

Araştırma Makalesi

Kalkış safhasında uçak motorlarından kaynaklanan görsel duman yoğunluğunun yapay sinir ağları ile tahmin edilmesi

Bülent KURT*

Edremit School of Civil Aviation, Balıkesir University, Balıkesir, Turkey.

*Correspondence: bulent.kurt@balikesir.edu.tr

DOI: 10.51513/jitsa.1692078

Özet: Uçak motorlarından kaynaklanan emisyonların azaltılması, çevresel sürdürülebilirlik ve hava kalitesinin korunması açısından kritik bir öneme sahiptir. Özellikle kalkış safhasında yayılan Smoke Number (SN), havaalanı çevresindeki hava kirliliğini artıran önemli bir parametredir. Bu çalışmada, SN değerini tahmin etmek amacıyla yenilikçi bir yapay sinir ağı (YSA) modeli geliştirilmiştir. Modelleme sürecinde, Uluslararası Sivil Havacılık Örgütü'ne (ICAO) ait Aircraft Engine Emissions Databank (EEDB) veri seti kullanılmıştır. En iyi tahmin performansını elde etmek amacıyla üç farklı eğitim algoritması uygulanmıştır: Bayesian Regularization (trainbr), Levenberg-Marquardt (trainlm) ve Scaled Conjugate Gradient (trainscg). Geliştirilen modellerin performansı, ortalama karesel hata (MSE), ortalama mutlak hata (MAE), kök ortalama kare hata (RMSE), korelasyon katsayısı (R) ve determinasyon katsayısı (R^2) gibi istatistiksel kriterlerle değerlendirilmiştir. Sonuçlara göre, trainbr algoritmasıyla eğitilen model en yüksek doğruluk oranına ulaşmış ve SN değerini 98% üzerinde doğrulukla ($R = 0.98761$) tahmin etmiştir. Bu çalışmada geliştirilen model, sürdürülebilir havacılık uygulamalarına katkı sunmakta ve emisyon yönetiminin optimize edilmesi açısından önemli bir potansiyel taşımaktadır.

Anahtar Kelimeler: Uçak emisyonları; yapay sinir ağları; görsel duman yoğunluğu; sürdürülebilirlik; EEDB

Prediction of the smoke number from aircraft engines during the takeoff phase using artificial neural networks

Abstract: Reducing emissions from aircraft engines is critically important for environmental sustainability and the preservation of air quality. In particular, the Smoke Number (SN) emitted during the take-off phase is an important parameter that increases air pollution around airports. In this study, an innovative artificial neural network (ANN) model was developed to predict the SN value. The modeling process utilized the Aircraft Engine Emissions Databank (EEDB) provided by the International Civil Aviation Organization (ICAO). To achieve the best prediction performance, three different training algorithms were applied: Bayesian Regularization (trainbr), Levenberg-Marquardt (trainlm), and Scaled Conjugate Gradient (trainscg). The performance of the developed models was evaluated using statistical criteria such as mean squared error (MSE), mean absolute error (MAE), root mean square error (RMSE), correlation coefficient (R), and coefficient of determination (R^2). The results indicated that the model trained with the trainbr algorithm achieved the highest accuracy, predicting the SN value with 98% accuracy ($R = 0.98761$). The proposed model contributes to sustainable aviation practices and holds significant potential for optimizing emission management.

Keywords: Aircraft emissions; artificial neural networks; smoke number; sustainability; EEDB

* Corresponding author.

ORCID: 0000-0002-1741-5427

Received 05.05.2025; Received in revised form 20.05.2025, 02.06.2025, 15.08.2025; Accepted 03.09.2025

Peer review under responsibility of Bandırma Onyedi Eylül University. This work is licensed under CC BY 4.0.

APA Citation Info: Kurt, B. (2025). Kalkış safhasında uçak motorlarından kaynaklanan görsel duman yoğunluğunun yapay sinir ağları ile tahmin edilmesi. Akıllı Ulaşım Sistemleri ve Uygulamaları Dergisi, 8(2), 147-157. <https://doi.org/10.51513/jitsa.1692078>

1. Giriş

Ulaştırma sektörü, günümüzde hava kirliliğinin temel kaynaklarından biri olarak öne çıkmaktadır (Kodak, 2024). Özellikle hava trafiğinde gözlenen artış ve operasyon ölçeğindeki büyüme, havacılık sektörünün hızlı bir şekilde gelişmesine neden olmaktadır. Bu büyüme, özellikle uçak motorlarından kaynaklanan egzoz emisyonları nedeniyle önemli çevresel sorunlara yol açmaktadır. Bu emisyonlar arasında yer alan is partikülleri ve görsel duman yoğunluğu (Smoke Number, SN), yerel hava kalitesini olumsuz etkilemekte ve uzun vadede iklim değişikliğine katkıda bulunmaktadır.

