

KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

İSTATİSTİK VE BİLGİSAYAR BİLİMLERİ ANABİLİM DALI

HAVA YOLLARI UÇUŞ EKİBİ İHTİYACININ MAKİNE ÖĞRENMESİ
VE ZAMAN SERİSİ MODELLERİ İLE TAHMİNİ

DOKTORA TEZİ

Kaan TOPRAK

MAYIS 2025
TRABZON



KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

İSTATİSTİK VE BİLGİSAYAR BİLİMLERİ ANABİLİM DALI

**HAVA YOLLARI UÇUŞ EKİBİ İHTİYACININ MAKİNE ÖĞRENMESİ
VE ZAMAN SERİSİ MODELLERİ İLE TAHMİNİ**

Kaan TOPRAK

Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsünde

"DOKTOR (İSTATİSTİK)"

Unvanı Verilmesi İçin Kabul Edilen Tezdir.

Tezin Enstitüye Verildiği Tarih : 29 / 04 / 2025

Tezin Savunma Tarihi : 29 / 05 / 2025

Tez Danışmanı : Dr. Öğr. Üyesi Uğur ŞEVİK

Trabzon 2025

ÖNSÖZ

“Hava Yolları Uçuş Ekibi İhtiyacının Makine Öğrenmesi ve Zaman Serisi Modelleri ile Tahmini” isimli bu tez Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsü İstatistik ve Bilgisayar Bilimleri Anabilim Dalı, Doktora Programı kapsamında hazırlanmıştır.

Akademik öğretim hayatım boyunca hiçbir desteğini esirgemeyen ve her zaman kıymetli bilgileriyle ve tecrübesiyle yolumu aydınlatan danışman hocam Sayın Dr. Öğr. Üyesi Uğur ŞEVİK’e teşekkürü bir borç bilirim. Yapıcı eleştirileri ve önerileri ile tezime büyük katkıları bulunan Dr. Öğr. Tolga BERBER ve Prof. Dr. Türkan Erbay DALKILIÇ hocalarıma saygılarımı ve teşekkürlerimi sunarım.

Tez çalışması boyunca desteklerini esirgemeyen İstatistik ve Bilgisayar Bilimleri Bölümü’ndeki tüm değerli hocalarıma teşekkürlerimi sunarım.

Hem veri elde etme aşamasında hem tez boyunca hem de proje sürecinde ellerinden gelen desteği gösteren başta Ekip Planlama Başkanı Sayın Ahmet ACAR’a, Sistem ve Program Geliştirme Müdürü Sayın Ercan Laçın başta olmak üzere Türk Hava Yolları’nda ki kıymetli yönetici ve arkadaşlarıma teşekkürlerimi sunarım.

Hayatım boyunca aldığım tüm kararlarda bilgi ve tecrübelerinden faydalandığım ve her kararında arkamda olan, maddi ve manevi desteklerini hiçbir zaman esirgemeyen ve bugünlere gelmemde en büyük paya sahip olan babam Kani TOPRAK’a, annem Gülhan TOPRAK’a ve ablam Gonca TOPRAK’a teşekkürlerimi sunarım.

Son olarak, hayatıma girdiği andan itibaren elimi hiç bırakmayan, her an yanımda olan, desteğini bir an olsun esirgemeyen, her düştüğümde beni kaldıran değerli yol arkadaşım BÜŞRA TOPRAK’a teşekkür eder minnettarlığımı sunarım.

Bu tez çalışmasının bundan sonraki çalışmalara katkı sağlamasını temenni ederim.

Kaan TOPRAK

Trabzon 2025

TEZ ETİK BEYANNAMESİ

Doktora tezi olarak sunduğum “Hava Yolları Uçuş Ekibi İhtiyacının Makine Öğrenmesi ve Zaman Serisi Modelleri ile Tahmini” başlıklı bu çalışmayı baştan sona kadar danışmanım Dr. Öğr. Üyesi Uğur ŞEVİK’in sorumluluğunda tamamladığımı, verileri/örnekleri kendim topladığımı, deneyleri/analizleri kendim yaptığımı, başka kaynaklardan aldığım bilgileri metinde ve kaynakçada eksiksiz olarak gösterdiğimi, çalışma sürecinde bilimsel araştırma ve etik kurallara uygun olarak davrandığımı ve aksinin ortaya çıkması durumunda her türlü yasal sonucu kabul ettiğimi beyan ederim. 29/05/2025

Kaan TOPRAK

İÇİNDEKİLER

	<u>Sayfa No</u>
ÖNSÖZ.....	III
TEZ ETİK BEYANNAMESİ.....	IV
İÇİNDEKİLER.....	V
ÖZET	VII
SUMMARY	VIII
ŞEKİLLER DİZİNİ.....	IX
TABLolar DİZİNİ.....	XII
SEMBOLLER VE KISALTMALAR DİZİNİ	XIII
1. GENEL BİLGİLER	1
1.1. Literatür Taraması	3
1.2. Makine Öğrenmesi (MÖ)	13
1.3. Makine Öğrenmesi Yöntemleri	14
1.3.1. Karar Ağaçları Tabanlı Yöntemler	15
1.4. Zaman Serisi.....	17
1.5. Kuruluştan Günümüze Türk Hava Yolları	25
1.6. Personel Yapısı.....	25
1.6.1. Uçuş Personeli.....	26
1.7. Uçuş Personeli Hakkında Bilgiler	27
1.7.1. Pozisyon	27
1.7.2. Anaüs (HomeBase)	28
1.7.3. Yetkinlikler	28
1.8. Küresel Havayolu Pazarı	28
1.9. Planlama Süreçleri.....	31
1.10. Planlama Terimleri	31
1.10.1. Aylık Planlama Periyodu	33
1.11. Tezde Kullanılacak Terimler	36
1.12. Tez Aşamaları.....	37
2. YAPILAN ÇALIŞMALAR.....	38
2.1. Modelleme Aşamaları	38
2.2. Analiz Sonuçları	39

2.3. Tahmin Modelleri.....	44
2.3.1. Çalışmada Kullanılan Zaman Serisi Temelli Yöntemler	44
2.3.2. Çalışmada Kullanılan Makine Öğrenmesi Yöntemleri	45
2.4. Başarı Performanslarının Karşılaştırması.....	46
2.4.1. Kaptan Sınıfı Kişi Sayısı Değişkeni İçin Tüm Modellere Ait Karşılaştırmalı Model Sonuçları	48
2.4.2. F/O Sınıfı Kişi Sayısı Değişkeni İçin Tüm Modellere Ait Karşılaştırmalı Model Sonuçları	51
2.4.3. P3 Sınıfı İçin Kişi Sayısı Değişkeni İçin Tüm Modellere Ait Karşılaştırmalı Model Sonuçları	53
2.4.4. Simülatör-Eğitim Değişkeni Tüm Modellere Ait Karşılaştırmalı Model Sonuçları	55
2.4.5. Ofis Değişkeni İçin Tüm Modellere Ait Karşılaştırmalı Model Sonuçları	57
2.4.6. Yıllık İzin Değişkeni İçin Tüm Modellere Ait Karşılaştırmalı Model Sonuçları	60
2.4.7. Filo ve Sınıf Bazlı Tahmin Sonuçları	62
3. BULGULAR VE TARTIŞMA	88
4. SONUÇLAR VE ÖNERİLER.....	93
5. KAYNAKLAR	95
6. EKLER.....	109
ÖZGEÇMİŞ	

Doktora Tezi

ÖZET

HAVA YOLLARI UÇUŞ EKİBİ İHTİYACININ MAKİNE ÖĞRENMESİ VE ZAMAN SERİSİ MODELLERİ İLE TAHMİNİ

Kaan TOPRAK

Karadeniz Teknik Üniversitesi
Fen Bilimleri Enstitüsü
İstatistik ve Bilgisayar Bilimleri Anabilim Dalı
Danışman: Dr. Öğr. Üyesi Uğur ŞEVİK
2025, 108 Sayfa, 15 Sayfa Ek

Covid-19 pandemisinden en çok etkilenen sektörlerin başında havayolu taşımacılığı gelmesine rağmen dünya ekonomisi açısından vazgeçilmez bir konumda bulunmaktadır. Son dönemlerde salgın hastalıklar ve terör olayları nedeniyle zaman zaman ekonomik krizler yaşanmıştır. Pandeminin etkisiyle dünyada çoğu havayolu şirketi küçülmeye gitmesine rağmen uzun vadede büyümesini sürdürmektedir. Pek çok havayolu şirketi için mevcut sefer sayıları ile pandemi öncesi sefer sayıları birbirine benzerlik göstermektedir. Pandeminin hayatımıza girmesiyle birlikte yolcu taşımacılığının yanı sıra havacılıkta kargo taşımacılığı da büyük önem kazanmıştır. Kargo seferlerine artan talep neticesinde uçak sefer sayılarında ki artış açıkça gözükmemektedir. Tüm havayolu şirketleri için artan talepler karşısında uçucu ekip ihtiyacı temel sorun olmuştur. Havayolu şirketleri bu sorunu çözmek için çeşitli çalışmalar yürütmektedir. Yapılan çalışma ile hava yolları için gelecek yıllarda oluşacak ekip ihtiyacı sayısını en etkin şekilde tahminlemesi hedeflenmektedir.

Bu projenin amacı, aşağıdaki çıktıları doğru bir şekilde gerçekleştirmek için makine öğrenmesi yardımıyla bir karar destek sistemi kurarak milli bayrak taşıyıcı havayolu şirketi olan Türk Hava Yolları'nın gelecek yıllar için ekip ihtiyacını tespit etmektir.

Ekip ihtiyacı sayısının tahmin edilmesi ile birlikte, gelecek yıllarda üretim saati, uçak sayısı ve destinasyon vb. değişkenler arttığında, uçuş operasyonlarının tam zamanlı ve eksiksiz olarak gerçekleştirilebilecek, yılın herhangi bir zamanında gelecek olan kargo, charter vb. ek gelir olan seferlerin sorunsuz bir şekilde icra edilebilecek, geçmişe dayalı olarak oluşturulan nöbetçi ekip sayılarının kullanım oranları incelenerek geleceğe yönelik daha optimal sayıda nöbet tahminleyerek hem gereksiz yere açılan nöbet maliyetinden tasarruf etmek hem de mevcut bulunan ekiplerin daha optimal kullanımını sağlanacaktır.

Projede birbirini takip eden üç temel adımdan oluşacaktır. Bunlardan ilki Ekip Planlama Başkanlığı sistemlerinden veri elde etmektir. Şu an kullanılan planlama sistemi geçmişe dönük verileri raporlar halinde planlamacıya sunabilmektedir. Veri elde etmek herhangi bir paket programa ya da kütüphaneye ihtiyaç bulunmamaktadır. Diğer bir adım ise, veri analizidir. Bu adımda elde edilen veri üzerinde Python yazılım dili kullanılarak veri madenciliği işlemleri yapılacaktır. Bu işlemlerin sonucunda analize hazır hale gelecek olan veri üzerinde farklı makine öğrenmesi algoritmaları uygulanacaktır. Uygulanan algoritmalar sonucu elde edilen sonuçlardan en optimal sonucu veren algoritma seçilecektir. Projenin son adımı ise kullanıcılar için arayüz oluşturmak olacaktır. Proje tamamlandıktan sonra elde edilecek yazılım planlamacıların kullanımına sunulacaktır. İlgili kişiler yapacakları çalışmalar ile gelecek yıllar için gerekli ekip sayısını tahmin edecek ve bu hedef doğrultusunda yeni ekipler istihdam edilecek, mevcut ekiplere ihtiyaçlar dahilinde eğitimler planlanarak terfi edilmesi ve gerekli görülen ihtiyacın giderilmesi sağlanacaktır.

Tezde yer alan veri seti ve analiz çıktıları, Türk Hava Yolları gizlilik politikaları ve etik prensipleri gereği değiştirilmiş, anonimleştirilmiş veya temsili şekilde sunulmuştur. Sunulan içerikler, tez çalışmasının bilimsel geçerliliğini etkilemeyecek şekilde hazırlanmıştır.

Anahtar Kelimeler: Yapay zekâ, Makine öğrenmesi, Ekip İhtiyacı, Havacılık

PhD. Thesis

SUMMARY

FORECASTING AIRLINE FLIGHT CREW NEEDS USING MACHINE LEARNING AND TIME SERIES MODELS

Kaan TOPRAK

Karadeniz Technical University
The Graduate School of Natural and Applied Sciences
Statistics and Computer Sciences Graduate Program
Supervisor: Assoc. Prof. Dr. Uğur ŞEVİK
2025, 108 Pages, 15 Pages Appendix

Although airline transportation is one of the sectors most affected by the Covid-19 pandemic, it is indispensable for the world economy. In recent times, economic crises have occurred from time to time due to epidemics and terrorist attacks. Although most airline companies in the world have downsized due to the effect of the pandemic, they continue to grow in the long run. With the introduction of the pandemic into our lives, cargo transportation in aviation has gained great importance as well as passenger transportation. In the face of increasing demands for all airline companies, the need for flight crew has been the main problem. Airline companies are carrying out various studies to solve this problem.

The aim of this project is to determine the team need for the coming years by establishing a decision support system with the help of machine learning in order to correctly realize the following outputs. Along with the estimation of the number of crew needs, when variables such as production hours, number of aircraft and destination increase, flight operations will be able to be carried out full-time and completely in the coming years, Cargo, charter, etc. flights with additional income that will arrive at any time of the year will be carried out without any problems, by examining the usage rates of the number of sentry teams created based on the past, a more optimal number of shifts will be estimated for the future, thereby saving the cost of unnecessary shifts and ensuring a more optimal use of the existing teams.

The project will consist of three successive basic steps. The first of these is to obtain data from the Crew Planning Presidency systems. The currently used planning system can present historical data to the planner in the form of reports. There is no need for any package program or library to obtain data. Another step is data analysis. Data mining operations will be performed using Python software language on the data obtained in this step. As a result of these processes, different machine learning algorithms will be applied on the data that will be ready for analysis. The algorithm that gives the most optimal result will be selected from the results obtained as a result of the applied algorithms. The last step of the project will be to create an interface for users. After the project is completed, the software will be made available to the planners. The relevant persons will estimate the number of teams required for the coming years through their studies and in line with this target, new teams will be employed, training will be planned for existing teams as needed, they will be promoted and the necessary needs will be met.

The dataset and analysis outputs presented in this thesis have been modified, anonymized or represented symbolically in accordance with the Turkish Airline's confidentiality policies and ethical principles. The presented content has been prepared in a way that does not compromise the scientific validity of the study.

Key Words: Artificial Intelligence, Machine Learning, Manpower, Aviation

ŞEKİLLER DİZİNİ

	<u>Sayfa No</u>
Şekil 1. THY A.O. personel yapısı	25
Şekil 2. Kokpit ekip yapısı.....	26
Şekil 3. Uçuş ekibi personel yapısı	27
Şekil 4. Trip örneği	32
Şekil 5. Pairing örneği 1.....	34
Şekil 6. Pairing örneği 2.....	34
Şekil 7. Tez Aşamaları.....	37
Şekil 8. Eksik verileri düzeltilmiş kokpit personeli	39
Şekil 9. Kokpit personelinin sınıf bazlı yıllara göre değişimi	40
Şekil 10. Aylık mevsimsellik deseni.....	41
Şekil 11. Yıllık mevsimsellik ve trend deseni	41
Şekil 12. Genel trend ve mevsimsellik	42
Şekil 13. Çalışma günlerinin yıllık dağılımı	43
Şekil 14. SARIMAX model sonuçları	48
Şekil 15. Prophet model sonuçları	49
Şekil 16. LSTM model sonuçları	49
Şekil 17. LSTM, XGBoost ve Rastgele Orman model karşılaştırılması	50
Şekil 18. SARIMA ve Holt-Winters model karşılaştırması.....	50
Şekil 19. F/O SARIMAX model sonuçları	51
Şekil 20. F/O sınıfı Prophet model sonucu	52
Şekil 21. LSTM, XGBoost ve Rastgele Orman model karşılaştırması.....	52
Şekil 22. P3 sınıfı SARIMAX tahmin sonuçları.....	53
Şekil 23. P3 Sınıfı Prophet model sonuçları	54
Şekil 24. P3 Sınıfı LSTM, XGBoost ve rastgele orman model karşılaştırması.....	54
Şekil 25. Kaptan sınıfı simülatör-eğitim model karşılaştırması.....	55
Şekil 26. F/O sınıfı simülatör-eğitim model karşılaştırması	56
Şekil 27. Kaptan sınıfı ofis model karşılaştırılması	57
Şekil 28. F/O sınıfı ofis model karşılaştırması	58
Şekil 29. Kaptan sınıfı yıllık izin model karşılaştırılması.....	60
Şekil 30. F/O sınıfı yıllık izin model karşılaştırılması	61

Şekil 31.	340 Kaptan sınıfı kişi sayısı model karşılaştırması	62
Şekil 32.	340 Kaptan sınıfı kişi sayısı hata metrikleri	62
Şekil 33.	777 Kaptan sınıfı kişi sayısı model karşılaştırması	63
Şekil 34.	777 Kaptan sınıfı kişi sayısı hata metrikleri	63
Şekil 35.	738 Kaptan sınıfı kişi sayısı model karşılaştırması	64
Şekil 36.	738 Kaptan sınıfı kişi sayısı hata metrikleri	64
Şekil 37.	320 Kaptan sınıfı kişi sayısı tahmin karşılaştırması	65
Şekil 38.	320 Kaptan sınıfı kişi sayısı hata metrikleri	65
Şekil 39.	340 F/O sınıfı kişi sayısı tahmin karşılaştırması	66
Şekil 40.	340 F/O sınıfı kişi sayısı hata metrikleri	66
Şekil 41.	777 F/O sınıfı kişi sayısı tahmin karşılaştırması	67
Şekil 42.	777 F/O sınıfı kişi sayısı hata metrikleri	67
Şekil 43.	320 F/O sınıfı kişi sayısı tahmin karşılaştırılması	68
Şekil 44.	320 F/O sınıfı için kişi sayısı hata metrikleri.....	68
Şekil 45.	738 F/O sınıfı kişi sayısı tahmin karşılaştırılması	69
Şekil 46.	738 F/O sınıfı kişi sayısı hata metrikleri	69
Şekil 47.	738 Kaptan sınıfı ofis tahmin karşılaştırılması.....	70
Şekil 48.	320 Kaptan sınıfı ofis tahmin karşılaştırılması.....	71
Şekil 49.	340 Kaptan sınıfı ofis tahmin karşılaştırılması.....	71
Şekil 50.	777 Kaptan sınıfı ofis tahmin karşılaştırılması.....	72
Şekil 51.	Kaptan sınıfı ofis MAE hata metriği	73
Şekil 52.	Kaptan sınıfı ofis RMSE hata metriği	73
Şekil 53.	Kaptan sınıfı ofis MAPE hata metriği	73
Şekil 54.	777 Filosu F/O sınıfı ofis tahmin karşılaştırılması	74
Şekil 55.	738 Filosu F/O sınıfı ofis tahmin karşılaştırılması	74
Şekil 56.	320 Filosu F/O sınıfı ofis tahmin karşılaştırılması	75
Şekil 57.	340 Filosu F/O sınıfı ofis tahmin karşılaştırılması	75
Şekil 58.	F/O Sınıfı ofis MAE hata metriği	76
Şekil 59.	F/O Sınıfı ofis RMSE hata metriği	76
Şekil 60.	F/O Sınıfı ofis MAPE hata metriği.....	76
Şekil 61.	Kaptan sınıfı yıllık izin MAE hata metriği.....	78
Şekil 62.	Kaptan sınıfı yıllık izin RMSE hata metriği.....	78
Şekil 63.	Kaptan sınıfı yıllık izin MAPE hata metriği.....	79
Şekil 64.	F/O sınıfı yıllık izin MAE hata metriği	80

Şekil 65.	F/O sınıfı yıllık izin RMSE hata metriği	81
Şekil 66.	F/O sınıfı yıllık izin MAPE hata metriği	81
Şekil 67.	Kaptan sınıfı simülatör eğitim MAE hata metriği	83
Şekil 68.	Kaptan sınıfı simülatör eğitim RMSE hata metriği	83
Şekil 69.	Kaptan sınıfı simülatör eğitim MAPE hata metriği.....	84
Şekil 70.	F/O sınıfı simülatör eğitim MAE hata metriği	85
Şekil 71.	F/O sınıfı simülatör eğitim RMSE hata metriği	85
Şekil 72.	F/O sınıfı simülatör eğitim MAPE hata metriği	86



TABLolar DİZİNİ

	<u>Sayfa No</u>
Tablo 1. Makine öğrenmesi yöntemleri	14
Tablo 2. Otoresif model karşılaştırması	22
Tablo 3. Hata metriklerinin karşılaştırılması	23
Tablo 4. Genişletilmiş Dickey Fuller test sonuçları.....	45
Tablo 5. Model hata metrik sonuçları	46
Tablo 6. Kaptan Sınıfı simülatör-eğitim model hata metrik sonuçları	55
Tablo 7. F/O Sınıfı simülatör-eğitim model hata metrik sonuçları.....	57
Tablo 8. Kaptan Sınıfı Ofis model hata metrik sonuçları	58
Tablo 9. F/O Sınıfı Ofis model hata metrik sonuçları.....	59
Tablo 10. Kaptan Sınıfı Yıllık İzin model hata metrik sonuçları.....	60
Tablo 11. F/O Sınıfı Yıllık İzin model hata metrik sonuçları.....	61

SEMBOLLER VE KISALTMALAR DİZİNİ

DHMI	: Devlet Hava Meydanları İşletmeleri
F/O	: Yardımcı Pilot (First Officer)
IATA	: Uluslararası Hava Taşımacılığı Birliği (International Air Transport Association)
KBB	: Kulak Burun Boğaz
MAE	: Ortalama Mutlak Hata (Mean Absolute Error)
MAPE	: Ortalama Mutlak Yüzdesel Hata (Mean Absolute Percentage Error)
MASE	: Ortalama Mutlak Ölçeklendirilmiş Hata (Mean Absolute Scaled Error)
MSE	: Ortalama Kare Hata (Mean Square Error)
P3	: En tecrübeli F/O sınıfı
R ²	: R-Kare
RMSE	: Kök Ortalama Kare Hata (Root Mean Square Error)
SHGM	: Sivil Havacılık Genel Müdürlüğü
SHT-FTL	: Sivil Havacılık Talimatı (Civil Aviation Instructions)
SMAPE	: Ortalama Simetrik Mutlak Yüzdesel Hata (Symmetric Mean Absolute Percentage Error)
THY	: Türk Hava Yolları

1. GENEL BİLGİLER

Havayolu şirketleri açısından en önemli konulardan bir tanesi insan kaynakları yönetimidir. Diğer üretim faktörleri düşünüldüğü zaman insan kaynakları yönetilmesi zor ve çok daha karmaşık bir konudur. İnsan kaynağının yönetilmesi sistemli ve planlı bir şekilde yürütülmesi ile mümkün olabilmektedir.

Örgütün hedeflerine ve yönetsel başarıya en verimli şekilde ulaşmak için atılması gereken ilk adım İnsan Kaynakları Planlamasıdır (İKP) (Bilgin, 2004).

İnsan Kaynakları Yönetiminde (İKY) başarının en temel ve önemli şartı, işletmenin ihtiyaç duyduğu iş gücünün belirlenmesi ve bu iş gücünden nasıl faydalanılacağına önceden planlı ve bilinçli bir şekilde tespit edilmesidir (Sabuncuoğlu, 2008).

İnsan kaynakları planı esas olarak, örgütün gelecekte ihtiyaç duyacağı sayı ve nitelikteki insan kaynaklarını ve bunları hangi yollardan sağlayacağını tahmin etme ve işletmenin insan kaynakları arz ve talebini dengede tutma faaliyetlerini içermektedir (Erdem, 2004).

Diğer bir ifadeyle İKP, örgütün gelecekte gereksinim duyacağı personelin hem nitelik hem de nicelik açısından önceden tespit edilmesi ve bu ihtiyaçların nasıl ve ne ölçüde karşılanabileceğinin planlanma sürecidir (Uçkun & Yüksel, 2007).

İnsan kaynakları planı, örgütün iç ve dış çevresindeki değişimlere karşı esnek olmalıdır. Teknolojik ilerlemeler, sosyo-kültürel değişimler, işgücü piyasasının durumu, yasal düzenlemeler, mahkeme kararları ve politik değişiklikler gibi dinamik koşullara yanıt verebilecek şekilde tasarlanmalıdır (Ünsalan & Şimşek, 2010).

Havayolu şirketlerinin faaliyet alanları oldukça geniş bir yelpazeye sahiptir. Bu faaliyetleri eksiksiz bir şekilde yerine getirebilmek için farklı görevleri yapabilecek personel gereksinimi nedeniyle insan kaynakları yönetimi oldukça karmaşıktır. Havayolu şirket personelleri temel olarak uçucu ve yer personeli olarak ikiye ayrılmaktadır. Uçucu personel ise kendi arasında kabin ve kokpit olarak sınıflanmaktadır. Örneğin Boeing filosunda geniş gövde uçaklarda kaptanlık yapan bir personeli göz önünde bulunduralım. Personel sadece Boeing 777 ve türevleri (77X,77K vb.) uçak tipinde kaptanlık yapabilir. İlgili ekip ek bir eğitim almadan Boeing 787(789) tipinde uçamamaktadır. Bu eğitimin belirli bir maliyeti bulunmaktadır. Burada insan kaynağı yönetimi devreye girmektedir. Eğer ilgili kaptana 787 tipi için eğitim verirsene, ilgili ekibi farklı uçak tiplerinde kullanabilir ve daha fazla gelir elde

etme ihtimalin ortaya çıkabilir. Boeing firmasının en yeni geniş gövde uçaklarından olan 787 uçakları eski 777 uçaklarına göre hem yakıt tasarrufu açısından daha ekonomiktir hem de menzili 777 tipine göre daha fazladır. İnsan kaynağı yönetimi olarak eğitim maliyetinden tasarruf etmek için ekibe simülatör eğitimi vermediğin zaman aslında uzun vadede zarar etmiş olma ihtimalin yüksektir. Bu durum tam tersi için de geçerlidir. Filoda az sayıda 787 tipinde uçak olmasına rağmen bütün Boeing geniş gövde kaptanlarına eğitim vermek şirket için ek maliyet oluşturacağı anlamına gelmektedir. Bu gibi konuların sorunsuz bir şekilde yerine getirilebilmesi için insan kaynakları yönetiminin etkin ve planlı bir şekilde yürütülmesi gerekmektedir.

İnsan gücü havayolu şirketleri başta olmak üzere birçok şirketin sahip olduğu en önemli değerdir. Bu nedenle Ekip ihtiyacı ile ilgili planlama yapılması işletmeler için en önemli konuların başında gelmektedir. Durum böyle olunca, ekip ihtiyacı verimlilik, rekabet, çalışan memnuniyeti ve işletme karlılığı açısından oldukça büyük bir önem taşımaktadır.

Ekip maliyetleri, havayolları için en büyük giderlerden biridir ve bu nedenle, kârı maksimize etmek için etkili insan gücü planlaması önemlidir. Tüm havayolu şirketleri için en önemli konulardan bir tanesi ekip ihtiyacıdır. Ekip ihtiyacını tam anlamıyla planlayabilmek hem uçuşları sorunsuz yapabilmek hem de ekip maliyetlerini minimumda tutabilmek için büyük önem arz etmektedir. Burada dikkat edilmesi gereken konulardan bir tanesi de ekip maliyetini minimize etmeyi amaçlarken ekip bulunmaması nedeniyle uçağın yerde kalması (tehir, iptal vb.) Havayolu şirketlerini ciddi zarara uğratmaktadır. Bu konuda dikkat edilmesi gereken bir diğer husus ise nöbetçi (ev veya alan nöbeti) ekip sayılarıdır. Nöbetçi sayısı planlanırken kendi içerisinde dikkat edilmesi gereken bazı durumlar vardır. Örneğin, nöbetçi ekip sayısını fazla tutulduğu halde kullanılan nöbetçi ekip sayısının az olması ya da bu durumun tam tersi, nöbetçi ekip sayısını minimum da tutularak, uçak için yeterli ekip sayısı bulunamaması sebebiyle uçağın yerde kalması ve şirketlere ekstra maliyet oluşturmaktadır.

İnsan kaynakları konusundaki etkin planlama, kurumun ihtiyaç duyduğu insan kaynağının sağlanması ve geliştirilmesine ilişkin çalışmalar yapar. Bu çalışmalar işletmenin içindeki gelişmeler kadar dışındaki gelişmeleri de içerir. Eğitim ve gelişme ihtiyacı planlamanın önemli bir bileşkesini oluşturur. Plansız bir insan gücü hantal bir kurumsal yapıya neden olabilir (Yumuşak & Kışlalıoğlu, 2008).

1.1. Literatür Taraması

Birçok insan gücü planlama modeli yaşın normal dağıldığını varsaymaktadır. Chirumamilla Shivanagaraju ve arkadaşlarının yaptığı çalışma da beta dağılımının yaşa uygunluğunu araştırmışlardır. Bir veri setinde insan gücü yaşı beta dağılımını takip ettiğinde emeklilik olasılığını ve emeklilik oranını dinamik olarak hesaplamak için bir yaklaşım geliştirmişlerdir. Basit bir insan gücü planlama sistemi dinamiği modeli çerçevesinde iki dağılımın karşılaştırmalı değerlendirmesini yapmış ve insan gücüne ilişkin çeşitli değişkenlerin beta dağılımlı yaş için normal dağılımlı yaşa göre daha makul değerler varsaydığını göstermişlerdir. Bu makalede, zaman ölçeğinde terfi, zaman ölçeği ve liyakate dayalı terfinin bir kombinasyonu ve farklı yaş gruplarındaki kişilerin işe alınması için modelleme yaparken, beta-dağıtılmış yaş varsayımının hiçbir zorluk yaratmadığını ortaya koymuşlardır (Shivanagaraju vd., 1998).

