

YAPAY SİNİR AĞLARI YÖNTEMİ İLE PETROL FİYATLARI TAHMİNİ

R. Şebnem KETREZ

İstanbul Üniversitesi, Sosyal Bilimler Enstitüsü, Sermaye Piyasası Uzmanlığı

sebnemakdol@gmail.com

Arif SALDANLI

İstanbul Üniversitesi, İktisat Fakültesi İşletme Bölümü, Finansman Anabilim Dalı

saldanli@istanbul.edu.tr

Özet

Amaç: Petrol fiyatlarındaki dalgalanmalar başta 1973 Petrol krizi olmak üzere birçok ekonomik krizin temel nedeni olarak görülmektedir. Ekonominin arz ve talep yanını aynı anda etkileyen bu faktörde meydana gelen fiyat hareketlerinin öngörülmesi ve tahmin edilmesi önem arz etmektedir. Literatürde petrol fiyatlarının yönünün kestirilmesinde farklı yöntemler kullanarak yapılmış birçok çalışma bulunmaktadır. Bu çalışma kapsamında ise yapay sinir ağları yönteminde farklı modeller kullanılarak petrol fiyatlarına ilişkin öngörü başarıları incelenerek karşılaştırma yapmak amaçlanmıştır.

Yöntem: Günlük ve Aylık veri modelleri kullanılarak petrol fiyatlarının Yapay Sinir Ağı modelleri ile tahminlemesi yapılmıştır..

Bulgular: Elde edilen bulgulara göre günlük periyot dikkate alınarak kullanılan veriler ile yapılan modellemede hata oranının oldukça düşük gerçekleştiği görülmüştür. Günlük periyot dikkate alınarak yapılan çalışmalarda, anlamlı girdi sayısı artması halinde, aylık periyot dikkate alınarak yapılan çalışmalarda ise nöron sayısının yükselmesi halinde olarak hata oranlarında düşüş gözlenmektedir.

Anahtar Kelimeler: Yapay Sinir Ağları, Fiyat Tahmini, Petrol Fiyatı, Enerji Piyasası, Katman

Bilgilendirme: Bu makale R.Şebnem Akdöl tarafından İstanbul Üniversitesi, Sosyal Bilimler Enstitüsü, Sermaye Piyasası Uzmanlığı programında sunulan “Yapay Sinir Ağları ile Petrol Fiyatları ve Yönlerinin Tahmini” (2017) başlıklı proje çalışmasından yararlanılarak hazırlanmıştır.

ESTIMATION OF PETROLEUM PRICES WITH ARTIFICIAL NEURAL NETWORKS MODEL

Abstract

Purpose: Fluctuations in oil prices are seen as fundamental reasons for many economic crises, especially the 1973 oil crisis. It is important to anticipate and predict the price movements that take place in this factor affecting the supply and demand side of the economy at the same time. There are many studies in the literature using different methods in estimating the oil prices. Within the scope of this study, it was aimed to compare and compare the forecasting successes of oil prices by using different models in artificial neural networks method.

Method: Estimation of oil prices with Artificial Neural Network models was made using Daily and Monthly data models.

Findings: According to the findings obtained, it is seen that the error rate in the model made with the data used by considering the daily period is very low. In the studies performed considering the daily period, when the number of significant inputs increases, when the number of neurons increases in the studies performed considering the monthly period, the error rates decrease.

Keywords: Artificial Neural Networks, Price Forecasting, Oil Prices, Energy Markets, Layer


Acknowledgement: This article is prepared by using the project presented by R. Şebnem KETREZ in İstanbul University, Social Sciences Institute, Capital Markets Expertise Program, titled “Estimation of Oil Prices and Directions by Artificial Neural Networks”(2017)

Giriş

Ham petrol bulunması ve yaygınlaşmasından sonra küresel ölçekte dünyanın en önemli emtialarından birisi olmuştur. Özellikle geçtiğimiz yüzyılda motorlu araçların gelişmesi ve yaygınlaşması ile birlikte ekonomik gelişme ve büyümenin ana hammaddelerinden birisi haline gelmiştir. Arz, talep ve siyasi gelişmeler başta olmak üzere birçok faktör petrolün fiyat hareketliliğini artırmaktadır. Bunun sonucunda birçok mal ve hizmetin fiyatlarında dalgalanmalar oluşmakta ve ekonomik öngörülebilirlik ve istikrar zarar görmektedir. Tüm mal ve hizmet piyasalarında oluşan fiyat düzeylerini hem arz hem de talep yönlü olarak etkileyen petrol fiyatlarının önceden tahmin edilmesi, birçok ekonomik aktör açısından büyük önem arz etmektedir.

ABD'de 1861'de açılan ilk kuyudan başlamak üzere geçtiğimiz 150 yılı aşkın süredir petrol dünyanın en önemli enerji kaynağı olmuştur. Bugün hala kara, deniz ve havada tüm taşıtların en çok kullanılan yakıtların hammaddesidir. Bu sebeple hem üreticiler, hem tüketiciler tarafından gelecekteki fiyatları en çok merak edilen emtialardan birisidir. Grafik 1 de görüldüğü üzere 2017 yılı itibari ile dünya enerji tüketiminin çok büyük bir kısmı petrol ile karşılanmaktadır.

Grafik 1. Dünya Enerji Tüketimi 2017



Kaynak: (British Petrol, 2017)

Yıllar boyunca diğer enerji kaynaklarının toplam enerji üretimi içerisindeki payı artmakla birlikte 2017 yılı itibari ile petrol ve türevleri hala en yaygın enerji kaynağı olma özelliğini muhafaza etmektedir. Birçok sektör açısından önemli bir maliyet kalemi olan enerji fiyatlarının tahmini hem ticari olarak hem de akademik olarak sıklıkla ele alınan konulardan biri olmuştur. Geçmişte çeşitli regresyon modelleri, GARCH (Generalized Autoregressive Conditional Heteroskedasticity) ve ARIMA (Autoregressive Integrated Moving Average) gibi modellerle tahmin çalışmaları yürütülmüş, daha yakın geçmişte ise bilgisayar teknolojisindeki ilerlemeler ve geliştirilen makine öğrenmesi algoritmalarıyla yapay sinir ağları kullanılarak oluşturulan modeller ile tahminlerdeki başarı seviyesinin yükseldiği gözlenmiştir.

Finansal zaman serileri ile ilgili olarak gerek hisse senedi ve endeks, gerek spot fiyat ve vadeli işlem enstrümanları fiyatlarının tahmini üzerine çok sayıda çalışma mevcuttur. Geleneksel regresyon modelleri, GARCH, ARIMA gibi modeller, YSA modelleri ve bunların çeşitli karşılaştırmaları farklı açılardan yapılmıştır. Bazı çalışmalar fiyat tahmini üzerine odaklanırken bazı çalışmalarda sadece yön tahmini yapılmıştır.

1. Yapay Sinir Ağları


Yapay sinir ağları (YSA), desen tanıma, tahmin, optimizasyon ve sınıflandırma gibi alanlara etkin bir biçimde uygulanabilen bir yapay zeka bilimidir (Azoff, 1994). Çalışma şekli insan beyninde bulunan nöronların çalışma şekline benzemektedir (Haykin, 1999).

