



**BİR LİMAN İŞLETMESİ İÇİN KAPASİTE YETERLİLİK
ANALİZİ**

Hande GÜZEY



T.C.
BURSA ULUDAĞ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

BİR LİMAN İŞLETMESİ İÇİN KAPASİTE YETERLİLİK ANALİZİ

Hande GÜZEY
0000-0003-3250-9939

Dr. Öğr. Üyesi Mehmet AKANSEL
0000-0002-4924-7587
(Danışman)

YÜKSEK LİSANS TEZİ
ENDÜSTRİ MÜHENDİSLİĞİ ANABİLİM DALI

BURSA – 2019

TEZ ONAYI

Hande GÜZEY tarafından hazırlanan “BİR LİMAN İŞLETMESİ İÇİN KAPASİTE YETERLİLİK ANALİZİ” adlı tez çalışması aşağıdaki jüri tarafından oy birliği ile Bursa Uludağ Üniversitesi Fen Bilimleri Enstitüsü Endüstri Mühendisliği Anabilim Dalı’nda **YÜKSEK LİSANS TEZİ** olarak kabul edilmiştir.

Danışman: Dr. Öğr. Üyesi Mehmet AKANSEL
0000-0002-4924-7587

Başkan: Dr. Öğr. Üyesi Mehmet AKANSEL
0000-0002-4924-7587
Uludağ Üniversitesi, Mühendislik
Fakültesi,
Endüstri Mühendisliği Anabilim Dalı

İmza


Üye: Doç. Dr. Tülin İNKAYA
0000-0002-6260-0162
Uludağ Üniversitesi, Mühendislik
Fakültesi,
Endüstri Mühendisliği Anabilim Dalı

İmza


Üye: Doç. Dr. Aytaç YILDIZ
0000-0002-6709-5812
Bursa Teknik Üniversitesi, Mühendislik ve
Doğa Bilimleri Fakültesi,
Endüstri Mühendisliği Anabilim Dalı

İmza


Yukarıdaki sonucu onaylarım

Prof. Dr. Hüseyin Aksel EREN
Enstitü Müdürü
07/10/2019

U.Ü. Fen Bilimleri Enstitüsü, tez yazım kurallarına uygun olarak hazırladığım bu tez çalışmada;

- tez içindeki bütün bilgi ve belgeleri akademik kurallar çerçevesinde elde ettiğimi,
- görsel, işitsel ve yazılı tüm bilgi ve sonuçları bilimsel ahlak kurallarına uygun olarak sunduğumu,
- başkalarının eserlerinden yararlanılması durumunda ilgili eserlere bilimsel normlara uygun olarak atıfta bulunduğumu,
- atıfta bulunduğum eserlerin tümünü kaynak olarak gösterdiğimi,
- kullanılan verilerde herhangi bir tahrifat yapmadığımı,
- ve bu tezin herhangi bir bölümünü bu üniversite veya başka bir üniversitede başka bir tez çalışması olarak sunmadığımı

beyan ederim.

20/08/2019

Hande GÜZEY

ÖZET

Yüksek Lisans Tezi

BİR LİMAN İŞLETMESİ İÇİN KAPASİTE YETERLİLİK ANALİZİ

Hande GÜZEY

Bursa Uludağ Üniversitesi
Fen Bilimleri Enstitüsü
Endüstri Mühendisliği Anabilim Dalı

Danışman: Dr. Öğr. Üyesi Mehmet AKANSEL

Dünya ticaretinin önemli bir kısmı denizyolu taşımacılığı ile yapılmaktadır. Bu sebeple limanlar uluslararası ticarete önemli bir yere sahiptir. Doğru kapasite planlaması tüm işletmelerin verimliliği ve yatırım planları açısından büyük önem taşımaktadır. Kapasite konusunda yapılacak planlama çalışmaları talep tahminine dayanmaktadır. Limanlar için özellikle önemli bir gösterge olan talep tahmini, gelecekteki kapasite ihtiyacının belirlenmesi konusunda fikir vermektedir.

Bu çalışmada, Türkiye'deki bir limanın talep tahmini problemi için farklı yöntemler karşılaştırılmıştır. 2012-2017 döneminde farklı operasyon türleri için (genel kargo, konteyner, araç) üç tip veri toplanmıştır. Önceki çalışmalar incelendiğinde talep tahmini için makine öğrenme yöntemlerinin sık kullanılmadığı ve konteyner terminallerinde talep tahminine yönelik çalışmaların, deniz terminallerinde yapılan çalışmalardan çok daha fazla olduğu görülmüştür. En iyi tahmin yöntemini belirlemek ve 2017 yılından sonraki iki yıl için yük elleçleme hacimlerini tahmin etmek amacıyla üç veri setine istatistiksel tahmin yöntemleri ve makine öğrenme yöntemleri uygulanmıştır. İstatistiksel tahmin yöntemleri ve makine öğrenme yöntemlerinin tahmin performansları analiz edilmiştir. Seçilen doğruluk ölçütlerine göre, Toplamsal Holt Winter's, konteyner ve araç elleçleme hacimleri için en iyi tahmin yöntemi olarak kabul edilirken, genel kargo için ARIMA yöntemi en iyi tahmin değerlerini sağlamıştır. Her veri tipi için, en iyi performans gösteren modelin tahmin sonuçları, limanın yapılacak rıhtım yapım çalışması sebebiyle 2017 yılından sonraki iki yıl için talebi karşılayabilecek kapasiteye sahip olup olmadığını analiz etmek için kullanılmıştır. Hesaplanan kapasite kullanım oranlarına göre yıkılacak olan iskelenin rıhtım doluluğunu fazla etkileyeceği bu sebeple limanın iskele yapımı tamamlanana kadar operasyon hızını artırıcı ve depolama alanlarını artırıcı planlar yapması gerektiği görülmüştür.

Anahtar Kelimeler: Talep tahmini, liman, veri madenciliği, istatistiksel modelleme, kapasite analizi

2019, ix + 74 sayfa.

ABSTRACT

MSc Thesis

CAPACITY AVAILABILITY ANALYSIS FOR A SEAPORT COMPANY

Hande GÜZEY

Bursa Uludağ University
Graduate School of Natural and Applied Sciences
Department of Industrial Engineering

Supervisor: Asst. Prof. Dr. Mehmet AKANSEL

An important part of world trade is done by sea transportation. Therefore, ports have an important place in international trade. Capacity planning is very important in terms of the efficiency of the all enterprises and investment plans. Planning studies on capacity are based on demand estimation. The demand forecasting, which is a particularly important indicator for ports, provides an idea about determining the future capacity need.

In this study, different methods are compared for demand forecasting problem of a seaport in Turkey. Three types of data were collected from the period of 2012-2017 for different operation types (general cargo, container, vehicle). When previous studies are examined, it is seen that machine learning methods are not used frequently for demand forecasting and studies on demand forecasting at container terminals are much more than studies conducted at marine terminals. Statistical forecasting methods and machine learning methods were applied to three data sets to determine the best estimation method and to estimate the handling volumes for the next two years after 2017. The comparison of the forecasting performances of statistical forecasting methods and machine learning methods have been analysed. According to chosen accuracy measures, Additive Holt Winter's was recognized as the best forecasting method for container and vehicle handling volumes, whereas ARIMA method ensured the best forecasting values for general cargo. For each data type, the prediction results of the best performing model were used to analyze whether the port has the capacity to handle the demand for the next two years after 2017 due to the quay construction work. According to the calculated capacity utilization rates, it will be seen that the quay to be demolished will affect the occupancy of the quay much and therefore plans should be made to increase the operational speed and increase storage areas until the pier construction is completed.

Key words: Demand forecasting, seaport, data mining, statistical modelling, capacity analysis

2019, ix + 74 pages.

TEŐEKKÜR

Tez alıőmam ve yksek lisans eęitimim sresince deęerli bilgi ve tecrbeleri ile bana yol gsteren danıőmanım Sayın Dr. ęr. yesi Mehmet AKANSEL'e teőekkrlerimi sunarım.

Tm eęitim hayatım boyunca maddi ve manevi desteklerini hibir zaman esirgemeyen sevgili aileme en iten teőekkrlerimi sunarım.

alıőmam sresince manevi destekleri ile bana yol gsteren sevgili arkadaőlarım ve sahip olduęu bilgileri esirgemeyerek katkıda bulunan sevgili Senem YILMAZ'a teőekkrlerimi sunarım.

Hande GZEY
20/08/2019

İÇİNDEKİLER

| | Sayfa |
|--|-------|
| ÖZET..... | i |
| ABSTRACT..... | ii |
| TEŞEKKÜR..... | iii |
| SİMGELER ve KISALTMALAR DİZİNİ..... | vi |
| ŞEKİLLER DİZİNİ..... | viii |
| ÇİZELGELER DİZİNİ..... | ix |
| 1. GİRİŞ..... | 1 |
| 2. KURAMSAL TEMELLER VE KAYNAK ARAŞTIRMASI..... | 3 |
| 2.1. Limanlar..... | 3 |
| 2.2. Ülke Ekonomisinde Limanların Önemi..... | 5 |
| 2.3. Türkiye’de Limanların Durumu..... | 5 |
| 2.4. Limanlarda Talep Tahmini ve Kapasite Kavramı..... | 6 |
| 2.5. Kaynak Araştırması..... | 8 |
| 3. MATERYAL VE YÖNTEM..... | 13 |
| 3.1. Zaman Serisi Yöntemleri..... | 14 |
| 3.2. Regresyon Analizi Yöntemleri..... | 16 |
| 3.3. Makine Öğrenme Yöntemleri..... | 17 |
| 3.4. Kapasite Hesaplama Yöntemi..... | 25 |
| 3.5. Veriler ve Parametreler..... | 26 |
| 3.6. Tahmin Yöntemlerinin R Studio ile Uygulanması..... | 30 |
| 4. BULGULAR..... | 32 |
| 4.1. Talep Tahmini Sonuçları..... | 32 |
| 4.2. Modellerin Performans Sonuçları..... | 34 |
| 4.3. Rıhtım Kapasitesi Doluluk Oranları..... | 44 |
| 5. SONUÇ..... | 48 |
| KAYNAKLAR..... | 49 |
| EKLER..... | 53 |
| EK 1. İstatistiksel Tahmin Yöntemlerinin Uygulanacağı Verilerin Okunması ve Üstel Düzeltme Yöntemleri İçin Zaman Serisi Formatına Dönüştürülmesine Ait R Script Kodları..... | 55 |
| EK 2. Kullanılan Girdi Değişkenlerine Ait Yıllık Verileri Aylık Verilere Dönüştürmek İçin Uygulanan İnterpolasyona Ait R Script Kodları..... | 56 |
| EK 3. Genel Kargo Verisi Üzerinde Uygulanan Üstel Düzeltme Yöntemlerine Ait R Script Kodları ve Performans Çıktıları..... | 57 |
| EK 4. Genel Kargo Verisi Üzerinde Uygulanan ARIMA Yöntemine Ait R Script Kodları ve Performans Çıktıları..... | 58 |
| EK 5. Genel Kargo Verisi Üzerinde Uygulanan Basit Doğrusal Regresyon Analizi Yöntemine Ait R Script Kodları ve Performans Çıktıları..... | 59 |
| EK 6. Çoklu Doğrusal Bağlantının Saptanmasında Kullanılan R Script Kodları ve Sonuçları..... | 60 |
| EK 7. Genel Kargo Verisi Üzerinde Uygulanan Regresyon Varsayımları Kontrol Sonuçları..... | 61 |
| EK 8. Konteyner Üzerinde Uygulanan Regresyon Varsayımları Kontrol Sonuçları..... | 62 |
| EK 9. Araç Verisi Üzerinde Uygulanan Regresyon Varsayımları Kontrol Sonuçları..... | 63 |
| EK 10. Genel Kargo Verisi Üzerinde Uygulanan Adım Adım Regresyon Analizine Ait R Script Kodları ve Performans Sonuçları..... | 64 |

| | |
|---|----|
| EK 11. Genel Kargo Verisi İçin Adım Adım Regresyon Sonucunda Kurulan Modele Ait Tahminler ve ANOVA Analizi Sonuçları | 65 |
| EK 12. Konteyner Verisi İçin Adım Adım Regresyon Sonucunda Kurulan Modele Ait Tahminler ve ANOVA Analizi Sonuçları | 66 |
| EK 13. Araç Verisi İçin Adım Adım Regresyon Sonucunda Kurulan Modele Ait Tahminler ve ANOVA Analizi Sonuçları | 67 |
| EK 14. Genel Kargo Verisi Üzerinde Uygulanan Destek Vektör Regresyon Yöntemlerine Ait R Script Kodları | 68 |
| EK 15. Farklı Yöntemlerin Performansının Belirlenmesinde Kullanılan Fonksiyonlar ve DVR Yöntemleri İçin Genel Kargo Verisi Üzerinde Uygulanmasına Ait R Script Kodları..... | 69 |
| EK 16. Genel Kargo Verisi Üzerinde Uygulanan Destek Vektör Regresyon Yöntemlerinin Performans Sonuçları ve En İyi Performansı Veren Yöntem İle Yapılan Tahmine Ait R Script Kodları | 70 |
| EK 17. Genel Kargo İçin En İyi Sonucu Veren İstatistiksel Tahmin Yöntemi ve DVR Yönteminin R Studio Grafikleri | 71 |
| EK 18. Konteyner İçin En İyi Sonucu Veren İstatistiksel Tahmin Yöntemi ve DVR Yönteminin R Studio Grafikleri | 72 |
| EK 19. Araç İçin En İyi Sonucu Veren İstatistiksel Tahmin Yöntemi ve DVR Yönteminin R Studio Grafikleri | 73 |
| ÖZGEÇMİŞ | 74 |

SİMGELER ve KISALTMALAR DİZİNİ

Simgeler

Açıklama

| | |
|------------------------|---|
| w | Çoklu düzlemin normal vektörü |
| b | Görelî alanın koordinat merkezine konumu |
| ξ_i, ξ_i^* | Aylak değişkenler |
| C | Ceza bedeli |
| $K(x_n, x_i)$ | Çekirdek fonksiyonu |
| $\phi(x)$ | Dönüşüm fonksiyonu |
| α_i, α_i^* | Lagrange çarpanları |
| \aleph | Giriş desenlerinin alanı |
| \mathfrak{S} | Özellik uzayı |
| i | Operasyon türü |
| V_i | Gelecek gemi sayısı |
| C_i | Elleçlenecek yük miktarı |
| P_i | Gemi başına yük miktarı |
| Y_i | Rıhtım fiili kapasitesi |
| T_i | Gemilerin ortalama rıhtımda kalış süresi |
| O_i | Operasyon türü için kullanılan ortalama rıhtım sayısı |
| Z | Rıhtımın mevcut kapasitesi |
| B | Rıhtım sayısı |
| D | Yıllık çalışılan gün sayısı |
| H | Günlük çalışma saati |
| KKO | Kapasite kullanım oranı |

Kısaltmalar

Açıklama

| | |
|-------|--|
| ABK | Akaike Bilgi Kriteri |
| AIK | Alıcı İşlem Karakteristiği |
| BÜD | Basit Üstel Düzeltme |
| ÇHW | Çarpımsal Holt Winters |
| ÇKA | Çok Katmanlı Algılayıcı |
| DVM | Destek Vektör Makinesi |
| DVR | Destek Vektör Regresyon |
| DVS | Destek Vektör Sınıflandırma |
| EAA | Eğri Altındaki Alan |
| EKDVM | En Küçük Kareler Destek Vektör Makinesi |
| GSMH | Gayri Safi Milli Hasıla |
| GSYH | Gayri Safi Yurt İçi Hasıla |
| HO | Hareketli Ortalama |
| HW | Holt-Winters |
| IMF | International Monetary Fund (Uluslararası Para Fonu) |
| MOHOM | Mevsimsel Otoresif Hareketli Ortalamalar Modeli |
| OECD | Organisation for Economic Co-operation and Development |
| OKH | Ortalama Karesel Hata |
| OKHK | Ortalama Karesel Hatanın Karekökü |

| | |
|---------|-------------------------------------|
| OMH | Ortalama Mutlak Hata |
| OMYH | Ortalama Mutlak Yüzdellik Hata |
| RTF | Radyal Temelli Fonksiyon |
| THW | Toplamsal Holt-Winters |
| TÜİK | Türkiye İstatistik Kurumu |
| TÜRKLİM | Türkiye Liman İşletmecileri Derneği |
| VAF | Varyans Artırıcı Faktör |



ŞEKİLLER DİZİNİ

Sayfa

| | |
|---|----|
| Şekil 3.1. Çalışma adımlarını gösteren akış şeması | 13 |
| Şekil 3.2. Hiper düzlemlerin gösterimi | 18 |
| Şekil 3.3. Doğrusal ayrılabilir verilerde optimum hiper düzlemi belirlemek için DVM gösterimi | 20 |
| Şekil 3.4. Çekirdek fonksiyonu ile verilerin doğrusal olarak ayrılması | 21 |
| Şekil 3.5. Veriyi iki ve üç parçaya bölme | 23 |
| Şekil 3.6. Uygulanan işlemlere ait akış şeması | 24 |
| Şekil 3.7. Hareketli pencere süreci | 31 |
| Şekil 4.1. Genel kargo talep verileri ve gelecek dönemlerdeki talep tahminleri | 43 |
| Şekil 4.2. Konteyner talep verileri ve gelecek dönemlerdeki talep tahminleri | 44 |
| Şekil 4.3. Araç talep verileri ve gelecek dönemlerdeki talep tahminleri | 44 |
| Şekil 4.4. 2018 ve 2019 yılı için eski iskele dahil kapasite kullanım oranı | 47 |

ÇİZELGELER DİZİNİ

| | Sayfa |
|---|-------|
| Çizelge 3.1. Tahmin yöntemlerinde kullanılan çıktı değişkenleri | 27 |
| Çizelge 3.2. İnterpolasyon için kullanılan yıllık girdi değişkenleri | 28 |
| Çizelge 3.3. İnterpolasyon sonrası elde edilen aylık girdi değişkenleri | 29 |
| Çizelge 4.1. Genel kargo için uygulanan yöntemler ile elde edilen tahmin sonuçları ... | 32 |
| Çizelge 4.2. Konteyner için uygulanan yöntemler ile elde edilen tahmin sonuçları | 33 |
| Çizelge 4.3. Araç için uygulanan yöntemler ile elde edilen tahmin sonuçları | 34 |
| Çizelge 4.4. Genel kargo için uygulanan istatistiksel yöntemlerin performans sonuçları | 35 |
| Çizelge 4.5. Konteyner için uygulanan istatistiksel yöntemlerin performans sonuçları ... | 35 |
| Çizelge 4.6. Araç için uygulanan istatistiksel yöntemlerin performans sonuçları | 35 |
| Çizelge 4.7. Genel kargo için değişkenler arası korelasyon değerleri | 36 |
| Çizelge 4.8. Konteyner için değişkenler arası korelasyon değerleri | 36 |
| Çizelge 4.9. Araç için değişkenler arası korelasyon değerleri | 36 |
| Çizelge 4.10. Bağımsız değişkenler için hesaplanan VAF değerleri | 37 |
| Çizelge 4.11. Genel kargo için nüfus bağımsız değişkeni kullanılarak kurulan modele ait ANOVA analizi sonuçları | 38 |
| Çizelge 4.12. Konteyner için dış ticaret ve nüfus bağımsız değişkenleri kullanılarak kurulan modele ait ANOVA analizi sonuçları | 38 |
| Çizelge 4.13. Araç için dış ticaret ve nüfus bağımsız değişkenleri kullanılarak kurulan modele ait ANOVA analizi sonuçları | 39 |
| Çizelge 4.14. Araç için nüfus bağımsız değişkeni kullanılarak kurulan modele ait ANOVA analizi sonuçları | 39 |
| Çizelge 4.15. Tüm operasyon türleri için seçilen çoklu regresyon modellerinin tahmin performansları | 39 |
| Çizelge 4.16. Genel kargo için bağımsız değişken olarak nüfus kullanılarak kurulan DVR yöntemi tahmin performansları | 40 |
| Çizelge 4.17. Konteyner için bağımsız değişken olarak dış ticaret, nüfus kullanılarak kurulan DVR yöntemi tahmin performansları | 40 |
| Çizelge 4.18. Araç için bağımsız değişken olarak dış ticaret, nüfus kullanılarak kurulan DVR yöntemi tahmin performansları | 41 |
| Çizelge 4.19. Tüm operasyon türleri için seçilen DVR yöntemlerinin tahmin performansları | 41 |
| Çizelge 4.20. Operasyon türleri için en iyi performansı veren yöntemlerin karşılaştırması | 42 |
| Çizelge 4.21. En iyi performansla sahip model ile yapılan tahminler | 42 |
| Çizelge 4.22. Genel kargo için kapasite hesaplamada kullanılan değişkenler ve değerleri | 45 |
| Çizelge 4.23. Konteyner için kapasite hesaplamada kullanılan değişkenler ve değerleri | 45 |
| Çizelge 4.24. Araç için kapasite hesaplamada kullanılan değişkenler ve değerleri | 45 |
| Çizelge 4.25. Genel kargo, konteyner ve araç için gerçekleşecek kapasite değerleri | 46 |
| Çizelge 4.26. Limanın mevcut rıhtım kapasitesi değerleri | 46 |
| Çizelge 4.27. Liman için rıhtım kapasitesi kullanım oranı tahminleri | 46 |

1. GİRİŞ

Deniz taşımacılığı dünya ticaretinin önemli bir kolunu oluşturmaktadır. Deniz taşımacılığının en önemli öğeleri limanlar ve gemilerdir (Usluer ve Alkan 2015). Liman, Ulaştırma Kıyı Yapıları Master Plan Çalışması Sonuç Raporu içerisinde gemilerin yükleme/boşaltma faaliyetlerini gerçekleştirdiği, gümrük, depolama, lojistik gibi çeşitli hizmetlerin de verildiği tesis olarak tanımlanmaktadır (Anonim 2010). Uluslararası ticaretin gelişmesinde denizyolu yük taşımacılığı önemli bir yere sahip olduğundan limanlar da ülkelerin ekonomik gelişmişlik seviyesinin belirlenmesinde önemli bir ölçüt olarak karşımıza çıkmaktadır (Balık 2014).

Limanların etkin ve verimli kullanımı uluslararası ticaretteki rekabet gücünü artırmaktadır (Oral ve Özerden 2010). Limanın en önemli göstergelerinden biri olan kapasite, limanlardaki verimliliğin belirlenmesinde kullanılan önemli bir parametredir. Doğru kapasite analizi, limanın ne kadar yük hacmine hizmet verebileceği, dolayısıyla gelecek için alınacak olan yatırım kararlarının temelini oluşturur (Oral 2014).

Talep tahmini kapasite hesaplamalarının temelini oluşturmaktadır. Trafik yük tahmini limanların geleceklerini planlayabilmeleri açısından önemli bir yere sahiptir (Akar ve Esmer 2015).

Bu çalışmada Türkiye'deki bir limanda gerçekleşecek olan rıhtım yapım çalışması sebebiyle gelecek iki yıl boyunca talebi karşılayabilecek kapasiteye sahip olup olmadığı analiz edilmiştir. Kapasite analizi öncesinde üç farklı yük tipi için trafik yükleri tahmin edilmiştir. Limanlarda yapılmış olan mevcut çalışmalar incelendiğinde talep tahmini için makine öğrenme yöntemlerinin sık kullanılmadığı (Gökkuş ve ark. 2017) ve konteyner terminallerinde talep tahminine yönelik çalışmaların, deniz terminallerinde yapılan çalışmalardan çok daha fazla olduğu görülmüştür. Trafik yük tahmini için istatistiksel tahmin yöntemleri ve makine öğrenme yöntemleri uygulanmış ve sonuçları karşılaştırılmıştır. Her yük tipi için, en iyi performans gösteren modelin tahmin sonuçları, limanın gelecek iki yıl boyunca talebi karşılayabilecek kapasiteye sahip olup olmadığının belirlenmesinde kullanılmıştır.

İkinci bölümde, limanlar hakkında genel bilgiler, ülke ekonomisi ve dünya ticaretinde limanların yeri ve önemi hakkında bilgiler verilmiştir.

Üçüncü bölümde, yük talep tahmini için kullanılmış olan yöntemler, modeller ve kullanılan parametrelere ait açıklamalar bulunmaktadır.

