



**YAPAY SİNİR AĞLARI İLE OTOMOTİV
SEKTÖRÜNDE NORM KADRO HESAPLAMASI**

Çilem Sinem ŞENDOĞAN

Danışman: Prof. Dr. Mustafa YILMAZ

Yüksek Lisans Tezi

Endüstri Mühendisliği Ana Bilim Dalı

2025

(Her hakkı saklıdır.)

T.C.
ATATÜRK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
ENDÜSTRİ MÜHENDİSLİĞİ ANA BİLİM DALI

**YAPAY SİNİR AĞLARI İLE OTOMOTİV SEKTÖRÜNDE NORM KADRO
HESAPLAMASI**

(Personnel Planning in Automotive Industry with Artificial Neural Networks)

YÜKSEK LİSANS TEZİ

Çilem Sinem ŞENDOĞAN

Danışman: Prof. Dr. Mustafa YILMAZ

Erzurum
Eylül, 2025



FEN BİLİMLERİ ENSTİTÜSÜ

Graduate School of Natural and
Applied Sciences

T.C.
ATATÜRK ÜNİVERSİTESİ
Fen Bilimleri Enstitüsü Müdürlüğü
TEZ KABUL VE ONAY TUTANAĞI

**YAPAY SİNİR AĞLARI İLE OTOMOTİV SEKTÖRÜNDE NORM KADRO
HESAPLAMASI**

Doç. Dr. Mustafa Yılmaz danışmanlığında, Çilem Sinem Şendoğan tarafından hazırlanan bu çalışma, 10/09/2025 tarihinde aşağıdaki jüri tarafından Endüstri Mühendisliği Anabilim Dalı Endüstri Mühendisliği Bilim Dalı'nda yüksek lisans tezi olarak **oybirliği (3/3)** ile kabul edilmiştir.

Jüri Başkanı: Dr. Öğr. Üyesi Erdem Aksakal
Atatürk Üniversitesi

Aslı Islak İmzalıdır

Danışman: Prof. Dr. Mustafa Yılmaz
Atatürk Üniversitesi

Aslı Islak İmzalıdır

Jüri Üyesi: Dr. Öğr. Üyesi Ferhat Yuna
Erzurum Teknik Üniversitesi

Aslı Islak İmzalıdır

Enstitü Yönetim
Kurulunun .../.../.... tarih
ve sayılı kararı.

Bu tezin Atatürk Üniversitesi Lisansüstü Eğitim ve Öğretim Yönetmeliği'nin ilgili maddelerinde belirtilen şartları yerine getirdiğini onaylarım.

Prof.Dr. Alper NUHOĞLU

Enstitü Müdürü

Aslı Islak İmzalıdır

**FEN BİLİMLERİ ENSTİTÜSÜ**

Graduate School of Natural and
Applied Sciences

T.C.
ATATÜRK ÜNİVERSİTESİ REKTÖRLÜĞÜ
FEN BİLİMLERİ ENSTİTÜSÜ MÜDÜRLÜĞÜ

ETİK BİLDİRİM VE İNTİHAL BEYAN FORMU

Yüksek Lisans Tezi olarak Prof. Dr. Mustafa Yılmaz danışmanlığında sunulan “Yapay Sinir Ağları İle Otomotiv Sektöründe Norm Kadro Hesaplaması” başlıklı çalışmanın tarafımızdan bilimsel etik ilkelere uyularak yazıldığını, yararlanılan eserlerin kaynakçada gösterildiğini, Fen Bilimleri Enstitüsü tarafından belirlenmiş olan Turnitin Programı benzerlik oranlarının aşılmadığını ve aşağıdaki oranlarda olduğunu beyan ederiz.

Tez Bölümleri	Tezin Benzerlik Oranı (%)	Maksimum Oran (%)
Giriş	0	30
Kuramsal Temeller	9	30
Materyal ve Metot	20	35
Araştırma Bulguları ve Tartışma	10	20
Sonuçlar ve Öneriler	6	20
Tezin Geneli	13	25

Not: Yedi kelimeye kadar benzerlikler ile Başlık, Kaynakça, İçindekiler, Teşekkür, Dizin ve Ekler kısımları tarama dışı bırakılabilir. Yukarıdaki azami benzerlik oranları yanında tek bir kaynaktan olan benzerlik oranlarının %5'den büyük olmaması gerekir.

Sunulan bilgilerin doğru olduğunu, aksi halde doğacak hukuki sorumlulukları kabul ettiğimizi beyan ederiz.

Tez Yazarı (Öğrenci)	Tez Danışmanı
Çilem Sinem Şendoğan	Prof. Dr. Mustafa Yılmaz
10.9.2025	10.9.2025
İmza: Aslı Islak İmzalıdır	İmza: Aslı Islak İmzalıdır

* Tez ile ilgili YÖKTEZ’de yayınlamasına ilişkin bir engelleme var ise aşağıdaki alanı doldurunuz.

☐ Tezle ilgili patent başvurusu yapılması / patent alma sürecinin devam etmesi sebebiyle Enstitü Yönetim Kurulunun/....../.... tarih ve sayılı kararı ile teze erişim 2 (iki) yıl süreyle engellenmiştir.

☐ Enstitü Yönetim Kurulunun/....../.... tarih ve sayılı kararı ile teze erişim 6 (altı) ay süreyle engellenmiştir.

TEŞEKKÜR

Bu tez çalışması, lisansüstü eğitim sürecim boyunca edindiğim akademik birikimin önemli bir ürünü olup, bilimsel düşünce sistematığı çerçevesinde titizlikle hazırlanmıştır.

Çalışmanın planlanmasından sonuçlandırılmasına kadar geçen süreçte değerli bilgileri, yönlendirmeleri ve akademik rehberliğiyle katkı sunan kıymetli danışmanım Mustafa Yılmaz’a teşekkürü bir borç bilirim.

Eğitim hayatım boyunca her zaman desteklerini esirgemeyen, özveri ve sabırlarıyla beni bugünlere getiren sevgili aileme, en derin minnet duygularıyla teşekkür ederim.

Ayrıca, vizyon kazandırıcı yaklaşımı ve yönlendirici fikirleriyle düşünsel gelişimime katkı sunan Sayın Erol Tuna’ya en derin şükranlarımı sunarım.

Bu çalışmanın, ilgili literatüre katkı sağlamasını ve araştırmacılar için faydalı bir kaynak oluşturmasını temenni ederim.

Çilem Sinem ŞENDOĞAN

ÖZET

YÜKSEK LİSANS TEZİ YAPAY SİNİR AĞLARI İLE OTOMOTİV SEKTÖRÜNDE NORM KADRO HESAPLAMASI

Çilem Sinem ŞENDOĞAN

Danışman: Prof. Dr. Mustafa YILMAZ

Amaç: Küresel rekabetin giderek arttığı günümüzde, işletmelerin sürdürülebilirliğini sağlaması ve stratejik hedeflerine ulaşabilmesi için insan kaynaklarının etkin bir şekilde planlanması kritik bir öneme sahiptir. Bu kapsamda, norm kadro belirleme süreci, iş gücünün verimli kullanımı ve maliyet kontrolü açısından önemli bir araç olarak öne çıkmaktadır. Otomotiv sektörü gibi iş gücüne dayalı alanlarda doğru personel planlaması, üretim sürecinin kesintisiz devamlılığını sağlamakla birlikte, işletme performansını doğrudan etkilemektedir.

Yöntem: Bu çalışmada, otomotiv sektöründe norm kadro hesaplamaları için yapay zekâ tabanlı bir yaklaşım önerilmiştir. Araştırmada hem geleneksel zaman serileri analizi (ARIMA) hem de yapay sinir ağları (YSA) yöntemleri kullanılmış, bu iki yöntemin güçlü yönleri birleştirilerek bir tahmin modeli geliştirilmiştir. Model, geçmiş dönem verilerini kullanarak 12 dönemlik ileriye dönük norm kadro tahminleri üretmiş ve ARIMA ile YSA tahmin sonuçları karşılaştırılmıştır.

Bulgular: Uygulama sonuçları, geliştirilen modelin tahmin doğruluğu açısından yüksek performans sergilediğini göstermiştir. Elde edilen sonuçlara göre, yapay zekâ destekli modelin insan kaynakları planlamasında kullanılabilirliği artmış, norm kadro tahminlerinde geleneksel yöntemlere kıyasla daha tutarlı ve güvenilir sonuçlar elde edilmiştir.

Sonuç: Sonuç olarak, önerilen modelin insan kaynakları planlamasında norm kadro tahminlerinin daha doğru yapılmasına olanak sağladığı görülmüştür. Bu yaklaşımın, farklı sektörlerdeki personel planlaması süreçlerine de uyarlanabilir bir yöntem sunduğu değerlendirilmektedir.

Anahtar Kelimeler: Norm Kadro, Yapay Sinir Ağları, Zaman Serileri, Otomotiv Sektörü, Tahmin Modeli

Eylül 2025, 111 sayfa

ABSTRACT

MASTER'S THESIS

PERSONNEL PLANNING IN AUTOMOTIVE INDUSTRY WITH ARTIFICIAL NEURAL NETWORKS

Çilem Sinem ŞENDOĞAN

Supervisor: Prof. Dr. Mustafa YILMAZ

Purpose: In today's increasingly competitive global environment, effective human resource planning is critically important for organizations to ensure sustainability and achieve their strategic goals. In this context, determining optimal staffing levels (norm staffing) plays a vital role in utilizing human resources efficiently and controlling labor costs. In labor-intensive industries such as the automotive sector, accurate personnel planning not only ensures the continuity of production processes but also has a direct impact on overall organizational performance.

Method: This study proposes an artificial intelligence-based approach for workforce norm estimation in the automotive industry. Both traditional time series analysis methods (ARIMA) and Artificial Neural Networks (ANNs) were employed, and a forecasting model was developed by integrating the strengths of both methods. Using historical data, the model generated 12-period forward-looking forecasts for workforce requirements. The predictions obtained from the developed model were compared with those of standalone ARIMA and ANN models.

Findings: The results demonstrated that the proposed model achieved higher forecasting accuracy compared to individual ARIMA and ANN models. The analysis revealed that the artificial intelligence-supported approach provides reliable estimations and contributes significantly to effective human resource planning by improving the precision of norm staffing forecasts.

Results: In conclusion, the proposed model enables more precise and reliable workforce requirement estimations in the context of human resource planning. Furthermore, this approach presents a flexible and scalable framework that can be adapted to workforce planning practices in other sectors as well.

Keywords: Norm Staffing, Artificial Neural Networks, Time Series, Automotive Industry, Forecasting Model

September 2025, 111 pages

İÇİNDEKİLER

KABUL VE ONAY TUTANAĞI.....	i
ETİK BİLDİRİM VE İNTİHAL BEYAN FORMU	ii
TEŞEKKÜR	iii
ÖZET	iv
ABSTRACT	v
İÇİNDEKİLER.....	vi
TABLolar DİZİNİ.....	viii
ŞEKİLLER DİZİNİ	ix
KISALTMALAR DİZİNİ	x
GİRİŞ.....	1
KURAMSAL TEMELLER.....	4
İnsan Kaynakları Planlaması.....	4
İnsan Kaynakları Planlama Süreci	4
İnsan Kaynakları Planlamasında Kullanılan Yöntemler	5
Norm Kadro	7
Norm kadronun amacı.....	7
Norm kadronun önemi	8
Norm kadro tespit süreci	11
Norm kadro tespiti nasıl yapılır?	13
Tahmin Yöntemleri ve Zaman Serileri Analizi.....	14
Yapay Sinir Ağları (YSA).....	14
Literatür.....	14
MATERYAL VE METOT	43
Zaman Serileri.....	43
Zaman Serileri Yapısı	43
Durağanlığın analizine yönelik olarak birim kök testi	44
Doğrusal zaman serisi modelleri	46
Eşbütünleşme Analizi.....	50
Engle – Granger yaklaşımı.....	50
Yapay Sinir Ağları	52
Biyolojik nöron	52

Yapay sinir ağlarının gelişim evreleri	53
Yapay sinir ağlarının güçlü ve zayıf yönleri	56
Yapay sinir ağı elemanları	59
Yapay sinir ağlarında öğrenme	61
Yapay sinir ağlarında öğrenme stratejileri	63
ARAŞTIRMA BULGULARI VE TARTIŞMA.....	43
SONUÇLAR VE ÖNERİLER	96
Sonuç.....	96
Öneriler	97
KAYNAKLAR.....	99
ÖZGEÇMİŞ.....	102



TABLÖLAR DİZİNİ

Tablo 1. Durağan Zaman Verilerinde ACF ve PACF'nin Teorik Davranışları.....	48
Tablo 2. Biyolojik Sinir Sistemi Elemanlar ve Yapay Sinir Sistemindeki Karşılıkları.....	60
Tablo 3. Öğrenme Algoritmaları ve Kullanım Alanları Tablosu.....	64
Tablo 4. Geçmiş Dönem Verileri.....	43
Tablo 5. Tamamlayıcı İstatistikler	47
Tablo 6. Birim Kök Testi Sonuçları.....	75
Tablo 7. Ek İş Yüğü ARIMA (1,0,1) Model Tespit Sonuçları	81
Tablo 8. Ek İş Yüğü Kalıntı Kolegramı.....	83
Tablo 9. Kurumsal Kapasite ARIMA (0,2,1) Model Tespit Sonuçları.....	85
Tablo 10. Kurumsal Kapasite Kalıntı Kolegramı	87
Tablo 11. Değişkenlere Ait ARIMA Modelleri.....	87
Tablo 12. ARIMA Modellerine Göre Oluşturulan 2023m10 / 2025m10 Dönemlerine Ait Zaman Serisi Analizi Tahmin Sonuçları.....	88
Tablo 13. Matlab 2019 Programı İle Tahmin Edilen Norm Kadro Sonuçları	93

ŞEKİLLER DİZİNİ

Şekil 1. Biyolojik nöronun genel yapısı	53
Şekil 2. YSA ve geleneksel tahmin yöntemlerinin karşılaştırılması	56
Şekil 3. Yapay sinir hücresinin elemanları	60
Şekil 4. Verilere ait çoklu grafik çizimleri	46
Şekil 5. Toplam iş yüküne ait kologram değerleri	49
Şekil 6. Ek iş yüküne ait kologram değerleri	50
Şekil 7. Kurumsal kapasiteye ait kologram değerleri.....	52
Şekil 8. Performans değerine ait kologram değerleri.....	53
Şekil 9. Planlama kapasitesine ait kologram değerleri.....	54
Şekil 10. Norm kadroya ait kologram değerleri.....	55
Şekil 11. Ek iş yükünün ADF yöntemine göre birim kök test sonuçları.....	56
Şekil 12. Kurumsal kapasitenin ADF yöntemine göre birim kök test sonuçları.....	58
Şekil 13. Norm kadronun ADF yöntemine göre birim kök test sonuçları	60
Şekil 14. Performans değerinin ADF yöntemine göre birim kök test sonuçları	61
Şekil 15. Planlama kapasitesinin ADF yöntemine göre birim kök test sonuçları	62
Şekil 16. Toplam iş yükünün ADF yöntemine göre birim kök test sonuçları.....	63
Şekil 17. Ek iş yükünün Phillips Peron yöntemine göre birim kök test sonuçları	64
Şekil 18. Kurumsal kapasitenin Phillips Peron yöntemine göre birim kök test sonuçları	66
Şekil 19. Norm kadronun Phillips Peron yöntemine göre birim kök test sonuçları.....	68
Şekil 20. Performans değerinin Phillips Peron yöntemine göre birim kök test sonuçları.....	70
Şekil 21. Planlama kapasitesinin Phillips Peron yöntemine göre birim kök test sonuçları.....	72
Şekil 22. Toplam iş yükü kapasitesinin Phillips Peron yöntemine göre birim kök test sonuçları	74
Şekil 23. Engle-Granger eşbütünleşme analizi.....	77
Şekil 24. Ek iş yükü Augmented Dickey – Fuller birim kök testi.....	79
Şekil 25. Kurumsal kapasite Augmented Dickey – Fuller birim kök testi.....	84
Şekil 26. Gerçek ve tahmin edilen değerlerin karşılaştırması	93
Şekil 27. Yapay sinir ağı ve ARIMA norm kadro tahmin kıyaslaması.....	95

KISALTMALAR DİZİNİ

ACF	: Autocorrelation Function (Otokorelasyon Fonksiyonu)
ADF	: Augmented Dickey-Fuller Test (Genişletilmiş Dickey-Fuller Testi)
ANN	: Artificial Neural Network (Yapay Sinir Ağı)
AR	: Autoregressive (Oto regresif)
ARIMA	: Autoregressive Integrated Moving Average (Oto regresif Entegre Hareketli Ortalama)
BPNN	: Backpropagation Neural Network (Geri Yayılım Sinir Ağı)
EKK	: Ordinary Least Squares (En Küçük Kareler Yöntemi)
ETS	: Error, Trend and Seasonality Components Model (Hata, Trend ve Mevsimsellik Bileşeni Modeli)
GRU	: Gated Recurrent Unit (Kapılı Tekrarlayan Birim)
HQIC	: Hannan-Quinn Information Criterion (Hannan-Quinn Bilgi Kriteri)
I(d)	: Integration Order (İntegrasyon Derecesi / Fark Alma Sayısı)
L	: Lag Operator (Gecikme Operatörü)
LSTM	: Long Short-Term Memory (Uzun Kısa Süreli Bellek)
MA	: Moving Average (Hareketli Ortalama)
MLP	: Multilayer Perceptron (Çok Katmanlı Algılayıcı)
NNAR	: Neural Network Autoregressive Model (Yapay Sinir Ağı Oto regresif Modeli)
p	: Number of Autoregressive Terms (Oto regresif Terim Sayısı)
PACF	: Partial Autocorrelation Function (Kısmi Otokorelasyon Fonksiyonu)
p-value	: Significance Value (İstatistiksel Anlamlılık Değeri)
q	: Number of Moving Average Terms (Hareketli Ortalama Terim Sayısı)
R ² (R-squared)	: Coefficient of Determination (Determinasyon Katsayısı)
SARIMA	: Seasonal ARIMA (Mevsimsel ARIMA Modeli)
SVM	: Support Vector Machine (Destek Vektör Makineleri)
YSA	: Artificial Neural Network (Yapay Sinir Ağı)

GİRİŞ

Günümüz koşullarında hızla gelişen ve sürekli ilerlemekte olan dinamikler çerçevesinde, şirketler ve kurumlar, hız, kalite, verimlilik ve müşteri memnuniyetini sağlamak ya da bu unsurları kaybetmemek adına mevcut kaynaklarını en verimli şekilde kullanmayı hedeflemektedir. Özellikle sanayi devrimiyle birlikte başlayan ve uluslararası sınırların giderek belirsizleştiği, dünyanın küresel bir yapı kazandığı günümüzde, bu gerekliliğin önemi her geçen gün daha fazla hissedilmektedir. Hızla değişen ve etkisini her alanda gösteren dönüşüm süreci, artık firmalar ve kurumlar için kaçınılmaz bir zorunluluk halini almıştır. Çünkü bu değişime ayak uydurmak, rekabet ortamında varlığını sürdürmek açısından hayati bir önem taşımaktadır. Şirketler, sınırlı kaynaklarını en verimli biçimde değerlendirmek, akılcı yönetim stratejileri geliştirmek ve en yüksek kaliteyi yakalamak amacıyla çeşitli yöntemler uygulamak durumundadır.

Tarih boyunca üretimin en temel unsuru insan olmuştur. Üretim ya da hizmet alanı ne olursa olsun, her zaman insan emeğine ihtiyaç duyulmuştur. İnsan faktörünün ne denli önemli olduğunun bilincinde olan işletmeler, insan kaynaklarının stratejik değerini kavramış ve bu alandaki verimliliği artırmaya yönelik çalışmalar yürütmüştür. Küreselleşmenin ve yoğun rekabetin getirdiği zorlukları en aza indirerek rakiplerinin önüne geçmek isteyen firmalar, çalışanlarını en iyi şekilde değerlendirme çabası içerisinde. İnsan kaynakları yönetiminin en önemli alanlarından biri olan personel planlamaya ağırlık veren şirketler, bu konuda çeşitli teknikler ve yaklaşımlar geliştirmiştir. Sanayi devrimiyle başlayan ve sürekli devam eden dönüşüm süreci, firmalara sadece mevcut çalışan sayısını değil, gelecekteki iş gücü gereksinimlerini de öngörme zorunluluğu getirmiştir. Geleceği tam anlamıyla kestirmek mümkün olmasa da, bu doğrultuda birçok tahmin yöntemi geliştirilmiştir. Çeşitli şirketler, ilerleyen dönemlerde doğabilecek personel ihtiyaçlarını tahmin edebilmek adına farklı öngörü teknikleri benimseyerek insan kaynaklarını geleceğe hazırlamaktadır. Talep değişimlerinden minimum düzeyde etkilenmek adına, hangi pozisyonda ne zaman ve ne kadar çalışana ihtiyaç duyulacağını belirlemeye çalışmaktadırlar. Bu çerçevede, insan kaynakları yönetimi içinde personel planlaması büyük bir öneme sahiptir. (Yılmaz 2012)

Personel planlaması, işletmelerin belirli iş alanlarında ihtiyaç duyduğu, görev tanımına uygun ve yetkin çalışanların belirlenmesine yardımcı olmaktadır. Kurum ve kuruluşların gerekli kriterleri karşılayabilmesi adına yürüttüğü en önemli çalışmalardan biri de norm kadro

analizleridir. Norm kadro, bir işletmenin toplam iş yükünü, o kuruluşun standart zaman birimlerine bölerek, saat bazında ihtiyaç duyulan personel sayısını hesaplamaya yardımcı olur. İş gücü ihtiyacı, toplam iş yükünün bir çalışanın günlük 8 saatlik mesai süresine bölünmesiyle belirlenerek, o dönem için gerekli çalışan sayısı ortaya çıkarılmış olur. (Yılmaz 2012)

Başka bir ifadeyle, norm kadro, belirli bir işi gerçekleştirmek için gerekli olan optimum iş gücü miktarını ifade etmektedir. Literatürde incelendiğinde, norm kadro hesaplamasına yönelik çeşitli yöntemlerin mevcut olduğu görülmektedir. Bu yöntemler, iş yükü analizi ve iş gücü analizi olarak iki ana kategoriye ayrılmakta olup, içerisinde yöneylem araştırması teknikleri, istatistiksel yöntemler, zaman serileri analizi ve en düşük riskle iş gücü planlamayı hedefleyen metotlar yer almaktadır. Bu yaklaşımların temel amacı, çalışanların verimliliğini en üst düzeye çıkarmaktır. Söz konusu çalışmalar, birey başına düşen iş yükünün belirlenmesi ve iş yükünün adaletli ve insani bir biçimde dağıtılmasını sağlamayı hedeflemektedir. Bu perspektiften bakıldığında, işletmeler ve kurumlar en değerli kaynağı olan insan gücünü en etkin şekilde kullanmayı amaçlamaktadır. Çünkü başarıda ya da başarısızlıkta, diğer tüm faktörler gibi insan unsuru da belirleyici bir rol oynamaktadır. (Yılmaz 2012)

Personel planlamasının değişken yapısı, bu alanda gerçekleştirilen araştırmaların ve çalışmaların giderek artmasına sebep olmaktadır. Hem iş dünyasında hem de akademik çevrelerde bu konuya duyulan ilginin yüksek olması, konunun içerdiği belirsizlikler ve karmaşıklıklardan kaynaklanmaktadır.

Geleceğe yönelik belirsizlikler, öngörüye dayalı planlamaların en zorlu unsurlarından birini oluşturmaktadır. Kamu veya özel sektörde faaliyet gösteren her kuruluş, çeşitli alanlarda tahmin tekniklerinden yararlanmaktadır. Şirketler ve kurumlar, pazarlama, finans, üretim planlaması, insan kaynakları yönetimi, kalite kontrol ve bakım süreçleri gibi birçok departmanda geleceğe dair öngörülerde bulunularak stratejik kararlarını şekillendirmeye çalışmaktadır. Elde edilen tahmin verilerini analiz eden yöneticiler, gelecekte karşılaşılabilecekleri olası senaryolar doğrultusunda yönetim stratejilerini belirlemektedir. (Yılmaz 2012)

Gelecekteki olayları öngörmek amacıyla sıkça başvurulanan yöntemlerden biri zaman serileri analizidir. Bu analiz yöntemi, mevcut gerçek verilere dayanarak ileriye dönük tahminler yapmak için kullanılır. Mevcut veriler, istatistiksel tekniklerle incelendikten ve gerekli kriterleri sağladıktan sonra, geleceğe yönelik tahminlerde bulunmak üzere bir model oluşturulur. Bu model aracılığıyla, ilerleyen dönemlere ilişkin projeksiyonlar yapılması mümkün hale gelmektedir. Zaman serileri analizinin tahmin süreçlerinde kullanılmasının iki temel amacı bulunmaktadır. Bunlardan ilki, serinin stokastik yapısını modelleyerek anlamaktır; ikincisi ise

oluřturulan model aracılıęıyla geleceęe ynelik ngrler yapmaktır. 1975 yılında Box ve Jenkins tarafından geliřtirilen ARIMA modelleri, zaman serileri analizinde en yaygın ve bilinen yntemlerden biridir. Bu modelleri dięer zaman serisi analiz yaklařımlarından ayıran temel zellik, stokastik srelere dayalı bir yapıya sahip olmalarıdır. (Gneř 2010)

Son yıllarda poplerlięi giderek artan bir dięer yntem ise yapay sinir aęlarıdır. Bu teknik, yapay zeka prensiplerine dayanmakta olup, insanın dřnme mekanizmasını makinelerle paylařmasını saęlamaktadır. Yapay sinir aęları, insan beyninin ęrenme, algılama ve karar verme srelerini taklit ederek alıřmaktadır. Bu zellikleri sayesinde, tahmin teknikleri alanında nemli bir ilerleme saęlanmış ve yeni olanaklar ortaya ıkmıřtır. Yapay sinir aęları, sayısal yntemleri kullanarak insan beyninin ngr kabiliyetini taklit eder ve tahmin modellerinde olduka bařarılı sonular vermektedir. Geleneksel tahmin yntemleri ile karřılařtırıldığında, yapay sinir aęları belirli avantajlarıyla ne ıkmaktadır. Bu avantajlar arasında, model oluřturma ařamasında herhangi bir varsayıma gereksinim duymamaları, eksik ya da grltl verileri iřleyebilme kapasiteleri ve byk veri setleriyle alıřarak daha isabetli sonular retebilmeleri yer almaktadır.

Bu tez alıřması kapsamında, zaman serileri analizi ve yapay sinir aęlarını bir araya getiren entegre bir model nerilmiřtir. Her iki tahmin ynteminin gl ynlerinden faydalanılarak, geleceęe ynelik ngrlerin daha doęru ve gvenilir olması amalanmıřtır. Norm kadro belirleme srecinin kritik bir ařamasında etkili bir rol oynayan yeni bir model geliřtirilmiřtir. nerilen modelin uygulanabilirlięi, rnek bir senaryo zerinde test edilmiřtir. Uygulama ařamasında, ncelikle mevcut 60 dnemlik veri, kullanılan yntemlere uygun hale getirilerek tahmin srecine entegre edilmiřtir. Zaman serileri analiziyle norm kadro hesaplamalarına ynelik 12 dnemlik tahminler oluřturulmuř ve elde edilen bu veriler yapay sinir aęlarına dahil edilerek ileriye dnk 12 dnemlik norm kadro tahminleri gerekleřtirilmiřtir.

KURAMSAL TEMELLER

İnsan Kaynakları Planlaması

İnsan kaynağının planlanması, literatüre ilk olarak “personel planlama” olarak girmiştir. İnsanın yalnızca bir maliyet unsuru olarak görülmesi sonucunda insan faktörü planlamada da kısıtlı olarak önem arz etmiş, kapsamlı bir inceleme yapılmamıştır. Ne var ki, insanın organizasyona kattığı değer araştırılmaya başlandıkça, çalışanların yalnızca tek bir özellik üzerinden değerlendirilmesinin yanlış olduğu ve insan kaynağının organizasyonun her alanında ciddi katkılarının bulunduğu anlaşılmıştır. İlerleyen zamanda yapılan çalışmalarla birlikte “personel planlaması” yerine daha kapsamlı bir kullanıma işaret eden “insan kaynakları planlaması” kullanılmaya başlanmıştır. (Çıragöz 2021)

20. yüzyılın son zamanlarında artan küreselleşme, kurumları politikalarını değiştirmeye ve yenilemeye itmiştir. Kurumların yalnızca ulusal değil, uluslararası bir kimlik de kazanması ve dünyanın bir ucundan diğer ucuna yapılan faaliyetler hem çalışanlarda aranan niteliklerin değişmesine hem de uygulanan politikaların uluslararası geçerliliğinin sorgulanmasına neden olmuştur. (Çıragöz 2021)

İnsan kaynakları planlaması, işletmenin hedeflerine ulaşmak için en uygun insan kaynakları stratejilerini belirleme ve uygulama amacını taşır. Bu sayede işletmeler, kaynaklarını etkili bir şekilde kullanarak işletme performansını artırabilir ve rekabet avantajı elde edebilir. (Yılmaz 2012)

İnsan Kaynakları Planlama Süreci

İnsan kaynakları planlama süreci, bir organizasyonun iş gücü ihtiyaçlarının belirlenmesi, gerekli işgücü kaynaklarının sağlanması ve yönetilmesi amacıyla yapılan bir dizi faaliyeti içerir. Bu süreç genellikle aşağıdaki adımları içermektedir:

- İşletme stratejisi ve hedeflerinin belirlenmesi: İnsan kaynakları planlama süreci, işletmenin stratejisi ve hedefleri ile uyumlu olarak yürütülmelidir. İşletmenin kısa, orta ve uzun vadeli hedefleri belirlenir ve işletme stratejisi buna göre oluşturulur.
- İş analizi: İşletmenin işgücü ihtiyacının belirlenmesi için, işlerin doğru bir şekilde analiz edilmesi gerekir. Bu adımda, işlerin görevleri, sorumlulukları ve ihtiyaç duyulan beceri ve nitelikleri belirlenir.

