

## AVRUPA BİRLİĞİ ÜYESİ ÜLKELERİN MORGAN STANLEY CAPITAL INTERNATIONAL ENDEKSLERİNİN DEĞERLENDİRİLMESİ ve YAPAY SİNİR AĞLARI İLE ÖNGÖRÜSÜ

Yasemin KESKİN BENLİ\*

Nuray GÜNERİ TOSUNOĞLU\*\*

### Öz:

Finansal öngörü hem akademisyenler hem de yatırımcılar açısından ekonominin geleceği hakkında fikir sağlayan önemli bir konudur. Bu çalışmada Avrupa Birliği üyesi on dört ülkenin Morgan Stanley Capital International endekslerinin değerlendirilmesi ve öngörülmesi amaçlanmıştır. Öngörü için yapay sinir ağları analizi seçilmiştir. Çalışmanın verileri 31 Aralık 1987-31 Ekim 2013 dönemini kapsamaktadır. Her bir endeks için yapay sinir ağı mimarisi ayrı ayrı belirlenmiştir. Çalışmada yer alan veriler aylık olduğundan 12 gecikmeli zaman serisi kullanılmıştır. Buna göre girdi tabakasında yer alacak nöronların sayısı 12 olarak belirlenmiştir. Gizli tabakadaki nöron sayısının seçimi için, nöron sayısının 1 ile 12 arasında değiştiği 12 durum her bir ülke için değerlendirilmiştir ve test kümelerinden elde edilen minimum HKOK değerine sahip model mimari yapıyı oluşturmuştur. Her bir ülke için oluşturulan mimari yapı kullanılarak ağın eğitimi gerçekleştirilerek en iyi ağırlık değerleri hesaplanmıştır. Elde edilen model yardımıyla test kümeleri için öngörüler elde edilmiştir. Performans ölçütü olarak HKOK ve MHO değerlerine bakılmıştır.

**Anahtar Kelimeler:** Borsa, Avrupa Birliği Üyesi Ülkeler, Zaman Serisi Analizi, Yapay Sinir Ağları, Öngörü.

---

\* Doç.Dr. Gazi Üniversitesi, İktisadi ve İdari Bilimler Fakültesi, Uluslararası Ticaret Bölümü, ykeskin@gazi.edu.tr

\*\*Yrd.Doç.Dr. Gazi Üniversitesi, İktisadi ve İdari Bilimler Fakültesi, Uluslararası Ticaret Bölümü, nguneri@gazi.edu.tr

## **EVALUATE THE MORGAN STANLEY CAPITAL INTERNATIONAL INDEX OF THE EUROPEAN UNION COUNTRIES AND FORECAST BY ARTIFICIAL NEURAL NETWORKS**

### **Abstract:**

Financial forecasting is an important issue that providing an idea about the future of the economy according to both academics and investors. In this study, we aimed to evaluate and forecast the Morgan Stanley Capital International index of the fourteen European Union countries. Artificial neural networks is chosen for forecasting. Data period is 31 December 1987-31 October 2013. The artificial neural network architecture is determined separately for each index. 12 lagged time series is used in the study because of the data is monthly. The number of neurons in the input layer is 12. For the selection of the number of neurons in the hidden layers, number of neurons that vary between 1 and 12 of the 12 cases are evaluated for each country. The model having a minimum RMSE and MAE value was created network architecture. For each country, the best weight values were calculated. As performance criteria the RMSE and MAE was selected.

**Keywords:** Stock Exchange, European Union Countries, Time Series Analysis, Artificial Neural Networks, Forecasting.

## **GİRİŞ**

Finans sektöründe hisse senedi borsa endekslerinin öngörüsü hem yatırımcılar hem de akademisyenler tarafından oldukça ilgi çeken bir konudur. Bireysel ya da kurumsal yatırımcıların, portföylerinde yer alan hisse senetlerinin fiyatlarındaki deđişimleri izlemeleri yatırımların karlılığı açısından büyük önem taşımaktadır. Merkez Bankası, Hazine, Sermaye Piyasası Kurulları ve Borsalar gibi kuruluşlar borsa endeksinin hareketlerini, ekonominin gidişatını belirleyen önemli bir deđişken olarak izlemektedirler (Metin, 1999: 89).

Borsa endeks öngörüsü için zaman serisi analizlerinden yararlanılmaktadır. Literatürde ve uygulamada kullanılan analiz tekniklerinden biri de yapay sinir ađlarıdır. Yapay sinir ađı modelleri diđer zaman serisi modelleri gibi ön koşullar gerektirmemesi ve belirli bir model kalıbının olmaması nedeniyle (Erilli, Eğrioglu, vd., 2010:43) son yıllarda finansal öngörü problemlerini çözmek için bir çok çalışmada kullanılmıştır. Hisse senedi piyasa endekslerinin yönünün tahmin edilmesinde, finansal kriz dönemlerinin belirlenmesinde, mali başarısızlıkların öngörülmesinde ve erken uyarı sistemlerinin geliştirilmesinde, mevcut zaman serisi analiz tekniklerine alternatif olarak kullanılan yapay sinir ađları başarılı sonuçlar sağlamaktadır.

