

Ham petrol fiyatlarının ANFIS ile tahmini

Oğuz KAYNAR¹, Metin ZONTUL², Ferhan DEMİRKOPARAN³

Özet

Ekonomik kalkınmanın temel ağırlıklı girdisini oluşturan ve halen dünyadaki en önemli enerji kaynağı olma özelliğini koruyan petrol, doğrudan ya da dolaylı olarak tüm sektörleri etkilemektedir. Bu nedenle petrol piyasasında ve dolayısıyla fiyatında ortaya çıkan değişiklikler, oluşturdukları zincirleme reaksiyonlar aracılığı ile hem ülke, hem de dünya ekonomisi üzerinde çeşitli etkiler yaratmaktadır. Karmaşık dinamiklerinden dolayı, oldukça değişken ve etkileşimli bir yapıya sahip petrol piyasasında geleceğe yönelik etkili planlar yapmak için doğru ve güvenilir tahminlere gereksinim vardır. Bu çalışmada orta ve uzun vadeli petrol fiyatlarını tahmin etmek amacıyla bulanık çıkarım sistemleriyle yapay sinir ağlarının birleşiminden oluşan ANFIS (Adaptive Neuro Fuzzy Inference System) kullanılmıştır.

Anahtar Kelimeler : ANFIS, Ham Petrol, Tahmin

Crude oil price forecasting by using ANFIS

Abstract

Oil which is basic input of economic development and resumes to be the most important source of energy in the world, affects all sectors directly or indirectly. Consequently, the changes on petrol industry, and thus, on petrol prices create various effects on both country and world economy by means of chaining reactions turning up. For making affective plans for the future about petrol industry which has a considerably unsteady and interactive structure because of its complex dynamics, straight and confidential predictions are needed. So, ANFIS (Adaptive Neuro Fuzzy Inference System) which consists of integration of fuzzy inference systems and artificial neural networks is used to predict crude oil prices in middle and long term in this study.

Keywords : ANFIS, Crude oil, Forecasting

¹ Yard. Doç. Dr. Oğuz Kaynar, Yönetim Bilişim Sistemleri Bölümü, Cumhuriyet Üniversitesi, Sivas, Türkiye

² Yard. Doç. Dr. Metin Zontul, Yazılım Mühendisliği Bölümü, İstanbul Aydın Üniversitesi, İstanbul, Türkiye

³ Arş. Gör. Ferhan Demirkoparan, Yönetim Bilişim Sistemleri Bölümü, Cumhuriyet Üniversitesi, Sivas, Türkiye
okaynar@cumhuriyet.edu.tr, metinzontul@aydin.edu.tr, fdemirkoparan@cumhuriyet.edu.tr

Giriş

Ham petrol; doğal gaz ile birlikte temel küresel enerji tüketiminin üçte ikisini karşılamasıyla, günlük 80 milyon varilli aşan talebi ve küresel arzıyla dünya ekonomisinin en kritik ticari mallarından biridir (Naseri, 2007). Dünya ekonomileri ekonomik kalkınmanın en temel ağırlıklı girdisi olan bu ürüne gün geçtikçe daha fazla gereksinim duymaktadır (Uğurlu, 2009). Enerjiye duyulan ihtiyacın artması petrolün ticari ve ekonomik dengeleri değiştirebilen stratejik bir araca, petrolü kendi coğrafyasında bulduran ülke ve bölgelerin ise, bu stratejik aracın stratejik rekabet alanlarına dönüşmesine neden olmuştur. 20. yüzyılın başından itibaren petrol, dünya ekonomi ve siyasetine damgasını vurmuş ve küresel ölçekte petrol stratejilerinin ortaya çıkmasına neden olmuştur (Aklin, 2008).

Küresel rekabet alanı içerisinde, öncelikle ülkeler ve ülkeler içerisinde hükümetler, petrol ve diğer enerji kaynaklarının geleceği konusunda, başta ekonomik olmak üzere siyasi, askeri ve toplumsal açıdan değerlendirmeler yaparak hedefler koymaktadırlar. Özellikle petrolün gelecek enerji stratejileri ve politikalarında önemli bir rol oynaması neticesinde hükümetler, ideolojileri ve kesin ekonomik tercihlerine bakmaksızın geniş perspektifte değerlendirmeler yapmayı amaç edinmektedirler. Uyguladıkları politikalar kapsamında; küresel rekabet alanında uzlaşsı olsun ya da olmasın, enerji piyasası lideri durumundaki ham petrolün dünya piyasasındaki yerine ve fiyatlarına öncelik vermekte ve buna göre stratejilerini ortaya koymaktadırlar (Aklin, 2008). Bu bakımdan ham petrol fiyatları, hükümetler için olduğu kadar sektördeki karar vericiler ve planlayıcılar tarafından da güvenilir tahminlere ihtiyaç duyulan, küresel olarak oldukça önemli bir değişkendir (Kaboudan, 2001). Çünkü ham petrol fiyatındaki keskin yükselişler, petrol ithal eden ülkelerin enflasyon ve ekonomik büyümelerini olumsuz yönde etkilemektedir. Bu gibi değişikliklere etkili bir şekilde yanıt verebilmek için güvenilir, kısa ve uzun dönemli ham petrol fiyatı tahminleri gerekmektedir (Abosedra, 2004). Temel mekanizmaları ve yönetim prensiplerinin karmaşık dinamikleri tam olarak anlaşılabilen, oldukça değişken ve etkileşimli bir piyasa olan petrol piyasasında (Bernabea, 2004) fiyat tahminleri arz ve talebin kestiriminde (Kaboudan, 2001) ve fiyat dalgalanmalarının negatif etkilerini bertaraf etmede kullanılmaktadır (Kulkarni, 2009).