Dördüncü bölümde, yük tipleri için yapılan tahmin sonuçları verilmiş ve yorumlanmıştır. Tahmin sonuçları kullanılarak yapılmış olan kapasite analizine ait sonuçlar da bu bölümde yer almaktadır.



2. KURAMSAL TEMELLER ve KAYNAK ARAŞTIRMASI

2.1. Limanlar

Günümüzde uluslararası ticari taşımacılıkta çok önemli bir paya sahip olan denizyolu taşımacılığının en önemli öğelerinden biri limanlardır. Liman, gemi ile diğer taşıma araçları arasında mal ve yolcu aktarılmasını veya yükün depolanmasını güvenlikle sağlamayı amaçlayan ve buna ilişkin olarak ekonomik işlevlerin gerçekleşmesine olanak veren tüm altyapı ve donanımın var olduğu hizmet yeridir (Balık 2014). Ulaştırma Kırıtı Yapıları Master Plan Çalışması Sonuç Raporu içerisinde ise liman “Gemileri dalga, akıntı ve rüzgar gibi etkilerden koruyan ve yükleme/boşaltma yapabilmeleri için çeşitli tesisleri olan suni veya doğal korunaklı su ve kara alanlarının yanı sıra gümrük, depolama, liman yönetimi, lojistik gibi çeşitli hizmet tesislerini içeren bir kompleks” şeklinde tanımlanmıştır (Anonim 2010).

Denizyolu taşımacılığı uluslararası ticaretin gelişimiyle yakından ilişkili olduğundan limanlar da uluslararası ticaretin ve sanayinin gelişmesinde önemli bir role sahiptir. Ülkelerin ekonomik gelişmişlik seviyesini gösteren limanların sayısı ve kapasiteleri, ülkelerin ulusal güç ve rekabet kapasitesi için de önemli bir gösterge olarak karşımıza çıkmaktadır. Limanların verdikleri hizmetler açısından gelişen talebi karşılayacak kapasiteye sahip olması gerekmektedir. Değişen ve gelişen hizmet anlayışı ile limanlarda lojistik hizmetler de verilir duruma gelmiştir. Balık (2014), limanları aşağıdaki şekilde sınıflandırmıştır.

Faaliyet Alanlarına Göre Limanlar

Kıtalararası limanlar: Dünya trafiğine cevap veren limanlardır.

Ulusal limanlar: Milli trafiğe cevap veren limanlardır.

Bölgesel limanlar: Bölgesel trafiğe cevap veren limanlardır.

Yerel limanlar: Mahalli trafiğe cevap veren limanlardır.

Yük Tiplerine Göre Limanlar

Genel kargo limanı: Kuru yük, paletli, jumbo (bigbag), dökme, paket vb. her türlü kuru yükün uygun nitelikteki araç, gereç ve teçhizat kullanılmasıyla yapılan yükleme, boşaltma ve istifleme operasyonlarını kapsamaktadır.

Konteyner limanı: Büyük tonajlı kara taşıtlarının giriş çıkış yapabildiği, konteyner adı verilen, deniz ve kara yük taşımacılığında kullanılan standart boyutlardaki kutulara yerleştirilmiş halde taşınan yüklerin elleçlendiği ve gümrük işlemlerinin yapıldığı, yük gemilerinin yanaşıp indirme-bindirme yaptığı limana denir.

Çok amaçlı liman: Birden fazla yük tipinin elleçlenmesine imkân veren limanlardır.

Ro-Ro limanı: Kapıdan kapıya taşımacılık anlayışının gemi taşımacılığına da yansıtılması ile römork ve kamyonlar yükleri ile birlikte Ro-Ro adı verilen büyük gemilerce taşınmaya başlanmıştır. Bu sayede bir noktada yüklenen bir araç arada hiç indirme bindirme yapmadan varması gereken noktaya nakliyat imkânı sağlamaktadır. Bu da daha hızlı ve ucuz transfer olanağı sunmaktadır. Bu şekilde nakliyat yapan devasa gemilerin yanaştığı indirme yaptığı, gümrük işlemlerinin yapıldığı, geniş park ve manevra alanları içeren büyük limanlara Ro-Ro limanı denir.

Dökme yük limanı: Maden cevheri, çimento, kum, tahıl, kömür gibi dökme kuru yüklerin elleçlendiği limanlardır.

Sıvı yük limanı: Petrol, doğalgaz, azot vb. kimyasalların transferinin yapıldığı büyük limanlardır.

Mülkiyet yapısına göre limanlar

Kamu limanları: Limanın sahipliği ve işletmesinin devlete ait olduğu limanlardır.

Kamu-özel limanları: Arazisi ve sahipliğinin devlete ait olduğu ancak özel sektör tarafından işletilen limanlardır.

Özel limanlar: Arazisi, sahipliği ve yönetiminin özel şirketlerde olduğu limanlardır.

Verdikleri hizmete göre limanlar

Ana liman: Bu limanların art alanlarından ithal/ihraç ettikleri kendi orijinal bölgesel yükleri vardır. Ayrıca diğer limanlardan gelen ulusal ya da uluslararası yüklerin uğrak veya besleme limanlarına aktarılmasını da sağlarlar.

Aktarma limanı: Genellikle uluslararası yük aktarımı için yüklerin elleçlendiği limanlar olup kendi art alanlarına hizmet etmezler.

Uğrak limanı: Bu tip limanlara uluslararası ya da kıtalararası gemiler de belli periyotlarda uğrayabilir ancak aktarma yükleri elleçlemezler. Aktarma konteyneri elleçleme potansiyellerine sahip olduklarından bu limanlar kolayca ana limana dönüşebilir.

Besleme limanı: Ana limanlara uğrayan konteyner gemileri bu limanlara uğramazlar, sadece ana limanlardan aktarılan yükleri elleçleyerek kendi art alanlarına hizmet ederler.

2.2. Ülke Ekonomisinde Limanların Önemi

Dünya ticaret hacmindeki artış ile denizyolu taşımacılığının önemi de artmıştır. Dünya ticaretinin büyük bir kısmında denizyolu taşımacılığı kullanılması sebebiyle limanların uluslararası ticaretteki önemi de büyüktür. Limanlar, büyük gelir ve istihdam kaynağı olmalarıyla birlikte ülkelerin dünyaya açılan kapısı konumundadır (Bayraktutan ve Özbilgin 2013). Uluslararası mal ticaretinin büyük bir kısmında denizyolu taşımacılığı kullanıldığından limanlar tedarik zincirinin temel taşlarından biri konumundadır. Limanların verimli çalışmasının ürün teslim zamanı üzerindeki etkisi ulusal ve/veya uluslararası rekabet gücünü belirlemektedir (Muslu 2017). Dolayısıyla limanlar taşımacılığın yanı sıra üretim, ticaret ve lojistik sistemleri için de büyük önem taşımaktadır.

Koçak ve Kişi (2015) etkin ve verimli limanların uluslararası ticareti bölgeye çekerek bölgesel ekonomik gelişime de büyük katkı sağladığını belirtmiştir. Oral ve Özderen (2010) limanların etkin ve verimli kullanılmasının taşıma süresi ve maliyeti düşürerek liman kullanıcısı firmaların dış rekabet gücünü arttırdığını ifade etmişlerdir.

2.3. Türkiye’de Limanların Durumu

Ülkemizin bulunduğu coğrafik konum sebebiyle Türk limanları büyük avantaja sahiptir. Bütün dünyada olduğu gibi ülkemizde de uluslararası ticaretin büyük bir bölümü denizyolu taşımacılığı ile gerçekleştirilmektedir. 8333 kilometre kıyı şeridine sahip ülkemizde 180 adet liman ve iskele bulunmakta olup, bunlardan yedi adedi Türkiye Denizcilik İşletmeleri tarafından, iki adedi de Türkiye Devlet Demir Yolları tarafından işletilmektedir. Deniz Ticaret Odası Sektör Raporunda yer alan bilgilere göre Türkiye’de 21 adet idari liman, 23 adet belediye limanı, 136 adet özel liman bulunmaktadır (Anonim 2017).

Türkiye limanlarının yapılanmaları, bir yük türünde uzmanlaşmış limanlardan çok farklı yük türüne hizmet verebilecek ekipmanlarla donatılan konvansiyonel türde liman özelliği göstermektedir.

Deniz Ticaret Odası sektör raporlarına göre jeo-stratejik açıdan denizyolu taşımacılığına son derece uygun olan Türkiye'nin uluslararası pazarlara ulaşmasında ve ülkenin ekonomik, sosyal ve ticari yapısı üzerinde, ulusal ulaştırma sisteminin son noktası olan limanlar oldukça etkilidir. Küreselleşme ile birlikte limanlar sadece bölgesel yüke hizmet veren limanlar olmaktan çıkmış ve bir bölgenin limanı olmaktan çok bölgedeki yük trafiğinin limanı olma yönünde gelişme göstermiştir. Limanlar yapılanmalarını bölgelerindeki aktarma yüklerinden daha fazla pay almak için düzenlemektedir (Anonim 2015, 2017).

2.4. Limanlarda Talep Tahmini ve Kapasite Kavramı

Ülke ekonomisinde büyük öneme sahip olan limanların verdiği hizmetler açısından gelişen talebi karşılayacak arza ve ekonomik gelişmeleri karşılayacak sosyal ve fiziki kapasiteye sahip olması gerekir (Balık 2014).

Dünyada ticaret olduğu sürece deniz ticareti var olacağından limanların verdikleri hizmetleri geliştirmek gerekmektedir. Talep tahmini tüm sektörlerde olduğu gibi limanlar için de geleceklerini planlayabilmeleri açısından önemli bir yere sahiptir. Günümüzdeki yoğun rekabet koşulları altında işletmelerin plan yapabilmeleri, gerekli yatırımları tespit edebilmeleri için bir karar destek sistemi niteliğindedir. Talep tahmini ayrıca kapasite hesaplamalarının temelini oluşturmaktadır. Bu sebeple limanlar da gelişen ticarete hizmet edebilmek için yük talep tahmini ile gelecekte ne kadar yük elleçleneceğini belirleyerek yatırım ve gelişim planlarını oluşturmalıdır (Esmer 2014, Akar ve Esmer 2015).

Ulaştırma Kıyı Yapıları Master Plan Çalışması Sonuç Raporu (Anonim 2010) ve Esmer (2014) içerisinde de belirtildiği üzere limanlara ilişkin yük talep tahmininde kullanılan başlıca veriler GSYH (Gayri Safi Yurt İçi Hasıla), toptan veya tüketici fiyat indeksi, kişisel tüketim harcamaları, kapasite kullanım oranları, hammadde, yarı mamul ve mamul ürünleri taşıma hacimleri, ithalat ve ihracat hacimleri, temel ürünlerin bölgesel tüketimi olarak sayılabilir. Limanlar için yük talep tahminine dair çalışmalar incelendiğinde

ağırlıklı olarak çoklu regresyon, doğrusal regresyon, logaritmik regresyon kullanılmış olup kullanılan yöntemlerin hepsinde temel veri olarak yük tarihçesi, nüfus verileri ve GSYH değerleri kullanılmıştır (Anonim 2010, Esmer 2014).

Liman kapasitesi bir limanın mevcut imkanları ile elleçleyebileceği yük hacmidir. Doğru kapasite analizi, limanın ne kadar yük elleçleyebileceği dolayısı ile ekipman veya altyapı yatırımlarına ne zaman başlaması gerektiğini gösterdiğinden kapasite limanlardaki en önemli göstergedir. Limanlarda kapasite teorik kapasite, gerçekleşen kapasite ve optimum kapasite olmak üzere üç gruba ayrılmaktadır. Teorik kapasite, belli kabuller altında matematiksel olarak hesaplanan, yılda ne kadar yük elleçlenebileceğini gösteren kapasitedir. Gerçekleşen kapasite, istatistiksel olarak limanların geçmiş yıllarda ulaştığı gerçekleşen yük trafiği üzerinden hesaplanan kapasitedir ve hesaplamada limanın tüm yıllar içerisinde ulaştığı en yüksek yük hacmi dikkate alınmaktadır. Optimum kapasite ise limanın zorlanmadan en etkin ve verimli çalışabildiği kapasitedir. Limanlara gelen yük zamanın bir fonksiyonudur. Elleçlenen yük hacimleri aylık ve mevsimlik farklılıklar gösterdiğinden zamana bağlı değişimler yıllık elleçlenecek yük hacmini de doğrudan etkilemektedir. Bu yüzden zamana bağlı değişimler pik faktörü ile kapasite analizlerine dahil edilmektedir. Zamana bağlı değişimler arttıkça pik faktörü de büyümekte ve yıllık elleçlenebilecek yük hacmi azalmaktadır (Oral 2014).

Ulaştırma Kısıtlı Yapıları Master Plan Çalışması Sonuç Raporu (Anonim 2010) içerisinde liman kapasitesine elleçleme kapasitesi, depolama kapasitesi ve rıhtım kapasitesi başlıkları altında değinilmiştir. Limanın elleçleme kapasitesi, yıl içerisinde elleçleyebileceği yük miktarı olup yükün çeşidine, limandaki elleçleme ekipmanlarına, gemini tipi ve boyutuna göre değişmektedir. Limanın depolama kapasitesi, yıl içerisinde depolama alanlarında depolanabilen yük hacmidir. Depolama kapasitesini etkileyen faktörler limanın geri sahası, elleçleme ekipmanları, zemin özellikleri ve liman saha kaplaması olarak sayılabilir. Rıhtım kapasitesi ise yıl içerisinde rıhtıma yanaşabilen gemi sayısı ile ölçülmekte olup yanaşan geminin tipi ve boyutlarına, limanın yıl içerisinde hizmet verebildiği gün sayısına, rıhtımın uzunluğu ve derinliğine, demirleme alanına, limanda bulunan elleçleme ekipmanları ve liman sahasına bağlı olarak değişmektedir.

2.5. Kaynak Araştırması

Limanlarda talep tahmini ve kapasite üzerine daha önce yapılmış olan bazı çalışmalar aşağıdaki gibidir.

Mak ve Yang (2007) Hong Kong'da aylık konteyner hacmi tahmini için DVM (Destek Vektör Makinesi)'in uyarlanmış bir biçimi kullanmıştır. Çalışmada önerilen DVM yöntemi ve yapay sinir ağı yöntemlerinin karşılaştırması yapılmıştır. Yöntemler uygulanırken Ocak 1995 ve Ekim 2006 aralığındaki toplam 142 gözlem kullanılmıştır. En iyi modele karar vermek için OMH (Ortalama Mutlak Hata) ve OKH (Ortalama Karesel Hata) değerleri karşılaştırılmış, sonuç olarak önerilen DVM yönteminin lojistik yönetiminde kullanmak için mükemmel bir araç olduğu görülmüştür.

Chou ve ark. (2007) 1989-2001 yılları arasındaki verileri kullanarak Tayvan'daki bir limanda ithalat konteyner miktarını tahmin etmiştir. Çalışmada klasik regresyon yöntemi ile yapılan tahmin değerleri ile geliştirilen regresyon modeli ile yapılan tahmin değerlerinin karşılaştırması yapılmıştır. Kullanılan veri setinde ihracat konteyner miktarları, ithalat konteyner miktarları, popülasyon, sanayi üretim indeksi, GSMH (Gayri Safi Milli Hasıla), GSYH, tarımsal GSYH, endüstriyel GSYH, hizmet GSYH değerleri bulunmaktadır. Veri setindeki ekonomik değişkenler arası korelasyonlar hesaplanmış, uygun bağımsız değişken seçimi için adım adım regresyon analizi uygulanmıştır. Sonrasında geliştirilen regresyon modeli ile tahminler yapılmış, sonuç olarak geliştirilen modele ait hata değerleri klasik regresyon ile yapılan tahmine ait hata değerlerinden daha düşük çıktığı için daha yüksek doğruluğa sahip olduğu görülmüştür.

Peng ve Chu (2009), Tayvan'daki üç büyük liman için altı farklı tahmin yöntemi ile konteyner hacmini tahmin etmiştir. Tahminler için klasik ayrışma modeli, trigonometrik regresyon modeli, mevsimsel kukla değişkenler ile regresyon modeli, gri model, hibrit gri model ve MOHOM (Mevsimsel Otoresif Hareketli Ortalamalar Modeli) modeli kullanılmıştır. Konteyner hacmini en doğru tahmin edecek yöntemi tespit etmek için tahmin değerleri karşılaştırılmıştır. Performans karşılaştırmasında her model için OMH, OMYH (Ortalama Mutlak Yüzdellik Hata), OKHK (Ortalama Karesel Hatanın Karekökü) değerleri hesaplanmıştır. Veri seti olarak Tayvan'daki limanlardan Ocak 2003- Aralık

2006 arasındaki aylık veriler kullanılmıştır. Sonuç olarak klasik ayrışma modelinin en doğru sonuçları verdiği görülmüştür.

Jugović ve Hess (2010) bir limanın konteyner trafiği için beş farklı yöntem ile tahminler yapmıştır. İlk olarak üç rakip limana ait 1995-2008 yıllarına ait verilere zaman serileri analizi uygulanarak doğrusal, parabolik ve üstel denklemler elde edilmiştir. Parabolik denklem ile limanın konteyner trafiği tahminlerini elde etmek üç limanın toplam konteyner trafiği tahmini kullanılmıştır. İkinci olarak liman tek başına değerlendirilerek 1992-2008 yıllarına ait verilerine parabolik eğilim ile zaman serileri analizi uygulanarak 2030 yılına kadar tahminler elde edilmiştir. Üçüncü olarak GSYH büyüme hızındaki değişime göre 2030 yılına kadar tahminler elde edilmiştir. Dördüncü olarak Avrupa Komisyonu tahminleri kullanılarak 2030 yılına kadar tahminler elde edilmiştir. Son olarak ise dış ticaret verileri bağımsız değişken, konteyner trafik verileri bağımlı değişken olacak şekilde regresyon analizi kullanılarak tahmin verileri elde edilmiştir. Uygulanan tüm yöntemler ile elde edilen tahmin değerlerin ortalaması alınmıştır. Sonuçlara göre limanın pazar talebinin terminalin mevcut kapasitesinin çok üzerinde olduğu sonucuna varılmıştır.

Gosasang ve ark. (2011), mevcut literatürü inceleyerek zaman serileri ve regresyon analizi olmak üzere iki çeşit yöntem ile konteyner hacim tahminlerine ait çalışmalar bulunduğunu tespit etmiştir. Çalışmalarında bir limanda ÇKA (Çok Katmanlı Algılayıcı) ve liner regresyon ile gelecek konteyner hacmini tahmin etmişlerdir. Bağımlı ve bağımsız faktör seçimleri mevcut çalışmalar içerisinde seçilmiştir. Limandaki 1999-2010 arası veriler kullanılmıştır. Öncelikle kargo hacmimi etkileyen faktörler tanımlanmış, sonrasında veriler toplanmıştır. Bağımlı faktör olarak konteyner sayısı, ithal edilen ve ihraç edilen konteyner hacimleri kullanılmıştır. Bağımsız faktör olarak GSYH, döviz kuru, nüfus, enflasyon oranı, faiz oranı ve yakıt fiyatı kullanılmıştır. Tahmin performanslarını karşılaştırılmasında OMH ve OKHK kullanılmıştır. İki yöntemle yapılan tahmin sonuçları karşılaştırıldığında ÇKA'nın daha etkili bir tahmin yöntemi olduğu sonucuna varılmıştır.

Xie ve ark. (2013), limanlardaki konteyner hacim tahmini için üç farklı yaklaşım kullanmıştır. Ocak 2001-Aralık 2012 arası aylık veriler (her limandan toplam 140 gözlem) toplanmıştır. Kullanılan yaklaşımların performanslarını karşılaştırmak için OKHK, HO (Hareketli Ortalama) ve OMYH değerleri hesaplanmıştır. Ayrıca farklı yaklaşımların istatistiksel önem derecesini ölçmek için DM (Diebold-Mariano) testi yapılmıştır. Model uygulamaları için EVIEWS ve MATLAB yazılım paketinde, DM testi R yazılım paketinde uygulanmıştır. Uygulanan EKDVM (En Küçük Kareler Destek Vektör Makinesi) modeli her liman için toplam 119 gözlem içeren deneme verisi ile Gaussian, Linear ve Polynomial olmak üzere üç farklı tip çekirdek fonksiyonunda uygulanmış olup performanslar karşılaştırıldığında en iyi sonucu Gaussian çekirdek fonksiyonun verdiği görülmüştür. Yapılan tahmin sonuçları karşılaştırıldığında önerilen yaklaşımların konteyner hacim tahmininde daha iyi sonuçlar verdiği görülmüştür.

Park ve Yoon (2014), bir limandaki genel kargo yükleri için rıhtım kapasitesini değerlendirmiştir. Değerlendirme yönteminde kapasite, rıhtım başına tek tip malzeme elleçleyen özel rıhtım kapasitesi ve rıhtım başına ikiden fazla çeşit malzeme elleçleyen genel kargo rıhtım kapasitesi olmak üzere ikiye ayrılmıştır. Özel rıhtım kapasitesi için yıllık elleçleme kapasitesi, rıhtım sayısı, elleçleme ekipmanı sayısı, elleçleme ekipmanı saatlik kapasitesi, kargo doluluk oranı (aynı rıhtımda ikiden fazla çeşit malzeme elleçleniyorsa), ekipman verimlilik oranı, günlük çalışma saati, yıllık çalışılan gün sayısı, rıhtım doluluk oranı ve makine kullanım oranı çarpımı ile hesaplanmıştır. Önerilen yeni yöntemde geleneksel yöntemde her rıhtıma ait kargo tipi oranı, rıhtım gemi boyutu oranı ve kargo tipi ve gemi boyutuna ait elleçleme kapasitesi eklenmiştir. Çalışma sonuçları geleneksel değerlendirme yönteminin gerçek durumu yansıtmadığını göstermiştir. Beş farklı limanda uygulanan geleneksel yöntem ve yeni yöntem karşılaştırıldığında yeni yöntemin daha uygulanabilir ve etkili olduğu görülmüştür.

Layaa ve Dullaert (2014), liman terminallerinde kapasite kullanımını ölçmek için standart kuyruk modelleri kullanmıştır. Sonuçların kapasite kullanımı hakkında faydalı bilgiler verdiği görülmüştür. Liman çıkış verileri, yıllık gemi girişleri, bekleme süreleri, genel kargo ve konteyner terminalleri için rıhtım doluluk seviyesi ve hizmet süresi verileri 1992-2009 dönemine ait veriler Tanzanya Limanları Kurumu'ndan toplanmıştır. Temel performans göstergeleri için M/M/K kuyruk modeli tasarlanmıştır. Modeli oluşturmak

için gemilerin varış oranları, hizmet oranları ve rıhtım sayısı girdi değişkeni olarak kullanılmıştır. Genel kargo terminalleri için gözlenen değerler ve kuyruk modeli ile hesaplanan değerler karşılaştırıldığında 1995, 2004 ve 2005 yılları dışında aynı ortalama varış oranı ve ortalama servis oranı ile model ile hesaplanan ortalama bekleme süresi gözlenen bekleme süresinden her zaman daha az çıkmıştır. Konteyner terminalleri için gözlenen ve modelin tahmin değerleri karşılaştırıldığında aynı ortalama varış oranı ve servis oranı için gözlenen ortalama bekleme süresinin çok uzun olduğu görülmüştür. Ek olarak 2006 ve 2007 yılları dışında gözlenen rıhtım doluluk seviyesinin daha yüksek olduğu görülmüştür. Sonuçlar genel olarak değerlendirildiğinde bekleme süreleri için gözlenen değerlerin model sonuçlarından daha yüksek olduğunu düşük servis seviyelerinde her iki terminal için kapasite kullanımının az olduğunu göstermiştir.

Akar ve Esmer (2015), Türkiye'deki konteyner limanlarının 2023 yılına kadar artan talebi karşılayacak kapasiteye sahip olup olmadıklarını analiz etmiştir. Regresyon analizi ile yapılan tahmin sonuçları ve konteyner limanlarının kapasiteleri karşılaştırılmıştır. 2015-2023 yılları konteyner yük talebini tahmin etmek için çoklu regresyon analizi kullanılmıştır. Modelde bağımlı değişken olarak konteyner yük miktarı, bağımsız değişken olarak toplam ithalat ve ihracat miktarı, popülasyon ve GSYH kullanılmıştır. Sonuçlara bakıldığında 2015-2023 yıllarında konteyner elleçleme miktarındaki sürekli bir artış olacağı gözlenmiştir. Elde edilen tahminler Türklim (Türkiye Liman İşletmecileri Derneği)'den alınan Türkiye'deki konteyner limanlarının kapasite verileri ile karşılaştırılmıştır. Elde edilen tahmin değerlerine göre Türkiye'nin tahmin edilen yük miktarını elleçleyecek kapasiteye sahip olduğu gözlenmiştir.


