

---

## ALTIN FİYATI GÜNLÜK GETİRİLERİNİN YAPAY SİNİR AĞLARI ALGORİTMASI VE MARKOV ZİNCİRLERİ MODELLERİ İLE TAHMİNİ

---

Salih ÇAM<sup>1</sup>

Süleyman Bilgin KILIÇ<sup>2</sup>

### Öz

Son on yılda altın fiyatları ile ilgili birçok çalışma yapılmıştır. Literatürdeki ilgili çalışmalar yapay sinir ağları algoritması ve Markov zincirleri modellerinin altın piyasası gelecek tahmininde oldukça iyi sonuçlar ürettiklerini göstermektedir. Bu çalışmada yapay sinir ağları algoritması ve Markov zincirleri modellerinin güçlü yönleri birlikte kullanılarak altın fiyatlarının günlük getirileri tahmin edilmiştir. Tahmin süreci, iki aşamada gerçekleştirilmiştir. İlk aşamada altın fiyatlarının günlük getirileri, en iyi tahmin performansına sahip yapay sinir ağları algoritması ile tahmin edilmiştir. İkinci aşamada ise yapay sinir ağlarından elde edilen tahmini altın getirileri üzerinden yüksek dereceden Markov zincirleri geçiş olasılıkları matrisleri hesaplanmıştır. Tahmin, üçüncü dereceden ve dördüncü dereceden Markov zincirleri modelleri ile yapay sinir ağları algoritması birlikte kullanılarak yapılmıştır ve uygulanan tahmin yöntemi sonucunda altın fiyatları getirilerinin gelecek tahmininde %70'i bulan başarı sağlanmıştır.

**Anahtar Kelimeler:** Yapay Sinir Ağları, Markov Zincirleri Modelleri, Altın Fiyatları

**JEL Sınıflandırması:** G1, C1, C4

---

## PREDICTION OF DAILY GOLD PRICE RETURNS WITH ARTIFICIAL NEURAL NETWORKS AND MARKOV CHAINS MODELS

---

### Abstract

During the last decade, there have been many studies on the prediction of gold prices. Artificial neural networks algorithm and Markov chains models perform fairly well in the prediction of gold prices. In this study, the daily returns of gold prices were estimated by using the powerful aspects of the artificial neural network algorithm and the Markov chains models. The prediction was made in two stages. In the first stage, the daily return series of gold prices were estimated by the artificial neural network algorithm which has the best prediction performance. In the second stage, the transition probabilities matrixes of high order Markov chains models were calculated from the estimated values that obtained from the artificial neural networks. The third order and the fourth order Markov chains models and the artificial neural networks algorithm were used jointly for prediction. In consequence of the applied methodology, about 70% success of prediction was achieved in the future prediction of the gold prices' returns.

**Key Words:** Artificial Neural Network, Markov Chains Models, Gold Price

**JEL Classification:** G1, C1, C4

---

<sup>1</sup> Arş. Gör., Çukurova Üniversitesi, İİBF, Ekonometri Bölümü, scam@cu.edu.tr

<sup>2</sup> Prof. Dr., Çukurova Üniversitesi, İİBF, Ekonometri Bölümü, sbilgin@cu.edu.tr

DOI: 10.18092/ulikidince.347048

Makalenin Geliş Tarihi (Received Date): 27-10-2017

Yayına Kabul Tarihi (Acceptance Date): 16-01-2018

## 1. Giriş

Altın dünyadaki en değerli madenlerden bir tanesidir. Yatırımcılar altını her zaman güvenli bir liman olarak görmektedir. Altın, savaş dönemleri de dâhil olmak üzere değerini koruyabilen tek maldır. Altının önemli bir yatırım aracı olması, altın fiyatlarının tahmini ile ilgili birçok çalışma yapılmasına neden olmuştur. Özellikle ilk defa Amerikalı ekonomist Eugene Fama (1970: 383) tarafından ortaya atılan etkin piyasa hipotezinden bu yana çalışmalar hız kazanmıştır. Fama'nın etkin piyasa hipotezine göre, etkin bir piyasa yeterince büyüktür ve bu piyasada birbirleri ile kar maksimizasyonu için rekabet eden birçok aktör vardır. Dolayısıyla tek alıcı veya satıcı piyasa fiyatını belirleyemez. 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 ve tahmin teknikleri kullanarak geleceğe yönelik 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 uzun dönemde ortalamanın üstünde getiri elde edilemez. Bu tür bir piyasada ortalamanın üstünde getiri sağlamak için halka açık olmayan (içeriden) bilgi sağlanmalıdır. Nihayet güçlü etkin bir piyasada, halka açık bilginin yanında içeriden bilgi de ortalamanın üstünde kar sağlamak adına yarar sağlamayacaktır. Dolayısıyla uzun dönem ortalama karı piyasa ortalama karının üstünde olması mümkün değildir.

Finansal piyasaların özelliklerine bakıldığında, etkin piyasalara en yakın piyasalar oldukları görülmektedir. Finansal piyasa verileri hem doğrusal hem de doğrusal olmayan ilişkiler içerdiğinden tahminleri oldukça zordur. Geleneksel ekonometrik modeller doğrusal ilişkileri yakalamakta başarılı olmalarına rağmen doğrusal olmayan ilişkileri yakalamakta zayıf kalmaktadırlar. Bu noktada yapay sinir ağları algoritması çok önemli bir tahmin yöntemi olarak karşımıza çıkmaktadır. Yapay sinir ağlarının yapısında kullanılan fonksiyonlar karmaşık yapıdaki serileri tahmin etmekte çok önemli bir rol oynar. Doğru fonksiyon seçimi ve doğru ağ yapısıyla yapay sinir ağı algoritmasından yüksek sınıflama başarıları elde edilebilmektedir. Kullanılan fonksiyon çeşitleri ve yapay sinir ağları algoritmasının genelleme özelliği bu algoritmanın en güçlü yönlerini oluşturmaktadır. Nitekim literatürde, yapay sinir ağları algoritması karmaşık yapıdaki verilerin gelecek tahminlerinde diğer birçok ekonometrik yöntemle karşılaştırıldığında daha başarılı sonuçlar ürettiği görülmüştür. Yapay sinir ağları algoritmasının yanı sıra finansal serilerin gelecek tahmininde kullanılan diğer bir yöntem Markov zincirleri modelleridir. Markov zincirleri modelleri, geçiş olasılıkları yardımı ile öngörüsü zor ve karmaşık yapıdaki finansal serilerin tahmininde başarılı sonuçlar üretmektedir. Bu çalışmadaki amaç yapay sinir ağları algoritması ve Markov zincirleri modellerinin güçlü yönlerini birlikte kullanarak tahmin başarısını artırmaktır. Tahmin başarısına ek olarak kullanılan metodoloji, yapılacak olan tahminin gerçekleşme olasılığının da elde edilmesini sağlayacaktır. Böylece yatırımcı bir sonraki günün pozitif veya negatif getiriye sahip olacağını Markov zincirlerinin geçiş olasılıkları matrisinden elde ederken, yapacağı tahminin doğru olma olasılığına da Yapay sinir ağları algoritması yardımıyla hesaplayabilecektir.

Çalışmanın bundan sonraki kısmında şu başlıklar yer alacaktır. İkinci bölümde konu ile ilgili daha önce yapılmış olan çalışmaların özeti kronolojik sıra ile verilecektir. Üçüncü bölümde ise yapay sinir ağları algoritması ile Markov zincirleri modellerinin teorisinden bahsedilecek ve çalışmada kullanılan veri seti tanıtılacaktır. Dördüncü bölümde uygulama ve analiz detayları yer alacak ve son bölümde elde edilen sonuçlar özetlenecektir.