“İnsanlar Sayesinde Rekabet Avantajı” isimli bir makalede Southwest Havayolları’nın insan kaynaklarına verdiği önemin şirket başarısına etkisi özellikle vurgulanmaktadır (Fisher, 1999).

İnsan gücü Vardiya planlaması ile ilgili yapılan bir araştırma da A.G. Lagodimos ve V. Leopoulos bir gıda imalat şirketinin personel planlama problem incelemişlerdir. İnsan gücü Vardiya planlaması olarak adlandırılan problem, belirli bir planlama periyodu boyunca günlük minimum iş gücünü tespit etmede kullanmışlardır. Tam sayılı doğrusal programlama olarak formülize edilen problem için iki Greddy Heuristic algoritma önermişlerdir. Elde edilen sonuçlar hem kalite hem de performans açısından tatmin edici sonuçlar ortaya çıkarmıştır (Lagodimos & Leopoulos, 2000).

Hemşire insan gücü planlamasında; geleneksel yöntemler, trend analizi, hasta sınıflandırma sistemleri, bakım kriterleri yaklaşımı, iş yükü analizi gibi çeşitli metotlar uygulanmaktadır. Sadece yatak ve hasta sayısına dayanarak hemşire iş gücü planlaması yapmak, doğru sonuçlar elde etmek için yeterli olmayacaktır (Yıldırım, 2002).

Ta-Hui Yang ve arkadaşlarının yaptıkları çalışma da ise bir havayolunun bakım insan gücü tedarikini etkin bir şekilde yönetebilmesi için çeşitli esnek stratejiler içeren bir model sunmuşlardır. Model, ticari bir yazılım paketi olan CPLEX kullanılarak çözülen karma tam sayılı bir program olarak formüle edilmiştir. Model performansını değerlendirmek için Tayvan’ın önde gelen havayolu şirketlerinden birinin işletme verilerini kullanmışlardır. Modeli, esnek vardiyalar için tüm gereksinimleri ve talepleri karşılarken, toplam bakım

insan gücü arzını en aza indirme hedefiyle, karma tamsayılı bir program olarak formüle etmişlerdir. Ön test sonuçlarına göre, bu tür esnek stratejilerin insan gücü düzenlemesi açısından etkili olduğu kanıtlanmışlardır (Yang vd., 2003).

Hastaların bakım gereksinimlerini göz önünde bulundurarak, ihtiyaç duyulan sağlık personeli sayısını belirlemek, maliyet hesaplamalarını yapmak ve bütçe oluşturmak amacıyla, zaman etüdüne dayalı insan gücü planlama yöntemleri kullanılmaktadır (Yıldırım & Yılmaz, 2004).

Havayolu kısa vadeli bakım insan gücü tedarik planlaması hakkında yapılan bir çalışma da ise bir matematiksel programlama modeli geliştirmek için üç esnek yönetim stratejisi ve ilgili işletme kısıtlamaları ile birleştirilmiş birden fazla türde uçak bakım sertifikasına sahip teknisyenleri ele almışlardır. Karma tam sayılı programlar olarak formüle etmişlerdir. Önerilen modellerin problem boyutlarının gerçek uygulamalarda çok büyük olması nedeniyle, problemleri etkin bir şekilde çözebilecek bir çözüm algoritması geliştirmişlerdir. Tüm problemlere çözüm bulmak için matematiksel programlama çözücüsü CPLEX'i kullanmışlardır. Araştırma sonuçlarını Tayvan'ın önde gelen havayolu şirketlerinden birinin işletme verilerini kullanarak bir örnek olay çalışması gerçekleştirmiş ve önerilen modellerin ve çözüm algoritmasının hem verimli hem de etkili olduğunu göstermişlerdir (Yan vd., 2004).

Literatürde insan gücü ile ilgili Shabbar Jaffry ve Nick Capon Donanma insan gücü planlamasında riskleri tahmin etmenin alternatif yöntemleri adlı çalışmayı yapmışlardır. Çalışma Birleşik Krallık Deniz Kuvvetleri'nin örnek olay incelemesini kullanarak, riski insan gücü planlamasına dahil etmek için niteliksel ve niceliksel yöntemleri karşılaştırmayı hedeflemişlerdir. Araştırma sonucunda Tarihsel verilerin mevcut olmaması nedeniyle kullanımı kısıtlanabilir ve sınırlı sayıda açıklayıcı değişkene aşırı güvenme tehlikesi ile karşılaşmışlardır (Jaffry & Capon, 2005).

Yan ve arkadaşları yaptıkları çalışma da farklı insan gücü tedarik ilkelerini, esnek yönetim stratejilerini ve ilgili işletme kısıtlamalarını birleştiren dört stratejik model, bir hava kargo terminalinin uzun vadeli insan gücü tedarikini daha etkin bir şekilde yönetmesine yardımcı olmak için geliştirmişlerdir. Modeller, bir matematiksel programlama çözücüsü kullanılarak çözülen tam sayılı/karışık tam sayılı doğrusal programlar olarak formüle edilmiştir. Modellerin pratikte nasıl performans gösterdiğini değerlendirmek için Tayvan'daki bir yurt içi hava kargo terminalinin işletim verilerini kullanan bir örnek olay

çalışması yapılmıştır. Ön test sonuçları, dört modelin verimli ve etkili olduğunu ve gerçek operasyonlara uygulanabileceğini göstermişlerdir (Yan vd., 2006).

Hastane insan gücü planlaması üzerine yapılan bir diğer çalışma da ise Gülhane Askeri Tıp Akademisi radyoloji Anabilim dalında gözlem tekniği ile uzman, teknisyen ve sekreter faaliyetleri değerlendirilmiş ve yapılan gözlemlere dayalı iş yükü hesaplamaları sonucunda kaç ekip ihtiyacı olduğu ve kaç ekip fazladan istihdam edildiği tespit edilmiştir (Cankul, 2006).

Samuel Taiwo yaptığı çalışma da işe alınacak insan gücünün etkin boyutunun belirlenmesinde tam sayılı programlamaya dayalı Doğrusal Programlama (LP) modelini uygulamıştır. Çalışma ayrıca, gelişmekte olan ülkelerdeki üretim organizasyonlarındaki gerçeklik faaliyetlerini yansıtmak için üretim kapasitesi/talep oranı ve izin verilen çalışma süresi gibi küresel kısıtlamaları da modele dahil etmiştir. Elde edilen sonuçlar, etkili insan gücü belirlemede modelin mevcut modele göre daha verimli olduğunu göstermiştir (Akinyele, 2007).

Afet Acil Müdahale Dönemleri için İnsan gücü Planlaması ile üzerine yapılan çalışmada, afet müdahalesinde en kritik kaynaklardan biri olan insan gücünün planlanması ve planlama süreçlerini etkileyen faktörlerin belirlenmesi amaçlanmıştır (Doğan, 2007).

Asa Holm yaptığı tez çalışmasının da havayolları için insan gücü planlaması konusunda çalışmıştır. Sunduğu modeller SAS Scandinavian Airlines firmasında yapılan manuel işlem sonuçları ile karşılaştırılmış ve geliştirdiği modelin %10 tasarruf sağladığı görülmüştür (Holm, 2008).

Satış sonrası destek insan gücü ile ilgili yapılan bir çalışma da Qunhong Tang ve arkadaşları personel seviyesi, seyahat mesafesi ve zamanında hizmet verilen müşterilerin yüzdesi arasındaki ilişkiyi incelemek için bir simülasyon modeli geliştirmişlerdir. Sayısal sonuçlar, önerdikleri seyahat mesafesi yaklaşım modelinin, klasik “karekök yasası”ndan ve literatürdeki diğer modellerden çok daha iyi performans gösterdiğini göstermişlerdir (Tang vd., 2008).

Connie Zheng ve Mei-Chih Hu yaptıkları çalışma da Singapur ve Tayvan'daki ekonomik yeniden yapılanma kapsamında bilgi, iletişim ve teknoloji sektörünün geliştirilmesine yönelik insan gücü planlamasına ilişkin konuları ele almışlardır. İki ülkede faaliyet gösteren 211 çok uluslu şirketten toplanan verileri kullanarak, çok uluslu şirketlerin yaşadığı işe alım zorluklarını ve yıpranma oranını ölçmüş ve ankete katılan şirketler arasındaki bilgi, iletişim ve teknoloji beceri eksikliklerinin boyutunu değerlendirmişlerdir.

Ülkenin teşvik ettiği bilgi, iletişim ve teknoloji insan gücü planlaması ve gelişiminin, genel olarak firma düzeyinde işe alım zorluklarını hafifletme üzerinde bazı etkileri olduğunu göstermişlerdir (Zheng & Hu, 2008).

V.A. Dimitriou ve N. Tsantas yaptıkları çalışma da İnsan gücü planlamasında eğitim ve işe alım kararları için zamana bağlı Markov modelinin geliştirilmesini hedeflemişlerdir.

Asimptotik davranışını incelemek için GAMM adı verilen gelişmiş hiyerarşik insan gücü planlama modelini kullanmışlardır (Dimitriou & Tsantas, 2010).

Havaalanı bagaj hizmetinin insan gücü planlaması için hedef programlama modelleri ve Karar Destek Sistemleri üzerinde yapılan bir çalışma da ise, Hong Kong Uluslararası Havalimanı'nda ki bagaj Hizmeti acentesin için insan gücü planlamasının çeşitli hedef kombinasyonlarına yaklaşmak için temel sabit uzunlukta vardiya görevleri oluşturma modeline dayalı üç model formülasyonu önerilmiştir. Araştırma sonucu elde ettikleri sonuçlar hizmet sağlanan firma tarafından beklenen olası iyileştirme sonuçlarıyla örtüşmüştür (Chu vd., 2010).

Havayolları için yapılan bir diğer tez çalışmasın da Thalen tabu arama tabanlı bir model geliştirmiştir. Elde edilen model Scandinavian Airlines verileri üzerinde test edilmiştir. Ticari karma tam sayılı programlamayı temel alan referans bir algoritma karşılaştırıldığı zaman tabu arama algoritması benzer çözümlere yaklaşık 30 kat daha hızlı sonuç bulmuştur (Thalen, 2010).

Yapılan bir diğer çalışma da ise çeşitli talep modelleri altında sağlık işgücü arzına yönelik dinamik kapasite artırma stratejileri incelenmiştir. Simülasyon deneyleri üç olası strateji altında gerçekleştirilmiştir. Sınırsız kapasite, kapasite artırımı yapılmadan sınırlı kapasite ve kapasite artırımı ile sınırlı kapasite. Bu aşamadaki amaç, üç uç stratejiden en uygun temel stratejiyi seçmek ve değerlendirmeden faydalı bilgiler elde etmektir. Simülasyon çalışmaları, beş girdi talebi (Dalgalandan, İstikrarlı büyüyen, S şeklinde, adım adım, dalgalanan ve istikrarlı büyüme kombinasyonu) modeli için 160 çeyreklik bir süre boyunca gerçekleştirilmiştir. Geliştirilen model, yöneticilerin çeşitli talep senaryoları altında uygulanabilir alternatif politikaları tahmin etmelerini ve değerlendirmelerini sağlamak için kapasite artırma stratejilerini simüle edebilmektedir. (Mutingi & Mbohwa, 2012).

Yapılan bir diğer çalışma ise işyeri hekimliğinde insan gücü planlaması için iş analizi ve simülasyon yaklaşımıdır. Bu çalışmada Türkiye'de olması gereken işyeri hekim sayıları farklı yaklaşımlar ile tahmin edilmeye çalışılmıştır (Yılmaz, 2012).

Yataklı tedavi kurumlarında hemşire iş gücü planlama yöntemleri üzerine yapılan çalışmadan elde edilen sistem, ülkemizdeki hastanelerin her biriminde ihtiyaç duyulan hemşirenin hemşire sayısını belirlemektedir (Bal, 2012).

İnsan gücü planlaması makro ve mikro planlamayı kapsamaktadır. Bu planlama, insan gücü arzı, ihtiyaçları, dağılımı ve görev tanımlarını içerirken, aynı zamanda planlama, yönetim ve kontrol süreçlerini de barındırır. Bu süreçler, birbirini takip eden ve birbirine bağlı bir dizi etkileşim zincirinden oluşur. Mevcut durum analizi, gerekli verilerin toplanması ve uygun stratejilerin geliştirilmesi, bu sürecin kritik aşamalarıdır (Şantaş vd., 2012).

Kateryna Kryshkevych Ukrayna Uluslararası Havayolları'nın bakım departmanı için gerekli teknisyen sayısını ve onların vardiya programlarını sağlamak için stratejik insan gücü planlamasına yönelik esnek bir model geliştirmiştir (Kryshkevych, 2013).

Klinikler hastaların yataklı olarak tetkik, tedavi ve bakım süreçlerinin gerçekleştirildiği servislerdir. Hastanelerin büyüklüğünü belirlemede kliniklerin yatak sayısı önemli bir faktördür. Hastalar, poliklinik, acil servis ve diğer kliniklerden gelerek yatırılmaktadır. Kliniklerin işleyişi genel olarak benzer olsa da cerrahi klinikler ile diğer klinikler arasında hasta teşhis ve tedavi süreçlerinde farklılıklar olabilmektedir (Çetik & Oğulata, 2014).

İnsan gücü planlamasında yapılan bir diğer çalışmayı ise Sudhakar Vundavalli Hindistan'da dişçilik insan gücü planlaması: 2020 yılı için mevcut senaryo ve gelecek projeksiyonları isimli çalışma ile yapmıştır. Hindistan'da diş hekimi/nüfus oranı 1:10.271 olmasına rağmen, yeni mezun diş hekimleri özel sektörde hayatta kalmakta zorlanıyor. Mevcut durum devam ederse, 2020 yılına kadar yüz binden fazla diş hekimi arz fazlası olacak. Mevcut durumun devam etmesi, yüksek düzeyde eğitilmiş diş hekimliği insan gücünün israfına yol açacak ve diş hekimlerinin mesleki dürüstlüğüne yönelik bir tehdit oluşturacaktır. Bu araştırma, diş hekimliği insan gücünün arz ve talebini kontrol etmek, insan gücünün tekdüze bir dağılımını sağlamak ve politika yapıcılara geleceğe yönelik yönler vermek için organize bir ulusal insan kaynakları planlama sistemine acil ihtiyaç olduğu gerçeğini vurgulamaktadır. Yaptıkları araştırma sonucunda, 2030 saatlik yılında diş hekimi nüfus oranının 1:13.239 olduğunu ve ihtiyaç duyulan toplam diş hekimi sayısının 91.411 olacağını göstermişlerdir. Hastaların efektif talebine dayalı insan gücü gereksinimlerinin sonuçlarına göre ise 2030 yılında diş hekimi nüfus oranı 1:18.738, toplam ihtiyaç duyulan diş hekimi sayısı ise 64.592 olacaktır (Vundavalli, 2014).

Ülkemizde Ekip İhtiyacı; Atalay, “Kliniklerin Kapasite Yönetiminde ve İnsan Gücü Planlamasında Zaman” adlı çalışmada, mevcut ve potansiyel insan gücü ile kaynakların maliyetlerinin doğru planlanabilmesi için bir yöntem geliştirmiştir. Araştırma sonucunda zamana dayalı faaliyet tabanlı maliyetlemenin işletme yönetimine maliyet ve insan gücü planlamasında önemli katkılar sağladığı sonucuna varmıştır (Atalay, 2015).

Literatürde ekip ihtiyacı ile ilgili yapılmış çalışmalar incelendiğinde, İstanbul Üniversitesi Cerrahpaşa Tıp Fakültesi KBB kliniğinde hemşire insan gücü planlaması ile ilgili bir çalışma yapılmıştır. Yapılan çalışma da iş yüküne dayalı olarak personel ihtiyacı belirleme yöntemi kullanılmıştır. Gündüz ve gece vardiyası olarak iki kısımda yürütülen çalışma mevcut olan ve aslında olması gereken hemşire sayısı karşılaştırılmıştır (İşçi, 2009). Yapılan bir diğer çalışma ise, Markov Zinciri ile İnsan Gücü Planlaması hakkındadır. Gerçekleştirilen çalışmada, kamu kurumlarının yetmişmiş personel eksikliği yaşamaması için geleceğe yönelik olarak projeksiyonlar geliştirilmiştir. Bu projeksiyonların oluşturulmasında yöntem olarak yöneylem araştırması tekniklerinden Markov Analizi kullanılmıştır (Köse vd., 2015).

Yapılan bir diğer çalışma ise, Türkiye’de Hemşirelik Eğitimi ve İnsan Gücü Planlamasına bakış üzerinedir. Devlet Planlama Teşkilatı’nın 2018 yılı için belirlediği hemşire insan gücü hedefine ulaşılabilmesi için 2014 ÖSYM okul kontenjanlarının %35 oranında artırılması gerektiği tespit edilmiştir (Kıran vd., 2015).

Mengqiao Yu ve arkadaşlarının ABD-Kanada’nın sınır geçişlerinden biri için güvenlik taramasından ödün vermeden zaman gecikmesini azaltmak amacıyla araçların varış oranlarının zamana göre nasıl değiştiğini ve stant başına hizmet oranının günün saatine ve aktif stant sayısına göre önemli ölçüde değişiklik gösterdiğini tespit etmek için bir araştırma yapmışlardır. Çalışma da bu verileri yakalamak ve ampirik verileri kullanarak model parametrelerini çoklu doğrusal regresyon kullanarak tahmin etmek için zamanla değişen bir kuyruk modeli önermişlerdir. Araştırma sonucunda, sınır personelinin toplam çalışma saatlerini artırmadan, ortalama gecikme açısından mevcut programa göre yaklaşık %18 oranında iyileştiğini ortaya koymuşlardır (Yu vd.,2016).

Massimo Di Francesco ve arkadaşları yaptıkları çalışma da aktarma konteyner terminallerine ilişkin kısa vadeli insan gücü planlama problemini incelemişlerdir. Modellemeyi tam sayılı doğrusal programlama formülasyonu ile yapmışlardır. Modelin optimal çözümleri, gerçek bir aktarma konteyner terminalinin benimsediği insan gücü politikasına uygun olarak alınan kararlarla karşılaştırılmışlardır. Hesaplamalı testler ile,

büyük aktarma konteyner terminalleri durumunda bile modelin en iyi şekilde çözülebileceğini göstermişlerdir (Francesco vd., 2016).

Genevieve Huedenu ve arkadaşları yaptıkları çalışmada Gana'nın Batı Bölgesindeki seçilmiş eğitim müdürlüklerinin insan gücü planlama faaliyetlerinin değerlendirilmesini hedeflemişlerdir. İlçelerdeki öğretmen ve öğretmen dışı personel ile ilçe müdürlüklerindeki memurlardan oluşan toplam 400 kişiden 180 kişilik örneklem seçmişlerdir. Hizmet koşulları, uygun çalışma ortamları, değerlendirme politikaları, düzensiz göreve başlama eğitimi ve kurumsal hedeflerin personel ihtiyaçları doğrultusunda düzenli olarak gözden geçirilmesi gibi sorunlar çözülmezse, insan gücü planlama faaliyetlerinin azalacağı sonucuna varmışlardır (Huedenu vd., 2018).

Doğumhanede çalışan ebeler için iş yükü analizine dayalı insan gücü planlamasına ilişkin yapılan çalışmada, Kocaeli ilindeki kamu hastanelerinde çalışan ebe sayısının yetersiz olduğu anlaşıırken, il genelindeki hastaneler arasında belirlenen standartları karşılamak için gerekenden fazla ebe istihdam edildiği anlaşılmıştır (Özkan & Uydacı, 2018).

Hendro Wicaksonoa ve Tianran Nia siparişe bağlı üretim şirketlerinde insan gücü hakkında yaptıkları çalışma da otomatik insan gücü modeli önermişlerdir. Yaklaşım, veri işleme ve analizini otomatikleştirmek için bir yazılım aracı olarak uygulanıyor ve bu, ilgili veri operasyon çabalarını ve planlama süresini önemli ölçüde azaltmaya yardımcı oluyor. Yapılan çalışmayı küçük bir siparişe bağlı imalat şirketindeki gerçek bir üretim biriminde test etmişlerdir. Şirketin uygulama sonucu, geliştirilen modelin, üretim planlamasına gelecekte kapasiteyi ayarlamak için gerekli önlemleri almak için yeterli zamana sahip olmasına yardımcı olduğunu göstermişlerdir. (Wicaksono & Ni 2020).

Gang Du ve Jingjing Zhang yaptıkları çalışma da Çin'de mevcut hemşirelik personelinin hizmet yeteneklerini tam olarak kullanacak şekilde düzenlenmesi önemlidir. Bu makale de bir günlük planlama periyodun da stokastik hizmet sürelerine sahip bölgeler arası çizelgeleme ve rotalama problemi için karma tam sayılı doğrusal programlama modeli önermişlerdir. Hasta zaman pencereleri, çalışma süresi düzenlemeleri, görev önemi ve beceri eşleştirme dahil olmak üzere bir dizi olası gerçekçi kısıtlama dikkate almışlardır Sorunun karmaşıklığından dolayı modeli çözmek için Hybrid Simulated Annealing Simülasyon algoritması tanıtılmıştır. Belirsizlik maliyetinin değerlendirilmesinde ise Monte Carlo simülasyon yöntemi kullanmışlardır. Sayısal örnek testler ile önerdikleri algoritmanın etkinliğini doğrulamışlardır (Du & Zhang, 2022).

Xin Wen ve arkadaşları çok sınıflı kabin ekipleri için bireysel planlama yaklaşımı benimseyen ve insan gücü ve maaliyeti azaltmayı hedefleyen analitik bir çalışma yapmışlardır. Önerilen bireysel eşleştirme modelinin ayırt edici özelliklerini Hong Kong merkezli bir havayolu şirketinin küçük ölçekli uçuş programları ile test etmişlerdir. Buna ilave olarak da geleneksel modele göre, genetik algoritmanın insan gücü kullanımının ve maliyetin azaltılması açısından avantajlarını incelemişlerdir (Wen, 2022).

Türkiye’de Sağlık sektöründe yapılan bir insan gücü araştırmasında çocuk acil servis hizmetlerinin Covid-19 pandemi sürecinde iş yükü ve insan gücü planlaması araştırılmıştır. 187 hemşireden veriler toplanmıştır. Ankete katılanların büyük çoğunluğu hemşire başına düşen hasta sayısının vardiyada çok fazla olduğunu, hemşire sayısının iş yüküne oranla yetersiz olduğunu, hemşirelik insan gücü planlamasının yetersiz ve taraflı olduğunu belirtmiştir (Kaya & Dalgıç, 2022).

Yapılan bir diğer çalışma da ise Suryana Sumantri ve arkadaşları nitel yaklaşımla betimsel araştırma yöntemi uygulamışlardır. Olguların gözlemlenmesine ve bir olgunun anlamının özünün incelenmesine vurgu yapan nitel bir yaklaşım kullanmaktadırlar. Bu yöntem, bir olgunun "ne (ne)", "nasıl (nasıl)" veya "neden (neden)" sorularına yanıt vermek için seçmişlerdir. Araştırma araçları gözlem, görüşme rehberleri ve anahtar araçlar olarak araştırmacılar. Yapılan çalışmanın sonucunda İstihdam yaklaşımı veya İnsan Gücü

Planlama Yaklaşımı Meslek Liselerinde kullanıma çok uygun olduğu sonucuna varmışlardır (Sumantri, 2023).

SARIMAX ile yapılan çalışmalar incelendiği zaman, Gıda sektöründe yapılan bir çalışmada ise, günlük gıda perakende satışları SARIMAX yöntemi ile tahmin edilmiştir.

Modelin, satışları etkileyen dışsal etkilerle daha iyi sonuç elde ettiği gösterilmiştir (Arunraj vd. 2016).

Elektrik ile ilgili yapılan başka bir çalışmada, elektrik piyasasında gün öncesi fiyat tahmini için SARIMAX yöntemi kullanılmıştır. Modelin mevsimsel bileşenleri de dikkate alarak yaptığı tahminlerin önemli ölçüde iyileştiği gösterilmiştir (McHugh vd. 2019).

ABD’de yapılan bir diğer çalışmada ise, elektrik talebi için SARIMAX modeli uygulanmıştır. Model, mevsimsel bileşenler ve dışsal değişkenler ile daha yüksek doğruluk ile tahmin yaptığı görülmüştür (Shadkam, 2020).

Manigandan ve arkadaşları yaptıkları çalışmada ABD’de doğalgaz üretimi ve tüketiminin SARIMAX modeli ile tahmin etmeye çalışmışlardır. Modelin mevsimsel

verilerle başarılı tahminler yaptığı görülmüştür fakat değişkenlik yüksek olduğunda doğruluğun azaldığını tespit etmişlerdir (Manigandan vd., 2021).

Ampountalas ise günlük otel talebi ile ilgili yaptığı çalışmada, SARIMAX, yapay sinir ağları ve GARCH modellerini karşılaştırmıştır. SARIMAX modeli diğer yöntemler ile karşılaştırıldığında daha yüksek doğruluk ile tahmin yaptığı belirtilmiştir (Ampountalas, 2021).

Verhoeven ve arkadaşlarının yaptığı çalışmada, Covid-19 süresinde Avrupa'dan ABD'ye Hava Kargo talebinin kısa vadeli tahmini için SARIMAX modelini kullanmışlardır. Model, ekonomik değişkenler (yakıt, pandemi kısıtlamalar vb.) eklendiğinde daha yüksek doğruluk ile tahmin yaptığı gözlemlenmiştir (Verhoeven vd., 2021).

Makine öğrenmesi ve zaman serisi modeli kullanılarak Küresel Yatay Işınım (Global Horizontal Irradiance -GHI) tahmini için hibrit bir model önermişlerdir. SARIMAX modeli, geçmiş verilerden bağımsız olarak mevsimselliği iyi yakalarken, Rastgele Orman modeli hava durumu değişkenlerini (nem, sıcaklık vb.) kullanarak tahmin doğruluğunu artırmıştır. Hibrit modelin kullanılması, yalnızca zaman serisi veya yalnızca makine öğrenmesi modeline dayanan tahminlere göre daha yüksek doğruluk sağladığı görülmüştür. (Shabbir & Chatuvedi, 2022).

Yapılan bir diğer çalışmada ise, Hindistan'ın Ahmedabad şehrinde SARIMAX modeli kullanılarak sıcaklık tahminleri yapılmıştır. Model, mevsimler verilerde yüksek doğruluk ile tahmin yapıldığı gözlemlenmiştir (Swain vd., 2024).

Mulla ve arkadaşları aylık yağış tahminleri ile ilgili yaptıkları çalışmada, mevsimsel değişkenlerin yağış tahmini üzerindeki etkisini analiz etmişlerdir. SARIMAX modelinin aylık yağış verilerini tahmin etmede başarılı olduğu belirtilmiştir (Mulla vd. 2024).

Ülkemizde SARIMAX ile ilgili yapılan çalışmalar incelendiğinde, Karcioğlu ve arkadaşlarının yaptığı çalışmada Covid-19 vaka sayılarının SARIMAX modeli ile tahminlemesi yapılmıştır. Model, mevsimsel dalgalanmaları da hesaba katarak pandeminin gidişatını tahmin etmede etkili olduğu belirtilmiştir (Karcioğlu vd., 2021).

Türkiye'deki elektrik tüketimi ile ilgili yapılan çalışmada ise, SARIMAX modeli kullanarak, mevsimsel etkilerle birlikte elektrik tüketimindeki artış ve azalış eğilimleri analiz edilmiştir (Nebati vd., 2021).

Tekin ve Sarı yaptıkları çalışmada perakende sektöründe mağaza bazlı talep tahmini için SARIMAX modeli ile topluluk öğrenmesi teknikleri karşılaştırılmıştır. SARIMAX

modelinin mevsimsel deęişimleri ve dıřsal faktörleri daha iyi yakaladıęı belirlenmiřtir (Tekin & Sarı, 2022).

Tarım Kredi Kooperatifleri için Kömür Satıř Tahmini isimli alıřmada ise SARIMAX modelinin mevsimsel olmayan bileřenleri ve dıř deęiřkenleri ieren bir yapıya sahip olduęu vurgulanmıř ve Türkiye’deki kömür satıřlarının tahmininde kullanımı incelenmiřtir (Acar, 2022).

Mevsimsel ARIMA (SARIMAX) ve Yapay Sinir Aęları ile Fiyat Tahmini isimli makalede ise, paslanmaz elik fiyatlarının tahmini için SARIMAX modeli, LSTM ile karřılařtırılmıřtır. Mevsimsel bileřenleri ieren SARIMAX modelinin daha yüksek doęruluęa sahip olduęu belirtilmiřtir (Duman, 2022).

Zaman Serilerinde Talep Tahmini isimli alıřmada ise SARIMAX modeli kullanılarak zaman serisi analizlerinde mevsimsel ve mevsimsel olmayan bileřenlerin etkileri gözlemlenmiřtir. Modelin bağımsız deęiřkenler eklenerek performansının artırılabilereęi gösterilmiřtir (Yüksel, 2023).

Arda Fazla yaptıęı alıřmada, SARIMAX modeli ile doęrusal olmayan tahmin yöntemlerinin kombinasyonu ele alınmıřtır. SARIMAX modeli, zaman serilerindeki trendleri yakalamada başarılı olmuř ancak daha karmařık desenleri modellemek için farklı yöntemlerle desteklenmesi gerektięi belirlenmiřtir (Fazla, 2024).

Yapılan bir dięer alıřmada ise, Türkiye’deki toplam konut satıřlarını tahmin etmek için SARIMAX modeli kullanılmıřtır. Model, dięer zaman serisi yöntemleriyle karřılařtırıldığında daha iyi performans gösterdięi belirtilmiřtir (Akusta, 2024).

Havacılıkta SARIMAX yöntemi ile yapılan alıřmalar incelendiğinde, Avusturalya havalimanlarında yolcu sayısının tahmini için SARIMAX modeli kullanılmıřtır. Model, turizm harcamaları ve mevsimsel deęiřkenlerle birleřtirilmiřtir. Elde edilen sonuçlar havalimanlarının pazarlama stratejilerini optimize etmelerine yardımcı olmuřtur (Tsui & Balli, 2017).

