

Yapay Sinir Ağları Ve Regresyon Modelleri İle Bist Ulusal -100 Endeksinin Tahmini

Forecasting Bist National-100 Index By Using Artificial Neural Network And Regression Models

Dr. Görkem SARIKAYA*

Öz:

Ülkemizde içinde bulunduğu siyasi ve politik riskler, Türkiye gibi gelişmekte olan ülkelerin ekonomisini ciddi ölçüde etkilemekte ve spekülasyon hareketlerin yaşanmasına neden olmaktadır. Bu durum borsalarda ve hisse senedi fiyatlarında ani iniş ve çıkışların olmasına sebep olmaktadır. Türkiye gibi gelişmekte olan piyasalarda hisse senedi fiyatlarının tahmin edilmesi oldukça güçtür. Yapılan öngörüler her zaman gerçekleşen değerleri güvenilir bir şekilde temsil edemeyebilir. Bu belirsizliği olabildiğince en aza indirmek için finansal analizciler, farklı modeller kullanarak analizler yapmaktadırlar. Günümüzde yapay sinir ağları modeli her alanda kullanılmaya başlandığı gibi finans alanında da oldukça sık kullanılmaya başlanmıştır. Bu çalışmada amaç yapay sinir ağları ve regresyon modeli ile BİST Ulusal-100 endeksinin tahmin edilmesidir. Çalışmanın başında doğrusal, logaritmik ve kübik regresyon modelleri oluşturularak hangi yöntemin performansının daha iyi ve hangi yöntemin daha üstün olduğu hata kareler ortalamasının kare kökü ile bulunmuştur. Bu doğrultuda BİST Ulusal-100 endeksinin 2005 ile 2012 yılları arasındaki kapanış fiyatları kullanılarak, 2013 yılı BİST Ulusal-100 endeksi kapanış değerleri tahmin edilmiştir. Analizde öncelikle regresyon modeli daha sonra da yapay sinir ağları modeli ile öngörülerde bulunulmuştur. Çıkan sonuçlar 2013 yılı gerçekleşen BİST Ulusal-100 endeksi kapanış fiyatları ile karşılaştırılmış-

* Ankara, gorkemsarikaya86@gmail.com, <https://orcid.org/0000-0002-1003-8972>

tır. Çalışmanın sonunda hangi yöntemin daha üstün ve hangi yöntemin 2013 yılı BİST Ulusal-100 endeksine daha yakın bir tahminde bulunduğu belirlenmiştir.

Anahtar sözcükler: yapay sinir ağları, regresyon, hisse senedi piyasası, tahmin

Abstract:

Developing countries' economies have always been impacted by political and other speculative risks. Since Turkey is one of the developing countries, its stock exchange experiences significant increases and decreases in stock prices. Due to the discussed significant changes, it is difficult to identify a method that is always reliable on forecasting stock prices. Predictions that are made may not always represent the actual values. To minimize this uncertainty, financial analysts use different financial models. Nowadays, artificial neural network model is introduced in different areas. So that it has been also favoured by most of the financial analyst in the field of finance. At the beginning of the study, linear, logarithmic and cubic regression models were created and which method had better performance and which method was superior was found by the square root of mean error squares. This study aimed to find a reliable method to forecast Bist National-100 Index's closing values. Stock value data from 2005 to 2012 were used to estimate 2013 year end closing values. Regression and artificial neural network models were used to predict 2013 stock values. The results were compared with 2013 year end actuals. Based on the magnitude of the variances to the actual results, one of the methods was identified as a more reliable model to forecast future stock values.

Key words: artificial neural network, regression, stock market, forecast

Giriş:

Finansal ve ekonomik piyasalarda öngörü kavramı gün geçtikçe önemini artırmaktadır. Kişiler, şirketler ve hatta ülkeler gelecekleri ile ilgili plan yapmak için öngörülerde bulunmaları gerekmektedir. Özellikle kurumsallaşma kavramı dünyada yaygınlaştıkça, bütçeleme, planlama ve organizasyon sistemi gelişmektedir. Bu doğrultuda öngörü yapmak, hedeflerin daha doğru bir şekilde tahmin edileceği ve getirilerin daha yüksek elde edileceği gerçeğini ortaya koymuştur.

Gelecek ile ilgili öngörülerde bulunurken farklı modeller kullanılmıştır. Öngöründe bulunabilmek için yapılan analizler, genellikle regresyon analizi ile yapılmaktaydı. Ancak yıllar geçtikçe ve teknoloji ilerledikçe bu alanda daha kapsamlı analizler ve daha gerçekçi tahminler yapılmaya başlanmıştır.

Daha önceki yıllarda yapılan öngörü modellerinde genelde veri seti olarak zaman serileri ve analiz yöntemi olarak da basit regresyon modelleri kullanılmaktaydı. Ancak ülkelerde yaşanan siyasi ve politik riskler bu yöntemlerle, öngöründe bulunmayı zorlaştırmaktadır; çünkü günümüzde olduğu gibi yıllar öncesinde de finansal alandaki tüm çalışmalar siyasi ve politik risklerden etkilenmekteydi. Bu yüzden finansal analizciler öngörülerinin, gerçeğe daha yakın olması için yeni analiz teknikleri denemeye başlamışlardır. Geçmişte yaşanan olaylardan etkilenen ve gelecekte oluşabilecek riskleri daha fazla dikkate alan, daha karmaşık ama daha iyi bir öngöründe bulunan, yapay sinir ağları modeli, günümüzde finansal alanda oldukça sık kullanılmaya başlanmıştır.