Uluslararası Sivil Havacılık Örgütü (ICAO), motor egzozundan çıkan dumanın görünürlüğünü ölçmek için SN parametresini tanımlamıştır. Bu ölçüm, egzoz gazları üzerine yerleştirilen filtreler aracılığıyla yapılır ve yüksek SN değerleri, egzozda daha fazla kurum partikülü bulunduğunu gösterir (Martini, 2008). ICAO'nun Çevresel Koruma Komitesi (CAEP), 2010 yılında uçucu olmayan partikül madde (nvPM) emisyonlarının ölçümü için kavramsal bir sistem önermiş, 2016 yılında ise ilk nvPM standardını kabul etmiştir. Bu standart, SN ile nvPM kütle yoğunluğu arasındaki istatistiksel ilişkiye dayandırılmış olup, 1 Ocak 2020 itibarıyla 26.7 kN minimum itme gücüne sahip tüm motorlar için zorunlu hale gelmiştir (Brink, 2020).

SN ve partikül emisyonlarının modellenmesi üzerine pek çok çalışma yapılmıştır. Stettler ve arkadaşları (2013), modern uçak motorlarından yayılan kara karbon (BC) emisyonlarının SN ile ilişkisini güncelleyerek tahmin doğruluğunu artırmıştır. Martini (2008), mevcut motorlar için kurum emisyonlarını tahmin eden ve gelecekteki tasarımlar için performans öngören bir model geliştirilmiştir. Wayson ve arkadaşları (2009) ise FOA3.0 metodolojisi ile ticari uçak motorlarından kaynaklanan ince partikül madde emisyonlarını tahmin ederek havaalanı çevresindeki hava kirliliği etkilerini incelemiştir.

Yakıt bileşiminin emisyonlar üzerindeki etkisine yönelik çalışmalar da literatürde yer almaktadır. Brink (2020), CFM56-7B motoru üzerinde farklı yakıt senaryoları ile NO_x, CO ve kurum emisyonlarını Pycaso modeliyle değerlendirmiştir. Christie ve arkadaşları (2017), Jet A-1 ve alternatif yakıt karışımlarında SN ile nvPM kütle konsantrasyonu arasındaki ilişkiyi analiz etmiştir. Qasem ve arkadaşları (2023) ise yakıtların moleküler bileşimine dayalı olarak duman noktası değerini yapay sinir ağları ile yüksek doğrulukla tahmin etmiştir.

Son yıllarda makine öğrenmesi temelli yaklaşımlar da önem kazanmıştır. Agarwal ve arkadaşları (2019), SCOPE11 yöntemini geliştirerek motor çıkışında BC ve SN tahminleri yapmıştır. Ge ve arkadaşları (2022), nvPM emisyonlarını tahmin eden APMEP-CNN adlı bir yapay sinir ağı modeli geliştirilmiştir. Zou ve arkadaşları (2025), uçak yakıt tüketimini modellemek üzere makine öğrenmesi teknikleri kullanmıştır. Ma ve arkadaşları (2025) ise uçaklarda emisyon tahmini için gelişmiş veri odaklı yaklaşımlar geliştirmiştir. Oruc (2025), uçak motorlarının havalimanı çevresindeki emisyon değerlerini cuckoo search algorithm (CSA) ve support vector regression (SVR) yöntemiyle tahmin etmektedir.

Diğer taraftan, emisyonların iklim ve hava kalitesi üzerindeki etkilerini değerlendiren çalışmalar da literatürde önemlidir. Trivanovic ve Pratsinis (2023), uçak motorlarından kaynaklanan kurum emisyonlarının iklim ve hava kalitesi üzerindeki etkilerini incelemiştir. Deng ve arkadaşları (2021), sivil uçak kargo bölmelerinde erken yangın tespiti için kızılötesi görüntü işleme tabanlı yeni bir duman algılama yöntemi geliştirmiştir. Jagtap ve arkadaşları (2024) ise sıvı hidrojenle çalışan turbofan motoru ile testler yapmıştır. Kurt (2024a), yakıt akışı parametresi değeri ile uçak motorlarında performans değerlendirmesi yapmıştır.