Bali’den ayrılan hava yolcularının sayısı kısa vadeli tahmini için, SARIMAX modeli kullanılmıřtır. SARIMAX modeline Google Trends verileri ek deęiřken olarak dahil edildięi zaman tahmin doęruluęunun arttıęı gözlemlenmiřtir (Oktama, 2021).

Yapılan bir dięer alıřmada ise, Avrupa’daki seili ölkelerde havalimanı altyapılarının gelişimini analiz etmek için SARIMAX modelini kullanmıřlardır. Havacılık sektöründe yolcu sayılarının mevsimsel olarak deęiřtięi göz önünde bulundurulduğunda, mevsimsel

eğilimleri yakaladığı için SARIMAX modeli mevsimsel değişimleri daha yüksek doğrulukla tespit ettiği görülmüştür (Cur vd., 2023).

Phuket’de hava yolcu sayısının tahmini için SARIMAX modeli kullanılmıştır. Mevsimsellik ve trend etkilerini içeren model, diğer yöntemlerle karşılaştırıldığında daha iyi performans göstermiştir (Pkotun & Thaminkaew, 2023).

Covid-19 pandemisinin Endonezya’daki iç hat uçuş sayısı üzerindeki etkisini SARIMAX modeli kullanarak analiz edilmiştir. SARIMAX modeli mevsimsel bileşenler sayesinde daha yüksek doğrulukta tahminler elde etmiştir (Zeinawaqi & Dzikrullah, 2024).

Singapur Changi Havalimanının uluslararası hava kargo trafiği SARIMAX-EGARCH modeli ile incelenmiştir. Model, döviz kuru ve yakıt fiyatları gibi ekonomik değişkenleri içerecek şekilde genişletildiği zaman tahmin doğruluğunun yükseldiği görülmüştür (Nguyen, 2024).

Uçak yakıt tüketiminin zaman serisi modelleri ile ilgili yapılan çalışma ile SARIMAX modeli ile uçak yakıt tüketimi tahmin edilmiştir. Model, mevsimsel ve trend etkilerini dikkate alarak, yakıt tüketimi tahminlerini hassas bir şekilde yaptığı görülmüştür (Tafur vd., 2024).

Ülkemizde havacılık sektöründe SARIMAX yöntemi ile yapılan çalışmalar incelendiğinde, Covid-19’un Türk hava sahasındaki hava trafiği üzerindeki etkisini SARIMAX modeli kullanarak analiz edilmiştir. Model, hava trafiğindeki dalgalanmaları başarılı bir şekilde tahmin ettiği gösterilmiştir (Gültekin & Kemaloğlu, 2023).

Önen yaptığı çalışmasında, Türkiye’deki havayolu yolcu talebinin tahmini için ARIMA, ARIMAX ve SARIMAX modellerini karşılaştırmıştır. Mevsimsel değişkenlerin etkisi göz önüne alındığında, SARIMAX modeli en iyi tahmin doğruluğu sağlamıştır (Önen, 2024).

Diğer bir çalışmada ise, havacılıkta kullanılan mekanik jiroskopların zaman serisi tahmini için SARIMAX modeli kullanılmıştır. Model, jiroskop hareketlerinin tahmininde etkili bulunmuştur (Kaçar, 2024).

1.2. Makine Öğrenmesi (MÖ)

Makine öğrenmesi, istatistik, veri madenciliği ve yapay zekâ disiplinlerinden doğan bir alandır. Yapay zekanın bilgisayar sistemlerinin programlanmadan verilerden öğrenmesine imkân sağlayan bir alt alanıdır. Büyük veri setleri üzerinde çalışan

algoritmaların, veri setlerini analiz ederek örüntüler çıkarmasını, tahminleme yapması ve karar alması üzerine kurulmuştur. Makine öğrenmesi, hem teorik hem de uygulamaları yönleriyle geniş bir araştırma alanına sahiptir. Sistemin kendi performansını artırmak için verilerden öğrenmesini amaçlamaktadır.

Makine öğrenmesi, denetimli öğrenme, denetimsiz öğrenme ve pekiştirmeli öğrenme olmak üzere temel olarak üç ana öğrenme kategoriye ayrılmaktadır.

Tablo 1. Makine öğrenmesi yöntemleri

Özellik	Denetimli Öğrenme	Denetimsiz Öğrenme	Pekiştirmeli Öğrenme
Tanım	Etiketli verilerle öğrenme	Etiketsiz verilerle örüntü keşfi	Ajanın ödül-maliyet sistemine göre öğrenmesi
Çıktı Türü	Belirli bir tahmin (sınıf veya değer)	Kümeleme veya örüntü keşfi	Optimal hareket dizisi
Öğrenme Yöntemi	Bağımlı değişken ile model oluşturma	Verilerdeki benzerlikleri bulma	Ajanın çevresiyle etkileşimi üzerinden öğrenme
Kullanılan Bazı Algoritmalar	Lojistik Regresyon, Karar Ağaçları, Rastgele Orman, SVM, Yapay Sinir Ağları (DNN, CNN)	K-Means, PCA, DBSCAN, Otomatik Kodlayıcılar (Autoencoders)	Q-Learning, Derin Q Ağ (DQN), PPO, Policy Gradient
Avantajları	Yüksek doğruluk, tahmin yapılabilirliği	Büyük veri kümelerinde örüntü keşfi, keşifçi analizler için uygun	Dinamik ortamlara uyum sağlayabilir, uzun vadeli karar alma yeteneği kazandırır
Dezavantajları	Etiketleme maliyetlidir, büyük veri gerektirir	Sonuçlar yorumlanması zor olabilir, doğruluğu denetimli öğrenmeye göre düşüktür	Eğitim süreci uzun olabilir, ödül fonksiyonu tasarlamak zordur

Tablo 1’de makine öğrenmesi yöntemleri temel olarak gösterilmiştir.

Son yıllarda gelişen algoritmalar ve artan hesaplama gücü sayesinde sağlık, finans, havacılık, güvenlik gibi birçok alanda kritik bir rol oynamaktadır.

1.3. Makine Öğrenmesi Yöntemleri

Makine Öğrenmesi yöntemleri, temel olarak algoritmaların verilerden nasıl öğrendiğine göre sınıflandırılmaktadır. Geleneksel olarak denetimli, denetimsiz ve pekiştirmeli öğrenme olmak üzere üç temel yaklaşım öne çıkmış olmasına rağmen

günümüzde özellikle belirli uygulama alanlarına uygun olacak şekilde geliştirilen alternatif yöntemlerde bulunmaktadır. Özellikle düşük verilerde veya yüksek açıklanabilirlik aranan sistemler için kural tabanlı sistemler, bulanık mantık (fuzzy logic) temelli yaklaşımlar, uzman sistemler ve sembolik yapay zekâ gibi alternatif yöntemlerde güncel veri setleri için sıklıkla tercih edilen yöntemlerdir.

1.3.1. Karar Ağaçları Tabanlı Yöntemler

Karar ağaçları tabanlı algoritmalar, veriyi dallara ayırarak tahmin yapan ve genellikle ağaç tabanlı bir yapı üzerine inşa edilen algoritmalarlardır.

Rastgele Orman (RF)

Rastgele Orman, 2001 yılında Breiman tarafından önerilen bir topluluk yöntemidir.

Birden fazla karar ağacını birleştirerek daha güçlü bir tahmin modeli oluşturan bir denetimli öğrenme yöntemidir.

Bootsrap Aggregating yöntemi ile çalışmaktadır. Yani her ağaç farklı veri örnekleri üzerinde eğitilir ve sonuçlar sınıflandırma veya regresyon ile birleştirilir. En önemli avantajları ise aşırı öğrenme'ye (overfitting) karşı dayanıklı ve gürültülü veriye karşı dirençli olmasıdır (Braiman, 2001).

$$\hat{y} = \frac{1}{c} \sum_{t=1}^T 1_{h_t(x)=T} \quad (1)$$

Rastgele orman algoritmasının çalışma mantığı,

- Rastgele veri seçimi (Bootstrap Örnekleme)
- Özellik rastgeleliği (Random Feature Selection)
- Ağaçların büyütülmesi
- Tahmin

LSTM

LSTM (Uzun kısa süreli bellek), 1997 yılında Hochreiter ve Schmidhuber tarafından önerilen bir tür geri beslemeli sinir ağıdır. Standart yinelemeli sinir ağlarında ki gradyan patlaması/sönmesi sorununu çözmek için geliştirilmiştir.

LSTM, tekrarlayan yapay sinir ağlarının özel bir türüdür. Zaman serisi verilerinde uzun vadeli ilişkileri öğrenebilmek için geliştirilen bir yöntemdir. İçermiş olduğu hafıza

hücreleri olarak da bilinen yapılar sayesinde geçmiş bilgileri uzun süre saklayabilme yeteneğine sahiptir (Hochreiter ve Schmidhuber, 1997).

LSTM'in ana fikri, hafızayı kapılar aracılığıyla kontrol ederek önemli bilgileri uzun süre saklamak ve gereksiz bilgileri unutmaktadır. Bu durumu sağlayan yapı ise şu şekildedir:

- Hücre Durumu (Cell State, C_t)
- Gizli Durum (Hidden State, h_t)
- Üç ana kapı mekanizması
 - a. Unutma kapısı: Ne unutulmalı?
 - b. Giriş kapısı: Ne ekleyelim?
 - c. Çıkış kapısı: Ne aktaralım?
- a. Unutma Kapısı:

$$f_t = \sigma(W_f x_t + U_f h_{t-1} + b_f) \quad (2)$$

x_t = Giriş vektörü h_{t-1} = Önceki gizli durum

C_{t-1} = Önceki hücre durumu

f_t Vektörü her hücre boyutunda 0-1 arası değer üretir. b. Giriş Kapısı:

$$i_t = \sigma(W_i x_t + U_i h_{t-1} + b_i) \quad (3)$$

c. Çıkış kapısı:

$$o_t = \sigma(W_o x_t + U_o h_{t-1} + b_o) \quad (4)$$

Zaman serisi tahminlerinde güçlü olan bu yöntem uzun dönemli ilişkileri modelleyebilmektedir.

XGBoost

XGBoost, Chen ve Guestrin tarafından 2016 yılında geliştirilmiştir. Boosting algoritmasının çok daha hızlı ve düzenlemeli bir versiyonudur.

Karar ağaçlarını ardışık olarak oluşturan makine öğrenmesi tabanlı bir algoritmadır. Eksik verilerle doğrudan çalışabilen bir model olan XGBoost aşırı öğrenmeye karşı dirençlidir. Her iterasyonda hatalı tahminlere odaklanarak yeni bir karar ağacı oluşturmaktadır (Chen ve Guestrin, 2016).

En önemli özelliği ise büyük veri setlerinde yüksek doğruluk ile tahminler yapabilmesidir.

- Başlangıçta sabit bir tahmin yapılır.
- Her iterasyonda hataları azaltmak için yeni bir karar ağacı eklenir.
- Her veri noktası için Gradyan ve Hessian hesaplaması yapılır.
- Yeni ağaç yaprakları oluşturulur.
- Yeni ağacın tahmini toplam modele eklenir.
- Adımlar tekrar edilir.
- Tüm ağaçların çıktısı toplanır.

Model çıktısı şu şekildedir.

$$\hat{y} = \sum_{k=1}^K f_k(x_i) \quad (5)$$

1.4. Zaman Serisi

Bir zaman serisi, düzenli aralıklarla toplanan bir veri dizisidir. Zaman serisi analizi ise, belirli zaman aralıklarında toplanan bu veriler üzerinde tahmin ve analiz yapan istatistiksel ve makine öğrenmesi tabanlı bir yöntemdir.

Zaman serileri geçmiş verilerin mevsimsellik, trend ve durağanlık özelliklerini kullanarak gelecek için tahminde bulunmayı sağlayan bir alandır. Zaman serileri ile yapılan tahminler, geçmiş verilere dayanarak, bir zaman serisinin gelecekteki değerlerini tahmin etmek için istatistiksel bir model kullanma sürecidir. Zaman serisi analiz süreci, gelecekteki verileri tahmin edebilmek için bazı önemli modelleri kullanmaktadır.

- Durağanlık
- Mevsimsellik
- Trend Analizi

Durağanlık: Temel olarak bakıldığında durağanlık, bir veri setinin zaman içerisinde değişime uğramaması olarak tanımlanabilmektedir. Diğer bir ifadeyle, ortalama, varyans kovaryans gibi istatistiksel özellikleri zamanla değişmeyen verilere durağan veri denilmektedir.

Mevsimsellik: Zaman serisi verisinin belirli davranışları belirli zaman dilimlerinde tekrar etmesi olarak tanımlanabilmektedir.

Trend Analizi: Trend analizi, zaman serisi verisinin uzun vadedeki genel yönüne veya belirli bir zaman diliminde değişim olup olmadığını ifade etmek için kullanılır. Başka bir ifadeyle, belirli bir zaman diliminde genel düşüşü veya büyümeyi ortaya koyar.

Zaman serileri durağan ve durağan olmayan seriler olmak üzere ikiye ayrılmaktadır.

Durağan Seri Ortalama, varyans ve kovaryans zaman içinde sabit olan serilerdir.

Durağan Olmayan Seri: Zaman içerisinde ortalama ve varyansı değişen serilerdir.

Zaman serisi analizinde kullanılan temel yöntemler şu şekildedir.

Hareketli ortalamalar:

Hareketli ortalamalar yöntemi üçe ayrılmaktadır.

Basit Hareketli Ortalama (SMA):

Basit hareketli ortalama, belirli zaman dilimi içerisindeki verilerin ortalamasını alarak seriyi düzleştirmeye ve trendi belirlemeye yardımcı olmaktadır. SMA, hesaplaması ve yorumlaması kolay bir yöntemdir ve kısa vadeli trendleri analiz etmek için uygun olmasına rağmen geleceğe yönelik tahmin yapmamaktadır ve ani değişimlere duyarlıdır.

$$\hat{y}_t = \frac{1}{k} \sum_{i=0}^{k-1} y_{t-i} \quad (6)$$

k = pencere boyutu

y_t = t döneminde ki gerçek gözlem $\hat{y}_t$ = t döneminde ki tahmini Ağırlıklı

Hareketli Ortalama (WMA):

Ağırlıklı hareketli ortalama, son dönem verilerine daha fazla ağırlık vererek geçmiş verilere kıyasla güncel verilere daha fazla önem veren bir yöntemdir. Bu sayede trendleri daha iyi yakalayabilmektedir.

$$\hat{y}_t = \frac{\sum_{i=0}^{k-1} w_i y_{t-i}}{\sum_{i=0}^{k-1} w_i} \quad (7)$$

w_i = i . Gözlemin ağırlığı

Üstel Hareketli Ortalama (EMA):

Üstel hareketli ortalama, en güncel verilere üstel ağırlık verir ve SMA'dan daha hızlı trend değişimini yakalamaktadır.

$$\hat{y}_t = \alpha y_t + (1 - \alpha)y_{t-1} \quad (8)$$

α = düzleştirme katsayısı

Üstel Düzleştirme:

Bu yöntem, zaman serilerinde trend ve mevsimselliği yakalamak için geçmiş verilere ağırlık vermektedir. Temel olarak üçe ayrılmaktadır.

Tek Üstel Düzleştirme (SES):

Sadece durağan zaman serileri için uygundur. Kısa vadeli tahminlerde başarılıdır. En büyük avantajlarından birisi basit ve hızlı hesaplanmaktadır.

Çift Üstel Düzleştirme (HES):

Trend içeren zaman serileri için uygundur. Mevsimselliği dikkate almamaktadır.

Üçlü Üstel Düzleştirme

Hem trend hem de mevsimselliği içeren seriler için uygundur. Parametre optimizasyonu gerektirmesi en büyük dezavantajlarından biridir.

Otoregresif Modeller:

Otoregresif modeller, geçmiş verileri ve hata terimlerini kullanarak gelecekteki değerlerin tahmin edilmesini sağlayan zaman serisi analiz yöntemleridir. Otoregresif modellerinden türlerinden bazıları AR, MA, ARMA, ARIMA, SARIMA, SARIMAX modelleridir.

AR (AutoRegressive – Otoregresif) Modeli:

Bir zaman serisinin geçmiş gözlemlerini kullanarak geleceğe yönelik tahmin yapılmasını sağlamaktadır. Modelin en önemli varsayımı, seride güçlü bir otokorelasyon olmasıdır.

$$X_t = c + \phi_1 X_{t-1} + \phi_2 X_{t-2} + \dots + \phi_p X_{t-p} + \epsilon_t \quad (9)$$

Burada:

X_t = Zaman serisinin tahmin edilen değeri

c = Sabit terim

p = Gecikme derecesi

ϕ_p = Otoregresif katsayıları ϵ_t = Hata terimidir.

AR modelinin en büyük avantajı basit ve anlaşılır olması ve trend ve otokorelasyona sahip veri setlerinde iyi çalışmasıdır. En büyük dezavantajlarından biri ise hata terimini dikkate almamasıdır. AR modelinin başarısı için parametre seçiminde çok dikkatli olunmalıdır.

MA (Moving Avarage – Hareketli Ortalama) Modeli:

MA modeli, serideki hata terimlerinin geçmiş değerlerine bağlı olarak gelecekteki değerleri tahmin etmeye çalışmaktadır.

$$X_t = c + \phi_1 \epsilon_{t-1} + \phi_2 \epsilon_{t-2} + \dots + \phi_p \epsilon_{t-p} + \epsilon_t \quad (10)$$

MA modelinin en önemli özelliklerinden biri durağan serilerde hata terimlerini düzelterek tahmin doğruluğunu artırmasıdır. Kısa vadeli tahminlerde daha yüksek doğrulukla tahmin yapmaktadır. En büyük dezavantajı ise geçmiş gözlemleri doğrudan kullanmamasıdır.

ARMA (AutoRegressive Moving Average) Modeli:

AR ve MA modellerinin birleşimi olan ARMA modeli hem geçmiş gözlemleri hem de hata terimlerini dikkate alarak tahmin yapmaktadır. ARMA modelleri AR ve MA modellerini birleştirdiği için daha iyi tahminler yapabilmektedir. Durağan serilerde daha yüksek doğruluk ile tahminler sunmaktadır. En büyük dezavantajı ise trend içeren seriler için uygun değildir.

$$X_t = c + \sum \phi_i X_{t-i} + \sum \phi_j \epsilon_{t-j} + \epsilon_t \quad (11)$$

ARIMA (AutoRegressive Integrated Moving Avarege) Modeli:

ARMA modeline durağan olmayan seriler için fark alma işlemini ekleyen gelişmiş bir modeldir. Trend içeren verilerde daha iyi çalışmaktadır. En önemli dezavantajı ise parametre optimizasyonu zordur.

$$X_t = AR(p) + I(d) + MA(q) \quad (12)$$

SARIMA (Seasonal ARIMA) Modeli:

SARIMA modeli, mevsimsel bileşenleri içeren zaman serileri için ARIMA modelinin genişletilmiş versiyonudur. SARIMA modelinin iki ana bileşeni bulunmaktadır. Klasik ARIMA bileşenleri (p, d, q) ve Mevsimsel Bileşenler P, D, Q, m .

$$SARIMA(p, d, q)(P, D, Q)_m \quad (13)$$

Burada:

p = Otoregresif bileşen (AR)

d = Fark alma derecesi (Durağanlaştırma)

q = Hareketli ortalama bileşeni (MA)

P = Mevsimsel Otoregresif bileşen

D = Mevsimsel fark alma derecesi

Q = Mevsimsel hareketli ortalama bileşeni

m = Mevsim periyodu'dur.

$$\begin{aligned} & \left(1 - \sum_{i=1}^p \phi_i L^i\right) \left(1 - \sum_{i=1}^q \theta_i L^i\right) \left(1 - \sum_{i=1}^P \phi_i L^{mi}\right) \left(1 - \sum_{i=1}^Q \theta_i L^{mi}\right) X_t = (1 + \epsilon_t) \end{aligned} \quad (14)$$

Burada:

L = Gecikme operatörü

ϕ_i = AR katsayıları

ϕ_i = Mevsimsel AR katsayıları

θ_i = MA katsayıları

Θ = Mevsimsel MA katsayıları

X_t = Zaman serisi verisi ϵ_t = Hata terimidir.

SARIMAX Modeli (Dışsal Değişkenli Mevsimsel ARIMA):

SARIMAX modeli, SARIMA modelinin genişletilmiş halidir ve dışsal değişkenleri içermektedir. Bu model, zaman serisinin sadece kendi geçmiş verilerine değil, başka değişkenlere de bağlı olan durumlarda kullanılmaktadır. SARIMAX modeli dışsal değişkenler sayesinde tahmin doğruluğunu artırabilmektedir. SARIMAX modeli matematiksel olarak şu şekilde ifade edilmektedir.

$$Y_t = SARIMA(p, d, q)(P, D, Q)_m + X_t\beta + \epsilon_t \quad (15)$$

Burada:

Y_t = Bağımlı değişken (tahmin edilmek istenen zaman serisi)

X_t = Bağımsız değişken (dışsal değişken)

β = Bağımsız değişken katsayıları ϵ_t = Hata terimini ifade etmektedir.

Genel olarak otoregresif modellerin avantaj ve dezavantajlarına göre Tablo 2’de gösterilmiştir.

Tablo 2. Otoregresif model karşılaştırması

Model	Avantajları	Dezavantajları
AR	Basit ve güçlü	Hata terimlerini kullanmaz
MA	Hata terimlerinden faydalanır	Geçmiş gözlemleri dikkate almaz
ARMA	Durağan seriler için uygundur	Karmaşık parametre seçimi
ARIMA	Trend içeren serilere uygundur	Model seçimi zordur
SARIMA	Mevsimsel serilerde başarılı	Daha fazla parametre gerektirir
SARIMAX	Dışsal değişkenleri kullanabilir	Karmaşıktır

Bir zaman serisi modeli, geçmiş verilere dayalı olarak gelecekteki değerleri tahmin etmektedir. Ancak, her model farklı doğruluk seviyelerine sahip olabilmektedir. Bu nedenle, tahmin edilen değerlerin gerçek değerlere ne kadar yakın olduğunu ölçmek için bazı performans metrikleri kullanılmaktadır.

Başarı metrikleri modelin ne kadar iyi tahmin ettiğini ölçmek, farklı modelleri karşılaştırmak ve modelin iyileştirilmesi gereken yönlerini belirlemek için büyük bir öneme sahiptir.

Zaman serisi analizinde yaygın olarak kullanılan hata metrikleri temel olarak üç gruba ayrılmaktadır.

Hata Tabanlı Ölçütler:

Ortalama Mutlak Hata (MAE): MAE, tahmin edilen değerler ile gerçek değerler arasındaki farkların mutlak değerlerinin ortalamasıdır. En önemli avantajları yorumlaması kolay ve aykırı değerlere karşı hassas olmamasıdır.

Hata Kareler Ortalaması (MSE): Hata terimlerinin karesinin ortalamasıdır. Büyük hataları daha fazla cezalandırdığı için model optimizasyonunda kullanışlıdır.

Hata Kareler Ortalamasının Kare Kökü (RMSE): MSE'nin karekökü alınarak hesaplanmaktadır ve hataların birimini orijinal veriyle aynı hale getirir. Aykırı değerlere duyarlıdır.

Ortalama Yüzdesel Hata (MPE): Ortalama Mutlak Yüzdesel Hata: MAPE, hatanın gerçek değere oranının yüzdesel olarak ortalamasını hesaplamaktadır. Sıfır değerler için tanımsızdır çünkü gerçek değer sıfır olduğunda hata sonsuza gitmektedir.

Bağıntı ve Uyum Ölçütleri:

R^2 : Tahmin edilen ve gerçek değerler arasındaki ilişkinin gücü ölçmektedir. Modelin açıklayıcı gücünü göstermektedir.

Özelleşmiş ve Alternatif Ölçütler:

Ortalama Mutlak Ölçeklendirilmiş Hata (MASE): Tahmin hatalarını serinin geçmiş değerlerindeki hatalarla karşılaştırarak ölçeklendirmektedir. ARIMA gibi modellerle karşılaştırma yapmaya uygundur.

Ortalama Simetrik Mutlak Yüzdesel Hata (SMAPE): SMAPE, MAPE'nin simetrik versiyonudur ve tahminlerin aşırı küçük veya aşırı büyük olmasını önlemektedir. En büyük avantajı negatif ve pozitif hataları dengelemesidir.

Hata metrikleri avantaj ve dezavantajlarına göre Tablo 3'de gösterilmiştir.

Tablo 3. Hata metriklerinin karşılaştırılması

Metrik	Avantajları	Dezavantajları
Ortalama Mutlak Hata (MAE)	Kolay yorumlanabilmektedir	Gerçek ve tahmin edilen değerler arasındaki mutlak farkın ortalaması
Ortalama Kare Hata (MSE)	Büyük hataları daha fazla cezalandırır	Birimi veriden farklıdır, Yorumlanması zor olabilir
Kök Ortalama Kare Hata (RMSE)	Gerçek hata ölçeğinde ölçüm yapar. Modelin performansını anlamada etkilidir	Aykırı değerlere karşı duyarlıdır, Büyük hatalar fazla cezalandırılır
Ortalama Mutlak Yüzdesel Hata (MAPE)	Farklı veri setlerini kıyaslama yapmak için uygundur	Gerçek değer ile tahmin arasındaki yüzdesel farkın ortalaması
Ortalama Simetrik Mutlak Yüzdesel Hata (SMAPE)	Negatif ve pozitif hataları dengeler	Bazı durumlarda tahmin edilen değerler sıfıra yakınsa hata artar
R-Kare (R^2)	Modelin genel doğruluğunu gösterir	Zaman serisi verilerinde yanıltıcı olabilir
Ortalama Mutlak Ölçeklendirilmiş Hata (MASE)	Mevsimsel verilere uygundur	Zaman serisinde yanıltıcı olabilir

Zaman serisi analizinde modelleme sürecinin en önemli aşamalarından biri uygun model seçimidir. Uygun modelin seçimi için birçok farklı yöntem vardır. Model tespiti yapılırken ilk olarak verinin durağanlığını kontrol etmek gerekmektedir. Çünkü zaman serisi analizinde kullanılan yöntemlerin çoğu zaman serisinin durağan olması durumunda başarılı olmaktadır. Zaman serisi verisinin durağan olup olmadığını anlayabilmek için otokorelasyon ve kısmi korelasyon katsayıları incelenir ve bu katsayıların istatistiksel olarak anlamlı olup olmadığına bakılır. Eğer bu katsayılar istatistiksel olarak anlamsız ise zaman serisi verisinin durağanlaştırılması gerekmektedir. Zaman serisi analizinin durağanlığını kontrol etmek için en sık kullanılan testlerden biri Dickey Fuller testidir.

Dickey Fuller Testi

Dickey Fuller 1979 yılında David Dickey ve Wayne Fuller tarafından önerilmiştir. Dickey Fuller, zaman serisinin birim kök içerip içermediğini kontrol etmek için kullanılan bir testtir. Birim kök içeren seriler durağan değildir. Durağan olmayan serilerin ise ortalaması zaman içinde değişebilir, varyansı büyüyebilir ve otokorelasyon yapısı sabit değildir. Dickey ve Fuller 1981 yılında ise testi genişletmiş ve Genişletilmiş Dickey Fuller (ADF) testini önermişlerdir. ADF'nin amacı, otokorelasyon varsa yanlılığı önlemek ve modeli daha genel kurmaktır (Dickey ve Fuller, 1979).

$$\Delta y_t = \beta_1 + \beta_2 t + \delta Y_{t-1} + \sum_{i=1}^p \alpha_i \Delta y_{t-1} + \epsilon_t \quad (16)$$

β = Sabit terim

βt = Deterministik trend

p = Gecikme uzunluğu

α_i = gecikme katsayıları

Bir serinin trendinin belirlenmesi için kullanılan yöntemler, serinin bir dağılıma bağlı olup olmasına göre; parametrik ve parametrik olmayan yöntemler olmak üzere iki başlık altına toplanmıştır. Mann-Kendall, Mann-Kendall sıra korelasyon testi ve Sen'in eğim testi parametrik olmayan yöntemlerdir. Spearman Rho ise doğrusal trend varlığını belirleme de kullanılan bir testtir (Mann,1945), (Kendall,1975), (Sen,1968) (Spearman,1904).

1.5. Kuruluştan Günümüze Türk Hava Yolları


Günümüzde herhangi bir endüstride karşılaşılan en büyük ve en karmaşık optimizasyon problemlerinden bazıları havayolu endüstrisinde bulunmaktadır. Türk Hava Yolları, Devlet Hava Yolları adıyla 20 Mayıs 1933 yılında 5 uçak ve 30'dan az çalışan ile yolculuğuna başlamıştır. İlk yurtdışı uçuşunu ise 1947 senesinde İstanbul – Atina arasında gerçekleştirmiştir. 1955 yılında ise ismini Türk Hava Yolları olarak değiştirmiştir. 1959 yılında Mesut Manioğlu'nun 9.000 metreye ulaşan irtifada kıtalararası uçuş yapabilmesiyle bilinen yaban kazından ilham alarak çizdiği yaban kazı figürü şirketin logosunu oluşturmaktadır.

2003 yılında uçak sayısı 65 olan ve halihazırda 464 uçak, günlük ortalama 1312 uçuş ve 350 destinasyon ile Dünyanın en çok ülkesine uçan havayolu unvanını elinde bulundurmaktadır. THY'de son 20 yılda çalışan sayısını 10 bin 267'den 7,5 kat artırarak 75 bin kişiye çıkarmıştır. Ülkemizin bayrak taşıyıcı firması olan Türk Hava Yolları 2033 senesinde uçak sayısını 833 uçağa, çalışan sayısını da 85 bine çıkarmayı hedeflemektedir (URL-1 ve URL-2, 2024).

THY filosu 125 tanesi geniş gövde, 304 tanesi dar gövde ve 24 tanesi kargo uçaktan oluşmaktadır. Bu 464 uçak Boeing ve Airbus firmalarının uçaklarıdır (URL-3, 2024).

1.6. Personel Yapısı

Türk Hava Yolları Anonim Ortaklığı bünyesinde çalışanlar Şekil 1'de görüldüğü gibi temel olarak uçuş ve yer personeli olmak üzere ikiye ayrılırlar.