Diğer doğrusal ve doğrusal olmayan regresyon yöntemlerinde olduğu gibi YSA'lar da bir veya daha fazla girdi değişkenini $\{x_i\}$, $i = 1, \dots, k$, bir veya daha fazla çıktı değişkeni $\{y_j\}$, $j = 1, \dots, k^*$ ile ilişkilendirmek için kullanılır. YSA ve diğer yöntemler arasındaki temel fark YSA'larda bir veya daha fazla gizli katman kullanılması ve bu gizli katmanda girdi değişkenlerinin özel bir fonksiyon ile dönüştürülmesidir. Bu gizli katman konsepti, gizemli görünmekle birlikte doğrusal olmayan istatistik prosesleri modellemede çok etkin bir çözüm sunmaktadır (McNelis, 2005).

Yapay sinir ağları bağlantı şekillerine göre ileri beslemeli ve geri beslemeli olmak üzere ikiye ayrılır (Diler, 2003). İleri beslemeli ağlarda herhangi bir katmandaki bir yapay sinir hücresi sadece bir sonraki katmandaki hücreler ile bağlantılıdır. Geri beslemeli ağlarda ise en az bir sinir hücresi bir önceki katmandaki bir hücre ile

bağlantılıdır (Elmas, 2011). Şekil 1 de tek gizli katmanlı 4 girdi değişkenli ve 2 çıkış değişkenli Yapay Sinir Ağı modeli örneklendirilmiştir.

Şekil 1. Tek gizli katmanlı, 4 girdi değişkenli, 2 çıkış değişkenli YSA modeli



Kaynak: (Fauset, 2011)

Yapay sinir ağlarında kullanılan nöron modellerinde üç önemli tarihsel aşama bulunmaktadır. Bu aşamalar McCulloch & Pitts (1943) nöron modeli, algaç modeli (Rosenblatt, 1958) ve çok katmanlı algaç modeli olarak sınıflandırılabilir.

1.1. McCulloch & Pitts (1943) Nöron Modeli

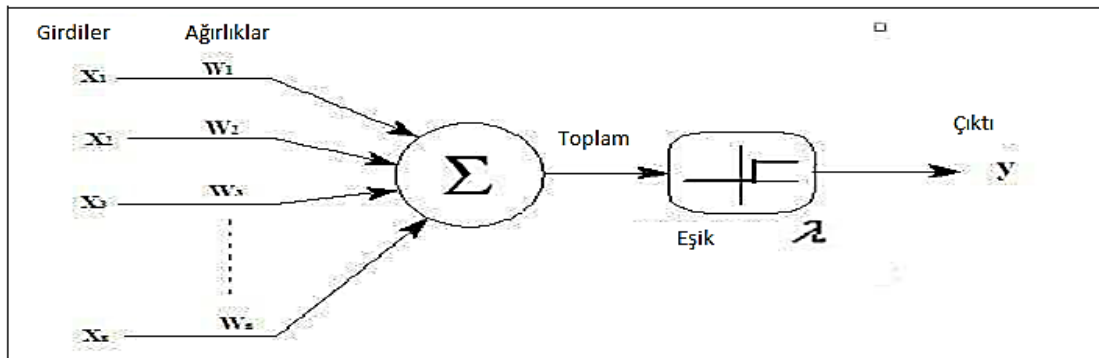
1943 yılında nörobilimci Warren S. McCulloch ve Walter Pitts yaptıkları çalışma ile formal nöron adını verdikleri ilk yapay nöronu ortaya koymuşlardır. Çalışmada temel olarak beynin birbirine bağlı birçok nöron kullanarak son derece karmaşık örüntüleri nasıl oluşturabildiğini anlamaya çalışmışlardır. Şekil 2 de modelin temel işleyiş mekanizması yer almaktadır. Kısaca MCP Nöronları adı verilen bu model biyolojik nöronların temel özelliklerini modelleyen Yapay Sinir Ağları modelinin gelişimine önemli katkılar sağlamıştır. (McCulloch, 1943) McCulloch-Pitts nöronunun matematiksel gösterimi denklem (1) de gösterildiği gibidir:

$$(1) \quad y = f(\sum_{i=1}^n W_i X_i - \lambda)$$

Formüldeki x_1, x_2, \dots, x_n ikili değer (0 ve 1) alan McCulloch-Pitts nöron inputlarını, w_1, w_2, \dots, w_n ise bağlantı ağırlıklarını göstermektedir. f işaret fonksiyonu, λ eşik değeri ve y ise McCulloch-Pitts nöronunun çıktısını göstermektedir ve aşağıdaki şekilde tanımlanmıştır.

$$(2) \quad f((X_1, \dots, X_n)(W_1, \dots, W_n)) = \begin{cases} 1, & \text{if } \sum_{i=1}^n W_i X_i \geq \lambda \\ 0, & \text{if } \sum_{i=1}^n W_i X_i < \lambda \end{cases}$$

Şekil 2. McCulloch & Pitts (1943) Nöronu



Kaynak: (McCulloch, 1943)

1.2. Algaç (Perceptron) Modeli (Rosenblatt 1958)

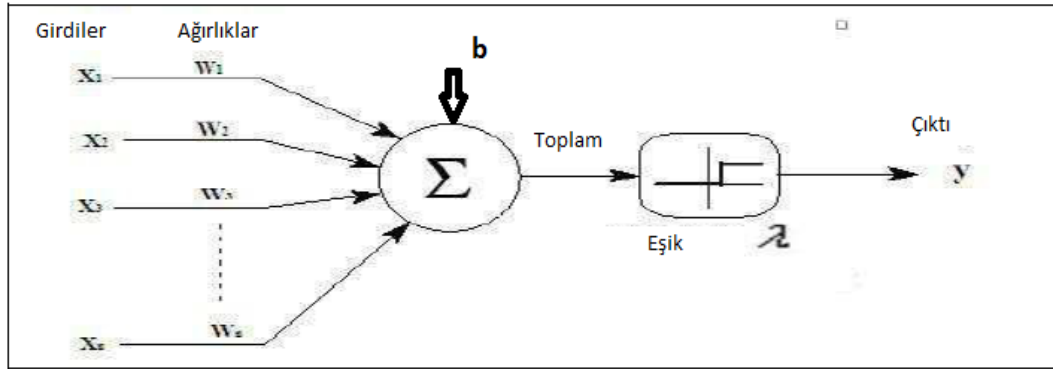
Rosenblatt (1958) McCulloch-Pitts Nöron modeline öğrenmeyi sağlayan ek özellikler ekleyerek "Algaç" Modelini oluşturmuştur. Temel olarak algılayıcı, girdilerin ilk önce birleştirme birimleri olarak adlandırılan bazı "önişlemciler" tarafından geçirildiği bir MCP nöronudur. Bu ilişki birimleri, girdilerdeki belirli özelliklerin varlığını algılar. Şekil 3 de Rosenblatt Algaç Modelinin temel işleyiş mekanizması gösterilmektedir. "Algaç" modeli öğrenme fonksiyonu olan ilk yapay nöronudur. "Algaç", doğrusal ayırıcı adı verilen doğrusal karar

sınırına göre giriş değişkenleri uzayını ikiye ayırır. Algaç çıktısının formülasyonu ,denklem (3) de gösterildiği gibidir.

$$(3) f((X_1, \dots, X_n)(W_1, \dots, W_n), b) = \begin{cases} 1, & \text{if } \sum_{i=1}^n W_i X_i + b \geq \lambda \\ 0, & \text{if } \sum_{i=1}^n W_i X_i + b < \lambda \end{cases}$$

Formüldeki x_1, x_2, \dots, x_n ikili değer (0 ve 1) alan Rosenblatt nöron inputlarını, w_1, w_2, \dots, w_n ise sinaptik bağlantı ağırlıklarını göstermektedir. f işaret fonksiyonu, λ eşik değeri ve b ise eğilim değerini gösterir.