Uçakların güvenilirliğini ve güvenliğini artırmak için uçak motorlarının ölçümleri yapılır ve kaydedilir. ICAO'nun Aircraft Engine Emissions Databank (EEDB) verileri, kalkış safhasında motor performansının ve çevresel etkilerin değerlendirilmesi için güvenilir bir temel sunmaktadır. Uçak motorları yüksek sıcaklık ve devirlerde çalıştığı için performans bozulması meydana gelebilir. Performans bozulması uçaklarda arızalara ve kazalara neden olabilir. Kalkış safhası, uçak motorlarının en yüksek anlık yakıt tüketimine ulaştığı uçuş evresidir; bu durum, motorların maksimum itki üretmesi nedeniyle gerçekleşir. Uçak motorları kalkış safhasında yüksek sıcaklık ve devirlerde çalıştığı için, uçak güvenliği açısından incelenmesi gereken bir süreçtir (Kurt, 2024b). Kalkış sırasında oluşan SN değeri, hem hava kalitesi hem de görsel kirlilik açısından kritik bir göstergedir. Literatürde uçağın sadece kalkış safhasında oluşan SN değerini tahmin eden bir yapay sinir ağı modeli bulunmamaktadır.

Bu çalışmada, kalkış safhasında uçak motorlarından kaynaklanan görsel duman yoğunluğunu tahmin etmeye yönelik yenilikçi bir yapay sinir ağı (YSA) modeli geliştirilmiştir. Model, Uluslararası Sivil Havacılık Örgütü'nün (ICAO) Aircraft Engine Emissions Databank (EEDB) kapsamında yer alan 447 farklı motor verisi kullanılarak eğitilmiş ve SN tahmininde %97'nin üzerinde doğruluk oranı elde etmiştir. Geliştirilen bu yaklaşım, uçak motorlarının kalkış anındaki performansını uzman görüşüne veya fiziksel test sistemlerine ihtiyaç duymaksızın değerlendirebilecek bir altyapı sunmaktadır. Literatürde kalkış safhasına özgü SN tahminine odaklanan bir YSA modelinin bulunmaması, çalışmanın özgün katkısını ve bilimsel değerini ortaya koymaktadır.

2. Veri ve yöntemler

2.1. Veri seti

Bu çalışmada görsel duman yoğunluğunu tahmin etmek için eğitim, test ve doğrulama verilerine ihtiyaç duyulmaktadır. Geliştirilecek model de kullanmak için ICAO uçak motorları egzoz emisyon veri seti seçilmiştir (ICAO, 2024). EEDB veri seti, ICAO Annex 16, Volume II'de belirtilen prosedürlere göre ölçülen ve motor üreticileri tarafından sağlanan emisyon bilgilerini içerir. Veri seti, özellikle 26.7 kilonewton üzeri statik itiş gücüne sahip turbojet ve turbofan motorlar için düzenlenmiş emisyon verilerini kapsamaktadır. Tablo 1'de gösterildiği gibi ICAO tarafından belirlenmiş safhalar, süre ve itki ayarı ile ölçümler yapılarak bu veriler elde edilmektedir.

Tablo 1. Referans emisyonlarının LTO (İniş ve Kalkış) döngüsü (ICAO, 2020)

Safhalar	Süre (sn)	İtke ayarı (kN)
Kalkış	0,7	100 %
Tırmanma	2,2	85 %
Yaklaşma	4,0	30 %
Taksi	26,0	7 %

Tablo 2'de görsel duman yoğunluğunu tahmin etmek için eğitimde kullanacağımız parametreler ve bu parametrelerin istatistiksel özellikleri sunulmuştur. Çalışma da kullanılan veri setinin 70 % i eğitim, 15 % doğrulama ve 15 % test aşamasında kullanılmak için Matlab ortamında rastgele ayrılmıştır. Veri setinden yanlılığı (bias) önlemek, temsil gücünü artırmak ve istatistiksel olarak güvenilir sonuçlar elde etmek için rastgele veri seçimi yapılmıştır.