Şekil 1. THY A.O. personel yapısı

1.6.1. Uçuş Personeli

Kokpit Ekibi

THY kokpit ekibi yaklaşık olarak 6500 kişidir. Bu 6500 kişi filo ve uçak tipine göre farklılıklar göstermektedir. Her bir kokpit üyesi bir filoda ve bir tip ailesinde uçabilmektedir.

Aşağıdaki grafikte bir ekip üyesinin uçabildiği uçak tipi ailesi belirtilmiştir. Örneğin geniş gövde Airbus uçabilen bir kokpit ekibi sadece Airbus 330 ve Airbus 350 uçak tiplerinde uçabilmektedir. Bir ekibin herhangi bir filo değişikliği yani Boeing – Airbus arasında ya da tip değişikliği yani dar-geniş gövde arasında bir geçiş yapabilmesi için o ekibin belirli süre eğitim alması gerekmektedir. Türk Hava Yolları’nda kokpit ekip dağılımı Şekil 2’de gösterilmiştir (URL-4, 2024).



Şekil 2. Kokpit ekip yapısı

Kabin Ekibi

THY’de yaklaşık olarak 15 bin tane kabin ekibi bulunmaktadır. Bunlar kabin amiri, kabin Memuru ve FlyChef olarak adlandırılan uçan aşçılardan oluşmaktadır. Kabin ekibi tecrübelerine göre farklı filo ve uçak tiplerinde uçabilmektedir. Yeni başlayan kabin memurlar Boeing ve Airbus uçaklarının dar gövdelerinde uçabilmektedir. Tecrübeli kabin memurları ise tüm dar gövdelere ek olarak bir adet geniş gövde uçuşu yapabilmektedirler.

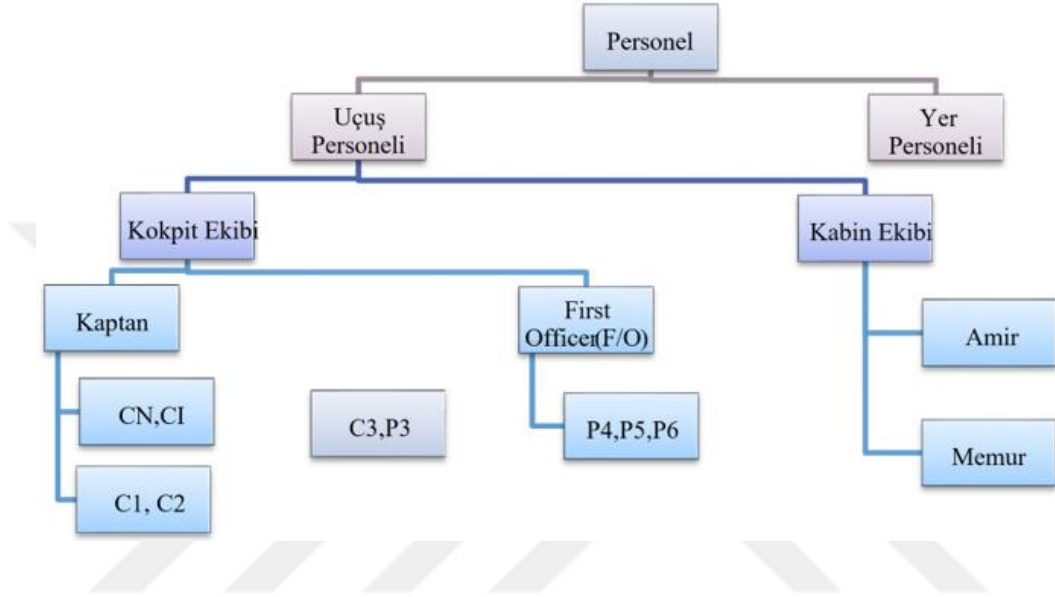
Tecrübeli kabin amirleri ise hem Boeing hem Airbus filolarında bulunan geniş gövdelerde uçabilirken hem de bir adet dar gövde uçağında görevli olarak uçuş yapabilmektedir.

1.7. Uçuş Personeli Hakkında Bilgiler

1.7.1. Pozisyon

Uçuş personelleri tecrübelerine göre farklı pozisyonlarda görev yapabilmektedirler.

Şekil 3’de uçuş ekiplerinin sınıfları ile ilgili bilgiler bulunmaktadır.



Şekil 3. Uçuş ekibi personel yapısı

Bir kokpit ekibi P6 FO rütbesiyle uçuş hayatına başlamaktadır. Yapılan uçuş sayısı ve yükselme kontrol uçuşları ile dar gövde de P4 rütbesine, geniş gövde de P3 rütbesine kadar yardımcı pilot olarak uçuş yapabilmektedir. Bir yardımcı pilotun kaptan rütbesiyle uçuşlarına devam edebilmesi için belirli eğitimlerden ve test uçuşlarından geçmek zorundadır. Bu süreci başarıyla tamamlayan bir yardımcı pilot uçuş hayatına C3 kaptan olarak devam etmektedir. Yardımcı pilotlukta olduğu gibi kaptanlıkta da rütbe yükseltilebilmesi için belirli eğitim ve uçuşlardan başarılı olması gerekmektedir.

Kabin ekipleri ise, işe başlama tarihleri itibariyle başladıkları memurluk rütbeleri belirli süre sonrasında yükselmektedir. Bir kabin memurunun kabin amiri olabilmesi için belirli bir yıl ve uçuş tecrübesine ek olarak amirlik eğitimini de başarıyla tamamlaması gerekmektedir.

1.7.2. Anaüs (HomeBase)

THY bünyesinde bulunan her bir uçuş ekibinin bir ana üssü bulunmaktadır. Ana üs, ekip üyesinin yaşadığı şehirdeki havaalanında başlayan ve yine o şehirdeki havaalanında son bulan uçuşlarda görevlendirilmesidir. THY’de İstanbul, Ankara ve Antalya ana üsleri bulunmaktadır. Örneğin ana üssü Ankara olan bir ekibi uçuş görevleri yine Ankara’dan başlayarak ve yine Ankara’da bitirerek icra etmektedir.

1.7.3. Yetkinlikler

Her uçuş ekibi THY’de istihdam edildikten sonra ana yetkinlik eğitimleri almaktadır. Bir kokpit ekibi işe başlarken hangi tip ve filo da uçacağını bilmektedir ve uçacağı uçak tipine göre eğitimini almaktadır. Fakat filoya yeni giren ya da farklı sebeplerle yetkinlik alınması gereken bir uçak tipini ilgili uçak tipinin eğitimini tamamlamadan uçuramamaktadır. Kokpit ekiplerinin aynı tip ailesinde olmasına rağmen farklı uçak tiplerini uçurabilmeleri için belirli yetkinliklere sahip olabilmesi gerekmektedir. Örneğin Boeing 777 yetkinliğine sahip bir kokpit üyesi yine aynı tip ailesinden olan Boeing 787 uçağında görevli olarak uçabilmesi için 787 tipinde belirli yetkinliklere sahip olabilmesi gerekmektedir. Bu yetkinlikler sınıf ve simülatör eğitimi ile elde edilmektedir.

1.8. Küresel Havayolu Pazarı

Dünya ekonomisinin vazgeçilmesi olan havayolu taşımacılığı, Covid-19 pandemisinden en çok etkilenen sektörlerin başında gelmiştir. Pandemi, seyahatlerde keskin bir düşüşe neden oldu ve bunun sonucunda 2020’de 137,7 milyar dolar, 2021’de 42 milyar dolar ve 2022’de 6,9 milyar dolarlık küresel kar kaybı yaşandı.

Pandeminin etkisiyle dünyada birçok havayolu şirketi küçülmeye gitmiş ya da iflas etmişlerdir. Havayolu şirketleri, pandemi nedeniyle küçülmeye gitmelerine rağmen uzun vadede büyümesini sürdürmektedir. Çoğu havayolu şirketi, mevcut sefer sayıları ile pandemi öncesi sefer sayılarını geçmişlerdir.

Küresel havayolu pazarının değeri 2023’te 346,81 milyar dolar olarak gerçekleşmiştir ve Polaris tarafından yapılan pazar araştırmasına göre, küresel havayolu pazarının 2019-2032 tahmin döneminde %3,53’lük bileşik yıllık büyüme oranında büyüyeceğini öngörüyor. Bu hızla giderse pazarın değeri 2032’de 473 milyar dolardan fazla olacağı öngörülmektedir.

Uluslararası Hava Taşımacılığı Birliği'nin (IATA) ayrıca toplam gelirlerin 2024 yılında 2023 yılına kıyasla %7,6 artarak 964 milyar dolara ulaşmasını bekliyor. ING'ye göre, Amerika Birleşik Devletleri'ndeki hava trafiği 2022'de 2019 seviyelerini aşarken, Asya Pasifik bölgesindeki talep geride kaldı ve trafik 2019 seviyesinin üçte ikisinin biraz altında kaldı. Ancak Aviation Week'in raporuna göre, 2023'ün dördüncü çeyreğinin başında Asya Pasifik bölgesindeki sistem koltuk kapasitesi neredeyse tamamen pandemi öncesi seviyelere ulaştı. Hem Uluslararası Hava Taşımacılığı Birliği hem de Uluslararası Havalimanları Konseyi'ne (ACI) göre sektör genelinde yolcu trafiğinin 2024 yılında 2019 seviyelerine ulaşacağı ve ardından yılda ortalama %3 oranında artacağı tahmin ediliyor (URL-5 ve URL-6, 2024).

Uluslararası Hava Taşımacılığı Birliği'nin 31 Ocak 2024'de yayınladığı rapora göre, "Pandemi sonrası güçlü toparlanma 2023'te de devam etti. Aralık trafiği 2019 seviyelerinin sadece %2,5 altında kaldı ve 4. çeyrekte güçlü bir performans sergileyerek havayollarının 2024'te normal büyüme modellerine dönüşünü hızlandığı göstermektedir. 2023'teki toplam trafik 2022'ye kıyasla %36,9 arttı. Küresel olarak 2023 yılının tamamında trafik, pandemi öncesi (2019) seviyelerin %94,1'inde gerçekleşti. Aralık 2023 toplam trafiği Aralık 2022'ye göre %25,3 artarak Aralık 2019 seviyesinin %97,5'ine ulaştı. Dördüncü çeyrek trafiği ise 2019'un %98,2'sinde gerçekleşti (URL-7, 2024).

Uluslararası Hava Taşımacılığı Birliği'nin küresel havayolu pazarı hakkında Aralık 2023'de yayınladığı rapora göre 2024 yılındaki öngörülerini aşağıdaki gibidir.

- Havayolu sektörünün net karının 2024'te 25,7 milyar dolara ulaşması bekleniyor (%2,7 net kâr marjı). Bu, 23,3 milyar dolarlık net kar (%2,6 net kâr marjı) göstermesi beklenen 2023 yılına göre hafif bir iyileşme olacaktır.
- Hem 2023 hem de 2024'te, dünya genelinde faiz oranları keskin enflasyonist dürtüye tepki olarak arttığı için, yatırılan sermayenin getirisi sermaye maliyetini yüzde 4 puan geride bırakacaktır.
- Havayolu sektörünün faaliyet kârının 2023'teki 40,7 milyar dolardan 2024'te 49,3 milyar dolara ulaşması beklenmektedir.
- 2024 yılında toplam gelirlerin yıldan yıla %7,6 artarak rekor 964 milyar dolara ulaşması beklenmektedir.
- Gider büyümesinin biraz daha düşük olarak %6,9 ile toplam 914 milyar dolar olması beklenmektedir.

- 2024 yılında yaklaşık 4,7 milyar insanın seyahat etmesi beklenmektedir; bu, 2019'da kaydedilen 4,5 milyarlık pandemi öncesi seviyeyi aşan tarihi bir yüksek rakamdır.
- Kargo hacimlerinin 2023 ve 2024'te sırasıyla 58 ve 61 milyon ton olması beklenmektedir (URL-8, 2024).

Pandeminin hayatımıza girmesiyle birlikte yolcu taşımacılığının yanı sıra havacılıkta kargo taşımacılığı da büyük önem kazanmıştır. Kargo hava taşımacılığının aynı yolcu hava taşımacılığında olduğu gibi zaman ve ücret konusunda birçok faydası bulunmaktadır. Kargo seferlerine artan talep neticesinde kargo uçak sefer sayılarındaki artış da açıkça gözükmemektedir. Uluslararası Hava Taşımacılığı Birliği, 2024'e güçlü bir başlangıç yapıldığını gösteren Ocak 2024 küresel hava kargo pazarlarına ilişkin yayınladığı verilerde,

Kargo ton-kilometre (CTK*) cinsinden ölçülen toplam talep, Ocak 2023 seviyelerine göre %18,4 arttı (uluslararası operasyonlar için %19,8). Bu önemli yükseliş, kargo ton kilometresinde (CTK) 2021 yaz sezonundan bu yana görülen en yüksek yıllık büyümeye işaret etmektedir. Mevcut kargo ton-kilometresi (ACTK) cinsinden ölçülen kapasite, Ocak 2023'e kıyasla %14,6 artmıştır (URL-9, 2024).

Türk Hava Yolları açısından bakıldığında zaman, 2023 yılında 106 milyar TL net kar ile tamamlamıştır. THY 2022 yılındaki net karı ise 47 milyar 429 milyon lira olmuştu. Milli bayrak taşıyıcısı bir önceki yıla oranla karını %244 oranında artırmıştır. 2022 yılında 71,8 milyon yolcu taşıyan şirket bir önceki seneye göre %16,1 artırarak 2023 yılında 83,4 milyon yolcu taşımıştır. Aynı sene 1,66 milyon ton kargo-posta taşımıştır. (URL-10, 2024)

Küresel havayolu verileri ve THY'nin geçmiş verilerine baktığımız zaman gelecek yıllarda yolcu ve kargo sayılarındaki artışın devam edeceği tahmin edilmektedir. Bu artan talebi karşılayabilmek için havayolu şirketleri açısından en önemli konulardan bir tanesi insan kaynakları yönetimidir. Diğer üretim faktörleri düşünüldüğünde zaman insan kaynakları yönetilmesi zor ve çok daha karmaşık bir konudur. İnsan kaynağının yönetilmesi sistemli ve planlı bir şekilde yürütülmesi ile mümkün olabilmektedir. Uluslararası Hava Taşımacılığı Birliği'nin 2024'te yaklaşık 4,7 milyar insanın seyahat etmesinin beklendiğini öngörmektedir. Bu, 2019'da kaydedilen 4,5 milyarlık pandemi öncesi seviyeyi aşan rekor bir rakamdır. Bu öngörüler, havayolu şirketleri için insan kaynağı yönetiminin ne kadar önemli bir konu olduğunu göstermektedir. Türk Hava Yolları'nın 2033 yılına kadar 833 uçağa sahip olma hedefi aynı zamanda ekip ihtiyacı probleminin de şirket için ne kadar önemli olduğunu bir göstergesidir.

1.9. Planlama Süreçleri

İnsan gücü planlama sürecinin net bir şekilde anlaşılabilmesi için planlama sürecinin doğru bir şekilde anlaşılması gerekmektedir. Planlama süreci birçok farklı aşamadan geçmektedir. Bu aşamalar planlama seviyesine ve planlama kaynaklarına bağlı olarak çeşitli süreçlerden oluşmaktadır. Planlama sürecindeki her adım belirli problemleri çözmesine rağmen, tümüyle birbiri ile bağlantılıdır. Planlamanın başında yapılacak en ufak bir değişiklik/hata planlamanın sonucuna direkt ve büyük bir etkisi olabilmektedir. Planlama süreci uçuş planlama, rota planlama, uçak planlama ve ekip planlama olarak farklı süreçlerin, her bir süreç tamamlandıktan sonra sonraki aşamaya geçilmek şartıyla devam eden, ilgili uçuşun icra edilmesi ile tamamlanan bir süreçtir. Uçuşun icra edilmesinde önce bu süreçlerden herhangi biri veya birkaçında yaşanacak en ufak bir değişiklik tüm ekip planlama sürecini etkilemektedir. Bu değişiklikler, uçuş ekibinin görev saatinden dinlenme süresine, uçuşu gerçekleştirecek ekip sayısına kadar her şeyi değiştirmektedir. Bu nedenle tüm süreçlerin minimum hata ile tamamlanması gerekmektedir.

Havayolu şirketlerinde görev alan kabin ve kokpit ekiplerinin yetkinliği olan uçak tipine göre, ulusal, uluslararası, şirketin sahip olduğu ya da sendikal kanun ve kurallara uygun olacak şekilde uçuş görevlerinin planlanması gerekmektedir. Uçuş ekiplerinin uçuş görev süreleri, uçuş süreleri, boş günleri, dinlenme süreleri ile bu görevlerin başlama ve bitiş saatlerini belirten uçuş programlarının kaydedilmesi gerekmektedir (Akyurt & Yaşlıoğlu, 2018).

Havayolu planlaması birbirine bağlı birçok aşamaya sahiptir. Uçuş planlarının yapılması, filo atama, uçak rotalama, ekip planlama bu planlama aşamalarından karşılaşılmakta olan en temel aşamalardır. Bu aşamaların en zor olanlarından biri de ekip planlamadır. Çünkü tüm havayolları için ekip maliyetleri, yakıt maliyeti ile en önemli giderlerdir. Ekip planlama sürecinin en optimal şekilde yapılması, havayolları için ekip maliyetlerini de optimum düzeyde tutacaktır.

1.10. Planlama Terimleri

Ekip planlama süreci genel olarak bir uçuş ekibinin bir aylık tüm görevlerini planlamak olarak tanımlanabilmektedir. Bu görevler ise temel olarak aktif ve pasif görev olarak ikiye ayrılmaktadır. Aktif görevler uçuş görevleri, eğitim/simülasyon, nöbet gibi görevlerdir. Pasif görevler ise boş gün/yıllık izin, aşı/muayene, ofis görevi gibi görevlerdir.

Uçuş ekiplerinin haftalık, aylık ve yıllık olarak limitlenen uçuş görev süreleri vardır. Aktif görevler uçuş görev süresine dahil olan görevlerdir. Pasif görevler ise ekiplerin uçuş görev sürelerine dahil olmayan görevlerdir. Ekip planlama birimlerinde tarafından gerçekleştirilen süreçlere en temel haliyle bakıldığı zaman, ekip üyesinin ana üssü olan havalimanından başlayan ve yine ekibin ana üs havaalanında biten uçuş hatları ile her bir uçuş bacağına ekip ihtiyacını karşılayacak şekilde ekiplere atanması olarak tanımlanmaktadır.

Bu süreçleri açıklamadan önce havayollarında kullanılan tabirleri açıklamak daha doğru olacaktır. Havacılık da kullanılan terimlerden en önemlileri leg, duty, trip ve layover'dır.

Leg(sektör): X havalimanından kalkan ve Y havalimanına varan her uçuş bir leg'dir.

Duty: Birden fazla leg'den oluşan görevlerdir.

Trip: X havalimanından başlayan ve son olarak X havalimanında biten tüm uçuş görevidir.

İlgili terimlerin daha iyi anlaşılabilmesi için bir örnekle açıklamak gerekirse,



Şekil 4. Trip örneği

Şekil 4'deki uçuş görevinde 1 trip, 3 duty ve 1+4+4 olmak üzere 9 leg vardır. SAW istasyonundan başlayan ve ESB istasyonunda biten ilk görev bir uçuş leg'idir ve aynı zamanda birinci duty'dir. ESB istasyonunda başlayan ve ESB istasyonunda biten ve toplam 4 leg'den oluşan ikinci duty'dir. ESB istasyonundan başlayan ve SAW istasyonunda biten 4 leg'den oluşan üçüncü duty'dir. SAW istasyonundan başlan ve SAW istasyonunda biten tüm leg'lerin toplamına ise bir trip denmektedir. Yukarıda ki birinci leg ile ikinci leg'in arası ve beşinci leg ile altıncı leg'in arası layover yani yatıdır. Eğer bir tripte yatı yok ise duty ve trip aynıdır ve sayısı birdir.

Uçuş Tipleri: Havayollarında genel olarak tanımlanan iki uçuş tipi bulunmaktadır. Bunlar iç hat ve dış hattır. İç hat havayolu şirketinin olduğu ülke içinde yaptığı uçuşlara denmektedir. İç hat uçuşları da kendi arasında iç git-gel ve iç yatı olarak ayrılmaktadır. İç yatı (İY), herhangi bir uçuş görevinde ekibin ana üssü dışında ve uluslararası havacılık

kurallarına göre minimum 8 saat dinlenme aldığı meydana yapacağı yatılara verilen addır. İç git-gel (İG) ise ülke içinde yapılan trip’de herhangi bir yatı olmaması anlamına gelmektedir. Dış hat ise havayolu şirketinin farklı herhangi bir ülkeye yapacağı uçuşları tanımlamak için kullanılan terimdir. Dış hat da kendi içinde üçe ayrılmaktadır. Bunlar extended range, dış yatı ve dış git-gel olarak tanımlanmaktadır. Extended range (ER) adı verilen ve uçuş süresi 8 saatten fazla olan tripler için kullanılan terimdir. Dış yatı (DY) ise bir tripte bulunan ve ekiplerin farklı bir ülke limanında minimum 8 saat dinlenme aldıkları uçuşları tanımlamak için kullanılmaktadır. Dış git-gel (DG) ise farklı bir ülke de dinlenme almadan icra edilen uçuşlar için kullanılmaktadır.

Briefing: Hava aracının güvenli ve verimli bir şekilde işletilmesi için uçuş planlamasına ve karar verme sürecine yardımcı olmak amacıyla hava durumu ve havacılık bilgilerinin pilot veya uçuş denetim personeli tarafından kullanılabilecek bir biçimde toplanması, tercüme edilmesi, yorumlanması ve özetlenmesidir. Standart bir briefingde;

Planlanan Uçuş Türü

Uçak Tipi

Çıkış ve Varış Limanı

Uçak Rotası

Uçuş İrtifaları

Tahmini Uçuş Süresi gibi süreçler değerlendirilmektedir. Briefing süresi uçuş tipine göre (ER, DY, DG, İY, İG) farklılık göstermektedir (URL-11, 2024).

Debriefing: Uçuş ile ilgili değerlendirmenin yapıldığı kısımdır.


Uçuş Süresi: Uçağın kalkış amacıyla park pozisyonundan ayrıldığı ve varış yaptığı limanda tekrardan park pozisyonuna gelerek tüm motorların kapandığı süreyi tanımlamaktadır.

Uçuş Görev Süresi: Ekiplerin uçuş görev süreleri brief, debrief ve uçuş süresinin toplamıdır.


1.10.1. Aylık Planlama Periyodu

Aylık planlama periyodu devam eden ayın ortasında başlayan, gelecek ay için ekip programlarını oluşturmak üzere yapılan işlemler tümüdür. Bu işlemler ise genel olarak iki kısımdan oluşmaktadır. Bunlar ekip eşleme (pairing) ve ekip atamadır (rostering).

Ekip planlama birimlerinin planlama süreci boyunca yaptığı ilk iş pairing olarak tanımlanan süreçtir. Pairing yani uçuş eşleme aynı havalimanında başlayıp bitmekte olan uçuş leg'lerinin birleştirilmesi ile oluşturulacak triplerin belirlenmesidir. Bu süreç bir leg'in varış havalimanı ile sonraki leg'in kalkış havalimanının uçak tipi ve tarih gibi kısıtlamalara göre birbirine eşlenmesi olarak tanımlanabilmektedir. Şekil 5 ve Şekil 6'da iki farklı pairing örneği gösterilmiştir.



Şekil 5. Pairing örneği 1



Şekil 6. Pairing örneği 2

Şekil 5'de yapılan uçuş eşleme doğru şekilde yapılmasına rağmen, Şekil 6'da yanlış bir uçuş eşleme yapılmıştır. GYD havalimanında biten bir leg ile TZX havalimanında başlayan bir leg pair edilmiştir. Bu nedenle ilgili uçuşların IST-GYD-IST ve IST-TZX-DIY olacak şekilde yeniden uçuş eşlemesi yapılması gerekmektedir.

Pairing işlemleri bittikten sonra uçuş eşlemesi yapılan her bir trip için, seferin ekip ihtiyacına bağlı olarak ekip ataması işlemi yapılmaktadır. Ekip ataması yapılırken dikkat edilen konulardan bazıları şu şekildedir:

- Ekip kalifikasyonu – Uçak Tipi: İlgili uçuşun icra edileceği uçak tipi ile ekibin sahip olduğu uçak tipinin eşleşmesi gerekmektedir.
- İlgili uçuşun icra edilebilmesi için gerekli minimum Kaptan, Yardımcı Pilot, Kabin Amiri ve Kabin Memuru sayısı: Bir uçuşun icra edilebilmesi için uçuş tipine bağlı olarak farklı sayıda ekibe ihtiyacı vardır. Örneğin, bir Sivas uçuşu 1 kaptan, 1 yardımcı pilot, 1 kabin amiri 4 kabin Memuru ile icra edilirken, 1 Amerika uçuşu 2 kaptan, 2 yardımcı pilot, 1 kabin amiri ve 10 kabin Memuru ile icra edilebilmektedir. Bu durum uçak tipine, uçuş tipi ve yolcu sayısı gibi kriterlere bağlı olarak değişiklik gösterebilmektedir.

- Liman yetkinliği-Ekip yetkinliği: Bazı havalimanları C kategori havalimanı listesinde yer almaktadır. C kategori meydanlar iniş yaklaşımları, hava durumları gibi özel sebepler nedeniyle özel şartlar aramaktadır. Kokpit ekipleri bu limanlara iniş yapabilmesi için yer eğitimi, simülatör eğitimi ve/veya uçuş eğitimi almak zorundadırlar. Bu eğitimi olmayan bir kokpit ekibi C kategori bir meydan için uçuş planlaması yapılmamaktadır.
- İniş limanında beklenen hava durumu ile kokpit ekip sertifikası: Bir havalimanı C kategori meydanlar listesinde olmamasına rağmen bazı günler kar ve sis gibi düşük görüş nedeniyle özel ekip talebi yapılabilir. Bu özel talebi karşılayabilmek için bu tarz durumlar için özel eğitim almış ekip planlaması yapılmaktadır.
- Dinlenme ve zindeliğe göre ekip planlanması: Bazı havayolları Fatigue Risk Management (FRM) adı verilen ekip zindeliğine dikkat etmektedir. Ekiplerin icra ettikleri uçuş ile ekiplerin yorgunlukları tahmin edilmektedir.

Bu tahmini yapan ekip planlama sistemleri ile entegre bazı paket programlar vardır. Zindelik değeri düşük olan ekiplere sefer planlaması yapılırken seferin tipi ve limanına bağlı olarak ekiplere sefer öncesi boş gün planlanarak ekiplerin zindeliklerini artırmak gerekebilmektedir.

Ekip planlama sistemlerinde uluslararası, ulusal, şirket ve sendikaya ait kurallar bulunmaktadır. Hem uçuş eşleme hem de ekip atama işlemleri bu kurallar çerçevesinde yapılmaktadır. Uçuş ekipleri Sivil Havacılık Genel Müdürlüğü'nün (SHGM) yayınladığı SHT-FTL e göre uçuş yapabilecekleri süreler belirtilmiştir. Ekip planlama birimleri uçuş ekiplerine planlama yaparken bu süreleri dikkate almaktadır.

Herhangi bir ekip üyesinin görevlendirildiği toplam görev süresi aşağıdakileri aşmayacaktır:

- Birbirini izleyen herhangi 7 gün içerisinde 60 görev saati;
- Birbirini izleyen herhangi 14 gün içerisinde 110 görev saati ve
- Birbirini izleyen herhangi 28 gün içerisinde 190 görev saati, o süre boyunca uygulanabildiği ölçüde eşit oranda yayılmış.
- Herhangi bir takvim yılı içerisinde 2000 görev saati.

Münferit ekip üyesinin görevli ekip üyesi olarak görevlendirildiği sektörlerin toplam uçuş süresi aşağıdakileri aşmayacaktır:

- Birbirini izleyen herhangi 28 gün içerisinde 100 saatlik uçuş süresi;

- Herhangi bir takvim yılı içerisinde 900 saatlik uçuş süresi; (01.01.2019 tarihinden itibaren yürürlüğe girecektir)
- Birbirini izleyen herhangi 12 takvim ayı içerisinde 1000 saatlik uçuş süresi (SHT-FTL, (2018).

Sivil Havacılık Genel Müdürlüğünün belirlediği kurallar haricinde havayolu şirketlerinin ve havayolu sendikalarının da belirledikleri kurallar bulunmaktadır. Sendika kurallarından bazıları şu şekildedir:

- Uçucu ekiplere boş süre olarak bir takvim ayında 8 adet boş takvim günü verilir. Bu boş günler 2+2+2+1+1 şeklinde ve takvim ayı içinde dengeli olarak planlanır.
- Uçucu ekiplerin tek boş günlerinden sonra 06:00 lokal saatten önce başlayan sefer planlanamaz.
- Uçucu ekiplere ana üste tek bir uçuş görevi, tek bir simülatör veya tek bir nöbet planlanabilir (URL-12, 2024).

Ekip atama işlemleri yapılırken uçuş süreleri, dinlenme süreleri, boş günler ile ilgili kurallara göre atamalar yapılmaktadır. Bu atamaların en iyi şekilde yapılabilmesi için bazı programlar kullanılmaktadır. Bu paket program da bulunan optimizer adı verilen sistem ile uçuşlar ekiplere en optimal şekilde atanmaktadır. Optimizer, az önce bahsedilen kurallara göre atama işlemlerini yapmaktadır. Örneğin bir uçuş ekibine belirtilen limitler dışına çıkan bir uçuş planlandıysa, ekip de illegallik oluşacaktır. Optimizer bu illegalliklerin önüne geçecek şekilde bir atama işlemi yapmaktadır ve illegalliğe sebep olan uçuşu ilgili ekibe atamayacaktır. Atama işlemleri tamamlandıktan sonra ekiplerin gelecek ay için tüm programları crew roster adlı doküman ile ekiplere bildirilmektedir. Bu doküman sayesinde ekipler bir uçuşa ne zaman ve hangi limanlara gideceklerini, hangi günlerde boş olacaklarını varsa hangi günlerde simülatör, ofis ya da yer eğitimi planlandıklarını bilmektedir.

