

TOBB EKONOMİ VE TEKNOLOJİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**BİR YÜKSEK HIZLI TREN HATTINDA YOLCU SAYISI
TAHMİN MODELLERİ GELİŞTİRİLMESİ**

YÜKSEK LİSANS TEZİ

Beyza Nur ERTEM

Endüstri Mühendisliği Anabilim Dalı

Tez Danışmanı: Doç. Dr. Kadir ERTOĞRAL

TEMMUZ 2020

TEZ BİLDİRİMİ

Tez içindeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edilerek sunulduğunu, alıntı yapılan kaynaklara eksiksiz atıf yapıldığını, referansların tam olarak belirtildiğini ve ayrıca bu tezin TOBB ETÜ Fen Bilimleri Enstitüsü tez yazım kurallarına uygun olarak hazırlandığını bildiririm.

Beyza Nur Ertem



ÖZET

Yüksek Lisans

Bir Yüksek Hızlı Tren Hattında Yolcu Sayısı

Tahmin Modelleri Geliştirilmesi

Beyza Nur Ertem

TOBB Ekonomi ve Teknoloji Üniversitesi

Fen Bilimleri Enstitüsü

Endüstri Mühendisliği Anabilim Dalı

Danışman: Doç Dr.Kadir Ertoğral

Tarih: Temmuz 2020

Doğru ve güvenilir talep tahminleri firmaların etkinliğini artırmasında önemli rol oynamaktadır. Her sektörde olduğu gibi gıda sektöründe de talep tahminleri konusu büyük önem arz etmektedir. Özellikle raf ömrü bir günlük olan gıdalarda fazla atık oluşmasını önlemek doğru sipariş tahminlerinin yapılması şarttır.

Çalışmamızda Türkiye Cumhuriyeti Devlet Demir Yolları'nın alt yüklenicisi olarak çalışan, yüksek Hızlı Trenlere yemek servisi sağlayan bir firma için yemek siparişlerinde belirleyici olan yolcu sayılarının tahmini için bir yaklaşım geliştirilmiştir. İlk aşama olarak günlük sipariş sisteminin kurulması amaçlanmış ve firmanın 2016 ve 2019 yılları arasındaki verileri kullanılarak yüksek hızlı trenlerin Ankara-İstanbul, İstanbul-Ankara güzergâhı arası hareket eden trenlerinin “business plus” ve “ekonomi plus” vagonlarında seyahat eden yolcu sayılarının çoklu regresyon modeliyle tahmin edilme konusu çalışılmıştır. Yolcu sayılarının iyi tahmini günlük yemek siparişlerinin daha doğru yapılmasını sağlayacak ve firmanın finansal kazancına dönüşecektir. Çalışmamızda veri gruplama ve regresyon model değişkenlerinin seçimlerinin farklı şekilde yapılmasına dayalı olarak çok sayıda tahmin modeli denenmiştir. Denenen modeller arasından seçilen en iyi üçü için ortalama mutlak hata hesaplanarak sonuçta yolcu sayıları için oldukça etkin tahmin model alternatifleri geliştirilmiştir. İkinci aşamada ise yine aynı tren verileri

kullanılarak haftalık yemek sipariřinin verildiđi durumlarda kullanılmak üzere haftalık yemek tüketim miktarlarının tahmini için Winters üstel düzeltme modeli üzerine çalışılmış ve tahminlerin güvenilirliđi mutlak hata ortalama yöntemi ile test edilmiştir.

Anahtar Kelimeler: Talep tahmini, Çoklu doğrusal regresyon, Tren yolcu sayısı tahmini, Winters üstel düzeltme



ABSTRACT

Master of Science
Developing Forecasting Models For Estimating The Number of Passengers on a
High Speed Train Line.

Beyza Nur Ertem

TOBB University of Economics and Technology

Institute of Natural and Applied Sciences

Department of Industrial Engineering

Supervisor: Assoc. Prof. Kadir Ertoğral

Date: July 2020

Correct and reliable order forecasting has an important role in increasing the efficiency of companies. Similar to other sectors, the demand forecasts are very important in Food industry. Especially in one day shelf life products, it is a must to make accurate order forecast and prevent food waste excess.

In this study an approach is developed for forecasting the passenger numbers in the the high speed train leg between Ankara and İstanbuls. The firms is a subcontractor to The Republic of Turkey State Railways. As a first step, it was aimed to create a daily order system and the forecasting with multiple regression of the passenger numbers who traveled Ankara-İstanbul and İstanbul-Ankara route in ‘Business Plus’ and ‘Economy Plus’ coaches using data from a catering company between 2016-2019 year. The accurate Passenger number estimation will create a better meal order and will lead into a financial savings. In our study several forecasting models are constructed based on different ways of data groping and the choices of independent regression variables. We selected the best three models among the models develop and we found the mean absolute percent error performance for selected models, which turn out to be quite accurate. In the second stage our study, using the same passenger data the Winters exponential smoothing method is studied to forecast the weekly meal consumption and the forecast accuracy is tested using MAPE values.

Key Words: Demand forecast, Multiple linear regression method, Passenger numbers forecast.

TEŞEKKÜR

Çalışmalarım boyunca değerli yardım ve katkılarıyla beni yönlendiren hocam Doç.Dr. Kadir Ertoğral'a, yüksek lisans yapmaya karar verdiğim andan itibaren arkamda duran ve her konuda bana destek olan çok sevdiğim yöneticim Cremonini Grup tren bölümü genel müdürü Nabil Joseph Zaidan'a, tez yazma aşamasında bütün kahrımı çeken, hep yanımda olan sevgili eşime, arkadaşlarıma ve destekleriyle her zaman yanımda olan hayattaki en büyük şansım aileme çok teşekkür ederim.



İÇİNDEKİLER

ÖZET	iv
ABSTRACT	vi
İÇİNDEKİLER	viii
ŞEKİL LİSTESİ	ix
ÇİZELGE LİSTESİ	x
KISALTMALAR	xi
SEMBOL LİSTESİ	xii
1.1 Tezin Amacı Ve Problemin Tanımı	2
1.3 Türkiye’de Tren İçi Yiyecek İçecek Servisinin Tarihi Gelişimi	5
1.4 Yüksek Hızlı Trenlerde Yiyecek İçecek Servisi	6
1.5 Günlük Yemek Siparişi Sistemi	8
2. LİTERATÜR ARAŞTIRMASI	13
3. TALEP TAHMİNİ ve TAHMİN YÖNTEMLERİ	19
3.1 Talep Tahmini	19
3.2 Talep Tahminin Aşamaları	20
3.3 Çalışmada Kullanılan Tahmin Yöntemleri	20
3.3.1 Regresyon analizi	20
3.3.1.1 Regresyon modelleri	22
3.3.1.2 En küçük kareler tekniği	23
3.3.1.3 Regresyon analizinin güvenilirliği ve anlamlılığı	25
3.3.1.4 Regresyon analizinin uygunluğunun değerlendirilmesi	28
3.3.2 Winters üstel düzeltme yöntemi	29
4. ÇOKLU DOĞRUSAL REGRESYON YÖNTEMİYLE GÜNLÜK SİPARİŞ SİSTEMİ İÇİN YOLCU SAYISI TAHMİNİ	33
4.1 Veri Seti	33
4.2 Yöntem	33
4.2.1 Veri gruplaması	34
4.2.1.1 Gün bazlı modelleme yaklaşımı	34
4.2.1.2 Trenlerin kalkış zamanına göre kalan süre itibariyle gruplanması	34
4.2.1.3 Dönemsel gruplama	36
4.2.2 Çoklu regresyon modelleri geliştirilmesi	36
4.2.3 Regresyon modellerin sonuçlarının karşılaştırılması	37
4.2.4 Regresyon analizi ve sonuç çizelgeleri	39
4.2.5 Seçilen regresyon modellerinin geçerliliği	46
4.2.6 Seçilen regresyon modelleri için tahmin MAPE analizi	48
5. WINTERS ÜSTEL DÜZELTME YÖNTEMİYLE HAFTALIK SİPARİŞ İÇİN HAFTALIK YOLCU SAYISI TAHMİNİ	51
5.1 Yöntem	51
5.1.1 Winters üstel düzeltme yöntemi tahmin sonuçları	52
5.1.2 Winters üstel düzeltme yöntemi modelleri için tahmin MAPE analizi	55
6. SONUÇLAR	57
KAYNAKLAR	59
EKLER	62
ÖZGEÇMİŞ	76

ŞEKİL LİSTESİ

Sayfa

Şekil 1.1 : 2003 -2018 Demiryolları toplam yolcu sayısı.....	4
Şekil 1.2 : 2009-2018 YHT yolcu sayıları bin kişi.....	5
Şekil 3.1: Doğrusal ve doğrusal olmayan regresyon örnekleri.....	23
Şekil 4.1:Tren hareket saatine göre verilerin gruplanması.....	35
Şekil 4.2: Regresyon analizi temel gruplama.....	37
Şekil 4.3: Regresyon modelleri r-kare karşılaştırması.....	43
Şekil 4.4: Bir güne ait regresyon analizi uygunluk grafikleri.....	46
Şekil 4.5: Regresyon modelleri r-kare karşılaştırması.....	47
Şekil 4.6 : Gruplandırılmamış 2 BD mevsimsel RM karşılaştırma.....	49
Şekil 5.1: Bir tren için yolcu sayısı dağılımı Ocak 2017- Ağustos 2019.....	49
Şekil 5.2: Ocak 2017- Mayıs 2019 Model 1(126 periyod) tahmin analizi.....	51
Şekil 5.3: Ocak 2017- Haziran 2019 Model 2 (130 periyod) tahmin analizi.....	52
Şekil 5.4: Ocak 2017- Temmuz 2019 Model 3 (134 periyod) tahmin analizi.....	52
Şekil 5.5: Tahmin sonuçları ile gerçekleşen değerlerin karşılaştırılması.	54

ÇİZELGE LİSTESİ

Sayfa

Çizelge 1.1: YHT güzergâhlarına göre yolcu sayısı.....	5
Çizelge 4.1: Bir gün için gruplandırılmadan kullanılan veri örneği.....	35
Çizelge 4.2: Yıllık iki ve üç bağımsız değişkenli regresyon modeli r-kare değeri.....	39
Çizelge 4.3: Mevsimsel iki bağımsız değişkenli regresyon modeli r-kare değeri.....	39
Çizelge 4.4: Mevsimsel üç bağımsız değişkenli regresyon modeli r-kare değeri.....	39
Çizelge 4.5: Aylık iki bağımsız değişkenli regresyon modeli r-kare değeri.....	40
Çizelge 4.6: Aylık üç bağımsız değişkenli regresyon modeli r-kare değeri.....	40
Çizelge 4.7: Yıllık iki ve üç bağımsız değişkenli regresyon modeli r-kare değeri.....	41
Çizelge 4.8: Mevsimsel iki bağımsız değişkenli regresyon modeli r-kare değeri.....	41
Çizelge 4.9: Mevsimsel üç bağımsız değişkenli regresyon modeli r-kare değeri.....	41
Çizelge 4.10: Aylık iki bağımsız değişkenli regresyon modeli r-kare değeri.....	41
Çizelge 4.11: Gruplandırılmış aylık üç BD regresyon modeli r-kare değeri.....	42
Çizelge 4.12: Tüm modeller için r-kare ve f değerleri.....	42
Çizelge 4.13: Gruplandırılmamış mevsimsel 2BD regresyon denklemleri.....	44
Çizelge 4.14: Gruplandırılmamış yıllık iki ve üç BD regresyon denklemleri.....	45
Çizelge 4.15: Seçilen modellerin VIF değerleri.....	46
Çizelge 4.16: Regresyon modellerine ait MAPE sonuçları.....	48
Çizelge 5.1: Üç modele ait mevsimsel faktörler.....	50
Çizelge 5.2: Üç modele ait kesim noktası ve eğim değerleri.....	51
Çizelge 5.3: Üç model için tahmin ve gerçekleşen değerlerin karşılaştırılması	53
Çizelge 5.4: Modellere ait MAPE sonuçları.....	54

KISALTMALAR

MAPE	: Mutlak Ortalama Hata (Mean Absolute Percentage Error)
YHT	: Yüksek Hızlı Tren
BD	: Bağımsız Değişken
BHÖYS	: Bir Hafta Önceki Yolcu Sayısı
OYS	: Ortalama Yolcu Sayısı
SAYS	: Sipariş Anındaki Yolcu Sayısı
TCDD	: Türkiye Cumhuriyeti Devlet Demiryolları
VIF	: Varyans Büyütme Faktörü (variance inflation factor)
ARIMA	: Otoregresif Hareketli Ortalamalar Modelidir.
SYS	: SonYolcu Sayısı

SEMBOL LİSTESİ

Bu çalışmada kullanılmış olan simgeler açıklamaları ile birlikte aşağıda sunulmuştur.

Simgeler	Açıklama
b_i	Ana kütle tahminlerinin parametreleri
b	Tahmin edilen kısmi regresyon katsayıları
\hat{y}	Bağımlı değişken
x	Bağımsız değişken
e_j	j parametreleri için hata terimini
x_{ij}	Bağımsız değişkenler
y	Bağımlı değişken
j	Birim değerlerinin sıra numarası
B	Bilinmeyen anakütle parametreleri
r	Korelasyon Katsayısı
r^2	Determinasyon Katsayısı
S_T	Bir sonraki (gelecek) dönemin tahmini
S_{T-1}	Son döneme ait yapılan tahmin
Z_T	Son döneme ait gerçek değer
α	Düzleştirme katsayısı
S_i	i periyodunun kesim noktası
G_i	Eğim
c_t	Mevsimsel faktör

1. GİRİŞ

Ulaştırma bir ülkenin siyasi, sosyal, kültürel ve ekonomik hayatına büyük etki eden bir olgudur. Gelişmiş bir ulaşım ağına sahip olan ülkeler kaynaklarını iyi işler ve değerlendirir iç ve dış ticarete gelişir. Özellikle demiryolu ulaşım sistemleri açısından önemi giderek artan toplu, taşımacılık anlayışının ilk ve en önemli unsurudur. Ülkemizde de demir yolu son yıllarda sürdürülebilir kalkınma hamlelerinin en önemli halkalarından biri olarak görülmüş ve bu sektörü canlandırmak için yoğun çaba sarf edilmiştir. 2009 yılından itibaren TCDD 'ye bağlı yüksek hızlı trenler ekspres trenlerle beraber demiryollarımızda hareket etmeye başlamıştır. Günümüzde yüksek hızlı trenler Ankara, İstanbul, Konya ve Eskişehir güzergâhlarında hareket etmektedir. Yüksek hızlı trenler ekspres trenlerden hem daha konforlu ve hızlı bir yolculuk imkânı sağlamaktadır. Ayrıca Yüksek hızlı trenlere ekspres trenlerden farklı olarak business, business plus ve ekonomi plus vagonlarına sahiptir. Yüksek Hızlı Tren ağlarının yapımının tamamlanması demiryoluna olan talebin artmasına sebep olmuştur. Yüksek hızlı trenlere olan talebin artması trenlerde yolculara verilen hizmetlerinde değişip gelişmesini sağlamıştır. Trenlerde verilen hizmetlerden biri olan yemek servisi Türkiye'de Cumhuriyet'in ilk yıllarında Haydarpaşa Ankara arasında ilk yataklı-yemekli vagonlu ekspres trenlerin denenmesi ile başlamıştır. İlk dönemlerde restoran özelliği gösteren yemekli vagonların ilerleyen zamanla beraber işletme şekli ve özelliği değişiklik göstermiştir. Yüksek hızlı tren yapılarının ekspres trenlerden farklı olması bu trenlerde yemek servisinin değiştirilmesini zorunlu kılmıştır ve yolculara business plus ve ekonomi plus vagonlarında koltuklarında taze yemek servisi yapılmaya başlanmıştır. Vagonlarda servisi yapılan yemeklerin, önceden tahmin edilen yolcu sayılarına göre günlük (kısmen iki gün öncesinde) siparişi verilmekte ve tren kalkış saatinde yakın bir saatte, belirlenen son yolcu sayısına göre yemeklerin trene yüklenmesi yapılmaktadır.

Üretilen ürün ve hizmetlerle ilgili talebin, güvenilir veriler kullanılarak mümkün olan en az sapma ile tahmin edilmesi, işletmeler için bir ihtiyaçtır. Talebin sağlıklı bir şekilde tahmin edilememesi durumunda ya trenlere yeterli miktarda yemek yüklenemeyecek ki bu da hem yolcu şikâyetine hem de eksik yemek yüklemekten dolayı firma için ceza maliyetine sebep olacak, ya da fazla yemek siparişi ile hem depolama maliyetinin hem de atık maliyetinin artmasına sebep olacaktır.

Talep tahmin modelleri ulařım sektöründe kullanılan önemli yönetsel araçlardandır. Gelecek talepleri tahmin etme ihtiyacını gidermek için günümüzde çeřitli tahmin teknikleri kullanılmaktadır. Talep tahminine yönelik kullanılan teknikler, birbirinden farklı sonuçlar vermekle birlikte, gelecekteki deęerleri tam olarak tahmin edememeleri genel ortak özellikleridir ve tahmin hatasının azaltılması model geliştirilirken ana amaçtır.

Bu çalışmanın temel amacı çoklu regresyon modeli kullanarak yüksek hızlı trenlerin Ankara-İstanbul güzergâhı arasında business ve ekonomi plus vagonlarında seyahat eden yolcu sayılarının tahmini için çoklu regresyon model yaklaşımına dayalı tahmin modeli geliřtirmesi ve bu tahmin modeline göre günlük sipariř sisteminin oluşturulmasına alt yapı hazırlanmasıdır. Dięer bir amacı ise business plus ve ekonomi plus vagonları için haftalık yemek sipariři verilmesi durumunda Winters üstel düzeltme yöntemi ile tahmin modelinin geliştirilmesi ve haftalık sipariř sisteminin kurulmasıdır.

Çalışmanın birinci bölümünün geri kalanında Türkiye’de demiryolu ve tren içi yiyecek içi servisinin tarihi ve řu anki yemek ve sipariř sisteminin nasıl olduęu anlatılmıřtır. İkinci bölümde ilgili literatür verilmiřtir. Üçüncü bölümde kullanılan tahmin yöntemleri ile ilgili bilgi verilmiřtir. Dördüncü ve beřinci bölümleri uygulamanın anlatıldıęı bölümlerdir ve hem regresyon analizi hem de Winters üstel düzeltme yönteminin aşamaları anlatılmıřtır. Son bölümde genel bir deęerlendirme verilmiřtir.

1.1 Tezin Amacı Ve Problemin Tanımı

Türkiye’de son zamanlarda önem kazanan yüksek hızlı trenlerin business plus ve ekonomi plus vagonlarına ait biletler TCDD için önemli bir gelir kaynaęıdır. Dolayısıyla yolcuların talebini artırabilmek amacıyla bu vagonlarda verilen hizmetler geliřtirilmeye çalışılmaktadır. Bu hizmetlerin en önemlisi vagonlarda yapılan yiyecek servisidir. Bu noktada devreye giren alt yüklenici firmalar trenlere doęru yolcu sayısı kadar günlük ve kaliteli yemek yüklemekle sorumludur. Tahmin edilen yolcu sayılarına göre sipariř edilen yemekler depolardan trenlere yükleme yapılmaktadır. Çalışmamızda bu firmaların doęru yolcu sayısı tahmininde etkin modeller geliřtirip doęru tahmin yapılarak, trenlere doęru sayıda yemek yüklenmesini saęlayan sipariř sisteminin kurulmasına alt yapı oluşturulması amaçlanmaktadır.

Firmalar için doğru tahminlerin yapılması hem maliyet hem müşteri memnuniyeti gibi konularda büyük ölçüde etkilidir. Doğru tahminler yapılmadığı zaman firma hem mali olarak olumsuz etkilenirken hem de müşteri talebini doğru olarak karşılayamadığı için itibar kaybına uğrar. Yemek siparişlerinin günlük olarak verildiği çalışmamıza konu olan firmada her iki konuda da zarara uğramamak adına doğru tahminler yapılarak sipariş sistemlerinin kurulması şarttır. Alt yüklenici firma yemek siparişlerini günlük olarak hazırladığından çalışmanın ilk aşamasında mevcut düzen için çoklu regresyon yöntemiyle tahmin modeli üzerine çalışılmıştır. Regresyon denklemlerine göre en uygun sonucu veren üç tahmin modeli seçilmiş ve güvenilirlikleri MAPE performans ölçütü ile kontrol edilmiştir. Böylelikle günlük yemek siparişi için kullanılması ön görülen en etkin tahmin modeli yaklaşımına ulaşılmıştır.

İkinci aşamada yemek siparişlerinin haftalık olduğu durum üzerinde durulmuştur. Haftalık talep tahmin modelinin geliştirilmeye çalışmamızın nedeni gelecekte firmanın haftalık olarak sipariş edilebilen uzun ömürlü yiyecekleri servis etmesi durumu için kullanabileceği bir model geliştirmektir. Haftalık sipariş edilebilen uzun ömürlü yiyeceklerin sipariş edilmesi opsiyonu firmaya satın alma ve lojistik açısından daha maliyet etkin çalışmasını sağlayacak bir durumdur. Haftalık yemek siparişi için Winters üstel düzeltme yöntemiyle tahmin modeli elde edilmiştir. Çoklu regresyon yöntemiyle yapılan tahmin modellerinde olduğu MAPE performans ölçütü ile güvenilirlik testi yapılmış ve tahmin denklemleri oluşturulmuştur.

1.2 Türkiye’de Demiryolu Tarihinin Gelişimi

Türkiye’de demir yolunun tarihi ilk olarak 22 Eylül 1856’da İzmir-Aydın güzergâhının bir İngiliz firması tarafından inşa edilmesiyle başlamıştır. Daha sonra diğer ülkelerde olduğu gibi hızla genişlemeye başlamıştır.

Demiryolları, Cumhuriyet döneminde devletin önemli bir parçası olarak kabul edilmiş ve yeni demiryolu projeleri ile genişlemeye devam etmiştir. 1923-1940 yılları arasında madenler, tarım, yolcular ve limanlara hizmet veren 3,000 km’den fazla yeni demiryolu hattı inşa edilmiş ve demiryolu Türkiye’yi işleyen bir devlet olarak birbirine bağlamaya yardım etmiştir.


II. Dünya Savaşı’ndan sonraki yıllarda ulaşımdaki önem karayollarına kaymış demiryolu uzunluğunda çok fazla artış gerçekleşmemiştir. Son yıllarda demiryolları

sürdürülebilir kalkınma hamlelerinin en önemli parçalarından olarak görülmüş ve 1951'den 2003 yılı sonuna kadar ihmal edilen bu sektörü canlandırmak için yoğun çaba sarf edilmiştir. 2003 yılından itibaren TCDD yüksek hızlı demiryolu hattı inşa etmeye başlamıştır (www.tcdd.gov.tr)


2009 yılında Ankara-Eskişehir hattının tamamlanmasıyla Türkiye yüksek hızlı trenle tanışmıştır. 2011 yılında Ankara-Konya arası yüksek hızlı tren seferleri başlamış, Eskişehir – İstanbul-Pendik arasındaki 2014'te, Pendik-Halkalı arasındaki kısım ise 12 Mart 2019'da Marmaray ile birlikte hizmete girmiştir(www.tcdrtasimacilik.gov.tr).

Konya-İstanbul hattının da açılmasıyla Türkiye'de şu an için 4 hatta yüksek hızlı tren faaliyeti bulunmaktadır. Yapımı devam eden YHT projeleri ise: Ankara-Sivas, Ankara-İzmir, Kayseri-Yerköy Yüksek Hızlı Demiryolu Projesi'dir. Bunların dışında henüz çalışma aşamasında olan diğer projelerde mevcuttur.

Yeni yüksek hızlı tren hatlarının açılması, YHT'ye olan talebin artmasına sebep olmuştur. Talebin artmasıyla birlikte yeni tren setleri satın alınmış ve tren sefer sayıları artırılmıştır. TCDD bünyesinde yaz döneminde günlük 52 YHT – 12 konvansiyonel tren seferi, kış döneminde ise 44 YHT – 12 konvansiyonel tren seferi bulunmaktadır. Demiryolu ile ulaşım daha kolay ve güvenli olması, seyahat sürelerinin kısılması, şehir merkezlerine kadar ulaşımın sağlanması özellikle YHT'yi kullanan yolcu sayılarında son yıllarda artış göstermesine sebep olmuştur. 2018 yılında YHT, kent içi ve konvansiyonel olmak üzere toplamda yaklaşık 110 milyon yolcu taşınmıştır. Şekil 1.1 ve Şekil 1.2'de yolcu sayılarında değişiklik gösterilmiştir. Yüksek hızlı trenlerin kullanımı güzergâh olarak da farklılık göstermektedir. Çizelge 1.1'de güzergâhlara göre yolcu sayısı bin kişi üzerinden gösterilmiştir.



Şekil 1.1: 2003 -2018 Demiryolları toplam yolcu sayısı.



Şekil 1.2: 2009-2018 YHT yolcu sayıları bin kişi.

Çizelge 1.1: YHT güzergâhlarına göre yolcu sayısı.

Güzergâh	2009	2010	2011	2012	2013	2014	2015	2016	2017	2018	Toplam
Ank-Esk	942	1.890	2.150	1.978	2.264	1.924	1.280	1.237	1.339	1.426	16.430
Ank-Konya			407	1.371	1.745	1.890	1.799	1.775	2.047	2.243	13.277
Ank-İst						992	1.956	2.203	2.873	3.269	11.293
Konya-İst					198	279	659	684	905	1.167	3.892
Toplam	942	1.890	2.557	3.349	4.207	5.085	5.694	5.899	7.164	8.105	44.892

1.3 Türkiye’de Tren İçi Yiyecek İçecek Servisinin Tarihi Gelişimi

Demir Yolunun kurucusu ve ilk Genel Müdürü Behiç Erkin Yemekli-Yataklı Vagonlar Servisinin ülkemizde başlayışını şöyle anlatır;

” Ankara’nın devlet merkezi olması ve Cumhuriyet merkezinin memlekete getireceği inkişaf dolayısıyla evvela Haydarpaşa-Ankara arasında başlamak üzere yataklı ve lokantalı vagonlar servisi tesis edilmesi zaruret halini almıştı. Bu maksatla Milletlerarası Yataklı Vagonlar Şirketi ile görüşmelere başladık ve 28 Mayıs 1924 tarihinde şirketin gönderdiği mümessil M.Lacombe ile bir mukavele akdettik Fakat yataklı vagonların fiilen işlemesi için bazı müşkülleri yenmek lazım geldi.”

1924 yılı 23 Temmuz’unda yapılan törende Haydarpaşa Ankara arasındaki ilk yataklı-yemekli vagonların denemesi yapılmıştır.

1927 yılı Ağustosundan itibaren Haydarpaşa-Ankara arasında haftada üç defa olmak üzere Anadolu Ekspresi adında bir lüks yataklı ekspres sefere başlamıştı. Bu treni kullananlardan %15 daha fazla ücret alınması sadece bir kesimin trenleri kullanması gibi sebeplerden tren seferleri iki yıl sonra kaldırılmıştır. Seferden kaldırılan bu lüks tren yerine dizi de diğer yolcu vagonları da bulunan “Anadolu Ekspresi” sefere konulmuştur. 1956 yılından itibaren günümüzde de popüler olan diğer yataklı-yemekli vagonlar hizmete başlamıştır. İlerleyen zamanla beraber yemekli vagonların işletme şekli ve özelliği değişiklik göstermiştir. Haziran 2004’te yemekli vagonlar özelleştirilmiştir. (kentvedemiryolu.com)

2009 yılında Türkiye yüksek hızlı trenler ekspres trenler ile birlikte harekete başlamıştır. Ekspres trenler yemekli vagon özelliğini hala taşıırken yüksek hızlı trenlerdeki yiyecek içecek servisi ekspres trenlerdeki yiyecek içecek servisinden farklı şekillenmiştir.