Yapay sinir ađları ile finansal öngörü konusunda literatürde yer alan çalışmalar incelendiğinde; Trippi ve Turban (1993), Refenes (1995) iflas öngörüsünde, Weigend vd. (1992), Wu (1995) döviz kuru tahmininde, White (1988) borsa verilerinin öngörülmesinde, Stock ve Watson (1998), Chen vd. (2001) ve Nakamura (2005) enflasyon oranının belirlenmesinde ileri beslemeli yapay sinir ađlarını kullandıkları görülmüştür (Erilli, Eğrioglu, vd., 2010:43). Malliaris ve Salchenberger (1996) gelecek volatilité deđerlerinin öngörüsünde, Kim, Hwang, vd., (2004 a), Kim, Oh, vd., (2004 b) finansal kriz modellemesinde, Yıldız (2001), Benli (2002) ve Benli (2005) finansal başarısızlığı öngörmeye, Phua, Ming, vd., (2000), Tektaş ve Karataş (2004), Cao, Leggio vd., (2005), Samanta ve Bordoloi (2005), Huang, Lai, vd., (2007), Avcı ve Çinko (2008) döviz kurunun ve hisse senedi piyasa endeksinin tahmininde, Erilli, Eğrioglu, vd., (2010) enflasyon öngörüsünde yapay sinir ađları ile başarılı sonuçlar elde etmişlerdir. Türkiye’de özellikle İMKB endeks deđerinin öngörüsü üzerine yapılmış çok sayıda çalışma bulunmaktadır (Diler (2003), Altay ve Satman (2005), Karaatlı, Güngör, vd., (2005), Avcı (2007), Hamzaçebi ve Bayramođlu (2007), Akel ve Bayramođlu (2008), Kutlu ve Badur (2009), Ulusoy (2010)).

Bu çalışmada Avrupa Birliği üyesi ondört ülkenin (Almanya, Avusturya, Belçika, Danimarka, Finlandiya, Fransa, Hollanda, İngiltere, İrlanda, İspanya, İsveç, İtalya, Portekiz ve Yunanistan), hisse senedi borsa endeks değerlerinin incelenmesi ve öngörüsü amaçlanmıştır. Öngörü için esnek modelleme yapısı nedeniyle yapay sinir ağları analizi kullanılmıştır. Ülkelerin endeks değerleri, gelişmiş ve gelişmekte olan 49 ülkeye ilişkin hisse senedi performanslarını izleyen bir endeks olan Morgan Stanley Capital International (MSCI) endeksinin aylık değerleridir.

Çalışmanın ilk bölümünde yapay sinir ağları açıklanarak yapay sinir ağlarının zaman serilerinde öngörü için kullanımı ele alınmıştır. İkinci bölümde uygulama yapılmış ve elde edilen bulgular sonuç bölümünde tartışılmıştır.

## **1) YAPAY SİNİR AĞLARI İLE ZAMAN SERİLERİNDE ÖNGÖRÜ**

### **A) Yapay Sinir Ağları**

Yapay sinir ağları, insan beyninin özelliklerinden olan öğrenme yolu ile yeni bilgiler türetebilme ve keşfedebilme gibi yetenekleri herhangi bir yardım almadan kendiliğinden gerçekleştirmek amacı ile biyolojik sinir ağlarından esinlenilerek geliştirilen bilgisayar sistemleri olarak bilinmektedir (Fausett, 1994:3; Öztemel, 2003:30). Birbirleriyle bağlantılı çok sayıda basit sinirin oluşturduğu bir model olan yapay sinir ağlarında ağı oluşturan sinirler beynin yapısını taklit ederek matematiksel hesaplamalar yapabilmektedir. Bu hesaplamalar sistemin en temel elemanı olan nöronlar (sinirler) ve nöronların birbirleriyle olan bağlantıları yardımıyla gerçekleşmektedir. Sinir ağları birbirleriyle yüksek bağlantıya sahip bu nöronlardan oluşmaktadır.

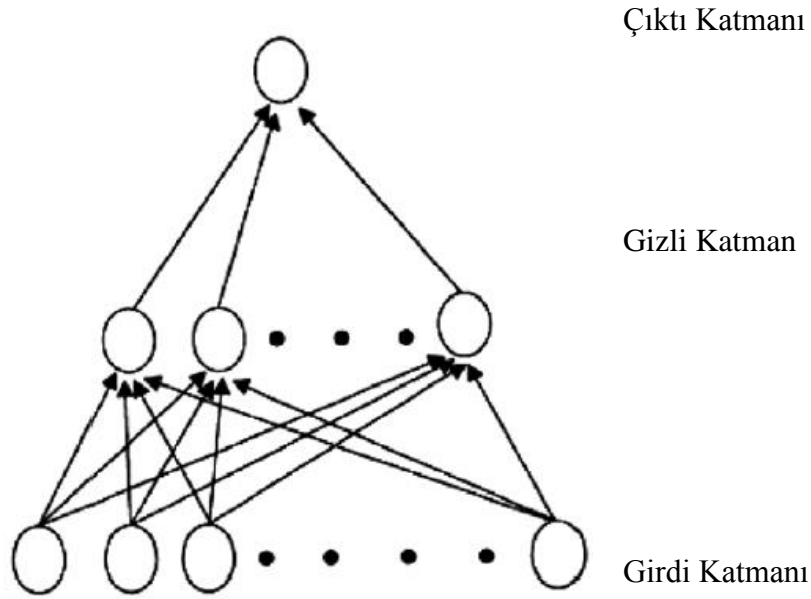
Bir yapay sinir ağı modeli oluşturulurken dikkate alınması gereken unsurlar aşağıda beş grup altında incelenmiştir:

#### *1) Ağın Mimari Yapısı*

Yapay sinir ađı modeli genel olarak giriş katmanı, gizli katman ve çıktı katmanı olmak üzere üç katmandan oluşmaktadır. Aşađıda Şekil 1’de Yapay sinir ađı modeli gösterilmiştir. Bir ađın oluştuđu katman sayısı ve bu katmanlarda yer alacak nöron sayıları ađın mimarisini verir.

### 2) Aktivasyon Fonksiyonu

Ađın çıktı deđeri, girdilerin ađırlıklandırılmış toplamının bir aktivasyon fonksiyonundan geçmesi ile hesaplanmaktadır. Aktivasyon fonksiyonunun seçimi oldukça önemlidir. Yaygın olarak kullanılan fonksiyon tipleri, doğrusal, rampa, eşik ve sigmoid fonksiyonlarıdır (Güneri ve Apaydın, 2004:174).



**Şekil 1:**

**Yapay Sinir Ađı Modeli** (Erilli, Eğriođlu, vd., 2010:45).

### 3) Ađın İşleyiş Biçimi

Ađdaki bilginin iletim yönünü gösteren işleyiş biçimi ileri beslemeli ve geri beslemeli olmak üzere ikiye ayrılır. İleri beslemeli yapay sinir ađlarında nöronlar arasındaki bağlantılar sadece tek bir yönde, ileri doğru giderler. Geri beslemeli ađlarda ise bir katman üzerinde yer alan nöronlar, kendisinden, katmandaki diđer nöronlardan ya da diđer katmanlardaki nöronlardan sinyal alabilmektedir (Elmas, 2003:63; Güneri ve Apaydın, 2004:175).

### 4) Öğrenme Süreci

Yapay sinir ağlarında öğrenme süreci, ağdaki bağlantıların ağırlıklarının ayarlanması ile çıktıların elde edilmesini sağlar. Öğrenme için kullanılan algoritmalar danışmanlı ve danışmansız olarak ikiye ayrılmaktadır. Danışmansız öğrenmede, hedeflenen çıktı değerleri verilmeden ağırlıklar ağ tarafından kendiliğinden ayarlanmaktadır. Danışmanlı öğrenmede ise hedef çıktı değerleri ağa bilgi olarak yüklenmekte ve ağırlıklar hedef çıktı ile ağ çıktısı arasındaki fark en küçük olacak biçimde ayarlanmaktadır. Danışmanlı öğrenmeyi kullanan sinir ağları için en yaygın olan öğrenme algoritması geri yayılım algoritmasıdır (Güneri ve Apaydın, 2004:175).

### 5) Performans Ölçütü

Bir yapay sinir ağı modelinden elde edilen çıktıların öğrenmeyi ne kadar iyi gerçekleştirdiğini belirlemek için performans ölçütlerinden yararlanılmaktadır. Hata kareler ortalaması, hata kareler ortalamasının karekökü, normalleştirilmiş hata kareler ortalaması, mutlak hata ortalaması ve ortalama mutlak hata yüzdesi en çok kullanılan ölçütlerdendir (Günay, Eğrioğlu, vd., 2007:131).

## B) Zaman Serileri Analizinde Yapay Sinir Ağlarının Uygulanışı

Zaman serilerinde en yaygın kullanılan yapay sinir ağı türü üç tabaklı ileri beslemeli modeldir. Öğrenim algoritması olarak danışmanlı öğrenim algoritmalarından geri yayılım algoritması tercih edilmektedir. Tek değişkenli zaman serileri için ağın girdileri geçmiş veya gecikmeli değişkenler, çıktısı ise öngörü değeridir (Eğrioğlu ve Aladağ 2005:2).

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

*Adım 1.* Verinin ön işlenmesi

İlk olarak veriler,

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

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

*Adım 2.* Veri organizasyonu

Bu adımda verilerin eğitim, geçerlilik ve test seti olmak üzere üç sete ayrılma işlemi gerçekleştirilir. Bu setlerin veri setinin yüzde kaç olacağı tespit edilir.

#### *Adım 3. Modelleme*

Modellemede, uygulamada kullanılacak olan yapay sinir ađı modeli oluşturulur. Model oluşturulurken, ađın mimarisi, aktivasyon fonksiyonu, işleyiş biçimi, öğrenme algoritması, öğrenme algoritmasına ilişkin parametreler ve performans ölçütü belirlenir.

