



T.C.
NECMETTİN ERBAKAN
ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ



YEŞİL HAVALİMANI UYGULAMALARI: İKİ
AŞAMALI KARBON EMİSYON TAHMİN
MODELİ

Zeynep İrem ÖZFİDAN

YÜKSEK LİSANS TEZİ

Endüstri Mühendisliği Anabilim Dalı

Nisan-2026
KONYA
Her Hakkı Saklıdır

TEZ KABUL VE ONAYI

Zeynep İrem ÖZFİDAN tarafından hazırlanan “**YEŞİL HAVALİMANI UYGULAMALARI: İKİ AŞAMALI KARBON EMİSYON TAHMİN MODELİ**” adlı tez çalışması 15/04/2026 tarihinde aşağıdaki jüri tarafından oy birliği ile Necmettin Erbakan Üniversitesi Fen Bilimleri Enstitüsü Endüstri Mühendisliği Anabilim Dalı’nda YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

Jüri Üyeleri

İmza

Danışman

Doç. Dr. Beyzanur ÇAYIR ERVURAL

.....

Üye

Prof. Dr. Ali KILIÇ

.....

Üye

Dr. Öğr. Üyesi Ahmet Reha BOTSALI

.....

Fen Bilimleri Enstitüsü Yönetim Kurulu’nun/.../20.. gün ve sayılı kararıyla onaylanmıştır.

Prof. Dr. Havvanur UÇBEYİAY
FBE Müdürü

Bu tez çalışması Necmettin Erbakan Üniversitesi Bilimsel Araştırma Projeleri Koordinatörlüğü tarafından 25YL16001 nolu proje ile desteklenmiştir.

TEZ BİLDİRİMİ

Bu tezdeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edildiğini ve tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını bildiririm.

DECLARATION PAGE

I hereby declare that all information in this document has been obtained and presented in accordance with academic rules and ethical conduct. I also declare that, as required by these rules and conduct, I have fully cited and referenced all material and results that are not original to this work.

Zeynep İrem ÖZFİDAN

Tarih:15.05.2026

ÖZET

YÜKSEK LİSANS TEZİ

YEŞİL HAVALİMANI UYGULAMALARI: İKİ AŞAMALI KARBON EMİSYON TAHMİN MODELİ

Zeynep İrem ÖZFİDAN

NECMETTİN ERBAKAN ÜNİVERSİTESİ FEN BİLİMLERİ ENSTİTÜSÜ
ENDÜSTRİ MÜHENDİSLİĞİ ANABİLİM DALI

Danışman: Doç. Dr. Beyzanur ÇAYIR ERVURAL

2026, 89 Sayfa

Jüri

Doç. Dr. Beyzanur ÇAYIR ERVURAL

Prof. Dr. Ali KILIÇ

Dr. Öğr. Üyesi Ahmet Reha BOTSALI

Hava taşımacılığı, birçok ulaşım türünden daha hızlı büyümekte ve gelişmektedir. Bu yüzden küresel emisyon artışında kritik bir paya sahiptir. Bu çalışmada Türkiye'nin havacılık kapasitesi açısından stratejik öneme sahip üç merkezi olan Sabiha Gökçen, Esenboğa ve Konya havalimanlarındaki uçakların iniş ve kalkış sırasında salınan CO₂ miktarının gelecek dönem projeksiyonu incelenmiştir. Kullanılan veriler 2014-2023 dönemini kapsayan 120 aylık veri setinden oluşmaktadır. Bu çalışmada, çok aşamalı bir karar destek modeli önerilmiştir. İlk olarak, uzman görüşlerine dayalı olarak Analitik Hiyerarşi Prosesi (AHP) yöntemi kullanılarak emisyonları etkileyen temel faktörler belirlenmiştir. En önemli üç faktörün LTO, yakıt tüketimi ve yük trafiği olduğu tespit edilmiştir. Daha sonra, her bir uçuş için emisyon değerleri Tier II yöntemi kullanılarak hesaplanmıştır. Hesaplanan bu emisyon verileri kullanılarak bir tahmin modeli geliştirilmiştir. Operasyonel değişkenlerin tahmini için Otoregresif Entegre Hareketli Ortalama (ARIMA), Üstel Düzleştirme (ETS) ve Mevsimsel Otoregresif Entegre Hareketli Ortalama (SARIMA) zaman serisi yöntemleri uygulanmış, model performansları karşılaştırılarak en uygun yöntem belirlenmiştir. Son tahmin aşamasında, makine öğrenimi tabanlı DVR (Destek Vektör Regresyonu), En Küçük Kareler Güçlendirme (Least Squares Boosting-LSBoost) ve Rastgele Orman (Random Forest-RF) yöntemleri kullanılmıştır. Bu tahmin yöntemlerinin performansları karşılaştırılarak, en düşük hata değerini veren modeller belirlenmiştir. En düşük hataya sahip olan model Sabiha Gökçen için %1,24 Ortalama Mutlak Yüzde Hata (Mean Absolute Percentage Error-MAPE) ve Konya için %0,78 MAPE değeri ile LSBoost modeli seçilirken Esenboğa Havalimanı için DVR modeli %2,99 MAPE değeri ile en düşük hataya sahip olan model olarak belirlenmiştir. Çalışmanın farklı koşullar altındaki davranışını gözlemlemek için, iyimser ve kötümser senaryolar altında değerlendirmeler yapılmıştır. İyimser senaryoda çevre politikaları kapsamında elde edilen karbon tasarrufu, kötümser senaryolardaki sonuçlarla karşılaştırılmıştır. Çok Amaçlı Optimizasyon Oran Analizi (Multi-Objective Optimization on the basis of Ratio Analysis- MOORA) tabanlı uçak tipi analizleri sonucunda daha çevreci uçak tipi kullanımının Konya Havalimanı için aylık yaklaşık 0,1-0,25 milyon kg CO₂ emisyon azaltımı sağlayabileceği gözlemlenirken, Sabiha Gökçen Havalimanı'nda bu değerin aylık yaklaşık 3-6 milyon kg CO₂ seviyesine ulaşabileceği belirlenmiştir. Elde edilen sonuçların, bu alandaki araştırmacılar ve politika yapıcılar için yol gösterici olması beklenmektedir.

Anahtar Kelimeler: AHP, Destek Vektör Regresyonu (DVR), Emisyon Tahmini, İniş-Kalkış (LTO) Döngüsü, Karbon Emisyonu, LSBoost, MOORA, Rastgele Orman (RF).

ABSTRACT

MS THESIS

GREEN AIRPORT APPLICATIONS: TWO-STAGE CARBON EMISSION FORECASTING MODEL

Zeynep İrem ÖZFİDAN

**THE GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCES OF
NECMETTİN ERBAKAN UNIVERSITY THE DEGREE OF MASTER OF
SCIENCE IN INDUSTRIAL ENGINEERING**

Advisor: Assoc. Prof. Dr. Beyzanur ÇAYIR ERVURAL

2026, 89 Pages

Jury

Assoc. Prof. Dr. Beyzanur ÇAYIR ERVURAL

Prof. Dr. Ali KILIÇ

Asst. Prof. Dr. Ahmet Reha BOTSALI

Air transportation is growing and developing more rapidly than many other modes of transportation. Therefore, it has a critical share in the increase of global emissions. In this study, the future projection of the amount of CO₂ emissions released during the landing and take-off phases of aircraft at Sabiha Gökçen, Esenboğa, and Konya airports, which are three strategically important hubs in terms of Türkiye's aviation capacity, was examined. The data used in the study consist of a 120-month dataset covering the 2014–2023 period. In this study, a multi-stage decision support model was proposed. First, the main factors affecting emissions were determined using the Analytic Hierarchy Process (AHP) method based on expert opinions. It was determined that the three most important factors were LTO, fuel consumption, and cargo traffic. Subsequently, emission values for each flight were calculated using the Tier II methodology. A prediction model was then developed using these calculated emission data. For the prediction of operational variables, time series methods including Autoregressive Integrated Moving Average (ARIMA), Exponential Smoothing (ETS), and Seasonal Autoregressive Integrated Moving Average (SARIMA) were applied, and the most suitable method was determined by comparing model performances. In the final prediction stage, machine learning-based methods including Support Vector Regression (SVR), Least Squares Boosting (LSBoost), and Random Forest (RF) were used. The performances of these prediction methods were compared, and the models with the lowest error values were identified. The model with the lowest error was determined as the LSBoost model with a Mean Absolute Percentage Error (MAPE) value of 1.24% for Sabiha Gökçen and 0.78% for Konya, whereas the SVR model was observed to have the lowest error for Esenboğa Airport with a MAPE value of 2.99%. In order to observe the behavior of the study under different conditions, evaluations were conducted under optimistic and pessimistic scenarios. In the optimistic scenario, the carbon savings achieved within the scope of environmental policies were compared with the results obtained under pessimistic scenarios. As a result of aircraft type analyses based on the Multi-Objective Optimization on the basis of Ratio Analysis (MOORA) method, it was observed that the use of more environmentally friendly aircraft types could provide an approximate monthly CO₂ emission reduction of 0.1-0.25 million kg for Konya Airport, while this value could reach approximately 3-6 million kg per month at Sabiha Gökçen Airport. The obtained results are expected to serve as a guiding resource for researchers and policy makers in this field.

Keywords: AHP, Support Vector Regression (SVR), Emission Prediction, Landing and Take-Off (LTO) Cycle, Carbon Emission, LSBoost, MOORA, Random Forest (RF).

ÖNSÖZ

Bu çalışma, hızla büyüyen hava taşımacılığının çevresel etkilerine odaklanarak, Türkiye'nin stratejik öneme sahip Sabiha Gökçen, Esenboğa ve Konya, havalimanlarında uçakların LTO (iniş-kalkış) safhasında oluşan emisyonları, özellikle CO₂ salımları çerçevesinde kapsamlı bir şekilde incelemektedir. Çalışmada, çok aşamalı bir karar destek yaklaşımı benimsenerek emisyonları belirleyen temel faktörler ortaya konulmuş, ileri tahmin yöntemleriyle geleceğe yönelik öngörüler geliştirilmiş ve farklı senaryolar altında elde edilen bulgular değerlendirilerek hem akademik literatüre katkı sağlanması hem de karar vericilere yol gösterilmesi amaçlanmıştır.

Öncelikle çalışmam kapsamında her aşamasında yol gösteren bilgi ve deneyimiyle akademik gelişimimde önemli katkı sağlamış olan değerli danışmanım Doç. Dr. Beyzanur ÇAYIR ERVURAL'a teşekkürlerimi sunarım. Araştırmam kapsamında hazırlanan anketlere katılım sağlayan ve veri sürecinde vakit ayıran, akademik katkıda bulunan ve görüşleriyle çalışmama yön veren bütün havacılık uzmanlarına ayrıca teşekkür ederim. Bu çalışmanın havacılık sektöründe sürdürülebilirlik alanında yapılan çalışmalara katkı sunması ve gelecek çalışmalara yol gösterebilmesi umuduyla.

Zeynep İrem ÖZFİDAN
KONYA-2026

İÇİNDEKİLER

ÖZET	iv
ABSTRACT.....	v
ÖNSÖZ	vi
İÇİNDEKİLER	vii
ŞEKİLLER LİSTESİ	ix
ÇİZELGELER LİSTESİ	x
SİMGELER VE KISALTMALAR	xi
1. GİRİŞ	1
2. KAYNAK ARAŞTIRMASI	4
2.1. Küresel İklim Değişikliği ve Havacılığa Etkileri.....	4
2.2. Yeşil Havalimanı Uygulamaları	4
2.2.1. Türkiye’de yeşil havalimanı uygulamaları	5
2.3. Sera Gazı Emisyonları	5
2.3.1. Ulaşım sektöründe sera gazı emisyonları	6
2.3.2. Havacılık faaliyetlerinden kaynaklanan sera gazı emisyonları.....	7
2.4. Havacılıkta Karbon Emisyonları Üzerine Yapılan Çalışmalar	9
3. MATERYAL VE YÖNTEM.....	17
3.1. Tier 2 Yöntemi.....	17
3.1.1. Havalimanında uçakların LTO (iniş/kalkış) döngüsü.....	19
3.2. Çok Kriterli Karar Verme Yöntemleri.....	20
3.2.1. Analitik hiyerarşi süreci (AHP) yöntemi	20
3.2.2. Multi-objective optimization by ratio analysis (MOORA) yöntemi	22
3.3. Zamana Bağlı Tahmin Modelleri.....	23
3.3.1. Otoregresif entegre hareketli ortalama (ARIMA) modeli	24
3.3.2. Mevsimsel otoregresif entegre hareketli ortalama (SARIMA) modeli	25
3.3.3. Üstel düzleştirme (ETS) modeli	26
3.4. Makine Öğrenmesi Modelleri	26
3.4.1. Destek vektör regresyonu (DVR) modeli	27
3.4.2. LSBoost (Least Squares Boosting) modeli	29
3.4.3. Random Forest modeli.....	30
4. UYGULAMA	31
4.1. Çalışmada İncelenen Havalimanlarının Tanıtımı	31
4.1.1. Sabiha Gökçen Havalimanı (SAW)	31
4.1.2. Esenboğa Havalimanı (ESB)	32
4.1.3. Konya Havalimanı (KYA).....	32
4.2. Veri Hazırlama ve İş Akışı	33
4.3. Tier 2 Yöntemi Uygulaması	34

4.4. Çok Kriterli Karar Verme Yöntemlerinin Uygulaması	35
4.4.1. AHP yöntemi uygulaması	35
4.4.2. MOORA yöntemi uygulaması	38
4.5. Tahmin Modellerinin Uygulanması	40
4.6. Girdi Tahmini (Zaman Serisi Modelleri)	41
4.6.1. ARIMA (1,1,1) modeli	41
4.6.2. ETS modeli	41
4.6.3. SARIMA modeli	41
4.7. CO ₂ Emisyon Tahmini (Makine Öğrenmesi Modelleri)	42
4.7.1. LSBoost modeli	42
4.7.2. DVR modeli	42
4.7.3. Random Forest modeli	42
4.7.4. Ek karşılaştırma modeli: SARIMA	42
4.8. Senaryo Analizi Uygulaması	43
5. ARAŞTIRMA SONUÇLARI VE TARTIŞMA	44
5.1. Tier 2 Yöntemi Sonuçları	44
5.2. AHP Yöntemi Sonuçları	49
5.3. Tahmin Modelleri Sonuçları	51
5.3.1. Operasyonel değişkenlerin (girdilerin) tahmini	52
5.3.2. Girdilere ilişkin makine öğrenmesi sonuçları	54
5.3.3. CO ₂ emisyonlarının zamana bağlı tahmini: SARIMA modeli	56
5.3.4. Makine öğrenmesi yaklaşımları	56
5.3.5. Performans karşılaştırması ve model seçimi	59
5.3.6. Aşırı uyum hesaplaması ve karşılaştırmalı analiz	60
5.4. MOORA Yöntemi Sonuçları	63
5.5. İyimserlik ve Kötümserlik Yaklaşımları Altında Senaryo Analizi	66
5.6. CO ₂ Emisyon Tahmini ve Senaryo Analizleri	67
5.6.1. CO ₂ emisyon tahmini	67
5.6.2. Senaryo analizleri	70
5.7. Tartışma	74
6. SONUÇLAR VE ÖNERİLER	76
6.1. Sonuçlar	76
6.2. Öneriler ve Gelecek Çalışmalar	77
KAYNAKLAR	80
EKLER	88

ŞEKİLLER LİSTESİ

Şekil 2.1. AB Ulaşım Sektörü için Karbon Emisyon Oranları (EEA, 2021).....	6
Şekil 2.2. Bir havalimanında karbon emisyonu oranları (BDL, 2020).....	7
Şekil 3.1. LTO (iniş/kalkış, landing/take off) döngüsü (EASA, 2016)	19
Şekil 4.1. Çalışmada kullanılan emisyon tahmin modelinin genel iş akışı.....	34
Şekil 4.2. Anket kriter karşılaştırma örneği	37
Şekil 4.3. Ankette seçilen kriterin puanlaması	37
Şekil 5.1. Çalışmada incelenen üç havalimanının LTO safhasında meydana gelen 10 yıllık CO ₂ değerleri.....	47
Şekil 5.2. Sabiha Gökçen, Esenboğa ve Konya Havalimanları karşılaştırmalı CO ₂ ısı haritası.....	47
Şekil 5.3. Sabiha Gökçen için CO ₂ emisyon tahmin grafiği.....	68
Şekil 5.4. Esenboğa için CO ₂ emisyon tahmin grafiği	69
Şekil 5.5. Konya için CO ₂ emisyon tahmin grafiği	69
Şekil 5.6. Sabiha Gökçen Havalimanı için gelecek 120 aylık CO ₂ tahmini.....	71
Şekil 5.7. Esenboğa için 120 aylık gelecek CO ₂ emisyon tahmin senaryoları	71
Şekil 5.8. Konya için gelecek 120 aylık CO ₂ tahmin senaryoları.....	72
Şekil 5.9. SAW, ESB VE KYA havalimanları için emisyon senaryoları karşılaştırması	73

ÇİZELGELER LİSTESİ

Çizelge 2.1. Havacılık sektöründe emisyon tahmini alanında yapılan bazı çalışmaların özeti.....	14
Çizelge 3.1. ICAO tarafından yayınlanmış ve çalışmada referans alınan uçak tiplerine ait emisyon faktörleri (kg/LTO) (ICAO, 2020)	18
Çizelge 3.2. Referans emisyon iniş ve kalkış (LTO) döngüsü süreleri (ICAO, 2020) ...	20
Çizelge 3.3. Örnek AHP Çizelgesi (Singh, 2014)	21
Çizelge 3.4. SARIMA parametre ağırlık değerleri	25
Çizelge 4.1. MOORA yönteminde kullanılan kriterlerin önem ağırlıkları	38
Çizelge 4.2. Sabiha Gökçen Havalimanı için oluşturulan MOORA karar matrisi (örnek)	39
Çizelge 5.1. Sabiha Gökçen (SAW), Esenboğa (ESB) ve Konya (KYA) havalimanları için 10 yıllık toplam yakıt değerleri (kg)	44
Çizelge 5.2. B738 hava aracı tipine göre 2014 yılı için 3 havalimanının LTO (iniş ve kalkış) ve emisyon değerleri	45
Çizelge 5.3. Çalışmada incelenen üç havalimanının 10 yıllık emisyon değerleri (kg) ..	46
Çizelge 5.4. 2014-2023 yılları arasında gerçekleşen Sabiha Gökçen Havalimanı (SAW), Esenboğa Havalimanı (ESB) ve Konya (KYA) havalimanlarında gerçekleşen toplam uçak iniş-kalkış (LTO) sayıları	48
Çizelge 5.5. İncelenen havalimanlarında 2014-2023 yılları arasında en yüksek CO ₂ emisyonuna sebep olan üç farklı uçak tipine ait CO ₂ ve iniş-kalkış (LTO) değerleri (DHMI)	49
Çizelge 5.6. Havalimanı genel emisyonu sebep olan faktörlerin önem sıralaması.....	49
Çizelge 5.7. Uçaklarda emisyonu sebep olan faktörlerin önem sıralaması	51
Çizelge 5.8. Zaman serileri girdi değişkenlerinin tahmin performansları	52
Çizelge 5.9. Makine Öğrenmesi için girdi performans göstergeleri sonuçları	54
Çizelge 5.10. SARIMA modeli CO ₂ emisyon performans göstergeleri	56
Çizelge 5.11. CO ₂ Emisyon Tahmin Modeli Performans Göstergeleri	57
Çizelge 5.12. Her havalimanı için nihai CO ₂ emisyon tahmin modeli sonuçları	60
Çizelge 5.13. Havalimanları arasında geçerlilik ve test RMSE değerlerinin karşılaştırılması	61
Çizelge 5.14. Sabiha Gökçen Havalimanı için 2014-2023 yılları arasında belirlenen en çevreci uçak tipleri	63
Çizelge 5.15. Sabiha Gökçen Havalimanı için 2014-2023 yılları arasında belirlenen en kirlletici uçak tipleri	64
Çizelge 5.16. Esenboğa Havalimanı için 2014-2023 yılları arasında belirlenen en çevreci uçak tipleri	64
Çizelge 5.17. Esenboğa Havalimanı için 2014-2023 yılları arasında belirlenen en kirlletici uçak tipleri	64
Çizelge 5.18. Konya Havalimanı için 2014-2023 yılları arasında belirlenen en çevreci uçak tipleri	65
Çizelge 5.19. Konya Havalimanı için 2014-2023 yılları arasında belirlenen en kirlletici uçak tipleri	65
Çizelge 5.20. İlgili havalimanlarında kullanılan uçakların verimlilik analizi	67

SİMGELER VE KISALTMALAR

Simgeler

CO₂	Karbon dioksit
CO	Karbonmonoksit
H₂O	Su Buharı
HC	Hidrokarbonlar
NO_x	Azot oksitler
PM	Partikül Madde
SO₂	Kükürt oksitler
t	ton
kg	kilogram

Kısaltmalar

AHP	Analitik Hiyerarşi Prosesi
ÇKKV	Çok Kriterli Karar Verme
ESB	Esenboğa Havalimanı'nın IATA kodu
IATA	Uluslararası Hava Taşımacılığı Birliği
ICAO	Uluslararası Sivil Hava Taşımacılığı Örgütü
IPCC	Hükümetler arası İklim Değişikliği Paneli
KYA	Konya Havalimanı'nın IATA kodu
LTO	İniş-Kalkış Döngüsü
MOORA	Çok Amaçlı Optimizasyon Oranı Analizi
UNFCCC	Birleşmiş Milletler İklim Değişikliği Çerçeve Sözleşmesi
UNCED	Birleşmiş Milletler Çevre ve Kalkınma Konferansı
SHGM	Sivil Havacılık Genel Müdürlüğü
SAW	Sabiha Gökçen Havalimanı'nın IATA kodu
DVR	Destek Vektör Regresyonu
LSBoost	Least Squares Boosting (En Küçük Kareler Güçlendirme Yöntemi)
MAPE	Ortalama Mutlak Yüzde Hata
R²	Belirlilik katsayısı
RF	Random Forest
RMSE	Kök Ortalama Kare Hata

1. GİRİŞ

Son yıllarda birçok ülke ekonomik ve toplumsal hedeflerine ulaşmak için yüksek düzeyde doğal çevre unsurlarına bağımlı hale gelmiştir. Ancak bu bağımlılık, özellikle karbon bazlı yakıtların kullanımı ve endüstriyel faaliyetler sonucu yüksek oranda sera gazı salınımına neden olmaktadır. Sanayi devriminin ilk yılları olarak bilinen 1750'li yıllarda, endüstriyel amaçlarla hidrokarbon yakıtların yoğun olarak kullanılmaya başlanmasından önce Karbondioksit (CO₂) oranları 280 ppm rakamlarındaydı. 2018 yılında ise bu değer 410 ppm'nin üzerine çıkmış ve her yıl 2-3 ppm oranında artmaktadır (Kurnaz, 2020). Güncel gözlemlerde ise bu oran yaklaşık 425 ppm rakamlarına ulaştığı göstermektedir (Lan vd., 2025). Bilim insanları, atmosferdeki CO₂ miktarının 2100 yılına kadar 880 ppm değerine yükseleceğini ve bu oranın küresel sıcaklık oranında 3,5 °C'lık bir yükselişe sebep olacağını bildiren birçok çalışma yürütmüştür (Brasseur ve Gupta, 2010). Sıcaklığın yükselmesi, yeryüzü ve atmosferini etkileyerek doğal afetlere sebebiyet vermektedir (Xu vd., 2022). Ulaşım sektöründe önemli bir yere sahip olan havacılık sektörü ise en fazla enerji tüketen ve kirlilik yaratan sektörlerden biri olarak bilinmektedir. Dünya genelindeki CO₂ salınımının yaklaşık %2'sine sebep olmaktadır (Brasseur ve Gupta, 2010).

Hava taşımacılığı, her yıl büyüyen ve talep gören bir ulaşım türü olup, bu da onu insan kaynaklı hava kirleticilerinin en önemli kaynaklarından biri haline getirmektedir. Aynı zamanda sürdürülebilirlik bağlamında kilit sektörlerden biri olan lojistik sektörü, geleceğimizi tehdit eden birçok çevre sorununun çözümünde önemli bir rol oynamaktadır (Yolcu, 2023). Hava ulaşımının CO₂ emisyonları, küresel ölçekte özellikle Karayolu ulaşımından daha az bir oran oluştursa da çevresel etkileri sebebiyle akademik çalışmalarda önemli bir araştırma unsuru haline gelmiştir. Hava araçlarının egzoz emisyonları esas olarak karbon monoksit (CO), karbon dioksit (CO₂), kükürt oksitler (SO_x), su buharı (H₂O), azot oksitler (NO_x), hidrokarbonlar (HC) ve diğer gazlar ve partiküllerden oluşmaktadır (Tokuslu, 2020).

Bu emisyonlar sonucunda küresel karbon döngüsü zarar görmekte ve potansiyel ekolojik, fiziksel ve sağlık sorunları da dahil olmak üzere bir dizi küresel ısınma sorununa yol açmaktadır (Ritchie vd., 2023). Üstelik bu durum, beraberinde hava taşımacılığı sektöründe büyük miktarda dış maliyete yol açmaktadır. Örneğin, yolcu uçuşları tarafından salınan CO₂ emisyonlarının dış iklim değişikliği maliyetleri, 2016 yılında seçilmiş 33 Avrupa havalimanında 19,1 milyar Euro olarak gerçekleşmiş olup, bu rakam

Avrupa Birliği Gayri Safi Yurt İçi Hasılası'nın %0,2'sine ulaşmaktadır (Schroten vd., 2019). Havacılık kaynaklı sera gazları ve hava kirleticilerinin iklim üzerindeki etkisi, emisyonun troposferdeki konumuna göre değişmektedir. Özellikle üst troposferde H₂O (Su buharı) ve NO_x (Azot Oksit) değerleri yüzeye göre daha düşüktür. Bu nedenle, karbon emisyonlarının kontrol altına alınması ve azaltılması hükümetler ve uluslararası toplum için acil bir öncelik haline gelmiştir.

Karbon emisyonlarının tahmin edilmesi ve incelenmesi de akademik araştırmaların odak noktalarından biridir (Qiao vd., 2020). Havacılık sektörü küresel ekonomide önemli bir rol oynamaktadır ve sürekli büyüyen ve gelişen kritik bir sektördür. Bununla birlikte, sürekli artan karbon emisyonları çevresel sürdürülebilirlik açısından büyük bir endişe kaynağıdır. Uluslararası Hava Taşımacılığı Birliği (IATA)'ne göre, havacılık sektörü küresel karbon emisyonlarında önemli bir paya sahiptir. Havacılık sektörü ekonomik kalkınmada çok önemli bir rol oynamasına rağmen, karbon emisyonları sürdürülebilirlik hedeflerine doğru ilerlemeyi engellemektedir. Bu sebeple, çevresel etkileri hafifletmek ve sürdürülebilir büyümeyi teşvik etmek için havacılık sektöründeki karbon emisyonlarını azaltmaya yönelik etkili stratejiler geliştirmek oldukça önemlidir.

Araştırmanın amacı

Bu çalışmanın amacı Türkiye'de yer alan havalimanlarından; Sabiha Gökçen, Esenboğa ve Konya havalimanlarında uçakların LTO safhasında meydana gelen emisyonların çok aşamalı bir karar destek modeli ile tahmin edilmesidir. İlk aşamada Tier 2 yöntemi uygulanarak uçakların LTO başına ürettiği aylık emisyon değerleri hesaplanmış, ikinci aşamada ise bu emisyonu sebep olan faktörler Analitik Hiyerarşi Prosesi (AHP) yöntemi ile önceliklendirilmiş ve AHP yönteminden ortaya çıkan önemli faktörler Makine Öğrenmesi algoritmalarına girdi olarak tanımlanmış ve bu veriler kullanılarak gelecek 10 yıllık bir tahmin modeli uygulanmıştır. Ayrıca, senaryo analizleri ve MOORA tabanlı filo değerlendirmeleri kullanılarak, daha çevreci ve iyimser koşullar altında emisyonların ne ölçüde azaltılabileceği analiz edilmiştir.

Araştırmanın önemi

Literatür incelendiğinde, bu alanda yapılan çalışmaların çoğunlukla birbirinden bağımsız ele alındığı görülmektedir. Mevcut çalışmalar genellikle ya yalnızca Tier yöntemlerine dayalı emisyon hesaplamalarına odaklanılmakta ya da mevcut veriler üzerinden tek bir tahmin yaklaşımı uygulanmaktadır. Buna karşılık emisyon hesaplama, karar verme süreçleri ve gelişmiş tahmin yöntemlerini bütüncül bir yaklaşımla ele alan

alışmalar ise oldukça sınırlıdır. Bu alışma yalnızca bir ynteme baėlı kalmayıp Tier II, ok Kriterli Karar Verme (KKV) ve Makine ėrenmesi yntemlerini uzman grüşleriyle entegre eden ok aşamalı bir tahmin modeli sunmasıyla literatürdeki diėer alışmalardan ayrılmaktadır.

Bu araştırmada, havalimanından saėlanan ve uçak operasyonlarına ilişkin veri toplama sürecinde saėlanan bilgilerin doėru ve güvenilir olduėu varsayılacaktır. Ayrıca, emisyon hesaplama ve tahmin modellerinde kullanılan yntemlerin geerliliėi ve güvenilirliėi kabul edilecektir. alışma süresince elde edilecek bulguların, genel havacılık sektörü için temsil edici olduėu varsayılmaktadır. Bu araştırma, yalnızca İstanbul Sabiha Göken, Ankara Esenboėa ve Konya havalimanında 2014-2023 yılları arasında meydana gelen uçak operasyonları ile sınırlıdır.



2. KAYNAK ARAŞTIRMASI

Bu bölümde, çalışmanın teorik altyapısını oluşturan kavramlar ve konuya ilişkin literatürde yer alan çalışmalar incelenmiştir. Öncelikle küresel iklim değişikliği ve havacılık sektörü üzerindeki etkileri ele alınmış, ardından yeşil havalimanı uygulamaları ile sera gazı emisyonları değerlendirilmiştir. Son olarak havacılıkta karbon emisyonları üzerine gerçekleştirilen çalışmalar özetlenmiştir.

2.1. Küresel İklim Değişikliği ve Havacılığa Etkileri

İklim uzmanlarına göre hava, yeryüzünün herhangi bir yer ve zamanında meydana gelen atmosfer kaynaklı olayların toplamıdır. İnsan aktivitelerinin çoğu hava olaylarından etkilenir. Bu sebeple hava olaylarının kısa vadeli tahminlerin yapılması, insan yaşamı açısından oldukça önem arz etmektedir. (Türkeş vd., 2000). İklim değişikliğinin başlıca nedeni, insan faaliyetlerinin bir sonucu olarak sera gazlarının salınmasıdır. Fosil yakıtların yakılması, endüstriyel faaliyetler ve ormansızlaşma bu gazların atmosferde birikmesine yol açmaktadır. Volkanik patlamalar, güneş radyasyonundaki değişiklikler ve yer kabuğu hareketleri gibi doğal olaylar da iklim değişikliğine katkıda bulunabilir. Ancak, mevcut değişikliklerin büyük çoğunluğu insan kaynaklıdır (Soza ve Ayres, 2018).

Küresel iklim değişikliğinin havacılık sektörü üzerindeki etkisi son yıllarda oldukça dikkat çeken bir konudur. Havacılık, hem CO₂ hem de CO₂ dışı emisyonlar yoluyla iklim değişikliğine önemli bir etkide bulunmaktadır. Ayrıca, bu etkilerin havacılık sektörünün büyümesine paralel olarak arttığı da açıktır (Lee vd., 2009).

Sonuç olarak, kısa vadeli hava olaylarını tahmin etme yeteneği, insan yaşamı için büyük önem taşır. Bu sürecin başarılı bir şekilde yürütülmesi için, doğru atmosferik verilerin bulunması bir ön koşul niteliğindedir (Türkeş vd., 2000).

