

İSTANBUL TEKNİK ÜNİVERSİTESİ ★ LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

**ZAMANINDA PERFORMANSI ARTIRMAK İÇİN MAKİNE ÖĞRENME
YAKLAŞIMI İLE BLOK SÜRE TAHMİNİ**

YÜKSEK LİSANS TEZİ

Seda SOYKAN

Bilgisayar Bilimleri Anabilim Dalı

Bilgisayar Bilimleri Programı

ŞUBAT 2024

İSTANBUL TEKNİK ÜNİVERSİTESİ ★ LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

**ZAMANINDA PERFORMANSI ARTIRMAK İÇİN MAKİNE ÖĞRENME
YAKLAŞIMI İLE BLOK SÜRE TAHMİNİ**

YÜKSEK LİSANS TEZİ

Seda SOYKAN

Bilgisayar Bilimleri Anabilim Dalı

Bilgisayar Bilimleri Programı

Tez Danışmanı: Dr. Öğr. Üyesi Sefer BADAY

ŞUBAT 2024

**ENHANCING ON-TIME PERFORMANCE THROUGH MACHINE LEARNING
APPROACH FOR PREDICTING BLOCK TIME**



M.Sc. THESIS

Seda SOYKAN

Department of Computer Science

Computer Science Program

Thesis Advisor: Assistant Professor Sefer BADAY

FEBRUARY 2024

İTÜ, Lisansüstü Eğitim Enstitüsü'nün 704201005 numaralı Yüksek Lisans Öğrencisi Seda SOYKAN, ilgili yönetmeliklerin belirlediği gerekli tüm şartları yerine getirdikten sonra hazırladığı “ZAMANINDA PERFORMANSI ARTIRMAK İÇİN MAKİNE ÖĞRENME YAKLAŞIMI İLE BLOK SÜRE TAHMİNİ” başlıklı tezini aşağıda imzaları olan jüri önünde başarı ile sunmuştur.

Tez Danışmanı : **Dr. Öğr. Üyesi Sefer BADAY**
İstanbul Teknik Üniversitesi

Jüri Üyeleri : **Doç. Dr. Ömer Faruk BEYCA**
İstanbul Teknik Üniversitesi

Dr. Öğr. Üyesi Nurullah ÇALIK
İstanbul Medeniyet Üniversitesi

Teslim Tarihi : 05 Ocak 2024
Savunma Tarihi : 05 Şubat 2024





Aileme,



ÖNSÖZ

Bu çalışmada destekleriyle bana yol gösteren, bilgi ve tecrübeleri ile katkılarını hiçbir zaman esirgemeyen değerli danışmanım Dr. Öğr. Üyesi Sefer BADAY'a teşekkürlerimi sunarım.

Tüm eğitim hayatım boyunca benden maddi ve manevi desteklerini esirgemeyen, tüm zorluklarda her zaman yanımda olan anneme, babama, kardeşlerime ve her zaman sevgisini ve desteğini hissettiğim sevgili dedeme de teşekkürlerimi bir borç bilirim. Bu zorlu yüksek lisans ve tez sürecinde her aşamada destek olan sevgili arkadaşım Eşma'ya da ayrıca teşekkür ederim.

Ocak 2024

Seda Soykan
Matematik Mühendisi



İÇİNDEKİLER

Sayfa

ÖNSÖZ	vii
İÇİNDEKİLER	ix
KISALTMALAR	xi
SEMBOLLER	xii
ÇİZELGE LİSTESİ	xiii
ŞEKİL LİSTESİ	xv
ÖZET	xvii
SUMMARY	xix
1. GİRİŞ	1
1.1. Havacılıkta Zamanında Performansın Önemi	1
1.2. Blok Süre, Uçuş Süresi ve Taksi Süreleri Terim Açıklamaları.....	2
1.3. Blok Süre Tahminlemesinin Endüstriye Sağlayacağı Kazanımlar.....	3
1.4. Amaç Ve Kapsam.....	4
2. LİTERATÜR ARAŞTIRMASI	7
3. DATASET	15
3.1. Veri Setleri	15
3.1.1. Zamanında performans verileri	15
3.1.2. Hava durumu verileri	16
3.1.3. Eğitim, validasyon ve test kümesi ayrışımı	17
3.2. Veri Analizi	18
3.2.1. Tanımlayıcı analiz	18
3.2.2. Boş değer analizi	18
3.2.3. Uç değer analizi	18
3.2.4. Nümerik değer analizi	19
3.2.5. Kategorik değer analizi	21
3.3. Özellik Mühendisliği	22
3.3.1. Veri tipi dönüşümleri	22
3.3.2. Özellik üretme	23
4. METODOLOJİ	25
4.1. Özellik Seçme Yaklaşımları	25
4.1.1. Pearson korelasyonu yöntemi	25
4.1.2. Isı haritası yöntemi	26
4.1.3. Karar ağaçları algoritması	26
4.1.4. En küçük kareler algoritması	26
4.2. Modelleme Adımında Tercih Edilen Algoritmalar	27
4.2.1. Lineer regresyon	28
4.2.2. Lasso regresyon.....	28
4.2.3. Ridge regresyon	28
4.2.4. Elastik net regresyon	29
4.2.5. Bagging regresyon	29

4.2.6. Random forest regresyon	29
4.2.7. XG Boost regresyon	30
4.3. Performans Değerlendirme Adımında Kullanılan Metrikler	30
4.3.1. Ortalama mutlak hata	30
4.3.2. Ortalama hata kareleri	31
4.3.3. Ortalama mutlak yüzde hata	31
4.3.4. Karekök ortalama hata kare	32
4.3.5. R kare	32
4.4. Hiperparametre Optimizasyonu	32
4.4.1. Grid search algoritması	33
4.4.2. Çarpaz doğrulama	34
5. BULGULAR VE TARTIŞMA	37
5.1. Özellik Seçme Yaklaşımları	39
5.2. Modeller	41
5.2.1. Blok süre tahmini	41
Ham model	41
Optimize model	42
5.2.2. Taksi kalkış süresi tahmini	43
Ham model	43
Optimize model	44
5.2.3. Taksi varış süresi tahmini	45
Ham model	46
Optimize model	46
5.2.4. Uçuş süresi tahmini	47
Ham model	48
Optimize model	48
5.3. Model Sonuçları Karşılaştırma	49
6. SONUÇ VE GELECEK ÇALIŞMALAR	55
6.1. Sonuçlar	55
6.2. Gelecek Çalışmalar	59
KAYNAKLAR	61
ÖZGEÇMİŞ	65

KISALTMALAR

BT	: Block Time
BTS	: Bureau of Transportation Statistics
JFK	: John F. Kennedy International Airport
KNN	: K-Nearest Neighbors
LAX	: Los Angeles International Airport
LSTM	: Long Short-Term Memory
MAE	: Mean Absolute Error
MAPE	: Mean Absolute Percentage Error
MSE	: Mean Squared Error
OTP	: On Time Performance
R2	: R-squared
RF	: Random Forest Algorithm
SFO	: San Francisco International Airport
SVM	: Support Vector Machines
RMSE	: Root Mean Squared Error
SMOTE	: Synthetic Minority Over-sampling Technique
US	: United States
XGB	: Extreme Gradient Boosting Algorithm



ÇİZELGE LİSTESİ

Sayfa

Çizelge 5.1 : Blok süre için ham model sonuçları gösterilmektedir.Blok süre için ham model sonuçları gösterilmektedir.	41
Çizelge 5.2 : Grid search sonrası blok süre için en iyi model ve parametreler gösterilmektedir.	42
Çizelge 5.3 : Blok süre için optimizasyon sonrası model sonuçları gösterilmektedir.	42
Çizelge 5.4 : Blok süre için test seti model sonuçları gösterilmektedir.	43
Çizelge 5.5 : Taksi kalkış süresi için ham model sonuçları gösterilmektedir.	44
Çizelge 5.6 : Grid search sonrası taksi kalkış için en iyi model ve parametreler gösterilmektedir.	44
Çizelge 5.7 : Taksi kalkış süresi için optimizasyon sonrası model sonuçları gösterilmektedir.	45
Çizelge 5.8 : Taksi kalkış süresi için ham model sonuçları gösterilmektedir.	45
Çizelge 5.9 : Taksi varış süresi için ham model sonuçları gösterilmektedir.	46
Çizelge 5.10 : Grid search sonrası taksi varış için en iyi model ve parametreler gösterilmektedir.	46
Çizelge 5.11 : Taksi varış süresi için optimizasyon sonrası model sonuçları gösterilmektedir.	47
Çizelge 5.12 : Taksi varış süresi için ham model sonuçları gösterilmektedir.	47
Çizelge 5.13 : Uçuş süresi için ham model sonuçları gösterilmektedir.	48
Çizelge 5.14 : Grid search sonrası uçuş süresi için en iyi model ve parametreler gösterilmektedir.	48
Çizelge 5.15 : Uçuş süresi için optimizasyon sonrası model sonuçları gösterilmektedir.	49
Çizelge 5.16 : Uçuş süresi için test seti model sonuçları gösterilmektedir.	49
Çizelge 6.1 : Model sonuçlarının karşılaştırması gösterilmektedir.	50
Çizelge 6.2 : Alt kategorilerin sonuçlarının karşılaştırması gösterilmektedir.	52



ŞEKİL LİSTESİ

Sayfa

Şekil 1.1 : Havacılıkta performansa dair terimler görsel olarak ifade edilmiştir.....	2
Şekil 3.1 : Hava durumuna ait veriler gösterilmektedir.....	16
Şekil 3.2 : Eğitim, validasyon ve test kümelerinin ayrımı gösterilmektedir.	17
Şekil 3.3 : Boş değere sahip kolonlar gösterilmektedir.	18
Şekil 3.4 : Uçuş menzil uzaklığı uç değer analizi gösterilmektedir.	19
Şekil 3.5 : Uçuş menzil uzaklığı uç değer analizi gösterilmektedir.	19
Şekil 3.6 : Planlanan ve gerçekleşen blok süreleri dağılımı gösterilmektedir.....	20
Şekil 3.7 : Taksi kalkış ve taksi varış süreleri dağılımı gösterilmektedir.....	20
Şekil 3.8 : Boş değere sahip kolonlar gösterilmektedir.	21
Şekil 3.9 : Haftanın günleri dağılımı gösterilmektedir.	21
Şekil 3.10 : Aylara göre dağılım gösterilmektedir.....	22
Şekil 4.1 : ML algoritmalarında takip edilen adımlar gösterilmektedir.	27
Şekil 4.2 : Hiperparametre optimizasyonu adımları gösterilmektedir.....	33
Şekil 5.1 : Taksi varış için pearson korelasyonu sonuçları gösterilmektedir.	39
Şekil 5.2 : Tüm değişkenler için ısı haritası sonuçları gösterilmektedir.....	40
Şekil 5.3 : Taksi kalkış için karar ağacı önem derecesi sonuçları gösterilmektedir. .	40
Şekil 6.1: Model karşılaştırmalarının sonuçları gösterilmektedir.....	57



ZAMANINDA PERFORMANSI ARTIRMAK İÇİN MAKİNE ÖĞRENME YAKLAŞIMI İLE BLOK SÜRE TAHMİNİ

ÖZET

Havacılık sektörü günümüzde hızla büyüyen ve gelişen bir endüstri olup, operasyonel verimlilik ve zaman yönetimi bu endüstri için büyük önem taşımaktadır. Özellikle on-time performansı, havayolu şirketleri ve havaalanları için oldukça önemli bir başarı metriği haline gelmiştir. Müşteri memnuniyeti, operasyonel verimlilik, maliyet etkinliği ve rekabet avantajı gibi birçok faktörü etkileyerek havacılık sektöründeki tüm paydaşlar için kritik bir yere sahiptir. Bu bağlamda, bu çalışma havacılıkta on-time performansın artırılması amacıyla blok süre tahmini üzerine odaklanmaktadır. Bu analiz, havayolu operasyonlarının zamanlama ve süreçlerin daha etkin bir şekilde yönetilmesine katkı sağlayarak hem havayolu şirketleri hem de havaalanları için önemli bir değer yaratmayı amaçlamaktadır.

Amerika Birleşik Devletleri Ulaştırma Bakanlığı tarafından sağlanan Ulaştırma İstatistikleri Bürosu (BTS) veri tabanı ve Azure platformu üzerinden elde edilen hava durumu verileri birleştirilerek, modelleme aşamasında kullanılmak üzere nihai bir veri seti oluşturulmuştur. Veri seti üzerinde gerekli filtrelemeler ve analizler gerçekleştirilmiş, veri ön işleme adımı eksik değerler ile uç değerlerin analizi ve veri doldurma gereksinimleri ele alınmıştır. Çalışma kapsamında iptal edilen veya yönlendirilen uçuşlar göz ardı edilmiş ve sadece varışı gerçekleşen uçuşlara odaklanılmıştır. Yayınlanan raporlar ve veri analizleri sonucunda, on-time performansında en fazla sapmaya sahip olan Florida eyaletinde gerçekleşen uçuşlar seçilmiştir. Bu filtrelemeyle birlikte, planlanan blok süre ile gerçekleşen blok süre arasında 20 dakikadan fazla fark olan uçuşlar da filtrelemeye dahil edilmiştir. Bu şekilde, çalışmada en problemli kitle seçilerek daha anlamlı ve katma değeri yüksek bir sonuç elde etmek amaçlanmıştır. Veri seti, 2021 Ocak ayından 2023 Haziran ayına kadar olan dönemi kapsamaktadır. Bu süre zarfında, 2021-2023 arası eğitim veri seti, 2023'ün ilk üç ayı validasyon veri seti ve son üç ay ise test veri seti olacak şekilde üçe ayrılmıştır.

Veri seti üzerinde yapılan analizlerde, blok süreleri, uçuş süreleri ve taksi süreleri için özellik seçimi adımı pearson korelasyonu ve ısı haritası analizleri gerçekleştirildi. Bunun yanı sıra en küçük kareler ve karar ağacı algoritmaları ile ön modeller oluşturularak, en önemli değişkenlerin belirlenmesi ve bu değişkenlerin modeli açıklama başarısı incelendi. Modelleme aşamasında, sürekli bir hedef değişkenin tahmin edilmesi gerektiği için denetimli makine öğrenmesi yöntemlerinden regresyon modelleri tercih edildi. Bu kapsamda Lineer Regresyon, Lasso, Ridge, Elastic Net, Random Forest, Bagging ve XG Boost regresyon modelleri kullanıldı. Tüm modeller için kullanılan regresyon tekniklerinde, ilk aşamada modellere varsayılan parametreler uygulandı. Daha sonra elde edilen sonuçlar, grid search ve çapraz doğrulama yöntemleri ile eğitilerek tekrar çalıştırıldı. Çapraz doğrulama sürecinde 5-katlı doğrulama modele uygulandı. Modellerin optimize edilmesi için uygulanan grid

search yöntemi için değerlendirme metriği olarak ortalama mutlak hata metriği seçildi, böylece sapmaların ne kadar olduğu daha iyi analiz edilebildi. Elde edilen sonuçlar sayesinde en iyi modellerin belirlenmesi ve en iyi parametrelerin keşfi sağlanmıştır. En iyi parametrelerle tercih edilen en iyi model, validasyon setinde tekrar eğitilmiş ve ardından model sisteme kaydedilmiştir. Daha sonra kaydedilen bu model, test veri seti üzerinde çalıştırılmıştır.

Optimize edilmiş model sonuçları ile test veri seti üzerinde çalıştırılan sonuçlar karşılaştırılmıştır. Ayrıca, modelin aşırı uyum ve aşırı basitleştirme problemleri incelenerek modelin genelleme yeteneği araştırılmıştır.

Performans değerlendirme metrikleri olarak ortalama mutlak hata, ortalama hata kareleri, kök ortalama mutlak hata karesi, R kare ve ortalama mutlak hata yüzdesi kullanılmıştır.

Modelleme adımının son aşamasında, bütünsel blok süre tahmini, parçalı blok süre toplamı tahmini, geçmişe dönük gerçekleşen bütünsel blok süre medyanı, taksi süreleri ve uçuş süresinden elde edilen medyan değerlerinin toplamından oluşan parçalı blok süre medyanı ve ilgili uçuş için daha önce planlanan blok süre sonuçları karşılaştırılmıştır.

Çalışma sonuçlarına göre, bütünsel olarak ele alınan blok süre tahmini, alt bileşenlerinin tahmin toplamını ifade eden taksi süreleri tahmini ve uçuş süresi tahmini toplamıyla karşılaştırıldığında, ilk yaklaşımın daha iyi sonuç verdiği görülmektedir. Blok süre tahmini modeli, 0.95 açıklanan varyans ve 6.15 mutlak ortalama hatayla rakiplerini geride bırakmıştır. Ayrıca, alt bileşenlerin tahminlerinin toplamı için R Kare değeri 0.93 ve MAE ise 7.18 olarak gözlemlenmiştir.

Geçmişe yönelik olarak, blok süre medyanı ile alt bileşenlerinin ortalamalarının toplamını ifade eden uçuş süresi medyan değeri ve taksi kalkış ve varış medyan değerlerinin toplamıyla karşılaştırıldığında, geçmişe yönelik bütünsel blok süre ortalamasının daha iyi sonuç verdiği görülmektedir. Ancak, bu medyan kıyaslamaları, makine öğrenimi yöntemleriyle tahmin gerçekleştirilen model ile karşılaştırıldığında 0.70 değerlerine düşerek önemli miktarda performans düşüklüğü göstermiştir.

Sonuç olarak, bütünsel blok süre tahmini, 0.95 açıklanan varyans ve 6.15 MAE değeri ile en iyi performansı gösteren model olmuştur. Bu model, hem alt kategorilerin ayrı ayrı tahminlerinin toplamı modelinden hem de geçmişe dönük gerçekleşen blok süre medyan değerinden ve alt bileşenlerin medyan toplamalarının karşılaştırmasından daha iyi bir performans sergilemiştir.

Bu çalışmanın sonuçları, havacılık sektöründe zamanında performansın artırılması ve operasyonel verimliliğin optimize edilmesi için blok süre tahmininin kritik bir öneme sahip olduğunu göstermektedir. Ayrıca, kullanılan veri kaynakları ve modelleme teknikleri, havacılık endüstrisinde verimliliği artırmak ve operasyonel süreçleri optimize etmek için potansiyel birer araç olarak öne çıkmaktadır. Bu çalışma, havacılık sektöründeki paydaşlara, on time performansın artırılması için veri odaklı ve analitik bir yaklaşımın önemini vurgulamakta ve gelecekte yapılacak çalışmalar için bir temel oluşturmaktadır.

ENHANCING ON-TIME PERFORMANCE THROUGH MACHINE LEARNING APPROACH FOR PREDICTING BLOCK TIME

SUMMARY

The aviation sector is a rapidly expanding and developing industry that holds significant importance in operational efficiency and time management. Particularly, on-time performance has emerged as a crucial success measure for airlines and airports. It significantly affects various factors such as customer satisfaction, operational efficiency, competitive advantage, and cost-effectiveness, holding vital importance for all stakeholders in the aviation sector. In this context, this study concentrates on block time estimation to enhance on-time performance in aviation.

Block time represents the duration from the aircraft's initial movement for takeoff until it completes its landing and comes to a stop. In other words, it signifies the time between the aircraft's departure from the runway and its arrival with engines shut down on the runway.

Additionally, block time is expressed as the total of taxi out time, flight time, and taxi in time for departure. Flight time is the period during which the aircraft is in the air between takeoff and landing. Taxi in time is the period during which an aircraft travels on the runway after landing until it arrives at the parking area. Taxi out time refers to the period during which an aircraft moves on the runway from the moment it starts its movement on the apron until it takes off.

