

**T.C.
SÜLEYMAN DEMİREL ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**YAPAY SİNİR AĞI VE BOX-JENKİNS MODELİ İLE YAZICI
SARF MALZEMELER VERİLERİNİN TAHMİNİ
İRAK ÖRNEĞİ**

Ban ALMAHMUD

**Danışmanı
Dr. Öğr. Üyesi Mehmet ALBAYRAK**

**YÜKSEK LİSANS TEZİ
BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI
ISPARTA 2019**



© 2019 [Ban ALMAHMUD]

TEZ ONAYI

Ban ALMAHMUD tarafından hazırlanan "**Yapay Sinir Ağı ve Box-Jenkins Modeli ile Yazıcı Sarf Malzemeler Verilerinin Tahmini Irak Örneği**" adlı tez çalışması aşağıdaki jüri üyeleri önünde Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü **Bilgisayar Mühendisliği Anabilim Dalı**'nda **YÜKSEK LİSANS TEZİ** olarak başarı ile savunulmuştur.

Danışman

Dr. Öğr. Üyesi Mehmet ALBAYRAK
Isparta Uygulamalı Bilimler Üniversitesi

Jüri Üyesi

Dr. Öğr. Üyesi Turgay AYDOĞAN
Süleyman Demirel Üniversitesi

Jüri Üyesi

Dr. Öğr. Üyesi Kubilay TAŞDELEN
Isparta Uygulamalı Bilimler Üniversitesi

Enstitü Müdürü

Doç. Dr. Şule Sultan UĞUR

TAAHHÜTNAME

Bu tezin akademik ve etik kurallara uygun olarak yazıldığını ve kullanılan tüm literatür bilgilerinin referans gösterilerek tezde yer aldığını beyan ederim.

Ban ALMAHMUD



İÇİNDEKİLER

	Sayfa
İÇİNDEKİLER	i
ÖZET	iii
ABSTRACT	iv
TEŞEKKÜR	v
ŞEKİLLER DİZİNİ	vi
ÇİZELGELER DİZİNİ	vii
KISALTMALAR DİZİNİ	viii
1. GİRİŞ	1
2. KAYNAK ÖZETLERİ	5
3. MATERYAL VE YÖNTEM	9
3.1. Zaman Serisi	10
3.1.1. Zaman Serisi Çeşitleri	10
3.1.2. Zaman Serisinin Öğeleri	11
3.1.2.1. Genel Trend	11
3.1.2.2. Mevsimsel Değişimler	12
3.1.2.3. Dönemsel Değişimler	12
3.1.2.4. Arızı veya Düzensiz Değişimler	12
3.1.3. Zaman Serisi Kavramları	13
3.1.3.1. Tam İstikrarlı	14
3.1.3.2. Zayıf İstikrarlı	14
3.1.4. Zaman Serilerini Düzenli Hale Getirmek	15
3.1.4.1. Süreç Ortalamasında Düzensiz Olan Zaman Serileri	15
3.1.4.2. Değişkenlerde Düzenli Olmayan Zaman Serileri	16
3.1.5. Düzenlilik Ölçme Testleri	17
3.1.5.1. Dickey – Fuller (DF) Testi	17
3.1.5.2. Genişletilmiş Dickey Fuller Testi (ADF)	17
3.1.5.3. Phillips ve Perron (PP) Testi	18
3.1.5.4. KPSS Testi	18
3.1.5.5. Ljung-Box Testi	18
3.1.5.6. Fonksiyonu ile Kısmi Otokorelasyon Fonksiyonu	19
3.1.6. Zaman Serisi Modelleri	22
3.1.6.1. Dönemsel Olmayan Otoregresif Model (AR)	22
3.1.6.2. Dönemsel Otoregresif Modeli (SAR)	23
3.1.6.3. Dönemsel Olmayan Hareketli Ortalama Modeli (MA)	23
3.1.6.4. Dönemsel Hareketli Ortalama Modeli (SMA)	24
3.1.6.5. Karmaşık Model (Otoregresif ve Hareketli Ortalama) (ARMA)	24
3.1.6.6. Dönemsel Karmaşık Model (Dönemsel Otoregresif ve Hareketli Ortalama)	25
3.1.6.7. Bütünleşmiş Otoregresif ve Hareketli Ortalama Modeli (ARIMA) ..	25
3.1.6.8. Dönemsel Bütünleşmiş Otoregresif ve Hareketli Ortalama Modeli (SARIMA)	26
3.2. Box – Jenkins (B-J) Metodolojisi	27
3.2.1. Model Belirleme	28
3.2.2. Modelin Tahmini	28
3.2.3. Modelin Teşhisi	29
3.2.4. Öngörü	31
3.3. Yapay Sinir Ağları	32

3.3.1. Yapay Sinir Ağlarının Temel Kavramı	35
3.3.2. Yapay sinir ağlarının özellikleri ve bileşenleri teknik kavramları	37
3.3.2.1. Aktivasyon Fonksiyonu	40
3.3.2.2. Eşik veya Adım Fonksiyonu	40
3.3.2.3. Çizgisel veya Parçalı Fonksiyon	41
3.3.2.4. Sigmoid Fonksiyon	41
3.3.3. Yapay Sinir Ağlarının Yapısı (Mimarisi)	42
3.3.3.1. Tek Katmanlı Ağlar	42
3.3.3.2. Çok Katmanlı Ağlar	42
3.3.4. Yapay Sinir Ağları Türleri	43
3.3.4.1. İleri Beslemeli Sinir Ağları	43
3.3.4.2. Geri Beslemeli Sinir Ağları.....	44
3.3.4.3. Otobağlantılı Sinir Ağları.....	44
3.3.5. Yapay Sinir Ağları Eğitimi	44
3.3.6. Yapay Sinir Ağlarında Öğrenme Algoritmaları	46
3.3.7. Bilgilerin Yapay Sinir Ağlarında İşlenmesi.....	48
3.3.8. Yapay Sinir Ağları Kullanımı ile Öngörü (Kestirim)	51
3.3.9. Modeller Arası Tercih Kriterleri	53
3.3.9.1. Akaike Bilgi Kriteri (AIC).....	53
3.3.9.2. Bilgi Kriteri (BIC).....	54
3.3.10. Yapay Sinir Ağları ve Zaman Serileri.....	54
3.3.10.1. Zaman Serileri ile Öngörü Tahminlerinde Yapay Sinir Ağlarının Uygulanması için Gerekli olan Kararlar.....	55
3.3.10.2. Zaman Serileri ile Öngörü Tahminlerinde Kullanılan Yapay Sinir Ağları Türleri.....	55
4. ARAŞTIRMA BULGULARI VE TARTIŞMA	57
4.1. Verilerin Tanımı.....	57
4.2. Verilerin Hazırlanması	58
4.3. Box and Jenkins Metodu Kullanılarak ARIMA Modelinin Oluşturulması	64
4.3.1. Tanımı ve Belirlenmesi Aşaması	64
4.3.2. Teşhis Aşaması	65
4.3.2.1. Durağanlık ve yansıma Araştırması	66
4.3.2.2. Kalıntı Analizi - Artıklar Analizi	66
4.3.3. Değerlendirme Aşaması	68
4.4. Yapay Sinir Ağları Modelinin Oluşturulması	69
4.5. Yapay Sinir Ağları Metodu ile Box – Jenkins Metodunun karşılaştırılması ve Öngörü Talebi	71
5. SONUÇ ve ÖNERİLER.....	74
KAYNAKÇA.....	76
ÖZGEÇMİŞ	83

ÖZET

Yüksek Lisans Tezi

YAPAY SİNİR AĞI VE BOX-JENKİNS MODELİ İLE YAZICI SARF MALZEMELER VERİLERİNİN TAHMİNİ "IRAK ÖRNEĞİ"

Ban ALMAHMUD

Süleyman Demirel Üniversitesi
Fen Bilimleri Enstitüsü
Bilgisayar Mühendisliği Anabilim Dalı

Danışman: Dr. Öğr. Üyesi Mehmet ALBAYRAK

Bu çalışma sırasında yazıcı sarf malzemeleri satışları öngörülerinde bulunabilmek amacıyla Box-Jenkins (B-J) Metodu ile Otoregresif, Bütünleşik Otoregresif Hareketli Ortalama (ARIMA) ve Yapay Sinir Ağları (YSA) yöntemleri kullanılmıştır. Toplam 132 gözleminden ibaret olan Ocak 2008 ile Aralık 2018 Arasındaki süreçte Irak'ta satılan yazıcı sarf malzemeleri miktarı değerleri ele alınarak buna ait zaman serisi incelenip analiz edilmiş ve (B-J) metodu uygulanarak veri temsili için Otoregresif ve Bütünleşik Otoregresif Hareketli Ortalama yöntemlerinin kullanılması sonucunda (ARIMA) modelleri arasında en uygun modelin (ARIMA) olduğu sonucuna varılmıştır. Bu modelin seçimin nedeni ise öngörü doğruluğu ölçeğine Karesel Hata (RMSE) ve Mutlak Hata (MAPE) dayalı olup Yapay Sinir Ağları (YSA) kullanıldığında ise en uygun modelin Çok Katmanlı Ağı (MLP) olduğunu görüldü. Bu iki sonuç arasında Karesel Hata (RMSE) ve Mutlak Hata (MAPE) Kıstası kullanılarak öngörü doğruluğu ve performansı yönlerinden karşılaştırma yapıldığında ise Yapay Sinir Ağları Çok Katmanlı (MLP) en uygun model olduğu görüldüğünden yazıcı sarf malzemeleri satışları serisinin ileriki satış miktarı değerlerinin öngörülmesi için bu model kurulmuştur. Böylece çalışma için en uygun ve ileriki öngörüler için daha elverişli olan model YSA(5.5.1) sinir ağı modeli olduğu sonucu ortaya çıkmıştır.

Anahtar Kelimeler: Yapay Sinir Ağı, Box-Jenkins Modeli, ARIMA Modelleri Algoritma, Yazıcı Sarf Malzemeleri, Satış, Veri, Tahmin.

2019, 83 sayfa

ABSTRACT

M.Sc. Thesis

PREDICTING THE SALE OF PRINTING STUFFS USING ARTIFICIAL NEURAL NETWORKS AND BOX-JENKINS MODEL "MODEL OF IRAQ"

Ban ALMAHMUD

**Süleyman Demirel University
Graduate School of Natural and Applied Sciences
Department of Computer Engineering**

Supervisor: Asst. Prof. Dr. Mehmet ALBAYRAK

This study aimed to use the methodology of (BOX & Jenkins) for self-regression, integrative moving averages (ARIMA) and artificial neural networks (ANNs) method to predict ink sales. Through the study and analysis of time series data of the printing stuffs sales index in Iraq during the period from January 2008 to December 2018 which represents 132 views and that is through the methodology application style (B&J) the style of autoregressive and moving averages integrative study that model is to represent the data among the models (ARIMA) which has been selected this model based on the use of a measure of prediction accuracy (RMSE), (MAPE) while when using the artificial neural networks (ANNs) model was (MLP) is the best among models of neural networks to represent data these two methods were compared in terms of accuracy and efficiency of prediction by using (RMSE), (MAPE) the standard results indicated that the model artificial neural networks (MLP) were reliable in predicting the extent of future series printing stuffs sales, thus, the most appropriate model for our study subject and more suitable for further predictions is ANN (5.5.1) neural network model.

Keywords: Artificial Neural Networks, Box-Jenkins Model, ARIMA Model, Algorithm, Printing Stuffs, Sales, Data, Prediction.

2019, 83 pages

TEŞEKKÜR

İlk başta bu çalışmamı tamamlamak için beni başarı yoluna götüren Yüce Rabbime minnet ve şükranlarımı sunar, daha sonra bu çalışmanın ortaya çıkması için gerekli katkıyı esirgemeyen Saygıdeğer Danışman Hocama sonsuz şükranlarımı bundan dolayı Allah'tan kendilerine hayırlar diler saygı ve takdirlerimi sunarım. Bununla birlikte derslerimi gösteren bütün hocalarıma şükranlarımı sunarken özellikle de tezimi değerlendirecek olan jüri üyelerine bana verecekleri bilgi ve yol gösterici eleştirilerinden dolayı, hiçbir bilgiyi esirgemeyen, yolumu aydınlatan ve bana parlak bir gelecek sunmanın yollarını gösteren tüm hocalarım ile bu çalışmanın ortaya çıkması için sadece bir güzel söz bile olsa uzaktan veya yakından yardımcı olan her kese sonsuz şükran ve minnetimi sunarım.

Ban ALMAHMUD
ISPARTA, 2019

ŞEKİLLER DİZİNİ

	Sayfa
Şekil 3.1. Hücre Detaylarının Açıklaması	33
Şekil 3.2. Yapay Sinir Ağı Genel Planı	35
Şekil 3.3. Ağ Yapısı Modeli.....	36
Şekil 3.4. Yapay Nöron Öğeleri.....	38
Şekil 3.5. Yapay Sinir Ağı Modeli.....	39
Şekil 3.6. Eşik (Adım) Fonksiyonu Açıklaması	41
Şekil 3.7. Çizgisel Fonksiyonun Açıklamalı Şekli	41
Şekil 3.8. Sigmoid Fonksiyonunun Açıklaması.....	41
Şekil 3.9. İleri Beslemeli Sinir Ağı Örneği.....	43
Şekil 3.10. Ağırlık Tadili (Uyarlanması) Genel Grafiği	45
Şekil 3.11. Hata Geri Yayılma Metodu.....	51
Şekil 4.1. ABD Doları ile Aylık Yazıcı Sarf malzemeler Satışla Miktarı Zaman Serisi Grafiği.....	58
Şekil 4.2. Temel Seri Otokorelasyon Fonksiyonu (AFC).....	60
Şekil 4.3. Temel Seri Kısmi Otokorelasyon Fonksiyonu (PAFC).....	60
Şekil 4.4. Birinci Dönemsel Farktan Sonra Yazıcı Sarf Malzemeler Satışları Zaman Serisi	61
Şekil 4.5. Yazıcı Sarf malzemeler Satışları Birinci Dönemsel Fark Sonrası Otokorelasyon Fonksiyonu.....	62
Şekil 4.6. Yazıcı Sarf malzemeler Satışları Birinci Dönemsel Fark Sonrası Kısmi Otokorelasyon Fonksiyonu.....	62
Şekil 4.7. ARIMA (0,1,0) (0,0,1) Modeli Kalıntı, Otokorelasyon ve Ljung – Box Testi Grafiği	67
Şekil 4.8. Kalıntıların Tekrarlanan Eğimi ve Normal Q-Q Çizimi.....	68
Şekil 4.9. Yapay Sinir Ağları Modelinde Kullanılan Veriler.....	70
Şekil 4.10. Deneylerden Elde Edilmiş olan Yapay Sinir Ağı Modeli.....	71
Şekil 4.11. YSA (5.5.1) Modelin Gerçek ve tahmini değerler belirlenir.	73

ÇİZELGELER DİZİNİ

	Sayfa
Çizelge 4.1. İstatistiksel Tanımlar.....	57
Çizelge 4.2. Zaman Serisinin Durağanlık Testleri	59
Çizelge 4.3. Yazıcı Sarf malzemeler Satışları Serisi için KPSS, PP ve ADF Testleri Sonuçları.....	61
Çizelge 4.4. Zaman Serisi Birinci Dönemsel Fark Sonrası Durağanlık Testleri	63
Çizelge 4.5. Yazıcı Sarf malzemeler Satışları Serisi için KPSS, PP ve ADF Testleri Sonuçları.....	64
Çizelge 4.6. Zaman Serisi için En Uygun Dönemsel Modelin Seçimi	65
Çizelge 4.7. Önerilen ARIMA(0,1,0) (0,0,1) Modeli Fonksiyon Tahmini.....	65
Çizelge 4.8. Kalıntıların Dağılım Özelliklerini Belirten Jarque – Bera Testi Sonuçları.....	68
Çizelge 4.9. ARIMA (0,1,0) (0,0,1) Modeli Parametreleri Test ve Değerlendirmesi.....	69
Çizelge 4.10. ARIMA(0,1,1) Modeli Öngörü Doğruluğu Ölçütü.....	69
Çizelge 4.11. Yapay Sinir Ağları Modeli.....	70
Çizelge 4.12. Box-Jenkins Metodu ile Yapay Sinir Ağları Metodunun Öngörü Doğruluğu Ölçütlerinin Karşılaştırılması	72
Çizelge 4.13. YSA (5.5.1) Modeli Öngörü Değerleri	73

KISALTMALAR DİZİNİ

ACF	Otokorelasyon Fonksiyonu (Autocorrelation Function)
ADF	Genişletilmiş Dickey Fuller Testi (Dickey Fuller Augments)
AIC	Akaike Bilgi Kriteri (Akaike Information Criterion)
ANN	Yapay Sinir Ağları (Artificial Neural Networks)
AR	Otoregresif Süreç (Autoregressive)
ARIMA	Otoregresif Entegre Hareketli Ortalama Süreci (Autoregressive Integrated Moving Average)
ARMA	Otoregresif Hareketli Ortalama Süreci (Mixed Autoregressive Moving Average)
BIC	Bilgi Kriteri (Bayesian Information Criterion)
B-J	Box and Jenkins
DF	Dickey Fuller
KPSS	Kwiatkowski -Phillips -Schmidt-Shin
MA	Hareketli Ortalama Süreci (Moving Average)
MAE	Ortalama Mutlak Hata (Mean Absolute Error)
MSE	Hata Kareleri Ortalaması (Mean Squared Error).
MAPE	Ortalama Mutlak Yüzde Hata (Mean Absolute Percentage Error)
MPE	Ortalama Yüzde Hata (Mean Percentage Error)
MLP	Çok Katmanlı Ağ (Multi Layer Perceptron)
OLS	Ordinary Least of Squares
PACF	Kısmi Otokorelasyon Fonksiyonu (Partial Autocorrelation Function)
PP	Phillips and Perron
RMSE	Kök Hata Kareleri Ortalaması (Root Mean Squared Errors)
SAR	Mevsimsel Otoregresif Süreç
SARIMA	Mevsimsel Otoregresif Entegre Hareketli Ortalama Süreci
SARMA	Mevsimsel Otoregresif Hareketli Ortalama Süreci
SMA	Mevsimsel Hareketli Ortalama Süreci

1. GİRİŞ

Tahmin, gelecek için planlama sürecindeki en önemli karar verme araçlarından ve en önemli unsurlardan biridir. Doğru kararı vermek için, mevcut tüm alternatifleri incelemek, en iyi olanı seçmek, bu karardan kaynaklanacak etkilerin neler olduğunu belirlemek, geçmiş ve şimdiki değişkenleri analiz etmek gerekir. Bu nedenle, tahminin, geleceği bilmek için geçmiş ve şimdiki verilere bağlı olduğunu görülebilir. Gelecek hakkında bilgimiz bulunmamakta ve gelecekle ilgili verilen kararlarda da yüksek risk olasılığı mevcuttur. Bu nedenle tahmine ihtiyaç duyulur. Bu riski azaltmak, geleceğin özelliklerini belirlemek, geçmiş ile gelecek arasındaki benzerlik derecesini bilmek için geçmişteki olayların seyrinin analiz edilmesine dayandırılmalıdır. Bu bilgi alınan kararda güveni arttırır. Tahmin araçları zaman serisi verilerinde sıklıkla kullanılır. Çünkü bu verilerin çoğu geçmişte meydana gelen olaylar için toplanmıştır (Ameen, 2005).

İstikrarsız ve yenileşmekte olan bir çevrenin gerektirdiği yenileşen bilgi çağında etkin, hızlı ve sürekli performans gerekir. Bu nedenle kurumların bu dalgalı ortamda devamlılık, dayanabilirlik ve uyum sağlayabilmeleri şarttır. Ancak bu kurumların etkili olmaları ve net sonuçlar elde edebilmeleri için de; yenilenebilir bilgilere dayalı, güçlü ve etkin bir bilgi tabanı oluşturmaları, bir dizi düzenlemelere sahip olmalıdırlar. Ayrıca, kurumun varlığının ve sürdürülebilirliğinin temeli olarak müşteri beklentilerine ve tüketici memnuniyetine cevap verebilmek şarttır. Bu düzenlemelerin aktif oldukları ortamın niteliğine uygun şekilde titiz, matematiksel, nicel ve bilimsel çalışmalar gibi unsurlarla birleştirilerek uygulama yöntemlerinin yeniden gözden geçirilmesi gerekir. Çünkü müşteri beklentilerine ve tüketici memnuniyetine cevap vermek, kuruluşun bulunma ve devam edebilmesinin temelidir.

Herhangi bir kurumun bekası ve sürekliliği farklı idarelerinin özellikle de satış yönetimi fonksiyonunun yeteneklerine bağlıdır. Çünkü diğer tüm idari fonksiyonlar satış yönetimi fonksiyonuna tabidir. Kuruluşun gelecekteki satış ve üretim hacmini belirleyebilen en aktif faaliyeti budur. Ayrıca üretimde kullanılan malzemeler için finansman hacminin, iş gücünün ve diğer harcamaların belirlenmesinde aktif rol oynamaktadır. Bütün bunlar süreç için ihtiyaç duyulan nakit akışının belirlenmesini

sağlar. Buna göre satış tahmini yönetimi diğer çeşitli faaliyetlerin kilit faaliyetidir. İyi bir tahminden, diğer fonksiyonların faaliyet ve gereksinimleri için iyi değerlendirmeler elde edilir.

Herhangi bir stratejinin etkinliği ve başarısı, en önemlisi kararların doğruluğu, uygulanması, hazırlanması, değerlendirilmesi ve geçerliliği birçok faktöre bağlıdır. Yani karar verme süreci, büyük ölçüde kestirim sisteminin çıktılarına dayanmaktadır; çünkü bu, kurumun gelecekte değişken ve olayların nasıl olacağına dair bir vizyondur. Aynı zamanda iş hiyerarşisinde de en önemli fonksiyondur (Karaman, 2004).

Tüm bu verilere rağmen, Irak'taki çoğu şirket, nicel ölçüm yöntemleri ve istatistiksel yöntemler kullanmanın önemini de bilmelerine rağmen, satış tahmin sürecindeki faaliyetlerinin çoğunda henüz basit ve geleneksel yöntemlere güvenmektedirler.

Tahmin (öngörü), karar verme araçlarından en önemlisi ve gelecek için planlama sürecinde yine en önemli unsurlardan biridir. Doğru karar vermek için, mevcut tüm alternatifleri incelemek, geçmişin ve bugünün değişkenlerini analiz etmek yoluyla, bu karardan kaynaklanacak etkileri, neyin en iyisi olduğunu belirlemek gerekir. Bu nedenle tahminin geleceği bilmek için geçmiş ve günümüzdeki verilere bağlı olduğunu söyleyebilir (Lendasse, 2000).

Tahmin modellerini oluşturmak için kullanılan birçok yöntem vardır: Farklı zaman serileri analiz yöntemleri en yaygın kullanılan yöntemdir. Yapay sinir ağları, genetik programlama, veri madenciliği yöntemleri ve benzerleri gibi diğer modern tahmin yöntemleri de vardır. Bu çalışmada, iki tahmin yöntemi kullanan zaman serisi tahmini vardır. Bunların biri geleneksel tarz Box-Jenkins modeli; diğeri ise modern yöntem yapay sinir ağları modelidir. Uygulama, yazıcı sarf malzemeler satış şirketlerinin zaman serilerine uygulanır.

Kestirim modellerini oluşturmak için birçok yöntem vardır, ancak bunlardan, farklı alanlarda en kullanışlısı, yöntem değişik zaman serisi analizi yöntemidir. Bu alanlardan en önemlisi de Irak ekonomisi üzerinde büyük etkisi olan yazıcı sarf malzemeler (toner) alanıdır.

Araştırmacılar simülasyon yazılımları kullanarak veri üretebilirler, çünkü bunlar gereken verilerin bulunmadığı durumlarda istatistiksel modellerin sonuçlarının özellik ve titizliğini belirlemede oldukça faydalıdır, çünkü simülasyon yöntemi hacim ve nitelik açısından farklı veri üretimi sağlar.

