

HAM PETROL FİYATLARININ YAPAY SİNİR AĞLARI İLE TAHMİNİ

CRUDE OIL PRICE FORECASTING WITH ARTIFICIAL NEURAL NETWORKS

Yrd. Doç. Dr. Oğuz KAYNAR, Cumhuriyet Üniversitesi İktisadi ve İdari Bilimler
Fakültesi Yönetim Bilişim Sistemleri Bölümü, okaynar@cumhuriyet.edu.tr

Arş. Gör. Serkan TAŞTAN, Cumhuriyet Üniversitesi İktisadi ve İdari Bilimler
Fakültesi Yönetim Bilişim Sistemleri Bölümü, stastan@cumhuriyet.edu.tr

Arş. Gör. Ferhan DEMİRKOPARAN, Cumhuriyet Üniversitesi İktisadi ve İdari
Bilimler Fakültesi Yönetim Bilişim Sistemleri Bölümü, ferhande@gmail.com

ÖZET

Ekonomide hemen her sektör, doğrudan ya da dolaylı olarak petrole bağımlıdır. 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 amaçla çalışmamızda ham petrol fiyatlarını tahmin etmek için klasik zaman serileri analiz yöntemlerinden ARIMA ile veri seti içerisindeki karmaşık ilişkileri başarıyla modelleyebilen son yıllarda zaman serisi analizinde sıkça yer alan MLP ve RBF yapay sinir ağları kullanılmıştır.

Anahtar Kelimeler: YSA, MLP, RBF, ARIMA, Ham Petrol, Tahmin

ABSTRACT

Almost every sector in economy is connected with oil 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,

classical time series analysis method ARIMA and MLP and RBF Neural Networks which are able to model complex relationships in data set and have a large part in time series analysis recently are used in this study.

Key Words: ANN, MLP, RBF, ARIMA, Crude oil, Forecasting

1. GİRİŞ

Ham petrol; doğal gaz ile birlikte temel küresel enerji tüketiminin üçte ikisini karşılamasıyla, günlük 80 milyon varil aşan talebi ve küresel arzıyla dünya ekonomisinin en kritik ticari mallarından biridir (Amin-Naseri ve Gharacheh 2007). Dünya ekonomileri ekonomik kalkınmanın en temel ağırlıklı girdisi olan bu ürüne gün geçtikçe daha fazla gereksinim duymaktadır (Uğurlu ve Ünsal 2009). Enerjiye duyulan ihtiyacın artması petrolün ticari ve ekonomik dengeleri değiştirebilen stratejik bir araca, petrolü kendi coğrafyasında bulunduran 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 ve Atman 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 uzlaşs olsun ya da olmasın, enerji piyasası lideri durumundaki ham petrolün dünya piyasasındaki yerine ve fiyatlarına öncelik vermekte ve buna göre stratejilerini ortaya koymaktadırlar (Aklin ve Atman 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 ve Baghetani 2004). Temel mekanizmaları ve yönetim prensiplerinin karmaşık dinamikleri tam olarak anlaşılamayan, oldukça değişken ve etkileşimli bir piyasa olan petrol piyasasında (Bernabe vd. 2004) fiyat tahminleri arz ve talebin kestiriminde (Kaboudan 2001) ve fiyat dalgalanmalarının negatif etkilerini bertaraf etmede kullanılmaktadır (Kulkarni ve Haidar 2009).

Ham petrol fiyatlarının tahmininde klasik zaman serileri ve son zamanlarda yapay sinir ağları başarıyla kullanılmaktadır. Zaman serileri yardımıyla tahmin yapmak için değişik yöntemler kullanılarak oluşturulan farklı modeller bulunmaktadır. Bu modeller arasında en çok bilinen ve yaygın olarak kullanılanı

ARIMA modelleridir. Seriyi oluşturan veriler arasında doğrusal bir ilişkinin olduğunu varsayan ve bu doğrusal ilişkiyi modelleyebilen ARIMA modelleri, durağan ya da çeşitli istatistiksel yöntemlerle durağan hale getirilen zaman serilerine başarıyla uygulanabilmektedir. Oysa uygulamada karşılaşılan birçok zaman serisi sadece doğrusal ilişki içermemektedir. Yapısı gereği hem doğrusal hem de doğrusal olmayan ilişkileri modelleyebilen yapay sinir ağları (YSA) , veri setine ilişkin fonksiyonel yapının tam olarak belirlenemediği durumlarda, veriden hareketle birçok değişik formdaki fonksiyonel yapıyı başarıyla modelleyebilmekte ve herhangi bir formdaki fonksiyona belirli bir doğrulukta yakınsayabilmektedir (Cybenko 1989; Hornik vd.1989; Hornik 1991). Ayrıca, genel fonksiyon yaklaşımıcısı olarak da bilinen yapay sinir ağları, parametrik olmayan bir yöntem olmasından dolayı istatistiksel yöntemlerin aksine veri seti üzerinde de herhangi bir ön varsayıma gerek duymaz. Bu nedenlerden dolayı YSA'lar son yıllarda zaman serilerinin analizinde sıkça kullanılan alternatif yöntemlerden biri olmuştur. Yapay sinir ağlarının zaman serilerinin tahmininde kullanıldığı çalışmalara ilişkin geniş bir derleme Zhang vd. (1998) tarafından yapılmıştır.