Block time estimation is crucial in the aviation industry for flight planning, operational efficiency, customer satisfaction, and cost management. High-accuracy block time predictions can result in gains such as increased operational efficiency, improved passenger satisfaction, cost reduction, and traffic management.

In the conducted study, OTP data from the United States Department of Transportation's BTS database was combined with weather data obtained through the Azure platform to create a comprehensive dataset. The focus was specifically on evaluating flight operations in Florida due to observed underperformance in punctuality compared to industry competitors. Flights with a block time deviation exceeding 20 minutes between scheduled and actual times were filtered out to concentrate on a dataset with potential for enhancing on-time performance.

The analysis covered the period from January 2021 to June 2023, with data from January 2021 to January 2023 used as the training set, the first three months of 2023 for validation, and the last three months for testing.

During the data preprocessing phase, thorough analyses of missing, empty, and outlier values were conducted, followed by necessary actions. Data distributions and relationships were examined using various methods and graphical representations.

For feature engineering, data transformations were performed to convert relevant fields into numerical, categorical, and date formats. Categorical variables were

included in the model using the one-hot encoding method. Some fields were merged to increase significance in the model, and historical averages were incorporated into the model using grouping techniques to enhance interpretability.

Machine learning techniques were utilized to predict block time holistically and its subcategories: taxi out time, flight time, and taxi in time. Regression models were exclusively employed due to all target variables having continuous values. The regression models included Linear Regression, Lasso Regression, Ridge Regression, Elastic Net Regression, Bagging Regression, Random Forest Regression, and XG Boost Regression.

After running all models with default parameters, hyperparameter optimization was applied using the grid search algorithm to define parameter ranges for each model and determine the best model and parameters. Additionally, a 5-fold cross-validation method was applied to prevent potential issues such as overfitting or underfitting.

Model performance was evaluated using metrics such as Mean Absolute Error (MAE), Mean Squared Error (MSE), Mean Absolute Percentage Error (MAPE), Root Mean Squared Error (RMSE), and R-squared score.

During the modeling phase, the outcomes of models predicting block time, taxi out time, taxi in time, and flight duration were presented. Model results before and after hyperparameter optimization using grid search and cross-validation were compared on the validation set. Subsequently, the optimized models underwent evaluation on the test dataset.

Alongside the machine learning-based regression models, the assessment stage also involved evaluating the results of historical median values for all target variables. This encompassed comparing the cumulative prediction of block time, which includes predictions for taxi departure time, taxi arrival time, and flight duration, with the historical median block time and the combined median values of its components.

When assessing the discrepancy between planned and actual block times, it was found that there is a substantial deviation. While the R-squared value remains at 0.48, the average absolute error shows a considerably high deviation of 36.65. This situation explains the poor on-time performance of carriers due to inaccuracies in the planning phase.

The main goal of this study is to prevent delays by accurately predicting future block times and to improve on-time performance indicators, known as OTP, in the industry. The study aims to use machine learning methods to predict block times more accurately and reliably in advance, thus contributing to on-time performance.

Upon reviewing the study results, it was evident that the comprehensive block time prediction, when compared to the sum of predicted taxi durations and flight duration, yielded better results. The block time prediction model outperformed competitors with an explained variance of 0.95 and a mean absolute error of 6.15. The total of component predictions resulted in an observed R-squared of 0.93 and an MAE of 7.18.

Similarly, comparing historical median block time and flight time with the combined medians of taxi departure and arrival times, the holistic block time exhibited superior performance. However, when contrasted with machine learning methods, both median comparisons experienced a significant drop to 0.70.

In evaluating model results, individual comparisons for taxi out time prediction and median, taxi in time prediction and median, and flight duration prediction and median

were carried out. Each sub-component prediction model produced closer results to the actual values and performed better across all metrics. Notably, significant differences were observed in predictions related to taxi durations. For taxi out, the prediction and median values saw a decrease in R-squared from 0.81 to 0.16 and an increase in MAE from 4.44 to 13.73. Similarly, for taxi in, the prediction and median values witnessed a decrease in R-squared from 0.82 to 0.11, and an increase in MAE from 2.87 to 8.40.

The model for comprehensive block time prediction, with an explained variance of 0.95 and an MAE value of 6.15, has excelled in performance. This model surpassed not only the combined predictions of individual sub-categories but also the historical median value of block times and the aggregated historical medians of sub-components.

The inclusion of weather and seasonal data along with other features and data science methods has proven to be more effective in explaining the target variable in the prediction model. These results highlight that machine learning prediction models can make much closer estimates to actual values.

The findings of this study emphasize the critical importance of block time prediction for improving on-time performance and optimizing operational efficiency in the aviation sector. Furthermore, the utilized data sources and modeling techniques are seen as potential assets for enhancing efficiency and streamlining operational processes within the aviation industry. This study underscores the significance of a data-driven and analytical approach for enhancing on-time performance and provides a groundwork for future research.



1. GİRİŞ

Bu bölümde zamanında performansın havacılık endüstrisindeki önemi incelenecektir. Sonrasında çalışma dahilinde makine öğrenmesi yöntemleri ile tahmin edilecek hedef değişkenlere ait terim açıklamaları sunulacaktır. Blok süre tahmininin endüstriye sağlayacağı kazanımlar ifade edilerek çalışmanın amaç ve kapsamı hakkında bilgilendirme yapılarak bölüm sonlandırılacaktır.

1.1. Havacılıkta Zamanında Performansın Önemi

Havacılık sektörü hızla büyüyen ve gelişen dinamiklere sahip bir endüstridir. Zaman yönetimi ve operasyonel verimlilik ise havacılık endüstrisi için kritik bir öneme sahiptir. Zamanında performansa uyum sağlayabilmek ise hava yolu şirketleri için en önemli başarı kriterlerinden bir tanesidir. Havayolu şirketleri zamanında performansın önemini bilmekle birlikte zamanında performans açısından sahip oldukları sıralamayı pazarlama enstrümanı olarak kullanmaktadırlar.[1]

Bu metriğe başarılı bir şekilde uyum sağlayabilmek aşağıda belirtilen kalemlerde hava yolları şirketlerine katkı sağlamaktadır.

- Operasyonel verimlilik
- Müşteri Memnuniyeti
- Maliyet Kalemlerin Azaltılması
- Rekabet Avantajı
- Marka İmajı

Hava yolları zamanında kalkış ve varış zaman sürelerine uyum sağlayamadığında operasyonel olarak bazı riskler meydana gelmektedir. Gerekli durumlarda tekrar uçuş planlaması, ekip planlaması ve envanter planlaması gerekmektedir. Gecikme yaşanması durumunda hava meydanlarına yapılması gereken ek ödemeler ve cezalar en önemli maliyet kalemlerinden bir tanesidir. Gecikme yaşanabilecek durumların önceden tahmin edilmesi ile ekonomik kayıplar önemli ölçüde azaltılabilir.[2]

Bunun yanı sıra bağlantılı yolcuların diğer uçuşlarını kaçırması sonucu kurumlar tazminat, vize, konaklama vb. maliyet kalemlerini de karşılamak durumundadır. Bu

durum müşteri memnuniyeti açısından oldukça olumsuz olmasının yanı sıra marka imajını da ciddi şekilde etkilemektedir. Tüm bu aksaklıklar sonucunda hava yolları rekabet avantajını kaybetme riskleri ile karşı karşıya kalmaktadır. Blok sürelerin zamanında gerçekleşmesi müşteri memnuniyeti ve sadakati açısından önemli bir katkı sağlamanın yanı sıra havaalanı, havayolu ve hava trafik yönetimi açısından da önemli bir etki alanı oluşturur. [3]

1.2. Blok Süre, Uçuş Süresi ve Taksi Süreleri Terim Açıklamaları

Çalışma dahilinde makine öğrenmesi teknikleri ile tahmin edilecek hedef değişkenlere ait terimlerin açıklamaları aşağıda ifade edilmiştir.


Blok süre: Uçağın kalkış için harekete başladığı ilk andan, iniş yapıp hareketinin tamamlayıp uçağın durduğu son ana kadar geçen süreyi ifade eder. Bir başka deyişle uçağın pistten kalkması ve varış anında pistte motor kapatması arasındaki süreyi gösterir.

Uçuş süresi: Uçağın kalkış ve iniş arasında havada kaldığı zamanı ifade eder.

Taksi Varış Süresi: Pistte iniş yapan uçağın park yerine gidene kadar pistte geçirdiği süreyi ifade eder.

Taksi Kalkış Süresi: Park halindeki uçağın uçuş için pistte harekete başladığı ilk andan kalkış anına kadar pistte geçen süreyi ifade eder.

Şekil 1.1’de yukarıda bahsedilen terimlerin görsel olarak ifade edilmesi gösterilmektedir.



Şekil 1.1 : Havacılıkta performansa dair terimler görsel olarak ifade edilmiştir.

Blok süre; giden taksi, uçuş süresi ve giden taksi sürelerinin birleşiminden meydana gelmektedir.

Uçuş programlarında planlanmış blok süre belirlenir. Bu süre planlanan varış ve planlanan kalkış süresi arasındaki farkı ifade eder. Uçuşun meydana gelmesi ile birlikte gerçekleşen blok süre olarak ifade edilecektir. Taksi süreleri ve uçuş süresi sürecinden oluşan bu toplam süre aynı zamanda kalkış kapısından hedef kapıya geçene kadar geçen süre olarak da ifade edilmektedir.[4]

Bu çalışma kapsamında blok süre bütünsel olarak ve alt bileşenlerinin toplamı olarak ayrı ayrı makine öğrenmesi yöntemlerinden regresyon modelleri ile tahmin edilecektir.

Ayrıca geçmişe yönelik gerçekleşen değer ortalamaları için yine aynı yaklaşım gözetilecektir.

1.3. Blok Süre Tahminlemesinin Endüstriye Sağlayacağı Kazanımlar

Blok sürenin tahmin edilmesi, havacılık sektöründe operasyonel verimliliği artırmak ve doğru planlama yapmak için önemlidir. Bu çalışmanın sonucunun, havayolu şirketleri için, özellikle program planlama aşamasında, zamanında performansta olası aksaklıkları öngörmelerine ve bu aksaklıkları azaltacak eylemleri önceden planlamalarına olanak sağlaması beklenmektedir. Tüm paydaşlar için uçuş gecikmelerin önceden tahmin edilmesi karar verme sürecinde kritik bir öneme sahiptir.

Uçuş sürelerinin tahmini zorlu bir stokastik süreçtir. Fazla tahmin edilmesi uçak ve mürettebat gibi kaynak israfına yol açarken, az tahmin edilmesi gecikmelere yol açabilir.[5]

Blok süre tahmininin katma değer sağlayacağı bazı önemli noktalar aşağıda belirtilmiştir;

Uçuş Planlaması: Uçuş planlaması aşamasında blok süre tahminleri kullanılır. Zamanında kalkış ve varış planlamalarında ve operasyonel kararlarda kullanılır.

Yolcu ve Bagaj Planlaması: Bağlantılı uçuşlar, bagaj ve diğer operasyonların planlanması aşamasında blok süre tahmini kullanılır.

Operasyonel Verimlilik: Uçuş rotaları, bakım süreleri ve ekip planlamaları blok süre tahminlerine göre daha optimal şekilde planlanabilir.

Meydanların Kapasite Yönetimi: Havaalanı operatörleri meydan trafiğini uçak iniş ve kalkışlarını planlayarak yönetir.

Maliyetlerin Düşürülmesi: Blok süre tahminlerinde meydana gelen sapmalar yakıt tüketimi, meydanlara ödenen cezalar, bağlantılı yolculara tazminat ödemeleri ve personel giderleri kalemlerinde ek giderlere sebebiyet vermektedir.

Sonuç olarak, blok süre tahmini, uçuş operasyonlarının etkin bir şekilde planlanması, maliyetlerin yönetilmesi ve müşteri memnuniyetinin sağlanması açısından önemli bir yere sahiptir. Bu nedenle, havayolu şirketleri doğru ve güvenilir blok süre tahminleriyle operasyonlarını başarıyla yönetebilirler.

1.4. Amaç Ve Kapsam

Bu çalışma kapsamında havacılıkta on time performans hedeflerine ulaşmada önemli bir adım ve ihtiyaç olan blok sürelerin önceden tahmin edilerek bu hedefe katkı sağlaması amaçlanmaktadır. Uçuş programları aylar öncesinden ve güncel operasyonel koşullar hakkında bilgi sahibi olmadan planlanır. [6]

Bu belirsizlikleri en aza indirmek için makine öğrenmesi yaklaşımı blok sürelerin önceden tahmin edilmesi hedeflenmiştir.

Bu çalışmanın verileri, Amerika Birleşik Devletleri Ulaştırma Bakanlığı tarafından sağlanan Ulaştırma İstatistikleri Bürosu (BTS) veri tabanından alınmıştır.[35] Ayrıca, bölgesel kırımda ve taşıyıcı firma bazında performans istatistikleri de incelenmiştir. Yayınlanan raporların incelenmesi ve veri analizi değerlendirmeleri sonucunda performans açısından rakiplerinin gerisinde kaldığı tespit edilen Florida eyaletindeki uçuşlara odaklanılmıştır. Ayrıca, endüstri standardı olarak kabul edilen 15 dakikalık gecikme eşiğinin üzerinde gecikmeye sahip uçuşlar çalışmaya dahil edilmiştir. Bu sayede, performans açısından en problemli kitle seçilerek ve modelin literatüre katma değerini artırmak amaçlanmıştır.

Blok süreler üzerindeki etkisini gözlemleyebilmek adına hava durumu dataları da çalışmaya dahil edilmiştir. Bu veriler Azure DevOps platformu üzerinden web servisleri aracılığıyla temin edilmiştir.[36] Hava durumu verileri, ortalama, minimum ve maksimum hava sıcaklıkları, yağış durumu, kar yağışı ve kar kalınlığı gibi özellikleri içermektedir.

Çalışma kapsamında Lineer regresyon, Lasso, Ridge, Elastic Net, Bagging Regresyon, Random Forest ve XGB gibi farklı modeller kullanılmış ve en iyi hiperparametrelerin tespiti için Gridsearch algoritması uygulanmıştır.

Ek olarak çarpraz doğrulama tekniği kullanılarak modelin performansı farklı alt kümeler üzerinde değerlendirilerek modelin genelleme performansı incelenmiştir.

Modeller Ortalama Mutlak Hata (MAE), Ortalama Mutlak Yüzde Hata (MAPE), Kök Ortalama Kare Hata (RMSE), R-kare ve Ortalama Kare Hatası (MSE) gibi standart metriklerin titiz bir şekilde değerlendirilmesinden geçmiştir.

Çalışma kapsamında blok süre bütünsel olarak tahmin edilmiştir. Blok süresi tahmin edilirken, blok sürenin alt bileşenleri olan taksi varış süresi, uçuş süresi ve taksi kalkış süreleri de ayrı ayrı tahmin edilmiştir. Bu şekilde, toplamda dört farklı tahmin modeli üzerinde çalışılmıştır.

Ayrıca, geçmişe dönük uçuş verilerinin performansını değerlendirmek amacıyla ilgili kalkış ve varış çiftleri için ilgili ayda gerçekleşen blok sürelerinin medyan değerleri de hesaplanmıştır.

Çalışma sonunda bütünsel blok süre tahmini, alt bileşenlerinin olan uçuş ve taksi sürelerinin tahminleri toplamı ve geçmişe dönük gerçekleşen blok süre medyan karşılaştırması yapılmıştır. Karşılaştırma sonucunda en iyi performansı bütünsel olarak tahmin edilen blok süre çalışmasında elde edildiği tespit edilmiştir.

Blok süre tahmini için en iyi performansı Elastik Net modeli göstermiştir. R-kare: 0.95, MAE: 6.15 ve RMSE: 13.89 sonuçları elde edilmiştir.

Taksi varış süre tahmini için en iyi performansı Lasso modeli göstermiştir. R-kare: 0.82, MAE: 2.87 ve RMSE: 26.26 sonuçları elde edilmiştir.

Taksi kalkış süre tahmini için en iyi performansı Elastik Net modeli göstermiştir. R-kare: 0.81, MAE: 4.44 ve RMSE: 10.60 sonuçları elde edilmiştir.

Uçuş süre tahmini için en iyi performansı Elastik Net modeli göstermiştir. R-kare: 0.97, MAE: 4.59 ve RMSE: 9.77 sonuçları elde edilmiştir.

Alt kategori tahminlerin toplamının performans metrik ölçüm sonuçları ise R-kare: 0.93, MAE: 7.18 ve RMSE: 16.36 şeklinde elde edilmiştir.

Gerçekleşen blok süre medyan değeri performans metrik ölçüm sonuçları R-kare: 0.77, MAE: 19.56 ve RMSE: 29.11 şeklindedir.

Gerçekleşen alt kategori medyan değerleri toplamının performans metrik ölçüm sonuçları R-kare: 0.72, MAE: 23.28 ve RMSE: 31.94 şeklindedir.

Planlanan blok süre ve gerçekleşen blok süre karşılaştırmasında performans metrik ölçüm sonuçları R-kare: 0.48, MAE: 36.65 ve RMSE: 41.37 şeklindedir.

Yukarıda belirtilen sonuçlara istinaden en başarılı tahminin bütünsel blok süre tahmininde elde edildiği görülmektedir. Ortalama mutlak hata, sürekli olarak havacılık endüstrisinin kabul edilen 15 dakikalık gecikme eşiğinin altında kalmıştır. Seçilen model, blok süresini tahmin etmede %0,95 oranında açıklanan varyans değerine ulaşmıştır. Ayrıca hava durumu verilerinin entegrasyonu, uçuş programları üzerindeki meteorolojik koşulların etkisini ortaya koyarak, modelin tahmin yeteneklerini artırmaktadır. Blok süresi tahminine yönelik bu bütünsel yaklaşım, bu alandaki anlayışımızı geliştirmektedir.

Bu çalışmanın bulguları zamanında performansı güçlendirmede doğru blok süresi tahmininin kilit rolünü vurgulamaktadır. Elastik Net algoritması, hava durumu verileri ile birlikte bu amaç için etkili bir araçtır. Bu bulgular, operasyonlarını optimize etmeyi, yolcu memnuniyetini artırmayı ve beklenmedik aksaklıkları en aza indirmeyi hedefleyen havacılık paydaşları için değerli iç görüler sunmaktadır. Gelecekteki araştırma çalışmaları, modeli geliştirecek, daha geniş bir bölgeyi ve farklı değişkenleri kapsayacak ve havacılık sektörü içindeki uygulanabilirliğini genişletecektir.