Şekil 3. Algaç Modeli




Kaynak: (Rosenblatt, 1958)

1.3. Çok katmanlı Algaç (Perceptron) Modeli

Gizli katmanı olmayan algaç sinir ağları girdi ve çıktı olarak sadece ikili değerler (0 ve 1) kabul etmekte ve bu sebeple sadece doğrusal olarak ayrıştırılabilen problemlerde sonuç vermektedir. Windrow ve Hoff (1960) delta kuralı adında, bağlantı ağırlıklarını değiştirerek istenen ve gerçek çıktı değeri arasındaki farkı azaltan yeni bir öğrenme kuralı ortaya koymuşlardır. Böylece çıktı değeri 0 ve 1 yerine herhangi bir değer de alabilir hale gelmiştir. Çok katmanlı algaç modeli, girdileri içeren bir katman, bir veya daha fazla gizli katman ve bir çıktı katmanından oluşmaktadır. Şekil 4 te çok katmanlı algaç modelinin temel işleyiş mekanizması gösterilmektedir.

Şekil 4. Çok Katmanlı Algaç Modeli



Kaynak: (Wongsinlatam, 2014)

Bu ağ sisteminde bilgi tek yönlü olarak ileriye doğru gitmektedir. Girdi katmanı bilgiyi gizli katmandaki nöronlara iletirken, gizli katman da çıktı katmanındaki nöronlara iletmektedir. Böylece tek gizli katmanlı bir model için ağ çıktısı denklem (4) te gösterilirdiği gibi oluşmaktadır.

$$(1) y_k = h\left\{\sum_{j=1}^J w_2(j, k)g\left[\sum_{i=1}^I w_1(i, j)x_i + b_1(j)\right] + b_2(k)\right\}$$

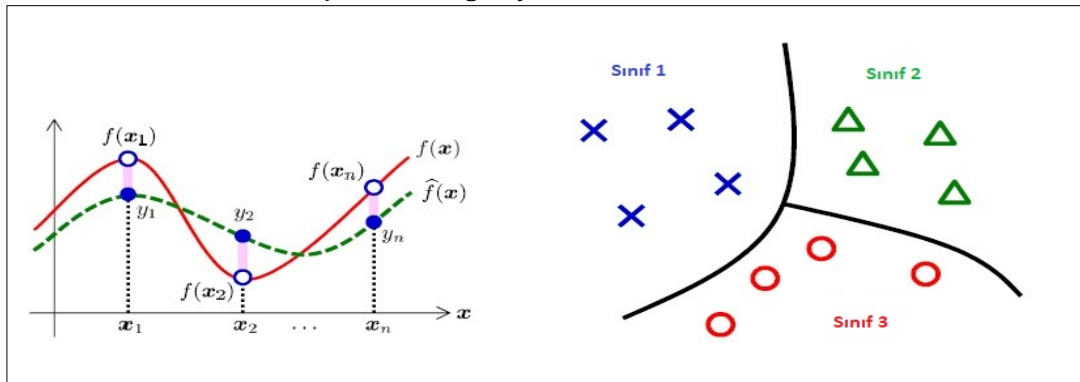
Formüldeki x_i ağırlık girdi değişkenlerini, I girdi değişken sayısını, J gizli katmandaki toplam düğüm sayısını, K çıkış katmanındaki nöron sayısını, g ve h sırasıyla ilk ve ikinci katmanın transfer/aktivasyon fonksiyonlarını, w_1 gizli katmanın ağırlık matrisini, w_2 çıkış katmanının ağırlık matrisini, b_1 ve b_2 ise sırasıyla gizli katman ve çıktı katmanlarının eğilim vektörlerini göstermektedir.

2. Yapay Sinir Ağlarında Öğrenme

YSA'larda öğrenme mevcut olan verinin tipine göre Danışmanlı öğrenme, Danışmansız öğrenme ve Pekiştirmeli öğrenme olmak üzere üçe ayrılır.

Danışmanlı öğrenme YSA'larda en temel makine öğrenmesi tipidir. Danışmanlı öğrenmede giriş vektörleri ve her bir giriş vektörüne karşılık gelen çıkış vektörleri bulunmaktadır. Ağın yaptığı bağlantı ağırlıklarını değiştirerek bu giriş vektörleri ile karşılık gelen çıkış vektörlerine ulaşılmaktadır. Bu amaçla ağın hesapladığı çıkış vektörü ile mevcut olan çıkış vektörü arasındaki farkı (ağın hesapladığı sonuçtaki hatayı) tanımlayan bir hata fonksiyonu tanımlanarak ve ağın farklı ağırlıklar denediği iterasyonlar oluşturularak, hata minimize edilmeye çalışılır. Hata değeri kabul edilebilir bir seviyeye ulaştığında öğrenme işlemi tamamlanmış kabul edilir. Şekil 5 te regresyon ve sınıflandırmaya dayalı öğrenme modeli gösterilmektedir. Danışmanlı öğrenme el yazısı, fotoğraf, konuşma tanılama, spam filtreleme, hava tahmini, fiyat tahmini, online reklam, astronomi verisi analizi gibi bir çok alanda kullanılmaktadır. Danışmanlı öğrenme problemi, eğer sonuç bir reel sayı ise "regresyon", sonuç evet/hayır gibi ikili bir değer ise "sınıflandırma", sonuç iyi/normal/kötü gibi bir değer ise "sıralama" olarak isimlendirilir.

Şekil 5. Regresyon ve Sınıflandırma



Kaynak: (Sugiyama, 2016)

Danışmansız öğrenmede, danışmalı öğrenmelerden farklı olarak sadece girdi değişkenler bulunmaktadır. Herhangi bir çıktı değişkeni ise yer almamaktadır. YSA girdi değişkenleri otomatik olarak sınıflandırılmaktadır. Böylelikle veri, kümeleme ve ayırıcılık tespitlerinde kullanılmakla birlikte danışmanlı öğrenme için bir ön hazırlık aşaması olarak da kullanılmaktadır (Sugiyama, 2016).

Pekiştirmeli öğrenmede ise YSA, numerik bir ödül parametresini hangi aksiyonların maksimize ettiğini keşfederek deneme yanılma yöntemi ile sonuca ulaşmaktadır (Barto, 1998). Otonom robot kontrolü, bilgisayar oyunları ve pazarlama stratejisi optimizasyonu gibi alanlarda kullanılır. Pekiştirmeli öğrenmenin arka planında regresyon, sınıflandırma vb. içeren danışmanlı ve danışmansız öğrenme metodları bulunur (Sugiyama, 2016).