Zaman serisinde kestirim süreci, zaman serisi verileri için uygun model seçiminden direk etkilenir. Kestirim doğruluğu, zaman serilerinin gözlem hacminden de etkilenebilir. Bu nedenle bu araştırmanın sorunu, Box and Jenkins (B-J) modeli ile yapay sinir ağları Artificial Neural Networks (ANN) modelinin arasında kestirim doğruluğu karşılaştırması yaptıktan sonra zaman serileri kestiriminin en doğru modelini bilmektir.

Yazıcı sarf malzemeleri, dijital dünyanın gelişimine rağmen fark edemediğimiz ve günlük işlerde sıklıkla kullandığımız ihtiyaçlardan biridir. Yazıcı sarf malzemeler; reklam, yayın, okul kullanımı, kamu kitaplarının ve diğerlerinin basımı dâhil tüm alanlarda kullanılmaktadır. Yazıcı sarf malzemeler, günlük hayatta fark edilmeyen ve dikkate alınmayan pek çok alanda kullanılır en önemli malzemedir. Yazıcı sarf malzemeler; günlük hayatta kullanılan yaşam gereksinimlerindendir. Kitap basımı ve diğer fotokopi fiyatlarının yükselmemesi için bu alanda çalışan yatırımcılar yazıcı sarf malzemeler fiyatını en düşük seviyede tutmaya çalışmaktadırlar.

Ülkede yaşanan ekonomik ve politik olaylardan dolayı diğer malzemeler gibi yazıcı sarf malzemelerin de fiyatı dalgalanmaya ve yükselmeye maruz kalır. Ülkenin politik dalgalanması ve değişken ekonomik şartlar nedeniyle yazıcı sarf malzemeler de satış miktarı ve fiyat değişikliği açısından bu durumdan fazlasıyla etkilenir. Bu nedenle yatırımcılar istatistik yöntemler kullanarak yazıcı sarf malzemelerin satış miktarını ve fiyatını tahmin etmeye ihtiyaç duyar. Yukarıdakilere dayanarak, çalışma sorunu aşağıdaki ana soruya odaklanmıştır:

Irak'taki yazıcı sarf malzemeler satışlarının miktarını öngörmede en uygun istatistiksel model nedir?

Bu çalışmanın amacı, Box–Jenkins (p, d, q) SARIMA ve Yapay Sinir Ağı (YSA) modellerinden hangisinin yazıcı sarf malzemeler satış miktarını öngörmeye daha uygun model olduğunu belirleme ve seçilen modelin Irak'taki yazıcı sarf malzemeler satışlarının gelecekteki miktarını tahmin edebilme konusu üzerinde odaklanmaktadır.

Yazıcı sarf malzemeler le ilgili çalışma verileri, yazıcı sarf malzemeler satıcı firmalarına ait elle yazılmış kendi kayıtlarından alınmaktadır. Çünkü bu firmaların veri tabanları yoktu. Veriler Ocak 2008 – Aralık 2018 yılları arasında alınan verilerdir.

Çalışma sınırları şöyle ayrılmıştır:

- Zaman Sınırları: Ocak 2008 – Aralık 2018 arasında.
- Mekansal limitler: Irak'taki yazıcı sarf malzemeler satış firmaları.
- Nesnel sınırlar: Yazıcı sarf malzemeler satışlarının miktarı.

Bu çalışma beş bölümden oluşuyor. İlk bölüm, önsöz: Çalışmanın sorunu, çalışmanın amacını içeren genel bir giriş ile ilgilidir. İkinci bölümde; önceki çalışmalar ele alınacaktır. Üçüncü bölümde, kullanılan zaman serisi modellerinin teorik çerçevesi, zaman serilerinin tanımı ve bileşenleri, otokorelasyon fonksiyonu, Box-Jenkins metodolojisinin en önemli modelleri, ARIMA tanı testlerinin yanı sıra değerlendirmesi ve tahminler, sinir ağlarının tanımı, kullanımları, çalışma mekanizmaları, bileşenleri, yapıları, sinir ağlarının eğitilmesi ve tahminlerini içeren yapay sinir ağları açıklanacaktır. Dördüncü bölüm, Box-Jenkins yöntemi ile yapay sinir ağı yöntemi kullanılarak, Yazıcı sarf malzemeler satış hacmine ilişkin seri verileri inceleniyor. Söz konusu serinin gelecek değerleri tahmin etmenin en iyi yolunu belirlemek, iki model arasında ayırım yapmak için uygun istatistiksel testleri kullanmaya yöneliktir. Çalışmanın beşinci bölümündeysen ana önerileri ve çalışmada kullanılan referanslar sunulacaktır.

2. KAYNAK ÖZETLERİ

Yapay sinir ağlarını ve Box-Jenkins (B-J) metodunu kullanarak birçok zaman serisi çalışmaları vardır. Bu bölümde, bu konuyla ilgili daha önceki çalışmalar sunulacaktır.

Gerra (1959), yumurta endüstrisi için temel ekonomik sistemi teşvik ettiğine inanılan bir dizi davranış ilişkileri ve kimlikler sundu. Denklemlerin uygulandığı yılların ötesinde yumurta endüstrisindeki değişkenlerin değerlerini tahmin etmeye yönelik denklemlerin (bir ekonometrik model) kullanılmasıyla, yıllık miktar değişkeni (yerli yumurta tüketimi, çiftliklerde yumurta üretimi, ortalama sayı) için daha iyi tahminler yapıldığını belirtmiştir. Çiftliklerdeki tabakalar ve satılan sayı eşanlı denklem yaklaşımından elde edilmiş, depolama hareketi ve fiyat değişkenleri gibi bazı değişkenler için daha iyi tahminler en küçük kareler yöntemi ile elde edilmiştir.

Suits (1962), ABD ekonomisinin ekonometrik bir modelini sunarken bir tahmin aracı olarak kullanımını gösterdi ve politika analizi için etkilerini araştırdı. Sunumu iki bölüme ayırdı. Bölüm-I, ekonometrik modellerin genel doğası ile son derece sadeleştirilmiş şematik bir örnek kullanarak, bir modelle tahminlerin nasıl yapıldığını, bir modelin ek bilgi ve muhakeme kararının verilmesine nasıl izin verileceğini ve kısa süreli ve uzun vadede nasıl çalıştığını göstermektedir. Model politika çarpanları modelin tersinden elde edildi. Pat-II, ekonomide 32 denklemi sunmuştur.

Bluestone (1963), broyler döngülerini tahmin etmek için geleneksel mevsimsel ayarlama ve veri filtreleme yöntemlerini uygulamıştır. Dönemsel uyum için nüfus sayımı yöntemini istihdam etti ve “iyi tanımlanmış 4 döngü” olarak adlandırdığı şeyi buldu. Broyler civciv yerleşimleri için yaklaşık 27 aylık bir döngü gereklidir ve broyler fiyatları için yaklaşık 30 aylık bir döngü önerilmiştir. Bu döngülerde broiler fiyatlarında yaklaşık 21 aydır.

Tobin ve Arthur (1964), broyler piliç fiyatları için altı aylık bir uzun geçiş filtresi (basit Hareketli Ortalama) ve kuluçka tedarik sürülerinde on iki aylık bir uzunluk kullanmıştır. Elde edilen filtrelenmiş seri, her iki seri için yaklaşık 30 aylık döngüleri

ortaya çıkarmıştır. 30 aylık döngünün iki serisinin zirveleri arasında 12 ila 18 aylık bir zaman farkı vardı. Benzer bulgular Gross ve Ray tarafından da gözlemlenmiştir.

Schmitz ve Watts (1970), Amerika Birleşik Devletleri, Kanada, Avusturya ve Arjantin'deki buğday verimlerini tahmin etmek için parametrik modelleme kullanmışlardır. Bu yaklaşımın özü, verilerin, hareketli ortalama ve otoregresif süreç biçimindeki rastgele bileşenlerin tahminini tanımlamak için kullanılmasıdır. Ekonometrik modellerle tahmin yapılırken denendiği gibi yapısal ilişkiyi belirlemedi ve ölçmedi. Amerika Birleşik Devletleri ve Kanada'daki verimi tahmin etmek için üssel düzleştirme kullandılar. Ayrıca parametrik modelleme ile üstel düzeltme arasındaki tahmin doğruluklarını karşılaştırmışlardır.

Leuthold vd. (1970), Günlük domuz eti fiyatının ve niceliğin tahmin edilmesine yönelik yaptıkları çalışmada, farklı tahmin yaklaşımlarının tahminsel doğruluğunu karşılaştırmak için Theil'in eşitsizlik katsayısı kullanılmıştır. Fiyat tahminine göre, ekonometrik model, rassal yürüyüş modeli ve ortalama model ile arz tahminleri için ekonometrik model, rassal yürüyüş modeli, ortalama model ve zaman serisi modelleri karşılaştırılmıştır. Zaman serileri modellemesi için gerekli olan verilerin tahmin edilecek olan değişkenle ilgili veriler olduğu, ekonometrik modeller için ise hem regresör hem de regresyonda verilere ihtiyaç duyulduğu sonucuna varmışlardır. Bu nedenle ekonometrik model kullanan tahminler stokastik olmayan geçici bir çerçeve çalışması kullananlardan biraz daha iyidir. Ayrıca, ikincisinin kullanımında biraz daha büyük hata yapma maliyeti, bir ekonometrik modelin oluşturulmasında ve verilerin toplanmasında ek maliyetten daha az olacaktır.

Montanes et al. (2002), nükleer enerji verileri ile yaptıkları analiz sonucunda, YSA'nın daha iyi tahmin performansına sahip olduğu ve ARIMA modellerinin zaman serisindeki sistematik değişiklikleri tahmin etmediği sonucuna varmışlardır.

Ture ve Kurt (2006), hepatit A virüsü vakalarının öngörüsü için çok katmanlı, radyal tabanlı ve zaman gecikmeli olmak üzere üç farklı YSA ile ARIMA modellerini kullanmıştır. 13 yıllık zaman serilerinin analizinin sonucu olarak, çok katmanlı YSA programının diğer yöntemlerden daha iyi tahmin performansına sahip olduğu görülmektedir.

Karaboga (2007), Kanyakumari Bölgesi'ne ait seçilmiş malların fiyatlarını tahmin etmek için sadece Zaman serisi modelleri kullanmıştır.

Commandeur ve Koopman (2007), Box–Jenkins yaklaşımının temelde sorunlu olduğunu ileri sürmektedir. Sorun şu şekilde ortaya çıkmaktadır: “Ekonomik ve sosyal alanlarda, gerçek seriler asla durağan değildir, ancak çok farklıdır”. Böylece araştırmacı soruyla yüzleşmek zorunda: durağanlığa ne kadar yakın yeterli? Yazarların belirttiği gibi, "Bu cevaplanması zor bir soru". Yazarlar ayrıca Box–Jenkins'i kullanmak yerine, zaman serisinin durağanlığının gerekmediği hallerde, durum alanı yöntemlerini kullanmanın daha iyi olduğunu tartışmaktadırlar.

Cancela (2008), Bu çalışma, ortalama 4175 görüntüleme ile 1-2-1991 ile 1-2-2006 arasındaki günlük zaman serisi verilerine dayanarak sinir ağı modelleri ve dört ülke için (Almanya, İtalya, Yunanistan ve Portekiz) ARIMA döviz kurları arasındaki karşılaştırmayı incelemektedir. Sonuç, YSA modelinin üstün olduğunu göstermiştir ve tahminde kullanılmıştır.

Hamzaçebi et al. (2009), yaptıkları tahmin çalışmasında YSA, ARIMA ve kısmi uyarlamalı tahmin tekniklerini karşılaştırmışlardır. Çalışmanın sonuçları YSA'nın diğer metotlardan daha iyi tahmin performansına sahip olduğuna işaret etmektedir.

Akdağ (2015), Enflasyon beklentileri ülkeler için büyük bir önem taşımaktadır ve bu tahminlere göre yatırımlar yapılmaktadır. Gelişmekte olan ülkeler açısından enflasyon oranının düşük seyretmesi önemli hedeflerden birisidir. Bu nedenle geçmiş verilere bakarak geleceğe yönelik doğru tahminlerde bulunulması önemlidir. Kısa vadeli takdir çalışmalarında en uygun yöntemlerden birisi zaman serileridir. Bu çalışmada Box-Jenkins ve Yapay Sinir Ağları olarak bilinen yöntemlerle enflasyon verisine ait zaman serisi analizi kullanılmış ve sonuçlar karşılaştırmalı olarak sunulmuştur.

Garg vd. (2016), Bu çalışma, Delhi için Gürültü Kontrol Mühendisliği Enstitüsü'nden Aralık 2013 ile Ağustos 2014 arasındaki dönemde elde edilen günlük verilere dayanarak Box-Jenkins Modelleri ile yapay sinir ağlarının tahmin

yeteneklerini karşılaştırmaktadır. Sonuç olarak, YSA modeli, uyum sağlama konusunda ARIMA'dan daha iyi performans göstermiştir.

Safi (2016), Bu çalışma, 2000-2014 dönemi için Filistin Devleti'nin GSYİH verilerine dayanarak Box-Jenkins Modelleri ile yapay sinir ağlarının tahmin yeteneklerini karşılaştırmaktadır. Sonuç, YSA modelinin ARIMA modelinin performansından daha üstün olduğunu göstermiştir.

Gao et al. (2017), Bu çalışma, ARIMA ve Yapay Sinir Ağı YSA modellerini, 22 Mart – 14 Temmuz 2010 tarihleri arasındaki zaman serisi verilerine dayanarak İngiltere enerji piyasası için elektrik fiyatları ile karşılaştırmaktadır. Çalışma, ARIMA modelinin, RMSE ölçeğinin öngörme doğruluğuna göre YSA modeline kıyasla iyi bir gelişme sağladığını göstermiştir.

Nury vd. (2017), Bu çalışma, Kuzeydoğu Bangladeş'in sıcaklık verilerine dayanarak Box-Jenkins Modelleri ile yapay sinir ağlarının tahmin yeteneklerinin arasındaki karşılaştırmayı incelemiştir. Bu karşılaştırma modelleme için 1957-2000 yılları arasındaki eğitim verileri ve performanslarını tahmin etmek için 2001-2012 yılları arasındaki veri grubundan oluşan iki veri kümesidir. Sonuçlar Box-Jenkins'in Modeli olan ARIMA YSA modelinden daha iyi performans sahip olduğu gösterdi

Ighravwe ve Anyaeche (2019), Bu çalışma, Nijerya'nın Apapa limanından toplanan verilere dayanarak Box-Jenkins Modelleri ile yapay sinir ağlarının tahmin yeteneklerinin arasındaki karşılaştırmayı incelemiştir. Geminin limanda ve rıhtımda geçirdiği günlerdir. Çalışma, YSA modelinin ARIMA modelinden daha üstün olduğunu göstermiştir.

Pandey (2019), Bu çalışma, Ocak 2007-Aralık 2016 tarihleri arasında Hindistan'da borsa günlük verilerine dayanarak Box-Jenkins Modelleri ile yapay sinir ağlarının tahmin yeteneklerini karşılaştırmaktadır. Sonuç, YSA modelinin ARIMA modelinden daha üstün olduğunu göstermiştir.

3. MATERYAL VE YÖNTEM

İstatistiksel alanlarda kesin tahminler oldukça önemlidir. Bu nedenle bu çalışmada, Irak'taki yazıcı sarf malzemeler satış miktarının tahmini için Box-Jenkins (B-J) Otoregresif ve Bütünleşik Hareketli Ortalama ARIMA (p,d,q) modeli metodolojisinin kullanımı ele alınacaktır. Box-Jenkins metodolojisinin kullanımı birkaç aşamadan geçmelidir (Abraham, 1983). Birincisi tanımlama aşamasıdır. Bu aşamada, verilere uygun başlangıç modeli seçmek için otokorelasyon'un nasıl kullanılacağı belirlenecektir. İkinci aşamada, verilere uygun model parametrelerinin tahmin edilmesi gerekir. Üçüncü aşama, ilk modelin uygunluğunu araştırmak için öncelikli testler ve belirtme incelemeleri ile ilgili çalışmalarla odaklanılacaktır. Son olarak dördüncü aşamadaysa, önerilen tahmin yöntemi, özellikleri, hataların tahmini ve çalışılan seri verilerinin gelecekteki değerlerinin nasıl tahmin edileceği ele alınacaktır.

Yapay Sinir Ağları (YSA), YSA tahmini, modern bir tahmin aracıdır. YSA, ağı öğrenme ve kendiliğinden eğitime yoluyla herhangi bir model (seri) ile başa çıkma yeteneğine sahiptir.

YSA, birbiriyle ilişkili birkaç işlem elementinden oluşan aritmetik bir sistem (Elements Processing) olarak tanımlanmakta ve içine giren verilerin işlenmesinde dengeli, dinamik yapısı ile karakterize edilmektedir. YSA, bilinebildiği kadarıyla canlı organizmalarda sinir ağını simüle etmek için kullanıldığından dolayı kendisine "Yapay Sinir Ağı" adı verilmiştir (Allend, 1999).

YSA bileşenleri: Yapay sinir ağı, nöron adı verilen bir hücre grubundan veya nörotransmitter (Connections Neural) ile birbirine bağlı bir grup düğümden ya da bir grup ağırlıklardan oluşmaktadır.

3.1. Zaman Serisi

Zaman Serisi (Time Series); zaman silsilesine dayalı olarak sıralanmış belli bir istatistiksel göstergenin takım değerleri olarak tanımlanabilir. Zaman Serisi kavramının basit analizi ise belli bir olayın tarihsel sıralamasını açıklayabilen matematiksel bir modelin kestirilmesi veya öngörülmesidir, bu model sayesinde zaman serisi değerlerini çok net ve dakik olarak kestirebilme imkânı vermenin yanı sıra belli olan olayın ileriki değerlerini öngörme ve tahmin etmek için kullanılabilir. Zaman serisi analiz yöntemi ise, aralarında herhangi bir iç bağlantı olmayan, kalıntı (hatalar) oranı en düşük seviyede bırakan verilerin tabiatına uygun matematiksel bir modelin oluşturulmasına dayanmaktadır (Anderson, 1971).

Zaman Serisini çeşitli bilgi ve değişik uygulama alanlarında gözlemek mümkündür, bu ve uygulama alanlarının başında ekonomi, eğitim, tıp, çevre, meteoroloji, tarım, kimya ve mühendislik gelmektedir, zaman serisinin bir kısmı olan talepler ile ilgili veriler gün, ay ve yıl gibi tarihsel olarak temsil edilmektedir. Bununla birlikte zaman serisi, oluş zamanına göre sıralanmış değişkenlerden alınmış ölçümlerin bir grubundan ibarettir. Milli gelir, işsizlik, sanayi üretimi ve benzeri ekonomik etkinliklere dair zaman serisi önemli zaman serilerinden sayılmaktadır, aynı şekilde ticaret ve sanayi şirketlerinin belli bir zaman süreci içerisinde yıllık satış ciroları için de geçerlidir. Bu demek değildir ki zaman serisi sadece ticaret ve ekonomi alanı için geçerlidir, bu konu örneğin belli bir bölgedeki yağmur miktarının ölçülmesi, herhangi bir eğitim kurumundaki öğrenci sayısı veya belli bir bölgenin nüfus yoğunluğu gibi alanları da kapsar. Öngörü işlemi elektrik, ekonomi ve benzeri birçok bilim alanı için yaygın bir konu olduğundan uzunca zaman öncesinden istatistikçilerin dikkatini çekmektedir (Lendasse, 2000).

3.1.1. Zaman Serisi Çeşitleri

Zaman Serisi; zaman sürecine göre birbirlerine bağlı sürekli (Continuous) ve ayrık olarak sürekli olmayan (Discrete) iki çeşit olarak tasnif edilebildiği gibi zaman etkisine bağlı olmayan özelliklere sahip olan serilere istikrarlı, zaman etkisine bağlı olan özelliklere sahip serilere ise istikrarsız seriler denir.

(Box ve Jenkins, 1976) Zaman Serisini; belli bir olayın zaman süreci içerisinde (Yıllık, çeyrek yıllık, aylık, haftalık, günlük) kayıt altına alınmış birbirine bağlı seri gözlemler grubu olarak tanımlamıştır, bu zaman serisi aralıklı ve aralıksız sürekli olan iki çeşit silsileye ayrılmaktadır.

Zaman Serisi modeli, zaman serisi değerlerini hataları ile önceki değerlere bağlayan fonksiyondur, istatistiksel zaman serisini bu formülle gösterebiliriz:

$$Z_t = f(t) + \varepsilon_t \dots; t = 0 \pm 1 \pm 2 \quad (3.1)$$

$f(t)$: Matematiksel fonksiyon ile gösterilen düzenli kısmı temsil eder.

ε_t : Beyaz gürültü diye adlandırılan rasgele kısmı temsil eder.

3.1.2. Zaman Serisinin Öğeleri

Zaman Serisinin incelenmesinin bir amacı da inceleme konusu olgunun tanımını yapmak ve bu olguyu toplam süre içerisinde direkt olarak etkiyen veya maruz kaldığı değişik etkenleri bilmektir. Aslında diyebiliriz ki, bu olguda muhtelif zaman dilimleri (periyotlar) içerisinde meydana gelen değişikliklere dört ayrı etken neden olmaktadır (Anderson, 1971) bunlar da:

- Genel Eğilim (Yön)
- Mevsimsel Değişimler
- Dönemsel Değişimler
- Arızı veya Düzensiz Değişimler

3.1.2.1. Genel Eğilim

Zaman Serisi genel trendi uzun vadeli temel değişimlerdir, bu değişimlerin en önemli özelliği ise değişimin çok yavaş ilerlemesi ve kademeli olarak kendini göstermesidir, kısa sürelerde görülmezken uzunca bir süre sonra belirlenmeye başlar ve aynı zamanda uzunca bir süre tek bir yönde devam eder. Genel Trend düşüncesi uzun

vadeli planlama işleri için çok faydalı olmuştur, özellikle de istikrarlı ve sürekli etkenlerden etkilenen nüfus artışı ve ekonomik kalkınma gibi sosyal ve ekonomik oluşumların ölçümlemesinde yararlı olduğu görülmektedir. Uzun vadeli etkenlerden etkilenmeyen ekonomik faaliyetlerin ölçümlemesinde genel trend metodunu kullanmak mümkün olmadığından bu gibi ölçümlemelerde dönemsel, mevsimsel ve arazi etkenlerden oluşan zaman serisinin istikrarlı olmayan ögesine başvurmamız gerekmektedir. Kamu bütçesinin yönetimi gibi planlama ve kısa vadeli öngörülerin oluşmasında önemli bir yer alan etkenlerdir.

3.1.2.2. Mevsimsel Değişimler

Bazen haftalık, bazen aylık veya mevsimlik olmak üzere süresi bir yılı geçmeyen ve belli zaman aralıklarında meydana gelen değişimlerdir. Yani değişik zaman dilimleri içerisindeki haftalarda, aylarda veya mevsimlerde ortaya çıkan benzer değişimlerdir diye tanımlayabiliriz. Buna örnek olarak Bayram zamanlarında elbise satışları, elektrik enerjisi tüketimi, bayram ve belli günlerde tebrik kartlarının satışı.

3.1.2.3. Dönemsel Değişimler

Zaman serisi değerlerinde meydana gelen ve süresi bir yıldan fazla olan düzenli veya düzensiz değişimler ile değişik uzunluk ve hacimdeki zaman serisi verilerinin belli dönemlerde gösterdiği değişikliklerdir. Buna örnek olarak devletlerin kalkınma, duraklama ve sonrasında gelen gerileme dönemlerindeki ekonomik gelişim süreçlerine orantılı olan ekonomik faaliyetlerin değişim etkisini gösterebiliriz.