Yapay sinir ağlarının en belirgin ve dikkat çeken özelliği, insan beyninin çalışma prensibini simüle etmeye çalışmasıdır (Karaatlı vd,2005;38). Diğer yöntemler ile karşılaştırıldığında, yapay sinir ağları modelinin bu özelliği, diğer yöntemlere göre en belirgin farkıdır. Yapay sinir ağları insan beyni gibi deneyimler yoluyla öğrenirler ve karmaşık hesaplamalara dayanan sorunlara çözüm getirirler (Karaatlı vd 2005:38). İnsan beyni gibi deneyimler sonucu çalışması, yapay sinir ağı modellerinde yapılan analizlerin daha az hata payına sahip olabileceği söylenebilir.

Bu çalışmada ekonomik ve siyasi alanda oluşabilecek her türlü belirsizlikten kolayca etkilenebilen ve ekonomik alanda bir gösterge niteliğinde olan BİST Ulusal-100 endeksi tahmin edilmiştir. Öngöründe bulunurken öncelikle temel öngörü modeli olan çoklu regresyon modeli ile öngöründe bulunulmuştur. Daha sonra,son yıllarda finansal alanda çok sık kullanılmaya başlanılan yapay sinir ağ modeli oluşturulup, 2013 BİST Ulusal-100 endeksi tahmin edilmiştir. Elde edilen sonuçlar karşılaştırılıp hangi modelin gerçekleşen değerlere daha yakın ve daha anlamlı olduğuna karar verilmiştir. BİST Ulusal-100 endeksini daha iyi tahmin eden modelin üstünlükleri ve başarısız yönleri belirlenmiştir.

Genel Kavramlar

Regresyon

Literatür

Regresyon yöntemi ilk olarak 1805 yılında Adrien Marie Legendre tarafından ortaya atılmıştır ve ilk uygulanış şekli en küçük kareler prensibidir. 1809 yılında da C.F. Gauss ise aynı yöntemi kendisinin 1795 yılından beri kullandığını idda etmiştir (Gauss1809). Regresyon terimi 19. yüzyılda İngiliz istatistikçisi Francis Galton tarafından bir biyolojik inceleme için ortaya atılmıştır. Bu incelemenin ana konusu kalıtım olup, aile içinde baba ve annenin boyu ile çocukların boyu arasındaki ilişkiyi araştırmakta ve çocukların boylarının bir nesil içinde eski ata nesillerinin ortalamasına geri döndüklerini yani bir nesil içinde ortalamaya geri dönüş olduğu söylemektedir (Galton 1877:492-495). Galton geri dönüş terimi için ilk yazısında İngilizce olarak “reversion” terimi kullanmışsa da sonradan aynı anlamda olan “regression” sözcüğü kullanmıştır (Galton 1877:492-495). Bu çalışmalarında Galton istatistiksel “regresyon” kavramını ve yöntemini de geliştirmiştir. Udney Yule ve Karl Pearson bu yöntemi daha geniş genel istatistiksel alanlara uygulayıp geliştirmişlerdir (Yule 1897: 812). Bu dönemde bağımlı ve bağımsız değişkenlerin normal dağılım gösterdiği varsayılmaktadır. Bu kısıtlayıcı varsayım R.A. Fisher’ın 1922 ve 1925de yaptığı yayınlar ile, sadece bağımlı değişkenin koşullu dağılımının normal olduğu hallere uygulanmak üzere daha genişletilmiştir (Fisher 1922:598).

Regresyon Analizi

Regresyon analizi; aralarında sebep-sonuç ilişkisi bulunan iki veya daha fazla değişken arasındaki ilişkiyi belirlemek ve bu ilişkiyi kullanarak o konu ile ilgili tahminler ya da kestirimler yapabilmek amacıyla yapılır (Şenesen 2008). Basit, doğrusal regresyon analizinde iki değişken arasında doğrusal bir ilişki olduğu kabul edilir. Çoklu regresyon analizinde ise ikiden daha fazla sayıda değişken arasında doğrusal bir ilişki bulunduğu kabul edilir. Eğer iki ya da daha fazla sayıda değişken arasında doğrusal olmayan ve biçimi önceden seçilen bir denklemle ifade edilen bir ilişki varlığı kabul ediliyor ise o zaman doğrusal olmayan regresyon analizi uygulanır (Goncaloğlu 2012).

Basit Doğrusal Regresyon Denklemi;

$$y = \alpha + \beta X + \epsilon_i \quad (1)$$

Şeklinde bir bağımlı ve bir de bağımsız değişken içeren bir modeldir. Burada;

y; bağımlı (sonuç) değişken olup belli bir hataya sahip olduğu varsayılır.

x; bağımsız (sebep) değişkeni olup hatasız ölçüldüğü varsayılır.