Twrdy ve Batista (2016), kuzey Adriyatik limanlarda konteyner hacmi tahmini için dinamik tahmin modelleri sunmuştur. Tahminler Markov zinciri yıllık büyüme oranı modeli, eğilim bileşeniyle zaman serisi modeli, bazı lineer dinamik süreçlerin sonucu olarak orijinal veri birikimini dikkate alan gri sistem modeli kullanılarak yapılmıştır. Tahmin sonrasında limanlar arası ilişkiler analiz edilmiştir. Veri seti olarak limanlardaki 1990-2013 arası yıllık konteyner hacimleri kullanılmıştır. Tahmin değerlerinin karşılaştırması için OMH, OMYH, OKHK hesaplanmıştır. Sonuç olarak en iyi tahmin değerlerini eğilim bileşenli zaman serisi modelinin verdiği görülmüştür.

Gökkuş ve ark. (2017), Türkiye limanlarının konteyner trafiğini tahmin etmiştir. GSYH, ihracat ve Türkiye nüfusunun geçmiş kayıtları sosyoekonomik göstergeler olarak kullanılarak farklı yaklaşımlara dayanan dört farklı yöntem ile tahmin yapılmıştır. Test verileri ile 2023 yılına kadar olan trafik verileri tahmin edilmiştir. Tahmin modellerinin performansları çeşitli performans ölçütleri ile değerlendirilmiştir. Çıktı değişkeni olarak Türkiye'deki üç farklı limana ait 1989-2015 yılları konteyner trafik verileri, girdi değişkeni olarak yıllık GSYH, popülasyon ve ihracat değerleri kullanılmıştır. Popülasyon ve GSYH verileri TÜİK (Türkiye İstatistik Kurumu) veritabanından, ihracat verileri ise IMF (International Monetary Fund) verilerinden derlenmiştir. Tahmin modellerinin performansı için OKHK ve OMYH değerleri karşılaştırılmıştır. Sonuçlara bakıldığında EKDVM modelinin diğer yöntemlere göre daha gerçekçi sonuçlar verdiği gözlemlenmiştir.

Nanda ve ark. (2018), ahşap ürünlerin kalitesini önemli ölçüde etkileyen termit (bir böcek türü) saldırılarını önlemek için bir yöntem önermiştir. Çalışma için bir ağaca 220 yeraltı termiti yerleştirilmiş ve sinyalleri izlenmiştir. Termitler ve arka plan gürültüsü tarafından üretilen sinyalleri ayırma sorununu çözmek için güvenilir bir sınıflandırma modeli oluşturulması amacıyla DVM algoritması uygulanmıştır. Termit algılama sistem performansında en iyi sonucu elde etmek için DVM algoritmasında kullanılan doğrusal, RTF (Radyal Temelli Fonksiyon), sigmoid ve polinom fonksiyonları karşılaştırılmıştır. Her bir çekirdek fonksiyonu, en iyi performansı elde etmek için optimize edilmesi gereken özel bir parametreye sahiptir. Çekirdek fonksiyonundaki parametreleri ayarlamak için grid arama yöntemi kullanılmış olup üst ve alt sınırlar için arama bölgesi uygun değerleri $C (2^{-15}, 2^{-14}, \dots, 2^2)$, $\gamma (2^{-10}, 2^{-9}, \dots, 2^2)$, $r (2^{-10}, 2^{-9}, \dots, 2^2)$ ve $d (0, 1, 2, 3)$ şeklinde belirlenmiştir. Eğitim veri setinde 10 kat çapraz doğrulama kullanılmıştır. Sınıflandırma modellerinin performansını değerlendirmek için AIK (Alıcı İşlem Karakteristiği) kullanılmıştır. Deneysel, R studio yazılımında e1071 paketi ile tamamlanmıştır. Performans sonuçlarını karşılaştırmak için kullanılan AIK eğrisinin altındaki alan EAA (Eğri Altındaki Alan) değeri ne kadar yüksek olursa, sınıflandırma modeli o kadar iyi olacağından sayısal analizler, diğer çekirdek fonksiyonları ile karşılaştırıldığında polinom çekirdek fonksiyonlu DVM algoritmasının en yüksek EAA değeri ile en iyi sınıflandırma doğruluğunu sağladığını göstermiştir.

3. MATERYAL VE YÖNTEM

Bu çalışmada, Türkiye'deki bir liman işletmesinin talep tahmini problemi için farklı yöntemler karşılaştırılmış ve elde edilen sonular kullanılarak limanın rıhtım kapasitesinin gelecek talebi karşılayıp karşılayamayacağı analiz edilmiştir. Çalışma için izlenen adımlar Şekil 3.1'de gösterilmektedir.



Şekil 3.1. Çalışma adımlarını gösteren akış şeması

3.1. Zaman Serisi Yöntemleri

Basit Üstel Düzeltme Yöntemi

En basit üstel düzeltme yöntemi, yalnızca bir parametrenin tahmin edilmesi gereken BÜD (Basit Üstel Düzeltme) yöntemidir. Bu yöntem, verilerde eğilim, mevsimsel ya da farklı bir bileşen bulunmadığı durumlar için uygundur. Gelecek döneme ait tahminler,

$$F_{t+1} = F_t + \alpha(Y_t - F_t)$$

eşitliği kullanılarak hesaplanır. Eşitlikte yer alan t zaman periyodunu, α ise (0,1) aralığındaki düzeltme faktörünü göstermektedir. Y_t , t zamanında gözlenen değer, F_t ise t zamanındaki tahmin değerini temsil etmektedir (Makridakis ve ark. 1998).

Holt'un Doğrusal Yöntemi

Holt yöntemi, eğilim içeren zaman serisi verileri için tahmin yapılmasında kullanışlıdır. Tek üstel düzeltme yöntemindeki seviye düzeltme parametresine ek olarak eğilim için bir düzeltme parametresi daha içerir. Seviye ve trend düzeltme parametreleri için t zamanındaki tahmin değerleri olan L_t ve b_t hesaplaması için

$$L_t = \alpha Y_t + (1 - \alpha)(L_{t-1} - b_{t-1})$$

$$b_t = \beta(L_t - L_{t-1}) + (1 - \beta)b_{t-1}$$

eşitlikleri kullanılır. β trend için (0,1) aralığındaki düzeltme faktörüdür. t zamanındaki tahmin değeri için ise

$$F_{t+m} = L_t + b_t m$$

eşitliği kullanılır. Seviye tahmini için başlangıç değeri $L_1 = Y_1$ ve trend tahmini için başlangıç değeri $b_1 = Y_2 - Y_1$ olarak alınır (Makridakis ve ark. 1998).

Holt-Winters Yöntemi

HW (Holt-Winters) yöntemi verilerin mevsimsellik gösterdiği durumlarda kullanılır. Holt metoduna ek olarak mevsimsellik için bir düzeltme parametresi daha içerir. α , β ve γ sırasıyla seviye, trend ve mevsimsellik için düzeltme parametrelerini temsil etmektedir. L_t , b_t , S_t sırasıyla seviye, trend ve mevsimsellik için t zamanındaki tahmin değerlerini göstermektedir. s sezon sayısı, m tahmin edilecek dönem sayısı, Y_t ise t zamanındaki gözlem değeridir (Makridakis ve ark. 1998).

ÇHW (Çarpımsal Holt-Winters) ve THW (Toplamsal Holt-Winters) olmak üzere iki ayrı başlık altında incelenebilir. ÇHW yöntemi

$$L_t = \alpha \left(\frac{Y_t}{S_{t-s}} \right) + (1 - \alpha)(L_{t-1} + b_{t-1})$$

$$b_t = \beta(L_t - L_{t-1}) + (1 - \beta)b_{t-1}$$

$$S_t = \gamma \left(\frac{Y_t}{L_t} \right) + (1 - \gamma)S_{t-s}$$

$$F_{t+m} = (L_t + b_t m)S_{t-s+m}$$

eşitlikleri ile hesaplanır. THW yöntemi için de

$$L_t = \alpha(Y_t - S_{t-s}) + (1 - \alpha)(L_{t-1} + b_{t-1})$$

$$b_t = \beta(L_t - L_{t-1}) + (1 - \beta)b_{t-1}$$

$$S_t = \gamma(Y_t - L_t) + (1 - \gamma)S_{t-s}$$

$$F_{t+m} = L_t + b_t m + S_{t-s+m}$$

eşitlikleri kullanılır. Her iki yöntem için seviye, trend ve mevsimsellik düzeltme parametreleri tahmini başlangıç değerleri aşağıdaki eşitlikler kullanılarak hesaplanır.

$$L_s = \frac{Y_1 + Y_2 + \dots + Y_s}{s}$$

$$b_s = \frac{Y_{s+1} - Y_1 + Y_{s+2} - Y_2 + \dots + Y_{2s} - Y_s}{s^2}$$

$$S_p = Y_p / L_s, \quad p = 1, 2, \dots, s$$

3.2. Regresyon Analizi Yöntemleri

Basit Doğrusal Regresyon Yöntemi

Basit doğrusal regresyon bağımsız bir değişken ile bağımlı bir değişken arasındaki ilişkiyi açıklamak için kullanılır. Y bağımlı değişken x bağımsız değişken, olmak üzere değişkenler arasındaki doğrusal ilişkiyi açıklayan regresyon modeli ve tahmin modeline ait eşitlikler aşağıdaki gibidir. Eşitliklerde yer alan \hat{y} tahmin modeline ait bağımlı değişkeni, α ve β regresyon katsayılarını, a ve b ise bu katsayıların tahmin değerlerini ifade etmektedir (Walpole ve ark 2007).

$$Y = \alpha + \beta x$$

$$\hat{y} = a + bx$$

Çoklu Doğrusal Regresyon Yöntemi

İki veya daha fazla bağımsız değişkenin bulunduğu durumlarda tahmin için en çok kullanılan yöntemdir. x_1, x_2, \dots, x_k gibi k adet bağımsız değişkenin Y bağımlı değişkeni ile olan ilişkisini açıklayan çoklu regresyon modeli ve tahmin modeli aşağıdaki gibidir (Walpole ve ark 2007).

$$Y = \beta_0 + \beta_1 x_1 + \dots + \beta_k x_k$$

$$\hat{y} = b_0 + b_1 x_1 + \dots + b_k x_k$$

Çoklu Doğrusal Bağlantı İçin Varyans Artırıcı Faktör Yaklaşımı

Çoklu doğrusal bağlantı bağımsız değişkenler arasında güçlü ilişki olması anlamına gelmektedir. Çoklu doğrusal bağlantı olması durumunda modelden çıkarılması gereken değişkenlerin belirlenmesinde VAF (Varyans Artırıcı Faktör) kullanılabilir (Albayrak 2005).

ARIMA

ARIMA(p, d, q) modeli durağan olmayan zaman serisi verilerine uygulanır. Makridakis ve ark. (1998) içerisinde de belirtildiği gibi modelde yer alan p otoregresif modelin derecesi, q hareketli ortalama modelinin derecesi, d ise fark alma derecesidir.

3.3. Makine Öğrenme Yöntemleri

Makine Öğrenmesi, yapay zekanın bir alt alanı olarak kabul edilir ve bilgisayarın öğrenmesini sağlayan teknik ve yöntemlerin geliştirilmesiyle ilgilidir. Zaman içerisinde, makine öğrenmesi için birçok teknik ve yöntem geliştirilmiştir (Jakkula 2012).

Tahmin gibi görevlerin gerçekleştirilmesini sağlamak için makinelerin öğrenmesini sağlayacak bilgisayar programları yazılmaktadır. Öğrenmenin amacı girdi alan bir model oluşturularak istenen sonucun üretilmesidir. Makine öğrenmesi için Gözetimli Öğrenme ve Gözetimsiz Öğrenme teknikleri kullanılır (Mohammed ve ark. 2016).


Gözetimli öğrenmede eğitim verileri etiket olarak adlandırılan çözümleri içerir. Çıktı vektörü, eğitim verilerinde mevcut olan her bir eğitim örneği için etiketlerden oluşur. Çıktı vektör etiketleri danışman tarafından sağlanır. Danışmanlar genellikle insanlardır, ancak etiketlemeler için makineler de kullanılabilir. En yaygın gözetimli öğrenme algoritmaları sınıflandırma ve regresyon olmak üzere iki gruba ayrılabilir. En çok kullanılan gözetimli öğrenme algoritmaları ise k-en yakın komşu kestirimi, doğrusal regresyon, lojistik regresyon, destek vektör makineleri, karar ağaçları, rasgele ormanlar ve yapay sinir ağlarıdır. Gözetimsiz öğrenmede verilerde etiket bulunmamaktadır. Ana fikir herhangi bir sebeple etiketi bulunmayan verilerdeki gizlenmiş yapıyı bulmak ve bir sonuç elde edebilmektir. En yaygın kullanılan algoritma ise öbeklemedir.

DVM, Destek Vektör Sınıflandırma (DVS) ve Destek Vektör Regresyon (DVR) olmak üzere iki ana kategori içerir. DVM yüksek boyutlu bir özellik alanı kullanan bir öğrenme sistemidir. Destek vektörlerin alt kümesi üzerinde genişletilmiş olan tahmin fonksiyonlarını verir. Benzer şekilde, DVR tarafından üretilen model yalnızca eğitim verilerinin alt kümesine bağlıdır. DVR, DVM yöntemleri içerisinde en yaygın kullanılanıdır (Smola ve Schölkopf 2004, Basak ve ark. 2007).

DVM literatürüne bakıldığında *nitelik* olarak adlandırılan bir tahmin değişkeni, hiper düzlemi tanımlamak için kullanılan ve *özellik* olarak adlandırılan dönüştürülmüş bir nitelik, bir durumu tanımlayan *vektör* isimli bir dizi özellik bulunmaktadır. Amaç, hedef değişkenin bir kategoriye ait durumları düzlemin bir tarafında, diğer kategoriye ait durumları düzlemin diğer tarafında olacak şekilde vektör kümelerini ayıran en uygun hiper düzlemi bulmaktır. Hiper düzleme yakın olan vektörler destek vektörü olarak adlandırılır (Ayodele 2010).

DVM, tüm olası hiper düzlemler arasından destek vektörleri arasındaki mesafenin mümkün olduğunca en fazla olanını seçer. Matematiksel hesaplamalar için aşağıdaki eşitlikler kullanılır. w çoklu düzlemin normal bir vektörü, b görelî alanın koordinat merkezine konumu, $i \in (1, \dots, \ell)$ olmak üzere (x_i, y_i) eğitim seti olarak tanımlanır (Jakkula 2012, Nanda ve ark. 2018).

$$\begin{aligned} wx_i + b &\geq 1, & Y_i &= +1 \\ wx_i + b &\leq -1, & Y_i &= -1 \\ y_i(wx_i + b) &\geq 1, & \forall i & \end{aligned}$$



Şekil 3.2. Hiper düzlemlerin gösterimi (Jakkula 2012)

Deneme verisi $\{(x_1, y_1), \dots, (x_l, y_l)\} \subset \mathfrak{X} \times \mathbb{R}$ olmak üzere lineer fonksiyon f aşağıdaki şekilde yazılır. \mathfrak{X} giriş desenlerinin alanını göstermektedir. (Örnek: $\mathfrak{X} = \mathbb{R}^d$)

$$f(x) = \langle w, x \rangle + b \quad w \in \mathfrak{X}, b \in \mathbb{R}$$

Lineer fonksiyonda yer alan $\langle \cdot, \cdot \rangle$, \mathfrak{X} içerisindeki bir noktayı ifade etmektedir. En küçük w 'yi elde etmek için Öklid normlarını minimize etmek gereklidir. ε gerçek değerlerden sapma miktarı, ℓ deneme verisi boyutu ve $i \in (1, \dots, \ell)$ olmak üzere minimizasyon için konveks optimizasyon modeli aşağıdaki şekilde yazılabilir.

$$\begin{cases} \min & \frac{1}{2} \|w\|^2 \\ & y_i - \langle w, x_i \rangle - b \leq \varepsilon \\ & \langle w, x_i \rangle + b - y_i \leq \varepsilon \end{cases}$$

Yukarıdaki yaklaşımı hatalara izin vermek istediğimiz durumlarda kullanmak mümkün olmadığı için bu tarz durumlarla başa çıkabilmek adına C sabiti gözlemlere uygulanan ceza olmak üzere ξ_i, ξ_i^* aylak değişkenleri ile birlikte optimizasyon problemi ve kısıtları aşağıdaki şekilde ifade edilebilir.

$$\begin{cases} \min & \frac{1}{2} \|w\|^2 + C \sum_{i=1}^n (\xi_i + \xi_i^*) \\ & y_i - \langle w, x_i \rangle - b \leq \varepsilon + \xi_i \\ & \langle w, x_i \rangle + b - y_i \leq \varepsilon + \xi_i^* \\ & \xi_i, \xi_i^* \geq 0 \end{cases}$$

Lagrange çarpanları $\alpha_i, \alpha_i^* \geq 0$ olmak üzere dual optimizasyon modeli aşağıdaki şekilde yazılır.

$$\begin{cases} \max & -\frac{1}{2} \sum_{i,j=1}^{\ell} (\alpha_i - \alpha_i^*)(\alpha_j - \alpha_j^*) \langle x_i, x_j \rangle - \varepsilon \sum_{i=1}^{\ell} (\alpha_i + \alpha_i^*) + \sum_{i=1}^{\ell} y_i (\alpha_i - \alpha_i^*) \\ & \sum_{i=1}^{\ell} (\alpha_i - \alpha_i^*) = 0, \quad \alpha_i, \alpha_i^* \in [0, C] \end{cases}$$

Destek vektör açılımı aşağıdaki şekilde ifade edilir. w , x_i eğitim desenlerinin lineer kombinasyonu olarak ifade edilebilir.

$$w = \sum_{i=1}^l (\alpha_i - \alpha_i^*) x_i$$

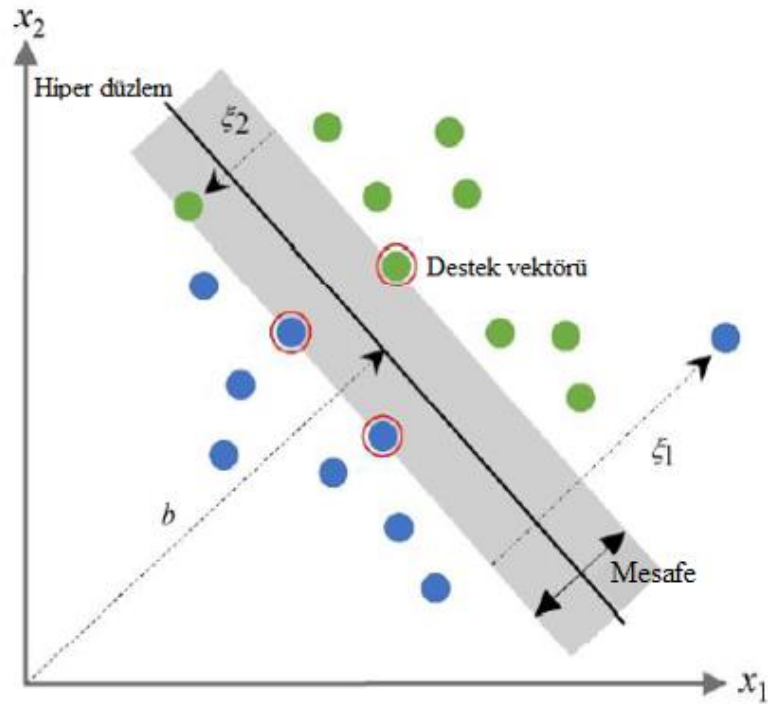
$$f(x) = (\alpha_i - \alpha_i^*) \langle w, x \rangle + b$$

$\alpha_i^* \in (0, C)$, $\xi_i = 0$ olmak üzere b 'nin hesaplaması için aşağıdaki eşitlikler kullanılır.

$$b = y_i - \langle w, x_i \rangle - \varepsilon, \quad \alpha_i \in [0, C]$$

$$b = y_i - \langle w, x_i \rangle + \varepsilon, \quad \alpha_i^* \in [0, C]$$


Verileri ayıran birçok hiper düzlem vardır. Ancak bunlardan sadece bir tanesi maksimum ayrılma sağlamaktadır. DVM'nin amacı, verileri hiper düzlemlerle ayırmak ve bunu çekirdek yöntemleri kullanarak doğrusal olmayan sınırlara genişletmektir.



Şekil 3.3. Doğrusal ayrılabilebilir verilerde optimum hiper düzlemi belirlemek için DVM gösterimi (Nanda ve ark. 2018)

Çekirdek Yöntemi

Veriler doğrusal ise, verileri bölmek için ayırıcı bir hiper düzlem kullanılabilir. Bununla birlikte, genellikle verilerin doğrusal olmadığı ve veri kümelerinin ayrıştırılmadığı durumlar söz konusudur. Çekirdek, girdi verilerini yüksek boyutlu bir uzaya doğrusal olmayan bir şekilde eşlemek için kullanılır. Çekirdek yöntemleri, DVM'lerinin doğrusal olmayan sınırlar oluşturmasına olanak sağlar (Jakkula 2012).



Şekil 3.4. Çekirdek fonksiyonu ile verilerin doğrusal olarak ayrılması (Jakkula 2012)

Çekirdek Fonksiyonları

Çekirdek fonksiyonu, DVM performansında kritik bir rol oynamaktadır ve iç çarpım yapısına sahip soyut bir vektör uzayı olan Hilbert uzaylarının çoğaltılmasına dayanmaktadır.

DV algoritması \mathfrak{H} özellik uzayını göstermek üzere x_i eğitim desenleri $\phi: X \rightarrow \mathfrak{H}$ ile önceden işlenerek ve sonrasında DVR algoritması uygulanarak doğrusal olmayan yapıya getirilebilir. Çekirdek fonksiyonu nokta ürünlü dönüşüm fonksiyonu ile orijinal veri alanını daha yüksek boyutlu yeni bir alana dönüştürür. Hedef zaten daha yüksek bir boyuta dönüştürülmüş olan verinin kolayca ayrılmasını sağlamaktır. Doğrusal olmayan eşlemenin doğrusal nokta ürünü olarak tanımlanan $k(x_i, x)$ çekirdek fonksiyonu aşağıdaki eşitlikle ifade edilir.

$$k(x_i, x) = \phi(x_i)\phi(x)$$

w ve regresyon tahmininde kullanılacak olan $f(x)$ ise aşağıdaki eşitliklere dönüşür.

$$w = \sum_{i=1}^l (\alpha_i - \alpha_i^*) \phi(x_i)$$
$$f(x) = \sum_{i=1}^l (\alpha_i - \alpha_i^*) k(x_i, x) + b$$

Her bir çekirdek fonksiyonu, en iyi performansı elde etmek için optimize edilmesi gereken belirli bir parametreye sahiptir. Bu parametrelere ait en iyi değerlerin bulunması için modelin oluşturulmasında minimum hatayı temel alan, belirlenen bir bölgede parametrelerin kombinasyonlarını arayarak çalışan grid-arama yöntemi kullanılabilir. Aşağıda DVM algoritması tarafından kullanılan çeşitli çekirdek fonksiyonları sunulmuştur (Nanda ve ark. 2018).

Linear: Bu fonksiyonda optimize edilmesi gereken parametreler C ve γ dir.

$$k(x, x') = \langle x, x' \rangle$$

Polynomial: Bu fonksiyonda optimize edilmesi gereken parametreler C , γ , r ve d 'dir.

$$k(x, x') = \langle x, x' \rangle^d$$

$$k(x, x') = (\gamma \langle x, x' \rangle + r)^d$$

Gaussian Radial Basis Function: Bu fonksiyonda optimize edilmesi gereken parametreler C ve γ dir.

$$k(x, x') = \exp(-\gamma \|x - x'\|^2 + C)$$


Sigmoid: Bu fonksiyonda optimize edilmesi gereken parametreler C , γ ve r 'dir.

$$k(x, x') = \tanh(\gamma \langle x, x' \rangle + r)$$

Yukarıdaki formüllerde optimize edilen C maliyet, γ gamma, r katsayı, d dereceyi ifade etmektedir. Gaussian ve polinom çekirdek fonksiyonu standart olarak kullanılan seçeneklerdir. Ancak etkisiz kalmaları ya da girdilerin ayrık yapılar olması durumunda daha ayrıntılı çekirdeklere ihtiyaç duyulmaktadır.

