

YAPAY SİNİR AĞLARI İLE ÖNGÖRÜ MODELLEMESİ

Burçin ATASEVEN

İstanbul Kültür Üniversitesi, İktisadi ve İdari Bilimler Fakültesi, İşletme Bölümü, Araştırma Görevlisi, Dr.

YAPAY SİNİR AĞLARI İLE ÖNGÖRÜ MODELLEMESİ

Özet: Gelişen teknolojiye paralel olarak artan işleme ve hesaplama gücü ile birlikte, karmaşık simülasyonların yapılması ve gelişmiş yapay zeka teknolojilerini kullanarak temel kriterlere dayalı olarak geleceğe dönük öngörümleme modellerinin gerçekleştirilmesi mümkün hale gelmiştir. Bu modellerin gerçekleştirilmesini sağlayan önemli bir uygulama alanı ise "Yapay Sinir Ağları"dır. Bu çalışmada öngörümleme tekniklerinden zaman serisi yöntemlerine giren "Box-Jenkins (ARIMA) Metodolojisi" ve "Yapay Sinir Ağları" yöntemlerinin öngörü performanslarını karşılaştırarak en yüksek başarıyı sağlayan yöntemin belirlenmesi ve belirlenen yöntem yardımıyla 11 yıl için bir şirketten rastgele seçilen dört ürünün aylar itibarıyla satış rakamlarının tahmin edilmesi amaçlanmıştır. Çalışmanın uygulama bölümünde öngörümleme tekniği olarak Yapay Sinir Ağlarının kullanımının daha başarılı sonuçlar ürettiği sonucuna varılmıştır.

Anahtar Kelimeler: Yapay Sinir Ağları, Öngörü Modelleri, Zaman Serileri Analizi, Box-Jenkins Metodolojisi

FORECASTING BY USING ARTIFICIAL NEURAL NETWORKS

Abstract: Along with the processing and computation power increasing parallel with the developing technology, performing complex simulations and establishing forecasting models using developed artificial intelligence technologies based on the main criterions have been rendered possible. One important application field ensuring the possibility of these models is "Artificial Neural Networks". In this study, it is aimed to determine the method providing the highest success by comparing the forecasting performances of the "Box-Jenkins (ARIMA) Methodology" and "Artificial Neural Networks" which are included in the time series methods of the forecasting techniques and to forecast with the determined method the sales values of three products choosen randomly from the products being produced in a company for 11 years are aimed. In the application part of the study it is reached to conclusion that to use Artificial Neural Networks as a forecasting method will give more successful results.

Keywords: Artificial Neural Networks, Forecasting Methods, Time Series Analysis, Box-Jenkins Methodology

I. GİRİŞ

Öngörü kavramı, bir değişkenin belirli varsayımlar altında gelecekte alabileceği değerlerin önceden yaklaşık olarak belirlenmesi olarak tanımlanır. Zaman serisi çözümlemesi ile öngörü, incelenen bir değişkenin şimdiki ve geçmiş dönemdeki gözlem değerlerini kullanarak ve birtakım varsayımlar altında öngörü değerlerinin hangi sınırlar arasında gerçekleşebileceğini ortaya koymak için yapılan uğraşlardır.

Doğru tahminin (veya öngörünün) başarılı kararları beraberinde getireceği ve bu şekilde elde edilen faydanın en üst düzeye çıkartılabileceği gerçeği, öngörü modellemesine olan ilgiyi artırmaktadır. Artan ilgi ile birlikte, bu alanda her geçen gün önemli gelişmeler olmaktadır. Öngörü modellemesinde kullanılabilen yöntemlerin çeşitliliği, model seçiminde bazı zorlukları beraberinde getirmiştir.

Öngörümleme teknikleri, nitel öngörümleme yöntemleri ve nicel öngörümleme yöntemleri olmak üzere iki şekilde sınıflandırılabilir. Her iki yöntemin çıkış noktası da ilgili değişkene ait gözlem değerleridir. Geçmiş ve şimdiki dönem gözlem değerlerinden, gelecek dönem gözlem değerleri belirli kurallar çerçevesinde öngörümlenir.

Bir zaman serisi, belli bir değişkene ilişkin zamana göre sıralanmış gözlem değerleridir. Zaman serisi analizi, öngörümlemede bulunulacak değişkenin geçmiş zaman değerlerini kullanarak gelecek değerlerin öngörümlemesi için model geliştirmede kullanılır. Model geliştirme, ilgili değişkene ait zaman serisinin analiz edilmesi, serinin ana eğiliminin ve özelliklerinin belirlenmesine dayanır. Zaman serileri analizi için yaygın olarak kullanılan bazı yöntemler vardır. Doğrusal zaman serilerinin analizinde oldukça başarılı sonuçlar veren Box-Jenkins modelleri bu tekniklerin en önemlilerindedir.

1980'li yılların sonlarından başlamak üzere zaman serilerine ilişkin kestirimler için kullanılmakta olan yöntemlerden biri de Yapay Sinir Ağları (YSA) yöntemidir. YSA öngörümleme tekniği günümüzde birçok alanda yaygın bir şekilde kullanılmaya başlanmıştır. Basit bir şekilde insan beyninin çalışma şeklini taklit eden YSA'ları Yapay Zeka Teknolojileri içinde önemli bir yere sahiptir. YSA metodolojisi veriden öğrenebilme, genelleme yapabilme, sınırsız sayıda değişkenle çalışabilme vb birçok önemli özelliğe sahiptir. Bu özellikleri sayesinde oldukça önemli avantajlar sağlayan YSA metodolojisi diğer alanlarda olduğu gibi öngörü modellemesi alanında da yaygın bir şekilde kullanılmaktadır. YSA, girdi ve çıktı değişkenleri arasındaki herhangi bir ön bilgiye gereksinim duymadan doğrusal ve doğrusal olmayan modellemeyi

sağlayabilmektedir. YSA'nın bir öngörümleme aracı olarak kullanılmasına ilişkin bir çok araştırmacı tarafından yapılmış çok sayıda çalışma olmasına rağmen, YSA'nın performansını etkileyen anahtar faktörlerin neler olduğu konusunda kesin bir yargı yoktur. Belirtilen bu faktörlere ek olarak, eğitim algoritması, veri kümesinin düzenlenmesi, kestirim dönemi uzunluğu faktörlerinin de YSA performansı üzerinde etkili olduğu düşünülmektedir. Bu nedenle bütün bu faktörlerin etkisini araştırarak bir çalışmanın faydalı olacağına inanılmaktadır.

Bu çalışmada, yeni bir yöntem olan Yapay Sinir Ağları (Artificial Neural Networks) teknolojisi incelenecek, öngörümleme tekniği olarak özel bir şirkette ele alınan üç ürünün satış rakamlarına uygulanacak ve literatürde yer alan başka öngörümleme teknikleri ile karşılaştırmalı olarak performans değerlendirmesi yapılacaktır.

II. YAPAY SİNİR AĞLARI

İnsan beyninin üstün özellikleri, bilim adamlarını üzerinde çalışmaya zorlamış ve beynin nörofiziksel yapısından esinlenerek matematiksel modeli çıkarılmaya çalışılmıştır. Beynin bütün davranışlarını tam olarak modelleyebilmek için fiziksel bileşenlerinin doğru olarak modellenmesi gerektiği düşüncesi ile çeşitli yapay hücre ve ağ modelleri geliştirilmiştir. Böylece Yapay Sinir Ağları denen yeni ve günümüz bilgisayarlarının algoritmik hesaplama yönteminden farklı bir bilim dalı ortaya çıkmıştır.

Genel anlamda YSA, beynin bir işlevi yerine getirme yöntemini modellemek için tasarlanan bir sistem olarak tanımlanabilir. YSA, yapay sinir hücrelerinin birbirleri ile çeşitli şekillerde bağlanmasından oluşur ve genellikle katmanlar halinde düzenlenir. Donanım olarak elektronik devrelerle veya bilgisayarlarda yazılım olarak gerçekleştirilebilir. Beynin bilgi işleme yöntemine uygun olarak YSA, bir öğrenme sürecinden sonra bilgiyi saklama ve genelleme yeteneğine sahip paralel dağılmış bir işlemcidir [1].

Turing makineleriyle temeli atılan yapay zeka üzerinde en fazla araştırma yapılan konu "Yapay Sinir Ağları"dır. Yapay sinir ağları, temelde tamamen insan beyni örneklenerek geliştirilmiş bir teknolojidir [2]. Bir sinir ağı, bilgiyi depolamak ve onu kullanışlı hale getirmek için doğal eğilimi olan basit birimlerden oluşan paralel dağıtılmış bir işlemcidir. İnsan beynine iki şekilde benzerlik göstermektedir:

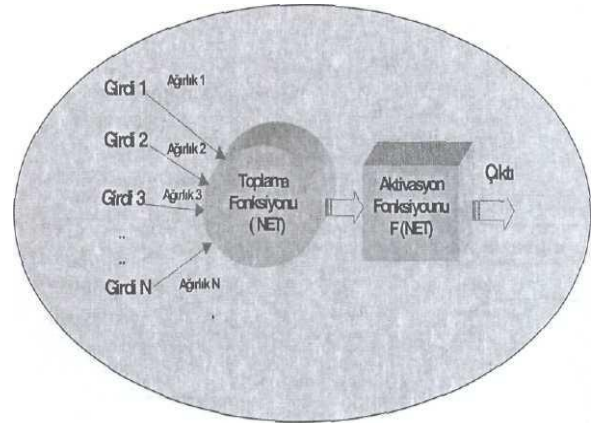
1. Bilgi, öğrenme süreci yoluyla ağ tarafından elde edilir.
2. Sinaptik ağırlıklar olarak bilinen nöronlar arası bağlantı kuvvetlerini, bilgiyi depolamak için kullanır [3].

II.1. Yapay Sinir Ağlarının Genel Özellikleri

Yapay bir sinir hücresi, biyolojik bir sinir hücresinin temel davranışlarından esinlenen matematiksel

modeli ortaya koyan bir algoritma veya fiziksel araç olarak tanımlanabilir. Biyolojik sinir hücresinin tanımından hareket ederek, yapay bir sinir hücresinin diğer sinir hücrelerinden aldığı sinyalleri bünyesinde topladığını ve toplam sinyal birikiminin belli bir eşiği aştığı anda, bu yapay sinir hücresinin kendi sinyalini bir başka sinir hücresine ilettiği söylenebilir [4].