1.4 Yüksek Hızlı Trenlerde Yiyecek İçecek Servisi

2009 yılında ilk yüksek hızlı seferleri Ankara-Eskişehir arasında başlamıştır. Ardından Konya ve İstanbul hatlarının da tamamlanmasıyla şu an da aktif olarak çalışan dört adet yüksek hızlı tren hattı bulunmaktadır. Ankara-Eskişehir, Ankara-Konya güzergâhları kısa yol trenleri; Ankara-İstanbul ve Konya-İstanbul güzergâhları ise trenleri uzun yol trenleri olarak kabul edilmektedir. Tren güzergâhına bağlı olarak TCDD’nin bünyesinde iki tip tren seti kullanılmaktadır. Kısa yol trenleri ekonomi, business ve ekspres trenlerdekine benzer restoran vagonundan oluşurken, uzun yol trenleri bu vagonlara ek olarak ekonomi plus ve business vagonlarından oluşmaktadır.

Yüksek hızlı trenlerde ekspres trenden farklı olarak yemek servisi yolculara hem restoran kısmında hem de yerinde yapılmaktadır. Yüksek hızlı trenlerde yemek servisi ilk olarak Ankara-Eskişehir seferinde, business vagonlarda seyahat eden yolculara sandviç ve bisküvi ikramı; ekonomi vagonunda seyahat eden yolculara ise servis arabalarında yiyecek ve içecek satışı yapılmasıyla başladı. Ankara-İstanbul hattının açılmasıyla birlikte uzun yolda seyahat eden yolcuların ihtiyaçlarının kısa yola göre farklılık gösterdiği tespit edildi, seyahat süresinin uzun olması yolcuların yemek yeme ihtiyacını artırmıştı. Bunun üzerine İstanbul güzergâhında business plus ve ekonomi plus vagonlarında seyahat etmeyi tercih eden yolculara günlük yemek menüleri servis

edilmeye başlandı. Her iki tren setinde bulunan yemekli vagonlar ise restoran özelliği taşımakta ve alışveriş yapmak isteyen yolcuların yiyecek içecek ihtiyaçları ücret karşılığında sağlamaktadır. İlerleyen zamanla beraber kısa yol kabul edilen Ankara-Eskişehir ve Ankara-Konya trenlerinin business vagonunda bisküvi ve sandviç ikramı yapılmasına, uzun yol kabul edilen İstanbul trenlerinin business plus ve ekonomi plus vagonlarında günlük yemek ikramı yapılmasına karar verildi. TCDD belirli periyotlarda ihale düzenleyerek trenlerde bulunan bu vagonların işletmesini alt yükleniciye devreder. İhaleyi alan alt yüklenici firma, business vagonlarda bisküvi, sandviç ve içecek ikramından, business plus ve ekonomi plus vagonlarda yemek ve içecek ikramından sorumludur. Ekonomi vagonunda ve restoran vagonunda (yemekli vagon) ise yiyecek ve içecek satışı yapmakla yükümlüdür.

Alt yüklenici firma business ve ekonomi plus yolcularına servis etmek için her hafta farklı olacak şekilde aylık bir menü hazırlar. Menüler ana yemek, tatlı, salatadan oluşur ve her biri belirli gramajdadır. Daha sonra bu menüler TCDD tarafından onaylanır. Hazırlanan yemek menüleri alt yüklenici firmanın deposunda bulunur. İstanbul güzergâhında hareket eden trenlerin business plus ve ekonomi plus yolcu sayılarına göre trenlere yüklenirler. Hareket etme saati 11.00'e kadar olan trenlere kahvaltı menüsü yüklenirken, hareket saati 11.00'dan sonra olan trenlere kırmızı et ve beyaz etten oluşan menüler yüklenir ve yolcunun isteğine göre TCDD'nin hostesleri tarafından yolculara yemekler servis edilir. Yemek alıp almamak yolcuların inisiyatifindedir. Yolcuların almadığı ya da fazla yüklenen yemekler trenlerde bulunan soğutucularda muhafaza edilir, tren seferini tamamladıktan sonra alt yüklenicinin Ankara' istasyonunda bulunan depolarına teslim edilir.

Yemek menülerini alt yüklenici firma kendi üretebildiği gibi başka bir tedarikçiden de temin edebilir. Siparişi verilerek tedarikçiden alınan günlük yemekler alt yüklenicinin istasyonlarda bulunan depolarında muhafaza edilir. Trenlerin sefer hareket saatine göre yükleme işlemi yapılır. Sefer saati ve sayısı mevsimsel olarak değişiklik göstermektedir. Ankara-İstanbul arasında yaz döneminde (Mart-Aralık) 8 gidiş-dönüş toplamda 16 sefer, kış döneminde(Aralık-Mart) ise toplamda 7 gidiş-dönüş toplamda 14 sefer bulunmaktadır. Her gidiş-dönüş trenler için bir tur kabul edilir. Trenlerden bazıları aynı gün içerisinde gidiş-dönüş seferini yapıp turunu tamamlarken bazıları dönüş seferini ertesi gün yaparak turunu tamamlamış olur. Yıl içinde değişiklik gösterse de genellikle 16.00'dan sonra Ankara'dan hareket eden trenler yatıya kalan

trenler olarak adlandırılır. Örneğin sabah 09.00'da Ankara'dan yola çıkan İstanbul treni aynı gün 14.00'de İstanbul'dan yola çıkarak Ankara'ya ulaşırken, saat 19.05'te Ankara'dan yola çıkan İstanbul treni bir gece İstanbul'da kaldıktan sonra ertesi gün sabah Ankara'ya dönerek turunu tamamlar. Günlük yemekler tüm trenlerin gidiş-dönüş seferini kapsayacak şekilde ilk sefer olan gidiş seferine yüklenir. Her sefer bir restoran, her bir yolcu da restorana gelen müşteri olarak düşünülebilir.

Türkiye'de business plus ve ekonomi plus vagonlarında yılda ortalama 517 bin yolcu seyahat etmektedir. Bu yolcuların sağlıklı ve güvenilir yemek yemelerini sağlamakla sorumlu olan alt yüklenici firma için maliyetlerini düşük tutmak da büyük önem arz eder. Firmalar için en büyük maliyet kalemi yiyecek maliyetidir. (İkram yiyecek gelirinin ortalama %40'ı yiyecek maliyetidir.) Yiyecek atığını düşük tutarak bu maliyetlerini kontrol altında tutabilirler. Satın alma fiyatları sabit olduğunda, firmaların maliyetlerini düşük tutmalarının tek yolu atık oranını azaltmaktır, bu da doğru siparişi vermekten geçer.

1.5 Günlük Yemek Siparişi Sistemi

Şu anki işleyişte alt yüklenici firma yemek teminini başka bir tedarikçi firmadan günlük olarak sağlamaktadır ve haftanın her günü için ayrı ayrı sipariş verilmektedir. Yemek sipariş her gün sabah saat 10.00'a kadar, hem ertesi gün gidiş-dönüş yapacak hem de yine ertesi gün öğleden sonra gidip bir sonraki gün dönüş yapacak trenler için verilir. Yani gidiş-dönüş seferleri aynı gün olan trenler için bir gün öncesinden, dönüş seferini gidiş seferinin ertesi gün tamamlayan trenler için iki gün öncesinden yemek siparişi verilmiş olur. Sipariş günü, tüm trenler için o anki bilet alan yolcu sayısı temel alınarak, sezgisel olarak yemek siparişi sayısı belirlenmektedir. Geliştireceğimiz tahmin yaklaşımı ve modeli kişiye bağlı hatası yüksek olabilen bu sezgisel yaklaşım yerine istatistiki bir tahmin modeli olarak kullanılacaktır.

Trenlere yemek yüklemesi kalkış saatine göre yapıldığı için sipariş verilen yemekler günde tren kalkış saati temel alınarak üç parti halinde depoya teslim edilmektedir. Verilen siparişin ilk partisi siparişin verildiği gün saat 17.00 ikinci parti bir sonraki gün sabah 08.00 'de ve üçüncü parti saat 12.00'de, depoya getirilir ve trenin kalkış saatine göre trenlere yükleme işlemi yapılır. Saat 17.00'de teslim edilen sipariş ile bir sonraki gün sabah hareket trenlerin yüklemesi, 08.00'de teslim edilen siparişle gün içinde hareket eden trenlerin yüklemesi, 12.00'de teslim edilen sipariş ile o gün gidip

ertesi gün dönüş yapacak olan trenlerin yüklemesi yapılır. Örneğin: Salı günü verilen yemek siparişi hem Çarşamba günü Ankara'dan gidip gün içinde geri dönerek turunu tamamlayan trenler için hem de Çarşamba günü Ankara'dan gidip bir gece İstanbul'da kalarak Perşembe günü sabah Ankara'ya dönen trenleri kapsar. Çarşamba günü Ankara'dan giden trenler için verilen yemek siparişinin ilk partisi Salı günü 17.00'de depoya teslim edilir. Bu parti ile Çarşamba günü sabah hareket edecek olan trenler yüklenir, ikinci parti Çarşamba günü 08.00'de depoya teslim edilir ve bu parti ile Çarşamba günü gün içinde gidiş-dönüş turunu tamamlayan trenlerin yüklemesi yapılır. Son partiyle ise Çarşamba günü Ankara'dan gidip Perşembe günü dönecek olan trenlerin yüklemesi yapılır. Her tren turu (Gidiş-Dönüş) için tek yükleme gidiş trenine yapılır.

Sipariş anında yemek siparişi verilecek trenler için o anki yolcu sayısı baz alınarak son yolcu sayısı tahmin edilir ve sipariş tahmin edilen o yolcu sayısına göre verilir. Son yolcu sayısının hatalı tahmin edilmesi alt yüklenici firmada iki türlü maliyete sebep olur. Eğer yolcu sayısı olduğundan az tahmin edilirse trenlere az yemek yüklenir ve eksik yemek yükleme cezası olarak TCDD tarafından firmaya yansıtılır. Yolcu sayısı olduğundan fazla tahmin edilirse firma için hem atık maliyeti hem de depolama maliyeti oluşur. Hatalı tahminden sonra Trenlere doğru yükleme yapılmamasına neden olan diğer bir etken ise tren bileti satışında uçaklardaki gibi check-in zamanı olmamasıdır. Check-in süresi olmadığı için yolcu sayısı kesin olarak bilinemez, hatta tren hareket ettiğinde diğer istasyonlardan binen olacağı için yolcu sayısında artış gözlemlenebilir.

Trenlerde ikramı yapılan yemekler taze ürünler olduğu için raf ömürleri bir gündür ve depolarda muhafaza edilme süreleri çok kısadır. Son kullanma tarihi geçen yemekler tekrar trenlerde kullanılamaz ve atık olur. Bu yüzden hem sipariş verilirken hem trenlere yükleme yapılırken çok dikkatli olunmalıdır.

Sipariş sisteminin aşamaları aşağıdaki gibi sıralanmıştır.

1. Öncelikle hangi seferler için sipariş verileceği belirlenir.
2. Belirlenen seferler için o an elektronik yolcu sisteminden bilet alan yolcu sayısına bakılır.
3. Bilet alan yolcu sayısına göre trenin hareket anında yolcu sayısının ne olacağı sezgisel olarak tahmin edilir.

4. Stokta bulunan yemek sayıları kontrol edilir. Tahmin edilen yolcu sayısına göre elde bulunan yemeklerin çıkarıldıktan sonra servis edilmek üzere yemek siparişi rakamı belirlenir ve sipariş verilir.

Mevcut düzende yaşanan sipariş ve yükleme problemleri aşağıdaki gibidir.

- Siparişi veren personel hiçbir sistem kullanmadan tamamen geçmiş verilerine dayalı olarak siparişi verir. Bu da firmanın kişiye bağlı olarak çalışmasına ve yeni bir personelin sipariş verme görevini doğru yapamamasına neden olur
- Trenler de uçaklardaki check-in olmadığı için net tren yolcu sayısı saptamak mümkün değildir, Eğer trenin yolcu sayısında beklenmeyen bir artış olursa bir sonraki sevkiyatla gelen partiyle ürün ilave alınarak eksiklik giderilir. Yüklemenin bir sonraki partiyle tamamlanması o partiyle yüklenecek trenlerinin ürün miktarının sapmasına sebep olur. Böyle durumlarda tedarikçi firmadan ara sipariş verilir, tedarikçi firma siparişi depoya yetiştirmeye çalışır. Ürünler zamanında gelmezse trenler eksik yüklenmiş olur.
- Trenlerde bir koltuk birden fazla kez satılabilir. (Ankara'dan Eskişehir'e kadar birisi Eskişehir'den İzmit'e kadar birisi İzmit'ten İstanbul'a kadar başka birisi aynı koltuğu satın alabilir.) Bu da son yolcu sayısının tren hareket ettikten sonra bile kesinleşmemesine sebep olur.
- Özellikle hazırlığı akşamdan yapılan sabah trenlerinde son yolcu sayısı kontrolü yapılamazsa ürünler fazla veya eksik olarak trene yüklenir. Risk almamak adına genellikle fazla yükleme yapılır. Bu da yine atık maliyetini ortaya çıkarır.
- Trenlere yolcu sayısından fazla yemek yüklendiğinde, fazla yemekler tren üzerinde personel tarafından ısıtıldığı için tekrar kullanılamaz hale gelir. Yemeklerin ömrü (son kullanım tarihi (SKT)) iki gündür, yaz aylarında ve yemek türüne bağlı olarak gün sayısı bire düşmektedir. Tren üzerine fazla yüklenen her yemek atık olarak kabul edilir ve tekrar kullanılamaz. (Trenler ortam olarak gıda saklamaya uygun olmadığı için bozulma daha hızlı olmaktadır.)

Kullanılan sipariř sistemi tahmine dayalı olmayıp kiřisel gemiř veriler zerinden ilerlediđi iin bu tip problemler yařanmaktadır. Bu alıřma ile oklu regresyon tahmin modeli kullanılarak dzenli bir sipariř sisteminin kurulması amalanmıřtır.





2. LİTERATÜR ARAŞTIRMASI

Catering hizmeti belli bir grubun beslenme ihtiyacını gidermek amacıyla kullanıma hazır yiyecekleri belirli bir merkezden planlayarak ve yöneterek ederek son müşteriye iletilmesidir. (Sezgin ve Özkaya, 2013). Catering endüstrisi geçmişte de geniş bir yelpazeye sahip olmakla birlikte toplumda yaşanan değişikliklerle son 30 yılda hem boyut olarak hem de yelpaze olarak büyük bir artış göstermiştir (Farber ve Todd, 2000). Türkiye’de tren içi yiyecek içecek servisi 1924 yılında Haydarpaşa Ankara arasında ilk yataklı- yemekli vagonlu ekspres trenlerin denenmesi ile başlamıştır. İlk dönemlerde restoran özelliği gösteren yemekli vagonların ilerleyen zamanla beraber işletme şekli ve özelliği değişiklik göstermiştir (www.kentvedemiryolu.com). Yüksek hızlı tren yapılarının ekspres trenlerden farklı olması bu trenlerde yemek servisinin değiştirilmesini zorunlu kılmış ve yolculara yerinde yemek servisi yapılmaya başlanmıştır.

Yolcu sayısı kadar trene yüklenen yemeklerle her yolcu için birebir servis yapılması beraberinde doğru yolcu sayısı tahmini yapmayı zorunlu kılmıştır. Hem tahmincinin geçmiş bilgi ve tecrübesiyle hem de zaman serisi analizleriyle yolcu sayısı tahmini yapılabilmesi sayısal ve sayısal olmayan talep tahmin metotlarının ikisinin de yolcu sayısı tahmini yapmak için uygun metotlar olduğunu göstermiştir (Çağıl,1997).

Yolcuların ulaşım araçlarını tercih ederken seyahat süresi, güvenlik, konfor, hava koşulları gibi bazı faktörleri göz önünde bulundurması regresyon analizini uygun bir tahmin modeli haline getirmektedir (Montgomery, Runger, 2002). Çin’de demiryolu yolcu taşımacılığı pazarının gelişim hızı ve yolcu taşımacılığı gelirinin oranı toplam gelirden sürekli artması üzerine demiryolu yolcu taşımacılığını etkileyen faktörleri analiz etmek için temel bileşen regresyon teorisini kullanarak, çoklu doğrusal bir regresyon modeli oluşturmuştur. Analiz sonucu Çin’in toplam nüfusu, diğer ulaşım sektörleri, nüfusun geliri yolcu talebini etkileyen başlıca faktörler olarak bulunmuştur (Gu, Lu, 2015). New South Wales’in Sidney bölgesindeki demiryolu talebi modellerini etkileyen faktörlerdeki uzamsal(mekânsal) değişkenliği araştırmak ve bu varyasyonları talep tahmin sürecine açıkça dahil etmek için coğrafi ağırlıklı regresyon modeli kullanılmış, kapsayıcı nüfus ve istihdam, hane halkı büyüklüğü, gelir ve yaş profili, araba sahipliği seviyeleri, tren sıklığı, otobüs değişim potansiyeli, bisiklet depolama hizmeti ve şehir merkezine uzaklık gibi etkenler modellerde kullanılan

değişkenler olarak seçilmiştir (Blainey, Mulley, 2013). Demiryolu sektöründe mevsimlerin, tatillerin, acil durumların ve stratejik rakiplerin değişmesi ile yolcu akış talebi de değişir. Bu faktörlere uyarlanabilen demiryolu yolcu akış tahmininin uyarlanabilir ve esnek bir yöntem olması gerekmektedir (Wei, San, 2019). Bu modellerin hepsi genel veya stratejik seviyede yolcu tahminine yöneliktir. Oysa bizim geliştirmemiz gereken model kısa dönemli ve özel bir yolculuk ayağındaki yolcu sayısının tahminine yöneliktir ve dolayısıyla farklılık içerir.

Havayolu firmalarındaki yemek servisi de demiryolundakine benzer özellik göstermektedir ve benzer metotlarla tahminleme yapılmıştır. Yine bir hava yolu şirketinde iç ve dış hat ikram satışlarının nelerden etkilendiğini ve hangi değişkenlere bağlı olarak değiştiğinin belirlenmesi ve buna bağlı olarak geleceğe yönelik tahmini satışların hesaplanması için çoklu doğrusal regresyon analizi yapılarak tahminleme modeli kullanılmıştır. Tahminleme sonucunda ortalama hata terimi katsayısının kabul edilir sınır içinde olduğu görülmüştür (Önen ve Karabulut, 2018).

Demiryollarında son yolcu sayısı trenler turunu tamamlayana kadar netlik kazanmaz bunun aksine havayolunda uçaklar hareket etmeden minimum bir saat önce yolcu sayısı netlik kazanır. Hava yolunda çalışan firmalar için uçağa yemeklerin yüklenmesinde bu bir avantaj olsa da yemeklerin hazırlanması aşaması daha önce yapıldığı için üretim yapılacak olan yemek sayısının ne kadar olacağına karar vermek gerekir. Goto ve diğerleri (2002) Kanada havayolları için Markov karar süreçleri yöntemi ile üretilmesi gereken yemek miktarlarını check-in sonrası belirlenen yolcu sayılarının son yolcu sayısı olduğunu kabul ederek kırk uçuşun verisini kullanarak belirlemiştir.

Demiryolu seyahat süresi uzun olduğu için yolcuların yemek ihtiyaçları günün belirli saat dilimlerine göre farklılık gösterebilir (sabah kahvaltı, öğlen ve akşam yemek). Yolcuların isteklerini karşılayabilmek adına tren içi servisinden sorumlu olan firmalar çeşitli yiyecek gruplarını trene yüklemek zorundadırlar. Tren kapasiteleri yiyeceklerin depolanması için yeterli olmadığından firmalar gerekli olan yiyecekleri ara istasyonlardan temin edebilir. Bu da beraberinde rotalama problemlerini ortaya çıkarır. Pekin ve Şangay arasında hareket eden yüksek hızlı trenlerin yükleme problemlerini giderebilmek adına sınırlayıcı zaman penceresi ve zaman limitli, üç aşamalı rotalama modeli üzerine çalışılmıştır. Modelde yolcu talebi, öğün süresi ve seyahat süresi arasındaki farkın öğün sürelerine bölünüp trene ait yolcu kapasitesi ve yükleme

faktörüyle çarpılmasıyla bulunmuştur (Wu ve diğerleri, 2016). Yine farklı bir rotalama çalışması olarak Çin yüksek hızlı trenlerinde farklı saat dilimlerindeki yolcu talebini karşılayabilmek için doğrusal olmayan karma tam sayılı programlama modeli kullanılmıştır (Wu ve diğerleri, 2018).

En çok kullanılan diğer bir tahmin metodu otoregresif hareketli ortalamalar modelidir (ARIMA). En hızlı ulaşım yöntemi olan havayolu ulaşımının ülkemiz boyutunda talep değerlendirmesini tahmin edebilmek, bu hizmeti sağlayan kurum, kuruluş ve firmalar için strateji planlaması ve yatırım öngörüsü değerlendirme kriterlerini oluşturabilmek adına ARIMA metodu ile çalışmalar yapılmıştır (Tortum ve diğerleri, 2014). Literatürde ARIMA ile farklı tahmin metodlarının performans karşılaştırılmasının yapıldığı çalışmalar bulunmaktadır. Doğal afetlerden sonra ihtiyaç duyulacak malzemelerin talep tahmini üzerine yapılan çalışmada; doğal afetlerden sonraki ilkyardım sürecinde acil ihtiyaç duyulan malzemelerin tahmininde doğrusal regresyon ve ARIMA gibi geleneksel istatistiksel ve ekonometrik metodları kullanılmıştır. Çalışma, 2008'deki Çin kış fırtınasından sonraki afet döneminde, tarımsal ürün talep tahmininde kullanılarak başarılı sonuçlar elde edilmiştir (Xu ve diğerleri, 2010). Yine turizm ve eğlence sektörüne olan talebi belirlemek üzere, Amerikan milli parklarından üç tanesini örnek seçilerek, bu parklardan elde edilen ziyaretçi sayıları gibi verilerle talep tahminleri yapılmış, istatistiksel tahmin yöntemlerinden olan ARIMA metodu ile diğer istatistiksel metodlar karşılaştırılmıştır. ARIMA metodunun diğer metotlara göre daha doğru tahminler ürettiği, hem yıllık hem de mevsimsel verilere göre yapılan tahminlerde de yüksek performans gösterdiği gözlenmiştir (Chen, 2000).

Yolcu talebi tahminlemesi için kullanılan popüler yöntemler arasında, yapay sinir ağları yöntemi de bulunmaktadır. Kısa süreli demiryolu yolcu talebi tahmini için 2 yapay sinir ağı yöntemi kullanılmıştır. Çoklu zamansal sinir ağı (MTUNN) ve paralel topluluk sinir ağı (PENN) modelleri kıyaslanmıştır (Tsai,2009). İstanbul Madrid arası uçuşlarında, yapay zekâ teknikleri ile ekonometrik bir model olan regresyon tekniği karşılaştırması yapılmıştır. Adaptif sinirsel bulanık çıkarım sistemi (ANFIS), yapay sinir ağları ve regresyon analizinin kullanıldığı bu çalışmada, yolcu talep tahmini konusunda en başarılı ve güvenilir sonuçları “yapay sinir ağları” tekniğinin verdiği tespit edilmiştir. Ayrıca yolcu talebini etkileyen faktörler literatürden tespit edilmiş, korelasyon analizine tabi tutulup ilişkili olanlar belirlenmiştir (Efendigil ve Eminler, 2017). Pekin uluslararası havalimanı yolcu akışı tahmini için ortalama etki değeri

(method of mean impact value (MIV)) ve doğrusal olmayan vektör otoregresyon sinir ağı (nonlinear vector auto-regression neural network (NVARNN)) yöntemleri kullanılarak tahmin modeli geliştirilmiştir (Sun ve diğerleri, 2019).

Zaman serileri uygulanabilirliği kolay ve pratik olduğu için çoğu sektörde yaygın olarak kullanılan bir talep tahmin yöntemidir. Yapılan çalışmalarda genellikle diğer tahmin metotları ile zaman serilerinin karşılaştırılması yapılarak en iyi tahmin yöntemi bulunmaya çalışılmıştır. Ürün ve hizmet satış talep tahminlerinde bu örneklere oldukça çok rastlanır. Ching-Chin ve diğerleri (2010) yeni ürünler için bir satış tahmin modeli oluşturmuşlardır. 4 kademeli bir tahmin olan bu modele yeni ürün tahmin sistemi adı verilmişlerdir. Tahmin yöntemi olarak zaman serisi modellerinden hareketli ortalama, üstel düzeltme, trend düzeltmeli üstel düzeltme modelleri; sezgisel yöntemlerden de satış endeksi, Taylor serisi ve difüzyon modeli tahmin modülünün içinde çalışacak yöntemler olarak belirlenmiştir. Yirmi yedi farklı senaryo test edilerek en iyi model bulunmaya çalışılmıştır. Parimita ve Arora (2015) süt ürünleri işletmesinde bir işletmede farklı ürün grupları için satış tahmini çalışması yapmışlardır. Yapılan çalışmada, hareketli ortalama modeli, üstel düzeltme doğrusal regresyon ve üstel regresyon uygulanmıştır. Ürün gruplarına göre tahmin yöntemlerinin performansının değiştiği gözlemlenmiştir. Gıda ithalatı alanında faaliyet gösteren bir firmanın 2013-2018 dönemi arası verileri kullanılarak satış tahmin modelleri oluşturulmuştur. Oluşturulan veri seti ile çoklu regresyon, yapay sinir ağları yöntemi, Winters metodu hareketli ortalamalar ve üstel düzeltme yöntemleri ve talep tahmin modelleri kurulmuştur. Kurulan modellerle yapılan tahminlerin hata terimleri karşılaştırılarak en uygun tahmin model belirlenmiştir (Yıldırım, 2019).

1986-2007 yılları arasında Türkiye'yi ziyaret eden turist sayılarına ait veriler kullanılarak 2008-2010 yıllarına ait tahminlemenin yapıldığı uzun periyodlu yabancı turist sayısının tahmini için yapay sinir ağlarının kullanılabilirliği ve geleneksel zaman serisi analizi yöntemleri ve Box-Jenkins yönteminin kullanımı ile elde edilen sonuçların karşılaştırılması yapılmış. Uygun tahmin yönteminin bulunması için zaman hata analizleri ve zaman serileri testleri kullanılmıştır (Önder ve Hasgöl, 2009). Sosyal ve Ömürgönülşen (2010) turizm sektöründe talep tahmini üzerine yaptıkları çalışmalarında 2000-2007 yılları arasında tesislere gelen yerli ve yabancı turist sayılarının verilerini kullanarak 2008 yılının ilk altı ayı için müşteri

tahminini gerçekleřtirmişlerdir. Talep tahmini yöntemi olarak Hareketli Ortalama, Basit Üstel Düzeltme ve Holt-Winters yöntemlerinin performanslarını karşılařtırmışlardır.

Ülkemizde yüksek hızlı trenlerin yolcu sayılarının tahminine ilişkin yapılmış bildiğimiz bir çalışma bulunmamaktadır. Çalışmamız literatürdeki bu boşluğu doldurmada önemli bir katkı olacaktır.





3. TALEP TAHMİNİ ve TAHMİN YÖNTEMLERİ

3.1 Talep Tahmini

Talep tahmini, bir hizmet veya mal için gelecekte oluşacak olan talebin, en doğru ve hatasız şekilde hesaplanması işlemidir. İleriye yönelik alınan kararların doğruluğu genellikle yapılan tahminlerin kuvvetine bağlıdır. İşletmelerde en sık tahmin edilmek istenen unsur taleptir. Talep tahmini için kullanılan yöntem ve teknikler yalnızca talep tahminleri için değil tüm tahminler için kullanılabilir (www.mku.edu.tr). Tahmin yöntemleri sayısal olmayan tahmin yöntemleri ve sayısal tahmin yöntemleri olarak kendi içinde aşağıdaki gibi ikiye ayrılır;

- Sayısal olmayan yöntemler: delphi yöntemi, satış gücü grupları yöntemi, yönetici görüşleri yöntemi, satış elemanları ve ürün hattı yöneticileri, nominal grup yöntemi, pazar araştırması yöntemi, tarihi analog yöntemi

- Sayısal yöntemler: ortalama yöntemleri, üstel düzeltme yöntemi, trend analizi yöntemi

Gelecek dönemde müşteriler tarafından ihtiyaç duyulan mal veya hizmetlerin miktar ve tutar olarak belirlenmesini sağlayan bir işlem olan talep tahmini, üretim planlaması, satış hacminin belirlenmesi, depolama miktarlarının saptanması, bölgelere göre dağıtım işlemlerinin yapılması konusunda firmalara rehberlik sağlayarak etkinliğin artırılmasına yardımcı olur (Akyıldız 2004).