2.2. Yeşil Havalimanı Uygulamaları

Zaman geçtikçe artan ve genellikle endüstri faaliyetlerinin sebep olduğu çevresel etkiler küresel çapta oldukça büyük bir sorun olarak görülmektedir. Bu sorunu çözmek ve çevresel etkilerin kötü etkilerini azaltmak için birçok farklı düzenleme geliştirilmektedir. Buna bağlı olarak yeşil kuruluş, yeşil yönetim, yeşil inovasyon ve yeşil üretim gibi birçok yeni konu, bu düzenlemelerin bir çözümleri olarak meydana gelmiştir. (Canöz ve Ertek, 2020). Yeşil yönetim, çevre dostu uygulamaların farklı sektörlerde kullanılması gerekliliği, son dönemlerde küresel ölçekte ihtiyaç duyulan bir kavramdır.

Çevre dostu yönetim anlayışına ihtiyacı olan önemli sektör havacılık sektörüdür. Havacılık ve havalimanı ortakları, havalimanı operasyonlarının sürdürülebilirlik çalışmalarına olan gerekliliği fark etmişlerdir (Bamidele vd., 2023).

2.2.1. Türkiye’de yeşil havalimanı uygulamaları

Havacılık sektörü, çoğu sektörde olduğu gibi zamanla artan çevresel sorunların etkileriyle karşı karşıyadır. Bu çevresel sorunların etkisi, sosyal ve beşerî tutumlara bağlı olarak değişmektedir. Çoğu ülkede artan refah oranları, insanlar için yaşam kalitesinde olan artış ile beraberinde beklentilerinin de yükselmesine sebep olmuştur. Bu olaylar sonucu havalimanlarının çevre ile olan etkileşimi daha dikkat edilmesi gereken bir konu haline gelmiştir. (Graham, 2008; Yavuz, 2022).

Türkiye’de bu konu adına oluşturulan bir proje olan ‘Yeşil Havalimanı Projesi’, Sivil Havacılık Genel Müdürlüğü’nce 2009 senesinde başlatılmıştır. 2013 senesinden beri devamlılığı sağlanmaktadır. Bu proje, havalimanı işletmelerine yönelik çevre politikalarının geliştirilmesi ve çevrenin korunmasına yönelik amaç ve hedeflerin tanımlanması yoluyla organizasyonel bir yapının sağlanması hedefleri ile oluşturulmuştur. Ayrıca bu kuruluşların hava kirliliği konusunda, Türkiye’nin de taraf olduğu çeşitli uluslararası anlaşma ve protokoller de dikkate alınmaktadır (Akpınar, 2015). Türkiye’de hükümet tarafından da bu konuda havalimanlarının çevreci olmasına yönelik bazı teşvikler yapılmaktadır. Örneğin; Yeşil Havaalanı Projesi kapsamında, canlılara zarar verebilecek ve sağlık sorunlarına sebep olabilecek çevresel kirliliğin henüz oluşmadan önlem alınması ve havalimanlarında çevreci uygulamaların sürdürülebilir olarak devam etmesi hedeflemektedir (SHGM).

2.3. Sera Gazı Emisyonları


Atmosferdeki sera gazı yoğunluğunun artışı, Dünya yüzeyine ulaşan güneş ışığının geri yansıtılmasını zorlaştırarak, gezegenimizin sıcaklığının yükselmesine neden olmaktadır. Sera gazlarının artışının en büyük nedeni, sanayi devrimiyle birlikte artan üretimdir. Sonuç olarak, küresel ısınma sorunu, ekonomik faaliyetlerden kaynaklandığı için sadece meteorologların değil, çevre ekonomistlerinin de ilgisini çekmektedir (Engin, 2010).

Fosil yakıt ve arazi kullanımından kaynaklanan sera gazı emisyonları 19. yüzyıldan bu yana sürekli artarak 2019 yılında geçmiş zamanların en üst seviyesine

ulaşmıştır. 2015 yılında imzalanan Paris Anlaşması, küresel sıcaklık artışını endüstri öncesi seviyelere göre 1,5°C ve 2°C ile sınırlandırma hedefini belirlemiştir. Ancak, mevcut emisyon artışları, planlanan altyapı yatırımları gözlemlendiğinde, Paris Anlaşması'nın hedeflerinin gerçekleştirilmesi günden güne zorlaşmaktadır (Höhne vd., 2020).

2.3.1. Ulaşım sektöründe sera gazı emisyonları

Günümüzde ulaştırma sektöründe ulaşım amacıyla üretilen enerjinin yüzde 95'i fosil yakıt harcayan motorlardan meydana gelmektedir. Ulaştırma sektörü, bir bütün olarak küresel sera gazı emisyonlarının yüzde 15-18'inden sorumludur. Bunların %70'i karayolu taşımacılığından, %12'si hava taşımacılığından kaynaklanmaktadır. Deniz, iç su yolları ve kanallarla yapılan taşımacılığın toplam emisyonların %11'ini oluşturduğu tahmin edilmektedir. Ayrıca hem yük hem de yolcu taşımacılığı dahil olmak üzere demiryolları da %2'lik bir paya sahiptir (King vd., 2010).



Şekil 2.1. AB Ulaşım Sektörü için Karbon Emisyon Oranları (EEA, 2021).

Şekil 2.1'de görüldüğü üzere karayolları tüm taşımacılık sektörleri arasında en yüksek CO₂ oranına sahip olan sektördür. Diğer tüm bölgelerin emisyonlarının yaklaşık üç katı karayolu taşımacılığından kaynaklanmaktadır. Karayolu lojistiğinin yanı sıra toplu taşımadan özel araç kullanımına geçişte de rol oynamaktadır. Öyle ki ortalama bir aile arabası her yıl çevreye 4,6 ton (t) CO₂ salmaktadır (Taşdemir ve Aydın, 2021). Havacılık sektörünün yıllık %5 büyüme hızının devam etmesi durumunda 2040 yılına kadar 1.700 ila 1.800 ton CO₂'nin doğaya salınacağı öngörülmektedir (EPA).


2.3.2. Havacılık faaliyetlerinden kaynaklanan sera gazı emisyonları

Sanayi devrimi nedeniyle kömür, doğalgaz ve petrol gibi doğal yakıtların kullanımının artmasıyla doğaya salınan CO₂ miktarı artmaya devam etmektedir. 1750 yılında atmosferde yaklaşık 280 ppm olan CO₂, 2005'te 380 ppm'e, 2019'da ise 410 ppm'e ulaşmıştır (Taşdemir ve Aydın, 2021).

Uluslararası Sivil Havacılık Örgütü (ICAO) ve Avrupa Birliği (AB) tarafından Uluslararası Havacılığa Yönelik Karbon Denkleştirme ve Azaltma Şeması (CORSIA) ve Avrupa Birliği Emisyon Yasası (EEA), salınım miktarlarını azaltmak veya sabit tutmak için belirli koşullar içinde Avrupa Birliği Emisyon Ticareti Programı EU-ETS programları başlatılmıştır (Taşdemir ve Aydın, 2021). Havalimanı emisyonları, özellikle çevre üzerinde çok sayıda şekilde etkiye sahiptir. Havalimanları, LTO döngüsü, yer hizmetleri ve ofis binaları gibi faktörler, karbon ayak izine katkıda bulunmaktadır (Durmaz vd., 2007).

2.3.2.1. Havalimanında karbon emisyonuna neden olan faktörler

Havalimanlarında uçaklar, otomobiller ve bazı araçlar; yakıt yanmasının kararı olarak emisyon oluştururlar. Uçak motorlarından meydana gelen emisyonlar ortalama olarak %70 CO₂ ve %30 H₂O'dan oluşmaktadır. Bu emisyonların %1'den daha az bölümü ise NO_x, SO_x, CO, kısmen yanmış ve yanmamış HC, partikül madde ve öteki iz bileşiklerden oluşmaktadır. Havalimanı emisyonlarının uçaklar haricindeki kaynakları ise servis otobüsü, uçakların servisini elde eden yer yardımcı ekipmanlarıdır (Masiol ve Harrison, 2014).



Şekil 2.2. Bir havalimanında karbon emisyonu oranları (BDL, 2020).

Havalimanları kaynaklı bir diğer emisyon kaynakları ise havalimanlarında elektrik elde eden yedek güç birimleri (APU) ve durağan havalimanı güç kaynaklarıdır. Bu kaynaklar da genel hatlarıyla fosil yakıtlar yakar ve buna benzer emisyonları üretir (FAA, 2015). Aşağıda Münih Havalimanı için karbon emisyonu oranları verilmiştir. Şekil 2.2.'de Görüldüğü üzere havalimanında emisyona sebep olan faktörlerden en yüksek orana sahip kapsam, havalimanı iş ortamından kaynaklanan dolaylı emisyonlardır.

2.3.2.2. Uçak kaynaklı sera gazı emisyonları

Uçak kaynaklı meydana gelen emisyonlar havalimanlarında görülen en yoğun emisyon kaynaklarından ve literatürde bulunan çalışmaların birçoğu uçak emisyonlarına odaklanmaktadır. IPCC (Hükümetlerarası İklim Değişikliği Paneli/ Intergovernmental Panel on Climate Change) raporlarına göre, yanma ürünü olarak meydana emisyonların %72'si CO₂, %27,6'sı H₂O'dan oluşurken %1'den daha az bir bölümü kalıntı ürünlerden oluşmaktadır (Masiol ve Harrison, 2014). Uçak gazı emisyonlarını oluşturan sera gazları; Karbon dioksit (CO₂), Karbon monoksit (CO), H₂O (Su Buharı), Azot Oksitler (NO_x), Nitröz Oksit (N₂O), Kükürt Oksitler (SO_x), Ozon (O³), Hidrokarbonlar (HC), Metan (CH₄), Partikül Madde (PM), Metan Haricindeki Uçucu Organik Bileşiklerdir (Özgünoğlu, 2017).

Karbondioksit (CO₂) atmosferin ısınmasına katkıda bulunan bir sera gazıdır ve Dünya'ya gelen ve Dünya'dan giden radyasyon dengesinin dengelenmesi. CO₂ emisyonlarının birincil kaynağı fosil yakıtların yakılmasıdır. CO₂ yaklaşık 200 yıllık bir atmosferik ömre sahiptir. Havacılık yakıtı dünya çapında en yaygın kullanılan fosil yakıtlardan biridir ve tüm fosil yakıt kullanımının %2-3'ünden sorumludur. Tüm ulaştırma sektörüyle karşılaştırıldığında, sivil havacılık tüm fosil yakıt tüketiminin sadece %2-3'ünden sorumludur. Özellikle jet gazyağı, sivil havacılıkta en yaygın kullanılan yakıttır ve toplam yakıt tüketiminin yaklaşık %20-25'ini oluşturmaktadır. (Gössling ve Upham, 2009).

Karbonmonoksit gazı, kokuya ve renge sahip olmayan bir sera gazı türüdür. CO gazının oluşmasındaki ana sebep Karbon bulunan yakıtların tam anlamıyla yanmamasından dolayı oluşmaktadır. Araçlarda karbon monoksit oluşumu, yanma verimliliğinin artırılması ve emisyon kontrol yöntemlerinin geliştirilmesi ile azaltılabilmektedir. CO genel anlamda motorlu taşıtlar, ev ısıtması, sanayi emisyonları ve biyokütle yanması gibi yanma süreçleri tarafından atmosferde üretilir. CO, 30 ve 90 gün

aralığında deęiřen bir süreye sahiptir. CO gazının, saęlık üzerindeki etkileri özellikle buna maruz kalan canlılarda kanın oksijen kapasitesini azaltması bakımından olumsuzdur, bu da kanın oksijen kapasitesini karboksihemoglobin formuna dönüřtürür. Bu durum solunum, sinir ve dolařım sistemlerinde birtakım hastalıklara neden olabilmektedir (Samoli vd., 2007).

Hidrojen ve karbondan oluřan hidrokarbonlar (HC), petrol ürünlerinin yanmasıyla oluřur. Yakıt tam olarak yanmadığında, HC üretilir ve bu da havaya karıřır ve sıcaklıęı artıran kötü kokulu bir gaza neden olur. Bu durum, motorlu taşıtlarda kullanılan benzin yakıtlarının eksik yanması sonucu ortaya çıkan yaygın bir durumdur. Sonuç olarak etilen ve benzen de dahil olmak üzere hidrokarbonlar üretilir. Bu hidrokarbonlar havadaki dięer kimyasallarla birleřtięinde canlı organizmalar üzerinde zararlı etkilere neden olabilir (Kutlar ve Arslan, 1998).

Azot oksit (NO_x), yüksek sıcaklık altında yanma iřlemi sonucunda ortaya çıkan renksiz ve kokusuz bir gazdır. Yanmanın tüm ařamalarında ortaya çıkar ve azot oksitler ařaęıdaki reaksiyonla oluřur. Yanma iřlemi sırasında nitrojen ve oksijenden oluřur. Azot oksit oluřumu hem yanma sıcaklıęına hem de motora baęlıdır. Motorun ilk alıřtırılmasında nitrojen oksitler düşük deęerlere sahiptir (Aydoęan B, 2008).

Sülfür dioksit (SO_2), atmosferdeki birincil hava kirleticilerden biridir ve endüstriyel üretimden kaynaklandıęı için doğrudan sülfür oksitlerle iliřkilidir. Yaklařık %80'i endüstriyel üretimden kaynaklanan SO_2 emisyonlarının çoęunluęu fosil yakıtların yanması sonucunda oluřur. SO_2 emisyonlarının büyük bir kısmı Avrupa ve Kuzey Amerika'da meydana gelirken, havacılıęın SO_2 emisyonlarına orantısız bir katkısı olduęunu belirtmek gerekir. SO_2 emisyonları ciddi saęlık sorunlarına neden olabilir ve küresel olarak 132 milyon ton ve 50-75 milyon ton arasında antropojenik emisyonu sebep olmaktadır. Avrupa'da yılda 20 milyon tondan fazla tüketilen sülfür olup, İngiltere Batı Avrupa'daki en büyük emisyon kaynaęıdır. Sadece İngiltere'de 2,56 milyon ton sülfür dioksit emisyonu meydana gelmektedir (Sonsuz vd., 2011).

2.4. Havacılıkta Karbon Emisyonları Üzerine Yapılan alıřmalar

Bu kısımda hava taşımacılıęındaki karbon emisyon salınımları ile ilgili alıřmalar özellikle son yıllarda yapılmıř alıřmalar dikkate alınarak incelenmiřtir

Stefanis vd. (2025), Alexandroupolis Havalimanı'ndaki 2019-2020 dönemindeki hava kalitesindeki emisyon farklarını incelemiřtir. Yöntem olarak Bayes ve doğrusal

regresyondan yararlanmışlardır. Çalışma sonucunda, 2020 yılında, COVID-19 kısıtlamaları nedeniyle CO₂ emisyonları %28,1, NO_x emisyonları %26,5 ve PM_{2.5} emisyonları %35,4 oranında azalmıştır. COVID-19 Pandemisinde yaşanan sınırlamalar esnasında emisyonların %28 ila %35 değerlerinde yer almaktadır ve geliştirilen modellerin PM_{2.5} yoğunluğunu yüksek doğrulukla tahmin edebildiği belirtilmiştir.

Mahendra vd. (2024), Endonezya'da havacılık emisyon tahmini için yapay sinir ağı modelleri olan LSTM ve GRU derin öğrenme yöntemlerini kullanarak en uygun yöntem olarak LSTM olarak belirlemişlerdir. Sinir ağıları %87'lik bir doğruluk oranına sahip olmuştur ve GRU modellerinden daha başarılı tahmin sonuçları verdiği ifade edilmiştir.

Pitanova vd. (2023), Endonezya'da bulunan beş farklı havalimanında uçuş süreleri, yakıt tüketimi ve emisyonlar arasındaki ilişkiyi analiz etmiştir. Yakıt tüketimi, uçuş sayısına göre hesaplanırken, CO₂ emisyonları ise ICAO'nun belirlediği metodolojiye uygun bir şekilde belirlenmiştir. Sonuçlarda gerçek yakıt tüketiminin 405.036 kg, planlanan yakıt tüketiminin ise 43.819 kg olduğunu göstermiştir. Emisyonlar açısından, kişi başına düşen gerçek değerler 7.585 kg olarak belirtilmiş, planlanan değeri ise 8.143 kg olarak hesaplanmıştır.

Kaika (2023), Havacılık emisyonlarının gelecek perspektifinden eğilimlerini değerlendirmek adına KAYA kimliği ve senaryo analizleri kullanmıştır. Çalışma, talep azaltım stratejilerinin emisyonları %61 oranında düşürebileceğini göstermekte ve sürdürülebilir havacılık yakıtlarının (SAF) yaygınlaştırılmasını önermiştir.

Orhan (2021), Ordu-Giresun Havalimanı'nda ticari uçak kaynaklı 2017 yılındaki LTO döngüsü safhasında meydana gelen emisyon miktarlarını analiz etmek amacıyla bir çalışma yapmıştır. Elde edilen verilere göre, uçakların yıllık yakıt tüketimi 6.551,52 ton olarak belirlenmiştir. CO emisyonları 66.81 ton, HC emisyonları 4.20 ton ve NO_x emisyonları ise 79.97 ton olarak tahmin edilmiştir. Elde edilen bulguların havalimanı emisyon yönetimi açısından önemli olduğu belirtilmiştir.

Acharya ve Bhattarai (2021), tarafından Katmandu havalimanındaki CO₂ emisyonları üzerine yapılan bu çalışmada 2016-2018 yılları arasında sırasıyla 56,55 ton, 65,66 ton ve 71,89 ton emisyon olduğu belirlenmiştir. Çalışma, uluslararası uçakların emisyonlara en büyük katkıyı yapan unsur olduğunu, Yer Destek Ekipmanlarının ise yakıt tüketiminin yalnızca %0,91'ini temsil ettiğini ortaya koymaktadır. 2030 yılına kadar emisyonlar iki katına çıkabileceği ve elektrikli GSE kullanımının CO₂'yi %80 oranında azaltabileceği belirtilmiştir.

Yu vd. (2020), Çin Havacılık endüstrisi için karbon emisyonu tahmin modeli geliştirmiştir. Genişletilmiş Log-Ortalama Divisia Endeksi (LMDI), Tapio ayırma modeli ve bir emisyon tahmini modeli kullanılmıştır. Sonuç olarak Çin'in sivil havacılık sektörünün 2020 yılına kadar 0,13 Gt CO₂ emisyonundan sorumlu olacağı tahmin edilmiştir.

Ünal vd. (2014), Nevşehir Kapadokya (Türkiye) Havalimanından kaynaklanan sera gazı emisyonlarını IPCC metodolojisi kullanarak değerlendirilmiştir. Çalışmada havalimanı kaynaklı sera gazı emisyonları hesaplanmış ve elde edilen sonuçlar mevzuat sınır değerleri ile karşılaştırılmıştır.

Akyüz vd. (2019), Muğla'daki Dalaman havalimanının 2017 yılındaki uçuşlardan kaynaklanan karbon salınımlarının IPCC tarafından belirlenen Tier yöntemleri kullanılarak analiz etmiştir. Sonuçlar, emisyonların büyük ölçüde turizm yoğunluğunun yüksek olduğu temmuz ve ağustos aylarında arttığını göstermiştir. Ayrıca Boeing 737 uçak tipinin en fazla emisyonu neden olduğu belirlenmiştir.

Terrenoire vd. (2019), sivil havacılığın CO₂ emisyonlarının iklimsel etkisini değerlendirmek için OSCARv2.2 Dünya Sistem Modelini kullanmıştır. Çalışma, 1940'tan 2100'e kadar bir dizi emisyon senaryosunu ve azaltma seçeneklerini inceleyerek, havacılık CO₂'sinin uzun vadeli antropojenik ısınmaya önemli ölçüde katkıda bulunabileceğini ortaya koymaktadır. Etkili azaltım stratejilerinin yokluğunda, havacılık emisyonları 2100 yılına kadar toplam ısınmanın %5,2'sini oluşturabileceği belirtilmiştir. Bu durum, havacılığın iklim üzerindeki etkisini sınırlandırmak için ciddi emisyon azaltma tedbirlerinin uygulanması gerekliliğini vurgulamaktadır.

Kito vd. (2020), 2005-2015 yılları arasında Japonya'nın iki büyük havayolu şirketi tarafından gerçekleştirilen uluslararası uçuşlardan kaynaklanan CO₂ emisyonlarını tahmin etmiştir. Çalışmada emisyonlara katkıda bulunan faktörleri belirlemek için bir endeks ayrıştırma analizi yapılmıştır. Ayrıca havacılıktan kaynaklanan aerosol kuvvetlerinin iklim üzerindeki etkileri de değerlendirilmiştir.

Akdeniz (2022), Türkiye'de Hasan Polatkan Havalimanı'nda gerçekleştirilen bu çalışma, uçak emisyonlarının çevresel ve ekonomik etkilerini değerlendirmeyi amaçlamaktadır. Çalışma, uçak ve uçuş türlerine göre emisyonları analiz ederek ve Küresel Isınma Potansiyeli (GWP) ve Çevresel Etki (EI) yöntemlerini kullanarak, hidrokarbonlar (HC), karbon monoksit (CO) ve nitrojen oksitler (NO_x) gibi kirleticilerin etkilerini değerlendirmektedir. Sonuçlar, taksi süresinin azaltılmasının emisyonları %1-6

oranında azaltılabileceğini ve Airbus A321 modelinin genel olarak en yüksek emisyonu katkıda bulunduğunu göstermektedir.

Liu vd. (2022), çalışmalarında gelişmiş nokta ve aralık tahminleri için çok amaçlı bir tanjant arama algoritması kullanarak hassas günlük karbon emisyonu tahmini için gelişmiş bir topluluk sistemi tanıtmışlardır. Sonuçlar, veri kümeleri arasında %1,1102 ve %1,1382'lik ortalama mutlak yüzde hataları (MAPE) ile doğrulukta kayda değer bir artış olduğunu göstermektedir. Bu da sistemi emisyon azaltma planlaması yapan politika yapımcılar için değerli bir araç haline getirmektedir.

Champeecharoensuk vd. (2024), tarafından COVID-19 öncesi dönemde Tayland'da iç hat ticari havacılıktan kaynaklanan sera gazı emisyonlarının tahmini ve analizi yapılmıştır. Tier 2 yöntemi ve Endeks ayrıştırma yöntemi (Decomposition method) ile yaparak 2015-2020 yılları için Tayland'daki ticari yurt içi havacılık kaynaklı toplam yıllık emisyonları 2.254 ton CO₂ eşdeğer olarak tahmin edilmiştir.

Guo vd. (2023), çalışmalarında 2050 yılına kadar çeşitli senaryolar altında Çin'de sivil havacılıktan kaynaklanan CO₂ ve hava kirletici emisyonlarındaki potansiyel değişikliklerin projeksiyonlarını sunmaktadır. İç hatlarda 235 havalimanındaki emisyonları analiz eden çalışma, özellikle seyir modundaki emisyonların toplamın %87-93'ünü oluşturduğunu, hidrokarbon (HC) ve karbon monoksit (CO) emisyonlarının ise iniş-kalkış (LTO) döngüsünde daha yoğun olduğunu göstermektedir. Senaryo analizlerinin sonuçları, uçuşlarda düşük emisyonlu yakıt kullanımı gibi tedbirlerin uygulanması yoluyla emisyonların 2030 yılına kadar %15 ila %26, 2050 yılına kadar ise %71 ila %93 oranında azaltılabileceğini göstermişlerdir.

Tokuslu (2020), Gürcistan'daki Tiflis Uluslararası Havalimanı'nda 2018 yılı için LTO döngüleri sırasında uçaklardan kaynaklanan nitrojen oksitler, karbon monoksit ve hidrokarbonlar dahil olmak üzere hava kirleticileri Tier 2 Yöntemi ile tahmin etmiş ve 2018 yılı boyunca toplam uçak emisyonlarının 428,78 t/y olduğunu tahmin etmiştir. Ayrıca, taksi süresindeki azalmanın LTO emisyonlarında %5'lik bir düşüşe yol açabileceğini öngörmüştür.

Turan (2020), İstanbul Havalimanı'nda jet yakıtlı ticari uçaklardan kaynaklanan yıllık sera gazı emisyonları Tier 2 yöntemini kullanarak hesaplamıştır. İstanbul Havalimanı'nda 2019 yılında faaliyet gösteren uçak tiplerini belirleyerek havalimanlarında ticari uçaklar tarafından salınan başlıca sera gazları için ayrıntılı bir değerlendirme yapmıştır. Sonuçlar, 2019 yılında İstanbul Havalimanı'nda 1.230.247 ton

CO₂, 34 ton HC, 6.300 ton NO_x, 2.915 ton CO ve 390 ton SO₂ emisyonu kaydedildiğini göstermiştir.

Lukačević vd. (2022), Podgorica Havalimanı'ndaki uçak operasyonlarının simülasyonunu kullanarak Uçak emisyonlarının hesaplanması için bir simülasyon modeli oluşturmuştur. Simülasyon sonuçları, Eurocontrol-IMPACT tarafından elde edilen sonuçlarla karşılaştırılması sonucu, Podgorica Havalimanı'nın henüz ciddi çevresel sorunlar yaratmayan küçük bir havalimanı olduğunu göstermiştir. Tüm yoğun gün için emisyonlar, Belgrad Havalimanı'ndaki dört saatlik yoğun dönemdeki emisyonlarla aynı seviyede olduğu tespit etmiştir.

Yang ve O'Connell (2020), Şangay'da Tüm yolcu uçuşları için hava taşımacılığı CO₂ emisyonlarını iki aşamalı bir model ile CO₂ emisyonları tahmin yöntemi geliştirmiştir. Otoregresif Entegre Hareketli Ortalama ARIMA lineer modeli ile tahmin ederek 2021 Haziran sonuna kadar atmosfere 36,49 milyon ton CO₂ salınacağını ortaya koymuştur.

Huang vd. (2023), Çin havacılık endüstrisindeki CO₂ emisyonlarını azaltmak ve gelecekteki emisyonları Filo genelinde indeks ayrıştırma ve senaryo analizi modeli ile senaryo analizi, havacılık CO₂ emisyonlarının farklı senaryolarda nasıl değişeceğini tahmin etmiştir.

L. Yang vd. (2023) ayrıştırma ve tahmin yöntemlerini bir arada kullanarak farklı senaryolar altında Çin havacılık sektöründeki CO₂ emisyonlarını incelemiştir. Çalışma, ekonomik büyüme ve trafik artışının emisyonlar üzerinde önemli bir etkiye sahip olduğunu göstermiştir.

Pamplona ve Alves (2020), Salvador Havalimanı'nda iç hat uçuşlarına ait 2015 uçuş programını ve 2014 başlangıç verilerini kullanarak, ekonomik büyümeye bağlı yolcu talebini ekonometrik bir modelle tahmin etmiş ve IPCC emisyon faktörlerine dayalı LTO çevrimi yaklaşımıyla 2020 yılına kadar havacılık kaynaklı emisyonları ileriye dönük olarak tahmin etmiştir. Çalışma, artan hava trafiğinde yıllık %0.744 talep artışının 2020'ye kadar emisyonlarda %65 artışa yol açacağını göstermiştir.

Hassan vd. (2018), Havacılık endüstrisi için CO₂ emisyon hedeflerinin olasılıksal olarak Kısmi denge modeli ve Monte Carlo simülasyonları kullanılarak hedeflerin ulaşılabilirliğinin analizini yaparak Biyoyakıtların 2050'ye kadar toplam tasarrufların %64'ünden sorumlu olduğu (havacılık teknolojilerinin %31 ve operasyonel iyileştirmelerin %5 olduğu) belirtmiştir.

Zhou vd. (2019), Çin'deki iniş ve kalkış (LTO) döngüleri sırasında sivil uçaklardan kaynaklanan hava kirletici emisyonların tahminini iyileştirmeyi amaçlamaktadır. Araştırmacılar, detaylı uçuş verilerini ve gerçek zamanlı meteorolojik koşulları bir araya getirerek daha doğru emisyon tahminleri geliştirmişlerdir. Sonuçlar, emisyonlarda önemli farklılıklar göstermekte ve geleneksel yöntemlerle olan tutarsızlıkları vurgulamaktadır. Araştırma, etkili çevre politikalarının oluşturulmasını desteklemek ve havacılık sektörünün hava kalitesi üzerindeki etkisini azaltmak için daha gelişmiş tahmin tekniklerine duyulan ihtiyacı vurgulamışlardır.

Yu vd. (2020), Havacılık endüstrisi için karbon emisyonunu Genişletilmiş log-ortalama Divisia endeksi modeli (LMDI), Tapio ayırma modeli ve bir emisyon tahmini modeli kullanılarak Çin'in sivil havacılık sektörünün 2020 yılına kadar 0,13 Gt CO₂ emisyonundan sorumlu olacağını öngörmüştür.

Genç (2022), Malatya Erhaç havalimanında yapılan bir çalışmada 2016-2020 yılları arasında uçaklardan kaynaklanan kirletici gazların emisyon miktarını hesaplamıştır. Toplamda 66.331,05 ton CO₂, SO_x, H₂O, HC, CO, NO_x ve PM olduğu tahmin etmiştir. Bu emisyon miktarının belirlenmesi, havacılık sektöründeki çevresel etkilerin değerlendirilmesi açısından önemli olduğunu belirtmiştir.

Çin'deki 241 havalimanını kapsayan bir çalışmada K. Wang vd. (2022), ICAO hesaplama yöntemini, regresyon analizini ve senaryo yaklaşımlarını birleştirmiştir. Sonuçlar, CO₂ emisyonlarının 2035 yılına kadar yaklaşık %50 artmasının beklendiğini göstermiştir.

