Döviz Kuru, Altın Fiyatları ve Borsa Getirileri Yönünün Yüksek Dereceden Markov Zincirleri Modelleri ile Tahmini

Estimation of Direction of Exchange Rate, Gold Price and Stock Market Returns with High Order Markov Chain Models

Prof. Dr. Süleyman Bilgin Kılıç (Çukurova University, Turkey)

Salih Çam (Çukurova University, Turkey)

Abstract

This study uses a hybrid high order Markov Chains Model to predict direction of exchange rate, gold price and stock market returns with the Artificial Neural Network Algorithm as an estimator of transition probability matrix. Many forecasting techniques are used to examine the direction of returns forecasting in the literature such as Markov Chains Model and Artificial Neural Network Algorithm. In this study, it is aimed to combine these two techniques and to utilize the predict values of the Artificial Neural Network Algorithm for calculate transition probabilities matrix. Calculations show that the hybrid model gives high correct classification probabilities besides of well approximated transition probabilities. Returns series of USD/TRY exchange rate, closing price of Borsa Istanbul Stock Exchange and gold prices cover the period of 01/01/2003 and 31/01/2016. All series are obtained from database of Central Bank of Turkey. As a result, although the transition probabilities almost equal to 0.5 and so estimation of these series are not easy, the transition probabilities and correct classification probabilities gained from the hybrid model provide substantial information related to direction of returns forecasting. Besides, estimated model provide valuable information to individual investors and companies, and could help them to take position against to risks.

1 Giriş

Etkin piyasa hipotezi Amerikalı ekonomist Fama (1970) tarafından ortaya atıldığından beri birçok araştırmaya konu olmuştur. Fama (1970) göre etkin bir piyasa yeterince büyüktür ve bu piyasada birbirleri ile kar maksimizasyonu için rekabet eden birçok aktör vardır. Dolayısıyla tek bir alıcı veya satıcı piyasada fiyatlamaya yapamaz. Genel olarak etkin piyasalar zayıf etkin piyasalar, orta etkin piyasalar ve güçlü etkin piyasalar olmak üzere üç şekilde karşımıza çıkmaktadır. Zayıf etkin piyasa hipotezine göre verilerin tarihsel özelliklerinden yola çıkarak gelecek ile ilgili çıkarım yapılamaz. Diğer bir ifade ile teknik analiz yardımı ile uzun dönemde piyasa ortalama getirisinin üstünde bir getiri elde etmek mümkün değildir. Orta etkin piyasa hipotezine göre ise yeni bir bilgi bütün aktörler tarafından hemen elde edilmektedir. Sonuç olarak orta etkin bir piyasada bilgi fiyatlanmıştır ve ortalamanın üstünde getiri sağlamaz. Bu tür bir piyasada ortalamanın üstünde getiri sağlamak için halka açık olmayan (içerden) bilgi sağlanmalıdır. Nihayet güçlü etkin bir piyasada, halka açık bilginin yanında içerden bilgi de ortalamanın üstünde kar sağlamak adına yarar sağlayacaktır.

Bir piyasanın yeterince büyük olması sadece iç piyasadaki aktör sayılarına bağlı değildir. Küreselleşen piyasalar ile birlikte artan dış ticaret, iç piyasalara yabancı sermaye girişini ve yabancı yatırımcı sayısını arttırmıştır. Dolayısıyla ticaret ilişkilerin olduğu ekonomilerde meydana gelen bir şok direkt olarak iç piyasadaki yabancı yatırımcıları ve döviz kuru üzerinden ihracat yapan yerli yatırımcıları etkilemektedir. Bu noktada hem yabancı yatırımcılar hem de yerli yatırımcılar açısından başta döviz kuru olmak üzere finansal piyasaların gelecek değerlerini öngörebilmek çok önemlidir. Bundan dolayı bu piyasalar ile ilgili ekstra bir bilgi elde edilmesi yatırımcılara avantaj sağlamanın yanında sözü geçen piyasaların doğru bir şekilde tahmin edilmesi hükümetler, şirketler ve yatırımcılara risklere karşı pozisyon alma şansı da taniyacaktır. Örneğin hükümetler açısından döviz kurunun kısa ve orta vadede nasıl hareket edeceği ile ilgili ekstra bir bilgi, uygulayacakları para politikalarını daha etkin kullanmalarına yardımcı olacaktır. Bireysel bir yatırımcının ekstra bir bilgiye sahip olması ise uzun dönem getirisini ortalama getirinin üstüne çıkartmasını sağlayacaktır. Bu çalışmaya konu olan piyasalar etkin piyasalar ya da etkin piyasalara en yakın piyasalardır. Dolayısıyla bu piyasalarla ilgili doğru ve güçlü tahminler elde etmek karar alıcılara ve yatırımcılara hareket alanı sağlayacaktır.