Öğrenme sonucunda hatanın minimize edilmiş olması iki sebeple olabilir. Ağ başarılı bir genelleme yapmış olabilir veya verileri ezberlemiş olabilir. Eğer başarılı bir genellemeye ulaşmış ise, algoritmaya daha önce hiç görmediği giriş vektörleri verildiği zaman makul bir sapma oranı ile çıkış vektörlerini tahmin edebilir. Herhangi bir problem için önceden tahmin edilebilen optimum katman sayısı ve nöron sayısı mevcut değildir. Genellikle deneme yanılma yöntemi ile sonuca ulaşılır (Aghababaeyan, 2011). Eğer öğrenme için verilen veri miktarı düşük ise ve/veya katman sayısı ve katmanlardaki nöron sayısı verilen problem için yüksek ise ağın verileri ezberleyerek başarılı bir genelleme yapamama ihtimali daha yüksek olur. Öğrenme aşamasında başarılı bir genellemeye ulaşıldığını tespit edebilmek için mevcut verilerin tamamı öğrenme için kullanılmaz. Belirli bir kısmı (%10-%20) test amaçlı kullanılmak üzere ayrılarak öğrenme işlemi tamamlandıktan sonra test için ayrılan veriler ile sonuçlar test edilir. Başarılı bir genellemede öğrenme esnasında oluşan hata oranı ile test verilerindeki hata oranının birbirine yakın olması beklenir. Ezberleme (overfitting) var ise test verilerinde yüksek hata oranı ortaya çıkar. Bu durumlarda model değiştirilerek yeni parametreler ile öğrenme işlemi tekrarlanarak başarı bir genellemeye ulaşmaya çalışılır.

3. Literatür Taraması

YSA'lar üzerine ilk çalışmalar günümüzden yaklaşık 75 sene öncesinde, McCulloch ve Pitts tarafından 1943 senesinde yapılan çalışmalarla başlamıştır. Sonraki yıllarda teknolojik imkânlarında da hızla gelişmesi ile birlikte finans, üretim gibi birçok alanda kullanımı yaygınlaşmıştır (Zupan, 2003) .

Moshiri ve Foroutan (2006) tarafından yapılan çalışmada günlük ham petrol fiyatlarının tahmini için ileri beslemeli YSA, ARMA (otoregresif hareketli ortalama) ve GARCH (otoregresif koşullu değişen varyans modeli) karşılaştırmalı olarak incelenmiştir. Çalışmada 4 Nisan 1983 ve 13 Ocak 2003 tarih aralığındaki ham petrol vadeli işlem fiyatları veri olarak alınmıştır Performans ölçümü için ortalama mutlak hata (OMH), hata karelerinin ortalaması (HKO) ve hata karelerinin ortalamasının karekökü (HKOK) kullanılmıştır. Test sonuçlarına göre YSA performansının (OMH=2.04, HKO=8.14, HKOK=2.85), ARMA (OMH=4.81, HKO=29.27, HKOK=5.41) ve GARCH (OMH=2.90, HKO=15.25, HKOK=3.90) 'a kıyasla çok daha başarılı olduğu görülmüştür.

2007 senesinde ise Shambora ve Rossiter tarafından petrol fiyatlarını tahmin etmek için girdi olarak teknik analizdeki kesişim kuralları kullanıldığı bir YSA modeli önerilmiştir. Modelin öğrenme aşamasında 16 Nisan 1991 - 1 Aralık 1997 tarihleri arasında günlük periyotlu vadeli işlem fiyatları dikkate alınmıştır. YSA modelinin sonucu olarak ortaya çıkan tahmini fiyatlar işlem sinyali olarak kullanılarak, çeşitli ölçütlerin de yardımı ile bir çeşit deneysel karlılık olarak ifade edilmiştir. Bu performans sonucu "al ve bekle" de dahil olmak üzere 3 tip strateji ile mukayese edilmiş ve bu stratejilere göre daha üstün performans sergilediği görülmüştür. Bu durum ham petrol vadeli işlem piyasasının yeterince etkin olmadığına işaret eden bir bulgu olarak ortaya konuşmuştur.

Ghaffari ve Zare 2009'da YSA ve bulanık mantık yaklaşımlarını birleştirerek günlük WTI ham petrol spot fiyatlarını üzerinde çalışma yapmışlardır. İlave olarak 5 Ocak 2004 - 30 Nisan 2007 aralığındaki günlük fiyatlara bir düzleştirme algoritması uygulamışlardır. Deneyle sonuçları düzleştirmenin tahmin algoritmasının performansını kayda değer miktarda artırdığını göstermiştir. Yazarlar her iki durumdaki modellerin yüzdesel doğru tahmin miktarlarını rastgele seçtikleri dönemler için de karşılaştırarak ve düzleştirme algoritması uygulanan modelin performansının daha iyi olduğunu rastgele seçilen dönemler için de daha iyi olduğunu teyit etmişlerdir. Örneğin 1-31 Mayıs 2007 tarihleri arasındaki 1 aylık süreçte düzleştirilmiş veri ile oluşturulan model %68.18 başarı sağlarken, diğer model %45.45 oranında başarı sağlamıştır. Bu bulgular düzleştirme algoritmasının öngörülemez kısa vadeli dalgalanmaları model oluşturma sürecine dâhil etmeyerek daha başarılı modeller oluşturulabileceğini göstermesi bakımından önemlidir.

Xiong ve diğerleri (2013) birkaç adım sonraki petrol fiyatını tahmin etmek için ileri beslemeli YSA'lara dayalı bir EMD (deneysel yöntem ayrıştırma) modelini SBM (eğim tabanlı teknik) ile birleştirmişlerdir. Oluşturulan modelin performansını değerlendirebilmek için üç ayrı modelin (Tekrarlı strateji, direkt strateji ve MIMO (Çoklu girdi-çoklu çıktı) strateji) performansını 07.01.2000 - 30.12.2011 tarihleri dikkate alınarak haftalık periyotlu WTI spot ham petrol fiyatları üzerinde mukayese etmişlerdir. Tahmin isabet oranı ve işlemci yüküne göre değerlendirildiğinde MIMO stratejisi kullanan EMD-SBM-YSA modelinin üç model arasında en iyi performansı gösterdiği görülmüştür. Örneğin 12 adım sonrası için yapılan örnekte MASE (ortalama mutlak ölçekli hata) değeri EMD-SBM-YSA modeli için 0.991, direkt EMD-SBM-YSA modeli için 0.948, MIMO EMD-SBM-YSA modeli için 0.914 çıkmıştır.

Kaboudan (2001) genetik programlama (GP) ve yapay sinir ağlarını aylık petrol verileri üzerinden tesadüfi hareket (RW) modeli ile karşılaştırmıştır. Bu amaçla Kaboudan, 1993-1999 seneleri arasındaki ham petrol spot fiyatları, dünya petrol üretimi, OECD tüketimi, dünya petrol stokları, ABD stoklarındaki değişim, ABD ithalat miktarları ve gecikmeli FOB ham petrol fiyatlarına ait zaman serilerini kullanmıştır. Hata karelerinin ortalaması ölçütüne göre, genetik algoritmalar ile tahmin modeli (HKO = 1.85), random walk (HKO=2.29) ve YSA modellerine (HKO=3.54) göre daha başarılı bir performans sergilemiştir. Rast (2001) tarafından yapılan çalışmada ham petrol fiyatlarının tahmini için Bulanık Mantık Metodu kullanılmıştır. Zaman serisi olarak ham petrol vadeli işlem fiyatlarını ham petrol spot fiyatının vadeli işlem piyasasındaki gelecek fiyatından daha düşük olduğu ve daha yüksek olduğu durum olmak üzere iki farklı duruma ayırarak kullanılmıştır. Ortaya çıkarılan model tahmin doğruluğunu ileri beslemeli bir YSA'ya göre %6.95 oranında geliştirmiştir.