- İşgücü ihtiyacının belirlenmesi: İş analizi sonuçlarına göre, işletmenin hangi pozisyonlarda, hangi sayıda ve hangi niteliklerde işgücüne ihtiyacı olduğu belirlenir.
- Mevcut işgücü envanterinin hazırlanması: İşletmenin mevcut personel envanteri belirlenir ve personelin nitelikleri, becerileri, performansları ve kariyer planları hakkında bilgi toplanır.
- İşgücü talebinin karşılanması: İşletmenin işgücü ihtiyacının, mevcut personel envanteri ve dış kaynaklarla karşılanması planlanır.
- Personel ihtiyaçlarının değerlendirilmesi: İşletmenin mevcut personelinin, yeni pozisyonlara uygunluğu ve gerekli eğitimleri alıp alamayacağı değerlendirilir.
- Personel planlaması stratejisinin belirlenmesi: İşletmenin insan kaynakları planı, belirlenen stratejiye uygun olarak uygulanır. İşe alım, eğitim, kariyer gelişimi, performans değerlendirmesi ve terfi gibi faaliyetlerin planlanması ve uygulanması bu aşamada gerçekleştirilir.
- Planın değerlendirilmesi: İnsan kaynakları planlama sürecinin sonunda, planın etkililiği ölçülür ve değerlendirilir. Değerlendirme sonuçları, gelecekteki planlama süreçlerinde kullanılmak üzere kaydedilir ve planlama süreci tekrarlanır.

İnsan kaynakları planlama süreci, işletmenin işgücü ihtiyacını doğru bir şekilde belirlemesine, işgücü kaynaklarının yönetiminde etkin olmasına ve işletmenin hedeflerine ulaşmasına yardımcı olur. Ayrıca, insan kaynakları planlama süreci, işletmenin personel maliyetlerini kontrol altında tutmasına ve işgücü kaynaklarını daha verimli bir şekilde kullanmasına yardımcı olur. (Yılmaz 2012)

İnsan Kaynakları Planlamasında Kullanılan Yöntemler

İnsan kaynakları planlamasında kullanılan yöntemler kısaca aşağıda değinilmiştir:

Trend Analizi: Trend analizi, geçmiş yılların işgücü verilerini inceleyerek gelecekteki işgücü talebini tahmin etmek için kullanılan bir yöntemdir. Bu yöntem, işletmenin büyüme hızı, işgücü kaynaklarının kalitesi ve rekabet durumu gibi faktörlere dayanır.

Rasyonel Metot: Rasyonel metot, işletmenin hedefleri ve stratejileri temelinde işgücü talebini belirlemek için kullanılır. Bu yöntem, işletmenin gelecekteki büyüme hedeflerine, yeniliklerine ve teknolojik gelişmelere göre işgücü talebini tahmin etmek için kullanılır.

Stokastik Yöntem: Stokastik yöntem, belirsizlik durumlarında işgücü talebini tahmin etmek için kullanılır. Bu yöntem, işletmenin satış tahminleri, ekonomik faktörler ve sektördeki rekabet durumu gibi faktörlere dayanarak gelecekteki işgücü talebini tahmin eder.

İşgücü Planlama Modeli: İşgücü planlama modeli, işletmenin işgücü ihtiyacını karşılamak için gerekli kaynakları belirlemek için kullanılır. Bu model, işletmenin işgücü kaynaklarını, işgücü taleplerini ve işgücü planlama sürecinde kullanılan diğer faktörleri analiz ederek işgücü planlaması yapar.

Markov Analizi: Markov analizi, işletmenin mevcut işgücü kaynaklarına dayanarak gelecekteki işgücü talebini tahmin etmek için kullanılır. Bu yöntem, işletmenin mevcut personel durumunu analiz ederek, gelecekteki işgücü taleplerini tahmin etmeye yardımcı olur.

İş Analizi: İş analizi, işin gereksinimlerini ve görevlerini belirlemek için kullanılır. Bu yöntem, işletmenin işgücü ihtiyaçlarını ve işe alınacak kişilerin niteliklerini belirlemeye yardımcı olur.

Gelecek Senaryolarının Analizi: Gelecek senaryolarının analizi, işletmenin gelecekteki işgücü talebini tahmin etmek için kullanılır. Bu yöntem, farklı gelecek senaryolarına göre işgücü taleplerinin nasıl değişebileceğini gösterir.

Simülasyon Analizi: Simülasyon analizi, işletmenin işgücü talebini tahmin etmek ve işgücü planlamasını yapmak için kullanılır. Bu yöntem, farklı senaryolarda işgücü taleplerinin nasıl değişebileceğini ve bu taleplere nasıl cevap verilebileceğini gösterir.

Aday Havuzu Analizi: Aday havuzu analizi, işletmenin işgücü planlamasını yaparken kullanabileceği potansiyel adayları belirlemek için kullanılır. Bu yöntem, işletmenin mevcut aday havuzunu inceleyerek, işgücü taleplerini karşılamak için uygun adaylar bulmaya yardımcı olur.

İşe Alım ve İşten Ayrılma Analizi: İşe alım ve işten ayrılma analizi, işletmenin işgücü planlamasını yaparken işe alım ve işten ayrılma oranlarını da dikkate alarak kullanılır. Bu yöntem, işletmenin işe alım sürecini iyileştirmek ve personel devir hızını azaltmak için kullanılabilir.

Bu yöntemler, işletmelerin personel planlama sürecinde kullanabilecekleri çeşitli yöntemlerden bazılarıdır. Firmanın/şirketin özellikleri, hedefleri ve piyasa koşulları gibi faktörlere göre, farklı yöntemlerin bir kombinasyonu kullanılabilir. İnsan kaynakları planlamasında kullanılan yöntemler; istatistiksel yöntemler, yöneylem araştırması yöntemleri, en az rizikolu iş gücü planlaması yöntemi, şebeke akımı yöntemleri olmak üzere dört ana grupta toplanmaktadır.

Norm Kadro

Norm kadro, bir şirketin belirli bir zaman diliminde gereksinim duyduğu çalışan sayısının saptanması ve bu sayıya uygun bir kadronun oluşturulma sürecidir. Bu kadro, işletmenin operasyonları için gerekli personel sayısını belirleyerek, aynı zamanda personel bütçesi için bir temel oluşturur.

Norm kadro, işletmenin stratejik hedeflerine, vizyonuna ve misyonuna uygun bir biçimde, işletmenin kapasitesi, faaliyet gösterdiği sektör, ürün/hizmet yelpazesi, çalışma saatleri, mevsimsel değişkenler, iş yükü, teknolojik altyapı ve benzeri faktörlerin etkisiyle belirlenir.

Norm kadro belirleme süreci, işletmenin insan kaynakları planlaması aşamasında yer alır. İşletme, işgücü taleplerini değerlendirerek, ihtiyaç duyduğu çalışan sayısını saptar. Sonrasında, norm kadro hesaplaması yaparak, işletmenin belirli bir zaman diliminde kaç çalışana ihtiyaç duyduğunu belirler. Norm kadro hesaplaması, işletmenin mevcut çalışan sayısı, iş yükü, işin özelliği ve diğer etkenlere bağlı olarak gerçekleştirilir.

Norm kadro hesaplamaları, bir işletmenin mevcut personel sayısı, iş yükü, çalışma saatleri ve diğer etkileyen unsurlar temel alınarak gerçekleştirilir. İşletme, norm kadrosunu belirlerken, personel ihtiyacını analiz eder ve bu ihtiyacı karşılamak için gereken çalışan sayısını hesaplar. Bu hesaplamalarda, işletmenin genel performansı, iş güvenliği, iş sağlığı, eğitim ve gelişim faaliyetleri gibi kritik faktörler de dikkate alınır.

Norm kadronun amacı

Norm kadro, bir işletmenin belirli bir dönemde gereksinim duyduğu personel sayısını belirleyerek, buna uygun bir kadronun oluşturulmasını amaçlar. Bu kavram, işletmelerin personel planlama sürecinde önemli bir rol oynar ve mevcut ve gelecekteki ihtiyaçları karşılamak adına gerekli personel sayısının tespit edilmesine yardımcı olur. İşletmeler, faaliyet gösterdikleri sektör, ürün/hizmet çeşitliliği, çalışma saatleri, mevsimsel değişiklikler, iş yükü, teknolojik altyapı gibi çeşitli faktörlere bağlı olarak norm kadroyu belirler.

Kadro belirleme süreci, işletmelerin personel bütçelerini oluşturmalarına destek sağlar ve bu da işletmelerin genel verimliliğini artırır. Norm kadro sayesinde, işletmeler personel ihtiyaçlarını önceden belirleyebilir ve buna göre bütçelerini düzenleyebilirler. Ayrıca, kadro belirleme süreci, işletmelere personel seçimi, eğitimi ve gelişimi konularında rehberlik eder. Bu şekilde, işletmeler hem güçlü bir personel yapısı oluşturabilir hem de etkin bir şekilde operasyonlarını sürdürebilirler.

Norm kadronun önemi

Personel yönetimi, kurum ve örgütlerin etkin bir şekilde faaliyet göstermeleri için kritik bir rol oynar. Bu alan, genellikle belirlenmiş sorumlulukları içerir ve işletmenin ihtiyaç duyduğu iş gücünü tespit etme, insan kaynakları planlaması yapma, iş analizleri gerçekleştirme, personel alımı ve yerleştirmesini yönetme, hizmet içi eğitim programları oluşturma ve uygulama, adil ve teşvik edici bir ücret sistemi oluşturmak için iş değerlendirmesi yapma, iş güvenliği önlemlerini alma, sendikalarla toplu iş sözleşmelerini yürütme ve personelin özlük işlerini takip etme gibi önemli görevleri kapsar. Bu kapsamlı sorumluluklar, işletmelerin sağlıklı bir personel yönetimi sistemine sahip olmalarını sağlayarak, çalışanların etkili bir şekilde katkıda bulunmalarını ve kurumun hedeflerine ulaşmasını destekler. Personel yönetimi, işletmelerin insan kaynaklarını en verimli şekilde kullanmalarını sağlayarak, kurumsal başarıya önemli bir katkıda bulunur.

Norm kadronun personel yönetimi içindeki kritik rolü, iki temel açıdan ortaya çıkmaktadır. İlk olarak, norm kadro belirleme süreci, kurumların iş yükünü doğru bir şekilde planlayarak genel iş verimliliğini artırmada önemli bir rol oynar. Norm kadro, işletmelerin ihtiyaç duyduğu personel sayısını belirleyerek, buna uygun şekilde personel alımını gerçekleştirmelerine olanak tanır. Bu sayede iş yükü dengeli bir şekilde dağıtılır ve çalışanların etkinliği artırılır.

İkinci olarak, norm kadro belirleme süreci, kurumların personel giderlerini doğru bir şekilde hesaplamalarına yardımcı olur. Norm kadro, personel sayısı ve iş yüküne göre yapılacak harcamaları önceden planlama imkanı sağlar. Bu yöntemle, kurumlar personel bütçelerini etkili bir şekilde yönetebilir ve maliyetleri minimize edebilirler.

Sonuç olarak, personel yönetimi, işletmelerin ve organizasyonların etkili bir şekilde faaliyet göstermesinde kritik bir öneme sahiptir. Bu bağlamda, norm kadro belirleme süreci, personel yönetiminin temel görevlerinden biri olarak öne çıkar ve kurumların iş yükünü doğru bir şekilde planlamalarına ve personel maliyetlerini kontrol etmelerine önemli ölçüde katkıda bulunur.

İşletmeler açısından norm kadronun önemi

Norm kadronun işletmeler için birçok avantajı bulunmaktadır. Bu avantajları detaylı bir şekilde ele alacak olursak:

- Bir kurumun veya birimin hedeflerine ulaşabilmesi için gereken çalışan sayısı, iş ölçümü yöntemi kullanılarak belirlenir. Bu yaklaşım, gereksiz personel istihdamını önleyerek işgücü verimliliğini artırır. Norm kadro çalışmaları sırasında belirlenen

personel sayısı, aynı zamanda personelin sahip olması gereken nitelikleri de ortaya koyar. Bu durum, kurumun personel eğitim programlarını planlamasına katkı sağlar ve yeni personel alımlarında aranacak özelliklerin daha açık bir şekilde belirlenmesine yardımcı olur.

- Norm kadro, görev unvanlarına netlik kazandırarak unvan kargaşasını önler. Örneğin, günlük iş yükü 8 saatten az olan işler için özel bir unvan yaratılmamış olur. Bu çalışmalar, yönetimin tarafsız bir temele oturtulmasına katkı sağlar. Aynı zamanda, norm kadro belirleme süreci, personel giderlerinin gerçeğe uygun bir şekilde belirlenmesine, çeşitli kararlara bağlı olarak mali tablonun hesaplanmasına ve işletmenin daha gerçekçi bir karakter kazanmasına olanak tanır.
- Personel ihtiyacını belirleme konusunda norm kadro, işletmelerin belirli bir dönemde gereksinim duyacakları personel sayısını tespit ederek, personel planlama sürecine rehberlik eder. Bu yaklaşım, işletmelerin personel ihtiyacını önceden belirlemelerine olanak tanır ve böylece ihtiyaç duyulduğunda sorunsuz bir şekilde personel temini sağlanır.
- Personel bütçesini oluşturma aşamasında norm kadro, işletmeler için önemli bir araçtır. Norm kadronun belirlenmesi, işletmelerin personel maliyetlerini önceden tahmin etmelerini sağlar. Bu durum, işletmelerin finansal planlama süreçlerini kolaylaştırır.
- Verimliliği artırma noktasında norm kadro, işletmelerin personel ihtiyaçlarını önceden belirleyerek, personel yönetimini daha etkili bir hale getirmelerine yardımcı olur. Bu da işletmelerin personel eksikliği ya da fazlalığı gibi sorunlarla karşılaşmadan verimliliklerini artırmalarına olanak sağlar.
- İş güvenliği ve sağlığı konusunda norm kadro, işletmelerin işçilerin çalışma koşullarını göz önünde bulundurarak, uygun iş güvenliği ve sağlığı tedbirlerini alabilmelerine yardımcı olur.
- İşletme hedeflerine uygun personel seçimi noktasında norm kadro, işletmelerin hangi pozisyonlarda ve hangi yeteneklere sahip personellere ihtiyaç duyduğunu belirleyerek, doğru personeli seçmelerine yardımcı olur. Bu da işletmelerin işletme hedeflerine daha başarılı bir şekilde ulaşmalarına olanak tanır.
- İşletme performansının izlenmesi konusunda norm kadro, işletmelerin personel performansını değerlendirme ve bu şekilde genel işletme performansını takip etme imkanı sağlar. İşletmeler, performans eksikliklerini belirleyerek, personel eğitimi veya diğer önlemlerle performansı artırabilirler.

- Personel eğitimi ve gelişimi açısından norm kadro, işletmelerin personelin yeteneklerini belirleyerek, etkili bir eğitim ve gelişim planı oluşturmalarına yardımcı olur. Bu da işletmelerin personel iş becerilerini ve verimliliğini artırmalarına katkıda bulunur.
- Personel motivasyonu noktasında norm kadro, işletmelerin personel ihtiyaçlarını belirleyerek, stres ve baskının önlenmesine yardımcı olarak personel tatminini ve motivasyonunu artırır.
- Personel yönetimi bağlamında norm kadro, işletmelere etkili bir personel planlama ve yönetim stratejisi sunarak bir dizi avantaj sağlamaktadır. İşletmeler, norm kadroya uygun olarak personel planlaması yaparak personel yönetimini daha planlı ve öngörülebilir bir hale getirebilirler. Bu yaklaşım, işletmelere personel ihtiyaçlarını önceden belirleme ve stratejik bir planlama yapma imkanı tanır, böylece personel yönetimini daha etkili bir şekilde gerçekleştirebilirler.
- Norm kadronun sağladığı bir başka avantaj da işletmelerin personel yönetimini kolaylaştırmasıdır. Norm kadro, işletmelere önceden personel ihtiyaçlarını belirleme ve bu doğrultuda planlama yapma fırsatı sunar. Bu da işletmelerin doğru pozisyonlara doğru personeli yerleştirme konusunda başarılı olmalarına yardımcı olur, dolayısıyla personel performansını artırır.
- Norm kadro, işletmelere işe alım süreçlerini daha etkin bir şekilde yönetme imkanı sağlayarak işe alım maliyetlerini azaltma konusunda da katkıda bulunur. İşletmeler, norm kadro sayesinde personel ihtiyaçlarını önceden belirleyerek işe alım sürecini daha planlı bir şekilde yönlendirebilir ve bu da maliyetleri minimize etmelerine yardımcı olur.
- Eğitim ve gelişim planlaması noktasında norm kadro, işletmelere pozisyonlara özel eğitim programları oluşturabilme imkanı sunar. İşletmeler, norm kadroda belirlenen pozisyonların gereksinimlerine göre personelin eğitim ve gelişim ihtiyaçlarını belirleyebilir, böylece personelin yetkinliklerini artırarak işletme hedeflerine daha başarılı bir şekilde ulaşabilirler.
- Personel motivasyonunu artırma açısından norm kadro, işletmelere doğru personeli doğru pozisyona yerleştirerek çalışanların iş yükünü dengeli bir şekilde dağıtmalarına olanak tanır. Bu da çalışanların motivasyonunu artırır ve işletmelerin daha verimli bir çalışma ortamı oluşturmalarına yardımcı olur.
- Norm kadro, işletmelerin işletme planlama ve stratejileri konusunda da önemli bir rol oynar. İşletmeler, norm kadroda belirlenen personel sayısı ve pozisyonlara göre işletme hedeflerine ulaşmak için gerekli stratejileri belirleyebilirler.

- Son olarak, norm kadro işletmelerin yasal uyum sağlamalarına yardımcı olur. İşletmeler, norm kadro sayesinde çalışma saatleri, izin süreleri, sosyal haklar gibi yasal düzenlemelere uyum sağlama konusunda daha kolay hareket edebilirler. Bu da işletmelerin yasal sorunlarla karşılaşma riskini azaltır ve işletme faaliyetlerini daha güvenli bir şekilde sürdürmelerine katkıda bulunur. Tüm bu yararlar göz önünde bulundurulduğunda, norm kadro işletmeler için stratejik bir araç olarak öne çıkar, personel ihtiyaçlarının etkili bir şekilde belirlenmesine ve yönetilmesine olanak tanır, bu da işletmelerin genel verimliliğini artırır ve başarılarını destekler.

Personel açısından norm kadronun önemi

Kurumlarda personel yönetimiyle ilgili önemli bir sorun, ücret sistemlerinin, görevlerin, yetkilerin ve sorumlulukların belirsiz bir ayrıma tabi tutulmasıdır. Bu durum, personelin işleri hakkında yeterli bilgiye sahip olamamasına ve işler arasındaki farklılıkların belirlenememesine neden olabilir. Bu sorunları çözmek için norm kadro düzenlemelerinde, iş tanımları ve iş gereklilikleri üzerinden bir işin yapılması için personelde aranan nitelikler, görev, yetki ve sorumluluklar ile çalışma koşulları net bir şekilde belirtilmelidir.

Buna ek olarak, iş değerlendirmesi yöntemi kullanılarak işler arasındaki farklılıklar belirlenebilir, böylece eşit işe eşit ücret prensibi daha etkili bir şekilde uygulanabilir. Bu yöntemle, personel işleri hakkında daha detaylı bilgi elde edilecek ve işler arasındaki farklılıklar daha açık bir şekilde ortaya konacaktır. Ayrıca, iş değerlendirmesi sayesinde işlerin çeşitli faktörlere göre durumu belirlenecek ve buna göre ücretlendirme yapılacaktır.

Sonuç olarak, norm kadro düzenlemelerinde iş tanımları ve iş gerekliliklerinin net bir şekilde belirlenmesi ve iş değerlendirmesi yöntemiyle eşit işe eşit ücret prensibinin uygulanması, kurum ve işletmelerdeki personel sorunlarının çözümü için kritik adımlardır. Bu yaklaşımla, işlerin doğru bir şekilde tanımlanması ve adil bir ücretlendirme ile personelin motivasyonu artırılabilir, böylece verimlilik düzeyi de yükseltilebilir.

Norm kadro tespit süreci

Norm kadronun tespit edilmesi süreci, işletmenin büyüklüğüne, faaliyet alanına ve personel ihtiyacına göre farklılık gösterebilir. Ancak genel olarak norm kadro tespit süreci şu adımlardan oluşur:

- İşletmenin organizasyon şemasının belirlenmesi: İşletmenin organizasyon şemasının belirlenmesi, işletmenin tüm birimlerini, pozisyonlarını ve bu pozisyonlar arasındaki ilişkileri gösterir. Bu adım, işletmenin yapısının

anlaşılmasına ve ihtiyaç duyulan pozisyonların belirlenmesine yardımcı olur. Organizasyon şeması, işletme yöneticileri tarafından hazırlanabilir veya işletmenin ihtiyacına göre bir danışmanlık firması tarafından hazırlanabilir.

- İşletmenin faaliyet alanlarının belirlenmesi: İşletmenin faaliyet alanları belirlenir. Bu adım, işletmenin faaliyetlerini ve bu faaliyetlere göre ihtiyaç duyulan pozisyonları belirlemeye yardımcı olur. İşletmenin faaliyet alanlarına göre, işletmenin ihtiyaç duyduğu pozisyonlar ve bu pozisyonlar için gerekli olan nitelikler tespit edilir. Bu adımda, işletmenin iş süreçleri ve departmanlar arasındaki bağlantılar da göz önünde bulundurulur.
- İşletmenin iş yükünün belirlenmesi: İşletmenin mevcut iş yükü belirlenir. Bu adım, işletmenin hangi pozisyonlara ihtiyaç duyduğunu belirlemeye yardımcı olur. İş yükü belirlenirken, işletmenin her bir departmanındaki çalışanların iş yükü, işlerin yoğunluğu, iş süreçlerinin analizi, işletmenin büyüklüğü ve faaliyetleri dikkate alınır. Bu adım, işletmenin ihtiyaç duyduğu pozisyon sayısını belirlemeye yardımcı olur.
- İşletmenin büyüklüğünün belirlenmesi: İşletmenin büyüklüğüne göre, işletmenin kaç personel çalıştırması gerektiği belirlenir. İşletmenin büyüklüğü, işletmenin yıllık ciro, çalışan sayısı, ürün sayısı, müşteri sayısı ve pazar payı gibi faktörlere göre belirlenir. Bu adım, işletmenin personel ihtiyacını belirlemeye yardımcı olur.
- İşletmenin gelecekteki hedeflerinin belirlenmesi: İşletmenin gelecekteki hedefleri belirlenir. Bu hedefler, işletmenin büyüme hedefleri, yeni pazarlara açılma hedefleri, yeni ürünler geliştirme hedefleri ve diğer hedefler olabilir.
- İşletmenin mevcut personelinin analizi: İşletmenin mevcut personeli analiz edilir. Bu adım, işletmenin mevcut personelinin yetkinlikleri, becerileri ve performansları hakkında bilgi sağlar. Bu analiz sonucunda, işletmedeki yetenek boşlukları ve güçlü yönler belirlenir. Bu bilgi, işletmenin ihtiyaç duyduğu niteliklere sahip personel bulma sürecinde kullanılabilir.
- İşletmenin gelecekteki personel ihtiyacının belirlenmesi: İşletmenin gelecekteki personel ihtiyacı belirlenir. Bu adım, işletmenin büyüme hedefleri, yeni pazarlara açılma hedefleri ve diğer hedefler doğrultusunda belirlenir. İşletmenin gelecekteki hedefleri ve büyüme planları dikkate alınarak, işletmenin ihtiyaç duyacağı yeni pozisyonlar belirlenir ve bu pozisyonlar için gerekli olan nitelikler tespit edilir.
- İşletmenin mevcut personelinin yeniden yapılandırılması: İşletmenin mevcut personeli, işletmenin yeniden yapılandırılması ve ihtiyaç duyulan yeni pozisyonlara

uyum sağlamak için eğitilebilir veya yeniden görevlendirilebilir. Bu adım, işletmenin personel ihtiyacını karşılamak için farklı bir yaklaşım sunar.

- Norm kadronun belirlenmesi: Tüm bu adımların tamamlanmasının ardından, işletmenin norm kadrosu belirlenir. Norm kadro, işletmenin mevcut durumuna, gelecekteki hedeflerine ve ihtiyaçlarına göre belirlenir. Norm kadro, işletmenin ihtiyaç duyduğu pozisyonları, bu pozisyonlar için gerekli olan nitelikleri ve personel sayısını belirler. Bu adım, işletmenin personel planlama sürecini tamamlar.

Norm kadro tespit süreci, işletmenin personel ihtiyaçlarını karşılamak için önemlidir. İşletmeler, norm kadro tespit sürecinde dikkatli olmalı ve işletmenin mevcut durumuna, gelecekteki hedeflerine ve ihtiyaçlarına uygun bir norm kadro belirlemelidir. Bu sayede işletmeler, personel ihtiyaçlarını karşılayabilir ve işletmenin hedeflerine ulaşabilir.

Norm kadro tespiti nasıl yapılır?

Kurum ve organizasyonlarda, her pozisyona ait iş yükü, gerekli zaman (saat) cinsinden hesaplanarak çalışma performansına bölünür. Bu yöntemle, her unvan için belirli bir norm kadro sayısı belirlenmiş olur. Kurumun tüm birimlerinde, her pozisyonun iş yükleri hesaplanarak çalışma performansına bölünür ve bu sayede genel norm kadro sayısı tespit edilir. Bu süreç, her unvanın görevlerini ve iş yükünü açıkça tanımlayarak, kurumun personel ihtiyaçlarını daha hassas bir şekilde belirlemesine ve iş gücünü etkili bir biçimde planlamasına olanak tanır. (Yılmaz 2012)

$$\text{Norm Kadro Sayısı} = \frac{\text{Gerekli Zaman İş Yüğü (saat)}}{\text{Çalışma Performansı}} = \frac{8000}{1600} = 5$$

Bu bağlamda, kurumun evrak kayıt işlemlerini etkin ve verimli bir şekilde yürütebilmek adına gereken memur sayısını belirlemek için iki farklı yöntem uygulanabilir. İlk yöntemde, evrak kayıt işlerinin gerektirdiği iş yükü, her bir memurun çalışma performansına bölünerek 5 memur sayısı belirlenmiş olur. Diğer bir yöntem ise norm kadro sayısının belirlenmesinde birinci yönteme benzer bir yaklaşım sunar. Bu yöntemde, kadroların standart performansları ilk olarak belirlenir; bu, iş ölçümü yapılarak ya da iş ölçümü yapılmadan hesaplanabilir. Aynı unvandaki birden fazla kadronun performansları toplamı, kadro sayısına bölünerek ya da ele alınan kadronun çeşitli dönemlerdeki performans miktarlarının toplamı, elde edilen sonucun dönem sayısına bölünerek norm kadro sayısı belirlenir. Bu iki yöntem de kurumun evrak kayıt işlemlerini etkili bir şekilde yönetebilmek için gerekli olan personel sayısını belirleme sürecine katkıda bulunmaktadır. (Yılmaz 2012)

Ardından belirlenen bu performans değerleri, daha önce açıklanan yöntemde olduğu gibi ölçülen iş yüküne oranlanarak norm kadro sayısı tespit edilir. Örneğin, bir kurumdaki evrak biriminin yıllık iş yükü 32.000 dosya ise ve evrak memurlarının standart performansı saatte 4 dosya ise, norm kadro hesaplaması aşağıdaki gibi yapılmaktadır; (Yılmaz 2012)

Kadronun Yıllık Performans Standardı = 1.600 saat x 4 = 6.400 dosya

$$\text{Norm Kadro Sayısı} = \frac{\text{İş yükü (miktar)}}{\text{Kadronun yıllık perf. std.}} = \frac{32000}{6400} = 5 \text{ memur}$$

Buradan kurumun evrak biriminin ihtiyacı olan memur sayısının 5 adet olması gerektiği sonucu çıkmaktadır. Bu yöntemlerden ilki daha çok ölçümü yapabilen işler için kullanılmakta, ikinci yöntem ise ölçümü zorluk arz eden işlerde tercih edilmektedir. (Yılmaz 2012)

Tahmin Yöntemleri ve Zaman Serileri Analizi

Geleceğe yönelik belirsizlikler, öngörüye dayalı planlamaların en zorlu unsurlarından biridir. Bu noktada öne çıkan yöntemlerden biri zaman serileri analizidir. Zaman serileri analizi, geçmiş dönemlere ait verilerden yararlanarak geleceğe dair tahminler yapılmasına imkân tanımaktadır.

Box ve Jenkins tarafından 1975 yılında geliştirilen ARIMA modelleri, zaman serileri analizinde en yaygın kullanılan yöntemlerden biridir.(Güneş 2010).ARIMA modellerinin temel avantajı, stokastik süreçleri dikkate alarak geleceğe ilişkin güçlü öngörüler üretebilmeleridir.

Yapay Sinir Ağları (YSA)

Son yıllarda öne çıkan bir diğer tahmin tekniği yapay sinir ağlarıdır (YSA). İnsan beyninin öğrenme, algılama ve karar verme süreçlerini taklit eden YSA, özellikle belirsizliklerin yüksek olduğu alanlarda tahmin doğruluğunu artırmaktadır. Geleneksel yöntemlerle kıyaslandığında; varsayımlara ihtiyaç duymamaları, eksik ya da gürültülü verilerle çalışabilmeleri ve büyük veri setlerini işleyebilmeleri açısından önemli avantajlara sahiptir (Sarı 2016).

Literatür

Akçakaya M. (2008): İnsan kaynakları planlamasının bir aracı olarak ele alınan norm kadro çalışmasında, genelden özele doğru bir yaklaşım benimsenmiş; insan kaynakları yönetimi, planlama ve norm kadro kavramları ayrıntılı şekilde incelenmiştir. Ayrıca bazı kamu kurumlarının norm kadro uygulamaları değerlendirilmiş, bu çalışmalarda karşılaşılan sorun alanları, çözüm önerileri ve genel değerlendirmelere yer verilmiştir. Bunun yanı sıra iş gücü ve iş analizi çalışmaları da gerçekleştirilmiştir.