2 Literatür

Markov zincirleri ve yapay sinir ağlarının uygulama alanları oldukça geniştir. Markov zincirleri fizik, internet, istatistik, iktisat, matematiksel biyoloji, müzik ve spor gibi birçok alanda kendine yer bulmuştur. Yapay sinir ağları ise finans, haberleşme, tıp ve ilaç sanayi v.b gibi geniş bir uygulama alanına sahiptir. Özellikle Markov zincirleri modelleri döviz kuru, altın fiyatları ve borsa verileri gibi gelecek değerlerinin tahmin edilmesi güç olduğu değişkenlerde sıklıkla kullanılmıştır. Bu tekniklerin finans alanındaki uygulamalarının birkaçı burada özetlenmiştir. Ryan (1973) borsa hareketlerini Markov zincirleri modellerini kullanarak tahmin etmiştir. Ryan yaptığı analizler sonucunda Markov zincirleri modelinin borsa hareketleri ile ilgili önemli bilgiler verdiğini

göstermiştir. Engel ve Hamilton (1990) Amerikan dolarındaki ani iniş ve çıkışları Markov zincirleri modellerini kullanarak serinin rastsal bir süreç izleyip izlemediğini başka bir ifade ile serinin Markov zincirleriyle tahmin edilemeyeceğini araştırmıştır. Yapılan analizler doğrultusunda yazar, incelediği dönem çerçevesinde serinin rastsal yürüyüşten daha iyi performans gösterdiğini bulmuştur. McQueen (1991) Markov zincirleriyle 1947-1987 dönemine ait yıllık borsa getirisi serisinin Markov sürecine uyduğunu göstermiştir. Başka bir ifade ile borsa getirilerinin Markov zincirleri modelleriyle tahmin edilebileceği sonucuna varmıştır. Marsh (2000) çalışmasında iki durumlu Markov zinciri modelini üç günlük döviz kuru getiri oranları serisine uygulamış ve serinin Markov sürecine uyduğu sonucuna varmıştır. Marsh analizine Alman Markı, İngiliz Sterlini ve Japon Yenini dahil etmiş ve bu üç döviz kuru serisini üç ayrı dönemler halinde analiz etmiştir. Araştırmacı 1980-1985, 1980-1990 ve 1980-1995 dönemleri olarak ele aldığı serilerin birinci dönemler için en iyi performansı sergilediklerini, dönem aralığı arttıkça Markov zincirlerinin tahmin performansının biraz düştüğünü gözlemlemiştir. Benzer bir çalışma Mills ve Jordanov (2003) tarafından yapılmış ve 1985-1995 dönemini kapsayan borsa verileri kullanılmıştır. Yazarlar yaptıkları analizler sonucunda Markov zincirlerinin özellikle uzun dönemde daha iyi tahmin performansı sergilediğini sonucuna varmışlardır. Kanas (2003) Amerika borsa verilerini 1872-1999 dönemi için dört farklı tahmin tekniği kullanarak analiz etmiştir. Kanas ikisi parametrik ikisi non-parametrik olan teknikler arasında Markov zincirleri ve yapay sinir ağları algoritmasının en az diğer iki teknik kadar iyi performans gösterdiklerini bildirmiştir. Ayrıca çalışmada dört değerlendirme kriteri uygulanmış ve bu kriterlere göre en iyi performansı Markov zincirleri göstermiştir. Can ve Öz (2009) USD döviz kurunu saklı Markov zincirleri modelini kullanarak tahmin etmişlerdir. 1992-2007 dönemi verileri kullandıkları çalışmalarında araştırmacılar, 2008 yılı için döviz kuru hareketlerini başarılı bir şekilde tahmin etmişlerdir. Aşkın, Güzin ve Gülizar (2012), altın fiyatlarının getiri yönlerini 2005-2009 yılları arası günlük veriler kullanarak analiz etmişler ve Markov zincirleri modellerinden anlamlı sonuçlar elde etmişlerdir. Ayrıca Kılıç (2013) ve Onalan (2014) çalışmalarında TL/USD döviz kurunu Markov zincirleri yardımıyla tahmin etmiş ve önemli bilgiler elde etmişlerdir. İlarıslan (2014) İMKB 10 indeksindeki on bankadan dokuz tanesinin hisse senedi fiyatları hakkında doğru öngörüler yapmıştır