1.11. Tezde Kullanılacak Terimler

Filo: Kokpit ekiplerinin yetkinlikleri oldukları uçak tipidir.

Kokpit Sınıfı: Kokpit ekiplerinin kaptan mı yardımcı pilot olarak mı görev yaptığının belirtildiği kısımdır. Kaptan Pilot, uçuş sorumlusu olarak görevlendirilen ekip iken, yardımcı pilot uçağın sevk ve idaresinden sorumlu olan, kaptan pilot haricindeki ilgili otorite tarafından yetkilendirilen ekiptir.

Simülâtör – Eğitim: Uçuş ekiplerinin yetkinliklerine göre düzenli periyotlarla aldıkları simülâtör ya da yer eğitimleri olarak tanımlanmaktadır.

Ofis: Uçuş ekiplerinin uçuş görevine ek olarak ofis personeli gibi görevlendirildiği anlamına gelmektedir.

Boş gün: Uçuş ekiplerinin aktif olarak görev yaptıkları günler dışında kalan diğer günlerdir.

Yıllık izin: Ekiplerin yılın belirli zamanlarında hakkettikleri izindir.


Kişi Sayısı: Filo ve kokpit sınıfı bazında uçucu ekiplerin sayısını ifade etmektedir.

Öğretmen Yükü: Simülâtör eğitimlerinde görevli olan öğretmen kaptanların meşguliyetlerini ifade etmek için kullanılan terimdir.

Ayrılış: İlgili filo ve sınıf bazında istifa, emeklilik, ölüm vb. nedenlerle işten ayrılma durumunu ifade etmektedir (URL-13, 2024).

1.12. Tez Aşamaları

Bu tezin hazırlanma aşamaları Şekil 7’de gösterilmiştir.



Şekil 7. Tez Aşamaları

2. YAPILAN ÇALIŞMALAR


Uçucu ekip ihtiyacı tahminlemesi yapılabilmesi için geçmiş yıllara ait veriler ay, yıl, filo, kokpit sınıfı kırımlarında ilgili sistemlerden elde edilmiştir. Bu çalışmada kullanılacak olan veriler Türk Hava Yolları Ekip Planlama Başkanlığı sistemlerinden alınmıştır.

2.1. Modelleme Aşamaları

Modelleme aşamaları sırasıyla aşağıda belirtilmiştir.

- o Veri yükleme: Ekip planlama sistemlerinden elde edilen 10 senelik verinin analiz için Jupyter Notebook'a yüklenmiştir.
- o Veri seti üzerinde eksik değer analizi yapılmış, eksik veri içeren aylar, ilgili değişkenin geçmiş ve gelecek değerleri dikkate alınarak tamamlanmıştır.
- o Pandemi kaynaklı sıra dışı düşük değerler lineer interpolasyon ile doldurulmuştur.
- o Veri seti zaman serisi analizine uygun olabilmesi için zaman formatı datetime'a çevrilmiştir.
- o Keşifsel Veri Analizi (EDA) uygulanmıştır.
- o Zaman serisinin trend, mevsimsellik ve dalgalanmaları analiz edilmiştir. o Pandemi dönemi özel olarak işaretlenmiştir.
- o Durağanlık kontrolü için Dickey-Fuller (ADF) testi uygulanmıştır.
- o Her kokpit sınıfı için SARIMA/SARIMAX, Holt-Winters, Prophet, LSTM, XGBoost ve Rastgele Orman modelleri geliştirilmiştir.
- o Model performans metrikleri ile model sonuçları değerlendirilmiştir.


2.2. Analiz Sonuçları



Şekil 8. Eksik verileri düzeltilmiş kokpit personeli

Şekil 8’de eksik verileri düzeltilmiş veri setinden elde edilen 2010-2022 arasında ki kokpit sayısının zaman içerisindeki değişimi gösterilmiştir. 2020-2022 pandemi dönemi gri ile vurgulanmıştır. Bu dönemde ciddi bir düşüş olduğu Şekil 8’de açıkça görülmektedir. Grafikten de net bir şekilde görüldüğü gibi kokpit personel sayısının yıllar için artan genel bir trendi bulunmaktadır.


Keşifsel veri analizi aşamasında, verinin zaman serisi grafikleri incelenmiş, genel trend, mevsimsellik ve olası ani değişimler analiz edilmiştir. 2010’dan 2019’a kadar toplam kokpit personeli sayısı düzenli bir artış trendi sergilediği gözlemlenmektedir. Veri, her yılın yaz aylarında tepe değerlerine ulaşırken, kış aylarında ise dip değerleri görmesi belirgin bir mevsimsel desen olduğunu ortaya çıkarmaktadır. Özellikle Temmuz-Ağustos dönemlerinde ekip sayısı zirve yaparken, Ocak-Şubat aylarında minimum seviyelere indiği açıkça görülmüştür. Bu mevsimsellik, hava yolu ile ulaşım talebinin yazın artması ve kışın azalmasıyla ilişkili olarak kokpit personeli sayısına da yansımıştır. 2019 sonuna kadar ki veride artan bir trend ve yinelenen yıllık döngüler net biçimde gözlemlenmiştir.



Şekil 9. Kokpit personelinin sınıf bazlı yıllara göre değişimi


Kokpit personelinin kaptan, F/O ve P3 sınıflarının yıllara göre değişimi Şekil 9’da gösterilmiştir. THY’nin kokpit personeli sayısının trendini, mevsimsel değişikliklerini ve pandemi gibi olağanüstü durumların etkilerini net bir şekilde ortaya koymaktadır.

Pandemi dönemi (2020-2021) veride büyük bir kırılmaya neden olduğu Şekil 9’da görülmektedir. 2020 yılında toplam personel sayısı, önceki yıllara kıyasla %50’ye varan oranlarda düşüş göstermiştir. 2021 yılında kısmi bir toparlanma olmuş olsa da ekip sayısı düzeyi hala trendin altında kaldığı gözükmemektedir. 2022 yılı itibariyle ise sayı yeniden artarak pandemi öncesi trend çizgisine yaklaşmıştır. Bu bulgular, pandemi döneminin istatistiksel açıdan bir aykırı durum olduğunu ve normal trendden sapma yarattığını açıkça göstermektedir. Dolayısıyla modelleme aşamasında bu dönem özel olarak ele alınmıştır.



Şekil 10. Aylık mevsimsellik deseni


Şekil 10’da her ayın ortalama kokpit personeli sayısı gösterilmektedir. Haziran, temmuz ve ağustos aylarında personel sayısı artarken ocak ve şubat aylarında ise daha düşük seviyelerde olduğu görülebilmektedir.



Şekil 11. Yıllık mevsimsellik ve trend deseni

Şekil 11’de yıllık bazda toplam ekip sayısının mevsimselliği ve trendi gösterilmiştir.

Pandemi de oluşan negatif trendin ve pandemi sonrası toparlanma süresi ile oluşan pozitif trend net bir şekilde görülebilmektedir.




Şekil 12. Genel trend ve mevsimsellik

Şekil 12’de kokpit ekip sayısının genel trendi ve mevsimsellik incelemeleri sonucunda zaman serisinin bileşenleri gösterilmektedir.

Genel trende bakıldığında zaman kokpit ekip sayısı yıllara göre artış olduğu anlaşılmaktadır. 2020-2022 yıllarında bir düşüş olduğu fakat 2022 itibarıyla tekrar toparlanmaya başladığı net bir şekilde görülmektedir.

Mevsimsellik sonuçları incelendiğinde, özellikle yaz aylarında personel sayısının arttığı görülmektedir. Yaz aylarında artan uçuş talepleri nedeniyle yapılan sefer sayıları da dikkate alındığında zaman kokpit sayısının neden arttığı anlaşılabilmektedir.

Hata sonuçları ise tahmin edilemeyen dalgalanmaları ve istisnai durumları göstermektedir. Özellikle 2016 yılında olan sapmalar 15 Temmuz hain darbe girişimi nedeniyle olduğu grafikten de açıkça görülebilmektedir. 2020-2022 arasında olan büyük sapmaların nedeni ise COVID-19 pandemi dönemi olmasıdır.



Şekil 13. Çalışma günlerinin yıllık dağılımı

Çalışma günleri dağılımları incelendiğinde ilginç desenler görülmüştür. Uçuş dışı meşguliyet olan Simülasyon-eğitim, ofis, boş gün ve yıllık izin nedeniyle uçuş yapılamayan günlerin dağılımı Şekil 13’de gösterilmiştir. Pandemi döneminde gelen uluslararası kısıtlamalar nedeniyle sadece tahliye ve kargo seferleri icra edilmiştir. Planlı yolcu seferleri yapılamadığı için kokpit ekipleri uçuş görevlerini gerçekleştirememişlerdir. Bu nedenle pandemi döneminde boş günler için aşırı sapma meydana gelmiştir. Simülasyon-eğitim günlerinin de pandemi döneminde belirgin şekilde düştüğü görülebilmektedir. Pandeminin bitmesi ve toparlanma sürecinin başlangıcı olan 2022’ye doğru tekrar artarak normale dönmüştür. Ofis görevi ve yıllık izin günleri de 2020’de dalgalanma gösterip, sonrasında tekrardan istikrarlı bir dağılım göstermiştir. Genel olarak bakıldığında ise, 2010-2019 arasında değişkenler daha tutarlı bir döngü izlerken, 2020-2021’de bu döngü bozulmuş, 2022’de ise tekrardan normal düzenine dönmeye başlamıştır.

Keşifsel veri analizi aşamasında verinin ortalama ve dağılım metrikleri de incelenmiştir. Kaptan ve F/O ihtiyacının toplam ekip sayısı içindeki oranlı yıllar içinde istikrarlı kaldığı gözlemlenmiştir. Değişkenlerin analiz sonuçları, aykırı değerlerin büyük ölçüde pandemi dönemine ait olduğunu da göstermektedir.

Modellemeye geçilmeden önce keşifsel veri analizin sonucu, verideki trend ve mevsimselliğin güçlü olduğu, pandemi döneminin ise istisnai bir etki yarattığını açık bir şekilde ortaya koymuştur. Modelleme aşaması bu sonuçlara göre yapılmıştır.

2.3. Tahmin Modelleri

Zaman serisi tahmini için iki ana yöntem denenmiştir. Bu yöntemler geleneksel istatistiksel yöntemler ve makine öğrenmesi/derin öğrenme yöntemleridir. Tüm modeller, 2010-2019 normal dönem trend ve mevsimselliğini yakalayıp, 2020-2021 dönemindeki anormallikleri mümkün olduğunca göz ardı ederek geleceğe yönelik sağlıklı tahminler üretmek üzere tasarlanmıştır. Model eğitiminde, verinin 2010-2021 aralığı eğitim (train) için kullanılmıştır. 2022 yılı verisi ile modellerin performansları test edilmiştir.

2.3.1. Çalışmada Kullanılan Zaman Serisi Temelli Yöntemler

Zaman serisi tahmini için kullanılan geleneksel istatistiksel yöntemlerden bazıları ARIMA, SARIMA, Holt-Winters ve Prophet yöntemleridir.

ARIMA: Zaman serisinin kendi gecikmeli değerleri ve hata terimleri ile ilişkisini modelleyen klasik bir yöntemdir. Veride belirgin bir yıllık mevsimsellik olduğundan, standart ARIMA modeline mevsimsel bileşenin eklenmesi gerekmiştir. Bu amaçla mevsimsellik içeren SARIMA modeli kullanılmıştır. Özellikle Box-Jenkins metodolojisinde yaygın olarak kullanılan ve airline modeli olarak da bilinen $(0,1,1) \times (0,1,1)_{12}$ modeli bu veri için uygun bulunmuştur. Bu model, verideki hem genel trendi hem de 12 aylık periyodik yapıyı fark alma ($d=1$, $D=1$) ve hareketli ortalama terimleriyle ($q=1$, $Q=1$) yakalayabilmektedir.

ARIMA/SARIMA modelini kurmadan önce serinin durağan olup olmadığı test edilmiştir. Yapılan kök testleri ve grafik incelemeleri serinin trend ve mevsimsellik içermesi nedeniyle durağan olmadığını göstermiştir. Elde edilen çıktı Tablo 4 ve Ek 1'de gösterilmiştir. Bu nedenle seriye uygun birinci mertebeden fark alma ve 12 aylık mevsimsel fark alma işlemleri uygulanmıştır. SARIMA modeli, geçmiş veriye en iyi uyumu sağlayacak şekilde Maksimum Olabilirlik yöntemiyle eğitilmiştir. Alternatif ARIMA yapıları da ACF/PACF grafiklerinden faydalanılarak değerlendirilmiştir. Sonuç olarak, mevsimsel

ARIMA modelinin veriyle iyi uyum sağladığı görülmüştür.

Tablo 4. Genişletilmiş Dickey Fuller test sonuçları

ADF İstatistiği	1.9721
P değeri	0.2990
%1 Kritik değer	-3.4344
%5 Kritik değer	-2.8633
%10 Kritik değer	-2.5677

Holt-Winters (Üstel Düzgünleştirme): Holt-Winters yöntemi serideki seviye, trend ve mevsimsellik bileşenlerini üstel ağırlıklarla güncelleyerek tahmin üretmektedir. Hem eklemeli(additif) hem de çarpımsal (multiplikatif) mevsimsel modeller denenmiştir. Verideki mevsimsel dalgalanmanın büyüklüğü genel trende bağlı olarak arttığı için, çarpımsal modelin daha uygun olduğu görülmüştür. Holt-Winters modelinde trend bileşeni için doğrusal (additif) yapı kullanılmış ve mevsimsel periyot 12 ay olarak belirlenmiştir. Modelin düzey, trend ve mevsimsellik katsayıları optimize edilerek en düşük hata verecek şekilde ayarlanmıştır.

Prophet (Facebook Prophet): Prophet modeli, verideki trendi lineer ya da parçalı doğrusal olarak, yıllık mevsimselliği ise Fourier serileriyle modelleyen bir yöntemdir. Bu çalışmada Prophet modeli yıllık periyodu 12 olacak şekilde ayarlanmıştır. Ayrıca, 2020-2021 döneminin anormalliğini yakalayabilmek için bu yıllara ait olası değişim noktaları da Prophet modeline dahil edilmiştir.

2.3.2. Çalışmada Kullanılan Makine Öğrenmesi Yöntemleri

Zaman serisi tahmini için kullanılan makine öğrenimi ve derin öğrenme yöntemlerden bazıları LSTM, XGBoost ve Rastgele Orman yöntemleridir.

LSTM (Long Short-Term Memory Sinir Ağı): LSTM, zaman serilerindeki uzun vadeli bağımlılıkları yakalamak için tasarlanmış olan bir yapay sinir ağı türüdür. Bu çalışma da LSTM modeli, 12 aylık geçmiş veriyi kullanarak bir sonraki ayı tahmin edecek şekilde eğitilmiştir. Veriler 0-1 aralığına ölçeklendirildi ve aşırı öğrenmeyi önlemek için dropout ve erken durdurma (early stopping) gibi teknikleri kullanılmıştır. Ancak veri setinin küçük olması ve pandemi döneminde oluşan belirsizlikler nedeniyle modelin aşırı öğrenme eğilimi artırılmıştır. Literatüre bakıldığında zaman küçük veri setlerinde LSTM gibi derin öğrenme yöntemlerinin diğer basit yöntemlere göre daha hatalı sonuçlar verebildiği bilinmektedir. Bu

çalışmada da LSTM modeli dikkatli bir şekilde kurulmasına rağmen doğruluk açısından geleneksel yöntemlerin gerisinde kalmıştır.

XGBoost (Aşırı Gradient Artırma Karar Ağaçları): XGBoost, birçok karar ağacını artarda eğiterek güçlü bir tahmin modeli oluşturan bir regresyon modelidir. Zaman serisi tahmini için, geçmiş aylara ait verilerden gecikme değerleri ve trend ile mevsimsellik bilgilerini temsil eden değişkenler kullanılmıştır. Model, her ay için son 12 ayı baz alarak bir sonraki ayı tahmin edecek şekilde eğitilmiştir. Veriler kayan pencere yöntemiyle hazırlanmıştır. Modelin derinliği ve öğrenme hızı gibi ayarları çapraz doğrulama yöntemiyle optimize edilmiştir. XGBoost, genellikle karmaşık yapıları öğrenmede daha iyi sonuçlar verirken, saf zaman serisi desenlerini yakalama konusunda geleneksel modellere karşı bazen dezavantajlı olabildiği görülmüştür.

Random Forest (Rastgele Orman): Rastgele orman, birden çok karar ağacının rastgele alt örneklem ve özellik seçimleriyle oluşturulup ortalamasının alındığı bir topluluk yöntemidir. Zaman serisi için Random Forest yaklaşımı, XGBoost ile benzer şekilde gerçekleştirilmiştir. 12 aylık gecikmeler özellik olarak kullanılarak her ayın tahmini yapılmıştır. Rastgele orman modelinde çok fazla parametre olmamakla birlikte, ağaç sayısı ve maksimum derinlik gibi parametreler denenerek hata minimize edilmeye çalışılmıştır. Rastgele Orman da tıpkı XGBoost gibi trendi ve mevsimselliği dışarıdan verilen özellikler sayesinde öğrenmeye çalışmış, ancak verinin kompleks yapısını tam kapsayamadığı gözlemlenmiştir.

2.4. Başarı Performanslarının Karşılaştırması

Bu çalışmada oluşturulan tüm modeller 2010-2021 yılları arası kişi sayısı verisinde eğitilmiş, 2022 yılı aylık verilerini tahmin etme performanslarına göre karşılaştırılmıştır. Karşılaştırma metrikleri olarak RMSE, MAE ve MAPE kullanılmıştır. Aşağıda her modelin test veri setindeki (2022) tahmin hataları Tablo 4, Ek 2 ve Ek 3’de gösterilmiştir.

Tablo 5. Model hata metrik sonuçları

Model	RMSE	MAE	MAPE	Açıklama
SARIMA	75.29	64.12	5,33	En düşük hata
Holt-Winters	120.05	106.71	7,58	
Prophet	321.84	286.54	10.38	
XGBoost	381.78	345.04	12.52	
LSTM	294.91	287.56	10.16	En yüksek hata


Tablo 5’te gösterilen model sonuçlarına bakıldığı zaman genel olarak SARIMA modelinin en iyi performansı gösterdiğini ortaya koymaktadır. SARIMA modelinin hata oranı en düşük olup, özellikle MAPE değerinin %5 civarında olması dikkat çekicidir. Bu model hem trendi hem de mevsimselliği etkin şekilde yakaladığı için 2022 yılındaki dalgalanmaları isabetli öngörebilmiştir. Holt-Winters ve Prophet modelleri de SARIMA’ya yakın performans göstermiş, hataları sadece biraz daha yüksek kalmıştır. Bu durum, her iki yaklaşımın da mevsimsel paternleri yakalamada başarılı olduğunu, ancak SARIMA’nın parametre optimizasyonu ile veriye biraz daha iyi uyum sağladığını göstermektedir.

Makine öğrenmesi tabanlı modellerden XGBoost, klasik yöntemlere kıyasla daha yüksek hata vermiştir. Bu model, bazı aylarda trend değişimlerini yakalamakta zorlanmış ve gerçek değerden aşırı sapmalar göstermiştir. Özellikle ağaç tabanlı modeller, veride görülmeyen yeni uç değerleri veya trend devamını dışa taşımakta bazen daha başarısız olabilmektedir. Nitekim literatürde incelendiğinde ARIMA modellerinin birçok durumda ağaç tabanlı modellere göre daha iyi performans gösterdiği görülebilmektedir.

LSTM modeli ise en zayıf performansı sergilemiştir. Küçük veri setlerinde LSTM’nin aşırı parametrik yapısı nedeniyle daha başarısız tahminler yapabilmektedir. Bu çalışmada da LSTM eğitimi eğitim verisine çok iyi uyup test verisinde beklenenden daha büyük hatalar verdiği gözlemlenmiştir.


Tüm model sonuçları karşılaştırıldığında, en iyi model SARIMA olarak belirlenmiştir. SARIMA modeli, 2022 yılının her ayı için en yakın tahminleri üretmiş ve toplam kokpit personel sayısını sadece %5’lik bir ortalama hata ile öngörmüştür. Ayrıca mevsimsel pik ve dip noktalarının zamanlamasını doğru şekilde tahmin edebilmiştir. En başarılı ikinci model Holt-Winters/Prophet olurken, bu modelin de kabul edilebilir seviyede hatalar verdiği ancak SARIMA modeline kıyasla tutarlı olmadığı saptanmıştır. Makine öğrenimi yöntemleri ile elde edilen modeller ise bu çalışma da klasik zaman serisi yaklaşımların gerisinde kaldığı görülmektedir.

2.4.1. Kaptan Sınıfı Kişi Sayısı Değişkeni İçin Tüm Modellere Ait Karşılaştırmalı Model Sonuçları




Şekil 14. SARIMAX model sonuçları

Şekil 14 incelendiği zaman aslında Türk Hava Yolları'nın son 15 sene de nasıl bir büyüme geliştirdiği açıkça görülebilmektedir. 2010 yılından sonra grafik eğiminde oluşan ani kırılım kaptan sayısında ki hızlı artışı göstermektedir. 2012 yılından itibaren personel sayısında ki artış daha istikrarlı ve kontrolü hale gelmiştir. Pandemi döneminde yaşanan bariz düşüş olurken pandemi sonrası toparlanma süreci SARIMAX modeli ile doğru bir şekilde yakalandığı görülebilmektedir. Toparlanma süreci ile kaptan sayısında yeniden yükseliş trendinin başladığı da Şekil 14'de net bir şekilde fark edilmektedir. SARIMAX modeli genel olarak trendi iyi yakalarken durağan dönemlerde ve normal artışlarda güçlü bir performans göstermiştir. 2023-2024 döneminde ki artış trendi havacılık sektörünün gelecek yıllarda büyümeye devam edeceğine dair güçlü bir sinyal vermektedir.




Şekil 15. Prophet model sonuçları

Prophet model sonuçlarına bakıldığı zaman genel olarak artış trendini başarılı bir şekilde yakaladığı, 2020 yılına kadar gerçek değerlerle benzer yükseliş eğilimini takip ettiği Şekil 15’de görülebilmektedir. Ancak pandemi döneminde ani düşüş ve sıçramalar bulunmaktadır. Prophet modeli bu sıçramalara tam uyum sağlayamamıştır. 2022 yılından itibaren genişleyen güven aralığı bu dönemde artan belirsizliği göstermektedir.




Şekil 16. LSTM model sonuçları

LSTM model sonuçları incelendiği zaman model genelinde yükseliş trendini belirli bir yıla kadar başarılı bir şekilde takip ettiği görülmektedir. Ancak yıllar ilerledikçe LSTM gerçek değerlere göre daha düz bir seyir izlemekte olduğu Şekil 16'dan anlaşılmaktadır. Özellikle 100. aydan sonra gerçek verilerle olan uyumu zayıflamaktadır. 120 ve 140. aylar arasında ki dalgalanmayı da yakalayamayan LSTM modeli, sonuçlara göre yetersiz öğrenme (underfitting) eğilimi göstermiştir.



Şekil 17. LSTM, XGBoost ve Rastgele Orman model karşılaştırılması


Şekil 17'de verilen LSTM, XGBoost ve Rastgele Orman model sonuçları karşılaştırıldığı zaman XGBoost modelinin diğer modellere göre dalgalanmaları ve trendi daha iyi yakaladığı görülebilmektedir. LSTM verideki dalgalanmalara tepkisiz kalırken Rastgele Orman modeli veride ki mevsimselliği ve trend etkisini yakalayamamış ve en kötü performansı göstermiştir.



Şekil 18. SARIMA ve Holt-Winters model karşılaştırması

SARIMA ve Holt-Winters model sonuçlarını şekil 18’de verilmiştir. Sonuçları karşılaştırdığımız zaman, SARIMA’nın trendi koruyan ve daha stabil bir tahmin çizgisi üretmiş olduğu görülebilmektedir. 2023-2024 yıllarında yapmış olduğu tahminler ile gerçek veri değerleriyle uyumlu başlamaktadır. Holt-Winters modeli ise daha keskin bir büyüme tahmini yapmıştır. Bu da 2024 yılı sonunda daha fazla kokpit ekibi olacağı anlamına gelmektedir. Sezonsal bileşeni daha kuvvetli olan Holt-Winters modeli dalgalanmaları daha belirgin yansıtmıştır.


2.4.2. F/O Sınıfı Kişi Sayısı Değişkeni İçin Tüm Modellere Ait Karşılaştırmalı Model Sonuçları



Şekil 19. F/O SARIMAX model sonuçları


SARIMAX F/O sınıfı tahmin sonuçları incelendiğinde genel trendi iyi takip ettiği görülmektedir. Gelecek yıllar için normal bir artış öngörmektedir. Pandemi döneminde yaşanan düşüşü SARIMAX modeli ile doğru bir şekilde yakalandığı görülebilmektedir.

Model sonuçlarına bütünüyle bakıldığı zaman, SARIMAX modeli genel olarak trendi iyi yakalarken pandemi ve normal dönemde güçlü bir performans göstermiştir.



Şekil 20. F/O sınıfı Prophet model sonucu

Prophet model sonuçları incelendiğinde, genel trendi ve mevsimselliği yakalamıştır, fakat son yıllarda genişleyen güven aralığı gelecek dönem için belirsizlik beklentisi olduğunun göstergesidir. 2022 sonrası daha yatay bir tahmin yapması, agresif büyüme öngörmediği anlatmaktadır.




Şekil 21. LSTM, XGBoost ve Rastgele Orman model karşılaştırması

LSTM, XGBoost ve Rastgele Orman model çıktıları karşılaştırıldığı zaman, gerçek veriye en yakın eğilimi XGBoost modelinin gösterdiği görülebilmektedir. Ani değişimleri

LSTM'den daha iyi yakalamıştır ve güçlü tahmin yapmış olmasına rağmen, zaman zaman fazla dalgalanma gösterdiği için aşırı öğrenme (overfitting) riski bulunmaktadır. Rastgele Orman ise mevsimselliği kısmen yakalamış ve düşüşleri tam olarak tahminleyememiştir.


Genel eğilimi koruyor fakat detay kayıplarında ciddi bir sapma bulunmaktadır.

2.4.3. P3 Sınıfı İçin Kişi Sayısı Değişkeni İçin Tüm Modellere Ait Karşılaştırmalı Model Sonuçları




Şekil 22. P3 sınıfı SARIMAX tahmin sonuçları

P3 sınıfı için SARIMAX tahmin sonuçları kaptan ya da F/O sınıfı kadar başarılı olmadığı görülebilmektedir. Tahmin çizgisi dalgalanmaları yakalayamamıştır. Özellikle 2020 sonrası gerçek değerlerden sapmıştır.



Şekil 23. P3 Sınıfı Prophet model sonuçları

Şekil 23'te P3 sınıfı için Prophet modelinin sonuçları gösterilmiştir. Model ani sıçramaları ve düşüşleri yakalayamazken, 2020 sonrası gerçek değerler ile tahmin değerleri arasındaki farkın açıldığı görülebilmektedir.




Şekil 24. P3 Sınıfı LSTM, XGBoost ve rastgele orman model karşılaştırması

P3 sınıfının verisi çok değişken bir yapıya sahip olduğu için klasik modeller bu seriyi tam olarak yakalayamamıştır. XGBoost daha esnek olmasına rağmen uzun dönem trendini kaçırmaktadır. LSTM ise genel eğilimi yakalarken ani değişimleri yakalamakta başarısız

olduğu görülebilmektedir. Rastgele Orman en çok sapmayı yapan model olmuştur. Model, karmaşık trendleri öğrenmekte zorlanmış ve düşük tahmin değerlerinde kalarak en başarısız tahmini yapmıştır.

2.4.4. Simülör-Eğitim Değişkeni Tüm Modellere Ait Karşılaştırmalı Model Sonuçları



Şekil 25. Kaptan sınıfı simülör-eğitim model karşılaştırması

Kaptan sınıfı için Simülör -eğitim model sonuçları incelendiğinde gerçek veriye en yakın tahminlerin SARIMAX modeli tarafından yapıldığı Şekil 25’de görülebilmektedir.

2023 sonrası daha stabil kalmış, genel trendi ve mevsimselliği iyi yakalamıştır. Prophet modeli, SARIMAX modelinden sonra en stabil ve dengeli tahminler yapan modeldir. Ani artış ve düşüşleri düzleştirdiği görülmüştür. Holt-Winters modeli aşırı tahminlerde bulunmuş

ve son yıllarda kopmalar yaşamıştır. LSTM modeline bakıldığında özellikle bazı dönemlerde gerçek veriden ciddi sapmalar yapmıştır. XGBoost ise diğer modeller ile karşılaştırıldığında daha yatay tahminler yaptığı görülmektedir. Aşırı uç tahminler yapmasa da gerçek değerleri yakalamada eksik kalmıştır.


Tablo 6. Kaptan Sınıfı simülör-eğitim model hata metrik sonuçları

Model	RMSE	MAE	MAPE	Açıklama
SARIMA	692.24	539.03	13.75	
Holt-Winters	1418.48	1292.67	24.97	En yüksek hata

Tablo 6'nın devamı

Prophet	871.94	692.62	15.03	
XGBoost	870.77	722.92	13.96	
LSTM	765.83	593.24	11.42	En düşük hata

Kaptan sınıfı simülatör-eğitim modellerinin hata Tablo 6, Ek 4 ve Ek 5’de verilmiştir. Tabloya bakıldığı zaman SARIMAX modelinin en stabil ve düşük yüzdesel hata veren model olduğu anlaşılmaktadır. Bu nedenle SARIMAX modeli açık ara en iyi modeldir. Prophet modeli MAPE derecesi en düşük olan ikinci model olarak karşımıza çıkmıştır. MAE ve RMSE değerleri de orta seviye de gitmiştir. SARIMAX kadar güçlü olmasa da en az tahmin hatasına sahip ikinci model olmayı başarmıştır. Holt-Winters model sonuçlarına bakıldığı zaman her ne kadar MAPE değeri SARIMAX’a yakın çıkmış da olsa MAE ve RMSE değerleri oldukça yüksek çıkmıştır. XGBoost ve LSTM sonuçları incelendiğinde bu iki modelinde aşırı hata ürettiği gözlemlenmiştir.



