluşturur. Bu düzenleme bulanık sistemimizin modellediği veriler yardımıyla çevresel bilgiyi kullanarak ilgili sistemi öğrenmesini ve kendi kendini güncellemesini sağlar. Yani kendini modelleyeceği veriye göre uyarlar/adapte eder. Bu nedenle uyarlanabilirdir [23]. Ayrıca ANFIS, sayısal gruplandırma ve kural koyma gibi gelişmiş veri analiz teknikleri de içermektedir.



Şekil 1. Uyarlanırlar (adaptif) ağ tabanlı bulanık mantık çıkarım sistemi (Adaptive neuro fuzzy inference system)

ANFIS, 6 katmandan oluşmaktadır. Bu sistem şekil 1’de gösterilmiştir. ANFIS yapısındaki her katmana ait düğüm işlevleri ve katmanların işleyişi sırasıyla şöyledir:

1. Katman: Girdi katmanı (Bu katmandaki her düğümden alınan giriş sinyalleri diğer katmanlara aktarılır.)

2. Katman: Bulanıklaştırma katmanı. (Burada, her bir düğümün çıkışı, giriş değerlerine ve kullanılan üyelik fonksiyonuna bağlı olan üyelik derecelerinden oluşmaktadır.)

3. Katman: Kural katmanı (Bu katmandaki her bir düğüm, Sugeno bulanık mantık çıkarım sistemine göre oluşturulan kuralları ve sayısını ifade etmektedir.)

4. Katman: Normalizasyon katmanı (Bu katmandaki her bir düğüm, kural katmanından gelen tüm düğümleri giriş değeri olarak kabul etmekte ve her bir kuralın normalleştirilmiş ateşleme seviyesini hesaplamaktadır.)

5. Katman: Arındırma (durulaştırma) katmanı (Burada her bir düğümden verilen kuralların ağırlıklandırılmış değerleri hesaplanmaktadır.)

6. Katman: Toplama katmanı (Burada her bir düğümün çıkış değeri toplanarak sonuçta, ANFIS sisteminin gerçek değeri elde edilir.)

ANFIS’in öğrenme algoritması, en küçük kareler yöntemi ile geri yayımlı öğrenme algoritmasının bir arada kullanılmasından oluşan karma öğrenme algoritmasıdır. Bu öğrenme algoritması hata geri yayılımına dayalıdır. Öğrenme işlemi iki aşamadan oluşur. Birinci aşamada giriş örnekleri üretilir ve öncül parametreler sabit kabul edilerek, en küçük ortalama kare (least mean square) metoduyla en iyi ikincil parametreler tespit edilir. İkinci aşamada ise giriş örnekleri yeniden üretilir ve ikincil parametreler sabit kabul edilerek öncül parametreler

eğim alçalması (gradient descent) metoduyla değiştirilir. Bu süreç daha sonra tekrar edilir [23].

3. UYGULAMA (APPLICATION)

3.1. Girdi Değişkenlerinin Seçimi ve Sınıflandırılması (Input Variables Selection and Classification)

Bu çalışmada, İMKB Ulusal 100 Endeksinin öngörülebilirliği geriye dönük olarak ANFIS ile test edilmiştir. Ayrıca endeksin tahmini için kullanılan girdilerin modele katkıları da tahmin performansı esas alınarak değerlendirilmiştir. Nisan 2006 – Aralık 2010 dönemini kapsayan yaklaşık dört buçuk yıllık süre analiz dönemi olarak seçilmiştir.

Bu çalışmada kullanılacak girdi değişkenleri belirlenirken; hisse senedi değerlerinin enflasyon ve kısa vadeli faiz oranı gibi makroekonomik faktörlerden doğrudan etkilendikleri göz önünde bulundurulmuştur [24]. Ayrıca literatürde daha önce yapılmış çalışmaların sonuçları dikkate alınmıştır [1, 9, 25].


Sonuç olarak, çalışmada öncelikle iki girdili (bir önceki günün dolar kuru ve gecelik faiz oranı) ve üç girdili (bir önceki günün dolar kuru, gecelik faiz oranı ve işlem hacmi) olmak üzere iki farklı model kurulmuş, çıktı değişkeni olarak ise İMKB Ulusal 100 Endeksi alınmıştır. Tüm değişkenler iş günü frekansında alınmış ve veriler, Türkiye Cumhuriyeti Merkez Bankası Elektronik Veri Dağıtım Sistemi'nden elde edilmiştir. Son aşamada da ANFIS modellerinin performansı, çoklu doğrusal regresyon yöntemi ile kıyaslanmıştır.