Veri Ön İşleme

Kurulan modelin performansı değerlendirilirken güvenilir bir hata tahmini için veri setinin alt kümelerle bölünmesi gerekir. Bağımsız veri kümelerinin mevcut olduğu durumda eğitim, model seçimi ve tahmin performansı için farklı kümeler kullanılabilir. Bu durumda veri setinin bölünmesine gerek olmaz. Ancak tek bir veri setinin mevcut olduğu durumda bağımsız veri kümeleri elde etmek için veri setini bölecek bazı stratejiler gerekir. Veri seti iki (eğitim, test) ya da üç (eğitim, doğrulama, test) parçaya bölünebilir.



Şekil 3.5. Veriyi iki ve üç parçaya bölme

Eğitim seti: Modelin parametrelerini öğrenmek ve tahmin etmek için kullanılır.

Doğrulama seti: Modeli değerlendirmek ve model seçimi için kullanılır.

Test seti: Modelin performansını değerlendirmek için kullanılır.

Veri bölme için en yaygın kullanılan strateji veriyi eğitim ve test seti olmak üzere iki parçaya bölmektir.

Makine öğrenme algoritmalarında modelin performansını doğru şekilde değerlendirmek için yeniden örnekleme yöntemleri kullanılır. En yaygın kullanılan yeniden örnekleme yöntemi çapraz doğrulamadır. Çapraz doğrulamada en yaygın kullanılan yöntemler K-kat çapraz doğrulama ve “birini dışarıda bırakma” çapraz doğrulamasıdır.

K-kat çapraz doğrulamada veri seti aynı büyüklükteki k adet parçaya bölünür. Veri setinde bir kısım test için kullanılırken kalan diğer kısımları eğitim için kullanılır. Bu işlem k kez tekrarlanır (Reitermanová 2010, Borovicka ve ark. 2012).

Birini dışarıda bırakma çapraz doğrulaması verilerin en iyi şekilde kullanılmasını sağlar. Bu yöntemde k veri seti büyüklüğüdür. Test için her seferinde bir birim veri kullanılırken kalan k-1 birim ise eğitim için kullanılır (Borovicka ve ark. 2012).

Zamana bağlı problemler için bu çapraz doğrulama yöntemlerinin, modeli eğitmek için kullanılan verilerden daha eski bir veri kümesiyle test yapılması ve kullanılan veri kümesi arasındaki zaman farkları gibi bazı dezavantajları vardır. Bu etkileri azaltmak için Hota ve ark. (2017)'de hareketli pencere yaklaşımı (moving window approach) önerilmiştir.

Bu yaklaşım zaman serisi verisinin gerçek değeri üzerinden kullanılan geçici bir yaklaşım olup bir penceredeki veriler modeli eğitmek, doğrulamak ve test etme için kullanıldıktan sonra bir sonraki pencere kullanılır. Pencere ve segment boyutu en az hataya ulaşana kadar artar. İlk segment seçildikten sonra ilk segmentin bitiminden başlayacak şekilde sonraki segment seçilir. Bu işlem tüm veri seti bir segment oluşturana kadar tekrarlanır.



Şekil 3.6. Hareketli pencere süreci

3.4. Kapasite Hesaplama Yöntemi

Çalışmada yapılan operasyonlar için gerekli olacak rıhtım kapasitenin hesaplamasında gelecek gemi sayısı, gemilerin ortalama rıhtımda kalış süresi, operasyon için kullanılan ortalama rıhtım sayısı ve gemi başına yük miktarı dikkate alınmıştır. Her bir operasyon türü için tahmin edilen yük miktarına göre gerekli olacak kapasitenin hesaplanmasında aşağıdaki eşitlikler kullanılmıştır.

$$V_i = C_i / P_i \quad (3.1)$$

$$Y_i = V_i * T_i * O_i \quad (3.2)$$

i : 1, 2, 3 (Operasyon türü sayısı (genel kargo, konteyner, araç))

V_i : i operasyon türü için gelecek gemi sayısı

C_i : Elleçlenen yük miktarı (tahmin)

P_i : Gemi başına yük miktarı

Y_i : Fiili kapasite

T_i : Ortalama rıhtımda kalış süresi

O_i : i operasyon türü için gemi başına kullanılan ortalama rıhtım sayısı

Mevcut kapasite hesaplanırken rıhtım sayısı, yıllık çalışılan gün sayısı ve günlük çalışma saati dikkate alınmıştır.

$$Z = B * D * H \quad (3.3)$$

Z: Mevcut kapasite

B: Rıhtım sayısı

D: Yıllık çalışılan gün sayısı

H: Günlük çalışma saati

Rıhtım kapasitesi kullanım oranı için kullanılan eşitlik aşağıdaki gibidir.

$$KKO = \sum_{i=1}^n Y_i / Z, \quad i = 1,2,3 \quad (3.4)$$

KKO: Kapasite Kullanım Oranı

$\sum Y_i$: Toplam Fiili Kapasite (Her yük tipi için hesaplanan fiili kapasitelerin toplamı)

3.5. Veriler ve Parametreler

Çalışmada gelecek iki yıl için tahmin edilecek olan genel kargo, konteyner ve araç elleçleme hacimlerinin aylık verileri, Ocak 2012 ile Aralık 2017 arasındaki dönem için Türkiye'de bir limandan toplanmıştır (72 gözlem).

İstatistiksel tahmin yöntemlerinde, 72 aylık veri setinin tamamı kullanılmıştır. DVR yöntemi uygulamasında, veriler eğitim seti (ilk 5 yıl) ve test veri seti (son yıl) olarak iki gruba ayrılmıştır.

DVR algoritmasında model performansını doğru şekilde değerlendirebilmek için yeniden örnekleme yöntemi olarak Hota ve ark. (2017)'de önerilen hareketli pencere yaklaşımı kullanılmıştır. Verileri bireysel olarak eğitmek için doğrusal, polinom ve radyal temelli çekirdek yöntemleri uygulanmış ve karşılaştırılmıştır.

Çekirdek yöntemleri için gerekli olan hiper-parametreler C ve σ^2 için Mak ve Yang (2007) 'de önerilen şekilde $C \in \{2^{-3}, 2^{-2}, \dots, 2^0, \dots, 2^9\}$ ve $\sigma^2 \in \{2^{-5}, \dots, 2^0, \dots, 2^9\}$ kullanılmıştır. Polinom çekirdek yönteminde kullanılan derece parametresi için $d \in \{2, 3, 4, 5\}$ ve ölçü parametresi için $scale \in \{10^{-5}, 10^{-4}, \dots, 10^0, \dots, 10^5\}$ kullanılmıştır. Her fonksiyon için eğitim seti, tahmin için kullanıldıktan sonra tahmin edilen değerler test setindeki gerçek verilerle karşılaştırılmıştır. Gelecekteki değerleri tahmin etmek için düşük hataya sahip olan model seçilmiştir.

Limandan toplanan yük elleçleme hacmine ait veriler Çizelge 3.1'de verilmiştir. Limanın gizlilik politikası nedeniyle, tablolardaki verilere dönüşüm uygulanmıştır.

Çizelge 3.1. Tahmin yöntemlerinde kullanılan çıktı değişkenleri

| Yıl | Ay | Genel Kargo (Ton) | Konteyner (TEU) | Araç (Adet) | Yıl | Ay | Genel Kargo (Ton) | Konteyner (TEU) | Araç (Adet) |
|------|----|-------------------|-----------------|-------------|------|----|-------------------|-----------------|-------------|
| 2012 | 1 | 173921,00 | 12182,3 | 6187,35 | 2015 | 1 | 127138,41 | 11594,7 | 10648,95 |
| 2012 | 2 | 120551,94 | 8471,45 | 10182,3 | 2015 | 2 | 152927,59 | 9419,8 | 16443,7 |
| 2012 | 3 | 181563,62 | 9811,1 | 11063 | 2015 | 3 | 205145,35 | 10881,65 | 20375,55 |
| 2012 | 4 | 162171,24 | 8961,55 | 10396,1 | 2015 | 4 | 182817,98 | 12934,35 | 15479,1 |
| 2012 | 5 | 166516,03 | 10608 | 8380,45 | 2015 | 5 | 179776,42 | 14313,65 | 11419,2 |
| 2012 | 6 | 154416,70 | 10830,95 | 9525,1 | 2015 | 6 | 188224,31 | 12930,45 | 18243,55 |
| 2012 | 7 | 140598,25 | 10204,35 | 5796,7 | 2015 | 7 | 195835,06 | 10723,7 | 15103,4 |
| 2012 | 8 | 184395,29 | 10292,1 | 4317,3 | 2015 | 8 | 148931,58 | 12591,8 | 9896,9 |
| 2012 | 9 | 166383,81 | 10330,45 | 8671 | 2015 | 9 | 139461,13 | 13783,9 | 16075,8 |
| 2012 | 10 | 158389,44 | 10673 | 9456,85 | 2015 | 10 | 191816,03 | 12055,55 | 19778,2 |
| 2012 | 11 | 199489,29 | 10961,6 | 8599,5 | 2015 | 11 | 199383,86 | 12496,25 | 21039,2 |
| 2012 | 12 | 135982,81 | 9586,2 | 8103,55 | 2015 | 12 | 167828,30 | 12990,9 | 18733 |
| 2013 | 1 | 146049,01 | 11023,35 | 6073,6 | 2016 | 1 | 171603,94 | 11991,2 | 7527,65 |
| 2013 | 2 | 154535,92 | 9066,85 | 10326,6 | 2016 | 2 | 156358,18 | 10278,45 | 14647,75 |
| 2013 | 3 | 211676,28 | 11180,65 | 15547,4 | 2016 | 3 | 204132,41 | 14101,75 | 15959,45 |
| 2013 | 4 | 164533,60 | 10304,45 | 13740,4 | 2016 | 4 | 292970,91 | 14218,1 | 14105 |
| 2013 | 5 | 143055,43 | 12987,65 | 13822,3 | 2016 | 5 | 172556,96 | 12931,1 | 18708,3 |
| 2013 | 6 | 180032,49 | 12467 | 12879,8 | 2016 | 6 | 174783,56 | 16075,15 | 23000,25 |
| 2013 | 7 | 175108,78 | 13230,75 | 10691,2 | 2016 | 7 | 207243,50 | 11854,05 | 18476,9 |
| 2013 | 8 | 147455,58 | 12158,9 | 5912,4 | 2016 | 8 | 157337,46 | 15318,55 | 13510,9 |
| 2013 | 9 | 192864,37 | 12442,95 | 9159,15 | 2016 | 9 | 184285,92 | 12698,4 | 10887,5 |
| 2013 | 10 | 145347,40 | 11966,5 | 8703,5 | 2016 | 10 | 161445,20 | 14943,5 | 19162,65 |
| 2013 | 11 | 187517,67 | 12761,45 | 11687 | 2016 | 11 | 225984,19 | 13783,9 | 18515,9 |
| 2013 | 12 | 213221,32 | 12332,45 | 12062,1 | 2016 | 12 | 190181,55 | 13958,75 | 20623,85 |
| 2014 | 1 | 106917,28 | 13995,15 | 5666,7 | 2017 | 1 | 241316,04 | 12769,25 | 12708,8 |
| 2014 | 2 | 160088,05 | 10547,55 | 9340,5 | 2017 | 2 | 174615,35 | 9161,1 | 16521,05 |
| 2014 | 3 | 192645,31 | 12005,5 | 14888,9 | 2017 | 3 | 189018,22 | 15374,45 | 18566,6 |
| 2014 | 4 | 147980,55 | 12080,9 | 15505,8 | 2017 | 4 | 189873,45 | 13700,05 | 19734 |
| 2014 | 5 | 170704,01 | 13997,75 | 15330,9 | 2017 | 5 | 213999,18 | 11748,75 | 18811 |
| 2014 | 6 | 161507,29 | 13892,45 | 17084 | 2017 | 6 | 211054,56 | 13847,6 | 19383 |
| 2014 | 7 | 161070,77 | 12355,85 | 15271,8 | 2017 | 7 | 227774,56 | 12701,65 | 14216,15 |
| 2014 | 8 | 182299,76 | 11820,25 | 5172,7 | 2017 | 8 | 187170,53 | 13809,25 | 11969,75 |
| 2014 | 9 | 156111,68 | 10561,85 | 13446,6 | 2017 | 9 | 211018,05 | 12231,05 | 12110,8 |
| 2014 | 10 | 194104,82 | 11655,15 | 14606,2 | 2017 | 10 | 227835,30 | 13057,85 | 17642,3 |
| 2014 | 11 | 139594,43 | 12723,1 | 18120,7 | 2017 | 11 | 189684,02 | 12669,8 | 19934,85 |
| 2014 | 12 | 203769,89 | 11954,8 | 20352,8 | 2017 | 12 | 196135,52 | 16210,35 | 15466,1 |

Basit doğrusal regresyon analizinin uygulamasında bağımsız değişken olarak zaman (ay) verisi kullanılmıştır.

Çoklu doğrusal regresyon ve DVR yöntemleri için, Esmer ve Akar (2015)'e benzer şekilde Türkiye'nin GSYH, nüfus ve dış ticaret değerleri modele girdi değişkenleri olarak seçilmiştir. Çıktı değişkeni olarak yük elleçleme hacimleri kullanılmıştır.

GSYH için 2012-2016 yılları için fiili oranlar TÜİK'ten (Anonim 2018a), tahmin edilen oranlar ise 2017-2019 yılları için Dünya Bankası'ndan (Anonim 2018b) elde edilmiştir. Nüfusun gerçek ve öngörülen değerleri TÜİK'ten alınmıştır (Anonim 2018a). Dış ticaretin gerçek değerleri TÜİK, 2018-2019 yılları için öngörülen oranları OECD'den (Organisation for Economic Co-operation and Development) alınmıştır (Anonim 2018c).

Tahmin yöntemlerinde kullanılmak üzere GSYH ve nüfus yıllık verilerinin aylık verilere dönüştürülebilmesi için Ajao ve ark. (2012) tarafından önerildiği gibi üçüncü derece polinom interpolasyonu uygulanmıştır. Dış ticaretin öngörülen değerleri için tüm ayların değerlerinin eşit olduğu varsayılmış ve tüm aylar için yıllık veri ortalaması kullanılmıştır. Çizelge 3.2 değişkenlerin aylık veriye dönüştürülmek üzere interpolasyon uygulanacak yıllara ait değerlerini göstermektedir. Dış ticaret değerlerinin 2012-2017 yılları için aylık değerleri mevcuttur. Bu nedenle çizelgede aylık değer tahmini yapılacak yıllara ait değerler verilmiştir. Çizelge 3.3 ise bu değişkenlerin dönüşüm sonrası elde edilen aylık değerlerini göstermektedir.

Çizelge 3.2. İnterpolasyon için kullanılan yıllık girdi değişkenleri

| Yıl | GSYH (Trilyon) | Nüfus (Milyon) | Dış Ticaret (Milyar Dolar) |
|------|-------------------|-------------------|-------------------------------|
| 2012 | 117,6 | 75,60 | - |
| 2013 | 122,4 | 76,70 | - |
| 2014 | 126,1 | 77,70 | - |
| 2015 | 133,79 | 78,70 | - |
| 2016 | 138,07 | 79,80 | - |
| 2017 | 148,28 | 80,80 | - |
| 2018 | 154,95 | 81,80 | 433,28 |
| 2019 | 161,14 | 82,80 | 461,87 |

(x_0, y_0) ve (x_1, y_1) noktaları için polinom interpolasyon denklemi aşağıdaki gibidir. Çizelge 3.3'deki değerler bu denklem kullanılarak elde edilmiştir.

$$f_1(x) = \frac{x-x_1}{x_0-x_1} y_0 + \frac{x-x_0}{x_1-x_0} y_1 \quad (3.5)$$

Çizelge 3.3. İnterpolasyon sonrası elde edilen aylık girdi değişkenleri

| Yıl | Ay | GSYH | Nüfus | Dış Ticaret |
|------|----|--------|-------|-------------|
| 2018 | 1 | 149,49 | 80,97 | 36,10 |
| 2018 | 2 | 149,98 | 81,04 | 36,10 |
| 2018 | 3 | 150,47 | 81,12 | 36,10 |
| 2018 | 4 | 150,96 | 81,19 | 36,10 |
| 2018 | 5 | 151,45 | 81,26 | 36,10 |
| 2018 | 6 | 151,95 | 81,34 | 36,10 |
| 2018 | 7 | 152,44 | 81,41 | 36,10 |
| 2018 | 8 | 152,94 | 81,48 | 36,10 |
| 2018 | 9 | 153,44 | 81,56 | 36,10 |
| 2018 | 10 | 153,94 | 81,64 | 36,10 |
| 2018 | 11 | 154,44 | 81,72 | 36,10 |
| 2018 | 12 | 154,95 | 81,8 | 36,10 |
| 2019 | 1 | 155,45 | 81,87 | 38,48 |
| 2019 | 2 | 155,96 | 81,95 | 38,48 |
| 2019 | 3 | 156,47 | 82,04 | 38,48 |
| 2019 | 4 | 156,98 | 82,12 | 38,48 |
| 2019 | 5 | 157,49 | 82,20 | 38,48 |
| 2019 | 6 | 158,01 | 82,28 | 38,48 |
| 2019 | 7 | 158,53 | 82,37 | 38,48 |
| 2019 | 8 | 159,04 | 82,45 | 38,48 |
| 2019 | 9 | 159,56 | 82,54 | 38,48 |
| 2019 | 10 | 160,09 | 82,62 | 38,48 |
| 2019 | 11 | 160,61 | 82,71 | 38,48 |
| 2019 | 12 | 161,14 | 82,8 | 38,48 |

Uygulanan tüm tahmin yöntemlerinin performans karşılaştırması için OKHK, OMYH ve OMH performans ölçüleri uygulanmıştır. Performans belirlemede kullanılacak olan hata değerlerinin hesaplanmasında aşağıdaki eşitlikler kullanılmıştır. Eşitliklerde kullanılan t zaman, n veri sayısı, y_t gerçek veri ve \hat{y}_t tahmin verisi olmak üzere $e_t = y_t - \hat{y}_t$ gerçek veri ve tahmin verisi arasındaki farkı ifade etmektedir.

$$OKHK = \sqrt{\frac{1}{n} \sum_{t=1}^n e_t^2} \quad (3.6)$$

$$OMH = \frac{1}{n} \sum_{t=1}^n |e_t| \quad (3.7)$$

$$OMYH = \left(\frac{1}{n} \sum_{t=1}^n \left| \frac{e_t}{y_t} \right| \right) \times 100 \quad (3.8)$$

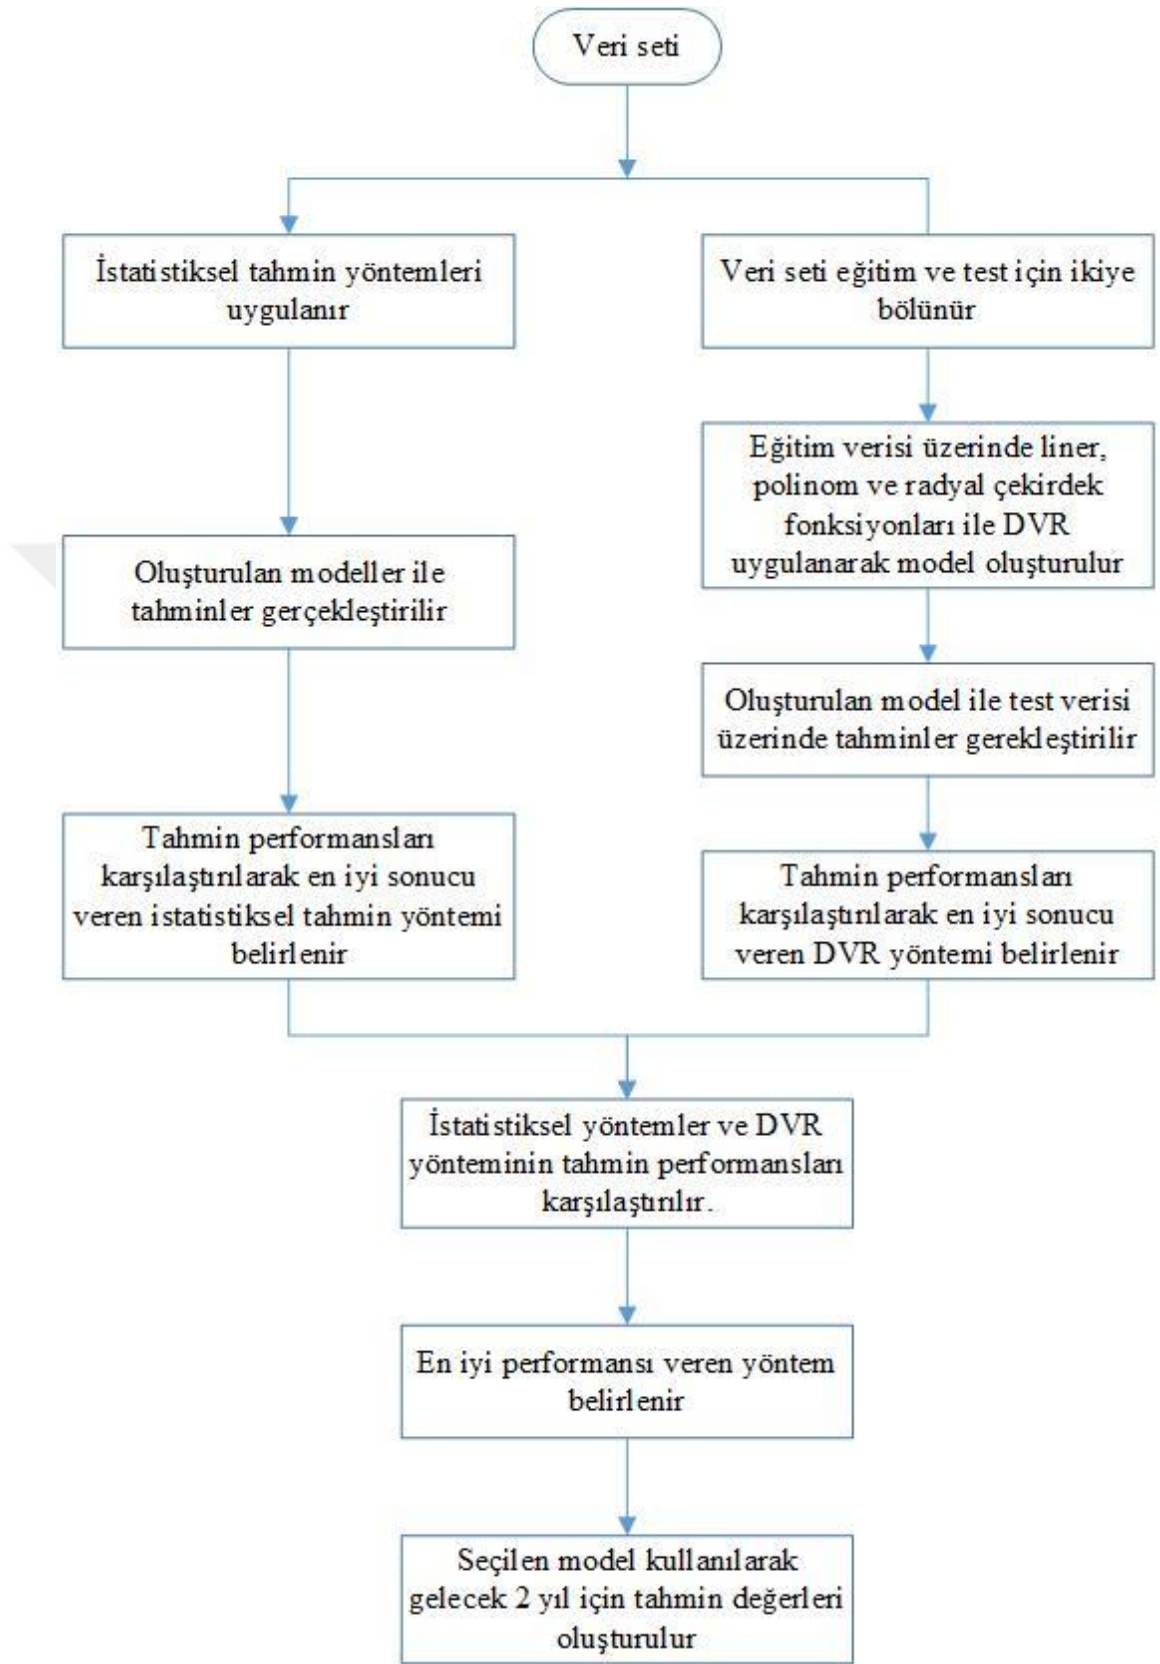
3.6. Tahmin Yöntemlerinin R Studio ile Uygulanması

Açıklanan tüm yöntemlerin uygulaması için R Studio kullanılmıştır. Kourentzes ve Petropoulos (2017)'de belirtildiği üzere R yalnızca tahminleme değil tüm istatistiksel analizler için kullanılabilecek güçlü bir araçtır.