2. LİTERATÜR ARAŞTIRMASI

Abdelghany ve diğerleri tarafından 2023 yılında yapılan bir çalışmada makine öğrenmesi yöntemleri ile blok süre tahmini yapılmıştır. Dataseti olarak 2017 ve 2018 yıllarında Amerika’da gerçekleşen uçuşlara ait yedi havaalanı çifti için model kurgulanmıştır. Modelleme kapsamında XG Boost, Regresyon Ağacı ve Random Forest modelleri kullanılmıştır. Tüm çiftler için en iyi sonuçlar XG Boost algoritmasından elde edilmiştir. Çalışma geçmişe dönük gerçekleşen blok süre medyanları ile karşılaştırılmış ve medyan değerlerinin makine öğrenmesi yöntemlerinden daha iyi sonuçlar verdiği görülmüştür. Havaalanı çiftlerinden JFK – LAX havaalanı çifti için XGB algoritması 0.29 R kare değerine sahipken, medyan alma yönteminde R kare değeri 0.43’e çıkmıştır. [7]

Wang ve diğerleri 2022 yılında en yoğun kalkış varış destinasyonlarından seçilen dört çiftin blok süre modellemesi üzerinde bir çalışma yapmıştır. Bu çalışma kapsamında lineer regresyon, ridge regresyon, multilayer perceptron, random forest, extra trees, adaptive boosting, and gradient boosting machines algoritmalarını kullanılmıştır. Ancak bu modellerin genelleme yeteneği olmadığı keşfedilerek, stacking model kurulmuştur. Bu model ile genelleme yeteneği daha yüksek sonuçlar elde etmişlerdir. RMSE metriği üzerinden yapılan incelemelerde SFO-JFK havaalanları çifti için GBM modeli 14.82 iken stacking algoritmasında 13.38’e düşmüştür. [8]

2019 yılında gerçekleştirilen farklı çalışmada Wang ve arkadaşları Amerika Birleşik Devletleri ve Çin’deki büyük havayolu şirketlerini blok süre belirleme davranışlarını karşılaştırmaktadır. Bu davranış farklılıklarının OTP’ye etkisi analiz edilmiştir. Amerika’da özellikle taksi kalkış süresi için tarihsel zaman dağılımı önem taşıırken Çin’de ise havaalanı durumuna göre değişmekte olduğu görülmüştür. Ayrıca her ülkenin blok süre belirleme davranışı bir diğerine uygulanmış, Çin’in Amerika’da aynı OTP’ye ulaşılacağı görülürken ABD daha kötü bir performans sergilemiştir. [9]

Chen ve diğerleri 2019 yılında ortaya koyduğu bir diğer çalışmada ise blok süre planlamasında kantil regresyon modeli sonuçlarına istinaden belli analizler

sunulmuştur. Bu değerlendirmelere göre uçağın havada geçirdiği süre artmasının bazı belirsizliklere yol açması ile birlikte her 100 km'lik ek mesafenin 3 dakikalık bir artışa sebep olduğu tespit edilmiştir. Ayrıca taksi çıkış ve giriş sürelerinin katsayılarının havada kalma süresinden daha fazla olduğu dolayısı ile blok süre belirlenmesinde ana faktörlerden olduğu da tespit edilmiştir. Son olarak havaalanı büyüklüğünün de blok süreleri etkilediği görülmüştür. [10]

Coy'un 2006 yılında gerçekleştirdiği çalışmada altı farklı havayolu firması için blok süre tahmini için istatistiksel model analizi yapılmıştır. Çoklu regresyon modeli çalışılmış olup, 2004 yılında gerçekleşen iki milyon iç hat uçuşu üzerinde test edilmiştir. Çalışma sonucuna göre varış saati, nüfus, havaalanı kullanımı, buzlanma gibi kötü hava koşulları gibi etkilerin blok süre tahmini üzerinde önemli açıklayıcılar olduğu keşfedilmiştir. [11]

Lu ve Hansen'in 2014 yılında yaptığı bir çalışmada geçmiş blok süre dağılımındaki bir değişikliği planlanan blok süre ve sistemin performansına etkisini araştırmıştır. Çalışma kapsamında çoklu regresyon modeli kullanılmıştır. Bu kapsamda bir önceki yıl yaşanan gecikmelerin bir sonraki sene planlanan blok sürenin artması ile sonuçlandığı gözlemlenmiştir. Ayrıca sağ iç kuyruk ve medyan değerinde meydana gelen bir değişikliği planlanan blok süreyi önemli ölçüde etkilediği de keşfedilmiştir. [12]

Kang ve Hansen'in 2017 yılında gerçekleştirdiği çalışmasında ise bazı blok süre planlama senaryoları hipotez olarak ortaya koyularak, bu senaryolara karşılık zamanında performans gerçekleşip gerçekleşmeyeceği tahmin edilmek istenmiştir. 5 hava yolu firması için korelasyonlu karma logit modelleri denenmiştir. Bu çalışma sonuçlarına göre havayollarının zamanında performansı yüzde bir oranında artırabilmek için blok süre planlamasını 0.38 ile 0.54 dakika arasında artırmaya istekli oldukları gözlemlenmiştir. Ek olarak erken varmaya göre zamanında performansa daha fazla değer verildiği de görülmüştür. [13]

Bir başka analizde ise Kang ve Hansen 2017 yılında gerçekleştirdikleri çalışmalarında John F. Kennedy Uluslararası Havalimanı'nda havaalanı yüzey operasyonlarının blok süre üzerindeki etkisi incelemiştir. Bu çalışma yüzey operasyonları sırasında taksi çıkış süresi için yapılan güncellemelere bağlı olarak planlanan blok süreleri 1 dakikadan 6 dakikaya kadar kısaltılabileceğini analiz etmiştir. Bu düzenleme

yapılırken zamanında performansa zarar vermemek için yüzey operasyonları yapılırken kapı gecikmeleri de dikkate alınmalıdır. [14]

Zhu ve Li'nin 2021 yılında yaptıkları çalışmada derin öğrenme metodu ile uçuş süresi ve olası gecikmeleri tahmin ederek yakıt yükleme kararı için bir analiz ortaya koydular. Çalışma kapsamında öncelikle uzaysal ağırlıklı kapsam sonrasında LSTM metodu kullanılmıştır. Çalışma uçuş sürelerini daha doğru tahminle ederek, yakıt tüketiminin %0.016 ile %1.915 arasında azalma meydana gelirken yakıtın tükenme riskini de minimize edeceğini ortaya koymuştur. [15]

Peng ve diğerlerinin 2021 yılında gerçekleştirdikleri çalışma ise veriye dayalı olarak uçuş sürelerinin tahmin edilmesine odaklanmaktadır. Çalışmada sekiz farklı makine öğrenmesi modeli kullanılmıştır. Bu modellerin arasında doğrusal ve doğrusal olmayan regresyon algoritmalarının yanı sıra ağaç yapısındaki modeller de tercih edilmiştir. Bu çalışma sonuçlarına göre ortalama mutlak hata 4.85'e kadar azalmaktadır. [16]

Stefanovic ve diğerlerinin 2020 yılında yaptıkları çalışmada Litvanya'daki havalimanlarında gerçekleşen uçuş süresi sapmaları analiz edilmiştir. Modelde yedi farklı makine öğrenmesi algoritması kullanılmıştır. Veri kümesi dengelenmesi için SMOTE tekniği kullanılmıştır. Model sonuçları incelendiğinde en iyi sonuçların gradyan destekli karar ağaçları algoritmasından elde edildiği görülmüştür. Kalkış için doğruluk oranı %88.59 iken varış için doğruluk oranı %96.02 olarak gözlemlenmiştir. [17]

Takeichi 2018 yılındaki çalışmasında ise uçuş süresinin belirsizliğinin yönetimi için adaptif bir model geliştirmiştir. Adaptif modelin statik modellere göre daha başarılı sonuçlar verdiği bulgulanmıştır. Bu modeldeki avantaj zaman temelli operasyonlara benzer şekilde 4D rota yönetiminde güvenlik ve verimliliğin aynı anda sağlanmasıdır. [18]

Balakrishna ve diğerlerinin 2010 yılındaki çalışmalarında takviyeli öğrenme yöntemleri ile taksi kalkış süresinin doğruluğu analiz edilmiştir. Dataseti olarak Tampa uluslararası havalimanı verileri kullanılmıştır. Çalışma sonuçlarına göre taksi kalkış süresi %93.7 başarı ile ve ortalama 1.5 dakikalık standart hata ile tahmin edilmiştir. Bireysel uçuşlar için %81'lik tahmin başarı ve 2 dakikalık standart hata gözlemlenmiştir. [19]

Stroiney ve arkadaşlarının 2013 yılında gerçekleştirdikleri çalışmada John F. Kennedy Uluslararası Havalimanı'ndaki (JFK) kalkış ölçümü öncesi ve sonrası karşılaştırmaları ile etkileri analiz edilmiştir. Kalkış ölçümünün performansı artırmada önemli bir etkisi olduğu görülmüştür. 2012 yaz dönemi için kalkış ölçümleri ile birlikte taksi kalkış süresinin uçuş başına 1.5 ile 2.7 dakika arasında iyileşme olduğu gözlemlenmiştir. [20]

Balakrishna ve arkadaşlarının 2008 yaptıkları çalışmada taksi kalkış anındaki gecikmelerin bir uçuşta blok süresinde önemli bir yere sahip olduğunun altını çizmiştir. 15 dakika periyodunda taksi kalkış sürelerini takviyeli öğrenme yöntemleri ile tahmin edilmesine odaklanmıştır. Amerika'daki en yoğun ve karmaşık havaalanlarından biri olan John F. Kennedy Uluslararası Havalimanı'na odaklanılmıştır. Bu veriler havacılık sistem performans metrikleri veri tabanından elde edilmiştir. Çalışma sonucunda 4:00 P.M.'den önce %65, sonrasında %53 olarak tahmin başarısı elde etmiştir. [21]

Lee ve arkadaşları 2016 yılında Charlotte Douglas Uluslararası Havaalanı'nda taksi kalkış sürelerinin makine öğrenmesi teknikleri ile tahmin edilmesi üzerine bir çalışma gerçekleştirmişlerdir. Lineer regresyon, random forest, support vector makineleri, neural networks ve dead reckoning algoritmaları kullanılmıştır. Lineer regresyon ve random forest modellerinden %65 ile %74 arasında ile en iyi başarı elde edilmiştir. Bu performans sınırının havaalanındaki karmaşıklık ve belirsizliklerden meydana geldiği gözlemlenmiştir. [22]

Malighetti ve diğerlerinin 2023 yılında yaptıkları bir çalışmada Avrupa'da 2019 yılında gerçekleşen uçuşlar gerçekleşen ve planlanan blok süreleri üzerinden incelenerek zamanında performansı etkileyen faktörler analiz edilmiştir. Bu farkların uçak, uçuş ve havaalanı özelliklerinden kaynaklandığını analiz etmişlerdir. Uçaklar genelde havaalanından geç kalkmasına rağmen zamanında zamanında varış gerçekleştirdiği gözlemlenmiştir. Bunun kök nedeni olarak da taşıyıcı firmaların tampon süre eklemesi ile olası belirsizlikleri öngörerek planlama yaptıklarını analiz edilmiştir. [23]

AhmadBeygi ve diğerleri 2008 yılında havayollarında yaşanan gecikmeleri incelemişlerdir. Çalışma sonucunda günün erken saatlerinde meydana gelebilecek gecikmeyi önlemenin katkısının altı çizilmiştir. Ayrıca uçuşları ve mürettebatın bir

arada bulunmasının da gecikme yayılımının azaltılmasında etkili olduğu gözlemlenmiştir. [24]

Alla ve arkadaşları 2022 yılında gerçekleştirdikleri bir çalışmada Amerika iç hat uçuşlarını kullanarak uçuş ve varış gecikmelerini tahmin modeli geliştirmişlerdir. Modelde bağımlı değişken olarak kalkış saati, varış zaman dilimi ve uçak modeli bilgileri kullanılmıştır. Model olarak Random Forest, KNN, Naive Bayes ve karar ağaçları algoritmaları kullanılmıştır. 0.93 doğruluk oranı ile en iyi sonuçlar random forest modelinden elde edilmiştir. [25]

Khaksar ve Sheikholeslami'nin 2017 yılı araştırmasında gecikme tahmini için Amerika veri setinde test edilerek İran Havayolu ağı için makine öğrenmesi modeli geliştirilmiştir. Algoritma olarak Bayesyan modelleme, karar ağacı, küme sınıflandırması, random forest ve hibrit modeller denenmiştir. %70 doğruluk oranı ile model başarısı yakalanılarak uçuş planlamalarına katkı sağlamak ve gecikmeleri önlemek hedeflenmiştir. Ek olarak çalışmaya göre Amerika'da gecikme ana nedenleri kalkış saati, rüzgar ve görünürlük olarak tespit edilirken, İran'da uçak tipi ve filo yaşı olarak gözlemlenmiştir. [26]

Atlıoğlu ve diğerleri 2020 yılında uçuş gecikmeleri için makine öğrenmesi yöntemlerinden denetimli öğrenme ile bir tahmin modeli üzerinde çalıştılar. On bir tane farklı model yaklaşımı sonuçları incelendiğinde F skorların karar ağacı ve KNN modellerinde sırası ile 0.816 ve 0.807 olduğu buna karşın gradyan artırma modellerinden olan GBM, XGB ve LGBM algoritmalarında ise yaklaşık 0.810 seviyesinde skorlar elde edilmiştir. [27]

Yazdi ve diğerleri 2020 yılında uçuş gecikmeleri tahmini için derin öğrenme temelli Levenberg-Marquart algoritması için araştırma gerçekleştirdiler. Veri setinin dengelemek için undersampling ve upsampling metodları denenmiştir. Ancak ikinci örneklem alma metodu aşırı uyuma sebebiyet verdiği için ilk yöntem ile ilerlenmiştir. Model sonuçları dengesiz ve dengeli veri setleri için ayrı ayrı değerlendirilmiştir. Sırası ile model başarıları %91.1 ve %96.2 olarak gözlemlenmiştir. [28]

2019'da Chakrabarty'nin ortaya koyduğu bir çalışmada American Airlines havayolunun gecikmelerini incelemek için veri madenciliği yöntemlerini kullandı. Amerika'da bulunan en yoğun beş havalimanı üzerinde gerçekleştirilen çalışmada

Gradyan Boosting sınıflandırma algoritması ile en iyi sonuç olarak %85.7 doğruluk ile keşfedildi. [29]

Wong ve Tsai'nin 2012 yılına ait araştırmasında düzenli olmayan operasyonların ek maliyet kalemlerine sebebiyet verdiği değerlendirilmiştir. Ortaya koyduğu Cox regresyon analizi sonuçlarına göre kalkış anında gecikmeye sebebiyet veren ana sebeplerin uçak tipi, kargo, ekipman, yolcu ve bagaj aksiyonları ve hava durumu olarak belirlemiştir. [30]

Kafle ve Zou'nun 2016 yılındaki analizinde uçuşlardaki gecikmelerin yayılımı ve azaltılmasını değerlendirdiği bir yaklaşım ortaya koymuştur. Bu analitik ve ekonometrik model sonuçlarının havayollarının uçuş programı ataması esnasında daha güvenilir ek süre atamasına katkı sağlayabileceğini ileri sürmüştür. [31]

Jacquillat ve Odoni'nin 2018 yılına ait bir yaptığı bir araştırmada havalanı kapasitesinin alt yapıya ve işletme prosedürlerine bağlı olduğu gözlemlenmiştir. Talep ve kapasiteye bağlı olarak planlamaların da farklılaştığı gözlemlenmiştir. Planlama, kapasite ve gecikme arasında doğru orantı olmadığı da bir diğer gözlemdir. Özellikle yoğun havalimanları için talep yönetimi sıklıkla azaltılması ve maksimum kapasite yönetimi için önemli bir katma değer sağlayacağı öngörülmüştür. [32]

Yin ve diğerlerinin 2020 yılında ortaya koydukları değerlendirmelerinde birden fazla aktif pist içeren metroplex havalimanlarında pist konfigürasyonu üzerinde bir analiz çıkartmışlardır. Şangay'da bulunan metroplex havalimanları üzerinde gerçekleştirilen model testlerinin sonuçlarına göre toplam ayarlanmış uçuş sayısını %36 oranında azalttığı gözlemlenmiştir. Ek olarak kalkış yapan uçaklara öncelik verilmesinin pist sisteminde performansı artırdığı ve ayarlanmak durumunda kalınan uçuş sayısını da azalttığı ayrıca gözlemlenmiştir. [33]

Sanz ve diğerlerinin 2021 yılında gerçekleştirdikleri çalışmada Bayesian network metodu ile hava durumunun gecikme üzerindeki etkisi araştırılmıştır. Çalışma kapsamında Adolfo Suárez Madrid-Barajas havaalanında 2015 ve 2018 yılları arasında gerçekleşen uçuşlar baz alınmıştır. Havaalanı Meteoroloji Endeksi değerlerinin 12'nin üzerinde olup olmamasına göre gecikme, iptal ve tıkanıklık arasında önemli bir ilişki olduğu gözlemlenmiştir. Bu gözleme ek olarak hava skorunun 10 puan artmasına karşılık varış gecikmesinin de 3.39 dakika arttığı analiz edilmiştir. Bunun yanı sıra

hava durumuna ait özel deęiřkenlerin de hedef deęiřken ile arasında iliřki olduęu tespit edilmiřtir. [34]

Sanz ve dięerlerinin 2021 yılına ait alıřmasında havaalanı pistlerinin belirli sayıda yoğunluęu kaldırabilecek řekilde kapasite sınırı olduęunu ortaya koymuřtur. Havalimanları aısından verimlilięin saęlanması iin pist planlamada optimizasyon modelinin onemi vurgulanmıřtır. Analiz alıřması sonucuna gre uaklar arasındaki 1 dakikalık ayırmanın mevcut durumdan %74 daha iyi, 2 dakikalık ayırmanın ise %51 daha iyi olduęu gzlemlenmiřtir. [35]

Zografos ve arkadaşlarının 2016 yılında gerekleřtirdikleri bir alıřmada mevcut slot planlama ve kapasite ynetimi incelemelerini sunmuřtur. İnceleme sonularına gre ortaya konulan yeni slot planlama yaklařımlarında mevcut sistemlerin deęiřkenlerinin yanı sıra kaynak kullanımı ve evresel faktrler ile zenginleřtirilmesinin katma deęerinin altını izmektedir. [36]



3. DATASET

Bu bölümde modelleme adımında kullanılan veri setlerinin nereden elde edildiği ve veri ön işleme adımında hangi süreçlerden geçtiği anlatılacaktır. Son adımda ise eğitim, validasyon ve test veri setlerinin ayırma yöntemine değinilecektir.

3.1. Veri Setleri

Bu adımda modelde kullanılan performans verileri ve hava durumu verileri hakkında bilgi verilecektir. Eğitim, validasyon ve test kümelerinin ayrışımı hakkında da bilgilendirme yapılacaktır.

3.1.1. Zamanında performans verileri

Bu çalışmanın verileri, Amerika Birleşik Devletleri Ulaştırma Bakanlığı tarafından sağlanan Ulaştırma İstatistikleri Bürosu (BTS) veri tabanından alınmıştır. Çalışma kapsamında 1 Ocak 2021 ile 30 Haziran 2023 tarihleri arasında gerçekleşen zamanında performans verileri baz alınmıştır. Data seti 2265457 kayıt ve 48 kolondan oluşmaktadır. Yalnızca varış noktalarına başarıyla ulaşan uçuşlar dikkate alınırken, yönlendirme, iptal veya yinleme durumlarına sahip uçuşlar veri kümesinden hariç tutuldu. Ayrıca çalışma, zamanında kalkış ve zamanında varma açısından optimum değerlerin altında performans sergileyen uçuşlara odaklanmıştır.

