T.C.
İSTANBUL ÜNİVERSİTESİ-CERRAHPAŞA
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

YÜKSEK LİSANS TEZİ

MAKİNE ÖĞRENİMİ TABANLI KANAT PROFİLİ ÜZERİNDEKİ AERODİNAMİK KUVVETLERİN TAHMİNİ VE ŞEKİL OPTİMİZASYONU MODELİNİN GELİŞTİRİLMESİ

Abdulsamet EKŞİ

DANIŞMAN
Doç. Dr. Selçuk SEVGEN

Bilgisayar Mühendisliği Anabilim Dalı

Bilgisayar Mühendisliği, Tezli Yüksek Lisans Programı

Şubat, 2025

TEZ KABUL VE ONAYI

Abdulsamet EKŞİ tarafından, **Doç. Dr. Selçuk SEVGEN** danışmanlığında hazırlanan **MAKİNE ÖĞRENİMİ TABANLI KANAT PROFİLİ ÜZERİNDEKİ AERODİNAMİK KUVVETLERİN TAHMİNİ VE ŞEKİL OPTİMİZASYONU MODELİNİN GELİŞTİRİLMESİ "** başlıklı bu çalışma, jürimiz tarafından **28/02/2025** tarihinde yapılan sınav sonucunda **oy birliği** ile başarılı bulunarak **Yüksek Lisans Tezi** olarak kabul edilmiştir.

Tez Jürisi

		İmza	**Sonuç**
DANIŞMAN	Doç. Dr. Selçuk SEVGEN İstanbul Üniversitesi-Cerrahpaşa Bilgisayar Mühendisliği Anabilim Dalı		☐ Kabul ☐ Ret
ÜYE	Prof. Dr. Muhammed Ali AYDIN İstanbul Üniversitesi-Cerrahpaşa Bilgisayar Mühendisliği Anabilim Dalı		☐ Kabul ☐ Ret
ÜYE	Dr. Öğr. Üyesi Ahmet KAŞİF Bursa Teknik Üniversitesi Bilgisayar Mühendisliği Anabilim Dalı		☐ Kabul ☐ Ret

Aileme ve Eşim Selin SEZER EKŞİ'ye ithaf ediyorum…

BÜTÇE DESTEKLERİ

MAKİNE ÖĞRENİMİ TABANLI KANAT PROFİLİ ÜZERİNDEKİ AERODİNAMİK KUVVETLERİN TAHMİNİ VE ŞEKİL OPTİMİZASYONU MODELİNİN GELİŞTİRİLMESİ

Bu tez çalışması için herhangi bir kurumdan bütçe desteği alınmamıştır.

TEŞEKKÜR

Tez konumu belirlemede ve teknik konularda kıymetli yönlendirmeler sağlayan Sadık YETKİN'e, yöneticilerime ve yüksek lisans çalışmam boyunca bana yol gösteren, beni doğru yolda tutan ve motive eden Danışman Hocam Doç. Dr. Selçuk SEVGEN'e teşekkür ederim.

Şubat 2025 Abdulsamet EKŞİ

İÇİNDEKİLER

Sayfa No

TEZ KABUL VE ONAYI ..... **ii**
BEYAN ..... **iii**
BÜTÇE DESTEKLERİ ..... **v**
TEŞEKKÜR ..... **vi**
İÇİNDEKİLER ..... **vii**
ŞEKİL LİSTESİ ..... **ix**
TABLO LİSTESİ ..... **x**
SİMGE VE KISALTMA LİSTESİ ..... **xi**
ÖZET ..... **xiii**
ABSTRACT ..... **xv**
1. GİRİŞ **1**
2. KAVRAMSAL ÇERÇEVE **4**
2.1. KANAT PROFİLİ VE ETKİ EDEN AERODİNAMİK KUVVETLER 4
2.1.1. Kanat Profillerinin İsimlendirilmesi – NACA 4 Basamaklı İsimlendirme 6
2.1.2. Kanat Profiline Etki Eden Aerodinamik Kuvvetler 7
2.2. LİTERATÜR TARAMASI 9
3. YÖNTEM **14**
3.1. VERİ SETİNİN OLUŞTURULMASI 14
3.2. VERİ ÖN İŞLEME 16
3.2.1. Veri Setinin İncelenmesi 16
3.2.2. Veri Temizleme 17
3.2.3. Eğitim ve Test Veri Setinin Hazırlanması 18
3.2.4. Öznitelik Seçimi 19
3.2.5. Veri Ölçekleme 20
3.3. MAKİNE ÖĞRENİMİ MODELLERİNİN EĞİTİLMESİ 21
3.4. MODEL PERFORMANSLARININ DEĞERLENDİRİLMESİ 21
3.5. EN İDEAL KANAT PROFİLİNİN ANALİZİ 23
4. BULGULAR **26**

5. TARTIŞMA **35**
6. SONUÇ VE ÖNERİLER **37**
KAYNAKLAR **39**
EKLER **41**
İNTİHAL RAPORU İLK SAYFASI **42**
ETİK KURUL İZİN YAZISI **43**
KURUM İZNİ YAZILARI **44**
ÖZGEÇMİŞ **45**

ŞEKİL LİSTESİ

Sayfa No

Şekil 2.1: Kanat Profili (Yükselen, 2024). 4

Şekil 2.2: Temel Kanat Profili Geometrisi (Yükselen, 2024). 5

Şekil 2.3: NACA2412 Airfoil Geometrik Parametreleri..... 7

Şekil 2.4: Kanat Profili Üzerindeki Kuvvetler. **7**

Şekil 3.1: XFOIL ile Kanat Profilleri Üzeri Etki Eden Aerodinamik Kuvvetlerin Analizi. 15

Şekil 3.2: Veri Seti Yapısı..... 16

Şekil 3.3: NACA 2122 Kanat Profili Üzerine Etki Eden Aerodinamik Kuvvetlerin Analizi.. 17

Şekil 3.4: C_L, C_D ve C_M'nin Mach Değerlerine Göre Kutu Grafi Yöntemi ile Analizi. 18

Şekil 3.5: Eğitim Veri Seti Oranlarına Göre Hata Değerleri (Yetkin ve diğ.,2024). 19

Şekil 3.6: Makine Öğrenimi Modellerinin Geliştirilmesi ve Performans Değerlendirme. 21

Şekil 4.1: Eğitim ve Validasyon Kayıp Fonksiyonu Grafiği. 30

Şekil 4.2: 256-128-64-32-1 Düğüm Sayılarına Sahip Model için Eğitim ve Validasyon Kayıp (Loss) Grafiği. 31

Şekil 4.3: 128-64-32-1 Düğüm Sayılarına Sahip Model için Eğitim ve Validasyon Kayıp (Loss) Grafiği. 32

TABLO LİSTESİ

Sayfa No

Tablo 3.1: Veri Setinde Farklı Mach Değerlerine Göre Yer Alan Veri Sayısı. 16

Tablo 4.1: C_L Tahmin Modeli Performanslarının Karşılaştırılması. 26

Tablo 4.2: CD Tahmin Modeli Performanslarının Karşılaştırılması. 27

Tablo 4.3: C_M Tahmin Modeli Performanslarının Karşılaştırılması. 27

Tablo 4.4: Modellerin Eğitim Sürelerinin Karşılaştırılması. 27

Tablo 4.5: Farklı Katman ve Düğüm Sayılarına Sahip Min-Max Normalizasyonu ile Ölçeklendirilmiş, Sigmoid Aktivasyon Fonksiyonu ile Eğitilen YSA Modellerinin Performansları. 29

Tablo 4.6: Farklı Katman ve Düğüm Sayılarına Sahip Z-score Standardizasyonu ile Ölçeklendirilmiş, Sigmoid Aktivasyon Fonksiyonu ile Eğitilen YSA Modellerinin Performansları. 30

Tablo 4.7: Farklı Aktivasyon Fonksiyonları için Performans Karşılaştırması. 33

Tablo 4.8: Evrişimsel Sinir Ağları ile Eğitilen Modellerin Performansları. 34

SİMGE VE KISALTMA LİSTESİ

Simgeler	Açıklama
α	: Hücum Açısı
C_L	: Taşıma Katsayısı
C_D	: Sürükleme Katsayısı
C_{Dp}	: Parazit Sürükleme Katsayısı
C_M	: Moment Katsayısı
S	: Kanat Alanı
ρ_∞	: Hava Yoğunluğu (Kütle/Hacim)
V_∞	: Havanın Hızı
y	: Çıktı Değeri (Aerodinamik Katsayılar)

Kısaltmalar	Açıklama
c	: Veter Uzunluğu
CNN	: Evrişimsel Sinir Ağı
D	: Sürükleme Kuvveti
DT	: Karar Ağacı (Decision Tree)
EVS	: Açıklanan Varyans Skoru (Explained Variance Score)
HAD	: Hesaplamalı Akışkanlar Dinamiği
L	: Taşıma Kuvveti
M	: Moment Kuvveti
MAE	: Ortalama Mutlak Hata (Mean Absolute Error)
MaxAE	: Maksimum Mutlak Hata (Maximum Absolute Error)
MSE	: Ortalama Kare Hata (Mean Squared Error)
MLP	: Çok Katmanlı Algılayıcılar
NACA	: Ulusal Havacılık Danışma Komitesi (National Advisory Committee for Aeronautics)
RF	: Rassol Orman (Random Forest)
SVM	: Destek Vektör Makinesi (Support Vector Machine)
SVMr	: Destek Vektör Makinesi Regresyon Regresyon Modeli

YSA : Yapay Sinir Ağı

ÖZET

YÜKSEK LİSANS TEZİ

MAKİNE ÖĞRENİMİ TABANLI KANAT PROFİLİ ÜZERİNDEKİ AERODİNAMİK KUVVETLERİN TAHMİNİ VE ŞEKİL OPTİMİZASYONU MODELİNİN GELİŞTİRİLMESİ

Abdulsamet EKŞİ

İstanbul Üniversitesi-Cerrahpaşa

Lisansüstü Eğitim Enstitüsü

Bilgisayar Mühendisliği Anabilim Dalı

Bilgisayar Mühendisliği, Tezli Yüksek Lisans Programı

Danışman : Doç. Dr. Selçuk SEVGEN

Aerodinamik katsayıların doğru tahmini, hava aracı tasarım süreçlerinde kritik bir rol oynamaktadır. Geleneksel Hesaplamalı Akışkanlar Dinamiği (HAD) yöntemleri yüksek doğruluk sağlamasına rağmen, yüksek hesaplama maliyetleri ve uzun simülasyon süreleri nedeniyle hızlı tasarım döngüleri için sınırlamalar oluşturmaktadır. Bu çalışmada, kanat profillerinin aerodinamik katsayılarını tahmin etmek amacıyla makine öğrenimi ve derin öğrenme tabanlı modeller geliştirilmiş ve performansları karşılaştırılmıştır. Veri seti, XFOIL yazılımı kullanılarak farklı Mach sayıları ($0.3 \leq Mach \leq 0.7$) ve hücum açıları ($4° \leq \alpha \leq 14°$) için elde edilen aerodinamik katsayılar ile oluşturulmuştur.

Eğitim ve test veri setleri oluşturulurken, farklı kanat profillerinin genelleme başarısını değerlendirmek amacıyla veri seti, kanat profili NACA numaralarına göre ayrılmıştır. Eğitim veri setinde yer alan hiçbir kanat profili, test veri setinde yer almamakta; aynı şekilde test veri setinde bulunan profiller de eğitim sırasında kullanılmamaktadır. Bu yöntem, modelin bilinmeyen kanat profilleri için tahmin yapabilme yeteneğini değerlendirmeyi amaçlamaktadır.

Tez kapsamında, Destek Vektör Makineleri (SVM), XGBoost, AdaBoost, Rassal Orman (Random Forest), Karar Ağacı (Decision Tree), Yapay Sinir Ağları (YSA) ve Evrişimsel Sinir Ağları (CNN) ile farklı makine öğrenimi modelleri test edilmiş; en yüksek doğruluk CNN ve YSA tarafından sağlanmıştır. Bununla birlikte XGBoost ve Rassal Orman, bazı aerodinamik katsayıların tahmininde derin öğrenme modellerine yakın performans göstermiş ve hızlı eğitim süreleri sayesinde alternatif bir yöntem olarak değerlendirilmiştir.

Çalışmanın özgün katkılarından biri, en ideal kanat profili seçiminde yalnızca taşıma katsayısı/sürükleme katsayısı (C_L/C_D) oranına değil, aynı zamanda moment katsayısına (C_M) dayalı çok kriterli bir değerlendirme yaklaşımının önerilmesidir. Sunulan yöntem, aerodinamik verimlilik ve uçuş stabilitesini aynı anda değerlendiren bir optimizasyon metriği kullanmaktadır. Sonuçlar, modelin farklı Mach sayıları ve hücum açıları için eğitildiğinde, bilinmeyen kanat profillerinde başarılı tahminler yaptığını göstermektedir. Böylece, makine öğrenimi tabanlı modellerin hava aracı tasarım süreçlerinde alternatif ve hızlı bir tahmin yöntemi olarak kullanılabileceği ortaya konmuştur.

Bu tez çalışması, makine öğrenimi ve derin öğrenme yaklaşımlarının aerodinamik analizlerde nasıl daha etkili kullanılabileceğini ortaya koyarak, veri odaklı tasarım süreçlerine katkı sağlamaktadır.

Şubat 2025 , 61 sayfa.

Anahtar kelimeler: Kanat Profili, Aerodinamik Analiz, Makine Öğrenimi, Hesaplamalı Akışkanlar Dinamiği

ABSTRACT

M.Sc. THESIS

MACHINE LEARNING BASED PREDICTION OF AERODYNAMIC FORCES ON WING PROFILE AND DEVELOPMENT OF SHAPE OPTIMIZATION MODEL

Abdulsamet EKŞİ

İstanbul University-Cerrahpaşa

Institute of Graduate Studies

Department of Computer Engineering

Computer Engineering, Thesis Master's Program

Supervisor : Assoc. Prof. Dr. Selçuk SEVGEN

The accurate prediction of aerodynamic coefficients plays a critical role in aircraft design processes. Although traditional Computational Fluid Dynamics (CFD) methods provide high accuracy, their high computational cost and long simulation times impose limitations on rapid design cycles. In this study, machine learning and deep learning-based models were developed and their performance was compared to predict aerodynamic coefficients of airfoil profiles. The dataset was generated using XFOIL software for different Mach numbers ($0.3 \leq \text{Mach} \leq 0.7$) and angles of attack ($4° \leq \alpha \leq 14°$).

To evaluate the generalization performance of different airfoil profiles, the dataset was split based on NACA airfoil numbers during the creation of training and test datasets. No airfoil geometry in the training dataset was included in the test dataset, and similarly, none of the airfoil geometries in the test dataset were used during training. This method aims to assess the model's ability to predict aerodynamic coefficients for previously unseen airfoil profiles.

In this study, various machine learning models, including Support Vector Machines (SVM), XGBoost, AdaBoost, Random Forest, Decision Tree, Artificial Neural Networks (ANN), and Convolutional Neural Networks (CNN), were tested. The results indicate that CNN and ANN achieved the highest prediction accuracy. However, XGBoost and Random Forest demonstrated comparable performance to deep learning models in predicting certain aerodynamic coefficients and were considered viable alternatives due to their faster training times.

One of the novel contributions of this study is the introduction of a multi-criteria evaluation approach for selecting the optimal airfoil profile, considering not only the lift-to-drag ratio (C_L/C_D) but also the moment coefficient (C_M). The proposed method employs an optimization metric that simultaneously evaluates aerodynamic efficiency and flight stability.

The results demonstrate that the trained model, developed for different Mach numbers and angles of attack, successfully predicts aerodynamic coefficients for previously unseen airfoil profiles. Thus, machine learning-based models have been identified as a viable and efficient alternative for aerodynamic coefficient estimation in aircraft design processes.

This thesis contributes to the field by demonstrating how machine learning and deep learning approaches can be effectively utilized in aerodynamic analysis, thereby supporting data-driven design processes.