Yukarıda Markov zincirleri ile ilgili literatürdeki çalışmaların bir kısmı özetlendi. Burada ise yapay sinir ağları algoritmasının finansal veriler ile uygulamasını içeren çalışmalar özetlenecektir. Markov zincirleri modellerinde olduğu gibi özellikle döviz kuru ve borsa verilerinin gelecek tahminleri için yapay sinir ağları algoritması oldukça fazla kullanılmıştır. Zhang ve Hu (1998) giriş katmanı ve gizli katmandaki düğüm sayılarının ağı performansı üzerindeki etkisini araştırdıkları çalışmalarında, Pound/USD döviz kuru serisini analiz için kullanmışlardır. Ampirik sonuçlar doğrultusunda yapay sinir ağları algoritmasının araştırmada kullanılan lineer modellerden daha iyi tahmin performansı gösterdiklerini gözlemlemişlerdir. Ayrıca ağ performansının verinin sıklığına göre de iyileştiğini bildirmişlerdir. Shin ve Han (2000) Won/USD döviz kuru değerlerini tahmin ettikleri çalışmalarında Genetik algoritma ile Yapay sinir ağları algoritmasını birlikte kullanımının tatmin eden sonuçlar verdiğini göstermişlerdir. Ayrıca Nag ve Mitra (2002) de Genetik algoritma ve Yapay sinir ağları algoritmasını birlikte kullanmış ve çalışmadaki diğer tekniklerden başarılı tahminler ürettiğini gözlemlemişlerdir. Diğer bir çalışmada ise Leung, Chen ve Daouk (2000) Genel regresyon sinir ağları modelini döviz kuru fiyatlarını analiz etmek için kullanmışlar ve bu tekniğin kullanılan diğer tekniklere kıyasla iyi performans sergilediği sonucuna varmışlardır. Kamruzzaman ve Sarker (2003) Avustralya Dolarını beş farklı para birimi karşısındaki değerini Yapay sinir ağları algoritmasıyla tahmin etmiştir. Kamruzzaman ve Sarker çalışmasında Yapay sinir ağları algoritmasını ARIMA modeliyle beş kritere göre karşılaştırmış ve YSA'dan daha başarılı tahminler elde etmiştir. Benzer şekilde Panda ve Narishman (2007) Rupı/USD döviz kurunun haftalık verilerinden yola çıkarak bir hafta sonraki değerini YSA, lineer otoregresif model ve rassal yürüyüş modelleriyle tahmin etmiştir. Yapılan değerlendirmelerden sonra YSA'dan daha doğru tahminler elde etmişlerdir. Gulseren, Kayakutlu ve Daniels (2011) NASDAQ indeksi günlük verilerinin yaklaşık yedi aylık dönemini kapsayan veri setini çok katmanlı Yapay sinir ağları algoritması ve birkaç hibrit modelin çıktıları üzerinden araştırmıştır. Çalışmanın sonucuna göre çok katmanlı Yapay sinir ağları modelinin güçlü tahminler ürettiği gözlemlenmiştir. Borsa getirisi, altın fiyatları getirisi ve faiz getirisi verilerini konu alan çalışmada Kılıç, Paksoy ve Genç (2014) serilerin YSA modeliyle tahminlerinin önemli bilgiler verdiği sonucuna varmışlardır.

3 Yöntem

Bu çalışmada USD/TL döviz kuru, altın fiyatları ve borsa verilerinin günlük getiri oranları kullanılmıştır. Her bir değişkene ait ikinci dereceden ve üçüncü dereceden Markov zincirleri geçiş olasılıkları matrisi hesaplanmıştır. Değişkenlerin üçüncü dereceden geçiş olasılıklarını hesaplamak amacıyla giriş verisi son üç günün getiri yönünün pozitif (+) veya negatif (-) olmasına bağlı olarak (+++), (++-), (+-+), (-++), (--+), (-+-), (+--), (- - -) olmak üzere sekiz adet Yapay sinir ağı modeli tahmin edilmiştir. Bütün yapay sinir ağları modelleri için yaklaşık yüz deneme yapılmış ve en yüksek performansı gösteren model seçilmiştir. Performans kriteri olarak Yapay sinir ağının toplam doğru tahmin etme başarısı ve getirinin iki yönünü minimum %50 doğrulukta tahmin etmesi dikkate alınmıştır. İkinci dereceden geçiş olasılıkları matrisini hesaplamak amacıyla ise giriş verisi son iki günün getiri yönünün pozitif (+) veya negatif (-) olmasına bağlı olarak (++), (+ -), (- +) ve (- -) olmak üzere dört Yapay sinir ağı modeli tahmin edilmiştir. Aynı şekilde bütün Yapay sinir ağı modelleri için yaklaşık yüz deneme yapılmış ve