Çalışma öncesi ön analiz çalışması gerçekleştirilmiş olup, geçmişe dönük veriler incelendiğinde zamanında performans açısından optimumun altında kalan daha fazla porta sahip olan Florida eyaletinde gerçekleşen uçuşlar seçilmiştir. Ek olarak modelin katkısını daha iyi gözlemleyebilmek adına havacılık endüstrisinin kabul ettiği 15 dakikalık gecikme eşiğinin üstünde gecikmeye sahip uçuşlar göz önünde bulundurulmuştur. Bu bağlamda planlanan blok süre ve gerçekleşen blok süre arasındaki fark yirmi dakikadan fazla olan uçuşlar seçilmiştir. Bazı uçuşlarda planlanan ile gerçekleşen süreler uyumlu olmasa da zamanında varış portuna ulaşabilmektedir. Buradaki gecikmeleri de çalışmaya dahil edebilmek için planlanan ve gerçekleşen blok süreler arasındaki farka ek olarak varış saatinde gecikme olan

uçuşlar da ayrıca filtrelenmiştir. Bu filtreler ile birlikte blok süresi açısından performansı ortalamanın altında olan uçuşlar seçilmiştir. Böylelikle blok süresini tahmin edebilmek için zamanında gerçekleştirmeler açısından daha kötü performans gösteren uçuşlara odaklanılarak katma değer sağlamak hedeflenmiştir.

Blok süre, uçuş süresi ve taksi sürelerini kapsayan toplam zamanı ifade etmektedir. Taxi out olarak literatürde ifade edilen taksi kalkış süresi ise, uçağın hareket etmesinden havalanmasına kadar pistte hareket ettiği süreyi, taxi in olarak ifade edilen taksi varış süresi de uçağın piste tekerin değmesinden kapıya gelene kadar pistte hareket halindeki süresini ifade etmektedir. Uçuş süresi ise uçağın havada geçirdiği süreyi temsil etmektedir. Bu çalışma kapsamında blok süre hem bütünsel olarak tahmin edilecek olup, hem de alt bileşenleri de ayrı ayrı tahmin edilecektir. Blok süre için alt bileşenlerin toplamı ve total blok süre tahminleri karşılaştırılacaktır.

On time performans data setinde planlanan blok süre, gerçekleşen blok süre, taksi süreleri, kalkış portu ve varış portuna dair tarih ve içerik bilgileri, eyalet, şehir, hava alanı bilgileri, gecikme durumları, gecikme sebepleri gibi data alanları bulunmaktadır.

3.1.2. Hava durumu verileri

Hava koşullarının uçuş süresi üzerindeki etkisini değerlendirmek için Azure DevOps platformu aracılığıyla hava durumu verileri toplandı. Port ve tarih bilgileri üzerinden ana data setine hava durumu dataları da birleştirilmiştir. Hava durumu veri seti aracılığıyla sıcaklık, yağış ve kar yağışı durumu gibi değişkenlerin elde edilmesine olanak sağladı. Şekil 3.1’de hava durumu için kullanılan veri alanları gösterilmektedir.

```
df_weather.info()

<class 'pandas.core.frame.DataFrame'>
RangeIndex: 11840501 entries, 0 to 11840500
Data columns (total 10 columns):
#   Column                Dtype
---  -
0   RECORD_DAY            int64
1   TEMP_MAX_CELCIUS      float64
2   TEMP_AVG_CELCIUS      float64
3   TEMP_MIN_CELCIUS      float64
4   PORT                  object
5   PRECIPITATION_MM      float64
6   HEATING_DEGREE_CELCIUS int64
7   COOLING_DEGREE_CELCIUS int64
8   SNOWFALL_CM           float64
9   SNOWDEPTH_CM          float64
dtypes: float64(6), int64(3), object(1)
memory usage: 903.4+ MB
```


Şekil 3.1 : Hava durumuna ait veriler gösterilmektedir.

Belirli bir hava alanında ilgili tarihte gerçekleşen ortalama, minimum ve maksimum sıcaklık, yağış, kar yağışı, kar derinliği, ısıtma ve soğutma sıcaklık dereceleri bilgilerine bu kaynak üzerinde ulaşılmıştır.

3.1.3. Eğitim, validasyon ve test kümesi ayrışımı

Veri seti 01.01.2021 ve 31.12.2023 tarihleri arasında Amerika Birleşik Devletleri'nde gerçekleşen uçuşları kapsamaktadır. Modelin eğitilmesi aşaması için eğitim kümesi ayrılmıştır. Modelin performansını değerlendirme, modelin genelleme yeteneği ve overfitting durumlarını analiz edebilmek için validasyon veri seti oluşturulmuştur. Modelin daha önce görmediği gerçek veriler üzerindeki başarısını değerlendirebilmek için de test veri seti ayrılmıştır.

Şekil 3.2'de eğitim, validasyon ve test setlerinin ayrışımı gösterilmektedir. Toplamda iki buçuk seneyi kapsayan veri setinden 01.01.2021 ve 31.12.2022 aralığı veri setini eğitmek üzere seçilmiştir. 2023 sonrası datalar ise validasyon ve test seti olarak işaretlenmiştir. 2023 yılının ilk üç ayı validasyon geri kalanı ise test setini temsil etmektedir. Validasyon seti üzerinde Grid search algoritması çalışıldıktan sonra optimize edilmiş model seçilerek test seti üzerinde bu model kullanılmıştır. Böylelikle overfitting ve train-test trade off problemlerinin önüne geçilmiştir.



Şekil 3.2 : Eğitim, validasyon ve test kümelerinin ayrımı gösterilmektedir.

Validasyon seti üzerinde Grid search algoritması çalışıldıktan sonra optimize edilmiş model seçilerek test seti üzerinde bu model kullanılmıştır. Bu şekilde overfitting ve modelin genellenebilir olmayışı problemlerinin önüne geçilmek hedeflenmiştir.

3.2. Veri Analizi

Bu adımda tanımlayıcı analiz, boş değer ve uç değer analizinin yanı sıra nümerik ve kategorik değişkenlerin analizine dair gerçekleştirilen çalışmalar paylaşılabacaktır.

3.2.1. Tanımlayıcı analiz

Veri setinde gerekli filtrelemeler yapıp veri temizliği yapıldıktan sonra kalan 138724 kayıt üzerinde çalışmaya devam edilmiştir. Bu çalışmada blok süre tahminleri çalışılacağı için iptal, yönlendirme durumları ve bazı gecikme kök nedenlerine ilişkin alanlarda datadan çıkarıldıktan sonra kalan 29 alan seçilmiştir. Bu seçilen data alanlarında standart sapma, ortalamalar, medyan ve çeyrekliklerden vb. oluşan istatistiki analiz sonuçları incelenerek data kalitesi kontrol edilmiştir.

3.2.2. Boş değer analizi

Veri setinde bütünselliği sağlamak ve güvenilir sonuçlar elde edebilmek için öncelikle boş veya eksik değer kontrolü yapılmıştır. Veri kalitesini artırmak için gerekli olan araştırma sonucunda eksik veya boş değer olarak tespit edilen aşağıdaki kolonlar dropna() metodu ile datasetinden kaldırılmıştır. Şekil 3.3'te boş değerlere sahip kolonlar belirtilmiştir.


TEMP_MAX_CELCIUS	6678
TEMP_AVG_CELCIUS	6678
TEMP_MIN_CELCIUS	6678
PORT	6678
PRECIPITATION_MM	6678
HEATING_DEGREE_CELCIUS	6678
COOLING_DEGREE_CELCIUS	6678
SNOWFALL_CM	6678
SNOWDEPTH_CM	6678

Şekil 3.3 : Boş değere sahip kolonlar gösterilmektedir.

Veri seti boş değerler üzerinden kontrol edildiğinde hava durumu data setine ait bazı kolonlarda eksik değerlerin olduğu görülmektedir.


3.2.3. Uç değer analizi

Veri setindeki aykırı değerleri belirlemek ve bunların sebep olabileceği etkileri anlamak için görselleştirme teknikleri ile analizler çalışılmıştır. Uç değer analizi için kutu grafiği gösterimlerinden faydalanılmıştır. Şekil 3.4'te uzaklık alanının uç değer analizi gösterilmektedir.



Şekil 3.4 : Uçuş menzil uzaklığı uç değer analizi gösterilmektedir.

Şekil 3.5’te planlanan uçuş süresinin uç değer analizi paylaşılmıştır.




Şekil 3.5 : Uçuş menzil uzaklığı uç değer analizi gösterilmektedir.

Uç değer analizi tüm data alanları için gerçekleştirilmiştir.


3.2.4. Nümerik değer analizi

Tüm nümerik değerler ayrı ayrı incelenerek dağılımları, çarpıklık ve basıklık durumları kontrol edilmiştir. Şekil 4’te planlanan ve gerçekleşen blok süre dağılımları verilmiştir. Şekil 3.6’da planlanan blok süre ve gerçekleşen blok sürelere ait dağılım grafiği sunulmuştur.



Şekil 3.6 : Planlanan ve gerçekleşen blok süreleri dağılımı gösterilmektedir.

Şekil 3.7’de ise taksi kalkış süresi ve taksi varış sürelerine ait dağılım grafikleri gösterilmiştir.



Şekil 3.7 : Taksi kalkış ve taksi varış süreleri dağılımı gösterilmektedir.

Şekil 3.8’de uzaklık ve uzaklık kategorilerine ait dağılım grafiğinin yanı sıra bu dağılımlara ait istatistikler de paylaşılmıştır.




Şekil 3.8 : Boş değere sahip kolonlar gösterilmektedir.

Tüm data alanları için çeşitli görselleştirme metodları ile dağılım, çarpıklık ve basıklık durumları analiz edilmiştir.


3.2.5. Kategorik değer analizi

Kategorik değişkenler data setini doğru anlamlandırabilmek ve başarılı model sonuçlarını elde etmek amacı ile analiz çalışması yapılmıştır. Her kategoriye ait ne kadar gözlem olduğu, veri setinde herhangi bir dengesizlik olup olmadığı ve nadir kategorileri gözlemlemek amacı ile çeşitli kütüphanelerin yardımı ile kategorik değişken analizleri yapılmıştır. Şekil 3.9’da haftanın günleri ifade eden ‘Day Of Week’ değişkenine ait dağılım görülmektedir.



Şekil 3.9 : Haftanın günleri dağılımı gösterilmektedir.

Şekil 3.10’da yılın aylarını ifade eden ‘Month’ değişkenine ait dağılım grafiği görülmektedir.



Şekil 3.10 : Aylara göre dağılım gösterilmektedir.

Tüm data alanları için bu analizler gerçekleştirilmiştir.

3.3. Özellik Mühendisliği

Model performansını artırmak, bağımlı ve bağımsız değişkenler arasındaki ilişkileri daha iyi yakalamak ve daha kabul edilebilir sonuçlar elde edebilmek için özellik mühendisliği adımı işletilmiştir. Bu kapsamda veri formatı dönüşümleri ve özellik üretme adımları takip edilmiştir. Özellik üretme, mevcut veri kümesinden yeni özellikler türetmeyi içerdiğinden, tahmine dayalı modellemenin kritik bir bileşenidir. Çalışmada modelin tahmin gücünü artırmak için özellik mühendisliği teknikleri uygulandı. Bu adımda mevcut verilerin kombinasyonları, farklı fonksiyonları ve veri dönüşümleri ile yeni öznitelikler oluşturulmuştur.

3.3.1. Veri tipi dönüşümleri

Veri kümesini modellemeye uygun hale getirmek için çeşitli veri dönüşümleri gerçekleştirilmiştir.

- **Kategorik Değişkenler:** Kategorik değişkenler, one hot kodlama tekniği kullanılarak ikili değişkenlere dönüştürülmüştür. Bu yaklaşım ile her kategori için ikili sütunlar oluşturularak veri kümesi genişletilmiş ve bunları etkili bir

şekilde makine öğrenimi modellerinde kullanılabilecek bir formata dönüştürülmüştür.

- Sayısal Değişkenler: Modelleme sürecine tutarlı bir şekilde katkıda bulunmalarını sağlamak için sayısal değişkenler gerektiği şekilde standartlaştırıldı veya normalleştirildi.
- Tarih Değişkenleri: Sezonallığı temsil eden değişkenler string formatına dönüştürülerek her kategorinin anlamlılığı analiz edilmiştir. Uçuş tarihi değişkeni ise gerekli ön işlemler yapıldıktan sonra date formatına dönüştürülmüştür.

Uçuş ve hava durumu verilerinin geçmiş ortalamaları aylık bazda hesaplanarak veri seti zamansal bilgilerle zenginleştirildi.

3.3.2. Özellik üretme

Uçağın kalkış yeri, varış yeri ve ay değişkeninin birleştirilmesi ile Dep_Arr_Month adında bir değişken üretilmiştir. Bu değişken daha sonra ilgili kalkış varış port çiftleri için geçmişe dönük aylık analizler için üretilecek diğer değişkenlerde baz olarak kullanılacaktır.

Uçak taşıyıcı firma tipi, sefer numarası, ay ve haftanın günleri değişkenlerinin birleştirilmesi ile oluşturulan yeni değişken olan Carier_FlNo_Month_DayWeek değişkeni de geçmişe dönük medyan değerleri alınırken gruplama yapmak için kullanılarak farklı bağımsız değişkenlerin geçmişe dönük ortalamaları kullanılmıştır.

Uçağın kalkış yaptığı portun dahil olduğu eyalet ve iniş yaptığı portun dahil olduğu eyalet kolonları birleştirilerek Org_Dest_State şeklinde yeni bir özellik üretilmiştir. Daha sonra bu değişken dummy değişkenleri oluşturma (get dummy) metodu ile modelde kullanılmıştır.

Aşağıdaki belirtilen alanlar için de yukarıda Dep_Arr_Month ve Carier_FlNo_Month_DayWeek olarak yeni üretilen değişkenler belirtilen bağımsız değişken bazında gruplanarak geçmişe dönük blok süre, uçuş süresi, taksi kalkış süresi, taksi varış süresi, hava sıcaklığı, yağış durumu ve kar kalınlığı vb. alanları için aylık ortanca değerleri yeni değişkenler olarak üretilmiştir.



4. METODOLOJİ

Bu bölümde çalışmada takip edilecek metodolojiler anlatılacaktır. Özellik seçme yaklaşımında modelde kullanılacak öznitelikler seçilirken göz önünde bulundurulacak teknikler paylaşılabacaktır. Modelleme aşamasında makine öğrenmesi yöntemlerinden denetimli öğrenmenin alt grubu olan regresyon modellerine ait bilgi verilecektir. Bu modellerin değerlendirmesinde kullanılan metriklerin açıklanması ile devam edilecektir. En son aşamada ise hiperparametre optimizasyonu için takip edilen adımlar anlatılacaktır.

4.1. Özellik Seçme Yaklaşımları

Özellik seçme adımından önce veri ön işleme adımında eksik veri, aykırı değer, normalizasyon gerekliliği gibi durumlar kontrol edilerek gerekli düzenlemeler yapılmıştır. Veri analizi kapsamında hangi özelliklerin model için uygun olduğuna dair veri keşfi çalışmaları da gerçekleştirilmiştir.

Modelin performansını artırmak ve model performansına etkisi en fazla olacak değişkenleri seçebilmek adına istatistiksel yöntemler kullanılmıştır. Model performans sonuçları değerlendirilerek en iyi özellikler tespit edilerek modeller oluşturulmuştur. Bu yöntemlerin bazıları aşağıda listelenmiştir.

4.1.1. Pearson korelasyonu yöntemi

Pearson korelasyonu sürekli değişkenler arasındaki lineer ilişkiyi ve şiddetini ölçen bir istatistiksel yöntemdir. 1' yakın değerler pozitif yönlü ilişkinin şiddetini, -1'e yaklaşan değerler negatif yönlü ilişkinin şiddetini ifade eder. 0 ise bir ilişki olmadığını gösterir.

Özellik seçiminde bağımlı ve bağımsız değişkenlerin ilişkisi hakkında bilgi verirken yüksek korelasyona sahip bağımsız değişkenler seçilerek model başarısı artırmak hedeflenmektedir.

4.1.2. Isı haritası yöntemi

Korelasyon matrisinin görsel gösterimi olan bu grafik türünde, değişkenler arasındaki ilişkiler hem farklı renk tonları ile hem de katsayılar değerlendirilerek analiz edilebilir. Aşağıdaki adımlar takip edilerek yüksek korelasyona sahip ve çoklu doğrusallık içeren değişkenler tespit edilerek model başarısı artırmak hedeflenir.

- Korelasyon analizi: Yüksek korelasyona sahip değişkenler belirlenir.
- Korelasyon katsayılarının analizi: Modelde birlikte kullanılabilecek değişkenler belirlenir.
- Özellik seçimi: Yüksek korelasyon analizi ve çoklu doğrusallık içerip içermediği kontrolüne göre özellik seçimi gerçekleştirilir.

4.1.3. Karar ağaçları algoritması

Karar ağacı algoritmalarında ağaç yapısı oluşturulurken hangi değişkenlerin daha belirleyici olduğu ve hedef değişkene katkısını belirleyebilmek önemli bir öngörü sağlar. Ağaç algoritmalarındaki "önemli değişkenler" yöntemi değişkenlerin önem düzeylerini belirlemede katkı sağlar. Aşağıdaki adımlar takip edilerek özellik seçiminde karar ağaçlarından faydalanılabilir.

- Karar ağacı modelinin oluşturulması: Öncelikle model oluşturulur.
- Değişkenlerin önem derecelerinin Belirlenmesi: Karar ağaçları algoritmalarında önemli değişkenler yöntemi ile önem dereceleri hesaplanır.
- Özellik seçimi: Önem derecesi daha yüksek olan değişkenler seçilir.

4.1.4. En küçük kareler algoritması

En küçük kareler regresyon analizi, bağımsız değişkenlerin bağımlı değişken üzerindeki etkilerini en hassas şekilde modellemeye çalışarak, değişkenler arasındaki ilişkiyi en iyi şekilde açıklamaya odaklanır. Bu şekilde, model üzerinde istatistiksel çıkarımlar yapabilmek ve özellikler arasındaki ilişkiyi anlamak için önemli bir algoritmadır.

Başlangıç aşamasında en küçük kareler yöntemi kullanılarak oluşturulan model, bağımsız değişkenlerin p-değerleri ve anlamlılıkları detaylı bir şekilde analiz edilmiştir. Aynı zamanda her bir değişkenin model katsayıları ve çoklu korelasyon durumları da incelenmiştir.


- P-değerlerinin ve katsayıların İncelenmesi: Modelin katsayıları ve p-değerleri analiz edilir. P-değeri, bir değişkenin istatistiksel olarak anlamlı olup olmadığını gösterir. Bu adımda, p-değeri belirli bir alfa düzeyinden (0.05) küçük olan değişkenler modelde tutulur.
- Korelasyon analizi: Özellikler arasındaki korelasyon kontrol edilir. Yüksek korelasyona sahip özelliklerden bir tanesi modelde kullanmak üzere seçilir.

Bu analizler kapsamında, regresyon modelinin oluşturulmasında kullanılan değişkenlerin istatistiksel olarak anlamlı olup olmadığını belirlemek ve bağımsız değişkenlerin bağımlı değişken üzerindeki etkilerini tahmin etmek amaçlanmıştır.

4.2. Modelleme Adımında Tercih Edilen Algoritmalar

Blok süre tahmini aşamasında kullanılacak tüm hedef değişkenler sürekli bir aralıkta yer aldığı için regresyon modelleri tercih edilmiştir. Bağımlı ve bağımsız değişkenler arasındaki ilişkiler öğrenilerek geleceğe yönelik blok süre tahminleri çalışılacaktır.

Bu çalışmada temel olarak Lineer Regresyon, Lasso Regresyon, Ridge Regresyon, Elastik Net Regresyon, Random Forest, Bagging ve XG Boost Regresyon modelleri kullanılmıştır. Modeller ait açıklamalar aşağıda ifade edilmiştir. Şekil 4.1’de veri bilimi süreçlerinde takip edilen adımlar görülmektedir.



Şekil 4.1 : ML algoritmalarında takip edilen adımlar gösterilmektedir.