Ürün özellikleri ve talep yöntemi, kullanılacak tahmin türünü ve kapsayacağı zaman dilimini etkiler. Bazı ürünlerin talep miktarları mevsimlere göre farklılık gösterir. Böyle durumlarda talebi etkileyen mevsimsel faktörleri iyi belirlemek ve buna uygun tahmin yöntemi kullanmak (Ergün ve Şahin, 2017) .

Tahmin çalışması yapılırken aşağıdaki maddeler göz önünde bulundurulmalıdır (Kobu, 1996) .

- Tahminler belirli ölçüde hataya sahiptir
- Miktar veya çeşitlilik bakımından büyük olan gruplara ait tahminler daha duyarlıdır.
- Tahmin yapılan zaman aralığı kısaltıkça duyarlılık artar

- Tahmin yapılırken geleceğe ait bilinen bilgiler tahmin hesabına dâhil edilmelidir.
- Tahmin yöntemi ile uygulamaya geçilmeden önce test edilmelidir.

3.2 Talep Tahminin Aşamaları

1. Bilgi Toplanması: Geçmiş veriler olmadan ileriye dönük bir planlama yapmak zordur. Yapılacak tahminin amaçları doğrultusunda toplanacak olan bilgilerin kapsamı, türü ve ayrıntısı belirlenmelidir. Eksik ve fazla bilgiler hatalı tahminlere yol açabilir.
2. Tahmin Döneminin Tespit Edilmesi: Talep sonuçlarının kullanılış amacı ile tahmin periyodu arasında yakın bir ilişki vardır. Örneğin, günlük ya da haftalık yapılan tahminlerin uzun dönemlerde kullanılması yanıltıcı sonuçlar verebilir (Tekin, 1996) .
3. Tahmin Yönteminin Seçilmesi: Diğer aşamalarda olduğu gibi burada da yapılacak olan tahminin amacına göre yöntemi seçmek en doğru yoldur. Talep tahmin yöntemi olarak öznel ve nesnel yöntemler kullanılabilir. Nesnel yöntemler istatistiksel ve matematiksel verileri temel alırken, öznel yöntemler kişi tecrübelerini temel alan yöntemlerdir. Hem öznel hem nesnel yöntemlerin bir arada kullanıldığı yöntemler en ideal tahmin yöntemidir (Bolt, 1994).
4. Tahmin sonuçlarının geçerliliğinin araştırılması: Elde edilen tahmin sonuçları gerçek değerlerle karşılaştırılmalı ve aradaki fark sistematik şekilde tespit edilmelidir.

3.3 Çalışmada Kullanılan Tahmin Yöntemleri

3.3.1 Regresyon analizi

Regresyon analizi, bağımlı bir değişken ile bağımsız bir veya daha fazla tahmin değişkeni arasındaki ilişkiyi sayısal hale getirmek için kullanılan istatistiksel bir yöntemdir (Howell, 1987). Aralarında sebep-sonuç ilişkisi veya genel anlamda ilişki bulunan iki veya daha fazla değişken arasındaki bağlantıyı belirleyerek o konu ile ilgili tahminler ya da öngörüler yapabilmeyi sağlayan en çok kullanılan metotlardan biri regresyon analizidir (www.belikesiruniversitesi.edu.com).

İngiliz bilim insanı Galton 19.Yüzyılda yaptıđı bir alıřmada, uzun boylu anne ve babaların ocuklarının boy ortalamalarının genel olarak anne ve babadan daha kısa boylu anne ve babalarının ocuklarının ise genel olarak daha uzun boylu olduklarını belirtmiřtir. Galton rnekteki boy uzunluklarının grup ortalamalarına dođru ekilmesine regresyon demiřtir(Ravid,1994). Bařka bir deyiřle regresyon, bir deđiřkene iliřkin lümlerin grup ortalamasına dođru ekilmesidir. Regresyon Analizi ise aralarında iliřki bulunan iki veya daha fazla deđiřkenden birinin bađımlı, diđerlerinin bađımsız deđiřken olarak ayrılmasıyla aralarındaki iliřkinin bir eřitlik ile aıklanmasıdır.

Regresyon analiziyle

Bađımlı ve bađımsız deđiřkenler arasında iliřki var mıdır?

Bađımlı ve bađımsız deđiřken arasında iliřki varsa iliřkinin gücü ve türü nedir?

Bađımlı deđiřkene ait tahmin yapabilmek mümkün müdür?

Bađımsız deđiřkenlerin birbirleri üzerinde etkisi var mıdır? Varsa nasıl bir etkidir gibi sorulara cevap aranır. (www.istatistikanaliz.com)

Montgomery (1982) regresyon analizinin ařađıdaki beř amaç için kullanılacağını belirtmiřtir.

Tanımlama: Arařtırmacı bir veri setindeki iliřkileri zetlemek veya tanımlamak amacıyla bir regresyon eřitliđi arařtırır. Bu amaçla regresyon analizini kullanırken veri seti ile ilgili minimum varsayımları yapmak gereklidir.

Katsayı Tahmini: Regresyon analizinin en yaygın kullanım amacıdır. Arařtırmacı burada kuramsal bir iliřkiyi dikkate almıř olabilir ve analiz sonuçlarının bu iliřkiyi destekleyip desteklemediđini arařtırır. Genellikle regresyon katsayılarının büyüklükleri ve iřaretlerine özel bir önem verilir. Genelde regresyon analizinin bu amacı diđer kullanım amaçlarıyla birlikte kullanılır.

Tahmin: Regresyon eřitliđi tahmin amaçlı olarak geliřtirilebilir. Bu amaçla regresyon analizinin kullanımı birok varsayımın sađlanmasını gerektirmektedir. rneđin aralık tahmini için normallik varsayımının sađlanması gerekir.

Kontrol: Regresyon modelleri bir sistemin kontrol ve gözetimi amacıyla da kullanılabilir. Regresyon analizinin bu amaçla kullanılması durumunda bağımsız değişkenlerin bağımlı değişkenle nedensellik yoluyla ilişkisi olması gerekmektedir. Ayrıca fonksiyonel ilişki ileri zamanda aralığında da geçerli olması gerekmektedir. Bu nedenle sonraki aşamalarda modelin düzeltilmesi gerekmektedir.

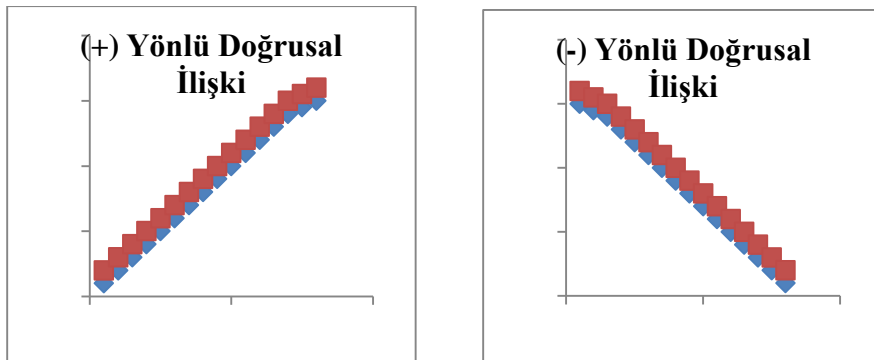
Değişken Seçimi: Bu durumda, potansiyel bağımsız değişkenler arasından bağımlı değişkeni anlamlı bir şekilde açıklayan veya açıklamayan değişkenleri araştırmak regresyon analizinin kullanım amaçlarındandır.

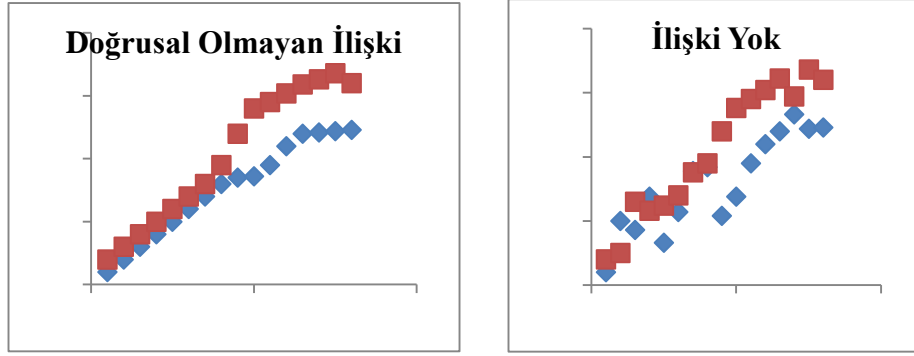
Regresyon Modelleri bağımsız değişken sayısına göre çoklu ve basit, bağımsız değişkenler arasındaki ilişkiye göre de doğrusal ve doğrusal olmayan regresyon modeli olarak sınıflandırılır.

3.3.1.1 Regresyon modelleri

3.3.1.1.1 Doğrusal olmayan regresyon modelleri

Regresyon analizine başlarken öncelikle aralarında ilişki aranacak iki ya da daha fazla sayıda değişkenin hangileri olduğuna karar vermek gerekir sonra da bu değişkenler arasındaki ilişkiyi gösteren denklemin biçimi için bir kabul yapmak gerekir. Bağımsız değişkenlerin arasındaki ilişkiye göre çoklu/basit doğrusal regresyon analizi ve çoklu/basit doğrusal olmayan regresyon analizi olarak iki sınıf yapılabilir. Regresyon analizine karar verilmeden önce saçılım grafiği hazırlanmalı (ilişki yok/doğrusal ilişki var/doğrusal olmayan ilişki var) ve değişkenler arasında korelasyon olup olmadığına bakılmalıdır (Köse, 2017). Aşağıdaki Şekil 3.1’de saçılım grafiklerine göre doğrusal ve doğrusal olmayan regresyon örnekleri gösterilmiştir.





Şekil 3.1: Doğrusal ve doğrusal olmayan regresyon saçılım grafikleri örnekleri.

3.3.1.1.2 Basit (Tekli) doğrusal regresyon

Bir tek bağımsız değişkenin kullanıldığı regresyon modeline tek değişkenli regresyon modeli denir. Basit doğrusal regresyon analizinde regresyon eşitliği i . gözlem için eşitlik (3.1) gibi yazılır;

$$\hat{y}_j = b_0 + b_1x_{1j} + b_2x_{2j} + \dots + b_px_{pj} + e_{ji} \quad (3.1)$$

Basit regresyon için;

$p = 1$ 'dir yani tek bağımsız değişken içerir.

3.3.1.1.3 Çoklu doğrusal regresyon

Bazı durumlarda ise; incelenen bir bağımlı değişkeni birçok bağımsız değişken etkileyebilir. Çok değişkenli regresyon analizinde bir den fazla bağımsız değişkenin aynı anda bağımlı değişkendeki değişimi açıklanmaktadır. Hesaplama ve yorum bakımından tek değişkenli regresyon analizine benzemektedir.

Çoklu doğrusal regresyon eşitliği verileri için eşitlik (3.2)'deki gibi denklem yazılır;

$$y_i = B_0 + B_1x_{1j} + B_2x_{2j} + \dots + B_px_{pj} + \varepsilon_{ji} \quad (3.2)$$

3.3.1.2 En küçük kareler tekniği

Regresyon modelini parametrelerini tahminde her ne kadar birkaç teknik kullanmak mümkünse de en yaygın kullanılan yöntem en küçük kareler tekniğidir.

En küçük kareler tekniğiyle hata kareleri toplamı minimize edilecek şekilde kısmi regresyon katsayıları tahmin edilmektedir. Modelde b_0 , regresyon yüzeyinin Y

eksenini kestiği noktayı göstermekte ve modelin sabit terimi olarak bilinmektedir. Modelde b_i 'ler x_i 'nin yönüne göre regresyon yüzeyinin eğimlerini göstermektedir. Her regresyon katsayısı, diğer bağımsız değişkenlerin sabit tutulması koşuluyla, i. değişkenin bağımlı değişken üzerindeki etkisini gösterir. Regresyon katsayıları aşağıdaki (3.3) ,(3.4) ve (3.5) eşitlikleri ile hesaplanmaktadır.

$$\mathbf{Eğim} = \mathbf{b}_1 = \frac{\sum_{j=1}^n (X_j - \bar{x})(Y_j - \bar{y})}{\sum_{j=1}^n (X_j - \bar{x})^2} \quad (3.3)$$

$$\mathbf{Sabit} = \mathbf{b}_0 = \bar{y} - b_1 \bar{x} \quad (3.4)$$

$$\mathbf{Örnek Hataları} = \mathbf{e}_j = y_j - \hat{y} \quad (3.5)$$

3.3.1.2.1 En küçük kareler tekniğinin varsayımları

En küçük kareler tekniğinin varsayımlarının sağlanmaması durumunda yapılan tahminler yanlı olmakta ve böylece ilgili anlamlılık testleri geçerliliğini yitirmektedir (Bilge, 2000). En küçük kareler yönteminin varsayımları aşağıdaki gibi özetlenebilir:

1. Hataların beklenen değeri (ortalaması) sıfırdır.
2. Hatalar birbirinden bağımsızdır. Yani, birim değerleri arasında sıra korelasyonu yoktur.
3. Hataların varyansı sabittir.
4. Hatalar ile bağımlı değişken arasında korelasyon yoktur.
5. Hatalar ve bağımsız değişkenler birbirinden bağımsızdır.
6. Bağımsız değişkenler arasında anlamlı ilişki yoktur.
7. Doğrusal regresyon analizinde bağımsız değişkenler sabit olmasına rağmen, bağımlı değişken tesadüfidir. Fakat, korelasyon analizinde her iki değişken de tesadüfidir.
8. Değişkenler hatasız ölçülmüşlerdir.
9. Bağımlı ve bağımsız değişkenler arasındaki ilişki doğrusaldır. Fakat bu doğrusallık koşulu kuşkusuz modelin parametreleri için gereklidir.(Değişkenler doğrusal olmayabilir)
10. Birim değerleri sayısı (n), değişken sayısından (p) büyük olmalıdır.

11. Bağımsız değişkenlerin varyansı sıfırdan büyük olmalıdır. Değişkenin tüm gözlem değerleri birbirine eşitse regresyon doğrusunun eğimi tanımsız olmaktadır.

Yukarıdaki varsayımlardan birinin sağlanamaması durumunda en küçük kareler tahminicileri yanlı, tutarsız veya etkisiz olmaktadır.

3.3.1.3 Regresyon analizinin güvenilirliği ve anlamlılığı

Regresyon katsayıları tahmin edildikten sonra, elde edilen tahminlerin güvenilirliğini belirlemek için kullanılan en yaygın endeksler korelasyon katsayısı (r) ve determinasyon (r^2) katsayısıdır. Korelasyon katsayısı -1 ile +1 arasında değer alır. Korelasyon katsayısının sıfıra eşit çıkması doğrusal ilişkinin olmadığını; -1 veya +1 'e yaklaşması ilişkinin kuvvetlendiğini gösterir. Determinasyon katsayısı ise korelasyon katsayısının karesine eşit olup 0 ile +1 arasında değer alır ve bağımlı değişkene ait toplam varyansın (bilginin) yüzde kaçının bağımsız değişkenlerle açıklandığını gösterir. Bu katsayılar aşağıdaki (3.6) ve (3.7) eşitlikleri ile hesaplanır.

Determinasyon Katsayısı

$$r^2 = \frac{\sum_{j=i}^n (\hat{Y}_j - \hat{y})^2}{\sum_{j=i}^n (Y_j - \hat{y})^2} \quad (3.6)$$

Eşitlikte $\sum_{j=i}^n (\hat{Y}_j - \hat{y})^2$, hata kareler toplamını; $\sum_{j=i}^n (Y_j - \hat{y})^2$, toplam kareler toplamını ifade eder.

Korelasyon Katsayısı

$$r = \frac{\sum_{j=1}^n (X_j - \bar{x})(Y_j - \bar{y})}{\sqrt{(\sum_{j=1}^n (X_j - \bar{x})^2)(\sum_{j=1}^n (Y_j - \bar{y})^2)}} \quad (3.7)$$

Hesaplanan Korelasyon katsayısı ve determinasyon katsayılarının anlamlılığı aşağıdaki testler kullanılarak belirlenmektedir.

2.3.1.3.1 Regresyon modelinin anlamlılığı için *F* testi

F testi regresyon analizinde bağımsız değişkenlerin bağımlı değişken üzerinde etkisinin olup olmadığını belirlemek amacıyla kullanılır. Ayrıca *F* testi ile bağımlı değişken ile bağımsız değişkenler arasındaki doğrusallık test edilebilir. Değişkenler arasındaki ilişkiyi test etmek ve ilişkinin anlamlı olup olmadığını anlamak için aşağıdaki hipotezler oluşturulur. (Tunç, 2018)

$$H_0: \beta_1 = \beta_2 = \dots = \beta_k = 0$$

$$H_1: \beta_1 \neq \beta_2 \neq \dots \neq \beta_k \neq 0$$

*H*₀ hipotezi regresyon katsayıların sıfır olduğunu dolayısıyla bağımlı değişkenin bağımsız değişkenler tarafından açıklanamadığını ve kurulan regresyon modelinin istatistiksel açıdan anlamlı olmadığını belirtir, *H*₁ hipotezi ise regresyon katsayılarından katsayılardan en az bir tanesinin 0 olmadığını söyleyerek modelin anlamlı olduğunu belirtir. (Şahinler, 2000)

F istatistiğinin hesabında eşitlik 3.8 kullanılır;

$$F = \frac{\sum_{j=1}^n (\hat{Y}_j - \bar{y}) / (k-1)}{\sum_{j=1}^n (Y_j - \hat{Y}_j)^2 / (n-k)} = \frac{R^2 / (k-1)}{(1-R)^2 / (n-k)} \quad (3.8)$$

F testi, serbestlik derecesine (*df*) göre ayarlanmış $\sum_{j=1}^n (\hat{Y}_j - \bar{y})^2$ ve $\sum_{j=1}^n (Y_j - \hat{Y}_j)^2$ gibi iki hata değişkeni arasındaki varyans analizidir. Regresyon analizinde payın serbestlik derecesi $df_1 = k - 1$ ve paydanın serbestlik derecesi $df_2 = n - k$ olmaktadır.

Hipotezleri incelemek için seçilen α güven düzeyi için *F* Çizelgesinden regresyonun serbestlik derecesindeki Çizelge değeri $F(k-1, n-1)$ bulunur, ardından hesaplanan *F*hesap istatistiği ile karşılaştırılır. $F_{hesap} < F(k-1, n-1)$ ise hipotezi reddedilerek modeldeki bağımsız değişkenlerin bağımlı değişkeni açıkladığı, regresyon modelinin istatistiksel açıdan anlamlı olduğu sonucuna varılır. Tersisi durumda ise hipotez kabul edilerek modelin anlamsız olduğu sonucuna söylenir. Bu durumda kullanılan veri seti kontrol edilerek yeni gözlem eklenerek, farklı bağımsız değişkenler kullanılarak modelin anlamlılığı tekrar kontrol edilir.

3.3.1.3.2 Regresyon katsayılarının anlamlılığı için t testi

t testi regresyon modelinde yer alan bağımlı değişken ile bağımsız değişkenler arasındaki ilişkinin gösterimi olan β parametrelerinin her birinin tek tek test edilmesi amacıyla kullanılır. Katsayıları test ederken ana kütle varyansı bilinmiyor ve gözlem sayısı $n < 30$ ise t testi ana kütle varyansı biliniyor ve gözlem sayısı $n > 30$ ise Z testi kullanılır (Kalaycı 2010). β_j gibi bir katsayının test edilmesi için aşağıdaki hipotez kurulur.

$$H_0: \beta_j = 0$$

$$H_0: \beta_j \neq 0$$

Hesaplanan test istatistiği çizelge değeri ile karşılaştırılarak katsayıların anlamlı veya anlamsız olduğu, bu katsayıya ait bağımsız değişkenin bağımlı değişkeni açıklayıp açıklamadığı tespit edilir. H_0 hipotezi kabul edilirse Bağımlı değişkeni, β_j katsayısına denk gelen X_j bağımsız değişkenin açıklamadığı ve modelden çıkarılması gerektiği söylenebilir (Tunç, 2018).

t testi aşağıdaki gibi hesaplanır.

Regresyon katsayılarının hataları, eşitlik (3.9)

$$S_{b_0} = S_{yx} \sqrt{\frac{\sum_{j=1}^n X_j^2}{n \sum_{j=1}^n (X_j - \bar{x})^2}} \quad \text{ve} \quad S_{b_1} = \frac{S_{yx}}{\sqrt{\sum_{j=1}^n (X_j - \bar{x})^2}} \quad (3.9)$$

Hata formüllerinden yararlanılarak regresyon katsayılarına ilişkin t değerleri aşağıdaki gibi hesaplanır:

Sabit Terim Anlamlılık Testi (3.10) eşitliği hesaplanır.

$$t = \frac{b_0}{S_{b_0}} = df = n - k \quad (3.10)$$

Regresyon Katsayısının anlamlılığı eşitlik (3.11) ile bulunur.

$$t = \frac{b_1}{S_{b_1}} = df = n - k \quad (3.11)$$

Korelasyon Katsayısının (r) Standart Hatası ve Değerleri eşitlik (3.12) ile hesaplanır.

$$S_r = \sqrt{\frac{(1-r)^2}{(n-k)}} \quad \text{ve} \quad t = \frac{r}{\sqrt{\frac{(1-r^2)}{(n-k)}}} \quad df = n - k \quad (3.12)$$

3.3.1.4 Regresyon analizinin uygunluğunun değerlendirilmesi

Regresyon sonuçları elde edilince hemen F testini inceleyip sonuçların anlamlı olup olmadığına bakılır. Fakat regresyon sonuçlarına modelin uygunluk aşamalarına göre bakılması büyük önem taşımaktadır. Regresyon sonuçlarına geçmeden önce, en küçük kareler tekniğinin doğrusallık, normallik, sabit varyanslılık, bağımsızlık, sapan birimlerin ve çoklu doğrusal bağlantının olmaması ve tahmin edilebilirlik varyansları yönünden sırayla incelenmesi gerekir. Elde edilen modelin uygunluğu için regresyon varsayımları aşağıdaki sırayla kontrol edilir (Albayrak, 2006).

1. Doğrusallığın Kontrol Edilmesi: Hatalar tahmin edilen değerler arasındaki serpilme diyagramına bakılır. Doğrusal olmayan bir dağılım, doğrusallık koşulunun sağlanmadığını gösterir. Doğrusallık varsayımı için ikinci olarak, hatalarla açıklayıcı değişkenler arasındaki serpilme diyagramları incelenebilir. Doğrusallık varsayımının sağlanamaması durumunda ya değişkenlerin daha uygun bir dönüşümle doğrusallaştırılması ya da doğrusal olmayan tahmin tekniklerinin kullanılması gerekir.
2. Normallığın Kontrol Edilmesi: Hataların normal olasılık grafiklerine bakılabilir. Hatalar güven sınırı içinde yer alıyorsa normallik varsayımının sağlandığını gösterir. Güven sınırları dışındaki hatalar, sapan birimlerin bir göstergesi olabilir.
3. Sabit Varyansın Kontrolü: Hatalarla tahmin edilen değerler veya hatalarla bağımsız değişkenler arasındaki serpilme diyagramları incelenerek bu varsayımın sağlanıp sağlanmadığına yüzeysel olarak karar verilir. Eğer serpilme diyagramı üzerindeki hatalar yukarıya veya aşağıya doğru oldukça anlamlı sistematik bir eğilim göstermeyip dikdörtgen şeklinde dağılıyorsa, sabit varyans varsayımının sağlandığını gösterir.
4. Bağımsızlık ve Otokorelasyonun Kontrol Edilmesi: Hatalarla zaman değişkeni arasındaki serpilme diyagramına bakılabilir.
5. Çoklu Doğrusal Bağlantının Kontrol Edilmesi: Bağımsız değişkenler için hesaplanan VIF değerleri incelenebilir. VIF değerleri 10'dan büyükse, çoklu doğrusal bağlantı söz konusu olabilir. Bağımsız değişkenler arasındaki yüksek

korelasyon katsayıları bağlantı sorununa neden olabilir. Çoklu doğrusal bağlantı sorunu söz konusu ise, bu sorun sapan birimlerden, örnekten ve ana kütleli yapısından kaynaklanmış olabilir.

3.3.2 Winters üstel düzeltme yöntemi

İlk olarak Holt, 1957’de mevsimsel olmayan zaman serilerinin trende sahip olmaması durumunda kullanılacak düzeltme yöntemini önerdi, 1958 yılında ise trendi de katarak yeni bir düzeltme yöntemi geliştirmiş oldu. Holt ile birlikte Modigliani, Muthve, Simon ve Winters düzeltme yöntemlerinin gelişmesinde büyük katkı sağlamışlardır. Winters 1960’da modele mevsimselliği de katarak hem trende hem mevsimselliğe sahip zaman serileri için yeni model geliştirmiştir (Ceyhan, 2009).

Geçmiş dönem değerlerinin ağırlıklı ortalaması hesaplanarak gelecek dönemin tahmin değeri olarak kullanılmasına üstel düzeltme tekniği denir. Ağırlıklı ortalamalar geçmişe gittikçe sıfır olmayacak şekilde üstel olarak azalma gösterir (Armutlu, 2008). Üstel düzeltme yönteminde tahmin yapılırken zaman serilerinde meydana gelen değişimler veya rassal dalgalanmalar dikkate alınır. Serideki dalgalanmaları azaltarak seride hâkim olan davranışın açık hale getirilmesini sağlamaktadır.

Çoğu zaman serisinin trend yapısı rasgele değişebilmektedir. Bu serilerin regresyon katsayısı her t zamanı için farklı değerlere sahip rastgele değişkendir. Yani bu serilerin trenleri stokastik özellik göstermektedir. Bu serilerin tahminleri yapılırken diğer ortalama yöntemleri kullanılamaz bunu yerine hem deterministik hem de stokastik trende sahip serilere uygulanabilen üstel düzeltme yöntemi kullanılır.

Üstel düzeltme yöntemleri basitliği ve çok fazla teknik bilgiye ihtiyaç duyulmadan kullanılabilmesi sebebiyle diğer tahmin yöntemlerine göre daha üstündür. Ayrıca verideki trendin ve mevsimselliğin varlığına göre farklı varsayımlar ile farklı düzeltme modelleri kurabilmesi de diğer bir üstünlüğüdür. Kısa dönemli öngörülerde başarılı sonuçlar vermesinden dolayı da sıkça kullanılan bir yöntemdir (Akgül, 2003)

Üstel düzeltme yönteminde gelecek dönemin ($T + 1$ döneminin) tahmini, T anındaki tahmin ve bu tahminin hatasının düzeltme katsayısı ile çarpılmasıyla eşitlik (3.13) gibi hesaplanır.

$$\hat{Z}_{T+1} = \hat{Z}_T + \alpha(e_t) \quad (3.13)$$

Denklem eşitlik (3.14-3.15) gibi de ifade edilir.

$$S_T = S_{T-1} + \alpha(Z_T - S_{T-1}) \quad (3.14)$$

$$\hat{Z}_{T+1} = S_T = \alpha\hat{Z}_{T+1} + (1 - \alpha)(S_{T-1}) \quad (3.15)$$

Üstel düzeltme yönteminde serinin tahminleri elde edilirken son döneme ait gözlem değerlerinin etkisi daha önemlidir. Üstel düzeltme yöntemi kendi içinde basit üstel düzeltme yöntemi, Brown üstel düzeltme tekniği Holt üstel düzeltme yöntemi ve Winters üstel düzeltme yöntemi olarak gruplandırılır.

Bu çalışmada Winters yöntemi ile ilgili bilgi verilecektir. Winters üstel düzeltme aynı anda hem trende ve mevsimsel dalgalanmaya sahip olan zaman serilerinin tahmininde kullanılır.

Winters Yöntemi ile tahmin modeli aşağıdaki eşitlik (3.16) gibi ifade edilir.

$$D_t = (S_i + (t - i)G_i) + c_t + \varepsilon_i \quad (3.16)$$

Üç parametre değerinin hesaplanmasıyla başlanılan modelde daha sonra bu parametrelerin değeri üstel düzeltme yöntemiyle güncellenir. Bu parametrelerin her biri farklı güncelleme denkleminde sahiptir.