2004 senesinde Mirmirani ve Li ABD'deki petrol fiyatını tahmin etmek için iki ayrı teknik uygulamıştır. İlk olarak petrol fiyatları, petrol tüketimi ve arzı şeklinde üç zaman serisi kullanarak vektör otoregresyonu (VAR), ikinci olarak ise para arzı, petrol arz ve tüketimi şeklinde üç zaman serisi kullanarak geri yayımlı YSA (BPNN)

ve genetik algoritma (GA) kullanılmıştır. Tahmin performansı Ocak 1986 ve Kasım 2002 arasında hata karelerinin ortalamasının karekökü (HKOK) ve ortalama mutlak hata (OMH) şeklinde iki kritere göre değerlendirilmiştir. Karşılaştırma sonucunda YSA-GA modeli HKOK=1.2354 ve OMH=0.8629 değerleri ile HKOK=4.69861 ve OMH=4.18883 değerlerini veren VAR modeline göre çok daha iyi bir performans sergilediği tespit edilmiştir.

Bir diğer çalışmada Wang (2005) petrol fiyatı tahmininde aylık ham petrol fiyatlarını tahmin etmek için ağ tabanlı metin madenciliği (WTM), kural tabanlı uzman sistemleri (RES), otoresif entegre hareketli ortalama (ARIMA) modeli ve YSA tekniğinin bir birleşimi olan TEI@I metodolojisini kullanmıştır. WTM ile internette petrol fiyatlarını etkileyebilecek düzensiz olaylara ait verileri almıştır. Alınan verilerin fiyat üzerindeki etkisini ölçmek için RES kullanılmıştır. Petrol fiyatlarına ait zaman serisinin doğrusal kısmı için ARIMA, doğrusal olmayan kısmı için ise YSA kullanılmıştır. WTM ile veri alınarak kurulan model Ocak 1970 – Aralık 2003 tarih aralığında aylık WTI spot ham petrol verileri üzerinde sadece ARIMA, sadece YSA ve basit bir YSA-ARIMA entegrasyonu ile karşılaştırılmıştır. Yaklaşımın etkinliğini doğru bir biçimde tespit edebilmek için 3 performans kriteri kullanılmıştır. Hata karelerinin ortalamasının karekökü (HKOK), yön istatistiği (Dist), ve isabet oranı. Deneysel sonuçlar TEI@I metodolojisinin kayda değer oranda en başarılı olduğunu ortaya koymuştur. 2000-2003 arasındaki TEI@I isabet oranı %85.42 iken YSA-ARIMA entegrasyonu sonuçları %70.83 olarak hesaplanmıştır. Aynı periyotta TEI@I HKOK 1.0549; ARIMA, YSA, YSA-ARIMA entegrasyonu için değerler sırasıyla 2.0350, 2.3336 ve 2.3392 olarak hesaplanmıştır. Benzer şekilde, yön istatistiği (Dist) değeri TEI@I için yaklaşık %100 iken sırasıyla ARIMA, YSA, YSA-ARIMA entegrasyonu için değerler %54.17, %70.83 ve %85.42 olarak elde edilmiştir.

2006 senesinde Xie tarafından yapılan bir diğer çalışmada Ocak 1970 – Aralık 2003 tarih aralığındaki aylık WTI ham petrol spot fiyatlarının tahmini için destekçi vektör makinesi (SVM, support vector machine) modeli kullanılmış ve sonuçlar ARIMA ve ileri beslemeli YSA ile mukayese edilmiştir. Kullanılan iki performans kriterine göre (HKOK ve Dist) SVM'nin diğer iki modele göre daha iyi performans gösterdiği sonucuna varılmıştır. Bununla birlikte, ileri beslemeli YSA, test edilen dört alt periyodun ikisinde SVM ve ARIMA'ya göre daha başarılı performans göstermiştir.

2007 senesinde yapılan bir diğer çalışmada Amin-Naseri ve Gharacheh tarafından aylık WTI ham petrol fiyatlarının tahmininde hibrit bir yapay zeka modeli kullanılmıştır. Hibrit model 3 popüler yapay zeka tekniğinden oluşmaktadır: ileri beslemeli YSA, genetik algoritmalar ve K-ortalamalar kümeleme. Modelin etkinliğini değerlendirmek amacıyla sonuçlar kısa vadeli enerji görünümü, Gaus prosesi, yapay zeka çerçeve sistemi ve YSA şeklinde dört tekil model ile karşılaştırılmıştır. WTI ham petrol fiyatları üç ayrı deneysel çalışma için Ocak 1983 – Aralık 2006 (Gaus prosesi ile mukayese edebilmek için), Ocak 1974- Aralık 2002 (Yapay zeka çerçeve modeli ile mukayese edebilmek için), Ocak 1983 – Aralık 2002 ve Ocak 1974 – Aralık 2001 (YSA ile karşılaştırma için) şeklinde dört dönemde incelenmiştir. Deneylerin sonuçlarına göre, oluşturulan hibrit modelin performansı kullanılan 9 karşılaştırma ölçütünün (HKOK, OMH...) çoğuna göre diğer tüm tekil modelleri geride bırakmıştır

2012'de Jammazi ve Aloui kısa vadeli ham petrol fiyatını tahmin etmek için geri yayımlı YSA ve "Haar A Trouc dalgalı ayrışması"nın bir birleşimi olan hibrit bir model kullanmışlardır. Çalışmada Ocak 1988 – Mart 2010 aralığındaki aylık bazda spot WTI ham petrol fiyatları very olarak kullanılmıştır. En iyi tahmin simülasyon sonuçlarını elde edebilmek için farklı YSA mimarileri ve üç farklı transfer fonksiyonu (sigmoid, iki kutuplu sigmoid ve hiperbolik tanjant) kullanılmıştır. Performans ölçümü için ise dört farklı ölçüt kullanıldı: HKOK, OMH, isabet oranı ve R2 dikkate alınmıştır. Karşılaştırmalı deney sonuçlarına göre 3 girdili ve 3 gizli katmanlı, hiperbolik tanjant aktivasyon fonksiyonu kullanılan hibrit model (HKO=3.59066, OMH=1.10108, isabet oranı=%80, R2=0.9988), geri yayımlı YSA'ya göre (HKO=4.48590, OMH=1.140342, isabet oranı=%76, R2=0.9892), daha üstün performans göstermiştir

4. Yöntem

YSA tasarımındaki en önemli konulardan birisi verinin periyodu ve büyüklüğüdür. Kısa vadeli tahminler için günlük ve gün içi gibi düşük periyotlu veriler, daha uzun vadeli tahminler için haftalık, aylık ve 3 aylık periyotlu veriler uygun düşmektedir. Periyodun yanı sıra benzeri öneme sahip bir diğer parametre de veri büyüklüğüdür. YSA ile model tasarımı için ne kadar fazla veri olursa o kadar doğru bir model geliştirilebilir şeklinde genel bir görüş vardır. Bu görüş makul görünmekle birlikte zaman serileri için her zaman geçerli değildir zira zaman içerisinde ekonomik koşulların değişmesi ile birlikte güncel olmayan eski etkileşimler oluşturulan tahmin modelini gelecekte gerçekleşme ihtimali bulunmayan biçimde şekillendirme eğilimi

göstererek olumsuz etkileyecektir. YSA modelini oluştururken bağımlı değişkene etki etmeyen verileri de dahil etmek modelin genelleme yapmasını zayıflatmaktadır (McNelis, 2005).