February 2025, 61 pages.

Keywords: Airfoil, Aerodynamic Analysis, Machine Learning, Computational Fluid Dynamics (CFD)

1. GİRİŞ

Havacılık sektörü hem ticari hem de askeri uygulamalarda, daha hafif, dayanıklı, hızlı ve verimli hava araçları tasarlama ve üretme hedefi doğrultusunda, akademik ve endüstriyel araştırma-geliştirme faaliyetlerinin odak noktası olmuştur. Bu hedef doğrultusunda sürekli olarak yenilikçi teknolojiler geliştirilmekte ve optimizasyon çalışmaları gerçekleştirilmektedir. Bu sürecin merkezinde yer alan kanat profilleri (airfoil), bir hava aracının aerodinamik performansını belirleyen en kritik unsurlardan biridir.

Kanat profilleri, yapısı ile, Bernoulli prensibine göre cismin iki zıt yüzeyinde basınç farkı meydana getirir. Bu sayede aerodinamik kuvvetler oluşarak uçakların havada kalması sağlanır. Kanat profilleri, hava akışıyla etkileşim sonucunda oluşan kaldırma (lift) ve sürükleme (drag) kuvvetlerini etkilerken, aynı zamanda moment kuvvetleriyle hava aracının stabilitesi ve manevra kabiliyeti üzerinde önemli bir rol oynamaktadır. Bu aerodinamik kuvvetlerin şekil ve akış şartlarına göre optimize edilmesi, modern havacılık tasarımlarının temel hedeflerinden biri olarak öne çıkmaktadır. Hava aracı üzerindeki aerodinamik kuvvetlerin analizi, en optimum hava aracı tasarımının gerçekleştirilmesinde ve tasarım kriterlerine göre farklı hava koşullarında hava aracı davranışlarının belirlenmesinde/analiz edilmesinde önemli bir yere sahiptir. Aerodinamik kuvvetlerin analiz aşamalarında, hava aracının ölçekli veya birebir boyutlarındaki versiyonları ile rüzgar tüneli testleri ve uçuş testleri gerçekleştirilebileceği gibi bilgisayar destekli analizler de gerçekleştirilebilmektedir.

Hava aracı yapısallarının, özellikle kanatların, aerodinamik davranışlarının analizinde Hesaplamalı Akışkanlar Dinamiği (HAD veya CFD) yaygın olarak kullanılmaktadır (Andrés-Pérez ve diğ. 2012; Yetkin ve diğ. 2024). HAD, akışkan davranışının etkili olduğu problemlerin sayısal yöntemler ve algoritmalar yardımıyla bilgisayar ortamında çözümlendiği, akışkanlar mekaniğinin bir dalıdır. Bilgisayar destekli HAD analizleri, çok sayıda tasarım parametresini içeren karmaşık problemlerin global optimumunu bulmada yüksek bir potansiyele sahiptir ve bu nedenle hava aracı tasarımlarında vazgeçilmez bir araçtır. Bu simülasyonlar, rüzgar tüneli deneylerine veya uçuş testlerine kıyasla önemli ölçüde zaman ve maliyet tasarrufu sağlamaktadır.

Örneğin; ticari uçak üreticisi Boeing, HAD ile rüzgar tüneli testlerini birleştirerek toplam rüzgar tüneli testi ihtiyacını yarıya indirmiştir. Bu entegrasyon, tasarım sürecini hızlandırmakla kalmamış, aynı zamanda maliyetleri de önemli ölçülerde azaltmıştır. HAD, eksik rüzgar tüneli testlerini tamamlamada kullanılmış ve bazı durumlarda rüzgar tüneli testleri tamamen ortadan kaldırılmıştır (Tinoco, 2008).

HAD simülasyonları, aerodinamik katsayı veri setleri oluşturmak için güvenilir bir yöntem olarak kabul edilmekle birlikte; her kanat geometrisi ve her senaryo için yüksek doğrulukta HAD analizi gerçekleştirmek yüksek hesaplama maliyetleri getirebilmektedir. Karmaşık geometriler için HAD simülasyonlarının sonuçları, yüksek performanslı bilgisayarlar kullanılarak birkaç saat sürebilmekte ve bu nedenle en ideal kanat profili yapısının belirlenebilmesi için tüm olası konfigürasyonların simülasyonu hem zaman hem de hesaplama maaliyeti açısından uygun olmamaktadır (Li ve diğ., 2021; Balla ve diğ. 2021; Yetkin ve diğ. 2024). Bir kanat profilinin çeşitli geometrik parametreler ve akış şartları altında davranışını incelemek için binlerce HAD simülasyonu gerekebilmekte ve bu da mühendislik uygulamalarında zaman ve maliyet açısından önemli bir yük getirebilmektedir. HAD araçlarının yerine makul bir doğrulukla tahmin yapabilecek alternatif yenilikçi modellerin kullanılması giderek daha fazla dikkate alınmakta ve bu alanda çalışmalar artmaktadır (Andrés-Pérez ve Paulete-Periáñez, 2021). Makine öğrenimi, HAD'ın bu sınırlarının üstesinden gelmek için umut vadeden bir yaklaşım olarak görülmektedir. Destek Vektör Makineleri (SVM), Yapay Sinir Ağları (YSA), XGBoost ve benzeri teknikler, HAD analizlerinden elde edilen veri setleri üzerinde öğrenerek aerodinamik kuvvetleri tahmin etmekte kullanılmıştır.

Makine öğrenimi modelleri, geometrik parametreler ve akış şartları arasındaki karmaşık ilişkileri yakalayarak daha genelleyici çözümler sunmaktadır. Literatürde, birçok çalışma HAD simülasyonlarına alternatif olarak, aerodinamik katsayıların tahmininde makine öğreniminin potansiyelini göstermiştir. Literatürde yer alan çalışmalar, yaygın olarak, HAD analizleri ile oluşturulan verisetleri üzerinde sabit Mach (akışkanlar mekaniğinde hareket halindeki bir kütlenin hızının, kütlenin bulunduğu şartlardaki ses hızına oranı) ve Reynold sayısı kullanılarak, farklı kanat profili geometrilerinin farklı hücum açısı değerlerindeki aerodinamik karakteristikleri üzerinden eğitilen farklı makine öğrenimi modellerine yer vermekte ve model başarımları karşılaştırılmaktadır (Santos ve diğ. 2008; Andrés-Pérez ve diğ. 2012; Li ve diğ.,

2021; Balla ve diğ. 2021; Andrés-Pérez ve Paulete-Periáñez, 2021; Moin ve diğ. 2022; Yetkin ve diğ. 2024).

Tez çalışması ile kısıtlı kanat yapısı geometrileri üzerinden, kanat profili üzerinde farklı Mach ve hücum açısı (Angle of Attack) değerlerinde makine öğrenimi destekli olarak aerodinamik kuvvetleri yüksek doğrulukta tahmin ederek, optimum kanat geometrisinin bulunması amaçlanmaktadır.

Kanat profili geometri geliştirilmesi için farklı maksimum kamburluk, maksimum kamburluk pozisyonu ve maksimum kalınlık değerleri kullanılarak NACA (Ulusal Havacılık Danışma Komitesi - National Advisory Committee for Aeronautics) dosyaları oluşturulmuştur. Kanat profillerinin aerodinamik analizleri açık kaynak kodlu XFOIL (Drela, 1989) yazılımı ile gerçekleştirilmiştir. Aynı veri seti üzerinde Destek Vektör Makineleri (SVM), XGBoost, AdaBoost, Rassal Orman (Random Forest), Kara Ağacı (Decision Tree), Yapay Sinir Ağları (YSA) ve Evrişimsel Sinir Ağları (CNN) makine öğrenimi modelleri eğitilerek, bu modellerin performansları ve eğitim için gerekli süre karşılaştırmaları yapılmıştır. Literatürdeki çalışmaların aksine, farklı Mach sayıları ve genişletilmiş veri setleri kullanılarak model performansının genelleme yeteneği detaylı bir şekilde incelenmiştir. Ayrıca, tez çalışmasının önemli bir özgünlük katmanı, veri setinin NACA numaralarına (farklı kanat profillerine) göre bölünmesi ve tamamen farklı geometrilerin test edilmesidir. Bu yaklaşımla, öğrenme sürecinde kullanılan geometrilerin test sürecinde yer almaması sağlanmış ve modelin genelleme kapasitesi daha etkili bir şekilde değerlendirilmiştir. Bu çalışmanın sonuçları, gelecekteki hava aracı tasarımlarında daha etkili ve verimli çözümler sunmak için önemli bir referans olabilecektir.

2. KAVRAMSAL ÇERÇEVE

2.1. KANAT PROFİLİ VE ETKİ EDEN AERODİNAMİK KUVVETLER

Hava araçlarının gövde ekseni doğrultusunda kesilmesiyle ortaya çıkan yanal kesite kanat profili (airfoil) denir. Kanat profilleri, genellikle Bernoulli prensibine göre tasarlanır. Bu prensibe göre, yüzeyin üst kısmından geçen havanın hızı arttıkça basıncı azalır ve alt yüzeydeki hava daha yüksek bir basınç oluşturur. İki zıt yüzeyde oluşan bu basınç farkı, kaldırma kuvveti gibi temel aerodinamik kuvvetlerin ortaya çıkmasına neden olur. Şekil 2.1'de kanat profili kesiti ve etrafındaki hava akışı görselleştirilmiştir.

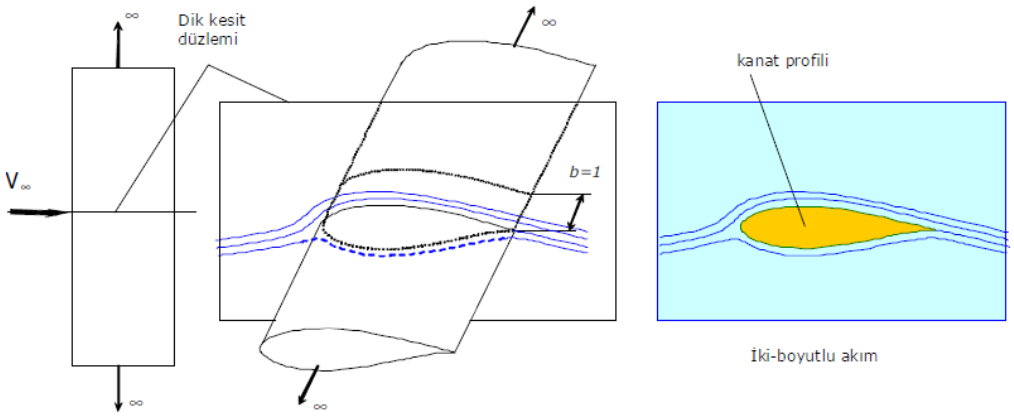

Şekil 2.1: Kanat Profili (Yükselen, 2024).

Kanat profilleri, hava araçlarının performansını doğrudan etkileyen temel yapısal bileşenler arasında yer alır. Bu profillerin geometrik özellikleri ve boyutları, hava akışıyla etkileşim sırasında oluşan aerodinamik kuvvetlerin dağılımını şekillendirir. Şekil 2.2'de temel kanat profili geometrisi paylaşılmıştır.

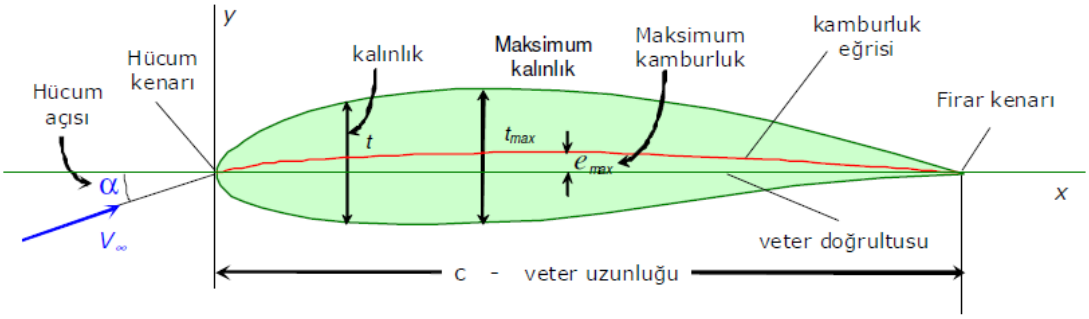

Şekil 2.2: Temel Kanat Profili Geometrisi (Yükselen, 2024).

Kanat profillerinde, uçuş doğrultusu ve akış yönüne göre en önde yer alan nokta hücum kenarı (leading edge) olarak adlandırılırken, en geride kalan nokta ise firar kenarı (trailing edge) olarak tanımlanır. Hücum kenarı, akışkanla ilk temas eden noktadır. Bu bölgenin tasarımı, akışın düzgün bir şekilde yönlendirilmesi ve türbülansın minimize edilmesi açısından kritik öneme sahiptir. Firar kenarı, kanat profilinin arka kısmında yer alır ve akışkanın kanadı terk ettiği noktadır. Firar kenarının aerodinamik tasarımı, hava akışının düzgün bir şekilde ayrılmasını ve minimum direnç oluşmasını sağlamaktadır.

Hücum ve firar kenarlarını birleştiren doğru, veter çizgisi (chord line) olarak adlandırılır. Bu çizginin uzunluğu ise veter uzunluğu (chord length) olarak tanımlanır ve kanat profili geometrisinin temel ölçütlerinden biridir.

Hücum açısı (Angle of Attack - α), aerodinamikte kanat profilinin veter çizgisi ile akış çizgileri arasında kalan açıyı ifade eder. Aynı zamanda, hareket doğrultusu ile serbest akım yönü arasındaki açı olarak da açıklanabilir. Hücum açısının büyüklüğü, kaldırma kuvveti üzerinde doğrudan etkili bir faktördür; bu açı arttıkça, kaldırma kuvveti de belirli bir noktaya kadar artış gösterir.

Kamburluk eğrisi (cambler line), kanat profilinin üst ve alt yüzeylerine eşit uzaklıkta bulunan hayali bir çizgidir. Bu eğri, kanat profilinin aerodinamik performansını etkileyen önemli bir unsurdur. Simetrik profillerde kamburluk eğrisi düz bir çizgi şeklindedir ve bu tür profiller genellikle simetrik kaldırma kuvveti sağlar.

Maksimum kamburluk, kanat profilinin üst ve alt yüzeyleri arasında bulunan kamburluk hattının en fazla eğriliğe sahip olduğu noktayı ifade eder. Bu nokta, genellikle profilin ön kısmına yakın bir bölgede yer alır ve aerodinamik performansı etkileyen kritik bir parametredir.

Kamburluğun büyüklüğü, profilin kaldırma kapasitesi üzerinde doğrudan bir etkiye sahiptir; yüksek kamburluk değerine sahip profiller genellikle daha yüksek kaldırma kuvveti üretir, ancak bu durum aynı zamanda direnç artışına da neden olabilir.

Maksimum kalınlık, kanat profilinin üst ve alt yüzeyleri arasındaki dikey mesafenin en büyük olduğu noktadaki kalınlık değeridir. Maksimum kalınlık noktası, kanat profilinin hücum kenarından itibaren ölçülen bir uzaklıkla ifade edilir ve bu noktanın yeri aerodinamik optimizasyon için büyük önem taşır.

Kanat tasarımında bu parametrelerin değişmesi ile, hava aracının aerodinamik davranışı ve performansı da değişmektedir. İstenilen çalışma koşullarında hedeflenen performansta çalışacak hava aracı tasarımı için ideal kanat profilinin tasarlanmasında, parametreler üzerinde değişiklikler gerçekleştirilerek etki eden aerodinamik kuvvetler analiz edilmektedir.

2.1.1. Kanat Profillerinin İsimlendirilmesi – NACA 4 Basamaklı İsimlendirme

NACA (National Advisory Committee for Aeronautics - Ulusal Havacılık Danışma Komitesi), kanat profillerini sistematik bir şekilde tanımlamak ve sınıflandırmak için geliştirilmiş bir isimlendirme sistemidir. Bu sistem, kanat profillerinin geometrik özelliklerini ve aerodinamik performansını özetleyen standart bir kodlama yöntemi sunmaktadır.