## 2. Literatür

Altın fiyatları başta olmak üzere, finansal piyasalarla ilgili geçmişte birçok çalışma yapılmıştır. Burada öncelikle Markov zincirleri modelleri kullanılarak yapılmış çalışmalar kronolojik sıraya göre verilmiştir. Sonrasında Yapay sinir ağları algoritması ile ilgili literatür özetlenmiştir. Markov zincirleri modelleriyle ilgili, konunun teorik yönünü inceleyen çalışmalara Rosenblatt ve Slepian (1962), Raftery (1985), Hamilton (1989), Berchtold ve Raftery (2002) ve Kim, Piger ve Startz (2007) örnek

olarak gösterilebilir. Markov zincirleri modellerine duyulan ilgi, özellikle Hamilton (1989) çalışmasından sonra önemli bir ivme kazanmıştır. Yazar bu çalışmasında literatürde daha önce sıkça kullanılan doğrusal modellere karşı doğrusal olmayan bir tahmin model önermiş ve önerdiği bu modelin özellikle rejim değişikliği yaşayan zaman serilerinde doğrusal modellere göre daha başarılı sonuçlar ürettiğini ileri sürmüştür. Hamilton (1989) çalışmasından sonra Markov zincirleri modellerinin finansal piyasaların tahminindeki kullanımı oldukça yaygınlaşmıştır. Markov zincirleri modelleri için seçilmiş çalışmalar şu şekilde özetlenebilir. McQueen ve Thorley (1991) çalışmalarında 1947-1987 dönemi için New York Borsasına ait yıllık borsa verilerinin rassal yürüyüş sınavasını Markov zincirleri modellerini kullanarak analiz etmiştir. Diğer bir ifade ile borsa verilerinin Markov zincirleri modelleri ile tahmin edilip edilemediğini araştırmıştır. Araştırmacılar yaptıkları analizler sonucunda New York Borsasına ait yıllık verilerin rassal yürüyüş sergilemediğini ve Markov zincirleri modelleriyle modellenebileceği sonucuna varmıştır. Marsh (2000), Japon Yeni, Alman Markı ve İngiliz Sterlinini iki durumlu Markov zinciri olarak modellediği çalışmada, döviz kurlarına ait verileri 1980-1985, 1980-1990 ve 1980-1995 olmak üzere üç dönem olarak ele almıştır. Marsh incelediği değişkenlerin verilerini üç günlük getiri serisi olarak incelemiş ve serilerin Markov sürecine iyi uyum sağladığı sonucuna varmıştır. Araştırmacı yaptığı analizler neticesinde model performansının 1990'lı yıllar için biraz düştüğünü ve en düşük performansın İngiliz Sterlini tahmininden elde edildiği sonucuna varmıştır. Diğer bir çalışma Mills ve Jordanov (2003) tarafından yapılmıştır. Araştırmacılar çalışmalarında 1982-1995 dönemine ait Londra Borsasının aylık verilerine Markov zincirleri modellerini uygulayarak, işlem hacminin arttığı dönemlerde gelecek tahmini yapmanın zorlaştığı işlem hacminin düştüğü zamanlarda ise tahmin başarısının arttığı sonucuna ulaşmıştır. Kılıç (2013) Markov zincirleri ve Yapay sinir ağları modellerini birlikte kullanarak USD/TRY döviz kurunu tahmin ettiği çalışmada 02 Ocak 1995 ve 30 Ekim 2012 dönemini kapsayan günlük getiri serisini ele almış ve yapay sinir ağı algoritması ile Markov zincirleri modellerini birlikte kullanılarak yüksek tahmin başarısı sağlamıştır. Kanas (2003) New York Borsasına ait 1872-1999 dönemini kapsayan yıllık verileri kullanarak New York Borsasıyla ilgili tahmin yapmıştır. Tahmin için ikisi parametrik ikisi parametrik olmayan dört tahmin yöntemi kullanmıştır. Parametrik yöntemlerden biri olarak Markov zincirleri modelini, parametrik olmayan yöntemlerden biri olarak da Yapay sinir ağları algoritmasını kullanmış ve bu iki yöntemin en az diğerleri kadar iyi performans sergilediği sonucuna varmıştır. Ayrıca araştırmacı belirlediği karşılaştırma kriterlerine göre sıralama yaptığında en iyi tahmin performansının Markov zincirleri modellerine ait olduğu sonucuna varmıştır. Tahmin metodu olarak Markov zincirleri modellerini kullanan diğer çalışmalara Kanas ve Genius (2005) , Öz (2009), Can ve Öz (2009), Mamipour ve Jezeie (2015) örnek olarak verilebilir. Markov zincirleriyle ilgili literatürden sonra çalışmanın ikinci kısmını oluşturan Yapay sinir ağları algoritmasıyla ilgili çalışmalar özetlenecektir.

Tam ve Kiang (1992) bankaların batma durumlarını Yapay sinir ağları algoritmasını kullanarak araştırdıkları çalışmalarında, Yapay sinir ağı sonuçlarını Lojistik regresyon lineer sınıflayıcı, k en yakın komşu ve lineer faktör analizi sonuçları ile karşılaştırmıştır. Yapılan karşılaştırmalar neticesinde Yapay sinir ağlarının bahsi geçen metotlardan üstün sonuçlara sahip olduğu sonucuna varılmıştır. Khashei, Hejazi ve Bijari (2007) çalışmalarında Yapay sinir ağları algoritması ve bulanık regresyon modellerini finansal piyasaların zaman serisi verilerine uygulamıştır. Araştırmacıların uyguladıkları hibrit yöntem finansal piyasaların gelecek tahminiyle ilgili güçlü sonuçlar üretmiştir. Özkan (2012) USD/TRY ve EU/TRY döviz kurlarını Yapay sinir ağları ve yapısal döviz kuru tahmin metotlarından bir tanesi olan parasal model ile tahmin etmiş ve elde ettiği sonuçları karşılaştırmıştır. Özkan yaptığı karşılaştırmalar sonucunda Yapay sinir ağları algoritmasının oynaklığı fazla olan döviz kuru tahmini için güçlü bir tahmin tekniği olduğu sonucuna varmıştır. Godarzi vd. (2014) çalışmalarında OECD ülkelerine ait makroekonomik büyüklüklere dinamik yapay sinir ağı algoritması (NARX) uygulamıştır. Çalışmada 1974-2009 yıllarını kapsayan veri seti eğitim verisi ve test verisi olmak üzere ikiye ayrılmıştır. Araştırmacılar yaptıkları karşılaştırmalar sonucunda çalışmada uygulanan yöntemin zaman serisi modellerinden daha iyi tahmin performansına sahip olduğu sonucuna varmıştır. Aydın ve Cavdar (2015) USD/TRY döviz kurunun altın fiyatları ve Borsa İstanbul 100 endeksi ile ilişkisini yapay sinir ağları ve VAR modellerini

kullanarak analiz etmiştir. Çalışmalarında aylık veriler kullanan araştırmacılar yapay sinir ağları algoritması ve VAR modellerini ayrı ayrı tahmin etmiş ve sonuçlarını karşılaştırmıştır. Yapılan analizler, yapay sinir ağları algoritmasının VAR modellerinden daha iyi tahmin sonuçları ürettiğini göstermiştir. Yüksel ve Akkoç (2016) altın fiyatlarını gümüş fiyatları, Brent petrol fiyatları, ABD Doları/Euro paritesi, EuroNext100, Dow Jones endeksi, ABD bonosu faiz oranı ve ABD TÜFE endeksini kullanarak Yapay sinir ağı algoritmasıyla tahmin etmiştir. Yüksel ve Akkoç belirledikleri kriterlere göre yaptıkları değerlendirme neticesinde Yapay sinir ağlarının altın fiyatlarını tahmin etmekte kullanılabileceği sonucuna varmıştır. Bu çalışmalara ek olarak Zhang ve Hu (1998), Leung, Chen ve Daouk (2000), Shin ve Han (2000), Nag ve Mitra (2002), Karmruzzaman ve Sarker (2003), Şeker vd. (2004), Panda ve Narasimhan (2007), Altan (2008), Kaynar ve Taştan (2009), Majhi, Panda ve Sahoo (2009), Paksoy ve Kılıç (2015) da çalışmalarında yapay sinir ağları algoritmasını kullanmışlardır.