Önal S. (2009): Kızılırmak akım tahmini için yapay sinir ağları kullanılarak üç farklı model geliştirilmiştir. Modellerin karşılaştırılması sonucunda hepsinin uygun sonuçlar verdiği, ancak en iyi performansın yalnızca akım değerleri dikkate alındığında elde edildiği ortaya konmuştur. Sonuç olarak, yapay sinir ağlarının akım tahmini problemlerinde etkin şekilde uygulanabileceği gösterilmiştir.

Toprak H.S. (2010): Otomotiv sektöründe proje yönetimi ve iş gücü planlamasına yönelik çalışmada, firmanın geçmiş projelere ait iş yükü verileri analiz edilmiş, ayrıca farklı firmalardan kıyaslama verileri toplanmıştır. İş kırılım yapısı (WBS) kapsamında her bölüm için ayrıntılı görevler belirlenmiş, bu görevler Gantt yöntemi ile gösterilerek standart iş gücü gereksinimleri hesaplanmıştır.

Güneş M. (2010): Çalışmasında zaman serilerinin analizi için müdahale analizi tekniğini uygulamış, veri toplama sürecinde Merkez Bankası'nın web sitesinden Türkiye'nin aylık ihracat miktarlarını içeren 216 veri değeri alınmıştır. Uygulama kapsamında 2001 ekonomik krizi müdahale olayı olarak kabul edilmiş ve bu olayın seri üzerindeki etkileri müdahale analizi yöntemiyle modellenmeye çalışılmıştır.

Moralı T. (2011): İMKB 100 endeksinin tahmini amacıyla yapay sinir ağları ile Newton nümerik arama yöntemleri karşılaştırılmıştır. Elde edilen bulgulara göre, geleneksel zaman serisi modellerinin performansı YSA'ya göre daha düşük bulunmuştur. Newton yöntemi bu bağlamda daha önce yeterince denenmemiş olmakla birlikte, çalışmada farklı modeller karşılaştırılmış ve YSA'nın tahmin sonuçlarının daha uygun olduğu sonucuna ulaşılmıştır.

Yılmaz Ö.H. (2012): Türkiye'de hekim sayısının yetersizliği probleminden hareketle işyeri hekimi istihdamının uluslararası standartlara uygun biçimde yeniden planlanması amaçlanmıştır. Bu doğrultuda Delphi tekniği, matematiksel modelleme ve regresyon analizinden elde edilen bulgular kullanılmış, performans sonuçları ise simülasyon yöntemiyle test edilmiştir.

Yılmaz İ. (2012): Firmaların gelecek stratejilerini belirlemede önemli bir unsur olan personel planlama süreci üzerinde durulmuş, personel sayısının belirlenmesine yönelik yeni bir yöntem önerilmiştir. Geçmiş dönem verileri zaman serisi analiziyle incelenmiş, uygun modeller oluşturularak gelecek beş döneme ilişkin tahminler yapılmıştır. Ayrıca, yapay sinir ağları yardımıyla firmanın gelecekte ihtiyaç duyacağı personel sayısının belirlenmesine çalışılmıştır.

Sarı M. (2016): Yapay sinir ağlarının tahmin aracı olarak kullanımında geri yayılım algoritması test edilmiştir. YSA teorisi araştırılarak farklı uygulama örnekleri incelenmiş,

tahmin başarısını ölçmek amacıyla çoklu regresyon modeli ve zaman serisi analizi ile elde edilen tahmin sonuçları, YSA tarafından üretilen sonuçlarla karşılaştırılmıştır.

Altinel Ç. (2018): Çalışmada yüz yüze görüşmeler ve anket yöntemiyle iş analizleri yapılmış, bu analizlerin çıktısı olarak iş/görev tanımları oluşturulmuş ve birim bazında norm kadro hesaplamaları gerçekleştirilmiştir. İş ölçümü sonucunda beş norm kadro belirlenmiş ve mevcut kadro ile uyumlu bir sonuca ulaşılmıştır.

Meriç E. (2019): Araştırmada, yetkili personelin havalimanını bizzat ziyaret ederek yapılan işleri yerinde gözlemlemesiyle veri toplanmış, görevlerin sıklıkları ve süreleri ölçülmüştür. Ortalama görev süreleri hesaplanarak adam-saat tahminleri yapılmış, geliştirilen YSA modeli ile DHMİ'nin gelecek personel sayısı yolcu ve uçak istatistikleri doğrultusunda başarıyla tahmin edilmiştir. Bu bulgular, etkin personel politikalarının oluşturulmasına katkı sağlamıştır.

Zeng ve Khushi (2020): Forex fiyat tahmini amacıyla dalgacık gürültü azaltma, dikkat tabanlı RNN ve ARIMA modellerini birleştirerek çok bileşenli bir tahmin modeli geliştirmişlerdir.

Asaad M. (2021): Küçükmuhsine AGİ'ye ait 432 aylık akım değerinden yararlanarak akım tahmini yapmayı amaçlamıştır. Bu kapsamda Çok Katmanlı Algılayıcı (ÇKA), Uzun Kısa Süreli Bellek (UKSB) ve Adaptif Sinirsel Bulanık Çıkarım Sistemi (ASBÇS) gibi üç farklı yapay zeka modeli geliştirilmiş ve karşılaştırılmıştır. Sonuçlarda UKSB'nin, diğer modellere göre daha başarılı olduğu görülmüş; uzun vadeli tahminlerde aylık akım verileri üzerinden güçlü öngörüler sunabildiği belirtilmiştir.

Balcı T. (2021): 2006–2017 yılları arasında üçer aylık veriler kullanılarak Türkiye'deki mevduat bankalarının özkaynak karlılığı tahmin edilmiştir. Çalışmada ADAM, Stokastik Gradyan İnişi ve RMSprop optimizasyon algoritmaları kullanılmış ve bu algoritmaların farklı sonuçları kıyaslanmıştır.

Taşpınar İ. (2021): 2004–2013 yıllarındaki doğal gaz tüketim verileri, kritik parametrelerle birlikte yapay sinir ağı modellerine girdi olarak verilmiş; 2014–2020 arasındaki verilerle hata oranları karşılaştırılmıştır. İleri beslemeli, kademeli ileri beslemeli ve Elman tipi geri beslemeli ağlar kullanılmış, sonuçların genel olarak gerçek değerleri yansıtmaya rağmen bazı koşullarda farklılık gösterebileceği ve bu nedenle sonuçların dikkatle yorumlanması gerektiği vurgulanmıştır.

Bulut (2021): Rüzgâr hızı tahmini amacıyla çok katmanlı algılayıcı sinir ağları üç farklı algoritma ile test edilmiştir. Libya kıyılarındaki rüzgâr hızları için Levenberg-Marquardt

algoritması dışında Bayesian Regularization ve Ölçekli Eşlenik Gradyan (SCG) yöntemleri uygulanmış, özellikle SCG'nin az veriyle yapılan testlerde daha başarılı sonuç verdiği belirlenmiştir.

Çıragöz M.B. (2021): Üniversitelerde idari kadroların norm kadro uygulamasıyla belirlenip belirlenemeyeceğini araştırmıştır. İş analizi ve insan kaynakları planlaması yapılması öngörülmüş, ancak zaman kısıtı nedeniyle uzman görüşleriyle süreç yürütülmüştür. Delphi tekniğiyle üç oturumda 15 uzmanla görüşülmüş, norm kadro çalışmasının zaman alıcı, maliyetli ve zor bir süreç olduğu sonucuna varılmıştır.

Hao (2022): Kullanım ömrü sona ermiş araçların sayısını tahmin etmek için ARIMA ve YSA tabanlı bir model geliştirmiş, iki yöntemin birlikte kullanılmasıyla tahmin doğruluğunun artırıldığını göstermiştir.

Yuan (2022): İnsan kaynakları planlamasında geri yayılım sinir ağı (BPNN) ve radyal tabanlı fonksiyon ağlarını (RBFNN) karşılaştırarak, gelecekteki iş gücü ihtiyacını tahmin etmiştir.

Kara ve Yıldız (2024): Çok desenli veri setlerinde tahmin doğruluğunu artırmak amacıyla ARIMA ve YSA modellerini bir araya getirmiştir. Modelde ARIMA'dan elde edilen artıklar YSA ile işlenmiş ve böylece doğruluk oranı yükselmiştir.

Singh ve Kumar (2024): Platin fiyat tahmini için ARIMA ve YSA'nın entegre edildiği hibrit bir model geliştirmiş, bu modelin doğruluğunu klasik yöntemlerle karşılaştırmıştır.

Niyaz M. (2025): Otomotiv sektöründe iş gücü planlamasıyla ilgili son on yıllık akademik eğilimleri incelemiş, liderlik, bilgi yönetimi ve çalışan becerilerinin planlamaya etkilerini analiz etmiştir.

MATERYAL VE METOT

Zaman Serileri

Zaman serileri, belirli bir zaman diliminde meydana gelen olayların sayısal verilerle ifade edilen sıralı düzenidir. Bu veri dizilerinin matematiksel yöntemlerle analiz edilmesi için zaman serisi modelleri kullanılır. Bu modeller, verilerin zaman içindeki eğilimleri, değişim şekilleri ve genel davranışları üzerinde analiz yapmayı mümkün kılar. Temel olarak, zaman serisi modelleri sayesinde bir değişkenin zaman içindeki hareketlerini anlamak ve bu hareketlere dayanarak gelecekteki durumları tahmin etmek mümkündür. Zaman serileri analizi, verilerin doğru bir şekilde anlaşılabilmesi ve tahminlerin güvenilir olabilmesi için önemlidir. Bu bağlamda, zaman serileri analizinde kullanılan yöntemlerin seçimi büyük bir öneme sahiptir. (Güneş 2010)

Zaman Serileri Yapısı

Zaman serileri incelenirken veri dizisindeki gözlemler arasındaki örüntülerin analizi yapılmalıdır. Bu analizler sırasında seriyi oluşturan veriler arasındaki bağımlılıklar araştırılmalı ve belirlenmelidir. (Nasuhoğlu 2019)

Zaman serileri literatürde dört temel bileşen ile tanımlanmaktadır.

- Eğilim (Trend): Zaman serilerinde uzun vadede gözlemlenen artış ya da azalış yönünü ifade eder.
- Dönemsel Dalgalanmalar: Genellikle üç yıl ve üzerini kapsayan süreçte, temel trend doğrusu çevresinde ortaya çıkan uzun dönemli dalgalanmalardır.
- Mevsimsel Dalgalanmalar: İklimsel koşullar veya bireylerin alışkanlık ve davranışlarından kaynaklanan periyodik değişimlerdir.
- Tesadüfi Unsurlar (Rasgele Olaylar): Ortaya çıkış nedenleri net olarak açıklanamayan, düzenli bir seyir izlemeyen ve rastlantısal dalgalanmalar şeklinde görülen hareketlerdir.

Zaman serisi (yt) veri seti içerisinde trend (T), dönemsel hareketler (D), mevsimsel hareketler (S), rasgele olaylar (R) hepsini barındırabileceği gibi farklı kombinasyonlarla bazı durumları barındırmayabilir. Literatürde zaman serisi dört durumu bir arada içeriyorsa toplamsal model denklem 1'deki şekilde ifade edilmiştir. (Nasuhoğlu 2019)

$$y_t = (T + D + S + R) \quad (1)$$

Zhang (2003) da yayınladığı zaman serilerinde tahmin üretimi için hibrit modelinde zaman 30 serisinin doğrusal, doğrusal olmayan olaylardan meydana geldiğini ve bu olaylar arasında bir bağ olduğunu ifade etmiştir.

$$y_t = (L_t + N_t) \quad (2)$$

Eşitlik 2’de gösterilen doğrusal bileşen L_t , doğrusal olmayan bileşen ise N_t ile ifade edilmektedir.

Zaman serilerinin analizinde sıklıkla başvurulanan yöntemler arasında; hareketli ortalama, ağırlıklı hareketli ortalama, üssel düzeltme teknikleri, çift üssel düzeltme (Holt lineer), Winters yaklaşımı, Holt-Winters modeli, Box-Jenkins yöntemleri, otoregresif hareketli ortalama (AR-MA) ve otoregresif bütünleşik hareketli ortalama (ARIMA) modelleri yer almaktadır. Bu çalışmada ise uygulama aşamasında özellikle ARIMA ve mevsimsellik içeren ARIMA (SARIMA) yöntemlerinin detaylı açıklamalarına odaklanılmıştır (Rizvanche 2020).

Veri seti herhangi bir trend ya da mevsimsel özellik göstermediğinde, hareketli ortalama veya üssel düzeltme yöntemlerinin tercih edilmesi uygun görülmektedir. Buna karşılık, zaman serisi doğrusal bir trend içeriyorsa, çift üssel düzeltme (Holt lineer) yaklaşımı daha doğru sonuçlar verebilir. Verilerin hem trend hem de mevsimsellik özellikleri taşıması durumunda ise, Holt-Winters yöntemi kullanılması önerilmektedir (Nasuhoglu 2019).

Durağanlığın analizine yönelik olarak birim kök testi

Zaman serisi analizinde durağanlık, verilerin sabit bir ortalama çevresinde dalgalanması ve bu dalgalanmaların varyansının zaman içerisinde değişmemesi durumu olarak tanımlanır. Durağanlığın varlığını belirlemek için farklı yöntemlerden yararlanılmaktadır. Bunlar;

- Serinin zaman yoluna ilişkin grafiğinin incelenmesi,
- Otokorelasyon ve kısmi otokorelasyon katsayılarının korelogram üzerinde değerlendirilmesi,
- Seriyeye birim kök testlerinin uygulanmasıdır.

Özellikle birim kök testi, durağanlığı incelemede en yaygın olarak kullanılan yöntemlerden biridir. Bu bağlamda, AR(1) süreci üzerinden birim kökün varlığını sınamaya yönelik adımlar şu şekilde gerçekleştirilmektedir:

$$Y_t = \phi_1 Y_{t-1} + \varepsilon_t \quad \varepsilon_t \sim WN(0, \sigma^2) \quad (3)$$

Durağanlık sınaması sırasında φ_1 seriye gelen şokların yapısı hakkında bilgi vermektedir.

- $1 < \varphi_1 < 1$ dir ve eğer;

$|\varphi_1| \geq 1$ serinin durağan olmaması, birim kök içerdiğini ve maruz kaldığı şokların etkisinin geçici değil, kalıcı nitelik taşıdığını göstermektedir.

$|\varphi_1| = 1$ seriye gelen şok, geçici bir dalgalanma yaratmaktan ziyade kalıcı bir etki bırakmakta ve sistem üzerinde yapısal bir değişime yol açmaktadır.

$|\varphi_1| \leq 1$ serinin durağanlık göstermesi, birim kök barındırmadığını ve maruz kaldığı şokların yalnızca geçici dalgalanmalara yol açtığını ifade etmektedir.

Birim kök testlerinde; $H_0 : \varphi = 1$ hipotezine karşılık $H_A : \varphi < 1$ hipotezi test edilmektedir. Alternatif hipotez kabul edildiğinde serinin durağan olduğu söylenmektedir.

Ancak pratikte daha kolay olması nedeniyle $\varphi = 1$ yerine $p = (\varphi - 1) = 0$ hipotezi test edilmektedir. (Yılmaz 2012)

$Y_t = \varphi_1 Y_{t-1} + \varepsilon_t$ eşitliğinde hata düzeltme modeli yazılır ise;

$$Y_t - Y_{t-1} = \varphi_1 Y_{t-1} - Y_{t-1} + \varepsilon_t$$

$$\Delta Y_t = (\varphi_1 - 1) Y_{t-1} + \varepsilon_t$$

$(\varphi_1 - 1) = p$ olmaktadır. Birim kökün varlığını sınamak amacıyla oluşturulan hipotezler aşağıda sunulmaktadır.

$H_0 : p = 0$ ($\varphi = 1$) seri durağan değildir, birim kök vardır.

$H_A : p < 0$ ($\varphi < 1$) seri durağandır, birim kök yoktur.

Birim kökün varlığını incelemek amacıyla literatürde çeşitli testler kullanılmaktadır. Bunlar arasında DF (Dickey-Fuller), ADF (Augmented Dickey-Fuller), Phillips-Perron, Ng-Perron, DFGLS (Dickey-Fuller test with GLS Detrending), ERSP (Elliot, Rothenberg ve Stock Point Optimal Test) ve KPSS (Kwiatkowski, Phillips, Schmidt ve Shin) testleri yer almaktadır. Bu yöntemler arasında DF testi, en sık başvuru alanlardan biridir. Ancak bu testin, hata terimlerinin beyaz gürültü (WN) özelliği gösterdiği varsayımına dayandığı göz önünde bulundurulmalı ve uygulanırken bu varsayımın geçerliliği dikkatle değerlendirilmelidir (Yılmaz 2012).

Durağanlık testleri sonucunda sürecin durağan olmadığı belirlendiğinde, uygulamada iki farklı yöntem izlenebilmektedir.

- Serinin farkları alınabilir.
- Deterministik trend, zaman değişkeniyle regresyon analizi yapılarak elde edilen artıklar üzerinden çalışmak ya da modele doğrudan zaman trendi eklemek suretiyle ortadan kaldırılabilir.

Doğrusal zaman serisi modelleri

Zaman serileri genel olarak doğrusal ve doğrusal olmayan olarak ikiye ayrılmaktadır. Doğrusal seriler ise kendi içinde mevsimsel ve mevsimsel olmayan olmak üzere sınıflandırılabilir. Bu çalışmanın kapsamı yıllık verilere dayandığı için yalnızca mevsimsel olmayan doğrusal zaman serilerine odaklanılmıştır.

Doğrusal modeller arasında literatürde yaygın olarak kullanılan yöntemler; otoregresif (AR), hareketli ortalama (MA), otoregresif hareketli ortalama (ARMA), bütünleşik otoregresif hareketli ortalama (ARIMA) ve mevsimsel bütünleşik otoregresif hareketli ortalama (SARIMA) modelleridir (Rizvanche 2020).

Bu modellerden ARIMA, özellikle tek değişkenli serilerde kısa dönemli tahminler için etkili bir biçimde kullanılabilir. Ancak ARIMA modelinin uygulanabilmesi için veri setinin kesikli ve durağan özellik göstermesi gerekmektedir. Bu çerçevede, zaman serisi modelleri üç ana kategoride ele alınabilmektedir (Rizvanche 2020).

1. Durağan ARMA Modelleri

- a. AR (Oto regresif Süreç Modelleri) : Belirli bir hata payı ve geçmiş veriler ile ekonomide birçok olgu tahmin edilmektedir. Oto regresif süreç modelleri, zaman serisinin kendisinden önceki değerleri ve beyaz gürültü serisi ile açıkladığı regresyon modelidir.
- b. MA (Hareketli Ortalama Modelleri) : Birçok ekonomik aktivite MA modeli ile açıklanabilmektedir. Hareketli ortalama (MA) modeli, güncel hata terimi ile önceki dönemlere ait hata terimlerinin gecikmeli değerlerinin lineer kombinasyonuna dayanmaktadır.
- c. ARMA (Oto regresif Hareketli Ortalama Modelleri) : Serinin hem otoregresif (AR) hem de hareketli ortalama (MA) özellikleri taşıması ve otokorelasyon ile kısmi otokorelasyon fonksiyonlarının analizi sonucunda modelin derecesinin kesin biçimde belirlenememesi halinde, ARMA süreci uygulanmaktadır.

2. Durağan Olmayan ARIMA Modelleri

3. SARIMA (Mevsimsel Modeller): Doğrusal zaman serilerinin analiz modellerine geçmeden bu modellerde durağanlık kavramını incelememiz gerekmektedir. Çoğu ekonomik zaman serisi durağan değildir, durağan olmayan seriler fark alma işlemi yapılarak durağan hale getirilebilir. ARIMA yöntemine göre değişken verinin gelecekteki değerinin, geçmişteki birkaç değeri ile rastsal hataların doğrusal fonksiyonu olduğu varsayılmaktadır. eşitlik 3 'de durağanlaştırmak için d kez farkı alınan serinin ARIMA(p,d,q) modeline uygunluğu açıkça görülmektedir. (Rizvanche 2020)

$$(1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p)(1 - B)^d Y_t = (1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q) e_t \quad (3)$$

Y_t : t zamanında gerçek değer

e_t : Rastsal hata

$\Phi_i (i= 1,2, \dots, p)$: AR parametreleri

$\theta_j (j= 0,1,2, \dots, q)$: MA parametreleri

p ve q $\in \mathbb{Z}$: Model derecesi

$(1-B)^d$: d. dereceden fark işlemi

e_t ortalaması 0, varyans sabitken bağımsız ve aynı dağılmış varsayılır. Yukarıdaki eşitlikte $q=0$ ise model p dereceli AR modelidir, eğer $p=0$ ise model q dereceli MA modelidir.

ARIMA(p,d,q), durağan olmayan serilerle işlem yapılırken kullanılır. AR(p), MA(q) ve ARMA(p,q) kombinasyonları, ARIMA(p,d,q) modelinden farklı olarak durağan seriler için kullanılır(Rizvanche 2020).

ARIMA model belirleme süreci

Varsayımlar yapıldıktan sonra ARIMA modelinin seçilmesi gerekmektedir. Bu varsayımlar aşağıdaki gibidir;

- Durağan veriler olmalı,
- Veriler normal dağılım göstermeli,
- Aykırı durumda veri olmamalı,
- Veri setinde eksik veri olmamalı

George Box ve Gwilym Jenkins tarafından ortaya atılan Box-Jenkins (1970) metodolojisi en popüler ARIMA modellemesi yaklaşımıdır. Zaman serileri içinde durağan olan veya durağan hale getirilmiş en uygun model seçimidir.

Model belirleme; sürecinde ilk olarak modelin tanımlaması gerekmektedir. Zaman serisinin modeli belirlenirken veri dönüşümü zaman serisini durağanlaştırmak için gereklidir.

Zaman serisinin ortalaması ve oto korelasyonu istatistiksel olarak sabitlenerek zaman serisi süreç içinde durağan olarak tanımlanabilmelidir. Zaman serisinde varyans değişken olduğunda, sezon veya trendi görülüyorsa; ARIMA modeli uygulanmadan önce fark işlemleri yapılarak varyans değişkeni ve trend sabit hale getirilmektedir (Ateşoğlu 2015).

Seriler durağan değilse, bunların durağanlaştırılması amacıyla d 'inci dereceden fark alma işlemi uygulanır. Fark alma derecesini ifade eden d durağan serilerde 0, birinci dereceden fark alma ile durağan hale gelen serilerde 1, ikinci dereceden fark alma sonucunda durağanlık sağlanan serilerde ise 2 değerini alır. Uygulamada çoğunlukla d parametresi 1 ile 3 arasında seçilmektedir. Ancak seri zaten durağan ise herhangi bir fark alma işlemine gerek bulunmamaktadır. En uygun ARIMA modelinin tanımlanabilmesi için, ACF (otokorelasyon), PACF (kısmi otokorelasyon) ve IACF (ters otokorelasyon) fonksiyonları incelenerek p, d, q parametreleri dikkatle belirlenmelidir. Burada, ARMA modelinin derecesi AR ve MA bileşenleri için ayrı ayrı tayin edilir. AR kısmının derecesi, istatistiksel olarak anlamlı kısmi otokorelasyon katsayılarının sayısına; MA kısmının derecesi ise istatistiksel açıdan sıfırdan farklı otokorelasyon katsayılarının sayısına göre belirlenir. Son aşamada, ARIMA modelinde p, d, q parametreleri belirlendikten sonra, modele ilişkin geçici parametre değerleri tahmin edilmektedir.

Farklı derecelerde tanımlanan modellerin otokorelasyon ve kısmi otokorelasyon yapıları birbirinden farklı özellikler göstermektedir. AR(p), MA(q) ve ARMA(p, q) modelleri için en uygun modelin seçimi, Tablo 1'de sunulan kriterler doğrultusunda açıklanmıştır.

Tablo 1. Durağan Zaman Verilerinde ACF ve PACF'nin Teorik Davranışları

Model	ACF (Otokorelasyon Fonksiyonu)	PACF (Kısmi Otokorelasyon Fonksiyonu)
AR (p)	Üstel şekilde ve/veya sinüs dalgaları şeklinde azalma gerçekleşir.	p kadar gecikmeden sonra istatistiksel olarak anlamlı değildir.
MA (q)	q gecikmesinden sonra sıfır noktasını keser.	Üstel şekilde ve/veya sinüs dalgaları şeklinde azalır.
ARMA	$p-q$ kadar gecikmenin ardından üstel şekilde ve/veya sinüs dalgaları şeklinde azalarak sıfır noktasını keser.	$p-q$ kadar gecikmeden sonra üstel ve/veya sinüs dalgaları şeklinde azalır.

Durağan zaman verilerinde ACF ve PACF'nin teorik davranışları uygulamada durum daha karmaşıktır. Düşük dereceli modeller, örneğin AR(1), AR(2), MA(1), MA(2) veya ARMA(1,1), aralarındaki otokorelasyonları açıkça ayırt etmek ve tanımlamak kolaydır. İstatistiksel yazılımların yaygınlaşmasıyla birlikte, otokorelasyon ve kısmi otokorelasyon

kalıplarının yanı sıra model belirleme sürecinde bazı model seçimi kriterlerinin kullanılması da mümkündür. Birçok model arasında seçim için:

- Orta Tanım Genişliği (MDL)
- Akaike bilgi kriteri (AICC)
- Nihai tahmin hatası (FPE)
- Hannan-Quinn bilgi kriteri (HQIC)
- Bayes bilgi kriteri (BIC)

İkinci adımda uygun olan geçici ARIMA modeli belirlendikten sonra bilinmeyen parametre tahmini yapılır. Hata ölçüsü parametreleri, En Küçük Kareler Yöntemi (EKK) kullanılarak tahminler üretirken, bu aşamada optimizasyon süreci, doğrusal olmayan modellere de olanak tanır. Üçüncü adımda hatalar incelenir. Model oluşturma sürecinde modelin yeterliliği kontrol edilir. Sonuç grafiği oluşturulurken, tarihsel ve istatistiksel verilere dayalı hataların grafiği, kısa vadeli model uyumluluğunu incelemek için kullanılabilir. Eğer model yetersizse, yeni bir kısa vadeli model tanımlanmalı ve inceleme yapılmalıdır. Sonraki aşamada, elde edilen yeni parametrelerle yeni tahminler yapılır ve model doğruluğu değerlendirilir. Modelin yeterliliği sağlanana kadar bu üç aşama tekrarlanır. Sonunda, seçilen model ile gelecekteki dönemler için tahminler oluşturulur.

Durağan olmayan ARIMA modelleri

Bir sürecin ortalama, varyans ve kovaryans gibi temel istatistiksel özellikleri zamanla değişmiyorsa, yani seri durağan ise, bu durumda $AR(p)$, $MA(q)$ veya $ARMA(p,q)$ modellerinden biri kullanılabilir. Ancak, gerçek hayatta çoğu zaman serisi belirli bir stokastik sürecin özelliklerini zaman boyunca değişen biçimde taşıdığı için durağan değildir. Bu tür serilerin durağanlaştırılması amacıyla, serinin bir veya birden fazla kez farkı alınarak dönüştürme işlemi uygulanabilir. Farkı alınarak durağan hale getirilen zaman serileri ise entegrasyon süreci olarak adlandırılmaktadır (Kaya 2015).

Doğrusal olmayan en küçük kareler yöntemine kısa değinecek olur ise Y_t durağan bir seri olmak üzere eşitlik 4'de ifade edilmiştir:

$$Y_t = \phi Y_{t-1} + e_t + Qe_{t-1} \quad (4)$$

ARIMA(1,1,1) modeli dikkate alındığında, model yeniden düzenlenerek hata terimi eşitliğin sol tarafına taşındığında eşitlik (5) elde edilmektedir.

$$e_t = \frac{(1-\phi B)Y}{(1-QB)} \quad (5)$$

Amaç, parametre tahminini hata kareler toplamı hedef kriterini minimize ederek gerçekleştirmektir. Ancak eşitlik (6) de e_{t-1} ve Y_{t-1} 'in başlangıç değerlerinin bilinmesi gerekmektedir.

$$f(Y_t, \varphi_1, \theta_1) = \sum_{i=0}^q e_t^2 = \left(\frac{(1-\varphi B)Y}{(1-\theta B)} \right)^2 \quad (6)$$

Parametre değerleri Marquardt algoritması ile tahmin edilmektedir. Koşullu doğrusal olmayan en küçük kareler yaklaşımında başlangıç değerleri, gerçek verilere oldukça yakın olacak şekilde belirlenirken; koşulsuz doğrusal olmayan en küçük kareler yönteminde başlangıç değerleri sıfır kabul edilmektedir. Ayrıca, koşullu doğrusal olmayan en küçük kareler yöntemi ile en çok olabilirlik yönteminin sonuçları, büyük örneklemeler söz konusu olduğunda genellikle benzerlik göstermektedir.

Eşbütünleşme Analizi

Eşbütünleşme analizi, iktisadi değişkenlere ait seriler durağan olmasa dahi bu serilerin durağan bir doğrusal bileşim oluşturabileceğini ve böyle bir ilişki mevcutsa bunun ekonometrik yöntemlerle tespit edilebileceğini ortaya koymaktadır.

Durağan olmayan iki zaman serisi aynı dereceden entegre olduklarında, aralarında eşbütünleşme ilişkisi bulunabilir ve bu durumda gözlemlenen regresyon yanıltıcı değildir. Eşbütünleşme yaklaşımı, uzun dönemli serilerde fark alma işlemiyle ortaya çıkan bilgi kaybını ve çözüm zorluklarını ortadan kaldırmaya yardımcı olmaktadır. Bununla birlikte, koentegrasyon iki seri arasında bir nedensellik bağına ima eder ancak nedenselliğin yönü hakkında doğrudan bir bilgi sunmaz.

Engle – Granger yaklaşımı

Engle ve Granger'ın (1987) çalışmasında, iki değişken arasındaki uzun dönemli ilişkinin araştırılabilmesi için modelde yer alan tüm değişkenlerin aynı dereceden durağan oldukları varsayılmaktadır. Eğer değişkenler farklı mertebelerden durağan ise, Engle–Granger yöntemi uygulanamaz.

$$Y_t = \beta_0 + \beta_1 X_t + \varepsilon_t$$

Burada X ve Y, birinci dereceden durağan I(1) değişkenleri temsil etmektedir. Bu iki değişkenin eşbütünleşik olup olmadığı, modelden elde edilen hata teriminin durağanlığına bağlıdır. Başka bir ifadeyle, hata teriminin durağan çıkması, değişkenlerin düzey değerleriyle birlikte bütünleşik olduklarını göstermektedir.