en iyi sınıflama başarısını gösteren ağ yapısı tahmin edici olarak seçilmiştir. Yapay sinir ağları modelleri hesaplanırken w giriş katmanı ile gizli katman arasındaki ağırlıkları gösteren matris, v ise gizli katman ile çıkış katmanı arasındaki ağırlıkları gösteren matris olarak hesaplanmıştır. Yapay sinir ağının çıkışı

$$\hat{Y}_t = F_2[(V_t^T F_1(W_t.X_t))] \quad [1]$$

olarak gösterilebilir. Burada $X = (x_0, x_1, \dots, x_p)^T \in R^{(p+1) \times 1}$ yapay sinir ağının giriş verisini temsil ederken $Y = (y_0, y_1, \dots, y_k)^T \in R^{(k+1)}$, X giriş verisine karşılık ağın çıkış verisini temsil etmektedir. Ayrıca $F_1(W_t.X_t)$ giriş katmanından gizli katmana aktivasyon fonksiyonudur ve şu şekilde gösterilmektedir.

$$F_1(W_t.X_t) = (F(net_{0(t)}), F(net_{1(t)}), \dots, F(net_{q(t)}))^T \in R^{(q+1) \times 1} \quad [2]$$

Burada $net_{i(t)} = \sum_{j=0}^p w_{ij(t)} \cdot x_{j(t)}$, $i = 0, 1, \dots, q$ 'dir ve $w_{i0(t)}$, $t=1, 2, \dots, q$ gizli katmandaki düğümlere giden

hata terimleridir. $F_2[(V_t^T F_1(W_t.X_t))]$ fonksiyonu ise gizli katmandaki net girdinin v çıkış katmanı ağırlıklarıyla çarpılmasıyla elde edilmiştir (Yu ve diğerleri, 2007, s.28-29). Başka bir ifade ile ağın çıktısıdır. $F_2(net)$ aktivasyon fonksiyonu oluşturulan Yapay sinir ağı modellerinin performanslarına göre sigmoid fonksiyonu olarak seçilmiştir.

Eşitlik [1]'den elde edilen $\hat{Y}_t$ tahmin değerleri geçiş olasılıkları matrisini hesaplamak için kullanılmıştır. Bütün geçiş olasılıkları için $n_{il, \dots, i0}$ yüksek dereceden Markov zincirlerinde geçiş tipinin sayısını, $\hat{p}_{il, \dots, i0}$ ilgili geçiş olasılığını ve m durum sayısını gösterebilir. Geçiş olasılıklarının en yüksek olabilirlik (EYO) tahmini şu şekilde hesaplanabilir.

$$\hat{p}_{il, \dots, i0} = \frac{n_{il, \dots, i0}}{n_{il, \dots, i1} +} \quad [3]$$

burada $n_{il, \dots, i1} + = \sum_{i_0=1}^m n_{il, \dots, i0}$ 'dır ve Yapay sinir ağının tahmin edilmiş değerleridir. Örneğin üç gün boyunca

pozitif getiri takip eden bir değişkenin bir adım sonraki getirisinin de pozitif olma olasılığı pozitif, pozitif, pozitif (+ + +) devam eden getirilerin sayısının bir sonraki gün pozitif gerçekleşmiş getirilerin sayısına bölünmesiyle bulunmaktadır.

Birinci dereceden Markov sürecinde bir değişkene ait gözlemlerin sadece kendinden bir önceki gözlemden etkilendiğini daha eski gözlemlerden etkilenmediği varsayılmaktadır. Fakat ikinci dereceden ve üçüncü dereceden Markov zincirlerinde bu varsayımın biraz gevşetilmesi gerekmektedir.

$$P(X_t = i_0 / X_0 = i_t, \dots, X_{t-2} = i_2, X_{t-1} = i_1) = P(X_t = i_0 / X_{t-2} = i_2, X_{t-1} = i_1) \quad [4]$$

$$P(X_t = i_0 / X_0 = i_t, \dots, X_{t-2} = i_2, X_{t-1} = i_1) = P(X_t = i_0 / X_{t-3} = i_3, X_{t-2} = i_2, X_{t-1} = i_1) \quad [5]$$

Eşitlik [4] ikinci dereceden Markov sürecini gösterirken [5] üçüncü dereceden Markov sürecini göstermektedir. Buna göre üçüncü dereceden Markov zincirinin geçiş olasılığı matrisi (8x2) boyutunda, ikinci dereceden Markov zincirinin geçiş olasılığı matrisi ise (4x2) boyutunda olacaktır