### 3. Veri Seti ve Metodoloji

Çalışmada Türkiye'ye ait 2 Ocak 2008 ile 28 Şubat 2017 tarihleri arasındaki günlük altın/ons kapanış fiyatları serisi kullanılmıştır. Altın fiyatları günlük düzey olarak Türkiye Cumhuriyet Merkez Bankası veri tabanından elde edilmiştir. Altın fiyatlarının getirilerini hesaplamak amacıyla, t dönemi ile t+1 dönemi arasındaki getiriyi hesaplamakta daha duyarlı olan  $r_t = \log P_t - \log P_{t-1}$  dönüşümü yapılmıştır. Burada  $P_t$  t günündeki altın/ons düzey fiyatını ve  $r_t$  ise t günündeki altın getirisini göstermektedir. Hesaplanan getirilerden yola çıkarak, pozitif getiriler için "1", negatif getiriler için "0" değerini alan "K" kukla değişkeni oluşturulmuştur. Yani;

$$K = \begin{cases} 1 & r_t > 0 \quad \text{ise} \\ 0 & r_t \leq 0 \quad \text{ise} \end{cases}$$

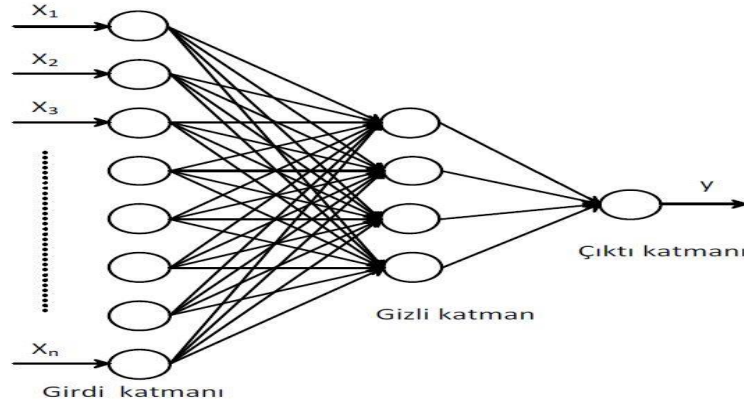
olacak şekilde K kukla değişkeni elde edilmiştir. Dördüncü dereceden Markov zincirlerinin geçiş olasılıklarını hesaplamak amacıyla, K değişkeninin bir gecikmeli, iki gecikmeli, üç gecikmeli ve dört gecikmeli değerine sahip olmak üzere dört yeni değişken oluşturulmuştur. Oluşturulan gecikmeli değerlere bağlı olarak on altı ( $2^4=16$ ) farklı durumu gösteren veri setleri hazırlanmıştır. Örneğin dört gecikmenin aynı anda pozitif olduğu süreç için bir veri seti, dört gecikmenin aynı anda negatif değer aldığı süreç için bir veri seti ve geriye kalan on dört olası durumun hepsi için ayrı veri setleri oluşturulmuştur. Elde edilen on altı farklı veri seti için on altı farklı yapay sinir ağı algoritması tahmin edilmiştir. Aynı işlemler üçüncü dereceden Markov zincirleri modelleri için de tekrarlanmıştır. Üçüncü dereceden Markov zincirlerinde ( $2^3=8$ ) durum mevcuttur ve buna bağlı olarak sekiz farklı veri seti oluşturulmuştur. Tahmin için kullanılan Yapay sinir ağları algoritmaları yaklaşık elli deneme sonunda en düşük nispi hataya ve en yüksek sınıflama başarısı sahip ağlar olarak seçilmiştir. Seçilen Yapay sinir ağları algoritmalarından elde edilen tahmini değerler yardımıyla yüksek dereceden Markov zincirlerinin geçiş olasılıkları hesaplanmıştır. Son olarak elde edilen geçiş olasılıkları ve yapay sinir ağlarının doğru sınıflama başarıları birlikte kullanılarak tahmin başarıları hesaplanmıştır.

#### 3.1. Yapay Sinir Ağları Algoritması

Yapay sinir ağları algoritması diğer birçok uygulama alanına ek olarak, ara değer hesaplama, sınıflama yapma, sinyal filtreleme ve kümeleme gibi işlevler gören güçlü bir parametrik olmayan tahmin yöntemidir. Yapay sinir ağları pratikte birçok avantaja sahiptir. Bu avantajlarına ek olarak hataları tolere edebilme ve değişkenler arasında doğrusal olmayan ilişkileri yakalayabilme becerisine de sahiptir. Yapay sinir ağlarını geleneksel ekonometrik yöntemlerden ayıran en önemli avantajlarından biri, modelin işlevselliğini göz önüne almanın gerekli olmamasıdır, yani değişkenler arasındaki işlevsel ilişki üzerine varsayımların gerekli olmamasıdır. Bunun yanında tüm modellerde olduğu gibi iyi bir tahminde bulunmak için uygun model yapısının doğru saptanması gerekmektedir (Kristjanpoller ve Minutolo, 2016: 233). Bir yapay sinir ağı algoritmasının yapısında temel olarak bir girdi katmanı bir gizli katman ve bir çıktı katmanı yer almaktadır. Girdi ve çıktı katmanlarında birçok

fonksiyon kullanılmasına rağmen, finansal piyasa verilerine en uygun fonksiyon tipi giriş katmanı için hiperbolik tanjant, çıkış katmanı için sigmoid fonksiyon olduğu söylenebilir (Yu vd., 2007:28).