Kanat profilleri NACA dört basamaklı isimlendirme sistemine göre aşağıdaki gibi tanımlanmaktadır:

- İlk rakam maksimum kamburluk değerinin veterin yüzdesinin ifade etmektedir.
- İkinci rakam maksimum kamburluk konumu (veter uzunluğu üzerindeki konumu) ifade etmektedir.
- Son iki rakam kanadın maksimum kalınlığını veterin yüzdesi olarak ifade etmektedir.

Örneğin, "NACA 2412" kodu, maksimum kamburluğun veter uzunluğunun %2'si kadar olduğu, bu kamburluğun %40'ta konumlandığı ve maksimum kalınlık oranının %12 olduğu anlamına gelmektedir. Şekil 2.3’te NACA2412 için airfoil geometrisi değerlerine yer verilmiştir.

Max Camber (%)	2	First digit. 0 to 9.5%
Max camber position (%)	40	Second digit. 0 to 90%
Thickness (%)	12	Third & fourth digit. 1 to 40%

Şekil 2.3: NACA2412 Airfoil Geometrik Parametreleri.

Tez çalışması kapsamında üretilen kanat profilleri NACA sistemi ile isimlendirilmiştir.

2.1.2. Kanat Profiline Etki Eden Aerodinamik Kuvvetler

Kanat profiline etki eden aerodinamik kuvvetler, hava akışıyla profilin etkileşimi sonucu ortaya çıkan ve hava aracının uçuş performansını doğrudan etkileyen temel kuvvetlerdir. Kanat profiline taşıma (kaldırma) kuvveti, sürükleme kuvveti ve yunuslama momenti (moment kuvveti) etki eder ve kanat profilinin aerodinamik analizlerinde bu kuvvetler kullanılır. Kanat profili üzerindeki kuvvetler Şekil 2.3'te gösterilmiştir.

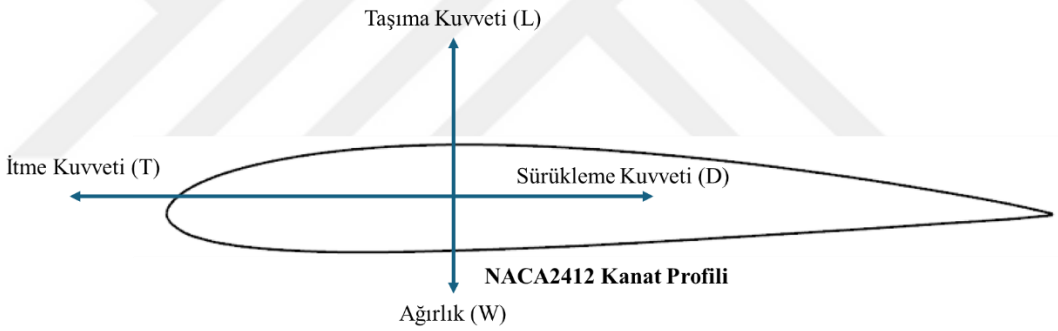

Şekil 2.4: Kanat Profili Üzerindeki Kuvvetler.

İtme kuvveti (thrust), uçağın motoru veya tahrik sistemi tarafından üretilen kuvvettir. Ağırlık kuvveti (weight), uçağın ağırlığından kaynaklı olarak yer çekimine doğru olan kuvvettir.

Taşıma kuvveti (lift), kanat profilinin hava akışı ile oluşturduğu basınç farkı sonucu ortaya çıkan ve genellikle dikey yönde (yer çekimine karşı) etkili olan kuvvettir. Bernoulli prensibine göre, kanadın üst yüzeyinden akan havanın hızı artar ve basıncı azalırken, alt yüzeyde daha düşük hızda bir akış ve daha yüksek bir basınç oluşur. Bu basınç farkı, kaldırma kuvvetinin meydana gelmesine neden olur. Bu kuvvet, hava aracının havada kalmasını sağlayan temel etkendir. Kanat profillerinin aerodinamik kuvvetlerinin analizinde boyutsuz katsayılar

kullanılmaktadır. Taşıma kat sayısı C_L ile gösterilmektedir. Taşıma katsayısının formülü (2.1)'de paylaşılmıştır.

$$C_L = \frac{\mathrm{L}}{(\frac{1}{2})\rho_\infty V_\infty^2 S} \tag{2.1}$$

Sürükleme kuvveti (drag), kanat profili ile hava arasındaki etkileşimden kaynaklanan ve hareket yönüne zıt yönde etkili olan kuvvettir. Hava akışının kanat profiline karşılık gösterdiği dirençten kaynaklanır. Sürükleme kuvveti, hava aracının enerji verimliliğini ve performansını doğrudan etkilemektedir. Sürükle katsayısı C_D ile gösterilmektedir. Sürükleme katsayısının formülü (2.2)'de paylaşılmıştır.

$$C_D = \frac{D}{(\frac{1}{2})\rho_\infty V_\infty^2 S} \tag{2.2}$$

Yunuslama momenti (moment kuvveti), kanat profilinin aerodinamik merkezinde meydana gelen ve profilin döndürülmesine neden olan kuvvettir. Bu kuvvet genellikle kaldırma kuvvetinin oluşturduğu dönme etkisinden kaynaklanır. Moment kuvveti, hava aracının denge ve kontrol performansı açısından önemlidir ve genellikle uçak tasarımında hesaplanması gereken kritik bir parametredir. Yunuslama katsayısı C_{My} ile gösterilmektedir. Moment katsayısının formülü (2.3)'te paylaşılmıştır.

$$C_{M_Y} = \frac{M_y}{(\frac{1}{2})\rho_\infty V_\infty^2 Sc} \tag{2.3}$$

Kanat profillerine etki eden aerodinamik kuvvetlerin hassas bir şekilde hesaplanması hem performans analizi hem de tasarım optimizasyonu için kritik bir öneme sahiptir. Bu kuvvetler, akış şartları (Mach sayısı, Reynolds sayısı ve hücum açısı gibi) ve kanat geometrisi parametreleri (maksimum kamburluk, kalınlık vb.) ile doğrudan ilişkilidir.

Kanat profillerinin aerodinamik yapısı akışın en az sürtünme ve en çok kaldırma kuvvetini oluşturacak şekilde tasarlanmalıdır. Literatürde yaygın olarak en ideal kanat profili geometrisinin karar verilmesinde kullanılan formül (2.4)'te paylaşılmıştır.

$$\text{En İdeal Kanat Profili} = \max\left({}^{C_L}/_{C_D}\right) \tag{2.4}$$

2.2. LİTERATÜR TARAMASI

Hava aracı yapısallarının, özellikle kanatların, aerodinamik davranışlarının analizinde Hesaplamalı Akışkanlar Dinamiği (HAD veya CFD) yaygın olarak kullanılmaktadır (Andrés-Pérez ve diğ. 2012; Yetkin ve diğ. 2024). Hava araçlarının tasarımında, HAD analizi ile aerodinamik kuvvetlerin hesaplanması rüzgar tüneli ve uçuş testlerine kıyasla zaman ve maliyet açısından avantajlar sağlamaktadır. Ancak; karmaşık geometrilerin ve ideal kanat profilinin belirlenmesi için gerçekleştirilen çok sayıda farklı parametre için gerçekleştirilen HAD simülasyonları, yüksek performanslı bilgisayarlar ile saatler sürebilmektedir. Bu sebeple, HAD araçlarının yerine makul doğrulukla tahmin yapabilecek vekil modellerin kullanılması giderek daha fazla dikkate alınmakta ve bu alanda çalışmalar artmaktadır (Andrés-Pérez ve Paulete-Periáñez, 2021).

Andrés-Pérez ve diğ. (2012), çalışmaları kapsamında kanat profillerinin aerodinamik tasarım süreçlerinde tasarım döngüsünü kısaltmak ve doğruluğu artırmak için, evrimsel programlama algoritması ile Destek Vektör Makinesi Regresyon (SVMr) algoritmasını birleştiren hibrit bir yaklaşımı önermektedir. Makaledeki çalışma ile HAD analizinin yerini alabilecek daha etkili bir tasarım metodu geliştirmesi amaçlanmıştır. Çalışma kapsamında, kanat profili üzerine etki eden aerodinamik kuvvetler, HAD analizlerini hızlandırmak amacıyla SVMr kullanılarak hızlı ve doğru bir şekilde tahmin edilmeye çalışılmıştır. 5000 farklı kanat profiliyle oluşturulan bir veri seti, yöntemlerin eğitim ve validasyonu için kullanılmıştır. 4000 kanat profili geometrisi eğitim, 1000 kanat profili geometrisi validasyon için kullanılmıştır. Önerilen yöntemin, XFOIL sonuçlarıyla büyük ölçüde uyumlu olduğu ve tasarım döngüsünü önemli ölçüde hızlandırdığı gösterilmiştir. Önerilen yöntem ile ideal kanat profili analizinin, HAD analizlerine kıyasla daha hızlı sonuçlar ürettiği gözlemlenmiştir. Yöntem, doğruluk ve hız açısından tatmin edici sonuçlar sağlamıştır. Makalede önerilen makine öğrenimi modeli SVMr'nin doğruluğu, eğitim veri setinin büyüklüğü ve kalitesine bağlıdır. Yüksek doğruluk istenen durumlarda, büyük veri setleri gerekmektedir. Çalışmada veri seti, sabit 0.3 Mach hız, 10^7 Reynold sayısı değerleri kullanılarak üretilmiştir. Hücum açısı 4°-14° arası değişmektedir. Sabit 0.3 Mach hız üzerinden model eğitilmesi çalışmanın kapsamını kısıtlamaktadır. Sübsonik hızda (ses hızının altındaki, 0-0.8 Mach sayısı arasında olan hızlar) aerodinamik kuvvetler daha

tutarlı olabilmekte, bu da modelin performansının yüksek olmasını sağlamaktadır. Dolayısıyla sonuçlar daha yüksek hız rejimlerinde geçerlilik göstermemiştir. Transonik hızlarda (yaklaşık olarak 0.8 – 1.2 Mach) hava araçlarına etkiyen aerodinamik kuvvetler farklılaşabilmekte, doğal olarak tahmini de zorlaşmaktadır. Ek olarak çalışmada tek bir makine öğrenimi modeli üzerinden ilerlenmiş, farklı makine öğrenimi modellerinin performansları karşılaştırılmamıştır.

Yondo ve diğ. (2018), gerçekleştirdikleri derleme çalışması ile uçak aerodinamiğinde kullanılan deney tasarımı ve yedek modeller üzerine kapsamlı bir inceleme sunarak, bu yöntemlerin yüksek maliyetli ve zaman alıcı CFD simülasyonlarına alternatif olabileceğini vurgulamaktadır. Yedek modelleme teknikleri arasında Kriging, co-Kriging, destek vektör makineleri (SVM), yapay sinir ağları (YSA) ve çok sadakatli modeller (multi-fidelity models) değerlendirilmiştir. Özellikle Kriging, destek vektör makineleri ve yapay sinir ağları gibi yedek modellerin doğruluk ve belirsizlik yönetimindeki etkisi ele alınmıştır. Ancak, çalışma yalnızca literatürdeki yöntemlerin bir özetini sunmuş, bu modellerin doğruluğunu artırmaya yönelik spesifik öneriler veya uygulama odaklı yenilikçi bir yaklaşım ortaya koymamıştır.

Moin ve diğ. (2021), makale kapsamında farklı kanat geometrilerinin aerodinamik katsayılarını değişen hücum açıları, Mach ve Reynolds sayılarında tahmin etmek için yapay sinir ağlarınınn (YSA) uygulanabilirliğini incelemişlerdir. NACA 4 ve 5 haneli seri kanat profilleri kullanılarak Javafoil'de oluşturulan veri setleri, farklı uçuş koşulları altında YSA modellerinin eğitimi için kullanılmıştır. Veri seti, NACA 4 haneli 560 kanat profili ve NACA 5 haneli 1120 kanat profilinden oluşmuş, her kanat profili için 315 farklı uçuş şartı (hücum açısı: -10° ila 10°, Mach sayısı: 0.1 ila 0.3, Reynold sayısı: $1x10^5$ ile $5x10^5$ arasında) için aerodinamik katsayıları içermiştir. Bu da toplamda NACA 4 haneli geometriler için 171.431 adet ve NACA 5 haneli geometriler için 283.244 adet verinin oluşmasına sebep olmuştur. Veri seti, eğitim, validasyon ve test veri setlerine sırasıyla %70, %15 ve %15 oranında ayrılmıştır. YSA modelleri, ReLU aktivasyon fonksiyonuyla dört katmanlı bir ağ mimarisine dayanmış ve eğitim ADAM optimizasyon algoritması ile gerçekleştirilmiştir. Sonuçlar, ağın az sayıda giriş verisiyle bile aerodinamik katsayıları yüksek doğrulukla tahmin edebildiğini göstermiştir. Ancak ağ, kırılım (stall: taşıma kuvvetinin ani olarak kaybedilmesi veya azalması) bölgelerinde doğruluk kaybı yaşamış ve özellikle sürükleme katsayısı (C_D) tahminlerinde hata oranları artmıştır. Bununla birlikte; çalışma kapsamında aerodinamik kuvvetlerin analizleri düşük Mach hızlarında (0.1-0.3) gerçekleştirilmiş olup, önerilen model transonik bölgeye yakın hızlar için bir çözüm sunmamaktadır.

Andrés-Pérez ve Paulete-Periáñez (2021), aerodinamik katsayıların (C_L ve C_D) tahmini için farklı vekil regresyon modellerinin performanslarını, NACA0012, RAE2822 ve DPW-W1 geometrileri üzerinde karşılaştırmaktadır. Çalışma kapsamında, NACA0012 ve RAE2822 kanat profilleri ile DPW-W1 kanadı için HAD simülasyonlarıyla oluşturulan veri setleri kullanılmıştır. Mach sayısı 0.1 ile 0.9, hücum açısı ise 0° ile 20° arasında değişen değerleri kapsamıştır. Çalışmada, destek vektör regresyonu (SVR), Çok Katmanlı Algılayıcılar (MLP), Kriging ve Ridge regresyon gibi 15 farklı regresyon modeli test edilmiştir. Sonuçlar, SVR modelinin yüksek doğruluk (R^2>0.98) ve düşük hata oranları (RMSE: 0.084) ile en iyi performansı gösterdiğini ortaya koymuştur. MLP modeli ise parametre optimizasyonundan sonra performansını önemli ölçüde artırmıştır. Bununla birlikte, çalışma yalnızca belirli geometriler üzerinden eğitim ve test gerçekleştirilmiş olup, aerodinamik tasarım sürecinde en ideal kanat profili tasarımının değerlendirilmesi için bir çözüm sunulmamıştır.

Yetkin ve diğ. (2024), aerodinamik katsayıların (C_L ve C_D) tahmini için farklı yapay zeka yöntemlerinin performansını değerlendirmeyi ve karşılaştırmayı amaçlamaktadır. Çalışma, NACA0012 ve RAE2822 kanat profilleri için HAD simülasyonlarıyla oluşturulan veri setinde makine öğrenimi, derin öğrenme ve yedek modeller kullanılarak gerçekleştirilmiştir. Kullanılan yöntemler arasında XGB, CatBoost, Bagging, Gradient Boosting, LightGBM, Random Forest gibi makine öğrenimi algoritmaları; Conv1D gibi derin öğrenme modelleri ve Gaussian Process Regression (GPR) yer almaktadır. CatBoost ve XGB modelleri, düşük hata oranları ve yüksek doğruluk değerleriyle en iyi performansı göstermiştir. CatBoost, hızlı eğitim süresi ve düşük hatalarıyla dikkat çekerken, Conv1D modelinin hiperparametre optimizasyonu sonucunda tatmin edici sonuçlar verdiği ancak uzun eğitim sürelerine ihtiyaç duyduğu belirtilmiştir. Çalışma kapsamında, sadece NACA0012 ve RAE2822 kanat profilleri üzerinden farklı makine öğrenimi modellerinin performansı değerlendirilmiş, aerodinamik tasarım sürecinde en ideal kanat profili tasarımının değerlendirilmesi için bir çözüm sunulmamıştır.

