

## YAPAY SİNİR AĞLARI İLE DOĞALGAZ TÜKETİM TAHMİNİ

Oğuz KAYNAR<sup>1</sup>  
Serkan TAŞTAN<sup>2</sup>  
Ferhan DEMİRKOPARAN<sup>3</sup>

**Özet:** Doğalgaz temini noktasında tamamen dışa bağımlı bir politika izleyen ve doğalgaz stok kapasitesi toplam tüketiminin ancak %5 ini karşılayan ülkemiz için tüketilen doğalgaz miktarının tahmini, son derece önemlidir. Talebin doğru bir şekilde tahmini, sektöre yapılacak yatırımları ve gaz alımı ile ilgili anlaşmaları, dolayısıyla sektörün gelişimini etkileyecek unsurlardan birini oluşturmaktadır. Çalışmanın amacı, yapay sinir ağları ve klasik zaman serileri (ARIMA modelleri) yardımıyla doğalgaz tüketimine ilişkin kısa dönemli öngöründe bulunmaktır. Ayrıca çalışmamızda her iki model ile elde edilen tahmin değerleriyle gözlenen değerler karşılaştırılarak modellerin performansı kıyaslanmıştır.

**Anahtar Kelimeler:** Yapay Sinir Ağları, MLP, ARIMA

**Abstract:** It is crucial to predict the natural gas consumption for our country that follow a foreign dependent policy to yield natural gas and whose storage capacity of natural gas is %5 of total consumption. Robust prediction of natural gas demand is one of the factors that affects sector-specific investments and agreements about buying gas and so development of natural gas sector. The object of this study is to prophesy the short-term natural gas consumption by the aid of artificial neural network and classical time series (ARIMA models). In this paper also, models' performances are analysed through the predicted and observed values obtained from both models, are compared.

**Keywords:** Artificial Neural Networks, MLP, ARIMA

### I.Giriş

Havayı kirletmeyen, petrol ve katı yakıtla kıyaslandığında çevre dostu bir enerji kaynağı olan doğalgaz, yüksek yanma verimi, kolaylıkla depolanabilir olması, kurum ve is gibi atık madde bırakmaması, kontrol edilebilir bir enerji kaynağı olması ve fiyat avantajlarından dolayı, başta ısınma olmak üzere, elektrik üretimi ve sanayide birçok alanda kullanılmaktadır. Çevre dostu olan bu enerji kaynağının temini noktasında tamamen dışa bağımlı bir politika izleyen Türkiye, doğal gaz ihtiyacının büyük bölümünü boru hatları yardımıyla Rusya, İran ve Azerbaycan'dan karşılamaktadır. Ayrıca Marmara Ereğlisi'ne Nijerya ve Cezayir'den gemilerle sıvılaştırılmış doğal gaz (LNG) tedarik edilmektedir. Doğal gazın çıkarıldığı kaynaktan tüketim noktalarına nakli, uluslararası antlaşmalarla güvence altına alınmasına karşın çeşitli nedenlerle, doğal gaz ithal edilen ülkelerden gelen doğal gaz akışı kesilebilmekte ve bunun sonucunda özellikle kış aylarında konutlarda ısınma ve sanayide üretimin

<sup>1</sup> Yrd. Doç. Dr. Cumhuriyet Üniversitesi İİBF Yönetim Bilişim Sistemleri Bölümü

<sup>2</sup> Arş. Gör. Cumhuriyet Üniversitesi İİBF Yönetim Bilişim Sistemleri Bölümü

<sup>3</sup> Arş. Gör. Cumhuriyet Üniversitesi İİBF Yönetim Bilişim Sistemleri Bölümü