Hyndman ve Khandakar (2008) de belirtildiği gibi istatistiksel talep tahmin yöntemlerinin uygulanması için *forecast* paketi kullanılmıştır. Üstel düzeltme yöntemleri ile yapılacak tahminler için bu pakette mevcut olan *ETS* fonksiyonu uygulanmıştır. ARIMA ile yapılacak olan tahminler için ise otomatik olarak parametreleri optimize ederek en küçük ABK (Akaike Bilgi Kriteri) değerine sahip olan modeli belirleme avantajına sahip olan *auto.arima* fonksiyonu uygulanmıştır.

İstatistiksel tahmin yöntemlerinin uygulanacağı veri setinin okunması ve üstel düzeltme yöntemleri için zaman serisi formatına dönüştürülmesine ait R script kodları EK 1'de verilmiştir. Tahmin yöntemlerinde kullanılan girdi değişkenlerinin yıllık verilerden aylık verilere dönüşümü için yapılan interpolasyon uygulamasına ait script dosyası EK 2'de verilmiştir. Genel kargo veri seti üzerinde üstel düzeltme yöntemleri, ARIMA ve basit doğrusal regresyon analizi için yapılan uygulamaya ait script dosyaları ve modellerin performans sonuçlarına ait çıktılar sırasıyla EK 3, EK 4 ve EK 5'de verilmiştir.

DVR yöntemi için, makine öğrenme algoritmalarını destekleyen *caret* paketi kullanılmıştır. Çapraz doğrulama tekniğinin uygulanması için, mevsimsellik gösteren veriler için uygun olan ve *caret* paketi tarafından desteklenen zaman dilimi yöntemi (*timeslice*) kullanılmıştır. Kuhn (2008)'de belirtildiği gibi *train* fonksiyonu yardımıyla grid-arama ile model için en iyi parametre değerleri belirlenerek yeniden örnekleme ile en iyi performansa sahip model seçimi yapılmıştır.



Şekil 3.7. Uygulanan işlemlere ait akış şeması

4. BULGULAR

4.1. Talep Tahmini Sonuçları

Bu bölümde 3. bölümde açıklanmış olan yöntemler kullanılarak elde edilmiş tahmin sonuçları ve performans karşılaştırmaları verilmiştir. Çizelge 4.1, Çizelge 4.2 ve Çizelge 4.3'de sırasıyla genel kargo, konteyner ve araç hacmi için uygulanan istatistiksel yöntemler ve en iyi sonucu veren DVR (Destek Vektör Regresyon) yöntemine ait tahmin sonuçları bulunmaktadır.

Çizelge 4.1. Genel kargo için uygulanan yöntemler ile elde edilen tahmin sonuçları

| Yıl | Ay | Toplamsal Holt-Winters | Çarpımsal Holt-Winters | ARIMA | Çoklu Doğrusal Regresyon | DVR (Lineer Çekirdek) |
|------|----|------------------------|------------------------|----------|--------------------------|-----------------------|
| 2018 | 1 | 186340,63 | 194965,87 | 212129,9 | 203455,72 | 187493,08 |
| 2018 | 2 | 187417,88 | 176339,47 | 211581,1 | 204018,55 | 187797,54 |
| 2018 | 3 | 228575,42 | 228813,52 | 210209,7 | 204586,91 | 188104,99 |
| 2018 | 4 | 223467,46 | 226931,05 | 210361,8 | 205160,60 | 188415,37 |
| 2018 | 5 | 204088,17 | 201737,70 | 211109,6 | 205739,82 | 188728,67 |
| 2018 | 6 | 211500,77 | 207473,89 | 211890 | 206324,43 | 189044,96 |
| 2018 | 7 | 212609,41 | 209574,95 | 212616,5 | 206914,43 | 189364,11 |
| 2018 | 8 | 200439,39 | 195418,08 | 213321,6 | 207509,96 | 189686,25 |
| 2018 | 9 | 204398,35 | 206929,06 | 214025,4 | 208110,89 | 190011,38 |
| 2018 | 10 | 207238,00 | 207212,13 | 214731,1 | 208717,21 | 190339,37 |
| 2018 | 11 | 227511,05 | 223722,33 | 215437,6 | 209329,05 | 190670,35 |
| 2018 | 12 | 219180,19 | 215535,12 | 216144,2 | 209946,29 | 191004,25 |
| 2019 | 1 | 195595,40 | 202722,39 | 216850,6 | 210568,93 | 191341,08 |
| 2019 | 2 | 196204,58 | 183331,72 | 217557,1 | 211197,09 | 191680,90 |
| 2019 | 3 | 237362,12 | 237856,64 | 218263,5 | 211830,64 | 192023,65 |
| 2019 | 4 | 232254,23 | 235870,37 | 218969,9 | 212469,59 | 192369,32 |
| 2019 | 5 | 212874,87 | 209658,54 | 219676,4 | 213114,07 | 192717,91 |
| 2019 | 6 | 220287,47 | 215593,36 | 220382,8 | 213763,94 | 193069,5 |
| 2019 | 7 | 221396,11 | 217750,06 | 221089,2 | 214419,27 | 193423,94 |
| 2019 | 8 | 209213,09 | 203016,25 | 221795,7 | 215079,99 | 193781,44 |
| 2019 | 9 | 213185,05 | 214948,82 | 222502,2 | 215746,18 | 194141,80 |
| 2019 | 10 | 216024,70 | 215217,01 | 223208,6 | 216417,82 | 194505,15 |
| 2019 | 11 | 236297,75 | 232337,23 | 223915,1 | 217094,86 | 194871,36 |
| 2019 | 12 | 227966,89 | 223808,19 | 224621,5 | 217777,36 | 195240,63 |

Çizelge 4.2. Konteyner için uygulanan yöntemler ile elde edilen tahmin sonuçları

| Yıl | Ay | Toplamsal Holt-Winters | Çarpımsal Holt-Winters | ARIMA | Çoklu Doğrusal Regresyon | DVR (Radyal Çekirdek) |
|------|----|------------------------|------------------------|----------|--------------------------|-----------------------|
| 2018 | 1 | 13366,29 | 13958,98 | 13575,78 | 14586,78 | 12095,14 |
| 2018 | 2 | 10777,54 | 10786,35 | 13575,78 | 14629,24 | 12093,87 |
| 2018 | 3 | 13761,52 | 13569,06 | 13575,78 | 14672,11 | 12092,69 |
| 2018 | 4 | 13679,34 | 13425,17 | 13575,78 | 14715,40 | 12091,63 |
| 2018 | 5 | 14208,01 | 14290,15 | 13575,78 | 14759,10 | 12090,66 |
| 2018 | 6 | 14799,38 | 14921,74 | 13575,78 | 14803,20 | 12089,81 |
| 2018 | 7 | 13157,11 | 13402,05 | 13575,78 | 14847,72 | 12089,05 |
| 2018 | 8 | 13922,41 | 13897,00 | 13575,78 | 14892,64 | 12088,38 |
| 2018 | 9 | 13410,41 | 13272,69 | 13575,78 | 14937,98 | 12087,80 |
| 2018 | 10 | 13632,54 | 13654,43 | 13575,78 | 14983,72 | 12087,30 |
| 2018 | 11 | 13882,33 | 13984,23 | 13575,78 | 15029,88 | 12086,88 |
| 2018 | 12 | 13505,23 | 13829,34 | 13575,78 | 15076,45 | 12086,52 |
| 2019 | 1 | 13529,45 | 14138,98 | 13575,78 | 15371,05 | 12085,05 |
| 2019 | 2 | 10936,45 | 10921,71 | 13575,78 | 15418,44 | 12085,04 |
| 2019 | 3 | 13916,28 | 13734,77 | 13575,78 | 15466,23 | 12085,04 |
| 2019 | 4 | 13830,06 | 13584,74 | 13575,78 | 15514,44 | 12085,04 |
| 2019 | 5 | 14354,79 | 14455,48 | 13575,78 | 15563,06 | 12085,04 |
| 2019 | 6 | 14942,33 | 15089,76 | 13575,78 | 15612,09 | 12085,04 |
| 2019 | 7 | 13296,33 | 13548,93 | 13575,78 | 15661,52 | 12085,04 |
| 2019 | 8 | 14057,99 | 14045,25 | 13575,78 | 15711,37 | 12085,04 |
| 2019 | 9 | 13542,46 | 13410,52 | 13575,78 | 15761,64 | 12085,04 |
| 2019 | 10 | 13761,13 | 13792,46 | 13575,78 | 15812,30 | 12085,04 |
| 2019 | 11 | 14007,57 | 14121,82 | 13575,78 | 15863,38 | 12085,04 |
| 2019 | 12 | 13627,21 | 13961,80 | 13575,78 | 15914,87 | 12085,04 |

Çizelge 4.3. Araç için uygulanan yöntemler ile elde edilen tahmin sonuçları

| Yıl | Ay | Toplamsal Holt-Winters | Çarpımsal Holt-Winters | ARIMA | Çoklu Doğrusal Regresyon | DVR (Radyal Çekirdek) |
|------|----|------------------------|------------------------|----------|--------------------------|-----------------------|
| 2018 | 1 | 10552,16 | 9432,28 | 16902,11 | 18888,49 | 14050,02 |
| 2018 | 2 | 15554,77 | 14528,85 | 18661,41 | 19004,99 | 13951,06 |
| 2018 | 3 | 19197,19 | 18372,64 | 19130,94 | 19122,62 | 13871,28 |
| 2018 | 4 | 17842,05 | 16778,67 | 18911,18 | 19241,37 | 13808,28 |
| 2018 | 5 | 17700,95 | 16314,54 | 18782,69 | 19361,25 | 13759,57 |
| 2018 | 6 | 20147,37 | 18374,49 | 18912,42 | 19482,24 | 13722,69 |
| 2018 | 7 | 16718,94 | 14222,30 | 19131,13 | 19604,37 | 13695,37 |
| 2018 | 8 | 11410,17 | 9216,75 | 19309,23 | 19727,63 | 13675,56 |
| 2018 | 9 | 15275,29 | 14241,77 | 19440,85 | 19852,00 | 13661,52 |
| 2018 | 10 | 17954,00 | 16603,82 | 19564,06 | 19977,50 | 13651,79 |
| 2018 | 11 | 19156,33 | 18077,24 | 19698,05 | 20104,14 | 13645,20 |
| 2018 | 12 | 19474,24 | 17605,62 | 19839,59 | 20231,89 | 13640,85 |
| 2019 | 1 | 11902,93 | 9721,19 | 19981,18 | 20360,77 | 13638,04 |
| 2019 | 2 | 16905,54 | 14962,34 | 20120,43 | 20490,78 | 13636,27 |
| 2019 | 3 | 20547,96 | 18906,62 | 20258,59 | 20621,91 | 13635,19 |
| 2019 | 4 | 19192,82 | 17253,75 | 20396,99 | 20754,16 | 13634,53 |
| 2019 | 5 | 19051,72 | 16764,60 | 20535,85 | 20887,55 | 13634,15 |
| 2019 | 6 | 21498,14 | 18868,36 | 20674,83 | 21022,05 | 13633,94 |
| 2019 | 7 | 18069,71 | 14594,79 | 20813,73 | 21157,69 | 13633,82 |
| 2019 | 8 | 12760,94 | 9451,98 | 20952,56 | 21294,45 | 13633,75 |
| 2019 | 9 | 16626,07 | 14595,99 | 21091,36 | 21432,33 | 13633,72 |
| 2019 | 10 | 19304,77 | 17006,30 | 21230,2 | 21571,34 | 13633,71 |
| 2019 | 11 | 20507,11 | 18504,32 | 21369,04 | 21711,48 | 13633,69 |
| 2019 | 12 | 20825,01 | 18011,03 | 21507,89 | 21852,74 | 13633,69 |

4.2. Modellerin Performans Sonuçları

Uygulama için kullanılan tüm yöntemlerin performans değerlerinin hesaplanmasında Denklem 3.6, Denklem 3.7 ve Denklem 3.8 kullanılmıştır. Çizelgelerde yer alan hata değerleri test verilerine aittir. Çizelgelerde yer alan model parametreleri yazılım tarafından otomatik hesaplanan ve yöntem için en iyi sonucu veren değerleri ifade etmektedir.

Yöntemlerin performansının belirlenmesinde kullanılan fonksiyonlar ve DVR yöntemleri için genel kargo verisi üzerinde uygulanmasına ait R script kodları EK 15’de verilmiştir.

İstatistiksel Yöntemlerin Performans Sonuçları

Genel kargo, konteyner ve araç hacmi için istatistiksel yöntemler ile yapılan tahmin sonuçları için test verisi üzerinde uygulanan performans ölçütü karşılaştırmaları sırasıyla Çizelge 4.4, Çizelge 4.5 ve Çizelge 4.6'da gösterilmiştir.

Çizelge 4.4. Genel kargo için uygulanan istatistiksel yöntemlerin performans sonuçları

| | OMYH (%) | OMH ($\times 10^3$) | OKHK ($\times 10^3$) | Parametreler |
|-------------------------------------|----------|-----------------------|------------------------|--|
| Basit Üstel Düzeltme Yöntemi | 7,97 | 26,47 | 35,11 | $\alpha = 0.0986$ |
| Holt'un Lineer Yöntemi | 8,02 | 25,49 | 31,56 | $\alpha = 0.0282, \beta = 0.0108$ |
| Toplamsal Holt-Winters | 10,35 | 33,50 | 41,11 | $\alpha = 0.0318, \beta = 2e-04, \gamma = 1e-04$ |
| Çarpımsal Holt-Winters | 9,75 | 31,54 | 38,16 | $\alpha = 0.0222, \beta = 2e-04, \gamma = 1e-04$ |
| ARIMA | 6,74 | 22,49 | 30,00 | $p = 2, d = 1, q = 2$ |
| Basit Doğrusal Regresyon | 11,59 | 38,77 | 49,71 | $\beta_0 = 260663, \beta_1 = 2042$ |

Çizelge 4.5. Konteyner için uygulanan istatistiksel yöntemlerin performans sonuçları

| | OMYH (%) | OMH ($\times 10^3$) | OKHK ($\times 10^3$) | Parametreler |
|-------------------------------------|----------|-----------------------|------------------------|---|
| Basit Üstel Düzeltme Yöntemi | 10,52 | 1,99 | 2,78 | $\alpha = 0.1755$ |
| Holt's Lineer Yöntemi | 10,10 | 1,90 | 2,52 | $\alpha = 1e-04, \beta = 1e-04$ |
| Toplamsal Holt-Winters | 7,86 | 1,57 | 2,02 | $\alpha = 1e-04, \beta = 1e-04, \gamma = 1e-04$ |
| Çarpımsal Holt-Winters | 8,41 | 1,68 | 2,03 | $\alpha = 1e-04, \beta = 2e-04, \gamma = 1e-04$ |
| ARIMA | 10,57 | 2,00 | 2,79 | $p = 0, d = 1, q = 1$ |
| Basit Doğrusal Regresyon | 10,50 | 2,15 | 2,76 | $\beta_0 = 17608.9, \beta_1 = 179.1$ |

Çizelge 4.6. Araç için uygulanan istatistiksel yöntemlerin performans sonuçları

| | OMYH (%) | OMH ($\times 10^3$) | OKHK ($\times 10^3$) | Parametreler |
|-------------------------------------|----------|-----------------------|------------------------|---|
| Basit Üstel Düzeltme Yöntemi | 18,62 | 4,39 | 4,96 | $\alpha = 0.164$ |
| Holt's Lineer Yöntemi | 18,61 | 4,22 | 4,99 | $\alpha = 1e-04, \beta = 1e-04$ |
| Toplamsal Holt-Winters | 10,19 | 2,45 | 2,97 | $\alpha = 0.2808, \beta = 2e-04, \gamma = 0.0013$ |
| Çarpımsal Holt-Winters | 13,10 | 3,08 | 3,55 | $\alpha = 0.5301, \beta = 1e-04, \gamma = 1e-04$ |
| ARIMA | 17,03 | 3,70 | 4,85 | $p = 2, d = 1, q = 2$ |
| Basit Doğrusal Regresyon | 20,37 | 5,61 | 6,58 | $\beta_0 = 18491.5, \beta_1 = 381.6$ |

Çoklu Doğrusal Regresyon Analizi Performans Sonuçları

Genel kargo, konteyner ve araç hacmi için değişkenler arası korelasyon değerleri sırasıyla Çizelge 4.7, Çizelge 4.8 ve Çizelge 4.9’da verilmiştir. Çizelgelerde yer alan zaman değişkeni ay değerlerini ifade etmektedir.

Çizelge 4.7. Genel kargo için değişkenler arası korelasyon değerleri

| | Zaman | Dış Ticaret | GSYH | Nüfus | Tonaj |
|-------------|-------|-------------|-------|-------|-------|
| Zaman | 1 | 0,27 | 0,19 | 0,16 | 0,15 |
| Dış Ticaret | 0,27 | 1 | -0,22 | -0,25 | 0,01 |
| GSYH | 0,19 | -0,22 | 1 | 0,99 | 0,47 |
| Nüfus | 0,16 | -0,25 | 0,99 | 1 | 0,47 |
| Tonaj | 0,15 | 0,01 | 0,47 | 0,47 | 1 |

Çizelge 4.8. Konteyner için değişkenler arası korelasyon değerleri

| | Zaman | Dış Ticaret | GSYH | Nüfus | TEU |
|-------------|-------|-------------|-------|-------|------|
| Zaman | 1 | 0,27 | 0,19 | 0,16 | 0,23 |
| Dış Ticaret | 0,27 | 1 | -0,22 | -0,25 | 0,02 |
| GSYH | 0,19 | -0,22 | 1 | 0,99 | 0,59 |
| Nüfus | 0,16 | -0,25 | 0,99 | 1 | 0,59 |
| TEU | 0,23 | 0,02 | 0,59 | 0,59 | 1 |

Çizelge 4.9. Araç için değişkenler arası korelasyon değerleri

| | Zaman | Dış Ticaret | GSYH | Nüfus | Adet |
|-------------|-------|-------------|-------|-------|------|
| Zaman | 1 | 0,27 | 0,19 | 0,16 | 0,18 |
| Dış Ticaret | 0,27 | 1 | -0,22 | -0,25 | 0,03 |
| GSYH | 0,19 | -0,22 | 1 | 0,99 | 0,62 |
| Nüfus | 0,16 | -0,25 | 0,99 | 1 | 0,64 |
| Adet | 0,18 | 0,03 | 0,62 | 0,64 | 1 |

Tüm operasyon türleri için değişkenler arası korelasyon değerleri karşılaştırıldığında GSYH ve nüfus değişkenleri arasında yüksek korelasyon olduğu görülmektedir. Bu sebeple bağımsız değişkenler arası çoklu doğrusal bağlantı olup olmadığı incelenmiştir.

Çizelge 4.10'da çoklu doğrusal bağlantının saptanması için hesaplanan VAF değerleri bulunmaktadır. VAF değerlerinin hesaplanmasına ait R script kodları ve sonuçlara ait çıktı dosyaları EK 6'da verilmiştir.

Çizelge 4.10. Bağımsız değişkenler için hesaplanan VAF değerleri

| Bağımsız Değişkenler | VAF |
|----------------------|-------|
| Zaman | 1.20 |
| Dış Ticaret | 1.24 |
| GSYH | 85.78 |
| Nüfus | 86.14 |

GSYH ve nüfus değişkenleri VAF değerleri 10'dan büyük olduğu için çoklu doğrusal bağlantıya sebep olan ana değişkenler olarak belirlenmiştir. Tüm operasyon türlerine uygulanacak olan çoklu regresyon yönteminde çoklu doğrusal bağlantı probleminin giderilmesi için kullanılacak olan değişkenlerin seçiminde adım adım regresyon yöntemi uygulanmıştır. Bu yöntem ile elde edilen son modeller üzerinde regresyon varsayımları kontrol edilmiştir. Genel kargo, konteyner ve araç hacmi için kurulan modellere ait doğrusal ilişki, hataların normal dağılıma uygunluğu ve eşit varyans kontrolü için oluşturulan grafikler sırasıyla EK 7, EK 8 ve EK 9'da verilmiştir.

Genel kargo verisi üzerinde uygulanan adım adım regresyon yönteminde anlamlı bağımsız değişken nüfus olarak belirlenmiştir. Çizelge 4.11'de nüfus bağımsız değişkeni kullanılarak kurulan modele ait ANOVA analizi sonuçları verilmiştir. Adım adım regresyon analizi uygulamasına ait R script kodları ve model performans sonuçları EK 10'da, model tahminleri ve ANOVA sonuçlarına ait R çıktıları EK 11'de verilmiştir.

Çizelge 4.11. Genel kargo için nüfus bağımsız değişkeni kullanılarak kurulan modele ait ANOVA analizi sonuçları

| | Kareler Toplamı | Serbestlik Derecesi | Kareler Ortalaması | F | Sonuç (Pr > F) |
|----------------|----------------------------|--------------------------------|-------------------------------|----------|------------------------------|
| Nüfus | 34933000000 | 1 | 34933000000 | 20,411 | 0,00002472 |
| Hatalar | 119800000000 | 70 | 1711500000 | | |

Konteyner verisi üzerinde uygulanan adım adım regresyon yönteminde anlamlı bağımsız değişkenler dış ticaret ve nüfus olarak belirlenmiştir. Çizelge 4.12’de dış ticaret ve nüfus bağımsız değişkenleri kullanılarak kurulan modele ait ANOVA analizi sonuçları verilmiştir. Model tahminleri ve ANOVA sonuçlarına ait R çıktıları EK 12’de verilmiştir.

Çizelge 4.12. Konteyner için dış ticaret ve nüfus bağımsız değişkenleri kullanılarak kurulan modele ait ANOVA analizi sonuçları

| | Kareler Toplamı | Serbestlik Derecesi | Kareler Ortalaması | F | Sonuç (Pr > F) |
|------------------------|----------------------------|--------------------------------|-------------------------------|----------|------------------------------|
| Dış Ticaret | 15049220 | 1 | 15049220 | 39,2948 | 0,00000002737 |
| Nüfus | 171262754 | 1 | 171262754 | 3,4529 | 0,06741 |
| Hatalar | 300729815 | 69 | 4358403 | | |

Araç verisi üzerinde uygulanan adım adım regresyon yönteminde anlamlı bağımsız değişkenler GSYH, dış ticaret ve nüfus olarak belirlenmiştir. Çoklu doğrusal bağlantı için yapılan test sonucunda nüfus ve GSYH çoklu doğrusal bağlantıya sebep olan değişkenler olarak belirlendiği için model GSYH değişkeni çıkarılarak dış ticaret ve nüfus bağımsız değişkenleri ile kurulmuştur. Çizelge 4.13’te dış ticaret ve nüfus bağımsız değişkenleri kullanılarak kurulan modele ait ANOVA analizi sonuçları verilmiştir.