Yapay sinir ađlarının girdi deđerlerini gecikmeli zaman serileri oluşturmaktadır.  $X_t$  zaman serisi için girdi deđerleri oluşturulurken, girdi tabakasındaki nöron sayısı  $m$  olmak üzere,  $m$  tane gecikmeli zaman serisi  $X_{t-1}, X_{t-2}, \dots, X_{t-m}$  biçiminde oluşturulur.

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

#### *Adım 4. En iyi ađrlık deđerlerinin hesaplanması*

Adım 3'te seçilen öğrenme algoritmasının eğitim seti üzerinde uygulanması ile en iyi ađrlık deđerleri bulunur. Bu deđerlerin kullanılması ile modelin çıktı deđerleri hesaplanır.

#### *Adım 5. Performans ölçütünün hesaplanması*

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

#### *Adım 6. Öngörü*

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

## **II) AVRUPA BİRLİĐİ ÜYESİ ÜLKELERİN HİSSE SENEDİ BORSA ENDEKSLERİNİN ÖNGÖRÜSÜ**

Uygulama için kullanılan veriler Avrupa Birliđi üyesi ülkelerinden Almanya, Avusturya, Belçika, Danimarka, Finlandiya, Fransa, Hollanda, İngiltere, İrlanda, İspanya,

İsveç, İtalya, Portekiz ve Yunanistan ülkelerinin Morgan Stanley Capital International (MSCI) borsa endeks değerlerinin aylık verileridir. Veriler MSCI'nin resmi web sitesinden alınmıştır.

Bu ülkelerden Almanya, Belçika, Fransa, Hollanda ve İtalya Avrupa Birliğinin kurucu üyelerinden olup, diğerleri 1995 yılına kadar Birliğe katılan ülkelerdir. Kurucu üyelerden sonra Avrupa Birliğine 1972'de üye olan üç ülke Danimarka, İngiltere ve İrlanda'dır. Yunanistan'ın birliğe girişi 1981'de ve İspanya ile Portekiz'in girişleri ise 1986'dadır. Bu çalışmada ele alınan ülkeler arasında son olarak, 1995'te Avusturya, Finlandiya ve İsveç Birliğe üye olmuştur.

Her ne kadar Lüksemburg da kurucu üyelerden olsa da analize dahil edilememiştir çünkü; MSCI veri tabanında bu ülke yer almamaktadır. Verilerde uyumun sağlanması amacıyla Lüksemburg verilerinin başka bir kaynaktan sağlanması da tercih edilmemiştir. Çalışmada 1995 sonrası Birliğe dâhil olan ülkeler de yer almamaktadır. Bunun iki temel sebebi bulunmaktadır. Birincisi bu ülkeler için veri setlerinin çok sağlıklı olmaması, ikincisi bu ülke borsalarının çalışmada yer alan diğer borsalar kadar gelişmiş olmamalarıdır. Böylece çalışmada toplam on dört ülke yer almıştır.

Almanya, Avusturya, Belçika, Danimarka, Fransa, Hollanda, İngiltere, İspanya, İsveç ve İtalya ülkeleri için veriler 1969 yılına kadar gitmekte, Finlandiya için 31 Aralık 1981'den, Yunanistan, İrlanda ve Portekiz için 31 Aralık 1987'den başlamaktadır. Verilerde homojenliğin sağlanması açısından analiz, 31 Aralık 1987 den başlatılmıştır. Verilerin son dönemi 31 Ekim 2013'tür.

Yapay sinir ağları ile zaman serisi uygulaması birinci bölümde verilen algoritma ile gerçekleştirilmiştir. Analiz için Neural Connection paket programı kullanılmıştır. Algoritma adımları aşağıdaki gibidir:

*Adım 1.* İlk önce veriler (1) eşitliği ile  $[0,1]$  aralığına dönüştürülmüştür.

*Adım 2.* Veri kümesi literatürde yer alan çalışmalardaki deneyimlerden yararlanılarak eğitim, geçerlilik ve test seti olmak üzere üç sete ayrılmıştır. Buna göre ilk %80'lik kısmı eğitim, sonraki %10'u geçerlilik ve son %10'luk kısmı ise test seti olarak belirlenmiştir.

*Adım 3.* Model tek girdi tabakası, tek gizli tabaka ve tek çıktı tabakasından oluşan ileri beslemeli bir ağıdır. Aktivasyon fonksiyonu sigmoid fonksiyonu olarak seçilmiştir. Öğrenme



algoritması geri yayılım algoritmasıdır ve öğrenme oranı 0,9'dur. Performans ölçütü olarak bir öngörü yönteminin doğruluđunu test etmede kullanılan Hata Kareler Ortalamasının Karekökü (HKOK) ve Mutlak Hata Ortalaması (MHO) deđerlerine bakılmıřtır. HKOK yöntemi büyük hatalara küçük hatalara oranla daha fazla önem verdiđinden, büyük hata deđerlerinin önemli olduđu durumlarda tercih edilen bir hata türüdür. MHO yöntemi de özellikle hata deđerlerinin toplamının önemli olduđu durumlarda kullanılmaktadır. Bu nedenle çalışmada her iki hata türü de kullanılmıřtır.