Biyolojik sinir ağlarının sinir hücreleri olduğu gibi yapay sinir ağlarının da yapay sinir hücreleri vardır. Yapay sinir hücreleri mühendislik biliminde proses elemanları olarak da adlandırılmaktadır. Şekil 1'de gösterildiği gibi her proses elemanın 5 temel elemanı vardır. Bunlar; girdiler, ağırlıklar, toplama fonksiyonu, aktivasyon fonksiyonu ve çıktılardır [5].




Şekil 1: Yapay Sinir Hücresinin Yapısı [5]

Yapay sinir ağları, yapay sinir hücrelerinin katmanlar şeklinde bağlanmasıyla oluşturulan veri tabanlı sistemler olup insan beyninin öğrenme ve değişik koşullar altında çok hızlı karar verebilme gibi yeteneklerinin, basitleştirilmiş modeller yardımıyla karmaşık problemlerin çözülmesinde kullanılmasını amaçlamaktadır [6].

Yapay sinir ağlarında, yapay nöronlar basit bir şekilde kümelendirilmektedirler. Bu kümelendirme tabakalar halinde yapılmaktadır ve daha sonra bu tabakalar bir diğerine ilişkilendirilmektedir. Temel olarak, tüm yapay sinir ağları benzer bir yapıya sahiptirler. Böyle bir genel yapı Şekil 2'de gösterilmiştir. Bu yapıda, bazı nöronlar girdileri almak için bazı nöronlar ise çıktıları iletmek için dış mekan ile bağlantılı haldedirler. Geri kalan tüm nöronlar ise gizli tabakalardadırlar, yani sadece ağ içinde bağlantıları vardır [7].

Tek tabaka veya tek eleman içeren bazı başarılı ağlar oluşturulabilmesine rağmen çoğu uygulamalar en az üç tabaka (girdi tabakası, gizli tabaka ve çıktı tabakası) içeren ağlara ihtiyaç duymaktadır. Girdi tabakası, dışarıdan girdileri alan nöronları içerir. Ayrıca, önemli olan bir nokta, girdi tabakasındaki nöronların girdi değerleri üzerinde bir işlem uygulamamasıdır. Sadece girdi değerleri bir sonraki tabakaya iletilir ve bu yüzden de bazı araştırmacılar tarafından ağların tabaka sayısına

dahil edilmezler. Çıktı tabakası ise çıktıları dışarı ileten nöronları içeren tabakadır. Girdi ve çıktı tabakaları tek tabakadan oluşurken bu iki tabaka arasında birden fazla gizli tabaka bulunabilir. Bu gizli tabakalar çok sayıda nöron içerirler ve bu nöronlar tamamen ağ içindeki diğer nöronlarla bağlantılıdır. Çoğu ağ türünde, gizli tabakadaki bir nöron sadece bir önceki tabakanın tüm nöronlarından sinyal alır. Nöron işlemini yaptıktan sonra ise çıktısını bir sonraki tabakanın tüm nöronlarına gönderir. Bu yapı ağın çıktısı için bir ileri besleme patikası oluşturur. Bu bir nöronun diğerine olan iletişim hattı, sinir ağları için önemli bir parçadır [7].



Şekil 2: Yapay Sinir Ağlarının Genel Yapısı [8]

Bir yapay sinir ağının yapısı ve sinir hücrelerinin sayısı değişiklik göstermelerine rağmen, yapay sinir ağının oluşumu için kabul görmüş herhangi bir kural bulunmamaktadır. Gerekli gizli katman sayısından az gizli katmana sahip yapay sinir ağları komplike fonksiyonların çözümünde yetersiz kalırken, çok fazla gizli katmana sahip yapay sinir ağları ise istenmeyen kararsızlıklarla karşılaşmaktadır. Gizli katman sayısı belirlendikten sonra karşılaşılan problem ise her bir tabakada kaç tane nöronun yer alacağına karar vermede karşımıza çıkmaktadır. Girdi katmanı için bir sorun bulunmamaktadır; bu sayı sistem içerisindeki girdilerin sayısına eşittir. Aynı şekilde, çıktı katmanı da istenilen çıktı sayısı ile belirlenebilmektedir. Esas sorun, gizli katmanlarda nöron sayısını belirlemektir. Geleneksel matris algoritması, matris boyutlarının ya girdi sayısına ya da çıktı sayısına eşit olması gerektiğini söylemektedir. Ne yazık ki, gizli katmanda en verimli şekilde kaç tane nöronun bulunacağı konusunda herhangi bir matematiksel test bulunmamaktadır. Deneme ve yanılma yöntemi uygulanarak karar verilmelidir [9].


II.2. Yapay Sinir Ağlarının Sınıflandırılması

Yapay sinir ağlarının yapılarına ve öğrenme algoritmalarına göre sınıflandırmak mümkündür. Çalışmanın bu alt bölümünde yapay sinir ağlarını sadece yapılarına göre sınıflandırıp bir sonraki alt bölümde öğrenme algoritmaları açıklanmaya çalışılacaktır.

Yapay sinir ağı mimarileri, sinirler arasındaki bağlantıların yönlerine göre veya ağ içindeki işaretlerin akış yönlerine göre ikiye ayrılmaktadır; ileri beslemeli (feed forward) ve geri beslemeli (feedback, recurrent) ağlardır.

İleri beslemeli ağlarda işlemci elemanlar genellikle katmanlara ayrılmışlardır. İşaretler, girdi katmanından çıktı katmanına tek yönlü bağlantılarla iletilir. İleri beslemeli YSA'da, hücreler katmanlar şeklinde düzenlenir ve bir katmandaki hücrelerin çıktıları bir sonraki katmana ağırlıklar üzerinden giriş olarak verilir. Giriş katmanı, dış ortamlardan aldığı bilgileri hiçbir değişikliğe uğratmadan orta (gizli) katmandaki hücrelere iletir. Bilgi, orta ve çıktı katmanında işlenerek ağ çıkışı belirlenir [10].

İleri beslemeli ağlara örnek olarak Çok Katmanlı Algılayıcılar (Multilayered Perceptrons-MLP) ve Öğrenme Vektör Nicelendirmesi (Learning Vector Quantization-LVQ) ağları verilebilir [11]. Çalışmada ileri beslemeli çok katmanlı algılayıcıyı kullanacağımızdan burada sadece Çok Katmanlı Algılayıcıların çalışmasından bahsedilecektir.



Şekil 3: Çok Katmanlı Algılayıcının Yapısı [11]

Tek bir katmandan oluşan bir algılayıcı sadece doğrusal fonksiyonları tahminleyebilir. Giriş ve çıktı katmanları arasında gizli katmanlara sahip olan ileri beslemeli çok katmanlı algılayıcılar ise tek katmanlı algılayıcıların karşılaştıkları sınırlamaları ortadan kaldırmaktadırlar [12].

Bir yapay sinir ağından çözmesi istenilen problem doğrusal değilse ilk başta tasarlanmış yapay sinir ağları ile

bunu modellemek mümkün değildir. Bu tür problemler için daha gelişmiş bir ağ türüne ihtiyaç duyulmuştur. Çok katmanlı alılayıcı da bu amaçla geliştirilen bir ağıdır. Birçok öğrenme algoritmasının bu ağı eğitmede kullanılabilir olması, bu modelin yaygın kullanılmasının sebebidir.

Şekil 3’de bir çok katmanlı algılayıcının yapısı gösterilmiştir. Bir çok katmanlı algılayıcı modeli, bir giriş, bir veya daha fazla gizli ve bir de çıkış katmanından oluşur. Her bir katmanda da bir veya daha fazla sayıda işlem elemanı bulunur. Bir katmandaki bütün işlem elemanları bir üst katmandaki bütün işlem elemanlarına bağlıdır. Bilgi akışı ileri doğru olup geri besleme yoktur. Bunun için bu tip ağlar ileri beslemeli sinir ağı modeli olarak adlandırılır. Giriş katmanında herhangi bir bilgi işleme yapılmaz. Giriş ve çıkış katmanındaki işlemci elemanı sayısı tamamen uygulanan probleme bağlıdır. Ara katman sayısı ve ara katmanlardaki işlemci elemanı sayısı ise, deneme yanılma yolu ile bulunur.

Geri beslemeli ağ mimarileri, genellikle danışmansız öğrenme kurallarının uygulandığı ağlarda kullanılmaktadır. Bu tip ağlarda en az bir hücrenin çıkışı kendisine veya diğer hücelere giriş olarak verilir ve genellikle geri besleme bir geciktirme elemanı üzerinden yapılır. Geri besleme, bir katmandaki hücreler arasında olduğu gibi katmanlar arasındaki hücreler arasında da olabilir. Bu yapısı ile geri beslemeli yapay sinir ağları, doğrusal olmayan dinamik bir davranış göstermektedir. Geri beslemeli ağlara örnek olarak Hopfield, Elman ve Jordan ağları verilebilir [13].

II.3. Yapay Sinir Ağlarında Öğrenme

Yapay sinir ağlarının en ayırt edici özelliklerinden birisi de öğrenme yeteneğine sahip olmasıdır. Öğrenme elde bulunan örnekler arasındaki yapının iyi bir davranış göstermesini sağlayabilecek olan bağlantı ağırlıklarının hesaplanması olarak tanımlanır. Yapay sinir ağları öğrenme esnasında elde ettiği bilgileri, sinir hücreleri arasındaki bağlantı ağırlıkları olarak saklar. Bu ağırlık değerleri yapay sinir ağlarının verileri başarılı bir şekilde işleyebilmesi için gerekli olan bilgileri içerir [14].

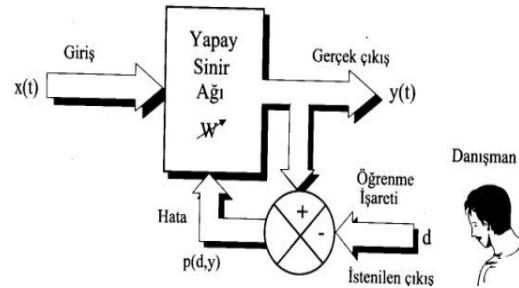
Yapay sinir ağları gibi öğrenme yöntemleri örneklerden öğrenmeye dayanmaktadır. Örneklerden öğrenmenin temel felsefesi bir olay hakkındaki gerçekleşmiş örnekleri kullanarak olayın girdi ve çıktıları arasındaki ilişkileri öğrenmek ve bu ilişkilere göre daha sonra oluşacak olan yeni örneklerin çıktılarını belirlemektir. Burada bir olay ile ilgili örneklerin girdi ve çıktıları arasındaki ilişkinin olayın genelini temsil edecek bilgiler içerdiği kabul edilmektedir. Değişik örneklerin olayı değişik açılardan temsil ettiği varsayılmaktadır. Farklı örnekler kullanarak böylece olay değişik açılardan öğrenilmektedir. Burada bilgisayara sadece örnekler gösterilmektedir. Bunlardan başka herhangi bir ön bilgi verilmemektedir. Öğrenmeyi gerçekleştirecek sistem

aradaki ilişkiyi kendi algoritmasını kullanarak keşfetmektedir [5].