4 Uygulama

Dolar/TL, Borsa İstanbul 100 indeksi ve altın fiyatlarının getirileri için hesaplanan geçiş olasılıkları matrisleri ve her bir Yapay sinir ağı algoritmasının özet bilgileri aşağıdaki tablolarda verilmiştir. Üçüncü dereceden Markov zincirleri için sekiz Yapay sinir ağı modeli tahmin edilmiş olup, bütün modellerin doğru tahmin etme başarıları ilgili tablolarda verilmiştir. Ayrıca bütün Yapay sinir ağlarının hesaplanan ağırlıkları EkA'da verilmiştir. Yapay sinir ağları tasarlanırken gizli katman fonksiyonu toplam fonksiyonu, çıkış katmanı fonksiyonu ise sigmoid fonksiyonu ve ağın eğitiminde Gradient descent metodu kullanılmıştır. Aşağıdaki $P_{altın(getiri)}$ matrisleri altın getirilerinin ikinci (1b) ve üçüncü (1a) dereceden geçiş olasılıklarını göstermektedir.

$$P_{Altin(getir\ddot{i})} = \begin{matrix} (+ + +) \\ (+ + -) \\ (+ - +) \\ (- + +) \\ (- - +) \\ (- + -) \\ (+ - -) \\ (- - -) \end{matrix} \begin{bmatrix} 0,410 & 0,590 \\ 0,553 & 0,447 \\ 0,469 & 0,531 \\ 0,569 & 0,431 \\ 0,457 & 0,543 \\ 0,471 & 0,529 \\ 0,537 & 0,463 \\ 0,463 & 0,537 \end{bmatrix}$$

(1a)

$$P_{Altin(getir\ddot{i})} = \begin{matrix} (++) \\ (+-) \\ (-+) \\ (--) \end{matrix} \begin{bmatrix} 0,498 & 0,502 \\ 0,538 & 0,462 \\ 0,473 & 0,527 \\ 0,511 & 0,489 \end{bmatrix}$$

(1b)

Aşağıdaki tablolar Altın getirileri serisiyle ilgili geçiş olasılıkları matrisindeki bütün Yapay sinir ağlarının (YSA) doğru sınıflama başarısını özetlemektedir.

Model	(+) yönü doğru tahmin etme başarısı (%)	(-) yönü doğru tahmin etme başarısı (%)	Toplam doğru tahmin etme başarısı (%)
(+ + +)	50,4	50,7	50,6
(+ - -)	58,2	50,8	54,6
(- + +)	51,3	56,4	54,0
(- - -)	52,0	50,0	51,1
Ortalama	52,98	51,98	52,58

Tablo 1. Altın Getirilerine Ait YSA Modelleri Sınıflama Başarıları

Model	(+) yönü doğru tahmin etme başarısı (%)	(-) yönü doğru tahmin etme başarısı (%)	Toplam doğru tahmin etme başarısı (%)
(+ + +)	50,0	65,7	59,0
(+ + -)	60,0	50,0	56,0
(+ - +)	52,2	57,9	55,2
(- + +)	67,9	53,5	60,5
(- - +)	50,8	59,4	55,1
(- + -)	57,3	62,2	59,9
(+ - -)	60,3	54,0	57,4
(- - -)	60,9	69,5	65,0
Ortalama	57,43	59,03	58,51

Tablo 2. Altın Getirilerine Ait YSA Modelleri Sınıflama Başarıları

Tablo1 ikinci dereceden modellerin başarılarını Tablo2 ise üçüncü dereceden modellerin sınıflama başarısını göstermektedir. Tabloya göre ikinci dereceden YSA'nın ortalama toplam doğru tahmin etme başarısı %52,58'dir. Bu oran üçüncü dereceden YSA modellerinde %58,51 düzeyine çıkmaktadır. Ayrıca tek tek bakıldığında ikinci dereceden modellerin en güçlü tahmini %58,2 olarak gerçekleşmişken üçüncü dereceden modellerin en güçlü tahmini %69,5 olarak gerçekleşmiştir. Bu istatistiklerin dışında ikinci dereceden modeller (+) yönlü getirileri %52,98 oranında, (-) yönlü getirileri 51,98 oranında doğru tahmin etmiştir. Bu oranlar Tablo2'de %57,43 ve 59,03 olarak gerçekleşmiştir. Borsa İstanbul 100 indeksine ait olasılıklar şu şekilde gerçekleşmiştir.