Petrol fiyatlarının tahminine ilişkin literatür incelendiğinde çok farklı çalışmalara rastlanmaktadır. Alexandridis ve Livanis (Alexandridis, 2008) açıklayıcı değişken olarak geçmiş petrol fiyatları, petrol üretici fiyat endeksi ve dünya ham petrol üretimini kullandıkları çalışmalarında, Wavelet Neural Network ile bir, üç ve altı aylık geleceğe yönelik ham petrol fiyat tahmini yapmışlardır. Amin-Naseri ve Gharacheh (Naseri, 2007) ise çalışmalarında ileri beslemeli yapay sinir ağları (YSA), genetik algoritma ve k-means kümeleme yöntemlerinden oluşan hibrit bir model önermişler ve önerdikleri modeli Amerikan Enerji İstatistik Ofisinin (EIA, Energy Information Administration) ekonometrik modeli ve literatürden üç YSA modeli ile karşılaştırmışlardır. Değerlendirmeleri sonucunda önerdikleri modelin bahsedilen modellerden daha iyi performans gösterdiğini belirtmişlerdir. Harrald ve Kamstra (Harrald, 1997) evrimsel programlama deneyimlerinden yararlandıkları çalışmalarında finansal tahminleri birleştirmek için bir yapay sinir ağı geliştirmişlerdir. Pan vd. (Pan, 2009) çoklu pazar dinamiklerinden yararlanarak ham petrol fiyatlarının kısa dönem eğilimlerinin günlük tahminini yaptıkları çalışmalarında 4 farklı yapay sinir ağı modeli tasarlamış ve geçmiş verilerle test etmişlerdir. Ghaffari ve Zare (Ghaffari, 2009) esnek hesaplama teknikleri kullanarak geliştirdikleri metod ile WTI'nin (West Texas Intermediate) ham petrol fiyatlarının günlük değişimlerini tahmin etmiş, tahmin edilen değer ile gerçek değeri karşılaştırarak aradaki farkı öğrenme algoritmasını aktive etmek için kullanmışlardır. Fernandez (Fernandez, 2007) ham petrol ve doğal gaz fiyatlarını günlük olarak tahmin ettiği çalışmasında YSA, support vector machines (SVM) ve ARIMA modellerini karşılaştırmıştır. 2-4 gün gibi kısa vadede

ARIMA'nın, 10-20 gün gibi uzun vadeli tahminlerde ise diğer iki metodun daha iyi performans gösterdiğini, YSA ve SVM'nin lineer kombinasyonunun ise modellerin tek tek gösterdiği performanstan daha iyi olduğunu belirtmişlerdir. Kulkarni ve Haidar (Kulkarni, 2009) ham petrol fiyatı tahmin modellemesi için çok katmanlı ileri beslemeli yapay sinir ağı önermişler ve 13 dönemlik dinamik YSA ile kısa dönemli tahminin en uygun model olduğunu belirtmişlerdir. Xie vd. (Xie, 2006) ham petrol fiyat tahmini yaptıkları çalışmalarında SVM tabanlı yeni bir model önermiş, bu modeli ARIMA ve BPNN modelleri ile karşılaştırarak önerdikleri modelin daha iyi performans gösterdiğini belirtmişlerdir.

Bu çalışmada ise ham petrol fiyatlarını tahmin etmek amacıyla uyarlamalı ağ bulanık sistemleri (Adaptive Neuro Inference System ANFIS) kullanılmıştır. İlk olarak Jang (Jang,1993) tarafından önerilen ANFIS, bulanık sistemlerle yapay sinir ağlarının birleşiminden oluşan tümeleşik bir sistemdir. Bulanık sistemler uzman görüş ve deneyimlerini sözel ifadeler yardımıyla sisteme aktarırken, yapısı gereği hem doğrusal hem de doğrusal olmayan ilişkileri modelleyebilen YSA, öğrenme özelliği sayesinde veriden hareketle birçok değişik formdaki fonksiyonel yapıyı başarıyla modelleyebilmekte ve herhangi bir formdaki fonksiyona belirli bir doğrulukta yakınsayabilmektedir (Cybenko,1989) (Hornik,1989) (Hornik,1991). Her iki yöntemin avantajlarını birleştiren ANFIS, son yıllarda tahmin, sınıflandırma, kontrol, zaman serileri analizi gibi bir çok alanda başarıyla kullanılmaktadır.

Çalışmamızda haftalık ve aylık ham petrol fiyatlarını içeren zaman serileri kullanılmıştır. Her iki veri seti için de ANFIS kullanılarak tahmin modelleri oluşturulmuş ve bu modeller yardımıyla orta ve uzun vadeli ham petrol fiyatları tahmin edilmiştir. Oluşturulan modellerin performansını kıyaslamak amacıyla ortalama mutlak yüzde hata (MAPE, Mean Absolute Percentage Error) performans kriteri kullanılmıştır. Bir çok performans ölçütü tanımlanmasına karşın MAPE'nin tercih edilmesinin nedeni, veri setinin ölçek büyüklüğünden bağımsız olarak 0-100 aralığında kolayca karşılaştırılabilir küçük değerler üretmesidir (Chen,2009). MAPE değeri ne kadar küçük olursa elde edilen tahmin değerleri gerçek değerlere o oranda yaklaşacaktır. MAPE değeri aşağıda verilen eşitlik yardımıyla hesaplanır.

$$MAPE = \frac{1}{N} \sum_{i=1}^N \left| \frac{d_i - \hat{y}_i}{d_i} \right| \times 100 \quad (1)$$

d_i , i . örneğe ait gerçek değeri gösterirken; \hat{y}_i , i . örneğe ilişkin tahmin değerini göstermektedir.