Yapay sinir ağlarının öğrenmesi için iki yaklaşım bulunmaktadır; danışmanlı (supervised) ve danışmansız (unsupervised) öğrenmedir.

Yapay sinir ağlarında en fazla kullanılan öğrenme metodu olan danışmanlı öğrenmede, yapay sinir ağına örnek olarak bir çıktı (beklenen çıktı) verilir ve bu çıktıyla ağı ürettiği çıktı karşılaştırılır. İki çıktı arasındaki fark hata olarak alınır. Başlangıçta genellikle rassal olarak verilen ağırlıklar ağ tarafından hata minimize edilene kadar döngüler halinde değiştirilir [7].

Danışmanlı öğrenmede, yapay sinir ağı kullanılmadan önce eğitilmelidir. Eğitim işlemi, sinir ağına giriş ve çıkış bilgileri sunmaktan oluşur. Bu bilgiler genellikle eğitim kümesi olarak tanımlanır. Yani, her bir giriş kümesi için çıkış kümesi ağı sağlanmalıdır [15].



Şekil 4: Danışmanlı Öğrenme Yapısı [11]

Şekil 4’de danışmanlı öğrenme yapısı gösterilmektedir. Bu öğrenme yönteminde öğrenmeye dışarıdan müdahale eden bir öğretmen, danışman vardır. Öğrenme danışmanın kontrolindedir. Danışman, eğitim kümesini ve hata değerini belirleyerek eğitimin ne kadar devam edeceğine karar verir. Bu yöntemin en önemli özelliği eğitim esnasında gerçek giriş, çıkış değerlerin kullanılmasıdır. Danışmanlı öğrenme kuralları şunlardır: [14]

1. Algılayıcı (Perceptron) Öğrenme Kuralı
2. Delta Öğrenme Kuralı
3. Genişletilmiş Delta Öğrenme Kuralı
4. Geri Yayılımlı Öğrenme Kuralı

Uygulamada geri yayılımlı öğrenme kuralını kullanacağımızdan burada danışmanlı öğrenme kurallarından sadece geri yayılımlı öğrenme kuralından bahsetmenin daha yararlı olacağı düşünülmektedir.

Yapay sinir ağlarının istenilen giriş-çıkış karakteristiğini ne kadar sağladığının bir ölçüsü olarak, yapay sinir ağının çıkış katmanındaki her sinirine ait hata sinyallerinin karelerinin toplamından oluşan bir uygunluk fonksiyonu tanımlanmıştır. Eğitimin k’inci iterasyonunda yapay sinir ağının çıkış katmanındaki i’inci sinirinin çıkış değeri y_i , bu sinirden vermesi istenilen değer d_i ile gösterilirse, i sinirinin hata sinyali:

$$e_i = d_i - y_i(k) \quad (2.1)$$

olarak elde edilir. Uygunluk fonksiyonu ise

$$E = \frac{1}{2} \sum_i e_i^2 = \frac{1}{2} \sum_i (d_i - y_i(k))^2 \quad (2.2)$$

denklemler ile ifade edilmektedir. Geri yayılım algoritmasının amacı uygunluk fonksiyonunu minimum yapmaktır. Uygunluk fonksiyonu yapay sinir ağının ağırlık değerlerine bağlı olduğundan, algoritma yapay sinir ağının ağırlıklarının en uygun biçimde değiştirilmesi işlemlerinden oluşmaktadır. Yapay sinir ağındaki her w_{ij} ağırlık değerinin değişme miktarı gradyan-azalma (gradient-descend) yöntemi olarak adlandırılan

$$\Delta w_{ij} = -\eta \frac{\partial E(w)}{\partial w_{ij}} \quad (2.3)$$

denkleminde yola çıkarak bulunmaktadır. Buradan öğrenme katsayısıdır.

Geri yayılım algoritmasında her iterasyon, ileri yayılım ve geri yayılım olmak üzere iki aşamadan oluşmaktadır. İleri yayılım aşamasında yapay sinir ağının o andaki durumunda yapay sinir ağına uygulanan giriş sinyallerine karşı yapay sinir ağının çıkışlarında oluşan hatalardan yola çıkılarak, devredeki ağırlıkların yeniden düzenlenmesi yapılmaktadır. Yapay sinir ağındaki her ağırlık değişimi

$$\Delta w_{ij} = \eta \delta_j y_i \quad (2.4)$$

denklemler ile yapılmaktadır. δ_j , çıkış katmanı sinirleri için

$$\delta_j = e_j(k) f'_j \quad (2.5)$$

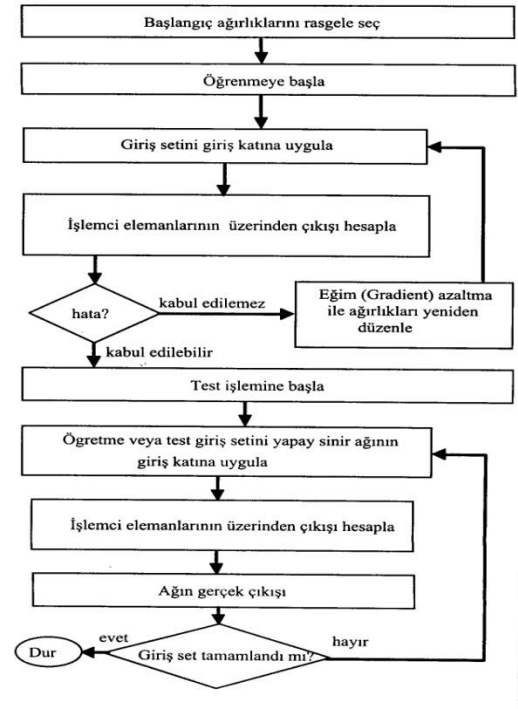
gizli katmanlarda bulunan sinirler için,

$$\delta_j = f'_j \sum_m \delta_m w_{mj} \quad (2.6)$$

olarak tanımlanmıştır. f_j , j sinirinin aktivasyon fonksiyonudur. Bu tanımlar ile hata sinyallerinin devrenin çıkışından girişine doğru akışı, ileri yayılım aşamasında sinyallerin ileri doğru akışına benzetilmektedir [16].

Geri yayılım algoritmasının daha iyi anlaşılması için, ağırlık öğrenme aşamasının akış şeması Şekil 5'de gösterilmiştir. Ağırlık eğitilmesinin sağlıklı bir şekilde gerçekleştirilebilmesi için başlangıçta rastgele olarak atanan bağlantı ağırlıkları çok önemlidir. Rastgele olarak atanan bağlantı ağırlıkları eğitime hangi noktadan başlayacağımızı belirlemektedir. Başlanan bu noktanın gerçek çözüme çok yakın veya uzak bir nokta olması tamamen başta belirleyeceğimiz değerlere bağlıdır. Yapay sinir ağlarında önemli noktalardan biri eğitimin ne kadar sürdürüleceğine karar verilmesidir. Eğitim işleminin tamamlanması için iki seçenek mevcuttur. Bunlardan ilki

belli bir miktardaki hata toleransını göze almak, o hata değerinden daha düşük hata değerine ulaşmaya kadar eğitimi sürdürmektir. Dolayısıyla bu durumda eğitim sayısından ziyade hata miktarı önemlidir. Burada hata toleransının makul sınırlar içerisinde olması gerekmektedir. Diğer seçenek sabit bir eğitim sayısının seçilmesidir. Burada eğitici belirlenen eğitim sayısı sonucunda elde edilecek olan hatayı kabul etmektedir. [11].



Şekil 5: Bir Ağda Geri Yayılımlı Öğrenme Algoritmasının Uygulanması [11]

Eğitim esnasında hata değerinin daima azalması beklenmemelidir. Bazen hatanın arttığı da gözlenebilir. Bu genellikle çözümden uzaklaştığımızın belirtisidir. Hata yüzeyi üzerinde yerel bir en küçük noktaya ulaşılmış iken eğitime devam edilirse, yerel en küçükten kurtuluncaya kadar hata değeri belli bir miktar artar. Daha sonra diğer bir en küçüğe doğru ilerlediğinde hata değeri yeniden azalmaya başlar. Bununla birlikte hata değerinin hiç azalmadan artması da o noktanın genel bir en küçük nokta olduğunun göstergesidir. Tüm bunlara rağmen çözüm esnasında hata yüzeyi hakkında bilgimiz olmadığı için ulaşılan noktanın yerel mi, yoksa genel bir en küçük nokta mı olduğuna karar vermek zordur. Bu yüzden yapılan birçok çalışmada, hata değerinin artmaya başladığı anda eğitime işleme son verilir [14].

YSA eğitimindeki diğer önemli bir parametre de öğrenme katsayısının, η , seçilmesidir. Bu katsayı bağlantı ağırlıklarındaki değişme miktarını kontrol eder. Verimli bir öğrenmenin seçilmesi için öğrenme katsayısının uygun seçilmesi önemlidir. Eşitliklerde kullanılan η değeri, her zaman pozitif ve birden küçük değerler almalıdır. Eğitim

için kullanılan örnekler birbirine çok benzer ise geniş η değerleri kullanılabilir ve böylece eğitim fazla zaman almaz (0,8 veya 0,9 gibi). Eğer kullanılan örnekler yeterince iyi değilse, gürültüden doğacak tehlikelerden sakınmak için η değeri 0,2-0,1 arasında tutulmalıdır. Örnekler hakkında bilgi yoksa, ortalama değer alınmalıdır [15].

Danışmansız öğrenme metodu ise, yapay sinir ağlarında sürekli araştırılan ve gelişen bir öğrenme metodudur. Bu metod, gelecekte bilgisayarların insan yardımı olmadan öğrenebileceklerinin göstergesidir. Ancak günümüzde sınırlı kullanım alanları bulan ve hala yoğun araştırma konusu olan bir öğrenme metodudur [7].

III. ÖNGÖRÜMLEME TEKNİKLERİ

Geleceği öngörümleme sosyo-ekonomik gelişmenin vazgeçilmez bir unsurudur. Karar verme durumunda olan bütün özel veya kamu kuruluşlarının gelecek zamanda durumlarını muhafaza etmeleri ve geliştirebilmeleri, gelecekteki olayları öngörümleyebilmeleri ve iyi bir plan çerçevesinde uygun çözümler bulmaları ile mümkündür[17].