Bu adımda tabakalarda yer alacak nöron sayıları da tespit edilmektedir. Çıktı tabakasında bir nöron yer almaktadır. Çalışmada aylık veriler bulunduđundan 12 gecikmeli zaman serisinin kullanılması uygun bulunmuřtur. Buna göre girdi tabakasında yer alacak nöronların sayısı 12 olarak belirlenmiřtir. Gizli tabakadaki nöron sayısının seçimi için, nöron sayısının 1 ile 12 arasında deđiřtiđi 12 durum her bir ülke için deđerlendirilmiřtir. Uygulama yapılarak her bir ülke için kendi test kümelerinden elde edilen HKOK ve MHO deđerleri hesaplanmış ve minimum HKOK ve MHO deđerine sahip model mimari yapıyı oluřturmuřtur. Her bir ülke için oluřturulan mimari yapı ve test kümesinden hesaplanan minimum HKOK deđerleri Tablo 1'de verilmiřtir.

**Tablo 1:**

**Test Seti için Yapay Sinir Ađı Modelinden Hesaplanan Hata Deđerleri**

Ülke*	Mimari Yapı	HKOK	MHO
<i>Almanya</i>	12-12-1	0,059530	0,048226
<i>Avusturya</i>	12-1-1	0,030969	0,025470
<i>Belçika</i>	12-2-1	0,029172	0,024902
<i>Danimarka</i>	12-2-1	0,074011	0,062716
<i>Finlandiya</i>	12-1-1	0,026646	0,021433
<i>Fransa</i>	12-4-1	0,047619	0,040193
<i>Hollanda</i>	12-4-1	0,045495	0,038443
<i>İngiltere</i>	12-12-1	0,041319	0,033202
<i>İrlanda</i>	12-4-1	0,012467	0,010890
<i>İspanya</i>	12-3-1	0,047246	0,041025
<i>İsveç</i>	12-1-1	0,065560	0,052647
<i>İtalya</i>	12-1-1	0,042803	0,036908
<i>Portekiz</i>	12-1-1	0,037822	0,032125
<i>Yunanistan</i>	12-6-1	0,017977	0,011911

\*Ülkeler alfabetik sıra ile verilmiřtir.

Tablo 1’de görülen mimari yapıda, ilk değer girdi tabakasındaki nöron sayısı, ikinci değer gizli tabakadaki nöron sayısı, üçüncü değer ise çıktı tabakasındaki nöron sayısıdır. Örneğin Almanya için oluşturulan modelin mimari yapısı 12–12–1, girdi tabakasinda 12 nöron, gizli tabakada 12 nöron ve çıktı tabakasinda 1 nöron olduğunu göstermektedir.

*Adım 4.* Her bir ülke için oluşturulan mimari yapıya göre ağırlık eğitimi gerçekleştirilmiş ve en iyi ağırlık değerleri elde edilmiştir.

*Adım 5.* Her ülke için test kümesine ilişkin öngörüler elde edilmiştir. Performans ölçütü olan HKOK ve MHO değerleri Tablo 1’de görülmektedir.

*Adım 6.* Adım 4’te elde edilen en iyi ağırlık değerlerinin kullanılması ile her bir ülke için test setlerine ilişkin öngörüler hesaplanmıştır.

Test seti Mayıs 2011- Ekim 2013 dönemini kapsamaktadır. Son oniki aylık dönem (Kasım 2012- Ekim 2013) değerlerine ilişkin öngörüler Tablo 2’de verilmiştir.