Bununla birlikte aylık, 3 aylık gibi periyotlarda tahminler yapmak büyük fonlar, gerçek alıcı ve satıcılar veya hükümetler için genel bir perspektif sağlayarak anlamlı olabilecek günlük ve hatta gün içi periyotlarında tahminler yapmak piyasada işlem yapan oyuncular için daha anlamlı olmaktadır.

Bu çalışmanın pratikte kullanılabilir olması hedeflenmiş ve öncelikli olarak günlük periyotlu veriler dikkate alınmıştır. Ham petrol üretimi, stokları, toplam rezervleri ve tüketimi gibi petrol fiyatını doğrudan etkileyen veriler haftalık ve daha ziyade aylık periyotlarda açıklandığı için bu verileri günlük periyotlu olarak temin etmek mümkün değildir. Bu sebeple bu çalışmada günlük temini mümkün ve pratik olan CME ham petrol vadeli işlem fiyatları başta olmak üzere çeşitli CME vadeli işlem kontratlarına ait veriler öncelikli kullanılmakla birlikte, çalışmada aylık temin edilebilen ham petrol üretim, stok ve tüketim bilgileri kullanılarak da çalışma yapılmıştır. Kullanılan günlük periyotlu veriler bir profesyonel gün sonu veri sağlayıcısı olan Norgate Data tarafından geriye dönük ayarlama yapılarak sürekli hale getirilmiş, zaman serisi analizine uygun verilerdir. Aylık periyotlu olan ham petrol üretim, stok ve tüketim bilgileri gibi veriler ise EIA'dan temin edilmiştir.

Çalışma kapsamı tek bir emtia'nın fiyatının tahmini gibi yalın bir konu olarak görünmekle birlikte gerek tahmin yöntemi ve model seçeneklerinin çokluğu, gerek türlü gerekçelerle seçilebilecek tarih aralıklarının başlı başına çok sayıda seçenek yaratması, gerekse tahmin amaçlı kullanılacak verilerde çok fazla varyasyon yapılabilmesi, bu konuda çok uzun ve kapsamlı çalışmalar yapılabileceğine işaret etmektedir. Farklı girdi değişkenler ile YSA öğrenme süreçleri de epeyce zaman almakta ve kısıtlı süre içerisinde yapılabilecek çalışma sayısını sınırlamaktadır. Bu sebeple bu çalışmada ileriki akademik ve ticari çalışmalara bir temel teşkil edecek nitelikte görece basit kurgular seçilmeye çalışılmıştır.

Çalışma boyunca kullanılan tüm YSA modellerinde tüm katmanlar Keras'ın temel YSA katmanı olan "Dense" seçilmiştir. Modellerde kullanılan gizli katman sayıları ve katmanlardaki nöron sayıları girdi değişken sayısına adapte edilmeye çalışılarak değiştirilmiştir. Aktivasyon fonksiyonu olarak zaman serisi tahminlerinde olumlu sonuç veren "relu" tercih edilmiş, optimizasyon motoru olarak "adam" tercih edilmiştir. "adam" optimizasyon motoru olarak en hızlı sonuca giden motorlardan biri olarak öne çıkmaktadır.

Yapılan tüm çalışmalarda mevcut verinin ilk %80'lik kısmı ile öğrenme çalışması yapılmış, geriye kalan %20'lik kısmı test için ayrılmıştır. Diğer bir deyişle YSA modeli oluşturulurken verinin son %20'lik kısmı hiç kullanılmamış ve model oluşturulduktan sonra modelin o ana kadar görmediği bir grup veri olarak kullanılarak modelin performansı sınanmıştır. Oluşturulan tüm modellerde tek kayıp fonksiyonu kullanılmıştır: HKOK (Hata Karelerinin Ortalamasının Karekökü).

Yapılan aylık periyotlu tahmin çalışmalarında 04-1994 ile 10-2017 arasındaki 283 adet aylık gözlem, günlük periyotlu tahmin çalışmalarında ise 04-1994 ile 10-2017 arasındaki 4700 günlük gözlem kullanılmıştır. Yapılan modellemelerde değişken olarak aşağıda yer alan 9 adet girdi kullanılmıştır.

1. Ham petrol üretimi, OPEC üyeleri toplamı
2. Ham petrol üretimi, OPEC üyeleri hariç toplam
3. Ham petrol üretimi, ABD saha toplamı
4. Ham petrol üretimi, Dünya
5. Petrol stokları, OECD toplamı
6. Petrol stokları, ABD, Stratejik rezervler hariç (ticari)
7. Petrol tüketimi, OECD toplamı
8. Petrol tüketimi, ABD, Endüstri sektörü toplamı
9. Bir önceki aya ait ham petrol fiyatı

5. Bulgular

Çalışma kapsamında öncelikle aylık gözlem değerleri kullanılarak 9 girdi değişken dikkate alınarak tahmin yapılmıştır. Bu aşamada üç farklı model oluşturulmuştur. Söz konusu modellere ile öğrenme ve test kümelerine ait bilgiler Tablo 1'de sunulmuştur.


Tablo 1. Aylık Veri Modellerine İlişkin Bilgiler

Model No	Katman Sayısı	NÖRON SAYISI				Girdi Sayısı	Süre	Hata	
		Giriş	Gizli-1	Gizli-2	Çıkış			HKOK Öğrenme	HKOK Test
Model-1	3	16	4	-	1	9	283 Ay	2,54	4,63
Model-2	3	8	4	-	1	9	283 Ay	3,48	4,62
Model-3	3	16	32	-	1	9	283 Ay	3,09	4,38


Tablo 1 incelendiğinde; üç modelde de 9 girdi ve 1 çıktı olduğu görülmektedir. Nöron sayılarındaki farklılardan dolayı öğrenme ve test kümelerine ait HKOK farklılaşmaktadır. Elde edilen bulgulara göre Model-1'in öğrenme HKOK'u daha düşük olmasına rağmen; test kümesi açısından Model-3'ün daha iyi olduğu söylenebilir.

Bu modeller kullanılarak gerçekleştirilen tahminlere ilişkin performansların değerlendirilebilmesi amacıyla sırasıyla Grafik 2, Grafik 3 ve Grafik 4 çizilmiştir.