Wallach ve diğ. (2006), önerdikleri çalışma kapsamında nakliye uçakları ve kanat profillerinin aerodinamik katsayılarını tahmin etmek için yapay sinir ağları kullanılmıştır. Temel aerodinamik katsayılar, hücum açısı, Mach sayısı ve Reynolds sayısına bağlı olarak modellenmiştir. Çalışma kapsamında Çok Katmanlı Algılayıcı (MLP) mimarisi kullanılmış ve NACA23012 kanat profili üzerinden eğitim gerçekleştirilmiştir. Eğitim için $1x10^6$ ila $5x10^6$ Reynolds sayıları arasında ve 0.20-0.82 Mach sayısı aralığında 99 veri noktası kullanılmıştır. Sonuçlar, önerilen yöntemin düşük veri setleriyle bile tatmin edici bir doğruluk doğruluk değeri

sağladığı göstermiştir. Çalışma kapsamında, sadece NACA23012 kanat profilleri üzerinden YSA performansı incelenmiş, farklı kanat profili geometrileri aerodinamik kuvvetlerinin tahmini için bir çözüm sunulmamıştır.

Balla ve diğ. (2021), iki boyutlu kanat profilleri ve üç boyutlu kanatlar için aerodinamik katsayıların (C_L, C_D ve C_M) tahmini amacıyla çoklu çıktı üreten bir yapay sinir ağı (YSA) modeli geliştirmiştir. Önerilen YSA, mevcut yöntemlerden farklı olarak, kanat yüzeyinde belirlenen noktalardaki basıncı tahmin etmeye odaklanmaktadır. HAD simülasyonları ile üretilen veri seti, farklı geometriler ve akış koşulları altında modelin doğruluğunu test etmek için kullanılmıştır. Mach sayısı 0.3 ile 0.9, hücum açısı ise -5° ile 11° arasında değişen değerlerde analiz yapılmıştır. Çalışma ile önerilen çoklu çıktı modelinin, tekli çıktı üreten modellere ve Uygun Ortogonal Ayrıştırma (Proper Orthogonal Decomposition-POD) yöntemine kıyasla daha doğru tahminler sunduğu belirtilmiştir. YSA modelinin, özellikle sübsonik ve transonik rejimlerde, genelleme kapasitesi ve doğruluk açısından üstünlük sağladığı belirtilmiştir.

Ahmed ve diğ. (2022), çalışmalarında dört farklı NACA serisi kanat profili için HAD simülasyonları ile elde edilen veri setiyle Geri Yayılımlı Sinir Ağı (Backpropagation Neural Network-BPNN) eğitmişlerdir. Veri seti, %70 eğitim ve %30 test olarak kullanılmıştır. Model, Hataların Karesinin Ortalamasının Karekökü (Root Mean Square Error – RMSE) değeri 3.57×10^{-7} gibi oldukça düşük bir hata oranıyla yüksek doğruluk sağlamıştır. Çalışmada, 0.1 ile 0.3 Mach sayıları arasında ve Reynolds sayısı 10^6 ile 5×10^6 arasında değişen koşullarda test edilmiştir. Ayrıca, hücum açısı 0° ile 10° arasında değişen değerlerde değerlendirilmiştir. Ancak çalışma, yalnızca dört NACA kanat profiline ve sınırlı akış koşullarına odaklanmış olup, daha geniş bir parametrik aralığı kapsamamaktadır. Ek olarak, model yalnızca düşük Mach hızlarında (0.1-0.3) test edilmiş, transonik veya süpersonik akış koşulları gibi daha karmaşık rejimlerde doğrulama yapılmamıştır. Bu durum, yöntemin daha geniş kapsamlı aerodinamik problemler üzerindeki uygulanabilirliğini sınırlamaktadır.

Literatürde aerodinamik katsayı tahmini için kullanılan yapay zeka modelleri genellikle NACA0012, RAE2822, NACA23012 gibi sınırlı sayıda kanat geometrisi ve belirli akış koşullarında test edilmiş olup, eğitim ve test veri setleri arasında geometrik bağımsızlık sağlanmamıştır. Bu durum, modellerin yeni kanat geometrileri üzerindeki genelleme yeteneğini sınırlayabilmektedir. Ayrıca, çalışmalarda genellikle eğitim ve test veri setleri rastgele

bölünerek modellenmekte ve geniş parametrik çeşitlilik içeren veri setlerinin kullanımı oldukça sınırlı kalmaktadır.

Bu çalışmada, literatürdeki eksikliklere yanıt vermek üzere, veri seti NACA profillerine göre tamamen ayrılmıştır. Eğitim veri setinde kullanılan hiçbir kanat geometrisi test veri setinde yer almamakta ve aynı şekilde test veri setinde kullanılan kanat geometrileri eğitimde bulunmamaktadır. Bu yaklaşım, modelin gerçek mühendislik uygulamalarında genelleme performansını doğrudan değerlendirmek açısından önemli bir avantaj sağlamaktadır. Veri seti Reynolds sayısı 10^7 sabit tutularak, 0.3 ile 0.7 Mach aralığında ve 4° ile 14° arasındaki hücum açılarında kanat profillerinin aerodinamik davranışları (C_L, C_D ve C_M) açık kaynaklı XFOIL yazılımı ile analiz edilerek veri seti oluşturulmuştur.

Çalışmada Destek Vektör Makineleri (SVM), XGBoost, AdaBoost, Rassal Orman (Random Forest), Kara Ağacı (Decision Tree), Yapay Sinir Ağları (YSA) ve Evrişimsel Sinir Ağları (CNN) gibi çeşitli makine öğrenimi yöntemleri ile taşıma katsayısı (C_L), sürükleme katsayısı (C_D) ve moment katsayısı (C_M) için tahmin modelleri eğitilerek modellerin performansları değerlendirilmiştir. Önerilen yöntem, farklı kanat profili geometrileri ile farklı hız ve hücum açısı rejimlerinde genelleme kapasitesini test ederek, optimum kanat geometrisini belirleme konusunda literatürdeki çalışmalardan ayrışmaktadır. Ayrıca, bu yöntem hem geniş parametrik çeşitliliği hem de eğitim ve test veri setlerinin geometrik bağımsızlığı ile havacılık endüstrisinde daha güvenilir ve uygulanabilir bir çözüm sunmaktadır.

3. YÖNTEM

3.1. VERİ SETİNİN OLUŞTURULMASI

Kanat profili geometri geliştirilmesi için, veter uzunluğu sabit alınarak, farklı maksimum kamburluk, maksimum kamburluk pozisyonu ve maksimum kalınlık değerleri kullanılarak NACA (Ulusal Havacılık Danışma Komitesi - National Advisory Committee for Aeronautics) dosyaları python kodu ile XFOIL (Drela, 1989) programı kullanılarak oluşturulmuştur. Kanat profillerinin aerodinamik analizleri açık kaynak kodlu XFOIL programı ile gerçekleştirilmiştir.

Tez çalışması kapsamında model performanslarını literatürdeki çalışmalar ile değerlendirebilmek adına, Andrés-Pérez ve diğ. (2012) ve Yetkin ve diğ. (2024) çalışmalarında alındığı gibi, Reynolds sayısı sabit 10^7 alınmış ve hücum açısı 4° ve 14° arasında 1° artacak şekilde belirlenmiştir. Kanat profili geometrilerin farklı hızlarda aerodinamik kuvvetlerinin analiz edilmesi ve tahmin modelinin geliştirilebilmesi için Mach değeri 0.3 ve 0.7 arasında 0.1 artacak şekilde belirlenmiştir. Farklı kanat profilleri geometrileri üretebilmek amacıyla maksimum kamburluk (veterin yüzdesi) değeri 0 ile 5 arasında 1 artan, maksimum kamburluk konumu (%) 0 ile 50 arasında 10 artan ve kalınlık değeri (mm) 1 ile 40 arasında 3 artan şekilde belirlenerek kanat profilleri oluşturulmuş ve XFOIL yazılımı ile etki eden aerodinamik kuvvetleri belirlenmiştir. Kanat profilleri özelliklerini tanımlayarak, aerodinamik kuvvetlerin veri setinin oluşturulmasında kullanılan python kodu EK-1'de verilmiştir. Python kodu ile farklı kanat profili geometrileri için XFOIL yazılımı kullanılarak gerçekleştirilen aerodinamik kuvvetlerin analizine ait ekran görüntüsü Şekil 3.1'de paylaşılmıştır.

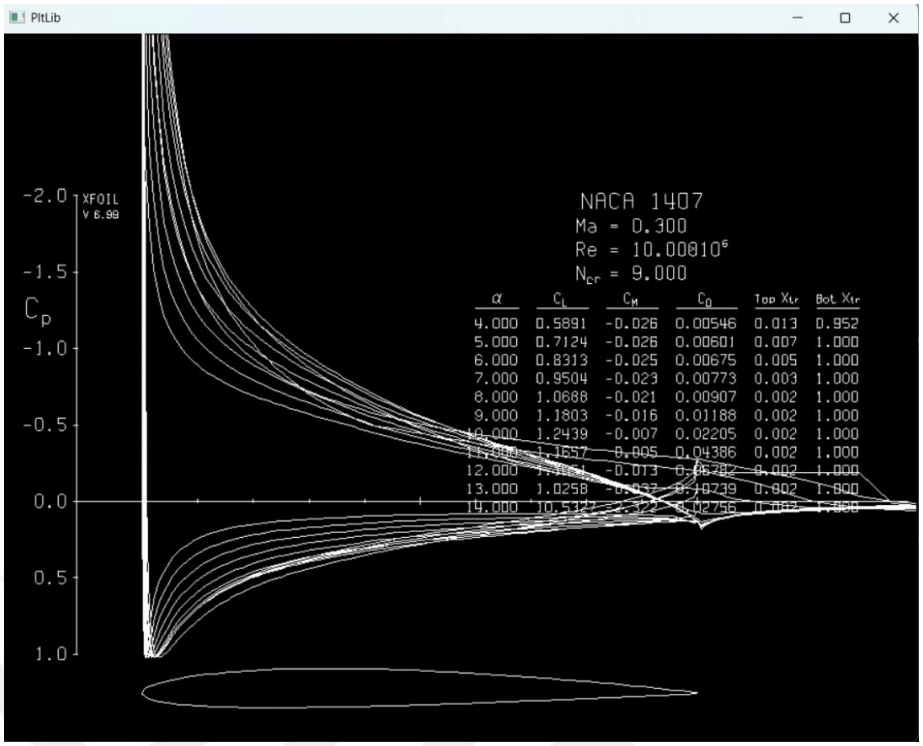

Şekil 3.1: XFOIL ile Kanat Profilleri Üzeri Etki Eden Aerodinamik Kuvvetlerin Analizi.

Oluşturulan veri setinde NACA geometrisi kodu, hücum açısı (α) değeri, taşıma katsayısı (C_L), sürükleme katsayısı (C_D), parazit sürükleme katsayısı (C_{Dp}) moment katsayısı (C_M), alt yüzey ve üst yüzey türbülans geçiş noktaları (Bot_Xtr ve Top_Xtr), maksimum kamburluk (veterin yüzdesi), maksimum kamburluk konumu (%), kalınlık (mm) ve Mach değerleri yazmaktadır.

Her bir satırda, farklı kanat geometrileri için tanımlanan uçuş koşullarında kanat profili üzerine etki eden taşıma katsayısı (C_L), sürükleme katsayısı (C_D), parazit sürükleme katsayısı (C_{Dp}) ve moment katsayısı (C_M) değerleri yazmaktadır. Şekil 3.2'de veri seti yapısı paylaşılmıştır.

	NACA	Alpha	CL	CD	CDp	CM	Top_Xtr	Bot_Xtr	Max Camber	Max Camber Position	Thickness	Mach
0	7	4.0	0.4703	0.00535	0.00140	0.0007	0.0113	0.8808	0.0	0.0	7.0	0.3
1	7	5.0	0.5855	0.00571	0.00196	0.0025	0.0065	0.9672	0.0	0.0	7.0	0.3
2	7	6.0	0.7110	0.00641	0.00271	0.0026	0.0045	0.9971	0.0	0.0	7.0	0.3
3	7	7.0	0.8340	0.00769	0.00417	0.0038	0.0030	1.0000	0.0	0.0	7.0	0.3
4	7	8.0	0.9533	0.00905	0.00569	0.0065	0.0026	1.0000	0.0	0.0	7.0	0.3
...	...	...	...	...	...	...	...	...	...	...	...	...
15103	5537	10.0	0.5913	0.09965	0.09634	0.0014	0.2397	0.3211	5.0	50.0	37.0	0.7
15104	5537	11.0	0.6444	0.11074	0.10751	0.0014	0.2285	0.3400	5.0	50.0	37.0	0.7
15105	5537	12.0	0.6975	0.12260	0.11947	0.0003	0.2175	0.3613	5.0	50.0	37.0	0.7
15106	5537	13.0	0.7451	0.13569	0.13266	-0.0018	0.2066	0.3852	5.0	50.0	37.0	0.7
15107	5537	14.0	0.7963	0.14955	0.14664	-0.0051	0.1961	0.4126	5.0	50.0	37.0	0.7

Şekil 3.2: Veri Seti Yapısı.

3.2. VERİ ÖN İŞLEME

Makine öğrenimi modellerinin doğruluğunu artırmak ve genelleme yeteneğini iyileştirmek amacıyla veri ön işleme süreci kritik bir aşamadır. Tez çalışması kapsamında veri seti özellikleri incelenmiş, makine öğrenimi modellerinin doğruluğunu artırmak, aşırı öğrenmeyi (overfitting) azaltmak ve eğitimi daha verimli hale getirmek için veri ön işleme gerçekleştirilmiştir. Veri analizi ve ön işleme çalışmaları Kaggle [1]üzerinden bulut ortamda gerçekleştirilmiştir.

3.2.1. Veri Setinin İncelenmesi

Veri setinde 363 adet NACA kanat profili için farklı uçuş koşullarında aerodinamik kuvvetlerin ve kanat profili parametrelerinin yer aldığı 15107 adet veri bulunmaktadır. Veri setinde farklı Mach hızlarına göre yer alan veri sayısı Tablo 3.1'de yer almaktadır.

Tablo 3.1: Veri Setinde Farklı Mach Değerlerine Göre Yer Alan Veri Sayısı.

Mach Değeri	Veri Sayısı
0.3	3741
0.4	3625
0.5	3408
0.6	2934
0.7	1400

[1] Kaggle, makine öğrenimi için çevrim içi olarak tümleşik geliştirme ortamı (IDE) sağlayan bir platformdur. https://www.kaggle.com/

Mach değeri arttıkça veri sayısında azalma görülmektedir. Bu azalmanın sebebi transonik hız bölgesine yaklaştıkça XFOIL programının hesaplama kapasitesinin yetersizliği ve kanat profillerinin bu alanlarda kırılıma uğramasıdır. Şekil 3.3'te yüksek Mach değerinde XFOIL ile kanat profiline etki eden aerodinamik kuvvetlerin analizinde oluşan bozulma ve hata görülmektedir. Oluşan bu bozulmalar HAD simülasyonlarında bir kısıt olup, aerodinamik kuvvetlerin tahminlemesinde makine öğrenimi modellerinin kullanım ihtiyacının artmasına sebep olmaktadır.