Çizelge 4.13. Araç için dış ticaret ve nüfus bağımsız değişkenleri kullanılarak kurulan modele ait ANOVA analizi sonuçları

| | Kareler Toplamı | Serbestlik Derecesi | Kareler Ortalaması | F | Sonuç (Pr > F) |
|------------------------|----------------------------|--------------------------------|-------------------------------|----------|------------------------------|
| Dış Ticaret | 3276331 | 1 | 3276331 | 0,1144 | 0,7363 |
| Nüfus | 1636763639 | 1 | 1636763639 | 57,1357 | 0,000000000128 |
| Hatalar | 1976639481 | 69 | 28646949 | | |

Çizelge 4.13'teki ANOVA analizi sonuçlarında dış ticaret değişkeni istatistiksel olarak anlamlı çıkmamıştır. Bu sebeple araç verisi için nüfus bağımsız değişkeni kullanılarak model kurulmuştur. Çizelge 4.14'te nüfus bağımsız değişkeni kullanılarak kurulan modele ait ANOVA analizi sonuçları verilmiştir. Model tahminleri ve ANOVA sonuçlarına ait R çıktıları EK 13'te verilmiştir.

Çizelge 4.14. Araç için nüfus bağımsız değişkeni kullanılarak kurulan modele ait ANOVA analizi sonuçları

| | Kareler Toplamı | Serbestlik Derecesi | Kareler Ortalaması | F | Sonuç (Pr > F) |
|----------------|----------------------------|--------------------------------|-------------------------------|----------|------------------------------|
| Nüfus | 1496497663 | 1 | 1496497663 | 49,408 | 0,000000001105 |
| Hatalar | 2120181788 | 70 | 30288311 | | |

Tüm operasyon türleri için yapılan adım adım regresyon uygulaması sonucunda kurulan modellerin performans sonuçları Çizelge 4.15'te gösterilmiştir.

Çizelge 4.15. Tüm operasyon türleri için seçilen çoklu regresyon modellerinin tahmin performansları

| Operasyon Türü | OMYH (%) | OMH (x10³) | OKHK (x10³) | Parametreler |
|---------------------------|---------------------|----------------------------------|-----------------------------------|---|
| Genel Kargo | 7,70 | 25,04 | 30,56 | $\beta_0 = -662517, \beta_1 = 12048$ |
| Konteyner | 10,59 | 1,94 | 2,53 | $\beta_0 = -56929.2, \beta_1 = 908.9,$ $\beta_2 = 159.9$ |
| Araç | 19,08 | 4,27 | 5,13 | $\beta_0 = -172852, \beta_1 = 2494,$ |

Destek Vektör Regresyon Modellerine Ait Performans Sonuçları

Tüm operasyon türleri için adım adım regresyon analizi uygulamasında belirlenmiş olan bağımsız değişkenler kullanılarak model kurulmuş, her model için farklı çekirdek fonksiyonları uygulanmış ve performansları karşılaştırılmıştır. Modellerin oluşturulmasında eğitim verisi, performans karşılaştırmasında kullanılan hata değerlerinin hesaplanmasında test verisi kullanılmıştır.

Çizelge 4.16, Çizelge 4.17 ve Çizelge 4.18’de sırasıyla genel kargo, konteyner ve araç için kurulan DVR modellerine ait performans sonuçları gösterilmiştir. Çizelgelerde yer alan parametreler yazılım tarafından otomatik hesaplanan ve yöntem için en iyi sonucu veren değerleri ifade etmektedir.

Çizelge 4.16. Genel kargo için bağımsız değişken olarak nüfus kullanılarak kurulan DVR yöntemi tahmin performansları

| | OMYH (%) | OMH ($\times 10^3$) | OKHK ($\times 10^3$) | Parametreler |
|------------|----------|-----------------------|------------------------|----------------------------------|
| svmLinear | 9,81 | 33,08 | 43,08 | C = 1 |
| svmLinear2 | 9,81 | 33,08 | 43,08 | C = 0.5 |
| svmPoly | 10,94 | 36,74 | 46,31 | C = 0.25, ölçü = 0.1, derece = 2 |
| svmRadial | 15,67 | 51,66 | 59,03 | C = 0.5, $\sigma = 134.2391$ |

Genel kargo verisi üzerinde farklı çekirdek fonksiyonları kullanılarak yapılan DVR uygulamasına ait R script kodları EK 14’de, performans sonuçları ve en iyi sonucu veren yöntem ile yapılan tahmine ait R script kodları EK 16’da verilmiştir.

Çizelge 4.17. Konteyner için bağımsız değişken olarak dış ticaret, nüfus kullanılarak kurulan DVR yöntemi tahmin performansları

| | OMYH (%) | OMH ($\times 10^3$) | OKHK ($\times 10^3$) | Parametreler |
|------------|----------|-----------------------|------------------------|-------------------------------|
| svmLinear | 16,41 | 2,98 | 3,63 | C = 1 |
| svmLinear2 | 15,89 | 2,88 | 3,51 | C = 0.5 |
| svmPoly | 13,77 | 2,50 | 3,05 | C = 1, ölçü = 0.1, derece = 1 |
| svmRadial | 10,58 | 2,07 | 2,94 | C = 0.25, $\sigma = 1.449089$ |

Çizelge 4.18. Araç için bağımsız değişken olarak nüfus kullanılarak kurulan DVR yöntemi tahmin performansları

| | OMYH (%) | OMH ($\times 10^3$) | OKHK ($\times 10^3$) | Parametreler |
|------------|----------|-----------------------|------------------------|---------------------------------|
| svmLinear | 28,8 | 6,16 | 7,70 | C = 1 |
| svmLinear2 | 28,11 | 5,99 | 7,56 | C = 0.5 |
| svmPoly | 24,76 | 5,19 | 6,86 | C = 0,5, ölçü = 0.1, derece = 2 |
| svmRadial | 17,57 | 4,25 | 4,74 | C = 0.5, $\sigma = 3.600488$ |

Genel kargo için yapılan DVR uygulamalarında lineer çekirdek fonksiyonu ile kurulan model, konteyner ve araç için ise radyal çekirdek fonksiyonu ile kurulan model en iyi sonucu vermiştir. Çizelge 4.19’da tüm operasyon türleri için seçilen modellerin performansları gösterilmiştir.

Çizelge 4.19. Tüm operasyon türleri için seçilen DVR yöntemlerinin tahmin performansları

| Operasyon Türü | Çekirdek | OMYH (%) | OMH ($\times 10^3$) | OKHK ($\times 10^3$) | Parametreler |
|----------------|-----------|----------|-----------------------|------------------------|-------------------------------|
| Genel Kargo | svmLinear | 9,81 | 33,08 | 43,08 | C = 1 |
| Konteyner | svmRadial | 10,58 | 2,07 | 2,94 | C = 0.25, $\sigma = 1.449089$ |
| Araç | svmRadial | 17,57 | 4,25 | 4,74 | C = 0.5, $\sigma = 3.600488$ |

İstatistiksel yöntemle yapılan tahmin sonuç performansları ve DVR yöntemi ile yapılan tahmin performansları karşılaştırıldığında genel kargo hacimleri için ARIMA yönteminin en iyi performansı verdiği görülmüştür. Konteyner ve araç elleçleme hacmi için ise THW yöntemi en iyi sonucu vermiştir. Çizelge 4.20’de her bir operasyon türü için uygulanan istatistiksel talep tahmin yöntemleri ve DVR yöntemlerine ait en iyi performans sonuçlarının karşılaştırması mevcuttur.

Çizelge 4.20. Operasyon türleri için en iyi performansı veren yöntemlerin karşılaştırması

| Operasyon Türü | Yöntem | OMYH (%) | OMH (x10 ³) | OKHK (x10 ³) | Parametreler |
|----------------|------------------------|----------|-------------------------|--------------------------|--|
| Genel Kargo | ARIMA | 6,74 | 22,49 | 30,00 | p = 2, d = 1, q = 2 |
| | DVR (Lineer Çekirdek) | 9,81 | 33,08 | 43,08 | C = 1 |
| Konteyner | Toplamsal Holt-Winters | 7,86 | 1,57 | 2,02 | $\alpha = 1e-04$, $\beta = 1e-04$, $\gamma = 1e-04$ |
| | DVR (Radyal Çekirdek) | 10,58 | 2,07 | 2,94 | C = 0.25, $\sigma = 1.449089$ |
| Araç | Toplamsal Holt-Winters | 10,19 | 2,45 | 2,97 | $\alpha = 0.2808$, $\beta = 2e-04$, $\gamma = 0.0013$ |
| | DVR (Radyal Çekirdek) | 17,57 | 4,25 | 4,74 | C = 0.5, $\sigma = 3.600488$ |

Tüm operasyon türleri için en iyi sonucu veren istatistiksel talep tahmini ve DVR yöntemlerine ait R Studio grafik çıktıları sırasıyla EK 17, EK 18 ve EK 19’da verilmiştir. En iyi performansı veren model kullanılarak yapılan tahmine ait sonuçlar Çizelge 4.21’de gösterilmiştir.

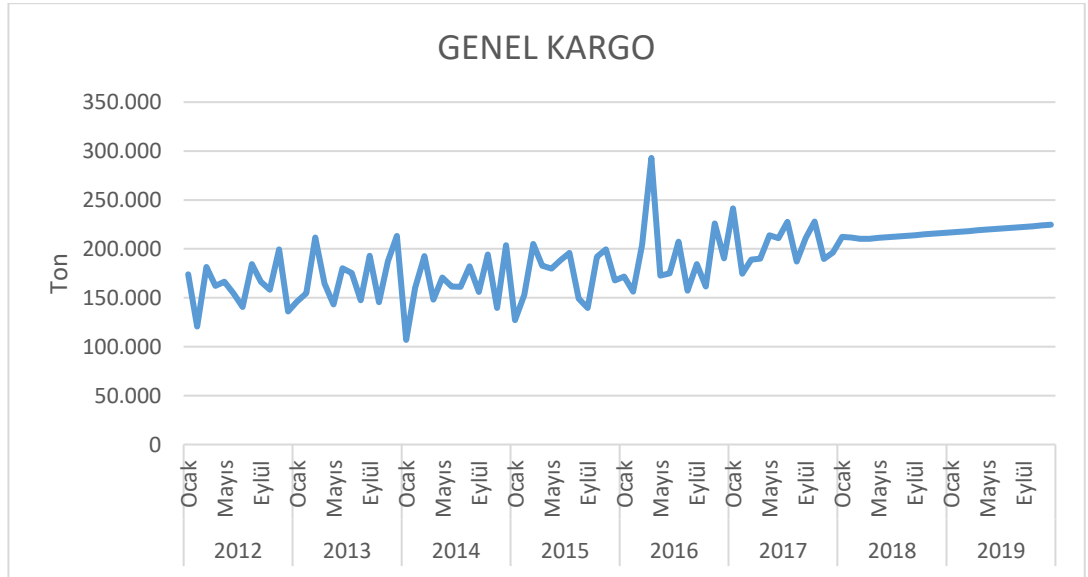
Çizelge 4.21. En iyi performansa sahip model ile yapılan tahminler

| Yıl | Ay | Genel Kargo (Ton) | Konteyner (TEU) | Araç (Adet) |
|------|----|-------------------|-----------------|-------------|
| 2018 | 1 | 212129,90 | 13366,29 | 10552,16 |
| 2018 | 2 | 211581,11 | 10777,55 | 15554,77 |
| 2018 | 3 | 210209,74 | 13761,53 | 19197,19 |
| 2018 | 4 | 210361,77 | 13679,35 | 17842,05 |
| 2018 | 5 | 211109,6 | 14208,01 | 17700,95 |
| 2018 | 6 | 211889,99 | 14799,39 | 20147,37 |
| 2018 | 7 | 212616,49 | 13157,11 | 16718,94 |
| 2018 | 8 | 213321,61 | 13922,42 | 11410,17 |
| 2018 | 9 | 214025,43 | 13410,42 | 15275,29 |
| 2018 | 10 | 214731,14 | 13632,54 | 17954,00 |
| 2018 | 11 | 215437,62 | 13882,34 | 19156,33 |
| 2018 | 12 | 216144,17 | 13505,24 | 19474,24 |

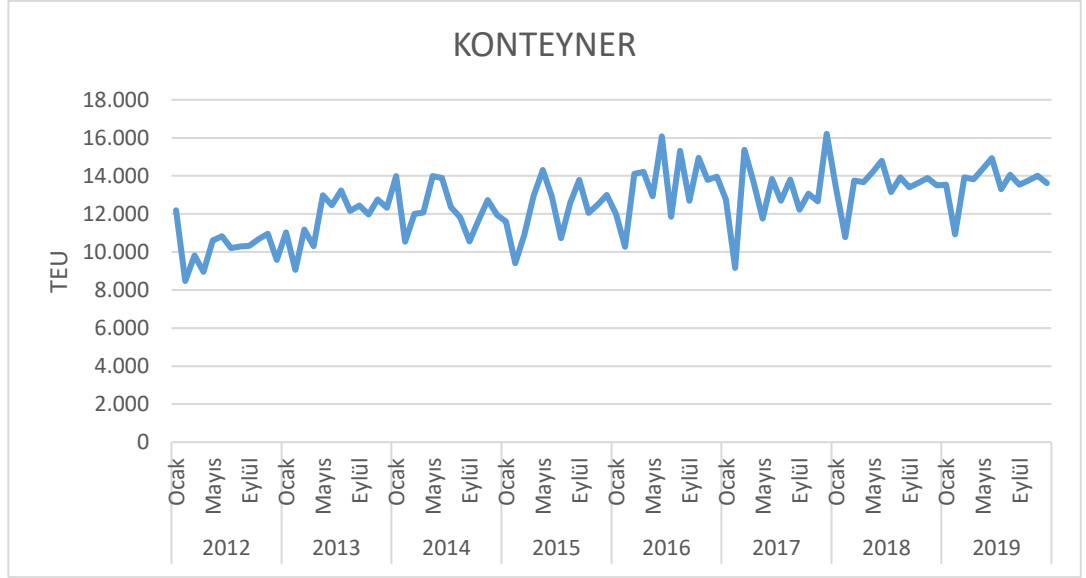
Çizelge 4.21. En iyi performansa sahip model ile yapılan tahminler (devam)

| Yıl | Ay | Genel Kargo (Ton) | Konteyner (TEU) | Araç (Adet) |
|------|----|-------------------|-----------------|-------------|
| 2019 | 1 | 216850,59 | 13529,46 | 11902,93 |
| 2019 | 2 | 217557,08 | 10936,45 | 16905,54 |
| 2019 | 3 | 218263,5 | 13916,29 | 20547,96 |
| 2019 | 4 | 218969,92 | 13830,06 | 19192,82 |
| 2019 | 5 | 219676,40 | 14354,8 | 19051,72 |
| 2019 | 6 | 220382,82 | 14942,34 | 21498,14 |
| 2019 | 7 | 221089,24 | 13296,34 | 18069,71 |
| 2019 | 8 | 221795,73 | 14058 | 12760,94 |
| 2019 | 9 | 222502,15 | 13542,46 | 16626,07 |
| 2019 | 10 | 223208,57 | 13761,14 | 19304,77 |
| 2019 | 11 | 223915,05 | 14007,58 | 20507,11 |
| 2019 | 12 | 224621,47 | 13627,21 | 20825,01 |

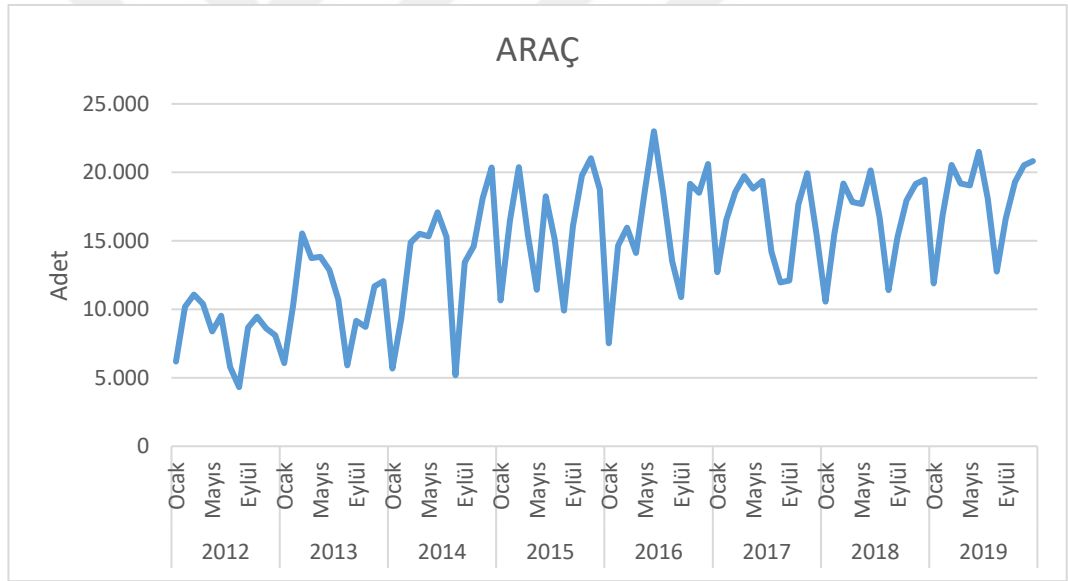
Şekil 4.1, Şekil 4.2 ve Şekil 4.3 sırasıyla tüm operasyon türleri için veri setindeki gerçek değerleri ve en iyi tahmin yöntemi kullanılarak üretilen tahmin değerlerine ait grafikleri göstermektedir.



Şekil 4.1. Genel kargo talep verileri ve gelecek dönemlerdeki talep tahminleri



Şekil 4.2. Konteyner talep verileri ve gelecek dönemlerdeki talep tahminleri



Şekil 4.3. Araç talep verileri ve gelecek dönemlerdeki talep tahminleri

4.3. Rıhtım Kapasite Doluluk Oranları

Bu bölümde 2018 ve 2019 yılları genel kargo, konteyner ve araç için gelecek yük tahmini sonuçlarına göre materyal ve yöntem bölümünde verilen kapasite hesaplama yöntemi kullanılarak yapılan liman rıhtım kapasitesi analiz sonuçları verilmiştir.

Her bir operasyon türü için kapasite hesaplamada kullanılan değişkenlerin değerleri limanın 2017 yılı verileri kullanılarak hesaplanmıştır. Çizelge 4.22, Çizelge 4.23 ve Çizelge 4.24’de kullanılan değerler mevcuttur. Çizelgelerdeki gelecek gemi sayısı hesaplamasında Denklem 3.1 kullanılmıştır.

Çizelge 4.22. Genel kargo için kapasite hesaplamada kullanılan değişkenler ve değerleri

| | 2018 | 2019 |
|---|-------------|-------------|
| Elleçlenen Yük Miktarı (Ton) | 2553558,60 | 2648832,55 |
| Gemi Başına Yük Miktarı (Ton) | 3292,19 | 3292,19 |
| Gelecek Gemi Sayısı | 775,64 | 804,58 |
| Ort. Rihtımda Kalış Süresi (Saat) | 53,85 | 53,85 |
| Gemi Başına Kullanılan Ort. Rihtım Sayısı (Adet) | 1,7 | 1,7 |

Çizelge 4.23. Konteyner için kapasite hesaplamada kullanılan değişkenler ve değerleri

| | 2018 | 2019 |
|---|-------------|-------------|
| Elleçlenen Yük Miktarı (TEU) | 162102,17 | 163802,11 |
| Gemi Başına Yük Miktarı (TEU) | 277,96 | 277,96 |
| Gelecek Gemi Sayısı (Adet) | 586,16 | 589,28 |
| Ort. Rihtımda Kalış Süresi (Saat) | 10,83 | 10,83 |
| Gemi Başına Kullanılan Ort. Rihtım Sayısı (Adet) | 1,5 | 1,5 |

Çizelge 4.24. Araç için kapasite hesaplamada kullanılan değişkenler ve değerleri

| | 2018 | 2019 |
|---|-------------|-------------|
| Elleçlenen Yük Miktarı (Adet) | 200983,52 | 217192,76 |
| Gemi Başına Yük Miktarı (Adet) | 532 | 532 |
| Gelecek Gemi Sayısı (Adet) | 378,08 | 408,57 |
| Ort. Rihtımda Kalış Süresi (Saat) | 11,39 | 11,39 |
| Gemi Başına Kullanılan Ort. Rihtım Sayısı (Adet) | 1,8 | 1,8 |

Her bir operasyon türü için tahmin edilen yük miktarına göre gerekli olacak kapasitenin hesaplama sonuçları Çizelge 4.25'te verilmiştir. Fiili kapasite hesaplamasında Denklem 3.2 kullanılmıştır.

Çizelge 4.25. Genel kargo, konteyner ve araç için gerçekleştirilecek kapasite değerleri

| Rıhtım x Saat | 2018 | 2019 |
|------------------------------|-------------|-------------|
| Genel Kargo | 67474 | 70901 |
| Konteyner | 9617 | 9724 |
| Araç | 7278 | 7471 |
| Toplam Fiili Kapasite | 84369 | 88096 |

Limanın mevcut rıhtım sayısı 14, eski iskele olmadığı durumdaki rıhtım sayısı 10'dur.

Mevcut rıhtım kapasitesinin hesaplamasında yıllık çalışılan gün sayısı 365, günlük çalışma saati 24 olarak alınmıştır. Mevcut kapasite hesaplamasında Denklem 3.3 kullanılmıştır. Çizelge 4.26'da limanın eski iskele dahil ve hariç olduğu durumda hesaplanmış olan mevcut rıhtım kapasitesi değerleri, Çizelge 4.27'de hesaplanan rıhtım kapasitesi kullanım oranları mevcuttur. Kapasite kullanım oranları Denklem 3.4 kullanılarak hesaplanmıştır.

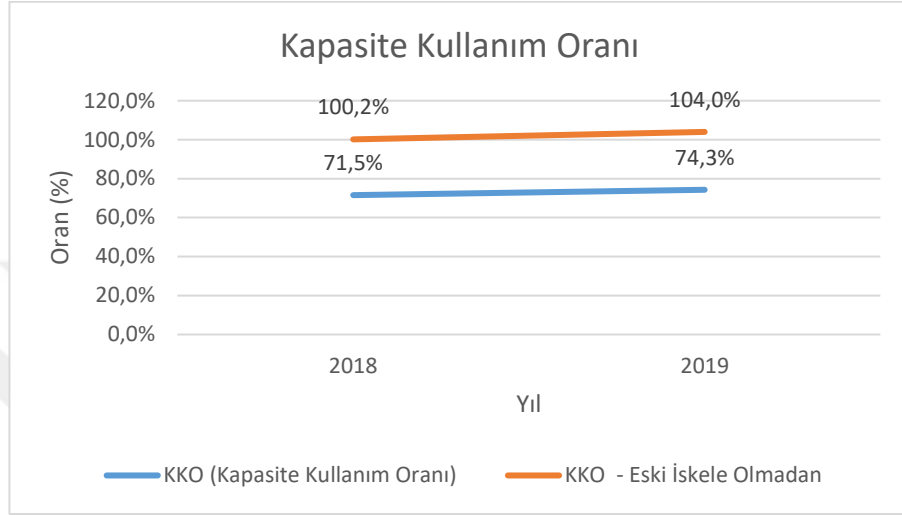
Çizelge 4.26. Limanın mevcut rıhtım kapasitesi değerleri

| Mevcut Kapasite (Rıhtım x Saat) | 2018 | 2019 |
|--|-------------|-------------|
| Eski iskele dahil | 122640 | 122640 |
| Eski iskele hariç | 87600 | 87600 |

Çizelge 4.27. Liman için rıhtım kapasitesi kullanım oranı tahminleri

| KKO(%) | 2018 | 2019 |
|--------------------------|-------------|-------------|
| Eski iskele dahil | 71,5% | 74,3% |
| Eski iskele hariç | 100,2% | 104% |

Şekil 4.4'te limanın 2018 ve 2019 yıllarında eski iskele dahil ve hariç iken rıhtım kapasitesi için hesaplanan kullanım oranları gösterilmiştir. Oranlara bakıldığında 2018 ve 2019 yılında eski iskele dahil iken kapasite sorunu yaşanmayacağı ancak iskele çalışması sırasında rıhtım doluluk oranının artacağı ve talebin karşılanmasında sorun yaşanacağı görülmektedir.