Tablo 2. Kalkış safhasında uçak motoruna ait veri setindeki parametrelerin değerleri (ICAO, 2024)

Parametreler	Örnek	En az	En çok	Ortalama	Std. sapma
Motor tipi	313	1,00	2,00	1,1917	,39426
Baypas oranı	313	0,64	12,72	6,2846	2,30511
Basınç oranı	313	11,40	49,40	30,6284	7,78073
Motorun maksimum nominal itme gücü (kN)	313	28,49	504,90	187,2748	114,63808
Çevresel barometrik basınç (kPa)	313	0,00	1019394,50	10802,0715	99831,59139
Ortam sıcaklığı (T)	313	144,00	308,50	287,1121	11,24516
Ortam nemi (kg/kg)	313	0,00	0,02	0,0073	0,00371
Yakıttaki hidrojen atomlarının karbon atomlarına oranı	313	0,00	13,89	2,2060	1,86219
Yakıttaki aromatik hidrokarbonların yüzdesi (%)	313	0,00	21,85	16,9228	2,22131
Kalkış safhasında görsel duman yoğunluğu	313	0,00	46,30	7,3685	5,93241


Doğrulama ve test grupları modelin doğruluğunu değerlendirmek için kullanılacaktır. Veri setindeki farklı ölçeklerdeki değişkenleri ortak bir ölçeğe getirerek modelin daha doğru ve dengeli öğrenmesini sağlamak için normalizasyon işlemi yapılmıştır. Normalizasyon işlemi denklem (1) de gösterildiği gibi minimum-maksimum ölçekleme yöntemi kullanılmıştır.

$$X' = \frac{X - X_{min}}{X_{max} - X_{min}} \quad (1)$$

2.2. Yapay sinir ağı yöntemi

Yapay sinir ağları (YSA), doğrusal ve doğrusal olmayan problemlerin çözümünde iyi sonuçlar veren, insan beynindeki nöronların çalışma sistemini örnek alan bir modeldir (Ateş, 2022). YSA modellerinin en önemli avantajı bir sistem hakkında tahmin yapabilmek için herhangi bir matematiksel bir modele ihtiyaç duymamaktır. YSA modellerinde amaç, eğitilen modelin giriş parametreleriyle çıkış parametresi arasındaki ilişkiyi veri kümesi üzerinden öğrenmesidir (Kılıç vd., 2024). Ayrıca eğitilen modelin, daha önce hiç görmediği girdilere karşılık doğru tahminler yapabilmesi istenmektedir.

YSA içerisinde en çok kullanılan ağ yapısı, hataların geriye yayılma ilkesine göre çalışan geriye beslemeli ağ mimarisidir. Bir YSA hücresi, girdi katmanı, değişken ağırlık çarpanları, toplam fonksiyonu, tanımlama (aktivasyon) fonksiyonu ve çıktı katmanı olmak üzere beş ana bölümden oluşur (Taşar vd., 2018). Bu ağ yapısının genel mimari yapısı Şekil 1’de gösterilmiştir.



Şekil 1. Temel bir YSA hücresi modeli

Şekil 1’de giriş parametre değerleri X_i sembolüyle gösterilmiştir. Her bir giriş parametresi değeri ağırlıklarla çarpıldıktan sonra eşik değeri (bias) ile toplanarak aktivasyon fonksiyonuna iletilir. Aktivasyon fonksiyonu aracılığıyla işlem gerçekleştirilerek modelin tahmin çıktısı olan y_i değeri elde edilir (Yavuz ve Deveci, 2012). Eğitim aşamasında, başlangıçta rastgele belirlenen ağırlıklar, modelin tahmin çıktıları ile gerçek değerler arasındaki fark doğrultusunda optimize edilir. Geliştirilen modelin eğitim aşamasında en küçük hata elde edilene kadar bu süreç sürer. YSA modelleri farklı problemlerde etkili sonuçlar verebilmektedir. Bu nedenle YSA modelleri, tahmin, sınıflandırma, kümeleme, optimizasyon ve doğal dil işleme gibi çeşitli problemlerin çözümünde kullanılmaktadır.

3. Model sonuçları ve değerlendirmeler

Bu çalışmada, uçak motorlarından kaynaklanan görsel duman yoğunluğunu tahmin etmede YSA modelinin performansı araştırılmıştır. Uçak motorlarına ait ölçüm verileri ICAO kurumunun web sayfasından elde edilmiştir. Elde verilerin ham hali, analiz edilmeden verimli kullanılamaz (Mumcu & Meşhur, 2025). Uçak motorları kalkış aşamasında en yüksek performansı gösterdiği için kalkış safhasındaki veriler seçilmiştir. Veri setinde toplam 447 uçak motoruna ait ölçüm verileri modeli geliştirmek için kullanılmıştır. Çalışmada, tüm veriler 70 % eğitim, 15 % doğrulama ve 15 % test için ayrılmıştır. Eğitim için 313 uçak motoruna ait veri, test ve doğrulama için 67 uçak motor verisi kullanılmıştır.