**Tablo 2:**  
**Test Setinin Gerçek Değerleri ile**  
**Yapay Sinir Ağı Öngörü Değerleri (Kasım 2012- Ekim 2013)**

Ülke	Kasım 2012	Aralık 2012	Ocak 2013	Şubat 2013	Mart 2013	Nisan 2013	Mayıs 2013	Haziran 2013	Tem. 2013	Ağus. 2013	Eyl. 2013	Ekim 2013	
<i>Almanya</i>	<sup>a</sup>	0,6148	0,6453	0,6856	0,6531	0,6446	0,6677	0,6835	0,6486	0,7002	0,6782	0,7495	0,8005
	<sup>b</sup>	0,5772	0,6138	0,6475	0,6946	0,6689	0,6462	0,6709	0,6842	0,6596	0,6902	0,6752	0,7319
<i>Avusturya</i>	<sup>a</sup>	0,2077	0,2273	0,2429	0,2348	0,2096	0,2309	0,2232	0,1956	0,2188	0,2329	0,2557	0,2682
	<sup>b</sup>	0,2127	0,2267	0,2329	0,2233	0,1991	0,2305	0,2260	0,1963	0,1959	0,2208	0,2378	0,2603
<i>Belçika</i>	<sup>a</sup>	0,4066	0,4178	0,4362	0,4557	0,4714	0,4697	0,4581	0,4301	0,4799	0,4698	0,5140	0,5482
	<sup>b</sup>	0,3863	0,4231	0,4317	0,4442	0,4648	0,4871	0,4866	0,4698	0,4390	0,4901	0,4808	0,5194
<i>Danimarka</i>	<sup>a</sup>	0,8480	0,8701	0,9759	0,9441	0,8980	0,9335	0,8937	0,8574	0,9343	0,9382	0,9826	1,0000
	<sup>b</sup>	0,8204	0,8238	0,8301	0,8610	0,8833	0,8900	0,8996	0,8895	0,8731	0,8822	0,8866	0,8979
<i>Finlandiya</i>	<sup>a</sup>	0,2525	0,2650	0,2854	0,2789	0,2704	0,2801	0,2788	0,2656	0,2840	0,2899	0,3446	0,3692
	<sup>b</sup>	0,2334	0,2593	0,2735	0,2977	0,2848	0,2738	0,2893	0,2847	0,2694	0,2889	0,2941	0,3586
<i>Fransa</i>	<sup>a</sup>	0,5325	0,5550	0,5925	0,5683	0,5578	0,5959	0,6001	0,5633	0,6251	0,6085	0,6678	0,6997
	<sup>b</sup>	0,4993	0,5322	0,5558	0,5986	0,5750	0,5727	0,6080	0,6166	0,5813	0,6290	0,6169	0,6704
<i>Hollanda</i>	<sup>a</sup>	0,5835	0,6041	0,6659	0,6098	0,6214	0,6430	0,6617	0,6320	0,7106	0,6974	0,7466	0,7898
	<sup>b</sup>	0,5624	0,5824	0,6030	0,6732	0,6221	0,6347	0,6611	0,6760	0,6460	0,7143	0,7094	0,7391
<i>İngiltere</i>	<sup>a</sup>	0,5780	0,5948	0,6275	0,6013	0,6072	0,6315	0,6284	0,5785	0,6338	0,6234	0,6721	0,7034
	<sup>b</sup>	0,5691	0,5786	0,5886	0,6179	0,6055	0,6121	0,6442	0,6349	0,5941	0,6353	0,6269	0,6663
<i>İrlanda</i>	<sup>a</sup>	0,0447	0,0581	0,0690	0,0781	0,0859	0,0822	0,0811	0,0758	0,0949	0,1057	0,1187	0,1405
	<sup>b</sup>	0,0552	0,0473	0,0604	0,0706	0,0779	0,0891	0,0861	0,0827	0,0809	0,1009	0,1124	0,1282


İspanya	a	0,3575	0,3783	0,4073	0,3757	0,3454	0,3906	0,3750	0,3381	0,3956	0,3824	0,4560	0,5102
	b	0,3277	0,3374	0,3617	0,3842	0,3778	0,3638	0,4068	0,4016	0,3572	0,3981	0,3908	0,4562
İsveç	a	0,8140	0,8519	0,9279	0,9406	0,9325	0,9348	0,9222	0,8541	0,9580	0,9272	0,9969	0,9986
	b	0,7889	0,8184	0,8443	0,9878	0,9183	0,9163	0,9252	0,9056	0,8469	0,9035	0,8993	0,9514
İtalya	a	0,1959	0,2120	0,2534	0,1897	0,1666	0,2150	0,2146	0,1605	0,2032	0,2071	0,2389	0,2972
	b	0,1808	0,1995	0,2024	0,2520	0,1884	0,1673	0,2254	0,2167	0,1712	0,2032	0,2117	0,2374
Portekiz	a	0,1797	0,2203	0,2709	0,2262	0,2187	0,2709	0,2261	0,2013	0,2224	0,2275	0,2497	0,2526
	b	0,1804	0,1754	0,2190	0,2678	0,2311	0,2195	0,2732	0,2453	0,2141	0,2206	0,2266	0,2585
Yunanistan	a	0,0189	0,0209	0,0324	0,0356	0,0325	0,0326	0,0252	0,0204	0,0299	0,0344	0,0481	0,0660
	b	0,0174	0,0175	0,0235	0,0363	0,0406	0,0389	0,0398	0,0324	0,0259	0,0385	0,0431	0,0555

a: Gerçek deđerler, b: Öngörü deđerleri


Test setlerine iliřkin (Mayıs 2011- Ekim 2013) gerçek ve öngörü deđerlerini gösteren grafikler Őekil 2'dedir.




Almanya





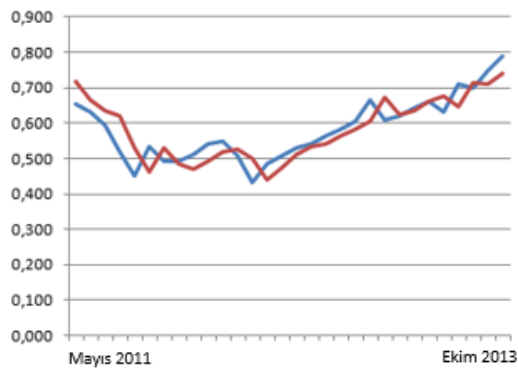


Avusturya




Belçika




Danimarka






İsveç



İtalya



Portekiz



Yunanistan

### Şekil 2:

#### Test Setlerine İlişkin Gerçek Deđerler ve Yapay Sinir Ađı Öngörü Deđerleri

( — gerçek, — öngörü)

### SONUÇ

Bu çalışmada Avrupa Birliđi üye ülkelerinin MSCI endeks deđerlerinin yapay sinir ađları ile öngörüsü amaçlanmıştır. Çalışma, Avrupa Birliđi üyesi on dört ülkenin MSCI borsa endekslerini aynı anda inceleme olanađı vermesi bakımından önem taşımaktadır.