durması gibi problemler yaşanmaktadır. Mevsimlik talep dalgalanmalarını bertaraf etmek ve ihtiyacı karşılamak üzere doğal gazın gaz ve sıvı formda depolanması yoluna gidilmektedir. Doğal gazın depolanması için; yeraltı su gölleri, yeraltı kaya tuzu yatakları, terk edilmiş madenler, doğal gaz ve petrol yatakları tercih edilmektedir. Ülkemiz, doğal gaz tüketiminin ancak yüzde beşini depolayabilecek stok kapasitesine sahiptir ve bu konuda yeni yatırımlar yapılarak stok kapasitesini artırma yolunda çalışmalar sürdürülmektedir. Tamamen dışa bağımlı olduğumuz ve stok kapasitemizin düşük olduğu doğal gaz sektörünün daha sağlıklı işleyebilmesi ve gelişebilmesi için talep, arz, iletim, dağıtım ve fiyatlandırma konularında planlar yapılması son derece önemlidir. Yapılacak planlama çalışmaları içerisinde en önemli konulardan birini doğal gaz talep miktarının doğru şekilde belirlenmesi oluşturmaktadır. Doğalgaz stok kapasitemizin düşük olması nedeniyle, doğal gaz talebinin doğru bir şekilde belirlenmesi doğalgaz alımı ile ilgili anlaşmaları ve yapılacak yatırımları etkileyecektir. Talep tahmini ne kadar doğru olursa, yapılan planlama çalışmaları da o kadar sağlıklı olacaktır.

Doğal gaz tüketim tahmininde klasik zaman serileri ve son zamanlarda yapay sinir ağları başarıyla kullanılmaktadır. Geçmiş dönemlere ilişkin gözlem değerleri yardımıyla geleceğe yönelik tahminler yapmayı amaçlayan zaman serisi modelleri tıp, mühendislik, işletme, ekonomi ve finans gibi birçok alanda yaygın bir şekilde kullanılmaktadır. Zaman serileri yardımıyla tahmin yapmak için değişik yöntemler kullanılarak oluşturulan farklı modeller bulunmaktadır. Bu modeller arasında en çok bilinen ve yaygın olarak kullanılan 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) son yıllarda zaman serilerinin analizinde kullanılan alternatif yöntemlerden biri olmuştur. Yapay sinir ağlarının zaman serilerinin tahmininde kullanıldığı çalışmalara ilişkin geniş bir derleme Zhang vd. tarafından yapılmıştır(Zhang vd, 1998).

Yapay sinir ağlarının en önemli avantajı, veri setine ilişkin fonksiyonel yapının tam olarak belirlenemediği durumlarda, veriden hareketle birçok değişik formdaki fonksiyonel yapıyı başarıyla modelleyebilmesidir. Genel fonksiyon yaklaşımcısı olarak da bilinen yapay sinir ağları, istatistiksel yöntemlerin aksine veri seti üzerinde her hangi bir ön varsayıma gerek duymaz.

Doğalgaz tüketiminin yapay sinir ağları ile tahminine ilişkin literatürde birçok çalışma yer almaktadır. Ivezic (2006) çalışmasında geçmiş günlere ait sıcaklık ve doğal gaz tüketim verilerini kullanarak Sibiryaya için günlük ve haftalık doğalgaz tüketim miktarlarını tahmin etmiştir. Garcia ve Mohagheg(2004) ise çalışmalarında 2020 yılına kadar Amerika Birleşik