Çizelge 2.1. Havacılık sektöründe emisyon tahmini alanında yapılan bazı çalışmaların özeti

Araştırmacı	Havalimanı/Bölge	Kullanılan Yöntem	Bulgular
Stefanis vd., (2025)	Alexandroupolis, Yunanistan	Bayesyen / Doğrusal Regresyon (ML)	COVID-19 emisyonları %28–35 oranında azaltmıştır; ML PM2.5'i doğru tahmin ediyor
Mahendra vd., (2024)	Endonezya	LSTM ve GRU	Sinir ağları %87'ye kadar doğruluk sağlamıştır; LSTM uzun dönem için daha iyi
Champeechoensuk vd., (2024)	Tayland	Tier 2 + Ayırıştırma	2015–2020 döneminde iç hat havacılığı 2.254 ton CO ₂ salmıştır
Kaika, (2023)	Küresel	Kaya kimliği + senaryolar	Talep azaltımı %61 emisyon azaltabilir.
Guo vd., (2023)	Çin (235 havalimanı)	Senaryo analizi	Seyir modu emisyonların %87–93'ünü oluşturmaktadır
Pitanova vd., (2023)	Endonezya	ICAO yakıt-modeli	Gerçek yakıt tüketimi planlanandan düşük

Çizelge 2.1.(devam) Havacılık sektöründe emisyon tahmini alanında yapılan bazı çalışmaların özeti

Araştırmacı	Havalimanı/Bölge	Kullanılan Yöntem	Bulgular
L. Yang vd., (2023)	Çin havacılığı	Ayrıştırma + tahmin	CO ₂ emisyonları farklı senaryolar altında tahmin edildi
K. Wang vd., (2022)	Çin (241 havalimanı)	ICAO + Regresyon + Senaryolar	CO ₂ 'nin 2035'te 1,5 kat artması bekleniyor
Akdeniz, (2022)	Türkiye (Hasan Polatkan)	Tier 2	Taksi süresi azaltılırsa %1–6 düşüş sağlanabilir
Wan vd., (2022)	Çin	Ensemble sistem	MAPE ~%1,1; çok yüksek doğruluk
Lukačević vd., (2022)	Karadağ (Podgorica)	Simülasyon	Küçük ve orta ölçekli havalimanlarında standart LTO taksi sürelerinin emisyonları fazla tahmin edebileceği belirtilmiştir.
Genç, (2022)	Malatya (Türkiye)	Tier 2	Toplam emisyon (2016–2020): 66.331 ton
Orhan, (2021)	Ordu–Giresun (Türkiye)	ICAO LTO hesaplama	Yakıt: 6.551 ton; NO _x : 79.9 ton
Acharya ve Bhattarai, (2021)	Katmandu	Tier 2 + Senaryolar	Emisyonlar 2030'da iki katına çıkabilir
Klöwer vd., (2021)	Küresel	Sayısal model + Senaryolar	2050'ye kadar 0.1°C ısınmaya neden olabilir
H. Yang ve O'Connell, (2020)	Şanghay	Bottom-up + ARIMA	2021 CO ₂ artışı %6.41 tahmin edildi
Tokuslu, (2020)	Tiflis	ICAO Tier 2 + Senaryolar	LTO %50 artarsa emisyon %55–60 artar
Pamplona ve Alves, (2020)	Salvador	Ekonometri + talep tahmini	Yıllık %0.744 talep artışının 2020'ye kadar emisyonlarda %65 artış oluşturabileceği gözlemlenmiştir.
Turan, (2020)	İstanbul Havalimanı	Tier 2	2019 CO ₂ : 1,23 Mt; NO _x : 6300 ton
Kito vd., (2020)	Japonya (Uluslararası)	Yakıt-bazlı hesap	2005–2015 CO ₂ eğilimleri
Zhou vd., (2019)	Çin	Geliştirilmiş LTO tahmini	Gerçek meteoroloji emisyon hesaplarını değiştirir
Ünal vd., (2014)	Nevşehir (Türkiye)	Tier 2	GHG emisyonları hesaplandı

Çizelge 2.1'de bulunan özet literatür çizelgesi incelendiğinde, havacılık sektörü kaynaklı emisyonların gelecek tahmininde birçok farklı yöntemin kullanıldığı görülmektedir. 2010-2025 yılları arasındaki çalışmalar, ICAO ve IPCC tabanlı hesaplamalardan genellikle ARIMA, regresyon modelleri, ayrıştırma yöntemleri ve LSTM/GRU gibi ileri Makine Öğrenmesi gibi yöntemlerin ve senaryo analizlerinin de uygulandığı görülmektedir. Bu kapsamda yapılan çalışmalar incelendiğinde, havacılık emisyonlarının geleceğe yönelik tahmininde Tier II hesaplama metodolojisi, uzman görüşlerine dayalı ÇKKV yöntemi (AHP) ve ileri seviye Makine Öğrenmesi algoritmalarının birlikte kullanıldığı bütünleşik ve çok aşamalı bir karar destek modeline rastlanmamıştır. Mevcut çalışmalar genellikle bu yöntemleri ya ayrı ayrı ya da sınırlı kombinasyonlar halinde ele almaktadır. Bu çalışma ise emisyon faktörlerini

önceliklendiren, operasyonel verileri yüksek doğrulukla tahmin eden ve elde edilen sonuçları senaryo analizleri ile destekleyerek verimli filo yapısının emisyon azaltım potansiyelini somut verilerle ortaya koyan bütünleşik bir yaklaşım sunmaktadır. Bu yönüyle literatüre katkı sağlaması amaçlanmaktadır.



3. MATERYAL VE YÖNTEM

Bu bölümde, emisyonların hesaplanması için kullanılacak yöntem olan Tier 2 yöntemi ve bu yöntemin kullanım alanı ele alınacaktır. Ardından uzman görüşlerine dayalı ÇKKV yöntemleri açıklanacak, son olarak emisyonların geleceğe yönelik tahminlerinde kullanılacak zaman serisi ve makine öğrenmesi yaklaşımlarına yer verilecektir.

3.1. Tier 2 Yöntemi

1972 yılında kurulan Birleşmiş Milletler Çevre Programı (UNEP-United Nations Environment Programı) ve Dünya Meteoroloji Örgütü (WMO-World Meteorological Örgütü) öncülüğünde 1988 yılında IPCC kurulmuştur. IPCC, uzman kadrosu ile iklim değişikliği konusunda bilimsel değerlendirmeler yapmakta ve bu bilgileri raporlamakla yükümlüdür (Genç ve Behçet, 2022).

Bu çalışma, IPCC'nin 'Enerji' başlığı altındaki 'Mobil Kaynaklardan Emisyonlar' bölümünü kullanarak enerji sistemlerinden ve ulaştırma sektöründen kaynaklanan emisyonların hesaplanmasına odaklanmaktadır. Çalışma, CO₂, NO_x, PM, CO, HC emisyonlarını içeren bir emisyon envanterinin oluşturulmasını ele almaktadır. Ulaştırma sektöründeki emisyonlar doğrudan yakıt yanması ile ilgilidir. Emisyon hesaplama yöntemleri farklı seviyelere ayrılmakta ve bu seviyelerin belirlenmesinde "Tier" kavramı kullanılmaktadır. Tier 1 yöntemi daha az veri gerektiren basit bir yöntem iken, Tier 2 yöntemi daha kapsamlı ve detaylı veri gerektiren bir yöntem olarak tanımlanmaktadır (IPCC, 2006). Bu emisyonlar IPCC'nin belirlediği Tier 1 veya 2 yöntemleri kullanılarak tahmin edilebilir (Bo vd., 2019).

Aşağıda yer alan Çizelge 3.1.'de referans alınan uçak tipleri ve emisyon faktörleri kg/LTO cinsinden verilmiştir. Çizelgede yer alan uçak tipleri ile DHMİ tarafından sağlanan uçak tipi ve LTO sayıları ile referans alınan emisyon faktörleri çarpılarak emisyonlar hesaplanmıştır.


Çizelge 3.1. ICAO tarafından yayınlanmış ve çalışmada referans alınan uçak tiplerine ait emisyon faktörleri (kg/LTO) (ICAO, 2020)

Uçak Tipi	CO ₂ (kg/LTO)	HC (kg/LTO)	NO _x (kg/LTO)	CO (kg/LTO)	SO ₂ (kg/LTO)	Toplam partikül madde kütlesi (kg/LTO)	Yakıt Tüketimi (kg/LTO)
Airbus A320	2665	0,34	9,90	8,14	0,42	0,17	843
Airbus A321	3195	0,17	16,23	5,81	0,51	0,23	1011
Airbus A330-200/300	7052	1,28	35,57	16,20	1,12	0,21	2232
Airbus A350-900	6756	0,94	39,81	20,27	1,07	0,20	2138
Airbus A380	11952	3,70	69,42	39,06	1,89	0,34	3782
Boeing 737-800/900	2784	0,72	12,30	7,07	0,44	0,12	881
Boeing 747-400	10245	2,25	42,88	26,72	1,62	0,24	3242
Boeing 757-200	4317	0,22	23,43	8,08	0,68	0,11	1366
Boeing 767-300	5608	1,19	28,19	14,47	0,89	0,17	1775
Boeing 777-200/300	7197	1,35	37,47	16,60	1,14	0,18	2277
CRJ-900	1517	0,04	4,40	4,12	0,24	0,03	480
ERJ-145	993	0,56	2,69	6,18	0,16	0,02	314
BAE 146	1801	1,41	4,07	11,18	0,29	0,07	570
Dornier 328 Jet	868	0,57	2,99	5,35	0,14	0,04	275
Gulfstream IV	2030	0,55	4,99	8,25	0,32	0,07	642
Cessna 525/560	458	1,66	0,28	16,20	0,07	0,05	145
DHC8-100	658	0,00	1,55	2,27	0,10	0,07	208
ATR72-500	641	0,29	1,88	2,35	0,10	0,07	203

Çizelge 3.1, Uçak tiplerine göre LTO başına CO₂, NO_x, CO, HC, SO₂, PM emisyonlarını (kg/LTO) göstermektedir. Çizelgenin tamamı EK-1’de verilmiştir. Çizelge 3.1’de yer alan değerler çizelgenin kısa özetiştir. Bu çalışmada elde edilen veriler ışığında, karbon emisyonları, çizelgedeki uçak tiplerinin LTO sayısı ile çarpılarak hesaplanmıştır.

3.1.1. Havalimanında uçakların LTO (iniş/kalkış) döngüsü

ICAO tarafından açıklanan LTO (iniş/kalkış, landing/takeoff) döngüsü kavramı, uçuşun 3000 ft ve altında meydana gelen uçuş safhaları için yapılır Hava kirleticileri çoğunlukla 3000 ft yüksekliğinde atmosfere karışmaktadır. Canlıların en fazla maruz kaldığı seviye olmasından ötürü birçok hava kalitesi çalışması bu yükseklik değerini standart olarak varsaymışlardır (Yay vd., 2014).



Şekil 3.1. LTO döngüsü (EASA, 2016)

LTO döngüsü iniş (yaklaşma, iniş ve taksi) ve kalkış (piste taksi, kalkış ve tırmanış) olmak üzere iki uçak sürecini kapsamaktadır (ICAO, 2011). Kalkış taksi aşaması, uçağın park pozisyonundan ayrılmasından pistin başlangıcına ulaşmasına kadar geçen süreyi içerir. Kalkış aşaması, uçağın pisti terk ettiği süreyi ifade eder. Bunu, uçağın kalkıştan sonra kazandığı irtifa olarak tanımlanan ve aşağıdaki süreyi kapsayan tırmanma aşaması olan 3000 feet (1000 metre) yüksekliğe kadar takip eder. Son olarak, yaklaşma aşaması uçağın inişe hazırlandığı aşamadır. Uçak motorlarının bu özel LTO döngüsü için tasarlandığına dikkat etmek oldukça önemlidir (Genç ve Behçet, 2022).

ICAO, 1960'ların sonu ve 1970'lerin başında uçak motoru emisyon standartlarının hesaplanması için LTO döngüsündeki faz sürelerini belirlemiştir. LTO döngüsünün tüm çalışma modlarındaki yakıt tüketimi ve emisyon oranları ve süreleri farklılık göstermektedir. Bunlar uçak tipine, meteorolojik koşullara ve havalimanındaki operasyonel hususlara dayanmaktadır. Bu çalışmada, yaklaşma, taksi, kalkış ve tırmanma süreleri ICAO standart LTO döngüsünden alınmıştır (ICAO, 2020).

Çizelge 3.2. Referans emisyon iniş ve kalkış (LTO) döngüsü süreleri (ICAO, 2020)

Operasyonel Aşama	Mod Süresi (Dakika)	İtki Ayarı (Maksimum Gücün %'si)
Approach (Yaklaşma)	4,0	30%
Taxi and ground idle (Taksi ve Yer rölanti)	26,0 Toplam (7,0 giriş / 19,0 çıkış)	7%
Take-off (Kalkış)	0,7	100%
Climb (Tırmanış)	2,2	85%

Yukarıda Çizelge 3.2’de yer alan ICAO tarafından belirlenen referans emisyon LTO döngüsü süreleri verilmiştir. Çalışmadaki LTO süreleri bu değerler referans alınarak emisyon hesaplama yöntemi değerleri ICAO emisyon çizelgesinde verilmiştir. Çalışmanın devamında bu yönteme yani Tier 2 yaklaşımından ve uygulanmasından söz edilecektir.

3.2. Çok Kriterli Karar Verme Yöntemleri

Çok kriterli karar verme uygulamalarında, kriterlerin tutarlı ve doğru bir şekilde ağırlıklandırılması karar sonuçlarının doğruluğu ve güvenilirliği açısından oldukça önemlidir. Güncel çalışmalarda, Analitik Hiyerarşi Süreci (AHP) ve En iyi-en kötü yöntemi (BWM) gibi karar verici odaklı yöntemler ile Entropi gibi veri temelli yaklaşımların bir arada kullanıldığı bütünleşik modellere olan ilgi artmaktadır. Bu tür yaklaşımlar hem nitel uzman yargılarını hem de nicel veri dinamiklerini sürece dahil ederek sonuçların güvenilirliğini maksimize etmektedir. Belirlenen bu ağırlıklar üzerinden alternatifleri sıralamak için literatürde farklı yöntemlerin farklı çözüm kümeleri sunabileceği vurgulanarak çok boyutlu bir bakış açısı teşvik edilmektedir (Çayır Ervural, 2026). Bu durum, kullanılan yöntemin karar verme süreci üzerindeki etkisinin önemli olduğunu göstermektedir.

3.2.1. Analitik hiyerarşi süreci (AHP) yöntemi

AHP tekniği 1980’li yıllarda Thomas L. Saaty tarafından yürütülen araştırma çalışmalarının bir sonucudur (Saaty, 1987). Araştırmacılar zamanla AHP’nin çeşitli varyantlarını geliştirmiş olsalar da bu bölümdeki amacı aşağıdaki ana hatlarla vurgulamaktır: bu yöntemin temel prosedürünü araç seçimi problemine atıfta bulunarak açıklamaktadır. Genel olarak, bu prosedürü üç ana bölüme ayırmak mümkündür:

Problemin Analizi, Karşılaştırmalı Değerlendirme ve Önceliklerin Belirlenmesi (Janic ve Reggiani, 2002).

Hiyerarşik yapı kurulduktan sonra, kriterler ve alternatifler arasında ikili karşılaştırmalar yapılır. Bu karşılaştırmalar kare matrisler aracılığıyla gerçekleştirilir ve her bir unsur, diğer unsurlarla göreceli önemine göre değerlendirilir. Değerlendirmelerde AHP'nin 1–9 ölçeği kullanılarak önem dereceleri belirlenir. Çizelge 3.3'te numaralandırılma çizelgesi gösterilmiştir (Singh, 2014). Bu aşamada amaç, havalimanı kaynaklı karbon emisyonuna etki eden faktörlerin önem derecelerinin belirlenmesidir.

Çizelge 3.3. Örnek AHP Çizelgesi (Singh, 2014)

Önem yoğunluğu	Tanım
1	Eşit Önem
3	Orta Derecede Önem
5	Güçlü Önem
7	Çok Güçlü Önem
9	Son Derece Önemli
2,4,6,8	2,4,6,8 Ara değerler için
Karşılıklar	Karşılıklar Tersini için Karşılaştırma, eğer i, j'ye 3, o zaman j'den i'ye 1/3

Eşitlik (3.1)'deki formül AHP yönteminin grup kararının tek bir sonuç vermesi amacıyla geometrik ortalamasının alınmasını gösteren formüldür:

$$a_{ij} = \left(\sum_{n=1}^k a_{ij}^{(n)} \right)^{\frac{1}{k}} \quad (3.1)$$

k , karar veren uzman (kişi) sayısı,

a_{ij} , i . kriterinin j kriterine göre göreceli önemini,

$a_{ij}^{(n)}$, n . katılımcının verdiği bireysel puan olarak gösterilmektedir.

Geometrik ortalama yöntemi kullanılarak her bir kriter için öncelik vektörü hesaplanması sonrası ağırlıklar normalize edilmiştir. Elde edilen ağırlıkların tutarlılığı daha sonra en büyük özdeğer (λ_{max}), Tutarlılık İndeksi (CI) ve Tutarlılık Oranı (CR) kullanılarak test edilmiştir. Bu bağlamda, tutarlılık oranı Eşitlik (3.2)'teki gibi hesaplanmıştır:

$$CI = \frac{\lambda_{max} - n}{n - 1}; CR = \frac{CI}{RI} \quad (3.2)$$

3.2.2. Multi-objective optimization by ratio analysis (MOORA) yöntemi

MOORA (Multi-Objective Optimization By Ratio Analysis) yöntemi; ilk olarak 2006 yılında Willem Karel M. Brauers ve Edmundas Kazimieras Zavadskas tarafından bir bütün olarak 2006 yılında ‘Control and Cybernetics’ adlı çalışmaları ile tanıtılmıştır. Bu metodun başlıca öne çıkan üstünlükleri (Ersöz ve Atav, 2011):

- Tüm amaçları dikkate ve değerlendirmeye alması,
- Alternatifler ve amaçlar arası tüm etkileşimler ayrı ayrı değil, aynı anda dikkate alınması,
- Kriterlerin normalize edilerek alternatiflerin objektif olarak karşılaştırılmasını sağlamasıdır.

MOORA yöntemi, çok kriterli karar verme problemlerinin çözümü için bir MCDM tekniği olarak kullanılan bir yaklaşımdır. Bu yöntem, özelleştirme problemleri gibi çok amaçlı ve çelişkili durumları ele alır. MOORA yöntemi, her bir alternatifin performansını temsil eden bir ölçüm skalasına göre oran sistemlerine dayalı olarak sıralama yapar. Bu yöntem, adımları takip ederek uygulanır. Ancak yöntemin kullanılabilmesi için bazı varsayımlar yapılması gerekmektedir. Bu varsayımlar arasında, kardinal sayıların kullanılması, alternatiflerin seçimiyle ilgili sürekli ölçeklerin tercih edilmesi ve niteliklerin hedef tanımıyla ilişkili olması yer alır. Örneğin, farklı performans derecelendirme kriterleri belirlenir. MOORA yöntemi, mevcut alternatifler ve hedef kriterleri arasındaki ilişkiyi değerlendirerek sıralama yapar (R. Singh vd., 2024).

Bu çalışmada MOORA yöntemi, havalimanlarında kullanılan uçak tiplerinin çevresel performanslarını değerlendirmek amacıyla uygulanmıştır. Alternatifler uçak tipleri olarak belirlenmiş; kriterler ise CO₂ emisyonu, NO_x emisyonu, yakıt tüketimi ve uçak yaşı olarak seçilmiştir. Çalışmada ele alınan tüm kriterler maliyet kriteri olarak değerlendirilmiş ve minimizasyon yaklaşımı benimsenmiştir.

İlk adım, farklı hedefleri göz önünde bulundurarak mevcut alternatiflerin performans derecelendirmesini içeren bir karar matrisi tanımlamaktır. İlk adımda karar matrisi Eşitlik (3.3)’de gösterildiği gibi tanımlanmaktadır. İkinci adımda ise Eşitlik (3.4)’te gösterildiği şekilde karar matrisi normalleştirilmesi yapılır (Kumar vd., 2023).

Üçüncü adımda ise alternatiflerin normalleştirilmiş değerlendirmesi Eşitlik (3.5)'teki gibi uygulanır. Son adımda ise en iyi parametrenin seçimi için sıralama yapılır:

$$\begin{bmatrix} x_{11} & x_{12} & \vdots & x_{1v} \\ x_{21} & x_{22} & \vdots & x_{2v} \\ \vdots & \vdots & \vdots & \vdots \\ \vdots & \vdots & \vdots & \vdots \\ \vdots & \vdots & \vdots & \vdots \\ x_{u1} & x_{u2} & \cdots & x_{uv} \end{bmatrix} \quad (3.3)$$

$$x_{ij}^* = \frac{x_{ij}}{\sqrt{\sum_{i=1}^n x_{ij}^2}} \quad (3.4)$$

- x_{ij} : i. alternatifin j. kriter değerini,
- x_{ij}^* : normalize edilmiş değeri,
- $i = 1, 2, \dots, n$: alternatif uçak tiplerini,
- $j = 1, 2, \dots, m$: kriterleri belirtmektedir.

Kriter ağırlıkları belirlenirken literatürde yaygın olarak kullanılan Analitik Hiyerarşi Süreci yaklaşımından yararlanılmıştır.

$$Y_i = - \sum_{j=1}^m w_j x_{ij}^* \quad (3.5)$$

Eşitlik (3.5)'te Y_i , i. alternatifin performans skorunu ifade etmektedir. w_j , kriter ağırlıklarını, x_{ij}^* ise normalize edilmiş kriter değerlerini göstermektedir. Bu çalışmada ele alınan tüm kriterler maliyet yönlü olduğundan, MOORA skoru yalnızca maliyet kriterleri üzerinden hesaplanmıştır.

Y_i Değerine göre alternatifler sıralanır ve daha yüksek Y_i değerine sahip olan alternatifler daha iyi performansı göstermektedir. Buna göre en yüksek Y_i değerine sahip alternatif en iyi seçenek olarak belirlenmektedir (Kumar vd., 2023). Elde edilen MOORA skorları, çalışmanın ilerleyen aşamalarında verimlilik indekslerinin oluşturulmasında ve senaryo analizinde kullanılmıştır.

3.3. Zamana Bağlı Tahmin Modelleri

Zamana bağlı tahminleme süreçlerinde geleneksel modeller her ne kadar yaygın olsa da karmaşık veri yapılarını çözümlemede bazen yetersiz kalmaktadır. Bu sebeple,

klasik yöntemleri ileri düzey algoritmalarla bir araya getiren bütünleşik modeller literatürde öncelikli bir konuma gelmiştir. Örneğin, genetik algoritmalarla desteklenen ARMA modelleri, tekil yaklaşımlara göre daha başarılı sonuçlar vermekte ve tahmin doğruluğunu maksimize etmektedir (Ervural vd., 2016).

Çalışmanın bu kısmında CO₂ emisyonlarını sadece zamana bağlı olarak değerlendirilebilmesi amacıyla tek değişkenli zaman serisi analizi uygulanmıştır. Bu doğrultuda, mevsimsellik ve trend unsurlarını dikkate alan SARIMA modeli kullanılmıştır. Zaman serisi modeli oluşturulurken, CO₂ emisyon değerleri geçmiş dönem değerlerine bağlı olarak modellenmiş ve herhangi bir girdi değişkeni kullanılmadan uygulanmıştır. Model parametreleri veri setine en uygun p, d, q değerleri seçilmiştir.

Bu analizin yapılma sebebi, çalışmanın ana modeline alternatif yaklaşım olarak incelenmesi ve sadece zamana bağlı olarak gelecek tahminlerinin performansını değerlendirmek amacıyla yapılmıştır.

3.3.1. Otoregresif entegre hareketli ortalama (ARIMA) modeli

$ARMA(p, q)$ Modelleri, en genel stabil stokastik süreçtir ve geçmişteki gözlemlerin ve geçmişte oluşan hata terimlerini değerlendiren doğrusal bir fonksiyondur. $ARMA$ modelleri genel hatları ile aşağıdaki gibi temsil edilebilir (Önder ve Hasgöl, 2009).

$$y_t = m + a_1 y_{t-1} + \dots + a_p y_{t-p} + \dots + u_t - \theta_1 u_{t-1} + \theta_2 u_{t-2} + \dots + \theta_q u_{t-q} \quad (3.6)$$

Durağan olmayan zaman serileri farklı fark baz alınarak durağan hale getirilir. Zaman serisinin bir doğrusallığı varsa birinci fark serisi stabil hale gelir. Eğer zaman serisine göre eğrisellik var ise farkların tekrar farkı ikinci farklar serisi durağanlaştırılır. Bu durumda olan model, $ARIMA(p, d, q)$ olarak ifade edilir. Burada “d” serinin stabil hale getirme (fark alma) parametresi ile gösterilebilir (Hamzaçebi ve Kutay, 2004).

Çalışmada her bir havalimanı için değişkenler için mevsimsel $ARIMA$ kullanılmıştır. Buna literatürde genellikle $SARIMA(pdq)x(PDQ)$ olarak adlandırılmıştır; burada P, D, Q sırasıyla modelin mevsimsel olmayan ve mevsimsel bileşenlerinin otoregresif (AR), bütünleşmiş (I) ve hareketli ortalama (MA) kısımlarının polinom sırasını belirleyen negatif olmayan tam sayılardır. $SARIMA$ modeli matematiksel olarak aşağıdaki gibi tanımlanmaktadır ve bu şekilde çalışmaya dahil edilmiştir (Chouliaras vd., 2016);

$$\Phi_p(B^s) \phi_p(B) (1-B)^d (1-B^s)^D y_t = \Theta_Q(B^s) \theta_q(B) \varepsilon_t \quad (3.7)$$

$\theta_q(B)$, q dereceden düzenli Hareketli Ortalama MA (Moving Average) polinomudur.

$\Phi_p(B^s)$, Mevsimsel AR polinomudur. (s mevsim periyodudur ve aylık veri için $s=12$ olarak belirlenmiştir).

$\Theta_Q(B^s)$, Q derecesinden mevsimsel MA polinomu,

$\nabla^d = (1-B)^d$ Düzenli fark operatörüdür ve zaman serisini durağan hale getirmek için uygulanmaktadır.

$\nabla_s^D = (1-B^s)^D$, Mevsimsel fark operatörüdür,

$B^k y_t = y_{t-k}$, Gecikme (backshift) operatörüdür.

ε_t , t zamanındaki beyaz gürültü hata terimidir.

3.3.2. Mevsimsel otoregresif entegre hareketli ortalama (SARIMA) modeli

Operasyonel değişkenlerin gelecekteki değerlerini tahmin etmek amacıyla Mevsimsel Otoregresif Entegre Hareketli Ortalama (Seasonal Autoregressive Integrated Moving Average- SARIMA) modeli kullanılmıştır. Model parametreleri Çizelge 3.4'te bulunan aralıkta otomatik olarak denenmiştir. SARIMA modeli aşağıdaki form ile ifade edilir:

$$SARIMA(p, d, q)(P, D, Q)_s$$

Burada,

- p : otoregresif terim sayısı
- d : fark alma derecesi
- q : hareketli ortalama terimi
- P, Q : mevsimsel parametreler
- S : mevsimsel periyot

Çizelge 3.4. SARIMA parametre ağırlık değerleri

Parametre	Aralık
P	0-3
D	0-1
Q	0-3
P	0-1
Q	0-1

Her parametre kombinasyonu için model tahmin edilerek en düşük RMSE değerine sahip model seçilmiştir. Ankara havalimanındaki yük trafiği değişkeninde yüksek varyans gözlemlendiği için $Y_{log} = \log(Y_K)$ dönüşümü uygulanmıştır. Çalışmada veri aylık olduğu için: $s = 12$ olarak belirlenmiştir.

Bu dönüşüm model stabilitesini artırmak amacıyla uygulanmıştır. SARIMA modeli kullanılarak tüm operasyonel değişkenler için 10 yıllık (120 ay) ileriye dönük tahminler elde edilmiştir.

3.3.3. Üstel düzeltme (ETS) modeli

Üstel düzeltme işlemini gerçekleştirmek için aşağıdaki adımları uygulamanız gerekir: Bu yöntem basit, ikili ve Holt-Winters modeli çeşitli seviyeleri, tarihsel ve mevsimsel bileşenleri sabitlemenize olanak tanır; özellikle Holt-Winters yöntemi mevsimsel verilerde yaygın olarak kullanılır (Gardner, 1985). Basit haliyle model: düzey, trend ve tahmin bileşenleri için sırasıyla Eşitlik (3.8), Eşitlik (3.9) ve Eşitlik (3.10) ile ifade edilir:

$$l_t = \alpha y_t + (1 - \alpha)(l_{t-1} + b_{t-1}) \quad (3.8)$$

$$b_t = \beta(l_t - l_{t-1}) + (1 - \beta)b_{t-1} \quad (3.9)$$

$$\hat{y}_{t+h} = l_t + hb_t \quad (3.10)$$

l_t : düzey bileşeni

b_t : trend bileşeni

α, β : düzeltme katsayıları (0–1 arası)

h : ileri tahmin adımı

3.4. Makine Öğrenmesi Modelleri

Havacılık sektöründeki bazı araştırmalar, zaman serisi yöntemlerinin yanı sıra destek vektör makineleri (DVM), yapay sinir ağları (YSA) ve rastgele orman (RF) gibi makine öğrenimi algoritmalarının yaygın olarak kullanıldığını ve bu yöntemlerin düşük hata oranlarıyla daha güvenilir tahmin sonuçları sağladığını göstermektedir (Ervural,

2024). Bu çalışmada Makine Öğrenme modellerinden; Destek vektör regresyonu, Random Forest (RF) ve LSBoost yöntemleri uygulanmıştır.

3.4.1. Destek vektör regresyonu (DVR) modeli

DVR, Vapnik (1998) tarafından geliştirilen destek vektör makinelerinin (DVM) istatistiksel öğrenme teorisine dayanan regresyon uzantısıdır. Destek vektör regresyonu (DVR), örüntü tanıma, sınıflandırma ve regresyon problemlerinde sağlam ve doğru bir veri madenciliği tekniği olarak ortaya çıkmaktadır (Vapnik, 1998). Günümüzde problemleri çözmedeki başarısı nedeniyle sık tercih edilen bir yöntemdir. Yöntemin temelini istatistiksel öğrenme teorisi oluşturmaktadır. DVR, Yapay sinir ağlarının ağ oluşturma sorunları, aşırı uyum sorunları ve model eğitimi için bir dizi veri noktası belirleme gibi bazı eksikliklerinin üstesinden gelmek için geliştirilmiştir (Kavousi-Fard vd., 2014).

Yukarıda açıklanan DVM tekniği başlangıçta ikili sınıflandırma için geliştirilen DVM, DVR (veya SVR) uzantısı ile regresyon problemlerine uyarlanmıştır. DVR'nin amacı, gerçek çıktılarından en fazla duyarsız kayıp fonksiyonunu (ε) saptıran bir fonksiyon bulmaktır (Ervural vd., 2019). Hatayı azaltırken, fonksiyonun düzgünlüğünü eş zamanlı olarak artırarak aşırı uyum riski azalır. Regresyon modeli, bir dizi yüksek boyutlu fonksiyon aracılığıyla oluşturulur. Eşitlik (3.11), (3.13) arasındaki formülasyonlar DVR metodolojisini matematiksel bir perspektiften açıklamaktadır (Ervural vd., 2019).

$$f(x) = w * \varphi(x) + b \quad (3.11)$$

Eşitlik (3.11)'de $\varphi(x)$ girdiler için kernel dönüşüm fonksiyonunu, w ve b ise parametreleri göstermektedir. Katsayılar, aşağıda verilen düzenlenmiş risk fonksiyonunun minimize edilmesiyle hesaplanır:

$$R(f) = C \frac{1}{2} \sum_{i=1}^n L_{\varepsilon}(y_i + f(x_i)) + \frac{1}{2} \|\omega\|^2 \quad (3.12)$$

Eşitlik (3.12)'de ε parametresi tolerans değerini ifade etmektedir.

$$L_{\varepsilon}(y, f(x)) = \begin{cases} 0, & |y - f(x)| < \varepsilon \\ |y - f(x)| - \varepsilon, & |y - f(x)| \geq \varepsilon \end{cases} \quad (3.13)$$

Eşitlik (3.13)'te, $L\varepsilon(y, f(x))\varepsilon$ duyarsız kayıp fonksiyonu olarak etiketlenmiştir. Tahmin edilen değer ε tüpü içindeyse kayıp sıfıra eşit olur. Yumuşak marj hiper düzlemine benzer şekilde, ε bölgesinden sırasıyla pozitif ve negatif sapmaları temsil eden ξ_i ve ξ_i^* olmak üzere iki gevşek değişkenin tanıtılması gerekir. Eşitlik (3.14) aşağıdaki kısıtlama formunda yeniden formüle edilir ve Eşitlik (3.15)'de blunan Lagrangian formu bu kısıt optimizasyon problemini çözer:

$$\frac{1}{2} \|\omega\|^2 + C \sum_{i=1}^n (\xi_i + \xi_i^*) \quad (3.14)$$

Kısıtlar,

$$\begin{aligned} |w * \varphi(x_i) + b| - y_i &\leq \varepsilon + \xi_i^* \\ y_i - |w * (x_i) + b| &\leq \varepsilon + \xi_i \\ \xi_i, \xi_i^* &\geq 0 \end{aligned}$$

$$\begin{aligned} \min \frac{1}{2} \|\omega\|^2 + C \sum_{i=1}^n (\xi_i + \xi_i^*) - \sum_{i=1}^n \beta_i [w * \varphi(x_i) + b - y_i + \varepsilon + \xi_i] - \\ \sum_{i=1}^n \beta_i^* [y_i - w * \varphi(x_i) + b + \varepsilon + \xi_i^*] - \sum_{i=1}^n \alpha_i \xi_i + \alpha_i^x \xi_i^* \end{aligned} \quad (3.15)$$

Dual Lagrangian formu aşağıda verilmiştir:

$$\begin{aligned} \max \sum_{i=1}^n y_i (\beta_i + \beta_i^*) - \varepsilon \sum_{i=1}^n (\beta_i + \beta_i^*) - \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n y_i (\beta_i + \beta_i^*) (\beta_j - \\ \beta_j^*) (x_i, x_j) \end{aligned} \quad (3.16)$$

Kısıtlar,

$$\begin{aligned} \sum_{i=1}^n (\beta_i + \beta_i^*) &= 0 \\ 0 &\leq \beta_i \leq C \\ 0 &\leq \beta_i^* \leq C \\ i &= 1, 2, 3, \dots, n \end{aligned}$$

Karush-Kuhn-Tucker teoremi ile tutarlı olarak, regresyon modeli şu şekilde ifade edilir:

$$f(x) = (\beta_i - \beta_i^*)K(x_i, x_j) + b \quad (3.17)$$

Bu formülasyon, destek vektör regresyonu (DVR) tekniklerinin karbon emisyonlarının ileriye dönük tahmini için nasıl kullanılabileceğini açıklamaktadır. DVR, regresyon problemlerini çözen ve karbon emisyonlarının gelecekteki eğilimlerini tahmin etmek için matematiksel bir model oluşturan bir destek vektör makinesi (DVM) çeşididir.