Veri bilimi yaşam döngüsü sürecinde veriler toplandıktan sonra analiz edilir. Sonrasında modele girecek veri seti uygun formda hazırlanır. Modelleme ve

değerlendirme süreci ile devam eder. Model istenilen başarıya ulaşmadığı koşulda bu yaşam döngüsü tekrarlanır. Tüm sürecin merkezinde her zaman veri vardır.

4.2.1. Lineer regresyon

Lineer regresyon veri bilimi ve istatistik alanlarında sıkça kullanılan temel algoritmalardan bir tanesidir. Model temel olarak bağımlı ve bağımsız değişken veya değişkenler arasındaki ilişkileri sayısal olarak ifade etmeye odaklanır.

Modelde öncelikle data setindeki gözlemleri temsil edecek en iyi düzlem ya da doğru oluşturulur. Sonrasında oluşturulan doğru veya düzlem matematiksel bir formül ile ifade edilir. Bu matematiksel denklem yardımı ile değişkenler arasındaki ilişkiler ortaya çıkarılabilir, tahminler gerçekleştirilerek karar destek sistemlerinde kullanılmasına olanak sağlar.

4.2.2. Lasso regresyon

Veri bilimi ve istatistik alanlarında yaygın olarak kullanılan bir diğer teknik ise lasso regresyondur. Bu model yaklaşımında karmaşıklığı azaltmak ve aşırı uyumu önlemek için L1 regülerizasyon olarak ifade edilen bir teknik kullanılır. Bu teknik yardımı ile gereksiz değişkenlerin katsayıları sıfıra yaklaştırılır ve bu şekilde filtelenmiş olur.

Bu model özellik seçimi adımında da regüle ettiği değişken katsayıları kontrol edilerek model performansına daha fazla etki edecek şekilde özellik seçimi yapılmasına olanak sağlar.

Yüksek boyutlu ve gürültülü veri setleri için etkili sonuçlar üretilmesine katkı sağlayan bu regresyon tekniği ayrıca iki değişken arasındaki ilişkinin yönü ve büyüklüğünü ifade eden kovaryans yapısı içeren veri seti için etkindir.

4.2.3. Ridge regresyon

Ridge regresyon tekniği de lasso regresyonunda olduğu gibi regresyon katsayıları üzerinde regülerizasyon işlemi uygular. L2 regülerizasyon olarak adlandırılan bu teknik katsayıları sıfıra yaklaştırır ancak lasso regresyonda olduğu gibi sıfıra eşitlemez. Bu şekilde modelin karmaşıklığı azaltılırken bazı değişkenler modelden tamamen çıkarılmış olmaz.

Katsayıları sıfıra yaklaştırması ancak modelde tutmaya devam etmesi sayesinde etkisiz veya gereksiz olarak işaretlenen değişkenlerin veri seti içerisinde kalması gerekiyorsa bu model tercih edilir.

Bu model çoklu doğrusallık içeren veri setlerinde başarılı sonuçlar sağlarken aynı zamanda aşırı uyum azaltılır ve modelin genelleme yeteneği artar.

4.2.4. Elastic net regresyon

Bu regresyon modeli daha önce bahsedilen lasso ve ridge modellerinde kullanılan L1 ve L2 regülarizasyon tekniklerini birleştirerek her iki modelin avantajlarından faydalanılmasına olanak sağlar.

Önceki iki modelin tek başına eksik kaldığı yerlerde veri setlerinde Elastik Net yaklaşımı daha başarılı sonuçlar elde edebilir.

Ridge model yaklaşımında modelin genelleme yeteneğini sağlarken, aynı zamanda Lasso yaklaşımından elde edilen aşırı uyuma direnç kazanımını da devam ettirir.

Bunun yanı sıra L1 regülarizasyon ile gereksiz özellikler filtrelenirken, L2 regülarizasyon ile model katsayıları stabil olarak tutulur.

4.2.5. Bagging regresyon

Bagging regresyon modeli ensemble olarak adlandırılan farklı modellerin bir araya gelmesi ile modelin daha güçlü tahmin yapabildiği bir algoritmayı kullanılır. Karmaşık ve varyansı yüksek olan veri setlerinde bu modeller tercih edilir.

Model yaklaşımında farklı alt kümeler ayrılacak olan veri setleri üzerinden farklı modellerden elde edilen tahminlerin birleştirilmesi ile bir tahmin yapılır. Bu şekilde aşırı uyum problemi azaltılır, modelin genellenebilirliği artırılır ve yüksek varyans azaltılır.

4.2.6. Random forest regresyon

Random forest regresyon tekniği, daha önce bahsedilen bagging regresyon gibi ensemble olarak tanımlanan farklı modellerin sonuçlarının birleştirilmesi ile daha iyi tahminler üreten bir modelleme tekniğidir.

Bu yöntemde farklı karar ağacı modellerinin farklı veri alt kümelerinde eğitilmesi sonucunda oluşan tahminlerin birleştirilmesi sonucu genel bir tahmin oluşturulur. Bu şekilde genellenebilirliği yüksek ve aşırı uyuma dirençli modeller oluşturulur.

Değişkenler arasında ilişkilerin karmaşık olduğu, gürültülü ve yüksek varyansa sahip veri setlerinde iyi bir tahmin performansı gösterir.

4.2.7. XG Boost regresyon

XG Boost Regresyon, karar ağaçları üzerine kurulmuştur ve yüksek boyutlu veri setlerinde hızlı çalışır ve yüksek performans gösterir. Eksik veri işleme, regülarizasyon ve özellik seçimi gibi adımları otomatik olarak gerçekleştirir.

XG Boost modeli oluşturulurken başlangıç tahmini ile başlanır. Sonrasında gradyan kaybı hesaplanır. Optimal ağaç sayısı belirlenir. Gradyan bilgisi kullanılarak her düğümdeki en iyi bölünmeler tespit edilir. En iyi bölünmelerden sonra yaprak düğümleri güncellenir. Yeni ağaç eklemeye devam edilerek modeller güncellenir. En son aşamada ise belirlenen durdurma kriterlerine ulaşıncaya kadar bu işlemler tekrar edilir.

4.3. Performans Değerlendirme Adımında Kullanılan Metrikler

Blok süre tahminlerinde kullanılan regresyon modellerinin performansını değerlendirmek ve farklı modeller arasında karşılaştırma yapabilmek adına tercih edilen bazı performans metrikleri kullanılmıştır. Çalışmada, bu metriklerin kullanılması, modellerin performansını detaylı bir şekilde değerlendirmeyi ve karşılaştırmalarını yapmayı amaçlamıştır.

Bu sayede, regresyon modellerinin blok süre tahminine ne kadar uyum sağladığı ve hangi modelin en iyi performansı sergilediği konusunda daha derinlemesine bir analiz yapılmıştır.

Gerçek veriler ile tahmin edilen blok süreler arasında hangi modelin daha başarılı sonuçları sağladığı tespit edilerek en uygun modeli seçmek üzere bir araç olarak kullanılmıştır.

4.3.1. Ortalama mutlak hata

Regresyon modellerinde performans değerlendirme aşamasında sıklıkla kullanılan ölçütlerden bir tanesidir. Bu metrik gerçekleşen değerler ile tahmin edilen değerler arasındaki uzaklığı ölçmektedir.

Yaklaşım olarak öncelikle tahmin edilen değerler ile gerçekleşen değerlerin farkının mutlak değeri hesaplanır. Daha sonra bu mutlak değerlerin ortalaması alınarak ortalama mutlak hata oranı hesaplanmış olur.

MAE kısaltması ile ifade edilen bu yöntemde mutlak değer alınarak ortalama hesaplandığı için negatif değerler pozitif değerleri sönümler. Bu şekilde daha doğru performans ölçümü gerçekleştirilebilir.

4.3.2. Ortalama hata kareleri

Mean Squared Error ingilizce ifadesinin kısaltması olarak kullanılan MSE performans metriği de yaygın olarak kullanılmaktadır. Tahmin ve gerçekleşen değerler arasındaki sapmaları anlamamıza yardımcı olur.

Yaklaşım olarak öncelikle her tahmin değeri ile gerçekleşen değer farkının karesi alınır. Daha sonra bu karelerin ortalaması hesaplanarak ortalama hata kareleri hesaplanmış olur.

MSE metriğini kullanmanın bazı avantajları ve dezavantajları bulunmaktadır. Başlıca avantajlarından bir tanesi artıkların kareleri alınması sebebi ile pozitif ve negatif hatalar dengeli bir şekilde değerlendirilebilir. Yine kareler alındığı için büyük hatalar daha fazla vurgulanır ve aykırı değerler de daha fazla ön plana çıkar. Bunların yanı sıra orijinal ölçüm birimi yerine karesel ölçekte sonuçlar ürettiğinde yorumlama aşamasında zorluklar yaşanabilir.

4.3.3. Ortalama mutlak yüzde hata

Ortalama mutlak yüzde hata metriği de yaygın olarak kullanılan bir metriktir. Genel olarak Mean Absolute Percentage Error ingilizce ifadesinin kısaltması olan MAPE ile temsil edilir. Temel amacı modelin gerçekleşen verilere ne kadar yakın tahmin edebildiğini yüzdesel olarak ölçmektir.

Bu metrik yaklaşımında öncelikle gerçekleşen değer ile tahmin edilen değer arasındaki mutlak yüzde hata hesaplanır. Daha sonra bu hesaplanan hataların ortalaması alınarak MAPE değeri elde edilir.

Ortalama mutlak yüzde hata değeri ne kadar düşükse modelin gerçekleşen değerlere o kadar yakın tahmin ettiği, tam tersi olarak da bu değer ne kadar yüksek ise gerçekleşen değerler ile tahmin edilen değerler arasındaki makasın açıldığı düşünülebilir. Sonuç olarak modelin doğruluğu ve güvenilirliğini ölçmek için MAPE önemli metriklerden bir tanesidir.

4.3.4. Karekök ortalama hata kare

Root Mean Squared Error ifadesinin kısaltması olarak kullanılan RMSE metriği, regresyon analizlerinde modellerin performansı değerlendirilebilmek için sıklıkla tercih edilmektedir.

Bu yaklaşımda gerçekleşen değerler ile tahmin edilen değerler arasındaki farkların kareleri hesaplanır. Daha sonra elde edilen bu karelerin ortalamasının karekökü hesaplanarak RMSE değeri elde edilir.

RMSE değerinin düşük olması gerçekleşen değerlere yakın tahminler yapıldığını ifade ederken, dolayısı ile modelin başarılı olduğu çıkarımı yapılabilir. RMSE değerinin yüksek olduğu durumlarda ise modelin tahmin başarısının daha düşük olduğu yorumu yapılabilir.

4.3.5. R kare

Bu metrik, modelin verilere ne kadar uyumlu olduğunu ifade etmektedir.

Bu yaklaşımda bağımlı değişkenler arasındaki varyans değerinin, modelin açıkladığı varyansa oranı hesaplanır. Bu sonuçlar 0 ve 1 arasında bir değer alır.

R Kare değeri ne kadar yüksek ise modelin verilere o kadar uyum sağlamak konusunda başarılı olduğu, 0'a yakın olduğu durumlarda ise modelin daha zayıf olduğu anlamına gelmektedir.


4.4. Hiperparametre Optimizasyonu

Hiperparametre optimizasyonu makine öğrenmesi modellerinde kullanılan hiper parametreler arasından en uygun değerleri bulmayı amaçlayan bir yöntemdir. Bu şekilde modelin performansının artırılmasının yanı sıra modelin genelleştirilebilir olması konusunda iyileşme hedeflenir.

Modelin genelleştirilebilir olması birçok açıdan önem taşır. Modelin validasyon seti üzerinde gösterdiği başarı kadar, daha önce görmediği veriler üzerinde de başarı göstermesi önemlidir. Bu şekilde gerçek dünya verileri üzerinde de modelin başarılı bir şekilde çalışabilme kapasitesini ifade eder.

Bu süreçte modelin aşırı uydurma ve aşırı basitleştirme problemlerine engel olacak şekilde hiperparametrelerin seçilmesi amaçlanır. Sonuç olarak modelin genelleme yeteneğini iyileştirilir.

Zaman ve kaynak yönetimi açısından incelendiğinde ise hiperparametre optimizasyonu verimliliğin artmasına katkı sağlar. En uygun hiperparametreler ile eğitilen modeller, daha az hesaplama gücü ve veri ile daha fazla performans ortaya koyabilir. Şekil 4.2’de hiperparametre optimizasyonu adımlarında çarpaz doğrulama süreci görülmektedir.



Şekil 4.2 : Hiperparametre optimizasyonu adımları gösterilmektedir.

Bu optimizasyon metodu çalışma kapsamında ele alınan tüm hedef değişkenler için uygulanmıştır.

4.4.1. Grid search algoritması

Hiperparametre optimizasyonu sürecinde yaygın olarak tercih edilen bu teknik, hiperparametrelerin en iyi kombinasyonunu bulmak için kullanılır. Modelin performansının ve genelleme yeteneğinin artırılması hedeflenmektedir.

Bu yaklaşım ile belirlenmiş bir hiperparametre seti üzerinde tüm kombinasyonlar denenerek modelin başarısını artıran en iyi hiperparametreler tespit edilir.

Grid search yaklaşımında aşağıdaki adımlar takip edilir;

- Parametre uzayı: Belirlenen hiperparametrelerin olası değerleri ayrı ayrı kombinasyonlarından parametre uzayı oluşturulur.
- Parametre uzayının keşfi: Tüm kombinasyonlar denenir.
- Performans karşılaştırması: Seçilen performans metriği üzerinden tüm kombinasyonların model performansı karşılaştırılır.
- Otomatik hiperparametre ayarı: Tüm olası kombinasyonlar denenerek en iyi hiperparametreler belirlenir.

Grid search çoğunluk ile çarpaz doğrulama yöntemi ile kullanılarak modelin gerçek başarısının doğru bir şekilde tespit edilmesi değerlendirilmesi amaçlanır.

4.4.2. Çarpaz doğrulama

Çarpaz doğrulama modelin performansını güvenilir ve doğru bir şekilde değerlendirebilmek, modelin genelleme yeteneğini artırmak ve aşırı uydurma gibi problemleri ortadan kaldırmak amacı ile kullanılan yaygın hiperparametre optimizasyonu tekniklerinden bir tanesidir.

Çarpaz doğrulama temel olarak rastgele olarak ayrılmış alt grupların üzerinde model performansının ölçülmesi ve değerlendirilmesi ilkesine dayanır.

Çarpaz doğrulama süreci işletilirken genel olarak aşağıdaki adımlar uygulanır;

- Veri setinin rastgele alt gruplara ayrılması
- Her alt grubun kendi içinde test ve eğitim kümesi olarak işaretlenmesi
- Modelin eğitim seti üzerinde eğitilip, test seti üzerinde performansının değerlendirilmesi
- Her alt grubun en az 1 kez test seti olarak kullanılması
- Seçilen K sayısı kadar işlemin tekrar edilmesi
- Sonuçların ortalaması alınarak modelin performansının ölçülmesi

Çarpaz doğrulama yöntemi genellikle Grid search algoritması ile birlikte kullanılır. Her bir hiperparametre kombinasyonu performansı çarpaz doğrulama ile kontrol edilir.

Bu şekilde modelin performansı artırılırken, aşırı uyum ya da aşırı basitleştirme problemleri göz önünde bulundurularak daha stabil ve genelleme yeteneği yüksek sonuçlar elde edilir.





5. BULGULAR VE TARTIŞMA

Modelleme bölümünde daha önce data seti ve metodoloji bölümlerinde bahsedilen yaklaşımların uygulamaları anlatılacaktır. Blok süre tahmini için dört farklı yaklaşım ele alınmıştır. Öncelikle blok süre bir bütün olarak regresyon problemi olarak değerlendirilmiş ve geçmiş verilerden öğrenerek ileri dönük tahminleri gerçekleştirilmiştir.

İkinci yaklaşımda blok sürenin alt bileşenleri olan uçuş süresi, taksi kalkış süresi ve taksi varış süreleri de ayrı ayrı modellenmiştir. Blok sürenin alt bileşenlerinden elde edilen tahminlerin toplamı hesaplanarak toplam blok süre tahmini elde edilmiştir.

Üçüncü yaklaşımda geçmişe dönük gerçekleşen blok süreler kalkış yeri, varış yeri ve ay değişkenlerine göre gruplanarak medyan değeri alınarak, bütünsel blok süre medyanı elde edilmiştir.

Son yaklaşımda ise blok sürenin alt bileşenleri uçuş süresi ve taksi süreleri yukarıda bahsedildiği gibi kalkış yeri, varış yeri ve ay bazında gruplanarak tüm bileşenler için ayrı ayrı medyan değerleri hesaplanmıştır. Nihai olarak uçuş süre medyanı, taksi kalkış süresi medyanı ve taksi varış süresi medyanı elde edilmiştir. Tüm bu alt bileşenlerin toplamı olarak toplam blok süre medyanı hesaplanmıştır.

Amerika Birleşik Devletleri Ulaştırma Bakanlığı tarafından sağlanan Ulaştırma İstatistikleri Bürosu (BTS) veri tabanından elde edilen uçuş performansı verileri ve Azure platformu üzerinden elde edilen hava durumu dataları birleştirilerek modellemede kullanılacak nihai veri seti hazırlanmıştır.

Data seti üzerinde gerekli filtrelemeler ve analizler gerçekleştirilmiş. Veri ön işleme adımı olarak eksik değer, uç değer analizleri, veri doldurma ihtiyaçları yönelik gerekli aksiyonlar alınmıştır. Çalışma dahilinde iptal edilen ya da yönlendirme yapılan seferler göz ardı edilerek, sadece varışı gerçekleştirmiş uçuşlara odaklanılmıştır.

Yayınlanan raporlar ve veri analizleri kapsamında on time performans konusunda en fazla sapmaya sahip olan Florida eyaleti seçilmiştir. Bu filtreye ek olarak planlanan

blok süre ve gerçekleşen blok süre arasında 20 dakikadan fazla fark olan uçuşlar çalışma kapsamında dahil edilmiştir. Bu şekilde çalışmada en problemlili kitle seçilerek daha anlamlı ve katma değeri yüksek bir sonuç elde etmek amaçlanmıştır.

Veri seti 2021 Ocak ayından 2023 Haziran ayına kadar olan dönemi kapsamaktadır. 2021-2023 arası eğitim veri seti, 2023 ilk üç ayı validasyon veri seti, son üç ayı ise test veri seti olarak üç bölüme ayrılmıştır.

Yukarıda bahsedilen blok süre, uçuş süresi ve taksi süreleri için daha önce özellik seçme adımında bahsedilen pearson korelasyonu, ısı haritası analizleri yapılmıştır. Ek olarak kurulan ön modeller olan en küçük kareler ve karar ağacı algoritmaları ile en önemli değişkenler ve bu değişkenlerin anlamlılıkları ve modeli açıklamada ne kadar başarılı olduğu tespit edilmiştir.

Modelleme aşamasında tahmin edilmek istenen tüm hedef değişkenler sürekli bir değere sahip olduğu için regresyon modelleri üzerinde durulmuştur. Bu bağlamda Lineer Regresyon, Lasso, Ridge, Elastic Net, Random Forest, Bagging ve XG Boost regresyon modelleri tercih edilmiştir.

Bahsi geçen tüm modeller ve tüm regresyon tekniklerinde modellere ilk aşamada default parametreler ile uygulanmıştır. Elde edilen sonuçlar grid search ve çarpaz doğrulama yöntemleri ile eğitilerek tekrar çalıştırılmıştır. Çarpaz doğrulama kapsamında 5-katlı doğrulama modele uygulanmıştır.