1. Kesim Noktası (Mevsimselliğin etkisi olmayan veri için) (S_t)
2. Eğim (Mevsimselliğin etkisi olmayan veri için) (G_t)
3. Mevsimsel faktör (c_t)

(S_t) Kesim Noktası, (G_t) eğim ve (c_t) mevsimsel faktör aşağıdaki eşitlik (3.17-3.18-3.19) ile hesaplanır:

$$S_t = \alpha \left(\frac{D_t}{c_{t-N}} \right) + (1 - \alpha)(S_{t-1} + G_{t-1}) \quad (3.17)$$

$\left(\frac{D_t}{c_{t-N}} \right)$: Son gözlenen değer

$(S_{t-1} + G_{t-1})$: Son tahmin

$$G_t = \beta(S_t - S_{t-1}) + (1 - \beta)G_{t-1} \quad (3.18)$$

$(S_t - S_{t-1})$: Son gözlemin eğimi

$(1 - \beta)G_{t-1}$: Son tahmin eğimi

$$c_t = \gamma \left(\frac{D_t}{S_t} \right) + (1 - \gamma) c_{t-N} \quad (3.19)$$

$\left(\frac{D_t}{S_t} \right)$: Mevsimsel faktör t dönemi

c_{t-N} : Mevsimsel faktör ile son tahmin

$$0 \leq \alpha, \beta, \gamma \leq 1$$

Tahmin modeli aşağıdaki eşitlik (3.20) gibi oluşturulur.

$$\begin{aligned} F_{t,t+\tau} &= (S_t + \tau G_t) c_{\text{mod } e(t+\tau)_N}, \text{mod } e(t+\tau)_N \neq 0 \\ F_{t,t+\tau} &= (S_t + \tau G_t) c_N, \text{mod } e(t+\tau)_N = 0 \end{aligned} \quad (3.20)$$



4. ÇOKLU DOĞRUSAL REGRESYON YÖNTEMİYLE GÜNLÜK SİPARİŞ SİSTEMİ İÇİN YOLCU SAYISI TAHMİNİ

4.1 Veri Seti

Çalışmamızda 2016-2019 Yılları arasında TCDD'nin alt yüklenicisi olarak faaliyet gösteren bir firmanın Ocak 2017 – Ağustos 2019 yılları arasındaki Ankara-İstanbul arası YHT trenlerinde gerçekleşen yolcu sayılarıyla ilgili veri seti kullanılmıştır. Veri setinde, trenlere ait belirli tarihlerde sipariş anında gözükten yolcu sayısı, gerçekleşen yolcu sayısı, yemek sipariş türü ve sayısı, yemek tüketim sayıları, yemek yükleme miktarları bulunmaktadır. Çalışmamızın ilk aşaması olan günlük sipariş sistemi probleminde kullanılacak en uygun regresyon modeli için Ankara-İstanbul arasında hareket eden trenlerin 14.681 adet tren seferi verisi incelenmiştir. Hedeflenen Regresyon tabanlı tahmin modeli özel günleri kapsamayacağı için özel günlere ait veriler çıkartılmıştır. Örneğin Ramazan ayı dönemine karşılık gelen veriler çıkartılarak Ramazandan önceki ve sonraki en yakın iki ayın ortalama değerleri Ramazan verisi yerine kullanılmıştır. Kullanılan veride eksik kayıtlar olduğu için toplamda 9156 günlük veri kullanılmıştır.

Veri setinde haftanın her bir gününe ait tren sayıları farklıdır. Ayrıca günlük tren sayıları yıl boyunca da farklılık arz etmektedir. Bu farklılıkları normalize edebilmek için her bir güne ait olan toplam yolcu sayısı toplam tren sayısına bölünerek ortalama tren başına yolcu sayısı verisi üzerinden modellerimiz geliştirilmiştir.

Çalışmamızın ikinci aşaması olan Winters üstel düzeltme yöntemi kullanılarak oluşturulan haftalık sipariş modelinde kullanılan veri setinde ise özel günler çıkarılmadan yine aynı yıllar (2016-2019) aralığında bulunan veriler normalize edilerek kullanılmıştır.

4.2 Yöntem

Günlük yemek siparişi için çoklu doğrusal regresyon modeli kullanılacaktır. Belirli gruplara ayrılmış olan tren verilerinin her biri için haftanın her gününe özel ayrı regresyon denklemleri elde edilmiştir. Elde edilen günlük tahmin modellerinin anlamlılık ve güvenilirlik testleri kontrol edilmiştir. En uygun tahmin modelini bulabilmek için geliştirilen regresyon denklemleri sonuçlarının haftalık ortalama değerleri alınmış ve modellerin haftalık ortalama performansı bulunmuştur. Haftalık

ortalama performansta en uygun sonucu veren tahmin modelleri seçilmiştir. Daha sonra en iyi performansa sahip üç tahmin modeli seçilip son üç aya ait olan verilerle simüle edilmiştir.

Yöntem kısmının ilk bölümünde verilerinin hangi amaçla neden gruplandırıldığından bahsedilip ardından elde edilen regresyon modellerinin sonuçları açıklanacaktır. Modellerinin sonuçlarına göre karşılaştırmalar yapıp seçilen en uygun üç tahmin modeli yaklaşımını güvenilirliği MAPE kullanılarak test edilecektir.

4.2.1 Veri gruplaması

İstenilen sonuca ulaşılabilmesi için verilerin doğru ve kullanışlı bir biçimde gruplandırılması önem taşımaktadır. Yanlış yapılan veri gruplaması, elde edilen sonucun eksik ya da hatalı yorumlanmasına neden olabilir. Günlük sipariş sistemi kurmak amacıyla yapılan yolcu sayısı tahmini çalışmalarında en uygun regresyon modelini bulabilmek için sahip olduğumuz tren verilerinde çeşitli şekillerde gruplamalar yapılmıştır. Bu gruplamalarla her grubun sahip olduğu özelliğin regresyon denklemi üzerindeki etkileri gözlemlenmeye çalışılmıştır.

4.2.1.1 Gün bazlı modelleme yaklaşımı

Geliştirilecek tahmin modelinin haftanın her gününe özel olarak geliştirilmesine karar verilmiştir ve her güne özel farklı regresyon denklemi elde edilmiştir. Regresyon modellerinin her gün için ayrı ayrı geliştirilmesinin temel sebebi, yolcu sayılarının haftanın her günü farklı davranış sergilemesidir. Örneğin Salı gününe ait yolcu biletlerine trenin hareket etme saatine kadar ulaşılabilirken, Cuma gününe ya da Pazar gününe ait yolcu biletleri erkenden tükenmektedir.

4.2.1.2 Trenlerin kalkış zamanına göre kalan süre itibariyle gruplanması

Sipariş anı ile tren hareket saati arasında geçen zamanın yolcu davranışlarına etkisi olabileceği öngörüsüne dayalı olarak bu süresin regresyon denklemi üzerindeki etkisini belirlemek amacıyla yapılan gruplamadır. Bu gruplamayla sipariş verilecek olan trenlerin hareket saatine bakılmadan tüm trenler için toplu olarak yemek siparişi tahmini yapıldığında mı yoksa trenleri kendi içinde hareket saatine göre gruplandırarak tahmin yapıldığında mı daha doğru tahminlerin ortaya çıkacağı belirlenmeye çalışılmıştır. Bu bağlamda iki ana tren veri grubu oluşturulmuştur.

Birinci grupta, sipariş anından sonra geçen zaman ve trenlerin kalkış saati göz önüne alınmaksızın, aynı sipariş günü için tüm trenlerin (takip eden iki günlük) verileri aynı anda işleme alınmıştır. Bu grup “gruplandırılmamış veri” olarak adlandırılmıştır. Haftanın her bir gününe ait tren sayısındaki farklılığı ve yıl içinde olabilecek farklılığı normalize edebilmek için her bir güne ait olan toplam yolcu sayısı toplam tren sayısına bölünerek ortalama tren başına yolcu sayısı verisinin gruplandırılmamış veri için kullanımını Çizelge 4.1’de ifade edilmiştir.

Çizelge 4.1: Bir gün için gruplandırılmadan kullanılan veri örneği.

Gözlem Sayısı	Sipariş Tarihi	Sipariş Anında Yolcu Sayısı	Son Yolcu Sayısı	Bir Tren İçin Sipariş Anındaki Yolcu Sayısı	Bir Tren İçin Gerçekleşen Son Yolcu Sayısı
4	5.1.2018	1436	2633	359	658
3	7.4.2019	1318	2173	439	724
2	9.8.2018	528	1085	264	543
4	11.10.2019	1258	2192	315	548

İkinci grupta sipariş anından (10.00) sonra geçen sürenin, yolcu bilet alım davranışı üzerindeki etkisini gözlemlemek için tren verileri, trenlerin hareket saatine göre üçe ayrılarak incelenmiştir. Örneğin hareket saati 06.00 olan tren ile hareket saati 19.00 olan trene ait yolcu talepleri farklı davranış göstermektedir. Bu grup “gruplandırılmış veri” olarak adlandırılmıştır Şekil 4.1’de gruplamanın hangi saat aralığı için yapıldığı gösterilmiştir.



Şekil 4.1: Tren hareket saatine göre verilerin gruplanması.

4.2.1.3 Dönemsel gruplama

Müşteri davranışlarıyla ilgili olası başka bir etkinin dönemsel olabileceği düşünülmüştür. Müşteri davranışlarının mevsime ve aya göre değişiminin etkisini analiz için eldeki veri tüm yıllığa ek olarak, mevsimsel (4 mevsim) ve aylık olmak üzere toplamda üç guruba ayrılarak kullanılmıştır. Dönemsel gruplamayla haftanın her gününün kendi içinde farklı davranış gösterdiği gibi aynı günün de mevsimsel ve aylık olarak farklı davranışa sahip olup olmayacağı belirlenmeye çalışılmıştır. Her günün yıllık, mevsimsel ve aylık olarak ayrı ayrı regresyon analizleri yapılmıştır.

4.2.2 Çoklu regresyon modelleri geliştirilmesi

Haftanın her günü için ayrı modeller geliştirilip sonraki iki gün için yolcu sayısı tahminini yaparken kullanılan en önemli bağımsız değişken yemek siparişi (sabah 10.00) anındaki bilet almış yolcu sayısıdır. Aynı günün bir hafta önceki gerçekleşmiş son yolcu sayısı ve yine haftanın aynı günü için ortalama yolcu sayısı tahmin yaparken kullanacağımız diğer iki bağımsız değişken olarak belirlenmiştir. Bu değişkenlerden ilk ikisi ve üçü kullanılarak iki grup regresyon denklemleri denenmiştir. Yani ilk regresyon grubunda bağımlı değişken olarak son yolcu sayısı; bağımsız değişken olarak sipariş anındaki biletli yolcu sayısı ve bir hafta önceki aynı gün yolcu sayısı kullanılmıştır (Tren başına ortalama yolcu sayısı). İkinci grupta ise ortalama yolcu sayısı bağımsız değişken olarak eklenmiş ve bağımsız değişken sayısı üç olmuştur. Bu modeller aşağıda gösterilmiştir;

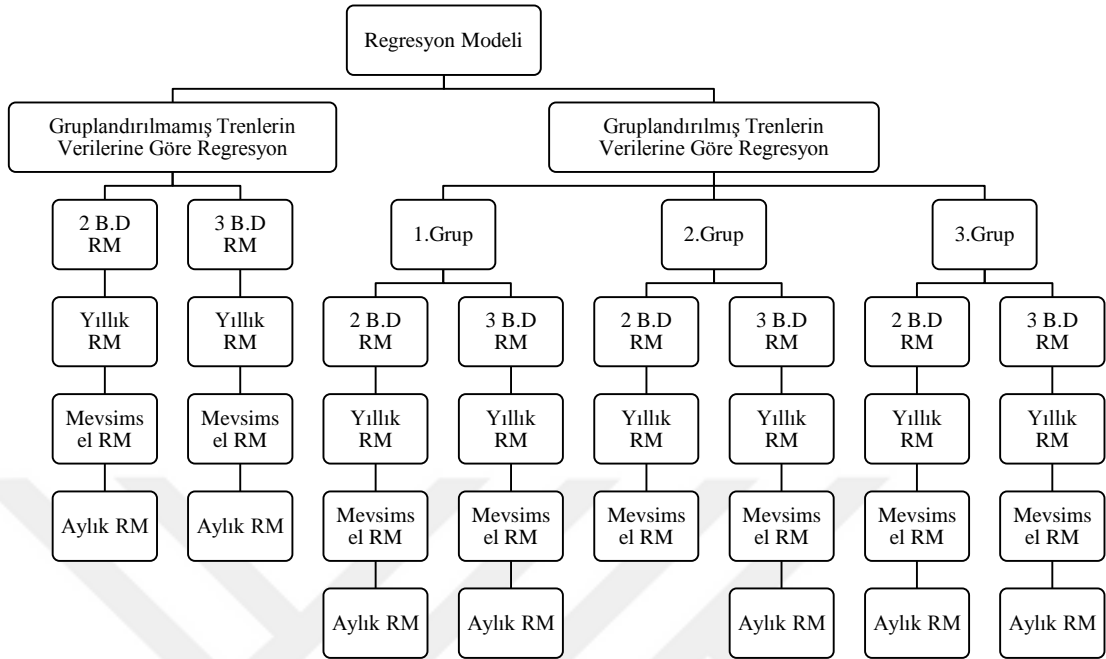
İki Bağımsız değişken ile kurulan regresyon modeli;

$$\text{Gerçekleşen Son Yolcu sayısı} = B_0 + B_1(\text{Sipariş anındaki yolcu sayısı}) + B_2(\text{Aynı gün için bir hafta önceki yolcu sayısı}) + \varepsilon$$

Üç Bağımsız değişken ile kurulan regresyon modeli;

$$\text{Son Yolcu sayısı} = B_0 + B_1(\text{Sipariş anındaki yolcu sayısı}) + B_2(\text{Aynı gün için bir hafta önceki yolcu sayısı}) + B_3(\text{Aynı gün için ortalama yolcu sayısı}) + \varepsilon$$

Tüm veri gruplaması ve regresyon modelleri şematik olarak aşağıda Şekil 4.2’de gösterilmiştir.



Şekil 4.2: Regresyon analizi temel gruplama.

Şekil 3’teki her bir kutudaki “yıllık” modeller yedi model içerir, haftanın her bir günü için bir model. “Mevsimsel” modeller $4 \times 7 = 28$ model içerir (4 mevsim ve 7 gün). Aylık modeller ise $12 \times 7 = 84$ model içermektedir. Veri gruplamaya ve bağımsız değişken sayısına göre her bir tür regresyon modelinden toplamda sekiz grup bulunmaktadır ve bu gruplar şekil 3 teki sütunlara karşılık gelir. Dolayısıyla çalışmamızda toplamda $8 \times (7 + 28 + 84) = 952$ ayrı regresyon modeli geliştirilmiştir. Regresyon analizleri için Minitab 19 programı kullanılmıştır.

4.2.3 Regresyon modellerin sonuçlarının karşılaştırılması

Regresyon modelleri, regresyonun güvenilirliğini gösteren R-kare (determinasyon katsayısı) ve anlamlılığı belirleyen F testi ve t testi sonuçları baz alınarak karşılaştırma yapılmıştır.

Gruplanmış ve gruplandırılmamış tren verileri ile haftanın her gününe özel yıllık, mevsimsel ve aylık olarak iki ve üç bağımsız değişkenli regresyon denklemleri kurulmuştur. Öncelikle her gruptaki haftanın günleri için ayarlanmış R-kare (Determinasyon Katsayısı) değeri ve F testi ve t testi sonuçları hesaplanmıştır. Yemek

siparişi sisteminde her gün için farklı regresyon modeli kullanılamayacağından (Pazartesi günü için “gruplanmamış yıllık 2 bağımsız değişkenli tahmin modeli, Perşembe günü için gruplanmış mevsimsel üç bağımsız değişkenli tahmin modeli) , haftanın yedi gününün ortalama güvenilirlik ve anlamlılık değerleri alınmış ve regresyon modellerinin sonuçları bu ortalama değerler üzerinden karşılaştırılmıştır.

Gruplandırılmamış yıllık modelde, bir günün üç yıl içindeki tüm verileri, ay ve mevsim ayırımı yapmaksızın gözlem olarak kullanılmıştır. Haftanın her günü için bir regresyon denklemi kurulmuş ve denklem sonuçlarının (ayarlanmış R-kare değerlerinin) ortalaması alınmıştır. Mevsimsel modelde, haftanın her bir gününün her mevsimdeki verisi ayrı ayrı kullanılarak o güne ait dört regresyon denklemi kurulmuş ve mevsimlerin ortalama regresyon denkleminin istatistikleri alınarak yedi gün için bir sonuç hesaplanmıştır. Aylık modelde aynı gün için günün 12 aydaki verileri ayrı ayrı kullanılarak o güne ait 12 regresyon denklemi kurulmuş ve ayların regresyon denklemi sonuçlarının ortalaması alınmıştır.

Gruplandırılmış tren veri grubunda ise yukarıdaki ortalamalara ek, 3 veri grubunun (06.00-12.00 Ankara-İstanbul gidiş-dönüş trenleri, 12.00'den sonra Ankara-İstanbul gidiş trenleri, ertesi gün İstanbul'dan dönüş trenleri) sonuçlarının ortalaması alınarak 6 adet regresyon modeli sonucu oluşturulmuştur. Bu analizle yıllık, mevsimsel ve aylık yaklaşım için ayrı ayrı tekrarlanmıştır.

Ortalama değerler içinden en yüksek ayarlanmış R-kare değerine sahip olan üç regresyon model yaklaşımı seçilmiştir. Bu seçilen modellerin F testi ve t testi ortalama sonuçları kontrol edilmiş ($p=0,000 <0,05$) , %95 güven aralığında anlamlı bulunmuştur.

Güvenirlilikleri ve anlamlılıkları kontrol edilen bu üç regresyon modelinin doğruluğu MAPE yöntemiyle karşılaştırılmıştır. Doğruluk testi için veri setinin son üç ayı (Haziran 2019, Temmuz 2019, Ağustos 2019) kullanılmıştır. Üç regresyon modelinin 2019 Mayıs ayına kadar olan verileri gözlem olarak kullanılarak yeniden regresyon denklemleri kurulmuştur. Elde edilen regresyon modeliyle haziran ayının tahmin doğruluğu yapılmış MAPE değerleri hesaplanmıştır. Ardından temmuz ve ağustos ayları verileri ile denklem iki kez güncellenerek her ayın MAPE değeri ayrı olarak hesaplanmıştır. Böylece tahmin yaklaşımımızın gerçek hayatta uygulaması simüle edilmiştir. MAPE değeri hesaplanırken de önce her gün için hesaplama yapılmış daha

sonra regresyon analizi sonucunda olduğu gibi haftalık ortalama alınarak MAPE değerleri karşılaştırılmıştır.

4.2.4 Regresyon analizi ve sonuç çizelgeleri

Regresyon analizi sonuçları regresyon modellerinin ortalama ayarlanmış R-kare, F testi ve t testi sonuç değerleri üzerinden raporlanmıştır. Gruplandırılmış ve gruplandırılmamış tren verileri için öncelikle iki bağımsız değişkenli regresyon modelleri kurulmuştur. Çizelge 4.2’de gruplandırılmamış verinin yıllık iki ve üç bağımsız değişkenli regresyon modeli R-kare değeri gösterilmiştir, mevsimsel iki ve üç bağımsız değişkenli regresyon ayarlanmış R-kare değeri sırasıyla Çizelge 4.3 ve Çizelge 4.4’te, aylık regresyon modelinin ayarlanmış R- kare değerleri ise Çizelge 4.5 ve Çizelge 4.6’ dır.

Çizelge 4.2: Yıllık iki ve üç bağımsız değişkenli regresyon modeli ayarlanmış r-kare değeri.

Gün	2 BD Regresyon R-Kare	3 BD Regresyon R-Kare
Pazartesi	32,85%	32,82%
Salı	55,25%	55,60%
Çarşamba	62,37%	62,01%
Perşembe	40,72%	40,14%
Cuma	70,78%	70,48%
Cumartesi	57,92%	58,03%
Pazar	70,34%	70,80%
Ort.	55,75%	55,70%

Çizelge 4.3: Mevsimsel iki bağımsız değişkenli regresyon modeli ayarlanmış r-kare değeri.

Gün	Kış	İlkbahar	Yaz	Sonbahar	Ort.
Pazartesi	66,07%	58,91%	62,55%	67,59%	63,78%
Salı	51,17%	30,42%	68,80%	81,08%	57,87%
Çarşamba	68,20%	84,77%	67,60%	58,39%	69,74%
Perşembe	45,81%	43,41%	50,47%	20,03%	39,93%
Cuma	71,07%	87,90%	81,00%	69,68%	77,41%
Cumartesi	78,80%	65,41%	57,44%	33,64%	58,82%
Pazar	76,52%	81,67%	64,82%	73,33%	74,09%
Ort.	65,38%	64,64%	64,67%	57,68%	63,09%

Çizelge 4.4: Mevsimsel üç bağımsız değişkenli regresyon modeli ayarlanmış r-kare değeri.

Gün	Kış	İlkbahar	Yaz	Sonbahar	Ort.
Pazartesi	0,00%	59,13%	61,30%	59,12%	44,89%
Salı	49,37%	29,81%	38,41%	39,43%	39,26%
Çarşamba	66,14%	67,80%	58,01%	63,30%	63,81%
Perşembe	43,49%	48,07%	48,07%	27,03%	41,67%
Cuma	60,37%	50,02%	69,32%	68,59%	62,08%
Cumartesi	59,13%	45,95%	55,53%	33,32%	48,48%
Pazar	57,17%	67,11%	62,01%	55,27%	60,39%
Ort.	47,95%	52,56%	53,30%	49,44%	51,51%

Çizelge 4.5: Aylık iki bağımsız değişkenli regresyon modeli ayarlanmış r-kare değeri.

Ay	Pazartesi	Salı	Çarşamba	Perşembe	Cuma	Cumartesi	Pazar	Ort.
Ocak	62,28%	0,00%	74,92%	60,16%	86,31%	85,00%	83,55%	64,60%
Şubat	93,20%	0,00%	83,22%	18,87%	71,87%	67,21%	91,49%	60,84%
Mart	49,72%	0,00%	82,55%	0,25%	94,44%	0,00%	73,71%	42,95%
Nisan	75,69%	86,72%	89,11%	65,68%	71,23%	64,34%	84,13%	76,70%
Mayıs	0,00%	67,51%	87,67%	66,77%	56,58%	62,37%	30,77%	53,10%
Haziran	21,85%	72,57%	55,88%	0,00%	77,81%	0,00%	0,00%	32,59%
Temmuz	70,19%	68,72%	82,03%	51,58%	65,47%	66,21%	63,53%	66,82%
Ağustos	63,36%	76,44%	84,94%	64,97%	87,23%	36,46%	50,80%	66,31%
Eylül	32,63%	63,54%	56,16%	86,90%	40,25%	68,28%	0,00%	49,68%
Ekim	64,67%	88,34%	0,00%	0,00%	89,96%	96,54%	88,90%	61,20%
Kasım	0,00%	90,79%	0,00%	15,18%	76,07%	46,63%	89,00%	45,38%
Aralık	69,11%	0,00%	36,37%	0,00%	76,49%	70,16%	0,00%	36,02%
Ort.	50,23%	51,22%	61,07%	35,86%	74,48%	55,27%	54,66%	54,68%

Çizelge 4.6: Aylık üç bağımsız değişkenli regresyon modeli ayarlanmış r-kare değeri.

Ay	Pazartesi	Salı	Çarşamba	Perşembe	Cuma	Cumartesi	Pazar	Ort.
Ocak	60,64%	43,97%	0,00%	56,75%	86,36%	86,52%	84,22%	59,78%
Şubat	93,57%	0,00%	89,91%	8,47%	0,00%	0,00%	96,82%	41,25%
Mart	71,14%	0,00%	83,94%	55,34%	95,79%	0,00%	94,28%	57,21%
Nisan	0,00%	91,37%	0,00%	0,00%	83,74%	66,50%	0,00%	34,52%
Mayıs	0,00%	0,00%	89,20%	57,34%	0,00%	73,28%	77,35%	42,45%
Haziran	89,15%	90,05%	80,23%	91,99%	0,00%	0,00%	0,00%	50,20%
Temmuz	77,57%	70,93%	88,79%	46,41%	0,00%	63,73%	66,88%	59,19%
Ağustos	87,28%	81,23%	92,09%	80,13%	85,26%	44,42%	56,67%	75,30%
Eylül	0,00%	82,03%	0,00%	91,39%	0,00%	79,81%	61,75%	45,00%
Ekim	86,63%	97,48%	94,88%	0,00%	95,77%	100,00%	92,25%	81,00%
Kasım	88,07%	91,79%	0,00%	39,39%	76,65%	82,74%	88,99%	66,80%
Aralık	0,00%	0,00%	0,00%	0,00%	84,44%	75,01%	64,06%	31,93%
Ort.	54,50%	54,07%	51,59%	43,93%	50,67%	56,00%	65,27%	53,72%

Gruplandırılmış veri için R-kare değerleri öncelikle alt gruplar için hesaplanmış, daha sonra hesaplanan değerlerin ortalaması alınmıştır. Sonuçlar gruplandırılmamış verilerde olduğu önce yıllık iki ve üç bağımsız değişkenli model için Çizelge 4.7’de, mevsimsel ve aylık iki ve üç bağımsız değişkenli regresyon modeli R-kare değerleri ise sırasıyla Çizelge 4.8, Çizelge 4.9, Çizelge 4.10 ve Çizelge 4.11’de gösterilmiştir.

Çizelge 4.7: Yıllık iki ve üç bağımsız değişkenli regresyon modeli ayarlanmış r-kare değeri.

Grup	2 BD Regresyon R-Kare	3 BD Regresyon R-Kare
1.Grup	61,92%	62,30%
2.Grup	56,06%	56,45%
3.Grup	42,33%	42,02%
Ort.	53,44%	53,59%

Çizelge 4.8: Mevsimsel iki bağımsız değişkenli regresyon modeli ayarlanmış r-kare değeri.

Grup	Kış	İlkbahar	Yaz	Sonbahar	Ort.
1.Grup	58,81%	76,50%	66,92%	56,12%	64,59%
2.Grup	56,70%	54,98%	40,85%	53,10%	51,41%
3.Grup	50,91%	46,87%	35,55%	30,30%	40,91%
Ort.	55,47%	59,45%	47,77%	46,51%	52,30%

Çizelge 4.9: Mevsimsel üç bağımsız değişkenli regresyon modeli ayarlanmış r-kare değeri.

Grup	Kış	İlkbahar	Yaz	Sonbahar	Ort.
1.Grup	57,52%	77,23%	67,21%	60,21%	65,54%
2.Grup	57,33%	61,40%	41,54%	57,30%	54,39%
3.Grup	52,12%	50,72%	38,48%	32,23%	43,39%
Ort.	55,66%	63,12%	49,08%	49,91%	54,44%

Çizelge 4.10: Aylık iki bağımsız değişkenli regresyon modeli ayarlanmış r-kare değeri.

Ay	1.Grup	2.Grup	3.Grup	Ort.
Ocak	55,26%	53,73%	50,45%	53,15%
Şubat	64,80%	45,37%	44,24%	51,47%
Mart	38,86%	57,47%	38,06%	44,80%
Nisan	75,50%	55,83%	39,93%	57,09%
Mayıs	62,68%	32,22%	49,23%	48,04%
Haziran	49,34%	25,58%	43,94%	39,62%
Temmuz	61,48%	20,52%	22,22%	34,74%
Ağustos	46,71%	37,61%	20,06%	34,79%
Eylül	46,00%	37,93%	46,49%	43,47%
Ekim	56,78%	59,43%	41,03%	52,41%
Kasım	63,82%	65,55%	54,47%	61,28%
Aralık	38,97%	43,60%	49,56%	44,04%
Ort.	55,02%	44,57%	41,64%	47,08%

Çizelge 4.11: Gruplandırılmış aylık üç bağımsız değişkenli regresyon modeli ayarlanmış r-kare değeri.