α ; sabit olup $x=0$ olduğunda y 'nin aldığı değerdir.

β ; regresyon katsayısı olup, x 'in kendi birimi cinsinden 1 birim değişmesine kar-

şılık y' de kendi birimi cinsinden meydana gelecek değişme miktarını ifade eder.

ϵ ; tesadüfi hata terimi olup ortalaması sıfır varyansı σ^2 olan normal dağılım gösterdiği varsayılır. Bu varsayımlar parametre tahmini için değil, katsayıların önem kontrolleri için gereklidir.

Bir regresyon modeli oluşturulurken genelde en-küçük kareler ve en-çok olabirlik teknikleri olarak bilinen iki yaklaşımdan birisi kullanılır (Goncaloğlu 2012). Eğer hata teriminin normal dağılım göstermesi şeklinde bir varsayım varsa en-çok olabirlik, hata teriminin dağılışı ile ilgili herhangi bir varsayım söz konusu değil ise en-küçük kareler tekniği kullanılarak parametreler tahmin edilir (Goncaloğlu 2012).

Çoklu (Multiple) Regresyon Analizi Denklemi;

$$y = \alpha + \beta_1 X_1 + \beta_2 X_2 + \beta_3 X_3 + \dots + \beta_p X_p + \epsilon_i \quad (2)$$

Şeklinde bir bağımlı ve p tane bağımsız değişken içeren bir modeldir. Burada; y ; bağımlı (sonuç) değişken olup belli bir hataya sahip olduğu varsayılır.

X_p ; bağımsız (sebepl) değişkeni olup hatasız ölçüldüğü varsayılır.

α ; sabit olup $x=0$ olduğunda y 'nin aldığı değerdir.

β ; regresyon katsayısı olup, x 'in kendi birimi cinsinden 1 birim değişmesine karşılık y' de kendi birimi cinsinden meydana gelecek değişme miktarını ifade eder.

ϵ ; tesadüfi hata terimi olup ortalaması sıfır varyansı σ^2 olan normal dağılım gösterdiği varsayılır.

Doğrusal olmayan regresyon analizinde değişkenler seçildikten sonra regresyon bağıntısının biçimine karar verilir (Goncaloğlu 2012). Ancak $f(X_1, X_2, \dots)$ fonksiyonunun doğrusal olmaması halinde regresyon katsayıları için varılacak denklemler de doğrusal olmayacağından çözülmesi genellikle zor olur. Bu yüzden uygun bir dönüşümle doğrusal regresyon haline çevirmek büyük kolaylık sağlamaktadır (Goncaloğlu 2012).

Zamana bağlı serilere regresyon modeli uygulanırken çeşitli dönüşümler kullanılabilir. Zaman serileri regresyon analizinde bağımsız değişken olarak "zaman" ele alınmaktadır. Başka bir deyişle, ilgilenilen zaman serisi zaman terimi (trend) ile açıklanmaya çalışılır (Kadılar 2005:96).

Aşağıdaki modeller zaman serilerinde dönüşüm yapmak için kullanılabilirler. Bu yöntemlerden hata kareler ortalaması karekökü en küçük olan model kullanılarak analize devam edilir (Kadılar 2005:96).

- Birinci Farklar Regresyon Modeli,
- Üstel Regresyon Modeli,
- Karesel Regresyon Modeli,

- Lojistik Regresyon Modeli,
- Kübik Regresyon Modeli,
- Logaritmik Regresyon Modeli,
- Diğer Regresyon Modelleri.

Yapay Sinir Ağları

Literatür

İlk yapay nöron, 1943 yılında nöropsikiyatrist Warren McCulloch ve bilim adamı Walter Pitts tarafından üretilmiştir. Bu dönemlerde teknolojinin çok fazla gelişmemiş olması ve kısıtlı olanaklardan dolayı yapay sinir ağları modeli çok fazla gelişmemiştir. 1969 yılında Minsky ve Papert bir kitap yayınlamaya, yapay sinir ağları alanında duyulan etik kaygıları da ortadan kaldırmış ve bu yeni teknolojiyi gündeme getirmiştir (Pekel 2008). Ancak yapay sinir ağlarında ilk ciddi gelişme 1990 yıllarda başlamıştır.

Yapay sinir ağlarını finansal anlamda ilk kullanan Kimoto ve arkadaşları olmuştur. Çalışmalarında Tokya Borsa endeksini tahmin etmişlerdir (Karaatlı vd 2005:38).

1997 yılında Ramon Lawrence “Using Neural Networks to Forecast Stock Market Prices” adlı makalesinde yapay sinir ağları ile etkin piyasalar hipotezini ve yapay sinir ağlarının istatistik ve diğer yöntemlere göre fiyat tahminindeki performansını test etmiştir. Çalışma sonucunda yapay sinir ağları ile fiyat tahminin mükemmel olmadığını ancak regresyon ve diğer matematiksel modellerden daha iyi bir performans sergilediğini söylemiştir.

2003 yılında Chen ve arkadaşları Tayvan Borsasının 1982 Ocak ile 1992 Ağustos ayı verilerini kullanarak hisse sendi getirilerini tahmin etmişlerdir. Çalışma sonucunda ise yapay sinir ağları ile getirilerin tahmin edilebileceği ve bu analiz ile yatırım kararları alınabileceği vurgulanmıştır.