Uyarlamalı ağ bulanık çıkarım sistemleri

Genel olarak bulanık çıkarım sistemleri, bulanık kuralların oluşturduğu kural tabanı, üyelik derecelerinin belirlenmesinde kullanılan veri tabanı ve kurallara bağlı olarak sonuçların üretilmesini sağlayan çıkarım birimlerinden oluşmaktadır (Fırat, 2007). Bulanık sistemlerde işleyiş 4 aşamada gerçekleşir. İlk olarak giriş değişkenlerine ilişkin üyelik fonksiyonlarının belirlenmesi ve giriş değişkenlerinin bulanıklaştırılması sağlanır. İkinci aşamada giriş ile çıkış arasındaki ilişkileri ortaya koyan kurallar belirlenir. Üçüncü aşamada bu kurallar yardımıyla çıkış karakteristiklerinin belirlenmesi sağlanır. Son aşama ise çıkışın belirlenmesi aşamasıdır. Bulanık sistemler eğer-ise kuralları yardımıyla giriş ve çıkış uzayını belirli bölgelere ayırarak giriş uzayını çıkış uzayına lineer olmayan şekilde haritalar. Giriş uzayının bölümlenmesi, eğer-ise kurallarının öncül kısmında kullanılan üyelik fonksiyonları yardımıyla gerçekleştirilirken çıkış uzayının bölümlenmesi işlemi çıkış üyelik fonksiyonları yardımıyla gerçekleştirilir (Nayak, 2004). Giriş üyelik fonksiyonunun

şeklini belirleyen üyelik fonksiyonlarına ait parametreler öncül parametreler, çıkış uzayının belirlenmesini sağlayan parametreler ise soncul parametreler olarak adlandırılır. Bulanık çıkarım sistemlerinin temel problemi üyelik fonksiyonlarını oluşturan parametrelerin belirlenmesi ve kuralların oluşturulması aşamasında genel bir yaklaşımın olmaması ve uzman kişilerin bu parametreleri belirlerken birçok deneme yapmasını zorunlu kılmasıdır. Bulanık sistem tasarımı için giriş ve çıkış üyelik fonksiyonlarına ait bu parametrelerin doğru bir şekilde belirlenmesi sistemin performansı açısından son derece önemlidir. Diğer yandan yapay sinir ağları, girişle çıkış arasındaki ilişkiyi veri setinden öğrenerek kendisini adapte etme yeteneğine sahiptir. Bulanık çıkarım sistemleriyle yapay sinir ağlarını birleştirmedeki ana düşünce bulanık sistemlerin bilgiyi anlaşılır bir şekilde sunma özelliği ile yapay sinir ağlarının öğrenme özelliğini kullanarak parametreleri optimize edecek şekilde yeni bir sistem geliştirmektir. Böylelikle bulanık sistemlerdeki üyelik fonksiyonlarına ilişkin parametreleri belirleyecek ve eğer-ise kurallarını otomatik olarak oluşturacak bir yapının ortaya çıkarılması sağlanmaktadır (Yurdusev, 2009).

Bulanık mantık uygulamalarında genellikle Mamdani (Mamdani, 1975) ve Sugeno (Takagi, 1985) bulanık çıkarım mekanizması kullanılmaktadır. İki çıkarım mekanizması arasındaki temel fark eğer-ise kurallarının soncul parametrelerinden kaynaklanmaktadır. Mamdani bulanık sisteminde eğer-ise kurallarının sonucu bir bulanık küme iken Sugeno tip bulanık çıkarım sisteminde sonuç ifadesi ya sabit bir değer ya da giriş değişkenlerinin fonksiyonudur. Eğer-ise kuralının sonuç ifadesi sabit bir değer ise bu tip sistemler sıfıncı dereceden Sugeno bulanık sistemler olarak adlandırılır, sonuç ifadesi giriş değişkenlerinin lineer bir fonksiyonu şeklindeyse birinci dereceden Sugeno bulanık sistemler olarak tanımlanır (Jang, 1997). Birinci dereceden iki girişli bir Sugeno bulanık çıkarım sistemi için eğer-ise kuralı aşağıdaki şekilde verilir.

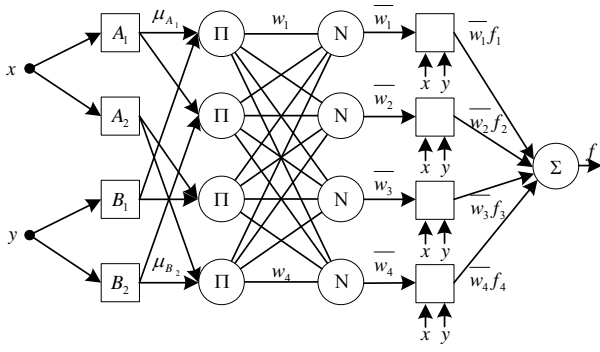
$$\text{If } x \text{ is } A_i \text{ and } y \text{ is } B_i \text{ then } f_i = p_i x + q_i y + r_i \quad (2)$$

A_i ve B_i giriş değişkenlerine ilişkin dilsel ifadeleri, p_i , q_i ve r_i ise kurala ilişkin soncul parametreleri göstermektedir. Şekil 1'den de görüleceği üzere ANFIS yapısı 5 katmanlı bir mimariye sahiptir.