Öngörümleme teknikleri, literatürde farklı şekillerde sınıflandırılmış olmakla beraber temelde iki grupta ele alınmaktadır [18][19]:

1. Nitel (kalitatif) Yöntemler,
2. Nicel (kantitatif) Yöntemler.

Genel olarak nicel yaklaşımların girdisi, çeşitli zaman aralıklarında toplanmış olan verilerdir. Verilerin iyi bir şekilde analiz edilmesi, bu yöntemlerin temelini oluşturmaktadır. Buna karşılık nitel yaklaşımlar, konu ile ilgili uzmanların bilgi ve deneyimlerinden yararlanarak bu alandaki gelişmelerin ne yönde olacağı, ne tür ihtiyaçlar ortaya çıkaracağı gibi konularda yoğunlaşmaktadır [20]. Uygulamada ileriye dönük öngörümlemelerde nicel ve nitel yöntemlerin bir arada kullanıldığı da görülmektedir. Nicel yöntemlerle elde edilen öngörümleme sonuçları tarafsız ve deneyimli uzmanların görüşleri ışığında değerlendirilerek kullanılabilir [21].

Öngörümleme ekonomik değişkenin geçmiş dönemlerde gerçekleşen sayısal değerleri esas alınarak, bir takım matematik ve istatistik kurullarla gelecekteki değerlerine bir yaklaşımda bulunmaya çalışan tüm öngörümleme teknikleri, nicel öngörümleme tekniği sınıfına girer. Bu yöntemlerin hepsinde, ele alınan veri setinin belirli bir sisteme göre geliştiği ve ayrıca sistemin yapısında tesadüfi unsurların da mevcut olduğu varsayımından hareket edilir [22]. Nicel öngörümleme teknikleri genel olarak iki gruba ayrılmaktadır: [23][24]

1. İlişkiye Dayalı (Nedensel) Yöntemler,
2. Zaman Serisi Analizleri.

Araştırmada esas alınan öngörümleme tekniği, nicel öngörümleme yöntemlerinden zaman serisi analizleri olduğundan, kısaca ilişkiye dayalı

yöntemlerden bahsedilerek zaman serisi analizleri yöntemleri daha kapsamlı olarak ele alınacaktır.

III.1. Zaman Serileri Analizi

Zaman serisi, zaman sırasına konmuş gözlem değerleri kümesi olarak tanımlanabilir. Zaman serisinde ilgilenilen özellik bir değişkendir. Bu değişken zaman içerisinde çeşitli nedenlere bağlı olarak farklı değerler alır. Dolayısıyla zaman serisi, zaman sırasına konmuş değişken değer kümesi olarak ifade edilebilir. Başka bir ifadeyle, gözlemlerin belirli bir dönem için gün, hafta, ay, üç ay, yıl gibi birbirini izleyen eşit aralıklarla yapılması ile elde edilen seriler zaman serileri olarak adlandırılmaktadır ve incelenen zaman serisi Y_t ile simgelendiğinde gözlemler de $t=1,2,\dots,T$ olmak üzere Y_1, Y_2, \dots, Y_t şeklinde gösterilebilir [25].

Zaman serileri analizinde, öngörümleme değişkene ilişkin veriler belirli bir veri seyri elde etmek üzere analiz edilmektedir. Bu nedenle öngörümleme sadece geçmiş verilerin bu amaçla analiz edilmesine ve yapılacak tahminlerde kullanılmasına dayanmaktadır. Bu özelliğinden dolayı zaman serileri analizi, değişmeyen koşullar altında daha etkin olmaktadır [26].

Zaman serileri analizinde literatürde yer alan bir çok yöntem bulunmaktadır. Bunlardan bazıları mekanik tahmin yöntemleri, hareketli ortalamalar yöntemi, üstel düzleştirme yöntemleri ve Box-Jenkins modelleridir. Bu alt bölümde Box-Jenkins metodolojisine değinilecektir.

III.1.1. Box-Jenkins Metodolojisi

Zaman serileri kesikli, doğrusal ve stokastik süreç içeriyorsa Box-Jenkins veya ARIMA modeli olarak adlandırılır. Anılan modeller doğrusal filtreleme modelleri olarak da bilinmektedir. Otoregresif (AR-Auto-Regressive), hareketli ortalama (MA-Moving Average), AR ve MA modellerinin karışımı olan Otoregresif Hareketli Ortalama (ARMA-Auto Regressive Moving Average) modelleri en genel doğrusal durağan Box-Jenkins modelleridir. Durağan olmayıp fark alma işlemi sonucunda durağanlaştırılan serilere uygulanan modellere Birleştirilmiş Otoregresif Hareketli Ortalama (ARIMA-Auto Regressive Integrated Moving Average) modeli adı verilir. ARIMA modeli Box-Jenkins tekniği olarakta adlandırılır. Box-Jenkins modellerinde amaç; zaman serisine en iyi uyan, en az parametre içeren doğrusal modelin belirlenmesidir [27].

Box ve Jenkins'e göre zaman serileri durağan veya bazı dönüşümlerle durağan hale dönüştürülebilen kesikli stokastik bir süreç olarak düşünülebilir. Box-Jenkins yönteminin kullanılabilmesi için, bir zaman serisinin ya durağan olması, ya da farkı alındığında durağanlaşması gerekir. Box-Jenkins'in amacı, örneklem verilerini türettiği düşünülebilecek bir istatistik modelini belirlemek ve tahmin etmektir. Tahmin edilen bu model kestirim için kullanılacaksa, modelin özellikleri zaman içinde, özellikle

de gelecek dönemlerde değişmemelidir. Yani durağan veri gereksiniminin basit nedeni, buverilerden çıkarsanan herhangi bir modelin de durağan ya da kararlı olabilmesi, dolayısıyla da kestirim için geçerli bir temel sağlayabilmesi gerektirir [28].

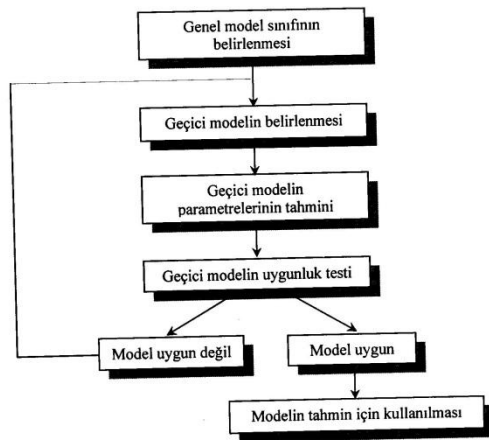
Box-Jenkins yöntemi, tüm model kombinasyonları arasından uygun bir modeli belirlemek için dört basamaktan oluşan tekrarlamalı bir yaklaşım kullanmaktadır. Bu basamaklar sırasıyla; belirleme, parametre tahminleri, uygunluk testleri ve ileriye yönelik öngörü aşamalarıdır. Belirlenen model yeterli değilse, süreç orjinal modeli geliştirmek için oluşturulan bir model kullanılarak tekrarlanır [29]. Bu aşamalar Şekil 6'da gösterilmiştir.

Model belirleme aşamasında, zaman serisinin otokovaryans, otokorelasyon ve kısmi otokorelasyon fonksiyonlarına başvurulur. Bu fonksiyonlar, sürecin AR(p), MA(q), ARMA(p,q) veya ARIMA(p,d,q) modellerinden hangisine uyduğunun tespitinde önemlidir [30].

Genel olarak OKF ve KOKF'ların seyrine bakılarak Box-Jenkins modelleri ile ilgili bilgi edinilmelidir ve bu bilgiler Tablo 1'de verilmektedir [31].

Tablo 1: AR, MA ve ARMA Modelleri için OKF ve KOKF'larının Seyri [31]

MODEL	OKF	KOKF
MA(q)	q gecikme sonrası keser.	Üstel olarak veya sinüs dalgaları şeklinde azalır.
AR(p)	Üstel olarak veya sinüs dalgaları şeklinde azalır.	p gecikme sonrası keser.
ARMA(p,q)	Üstel olarak veya sinüs dalgaları şeklinde azalır. p gecikme sonrası keser.	Üstel olarak veya sinüs dalgaları şeklinde azalır. q gecikme sonrası keser.



Şekil 6: Box-Jenkins Yöntemiyle Model Belirleme Aşamaları [32]

III.1.1.1. AR(p) Modelleri

Bir serinin cari değerlerinin geçmiş dönemlerdeki değerleri ile arasındaki doğrusal bağlantı doğru belirlendiğinde, sistemin kalıntıları rassal değişken özelliği taşıyacaktır. Bunu sağlayacak süreç ise “otoregresif” süreç olarak adlandırılmaktadır. Bu bağlamda p’inci mertebeden otoregresif modelde; AR(p) zaman serisi değişkeninin içinde bulunduğu dönemdeki (cari) değeri, serinin p dönem geçmiş değerlerinin ağırlıklı toplamına artı rassal hata terimine bağlı olarak açıklanmaktadır. Genel olarak;

$$y_t = \phi_1 y_{t-1} + \phi_2 y_{t-2} + \dots + \phi_p y_{t-p} + e_t \quad (3.1)$$

veya

$$y_t - \phi_1 y_{t-1} - \phi_2 y_{t-2} - \dots - \phi_p y_{t-p} = e_t \quad (3.2)$$

şeklinde ifade edilen süreç, p’inci mertebeden otoregresif süreç olarak adlandırılmaktadır. Bu denklemde;

y_t = Trend etkisi kaldırılmış seriyi,

p = Otoregresif sürecin mertebesini (serinin geçmiş değerlerinin sayısı),

ϕ = Bugünkü dönem ile geçmiş dönem değerleri arasındaki ilişkiyi gösteren ilişki katsayıları (ağırlıklar),

e_t = Model tarafından açıklanamayan hata terimini göstermektedir.

(3.1) ve (3.2) nolu denklemlerde e_t ile simgelenen hata terimi; sıfır ortalama ile sabit varyansa ve bağımsız, rassal sürece (white noise) sahiptir. Ayrıca, e_t ’ler, y_{t-p} ’lerden bağımsız olup herhangi bir dönemdeki hata ile arasında ilişki söz konusu değildir. δ ile simgelenen yığılım parametresine sahip AR(p) süreci;

$$y_t = \phi_1 y_{t-1} + \phi_2 y_{t-2} + \dots + \phi_p y_{t-p} + \delta + e_t \quad (3.3)$$

veya

$$y_t - \phi_1 y_{t-1} - \phi_2 y_{t-2} - \dots - \phi_p y_{t-p} - \delta = e_t \quad (3.4)$$

şeklinde ifade edilmektedir. δ , stokastik sürecin ortalaması ile ilgili sabittir ve “yığılım parametresi” olarak adlandırılmaktadır. Modele sabitin katılması ise, serinin sıfırdan farklı olmasına izin verilmesi şeklinde ifade edilir. (3.3) ve (3.4) nolu denklemlerde $\delta, \sigma_e^2, \phi_1, \phi_2, \phi_3, \dots, \phi_p$ olacak şekilde (p+2) tane; (3.1) ve (3.2) nolu denklemlerde ise, $\sigma_e^2, \phi_1, \phi_2, \phi_3, \dots, \phi_p$ olacak şekilde (p+1) tane bilinmeyen parametre vardır ve bu değerler verilerden tahmin edilmektedirler. σ_e^2 , “white noise” süreci özelliği taşıyan e_t ’nin varyansını simgelemektedir.