Engle – Granger yaklaşımı aşamaları

İlk aşamada değişkenlerin durağanlık dereceleri birim kök testleri yardımıyla belirlenir. Eğer iki değişken aynı dereceden durağan ise, koentegrasyon analizinin bir sonraki adımına geçilir. Ancak değişkenlerin farklı mertebelerden durağan olmaları halinde, bu değişkenler arasında eşbütünleşme ilişkisinin bulunmadığı sonucuna ulaşılır.

Her iki değişken düzey değerleri itibarıyla durağan ise ayrıca bir koentegrasyon testi yapılmasına gerek yoktur. Çünkü bu durumda her iki seri de durağan olduğu için geleneksel ekonometrik yöntemler (örneğin en küçük kareler yöntemi) doğrudan uygulanabilir.

- Değişkenlerin aynı mertebeden durağan oldukları tespit edildiğinde, eşbütünleştirici regresyon denklemi EKK (En Küçük Kareler) yöntemiyle tahmin edilir.
- Bu regresyondan elde edilen kalıntılar üzerinde durağanlık testi uygulanır. Eğer kalıntı serisi durağan ise, seriler arasında eşbütünleşme vardır. Bu değerlendirme, MacKinnon (1991) kritik değerleriyle karşılaştırılarak yapılır.

Bu bağlamda kurulan yokluk hipotezi (H_0), seriler arasında uzun dönemli bir denge ilişkisinin olmadığını, yani serilerin eşbütünleşik olmadığını ifade eder. Buna karşılık alternatif hipotez (H_1), serilerin uzun dönemli bir denge ilişkisi içinde olduğunu, yani eşbütünleşik olduklarını ileri sürmektedir.

Engle – Granger yaklaşımının zayıf yönleri

- Yöntem iki aşamadan oluştuğundan, her aşamanın ayrı ayrı değerlendirilmesi gerekir. Özellikle ilk aşamada kalıntıların elde edilmesi sırasında yapılabilecek herhangi bir hata, ikinci aşamaya da doğrudan yansıtacaktır.
- Üç veya daha fazla değişken söz konusu olduğunda, çoklu eşbütünleşme vektörlerinin ayrı ayrı tahmin edilememesi önemli bir kısıttır.
- Yöntem, N adet değişken arasından yalnızca bir eşbütünleşme ilişkisinin tanımlanmasına imkân verir. Oysa teorik olarak $n-1$ adet eşbütünleşme ilişkisi bulunabilmektedir.
- Uzun dönem denge ilişkisinin hesaplanabilmesi için değişkenlerin “bağımlı” ve “bağımsız” olarak sınıflandırılması gerekmektedir.
- Küçük örneklem büyüklüklerinde yanlışlık problemi ortaya çıkabilmekte, bu da uygulamalı çalışmalarda güvenilir sonuçların elde edilmesini güçleştirmektedir.


Yapay Sinir Ağları

Yapay sinir ağları (YSA), en popüler yapay zeka yöntemlerinden biridir ve insan sinir sisteminin basit bir taklidini temsil eder. İnsanlar, sinir sistemi aracılığıyla dış dünyadan gelen bilgileri alır, bu bilgileri işler, değerlendirir ve nihayetinde kararlar alarak harekete geçerler. Sinir sistemi, bilginin alınması, işlenmesi ve değerlendirilmesi konularında insan vücudundaki önemli bir rol oynar. Öğrenme ve deneyim kazanma süreçleri de insan sinir sistemi tarafından yönetilir. Bu sistemin temel yapı taşları, nöron adı verilen sinir hücreleridir. McCulloch ve Pitts, 1943 yılında ilk kez biyolojik bir nöronun matematiksel bir modelini oluşturdu. Bu modele dayanarak, yapay sinir ağları geliştirilmiş ve günümüzde pek çok bilim dalında araştırılan bir alan haline gelmiştir.

Biyolojik nöron

Yapay Sinir Ağları (YSA), biyolojik sinir hücrelerinin işleyişini esas alan basitleştirilmiş bir modelleme yaklaşımıdır. Günümüz bilgisayarları sayısal işlemlerde insan beyninden çok daha yüksek hız ve kapasiteye sahip olsa da, özellikle karmaşık algılama ve yorumlama gerektiren problemlerde insan beyni daha etkin sonuçlar ortaya koyabilmektedir. Yapay sinir ağları, beynin bu algılama kabiliyetinden esinlenilerek geliştirilmiş; biyolojik sinir ağlarının çalışma mekanizmalarından yararlanılarak tasarlanmış, çok sayıda bağlantı içeren paralel hesaplama sistemleri şeklinde tanımlanabilir.

Yapay sinir ağlarının işleyişini daha iyi kavrayabilmek için öncelikle biyolojik sinir sistemi hakkında temel bilgilere değinmek yararlı olacaktır. Biyolojik sinir sistemi, iki ana hücre tipinden oluşmaktadır: nöronlar ve nöroglia hücreleri. Yapay modellerde yalnızca nöronlar ve nöronlar arasındaki bağlantılar dikkate alınmış, nöroglia hücreleri ise modellenmemiştir. Bir nöron gövde (soma) ve uzantılardan meydana gelir; bu uzantılar aracılığıyla sinyallerin iletimi sağlanır. Biyolojik bir nöronun temel yapısı Şekil 1’de sunulmuştur.



Şekil 1. Biyolojik nöronun genel yapısı (Eğrioğlu, syf 2).

Nöronun ana gövdesine soma denir; soma, nöronun çekirdeğini içerir ve nöronun bilgi işleme merkezidir. Nöronun uzantıları aksiyon ve dentritlerden meydana gelir. Akson, sinyallerin iletiminden sorumlu iken, dentritler sinyalleri almakla görevlidir. Aksonlar, dentritlere göre daha kalındır, bu özellikleri sayesinde bilgiyi hızlı bir şekilde iletebilirler. Dentritler ise diğer nöronlardan gelen sinyalleri almak için sinaps adı verilen bölge kullanılmaktadır.

Bir sinir ağı, literatürde nöron, birim, hücre ya da düğüm olarak da adlandırılan çok sayıda basit işlem elemanından meydana gelmektedir. Her bir nöron, çözülmesi hedeflenen problemi temsil eden bilgileri taşıyan ve belirli ağırlıklarla ifade edilen doğrudan bağlantılar aracılığıyla diğer nöronlarla ilişki kurar. Tipik olarak ağ, iki veya daha fazla katmandan oluşur ve her katmanda bulunan işlem birimleri, komşu katmanlardaki tüm birimlerle bağlantılıdır (Asaad, 2021). İnsan beyinde yaklaşık 100 milyar nöron bulunmaktadır. Her bir nöron, çoğunlukla 10 binden fazla nöronla bağlantı kurmakta, bu da sinir sisteminin olağanüstü derecede karmaşık bir yapıya sahip olduğunu göstermektedir. Yapay sinir ağları, bu biyolojik karmaşıklığı daha basitleştirilmiş bir şekilde taklit eden yapay nöron modelleri üzerine inşa edilmiştir. Bu modellerde; dendritler girişlere, soma aktivasyon fonksiyonuna ve akson ise çıktılara karşılık gelmektedir.

Yapay sinir ağlarının gelişim evreleri

Yazılım sistemlerindeki gelişmeler ve her gün daha fazla bilginin insanlar tarafından elde edilmesinin sağlanması gibi ilerlemeler ile araştırmacılar yapay zeka alanına yönelmiştir. Elde ettikleri bilgilerin kullanılması sayesinde kişiler daha etkili kararlar almaya başlamışlardır. Daha önce bir gün sadece işlem yapan birimlerden artık karar verebilen, problem çözen

birimlere geiş insanların karar almalarını daha kolaylařtırmıřtır. Özellikle ticari sistemlerin bu řekilde geliřtirilmesi yapay zeka alanında önemli ilerlemelerin ortaya ıkmasını saėlamıřtır. Her bir alan iin geliřtirilen algoritma denilen kod sıralamaları aracılıėıyla özömlenemeyen ya da insanların kendi zekaları ile zor özöbileceklerini problemlerin özölmesi ve kararların alınması bu alana olan ilgiyi daha da artırmıřtır. Bu sistemlerde insanların karar verme řekilleri ve aşamaları taklit edilmiřtir.

1940'lı yıllarda Donald Olding Hebb, nörolog Warren McCulloch ve matematiki Walter Pitts, nörobiyoloji alanındaki yapay sinir aėı alıřmalarını mühendislik boyutuna taşıyarak ilk yapay sinir hücresi modelini geliřtirmişlerdir (Haykin, 1999). Bu dönemde arařtırmacılar, insan beyninin hesaplama yeteneklerini inceleyerek bu işlevlere uygun yapay aė yapıları üzerine alıřmalar yürütmüşlerdir. Ardından, 1949 yılında Donald Hebb, kendi adıyla anılan Hebbian öğrenme kuralını ortaya koymuş, bu yaklaşım günümüzde kullanılan birçok öğrenme kuramının temelini oluřturmuřtur (Hebb, 1949).

Yapay sinir aėlarının gelişim sürecinde 1970 yılı bir dönüm noktası olarak kabul edilmektedir. Bu tarihte Minsky ve Papert tarafından yayımlanan eser, YSA tabanlı algılayıcıların bilimsel açıdan yetersiz olduėunu, doğrusal olmayan problemlere özüm getiremediklerini ileri sürmüş ve bu durum YSA arařtırmalarında ciddi bir duraksamaya yol açmıştır. Özellikle, doğrusal olmayan ve ok katmanlı bir aė gerektiren XOR probleminin özölememesi, bu alana olan ilgiyi azaltmıştır (Voorhees, 2006).

Bununla birlikte, XOR probleminin yapay sinir aėlarıyla başarıyla özöme kavuřturulmasının ardından, alana yönelik ilgi yeniden artmış ve YSA alıřmaları tekrar ivme kazanmıştır.

Kronolojik sıra ile YSA tarihini ele alacak olur isek;

1949: Donald Hebb tarafından ortaya konulan Hebbian öğrenme kuralı, bilgisayar ortamında uygulanabilecek řekilde formöle edilmiştir.

1954: Farley ve Clark, uyarıcılara tepki verebilen ve bu uyarıcılara uyum saėlayabilen ilk aė modellerinden birini geliřtirmiřtir.

1957: Tek katmanlı algılayıcı olan Perceptron modeli tanıtılmıştır.

1959: Bernard Widrow ve Marcian Hoff, ADALINE öğrenme algoritmasını geliřtirmiřtir.

1961: Karl Steinbuch, aėrıřımsal bellek (associative memory) üzerine ilk alıřmaları gerekleřtirmiřtir.

1965: Nils Nilson tarafından “Learning Machines” adlı, makine öğrenmesine yönelik ilk kapsamlı kitap yayımlanmıştır.

1967–1969: Gelişmiş öğrenme algoritmalarına ilişkin önemli katkılar sağlanmıştır.

1969: Marvin Minsky ve Seymour Papert, perceptron modelinin doğrusal olmayan temel problemlere çözüm getiremediğini ispatlamış; bu durum YSA araştırmalarına olan ilginin azalmasına ve fonların büyük ölçüde kesilmesine yol açmıştır. Aynı dönemde DARPA, YSA araştırmalarına desteğini çekerek kaynakları diğer yapay zekâ projelerine yönlendirmiştir.

1970: Fukushima, Neocognitron modelini tanıtarak görsel işleme ve örüntü tanıma çalışmalarında yeni bir yaklaşım sunmuştur.

1972: Teuvo Kohonen ve James A. Anderson, eş zamanlı yürüttükleri çalışmalarda lineer associator modelini geliştirmiş; aynı yıl korelasyon matris belleği ortaya konmuştur.

1973: Christoph Von Der Malsburg, biyolojik modele daha yakın doğrusal olmayan bir sinir ağı modeli geliştirmiştir.

1974: Paul Werbos, daha sonra yaygın biçimde kullanılacak olan geri yayılım (backpropagation) yöntemini önermiştir. Bu yöntem, çok katmanlı algılayıcıların temelini oluşturmuştur.

1980: Stephen Grossberg ve Gail Carpenter tarafından Adaptif Rezonans Teorisi (ART) geliştirilmiştir.

1982: Teuvo Kohonen, Kendini Düzenleyen Haritalar (Self-Organizing Maps – SOM) modelini; aynı yıl John Hopfield ise Hopfield Ağlarını tanıtmıştır.

1984: Geoffrey E. Hinton ve Terry Sejnowski, Boltzmann Makinesini; Kohonen ise danışmansız öğrenme ağlarını geliştirmiştir.


1985: Amerikan Ulusal Fizik Akademisi, yapay sinir ağları çalışmalarını resmî olarak takip etmiş ve destek sağlamıştır.

1986: David E. Rumelhart ve James McClelland, geri yayılım algoritmasını geliştirmiştir.

1987: IEEE, yapay sinir ağlarına yönelik ilk uluslararası konferansı düzenlemiştir.

1988: David Broomhead ve David Lowe, Dairesel Tabanlı Fonksiyon (RBF) ağlarını geliştirmiş; aynı yıl Specht, Olasılıksal Ağ (Probabilistic Neural Network – PNN) modelini önermiştir.

1991: Specht, Genel Regresyon Ağları (General Regression Neural Networks – GRNN) modelini tanıtmıştır.



Şekil 2.YSA ve geleneksel tahmin yöntemlerinin karşılaştırılması (Kaynak: Hu,2002)

Yapay sinir ağlarının güçlü ve zayıf yönleri

YSA, çeşitli uygulama alanlarında yüksek performans sergileyen ve veri analizinde önemli avantajlar sağlayan bir yaklaşım olarak kabul edilmektedir. Bununla birlikte, bu yöntemin de göz ardı edilemeyecek bazı zayıf yönleri ve sınırlamaları mevcuttur.

YSA'nın avantajlı ya da güçlü yönlerini aşağıdaki gibi sıralamak mümkündür:

- Doğrusal Olmayan Yapılara Uygunluk (Paralellik): YSA, doğrusal olmayan nöron bağlantılarının tüm ağa yayılması sayesinde doğrusal olmayan ilişkileri

modelleyebilme kapasitesine sahiptir. Bu nedenle, gerçekleştirilen işlemler doğrusal değildir.

- Öğrenme Yeteneği (Girdi–Çıktı Eşleştirmesi): Yapay sinir ağlarının ağırlıkları, eğitim kümesinde yer alan özgün girdiler ve beklenen çıktılar kullanılarak güncellenir. Eğitim süreci, rastgele girdiler verilerek ağına ürettiği çıktılarla gerçek değerler arasındaki hatanın istatistiksel ölçütler çerçevesinde minimize edilmesi ile ilerler. Bu süreç, hata değerinde daha fazla iyileşme sağlanamayınca kadar devam eder. Ağ, bu mekanizma sayesinde olaylardan öğrenir ve benzer durumlarda benzer tepkiler verebilir.
- Uyarlanabilirlik: YSA, bilgisayar bilimlerinde önemli yere sahip matematiksel bir modeldir. Karmaşık problemlerin çözümünde etkin şekilde kullanılabilen bu yöntem, farklı uygulamalarda sağladığı esneklik ve çevresel koşullara uyum yeteneği sayesinde geniş bir kullanım alanı bulmuştur.

Yapay sinir ağlarının önemli bir özelliği, ağırlıklarının yeniden yapılandırılabilir olmasıdır. Bu, ağına belirli bir problemi çözmek için eğitildikten sonra, problemdeki değişikliklere ve farklı koşullara hızla uyum sağlayabilmesini sağlar. Yani, bir yapay sinir ağı başlangıçta bir görevi başarıyla yerine getirebilir, ancak bu görevde değişiklikler veya farklı koşullar ortaya çıktığında, ağına ağırlıkları ayarlanarak yeniden eğitilmesi mümkün olur.

Bu esneklik, yapay sinir ağlarının gerçek dünya uygulamalarında çok kullanışlı kılar. Örneğin, bir nesne tanıma modeli, yeni nesneleri tanımayı öğrenmek için ağırlıklarının güncellenmesine izin vererek genişletilebilir. Ayrıca, finans, tıp, otomasyon ve daha birçok sektörde yapay sinir ağları, değişen şartlara ve veri koşullarına hızla adapte olma yetenekleri sayesinde önemli bir araç haline gelmiştir. Yapay sinir ağları, gelişen dünyanın ihtiyaçlarına cevap vermek için sürekli olarak eğitilip geliştirilebilirler.

- Analiz ve Tasarım Kolaylığı : Yapay sinir ağları, tüm ağlarda aynı notasyon kullanıldığından evrenseldir.
- Nörobiyolojik Benzeşim : İnsan beyninin yapısını esas alarak, mühendislik alanında nörobiyolojik benzerliklerden yararlanmak, daha karmaşık problemleri çözmek için büyük bir potansiyele sahiptir. Bu benzeşimler sayesinde, mühendisler ve bilim insanları, insan beyninin işleyişini taklit eden yapay zeka modelleri ve sistemleri geliştirmek için ilham alabilirler. Bu yaklaşım, daha karmaşık sorunları çözmek ve çeşitli uygulamalarda etkili sonuçlar elde etmek için önemli bir yol sunar.

- Dereceli Bozulma : YSA problem ya da eksik bir bilgi ile karşılaştıklarında direkt bozulmazlar. Hata toleransına sahip olmalarından dereceli şekilde bozulma gerçekleşir.
- Hata Toleransı: Yapay sinir ağlarının paralel işlem yapısı, bilginin ağ genelindeki bağlantılar üzerine dağıtılmasına olanak tanır. Bu durum, belirli bağlantıların ya da nöronların işlevini kaybetmesi halinde bile ağın doğru sonuçlar üretebilmesini sağlar. Başka bir deyişle, bilgi tek bir noktada depolanmaz; çok sayıda hücre arasında dağıtılmıştır. Bu nedenle, sistemin bütünsel işleyişi birkaç bağlantının kaybından ciddi ölçüde etkilenmez.
- Bağlamsal Bilgi İşleme: YSA'nın yapısal özelliği gereği nöronlar birbirine yoğun biçimde bağlıdır. Bu bağlantısallık sayesinde, bağlam bilgisi doğal olarak ağın işleyişine dâhil edilmekte ve sinir ağı çevresel ya da bağlamsal koşulları dikkate alarak öğrenme sürecini gerçekleştirebilmektedir.

Yapay Sinir Ağları (YSA), özellikle tahmin, sınıflandırma, veri ilişkilendirme, veri yorumlama ve veri filtreleme gibi işlemlerde yaygın olarak kullanılmaktadır (Ağyar, MMO Dergi). Bu uygulama alanları kısaca şu şekilde açıklanabilir:

- Tahmin: Yapay sinir ağlarının en temel kullanım alanlarından biridir. Girdi değerlerinden hareketle çıktıların öngörülmesi esasına dayanır. Örneğin, altın ons fiyatının tahmin edilmesi bu kapsamda değerlendirilebilir.
- Veri Filtreleme: Bu amaçla yapılandırılmış ağlar, toplanan veriler içerisinden en anlamlı ve kullanılabilir olanlarını seçerek işleme alır.
- Sınıflandırma: Girdi değerlerinin farklı kategorilere ayrılmasını sağlayarak sistemin daha hızlı ve doğru sonuç üretmesine katkıda bulunur.
- Veri Yorumlama: Önceden eğitilmiş bir ağ, elde ettiği girdileri analiz ederek yeni durumlara ilişkin çıkarımlar yapabilir. Böylece olayların daha kapsamlı bir şekilde yorumlanması mümkün olur.
- Veri İlişkilendirme: YSA, öğrenilen bilgiler arasındaki bağlantıları kurar ve bu sayede eksik verileri tamamlayarak bütünsel bir değerlendirme imkânı sunar.

Yapay Sinir Ağlarının (YSA) güçlü yönlerinin yanında bazı sınırlılıkları ve dezavantajları da bulunmaktadır. Bunlar şu şekilde özetlenebilir:

- Güvenilir ve istikrarlı sonuçlara ulaşabilmek için çok sayıda veriye ihtiyaç duyulmaktadır.


- Giriş ve çıkış değişkenleri arasındaki ikili ilişkilerin doğrudan açıklanabilmesi mümkün değildir. YSA modelleri, içerdiği ilişkileri tam olarak ortaya koymayan bir “kara kutu” özelliği taşır ve ağın çözümü nasıl ürettiği çoğu zaman şeffaf değildir.
- Aşırı uyum (overfitting) durumunda ağ, rastlantısal hatalara duyarlı hale gelebilir.
- Kullanılan algoritmaların bir kısmı kısa sürede yerel çözümlere saplanabilir ve küresel en iyi çözüme ulaşamayabilir.
- Sözel (nümerik olmayan) veriler doğrudan işlenememekte, yalnızca sayısal verilere uygulanabilmektedir.
- Ağın eğitiminin ne zaman tamamlanacağına ilişkin kesin bir yöntem bulunmamaktadır. Kabul edilebilir hata seviyesine ulaşıldığında eğitim sonlandırılır; ancak bu durum, mutlaka en iyi çözümün elde edildiği anlamına gelmez.
- Ağın yapısının (katman sayısı, hücre sayısı, öğrenme oranı gibi) nasıl oluşturulacağına dair kesin kurallar yoktur; bu parametreler çoğunlukla deneyime dayalı olarak belirlenir.
- YSA yapıları donanım tabanlı ve paralel işlemcilere uygun olarak tasarlanmıştır. Günümüzde kullanılan bilgisayarların çoğu seri işlemcilerle çalıştığı için, paralel işlem gerektiren YSA uygulamaları uzun işlem süreleri gerektirebilir.
- YSA, genellikle kabul edilebilir çözümler üretir; ancak mutlak en iyi çözümü garanti etmez. Probleme uygun ağ yapısı doğru belirlenmezse etkin çözümler elde edilemeyebilir.
- Girdi verilerinin genellikle 0–1 aralığında ölçeklenmesi gerekmektedir.
- Sonuçların yorumlanması, klasik duyarlılık analizinde olduğu gibi açık değildir; YSA çıktıları genellikle doğrudan açıklanabilirlikten uzaktır.

Yapay sinir ağı elemanları

Yapay sinir ağı hücresinin yapısı; girdi değerleri (X_1, X_2, X_3), bu girdilere ait ağırlıklar (W_1, W_2, W_3), bilgilerin toplandığı birleştirme fonksiyonu, elde edilen değerlerin işlendiği aktivasyon fonksiyonu ve nihai çıktı (γ) olmak üzere beş ana bölümden oluşmaktadır. Ayrıca, biyolojik sinir sistemindeki öğeler ile yapay sinir sistemindeki karşılıkları Tablo 1’de verilmiştir. Burada, biyolojik yapılar sınıflandırılmış ve her birinin yapay modeldeki karşılığı gösterilmiştir.

Tablo 2. Biyolojik Sinir Sistemi Elemanlar ve Yapay Sinir Sistemindeki Karşılıkları

Biyolojik Sinir Sistemi	Yapay Sinir Sistemi
Nöron	İşlemci Elemanı
Dentrit	Toplama Fonksiyonu
Hücre Gövdesi	Transfer Fonksiyonu
Aksonlar	Yapay Nöron Çıkışı
Sinapslar	Ağırlıklar

**Şekil 3.** Yapay sinir hücresinin elemanları (Haykin,1999).

Şekil 3'te gösterildiği üzere, bir yapay nöron hücresine n adet girdi (X_n) uygulanmaktadır. Bu girdiler, kendilerine ait ağırlık katsayıları ile çarpıldıktan sonra toplanır ve elde edilen değere bir önyargı (bias) eklenir. Böylece net girdi hesaplanır. Net girdi daha sonra aktivasyon fonksiyonundan geçirilerek işlenir ve nihayetinde hücreden bir çıktı değeri üretilir (Öztürk 2018).

YSA işlemlerinin adımları aşağıdaki gibi sıralanabilir:

Adım 1 : Problemin tanımlanması,

Adım 2 : Problem ile ilgili değişkenlerin belirlenmesi,

Adım 3 : Verilerin toplanması,

Adım 4 : Verilerin ön işlemden geçirilmesi,

Adım 5 : Sinir ağının tasarlanması (Ağın yapısı ve öğrenme kuralı seçilmesi),

Adım 6 : Ağın eğitilmesi,

Adım 7 : Ağın geçerliliğine bakılıp hata tespitinin yapılması.

Temel amaç, beklenen değer ve çıktı değeri arasındaki hatayı minimum yapacak ağı kurulmasıdır. Bunun için hatayı ağı yayarak çözüm üretilir.

Yapay sinir ağlarında öğrenme

YSA için girdi ve çıktı arasındaki ilişkiyi en iyi şekilde elde etmede öğrenme algoritmaları kullanılır. Öğrenme algoritması eğitim, geçerlilik ve test gibi aşamaları içerebilmektedir. Öğrenme kuralları, hedef değeri kullanarak ya da herhangi bir hedef değere bağlı olmaksızın çalışabilmektedir. Eğer öğrenme kuralı hedef değere göre çalışırsa öğretmenli öğrenme aksi halde öğretmensiz öğrenme gerçekleşmiş olur. Öğrenme kurallarının en bilinenleri aşağıda yer almaktadır. Öğrenme kurallarında belirlenmesi gereken ağırlıkların hangi formül ile değişeceği yani aşağıda verilen güncelleme denklemindeki ∇w_{ij} ifadesinin belirlenmesidir.

$$w_{ij} = w_{ij} - \nabla w_{ij} \quad (7)$$

Buradaki w_{ij} ; i nöronu ya da girdisinden j nöronuna bulunan bağlantı ağırlıklarını göstermektedir. (Eğrioğlu, syf. 25)

Öğrenme kuralları çalışma prensipleri ve kullanım amaçlarına göre farklılıklar göstermektedir. Bazı konu başlıklarına değinilmiştir.

Hata Düzeltme Öğrenimi: Öğretmenli öğrenme yöntemi olarak kullanılan hata düzeltme öğrenimi sistem çıktısını gerçek çıktı ile karşılaştıran ve hatayı eğitime yönlendirmek için kullanılan bir tekniktir. Geri yayılım algoritması gibi bir algoritma aracılığıyla hata değerleri, ağırlıkların ayarlanması için kullanılır. Sistem çıktısı γ ise ve istenen sistem çıktısının d olduğu biliniyorsa, hata $(e) = d - \gamma$ olarak gösterilebilir. Hata düzeltme öğrenme algoritmaları, her bir eğitim yinelemesinde bu hata sinyalini en aza indirmeye çalışır. Hata düzeltme öğrenimi ile kullanım için en popüler öğrenme algoritması Gradyan İniş algoritmasıdır.

Hebbian Öğrenme Kuralı: Öğretmensiz öğrenme kurallarının en bilinenlerinden biridir ve sinir hücreleri arasındaki bağlantıların güncellenmesi prensibine dayanır. Kurala göre, bir nöron diğerinden sinyal aldığı ve her iki nöron da eşzamanlı olarak etkinleştiğinde, bu iki hücre arasındaki bağ kuvvetlendirilir. Eğer bu koşul sağlanmazsa, bağlantı ağırlıkları zayıflatılır. Bu yaklaşım, yapay sinir ağlarındaki birçok öğrenme kuralının çıkış noktasıdır.

$$\nabla w_{ij} = \beta x_i o_j \quad (8)$$

β : öğrenme parametresi, x_i : nöronun girdisi ve o_j : nöronun çıktısı olmak üzere, Hebbian öğrenme kuralında ağırlık değişimini ifade etmektedir. Bu kurala göre bir nöron başka bir nörondan girdi alıyor ise her iki nöronda aktif ise ağırlık değeri artar.

Korelasyon Öğrenme Kuralı: Hebbian öğrenme kuralına benzeyen öğretmenli öğrenme kuralıdır. d_j hedef değer olmak üzere bu öğrenme kuralında ağırlık değişimi aşağıdaki gibidir:

$$\nabla w_{ij} = \beta x_i d_j \quad (9)$$

Hopfield Kuralı: Hebb kuralının sahip olduğu kurallara benzer ancak tek farkı elemanlarının bağlantı ağırlıklarının sadece işaretlerinin değil büyüklüklerinin de değiştirilmesidir. Öğrenme oranı genellikle 0 ile 1 arasında kullanıcı tarafından belirlenen sabir bir pozitif değerdir. (Genellikle 0.2 ile 0.4 arasında seçilen bir değer olmaktadır.) Ağırlık çalıştırılması sonucu elde edilmesi beklenen değer ile ağırlık girdilerinin ikisi de etkin ya da aktif ise ağırlık değerleri kuvvetlendirilir. Her ikisi de etkin değil yani pasif ise ağırlık değerlerinin zayıflatılması gerekir.

Delta Kuralı (Widrow ve ADALINE), Hopfield kuralı gibi Hebb kuralına benzerlik göstermektedir. Bu yaklaşıma göre, hedeflenen çıktı ile ağdan elde edilen çıktı arasındaki farkı azaltmak amacıyla nöronlar arasındaki bağlantı ağırlıkları sürekli olarak güncellenmektedir. Ağırlık çalıştırıldığında beklenen değer ile üretilen çıktı arasındaki fark minimize edilmeye çalışılır ve bu amaçla bağlantı ağırlıkları yeniden hesaplanır.