Şekil 26. F/O sınıfı simülatör-eğitim model karşılaştırması

Şekil 26’da F/O sınıfı simülatör-eğitim model sonuçları karşılaştırılmıştır. Sonuçlara bakıldığı zaman SARIMAX ve Prophet modellerinin en güvenilir tahminler sunduğu anlaşılmaktadır. SARIMAX dengeli ve istikrarlı bir tahmin yaparken, geçmiş trendi koruyor ve ani sıçramalar yapmamaktadır. Prophet modeli ise geçmiş dalgalanmalara göre daha stabil bir tahmin çizgisi çektiği görülmektedir. LSTM modeli fazla dalgalı ve tahmin

aralığının geniş olduğu bir banda sahiptir. XGBoost, en düşük seviye de tahmin üreten model olarak gözlemlenmiştir. Özellikle son yıllarda ki artış trendini yakalayamamıştır. HoltWinters modelinin ise diğer modellere göre daha yatay bir tahmin çizgisi bulunmaktadır.


Sezonsal etkiyi yakalamakta zorlandığı görülmektedir.

Tablo 7. F/O Sınıfı simülatör-eğitim model hata metrik sonuçları

Model	RMSE	MAE	MAPE	Açıklama
SARIMA	613.30	539.48	31.73	
Holt-Winters	709.63	558.50	28.75	
Prophet	588.02	528.74	34.35	En yüksek hata
XGBoost	475.83	412.08	24.15	En düşük hata
LSTM	511.79	470.81	27.96	

Tablo 7, Ek 6 ve Ek 7’de F/O sınıfı simülatör-eğitim model sonuçlarının hata metrikleri gösterilmiştir. LSTM ve XGBoost modelleri hem genel hata hem de MAPE açısından en güçlü sonuçları veren modeller olmuştur. SARIMAX modeli geleneksel model olarak ortalama bir başarı sağladığı görülmektedir. Prophet ve Holt-Winters modelleri ise tüm metrikler de en kötü sonuçları üreten modeller olmuşlardır.

2.4.5. Ofis Değişkeni İçin Tüm Modellere Ait Karşılaştırmalı Model Sonuçları




Şekil 27. Kaptan sınıfı ofis model karşılaştırılması

Kaptan sınıfı için ofis model sonuçları karşılaştırılması Şekil 27’de verilmiştir. Karmaşık yapıyı ve trendi en iyi yakalayan modelin XGBoost modeli olduğu görülmüştür. Bir diğer başarılı model ise LSTM olmuştur. LSTM, dalgalanmaları iyi öğrenmiş olmasına rağmen zaman zaman sapmalar yaşadığı görülebilmektedir. SARIMAX ve Holt-Winters modelleri pandemi ve ani değişimleri yakalamakta zorlanmıştır. Bu nedenle daha düz tahminler üretmişlerdir. Prophet modeli ise gerçek veriden en ciddi anlamda uzaklaşan model olarak bu veri seti için yetersiz kalmıştır.

Tablo 8. Kaptan Sınıfı Ofis model hata metrik sonuçları

Model	RMSE	MAE	MAPE	Açıklama
SARIMA	690.50	621.67	41.11	
Holt-Winters	261.37	201.94	12.70	En düşük hata
Prophet	820.42	791.58	51.54	En yüksek hata
XGBoost	350.92	129.22	18.15	
LSTM	511.79	258.16	27.96	

Tablo 8, Ek 8 ve Ek 9’da Kaptan sınıfına ait hata metrikleri incelendiğinde, tüm metriklerde en düşük hatayı gösteren model Holt-Winters olmuştur. LSTM ve XGBoost birbirine yakın hatalar ortaya çıkararak alternatif modeller olarak öne çıkmaktadır. SARIMAX ve Prophet modelleri ise en yüksek hata değerlerine sahip iki model olarak göze çarpmaktadır.



Şekil 28. F/O sınıfı ofis model karşılaştırması


F/O sınıfına ait ofis model sonuçları karşılaştırıldığı zaman en güçlü modellerin SARIMAX ve Holt-Winters modelleri olduğu şekil 28’de görülmektedir. Bu iki modelin geçmiş veride ki düşüş eğilimini fazlasıyla yansıttığı görülebilmektedir. Bu nedenle düşük tahminler yapmıştır. Prophet modeli mevsimsel dalgalanmaları iyi yansıtıp, orta seviye tahminler yapmış olmasına rağmen ani çıkış ve düşüşleri öngörememektedir. LSTM ve XGBoost artışı en fazla öngören modellerdir. Yüksek risk-yüksek getiri tahminleri yapmıştır.

Tablo 9. F/O Sınıfı Ofis model hata metrik sonuçları

Model	RMSE	MAE	MAPE	Açıklama
SARIMA	343.89	304.96	74.98	
Holt-Winters	171.59	160.55	41.73	
Prophet	384.40	374.14	90.80	En yüksek hata
XGBoost	77.92	59.44	12.42	En düşük hata
LSTM	74.87	61.76	14.76	

Tablo 9, Ek 10 ve Ek 11’de gösterilen F/O sınıfı Ofis hata metrikleri incelendiğinde, en düşük hataya sahip modellerden biri olan XGBoost modeli göze çarpmaktadır. Hem ortalama hata hem de yüzdesel hata açısından en dengeli modellerden biri olmuştur. LSTM modeli de XGBoost gibi en iyi performans gösteren bir diğer modeldir. Zaman serisindeki karmaşıklığı yakalamada başarılı olduğu söylenebilmektedir. Holt-Winters ortalama bir performans göstermiştir. Sezonsal etkileri iyi yakalamasına rağmen MAPE değeri bakımından LSTM ve XGBoost modelinin arkasında kalmıştır. SARIMAX ve Prophet modelleri ofis tahmini için çok zayıf olduğu anlaşılmaktadır. SARIMAX modeli özellikle trend ve ani sıçramaları yakalamakta zorlanmıştır.

2.4.6. Yıllık İzin Değişkeni İçin Tüm Modellere Ait Karşılaştırmalı Model Sonuçları



Şekil 29. Kaptan sınıfı yıllık izin model karşılaştırılması


Şekil 29’da Kaptan sınıfına ait yıllık izin model sonuçları incelendiğinde, XGBoost ve Holt-Winters modelleri en uygun modeller olarak öne çıkmaktadır. XGBoost modeli dalga hareketlerine daha duyarlı ve ani yükseliş ve düşüşleri en iyi yakalayan modeldir. HoltWinters ise mevsimsel dalgalanmaları iyi yakalamasına rağmen, ani yükseliş ve düşüşleri düzleştirerek tahmin yaptığı görülmektedir. SARIMAX modelinin büyük sıçramalara karşı yetersiz kaldığı gözlenmektedir. LSTM modeli ortalama bir tahmin yaparken, veride ki ani değişimleri kaçırmaktadır. Prophet modeli ise aşırı dalgalı ve fazla yukarı yönlü tahminler yapmıştır.

Tablo 10. Kaptan Sınıfı Yıllık İzin model hata metrik sonuçları

Model	RMSE	MAE	MAPE	Açıklama
SARIMA	2513.94	1946.92	82.53	
Holt-Winters	2255.25	1700.89	91.14	En yüksek hata
Prophet	2564.30	1849.23	85.15	
XGBoost	3190.95	2160.97	61.94	En düşük hata
LSTM	2626.40	1927.02	63.33	

Tablo 10, Ek 12 ve Ek 13’de kaptan sınıfı yıllık izin hata metrikleri verilmiştir. İlgili metrikler incelendiğinde, en düşük hata oranları ile XGBoost modeli en başarılı model

olmasına rağmen genel olarak hata metrikleri değerleri oldukça yüksek değerlere sahiptirler ve bu veri seti için çok zayıf bir performans göstermişlerdir.



Şekil 30. F/O sınıfı yıllık izin model karşılaştırılması

Şekil 30’da F/O sınıfına ait yıllık izin modelleri karşılaştırıldığında LSTM ve XGBoost modelleri en iyi iki model olarak öne çıkmaktadır. Bu iki model, mevsimselliği ve ani değişimleri yakalamakta diğer modellere göre çok daha başarılı olduğu görülebilmektedir. SARIMAX ve Holt-Winters modelleri gerçek seriden sapmalar göstermektedir. Bu iki model, mevsimsel dalgalanmaları yakalamayı başarabilse de düz çizgisel bir tahmin yapmışlardır.

Tablo 11. F/O Sınıfı Yıllık İzin model hata metrik sonuçları


Model	RMSE	MAE	MAPE	Açıklama
SARIMA	1889.08	1590.43	185.64	En yüksek hata
Holt-Winters	1711.59	1533.34	178.02	
Prophet	1600.76	1490.63	171.12	
XGBoost	1026.39	583.69	82.81	En düşük hata
LSTM	1369.40	1064.38	121.09	

Tablo 11, Ek 14 ve Ek 15’de verilen hata metrikleri incelendiğinde XGBoost modeli diğer modellere göre daha başarılı bir model olmuş olmasına rağmen genel sonuçlara


bakıldığı zaman hata değerlerinin oldukça yüksek olması bu veri seti için uygun modeller olmadıkları anlaşılabilmektedir.

2.4.7. Filo ve Sınıf Bazlı Tahmin Sonuçları

Kaptan Sınıfı Kişi Sayısı Model Sonuçları




Şekil 31. 340 Kaptan sınıfı kişi sayısı model karşılaştırması




Şekil 32. 340 Kaptan sınıfı kişi sayısı hata metrikleri

340 filosuna ait kaptan sayısı ile ilgili model ve hata metrikleri Şekil 31 ve 32’de verilmiştir. Sonuçlara göre en iyi performans gösteren modellerin SARIMAX ve HoltWinters olduğu MAPE değerlerine bakıldığı zaman açıkça görülebilmektedir.



Şekil 33. 777 Kaptan sınıfı kişi sayısı model karşılaştırması




Şekil 34. 777 Kaptan sınıfı kişi sayısı hata metrikleri

Şekil 34 ve 35’de verilen 777 kaptan sınıfına ait değerlere bakıldığı zaman en düşük MAPE değerine sahip olan SARIMAX modelinin en başarılı model olduğu anlaşılabilmektedir. Holt-Winters modeli de tıpkı SARIMAX gibi düşük hata değerine sahip olmuştur. Diğer modellerin gerek MAPE gerek diğer hata metrikleri çok yüksek çıkması, veriye uygun olmadıklarını göstermiştir.



Şekil 35. 738 Kaptan sınıfı kişi sayısı model karşılaştırması




Şekil 36. 738 Kaptan sınıfı kişi sayısı hata metrikleri

Boeing 738 filosu için geliştirilen modeller ve hata metrikleri Şekil 35 ve 36’da verilmiştir. Model sonuçları incelendiğinde gerçek değerlere en yakın tahmini yapan modelin en düşük MAPE değeriyle SARIMAX olduğu görülebilmektedir. Holt-Winters modeli de MAPE değeri bakımından SARIMAX’a benzer bir performans göstermiştir.

Diğer modeller tıpkı 777 sınıfında olduğu gibi daha yüksek hata ile tahminler üretmiştir.




Şekil 37. 320 Kaptan sınıfı kişi sayısı tahmin karşılaştırması




Şekil 38. 320 Kaptan sınıfı kişi sayısı hata metrikleri

Airbus 320 filosunda kaptan olarak görev yapan ekiplerin model ve metrik sonuçları Şekil 37 ve 38’de verilmiştir. SARIMAX modeli en başarılı model olarak öne çıkmaktadır. En düşük MAPE değeriyle de gerçek veriye ne kadar paralel tahmini yaptığı anlaşılabilmektedir. Holt-Winters modeli her ne kadar diğer modellere göre düşük MAPE değerine sahip de olsa veride ki sıçramaları tam olarak yakalayamamış ve gerçek değerlerin altında tahminler yapmıştır. LSTM kısa vadede HW’a benzese de gerçek değerlere verdiği tepkinin zayıf olduğu Şekil 44’den anlaşılabilmektedir.

F/O Sınıfı Kişi Sayısı Model Sonuçları




Şekil 39. 340 F/O sınıfı kişi sayısı tahmin karşılaştırması




Şekil 40. 340 F/O sınıfı kişi sayısı hata metrikleri

Airbus A340 F/O sınıfı karşılaştırılmalı model sonuçları şekil 39’da verilmiştir. Hata metrik sonuçlarına bakıldığı zaman en düşük MAPE değerine sahip modelin Holt-Winters olduğu anlaşılabilmektedir. Gerçek veriye yakın giden bir tahmin eğrisi olmasına rağmen daha düz tahminlerde bulunmuştur. SARIMAX modeli incelendiğinde, MAPE değeri her ne kadar HW’den biraz daha yüksek de olsa, en stabil ve gerçek veriyi en iyi takip eden model olduğu Şekil 40’da görülebilmektedir. Prophet, LSTM ve XGBoost modelleri gerçek verinin oldukça altında kalan tahminler üretmişlerdir. Bu durum Şekil 52’de ki hata metrik değerlerine bakınca da kolayca anlaşılabilmektedir.



Şekil 41. 777 F/O sınıfı kişi sayısı tahmin karşılaştırması




Şekil 42. 777 F/O sınıfı kişi sayısı hata metrikleri

Şekil 41 ve 42’de Boeing 777 F/O sınıfına ait tahmin ve hata metrikleri verilmiştir. Hem model tahmin sonuçlarına hem hata metriklerine bakıldığı zaman en yakın tahmini yapan modelin SARIMAX olduğu anlaşılabilmektedir. Özellikle son dönemde olan sert yükselişi başarılı bir şekilde yakalamasıyla diğer modellerin önüne geçmiştir. Holt-Winters modeli de her ne kadar SARIMAX modeline yakın performans göstermiş olsa da son dönem de olan sıçramayı SARIMAX kadar başarılı yakalayamamıştır. Prophet modeli ise genel olarak eğilimi yakalamıştır fakat tahminler gerçek veriden biraz daha yukarda kalmıştır.



Şekil 43. 320 F/O sınıfı kişi sayısı tahmin karşılaştırılması




Şekil 44. 320 F/O sınıfı için kişi sayısı hata metrikleri

Airbus A320 filosu F/O sınıfı için geliştirilen model ve hata metriklerine bakıldığı zaman gerçek veriye en yakın tahmin yapan modelin yine SARIMAX olduğu Şekil 43’de görülebilmektedir. Hem düşüş eğilimini hem de 2023 sonrası yaşanan toparlanma sürecini iyi yakalamış olması Şekil 44’de bakıldığı zaman düşük MAPE değerinden de anlaşılabilmektedir. Holt-Winters ve XGBoost modelleri SARIMAX modeline yakın tahminler yapmışlardır. HW daha düz tahminler üretip, düşüş sonrası toparlanmayı yakalayamazken, XGBoost düşüşü görürken, toparlanmayı tam anlamıyla tahmin edememiştir.




Şekil 45. 738 F/O sınıfı kişi sayısı tahmin karşılaştırılması



Şekil 46. 738 F/O sınıfı kişi sayısı hata metrikleri


Şekil 45 ve 46’da Boeing 738 filosu F/O sınıfına ait model karşılaştırılması ve hata metrikleri verilmiştir. Diğer modellere benzer şekilde en iyi performansı yine SARIMAX modeli göstermiştir. Düşüş sonrası toparlanmayı temkinli bir şekilde yansıttığı görülebilmektedir. Holt-Winters modeli de benzer bir eğilim de performans göstermesine rağmen sert bir toparlanma öngörmektedir. SARIMAX’a göre daha iyimser bir model olarak öne çıkmaktadır. XGBoost modeli de dengeli bir tahmin yapmış da olsa SARIMAX kadar güçlü değildir. LSTM modelinin ise gerçek veriyle paralelliği zayıf ve tahmin değerleri düşüş eğilimindedir.

Kaptan Sınıfı Ofis Değişkeni Model Sonuçları




Şekil 47. 738 Kaptan sınıfı ofis tahmin karşılaştırılması

Boeing 738 kaptan sınıfı ofis görevleri için üretilen modeller Şekil 47’de gösterilmiştir. Model tahmin sonuçlarına bakıldığında, SARIMAX modeli en sert çıkışı yapan model olarak göze çarpmaktadır. Mevcut trend ile en uyumsuz tahmin yapan modellerden biri olmuştur. Holt-Winters modeli dalgalı seyri kısmen korumuş olmasına rağmen yukarı yönlü tahminler yapmaktadır. En yatay ve durağan tahmini yapan model ise LSTM’dir. Gerçeğe yakın tahminler yapmış olmasına rağmen, ani değişimlere karşı duyarsız kalmıştır. Diğer modeller ile karşılaştırıldığında Prophet modeli, en dengeli ve düz tahmin yapan model olarak göze çarpmasına rağmen gerçek verinin ani hareketlerini tepkisiz kalmıştır.




Şekil 48. 320 Kaptan sınıfı ofis tahmin karşılaştırılması

320 Kaptan sınıfı ofis günleri model sonuçları karşılaştırıldığında Holt-Winters modelinin bu veri setine en uygun model olduğu Şekil 48’de görülebilmektedir. HW modeli mevcut düşüş trendini en iyi yakalayan model olarak da öne çıkmaktadır. XGBoost modeli diğer modellere göre daha yukarıda kalan ama tahmin aralığının daha az olduğu bir tahmin üretmiştir. SARIMAX modeline bakıldığı zaman ise, yukarı doğru eğimi ve en yukarıda kalan tahminlerine ek olarak gerçek veri düşüş trendinde iken toparlanma ön görerek en başarısız modellerden olmuştur.




Şekil 49. 340 Kaptan sınıfı ofis tahmin karşılaştırılması

Şekil 49’da 340 filosu kaptan sınıfına ait modeller karşılaştırılmıştır. Holt-Winters modeli bu veri seti için en dengeli makul olmasına en olarak gerçek değer eğilimini en iyi takip eden model olarak diğer modellerden bir adım öne çıkmaktadır. SARIMAX modeli pandemi döneminde oluşan düşüşten sonra toparlanma sürecini daha hızlı yapmaktadır. Buda yukarı yönlü iyimser bir tahmin yaptığı anlamına gelmektedir. LSTM modeli dalgalanmayı ve düşüşü yakalayabilmesine rağmen bazı dönemlerde aşırı düşük değerler tahmin ettiği görülmüştür. Prophet ve XGBoost modelleri ise gerçek veriden belirgin şekilde uzak tahminler yaparak en başarısız performansı gösteren modeller olmuştur.




Şekil 50. 777 Kaptan sınıfı ofis tahmin karşılaştırılması


Boeing 777 filosu kaptan sınıfı için modeller karşılaştırıldığı zaman bu filo için de Holt-Winters modeli dengeli bir tahmin üretmesiyle bir adım öne çıkmış gözükmemektedir. Her ne kadar gerçek veriye yaklaşmış da olsa dalga boylarına bakıldığında zaman gerçek veri kadar büyük değil de daha yumuşak ilerlediği Şekil 50’de görülebilmektedir. Gerçek verinin üstünde yaptığı tahminlerle SARIMAX modeli her ne kadar son zamanlar da oluşan trendin yukarı doğru olacağını öngörse de fazla iyimser bir model olarak göze çarpmaktadır.



Şekil 51. Kaptan sınıfı ofis MAE hata metriği




Şekil 52. Kaptan sınıfı ofis RMSE hata metriği




Şekil 53. Kaptan sınıfı ofis MAPE hata metriği

Tüm filoların kaptan sınıflarının ofis günlerine ait hata metrikleri Şekil 51, Şekil 52 ve Şekil 53’de verilmiştir. XGBoost ve LSTM modelleri 320, 340 ve 738 filoları için en düşük hata değerine sahip modeller olmuşlardır. MAPE değerlerine bakıldığı zaman ise 777 filusunda en düşük hatayı veren modelin SARIMAX olduğu açıkça görülmektedir. Tüm hata metriklerine bakıldığı zaman Prophet modelinin en yüksek hata oranıyla bu veri setlerine uygun olmadığı çok net bir şekilde belli olmaktadır.


F/O Sınıfı Ofis Değişkeni Model Sonuçları




Şekil 54. 777 Filosu F/O sınıfı ofis tahmin karşılaştırılması




Şekil 55. 738 Filosu F/O sınıfı ofis tahmin karşılaştırılması




Şekil 56. 320 Filosu F/O sınıfı ofis tahmin karşılaştırılması




Şekil 57. 340 Filosu F/O sınıfı ofis tahmin karşılaştırılması



Şekil 58. F/O Sınıfı ofis MAE hata metriği



Şekil 59. F/O Sınıfı ofis RMSE hata metriği



Şekil 60. F/O Sınıfı ofis MAPE hata metriği

Tüm filoların F/O sınıflarına ait model ve hata metriklerine bakıldığı zaman 320 filosu için tüm metriklerde en düşük hata değerine sahip olan modelin Holt-Winters modeli olduğu Şekil 58, 59 ve 60'da açık bir şekilde gözükmemektedir. LSTM ise Holt-Winters'a en yakın hata payına sahip olurken SARIMAX modeli bu filo ve sınıf kırılımının da en başarısız model olarak göze çarpmaktadır. Şekil 57'de verilen model tahmin karşılaştırılmasına göre de gerçek değerlere en yakın tahmini üreten modelin Holt-Winters olduğu görülebilmektedir. Bir diğer başarılı model olan LSTM'in de tahmin sonuçlarına bakıldığı zaman HW gibi trendi iyi yakalayabildiği görülebilmektedir.


Boeing 738 filosuna ait model karşılaştırmaları Şekil 56'de verilmiştir. Hem model tahmin sonuçları hem hata metrikleri karşılaştırıldığı zaman LSTM ve XGBoost modellerinin diğer modellere göre daha aşağıda ve gerçek değere en yakın tahminler yaparak, bu filo ve sınıf için en başarılı performans gösteren modeller olduğu anlaşılabilmektedir. 738 filosu için en başarısız modellerin ise SARIMAX ve Prophet modelleri olduğu model sonuçları ve hata değerlerinden net bir şekilde anlaşılmaktadır.

Şekil 58'de verilen 340 filosuna ait model karşılaştırma ve hata metriklerine bakıldığı zaman, LSTM modelinin bu filo sınıfında açık ara en başarılı model olduğu çok net bir şekilde görülmektedir. XGBoost modeli de LSTM gibi gerçek veri çizgisine en yakın tahmin modeli olmuştur. SARIMAX, Prophet ve Holt-Winters gerçek veriden çok fazla sapma yaparak bu Airbus A340 filosu için uygun bir model olmadıklarını göstermişlerdir.


Boeing 777 filosuna ait tahminler incelendiğinde ise en başarılı modeller diğer geniş gövde filosu olan Airbus A340 filosu gibi LSTM ve XGBoost modelleri olmuştur. En stabil ve gerçek veriye en yakın tahmini yapan modeller olduğu Şekil 55'da da görülebilmektedir.

Gerçek değerlerden aşırı sapmalar yapan Prophet modelinin ise diğer filolarda olduğu gibi bu veri setine de uygun olmadığı açık bir şekilde görülmektedir.


Kaptan Sınıfı Yıllık İzin Değişkeni Model Sonuçları



Şekil 61. Kaptan sınıfı yıllık izin MAE hata metriği



Şekil 62. Kaptan sınıfı yıllık izin RMSE hata metriği



Şekil 63. Kaptan sınıfı yıllık izin MAPE hata metriği

Şekil 61, 62 ve 63’de kaptan sınıfı yıllık izin tahminlerine ait hata metrikleri verilmiştir. Tüm filolara ait hata metrikleri genel olarak yüksek seviyelerde olduğu görülebilmektedir. Airbus A320 filosuna ait hata metrikleri incelendiğinde en düşük hata payına sahip olan modelin Holt-Winters modeli olduğu gerçeğe en yakın değerler ürettiği anlaşılabilmektedir. Tahmin modeli her ne kadar ani değişimleri kaçırmış olsa bile diğer modellere göre en başarılı performansı gösteren model olarak öne çıkmıştır. SARIMAX modeli de en düşük hata metriklerine sahip ikinci model olmuştur. SARIMAX modeli de HW modeli gibi ani değişimleri ve trendi başarılı bir şekilde yakalayamadığı hata metriklerine bakıldığında anlaşılabilmektedir. Çoğu model de olduğu gibi bu filo ve sınıf özelinde de en başarısız tahminleri Prophet modeli üretmiştir.


Bir diğer dar gövde uçağı olan Boeing kaptan sınıfı için de en başarılı performans gösteren model Holt-Winters modeli olmuştur. Her ne kadar ani değişimleri tam anlamıyla yakalayamamış olsa da sonlara doğru oluşan düşüş trendini en iyi şekilde yakalan model olmayı başarmıştır. En başarılı ikinci model bu filo için LSTM olmuştur. LSTM’de tıpkı HW gibi en yakın tahmini yapabilen bir diğer modeldir. HW’den farklı olarak son dönemde ki düşüşü tam anlamıyla yakalayamamıştır. Prophet modeli bu model için de uygun bir model olmadığı hata sonuçlarına bakıldığında net bir şekilde anlaşılabilmektedir.

Bir diğer Boeing modeli olan 777 filosunun sonuçları incelendiğinde model sonuçlarının genel olarak birbirine yakın ve yüksek MAPE sonuçları ortaya çıktığı görülebilmektedir. Bu durumda modellerin değişimleri doğru bir şekilde öğrenemedikleri,


ani deęişimleri kaçırdıkları, 2023 yılında olan yükseliş trendini yakalayamadıkları net bir şekilde anlaşılamamaktadır. Benzer hata paylarına sahip olmalarına rağmen en düşük MAPE deęerine sahip modelin yine Holt-Winters olduęu görülebilmektedir. SARIMAX modeli de bir dięer düşük MAPE deęerine sahip model olmuştur. Bu iki model her ne kadar yükseliş trendini yakalayamamış olsalar bile son dönemde oluřan deęişimi daha iyi yakalayarak dięer modellere göre daha öne çıkmışlardır.

Dięer bir geniş gövde filosu olan Airbus 340 filusunda görev yapan kaptanların yıllık izin modellerinin hata metrik sonuçları incelendiğinde dięer filoların aksine Prophet modeli en başarılı performans gösteren model olmuştur. Prophet modeli, dięer modellere göre gerçek veriye en yakın tahmin yaptıęı görülmüştür. Modellerin dięer filolarda olduęu gibi ani yükseliş öğrenemedięi hata deęerlerinden net bir şekilde anlaşılabilir. Prophet modeli ise oluřan ani deęişimleri çok keskin olmasa da dięer modellere göre daha ılımlı tahmin yapmıştır.


F/O Sınıfı Yıllık İzin Deęişkeni Model Sonuçları



Şekil 64. F/O sınıfı yıllık izin MAE hata metrięi



Şekil 65. F/O sınıfı yıllık izin RMSE hata metriği



Şekil 66. F/O sınıfı yıllık izin MAPE hata metriği

Türk Hava Yolları'nda First Officer olarak görev yapan uçuş ekiplerinin yıllık izin modellerinin hata metrikleri Şekil 64, 65 ve 66'da gösterilmiştir. Geniş gövde uçaklarına bakıldığı zaman hata metriklerinin birbirine çok benzer hata değerlerine sahip oldukları görülebilmektedir. Boeing 777 filosu için gerçek değere en yakın tahminleri yapan modellerin Holt-Winters ve XGBoost olduğu MAPE değerine bakıldığı zaman net bir şekilde anlaşılmaktadır. Genel olarak modeller ani değişimlere göre daha ılımlı tahminler yapmış olsa da HW ve XGBoost modelleri değişimleri daha iyi öğrendikleri görülmüştür.


SARIMAX modeli de bu iki modele alternatif olarak en başarılı üçüncü model olarak öne çıkmıştır. Diğer modellerden temel farkı diğer modeller yükseliş trendini başından itibaren yakalarken SARIMAX başlangıç kısmını kaçırmıştır.

Diğer geniş gövde filosu olan 340 filosunun veri seti, diğer veri setlerine nispeten ani değişimler daha az ve yumuşaktır. Bu nedenle MAPE değerleri birbirine yakın çıkmıştır. MAPE hata metriğine göre en başarılı modelin yine Holt-Winters olduğu görülmüştür. HW, veride ki kırılımları en iyi şekilde öğrenen ve gerçek veriye en yakın model sonuçlarını üretmiştir. Diğer başarılı model olan SARIMAX modeli de HW modeli gibi gerçeğe yakın değerler tahmin etmiş ve diğer modellerin önüne geçmiştir. HW'den geri de kalmasının temel nedeni son dönemler de oluşan kırılımı daha ılımlı bir şekilde tahmin etmesidir.


Boeing 738 filosu sonuçlarında ise 340 filosunun aksine daha belirgin hata değerleri mevcuttur. XGBoost ve LSTM modelleri diğer modellere göre çok daha az MAPE değerleriyle öne çıkan iki model olmuştur. 340 filusunda olduğu gibi bu veri setinde de mevsimsel kırılımlar daha ılımlıdır. 738 filusunda yapılan tahminler gerçek değerlere göre daha yüksek şekilde olmuştur. Buda toparlanma döneminin daha hızlı olacağını öngörmüşlerdir. Çoğu modelde en başarılı performansı gösteren Holt-Winters modeli bu veri seti için en yüksek hata payına sahip model olmuş ve veriye uygun olmadığı açıkça görülmüştür.

Diğer bir dar gövde filosu olan Airbus A320 filusunda ise en başarılı tahmin üreten modelin XGBoost olduğu net bir şekilde görülebilmektedir. Gerçek değerlere en yakın sonuçları üreten ve kırılımları iyi şekilde yakalamayı başaran model olan XGBoost bu veri seti için en uygun model olduğunu kanıtlamıştır. Diğer modeller ise tıpkı 738 filusunda olduğu gibi daha çabuk toparlanma öngörmüş ve tahmin değerleri gerçek değerlerden yukarı doğru sapma yapmıştır.