$$P_{Bist100(getir\ddot{i})} = \begin{matrix} (+ + +) \\ (+ + -) \\ (+ - +) \\ (- + +) \\ (- - +) \\ (- + -) \\ (+ - -) \\ (- - -) \end{matrix} \begin{bmatrix} 0,494 & 0,506 \\ 0,417 & 0,583 \\ 0,451 & 0,549 \\ 0,605 & 0,395 \\ 0,452 & 0,548 \\ 0,548 & 0,452 \\ 0,534 & 0,466 \\ 0,534 & 0,466 \end{bmatrix}$$

(2a)

$$P_{Bist100(getir\ddot{i})} = \begin{matrix} (++) \\ (+-) \\ (-+) \\ (--) \end{matrix} \begin{bmatrix} 0,338 & 0,662 \\ 0,495 & 0,505 \\ 0,510 & 0,490 \\ 0,557 & 0,443 \end{bmatrix}$$

(2b)

(2a) BİST100 indeksine ait üçüncü dereceden geçiş olasılığı matrisini gösterirken (2b) BİST100 indeksine ait ikinci dereceden geçiş olasılığı matrisini göstermektedir.

Model	(+) yönü doğru tahmin etme başarısı (%)	(-) yönü doğru tahmin etme başarısı (%)	Toplam doğru tahmin etme başarısı (%)
(+ + +)	33,5	65,9	49,1
(+ - -)	52,3	53,6	52,9
(- + -)	55,0	54,0	54,5
(- - -)	59,3	48,7	54,6
Ortalama	50,03	55,55	52,78

Tablo 3. BİST100 İndeksine Ait İkinci Dereceden YSA Modellerinin Sınıflama Başarıları

Model	(+) yönü doğru tahmin etme başarısı (%)	(-) yönü doğru tahmin etme başarısı (%)	Toplam doğru tahmin etme başarısı (%)
(+ + +)	51,7	53,6	52,5
(+ + -)	45,2	63,3	52,8
(+ - +)	50,0	62,1	54,9
(- + +)	61,6	41,1	52,7
(- - +)	53,5	63,3	58,3
(- + -)	64,5	55,7	60,3
(+ - -)	58,3	52,3	55,5
(- - -)	61,5	52,3	60,1
Ortalama	55,79	55,46	55,89

Tablo 4. BİST100 İndeksine Ait Üçüncü Dereceden YSA Modellerinin Sınıflama Başarıları

Tablo3 ve Tablo4’de sırasıyla BİST100 indeksine ait ikinci dereceden YSA modeli ve üçüncü dereceden YSA modelinin doğru sınıflama başarıları özetlenmiştir. Tahmin edilen geçiş olasılıkları matrislerine göre getirilerin (+) veya (-) olma olasılıkları genel olarak %45-%55 aralığında gerçekleşmiştir. YSA modellerin performanslarına baktığımızda ise üçüncü dereceden modellerin ikinci dereceden modellere kıyasla daha iyi performans gösterdikleri görülmektedir. Üçüncü dereceden modellere göre ekstra %5,89 oranında bilgiye sahip olmaktayız. İkinci dereceden modellere göre ise bu oran %2,78 seviyesine düşmektedir. Bütün modeller incelendiğinde (+) yönlü getiri maksimum %61,6 oranında doğru tahmin edilebilirken (-) yönlü getiri %65,9 oranında tahmin edilebilmiştir. Son olarak USD/TL döviz kuru serisine ait geçiş olasılıkları matrisleri ve doğru sınıflama başarıları şu şekilde gerçekleşmiştir.

$$P_{USD/TL(\text{getiri})} = \begin{matrix} (+ + +) \\ (+ + -) \\ (+ - +) \\ (- + +) \\ (- - +) \\ (- + -) \\ (+ - -) \\ (- - -) \end{matrix} \begin{bmatrix} 0,528 & 0,472 \\ 0,487 & 0,513 \\ 0,503 & 0,497 \\ 0,503 & 0,497 \\ 0,495 & 0,505 \\ 0,446 & 0,554 \\ 0,335 & 0,665 \\ 0,253 & 0,747 \end{bmatrix} \quad (3a)$$

$$P_{USD/TL(\text{getiri})} = \begin{matrix} (+ +) \\ (+ -) \\ (- +) \\ (- -) \end{matrix} \begin{bmatrix} 0,493 & 0,507 \\ 0,133 & 0,867 \\ 0,512 & 0,488 \\ 0,202 & 0,798 \end{bmatrix} \quad (3b)$$

(3a) USD/TL döviz kuruna ait üçüncü dereceden Markov zinciri geçiş olasılığı matrisini gösterirken (3b) aynı seriye ait ikinci dereceden Markov zinciri geçiş olasılığı matrisini göstermektedir.