Grafik 2. Model 1 Performans Grafiği



Grafik 3. Model 2 Performans Grafiği




Grafik 4. Model 3 Performans Grafiği



Çalışmanın diğer aşamasında ise günlük gözlem değerleri kullanılarak tahminleme yapılmıştır. Yapılan günlük periyotlu tahmin çalışmalarında 04.01.2000'den 03.11.2016'ya kadar toplam 4.227 günlük veri kullanılmıştır. Tüm çalışmalarda girdi değişken olarak önceki günlerdeki fiyat verisi dikkate alınmıştır. Örneğin 2 girdi değişken kullanıldığında; n. günü tahmin etmek için n-1 ve n-2. günlerin fiyatları kullanılmıştır. Gün sayısı fazla olduğundan dolayı bu modeller için gerçek fiyatlar ve tahmin edilen fiyatlar tüm süreç için üst üste koyulduğunda görünür olmamaktadır. Bu sebeple fikir vermesi açısından belirtilen süreçteki gerçek petrol fiyatları ve tahmin edilen fiyatlar Grafik 5 ve Grafik 6 da sunulmuştur. Bu grafikler ayırt edilemeyecek düzeyde


yaklaşık olarak aşağıdaki tüm modeller için geçerlidir. Modeller arasında farklılık gösteren kısımları görselleştirmek için test sürecinden 100'er günlük birer kesit grafiği her bir model ile birlikte ayrıca sunulmuştur.

Grafik 5. 04.01.2000- 03.11.2016 arası 4227 günlük süreçte ham petrol fiyatları



Grafik 5'e bakıldığında petrol fiyatlarının 4227 günlük seyri görülmektedir. Bu verinin dönem aralığı öğrenme ve test kümesi olmak üzere ikiye ayrılmıştır. Bu veri dönemleri kullanılarak gerçekleştirilen tahminlere ait grafik ise aşağıda sunulmuştur.

Grafik 6. 04.01.2000- 03.11.2016 arası 4227 günlük süreçte öğrenme ve test süreçleri için tahmin edilen hampetrol fiyatları



Çalışma kapsamında aylık verilerin yanısıra 100 günlük veri kullanılarak 3 farklı model oluşturulmuştur. Söz konusu modellere ile öğrenme ve test kümelerine ait bilgiler Tablo 2'de sunulmuştur.

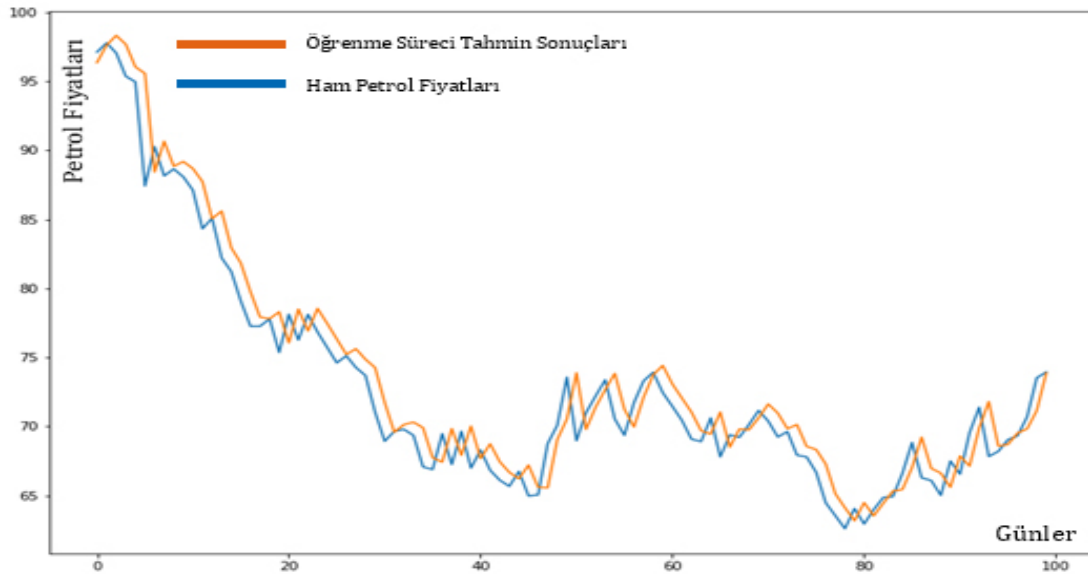
Tablo 2. Günlük Veri Modellerine İlişkin Bilgiler

Model No	Katman Sayısı	NÖRON SAYISI				Girdi Sayısı	Süre	Hata	
		Giriş	Gizli-1	Gizli-2	Çıkış			HKOK Öğrenme	HKOK Test
Model-4	3	8	4	2	1	2	100 Gün	1,32	1,42
Model-5	3	8	4	2	1	5	100 Gün	1,24	1,32
Model-6	3	8	4	2	1	15	100 Gün	1,11	1,19


Tablo 2 incelendiğinde; günlük gözlem değerleri kullanılarak üç farklı model ile tahminlerin gerçekleştirildiği görülmektedir. Bu modellerin sadece girdi sayıları farklılık göstermektedir. Öğrenme ve test veri kümeleri için hesaplanan HKOK değerleri incelendiğinde en iyi performansa sahip modelin Model-6 olduğu söylenebilir.

Bu modeller kullanılarak gerçekleştirilen tahminlere ilişkin performansların değerlendirilebilmesi amacıyla sırasıyla Grafik 7, Grafik 8 ve Grafik 9 çizilmiştir.


Grafik 7. Model 4 Performans Grafiği



Grafik 8. Model 5 Performans Grafiği



Grafik 9. Model 6 Performans Grafiği



Günlük periyotlu veriler ile yapılan çalışmalarda (Model 4, Model 5, Model 6) beklendiği gibi hata oranı daha düşüktür. Bu verilerde anlamlı girdi sayısı arttıkça hata oranlarında düşüş gözlenmektedir. Aylık periyotlu veriler kullanılarak yapılan tahminlerde (Model 1, Model 2, Model 3) nöron sayısının yükselmesine paralel olarak hata oranlarında düşüş gözlenmektedir.

Sonuç

Bu araştırma kapsamında petrol fiyatının yapay sinir ağları ile tahmin çalışmaları yapılmıştır. Petroldeki fiyat hareketliliği ticari maliyetleri ve dolayısıyla ekonomiyi direkt etkilediği için fiyat istikrarı, veya en azından öngörülebilirliği, dolayısıyla tahmin edilebilirliği büyük önem taşımaktadır.

Tahmin çalışması günlük ve aylık periyot olarak iki şekilde ele alınmıştır. Günlük periyotlu veriler ile yapılan çalışmalarda beklendiği gibi hata oranı daha düşüktür. Bu verilerde anlamlı girdi sayısı arttıkça hata oranlarında düşüş gözlenmektedir. Aylık periyotlu olan çalışmalarda nöron sayısının yükselmesine paralel olarak hata oranlarında düşüş gözlenmektedir.

Bu alandaki çalışmalara günlük fiyat tahmininde fiyatı etkileyebilecek diğer finansal enstrümanların fiyatları, anlık petrol haberleri ve açıklama verileri gibi bilgiler işlenerek ilave edilir ise daha başarılı sonuçlar alınabileceği öngörülmektedir.

Kaynakça

Aghababaeyan, R., Siddiqui, T.& Khan, A.N. (2011) Forecasting the Tehran Stock Market by Artificial Neural Network. International Journal of Advanced Computer Science and Applications Special Issue on Artificial Intelligence.

Amin-Naseri, M. R.,Gharacheh, E. A. (2007) A hybrid artificial intelligence approach to monthly forecasting of crude oil price time series., CEANN'2007, pp. 160-167.

Azoff, M. (1994) Neural network time series forecasting of financial markets. New York: John Wiley.