Türkiyede ise yapay sinir ağları konusu ile ilgili finansal alanda Karaatlı, Güngör ve diğerleri “Hisse Senedi Fiyat Hareketlerinin Yapay Sinir Ağları Yöntemi ile Tahmin Edilmesi” adlı makalesinde BİST Ulusal-100 endeksi verilerini kullanarak tahmin etmişlerdir. Çalışmada regresyon modeli ile yapay sinir ağları modellerini hata kareler ortalaması karekökü kriterine göre karşılaştırmışlardır. Sonuç olarak, hata kareler ortalaması karekökü kriterine göre yapay sinir ağları modeli regresyon modeline göre daha iyi bir tahmin modeli oluşturmuştur.

Küçükocaoğlu, Benli ve Küçüksözen ise yapay sinir ağları modelini finansal bilgi manipülasyonu alanında kullanmışlardır. Çalışmalarında finansal bilgi manipülasyonu yapan ve yapmayan şirketlerin ayrımı, yapay sinir ağları modeli ile tahmin edilmiştir. Çalışma sonucunda yapılan tahminin doğru olma olasılığı %86,17 bulunmuştur. Sonuç olarak, finansal bilgi manipülasyonunu ortaya çıkarmaya yarayan değişkenler bilindiğinde, modele yeni katılan şirketlerin gelecekteki

durumlarını tahmin etmek için yapay sinir ağları yaklaşımının bir yöntem olarak kullanılabileceğini söylemişlerdir.

Yapay Sinir Ağ Modelleri

Yapay sinir ağları aslında yapay zeka teknolojisidir. Genel anlamda insan beyninin sinir ağlarının taklit eden bir bilgisayar programıdır (Aygören vd 2012:77). Çok değişkenli modellerde, değişkenler arasında karmaşık etkileşimin bulunduğu tek bir sonucun olmadığı kümelerde kullanılan bir modeldir (Küçükkoçoğlu 2009). Bu özelliğinden dolayı finansal alanda kullanıma uygun bir araç olarak görülmektedir.

Yapay sinir ağları modeli bilgisayar programı olarak tasarlanırken amacı biyolojik sinir sisteminin çalışma prensibini simüle etmektir. Simüle edilen sinir hücreleri nöronlar içerir ve bu nöronlar çeşitli şekillerde birbirlerine bağlanarak ağı oluştururlar. Bu ağlar; hafızaya alma ve verme arasındaki ilişkiyi ortaya çıkarma kapasitesine sahiptirler (Kocabaş 1999).


Yapay sinir ağlarında 3 katman bulunmaktadır. Bunlar; girdi katmanı, çıktı katmanı ve gizli katmandır.

Girdi katmanı modeldeki ilk katmandır. Modele girecek olan verilerin modele alınmasını sağlar. İstatistiksel olarak veri grubundaki bağımsız değişkenler girdi katmanı olarak adlandırılır. Çıktı katmanı ise son katmandır. Yapay sinir ağları modelinde çıktı katmanı veriyi dışarıya iletir. İstatistiksel olarak bağımlı değişken olarak adlandırılan veri çıktı katmanıdır. Gizli katmanlar ise modelde girdi katmanı ile çıktı katmanı arasında yer alır. Gizli katmanın dışarı ile bir bağlantısı yoktur. Biyolojik olarak açıklanacak olursa, girdi katmanındaki sinyali alıp çıktı katmanına iletirler.

Gizli katmandaki, gizli nöronlarının sayısının belirlenmesi çok önemlidir. Ağın büyüklüğünün tanımlanması, ağın performansının bilinmesi açısından önem taşımaktadır. Gizli nöronların ve katmanlarının sayısının artırılması veya azaltılması, ağın basit ya da karmaşık bir yapıda olmasını etkilemektedir (Küçükkoçoğlu 2009).

Aşağıdaki yapay sinir ağı modelinde, X ile girdiler, h ile gizli katmandan gelen çıktılar, Y ile ise sonuçtan elde edilen çıktılar belirtilmiştir (Güneri 2001).

Şekil 1: Yapay Sinir Ağı Yapısı



Yapay sinir ağını eğitmek için kullanılan veri setine eğitim veri seti denir. Daha sonra test aşamasında, eğitim verisinde kullanılmayan veriler ile yapay sinir ağı modeli test edilir (Erdoğan ve Özyürek 2012). Gerçek çıkış ile test çıkışı kontrol edilerek ortalama hata hesaplanır. Eğitim veri seti ve test veri seti rastgele seçilebilir.

Yapay Sinir ağı modelinde 3 tip ağ mevcuttur;

İleri Beslenmeli Ağ: Her bir katmandaki hücreler sadece bir önceki katmanın hücrelerince beslenir.

Kaskat Bağlantılı Ağ: Hücreler sadece önceki katmanlardaki hücrelerce beslenir.

Geri Beslemeli Ağ: En az bir hücre sonraki katmanlardaki hücrelerce de beslenir.