Modelleri optimize etmek amacı ile uygulanan Grid search çarpaz doğrulama metodu için değerlendirme metriği olarak sapmaların ne kadar olduğunu daha iyi analiz edebilmek adına ortalama mutlak hata metriği seçilmiştir.

Buradan elde edilen sonuçlar yardımı ile hem en iyi modellerin tespiti sağlanmış hem de en iyi parametreler keşfedilmiştir.

En iyi parametreler ile tercih edilen en iyi model validasyon setinde tekrar eğitilerek model sisteme kaydedilmiştir. Daha sonra kayıt edilen bu model, test veri seti üzerinde tekrar çalıştırılmıştır.

Optimize edilmiş model sonucu ve modelin daha önce hiç görmediği test veri seti üzerinde çalıştırılan model sonuçları karşılaştırılmıştır. Overfit gibi aşırı uyum ve underfit gibi aşırı basitleştirme problemleri ve modelin genellenebilir olup olmadığı araştırılmıştır.


Bütünsel blok süre tahmini, parçalı blok süre toplamı tahmini, geçmişe dönük gerçekleşen bütünsel blok süre medyanı, taksi süreleri ve uçuş süresinden elde edilen medyanların toplamından oluşan parçalı blok süre medyanı ve ilgili uçuş için daha önce planlanan blok süre sonuçları karşılaştırması yapılmıştır.

Özellik seçimi adımımda ilk data setinde türetilen değişkenler ile birlikte yaklaşık 61 adet değişken bulunmaktaydı. Bu bağımsız değişkenlerin bir kısmında hedef değişkeni açıklama oranı düşük iken bir kısmında ise çoklu doğrusal bağlantı bulunmaktaydı. Bu ilişkilerin yönü, şiddeti veya herhangi bir ilişki olup olmadığı konusunda bazı özellik seçme yöntemleri kullanılmıştır.

Şekil 5.1’ de blok süre için pearson korelasyon katsayıları gösterilmektedir. Bu korelasyon yaklaşımında değişkenler arasındaki ilişkinin yönü ve şiddeti ölçülmektedir. Bu bağlamda uçuş süresi, uzaklık kategorisi, maksimum sıcaklık ve yağış gibi faktörlerin öne çıktığı görülmektedir.




39



Şekil 5.2 : Tüm değişkenler için ısı haritası sonuçları gösterilmektedir.

Şekil 5.3'te taksi kalkış süresi için karar ağacı algoritmasındaki ‘feature_importance’ metodu ile değişkenlerin önem dereceleri sıralanmıştır.



Şekil 5.3 : Taksi kalkış için karar ağacı önem derecesi sonuçları gösterilmektedir.

Bu özellik seçimi adımları çalışma kapsamında ele alınan tüm hedef değişkenler için uygulanmıştır.

5.2. Modeller

Bu adımda blok süre ve blok sürenin alt kırımları olan taksi kalkış süresi, taksi varış süresi ve uçuş süresi için gerçekleştirilen modelleme süreçleri anlatılacaktır. İlk adım olarak kurulan ham modelin değerlendirmelerinin ardından, bir önceki bölümde aktarılan hiperparametre optimizasyonu yöntemleri tekrar inşa edilmiş olan optimize model sonuçları paylaşılacaktır.

5.2.1. Blok süre tahmini

Havacılık endüstrisinde blok süre uçağın pistte hareketine başladığı ilk andan, uçuşu tamamlayarak pistte tekrar park pozisyonuna geçtiği toplam süreyi ifade etmektedir. Bu çalışma kapsamında çeşitli makine öğrenmesi yöntemleri ile blok süre tahmin edilmiştir. Blok süre sürekli bir değişken olduğu için regresyon modelleri tercih edilmiştir.

Girdi olarak geçmişe dönük taşıyıcı firma, uçuş ve tarihsel alanların birleştirilmesi ile oluşan yeni özellik üzerinden gruplanarak geçmişe dönük alınan medyan değerleri önemli olduğu tespit edilerek bu veriler kullanılmıştır. Ek olarak uzaklık ve dönem bilgisinin de önemli olduğu görülmüştür. Özellik seçme adımında tespit edilen hava durumu verileri de eklenmiştir. Son olarak türetilen diğer bir özellik olan kalış ve varış eyaletlerine ilişkin en önemli çiftler de modelde yer almıştır.

Ham model

İlk olarak default parametreler yardımı ile ham model kurulumu gerçekleştirilmiştir. Çizelge 5.1’de blok süre tahmin modellerinin sonuçları görülmektedir. R Kare metriğine bakıldığında genel olarak hepsinin yakın sonuçlar verdiğini ancak XG Boost algoritmasının 0.96 ile bir rakiplerinin bir adım gerisinde kaldığı görülmektedir. Ortalama mutlak hata ve ortalama mutlak yüzdesel hata metrikleri üzerinden kontrol edildiğinde ise Lasso algoritması en iyi sonucu elde edilmiştir. RMSE değeri ise en düşük değeri Lineer regresyon ve Elastic Net modellerinde sağlamıştır.

Çizelge 5.1 : Blok süre için ham model sonuçları gösterilmektedir. Blok süre için ham model sonuçları gösterilmektedir.

MODEL	MAE	MSE	RMSE	R Kare	MAPE
Linear Reg.	4.48	117.13	10.82	0.97	2.34
Lasso	4.23	117.45	10.84	0.97	2.23
Ridge	4.41	117.27	10.83	0.97	2.31
Elastic Net	4.48	117.13	10.82	0.97	2.34

Bagging	5.59	129.35	11.37	0.96	2.89
Random Forest	4.71	118.59	10.89	0.97	2.44
XG Boost	5.60	132.08	11.49	0.96	2.88

Optimize model

Modelleri optimize etmek için uygulanan grid search 5 katlı çarpraz doğrulama sonuçları Çizelge 5.2.'de gösterilmektedir. Bu çizelge sonuçlarına göre belirlenen performans metriği olan ortalama mutlak hata üzerinden kontrol sağlandığında en iyi sonucun 4.38 değeri ile Elastic Net algoritmasından elde edildiği görülmektedir. Bu sonuca ulaşmak için kullanılan en iyi parametreler ise $\alpha=0.1$ ve $l1_ratio=0.1$ olduğu görülmektedir.

Çizelge 5.2 : Grid search sonrası blok süre için en iyi model ve parametreler gösterilmektedir.

Model	MAE	En iyi parametreler
Linear Reg.	4.77	normalize=True
Lasso	4.77	$\alpha=10.0$
Ridge	4.39	$\alpha=0.1$
Elastic Net	4.38	$\alpha=0.1 \mid l1_ratio=0.1$
Bagging	5.04	n_estimators=30
Random Forest	6.05	max_depth=5,n_estimators=200
XG Boost	5.32	learning_rate=0.1,max_depth=5

Çizelge 5.3'te ise en iyi performansa sahip Elastic Net algoritmasının optimize edilmeden önceki ve sonraki durumları görülebilmektedir. Grafik analiz edildiğinde modelin hiperparametre optimizasyonu sonrasında tüm değerlendirme metriklerinde iyileşme olduğu gözlemlenmektedir.

Çizelge 5.3 : Blok süre için optimizasyon sonrası model sonuçları gösterilmektedir.

MODEL	MAE	MSE	RMSE	R Kare	MAPE
Elasticnet	4.41	117.27	10.83	0.97	2.31
Elasticnet Tuned	4.38	117.25	10.83	0.97	2.30

Çizelge 5.4' te eğitim veri seti üzerinde valide edilerek en iyi model ve en iyi parametreler ile inşa edilmiş Elastic Net algoritmasının test veri seti üzerinde uygulanmasından elde edilen sonuçları görülmektedir. İlgili tabloda hem kurulan ilk

model hem optimize edilmiş model hem de test seti üzerinde uygulanmış model sonuçları bulunmaktadır.

Çizelge 5.4 : Blok süre için test seti model sonuçları gösterilmektedir.

MODEL	MAE	MSE	RMSE	R Kare	MAPE
Elastic Net	4.41	117.27	10.83	0.97	2.31
Elastic Net Tuned	4.38	117.25	10.83	0.97	2.30
Elastic Net Test	6.15	192.97	13.89	0.95	3.15

Test veri seti modelin daha önce görmediği datalardan oluşması modelin genelleme performansını doğru değerlendirebilmek adına büyük önem taşımaktadır. Sonuçlar analiz edildiğinde metriklerde bir miktar azalma olmakla birlikte modelin genelleme başarısının iyi olduğu gözlemlenmiştir. MAE değeri 4.41'den 6.15'e çıkmaktadır. R kare değeri ise 0.97'den 0.95'e inmiştir.

5.2.2. Taksi kalkış süresi tahmini

Havacılık endüstrisinde taksi kalkış süresi uçağın park yerinden hareketine başladığı ilk andan tekerlerin yerden kesildiği kalkış anına kadar pistte hareketli geçirdiği süreyi ifade eder. Bu bölümde farklı regresyon modelleri ile taksi kalkış süresi tahmin edilmiştir. Taksi kalkış süresinin hedef değişkeni de sürekli bir değer olduğu için regresyon modelleri tercih edilmiştir.

Girdi olarak geçmişe dönük taşıyıcı firma, uçuş ve tarihsel alanların birleştirilmesi ile oluşan yeni özellik üzerinden gruplanarak geçmişe dönük alınan medyan değerleri önemli olduğu tespit edilerek bu veriler modelde kullanılmıştır. Ek olarak uzaklık ve dönem bilgisi de önemli olmuştur. Özellik seçme adımında tespit edilen hava durumu verileri de eklenmiştir. Son olarak türetilen diğer bir özellik olan kalış ve varış eyaletlerine ilişkin en önemli çiftler de modelde yer almıştır.

Ham model

İlk olarak default parametreler yardımı ile ham model kurulumu gerçekleştirilmiştir. Çizelge 5.5'te taksi kalkış süresi tahmin modellerinin sonuçları görülmektedir. MAE sonuçları incelendiğinde Lineer regresyon, lasso ve elastic net modellerinin benzer

performans göstererek 3.12 değerine ulaştığı görülmektedir. R kare olarak tüm modeller 0.88 ile aynı sonucu alırken, XG Boost daha geride kalarak 0.86 değerine ulaştığı anlaşılmaktadır. MAPE metriğinde ise en iyi performansı 12.27 ile lasso modeli elde etmiştir.

Çizelge 5.5 : Taksi kalkış süresi için ham model sonuçları gösterilmektedir.

MODEL	MAE	MSE	RMSE	R Kare	MAPE
Linear Reg.	3.12	59.93	7.74	0.88	12.58
Lasso	3.12	60.02	7.75	0.88	12.27
Ridge	3.16	60.09	7.75	0.88	12.44
Elastic Net	3.12	59.93	7.74	0.88	12.58
Bagging	4.23	70.34	8.39	0.86	16.52
Random Forest	3.66	64.14	8.01	0.88	14.79
XG Boost	4.39	69.95	8.36	0.86	17.95

Optimize model

Modelleri optimize etmek için uygulanan grid search 5 katlı doğrulama sonuçları Çizelge 5.6.'da gösterilmektedir. Bu çizelge sonuçlarına göre belirlenen performans metriği olan ortalama mutlak hata üzerinden kontrol sağlandığında en iyi sonucun 3.09 değeri ile Lasso algoritmasından elde edildiği görülmektedir. Bu sonuca ulaşmak için kullanılan en iyi parametre olarak alpha=10 değerinin olduğu görülmektedir.

Çizelge 5.6 : Grid search sonrası taksi kalkış için en iyi model ve parametreler gösterilmektedir.

Model	MAE	En iyi parametreler
Linear Reg.	3.11	normalize=True
Lasso	3.090	alpha=10.0
Ridge	3.11	alpha=0.1
Elastic Net	3.095	alpha=0.1 l1_ratio=0.1
Bagging	4.92	n_estimators=30
Random Forest	3.95	max_depth=10,n_estimators=200
XG Boost	3.87	learning_rate=0.1,max_depth=10

Çizelge 5.7'de ise en iyi performansa sahip Lasso algoritmasının optimize edilmeden önceki ve sonraki durumları görülebilmektedir. Grafik analiz edildiğinde modelin hiperparametre optimizasyonu sonrasında R kare hariç tüm değerlendirme metriklerinde iyileşme olduğu gözlemlenmektedir. R kare değeri ise 0.88 olarak sabit kalmıştır.

Çizelge 5.7 : Taksi kalkış süresi için optimizasyon sonrası model sonuçları gösterilmektedir.

MODEL	MAE	MSE	RMSE	R Kare	MAPE
Lasso	3.12	60.02	7.75	0.88	12.27
Lasso Tuned	3.09	59.91	7.74	0.88	12.18

Çizelge 5.8’ de eğitim veri seti üzerinde valide edilerek en iyi model ve en iyi parametreler ile inşa edilmiş Lasso algoritmasının test veri seti üzerinde uygulanmasından elde edilen sonuçlar görülmektedir. İlgili tabloda hem kurulan ilk model hem optimize edilmiş model hem de test seti üzerinde uygulanmış model sonuçları bulunmaktadır.

Çizelge 5.8 : Taksi kalkış süresi için ham model sonuçları gösterilmektedir.

MODEL	MAE	MSE	RMSE	R Kare	MAPE
Lasso	3.12	60.02	7.75	0.88	12.27
Lasso Tuned	3.09	59.91	7.74	0.88	12.18
Lasso Test	4.44	112.32	10.60	0.81	17.43

Sonuçlar kontrol edildiğinde metriklerde bir miktar azalma olmakla birlikte modelin genelleme başarısının iyi olduğu gözlemlenmiştir. MAE değeri 3.09’dan 4.44’e çıkmaktadır. R kare değeri ise 0.88’den 0.81’e inmiştir.

5.2.3. Taksi varış süresi tahmini

Havacılık endüstrisinde taksi varış süresi uçağın iniş yaptıktan sonra park yerine gidip motorların kapatılmasına kadar pistte hareketli geçirdiği süreyi ifade etmektedir. Bu çalışma ile daha önce bahsedilen analitik yöntemler ile taksi geliş süresi tahmin edilmiştir. Taksi varış süresi sürekli bir değişken olduğu için regresyon modelleri tercih edilmiştir.

Girdi olarak geçmişe dönük taşıyıcı firma, uçuş ve tarihsel alanların birleştirilmesi ile oluşan yeni özellik üzerinden gruplanarak geçmişe dönük alınan medyan değerleri önemli olduğu tespit edilerek bu veriler kullanılmıştır. Ek olarak uzaklık ve dönem bilgisi de önemli olmuştur. Özellik seçme adımında tespit edilen hava durumu verileri de eklenmiştir. Son olarak türetilen diğer bir özellik olan kalış ve varış eyaletlerine ilişkin en önemli çiftler de modelde yer almıştır.

Ham model

İlk olarak default parametreler yardımı ile ham model kurulumu gerçekleştirilmiştir. Çizelge 5.9’de gelen taksi varış süresi tahmin modellerinin sonuçları görülmektedir. MAE metriğine göre en iyi sonuç Lasso modelinden sağlanmıştır. R kare olarak Bagging, RF ve XGB algoritmaları diğer modeller ile kıyaslandığında geride kalmıştır. MAPE metriğinin performans sonuçlarına göre yine en iyi sonuç Lasso modelinden elde edilmiştir.

Çizelge 5.9 : Taksi varış süresi için ham model sonuçları gösterilmektedir.

MODEL	MAE	MSE	RMSE	R Kare	MAPE
Linear Reg.	1.94	28.98	5.38	0.88	18.42
Lasso	1.91	29.02	5.39	0.88	17.42
Ridge	1.95	29.07	5.39	0.88	17.93
Elastic Net	1.94	28.98	5.38	0.88	18.42
Bagging	2.82	35.02	5.92	0.86	28.52
Random Forest	2.48	31.96	5.65	0.87	26.22
XG Boost	3.12	36.37	6.03	0.85	32.85

Optimize model

Modelleri optimize etmek için uygulanan grid search 5 katlı doğrulama sonuçları Çizelge 5.10.’da gösterilmektedir. Bu çizelge sonuçlarına göre belirlenen performans metriği olan ortalama mutlak hata üzerinden kontrol sağlandığında en iyi sonucun 1.88 değeri ile Lasso algoritmasından elde edildiği görülmektedir. Bu sonuca ulaşmak için kullanılan en iyi parametrenin ise $\alpha=10$ olduğu görülmektedir.

Çizelge 5.10 : Grid search sonrası taksi varış için en iyi model ve parametreler gösterilmektedir.

Model	MAE	En iyi parametreler
Linear Reg.	1.936	normalize=True
Lasso	1.886	$\alpha=10.0$
Ridge	1.935	$\alpha=0.1$
Elastic Net	1.904	$\alpha=0.1$ $l1_ratio=0.1$
Bagging	2.615	n_estimators=30
Random Forest	3.782	max_depth=10,n_estimators=200
XG Boost	2.755	learning_rate=0.1,max_depth=10

Çizelge 5.11’de ise en iyi performansa sahip Lasso algoritmasının optimize edilmeden önceki ve sonraki durumları görülebilmektedir. Grafik analiz edildiğinde modelin

hiperparametre optimizasyonu sonrasında tüm değerlendirme metriklerinde iyileşme olduğu gözlemlenmektedir.

Çizelge 5.11 : Taksi varış süresi için optimizasyon sonrası model sonuçları gösterilmektedir.

MODEL	MAE	MSE	RMSE	R Kare	MAPE
Lasso	1.91	29.02	5.39	0.88	17.42
Lasso Tuned	1.89	28.98	5.38	0.88	17.16

Çizelge 5.12’ de eğitim veri seti üzerinde valide edilerek en iyi model ve en iyi parametreler ile inşa edilmiş Lasso algoritmasının test veri seti üzerinde uygulanmasından elde edilen sonuçlar görülmektedir. İlgili tabloda hem kurulan ilk model hem optimize edilmiş model hem de test seti üzerinde uygulanmış model sonuçları bulunmaktadır.

Çizelge 5.12 : Taksi varış süresi için ham model sonuçları gösterilmektedir.

MODEL	MAE	MSE	RMSE	R Kare	MAPE
Lasso	1.91	29.02	5.39	0.88	17.42
Lasso Tuned	1.89	28.98	5.38	0.88	17.16
Lasso Test	2.87	59.71	7.73	0.82	26.26

Test veri seti modelin daha önce görmediği datalardan oluşması modelin genelleme performansını doğru değerlendirebilmek adına büyük önem taşımaktadır. Sonuçlar analiz edildiğinde metriklerde bir miktar azalma olmakla birlikte modelin genelleme başarısının iyi olduğu gözlemlenmiştir. MAE değeri 1.89’dan 2.87’ye çıkmaktadır. R kare değeri ise 0.88’den 0.82’e inmiştir.

5.2.4. Uçuş süresi tahmini

Havacılık endüstrisinde uçuş süresi uçağın pistten teker kestiği kalkış anından piste tekrar tekerlerin değdiği iniş anına kadar havada seyir halinde olduğu süreyi ifade etmektedir. Bu çalışmada da regresyon yöntemleri ile uçuş süresi tahmin edilmiştir. Uçuş süresi sürekli bir değişken olduğu için regresyon modelleri tercih edilmiştir.

Girdi olarak geçmişe dönük taşıyıcı firma, uçuş ve tarihsel alanların birleştirilmesi ile oluşan yeni özellik üzerinden gruplanarak geçmişe dönük alınan medyan değerleri önemli olduğu tespit edilerek bu veriler kullanılmıştır. Ek olarak uzaklık ve dönem bilgisi de önemli olmuştur. Özellik seçme adımında tespit edilen hava durumu verileri de eklenmiştir. Son olarak türetilen diğer bir özellik olan kalış ve varış eyaletlerine ilişkin en önemli çiftler de modelde yer almıştır.