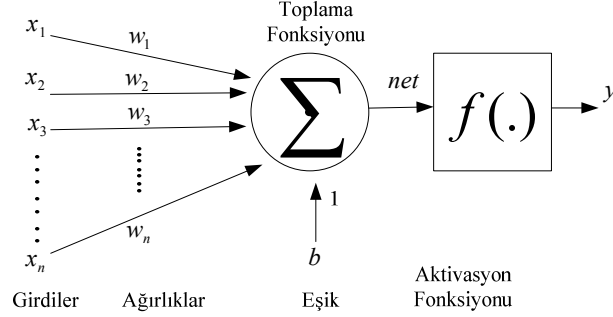
Devletleri'ndeki doğal gaz üretim miktarını tahmin eden YSA modeli geliştirmiştir. Bolen ise yaptığı tez çalışmasında ABD'nin sıvılaştırılmış gaz ithalini tahmin etmek için yapay sinir ağlarından faydalanmıştır. Khotanzad (2000) ise çalışmasında iki aşamalı yapı önermiştir. Birinci aşamada iki adet paralel çalışan adaptif yapay sinir ağı kullanarak ayrı ayrı elde ettiği günlük doğal gaz tüketim tahminlerini ikinci aşamada bir birleştirme ünitesinden geçirerek son tahmin değerini elde etmiştir. Brown ve diğerleri ise çalışmalarında YSA kullanarak geliştirdikleri günlük doğal gaz tüketim modelini lineer regresyon modelleriyle karşılaştırmışlar ve YSA kullanılarak elde edilen tahmin değerlerinin daha iyi sonuçlar verdiğini göstermişlerdir. Viet ve Mandziuk (2003) Polonya'nın belirli bir bölgesinde doğal gaz tüketiminin tahmini için gerçekleştirdikleri çalışmada YSA ve Bulanık YSA modellerini kullanmışlar ve uzun dönemli aylık tahminlerin orta dönemli haftalık tahminlere oranla daha iyi sonuçlar verdiğini göstermişlerdir. Ayrıca çalışmalarında, YSA kullanılarak gerçekleştirilen tahmin sonuçlarının klasik istatistiksel yöntemlerle elde edilen tahmin sonuçlarından daha iyi olduğunu belirtmişlerdir.

Bu çalışmada ise Ankara iline ilişkin doğal gaz tüketim tahmini çalışması yapılmıştır. Bu amaçla klasik zaman serileri analizi ile ileri beslemeli yapay sinir ağları kullanılarak tahmin modelleri oluşturulmuş günlük haftalık veriler kullanılarak kısa dönemli tahmin sonuçları elde edilmiş, her iki yöntem içinde elde edilen tahmin değerleri ile gerçek değerler karşılaştırılmıştır.

## II. Yöntem

### A. Yapay Sinir Ağları

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 öğrenebilme, 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 ağıın öğrenmesi istenen örnekler tarafından belirlenir. Ağırlıklar ( $w_1, w_2, \dots, w_n$ ), girdi kümesi veya kendinden önceki bir tabakadaki başka bir işlem elemanın 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.

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

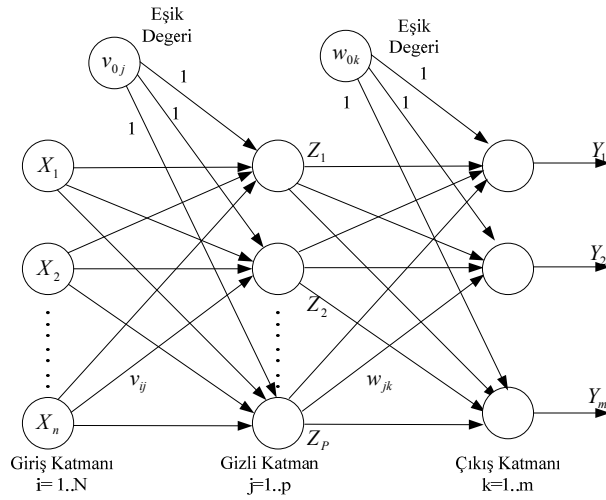
Toplam fonksiyonu sonucunda elde edilen değer doğrusal ya da doğrusal olmayan türevlenebilir bir transfer fonksiyonundan geçirilerek işlem elemanın çıktısı hesaplanır.

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

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 (Perceptron, Adaline, MLP, 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 ağlarıdır. (Multiple Layer Perceptron-MLP )

### 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 dışarıyailetildiği 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, 2003:30). 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 de verilen hata fonksiyonunun minimize edilmesiyle düzenlenir.

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

Eşitlikte  $y_k$  ağıın ürettiği çıktıyı  $t_k$  ise gerçek çıktı değerini göstermektedir. Hatayı en aza indirmek için bağlantı ağırlıkları yeniden düzenlenerek güncellenir. Böylece ağıın 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 ağıın yapısının belirlenmesi gerekmektedir. Ağ yapısının belirlenme süreci, ağıın 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' de 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.