Şekil 1: Yapay Sinir Ağı Algoritmasının Temel Yapısı



Kaynak: www.tuzen.net

Şekil 1 bir Yapay sinir ağı algoritmasının temel yapısını göstermektedir.  $X_t$  girdi verisi matrisi,  $W_t$  girdi katmanı ile gizli katman arasındaki ağırlık matrisi,  $F_1$  girdi katmanı ile gizli katman arasındaki fonksiyon,  $V_t^T$  gizli katman ile çıktı katmanı arasındaki ağırlık matrisi ve  $F_2$  gizli katman ile çıktı katmanı arasındaki aktivasyon fonksiyonu olmak üzere, Yapay sinir ağının temel yapısı aşağıdaki şekilde ifade edilebilir.

$$\hat{Y}_{t+1} = F_2[(V_t^T F_1(W_t \cdot X_t))] \quad (1)$$

Burada,  $X = (x_0, x_1, \dots, x_p)^T \in R^{(p+1) \times 1}$  yapay sinir ağının giriş verisi vektörünü gösterirken  $Y = (y_0, y_1, \dots, y_k)^T \in R^{(k+1)}$  yapay sinir ağının çıktı verisi vektörünü göstermektedir. Katmanlar arasındaki ağırlık matrisleri

$$W = \begin{bmatrix} w_{10} & w_{11} & \dots & w_{1p} \\ w_{20} & w_{22} & \dots & w_{2p} \\ \dots & \dots & \dots & \dots \\ w_{q0} & w_{q1} & \dots & w_{qp} \end{bmatrix} = (W_0, W_1, \dots, W_p) \in R^{q \times (p+1)}$$

$$V = \begin{bmatrix} v_{10} & v_{20} & \dots & v_{k0} \\ v_{11} & v_{21} & \dots & v_{k1} \\ \dots & \dots & \dots & \dots \\ v_{1q} & v_{2q} & \dots & v_{kq} \end{bmatrix} = (V_0, V_1, \dots, V_K) \in R^{(q+1) \times k}$$

şeklinde tanımlanmıştır.  $W$  ağırlık matrisinin ilk sütünü girdi katmanı ile gizli katman arasındaki hata terimlerini temsil ederken,  $V$  ağırlık matrisinin ilk satırı gizli katman ile çıktı katmanı arasındaki hata terimlerini temsil etmektedir. Eşitlik (1)'deki genel ifadede yer alan  $F_1(W_t \cdot X_t)$  fonksiyonu,

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

olarak yazılabilir. Burada  $net_{i(t)} = \sum_{j=0}^p w_{ij(t)} \cdot x_{j(t)}$ ,  $i = 0, 1, \dots, q$ 'dir.  $w_{i0(t)}$ ,  $t=1, 2, \dots, q$  gizli katmanın

hata terimleri ve  $v_{ij(t)}$   $i = 1, 2, \dots, q$ ,  $j = 1, 2, \dots, k$  gizli katmandaki  $i$  düğümünden çıktı katmanındaki  $j$  düğümüne giden ağırlıklardır.  $v_{i0(t)}$  çıktı katmanındaki hata terimleridir (Yu vd., 2007:29).

### 3.2. Markov Zincirleri Modelleri

Adını Rus matematikçi Andrei Anderievich Markov'dan alan Markov zincirleri, belirsizlik altında karar alma tekniğidir. Öztürk (2014: 733) belirsizlik altında karar almayı şu şekilde ifade etmektedir: Karar problemlerinde, sıkça belirsizliklere dayanan olaylara ilişkin karar alma ile yüz yüze geliriz. Bu belirsizlik genelde, doğal olayın belirsizliğinden veya temel değişkenin akla gelmeyen değişim kaynağından ortaya çıkar. Bu değişkenliğe nitel olarak yaklaşımdan ziyade, onu matematiksel model haline dönüştürüp nicel olarak inceleriz. Doğal olay düzgünlüğün bazı derecelerini sergilerse, bu işlem yapılabilir ve onun değişkeni olasılık modeli ile tanımlanır.

$S_t$   $\{t=1, 2, 3, \dots, N\}$  tamsayı değerleri alan ve rassal dağılan bir değişken olsun. Birinci dereceden Markovian süreçler  $S_t$ 'nin şimdiki değerinin sadece  $S_{t-1}$  dönemine bağlı olduğunu varsayar.

$$P\{s_t = j / s_{t-1} = i, s_{t-2} = k, \dots\} = P\{s_t = j / s_{t-1} = i\} = P_{ij} \quad (3)$$

böyle bir süreç  $\{P_{ij} \}_{i,j=1,2,3,\dots,N}$  olasılık matrisi ve  $N$  durumlu Markov süreci olarak tanımlanır. Burada  $P_{ij}$  durum  $i$ 'den durum  $j$ 'ye geçiş olasılığını ifade etmektedir. Durum  $i$ 'den diğer tüm durumlara geçme olasılıkları toplamı bir eştir ve  $p_{i1} + p_{i2} + \dots + p_{iN} = 1$  şeklinde gösterilmektedir. Bütün geçiş olasılıklarını  $(N \times N)$  boyutlu  $P$  geçiş olasılıkları matrisinde toplamak mümkündür.

$$P = \begin{bmatrix} p_{11} & p_{12} & \dots & p_{1N} \\ p_{21} & p_{22} & \dots & p_{2N} \\ \dots & \dots & \dots & \dots \\ p_{N1} & p_{N2} & \dots & p_{NN} \end{bmatrix}_{N \times N}$$

$P$  geçiş olasılıkları matrisinde sütun  $j$  ve satır  $i$   $P_{ij}$  geçiş olasılığını göstermektedir (Hamilton, 1994: 678). Yukarıdaki tanımlamalar birinci dereceden  $N$  durumlu Markov sürecini tanımlamaktadır. Bunun yanında Markov zincirleri modellerini yüksek dereceden modellemek de mümkündür. Birinci dereceden Markov zincirleri hipotezi mevcut gözlemin sadece bir önceki gözlemden etkilendiğini ve daha önceki gözlemlerden etkilenmediğini söylemektedir. Fakat pratikte birçok değişken birden çok geçmiş değerden etkilenebilmektedir.

$$P\{s_t = j / s_{t-1} = i, s_{t-2} = k, \dots\} = P\{s_t = j / s_{t-1} = i, s_{t-2} = k\} = P_{kij} \quad (4)$$

Yukarıdaki süreç ikinci dereceden Markov sürecini ifade etmektedir. İkinci dereceden markovian sürecinin  $P$  geçiş olasılıkları matrisini aşağıdaki şekilde ifade etmek mümkündür. Buna göre  $P_{kij}$  gösterimindeki ilk indis iki dönem önce sistemin içinde bulunduğu durumu, ikinci indis bir önceki dönemde sistemin içinde bulunduğu durumu ve son indis ise sistemin mevcut durumunu temsil etmektedir.

$$P_{kij} = \begin{bmatrix} p_{111} & 0 & 0 & p_{112} & 0 & 0 & p_{113} & 0 & 0 \\ p_{211} & 0 & 0 & p_{212} & 0 & 0 & p_{213} & 0 & 0 \\ p_{311} & 0 & 0 & p_{312} & 0 & 0 & p_{313} & 0 & 0 \\ 0 & p_{121} & 0 & 0 & p_{122} & 0 & 0 & p_{123} & 0 \\ 0 & p_{221} & 0 & 0 & p_{222} & 0 & 0 & p_{223} & 0 \\ 0 & p_{321} & 0 & 0 & p_{322} & 0 & 0 & p_{323} & 0 \\ 0 & 0 & p_{131} & 0 & 0 & p_{312} & 0 & 0 & p_{133} \\ 0 & 0 & p_{231} & 0 & 0 & p_{232} & 0 & 0 & p_{233} \\ 0 & 0 & p_{331} & 0 & 0 & p_{332} & 0 & 0 & p_{333} \end{bmatrix}$$

$P_{kij}$  geçiş olasılıkları matrisi ikinci dereceden ve üç durumlu bir sistemin olasılık matrisidir. Yüksek dereceden Markov zincirinde  $n_{ik.....i0}$  geçiş tipinin sayısını gösterirken  $\hat{P}_{ik.....i0}$  ilgili geçiş olasılığını gösterdiğini varsayalım. Geçiş olasılığının en yüksek olabilirlik (EYO) tahmini şu şekilde hesaplanır.

$$\hat{P}_{ik.....i0} = \frac{n_{ik.....i0}}{n_{ik.....i1} + \sum_{i_0=1}^m n_{ik.....i0}}$$

olarak ifade edilebilir (Berchtold ve Raftery, 2002: 340). Bu olasılık ilgilenilen durum sayısının toplam durum sayısına bölümünden başka bir şey değildir. Aynı durum daha yüksek markov zincirleri için de genelleştirilebilir.