Modelin geliştirilmesi için EEDB veri setinden; motor tipi, baypas oranı, basınç oranı, motorun maksimum nominal itme gücü, çevresel barometrik basınç, ortam sıcaklığı, ortam nemi, yakıttaki hidrojen atomlarının karbon atomlarına oranı, yakıttaki aromatik hidrokarbonların yüzdesi ölçüm değerleri giriş parametresi olarak belirlenmiştir. Bu parametreler modelin giriş katmanına

uygulandığında çıkışından kalkış safhasında SN tahmin edilecektir. Görsel duman yoğunluğunu tahmin eden modeli geliştirmek için Bayesian Regularization (trainbr), Levenberg-Marquardt (trainlm), ve Scaled Conjugate Gradient (trainscg) eğitim algoritması kullanılmıştır. Bayesian Regularization (trainbr), yapay sinir ağlarının eğitiminde kullanılan gelişmiş bir algoritmadır ve modelin genelleme yeteneğini artırmak amacıyla ağırlıklara ceza terimi ekleyerek aşırı öğrenmeyi (overfitting) engeller. Levenberg-Marquardt (trainlm) algoritması ise, Newton türevli optimizasyon yöntemleri ile gradyan iniş yönteminin birleşimi olarak çalışır ve ikinci dereceden hata yüzeylerine karşı hassasiyeti sayesinde hızlı yakınsama sağlar. Scaled Conjugate Gradient (trainscg) algoritması, belleği verimli kullanan bir eğitim algoritmasıdır. Bu üç algoritma ile eğitilen modeller arasında en iyi modeli seçmek için hata performans kriterlerine göre sonuçların karşılaştırılması gerekmektedir. Bu karşılaştırma için beş ayrı hata performans kriteri seçilmiştir.

Geliştirilen modeller için ortalama karesel hata (MSE), ortalama mutlak hata (MAE), kök ortalama kare hata (RMSE), korelasyon katsayısı (R) ve determinasyon katsayısı (R^2) hesaplanmıştır. Elde edilen sonuçlar model tahmini ve gözlem verilerinin performanslarını karşılaştırmak için kullanılmıştır. MSE, MAE ve RMSE hata performans modellerinin matematiksel ifadeleri sırasıyla Denklem (2)-(4) de verilmiştir. Burada N veri sayılarını, $SN_{ölçüm}$ kalkış safhasında görsel duman yoğunluğunu ve SN_{tahmin} tahmin edilen kalkış safhasında görsel duman yoğunluğunu göstermektedir.

$$MSE = \frac{1}{N} \sum_{i=1}^N (SN_{ölçüm} - SN_{tahmin})^2 \quad (2)$$

$$MAE = \frac{1}{N} \sum_{i=1}^N |SN_{ölçüm} - SN_{tahmin}| \quad (3)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (SN_{ölçüm} - SN_{tahmin})^2} \quad (4)$$

Tablo 3, üç farklı eğitim algoritmasının (Bayesian Regularization - trainbr, Levenberg-Marquardt - trainlm, ve Scaled Conjugate Gradient - trainscg) hata performanslarını istatistiksel hata ölçütlerine göre karşılaştırmalı olarak sonuçları sunmaktadır. Kalkış safhasında görsel duman yoğunluğunu en iyi tahmin eden YSA modelini seçmek için karşılaştırmalı analiz, korelasyon katsayısı (R), ortalama kare hata (MSE), ortalama mutlak hata (MAE), kök ortalama kare hata (RMSE), determinasyon katsayısı (R^2) kriterleri üzerinden gerçekleştirilmiştir.

Tablo 3. Kalkış safhasında görsel duman yoğunluğunu tahmin eden YSA modellerinin performans sonuçları.

Hata kriterleri ve aşamalar		Eğitim algoritmaları		
		trainbr	trainlm	trainscg
R	Eğitim	0,9876122	0,9586146	0,5963826
	Doğrulama	0,9752393	0,8991308	0,6253009
	Test	0,9735947	0,8456342	0,5841275
MSE	Eğitim	0,0003922	0,0013880	0,0103469
	Doğrulama	0,0005581	0,0021312	0,0084362
	Test	0,0008268	0,0037914	0,0081150
MAE	Eğitim	0,0120051	0,0241384	0,0763758
	Doğrulama	0,0131773	0,0292867	0,0742715
	Test	0,0131660	0,0338459	0,0703092
RMSE	Eğitim	0,0198040	0,0372563	0,1017198
	Doğrulama	0,0236252	0,0461650	0,0918489
	Test	0,0287557	0,0615748	0,0900836
R^2	Eğitim	0,9753385	0,9188281	0,3550606
	Doğrulama	0,9444440	0,7968889	0,3864445
	Test	0,9478341	0,6308348	0,3063163
Eğitim süresi (saniye)		4,838655	4,761117	4,479625