Makine öğrenmesi yöntemlerinin enerji tüketimi tahmininde de etkin bir şekilde kullanıldığı ve özellikle destek vektör regresyonu (DVR) modelinin diğer yöntemlere kıyasla daha yüksek tahmin doğruluğu sağladığı literatürde belirtilmektedir (Beyca vd., 2019). Bu çalışmada uçakların emisyon verilerinin özelliğe dayalı alandaki doğrusal olmayan yapısını daha iyi temsil etmek için, Radial Basis Function (RBF) kernel kullanılmıştır (*fitrsvm*). Modelden önce veri seti normalize edilerek model uygulanmıştır (*zscore()*). RBF çekirdeği, düzgünlük parametresi sayesinde aşırı uyum riskini en aza indirerek daha güvenilir ve daha stabilize edilmiş tahmin sonuçları vermektedir.

3.4.2. LSBoost (Least Squares Boosting) modeli

Boosting (Güçlendirme) yöntemleri, bir dizi zayıf öğreniciyi ardışık olarak bir araya getirerek tek ve güçlü bir tahmin modeli elde etmeye dayanan topluluk (ensemble) öğrenme yaklaşımıdır. Zayıf öğreniciler genellikle karar ağaçlarıdır ve her bir ağaç, önceki ağaçların hatalarını düzeltmeye çalışır; böylece nihai model, bu zayıf öğrencilerin doğrusal birleşiminden oluşur (Rizkallah, 2025).

MATLAB ortamında “LSBoost” yöntemini kullanan *fitensemble* işlevi, LSBoost şeması ile karar ağacı tabanlı regresyon öğrencilerini tekrar tekrar eğiterek kalıntı karelerinin toplamını en aza indiren bir topluluk modeli oluşturulmasına olanak tanır.

LSBoost, regresyon problemleri için geliştirilmiş bir boosting algoritması olup, tahmin hatalarını iteratif olarak azaltmayı amaçlamaktadır. Model, her iterasyonda bir önceki modelin hatalarını öğrenerek kendini günceller. Modelin amacı, Eşitlik (3.18)’deki gibi kare hata kaybını minimize etmektir. Daha sonra Eşitlik (3.19)’da gösterilen başlangıç modeli, hedef değişkenin ortalaması ile tanımlanır. Her iterasyonda artıklar (residuals) Eşitlik (3.20)’deki gibi hesaplanır ve bu artıklar üzerine bir zayıf öğrenici (karar ağacı) eğitilir ve model sırasıyla aşağıdaki şekilde güncellenir:

$$L(y, F(x)) = \frac{(y - F(x))^2}{2} \quad (3.18)$$

$$F_0(x) = \bar{y} \quad (3.19)$$

$$r_i = y_i - F_{m-1}(x_i) \quad (3.20)$$

$$F_m(x) = F_{m-1}(x) + v \cdot h_m(x) \quad (3.21)$$

Burada:

- $h_m(x)$: m 'inci iterasyonda eğitilen karar ağacı
- v : öğrenme oranı (learning rate).

Son tahmin, M iterasyon sonunda elde edilen modeldir: $F_M(x)$

Bu çalışmada LSBoost modeli, SARIMA ile tahmin edilen girdiler kullanılarak CO₂ emisyonlarını tahmin etmek amacıyla uygulanmıştır.

3.4.3. Random Forest modeli

Random Forest regresyonu, çok sayıda bulunan karar ağaçlarının ortalamasını alarak hedef olan değişkenleri tahmin eden güçlü bir Makine Öğrenmesi yöntemidir. Özellikle doğrusal olmayan ilişkiler, çok sayıda değişken ve etkileşim içeren veri kümelerinde ortaya çıkmaktadır. Temel çalışma prensibi olarak Birçok derin regresyon ağacı örnekleri üzerinde durur ve her düğüm için rastgele seçilen bir alt özelliğin kümesinden en iyi bölüme geçer. Model doğrusal form sağlayamadığından dolayı karmaşık olan ilişkileri ve etkileşimleri iyi yakalayan bir yöntemdir (Ishwaran ve Lu, 2019). Her bir karar ağacı, giriş vektörü x için bir tahmin üretir Eşitlik (3.22)'te $T_t(x)$, t 'inci karar ağacının tahminini ifade etmektedir:

$$\hat{y}_t = T_t(x) \quad (3.22)$$

Topluluk modelinin nihai tahmini ise tüm ağaçların ortalaması alınarak elde edilir:

$$\hat{y}_{RF}(x) = \frac{1}{M} \sum_{t=1}^M T_t(x) \quad (3.23)$$

4. UYGULAMA

Çalışmada, Sabiha Gökçen, Esenboğa ve Konya için Devlet Hava Meydanları İşletmesi tarafından sağlanan uçuş verilerinden yararlanılmıştır. Bu çalışma kapsamında son dönemlerde yaygın olarak kullanılan uçak emisyon hesaplaması yöntemi olan Tier 2 yöntemi LTO (iniş-kalkış) safhası için yapılmış, daha sonra yıllık uçak tipi verileri aylık verilere dönüştürülerek aylık emisyon verileri elde edilmiştir.

Çalışmada, uçak tipi ve uçuş operasyonları gibi emisyon hesaplamalarında kullanılacak veriler, Sabiha Gökçen, Esenboğa ve Konya havalimanlarına ait 2014–2023 dönemini kapsayan 10 yıllık veri seti üzerinden temin edilmiştir. Bu veriler, DHMİ'nin resmî sitesinden alınan aylık istatistiklerle birlikte kullanılarak orantısal ayrıştırma yöntemi ile uçak tipi bazlı aylık iniş-kalkış döngülerine dönüştürülmüştür. ICAO ve IPCC gibi kuruluşlardan elde edilen emisyon katsayıları kullanılarak uçak kaynaklı emisyonlar Tier II metodolojisine uygun şekilde hesaplanmıştır. İlerleyen aşamada, emisyonla etki eden faktörlerin belirlenmesi amacıyla uzman anketleri uygulanmış; bu sayede 10 yıllık tahmin modeline temel oluşturan daha bütünlüklü bir yaklaşım geliştirilmiştir.

4.1. Çalışmada İncelenen Havalimanlarının Tanıtımı

Çalışmada üç farklı havalimanı incelenecektir: İstanbul Sabiha Gökçen Havalimanı, Ankara Esenboğa Havalimanı ve Konya Havalimanı. Bu havalimanları; kapasite, uçuş trafiği ve operasyonel büyüklükler açısından birbirlerinden belirgin şekilde farklılık göstermektedir. Bu farklılıklar, havalimanlarının karbon emisyon profillerinin karşılaştırılabilir şekilde analiz edilmesine olanak sağlaması nedeniyle çalışma kapsamında tercih edilmiştir.

4.1.1. Sabiha Gökçen Havalimanı (SAW)

Sabiha Gökçen Havalimanı (IATA: SAW, ICAO: LTFJ) İstanbul, Türkiye'de yer alan ve 2001 yılında faaliyete açılan bir havalimanıdır. Adını Türkiye'nin ilk kadın pilotu olan Sabiha Gökçen'den almıştır. Havalimanı özellikle düşük maliyetli havayolları için önemli bir bağlantı merkezi haline gelmiştir.

İstanbul Sabiha Gökçen havalimanı 2023 yıl sonu DHMİ verilerine göre 221.077 ticari uçuş sayısı, 407.950 ton yük (kargo, posta, bagaj) ve 36.825.424 yolcu sayısı ile Türkiye'nin en işlek ikinci havalimanıdır. Geçmişten günümüze bakıldığında geçmiş yıllarda İstanbul Atatürk Havalimanı Türkiye'de en işlek havalimanı iken Atatürk

havalimanının yerine İstanbul Havalimanı hizmete girişinden itibaren 2019 itibariyle yerini İstanbul Havalimanı (LTFM) almıştır ancak bu durum Sabiha Gökçen havalimanının genellikle her zaman ikincil işlek havalimanı konumunda olmasına herhangi bir etkide bulunmamıştır.

Sabiha Gökçen Havalimanı, İstanbul'un Anadolu yakasında yer alan uluslararası bir havalimanıdır. İstanbul'un en büyük ikinci havalimanıdır. İstanbul Sabiha Gökçen Havalimanı, çok sayıda iç ve dış hat uçuşuna hizmet veren Türkiye'nin en işlek havalimanlarından biridir. Şehir merkezine olan uzaklığına rağmen, havalimanı çeşitli ulaşım seçenekleri sunmaktadır. Terminal binaları, yolcu konforunu ve hizmet kalitesini artırmak için tasarlanmış modern tesislerle donatılmıştır. Sabiha Gökçen Havalimanı, İstanbul'un havayolu trafiğini dengelemede ve şehrin ulaşım kapasitesini artırmada önemli bir rol oynamaktadır (EE, 2024).

4.1.2. Esenboğa Havalimanı (ESB)

Esenboğa Havalimanı (ESB), Türkiye'nin başkenti Ankara'da bulunan ve 1955 yılında faaliyete geçen bir havalimanıdır. Adını, havalimanının bulunduğu Esenboğa köyünden almaktadır. Hem iç hem de dış hat uçuşlarının gerçekleştirildiği havalimanı, Türkiye'nin en önemli ulaşım merkezlerinden biridir. Esenboğa havalimanı 2023 yıl sonu DHMİ verilerine göre 117.630 ton yük trafiği, 80.156 ticari uçuş sayısı ve 11.950.940 yolcu sayısı ile genellikle Türkiye'nin üçüncü en yüksek ulaşım trafiğine sahip havalimanıdır (DHMİ). Bu durum Ankara şehrinin Türkiye'nin başkenti olması ile açıklanabilir. 2006 yılında iç ve dış hatlar için aynı terminal binasında hizmet vermeye başlamıştır. İç hatlarda güçlü bir trafik ağına sahiptir. Esenboğa Havalimanı 2012 yılında Türkiye'nin ilk karbon-nötr havalimanı olmuştur (TAV Havalimanları).

Esenboğa Havalimanı (IATA: ESB, ICAO: LTAC), Türkiye'nin başkenti Ankara'ya hizmet veren uluslararası bir havalimanıdır. Şehir merkezinin 28 km kuzeyinde, Çubuk ilçesi sınırları içinde yer almaktadır. Devlet Hava Meydanları İşletmesi'ne aittir ve TAV Havalimanları tarafından işletilmektedir.

4.1.3. Konya Havalimanı (KYA)

Konya Havalimanı (IATA: KYA), Türkiye'nin İç Anadolu Bölgesi'nde, Konya ilinde yer alan ve 2000 yılında sivil hava trafiğine açılan bir havalimanıdır. Konya'nın hem iç hatlar hem de uluslararası seferler düzenleyen önemli ulaşım merkezlerinden biri

olan havalimanı, özellikle turizm, ticaret ve tarım sektörleri için kritik bir rol oynamaktadır. Bu incelemede, Konya Havalimanı'nın altyapısı ve kullanım düzeni hakkında bilgi verilecektir.

Konya havalimanı, 2023 yıl sonu DHMİ verilerine göre 903.361 yolcu sayısı, 6.501 ticari uçak sayısı ve 9.718 ton yük trafiği ile genellikle çalışmada incelenen diğer havalimanlarından daha düşük ulaşım trafiğine sahip havalimanıdır.

Konya Havalimanı'nda hava ulaşımı, 3. Ana Jet Üs Komutanlığı'na bağlı askeri hava üssüne ilave edilen sivil tesislerle sağlanmaktadır. Bu tesisler 29 Ekim 2000 tarihinde hizmete girmiş, 17 Nisan 2001 tarih ve 2001/2332 sayılı Bakanlar Kurulu Kararı ile uluslararası yolcu trafiğine açılmıştır. Yıllık 17.520 uçak kapasitesine sahip olan havalimanı 196.000 m²'lik bir alanı kaplamaktadır (Konya Havalimanı, 2024).

Terminal binası hem iç hem de dış hat uçuşları için ortak kullanılmaktadır. Giden yolcular zemin kattan, gelen yolcular ise bodrum kattan çıkış yapmaktadır. Zemin katta ortak salon, iç hatlar gidiş salonu, dış hatlar gidiş salonu ve VIP salonu bulunmaktadır. Bodrum katında bagaj alım alanı, idari ofisler ve pasaport ve gümrük kontrol tesisleri yer almaktadır (Konya Havalimanı, 2024).

4.2. Veri Hazırlama ve İş Akışı

Çalışmada, yıllık uçak tipi başına düşen LTO (Landing and Take Off) değerleri DHMİ tarafından sağlanmış olup, DHMİ internet sayfası verilerinde bulunan aylık LTO sayıları ile uçak tipine göre yıllık LTO değerleri, Orantısal ayrıştırma yöntemi ile aylık düzeye dönüştürülmüştür. Bu yöntem ile yıllık değerler, aylık değerlere orantılı olarak paylaştırılmıştır. Yöntem IMF'nin Quarterly National Accounts Manual (International Monetary Fund (IMF), 2017) rehberinde yayınlanan Bölüm 6: The Pro Rata Distribution and the Step Problem yaklaşımı ile uygulanmıştır.

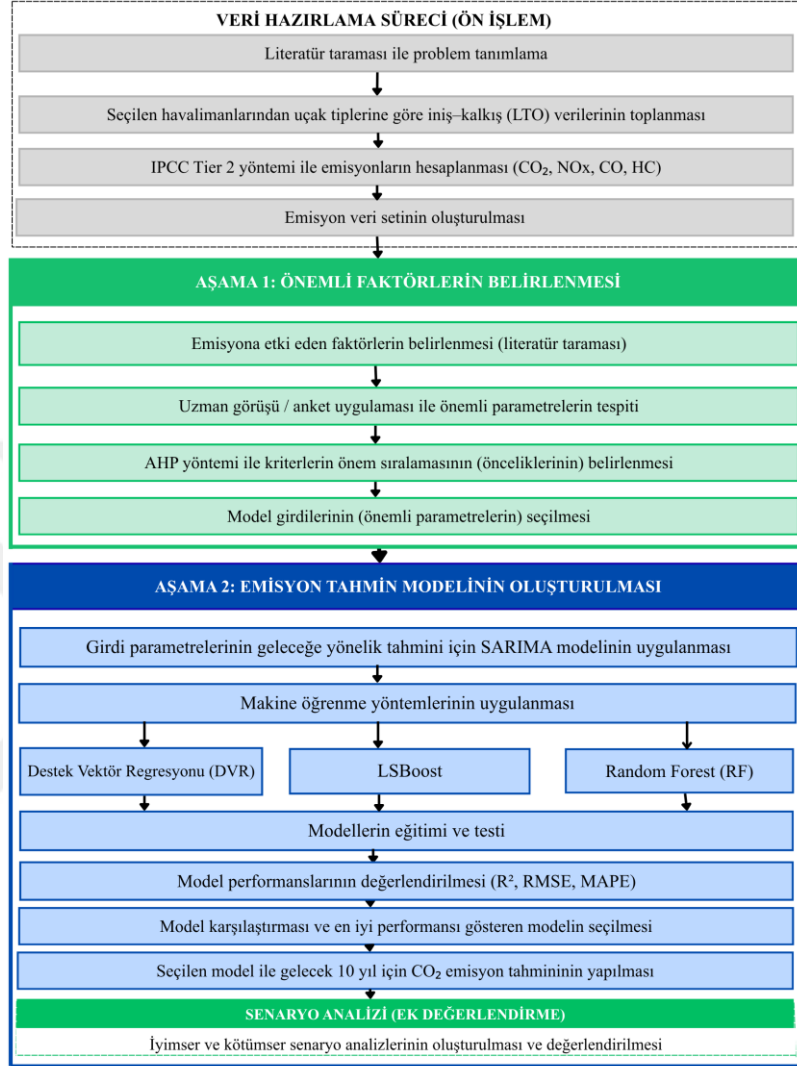
Küresel olarak yaşanan COVID-19 Pandemi olayı sebebi ile 2020-2021 yıllarında uçuş oranlarının olağandışı düşüş yaşandığı için, IPCC 2019 Refinement kapsamında önerilen doğrusal interpolasyon yöntemi uygulanarak 2019 ve 2022 gibi pandemi etkisinin bittiği zamanlar arasında sabit yıllık değişim olduğu varsayılarak ara yıllar ve içerisindeki aylar hesaplanmıştır ve eksik gözlemler doğrusal interpolasyon yöntemi ile tamamlanmıştır. (IPCC, 2019). Böylece zaman serisi tutarlılığını korumaktadır.

Modelleme süreci temel olarak iki bölümden oluşmaktadır:

- Operasyonel değişkenlerin zaman serisi tahmini

- Makine öğrenmesi yöntemleri ile CO₂ emisyon tahmini

Bu çalışmada kullanılan modelin genel iş akışı Şekil 4.1’de gösterilmektedir.



Şekil 4.1. Çalışmada kullanılan emisyon tahmin modelinin genel iş akışı

4.3. Tier 2 Yöntemi Uygulaması

Bu çalışmada, her bir kirleticisi madde (CO_2, NO_x, PM, CO, HC) için uçak emisyonları, uçak tipi başına toplam LTO döngüsü sayısı ve ilgili emisyon faktörleri temel alınarak hesaplanmıştır. Genel formül şu şekilde ifade edilir:

$$Toplam Emisyon_x = N_{LTO} \times EF_x \quad (4.1)$$

Eşitlik (4.1)'de N_{LTO} , belirli bir havalimanında belirli bir uçak tipi için toplam LTO döngüsü sayısıdır,

EF_x , kirletici x (kg/LTO) için emisyon faktörüdür,

x , CO_2 , NO_x , PM , CO veya HC gibi sera gazlarını ifade eder.

Hesaplanan emisyon değerlerinin ardından, bu emisyonlara etki eden operasyonel parametrelerin önem derecelerini belirlemek amacıyla AHP yöntemine başvurulmuştur.

4.4. Çok Kriterli Karar Verme Yöntemlerinin Uygulaması

Bu çalışmada havalimanında emisyonu sebep olan kriterler alanında deneyim ve bilgi sahibi 30 havacılık uzmanı tarafından çevrimiçi anketler aracılığıyla değerlendirilmiştir. Yapılan anket çalışmasında hem genel havalimanı için emisyonu sebep olan faktörler değerlendirilmiş hem de uçak operasyonlarında emisyonu sebep olan bazı kriterler AHP yöntemi ile değerlendirilmiştir. Sonraki aşamada ise bazı AHP kriter ağırlıklarından da yararlanılarak MOORA yöntemi ile verimli ve verimsiz uçak sıralaması uygulanarak gelecek yeşil filo tahmini için ön hazırlık çalışması yapılacaktır. Bu sayede emisyonlar sade bir şekilde tahminlenmeyecek gelecekte daha verimli olan uçak tipleri daha fazla olursa emisyonların ne kadar düşeceği ve verimsiz uçak tipleri ne kadar fazla olursa bir o kadar emisyonların artacağı da gözlemlenecektir.

4.4.1. AHP yöntemi uygulaması

Birçok faktör emisyon değerlendirmelerinde sapmalara yol açabilir. Bu faktörlerden bazıları uçak tipi, uçak ağırlığı ve uçuş güzergahı özellikleridir (Wang ve diğerleri, 2024). Karbon emisyonuna sebep olan bir diğer parametre de uçak ağırlığıdır. Daha ağır uçakların daha fazla yakıtı ihtiyaç duyması, özellikle kalkış ve tırmanış olmak üzere tüm LTO aşamalarında daha yüksek emisyonlara yol açar (Glowacki ve Kawalec, 2016). Ayrıca, kullanılan uçak modelleri ve motor tipleri de emisyonlar üzerinde önemli bir etkiye sahiptir. Mevcut literatürde de belirtildiği gibi, farklı motor tipleri ve uçak modelleri farklı emisyon faktörlerine ve verimliliklere sahiptir. Motor teknolojisindeki son gelişmeler, eşdeğer uçuş süreleri için daha az CO_2 emisyonu üreten daha verimli motorların geliştirilmesine yol açmıştır. Bazı uçakların örneğin Airbus A321 ve Boeing 738 uçak tiplerinin, bir havalimanındaki toplam emisyonlar üzerinde baskın bir etkiye sahip olduğu belirlenmiştir. Bu durum, bu uçakların yüksek uçak operasyonları ve farklı emisyon profillerine dayandırılabilir (Akdeniz, 2022).

Havalimanı ve uçak emisyonları hem havalimanı hem de uçak düzeyinde bir dizi karmaşık faktör tarafından şekillenir. Başlıca emisyon kaynakları, iniş ve kalkış (LTO) döngüleri sırasında uçak operasyonlarıdır, ancak yer hizmetleri, terminal operasyonları ve yardımcı ekipmanlar da önemli rol oynar. Uçaklara özgü özellikler de emisyon profillerini etkiler. Havalimanı emisyonlarının çoğu, LTO döngüleri sırasında, özellikle taksi, kalkış, tırmanma ve yaklaşma aşamalarında uçaklardan kaynaklanır. Taksi süresi kritik bir faktördür. Taksi süresini sadece 2 dakika azaltmak, LTO emisyonlarını %4-6 oranında düşürebilir (Tokuslu, 2020). Apron otobüsleri, bagaj taşıma araçları ve itme traktörleri gibi araçlar, özellikle dizel veya benzinle çalıştırıldığında emisyonlara katkıda bulunmaktadır. Yer destek ekipmanlarının elektrifikasyonu, CO₂ emisyonlarını önemli ölçüde azaltabilir (Masiol ve Harrison, 2014). Uçaklara yer hizmetlerinde güç sağlamak için kullanılan Yardımcı Güç Ünitesi (Auxiliary Power Unit – APU), özellikle kapı elektrifikasyonu mevcut olmadığında önemli emisyon kaynaklarıdır (H. Xu vd., 2020). Terminallerdeki ısıtma, soğutma ve elektrik tüketimi de havalimanının toplam emisyonlarına katkıda bulunmaktadır, ancak bunlar genellikle uçak operasyonlarına kıyasla daha küçük bir paya sahiptir (Greer vd., 2020). Kara ulaşım araçları (otobüsler, taksiler, özel araçlar) toplam havalimanı sera gazı emisyonlarının %11'ine kadarını oluşturabilir. Atık yönetimi (atık işleme, geri dönüşüm) ve buz çözme faaliyetleri, kesin etkilerini ölçen sınırlı sayıda araştırma bulunmakla birlikte, küçük ancak önemli katkıda bulunan faktörlerdir (Masiol ve Harrison, 2014).

Çalışma için iki kategoride AHP uygulaması yapılmıştır:

- Genel havalimanı kaynaklı emisyon faktörleri,
- Uçak operasyon kaynaklı emisyon faktörleri.

Çalışmada AHP analizi hem havalimanı genel sürdürülebilirlik faaliyetlerini hem de uçak operasyonlarına bağlı oluşan emisyon kaynaklarını ele alarak değerlendirilmiştir. Ancak geliştirilen emisyon tahmin modeli yalnızca uçak operasyonlarına dayanmaktadır.

Havalimanı operasyonlarında emisyona sebep olan faktör seçimi için belirlenen kriterler aşağıdaki gibi belirlenmiştir:

- Uçak iniş-kalkış hareketleri (LTO),
- Yer hizmetleri destek ekipmanları (GSE),
- Yardımcı güç üniteleri (APU),
- Havalimanı ulaşım araçları (otobüs, taksi vb.),
- Terminal enerji kullanımı,

- Atık yönetimi ve geri dönüşüm faaliyetleri.

Belirlenen kriterler literatür taraması ve uzman görüşleri doğrultusunda değerlendirilerek analiz sürecine dahil edilmiştir. Uzmanlardan, her iki kriteri, Çizelge 3.3 örneğindeki gibi 1–9 ölçeği üzerinden karşılaştırmaları istenmiştir. Böylece her katılımcı için 6×6 boyutunda bir karşılaştırma matrisi oluşturulmuştur. Her bir uzman için elde edilen matrislerden özvektör yöntemi ile ağırlıklar ve Tutarlılık Oranı (CR) hesaplanmıştır. $CR \leq 0.10$ olması, kararların tutarlı olduğunu göstermektedir. Anket çalışması Google Forms üzerinden oluşturulmuş ve ilgili uzmanlara LinkedIn uygulaması aracılığıyla göndererek çevrimiçi anketler uygulanmıştır. 30 uzmandan elde edilen bireysel matrislerin geometrik ortalaması alınarak grup düzeyinde karar matrisi oluşturulmuştur. Grup matrisinden türetilen özvektör yardımıyla her bir kriterin ağırlığı hesaplanmıştır. Şekil 4.2’de çalışmada yapılan anketin örnek sorusu gösterilmiştir.

1. Hangi kriter havalimanında karbon emisyonlarının oluşumunda daha fazla etkilidir? *

- ☐ Uçak iniş kalkış hareketleri (LTO)
- ☐ Yer hizmetleri destek ekipmanları (Ground support equipment)

Şekil 4.2. Anket kriter karşılaştırma örneği

1. Seçtiğiniz kriterin, diğerine göre emisyonlara etkisini 1’den 9’a kadar değerlendiriniz. *

	1	2	3	4	5	6	7	8	9	
Diğer kriterle eşit öneme sahip	☐	☐	☐	☐	☐	☐	☐	☐	☐	Diğer kriterle göre son derece önemli

Şekil 4.3. Ankette seçilen kriterin puanlaması

AHP anketinde, katılımcılara verilen ikili karşılaştırma sorularının örnek formatı Şekil 4.2’de verilmiştir. Çalışmada hem genel havalimanı emisyonu sebep olan hem de uçak operasyonlarında emisyonu sebep olan faktörler bu anket formu şeklinde yapılmıştır. Her iki ankette de soru yapısı aynı ama karşılaştırılan kriterler farklıdır. Katılımcılardan 1-9 ölçeğine göre hangi kriterin diğerine göre ne kadar önemli olduğunu

belirtmeleri istenerek anketler doldurulmuştur. Puanlama kısmı ise Şekil 4.3'te verilmiştir.

4.4.2. MOORA yöntemi uygulaması

Yapılan MOORA yönteminde nihai ağırlıklar, ham ağırlıkların toplamına bölünerek normalize edilir: CO₂ emisyonu için kullanılan 0,263 değeri, AHP analizinde emisyonları temsil eden operasyonel kriterlerin (LTO ve Uçak tipi) toplam ağırlığının, CO₂ ve NO_x arasında eşit oranda paylaştırılması sonucu elde edilen MOORA ham ağırlığını ifade etmektedir.

Eşitlik (4.2)'de AHP sonuçlarının MOORA yöntemine nasıl katsayı olarak düzenlendiği gösterilmiştir. MOORA katsayıları bu şekilde hesaplanmıştır.

Emisyonlar (CO₂ ve NO_x) ve yakıt tüketimi değerlerinin etkisinin, LTO kaynaklı birim performans değerlerinin belirlenebilmesi amacıyla, değerler ilgili uçak tiplerinin LTO sayılarına bölünerek normalize edilmiştir. Emisyonlar, operasyonel faaliyetler ile uçağın teknolojik özelliklerinin bütünleşik etkisinden kaynaklanmaktadır. Bu bağlamda, uçuş sayısını temsil eden LTO değişkeni emisyonlarda belirleyici faktör olarak kabul edilirken, uçak tipi ikincil bir belirleyici unsur olarak değerlendirilmiştir. Sonuç olarak, emisyon kriterlerinin ağırlıklandırılmasında LTO'ya %70, uçak tipine ise %30 oranında ağırlık uygulanmıştır. Bu kapsamda hesaplanan ağırlıklar:

$$CO_2 = 0.407 \times 0.70 + 0.120 \times 0.30 = 0.321$$

$$NO_x = 0.407 \times 0.70 + 0.120 \times 0.30 = 0.321$$

Olarak belirlenmiştir.

Çizelge 4.1. MOORA yönteminde kullanılan kriterlerin önem ağırlıkları

Kriter	AHP'deki Ham Ağırlık	MOORA Ham Ağırlığı	Normalize MOORA Ağırlığı (w _i)
Yakıt tüketimi	0,238	0,239	0,247
CO ₂ Emisyonu	—	0,321	0,332
NO _x Emisyonu	—	0,321	0,332
Uçak Yaşı	0,086	0,087	0,090

$$v_{ij} = w_j \cdot x_{ij}^* \quad (4.2)$$

Eşitlik 4.2'de kullanılan parametreler aşağıda açıklanmıştır:

v_{ij} , i alternatifinin j kriteri için ağırlıklandırılmış normalize değeri,

w_j , j kriterine ait önem ağırlığı derecesi,

x_{ij}^* , i alternatifinin j kriterine göre normalize edilmiş değeri olarak gösterilmektedir.

Tüm kriterlerin maliyet yönlü (minimize edilmesi gereken) olması nedeniyle MOORA performans değeri aşağıdaki şekilde hesaplanmıştır:

$$Y_i = - \sum_{j=1}^m w_j x_{ij}^* \quad (4.3)$$

Bu kapsamda her bir uçak tipi için Y_i performans değeri hesaplanmıştır. Bu değer, ilgili uçak tipinin çevresel ve operasyonel verimliliğini temsil etmektedir.

Örnek olarak B38M uçak tipi için MOORA performans değeri aşağıdaki şekilde hesaplanmıştır:

$$Y_i = -(0,247 \cdot x_1 + 0,332 \cdot x_2 + 0,332 \cdot x_3 + 0,090 \cdot x_4)$$

Hesaplamalar sonucunda B38M uçak tipi için MOORA performans değeri yaklaşık olarak -0,1379 olarak elde edilmiştir. Bu değer, ilgili uçak tipinin düşük maliyet ve emisyon değerleri nedeniyle diğer alternatiflere kıyasla daha düşük maliyet ve emisyon değerlerine sahip olduğunu ifade etmektedir.

Çizelge 4.2. Sabiha Gökçen Havalimanı için oluşturulan MOORA karar matrisi (örnek)

Uçak Tipi	Yakıt (norm)	CO ₂ (norm)	NO _x (norm)	Uçak Yaşı (norm)
B38M	0,00	0,00	0,00	0,01
A320	0,04	0,04	0,03	0,08
B738	0,04	0,04	0,04	0,05
A321	0,04	0,05	0,05	0,06
B744	0,14	0,15	0,13	0,07
AN12	0,14	0,15	0,13	0,15
C25M	0,01	0,01	0,00	0,01
E550	0,01	0,01	0,00	0,03

Çizelge 4.2, MOORA yönteminin uygulanışını örneklendirmek amacıyla Sabiha Gökçen Havalimanı (SAW) veri setinden seçilen belirli uçak tiplerine ait normalize

edilmiş değerler sunulmuştur. Analizlerin bütününde tüm uçak tiplerini kapsayan karar matrisi esas alınmış; Çizelge 4.2’de ise yalnızca yöntemin işleyişini göstermek adına temsili bir bölüm gösterilmiştir.