Model	(+) yönü doğru tahmin etme başarısı (%)	(-) yönü doğru tahmin etme başarısı (%)	Toplam doğru tahmin etme başarısı (%)
(+ + +)	61,0	55,7	58,4
(+ + -)	49,6	51,9	50,9
(+ - +)	58,6	58,8	58,7
(- + +)	56,0	54,8	55,4
(- - +)	58,6	59,5	59,0
(- + -)	51,9	60,7	57,0
(+ - -)	35,2	67,7	55,0
(- - -)	32,4	79,9	59,9
Ortalama	50,41	61,125	56,79

Tablo 5. USD/TL Döviz Kuruna Ait Üçüncü Dereceden YSA Modellerinin Sınıflama Başarıları

Model	(+) yönü doğru tahmin etme başarısı (%)	(-) yönü doğru tahmin etme başarısı (%)	Toplam doğru tahmin etme başarısı (%)
(+ +)	55,8	54,2	55,0
(+ -)	14,2	87,4	55,3
(- +)	51,8	49,5	50,6
(- -)	20,6	80,1	54,7
Ortalama	35,6	67,8	53,9

Tablo 6. USD/TL Döviz Kuruna Ait İkinci Dereceden YSA Modellerinin Sınıflama Başarıları

Tablo4 ve Tablo5 USD/TL döviz kuruna ait ikinci ve üçüncü dereceden YSA modellerin bilgilerini özetlemektedir. Buna göre üçüncü dereceden YSA modelleri ortalama olarak %56,79 oranında doğru sınıflama yapmıştır. Tablo4’den anlaşılabileceği gibi (- - -) modeli (+) yönü çok iyi tahmin edemese de (-) getiriyi %79,9 ile diğer modellere kıyasla en iyi tahmin eden model olmuştur. Yine USD/TL döviz kuru tahmininin de üçüncü dereceden YSA modelleri ikinci dereceden modellere göre daha iyi sonuçlar vermişlerdir. Yöntem kısmında her bir modelin yaklaşık 100 denemeden sonra seçildiği ve seçim kriterlerinin en yüksek toplam doğru tahmin etme başarısı ile modellerin getiri yönlerini minimum %50 doğru tahmin etmeleri olarak belirlendiği vurgulanmıştır. Fakat bazı modelleri her iki yönü %50’den yüksek tahmin edemediği görülmektedir. Bunun sebebi YSA’nın yapılan 100 deneme sonucunda minimum %50 sınıflama başarısının yakalanamamış olmasıdır. Dolayısıyla bu modeller için sadece en iyi toplam doğru sınıflama başarısı göz önünde bulundurulmuştur.

5 Sonuç

Markov zincirleri ve Yapay sinir ağlarının değişkenliği çok fazla olan serilerde lineer modellere kıyasla tahmin gücünün daha iyi olduğu önceki çalışmalardan anlaşılmaktadır. Bu çalışmada YSA ve Markov zincirleri birleştirilerek modellerin tahmin gücünün yanında geçiş olasılıkları matrisine ait her bir olasılığın doğru sınıflama başarısını da görme şansını elde ettik. Böylelikle herhangi bir serinin herhangi bir modeli için bir sonraki getiri yönünün % kaç olasılıkla (-) ve ya (+) olacağını söylemenin yanında bu gerçekleşecek olasılığın da % kaç olasılıkla doğru olacağını görebiliyoruz. Örneğin altın fiyatları serisi için son üç günün getirisi (- - -) olduğunda sonraki günün (-) olma olasılığı %53,7 ve bu ve eğer ilgili YSA modeli (-) tahmin ediyorsa bu tahmin % 69,5 olasılıkla doğru olacaktır. Aynı şekilde sonraki günün getirisinin (+) olma olasılığı %46,3 iken bu olasılığa bağlı modelin (+) tahmini %60,9 oranında doğru olacaktır. Serilerin tahmin edilme başarılarına bakıldığında en iyi performansın altın fiyatları serisine ait olduğu görülmektedir. Ayrıca altın serisi de dahil olması koşuluyla bütün seriler için üçüncü dereceden YSA modelleri ikinci dereceden YSA modellerinden üstün performans gösterdiği sonucuna da varılabilir. Finansal piyasalar etkin piyasalara en yakın piyasalar olması ya da başka bir ifade ile verilerin tarihsel özelliklerinden yararlanarak gelecek ile ilgili tahmin yapma zorluğu böyle bir sonucu doğurmuş olabilir. Bu doğrultuda iki gecikmenin dahil edildiği modellerin üç gecikme dahil edilen modellere göre daha az bilgi içermesi olağan karşılanabilir. Bunun doğruluğunu görmek adına serilerin birinci dereceden ve dördüncü dereceden YSA modellerine bakılabilir. Ayrıca bütün serilerin ayıca her bir derece için serilerin rassal yürüyüş sergileyip sergilemediği analiz edilebilir.