Trainbr algoritması, tüm metriklerde en düşük hata oranlarını ve en yüksek korelasyon katsayılarını sağlamıştır. Özellikle eğitim, doğrulama ve test setleri için R değerleri sırasıyla 0.9876, 0.9752 ve 0.9735 düzeyindedir. Bu değerler, modelin verilerle yüksek doğrusal ilişki kurduğunu ve genelleme yeteneğinin güçlü olduğunu göstermektedir. Benzer şekilde, R^2 değerleri de eğitim ve test aşamalarında sırasıyla 0.9753 ve 0.9478 gibi yüksek seviyelerdedir. Ayrıca, trainbr algoritmasının MSE (eğitimde 0.0003922) ve RMSE (eğitimde 0.0198) değerleri, modelin hata miktarını minimum düzeyde tuttuğunu göstermektedir. Bu sonuçlar, overfitting eğilimi olmaksızın yüksek doğrulukla öğrenme başarısı elde edildiğine işaret etmektedir.


Trainlm algoritması, trainbr'ye kıyasla daha yüksek hata oranları ve daha düşük R- R^2 değerleri üretmiştir. Eğitim seti için R değeri 0.9586, test seti için ise 0.8456 olarak ölçülmüştür. MSE değerlerinin daha yüksek (örneğin test aşamasında 0.0037914) olması, modelin doğruluk açısından daha sınırlı performans sergilediğini göstermektedir. Bununla birlikte, eğitim süresi açısından en hızlı algoritma olmasa da 4.76 saniye ile düşük süreli bir hesaplama gerektirmiştir.

Trainscg algoritması ise performans açısından en zayıf sonucu vermiştir. Eğitim ve test için R değerleri sırasıyla 0.5963 ve 0.5841 seviyesindedir ve bu durum, modelin tahmin başarısının oldukça düşük olduğunu ve doğrusal ilişkinin zayıf kaldığını göstermektedir. Ayrıca MSE ve MAE gibi hata metrikleri, diğer algoritmalara kıyasla oldukça yüksektir. Bu durum, özellikle küçük veri setleri veya karmaşık doğrusal olmayan problemlerde trainscg algoritmasının yetersiz kalabileceğini göstermektedir.



Sonuç olarak, tüm kriterler dikkate alındığında trainbr algoritması, hem öğrenme doğruluğu hem de genelleme başarısı açısından en iyi sonuçları sunmaktadır. Düşük hata metrikleri, trainbr algoritması ile eğitilen modeli SN parametresini tahmin eden en iyi model olduğunu göstermektedir. Geliştirilen en iyi modelin detayları Tablo 4'de ve yapısını gösteren ekran alıntısı Şekil 2'de sunulmuştur. Kalkış safhasında görsel duman yoğunluğunu tahmin eden modelin hata performans grafikleri Şekil 3-5'de gösterilmiştir.

Tablo 4. Kalkış Trainlm eğitim algoritması ile geliştirilen YSA modelinin ayrıntıları.


Ağın parametreleri	Detaylar		
Mimarisi	9 giriş, 1 çıkış, 2 gizli katman nöron sayısı (15-1)		
Aktivasyon fonksiyonu	Gizli katman: 'tansig' – 'purelin'		
	Çıkış katmanı: "Linear"		
Eğitim algoritması	Bayesian Regularization – 'trainbr'		
Performans fonksiyonu kriterleri	Minimum MSE		
Durdurma kriterleri	Doğrulama hatası artmaya başladığında eğitim durdurulur		
Veri seti	Eğitim	Doğrulama	Test
	313 tane	67 tane	67 tane





Şekil 2. Matlab ortamında geliştirilen YSA modelinin yapısı



Şekil 3. Geliştirilen en iyi YSA modelinin eğitim veri setindeki performans grafikleri



Şekil 4. Geliştirilen en iyi YSA modelinin doğrulama veri setindeki performans grafikleri



Şekil 5. Geliştirilen en iyi YSA modelinin test veri setindeki performans grafikleri

4. Sonuçlar

Bu çalışma kapsamında, uçak motorlarının kalkış safhasında görsel duman yoğunluğunu yüksek doğrulukla tahmin edebilen, YSA tabanlı bir model geliştirilmiştir. Literatürde EEDB veri setini kullanarak görsel duman yoğunluğunu tahmin eden bir çalışma bulunmamaktadır. ICAO'nun EEDB veri setinden elde edilen motor ve çevresel parametreler, modelin giriş verileri olarak kullanılmış; farklı eğitim algoritmalarının karşılaştırıldığı analiz sonucunda, Bayesian Regularization (trainbr) algoritması en başarılı tahmin performansını göstermiştir. Model, eğitim, doğrulama ve test aşamalarında yüksek korelasyon katsayısı (R) ve düşük hata oranları (MSE, MAE, RMSE) ile dikkat çekmiştir.