3.1.2.4. Arazi veya Düzensiz Değişimler

Yukarıda sıraladığımız kategorilere girmeyen ve açıklanması mümkün olmayan hatalara dayalı olarak ortaya çıkan etkenleri arazi veya ani değişimler olarak niteleyebiliriz, bunların sonucu olarak düzenli olmayan tesadüfi etkenler diye adlandırılır, örnek olarak savaş, deprem, su taşkınları ve siyasi gelişmeler gibi olayların satışları etkileyen olağanüstü etkenlere gelişigüzel değişimler diye tanımlanır ve etkileri de olayın sona ermesinden sonra ortadan kalkar.

Son olarak, bu ögeleri tanımak ve değerlendirmek zaman serisi çalışmasının hedeflerinden birisidir. Genel trendi bilmek bize uzun vadeli planlama yapmamıza yardımcı olacağı gibi ileride meydana gelebilecek olan olayları da kestirmemize vesile olur, mevsimsel veya dönemsel değişimleri bilmemiz ise bizlere kısa vadeli planlamada yardımcı olacaktır.

3.1.3. Zaman Serisi Kavramları

Zaman Serilerini analiz edebilmek için aşağıda sıralanan kavramlara değinmek gerekir:

Zaman Serisini iki ayrı sınıfa ayırmak mümkündür, bunlar istikrarlı zaman serisi ile istikrarsız zaman serisidir.

Zaman serisi analizlerinde ve uygun matematiksel modelin kurulmasında, verilerin istikrarlı veya istikrarsız olması önem arz etmektedir. $(t, h + t)$ süreci içerisinde zaman serisinin çizimi bazı zamanlarda başka bir süreç içerisinde $(s, h + s)$ çizilen zaman serisi ile aynı olabilir, bu demektir ki serilerin davranışları arasında zamansal bir uyum söz konusu olduğu ve buna da istikrarlı yani düzenlilik (Stationary) denir (Voind, 1999).

Bütün ekonomik uygulamalarda zaman serisinin durağanlık özelliği taşıdığı varsayılır, burada Box-Jenkins modellerinin analizindeki ilk adımın zaman serisinin durağan ve hareketsiz olmasından emin olunması gelmektedir, durağanlık ise istatistikte zaman serisi hesaplama ortamı ile bilinenlerin sabit olduğu anlamına gelmektedir (Lendasse, 2000).

Zaman süreci içerisinde istatistiksel özelliklerin sabit olması durumunda zaman serisinin durağandır denir, yani bu özelliklerin ileri veya geri yayılım durumu bulunmamakla birlikte zaman birimleri sayısı da tam istikrarlı ve zayıf istikrarlı diye iki çeşitten oluşur (Voind, 1999).

3.1.3.1. Tam İstikrarlı

Herhangi sabit bir veriden seçilen bütün zaman noktalarının $(t_1, t_2, \dots, t_m)$ herhangi bir gözlem (değişkenler) grubu ortak dağılım olasılığı $(X_{t1}, X_{t2}, \dots, X_{tm})$ ile $(X_{t1+k}, X_{t2+k}, \dots, X_{tm+k})$ ortak dağılım olasılığının aynı olması durumunda o zaman serisi veya rastgele işleme (Y_t) tam durağan (istikrarlı) denir (Priestley, 1981).

$$\Pr (X_{t1}, X_{t2}, \dots, X_{tm}) = \Pr (X_{t1} + k, X_{t2} + k, \dots, X_{tm} + k) \quad (3.2)$$

Yukarıdaki şartın yerine getirilmesi halinde bu seri tam durağan (istikrarlı) olur.

3.1.3.2. Zayıf İstikrarlı

Zayıf durağanlık kavramı, ortalama ile varyansın sabit olması kaydıyla zamanla değişkenler ortak dağılım olasılığının $(X_{t2}, X_{t1}, X_{tm}, \dots)$ belli düzeylerde değişmesine izin vermektedir, aynı zamanda değişimin $\text{COV}(X_t, X_{t+k})$ zamana (t) dayalı olmayıp sadece yavaşlama sürelerinin (K) göstergesi olması gerekmektedir. Özel bir halde ise, $E(X_t = \mu)$ nin zamana (t) dayalı olmayıp sabit bir miktar olduğunda zaman serisine (X_t) Birinci Dereceden İstikrarlı (First Order Stationary) denir.

Aşağıda sıralanan şartların oluşması durumunda ise zaman serisine (X_t) İkinci Dereceden İstikrarlı (Second Order Stationary) zaman serisi denir (Priestley, 1981).

- Zaman serisi ortalaması sabit olduğunda

$$E(X_t) = \mu \quad (3.3)$$

Burada (μ) rasgele sürecin ortalaması olup zamana (t) dayalı olmayıp sabittir. Bu ortalama aşağıda yer alan zaman serisi gözlemlerinden tahmin edilir:

$$\hat{\mu} = \bar{X} = \frac{1}{n} \sum_{t=1}^n Y_t \quad (3.4)$$

- Zaman serisi varyansı sabit olduğunda

$$\text{var}(X_t) = E(X_t - \mu)^2 = \sigma_x^2 = \gamma_0 \dots \quad (3.5)$$

Burada (γ_0) rasgele sürecin farklılığı olup zamana (t) dayalı olmayıp sabittir. Bu farklılık aşağıda yer alan zaman serisi gözlemlerinden tahmin edilir:

$$\hat{\gamma}_0 = \frac{1}{n-1} \sum_{t=1}^n (X_t - \bar{X})^2 \quad (3.6)$$

- Oto – Değişim (Zaman Serisi Ortak Varyansı)

$$\text{cov}(X_t, X_{t+k}) = E(X_t - \mu)(X_{t+k} - \mu) = \gamma_k \quad (3.7)$$

Burada γ_k sapma K sırasındaki rasgele işlemin oto-değişimini gösterir, k dan itibaren bütün gerçek değerleri için zamana (t) dayalı olmayıp sabittir. Bu farklılık aşağıda yer alan zaman serisi gözlemlerinden tahmin edilir:

$$\hat{\gamma}_k = \frac{1}{n} \sum_{t=1}^n (X_t - \bar{X})(X_{t+k} - \bar{X}) \dots \quad (3.8)$$

($\hat{\gamma}_k$; $k = 0 \pm 1 \dots$) Grubuna Oto-Değişim Fonksiyonu (Auto Covariance Function) denir.

3.1.4. Zaman Serilerini Düzenli Hale Getirmek

Zaman serileri genellikle ya süreç ortalamasında ya da değişkenlerinde sabit değildir. Zaman Serisinin düzenli bir silsileye dönüştürülmesi için birden çok metot bulunmaktadır (Hamilton, 1994).

3.1.4.1. Süreç Ortalamasında Düzensiz Olan Zaman Serileri

Zaman serisi verilerinin sabit bir ortam çevresinde akmaması halinde, bu ortalama düzenli olmayan zaman serisi demektir, süreç ortalamasında serinin düzenli olmasını sağlamak için uygun olan değişkenleri (d) alırız.

Eğer X_t Serisi düzenli olmayan bir zaman serisini gösteriyor ise; bu serinin düzenli hale dönüştürülmesi bu şekilde olur (Spyros, 1983):

$$Y_t = \Delta^d X_t \quad (3.9)$$

Burada $\Delta = B-1$: Şayet

$$B X_t = X_{t-1} \quad (3.10)$$

$$B^2 X_t = X_{t-2} \quad (3.11)$$

B geriye doğru kaydırma etkeni olarak adlandırılır.

Zaman serisinin değişkenlerini (d) ele almanın amacı o zaman serisinin düzenliliğini (istikrarını) sağlamaktır, genellikle de bunun değeri $d = 1, 2$ ye eşittir (Anderson, 1976).

Değişkenler süreci, öz bağlantı değerlerinin sıfıra düşürülmesi için sürekli olan mekanik bir görevdir. Bu görev iki veya üç geriye doğru zaman süreçlerinde gerçekleşir (Ljung, G., 1985) Birden fazla bir farklılığı uygulamakta mümkün olmakla birlikte genellikle Birinci ve İkinci fark yeterlidir.

3.1.4.2. Değişkenlerde Düzenli Olmayan Zaman Serileri

Sağlam ve dinamik bir modelin elde edilmesinin en temel problemlerinden birisi de değişkenlerin sabit olmamasıdır. Bu problemin giderilmesi yolu ise zaman serisi dönüştürücülerinin (Logaritma veya Karekök ...v.b. gibi) alınmasıdır (Vandaele, 1990) zaman serisi dönüştürücülerinin alınması suretiyle düzenli zaman serileri elde etmemize yardımcı olur.

Özellikle pozitif bir seri için geçerli yaygın olan Dört adet dönüştürücü bulunmaktadır, varsayalım asli seri olan $Y_t > 0$ ve X_t de dönüştürülen seridir, buna göre dönüşümler (Priestley, 1981):

- $X_t = \ln(Y_t) \dots \dots \dots$ Algoritma Dönüşümü
- $X_t = \ln\left(\frac{CY_t}{1-CY_t}\right) \dots \dots \dots$ Lojistik Dönüşüm
- $X_t = \sqrt{1/y_t} \dots \dots \dots$ Karekök Dönüşümü
- $X_t = \begin{cases} \frac{Y_{t-1}^\lambda}{\lambda} \\ \ln(y) \end{cases} \dots \dots \dots$ Box & Cox Dönüşümü

3.1.5. Düzenlilik Ölçme Testleri

Herhangi bir zaman serisinin düzenliliğini ölçmek için çok sayıda test metodu bulunmaktadır, bu testlerden bir kısmı aşağıda gösterilmektedir:

3.1.5.1. Dickey – Fuller Testi

Bu test sayesinde serinin düzenli olup veya olmadığına karar verilebilir. Basit olan Dickey – Fuller (DF) testi üç adet basit denkleme dayanmaktadır, bu denklemlerde (1) inci seviye öz sapma modellerinden rasgele olgunun bulunduğu varsayılmaktadır (Dickey, 1981):

$$1 - \Delta X_t = \alpha_1 X_{t-1} + e_t \quad (3.12)$$

$$2 - \Delta X_t = \alpha_0 + \alpha_1 X_{t-1} + e_t \quad (3.13)$$

$$3 - \Delta X_t = \alpha_0 + \alpha_1 X_{t-1} + B_t + e_t \quad (3.14)$$

Δ : Birinci Değişken Katsayısı, yani $X_t = X_t - X_{t-1}$

e_t : Beyaz Gürültü Değişkeni (White Process Noise)

3.1.5.2. Genişletilmiş Dickey Fuller Testi

Basit Dickey Fuller testi (DF) sadece (1) inci seviyeden olan öz sapma modelleri ile sınırlı kalmaktadır. Dickey& Fuller bu sefer (1) inci seviyeden büyük olan öz sapma modellerini kapsayacak şekilde testi büyütme yoluna gitmiştir. Bu test aşağıda sıralanan Üç denkleme dayanmaktadır (Dickey, 1981):

$$\Delta X_t = \alpha_1 \sum_{j=1}^p B_j \Delta X_{t-1} + e_t \dots \quad (3.15)$$

$$\Delta X_t = \alpha_0 + \alpha_1 X_{t-1} + \sum_{j=1}^p B_j \Delta X_{t-1} + e_t \quad (3.16)$$

$$\Delta X_t = \alpha_0 + \alpha_1 X_t + \sum_{j=1}^p B_j \Delta X_{t-1} + e_t \dots \quad (3.17)$$

e_t : Beyaz Gürültü Değişkenini temsil etmektedir.

Burada gerçekleşen test Basit Dickey Fuller testinin aynısıdır $H_0: \alpha_1=0$ (Birleşme Kökü Bulunmakta)

3.1.5.3. Phillips ve Perron (PP) Testi

Bu testte (Perron, 1987) basit Dickey Fuller testinde karşılaşılan rasgele hatanın belirlenmemesi ile standart olmayan otokorelasyon fonksiyon problemlerini ortadan kaldırmaktadır.

3.1.5.4. KPSS Testi

(Kwiatkowski ve Phillips, 1992) Zaman serisi istikrarını test etmek üzere geliştirilen Dickey–Fuller Testinin tamamlayıcısı olan yeni bir testi geliştirdi. Bu testte; Dickey–Fuller testinde varsayılan zaman serisinin düzenli olmaması ve yönünün olmamasının aksine, zaman serisinin düzenli ve istikrarlı olduğu varsayılmaktadır.

3.1.5.5. Ljung-Box Testi

Box-Pierce testinin aynısı olan alternatif bir test daha bulunmaktadır, bu testin adı Box-Ljung olup Q örnekleme halinde bu formül ile gösterilmekte ve m den daha doğru sonuçlar vermektedir (Hill, 2011).

$$LB = n(n + 2) \sum_{k=1}^m \frac{\bar{p}^2}{n-k} \quad (3.18)$$

m: Zaman aralıklarının sayısı

Bu testin büyük hacimli örneklerin yanı sıra küçük hacimli örneklerin en küçük hacimli Q değerinden büyük olan değere eşit kareköklü dağılıma sahiptir, burada elde edilecek olan Q değeri tablo değerinden büyük ise otokorelasyon fonksiyonun

parametreleri sıfıra eşit olduğu varsayımını reddederek serinin durağan olmadığını Kabul edebiliriz, $H:P_k = 0$ varsayımın reddi.

3.1.5.6. Fonksiyonu ile Kısmi Otokorelasyon Fonksiyonu

İncelenmekte olan bir zaman serisinin düzenli olup veya olmadığının bilinmesi hususunda Otokorelasyon Fonksiyonu (ACF) ile Kısmi Oto-Korelasyon Fonksiyonu (PACF) konusunu araştırmak önem arz etmektedir. Bu araştırma ve inceleme, ya çalışmaya konu olan olayın grafiğinin ya da Otokorelasyon Fonksiyonu (ACF) ile Kısmi Oto-Korelasyon Fonksiyonunun (PACF) gözlemlenmesi ile mümkün olur, bu konu aşağıda daha detaylı bir şekilde ele alınmıştır:

- **Otokorelasyon Fonksiyonu (ACF)**

Değişkenler arasında korelasyonun (Bağlantı) anlamı bir zaman serisi içerisinde yer alan seri değişkenlerin arasında bir ilişkinin var olduğudur, değişkenler veya gözlemler birbirleri ile bağlantılıdır denilmektedir.

Otokorelasyon ise muhtelif sapma süreçlerinde (k) aynı değişken içerisinde bulunana değer arasında var olan ilişki derecesini açıklayan bir gösterge olup bunun değeri de (1 veya - 1) arasında değişmekte yani $(-1 \leq \rho_k \leq 1)$ olduğu ve bu formül ile hesaplanır (Box, 1970):

$$\rho_k = \frac{\gamma_k}{\gamma_0} = \frac{k \text{ Noktasındaki Değişim}}{\text{Farklılık}} \quad (3.19)$$

Zira:

$$\gamma_k = \frac{\sum (y_t - \bar{y})(y_{t+k} - \bar{y})}{n - k - 1} \quad (3.20)$$

n = Örneğin Hacmi.

K = Zaman Dilimi Uzunluğu

$$\gamma_0 = \frac{\sum (y - \bar{y})^2}{2n - 1} \quad (3.21)$$

Oto–Korelasyon işlemlerinin istatistiksel dağılımı sıfır ortalamalı ve $\frac{1}{n}$ farklı hesap ortamında doğal bir dağılımdır. Burada $n = 0, 1, 2, 3, \dots, \rho_k \sim N\left(0, \frac{1}{n}\right)$ (Bartlett, 1946)

Zaman serisi ortalamasında çıkış veya iniş yönünde bir hareketlenmenin bulunmasından dolayı düzensiz bir zaman serisi ise, örneğin (ACF) fonksiyonu kesilmez ve sıfıra doğru yavaşça sarmaz, bunda nedeni gözlemler, zaman serisinin birden çok zaman süreçleri içerisinde hesap ortamının yönüne doğru sarmaya meyilli olduğundandır. Bunun sonucu olarak da uzun vadeli sapma süreçlerinde çok sayıda oto – korelasyona rastlamak mümkündür (Brockwell, 1994).

Kalıntılara ait Oto–korelasyon fonksiyonu, modelin uygunluğunun test edilmesi için önemli bir araç olup bu testte kalıntı hatalarının rastlantılarını test etme yolu ile bu şekilde olur (Vandall ve Walter, 2004).

$$\rho_k = \begin{cases} 1 & k = 0 \\ 0 & k \neq 0 \end{cases}$$

Oto–Korelasyon Fonksiyonu (ACF) Özellikleri

- $1 = \rho_0$ demektir ki otokorelasyon (ACF) katsayısının 0 noktasında tam Birdir.
- $\rho_k = \rho_{-k}$ Burada otokorelasyon (ACF) fonksiyonu, önemli olan süreç boyu K olduğundan önündeki işarete bakılmaksızın pozitif değer alır.
- $|\rho_k| \leq 1$ Otokorelasyon (ACF) katsayısının mutlak değeri Bire eşit veya daha azdır.
- ρ_k Değerinin Tam Bire yakın (+1.0) veya (- 1.0) ise seri olan pozitif veya negatif zaman serisi gözlemleri arasındaki ilişki büyük olur.
- ρ_k Değeri sıfıra yaklaştığı sürece zaman serisi gözlemleri arasındaki ilişki de zayıflar, bu değer sıfıra eşit olması halinde ise gözlenen değerler arasında herhangi bir bağlantının bulunmadığı demektir.
- Otokorelasyon serisi her zaman tam pozitifdir (Shaarawi, 2005)

- **Kısmi Otokorelasyon Fonksiyonu (PACF)**

Zaman serisi değerlerinin sabit olduğu varsayılarak aynı seri içerisindeki Z_{t-k}, Z_t arasında asılı kalanları ölçen bir göstergedir. Bu gösterge AR(P) Seviyesindeki otosapma modelinin en son sınırı olarak tanımlanmaktadır. Kısmi otokorelasyon fonksiyonu katsayısı oto-bağlantı yolu ile elde edilebilir (Shaarawi, 2005).

Kısmi otokorelasyon fonksiyonu (PACF) zaman serisi analizinde kullanıldığı gibi istikrarlı olan rasgele işlem modelleri grubu içerisinde en uygun modeli seçmek, seviyesini belirlemek ve kalıntı hatalarının rasgele testi yolu ile örnek verilerine uygun olup veya olmadığını test etmek içinde kullanılmaktadır.

ϕ_{kk} Değeri, aralarında oluşan $z_{t-1}, z_{t-2}, \dots, z_{t-k-1}$ değişkenler sonucu ortaya çıkan bağlantı etkisinin giderilmesinden sonra Z_t ve Z_{t-k} arasındaki bağlantı değerini vermektedir. Geri yayılma (k) sürecinde (ϕ_{kk}) ile sembolize edilir ve hesaplanmasının bir metodu da kısmi sapma katsayısı ϕ_{kk} hesabı ile yapılmaktadır.

Düzenli olan zaman serisine ait kısmi otokorelasyon fonksiyonu (PACF), sapma süreleri arttıkça sıfıra doğru hızlı bir sapma eğilimi gösterir veya belli sayıdaki (k) sapma süreleri sonrasında tamamen kesilir (Anderson, 1942).

Kısmi Otokorelasyon Fonksiyonunun (PACF) Özellikleri

- Kısmi otokorelasyon fonksiyonu (PACF) katsayısı, herhangi bir düzenli işlemde Sıfır noktasında Bir'e eşit olur, yani $\phi_{00} = 1$ dir.
- ϕ_{kk} Değeri her zaman kapalı süreç $[-1, 1]$ içerisinde yer alır.
- Z_t, Z_{t-1} arasında değişkenlerin bulunmamasından ötürü, Birinci zaman dilimi içerisindeki kısmi otokorelasyon fonksiyonu (PACF) katsayısı daima birinci zaman dilimi içerisindeki otokorelasyon fonksiyonuna eşittir, yani $\phi_{11} = \rho_1$ dir.

- Şayet $\phi_{kk} = 0$ ise bu demektir ki herhangi bir zaman dilimi değişkenleri K arasında kısmi doğrusal bir ilişkinin bulunmadığı anlamına gelmektedir, buna rağmen aralarında doğrusal olmayan kısmi bir ilişkinin bulunması da mümkündür (Shaarawi, 2005).

3.1.6. Zaman Serisi Modelleri

Bu bölümde rastlantı sonucu oluşan zaman serileri modellerini ele alacağız, bu modellerin en önemli olanları ise Otoregresif Modeli (Autoregressive Model (AR)), Hareketli Ortalama Modeli (Moving Model Average (MA)), Otoregresif Hareketli Ortalama Modeli (Mixed Autoregressive Moving Average Model (ARMA)), Bütünleşmiş Otoregresif Hareketli Ortalama Modeli Autoregressive Integrated Moving Average Models (ARIMA) ve Dönemsel Bütünleşmiş Karmaşık Ortalama Modeli (SARIMA) dir.

3.1.6.1. Dönemsel Olmayan Otoregresif Model (AR)

Durağan ya da istikrarlı zaman serilerini inceleyenlerin öncülerinden olan Yule, 1926 Yılında otoregresif AR (P) modelini ele almış ancak 1931 Yılında Wilker isimli bilim İnsanı tarafından otoregresif modelleri için genel bir modeli ortaya çıkarmıştır (Priestley, 1981).

$\{\alpha_t | t \in T\}$ ' nin 0 ortalama ve α_a^2 varyansı ile Beyaz gürültü işlemi olduğunu varsayalım, bu işleme $\{X_t | t \in T\}$ p seviyesinde otoregresif AR (p) işlem denilir (Anderson, 1976; Powell, 1997; Xuan, 2004).

p seviyesinde otoregresif AR (p) İşlem Modeli Genel Karakteristiği ise:

$$y_t = \mu + \phi_1 y_{t-1} + \phi_2 y_{t-2} + \dots + \phi_p y_{t-p} + \varepsilon_t \quad (3.22)$$

ε_t Beyaz gürültü eğimini (Rasgele Eğim) temsil etmekte olup 0 ortalama ve σ_ε^2 varyansı ile doğal bir dağılım gösterir. μ sabittir ve $1 \leq \phi \leq 1$ dir. $\phi_1, \phi_2, \dots, \phi_p$ Otoregresif modelin bilinenlerini temsi eder.

Bu karaktere otoregresif AR denir ve şimdiki ile önceki özelemler arasında olan ilişkiyi temsil eder.

Bu türden olan AR Modelinin otokorelasyon fonksiyonu kademeli bir şekilde aşağıya azalarak eğik bir şekil almakla birlikte sapma periyotları (k) artar ve p periyodu sonunda buna ait olan kısmi otokorelasyon fonksiyonu kesilir (Ameen, 2005).

3.1.6.2. Dönemsel Otoregresif Modeli (SAR)

Bu modelin genel şekli bu şekilde formüle edilebilir:

$$y_t = \phi_s y_{t-s} + \phi_{2s} y_{t-2s} + \phi_{ps} y_{t-ps} + \varepsilon_t \quad (3.23)$$

Burada: ϕ_s Dönemsel otoregresif karakterini gösterir, P Dönemsel modelin derecesini gösterir.

3.1.6.3. Dönemsel Olmayan Hareketli Ortalama Modeli (MA)

$\{\varepsilon_t | t \in T\}$ 'nin 0 ortalama ve σ_ε^2 varyansı ile Beyaz gürültü işlemi olduğunu varsayalım, bu işleme $\{x_t | t \in T\}$ q seviyesinde hareketli ortalama $MA(q)$ işlem denilir (Vandaele, 1990; Powell, 1997).

Birdn fazla Bilim İnsanı hareketli ortalama $MA(q)$ modelini incelemiş ve bu modeli (q) seviyesinde bu şekilde formüle etmiştir:

$$y_t = \mu - \theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2} - \dots - \theta_q \varepsilon_{t-q} + \varepsilon_t \quad (3.24)$$

Burada:

ε_t Rasgele eğimi temsil etmekte olup 0 ortalama ve σ_ε^2 varyansı ile doğal bir dağılım gösterir, μ sabittir ve $-1 \leq \theta \leq 1$ dir.