Ay	1.Grup	2.Grup	3.Grup	Ort.
Ocak	54,03%	55,31%	52,82%	54,06%
Şubat	59,83%	51,72%	42,60%	51,38%
Mart	57,44%	63,85%	46,18%	55,82%
Nisan	80,91%	65,98%	44,65%	63,85%
Mayıs	68,46%	38,37%	60,69%	55,84%
Haziran	55,36%	32,14%	23,41%	36,97%
Temmuz	53,35%	26,52%	33,59%	37,82%
Ağustos	40,24%	37,60%	32,47%	36,77%
Eylül	16,73%	26,08%	35,66%	26,15%
Ekim	48,87%	52,08%	62,56%	54,50%
Kasım	23,84%	60,29%	55,89%	46,67%
Aralık	13,47%	19,98%	37,21%	23,55%
Ort.	47,71%	44,16%	43,98%	45,28%

Tüm Regresyon Modellerine ait ayarlanmış R-kare ve F değerine ait sonuçlar Çizelge 4.12'deki gibidir.

Çizelge 4.12: Tüm modeller için ayarlanmış r-kare ve f değeri.


Gruplandırılmış İki Bağımsız Değişkenli Regresyon Modeli						
Dönem	R-Kare	F	P	p1	p2	p3
Yıllık	53,44%	64,25	0,00	0,00	0,00	
Mevsimsel	52,30%	19,70	0,02	0,06	0,22	
Aylık	47,08%	9,74	0,17	0,90	0,50	

Gruplandırılmış Üç Bağımsız Değişkenli Regresyon Modeli						
Dönem	R-Kare	F	P	p1	p2	p3
Yıllık	53,59%	43,78	0,00	0,00	0,00	0,35
Mevsimsel	54,44%	14,73	0,01	0,04	0,19	0,34
Aylık	45,28%	276,60	0,15	0,19	1,39	0,38

Gruplandırılmamış İki Bağımsız Değişkenli Regresyon Modeli						
Dönem	R-Kare	F	P	p1	p2	p3
Yıllık	55,75%	78,89	0,00	0,00	0,00	
Mevsimsel	63,09%	29,22	0,00	0,02	0,00	
Aylık	54,68%	13,52	0,10	0,19	0,35	

Gruplandırılmamış Üç Bağımsız Değişkenli Regresyon Modeli						
Dönem	R-Kare	F	P	p1	p2	p3
Yıllık	55,70%	52,93	0,00	0,00	0,00	0,00
Mevsimsel	51,51%	20,07	0,00	0,07	0,25	0,45
Aylık	53,72%	14,99	0,11	0,23	0,47	0,37

Yapılan regresyon analizi sonucunda F istatistiğinin yıllık regresyon modellerinin tümü ve iki bağımsız değişkenli gruplandırılmamış mevsimsel regresyon modeli için ($P=0,000 < 0,05$) %95 güven aralığında anlamlı olduğu görülmüştür. İlgili regresyonların modeli açıklama oranı (R-kare değeri), regresyona giren bağımsız değişkenlerin modeli kabul edilebilir seviyede açıkladığını ve iyi bir uyum değerini göstermektedir. Yine yıllık regresyon modellerinin tümünde ve iki bağımsız değişkenli gruplandırılmamış mevsimsel regresyon modellerinde yer alan bağımsız değişkenlerin t testi ($p=0,00$) $< 0,05$ olup istatistiksel olarak regresyon anlamlı bulunmuştur.



Şekil 4.3: Regresyon modelleri ayarlanmış r-kare karşılaştırması.

Şekil 4.3'te yukardaki çizelgelerde verilmiş olan ayarlanmış R-kare değerleri özetlenmiştir. Genel olarak tahmin modelleri birbirine yakın determinasyon katsayısı değerine sahip olduğu gözlemlenmiştir. En iyi tahmin sonuçlarına ulaşabilmek için on iki tahmin modeli arasından en iyi üç ayarlanmış R-kare değerine sahip regresyon modelleme yaklaşımını seçilmiştir. Modellerin geçerlilikleri kontrol edildikten sonra Çizelge 4.13 ve Çizelge 4.14'te bulunan regresyon denklemleri yolcu sayısı tahminleri yapılmış ve model tahmin performanslarının MAPE itibariyle simüle edilip karşılaştırılmıştır. Ayarlanmış R-kare itibariyle, gruplandırılmamış tren verilerine sahip gruplandırılmamış iki bağımsız değişkenli yıllık ve mevsimsel regresyon analizi ve gruplandırılmamış üç bağımsız değişkenli yıllık regresyon analizi en yüksek R-kare değerlerine sahiptir ve bu modeller için uygunluk analizinden sonraki bölümde MAPE analizi yapılmıştır.

Çizelge: 4.13 Gruplandırılmamış mevsimsel 2BD regresyon denklemleri.

Regresyon Modeli	Denklem
Gruplandırılmamış Mevsimsel 2 BD Pazartesi Kış	KSYS = 25,79 + 0,298 BHÖYS+ 0,5784 SAYS
Gruplandırılmamış Mevsimsel 2 BD Pazartesi İlkbahar	KSYS = 29,45 + 0,115 BHÖYS+ 0,788 SAYS
Gruplandırılmamış Mevsimsel 2 BD Pazartesi Yaz	KSYS = 25,33 + 0,557 BHÖYS+ 0,1503 SAYS
Gruplandırılmamış Mevsimsel 2 BD Pazartesi Sonbahar	KSYS = 12,66 + 0,555 BHÖYS+ 0,586 SAYS
Gruplandırılmamış Mevsimsel 2 BD Salı Kış	KSYS = 41,69 + 0,034 BHÖYS+ 0,599 SAYS
Gruplandırılmamış Mevsimsel 2 BD Salı İlkbahar	KSYS = 30,7 + 0,037 BHÖYS+ 1,011 SAYS
Gruplandırılmamış Mevsimsel 2 BD Salı Yaz	KSYS = 26,27 + 0,556 BHÖYS+ 0,1322 SAYS
Gruplandırılmamış Mevsimsel 2 BD Salı Sonbahar	KSYS = 2,73 + 0,662 BHÖYS+ 0,719 SAYS
Gruplandırılmamış Mevsimsel 2 BD Çarşamba Kış	KSYS = 33,03 + 0,136 BHÖYS+ 0,6364 SAYS
Gruplandırılmamış Mevsimsel 2 BD Çarşamba İlkbahar	KSYS = 7,57 + 0,435 BHÖYS+ 0,915 SAYS
Gruplandırılmamış Mevsimsel 2 BD Çarşamba Yaz	KSYS = 37,66 + 0,350 BHÖYS+ 0,1944 SAYS
Gruplandırılmamış Mevsimsel 2 BD Çarşamba Sonbahar	KSYS = 32,66 + 0,283 BHÖYS+ 0,504 SAYS
Gruplandırılmamış Mevsimsel 2 BD Perşembe Kış	KSYS = 42,3 + 0,134 BHÖYS+ 0,3871 SAYS
Gruplandırılmamış Mevsimsel 2 BD Perşembe İlkbahar	KSYS = 57,0 + 0,071 BHÖYS+ 0,279 SAYS
Gruplandırılmamış Mevsimsel 2 BD Perşembe Yaz	KSYS = 34,1 + 0,481 BHÖYS+ 0,1001 SAYS
Gruplandırılmamış Mevsimsel 2 BD Perşembe Sonbahar	KSYS = 69,7 + 0,013 BHÖYS+ 0,1421 SAYS
Gruplandırılmamış Mevsimsel 2 BD Cuma Kış	KSYS = 37,71 + 0,139 BHÖYS+ 0,4290 SAYS
Gruplandırılmamış Mevsimsel 2 BD Cuma İlkbahar	KSYS = 12,75 + 0,380 BHÖYS+ 0,727 SAYS
Gruplandırılmamış Mevsimsel 2 BD Cuma Yaz	KSYS = 17,49 + 0,678 BHÖYS+ 0,1138 SAYS
Gruplandırılmamış Mevsimsel 2 BD Cuma Sonbahar	KSYS = 24,67 + 0,465 BHÖYS+ 0,322 SAYS
Gruplandırılmamış Mevsimsel 2 BD Cumartesi Kış	KSYS = 35,81 + 0,150 BHÖYS+ 0,4391 SAYS
Gruplandırılmamış Mevsimsel 2 BD Cumartesi İlkbahar	KSYS = 21,20 + 0,591 BHÖYS+ 0,1824 SAYS
Gruplandırılmamış Mevsimsel 2 BD Cumartesi Yaz	KSYS = 15,1 + 0,758 BHÖYS+ 0,0531 SAYS
Gruplandırılmamış Mevsimsel 2 BD Cumartesi Sonbahar	KSYS = 35,8 + 0,477 BHÖYS+ 0,1001 SAYS
Gruplandırılmamış Mevsimsel 2 BD Pazar Kış	KSYS = 31,84 + 0,179 BHÖYS+ 0,5574 SAYS
Gruplandırılmamış Mevsimsel 2 BD Pazar İlkbahar	KSYS = 9,65 + 0,492 BHÖYS+ 0,679 SAYS
Gruplandırılmamış Mevsimsel 2 BD Pazar Yaz	KSYS = 28,33 + 0,515 BHÖYS+ 0,1495 SAYS
Gruplandırılmamış Mevsimsel 2 BD Pazar Sonbahar	KSYS = 19,48 + 0,468 BHÖYS+ 0,463 SAYS

Çizelge: 4.14 Gruplandırılmamış yıllık iki ve üç BD regresyon denklemleri.

Regresyon Modeli	Denklem
Gruplandırılmamış Yıllık 2 BD Pazartesi	KSYS = 33,19 + 0,3005 SAYS+ 0,3470 BHÖYS
Gruplandırılmamış Yıllık 2 BD Salı	KSYS = 27,49 + 0,3398 SAYS + 0,4001 BHÖYS
Gruplandırılmamış Yıllık 2 BD Çarşamba	KSYS = 28,61 + 0,3072 SAYS + 0,4043 BHÖYS
Gruplandırılmamış Yıllık 2 BD Perşembe	KSYS = 42,17 + 0,1727 SAYS + 0,3262 BHÖYS
Gruplandırılmamış Yıllık 2 BD Cuma	KSYS = 24,36 + 0,3067 SAYS + 0,4560 BHÖYS
Gruplandırılmamış Yıllık 2 BD Cumartesi	KSYS = 21,53 + 0,1505 SAYS + 0,6011 BHÖYS
Gruplandırılmamış Yıllık 2 BD Pazar	KSYS = 19,58 + 0,3316 SAYS + 0,5228 BHÖYS
Gruplandırılmamış Yıllık 3 BD Pazartesi	KSYS = 20,4 + 0,2897 SAYS+ 0,3290 BHÖYS + 0,244 OYS
Gruplandırılmamış Yıllık 3 BD Salı	KSYS = 48,1 + 0,3557 SAYS + 0,4375 BHÖYS- 0,406 OYS
Gruplandırılmamış Yıllık 3 BD Çarşamba	KSYS = 29,2 + 0,3079 SAYS + 0,4065 BHÖYS- 0,012 OYS
Gruplandırılmamış Yıllık 3 BD Perşembe	KSYS = 40,5 + 0,1707 SAYS + 0,3199 BHÖYS+ 0,031 OYS
Gruplandırılmamış Yıllık 3 BD Cuma	KSYS = 25,55 + 0,3084 SAYS + 0,4649 BHÖYS- 0,030 OYS
Gruplandırılmamış Yıllık 3 BD Cumartesi	KSYS = 31,7 + 0,1572 SAYS + 0,6265 BHÖYS- 0,164 OYS
Gruplandırılmamış Yıllık 3 BD Pazar	KSYS = 36,3 + 0,3508 SAYS + 0,5639 BHÖYS- 0,325 OYS

4.2.5 Seçilen regresyon modellerinin geçerliliği

Seçilen modellerin saçılım grafikleri incelenmiş ve en küçük kareler terimin varsayımları olan;

-Hata terimlerinin normalliği

-Hata terimlerinin seri korelasyon olmaması

-Hata terimlerinin varyanslarının homojenliği şartlarını sağladığı gözlemlenmiştir.

-Regresyon analizinin VIF değerleri bağımsız değişkenler arasında çoklu lineer bağlantı olmadığını göstermiştir.

Yapılan analiz sonucunda F istatistiğinin anlamlı olduğu, ($P=0,000 < 0,05$, %95 güven aralığında) görülmüştür. Seçilen regresyonun modellerinin R-kare değerleri kabul edilebilir seviyede (%55,75-%63,09) olup bu sonuç regresyona giren bağımsız değişkenlerin modeli oldukça yüksek seviyede açıkladığını ve iyi bir uyum değerine sahip olduğunu göstermektedir. Modelde yer alan bağımsız değişkenler ($p=0,00$) $< 0,05$ olup istatistiksel olarak anlamlı bulunmuştur. Regresyon doğrusallığını gösterme yöntemlerinden biri olan bağımsız değişkenler ile bağımlı değişken arasındaki ilişkiyi gösteren grafik Şekil 4.5'te verilmiştir.

Söz konusu modellerin geçerliliğini gösteren Çizelge 4.15 ve Şekil 4.4 aşağıda belirtilmektedir. Çizelge 4.15'te bağımsız değişkenlere ait VIF değerleri < 10 ve aralında bağımlı ilişki olmadığını gösterir.

Çizelge 4.15: Seçilen modellerin VIF değerleri.

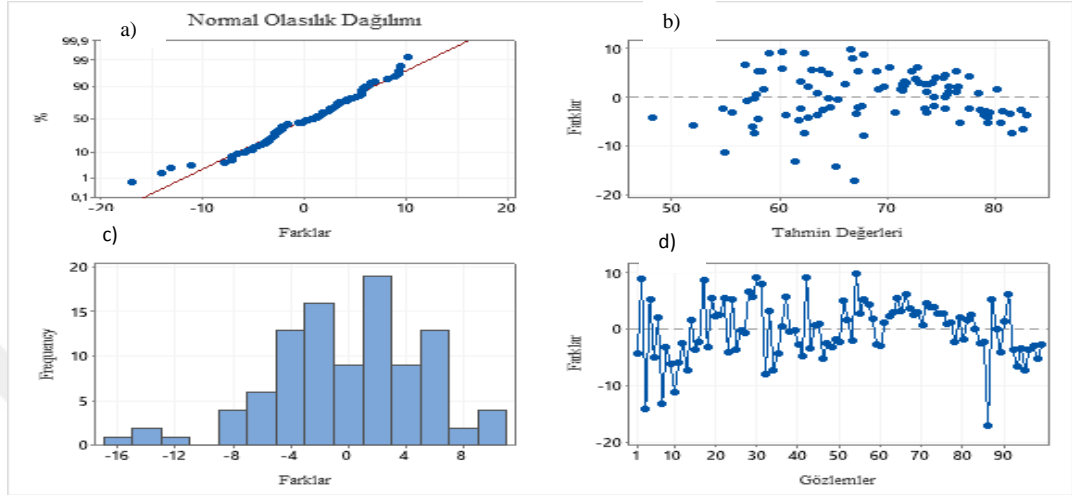
Gruplandırılmamış Yıllık 2 BD Regresyon Modeli VIF değerleri							
Gün	Pazartesi	Salı	Çarşamba	Perşembe	Cuma	Cumartesi	Pazar
VIF	1,17	1,46	1,32	1,22	1,37	1,11	1,29

Gruplandırılmamış Yıllık 3 BD Regresyon Modeli VIF değerleri							
Model/Gün	Pazartesi	Salı	Çarşamba	Perşembe	Cuma	Cumartesi	Pazar
SPAY	1,22	1,52	1,43	1,34	1,45	1,15	1,38
BHÖYS	1,27	1,65	1,77	1,44	2,19	1,23	1,52
OYS	1,21	1,37	1,76	1,48	2,16	1,2	1,47


Gruplandırılmamış Mevsimsel 2 BD Regresyon Modeli VIF değerleri							
Dönem/Gün	Pazartesi	Salı	Çarşamba	Perşembe	Cuma	Cumartesi	Pazar
Kış	1,12	1,28	1,02	1,18	1,12	1,43	1,48
İlkbahar	1,19	1,13	1,57	2,29	2,46	1,13	1,25
Yaz	1,27	1,93	1,84	1,23	2,09	1,07	1,31
Sonbahar	1,06	1,44	1,24	1,3	1,79	1,02	1,47

Şekil 4.4 'te ise bir güne ait olan regresyon modelinin grafiklerinden.

- Hataların dağılımı regresyon analizinin normallik varsayımı sağladığını
- Tahmin edilen değerler ile hataların dağılımı sabit varyansı
- Gözlem değerleri ile hataların grafiği, hata terimlerinin seri korelasyon olmadığını gösterir.



Şekil 4.4: Bir güne ait regresyon analizi uygunluk grafikleri.




Şekil 4.5: Bir güne ait üç bağımsız değişkenle ilgili bağımlı değişken arasındaki ilişki.

4.2.6 Seçilen regresyon modelleri için tahmin MAPE analizi

En yüksek R-kare değerine sahip olan 3 model için tahmin doğruluk test yöntemi olarak MAPE tercih edilmiştir. Haziran, Temmuz, Ağustos verileri bu üç regresyon modelleme yaklaşımını test etmek için kullanılmıştır. Her model için Mayıs 2019'a kadar olan veri kullanılarak regresyon denklemleri kurulmuştur. Bu modeller aylık veriyle güncelleneceği varsayılarak Haziran, Temmuz ve Ağustos başında yeniden güncellenerek gerçek hayatta bu üç modelleme yaklaşımının performansı simule edilmiştir. MAPE değerleri günlük olarak hesaplanmış ve her günün ortalaması alınarak bu 3 regresyon modelleme yaklaşımının tahmin doğruluğu 3 ay için Çizelge 4.17'de verilmiştir. MAPE itibarıyla genel anlamda üç yaklaşımında oldukça başarılı olduğu gözlemlenmiştir. Regresyon analizi sonuçları en iyi model olan "gruplanmamış mevsimsel iki bağımsız değişkenli tahmin modeline" ait gerçek değerler ile tahmin değerlerinin karşılaştırıldığı grafik Şekil 4.6'da verilmiştir.

Çizelge 4.16: Regresyon modellerine ait MAPE sonuçları.

Gün	2 Bağımsız Değişkenli Gruplandırılmamış Yıllık MAPE Değerleri			3 Bağımsız Değişkenli Gruplandırılmamış Yıllık MAPE Değerleri			2 Bağımsız Değişkenli Gruplandırılmamış Mevsimsel MAPE Değerleri		
	Haziran	Temmuz	Ağustos	Haziran	Temmuz	Ağustos	Haziran	Temmuz	Ağustos
Pazartesi	16,63	12,08	5,46	18,34	12,75	6,24	13,92	10,75	4,27
Salı	9,5	13,17	6,32	9,34	12,58	5,55	18,63	8,62	2,83
Çarşamba	9,02	11,22	7,7	8,57	13,69	6,91	14,45	7,14	3,13
Perşembe	4,07	3,55	4,79	4,13	3,61	4,9	8,56	3,4	3,67
Cuma	7,97	8,3	5,31	7,99	8,39	5,31	6,67	4	1,68
Cumartesi	3,6	4,06	4,29	3,61	3,97	3,98	5,37	3,49	3,62
Pazar	8,02	7,73	8,3	8,35	7,53	7,45	9,26	2,42	3,47
Ortalama	8,4	8,59	6,02	8,62	8,93	5,76	10,98	5,69	3,24



Şekil 4.6: Gruplandırılmamış iki bağımsız değişkenli mevsimsel regresyon modeli Tahminleri ile gerçek değerlerin karşılaştırılması.

MAPE sonuçlarından ve tahmin grafiğinden de anlaşılacağı gibi tahmin değerleri ile gerçek gözlem değerleri birbirine paralellik göstermektedir.




5. WINTERS ÜSTEL DÜZELTME YÖNTEMİYLE HAFTALIK SİPARİŞ İÇİN HAFTALIK YOLCU SAYISI TAHMİNİ

Trenlerde servis edilen yemeklerin uzun raf ömrüne sahip olması durumunda yemekler haftanın menüsüne göre bir haftayı kapsayacak şekilde bir kerede sipariş verilebilir. Haftalık sipariş verilmesi satın alma ve transfer fiyatlarında düşüğe sebep olacağı için bu sistem maliyetleri olumlu etkiler. Tezin bu aşamasında haftalık sipariş verilmesi durumunda kullanılacak olan tahmin modellerinin geliştirilmesi ve haftalık sipariş sisteminin kurulması üzerine çalışılmıştır.

5.1 Yöntem

Haftalık sipariş sistemi için tahmin yöntemi olarak Winters üstel düzeltme yöntemi ile modelleme yapılmıştır. Verilerin mevsimsel etkiye ve trende sahip olması bu yaklaşımı tahmin yöntemi olarak seçmemizin temel sebebidir. Winters Üstel düzeltme yöntemiyle tahmin modelleri geliştirilirken Ocak 2017 ve Ağustos 2019 arasında trenlerin business plus ve ekonomi plus vagonlarının tren verileri 52 haftalık periyodlara ayrılmıştır. Toplam 139 haftanın yıllar içindeki hareketi gözlemlenmiştir. Yolcu sayılarının sahip olduğu trend ve mevsimsellik Şekil 5.1’de incelenebilir.

İlk tahmin modeli Mayıs 2019’a kadar olan tren verileri kullanılarak yapıldıktan sonra Haziran 2019 ve Temmuz 2019 verileri sırayla eklenerek model güncellenmiş, yeni tahmin modelleri kurulmuş ve her üç ayın (Haziran, Temmuz, Ağustos) tahmin değerleri ve gerçekleşen değerleri karşılaştırılmıştır. Yani Mayıs 2019 sonuna kadar veriler ile geliştirilen model ile Haziran 2019’un , Haziran verileri eklenip oluşturulan model ile Temmuz ayının son olarak Temmuz verileri eklenerek oluşturulan tahmin modeli ile Ağustos ayının tahminleri yapılmıştır. Toplam üç adet tahmin modeli kurulmuştur. Bu tahminlerin güvenilirliği MAPE ile kontrol edilmiştir.



Şekil 5.1: Bir tren için yolcu sayısı dağılımı Ocak 2017- Ağustos 2019.

5.1.1 Winters üstel düzeltme yöntemi tahmin sonuçları

Winters Üstel düzeltme yöntemi ile Mayıs, Haziran ve Temmuz 2019'a kadar olan verileri kapsayan üç adet tahmin modeli geliştirilmiştir. 126 haftalık, 130 haftalık ve 134 haftalık periyodları içeren tahmin modelleri sırasıyla model 1, model 2 ve model 3 olarak adlandırılmıştır. Modellere ait mevsimsel faktörler Çizelge 5.1'deki gibidir.

Çizelge 5.1: Üç modele ait mevsimsel faktörler.

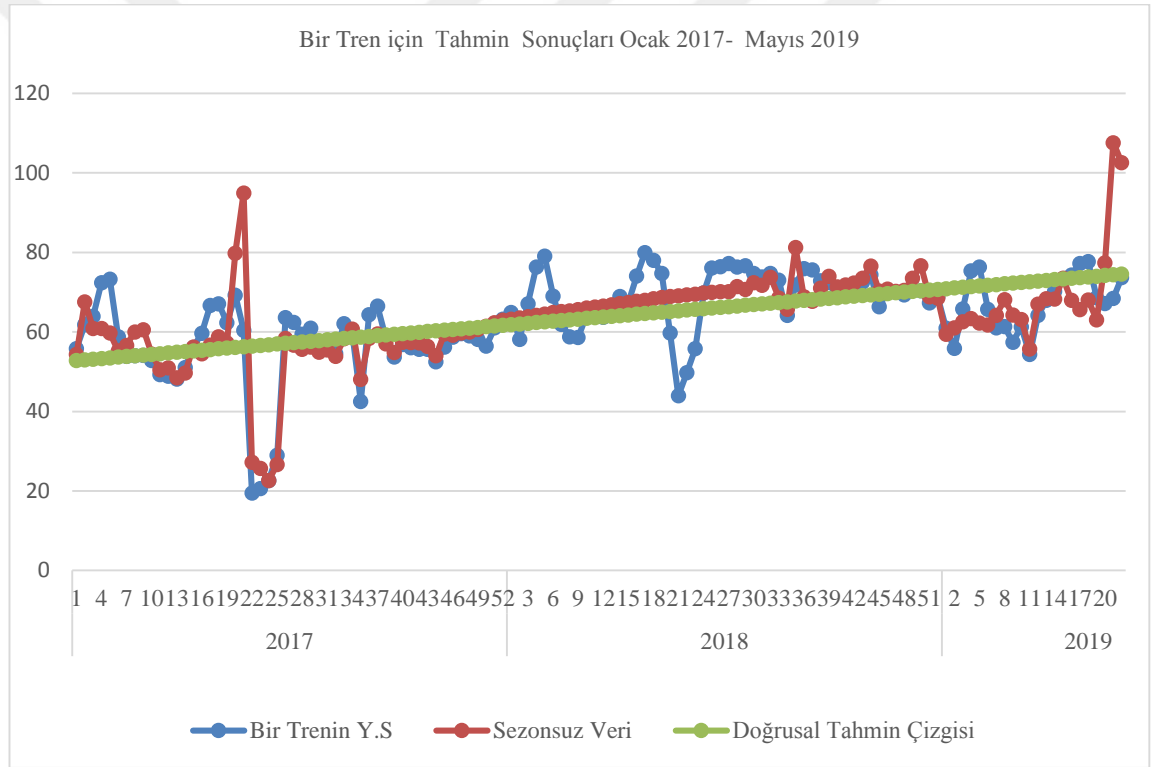
Hafta	Model 1	Model 2	Model 3
1	1,0263	1,0260	0,9458
2	0,9156	0,9153	0,8542
3	1,0510	1,0507	0,9924
4	1,1893	1,1890	1,1295
5	1,2263	1,2259	1,2325
6	1,0639	1,0636	1,0693
7	0,9507	0,9503	0,9555
8	0,9003	0,9000	0,9049
9	0,8928	0,8925	0,8974
10	0,9713	0,9709	0,9762
11	0,9752	0,9749	0,9802
12	0,9585	0,9582	0,9634
13	0,9938	0,9934	0,9988
14	1,0274	1,0270	1,0326
15	0,9993	0,9989	1,0044
16	1,0942	1,0938	1,0997
17	1,1765	1,1761	1,1825
18	1,1415	1,1412	1,1474
19	1,0881	1,0878	1,0937
20	0,8674	0,8671	0,8718
21	0,6363	0,6361	0,6396
22	0,7182	0,7179	0,7218
23	0,8023	0,8020	0,8064
24	1,0003	1,0000	1,0054
25	1,0871	1,0868	1,0927
26	1,0898	1,0894	1,0953
27	1,1011	1,1007	1,1067
28	1,0687	1,0683	1,0741
29	1,0845	1,0842	1,0901
30	1,0333	1,0330	1,0385
31	1,0298	1,0294	1,0350
32	1,0131	1,0127	1,0182
33	1,0649	1,0646	1,0703
34	0,9759	0,9756	0,9808
35	0,8843	0,8840	0,8888
36	1,1023	1,1019	1,1079
37	1,1171	1,1167	1,1228
38	1,0261	1,0257	1,0313
39	0,9796	0,9793	0,9846
40	0,9907	0,9904	0,9958
41	0,9783	0,9780	0,9833
42	0,9720	0,9717	0,9770
43	0,9861	0,9858	0,9911
44	0,9720	0,9717	0,9770
45	0,9441	0,9438	0,9489
46	0,9910	0,9907	0,9961
47	0,9973	0,9970	1,0024
48	0,9841	0,9838	0,9891
49	0,9589	0,9764	0,9817
50	0,9185	0,9534	0,9586
51	0,9783	0,9613	0,9665
52	1,0046	0,9850	0,9903

Üç modele ait kesim noktası ve eğim değerleri Çizelge 5.2’de verilmiştir.