Kaynakça

- Aşkın, Güzin ve Gülüzar,2012. Altın Fiyatlarındaki Dağılımların Markov Zinciri ile Analizi: Uzun Erimli Olasılıklar. *Erciyes Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*. Sayı **40**,ss.119-142
- Can, T., ve Öz, E. (2009). Saklı Markov modelleri kullanılarak Türkiye’de dolar kurundaki değişimin tahmin edilmesi. *İstanbul Üniversitesi İşletme Fakültesi Dergisi*, **38(1)**, 1-23.
- Guresen, E., Kayakutlu, G., & Daim, T. U. (2011). Using artificial neural network models in stock market index prediction. *Expert Systems with Applications*, **38(8)**, 10389-10397.
- Engel, C., ve Hamilton, J. D. (1990). Long swings in the dollar: Are they in the data and do markets know it?. *The American Economic Review*, 689-713.
- İLARSLAN, K. (2014). Hisse Senedi Fiyat Hareketlerinin Tahmin Edilmesinde Markov Zincirlerinin Kullanılması: İMKB 10 Bankacılık Endeksi İşletmeleri Üzerine Ampirik Bir Çalışma. *Journal of Yasar University*, **35(9)**.
- Kamruzzaman, J., ve Sarker, R. A. (2003, December). Forecasting of currency exchange rates using ANN: A case study. In *Neural Networks and Signal Processing, 2003. Proceedings of the 2003 International Conference on* (Vol. 1, pp. 793-797). IEEE.
- Kanas, A. (2003). Non-linear forecasts of stock returns. *Journal of Forecasting*, **22(4)**, 299-315.
- KILIÇ, S. B. (2013). Predicting the Direction of Gold Price Returns: Integrating Composite Artificial Neural Network Models by Markov Chain Process. *Çukurova Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, **17(2)**.

- Leung, M. T., Chen, A. S., ve Daouk, H. (2000). Forecasting exchange rates using general regression neural networks. *Computers & Operations Research*, **27(11)**, 1093-1110.
- Malkiel, B. G., ve Fama, E. F. (1970). Efficient capital markets: A review of theory and empirical work. *The Journal of Finance*, **25(2)**, 383-417.
- Marsh, I. W. (2000). High-frequency Markov switching models in the foreign exchange market. *Journal of Forecasting*, **19(2)**, 123-134.
- McQueen, G., ve Thorley, S. (1991). Are stock returns predictable? A test using Markov chains. *The Journal of Finance*, **46(1)**, 239-263.
- Mills, T. C., ve Jordanov, J. V. (2003). The size effect and the random walk hypothesis: Evidence from the London Stock Exchange using Markov chains. *Applied Financial Economics*, **13(11)**, 807-815.
- Nag, A. K., ve Mitra, A. (2002). Forecasting daily foreign exchange rates using genetically optimized neural networks. *Journal of Forecasting*, **21(7)**, 501-511.
- Onalan, O. (2014). Currency exchange rate estimation using Grey Markov Prediction Model. *Journal of Economics Finance and Accounting*, **1(3)**, 205-217.
- Paksoy, S., ve Kilic, S. B. (2015). Forecasting the Direction of BIST 100 Returns with Artificial Neural Network Models. *International Journal of Latest Trends in Finance and Economic Sciences*, **4(3)**, 7.
- Panda, C., & Narasimhan, V. (2007). Forecasting exchange rate better with artificial neural network. *Journal of Policy Modeling*, **29(2)**, 227-236.
- Ryan, T. M. (1973). Security prices as Markov processes. *Journal of Financial and Quantitative Analysis*, **8(01)**, 17-36.
- Shin, T., ve Han, I. (2000). Optimal signal multi-resolution by genetic algorithms to support artificial neural networks for exchange-rate forecasting. *Expert Systems with Applications*, **18(4)**, 257-269.
- Yu, L., Wang, S., & Lai, K. K. (2010). *Foreign-exchange-rate forecasting with artificial neural networks (Vol. 107)*. Springer Science & Business Media.
- Zhang, G., & Hu, M. Y. (1998). Neural network forecasting of the British pound/US dollar exchange rate. *Omega*, **26(4)**, 495-506.