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

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

*B. Box-Jenkins Metodolojisi Ve Arıma Modelleri*

Box-Jenkins yöntemi tek değişkenli zaman serilerinin ileriye dönük tahmin ve kontrolünde kullanılan istatistiksel öngörü yöntemlerinden biridir. Zamana bağlı olayların rassal karakterde olaylar, bu olaylarla ilgili zaman serilerinin ise stokastik süreç olduğu varsayımına dayanarak geliştirilmiş olan bu yöntemin uygulandığı zaman serisinin eşit aralıklı gözlem değerlerinden oluşan kesikli ve durağan bir seri olduğu varsayılmaktadır. Ancak gerçekte zaman serilerinin ortalama ve varyansında zamana bağlı olarak bir değişim olmaktadır. Durağan olmayan zaman serilerinde görülen bu değişim, genellikle trend, düzenli, düzensiz dalgalanmalar ve tesadüfi dalgalanmaların etkisiyle gerçekleşir. Durağan olmayan zaman serilerinin Box-Jenkins yöntemiyle öngörüsü için seri bazı dönüşüm yöntemleriyle durağan hale getirilmelidir.

Box-Jenkins Yöntemi ile öngörü dört aşamada gerçekleşmektedir.

1. Model Belirleme: Zaman serisine uygun Box-Jenkins modeli bu aşamada belirlenir.
2. Parametre Tahmini: Model belirleme aşamasında belirlenen modele ilişkin parametrelerin tahmin edildiği aşamadır.
3. Uygunluğun Testi: Modelin veri setine uygunluğunun istatistiksel yöntemlerle test edildiği bu aşamada model uygun bulunursa son aşamaya geçilir, uygun bulunmazsa başka bir modelin belirlenmesi için ilk aşamaya dönülür.
4. Tahmin: Seçilen en uygun model tahmin için kullanılır.

Box-Jenkins Yöntemi ile tahmin edilen zaman serisi modelleri; Otoregresif (AR) Modeli, Hareketli Ortalama (MA) Modeli, Otoregresif-Hareketli Ortalama (ARMA) Modeli ve Otoregresif Bütünleşik Hareketli Ortalama (ARIMA) Modelidir.

ARIMA modelleri, durağan olmayan ancak fark alma işlemiyle durağan hale dönüştürülmüş serilere uygulanan modellerdir. Durağan olmayan ancak fark alma işlemiyle durağan hale dönüştürülmüş serilere uygulanan modellere “durağan olmayan doğrusal stokastik modeller” denir. Bu modeller d dereceden farkı alınmış serilere uygulanan, değişkenin t-dönemindeki değerinin belirli sayıdaki geri dönem değerleri ile aynı dönemdeki hata teriminin doğrusal bir fonksiyonu olarak ifade edildiği AR ve değişkenin t-dönemindeki değerinin aynı dönemdeki hata terimi ve belirli sayıda geri dönem hata terimlerinin doğrusal fonksiyonu olarak ifade edildiği 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.

Genel ARIMA(p,d,q) modeli aşağıdaki gibi formüle edilir.

$$Z_t = \Phi_1 Z_{t-1} + \Phi_2 Z_{t-2} + \dots + \Phi_p Z_{t-p} + \delta + a_t - \Theta_1 a_{t-1} - \Theta_2 a_{t-2} - \dots - \Theta_q a_{t-q} \quad (7)$$

Burada  $Z_t, Z_{t-1}, \dots, Z_{t-p}$  d dereceden farkı alınmış gözlem değerlerini,  $\Phi_1, \Phi_2, \dots, \Phi_p$  d dereceden farkı alınmış gözlem değerleri için katsayıları,  $\delta$  sabit değeri,  $a_t, a_{t-1}, \dots, a_{t-q}$  hata terimlerini ve  $\Theta_1, \Theta_2, \dots, \Theta_q$  hata terimleri ile ilgili katsayıları göstermektedir.

### III. Uygulama

Çalışmada kullanılan veriler, Ankara iline ilişkin Ocak 2005 ile Haziran 2006 arasındaki günlük ve haftalık doğalgaz arz değerleridir. MLP ve ARIMA modelleri için her iki veri setinin son 10 gözlemi, yapılan tahminleri test etmek için kullanılmıştır. MLP modellerinde kalan verinin %80 i eğitim %20 si ise doğrulama verisi olarak ayrılmıştır.