#### 4. Ampirik Bulgular

Uygulamada öncelikle dördüncü dereceden Markov zincirleri modelleri ve ilgili yapay sinir ağı algoritmalarının sonuçları verilmiştir. Daha sonra üçüncü dereceden Markov zincirleri ve ilgili yapay sinir ağlarının sonuçları özetlenmiştir. Tablo 1 altın fiyatları getiri serisinin t zamanın dört gün öncesinden itibaren, sistemin negatif veya pozitif getiriye sahip olma olasılıklarını göstermektedir. Tablodaki  $r_1$  (++++),  $r_2$  (-+++),  $r_3$  (+++) ,  $r_4$  (+++) ,  $r_5$  (+++),  $r_6$  (-++) ,  $r_7$  (-+-) ,  $r_8$  (-+-) ,  $r_9$  (+--),  $r_{10}$  (+--),  $r_{11}$  (+--),  $r_{12}$  (-+-) ,  $r_{13}$  (-+-) ,  $r_{14}$  (-+-) ,  $r_{15}$  (+-- ) ve  $r_{16}$  (-+-) dördüncü dereceden Markov zincirlerine ait getirilerin sırasıyla devam ettiği süreçleri temsil etmektedir. Geçiş olasılıklarındaki sıfır değerleri iki durum arasında geçişin mümkün olmadığı anlamına gelmektedir. Örneğin sistem dört gün boyunca pozitif  $r_1$  (++++) durumundayken sadece  $r_1$  (++++) ve  $r_5$  (+++ ) hücrelerindeki olasılıklar mevcut olacaktır ve geriye kalan hücrelerdeki değerlerin tamamı sıfır olacaktır. Bu durum dört gün üst üste pozitif getiriye sahip süreçten diğer süreçlere geçişin mümkün olmadığını göstermektedir. Geçiş olasılıkları matrisindeki bütün olasılık değerleri yapay sinir ağları algoritmalarından elde edilen tahmini getiriler üzerinden hesaplanmıştır. Buna göre dört gün boyunca pozitif getiri gerçekleşmesi durumunda, başka bir ifadeyle sistem  $r_1$  durumundayken bir sonraki gün %44 olasılıkla negatif getiriye, %56 olasılıkla pozitif getiriye sahip olması beklenmektedir. Dördüncü dereceden Markov zincirleri geçiş olasılıkları matrisi dört gün öncesine bağlı olarak t döneminde sistemin pozitif veya negatif getiriye sahip olma olasılıklarını içermektedir. Geçiş olasılıkları t+1 dönemi için tahmin sürecinin ilk adımını oluşturmaktadır.

Tablo 1'deki geçiş olasılıkları incelendiğinde olasılıkların çoğunlukla %45-%55 aralığında olduğu görülmektedir. %50'nin biraz altında ve üstündeki bu olasılık değerleri t+1 dönemi için getiri tahmin etmenin oldukça zor olduğunu ima etmektedir.

Tablo 1: Dördüncü Dereceden Markov Zincirleri Geçiş Olasılıkları Matrisi

	$r_1$	$r_2$	$r_3$	$r_4$	$r_5$	$r_6$	$r_7$	$r_8$	$r_9$	$r_{10}$	$r_{11}$	$r_{12}$	$r_{13}$	$r_{14}$	$r_{15}$	$r_{16}$
$r_1$	.44	.00	.00	.00	.56	.00	.00	.00	.00	.00	.00	.00	.00	.00	.00	.00
$r_2$	.00	.56	.00	.00	.00	.00	.00	.44	.00	.00	.00	.00	.00	.00	.00	.00
$r_3$	.00	.00	.42	.00	.00	.00	.00	.00	.00	.58	.00	.00	.00	.00	.00	.00
$r_4$	.00	.00	.00	.47	.00	.00	.00	.00	.00	.00	.53	.00	.00	.00	.00	.00
$r_5$	.61	.00	.00	.00	.39	.00	.00	.00	.00	.00	.00	.00	.00	.00	.00	.00
$r_6$	.00	.00	.00	.00	.00	.46	.00	.00	.00	.00	.00	.00	.54	.00	.00	.00
$r_7$	.00	.00	.00	.00	.00	.00	.52	.00	.00	.00	.00	.00	.00	.48	.00	.00
$r_8$	.00	.51	.00	.00	.00	.00	.00	.49	.00	.00	.00	.00	.00	.00	.00	.00
$r_9$	.00	.00	.00	.00	.00	.00	.00	.00	.50	.00	.00	.00	.00	.00	.50	.00
$r_{10}$	.00	.00	.63	.00	.00	.00	.00	.00	.00	.37	.00	.00	.00	.00	.00	.00
$r_{11}$	.00	.00	.00	.68	.00	.00	.00	.00	.00	.00	.32	.00	.00	.00	.00	.00
$r_{12}$	.00	.00	.00	.00	.00	.00	.00	.00	.00	.00	.00	.64	.00	.00	.00	.36
$r_{13}$	.00	.00	.00	.00	.00	.47	.00	.00	.00	.00	.00	.00	.53	.00	.00	.00
$r_{14}$	.00	.00	.00	.00	.00	.00	.54	.00	.00	.00	.00	.00	.00	.46	.00	.00
$r_{15}$	.00	.00	.00	.00	.00	.00	.00	.00	.56	.00	.00	.00	.00	.00	.44	.00
$r_{16}$	.00	.00	.00	.00	.00	.00	.00	.00	.00	.00	.00	.57	.00	.00	.00	.43

Yapay sinir ağı ile Markov zincirleri modellerinin birlikte kullanılmasındaki temel amaç %50'nin üzerinde ekstra bilgi sağlamaktır. Aksi halde zaten t+1 dönemindeki getirinin %50 olasılıkla negatif, %50 olasılıkla pozitif olacağı bilinmektedir. Dolayısıyla %50'nin üzerindeki ekstra bilgi tahmin başarısı olarak değerlendirilebilir. Markov zincirleri modellerinin yapay sinir ağları algoritmasıyla birlikte kullanılması, durumlar arasındaki geçiş olasılıklarına ek olarak yapılacak olan tahminlerin doğruluk oranlarının da elde edilmesini sağlamaktadır. Böylelikle sistemdeki durumların geçiş olasılıkları yardımıyla yatırım kararı alan yatırımcı yapay sinir ağları algoritmalarının doğru sınıflama başarılarıyla t+1 dönemi getirisini tahmin edebilecektir. Örneğin dördüncü dereceden Markov süreci negatif, pozitif, pozitif ve negatif ( $r_8$ ) devam ettiğini varsayalım. Bu durumda t+1 döneminde getiri %49 olasılıkla negatif, %51 olasılıkla pozitif olacaktır. Yatırımcı bu oranlara bakarak yatırım kararı alırsa t + 1 dönemi için yapacağı tahminin güvenilirlik ölçüsünü, başka bir ifade ile tahminin doğru gerçekleşme olasılığını ilgili yapay sinir ağının doğru sınıflama başarısından elde edecektir.