Petrol fiyatlarının YSA ile tahminine ilişkin literatür incelendiğinde çok farklı çalışmalara rastlanmaktadır. Alexandridis ve Livanis (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 (2007) ise çalışmalarında ileri beslemeli 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 (1997) evrimsel programlama deneyimlerinden yararlandıkları çalışmalarında finansal tahminleri birleştirmek için bir yapay sinir ağı geliştirmişlerdir. Pan vd. (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 (2009) esnek hesaplama teknikleri kullanarak geliştirdikleri metot 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 (2007), ham petrol ve doğal gaz fiyatlarını günlük olarak tahmin ettiği çalışmasında yapay sinir ağları (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 (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. (2006) ham

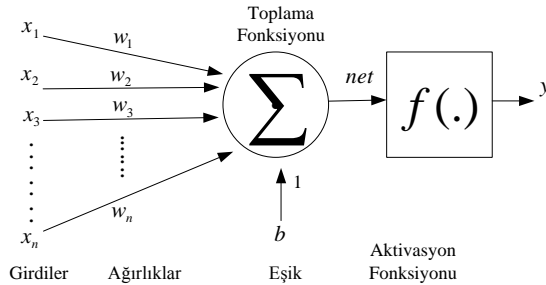
petrol fiyat tahmini yaptıkları çalışmalarında SVM tabanlı yeni bir model önermiş, bu modeli ARIMA ve BPNN modelleri ile karşılaştırarak önerdikleri modelin daha iyi performans gösterdiğini belirtmişlerdir.

Bu çalışmada ise Amerikan enerji istatistik ofisinin yayınladığı Ocak 1986 ve Nisan 2009 tarihleri arası WTI ham petrol fiyatlarından oluşan aylık zaman serisi kullanılmıştır. Klasik zaman serisi yöntemlerinden ARIMA ile MLP ve RBF yapay sinir ağları tahmin modelleri oluşturulmuştur. Her üç yöntemle elde edilen sonuçlar ortalama mutlak yüzde hata (MAPE, Mean Absolute Percentage Error) performans kriteri kullanılarak karşılaştırılmıştır.

2. YAPAY SİNİR AĞLARI

Yapay sinir ağları, biyolojik sinir ağlarından esinlenilerek ortaya çıkarılan ve biyolojik sinir ağlarına benzer bazı performans özellikleri içeren bir bilgi işleme sistemidir (Fausett 1994, s.3). Basit bir şekilde insan beyninin çalışma şeklini taklit eden YSA'lar veriden öğrenme, genelleme yapabilme, sınırsız sayıda değişkenle çalışabilme vb. birçok önemli özelliğe sahiptir. YSA'nın çalışmasına esas teşkil eden en küçük birimler yapay sinir hücresi ya da işlem elemanı olarak isimlendirilir. En basit yapay sinir hücresi Şekil 1'de de görüleceği üzere girdiler, ağırlıklar, birleştirme fonksiyonu, aktivasyon fonksiyonu ve çıkış olmak üzere 5 ana bileşenden oluşmaktadır.

Şekil 1: Yapay Sinir Hücresi



Girdiler (x_1, x_2, \dots, x_n), diğer hücrelerden ya da dış ortamlardan hücreye giren bilgilerdir. Bunlar ağırlık öğrenmesi istenen örnekler tarafından belirlenir. Ağırlıklar (w_1, w_2, \dots, w_n), girdi kümesi veya kendinden önceki bir tabakadaki başka bir işlem elemanının bu işlem elemanı üzerindeki etkisini ifade eden değerlerdir. Her bir girdi, o girdiyi işlem elemanına bağlayan ağırlık değeriyle çarpılarak, toplam fonksiyonu aracılığıyla birleştirilir. Toplam fonksiyonu eşitlik 1'de verildiği şekildedir.

$$net = \sum_{i=1}^n w_i x_i + b \quad (1)$$

Toplam fonksiyonu sonucunda elde edilen değer doğrusal ya da doğrusal olmayan türevlenebilir bir transfer fonksiyonundan geçirilerek işlem elemanının çıktısı hesaplanır.