Geliştirilen model, sadece teorik bir başarı değil, aynı zamanda uygulama açısından da önemli kazanımlar sunmaktadır. Bu model motor tasarım süreçlerinde çevresel etki değerlendirmeleri ve uçak motorlarının performans bozulmasını tespit etme potansiyeli taşımaktadır. Ayrıca, görsel duman yoğunluğu ile nvPM emisyonları arasındaki istatistiksel ilişkiler göz önünde bulundurulduğunda, geliştirilen bu tahmin modeli, dolaylı olarak yeni nesil regülasyonlara (örneğin nvPM standartları) uyumluluk analizlerinde de kullanılabilecek potansiyele sahiptir. Gelecekte yeni sensörler ve sistemler geliştirilmesi ile uçakların test sistemlerine gereksinim duymadan uçak motorlarının performansı anlık olarak değerlendirilebilecektir. Havacılık otoritesi bu sistemlerin uygulanmasına izin verdiğinde, uçakların güvenliği ve güvenilirliği artacaktır. Gerçek uçuş verileriyle doğrulama yapılmadığından modelin saha koşullarındaki geçerliliği henüz gösterilememiştir. Sonuç olarak, bu araştırma, YSA ile görsel duman yoğunluğunun tahmini konusunda literatüre yenilikçi ve uygulanabilir bir katkı sunmakta; sürdürülebilir ve çevreci havacılık teknolojilerinin geliştirilmesine temel oluşturmaktadır.

Destek ve Teşekkür Beyanı

Çalışma herhangi bir destek almamıştır. Teşekkür edilecek bir kurum veya kişi bulunmamaktadır.

Çıkar Çatışması Beyanı

Çalışma kapsamında herhangi bir kurum veya kişi ile çıkar çatışması bulunmamaktadır.

Kaynaklar

- Agarwal, A., Speth, R. L., Fritz, T. M., Jacob, S. D., Rindlisbacher, T., Iovinelli, R., & Barrett, S. R. (2019). SCOPE11 method for estimating aircraft black carbon mass and particle number emissions. *Environmental Science & Technology*, 53(3), 1364–1373. <https://doi.org/10.1021/acs.est.8b04060>
- Ateş, K. T. (2022). Investigation of factors affecting compressive strength of cement and concrete with prediction methods used in artificial intelligence algorithms. *International Journal of Advances in Engineering and Pure Sciences*, 34(2), 242–261. <https://doi.org/10.7240/jeps.1013130>
- Brink, L. F. J. (2020). Modeling the impact of fuel composition on aircraft engine NOx, CO and soot emissions. (Doctoral dissertation, Massachusetts Institute of Technology). Retrieved from <https://dspace.mit.edu/handle/1721.1/129181>
- Christie, S., Lobo, P., Lee, D., & Raper, D. (2017). Gas turbine engine nonvolatile particulate matter mass emissions: correlation with smoke number for conventional and alternative fuel blends. *Environmental Science & Technology*, 51(2), 988-996. <https://doi.org/10.1021/acs.est.6b03766>
- Deng L, Chen Q, He Y, Sui X, Wang Q. (2021), Detection of smoke from infrared image frames in the aircraft cargoes. *International Journal of Distributed Sensor Networks*, 17(4). <https://doi.org/10.1177/15501477211009808>
- Ge, F., Yu, Z., Li, Y., Zhu, M., Zhang, B., Zhang, Q., & Chen, L. (2022). Predicting aviation non-volatile particulate matter emissions at cruise via convolutional neural network. *Science of The Total Environment*, 850, 158089. <https://doi.org/10.1016/j.scitotenv.2022.158089>
- International Civil Aviation Organization. (2020). *Airport air quality manual* (Doc 9889). Erişim: 03 Nisan, 2025, https://www.icao.int/publications/documents/9889_cons_en.pdf