Uygulama:

Bu çalışmada yapay sinir ağları modeli ile BİST Ulusal-100 endeksi tahmin edilmiştir. Analizde BİST Ulusal-100 endeksinin 2005 ile 2012 yılları arasındaki aylık kapanış fiyatları kullanılarak, 2013 yılı BİST Ulusal-100 endeksi aylık kapanış değerleri tahmin edilmiştir. Analizde öncelikle regresyon modeli daha sonra da yapay sinir ağları modeli ile öngörülerde bulunulmuştur. Çıkan sonuçlar 2013 yılı gerçekleşen BİST Ulusal-100 endeksi kapanış fiyatları ile karşılaştırılmıştır.

Analizde kullanılan verilerin hepsi Merkez Bankası web sayfasından alınmıştır (www.tcmb.gov.tr). BİST Ulusal-100 endeksi bağımlı değişken olarak alınmıştır. Bağımsız değişken olarak ise; hazine bonusu, cumhuriyet altını satış fiyatı, enflasyon oranı (TÜFE), sanayi üretim endeksi, döviz kurları (reel efektif döviz kuru TÜFE bazlı) ve zaman değişkeni kullanılmıştır.

Çalışmanın regresyon analizi kısmında SPSS 15.0 paket programı kullanılmıştır. Regresyon analizi yapılmadan önce tanımlayıcı istatistikler hesaplatılmıştır. Daha sonra verilerin normal dağılım gösterip göstermediği test edilmiştir.

Tablo 1: Tanımlayıcı İstatistikler

			Statistics	Std.Error
BIST100	Mean		47.393,3648	1.387,41831
	95% Confidence Interval	Upper Bound	44.638,9912	
		Lower Bound	50.147,7384	
	Median		46.783,5350	
	Variance		184.793.238,978	
	Standart Deviation		13.593,86770	
	Minimum		23.591,64	
	Maximum		78.208,44	
	İnterval		54.616,80	
	Skewness		,055	,246
	Kurtosis		-,933	,488

H_0 : Verilerin dağılımı ile normal dağılım arasında fark yoktur.

H_1 : Verilerin dağılımı ile normal dağılım arasında fark vardır.

Tablo 2: Normallik Testi

	Kolmogorov-Smirnov(a)			Shapiro-Wilk		
	Statistics	Df	Sig.	Statistics	df	Sig
BIST100	,071	96	,200(*)	,972	96	,068

Yukarıdaki normallik tablosu incelendiğinde hem Kolmogorov-Smirnov hem de Shapiro-Wilk testine göre önemlilik değeri 0,05'den büyük çıktığı için H_0 kabul edilir. Yani %95 güvenilirlik seviyesinde verilerin normal dağıldığını söyleyebiliriz.

Regresyon analizinde hangi yöntemin kullanılacağına karar vermek amacıyla verilere "Curve Estimation" uygulanmıştır. Doğrusal, Logaritmik ve Kübik regresyon modelleri oluşturulmuştur. Her 3 modelinde hata kareler ortalaması karekökü hesaplanmıştır. Buna göre en küçük hata kareler ortalamasının kareköküne sahip olan model ile analize devam edilmiştir.


Hata kareler ortalamasının karekökü hesaplaması için aşağıdaki formül kullanılmıştır;

$$[\quad \quad \quad (3)$$

Yapılan hesaplamalar sonucunda kübik regresyon modelinin hata kareler ortalaması karekökü en küçük bulunmuştur. Kübik regresyon modeline göre tahmin edilen BİST Ulusal-100 endeksi 2013 aylık kapanış verileri aşağıdaki gibidir;

Tablo 3: BİST 100 ve Kübik Regresyon Modeli ile Tahmin

	DATE	BİST 100	ESTIMATION WITH CUBIC REGRESSION
XU100	31.01.2013	78.783,47	74.233,79
XU100	28.02.2013	79.333,67	75.417,17
XU100	29.03.2013	85.898,99	76.634,04
XU100	30.04.2013	86.046,04	77.884,95
XU100	31.05.2013	85.990,01	79.170,50
XU100	28.06.2013	76.294,51	80.491,25
XU100	31.07.2013	73.377,45	81.847,78
XU100	29.08.2013	66.394,41	83.240,66
XU100	30.09.2013	74.486,56	84.670,46
XU100	31.10.2013	77.620,37	86.137,76
XU100	29.11.2013	75.748,27	87.643,13
XU100	31.12.2013	67.801,73	89.187,15

Şekil 2: BİST 100 ve Kübik Regresyon Modeli ile Tahmin Grafiği

Tablo 3 ve Şekil 2 incelendiğinde gerçekleşen endeks değerleri ile kübik regresyon modeli ile yapılan tahminler arasında farklılık gözükmektedir. 2013 yılı aylık kapanış değerleri ile BİST Ulusal-100 endeksi, gerçekleşen değerlerden daha düşük tahmin edilmiştir. Ama; Mayıs ayına kadar her iki seride de artış gözükmektedir. Mayıs ayı itibarıyla gerçekleşen değerler düşmeye başlamasına rağmen kübik reg-

resyon modeli ile tahmin edilen serimiz yıl sonuna kadar her ay artış göstermektedir.