AR(p) süreci, $BY_t = Y_{t-1}, B^2 Y_t = Y_{t-2}$ olarak işleyen geri kaydırma işlemcisi: B kullanıldığında ($\delta = 0$ varsayımı ile)

$$1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p y_t = e_t \quad (3.5)$$

veya kısaca

$$\phi(B)y_t = e_t \quad (3.6)$$

olarak gösterilebilir. p'inci mertebeden AR işlemcisi olan $\phi(B)$ 'nin açılımı ise,

$$\phi(B) = 1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p \quad (3.7)$$

olarak yapılmaktadır [31].

III.1.1.2. MA(q) Modelleri

Hareketli ortalama MA(q) süreci bir zaman serisinin t dönemdeki değerini, rastgele bir değişken olan kalıntı (hata) payının cari ve geçmiş dönem değerlerinin ağırlıklı ortalaması ile ifade eden bir süreçtir ve aşağıdaki gibi gösterilir:

$$Y_{t+1} = e_{t+1} + \theta e_t \quad (3.8)$$

Denklem (3.8)'deki istatistik model bir hareketli ortalama sürecidir. Genelde bir hareketli ortalama süreci, 1,2 veya daha fazla dönem geriye doğru rastgele kalıntıların e_t ağırlıklı bir ortalaması olarak ekonomik değişkeny_t'ye ait zaman serisi gözlemlerini gösterir.

Genel bir MA(q) süreci için istatistiksel model aşağıdaki gibidir:

$$y_t = \mu + e_t + \theta_1 e_{t-1} + \theta_2 e_{t-2} + \dots + \theta_q e_{t-q} \quad (3.9)$$

Burada korelasyonsuz rastgele kalıntılar e_t ortalaması sıfır ve sabit bir varyansa sahiptir, $\theta_i (i=1,2,\dots,q)$ bilinmeyen parametrelerdir. Denklem (3.9)'a dikkat edilirse AR(p) modelinden farklı olarak "yığılım" parametresi, δ yerine μ ile gösterilmiştir. Bu tanımlamaya göre MA(q) sürecinin ortalaması aşağıdaki gibi gösterilir:

$$E(y_t) = \mu \quad (3.10)$$

Varyansı ise denklem (3.11)'deki gibi yazılır:

$$\begin{aligned} var y_t &= \gamma_0 \\ &= E (y_t - \mu)^2 \\ &= E (e_t^2 + \theta_1^2 e_{t-1}^2 + \dots + \theta_q^2 e_{t-q}^2 + 2\theta_1 \theta_2 e_{t-1} e_{t-2} + \dots \\ &= \sigma_e^2 + \theta_1^2 \sigma_e^2 + \dots + \theta_q^2 \sigma_e^2 \\ &= \sigma_e^2 (1 + \theta_1^2 + \dots + \theta_q^2) \end{aligned} \quad (3.11)$$

Bütün çarpaz çarpım terimlerinin beklenen değerleri sıfırdır. Çünkü rastgele kalıntılar e_t bağımsız ve korelasyonsuz olarak varsayılmaktadır [33].

Denklem (3.9) geri kaydırma işlemcisi: B kullanıldığında ise, $\mu = 0$ olması halinde

$$y_t = (1 - \theta_1 B - \theta_2 B^2 - \theta_3 B^3 - \dots - \theta_q B^q) e_t \quad (3.12)$$

veya kısaca

$$y_t = \theta(B) e_t \quad (3.13)$$

olarak ifade edilmektedir. MA(q) işlemcisi olarak adlandırılan $\theta(B)$, B işlemcisinin polinomial fonksiyonudur ve açılımı

$$\theta(B) = (\theta_0 - \theta_1 B - \theta_2 B^2 - \theta_3 B^3 - \dots - \theta_q B^q) \quad (3.14)$$

olarak yapılmaktadır. θ_0 , genellikle $\theta_0 = 1$ olarak alınmaktadır. Box ve Jenkins MA sürecini, "y_t çıktısı, e_t girdi iken $\theta(B)$ transfer fonksiyonunun doğrusal filtreden geçmesi ile elde edilmektedir" ifadesi ile tanımlamaktadır [31].

III.1.1.3. ARMA(p,q) Modelleri

Zaman serisi modellerinde esneklik sağlamak için en az sayıda parametre kullanma ilkesini gerçekleştirmek amacıyla bazı hallerde modele hem otoregresif hem de hareketli ortalama parametrelerinin alınması birçok fayda sağlamaktadır. Bu düşünce ARMA(p,q) modelini ortaya çıkarmıştır [34].

ARMA modelleri en genel durağan stokastik süreç modelleri olup, geçmiş gözlemlerin ve geçmiş hata terimlerinin doğrusal bir fonksiyonudur. ARMA(p,q) modelleri genel olarak aşağıdaki gibi gösterilir:

$$y_t = \phi_1 y_{t-1} + \dots + \phi_p y_{t-p} + \delta - \theta_1 e_{t-1} - \theta_2 e_{t-2} - \dots - \theta_q e_{t-q} \quad (3.15)$$

Yığılım parametresinin olmaması durumunda, $\delta = 0$ varsayımıyla Denklem (3.15) şu şekilde yazılır:

$$y_t = \phi_1 y_{t-1} + \phi_2 y_{t-2} + \dots + \phi_p y_{t-p} + e_t - \theta_1 e_{t-1} - \theta_2 e_{t-2} - \dots - \theta_q e_{t-q} \quad (3.16)$$

Denklem (3.15)'de, $y_{t-1}, y_{t-2}, \dots, y_{t-p}$ geçmiş gözlem değerlerini, $\phi_1, \phi_2, \dots, \phi_p$ geçmiş gözlem değerleri için katsayıları, δ yığılım parametresini, $e_t, e_{t-1}, e_{t-2}, \dots, e_{t-q}$ hata terimlerini ve $\theta_1, \theta_2, \dots, \theta_q$ hata terimleri ile ilgili katsayıları temsil etmektedir [35].

Süreç, geri kaydırma işlemcisi: B ile ($\delta = 0$ hali için)

$$\begin{aligned} (1 - \phi_1 B - \phi_2 B^2 - \phi_3 B^3 - \dots - \phi_p B^p) y_t &= \\ (1 - \theta_1 B - \theta_2 B^2 - \theta_3 B^3 - \dots - \theta_q B^q) e_t & \end{aligned} \quad (3.17)$$

ve kısaca

$$\phi(B) y_t = \theta(B) e_t \quad (3.18)$$

olarak gösterilebilir. ARMA(p,q) sürecinde (3.15) nolu denklemde $\delta \neq 0$ varsayımı ile $[p+q+2]$ bilinmeyen söz konusu olup verilerden tahmin edilmektedirler. ARMA modellerinde, p ve q mertebeleri ile ilgili olarak, $p \leq 2$ ve $q \geq 2$ olmasının seriyi yeteri kadar açıklayacağı ifade edilmektedir, ayrıca p ve q mertebelerinin aynı olması da gerekli değildir [31].

III.1.1.4. ARIMA (p,d,q) Modelleri

Durağan olmayıp farkı alınarak durağan hale getirilmiş serilere uygulanan modellere “durağan olmayan doğrusal stokastik modeller” veya “kısaca entegre modeller” denir. Bu entegre modeller belirli sayıda fark alınmış serilere uygulanan AR ve MA modellerinin birleşimidir. Eğer AR modelinin derecesi p, MA modelin derecesi q ve serinin de d kez farkı alınmışsa bu modele (p,d,q) dereceden “Otoregresif Entegre Hareketli Ortalama” modeli denir ve ARIMA(p,d,q) şeklinde gösterilir [30].

ARIMA(p,d,q) şeklinde gösterilen otoregresif bütüleşik (entegre) hareketli ortalama modelinin genel ifadesi,

$$w_t = \phi_1 w_{t-1} + \phi_2 w_{t-2} + \dots + \phi_p w_{t-p} + e_t - \theta_1 e_{t-1} - \theta_2 e_{t-2} - \dots - \theta_q e_{t-q} \quad (3.19)$$

eşitliği ile verilir.

Denklem (3.19)'daki model, ARMA(p,q) modelindeki y_t teriminin yerine w_t teriminin yazılmış halidir. Bu durum, durağan olmayan y_t sürecinin d derece farkı alınarak durağanlaştırılması sonucu w_t sürecinin elde edilmesinden kaynaklanmaktadır.

$$w_t = \Delta^d y_t \quad (3.20)$$

eşitliğinde,

w_t = fark alma sonucu oluşan seriyi

Δ = fark alma işlemcisini

d = fark alma derecesini

göstermektedir. birinci farklar serisi durağan ise,

$$\Delta y_t = w_t = y_t - y_{t-1} = (1-B)y_t \quad (3.21)$$

eşitliği yazılabilir. Benzer şekilde serinin durağan hale gelmesi için d defa fark alınmışsa,

$$\Delta^d y_t = w_t = (1-B)^d y_t \quad (3.22)$$

ifadesi yazılabilir. ARIMA(p,d,q) modelinin orjinal veri cinsinden genel gösterimi, $\delta \neq 0$ varsayımı ile


$$\Delta^d y_t = \delta + \gamma_1 \Delta^d y_{t-1} + \gamma_2 \Delta^d y_{t-2} + \dots + \gamma_p \Delta^d y_{t-p} + e_t - \theta_1 e_{t-1} - \dots - \theta_q e_{t-q} \quad (3.23)$$

olacak şekilde yapılmaktadır. İncelenen y_t serisinin durağan olmaması nedeni ile yapılan (3.20) nolu dönüşümle serinin durağanlığı sağlanmakta ve ardından (3.19) nolu denklemle gösterilmektedir.