Tablo 2: Yapay Sinir Ağı Algoritmalarının Doğru Sınıflama Başarıları

Model	Eğitim verisi			Test verisi		
	Negatif (%)	Pozitif (%)	Toplam (%)	Negatif (%)	Pozitif (%)	Toplam (%)
(+ + + +)	54.5	54.9	54.7	67.6	71.1	69.4
(- + + +)	59.3	47.8	53.4	68.2	63.4	65.9
(+ - + +)	48.0	68.2	58.5	62.1	76.7	69.5
(+ + - +)	72.4	47.8	60.5	66.7	58.5	62.5
(+ + + -)	63.8	52.9	58.1	62.9	69.0	65.6
(- - + +)	35.7	69.2	53.1	61.8	70.6	66.2
(- + - +)	57.7	60.8	59.3	67.3	69.4	68.2
(- + + -)	55.7	58.1	56.9	60.7	60.5	60.0
(+ - - +)	64.6	58.3	61.3	64.1	70.4	66.7
(+ - + -)	33.3	67.1	50.3	52.8	70.7	64.9
(+ + - -)	45.7	76.5	62.6	51.9	82.1	69.7
(- - - +)	68.5	30.0	51.2	81.8	52.2	66.7
(- - + -)	57.1	48.4	53.1	63.4	61.3	62.5
(- + - -)	56.9	51.3	54.2	66.7	76.9	61.4
(+ - - -)	53.3	62.6	58.0	64.3	70.0	67.6
(- - - -)	40.0	81.7	63.3	60.0	69.2	65.2
Ortalama	53.2	59.1	56.6	63.3	68.6	65.7

Tablo 2 dördüncü dereceden Markov zincirlerine ait on altı durum için tahmin edilmiş yapay sinir ağlarının doğru sınıflama başarılarını göstermektedir. Yapay sinir ağlarına ait eğitim verisine uyum ve test verisi için tahmin gücünü gösteren doğru sınıflama başarıları birlikte verilmiştir. Tahmin gücünü ölçmekte kullanılacak ölçüt ilgili yapay sinir ağının test verisinde sağladığı doğru sınıflama başarısıdır. Bu başarı oranları yapay sinir ağının hiç tanımadığı bir veri setinden elde edildiği için çok değerlidir. Sınıflama başarılarının yüksek olması yapay sinir ağlarının yorum gücünü göstermektedir. Başka bir ifade ile ağ, daha önce tanımadığı bir problemle karşılaştığında ağ içindeki bilgileri kullanarak bu problemle ilgili güçlü tahminler üretebilmektedir. Tablo 2'ye bakıldığında eğitim verisinde yapay sinir ağları negatif yönlü getirileri ortalama %53.2, pozitif yönlü getirileri ortalama %59.1 ve bir bütün olarak ise getirileri ortalama %56.6 oranında doğru sınıflamıştır. Aynı yapay sinir ağları test verisinde negatif yönlü getirileri %63.3, pozitif yönlü getirileri %68.6 ve toplamda ortalama %65.7 oranında doğru sınıflamıştır. Özellikle test verisindeki doğru sınıflama başarıları oldukça yüksektir. Karmaşık yapıdaki ve oynaklığı yüksek finansal verilerin getirilerini toplamda %65.7 doğru sınıflamak, yapılacak 100 tahminin yaklaşık 66 tanesinin doğru yapılması anlamına gelmektedir. %65.7 altın piyasası için oldukça yüksek bir tahmin başarısı olmasına rağmen uzun dönemde pozitif getiriyi garanti etmez. Yani, doğru tahmin edilmiş 66 getirinin beklenen değeri, yanlış tahmin edilmiş 34 getirinin beklenen değerinden küçük olabilir. Unutulmamalıdır ki zayıf etkin piyasalarda uzun dönemde beklenen getiri sifıra çok yakındır. Bundan dolayı önerilen metodoloji kısa dönemde kar sağlamak adına önemli bilgiler sağlamasına rağmen, uzun dönemde pozitif getiriyi garanti etmez.



Uygulanan yöntemle tahmin süreci şöyle özetlenebilir. Örneğin sitemin  $r_4$ 'de olduğunu varsayalım. Bu durumda tablo 1'den bir sonraki günün %53 olasılıkla pozitif, %47 olasılıkla negatif olacağını görebiliyoruz. Yatırım yapmayı düşünen yatırımcı son dört günün getirilerini ilgili yapay sinir ağına girdi verisi olarak verecek ve buna karşılık bir tahmin değeri elde edecektir. Yapay sinir ağının ürettiği getiri değeri pozitif ise %58.5 olasılıkla doğru tahmindir. Yapay sinir ağının ürettiği tahmin ettiği getiri değeri negatif ise %66.7 olasılıkla doğru tahmindir. Bu süreci takip eden yatırımcı ortalama olarak yaklaşık %63 doğru tahmin elde edecektir. Yani yatırımcı %13 ekstra bilgi sağlamış olacaktır.

Tablo 3: Yapay Sinir Ağları Algoritmalarının Önem Analiz Sonuçları

Model	t-4	t-3	t-2	t-1
(++++)	0.53	0.20	0.15	0.12
(-++ +)	0.35	0.30	0.30	0.05
(+ - +)	0.15	0.22	0.39	0.24
(+ + +)	0.33	0.20	0.27	0.20
(++ +)	0.23	0.22	0.30	0.25
(- - +)	0.15	0.21	0.25	0.39
(- + +)	0.24	0.20	0.26	0.30
(- + -)	0.42	0.18	0.24	0.15
(+ - -)	0.25	0.24	0.19	0.32
(+ - +)	0.11	0.15	0.38	0.36
(+ + -)	0.22	0.45	0.21	0.12
(- - +)	0.28	0.08	0.29	0.35
(- - -)	0.10	0.35	0.20	0.35
(- + -)	0.33	0.29	0.20	0.18
(+ - -)	0.22	0.20	0.29	0.29
(- - -)	0.08	0.26	0.43	0.23
Ortalama	0.25	0.23	0.27	0.24

Tablo 3 dördüncü dereceden Markov zincirlerine ait olası on altı farklı durumu için dört gecikmeli değerin (günün) önem oranlarını göstermektedir. Tabloya bakıldığında t dönemindeki getiriyi t-4 dönemi ortalama %25 oranında, t-3 dönemi ortalama %23, t-2 dönemi ortalama %27 ve t-1 dönemi ortalama %24 etkilemektedir. Oranlar, mevcut durum gecikmeli değerlerden neredeyse eşit orana etkilendiğini göstermektedir. Tabloda en dikkat çekici oran, getirinin dört gün boyunca pozitif devam ettiği süreçte karşımıza çıkmaktadır. Bu süreçte t dönemindeki getiri %53 oranında dört gün önceki getiriden etkilenmektedir. Bir diğer ilgi çekici durum ise getirilerin negatif devam ettiği süreçte, t dönemindeki getiri dört gün önceki getiriden neredeyse etkilenmemektedir. Yapay sinir ağının önem analizi, t-i dönemindeki getirilerin t dönemindeki getiriyi etkileme büyüklüklerini sağlamasına rağmen etkinin yönü hakkında bilgi vermemektedir.