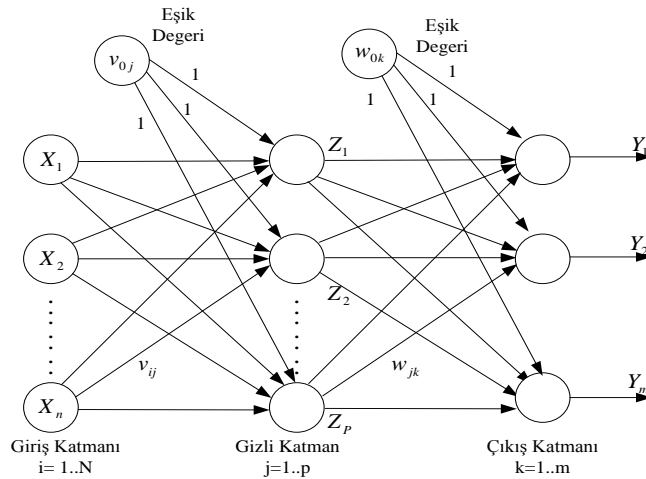
$$y = f(net) = f\left(\sum_{i=1}^n w_i x_i + b\right) \quad (2)$$

Yapay sinir ağlarında çok çeşitli ağ yapıları ve modelleri vardır. Yapay sinir ağı, Şekil 1'de gösterilen bir dizi sinir hücresinin ileri sürümlü ve geri beslemeli bağlantı şekilleri ile birbirine bağlanmasından oluşur. Günümüzde, belirli amaçlarla ve değişik alanlarda kullanılmaya uygun birçok yapay sinir ağı modeli (MLP, RBF, LVQ, Hopfield, Recurrent, SOM, ART vb.) geliştirilmiştir. Bu ağ yapıları içerisinde en yaygın kullanım alanı bulan ve çalışmamızda da kullanılan çok katmanlı ileri beslemeli yapay sinir ağları (MLP, Multiple Layer Perceptron) ile radyal tabanlı fonksiyon (RBF, Radial Basis Function) ağlarıdır.

2.1 Çok Katmanlı İleri Beslemeli Yapay Sinir Ağları (MLP)

MLP ağlarında nöronlar katmanlar şeklinde organize edilmiştir. MLP'de ilk katman girdi katmanıdır. Girdi katmanı, çözülmesi istenilen probleme ilişkin bilgilerin YSA'ya alınmasını sağlar. Diğer katman ise ağ içerisinde işlenen bilginin dışarıya iletiildiği çıktı katmanıdır. Girdi ve çıktı katmanlarının arasında yer alan katmana ise gizli katman adı verilir. MLP ağlarında birden fazla gizli katman da bulunabilir. Şekil 2, tipik bir MLP ağının yapısını göstermektedir.

Şekil 2: Çok Katmanlı İleri Beslemeli Yapay Sinir Ağı



Teknik olarak, bir YSA'nın en temel görevi, örnek veri setindeki yapıyı öğrenerek, istenilen görevi yerine getirecek şekilde genelleştirmeler yapmaktır. Bunun yapılabilmesi için ağ, ilgili olayın örnekleri ile eğitilerek genelleme yapabilecek yeteneğe kavuşturulur (Öztemel 2003, s.30). YSA'nın öğrenmesi, işlem elemanlarının sahip olduğu ağırlıkların, seçilen eğitim algoritmalarıyla değiştirilmesi ile yapılmaktadır. Anlaşılması kolay ve matematiksel olarak ispatlanabilir olmasından dolayı MLP ağlarının eğitiminde geri yayılım (Backpropagation) algoritması kullanılmaktadır. Bu algoritma, hataları geriye doğru çıkıştan girişe azaltmaya çalışmasından dolayı geri yayılım ismini almıştır. Geri yayılım algoritması danışmanlı öğrenme yapısına sahip ve birçok uygulamada kullanılmış en yaygın öğrenme algoritmasıdır. Danışmanlı öğrenme algoritmalarında ağın eğitimi için, ağa örnek olarak girdi ve çıktı değerlerden oluşan bir örnek veri seti verilir. Verilen hedef çıktı değerleri, YSA literatüründe danışman ya da öğretmen olarak adlandırılır. Danışmanlı öğrenme algoritmalarında öğrenme aşamasında ağırlıklar, eşitlik 3'te verilen hata fonksiyonunun minimize edilmesiyle düzenlenir.

$$E = \frac{1}{2} \sum_{k=1}^m (y_k - t_k)^2 \quad (3)$$

Eşitlikte y_k ağın ürettiği çıktıyı t_k ise gerçek çıktı değerini göstermektedir. Hatayı en aza indirmek için bağlantı ağırlıkları yeniden düzenlenerek güncellenir. Böylece ağın gerçek çıktı değerlerine en yakın çıktı değerlerini üretmesi amaçlanır. Geri yayılım algoritmasının detayı için (Fauset 1994, s.294-296) incelenebilir.