Normalize edilmiş değerler incelendiğinde; B38M gibi yeni nesil uçakların, daha düşük emisyon ve yakıt tüketim performansı gösterdiği gözlemlenmektedir. Buna karşın, AN12 ve B744 gibi eski teknolojiye sahip veya kargo odaklı uçakların daha yüksek normalize değerlere sahip olduğu belirlenmiştir. Ayrıca, normalizasyon işlemi sonucunda elde edilen verilerin ölçeği oldukça küçük olduğundan, bazı değerlerin yuvarlama nedeniyle sıfıra yakın görüldüğü dikkate alınmalıdır. Elde edilen MOORA skorlarına göre uçak tipleri sıralanmış ve belirli bir eşik değere göre üst performans gösteren uçaklar verimli, ortalamadan düşük performans gösteren uçaklar ise verimsiz olarak sınıflandırılmıştır.

Çalışmada havalimanlarının uçak kaynaklı emisyonlarının hesaplanması için verimlilik oranı hesaplanmıştır. Havalimanı bazlı verimlilik indeksi aşağıdaki şekilde hesaplanmıştır:

$$EI = \frac{N_{verimli}}{N_{verimli} + N_{verimsiz}}$$

Burada:

EI : verimlilik indeksi

$N_{verimli}$: verimli uçak sayısı

$N_{verimsiz}$: verimsiz uçak sayısı

4.5. Tahmin Modellerinin Uygulanması

Operasyonel değişkenlerin (LTO sayısı, yakıt tüketimi ve yük trafiği) gelecekteki tahminleri oluşturulduktan sonra, ikinci aşamada bu değişkenleri girdi olarak kullanarak CO₂ emisyonlarını tahmin etmek üzere makine öğrenimi algoritmaları uygulanmıştır. Modellerin eğitim performansını değerlendirmek ve genelleme yeteneklerini test etmek amacıyla veri kümesi iki gruba ayrılmıştır: Modelin değişkenler arasındaki ilişkileri öğrenmesi için %80 eğitim verisi kullanılmıştır. Modelin daha önce görmediği veriler üzerindeki tahmin performansını değerlendirmek için %20 test verisi ayrılmıştır.

Veri bölünmesi, toplam verinin (n) %80-%20 karşılık gelen gözlem sayısının en yakın tam sayıya yuvarlanmasıyla gerçekleştirilmiştir. Bu durum, aşırı uyum riskini kontrol edilmesini sağlayarak test aşamasındaki performansın daha güvenilir olarak ölçülebilmesini sağlamıştır.

Model performansı aşağıdaki metrikler kullanılarak değerlendirilmiştir:

- Kök Ortalama Kare Hatası (RMSE)
- Ortalama Mutlak Yüzde Hatası (MAPE)
- Belirlilik Katsayısı (R^2)

Elde edilen sonuçlar doğrultusunda, en düşük hata değerine sahip model her havalimanı için ayrı ayrı belirlenmiştir.

Çalışmada 2014–2023 yılları arasında üç havalimanına ait aylık operasyon verileri kullanılmıştır. Analizde kullanılan değişkenler aşağıda verilmiştir.

- LTO (iniş ve kalkış sayısı)
- Yük Trafiği (posta, kargo, bagaj ağırlığı)
- Yakıt tüketimi
- CO₂

CO₂ ve Yakıt tüketimi değerleri IPCC tarafından önerilen Tier 2 yöntemi kullanılarak hesaplanmıştır.

4.6. Girdi Tahmini (Zaman Serisi Modelleri)

İlk aşamada, CO₂ emisyonunu etkileyen temel değişkenler olan: LTO, Yük trafiği, Yakıt tüketimi verileri zaman serisi yöntemleri ile tahmin edilmiştir. Bu kapsamda üç farklı model uygulanmıştır:

4.6.1. ARIMA (1,1,1) modeli

Temel zaman serisi modeli olarak kullanılmıştır. Trend bileşenini modelleyebilmesine rağmen mevsimsel etkileri doğrudan içermemektedir.

4.6.2. ETS modeli

Trend ve düzey bileşenlerini modellemek için uygulanmıştır. Ancak bazı veri setlerinde mevsimsel yapıyı yeterince temsil edememiştir.

4.6.3. SARIMA modeli

Hem trend hem de mevsimsel bileşenleri birlikte modelleyebildiği için tercih edilmiştir. Aylık veri yapısına uygun olarak mevsimsellik değeri 12 alınmıştır. Bu modeller karşılaştırılmış ve genel olarak en iyi performansı verdiği için SARIMA modeli seçilmiştir. Seçilen model ile her bir değişken için 120 aylık tahminler elde edilmiştir.

Ayrıca, Konya Havalimanı verilerinde gözlenen ani düşüş eğiliminin tahmin performansını olumsuz etkilemesini azaltmak amacıyla 3 dönemlik hareketli ortalama (Moving Average-3, MA3) yaklaşımı uygulanmıştır. Bu işlem ile veri serisinin daha dengeli ve kararlı bir eğilim göstermesi amaçlanmıştır.

4.7. CO₂ Emisyon Tahmini (Makine Öğrenmesi Modelleri)

İkinci aşamada, SARIMA ile tahmin edilen girdiler kullanılarak CO₂ emisyon tahmini gerçekleştirilmiştir. Bu kapsamda aşağıdaki Makine Öğrenmesi modelleri uygulanmıştır:

4.7.1. LSBoost modeli

Modelde 0.1 öğrenme oranı kullanılmıştır. Karar ağacı sayısı farklı parametreler ile test edilmiş olup, 50, 100 ve 200 karar ağacı kullanılarak benzer performans sonuçları elde edildiği görülmüştür. Bu doğrultuda model, iteratif hata azaltma yaklaşımıyla tahmin doğruluğunu artırmayı hedeflemektedir.

4.7.2. DVR modeli

Doğrusal olmayan ilişkileri modellemek amacıyla kullanılmıştır. Modelde RBF çekirdeği tercih edilmiş ve veriler normalize edilmiştir.

4.7.3. Random Forest modeli

Modelde 100 karar ağacı ve bagging yöntemi uygulanmıştır. Tüm modeller RMSE, MAPE, R² kriterlerine göre değerlendirilmiştir:

En düşük hata değerine sahip model, ilgili havalimanı için en iyi model olarak seçilmiştir.

4.7.4. Ek karşılaştırma modeli: SARIMA

CO₂ tahmini için ayrıca doğrudan zaman serisi yaklaşımı da test edilmiştir. CO₂ değerleri doğrudan zaman serisi olarak modellenmiş ve sonuçlar Makine Öğrenmesi modelleri ile karşılaştırılmıştır. Bu karşılaştırma, tek değişkenli model ile çok değişkenli model arasındaki farkı görmek amacıyla yapılmıştır.

4.8. Senaryo Analizi Uygulaması

Bu çalışmada, gelecekteki CO₂ emisyonlarının farklı operasyonel koşullar altında nasıl değişeceğini analiz etmek amacıyla senaryo analizi gerçekleştirilmiştir. Senaryo tasarımında, MOORA yöntemi ile belirlenen performans kriterleri dikkate alınmıştır.

- İyimser Senaryoda, Düşük emisyonlu uçakların kullanım oranının arttığı, yakıt verimliliğinin yükseldiği, operasyonel verimliliğin arttığı varsayılmıştır. Bu kapsamda girdi değişkenleri belirli oranlarda iyileştirilmiş ve modele verilmiştir.
- Kötümser Senaryoda, Eski ve yüksek emisyonlu uçakların kullanım oranının arttığı, yakıt tüketiminin yükseldiği, operasyonel verimliliğin azaldığı varsayılmıştır. Bu doğrultuda girdi değişkenleri olumsuz yönde değiştirilerek modele uygulanmıştır.

5. ARAŞTIRMA SONUÇLARI VE TARTIŞMA

Bu bölümde, çalışmada uygulanan yöntemlerden elde edilen bulgular sunulmuş, sonuçlar değerlendirilmiş ve literatürdeki benzer çalışmalar ışığında tartışılmıştır.

5.1. Tier 2 Yöntemi Sonuçları

Tier 2 yöntemi sonucunda elde edilen değerler özet çizelgeleri ve grafiklerle sunulmuştur. Hesaplamalar sonucunda emisyonların LTO sayısı ile doğru orantılı olduğu gözlemlenmiştir. Çizelgeye dahil olmayan bazı uçak tipleri için, kapasite ve performans açısından benzer uçak tiplerinin katsayıları kullanılarak tahmini emisyonlar hesaplanmıştır. Bazı özel veya nadir uçak tipleri ise mevcut veri tabanında yer almadığından hesaplamalara dahil edilmemiştir; bu durum, toplam emisyonların küçük bir kısmını temsil etmektedir ve çalışmanın genel bulgularını etkilemeyecek düzeydedir.

Çizelge 5.1, Sabiha Gökçen (SAW), Esenboğa (ESB) ve Konya (KYA) havalimanlarında 2014-2023 yıllarına ait toplam 10 yıllık dönemde toplam yakıt tüketiminin kg cinsinden gösterilmiştir.

Çizelge 5.1. Sabiha Gökçen (SAW), Esenboğa (ESB) ve Konya (KYA) havalimanları için 10 yıllık toplam yakıt değerleri (kg)

Havalimanları	Toplam yakıt (kg)
ESB	750.307.054
KYA	198.020.986
SAW	1.781.400.843
Genel Toplam	2.729.728.883

Çizelge 5.1, Sabiha Gökçen (SAW), Esenboğa (ESB) ve Konya (KYA) havalimanlarının 10 yıllık toplam yakıt tüketimini göstermektedir. Sonuçlar, üç havalimanı arasında yakıt kullanımında önemli farklılıklar olduğunu göstermektedir. SAW, 1.781.400.843 kg ile en yüksek toplam yakıt tüketimini kaydetmiş ve toplamın yaklaşık %65,3'ünü oluşturmuştur. ESB, 750.307.054 kg ile yaklaşık %27,5'lik bir paya sahip olarak ikinci sırada yer almıştır. KYA, 198.020.986 kg ile en düşük değeri göstermiş ve toplam tüketimin sadece %7,2'sini oluşturmuştur. Bu dağılım,

havalimanlarının ölçeğini ve operasyonel yoğunluğunu yansıtmaktadır. SAW, büyükşehir ve metropol merkezi olarak hem hava trafiği hacmi hem de uçak tipi çeşitliliği açısından doğal olarak baskındır. Üç havalimanının toplam yakıt tüketimi 2.729.728.883 kg'dır. SAW'ın büyük payı, ulusal havacılıkla ilgili yakıt talebinin ana itici gücü olarak rolünü vurgulamaktadır, KYA'nın nispeten küçük katkısı ise havalimanı konumu itibarıyla toplam havacılık emisyonları üzerindeki etkisinin daha sınırlı olduğunu göstermektedir.

Çizelge 5.2. B738 hava aracı tipine göre 2014 yılı için 3 havalimanının LTO (iniş ve kalkış) ve emisyon değerleri (kg)

Havalimanı	Uçak Tipi	LTO Sayısı	CO ₂ (kg)	HC (kg)	NO _x (kg)	CO (kg)	SO ₂ (kg)	Toplam partikül kütlesi (kg)
SAW	B738	135.555	377.385.120	97.599,6	1.667.327	958.373,9	59.644,2	16.266,6
ESB	B738	52.093	145.026.912	37.506,96	640.743,9	368.297,5	22.920,92	6.251,16
KYA	B738	4.036	11.236.224	2.905,92	49.642,8	28.534,52	1.775,84	484,32

Yukarıda yer alan Çizelge 5.2' de B738 (B737-800) tipi hava aracının 2014 yılına ait toplam örnek iniş kalkış sayıları ve emisyon değerleri verilmiştir. Çalışmada kullanılan üç havalimanı için bu şekilde birçok uçak tipi ve 2014-2023 yıllarını kapsayan 10 yıllık iniş kalkış verisi kullanılmıştır. Sabiha Gökçen (SAW), içerdiği yoğun uçuş trafiği sebebiyle ve B738 tipi uçağın kullanım sıklığından ötürü en yüksek emisyonu sebep olan uçak tipi ve havalimanıdır. Ankara Esenboğa (ESB) ise, orta seviyede yer almakta ve toplam emisyonları Sabiha Gökçen (SAW)'e kıyasla daha düşüktür. Konya (KYA) havalimanı ise en düşük LTO sayısı ve emisyon oranlarına sahiptir. Bu çizelge, havalimanlarının trafik yoğunluğunu ve B738 uçak tipinin kullanım sıklığının toplam CO₂ emisyonlarına doğrudan etkilediğini göstermektedir. Tüm uçak tipleri arasından en yüksek uçuş yapan tip olduğundan, emisyon azaltım stratejilerini öncelikli olarak bu uçak tipinde odaklanması önerilmektedir.

Yakıt tüketimi, iniş ve kalkış (LTO) döngülerinin sayısı ve uçak filosunun büyüklüğü ile doğrudan bağlantılıdır. Yoğun trafiğe sahip havalimanlarında, özellikle orta ve büyük gövdeli uçakların yakıt tüketimi daha yüksek düzeylerde gerçekleşmektedir. Bu nedenle, Çizelge 5.3'te gözlemlenen dağılım, her havalimanının beklenen operasyonel ölçeği ile uyumludur. Veriler, SAW'ın üç havalimanı arasında

havacılık yakıtı tüketimine en büyük katkıyı sağlayan havalimanı olduğunu, ESB'nin ise ikincil bir rol oynadığını, KYA ise en düşük seviyede olduğu doğrulamaktadır.


Çizelge 5.3. Çalışmada incelenen üç havalimanının 10 yıllık emisyon değerleri (t)

Havalimanı	Toplam CO ₂	Toplam HC	Toplam NO _x	Toplam CO	Toplam SO ₂	Toplam Partikül kütlesi (t/LTO)
SAW	5.629.215,0	1.338,6	22.999,9	17.054,2	889,9	240,4
ESB	2.371.060,5	652,4	10.324,6	6.810,1	374,8	106,7
KYA	256.558,8	64,0	1.041,4	805,1	40,5	12,3

Çizelge 5.3, çalışmada incelenen İstanbul Sabiha Gökçen (SAW), Ankara Esenboğa (ESB) ve Konya (KYA) havalimanlarının 2014–2023 yılları arasındaki toplam 10 yıllık uçak emisyonları t (ton) cinsinden göstermektedir. Çizelge verilerine göre, CO₂ emisyonu en yüksek havalimanı 5,63 milyon ton ile SAW olup, ESB 2,37 milyon ton ile ikinci sırada KYA ise 0,26 milyon ton ile en düşük değer olarak yer almaktadır.

Diğer emisyon türlerinde de benzer bir dağılım gözlemlenmektedir: HC (Uçucu Organik Bileşikler), SAW 1.338,6 t ile lider konumda iken, ESB 652,4 t ve KYA 64,0 t değerleriyle daha düşük seviyededir. NO_x (Azot Oksitler), SAW 22.999,9 t ile en yüksek değere sahip, ESB 10.324,6 t ve KYA 1.041,4 t olarak gerçekleşmiştir. CO (Karbon Monoksit), SAW 17.054,2 t ile yüksek seviyede olup, ESB 6.810,1 t ve KYA 805,1 t ile takip etmektedir. SO₂ (Kükürt Dioksit) ve PM (Partikül kütlesi), SAW 889,9 t SO₂ ve 240,4 t PM ile diğer havalimanlarını açık farkla geçmektedir. ESB orta seviyede, KYA ise düşük seviyede emisyon üretmektedir.


Bu sonuçlar, havalimanlarının trafik yoğunluğu ve uçak tiplerine bağlı olarak emisyon miktarlarının farklılık gösterdiğini ortaya koymaktadır. SAW, yoğun yolcu trafiği ve büyük uçak tiplerinin kullanımı nedeniyle tüm emisyon türlerinde lider konumda iken, KYA hem düşük uçuş sayısı hem de küçük uçak tipleri nedeniyle çok daha düşük emisyon değerlerine sahiptir. ESB ise orta seviyede emisyon üretmektedir.



Şekil 5.1. Çalışmada incelenen üç havalimanının LTO safhasında meydana gelen 10 yıllık CO₂ değerleri

Yukarıda yer alan Şekil 5.1 incelendiğinde İstanbul Sabiha Gökçen, Ankara Esenboğa ve Konya Havalimanları için 10 yıllık CO₂ emisyon değerleri karşılaştırılmıştır. 2014-2019 dönemlerinde tüm emisyon türlerinde genel bir artış gözlemlenmiştir. CO₂ ve değeri diğer kirletici gazlara (NO_x, CO, SO₂, HC ve PM) oranla daha fazla salınım gerçekleştirdiği gözlemlenmiştir. Görülen bu artış, havalimanlarındaki uçuş iniş kalkış sayılarının yıllar içinde yükselmesi ile paralel olarak gerçekleşmiştir.

2020 yılında COVID-19 pandemisinin etkisiyle uçuş faaliyetlerinde ciddi bir düşüş yaşanmış ve tüm emisyon türlerinde belirgin bir azalma gözlemlenmiştir. CO₂ ve NO_x emisyonlarındaki düşüş daha ciddiye, CO, SO₂, HC ve PM emisyonları da önemli ölçüde azalmıştır. 2021-2023 döneminde ise havacılık faaliyetlerinin yeniden başlamasıyla beraber emisyonlarda tekrar artış eğilimi gözlemlenmiştir. CO₂ ve NO_x emisyonları pandemi öncesi seviyelere yaklaşırken, diğer kirleticiler de artış göstermiştir ancak genel seviyeleri CO₂ ve NO_x kadar yüksek değildir.



Şekil 5.2. Sabiha Gökçen, Esenboğa ve Konya Havalimanları karşılaştırmalı CO₂ ısı haritası

Yukarıdaki Şekil 5.2’de bulunan CO₂ ısı dağılım haritası incelendiğinde Sabiha Gökçen havalimanının en yüksek ısı derecelerine sahip olduğu, Esenboğa havalimanının ise daha orta değerlerde kaldığı ve Konya havalimanının en düşük CO₂ ısı seviyelerinde olduğu görülmektedir. Bunun en büyük sebebi olarak Uçuş ağındaki yoğunluk ile emisyon değerlerinin doğru orantılı olduğunu söyleyebiliriz. Aynı zamanda geçmişten bugünkü değerlere bakıldığında emisyon oranlarında geçmiş yıllarda son yıllara nazaran daha yüksek ısı seviyelerinin olduğu gözlemlenmektedir. Bu durum gelişen teknoloji, alternatif sürdürülebilir yakıt kullanımının artması ve şirketlerin sürdürülebilirlik politikalarının etkisinin olduğunu göstermektedir.

Aşağıda bulunan Çizelge 5.4’te Sabiha Gökçen, Esenboğa ve Konya havalimanlarının toplam uçak LTO (İniş ve Kalkış) döngülerinin karşılaştırılması yapılarak havalimanı operasyonel ölçeklerindeki farklılıkları açıkça ortaya koymaktadır. İstanbul Sabiha Gökçen Havalimanı’nın Ankara Esenboğa ve Konya Havalimanlarına kıyasla önemli ölçüde daha yüksek uçuş trafiğine sahip olduğu görülmektedir. Bu gözlem, Sabiha Gökçen havalimanının diğer havalimanlarına kıyasla daha yoğun bir ulaşım faaliyetlerinin olduğunu göstermektedir. Esenboğa Havalimanı orta düzeyde bir faaliyet gösterirken, Konya Havalimanı ise en düşük LTO sayılarına sahiptir. Bu farklılıklar, emisyon hesaplanmasında havalimanının bulunduğu şehrin ulaşım yoğunluğunun önemli olduğunu göstermektedir.

Çizelge 5.4. 2014-2023 yılları arasında gerçekleşen Sabiha Gökçen Havalimanı (SAW), Esenboğa Havalimanı (ESB) ve Konya (KYA) havalimanlarında gerçekleşen toplam uçak iniş-kalkış (LTO) sayıları

Toplam Uçak İniş-Kalkış (LTO) Sayıları (2014-2023)		
SAW	ESB	KYA
2.061.477	917.224	78.517

Çalışmadaki uçak tipi ve iniş-kalkış sayıları (LTO) 2014–2023 yılları için Devlet Hava Meydanları İşletmesi (DHMI)’den temin edilmiştir. Emisyon katsayıları ise ICAO Air Quality Manual (2020)’den alınmıştır. Çalışmanın ilerleyen aşamasında, anket yoluyla veri toplama sürecine geçilecek ve emisyonu sebep olan faktörler ÇKKV yöntemlerinden AHP kullanılarak önceliklendirilip analiz edilecektir.

Çizelge 5.5. İncelenen havalimanlarında 2014–2023 yılları arasında en yüksek CO₂ emisyonuna sebep olan üç farklı uçak tipine ait CO₂ ve iniş-kalkış (LTO) değerleri (DHMI)

Uçak Tipi	CO ₂ (kg)	LTO sayısı
B738	4.982.430.144	1.789.666
A320	942.546.540	353.676
A20N	680.867.719	343.699

Çizelge 5.5’te incelediğiniz çizelgeler çalışmanın yalnızca özeti niteliğindedir. Çalışmadaki her havalimanı için 2014-2023 yılları arasındaki her yıl için ayrı ayrı emisyon hesaplaması yapılmıştır. Çizelge 5.5 verilerine göre, B738 (Boeing 737-800), toplam 4.982.430.144 kg CO₂ emisyonu ile en yüksek katkıyı sağlamaktadır. Bu uçak, 1.789.666 LTO gerçekleştirmiştir ve tüm havalimanları içindeki emisyonun büyük bölümünden sorumludur. A320 (Airbus A320), 942.546.540 kg CO₂ ile ikinci sıradadır; toplam 353.676 LTO sayısı ile emisyon üretmektedir. A20N (Airbus A320neo), 680.867.719 kg CO₂ ile üçüncü sırada yer almakta ve 343.699 LTO sayısına sahiptir. Bu bulgular, CO₂ emisyonlarının büyük oranda belirli uçak tiplerine bağlı olduğunu ve emisyon azaltma stratejilerinin en kirlletici uçak tiplerine öncelik vermesi ve trafiğin yoğun olduğu havalimanlarında operasyonel optimizasyonu dikkate alması gerektiğini göstermektedir ve gelecekteki 10 yıllık emisyon tahmin modellerinin geliştirilmesi için tutarlı bir temel sağlamaktadır.

5.2. AHP Yöntemi Sonuçları

Genel havalimanı operasyonları ile ilgili olarak yapılan analiz sonucuna göre grup tutarlılık oranı (CR) 0,063 olarak bulunmuş, bu değer 0,10’un altında olduğundan yapılan karşılaştırmaların tutarlı olduğu sonucuna varılmıştır. Hesaplanan önem ağırlıkları ise Çizelge 5.6’da verilmiştir.

Çizelge 5.6. Havalimanı genel emisyonu sebep olan faktörlerin önem sıralaması

Kriter	Ağırlık (W)
LTO	0,37
GSE (Yer destek ekipmanları)	0,14
APU (Yedek Güç Birimi)	0,12
Ulaşım araçları (otobüs vb.)	0,13
Terminal enerji kullanımı	0,18
Atık Yönetimi	0,06

Elde edilen sonuçlar, havalimanı kaynaklı karbon emisyonlarının büyük ölçüde uçak hareketlerinden (LTO) kaynaklandığını ortaya koyarak literatürü desteklemektedir. Bununla birlikte, yer hizmetleri ekipmanları ve yardımcı güç üniteleri de önemli emisyon kaynakları arasında yer almaktadır. Havalimanı emisyonları içerisinde ise atık yönetimi ve geri dönüşüm faaliyetlerinin payının oldukça sınırlı olduğu görülmektedir. Bu bulgu, emisyon azaltım politikalarının öncelikle uçak operasyonları, yer hizmetleri ve yardımcı güç üniteleri alanlarında yoğunlaştırılması gerektiğini göstermektedir.

Uçak operasyonlarının LTO safhasında oluşan emisyonlara sebep olan faktörlere ilişkin değerlendirme kriterleri aşağıdaki şekilde belirlenmiştir:

- Uçak iniş-kalkış sayısı (LTO döngüsü),
- Yakıt tüketimi,
- Yolcu trafiği (taşınan yolcu sayısı),
- Yük trafiği (kargo, posta ve bagaj ağırlığı),
- Uçak yaşı,
- Uçak tipi

Buradaki kriterlerden uçak iniş-kalkış sayısı (LTO döngüleri) toplam emisyonlarla doğrudan ilişkilidir; döngü sayısı ne kadar fazla olursa, emisyonlar da o kadar yüksek olur. Araştırmalar, LTO döngülerindeki artışın NO_x, CO ve HC emisyonlarında önemli bir artışa yol açtığını tutarlı bir şekilde göstermektedir. Örneğin, LTO döngülerinde %50'lik bir artış, emisyonlarda %55-60'lık bir artışa neden olur (Tokuslu, 2020; Zhou vd., 2019). LTO aşamasında gerçekleşen yakıt tüketimi, emisyon oluşumunun temel belirleyicilerinden biridir. Özellikle kalkış, tırmanma ve taksi esnasında daha fazla yakıt kullanımı, CO₂, NO_x ve PM gibi emisyonları büyük ölçüde arttırmaktadır (Lee vd., 2021). Uçak ve motor tipleri, emisyon indekslerini, yakıt akışını ve aşama özel emisyonları belirler. Taksi süresi ve itme ayarları önemli bir etkiye sahiptir; daha uzun taksi süreleri, daha yüksek HC ve CO emisyonlarına neden olmaktadır. Taksi süresini iki dakika azaltmak, toplam LTO emisyonlarını %4-6 oranında düşürebilir (H. Xu vd., 2020). Yolcu ve kargo trafiği, kullanılan uçakların boyutu ve türünü ve yükünü etkileyerek dolaylı olarak emisyonları etkiler ve böylece LTO başına emisyonları etkiler. Uçakların yaşının doğrudan etkisi minimum düzeydedir; motor teknolojisi ve bakımı daha önemlidir (Zhou vd., 2019).

Uzmanlardan alınan ikili karşılaştırmalar 1–9 ölçeğinde değerlendirilmiş, her bir uzman için ayrı karşılaştırma matrisleri oluşturulmuş ve bu matrislerin geometrik

ortalaması alınarak grup karar matrisi elde edilmiştir. Grup karar matrisinden elde edilen faktörlerin önem dereceleri Çizelge 5.7’de gösterilmiştir.

Uçak operasyonları ile ilgili olarak yapılan analiz sonucuna göre grup tutarlılık oranı (CR) 0,029 olarak bulunmuş, bu değer 0.10’un altında olduğundan yapılan karşılaştırmaların tutarlı olduğu sonucuna varılmıştır.

Çizelge 5.7. Uçaklarda emisyonu sebep olan faktörlerin önem sıralaması

Kriter	Ağırlık	Sıra
LTO sayısı	0,407	1
Yakıt tüketimi	0,238	2
Uçak Tipi	0,119	3
Uçak Yaşı	0,086	4
Yük Trafiği	0,084	5
Yolcu Trafiği	0,062	6

Yukarıda yer alan Çizelge 5.7’de görüldüğü üzere uçak iniş ve kalkış emisyonlarında en yüksek oranda uçak iniş kalkış sayısı, bir sonraki önemli faktörler uçak tipi, yakıt tüketimi ve uçak yaşı olarak hesaplanmıştır. En düşük öneme sahip faktörler ise yük trafiği ve yolcu sayısı olarak belirlenmiştir. Bu durum emisyon performansı konusunda yük ve yolcu faktörlerinin diğer kriterlere kıyasla ikincil bir role sahip olduğunu ortaya koymaktadır. Her ne kadar bütün faktörler birbiriyle bağlantılı olsa da emisyonlar konusunda genel görüşler literatürü destekler niteliktedir.

Yapılan AHP yöntemi sonucunda emisyonlara sebep olan faktörlerin önem dereceleri belirlenmiş, karar yapısının karmaşık hale gelmesini önlemek ve daha yüksek etkili faktörlere odaklanmak için yalnızca AHP sonucunda yüksek önem derecesine sahip kriterler tahmin modeline direkt dahil edilmiştir. Her ne kadar yük trafiği kriteri AHP sonuçlarına göre düşük önem derecesine sahip olsa da havalimanı operasyonlarının bütüncül yapısını yansıtabilmek amacıyla tahmin modeline dahil edilmiştir. Bu kapsamda LTO sayısı yakıt tüketimi, uçak tipi ve uçak yaşı kriterleri ise MOORA analizine taşınmıştır.

5.3. Tahmin Modelleri Sonuçları

Bu bölümde, operasyonel değişkenlerin tahminine ilişkin sonuçlar, kullanılan makine öğrenmesi ve zaman serisi yöntemlerinin performansları ile CO₂ emisyon tahminlerine yönelik elde edilen bulgular sunulmaktadır.

5.3.1. Operasyonel değişkenlerin (girdilerin) tahmini

Giriş değişkenlerinin (LTO, yük trafiği (kargo, posta ve bagaj ağırlığı) ve yakıt tüketimi) tahmin performansı, her havalimanı için RMSE, MAPE ve R^2 ölçütleri kullanılarak değerlendirilmiştir.

Çizelge 5.8. Zaman serileri girdi değişkenlerinin tahmin performansları

Havalimanı	Değişken	Model	RMSE	MAPE (%)	R^2	AIC	BIC
Esenboğa	LTO	SARIMA (1,1,1) (1,0,1)	574,31	5,76	0,896	1880,10	1888,46
		ETS	619	11,10	0,908		
		ARIMA (1,1,1)	984	14,30	0,767		
Esenboğa	Yük Trafiği	SARIMA (2,1,1) (1,0,1)	757,84	5,52	0,858	18,27	29,42
		ETS	1,841	29,58	0,505		
		ARIMA (1,1,1)	2,205	33,01	0,290		
Esenboğa	Yakıt	SARIMA (1,1,2) (1,0,1)	554,448	6,82	0,903	3530,90	3542,05
Esenboğa	Yakıt	ETS	537,273	11,68	0,919		
		ARIMA (1,1,1)	838,788	14,29	0,802		
Sabiha Gökçen	LTO	SARIMA (2,1,1) (1,0,1)	1,363,94	4,01	0,845	2093,96	2105,11
		ETS	941	2,63	0,926		
		ARIMA (1,1,1)	2,078	9,14	0,641		
Sabiha Gökçen	Yük Trafiği	SARIMA (1,1,1) (1,0,1)	1,298,35	3,15	0,945	-95,95	-87,59
		ETS	3,178	95,22	0,800		
		ARIMA (1,1,1)	4,467	91,82	0,605		
Sabiha Gökçen	Yakıt	SARIMA (2,1,2) (1,0,1)	1,135,109	4,13	0,854	3709,75	3723,69
		ETS	781,168	2,64	0,931		
		ARIMA (1,1,1)	1,763,887	9,23	0,647		
Konya	LTO	SARIMA (1,1,1) (0,0,1)	98,87	12,60	0,593	1454,78	1463,14
		ETS	99	38,11	0,661		
		ARIMA (1,1,1)	119	37,63	0,505		

Çizelge 5.8.(devam) Zaman serileri girdi değişkenlerinin tahmin performansları

Havalimanı	Değişken	Model	RMSE	MAPE (%)	R ²	AIC	BIC
Konya	Yük Trafığı	SARIMA (1,0,1) (1,0,1)	41,42	4,65	0,942	-47,54	-39,18
		ETS	118	—	0,835		
		ARIMA (1,1,1)	222	—	0,410		
Konya	Yakıt	SARIMA (1,1,1) (0,0,1)	85,091	12,83	0,661	3078,94	3087,30
		ETS	84,602	46,95	0,709		
		ARIMA (1,1,1)	104,201	51,41	0,558		

Çizelge 5.8’de gösterildiği üzere, SARIMA sonuçları Ankara Esenboğa Havalimanı’na ait tüm girdi değişkenlerinin yüksek doğrulukla tahmin edildiğini göstermektedir. 0,858 ile 0,903 arasında değişen R² değerleri, modelin verilerdeki ilişkileri başarıyla yakaladığını ortaya koymaktadır. Ayrıca, %6’nın altındaki MAPE değerleri, tahmin hatalarının kabul edilebilir sınırlar içinde kaldığını göstermektedir.