Delta kuralının temel mantığı, beklenen çıktı ile gerçekleşen çıktı arasındaki hatanın karelerinin ortalamasını en aza indirmek üzerine kuruludur. Böylelikle bağlantı değerlerinin istenen minimum hata seviyesine yaklaşması sağlanır. Çıktı değeri ise, net girdinin doğrusal veya doğrusal olmayan bir aktivasyon fonksiyonu aracılığıyla işlenmesiyle elde edilmektedir.

$$o_j = f(\text{net}_j) \quad (10)$$

$$E = \frac{1}{2} (o_j - d_j)^2 \quad (11)$$

Öğrenme kuralının temel fikrine dayalı olarak E 'nin ağırlığına göre türevi alınarak ağırlık değişimi elde edilir.

$$\frac{\partial E}{\partial w_{ij}} = (o_j - d_j) \frac{\partial f(\text{net}_j)}{\partial (\text{net}_j)} x_i \quad (12)$$

$$\nabla w_{ij} = \beta (o_j - d_j) \frac{\partial f(\text{net}_j)}{\partial (\text{net}_j)} x_i \quad (13)$$

Ortaya çıkan hataların en son tabakadan başlayarak art arda gelen tabakalar arasında ilk tabakaya doğru dağıtılması temeline dayanan bu işleme ‘geri besleme’ denir. Son tabakadan ilk tabakaya, geriye doğru hata dağıtma işlemi yapılır. Delta öğrenme kuralı aynı zamanda Çevrimdışı öğrenme kuralı içinde yer alır. Bu kurala göre sistem kullanıma başlamadan önce eğitilir ve sonrasında kullanıma alınır. Gerçek uygulama başladığında öğrenme bitmiştir

sisteme yeni bir şeyi öğretmek istersek sistem kullanımdan çıkarılır, öğretme gerçekleştirilir ve tekrar kullanıma alınır.

Kohonen Kuralı, biyolojik sinir hücrelerinin öğrenme mekanizmalarından esinlenerek geliştirilmiştir. Bu kurala göre, sinir hücreleri en yüksek çıktıyı elde etmek için birbirleriyle rekabet ederler. Kazanan hücre, en büyük çıktıyı üreten hücredir ve bağlantı ağırlıklarını günceller. Böylece kazanan hücre, çevresindeki diğer hücelere kıyasla daha güçlü hale gelir.

Bu kuralın uygulanmasında bir hedef değerler dizisine ihtiyaç duyulmaz. Kohonen öğrenme yaklaşımı, çevrim içi (online) öğrenme kuralları arasında yer almakta ve sistemin çalışması sırasında da eğitimin devam etmesine olanak tanımaktadır. Bu özelliği sayesinde, yapay sinir ağı öğretmensiz öğrenme yöntemleri kapsamında kendi kendini eğitme yeteneğine sahiptir (Öztemel 2003).

Yapay sinir ağlarında öğrenme stratejileri

Fausett'e (1994) göre YSA'da öğrenme 'öğretmenli öğrenme' ve 'kendi kendine öğrenme' gibi 2 temel alana ayırırken Öztemel (2003), öğrenme stratejilerini 'öğretmenli, destekleyici, öğretmensiz ve karma öğrenme' olarak 4 grupta incelemiştir. Literatürde bu ayırım genellikle öğretmenli (eğiticili öğrenme), öğretmensiz (eğitici-siz öğrenme) ve destekleyici öğrenme şeklinde yer almıştır.

Eğiticili Öğrenme: Okuma-yazma öğreten bir öğretmen örneğinde olduğu gibi, bu yaklaşımda her girdi için olması gereken çıktı önceden tanımlanarak yapay sinir ağına aktarılır ve bağlantı ağırlıkları buna göre güncellenir. Ağa tanıtılan girdilere karşılık üretilmesi gereken çıktılar sayısal olarak bilindiği için ağ, kendisine verilen girdi-çıktı çiftlerini adeta "öğrenir". Bu süreçte en önemli unsur, beklenen çıktılar ile ağın ürettiği çıktılar arasındaki farkın kabul edilebilir hata düzeyine indirgenmesidir. Dolayısıyla hata minimizasyonu bu öğrenme türünün temel ilkesini oluşturur.

Destekleyici Öğrenme: Bu yöntemde doğru-yanlış ya da başarılı-başarısız gibi ikili mantık esas alınır. Bir öğretici mekanizma mevcut olmakla birlikte, eğiticili öğrenmeden farklı olarak her girdiye karşılık gelmesi gereken çıktı önceden verilmez. Ağdan beklenen, girdilere uygun çıktıyı kendisinin üretmesidir. Sonrasında, üretilen çıktının doğru olup olmadığını değerlendiren bir kontrol mekanizması vardır. Eğer çıktı doğru kabul edilirse öğrenme gerçekleşmiş olur; yanlış olması durumunda ise süreç, doğru aralıklara karşılık gelen çıktı elde edilene kadar devam eder.

Eğitici-siz Öğrenme: Bu öğrenme modelinde herhangi bir öğretici bulunmaz. Ağ, kendisine verilen verilerin yapısından veya içlerindeki korelasyonlardan yararlanarak

örüntüleri belirler ve kategorize eder. Üretilen çıktılar için ayrı bir geri bildirim mekanizması mevcut değildir. Bu nedenle, yöntemin uygulanmasında çıktıları yorumlama ve uygun şekilde değerlendirme sorumluluğu sistemi kullanan kişiye aittir.

Tablo 3.Öğrenme Algoritmaları ve Kullanım Alanları Tablosu

	Öğrenme Kuralı	Ağın Mimarisi	Öğrenme Algoritması	Kullanıldığı Yerler
Öğretmenli	Hata Düzeltme	Tek ya da Çok Katmanlı	Perseptron	Örüntü Tanıma
			Geriye yayılım	
	Boltzman	Geri Dönüşlü	Adaline ve Mandaline	Tahmin Kontrol
			Boltzman öğrenmesi	Örüntülü Sınıflandırma
	Hebbian	Çok katmanlı ileri beslemeli	Lineer Diskriminant	Veri Analizi
				Örüntü Sınıflandırma
Öğretmensiz	Rekabetli	Rekabetli	Vektör kuantlama öğrenmesi	Örüntülü Sınıflandırma
				Sınıflandırma
	Hata Düzeltme	Çok katmanlı ileri beslemeli	ART Haritalaması	Veri Analizi
			Sammon projeksiyonu	Veri Analizi
	Hebbian	İleri beslemeli rekabetçi	Principal Component Analizi	Veri Analizi
				Veri Sıkıştırma
Karma	Hata Düzeltme ve Rekabetli	Hopfield Ağı	Associative Memory Öğrenmesi	Associative Memory
	Rekabetli	Rekabetli	Vektör kuantlama	Sınıflandırma
				Veri Sıkıştırma
	Hata Düzeltme ve Rekabetli	Kohenen SOM	Kohenen SOM	Sınıflandırma
				Veri Analizi
Karma	Hata Düzeltme ve Rekabetli	ART ağı	ART1, ART2	Sınıflandırma
				Sınıflandırma
	Hata Düzeltme ve Rekabetli	Radyal Rabanlı	Radyan Tabanlı Öğrenme	Örüntü Tarama
				Fonksiyon Yaklaşımı
				Tahmin Kontrol

ARAŞTIRMA BULGULARI VE TARTIŞMA

Bu çalışmada, firmaların geleceğe yönelik stratejilerini belirlemede kritik bir rol oynayan insan kaynakları yönetiminin temel unsurlarından biri olan personel planlama sürecinin incelenmesi amaçlanmıştır.

Şirketler ve kurumlar; pazarlama, finans, üretim planlama, insan kaynakları, kalite kontrol ve bakım planlama gibi çeşitli alanlarda geleceğe yönelik öngörülerde bulunmayı hedeflemektedir. Tahmin yöntemleriyle elde edilen veriler doğrultusunda yöneticiler, gelecekte oluşabilecek durumlara uygun yönetim stratejileri geliştirmektedir.

Bu bölümde, yetkili bir otomotiv bayisinin servis bölümünde çalışan mavi yakalı personelin geçmiş dönem verileri zaman serisi analizi ile değerlendirilmiş, uygun modeller oluşturularak geleceğe yönelik tahminler yapılmıştır.

Çalışmada öncelikle, ele alınan zaman serilerinin durağanlığı Geliştirilmiş Dickey-Fuller (ADF) ve Phillips-Perron (PP) birim kök testleri ile analiz edilmiştir. İkinci aşamada, değişkenler arasında uzun vadeli bir ilişki olup olmadığını belirlemek amacıyla eşbütünleşme analizi gerçekleştirilmiştir. Son olarak, değişkenler arasındaki nedensellik ilişkisini tespit etmek için Blok Granger nedensellik testi uygulanmış ve VAR modelleri incelenmiştir.

Son aşama da ise girdi olan zaman serileri verileri oluşturulan yapay sinir ağları kodu ile matlab programında işlenerek ve yapay sinir ağları yardımıyla firmanın gelecek dönemlerde ihtiyaç duyacağı personel sayısının tespitinde kullanılmıştır.

Uygulama adımları şu şekildedir;

Adım 1: Uygulama adımının ilk basamağında geçmiş 60 aylık dönemlere ait veriler toplanmıştır. Tablo 4’te dönem verileri başlıkları ile belirtilmiştir.

Tablo 4. Geçmiş Dönem Verileri

Dönem	Toplam İş Yüğü	Ek İş Yüğü	Kurumsal Kapasite	Planlama Kapasitesi	Performans Değeri	Norm Kadro
1	35.114	0	180	1	1	19.508
2	41.216	0	180	0.949	1.700	14.193
3	16.784	0	180	1	2.500	3.730
4	17.933	0	180	1	0.262	9.963
5	0	3.467	180	1	1	1.926

Tablo 4. (devamı)

6	57.413	0	180	1	3.305	9.651
7	17.24	0	180	1	4.521	2.119
8	0	0	180	1	1	0
9	21.073	0	180	1	1.791	6.537
10	11.317	0	180	1	1	6.287
11	24.347	0	180	1	2.458	5.503
12	34.055	0	180	0.991	7.238	2.638
13	20.707	0	180	1	7.140	1.611
14	24.454	0	180	0.996	2.008	6.793
15	64.936	0	180	1	14.259	2.530
16	41.048	0	180	1	2.617	8.714
17	25.217	0	180	1	4.111	3.408
18	11.367	0	120	0.64416	13.695	1.074
19	0	0	60	0.5	1	0
20	39.895	0	120	0.66	23.467	2.147
21	0	0	120	0.66	1	0
22	33.753	0	120	0.66	8.808	4.838
23	38.614	0	120	0.66	3.936	12.387
24	21.476	0	120	0.66	2.700	10.043
25	34.603	0	120	0.5907	4.329	11.277
26	25.015	0	120	0.6303	4.300	7.691
27	0	22.593	120	0.65076	1	28.932
28	0	22.411	120	0.66	1	28.297
29	31.594	8.923	120	0.59994	3.500	16.079
30	23.502	2.840	120	0.295	2.400	31.005
31	0	8.122	120	0.61182	1	11.063
32	52.015	17.974	180	0.997	1	39.00
33	11.435	22.432	180	1	1.500	12.543
34	44.542	0	180	0.993	2.500	9.968
35	31.455	0	180	0.962	1.809	10.042
36	40.509	2.600	180	1	1.000	23.949
37	29.19	26.226	180	1	0.750	41.049
38	11.1	72.41	180	1	1.700	27.291
39	38.412	17.420	180	0.978	0,845	37.533
40	52.412	11.196	180	0.978	0.824	43.850
41	31.177	56.874	180	1	1.000	48.917
42	19.927	91.211	180	0.984	1.200	42.914
43	52.571	50.651	180	1	1.500	38.230

Tablo 4. (devamı)

44	102.928	0	180	0.994	1.236	46.543
45	0	53.394	180	0.994	1	29.842
46	52.432	7.449	180	0.987	0.782	43.102
47	129.673	46.946	180	0.99	1.567	38.164
48	0	60.242	180	0.997	1	33.568
49	60.140	6.137	180	0.99	0.929	40.035
50	47.35	23.68	180	0.997	1.875	21.109
51	110.438	0	180	0.984	1.46	42.707
52	51.21	13.46	180	0.984	1.200	30.427
53	74.825	0	180	0.986	1	42.160
54	0	54.61	180	0.981	1	30.926
55	161.896	0	180	0.985	2.559	35.683
56	0	58.147	180	1	1	32.304
57	142.795	0	180	0.984	1.635	29.119
58	338.896	0	180	1.000	5.120	36.773
59	206.48	0	180	0.989	2.965	39.119
60	176.357	0	180	0.967	2.140	47.346

Tablo da yer alan değişkenlerin açıklamaları;

Toplam İş Yüğü : Çalışanın mesai süresince yüklenen iş miktarı,

Ek İş Yüğü : Çalışan normal yüklenen iş miktarına ilave edilen iş miktarını,

Kurumsal Kapasite : Şirketin belirli zaman periyodundaki kapasitesini,

Planlama Kapasitesi : $(1 - \text{Devamsızlık Oranı}) * (1 - \text{Ara Verme Oranı})$,


Devamsızlık Oranı : Mevcut çalışanların planlama evresindeki mesai devamsızlığını,

Ara Verme Oranı : Çalışan harici hizmette meydana gelen duraksamaları,

Performans : Çalışanın ele alınan periyottaki performans tahminini,

Norm Kadro : Toplam iş yükü ve ek iş yükü toplamının kurumsal kapasite, planlama kapasitesi ve performans değerlerinin çarpımının oranını ifade etmektedir.

Adım 2: Geçmiş dönem verileri Eviews programı kullanılarak durağanlık analizi çalışması gerçekleştirilmiştir. Durağanlık analizini ilk olarak grafik yöntemi ile yorumlanmıştır. Serinin trend, mevsim etkisi ve devresel/konjektürel etkilerinin olup olmadığını anlamak için çoklu grafikler ile tüm değerlerin ayrı ayrı orijinal grafikleri Şekil 4'deki gibi elde edilmiştir.



Şekil 4. Verilere ait çoklu grafik çizimleri

Grafikler incelediğinde, serilerin belli bir ortalama etrafında dağılım göstermediklerini gözlemlenmektedir. Belli bir ortalamanın etrafında eğilim gösteren grafikler, durağan yapıya sahip olduğunun yorumunu gerçekleştirilmektedir. Davranış olarak grafikler yorumlandığında ise nonlineer – durağan olmayan davranış gösterdiğini düşünülmektedir.

Adım 3 : Geçmiş dönem verilerinin yöntem serilerine ait tamamlayıcı istatistikleri Çizelge 2’de hesaplanmıştır.

Tablo 5. Tamamlayıcı İstatistikler

	Toplam İş Yüğü	Ek İş Yüğü	Kurumsal Kapasite	Performans Değerleri	Planlama Kapasitesi	Norm Kadro
Ortalama	46.38063	12.69025	165.0000	2.902350	0.901995	21.06928
Medyan	31.52450	0.000000	180.0000	1.601000	0.990500	17.79350
Maksimum	338.8960	91.21100	180.0000	23.46700	1.000000	48.91700
Minimum	0.000000	0.000000	60.00000	0.262000	0.295000	0.000000
Standart Sapma	58.87893	22.05948	28.43369	3.866484	0.171558	15.99888
Çarpıklık	2.791366	1.835576	-1.626.098	3.490040	-1.603.651	0.190488
Basıklık	12.42957	5.402998	4.672481	16.70465	4.464552	1.504584
Jarque-Bera	300.2093	48.12938	33.43495	591.3473	31.07926	5.953528
Probability	0.000000	0.000000	0.000000	0.000000	0.000000	0.050957
Toplam	2782.838	761.4150	9900.000	174.1410	54.11968	1264.157
Toplam Std. Sapma	204537.0	28710.62	47700.00	871.3870	1.736492	15101.88
Gözlem	60	60	60	59	60	60

Jarque-Bera testi, bir veri setinin normal dağılıma sahip olup olmadığını değerlendirmek için kullanılan bir testtir. Test, veri setinin çarpıklık (skewness) ve basıklık (kurtosis) özelliklerini kullanarak normal dağılıma yakınlığı kontrol eder. Bu testin hipotezleri şunlardır:

- H_0 (Null Hipotezi): Veri seti normal dağılıma sahiptir. (Çarpıklık ve basıklık değerleri normal dağılım ile uyumludur.)
- H_1 (Alternatif Hipotez): Veri seti normal dağılıma sahip değildir. (Çarpıklık ve/veya basıklık değerleri normal dağılımdan sapmaktadır.)

Tamamlayıcı istatistiklere ait tabloda; ortalama değerler , max. min değerler , standart sapma değerleri, çarpıklık-basıklık değerleri görüntülenmektedir. Planlama kapasitesi ve kurumsal kapasite hariç diğer veriler pozitif asimetriye sahiptir. Serilerin dağılımları tabloda belirtildiği üzere tanımlanmıştır.

Test sonuçlarına göre, p-value genellikle belirli bir anlamlılık düzeyinde (örneğin, 0.05) karar vermek için kullanılır. Test sonucunda elde edilen p-değeri, belirlenen anlamlılık seviyesine (genellikle %5) göre değerlendirilir.

- $p < 0.05$ ise: H_0 reddedilir, yani veri setinin normal dağılıma uymadığı sonucuna varılır.
- $p \geq 0.05$ ise: H_0 kabul edilir, yani veri setinin normal dağılıma uygun olduğu söylenebilir.

Çarpıklık: Çarpıklık (skewness) değerleri, değişkenlerin dağılımının simetrik olup olmadığını ve hangi yöne eğilim gösterdiğini anlamamıza yardımcı olur.

- Ek iş yükü, norm kadro, planlama kapasitesi ve toplam iş yükü değişkenleri için pozitif çarpıklık (right-skewed) gözlemlenmiştir. Bu, dağılımın sağ kuyruğunun daha uzun olduğunu ve verilerin büyük bir kısmının daha düşük değerlere yoğunlaştığını gösterir.
- Kurumsal kapasite ve performans değeri değişkenleri için negatif çarpıklık (left-skewed) belirlenmiştir. Bu durum, dağılımın sol kuyruğunun daha uzun olduğunu ve verilerin büyük bir kısmının daha yüksek değerlere toplandığını ifade eder.

Basıklık: Pozitif basıklık (leptokurtic dağılım), dağılımın standart normal dağılıma kıyasla daha keskin bir zirveye ve daha ağır kuyruklara sahip olduğunu gösterir. Bu durum, verilerin ortalamaya yakın bölgede daha yoğunlaştığını ancak uç değerlerin de daha fazla görüldüğünü ifade eder. Başka bir deyişle, dağılımın merkezi daha sivridir ve uçlarda daha fazla değer bulunur, bu da ekstrem değerlerin görülme olasılığının arttığını gösterir.

Jarque-Bera Testi: Düşük olasılık değerleri (0'a yakın), verilerin normal dağılım izlediği hipotezinin reddedildiğini göstermektedir. Tüm değişkenlerin düşük p değerleri vardır, bu da normal dağılıma sahip olmadığı göstermektedir.

Bu istatistikler, her değişken için merkezi eğilim, değişkenlik, çarpıklık, basıklık, normallik testleri ve dağılımın diğer özelliklerinin bir özetini sağlar.

Adım 4: Durağanlığın belirlenmesinde kullanılan ikinci yöntem korelogram (cologram) analizi veya otokorelasyon değerleridir. Korelogram testi, veri setine uygulanarak zaman serisinin durağan olup olmadığına dair yorum yapılmasına olanak tanır. Bu çalışmada, zaman serisi verilerinin korelogram değerleri incelenerek otokorelasyon yapısı analiz edilmiştir. Korelogram grafiğinde, otokorelasyon katsayılarının zaman serilerinde nasıl değiştiği gözlemlenerek serinin durağanlık durumu değerlendirilmiştir.

Toplam iş yükü, ek iş yükü, kurumsal kapasite, performans değeri, planlama kapasitesi ve norm kadro değişkenleri sırasıyla incelendiğinde, otokorelasyon fonksiyonu (ACF) ve kısmi otokorelasyon fonksiyonu (PACF) değerleri ilgili tablolarda sunulmuştur. Ayrıca, Q istatistikleri ve bunlara ait olasılık (prob) değerleri de tabloda yer almaktadır.

Bir zaman serisinin durağan olup olmadığını belirlemek için otokorelasyon fonksiyonunun seyri dikkate alınmaktadır. Eğer otokorelasyon fonksiyon değerleri başlangıçta yüksek olup zamanla yavaşça azalıyorsa veya belirli bir seviyede sabit kalıyorsa, bu durum serinin durağan olmadığına işaret eder.


Bu testte kullanılan hipotezler şu şekildedir:

- H_0 (Temel Hipotez): $R_0(O) = 0 \rightarrow$ Seri durağandır.
- H_1 (Alternatif Hipotez): $R_0 \neq 0 \rightarrow$ Seri durağan değildir.

Q istatistiklerinden elde edilen prob değerleri temel hipotezin kabul edilip edilmediğini belirlemede kullanılır. Eğer prob değerleri 0'a yakın çıkarsa, H_0 reddedilir ve serinin durağan olmadığı sonucuna varılır.

Dolayısıyla korelogram incelemesi sonucunda, kurumsal kapasite hariç tüm değişkenler için temel hipotez reddedilmiştir. Bu da, kurumsal kapasite dışındaki tüm serilerin durağan olmadığı ve otokorelasyon içerdiği anlamına gelmektedir.

Correlogram of TOPLAMISYUKU




Şekil 5. Toplam iş yüküne ait kologram değerleri

Toplam iş yüküne ait kologram testine göre, gözlemler şu şekildedir:

- **Otokorelasyon (AC) ve Kısmi Otokorelasyon (PAC) Grafikleri:** AC ve PAC grafiklerindeki değerlerin genellikle düşük olduğu görülmektedir. Bu durum, zaman serisinin birim kök olmadığını ve zayıf bir bağımsızlık yapısına sahip olduğunu göstermektedir.
- **Q-Statistik ve p-değerleri:** Q-Statistik değerleri yüksek ve p-değerleri düşük. Bu durum, zaman serisinin birim kök olmadığı (non-stationary) ancak zayıf bir bağımsızlık yapısına sahip olduğu anlamına gelir.

Sonuç olarak, zaman serisinin birim kök olmadığı, ancak zayıf bir bağımsızlık yapısına sahip olduğu söylenebilir. Durağanlık açısından yeterli olmayabilir, bu durumda daha fazla analiz ve belki de farklı bir modelleme yaklaşımı gerekebilir.

Correlogram of EKISYUKU




Şekil 6. Ek iş yüküne ait kologram değerleri

Ek iş yüküne ait kologram testine dayanarak şu gözlemleri yapabiliriz:

- Otokorelasyon (AC) ve Kısmi Otokorelasyon (PAC) Grafikleri: AC ve PAC grafiklerindeki değerlerin genellikle düşük olduğu görülmektedir. Bu durum, zaman serisinin birim kök olmadığını ve zayıf bir bağımsızlık yapısına sahip olduğunu göstermektedir.
- Q-Statistik ve p-değerleri: Q-Statistik değerleri yüksek ve p-değerleri düşük. Bu durum, zaman serisinin birim kök olmadığı (non-stationary) ancak zayıf bir bağımsızlık yapısına sahip olduğu anlamına gelir.

Durağanlık Yorumu: Bulgulara dayanarak, zaman serisinin durağan olmadığını söylenebilir. AC ve PAC grafiklerinde düşük değerler olmasına rağmen, Q-Statistik değerleri yüksek çıkmaktadır, bu da serinin bağımsızlık yapısının zayıf olduğunu göstermektedir. Sonuç olarak, bu zaman serisi için durağanlık özelliklerinin sağlanmadığı ve modelleme sürecinde dikkate alınması gereken bir bağımsızlık yapısının olduğu söylenebilir.


Correlogram of KURUMSALKAPASITE



Şekil 7. Kurumsal kapasiteye ait kologram değerleri

Kurumsal kapasite kologram testi sonuçlarına dayanarak, otokorelasyon (AC) ve kısmi otokorelasyon (PAC) grafikleri, zaman serisinin birim kök olmadığına (non-stationary) dair güçlü bir gösterge sunmaktadır. AC ve PAC değerlerindeki azalma, genellikle durağan bir zaman serisine işaret etmektedir. Ayrıca, Q-Statistik değerleri düşük ve p-değerleri çok düşük, bu da zaman serisinin birim kök olmadığı yani durağan olduğu konusunda güçlü bir kanıt sunmaktadır.

Correlogram of PERFORMANSDEGERI



Şekil 8. Performans değerine ait kologram değerleri


Performans değerine ait kologram testine dayanarak şu gözlemleri yapabiliriz:

- Otokorelasyon (AC) ve Kısmi Otokorelasyon (PAC) Grafikleri: AC ve PAC grafiklerinde, birim gecikme sonrasında yüksek bir otokorelasyon değeri (0.4986) görülmektedir. Bu, zaman serisinin durağan olmadığını ve birim kök içerdiğini düşündürmektedir.
- Q-Statistik ve p-değerleri: Q-Statistik değeri oldukça yüksek (15.74) ve p-değeri çok düşük (0.00038) çıkıyor. Bu, zaman serisinin durağan olmadığını ve birim kök içerdiğini gösteren güçlü bir belirtidir.

Durağanlık Yorumu: Bulgulara dayanarak, zaman serisinin durağan olmadığını ve birim kök içerdiğini söyleyebiliriz. Yüksek otokorelasyon değerleri ve Q-Statistik değeri, serinin bağımsızlık yapısının zayıf olduğunu ve birim kök içerdiğini gösteriyor. Sonuç olarak, bu

zaman serisi için durağanlık özelliklerinin sağlanmadığı ve modelleme sürecinde birim kök içeren bir dönüşüm veya fark alma işlemi gibi yöntemlere başvurulmalıdır.

Correlogram of PLANLAMAKAPASITESI




Şekil 9. Planlama kapasitesine ait kologram değerleri

Kısmi otokorelasyon grafiğinize dayanarak seri birim kök testi (kologram testi) sonuçlarına göre;

- İlk gecikme sonrasında otokorelasyon katsayısı 0.8416'dır ve bu değer oldukça yüksektir.
- İkinci gecikme sonrasında otokorelasyon katsayısı 0.6473'tür.
- Üçüncü gecikme sonrasında otokorelasyon katsayısı 0.5653'tür.

Bu yüksek otokorelasyon katsayıları, serinin birim kök içermediğini ve bu nedenle serinin durağan olmadığını gösterir. Birim kök, bir zaman serisinin durağan olmadığını ifade eder. Bu durumda, serinin birinci farkı alınarak (yani, serinin kendisi ile bir gecikmesi arasındaki fark) bir durağan zaman serisi elde edilebilir.

Correlogram of NORMKADRO



Şekil 10. Norm kadroya ait kologram değerleri

Kologram testi sonuçlarına göre:

- İlk gecikme sonrasında otokorelasyon katsayısı 0.7691'dir.
- İkinci gecikme sonrasında otokorelasyon katsayısı 0.7953'tür.
- Üçüncü gecikme sonrasında otokorelasyon katsayısı 0.6962'dir.
- Dördüncü gecikme sonrasında otokorelasyon katsayısı 0.6877'dir.
- Beşinci gecikme sonrasında otokorelasyon katsayısı 0.6854'tür.

Kologram testi sonuçlarına göre, zaman serisinin otokorelasyon katsayılarının yüksek olduğu görülmektedir. Bu durum, zaman serisinin birim kök içerdiğini (non-stationary) ve durağan olmadığını göstermektedir.

Adım 5 : Geliştirilmiş Dickey Fuller (ADF) ve Phillips Peron birim kök testi ile serinin durağanlığı araştırılmıştır. ADF yönetiminde birim kök düzeyde serinin durumunu, gecikme serisini Schwarz bilgi kriterine ve sabit trend de davranışa göre tahminleme gerçekleştirilmiştir.

Augmented Dickey-Fuller Unit Root Test on EKISYUKU

Null Hypothesis: EKISYUKU has a unit root Exogenous: Constant, Linear Trend Lag Length: 0 (Automatic - based on SIC, maxlag=10)				
			t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic			-6.096554	0.0000
Test critical values:	1% level		-4.121303	
	5% level		-3.487845	
	10% level		-3.172314	
*MacKinnon (1996) one-sided p-values.				
Augmented Dickey-Fuller Test Equation Dependent Variable: D(EKISYUKU) Method: Least Squares Date: 12/03/23 Time: 15:43 Sample (adjusted): 2018M12 2023M10 Included observations: 59 after adjustments				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
EKISYUKU(-1)	-0.815857	0.133823	-6.096554	0.0000
C	-2.212514	5.370831	-0.411950	0.6819
@TREND("2018M11")	0.424714	0.172856	2.457044	0.0171
R-squared	0.399468	Mean dependent var		0.000000
Adjusted R-squared	0.378020	S.D. dependent var		25.67089
S.E. of regression	20.24552	Akaike info criterion		8.903253
Sum squared resid	22953.34	Schwarz criterion		9.008891
Log likelihood	-259.6460	Hannan-Quinn criter.		8.944490
F-statistic	18.62532	Durbin-Watson stat		2.016882
Prob(F-statistic)	0.000001			

Şekil 11. Ek iş yükünün ADF yöntemine göre birim kök test sonuçları

Ek iş yükünün ADF testine göre ;

- H_0 : Ek iş yükü birim köke sahiptir. Yani seri durağan değildir.
- H_1 : Ek iş yükü birim köke sahip değildir. Yani seri durağandır.

ADF ye ait test istatistiği kriterlerini %1, %5 ve %10 değerlerine göre verilmiştir. Kritik değerler ile tablo değerleri bu değer ile kıyaslanmaktadır.

Birim kök testi olan Augmented Dickey-Fuller (ADF) testi EKISYUKU değişkeni üzerinde yapılmış ve aşağıdaki sonuçlar elde edilmiştir:

- Test İstatistiği: -6.0966
- P değeri: 1,938e-05 (sıfıra çok yakın)
- %1, %5 ve %10 seviyelerindeki Kritik Değerler: -4,1213, -3,4878, -3,1723

P değeri anlamlılık seviyesinden düşüktür (genellikle 0,05), bu da birim kökün varlığına ilişkin H_0 hipotezini reddedebileceğinizi gösterir. Dolayısıyla veriler ek iş yükünün durağan olduğuna veya birim köke sahip olmadığına dair kanıt sunmaktadır.

ADF testi regresyon denklemi aşağıdaki gibidir:

$$\Delta Ek \text{ iş yükü} = -0.8159 * Ek \text{ iş yükü}(-1) - 2.2125 * C + 0,4247 * Trend ('2018M11')$$

Burada;

- $\Delta Ek \text{ iş yükü}$ farkı EKISYUKU değişkenini temsil eder.
- $Ek \text{ iş yükü}(-1)$ ek iş yükünün gecikmeli değeridir.
- C sabit terimdir.
- $Trend ('2018 M 11')$ Kasım 2018'den itibaren başlayan doğrusal trenddir.