Nisan 2006 – Aralık 2010 arasındaki yaklaşık dört buçuk yıllık her bir değişken için toplam 1187 veri kullanılmıştır. Bu veriler, eğitim, kontrol ve test seti olmak üzere üç veri setine ayrılmışlardır. Ağ eğitmek amacıyla tüm veri setinin yaklaşık %60'ı (717 adet) eğitim veri seti için, %20'si (235 adet) ise test için ayrılmış ve geriye kalan % 20 de modelin doğrulanması amacıyla kontrol seti olarak kullanılmıştır.


Eğitim veri seti ile ağ girdi/çıkı verileri arasındaki ilişkiyi öğrenmekte ve üyelik fonksiyonu parametrelerini, belirlenen devir sayısına ya da istenen hata düzeyine erişinceye kadar düzenlemektedir. Kontrol veri seti ile modelin geçerliliği doğrulanırken test veri seti ile de eğitilen ve parametreleri düzenlenen modelin daha önce hiç karşılaşmadığı veriler karşısında genelleme kabiliyeti ölçülmektedir.

3.2. ANFIS Modelleri ile İMKB Ulusal 100 Endeksi Tahmini (ISE National 100 Index Forecasting with ANFIS Models)

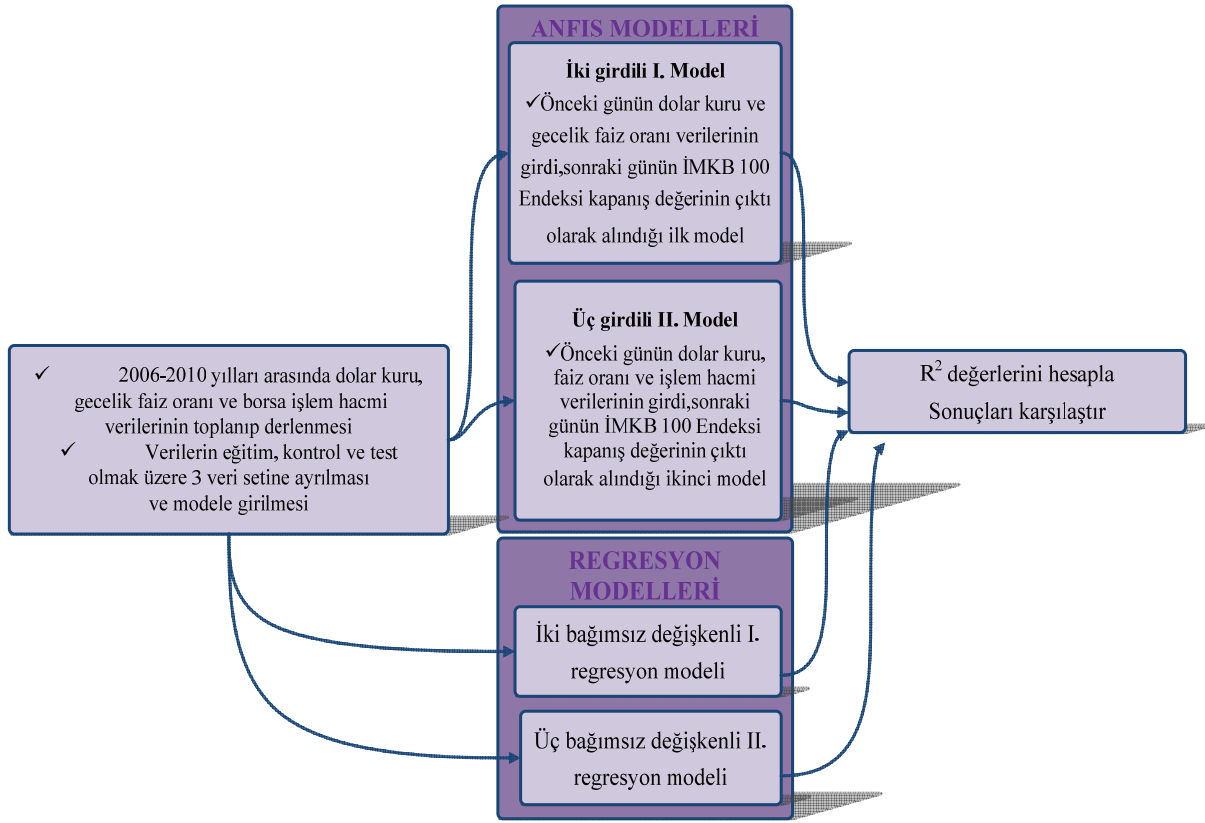
Oluşturulan her iki ANFIS modelinde de Bulanık Çıkarım Sistemi (BÇS)'nin girdi/çıkı üyelik fonksiyonu tipi ve üyelik fonksiyonlarının sayısı, deneme yanılma yöntemiyle en az test hatası veren alternatif esas alınarak belirlenmiş ayrıca test hatası ile eğitim hatası arasındaki farkın çok yüksek çıkmadığı seçenekler dikkate alınmıştır. Şekil 3 ve 4 'de oluşturulan ikili ve üçlü modellerin eğitim ve test sonuçları grafiksel olarak görülmektedir.