$\theta_1, \theta_2, \dots, \theta_p$ Otoregresif modelin bilinenlerini temsi eder ve halihazır gözlem değeri ise şimdiki ile önceki gözlemler arasındaki rasgele hatalara dayanır.

Bu türden olan MA Modelinin otokorelasyon fonksiyonu (ACF) (q) Sapmasından sonra kesilir ya da sıfıra doğru yaklaşırken kısmi otokorelasyon fonksiyonu (PACF) eğik bir şekilde azalır (Ameen, 2005).

3.1.6.4. Dönemsel Hareketli Ortalama Modeli (SMA)

Yavaşlama (L) Faktörünü kullandığımız zaman:

$$Y = \Theta_s(L^s)_{\varepsilon_t} = (1 - \Theta_s L^s - \Theta_{2s} L^{2s} - \dots - \Theta_{Qs} L^{Qs})_{\varepsilon_t} \quad (3.25)$$

Q seviyesinde dönemsel hareketli ortalama modeli ana formülü bu şekilde olur:

$$Y_t = \varepsilon_t - \Theta_s \varepsilon_{t-s} - \Theta_{2s} \varepsilon_{t-2s} - \dots - \Theta_{Qs} \varepsilon_{t-Qs} \quad (3.26)$$

Burada Θ_s dönemsel hareketli ortalama modeli $-1 < \Theta < 1$ karakterini temsil etmektedir, Q Dönemsel Modelin derecesini, S Dönem periyodu uzunluğunu temsil eder.

3.1.6.5. Karmaşık Model (Oto regresif ve Hareketli Ortalama) (ARMA)

Bu model oto regresif modeller ile hareketli ortalama modellerinin karışımından ortaya çıkmakta olup ARMA (p,q) ile gösterilmekte ve verilerin durağan yani istikrarlı olması halinde kullanılmaktadır. Bu modelin (p,q) derecesindeki genel formülü ise (Box – Jenkins, 1976):

$$y_t = \mu + \phi_1 y_{t-1} + \phi_2 y_{t-2} + \dots + \phi_p y_{t-p} + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2} - \dots - \theta_q \varepsilon_{t-q} \quad (3.27)$$

Bunun otokorelasyon fonksiyonu ile kısmi otokorelasyon fonksiyonu kademeli olarak azalmaktadır.

Geri yayılım katsayısını (B) kullandığımızda seriyi bu şekilde gösterebiliriz:

$$\phi_p(B)y_t = \phi_0 + \theta_q(B)\varepsilon_t \quad (3.28)$$

$\phi_p(B)$ otoregresif ($\phi_p, \dots \phi_t$) bilinenleri (B) sınırı içerisinde müteaddittir.

$\theta_p(B)$ otoregresif ($\theta_p, \dots \theta_t$) bilinenleri (B)Sınırı içerisinde müteaddittir.

Bu modelde durağanlığın sağlanması için ($\phi_p(B) = 0$) denkleminin kökleri birim çemberinin dışında olması gerekmektedir.

Aynı şekilde: ($\theta_q(B) = 0$) denkleminin kökleri birim çemberi için de geçerlidir (Aljubouri, 2010).

3.1.6.6. Dönemsel Karmaşık Model (Dönemsel Oto regresif ve Hareketli Ortalama)

Bu genel şekilde gösterilir:

$$y_t = \phi_s y_{t-s} + \phi_{2s} y_{t-2s} + \dots + \phi_{ps} y_{t-ps} + \varepsilon_t - \theta_s \varepsilon_{t-s} - \theta_{2s} \varepsilon_{t-2s} - \dots - \theta_{qs} \varepsilon_{t-qs} \quad (3.29)$$

3.1.6.7. Bütünleşmiş Oto regresif ve Hareketli Ortalama Modeli (ARIMA)

ARIMA Modeli tek değişkenli modeller arasında kullanımı en yaygın olan modeldir. Genel olarak bu model eşya fiyatları, enflasyon ve ürün fiyatları gibi birçok ekonomik olayların değerinin öngörülmesi için kullanılmaktadır (Meyler, 1998; Fkiring, 1991). Bu model aynı zamanda örneğin bazı hastalıkların yıllar içerisindeki gelişimini tahmin etmek gibi ekonomik olmaya başka değişkenlerin de öngörülmesi için kullanılmaktadır (Purohit, 1998).

Bazı zaman serileri modelleri kendi içerisinde istikrarsızdır, ancak yapılacak olan bazı müdahaleler ya da varyansını değiştirmek gibi işlemlerden sonra istikrarlı (durağan) hale gelir. Dolayısıyla bu işlemi tabir eden model ana modelden farklı olacağından gerçekleştirilmiş olan müdahale ve işlemleri içermiş olması gerekmektedir. Bu türden olan istikrarlı modellere Bütünleştirilmiş Oto regresif ve Hareketli Ortalama Modeli adı verilir (Dobre, 2008).

(ARIMA) Modeli zaman serileri modelleri arasında en çok kullanılan model olup bu model içerisinde gerek otoregresif ve hareketli ortalama gerekse karmaşık olan modelleri elde edebiliriz, bu modeller üç ayrı kısımdan oluşmaktadır, Birinci kısmı genel olarak zaman serisi öngörülerini belirlemek gibi işlemlerde kullanılan otoregresif (AR(p)) modeli, İkinci kısmı da hareketli ortalamayı (MA(q)), Üçüncü kısım ise serinin istikrarlı olması için gerekli olan varyansları (I(d)) tabir eder. Bu model geri yayılım katsayılarını (B) kullanarak bu genel şekil ile gösterilir (Dobre, 2008):

$$\phi(B)(1 - B)^d X_t = \phi_0 + \theta(B)\varepsilon_t \quad (3.30)$$

$$\phi(B) = (1 - \phi_1 B - \dots - \phi_p B^p) \quad (3.31)$$

$$\theta(B) = (1 - \theta_1 B - \dots - \theta_q B^q) \quad (3.32)$$

$$(1 - B)^d = \Delta^d \quad (3.33)$$

$Z_t = \Delta^d X_t$ Varsayılarak bütünleştirilmiş otoregresif ve hareketli ortalama modelin ARIMA (p, d, q) genel şekli böyle olur:

$$Z_t = \mu + \phi_1 Z_{t-1} + \dots + \phi_p Z_{t-p} + \dots + \varepsilon Z_{t-p-d} + \varepsilon_1 - \theta_1 \varepsilon_{t-1} - \dots - \theta_q \varepsilon_{t-q} \quad (3.34)$$

Bu özellikten dolayı ARIMA Modeli derece farklılığı olmakla birlikte ARMA Modelinin istikrarlı bir türü olarak kabul edilir (Kaiser ve Maravall, 2001).

3.1.6.8. Dönemsel Bütünleşmiş Otoregresif ve Hareketli Ortalama Modeli (SARIMA)

Zaman serileri aslında dönemsel etki faktörleri içermektedir, bu faktörler p ve q değerlerinin yükselmesine neden olarak öngörü tahminlerini zorlaştırmaktadır. Bundan dolayı da dönemsel etki faktörlü bütünleştirilmiş SARIMA (p,d,q) adlı model oluşturulmuş ve matematiksel olarak bu şekilde formüle edilmiştir:

$$\phi(L)\Phi(L^s)\nabla^d \nabla_s^D Y_t = \theta(L)\Theta(L^s)\varepsilon_t \quad (3.35)$$

Burada:

$$\Phi(L^s) = 1 - \phi_1 L^s - \phi_2 L^{2s} - \phi_p L^{ps} \quad (3.36)$$

$$\Theta(L^s) = 1 - \theta_1 L^s - \theta_2 L^{2s} - \theta_q L^{qs} \quad (3.37)$$

$\nabla_s^D = (1 - L^s)^D$ Dönemsel farklılıkları (D) göstermekte ve $\nabla^d = (1 - L)^d$ de gerekli olan durağanlığı y_t sağlayan (d) derecesindeki seri farklılıkları gösterir.

3.2. Box–Jenkins (B-J) Metodolojisi

Bilim insanları Box ve Jenkins'in 1970 Yılında yayımlanan eserlerinde orta koydukları analiz metodu, en güvenilir modern analiz üsluplarından birisi sayılabilen zaman serisi modern analiz metodu olarak kabul edilmiştir. Ortaya koydukları bu metot, diğer birçok başka öngörü metotlarından farklı olup bu özellikleri bulunmaktadır (Sharawi, 2005):

- Kapsamlı, düzenli ve güvenilir bir öngörü ve modelleme sistemidir. Bu demektir ki, zaman serilerinin analizinin; uygun modelin seçilmesi aşamasından başlayıp bu modelin özelliklerini tahmin ve teşhis etmek ve daha sonra ileride elde edilecek olan gözlemleri öngörme aşamasına kadar olan bütün aşamalarında kesin ve kapsamlı çözümler sunmaktadır.
- Serinin gözlemleri arasında bağımsızlığı varsaymamakta olup bunun yerine, pratikte karşılaştığımız birçok zaman serisi modelinin aksine kuvveti ve kudreti ile bilinen ARMA modelleri aracılığıyla verilerin içerisinde yerleşmiş olan bağlantı modellerini kullanarak sonuçta istatistiksel olarak koordineli ve güvenilir öngörülerini elde etmemizi sağlar.
- Gerekli olan verilerin tamamı veya yeterli kadarının bulunması durumunda, başka metotlardan daha dakik ve kapsamlı öngörüler elde edilir.
- Başka metotlarla elde edilmesi mümkün olmayan, dönemsel olan ve olmayan uygun ileri gözlemler için güvenilir zaman periyotları verir.

Box–Jenkins metodolojisini kullanarak zaman serileri modellerinin oluşturulması Dört ayrı süreçte gerçekleşir bunlar; belirleme süreci, tahmin süreci, teşhis süreci ve son olarak da öngörü sürecidir (Box ve Jenkins, 1976).

3.2.1. Model Belirleme

Zaman serileri modellerinin belirlenmesi süreci, zaman serileri modellerinin kurulmasında en önemli aşamadır. Bu algoritma sürecinin ilk aşamanın temelini 1976 yılında iki bilim insanı olan Box ve Jenkins oluşturmuştur. Belirleme süreci öncesinde ise verilerin hazırlanması aşaması gelir, verilerin çizime dönüştürülmesi, tam ve kısmi otokorelasyon bağlantılarının gözlemleri sırasında verilerin düzenli olması halinde bu veriler tanınmaya veya belirlenmeye hazırdır anlamına gelir, serinin ortalama ve varyansında düzensizliklerin bulunması halinde ise, bu düzensizliğin ortalamada giderilmesi için birinci varyansları ($d=1$) alınır. Bu işleme rağmen düzensizliğin giderilmemesi halinde de İkinci varyans ($d=2$) alınır. Genellikle birinci veya ikinci varyansı alınca seri düzenli hale gelir. Düzensizliğin varyansta olması durumunda ise bu düzensizlik verilerin uygun dönüşümü yolu ile giderilir. Zaman serisi istikrara (düzene) kavuşmasından sonra model belirleme aşamasına geçilir, bu aşama zaman serisini oluşturan veriler ile başka bilgilerin kullanılmasına geçilmesi anlamına gelir. Burada asıl amaç Genel Doğrusal Modeli ARIMA için gerekli olan (p,d,q) değerinin elde edilmesidir (Box ve Jenkins, 1976).

Modeli ve derecesini belirlemede kullanılan iki Fonksiyon ise otokorelasyon (ACF) ile kısmi otokorelasyon (PACF) Fonksiyonlarıdır. Bu İki fonksiyonun grafiği çizilerek otokorelasyon ve kısmi otokorelasyon işlemlerinin, otokorelasyon (ACF) ile kısmi otokorelasyon (PACF) Fonksiyonları teorik davranışı ile uyumu sağlanır (Ameen, 2005).

3.2.2. Modelin Tahmini

Modelin tahmini süreci, zaman serilerinin incelenmesi ve analizinin İkinci aşamasıdır, bu aşama öncesi oluşturulması istenilen zaman serisi için uygun bir modelin belirlenmesidir. Kurulması istenilen modelin ana amacının gerçekleşmesi için de doğru öngörünün oluşturulması gerekmektedir, bu oluşturma işlemi sırasında da öngörünün tahmin kalitesi ile ele alınan zaman serisine uygunluğunun garanti edilmesi gerekir, model tahminin düzgün yapılması için birçok metot bulunmaktadır, bunların en önemlileri ise (Pierce, 1971):

- Olağan En Küçük Kareler Metodu (Method of Ordinary Least Squares (OLSE), Bu metod tahmini hata karelerinin azaltılması ve minimum düzeye getirilmesi esasına dayanmaktadır.
- Maksimum Olasılıklar Metodu (Method Maximum Likelihood MLE), bu metodu bu şekilde özetlemek mümkündür, tahmin edilmesi düşünülen modelin sıralanmış değerlerinin belirlenmesi; hata karelerini en aza indirgeyen olasılık fonksiyonun büyütülmesi esasına göre yapılmasıdır.

3.2.3. Modelin Teşhisi

Birinci aşamada oluşturulan zaman serisi modeli; modelin verilerini, genel yapısını ve rasgele değişkenleri (ε_t) oluşturan rasgele işlemlere dair birtakım önemli teorik varsayımlara dayanır. Model taslağını tanıma ve özelliklerinin tahmin edilmesinden sonra bu modelin değerlendirilmesi yapılarak bu teorik varsayımlara uygun olup veya olmadığından emin olunması gerekmektedir. Teşhis aşamasında yapılanlar ise birçok test ve analizlerin yapılmasından ibarettir (Sharawi, 2005).

- Durağanlık Analizi

Tahmin aşamasında elde etmiş olduğumuz otoregresif özellikleri değerlendirilerek durağanlık özelliğinin gerçekleşmiş olup veya olmadığından emin olunur. Bu da demektir ki denklem kareköklerinin tamamı birim dairesi dışında kalmasıdır ($\phi(B) = 0$), yani her bir karekök mutlak değerinin tam Birden fazla olması halinde bu rasgele işlemin durağan olduğuna işaret eder.

- Yansıtma Analizi

Denklem kareköklerinin ($\phi(B) = 0$) tamamı birim dairesi dışında kalmış olması halinde, hareketli ortalamaya dair değerlendirmeler yansıtma şartlarının oluştuğunu gösterir. Yani her bir karekök mutlak değerinin tam Birden fazla olması halinde esas modelin yansıtıldığı anlamına gelir, kareköklerden herhangi birisinin değeri 1'e yakın ise bu demektir ki gerekli olmayan varyanslar kullanılmıştır.

- **Kalıntı Analizi (Artıklar Analizi)**

Model ile ilgili olan özelliklerin belirlenmesinden sonra ARIMA ile ilgili olan varsayımların bulunmasından emin olunması gerekmektedir. Bu modelin esas varsayımı ise kalıntılar, Sıfır ortalama ve sabit varyansıyla bağımsız rasgele değişkenleri temsil eder. Kalıntıların grafiğe çizilmesi ile birlikte; istatistiksel testler ile ortaya çıkması veya bulunması mümkün olmayan genel trend, ayrıştırma ve aykırı veriler gibi kalıntıların ana görüntüsü ortaya çıkar (Sharawi, 2005).

Aynı zamanda kalıntıların otokorelasyon analizleri kanalıyla İki metot ile modelin uygun olup veya olmadığı ile bu modelin zaman serisi verilerini temsil etme yeterliliğinin bulunup veya bulunmadığı test edilir (Aljubouri, 2010).

Birinci Metot

Aşağıda yazılı olan yokluk hipotezini (Ljung-Box(Q)) test etmek için kullanılan seri bağımsızlık testine dayanan bir metottur:

$$H_0: \rho_1 = \rho_2 = \dots \rho_s = 0 \quad (3.38)$$

Bu metot kalıntılara dair otoregresif fonksiyonlara dayalı olup, (Q) Testi istatistiksel matematik Formülü de:

$$Q(s) = n(n + 2) \sum_{k=1}^s \left(\frac{1}{n} - k \right) r_k^2 \quad (3.39)$$

Q Testi ölçütü χ^2 dağılımını izlemekte ve $Q(s) \sim \chi^2_{((s-m), \alpha)}$ dir.

m = Tahmini katsayı adedi

K = Toplam sapma adedi

S = Mümkün olan maksimum sapma

İkinci Metot

Bu metot, (0,95) Olasılıkla $(\pm \frac{1.96}{\sqrt{n}})$ Sınırları içerisinde kalması gerekli olan tahmini otokorelasyon fonksiyonun güven sınırlarına dayalı olan bir metottur. Bunun gerçekleşmesi ile kalıntıların rasgele dağıldığı anlamına gelir ve modelin verileri tam bir şekilde temsil ettiğinden öngörü oluşturulması için kullanılabilir olur. Kalıntıların otokorelasyon fonksiyonları ise Sıfır ortalama ve $(\frac{1}{n})$ varyansıyla doğal dağılım gösterir.

3.2.4. Öngörü

Öngörünün nesnel hedefi (Object Forecasting) öngörü hatası minimum kare ortalamasını elde etmektir (Minimize Mean Square of Forecating) (Powell, 1997).

Burada (t), istenilen öngörü hesaplamasında (h) kadar zaman periyotları içerisinde oluşacak olan gözlem değerindeki hali hazır zamanı gösterir. Yani henüz gerçekleşmeyen gözlem değerinin (y_{t+h}) öngörülmesidir. Bu durumda (h) ye öngörü ufku (Prediction–Horizon) ya da rehber zaman (Time Lead) denir (Girard, 2002).

Aynı zamanda (h) y_t de (h) kadar zaman periyotları sonrasında oluşacak olan gözlem değerinin (y_{t+h}) zaman periyodu (t) içerisinde elde edeceğimiz öngörü değerini göstermektedir. Örneğin (h = 1) ise, $(1)y_t$ de tek bir zaman periyodu sonrası oluşacak olan y_{t+1} Gözleminin (t) sürecinde elde edilen öngörü değerini göstermektedir (Vandaele, 1990).

Öngörü süreci zaman serileri modellerinin oluşturulması ve analizinin son aşaması olup işlemin ana hedefidir. Eldeki verilere uygun olan modelin belirlenmesinden sonra bu modelin belli periyotlar (L) içerisinde ileriki olgunun değerlerini ölçmek için kullanılır ve aynı şekilde (L) basamakları sonrasında öngörü hesaplaması da bu formülle yapılır (Douglas, 1976):

$$\hat{Z}_{t+1} = E\{Z_{t+1}|Z_t, Z_{t-1}, Z_{t-2} \dots \dots\} \text{ for } L \geq 1 \quad (3.40)$$


Bu aşamaya; ancak taslak modelin doğruluğunun ve teorik varsayımlara uygunluğundan emin olmak için yapılacak olan bütün test ve teşhis deneylerinden başarıyla geçmesinden sonra geçmek mümkün olur. Yapılacak olan bunca test ve deney sonrasında modelin başarılı olmaması halinde bu modeli yukarıda teşhis metodunda yazılı olduğu şekilde aynı işlemlerden geçirilmesi ve başarı sağlaması kaydıyla daha performanslı başka bir model ile değiştirmek gerekir.

3.3. Yapay Sinir Ağları

Yapay Sinir Ağları (YSA); insan beyni yerine düşünme, anlama, duyma, konuşma ve hareket gibi olguları işleme koyan bilgisayarların insan zekâsına eşdeğer düzeyde programlar tasarlayan bilgi işlem dalının bir türevi olan yapay zekâ bilimine bağlı bir bilim dalıdır (Shraqawi, 1996).

YSA, bilinen klasik metotlardan farklı bir şekilde değişkenler arası ilişkileri tanımlamak için en uygun bir metottur. YSA aynı zamanda dış girdileri cevaplandırmak gibi verilerin dinamik bir üslupla çalıştırılmasına imkân veren birbirlerine bağlı basit unsurlar gruplarından oluşan bir hesaplama sistemidir. Bundan dolayı YSA, biyolojik sinir ağlarına eşdeğer üslupla belli görevleri yerine getirme özelliği olan bir bilgi işlem sistemi olarak kabul edilmektedir (İssa, 2000).

Günümüzde YSA, değişik alanlarda karşılaştığımız geniş gruplara dair problemlerin ortak bir çözüm aracı olmuştur. YSA, yapı ve çalışma yönünden biyolojik insan beynine benzer modern zekâ teknolojisi olarak kabul görmekle birlikte, belli bir görevi yerine getirmek için basit işlem birimlerinden oluşan ve paralel dağılımlı dev işlemleri gerçekleştiren, insan beynine çok yakın bir işlevi olan bir hesaplama sistemidir. Burada sözü edilen basit işlemlere ise (Nöron) adı verilmektedir Şekil 3.1' te gösterilmektedir.



Şekil 3.1. Hücre Detaylarının Açıklaması (Ciaburro ve Venkateswaran, 2017)

Yapay Sinir Ağlarının yapısı, sinir hücreleri arasındaki elektrik frekanslarının alışverişinden oluşan karışık bir sistem ile çalışmakta olan, eğitim yolu ile bilgi alma ve geçmişten öğrenme gibi fonksiyonları bakımından insan beyni yapısına benzerlik göstermektedir. Bu gerçekten dolayı da düşünce bilimleri alanında çalışmakta olan birçok bilim insanı ve araştırmacıları Yapay Zekâ konusunda araştırmaya zorlamış ve neticesinde de Yapay Ağlara ve bunun geliştirilmesi yollarının bulunmasına ulaşılmıştır (Zurada, 1992).

Çalışmamızın bu bölümünde, YSA ele alınarak bunun içerisinde yer alan tanımlar, tarihsel gelişim süreci, nasıl başladığı, kullanma alanları, nelerden oluştuğu, çalışma mekanizması, eğitim ve alıştırma işlemlerinin ne şekilde yapıldığı ile son olarak da YSA kullanılarak öngörü (Kestirim) işlemi basamaklarına değinilecektir.

YSA üzerindeki çalışmaların geçen yüzyılda başladığını söyleyebiliriz, zira Freud isimli düşünür bu olgunun genel düşüncesinin felsefî yönüne değinmiştir. İlkel ağların ilk uygulaması ise 1913 Yılında Russell isimli kişi tarafından bu ağların genel yapısına dayalı olan bir hidrolik cihaz ile başlamış olsa da 1940 – 1950 Yılların ise bu ağların gelişmeye başladığı yıllar olduğunu kabul edebiliriz zira, bu yıllarda birçok bilim insanı ve mühendisin bu ağları geliştirmede büyük katkıları olmuştur ancak, Yetmişli yıllar ise YSA gerçek sıçrama yılları olduğu bilinmektedir (Shraqawi, 1996).

Yapay Sinir Ağları (YSA), giren verileri işleyen, birbirleri ile bağlantılı, paralel ve dinamik yapıya olan birtakım bilgi işlem birimlerinden oluşan bir matematik sistemi olarak tanımlanır (Kumar, 2004).

(Shraqawi, 1996) tarafından yapılan tanımda ise YSA'nın kenar ağırlıkları değerlerinin tadili ile şekil ve grafikleri (Patterns) depolama kapasitesi olan kenar ağırlıklı yönlendirilmiş grafikler olarak tanımlamıştır. Buna göre de bu ağlar giren verilen tanımlanmamış bilinmeyen (Unknown) olması veya tam (Incomplate) olmaması durumunda bu şekil ve grafikleri tekrardan tanıma imkânı olacaktır. Bütün YSA aşağıda sıralanan aynı özelliklere sahiptir:

- Dağıtılmış temsil (Distributed Representative)
- Yerinde işleme (LocalProcessing)
- Doğrusal olmayan işleme (Non liner Processing)

Sinir ağları, klasik metot ve algoritmalar ile çözülmesi güç olan birçok uygulamada kullanılan bir yöntem olup zira bütün sinir ağları problem çözmede gerçek durumun simülasyonu üslubuna dayalı olarak çalışmaktadır. Dolayısıyla YSA, modül tasnifi (Pattern Classification) ve modül tanıma (Pattern Recogniaition) dahil birçok konuyu çözmek için etkili bir araç olduğundan birçok mali, tıp, jeoloji ve mühendislik dallarında öngörü, tasnif ve kümelenme (Clustering) gibi problemlerin çözümünde kullanılmaktadır (Christopher, 2000).