Analizde yapay sinir ağı modeli Matlab 8.1.0 yazılım programı kullanılarak yapılmıştır. Yapay sinir ağı modeli oluşturulurken geri yayılım ağı (backpropagation network) kullanılmıştır. 2005-2012 yılı aylık veriler toplamı 96 dır. 96 verinin %80'ine denk gelen 77 veri öğrenme amaçlı, geriye kalan ve %20'sine denk gelen 19 veri test amaçlı kullanılmıştır. Öğrenme ve test amaçlı veriler rastgele seçilmiştir. Rastgele seçilen 6 ayrı veri grubu oluşturulmuştur. Yapay sinir ağı modelimiz oluşturulurken 6 katman yer almaktadır. Bunlardan ilki giriş katmanı, diğer 4 katman gizli katman ve son katman ise çıkış katmanıdır. Giriş katmanında 6 adet açıklayıcı değişken yer almaktadır. 1. Gizli katmanda 10 adet nöron, 2. Gizli katmanda 1 adet nöron, 3. Gizli katmanda 10 adet nöron ve 4. Gizli katmanda ise 12 adet nöron bulunmaktadır. Çıkış katmanında ise 1 adet bağımlı değişken vardır. Gizli katmanlardaki nöron sayıları farklı denemeler yapılarak bulunmuştur. Nöron sayılarına, gerçekleşen değerlere en yakın sonuçları verdiği için karar verilmiş olup farklı nöron sayıları ile oluşturulan 6 farklı veri grup içinden en iyi grup ve en iyi ağ, hata kareler ortalaması karekökü en küçük olan ağ ve en küçük olan grup olarak seçilmiştir.

Yapay sinir ağı modeline göre oluşturulan modelin hata kareler ortalamasının karekökü 20.103,48 iken kübik regresyon modeli ile oluşturulan verilerin hata kareler ortalamasının karekökü 25.779,21 olarak hesaplanmıştır. Bu bulgular ışığında analizde yapay sinir ağı modeli ile oluşturulan veriler dikkate alınmıştır.


Yukarıdaki çalışmada ilk olarak yapay sinir ağı modelinin yapısı oluşturulmuştur. Daha sonra 2013 BİST Ulusal-100 endeksi tahmin edilebilmesi için bağımsız değişkenler belirlenmiştir. Bunun için yine 6 farklı grup oluşturulmuş ve bu gruplarda 6 katman kullanılmıştır. Yine 1. katman giriş katmanı, 6. katman ise çıkış katmanıdır. Gizli katmanda yer alan nöron sayıları daha önce belirlenen nöron sayıları olarak belirlenmiştir. Tahmin edilen bağımsız değişkenlerin yardımı ile 2013 yılı BİST Ulusal-100 endeksi aylık kapanış fiyatları tahmin edilmiştir.

Analiz sonucunda yapay sinir ağı modeli ile oluşturulan veriler aşağıdaki gibidir;

Tablo 4: BIST 100 ve Yapay Sınır Ağ Modeli ile Tahmin

	DATE	BIST 100	ESTIMATION WITH ARTIFICIAL NEURAL NETWORK MODEL
XU100	31.01.2013	78.783,47	76.537,98
XU100	28.02.2013	79.333,67	77.451,04
XU100	29.03.2013	85.898,99	78.391,20
XU100	30.04.2013	86.046,04	79.437,90
XU100	31.05.2013	85.990,01	80.835,31
XU100	28.06.2013	76.294,51	81.921,67
XU100	31.07.2013	73.377,45	82.045,34
XU100	29.08.2013	66.394,41	82.459,90
XU100	30.09.2013	74.486,56	82.952,05
XU100	31.10.2013	77.620,37	84.371,45
XU100	29.11.2013	75.748,27	85.239,54
XU100	31.12.2013	67.801,73	86.182,23

Şekil 3: BIST 100 ve Yapay Sınır Ağları Modeli ile Tahmin Grafiği



Şekil 3: BIST 100 ve Yapay Sınır Ağları Modeli ile Tahmin Grafiği


Tablo 4 ve Şekil 3 incelendiğinde yapay sinir ağları modeli ile oluşturulan veri seti, BİST Ulusal-100 endeksini Ocak ve Şubat aylarında yakın tahmin etmiştir. Tahmini değerlere göre endeks yıl sonuna kadar artış göstermektedir. Ancak gerçekleşen değerler yıl içinde artış ve azalışlar göstermiştir.

Tablo 5: BIST 100, Kübik Regresyon ve Yapay Sinir Ağ Modeli ile Tahmin

	DATE	BIST 100	ESTIMATION WITH CUBIC REGRESSION	ESTIMATION WITH ARTIFICIAL NEURAL NETWORK MODEL
XU100	31.01.2013	78.783,47	74.233,79	76.537,98
XU100	28.02.2013	79.333,67	75.417,17	77.451,04
XU100	29.03.2013	85.898,99	76.634,04	82.391,20
XU100	30.04.2013	86.046,04	77.884,95	82.937,90
XU100	31.05.2013	85.990,01	79.170,50	83.135,31
XU100	28.06.2013	76.294,51	80.491,25	84.921,67
XU100	31.07.2013	73.377,45	81.847,78	85.045,34
XU100	29.08.2013	66.394,41	83.240,66	86.659,90
XU100	30.09.2013	74.486,56	84.670,46	87.952,05
XU100	31.10.2013	77.620,37	86.137,76	88.371,45
XU100	29.11.2013	75.748,27	87.643,13	89.239,54
XU100	31.12.2013	67.801,73	89.187,15	90.782,23