Tablo 4: Üçüncü Dereceden Markov Zincirleri Geçiş Olasılıkları

	(+++)	(+ + -)	(+ - +)	(- + +)	(- - +)	(- + -)	(+ - -)	(- - -)
(+ + +)	.54	.46	.00	.00	.00	.00	.00	.00
(+ + -)	.60	.40	.00	.00	.00	.00	.00	.00
(+ - +)	.00	.00	.52	.00	.00	.00	.47	.00
(- + +)	.00	.00	.00	.54	.00	.46	.00	.00
(- - +)	.00	.00	.00	.00	.48	.00	.00	.52
(- + -)	.00	.00	.00	.50	.00	.50	.00	.00
(+ - -)	.00	.00	.40	.00	.00	.00	.60	.00
(- - -)	.00	.00	.00	.00	.56	.00	.00	.44

Tablo 4 üçüncü dereceden Markov zincirleri modellerine ait geçiş olasılıklarını özetlemektedir. Tablodaki olasılıkların büyük bir kısmının %45-%55 arasındaki değerlere sahip olduğu görülmektedir. Üçüncü dereceden Markov zincirinde  $2^3=8$  farklı durum söz konusudur. Dördüncü dereceden Markov zincirlerinde olduğu gibi sıfır değerli geçiş olasılıkları iki durum arasında geçişin mümkün olmadığını ifade etmektedir.

Tablo 5: Yapay Sinir Ağları Doğru Sınıflama Başarıları

	Eğitim			Test		
	Negatif(%)	Pozitif(%)	Toplam(%)	Negatif(%)	Pozitif(%)	Toplam(%)
(+++)	46.1	58.0	52.1	68.2	71.4	70.0
(++-)	35.0	64.0	50.3	50.0	72.7	60.0
(+-+)	63.1	50.8	57.1	61.3	66.7	63.9
(-++)	55.7	41.2	48.2	66.7	75.0	70.8
(- -+)	66.8	40.2	54.0	66.7	68.4	67.4
(+ - -)	55.3	53.6	54.4	69.2	66.7	67.9
(+ - -)	45.3	49.2	47.4	70.0	60.0	66.7
(- - -)	44.3	67.9	56.6	71.4	72.0	71.8
Ortalama	51.5	53.1	52.5	65.4	69.1	67.3

Tablo 5 üçüncü dereceden Markov zincirlerinin olası sekiz duruma ait yapay sinir ağlarının doğru sınıflama başarılarını göstermektedir. Ağların doğru sınıflama başarılarına bakıldığında eğitim verisine %52.3 uyum sağladığı ve test verisine %67.3 uyum sağladığı görülmektedir. Dördüncü dereceden Markov zincirlerinde bu oranlar sırasıyla %56.6 ve %65.7 gerçekleşmişti. Burada önemli olan oranlar test verisi üzerinden elde edilen oranlardır. Karşılaştırma yapıldığında üçüncü dereceden Markov zincirlerinin dördüncü dereceden Markov zincirlerine göre %1.6 oranında daha iyi performans gösterdiği görülmektedir. Ayrıca tek tek bütün yapay sinir ağlarının doğru sınıflama başarıları karşılaştırıldığında üçüncü dereceden Markov zincirlerinin daha iyi tahmin başarıları gösterdiği görülmektedir. Son olarak üçüncü dereceden Markov zincirlerine ait yapay sinir ağlarının önem analizleri tablo 6'da özetlenmiştir.

Tablo 6: Yapay Sinir Ağları Algoritmalarının Önem Analizi Sonuçları

	t-3	t-2	t-1
(+++)	0.43	0.33	0.24
(++-)	0.38	0.28	0.34
(+-+)	0.48	0.25	0.27
(-++)	0.35	0.27	0.38
(- -+)	0.40	0.44	0.16
(+ - -)	0.41	0.28	0.31
(+ - -)	0.47	0.36	0.17
(- - -)	0.10	0.45	0.45
Ortalama	0.38	0.33	0.29

Önem analizi sonuçları üçüncü dereceden Markov zincirlerinde t dönemi getirilerinin %38 ile en çok t-3 döneminden etkilendiğini göstermektedir. Burada dikkat çeken olasılık pozitif negatif pozitif devam eden süreçte t-3 dönemine aittir. Buna göre üç gün önceki getiri bugünkü getiriyi tek başına %48 oranında etkilemektedir. Önem analizi sonuçları geçmiş dönemler için değerli bilgiler vermesine rağmen etkinin yönü hakkında bilgi vermemektedir. Yani t-3 döneminin etki gücü %48 olarak bulunurken bu etkinin pozitif veya negatif olduğu bilgisine bu analiz ile ulaşmak mümkün değildir.

## 5. Sonuç

Altın piyasası ve diğer finansal piyasalar dalgalanmaların ve verideki gürültünün fazla olduğu piyasalardır. Bu nedenle finansal piyasaların düzeyini veya en azından getirilerin yönünü tahmin etmek oldukça zordur. Pratikte bir finansal piyasa zayıf etkin piyasaya en yakın piyasa türüdür. Zayıf etkin bir piyasada teknik analiz yoluyla uzun vadede pozitif kar elde etmek oldukça zordur. Böyle

bir piyasada teknik analiz ile sadece pozitif kar elde etme olasılığı artırılabilir. Çalışmadaki temel amaç %50 olan gerçekleşme olasılığını olduğunca artırmaktır. Bu doğrultuda çalışmada doğrusal olmayan ilişkileri yakalamakta başarılı olan iki tahmin tekniğinin güçlü yönleri birleştirilerek kullanıldı ve %65'in üzerinde tahmin başarısı sağlandı. Yapay sinir ağları örnekler temelinde öğrenme gerçekleştirdiği için test verisinden elde edilen doğru sınıflama başarıları oldukça güvenilirdir. Zira yapay sinir ağı test verisindeki örnekleri daha önce hiç görmemektedir. Yapay sinir ağları, yaptıkları tahminleri ağı içindeki saklı bilgiden sağlamaktadır. Saklı bilgideki kasıt katmanlar arasındaki ağırlıklar ve kullanılan fonksiyon tipleridir. Yapay sinir ağlarının bu özelliklerinin yanı sıra Markov zincirleri modellerinin geçiş olasılıkları süreçler (durumlar) arasındaki olasılık ilişkilerini özet halinde sunmaktadır. Böylelikle tahminden önceki aşamada yatırımcıya karar verme konusunda rehberlik etmiş olmaktadır. Sonuç olarak bu çalışmada Markov zincirleri modelleri ve yapay sinir ağları algoritması birlikte kullanılarak yeni bir tahmin metodolojisi önerilmiş ve önerilen metodoloji ile altın fiyatlarıyla ilgili %70'i bulan tahmin başarısı elde edilmiştir.

#### Kaynakça

- Altan, Ş. (2008). Döviz Kuru Öngörü Performansı İçin Alternatif Bir Yaklaşım: Yapay Sinir Ağı. *İktisadi ve İdari Bilimler Fakültesi Dergisi*, 10(2), 1-20.
- Aydin, A. D. ve Cavdar, S. C. (2015). Comparison of Prediction Performances of Artificial Neural Network (ANN) and Vector Autoregressive (VAR) Models by Using The Macroeconomic Variables of Gold Prices, Borsa Istanbul (BIST) 100 Index and US Dollar-Turkish Lira (USD/TRY) Exchange Rates. *Procedia Economics and Finance*, 30, 3-14.
- Berchtold, A. ve Raftery, A. E. (2002). The Mixture Transition Distribution Model For High-Order Markov Chains and Non-Gaussian Time Series. *Statistical Science*, 328-356.
- Can, T. ve Öz, E. (2009). Saklı Markov Modelleri Kullanılarak Türkiye'de Dolar Kurundaki Değişimintahmin Edilmesi. *Istanbul University Journal of the School of Business Administration*, 38(1).
- Godarzi, A. A., Amiri, R. M., Talaei, A. ve Jamasb, T. (2014). Predicting Oil Price Movements: A Dynamic Artificial Neural Network Approach. *Energy Policy*, 68, 371-382.
- Hamilton, J. D. (1989). A New Approach To The Economic Analysis Of Nonstationary Time Series And The Business Cycle. *Econometrica: Journal of the Econometric Society*, 357-384.
- Hamilton, J. D. (1994). *Time Series Analysis* (Vol. 2). Princeton: Princeton University Press.
- 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
- Kanas, A. ve Genius, M. (2005). Regime (non) Stationarity In the US/UK Real Exchange Rate. *Economics Letters*, 87(3), 407-413.
- Kaynar, O. ve Taştan, S. (2009). Zaman Serisi Analizinde Mlp Yapay Sinir Ağları ve Arıma Modelinin Karşılaştırılması. *Erciyes Üniversitesi İktisadi Ve İdari Bilimler Fakültesi Dergisi*, (33), 161-172.
- Khashei, M., Hejazi, S. R. ve Bijari, M. (2008). A New Hybrid Artificial Neural Networks and Fuzzy Regression Model for Time Series Forecasting. *Fuzzy Sets And Systems*, 159(7), 769-786.
- Kılıç, S. B. (2013). Integrating Artificial Neural Network Models By Markov Chain Process: Forecasting The Movement Direction Of Turkish Lira Us Dollar Exchange Rate Returns. *Çukurova Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 22(2).