Son yıllarda YSA'nın kullanımı bir hayli gelişmiş ve klasik modellerin yerini almıştır. Sinir ağları modelleri klasik istatistik modellerine kıyasla daha dakik ve daha kolay öngörme yeteneğini kanıtladığından dolayı klasik modellerin yerini almıştır. YSA modeli gerekli olan değişkenlerin yapısı ile ilgili olan belli varsayımlar ile bu değişkenlerin birbirleri ile olan ilişkilerin bilinmesine gerek kalmadan, normal ve klasik öngörü modellerinin aksine YSA'nın kullanılması mümkündür. Bununla birlikte, YSA'nın kullanılması başlı başına bir hedef olmayıp uygulama alanlarının herhangi birisinde herhangi bir olayın veya toplam değişkenler grubunun ileride oluşacak olan değerlerinin öngörülmesi için aktif ve garantili bir araçtır (Mitchell, 1997).

- Tıp Alanı: İnsan beyinde olduğu gibi hatırlamaya dayalı ani karar verme uygulaması, yani hastalığın teşhisi ilkesi.
- Telli ve Telsiz Haberleşme: Genellikle telefon hatlarında olduğu gibi ses yankılarından kurtulma ve hedef belirleyen askeri radar cihazlarında.

- Bankacılık Alanında: Dokunma ya da göz bebeği tanıma yolu ile banka hesabı açma ve imza ile el yazısı tanıma gibi işlemlerde.
- İş Alanında: Özellikle ekonomik alanına giren işlerde olmak üzere birçok iş alanlarında kullanılmaktadır.

3.3.1. Yapay Sinir Ağlarının Temel Kavramı

Genel olarak her bir Sinir Ağı, yapay nöron katmanları şeklinde sıralandığını söyleyebiliriz, girdi katmanı, çıktı katmanı ve bu iki katman arasında bulunan gizli bir katman bulunur Şekil 3.2' te gösterilmektedir (Zurada, 1992; Sharqawi, 1996).




Şekil 3.2. Yapay Sinir Ağı Genel Planı (Ciaburro ve Venkateswaran, 2017)

Bu katmanlardan herhangi birisinde bulunan her bir nöron odan sonra gelen katmanın içerisinde bulunan bütün nöronlarla bağlantılıdır, önceki katmandan gelen sinyal veya değeri işler ve sonuç değerini çıkışa gönderir, buradan gelen tek sonuçta bir sonraki katmanda bulunan bütün nöronlara transfer olur. Her bir nöron birden çok değeri girdiden (Input) alır ve çıktı (Output) tek bir değer gönderir. Bilindiği üzere yapay nöronun çalışma mekanizması biyolojik beyin nöronlarından esinlenerek geliştirilmiştir, Biyolojik nöronlarda her bir Gelen Bağlantı Ağına (Incoming Synapse) yani Feri Sinir Ağlarına (Dendrite Weight) Ağ Ağırlığı denilen bir değer verilir, bu değer kendi değerini ve önemini belirleyerek ağın modellenmesine yardımcı olur. Bu ağırlık o ağın değerini ve nörona olan etkisini belirler. Her bir ağ ağırlığı girdi değerleri çarpılır ve daha sonra gelen ağların çarpım sonuçları toplanır. Genelde biyolojik nöronlar eşik değeri kuralına tabidir. Şayet girdi değerleri ağırlıklı toplamı (Weighted Sum) eşik (Threshold) denen belli bir değerden büyük ise bu nöron, sinir ekseni (Axon) boyunca “Geciken Tepki” adı verilen bir tepki veya

elektrik sinyali üretir. Bu sinyal ferî eksenler yoluyla diğêr bütün çıktı ağılarına (Outgoing Synapses) ulaşır. Buradan da beyinde bulunan diğêr nöronlara dağılır.

Model Nöron Ağları bu tür davranışı taklit etmeye çalışır, her bir nöron kümesi kendisinden önceki nöronlarla olan bağlantıları yolu ile bir grup girdi alır. Her bir kümenin kendine ait aktivasyon fonksiyonu (Activation Function) veya transfer fonksiyonu (Transfer Function) Bulunmaktadır, bu fonksiyonlar yoluyla biyolojik nöronlarda olduğı gibi kümenin hangi anda ve nasıl çalışacağı ve vermesi gerekli olan çıktı değerini belirler.

Yapay Sinir Ağları, merkez işlemci birimlerinden oluşan bağlayıcı bir sistemdir, bu demektir ki, belli bir yapı şekli alabilmek için birbirine bağlı değışik işlem icra etme yeteneğı olan ve lokal bir hafıza olarak çalışabilen işlemci eleman (Processing Element) dır. Bu biyolojik ağıın yapısı Şekil 3.3' te gösterilmektedir (Fahmi, 1994).



Şekil 3.3. Ağ Yapısı Modeli (Fahmi, 1994)

- Sinir, İnsan beyninin ana kısmıdır, dendrit (Dallanma) adı verilen dâhili algı gövdesi kanalıyla diğêr sinirler tarafından gönderilen sinyalleri karşılama ve karıştırmaya görevi yapan basit bir işlem birimidir.
- Sinir Ağı, Sinir hücresi eksenî ile sinir teferruatı arasında bağlantıyı sağlayan eksendir, aslında bu eksen doğal kimyasal birimlerden oluşmakla birlikte elektrikli bir yönü de bulunmaktadır. İnsan beyni daha çok öğrendikçe bu ağların birleşme kuvvetini tadil eder ve değıştirir, bu sinirlerden insan beyninde şiddetli yoğunlukta birbirine bağlı tasavvur edilemeyecek şekilde on milyarlarca bulunmaktadır.

Burada değinilmesi gerekli olan bir husus ise, yapay sinir ağlarında veri işleme işlemi, ağ içerisinde bulunan hücreler arasına yerleşik sinir parçacıkları yoluyla sinyallerin transferi kanalıyla gerçekleşmekte olup bu parçacıkların her birinin “Ağırlık” adı verilen belli bir değerde tercihi bulunmaktadır, bu ağırlık değeri aynı parçacığın sinyal değeri ile çarpılır, aynı zamanda her bir hücrenin, belli bir hücre net girdilerini çıktı sinyallerine (Output Signals) dönüştüren Aktivasyon Fonksiyonu (Activation Function) bulunmaktadır.


3.3.2. Yapay sinir ağlarının özellikleri ve bileşenleri teknik kavramları

- Katmanlar (Layers), Sinir ağı katmanlarının toplan adedidir. Girdi kümeleri (Nodes) sadece ağırlıkların dağılımı için kullanıldığı dikkate alınarak katmanlar, girdi katmanları (Input Layers) ile çıktı katmanlarından (Output Layers) oluşmaktadır.
- Katman Hacmi (Layers Size), Yapay sinir ağı çalıştırma programında belirlenmiş olan hafıza hacmini belirler.
- Kullanılan Sinir Fonksiyonu (Neural Function), lojistik fonksiyondur.

$$f(x) = \frac{1}{1+e^{-x_i}} \quad (3.41)$$

Yapay sinir ağları birçok özelliğe sahiptir, bunlardan bir kısmı (Fahmi, 1994) Kuvvetli bir matematik esasına dayanır.

- İnsan beynini taklit yöntemi ile zeki bilgi işleme teknolojisinin bir uygulamasıdır.
- Her türden nesnel ve her miktarda bilgiyi kabul eder.
- Ağ üzerinde çalıştırılan haller kanalıyla kazanılan bilgileri depolama yeteneğinin bulunması.
- Muhtelif bilimsel alanda kullanma ve uygulama imkânının bulunması.



Şekil 3.4. Yapay Nöron Öğeleri (Krose ve Smagt, 1996).

Yukarıda açıkladığımız üzere nöron ağlarının bir grup işlem biriminden oluştuğu, altta yer alan 3.4' No.lu şekilde nöron öğeleri gösterilmektedir. İnsanoğlunun dış dünya ile bağlantısını sağlayan girdi birimleri bulunmaktadır, bunlar beş duyu organlarıdır. Aynı şekilde yapay sinir ağları da girdi birimleri ile bu girdileri işleyen birimlere ihtiyacı bulunmaktadır. Bu işlem birimlerinde ağırlıkların kontrolünde bir takım matematiksel işlen gerçekleşir ve bunun sonucunda ağa girene her bir girdi karşılığında uygun bir tepki ortaya çıkar.

Girdi birimleri kendi başına girdi katmanı denilen katmanı oluşturur, işlem birimleri ise bu girdileri işleme katmanı işlevini görür ve sonuçları ortaya çıkartır. Bu katmanların arasında o katmanı sonrasında gelen katmanla bağlayan ara bağlantı elemanları bulunmakta ve bunların vasıtasıyla da bu ara bağlantı elemanlarının ağırlıkları kontrol altına alınır. Ağ içerisinde girdi katmanından sadece bir adet bulunmakla birlikte, biden çok işleme katmanı da bulunmaktadır (Krose ve Smagt, 1996).

Yukarıda yer alan 3.4' No.lu şekilde görüldüğü gibi her bir nöron bu öğelerden oluşmaktadır:

- Girdi Sinyalleri (Input): ($x_1, x_2, x_3, \dots, x_n$) Bu sinyaller nicel ve nitel veriler şeklinde olabilir veya başka bir işlem birimi için çıktı veya metin, şekil, ses veya başka türlü bir olgu şeklinde de olabilir.
- Ağırlıklar Kuvveti (Weights): ($w_{j1}, w_{j2}, w_{j3}, \dots, w_{jn}$) Burada ağırlık bir önceki ve bir sonraki öğelerin bağlantı şiddetini ifade eder. Yapay sinir ağları her öğenin, oransal önemi ile girdi verilerinin matematiksel değerini ifade eden tercihlili ağırlığına dayanır. Ağırlıklar ağ içerisinde bulunan katmanlar arasında veri transferini sağlar ve

çıktı değerlerini etkiler, Toplam Fonksiyonu denilen ağ içi öğrenme özelliği yolu ile de bu ağırlıkların tadil edilmesi mümkündür.


- İşleme Ögesi (J) (Processing Element): Bu öge iki bölüme ayrılmaktadır:

1. Toplama (Summation Function) Fonksiyonu, bu fonksiyon ile girdi sinyalleri toplanır ve giriş yapan her bir girdi ögesi için tercihli ağırlıklı toplamın (Sum Weighted) bulunmasına yardımcı olur ve bunun sonucunda da en uygun tercihli toplam elde edilir.

2. Transfer ya da Aktivasyon Fonksiyonu (Activation Function) bu fonksiyon nöron çıktısını sınırlar ve bu özelliğinden ötürü bu fonksiyona sıkıştırma (Squashing) bağı denilmektedir, bu fonksiyon çıktıların $[-1, 1]$ veya $[0, 1]$ aralığında ve olmasını sağlar çıktı (Output) (X_j) ise bir sonuç ya da problemin çözümünden ibarettir.

Sinir ağları, nöron denilen birtakım komplike işlemci ögeleri grubundan oluşmaktadır, bu ögeler belli sayıda adımlar ile matematik işlemlerini yapmaya muktedirdir (Landt, 1975).

Bilgi işleme ilk önce basit işleme ögelerinden geçer, sinyallerde transfer özelliği olan bağlantı hatlar kanalıyla sinirler arasından geçer. Bu bağlantı hatlarında her bir girdiye belli bir ağırlık verilir ve nörona giren sinyal ile çarpılır.



Şekil 3.5. Yapay Sinir Ağı Modeli (Ciaburro ve Venkateswaran, 2017)

Yukarıda yer alan 3.5' No.lu şekilde gördüğü üzere sinir ağları üç ayrı katmandan oluşmaktadır. Bunlar:

- Girdi Katmanı (Input Layer)
- Gizli Katman (Hidden Layer)
- Çıktı Katmanı (Output Layer)

Bununla birlikte, YSA'nın üç ayrı özelliği de bulunmaktadır, bu özellikler ile yapay sinir ağlarının tanımı yapılır. Bunlar (Allend, 1999; İssa, 2000):

- Nöronlar arası bağlantı şekli (Mimari Yapı Denilmekte)
- Bu bağlantıların ağırlıklarını belirleyen yöntem (Eğitim, Öğrenme, Algoritma) denir.
- Kullanılan aktivasyon fonksiyonu.

3.3.2.1. Aktivasyon Fonksiyonu

Aktivasyon Fonksiyonu nöron çıktılarını sınırlar ve aşağıda sıralanan özelliklere sahip olması gerekmektedir:


- Süreklilik halinde olması,
- Ayırmaya elverişli ve hesaplamasının kolay olması,
- Akışkan olması ve çelişkili olmaması.

Aktivasyon Fonksiyonu (a) sembolü ile gösterilmekte olup üç ayrı türdedir (Kabundi, 2002; Haykin, 1994).

3.3.2.2. Eşik veya Adım Fonksiyonu

$$a = \begin{cases} 1, & \text{if } z \geq 0 \\ 0, & \text{if } z < 0 \end{cases}$$

Bu Fonksiyon çıktı miktarını sınırlar ve girdinin sıfıra eşit veya daha büyük olması halinde çıktıların bire eşit olmasını sağlar. Girdinin sıfırdan az olması halinde de çıktının Sıfıra eşit olmasını sağlar, bu durum Şekil 3.6'da gösterilmektedir. Bu fonksiyon, modüllerin tasnifi ve tanımlaması gibi işlevleri kararlaştıran nöronlarda Sert Sınır Fonksiyonu (Hard Limit Function) olarak tanımlanmaktadır.




Şekil 3.6. Eşik (Adım) Fonksiyonu Açıklaması (Ciaburro ve Venkateswaran, 2017)

3.3.2.3. Çizgisel veya Parçalı Fonksiyon

$$a = \begin{cases} 1 & \text{if } z \geq 0.5 \\ z & \text{if } -0.5 < z < 0.5 \\ 0 & \text{if } z \leq -0.5 \end{cases}$$


Bu Fonksiyon çizgisel çözümlerde kullanılan nöronlarda bulunur. Şekil 3.7'deki gibi.



Şekil 3.7. Çizgisel Fonksiyonun Açıklamalı Şekli (Ciaburro & Venkateswaran, 2017)

3.3.2.4. Sigmoid Fonksiyon

$$a = \frac{1}{1 + \exp(-az)} \quad (3.42)$$



Şekil 3.8. Sigmoid Fonksiyonunun Açıklaması (Ciaburro ve Venkateswaran, 2017)

Bu fonksiyon $(-\infty, \infty)$ arasındaki girdi değerini alır ve çıktı değerini 0 ile 1 Arasında sıkıştırır. Bu fonksiyonun kolay türevlerinin alınması ve bol çeşitliliği ile yaygın bir şekilde kullanılmaktadır. Şekil 3.8 Sigmoid Fonksiyonunu göstermektedir.

3.3.3. Yapay Sinir Ağlarının Yapısı (Mimarisi)

Nöronların katmanlardaki veya düzlemlerdeki dizilişi ile katmanlar arasında veya içerisindeki bağlantı şekillerine sinir ağlarının mühendislik veya mimari yapısı denir. Ağ içerisindeki katmanların hesaplaması girdi katmanları göz ardı edilerek yapılır ya da nöronlar arası bağlantı adedi ile bilinebilir (İssa, 2000).

Yapay Sinir Ağları içerdiği katman adedi yönünden İki türe ayrılır (Moseley, 2003; Kumar, 2004; İssa, 2000).

3.3.3.1. Tek Katmanlı Ağlar

Bu tür ağlar sadece İki katmandan oluşur bunlar, Girdi Katmanı (Input Layer) ve Çıktı Katmanı (Output Layer) buraya giriş yapan sinyaller girdi katmanından ileriye doğru akarak çıktı katmanı yönüne yol alır, şekilde görüldüğü gibi.

3.3.3.2. Çok Katmanlı Ağlar

İçerisinde bir veya birden fazla sayıda gizli katmanların yer aldığı ağlardır. Burada bulunan bu gizli katman veya katmanlar bütün problemleri çözmeye yeterli olmaktadır.

Bu tür ağların girdi ve çıktılar arasında fonksiyon transferine daha bir esneklik kazandıran orta katmanların bulunması nedeniyle, tek katmanlı ağlarda çözülebilen konulardan daha da zor ve komplike konuların bu tür ağlarda çözülebilmeye özelliği bulunmaktadır. Bu tür ağlarda eğitimin her ne kadar uzunca bir süre almasına rağmen ancak burada yapılan eğitimlerin başkalarına kıyasla daha da başarılı sonuçlar vermektedir. Bazen uzunca bir süre eğitim yapmamıza rağmen tek katmanlı bir ağda problemin kesin çözümüne ulaşılmadığına rastlanabilir, bundan dolayı birçok problemin çok katmanlı ağlarda çözülmesi yoluna gidilir, aslında problemin

kendi özelliklerine bakıldığında bu problemin hangi tür bir ağda çözüleceği veya ne tür bir ağı kullanılmasının gerekli olduğu kendiliğinden ortaya çıkar. Bu tür ağlar kendi içerisinde iki türe ayrılmaktadır bunlar, “İleri Beslemeli Ağlar” ile “Geri (Ters) Beslemeli Ağlar” olmakla birlikte bu ağlarda “Üç Katman Ağırlık” da bulunmaktadır bunlar da (İssa, 2000):


- Girdi Düzlemi ile Gizli Düzlem Arası Ağırlık Katmanı (Input to Hidden Weights)
- Gizli Düzlemler Arası Ağırlık Katmanı (Hidden Weights)
- Çıktı Düzlemi ile Gizli Düzlem Arası Ağırlık Katmanı (Output to Hidden Weights)

3.3.4. Yapay Sinir Ağları Türleri

Yapay Sinir Ağları (YSA) birden fazla şekillerde tasarlanır, bunun anlamı da sinir hücrelerinin değişik yollarla ulaştırılmasının sağlanması demektir, bunların bir kısmı da (Mitchell, 1997):

3.3.4.1. İleri Beslemeli Sinir Ağları

Bu tür ağlar, yapısı itibarıyla kendisini oluşturan birimler arasında bağlayıcı kapalı devrenin bulunmamasıdır. Bu türden olan ağların kullanımı oldukça yaygındır. Bu türden olan ağlarda minimum İki katmandan oluşmaktadır, bu türün birçoğunda da girdi katmanı ile çıktı katmanı arasında gizli bir katman (Layer Hidden) bulunur, matematik işlemler girdi katmanından sadece ileriye doğru hareket ederek gizli katmanlar üzerinden çıktı katmanına şekil 3.9' te izah edildiği şekilde transfer olur:



Şekil 3.9. İleri Beslemeli Sinir Ağı Örneği (Ciaburro ve Venkateswaran, 2017)

3.3.4.2. Geri Beslemeli Sinir Ağları

Daha mükemmel sonuçlar elde etmek amacıyla bu tür ağların çıktılarında bulunan geri besleme yolu kanalıyla çıkan sonuçlar tekrar girdi olarak sisteme yeniden aktarılır.

3.3.4.3. Otobağlantılı Sinir Ağları


Kendisini oluşturan bütün öğelerin önemli işlevler üstlendiği türden ağlar olup aynı anda girdileri karşılar ve çıktı olarak iletir.

3.3.5. Yapay Sinir Ağları Eğitimi

Yapay Sinir Ağlarında (YSA) çıktı sinyalleri her zaman girdi sinyallarına bağlı olarak çıkış yapar (Kumar, 2004).

Bu ağlar genellikle sürekli olmayıp tekrarı yoktur, başka bir anlatımla da kümeler arasındaki bağlantılar sürekli değildir. Yapay Sinir Ağları hata hacmine (Hata Karesi Ortalaması) dayalı olan öğrenme ilkesine dayanır. Katmanlar arasında oluşan ağırlıklar, aynı ağırlığın hatanın oluşmasına olan katkısı kadardır. Ağ, modülün en uygun ve kabul edilebilir sonuçları gerçekleştirecek olan ideal ağırlığı elde edinceye değin ağırlıkların güncellenmesine devam eder (Christopher, 2000).

Sinir ağları eğitimi, öğrenme algoritmaları (Learning Algorithms) denilen uzman algoritmalar vasıtasıyla gerçekleşir. Bu algoritmaların görevi; ağın elde edilmesi istenilen sonuca tam veya en yakın bir mertebede ulaşmasını sağlayan ideal ağırlık değerini ortaya koyan belli bir ölçeğe dayalı olarak ağın işlevini iyileştirmek ve hataları (Signal Error) minimum düzeye indirilmesini sağlayan ağırlıkları tadil etmek yani uyarlamaktır. Ağırlık tadili her bir devrede kısmen gerçekleşir, hata sinyali de gerçek değere ne kadar yakın veya uzak olduğuna dair bir gösterge veya rehber olarak alınır. Şekil 3.10'te ağırlık uyarlanması genel grafiğini göstermektedir (Christopher, 2000).



Şekil 3.10. Ağırlık Tadili (Uyarlanması) Genel Grafiği (Alobaidi, 2000)

Yönlendirilmiş eğitimde bilinen en ünlü algoritmalarından birisi “Hata Geri Yayılım Algoritması”dır (Back Propagation), buna “Genelleştirilmiş Delta Kuralı” algoritması (Generalized Rule Delta) denir. Bu algoritma yapay sinir ağları (YSA) eğitiminde örnek bir metot olmakla birlikte yaygın bir şekilde de kullanılmaktadır. Bu metot Standart En Düşük Ortalama Kareleri (MSE) olup hatayı en aza indirmektedir (Basit bir anlatımla, bu metot; ağ tarafından hesaplanan çıktı değerindeki toplam hata karesi minimum değerini bulmak için kullanılan kademeli eğim (Descent Gradient) metodundan ibarettir). Sonuçta, herhangi bir öğrenme ve eğitime tabi olmayan yeni verileri öngörmeye itimat edebileceğimiz ideal ağırlıklara ulaşma imkânımız olur. İşte yapay sinir ağlarının eğitim amacı da budur, bu algoritmalar çok katmanlı ağların eğitiminde kullanılır (Kisi, 2005; İssa, 2000)

$$\Delta w_{ji}(k+1) = \eta \delta_j x_i + \rho \Delta w_{ji}(k) \quad (3.43)$$

Burada

$$\delta_j = f'(net)(d_j - y_j)$$

$$\delta_j = f'(net) \sum \delta_{ji}$$

ρ : Momentum Katsayısı (Momentum Term)

Δw_{ji} .i, j: Hücreleri Ağırlıklarının Tadili Miktarı

η : Öğrenme Oranı Katsayısı (Learning Rate)

δ : Ağırlık Tadili Katsayısı (İstenilen Değer ile Çıktı Sinyali arasındaki Fark)

d : İstenilen Değer (Desired Value).

Y : Çıktı Sinyali Değeri

K : Tekrarlama Göstergesi (Iteration Index).

3.3.6. Yapay Sinir Ağlarında Öğrenme Algoritmaları

Ağ eğitimi, özenle seçilmiş olan örnekler grubunun verilmesi ile gerçekleşir, bu şekilde ağın hızlı öğrenme yoluna girmesine katkı sağlar. Bu örnekler grubuna Eğitim Kategorisi adı verilir. Yapay Sinir Ağlarının eğitim metodu eğitim kategorisine bağlı olarak İki bölüme ayrılır bunlar, Kontrollü Eğitim ve Kontrolsüz Eğitimidir (Gadoue, 2005). Yapay Sinir Ağlarındaki eğitim algoritmalarının amacı ise tercihli ağırlıkların değerini belirlemektir, bu amaç ağı bu Üç metot ile eğitilmesi ile mümkün olur (Mitchell, 1997):

- Gözetimli Eğitim (Supervised Learning)

Yapay Sinir Ağlarının kontrollü eğitimi, verilerin Girdi Modeli (Input Pattern) ve Çıktı Modeli (Output Pattern) denilen bir çift model şeklinde ağı verilmesi düşüncesine dayanır. Bu iki modelde hedeflenmiş çıktılar vektörüne bağlıdır (Target Output Vector). Ağ; ağ çıktıları ile gerçek çıktılar arasındaki farkı, daha sonra ağ çıktıları ile gerçek çıktılar arasında oluşan farkı aza indirmek için kullanılacak olan ağırlık tadil fonksiyonunun “Delta Fonksiyonu” (Delta Function) hesaplanmasında kullanır. Ağırlık tadilinin amacı ise ağırlık güncelleme fonksiyonu veya öğrenme fonksiyonu (Learning Function) kullanmak yoluyla bir yapay sinir ağı oluşması için gerekli olan en uygun sonuçları elde etmektir.