Şekil 4: BIST 100, Kübik Regresyon ve Yapay Sinir Ağları Modeli ile Tahmin Grafiği

Şekil 4: BIST 100, Kübik Regresyon ve Yapay Sinir Ağları Modeli ile Tahmin Grafiği



Kübik regresyon ve yapay sinir ağları modelleri ile oluşturulan veri setleri karşılaştırılacak olunursa; yapay sinir ağları modeli ile oluşturulan BİST Ulusal-100 endeksi, kübik regresyon modeli ile oluşturulan BİST Ulusal-100 endeksine göre gerçekleşen aylık değerlere Mayıs ayına kadar daha yakındır. Ancak her iki model de yıl içindeki artış ve azalışları, yani dalgalanmaları yansıtamamıştır.

Tartışma ve Sonuç:

Bu çalışmada BİST Ulusal-100 endeksi verileri kullanılarak kübik regresyon ve yapay sinir ağları modeli ile 2013 yılı aylık BİST Ulusal-100 endeksi tahmin edilmiştir. Öncelikle doğrusal, logaritmik ve kübik regresyon modelleri oluşturularak hangisinin performansının daha iyi olduğu hata kareler ortalamasının kare kökü ile bulunmuştur. 3 modelden hata kareler ortalamasının karekökü en küçük olan, kübik regresyon modeli ile BİST Ulusal-100 endeksi 2013 yılı kapanış değerleri tahmin edilmiştir. Daha sonra yapay sinir ağları modeli ile 6 katmanlı bir model oluşturulmuştur. Oluşturulan modelde 4 adet gizli katman bulunmaktadır. Bunlardan; 1. gizli katmanda 10 adet, 2. gizli katmanda 1 adet, 3. gizli katmanda 10 adet ve son olarak 4. gizli katmanda ise 12 adet nöron bulunmaktadır. Oluşturulan ağlar ve gruplar arasında en iyi performansı sağlayan ağa ve gruba karar verilirken, hata kareler ortalamasının karekökü en küçük olan dikkate alınmıştır.

Yapılan uygulama sonucunda; yapay sinir ağları modelinin kübik regresyon modeline göre daha iyi bir performans sergilediği görülmektedir. Yukarıdaki tablolar ve grafikler incelendiğinde Mayıs ayına kadar BİST Ulusal-100 endeksi artış göstermektedir. Ocak –Mayıs ayları arasında kübik regresyon modeli de, yapay sinir ağları modeli de bu artışı yansıtmaktadır. Ancak yapay sinir ağları modelinin bulmuş olduğu değerler, gerçekleşen değerlere daha yakındır.

Haziran ayı itibarıyla BİST Ulusal-100 endeksinde ciddi bir düşüş yaşanmıştır. Bu durum Türkiye’de Haziran ayında başlayan ve etkisi bir kaç ay süren Gezi Parkı eylemlerinden kaynaklanmakta olduğunu düşünülebilir. Bu durum, modele eklenemeyen bir değişken olduğu için; hem yapay sinir ağları modeli hem de kübik regresyon modeli, bu durumdan etkilenmemiş ve modellerde düşüş yaşanmamıştır.

Eylül ayında BİST Ulusal-100 endeksi artış göstermeye başlamıştır ancak yine Aralık ayının ikinci yarısında Türkiye’de yaşanan siyasi ve politik olaylardan dolayı BİST Ulusal-100 endeksi hızlı bir düşüşe geçmiştir ve aylık kapanışı bir önceki aya göre daha düşük olmuştur. Beklenmeyen bu durum da analizde kullanılan modellere yansımamıştır.

Bulgular ışığında; Türkiye’de yaşanan siyasi ve politik olaylar modellere eklenemeyen ve tahmin edilemeyen faktörler olduğu için, bu dönemlerde yapılan hesaplamaların gerçeği yansıtmayacağı beklenen bir durumdur. Ancak Ocak ve Mayıs ayı arasındaki zaman dikkate alınacak olunur ise; yapay sinir ağları ile oluşturulan model, gerçekleşen endeks değerlerine, kübik regresyon modeline göre daha yakın bir tahminde bulunmuştur. İleriki dönemlerde modele eklenemeyen faktörler olmayacağı var sayılır ise; yapay sinir ağları modeli ile BİST Ulusal-100 endeksinin tahmin edilebileceği söylenebilir.

Kaynakça:

AYGÖREN, Hakan., Hakan. SARITAŞ. ve Tuncay. MORALI, (2012), “İMKB 100 Endeksinin Yapay Sinir Ağları ve Newton Nümerik Arama Modelleri ile Tahmini”, **Uluslararası Alanya İşletme Fakültesi Dergisi**, IV,12:73-88.