Katmanlarda farklı şekillere sahip düğümler değişik işlevlere sahip fonksiyonları içerir. Kare şeklinde gösterilen düğümler adaptif düğümler olarak adlandırılır ve düğümlere ait parametreler ağın eğitimi sırasında ayarlanır (Ying, 2008). Daire şeklinde gösterilen düğümler ise sabit düğümlerdir. Her bir katmandaki fonksiyonların işlevi aşağıda açıklanmıştır:

Katman1(Giriş katmanı): Bu katmanda yer alan düğümler ayarlanabilen düğümlerdir ve bu düğümlerde giriş değişkenlerine ait bulanık kümelerle ilişkin üyelik fonksiyonları yer almaktadır. Bu düğümlerin çıkışı, ilgili üyelik fonksiyonunun derecesini göstermektedir ve eşitlik 3' teki şekilde verilir.

$$\begin{aligned} O_{1,i} &= \mu_{A_i}(x) \quad i = 1, 2 \\ O_{1,i} &= \mu_{B_{i-2}}(y) \quad i = 3, 4 \end{aligned} \quad (3)$$



Şekil 1. Anfis Mimarisi

x , y değerleri i . düğüme ilişkin giriş değerlerini A_i ve B_i sözel olarak ifade edilen bulanık kümeleri, μ_{A_i} ve μ_{B_i} değerleri ise bu kümelere ait üyelik fonksiyonlarının derecelerini göstermektedir. Üyelik fonksiyonu olarak literatürde trapez, üçgen, genelleştirilmiş-bell, ve gauss fonksiyonları önerilmiştir. Bunlar arasında en yaygın olanı ve çalışmamızda da kullanılan genelleştirilmiş-bell fonksiyonu eşitlik 4'te verilmiştir.

$$\mu(x) = \frac{1}{1 + \left(\frac{x - c_i}{a_i} \right)^{2b_i}} \quad (4)$$

$\{a_i, b_i, c_i\}$ bu üyelik fonksiyonun şeklini belirleyen parametrelerdir ve öncül parametreler olarak adlandırılırlar. c_i parametresi bell fonksiyonunun merkezini, a_i değeri fonksiyonun genişlik değerini, b_i ise fonksiyona ilişkin düzeltme faktörünü belirler.

Katman2 (Kural katmanı): Π ile etiketlenen bu katmandaki düğümlerin tamamı sabit düğümlerdir. İlgili kuralın öncül kısmına ait üyelik fonksiyonlarına T-norm (AND yada çarpım operatörü) operatörünün uygulanması sonucunda ilgili düğümün çıkışı hesaplanır. Böylelikle her bir kuralın çıkış fonksiyonunun şeklini belirlemedeki etkisi elde edilir ve bu değer ilgili kuralın tetikleme ya da ateşleme ağırlığı (Firing strength) olarak adlandırılır. Bu katmanın çıkışları bir önceki katmandan elde edilen üyelik derecelerinin çarpımı şeklinde hesaplanır.

$$O_{2,i} = w_i = \mu_{A_j}(x) \times \mu_{B_j}(y) \quad (5)$$

$$i = 1, \dots, 4; j = 1, 2$$

Katman3 (Normalizasyon katmanı): Bu katmanda yer alan her bir düğüm N ile etiklendirilmiş sabit bir düğümdür. i . düğümün çıkışı, i . kuralın tetikleme ağırlığının tüm kuralların tetikleme ağırlıklarının toplamına oranı şeklinde hesaplanır. Bu katmanın çıkışları, normalize edilmiş tetikleme ağırlıkları olarak adlandırılırlar.

$$O_{3,i} = \bar{w}_i = \frac{w_i}{\sum_{k=1}^4 w_k} \quad i = 1, \dots, 4 \quad (6)$$

Ham petrol fiyatlarının ANFIS ile tahmini

Katman4(Sonuç katmanı): Bu katmandaki her bir düğüm, her bir kuralın toplam çıkış fonksiyonu üzerindeki etkisini belirler ve aşağıda verildiği şekilde hesaplanır.

$$O_{4,i} = \overline{w}_i f_i = \overline{w}_i (p_i + q_i + r_i) \quad i = 1, \dots, 4 \quad (7)$$

\overline{w}_i bir önceki katmanın çıkışını ifade ederken $\{p_i, q_i, r_i\}$ ise i . kurala ilişkin ayarlanabilen soncul parametreleri göstermektedir. Aynı zamanda bu parametreler Sugeno bulanık çıkarım sitemindeki lineer fonksiyonun katsayıları olarak da bilinir.