- Kontrolsüz Eğitim (Unsupervised Learning)

Yapay Sinir Ağlarının kontrolsüz eğitimi ya da kendi kendine eğitimin esası, çıktılarına verilecek olan bir grup verilerden elde edeceği girdi özelliklerini tanıma ve ayırt etme yeteneğine dayanmaktadır. Bu metot bir önceki kontrollü eğitimin aksine, vereceği sonuçları daha önceden hiç görmediği ve bilmediği örneklerden esinlenmeden verebilmesidir. Bu demektir ki, sinir ağları gösterilen modellerin özelliklerine uygun olarak bağlantı ağırlıkları düzenleme ve kendi birimlerini çalıştırma yeteneğine sahiptir.

Bu tür öğrenme türünde ağın belli bir girdiye karşılık uygun bir çıktı elde edilmesi için eğitim yapılmaz. Burada ağı sadece eğitim grubu girdi öğeleri verilir ve ağ

birbirleri ile benzer olan öğeleri bir grup içerisinde toplar ve öğrenme algoritmaları da ağ içerisinde bulunan bağlantı ağırlıklarını düzenler ve benzer gruplara transfer eder.

- Yeniden Destekleme Yolu ile Eğitim (Learning Reinforcement)

Destekleme eğitimi kontrollü ve kontrolsüz eğitim metotlarının karışımı esasına dayanmaktadır. Burada kontrolsüz eğitimde olduğu gibi çıktıların gerçek değerleri ağa bildirilmez, ancak burada kontrollü eğitimde olduğu gibi ağa sonuçlarının doğru ya da yanlış olduğu şekline işaret edilir. Bu türden olan ağların eğitimi için muhtelif algoritmalar bulunmakta, bunlardan bazıları ise:

- Geri Yayılımlı Sinir Ağları (Back Propagation Neural Networks)

Geri veya ters yayılımlı sinir ağları, ağ içerisinde bulunan devreler vasıtasıyla her İki yönde hareket edebilen ve transfer olabilen sinyallere sahip olabilir. Bu tür ağlar kuvvetli ve bir hayli komplike yapıya sahip olmakla birlikte denge noktasına varana değin sürekli bir şekilde hareket eder ve durağanlığını değiştirir, yani girdiler değişeceğinden yeniden denge oluşturmaya yönelir (Stergiou, ve Siganos, 1996).

Aynı zamanda hata geri yayılımlı sinir ağları, ağ çıktısı tarafından hesaplanan hata karesinin en düşük değerini saptayan ortalama hata karesi prensibine dayanır, modele en uygun sonucu veren ideal ağırlık değeri bulununcaya değin ağırlıklar, katmanlar arasında yenilenerek tekrarlanır. Hata geri yayılımı kontrollü eğitim (Supervised Learning) metodunu kullanır, buda ağa hesaplanması istenilen girdi ve çıktı örneği verilir demektir ve sonuçta hata payı hesaplanır (Gerçek ve tahmin edilen değerler arasındaki fark). Geri yayılımlı ağların ana düşüncesi ağın eğitim yolu ile öğrenmek suretiyle hatanın en aza indirilmesidir. Eğitim, ağın uyarlanması amacıyla hatanın en düşük düzeye kalmasını sağlamak için rasgele ağırlıklar ile başlar (Zurada, 1992).

- Geri Yayılımlı Sinir Ağlarının Algoritması

Hata geri yayılımlı sinir ağlarının algoritması eğitim ağlarında kullanılan en önemli algoritmalarından birisidir. Bu algoritma, gerçek sonuçlar ve elde edilmesi istenilen

sonuçlarıyla değeri belirlenen uygun hata fonksiyonu seçimine dayanmanın yanı sıra ağırlıklar ve eşikler gibi ağın özelliklerine de dayanmaktadır.

$$\mu = \sum_{i=1}^N w_i x_i \quad (3.44)$$

$$Y = f(\mu - \theta) \quad (3.45)$$

Burada:

($X_1, X_2, \dots, X_n$) Çıktıları temsil eder.

($W_1, W_2, \dots, W_n$) Ağırlıkları temsil eder.

μ = Nöron hassaslığı temsil eder.

θ = Eşiği temsil eder.

Y = Ağ çıktısını temsil eder.

$f()$ = Hassasiyet Fonksiyonunu temsil eder.

Hata geri yayılım algoritması İki ayrı metot ile uygulanabilir bunlar, on-line mode ve batch mode metotlarıdır. On-line modülünde hata fonksiyonu her girdi modülünde hesaplanır ve hata sinyali de ağ içerisinde geri teperek ağırlıkları tadil eder. Hesaplanan hata fonksiyonu ise burada gerçek değerler ile elde edilmesi istenilen değerler arasındaki ortalama hata karesidir MSE, yeni elde edilen ağırlıklar ise, modülün hesaplamasında kullanılır ve tüm modülleri temsil eder buna da tekrar (Iteration) denir.

Batch Modülünde ise hata sinyalleri her bir girdide yeniden hesaplanır, ağırlıklarda tüm değerlerin girmesi ve değerlendirilmesinden sonra tadil edilir ve düzeltilir, hata fonksiyonu da tüm sinyallerin hata grubunu MSE hesaplar, bu demektir ki bu modül her bir çıktı birimi veya tüm modüllerin MSE hesaplar (Ampazis, 1998).

3.3.7. Bilgilerin Yapay Sinir Ağlarında İşlenmesi

Bilgilerin yapay sinir ağlarında işlenmesini öğrenmek için aşağıda sıralanan terimlerin ne anlama geldiğinin bilinmesi gerekmektedir:

- Girdiler (Input)
- Çıktılar (Output)

- Ağırlıklar (Weights)
- Aktarma Fonksiyonu (Transformation Function)

Aktarma fonksiyonu iç aktifleşmeyi temsil eden toplayıcı ve birleştirici fonksiyon olan $Y = \sum_{i=1}^n X_{ij}W_{ij}$ ye dayalıdır, buna tetikleme fonksiyonu da denir. Burada sinir diğer sinirlerden veya dış kaynaktan gelen girdileri karşılar ve çıktıya gönderir. Lojistik Fonksiyonu ile Lojistik Aktarma Fonksiyonu bütün araştırmalarda kullanılan fonksiyonlardır, zira burada elde edilen çıktılar sıfır ile tam bir arasında sıkışmış rakamlar olarak ortaya çıkar ve fonksiyon bu şekli alır (Haykin, 1999; Kumar, 2004):

$$Y_x = \frac{1}{1+e^{-x}} \quad (3.46)$$

Burada:

Y_x :Aktarma Fonksiyonu

Y: Sinirler Arası Tercihli Ağırlıkları Gösteren Bileşik Rakamdır.

- Verilerin Toplanması ve Hazırlanması

Bu işlem ikiye ayrılmaktadır bunlar, Eğitim (Training) ve Test olup bu şekilde açıklaması mümkündür:

- Eğitim

Yapay Sinir Ağlarının iki tür eğitimi bulunmaktadır bunlar:

1 – Denetimli Eğitim Metodu (Supervised)

Bu metot ile veriler toplanır ve Girdi verileri ile Çıktı verileri olarak İki ayrı türe bölünür. Girdi verileri ileride öngörülen değerleri elde etmek amacıyla işlenir ve sonuçları çıktı değerleri ile karşılaştırılır, buna göre de ağırlıkların tadili yani düzeltilmesi yoluna gidilir.

2 – Denetimsiz Eğitim Metodu (Unsupervised)

Bu metot ile bir önceki metot arasında büyük bir benzerlik olmakla birlikte, ancak bu metotta çıktı değişkenlerinin herhangi bir değerinin bulunmaması farkı yer almaktadır. Girdi verileri gruplara ayrılarak ağ tarafından görülmeyen özellikleri bulunur, daha sonra girdi verileri gruplara ayrılarak kendi aralarında karşılaştırılır.

- Test

Yapay Sinir Ağları bağlantı kümelerinin orantılı ağırlık değişimi esasına dayanır, dolayısıyla bu tür ağların aşağıda açıklanan iki aşamada gerçekleşen öğrenme kuralları yaratma imkanına sahiptir:

Birinci aşama, bu aşamada orantılı ağırlıkların ilkel değerleri seçilir veya ağ bağlantı kümeleri arasındaki ağırlıkların ilkel değerleri rasgele seçilir. Ağırlıkların geliştirilmesi girdi verilerinin çıktıların hesaplanması eğitiminde oldukça etkili bir rolü bulunmakta, daha sonra hali hazır çıktılar ile ağda hedeflenen çıktıların karşılaştırılmasına başlanır.

İkinci Aşama, Bu aşamada ise, hâlihazır çıktılar ile ağda hedeflenen çıktıların hata karelerinin en düşük toplamının hesaplanması yoluyla yapılan karşılaştırma işlemi sonucunda elde edilen hata hesaplanır:

$$E = \sum_{i=1}^n \sum_{j=1}^k (X_{ij} - W_{ij})^2 \quad (3.47)$$

$$i = 1, 2 \dots n, \quad j = 1, 2 \dots k$$

Burada:

n = Numune Hacmi

K = Numune Adedi

i = Çıktı Katmanında İşlem Gören Öğelerin Adedi

x = Hedeflenen Çıktılar

y = Çıktı Katmanında İşlem Gören Öğeleri Temsil Eden Ağ Çıktıları

Hata Geri Yayılım yolu ile eğitim (Propagation Back-Error), ileri beslemeli sinir ağlarının en önemli yönlendirilmiş öğrenme yollarından birisidir, bu aşama Üç ayrı faz ile uygulanır, bunlar:

1 – İlerleme Fazı (Forward Phase)


Burada eğitim modülleri, her bir girdi için tahmin edilen çıktı tahsis etmek suretiyle sinir ağına tanıtılır, gerçek değer ile tahmin edilen değer arasındaki hata (Error) hesaplanır.

2 – Gerileme Fazı (Backward Phase)

Bu fazda, bir önceki fazda elde edilen gerçek değer ile tahmin edilen değer arasındaki farkı ileri itme veya geri çekme işlemi uygulanır.

3 – Ağırlıkların Tadili veya Düzeltilmesi Fazı (Adaptation of Weight Phase)

Burada çıktı modülü ile sinir ağı çıktısı arasındaki fark azaltılır, bu işlem aşağıda yer alan 3.11' No.lu şekilde gösterilmektedir:



Şekil 3.11. Hata Geri Yayılma Metodu (Alotaibi, 2003)

3.3.8. Yapay Sinir Ağları Kullanımı ile Öngörü (Kestirim)

Yapay Sinir Ağlarını kullanmak suretiyle öngörülerde bulunma birçok alanda önem kazanan modern bilimsel uygulamalardan birisi olmuştur. Girdiği alanlar arasında örneğin döviz fiyatları, mali gelir ve benzeri konuların öngörü için çok katı ve dakik

şartları gerektirmediginden yaygın bir şekilde kullanılmakta ve aynı zamanda olmayan verilerin davranışını açıklamaktadır.

Hata geri yayımlı ağıların öngörü işlevini aşağıda sıralanan adımlarla özetleyebiliriz (Sinha, 2002):

Birinci Adım, değişkenlerin seçimi (Variables Selection), problemi çok iyi bir şekilde temsil edecek olan değişkenlerin seçilmesi şarttır.

İkinci Adım, verilerin işlenmesi (Data Processing), kullanılacak olan veriler üzerinde genel yön belirleme, değişkenler arası ilişkiler ve verilerin dağılımı değerinin bulunması gibi bazı işlemlerin gerçekleştirilmesi.

Üçüncü Adım, verilerin gruplara ayrılması (Divide Data Set Into), var olan veriler bu gruplara ayrılır:

- Eğitim Grubu (Training Set) Veri numunesi öğrenme ve belirleme grubu.
- Test Grubu (Testing Set) Bu yolla varsayılan ağın yeteneğinin test edilmesi ve kullanma imkanının bulunup veya bulunmamasına karar verilir.
- Geçerlilik Grubu (Valid Action) Ağın nihai performansını test eden gruptur.

Dördüncü Adım, sinir ağı modeli (Örneği) (Neural Network Paradigm) Sinir ağı modelinin belirlenmesi sırasında aşağıda yazılı olanların belirlenmiş olması gerekmektedir:

- Girdi Nöronları, bağımsız değişkenlerin sayısına eşit olan.
- Gizli Katmanların Adedi, ağda kullanılacak olan hata değerine dayalı olan.
- Gizli Nöronların Sayısı, test yolu ile belirlenir.
- Çıktı Nöronu, genellikle Bire eşit olur.

Beşinci Adım, değerlendirme ölçütü (Evaluation Criteria) Hata değerlendirilmesi için geri yayımlı ağlarda kullanılan ölçüt Hata Kareleri Toplamıdır (MSE).

Altıncı Adım, ağı eğitimi (Neural Network Training) bu adımlardan oluşmaktadır:

- Modülün Eğitimi: Hata karesinin en düşük değerini belirleyen nöronlar arası ağırlıkların toplamının bulunması,
- Hata Geri Yayılımlı Ağ Algoritması: Eğriliği azaltmak için eğitim algoritması kullanılır.

Yedinci Adım, uygulama (Implementation) bu adımda ağın verilerdeki değişiklikler ile olan uyumu, eğitimin tekrarı imkanı ve veri değişiminde en düşük hata karesinin elde edilmesi gibi hususların test edildiğinden bu adımın en önemli adımlardan birisi olduğu kabul edilmektedir, Sinir ağlarının kurulması programlama yolu ile olur (Yapay sinir ağları bir bilgisayar programından ibarettir), bu program belli bir problemi çözmek için çok sayıda devreden oluşmaktadır (Ameen, 2005).

3.3.9. Modeller Arası Tercih Kriterleri

Gelecekteki değerleri öngörme işleminde kullanılan modeller arasından en uygun modeli seçme kriterleri aşağıda sıralanmaktadır:

3.3.9.1. Akaike Bilgi Kriteri (AIC)

Akaike isimli araştırmacı (1973) Akaike Bilgi Kriteri adıyla bilinen (AIC) Kriterini bulmuştur:

$$AIC = -2 (\text{maksimum şartlı olasılık}) + 2M$$

Model verilere göre M bilgisinde ise AIC Kriteri, kesin hata farkı miktarı delaletiyle bu şekilde olur:

$$AIC (M) = n \ln \sigma_{\alpha}^2 + 2M \quad (3.48)$$

Burada:

M: Modelin Seviyesi

n: Gözlem Adedi

σ^2 :Hata Farkı Miktarı olup $\sigma^2 = \sum_{t=1}^n (y_t - \hat{y}_t) / (n - p)$ formülü ile yazılır.

Kriterin en düşük değerini karşılayan model seçilir.

3.3.9.2. Bilgi Kriteri (BIC)

Araştırmacı Akaike 1978 – 1979 Yıllarında (AIC) Kriterini geliştirerek (BIC) adı verilen yeni bir kriteri (Bayesian Information Criterion) ortaya çıkarmıştır, bunun formülü de şöyledir:

$$BIC(M) = n \ln \sigma_{\varepsilon}^2 - (n - M) \ln \left(1 - \frac{M}{n} \right) + M \ln(n) + M \ln \left[\frac{\frac{\sigma_y^2}{\sigma_{\varepsilon}^2} - 1}{M} \right] \quad (3.49)$$

Burada:

σ_{ε}^2 : Hata Farkı Miktarı

n: Bilgi Adedi

M: Modelin Seviyesi

σ_y^2 : Seri Farkı Miktarı

Kriterin en düşük değerini karşılayan model seçilir.

3.3.10. Yapay Sinir Ağları ve Zaman Serileri

Aktif bir uygulama alanı olan Zaman Serisi kanalıyla geleceği kestirim uygulaması sırasında yapay sinir ağlarının kullanımı pek yaygındır. Zaman serileri ile kestirim (Öngörü) metodunun kullanıldığı ve genel olarak zaman serileri analizi yöntemleri olarak bilinen klasik yöntemlerden olan hareketli ortalama, sigmoid fonksiyonu ve Box-Jenkins modelleri gibi çok sayıda klasik istatistik uygulamalarına alternatif veya paralel metot olarak yapay sinir ağları tekniği kullanılmaya başlandı. Öngörü uygulamalarında kullanılan yapay sinir ağları modelleri klasik öngörü uygulamaları ile rekabet ederek elde ettiği sonuçların güvenilirliği ve doğruluğu ile birçok durumda daha da üstünlük kazanmıştır. Yapay sinir ağlarının zaman serileri içerisinde öngörü yeteneğini ortaya koyarak çizgisel olmayan verileri işlemede bir hayli yetenekli olduğunu kanıtlamıştır. Aslında, bütün veri serileri doğrudan çizgisel olmayan ilişkiler ortaya koymaktadır, bu durumda yapay sinir ağlarına klasik öngörü metotlarına kıyasla daha bir üstünlük sağlamaktadır. Zira birçok klasik öngörü metodu çizgisel üslup kullanmakta yani çizgisel verileri ile işlem yapmaktadır.

Zaman serileriyle öngörü uygulamaları amacıyla yapay sinir ağlarının kullanımı Seksenli Yılların sonunda başlanmıştır, bunun ilk girişimi 1987 Yılında (Farber) ve (Lapedes) tarafından gerçekleştirilmiştir, istikrarlı olmayan zaman serisiyle öngörü için çok katmanlı Multi Layer Perceptron ve geri yayılım algoritmasını kullanmışlardır. Bu çalışma doğrusal regresif ve Box-Jenkins modelleri gibi çok sayıda klasik istatistik uygulamalarına kıyasla daha üstün sonuçlar verdi. Şimdi ise yapay sinir ağları zaman serileri içerisinde kullanılan en yaygın ve temel üslûlerin başında gelmektedir.

3.3.10.1. Zaman Serileri ile Öngörü Tahminlerinde Yapay Sinir Ağlarının Uygulanması için Gerekli olan Kararlar

Zaman serileriyle öngörülerde bulunmak amacıyla yapay sinir ağı kurulması gerekli olan işlemler aşağıda sıralanmaktadır:

- Sinir ağının mimari yapısının belirlenmesi, yani istenilen katman sayısının ve katmanlar içerisindeki nöronların sayılarının belirlenmesi.
- Öngörüü oluşturmada kullanılan zaman verileri miktarını belirleyen girdi katmanındaki nöron adedinin belirlenmesi.
- Sadece tek öngörü ile uyuşan nöronları içeren çıktı katmanı.
- Ağın, zaman serisi eğilimleri ile elde edilen öngörüler arasındaki doğrusal olmayan ilişki yaklaşımı performansını belirleyen gizli katmandaki nöron adedinin belirlenmesi.
- Yapay sinir ağına girilecek olan veriler üzerinde bir takım matematiksel dönüşümler yapmak suretiyle hazırlanması ağın performans ve işlevini kolaylaştıracaktır.
- Yapay sinir ağları uygulamalarında en önemli faktör olan uygun nitelikteki eğitim algoritmasının seçilmesi.

3.3.10.2. Zaman Serileri ile Öngörü Tahminlerinde Kullanılan Yapay Sinir Ağları Türleri

Zaman serileriyle öngörülerde bulunmak amacıyla kullanılan yapay sinir ağlarının en yaygın olan türleri aşağıda sıralanmaktadır:

1. Çok Katmanlı Multi Layer Perceptron (MLP) Ağı.
2. Işın Tabanlı Fonksiyonlu Ağ (Radial Basis Function) (RBF).
3. Geri Dönüşümlü Ağ (Recurrent Networks).
4. Sigma – pi & pi Sigma Ağı.
5. Ridge Polynominal Ağı.
6. Aşırı Öğrenme Aleti (Prediction of the Concentration of Air Pollutants Based on ELM).

Yukarıda sıralanan bu ağlardan bazılarını açıklamaya çalışacağız ve bunlardan en önemli olanı çok katmanlı Multi Layer Perceptron (MLP) ağı olup bazı malların satışıyla ilgili zaman serisiyle veri analizlerinde kullanılmıştır.

Çok Katmanlı Multi Layer Perceptron (MLP) Ağı: Zaman serileriyle öngörülerde bulunmak amacıyla kullanılan yapay sinir ağlarının en yaygın olanıdır, bu ağın çalışma düzeni zaman serisinin önceki değerlerinin ağa girdi olarak verilmesidir, doğrusal olmayan dönüştürücü kullanılarak girdi ağırlıkları gizli katmanda toplanır. Öngöründe kullanılan MLP Ağı genel formülü de:

$$\tilde{X}_{(t)} = w_0 + \sum_{j=1}^h w_j f_j \left[\sum_{i=1}^n w_{ij} x(k-i) \right] + w_{j0} \quad (3.50)$$

Burada:

h.: Gizli Katman Birim Adedi

n.: Girdiler Birim Adedi

w_{ij} .: Girdiler ile Gizli Katman Arasındaki Ağırlıklar

w_j .: Çıktı Katmanı ile Gizli Katman Arasındaki Ağırlıklar

f_j .: Gizli Birimler Tetikleme Fonksiyonu

4. ARAŞTIRMA BULGULARI VE TARTIŞMA

Bu bölümde, yazıcı sarf malzeme satışları göstergesi zaman serisi verilerinin analizi için gerekli olan bütün bilimsel metotlar ele alınacaktır. Amaç, araştırma modeli üzerine Box–Jenkins (B-J) metodu ile yapay sinir ağları metodu uygulanarak, sonuçlarına göre hangi metodun gelecek değerleri öngörmeye daha uygun olduğunu saptamaktır.

Aynı zamanda bu bölüm kapsamında bütün veriler ile bunların “R 3.6.1”, “Microsoft Excel” “IBM-SPSS-Statistics25” ve “Minitab” gibi istatistikte kullanılan programları kullanarak yapılan analizleri de yer almaktadır. Başlangıçta mümkün olan Bütünleşik Otoregresif Hareketli Ortalama SARIMA (p, d, q) modellerinden en uygun olanını işleme uyarlama ve daha sonrada yapay sinir ağları (YSA) kullanılarak en uygun model belirlenir. Bu işlemlerden sonra özel istatistik ölçümlerin kullanılmasıyla her iki modelden elde edilen sonuçlar karşılaştırılarak serinin ileriki değerlerini öngörmek için en uygun olan model belirlendikten sonra en uygun olan bu model üzerinden seri değerlerinin öngörme aşamasına geçilir.

4.1. Verilerin Tanımı


Elimizde bulunan veriler 132 aylık gözlemden oluşan Ocak 2008 ile Aralık 2018 Ayları arasında ABD doları ile gerçekleşen aylık yazıcı sarf malzemeler satışları verileridir. Verilerin toplanması ve analiz edilmesi istatistik biliminin en önemli görevlerinden birisidir. Bu verilerin özellikleri ile ilgili genel bir bilgi elde edebilmek için bu verilerin bir takım tanımsal istatistiklerini sıralamak gerekir. Sıralama “R 3.6.1” programını kullanarak aşağıda elde edilen sonuçlar Çizelge 4.1’de gösterilmektedir:

Çizelge 4.1. İstatistiksel Tanımlar

Veri	Örnek Hacmi (N)	Min. Değer	Max. Değer	Hesap Ortalaması	Ortak Payda	Eğim	Basıklık
Değer	132	240	698	464.704545	484	-0.272863	-0.920264

4.2. Verilerin Hazırlanması

Dört aşamalı Box-Jenkins Metodu kullanmadan önce bütün verilen ortalama ve farklılıkları yönünden durağan hale getirilmeleri için gerekli olan dönüşümlerin uygulanması gerekmektedir. Bunu gerçekleştirmek için de zaman serisinin grafiği çizilir. Bu grafikte çalışma konusu olan yazıcı sarf malzeme satışları miktarlarının gelişim modelini gösterilmekte olup bununla da bu satışların genel bir yönünün bulunup veya bulunmadığı, farklılıkların bulunmadığının belirlenmesi, seri içerisinde aşırı veya aykırı herhangi bir değerin bulunup veya bulunmadığı gibi temel özelliklerine ulaşma imkânı sağlanır.