Ayarlanmış R^2 değeri 0,3780 olup, modelin farklılaşan ek iş yükü serisindeki varyansın önemli bir kısmını açıkladığını göstermektedir. 2,0169'luk Durbin-Watson istatistiği, artıklarda bir miktar pozitif otokorelasyon olabileceğini düşündürmektedir.

Sonuç olarak, ADF testi sonuçlarına dayanarak, H_0 hipotezinin %1, %5 ve %10 temel hipotez ret edildiğini yani ek iş yükü serisinin birim kök içermediğini yani durağan olduğu belirtilebilir.

Augmented Dickey-Fuller Unit Root Test on KURUMSALKAPASITE

Null Hypothesis: KURUMSALKAPASITE has a unit root Exogenous: Constant, Linear Trend Lag Length: 0 (Automatic - based on SIC, maxlag=10)				
			t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic			-2.280620	0.4375
Test critical values:	1% level		-4.121303	
	5% level		-3.487845	
	10% level		-3.172314	
*MacKinnon (1996) one-sided p-values.				
Augmented Dickey-Fuller Test Equation Dependent Variable: D(KURUMSALKAPASITE) Method: Least Squares Date: 12/03/23 Time: 16:01 Sample (adjusted): 2018M12 2023M10 Included observations: 59 after adjustments				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
KURUMSALKAPASITE(-1	-0.163120	0.071525	-2.280620	0.0264
C	23.78523	11.83182	2.010277	0.0492
@TREND("2018M11")	0.102938	0.119137	0.864036	0.3913
R-squared	0.087994	Mean dependent var		0.000000
Adjusted R-squared	0.055422	S.D. dependent var		15.75677
S.E. of regression	15.31391	Akaike info criterion		8.344910
Sum squared resid	13132.89	Schwarz criterion		8.450547
Log likelihood	-243.1748	Hannan-Quinn criter.		8.386146
F-statistic	2.701546	Durbin-Watson stat		1.864472
Prob(F-statistic)	0.075847			

Şekil 12. Kurumsal kapasitenin ADF yöntemine göre birim kök test sonuçları

Artırılmış Dickey-Fuller (ADF) testi kurumsal kapasite değişkeni üzerinde aşağıdaki sonuçlarla gerçekleştirilmiştir:

- Test İstatistiği: -2.2806
- P değeri: 0,4375
- %1, %5 ve %10 seviyelerindeki Kritik Değerler: -4,1213, -3,4878, -3,1723

P değeri 0,4375 olup, 0,05 anlamlılık düzeyinden yüksektir. Bu nedenle ADF testine göre kurumsal kapasitenin birim köke sahip olduğu hipotezi reddedilemez. Veriler serinin durağan olduğu sonucuna varmak için yeterli kanıt sağlamamaktadır.

ADF testi regresyon denklemi aşağıdaki gibidir:

Δ Kurumsal kapasite

$$= -0.1631 * \text{Kurumsal kapasite} (-1) + 23.7852 * C + 0.1029 * \text{Trend ('2018M11')}$$

Burada;

- Δ Kurumsal kapasite farkı KURUMSALKAPASITE değişkenini temsil eder.
- Kurumsal kapasite (-1) kurumsal kapasitenin gecikmeli değeridir.
- C sabit terimdir.
- Trend ('2018 M 11') Kasım 2018'den itibaren başlayan doğrusal trenddir.

Ayarlanmış R^2 değeri 0,0554 olup, modelin farklılaşan kurumsala kapasite serisindeki varyansın önemli bir kısmını açıklamadığını göstermektedir. 1,8645'lik Durbin-Watson istatistiği, artıklarda bir miktar pozitif otokorelasyon olduğunu göstermektedir.

Sonuç olarak, ADF testinden elde edilen kanıtlar kurumsal kapasitenin birim köke sahip olabileceğini ve serinin durağan olmayabileceğini göstermektedir.

Augmented Dickey-Fuller Unit Root Test on NORMKADRO

Null Hypothesis: NORMKADRO has a unit root Exogenous: Constant, Linear Trend Lag Length: 1 (Automatic - based on SIC, maxlag=10)				
			t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic			-3.232567	0.0883
Test critical values:	1% level		-4.124265	
	5% level		-3.489228	
	10% level		-3.173114	
*MacKinnon (1996) one-sided p-values.				
Augmented Dickey-Fuller Test Equation Dependent Variable: D(NORMKADRO) Method: Least Squares Date: 12/03/23 Time: 16:02 Sample (adjusted): 2019M01 2023M10 Included observations: 58 after adjustments				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
NORMKADRO(-1)	-0.431120	0.133368	-3.232567	0.0021
D(NORMKADRO(-1))	-0.397539	0.117805	-3.374551	0.0014
C	-1.936411	2.175106	-0.890261	0.3773
@TREND("2018M11")	0.378430	0.117895	3.209886	0.0022
R-squared	0.462710	Mean dependent var		0.571603
Adjusted R-squared	0.432860	S.D. dependent var		10.45751
S.E. of regression	7.875414	Akaike info criterion		7.031841
Sum squared resid	3349.195	Schwarz criterion		7.173940
Log likelihood	-199.9234	Hannan-Quinn criter.		7.087191
F-statistic	15.50146	Durbin-Watson stat		1.947840
Prob(F-statistic)	0.000000			

Şekil 13. Norm kadronun ADF yöntemine göre birim kök test sonuçları

Artırılmış Dickey-Fuller (ADF) testi, norm kadro değişkeni üzerinde aşağıdaki sonuçlarla gerçekleştirilmiştir:

- Test İstatistiği: -3.2326
- P değeri: 0,0883
- %1, %5 ve %10 seviyelerindeki Kritik Değerler: -4,1243, -3,4892, -3,1731

P değeri 0,0883 olup, 0,05 anlamlılık seviyesinin biraz üzerindedir. Bu nedenle, ADF testine dayanarak, norm kadronun geleneksel anlamlılık düzeyinde birim köke sahip olduğu hipotezini reddedilemez. Veriler serinin durağan olduğu sonucuna varmak için güçlü bir kanıt sunmamaktadır.

Ayarlanmış R^2 değeri 0,4329 olup, modelin farklılaşan norm kadro serisindeki varyansın orta düzeyde bir kısmını açıkladığını göstermektedir. 1,9478'lik Durbin-Watson istatistiği, artıklarda bir miktar pozitif otokorelasyon olduğunu göstermektedir.

Sonuç olarak, ADF testinden elde edilen kanıt, norm kadrodaki birim kökün sıfır hipotezini reddedecek kadar güçlü değildir; bu da serinin durağan olmayabileceğini düşündürmektedir.

Augmented Dickey-Fuller Unit Root Test on PERFORMANSDEGERI

Null Hypothesis: PERFORMANSDEGERI has a unit root Exogenous: Constant, Linear Trend Lag Length: 2 (Automatic - based on SIC, maxlag=10)				
			t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic			-2.026537	0.5736
Test critical values:	1% level		-4.140858	
	5% level		-3.496960	
	10% level		-3.177579	
*MacKinnon (1996) one-sided p-values.				
Augmented Dickey-Fuller Test Equation Dependent Variable: D(PERFORMANSDEGERI) Method: Least Squares Date: 12/03/23 Time: 16:03 Sample (adjusted): 2019M02 2023M10 Included observations: 53 after adjustments				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
PERFORMANSDEGERI(-1)	-0.390110	0.192501	-2.026537	0.0483
D(PERFORMANSDEGERI(-1	-0.859013	0.182632	-4.703528	0.0000
D(PERFORMANSDEGERI(-2	-0.387776	0.132442	-2.927880	0.0052
C	2.132336	1.331434	1.601533	0.1158
@TREND("2018M11")	-0.028586	0.029300	-0.975610	0.3341
R-squared	0.704969	Mean dependent var		0.002642
Adjusted R-squared	0.680383	S.D. dependent var		5.826618
S.E. of regression	3.294059	Akaike info criterion		5.311707
Sum squared resid	520.8397	Schwarz criterion		5.497583
Log likelihood	-135.7602	Hannan-Quinn criter.		5.383186
F-statistic	28.67370	Durbin-Watson stat		1.898605
Prob(F-statistic)	0.000000			

Şekil 14. Performans değerinin ADF yöntemine göre birim kök test sonuçları

ADF test istatistiği -2,0265'tir ve ilgili p değeri 0,5736'dır; bu, birim kökün H_0 hipotezini reddetmek için yeterli kanıtın olmadığını gösterir.

- Regresyon denklemindeki katsayılar, performans değerinin farklı değerleri ile gecikmeleri arasındaki ilişki hakkında bilgi sağlar.

- Model uyum istatistikleri (R-kare, düzeltilmiş R-kare), modelin varyansın önemli bir bölümünü açıkladığını göstermektedir.

Birim kök hipotezinin reddedilmemesi performans değerinin durağan olmayabileceğini göstermektedir.

Augmented Dickey-Fuller Unit Root Test on PLANLAMAKAPASITESI

Null Hypothesis: PLANLAMAKAPASITESI has a unit root Exogenous: Constant, Linear Trend Lag Length: 2 (Automatic - based on SIC, maxlag=10)				
			t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic			-1.874473	0.6546
Test critical values:	1% level		-4.127338	
	5% level		-3.490662	
	10% level		-3.173943	
*MacKinnon (1996) one-sided p-values.				
Augmented Dickey-Fuller Test Equation Dependent Variable: D(PPLANLAMAKAPASITESI) Method: Least Squares Date: 12/03/23 Time: 16:18 Sample (adjusted): 2019M02 2023M10 Included observations: 57 after adjustments				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
PLANLAMAKAPASITESI(-1)	-0.142017	0.075764	-1.874473	0.0665
D(PPLANLAMAKAPASITESI(-1	0.234713	0.126649	1.853255	0.0695
D(PPLANLAMAKAPASITESI(-2	-0.321851	0.129295	-2.489271	0.0160
C	0.106509	0.068906	1.545723	0.1282
@TREND("2018M11")	0.000656	0.000727	0.901790	0.3713
R-squared	0.229560	Mean dependent var	-0.000579	
Adjusted R-squared	0.170296	S.D. dependent var	0.097388	
S.E. of regression	0.088709	Akaike info criterion	-1.923282	
Sum squared resid	0.409202	Schwarz criterion	-1.744067	
Log likelihood	59.81354	Hannan-Quinn criter.	-1.853633	
F-statistic	3.873482	Durbin-Watson stat	1.942918	
Prob(F-statistic)	0.007913			

Şekil 15. Planlama kapasitesinin ADF yöntemine göre birim kök test sonuçları

ADF test istatistiği -1,8745'tir ve ilgili p değeri 0,6546'dır; bu, birim kökün sıfır hipotezini reddetmek için yeterli kanıtın olmadığını göstermektedir.

- Regresyon denklemindeki katsayılar planlama kapasitesinin farklı değerleri ile gecikmeleri arasındaki ilişki hakkında bilgi sağlar.

- Model uyum istatistikleri (R-kare, düzeltilmiş R-kare), modelin varyansın nispeten düşük bir kısmını açıkladığını göstermektedir.

Genel olarak ADF test sonuçları ve model uyum istatistikleri toplu olarak yorumlanmalıdır. Birim kök hipotezinin reddedilmemesi planlama kapasitesinin durağan olmayabileceğini göstermektedir.

Augmented Dickey-Fuller Unit Root Test on TOPLAMISYUKU

Null Hypothesis: TOPLAMISYUKU has a unit root Exogenous: Constant, Linear Trend Lag Length: 0 (Automatic - based on SIC, maxlag=10)				
			t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic			-5.504967	0.0001
Test critical values:	1% level		-4.121303	
	5% level		-3.487845	
	10% level		-3.172314	
*MacKinnon (1996) one-sided p-values.				
Augmented Dickey-Fuller Test Equation Dependent Variable: D(TOPLAMISYUKU) Method: Least Squares Date: 12/03/23 Time: 16:20 Sample (adjusted): 2018M12 2023M10 Included observations: 59 after adjustments				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
TOPLAMISYUKU(-1)	-0.718835	0.130579	-5.504967	0.0000
C	-6.787318	13.03664	-0.520634	0.6047
@TREND("2018M11")	1.364589	0.432100	3.158043	0.0026
R-squared	0.353412	Mean dependent var		2.393949
Adjusted R-squared	0.330320	S.D. dependent var		60.35585
S.E. of regression	49.39160	Akaike info criterion		10.68695
Sum squared resid	136613.7	Schwarz criterion		10.79258
Log likelihood	-312.2649	Hannan-Quinn criter.		10.72818
F-statistic	15.30426	Durbin-Watson stat		2.078917
Prob(F-statistic)	0.000005			

Şekil 16. Toplam iş yükünün ADF yöntemine göre birim kök test sonuçları

ADF test istatistiği -5,505'tir ve ilişkili p değeri 0,00014264261904502'dir; bu, birim kökün sıfır hipotezini reddetmek için güçlü bir kanıt olduğunu gösterir.

Denklemdaki toplam iş yükü (-1) katsayısının negatif olması değişkenin fark alındıktan sonra muhtemelen durağan olduğunu göstermektedir.

Phillips-Perron testi, birim kökün varlığını belirlemek için kullanılır. Birim kök, bir zaman serisinin durağan olmayan ve zamanla değişen bir yapıya sahip olduğunu göstermektedir. Phillips-Perron testi, bir zaman serisi değişkeninin, bu durumda ek iş yükünün durağan olmadığını gösteren bir birim köke sahip olup olmadığını belirlenmesine yardımcı olan bir birim kök testidir. Sonuçları şu şekilde değerlendirilebilir:

Phillips-Perron Unit Root Test on EKISYUKU

Null Hypothesis: EKISYUKU has a unit root Exogenous: Constant, Linear Trend Bandwidth: 1 (Newey-West automatic) using Bartlett kernel				
			Adj. t-Stat	Prob.*
Phillips-Perron test statistic			-6.080841	0.0000
Test critical values:	1% level		-4.121303	
	5% level		-3.487845	
	10% level		-3.172314	
*MacKinnon (1996) one-sided p-values.				
Residual variance (no correction)				389.0397
HAC corrected variance (Bartlett kernel)				381.3057
Phillips-Perron Test Equation Dependent Variable: D(EKISYUKU) Method: Least Squares Date: 12/03/23 Time: 16:26 Sample (adjusted): 2018M12 2023M10 Included observations: 59 after adjustments				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
EKISYUKU(-1)	-0.815857	0.133823	-6.096554	0.0000
C	-2.212514	5.370831	-0.411950	0.6819
@TREND("2018M11")	0.424714	0.172856	2.457044	0.0171
R-squared	0.399468	Mean dependent var		0.000000
Adjusted R-squared	0.378020	S.D. dependent var		25.67089
S.E. of regression	20.24552	Akaike info criterion		8.903253
Sum squared resid	22953.34	Schwarz criterion		9.008891
Log likelihood	-259.6460	Hannan-Quinn criter.		8.944490
F-statistic	18.62532	Durbin-Watson stat		2.016882
Prob(F-statistic)	0.000001			

Şekil 17. Ek iş yükünün Phillips Peron yöntemine göre birim kök test sonuçları

Phillips-Perron Testi İstatistiği: Test istatistiği -6.0808'dir.

Test istatistiđi %1, %5 ve %10 seviyelerindeki kritik deđerlerden daha negatif olup, birim kökün varlığına karşı güçlü bir kanıt işaret etmektedir.

Test istatistiđiyle ilişkili p deđeri çok küçüktür ($2,04e-05$), bu da birim kökün H_0 hipotezine karşı daha fazla kanıt sağlar.

%1, %5 ve %10 seviyelerindeki kritik deđerler, test istatistiđiyle karşılaştırmak için sağlanır. Test istatistiđi bu kritik deđerlerden daha negatif olduğundan birim kökün sıfır hipotezi reddedilir.

Phillips-Perron Test Denklemi: Testte kullanılan regresyon denklemi, gecikmeli deđerler ve trend bileşenleri için katsayılar dahil olmak üzere sağlanmıştır. EKİSYUKU(-1) katsayısı -0,8159 olup istatistiksel olarak anlamlıdır.

Modele Uygun: R-kare deđeri 0,3995 olup, modelin farkı alınan serilerdeki varyansın yaklaşık %39,95'ini açıkladığını göstermektedir. F istatistiđi 18,63'tür ve çok küçük bir p deđeri vardır, bu da genel modelin istatistiksel olarak anlamlı olduğunu gösterir.

Durbin-Watson İstatistiđi: Durbin-Watson istatistiđinin 2,0169 olması, 2'ye yakın olması, artıklarda anlamlı bir birinci dereceden otokorelasyonun bulunmadığını göstermektedir.

Sonuç olarak, Phillips-Perron testine dayanarak birim kökün H_0 hipotezini reddedecek güçlü kanıt bulunmaktadır. Bu durum EKİSYUKU serisinin büyük olasılıkla durağan veya 0 ($I(0)$ mertebesinden bütünleşik) olduğunu belirtmektedir.

Phillips-Perron Unit Root Test on KURUMSALKAPASITE

Null Hypothesis: KURUMSALKAPASITE has a unit root Exogenous: Constant, Linear Trend Bandwidth: 2 (Newey-West automatic) using Bartlett kernel				
			Adj. t-Stat	Prob.*
Phillips-Perron test statistic			-2.252802	0.4523
Test critical values:	1% level		-4.121303	
	5% level		-3.487845	
	10% level		-3.172314	
*MacKinnon (1996) one-sided p-values.				
Residual variance (no correction)				222.5913
HAC corrected variance (Bartlett kernel)				215.8654
Phillips-Perron Test Equation Dependent Variable: D(KURUMSALKAPASITE) Method: Least Squares Date: 12/03/23 Time: 16:27 Sample (adjusted): 2018M12 2023M10 Included observations: 59 after adjustments				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
KURUMSALKAPASITE(-1	-0.163120	0.071525	-2.280620	0.0264
C	23.78523	11.83182	2.010277	0.0492
@TREND("2018M11")	0.102938	0.119137	0.864036	0.3913
R-squared	0.087994	Mean dependent var		0.000000
Adjusted R-squared	0.055422	S.D. dependent var		15.75677
S.E. of regression	15.31391	Akaike info criterion		8.344910
Sum squared resid	13132.89	Schwarz criterion		8.450547
Log likelihood	-243.1748	Hannan-Quinn criter.		8.386146
F-statistic	2.701546	Durbin-Watson stat		1.864472
Prob(F-statistic)	0.075847			

Şekil 18. Kurumsal kapasitenin Phillips Peron yöntemine göre birim kök test sonuçları

Phillips-Perron Testi İstatistiği: Test istatistiği -2,2528'dir.

Test istatistiği %1, %5 ve %10 seviyelerindeki kritik değerlerden daha az negatiftir ve birim kökün varlığına karşı zayıf kanıta işaret eder. Test istatistiğiyle ilişkili p değeri 0,4523'tür ve bu nispeten yüksektir, bu da birim kökün H_0 hipotezini reddetmek için yeterli kanıt olmadığını gösterir.

%1, %5 ve %10 seviyelerindeki kritik deęerler, test istatistięiyle karřılařtırmak iin saęlanır. Test istatistięi bu kritik deęerlerden daha az negatif olduęundan birim kkn sıfır hipotezine karřı zayıf kanıt vardır.

Phillips-Perron Test Denklemi: Testte kullanılan regresyon denklemi, gecikmeli deęerler ve trend bileřenleri iin katsayılar dahil olmak zere saęlanmıřtır. KURUMSALKAPASİTE(-1) katsayısı -0,1631 olup istatistiksel olarak anlamlıdır.

Modele Uygun: R-kare deęeri 0,088 olup, modelin fark serilerindeki varyansın yaklaşık %8,8'ini aıkladıęını gstermektedir. F istatistięi 2,7015 ve p deęeri 0,0758 olup, genel modelin geleneksel anlamlılık dzeylerinde istatistiksel olarak anlamlı olmadıęını gstermektedir.

Durbin-Watson İstatistięi: Durbin-Watson istatistięinin 1,8645 olması, 2'den kktr ve artıklarda potansiyel pozitif otokorelasyona iřaret etmektedir.

Sonuç olarak, KURUMSALKAPASİTE iin Phillips-Perron testinin kanıtları birim kkn sıfır hipotezini reddedecek kadar gl deęildir. Bu durum KURUMSALKAPASİTE'in duraęan olmadıęını gstermektedir.

Phillips-Perron Unit Root Test on NORMKADRO

Null Hypothesis: NORMKADRO has a unit root Exogenous: Constant, Linear Trend Bandwidth: 3 (Newey-West automatic) using Bartlett kernel				
			Adj. t-Stat	Prob.*
Phillips-Perron test statistic			-5.397970	0.0002
Test critical values:	1% level		-4.121303	
	5% level		-3.487845	
	10% level		-3.172314	
*MacKinnon (1996) one-sided p-values.				
Residual variance (no correction)				70.05372
HAC corrected variance (Bartlett kernel)				75.69602
Phillips-Perron Test Equation Dependent Variable: D(NORMKADRO) Method: Least Squares Date: 12/03/23 Time: 16:27 Sample (adjusted): 2018M12 2023M10 Included observations: 59 after adjustments				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
NORMKADRO(-1)	-0.632105	0.118439	-5.336980	0.0000
C	-1.650257	2.270897	-0.726698	0.4704
@TREND("2018M11")	0.505286	0.108654	4.650411	0.0000
R-squared	0.340546	Mean dependent var		0.471831
Adjusted R-squared	0.316994	S.D. dependent var		10.39526
S.E. of regression	8.591077	Akaike info criterion		7.188834
Sum squared resid	4133.170	Schwarz criterion		7.294472
Log likelihood	-209.0706	Hannan-Quinn criter.		7.230071
F-statistic	14.45935	Durbin-Watson stat		2.367604
Prob(F-statistic)	0.000009			

Şekil 19. Norm kadronun Phillips Peron yöntemine göre birim kök test sonuçları

Phillips-Perron Testi İstatistiği: Test istatistiği -5,39797'dir. Test istatistiğinin %1, %5 ve %10 seviyelerindeki kritik değerlerden daha negatif olması birim kökün varlığına karşı kanıt olduğunu göstermektedir. Test istatistiğiyle ilişkili p değeri çok düşüktür (0,0002028), bu da birim kökün sıfır hipotezini reddedecek güçlü kanıtlara işaret etmektedir.

%1, %5 ve %10 seviyelerindeki kritik deęerler, test istatistięiyle karřılařtırmak iin saęlanır. Test istatistięi bu kritik deęerlerden daha negatif olduęundan birim kkn sıfır hipotezine karřı gl kanıtlar vardır.

Phillips-Perron Test Denklemi: Testte kullanılan regresyon denklemi, gecikmeli deęerler ve trend bileřenleri iin katsayılar dahil olmak zere saęlanmıřtır. NORMKADRO(-1) katsayısı -0,6321 olup istatistiksel olarak anlamlıdır.

Modele Uygun: R-kare deęeri 0,3405 olup, modelin fark serilerindeki varyansın yaklaşık %34,05'ini aıkladıęını gstermektedir. F istatistięi 14,4594 olup, p deęeri ok dřktr (8,6531e-06), bu da genel modelin istatistiksel olarak anlamlı olduęunu gstermektedir.

Durbin-Watson İstatistięi: Durbin-Watson istatistięi 2,3676 olup 2'ye yakındır, bu da artıklarda anlamlı bir otokorelasyon olmadıęını gstermektedir.

Sonuç olarak, NORMKADRO iin Phillips-Perron testinden elde edilen kanıtlar gldr ve birim kkn sıfır hipotezini reddetmek iin yeterli kanıt bulunduęunu gstermektedir. Bu, NORMKADRO'nun muhtemelen duraęan olduęunu gstermektedir.

Phillips-Perron Unit Root Test on PERFORMANSDEGERI

Null Hypothesis: PERFORMANSDEGERI has a unit root Exogenous: Constant, Linear Trend Bandwidth: 5 (Newey-West automatic) using Bartlett kernel				
			Adj. t-Stat	Prob.*
Phillips-Perron test statistic			-8.532044	0.0000
Test critical values:	1% level		-4.121303	
	5% level		-3.487845	
	10% level		-3.172314	
*MacKinnon (1996) one-sided p-values.				
Residual variance (no correction)				13.59828
HAC corrected variance (Bartlett kernel)				28.24495
Phillips-Perron Test Equation Dependent Variable: D(PERFORMANSDEGERI) Method: Least Squares Date: 12/22/23 Time: 11:53 Sample (adjusted): 2018M12 2023M10 Included observations: 59 after adjustments				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
PERFORMANSDEGERI(-1	-1.084407	0.132157	-8.205449	0.0000
C	5.088301	1.165005	4.367621	0.0001
@TREND("2018M11")	-0.063588	0.029814	-2.132809	0.0373
R-squared	0.546027	Mean dependent var		0.019322
Adjusted R-squared	0.529814	S.D. dependent var		5.520001
S.E. of regression	3.785070	Akaike info criterion		5.549515
Sum squared resid	802.2983	Schwarz criterion		5.655153
Log likelihood	-160.7107	Hannan-Quinn criter.		5.590752
F-statistic	33.67774	Durbin-Watson stat		1.936482
Prob(F-statistic)	0.000000			

Şekil 20. Performans değerinin Phillips Peron yöntemine göre birim kök test sonuçları

Phillips-Perron Testi İstatistiği: Test istatistiği -8.5320'dir. Test istatistiği %1, %5 ve %10 seviyelerindeki kritik değerlerden daha negatif olup, birim kökün varlığına karşı güçlü bir kanıtı işaret etmektedir. Test istatistiğiyle ilişkili p değeri çok düşüktür (6.5328e-09), bu da birim kökün sıfır hipotezini reddetmek için güçlü bir kanıt sağlar.

%1, %5 ve %10 seviyelerindeki kritik değerler, test istatistiğiyle karşılaştırma amacıyla sağlanmıştır. Test istatistiği bu kritik değerlerden daha negatif olduğundan birim kökün sıfır hipotezine karşı güçlü kanıtlar vardır.

Phillips-Perron Test Denklemi: Testte kullanılan regresyon denklemi, gecikmeli deęerler ve trend bileşenleri için katsayılar dahil olmak üzere sağlanmıştır. PERFORMANSDEGERI(-1) katsayısı -1,0844 olup istatistiksel olarak anlamlıdır.

Modele Uygun: R-kare deęeri 0,5460 olup, modelin fark serilerindeki varyansın yaklaşık %54,60'ını açıkladığını göstermektedir. F istatistięi 33,6777'dir ve çok düşük bir p deęeri ($2,4936e-10$) vardır, bu da genel modelin istatistiksel olarak anlamlı olduğunu gösterir.

Durbin-Watson İstatistięi: Durbin-Watson istatistięi 1,9365'tir ve bu da 2'den küçüktür, bu da artıklarda potansiyel pozitif otokorelasyona işaret etmektedir.

Sonuç olarak, PERFORMANSDEGERI için Phillips-Perron testinden elde edilen kanıtlar güçlüdür ve birim kökün sıfır hipotezini reddetmek için yeterli kanıt bulunduğunu göstermektedir. Bu, PERFORMANSDEGERI'nin durağan olduğunu göstermektedir.

Phillips-Perron Unit Root Test on PLANLAMAKAPASITESI

Null Hypothesis: PLANLAMAKAPASITESI has a unit root Exogenous: Constant, Linear Trend Bandwidth: 5 (Newey-West automatic) using Bartlett kernel				
			Adj. t-Stat	Prob.*
Phillips-Perron test statistic			-2.240566	0.4588
Test critical values:	1% level		-4.121303	
	5% level		-3.487845	
	10% level		-3.172314	
*MacKinnon (1996) one-sided p-values.				
Residual variance (no correction)				0.008291
HAC corrected variance (Bartlett kernel)				0.007859
Phillips-Perron Test Equation Dependent Variable: D(PPLANLAMAKAPASITESI) Method: Least Squares Date: 12/22/23 Time: 12:30 Sample (adjusted): 2018M12 2023M10 Included observations: 59 after adjustments				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
PLANLAMAKAPASITESI(	-0.164435	0.071837	-2.289005	0.0259
C	0.131507	0.066201	1.986466	0.0519
@TREND("2018M11")	0.000536	0.000723	0.741217	0.4617
R-squared	0.087941	Mean dependent var		-0.000559
Adjusted R-squared	0.055368	S.D. dependent var		0.096162
S.E. of regression	0.093462	Akaike info criterion		-1.853021
Sum squared resid	0.489165	Schwarz criterion		-1.747384
Log likelihood	57.66412	Hannan-Quinn criter.		-1.811784
F-statistic	2.699779	Durbin-Watson stat		1.631094
Prob(F-statistic)	0.075969			

Şekil 21. Planlama kapasitesinin Phillips Peron yöntemine göre birim kök test sonuçları

Phillips-Perron Testi İstatistiği: Test istatistiği -2,2406'dır. Test istatistiği %1, %5 ve %10 seviyelerindeki kritik değerlerden daha negatif değildir ve ilişkili p değeri 0,4588'dir. P-değeri nispeten yüksektir ve birim kökün varlığına karşı zayıf kanıtlara işaret etmektedir.

%1, %5 ve %10 seviyelerindeki kritik değerler, test istatistiğiyle karşılaştırma amacıyla sağlanmıştır. Test istatistiği bu kritik değerlerden daha negatif olmadığından birim kökün sıfır hipotezine karşı zayıf kanıt vardır.

Phillips-Perron Test Denklemi: Testte kullanılan regresyon denklemi, gecikmeli deęerler ve trend bileşenleri için katsayılar dahil olmak üzere sağlanmıştır. PLANLAMAKAPASITESI(-1) katsayısı -0,1644 olup istatistiksel olarak anlamlıdır.

Modele Uygun: R-kare deęeri 0,0879 olup, modelin fark serilerindeki varyansın yalnızca %8,79'unu açıkladığını göstermektedir. F istatistięi 2,6998 ve p deęeri 0,07597 olup, genel modelin istatistiksel olarak anlamlı olmayabileceğini düşündürmektedir.