Ham model

İlk olarak default parametreler yardımı ile ham model kurulumu gerçekleştirilmiştir. Çizelge 5.13'te uçuş süresi tahmin modellerinin sonuçları görülmektedir. R Kare metriğine bakıldığında tüm modellerin 0.98 ile aynı sonucu verdiği görülmektedir. MAE metriği üzerinde kontrol sağlandığından en iyi sonuç 2.96 ile lasso modeline ait olduğu saptanmaktadır. RMSE değeri de en iyi sonucu 7.34 ile lasso modelinde alırken, 7.35 değeri ile lineer regresyon ve elastic net modelleri performans rekabetinde takip etmektedir.

Çizelge 5.13 : Uçuş süresi için ham model sonuçları gösterilmektedir.

MODEL	MAE	MSE	RMSE	R Kare	MAPE
Linear Reg.	3.33	54.04	7.35	0.98	2.24
Lasso	2.96	53.88	7.34	0.98	1.98
Ridge	2.79	54.12	7.36	0.98	1.87
Elastic Net	3.33	54.04	7.35	0.98	2.24
Bagging	4.02	59.77	7.73	0.98	2.79
Random Forest	3.55	54.50	7.38	0.98	2.47
XG Boost	4.28	69.11	8.31	0.98	2.89

Optimize model

Modelleri optimize etmek için uygulanan grid search 5 katlı doğrulama sonuçları Çizelge 5.14.'te gösterilmektedir. Bu çizelge sonuçlarına göre belirlenen performans metriği olan ortalama mutlak hata üzerinden kontrol sağlandığında en iyi sonucun 3.16 değeri ile Elastic Net algoritmasından elde edildiği görülmektedir. Bu sonuca ulaşmak için kullanılan en iyi parametreler ise $\alpha=0.1$ ve $l1_ratio=0.1$ olduğu görülmektedir.

Çizelge 5.14 : Grid search sonrası uçuş süresi için en iyi model ve parametreler gösterilmektedir.

Model	MAE	En iyi parametreler
Linear Reg.	3.32	normalize=True
Lasso	3.23	$\alpha=10.0$
Ridge	3.25	$\alpha=0.1$
Elastic Net	3.16	$\alpha=0.1$ $l1_ratio=0.1$
Bagging	3.72	n_estimators=30
Random Forest	5.52	max_depth=10,n_estimators=200
XG Boost	4.30	learning_rate=0.2,max_depth=5

Çizelge 5.15'te ise en iyi performansa sahip Elastic Net algoritmasının optimize edilmeden önceki ve sonraki durumları görülebilmektedir. Grafik analiz edildiğinde

modelin hiperparametre optimizasyonu sonrasında tüm değerlendirme metriklerinde iyileşme olduğu gözlemlenmektedir.

Çizelge 5.15: Uçuş süresi için optimizasyon sonrası model sonuçları gösterilmektedir.

MODEL	MAE	MSE	RMSE	R Kare	MAPE
Elasticnet	3.33	54.04	7.35	0.98	2.24
Elasticnet Tuned	3.17	53.98	7.35	0.98	2.12

Çizelge 2.16’ te eğitim veri seti üzerinde valide edilerek en iyi model ve en iyi parametreler ile inşa edilmiş Elastic Net algoritmasının test veri seti üzerinde uygulanmasından elde edilen sonuçlar görülmektedir. İlgili tabloda hem kurulan ilk model hem optimize edilmiş model hem de test seti üzerinde uygulanmış model sonuçları bulunmaktadır.

Çizelge 5.16: Uçuş süresi için test seti model sonuçları gösterilmektedir.

MODEL	MAE	MSE	RMSE	R Kare	MAPE
Elastic Net	3.24	54.13	7.36	0.98	2.16
Elastic Net Tuned	3.17	53.98	7.35	0.98	2.12
Elastic Net Test	4.59	95.49	9.77	0.97	3.15

Test veri seti modelin daha önce görmediği datalardan oluşması modelin genelleme performansını doğru değerlendirebilmek adına büyük önem taşımaktadır. Sonuçlar analiz edildiğinde metriklerde bir miktar azalma olmakla birlikte modelin genelleme başarısının iyi olduğu gözlemlenmiştir. MAE değeri 3.17’den 4.59’a çıkmaktadır. R kare değeri ise 0.98’den 0.97’e inmiştir.

5.3. Model Sonuçları Karşılaştırma

Bu bölümde daha önce modelleme adımında elde edilen sonuçlar, geçmişe dönük ortalanca değer ve planlanan blok süre sonuçları ve bu sonuçların değerlendirilmesi yapılacaktır. Bu kapsamda ilk olarak blok süre model sonuçları karşılaştırması, ikinci aşamada ise alt kategori karşılaştırmaları sunulacaktır. Çizelge 6.1’de elde edilen model sonuçları yer almaktadır.

Çizelge 5.17: Model sonuçlarının karşılaştırması gösterilmektedir.

MODEL	MAE	MSE	RMSE	R Kare	MAPE
Planlanan ve Gerçekleşen Blok Süre	36.65	1711.67	41.37	0.48	23.73
Gerçekleşen ve Tahminlenen Blok Süre	6.15	192.97	13.89	0.95	3.15
Gerçekleşen ve Parçalı Tahmin Toplamı Blok Süre	7.18	267.51	16.36	0.93	3.70
Gerçekleşen ve Medyan Toplamı Blok Süre	19.56	847.60	29.11	0.77	10.44
Gerçekleşen ve Parçalı Medyan Toplamı Blok Süre	23.28	1020.42	31.94	0.72	11.65

Çizelge 5.1’de ifade edilen parçalı tahmin toplamı; blok sürenin alt bileşenleri olan taksi kalkış süresi, uçuş süresi ve taksi varış sürelerine dair tahmin modellerinden elde edilen sonucu ifade etmektedir.

Parçalı medyan toplamı ifadesi ise aynı şekilde blok sürenin yukarıda bahsedilen alt bileşenlerinin ayrı ayrı geçmişe ait gerçekleşen medyan değerlerinin tespit edilip toplanması ile elde edilen sonucu ifade etmektedir.

Medyan hesaplamalarında geçmişe ait ilgili kalkış yeri, varış yeri ve ilgili ay bazında gruplama gerçekleştirilerek ortanca değer alınarak hesaplama yapılmıştır.

Planlanan blok süre ifadesi ise ilgili taşıyıcı firma tarafından öncesinde planladıkları blok süreyi göstermektedir.

Tüm karşılaştırma metrikleri modelin daha önce görmediği test seti üzerinde uygulanarak model sonuçları listelenmiştir.

Model sonuçları incelendiğinde taşıyıcı firma tarafından daha önce planlanan blok süre ile gerçekleşen blok süre arasında ciddi bir fark olduğu tüm metrik sonuçlarında açıkça görülmektedir. R kare değeri 0.41.37’de kalmakla beraber, mutlak ortalama hata değeri ise 36.65 gibi endüstride kabul edilebilecek değerin çok üstünde bir sapmaya sebep olmuştur. Ortalama karesel hata değeri ise diğer tüm metriklerde ciddi bir şekilde farklılaşarak en yüksek MSE olan 1711.67 değerini almıştır. RMSE değeri ise diğerleri ile karşılaştırıldığında 41.37 ile yine en yüksek sapmaya işaret etmektedir.

Bu kapsamda taşıyıcı firmalar tarafından planlama safhasında planlanan blok sürelerin gerçekleşen blok süreler ile ciddi oranda farklılaştığı anlaşılmaktadır. Bu durumun

zamanında performans açısından düşük performans sergilemeye, gecikmelere ve diğer negatif etkilere sebebiyet verebileceği görülmektedir. Bu problemi çözmek için planlama aşamasında daha başarılı yöntemler ile tahmin edilmesine duyulan ihtiyacı gözler önüne sermektedir. Bu çalışmada önceden blok sürelerin doğru tahmin edilmesi ihtiyacının giderilmesi ve zamanında performansa katkı sağlayacak şekilde makine öğrenmesi teknikleri ile daha doğru ve güvenilir planlama yapılmasına olanak sağlamaktır.

Tahmin edilen blok süre ve ayrı ayrı tahmin edilen alt bileşenlerin toplamı parçalı blok süre tahmin toplamı karşılaştırılması yapıldığında tüm metriklere odaklanıldığında bütünsel blok süre tahmini kalan metriklerin hepsinde daha başarılı sonuçlar vermiştir. Bu çalışma kapsamında özellikle dikkate aldığımız ortalama mutlak hata oranı ilk modelde 6.15 değerini alırken, toplam tahmin yaklaşımında 7.18 değerine çıkmaktadır. Bu değer planlanan süre MAE değeri olan 36.65 ile kıyaslandığında modelin tahmin başarısını gözler önüne sermektedir. Yine aynı şekilde MAPE değeri bütünsel yaklaşımda 3.15, diğer modelin 3.70 değeri ile kıyaslandığında daha başarılı bir sonuç vermektedir. MAPE değerinde de 192.97'den 267.51 ile en yüksek farklılaşmanın olduğu metriği yansıtmaktadır.

Bu bağlamda bütünsel yaklaşım ile tahmin edilen blok süre tahmini yaklaşımının, taksi kalkış, taksi varış ve uçuş sürelerin ayrı ayrı tahmin edilip toplam tahmin yaklaşımına kıyasla daha başarılı sonuçlar verdiği görülmektedir.

Geçmişe dönük gerçekleşen değerlerin planlama aşamasında kullanabilir olup olmadığı araştırmak için de medyan değerleri de analiz kapsamında çalışılmıştır. Burada da yine makine öğrenmesi tekniğinde olduğu gibi hem bütünsel hem de alt bileşenlerin toplamı olarak kıyaslama yapılmıştır. Taksi varış, taksi kalkış ve uçuş süresi için de ayrı ayrı gerçekleşen, tahmin edilen ve geçmişe dönük ortalamaların hesaplandığı alt bileşenler de Çizelge 5.1'de sunulmuştur.

Bu bağlamda toplam blok süre medyan değerinin, parçalı medyan değerlerinin toplamı ile karşılaştırıldığında her metrik biriminde daha başarılı sonuçlar verdiği görülmektedir. R Kare 0.77'den 0.72'ye düşmektedir. Ortalama mutlak hata değeri ise 19.56'dan 24.28'e çıkmaktadır. MAPE ve MSE değerleri de yine artmıştır.

Bu sonuçlara istinaden medyan değerleri kendi içinde kıyaslandığında bütünsel yaklaşım daha iyi sonuçlar verse de makine öğrenmesi teknikleri ile tahmin edilen

bütünsel tahmin ve parçalı tahmin toplamı yaklaşımlarının her ikisinin de çok geride kaldığı görülmektedir. R kare değerlerinin sırasıyla 0.95 ve 0.93'ten 0.77 ve 0.72 değerlerine düştüğü görülmektedir. Bu noktada da modelleme aşamasında bilgi artırımına katkı sağlamak için veri setine dahil edilen hava durumu, sezonsallık ve diğer türetilen değişkenler ile birlikte işletilen veri bilimi tekniklerinin modelin tahmin etme başarısını artırdığı görülmektedir.

Çizelge 6.2'de blok sürenin alt kategorileri olan uçuş ve taksi süreleri karşılaştırması verilmiştir. Çizelge 6.1'de elde edilen model sonuçları yer almaktadır.

Çizelge 5.18: Alt kategorilerin sonuçlarının karşılaştırması gösterilmektedir.

MODEL	MAE	MSE	RMSE	R Kare	MAPE
Gerçekleşen ve Tahminlenen Taksi Kalkış Süresi	4.44	112.32	10.60	0.81	17.43
Gerçekleşen ve Medyan Taksi Kalkış Süresi	13.73	487.13	22.07	0.16	46.08
Gerçekleşen ve Tahminlenen Taksi Varış Süresi	2.87	59.71	7.73	0.82	26.25
Gerçekleşen ve Medyan Taksi Varış Süresi	8.40	287.00	16.94	0.11	50.54
Gerçekleşen ve Tahminlenen Uçuş Süresi	4.59	95.49	9.77	0.97	3.15
Gerçekleşen ve Medyan Uçuş Süresi	12.45	343.84	18.54	0.90	8.24

Taksi kalkış süresi tahmin modeli ile geçmişe dönük gerçekleşen verilerin ortalaması kıyaslandığında tahmin modelinin çok daha başarılı sonuçlar verdiği görülmektedir. R kare değeri incelendiğinde 0.81'den 0.16'ya kadar düştüğü görülmektedir. Bu sonuç da sadece geçmiş datanın ileri dönük süreleri açıklamada başarısız olduğu görülmektedir. Modele eklenen hava durumu ve sezon bilgileri gibi bağımsız değişkenlerin de hedef değişkeni açıklamada önemli bir katkı sağladığı ifade edilebilir. MAE, MSE, MAPE ve RMSE değerlerinde de önemli derecede artışlar gözlemlenmiştir.

Taksi varış süresi incelendiğinde ise taksi kalkış sürelerinde olduğu gibi makine öğrenmesi tahmin modelinin medyan değerine göre tüm metriklerde ciddi oranda farklılaşarak daha başarılı olduğu gözlemlenmektedir. R Kare değerinin 0.82'den 0.11

gibi çok daha düşük değerlere geldiği görülmektedir. MSE değeri ise 59.71'den 287 değerine çıkmış, MAE ve MAPE değerlerinde de önemli artışlar gözlemlenmiştir. RMSE değeri ise 7.73'den 19.94'e kadar çıkmıştır.

Taksi süreleri için tahmin modellerinin daha başarılı olduğunun tespiti ile birlikte sadece geçmiş gerçekleşen taksi sürelerine dayanarak bu değişkenlerin geleceğe yönelik tahmin edilmesi konusunda çok başarılı olamadığı görülmektedir.

Son olarak uçuş süresi tahmini ve geçmişe dönük gerçekleşen uçuş sürelerinin medyan değeri incelenmiştir. Bu kıyaslama sonucunda da üstteki örneklere benzer şekilde uçuş süresi tahmin etme modelinin çok daha başarılı sonuçlar verdiği görülmektedir. R kare değeri 0.97'den 0.90'a düşmektedir. MAE değeri 4.59'dan 12.45'e çıkarken MAPE ve MSE değerlerinde de anlamlı artışlar söz konusudur.

Uçuş süresinin de ek özellikler ile desteklenerek ileriye yönelik tahminler için modelleme teknikleri ile zamanında performans açısından kayda değer farklılaşma elde edilebileceği gözlemlenmiştir.

Sonuç olarak bu çalışma kapsamında blok süre hem bütün olarak hem de alt bileşenleri olan uçuş, taksi kalkış ve varış süreleri ayrı ayrı modellenmiştir. Bunun yanı sıra geçmişe dönük gerçekleşen ortalamalar da aynı şekilde bütün olarak ve ayrı ayrı ele alınarak medyan hesaplamaları yapılmıştır. Alt bileşenlerin toplamı ve bütünsel blok süreler karşılaştırılmıştır. Alt bileşenler olan uçuş ve taksi süreleri de tahmin ve medyan hesaplamaları bazında kendi içinde de karşılaştırmaları yapılmıştır. Son olarak planlanan blok süre ve gerçekleşen blok süre de kıyaslama tablosunda eklenerek zamanında performans açısından taşıyıcı firmaların ne kadar başarılı planlama yaptığını gözlemleyebilmek amaçlanmıştır.

Tüm bu karşılaştırmalar sonucunda 0.95 R kare ve 6.15 mutlak yüzdesel hata oranı ile en başarılı sonuç bütünsel olarak tahmin edilen blok süre modeli ile elde edilmiştir. Model tüm değerlendirme metriklerinde en yüksek sonuçları elde etmiştir. Bu sonuçlar planlanan ve gerçekleşen blok süre metrik sonuçları olan 0.48 R kare ve 36.65 MAE değeri ile kıyaslandığında modelin hedef değişkeni açıklamada önemli bir katkı sağladığı görülmektedir. Bu modele en yakın rakip olan alt bileşenlerin tahminlerinin toplamı olan model olmak ile birlikte bu modelin sonuçları R Kare 0.93 ve MAE 7.18 ile diğer modeli takip etmektedir. Her iki medyan yaklaşımı da R kare olarak 0.70 değerlerinde sonuçlar üreterek tahmin modelinin gerisinde kalmıştır.



6. SONUÇ VE GELECEK ÇALIŞMALAR

Bu bölümde çalışma sonuçları ve gelecekte yapılabilecek olası çalışmalara dair değerlendirmeler yapılacaktır.

6.1. Sonuçlar

Bu çalışma kapsamında Amerika Birleşik Devletleri Ulaştırma Bakanlığı tarafından sağlanan BTS veri tabanındaki OTP verileri ve Azure platformu üzerinden elde edilen hava durumu dataaları birleştirilerek oluşturulan data seti üzerinde çalışılmıştır.

Ulaştırma istatistikleri bürosunda yayınlanan raporlar ve verinin analiz sonuçları incelenerek zamanında performans konusunda rakiplerinin gerisinde kaldığı keşfedilen Florida eyaletinde gerçekleşen uçuşlar seçilmiştir. Ek olarak planlanan ve gerçekleşen blok süre arasında 20 dakikadan fazla olan uçuşlar da ayrıca filtrelenerek zamanında performans konusunda gelişim alanı yüksek olan veri setine odaklanılmıştır. Bu şekilde çalışma sonuçlarının katma değerinin daha yüksek olması da hedeflenmiştir.

Ocak 2021'den Haziran 2023'e kadar olan dönem veri setinde çalışılmıştır. Ocak 2021'den Ocak 2023'e kadar olan periyot eğitim kümesi için seçilmiştir. 2023 yılının ilk üç ayı validasyon, son üç ayı ise test veri seti olarak ayrılmıştır.

Veri ön işleme adımında eksik değer, boş değer ve uç değer analizleri gerçekleştirilmiş ve gerekli aksiyonlar alınmıştır. Grafik ve çeşitli yöntemler ile veri analiz edilerek verilerin dağılımı ve birbirleri ile olan ilişkileri incelenmiştir.

Özellik mühendisliği adımında ise veri dönüşümleri yapılarak gerekli yerlerde nümerik, kategorik ve tarih formatına dönüştürme gerçekleştirilmiştir. Kategorik değişkenler one hot encoding yöntemi ile modele dahil edilmiştir. Bazı alanlar birleştirilerek modeldeki anlamlılık artırılmış, bazı gruplamalar yöntemi ile geçmişe dönük ortalamalar alınarak modeldeki açıklayıcılığına göre modele eklemeler yapılmıştır.

Metodoloji olarak blok süre hem bütünsel olarak makine öğrenmesi yöntemleri ile tahmin edilmiş, hem de blok sürenin alt kategorileri olan taksi kalkış süresi, uçuş süresi ve taksi varış süresi de aynı şekilde makine öğrenmesi teknikleri ile tahmin edilmiştir. Çalışma dahilinde tahmin edilmek istenen tüm hedef değişkenler sürekli bir değere sahip olduğu için denetimli öğrenme tekniklerinden regresyon modelleri üzerinde çalışılmıştır.

Kullanılan regresyon modelleri aşağıda belirtilmiştir.