Şekil 3. İkili ve üçlü modellerin eğitim süreçleri (Training process of dual nad triple models)



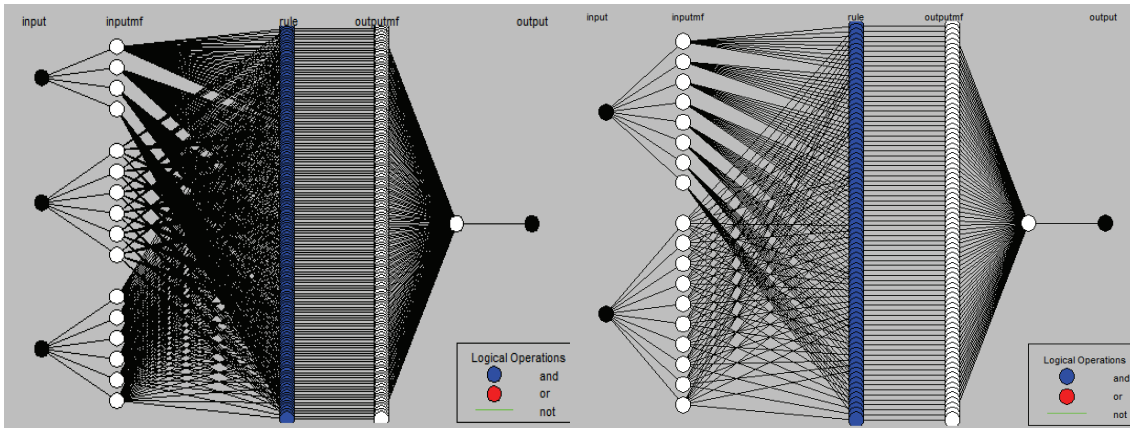
Şekil 4. İkili ve üçlü modellerin test sonuçları (Test results of dual and triple models)



Şekil 2. Uygulanan metodolojinin akış şeması (Flow diagram of applied methodology)

Tablo 1'de her iki modelin parametreleri ve modellerin eğitim ve test hataları, ortalama hata karelerinin karekökü (Root Mean Square Error-RMSE) ve ortalama mutlak yüzde hata (Mean Absolute Percentage Error - MAPE) cinsinden verilmiştir.

Şekil 5'de her iki modelin ağ yapıları görülmektedir. Model yapılarından da anlaşılacağı üzere üç girdili model daha karmaşık bir yapıya ve daha fazla kurala sahip olmasına karşılık iki girdili model daha iyi bir tahmin sonucu vermiştir.



Şekil 5. İkili ve üçlü modellerin ağ yapıları (Network structure of dual and triple models)

Tablo 1. ANFIS modellerinin parametreleri ve ilgili tahmin hataları (Parameters of ANFIS models and related forecasting errors)

	Üyelik fonk. tipi	Üyelik fonk. sayısı	Bulanık kural sayısı	Devir sayısı	Eğitim hatası (RMSE)	Test hatası (RMSE)	Ort. Mutlak Yüzde Hata (MAPE)
İki girdili model	gbell	8 10	80	25	3278	3561	0,048
Üç girdili model	gbell	4 6 6	144	50	3570	3805	0,066

3.2. Çoklu Regresyon Analiziyle İMKB Ulusal 100 Endeksi Tahmini (ISE National 100 Index Forecasting with Multiple Regression Analysis)

Bu çalışmada ayrıca ANFIS ile elde edilen tahmin sonuçlarını karşılaştırmak amacıyla aynı veriler kullanılarak, geleneksel istatistikî yöntemlerden çoklu regresyon analizi ile de İMKB 100 Endeksi geriye dönük olarak tahmin edilmiştir.