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 ve gizli katmanda kullanılan nöron sayısı 1 den 10 ' a kadar değiştirilerek 100 farklı yapay sinir ağı modeli elde edilmiştir. Veriler MLP ile oluşturulan ağlara girilmeden önce ağın yapısına uygun hale getirilerek; gerekli giriş ve çıkış vektörleri oluşturulmuştur. Daha sonra bu vektörler [-1 1] aralığında normalleştirilmiştir. Eğitim verileri ağa sunularak ağın öğrenme işlemi gerçekleştirilmiş bu 100 model içerisinde test verileri için en küçük hata kareleri ortalaması(MSE) değerini veren yapay sinir ağı modeli seçilmiştir. Haftalık veriler için giriş nöron sayısı 2, gizli nöron sayısı 2, günlük veriler için ise giriş nöron sayısı 2, gizli nöron sayısı 4 olan MLP modeli en uygun model olarak seçilmiştir.

Veri setine uygun Box-Jenkins modelinin belirlenmesi için hem günlük hem haftalık veriler için farklı modeller oluşturulmuştur. Bu modeller içerisinde günlük veriler için sabit terim içermeyen ARIMA(3,1,2); haftalık veriler içinse sabit terim içeren doğal logaritmik dönüşüm yapılmış ARIMA(1,0,0) modelinin kullanılması uygun görülmüştür.

Çalışma sonucunda her iki veri seti için elde edilen sonuçlar Tablo 1 ve Tablo2'de verilmiştir. Tablolar incelendiğinde haftalık veriler için ARIMA ve MLP modellerinin ortalama hata kareler degerleri (MSE Mean Square Error) (262858,74 - 225302,08); günlük veriler için ise (2310,30 - 1807,82) şeklinde hesaplanmıştır. MSE performans ölçütü kullanılarak modellerin tahmin sonuçları kıyaslandığında YSA modellerinin ARIMA modellerinden daha iyi tahmin performansına sahip olduğu görülmektedir.



Tablo 1: *Günlük Doğalgaz Verilerine İlişkin Tahmin ve Gözlenen Değerler*

Gözlenen Değerler	ARIMA Tahmin	MLP Tahmin
833	814	831,16
880	860	832,09
811	896	868,02
865	800	840,93
791	875	848,73
750	786	821,48
750	721	764,66
803	776	748,35
796	819	782,71
788	809	799,40
MSE	2310,30	1807,82
MAPE(%)	5,07	4,42

Tahmin sonuçlarını karşılaştırmak için kullanılan diğer bir performans ölçüsü de ortalama mutlak yüzde hata (MAPE, Mean Absolute Percentage Error) değeridir. Bu değer ölçekten bağımsız olup eşitlik 8 de verildiği gibi yüzde değer olarak hesaplanmaktadır.

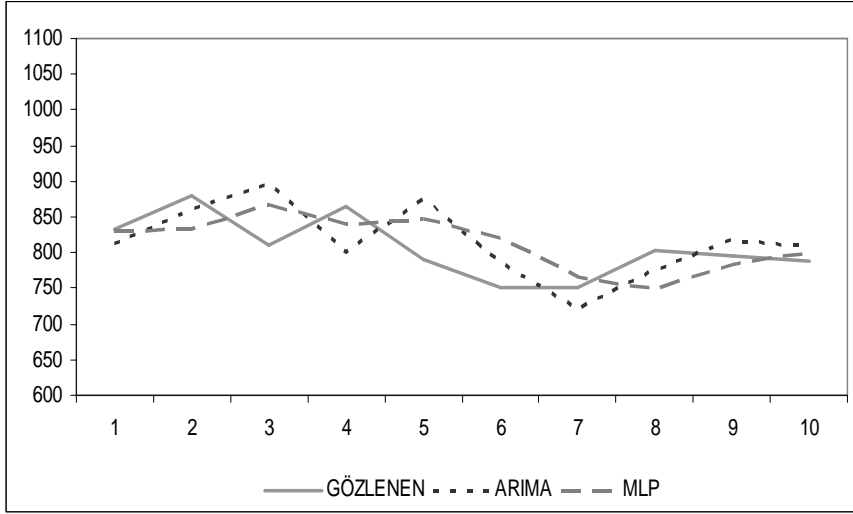
$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{y_t - \hat{y}_t}{y_t} \right| \times 100 \quad (8)$$

Eşitlikte  $y_t$  gerçek gözlem değerlerini gösterirken,  $\hat{y}_t$  ise tahmin edilen değeri göstermektedir.