CHEN, An Sing., Mark. T., LEUNG. ve Hazem. DAOUK, (2003), “Application of Neural Networks to an Emerging Financial Market: Forecasting and Trading the Taiwan Stock Index”, **Pergamon Computers & Operations Research**, XXX,6:901,923.

BİRCAN, Hüdaverdi., Metin. ZONTUL., ve Ahmet. G. YÜKSEL, (2006), “Som Tipinde Yapay Sinir Ağlarını Kullanarak Türkiye'nin İhracat Yaptığı Ülkelerin Kümelenmesi Üzerine Bir Çalışma”, **İktisadi Bilimler Dergisi**, XX, 2:219-239.

DOĞAN, Gülay, (2010), “Yapay Sinir Ağları Kullanılarak Türkiye'deki Özel Bir Sigorta Şirketinde Portföy Değerlendirmesi”, **Hacettepe Üniversitesi İstatistik Anabilim Dalı, Yüksek Lisans Tezi**, Ankara.

ERDOĞAN, Elif. ve Hamide. ÖZYÜREK, (2012), “Yapay Sinir Ağlar ile Fiyat Tahminlemesi”, **Sosyal ve Beşeri Bilimler Dergisi**, IV, 1: 85-92.

FISHER, J. Aldrich, (1922), “The Goodness of Fit of Regression Formulae and the Distribution of Regression Coefficients”, **J. Royal Statist. SoC.**, XX,4: 401-417.

FISHER, J. Aldrich, (1925), “**Statistical Methods for Research Workers**” Edinburg: Oliver and Boyd, <http://trove.nla.gov.au/work/10809098?q&sort=holding+desc&_id=1394179683545&versionId=15607207>, Erişim: 07.03.2014

GALTON, Francis, (1877), “Typical Laws of Heredity”, **Nature** 15, XV,5:492-495.

GAUSS, C. Friderico, (1809), “**Theoria Motus Corporum Coelestium in Sectionibus Conicis Solem Ambientum**”, <<http://onlinelibrary.wiley.com/doi/10.1002/asna.18550402508>>, Erişim Tarihi:01.02.2014.

GONCALOĞLU, Berrin, (2012), “Regresyon Analizi”, **Yıldız Teknik Üniversitesi Çevre Mühendisliği Bölümü, Eğitim Notları**, <http://www.yarbis.yildiz.edu.tr/.../goncal_198bf26f67f7ff5160d68d1af0e34fe8.pdf>, Erişim Tarihi: 24.02.2014

GÜNERİ, Nermin, (2001), “Öğrenci Başarısızlıklarının Analizinde Sinir Ağları Yaklaşımının Lojistik Regresyon Analizi ile Karşılaştırılması”, **Ankara Üniversitesi, Yayınlanmamış Yüksek Lisans Tezi**.

KADILAR, Cem, (2005), “**SPSS Uygulamalı Zaman Serileri Analizine Giriş**” Bizim Büro Basımevi.

KARAATLI, Meltem, (2003), “Yapay Sinir Ağları Yöntemi ile Tahmin (İMKB'de Bir Uygulama)”, **T.C Süleyman Demirel Üniversitesi Sosyal Bilimler Enstitüsü İşletme Anabilim Dalı, Yüksek Lisans Tezi**, Isparta.

KARAATLI, Meltem., İbrahim. GÜNGÖR, Yusuf. DEMİR. ve Şeref. KALAYCI, (2005), “Hisse Senedi Fiyat Hareketlerinin Yapay Sinir Ağları ile Tahmin Edilmesi” ,**Balıkesir Üniversitesi Bandırma İktisadi ve İdari Bilimler Fakültesi Akademik Fener Dergisi**, III,3:38-48.

KOCABAŞ,Şakir,(1998), “Yapay Zeka Ders Notları”, İstanbul Teknik Üniversitesi.

KÜÇÜKKOCAOĞLU, Güray, Yasemin. K. BENLİ. ve Cemal. KÜÇÜKSÖZEN, (2009), “ Finansal Bilgi Manipülasyonunun Tespitinde Yapay Sinir Ağı Modelinin Kullanımı” İMKB Dergisi, IX,36:1-30.

LAWRENCE, Roman, (1997), “Using Neural Networks to Forecast Stock Market Prices”, **Department of Computer Science University of Manitoba**.

ÖZALP, Alperen. ve Sermet. ANAGÜN, (2001), “Sektörel Hisse Senedi Fiyat Tahmininde Yapay Sinir Ağı Yaklaşımı ve Klasik Tahminleme Yöntemleri ile Karşılaştırma” **Makine Mühendisleri Odası Endüstri Mühendisliği Dergisi**, XII, 3-4: 2-17.

PEARSON, Karl, (1903), “The Law of Ancestral Heredity” **Biometrika**, II,2:27-29.

PEKEL, I. Özlem. (2008), “ Yapay Sinir Ağları”, **Orta Doğu Teknik Üniversitesi Bilgisayar Topluluğu Elektronik Dergisi**, II,2:1-7.

ŞENESEN, Ümit. ve Gülay. ŞENESEN, (2008), “**Temel Ekonometri**” Literatür Yayınları.

YULE, G. Udney, (1897), “On the Theory of Corralation”, **J. Royal Statist.Soc.**, LX,4:812-854.