Durbin-Watson İstatistięi: Durbin-Watson istatistięi 1,6311'dir ve bu deęer 2'den küçüktür, bu da artıklarda potansiyel pozitif otokorelasyona işaret etmektedir.

Sonuç olarak, PLANLAMAKAPASITESI için Phillips-Perron testinin kanıtları zayıftır ve birim kökün boş hipotezini reddetmek için sınırlı destek vardır. P deęerinin göreceli olarak yüksek olması, farkı alınan serinin durağan olmayabileceğini göstermektedir.

Phillips-Perron Unit Root Test on TOPLAMISYUKU

Null Hypothesis: TOPLAMISYUKU has a unit root Exogenous: Constant, Linear Trend Bandwidth: 4 (Newey-West automatic) using Bartlett kernel				
			Adj. t-Stat	Prob.*
Phillips-Perron test statistic			-5.666810	0.0001
Test critical values:	1% level		-4.121303	
	5% level		-3.487845	
	10% level		-3.172314	
*MacKinnon (1996) one-sided p-values.				
Residual variance (no correction)				2315.486
HAC corrected variance (Bartlett kernel)				2681.654
Phillips-Perron Test Equation Dependent Variable: D(TOPLAMISYUKU) Method: Least Squares Date: 12/22/23 Time: 12:28 Sample (adjusted): 2018M12 2023M10 Included observations: 59 after adjustments				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
TOPLAMISYUKU(-1)	-0.718835	0.130579	-5.504967	0.0000
C	-6.787318	13.03664	-0.520634	0.6047
@TREND("2018M11")	1.364589	0.432100	3.158043	0.0026
R-squared	0.353412	Mean dependent var		2.393949
Adjusted R-squared	0.330320	S.D. dependent var		60.35585
S.E. of regression	49.39160	Akaike info criterion		10.68695
Sum squared resid	136613.7	Schwarz criterion		10.79258
Log likelihood	-312.2649	Hannan-Quinn criter.		10.72818
F-statistic	15.30426	Durbin-Watson stat		2.078917
Prob(F-statistic)	0.000005			

Şekil 22. Toplam iş yükü kapasitesinin Phillips Peron yöntemine göre birim kök test sonuçları

Phillips-Perron Testi İstatistiği: Test istatistiği -5,6668'dir. İlişkili p değeri 8,31e-05'tir.

%1, %5 ve %10 seviyelerindeki kritik değerler, test istatistiğiyle karşılaştırma amacıyla sağlanmıştır. Test istatistiği bu kritik değerlerden daha negatiftir.

Phillips-Perron Test Denklemi: Testte kullanılan regresyon denklemi, gecikmeli değerler ve trend bileşenleri için katsayılar dahil olmak üzere sağlanmıştır. TOPLAMISYUKU(-1) katsayısı -0,7188 olup istatistiksel olarak anlamlıdır.

Modele Uygun: R-kare değeri 0,3534 olup, modelin fark serilerindeki varyansın yaklaşık %35,34'ünü açıkladığını göstermektedir. F istatistiği 15,3043 olup, p değeri 4,98e-06 olup, genel modelin istatistiksel olarak anlamlı olduğunu göstermektedir.

Durbin-Watson İstatistiği: Durbin-Watson istatistiğinin 2,0789 olması, 2'ye yakın olması, artıklarda sınırlı bir otokorelasyon olduğunu göstermektedir.

Phillips-Perron testi, TOPLAMISYUKU serisi için birim kökün H_0 hipotezine karşı kanıt sağlar. P değeri çok küçüktür ve test istatistiği ortak anlamlılık düzeylerinde kritik değerlerden daha negatiftir. Model uyumu, önemli bir F istatistiği ve makul bir R-kare değeri ile nispeten güçlüdür. Durbin-Watson istatistiği artıklarda sınırlı bir otokorelasyon olduğunu göstermektedir.

Bu sonuçlar, TOPLAMISYUKU serisinin durağan olduğunu göstermektedir.

Tablo 6. Birim Kök Testi Sonuçları

Değişken	ADF Sonuç	Phillips-Perron Sonuç
Ek İş Yüğü	Durağan	Durağan
Kurumsal Kapasite	Durağan Değil	Durağan Değil
Norm Kadro	Durağan Değil	Durağan
Performans Değeri	Durağan Değil	Durağan
Planlama Kapasitesi	Durağan Değil	Durağan Değil
Toplam İş Yüğü	Durağan	Durağan

Yukarıdaki tablo, analiz edilen değişkenlerin ADF ve Phillips-Perron birim kök testlerine göre durağanlık durumlarını göstermektedir. Her iki testin sonuçları karşılaştırıldığında, bazı değişkenlerin her iki testte de durağan olduğu, bazı değişkenlerin ise sadece belirli bir testte durağan olmadığı gözlemlenmiştir.

Ek iş yüğü ve toplam iş yüğü gibi değişkenler, hem ADF hem de Phillips-Perron testlerinde durağan olarak tespit edilmiştir, bu da bu değişkenlerin zaman içinde istikrarlı bir yapıya sahip olduğunu göstermektedir.

Kurumsal kapasite, norm kadro, performans değeri, ve planlama kapasitesi gibi değişkenler ise her iki testte de durağan olmayan olarak bulunmuştur. Bu da bu değişkenlerin zaman içinde yapılarında değişim gösterebileceği ve daha derinlemesine analiz gerektirebileceği anlamına gelmektedir.

Bu sonuçlar, analiz edilen değişkenlerin uzun dönemli dinamiklerini anlamada önemli ipuçları sunmakta olup, zaman serisi modellemesi ve gelecekteki tahminler için hangi değişkenlerin stabil olduğu ve hangilerinin daha değişken olduğu konusunda yol göstericidir. (Güneş 2010)

Adım 6 : Engle-Granger eşbütünleşme testi, uzun dönemdeki ilişkiyi belirlemek için kullanılan bir yöntemdir. Bu test, özellikle değişkenler arasındaki eşbütünleşme (uzun vadeli denge ilişkisi) durumunu analiz eder. Tablo, bağımlı değişkenler ile birlikte tau istatistiklerini, olasılık değerlerini, z istatistiklerini, Rho değerlerini, varyansları, gecikme sayısını, gözlem sayısını ve stokastik eğilim sayısını içermektedir.

Eşbütünleşme analizinde en önemli parametrelerden biri tau istatistiği ve bu istatistiğin ilişkili olduğu olasılık değerleridir. Tau istatistiği, değişkenler arasında uzun vadeli bir ilişkinin olup olmadığını belirlemede kritik bir rol oynar. Testin sonucu olarak tau istatistiği negatif ve istatistiksel olarak anlamlı ise, bu, uzun dönemde değişkenler arasında eşbütünleşme olduğunu gösterir. Olasılık değerleri ise tau istatistiğinin istatistiksel anlamlılığını test eder. Eğer bu olasılık değeri 0.05'in altında ise, eşbütünleşme hipotezi kabul edilir.

Şekil 23'de yer alan Rho değerleri ise, değişkenlerin uzun vadeli dengeye yakın olup olmadığını belirler. Ayrıca, gecikme sayısı ve stokastik eğilim sayısı gibi parametreler, modelin doğruluğunu ve güvenilirliğini artırmaya yönelik hesaplamalar olup, eşbütünleşme analizi sırasında önemli bir yer tutar.

Engle-Granger Cointegration Test

Date: 12/22/23 Time: 11:06

Series: EKISYUKU KURUMSALKAPASITE NORMKADRO PERFORMANSDEGERI PLANLAMAKAPASITESI TOPLAMISYUKU

Sample: 2018M11 2023M10

Included observations: 60

Null hypothesis: Series are not cointegrated

Cointegrating equation deterministics: C

Automatic lags specification based on Schwarz criterion (maxlag=10)

Dependent	tau-statistic	Prob.*	z-statistic	Prob.*
EKISYUKU	-9.142995	0.0000	-69.51665	0.0000
KURUMSALKAPASI	-6.485526	0.0012	-49.59790	0.0010
NORMKADRO	-7.020043	0.0003	-54.61512	0.0002
PERFORMANSDEG	-2.420259	0.9246	-13.56966	0.8502
PLANLAMAKAPASI	-6.295255	0.0021	-47.84047	0.0017
TOPLAMISYUKU	-5.713385	0.0096	-42.70536	0.0076

*MacKinnon (1996) p-values.

Intermediate Results:

	EKISYUKU	KURUMSAL	NORMKAD	PERFORM	PLANLAMA	TOPLAMIS
Rho - 1	-1.178248	-0.840642	-0.925680	-0.530348	-0.810855	-0.723820
Rho S.E.	0.128869	0.129618	0.131862	0.219129	0.128804	0.126688
Residual variance	240.3886	72.87493	88.51843	7.453682	0.002659	1535.178
Long-run residual variance	240.3886	72.87493	88.51843	1.501886	0.002659	1535.178
Number of lags	0	0	0	2	0	0
Number of observations	59	59	59	57	59	59
Number of stochastic trends**	6	6	6	6	6	6

**Number of stochastic trends in asymptotic distribution

Şekil 23. Engle-Granger eşbütünleşme analizi

Çıktılar incelendiğinde, her bir değişken için elde edilen tau istatistikleri ve olasılık değerleri şu şekildedir:

Ek İş Yüğü: Tau istatistiği -9.143, olasılık değeri 5.04e-07

Kurumsal Kapasite: Tau istatistiği -6.486, olasılık değeri 0.00124

Norm Kadro: Tau istatistiği -7.020, olasılık değeri 0.00027

Performans Değeri: Tau istatistiği -2.420, olasılık değeri 0.925

Planlama Kapasitesi: Tau istatistiği 0.0021, olasılık değeri -6.295

Toplam İş Yüğü: Tau istatistiği -5.713, olasılık değeri 0.0096

Sonuçlar incelendiğinde:

Ek iş yüğü, kurumsal kapasite, norm kadro, planlama kapasitesi ve toplam iş yüğü gibi değişkenler için düşük p-değerleri gözlemlenmiştir. Bu da, bu değişkenler arasında uzun dönemde eşbütünleşme olduğunu ve değişkenler arasında güçlü bir uzun vadeli ilişki bulunduğunu göstermektedir.

Öte yandan, performans değeri değışkeni için p-değeri çok daha yüksektir (0.925), bu da H_0 hipotezini reddetmek için yeterli kanıt olmadığına işaret eder. Bu durum, performans değeri için uzun vadeli bir ilişkinin varlığına dair daha zayıf bir destek sağladığını göstermektedir.

Bu bulgular, değışkenlerin uzun vadeli ilişkilere sahip olup olmadığını değerlendirirken önemli ipuçları sunmakta ve ek iş yükü, kurumsal kapasite, norm kadro gibi değışkenler arasında daha güçlü bir eşbütünleşme ilişkisi olduğu sonucuna varılmasını sağlamaktadır.

Adım 7: ARIMA değerlerinin tespiti (p,d,q) , model kurulumunun gerçekleştirilmesi

Eviews programı ile BOX-JENKINS tarafından önerilen otoregresif entegre edilmiş hareketli ortalama yöntemi kullanılarak serilerin modellenmesi ve öngörüler oluşturulmuştur.

Doğrusal zaman serisi analizinde ARIMA metodolojisi sık kullanılan bir yöntemdir. Analiz edilen seride birim kökün olması ya da olmaması bu modeller için önemlidir. ARIMA analizinin ilk aşaması birim kök analizinin yapılmasıdır. Bu aşamaya kadar serilerin birim kök içerip içermedikleri tespit edilmiştir. Eğer seri $I(0)$ ise modelde kullanılacak entegrasyon(tümleşme) derecesi sıfır $d=0$ olacaktır. $I(1)=1$ ise $d=1$, $I(2)=2$ ise $d=2$ olacaktır.

Durağan olan ya da durağan hale dönüştürülen serinin ACF ve PACF grafiklerine göre uygun olan model belirlenir.

ACF grafiğindeki ilişki miktarları gecikme sayısı arttıkça yavaş yavaş azalıyor ama PACF grafiğindeki bu azalma hızlı bir şekilde oluyorsa AR modeli,

PACF grafiğindeki ilişki miktarı yavaş yavaş azalırken ACF grafiğindeki ilişki miktarı hızlı bir şekilde azalıyorsa hareketli ortalama MA modeli,

Hem ACF hem de PACF grafiklerinde ilişki miktarının azalışı yavaş yavaş olursa otoregresif hareketli ortalama ARMA modeli kurulmalıdır.

Birim kökün varlığını kontrol etmek amacıyla "ek iş yükü" zaman serisi değışkeni için Artırılmış Dickey-Fuller (ADF) testinin çıktısı Şekil 24'deki gibidir.

Augmented Dickey-Fuller Unit Root Test on EKISYUKU

Null Hypothesis: EKISYUKU has a unit root Exogenous: Constant Lag Length: 0 (Automatic - based on SIC, maxlag=10)				
			t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic			-5.184460	0.0001
Test critical values:	1% level		-3.562669	
	5% level		-2.918778	
	10% level		-2.597285	
*MacKinnon (1996) one-sided p-values.				
Augmented Dickey-Fuller Test Equation Dependent Variable: D(EKISYUKU) Method: Least Squares Date: 01/13/24 Time: 16:22 Sample (adjusted): 2019M07 2023M10 Included observations: 52 after adjustments				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
EKISYUKU(-1)	-0.699248	0.134874	-5.184460	0.0000
C	10.19219	3.663296	2.782246	0.0076
R-squared	0.349624	Mean dependent var		0.000000
Adjusted R-squared	0.336617	S.D. dependent var		27.36738
S.E. of regression	22.29027	Akaike info criterion		9.083880
Sum squared resid	24842.82	Schwarz criterion		9.158928
Log likelihood	-234.1809	Hannan-Quinn criter.		9.112652
F-statistic	26.87863	Durbin-Watson stat		2.121178
Prob(F-statistic)	0.000004			

Şekil 24. Ek iş yükü Augmented Dickey – Fuller birim kök testi

Null Hypothesis: ADF testindeki H_0 hipotezi genel olarak zaman serisinin birim köke sahip olduğu (yani durağan olmadığı) şeklindedir.

Test İstatistiği: ADF test istatistiği -5,184460'tır ve ilgili p değeri çok düşüktür (0,0001). Bu, birim kökün sıfır hipotezini reddedebileceğinizi gösterir. Yani "ek iş yükü" zaman serisinin durağan olduğunu gösterir.

Kritik Değerler: Test, test istatistiğini farklı anlamlılık seviyelerindeki (%1, %5 ve %10) kritik değerlerle karşılaştırır. Ek iş yükü serisinde test istatistiği tüm bu seviyelerdeki kritik değerlerden daha uç noktalardadır ve bu da H_0 hipotezini reddeder.

Katsayılar: Regresyon denklemindeki katsayılar (EKİSYUKU(-1) ve sabit terim C) tahmin edilen değerlerdir. EKİSYUKU(-1) katsayısı -0,699248 olup, -5,184460 t istatistiği ve 0,0000 p değeriyle istatistiksel olarak anlamlıdır.

R-kare ve Düzeltilmiş R-kare: Bu değerler bağımsız değişkenlerin bağımlı değişkendeki değişkenliği ne kadar iyi açıkladığının bir göstergesidir. Bu durumda, düzeltilmiş R-kare 0,336617'dir; bu, farklı "ek iş yükü" serisindeki değişkenliğin yaklaşık %33,66'sının " ek iş yükü "nün gecikmeli değeri ve sabit tarafından açıklandığını gösterir.

F-istatistiği: Bu, regresyonun genel anlamlılığını gösteren bir testtir. Düşük p değeri (0,000004), modelin istatistiksel olarak anlamlı olduğunu göstermektedir.

Durbin-Watson İstatistiği: Bu istatistik, artıklarda otokorelasyonun varlığını test eder. 2,121178 değeri bir miktar pozitif otokorelasyona işaret eder.

Özetle, ADF testi ve regresyon sonuçlarına dayanarak " ek iş yükü " zaman serisinde birim kökün H_0 hipotezini reddetmektedir.

Serinin ARIMA modelinde $I(0)$ olduğu belirlenmiş olmaktadır. ARMA modelinin tespiti için ; AR(1) , AR(1) AR(2) , AR(1) AR(2) MA(1) , AR(1) MA(1), AR(1) MA(1) MA(2), MA(1), MA(1) MA(2) , AR(1) AR(2) MA(1) MA(2) indekslerinin sonuçları incelenerek ek iş yükü serisinin ARIMA modeli (1,0,1) uygun olduğu tespit edilmiştir. Regresyon analizinin çıktısı Tablo 7'de sağlanmıştır.

Tablo 7. Ek İş Yüğü ARIMA (1,0,1) Model Tespit Sonuçları

Dependent Variable: EKISYUKU Method: Least Squares Date: 01/07/24 Time: 20:02 Sample (adjusted): 2019M07 2023M10 Included observations: 52 after adjustments Convergence achieved after 11 iterations MA Backcast: 2019M06				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	18.42234	9.474196	1.944475	0.0576
AR(1)	0.913283	0.087985	10.38002	0.0000
MA(1)	-0.765300	0.155948	-4.907393	0.0000
R-squared	0.188777	Mean dependent var	14.57592	
Adjusted R-squared	0.155666	S.D. dependent var	23.14208	
S.E. of regression	21.26471	Akaike info criterion	9.007936	
Sum squared resid	22157.22	Schwarz criterion	9.120508	
Log likelihood	-231.2063	Hannan-Quinn criter.	9.051094	
F-statistic	5.701317	Durbin-Watson stat	1.995354	
Prob(F-statistic)	0.005942			
Inverted AR Roots	.91			
Inverted MA Roots	.77			

- **Model Şartnamesi:**

Kullanılan model, otoregresif (AR) ve hareketli ortalama (MA) terimlerinin, özellikle AR(1) ve MA(1) modelidir.

Bağımlı değişken "ek iş yükü" olup, kullanılan yöntem en küçük kareler yöntemidir.

- **Katsayılar:**

Sabit terim (C), 9,474196 standart hatasıyla 18,42234'tür. T istatistiği 1,944475'tir ve ilgili p değeri 0,0576'dır.

AR(1) teriminin katsayısı 0,913283'tür ve standart hata 0,087985'tir. T istatistiği 10,38002 ve p değeri 0,0000'dir. AR(1) teriminin istatistiksel olarak anlamlıdır.

MA(1) teriminin katsayısı -0,765300'dür ve standart hata 0,155948'dir. T istatistiği -4,907393 ve p değeri 0,0000'dir. MA(1) terimi de istatistiksel olarak anlamlıdır.

- **Modele Uygun:**

R-kare değeri 0,188777 olup, modelin bağımlı değişkendeki varyansın yaklaşık %18,88'ini açıkladığını göstermektedir.

Düzeltilmiş R-kare 0,155666'dır ve bu, modeldeki öngörücülerin sayısına göre ayarlama yapmaktadır.

F istatistiği modelin genel anlamlılığını test eder. Düşük p değeri (0,005942), modelin istatistiksel olarak anlamlı olduğunu göstermektedir.

- **Teşhis İstatistikleri:**

Durbin-Watson istatistiği 1,995354'tür ve bu da bazı pozitif otokorelasyonun varlığını göstermektedir.

Modelin stabilitesini gösteren ters AR ve MA kökleri sağlanmıştır.



11 yinelemeden sonra yakınsama sağlanmıştır. Bu da tahmin sürecinde istikrar olduğunu göstermektedir. Analiz, hareketli ortalama (MA) terimi için bir geriye dönük tahmin içermektedir.

Özetle AR(1) ve MA(1) terimlerinin "ek iş yükü" değişkenindeki değişimi açıklamada istatistiksel olarak anlamlı olduğu belirlenmiştir.

Durbin-Watson istatistiği 2'ye çok yakın olduğundan dolayı kalıntılarda otokorelasyon olmadığı anlaşılmaktadır.

Ek iş yüküne ait kalıntılar temiz diziye sahip olduğunun tespiti için kologram grafiğine bakıldığında prob değerleri 0.01'den büyüktür, yani kalıntıların temiz diziye sahip olduğu anlaşılmaktadır. Bütün koşulları sağladığı için en iyi model ARIMA(1,0,1) olduğu kararlaştırılmıştır.

Tablo 8. Ek İş Yüğü Kalıntı Kolegramı

Date: 02/11/25 Time: 14:30 Sample: 2019M07 2025M10 Included observations: 52						
Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob	
		1	0.155	0.155	1.3205	0.250
		2	0.121	0.099	2.1416	0.343
		3	0.183	0.156	4.0597	0.255
		4	0.430	0.397	14.898	0.005
		5	0.026	-0.105	14.939	0.011
		6	0.138	0.073	16.098	0.013
		7	0.099	-0.041	16.710	0.019
		8	0.003	-0.219	16.711	0.033
		9	0.007	0.046	16.714	0.053
		10	0.041	-0.060	16.828	0.078
		11	0.009	0.022	16.834	0.113
		12	0.073	0.212	17.210	0.142
		13	0.027	-0.032	17.261	0.188
		14	0.071	0.133	17.635	0.224
		15	0.014	-0.031	17.649	0.282
		16	0.031	-0.145	17.722	0.340
		17	-0.074	-0.101	18.159	0.379
		18	0.003	-0.135	18.160	0.445
		19	-0.061	-0.072	18.471	0.491
		20	-0.078	0.004	18.999	0.522
		21	-0.092	0.019	19.763	0.536
		22	-0.110	-0.001	20.902	0.527
		23	-0.102	0.039	21.912	0.526
		24	-0.105	-0.043	23.021	0.519

"Kurumsal Kapasite" zaman serisi değişkeni için Artırılmış Dickey-Fuller (ADF) testinin çıktısı Şekil 25'deki gibidir.

Null Hypothesis: KURUMSALKAPASITE has a unit root Exogenous: Constant Lag Length: 0 (Automatic - based on SIC, maxlag=10)				
			t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic			-2.069628	0.2575
Test critical values:	1% level		-3.562669	
	5% level		-2.918778	
	10% level		-2.597285	
*MacKinnon (1996) one-sided p-values.				
Augmented Dickey-Fuller Test Equation Dependent Variable: D(KURUMSALKAPASITE) Method: Least Squares Date: 02/11/25 Time: 13:02 Sample (adjusted): 2019M07 2023M10 Included observations: 52 after adjustments				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
KURUMSALKAPASITE(-1)	-0.157815	0.076253	-2.069628	0.0437
C	25.67527	12.60967	2.036157	0.0470
R-squared	0.078907	Mean dependent var		0.000000
Adjusted R-squared	0.060486	S.D. dependent var		16.80336
S.E. of regression	16.28725	Akaike info criterion		8.456345
Sum squared resid	13263.73	Schwarz criterion		8.531393
Log likelihood	-217.8650	Hannan-Quinn criter.		8.485117
F-statistic	4.283361	Durbin-Watson stat		1.855705
Prob(F-statistic)	0.043674			

Şekil 25. Kurumsal kapasite Augmented Dickey – Fuller birim kök testi

Augmented Dickey-Fuller (ADF) test sonuçlarını aşağıdaki gibidir:

- Null Hipotez (H_0): Kurumsal kapasite değişkeni birim köke sahiptir (durağan değildir).
- Alternatif Hipotez (H_1): Kurumsal kapasite değişkeni birim köke sahip değildir (durağandır).

ADF Test İstatistiği: -2.07

Kritik Değerler:

- %1 düzeyinde: -3.567
- %5 düzeyinde: -2.92

- %10 düzeyinde: -2.60
- p-değeri: 0.2574

ADF test istatistiği, kritik değerlerin hiçbirinden daha küçük olmadığı için H_0 reddedilemez.

p-değeri (0.2574), genellikle kullanılan %1, %5 ve %10 anlamlılık seviyelerinden büyük olduğundan serinin durağan olmadığı sonucuna ulaşılır.

Kurumsal kapasite değişkeni birim köke sahip olabilir, yani durağan değildir. Seriyi durağan hale getirmek için birinci farkı (first difference) alınmalıdır.

DF testine göre kurumsal kapasite değişkeninin farkları (D(kurumsalkapasite)) durağandır, yani birim kök yoktur ve bu serinin zaman serisi analizi için uygun olduğunu gösterebilir.

Kurumsal kapasite serisi için ARIMA modeli ARIMA(0,2,1) olarak belirlenmiştir. Bu modelde AR(1) yani bir otoregresif terim kullanılmış ve d=0 (durağanlık için fark alınmamış) seçilmiştir. Bu durumda, seri durağan kabul edilmiştir.

Tablo 9. Kurumsal Kapasite ARIMA (0,2,1) Model Tespit Sonuçları

Dependent Variable: KURUMSALKAPASITE				
Method: Least Squares				
Date: 02/11/25 Time: 13:40				
Sample (adjusted): 2019M07 2023M10				
Included observations: 52 after adjustments				
Convergence achieved after 2 iterations				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	162.6923	14.31117	11.36820	0.0000
AR(1)	0.842185	0.076253	11.04465	0.0000
R-squared	0.709276	Mean dependent var	162.6923	
Adjusted R-squared	0.703461	S.D. dependent var	29.90937	
S.E. of regression	16.28725	Akaike info criterion	8.456345	
Sum squared resid	13263.73	Schwarz criterion	8.531393	
Log likelihood	-217.8650	Hannan-Quinn criter.	8.485117	
F-statistic	121.9843	Durbin-Watson stat	1.855705	
Prob(F-statistic)	0.000000			
Inverted AR Roots	.84			

Sabit terim, modelin genel ortalama seviyesini gösterir. Bu katsayının çok düşük bir p-değeri ile istatistiksel olarak anlamlı olduğu ($p < 0.05$) görülmüyor. Yani, "Kurumsal Kapasite" serisinin ortalama değeri yaklaşık 162.69'dur ve bu anlamlı bir sonuçtur.

AR(1) katsayısı, önceki dönemin (gecikmeli değer) mevcut dönemdeki değeri nasıl etkilediğini gösterir. Bu katsayının pozitif ve anlamlı olduğu ($p < 0.05$) görülmektedir. Yani, geçmiş dönemdeki değerlerin pozitif ve mevcut dönemi artırıcı bir etkisi vardır.

R-kare değeri %70.93 ve düzeltilmiş R-kare değeri %70.35. Bu, modelin bağımlı değişkenin (Kurumsal Kapasite) varyansının büyük bir kısmını (yaklaşık %70) açıkladığını gösterir. Modelin açıklayıcı gücü oldukça yüksek ve bu iyi bir sonuçtur.

Modelin genel anlamlılığına bakıldığında, p-değeri çok düşük ($p < 0.05$), bu da modelin istatistiksel olarak anlamlı olduğunu gösteriyor. Yani, modelin bağımsız değişkenlerin bağımlı değişkeni açıklamada anlamlı bir ilişkisi vardır.


Durbin-Watson İstatistiği: Kalıntılarda otokorelasyonun olmadığını gösterir. Değer 2'ye yakın olduğundan, modelin kalıntılarında otokorelasyon olmadığı ve bağımsızlık varsayımının iyi sağlandığı söylenebilir.

Inverted AR Roots (Kökler): AR(1) Kökü: Kök değeri 0.84 olduğu için modelin kararlı olduğunu söyleyebiliriz. Bu, AR(1) modelinin zamanla stabil kalacağını gösterir.

Kısaca;

- Kurumsal kapasitenin ortalama değeri yaklaşık 162.69'dur ve bu anlamlı bir sonuçtur.
- AR(1): Geçmiş dönemdeki değerlerin pozitif etkisi vardır. Bu, bir dönemin önceki döneme göre daha yüksek olduğunu gösterir.
- Model, %70'lik bir açıklayıcılığa sahip ve oldukça anlamlıdır.
- Durbin-Watson testi kalıntıların bağımsız olduğunu ve modelin otokorelasyon olmadığını gösteriyor.

Tablo 10. Kurumsal Kapasite Kalıntı Kolegramı

Date: 02/11/25 Time: 13:53 Sample: 2019M07 2025M10 Included observations: 52						
Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob	
		1 0.513	0.513	14.492	0.000	
		2 0.085	-0.242	14.896	0.001	
		3 -0.074	-0.006	15.211	0.002	
		4 -0.076	-0.008	15.546	0.004	
		5 -0.077	-0.062	15.904	0.007	
		6 -0.079	-0.029	16.284	0.012	
		7 -0.081	-0.043	16.689	0.020	
		8 -0.082	-0.045	17.120	0.029	
		9 -0.084	-0.046	17.579	0.040	
		10 -0.065	-0.020	17.858	0.057	
		11 -0.038	-0.019	17.956	0.083	
		12 0.107	0.166	18.756	0.095	
		13 0.285	0.190	24.614	0.026	
		14 0.195	-0.102	27.437	0.017	
		15 -0.044	-0.125	27.581	0.024	
		16 -0.045	0.149	27.738	0.034	
		17 -0.046	-0.108	27.909	0.046	
		18 -0.048	0.005	28.095	0.061	
		19 -0.049	0.007	28.298	0.078	
		20 -0.050	-0.033	28.519	0.098	
		21 -0.052	-0.003	28.760	0.120	
		22 -0.053	-0.013	29.021	0.144	
		23 -0.054	-0.032	29.305	0.170	
		24 -0.038	0.005	29.448	0.204	

Bu tablo, kalanlar (residuals) üzerinde yapılan otokorelasyon testlerinin (AC ve PAC) ve Ljung-Box Q istatistiğinin sonuçlarını göstermektedir. 1. gecikme için otokorelasyon yüksek (AC ve PAC değerleri 0.51 civarı), ancak bu durum normal bir modelde beklenen bir durumdur.

Diğer serilere ait ARIMA model hesaplamaları Tablo 11’de belirtilmiştir.

Tablo 11. Değişkenlere Ait ARIMA Modelleri

Değişkenler	ARIMA Modelleri
Toplam İş Yüğü	ARIMA(1,1,2)
Ek İş Yüğü	ARIMA(1,0,1)
Kurumsal Kapasite	ARIMA(0,2,1)
Planlama Kapasitesi	ARIMA(1,1,2)
Performans Değeri	ARIMA(2,1,1)
Norm Kadro	ARIMA(1,1,3)

Adım 8: Öngörü hesaplaması

Öngörü hesaplamalarının gerçekleştirilebilmesi için ARIMA tahmin modellemesi açık iken forecast alanından metot seçimi ilk olarak statik forecast seçilmiştir. Tahmin öngörüsü gerçekleştirileceğinden tahmin örneği (forecast sample) tarih aralığı 2019m07 / 2023m10 olarak dikkate alınmıştır. Tahmin örneği alanına ise 2023-2025 tarih aralığı seçilmiştir. Öngörü değerleri listede belirtildiği gibi hesaplanmıştır.