Benzer şekilde, Sabiha Gökçen Havalimanı için elde edilen SARIMA sonuçları da güçlü bir tahmin performansı ortaya koymaktadır. Özellikle kargo trafiği değişkeni 0,945 gibi yüksek bir R² değerine ulaşmış olup, bu da modelin bu değişkeni tahmin etmede oldukça etkili olduğunu göstermektedir. Tüm değişkenler genelinde nispeten düşük seyreden MAPE değerleri (yaklaşık %3–4), modelin tutarlılığını ve güvenilirliğini ayrıca teyit etmektedir.

Buna karşılık, Konya Havalimanı için SARIMA modeli, LTO ve yakıt tüketimi değişkenlerinde nispeten daha düşük R² değerleri elde edilmiştir (sırasıyla 0,593 ve 0,661). Bu durum, bu havalimanıyla ilişkili daha küçük veri setine ve daha düşük trafik hacmi ile ilişkilendirilebilir. Bununla birlikte, kargo trafiği değişkeni için elde edilen yüksek R² değeri (0,942), modelin belirli değişkenler için hala güvenilir tahminler üretebildiğini göstermektedir.

ETS modeli ise daha yüksek R² değerleri alarak özellikle yüksek mevsimsel yapı içeren veri setlerinde (örneğin Sabiha Gökçen LTO ve yakıt verileri) oldukça güvenilir sonuçlar vermiştir. Ancak bazı değişkenlerde MAPE değerlerinin yüksek olması, modelin hata oranının daha dengesiz yapıda olduğunu göstermiştir.

ARIMA modeli ise genel olarak diğer modellere kıyasla daha düşük performans sergilemiş olup, özellikle mevsimsel bileşenleri içermemesi nedeniyle zaman serisindeki

periyodik dalgalanmaları yeterince yakalayamamıştır. Bu durum, daha yüksek RMSE ve MAPE değerleri ile kendini göstermektedir.

Konya havalimanına ait bazı değişkenlerde MAPE değerlerinin hesaplanamaması (sıfır değerler sebebiyle) bu metriğin her durumda güvenilir olmayabileceğini göstermekte ve bu tür durumlarda model performansının değerlendirilmesinde R^2 ve RMSE değerleri daha anlamlı bir gösterge sunmuştur.

Genel olarak, SARIMA tabanlı tahmin yaklaşımı, tüm havalimanları için, özellikle orta ve yüksek trafikli havalimanları için güvenilir giriş tahminleri sağlamaktadır. Bu sonuçlar, sonraki CO₂ emisyon modelleme aşaması için sağlam ve tutarlı bir temel oluşturmaktadır.

5.3.2. Girdilere ilişkin makine öğrenmesi sonuçları

Bu kısımda operasyonel değişkenlerin yalnızca zaman serisi ile değil aynı zamanda farklı tahmin modelleri ile de karşılaştırma yapılması amacıyla literatürde de en yaygın kullanılan makine öğrenimi modellerinden DVR, Boost ve Random Forest (RF) olarak 3 farklı model performansları girdi değerlerinin performans göstergeleri Çizelge 5.9’da verilmiştir.

Çizelge 5.9. Makine Öğrenmesi için girdi performans göstergeleri sonuçları

Havalimanı	Model	Değişken	RMSE	MAPE (%)	R^2
ESB	DVR	LTO	496	5,69	0,781
	Boost	LTO	775	9,73	0,466
	RF	LTO	623	7,19	0,655
	DVR	Yük	1379	12,28	0,460
	RF	Yük	1399	13,02	0,445
	Boost	Yük	1711	15,35	0,169
	DVR	Yakıt	430,851	6,32	0,709
	Boost	Yakıt	704,001	11,34	0,224
	RF	Yakıt	851,989	13,53	-0,137
SAW	DVR	LTO	1010	4,17	0,834
	Boost	LTO	1567	6,65	0,600
	RF	LTO	1300	5,62	0,725
	DVR	Yük	4285	10,11	0,266

Çizelge 5.9.(devam) Makine Öğrenmesi için girdi performans göstergeleri sonuçları

Havalimanı	Model	Değişken	RMSE	MAPE (%)	R ²
	Boost	Yük	3975	9,08	0,369
	RF	Yük	4488	10,10	0,196
	DVR	Yakıt	1,012,619	5,91	0,673
	Boost	Yakıt	1,116,369	6,07	0,602
	RF	Yakıt	1,069,228	6,14	0,635
KONYA	DVR	LTO	108	16,07	0,037
	Boost	LTO	107	14,25	0,051
	RF	LTO	98	14,42	0,198
	DVR	Yük	115	12,43	0,564
	Boost	Yük	145	16,06	0,308
	RF	Yük	128	12,35	0,459

Model performans göstergeleri incelendiğinde, her havalimanı ve her girdi için farklı performans göstergeleri bulunsa da MAPE oranları benzer seviyede olduğu belirlenmiş ancak R² (açıklayıcılık) değerlerinin her havalimanı ve girdiler için farklı sonuçlar verdiği gözlemlenmiştir. Özellikle Konya havalimanı gibi düşük veri hacmine sahip havalimanlarında daha düşük R² değerlerine sahip olması da makine öğrenimi yaklaşımlarının sınırlı veri yapılarında tahmin performansının azalabildiğini göstermektedir.

SARIMA modelleri için hesaplanan AIC ve BIC değerlerinin ayrıldığı, tüm havalimanları ve değişkenler için değerlerin bir dağılımının gösterildiği görülmektedir. Daha düşük AIC ve BIC değerleri modelinde veri ile daha iyi uyum yaşandığını ifade etmektedir. Özellikle bazı değişkenlerde (örneğin yük şeması) negatif AIC değerlerinin elde edilmesi, modelin veriyle güçlü uyum sağladığını göstermektedir. Bununla birlikte, bu başarılı model seçiminde yalnızca AIC/BIC kriterleri değil, tahminin doğruluğunu doğrudan gösteren RMSE, MAPE ve R² metrikleri esas alınmıştır. Bu nedenle AIC ve BIC değerleri, seçilen modellerin sürdürülmesini sağlayan bir ölçüt olarak değerlendirilmiştir.

Girdi tahmin performansları incelendiğinde, zaman serisi analizi yöntemi olan SARIMA modellerinin Makine öğrenimi modellerine oranla daha iyi sonuç verdiği belirlenmiştir. Aynı zamanda SARIMA modeli verilerin mevsimsel ve trend odaklı

olmasından ötürü daha iyi sonuç verdiği de gözlemlenmiştir. Bu sebeple nihai girdi tahmini için SARIMA modeli seçilmiştir.

5.3.3. CO₂ emisyonlarının zamana bağlı tahmini: SARIMA modeli

İncelenen havalimanlarının CO₂ değerleri ile zamana bağlı tahmin modeli geliştirilmiştir. Zaman serilerinde bulunan ve havalimanlarının mevsimsel olmasının da etkisi ile trend ve mevsimsel bileşenlerin modellenmesi için Mevsimsel Otoregresif Entegre Hareketli Ortalama (SARIMA) yöntemi tercih edilmiştir. Uygulamada aylık veri yapısı dikkate alınarak mevsimsellik değeri 12 olarak belirlenmiş ve tüm veri setleri SARIMA (1,1,1) (1,1,1)₁₂ olarak uygulanmıştır. Model performansı R₂ ve MAPE değerleri ile değerlendirilmiştir.

Çizelge 5.10. SARIMA modeli CO₂ emisyon performans göstergeleri

Havalimanı	R ²	MAPE (%)
ESB	0,8409	13,92
KYA	0,5832	28,84
SAW	0,7976	4,83

Çizelge 5.10 incelendiğinde, SARIMA modelinin ESB ve SAW havaalanlarında belirli bir açıklayıcı güce sahip olduğunu, ancak Konya havalimanı için özellikle yetersiz kaldığını göstermektedir. Konya için elde edilen düşük R² değeri (0,5832), modelin emisyon değerlerini açıklama kapasitesinin sınırlı olduğunu göstermektedir. Bu bulgu, CO₂ emisyonlarını yalnızca zamana bağlı modellemenin yetersiz kalabildiğini göstermektedir.

5.3.4. Makine öğrenmesi yaklaşımları

Bu çalışmada, havalimanı kaynaklı CO₂ emisyonlarını tahmin etmek amacıyla üç farklı makine öğrenimi algoritması; Random Forest, En Küçük Kareler Güçlendirme (LSBoost) ve RBF çekirdeğine sahip Destek Vektör Regresyonu (DVR) yöntemleri kullanılmıştır. Her bir modelin performansı Kök Ortalama Kareler Hatası (RMSE) ve

Ortalama Mutlak Yüzde Hatası (MAPE) kullanılarak değerlendirilmiş ve sonuçlar Çizelge 5.11’de özetlenmiştir.

Çizelge 5.11. CO₂ Emisyon Tahmin Modeli Performans Göstergeleri

Havalimanı	Model	RMSE	MAPE (%)	R ²
ESB	DVR	601,072	2,99	0,945
ESB	LSBoost	811,956	4,02	0,900
ESB	RF	824,519	4,29	0,897
SAW	LSBoost	970,970	1,24	0,972
SAW	DVR	2,250,669	3,50	0,847
SAW	RF	2,867,555	5,82	0,752
KYA	LSBoost	18,515	0,78	0,996
KYA	DVR	43,175	1,98	0,977
KYA	RF	77,230	3,82	0,925

5.3.4.1. Destek vektör regresyonu sonuçları

Radyal Temel Fonksiyon (RBF) çekirdeğine sahip Destek Vektör Regresyonu (DVR) modeli, girdi verilerini daha yüksek boyutlu özellik uzaylarına eşleyerek karmaşık ilişkileri modelleyebilen güçlü bir doğrusal olmayan regresyon tekniğidir. DVR için tahmin performansları Çizelge 5.17’de gösterilmiştir.

Ankara Esenboğa Havalimanı için DVR, 601.072 gibi önemli ölçüde daha düşük bir test RMSE ve %2,99'luk bir MAPE elde ederek, Random Forest ve LSBoost modellerini önemli bir farkla geride bırakmıştır. Bu, modelin doğrusal olmayan emisyon modellerini yakalama konusundaki güçlü yeteneğini göstermektedir.

Sabiha Gökçen Havalimanı için DVR modeli, 2,250,669 Test RMSE ve %5,82 MAPE değerleri elde etmiştir. RMSE değeri LSBoost'tan önemli ölçüde düşük olmasına rağmen, MAPE değeri daha yüksektir. Bu durum, DVR'nin büyük mutlak hataları en aza indirmede daha iyi performans gösterirken, LSBoost'un bu veri kümesi için daha iyi göreceli doğruluk sağladığını göstermektedir.

Konya Havalimanı için LSBoost, 18,515 test RMSE ve %0,78 MAPE ile yine en iyi performansı sergilemiştir. Bu, LSBoost'un daha küçük veri kümelerinde bile oldukça etkili olduğunu teyit etmektedir.

Genel olarak, DVR modeli RMSE açısından tutarlı bir şekilde üstün performans sergilemekte ve rekabetçi MAPE değerlerini korumaktadır; bu da onu farklı havalimanı ölçeklerinde en sağlam model haline getirmektedir.

5.3.4.2 LSBoost yöntemi sonuçları

LSBoost (En Küçük Kareler Güçlendirme) algoritması, tahmin doğruluğunu artırmak amacıyla birden fazla zayıf öğreniciyi (genellikle karar ağaçlarını) bir araya getiren bir toplu öğrenme yöntemidir. Artık hataları sırayla en aza indirerek, LSBoost tek bir karar ağacına kıyasla daha karmaşık kalıpları tespit edebilmektedir.

Ankara Esenboğa Havalimanı için LSBoost modeli, 1.383.829 test RMSE ve %6,85 MAPE değerlerine ulaşarak Random Forest modeline göre hafif bir iyileşme göstermiştir. Ancak, bu iyileşme sınırlı kalmıştır; bu da modelin verilerdeki belirli doğrusal bozukluklar için zorlandığını göstermektedir.

Sabiha Gökçen Havalimanı için LSBoost modeli daha başarılı performans sergilemiştir. MAPE değeri %1,21 ile oldukça düşük olup yüksek göreceli doğruluğu gösterirken, RMSE değeri 4.650.304'e ulaşmış ve bu Karar Ağacı modelinden belirgin şekilde daha yüksektir. Bu tutarsızlık, modelin ortalama yüzde hatalarında iyi performans göstermesine rağmen, mutlak terimlerle büyük sapmalara karşı hala duyarlı olabileceğini göstermektedir. Bu davranış, veri setinde aşırı değerlerin varlığı veya yüksek değişkenlikle ilişkilendirilebilir.

Konya Havalimanı için LSBoost modeli, 18,515 test RMSE ve %0,78 MAPE değerlerine ulaşarak makul bir performans sergilemiştir.

5.3.4.3 Random Forest yöntemi sonuçları

Bu çalışmada, Random Forest algoritması, CO₂ emisyon tahmin performansını değerlendirmek için kullanıldı. Random Forest, birçok karar ağacını birleştiren bir yöntemdir ve daha stabil tahminler vermektedir. Model performansı, RMSE, MAPE ve R² metrikleriyle değerlendirilmiştir. Sonuçlar, Random Forest'ın farklı havalimanlarında birbirinden farklı performanslar sergilediğini göstermektedir. Ankara Esenboğa Havalimanı için RMSE = 1,374,602 ve MAPE = %6,74 değerleri elde edildi. Ancak DVR modeli daha düşük hata değerleri göstermiştir. Sabiha Gökçen Havalimanı'nda daha düşük performans (RMSE = 3,949,914, MAPE = %8,53) görülmüştür. Konya Havalimanı'nda ise daha başarılı sonuçlar (RMSE = 63,672, MAPE = %3,28)

sağlanmıştır. Overfitting analizi, modelin genelleme yeteneğinin yüksek olduğunu göstermektedir ancak DVR ve LSBoost algoritmaları, daha düşük hata oranları ile daha iyi performansa sahip olduğunu göstermektedir. Random Forest, nihai tahmin modeli olarak seçilmedi fakat karşılaştırma sürecinde destekleyici bir yöntem olarak değerlendirilmiştir.

5.3.5. Performans karşılaştırması ve model seçimi

Bu çalışmada, havalimanı kaynaklı CO₂ emisyonlarını tahmin etmek amacıyla üç farklı makine öğrenimi modelinin (Random Forest, LSBoost ve Destek Vektör Regresyonu (DVR)) performansı değerlendirilmiştir. Model doğruluğu ve güvenilirliğinin kapsamlı bir şekilde değerlendirilmesini sağlamak amacıyla, değerlendirme Kök Ortalama Karese Hata (RMSE), Ortalama Mutlak Yüzde Hata (MAPE) ve belirleme katsayısı (R^2) gibi çeşitli performans ölçütleri kullanılarak gerçekleştirilmiştir. Karşılaştırmalı sonuçlar, model performansının trafik hacmi, veri değişkenliği ve karmaşıklık gibi her bir havalimanı veri setinin özelliklerine bağlı olarak değiştiğini göstermektedir.

Ankara Esenboğa Havalimanı için DVR modeli, en düşük RMSE (601.072) ve MAPE (%2,99) değerlerini elde ederek ve 0,945 gibi yüksek bir R^2 değerine ulaşarak diğer modellerden açıkça üstün performans göstermiştir. Bu, modelin girdi değişkenleri ile CO₂ emisyonları arasındaki doğrusal olmayan ilişkileri yakalama konusundaki güçlü yeteneğini göstermektedir. Buna karşılık, LSBoost modeli nispeten daha yüksek hata değerleri göstermiş olup, bu da bu veri setindeki karmaşık emisyon dinamiklerini modelleme konusundaki sınırlı yeteneklerini ortaya koymuştur.

Sabiha Gökçen Havalimanı için, düzenlemeli LSBoost modeli genel olarak en iyi performansı Sergilemiştir. Düzenlenmemiş haliyle nispeten daha yüksek bir RMSE değerine sahip olmasına rağmen, düzenlemeli versiyon tahmin doğruluğunu önemli ölçüde artırarak %1,21'lik bir MAPE ve 0,984'lük bir R^2 değeri elde etti. Bu durum, topluluk tabanlı yöntemlerin uygun şekilde ayarlandığında büyük ölçekli ve karmaşık veri kümeleri için oldukça etkili olduğunu göstermektedir. DVR modeli bazı konfigürasyonlarda LSBoost'a kıyasla daha düşük bir RMSE elde etmesine rağmen, daha yüksek MAPE değeri, daha az tutarlı bir göreceli doğruluğa işaret etmektedir.

Konya Havalimanı için, LSBoost modeli yine en iyi performansı sergilemiş; en düşük RMSE (43.175) ve MAPE (%0,78) değerlerinin yanı sıra en yüksek R^2 değerini

(0,996) elde etmiştir. Ancak, nispeten küçük veri kümesi ve daha düşük trafik hacmi göz önüne alındığında, bu sonuçlar dikkatle yorumlanmalıdır; zira daha küçük veri kümeleri aşırı iyimser performans metriklerine yol açabilir.

Model sağlamlığını daha ayrıntılı olarak değerlendirmek amacıyla, eğitim ve test RMSE değerleri karşılaştırılarak bir aşırı uyum analizi gerçekleştirilmiştir. Sonuçlar, eğitim ve test hataları arasındaki farkların genel olarak ılımlı veya negatif olduğunu göstermiştir; bu da modellerin aşırı uyum sorunu yaşamadığını göstermektedir. Özellikle, birkaç durumda gözlemlenen negatif fark değerleri, modellerin iyi genelleme yaptığını göstermektedir; ancak bu durum, eğitim ve test kümeleri arasındaki veri dağılımındaki farklılıkları da yansıtabilmektedir.

Genel değerlendirmeye dayanarak, her bir havalimanı için nihai model seçimi, düşük RMSE, düşük MAPE, yüksek R^2 ve genelleme yeteneği gibi performans kriterlerinin birleşimi dikkate alınarak belirlenmiştir. Buna göre, Esenboğa havalimanı için en uygun model olarak DVR modeli seçilirken, Sabiha Gökçen ve Konya Havalimanı içinse düzenlemeli LSBoost modeli seçilmiştir. Çizelge 5.12’de nihai sonuç çizelgesi yer almaktadır.

Çizelge 5.12. Her havalimanı için nihai CO₂ emisyon tahmin modeli sonuçları

Havalimanı	Seçilen Model	R^2	MAPE (%)
ESB	DVR	0,945	2,99
SAW	LSBoost	0,972	1,24
KONYA	LSBoost	0,996	0,78

Sonuç olarak, bulgular, doğrusal olmayan ve ensemble tabanlı makine öğrenimi modellerinin havalimanı düzeyindeki CO₂ emisyonlarının modellenmesinde üstün performans sağladığını göstermektedir. Ayrıca, sonuçlar, tüm durumlarda tek bir modele güvenmek yerine, veri setinin özelliklerine göre uyarlanmış model seçiminin önemini vurgulamaktadır.

5.3.6. Aşırı uyum hesaplaması ve karşılaştırmalı analiz

Yüksek doğruluk değerleri tek başına modelin güvenilir olduğunu göstermemesi sebebiyle modellerin genelleme yeteneklerini değerlendirmek amacıyla veriler %80 eğitim, %20 Test olarak bölünerek bir aşırı uyum analizi gerçekleştirilmiştir. Aşırı uyum problemini önlemek amacıyla eğitim verisinden ayrıca bir doğrulama alt kümesi

oluşturulmuştur. Model hiperparametreleri bu doğrulama verisi üzerinden optimize edilerek model performansı değerlendirilmiştir. Zaman serisi yapısının korunması amacıyla veri bölme işlemi kronolojik sıraya göre gerçekleştirilmiştir. Eğitim verisinin %20'lik kısmı doğrulama (validation) verisi olarak ayrılmıştır.

Bu analizde, doğrulama RMSE ile test RMSE arasındaki fark ($\Delta RMSE$) temel bir gösterge olarak kullanıldı: $\Delta RMSE = RMSE_{test} - RMSE_{validation}$.

Çizelge 5.13. Havalimanları arasında geçerlilik ve test RMSE değerlerinin karşılaştırılması

Havalimanı	Model	Validation RMSE	Test RMSE	$\Delta RMSE$
Esenboğa	RF	8,656,067	3,798,579	-4,857,488
	LSBoost	6,686,743	2,660,677	-4,026,066
	DVR	12,976,901	8,298,926	-4,677,975
Sabiha Gökçen	RF	8,208,348	4,191,026	-4,017,322
	LSBoost	6,378,977	1,802,492	-4,576,485
	DVR	13,469,095	4,377,427	-9,091,668
Konya	RF	549,255	182,064	-367,191
	LSBoost	484,655	135,748	-348,908
	DVR	888,562	306,821	-581,742

Genel olarak hem pozitif hem de negatif $\Delta RMSE$ değerleri gözlemlenmiştir. Pozitif $\Delta RMSE$ değerleri potansiyel aşırı uyum sorununa işaret ederken, negatif değerler güçlü genelleme yeteneğini göstermektedir.

Random Forest modeli overfitting analizi kapsamında incelendiğinde, validation ve test hata değerleri arasındaki farkın oldukça düşük olduğu görülmektedir. Bu durum modelin genelleme kabiliyetinin yüksek olduğunu göstermektedir. Ancak düşük $\Delta RMSE$ değerine rağmen, toplam hata (RMSE) açısından DVR ve LSBoost modellerinin daha iyi performans sergilediği belirlenmiştir. Bu nedenle Random Forest modeli, stabil bir yapı sunmasına rağmen nihai model olarak tercih edilmemiştir.

Bu çalışmanın önemli bir bulgusu, girdi değişkeni tahminlerinden kaynaklanan hataların modelleme sürecinde yayılması ve CO₂ emisyon tahminlerini doğrudan

etkilemesidir. SARIMA tabanlı girdi tahminlerinin getirdiği belirsizlikler, makine öğrenimi modellerinin performansını etkilemektedir.

Bu durum, modellerin bir zayıflığı olarak değil, çok aşamalı tahmin sistemlerinin doğasında var olan bir özellik olarak yorumlanmalıdır. Bu bulgular, emisyon tahmin çalışmalarında girdi belirsizliğini dikkate almanın önemini vurgulamaktadır.

5.3.6.1 Sabiha Gökçen Havalimanı aşırı uyum ve hata analizi incelemesi

Çizelge 5.13'te LSBoost modeli için negatif bir $\Delta RMSE$ değeri elde edilmiştir; bu da modelin aşırı uyum göstermediğini ve güçlü bir genelleme yeteneğine sahip olduğunu göstermektedir. Düzenleme parametrelerinin kullanılması, bu performans artışına önemli ölçüde katkıda bulunduğu düşünülmektedir. Benzer şekilde, DVR modeli de negatif $\Delta RMSE$ değerleri göstermektedir. Ancak, bu durumda genel performansı LSBoost modelinden biraz daha düşüktür.

Sonuç olarak hem tahmin doğruluğu hem de genelleme performansı göz önüne alındığında, düzenlemeli LSBoost modeli Sabiha Gökçen Havalimanı için en uygun model olarak belirlenmiştir.

5.3.6.2. Esenboğa Havalimanı aşırı uyum ve hata analizi incelemesi

Çizelge 5.13'te gösterildiği gibi LSBoost modeli, doğrulama hatalarından test hatalarına doğru belirgin bir artış sergilemektedir. Özellikle, gözlemlenen yüksek $\Delta RMSE$ değeri, aşırı uyum eğilimi olduğunu göstermektedir.

Buna karşın, DVR modeli farklı bir eğilim sergilemektedir. Test RMSE'sinin doğrulama RMSE'sinden daha düşük olması (negatif $\Delta RMSE$), modelin aşırı uyum sorunuyla karşılaşmadığını ve güçlü bir genelleme yeteneğine sahip olduğunu göstermektedir. Ancak, nispeten daha yüksek doğrulama hatası, veri dağılımındaki varyasyonların model performansını etkileyebileceğini düşündürmektedir.

Genel olarak, DVR modeli Esenboğa Havalimanı için daha dengeli ve genelleştirilebilir sonuçlar sunmaktadır.

5.3.6.3. Konya Havalimanı aşırı uyum ve hata analizi incelemesi

Çizelge 5.13'te gösterildiği gibi, tüm modeller negatif $\Delta RMSE$ değerleri sergilemektedir; bu da hiçbir modelin aşırı uyum sorunuyla karşılaşmadığını ve test veri setinde daha iyi performans gösterdiğini göstermektedir. Ancak bu sonuçlar dikkatle

yorumlanmalıdır. Konya Havalimanı'ndaki veri setinin nispeten küçük olması ve trafik hacminin düşük olması nedeniyle, model performansı aşırı iyimser görünebilir. Dolayısıyla, bu sonuçların genelleme yapısı sınırlı olabilir.

Buna rağmen, LSBoost modeli en düşük hata değerlerine ulaşmakta ve en istikrarlı performansı sergilemektedir; bu da onu Konya Havalimanı için en uygun model haline getirmektedir.

5.4. MOORA Yöntemi Sonuçları

Her uçak tipi için tüm kriterlerin ağırlıklı normalize değerleri her havalimanı için ayrı ayrı hesaplanmış ve ağırlıklandırılmış karar matrisi elde edilmiştir. Değerler her havalimanı için ayrı ayrı hesaplanmıştır. Her havalimanı uçuş verileri birbirinden farklı olduğundan dolayı her bir havalimanı ayrı ayrı değerlendirilmiş olup aşağıda çizelge olarak gösterilmiştir.

Çalışmada verilerin güvenilir sonuçlar verebilmesi açısından yolcu ve kargo uçakları ve diğer iş jetleri gibi uçaklar kendi aralarında gruplandırılmış ve genel sonuçlarda yolcu ve kargo uçakları olduğundan sonuç bulgular çizelgeler halinde yolcu ve kargo olarak her havalimanı için ayrı ayrı sonuçlar gösterilmiştir.

Aşağıda yer alan Çizelge 5.14'te bulunan Sabiha Gökçen havalimanı için 2014-2024 yıllarının ortalaması ile belirlenen en çevreci olarak belirlenen uçak tipleri aşağıdaki gibidir.

Çizelge 5.14. Sabiha Gökçen Havalimanı için 2014-2023 yılları arasında belirlenen en çevreci uçak tipleri

Kategori	Uçak tipi	Ortalama Filo Yaşı	Toplam LTO	Toplam Yakıt	Toplam CO ₂	Toplam NO _x	Rank
Passenger	B38M	2,5	13046	991496	3144086	4174,72	1
Other	C25M	5,5	10	1450	4580	2,8	2
Passenger	E50P	10,83	47	6815	21526	13,16	3
Other	E550	11,5	713	103385	326554	199,64	4
Other	C510	11,57	88	12760	40304	24,64	5

Sabiha Gökçen Havalimanında 2014-2023 yılları için B38M (737 MAX 8) modelinin eski nesil B738'e göre daha çevreci uçak tipi olarak gözlemlenmektedir. C25M, E50P, E550 VE C510 gibi diğer uçak tipleri de çevreci diğer uçak tipleri

arasındadır. Burada ortalama filo/uçak yaşı ortalaması daha düşük olduğu yani çevreci uçakların daha genç olduğu gözlemlenmektedir.

Çizelge 5.15. Sabiha Gökçen Havalimanı için 2014-2023 yılları arasında belirlenen en kirlетici uçak tipleri

Kategori	Uçak tipi	Ortalama Yaş	Toplam LTO	Toplam Yakıt	Toplam CO ₂	Toplam NO _x	Rank
Passenger	B741	49,67	20	71960	227400	990,4	1
Passenger	B742	44,5	22	79156	250140	1089,44	2
Cargo	C130	62,5	424	1374608	4343880	18181,12	3
Cargo	AN12	59,33	658	2133236	6741210	28215,04	4
Passenger	L188	57	12	38904	122940	514,56	5

Çizelge 5.15 incelendiğinde, SAW’da da en kirlетici tipler yaşlı geniş gövdeler ve ağır kargo uçakları olarak belirlenmiştir. B741 ve B742 tipleri yolcu uçağı kategorisinde yüksek emisyonu sebep olan uçak tiptiyken, C130 ve AN12 tipi gibi kargo uçakları da yine aynı şekilde yüksek kirlетicilik oranlarına sahip olduğu gözlemlenmektedir.

Çizelge 5.16. Esenboğa Havalimanı için 2014-2023 yılları arasında belirlenen en çevreci uçak tipleri

Kategori	Uçak tipi	Ortalama Yaş	Toplam LTO	Toplam Yakıt	Toplam CO ₂	Toplam NO _x	Rank
Passenger	B38M	2	5791	440116	1395631	1853,12	1
Other	C68A	4	433	62785	198314	121,24	2
Other	E550	5	237	34365	108546	66,36	3
Other	C25M	6	13	1885	5954	3,64	4
Other	EA50	10	106	15370	48548	29,68	5

Çizelge 5.16 incelendiğinde Sabiha Gökçen’de de en verimli uçak tipi olan B738 MAX (B38M) uçak tipinin Esenboğa Havalimanında da en verimli uçak tipleri sıralamasına girmiştir. Devam eden uçak tipleri olan C68A, E550, C25M, EA50 gibi uçak tipleri de diğer en çevreci uçak tipleri derecesine girmiştir.

Çizelge 5.17. Esenboğa Havalimanı için 2014-2023 yılları arasında belirlenen en kirlетici uçak tipleri

Kategori	Uçak tipi	Ortalama Yaş	Toplam LTO	Toplam Yakıt	Toplam CO ₂	Toplam NO _x	Rank
Passenger	B743	42	38	133152	420812	2470	1

Çizelge 5.17.(devam) Esenboğa Havalimanı için 2014-2023 yılları arasında belirlenen en kirletici uçak tipleri

Kategori	Uçak tipi	Ortalama Yaş	Toplam LTO	Toplam Yakıt	Toplam CO ₂	Toplam NO _x	Rank
Cargo	C130	63	1386	4493412	14199570	59431,68	5
Other	A345	17	59	199007	628881	3802,55	2
Other	A346	17	508	1713484	5414772	32740,6	3
Passenger	B742	47	220	791560	2501400	10894,4	4

Çizelge 5.17, Esenboğa havalimanı için 2014-2023 yılları arasında belirlenen en kirletici uçak tipleri gösterilmektedir. Buna göre B743 yolcu uçağı en yüksek kirleticilik oranına sahipken A345, A346, B742, C130 gibi uçak tipleri de benzer oranda kirleticiliğe sahip olduğu gözlemlenmektedir.

Çizelge 5.18. Konya Havalimanı için 2014-2023 yılları arasında belirlenen en çevreci uçak tipleri

Kategori	Uçak tipi	Ortalama Yaş	Toplam LTO	Toplam Yakıt	Toplam CO ₂	Toplam NO _x	Rank
Passenger	B38M	3	308	74228	23408	98,56	1
Other	E550	5	14	6412	2030	3,92	2
Other	EA50	9,67	10	4580	1450	2,8	3
Other	C510	11,33	30	13740	4350	8,4	4
Other	C680	14,33	60	27480	8700	16,8	5

Çizelge 5.18, Konya havalimanı uçak operasyonlarında 2014-2023 yılları arası için en çevreci uçak tiplerini göstermektedir. Bu çizelge incelendiğinde B38M uçak tipi gibi uçak tipleri de genellikle diğer havalimanlarında olduğu gibi düşük emisyon yayan uçak tiplerinden biri olduğu gözlemlenmektedir. Diğer uçak tiplerine bakacak olursak E550, EA50, C510 ve C680 uçak tiplerinin aynı zamanda düşük emisyon yayan çevreci uçaklar olduğu gözlemlenmektedir.