Regresyon analizi yapılırken; regresyon denklemi oluşturmak için ANFIS modellerindeki eğitim setleri kullanılmış, oluşturulan regresyon modellerinin tahmin tutarlılığını tespit etmek için ise yine ANFIS modellerinde kullanılan test veri setleri kullanılmıştır.

Oluşturulan iki girdili (dolar kuru ve gecelik faiz oranı) regresyon denklemi:

$$\text{Endeks} = 142410 - 51746 \text{ dolar kuru} - 1890 \text{ gecelik faiz oranı}$$

Üç girdili (dolar kuru, gecelik faiz oranı ve borsa işlem hacmi) regresyon denklemi:

$$\text{Endeks} = 124078 - 47528 \text{ dolar kuru} - 1442 \text{ gecelik faiz oranı} + 3,77 \text{ işlem hacmi}$$

**Şekil 6.** İkili ve üçlü ANFIS modellerinin tahmin sonuçları (Forecasting results of ANFIS models)


3.4. Tahmin Sonuçları (Forecasting Results)

ANFIS ve regresyon analiziyle oluşturulan iki ve üç girdili modellerin tahmin tutarlılıkları, belirleyicilik katsayısı (R-kare) kullanılarak birbirleriyle karşılaştırılmıştır. 250 veriden oluşan test kümesi içinden seçilen 50 adet veri üzerinden tüm modeller için hesaplanan R^2 değerleri Tablo 2'de görüldüğü gibidir.

Tablo 2. Tüm modellerin R^2 ve Ortalama mutlak yüzde hata değerleri (R^2 and MAPE values of all models)

Model	İki Girdili		Üç Girdili	
	ANFIS	Regresyon	ANFIS	Regresyon
R^2	0,971	0,574	0,953	0,595
MAPE	0,048	2,417	0,066	1,081

Şekil 6'ya bakıldığında her iki ANFIS modelinin de yüksek tutarlılıkta tahmin edebilir olduğu ve ikili modelin üçlü modelden daha iyi tahmin sonuçları verdiği görülmektedir. Borsa endeksinin doğrusal olmayan, kompleks yapısından dolayı regresyon analizi ile yapılan tahminlerin tutarlı olmadığı sonucuna ulaşılmıştır. (Bkz. Şekil 7)

**Şekil 7.** Regresyon modellerinin tahmin sonuçları (Forecasting results of regression models)

4. SONUÇLAR (Conclusions)

Bu çalışmada İMKB Ulusal 100 Endeksi tahmininde bulunulmuş ve bu amaçla da yapay sinir ağları ve bulanık mantık yöntemlerinin birleşiminden oluşan iki ayrı ANFIS modeli ve çoklu regresyon modelleri kullanılmış ve tüm bu modellerin tahmin sonuçları birbirleriyle karşılaştırılmıştır. Bir önceki günün Amerikan doları ve gecelik faiz oranlarının değişken olarak kullanıldığı I. ANFIS modelinde belirlenen dönem için en yüksek R² değerine ulaşılmış ve en düşük ortalama tahmin hatası elde edilmiştir.

Sonuç olarak literatürdeki diğer çalışmalarla karşılaştırıldığında; karmaşık bir modele gereksinim duyulmadan ANFIS ile yalnızca iki girdi değişkeni kullanarak, İMKB 100 Endeksinin yüksek tutarlılıkta kısa dönemli öngörülebilir olduğu sonucuna ulaşılmıştır.

KAYNAKLAR (References)