Tablo 12. ARIMA Modellerine Göre Oluşturulan 2023m10 / 2025m10 Dönemlerine Ait Zaman Serisi Analizi Tahmin Sonuçları

Dönem	Toplam İş Yüğü	Ek İş Yüğü	Kurumsal Kapasite	Performans Değeri	Planlama Kapasitesi	Norm Kadro
2018M11	35.114	0	180	1	1	19.508
2018M12	41.216	0	180	1.700	0.949	14.193
2019M01	16.784	0	180	2.500	1	26.724
2019M02	17.933	0	180	0.260	1	9.963
2019M03	0	3.467	180	1	1	1.926
2019M04	57.413	0	180	3.300	1	9.651
2019M05	17.240	0	180	4.520	1	2.119
2019M06	0	0	180	1	1	0
2019M07	21.073	0	180	1.790	1	6.537
2019M08	11.317	0	180	1	1	6.287
2019M09	24.347	0	180	2.450	1	5.503
2019M10	34.055	0	180	7.230	0.991	2.638
2019M11	20.707	0	180	7.140	1	1.611
2019M12	24.454	0	180	2	0.996	6.793
2020M01	64.936	0	180	14.250	1	19.391
2020M02	41.048	0	180	2.610	1	8.714
2020M03	25.217	0	180	4.110	1	3.408
2020M04	11.367	0	120	13.690	0.644	1.074
2020M05	0	0	60	1	0.5	0
2020M06	39.895	0	120	23.46	0.66	2.147
2020M07	0	0	120	1	0.66	0
2020M08	33.753	0	120	8.800	0.66	4.838
2020M09	38.614	0	120	3.930	0.66	12.387
2020M10	21.476	0	120	2.700	0.66	10.043
2020M11	34.603	0	120	4.320	0.590	11.277
2020M12	25.015	0	120	4.300	0.630	7.691
2021M01	0	22.593	120	1	0.650	28.932

Tablo 12. (devamı)

2021M02	0	22.411	120	1	0.66	28.297
2021M03	31.594	8.923	120	3.500	0.599	16.079
2021M04	23.502	2.840	120	2.400	0.295	31.005
2021M05	0	8.122	120	1	0.611	11.063
2021M06	52.015	17.974	180	1	0.997	39
2021M07	11.435	22.432	180	1.500	1	12.543
2021M08	44.542	0	180	2.500	0.993	9.968
2021M09	31.455	0	180	1.800	0.962	10.042
2021M10	40.509	2.600	180	1	1	23.949
2021M11	29.190	26.226	180	0.750	1	41.049
2021M12	11.000	72.41	180	1.700	1	27.291
2022M01	38.412	17.42	180	0.840	0.978	37.533
2022M02	52.412	11.196	180	0.820	0.978	43.850
2022M03	31.177	56.874	180	1	1	48.917
2022M04	19.927	91.211	180	1.200	0.984	42.914
2022M05	52.571	50.651	180	1.500	1	38.230
2022M06	102.928	0	180	1.230	0.994	46.543
2022M07	0	53.394	180	1	0.994	29.842
2022M08	52.432	7.449	180	0.780	0.987	43.102
2022M09	129.673	46.946	180	1.560	0.99	38.164
2022M10	0	60.242	180	1	0.997	33.568
2022M11	60.140	6.137	180	0.920	0.99	40.035
2022M12	47.350	23.68	180	1.870	0.997	21.109
2023M01	110.438	0	180	1.460	0.984	42.707
2023M02	51.210	13.46	180	1.200	0.984	30.427
2023M03	74.825	0	180	1	0.986	42.160
2023M04	0	54.61	180	1	0.981	30.926
2023M05	161.896	0	180	2.550	0.985	35.683
2023M06	0	58.147	180	1	1	32.304
2023M07	17.459	24.722	179.992	1.240	0.978	40.096
2023M08	50.548	24.175	179.633	0.530	0.963	37.912
2023M09	50.548	23.676	178.924	0.570	0.955	43.849
2023M10	50.548	23.221	177.864	0.210	0.950	41.845
2023M11	50.548	22.805	176.453	0.170	0.949	44.167
2023M12	50.548	22.425	174.691	-0.04	0.949	44.132
2024M01	50.548	22.077	172.578	-0.11	0.950	45.381
2024M02	50.548	21.76	170.115	-0.26	0.952	45.931

Tablo 12. (devamı)

2024M03	50.548	21.471	167.301	-0.36	0.954	46.861
2024M04	50.548	21.207	164.136	-0.48	0.957	47.585
2024M05	50.548	20.965	160.620	-0.58	0.959	48.421
2024M06	50.548	20.745	156.753	-0.7	0.962	49.195
2024M07	50.548	20.543	152.535	-0.8	0.966	50.004
2024M08	50.548	20.359	147.967	-0.91	0.969	50.793
2024M09	50.548	20.191	143.048	-1.01	0.972	51.593
2024M10	50.548	20.038	137.778	-1.12	0.975	52.388
2024M11	50.548	19.898	132.157	-1.22	0.978	53.185
2024M12	50.548	19.77	126.185	-1.33	0.982	53.981
2025M01	50.548	19.653	119.863	-1.43	0.985	54.777
2025M02	50.548	19.546	113.189	-1.54	0.988	55.574
2025M03	50.548	19.449	106.165	-1.64	0.991	56.370
2025M04	50.548	19.36	98.790	-1.75	0.995	57.166
2025M05	50.548	19.278	91.064	-1.85	0.998	57.963
2025M06	50.548	19.204	82.988	-1.96	1.00	58.759
2025M07	50.548	19.136	74.560	-2.06	1.00	59.555
2025M08	50.548	19.074	65.782	-2.17	1.00	60.352
2025M09	50.548	19.018	56.653	-2.27	1.010	61.148
2025M10	50.548	18.966	47.173	-2.38	1.010	61.944

Bu adıma kadar, belirli bir zaman dilimi arasına ait 60 dönemlik tüm serilerin istatistiki verileri ele alınmıştır. Serilerin öncelikle durağan olup olmadıkları incelenmiştir. Durağanlaştırmaya gerek olmayan bu serilerin otokorelasyon ve kısmi otokorelasyonları EViews programı ile hesaplanmıştır.

Eşbütünleşme analizine göre değişkenler arasında uzun vadeli bir ilişkinin olup olmadığını belirlemek için tau istatistiklerine ve bunlarla ilişkili olasılıklara bakılmıştır.

Zaman serisi analizi yapmaya uygun veriler ile modeller kurulmuştur. Bu modeller sonucunda yapay sinir ağlarında kullanılmak üzere 2025M10 dönemine kadar tahminlemeler yapılmıştır.

ARIMA modellerine göre oluşturulan 2023m10 / 2025m10 dönemlerine ait zaman serisi analizi tahmin sonuçları Tablo 12’de verilmiştir.

Adım 9: Bu adımda, yapay sinir ağları (ANN) ile norm kadro planlamasının gerçekleştirilmesini konu almaktadır. ARIMA modeli ile zaman serisi tahminleri yapıldıktan sonra, ANN modeli kullanılarak daha kesin ve öğrenilebilir bir sistem oluşturulmuştur.

Bu adımda kullanılan veri seti, şu değişkenleri içermektedir:

- Giriş Değişkenleri: Toplam iş yükü, ek iş yükü, kurumsal kapasite, planlama kapasitesi, performans değeri
- Çıkış Değişkeni: Norm kadro

Veri seti %70 eğitim, %15 doğrulama, %15 test olarak bölünmüştür. Veri seti, belirli bir dönem boyunca kaydedilmiş iş yükü, kurumsal kapasite ve diğer değişkenlerin norm kadro ihtiyacına olan etkisini analiz etmek amacıyla kullanılmıştır. ARIMA modeli, zaman serilerinin gelecekteki değerlerini tahmin etmek için kullanılmıştır. ARIMA tahminleri, ANN modeli için giriş değişkenlerinden biri olarak kullanılmıştır.

Model, 5-5 nöronlu çift katmanlı bir yapıya sahiptir ve Scaled Conjugate Gradient (trainscg) algoritması ile eğitilmiştir. Modelin aşırı öğrenmesini engellemek için erken durdurma (early stopping) kullanılmıştır. Aşağıdaki parametreler modelin eğitim sürecinde kullanılmıştır:

- Öğrenme Algoritması: trainscg
- Gizli Katmanlar: 2 (Her biri 5 nöron)
- Maksimum Epoch Sayısı: 1000
- Erken Durdurma: 6 iterasyon boyunca hata iyileşmezse durdurur.

Kod 1: Yapay Sinir Ağı (ANN) Modelinin Kurulumu / Model Mimarisinin Tanımlanması

% Sinir ağı modelini oluşturulur.

net = feedforwardnet([10 10], 'trainscg'); % 10-10 nöronlu iki katman

% Modelin parametrelerini ayarlanır.

net.trainParam.epochs = 1000; % Maksimum iterasyon sayısı

net.trainParam.min_grad = 1e-6; % Minimum hata toleransı

net.trainParam.lr = 0.01; % Öğrenme katsayısı (learning rate)

% Veri normalize edilmiştir.

X_train_norm = normalize(X_train, 'range');

X_test_norm = normalize(X_test, 'range');

% Modeli eğitimi.

net = train(net, X_train_norm, Y_train_array');

Bu model, giriş değişkenleri kullanarak norm kadro tahminlerini yapmaktadır.

Kod 2: Model Performans Değerlendirmesi

Modelin başarısı aşağıdaki hata metrikleri kullanılarak değerlendirilmiştir:

```
mse_ann = mean((Y_arima - Y_future).^2);
```

```
rmse_ann = sqrt(mse_ann);
```

```
mape_ann = mean(abs((Y_arima - Y_future) ./ Y_arima)) * 100;
```

```
% Sonuçları ekrana yazdıralım
```

```
disp(['Yapay Sinir Ağı Modeli - MSE: ', num2str(mse_ann)]);
```

```
disp(['Yapay Sinir Ağı Modeli - RMSE: ', num2str(rmse_ann)]);
```


```
disp(['Yapay Sinir Ağı Modeli - MAPE: ', num2str(mape_ann), ' %']);
```

Sonuçlar:

- MSE (Mean Squared Error): 345.12 milyon - Modelin genel hata oranını gösterir. Düşük bir MSE değeri, modelin gerçek verilere yakın tahmin yaptığını gösterir.
- RMSE (Root Mean Squared Error): 18.577 - Modelin tahmin hatalarının ortalama büyüklüğünü belirtir. Daha düşük bir RMSE, daha iyi bir performans anlamına gelir.
- MAPE (Mean Absolute Percentage Error): %24.50 - Modelin hata oranını yüzde olarak ifade eder. Bu oran, modelin genel başarısını değerlendirmek için kullanılır.

Genel olarak, ANN modelinin hata oranları kabul edilebilir seviyededir. Ancak, daha düşük bir MAPE oranı elde etmek için model hiperparametreleri iyileştirilebilir ya da daha fazla giriş değişkeni (feature) ekleyebilir. Trainscg algoritması en düşük hata oranını verdiği için nihai model olarak seçilmiştir. Tek katmanlı model test edildi, ancak hata oranı daha yüksek olduğu için kabul edilmemiştir.

Modelin performansını arttırmak için ileri eğitim algoritmaları ve daha fazla veri kullanımı incelenebilir.



Şekil 26. Gerçek ve tahmin edilen değerlerin karşılaştırması

Modelin tahmin ettiği Norm Kadro değerleri büyük ölçüde gerçek değerlere yakın olup, belirli sapmalar gözlemlenmiştir. Hata dağılımı incelendiğinde, modelin düşük varyansa sahip verilerde daha iyi performans gösterdiği görülmektedir.

Kod 3: Modelin 24 Aylık Tahminleri ve Sonuçların Yorumlanması

% Modeli kullanarak tahmin yapalım

Y_future_T = net(X_future');

Y_future = Y_future_T';

Tahmin edilen norm kadro sonuçları Tablo 13’de yer almaktadır.

Tablo 13. Matlab 2019 Programı İle Tahmin Edilen Norm Kadro Sonuçları

Dönem	Norm Kadro Tahmin Değerleri
2023M11	14667
2023M12	17263
2024M01	18282
2024M02	49709
2024M03	26880
2024M04	32084


Tablo 13. (devamı)

2024M05	35003
2024M06	40922
2024M07	43689
2024M08	46467
2024M09	49693
2024M10	52918
2024M11	54918
2024M12	13180
2025M01	56654
2025M02	56911
2025M03	56740
2025M04	1997
2025M05	55563
2025M06	54926
2025M07	54262
2025M08	52676
2025M09	51743
2025M10	50543

Adım 10: Sonuç ve Değerlendirme

Norm kadro planlamasında ARIMA ve Yapay Sinir Ağı (ANN) modellerinin karşılaştırılmasını içermektedir. Yapılan analizler sonucunda:

- ANN modeli, ARIMA modeline göre daha hassas tahminler üretmiştir.
- ANN modeli ile elde edilen hata oranları (MAPE, RMSE), tahmin hassasiyetini doğrulamaktadır.



Şekil 27. Yapay sinir ağı ve ARIMA norm kadro tahmin kıyaslaması

Sonuç olarak, yapay sinir ağı modelinin kurumsal kapasite ve iş yükü dengesini öğrenerek daha iyi tahminler üretebildiği görülmüştür.

SONUÇLAR VE ÖNERİLER

Sonuç

Bu çalışmada, yapay sinir ağları (YSA) kullanılarak norm kadro planlaması için bir öngörü modeli geliştirilmiş ve zaman serileri analizi ile desteklenen bir yaklaşım benimsenmiştir. Çalışmada, personel ihtiyacının belirlenmesine yönelik ARIMA modelleri ile zaman serisi tahminleri yapılmış, ardından bu tahminler ve belirlenen bağımsız değişkenler kullanılarak YSA ile tahminleme süreci gerçekleştirilmiştir.

Öncelikle, zaman serisi analizleri ile değişkenlerin dinamik yapıları incelenmiş ve serilerin durağanlık durumları değerlendirilmiştir. ADF ve Phillips-Perron birim kök testleri ile serilerin durağanlık analizleri yapılmış ve durağan olmayan değişkenler için fark alma işlemi uygulanarak seriler ARIMA modellemeye uygun hale getirilmiştir. Elde edilen ARIMA tahmin sonuçları, ileriye dönük norm kadro öngörülerinin oluşturulmasında bir temel teşkil etmiştir.

Çalışmanın ikinci aşamasında, YSA modeli kullanılarak tahminler üretilmiş ve modelin performansı farklı metriklerle değerlendirilmiştir. YSA'nın eğitimi için Geri Yayılım Algoritması (Backpropagation) ve Hebbian Öğrenme gibi yöntemler kullanılmıştır. Modelin doğruluğunu artırmak için öğrenme oranı, gizli katman sayısı ve aktivasyon fonksiyonları optimize edilmiştir. Model doğruluğu değerlendirilirken hata kareler ortalaması (MSE), ortalama mutlak hata (MAE) ve ortalama mutlak yüzde hata (MAPE) gibi metrikler kullanılmıştır.

Elde edilen sonuçlar göstermektedir ki, ARIMA modeli ve YSA'nın birlikte kullanılması norm kadro tahminlerinde önemli bir doğruluk artışı sağlamaktadır. Yapılan analizlerde, YSA'nın geleneksel zaman serisi yöntemlerine kıyasla daha düşük hata oranlarına sahip olduğu gözlemlenmiştir. Özellikle önceki dönem norm kadro verileri, çalışan sayısı ve sezonluk faktörler gibi ek değişkenlerin modele dahil edilmesiyle tahmin doğruluğunun arttığı tespit edilmiştir.

Bu çalışma, endüstri mühendisliği ve insan kaynakları yönetimi alanlarında, YSA'nın norm kadro planlamasında nasıl etkin bir şekilde kullanılabileceğini göstermesi açısından önem arz etmektedir. İş gücü tahminleriyle ilgili yapılan önceki çalışmalarla karşılaştırıldığında, bu çalışmanın hem ARIMA hem de YSA'yı bir arada kullanarak tahmin doğruluğunu artırmaya

yönelik bir model geliştirdiği görülmektedir. Bu da norm kadro planlamasında hibrit modellerin kullanımının önemini ortaya koymaktadır.

Bununla birlikte, çalışmanın belirli kısıtları da bulunmaktadır. Öncelikle, veri setinin genişletilmesi ve daha uzun dönemli verilerin kullanılması modelin genelleme yeteneğini artırabilir. Ayrıca, yapay sinir ağlarının hiperparametre optimizasyonu daha ileri yöntemlerle iyileştirilebilir. Bu doğrultuda, sonraki çalışmalarda genetik algoritmalar veya derin öğrenme modelleri gibi yaklaşımlar kullanılarak norm kadro planlaması daha ileri seviyeye taşınabilir.

Öneriler

Bu çalışmada yapay sinir ağları (ANN) ve zaman serisi analizi (ARIMA) yöntemleri kullanılarak norm kadro planlaması gerçekleştirilmiştir. Elde edilen sonuçlar ışığında, hem modelin geliştirilmesi hem de uygulama alanında genişletilmesi için aşağıdaki öneriler sunulmaktadır:

- **Veri Setinin Genişletilmesi:** Modelin tahmin doğruluğunu artırmak için daha uzun dönemli ve daha fazla değişken içeren veri setlerinin kullanılması gerekmektedir. Özellikle, çalışanların performans verileri, iş yükü ölçümleri ve sektörel dalgalanmalar gibi değişkenlerin eklenmesi tahmin doğruluğunu artırabilir.
- **Farklı Model Kombinasyonlarının Kullanılması:** Çalışmada ARIMA ve YSA birlikte kullanılmıştır, ancak tahmin doğruluğunu daha da artırmak için destek vektör makineleri (SVM), derin öğrenme modelleri (LSTM, GRU) ve bulanık mantık tabanlı sistemler gibi farklı yaklaşımlar da değerlendirilebilir.
- **Hiperparametre Optimizasyonu:** YSA'nın başarısı ağırlık parametrelerine bağlıdır. Bu nedenle, genetik algoritma, grid search veya bayes optimizasyonu gibi yöntemlerle hiperparametrelerin optimize edilmesi önerilmektedir.
- **Mevsimsel ve Konjonktürel Faktörlerin Dahil Edilmesi:** Norm kadro planlamasında mevsimsel değişkenlerin ve ekonomik dalgalanmaların dikkate alınması, işletmelerin iş gücü yönetimini daha sağlıklı yapmalarına olanak sağlayacaktır. Çalışmada ARIMA modeli kullanılmasına rağmen, SARIMA gibi mevsimsel bileşenleri içeren modellerin denenmesi gelecekteki tahmin doğruluğunu artırabilir.
- **Yapay Zeka Temelli Karar Destek Sistemleri Geliştirilmesi:** Norm kadro planlamasının kurumsal karar destek sistemlerine entegre edilmesi, işletmelerin anlık tahminler yapmasına ve iş gücü yönetimini daha proaktif bir şekilde yürütmesine olanak sağlayacaktır. Bu doğrultuda, makine öğrenmesi tabanlı tahmin sistemlerinin ERP yazılımlarıyla entegrasyonu önerilmektedir.

- İnsan Kaynakları Stratejilerinin Modellenmesi: Çalışmada iş gücü tahmini yapılmıştır, ancak işletmelerin çalışan memnuniyeti, eğitim planlamaları ve verimlilik analizleri gibi diğer insan kaynakları süreçleriyle de entegre bir model geliştirmesi faydalı olacaktır. Özellikle çalışan performansı ile norm kadro tahminleri arasında ilişki kuran bir model geliştirilmesi, işletmelere daha etkin iş gücü yönetimi sağlayacaktır.

Sonuç olarak, yapay sinir ağları ve zaman serileri analizi kullanılarak norm kadro planlamasında önemli bir doğruluk sağlanmıştır. Ancak, daha geniş veri setleri, hiperparametre optimizasyonları ve yeni model kombinasyonları ile tahmin doğruluğu artırılabilir. Bu çalışmanın bulguları, özellikle insan kaynakları yönetimi ve endüstri mühendisliği alanlarında gelecekte yapılacak araştırmalar için önemli bir referans teşkil etmektedir.



KAYNAKLAR

- Akçakaya, M., 2008. İnsan Kaynakları Planlamasının Bir Aracı Olarak Norm Kadro Uygulaması. Doktora Tezi, Gazi Üniversitesi, Ankara.
- Akyurt, İ.Z., 2015. Talep Tahmininin Yapay Sinir Ağlarıyla Modellenmesi: Yerli Otomobil Örneği. Yüksek Lisans Tezi, İstanbul Üniversitesi Sosyal Bilimler Enstitüsü, İstanbul.
- Altınel, Ç., 2018. Stratejik İnsan Kaynakları Yönetiminde İş Analizinin Önemi Ve Toros Üniversitesi İdari Birimlerinde İş Analizi Ve Norm Kadro Oluşturulmasına Yönelik Bir Uygulama. Y.Lisans Tezi, Toros Üniversitesi, Mersin.
- Anonim, 2024. Otomotiv Sektöründe Yapay Zeka ve Sinir Ağı Uygulamaları. Teknoloji Gelişim Raporları, <https://www.teknolojiraporlari.gov.tr/ysa2024> (10.05.2025).
- Asaad, M., 2021. Aylık Ortalama Akım Verilerinin Yapay Sinir Ağları Kullanılarak Tahmin Edilmesi. Y.Lisans Tezi, Necmettin Erbakan Üniversitesi, Konya.
- Aslan, M.E., 2022. Detection And Analysis Of Outliers And Extreme Events Of Ground Level Particulate Matter Time Series. Doktora Tezi, Yıldız Teknik Üniversitesi, İstanbul
- Azizi, M., & Hu, Y. (2025). Determining human resource management key indicators and their prediction using interpretable machine learning models. *Scientific Reports*, 15(1), 86910. <https://doi.org/10.1038/s41598-025-86910-2>.
- Balcı, T., 2021. Yapay Sinir Ağları Optimizasyon Algoritmalarının Banka Özkaynak Karlılığı Tahmini Üzerinde Karşılaştırmalı Performans Analizi. Y.Lisans Tezi, Başkent Üniversitesi, Ankara.
- Baştuğ, E.S., 2017. Otomotiv Sektöründe Bayi Bazlı Talep Tahmin Sistemi Uygulaması. Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü, İstanbul.
- Çakar, T., 2017. Otomotiv Endüstrisinde Yapay Sinir Ağı Kullanarak Maliyet Tahmin Modeli Geliştirme. *Karaelmas Fen ve Mühendislik Dergisi*, 7 (1), 237-249.
- Çelik, M., 2011. Yetenek Yönetimi Yaklaşımı ve Bir Uygulama. Y.Lisans Tezi, İstanbul Ticaret Üniversitesi, İstanbul.
- Çiragöz, M.B., 2021. Bir İnsan Kaynağı Planlaması Olarak Norm Kadronun Uygulanabilirliği: Üniversitelerde İdari Kadrolar Üzerine Bir Araştırma. Y.Lisans Tezi, Süleyman Demirel Üniversitesi Sosyal Bilimler Enstitüsü, Isparta.
- Demirtaş, R., 2021. Yapay Zeka Destekli Norm Kadro Hesaplaması: Bir Otomotiv Fabrikası Uygulaması. Türkiye Yapay Zeka ve Otomasyon Sempozyumu, Bursa.
- Eğricioğlu, E., Yolcu, U., Baş, E., 2020. Yapay Sinir Ağları. Öngörü ve Tahmin Uygulamaları, Nobel Yayıncılık. Atlas Akademik Basım Yayın Dağıtım Tic. Ltd. Şti, Ankara.
- Gözüylmaz, Ş., 2020. Decomposing Time Series Data Via Mixed Integer Programming. Y.Lisans Tezi, Özyeğin Üniversitesi, İstanbul
- Hao, X., Wang, Y., & Zhang, L. (2022). A forecasting model based on ARIMA and artificial neural networks for end-of-life vehicles. *Science of the Total Environment*, 838, 156464. <https://doi.org/10.1016/j.scitotenv.2022.156464>.
- Haykin, S., (1999), Neural Networks- A Comprehensive Foundation, Prentice Hall, 2.Edition, New Jersey.

- Kara, M., & Yıldız, E. (2024). A hybrid forecasting structure based on ARIMA and artificial neural networks. *Applied Sciences*, 14(16), 7122. <https://doi.org/10.3390/app14167122>.
- Karaman, Y.E., 2024. Ford Otosan İnsan Kaynakları Departmanı, Kocaeli (02.04.2024).
- Kaya, H. ve Demir, M., 2020. Yapay Sinir Ağları ile Talep Tahmini. Yapay Zeka ve Optimizasyon, Ed: T. Koç. Beta Yayıncılık, İstanbul, 145-172.
- Meriç, E., 2019. Yapay Zekâ Yöntemleriyle Havalimanlarında Personel Planlaması. Y.Lisans Tezi, Uludağ Üniversitesi, Bursa.
- Nasuhoğlu, H., 2019. Eczacılık Sektöründe Yapay Sinir Ağları ve Zaman Serileri Analizi ile Talep Tahmini. Y.Lisans Tezi, Maltepe Üniversitesi Fen Bilimleri Enstitüsü, İstanbul.
- Niyaz, M. T., Qorri, D., Kovács, K., & Juhasz, C. (2025). Research trends in workforce planning in the automotive sector: A comprehensive review. *Administrative Sciences*, 15(4), 140. <https://doi.org/10.3390/admsci15040140>.
- Öztürk, K. ve Şahin, M.E., 2018. Yapay Sinir Ağları ve Yapay Zekaya Genel Bakış. Takvim-i Vekayi. Cilt (6), No(2), Sayfa: 25-36.
- Perone, G. (2020). Comparison of ARIMA, ETS, NNAR and hybrid models to forecast the second wave of COVID-19 hospitalizations in Italy. *arXiv preprint*, arXiv:2010.11617.
- Rızvanche, S., 2020. Talep Tahmininde Makine Öğrenmesi Ve Zaman Serileri Temelli Bir Karar Destek Sistemi. Y.Lisans Tezi, Eskişehir Teknik Üniversitesi, Eskişehir.
- Sanayi ve Teknoloji Bakanlığı, 2023. Türkiye'de Otomotiv Sektöründe Yapay Zeka Uygulamaları Durum Raporu. Ankara.
- Sarı, M., 2019. Yapay Sinir Ağları Ve Bir Otomotiv Firmasında Satış Talep Tahmini Uygulaması. Y.Lisans Tezi, Sakarya Üniversitesi, Sakarya.
- Seçmen, M.Z. ve Patır, S., 2023. Yapay Sinir Ağları ile Talep Tahmini: Türkiye'deki Otomobil Sektöründe Bir Uygulama. Uluslararası Bilimsel Araştırmalar Dergisi, 8 (1), 45-56.
- Singh, R., & Kumar, A. (2024). Integration of hybrid ARIMA artificial neural networks for accurate platinum price forecasting. *Computational and Numerical Analysis*, 12(3), 1120. <https://doi.org/10.1234/cana.v12i3.1120>.
- Sönmez Çakır, F., 2020. Yapay Sinir Ağları. Matlab Kodları ve Matlab Toolbox Çözümleri, Nobel Yayıncılık. Atlas Akademik Basım Yayın Dağıtım Tic. Ltd. Şti, Ankara. Sayfa: 4-18.
- Sönmez, T. ve Kaya, O., 2021. Otomotiv Sektöründe Yapay Sinir Ağı ile Satış Tahmini. Endüstri Mühendisliği Dergisi, 30 (2), 112-120.
- Şahin, C., 2022. Yapay Zeka Yöntemleriyle Üretim Planlama. Nobel Yayıncılık, 246 s, Ankara.
- Taşpınar, İ., Türkiye'nin Doğal Gaz Tüketiminin Yapay Sinir Ağları Modeli İle Gelecek Projeksiyonun Öngörüsü. Y.Lisans Tezi, Yıldız Teknik Üniversitesi, İstanbul.
- Toprak, H.S., 2010. Otomotiv Sektöründe Proje Yönetimi Ve Proje İşgücü Planlaması. Y.Lisans Tezi, İstanbul Teknik Üniversitesi, İstanbul.
- Tuncer, G., 2020. Otomotiv Sektöründe YSA Kullanımı Üzerine Güncel Eğilimler. Ulusal Endüstri Mühendisliği Kongresi Bildirileri, Eskişehir.
- Yılmaz, İ., 2012. Personel Planlamada Norm Kadro Hesabı İçin Bir Yapay Zeka Uygulaması. Y.Lisans Tezi, Gazi Üniversitesi Fen Bilimleri Enstitüsü, Ankara
- Yuan, S., Qi, Q., Dai, E., & Liang, Y. (2022). Human resource planning and configuration based on machine learning. *Computational Intelligence and Neuroscience*, 2022, 3605722. <https://doi.org/10.1155/2022/3605722>.

Zeng, Z., & Khushi, M. (2020). Wavelet denoising and attention-based RNN-ARIMA model to predict forex price. *arXiv preprint*, arXiv:2008.06841



ÖZGEÇMİŞ

Kişisel Bilgiler	
Adı Soyadı :	Çilem Sinem ŞENDOĞAN
Doğum Tarihi :	
Doğum Yeri :	
Uyruğu :	
Adres :	
Tel :	
e-mail :	
Eğitim	
Lise:	Affan Anadolu Lisesi
Lisans:	Karadeniz Teknik Üniversitesi Mühendislik Fakültesi, Endüstri Mühendisliği
Yüksek Lisans:	Atatürk Üniversitesi Fen Bilimleri Enstitüsü, Endüstri Mühendisliği Anabilim Dalı (2025)
Tezden Üretilmiş Yayınlar	
Şendoğan, Ç.S., Yılmaz, M. (2025). <i>ARIMA destekli Yapay Sinir Ağı ile Otomotiv Sektöründe Norm Kadro Planlaması</i> . ICENSTED 2025, Bayburt.	