Çizelge 5.19. Konya Havalimanı için 2014-2023 yılları arasında belirlenen en kirletici uçak tipleri

Kategori	Uçak tipi	Ortalama Yaş	Toplam LTO	Toplam Yakıt	Toplam CO ₂	Toplam NO _x	Rank
Cargo	C130	61,5	203	2079735	658126	8704,64	1
Cargo	C160	50,67	155	1587975	502510	6646,4	2
Cargo	IL76	42,33	29	297105	94018	1243,52	3
Passenger	B39M	1	14	27328	52948	971,88	4

Çizelge 5.19.(devam) Konya Havalimanı için 2014-2023 yılları arasında belirlenen en kirletici uçak tipleri

Kategori	Uçak tipi	Ortalama Yaş	Toplam LTO	Toplam Yakıt	Toplam CO ₂	Toplam NO _x	Rank
Passenger	A333	25,25	256	1805312	571392	9105,92	5

Çizelge 5.19 incelendiğinde Konya havalimanında 2014-2023 yılları için en kirletici uçak tiplerinin genelde kargo uçaklarına ait olduğunu ve yaşlı filoya sahip olduğunu gözlemlenmektedir. B39M yolcu uçağının genç filo olarak kirletici uçak tipleri arasında yer olması ise Konya havalimanının daha az uçuş ağına sahip olması ile ilişkilendirilebilir.

5.5. İyimserlik ve Kötümserlik Yaklaşımları Altında Senaryo Analizi

Çalışmada, Sabiha Gökçen, Esenboğa ve Konya havalimanlarında kullanılan uçak tipleri, MOORA yöntemi uygulanarak “verimli (iyimser, yeşil)” ve “verimsiz (kötümser, kirletici)” olmak üzere iki grupta sınıflandırılmıştır. MOORA yönteminde uçak tipleri alternatif olarak ele alınırken, kriterler de yakıt tüketimi, CO₂ emisyonu, NO_x emisyonu ve ortalama uçak yaşı olarak belirlenmiştir. Her bir uçak tipi için hesaplanan sıralama değerleri doğrultusunda ilgili havalimanlarında ortalama değer altında kalan uçaklar “yeşil ve çevreci” olarak belirlenmiş, geri kalanlar uçaklar “kirletici” grup olarak belirlenmiştir.

Her havalimanında verimli ve verimsiz olan gruplarda bulunan uçak sayıları MOORA analizi ile hesaplanmıştır. Sabiha Gökçen havalimanı için 77 verimli 76 verimsiz uçak tipi bulunurken, Esenboğa havalimanında 77 verimli ve 77 verimsiz, Konya havalimanında ise 31 verimli 31 verimsiz uçak tipi belirlenmiştir. Bu sayede çalışmada yer alan havalimanlarında verimli ve verimsiz olarak gruplandırılan bu uçakların sayısal olarak belirlenen verilerin birbirine yakın olduğu ama LTO yoğunluğu bakımından önemli farklılıklarının olduğu gözlemlenmektedir.

Ayrıca MOORA sonuçlarına göre, her havalimanı için verimli ve verimsiz olarak iki gruba ayrılmış ve LTO sayıları hesaplanmıştır. Bu LTO değerinden yararlanılarak filo düzeyinde bir verimlilik indeksi hesaplanmıştır. Verimlilik indeksi, verimli gruba düşen toplam LTO sayısının havalimanı toplam LTO sayısına oranı olarak hesaplanmıştır ve bu veriler aşağıda Çizelge 5.20’de gösterilmiştir.

Çizelge 5.20. İlgili havalimanlarında kullanılan uçakların verimlilik analizi

Havalimanı	Verimli (n)	Verimsiz (n)	Yakıt (kg/LTO) Verimli / Verimsiz	CO ₂ (kg/LTO) Verimli / Verimsiz	NO _x (kg/LTO) Verimli / Verimsiz	Toplam LTO	Verimlilik İndeksi
ESB	77	77	315 / 1805	996 / 5575	2,54 / 25,55	891,463	0,129
KONYA	31	31	267 / 1298	843 / 3781	1,95 / 16,79	74,834	0,116
SAW	77	76	320 / 1830	1012 / 5652	2,56 / 25,21	2,047,280	0,235

Çizelge 5.20’de, ilgili havalimanlarında uçan uçakların verimlilik analizi yapılmış ortalamanın üzerinde bulunan uçak tipleri en çevreci uçaklar olarak sıralanarak daha az emisyonu sebep olurken, geri kalan uçak tipleri kötümser senaryolarda temsil edilen uçak tipleri olarak belirlenmiştir. Sabiha Gökçen (SAW) uçuş yoğunluğu sebebiyle en büyük çevresel yükü oluşturmakta; Konya ise küçük operasyon hacmi ve daha dengeli filo yapısı sebebiyle en verimli havalimanı görünümündedir.

5.6. CO₂ Emisyon Tahmini ve Senaryo Analizleri


Bu bölümde, önerilen tahmin çerçevesinden elde edilen gelecekteki CO₂ emisyon tahminleri sunulmaktadır. Sonuçlar, hem temel (normal) tahminleri hem de senaryo temelli tahminleri içermekte olup, SARIMA tabanlı girdi tahminleri ile makine öğrenimi modellerini birleştiren bütünleşmiş modelleme yaklaşımıyla tutarlılığı sağlamaktadır.

5.6.1. CO₂ emisyon tahmini

Temel senaryo, tahmin modelinin herhangi bir değişiklik yapılmaksızın doğrudan çıktısını yansıtmaktadır. Bu tahminler, her havalimanı için seçilen en iyi performans gösteren modeller kullanılarak oluşturulmuştur (ESB DVR, SAW ve KYA için LSBoost). Sonuçlar, 120 aylık (10 yıllık) bir zaman diliminde CO₂ emisyon tahminlerini sunmaktadır.

5.6.1.1. Sabiha Gökçen Havalimanı CO₂ emisyon tahmini

Sabiha Gökçen Havalimanı için yapılan CO₂ emisyon tahminleri aşağıdaki Şekil 5.3’te verilmiştir. Yüksek trafik hacmi ve operasyon yoğunluğu nedeniyle, Sabiha Gökçen Havalimanı analiz edilen tüm havalimanları arasında en yüksek emisyon seviyelerine sahiptir.




Şekil 5.3. Sabiha Gökçen için CO₂ emisyon tahmin grafiği

Şekil 5.3 incelendiğinde, Sabiha Gökçen Havalimanı CO₂ emisyon tahmin verileri gösterilmektedir. Burada siyah çizgi geçmiş verileri, kırmızı çizgi ise 10 yıllık tahmini (121-240. aylar) temsil etmektedir. Y eksenindeki 10^7 ölçeğine göre, aylık emisyonların 36 ile 60 milyon kg arasında dalgalanacağı öngörülmektedir. Model, 80. aylardaki 'pandemi şokunu' etkili bir şekilde yakalamış ve gerçek havacılık toparlanma eğilimleriyle uyumlu bir iyileşme göstermiştir. Tahmin, İstanbul'un havacılık trafiğindeki mevsimsel dalgalanmaları doğru bir şekilde yansıtmaktadır. Yoğun dönemlerde emisyonlar 60 milyon kg eşiğine ulaşmaktadır. Geçmiş eğilimler ile gelecek projeksiyonları arasındaki yüksek uyum, LSBoost modelinin karmaşık mevsimsel verileri genelleştirme ve uzun vadede tahmin tutarlılığını koruma konusunda güçlü olduğunu göstermektedir.

5.6.1.2. Esenboğa Havalimanı CO₂ emisyon tahmini

Esenboğa Havalimanı için tahmin sonuçları, Sabiha Gökçen Havalimanı'na kıyasla nispeten istikrarlı bir emisyon eğilimi göstermektedir. Tahmin edilen CO₂ emisyonları, tahmin dönemi boyunca 20 milyon kg ile 23 milyon kg arasında değişmektedir. Emisyonlardaki ılımlı artış, trafik artışı olmakla birlikte bunun daha büyük metropol havalimanlarındaki kadar yoğun olmadığı dengeli bir operasyon yapısını yansıtmaktadır.

Sonuçlar ayrıca emisyon değişkenliğinin daha düşük olduğunu göstermekte olup, bu da operasyonel davranışın daha öngörülebilir olduğunu işaret etmektedir.




Şekil 5.4. Esenboğa için CO₂ emisyon tahmin grafiği

Ankara Esenboğa Grafiği incelendiğinde, Orta standart ve çeşitlilik veriyi en iyi normalize eden DVR (Destek Vektör Regresyon) çalıştırılmıştır. Tahmin Başarısı: %94,5 R^2 açıklayıcılık oranı ve %2,99 MAPE hata payı ile yüksek kararlılık sağlandı. Model, 80. ayda sert düşüşten etkilenmeyerek toparlanma (iyileşme) aşamasını başarıyla yakalamıştır. Emisyonların yıllık ortalama 21-22 milyon kg CO₂ 10⁷ işleyişinde) seviyesinde stabil olması özelliği. Güven aralığının (CI) sabit genişliği, 10 yıllık projeksiyonda düşük varyanslar ve yüksek kararlılığı kanıtlanır.

Tahmin eğrisindeki dalgalanmalar, Ankara'daki uçuş trafiğinin mevsimsel döngüsünü (yaz/kış farklılıklarını) yansıtmaktadır. Model, bu mevsimselliği koruyarak güvenilir bir biçimde geleceğe projekte etmiştir.

5.6.1.3. Konya Havalimanı CO₂ emisyon tahmini



Şekil 5.5. Konya için CO₂ emisyon tahmin grafiği


Bu çalışmada incelenen üç havalimanı arasında, Konya Havalimanı (KYA), daha özel bir operasyonel ölçeğe sahip bölgesel bir merkez olarak rolünü yansıtan en düşük mutlak emisyon seviyelerine sahiptir. 2024–2033 dönemi için öngörülen CO₂ emisyonlarının, aylık 2 milyon kg ile 2,5 milyon kg (yıllık yaklaşık 20 ila 25 milyon kg) arasında değişen dar bir aralıkta sabit kalacağı tahmin edilmektedir. Bu nispeten düşük ve istikrarlı emisyon profili, öncelikle havalimanının tutarlı uçuş sıklığına ve Sabiha Gökçen gibi büyük merkezlerde görülen yüksek yoğunluklu uluslararası transit dalgalanmalarının bulunmadığı trafiğinin kendine özgü bölgesel özelliklerine yorulabilir. Modelleme açısından, LSBoost algoritması bu veri seti için son derece etkili olmuş ve 0,996 'lık bir R² değeri ile çalışmanın en yüksek sayısal istikrarını ve %0,78 gibi dikkat çekici derecede düşük bir MAPE değeri sağlamıştır. Bu durum Konya gibi küçük veri değerlerinde LSBoost modelinin daha iyi sonuçlar verdiğini göstermiştir.

5.6.2. Senaryo analizleri

Çalışma, MOORA yöntemi ile uçak tiplerinin verimlilik analizi ile gelecek senaryosunda Baz, İyimser (Yeşil) ve Kötümser senaryo olarak üç ayrı senaryo altında toplanmıştır.

- Baz senaryo: Değişime uğramamış saf tahmin verileri
- Yeşil senaryo: Daha çevre dostu ve yeni nesil uçak tiplerinin (örneğin, B38M) ilgili havalimanında arttığını gösterir. Bu senaryoda, emisyon değerleri belirli sabit bir azaltma oranı değil, her havalimanına özgü dinamik verimlilik endekslerine göre stabilize edilmiştir.
- Kötü senaryo: Daha yüksek emisyonlu ve daha verimsiz eski nesil uçak tiplerinin ilgili havalimanında arttığı durumdaki senaryoyu gösterir. Bu senaryoda, emisyon değerleri de her havalimanına özgü verimlilik endekslerine göre verimsizlik marjına göre yukarı doğru ayarlanmıştır. Bu senaryo filo yenileme çalışmalarının azaldığı ya da gecikmeler sonucu meydana gelebilecek emisyon değerlerini gösteren senaryodur.


Her senaryoda, Destek vektör regresyonu ile tahmin edilen LTO ve emisyon verilerinin aynı trafik oranı içinde farklı filo birleşimlerine göre nasıl değişiklik göstereceği hesaplanmış ve CO₂ için üç ayrı senaryo oluşturulmuştur. Normal, Yeşil ve Kötümser senaryolarda 10 yıllık toplam CO₂ tahmin değerleri verilmiştir.



Şekil 5.6. Sabiha Gökçen Havalimanı için gelecek 120 aylık CO₂ tahmini

Şekil 5.6. incelendiğinde Sabiha Gökçen havalimanı için geçmiş 120 aylık veriler ile gelecek 120 aylık tahmini veriler üç ayrı şekilde gösterilmiştir. Kırmızı olarak gösterilmiş olan grafik çizgileri kötü senaryoyu temsil etmektedir ve emisyonların 35-100 milyon kg değerlerine varacağını göstermektedir. Yeşil olan çizgiler ise daha düşük emisyon seviyelerine varacağını 27-75 milyon kg seviyelerinde olacağını göstermektedir. Mavi olarak gösterilen çizgiler ise normal yani baz tahmin verileridir. Normal tahmin değerlerine bakıldığında 2024-2033 yılları arasında ortalama 30-80 milyon kg CO₂ emisyonu değerlerinde olacağı gözlemlenmektedir. Sabiha Gökçen diğer havalimanlarına kıyasla en yüksek CO₂ tahmini değerlerine sahiptir.


Bu sonuçlar incelendiğinde Sabiha Gökçen Havalimanında uygulanacak bir emisyon azaltım politikasının yaklaşık 3-6 milyon kg CO₂ tasarrufu sağlayabileceği görülmektedir.



Şekil 5.7. Esenboğa için 120 aylık gelecek CO₂ emisyon tahmin senaryoları

Şekil 5.7 incelendiğinde Esenboğa havalimanı için geçmiş 120 aylık veriler ile gelecek 120 aylık tahmini veriler üç ayrı şekilde gösterilmiştir. Kırmızı olarak gösterilmiş olan grafik çizgileri kötü senaryoyu temsil etmektedir ve emisyonların 24-32 milyon kg'a

varacağını göstermektedir. Yeşil olan çizgiler ise daha düşük emisyon seviyelerine varacağını 16-24 milyon kg seviyelerinde olacağını göstermektedir. Mavi olarak gösterilen çizgiler ise normal yani baz tahmin verileridir. Normal tahmin verileri incelendiğinde Esenboğa havalimanının gelecek 2024-2033 yılları arasında yaklaşık 17-25 milyon kg CO₂ salınımı gerçekleştireceği öngörülmektedir. Emisyon azaltım politikaları ile yaklaşık 1-1,5 milyon kg CO₂ tasarrufu sağlanabileceği gözlemlenmiştir.




Şekil 5.8. Konya için gelecek 120 aylık CO₂ tahmin senaryoları

Şekil 5.8 incelendiğinde Konya havalimanı için geçmiş 120 aylık veriler ile gelecek 120 aylık tahmini veriler üç ayrı şekilde gösterilmiştir. Kırmızı olarak gösterilmiş olan grafik çizgileri kötü senaryoyu temsil etmektedir ve emisyonların 2,0-2,6 milyon kg değerlerine varacağını göstermektedir. Yeşil olan çizgiler ise daha düşük emisyon seviyelerine varacağını 1,6-2,0 milyon kg seviyelerinde olacağını göstermektedir. Mavi olarak gösterilen çizgiler ise normal yani baz tahmin verileridir. Normal tahmin verileri incelendiğinde ise yaklaşık 1,8-2,4 milyon kg CO₂ salınımı gerçekleşeceği öngörülmektedir. Diğer havalimanlarına göre en düşük CO₂ seviyeleri Konya havalimanındadır. Bu havalimanında yaşanacak emisyon azaltım strateji ve politikaları ile aylık bazda yaklaşık 100-250 bin kg CO₂ azaltımı gerçekleşebilmesi olağandır.

Yukarıda bulunan şekiller incelendiğinde her bir havalimanı için ayrı ayrı senaryolar ile CO₂ emisyonu grafik ile gösterilmiştir. Sabiha Gökçen yüksek LTO sayısına göre orantılı CO₂ sayısına sahiptir. Bu oranda şehir içi ulaşım trafiğinin önemi oldukça yüksektir. Esenboğa ve Konya havalimanları da benzer oranda bir değişime sahip olmakla birlikte Esenboğa emisyonlar noktasında diğer havalimanlarına kıyasla orta noktada yer almaktadır. Konya havalimanı ise düşük uçuş trafiği sebebiyle ve daha yerel bir konumda

olmasından dolayı daha düşük konumdadır. Aşağıda Sabiha Gökçen Havalimanı için 2014-2033 yılları arasında tahmin edilen CO₂ değerleri verilmiştir.

Aşağıdaki grafiklerde Sabiha Gökçen, Esenboğa ve Konya havalimanları karşılaştırmalı emisyon değerleri gösterilmektedir.



Şekil 5.9. SAW, ESB VE KYA havalimanları için emisyon senaryoları karşılaştırması

Şekil 5.9 incelendiğinde, üç havalimanı arasındaki emisyon büyüklüğü farkını açıkça göstermektedir. Üst Kısımında yer alan İstanbul Sabiha Gökçen (SAW), yüksek trafik yoğunluğu ve geniş filo büyüklüğü nedeniyle en büyük emisyon kaynağıdır. Ankara Esenboğa (ESB) orta seviyede bir emisyon profili sergilerken, Konya (KYA) rekabet ve düşük emisyon seviyeleri nedeniyle en alt kısımda yer almaktadır. MOORA yöntemi kullanılarak kaydedilen verimlilik endekslerinin etkisi, havalimanlarının kapasitesiyle orantılı olarak artmaktadır. İyimser ve Kötümser senaryolar arasındaki fark, SAW için en yüksek orandadır. Bu durum, Sabiha Gökçen’de MOORA temelli önlemlerden (filo yenileme, yakıt oranları) ve önemli büyümeden elde edilen faydaların gerçekleştiğini göstermektedir. ESB için senaryolar arasındaki fark göze çarpmaktadır ancak SAW’daki kadar belirgin değildir. Bu durum, Esenboğa’nın orta seviye özelliklerine uygun bir tepkiyi yansıtmaktadır. Ancak Konya gibi Düşük trafik hacmine sahip bölgesel havalimanlarında, filo modernizasyonunun toplam emisyon üzerindeki marjinal etkisi, yüksek trafikli havalimanlarına göre daha sınırlıdır. Bu bulgu, düşük hacimli havalimanlarında verimlilik artışlarının toplam emisyonlar üzerindeki etkisinin, mutlak trafik artışına kıyasla daha sınırlı olduğunu göstermektedir.

Analizin önemli bir bulgusu, senaryo değişikliklerinin “sabit bir yüzde” (örneğin genel olarak %10 artış) ile değil, “dinamik verimlilik endeksleri” ile belirlenmiş olmasıdır. Sabit bir yüzde kullanılmış olsaydı, Konya için de benzer bir sapma

gözlemlenirdi. Ancak, MOORA sonuçlarının ortaya koyduğu verimlilik analizi sayesinde, her havalimanı kendine has verimlilik performans analizi ile uygun şekilde senaryo grafikleri oluşturulmuştur.

5.7. Tartışma

Bu bölümde; Sabiha Gökçen (SAW), Esenboğa (ESB) ve Konya (KYA) havalimanları için elde edilen emisyon bulguları, çok kriterli karar verme sonuçları ve tahmin modellerinin performansı, mevcut literatür ve operasyonel dinamikler ışığında analiz edilmiştir.

Çalışma sonuçları, emisyon hacminin doğrudan havalimanı kapasitesi ve uçuş ağının yapısıyla (ana aktarma merkezi ve bölgesel) ilişkili olduğunu doğrulamaktadır. Sabiha Gökçen Havalimanı'nın toplam yakıt tüketiminin %65,3'ünü kapsamaması, literatürde yer alan "merkezi aktarma havalimanlarında emisyon yoğunluğu" bulgularıyla (Postorino ve Mantecchini, 2014) örtüşmektedir. AHP analizinin sonuçları bu durumu desteklemekte; emisyon üzerindeki en önemli faktörün LTO (Landing and Take Off) sayısı (0,407) olduğunu açıkça göstermektedir. SAW'ın yoğun uçuş trafiği, emisyon miktarındaki bu orantısız artışın temel gerekçesi olarak değerlendirilmiştir.

İncelenen tüm uçak tipleri içerisinde B737-800'ün (B738) toplam emisyon değerlerinin yaklaşık %80'inden sorumlu olması, Türkiye'deki iç hatlar ile kısa ve orta mesafeli uluslararası uçuşlarda uçak filosunun yapısının çevre üzerindeki etkisini sayısal olarak ortaya koymaktadır. MOORA yöntemi ile yapılan verimlilik analizi, yalnızca LTO sayısının değil, uçak tipinin de emisyon üzerinde önemli rol oynadığını göstermiştir. Özellikle B38M (Boeing 737 MAX 8) tipi uçakların en çevreci model olarak belirlenmesi, yeni nesil motor teknolojilerinin emisyon azaltımındaki potansiyelini göstermektedir. Buna karşın, Konya Havalimanı'nda gözlemlenen yaşlı kargo filolarının (C130, C160) düşük uçuş sayısına rağmen yüksek birim emisyon üretmesi, operasyonel verimlilik odaklı filo yenileme stratejilerinin önemini vurgulamaktadır.

Bu çalışmada kullanılan SARIMA–Makine Öğrenimi (ML) bütünleşik yaklaşımı, literatürdeki geleneksel yöntemlere kıyasla daha yüksek doğruluk sergilemiştir. Benzer çalışmalarda MAPE değerleri genellikle %5 ile %15 aralığında raporlanırken, bu çalışmada SAW için %1,21 ve KYA için %0,78 gibi oldukça düşük hata oranları elde edilmiştir. Elde edilen bu yüksek performans, LSBoost ve DVR algoritmalarının

operasyonel deęiřkenler (yakıt, LTO, yük) arasındaki doęrusal olmayan ve karmařık iliřkileri etkin bir řekilde modelleyebilme yeteneęine dayandırılabilir.

Grafiklerde 80. ay civarında gözlemlenen keskin düşüş, küresel havacılık literatüründeki “pandemi etkisi” verileriyle tutarlıdır. Doğrusal interpolasyon ve SARIMA desteęiyle desteklenen modelin bu düşüşü bir sistem hatası olarak algılamayıp bunun yerine sonrasında gelen toparlanma eğilimini algılaması (V řeklinde toparlanma), modelin güvenilirliğini kanıtlamıştır.



6. SONUÇLAR VE ÖNERİLER

Bu bölümde, araştırma kapsamında elde edilen temel bulgular özetlenmiş, çalışmanın genel sonuçları değerlendirilmiş ve gelecekte gerçekleştirilebilecek çalışmalara yönelik öneriler sunulmuştur.

6.1. Sonuçlar

Bu araştırma, Türkiye'nin havacılık sektöründeki farklı operasyonel ölçekleri temsil eden İstanbul Sabiha Gökçen (SAW), Ankara Esenboğa (ESB) ve Konya (KYA) havalimanlarının uçak kaynaklı emisyon profillerini; hesaplama, kriter önceliklendirme ve Makine Öğrenmesi algoritmalarıyla kapsamlı bir şekilde analiz etmiştir. Çalışmanın çıktıları, sürdürülebilir havacılık yönetimi için stratejik bir karar destek mekanizması sunmaktadır. Elde edilen temel bulgular aşağıda maddeler halinde detaylandırılmıştır:

- IPCC Tier 2 metodolojisiyle yapılan hesaplamalar, emisyon hacminin doğrudan operasyonel trafik yoğunluğuyla ilişkili olduğunu göstermiştir. Toplam 10 yıllık yakıt tüketiminin %65,3'ünden (1,78 milyar kg) sorumlu olan Sabiha Gökçen Havalimanı en büyük emisyon odağı olarak belirlenmiştir. Esenboğa %27,5 pay ile orta ölçekli bir profil sergilerken, Konya Havalimanı %7,2 ile bölgesel ve daha düşük ve dengeli bir emisyon profiline sahiptir.
- Uzman görüşlerine dayalı Analitik Hiyerarşi Süreci (AHP) sonucunda, emisyonlar üzerindeki en baskın faktörün LTO sayısı (0,407) olduğu tespit edilmiştir. Bunu sırasıyla yakıt tüketimi (0,238) ve uçak tipi (0,119) izlemektedir. Bu hiyerarşi, emisyon azaltım politikalarının sadece teknolojik değil, operasyonel optimizasyon (taksi sürelerinin kısaltılması vb.) odaklı olması gerektiğini ortaya koymaktadır.
- ÇKKV yöntemi olan MOORA ile yapılan analizde, uçak tipleri "Verimli (İyimser)" ve "Verimsiz (Kötümser)" olarak ayrılmıştır. B38M (Boeing 737 MAX 8) tipi uçaklar en yüksek çevresel performans endeksine sahipken; yaşlı kargo ve geniş gövdeli uçakların (C130, AN12, B742) birim LTO başına emisyon yoğunluğunun çok daha yüksek olduğu belirlenmiştir. Bu durum, havayolu işletmeleri için "genç filo" stratejisinin çevresel sürdürülebilirlik üzerindeki doğrudan etkisini ortaya koymaktadır.

Tahmin modeli için ilk aşamada, emisyonun ana belirleyicileri olan operasyonel değişkenlerin yani girdilerin (LTO sayısı, yakıt tüketimi ve yük trafiği) gelecek 10 yıllık trendlerini belirlemek için SARIMA modeli kullanılmıştır. SARIMA, özellikle havacılık verilerindeki döngüsel ve mevsimsel hareketleri yüksek başarıyla yakalamış; makine öğrenmesi modelleri için gerekli olan 120 aylık (2024–2033) kararlı girdi projeksiyonlarını oluşturmuştur. Bu bütünleşik yaklaşım, emisyon tahminlerinin sadece statik varsayımlara değil, dinamik zaman serisi trendlerine dayanmasını sağlamıştır.

Çalışmada test edilen üç farklı makine öğrenmesi algoritması (Random Forest, LSBoost, DVR) içinden veri setinin karakteristiğine göre en uygun modeller seçilmiştir: DVR (Destek Vektör Regresyonu): Ankara (%2,99 MAPE) orta veri setlerinde, doğrusal olmayan ilişkileri yakalama ve genelleme kabiliyeti açısından en kararlı model olmuştur. LSBoost (En Küçük Kareler Güçlendirme): Yüksek hacimli ve mevsimselliği keskin olan Sabiha Gökçen verisinde %1,21 MAPE ve 0,984 R^2 değeriyle en yüksek hassasiyeti sunmuştur. Konya Havalimanı verilerinde ise LSBoost modeli ile %0,78 MAPE değeri elde edilmiş ve düşük operasyon hacmine rağmen başarılı tahmin performansı sağlanmıştır.

MOORA verimlilik endeksleriyle entegre edilen İyimser Senaryo, verimli filo geçişinin emisyon azaltımındaki önemli rolünü ortaya koymuştur. Sabiha Gökçen’de iyimser ve kötümser senaryolar arasındaki farkın oldukça geniş olması, stratejik müdahalelerin (özellikle filo yenilemenin) en büyük çevresel kazanımı yüksek trafikli havalimanlarında sağlayacağını göstermektedir. Trend projeksiyonları, emisyonların Ankara’da 21,5 milyon kg, Konya’da ise 1,5 milyon kg seviyelerinde dengelenebileceğini; Sabiha Gökçen’de ise artış eğiliminin devam ettiğini ve bu durumun operasyonel iyileştirmelerle yönetilmesi gerektiğini ortaya koymaktadır.

6.2. Öneriler ve Gelecek Çalışmalar

Bu çalışmanın bulgularına dayanarak, havalimanı ile ilgili emisyon değerlendirme ve yönetimini iyileştirmek için çeşitli metodolojik, operasyonel ve politika odaklı öneriler sunulabilir.

İlk olarak, gelecekteki çalışmalar, ayrıntılı operasyonel veriler elde edildiğinde, Tier 3 yaklaşımları gibi daha üst düzey emisyon metodolojileri benimseyerek emisyon hesaplama doğruluğunu artırabilir. Gerçek taksi giriş ve çıkış süreleri, motora özgü itme ayarları ve uçağa özgü operasyonel profillerin dahil edilmesi, yerel havalimanı

koşullarının daha kesin bir şekilde temsil edilmesini sağlayacaktır. Bu tür iyileştirmeler, standart emisyon faktörleriyle ilişkili belirsizliği azaltacak ve emisyon envanterlerinin güvenilirliğini artıracaktır.

Bu çalışmada kullanılan karar destek çerçevesi, ek ÇKKV yöntemleri entegre edilerek genişletilebilir. AHP ve MOORA, emisyonla ilgili faktörleri önceliklendirmek ve uçak tiplerini karşılaştırmak için kullanılırken farklı alternatif teknikler karşılaştırmalı analiz için uygulanabilir. Bu, sıralama sonuçlarının sağlamlık kontrollerini mümkün kılacak ve karar sonuçlarının farklı metodolojik varsayımlara duyarlılığı hakkında daha derin içgörüler sağlayacaktır.

Sonuçlar LTO operasyonları ve yakıt tüketiminin havalimanı düzeyindeki emisyonları etkileyen en önemli faktörler olduğunu göstermektedir. Buna göre, havalimanı işletmecileri ve politika yapıcılar, LTO ile ilgili emisyonları azaltmaya yönelik operasyonel stratejilere öncelik vermelidir. Bu stratejiler arasında taksi prosedürlerinin optimize edilmesi, rölanti sürelerinin azaltılması, tek motorlu taksi kullanımının teşvik edilmesi ve daha yakıt verimli uçak filolarının benimsenmesinin desteklenmesi yer alabilir. Bu tür operasyonel önlemler, büyük altyapı yatırımları gerektirmeden emisyonların hemen azaltılmasını sağlayabilir.

Son olarak, tahmin modellemesi ile ilgili olarak, gelecekteki araştırmalar meteorolojik koşullar, pist konfigürasyonu, uçak yük faktörleri ve gerçek zamanlı trafik yönetimi verileri gibi ek açıklayıcı değişkenleri dahil etmekten fayda sağlayabilir. Bu değişkenlerin dahil edilmesi, modelin doğruluğunu ve sağlamlığını daha da artırabilir. Ayrıca, zaman serisi teknikleriyle makine öğrenimi modellerini birleştiren bütünsel tahmin yaklaşımları hem zamansal kalıpları hem de doğrusal olmayan ilişkileri daha iyi yakalamak için araştırılabilir.

Bununla birlikte, çalışmada ele alınan girdi değişkenleri ağırlıklı olarak operasyonel ve teknik faktörlerle sınırlı tutulmuştur. Gelecek çalışmalarda, ekonomik ve sosyolojik değişkenlerin de analize dâhil edilmesiyle, havacılık emisyonlarının daha bütüncül bir açıdan değerlendirilmesi mümkün olabilir. Bu kapsamda, uzman görüşlerine dayalı kriter belirleme sürecinin farklı paydaş gruplarını kapsayacak şekilde genişletilmesi ve değişkenlerin bu doğrultuda yeniden yapılandırılması önerilmektedir.

Bu çalışmada, gelecek tahmin modeli kapsamında yalnızca CO₂ emisyonlarına odaklanılmıştır. Gelecek çalışmalarda, NO_x başta olmak üzere diğer emisyon türlerinin de ayrıntılı biçimde ele alınması, havacılık kaynaklı çevresel etkilerin daha kapsamlı

şekilde ortaya konulmasına katkı sağlayacaktır. Ayrıca, farklı emisyon türleri için geliştirilecek çoklu tahmin modelleri, çevresel karar destek süreçlerini güçlendirebilir.