Katman5(Çıkış katmanı): Σ ile simgelenen bu katman tek düğümüne sahiptir ve bu düğüm kendisine gelen tüm sinyallerin toplamını alarak sistemin toplam çıkışını hesaplar.

$$O_{5,i} = \sum_{i=1}^4 \overline{w}_i f_i = \frac{\sum_{i=1}^4 w_i f_i}{\sum_{i=1}^4 w_i} \quad (8)$$

ANFIS ağının eğitimi, tek başına gradyent eğim azalım algoritması ya da en küçük hata kareler yöntemi ile gradyent eğim azalım algoritmasının birleşiminden oluşan tümleşik eğitim algoritması yardımıyla gerçekleştirilir. Gradyent eğim azalım algoritması tek başına tüm parametreleri belirlemek için kullanılabilir fakat eğitim süresinin uzun olması ve bölgesel minimumlara takılma riski nedeniyle ağın eğitiminde genellikle Jang tarafından önerilen iki aşamalı tümleşik (hybrid) eğitim algoritması kullanılır. Hybrid eğitim algoritması ileri ve geri yönde olmak üzere iki aşamadan oluşur. Eğitimin başında üyelik fonksiyonları tanımlanarak öncül parametrelerin ilk değerleri belirlenir. Eğitim algoritmasının ileri doğru olan geçişinde bu öncül parametreler (a_i, b_i, c_i) sabit tutularak dördüncü katmana kadar her bir katmanın çıkışı hesaplanır. Ardından (p_i, q_i, r_i) soncul parametreleri en küçük hata kareler yöntemiyle elde edilir. Öncül parametreler belirli bir sabit değerde iken sistemin genel çıkışı soncul parametrelerin doğrusal birleşimi şeklinde yazılabilir.

$$\begin{aligned} f_{out} &= \sum_{i=1}^n \overline{w}_i f_i = \overline{w}_1 f_1 + \overline{w}_2 f_2 + \overline{w}_3 f_3 + \overline{w}_4 f_4 \quad (9) \\ &= (\overline{w}_1 x) p_1 + (\overline{w}_1 y) q_1 + w_1 r_1 + (\overline{w}_2 x) p_2 + (\overline{w}_2 y) q_2 + w_2 r_2 \\ &+ (\overline{w}_3 x) p_3 + (\overline{w}_3 y) q_3 + w_3 r_3 + (\overline{w}_4 x) p_4 + (\overline{w}_4 y) q_4 + w_4 r_4 \end{aligned}$$

n adet örnek içeren eğitim veri seti için, bilinen (x_i, y_i) değerleri giriş örneklerini, d_i ise bu giriş değerlerine karşılık ilgili çıkış değerini gösterebilir. Öncül parametreler bilindiğinden sistemin çıkışı f , soncul parametreler yardımıyla matris formunda lineer denklem sistemi olarak ifade edilir.

$$f = B\theta \quad (10)$$

Eşitlikte θ soncul parametreleri içeren bilinmeyenler matrisini, B ise bilinen katsayılar matrisini göstermektedir. Eğer B matrisinin tersi alınabiliyorsa en küçük kareler hata tahmincisi θ^* aşağıda verilen şekilde hesaplanır.

$$\theta^* = B^{-1} f \quad (11)$$

B matrisinin tersinin alınmadığı durumda ise θ^* değerini bulmak için yalancı tersleme (pseudo-inverse) yönteminden faydalanılır.

$$\theta^* = (B^T B)^{-1} B^T f \quad (12)$$

Soncul parametreler belirlendikten sonra eldeki eğitim verisi için sistemin toplam hatası eşitlik 13 yardımıyla hesaplanır.

$$E = \sum_{i=1}^n E_i = \sum_{i=1}^n (d_i - f_{out_i})^2 \quad (13)$$

E_i , ağa sunulan i . giriş için sistemin hatasını, d_i , i . giriş değeri için arzu edilen çıkış değerini, f_{out_i} i . giriş için sistemin hesapladığı çıkış değerini, E ise tüm girdiler için sistemin toplam hatasını göstermektedir.

Hybrid öğrenme algoritmasının geriye doğru geçişinde ise sonuç parametreleri sabitlenerek her bir düğüm için hata değişim oranı $\partial E_i / \partial O_i$ hesaplanır. Zincir kuralı uygulanarak, sistemde herhangi bir öncül parametreyi simgeleyen α değişkenine göre toplam hata değişimi aşağıda verilen şekilde hesaplanır.

$$\frac{\partial E}{\partial \alpha} = \sum_{i=1}^n \frac{\partial E}{\partial \alpha} = \sum_{i=1}^n \sum_{O \in S} \frac{\partial E}{\partial \tilde{O}} \frac{\partial \tilde{O}}{\partial \alpha} \quad (14)$$

Eşitlikte α , herhangi bir öncül parametreyi, S , çıkışı α 'ya bağlı olarak değişen düğümlerin kümesini, \tilde{O} ise bu küme içerisinde yer alan herhangi bir düğümün çıkışını göstermektedir. Daha sonra öncül parametreler aşağıdaki eşitlikler yardımıyla güncellenir.

$$\Delta \alpha = -\eta \frac{\partial E}{\partial \alpha} \quad (15)$$

$$\alpha_{yeni} = \alpha_{eski} + \Delta \alpha$$

η öğrenme oranını, $\Delta \alpha$ ise α değişkenine ait değişim miktarını göstermektedir. parametrelerin optimum şekilde ayarlanmasını sağlayan eğitim işlemi, sistemin toplam hatası belirli bir değerin altında kalıncaya kadar ya da verilen iterasyon sayısına ulaşıncaya kadar devam eder. Hybrid öğrenme algoritması için detaylı bilgiler Jang (Jang,1997) dan elde edilebilir.