International Civil Aviation Organization. (2024). *ICAO Aircraft Engine Emissions Databank*. Erişim: 01 Kasım, 2024, <https://www.easa.europa.eu/en/domains/environment/icao-aircraft-engine-emissions-databank>

Jagtap, S. S., Childs, P. R., & Stettler, M. E. (2024). Conceptual design-optimisation of a future hydrogen-powered ultrahigh bypass ratio geared turbofan engine. *International Journal of Hydrogen Energy*, 95, 317-328. <https://doi.org/10.1016/j.ijhydene.2024.10.329>

Kılıç, İ., Aydın, M., & Şahin, H. (2024). Predicting battery capacity with artificial neural networks. *Akıllı Ulaşım Sistemleri ve Uygulamaları Dergisi*, 7(2), 99-112. <https://doi.org/10.51513/jitsa.1380584>

Kodak, G. (2024). An Investigation on the use of air quality models in ship emission forecasts. *Akıllı Ulaşım Sistemleri ve Uygulamaları Dergisi*, 7(1), 15-30. <https://doi.org/10.51513/jitsa.1425614>

Kurt, B. (2024a). Prediction of performance degradation in aircraft engines with fuel flow parameter. *Neural Computing and Applications*, 36(6), 2973-2982. <https://doi.org/10.1007/s00521-023-09174-9>

Kurt, B. (2024b). Evaluation of aircraft engine performance during takeoff phase with machine learning methods. *Neural Computing and Applications*, 36(30), 19173-19190. <https://doi.org/10.1007/s00521-024-10220-3>

Ma, S., Lin, S., Han, B., Zhang, C., Wei, Z., Xue, L., & Hopke, P. K. (2025). Revealing considerable emissions reduction potential in flight operations: A real-time emission perspective. *Transportation Research Part D: Transport and Environment*, 143, 104745. <https://doi.org/10.1016/j.trd.2025.104745>

Martini, B. (2008). Development and assessment of a soot emissions model for aircraft gas turbine engines. (*Doctoral dissertation, Massachusetts Institute of Technology*). Retrieved from <https://dspace.mit.edu/handle/1721.1/45256>

Mumcu, B., & Meşhur, H. F. A. (2025). Yapay Zekâ ve Yeşil Ulaşım Birlikteliğinin Kente Etkileri. *Akıllı Ulaşım Sistemleri ve Uygulamaları Dergisi*, 8(1), 66-89. <https://doi.org/10.51513/jitsa.1529225>

Oruc, R. (2025). Prediction of emission and exergy parameters of commercial high by-pass turbofan engines based on CSA-SVR model. *Journal of Thermal Analysis and Calorimetry*, 1-13. <https://doi.org/10.1007/s10973-025-14403-5>

Qasem, M. A. A., Al-Mutairi, E. M., & Jameel, A. G. A. (2023). Smoke point prediction of oxygenated fuels using neural networks. *Fuel*, 332, 126026. <https://doi.org/10.1016/j.fuel.2022.126026>

Stettler, M. E., Swanson, J. J., Barrett, S. R., & Boies, A. M. (2013). Updated correlation between aircraft smoke number and black carbon concentration. *Aerosol Science and Technology*, 47(11), 1205-1214. <https://doi.org/10.1080/02786826.2013.829908>

Taşar, B., Üneş, F., Demirci, M., & Kaya, Y. Z. (2018). Yapay sinir ağları yöntemi kullanılarak buharlaşma miktarı tahmini. *Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi*, 9(1), 543-551.

Trivanovic, U., & Pratsinis, S. E. (2023). Opinion: Eliminating aircraft soot emissions. *Aerosol Research Discussions*, 2023, 1-17. <https://doi.org/10.5194/ar-2-207-2024>

Wayson, R. L., Fleming, G. G., & Iovinelli, R. (2009). Methodology to estimate particulate matter emissions from certified commercial aircraft engines. *Journal of the Air & Waste Management Association*, 59(1), 91-100. <https://doi.org/10.3155/1047-3289.59.1.91>

Yavuz, S., & Deveci, M. (2012). İstatiksel normalizasyon tekniklerinin yapay sinir ağı performansına etkisi. *Erciyes Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, (40), 167-187.

Zou, R., Wang, B., Wang, K., Shang, W. L., Xue, D., & Ochieng, W. Y. (2025). A pathway to sustainable aviation: Modeling aircraft takeoff mass for precise fuel consumption and aircraft emission calculations. *Energy*, 319, 135074. <https://doi.org/10.1016/j.energy.2025.135074>