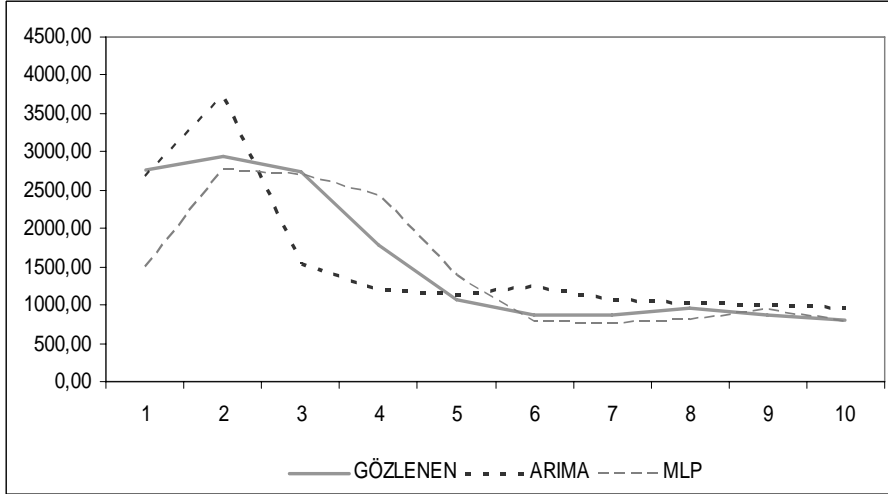
Tablo 2: *Haftalık Doğalgaz Verilerine İlişkin Tahmin ve Gözlenen Değerler*

Gözlenen Değerler	ARIMA Tahmin	MLP Tahmin
2769,71	2667,87	1493,18
2939,86	3719,85	2766,70
2741,71	1542,05	2688,43
1777,43	1207,79	2434,84
1059,00	1128,32	1387,68
865,71	1249,48	779,78
858,86	1075,39	750,03
961,71	1016,38	799,65
863,29	997,02	931,85
791,86	954,08	776,35
MSE	262858,74	225302,08
MAPE(%)	22,38	17,13

Tablo 1’de görüleceği gibi günlük veriler için MLP modelinden elde edilen MAPE değeri %4.42 iken ARIMA modeli için hesaplanan değer %5.07 dir. Benzer şekilde haftalık veriler için Tablo 2 incelendiğinde MLP için MAPE değeri %17.13 iken ARIMA modeli için bu %22.38 olarak hesaplanmıştır. Bu sonuçlara göre, her iki veri seti içinde daha düşük MAPE değerlerine sahip YSA modelleri ARIMA modellerinden daha yüksek tahmin performansı göstermiştir. Ayrıca gözlenen değerler ile tahmin değerlerine ilişkin grafikler Şekil 3 ve Şekil 4’de gösterilmiştir.



Şekil 3: Günlük Doğalgaz Verilerine İlişkin Tahmin ve Gözlenen Değerler



Şekil 4: Haftalık Doğalgaz Verilerine İlişkin Tahmin ve Gözlenen Değerler

#### IV Sonuç ve Öneriler

Bu çalışmada, yapay sinir ağları ve ARIMA zaman serisi analiz yöntemleri kullanılarak Ankara ilinin doğal gaz tüketimi tahmin edilmiştir. Çalışmada kullanılan veriler günlük ve haftalık biçimde olup Botaş A.Ş Genel Müdürlüğü'nden temin edilmiştir. Her iki yöntem içinde farklı modeller oluşturularak eğitim ve test verileri için en küçük MSE değerlerine sahip modeller, en iyi modeller olarak seçilmiş ve bu modeller yardımıyla 10 adet test verisi için tahminler gerçekleştirilmiştir. Her iki yöntem yardımıyla elde edilen tahmin sonuçları MSE ve MAPE performans kriterleri yardımıyla karşılaştırılmıştır. Her iki performans ölçütü içinde yapay sinir ağı modelleri ARIMA modellerinden daha iyi tahmin performansı sergilemişlerdir.