Kaptan Sınıfı Simülör Eğitim Değişkeni Model Sonuçları



Şekil 67. Kaptan sınıfı simülör eğitim MAE hata metriği



Şekil 68. Kaptan sınıfı simülör eğitim RMSE hata metriği




Şekil 69. Kaptan sınıfı simülör eğitim MAPE hata metriği

Simülör eğitim tahmin modellerinin hata metrikleri Şekil 67, 67 ve 69’da gösterilmiştir. 320 filosuna bakıldığı zaman en başarılı modelin XGBoost modeli olduğu MAPE değerlerine bakıldığı zaman net bir şekilde görülebilmektedir. XGBoost modeli gerçek değerlere en yakın tahminleri üretmesinin yanında mevsimsel kırılımları da en iyi yakalayan model olmuştur. SARIMAX modeli de XGBoost gibi gerçek veriye en yakın tahminleri üreten bir diğer model olurken, ikinci başarılı model olmasının nedeni değişimleri XGBoost kadar iyi yakalayamamıştır. Holt-Winters modeli ne mevsimsel kırılımları ne de trendi öğrenemeyerek açık ara en kötü tahminleri yapmış ve bu veri seti için en başarısız model olmuştur.


340 filosu sonuçlarına bakıldığında ise gerçek veriye en yakın tahminleri yapan ve değişimleri en iyi yakalayan model Prophet modeli olmuştur. Holt-Winters ve SARIMAX ise Prophet modelinden sonra en başarılı tahminler üreten diğer alternatif modeller olmuştur. 777 filosu için de en yüksek performans gösteren model diğer geniş gövde filosunda olduğu gibi Prophet modeli olmuştur. LSTM modeli ise alternatif model olarak öne çıkan bir diğer modeldir.

Diğer Boeing modeli olan 738 filosu sonuçlarına da bakıldığında en başarılı modelin SARIMAX olduğu görülebilmektedir. 738 filosuna ait veri setinde kırılımlar daha dar aralıktır. Bu nedenle modeller genel olarak birbirlerine yakın tahminler üretmişlerdir. Çoğu model kırılımları başarılı bir şekilde yakalarken LSTM modeli daha düz bir tahminde bulunarak en başarısız model olmuştur.


F/O Sınıfı Simülör-Eğitim Model Sonuçları



Şekil 70. F/O sınıfı simülör eğitim MAE hata metriği



Şekil 71. F/O sınıfı simülör eğitim RMSE hata metriği



Şekil 72. F/O sınıfı simülatör eğitim MAPE hata metriği

First Officer sınıfı simülatör eğitim tahmin sonuçları Şekil 70, 71 ve 72’de gösterilmiştir. Airbus 340 filosu hata metrik sonuçlarına bakıldığında zaman tüm modellerin birbirine çok yakın performans gösterdiği görülmektedir. Tüm modeller veri setinde ki kırılımları iyi yakalayabilmiştir. Genel olarak bakıldığında ise LSTM modelini öne çıkaran özellik gerçeğe en yakın tahminler yapması ve kırılımları doğru şekilde yakalamış olmasıdır. Her ne kadar son dönemde ki ani yükseliş trendini tam olarak yakalayamamışlar da genel anlamda modellere en uyumlu veri seti olarak göze çarpmaktadır.

777 filosu sonuçlarına bakıldığında zaman tıpkı 340 filusunda olduğu gibi genel olarak hata metrikleri birbirine çok yakın değerler üretmiştir. Holt-Winters hariç diğer dört model de gerçek veriye çok yakın tahminler üretmiş ve mevsimsel kırılımları iyi şekilde yakalayabilmiştir. Prophet modelinin diğer modellerden bir adım öne çıkaran özelliği ise son dönemde yaşanan düşüşü diğer modellere göre daha başarılı öngörmüştür.

Diğer bir Boeing uçağı olan 738 filusunda ise en başarılı tahmini Holt-Winters yapmış olarak görülmektedir. Diğer modellere göre gerçeğe daha yakın tahminler yapmayı başarmış ve mevsimsel dalgalanmaları daha iyi öngörmüştür. Prophet ve SARIMAX modelleri diğer modellere göre dalgalanmaları yakalayamamış ve tahminler daha pozitif yönde olacak şekilde yapmışlardır.

Airbus A320 filusunda ise Holt-Winters ve LSTM modelleri birbirine çok yakın performans gösterirken diğer modellere göre açık ara daha düşük hata oranıyla tahminler yapmışlardır. HW modelini LSTM’den bir adım öne çıkaran en belirgin özellik ise

dalgalanmayı çok daha iyi yakalayabilmiş olmasıdır. Diğer modeller ise Holt-Winters ve LSTM'e göre daha olumlu tahminler yaparken, mevsimselliği başarılı bir şekilde yakalayamamıştır.



3. BULGULAR VE TARTIŞMA

Zaman serileri geçmiş verilerin mevsimsellik, trend ve durağanlık özelliklerini kullanarak gelecek için tahminde bulunmayı sağlayan bir alandır. Zaman serileri ile yapılan tahminler, geçmiş verilere dayanarak, bir zaman serisinin gelecekteki değerlerini tahmin etmek için istatistiksel bir model kullanma sürecidir. Zaman serisi analiz süreci, gelecekteki verileri tahmin edebilmek için bazı önemli modelleri kullanmaktadır.

Zaman serisi analizinde modelleme sürecinin en önemli aşamalarından biri uygun model seçimidir. Uygun modelin seçimi için birçok farklı yöntem vardır. Model tespiti yapılırken ilk olarak verinin durağanlığını kontrol etmek gerekmektedir. Çünkü zaman serisi analizinde kullanılan yöntemlerin çoğu zaman serisinin durağan olması durumunda başarılı olmaktadır. Zaman serisi verisinin durağan olup olmadığını anlayabilmek için otokorolasyon ve kısmi korelasyon katsayıları incelenir ve bu katsayıların istatistiksel olarak anlamlı olup olmadığına bakılır. Eğer bu katsayılar istatistiksel olarak anlamsız ise zaman serisi verisinin durağanlaştırılması gerekmektedir.

Veri setinde eksik değerler bulunmakta olup, özellikle pandemi döneminde (2020-2021) uluslararası kısıtlamalar nedeniyle uçuş operasyonlarındaki azalma ile oluşan sıra dışı durumlar tespit edilmiştir. Pandemi kaynaklı sıra dışı düşük değerler lineer interpolasyon yöntemi ile düzeltilmiştir. Eksik veri içeren aylar, ilgili değişkenin geçmiş ve gelecek değerleri dikkate alınarak tamamlanmıştır.

Mevsimsel desen belirgin şekilde gözlemlenmiştir. Özellikle yaz aylarında (Haziran, Temmuz, Ağustos) kokpit personeli ihtiyacı artmaktadır. Trend analizi, yıllar içinde toplam kokpit personeli ihtiyacında artış olduğunu göstermektedir. Pandemi dönemi (2020-2021) aykırı değer olarak belirlenmiştir.

Bu tez çalışmasında kapsamında model tahminlerinin yapılabilmesi için zaman serileri ve makine öğrenmesi yöntemlerinden farklı tahminleme yöntemleri olan 6 farklı yöntem karşılaştırılarak model tahminlerinin RMSE, MAE, MAPE metriklerine göre başarısı ölçülmüştür. Yöntemler temel olarak kişi sayısı, simülatör-eğitim, ofis ve yıllık izin olarak iki gruba ayrılarak ve kendi içlerinde karşılaştırılarak en iyi sonucu hangi grubun verdiğine karar verilecektir.

Karşılaştırma yapılan yöntemler şu şekildedir.

- SARIMAX
- Holt-Winters
- Prophet
- LSTM
- XGBoost
- Rastgele Orman

MAPE, RMSE, MAE hata metriği kullanılarak model performansının üç farklı açıdan değerlendirilmesi sağlanmıştır. MAPE, gerçek değerlere göre modelin tahmin hatasının yüzde cinsinden büyüklüğünü ölçmektedir. Bu hata metriği özellikle modelin yüzdesel hata açısından genel performansını değerlendirmek için kullanılmıştır. MAE ise tahmin edilen değerler ile gerçek değerler arasındaki farkın mutlak ortalamasını vermektedir. MAE'nin en önemli özelliklerinden birisi sapma büyüklüklerini daha doğru ölçmesidir. Tahmin edilen bazı kokpit sınıfı sonuçlarında MAPE değeri düşük olmasına rağmen MAE değerinin çok daha yüksek olduğu gözlemlenmiştir. Bu durum, yüzdesel hatanın düşük olmasına rağmen mutlak hata büyüklüğünün yüksek olduğunu göstermektedir.

Zaman serisi tahmin modellerinin performanslarına bakıldığında zaman hem MAPE hem MAE değeri düşük olup en başarılı olduğu sınıflar Boeing 777, Boeing 738 ve Airbus 340 filosunda görev yapan kaptan sınıflarına ait tahminler olmuştur. Hata değerleri %3 seviyelerinde çıkmış ve çok yüksek doğrulukla tahminler yapılmıştır. Bu sınıflardaki zaman serisi verilerinin daha düzenli ve öngörülebilir olduğu yapılan çalışmalar bölümünde elde edilen model tahmin sonuçlarından açıkça görülebilmektedir.

Airbus A320 ve Boeing 777 filosunun F/O sınıfı için yapılan tahminler de yaklaşık %5-6 MAPE değerleriyle en başarılı performans gösteren sınıflar olmuştur. Yüksek başarıyla performansı gösteren bu sınıflara ait verilerin yapısının iyi yakalanabildiği model sonuçlarından net bir şekilde anlaşılmaktadır.

Bir diğer düşük MAPE değerine sahip model ise yaklaşık %7-8 hata payıyla tahmin üreten Airbus 320 filosunda kaptan olarak görev yapan ekipler için geliştirilen modeller yüksek performans elde etmiştir. Bu filo için geliştirilen diğer modeller de genel olarak hata değerleri bakımından maksimum %13 olacak şekilde yüksek başarı ile tahmin etmişlerdir.

MAPE değerleri yaklaşık %10 olan diğer filo ve sınıflar ise Airbus 340 ve Boeing 738 filosunda görev yapan First Officer'ların modelleri başarılı olmuşlardır. Bu kokpit sınıflarına

ait verilerdeki mevsimsellik ve karmaşıklık geliştirilen modelleme yöntemleri ile kabul edilebilir sonuçlar elde edilmiştir.

%10 ve altında MAPE değerine sahip modellere bakıldığı zaman genel olarak kişi sayısı ile ilgili geliştirilen modeller olmuştur. Diğer değişkenler için geliştirilen modeller ise kişi sayısı değişkeni için geliştirilen modeller kadar yüksek doğrulukla tahminler yapamamıştır.

Tüm filolarda görev yapan kaptanların simülatör eğitimleri üzerine kurulan modeller genel olarak %10-15 bandında MAPE değerlerine göre tahminler yaparak başarılı modeller arasına girmişlerdir.

Boeing 738 ve Airbus A340 filosunda görev yapan kaptanların ofis değişkenleri için kurulan modeller de yaklaşık %15 civarında hata payıyla tahminler üreterek başarılı tahminler yapan modellerden bazıları olmuştur. 320 ve 777 filosunda görev yapan kaptanlar için yapılan tahminler 738 ve 340 filosunda ki modeller kadar başarılı olamamış olmasalar da yaklaşık %20 MAPE değeriyle tahminler yaparak kabul edilebilir modeller üreten arasına girmişlerdir.

738, 340 ve 320 filosunda görev yapan F/O'ların simülatör-eğitim tahminlerini yapmak için geliştirilmiş olan modeller ise %20-30 arasında hata değerleriyle orta derecede performans gösteren modeller olmuştur. 777 sınıfında görev yapan F/O modelleri ise diğer filolara göre daha yüksek hata ile tahminler yapmıştır.

Tüm filolar da görev yapan F/O'ların ofis tahminleri için geliştirilen modeller ise yaklaşık %30-40 arasında MAPE değerleriyle tahminler yapmışlardır. Orta düzey başarı performansı gösteren bu sınıflara ait verilerin yapısının kısmen yakalanabildiği, ancak verilerdeki bazı unsurların tahmin zorlukları oluşturduğunu göstermektedir.

Yıllık için geliştirilen modellerin, MAPE, MAE ve RMSE değerleri en yüksek olan modeller olmuştur. Hem kaptan hem F/O sınıflarına ait yapılan diğer değişken modellerine göre yaklaşık %50-70 aralığında MAPE değerlerine sahip olarak daha başarısız sonuçlar elde edilmiştir. Bu kokpit sınıflarına ait verilerdeki düzensizlik ve karmaşıklık basit modelleme yöntemlerinin yetersiz kaldığını göstermektedir. Analiz sonuçlarını, bu kategoriler için daha gelişmiş modelleme yöntemlerine ihtiyaç duyulduğunu ortaya koymaktadır.

Model türlerine göre performans farklılıklarına bakıldığı zaman, zaman serisi modellerinin daha başarılı sonuçlar ortaya koyduğu açıkça görülebilmektedir. SARIMAX ve Holt-Winters yöntemleri daha düzenli yapıya sahip kokpit sınıflarında çok daha başarılı

sonular vermiřtir. zellikle kaptan kiři sayısı, simlatr-eđitim iin elde edilen sonulara gre modelin hata oranlarının dřk olması dikkat ekmektedir. Bu modeller trend ve mevsimsellik unsurlarını bařarılı bir řekilde yakalamıř ve veride ki dzensizliđi ortadan kaldırmıřtır.

Makine đrenmesi modellerinin performansına bakıldıđı zaman, XGBoost ve LSTM gibi makine đrenmesi tabanlı modeller, zaman serisi modellerine gre zellikle kiři sayısı tahminleri iin ok daha fazla hata oranlarına sahiptir. Bu modeller trend ve mevsimsellik zelliđi tařıyan zaman serisi verilerini yakalamakta yetersiz kalmıř ve modelin bařarılı olmayan tahminler retmesine sebep olmuřtur.

Kokpit sınıf kategorilerinin analiz sonularına bakıldıđı zaman F/O sınıfı iin yapılan tahminlerin daha yksek hata oranlarına sahip olduđu gzkmektedir. Bu durumun F/O sınıflarının operasyonel olarak daha fazla belirsizlik yařadıklarını gstermektedir. zellikle dar gvde uaklar da grev yapan F/O sınıflarına operasyonel olarak daha fazla ihtiya duyulduđu, uuř sre/gn gibi iř yklerinin diđer filo ve sınıflara gre daha belirsiz ve fazla olduđu analiz sonularından aıka grlebilmektedir.

Genel olarak analiz sonularına bakıldıđı zaman, model performanslarının veri setlerine gre ok byk farklılıklar gstermediđi grlmřtir. Basit tahmin yntemlerinin ise zellikle dzensiz ve karmařık veri setlerinde yetersiz kaldıđı bazı deđiřkenler iin aıka grlmřtir. Zaman serisi verilerinin modellenmesinde dođru model seiminin ne kadar nemli olduđu aıka grlebilmektedir. Modellerin farklı MAPE sonuları, belirli veri setleri ve problem trleri iin farklı modelleme tekniklerinin daha uygun olabileceđini gstermektedir. Veri setinin zelliklerine bađlı olarak tahmin dođruluđunu artırmak iin dřk MAPE deđerlerine sahip modellerin tercih edilmesi gerekmektedir. SARIMAX ve Holt-Winters modelleri, genel olarak en dřk MAPE deđerleri ile en dođru tahminleri yapmıřtır ve zaman serisi analizleri iin en uygun modeller olarak ne ıkmaktadır. Prophet modelleri de zaman serisi analizinde yaygın olarak kullanılan yntemlerdir, ancak ARIMA ve Holt-Winters modellerine kıyasla biraz daha yksek hata oranlarına sahiptir. Diđer makine đrenimi algoritmaları ise tahmin dođruluđunda orta seviyede kalmıřtır. Tahmin dođruluđunu artırmak iin ARIMA, SARIMA gibi zaman serisi tahmin modellerinin seilmesi nerilmektedir.

Modelin performans farklılıklarının kaynaklarını analiz etmek, model optimizasyonuna ynelik nemli bilgiler sađlayabilir. Bazı kategorilerde, veri n iřleme ařamasında farklı veri normalizasyon teknikleri kullanılabilir ya da modelin belirli zellikler

iin daha duyarlı hale getirilmesi saėlanabilir. zellikle kaptan gruplarında daha iyi performans saėlamak iin alternatif zaman serisi modelleri denenebilir.

Ayrıca, verilerdeki trend ve mevsimsellik unsurlarının analiz edilerek, modelin bu unsurları daha iyi yakalaması saėlanabilir. Bu, doktora tezi kapsamında literatürde tartışılan farklı zaman serisi modelleme tekniklerinin karşılaştırmalı analizi iin de kullanılabilir.



4. SONUÇLAR VE ÖNERİLER

Günümüzde havacılık sektörünün büyümesi ve Pandeminin etkisini kaybetmesiyle birlikte hava yolu ulaşımına talep artmıştır. Bu artan uçuş talebinin sonucunda uçuş personeline olan ihtiyacın da arttığı görülmektedir.

Havayolu şirketleri uzun vadeli kokpit ekip ihtiyacı konusunda birçok çalışma yürütmektedir. Kokpit ekiplerinin istihdam edildikten sonra uçuşa başlamaları yaklaşık olarak 2 sene sürmektedir. Bu durum göz önünde bulundurulduğu zaman uzun vadeli ekip ihtiyacı hesaplamasının ne kadar önemi olduğu açıkça görülmektedir.

Uzun vadeli kokpit ekip ihtiyacının doğru hesaplanması Türk Hava Yolları'nın büyüme hedefleri doğrultusunda büyük rol oynamaktadır. Oluşturulacak olan karar destek sistemi ile birlikte, halihazırda dünyanın en çok ülkesine uçan havayolu olarak tarihe geçen Türk Hava Yolları, gelecek yıllara yönelik kokpit ekip ihtiyacını daha doğru hesaplayarak 2033 hedeflerine daha kolay ulaşacaktır.

Karar destek sisteminin oluşturulabilmesi için çeşitli modern ve klasik makine öğrenmesi yöntemlerinin model performansları değerlendirilmiştir. Model performanslarına ek olarak elde edilen modelin performansı günümüz verileri ile de test edilmiş ve model sonuçları ile 2024 yılı istihdam sayıları birbirine çok yakın çıkmıştır. Bu da elde edilen modelin iyi çalıştığını göstermiştir.

Modelin performans farklılıklarının kaynaklarını analiz etmek, model optimizasyonuna yönelik önemli bilgiler sağlayabilir. Bazı kategorilerde, veri ön işleme aşamasında farklı veri normalizasyon teknikleri kullanılabilir ya da modelin belirli özellikler için daha duyarlı hale getirilmesi sağlanabilir. Özellikle kaptan gruplarında daha iyi performans sağlamak için alternatif zaman serisi modelleri denenebilir.

Ayrıca, verilerdeki trend ve mevsimsellik unsurlarının analiz edilerek, modelin bu unsurları daha iyi yakalaması sağlanabilir. Bu, doktora tezi kapsamında literatürde tartışılan farklı zaman serisi modelleme tekniklerinin karşılaştırmalı analizi için de kullanılabilir.

Bu tez çalışmasının kapsamı genişletilerek 1505 Üniversite-Sanayi iş birliği proje olarak sunulmuş olup, TUBITAK tarafından 5240019 proje numarası 01 Ağustos 2024 tarihi itibarı ile kabul edilmiştir. Projedeki temel gelecek 36 ay için belirli başlıklar altında bir tahminleme yaparak, uzun vadeli uçuş ekibi tahminlemesi için bir karar destek sistemi oluşturulması hedeflenmektedir.

Tez kapsamında yapılmış olan kokpit ekip ihtiyacı tahminleme, proje kapsamında kabin ekip ihtiyacı tahminleme analizi ile devam edecek ve Türk Hava Yolları'nın uzun vadeli uçuş ekibi ihtiyacı hesaplamasında daha doğru sonuç elde etme hedefinin gerçekleştirilmesi planlanmaktadır. Planlanan uygulamanın geliştirilmesi ile milli bayrak taşıyıcı firmamız uçuşların arttığı dönemler de kalifiye ekip ihtiyacı yaşamayacaktır. Bu şekilde yapılacak olan çalışmanın uçuş personeli dışında kalan diğer personeller açısından uzun vadeli tahminleme çalışanlarına da fayda sağlayacak düzeye gelmesi planlanmaktadır.



5. KAYNAKLAR

- Acar, G. (2022). Zaman serisi yöntemleri ve XGBoost algoritması ile kömür satış tahmini: Türkiye Tarım Kredi Kooperatifleri uygulaması= Sales prediction using time series and XGBoost algorithm: Application of Agricultural Credit Cooperatives of Turkey (Master's thesis, Sakarya Üniversitesi).
- Akinyele S.T. (2007), Determination Of The Optimal Manpower Size Using Linear Programming Model- Research Journal Of Business Management 1 (1): 30-36, 2007 Issn 1819-1932
- Akusta, A. (2024). Konut Piyasası Trendlerinin Çözümlemesi: Türkiye'de Toplam Konut Satışlarının Tahmini. Necmettin Erbakan Üniversitesi Siyasal Bilgiler Fakültesi Dergisi, 6(1), 113-127.
- Akyurt İ.Z. Ve Yaşlıoğlu D.T (2018), Havacılık Sektöründe Ekip Planlama Yönetimi: Bir Türk Havayolu Örneği, İşletme Araştırmacıları Dergisi, 19/1 (2018) 424-446
- Atalay B. (2015), Kliniklerin Kapasite Yönetiminde ve İnsan Gücü Planlamasında Zamana Dayalı Faaliyet Tabanlı Maliyetleme- Journal Of Accounting, Finance And Auditing Studies 1/1 (2015) 40-61
- Altın Yavuz, A. (2021). İlerleyen Sansürlü Örneklemelere Dayalı Olarak Weibull Dağılımının Şekil Parametresinin Sağlam Tahmin Edicileri. Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü Dergisi, 25(2), 410-418.
- Ampountolas, A. (2021). Modeling and forecasting daily hotel demand: A comparison based on sarimax, neural networks, and garch models. Forecasting, 3(3), 580-595.
- Anderson, T. (1962). On the distribution of the two-sample Cramer-von Mises criterion. The Annals of Mathematical Statistics, 33(3), 1148-1159.
- Anderson, T., & Darling, D. (1952). Asymptotic theory of certain goodness of fit criteria based on stochastic processes. The Annals of Mathematical Statistics, 23(2), 193-212.
- Anderson, T., & Darling, D. (1954). A test of goodness of fit. Journal of the American Statistical Association, 49(268), 765-769.
- Angus, J. (1994). The probability integral transform and related results. SIAM review, 36(4), 652-654.
- Arizono, I., & Ohta, H. (1989). A test for normality based on Kullback—Leibler information. The American Statistician, 43(1), 20-22.
- Arshad, M., Rasool, M., & Ahmad, M. (2003). Anderson Darling and modified Anderson Darling tests for generalized Pareto distribution. Pakistan Journal of Applied Sciences, 3(2), 85-88.

- Arunraj, N. S., Ahrens, D., & Fernandes, M. (2016). Application of SARIMAX model to forecast daily sales in food retail industry. *International Journal of Operations Research and Information Systems (IJORIS)*, 7(2), 1-21.
- Aydemir, İ., & Yaşar, G. Y. (2016). Ergonomik tasarımın sağlık çalışanları ve hasta güvenliğine etkisi. *Sağlık ve Hemşirelik Yönetimi Dergisi*, 3(3), 174-184.
- Bal, M. D. (2014). Yataklı Tedavi Kurumlarında Hemşire İnsangücü Planlama Yaklaşımları. *Sağlık ve Hemşirelik Yönetimi Dergisi*, 3(1), 148-154.
- Bain, L., & Engelhardt, M. (1987). *Introduction to probability and mathematical statistics*. Brooks/Cole.
- Balakrishnan, N., & Nevzorov, V. (2004). *A primer on statistical distributions*. Hoboken, New Jersey: John Wiley & Sons Inc.
- Balakrishnan, N., Voinov, V., & Nikulin, M. (2013). *Chi-squared goodness of fit tests with applications*. United States of America: Elsevier.
- Baringhaus, L., & Henze, N. (1988). A consistent test for multivariate normality based on the empirical characteristic function. *Metrika*, 35(1), 339-348.
- Batsidis, A., Economou, P., & Bar-Lev, S. (2022). A Comparative Study of Goodness-of-Fit Tests for the Laplace Distribution. *Austrian Journal of Statistics*, 51(2), 91-123.
- Bayoud, H. (2021). Tests of normality: new test and comparative study. *Communications in Statistics-Simulation and Computation*, 78(1), 1-22.
- Bera, A., & Jarque, C. (1981). Efficient tests for normality, homoscedasticity and serial independence of regression residuals: Monte Carlo evidence. *Economics Letters*, 7(4), 313-318.
- Bilgin K.U. (2004), *Kamu Performans Yönetimi*, Todaie Yayınları, Ankara, 2004. Boston.
- Bonett, D., & Seier, E. (2002). A test of normality with high uniform power. *Computational Statistics & Data Analysis*, 40(3), 435-445.
- Bontemps, C., & Meddahi, N. (2005). Testing normality: a GMM approach. *Journal of Econometrics*, 124(1), 149-186.
- Breiman, L. (2001). Random forests. *Machine learning*, 45, 5-32.
- Brys, G., Hubert, M., & Struyf, A. (2008). Goodness-of-fit tests based on a robust measure of skewness. *Computational statistics*, 23(3), 429-442.
- Brys, G., Hubert, M., & Struyf, A. (2008). Goodness-of-fit tests based on a robust measure of skewness. *Computational Statistics*, 23(3), 429-442.
- Cabaña, A., & Cabaña, E. (2003). Tests of normality based on transformed empirical processes. *Methodology and Computing in Applied Probability*, 5(3), 309-335.

- Cankul, H. İ. & Erigüç, G. (2000), “Hemşirelik Faaliyetlerinin Türlerine Ve Zamana Göre İncelenmesi”, I. Ulusal Sağlık İdaresi Kongre Kitabı, Ankara.
- Chaichatschwal, R., & Budsaba, K. (2007). A power comparison of goodness-of-fit tests for normality based on the likelihood ratio and the non-likelihood ratio. *Thailand Statistician*, 5(2007), 57-68.
- Chen, L., & Shapiro, S. (1995). An alternative test for normality based on normalized spacings. *Journal of Statistical Computation and Simulation*, 53(3-4), 269-287.
- Chen, T., & Guestrin, C. (2016, August). Xgboost: A scalable tree boosting system. In *Proceedings of the 22nd acm sigkdd international conference on knowledge discovery and data mining* (pp. 785-794)
- Chirumamilla Shivanagaraju C., Mahanty B., Vizayakumar K. Ve Mohapatra P. K.J. (1998), Beta-Distributed Age In Manpower Planning Models-Applied Mathematical Modelling 22 (1998) 23±37
- Chu C.K., Zhu M., & Zhu L. (2010), Goal Programming Models And Dss For Manpower Planning Of Airport Baggage Service- Lecture Notes In Economics And Mathematical Systems, 2010, V.634, P. 189-199
- Cochran, W. (1952). The χ^2 test of goodness of fit. *The Annals of Mathematical Statistics*, 23(3), 315-345.
- Coin, D. (2008). A goodness-of-fit test for normality based on polynomial regression. *Computational Statistics & Data Analysis*, 52(4), 2185-2198.
- Connie Zheng C., & Hu M.C., (2008), Challenge To Ict Manpower Planning Under The Economic Restructuring: Empirical Evidence From Mncs In Singapore And Taiwan- *Technological Forecasting & Social Change* 75 (2008) 834–853
- Cox, D. (1961). Tests of separate families of hypotheses. J. Neyman (Dü.), *Proceedings of the fourth Berkeley symposium on mathematical statistics and probability*. içinde 1, s. 105-123. University of California Press.
- Cox, D. (1962). Further results on tests of separate families of hypotheses. *Journal of the Royal Statistical Society. Series B (Methodological)*, 24(2), 406-424.
- Cramér, H. (1928). On the composition of elementary errors. *Scandinavian Actuarial Journal*, 1928(1), 13-74. doi:10.1080/03461238.1928.10416862
- Crzregorzewski, P., & Wirzorkowski, R. (1999). Entropy-based goodness-of-fit test for exponentiality. *Communications in Statistics-Theory and Methods*, 28(5), 1183-1202.
- Cur, K., Gołda, P., Izdebski, M., Świergolik, S., & Radomyski, A. (2023). Development of aviation infrastructure in selected European countries: statistical analysis and implications. *Aviation and Security Issues*, 4(2), 107-137.