Şekil 4.4. 2018 ve 2019 yılı için eski iskele dahil kapasite kullanım oranı

5. SONUÇ

Bu çalışmada genel kargo, konteyner ve araç taşıma hacimleri için en iyi tahmin yöntemi belirlenerek 2017 yılından sonraki iki yıl için değerleri tahmin edilmiştir. Üç çeşit çalışma verisine üstel düzeltme, regresyon ve çekirdek fonksiyonlarıyla beraber DVR yöntemi uygulanmıştır. Seçilen performans ölçütlerine göre, Toplamsal Holt-Winters yöntemi konteyner ve araç taşıma hacimleri için en iyi tahmin yöntemi olarak kabul edilirken, ARIMA yöntemi genel kargo için en iyi tahmin değerlerini sağlamıştır. Elde edilen talep tahmini sonuçları, DVR yönteminin talep tahminine uygulanabileceğini, ancak Holt-Winters yönteminin mevsimsellik gösteren veriler için DVR yönteminden daha uygun olduğunu göstermiştir.

Çalışmada en iyi performansı veren modeller ile yapılan tahmin sonuçları kullanılarak limanın elleçleme hacmi tahmin edilen yıllar için rıhtım kapasite kullanım oranı analiz edilmiştir. Hesaplanan kapasite kullanım oranlarına bakıldığında yıkılacak olan iskelenin rıhtım doluluğunu fazla etkileyeceği, bu sebeple limanın iskele yapımı tamamlanana kadar operasyon hızını artırıcı ve depolama alanlarını artırıcı planlar yapması gerektiği görülmüştür.

Yapılan çalışma talep tahmininde regresyon analizi dışında yöntemlerin kullanılması ve konteyner dışında yük cinslerine de hizmet veren bir limanda uygulanması sebebiyle literatüre önemli bir katkı sağlamaktadır. Çalışma sonuçları, limanlarda talep tahmini ve kapasite hesaplamasının yakın ilişkisini ve önemini vurgulamaktadır. Ayrıca gelecekte limanlar üzerinde yapılacak trafik yük tahmini uygulamalarında aynı anda birden fazla makine öğrenme algoritmasını kullanmaya olanak sağlayan derin öğrenme yöntemlerinin uygulanabileceğini göstermektedir.

KAYNAKLAR

Ajao, I.O., Ibraheem, A.G., Ayoola, F.J. 2012. Cubic spline interpolation: A robust method of disaggregating annual data to quarterly series. *Journal of Physical Sciences and Environmental Safety*, 2(1): 1-8.

Akar, O., Esmer, S. 2015. Cargo demand analysis of container terminals in Turkey. *Journal of ETA Maritime Science*, 3(2): 117-122.

Albayrak, A.S. 2005. Çoklu Doğrusal Bağlantı Halinde En Küçük Kareler Tekniğinin Alternatifi Yanlı Tahmin Teknikleri ve Bir Uygulama, *ZKÜ Sosyal Bilimler Dergisi*, 1(1): 105-126.

Anonim, 2010. Ulaştırma K1y1 Yapıları Master Plan Çalışması – Sonuç Raporu. Ankara.

Anonim, 2015. Deniz Sektörü Raporu. Deniz Ticaret Odası, İstanbul.

Anonim, 2017. Deniz Sektörü Raporu. Deniz Ticaret Odası, İstanbul.

Anonim, 2018a. TSI. Turkish Statistical Institute, <http://www.turkstat.gov.tr/UstMenu.do?metod=temelist> – (Erişim tarihi: 05.10.2018).

Anonim, 2018b. World Bank, <https://datacatalog.worldbank.org/dataset/global-economic-prospects> – (Erişim tarihi: 05.10.2018).

Anonim, 2018c. OECD, <https://data.oecd.org/trade/trade-in-goods-and-services-forecast.htm> – (Erişim tarihi: 05.10.2018).

Ayodele, T.O. 2010. Types of Machine Learning Algorithms. India: In-Tech. <https://www.intechopen.com/books/new-advances-in-machine-learning/types-of-machine-learning-algorithms>-(Erişim Tarihi: 01.02.2018).

Balık, İ. 2014. Limanlar ve liman yeri seçimi. *Kent Kültürü ve Yönetimi Dergisi*, 7(2): 37-48.

Basak, D., Pal, S., Patranabis, D.C. 2007. Support Vector Regression. *Statistics and Computing*, 11(10): 203-224.

Bayraktutan, Y., Özbilgin, M. 2013. Limanların ulusal ticarete etkisi ve Kocaeli limanlarının ülke ekonomisindeki yeri. *Kocaeli Üniversitesi Sosyal Bilimler Dergisi*, 26: 11-41.

Borovicka, T., Jirina, M., Kordik, P., Jirina M. 2012. Selecting Representative Data Sets. India: Intech. <https://www.intechopen.com/books/advances-in-data-mining-knowledge-discovery-and-applications/selecting-representative-data-sets>-(Erişim Tarihi: 01.02.2018)

Chou, C.C., Chu, C., Liang G. 2007. A modified regression model for forecasting the volumes of Taiwan's import containers, *Mathematical and Computer Modelling*, 47 (2008): 797-807.

Esmer, S. 2014. Talep tahminleri ışığında Türk limanlarına yönelik kapasite analizi. 8. Kıyı Mühendisliği Sempozyumu, 7-9 Kasım 2014, İTÜ İşletme Fakültesi C Amfisi Maçka, İstanbul.

Gosasang, V., Chandraprakaikul, W., Kiattisin, S. 2011. A Comparison of Traditional and Neural Networks Forecasting Techniques for Container Throughput at Bangkok Port. *The asian Journal of Shipping and Logistics*, 27(3): 463-482.

Gökkuş, Ü., Yıldırım, M.S., Aydın, M.M. 2017. Estimation of container traffic at seaports by using several soft computing methods: A case of Turkish seaports, *Discrete Dynamics in Nature and Society*, 2017(2017): 15.

Hyndman, R.J., Khandakar, Y. 2008. Automatic Time Series Forecasting: The forecast Package for R. *Journal of Statistical Software*, 27(3): 1-22.

Hota, H.S., Handa, R., Shrivastava, A.K. 2017. Time Series Data Prediction Using Sliding Window Based RBF Neural Network, *International Journal of Computational Intelligence Research*, 13(5): 1145-1156.

Jakkula, V.R. 2012. Tutorial on support vector machine (SVM). School of EECS, Washington State University. <https://pdfs.semanticscholar.org/7cc8/3e98367721bfb908a8f703ef5379042c4bd9.pdf> (Erişim Tarihi: 01.02.2018).

Jugović, A., Hess, S., Jugović, T. 2010. Traffic demand forecasting for port services. *Promet-Traffic & Transportation*, 23(1): 59-69.

Koçak, E., Kişi, H. 2015. Liman özelleştirmeleri: Mersin limanı için beklentiler ve gerçekleştirmeler. *International Journal of Economic and Administrative Studies*, 15: 280-296.

Kourentzes, N., Petropoulos, F. 2007. Forecasting with R. International Symposium on Forecasting 2017, June 25 – 28, 2017, Cairns, Australia.

Kuhn, M. 2008. Building Predictive Models in R Using the caret Package. *Journal of Statistical Software*, 28(5): 1-26.

Layaa, J., Dullaert, W. 2014. Measuring and analysing terminal capacity in East Africa: The case of the seaport of Dar es Salaam, *Maritime Economics & Logistics*, 16(2): 141-164.

Mak, K.L., Yang, D.H. 2007. Forecasting Hong Kong's Container Throughput with Approximate Least Squares Support Vector Machines. Proceedings of the World Congress on Engineering 2007 Vol I WCE 2007, July 2 – 4, 2007, London, U.K.

Makridakis, S.G., Wheelwright, S.C., Hyndman, R.J. 1998. Exponential smoothing methods, The Box-Jenkins methodology for ARIMA models: Forecasting methods and applications 3rd edition, Ed.: Wiley, J., New York, United States of America, pp: 138-184, pp: 313-389.

Mohammed, M.M.Z.E., Bashier, E.B.M. 2016. Types of Machine Learning Algorithms, CRC Press, Boca Raton, FL, USA.

Muslu, E. 2017. Türkiye'nin lojistik üs olmasında limanların stratejik yönetiminin önemi: Samsun limanı örneği. III. Ulusal Liman Kongresi, 2-3 Kasım 2017, Dokuz Eylül Üniversitesi Denizcilik Fakültesi Tınaztepe Yerleşkesi, İzmir.

Nanda, M.A., Seminar, K.B., Nandika, D., Maddu, A. 2018. A Comparison Study of Kernel Functions in the Support Vector Machine and Its Application for Termite Detection, *Information*, 9(1): 5.

Oral, E.Z., Özerden, A. 2010. İzmir Alsancak limanında yük ve gemi hizmet olanaklarının geliştirilmesi. İzmir Ticaret Odası. İzmir.

Oral, E.Z. 2014. Genel kargo limanlarının kapasite analizi. 8. Kıyı Mühendisliği Sempozyumu, 7-9 Kasım 2014, İTÜ İşletme Fakültesi C Amfisi Maçka, İstanbul.

Park, N., Yoon, D., Park, S. 2014. Port Capacity Evaluation Formula for General Cargo, *The Asian Journal of Shipping and Logistics*, 30(2): 175-192.

Peng, W., Chu, C. 2009. A comparison of univariate methods for forecasting container throughput volumes, *Mathematical and Computer Modelling*, 50 (2009): 1045-1057.

Reitermanová, Z. 2010. Data Splitting. Proceedings of the 19th Annual Conference of Doctoral Students - WDS 2010, June 1 – 4, 2010, Prague.

Smola, A.J., Schölkopf, B. 2004. A Tutorial on Support Vector Regression. *Statistics and Computing*, 14: 199-222.

Twrdy, E., Batista, M. 2016. Modeling of container throughput in Northern Adriatic ports over the period 1990-2013, *Journal of Transport Geography*, 52(2016): 131-142.

Usluer, H.B., Alkan, G.B. 2015. Liman planlama ve geliştirmede deniz bilimlerinin önemi. II. Ulusal Liman Kongresi, 5-6 Kasım 2015, Dokuz Eylül Üniversitesi Denizcilik Fakültesi Tınaztepe Yerleşkesi, İzmir.

Walpole, R.E, Myers, R.H., Myers, S.L., Ye, K. 2007. Simple linear regression and correlation, Multiple linear regression and certain nonlinear regression models: Probability & statistics for engineers & scientists eight edition, Ed.: Yagan, S. United States of America, pp: 389-444, pp: 445-510.

Xie, G. Wang, S., Zhao, Y., Lai, K.K. 2013. Hybrid approaches based on LSSVR model for container throughput forecasting: A comparative study, *Applied Soft Computing*, 13(2013): 2232-2241.



EKLER

- EK 1** İstatistiksel Tahmin Yöntemlerinin Uygulanacağı Verilerin Okunması ve Üstel Düzeltme Yöntemleri İçin Zaman Serisi Formatına Dönüştürülmesine Ait R Script Kodları
- EK 2** Kullanılan Girdi Değişkenlerine Ait Yıllık Verileri Aylık Verilere Dönüştürmek İçin Uygulanan İnterpolasyona Ait R Script Kodları
- EK 3** Genel Kargo Verisi Üzerinde Uygulanan Üstel Düzeltme Yöntemlerine Ait R Script Kodları ve Performans Çıktıları
- EK 4** Genel Kargo Verisi Üzerinde Uygulanan ARIMA Yöntemine Ait R Script Kodları ve Performans Çıktıları
- EK 5** Genel Kargo Verisi Üzerinde Uygulanan Basit Doğrusal Regresyon Analizi Yöntemine Ait R Script Kodları ve Performans Çıktıları
- EK 6** Çoklu Doğrusal Bağlantının Saptanmasında Kullanılan R Script Kodları ve Sonuçları
- EK 7** Genel Kargo Verisi Üzerinde Uygulanan Regresyon Varsayımları Kontrol Sonuçları
- EK 8** Konteyner Üzerinde Uygulanan Regresyon Varsayımları Kontrol Sonuçları
- EK 9** Araç Verisi Üzerinde Uygulanan Regresyon Varsayımları Kontrol Sonuçları
- EK 10** Genel Kargo Verisi Üzerinde Uygulanan Adım Adım Regresyon Analizine Ait R Script Kodları ve Performans Sonuçları
- EK 11** Genel Kargo Verisi İçin Adım Adım Regresyon Sonucunda Kurulan Modele Ait Tahminler ve ANOVA Analizi Sonuçları
- EK 12** Konteyner Verisi İçin Adım Adım Regresyon Sonucunda Kurulan Modele Ait Tahminler ve ANOVA Analizi Sonuçları
- EK 13** Araç Verisi İçin Adım Adım Regresyon Sonucunda Kurulan Modele Ait Tahminler ve ANOVA Analizi Sonuçları
- EK 14** Genel Kargo Verisi Üzerinde Uygulanan Destek Vektör Regresyon Yöntemlerine Ait R Script Kodları

- EK 15** Farklı Yöntemlerin Performansının Belirlenmesinde Kullanılan Fonksiyonlar ve DVR Yöntemleri İçin Genel Kargo Verisi Üzerinde Uygulanmasına Ait R Script Kodları
- EK 16** Genel Kargo Verisi Üzerinde Uygulanan Destek Vektör Regresyon Yöntemlerinin Performans Sonuçları ve En İyi Performansı Veren Yöntem İle Yapılan Tahmine Ait R Script Kodları
- EK 17** Genel Kargo İçin En İyi Sonucu Veren İstatistiksel Tahmin Yöntemi ve DVR Yönteminin R Studio Grafikleri
- EK 18** Konteyner İçin En İyi Sonucu Veren İstatistiksel Tahmin Yöntemi ve DVR Yönteminin R Studio Grafikleri
- EK 19** Araç İçin En İyi Sonucu Veren İstatistiksel Tahmin Yöntemi ve DVR Yönteminin R Studio Grafikleri

EK 1 İSTATİSTİKSEL TAHMİN YÖNTEMLERİNİN UYGULANACAĞI VERİLERİN OKUNMASI VE ÜSTEL DÜZELTME YÖNTEMLERİ İÇİN ZAMAN SERİSİ FORMATINA DÖNÜŞTÜRÜLMESİNE AİT R SCRIPT KODLARI

```
install.packages("readxl")
library(readxl) #load package

gk_data = read_excel("R Application/Data/GK_Data.xlsx", sheet = "Data")
gk_newdata = read_excel("R Application/Data/GK_Data.xlsx", sheet = "NewData")

kt_data = read_excel("R Application/Data/KT_Data.xlsx", sheet = "Data")
kt_newdata = read_excel("R Application/Data/KT_Data.xlsx", sheet = "NewData")

roro_data = read_excel("R Application/Data/RORO_Data.xlsx", sheet = "Data")
roro_newdata = read_excel("R Application/Data/RORO_Data.xlsx", sheet = "NewData")

#Convert to time series data (Monthly)
ts_gktotal <- ts(gk_data$TotalTonnage, start=c(2012,1,1), end=c(2017,12,1), frequency=12)
ts_ktttotal <- ts(kt_data$TotalTEU, start=c(2012,1,1), end=c(2017,12,1), frequency=12)
ts_rrtotal <- ts(roro_data$Total, start=c(2012,1,1), end=c(2017,12,1), frequency=12)
```

EK 2 KULLANILAN GİRDİ DEĞİŞKENLERİNE AİT YILLIK VERİLERİ AYLIK VERİLERE DÖNÜŞTÜRMEK İÇİN UYGULANAN İNTEPOLASYONA AİT R SCRIPT KODLARI

```
library(readxl)

data_Yearly = read_excel("R Application/Data/Data_Yearly.xlsx", sheet = "Data")
newdata_Yearly = read_excel("R Application/Data/Data_Yearly.xlsx", sheet = "NewData")

#Interpolation for real yearly data to monthly data
monthly_population = spline(data_Yearly$t,data_Yearly$Population,
                             n = 12*length(data_Yearly$t),
                             method = "fmm",
                             xmin = 1,
                             xmax = 72,
                             ties = "mean")

monthlyPopulation = data.frame(t = monthly_population$x, Population = monthly_population$y)

monthly_GDP = spline(data_Yearly$t,data_Yearly$GDP,
                      n = 12*length(data_Yearly$t),
                      method = "fmm",
                      xmin = 1,
                      xmax = 72,
                      ties = "mean")

monthlyGDP = data.frame(t = monthly_GDP$x, GDP = monthly_GDP$y)

#Interpolation for forecasting yearly data to monthly data
new_monthly_population = spline(newdata_Yearly$t,newdata_Yearly$Population,
                                 n = 12*length(newdata_Yearly$t),
                                 method = "fmm",
                                 xmin = 73,
                                 xmax = 108,
                                 ties = "mean")

newmonthlyPopulation = data.frame(t = new_monthly_population$x, Population = new_monthly_population$y)

new_monthly_GDP = spline(newdata_Yearly$t,newdata_Yearly$GDP,
                          n = 12*length(newdata_Yearly$t),
                          method = "fmm",
                          xmin = 73,
                          xmax = 108,
                          ties = "mean")

newmonthlyGDP = data.frame(t = new_monthly_GDP$x, GDP = new_monthly_GDP$y)
```

EK 3 GENEL KARGO VERİSİ ÜZERİNDE UYGULANAN ÜSTEL DÜZELTME YÖNTEMLERİNE AİT R SCRIPT KODLARI VE PERFORMANS ÇIKTILARI

Üstel Düzeltme Yöntemlerine Ait R Script Kodları:

```
install.packages("forecast")
library(forecast)

# ses with additive errors
ets_gktotal1 = ets(ts_gktotal, model = "ANN")
mae_gkTotal1 = mae(ts_gktotal[60:72] - forecast(ets_gktotal1)$fitted[60:72])
mape_gkTotal1 = mape(ts_gktotal[60:72], forecast(ets_gktotal1)$fitted[60:72])
rmse_gkTotal1 = rmse(ts_gktotal[60:72] - forecast(ets_gktotal1)$fitted[60:72])
forecast_gk_total1 = forecast(ets_gktotal1, h = 24)
plot(forecast_gk_total1)

# Holt's Linear Method with additive errors
ets_gktotal2 = ets(ts_gktotal, model = "AAN")
mae_gkTotal2 = mae(ts_gktotal[60:72] - forecast(ets_gktotal2)$fitted[60:72])
mape_gkTotal2 = mape(ts_gktotal[60:72], forecast(ets_gktotal2)$fitted[60:72])
rmse_gkTotal2 = rmse(ts_gktotal[60:72] - forecast(ets_gktotal2)$fitted[60:72])
forecast_gk_total2 = forecast(ets_gktotal2, h = 24)
plot(forecast_gk_total2)

# additive Holt-winter's method with additive errors
ets_gktotal3 = ets(ts_gktotal, model = "AAA")
mae_gkTotal3 = mae(ts_gktotal[60:72] - forecast(ets_gktotal3)$fitted[60:72])
mape_gkTotal3 = mape(ts_gktotal[60:72], forecast(ets_gktotal3)$fitted[60:72])
rmse_gkTotal3 = rmse(ts_gktotal[60:72] - forecast(ets_gktotal3)$fitted[60:72])
forecast_gk_total3 = forecast(ets_gktotal3, h = 24)
plot(forecast_gk_total3)

# multiplicative Holt-winter's method with multiplicative errors
ets_gktotal4 = ets(ts_gktotal, model = "MAM")
mae_gkTotal4 = mae(ts_gktotal[60:72] - forecast(ets_gktotal4)$fitted[60:72])
mape_gkTotal4 = mape(ts_gktotal[60:72], forecast(ets_gktotal4)$fitted[60:72])
rmse_gkTotal4 = rmse(ts_gktotal[60:72] - forecast(ets_gktotal4)$fitted[60:72])
forecast_gk_total4 = forecast(ets_gktotal4, h = 24)
plot(forecast_gk_total4)
```

Üstel Düzeltme Yöntemlerine Ait Model Performans Sonuçları:

| | |
|---------------|------------------|
| mae_gkTotal1 | 26471.9783664992 |
| mape_gkTotal1 | 7.9725393826068 |
| rmse_gkTotal1 | 35118.75047568 |
| mae_gkTotal2 | 25492.3905058816 |
| mape_gkTotal2 | 8.02867617265005 |
| rmse_gkTotal2 | 31565.9855224674 |
| mae_gkTotal3 | 33507.510489967 |
| mape_gkTotal3 | 10.3571240035748 |
| rmse_gkTotal3 | 41119.6524088483 |
| mae_gkTotal4 | 31541.2431071839 |
| mape_gkTotal4 | 9.75271846201294 |
| rmse_gkTotal4 | 38164.1196270479 |

EK 4 GENEL KARGO VERİSİ ÜZERİNDE UYGULANAN ARIMA YÖNTEMİNE AİT R SCRİPT KODLARI VE PERFORMANS ÇIKTILARI

ARIMA Yöntemine Ait R Script Kodları:

```
library(forecast)

arima_gktotal = auto.arima(gk_data$TotalTonnage)
mae_gkTotal1 = mae(gk_data$TotalTonnage[60:72] - forecast(arima_gktotal)$fitted[60:72])
mape_gkTotal1 = mape(gk_data$TotalTonnage[60:72], forecast(arima_gktotal)$fitted[60:72])
rmse_gkTotal1 = rmse(gk_data$TotalTonnage[60:72] - forecast(arima_gktotal)$fitted[60:72])
pred_arima_gktotal = forecast(arima_gktotal, h = 24)
plot(pred_arima_gktotal)
```

ARIMA Yöntemine Ait Model Performans Sonuçları:

| | |
|---------------|------------------|
| mae_gkTotal1 | 22497.5693327589 |
| mape_gkTotal1 | 6.74457336124182 |
| rmse_gkTotal1 | 30006.7738263579 |

EK 5 GENEL KARGO VERİSİ ÜZERİNDE UYGULANAN BASİT DOĞRUSAL REGRESYON ANALİZİ YÖNTEMİNE AİT R SCRIPT KODLARI VE PERFORMANS ÇIKTILARI

R Script Kodları:

```
# SIMPLE LINEAR REGRESSION #  
  
# GK  
lm_gktotal1 = lm(formula = TotalTonnage ~ t, data = gk_data)  
mae_gkTotal1 = mae(gk_data$TotalTonnage[60:72] - fitted(lm_gktotal1)[60:72])  
mape_gkTotal1 = mape(gk_data$TotalTonnage[60:72],fitted(lm_gktotal1)[60:72])  
rmse_gkTotal1 = rmse(gk_data$TotalTonnage[60:72] - fitted(lm_gktotal1)[60:72])  
  
lm_newdata = data.frame('t'=c(73:96))  
pred_lm_gktotal1 = predict(lm_gktotal1, lm_newdata)
```

Model Performans Sonuçları:

| | |
|---------------|------------------|
| mae_gkTotal1 | 38770.5070324721 |
| mape_gkTotal1 | 11.5992926568897 |
| rmse_gkTotal1 | 49710.2697460132 |

EK 6 ÇOKLU DOĞRUSAL BAĞLANTININ SAPTANMASINDA KULLANILAN R SCRIPT KODLARI VE SONUÇLARI

```
install.packages("mctest")
library(mctest)

omcdiag(x = gk_data[,1:4], y = gk_data$TotalTonnage)
imcdiag(x = gk_data[,1:4], y = gk_data$TotalTonnage)
```

```
Call:
omcdiag(x = gk_data[, 1:4], y = gk_data$TotalTonnage)
```

Overall Multicollinearity Diagnostics

| | MC Results | detection |
|------------------------|------------|-----------|
| Determinant X'X : | 0.0094 | 1 |
| Farrar Chi-Square: | 315.8494 | 1 |
| Red Indicator: | 0.4549 | 0 |
| Sum of Lambda Inverse: | 174.3904 | 1 |
| Theil's Method: | 1.6063 | 1 |
| Condition Number: | 1094.1167 | 1 |

```
1 --> COLLINEARITY is detected by the test
0 --> COLLINEARITY is not detected by the test
```

```
Call:
imcdiag(x = gk_data[, 1:4], y = gk_data$TotalTonnage)
```

All Individual Multicollinearity Diagnostics Result

| | VIF | TOL | wi | Fi | Leamer | CVIF | Klein |
|--------------|---------|--------|-----------|-----------|--------|----------|-------|
| t | 1.2057 | 0.8294 | 4.6635 | 7.0981 | 0.9107 | 1.7409 | 0 |
| ForeignTrade | 1.2489 | 0.8007 | 5.6428 | 8.5887 | 0.8948 | 1.8033 | 0 |
| GDP | 85.7887 | 0.0117 | 1921.8777 | 2925.2109 | 0.1080 | 123.8643 | 1 |
| Population | 86.1470 | 0.0116 | 1929.9987 | 2937.5716 | 0.1077 | 124.3816 | 1 |

```
1 --> COLLINEARITY is detected by the test
0 --> COLLINEARITY is not detected by the test
```