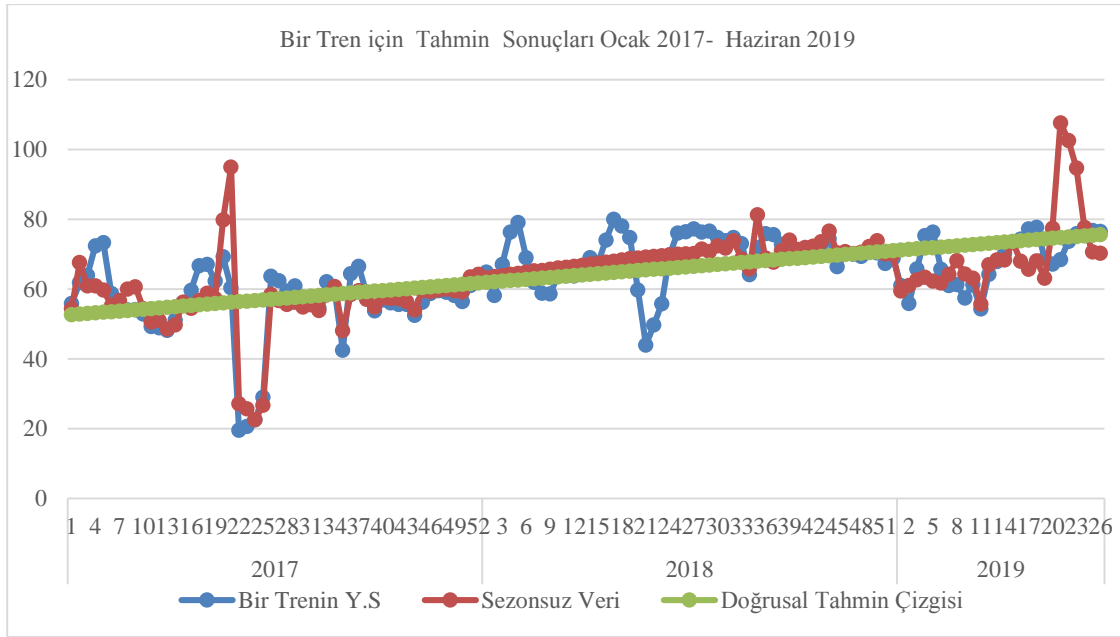
Çizelge 5.2: Üç modele ait kesim noktası ve eğim değerleri.

	Model 1 (Periyod 126)	Model 2 (Periyod 130)	Model 3 (Periyod 134)
Eğim (G0)	0,1739	0,1781	0,1663
Kesme Noktası	52,6509	52,4793	53,1592
Tahmin (S0)	74,5672	75,6327	75,4440


Yukarıdaki veriler tahmin denkleminde yerine yerleştirilerek Şekil 5.2, Şekil 5.3 ve Şekil 5.4’te üç model için ayrı ayrı gösterilmiştir.



Şekil 5.2: Ocak 2017- Mayıs 2019 Model 1(126 periyod) tahmin analizi.



Şekil 5.3: Ocak 2017- Haziran 2019 Model 2 (130 periyod) tahmin analizi.



Şekil 5.4: Ocak 2017- Temmuz 2019 Model 3 (134 periyod) tahmin analizi.


5.1.2 Winters üstel düzeltme yöntemi modelleri için tahmin MAPE analizi

Güncellenen modeller ile Haziran, Temmuz ve Ağustos'a ait haftalar için tahminler yapılmış ve gerçek gözlem değerleri ile karşılaştırılmıştır. Çizelge 5.3'te üç tahmin modeli için de karşılaştırmalar gösterilmiştir. Çizelgede hangi haftalar için tahmin yapıldığı ve o haftanın kaçınıcı gözlem olduğu belirtilmiştir. Tahmin modellerine ait MAPE değerleri Çizelge 5.4'te verilmiştir.

Çizelge 5.3: Üç tahmin modeli için de tahmin ve gerçekleşen değerlerin karşılaştırılması.

		Haziran		Temmuz		Ağustos	
Gözlem	Hafta	Gerçekleşen	Tahmin	Gerçekleşen	Tahmin	Gerçekleşen	Tahmin
127	23	76	60				
128	24	78	75				
129	25	77	81				
130	26	77	82				
131	27			76	83		
132	28			76	81		
133	29			75	83		
134	30			75	79		
135	31					76	78
136	32					74	77
137	33					74	81
138	34					76	75
139	35					75	68

Haziran, Temmuz ve Ağustos'a ait güncellenen modellerden elde edilen tahmin değerleri ve gerçek değerlerin karşılaştırılması Şekil 5.5'te gösterilmiştir.



Şekil 5.5: Tahmin sonuçları ile gerçekleşen değerlerin karşılaştırılması.

Çizelge 5.4: Modellere ait MAPE sonuçları.

	Haziran	Temmuz	Ağustos	Ort.
MAPE	9,4775	8,1636	5,9391	7,8601

Winters yöntemiyle yapılan talep tahmini yaklaşımının her üç ay içinde doğrulukları kabul edilebilir sınırlar içerisinde olduğu gözlemlenmiştir.

6. SONUÇLAR

Bu çalışma Türkiye’de yüksek hızlı trenlerin ekonomi ve business plus vagonlarının yolcu sayısı tahmini ile yapılan ilk çalışma olma özelliğini taşımaktadır. Çalışmanın amacı her ne kadar bu vagonlardaki yolcu sayısı tahminine dayalı günlük sipariş sistemi kurmak olsa da gelecek dönemde trenlerin toplam yolcu sayısı tahmin çalışmaları ile günlük sefer sayısının dönemsel olarak hesaplanması, tren içinde yolcuların ihtiyaç duyduğu diğer materyallerin satın alma miktarının ve yükleme miktarının saptanması, yolcu sayısına bağlı olarak trenlerde görev alması gereken hizmet personelinin belirlenmesi gibi konulara ışık tutması diğer bir amaçtır.

Regresyon denklemleri incelendikten sonra seçilen üç regresyon modelleme yaklaşımı determinasyon katsayılarının birbirine çok yakın olduğu tespit edilmiştir. MAPE değerlerine göre sipariş sistemi oluşturmak için iki bağımsız değişkenli gruplandırılmamış mevsimsel regresyon modelinin en uygun model olduğu gözlemlenmiştir. Seçilen diğer yüksek R-kare değerine sahip modeller ile ana modelimizin tahminin de elde edilen MAPE değerleri 3,24 ile 10,98 arasında değer almış olup kabul edilebilir seviyededir.

Aylık olarak tahmin modeli oluşturma durumunda kullanılan veriler aylık olarak parçalandığı zaman kullanışlı bir veri grubu sayı itibariyle oluşmamış, bu da regresyon denklemlerinin anlamlılık ve güvenilirlik testlerine olumsuz olarak yansımıştır. İlerleyen dönemlerde artan veri sayısı ile aylık olarak tekrar tahmin modelleri denenebilir.

Tezin ikinci çalışması olan haftalık sipariş sistemi kurulması durumunda tahmin yöntemi olarak tercih edilen yöntem Winters üstel düzeltme yöntemi olmuştur. Verilerimizin sahip olduğu trend ve mevsimsellik özelliğine en uygun tahmin yöntemi olan Winters metoduyla elde edilen tahmin sonuçları gerçek değerlerle paralel davranış sergilemiştir. MAPE değerlerini kontrol ettiğimizde, Winters yönteminin simüle edilen üç ay için de oldukça doğru ve güvenilir tahminler yaptığını söyleyebiliriz. Bu yöntemin haftalık yolcu sayısı tahminleri için olumlu sonuçlar vermesi raf ömrü uzun olan gıdaların ve tüketimi yolcu sayısına bağlı olan diğer materyallerin talebi için de kullanılabilir olduğunu göstermiştir.

Belirlenen tahmin yaklaşımı ve modeller firmaya günlük yemek siparişi için doğru bir şekilde tahmin edebilme imkânı sağlayacak, kişiye bağlı ve hataya açık bir sistem

yerine istatistiksel modele dayalı bir sisteme geçişin alt yapısını oluşturacaktır. Ayrıca çalışmamız Türkiye’de tren yolcu sayısı tahmin modellemesine yönelik bu kapsamdaki ilk çalışma olması nedeniyle literatüre değerli bir katkı olmuştur.



KAYNAKLAR

- Akgül, I.** (2003). Zaman serileri analizi ve ARIMA modelleri. *İstanbul Dergisi*, 3(10).
- Akyıldız, M.** (2004). Lojistik dış kaynak kullanımının gelişimi ve Türkiye'deki kullanım biçimleri. *Dokuz Eylül Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 6, 3.
- Albayrak, A.S.** (2006). *Uygulamalı Çok Değişkenli İstatistik Teknikleri* (1. b.). Ankara: Asil Yayın Dağıtım.
- Armutlu İ.** (2008). *İşletmelerde Uygulamalı İstatistik* (2 b.). İstanbul: Alfa Yayınları.
- Blainey, S., & Mulley, C.** (2013). Using geographically weighted regression to forecast rail demand in the Sydney region. *Transport Research Forum*, 5(11), 2-3.
- Büyüköztürk, Ş., Çokluk, Ö., & Köklü, N.** (2019). *Sosyal Bilimler İçin İstatistik*. Ankara: Salmat Basım Yayıncılık.
- Chen, C., & Jui-Chi, L.** (2000). Forecasting method applications to recreation and tourism demand. *Doktora Tezi*. USA: North Carolina State University.
- Ching-Chin, C., Leng, A., Ling-Ling, W., & Ling-Chieh, K.** (2010). Designing a decision support system for new product sales forecasting. *Expert System with Applications*, 37.
- Çağlı, G.** (1997). Mevsimsellik olmayan Box-Jenkins modellerinde iki aşamalı yapay sinir ağlarının kullanılması ve bir uygulama. *Doktora Tezi*. İstanbul: İstanbul Üniversitesi.
- Efendigil, T., & Eminler, Ö.** (2017). The importance of demand estimation in the aviation sector: a model to estimate airline passenger demand. *Tarım ve Gıda Değer Zincirlerinde Yöneylem Araştırmaları ve Endüstri Mühendisliği Özel Sayısı*, 12, 14.
- Ergün, S., & Şahin, S.** (2017). İşletme talep tahini üzerine literatür araştırması. *Ulakbilge*, 5, 469-487.
- Goto, H.**(2002). Coffee, Tea, or ...?: A Markov Decision Process Model for Airline.
- Farber, J., & Todd, E.** (2000). Sade handling of foods. *CRC Press*, 7, 16.
- Gu, S., & Lu, X.** (2015). Analysis of China railway passenger volume's influence factors based on principal component regression. *International Conference on Logistics Informatics and Service Sciences* (s. 41-42). Şangay: LISS.
- Howell, D.** (1987). *Statistical methods for psyclogy*. Boston: Duxbury Yayıncılık.
- Goto, JH., Lewis, M., & Puterman, M.** (2019, Aralık 25). *Coffee, tea, or...? A Markov decision process model for airline meal provisioning*. ResearchGate: <https://www.researchgate.net/publication> adresinden alındı

- Kalaycı, Ş.** (2010). *SPSS uygulamalı çok değişkenli istatistik teknikleri*. Ankara: Asil Yayın Dağıtım.
- Montgomery, D., & Runger, G.** (2002). *Applied Statistics and Probability for Engineers*. Newyork: Jhon Wiley&Sons.
- Önder, E., & Hasgül, Ö.** (2009). Yabancı ziyaretçi sayısının tahmininde Box-Jenkins modeli, Winters yöntemi, Yapay sinir ağlarıyla zaman seri analizi. *Istanbul University Business Economy Institute Journal of Management*, 62, 62-83.
- Önen, V., Karabulut, N.** (2018). Havayolu uçak içi ikram satış tahmin modeli bir havayolu uygulaması, *Avrasya Sosyal ve Ekonomi Araştırmalar*, 100-121
- Parmita, E., & Arora, E.** (2015). Sales forecasting of milk and milk products by quantitative techniques-A case study. *Int. J. Multi disciplinary Approach and Studies*, 305-310.
- Pektaş, İ.** (2019). TCDD Faaliyet Raporu. *Arus Raylı Sistemler Sektör Analiz Aylık Dergisi*, 39.
- Ravid, R.** (1994). *Practical Statistics for Educators*. Newyork: Press of America.
- Sezgin, C., & Özkaya, F.** (2013). Toplu beslenme sistemlerine genel bir bakış. *Academic Food J Journal*, 124-128.
- Sosyal, M., & Ömürkünülen, M.** (2010). Türk turizm sektöründe talep tahmini üzerine bir uygulama. *Anatolia Turizm Araştırmaları Dergisi*, 128-136.
- Sun, Ş., Lu, H., Tsui, K., & Wang, S.** (2019). Nonlinear vector auto-regression neural network for forecasting air passenger flow. *Journal of Air Transport Management*, 7-11.
- Şahinler, S.** (2000). En küçük kareler yöntemi ile doğrusal regresyon modeli oluşturmanın temel prensipleri. *Mustafa Kemal Üniversitesi Ziraat Fakültesi Dergisi*, 57-73.
- Tortum, A., Gözcü, O., & Çodur, M.** (2014). Air transportation demand estimation in Turkey by ARIMA models araştırma makalesi. *Iğdır Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 39-54.
- Tsa, H., Lee, K., & Wei, C.** (2009). *Neural network based temporal feature models for short-term railway passenger demand forecasting*. Newyork: Elsevier.
- Tunç, Z.** (2018). En küçük kareler ve temel bileşenler regresyon analizlerinin karşılaştırılması . *Yüksek Lisans Tezi*. Malatya: İnönü Üniversitesi.
- Wei, C.** (2019). Research on forecast method of railway passenger flow demand in presale period. *Materials Science and Engineering*. Şangay.
- Wu, X., Nie, L., & Xu, M.** (2016). *Designing an integrated distribution system for catering services for high speed railways: A three-echelon location routing model with tight time windows and time deadlines*, *Transportation Research Part E*. Newyork: Elsevier.

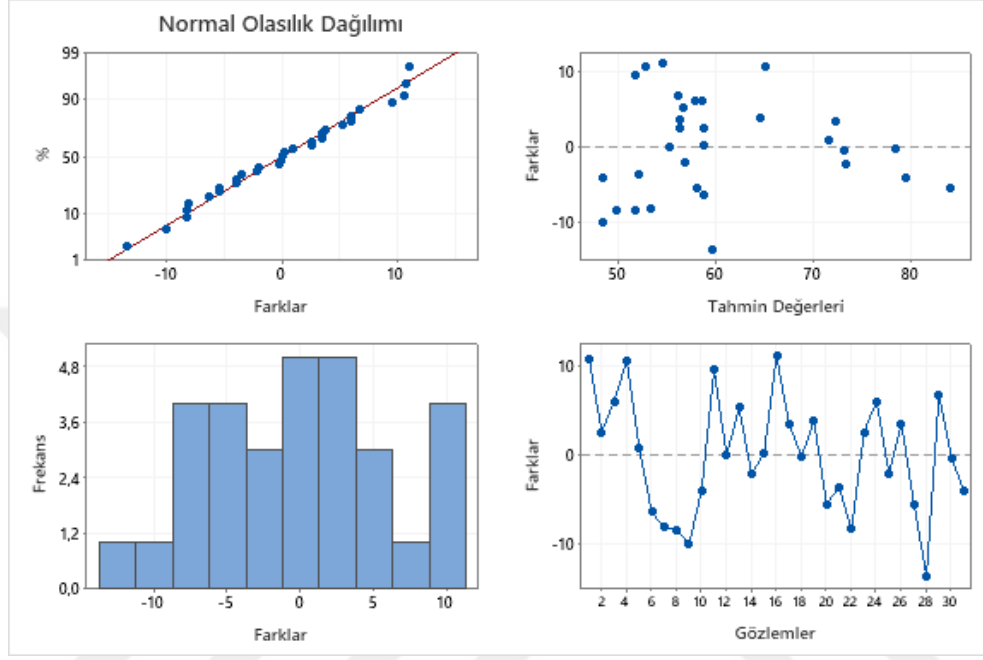
- Wu, X., Nie, L., Xu, M., & Zhao, L.** (2018). Distribution planning problem for a high-speed rail catering service considering time-varying demands and pedestrian congestion: A lot sizing-based model decomposition algorithm. *Transportation Research* , 61-89.
- Xu, C., Xiaoyan, S., Oi, X., & Hua, Z.** (2010). Forecasting demand of commodities after natural disasters. *Expert System With Applications*, 37, 4313-4317.
- Yıldırım, A.** (2019). Talep tahmin yöntemlerinin karşılaştırılmalı analizi:Gıda sektöründe bir uygulama. *Yüksek Lisans Tezi*. İstanbul: İstanbul Kültür Üniversitesi.
- Gültekin, F.** (2019).Endüstri mühendisliği ders notları.stambul: İstanbul Kültür Üniversitesi. <http://www.balikesir.edu.tr> alındığı tarih 12.02.2019
- Regresyon Analizi.* <http://www.istatistikanalizi.com> alındığı tarih: 03.03.2020
- TCDD Taşımacılık A.Ş. [http:// www.tcddtasimacilik.gov.tr](http://www.tcddtasimacilik.gov.tr) alındığı tarih: 20.03.2020
- Temel Regresyon Analizi.* <http://www.mku.edu.tr> alındığı tarih:04.03.2020
- Yemekli yataklı vagonların tarihi.* <http://kentvedemiryolu.com> alındığı tarih: 16.11.2019



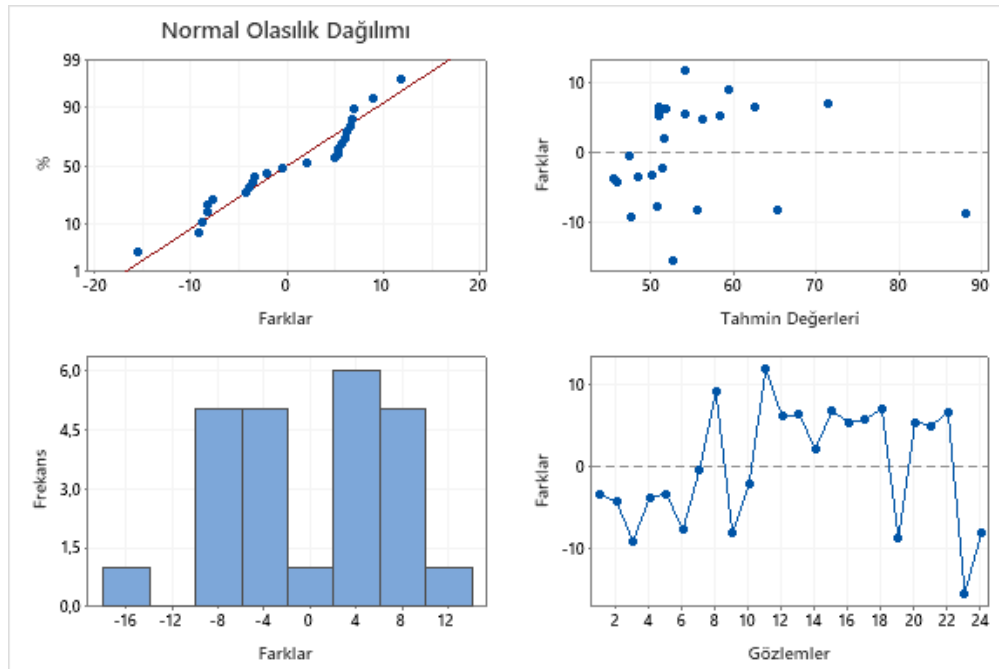
EKLER

EK.1.: Gruplandırılmamış Mevsimsel İki Bağımsız Değişkenli Regresyon Modeli Saçılım Grafikleri