MLP ağlarının zaman serisi tahmininde kullanılabilmesi için ağın yapısının belirlenmesi gerekmektedir. Ağ yapısının belirlenme süreci, ağın kaç katmandan oluşacağını, her katmanda kaç işlem elemanı bulunacağını, bu işlem elemanlarının hangi transfer fonksiyonuna sahip olacağını belirlenmesi işlemlerini kapsar. Kaç dönemlik tahmin yapılacağına bağlı olarak çıkış nöron sayısı belirlenir. Girişte kullanılacak nöron sayısını belirlemek çıkış nöron sayısını belirlemek kadar kolay değildir, çünkü serinin t zamandaki değerinin geçmiş kaç gözlem değerinden etkilendiğinin belirlenmesi kritik bir sorudur ve bu sorunun cevabı girdi işlem elemanı sayısının kaç olacağını göstermektedir. Tang ve Fishwick, girdi işlem elemanı sayısının ARIMA (p,d,q) modelindeki p derecesine eşit alınması gerektiğini söylemektedir (Tang ve Fishwick,1993). Fakat Zhang bu yaklaşımın MA modellerinin AR terimi içermemesi ve Box-Jenkins modellerinin doğrusal modeller olması nedeniyle uygun olmadığını, girdi işlem elemanı sayısının deneme yanılma yoluyla belirlenebileceğini ifade etmektedir (Zang vd. 1998). Zaman serisi modellemede genellikle tek gizli katmana sahip ağ yapıları yeterli olmaktadır. Çıkış değeri (y_t) ile geçmiş N gözlem değerinden oluşan girişler ($y_{t-1}, y_{t-2}, \dots, y_{t-N}$) arasındaki ilişki eşitlik 4'te verilmiştir.

$$y_t = w_o + \sum_{j=1}^p w_j f \left(v_{0j} + \sum_{i=1}^N v_{ij} y_{t-i} \right) + e_t \quad (4)$$

Eşitlikte; w_j, v_{ij} nöronlar arasındaki ağırlık değerlerini, p gizli nöron sayısını, f ise gizli katmanda kullanılan doğrusal olmayan aktivasyon fonksiyonunu göstermektedir. En çok kullanılan aktivasyon fonksiyonları sigmoid(5) ve hiperbolik tanjant(6) fonksiyonlarıdır.

$$f(x) = \frac{1}{1 + e^{-x}} \quad (5)$$

$$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (6)$$

2.2 Radyal Tabanlı Fonksiyon Ağları


RBF ağları da MLP ağları gibi bir giriş katmanı, aktivasyon fonksiyonu olarak ağa ismini veren radyal fonksiyonların kullanıldığı tek bir gizli katman ve çıkış katmanı olmak üzere 3 katmanlı mimariden oluşmaktadır (Şekil 1). Bir RBF ağının çalışma ilkesi, giriş verisine bağlı olarak gizli katmanda uygun genişlik ve merkez değerlerine sahip RBF'leri belirleyerek, çıkış katmanında bu fonksiyonların ürettiği çıktılarının uygun ağırlık değerleriyle doğrusal birleşimlerini oluşturup giriş-çıkış arasındaki ilişkiyi belirleme süreci olarak açıklanabilir. İlk olarak çok değişkenli interpolasyon problemlerinin çözümünde kullanılan (Powel, 1987) radyal tabanlı fonksiyonların yapay sinir ağlarında kullanımı Broomhead and Lowe tarafından gerçekleştirilmiştir (Broomhead and Lowe, 1988). MLP'ye oranla daha kısa zamanda eğitilmesi (Moody ve Darken) ve lokal minimumlara takılmaksızın en iyi çözüme yakınsamaları (Park ve Sandberg 1991) gibi özelliklerinden dolayı RBF ağları tahmin, eğri uydurma ve fonksiyon yaklaşırma gibi problemlerin çözümünü içeren uygulamalarda MLP'ye alternatif bir sinir ağı olarak kullanılmaya başlanmıştır (Bianchini vd .1995; Chen vd 1991).

Giriş katmanındaki veriler MLP den farklı olarak ağırlık değerleri ile çarpılmadan direkt olarak gizli katmana iletilirler. Gizli katmanda yer alan radyal fonksiyonların merkezlerini gösteren U_j referans vektörleri ile giriş vektörü arasındaki uzaklık değerine bağlı olarak gizli katman çıkışında eşitlik 7'de gösterildiği şekliyle bir değer üretilir

$$\varphi_j = e^{-\left[\frac{\|x_i - U_j\|^2}{\sigma_j^2} \right]} \quad (7)$$

Birçok uzaklık ölçüsü tanımlanmasına rağmen uzaklık ölçüsü olarak genelde Öklid uzaklığı kullanılır. Giriş vektörü, referans vektörüne ne kadar çok benziyorsa fonksiyonun üreteceği değer o oranda büyük olacaktır. Gizli katmanda kullanılmak üzere çok sayıda radyal tabanlı fonksiyon (Gaussian, Multi-Quadric, Generalized Multi-Quadric, Thin Plate Spline) önerilmesine karşın uygulamalarda en çok Gaussian fonksiyon tercih edilmiştir. Chen vd. ağda kullanılacak radyal fonksiyon seçiminin ağırlık performansı üzerinde önemli bir etkisinin olmadığını belirtmişlerdir (Chen vd, 1991).