- Kim, C. J., Piger, J. ve Startz, R. (2008). Estimation of Markov Regime-Switching Regression Models With Endogenous Switching. *Journal of Econometrics*, 143(2), 263-273.
- Kristjanpoller, W. ve Minutolo, M. C. (2016). Forecasting Volatility Of Oil Price Using An Artificial Neural Network-GARCH Model. *Expert Systems with Applications*, 65, 233-241.
- Leung, M. T., Chen, A. S. ve Daouk, H. (2000). Forecasting Exchange Rates Using General Regression Neural Networks. *Computers and Operations Research*, 27(11), 1093-1110.
- Majhi, R., Panda, G. ve Sahoo, G. (2009). Efficient Prediction Of Exchange Rates With Low Complexity Artificial Neural Network Models. *Expert Systems with Applications*, 36(1), 181-189.
- 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.
- Mamipour, S. ve Vaezi Jezeie, F. (2015). Non-Linearities in The Relation Between Oil Price, Gold Price And Stock Market Returns in Iran: A Multivariate Regime-Switching Approach.
- 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.
- Öz, E. (2009). İstanbul Menkul Kıymetler Borsası Üzerine Saklı Markov Modeli ile Bir Tahminleme. *Ekonomik Yaklaşım*, 20(72), 59-85.
- Özkan, F. (2012). Döviz Kuru Tahmininde Parasal Model ve Yapay Sinir Ağları Karşılaştırması. *Business and Economics Research Journal*, 3
- Öztürk, A. (2014). Yöneylem Araştırması. *Ekin Kitabevi Yayınları, BURSA*
- 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. ve Narasimhan, V. (2007). Forecasting Exchange Rate Better With Artificial Neural Network. *Journal of Policy Modeling*, 29(2), 227-236.
- Raftery, A. E. (1985). A Model For High-Order Markov Chains. *Journal of the Royal Statistical Society. Series B (Methodological)*, 528-539.
- Rosenblatt, M. ve Slepian, D. (1962). N th Order Markov Chains with Every N Variables Independent. *Journal of the Society for Industrial and Applied Mathematics*, 10(3), 537-549.
- 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.
- Şeker, M., Yıldırım, E. S. ve Berkay, A. (2004). Yapay Sinir Ağlarının Ekonomik Tahminlerde Kullanılması. *Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi*, 10(4), 79-83.

- Tam, K. Y. ve Kiang, M. Y. (1992). Managerial Applications Of Neural Networks: The Case Of Bank Failure Predictions. *Management science*, 38(7), 926-947.
- Yu, L. ve Lai Shouyang (2007). Foreign-Exchange-Rate Forecasting With Artificial Neural Network. *Springer Publisher*.
- Yüksel, R. ve Akkoç, S. (2016). Altın Fiyatlarının Yapay Sinir Ağları İle Tahmini Ve Bir Uygulama.
- Zhang, G. ve Hu, M. Y. (1998). Neural Network Forecasting Of The British Pound/US Dollar Exchange Rate. *Omega*, 26(4), 495-506

---

## PREDICTION OF DAILY GOLD PRICE RETURNS WITH ARTIFICIAL NEURAL NETWORKS AND MARKOV CHAINS MODELS

---

### *Extended Abstract*

**Aim:** Many investors have a great deal of interest in financial markets, such as stock exchanges, exchange rates and gold markets. Therefore, the financial markets have high trading volume depending on the interest of investment and the difficulty of prediction about the future of these markets. The volatility of financial markets is high with a large number of buyers and sellers and information spreads very quickly. Eugene Fama (1970) proposed a weak-form market efficiency of the stock market. In a weak form of efficient market, it is not possible to make profits higher than the average market's returns in the long run through technical analysis. The aim of this study is to make powerful predictions about the daily returns of gold price by utilizing both Markov chains models and artificial neural networks algorithm to obtain the correct classification success over fifty percent.

**Methods:** In this study, the returns of daily gold prices estimated by using the Artificial Neural Networks algorithm and High-Order (third order and fourth order) Markov chains models. The gold market closing prices used to calculate the returns of daily gold prices for the period of January 1, 2000- February 28, 2017. The study consists of two stages. In the first stage, the lagged values of the returns of daily gold prices used as the input data of artificial neural network (ANN) and the predicted values of the returns of daily gold prices obtained from ANN. In the second stage, the transition probabilities matrix of the third order and the fourth order Markov chains models derived from the predicted values of the ANN. Because of the methodology used, as well as the strong prediction results of ANN, the correct classification success of ANN that used for the reliability of the predictions obtained. Thus, while the transition probabilities matrix of Markov chains models guides investors for investment, the correct classification results of the artificial neural network algorithms provide the probability of correctness degree of the prediction made. Additionally, the importance analysis results of ANN obtained and these results utilized for the significance level and the magnitude of effects on past values.

**Findings:** The results show that the third order Markov chain models have slightly better prediction performance than the fourth order Markov chain models. The ANN belonging to third order Markov chains models correctly predicted positive returns by 69.1% and negative returns by %65.4, while the ANN belonging to fourth order Markov chains models correctly predicted positive returns by 68.6% and negative returns by %63.3. As a whole, the third order Markov chains produced %67.3 correct prediction rate, while the fourth order Markov chains produced % 65.7 correct prediction rate. Additionally, while the returns of "t-3", "t-2" and "t-1" periods in the third order Markov chains models have 38%, 33% and 29% significance or effect on the returns of "t" period, respectively. In the fourth order Markov chains models these rates are %25, %23, %27 and %24 for "t-4", "t-3", "t-2" and "t-1" periods, respectively.

**Conclusion:** The volatility and fluctuations of data belonging to the gold market and other financial markets are quietly high. That is why, it is difficult to predict the level of financial markets values or at least the movement of the returns. In practice, a financial market is the closest market type to a weak form of efficient market introduced by Fama (1970). Furthermore, in a weak form of efficient market, it is very difficult to achieve positive profit in the long run through technical analysis. In this study, on the purpose of getting better prediction results, the strengths of the two forecasting techniques, which are successful in capturing nonlinear relationships between variables, used combined and as a result, more than 67% prediction success achieved. Since the ANN performs learning on the basis of samples and never seen the test data before, the prediction results of the ANN is highly reliable. Because of the proposed methodology, valuable information obtained for the future prediction of daily gold price.