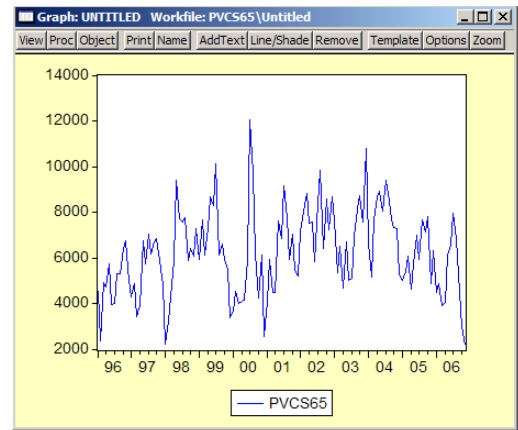
Bütünleşik ARMA modelleri olarak adlandırılan ARIMA modelleri, durağan olmayan serilerin durağan olana kadar kaç defa farklarının alındığını gösteren d derecesine, AR terim sayısı p ve MA terim sayısı q'nun ilave edilmesi ile belirlenmektedir [31].

IV. UYGULAMA


Araştırmada ele alınan şirketin satış sorumlusu ile yapılan görüşmeler sonucunda ilgili şirkette toplam 15 adet ürün satışı yapıldığı bilgisi alınmıştır. Her bir ana ürün kendi içerisinde yan ürünlere ayrılmaktadır. Çalışmamızda bu ana ürünler içerisinde rastgele olarak üç ürünün 10 yıllık satış rakamları ton bazında ele alınmıştır. Çalışmamızda kullanılan PVC S39, PVC S 65, ve PTA isimli ürünlerin “EViews 5” paket programı kullanılarak çizilen zaman yolu grafikleri aşağıdaki gösterilmektedir.



Şekil 7: PVC S 39 Ürünün Zaman Yolu Grafiği



Şekil 8: PVC S 65 Ürünün Zaman Yolu Grafiği



Şekil 9: PTA Ürünün Zaman Yolu Grafiği

IV.1. Box-Jenkins Metodolojisi ile Satış Öngörümlemesi

Çalışmanın bu bölümünde her bir ürünün ayrı ayrı bir önceki bölümde sözü edilen Box-Jenkins metodolojisi ile öngörümlemesi yapılmıştır. Üç ürüne ait aylık satış rakamlarının Box-Jenkins metodolojisine göre öngörümlemesi yapılırken “EViews 5” paket programından yararlanılmıştır.

Tablo 2: Tüm Ürünlerin ADF Birim Kök Test Sonuçları

Ürünler	ADF Birim Kök Test Sonuçları		
		Kesmeli	Kesmeli ve Trend
PVC S 39	ADF Test İstatistiği	-5,051346	-5,627979
	Test Kritik Değerleri		
	1% level	-3,481217	-4,030157
	5% level	-2,883753	-3,444756
	10% level	-2,578694	-3,147221
PVC S 65	ADF Test İstatistiği	-5,678521	-5,673144
	Test Kritik Değerleri		
	1% level	-3,481217	-4,030157
	5% level	-2,883753	-3,444756
	10% level	-2,578694	-3,147221
PTA	ADF Test İstatistiği	-7,804964	-8,150338
	Test Kritik Değerleri		
	1% level	-3,481217	-4,030157
	5% level	-2,883753	-3,444756
	10% level	-2,578694	-3,147221

Box-Jenkins yöntemin uygulanabilmesi, zaman serisinin hem ortalamada hem de varyansta durağan olması gerektiği için ilk aşamada serinin durağan olup olmadığına karar vermek gerekmektedir. Bunun için de öncelikle ürünlerin otokorelasyon ve kısmi otokorelasyon fonksiyonlarını gösteren korelogram grafikleri çizilmiştir.

Durağanlığı sınamanın bir başka yolu “Birim Kök (Unit Root)” testleridir. Literatürde birçok birim kök testi yer almaktadır. Elder ve Kennedy’e göre “Genişletilmiş (Augmented) Dickey-Fuller” birim kök

testi literatürde var olan testler arasında en yaygın olarak kullanılanıdır [36]. Bu nedenle ilgili ürünün OKF ve KOKF grafikleri çizildikten sonra, zaman serilerinin durağanlığının sınanması için ADF birim kök testi uygulanmıştır. Çalışmamızda ele alınan ürünleri için yapılan ADF birim kök testi sonuçları aşağıda verilmiştir.

Tüm ürünlerin ADF Birim Kök Test sonuçlarına bakıldığında, ilgili ürünlerin zaman serilerinin durağan olduğu görülmektedir. İlgili ürünlere ait Box-Jenkins modelinin belirlenmesinde, otokorelasyon ve kısmi otokorelasyon fonksiyonlarının grafiklerine bakılır. Model belirleme aşamasında, sadece OKF ve KOKF grafiklerine bakılması ileri düzey AR(p), MA(q) ve özellikle ARMA(p,q) süreçlerinin belirlenmesinde yeterli olmadığından ötürü korelogramların yanında bazı model seçme kriterleri kullanılmaktadır. Akmut vd.’e göre en yaygın kullanılan model seçim kriterleri “Akaike Bilgi Kriteri” (Akaike Information Criterion – AIC) ve “Schwartz Bayes Kriteri” (Schwartz Bayesian Criterion – SBC) dir [37]. İlgili ürünlerin AIC değerlerine bakıldıktan sonra en küçük AIC değerine sahip olan model en uygun model olarak seçilmiş ve bulunan Box-Jenkins modeline göre öngörümlemeleri yapılmıştır.

Tablo 3: Tüm Ürünlerin En Uygun Box-Jenkins Modelleri, AIC Değerleri ve Model Denklemleri

Ürünler	En Uygun Box-Jenkins Modeli	AIC Değeri	Modelin Denklemi
PVCS 39	AR(1)	15,870	$y_t = 814,8131 + 0,6666 y_{t-1}$
PVC S 65	AR(1)	17,504	$y_t = 2607,895 + 0,582025 y_{t-1}$
PTA	AR(1)	17,835	$y_t = 3178,298 + 0,338054 y_{t-1}$

IV.2. Yapay Sinir Ağları İle Satış Öngörümlemesi

Zaman serileri ile öngörümlemede bulunabilmek için bilinen ve en yaygın kullanılan istatistik yöntemlerin en kapsamlısı Box-Jenkins modelleridir. Otoregresif (AR), Hareketli Ortalama (MA), Otoregresif-Hareketli Ortalama (ARMA) ve Bütünleşik Otoregresif-Hareketli Ortalama (ARIMA), Box-Jenkins öngörümleme modelleridir. Box-Jenkins metodolojisi; kesikli, doğrusal stokastik süreçlere dayanır. Ancak gerçek hayata ilişkin seriler genellikle doğrusal değildir. Bu sebeple doğrusal olmayan zaman serilerini modellemede farklı tekniklere ihtiyaç vardır. Son 25 yıldır Bilinear Model, Threshold Autoregressive Model (TAR), Autoregressive Conditional Heterocedastic (ARCH) Model gibi bir çok doğrusal olmayan zaman serisi modeli geliştirilmiştir. Bu modeller doğrusal modellere göre daha başarılı iseler de, uygulaması zor, probleme özgü ve genelleştirmeden uzak modellerdir. Önerilen bu modeller, veriler arasındaki

ilişkinin net olduğu ve bu ilişkiye ait bilginin bilindiği durumda geçerlidir. Ayrıca bu modellerden herhangi biri, veri kümesinde saklı bütün doğrusal olmayan yapıyı ortaya çıkarmada başarılı değildir.

1980'li yılların sonlarından itibaren zaman serileri öngörülmesinde kullanılmakta olan önemli yöntemlerden biri de yapay sinir ağları (YSA) tekniğidir. YSA, girdi ve çıktı değişkenleri arasındaki herhangi bir ön bilgiye ve varsayıma ihtiyaç duymadan gerekli modellemeyi sağlayabilmektedir. Bu sebeple YSA, öngörülme aracı olarak diğer yöntemlere göre daha fazla avantaja sahiptir ve daha başarılı sonuçlar ortaya koyabilmektedir. Literatürde YSA'nın zaman serileri öngörülmesinde kullanımına yönelik bir çok çalışma yapılmıştır.

Zaman serileri geleceği öngörülme, tek dönemli veya çok dönemli olabilir. Çok dönemli öngörülmede bulunurken, YSA iki farklı yaklaşımı kullanabilmektedir. Bunlardan birincisi, Box-Jenkins modellerindeki gibi tek dönemli iteratif öngörülmedir. Diğerisi ise, birden fazla dönemin aynı anda öngörülmesinin yapıldığı direkt metot olarak adlandırılan durumdur. Çalışmamızda YSA ile öngörülme yapılırken "MATLAB 7" paket programı kullanılarak iteratif yaklaşım benimsenmiştir. Oluşturulan YSA modelinde öğrenme algoritması olarak, literatürde var olan çalışmalar içerisinde en fazla kullanılan Geri Yayılım (Back-Propagation) Levenberg-Marquardt öğrenme algoritması kullanılmıştır.

IV.2.1. Geliştirilen YSA'da Levenberg-Marquardt Öğrenme Metodu

Temel olarak, bu algoritma maksimum komşuluk fikri üzerine kurulmuş bir en az kareler hesaplama metodudur. Bu metod, diğer öğrenme algoritmalarının en iyi özelliklerinden oluşur ve diğer metodların kısıtlarını ortadan kaldırır. Genel olarak, bu metod yavaş yakınsama problemlerinden etkilenmez.

$E(w)$ 'nin bir amaç hata fonksiyonu olduğu

düşünülürse m tane hata terimi için $e_i^2(w)$ aşağıda verilmiştir.

$$E(w) = \sum_{i=1}^m e_i^2(w) = \left\| f(w) \right\|^2 \quad (4.1)$$

$$e_i^2(w) \equiv (y_i - yd_i)^2$$

Bu eşitlikte y_i ve yd_i dir.

Burada amaç fonksiyonu $f(\cdot)$ ve onun Jakobiyeni J 'nin bir noktada w olarak bilindiği farz edilir.

LMM'de hedef, parametre vektörü w 'nin $E(w)$ minimum iken bulunmasıdır. LMM'nin kullanılmasıyla

yeni vektör w^{k+1} , farz edilen vektör w_k 'dan hesaplanır.

$$w_{k+1} = w_k + \delta w_k \quad (4.2)$$

Burada δw_k aşağıdaki şekilde verilir.

$$(J_k^T J_k + \lambda I) \delta w_k = -J_k^T f(w_k) \quad (4.3)$$

Eşitlikte,

J_k : f 'in w_k değerlendirilmiş Jakobyeni,

λ : Marquardt parametresi, ve

I : birim veya tanımlama matrisidir.