1. Kutlu, B., Badur, B., “Yapay Sinir Ağları İle Borsa Endeksi Tahmini”, **Yönetim**, 63:25-40, (2009)
2. İşeri, M., Çağlar, H., Çağlar N., “A model proposal for the chaotic structure of Istanbul stock exchange”, **Chaos, Solitons and Fractals** 36:1392–1398, 2008.
3. Murphy, J.J., “Technical Analysis of the Financial Markets: A Comprehensive Guide to Trading Methods and Applications” New York Institute of Finance, 1999.
4. Diler, A. İ., “İMKB Ulusal 100 Endeksinin Yönünün Yapay Sinir Ağları: Hata Geriye Yayma Yöntemi ile Tahmin Edilmesi”, **İMKB Dergisi**, 7:65–81, 2003.
5. Yumlu, S., Gürgen, F., Okay, N., “A Comparison of Global, Recurrent and Smoothed-Piecewise Neural Models for Istanbul Stock Exchange Prediction”, **Pattern Recognition Letters**, 26:2903- 2103, 2004.
6. Altay, E., Satman, M. H., “Stock Market Forecasting: Artificial Neural Networks and Linear Regression Comparison in an Emerging Market”, **Journal of Financial Management and Analysis**, 18(2):18-33, 2005.
7. Karaatlı, M., Güngör, İ., Demir Y. Kalaycı, Ş., “Hisse Senedi Fiyat Hareketlerinin Yapay Sinir Ağları Yöntemi ile Tahmin Edilmesi”, **Balikesir Üniversitesi İİBF Dergisi**, 2(1), 22–48, 2005.
8. Karaçor, Z., Alptekin, V. “Finansal Krizlerin Önceden Tahmin Yoluyla Değerlendirilmesi: Türkiye Örneği”, **Yönetim ve Ekonomi**, 13 (2), 237-256, 2006.
9. Avcı, E., “Forecasting daily and sessional returns of the ISE-100 index with neural network models”, **Journal of Dogus University**, 8(2):128–142, 2007.
10. Hamzaçebi, C., Bayramoğlu, M. F., “Yapay Sinir Ağları ile İMKB 100 Endeksinin Tahmini”, **YAEM 27.Ulusal Kongresi**, Dokuz Eylül Üniversitesi Mühendislik Fakültesi Endüstri Mühendisliği Bölümü ve Yöneylem Araştırması Derneği, 2007.
11. Yıldız, B., Yalama A., Coşkun M., “Forecasting the Istanbul Stock Exchange National 100 Index Using an Artificial Neural Network”, **World Academy of Science, Engineering and Technology** 46:36-39, 2008.
12. Ögüt, H., Doğanay M. , Aktaş,R., “Detecting stock-price manipulation in an emerging market: The case of Turkey”, **Expert Systems with Applications** 36 :11944–11949, 2009.
13. Quek, C. Predicting the impact of anticipator action on US stock market – An event study using ANFIS (a neural fuzzy model). **Computational Intelligence**, 23, 117–141, 2005.
14. Trinkle, B. S., “Forecasting annual excess stock returns via an adaptive network-based fuzzy inference system”, **Intelligent Systems in Accounting, Finance and Management**, 13(3), 165–177, 2006.
15. Atsalakis, G., Valavanis, K., “Forecasting stock market short-term trends using a neuro-fuzzy based methodology” **Expert Systems with Applications**, 36(3) : 10696–10707, 2009.
16. Akbar E., Werya A. , “Adapted Neuro-Fuzzy Inference System on indirect approach TSK fuzzy rule base for stock market analysis”, **Expert Systems with Applications** 37:4742–4748, 2010.
17. Boyacioglu, M., A., Avcı, D., “An Adaptive Network-Based Fuzzy Inference System (ANFIS) for the prediction of stock market return: The case of the Istanbul Stock Exchange” , **Expert Systems with Applications** 37 : 7908–7912, 2010.
18. Atsalakis G., Valavanis K., “Surveying stock market forecasting techniques – Part II: Soft computing methods”, **Expert Systems with Applications** 36(3) : 5932–5941 2009.
19. Baykal, N., Beyan T., “Bulanık mantık uzman sistemler ve denetleyiciler”, **Bıçaklar Kitabevi**, Ankara 2004.
20. Abraham, A., “Neuro-fuzzy systems: state-of-the-art modeling techniques, connectionist models of neurons, learning processes and artificial intelligence”, **Lecture Notes in Computer Science**, 2084: 269-276, 2001.
21. Takagi, T., Sugeno, M., “Fuzzy identification of systems and its applications to modelling and control”, **IEEE Transactions on Systems, Man, and Cybernetics**, 15: 116–132, 1985.
22. Jang, J. S. R., “ANFIS: Adaptive-network based fuzzy inference systems”, **IEEE Trans. On Systems, Man, and Cybernetics**, 23 (03): 665-685, 1993.
23. Demuth, H., Beale, M., “Anfis and the ANFIS Editor GUI” **Fuzzy logic toolbox for use with**

MATLAB, User's Guide Version 4, 2:104-130, MA, 2000.

24. Izumi, K., & Ueda, K. Analysis of exchange rate scenarios using an artificial market approach. **Proceedings of the international conference on artificial intelligence**, 2:360–366, 1999.

25. Akel, V., Bayramođlu, M., F., “Kriz Dönemlerinde Yapay Sinir Ağları ile Finansal Öngöründe Bulunma: İmkb 100 Endeksi Örneđi”, **International Symposium on International Capital Flows and Emerging Markets**, Balıkesir, 2008.