Şekil 3: RBF Yapay Sinir Ağı



Eşitlikte gösterilen X_i değeri o an ağı sunulan girdi vektörünü U_j referans vektörünü, $\|\cdot\|$ uzaklık fonksiyonu σ_j ise Gaussian fonksiyonunun genişlik değerini göstermektedir. Gizli katman çıkışında elde edilen ϕ_j değerleri daha sonra w_{kj} ağırlık değerleri ile çarpılıp toplanarak eşitlik 8'de verildiği gibi ağı çıkışı hesaplanır.

$$y_k = \sum_{j=1}^L \phi_j w_{kj} + w_{k0} \quad (8)$$

RBF ağlarının eğitimi, gizli katmanda yer alan radyal fonksiyona ait merkez vektörü (U_j) ile genişlik değerinin (σ_j) ve gizli katman ile çıkış katmanı arasında yer alan ağırlık (w_{kj}) parametrelerinin belirlenmesi sürecini kapsar. Referans vektörü ve referans vektörünün genişliğini belirlemek üzere literatürde birçok yöntem önerilmiştir. Bunlardan bazıları aşağıda sıralanmıştır:

Merkez vektörlerini veri seti içerisinde seçmek. Bu yöntemde gizli katmanda kullanılacak veri seti sayısı, ağı sunulan örnek sayısına eşitlenerek her bir örnek veri seti aynı zamanda merkez vektör olarak kullanılır. Kısaca giriş uzayındaki her bir nokta için bir radyal fonksiyon belirlenir. Bu durum gerçek RBF (Exact RFB) olarak adlandırılır. Bu durumun iki sakıncası vardır. Bunlardan ilki, veri setinin büyük olması durumunda hesap karmaşası yaratacak boyut problemidir. Diğeri ise ağıdaki verilerin gürültülü olması durumunda ağı bu gürültülü değerleri

de öğreneceğinden eğitim verisi için sıfır hata ile öğrenme gerçekleşirken test verisi için sistemin performansı aynı oranda iyi olmayacaktır. Bu nedenle hesap karmaşasını azaltmak ve ağın aşırı öğrenmesinden kaynaklanan ezberleme sorununu gidermek için gizli katmandaki nöron sayısı giriş veri setindeki örnek sayısından daha küçük seçilir. Bu durumda merkez vektörleri giriş vektörlerinden rastgele seçilerek belirlenir.

Merkez vektörlerinin danışmasız öğrenme ile belirlenmesi: Bu yöntemde giriş vektörleri bilinen k-ortalamar ve kendinden örgütlemeli ağlar SOM (Self Organization Map) yöntemlerinden biri kullanılarak belirli sayıda kümelere ayrılır ve her bir kümenin merkezi radyal fonksiyonların merkezi olarak atanır. Tüm radyal fonksiyonlar için σ_j çok küçük ya da çok büyük seçilmemek kaydıyla kullanıcı tarafından belirlenebildiği gibi $(\sigma = d_{\max} / \sqrt{2M})$ eşitliğiyle de hesaplanabilir (Haykin 1999, s.321).

Merkez vektörleri ve σ değeri belirlendikten sonraki aşama gizli katmanla çıkış katmanı arasında yer alan w_{kj} değerlerinin belirlenmesidir. Gizli katman çıkışları (φ_j) belirlendikten sonra, w_{kj} değerleri MLP ağlarında olduğu gibi geri yayılım algoritması yardımıyla iteratif olarak ya da en küçük hata kareleri yöntemiyle eşitlik 9'da verilen denklemin çözümü sonucunda tek aşamada elde edilir.

$$\varphi W^T = T \quad (9)$$

3. MEVSİMSSEL ARIMA MODELLERİ

Box-Jenkins modelleri kısa ve orta vadedeki tek değişkenli zaman serilerinin ileriye dönük tahmin ve kontrolünde uzun süredir başarıyla kullanılan bir istatistiksel öngörü yöntemidir. Farklı zaman serileriyle kullanılabilmesi, güçlü teorik temelleri ve uygulamadaki başarısıyla Box-Jenkins yaklaşımı popüler bir yaklaşım haline gelmiştir (Frechtling 1996, s.96). Box-Jenkins yaklaşımı Otoregresif (AR) ve Hareketli Ortalama (MA) tahmin metotlarının birleşimidir ve durağan serilere uygulanabilir. Durağan olmayan zaman serilerinde durağanlığı sağlamak için fark alma yöntemi kullanılır.

Otoregresif Bütünleşik Hareketli Ortalama Modeli (ARIMA), d dereceden farkı alınmış serilere uygulanan, değişkenin t-dönemindeki değerinin belirli sayıda geri dönem değerleri ile aynı dönemdeki hata teriminin doğrusal bir fonksiyonu olarak ifade edildiği Otoregresif (AR) ve değişkenin t-dönemindeki değerinin aynı dönemdeki hata terimi ve belirli sayıda geri dönem hata terimlerinin doğrusal fonksiyonu olarak ifade edildiği Hareketli Ortalama (MA) modellerinin birer birleşimidir. Modellerin genel gösterimi ARIMA (p, d, q) şeklindedir. Burada p ve q sırasıyla Otoregresif (AR) Modelin ve Hareketli Ortalama (MA) Modelinin derecesi, d ise fark alma derecesidir.