Levenberg-Marquardt algoritması aşağıdaki şekilde özetlenebilir:

$E(w_k)$

(i) w_k 'yı hesapla,

(ii) küçük bir λ değeri ile başla (mesela $\lambda = 0,01$),

(iii) δw_k için Denklem (3.3)'ü çöz ve $E(w_k + \delta w_k)$ değerini hesapla,

(iv) şayet $E(w_k + \delta w_k) \geq E(w_k)$ λ 'yı 10 kat arttır ve (iii)'e git,

(v) şayet $E(w_k + \delta w_k) < E(w_k)$ λ 'yı 10 azalt,

$w_k : w_k \leftarrow w_k + \delta w_k$ 'yi güncelleştir ve (iii)'e git.

Hedef çıkışı hesaplamak için bir MLP'nin LMM kullanılarak öğretilmesi ağırlık dizisi w_0 'a bir başlangıç

değerinin atanması ile başlar ve hatalarının karelerinin toplamı e_i^2 'nin hesaplanmasıyla devam eder. Her e_i^2 terimi, hedef çıkış (y) ile gerçek çıkış (y_d) arasındaki farkın karesini ifade eder. Bütün veri seti için e_i^2 hata terimlerinin tamamının elde edilmesiyle, ağırlık dizileri (i)'den (v)'e kadar olan LMM adımlarının uygulanmasıyla adapte edilir [11].

IV.2.2. Geliştirilen YSA'nın Topolojisi


Uygulamada kullanılan YSA Çok Katmanlı İleri Beslemeli bir yapay sinir ağıdır. Danışmanlı öğrenme yöntemlerinden Geri Yayılım Algoritmasını kullanan İleri Beslemeli YSA'nın bu çalışmada tercih edilmesinin nedeni, zaman serilerinin modellenmesi ve öngörümleme çalışmalarında en çok kullanılan yöntem olması ve hem doğrusal hem de doğrusal olmayan yapıların modellenmesinde gösterdiği öngörü başarısıdır.

Öngörümlemede kullanılacak bir YSA modelinin tasarımında aşağıdaki değişkenlerin belirlenmesi gerekmektedir:

1. Girdi nöron sayısı,
2. Gizli katman ve gizli katman nöron sayısı,
3. Çıktı nöron sayısı.

Bu değişkenlerin seçimi ilgilenilen probleme göre değişiklik göstermektedir. Optimal ağ topolojisinin belirlenmesinde önerilen bazı yöntemlerin olmasına rağmen, bu yöntemlerin hiçbiri gerçek öngörümleme problemleri için en uygun çözümü garanti etmemektedir. Bundan dolayı, bu parametrelerin belirlenmesinde kesin ve açık yöntemler bulunmamaktadır, ancak sezgisel yaklaşımlar ve kısıtlı deneylere dayalı benzetim çalışmaları yardımcı olabilmektedir.

Genellikle literatürde, girdi katmanında 10, 11 ve 12 nöron sayısı kullanılarak YSA'larının geliştirildiği görülmektedir. Bu tez kapsamında geliştirilen ileri beslemeli YSA'da ise 10 adet nörona sahip bir girdi katmanının kullanılması benimsenmiştir.



Şekil 10: Geliştirilen YSA Topolojisi

Geliştirilen YSA'da iteratif öngörümleme yöntemi benimsendiğinden çıktı nöron sayısı birdir. Aynı şekilde literatürde geliştirilen ileri beslemeli YSA'larda genellikle tek gizli katman kullanılmaktadır. Bu nedenle çalışmada geliştirilen YSA modelinde tek gizli katman kullanılması uygun görülmüştür. İteratif yaklaşım benimsenerek geliştirilen YSA modeli aşağıdaki şekilde gösterilmektedir.

Girdi katmanı ile gizli katman arasında tanjant-sigmoid transfer fonksiyonu kullanıldığından geçmiş döneme ait gerçek satış rakamları, MATLAB'de var olan fonksiyonlar kullanılarak [-1,+1] aralığında yer alacak şekilde ölçeklendirilmiştir. Gizli katman ile çıktı katmanı arasında ise doğrusal transfer fonksiyonu kullanılmıştır.


Tablo 4: Ele Alınan Ürünlerle İlişkin Belirlenen En İyi Ağ Topolojileri

Ürün Adı	En İyi Ağ Topolojisi		
	Girdi Katmanı Nöron Sayısı	Gizli Katman Nöron Sayısı	Çıktı Katmanı Nöron Sayısı
PVC S 39	10	8	1
PVC S 65	10	6	1
PTA	10	9	1

Her bir ürünün test kümesi için ilgili YSA'nın doğruluğunu tespit etmek amacıyla "Hata Karelerinin Ortalaması" (Mean Squared Error – MSE) performans ölçütünü kullanan YSA'ların çalıştırılmasına ilişkin rastgele seçilen örnek uygulamalar aşağıdaki tabloda ve takip eden şekillerde gösterilmiştir.

Tablo 5: Ele Alınan Ürünlerle İlişkin Örnek Uygulama Sonuçları


Ürün Adı	Hata Kareleri Ortalaması (MSE)
PVC S 39	2,4268.106
PVC S 65	6,8424.106
PTA	1,0376.107




Şekil 11: YSA'nın PVC S 39 Ürünün Test Kümesine Ürettiği Değerler

Gizli katmandaki nöron sayısının belirlenmesinde deneme-yenilme yöntemi benimsenmiştir. Buradan hareketle her bir seri için en iyi yapay sinir ağı modeli doğrulama kümesinde en iyi sonucu veren (en düşük hata kareler toplamını veren) ağ olarak seçilmiştir. Ele alınan her bir ürün serisi için toplam 131 adet satış verisi yer almaktadır. Bu serilerdeki verilerin %80'i eğitim kümesi, %10'u doğrulama kümesi ve kalan %10'u ise test kümesi olarak ele alınmıştır. Bir başka ifade ile, her bir serideki 131 değerden 95 tanesi eğitim kümesine, 13 tanesi doğrulama kümesine, kalan 13 tanesi ise test kümesine

tahsis edilmiştir. Yapılan denemeler sonucunda her bir ürün serisi için en iyi ağ topolojileri aşağıdaki tabloda gösterilmiştir.



Şekil 12: YSA'nın PVC S 65 Ürünün Test Kümesine Ürettiği Değerler



Şekil 13: YSA'nın PTA Ürünün Test Kümesine Ürettiği Değerler

IV.3. Kullanılan Yöntemlerin Karşılaştırılması

Öngörü modellerinin performanslarının karşılaştırılması amacı ile çeşitli performans ölçütleri kullanılmaktadır. Öngörünün performansının testi için, öngörü değerleri ile mevcut olan gerçek değerler arasındaki farklar, yani öngörü hataları (kalıntılar-residuals), bazı formüllerle modellerin öngörü performansını karşılaştırmaya yardımcı olabilecek şekilde standartlaştırılır. Modellerin öngörü performansının ölçümünde kullanılan hesaplamalar; Hata Kareleri Ortalaması (Mean Squared Error – MSE), Ortalama Hata Karelerinin Karakökü (Root Mean Squared Error – RMSE), Ortalama Mutlak Hata (Mean Absolute Error – MAE), Ortalama Yüzdü Hata (Mean Percentage Error – MPE), Hata Kareleri Toplamı (Sum of Squared Errors – SSE), Ortalama Mutlak Yüzdü Hata (Mean Absolute Percentage Error – MAPE) ve Theil-U istatistiği olarak sıralanabilir. Çalışmada kullanılan yöntemlerin performanslarının karşılaştırılmasında Hata Kareleri Toplamı (SSE) performans ölçütü kriteri kullanılmıştır. Hata kareleri toplamı performans ölçütü kriterinin denklemi aşağıdaki gibi gösterilmektedir.

e_t : t dönemindeki öngörü hatası,

y_t : t döneminde gerçekleşen değer,

\hat{y}_t : t dönemi için hesaplanan öngörü değeri

n : öngörülen dönem sayısı olmak üzere,

$$SSE = \sum_{t=1}^n (e_t)^2 \quad e_t = y_t - \hat{y}_t$$

Buna göre Hata Kareleri Toplamını ölçüt kabul ederek çalışmamızda kullanılan yöntemlerin öngörü performansları aşağıdaki Tablo 6'da verilmiştir.

Tablo 6: Kullanılan Yöntemlerin Öngörümle Performanslarının Karşılaştırılması

Ürün Adı	Öngörümleme Sonuçları - Hata Kareleri Toplamı (SSE)	
	Box-Jenkins Metodolojisi	Yapay Sinir Ağları
PVC S 39	57633690	1886100
PVC S 65	29500000	20158000
PTA	411000000	5640700

Tablo 6'da görüldüğü üzere öngörümleme yöntemlerinden Yapay Sinir Ağları, kullanılan diğer yöntemlere göre her bir üründe daha küçük hata kareleri toplamı vererek en iyi sonuçları üretmiştir.

V. SONUÇ VE ÖNERİLER

Bu çalışmada, öngörümleme teknikleri içerisinde önemli bir yer tutan zaman serileri analizinde, geleceği öngörümlemede kullanılan geleneksel öngörümleme yöntemlerine alternatif olarak öne sürülen, Yapay Sinir Ağları metoduna yer verilmiştir. Yapay sinir ağları, özellikle son 20 yılda büyük gelişme gösteren bir çalışma disiplindir.