Ham petrol fiyatlarının ANFIS ile tahmini

Uygulama ve sonuçlar

Çalışmada Amerikan Enerji İstatistik Ofisi'nin yayınladığı Ocak 1986 ve Nisan 2009 tarihleri arasındaki haftalık ve aylık WTI ham petrol fiyatlarına ilişkin zaman serileri kullanılmış ve uygulamalar Matlab Fuzzy Toolbox modülü yardımıyla hazırlanan bir yazılımla gerçekleştirilmiştir.

ANFIS'in zaman serisi modellemesinde kullanılabilmesi için en kritik soru modelin giriş değişkenlerinin nasıl belirleneceğidir. Çünkü serinin t zamandaki değerinin geçmiş kaç gözlem değerinden etkilendiğinin belirlenmesi gerekmektedir. Çıkış değerinin, hangi giriş değerlerinden etkilendiğini belirlemek için genel bir yaklaşım bulunmamaktadır. Zhang bu değer deneme yanılma yoluyla belirlenebileceğini belirtmiştir (Zhang vd. 1998). Çıkış değeri (y_t) ile geçmiş N gözlem değerinden oluşan girişler ($y_{t-1}, y_{t-2}, \dots, y_{t-N}$) arasındaki ilişki eşitlik 16'da verilmiştir.

$$y_t = f(y_{t-1}, y_{t-2}, \dots, y_{t-N}) \quad (16)$$

Bu amaçla çalışmamızda her iki veri seti içinde farklı giriş değişkenlerine sahip modeller oluşturulmuştur. Bu modeller içerisinde eğitim veri seti için en küçük ortalama hata kare değerine sahip modeller, en iyi modeller olarak belirlenmiştir.

Öncelikle oluşturulan her model için veriler -1 ile 1 aralığında normalize edilmiştir. Daha sonra veri setinin son 15 gözlemi test verisi olarak ayrılırken kalan verilerin %80'i ağı eğitimi için, %20'si ise ağı aşırı öğrenmesinden dolayı ortaya çıkacak ezberleme sorununu gidermek amacıyla doğrulama verisi olarak ayrılmıştır. Haftalık veriler için toplam veri sayısı 1220, eğitim veri sayısı 964, doğrulama veri sayısı 241 olarak belirlenmiştir. Aylık veri seti içinse bu değerler sırasıyla 280, 212, 53 olacak şekilde elde edilmiştir.

Ağ eğitilmeden her model için FIS yapısının belirlenmesi gerekmektedir. FIS yapısının belirlenme süreci, her bir giriş değişkenine ait üyelik fonksiyonlarının sayısının, bu üyelik fonksiyonlarına ait parametrelerin değerlerinin ve kuralların belirlenmesi aşamalarını içerir. FIS yapısını oluşturmak amacıyla Matlab'da `genfis1` ve `genfis2` isimli iki adet fonksiyon bulunmaktadır. İki fonksiyon arasındaki temel fark giriş uzayını bölümleyen kuralların nasıl oluşturulacağı ile ilgilidir.

`Genfis1` her değişkene ilişkin üyelik fonksiyonlarının olası tüm kombinasyonlarını kullanarak giriş uzayını ızgara şeklinde bölütler (grid partition). Bu yöntemin en büyük dezavantajı çok sayıda kural üretmesi ve buna bağlı olarak eğitilmesi gereken çok sayıda parametrenin oluşmasıdır. N adet değişken, her değişken için P adet üyelik fonksiyonu ve her üyelik fonksiyonuna ait L parametre olduğu düşünülürse toplam P^N adet kural oluşmakta ve bunun sonucunda $P^N(N+1)$ adet lineer parametre (soncul parametre) ile $N \times P \times L$ adet lineer olmayan parametrenin (öncül parametreler) eğitilmesi gerekmektedir. Giriş değişken sayısının fazla, veri setinin küçük olması durumunda parametrelerin hesaplanmasını engelleyen ve aynı zamanda boyut problemi olarak da adlandırılan durum ortaya çıkmaktadır.

Boyut problemini aşmak amacıyla kural sayısının azaltılması gerekmektedir. `Genfis2` fonksiyonu giriş veri setini çıkarımlı kümeleme algoritması yardımıyla kümeleyerek her bir küme için bir kural oluşturmaktadır. Aynı zamanda elde edilen kümelerin merkezleri, giriş değişkenlerine ilişkin üyelik fonksiyonlarının parametrelerinin başlangıç değerlerini oluşturmaktadır. Çalışmamızda her iki kural

oluşturma yöntemi de kullanılmıştır ve tüm modellerin eğitimi hybrid öğrenme algoritmasıyla gerçekleştirilmiştir.

Matlab ortamında FIS yapılarını oluşturmak için iki farklı yazılım oluşturulmuştur. FIS yapısının genfis1 yardımıyla belirlendiği yazılımda giriş değişken sayısı 1 den başlayarak boyut problemi çıkmayacak şekilde belirli bir değere kadar artırılarak, farklı giriş sayılarına sahip ağ yapıları oluşturulmuştur. Ardından her bir model için üyelik fonksiyon sayıları 2'den başlayarak artırılmış ve olası tüm üyelik fonksiyon sayılarının denendiği alt modeller oluşturulmuştur. Bu modeller içerisinde en iyi performansı veren model, en iyi model olarak seçilmiştir. Haftalık veriler için genfis1 yardımıyla elde edilen modeller içerisindeki en iyi model, Model1 olarak adlandırılmıştır. Aylık veriler için elde edilen en iyi model ise Model3 olarak isimlendirilmiştir. Model1, 2 giriş ve her giriş için 5 üyelik fonksiyonu ile 25 kural içermektedir. Model3 ise 1 giriş ve her giriş için 2 üyelik fonksiyonu ile toplam 2 kuraldan oluşmaktadır.