Uygulamada birçok zaman serisi her s gözlemde tekrar eden, tabii ve sosyo-ekonomik nedenlerin ortaya çıkardığı mevsimsel periyodik bir bileşen içerir (Chatfield 2003, s.66). Box-Jenkins bu mevsimsel bileşeni modelleyebilmek amacıyla, ARIMA modelinin geliştirilmiş bir biçimi olan ve mevsimsel ARIMA (SARIMA) modeli olarak adlandırılan modeli önermiştir (Franses 1996, s.41). Bir SARIMA modeli mevsimsel ve mevsimsel olmayan iki bölümden oluşur. Mevsimsel ve mevsimsel olmayan bölümler sırasıyla P,Q ve p,q olmak üzere kendi otoregresif ve hareketli ortalama parametrelerine sahiptir. SARIMA modelinde mevsimsel fark alma sayısı D, mevsimsel olmayan fark alma sayısı ise d ile gösterilir. Mevsimsel ARIMA modelleri genel olarak ARIMA(p,d,q)(P,D,Q)s biçimde ifade edilir ve eşitlik 10'daki gibi yazılabilir (Kuvulmaz vd.,2005).

$$\begin{aligned} \varphi_p(B)\Phi_P(B^s)(1-B)^d(1-B^s)^D y_t &= \theta_q(B)\Theta_Q(B^s)\varepsilon_t \\ \varphi_p(B) &= 1 - \varphi_1 B - \varphi_2 B^2 - \dots - \varphi_p B^p \\ \Phi_P(B) &= 1 - \Phi_s B^s - \Phi_{2s} B^{2s} - \dots - \Phi_{Ps} B^{Ps} \\ \theta_q(B) &= 1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q \\ \Theta_Q(B) &= 1 - \Theta_s B^s - \Theta_{2s} B^{2s} - \dots - \Theta_{Qs} B^{Qs} \end{aligned} \quad (10)$$

Modelde Φ ve Θ , P ve Q. dereceden B^s 'in polinomunu, φ ve θ ise p ve q. dereceden B'nin polinomunu belirtmektedir. s mevsimsel uzunluktur ve aylık seriler için s=12, üç aylık veriler için ise s=4'dür. $(1-B^s)^D$ ve $(1-B)^d$ sırasıyla mevsimsel ve mevsimsel olmayan fark alma operatörleridir. ε_t ise hata terimidir.

Mevsimsel ARIMA modellerinde öngörü dört aşamada gerçekleşmektedir. İlk önce serinin durağanlığı kontrol edilir ve durağan olmayan serinin durağanlığı sağlanarak uygun Box-Jenkins modeli belirlenir. İkinci aşamada belirlenen modele ilişkin parametreler tahmin edilir. Daha sonra modelin veri setine uygunluğu istatistiksel yöntemlerle test edilir. Üçüncü aşamada önceki aşamada belirlenen model uygun bulunursa son aşamaya geçilir, uygun bulunmazsa başka bir modelin belirlenmesi için ilk aşamaya dönülür. Son aşamada ise seçilen en uygun model tahmin için kullanılır.

III. UYGULAMA VE SONUÇLAR

Çalışmada kullanılan veriler, Ocak 1986 ve Nisan 2009 tarihleri arası ham petrol fiyatlarını gösteren aylık zaman serisidir. MLP, RBF ve SARIMA modelleri için veri setinin son 15 gözlemi, yapılan tahminleri test etmek için kullanılmıştır. MLP modellerinde kalan verinin %80'i eğitim %20'si ise doğrulama verisi olarak ayrılmıştır. RBF içinse test verileri dışındaki tüm veriler eğitim verisi olarak

kullanılmıştır. Veriler MLP ve RBF ile oluşturulan ağlara girilmeden önce ağın yapısına uygun hale getirilerek; gerekli giriş ve çıkış vektörleri oluşturulmuştur.

Bu çalışmada yapay sinir ağları modellerinin oluşturulması için Matlab programı kullanılarak bir yazılım geliştirilmiştir. Çalışma kapsamında oluşturulan tüm MLP modelleri 3 katmanlı bir mimariye sahiptir. Gerçekleştirilen yazılım sayesinde giriş nöron sayısı 1'den 12'ye, gizli katmanda kullanılan nöron sayısı ise 1 den 10'a kadar değiştirilerek 120 farklı MLP sinir ağı modeli elde edilmiştir. Eğitim verileri ağı sunularak MLP ağının öğrenme işlemi gerçekleştirilmiş; bu 120 model içerisinde test verileri için en küçük hata kareleri ortalaması (MSE) değerini veren yapay sinir ağı modeli seçilmiştir. Giriş nöron sayısı 11, gizli nöron sayısı 3 olan MLP modeli en uygun model olarak belirlenmiştir.