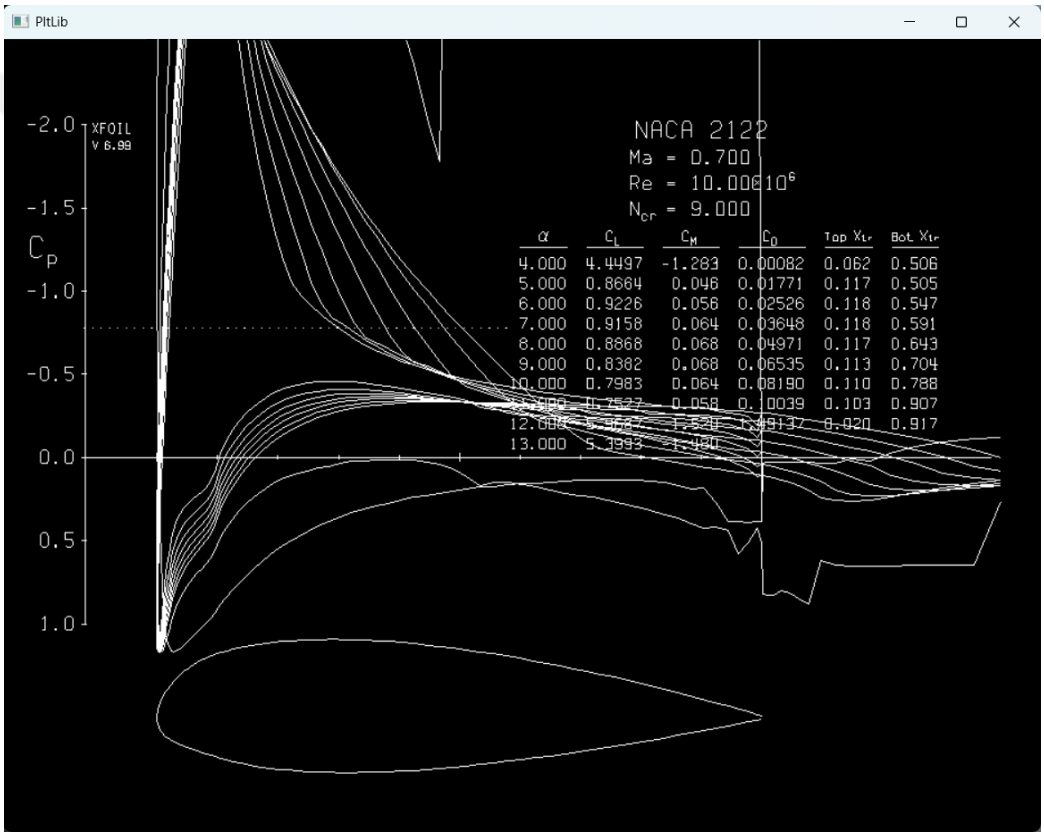

Şekil 3.3: NACA 2122 Kanat Profili Üzerine Etki Eden Aerodinamik Kuvvetlerin Analizi.

3.2.2. Veri Temizleme

Makine öğrenimi modellerinin doğruluğunu artırmak ve genelleme yeteneğini iyileştirmek amacıyla veri ön işleme süreci kritik bir aşamadır. Veri seti üzerinde gerçekleştirilen incelemede eksik veri bulunmadığı tespit edilmiştir. Hatalı ve aykırı verilerin temizlenmesi için C_L, C_D ve C_M değerlerinin dağılımı kutu grafiği yöntemi ile incelenmiştir. Kutu grafiği yöntemi, veri analizi sürecinde aykırı değer tespiti, dağılım analizi ve grup

karşılaştırmaları için etkili bir araçtır. Şekil 3.4'te C_L, C_D ve C_M'nin Mach değerlerine göre kutu grafi yöntemi ile görselleştirilmesi yer almaktadır.

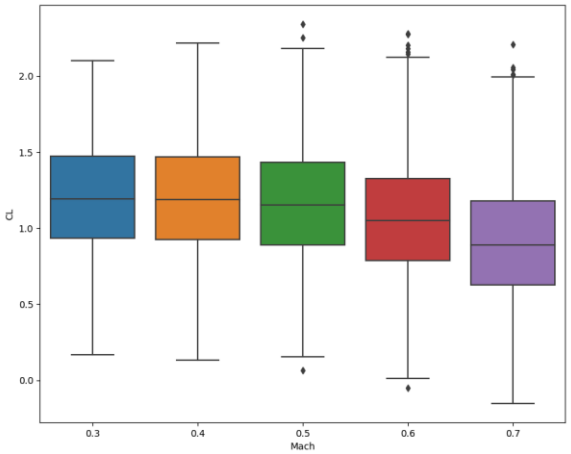

Şekil 3.4.a: C_L Kutu Grafiği

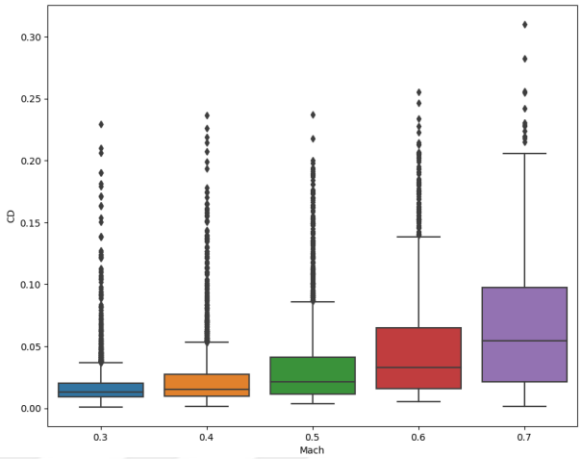

Şekil 3.4.b: C_D Kutu Grafiği

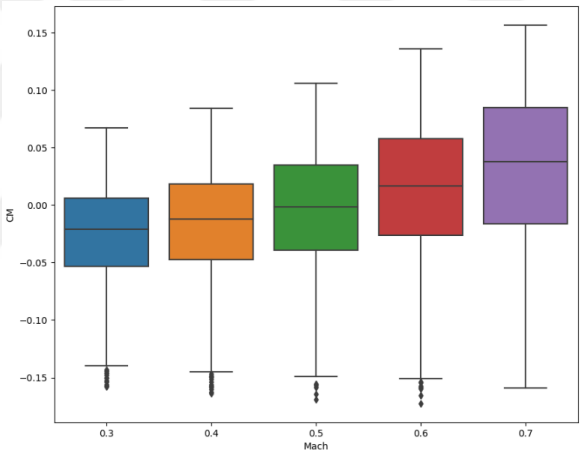

Şekil 3.4.c: C_M Kutu Grafiği

Şekil 3.4: C_L, C_D ve C_M'nin Mach Değerlerine Göre Kutu Grafi Yöntemi ile Analizi.

C_L değerlerinin düşük uçuş açısı (α) değerlerinde negatif olması beklenmemektedir. Veri setinde α değeri 6'dan küçük olan ölçüler için, eğer C_L 0'dan küçükse veri setinden temizlenmiştir. Temizle işlemi sırasında uçuş açısı 6'dan küçük 13 C_L değeri hatalı ölçüm olarak değerlendirilmiş ve veri setinden temizlenmiştir. Veri seti temizleme işleme sonrası 15097 satır veri kalmıştır.

3.2.3. Eğitim ve Test Veri Setinin Hazırlanması

Veri tabanlarının %80'i eğitim için kullanılmış ve kalan %20'si test için ayrılmıştır. Bu orana, Yetkin ve diğ. (2024) makalelerinde gerçekleştirdiği eğitim boyutu duyarlılık analizine

göre karar verilmiştir. Şekil 3.5'te Yetkin ve diğ. (2024) tarafından gerçekleştirilen farklı eğitim oranları için ortak mutlak hata değerleri (MAE) paylaşılmıştır. Eğitim veri seti oranı %80 olduğunda en düşük hata değeri elde edildiği, bundan sonra aşırı uyum nedeniyle hatanın arttığını görünmektedir.

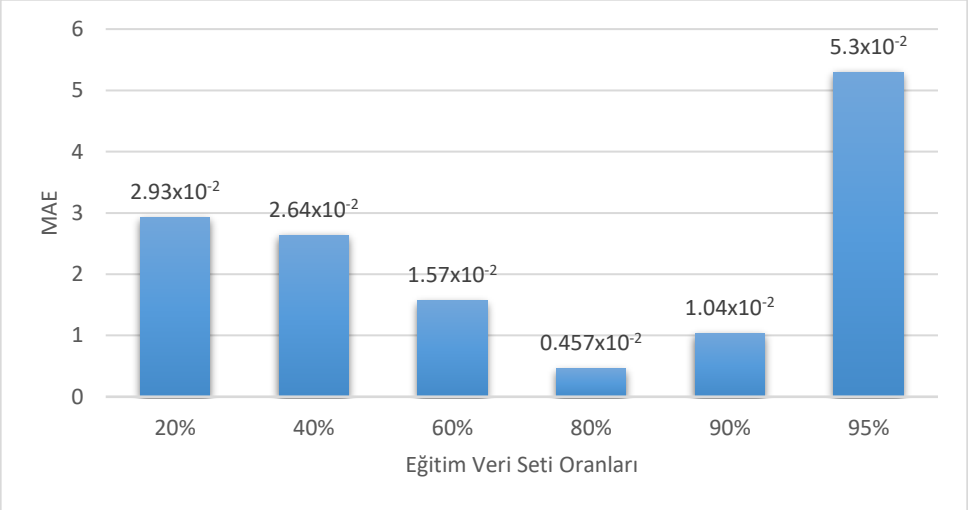

Şekil 3.5: Eğitim Veri Seti Oranlarına Göre Hata Değerleri (Yetkin ve diğ.,2024).

Eğitim ve test veri setinin ayrılması NACA kanat profili geometrilerine göre gerçekleştirilmiştir. Böylece model testi, eğitim veri setinde yer almayan farklı geometriler için gerçekleştirilmiş olacaktır. Bölünme rastgele olarak gerçekleştirilmiştir. Eğitim veri setinde 290, test veri setinde 73 NACA kanat profili geometrisi yer almaktadır. Eğitim veri setinde 290 kanat geometrisi için farklı uçuş koşullarında 11907 adet veri bulunmaktadır. Eğitim veri setinde 290 kanat geometrisi için farklı uçuş koşullarında 11907 adet veri bulunmaktadır. Test veri setinde 73 kanat geometrisi için farklı uçuş koşullarında 3189 adet veri bulunmaktadır.

3.2.4. Öznitelik Seçimi

Bu çalışmada, makine öğrenimi modellerinin aerodinamik kuvvetleri yüksek doğrulukla tahmin edebilmesi için öznitelik seçimi süreci titizlikle gerçekleştirilmiştir. Havacılık aerodinamiğinde kanat profilinin şekli ve uçuş koşulları, aerodinamik kuvvetler üzerinde doğrudan etkili olduğundan, literatür taraması ve mühendislik bilgisi doğrultusunda maksimum kamburluk (Max Camber), maksimum kamburluk maksimum kamburluk konumu (Max Camber Position), kalınlık (Thickness), hücum açısı (Alpha) ve uçuş hızı (Mach) değişkenleri öznitelik olarak belirlenmiştir. Bu değişkenler, kanat profilinin aerodinamik karakteristiklerini ve uçuş koşullarını temsil eden kritik parametrelerdir. Maksimum kamburluk ve maksimum

kamburluk konumu, kanat profilinin eğriliğini ve kaldırma üretme kapasitesini belirlerken; kalınlık, hava akışı üzerindeki basınç dağılımını ve sürükleme katsayısını doğrudan etkilemektedir. Ayrıca, hücum açısı ve Mach sayısı uçuş koşullarını belirlemektedir. Bu çalışmada, seçilen öznitelikler kullanılarak C_L, C_D ve C_M tahmin edilmiştir. Öznitelik seçim sürecinde, modelin genelleme yeteneğini artırmak ve hesaplama maliyetini optimize etmek amacıyla gereksiz veya yüksek korelasyonlu değişkenler analiz edilerek çıkarılmıştır. Bu yaklaşım ile, modelin yalnızca fiziksel olarak anlamlı ve aerodinamik açıdan etkili değişkenleri kullanarak tahmin yapması amaçlanmaktadır.

3.2.5. Veri Ölçekleme

Makine öğrenimi modellerinin doğruluğunu artırmak ve eğitim sürecini stabilize etmek amacıyla veri ölçekleme kritik bir ön işleme adımıdır. Bu çalışmada, farklı ölçeklendirme yöntemlerinin model performansına etkisini incelemek amacıyla hem Min-Max normalizasyonu hem de standart ölçeklendirme (Standard Scaler) uygulanmıştır. Min-Max normalizasyonu, veriyi belirli bir aralığa (genellikle [0,1]) indirerek değişkenler arasındaki ölçek farklılıklarını giderirken, standart ölçeklendirme (Z-score standardizasyonu), veriyi ortalaması 0 ve standart sapması 1 olacak şekilde dönüştürerek dağılımın normalize edilmesini sağlamaktadır. Özellikle, aerodinamik katsayıların geniş değer aralıklarına sahip olması nedeniyle, farklı ölçeklendirme yöntemleri kullanılarak modellerin doğruluk üzerindeki etkisi test edilmiş ve uygun ölçekleme yöntemi belirlenmiştir. Veri ölçekleme eğitim ve test veri setleri ayrıldıktan sonra eğitim veri seti referans alınarak gerçekleştirilmiştir. Makine öğrenimi modellerinin havacılık mühendisliği tasarım süreçlerine entegrasyonunu sağlamak ve modelin genelleme yeteneğini artırmak amacıyla veri ölçekleme işlemi, yalnızca eğitim veri seti baz alınarak gerçekleştirilmiştir. Uçak tasarım sürecinde, mühendislerin ve tasarımcıların yalnızca mevcut aerodinamik verilerden yola çıkarak yeni tasarımlar geliştirdiği ve tasarım aşamasında gelecekteki test verilerine erişimlerinin mümkün olmadığı göz önünde bulundurulmuştur. Bu doğrultuda, Min-Max normalizasyonu ve Z-score standardizasyonu (Standard Scaler) yalnızca eğitim veri setinin istatistiksel özelliklerine göre hesaplanmış ve aynı dönüşümler test veri setine uygulanmıştır. Böylece, geliştirilen modelin, yeni bir kanat profili veya farklı uçuş koşulları için tahmin yaparken, eğitim sırasında erişebildiği veriler üzerinden genelleme yapması sağlanmıştır. Bu yaklaşım, makine öğrenimi tabanlı tahminleme modellerinin havacılık tasarım süreçlerine entegrasyonunu güçlendirmekte ve mühendislerin karar verme mekanizmalarına katkı sağlamaktadır.

3.3. MAKİNE ÖĞRENİMİ MODELLERİNİN EĞİTİLMESİ

Tez çalışması kapsamında Destek Vektör Makineleri (SVM), XGBoost, AdaBoost, Rassal Orman (Random Forest), Kara Ağacı (Decision Tree), Yapay Sinir Ağları (YSA) ve Evrişimsel Sinir Ağları (CNN) ile farklı makine öğrenimi modelleri eğitilerek modellerin performansları karşılaştırmıştır. Modeller 2 farklı ölçekleme yöntemi ile eğitilerek, model performansları karşılaştırılmıştır. Yapay Sinir Ağları ile farklı katman sayısı, düğüm sayısı ve aktivasyon fonksiyonları kullanılarak modeller eğitilmiş, performansları değerlendirilmiştir. Çalışma kapsamında, Evrişimsel Sinir Ağlarının aerodinamik katsayıların tahminde performansının değerlendirmesi amacıyla C_L, C_D ve C_M için modeller eğitilmiştir. Tüm eğitilen modellerin performansları ile birlikte, eğitim süreleri karşılaştırılmıştır. Şekil 3.6'da tez çalışması kapsamında uygulanan yöntem ve akış yer almaktadır.