Şekil 4.1. ABD Doları ile Aylık Yazıcı Sarf Malzemeler Satışla Miktarı Zaman Serisi Grafiği (2008-2018 Yıllar Arası)

Şekil 4.1 ise “R 3.6.1” Programını kullanarak elde edilen o zaman serisinin resmini göstermektedir. Burada anlaşıldığı üzere zaman serisinin davranışının dönemsel olduğunu ve ortalamada durağan olmadığını göstermektedir.


Gerileme zamanlarının (Lags) toplam ağırlıklarını incelemek amacıyla Çizelge 4.2 üzerinden ele alındığında en son çizgi olan (24) sınırında (Ljung-Box) (Q- stat) ın hesaplanabilir değeri (1452.67) olduğu görülmektedir. Bu değer ($X^2_{(0.05,24)} = 36.42$) istatistiği çizgisel değerinden büyük olduğundan otokorelasyon fonksiyonu işlemleri sıfıra eşittir. Varsayımını dikkate alarak serinin durağan olmadığına karar verebilir. Çizelge 4.2'deki sonuçlar "Minitab" kullanarak elde edilmiştir.

Çizelge 4.2. Zaman Serisinin Durağanlık Testleri


Lag	ACF	LBQ	PACF
1	0.975499	128.49	0.975499
2	0.950735	251.47	-0.017835
3	0.923758	368.48	-0.058390
4	0.895162	479.21	-0.047199
5	0.865140	583.45	-0.042539
6	0.834672	681.25	-0.022448
7	0.803172	772.54	-0.034679
8	0.771355	857.41	-0.021747
9	0.739282	936.00	-0.020529
10	0.707036	1008.48	-0.020101
11	0.674334	1074.95	-0.026767
12	0.642123	1135.73	-0.008407
13	0.603694	1189.90	-0.148129
14	0.565439	1237.83	-0.021455
15	0.527864	1279.95	-0.000749
16	0.489843	1316.54	-0.027900
17	0.451452	1347.88	-0.029259
18	0.412619	1374.30	-0.036368
19	0.373745	1396.17	-0.025247
20	0.335092	1413.90	-0.022430
21	0.297634	1428.02	-0.003689
22	0.260477	1438.93	-0.023026
23	0.222924	1446.99	-0.039161
24	0.186215	1452.67	-0.018061

Bununla birlikte, temel seri verilerinin otokorelasyon ve kısmi otokorelasyon Fonksiyonlarını gösteren Şekil 4.2 ve 4.3'dan Görüldüğü üzere, temel seri verilerinin otokorelasyon fonksiyonu ile kısmi otokorelasyon işlemleri güvenlik sınırı dışında kalmaktadır. Bu demektir ki, işlemlerin %5'lik ağırlık seviyesi içerisinde ağırlık

olarak Sıfırdan farklıdır, bunun da anlamı zaman serisinin durağan olmadığıdır. Şekil 4.2'deki sonuçlar “R 3.6.1” kullanarak elde edilmiştir.



Şekil 4.2. Temel Seri Otokorelasyon Fonksiyonu (AFC)



Şekil 4.3. Temel Seri Kısmi Otokorelasyon Fonksiyonu (PAFC)


Ortalamanın durağan olmadığından emin olmamak için kök birim testlerinden olan (KPSS), (ADF) ve (PP) Testleri uygulanmıştır. Aşağıda yer alan Çizelge 4.3'de bu testlerin sonuçları yer almaktadır. Şekil 4.3'deki sonuçlar “R 3.6.1” kullanarak elde edilmiştir.

Çizelge 4.3. Yazıcı Sarf Malzemeler Satışları Serisi için KPSS, PP ve ADF Testleri Sonuçları

Testin Adı	Değeri	P – Değeri	Durum
Dickey – Fuller (ADF) Testi	-2.1917	0.4968	Durağan değil
Phillps – Perron (PP) Testi	-6.1868	0.7589	Durağan değil
KPSS Testi	2.2064	0.01	Durağan değil

Çizelge 4.3'ten anlaşıldığı üzere Dickey–Fuller (ADF) testi ve Phillips–Perron (PP) testlerinin P değeri 0.05 ten büyük olduğu aynı zamanda da bu değer (KPSS) testinde ise 0.05 ten küçük olduğu görülmektedir, bu durumda zaman serisinin ortalamada durağan olmadığının bir kanıtıdır. Çizelge 4.3'deki sonuçlar “R 3.6.1” kullanarak elde edilmiştir.


Bundan dolayı Şekil 4.4'te açıklandığı gibi zaman serisinin Birinci Dönemsel Farkı “R 3.6.1” kullanarak alınmış göstermektedir.




Şekil 4.4. Birinci Dönemsel Farktan Sonra Yazıcı Sarf Malzemeler Satışları Zaman Serisi

Esas veya temel zaman serisi verilerinin birinci dönemsel farkı alındığında, Şekil 4.4'de görüldüğü gibi zaman serisi, Otokorelasyon ve Kısmi Otokorelasyon Fonksiyonları değerlerinin tamamı güven sınırı içerisinde kalır. Şekil 4.5 ve 4.6, aynı zamanda Çizelge 4.4'da görüldüğü gibi çizgi (24)'e denk gelen (Ljung-Box)

Hesaplanabilir Değeri ($11.5806 < X^2_{(0.05,24)} = 36.42$) değerinden düşük olduğu bu demektir ki serinin Birinci Dönemsel Farkının alınmasından sonra durağan hale gelmiştir.



Şekil 4.5. Yazıcı Sarf Malzemeler Satışları Birinci Dönemsel Fark Sonrası Otokorelasyon Fonksiyonu



Şekil 4.6. Yazıcı Sarf Malzemeler Satışları Birinci Dönemsel Fark Sonrası Kısmi Otokorelasyon Fonksiyonu

Çizelge 4.4. Zaman Serisi Birinci Dönemsel Fark Sonrası Durağanlık Testleri

Lag	ACF	LBQ	PACF
1	0.078403	0.8239	0.078403
2	0.097760	2.1146	0.092180
3	0.108543	3.7183	0.095755
4	0.098317	5.0444	0.077528
5	0.021260	5.1069	-0.007887
6	0.068426	5.7595	0.043788
7	-0.004376	5.7622	-0.029870
8	0.015426	5.7959	-0.000231
9	-0.001402	5.7962	-0.011308
10	0.035758	5.9803	0.030358
11	-0.023900	6.0633	-0.026038
12	-0.160263	9.8237	-0.170695
13	0.008582	9.8346	0.029787
14	-0.052069	10.2383	-0.031724
15	0.017563	10.2847	0.058949
16	0.012912	10.3099	0.037566
17	-0.006014	10.3155	-0.005141
18	-0.036794	10.5242	-0.024418
19	-0.047591	10.8765	-0.067653
20	-0.041433	11.1460	-0.027562
21	-0.040903	11.4110	-0.030029
22	-0.030947	11.5641	0.007405
23	-0.009702	11.5793	0.006119
24	-0.002880	11.5806	-0.009737

Buna göre diyebiliriz ki, zaman serisi Birinci Fark işlemi sonrasında durağan hal gelmiştir. Serinin durağanlaştırılması için gerekli olan farklılığın minimum değeri ($d=1$) olur.

Ortalamanın durağanlığından emin olmak için kök birim testlerinden olan (KPSS), (ADF) ve (PP) Testleri uygulanmıştır. Aşağıda yer alan Çizelge 4.5'de “R 3.6.1” kullanarak bu testlerin sonuçları yer almaktadır.

Çizelge 4.5. Yazıcı Sarf Malzemeler Satışları Serisi için KPSS, PP ve ADF Testleri Sonuçları

Testin Adı	Değeri	P – Değeri	Durum
Dickey–Fuller (ADF) Testi	-3.6608	0.03	Durağan
Phillips–Perron (PP) Testi	-132.68	0.01	Durağan
KPSS Testi	0.091759	0.1	Durağan

Yukarıda yer alan Çizelge 4.5'den anlaşıldığı üzere, (ADF) ve (PP) Testlerindeki P-Değeri 0.05 ten az olduğudur. Bu da ki yokluk olasılığı teorisinin reddedildiği (H_0 : Kök birim varlığı) anlamına gelir. (KPSS) Testinde ise bu değer 0.05 ten büyük olduğu görülmekte olup bu da yokluk olasılığı teorisinin reddedilmediği (H_0 : Kök birim bulunmaması) anlamına gelir. Dolayısıyla ilk farklılık serisinin durağan olmasına neden olmakta ve bu testlerin sonucunda çalışmamız konusu olan zaman serisinin durağan olduğunu kanıtlamaktadır.

4.3. Box-Jenkins Metodu Kullanılarak ARIMA Modelinin Oluşturulması

Yazıcı sarf malzemeler satışı miktarlarını aşamalarına göre Box-Jenkins Metodu uygulayarak öngörüle bulunmaya çalışılmıştır.

4.3.1.Tanımı ve Belirlenmesi Aşaması

Durağan bir zaman serisine ulaşıldıktan sonraki adımda ilk olarak çalışma konusu zaman serisine uygun dönemsel modelin belirlenmesine geçilir. Çizelge 4.6'de açıklandığı gibi (RMSE, MAE, MAPE, MASE, AIC, BIC) ölçütlerine dayanılarak (R 3.6.1) programı vasıtasıyla birden fazla model ele alınmıştır.

Çizelge 4.6. Zaman Serisi için En Uygun Dönemsel Modelin Seçimi

Model	RMSE	MAE	MAPE	MASE	AIC	BIC
ARIMA(0,1,0) (0,0,1)	14.31712	6.47052	1.451328	0.093595	1076.64	1085.26
ARIMA(0,1,0) (0,0,0)	14.92483	7.176106	1.556303	0.103801	1082.95	1085.83
ARIMA(0,1,0) (1,0,0)	14.80679	7.610727	1.642465	0.110088	1083.09	1088.84
ARIMA(0,1,0) (1,0,1)	14.78277	7.558436	1.634145	0.109331	1084.78	1093.41

Çizelge 4.6' te görüldüğü gibi bu tabloda görüldüğü üzere en uygun modelin ARIMA (0,1,0) (0,0,1) olduğudur zira bu model en düşük istatistiksel ölçüt değerlerini (RMSE, MAE, MAPE, MASE, AIC, BIC) içermektedir. Dolayısıyla öngörü için önerilen en uygun modelin ARIMA (0,1,0) (0,0,1) Modeli olduğu görülmektedir.

Bu modelin fonksiyon değerleri “R 3.6.1” kullanarak aşağıda Çizelge 4.7'te gösterilmektedir:

Çizelge 4.7. Önerilen ARIMA(0,1,0) (0,0,1) Modeli Fonksiyon Tahmini

Model	Fonksiyonu	Değeri	Standart Hata
MA(1)	θ_1	-0.2168	0.0950

Bu tablodan anlaşıldığı üzere, θ_1 Fonksiyonun tahmin edilen mutlak değeri standart hatanın (0.4336) iki mislinden daha da büyüktür, bu da önerilen model fonksiyonun sağlamlığını göstermektedir.

4.3.2. Teşhis Aşaması

Bu aşama Box-Jenkins Metodolojisinde temel aşamalardan birisi olarak kabul edilmektedir. Bu aşamada önerilmiş olan modelin ne derecede kabul gördüğü saptanır. Bu aşama ile ya kullanılmakta olan modelle analizlere ve istenilen hedefe doğru devam edilmesi ya da bunu bırakıp tekrar başa dönülmesine karar verilir. Burada ele alınan model birden fazla istatistiksel testlere tabi tutulur, model bu testleri başarı ile geçtiği durumda kullanmaya elverişli olduğu demektir. Söz konusu bu testler ise durağanlık, yansıtma, kalıntıların analizi ile modelin en düşük ve en yüksek uygunluk belirleme testleridir.

4.3.2.1. Durağanlık ve yansıma Araştırması (Stillness and reflection)


Bir modelin durağanlık ve yansıtma şartlarının oluşması o modele girilen verileri alma ve kabul etme kapasitesinin göstergesidir. Bilindiği üzere bütün hareketli ortalama serileri, θ Fonksiyonu üzerine herhangi bir kayıt veya şart getirmeden her zaman durağandır ve hareketli ortalama işlemi aynı zamanda da yansıtma şartlarını gerçekleştirmektedir, bu modelin yansıtma şartı da $|\theta_1| < 1$ dir.

Bu da bu model için kabul edilebilir bir değerdir zira Tablo 5.4'te görüldüğü gibi $|\theta_1| = 0.2168 < 1$ dir.

4.3.2.2. Kalıntı Analizi - Artıklar Analizi (Residual analysis)

Modelin teşhis ve öngörü işlemlerine olan uygunluğundan emin olmak amacıyla, seçili model kalıntılarının (Hataların) Otokorelasyon ve Kısmi Otokorelasyon Fonksiyonları test edilir Şekil 4.7' de Burada görüldüğü gibi bütün Otokorelasyon ve Kısmi Otokorelasyon Fonksiyonları değerlerinin tamamı güven sınırı içerisinde kalmaktadır. Bu demektir ki, modelin bütün hataları rastgele değişkenlerden ibaret olup Şekil 4.7' de görüldüğü gibi doğal dağılım trendi izlemektedir.


Şekil 4.7'dan anlaşıldığı üzere kalıntı (Residuals) serisinin “R 3.6.1” kullanarak sıfır çevresinde nispeten toparlandığı görülmektedir.



Şekil 4.7. ARIMA (0,1,0) (0,0,1) Modeli Kalıntı, Otokorelasyon ve Ljung – Box Testi Grafiği

Ljung – Box Testi ile ilgili olan Şekil 4.7. son kısmından anlaşıldığı üzere P-Value değerlerinin tamamı bütün zaman dilimlerinde 0.05'ten fazla olduğudur. Kalıntıların rasgele oluşundan emin olmak içinse Otokorelasyon Fonksiyonuna (ACF) bakmak yeterlidir. Aynı şekil 4.7'nin ikinci kısmında ise her bir zaman dilimi içerisindeki kalıntıların bütün Otokorelasyon Fonksiyonları güven sınırı içerisinde kalmaktadır, bu demektir ki bu modelin kalıntıları birbirleri ile bağlantılı olmayıp bu kalıntılar rasgele sıralanmaktadır.

Kalıntıların tekrarlanan eğim ve Normal Q-Q çizimi şekilleri bu kalıntıların dağılımını (Standardized Residuals) belirlemektedir. Kalıntıların (Residuals) tekrarlanan eğimini temsil eden Şekil 4.8'de görüldüğü üzere bu kalıntıların tam olmasa bile doğal düzene meyilli olduğu ve Normal Q-Q çiziminde temsil eden yine bu şekilden bütün kalıntıların (Residuals) “R 3.5.1” kullanarak doğru bir çizgi etrafından sıralandığı görülmektedir. Ancak sağ tarafta bulunan bazı değerlerin eğim çizgisinden uzaklaştığı görülmektedir. Bu da kalıntı dağılımının (Standardized Residuals) doğal olmadığının bir kanıtı olarak kabul edilebilir.



Şekil 4.8. Kalıntıların Tekrarlanan Eğimi ve Normal Q-Q Çizimi

Bu işlemde emin olmak amacıyla kalıntıların dağılım özellikleri Jarque – Bera Testine tabi tutularak aşağıda yer alan Çizelge 4.8'da gösterilmektedir:

Çizelge 4.8. Kalıntıların Dağılım Özelliklerini Belirten Jarque – Bera Testi Sonuçları

Jarque-Bera Test	X-squared	DF	p-value
	2740.2	2	2.2e-16

Burada görüldüğü üzere p değeri 0.05 ten az olduğu ve bunun da Sıfır Teorisini (H_0 : Kalıntı Doğal Dağılımı) reddetmek için yeterli bir neden olduğu ve aynı zamanda kalıntılarda doğrusal olmayan bir düzenin bulunduğu kanıtıdır, bundan dolayı doğrusal olmayan diğer modellerin kullanılmasının gerekli olduğunu göstermektedir.

4.3.3. Değerlendirme Aşaması

ARIMA(0,1,0) (0,0,1) Modeli değerlendirme sonuçları ile ilgili olan Çizelge 4.9'den anlaşıldığı üzere “Minitab” kullanarak SAM(01) Modeli parametrelerinin tahmini değerinin tamamı; fonksiyon seviyesi değerinin (P-value) %5 ağırlık seviyesinden düşük olması halinde ağırlıklı olur.

Çizelge 4.9. ARIMA (0,1,0) (0,0,1) Modeli Parametreleri Test ve Değerlendirmesi

Parameter	Estimate	Std. Error	T	P-value
SMA(01)	0.2443	0.0958	2.55	0.012

Yaptığımız çalışma sonunda yazıcı sarf malzemeler satışı miktarının öngörülmesi için gerekli olan bütün muayene ve teşhis testlerini üstün başarıyla geçmiş ve kanıtlanmış olan modelin diğer modellere nazaran ARIMA(0,1,0) (0,0,1) Modeli olduğunu saptamıştır.

ARIMA(0,1,0) (0,0,1) Modeli kullanılarak filen gerçekleşen değerleri ile öngörülen değerler arasındaki öngörü hata miktarını saptamak için öngörü Doğruluğu ölçütü olan MAE, MAPE ve RMSE kullanılmış ve bu sonuçlar “R 3.6.1” kullanarak elde edilmiştir. Çizelge 4.10'da görüldüğü gibidir.

Çizelge 4.10. ARIMA(0,1,1) Modeli Öngörü Doğruluğu Ölçütü

ARIMA(0,1,0) (0,0,1)	MAE	RMSE	MAPE
	64.99551	65.10048	9.481377

4.4. Yapay Sinir Ağları (YSA) Modelinin Oluşturulması

YSA zaman serilerinin analizi için kullanılan en uygun ve kolay metotlardan birisidir, burada verileri herhangi bir işleme tabi tutmadan kullanmak mümkündür. Araştırmacılar, zaman serilerinin öngörülerinde değişik ağları kullanmış ancak bunların içerisinde ve bu çalışmamızda kullanmış olduğumuz MLP Sinir Ağı en yaygın kullanıma sahip sinir ağı olmuştur.

Veriler rastgele seçilmiş olup bunların %80' eğitim ve %20' testi kullanılmıştır. Aynı zamanda Sinir Ağları Araçlarının (Neural Network Toolbox) uygulama metodunu belirlemek için de IBMSPPS Statistics25 Programı kullanılmıştır.

Verileri ağı girmeden önce çalışmamızın konusu olan seri yapay sinir ağları ile bazı bölümlendirmeler ile donatılmıştır, zira yazıcı sarf malzemeler satışları zaman serisi birçok dış faktörden etkilenmektedir. Bunlar, dolar fiyatındaki dalgalanmalar,

mürekkebin kalitesi, türü, rengi ve satış fiyatları gibi faktörlerin yanı sıra mevsimsel veya siyasi değişikliklerde zaman serisini etkilemektedir. Buna göre de girdi ve çıktı katmanları zaman serisinin bölünmüş değerleri Şekil 4.9'te gösterildiği gibi inşa etmiş olduğumuz Altı adet veri grubunun her birisi için bu şekilde oluşmaktadır (x_{t-12} , x_{t-24} ... x_{t-k}).



Şekil 4.9. Yapay Sinir Ağları Modelinde Kullanılan Veriler

Modelleri muhtelif sayıda gizli katman ve muhtelif sayıda sinir hücreleri ile (1-50) tasarlanmış ve rastgele seçilmiş muhtelif tekrarları (epoch) ile birden çok teste tabi tutulmuştur, verilerden elde edilen modeller seçilmiştir.


Ağın eğitimi ve ön beslemeli sinir ağlarının geri yayılım algoritmasının uygulanmasından sonra, YSA modeli Çizelge 4.11'de görüldüğü gibi MAPE ve RMSE ile “R 3.5.1” kullanarak elde edilmiştir.

Çizelge 4.11. Yapay Sinir Ağları Modeli

Kullanılan Zaman Serisi	Giriş Katmanındaki Nöron Sayısı	Gizli Katman Sayısı	Çıkış Katmanı	MAPE (%)	RMSE
YSA	5	5	1	0.061	1.283

4.11'lu Çizelgeyi incelediğimizde, Modelde YSA (5.5.1) bir giriş katmanı, bir gizli katman ve bir çıkış katmanı bulunmaktadır. Giriş katmanında beş, gizli katmanda beş, çıkış katmanında ise bir nöron bulunmaktadır.

Bu modelde bilgi güncellenmesi için ön beslemeli sinir ağıları için geri yayılım algoritması uygulanmıştır. Aktarma Fonksiyonu olarak (Normalized) seçilmiş ve gizli katmanlar içinde minimum ve maksimum değeri (1–50) arası olan (Architecture) belirlenmiştir. Eğitim türünden (Type of Training) eğitim fonksiyonu olarak (Batch) seçilmiştir, iyileştirme algoritmasından (Optimization Algorithm) (Scaled Conjugate Gradient) seçilmiş, ağ eğitimi işlev kalitesi için de (Mean of Squares Error Performans) belirlenmiş ve (Maximum Training Epochs) kendiliğinden hesaplanmıştır. Şekil 4.10'te “SPSS” kullanarak elde edilmiş olan yapay sinir ağı modelinin temsil etmektedir.



Şekil 4.10. Deneylerden Elde Edilmiş olan Yapay Sinir Ağı Modeli

4.5. Yapay Sinir Ağları Metodu ile Box – Jenkins Metodunun karşılaştırılması ve Öngörü Talebi

Çizelge 4.12'te yazıcı sarf malzemeler satışlarının öngörüsü için kullanılacak olan en uygun modelin belirlenmesi amacıyla Irak cumhuriyetinin farklı illerinde gerçekleşen yazıcı sarf malzemeler satışı verileri için kullanılan metotlardan elde edilen RMSE, MAE ve MAPE öngörü doğruluğu ölçütü “R 3.5.1” kullanarak gösterilmektedir.

Çizelge 4.12. Box-Jenkins Metodu ile Yapay Sinir Ağları Metodunun Öngörü Doğruluğu Ölçütlerinin Karşılaştırılması

Model	MAE	RMSE	MAPE
ARIMA(0,1,0) (0,0,1)	64.99551	65.10048	9.481377
YSA(5.5.1)	19.05708	22.89402	2.97907


Yukarıda Çizelge 4.12'te görüldüğü üzere RMSE, MAE, MAPE öngörü doğruluğu ölçütüne dayalı olarak yapılan karşılaştırmada YSA(5.5.1) sinir ağı modelinin öngörü doğruluğu ölçütü değeri daha düşük olduğundan ARIMA(0,1,0) (0,0,1) Modelinden daha üstün olduğu, dolayısıyla çalışma konusu için en uygun ve ileriki öngörüler için daha elverişli olan model YSA(5.5.1) sinir ağı modelidir.

Öngöründe bulunmak zaman serilerinin modern analizlerinin en son aşamasıdır, bu aşamaya ancak yapay sinir ağları ile Box–Jenkins modellerinin arasından en uygun olanın seçildiğinden emin olunması gerekir. MAPE Ölçütünün en düşük değerini bulmak için YSA (5.5.1) Modeli kullanılmış ve Ocak 2019 ile Aralık 2020 Ayları arası 24 adet ileriki değer için öngöründe bulunulmuştur. Öngöründe bulunduğumuz 24 adet sonucu daha önceden bilgi sahibi olduğumuz filen gerçekleşen sonuçlarla karşılaştırarak aşağıda Çizelge 4.13'te yer alan sonuçlar “SPSS” kullanarak elde edilmiştir. Bundan 2020 yılındaki tahminleri, yazıcı sarf malzemeleri satışlarının miktarında bir iyileşme olduğunu göstermektedir.