Genfis2 yardımıyla oluşturulan modellerde giriş değişken sayısı benzer şekilde 1'den başlayarak boyut problemi çıkarmayacak en yüksek giriş sayısına kadar artırılmıştır. Çıkarımlı kümeleme algoritması yardımıyla kuralları belirleyen genfis2 fonksiyonunda kullanılan küme genişlik değeri 0.1 değerinden 1 değerine 0.05 adımlarla artırılarak farklı sayıda geçerli kurala sahip alt modeller oluşturulmuştur. Bu modeller içerisinde haftalık veriler için en iyi performansı gösteren Model2, 9 giriş ve 2 kurala sahiptir. Aylık veri seti için elde edilen en iyi performansla sahip Model4 ise 6 giriş ve 3 kurala sahiptir.

Haftalık veriler için Model1 ve Model2'ye ilişkin gerçek değerler ile tahmin değerleri ve bu modellere ilişkin MAPE değerleri Tablo 1'de gösterilmiştir. Bu tabloya ilişkin grafik ise Şekil 2'de verilmiştir. Benzer şekilde aylık veriler için elde edilen sonuçlara ilişkin değerler Tablo 2 ve Şekil 3'de gösterilmiştir.

Tablo 1'den de görüleceği üzere test verileri için Model1 ve Model2'den elde edilen MAPE değerleri sırasıyla 4,8651 ve 4,6684'tür. Tablo 2'de gösterilen aylık verilere ilişkin Model2 ve Model4 ait MAPE değerleri ise 13,5458 ve 6,8345'tir. MAPE değerleri dikkate alındığında genfis2 fonksiyonu kullanılarak oluşturulan Model2 ve Model4, genfis1 fonksiyonu kullanılarak oluşturulan Model1 ve Model3'e oranla daha düşük MAPE değeriyle daha yüksek performans sergilemişlerdir. Bunun nedeni kümeleme yardımıyla kural sayısının azaltılması, dolayısıyla boyut problemi sorununun gevşetilerek daha fazla sayıda girişe sahip modellerin oluşturulması ve bu modeller içerisinde en iyi performans sergileyen modellerin seçilmesidir.

Tablo 1. Haftalık ham petrol fiyatları için gözlenen ve tahmin edilen değerler

GÖZLENE	MODEL1	MODEL2
40,78	42,5108	40,5177
36,94	40,2162	41,2779
37,15	36,9283	34,0979
41,1	36,7246	39,4285
43,18	41,6469	40,7400
45,66	43,4553	42,7664
49,49	46,2133	48,4581
52,99	50,8280	50,5218

Ham petrol fiyatlarının ANFIS ile tahmini

50,34	53,9936	53,1904
50,46	49,1678	48,8781
49,86	49,8099	50,3829
47,8	48,9639	48,4182
50,2	46,5736	47,7119
55,96	50,6438	50,5250
57,94	58,2080	57,4659
MAPE	4,8651	4,6684

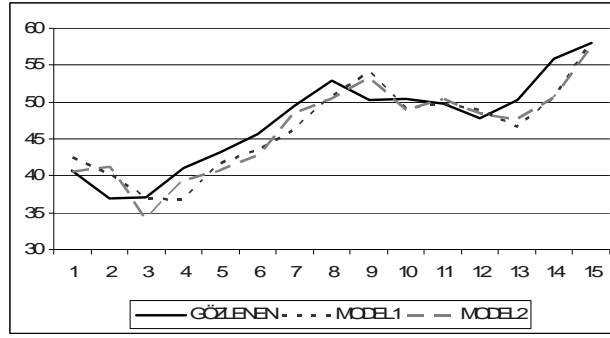
(Tablo 1. Devam)

Bir diğ er durum ise haftalık verilere ait modellerin aylık verilere ait modellere oranla daha yüksek tahmin performansı sergilemeleridir. Haftalık veri sayısının aylık veri sayısına oranla daha fazla olması ađın daha iyi eđitilmesine neden olmuřtur.


Sonuç olarak veri sayısının yeterli olması durumunda her iki bölümlleme yöntemiyle oluşturulan ANFIS modelleri, son derece deđişken ve dinamik yapıdaki petrol fiyatları zaman serilerini başarıyla modellemişlerdir. Veri sayısının yetersiz olduđu durumlarda kümeleme algoritmaları yardımıyla kural sayısı azaltılarak boyut probleminin neden olduđu daha az sayıda deđişkenle model oluřturma zorunluluđu ortadan kalkmaktadır. Ayrıca kural sayısının azalması ile birlikte hesaplanacak parametrelerin sayısı da azalmakta bunun neticesinde ađın eđitimi daha kısa sürede tamamlanmakta ve giriş deđişken sayısındaki kısıtlama azaltılarak daha iyi performansa sahip modellerin araştırılması mümkün olmaktadır.