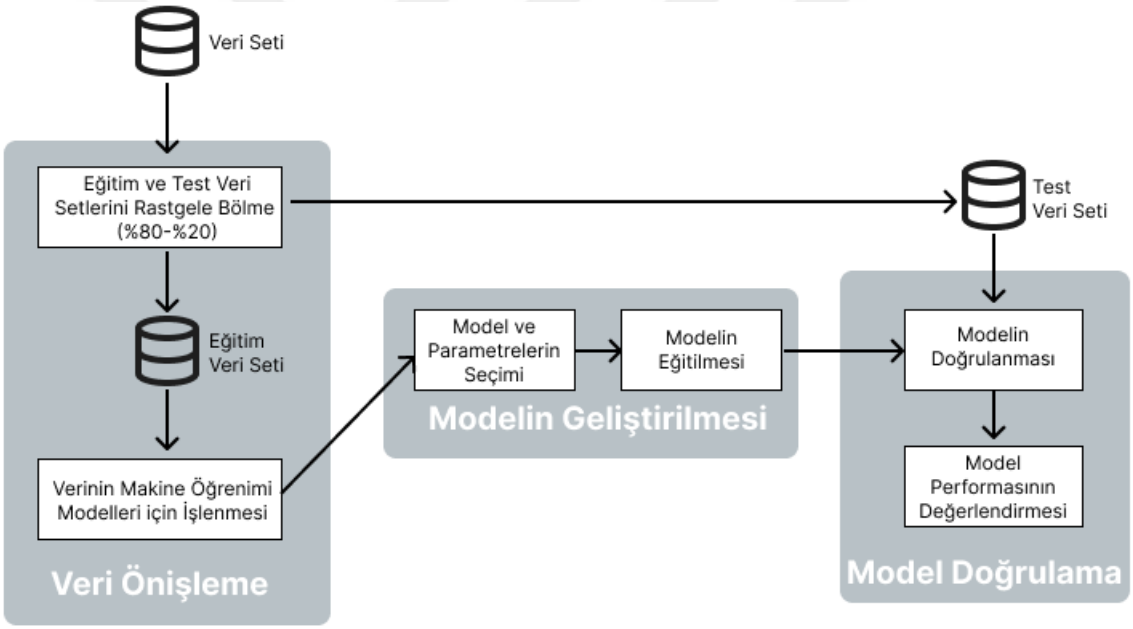

Şekil 3.6: Makine Öğrenimi Modellerinin Geliştirilmesi ve Performans Değerlendirme.

3.4. MODEL PERFORMANSLARININ DEĞERLENDİRİLMESİ

Tez çalışması kapsamında, geliştirilen makine öğrenimi modellerinin aerodinamik katsayıları tahmin etme başarısını değerlendirmek amacıyla çeşitli istatistiksel performans metrikleri kullanılmıştır. Model doğruluğunu, genelleme yeteneğini ve hata dağılımını kapsamlı bir şekilde analiz edebilmek için R^2 Skoru (R Squared Score), Açıklanan Varyans Skoru (Explained Variance Score - EVS), Ortalama Kare Hata (Mean Squared Error - MSE),

Ortalama Mutlak Hata (Mean Absolute Error - MAE) ve Maksimum Mutlak Hata (Maximum Absolute Error) metrikleri tercih edilmiştir.

R² Skoru, bağımsız değişkenlerin bağımlı değişken üzerindeki açıklayıcılık gücünü ölçen bir metriktir. R² skoru, modelin tahmin edilen değerlerinin gerçek değerlere olan yakınlığını gösterir ve 1'e yaklaşan değerler, modelin yüksek doğrulukla tahmin yaptığını ifade etmektedir. Negatif veya sıfıra yakın değerler, modelin yetersiz bir genelleme performansına sahip olduğunu göstermektedir. R^2 formülü (3.1)'de yer almaktadır.

$$R^2 = 1 - \sum_{i}^{n} \frac{\left(y_{i_{gerçek}} - y_{i_{tahmin}}\right)^2}{\left(y_{i_{gerçek}} - ortalama(y_{gerçek})\right)^2} \tag{3.1}$$

Açıklanan Varyans Skoru (EVS), modelin tahmin ettiği değerlerin gerçek verilerin varyansını ne kadar iyi açıkladığını test eder. R² değerinde olduğu gibi, 1 mümkün olan en iyi sonuçtur. Skorun 1'e yaklaşması, modelin verideki değişimleri büyük ölçüde doğru tahmin ettiğini gösterirken; sıfıra yakın olması, modelin tahminlerinin veri içindeki değişkenliği yeterince iyi açıklayamadığını göstermektedir. Açıklanan varyans skoru formülü (3.2)'de yer almaktadır.

$$EVS = 1 - \frac{1}{n}\sum_{i}^{n} \frac{Varyans\left(y_{i_{gerçek}} - y_{i_{tahmin}}\right)}{Varyans\left(y_{i_{gerçek}}\right)} \tag{3.2}$$

Ortalama Kare Hata (MSE), modelin tahmin edilen ve gerçek değerler arasındaki farkların karesinin ortalaması ile hesaplanmaktadır. Daha düşük MSE değerleri, modelin genel hata seviyesinin daha küçük olduğunu ve tahmin başarısının daha yüksek olduğunu ifade etmektedir. Ancak, hata değerlerinin karesinin alınması nedeniyle büyük hatalar diğerlerine göre daha fazla ağırlıklandırılmaktadır. Böylece MSE ile büyük hata değerlerinin etkisi takip edilebilmektedir. Ortalama kare hata formülü (3.3)'te yer almaktadır.

$$\text{MSE} = \frac{1}{n}\sum_{i}^{n} \left(y_{i_{gerçek}} - y_{i_{tahmin}}\right)^2 \tag{3.3}$$

Ortalama Mutlak Hata (MAE), modelin yaptığı tahminlerin gerçek değerler ile arasındaki farkın mutlak değerinin ortalamasıdır. Birim bazlı hata değerlendirmesi sağladığı için, modelin

tahminlerinin ne kadar tutarlı olduğunu belirlemek amacıyla kullanılmaktadır. Düşük değer, modelin tahmin performansının daha iyi olduğunu göstermektedir. Negatif değerli hataların model performans değerlendirmesin hataya sebep olmaması için çalışma kapsamında kullanılmıştır. Ortalama mutlak hata formülü (3.4)'te yer almaktadır.

$$\mathrm{MAE} = \frac{1}{n}\sum_{i}^{n}\left|y_{i_{gerçek}} - y_{i_{tahmin}}\right| \tag{3.4}$$

Maksimum Mutlak Hata (MaxAE), modelin yaptığı tahminlerdeki en büyük hata miktarını ölçmek amacıyla kullanılmıştır. Bu metrik, özellikle uç değerler (outlier) karşısında modelin dayanıklılığını değerlendirmek için kullanılmaktadır. Havacılık mühendisliğinde, bazı uçuş koşulları ve kanat profilleri için hataların minimize edilmesi kritik önem taşıdığından, maksimum mutlak hata metriği, modelin en kötü senaryodaki performansını analiz etmek için önemli bir kriterdir. Maksimum mutlak hata formülü (3.5)'te yer almaktadır.

$$\mathrm{MaxAE} = \max\left(\left|y_{i_{gerçek}} - y_{i_{tahmin}}\right|\right) \tag{3.5}$$

Model performans değerlendirmeleri, farklı makine öğrenimi algoritmalarının aerodinamik katsayıları tahmin etme başarısını karşılaştırmak ve en uygun yöntemi belirlemek amacıyla detaylı olarak analiz edilmiştir. Bu süreçte, modellerin genelleme yeteneğini artırmak amacıyla performans ölçümleri yalnızca test veri seti üzerinde gerçekleştirilmiştir. Böylece, modelin eğitim verisine aşırı uyum göstermesi durumundan kaçınılmış ve modelin tasarım süreçlerinde yeni kanat profilleri için sağladığı tahmin doğruluğu daha nesnel bir şekilde değerlendirilebilmiştir. Bu metrikler arasındaki karşılaştırmalar, makine öğrenimi tabanlı aerodinamik tahmin modellerinin doğruluk ve güvenilirliğini belirlemeye yönelik kapsamlı bir çerçeve sunmaktadır.

3.5. EN İDEAL KANAT PROFİLİNİN ANALİZİ

Bu çalışmada, en ideal kanat profili geometrisinin belirlenmesi amacıyla makine öğrenimi tabanlı aerodinamik katsayı tahmini sonuçları kullanılarak çok kriterli bir optimizasyon yaklaşımı geliştirilmiştir. Havacılık aerodinamiğinde, bir kanat profilinin verimliliği genellikle kaldırma ve sürükleme katsayılarının oranı (C_L/C_D) ile değerlendirilirken, moment katsayısı (C_M) da uçuş stabilitesi ve kontrol edilebilirlik açısından kritik bir parametre

olarak öne çıkmaktadır. Bu nedenle, en uygun kanat profili seçimi sürecinde yalnızca C_L/C_D oranı değil, aynı zamanda C_M değeri de dikkate alınarak çok kriterli bir değerlendirme yapılmıştır.

Önerilen yöntem, öncelikle eğitim veri seti ve makine öğrenimi modeli tarafından tahmin edilen aerodinamik katsayılar kullanılarak her kanat profili için C_L/C_D oranlarının hesaplanmasıyla başlamaktadır. Yüksek aerodinamik verimliliğe sahip bir kanat profili, kaldırma kuvvetinin maksimum, sürükleme kuvvetinin ise minimum olduğu durumlarda elde edilmektedir. Bu nedenle, her Mach sayısı ve hücum açısı için C_L/C_D değerleri hesaplanmış ve en yüksek ortalama değere sahip profiller belirlenmiştir. Ancak, bir kanat profili yalnızca yüksek C_L/C_D oranına sahip olduğu için ideal kabul edilemez; uçuş dinamikleri açısından kritik olan moment katsayısı da bu değerlendirmeye dahil edilmelidir.

Moment katsayısının değerlendirilmesi sırasında, kararlı bir uçuş için stabilite kriterleri dikkate alınmıştır. Düşük moment katsayısı veya hücum açısına bağlı olarak düzgün değişen bir C_M eğrisi, uçuş sırasında aşırı dengesizlik oluşturmayan profillerin belirlenmesini sağlamaktadır. Çok büyük negatif C_M değerleri, uçağın aşırı burun aşağı moment üretmesine neden olabilirken, yüksek pozitif C_M değerleri ise burun yukarı moment oluşturabilir, bu nedenle stabil bir uçuş sağlamak için ideal kanat profilinin C_M değeri sıfıra yakın veya düşük varyansa sahip olmalıdır.

Bu çalışmada, en uygun kanat profilinin belirlenmesi için hem aerodinamik verimliliği hem de stabiliteyi dikkate alan birçok kriterli değerlendirme metriği oluşturulmuştur. Bu amaçla, her profil için normalize edilmiş C_L/C_D oranı ve $|C_M|$ değeri hesaplanarak (3.6)'daki skor fonksiyonu kullanılmıştır.

$$\delta = \lambda_1 \times \left(\frac{C_L}{C_D}\right)_{normalize} - \lambda_2 \times |C_M|_{normalize} \tag{3.6}$$

Bu fonksiyon, kanat profilinin toplam skorunu ifade etmektedir. Burada, C_L/C_D normalizasyonu, tüm profiller içinde 0-1 aralığında ölçeklenmiş değerleri temsil ederken, $|C_M|$ normalizasyonu ise moment katsayısının stabilitesini değerlendirmek için kullanılmaktadır. Skor fonksiyonundaki λ_1 ve λ_2 katsayıları, aerodinamik verimlilik ile stabilite arasındaki önceliği belirlemek için ayarlanabilir. Eğer aerodinamik verimlilik ön planda tutulacaksa $\lambda_1>\lambda_2$, stabilite daha önemliyse $\lambda_2>\lambda_1$ seçilebilir. Dengeli bir değerlendirme için $\lambda_1=0.7$ ve $\lambda_2=0.3$ gibi

değerler önerilmektedir. Bu fonksiyon kullanılarak en yüksek skora sahip kanat profili, en ideal profil olarak belirlenmektedir.

Önerilen yöntemin uygulanması için öncelikle her kanat profili için C_L/C_D ve C_M değerleri hesaplanmakta, ardından bu değerler normalleştirilerek skor fonksiyonu ile çok kriterli değerlendirme yapılmaktadır. Bu süreç sonucunda hem aerodinamik olarak verimli hem de uçuş stabilitesi açısından optimum performans sağlayan kanat profili seçilmektedir. Çalışma kapsamında geliştirilen yöntem, yalnızca mevcut veri setindeki profiller arasında en iyi aerodinamik özelliklere sahip olanı belirlemekle kalmayıp, ilerleyen çalışmalarda kanat profili optimizasyonuna da temel oluşturabilecek bir karar mekanizması sağlamaktadır.

4. BULGULAR

Bu bölümde, eğitilen makine öğrenimi modellerinin aerodinamik katsayıları (C_L, C_D ve C_M) tahmin etme performansına ilişkin elde edilen sonuçlar sunulmaktadır. Çalışma kapsamında farklı makine öğrenimi algoritmaları kullanılarak eğitim ve test veri setleri üzerinde performans analizleri gerçekleştirilmiş, her modelin tahmin doğruluğu karşılaştırılmasında R^2 Skoru, Açıklanan Varyans Skoru (EVS), Ortalama Kare Hata (MSE), Ortalama Mutlak Hata (MAE) ve Maksimum Mutlak Hata (MaxAE) kullanılmıştır. C_L, C_D ve C_M için her bir makine öğrenimi algoritması ile 3 ayrı model eğitilmiştir. Her model Min-Max normalizasyonu ve Z-score standardizasyonu kullanılarak eğitilmiş ve model performansları karşılaştırılmıştır. Modellerin eğitim süreleri karşılaştırması gerçekleştirilmiştir. Ayrıca, farklı aerodinamik parametreler ve uçuş koşulları altında modellerin başarımı detaylı olarak incelenmiş ve hangi modelin daha yüksek doğruluk sağladığı belirlenmiştir.

Destek Vektör Makinesi Regresyonu, XGBoost, AdaBoost, Karar Ağacı (DT) ve Rassal Orman (RF) ile eğitilen C_L modellerin performansları, Min-Max normalizasyonu ve Z-score standardizasyonu ile eğitilen modeller için Tablo 4.1'de paylaşılmıştır.

Tablo 4.1: C_L Tahmin Modeli Performanslarının Karşılaştırılması.

	R^2		**EVS**		**MSE**		**MAE**		**MaxAE**	
	Z-score	**MinMax**	**Z-score**	**MinMax**	**Z-score**	**MinMax**	**Z-score**	**MinMax**	**Z-score**	**MinMax**
SVM	0.9655	0.9047	0.9656	0.9192	0.0053	0.0147	0.0434	0.0990	0.6375	0.5374
XGBoost	0.9675	0.9687	0.9676	0.9688	0.0050	0.0048	0.0410	0.04	0.6162	0.6153
AdaBoost	0.9665	0.9678	0.9667	0.9679	0.0052	0.0049	0.0417	0.0407	0.9075	0.9075
DT	0.9585	0.9597	0.9590	0.9601	0.0064	0.0062	0.0467	0.0458	0.9075	0.9075
RF	0.9691	0.9701	0.9697	0.9706	0.0047	0.0046	0.0431	0.0425	0.4863	0.4878

Destek Vektör Makinesi Regresyonu, XGBoost, AdaBoost, Karar Ağacı (DT) ve Rassal Orman (RF) ile eğitilen C_D modellerin performansları, Min-Max normalizasyonu ve Z-score standardizasyonu ile eğitilen modeller için Tablo 4.2'de paylaşılmıştır.

Tablo 4.2: CD Tahmin Modeli Performanslarının Karşılaştırılması.