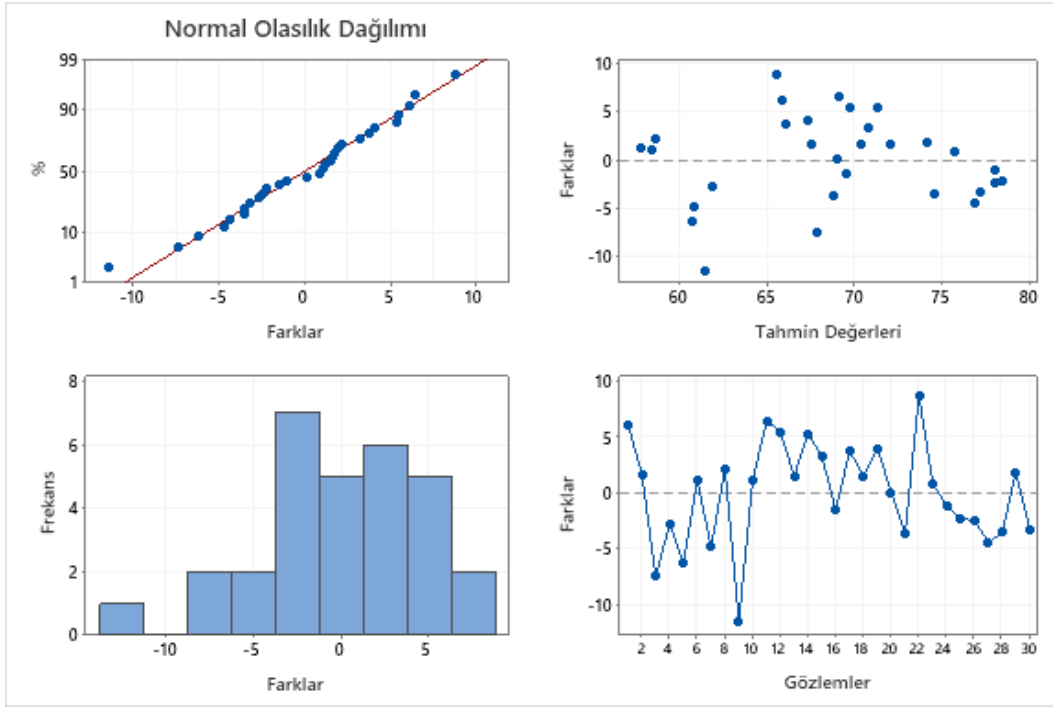
Kış Mevsimi Pazartesi



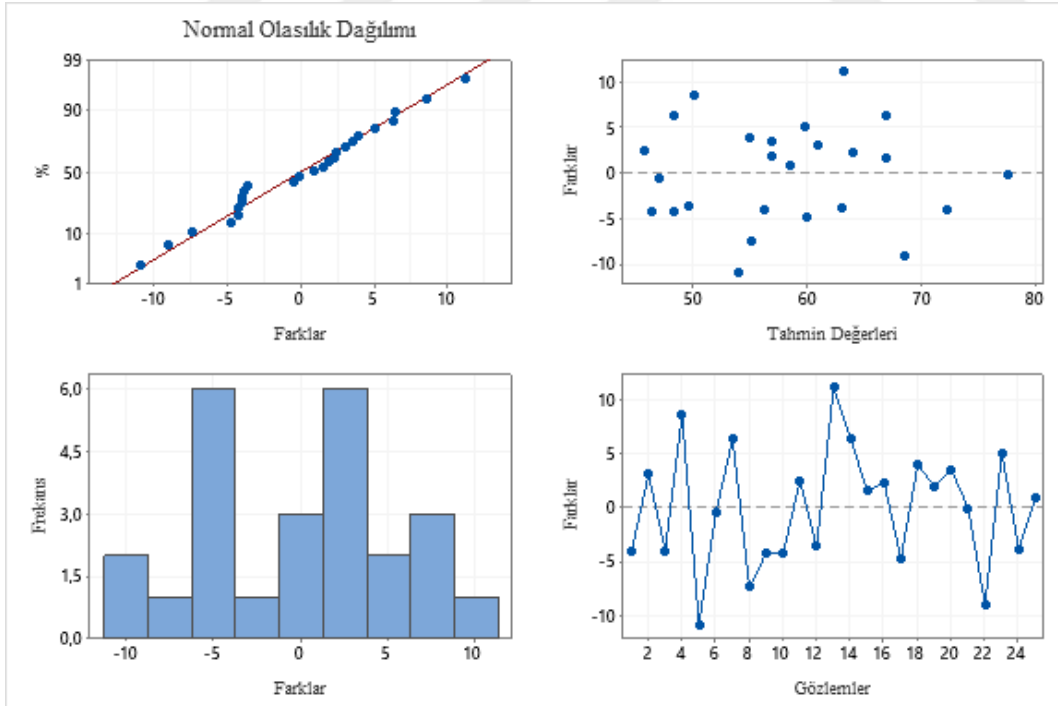
İlkbahar Mevsimi Pazartesi



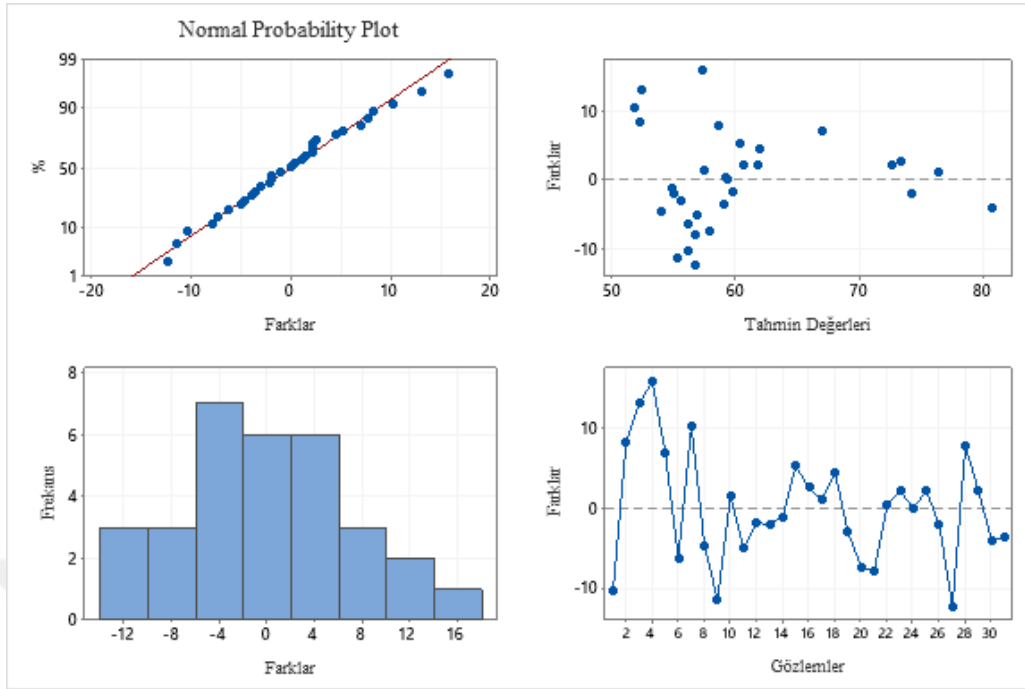
Yaz Mevsimi Pazartesi



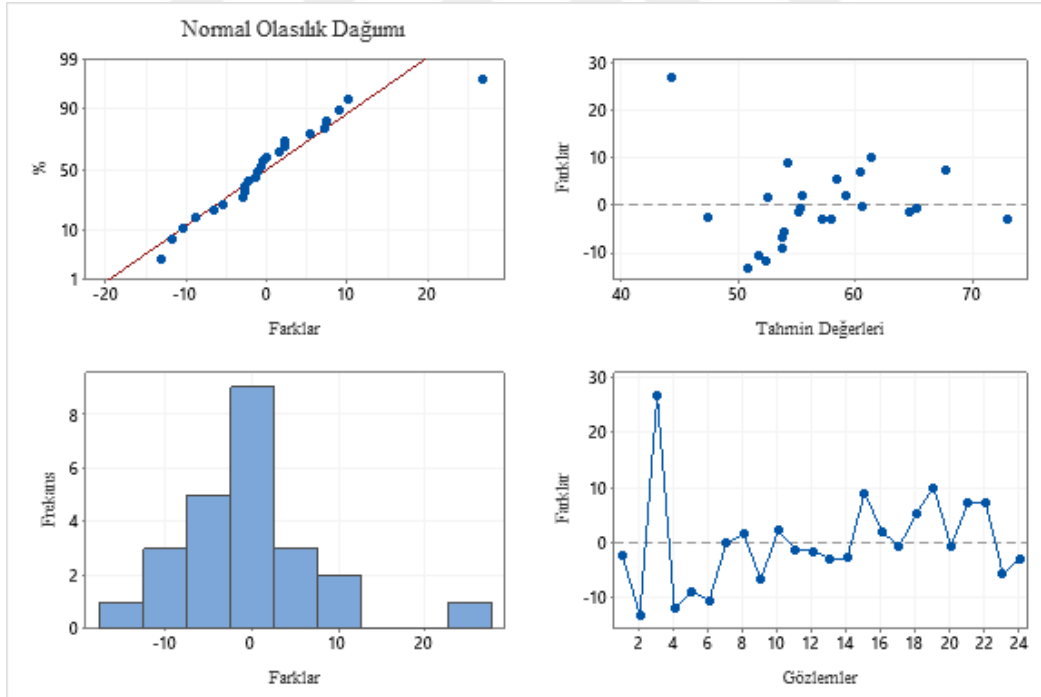
Sonbahar Mevsimi Pazartesi



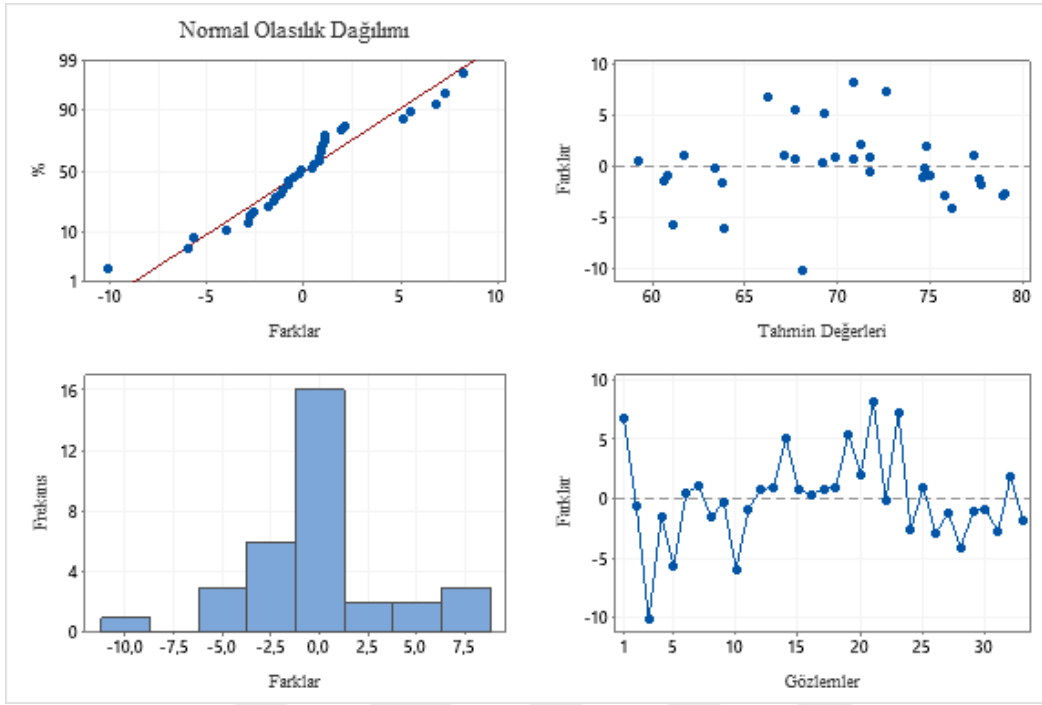
Kış Mevsimi Salı



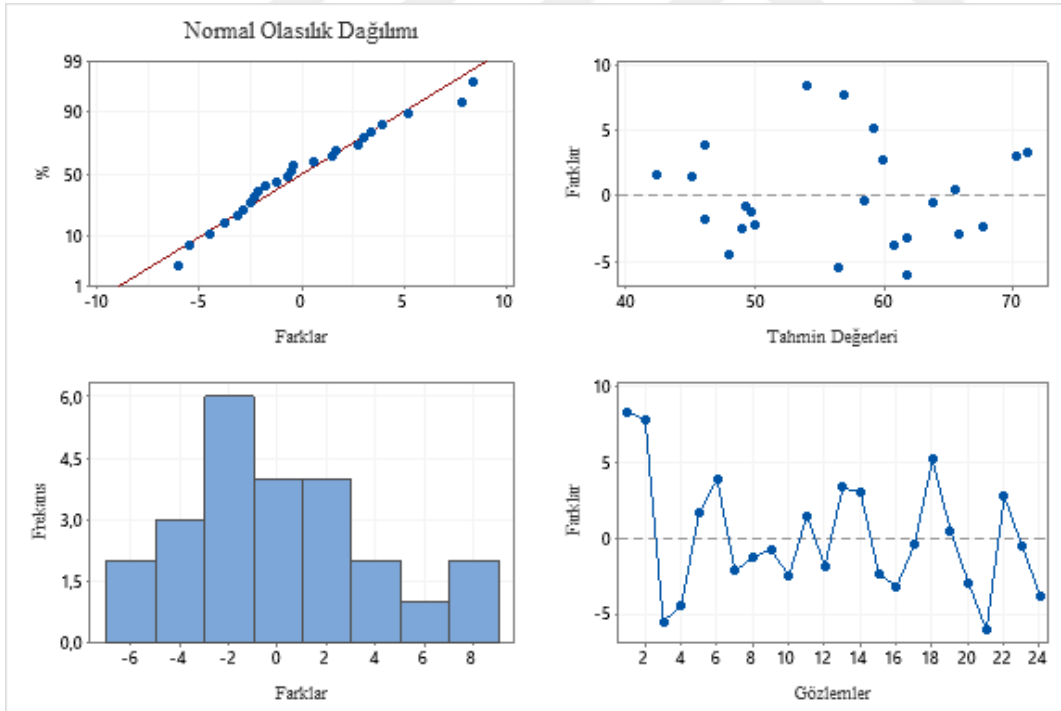
İlkbahar Mevsimi Salı



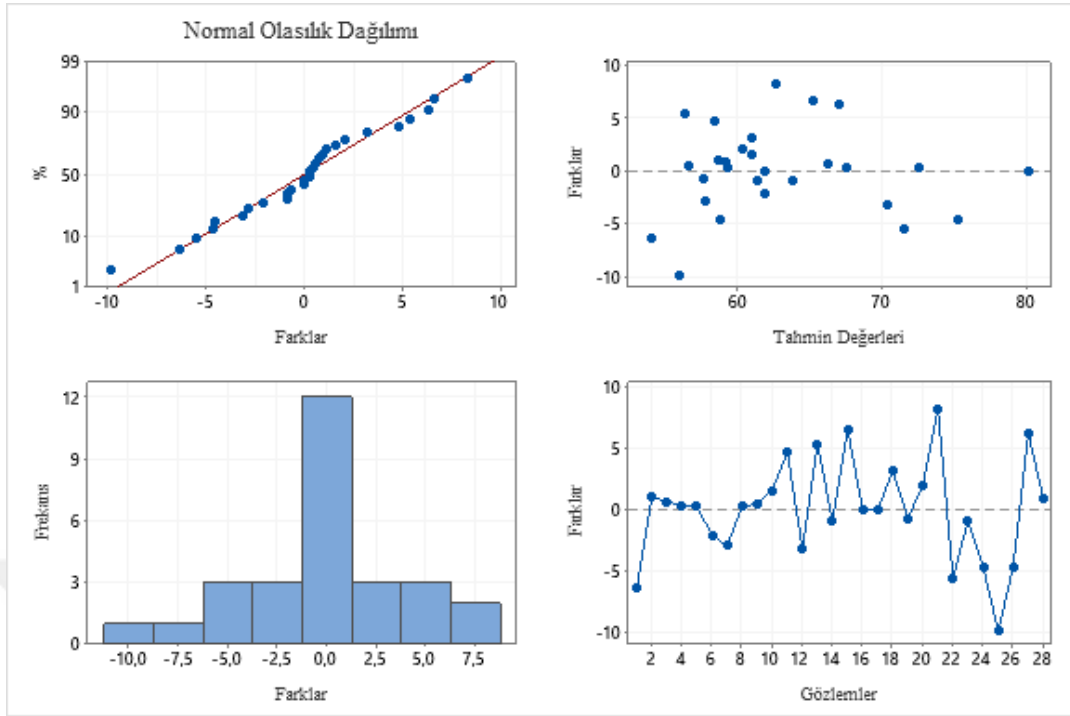
Yaz Mevsimi Salı



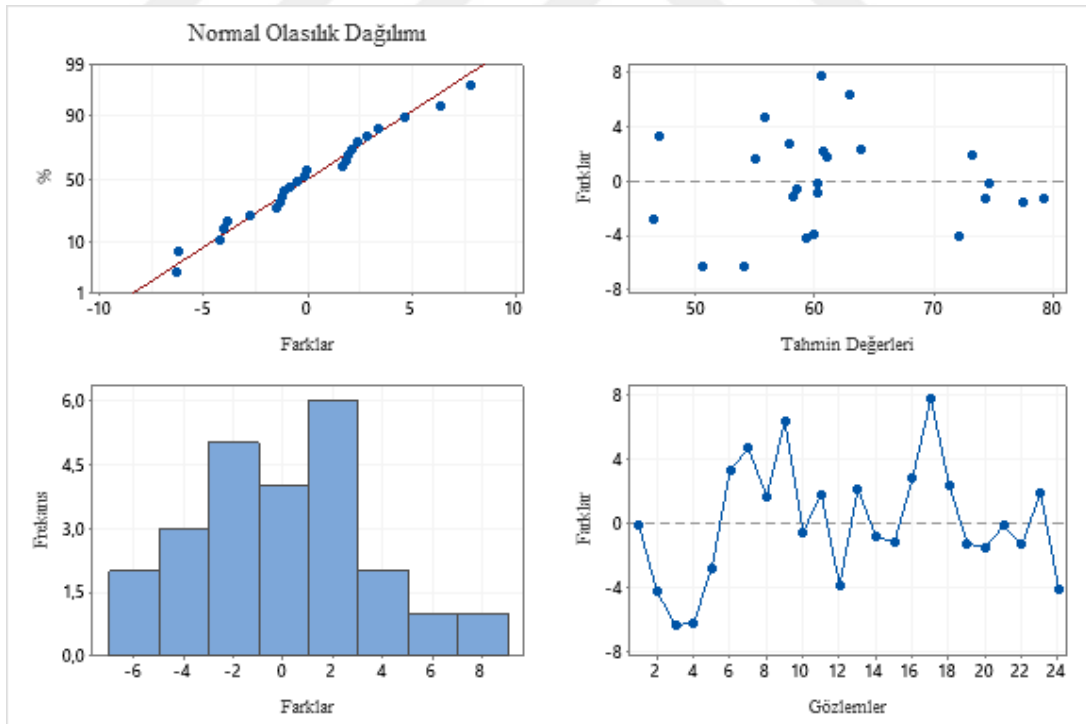
Yaz Mevsimi Sonbahar



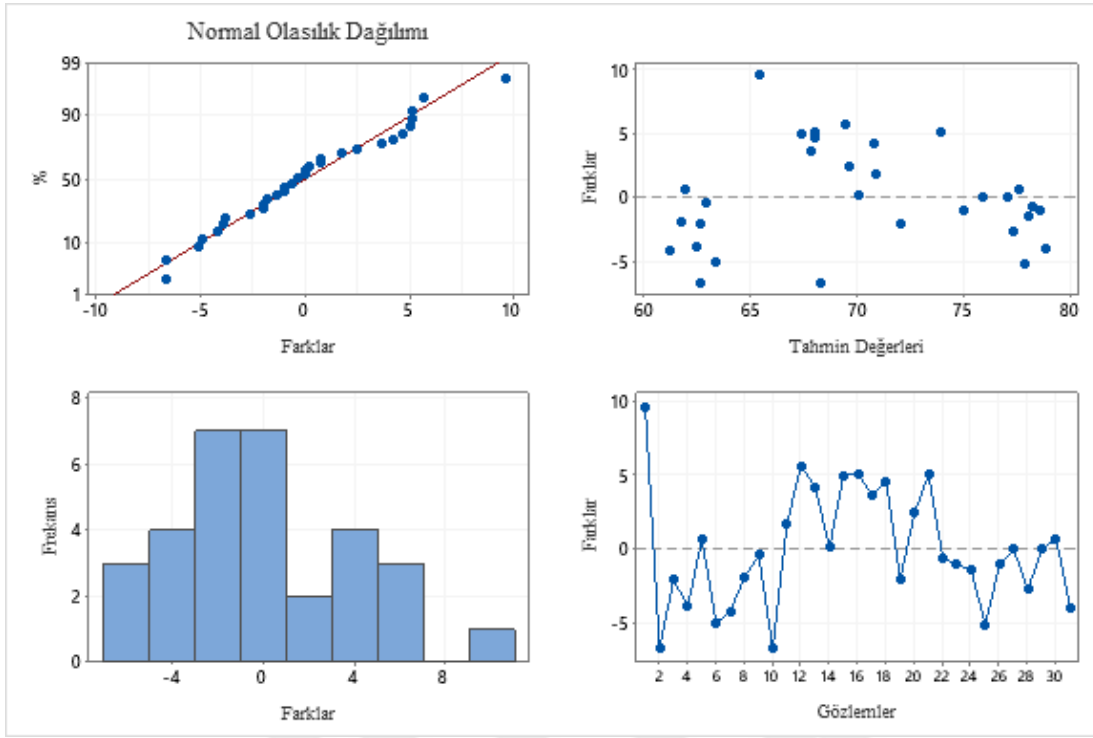
Kış Mevsimi Çarşamba



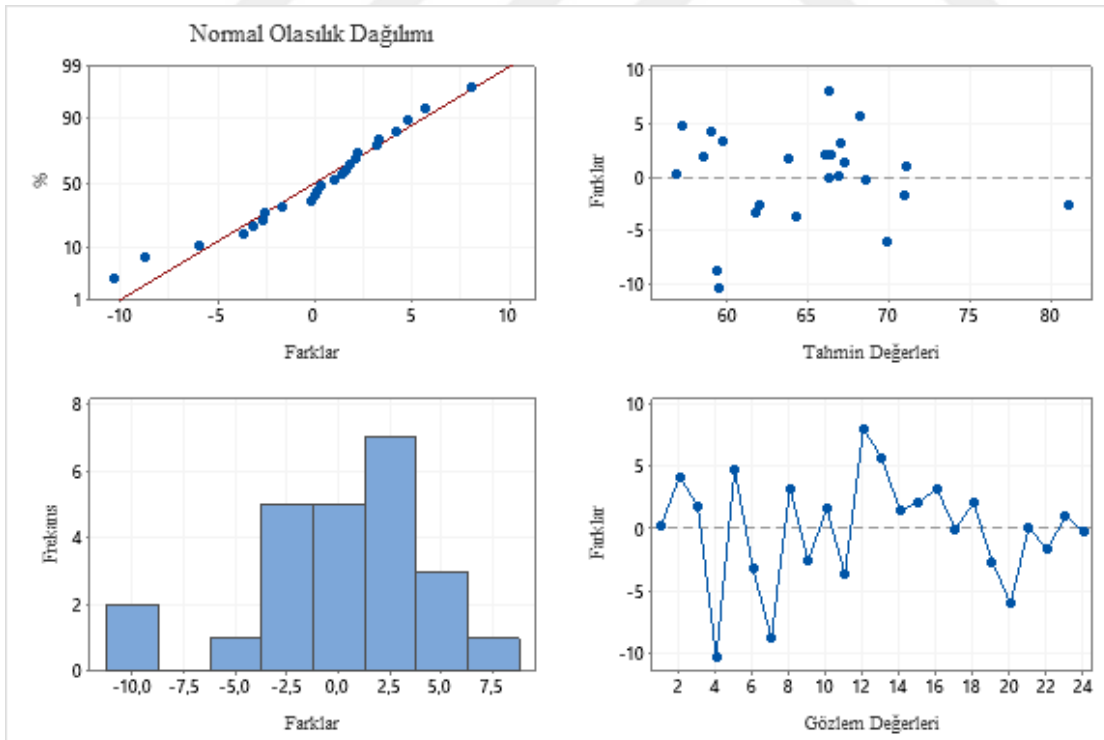
İlkbahar Mevsimi Çarşamba



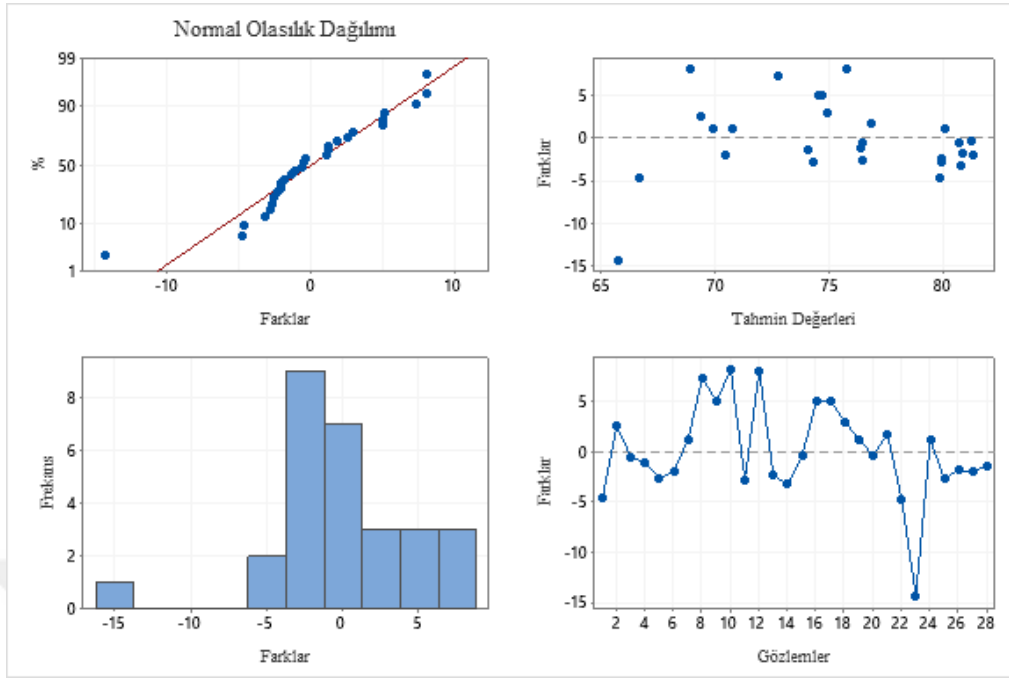
Yaz Mevsimi Çarşamba



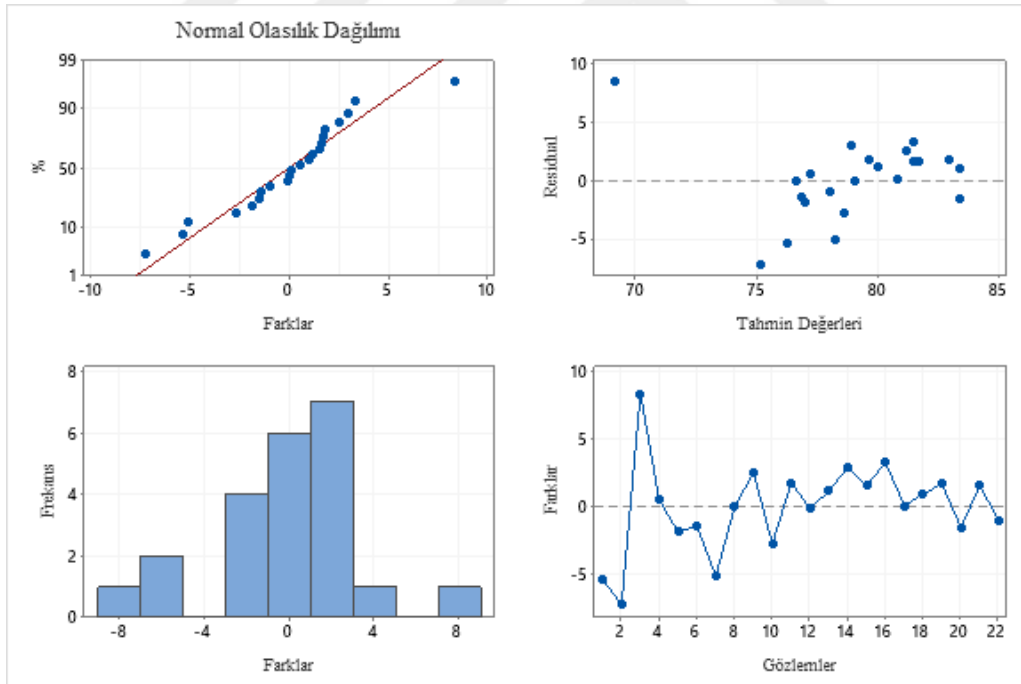
Sonbahar Mevsimi Çarşamba



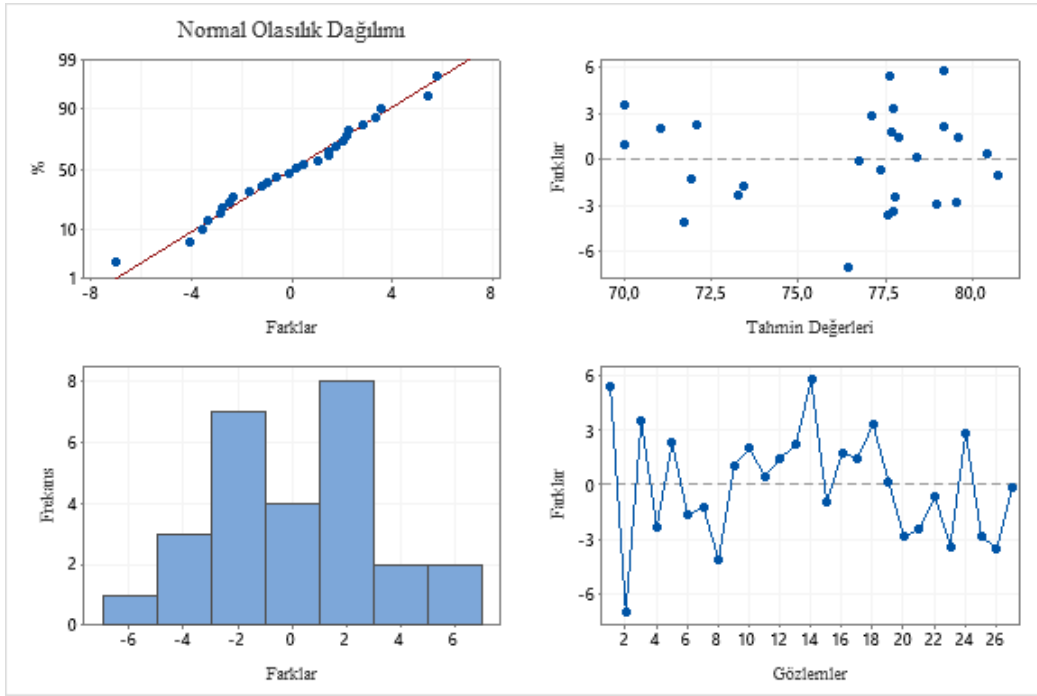
Kış Mevsimi Perşembe



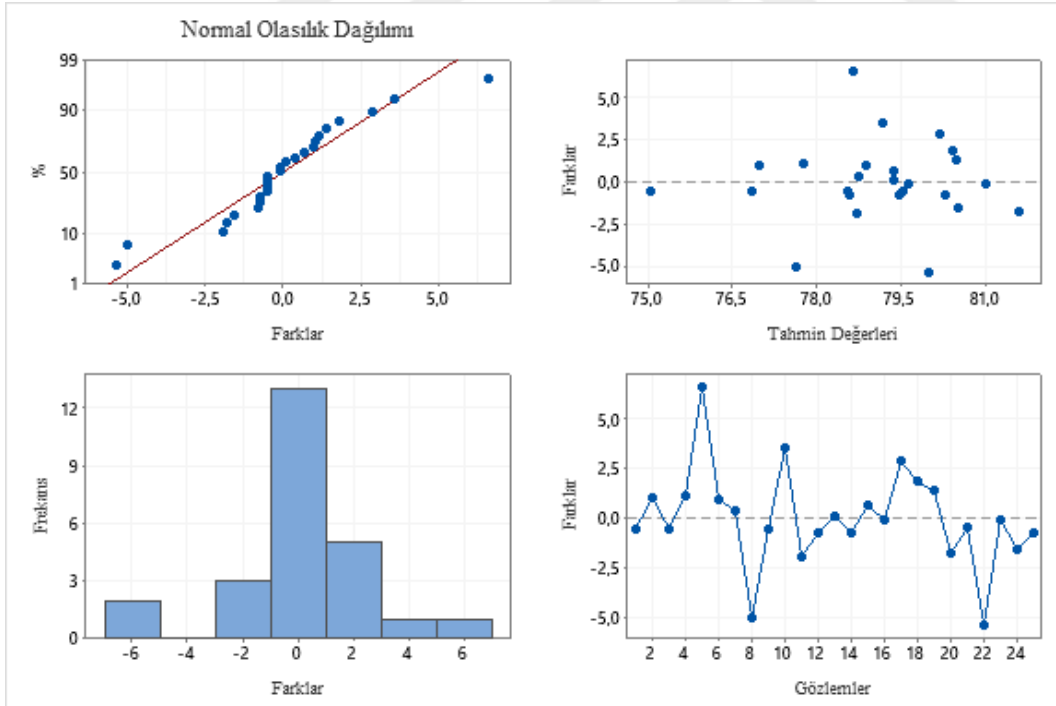
İlkbahar Mevsimi Perşembe



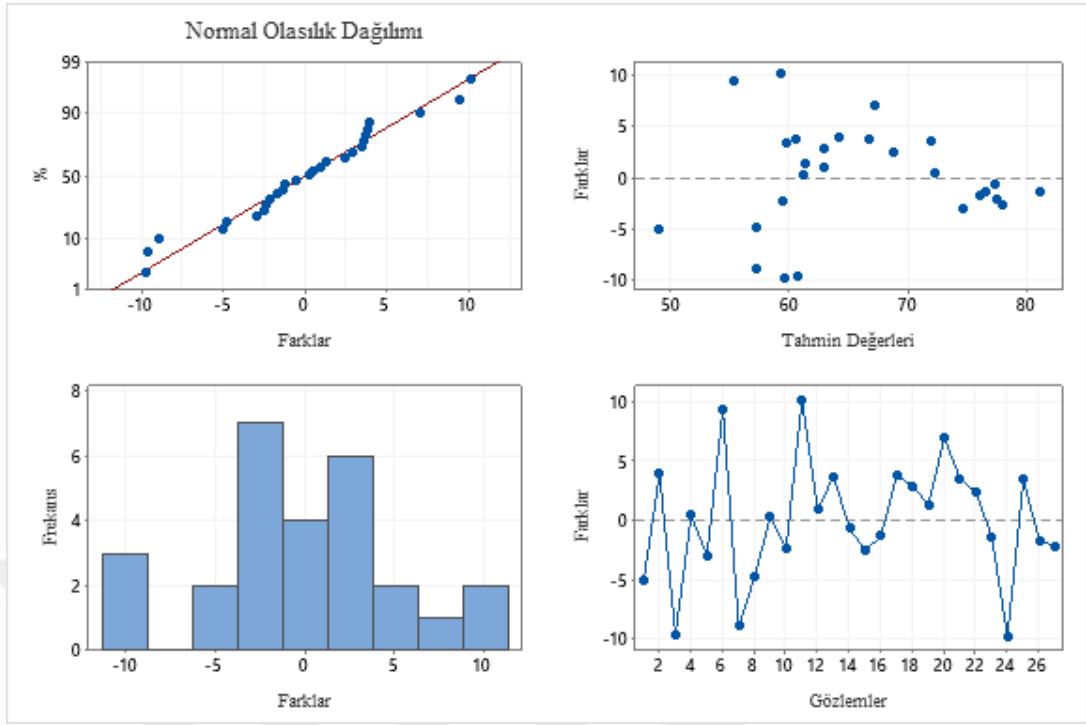
Yaz Mevsimi Perşembe



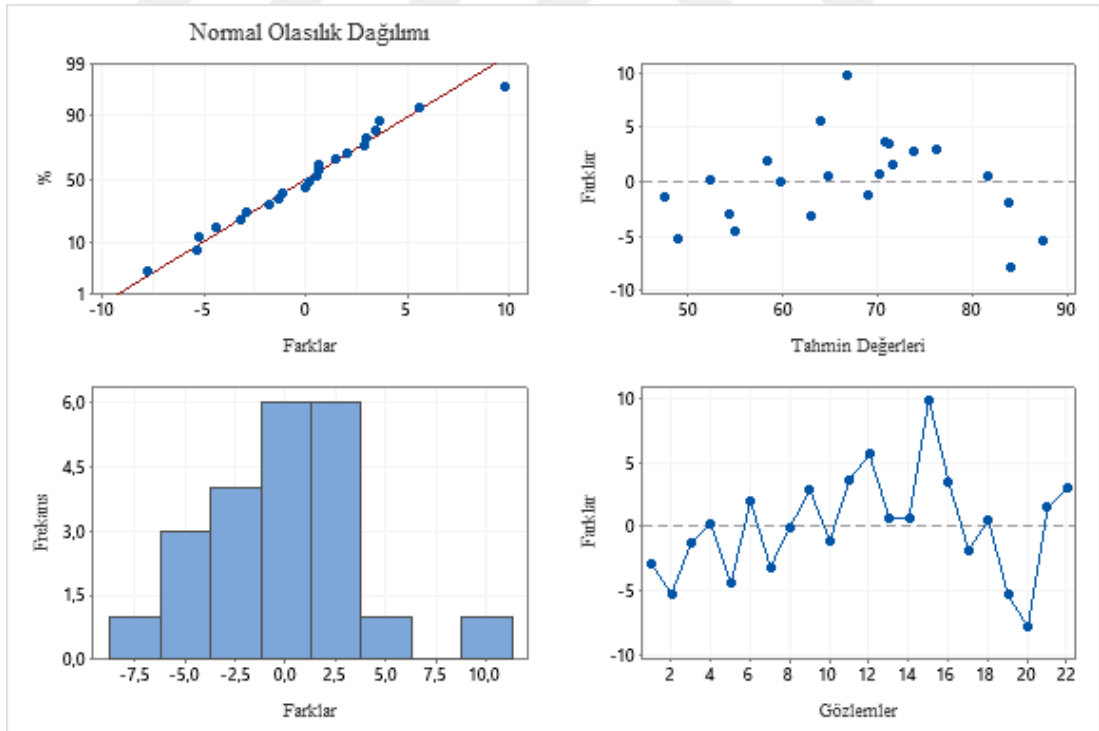
Sonbahar Mevsimi Perşembe



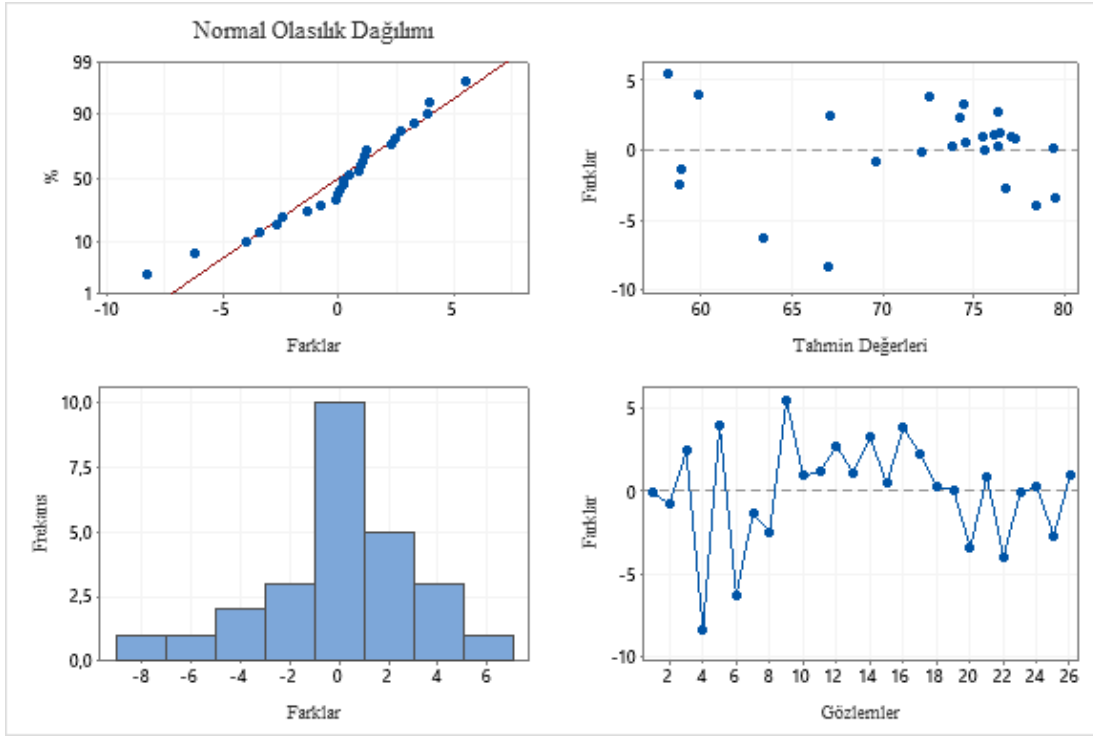
Kış Mevsimi Cuma



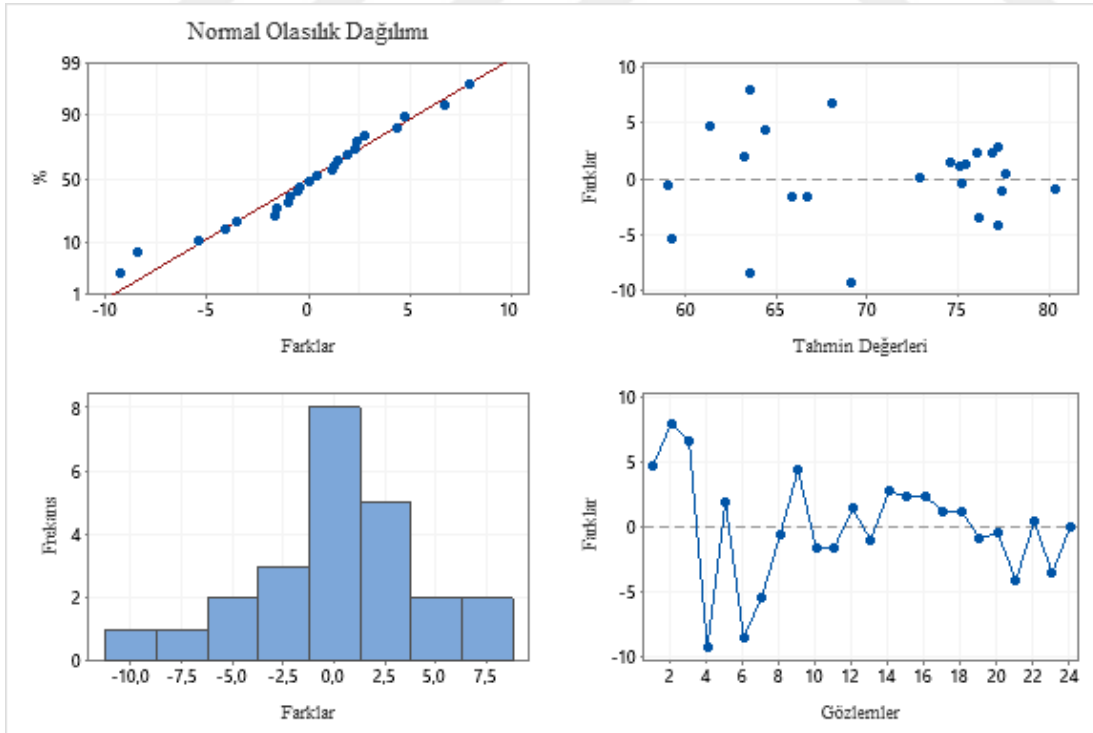
İlkbahar Mevsimi Cuma



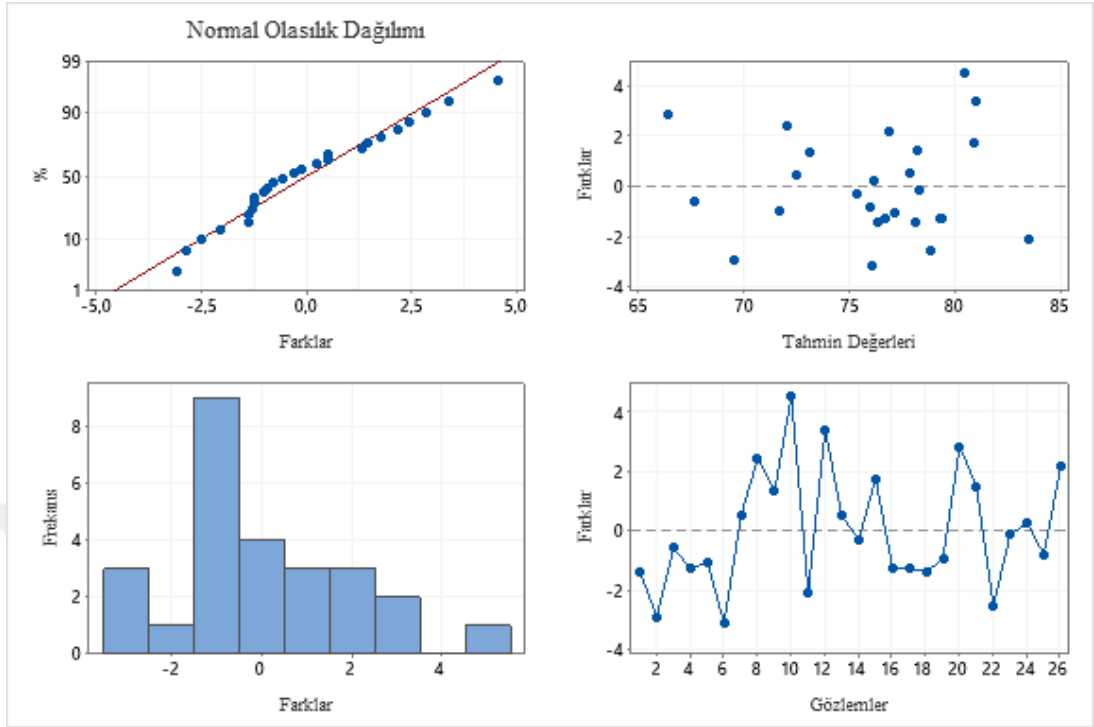
Yaz Mevsimi Cuma



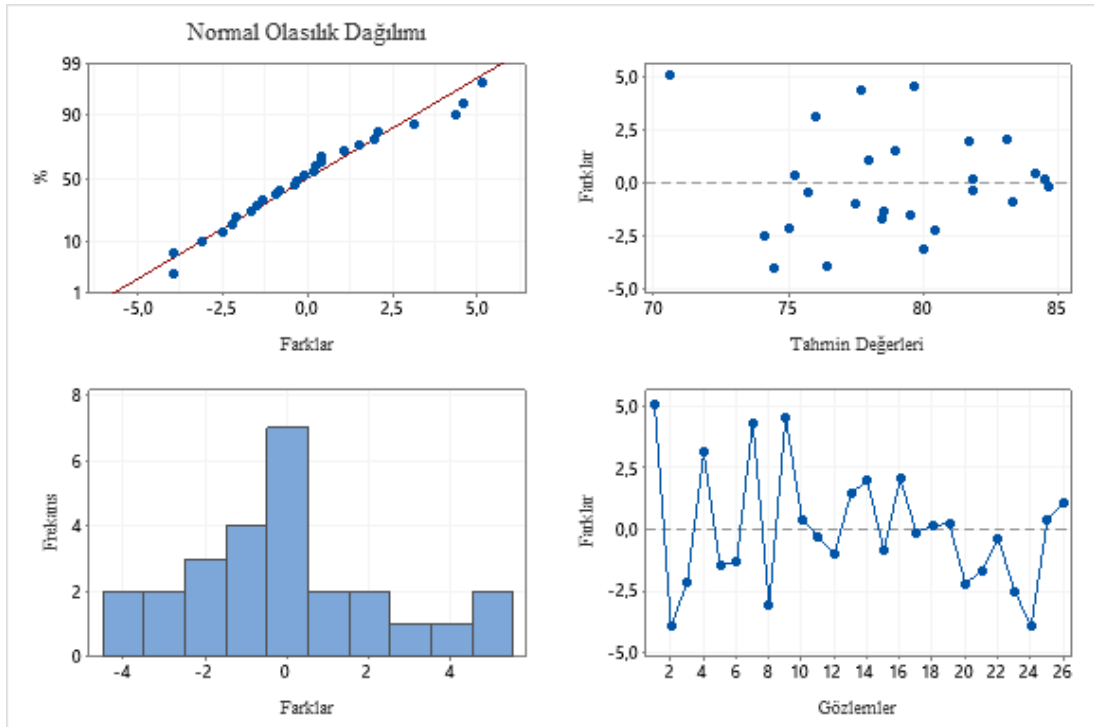