Öngörümleme yöntemleri, temel olarak nicel ve nitel yöntemler olarak ikiye ayrılır. Genel olarak nicel yaklaşımların girdisi, çeşitli zaman aralıklarında toplanmış olan verilerdir. Verilerin iyi bir şekilde analiz edilmesi, bu yöntemlerin temelini oluşturmaktadır. Son yıllarda geleneksel öngörümleme yöntemlerine alternatif olarak kullanılmaya başlanan yöntemlerden birisi de Yapay Sinir Ağlarıdır. Bilim dünyası 1940'lı yıllarda Yapay Sinir Ağları ile tanışmıştır. Bu alanda yapılan ilk çalışmalar beyin hücrelerinin işlevlerinin ve birbirleri ile haberleşme şekillerinin ortaya çıkarılmasını amaçlamaktaydı. O zamandan beri Yapay Sinir Ağları gerek teorik gerekse pratik anlamda dikkate değer miktarda yol katetmiştir. Bugün birçok hücrenin belli bir düzende bir araya getirilmesi ve uygun öğrenme algoritmalarının kullanılması ile sinir ağları kurulabilmekte ve bu ağlar çok karmaşık görevleri başarıyla yerine getirebilmektedir. Ağ, kendisine sunulan veriler arasında bağlantılar kurarak problemi öğrenmekte,

deneysel sonuçları depolamakta ve bunları kullanıma hazırlamaktadır. Yapay sinir ağları, insan beyninin temel birimi olan nöronlara benzer olarak düzenlenen yapay nöronların farklı topoloji ve ağ modelleriyle birbirine bağlanmasıyla oluşan karmaşık sistemlerdir. Bu anlamda, bu ağlar insan beyninin biyolojik fonksiyonlarının basit bir modellenmesinden ibarettir. Bir yapay sinir ağı, birbiriyle etkileşim içindeki pek çok yapay nöronun paralel bağlı bir hiyerarşik organizasyonudur. Yapay sinir ağında hesaplama algoritmik programlamaya bir seçenek oluşturan, temel olarak yeni ve farklı bir bilgi işleme tekniğidir. Yapay sinir ağları bilinen hesaplama yöntemlerinden farklı bir hesaplama yöntemi önermektedir. Buldukları ortama uyum sağlayan, adaptif, eksik bilgi ile çalışabilen, belirsizlikler altında karar verebilen, hatalara karşı toleranslı olan bu hesaplama yönteminin hayatın hemen hemen her alanında başarılı uygulamalarını görmek mümkündür. Oluşturulacak olan ağın yapısının belirlenmesinde, ağ parametrelerinin seçiminde, belirli bir standardın olmaması, problemlerin sadece nümerik bilgiler ile gösterilebilmesi, eğitimin nasıl bitirileceğinin bilinmemesi ve ağın davranışlarının açıklanamamasına rağmen bu ağlara olan ilgi her geçen gün artmaktadır. Özellikle öngörümleme, sınıflandırma, örüntü tanıma, sinyal filtreleme, veri sıkıştırma ve optimizasyon çalışmalarında yapay sinir ağları en güçlü teknikler arasında sayılabilir. Biyolojik sinirlerden esinlenerek elde edilen YSA, doğrusal olmayan ve paralel bilgi işleme özellikleriyle; bulunduğu ortamın değişmesiyle ürettiği sonucu değiştirebilme, giriş parametrelerindeki küçük değişimleri tolere edebilme, değişik bazı veriler karşısında daha önceki veri değerleri içerisinde var olan benzer özellikleri keşfederek, deneyimi olmadığı halde yeni veri değerlerine cevap verebilme gibi üstün özelliklere sahiptir.

Yapay Sinir Ağlarının mevcut olan bu avantajlarından yola çıkarak hazırlanan çalışmamızda Petkim'de üretilmekte olan dört ürüne ilişkin öngörümlemede kullanılan YSA modeli, geleneksel zaman serileri öngörümlemesinde kullanılan Trendin Bileşenlerine Ayrılması ve Box-Jenkins Metodolojisi ile karşılaştırılmış ve sonuç olarak her bir ürüne göre oluşturulan farklı yapıdaki YSA modellerinin daha düşük hatalar vermesinden dolayı daha başarılı olduğu görülmüştür.

Ülkemizde gerek Yapay Sinir Ağları ile gerekse geleneksel zaman serileri öngörümleme yöntemleri ile satış değerlerinin modellenmesi ve öngörümlemesine ilişkin çalışmaların sınırlı sayıda olduğu ve Petkim'de mevcut olan herhangi bir satış öngörümleme yönteminin kullanılmadığı dikkate alındığında, bu çalışmanın Türkiye'deki satış öngörümleme literatürüne ve Petkim'de çalışan yöneticilerin geleceğe yönelik planlama çalışmalarına önemli katkılar sağlayacağı düşünülmektedir.

YARARLANILAN KAYNAKLAR

- [1] Yapay Sinir Ağları Hakkında, (<http://www.akademiya.payzeka.com/DesktopDefault.aspx?tabindex=4&tabid=4>) [17.07.2010].
- [2] Ergezer, H.; Dikmen M.&Özdemir E. (2003). Yapay Sinir Ağları Ve Tanıma Sistemleri.*Pivolka*, 2(6), 14-17.
- [3] Haykin, S. (1999).*Neural Networks: A Comprehensive Foundation*. New Jersey: Prentice Hall Inc.
- [4] Fahey, C. Artificial Neural Networks. (http://www.colinfahey.com/2003apr20_neuron/2003apr20_neuron.htm) [17.08.2006].
- [5] Öztemel, E. (2006).*Yapay Sinir Ağları*. 2. Baskı. İstanbul: Papatya Yayıncılık.
- [6] Koç, M. L.; Balas C. E. & Arslan, A. (2004).Taş Dolgu Dalgakıranların Yapay Sinir Ağları İle Ön Tasarımı.*İMO Teknik Dergi*, 15(4), 3351-3375.
- [7] Anderson, D. & McNeill, G. Artificial Neural Networks Technology.(<https://www.thedacs.com/techs/neural/neural.title.php>) [11.12.2006].
- [8] Yurtoğlu, H. (2005). Yapay Sinir Ağları Metodolojisi ile Önörü Modellemesi: Bazı Makroekonomik Değişkenler için Türkiye Örneği.*Uzmanlık Tezi*, Devlet Planlama Teşkilatı.
- [9] Detienne, K. B.; Detienne D. H. & Joshi, S. A. (2003). Neural Networks As Statistical Tools For Business Researchers.*Organizational Research Methods*, 6(2), 236-265.
- [10] Rojas, R. (1996).*Neural Networks-A Systematic Introduction*. Berlin: Springer-Verlag.
- [11] Sağıroğlu, Ş.; Beşdok E. & Erler, M. (2003).*Mühendislikte Yapay Zeka Uygulamaları I: Yapay Sinir Ağları*. Kayseri: Ufuk Kitap Kıratsiye-Yayıncılık.
- [12] Alpaydın, E. (2004).*Introduction To Machine Learning*. England: The MIT Press Cambridge.
- [13] Alataş, B. Sinirsel Ağlar, (www.firat.edu.tr/akademik/fakulteler/muhendislik/bilgisayar/balatas/SinirselAglar.pdf) [16.09.2006].
- [14] Şen, Z. (2004).*Yapay Sinir Ağları İlkeleri*. İstanbul: Su Vakfı Yayınları.
- [15] Elmas, Ç. (2003).*Yapay Sinir Ağları (Kuram, Mimari, Eğitim, Uygulama)*. 1. Baskı. Ankara: Seçkin Yayıncılık.
- [16] Karadeniz, M.; Yüncü, S. & Aydemir, M. -T. Asenkron Motorlarda Stator Direncinin Yapay Sinir Ağları İle Tahmini.(www.fbe.gazi.edu.tr/bolumler/guadek/6.doc)[05.06.2007].
- [17] Bircan, H. & Karagöz, Y. (2003). Box-Jenkins Modelleri İle Aylık Döviz Kuru Tahmini Üzerine Bir Uygulama.*Kocaeli Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 6(2), 49-62.
- [18] Özmucur, S. (1990). *Geleceği Tahmin Yöntemleri*.İstanbul, İstanbul Sanayi Odası Araştırma Dairesi Yayınları.
- [19] Fretchling, D. C. (1996).*Practical Tourism Forecasting*. Oxford: Butterworth-Heinemann.

- [20] Archer, B. (1980). Forecasting Demand: Quantitative And Intuitive Techniques. *International Journal Of Tourism Management*, 1(1), 5-12.
- [21] Orhunbilge, N. (1999). *Zaman Serileri Analizi Tahmin Ve Fiyat İndeksleri*. İstanbul: Tunç Matbaacılık A.Ş.
- [22] Montgomery, D. C. & Johnson, L. A. (1976). *Forecasting And Time Series Analysis*. New York: McGraw-Hill Book Company.
- [23] De Lugio, S. A. (1998). *Forecasting Principles And Applications*. Boston: Irwin/McGraw-Hill.
- [24] Başoğlu, U. & Parasız, İ. (2003). *İktisadi Verilerin Analizi Ve Temel Öngörü Yöntemleri*. Bursa: Ekin Kitabevi.
- [25] Akgül, I. (2003). *Geleneksel Zaman Serisi Yöntemleri*. İstanbul: Der Yayınları.
- [26] Bhattacharya, S. (1997). A Comparative Study Of Different Methods Of Predicting Time Series. *Yüksek Lisans Tezi*, Concordia University.
- [27] Topçuoğlu, K.; Pamuk, G. & Özgürel, M. (2005). Gediz Havzası Yağışlarının Stokastik Modellemesi. *Ege Üniversitesi Ziraat Fak. Dergisi*, 42(3), 89-97.
- [28] Gujarati, D. N. (2003). *Basic Econometrics*. Fourth Edition. USA: McGraw-Hill Inc.
- [29] Hanke, J. E. & Reitsch, A. G. (1992). *Business Forecasting*. Fourth Edition. Boston: Allyn And Bacon.
- [30] Box, G. P. & Jenkins, G. M. (1976). *Time Series Analysis Forecasting And Control*. San Francisco: Holden-Day Press.
- [31] Akgül, I. (2003). *Zaman Serilerinin Analizi Ve ARIMA Modelleri*. İstanbul: Der Yayınları.
- [32] Yaman, K.; Sarucan, A.; Atak, M. & Aktürk, N. (2001). Dinamik Çizelgeleme İçin Görüntü İşleme ve ARIMA Modelleri. *Gazi Üniversitesi Müh. Mim. Fak. Dergisi*, 16 (1), 19-40.
- [33] Giriffiths, W. E.; Hill, C. R. & Judge, G. G. (1992). *Learning And Practicing Econometrics*. New York: John Wiley And Sons Inc.
- [34] Kayım, H. (1985). *İstatistiksel Ön Tahmin Yöntemleri*. Ankara: Hacettepe Üniversitesi İktisadi Ve İdari Bilimler Fakültesi Yayınları, No. 11.
- [35] Hamzaçebi, C. & Kutay, F. (2005). Yapay Sinir Ağları İle Zaman Serileri Tahmini. *4. İstatistik Kongresi*, 08-10 Mayıs, Antalya, 265-270.
- [36] Elder, J. & Kennedy, P. (2001). Testing For Unit Roots: What Should Students Be Taught?. *Journal Of Economic Education*, 32(2), 137-146.
- [37] Akmut, Ö.; Aktaş, R. & Binay, H. S. (1999). *Öngörü Teknikleri Ve Finans Uygulamaları*. Ankara: Siyasal Kitabevi.



Burçin ATASEVEN

b.ataseven@iku.edu.tr

Burçin Ataseven, PhD. was graduated from Dokuz Eylül University, Faculty of Business Administration, Business Administration Department. She has a Ph.D. of Statistics at Marmara University. She is a research assistant at İstanbul Kültür University, Business Administration Department. Her main research areas are data quality, survey methodology and sampling techniques.