	R^2		EVS		MSE		MAE		MaxAE	
	Z-score	**MinMax**	**Z-score**	**MinMax**	**Z-score**	**MinMax**	**Z-score**	**MinMax**	**Z-score**	**MinMax**
SVM	0.8863	0.7692	0.8869	0.7701	0.00013	0.00027	0.0991	0.0130	0.1686	0.1893
XGBoost	0.9366	0.9359	0.9366	0.9359	0.00007	0.00008	0.0400	0.0038	0.1399	0.1384
AdaBoost	0.9379	0.9359	0.9380	0.9366	0.00007	0.00008	0.0407	0.0033	0.2018	0.2018
DT	0.9280	0.9288	0.9283	0.9295	0.00008	0.00008	0.0458	0.0036	0.2018	0.2018
RF	0.9471	0.9448	0.9474	0.9453	0.00006	0.00007	0.0425	0.0033	0.1417	0.1417

Destek Vektör Makinesi Regresyonu, XGBoost, AdaBoost, Karar Ağacı (DT) ve Rassal Orman (RF) ile eğitilen C_M modellerin performansları, Min-Max normalizasyonu ve Z-score standardizasyonu ile eğitilen modeller için Tablo 4.3'te paylaşılmıştır.

Tablo 4.3: C_M Tahmin Modeli Performanslarının Karşılaştırılması.

	R^2		EVS		MSE		MAE		MaxAE	
	Z-score	**MinMax**	**Z-score**	**MinMax**	**Z-score**	**MinMax**	**Z-score**	**MinMax**	**Z-score**	**MinMax**
SVM	0.9638	0.8894	0.9638	0.8926	0.00010	0.00031	0.0139	0.0139	0.2079	0.1698
XGBoost	0.9768	0.9773	0.9768	0.9773	0.00006	0.00006	0.0044	0.0044	0.0885	0.0881
AdaBoost	0.9486	0.9486	0.9488	0.9487	0.00014	0.00014	0.0075	0.0075	0.2017	0.2017
DT	0.9365	0.9303	0.9370	0.9314	0.00018	0.00019	0.0089	0.0089	0.2017	0.2017
RF	0.9536	0.9509	0.9538	0.9513	0.00013	0.00014	0.0070	0.0070	0.1792	0.1792

Eğitilen modellerin, eğitim sürelerinin karşılaştırılması Tablo 4.4'te paylaşılmıştır. Tüm süreler saniye cinsindendir.

Tablo 4.4: Modellerin Eğitim Sürelerinin Karşılaştırılması.

	C_L		C_D		C_M	
	Z-score	**MinMax**	**Z-score**	**MinMax**	**Z-score**	**MinMax**
SVM	2.989	0.312	2.651	0.302	1.868	0.274
XGBoost	1.055	0.756	1.045	0.666	1.053	2.195
AdaBoost	2.910	2.914	2.800	2.801	2.793	2.714
DT	6.109	6.069	4.491	4.445	4.358	4.334
RF	3.010	3.003	7.830	7.875	4.497	4.426

Destek Vektör Makinesi Regresyonu, XGBoost, AdaBoost, Karar Ağacı (DT) ve Rassal Orman (RF) ile eğitilen modeller karşılaştırıldığında, C_L taşıma kuvveti katsayısı tahminlemede modellerin %95 (R^2 değeri referans alınmıştır) üzerinde başarım gösterdiği, maksimum mutlak

hata değeri de göz önünde bulundurulduğunda en başarılı tahminlemenin Rassal Orman (RF) ile geliştirilen model ile sağlandığı gözlemlenmektedir. SVM ile eğitlen modelde Z-score standardizasyonu ile eğitilen model daha başarılı olduğu, diğer makine öğrenimi algoritmalarında Min-Max normalizasyonu ile eğitilen tahminleme modellerinde ufak iyileşmeler olduğu gözlemlenmektedir. AdaBoost ve Karar Ağacı ile eğitilen modellerin R^2 ve EVS başarımları yüksek olsa da maksimum mutlak hata değerleri diğer modellere göre yüksek çıkmaktadır.

C_D sürükleme katsayısı tahminlemede, en başarılı tahminlemenin Rassal Orman (RF) ile geliştirilen model tarafından gerçekleştirildiği gözlemlenmektedir. Tahminleme %94,71 R^2 ve %94,48 EVS başarımı ile gerçekleştirilmiştir. Z-score standardizasyonu ile gerçekleştirilen modeller, genel olarak daha başarılı sonuç göstermiştir.

C_M moment katsayısı için geliştirilen modellerde, en başarılı performansı XGBoost ile eğitilen model gerçekleştirmiştir. Z-score standardizasyonu ile geliştirilen modelde %97,68 (R^2 değeri referans alınmıştır), Min-Max normalizasyonu ile geliştirilen modelde %97,63'lik bir tahminleme başarımı gösterilmiştir. Maksimum mutlak hata değeri 0.0881 olup, aykırı değerlerin tahminlemesinde de yüksek başarım elde edilmiştir.

Aerodinamik kuvvetlerin tahmin doğruluğunun iyileştirilmesi ve derin öğrenme modellerinin aerodinamik kuvvetlerin tahminlenmesinde kullanımının ve performansının değerlendirilmesi amacıyla, tez çalışması kapsamında Yapay Sinir Ağları ile farklı katman sayısı, düğüm sayısı ve aktivasyon fonksiyonları kullanılarak modeller eğitilmiş, performansları değerlendirilmiştir. Model eğitiminde 256-128-64-32-1, 128-64-32-1, 64-32-16-1, 16-8-4-1 ve 8-4-1 katman ve düğüm sayıları kullanılmıştır. Kayıp fonksiyonu olarak Ortalama Kare Hata (MSE), değerlendirme metriği olarak doğruluk (accuracy) ve optimizasyon için Adam optimizasyon algoritması kullanılmıştır. Aktivasyon fonksiyonu olarak giriş ve gizli katmanlarda "sigmoid", "ReLU" ve "tanh" fonksiyonları kullanılmış ve performansları karşılaştırılmıştır. Çıkış katmanında "linear" aktivasyon fonksiyonu kullanılmıştır. Her katman arasında aşırı öğrenmeyi engellemek amacıyla %20 oranında seyreltme katmanı kullanılmıştır. Modellerin eğitimde veri seti %15 validasyon için bölünmüş ve 100 iterasyon (epoch) ile gerçekleştirilmiştir. Model eğitiminde kaggle tarafından sunulan grafik işleme birimi (Graphics Processing Unit - GPU) GPU P100 kullanılmıştır. Tablo 4.5'te veri setinin Min-Max

normalizasyonu ile ölçeklendiği ve aktivasyon fonksiyonu sigmoid olarak eğitilen farklı katman ve düğüm sayısına sahip YSA modellerin performansları yer almaktadır.

Tablo 4.5: Farklı Katman ve Düğüm Sayılarına Sahip Min-Max Normalizasyonu ile Ölçeklendirilmiş, Sigmoid Aktivasyon Fonksiyonu ile Eğitilen YSA Modellerinin Performansları.

		R^2	EVS	MSE	MAE	MaxAE	Süre(sn)
Giriş Katmanı: 256 **Gizli Katman:** 128-64-32 **Çıkış Katmanı:** 1 **Aktiv Fonk.:** Sigmoid **Veri Ölçekleme:** Min-Max	C_L	0.9804	0.9804	0.0030	0.0329	0.6179	376.55
	C_D	0.9513	0.9530	0.00006	0.0034	0.1315	376.90
	C_M	0.9818	0.9825	0.00005	0.0039	0.1315	375.75
Giriş Katmanı: 128 **Gizli Katman:** 64-32 **Çıkış Katmanı:** 1 **Aktiv Fonk.:** Sigmoid **Veri Ölçekleme:** Min-Max	C_L	0.9670	0.9670	0.0051	0.0444	0.5858	342.742
	C_D	0.9189	0.9190	0.00010	0.0039	0.1683	344.406
	C_M	0.9769	0.9769	0.00006	0.0043	0.1293	343.844
Giriş Katmanı: 64 **Gizli Katman:** 32-16 **Çıkış Katmanı:** 1 **Aktiv Fonk.:** Sigmoid **Veri Ölçekleme:** Min-Max	C_L	0.9382	0.9387	0.0095	0.0610	0.6844	347.45
	C_D	0.9076	0.9120	0.00011	0.0051	0.1188	347.83
	C_M	0.9631	0.9632	0.00010	0.0059	0.1113	346.56
Giriş Katmanı: 32 **Gizli Katman:** 16-8 **Çıkış Katmanı:** 1 **Aktiv Fonk.:** Sigmoid **Veri Ölçekleme:** Min-Max	C_L	0.8857	0.8896	0.0176	0.0903	0.7217	346.94
	C_D	0.8936	0.8949	0.0001	0.0054	0.1580	345.66
	C_M	0.9398	0.9398	0.0002	0.0076	0.0968	347.10
Giriş Katmanı: 16 **Gizli Katman:** 8-4 **Çıkış Katmanı:** 1 **Aktiv Fonk.:** Sigmoid **Veri Ölçekleme:** Min-Max	C_L	0.6494	0.6495	0.0539	0.1703	1.1348	345.35
	C_D	0.8621	0.8656	0.0002	0.0063	0.1222	345.62
	C_M	0.9105	0.9109	0.0002	0.0099	0.1134	344.92
Giriş Katmanı: 8 **Gizli Katman:** 4 **Çıkış Katmanı:** 1 **Aktiv Fonk.:** Sigmoid **Veri Ölçekleme:** Min-Max	C_L	0.6998	0.7023	0.0462	0.1553	0.9221	319.70
	C_D	0.8525	0.8525	0.0002	0.0063	0.1240	320.25
	C_M	0.9151	0.9152	0.0002	0.0099	0.1157	319.36

En başarılı tahmin performansın giriş katmanında 256 düğüm, 3 gizli katmanda sırasıyla 128,64 ve 32 düğüm olan model tarafından gerçekleştirildiği gözlemlenmektedir. Katman ve düğüm sayıları azaldıkça model performansının düştüğü görülmektedir. Ancak katman ve düğüm sayısının artması ile eğitim süreleri uzamaktadır. Şekil 4.1'de en başarılı modele ait eğitim ve validasyon kayıp değerlerinin karşılaştırıldığı grafik yer almaktadır. İterasyon (epoch) sayısı arttıkça kayıp fonksiyonu değerinin azaldığı, 100. iterasyona yaklaşıldıkça eğitim ve validasyon kayıplarının 0'a yaklaştığı ve yatay seyrettiği görülmektedir.

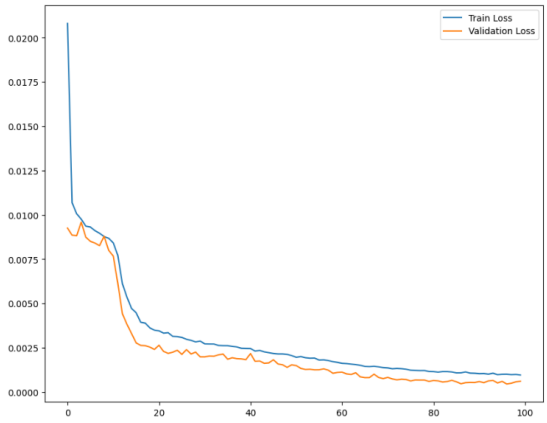

Şekil 4.1: Eğitim ve Validasyon Kayıp Fonksiyonu Grafiği.

Tablo 4.6'da veri setinin Z-score standardizasyonu ile ölçeklendiği ve aktivasyon fonksiyonu sigmoid olarak eğitilen farklı katman ve düğüm sayısına sahip YSA modellerin performansları yer almaktadır.

Tablo 4.6: Farklı Katman ve Düğüm Sayılarına Sahip Z-score Standardizasyonu ile Ölçeklendirilmiş, Sigmoid Aktivasyon Fonksiyonu ile Eğitilen YSA Modellerinin Performansları.

		R^2	EVS	MSE	MAE	MaxAE	Süre(sn)
Giriş Katmanı: 256 **Gizli Katman:** 128-64-32 **Çıkış Katmanı:** 1 **Aktiv Fonk.:** Sigmoid **Veri Ölçekleme:** Z-score	C_L	0.9876	0.9886	0.0019	0.0264	0.5465	375.38
	C_D	0.9504	0.9504	0.0001	0.0025	0.1731	372.84
	C_M	0.9800	0.9801	0.0001	0.0036	0.1469	374.98
Giriş Katmanı: 128 **Gizli Katman:** 64-32 **Çıkış Katmanı:** 1 **Aktiv Fonk.:** Sigmoid **Veri Ölçekleme:** Z-score	C_L	0.9863	0.9865	0.0021	0.0273	0.5285	241.80
	C_D	0.9513	0.9514	0.0001	0.0028	0.1628	273.79
	C_M	0.9771	0.9772	0.0001	0.0036	0.1587	249.29
Giriş Katmanı: 64 **Gizli Katman:** 32-16 **Çıkış Katmanı:** 1 **Aktiv Fonk.:** Sigmoid **Veri Ölçekleme:** Z-score	C_L	0.9734	0.9738	0.0041	0.0395	0.5507	348.56
	C_D	0.9407	0.9411	0.0001	0.0039	0.1666	347.85
	C_M	0.9721	0.9723	0.0001	0.0045	0.1426	348.43
Giriş Katmanı: 32 **Gizli Katman:** 16-8 **Çıkış Katmanı:** 1 **Aktiv Fonk.:** Sigmoid **Veri Ölçekleme:** Z-score	C_L	0.9498	0.9514	0.0077	0.0539	0.5850	349.389
	C_D	0.9138	0.9169	0.0001	0.0047	0.1163	347.133
	C_M	0.9575	0.9575	0.0001	0.0063	0.1139	348.197
Giriş Katmanı: 16 **Gizli Katman:** 8-4 **Çıkış Katmanı:** 1 **Aktiv Fonk.:** Sigmoid **Veri Ölçekleme:** Z-score	C_L	0.9250	0.9272	0.0115	0.0702	0.6636	347.882
	C_D	0.8577	0.8622	0.0002	0.0066	0.1191	348.081
	C_M	0.9273	0.9273	0.0002	0.0088	0.1116	346.962
Giriş Katmanı: 8 **Gizli Katman:** 4 **Çıkış Katmanı:** 1 **Aktiv Fonk.:** Sigmoid **Veri Ölçekleme:** Z-score	C_L	0.8155	0.8163	0.0284	0.1105	1.0339	322.295
	C_D	0.8614	0.8626	0.0002	0.0063	0.1226	320.603
	C_M	0.9151	0.9152	0.0002	0.0099	0.1157	322.480

Veri setinin Z-score standardizasyonu ile ölçeklendirilmesi ile eğitilen modellerin performanslarının genel olarak iyileştiği gözlemlenmiştir. En başarılı model C_L için %98,76 R^2 ile giriş katmanında 256 düğüm, 3 gizli katmanda sırasıyla 128, 64 ve 32 düğüm olan model tarafından gerçekleştirildiği gözlemlenmektedir. 128 düğümlü giriş katmana ve 64 ve 32 düğümlü gizli katmana sahip model ise %98,63 R^2 skoru ile yakın ve başarılı bir tahminleme gerçekleştirmiştir. C_D için en başarılı model %95,13 R^2 skoru ile giriş katmanında 128 düğüm, 2 gizli katmanda sırasıyla 64 ve 32 düğüm olan model tarafından gerçekleştirildiği gözlemlenmektedir. C_M için en başarılı model %98 R^2 skoruna sahip giriş katmanında 256 düğüm, 3 gizli katmanda sırasıyla 128, 64 ve 32 düğüm olan model tarafından gerçekleştirildiği gözlemlenmektedir. Model performans değerlendirmesinde 256-128-64-32-1 düğüm sayılarına sahip 3 gizli katmanlı model başarılı bir sonuç göstermiştir. Ancak en uzun eğitim süresine sahip modeldir. Şekil 4.2'de 256-128-64-32-1 düğüm sayılarına sahip 3 gizli katmanlı modele ait her bir iterasyondaki eğitim ve validasyon kayıp fonksiyonu grafiği gösterilmektedir.

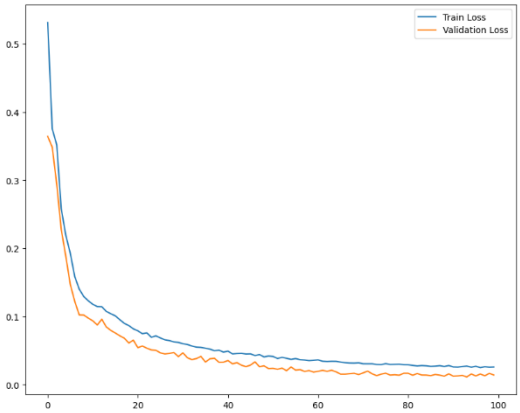

Şekil 4.2.a: C_L Eğitim ve Validasyon Kayıp Grafiği.