Uzman görüşleri doğrultusunda, sürdürülebilir havacılık yakıtlarının (SAF) kullanımının artırılmasının emisyonların azaltılmasında önemli bir potansiyel sunduğu değerlendirilmektedir. Bu nedenle, havayolu işletmelerinin SAF kullanımına yönelik stratejiler geliştirmesi ve bu yakıtların operasyonel süreçlere entegrasyonunun desteklenmesi önerilmektedir. Bunun yanı sıra, taksi sürelerinin optimizasyonuna yönelik operasyonel iyileştirmelerin, özellikle LTO kaynaklı emisyonların azaltılmasında etkili bir araç olabileceği öngörülmektedir. Bu doğrultuda, taksi süresi yönetimine ilişkin planlama ve optimizasyon çalışmalarının artırılması önerilmektedir.



KAYNAKLAR

- Acharya, R., ve Bhattarai, N. (2021). Analysis of Greenhouse Gas Emission From Aircrafts and Ground Service Equipment at Tribhuvan International Airport of Nepal. *Journal of Advanced College of Engineering and Management*, 6, 111–122. <https://doi.org/10.3126/jacem.v6i0.38344>
- Akdeniz, H. Y. (2022). Estimation of aircraft turbofan engine exhaust emissions with environmental and economic aspects at a small-scale airport. *Aircraft Engineering and Aerospace Technology*, 94(2), 176–186. <https://doi.org/10.1108/AEAT-11-2020-0264>
- Akpunar, İ. (2015). *Yeşil Havaalanı Kriterleri Kapsamında Türkiye'deki Karbon Emisyonunun Tahmini* [Yüksek Lisans Tezi]. Türk Hava Kurumu Üniversitesi Sosyal Bilimler Enstitüsü.
- Akyüz, A. Ö., Kumaş, K., İnan, O., ve Güngör, A. (2019). Muğla Hava Trafiğinin Karbon Ayak İzi Açısından İncelenmesi. *Academic Platform Journal of Engineering and Science*, 7(2), 291–297. <https://doi.org/10.21541/apjes.466338>
- Aydoğan B. (2008). *Biyodizel Kullanılan Dizel Motorlarda NOx Emisyonlarının ve NOx Emisyonları Azaltma Yöntemlerinin İncelenmesi* [Yüksek Lisans Tezi]. Pamukkale Üniversitesi.
- Bamidele, R. O., Oztüren, A., Haktanir, M., ve Ogunmökün, O. A. (2023). Realizing Green Airport Performance through Green Management Intransigence, Airport Reputation, Biospheric Value, and Eco-Design. *Sustainability*, 15(3), 2475. <https://doi.org/10.3390/su15032475>
- BDL. (2020). *Climate protection report*. <https://www.bdl.aero/en/publication/climate-protection-report/>
- Beyca, O. F., Ervural, B. C., Tatoglu, E., Ozuyar, P. G., ve Zaim, S. (2019). Using machine learning tools for forecasting natural gas consumption in the province of Istanbul. *Energy Economics*, 80, 937–949. <https://doi.org/10.1016/j.eneco.2019.03.006>
- Bo, X., Xue, X., Xu, J., Du, X., Zhou, B., ve Tang, L. (2019). Aviation's emissions and contribution to the air quality in China. *Atmospheric Environment*, 201, 121–131. <https://doi.org/10.1016/j.atmosenv.2019.01.005>
- Brasseur, G. P., ve Gupta, M. (2010). Impact of Aviation on Climate. *Bulletin of the American Meteorological Society*, 91(4), 461–464. <https://doi.org/10.1175/2009BAMS2850.1>
- Canöz, N., ve Ertek, A. (2020). Yeşil kuruluş sertifikasının yeşil imaj oluşumuna katkısı: Türk sivil havacılığı üzerine bir araştırma. *International Journal of Aeronautics and Astronautics*, 1(1), 23–32.

- Çayır Ervural, B. (2026). A Hybrid Ahp-Bwm-Entropy Framework for Ideal Supplier Selection. *International Journal of the Analytic Hierarchy Process*, 18(1). <https://doi.org/10.13033/ijahp.v18i1.1319>
- Champeecharoensuk, A., Dhakal, S., Chollacoop, N., ve Phdungsilp, A. (2024). Greenhouse gas emissions trends and drivers insights from the domestic aviation in Thailand. *Heliyon*, 10(2), e24206. <https://doi.org/10.1016/j.heliyon.2024.e24206>
- Chouliaras, G. I., Kardakos, C. K., ve Simoglou. (2016). 2016 IEEE International Energy Conference (ENERGYCON). IEEE.
- DHİMİ. (2024). Konya Havalimanı. <https://konyahavalimani.com/sayfalar/hakkimizda>
- Durmaz, V., Banar. Müfide, Küçükönel, H., ve Özen, M. (2007). Havaalanı Faaliyetlerinin Çevresel Etkilerini Azaltmaya Yönelik Mevzuat. *Celal Bayar Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 5(1), 66–87.
- EE. Sabiha Gökçen Havalimanı. <https://ecelelectronics.com.tr/Referanslar/Havalimani/Sabiha-Gokcen-Havalimani>. Retrieved November 1, 2024, from <https://ecelelectronics.com.tr/referanslar/havalimani/sabiha-gokcen-havalimani>
- Engin, B. (2010). İklim Değişikliği ile Mücadelede Uluslararası İşbirliğinin Önemi. *Sosyal Bilimler Dergisi*, 2(2), 71–82.
- EPA. *Green Vehicle Guide*. <https://www.epa.gov/greenvehicles>.
- Ersöz, F., ve Atav, A. (2011). Çok Kriterli Karar Verme Problemlerinde Moora Yöntemi. *YAEM, Sakarya University*.
- Ervural, B. Ç. (2024). Air Passenger Demand Forecasting Using Machine Learning Algorithms: A Case Study of Turkey in Airline Industry in T. Paksoy ve S. Demir (Eds.), *Smart and Sustainable Operations Management in the Aviation Industry* (1st ed., p. 26). CRC Press.
- Ervural, B. C., Beyca, O. F., Tatoglu, E., Ozuyar, P. G., ve Zaim, S. (2019). Using machine learning tools for forecasting natural gas consumption in the province of Istanbul. *Energy Economics*, 80, 937–949. <https://doi.org/10.1016/j.eneco.2019.03.006>
- Ervural, B. C., Beyca, O. F., ve Zaim, S. (2016). Model Estimation of ARMA Using Genetic Algorithms: A Case Study of Forecasting Natural Gas Consumption. *Procedia- Social and Behavioral Sciences*, 235, 537–545. <https://doi.org/10.1016/j.sbspro.2016.11.066>
- FAA. (2015). Aviation Emissions, Impacts ve Mitigation: A Primer. *Office of Environment and Energy*.

- Gardner, E. S. (1985). Exponential smoothing: The state of the art. *Journal of Forecasting*, 4(1), 1–28. <https://doi.org/10.1002/for.3980040103>
- Genç, R. (2022). *Malatya Erhaç Havalimanı için uçak emisyonlarının belirlenmesi ve çevreye etkileri*. İnönü Üniversitesi, Fen Bilimleri Enstitüsü.
- Genç, R., ve Behçet, R. (2022). Malatya Erhaç Havalimanını Kullanan Uçakların Çevresel Etkileri. *EJONS International Journal on Mathematic, Engineering and Natural Sciences*, 22.
- Glowacki, P., ve Kawalec, M. (2016). Quantitative Emissions Of No_x, Co and Co₂ During Aircraft Operations. *International Council of the Aeronautical Sciences, ICAS*.
- Gössling, S., ve Upham, P. (2009). *Climate Change and Aviation. Issues, Challenges and Solutions*. Routledge.
- Graham, A. (2008). *Managing Airports: An International Perspective*.
- Greer, F., Rakas, J., ve Horvath, A. (2020). Airports and environmental sustainability: a comprehensive review. *Environmental Research Letters*, 15(10), 103007. <https://doi.org/10.1088/1748-9326/abb42a>
- Guo, X., Ning, C., Shen, Y., Yao, C., Chen, D., ve Cheng, S. (2023). Projection of the Co-Reduced Emissions of CO₂ and Air Pollutants from Civil Aviation in China. *Sustainability*, 15(9), 7082. <https://doi.org/10.3390/su15097082>
- Hamzaçebi, C., ve Kutay, F. (2004). Yapay Sinir Ağları ile Türkiye Elektrik Enerjisi Tüketiminin 2010 Yılına Kadar Tahmini. *Gazi Üniv. Müh. Mim. Fak. Der.*
- Hassan, M., Pfaender, H., ve Mavris, D. N. (2018, June 25). Impact of Aircraft Technologies on US Fleet CO₂ Emissions. *2018 Aviation Technology, Integration, and Operations Conference*. <https://doi.org/10.2514/6.2018-2870>
- Höhne, N., den Elzen, M., Rogelj, J., Metz, B., Fransen, T., Kuramochi, T., Olhoff, A., Alcamo, J., Winkler, H., Fu, S., Schaeffer, M., Schaeffer, R., Peters, G. P., Maxwell, S., ve Dubash, N. K. (2020). Emissions: world has four times the work or one-third of the time. *Nature*, 579(7797), 25–28. <https://doi.org/10.1038/d41586-020-00571-x>.
- Huang, F., Zhang, T., Wang, Q., ve Zhou, D. (2023). CO₂ emission change in China's aviation industry: A fleet-wide index decomposition and scenario analysis. *Transportation Research Part D: Transport and Environment*, 119, 103743. <https://doi.org/10.1016/j.trd.2023.10374>
- ICAO. (2011). *Airport Air Quality Manual*.
- International Monetary Fund (IMF). (2017). *Quarterly National Accounts Manual: Concepts, Data Sources, and Compilation*.
- IPCC. (2006). *Intergovernmental Panel on Climate Change (IPCC) Guidelines for National Greenhouse Gas Inventories*.

- IPCC, 2019 Refinement to the 2006 IPCC Guidelines for National Greenhouse Gas Inventories. (2019). 2019 Refinement to the 2006 IPCC Guidelines for National Greenhouse Gas Inventories. In *2019 Refinement to the 2006 IPCC Guidelines for National Greenhouse Gas Inventories* (5th ed., Vol. 1, pp. 5.13-5.15).
- Ishwaran, H., ve Lu, M. (2019). Standard errors and confidence intervals for variable importance in random forest regression, classification, and survival. *Statistics in Medicine*, 38(4), 558–582. <https://doi.org/10.1002/sim.7803>
- Kaika, D. (2023). Decomposition of the Kaya identity in the European Mediterranean countries over the 1990-2020 period with respect to CO₂ emissions. *E3S Web of Conferences*, 436, 05001. <https://doi.org/10.1051/e3sconf/202343605001>
- Kavousi-Fard, A., Samet, H., ve Marzbani, F. (2014). A new hybrid Modified Firefly Algorithm and Support Vector Regression model for accurate Short Term Load Forecasting. *Expert Systems with Applications*, 41(13), 6047–6056. <https://doi.org/10.1016/j.eswa.2014.03.053>
- King, M. E., Lessidrenska, Teodorina., Akın, N., Eğilmez, Esra., ve Yıgıcı, E. Murat. (2010). *Dünya'nın geçici bekçileri: Dünya'daki yaşamı sürdürülebilir kılmak için*. Caretta.
- Kito, M., Nagashima, F., Kagawa, S., ve Nansai, K. (2020). Drivers of CO₂ emissions in international aviation: the case of Japan. *Environmental Research Letters*, 15(10), 104036. <https://doi.org/10.1088/1748-9326/ab9e9b>
- Klöwer, M., Allen, M. R., Lee, D. S., Proud, S. R., Gallagher, L., ve Skowron, A. (2021). Quantifying aviation's contribution to global warming. *Environmental Research Letters*, 16(10), 104027. <https://doi.org/10.1088/1748-9326/ac286e>
- Konya Havalimanı. <https://konyahavalimani.com/sayfalar/hakkimizda>.
- Kumar, R., Prinshu, Kumar Mishra, A., Dutta, S., ve Kumar Singh, A. (2023). Optimization and prediction of response characteristics of electrical discharge machining using AHP-MOORA and RSM. *Materials Today: Proceedings*, 80, 333–338. <https://doi.org/10.1016/j.matpr.2023.02.138>
- Kurnaz, L. (2020). *Son Buzul Erimeden* (S. Arlı, Ed.). Doğan Yayınevi.
- Kutlar, O. A., ve Arslan, H. (1998). *Taşıt Egzozundan Kaynaklanan Kirleticiler İşletme Bakım Yapısal ve Yasal Önlemler Bu Önlemlerin Güncel Uygulamaları*.
- Lan, X., Thans, P., ve Thoning, K. W. (2025, September 5). *Trends in globally-averaged CO₂ determined*. NOAA Global Monitoring Laboratory Measurements.
- Lee, D. S., Fahey, D. W., Forster, P. M., Newton, P. J., Wit, R. C. N., Lim, L. L., Owen, B., ve Sausen, R. (2009). Aviation and global climate change in the

- 21st century. *Atmospheric Environment*, 43(22–23), 3520–3537. <https://doi.org/10.1016/j.atmosenv.2009.04.024>
- Lee, D. S., Fahey, D. W., Skowron, A., Allen, M. R., Burkhardt, U., Chen, Q., Doherty, S. J., Freeman, S., Forster, P. M., Fuglestvedt, J., Gettelman, A., De León, R. R., Lim, L. L., Lund, M. T., Millar, R. J., Owen, B., Penner, J. E., Pitari, G., Prather, M. J. ve Wilcox, L. J. (2021). The contribution of global aviation to anthropogenic climate forcing for 2000 to 2018. *Atmospheric Environment*, 244, 117834. <https://doi.org/10.1016/j.atmosenv.2020.117834>
- Liu, Z., Jiang, P., Wang, J., ve Zhang, L. (2022). Ensemble system for short term carbon dioxide emissions forecasting based on multi-objective tangent search algorithm. *Journal of Environmental Management*, 302, 113951. <https://doi.org/10.1016/j.jenvman.2021.113951>
- Lukačević, N., Mirković, B., Đogatović, M., ve Ganić, E. (2022). Simulation model for estimation of aircraft emissions at Airport Podgorica. *Transportation Research Procedia*, 65, 180–189. <https://doi.org/10.1016/j.trpro.2022.11.021>
- Mahendra, F., S, R., Hannim, S., ve Arifin, M. (2024). Predicting Future Aircraft Emissions in Indonesia: A Comparative Analysis using LSTM and GRU Methods. *Proceedings of the 2nd International Conference on Aviation Industry, Education, and Regulation, AVINER 2023, 8-9 November 2023, Jakarta, Indonesia*. <https://doi.org/10.4108/eai.8-11-2023.2345860>
- Masiol, M., ve Harrison, R. M. (2014). Aircraft engine exhaust emissions and other airport-related contributions to ambient air pollution: A review. *Atmospheric Environment*, 95, 409–455. <https://doi.org/10.1016/j.atmosenv.2014.05.070>
- Önder, E., ve Hasgöl, Ö. (2009). *Yabancı Ziyaretçi Sayısının Tahmininde Boxjenkins Modeli, Winters Yöntemi ve Yapay Sinir Ağlarıyla Zaman Serisi Analizi*.
- Orhan, I. (2021). Passenger aircraft emissions analysis at Ordu-Giresun International Airport, Turkey in 2017. *Aircraft Engineering and Aerospace Technology*, 93(4), 682–689. <https://doi.org/10.1108/AEAT-09-2020-0209>
- Özgünoğlu, K. (2017). *Tier Metoduyla Uçaklardan Kaynaklanan Emisyonların Belirlenmesi: Kahramanmaraş Havalimanı Örneği* [Yüksek Lisans Tezi]. Fen Bilimleri Enstitüsü.
- Pamplona, D. A., ve Alves, C. J. P. (2020). Civil Aircraft Emissions Study and Pollutant Forecasting at a Brazilian Airport. *Engineering, Technology and Applied Science Research*, 10(1), 5217–5220. <https://doi.org/10.48084/etasr.3227>
- Pitanova, G. C., Ahyudanari, E., ve Chilongola, F. (2023). Analysis of Fuel Consumption and Emissions Produced by Aircraft at Indonesian Airports. *Jurnal Teknologi Transportasi Dan Logistik*, 4(2), 169–174. <https://doi.org/10.52920/jttl.v4i2.183>

- Postorino, M. N., ve Mantecchini, L. (2014). A transport carbon footprint methodology to assess airport carbon emissions. *Journal of Air Transport Management*, 37, 76–86. <https://doi.org/10.1016/j.jairtraman.2014.03.001>
- Qiao, W., Lu, H., Zhou, G., Azimi, M., Yang, Q., ve Tian, W. (2020). A hybrid algorithm for carbon dioxide emissions forecasting based on improved lion swarm optimizer. *Journal of Cleaner Production*, 244, 118612. <https://doi.org/10.1016/j.jclepro.2019.118612>
- Ritchie, H., Rosado, P., ve Roser, M. (2023). *CO₂ and greenhouse gas emissions*. Our World in Data. <https://ourworldindata.org/co2-and-greenhouse-gas-emissions>
- Rizkallah, L. W. (2025). Enhancing the performance of gradient boosting trees on regression problems. *Journal of Big Data*, 12(1), 35. <https://doi.org/10.1186/s40537-025-01071-3>
- Samoli, E., Touloumi, G., Schwartz, J., Anderson, H. R., Schindler, C., Forsberg, B., Vigotti, M. A., Vonk, J., Košnik, M., Skorkovsky, J., ve Katsouyanni, K. (2007). Short-Term Effects of Carbon Monoxide on Mortality: An Analysis within the APHEA Project. *Environmental Health Perspectives*, 115(11), 1578–1583. <https://doi.org/10.1289/ehp.10375>
- Schroten, A., Wijngaarden, L. van, Essen, H. van, Sutter, D., ve Andrew, E. (2019). *Sustainable transport infrastructure charging and internalisation of transport externalities*.
- SHGM, *yesil havaalani green airport projesi*. SHGM. Retrieved October 31, 2025, from <https://web.shgm.gov.tr/tr/kurumsal-projeler/194-yesil-havaalani-green-airport-projesi>
- Singh, R., Pathak, V. K., Kumar, R., Dikshit, M., Aherwar, A., Singh, V., ve Singh, T. (2024). A historical review and analysis on MOORA and its fuzzy extensions for different applications. *Heliyon*, 10(3), e25453. <https://doi.org/10.1016/j.heliyon.2024.e25453>
- Sonsuz, B., Karafazlıoğlu, M., Kargı, H., Çıpkı, M., ve Kargıoğlu, F. (2011). *Adapazarı İlçesindeki Endüstriyel Kaynaklı Emisyonların Envanterlenmesi* [Bitirme Tezi]. Sakarya Üniversitesi.
- Soza, E., ve Ayres, K. (2018). Global Warming and Climate Change. *Proceedings of MOL2NET 2018, International Conference on Multidisciplinary Sciences, 4th Edition*, 5474. <https://doi.org/10.3390/mol2net-04-05474>
- Stefanis, C., Manisalidis, I., Stavropoulou, E., Stavropoulos, A., Tsigalou, C., Voidarou, C. (Chrysa), Constantinidis, T. C., ve Bezirtzoglou, E. (2025). Assessing the Impact of Aviation Emissions on Air Quality at a Regional Greek Airport Using Machine Learning. *Toxics*, 13(3), 217. <https://doi.org/10.3390/toxics13030217>

- Taşdemir, M., ve Aydın, E. (2021). Havacılıkta Karbon Azaltım Uygulamaları ve Şirket Stratejileri. *International Symposium of Scientific Research and Innovative Studies*.
- TAV Havalimanları. *Ankara Esenboğa Havalimanı*. <https://tavairports.com/ankara-esenboga-havalimani>.
- Terrenoire, E., Hauglustaine, D. A., Gasser, T., ve Penanhoat, O. (2019). The contribution of carbon dioxide emissions from the aviation sector to future climate change. *Environmental Research Letters*, 14(8), 084019. <https://doi.org/10.1088/1748-9326/ab3086>
- Tokuslu, A. (2020). Estimation of aircraft emissions at Georgian international airport. *Energy*, 206, 118219. <https://doi.org/10.1016/j.energy.2020.118219>
- Turan, P. (2020). *Yeşil havalimanı kapsamında sera gazı emisyonları: İstanbul Havalimanı örneği* [Yüksek Lisans Tezi]. Kocaeli Üniversitesi, Sosyal Bilimler Enstitüsü.
- Türkeş, M., Sümer, U. M., ve Çetiner, G. (2000). Küresel iklim değişikliği ve olası etkileri. *İstanbul Sanayi Odası, Çevre Bakanlığı, Birleşmiş Milletler İklim Değişikliği Çerçeve Sözleşmesi Seminer Notları*, 7–24.
- Ünal, İ., Türkoğlu, F., ve Doğan, B. (2014). Nevşehir kapadokya havalimanının emisyon ve gürültü açısından değerlendirilmesi. *Mühendis ve Makina*, 55(654).
- Vapnik, V. N. (1998). *Statistical Learning Theory*. Wiley.
- Wan, J., Zhang, H., Lyu, W., ve Zhou, J. (2022). A Novel Combined Model for Short-Term Emission Prediction of Airspace Flights Based on Machine Learning: A Case Study of China. *Sustainability*, 14(7), 4017. <https://doi.org/10.3390/su14074017>
- Wang, J., Zhang, H., Yu, J., Lu, F., ve Li, Y. (2024). Modeling Civil Aviation Emissions with Actual Flight Trajectories and Enhanced Aircraft Performance Model. *Atmosphere*, 15(10), 1251. <https://doi.org/10.3390/atmos15101251>
- Wang, K., Wang, X., Cheng, S., Cheng, L., ve Wang, R. (2022). National emissions inventory and future trends in greenhouse gases and other air pollutants from civil airports in China. *Environmental Science and Pollution Research*, 29(54), 81703–81712. <https://doi.org/10.1007/s11356-022-21425-1>
- Xu, B.-Z., Li, X.-L., Wang, W.-F., ve Chen, X. (2022). Expanding the theory for reducing the CO2 disaster—Hypotheses from partial least-squares regression and machine learning. *Frontiers in Earth Science*, 10. <https://doi.org/10.3389/feart.2022.1004920>
- Xu, H., Fu, Q., Yu, Y., Liu, Q., Pan, J., Cheng, J., Wang, Z., ve Liu, L. (2020). Quantifying aircraft emissions of Shanghai Pudong International Airport with aircraft ground operational data. *Environmental Pollution*, 261, 114115. <https://doi.org/10.1016/j.envpol.2020.114115>

- Yang, H., ve O'Connell, J. F. (2020). Short-term carbon emissions forecast for aviation industry in Shanghai. *Journal of Cleaner Production*, 275, 122734. <https://doi.org/10.1016/j.jclepro.2020.122734>
- Yang, L., Hu, Y.-J., Wang, H., Li, C., Tang, B.-J., Wang, B., ve Cui, H. (2023). Uncertainty quantification of CO₂ emissions from China's civil aviation industry to 2050. *Journal of Environmental Management*, 336, 117624. <https://doi.org/10.1016/j.jenvman.2023.117624>
- Yavuz, İ. (2022). *T.C. Kocaeli Üniversitesi Sosyal Bilimler Enstitüsü Havacılık Yönetimi Anabilim Dalı Havacılık Yönetimi Bilim Dalı Havaalanlarında Çevresel Sürdürülebilirlik Uygulamaları Kapsamında Karbon Emisyonu Azaltımının Değerlendirilmesi* [Yüksek Lisans Tezi]. İlayda YAVUZ.
- Yay, O. D., Yılmaz, E., Döğeroğlu, T., Turgut, E. T., Cavcar, M., Usanmaz, Ö., ve Armutlu, K. (2014). Gerçek Karışma Yüksekliği ve Uçuş Fazı Süreleri ile Hesaplanan Uçak Emisyonlarının ICAO Değerleri ile Karşılaştırması. *Hava Kirliliği Araştırmaları Dergisi*, 3, 47–52.
- Yolcu, M. B. (2023). Avrupa Yeşil Mutabakatı ve Türkiye'deki Yeşil Lojistik Uygulamaları. *Econder International Academic Journal*. <https://doi.org/10.35342/econder.1399162>
- Yu, J., Shao, C., Xue, C., ve Hu, H. (2020). China's aircraft-related CO₂ emissions: Decomposition analysis, decoupling status, and future trends. *Energy Policy*, 138, 111215. <https://doi.org/10.1016/j.enpol.2019.111215>
- Zhou, Y., Jiao, Y., Lang, J., Chen, D., Huang, C., Wei, P., Li, S., ve Cheng, S. (2019). Improved estimation of air pollutant emissions from landing and takeoff cycles of civil aircraft in China. *Environmental Pollution*, 249, 463–471. <https://doi.org/10.1016/j.envpol.2019.03.088>

EKLER**EK-1 Referans alınan LTO emisyon faktörleri****Attachment B to Appendix 1****SIMPLIFIED AIRCRAFT EMISSION INDICES****Table B-1. LTO emission factor by aircraft**

Aircraft ¹		LTO emission factors/aeroplane (kg/LTO/aircraft and #LTO/aircraft) ²							Fuel consumption (kg/LTO/aircraft)
		CO ₂ ³	HC	NO _x	CO	SO _x ⁴	tPM/mass	nvPM/number	
Large commercial aircraft ⁵	A300	5 445	1.25	25.86	14.80	0.86	0.16	1.58E+18	1 723
	A310	4 761	6.30	19.46	28.30	0.75	0.17	9.99E+17	1 507
	A318	2 274	0.91	6.76	12.14	0.36	0.07	5.48E+17	719
	A319	2 390	1.20	8.70	7.86	0.38	0.14	2.54E+18	756
	A320	2 665	0.34	9.90	8.14	0.42	0.17	3.28E+18	843
	A320neo	1 981	0.10	5.95	6.95	0.31	0.04	2.35E+17	627
	A321	3 195	0.17	16.23	5.81	0.51	0.23	4.62E+18	1 011
	A321neo	2 373	0.09	10.76	6.94	0.38	0.06	2.86E+17	751
	A330-200/300	7 052	1.28	35.57	16.20	1.12	0.21	2.42E+18	2 232
	A340-200	6 111	4.05	31.08	25.75	0.97	0.18	8.18E+17	1 934
	A340-300	6 383	3.90	34.81	25.23	1.01	0.19	8.77E+17	2 020
	A340-500/600	10 659	0.14	64.45	15.31	1.69	0.19	7.95E+17	3 373
	A350-900	6 756	0.94	39.81	20.27	1.07	0.20	2.63E+18	2 138
	A350-1000	7 851	0.90	56.91	20.23	1.24	0.24	2.77E+18	2 484
	A380	11 952	3.70	69.42	39.06	1.89	0.34	3.37E + 18	3 782
	707	5 880	97.45	10.96	92.37	0.93	2.15	1.88E+19	1 864
	717	2 143	0.05	6.68	6.78	0.34	0.09	7.80E+17	678
	727-200	4 610	8.14	11.97	27.16	0.73	0.52	1.11E+19	1 459
	737-300/400/500	2 737	1.43	6.98	6.48	0.43	0.14	2.55E+18	866
	737-600	2 279	1.01	7.66	8.65	0.36	0.09	1.23E+18	721
	737-700	2 462	0.86	9.12	8.00	0.39	0.09	1.40E+18	779
	737-800/900	2 784	0.72	12.30	7.07	0.44	0.12	2.04E+18	881
	747-200	11 370	18.24	49.52	79.78	1.80	0.46	3.33E+18	3 598
	747-300	11 074	2.73	65.00	17.84	1.75	0.37	4.01E+18	3 504
	747-400	10 245	2.25	42.88	26.72	1.62	0.24	6.28E+17	3 242
	747-8	11 044	0.84	44.32	27.61	1.75	0.24	2.76E+18	3 495
	757-200	4 317	0.22	23.43	8.08	0.68	0.11	1.20E+18	1 366
	757-300	4 625	0.11	17.85	11.62	0.73	0.33	5.88E+18	1 464

EK-2 Referans alınan LTO emisyon faktörleri

3-A1-32

Airport Air Quality Manual

Aircraft ¹		LTO emission factors/aeroplane (kg/LTO/aircraft and #LTO/aircraft) ²							Fuel consumption (kg/LTO/aircraft)
		CO ₂ ³	HC	NO _x	CO	SO _x ⁴	tPM _{mass}	nvPM _{number}	
	767-200	4 622	3.32	23.76	14.80	0.73	0.18	1.04E+18	1 463
	767-300	5 608	1.19	28.19	14.47	0.89	0.17	1.68E+18	1 775
	767-400	5 522	0.98	24.80	12.37	0.87	0.13	3.74E+17	1 748
	777-200/300	7 197	1.35	37.47	16.60	1.14	0.18	1.14E+18	2 277
	787-8	5 468	0.24	28.75	10.34	0.87	0.12	1.15E+18	1 730
	CS 100 / A220-100	1 890	0.06	8.25	3.44	0.30	0.05	5.34E+17	598
	CS 300 / A220-300	1 890	0.06	8.25	3.44	0.30	0.05	5.34E+17	598
	EMB170	1 589	0.04	4.84	4.05	0.25	0.03	1.01E+17	503
	EMB190	2 059	1.14	6.43	12.13	0.33	0.06	1.87E+17	652
	DC-10	7 287	2.37	35.65	20.59	1.15	0.24	1.26E+18	2 306
	DC-8-50/60/70	5 357	1.51	15.62	26.31	0.85	0.14	1.46E+18	1 695
	DC-9	2 646	4.63	6.16	16.29	0.42	0.29	6.18E+18	837
Large commercial aircraft ⁵ Source: ICAO (2018) ⁶ ICCAIA (2014) ICCAIA (2018)	MD-11	7 287	2.37	35.65	20.59	1.15	0.24	1.26E+18	2 306
	MD-80	3 184	1.87	11.97	6.46	0.50	0.27	5.76E+18	1 008
	MD-90	2 759	0.06	10.76	5.53	0.44	0.26	5.93E+18	873
	TU-134	2 931	17.98	8.68	27.98	0.46	0.66	1.24E+19	928
	TU-154-M	5 959	13.17	12.00	82.88	0.94	1.11	2.96E+19	1 886
	TU-154-B	7 030	119.03	14.33	143.05	1.11	1.58	1.96E+19	2 225
Regional jets/business jets > 26.7 kN thrust	RJ-RJ85	1 906	1.35	4.34	11.21	0.30	0.09	2.09E+18	603
	BAE 146	1 801	1.41	4.07	11.18	0.29	0.07	8.26E+17	570
	CRJ-100ER	1 056	0.63	2.27	6.70	0.17	0.04	5.16E+17	334
	CRJ-900	1 517	0.04	4.40	4.12	0.24	0.03	7.34E+16	480
	ERJ-145	993	0.56	2.69	6.18	0.16	0.02	1.81E+17	314
	Fokker 100/70/28	2 387	1.43	5.75	13.84	0.38	0.34	9.19E+18	755
	Domier 328 Jet	868	0.57	2.99	5.35	0.14	0.04	5.56E+17	275
	Gulfstream IV	2 030	0.55	4.99	8.25	0.32	0.07	5.22E+17	642
	Gulfstream V	1 857	0.60	5.70	8.90	0.29	0.13	1.00E+18	588
	Gulfstream VI	1 925	0.80	5.13	11.82	0.30	0.09	6.21E+17	609
	Gulfstream VII-500	1 619	0.01	6.34	3.20	0.26	0.03	6.04E+16	512
	RRJ85-LR	2 147	0.27	5.90	9.21	0.34	0.15	1.04E+18	679
Low thrust jets (Fn < 26.7 kN)	Yak-42M	1 919	1.68	7.11	6.81	0.30	0.09	1.62E+18	607
	Cessna 525/560	458	1.66	0.28	16.20	0.07	0.05	1.20E+18	145
Turboprops Source: FCI ⁷	Beech King Air ⁸	241	0.64	0.32	2.99	0.04	0.02	6.51E+17	76
	DHC8-100 ⁹	658	0.00	1.55	2.27	0.10	0.07	2.23E+18	208
	ATR72-500 ¹⁰	641	0.29	1.88	2.35	0.10	0.07	2.36E+18	203