- Lineer Regresyon
- Lasso Regresyon
- Ridge Regresyon
- Elastic Net Regresyon
- Bagging Regresyon
- Random Forest Regresyon
- XG Boost Regresyon

Tüm modeller default parametreler ile çalıştırıldıktan sonra hiperparametre optimizasyon uygulanmıştır. Hiperparametre optimizasyonu için grid search algoritması kullanılarak her model için ilgili parametre aralığı tanımlanmış, iyi model ve en iyi parametrelerin belirlenebilmesi için ilgili parametre uzayında çalıştırılmıştır. Grid search yöntemi ile birlikte 5 katlı çapraz doğrulama metodu da hiperparametre optimizasyonu kapsamında modellere uygulanarak modelin genelleme başarısı ve aşırı öğrenme ya da aşırı basitleştirme gibi olası problemlerin önüne geçmek hedeflenmiştir.

Modelin başarısının değerlendirilmesinde ise aşağıdaki metrikler kullanılmıştır.

- MAE: Mutlak Ortalama Hata
- MSE: Mutlak Karesel Hata
- MAPE: Mutlak Ortalama Yüzdesel Hata
- RMSE: Mutlak Karesel Hatanın Karekökü
- R Kare: R Kare Skor

Modelleme adımında blok süre tahmini ve taksi kalkış süresi tahmini, taksi varış süresi tahmini, uçuş süresi tahmini model sonuçları paylaşılmıştır. Hiperparametre optimizasyonu kapsamında grid search ve çarpaz doğrulama sonucunda optimize edilmiş model sonuçları validasyon seti üzerinde öncesi ve sonrası olarak karşılaştırmaları yapılmıştır. Optimize edilen model test veri seti üzerinde uygulanarak sonuçlar incelenmiştir.

Makine öğrenmesi yöntemleri ile tahmin edilen regresyon modellerinin yanı sıra, tüm hedef değişkenler için geçmişe dönük gerçekleşen medyan değerlerinin sonuçları da model sonuçları değerlendirme adımında değerlendirilmiştir. Bu kapsamda blok süre tahmini, blok sürenin alt kategorileri olan taksi kalkış süresi tahmini, taksi varış süresi tahmini ve uçuş süresi tahminlerinin toplamını ifade eden parçalı tahmin toplamı blok süre, geçmişe yönelik blok süre medyanı ve alt bileşenlerin medyan değerlerinin toplamını ifade eden parçalı medyan toplamı blok süre ve planlanan blok süre karşılaştırması Şekil 6.1’de gösterilmiştir.

Model	MAE	MSE	RMSE	R ² Skor	MAPE
Planlanan Blok Süre - Gerçekleşen Blok Süre	36.65	1711.67	41.37	0.48	23.73
Gerçekleşen Blok Süre - Tahminlenen Blok Süre	6.15	192.97	13.89	0.95	3.15
Gerçekleşen Blok Süre - Parçalı Tahmin Toplamı Blok Süre	7.18	267.51	16.36	0.93	3.70
Gerçekleşen Blok Süre - Medyan Toplamı Blok Süre	19.56	847.60	29.11	0.77	10.44
Gerçekleşen Blok Süre - Parçalı Medyan Toplamı Blok Süre	23.28	1020.42	31.94	0.72	11.65

Şekil 6.1: Model karşılaştırmalarının sonuçları gösterilmektedir.

Planlanan blok süre ve gerçekleşen blok süreler arasında değerlendirme yapıldığında ciddi miktarda sapma olduğu görülmektedir. R kare değeri 0.48’de kalırken, ortalama mutlak hata değeri ise 36.65 ile oldukça yüksek bir sapma göstermektedir. Bu durum taşıyıcı firmaların planlama aşamasında yanlışlıklar yaptığı için zamanında performans konusunda düşük performans göstermesini açıklamaktadır.

Bu çalışmanın amacı da ileriye yönelik blok sürelerin doğru tahmin edilmesi ile gecikmelerin önüne geçmek ve endüstride OTP olarak ifade edilen zamanında performans göstergelerini yukarı taşımaktır. Bu kapsamda çalışmada makine öğrenmesi yöntemleri ile blok sürelerin daha doğru ve daha güvenilir bir şekilde önceden tahmin edilerek planlama yapılması ve zamanında performansa katkı sağlamak hedeflenmiştir.

Çalışma sonuçları incelendiğinde bütünsel olarak ele alınan blok süre tahminin, taksi süreleri tahmini ve uçuş süresi tahmini toplamı ile karşılaştırıldığında ilk yaklaşımın daha iyi sonuç verdiği görülmektedir. 0.95 açıklanan varyans ve 6.15 mutlak ortalama hata ile blok süre tahmini modeli rakiplerini geride bırakmıştır. Alt bileşenlerin tahminlerinin toplamı ise R Kare 0.93 ve MAE 7.18 olarak gözlemlenmiştir.

Aynı şekilde geçmişe yönelik blok süre medyanı ve uçuş süresi medyanı, taksi kalkış ve varış medyan değerlerinin toplamı kıyaslandığında bütünsel blok sürenin daha iyi sonuç verdiği görülmekle birlikte makine öğrenmesi yöntemleri ile karşılaştırıldığında her iki medyan kıyaslaması 0.70 değerlerine düşerek önemli miktarda performans düşüklüğü göstermiştir. Model sonuçlarını değerlendirme adımında ayrıca taksi kalkış tahmin ve medyanı, taksi varış tahmin ve medyanı, uçuş süresi tahmin ve medyanı karşılaştırmaları tek tek yapılmış olup her alt bileşen için aynı şekilde tahmin modeli gerçekleşen değere daha yakın sonuçlar üreterek tüm metriklerde daha başarılı olmuştur. Özellikle taksi sürelerine dair yapılan tahminlerde önemli farklar gözlemlenmiştir. Taksi kalkış için tahmin ve medyan değerleri sırasıyla R kare değeri 0.81'den 0.16 ya düşmüş, MAE değeri ise 4.44'ten 13.73'e çıkmıştır. Taksi varış için tahmin ve medyan değerleri sırasıyla R kare değeri 0.82'den 0.11'e düşmüş, MAE değeri ise 2.87'den 8.40'a çıkmıştır.

Sonuç olarak bütünsel blok süre tahmin 0.95 açıklanan varyans ve 6.15 MAE değeri ile en iyi performansı gösteren model olmuştur. Bu model hem alt kategorilerin ayrı ayrı tahminlerinin toplamı modelinden hem geçmişe dönük gerçekleşen blok süre medyan değerinden hem de geçmişe dönük gerçekleşen alt bileşenlerin medyan toplamalarının karşılaştırmasından daha iyi performans göstermiştir.

Tahmin modeline eklenen hava durumu ve sezon durumu bilgilerinin yanı sıra eklenen diğer özniteliklerin ve kullanılan veri bilimi yöntemlerinin hedef değişkeni açıklamada daha başarılı olduğu ve makine öğrenmesi tahmin model sonuçlarının gerçekleşen değerlere çok daha yakın tahminler yapabildiğini göz önüne sermektedir.

Bu çalışmanın bulguları, havacılık sektöründe on time performansın artırılması ve operasyonel verimliliğin optimize edilmesi amacıyla blok süre tahmininin kritik bir öneme sahip olduğunu göstermektedir. Ayrıca, kullanılan veri kaynakları ve modelleme teknikleri, havacılık endüstrisinde verimliliği artırmak ve operasyonel süreçleri optimize etmek için potansiyel birer araç olarak öne çıkmaktadır. Bu çalışma,

havacılık sektöründeki paydaşlara, on time performansın artırılması için veri odaklı ve analitik bir yaklaşımın önemini vurgulamakta ve gelecekte yapılacak çalışmalar için bir temel oluşturmaktadır.

Bu çalışmanın sonuçları havacılık endüstrisinde çeşitli kullanım alanlarına sahiptir. Makine öğrenmesi teknikleri ile blok süre tahmin edilmesi sonucunda birçok alanda iyileşme sağlanabilir.

Bunların başında uçuş planlama süreçleri gelmektedir. Blok süre tahminleri uçuş programları oluşturulurken kullanılarak kalkış ve varış süreleri ve diğer planlamalarda katkı sağlayacaktır.

Müşteri memnuniyeti açısından incelendiğinde ise özellikle aktarmalı uçuş gerçekleştiren yolcular açısından zamanında varmak en önemli kriterlerden bir tanesidir. Daha doğru ve güvenilir tahminler ile müşteri memnuniyeti artırılabilir.

Maliyet açısından değerlendirildiğinde ise doğru blok süre tahmin edilmesi ile yakıt tüketimi ve personel planlamaları açısından da güvenilir ve başarılı ileri dönük tahminler önem arz etmektedir.

6.2. Gelecek Çalışmalar

Bu çalışma kapsamında makine öğrenmesi teknikleri kullanılmıştır. Gelecek çalışmalarda derin öğrenme teknikleri kullanılarak daha kompleks ilişkilerin anlaşılması ile daha başarılı sonuçlar elde edilebilir.

Çalışma kapsamında Amerika Birleşik Devletleri bölgesinde gerçekleşen uçuşlar göz önüne alınmıştır. Farklı bölgeler dahil edilerek model eğitilebilir ve sonuçlar incelenerek modelin genelleme başarısı değerlendirilebilir.

Çalışma doğrultusunda kullanılan öznitelikler çeşitlendirilebilir ya da farklı öznitelikler üretilebilir. Bu şekilde modelin doğruluğu artırılarak daha başarılı model sonuçları elde etmek hedeflenebilir.

Bu çalışmada hava durumu verileri kullanılsa da daha hassas hava durumu özelliklerinin hedef değişkeni açıklamadaki etkisi araştırılarak, farklı girdiler ile farklı model denemeleri gerçekleştirilebilir.

Çalışmada geçmişe dönük veriler kullanılmıştır. Gerçek zamanlı olarak verilerin anlık olarak güncellenmesi sağlanarak anlık operasyonlarda daha esnek modeller kurularak karar destek sistemlerine katkı sağlayabilir.



KAYNAKLAR

- [1] **Yimga, J. (2021).** the airline on-time performance impacts of the covid-19 pandemic. *transportation research interdisciplinary perspectives*, 10, 100386. <https://doi.org/10.1016/j.trip.2021.100386>
- [2] **Qu, J. and Chen, B. (2023).** classification algorithms and applications for flight delay prediction based on unbalanced data.. <https://doi.org/10.1117/12.2681061>
- [3] **Tian, Y., Wang, Q., Li, H., & Vanga, R. (2020).** assessment of flight block time reliability under different delay time windows: a case study. *Ieee Access*, 8, 9565-9577. <https://doi.org/10.1109/access.2020.2963986>
- [4] **Abdelghany, A., & Abdelghany, K. (2018).** *Airline network planning and scheduling*. John Wiley & Sons.
- [5] **Abdelghany, K., Shah, S., Raina, S., & Abdelghany, A. (2004).** a model for projecting flight delays during irregular operation conditions. *Journal of Air Transport Management*, 10(6), 385-394. <https://doi.org/10.1016/j.jairtraman.2004.06.008>
- [6] **Deshpande, V. and Arikan, M. (2012).** the impact of airline flight schedules on flight delays. *Manufacturing & Service Operations Management*, 14(3), 423-440. <https://doi.org/10.1287/msom.1120.0379>
- [7] **Abdelghany, A., Guzhva, V., & Abdelghany, K. (2023).** the limitation of machine-learning based models in predicting airline flight block time. *journal of air transport management*, 107, 102339. <https://doi.org/10.1016/j.jairtraman.2022.102339>.
- [8] **Wang, C., Hu, M., Yang, L., & Zhao, Z. (2022).** improving the spatial-temporal generalization of flight block time prediction: a development of stacking models. *journal of air transport management*, 103, 102244. <https://doi.org/10.1016/j.jairtraman.2022.102244>
- [9] **Wang, Y., Zhou, Y., Hansen, M., & Chin, C. (2019).** scheduled block time setting and on-time performance of u.s. and chinese airlines—a comparative analysis. *transportation research part a policy and practice*, 130, 825-843. <https://doi.org/10.1016/j.tra.2019.09.043>
- [10] **Chen, Y., Zhong, S., & Yan, Z. (2021).** examination on the setting of scheduled block time in china's aviation framework dependent on quantile regression model. *Soft Computing*, 27(6), 3403-3410. <https://doi.org/10.1007/s00500-021-06034-3>
- [11] **Coy, S. (2006).** a global model for estimating the block time of commercial passenger aircraft. *Journal of Air Transport Management*, 12(6), 300-305. <https://doi.org/10.1016/j.jairtraman.2006.07.005>

- [12] **Lu, H. and Hansen, M.** (2014). block time reliability and scheduled block time setting. *transportation research part b methodological*, 69, 98-111. <https://doi.org/10.1016/j.trb.2014.08.008>
- [13] **Kang, L. and Hansen, M.** (2017). behavioral analysis of airline scheduled block time adjustment. *transportation research part e logistics and transportation review*, 103, 56-68. <https://doi.org/10.1016/j.tre.2017.04.004>
- [14] **Kang, L. and Hansen, M.** (2018). assessing the impact of tactical airport surface operations on airline schedule block time setting. *transportation research part c emerging technologies*, 89, 133-147. <https://doi.org/10.1016/j.trc.2018.01.018>
- [15] **Zhu, X. and Li, L.** (2021). flight time prediction for fuel loading decisions with a deep learning approach. *Transportation Research Part C Emerging Technologies*, 128, 103179. <https://doi.org/10.1016/j.trc.2021.103179>
- [16] **Zhang, J., Peng, Z., Yang, C., & Wang, B.** (2021). data-driven flight time prediction for arrival aircraft within the terminal area. *Iet Intelligent Transport Systems*, 16(2), 263-275. <https://doi.org/10.1049/itr2.12142>
- [17] **Stefanovič, P., Štrimaitis, R., & Kurasova, O.** (2020). prediction of flight time deviation for lithuanian airports using supervised machine learning model. *Computational Intelligence and Neuroscience*, 2020, 1-10. <https://doi.org/10.1155/2020/8878681>
- [18] **Takeichi, N.** (2018). adaptive prediction of flight time uncertainty for ground-based 4d trajectory management. *transportation research part c emerging technologies*, 95, 335-345. <https://doi.org/10.1016/j.trc.2018.07.028>
- [19] **Balakrishna, P., Ganesan, R., & Sherry, L.** (2010). accuracy of reinforcement learning algorithms for predicting aircraft taxi-out times: a case-study of tampa bay departures. *transportation research part c emerging technologies*, 18(6), 950-962. <https://doi.org/10.1016/j.trc.2010.03.003>
- [20] **Stroiney, S., Levy, B., Khadilkar, H., & Balakrishnan, H.** (2013). assessing the impacts of the jfk ground management program.. <https://doi.org/10.1109/dasc.2013.6712508>
- [21] **Balakrishna, P., Ganesan, R., Sherry, L., & Levy, B.** (2008). estimating taxi-out times with a reinforcement learning algorithm. <https://doi.org/10.1109/dasc.2008.4702812>
- [22] **Levy, B. and Legge, J.** (2008). objective and automatic estimation of excess taxi-times. <https://doi.org/10.1109/icsurv.2008.4559197>
- [23] **Lee, H., Malik, W., & Jung, Y.** (2016). Taxi-out time prediction for departures at charlotte airport using machine learning techniques. *16th AIAA Aviation Technology, Integration, and Operations Conference*. <https://doi.org/10.2514/6.2016-3910>
- [24] **Malighetti, P., Morlotti, C., Redondi, R., & Pleari, S.** (2023). the turnaround tactic and on-time performance: implications for airlines' efficiency. *Research in Transportation Business & Management*, 46, 100874. <https://doi.org/10.1016/j.rtbm.2022.100874>

- [25] **AhmadBeygi, S., Cohn, A., Guan, Y., & Belobaba, P.** (2008). analysis of the potential for delay propagation in passenger airline networks. *Journal of Air Transport Management*, 14(5), 221-236. <https://doi.org/10.1016/j.jairtraman.2008.04.010>
- [26] **Alla, H., Moumoun, L., & Balouki, Y.** (2022). impact of aircraft performance and time of the day on flight arrival delays prediction in the united states: a machine learning classification. *Itm Web of Conferences*, 48, 03005. <https://doi.org/10.1051/itmconf/20224803005>
- [27] **Khaksar, H. and Sheikholeslami, A.** (2017). airline delay prediction by machine learning algorithms. *Scientia Iranica*, 0(0), 0-0. <https://doi.org/10.24200/sci.2017.20020>
- [28] **Athoğlu, M., Bolat, M., Sahin, M., Tunali, V., & Kilinc, D.** (2020). supervised learning approaches to flight delay prediction. *Sakarya University Journal of Science*, 24(6), 1223-1231. <https://doi.org/10.16984/saufenbilder.710107>
- [29] **Yazdi, M., Tabbakh, S., Chabok, S., & Kheirabadi, M.** (2020). flight delay prediction based on deep learning and levenberg-marquart algorithm. *Journal of Big Data*, 7(1). <https://doi.org/10.1186/s40537-020-00380-z>
- [30] **Chakrabarty, N.** (2019). a data mining approach to flight arrival delay prediction for american airlines.. <https://doi.org/10.1109/iemeconx.2019.8876970>
- [31] **Kafle, N. and Zou, B.** (2016). modeling flight delay propagation: a new analytical-econometric approach. *Transportation Research Part B Methodological*, 93, 520-542. <https://doi.org/10.1016/j.trb.2016.08.012>
- [32] **Kafle, N. and Zou, B.** (2016). modeling flight delay propagation: a new analytical-econometric approach. *Transportation Research Part B Methodological*, 93, 520-542. <https://doi.org/10.1016/j.trb.2016.08.012>
- [33] **Jacquillat, A. and Odoni, A.** (2018). a roadmap toward airport demand and capacity management. *Transportation Research Part a Policy and Practice*, 114, 168-185. <https://doi.org/10.1016/j.tra.2017.09.027>
- [34] **Yin, J., Ma, Y., Tian, W., Chen, D., Hu, Y., & Ochieng, W.** (2020). Impact analysis of demand management on runway configuration in metroplex airports. *Ieee Access*, 8, 66189-66212. <https://doi.org/10.1109/access.2020.2985288>
- [35] **Rodríguez-Sanz, Á., Cano, J., & Fernández, B.** (2021). Impact of weather conditions on airport arrival delay and throughput. *Aircraft Engineering and Aerospace Technology*, 94(1), 60-78. <https://doi.org/10.1108/aeat-12-2020-0318>
- [36] **Zografos, K., Madas, M., & Androutopoulos, K.** (2016). Increasing airport capacity utilisation through optimum slot scheduling: review of current developments and identification of future needs. *Journal of Scheduling*, 20(1), 3-24. <https://doi.org/10.1007/s10951-016-0496-7>
- [37] **Url-1** < <https://www.transtats.bts.gov/>>, erişim tarihi 31.12.2023.
- [38] **Url-2** < <https://learn.microsoft.com/en-us/rest/api/>>, erişim tarihi 31.12.2023.



ÖZGEÇMİŞ

Ad-Soyad : SEDA SOYKAN

ÖĞRENİM DURUMU:

- **Lisans** : 2014, İstanbul Teknik Üniversitesi, Fen Edebiyat Fakültesi, Matematik Mühendisliği Bölümü
- **Yüksek Lisans** : 2024, İstanbul Teknik Üniversitesi, Bilgisayar Bilimleri Anabilim Dalı, Bilgisayar Bilimleri Programı

YÜKSEK LİSANS TEZİNDEN TÜRETİLEN YAYINLAR, SUNUMLAR VE PATENTLER:

- **Soykan S., Baday S.** 2023 Enhancing On Time Performance through Flight Time Prediction-A Machine Learning Approach. *International Conference on Engineering Technologies Congress*, November 23-25, 2023 Konya, Turkey.