Tablo 1’de yer alan HKOK ve MHO deđerleri incelenecek olursa maksimum hatanın Danimarka borsasından elde edildiđi görülebilir (HKOK=0,0740 MHO=0,0627). Bu durum Danimarka borsasına ilişkin grafikte de gözlenebilir (Şekil 2). Hata deđerinin büyüklüğü bakımından ikinci sırada ise İsveç borsası yer almaktadır (HKOK=0,0655 MHO=0,0526). Üçüncü sırada yer alan ülkenin Almanya olduđu görülmektedir (HKOK=0,0655

MHO=0,0526). Diğer tüm ülkelere ilişkin her iki hata değeri de %5' in altında yer almıştır. Tablo 2 ve Şekil 2' de görülebileceği gibi çalışmada yapay sinir ağları ile başarılı öngörüler elde edildiği söylenebilir.

Bu çalışmada öngörü için yapay sinir ağları tercih edilmiştir. Gelecek çalışmalarda bu yönteme alternatif olarak, endeks öngörüsü için son yıllarda kullanılmaya başlanan, yapay sinir ağları ile birleştirilmiş melez tekniklerin kullanılması önerilebilir. Ayrıca bulanık yöntemlerle yapılacak analizlerin de başarılı sonuçlar verebileceği düşünülmektedir. Bunların yanı sıra modelden elde edilen öngörülerin yatırımcıların karlarını maksimize edebilmesinde nasıl değerlendirilebileceği üzerinde de çalışmalar yapılabilir. Çalışmada incelenen Avrupa Birliği üye ülkelerine ilişkin borsa endekslerine ek olarak Amerika ve Asya borsaları da incelenerek dünya ekonomisindeki etkileşimler izlenebilir.

### KAYNAKÇA

- AKEL, Veli ve BAYRAMOĞLU, Mehmet F. (2008), “Kriz Dönemlerinde Yapay Sinir Ağları İle Finansal Öngöründe Bulunma: İMKB 100 Endeksi Örneği”, International Symposium On International Capital Flows And Emerging Markets, Balıkesir, Bandırma, 24-27 Nisan 2008.
- ALTAY, Erdinç ve SATMAN, M. Hakan (2005), “Stock Market Forecasting: Artificial Neural Networks and Linear Regression Comparison in An Emerging Market”, *Journal of Financial Management and Analysis*, 18 (2), pp. 18-33.
- AVCI, Emin (2007), “Forecasting Daily And Sessional Returns of The Ise-100 Index With Neural Network Models”, *Doğuş Üniversitesi Dergisi*, 8 (2), ss. 128-142.
- AVCI, Emin ve ÇİNKO, Murat (2008), “Endeks Getirilerinin Yapay Sinir Ağları Modelleri ile Tahmin Edilmesi: Gelişmekte Olan Avrupa Borsaları Uygulaması”, *İktisat, İşletme ve Finans Dergisi*, 23 (266), ss. 114-137.
- BENLİ, Yasemin K. (2002), “Finansal Başarısızlığın Tahmininde Yapay Sinir Ağı Kullanımı ve İMKB’de Uygulama”, *Muhasebe Bilim Dünyası Dergisi*, 4(4), ss. 17-30.
- BENLİ, Yasemin K. (2005), “Bankalarda Mali Başarısızlığın Öngörülmesi Lojistik Regresyon ve Yapay Sinir Ağı Karşılaştırması”, *Gazi Üniversitesi Endüstriyel Sanatlar Eğitim Fakültesi Dergisi*, 16, ss. 31-46.
- CAO, Qing., LEGGIO, Karyl B., SCHNIEDERJANS, Marc J. (2005), “A Comparison Between Fama And French’s Model and Artificial Neural Networks in Predicting the Chinese Stock Market”, *Computers and Operations Research*, 32(10), pp. 2499-2512.