RBF ağlarıyla tahmin gerçekleştirmek için iki farklı yaklaşım kullanılmıştır. İlk yaklaşımda gizli katmandaki nöron sayısı eğitim veri setindeki gözlem sayısına eşit alınarak referans vektörleri veri setindeki giriş değerlerine eşitlenmiştir. İkinci yaklaşımda gizli katmandaki nöron sayısı 1'den başlayıp 30'a kadar artırılarak 30 adet model oluşturulmuştur. Gizli katmanda yer alan radyal fonksiyonların merkezi veri setinden rastgele seçilerek belirlenmiştir. Her iki yaklaşımda da serinin t zamandaki değerinin geçmiş kaç gözlem değerinden etkilendiğini belirlemek üzere giriş nöron sayısı 1'den 12'ye kadar değiştirilmiştir. Sonuçta birinci yaklaşım için 12 model, ikinci yaklaşım içinse 12x30 model denenmiştir. Oluşturulan modeller içinden test verileri için en küçük MSE değerini veren RBF modeli seçilmiştir. En iyi sonucu veren RBF modeli için giriş nöron sayısı 12, gizli katman nöron sayısı 15'tir.

Veri setine uygun SARIMA modelinin belirlenmesi için öncelikle veri setinin durağanlığı incelenmiştir. Durağan olmayan zaman serisi durağan hale getirilerek en uygun modeli belirlemek üzere geçici modeller oluşturulmuştur. Geçici modeller içerisinde AIC, BIC ve R^2 kriterlerine göre ARIMA(1,1,0)(1,0,1)12 modeli en uygun model olarak belirlenmiştir.

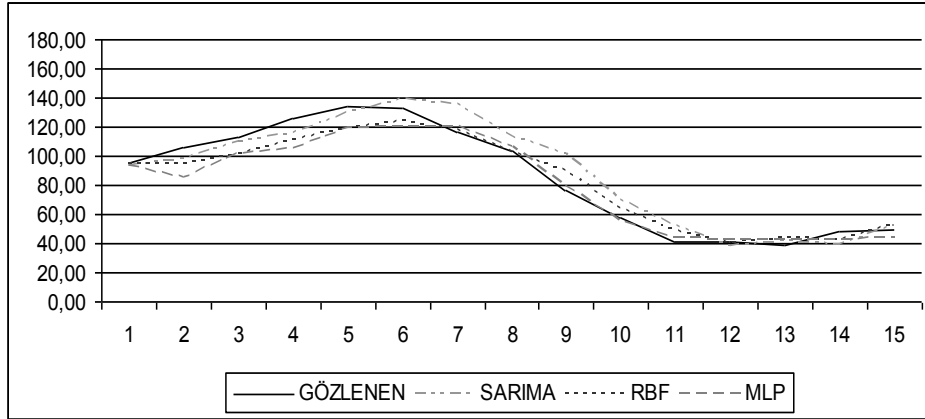
Çalışmada SARIMA, MLP ve RBF'den elde edilen modeller in karşılaştırılması için MAPE kriterinden faydalanılmıştır ve sonuçlar Tablo1'de verilmiştir. Tablo 1 incelendiğinde SARIMA, MLP ve RBF modellerine ilişkin MAPE değerleri sırasıyla %11,3378 - %8,8659 - %8,0652 olarak bulunmuştur. En iyi sonuç RBF modelinden elde edilmiştir. Ayrıca verilere ilişkin gözlenen değerler ile tahmin değerlerine ilişkin grafik Şekil 4'te gösterilmiştir.

Gerek MLP, gerekse RBF yapay sinir ağları kullanılarak elde edilen tahmin sonuçları SARIMA ile elde edilen tahmin değerlerinden daha iyi performans sergilemişlerdir. Sonuç olarak, uygun ağ yapısı ve yeterli sayıda veri kullanıldığında, zaman serilerinin tahmininde yapay sinir ağları istatistiksel yöntemlere alternatif bir yöntem olarak kullanılabilir.

Tablo1: Aylık ham petrol fiyatları için gözlenen ve tahmin edilen değerler

GÖZLENEN	SARIMA	RBF	MLP
95,3900	92,7400	93,9052	92,8409
105,4500	97,3900	93,8744	85,0057
112,5800	109,9100	101,3730	101,1865
125,4000	115,8800	111,1066	105,2190
133,8800	129,3800	118,6197	118,4302
133,3700	138,3200	122,9776	119,6458
116,6700	135,6900	117,0903	120,5550
104,1100	112,6900	102,8040	105,3930
76,6100	100,8700	89,4938	79,1227
57,3100	69,2600	63,7011	55,4780
41,1200	52,2500	48,7194	43,3176
41,7100	37,8800	40,4751	42,6256
39,0900	41,6600	43,1736	42,7404
47,9400	38,9200	42,7278	42,6600
49,6500	51,5900	53,4067	43,7203
MAPE	%11,3378	%8,8659	%8,0652

Şekil 4: Aylık ham petrol fiyatları için gözlenen ve tahmin edilen değerlerin grafiği



KAYNAKLAR

Abosedra, S. ve Baghetani, H., "On The Predictive Accuracy of Crude Oil Futures Prices", Energy Policy, Volume:32, 2004.