Sonbahar Mevsimi Cuma



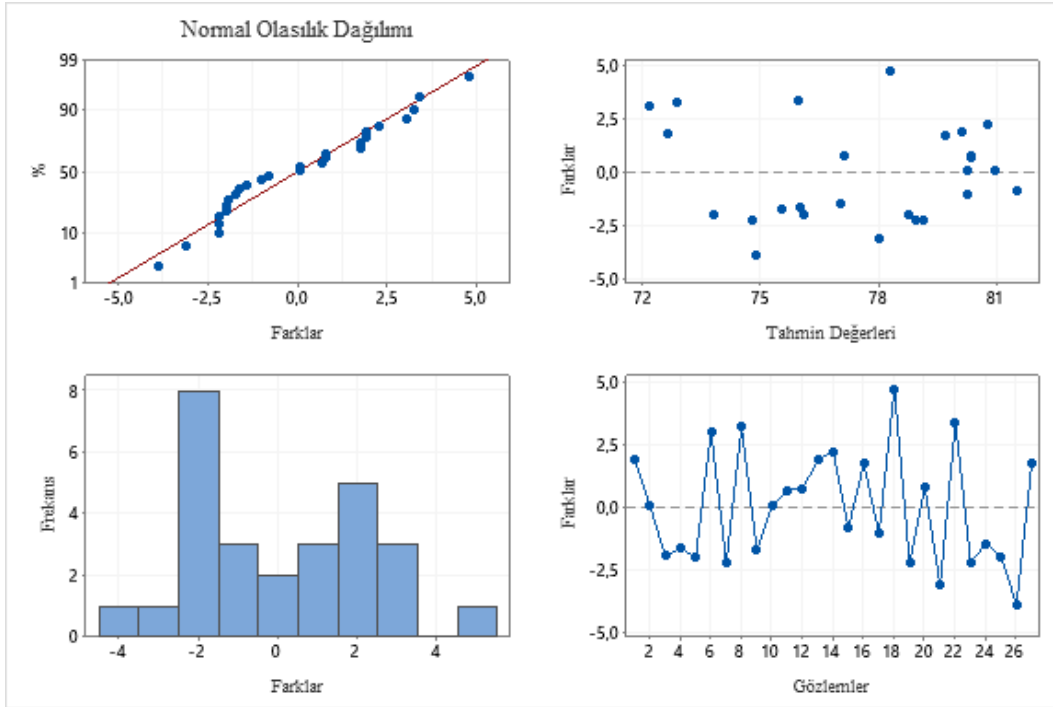
Kış Mevsimi Cumartesi



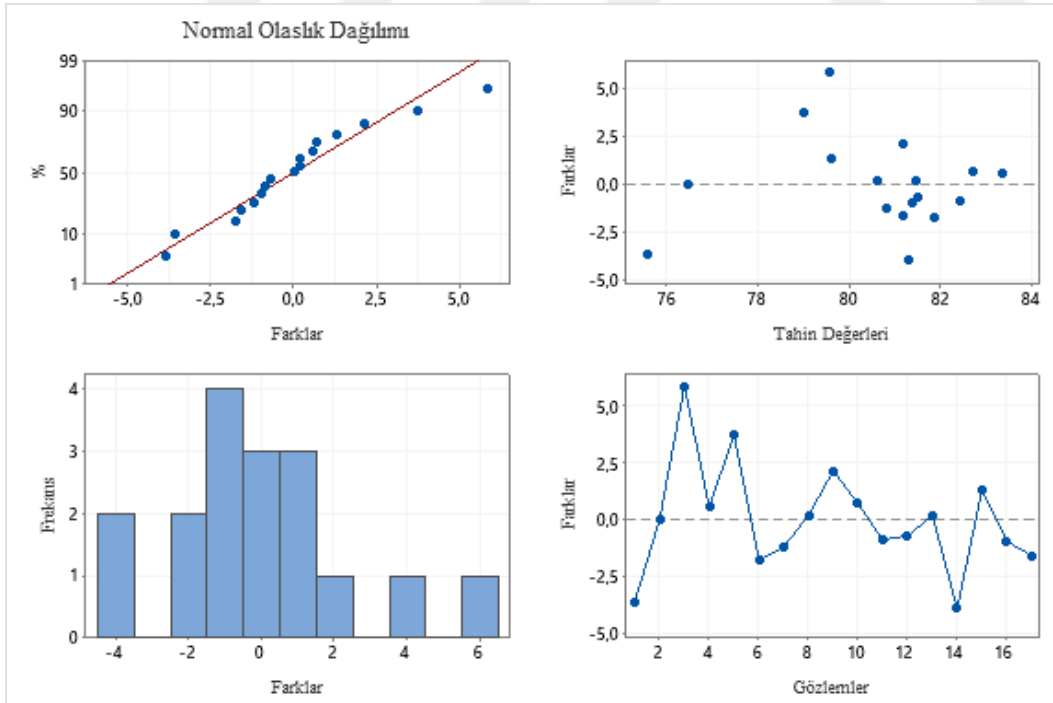
İlkbahar Mevsimi Cumartesi



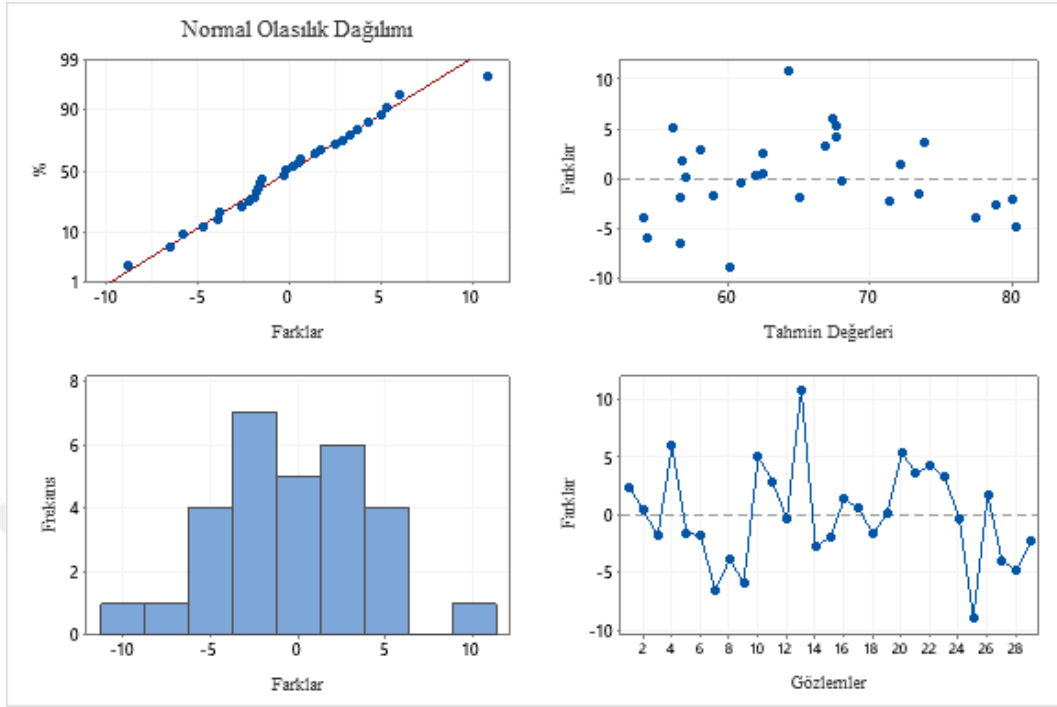
Yaz Mevsimi Cumartesi



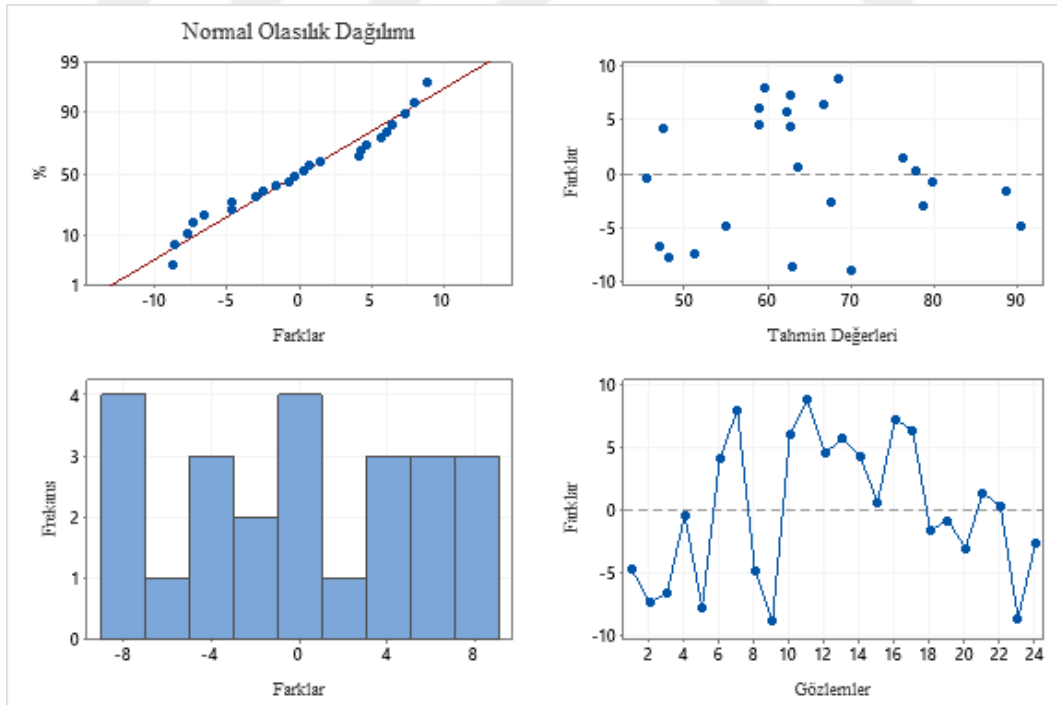
Sonbahar Mevsimi Cumartesi



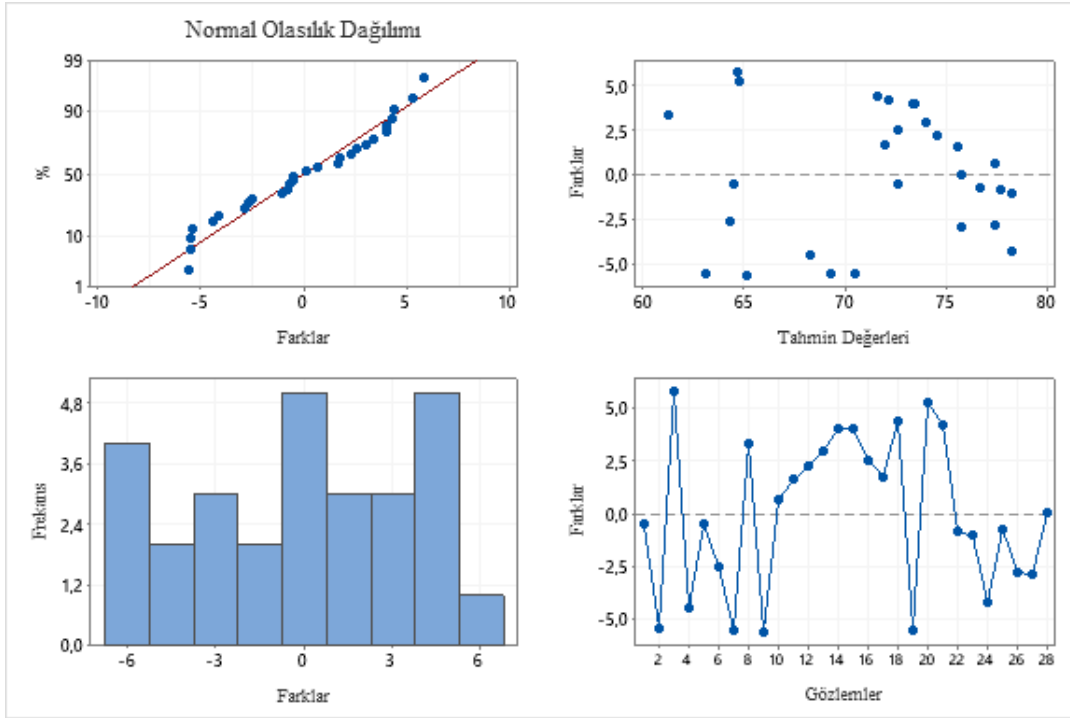
Kış Mevsimi Pazar



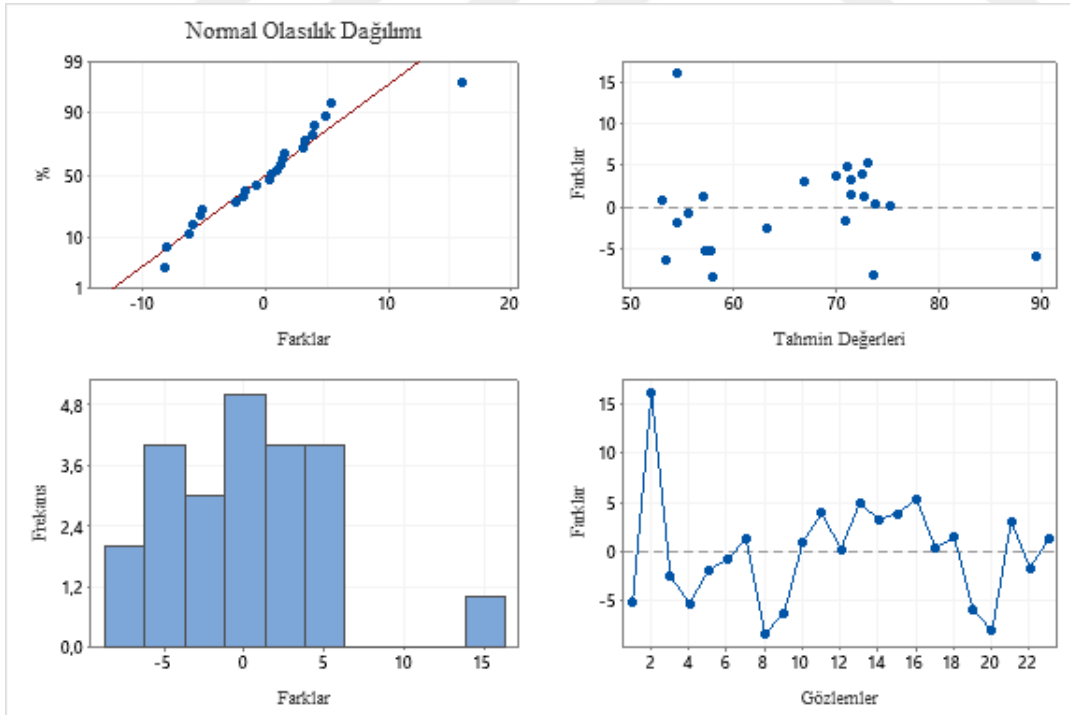
İlkbahar Mevsimi Pazar



Yaz Mevsimi Pazar



Sonbahar Mevsimi Pazar



ÖZGEÇMİŞ

Ad-Soyad : BEYZA NUR ERTEM
Uyruđu : T.C
Dođum Tarihi ve Yeri : 14.09.1991 Altındađ
E-posta :beyzaozturk1991@gmail.com

ÖĐRENİM DURUMU:

- **Lisans** : 2014, Ankara Üniversitesi, Mühendislik Fakültesi, Gıda Mühendisliđi
- **Yüksek lisans** : 2020, Tobb Ekonomi ve Teknoloji Üniversitesi, Fen Bilimleri Enstitüsü, Endüstri Mühendisliđi

MESLEKİ DENEYİM VE ÖDÜLLER:

Yıl	Yer	Görev
2016-2019	Cremonini Restauration Sas Merkezi Fransa Ankara Şubesi Kontroler	Kontoler
2015-2016	Big Bang Burger	Maliyet Kontrol Uzmanı

YABANCI DİL: İngilizce

TEZDEN TÜRETİLEN SUNUM:

Ertođral K., **Öztürk B.** 2020. Development of Multiple Linear Regression Forecasting Approach for The Number of Customers in A High Speed Train Line, 3rd International E-Conference on Mathematical Advances and Applications, June 24-27, 2020
Istanbul, Turkey