British Petrol. (2017) World Energy 2017 <https://www.bp.com/content/dam/bp/en/corporate/pdf/energy-economics/statistical-review-2017/bp-statistical-review-of-world-energy-2017-full-report.pdf>

Diler, A. (2003) İMKB Ulusal-100 Endeksinin Yönünün Yapay Sinir Ağlarıyla Hata Geriye Yayma Yöntemi İle Tahmin Edilmesi. İMKB Dergisi (7)

Elmas, Ç. (2011) Yapay Zeka Uygulamaları. Ankara, Seçkin Yayıncılık.

Fauset, L. (2011) Fundamentals of Neural Networks

- Ghaffari, A., Zare S. (2009) A novel algorithm for prediction of crude oil price variation based on soft computing. *Energy Economics* 31, pp. 531-536.
- Haykin, S. (1999) *Neural networks a comprehensive foundation*. New Jersey: Wiley.
- Jammazi, R., Aloui, C. (2012) Crude oil price forecasting: Experimental evidence from wavelet decomposition and neural network modeling. *Energy Economics* 34(3), pp. 828-841.
- Kaboudan, M. A. (2001). Compumetric forecasting of crude oil prices. pp. 283-287.
- McCulloch, W. S., Pitts. W. A. (1943) A logical calculus of the ideas immanent in nervous activity, *Bulletin of Mathematical Biophysics* 5, 115-33.
- McNelis, P. D., (2005) *Neural Networks in Finance*. London: Elsevier.
- Mirmirani, S., Li, H.C. (2004) A comparison of VAR and neural networks with genetic algorithm in forecasting price of oil. *Advances in Econometrics* 19, pp. 203-223.
- Moshiri, S., Forotuan, F. (2006) Forecasting Nonlinear Crude Oil Future Prices. *Energy Journal* 27, pp. 83-97.
- Rast, M., (2001) Fuzzy neural networks for modelling commodity markets. (NAFIPS'2001), pp. 952-955.
- Rosenblatt, F., (1958) The Perceptron: A probabilistic model for information storage and organization in the brain. *Psychological Review* 65, pp. 386-408.
- Shambora, W. E., Rossiter, R. (2007) Are there exploitable inefficiencies in the futures market for oil?. *Energy Economics* 29, pp. 18-27.
- Sugiyama, M., 2016. *Introduction to Statistical Machine Learning*. Massachusetts: Elsevier.
- Wang, S. Yu, L., Lai, K.K. (2005) Crude oil price forecasting with TEI@I methodology. *Journal of Systems Sciences and Complexity* 18(2), pp. 145-166.
- Widrow, B., Hoff, M. E. (1960) Adaptive switching circuits. Institute of Radio Engineers, Wester Electronic Show and Convention, Convention Record, Part 4, pp. 96-104.
- Wongsinlatam, M. S. a. W. (2014) Prediction Model for Crude Oil Price Using Artificial Neural Networks. *Applied Mathematical Sciences*, Vol. 8, 2014, no. 80, pp. 3953 - 3965.
- Xie, W., Yu, L., Xu, S., Wang, S. (2006) A new method for crude oil price forecasting based on support vector machines. *Lecture notes in computer science* 3994, pp. 44-451.
- Xiong, T., Bao, Y., Hu, Z. (2013) Beyond One-Step-Ahead Forecasting: Evaluation of Alternative Multi-Step-Ahead Forecasting Models for Crude Oil Prices. *Energy Economics*, 40, 405-415.
- Zupan, J. (2003). Basics of artificial neural networks. *Data handling in science and technology* 23, 218.

ESTIMATION OF PETROLEUM PRICES WITH ARTIFICIAL NEURAL NETWORKS MODEL

Extended Abstract

Introduction: Oil has been the world's most important energy source for more than 150 years, when we first passed through the first pit opened in Pennsylvania on August 16, 1861. Today it is still the raw material of the most used fuels of all vehicles in land, sea and air. For this reason, the future prices of both producers, consumers and merchants are among the most sought-after commodities. As a result, both the commercial environment and the academic environment are often subject to price estimation. In the past, various regression approaches, models such as GARCH and ARMA have been used in estimating studies, and more recently, relatively more efficient prediction studies have been conducted with developing hardware and algorithms and models built with artificial neural networks.

There are a number of studies on the estimation of stock prices and futures prices, futures and futures, as well as spot and futures prices. Models such as traditional regression models, GARCH, ARIMA, ANN models and their various comparisons are made from different angles. While some studies have focused on price estimation, some studies have only attempted to make direction estimates. In this study, it is aimed to estimate the price of oil. In doing so, it is aimed to use as much of the current tools as possible as efficiently as possible and to develop a commercially viable approach.

Methodology: One of the most important issues in ANN design is the period and size of the grant. For short-term estimates, low-periodic data such as daily and daytime are available. For longer-term estimates, weekly, monthly and quarterly data are appropriate. Another parameter with the same prefix as the period is the data size. With ANN there is a general view that the more data available for model design, the more accurate a model can be developed. This view seems plausible, but does not always apply to time series because, as economic conditions change over time, up-to-date outdated interactions will adversely affect the forecasting model, with a tendency to shape it in a way that is unlikely to occur in the future.

Although the scope of the study seems to be a lean issue such as the estimation of the price of a single commodity, the multiplicity of forecasting methods and model alternatives, the choice of date ranges for which it is possible to select for any reason, and the possibility of making too many variations on the data to be used for estimation purposes, indicating that extensive work can be done. ANN learning processes with different input variables also take a considerable amount of time and limit the number of works that can be done in a limited time. For this reason, it has been tried to choose simple fictions in this study in terms of the quality that will constitute a basis for future academic and commercial studies.

In all the ANN models used throughout the study, all layers were selected as the "basic" ANN layer of Keras. The hidden layer numbers used in the models and the neuron numbers in the layers have been changed by trying to adapt to the input variable number. As an activation function, "relu" which gives positive results in the time series estimations is preferred, "man" as the optimization engine is preferred. "Man" stands out as one of the fastest-reaching motors as an optimization engine. For example, in the following study, where learning costs are compared, they are the least costly.

Results: Within the scope of this research, estimation of oil price with artificial neural networks has been done. Price stability, or at least predictability, therefore predictability is of great importance as the price volatility in the oil affects the business costs and therefore the economy directly. Estimation work is handled in two ways as daily and monthly periods. The error rate is lower as expected with studies done with daily periodical data. As the number of significant inputs increases in these data, the error rates decrease. Monthly periodic studies show a decrease in the error rates in parallel with the increase in the number of neurons.

It is predicted that more successful results can be obtained if the prices of other financial instruments that may affect the price in the daily price estimation of the work in this area are added by processing information such as instant oil news and explanation data.

Conclusion and Discussion: Nowadays, energy expenditures within the global economy have a considerable share. Petroleum supply against intense demand is realized by a limited number of countries. In addition to the basic supply and demand mechanism, economic contracts and political developments among countries can have a significant effect on oil prices. In this respect, it is necessary to avoid the risks that may arise by predicting oil prices. Data were taken daily in order to make the estimates meaningful.

However, many factors that affect the price of oil cannot be determined on a daily basis. Therefore, it is not possible to find data other than the price that can be used in the daily estimates, and this data is used in the monthly estimation study. It is anticipated that further work will be achieved if further studies to be performed on this area are made by adding information such as prices of other financial instruments that may affect the price in the daily price forecast, such as instant oil news and statement data.