Tablo 2. Aylık ham petrol fiyatları için gözlenen ve tahmin edilen deđerler

GÖZLENEN	MODEL3	MODEL4
95,39	93,9332	89,3087
105,45	96,3196	97,8199
112,58	106,2392	103,7543
125,40	113,2690	113,0337
133,88	125,9073	126,4989
133,37	134,2661	135,5335
116,67	133,7634	123,8075
104,11	117,3012	103,2937
76,61	104,9180	95,3025
57,31	77,7979	59,7779
41,12	58,7372	41,7085
41,71	42,3446	39,0150
39,09	42,9701	38,7703
47,94	40,1607	39,4916
49,65	49,3876	50,7071
MAPE	13,5458	6,8345



Şekil 2. Haftalık ham petrol fiyatları için gözlenen ve tahmin edilen değerlerin grafiği



Şekil 3. Aylık ham petrol fiyatları için gözlenen ve tahmin edilen değerlerin grafiği

Kaynaklar

- M. R. Amin-Naseri, E. A. Gharacheh, "A hybrid artificial intelligence approach to monthly forecasting oil price time series", Proceedings of EANN, 2007.
- E. Uğurlu, A. Ünsal, "Ham Petrol İthalatı ve Ekonomik Büyüme: Türkiye", 10. Ekonometri ve İstatistik Sempozyumu, Erzurum 27-29 Mayıs 2009.
- K.Aklin, S. Atman, Küresel Petrol Stratejilerinin Jeopolitik Açıdan Dünya ve Türkiye Üzerindeki Etkileri, İstanbul Ticaret Odası, İstanbul, 2008.
- M. A. Kaboudan, "Compumetric Forecasting Of Crude Oil Prices", Proceedings of The 2001 Congress on Evolutionary Computation, 1, 2001.
- S. Abosedra, H. Baghetani, "On The Predictive Accuracy of Crude Oil Futures Prices", Energy Policy, 32, 1389-1393, 2004.
- A. Bernabea, E. Martinaa, J. A. Ramirez, C. I. Valdez, "A Multi-Model Approach for Describing Crude Oil Price Dynamics", Physica A, 338, 567-584, 2004.
- S. Kulkarni, I. Haidar, "Forecasting Model For Crude Oil Price Using Artificial Neural Networks And Commodity Futures Prices", International Journal of Computer Science and Information Security, 2(1), 2009.
- A. Alexandridis, E. Livanis, "Forecasting Crude Oil Prices Using Wavelet Neural Networks", In the proc. of 5th FSDET, Athens, Greece, 8 May, 2008.
- P. G. Harrald, M. Kamstra, "Evolving Artificial Neural Networks To Combine Financial Forecasts", IEEE Transactions On Evolutionary Computation, 1(1), 40-52, 1997.
- H. Pan, I. Haidar, S. Kulkarni, "Daily Prediction Of Short Term Trends Of Crude Oil Prices Using Neural Networks Exploiting Multimarket Dynamics", Front. Comput. Sci., 3(2), 177-191,

2009.

A. Ghaffari, S. Zare, "A Novel Algorithm For Prediction Of Crude Oil Price Variation Based On Soft Computing", *Energy Economics*, 31, 531-536, 2009.

V. Fernandez, "Forecasting commodity prices by classification methods: The cases of crude oil and natural gas spot prices", *Banco Central De Chile Conference*, July 27, 2007.

W. Xie, L. Yu, S.Y. Xu, S.Y. Wang, "A New Method for Crude Oil Price Forecasting Based on Support Vector Machines", *Lecture Notes in Computer Science*, 3994, 2006.

J.S. R. Jang, "ANFIS: adaptive-network-based fuzzy inference system, *IEEE Trans Syst, Man, Cybernet*", 23(3), 665–685, 1993.

G. Cybenko, "Approximation by superpositions of a sigmoidal function. *Mathematical Control Signals Systems*", 2, 303–314, 1989.

K. Hornik, M. Stinchcombe, H. White, "Multilayer feedforward networks are universal approximators.", *Neural Networks* 2, 359–366, 1989.

K. Hornik, "Approximation capability of multilayer feedforward networks." , *Neural Networks* 4, 251–257, 1991.

M. S. Chen, L. C. Ying, M. C. Pan "Forecasting tourist arrivals by using the adaptive network-based fuzzy inference system" , *Expert Systems with Applications*, 2009.

M. Firat, M. Güngör, "River Flow Estimation using Adaptive Neuro Fuzzy Inference System", *Mathematics and Computers in simulation*, 75(3-4), 87-96, 2007.

P.C. Nayak, K.P. Sudheer, D.M. Ragan, K.S. Ramasastri, "A neuro fuzzy computing technique for modeling hydrological time series", *Journal of Hydrology*", 29, 52–66, 2004.

M.A. Yurdusev, M. Firat, "Neuro-Fuzzy Inference System and Artificial Neural Networks for Municipal Water Consumption Prediction", *Journal of Hydroinformatics*, 365, 225-234, 2009.

E.H. Mamdani, S. Assilian, "An experiment in linguistic synthesis with a fuzzy logic controller", *Int. Journal of Man-Machine Studies*, 7(1), 1-13, 1975.

T. Takagi, Sugeno M. "Fuzzy identification of systems and its applications to modeling and control", *IEEE Trans. Syst., Man Cybern.*, 15, 116–132, 1985.

J.S.R. Jang, C.T. Sun, E. Mizutani, *Neuro-Fuzzy and Soft Computing*, Prentice Hall, United States of America, 1997.

L.C. Ying, M.C. Pan "Using adaptive network based fuzzy inference system to forecast regional electricity loads", *Energy Conversion and Management*, 49, 205–211, 2008.