Çizelge 4.13. YSA (5.5.1) Modeli Öngörü Değerleri

Aylar	Gerçek Veriler		Öngörüler Veriler	
	2017 Değerleri	2018 Değerleri	2019 Değerleri	2020 Değerleri
Ocak	602	641	638.18	616.31
Şubat	606	655	637.33	615.54
Mart	610	653	627.86	624.14
Nisan	613	658	625.66	625.42
Mayıs	614	662	612.41	635.67
Haziran	616	664	685.23	638.91
Temmuz	624	668	676.54	640.38
Ağustos	626	673	674.88	643.22
Eylül	629	677	667.76	648.15
Ekim	630	682	662.5	650.61
Kasım	634	689	656.6	650.16
Aralık	647	698	644.49	646.53

Şekil 4.11'te orijinal ile tahmini seri eğrileri arasındaki benzerliği görülebilir.



Şekil 4.11. YSA (5.5.1) Modelin Gerçek ve tahmini değerleri.

5. SONUÇ ve ÖNERİLER

İstikrarsız ve yenileşmekte olan bir çevrenin gerektirdiği yenileşen bilgi çağında etkin, hızlı ve sürekli performans iyileştirmeler gerekmektedir. Bu nedenle kurumların bu değişken ortamda devamlılık, dayanabilirlik ve uyum sağlayabilmeleri şarttır. O yüzden satış miktarlarının geleceğini öngörmek için en uygun modelin oluşturulması hedef olarak koyulması faydalı olacaktır. Bu çalışmada iki adet istatistiksel model kullanılmış olup bunların birincisi Bütünleşmiş Otoregresif Ortalama Modeli (ARIMA) ikincisi ise Yapay Sinir Ağları (YSA) modelidir. Bu iki model yazıcı sarf malzeme satışları miktarlarının karşılaştırılması amacıyla uygulanmış olup aşağıdaki sonuçlar elde edilmiştir.

Bu çalışmada zaman serisi yöntemlerinden, “Box-Jenkins (ARIMA)” ve “Yapay Sinir Ağları” yöntemlerinin öngörü doğruluklarını karşılaştırarak en yüksek doğruluğu sağlayan yöntem ve modelin belirlenmesi ve belirlenen model yardımıyla 2008–2018 yılları için Irak’taki yazıcı sarf malzemelerin satış miktarını aylar itibariyle modellenmesi amaçlanmıştır. Yazıcı sarf malzemeleri satışları zaman serisi, varyans ve ortalama yönleri ile durağan olmayan bir seridir. Aylık zaman serileri için gerekli olan durağan ve tahmin ile öngöründe bulunmaya uygun bir modelin elde edilmesi için ister girdi isterse gizli katmanlar olsun çok katmanlı modellere ihtiyaç vardır. Çalışmamın sonunda, yazıcı sarf malzemeler satışlarının tanımı ve tahmini için Sinir Ağları modellerin olan MLP-5-5-1, Box–Jenkins yönteminin olan SARIMA(0,1,0)(0,0,1) modeline göre daha uygun olduğu saptanmıştır. Yapay sinir ağları yöntemi ile serinin durağan hale getirilmesi için dönüştürme fonksiyonlarına başvurmaya gerek kalmadan değişkenler arası doğrusal olmayan problemlerin ortadan kaldırılması mümkündür. Elde edilmiş olan modelin, planlama ve uygulama birimlerince serinin trendlerini öğrenmek ve olayın analizi ile etüdünü yapmak amacıyla kullanılması mümkündür. Box–Jenkins Yöntemi ile Sinir Ağları Yöntemini karşılaştırıldığında istatistik tahmin ölçütlerinin farklı olduğu görülmektedir. Sonuçlardan görüleceği üzere yapay sinir ağları istatistiksel hesaplamaların bütün değişkenleri ile hazır olan verilerini dikkate alan bir yöntemdir.

İleriye yönelik, yazıcı sarf malzemelerin şirketi üretim, pazarlama, işletme yönetimi gibi konulara daha fazla önem vermesi ve geliştirmesinin yanı sıra satış miktarlarının

artırılması için de pazarlama ve satış konularında yeni yöntemleri geliştirmesi gerekmektedir. Gelecekte, yapılacak çalışmalar için; farklı mimarilere sahip yapay sinir ağı modelleri kullanılarak, tahmin çalışmaları önerilebilir. Öngörü metotları arasında en uygun olanını belirlemek amacıyla yeni tahmin ve öngörü testlerinin yapılması, bu amaçla Box–Jenkins yöntemi ile sinir ağı yöntemi karışımı homojen metotların kullanmak önemlidir.

Tahmin için kullanılan bu modeldeki çalışma; "Garg et al. (2016), Safi (2016), Ighravwe ve Anyaeche (2019), Pandey (2019)", çalışmasıyla benzerlik gösterirken, "Gao et al. (2017), Nury et al. (2017)" çalışmasıyla farklılaşmaktadır. Çalışmada en uygun model, Box–Jenkins yöntemi olduğu görülmektedir. Bunun nedeni, Box–Jenkins modelinin doğrusal veriye sahip olan modellerde kullanılmasıdır. Doğrusal olmayan verilerde ise doğru sonuç her zaman alınamamaktadır.

Çalışma sonuçlarından da görüleceği üzere, tüm durumlar için uygun özel bir tahmin yöntemi yoktur. Verinin durumuna bakılarak en uygun modelin seçilmesi ve sonucunda da gerekli kontrollerin yapılması önemlidir. Bazı durumlarda birden fazla yöntemin birlikte kullanılması doğruluk oranını arttırabilmektedir.

KAYNAKLAR

- Azoff, E.M., 1994. Neural Network Time Series Forecasting of Financial Markets. John Wiley & Sons, Inc.
- Ameen, B.H., 2005. Musul Şehrinde Elektrik Tüketimini Uygulayarak Zaman Serilerinin Tahmininde Sinir Ağlarının Kullanılması, Yüksek Lisans Tezi, Musul Üniversitesi, Irak.
- Akdağ, M., 2015. Box Jenkins Ve Yapay Sinir Ağı Modelleri İle Enflasyon Tahmini: Atatürk Üniversitesi, Fen Bilimleri Enstitüsü, Endüstri Mühendisliği Anabilim Dalı, Yüksek Lisans Tezi, Erzurum.
- Abraham, B.A., 1983. Statistical Methods for Forecasting. New York: John Wiley and Sons Inc.
- Allend, H.M., 1999. Artificial Neural Network in Time Series Forecasting. Germany: A comparative Analysis German Academic Exchange Service (DAAD).
- Anderson T.W., 1971. The Statistical Analysis of Time Series, John Wiley and Sons, Inc, NewYork.
- Anderson, R.I., 1942. Distribution of the Series Analysis Correlation Coefficient, ANN Mat .Statistic vol .13.
- Anderson, O.D., 1976. Time Series Analysis and Forecasting the Box-Jenkins Approach , F.I.S., Butter Worths (Publishers) Ltd.
- Ampazis, N., 1998. "Introduction to Neural Networks", www.iitnrcps.ariadneet.gr/nearal/index.
- Alobaidi, M., 2000. "Artificial Neural Networks", Journal of Computer Research, Volume 4, Issue 1, Baghdad, Iraq.
- Alotaibi, F., 2003. "The Use of Time Series and Neural Networks in Prediction of Indexes", Master Thesis in Applied Statistics, Suez Canal University, Egypt.
- Allam, I., 2000. Sinir Ağları, Geometrik Yapı - Algoritmalar – Uygulamalar, Halep, Suriye.
- Aljubouri, W.D.S., 2010. İkili Değişkenli Zaman Serisi Kullanarak Irak'taki aylık Tüketici Fiyatlarındaki Enflasyon Seviyesini Tahmin Etmek.
- Beck, A.H., 2005. Musul Şehrinde Elektrik Tüketimini Uygulayarak Zaman Serilerinin Tahmininde Sinir Ağlarının Kullanılması, Yüksek Lisans Tezi, Musul Üniversitesi, Irak.
- Bluestone, H., 1963. "The Cycles in Broilers." Poultry and Egg Situation, USDA ERS PES-226 (1963): 13-18.

- Brockwell, P.J., and Davis, R.A., 1991. Time Series: Theory and Methods, 2nd Edition, Springer-Verlag, New York.
- Box, G.E.P., and Cox, D.R., 1964. An Analysis of Transformations (With Discussion), J. R. Stat. Soc. B 26, 211–252.
- Brockwell, P.J., 1994. On Continuous Time Threshold ARMA Processes, J. Statistical Planning and Inference 39, 291–304.
- Baranrd, G.A., Jenkins, G.M., and Winsten, C.B., 1982. Likelihood inference and Time Series, Jour Royal Stat, Soc, A125, 32, 1.
- Box, G., and Pierce, D., 1970. Distribution of Autocorrelation in Autoregressive Moving Average Time Series Models , Journal of the American Statistical Association, 65 .
- Bartlett, M., 1946. On the Theoretical Specification of Sampling Properties of Auto Correlated Time Series , Journal of the Royal Statistical Society, Series B8, 27-41.
- Box, G., and Jenkins, G., 1976. Time Series Analysis forecasting and Control Sanfrancisco Helden -day.
- Bakri, N., 2000. Cezai İstatistiklerin Kökenleri, Naif Arab University for Security Sciences.
- Commaeaeur, J.J.F., and Koopman, S.J., 2007. Introduction to State Space Time Series Analysis.
- Christopher, M.F., 2000. "Neural Networks: Literature Review From a Statistical Perspective", SCU, Hayward, Statistics Department.
- Ciaburro, G., and Venkateswaran, B., 2017. "Neural Networks with R: Smart Models Using CNN, RNN, Deep Learning, and Artificial Intelligence Principles", Birmingham, UK : Packt Publishing.
- Cancela, A., 2008. "Comparative Study of Artificial Neural Network and Box Jenkins Arima for Stock Price Indexes", ISCTE Business School, Masterin Data Analysis Prospecting.
- Çuhadar, M., 2006. "Turizm Sektöründe Talep Tahmini için Yapay Sinir Ağları Kullanımı ve Diğer Yöntemlerle Karşılaştırmalı Analizi", Süleyman Demirel Üniversitesi Sosyal Bilimler Enstitüsü.
- Çetin, E., 2003. Yapay Sinir Ağları:(Kuram, Mimari, Eğitim, Uygulama). Seçkin Yayıncılık.
- Dobre, I., and Adriana, A.A., 2008. "Modelling Unemployment Rate Using Box-Jenkins Procedure".

- Dickey, D., and Fuller, W., 1981. "Likelihood Ratio Statistical for Autoregressive Time Series with a Unit Root", *Econometrical*, vol 49 .
- Dickey, D., and Fuller, W., 1979. "Distribution of Estimators for Autoregressive Time Series with a Unit Root", *Journal of the American Statistical Association*, 74, (431-427) , USA .
- Douglas, C.M., and Contreras, J.G., 1976. "Note on Forecasting with Adaptive Filtering", *O.P.Q*, vol .24 No 4.
- Douglas, N., 1981. "Bayesian Confidence Intervals for Smoothing Splines" *JASA* - DECEMBER, V 83 .404.
- Ergezer, H., Dikmen, M., and Özdemir, E., 2003. "Yapay Sinir Ağları ve Tanıma Sistemleri." *PiVOLKA* 2.6: 14-17.
- Foster, W.R., Collopy, F., and Ungar, L.H. 1992. "Neural Network Forecasting of Short, Noisy Time Series." *Computers & Chemicalengineering* 16.4 (1992): 293-297.
- Field, A.S., 2003. *Discovering Statistics Using SPSS for Windows*.
- Fkiring, M., and Al -Turki, I., 1991. *Forecasting Agricultural Economic System, Cybernetics and System: An International Journal*, 22: 17 -24.
- Fahmi, D., 1994. *Hesaplama ve Yapay Zeka, Mısır Modern Matbaaları, Mısır Arap Cumhuriyeti*.
- Gerra, M.J., 1959. *The Demand, Supply, and Price Structure for Eggs*. US Dept. of Agriculture,.
- Girard, A., Rasmussen, C.E., and Murray S.R., 2002. *Gaussian Process Priors with Uncertain Inputs: Multiple -Step Ahead Prediction*, Technical Report, TR-2002-119, Dept. of Computing Science, University of Glasgow.
- Gao, G., Lo, K., and Fan, F.L., 2017. "Comparison of ARIMA and ANN Models Used in Electricity Price Forecasting for Power Market". *Energy and Power Engineering*, University of Strathclyde, Glasgow, UK, No. 9. pp. 120-126.
- Garg, N., Sharma, M.K., Parmar, K.S., Soni, K., Singh, R.K., and Maji, S., 2016. "Comparison of ARIMA and ANN Approaches in Time-Series Predictions of Traffic Noise", *Noise Control Engineering Journal*, Vol. 64, No. 4, pp:522-531.
- Gadoue, S., Giaouris, D., and Finch, J., 2005. "Tuning of PI Speed Controller in DTC of Induction Motor Based on Genetic Algorithms and Fuzzy Logic Schemes. In D. Manolakis & A. Gogoussis (Eds)", *5th International Conference on Technology and Automation*, pp (90-85) .

- Hagan, M.T., Howard, B.D., and Mark, H.B., 1996. Neural Network Design. Vol. 20. Boston: PwsPub.
- Hamzaçebi, C., and Fevzi, K., 2004. "Yapay Sinir Ağları ile Türkiye Elektrik Enerjisi Tüketiminin 2010 Yılına Kadar Tahmini." Gazi Üniversitesi Mühendislik-Mimarlık Fakültesi Dergisi 19.3.
- Hamzaçebi, C., Akay, D., and Kutay, F., 2009. Comparison of Direct and Iterative Artificial Neural Network Forecast Approaches in Multi-Periodic Time Series Forecasting. Expert Systems with Applications, 36(2), 3839-3844.
- Hamilton, J., 1994. "Time Series Analysis." Princeton University Press.
- Haykin, S., 1999. "Neural Networks Acomprehensive Foundation" Second Edition.
- Haykin, S., 1994. "Neural Networks Acomprehensive Foundation." Macmillan College Publishing Company, USA.
- Hill, C., Griffiths, W. and Judge, G., 2011. "Using EvIEWS for Undergraduate Econometrics / R." 2nd, New York : Wiley.
- Ighravwe, D., Anyaeche, C., 2019. "Acomparison of ARIMA and ANN Techniques In Predicting Port Productivity and Berth Effectiveness.", International Journal of Data and Network Science, Vol. 3, pp. 13-22.
- İssa, A., 2000. Sinir Ağları, Geometrik yapı - Algoritmalar – Uygulamalar, Halep, Suriye.
- Karaboga, D., and Bahriye, A., 2007. "Artificial Bee Colony (ABC) Algorithm on Training Artificial Neural Networks." Signal Processing and Communications Applications, 2007. SIU 2007. IEEE 15th. IEEE.
- Kwiatkowski, D.P.C.B., Phillips, P.S. and Shin, Y., 1992. Testing the Null Hypothesis of Stationarity against the Alternative of a Unit Root , Journal of Econometrics, 54, pp. 159-178, North-Holland.
- Kosko, B., 1992. "Neural Networks and Fuzzy Systems: A Dynamical System Approach to Machine Intelligence Book and Disk", Vol. 1 Prentice hall.
- Krose, B., and Smagt, V.D.P., 1996 . "An Introduction to neural networks", Eighth Edition. The university of Amsterdam, pp 33-34.
- Kisi, O., 2005. "Daily River Flow Forecasting Using Artificial Neural Networks and Auto -Regressive Models", Turkish J. Eng .Env . Sci ., 9-20, turkey.
- Kumar, D., Negesh, K., and Sathish, T., 2004. "River Flow Forecasting Using Recurrent Neural Networks", Water Resources Management, vol 18.

- Kabundi, A., 2002. "Macroeconomic Forecasting: A Comparison Between Artificial Neural Networks and Econometric Models." MA, Thesis, Rand Afrikan University.
- Kermanshahi, B., and Iwamiya, H., 2002. "Up to year 2020 Load Forecasting Using Neural Nets", International Journal Electrical Power and Energy System 24(9), pp:789-797.
- Karaman, A., 2004. "An Experimental Study on Forecasting Using Test Processes", Industrial and Systems Engineering Rutgers, University Piscataway, NJ08854, U.S.A .
- Kaiser, R., and Maravall, A., 2001. "Notes on Time Series Analysis ARIMA Models and Signal Extraction", Benco de Espona servicio Estudios.
- Leuthold, R.M., et al., 1970. "Forecasting Daily Hog Prices and Quantities: A study of Alternative Forecasting Techniques." Journal of The American Statistical Association 65.329 : 90-107.
- Lee, K.Y., Cha, Y.T., and Park, J.H., 2003. "Short Term Load Forecasting Using an Artificial Neural Network." IEEE Transactions on Power Systems 7.1 (1992): 124-132. Öztemel, Ercan. Yapay Sinir Ağları. PapatyaYayincilik, Istanbul.
- Lendasse, A., Bodt, E., Wertz, V., And Vwrleysen, M., 2000. Non-Linear Financial Time Series Forecasting Application to The Bel 20 Stock Market Index , European Journal of Economic and Social System, vol14 .
- Ljung, G., 1985. "Diagnostic Testing of Univariate Time Series Model Identification." Biometrika, vol . (72), No (2) .
- Landt, F., 1975. Stock Price Prediction Using Neural Network, Master leiden University.
- Makridakis, S., and Michele, H., 1997. "ARMA Models and the Box–Jenkins Methodology." Journal of Forecasting 16.3 : 147-163.
- Montanes, E., Quevedo, J.R., Prieto, M.M., and Menéndez, C.O., 2002. Forecasting Time Series Combining Machine Learning and Box-Jenkins Time Series Advances in Artificial Intelligence—Iberamia 2002 (pp. 491-499): Springer.
- Meyler, A., Kenny, G., and Quinn, T., 1998. Forecasting Irish Inflation Using ARIMA Models , Central Bank of Ireland Technical Paper.
- Mitchell, T.M., 1997. "Machine learning Boston." WCB/ Mcgraw-hill, New York.
- Moseley, N., 2003. Modeling Economic Time Series A focused Time Lagged Feed Forwarded Neural Network ", Proceeding of Student Research Day, CSIS, Pace University .

- Nury, A., Hasan, K., and Alam, J., 2017. "Comparative Study of Wavelet-ARIMA and Wavelet-ANN Models For Temperature Time Series Data in Northeastern Bangladesh", *Journal of King Saud University – Science*, Vol. 29, pp. 47–61.
- Nahmias, S., and Ye, C., 2009. *Production and Operations Analysis*. Vol. 6. New York: McGraw-Hill.
- Priestley, M.B., 1981. *Spectral Analysis and Time Series*, Academic Press, New York.
- Perron, P., and Phillips, P.C.B., 1987. "Does GNP Have a Unit Root?: A Reevaluation." *Economics Letters*, Elsevier, vol .23 (2) , pages 139-145.
- Powell, J.L., 1997. "Time Series Analysis: Forecasting Product Demand and Rervenue Econometrics Laboratory and Center for Regulatory Policy University of Californial at Berkeley January 7-9, 1998" *Econometrices Laboratory .U.C.Berkeley*.
- Pandey, V., 2019. "Predictive Efficiency of ARIMA and ANN Models: A Case Analysis of Nifty Fifty in Indian Stock Market", *International Journal of Applied Engineering Research*, Vol. 14, No 2, pp. 232-244.
- Rowley, H.A., Shumeet, B., and Takeo, K., 1998. "Neural Network-Based Face Detection." *IEEE Transactions on Pattern Analysis and Machine Intelligence* 20.1 : 23-38.
- Purohit, S., Kelkar, S., and Asimha, V., 1998. "Time Series Analysis of Patients With Rotavirus Diarrhoea in Pune, India", *J .Diarrhoeal Disease Research Bangladesh* Jun: 16 (2) : 74-83.
- Suits, D.B., 1962. "Forecasting and Analysis with an Econometric Model." *The American Economic Review* 52.1.
- Sağıroğlu, Ş., Erkan, B., and Erler, M., 2003. *Mühendislikte Yapay Zeka Uygulamaları-1: Yapay sinir ağları*. Ufuk Kitap Kirtasiye-Yayıncılık.
- Schmitz, A., and Donald, G.W., 1970. "Forecasting Wheat Yields: An application of Parametric Time Series Modeling." *American Journal of Agricultural Economics* 52.2 : 247-254.
- Specht, D.F., 1991. "A General Regression Neural Network." *IEEE Transactions on Neural Networks* 2.6 : 568-576.
- Spyros, M., Steven, C.W and Victor, E.M., 1983. "Forecasting Methods and Application", Second Edition, John Wiley and Sons.
- Sinha, H., 2002. *Designing a Neural Network for Forecasting Financial and Economic Time Series* , June 4th, Indie.

- Sherkaoui, M., 1996. Yapay Zeka ve Sinir Ağları, Egyptian Modern Printing Press, Cairo, Egypt.
- Sharawei, S., 2005. Zaman Serilerinin Modern Analizine Giriş, Kral Abdulaziz Üniversitesi, Baskı 1.
- Stergiou, C., and Siganos, D., 1996. "Introduction to Neural Networks", Download on 31 March 2004 from World Wide web: http://www.doc.ic.ac.uk/~nd/surprise_96/journal/vol14/cs11/report.htm.
- Safi, S., 2016. "A Comparison of Artificial Neural Network and Time Series Models for Forecasting GDP in Palestine." American Journal of Theoretical and Applied Statistics, Vol. 5, No. 2, pp. 58-63.
- Tobin, B.F., and Arthur, H.B., 1964. "Dynamics of Adjustment in The Broiler Industry, " Dynamics of Adjustment in The Broiler Industry.
- Tang, Z., Chrys A., and Paul A.F., 1991. "Time Series Forecasting Using Neural Networks vs. Box-Jenkins Methodology." Simulation 57.5 : 303-310.
- Ture, M., and Kurt, I., 2006. Comparison of Four Different Time Series Methods To Forecast Hepatitis A Virus Infection. Expert Systems with Applications, 31(1), 41-46.
- Voind, H.D., 1999. Time Series Analysis, Economic Fordham University, Bronx, New York, USA.
- Vandaele, W., 1990. Applied Time Series and Box-Jenkins Models, Academic Press.
- Vandall, W., 2004. Box-Jenkins Modeli ve Uygulama Açısından Zaman Serisi , Dar Al-Marikh Yayın Evi, Riyad, Suudi Arabistan.
- Xuan, T., 2004. Autoregressive Hidden Markor Model with Application in ELNINO Study, Department of Mathematics and Statistics, University of Saskatchewan, Saskatoon.
- Zhang, G.P., and Min, Q.İ., 2005. "Neural Network Forecasting for Seasonal and Trend Time Series." European Journal of Operational Research 160.2 : 501-514.
- Zhang, G.P., 2003. "Time Series Forecasting Using a Hybrid ARIMA and Neural Network Model." Neurocomputing 50 (): 159-175.
- Zurada, J.M., 1992. " Introduction to Artificial Neural Systems ", West Publishing Company, 1992.

ÖZGEÇMİŞ

Adı Soyadı : Ban Al Mahmud
uyruk : İrak Cumhuriyeti
Doğum Yeri ve Yılı : 8/11/1973 / Bağdat
Medeni Hali : Bekar
Yabancı Dili : İngilizce, Türkçe
E-posta : banbbbb@gmail.com

Eğitim Durumu

Lisans : Bağdad Üniversitesi Eğitim ve Soyut Bilimler Fakültesi/ İbn Alheysem Bilgisayar Bilimleri, (2002-2006)