- DİLER, Ali İ. (2003), “İMKB Ulusal 100 Endeksinin Yönünün Yapay Sinir Ađları: Hata Geriye Yayma Yöntemi ile Tahmin Edilmesi”, *İMKB Dergisi*, 7(25-26), ss. 66–81.
- EĐRİOĐLU, Erol ve ALADAĐ, Ç.Hakan (2005), “Yapay Sinir Ađları ve Arıma Modellerin Melez Yaklaşımı ile Zaman Serilerinde Öngörü”, VII. Ulusal Ekonometri ve İstatistik Sempozyumu, İstanbul Üniversitesi, İstanbul, 26-27 Mayıs 2005.
- ELMAS, Çetin (2003), *Yapay Sinir Ađları (Kuram, Mimari, Eđitim, Uygulama)*. Seçkin Yayınları, Ankara.
- ERİLLİ, N.Alp., EĐRİOĐLU, Erol., YOLCU, Ufuk., ALADAĐ, Ç.Hakan., USLU, V.Rezan (2010), “Türkiye’de Enflasyonun İleri ve Geri Beslemeli Yapay Sinir Ađlarının Melez Yaklaşımı ile Öngörüsü”, *Dođuş Üniversitesi Dergisi*, 11 (1), ss. 42-55.
- FAUSETT, Laurene V. (1994), *Fundamentals of Neural Networks: Architectures, Algorithms and Applications*, Prentice Hall, USA.
- GÜNAY, Süleyman., EĐRİOĐLU, Erol., ALADAĐ, Ç. Hakan (2007), *Tek Deđerışkenli Zaman Serileri Analizine Giriş*, Hacettepe Üniversitesi Yayınları, Ankara.
- GÜNERİ, Nuray ve APAYDIN, Ayşen (2004), “Öğrenci Başarılarının Sınıflandırılmasında Lojistik Regresyon Analizi ve Sinir Ađları Yaklaşımı”, *Ticaret ve Turizm Eđitim Fakültesi Dergisi*, 2004(1), ss. 170 -188.
- HAMZAÇEBİ, Coşkun ve BAYRAMOĐLU, Mehmet F. (2007), “Yapay Sinir Ađları ile İMKB 100 Endeksinin Tahmini”, YAEM 27.Ulusal Kongresi, Dokuz Eylül Üniversitesi Mühendislik Fakültesi Endüstri Mühendisliđi Bölümü ve Yöneylem Araştırması Derneđi, İzmir, 2-4 Temmuz 2007.
- HUANG, Wei., LAI, King K., NAKAMORI, Yoshiteru., WANG, Shouyang., YU, Lean (2007), “Neural Networks in Finance and Economics Forecasting”, *International Journal of Information Technology & Decision Making*, 6 (1), pp. 113–140.
- KARAATLI, Meltem., GÜNGÖR, İbrahim., DEMİR, Yusuf., KALAYCI, Şeref (2005), “Hisse Senedi Fiyat Hareketlerinin Yapay Sinir Ađları Yöntemi ile Tahmin Edilmesi”, *Balıkesir Üniversitesi Bandırma İİBF, Akademik Fener Dergisi*, 2(1), ss. 22–48.
- KIM, Tae Yoon., HWANG, Changha., LEE, Jongkyu (2004 a), “Korean Economic Condition Indicator Using a Neural Network Trained on the 1997 Crisis”, *Journal of Data Science*, 2(4), pp. 371–381.
- KIM, Tae Yoon., OH, Kyong Joo., SOHN, Insuk., HWANG, Changha (2004 b), “Usefulness of Artificial Neural Networks for Early Warning System of Economic Crisis”, *Expert Systems With Applications*, 26(4), pp. 583-590.

- KURUP, Pradeep U. and DUDANI, Nitin K. (2002), “Neural Networks For Profiling Stress History of Clays From PCPT Data”, *Journal of Geotechnical and Geoenvironmental Engineering*, July 2002, 128(7), pp. 569-580.
- KUTLU, Birgül ve BADUR, Bertan (2009), “Yapay Sinir Ağları İle Borsa Endeksi Tahmini”, *Yönetim*, 20(63), ss. 25-40.
- MALLIARIS, Mary and SALCHENBERGER, Linda (1996), “Using Neural Networks to Forecast The S&P100 Implied Volatility”, *Neurocomputing*, 10(2), pp. 183-195.
- METİN, Kıvılcım (1999), “İstanbul Menkul Kıymetler Borsası Endeksi'ni Belirleyen Makro Büyüklükler ve Etkin Piyasalar Varsayımı”, *Ekonomik Yaklaşım*, 10(34), ss. 89-94
- ÖZTEMEL, Ercan (2003), *Yapay Sinir Ağları*, Papatya Yayınları, İstanbul.
- PHUA, Paul Kang H., MING, Daohua., LIN, Weidong (2000), “Neural Network With Genetic Algorithms for Stocks Prediction”, Fifth Conference of the Association of Asian-Pacific Operations Research Societies Proceedings, Singapore, 5th -7th July 2000.
- TEKTAŞ, Arzu ve KARATAŞ, Abdülmecit (2004), “Yapay Sinir Ağları ve Finans Alanına Uygulanması: Hisse Senedi Fiyat Tahminlemesi”, *Atatürk Üniversitesi İktisadi ve İdari Bilimler Dergisi*, 18(3-4), ss. 337-349.
- SAMANTA, G.P and BORDOLOI, Sanjip (2005), “Predicting Stock Market- an Application of Artificial Neural Network Technique Through Genetic Algorithm”, *Finance India*, 19(1), pp. 173-188.
- ULUSOY, Tolga (2010), “İMKB Endeks Öngörüsü İçin İleri Beslemeli Ağ Mimarisine Sahip Yapay Sinir Ağı Modellemesi”, *Uluslararası İktisadi ve İdari İncelemeler Dergisi*, 2(5), ss. 21-40.
- YILDIZ, Birol (2001), “Finansal Başarısızlığın Öngörülmesinde Yapay Sinir Ağı Kullanımı ve Halka Açık Şirketlerde Ampirik Bir Uygulama”, *İMKB Dergisi*, 17, ss. 51-67.