Ayrıca günlük veriler için hesaplanan performans ölçütlerinin haftalık veriler için hesaplanan değerlerden daha iyi olduğu görülmüştür. Bu durum ağı eğitiminde kullanılan veri sayısı arttıkça yapay sinir ağlarının daha iyi sonuç verdiğini göstermektedir. Sonuç olarak veri setindeki lineer ilişkiler yanında lineer olmayan ilişkileri de başarıyla modelleyebilmesi, veri üzerinde her hangi bir ön varsayım gerektirmemesi ( normallik, fonksiyonel yapı vb.) gibi özelliklerinden dolayı yapay sinir ağları uygun ağ yapısı ve yeterli sayıda veri kullanıldığında çok başarılı sonuçlar üretmektedir. Bu özelliklerinden dolayı serisi analizinde klasik istatistiksel yöntemlere alternatif bir yöntem olarak kullanılabilir.

Bu çalışmada kullanılan modellerde, değişkenler sadece geçmişteki doğal gaz tüketim gözlemleridir. Doğalgaz tüketimini etkileyen faktörler arasında doğalgazın fiyatı, alternatif enerji kaynaklarının (petrol, kömür elektrik gibi) fiyatları, hava sıcaklığı, abone sayısı gibi değişkenlerde sayılabilir. Bu farklı değişkenlere ait verilerin olmayışı ve modellere dahil edilememesi çalışmanın kısıtlarından birini oluşturmaktadır. Ülkemizde Aylık bazda doğalgaz istatistiklerine ait veri sayısının az oluşu aylık tahmin yapacak modellerin oluşturulmasına engel teşkil etmiştir. İleriki çalışmalarda farklı değişkenlere ilişkin veriler temin edilerek bu değişkenleri kullanan regresyon modelleri oluşturulup tahmin sonuçları karşılaştırılabilir.

#### Kaynaklar

- Bolen, M. S.(2005) "A New Methodology for Analyzing and Predicting U.S. Liquefied Natural Gas Imports Using Neural Networks", Texas A&M University, Yüksek Lisans Tezi.
- Brown, R. H., Matin, L., Kharout, P., and Piessens, L. P. (1996) "Development of Artificial Neural-network Models to Predict Daily Gas Consumption", A.G.A. Forecasting Rev., 5, pp. 1-22.
- Fausett, L.(1994) Fundamentals of Neural Networks: Architectures, Algorithms and Applications, Prentice Hall.
- Garcia, A., Mohagheg, S. D. (2004) "Forecasting US Natural Gas

- Production into year 2020: a comparative study”, Eastern Society of Petroleum Engineers Regional Conference ,SPE 91413.
- Ivezic, D. (2006) “Short-Term Natural Gas Consumption Forecast”, FME Transactions VOL. 34, No 3, 165-169.
- Khotanzad, A., Elragal, H., and Lu, Tsun-Liang (2000) “Combination of Artificial Neural-Network Forecasters for Prediction of Natural Gas Consumption”, IEEE Trans. Neural Netw., 11, pp. 464–473.
- Öztemel, Ercan. (2003) Yapay Sinir Ağları, Papatya Yayıncılık, İstanbul.
- Tang, Z, Fishwick, P.A. (1993),”Feedforward neural nets as models for time series forecasting”,ORSA Journal on Computing, Vol. 5 (4), pp.374–385
- Viet, N.H. ve Mandzuik, J. (2003) “Neural and Fuzzy Neural Networks for Natural Gas Consumption Prediction”, IEEE XIII Workshop on Neural Networks for Signal Processing, pp.759-768.
- Zhang, G., Patuwo, B. E., Hu, M. Y. (1998) “Forecasting with artificial neural networks: the state of the art”, International Journal of Forecasting, 14, ss.35-62.