Aklin, K. ve Atman, S., Küresel Petrol Stratejilerinin Jeopolitik Açından Dünya ve Türkiye Üzerindeki Etkileri, İstanbul: İstanbul Ticaret Odası, Yayın-No:2006-48, 2008.

Alexandridis A., Livanis E, "Forecasting Crude Oil Prices Using Wavelet Neural Networks".In the proc. of 5th FSDET, Athens, Greece, 8 May, 2008.

Amin-Naseri, M. R. ve Gharacheh, E. A., "A hybrid artificial intelligence approach to monthly forecasting oil price time series". Proceedings of EANN, 2007.

Bernabe, A. ve diğerleri, "A Multi-Model Approach for Describing Crude Oil Price Dynamics", Physica A, Volume:338, 2004.

Bianchini, M., Frasconi, P. & Gori, M. (1995) Learning without local minima in radial basis function networks. IEEE Trans. Neural Networks 6(3), s.749-755.

Broomhead DS, Lowe D.(1988), "Multivariable functional interpolation and adaptive Networks", Complex Systems 2: s.321-355.

Chatfield C.,(2003),The analysis of time series: an introduction, CRC Pres

Chen, S., Cowan, C. F. N., Grant, P. M. (1991), "Orthogonal least squares learning algorithm for radial basis function networks.", IEEE Trans. Neural Networks 2(2), s.302-309.

Cybenko G. (1989), "Approximation by superpositions of a sigmoidal function. Mathematical Control Signals Systems" 2: s.303-314.

Fausett, L.(1994), Fundamentals of Neural Networks: Architectures, Algorithms and Applications, Prentice Hall.

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

Franses P. H.(1996),Periodicity And Stochastic Trends in Economic Time Series, Oxford University Press

Frechtling D. C.(1996), Practical Tourism Forecasting, Elsevier

Ghaffari, A. ve Zare, S., "A Novel Algorithm For Prediction Of Crude Oil Price Variation Based On Soft Computing", Energy Economics, Volume:31, 2009.

Harrald, P. G. ve Kamstra, M., "Evolving Artificial Neural Networks To Combine Financial Forecasts", IEEE Transactions On Evolutionary Computation, Volume:1, No:1, 1997.

Haykin, S.(1999),Neural Networks - A Comprehensive Foundation, Prentice Hall.

Hornik K, Stinchcombe M, White H.(1989). "Multilayer feedforward networks are universal approximators.", Neural Networks 2: s.359-366.

Hornik K. (1991), "Approximation capability of multilayer feedforward networks." ,Neural Networks 4: s.251-257.

Kaboudan, M. A., "Compumetric Forecasting Of Crude Oil Prices", Proceedings of The 2001 Congress on Evolutionary Computation, Volume:1, 2001.

Kulkarni, S. ve Haidar, I., "Forecasting Model For Crude Oil Price Using Artificial Neural Networks And Commodity Futures Prices", International Journal of Computer Science and Information Security, Volume:2, No:1, 2009.

Kuvulmaz J., Usanmaz S., Engin S. N.(2005), "Time-Series Forecasting by Means of Linear and Nonlinear Models.", MICAI 2005, s.504-513

Moody, J. & Darken, C. J. (1989), "Fast learning in networks of locally-tuned processing units." ,Neural Computation 1(2), s.281-294.

Öztemel, E.(2003),Yapay Sinir Ağları, Papatya Yayıncılık, İstanbul.

Pan, H., Haidar, I. ve Kulkarni, S., "Daily Prediction Of Short Term Trends Of Crude Oil Prices Using Neural Networks Exploiting Multimarket Dynamics", Front. Comput. Sci., Volume:3, No:2, 2009.

Park, J. ve Sandberg,I.W.(1991)," Universal approximations using Radial-Basis-Function Network." , Neural Computation 3(2), s.246-257

Powell MJD.(1987),"Radial basis functions for multivariable interpolation: a review. In Algorithms for Approximation", Mason JC, Cox MG (eds.) Carendon Press: Oxford; s.143-167.

Tang, Z, Fishwick, P.A.(1993),"Feedforward neural nets as models for time series forecasting",ORSA Journal on Computing, Vol. 5 (4), s.374-385.

Uğurlu, E. ve Ünsal, A., "Ham Petrol İthalatı ve Ekonomik Büyüme: Türkiye", 10. Ekonometri ve İstatistik Sempozyumu'na sunulan bildiri, Erzurum 27-29 Mayıs 2009.

Xie, W. ve diğeri, "A New Method for Crude Oil Price Forecasting Based on Support Vector Machines", Lecture Notes in Computer Science, Volume:3994, 2006.

Zhang, G., Patuwo, B. E. ve Hu, M. Y. (1998) "Forecasting with artificial neural networks: the state of the art", International Journal of Forecasting, 14, s.35-62.