- Çetik, M.O. & Oğulata S.N. Hastane Hizmet Birimleri Arasında İş Akışının Ergonomik Di
 Francesco M., Llorente N.D.M., Zanda S. ve Zuddas P. (2016), An Optimization
 Model For The Short-Term Manpower Planning Problem
- D'Agostino, R., & Stephens, M. (1986). Goodness-of-Fit Techniques. Marcel Dekker Inc.,
 New York.
- D'Agostino, R. B. (1971). An omnibus test of normality for moderate and large size samples.
 Biometrika, 58(2), 341-348.
- D'agostino, R., & Pearson, E. (1973). Tests for departure from normality. Empirical results
 for the distributions of b^2 and $\sqrt{b}$. Biometrika, 60(3), 613-622.
- Dekking, F., Kraaikamp, C., Lopuhaä, H., & Meester, L. (2005). A Modern Introduction to
 Probability and Statistics: Understanding why and how (Cilt 488). Delft,
 Netherlands: Springer.
- Del Barrio, E., Cuesta-Albertos, J. A., Matrán, C., & Rodríguez-Rodríguez, J. M. (1999).
 Tests of goodness of fit based on the L2-Wasserstein distance. Annals of Statistics,
 27(4), 1230-1239.
- Di Francesco, M., Llorente, N. D. M., Zanda, S., & Zuddas, P. (2016). An optimization
 model for the short-term manpower planning problem in transshipment container
 terminals. Computers & Industrial Engineering, 97, 183-190.
- Dickey, D. A., & Fuller, W. A. (1979). Distribution of the estimators for autoregressive time
 series with a unit root. Journal of the American statistical association, 74(366a),
 427-431.
- Dimitriou V.A. Ve Tsantas N. (2010), Evolution Of A Time Dependent Markov Model For
 Training And Recruitment Decisions In Manpower Planning- Linear Algebra And Its
 Applications 433 (2010) 1950–1972
- Dodge, Y. (2006). The Oxford dictionary of statistical terms. New York: Oxford University
 Press. Doğan, A. (2007). Afet Acil Müdahale Dönemleri İçin İnsangücü Planlaması
 Yapmak. Dokuz Eylül Üniversitesi (Turkey).
- Domanski, C., & Szczepocki, P. (2020). Comparison of selected tests for univariate
 normality based on measures of moments. Statistics in Transition New Series, 21(5),
 151-179.
- Dong, L., & Giles, D. (2007). An empirical likelihood ratio test for normality.
 Communications in Statistics—Simulation and Computation, 36(1), 197-215.
- Doornik, J., & Hansen, H. (2008). An omnibus test for univariate and multivariate normality.
 Oxford Bulletin of Economics and Statistics, 70(1), 927-939.
- Du G., & Zhang J. (2022), Cross-Regional Manpower Scheduling And Routing Problem
 With Stochastic Service Times In Home Health Care- Computers & Industrial
 Engineering 173 (2022) 108668

- Dudewicz, E. J., van der Meulen, E. C., SriRam, M. G., & Teoh, N. K. (1995). Entropybased random number evaluation. *American Journal of Mathematical and Management Sciences*, 15(1-2), 115-153.
- Duman, E. (2022). Price Forecasting with Machine Learning: An Application in Stainless Steel Industry (Master's thesis, Marmara Universitesi (Turkey)).
- Epps, T. (2005). Tests for location-scale families based on the empirical characteristic function. *Metrika*, 62(1), 99-114.
- Epps, T., & Pulley, L. (1983). A test for normality based on the empirical characteristic function. *Biometrika*, 70(3), 723-726.
- Epps, T., Singleton, K., & Pulley, L. (1982). A test of separate families of distributions based on the empirical moment generating function. *Biometrika*, 69(2), 391-399.
- Erdem, B. (2004). Otel İşletmelerinde İnsan Kaynakları Planlamasının Yeri ve Önemi. *Balıkesir Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 7(11), 35-54.
- Ersan, E., & Mersin, S. (2023). Kaynakça Nasıl Yazılır. *Fen Bilimleri Tez Dergisi*, 12(5), s. 123-135.
- Esteban, M. D., Marhuenda, Y., Morales, D., & Sanchez, A. (2007). New goodness-of-fit tests based on sample quantiles. *Communications in Statistics—Simulation and Computation*, 36(3), 631-642.
- Esteban, M., Castellanos, M., Morales, D., & Vajda, I. (2001). Monte Carlo comparison of four normality tests using different entropy estimates. *Communications in StatisticsSimulation and Computation*, 30(4), 761-785.
- Evren, A., & Tuna, E. (2012). On some properties of goodness of fit measures based on statistical entropy. *International Journal of Research and Reviews in Applied Sciences*, 13(1), 192-205.
- Fan, J. (1996). Test of significance based on wavelet thresholding and Neyman's truncation. *Journal of the American Statistical Association*, 91(434), 674-688.
- Fan, Y. (1997). Goodness-of-fit tests for a multivariate distribution by the empirical characteristic function. *Journal of Multivariate Analysis*, 62(1), 36-63.
- Fan, Y. (1998). Goodness-of-fit tests based on kernel density estimators with fixed smoothing parameters. *Econometric Theory*, 14(5), 604-621.
- Fazla, A. (2024). Time and context sensitive optimization of machine learning models for sequential data prediction (Doctoral dissertation, bilkent university).
- Filliben, J. (1975). The probability plot correlation coefficient test for normality. *Technometrics*, 17(1), 111-117.

- Fisher, Cynthia D. (1999). Human Resource Management. Houghton Mifflin Co.: Holm A. (2008), Manpower Planning In Airlines- Modeling And Optimization- Linkopings Universitesi- 2008. <https://Pp.Bme.Hu/Tr/Article/View/7099> Adresinden Erişildi.
- Forbes, C., Evans, M., Hastings, N., & Peacock, B. (2011). Statistical distributions (Fourth Edition b.). Hoboken, New Jersey: John Wiley & Sons Inc.
- Fortiana, J., & Grané, A. (2003). Goodness-of-fit tests based on maximum correlations and their orthogonal decompositions. *Journal of the Royal Statistical Society: Series B (Statistical Methodology)*, 65(1), 115-126.
- Freeman, M., & Tukey, J. (1950). Transformations related to the angular and the square root. *The Annals of Mathematical Statistics*, 21(4), 607-611.
- Frosini, B. V. (1987). On the distribution and power of a goodness-of-fit statistic with parametric and nonparametric applications. P. Revesz, K. Sarkadi, & P. K. Sen (Dü) içinde, *Goodness-of-fit* (s. 133-154). Amsterdam: North Holland Publishing Company.
- Gel, Y., & Gastwirth, J. (2008). A robust modification of the Jarque-Bera test of normality. *Economics Letters*, 99(1), 30-32.
- Glen, A., Leemis, L., & Barr, D. (2001). Order statistics in goodness-of-fit testing. *IEEE Transactions on Reliability*, 50(2), 209-213.
- Gokhale, D. (1983). On entropy-based goodness-of-fit tests. *Computational Statistics & Data Analysis*, 1, 157-165.
- Grané, A. (2012). Exact goodness-of-fit tests for censored data. *Annals of the Institute of Statistical Mathematics*, 64(6), 1187-1203.
- Hegazy, Y., & Green, J. (1975). Some New Goodness-Of-Fit Tests Using Order Statistics. *Journal of the Royal Statistical Society: Series C (Applied Statistics)*, 24(3), 299-308.
- Heyde, C. (1975). A supplement to the strong law of large numbers. *Journal of Applied Probability*, 12(1), 173-175.
- Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. *Neural computation*, 9(8), 1735-1780.
- Hosking, J. (1990). L-moments: Analysis and estimation of distributions using linear combinations of order statistics. *Journal of the Royal Statistical Society: Series B (Methodological)*, 52(1), 105-124.
- Hubbard, R., & Lindsay, R. (2008). Why P values are not a useful measure of evidence in statistical significance testing. *Theory & Psychology*, 18(1), 69-88.
- Jaffry S. Ve Capon N. (2005). Alternative Methods Of Forecasting Risks In Naval Manpower Planning -International Journal Of Forecasting 21 73- 85

- Jarque, C., & Bera, A. (1980). Efficient tests for normality, homoscedasticity and serial independence of regression residuals. *Economics letters*, 6(3), 255-259.
- Johnson, N. L., Kotz, S., & Balakrishnan, N. (2019). *Genesis*. N. Balakrishnan, & A. P. Basu (Dü) içinde, *Exponential Distribution: Theory, Methods and Applications* (s. 1-4). New York: Taylor & Francis Group.
- Johnson, N., Kotz, S., & Balakrishnan, N. (1995). *Continuous univariate distributions, volume 2* (Second Edition b., Cilt 289). Hoboken, New Jersey: John Wiley & Sons Inc.
- Karcıoğlu, A. A., Tanışman, S., & Bulut, H. (2021). Türkiye'de COVID-19 Bulaşısının ARIMA Modeli ve LSTM Ağı Kullanılarak Zaman Serisi Tahmini. *Avrupa Bilim ve Teknoloji Dergisi*, (32), 288-297.
- Kaya A. & Dalgıç A.İ., (2022), Evaluating Workload And Manpower Planning Among Pediatric Emergency Department Nurses İn Turkey During Covid-19: A Cross-Sectional, Multicenter Study- *Journal Of Pediatric Nursing* 65 (2022) 69–74
- Kendall, K. (1975). Thin-film peeling-the elastic term. *Journal of Physics D: Applied Physics*, 8(13), 1449.
- Khinchin, A. I. (1957). *Mathematical foundations of information theory*. (R. A. Silverman, & M. D. Friedman, Çev.) New York: Dover Publication Inc.
- Kıran, B., & Taşkıran, E. G. (2015). Türkiye'de Hemşirelik Eğitimi ve İnsan Gücü Planlamasına Bakış. *Mersin Üniversitesi Tıp Fakültesi Lokman Hekim Tıp Tarihi ve Folklorik Tıp Dergisi*, 5(2), 62-68.
- Kobayashi, H., Mark, B., & Turin, W. (2012). *Probability, random processes, and statistical analysis*. New York, USA: Cambridge University Press.
- Kolmogorov, A. (1933). *Grundbegriffe der Wahrscheinlichkeitsrechnung*. Berlin: Julius Springer.
- Köse E., Genç T. & Kabak M. (2015), Markov Analizi İle İnsan Gücü Planlaması, C.Ü. İktisadi ve İdari Bilimler Dergisi, Cilt 16, Sayı 2, 2015
- Kryshkevych K. (2013). A Flexible Approach To Effective And Efficient Manpower Planning For Ukraine International Airlines At Main Station Boryspil International Airport. *Transportation Engineering* 41/1 (2013) 21–24 Doi: 10.3311/Pptr.7099.
- Kuiper, N. (1960). Tests concerning random points on a circle. *Proceedings of the Koninklijke Nederlandse Akademie van Wetenschappen: Series A*, 63, s. 38-47.
- Kullback, S., & Leibler, R. (1951). On information and sufficiency. *The Annals of Mathematical Statistics*, 22(1), 79-86.
- Laio, F. (2004). Cramer-von Mises and Anderson-Darling goodness of fit tests for extreme value distributions with unknown parameters. *Water Resources Research*, 40(9).

- Lagodimos A.G. & Leopoulos V. (2000), Greedy Heuristic Algorithms For Manpower Shift Planning- Int. J. Production Economics 68 (2000) 95-106
- Ledwina, T. (1994). Data-driven version of Neyman's smooth test of fit. *Journal of the American Statistical Association*, 89(427), 1000-1005.
- Lilliefors, H. (1967). On the Kolmogorov-Smirnov test for normality with mean and variance unknown. *Journal of the American Statistical Association*, 62(318), 399-402.
- Mann, H. B. (1945). Nonparametric tests against trend. *Econometrica: Journal of the econometric society*, 245-259.
- Manigandan, P., Alam, M. S., Alharthi, M., Khan, U., Alagirisamy, K., Pachiyappan, D., & Rehman, A. (2021). Forecasting natural gas production and consumption in United States-evidence from SARIMA and SARIMAX models. *Energies*, 14(19), 6021.
- Mardia, K. V. (1972). *Statistics of Directional Data*. London, England: Academic Press.
- Marques de Sá, J. (2007). *Applied statistics using SPSS, statistica, Matlab and R*. USA: Springer Company.
- Massey Jr, F. J. (1951). The Kolmogorov-Smirnov test for goodness of fit. *Journal of the American Statistical Association*, 46(253), 68-78.
- Matsui, M., & Takemura, A. (2005). Empirical characteristic function approach to goodness-of-fit tests for the Cauchy distribution with parameters estimated by MLE or EISE. *Annals of the Institute of Statistical Mathematics*, 57(1), 183-199.
- McHugh, C., Coleman, S., Kerr, D., & McGlynn, D. (2019, December). Forecasting day-ahead electricity prices with a SARIMAX model. In *2019 IEEE symposium series on computational intelligence (SSCI)* (pp. 1523-1529). IEEE.
- Mendes, M., & Pala, A. (2003). Type I error rate and power of three normality tests. *Pakistan Journal of Information and Technology*, 2(2), 135-139.
- Mulla, S., Pande, C. B., & Singh, S. K. (2024). Times series forecasting of monthly rainfall using seasonal auto regressive integrated moving average with EXogenous variables (SARIMAX) model. *Water Resources Management*, 38(6), 1825-1846.
- Mutingi M. Ve Mbohwa C. (2012), *Dynamic Capacity Augmentation Strategies For Health Manpower Supply Under Various Demand Patterns- C1e42 Proceedings*, 16-18 July 2012, Cape Town, South Africa © 2012 C1e & Sane
- Nakas, C. (2007). Performance of the One-Sample Goodness-of-Fit P-P-Plot Length Test. *Communications in Statistics—Simulation and Computation*, 36(5), 1053-1059.
- Nebati, E. E., Taş, M., & Ertaş, G. (2021). Türkiye’de elektrik tüketiminde talep tahmini: zaman serisi ve regresyon analizi ile karşılaştırma. *Avrupa Bilim ve Teknoloji Dergisi*, (31), 348-357.

- Neyman, J. (1949). Contribution to the theory of χ^2 test. J. Neyman (Dü.), Proceedings of the First Berkeley Symposium on Mathematical Statistics and Probability içinde (s. 239-273). University of California Press.
- Nguyen, Q. H. (2024). Modeling the volatility of international air freight: A case study of Singapore using the SARIMAX-EGARCH model. *Journal of Air Transport Management*, 117, 102593.
- Noughabi, H., & Arghami, N. (2011). Monte Carlo comparison of seven normality tests. *Journal of Statistical Computation and Simulation*, 81(8), 965-972.
- Oktama, P. D. W. (2021). Short-Term Forecasting of Air Travellers Outflows from Bali Using Web Search Data. In *Proceedings of The International Conference on Data Science and Official Statistics* (Vol. 2021, No. 1, pp. 448-457).
- Onyper, S., Thacher, P., Gilbert, J., & Gradess, S. (2012). Class start times, sleep, and academic performance in college: A path analysis. *Chronobiology International*, 29(3), 318-335.
- Owen, A. (2001). *Empirical likelihood* (1 b.). New York: Chapman and Hall/CRC.
- Özkan, Ş., & Uydacı, M. (2020). Kamu Hastanelerinde İş Yüküne Dayalı Hemşire İşgücü Gereksiniminin Belirlenmesi. *Sağlık Ve Hemşirelik Yönetimi Dergisi*, 7(3), 339351.
- Park, S. (1999). A goodness-of-fit test for normality based on the sample entropy of order statistics. *Statistics & probability letters*, 44(4), 359-363.
- Pearson, K. (1900). X. On the criterion that a given system of deviations from the probable in the case of a correlated system of variables is such that it can be reasonably supposed to have arisen from random sampling. *The London, Edinburgh, and Dublin Philosophical Magazine and Journal of Science*, 50(302), 157-175.
- Pettitt, A. (1977). Testing the normality of several independent samples using the AndersonDarling statistic. *Journal of the Royal Statistical Society: Series C (Applied Statistics)*, 26(2), 156-161.
- Photun, A., & Thaminkaew, T. (2023, August). Forecasting Air Passengers in Phuket, Thailand: An Application of Machine Learning Algorithms. In *2023 4th International Conference on Big Data Analytics and Practices (IBDAP)* (pp. 1-6). IEEE.
- Rahman, M., & Govindarajulu, Z. (1997). A modification of the test of Shapiro and Wilk for normality. *Journal of Applied Statistics*, 24(2), 219-236.
- Ramachandran, K., & Tsokos, C. (2015). *Mathematical Statistics with Applications in R* (Second Edition b.). Academic Press.
- Ramachandran, K., & Tsokos, C. (2021). *Mathematical statistics with applications in R* (Third Edition b.). Academic Press.

- Razali, N., & Yap, B. W. (2011). Power comparisons of shapiro-wilk, kolmogorov-smirnov, lilliefors and anderson-darling tests. *Journal of Statistical Modeling and Analytics*, 2(1), 21-33.
- Reschenhofer, E., & Bomze, I. (1991). Length tests for goodness of fit. *Biometrika*, 78(1), 207-216.
- Romao, X., Delgado, R., & Costa, A. (2010). An empirical power comparison of univariate goodness-of-fit tests for normality. *Journal of Statistical Computation and Simulation*, 80(5), 545-591.
- Rosenblatt, M. (1956). A central limit theorem and a strong mixing condition. *Proceedings of the National Academy of Sciences*, 42(1), 43-47.
- Rosin, P., & Rammler, E. (1933). Laws governing the fineness of a powdered coal. *Journal of Institute of Fuel*, 7, 29-36.
- Sabuncuoğlu, Z. (2008). İnsan Kaynakları Yönetimi Uygulamalı, (3. Baskı). Bursa. Alfa Aktüel Basın Yayın Dağıtım Ltd. Şti.
- Saksena, R. S. (1980). *A Handbook of Statistics (Cilt 1)*. (P. R. Krishnaiah, Dü.) Motilal Banarsidass Publishe.
- Seier, E. (2002). Comparison of tests for univariate normality. *InterStat Statistical Journal*, 1(2002), 1-17.
- Sen, P. K. (1968). Estimates of the regression coefficient based on Kendall's tau. *Journal of the American statistical association*, 63(324), 1379-1389.
- Shabbir, H., & Chaturvedi, A. (2022, March). Day ahead hybrid forecasting of global horizontal irradiance using machine learning (rastgele Orman algorithm) and timeseries model (SARIMAX). In *2022 International conference on emerging smart computing and informatics (ESCI)* (pp. 1-6). IEEE.
- Shadkam, A. (2020). Using SARIMAX to forecast electricity demand and consumption in university buildings (Doctoral dissertation, University of British Columbia).
- Shah, V., Patel, N., Shah, D., Swain, D., Mohanty, M., Acharya, B., ... & Kanavos, A. (2024). Forecasting Maximum Temperature Trends with SARIMAX: A Case Study from Ahmedabad, India. *Sustainability*, 16(16), 7183.
- Shan, G., Vexler, A., Wilding, G., & Hutson, A. (2010). Simple and exact empirical likelihood ratio tests for normality based on moment relations. *Communications in Statistics—Simulation and Computation*, 40(1), 129-146.
- Shannon, C. (1948). A mathematical theory of communication. *The Bell System Technical Journal*, 27(3), 379-423.
- Shapiro, S. S., & Francia, R. S. (1972). An approximate analysis of variance test for normality. *Journal of the American Statistical Association*, 67(337), 215-216.

- Shapiro, S. S., & Wilk, M. B. (1965). An analysis of variance test for normality (complete samples). *Biometrika*, 52(3/4), 591-611.
- Shapiro, S., Wilk, M., & Chen, H. (1968). A comparative study of various tests for normality. *Journal of the American Statistical Association*, 63(324), 1343-1372.
- S.H.G.M. (2018). Uçuş ve Görev Süresi Sınırlamalar ile dinlenme gereklilikleri talimatı. Rev02. Ankara: Sivil Havacılık Genel Müdürlüğü.
- Siraj-Ud-Doulah, M. (2019). A Comparison among Twenty-Seven Normality Tests. *Research & Reviews: Journal of Statistics*, 8(3), 41-59.
- Smirnov, N. (1939). Estimate of deviation between empirical distribution functions in two independent samples. *Bulletin Moscow University*, 2(2), 3-16.
- Song, K.-S. (2002). Goodness-of-fit tests based on Kullback-Leibler discrimination information. *IEEE Transactions on Information Theory*, 48(5), 1103-1117.
- Spearman C.E, 1904. The proof and measurement of association between two things. *American Journal of Psychology* 15: 72–101.
- Stephens, M. (1974). EDF statistics for goodness of fit and some comparisons. *Journal of the American Statistical Association*, 69(347), 730-737.
- Student. (1908). The probable error of a mean. *Biometrika*, (6), 1-25. doi:<https://doi.org/10.2307/2331554>
- Sumantri S., Muchtarom, Hndriawan E., Rinaldi F. Ve Firman (2023), Education Strategic Planning: Manpower Planning Approach Study-Edumaspul Jurnal Pendidikan Vol. 7 – No. 1, Year (2023), Page 325-330
- Sullivan, G., & Feinn, R. (2012). Using effect size-or why the P value is not enough. *Journal of Graduate Medical Education*, 4(3), 279-282.
- Şantaş, F., Özer, Ö. & Çıraklı, Ü. (2012). Türk Kalkınma Planlarında Sağlık İnsan Gücü Planlaması. *Çankırı Karatekin Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*. Cilt: 2, Sayı: 2, 45-59.
- Tang Q., Wilson G.R. & Perevalov E. (2008), An Approximation Manpower Planning Model For After-Sales Field Service Support-Computers & Operations Research 35 (2008) 3479 – 3488
- Tekina, A. T., & Sarıb, C. Mağaza Tabanlı Talep Tahmini: Topluluk Öğrenmes Yaklaşımları ile Zaman Serisi Yaklaşımı Karşılaştırılması., *International Engineering and Technology Management Summit 2022– ETMS2022*
- Thalen B. (2010), Manpower Planning For Airline Pilots — A Tabu Search Approach Linköpings Universitesi – 2010


- Tolikas, K., & Heravi, S. (2008). The Anderson-Darling goodness-of-fit test statistic for the three-parameter lognormal distribution. *Communications in Statistics—Theory and Methods*, 37(19), 3135-3143.
- Torabi, H., Montazeri, N., & Grané, A. (2016). A test for normality based on the empirical distribution function. *Statistics and Operations Research Transactions*, 40(1), 55-88.
- Towhidi, M., & Salmanpour, M. (2007). A new goodness-of-fit test based on the empirical characteristic function. *Communications in Statistics—Theory and Methods*, 36(15), 2777-2785.
- Uçkun, C. G., & Yüksel, A. (2007). Aile Şirketlerinin Performansının Arttırılmasında Bir Strateji: Dış Kaynaklardan Yararlanma (Outsourcing). *Karamanoğlu Mehmetbey Üniversitesi Sosyal ve Ekonomik Araştırmalar Dergisi*, 2007(3), 25-39.
- Uhm, T., & Yi, S. (2021). A comparison of normality testing methods by empirical power and distribution of P-values. *Communications in Statistics-Simulation and Computation*, 1-14.
- Uyanto, S. (2022). An Extensive Comparisons of 50 Univariate Goodness-of-fit Tests for Normality. *Austrian Journal of Statistics*, 51(3), 45-97.
- Ünsalan, E. Şimşeker B. (2010). Meslek Yüksek Okulları İçin Metep'e Göre Hazırlanmış İnsan Kaynakları Yönetimi, (3.Baskı). Ankara. Detay Yayıncılık.
- Van Zyl, J. (2018). The performance of univariate goodness-of-fit tests for normality based on the empirical characteristic function in large samples. *Communications in Statistics-Simulation and Computation*, 47(4), 1146-1156.
- Vasicek, O. (1976). A test for normality based on sample entropy. *Journal of the Royal Statistical Society. Series B (Methodological)*, 38(1), 54-59.
- Verhoeven, B., Van Hout, N., Devaraj, A., Zwitzer, H., Crapts, T., Ion, A., ... & Dugundji, E. (2021). Short-term forecasting of air cargo demand from a European airport hub to the United States during covid-19 (No. TRBAM-21-00166).
- Von Plato, J. (2005). AN Kolmogorov, *Grundbegriffe der wahrscheinlichkeitsrechnung* (1933). I. G. Guinness (Dü.) içinde, *Landmark Writings in Western Mathematics 1640-1940* (s. 960-969). Elsevier.
- Vundavalli S. (2014), Dental Manpower Planning In India: Current Scenario And Future Projections For The Year 2020- *International Dental Journal* 2014; 64: 62–67
- Wang, J. (2012). Sample distribution function based goodness-of-fit test for complex surveys. *Computational Statistics & Data Analysis*, 56(3), 664-679.
- Watson, G. (1961). Goodness-of-fit tests on a circle. *Biometrika*, 48(1/2), 109-114.
- Watson, G. (1962). Goodness-of-fit tests on a circle. II. *Biometrika*, 49(1/2), 57-63.

- Weibull, W. (1939). A statistical theory of the strength of material. *Ingeniors Vetenskapa Acadamiens Handligar*, 151, 5-45.
- Weibull, W. (1951). A statistical distribution function of wide applicability. *Journal of Applied Mechanics*, 18, 192-297.
- Wen X., Chung S.H., Ji P. Ve Sheu J.B. (2022), Individual Scheduling Approach For MultiClass Airline Cabin Crew With Manpower Requirement Heterogeneity- *Transportation Research Part E* 163 (2022) 102763
- Wicaksono H., & Ni T. (2020), An Automated Information System For Medium To ShortTerm Manpower Capacity Planning In Make-To-Order Manufacturing- *Procedia Manufacturing* 52 (2020) 319–324
- Wijekularathna, D., Manage, A., & Scariano, S. (2019). Power analysis of several normality tests: A Monte Carlo simulation study. *Communications in Statistics-Simulation and Computation*, 51(3), 757-773.
- Wilks, S. S. (1935). The likelihood test of independence in contingency tables. *The Annals of Mathematical Statistics*, 6(4), 190-196.
- Ya S., Yang T.H., & Chen H.H. (2004). Airline Short-Term Maintenance Manpower Supply Planning- *Transportation Research Part A* 38 (2004) 615–642)
- Yan S., Chen C.H., & Chen C.H. (2006), Long-Term Manpower Supply Planning For Air Cargo Terminals- *Journal Of Air Transport Management* 12 (2006) 175–181
- Yang T. H., Yan S. Ve Chen H.H. (2003). An Airline Maintenance Manpower Planning Model With Flexible Strategies- *Journal Of Air Transport Management* 9 (2003) 233–239
- Yap, B., & Sim, C. (2011). Comparisons of various types of normality tests. *Journal of Statistical Computation and Simulation*, 81(12), 2141-2155.
- Yazici, B., & Yolacan, S. (2007). A comparison of various tests of normality. *Journal of Statistical Computation and Simulation*, 77(2), 175-183.
- Yıldırım, D. (2002). Hemşire İnsan Gücü Planlaması. *Hemşirelik Dergisi*, 12 (48), 57-70.
- Yıldırım, D. & Yılmaz, S. (2004). Bir Ameliyathanede Günlük Çalışılması Gereken Hemşire Sayısının Belirlenmesi. *Hemşirelikte Araştırma Geliştirme Dergisi*,
- Yıldırım, N., & Gökpınar, F. (2012). Bazı Normallik Testlerinin 1. Tip Hataları ve Güçleri Bakımından Kıyaslanması. *Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 16(1), 109-115.
- Yılmaz, Ö. H. (2012). İşyeri Hekimliğinde İnsan Gücü Planlaması İçin İş Analizi ve Simülasyon Yaklaşımı. *Çukurova Üniversitesi Fen Bilimleri Enstitüsü, Endüstri Mühendisliği Ana Bilim Dalı*.


- Yu M., Ding Y., Lindsey R ve Shi C. (2016). A Data-Driven Approach To Manpower Planning At U.S.–Canada Border Crossings. *Transportation Research Part A* 91 (2016) 34–47.
- Yumuşak, S., Ve Kışlalıoğlu, R. S. (2013). İşletmeler Üzerinde İnsan Kaynakları Planlamasının Yeri ve Önemi Üzerine Bir Alan Uygulaması. *Dumlupınar Üniversitesi Sosyal Bilimler Dergisi*, (36).
- Yüksel, B. (2023). Zaman serilerinde talep tahmini (Demand prediction in time series). *YBS Ansiklopedi*, 11(2), 1-18.
- Zghoul, A. (2010). A goodness of fit test for normality based on the empirical moment generating function. *Communications in Statistics-Simulation and Computation*, 39(6), 1292-1304.
- Zhang, J. (2002). Powerful goodness-of-fit tests based on the likelihood ratio. *Journal of the Royal Statistical Society: Series B (Statistical Methodology)*, 64(2), 281-294.
- Zhang, J., & Wu, Y. (2005). Likelihood-ratio tests for normality. *Computational Statistics & Data Analysis*, 49(3), 709-721.
- Zhang, P. (1999). Omnibus test of normality using the Q statistic. *Journal of Applied Statistics*, 26(4), 519-528.
- Zeinawaqi, Z., & Dzikrullah, A. A. (2024). Factors Affecting The Number Of Domestic Flights In Indonesia During Covid-19 Pandemic Using SARIMAX Method. *Jurnal Matematika, Statistika dan Komputasi*, 21(1), 1-9.

6. EKLER


Ek 1.




Ek 2. Kaptan Kişi Sayısı Model Sonuçları




Ek 3. Kaptan Kişi Sayısı MAPE Sonuçları




Ek 4. Kaptan Sınıfı Simülatör-Eğitim Model Sonuçları




Ek 5. Kaptan Sınıfı Simülatör-Eğitim MAPE Sonuçları





Ek 6. F/O Sınıfı Simülör-Eğitim Model Sonuçları




Ek 7. F/O Sınıfı Simülatör-Eğitim MAPE Sonuçları


Ek 8. Kaptan Sınıfı Ofis Model Sonuçları




Ek 9. Kaptan Sınıfı Ofis MAPE Sonuçları


Ek 10. F/O Sınıfı Ofis Model Sonuçları




Ek 11. F/O Sınıfı Ofis MAPE Sonuçları


Ek 12. Kaptan Sınıfı Yıllık İzin Model Sonuçları



Ek 13. Kaptan Sınıfı Yıllık İzin MAPE Sonuçları

Ek 14. F/O Sınıfı Yıllık İzin Model Sonuçları



Ek 15. F/O Sınıfı Yıllık İzin MAPE Sonuçları

ÖZGEÇMİŞ

Kaan TOPRAK, ilk ve orta öğrenimini Ziya Gökalp İlköğretim Okulu'nda bitirdikten sonra lise eğitimini Erzincan Milli Piyango Anadolu Lisesi'nde tamamladı. 2010 yılında girdiği KTÜ, Fen Fakültesi, İstatistik ve Bilgisayar Bilimleri Bölümü'nden 2015 lisans, 2018'de yüksek lisans programından mezun oldu. 2018 yılında KTÜ, Fen Fakültesi, İstatistik ve Bilgisayar Bilimleri Bölümü'nde Doktora eğitimi alırken aynı yıl Türk Hava Yolları Ekip Planlama Başkanlığı Sistem ve Program Geliştirme Müdürlüğünde uzman olarak işe başlamıştır. Evli ve bir kızı olan Kaan TOPRAK iyi derecede İngilizce bilmektedir.