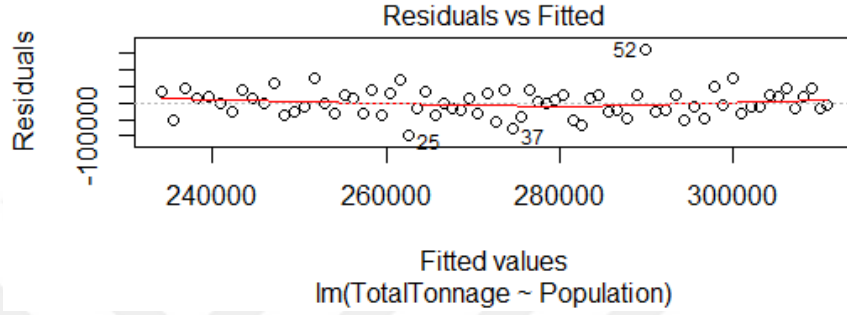
t , ForeignTrade , GDP , Population , coefficient(s) are non-significant may be due to multicollinearity

R-square of y on all x: 0.2468


* use method argument to check which regressors may be the reason of collinearity

EK 7 GENEL KARGO VERİSİ ÜZERİNDE UYGULANAN REGRESYON VARSAYIMLARI KONTROL SONUÇLARI

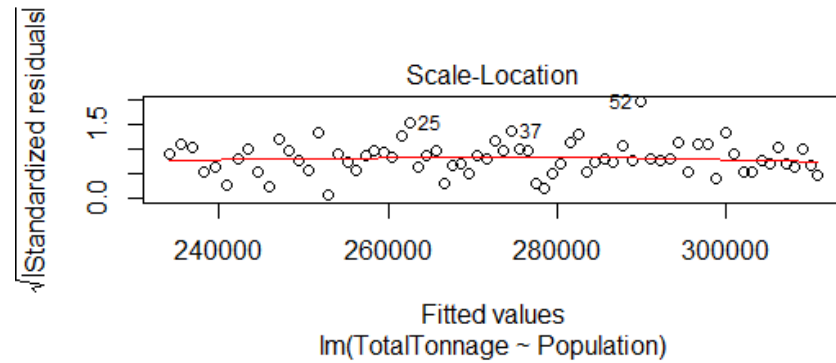
Model Hatalarının Tahmin Değerleriyle Karşılaştırması



Hataların Normal Dağılıma Uygunluk Grafiği

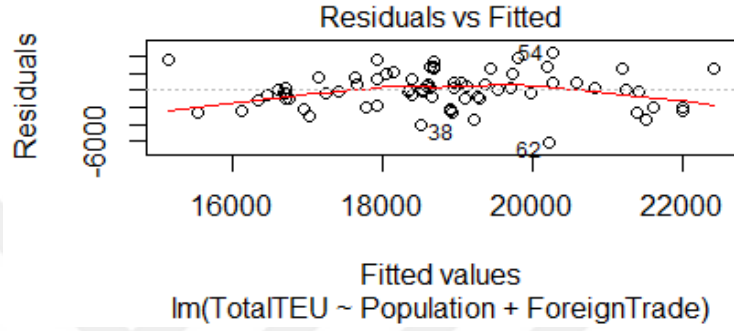


Eşit Varyans Kontrolü

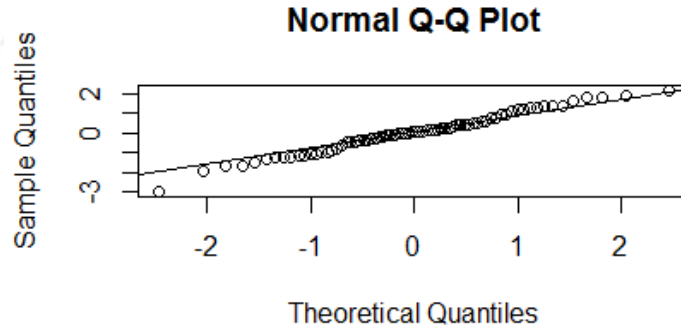


EK 8 KONTEYNER VERİSİ ÜZERİNDE UYGULANAN REGRESYON VARSAYIMLARI KONTROL SONUÇLARI

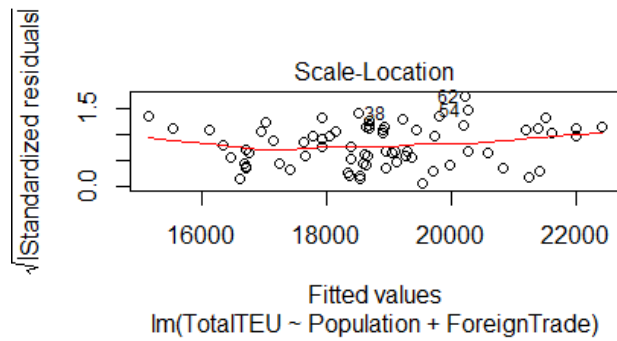
Model Hatalarının Tahmin Değerleriyle Karşılaştırması



Hataların Normal Dağılıma Uygunluk Grafiği




Eşit Varyans Kontrolü




EK 9 ARAÇ VERİSİ ÜZERİNDE UYGULANAN REGRESYON VARSAYIMLARI KONTROL SONUÇLARI

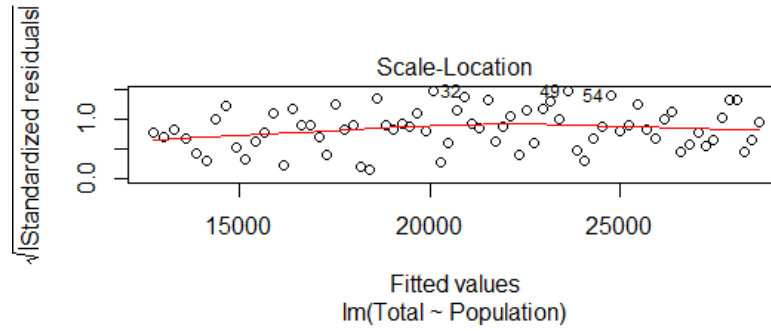
Model Hatalarının Tahmin Değerleriyle Karşılaştırması



Hataların Normal Dağılıma Uygunluk Grafiği



Eşit Varyans Kontrolü



EK 10 GENEL KARGO VERİSİ ÜZERİNDE UYGULANAN ADIM ADIM REGRESYON ANALİZİNE AİT R SCRIPT KODLARI VE PERFORMANS SONUÇLARI

Adım Adım Regresyon Analizine Ait R Script Kodları

```
# STEPWISE REGRESSION #
library(MASS)

correlation_gk=cor(gk_data[,]) # Correlations between variables for GK Data

# Model:
m1m_gktotal1=lm(formula= TotalTonnage ~ ForeignTrade + GDP + Population + t,
                data=gk_data)
summary(m1m_gktotal1)
mae_gkTotal1 = mae(gk_data$TotalTonnage[60:72] - fitted(m1m_gktotal1)[60:72])
mape_gkTotal1 = mape(gk_data$TotalTonnage[60:72],fitted(m1m_gktotal1)[60:72])
rmse_gkTotal1 = rmse(gk_data$TotalTonnage[60:72] - fitted(m1m_gktotal1)[60:72])

step <- stepAIC(m1m_gktotal1, direction = "both")
step$anova

# Final Model:
m1m_gktotal=lm(formula= TotalTonnage ~ Population,
               data=gk_data)
summary(m1m_gktotal)
mae_gkTotal = mae(gk_data$TotalTonnage[60:72] - fitted(m1m_gktotal)[60:72])
mape_gkTotal = mape(gk_data$TotalTonnage[60:72],fitted(m1m_gktotal)[60:72])
rmse_gkTotal = rmse(gk_data$TotalTonnage[60:72] - fitted(m1m_gktotal)[60:72])

pred_m1m_gktotal = predict(m1m_gktotal, gk_newdata)
```

Modele Ait Performans Sonuçları

| | |
|--------------|------------------|
| mae_gkTotal | 25044.7998351527 |
| mape_gkTotal | 7.70528228661805 |
| rmse_gkTotal | 30568.2162490529 |

EK 11 GENEL KARGO VERİSİ İÇİN ADIM ADIM REGRESYON SONUCUNDA KURULAN MODELE AİT TAHMİNLER VE ANOVA ANALİZİ SONUÇLARI

Model Tahminleri

```
Call:
lm(formula = TotalTonnage ~ Population, data = gk_data)

Residuals:
    Min       1Q   Median       3Q      Max
-98098 -26246  -2758   25242 160729

Coefficients:
              Estimate Std. Error t value Pr(>|t|)
(Intercept)  -662517    207336  -3.195   0.0021 **
Population     12048      2667    4.518 2.47e-05 ***
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 41370 on 70 degrees of freedom
Multiple R-squared:  0.2258,    Adjusted R-squared:  0.2147
F-statistic: 20.41 on 1 and 70 DF,  p-value: 2.472e-05
```

ANOVA Analizi Sonuçları

Analysis of Variance Table

```
Response: TotalTonnage
      Df    Sum Sq  Mean Sq F value    Pr(>F)
Population  1 3.4933e+10 3.4933e+10  20.411 2.472e-05 ***
Residuals  70 1.1980e+11 1.7115e+09
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```

EK 12 KONTEYNER VERİSİ İÇİN ADIM ADIM REGRESYON SONUCUNDA KURULAN MODELE AİT TAHMİNLER VE ANOVA ANALİZİ SONUÇLARI

Model Tahminleri

```
Call:
lm(formula = TotalTEU ~ Population + ForeignTrade, data = kt_data)

Residuals:
    Min       1Q   Median       3Q      Max
-6136.8 -1066.7   52.1  1215.4  4460.3

Coefficients:
            Estimate Std. Error t value Pr(>|t|)
(Intercept) -56929.21  11798.65  -4.825 8.08e-06 ***
Population    908.93    139.09   6.535 9.17e-09 ***
ForeignTrade  159.90     86.05   1.858 0.0674 .
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 2088 on 69 degrees of freedom
Multiple R-squared:  0.3825,    Adjusted R-squared:  0.3646
F-statistic: 21.37 on 2 and 69 DF,  p-value: 5.971e-08
```

ANOVA Analizi Sonuçları

Analysis of Variance Table

```
Response: TotalTEU
      Df Sum Sq Mean Sq F value Pr(>F)
Population  1 171262754 171262754 39.2948 2.737e-08 ***
ForeignTrade  1  15049220  15049220  3.4529  0.06741 .
Residuals    69 300729815  4358403
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```

EK 13 ARAÇ VERİSİ İÇİN ADIM ADIM REGRESYON SONUCUNDA KURULAN MODELE AİT TAHMİNLER VE ANOVA ANALİZİ SONUÇLARI

Model Tahminleri

```
Call:
lm(formula = Total ~ Population, data = roro_data)

Residuals:
    Min       1Q   Median       3Q      Max
-12128.1  -4371.1    506.3   3814.3  10628.3

Coefficients:
              Estimate Std. Error t value Pr(>|t|)
(Intercept) -172852.2    27582.1  -6.267 2.63e-08 ***
Population     2493.6     354.8    7.029 1.11e-09 ***
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 5503 on 70 degrees of freedom
Multiple R-squared:  0.4138,    Adjusted R-squared:  0.4054
F-statistic: 49.41 on 1 and 70 DF,  p-value: 1.105e-09
```

ANOVA Analizi Sonuçları

```
Analysis of Variance Table

Response: Total
          Df    Sum Sq  Mean Sq F value    Pr(>F)
Population 1 1496497663 1496497663  49.408 1.105e-09 ***
Residuals 70 2120181788   30288311
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```


EK 14 GENEL KARGO VERİSİ ÜZERİNDE UYGULANAN DESTEK VEKTÖR REGRESYON YÖNTEMLERİNE AİT R SCRIPT KODLARI

```
library(readxl) #load package
training_gkdata = read_excel("R Application/Data/Data_GK_ML.xlsx", sheet = "TrainingData")
test_gkdata = read_excel("R Application/Data/Data_GK_ML.xlsx", sheet = "TestData")

library(caret)
ctrl = trainControl(method = "timeslice", initialwindow = 12, horizon = 12, fixedwindow = FALSE)

# svmLinear
svmGrid_L = expand.grid(C= 2^c(-3:10))
svmLineartune = train(TotalTonnage ~ Population,
  data = training_gkdata,
  method = "svmLinear",
  preProc = c("center", "scale"), #Center and scale data
  tunelength = 10,
  tuneGrid = svmGrid_L,
  trControl = ctrl,
  metric = "Rsquared")
prediction_linear = predict(svmLineartune,test_gkdata)

# svmLinear2
svmGrid_L2 = expand.grid(C= 2^c(-3:10))
svmLineartune2 = train(TotalTonnage ~ Population,
  data = training_gkdata,
  method = "svmLinear2",
  preProc = c("center", "scale"), #Center and scale data
  tunelength = 10,
  tuneGrid = svmGrid_L2,
  trControl = ctrl,
  metric = "Rsquared")
prediction_linear2 = predict(svmLineartune2,test_gkdata)

# svmPoly
svmGrid_P = expand.grid(C= 2^c(-3:10), degree = c(2,3,4,5), scale = 10^c(-5:5))
svmPolytune = train(TotalTonnage ~ Population,
  data = training_gkdata,
  method = "svmPoly",
  preProc = c("center", "scale"), #Center and scale data
  tunelength = 10,
  tuneGrid = svmGrid_P,
  trControl = ctrl,
  metric = "Rsquared")
prediction_poly = predict(svmPolytune,test_gkdata)

# svmRadial
svmGrid_R = expand.grid(C= 2^c(-3:10), sigma= 2^c(-5:9))
svmRbftune = train(TotalTonnage ~ Population,
  data = training_gkdata,
  method = "svmRadial",
  preProc = c("center", "scale"), #Center and scale data
  tunelength = 10,
  tuneGrid = svmGrid_R,
  trControl = ctrl,
  metric = "Rsquared")
prediction_rbf = predict(svmRbftune,test_gkdata)
```

EK 15 FARKLI YÖNTEMLERİN PERFORMANSININ BELİRLENMESİNDE KULLANILAN FONKSİYONLAR VE DVR YÖNTEMLERİ İÇİN GENEL KARGO VERİSİ ÜZERİNDE UYGULANMASINA AİT R SCRIPT KODLARI

Performans Ölçütü Olarak Kullanılan Fonksiyonlara Ait R Script Kodları:

```
# Function that returns Root Mean Squared Error (RMSE)
rmse = function(error)
{
  sqrt(mean(error^2))
}

# Function that returns Mean Absolute Error (MAE)
mae = function(error)
{
  mean(abs(error))
}

# Function that returns Mean Absolute Percentage Error (MAPE)
mape=function(actual,predicted)
{
  mean(abs((actual-predicted)/actual))*100
}
```

Uygulanan Destek Vektör Regresyon Yöntemleri İçin Performans Değerlerinin Hesaplanmasına Ait R Script Kodları:

```
#performance linear
rmse_linear = rmse(test_gkdata$TotalTonnage-prediction_linear)
mape_linear = mape(test_gkdata$TotalTonnage,prediction_linear)
mae_linear = mae(test_gkdata$TotalTonnage-prediction_linear)

#performance linear2
rmse_linear2 = rmse(test_gkdata$TotalTonnage-prediction_linear2)
mape_linear2 = mape(test_gkdata$TotalTonnage,prediction_linear2)
mae_linear2 = mae(test_gkdata$TotalTonnage-prediction_linear2)

#performance poly
rmse_poly = rmse(test_gkdata$TotalTonnage-prediction_poly)
mape_poly = mape(test_gkdata$TotalTonnage,prediction_poly)
mae_poly = mae(test_gkdata$TotalTonnage-prediction_poly)

#performance rbf
rmse_rbf = rmse(test_gkdata$TotalTonnage-prediction_rbf)
mape_rbf = mape(test_gkdata$TotalTonnage,prediction_rbf)
mae_rbf = mae(test_gkdata$TotalTonnage-prediction_rbf)|
```

EK 16 GENEL KARGO VERİSİ ÜZERİNDE UYGULANAN DESTEK VEKTÖR REGRESYON YÖNTEMLERİNİN PERFORMANS SONUÇLARI VE EN İYİ PERFORMANSI VEREN YÖNTEM İLE YAPILAN TAHMİNE AİT R SCRIPT KODLARI

Uygulanan Farklı Çekirdek Fonksiyonları İçin Ortalama Mutlak Hata Değerleri:

| | |
|-------------|------------------|
| mae_linear | 33080.3135415064 |
| mae_linear2 | 33080.3158838079 |
| mae_poly | 36748.4827277242 |
| mae_rbf | 51664.0766210672 |

Uygulanan Farklı Çekirdek Fonksiyonları İçin Ortalama Mutlak Yüzdellik Hata Değerleri:

| | |
|--------------|------------------|
| mape_linear | 9.81092645738376 |
| mape_linear2 | 9.81092718074422 |
| mape_poly | 10.9475271705352 |
| mape_rbf | 15.679427986323 |

Uygulanan Farklı Çekirdek Fonksiyonları İçin Ortalama Karesel Hatanın Karekökü Değerleri:

| | |
|--------------|------------------|
| rmse_linear | 43084.5412283642 |
| rmse_linear2 | 43084.5432722134 |
| rmse_poly | 46313.9218450944 |
| rmse_rbf | 59032.8803840531 |


En İyi Performansı Veren Linear Çekirdek Fonksiyonu İle Gelecek İki Yıl İçin Yapılan Tahmine Ait R Script Kodları

```
# Predict with best model
gk_newdata = read_excel("R Application/Data/Data_GK_ML.xlsx", sheet = "NewData")
prediction_gk = predict(svmLineartune,gk_newdata)
```

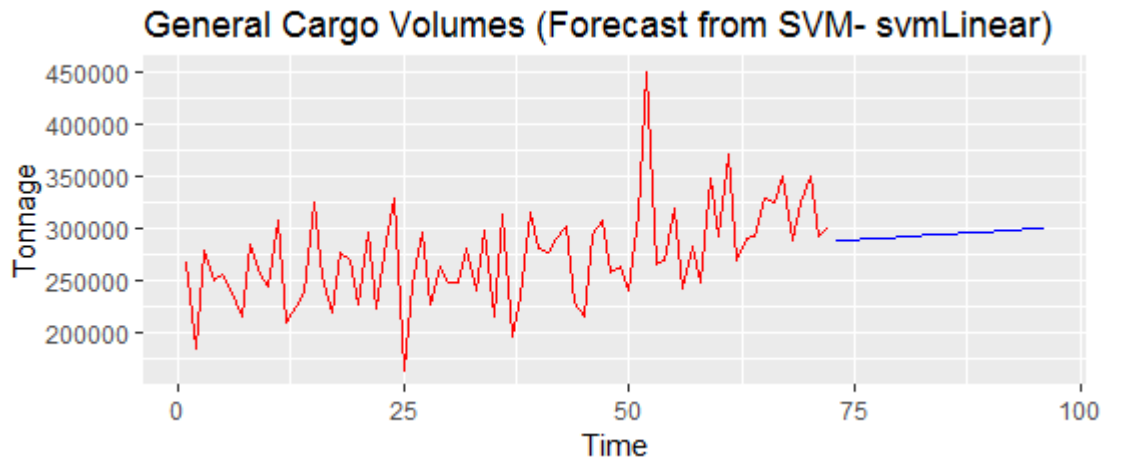
EK 17 GENEL KARGO İÇİN EN İYİ SONUCU VEREN İSTATİSTİKSEL TAHMİN YÖNTEMİ VE DVR YÖNTEMİNİN R STUDIO GRAFİKLERİ

ARIMA:

Forecasts from ARIMA(2,1,2) with drift




DVR (Linear Çekirdek Fonksiyonu):



EK 18 KONTEYNER İÇİN EN İYİ SONUCU VEREN İSTATİSTİKSEL TAHMİN YÖNTEMİ VE DVR YÖNTEMİNİN R STUDIO GRAFİKLERİ


Toplamsal Holt-Winters:

Forecasts from ETS(A,Ad,A)



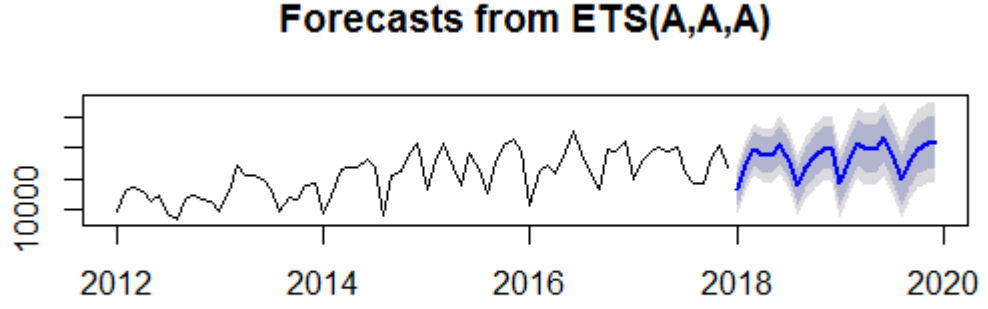
DVR (Radyal Çekirdek Fonksiyonu):

Total TEU (Forecast from SVM- svmRadial)

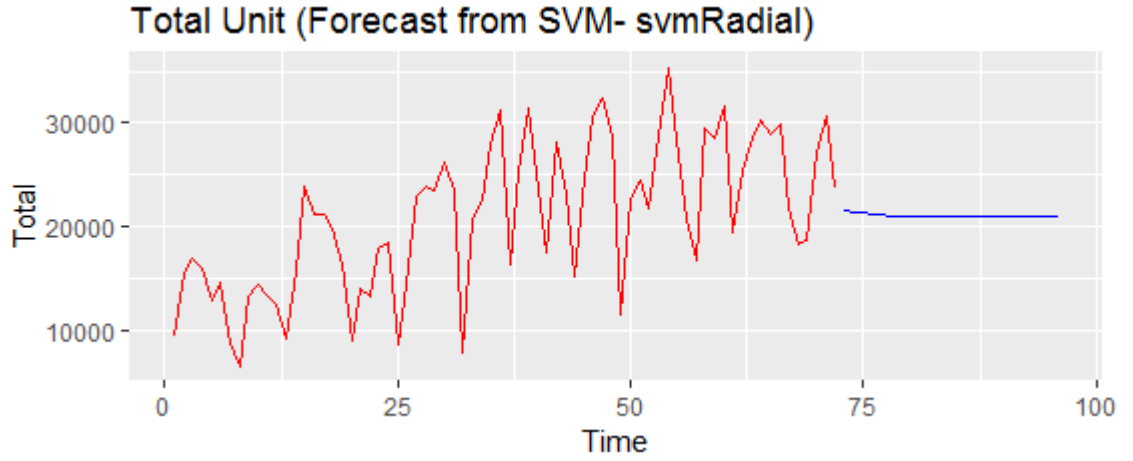


EK 19 ARAÇ İÇİN EN İYİ SONUCU VEREN İSTATİSTİKSEL TAHMİN YÖNTEMİ VE DVR YÖNTEMİNİN R STUDIO GRAFİKLERİ

Toplamsal Holt-Winters:



DVR (Radyal Çekirdek Fonksiyonu):



ÖZGEÇMİŞ

Adı Soyadı : Hande GÜZEY
Doğum Yeri ve Tarihi : Osmangazi 01.03.1989
Yabancı Dil : İngilizce

Eğitim Durumu

Lise : Bursa Kız Lisesi (2003-2007)
Lisans : Ege Üniversitesi, İstatistik (2008-2012)
Yüksek Lisans : Uludağ Üniversitesi, Endüstri Mühendisliği (2014-)

Çalıştığı Kurum/Kurumlar

: Borusan Lojistik (İş Analisti, 2017-)
Yalın Software (Yazılım Geliştirme Uzmanı, 2013-2017)

İletişim (e-posta)

: hndgzy@gmail.com

Yayınları

:

Guzey, H., Akansel, M. 2019. A Comparison of SVM and Traditional Methods for Demand Forecasting in a Seaport: A Case Study. *International Journal of Scientific and Technological Research*, 5(3): 168-176.