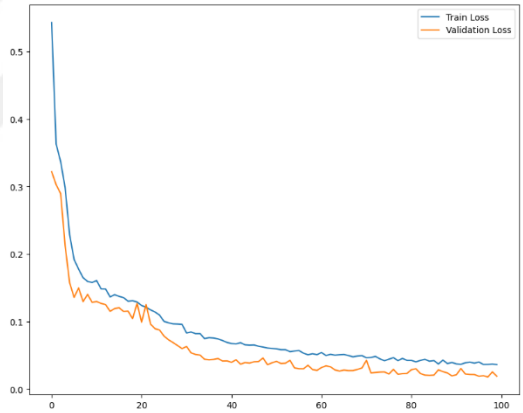

Şekil 4.2.b: C_D Eğitim ve Validasyon Kayıp Grafiği.

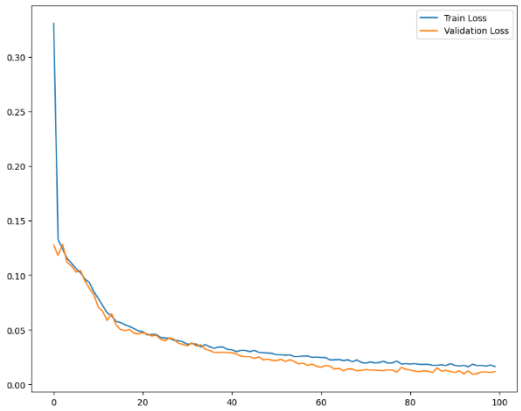

Şekil 4.2.c: C_D Eğitim ve Validasyon Kayıp Grafiği.

Şekil 4.2: 256-128-64-32-1 Düğüm Sayılarına Sahip Model için Eğitim ve Validasyon Kayıp (Loss) Grafiği.

128-64-32-1 düğüm sayılarına sahip 2 gizli katmanlı model, tahminleme performansı olarak çok yakın bir başarım göstermekle birlikte C_L, C_D ve C_M için geliştirilen ayrı modellerin her birinde ortalama %30-35 daha hızlı eğitim süresine sahiptir. Şekil 4.3'te 256-128-64-32-1 düğüm sayılarına sahip 3 gizli katmanlı modele ait her bir iterasyondaki eğitim ve validasyon kayıp fonksiyonu grafiği gösterilmektedir.

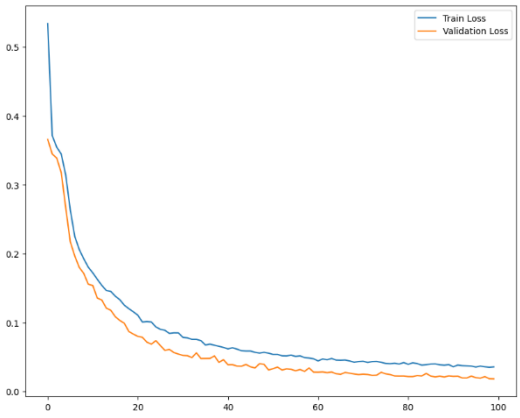

Şekil 4.3.a: C_L Eğitim ve Validasyon Kayıp Grafiği.

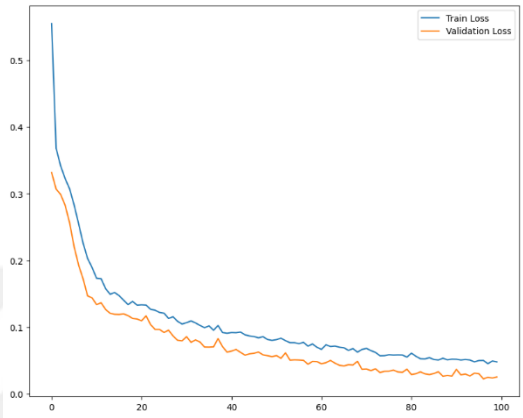

Şekil 4.3.b: C_D Eğitim ve Validasyon Kayıp Grafiği.

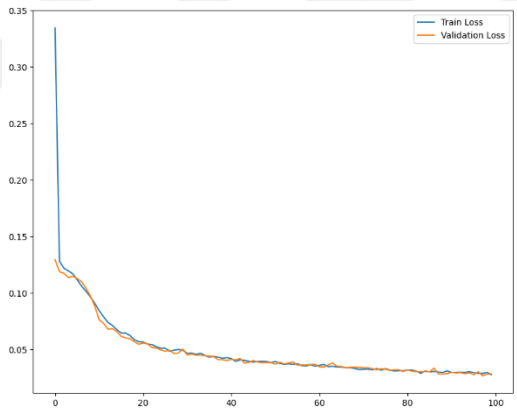

Şekil 4.3.c: C_D Eğitim ve Validasyon Kayıp Grafiği.

Şekil 4.3: 128-64-32-1 Düğüm Sayılarına Sahip Model için Eğitim ve Validasyon Kayıp (Loss) Grafiği.

"ReLU" ve "Tanh" aktivasyon fonksiyonların performansları hızlı eğitim süresi ve yüksek başarım değerleri sebebiyle 2 gizli katmanlı 128-64-32-1 düğüm sayılarına sahip model ile eğitilerek karşılaştırılacaktır. Tablo 4.7'de "Sigmoid", "ReLU" ve "Tanh" aktivasyon fonksiyonları ile eğitilen modellerin performansları yer almaktadır.

Tablo 4.7: Farklı Aktivasyon Fonksiyonları için Performans Karşılaştırması.

		R^2	EVS	MSE	MAE	MaxAE	Süre(sn)
Giriş Katmanı: 256 **Gizli Katman:** 128-64-32 **Çıkış Katmanı:** 1 **Aktiv Fonk.:** Sigmoid **Veri Ölçekleme:** Z-score	C_L	0.9876	0.9886	0.0019	0.0264	0.5465	375.38
	C_D	0.9504	0.9504	0.0001	0.0025	0.1731	372.84
	C_M	0.9800	0.9801	0.0001	0.0036	0.1469	374.98
Giriş Katmanı: 128 **Gizli Katman:** 64-32 **Çıkış Katmanı:** 1 **Aktiv Fonk.:** Sigmoid **Veri Ölçekleme:** Z-score	C_L	0.9863	0.9865	0.0021	0.0273	0.5285	241.80
	C_D	0.9513	0.9514	0.0001	0.0028	0.1628	273.79
	C_M	0.9771	0.9772	0.0001	0.0036	0.1587	249.29
Giriş Katmanı: 128 **Gizli Katman:** 64-32 **Çıkış Katmanı:** 1 **Aktiv Fonk.:** Tanh **Veri Ölçekleme:** Z-score	C_L	0.9792	0.9792	0.0031	0.0371	0.6218	192.47
	C_D	0.9643	0.9659	0.00004	0.0031	0.1444	192.62
	C_M	0.9788	0.9792	0.00006	0.0044	0.1404	191.47
Giriş Katmanı: 128 **Gizli Katman:** 64-32 **Çıkış Katmanı:** 1 **Aktiv Fonk.:** ReLU **Veri Ölçekleme:** Z-score	C_L	0.9744	0.9797	0.0039	0.0444	0.3465	200.16
	C_D	0.9633	0.9633	0.00004	0.0027	0.1859	197.27
	C_M	0.9811	0.9811	0.00005	0.0048	0.1435	204.64

"Tanh" ve "ReLU" aktivasyon fonksiyonu ile eğitilen modellerde eğitim sürelerinin daha hızlı olduğu gözlemlenmiştir. C_L modeli için en başarılı sonuç sigmoid aktivasyon fonksiyonu ile eğitilen modellere aittir. C_D ve C_M modelleri için en başarılı sonuç ReLU aktivasyon fonksiyonu ile eğitilen modeller ile elde edilmiştir.

Evrişimsel sinir ağlarının (CNN) performansını değerlendirmek için sigmoid, tanh ve ReLU aktivasyon fonksiyonları ile C_L, C_D ve C_M için 1 boyutlu evrişimli sinir ağı tabanlı model geliştirilmiş ve performansları karşılaştırılmıştır. Modelin giriş katmanı, eğitim veri setinin boyutuna uygun olarak 32 filtre ve 2 adım sayısı ile 1 boyutlu CNN (Conv1D) kullanılarak oluşturulmuştur. 1 boyutlu evrişim katmanı (Conv1D)**,** giriş verisinin uzaysal ilişkilerini öğrenerek önemli öznitelikleri çıkarır ve modelin temel öğrenme mekanizmasını oluşturur. Evrişim katmanında çıkarılan uzaysal öznitelikler, tam bağlı (Fully Connected) katmanlara aktarılabilmesi için Flatten() katmanı ile tek boyutlu bir vektöre dönüştürülmüştür. Modelin öğrenme kapasitesini artırmak amacıyla 128, 64 ve 32 nörona sahip üç adet tam bağlı katman eklenmiştir. Bu katmanlar, evrişim katmanı tarafından çıkarılan yüksek seviyeli özellikleri işleyerek modelin tahmin performansını iyileştirmektedir. Tahmin edilecek aerodinamik kuvvetlerin sürekli bir değer aralığında olması nedeniyle, çıkış katmanı 1 nöronlu tam bağlı bir yapı ile oluşturulmuştur. Bu katmanda aktivasyon fonksiyonu olarak doğrusal (linear)

aktivasyon tercih edilmiştir. Tablo 4.8'de evrişimsel sinir ağları ile eğitilen modellerin performansları yer almaktadır.

Tablo 4.8: Evrişimsel Sinir Ağları ile Eğitilen Modellerin Performansları.

		R^2	EVS	MSE	MAE	MaxAE	Süre(sn)
CNN **Aktiv Fonk.:** Sigmoid **Veri Ölçekleme:** Z-score	C_L	0.9876	0.9877	0.0019	0.0261	0.529474	394.43
	C_D	0.9522	0.9534	0.0000	0.0031	0.164521	372.84
	C_M	0.9855	0.9858	0.00004	0.0031	0.147382	374.98
CNN **Aktiv Fonk.:** Tanh **Veri Ölçekleme:** Z-score	C_L	0.9791	0.9791	0.0032	0.0374	0.5182	391.24
	C_D	0.9455	0.9460	0.00006	0.0032	0.1644	394.01
	C_M	0.9738	0.974	0.00007	0.0046	0.1360	394.88
CNN **Aktiv Fonk.:** Relu **Veri Ölçekleme:** Z-score	C_L	0.9742	0.9799	0.0040	0.0471	0.4777	363.89
	C_D	0.9713	0.9716	0.00003	0.0028	0.1392	391.33
	C_M	0.9679	0.9723	0.00009	0.0064	0.1491	394.35

Evrişimsel sinir ağları (CNN), C_L ve C_M için sigmoid aktivasyon fonksiyonu, C_D için modellerde ReLU aktivasyon fonksiyonunun kullanılarak geliştirilen modellerde yüksek doğruluk elde etmiştir. Ancak eğitim süreleri diğer modellere göre nispeten daha uzun olmaktadır.

5. TARTIŞMA

Tez çalışması kapsamında, hava aracı kanat profillerinin aerodinamik katsayılarının tahmini için farklı makine öğrenimi modelleri eğitilmiş ve performansları karşılaştırılmıştır. Destek Vektör Makineleri (SVM), XGBoost, AdaBoost, Karar Ağacı (DT), Rassal Orman (RF), Yapay Sinir Ağları (YSA) ve Evrişimsel Sinir Ağları (CNN) kullanılarak geliştirilen modellerin doğrulukları incelenmiş, eğitim süreleri karşılaştırılmış ve öznitelik ölçekleme yöntemlerinin model başarımına etkisi değerlendirilmiştir. Çalışmada kullanılan veri seti, XFOIL yazılımı ile hesaplanmış aerodinamik katsayılar olup, test veri seti eğitimde kullanılan profillerden bağımsız olarak oluşturulmuştur. Bu yaklaşım, modelin gerçek tasarım süreçlerinde daha önce karşılaşmadığı kanat profilleri için tahmin yapma kabiliyetini değerlendirmeye olanak tanımıştır.

Model performansı analiz edildiğinde, CNN ve YSA modellerinin yüksek doğruluk sağladığı ancak eğitim süresinin klasik makine öğrenimi modellerine kıyasla daha uzun olduğu tespit edilmiştir. Bu bulgular, literatürde Guo ve diğ. (2016) ve Yetkin ve diğ. (2024) tarafından yapılan çalışmalarda elde edilen sonuçlarla uyumludur. Söz konusu çalışmalarda CNN tabanlı modellerin aerodinamik analizlerde daha başarılı olduğu, ancak hesaplama maliyetlerinin geleneksel yöntemlere kıyasla daha yüksek olduğu vurgulanmıştır.

Literatürde yer alan bazı çalışmalarda (Andrés-Pérez ve diğ., 2012, Yekin ve diğ., 2024, Moin ve diğ. 2021, Wallach ve diğ.) moment katsayısı (C_M) tahmin edilmemiş, yalnızca derin öğrenme tabanlı modellerde C_M tahmini gerçekleştirilmiştir. Moment katsayısının tahmin edilmesinin taşıma ve sürükleme katsayılarına kıyasla daha karmaşık bir problem olması nedeniyle, klasik makine öğrenimi algoritmalarının bu parametreyi yeterince iyi öğrenemediği gözlemlenmiştir. Andrés-Pérez ve Paulete-Periáñez (2021) tarafından yapılan çalışmada da CNN'in aerodinamik analizlerde C_M tahmininde geleneksel yöntemlere kıyasla daha başarılı olduğu ortaya konmuştur.

Çalışmanın önemli bir bulgusu, bazı test veri setlerinin yalnızca belirli kanat profilleri ile oluşturulmuş olmasıdır (Andrés-Pérez ve Paulete-Periáñez, 2021, Yetkin ve diğ.,2024, Wallach ve diğ. 2006). Eğitim veri setinden tamamen farklı kanat profilleri kullanılarak oluşturulan test

seti, modelin genelleme yeteneğinin daha nesnel bir şekilde değerlendirilmesini sağlamıştır. Sonuçlar, modelin eğitim veri setine benzer kanat profilleri için daha iyi tahmin yaptığı, ancak daha önce hiç görmediği profillerde hata oranlarının arttığını göstermektedir. Yetkin ve diğ. (2024) tarafından yapılan çalışmada da eğitim veri setinin çeşitliliğinin model başarımında kritik bir rol oynadığı ve genişletilmiş veri setlerinin tahmin doğruluğunu artırabileceği vurgulanmıştır.

Çalışmada geliştirilen çok kriterli değerlendirme metriği, C_L/ C_D oranı ve C_M değerlerini dikkate alarak en ideal kanat profilinin belirlenmesini sağlamıştır. Aerodinamik verimliliğin yanı sıra uçuş stabilitesini de içeren bu yaklaşım, yalnızca yüksek taşıma ve düşük sürükleme sağlayan profilleri değil, aynı zamanda uçuş dengesini koruyan profilleri de seçmeyi mümkün kılmıştır. Bu çok kriterli optimizasyon yaklaşımı, Andrés-Pérez ve diğ. (2012) tarafından sunulan yalnızca C_L/ C_D oranına dayalı optimizasyon yöntemlerine kıyasla daha kapsamlı bir analiz sunmaktadır. Literatürde yer alan diğer çalışmalarla karşılaştırıldığında, bu çalışmanın en önemli katkısı, derin öğrenme tabanlı modellerin C_M tahmini üzerindeki başarısını ortaya koyması ve ideal kanat profili seçiminde aerodinamik katsayıları çok kriterli bir yöntemle değerlendirmesidir.

Bu çalışmada elde edilen bulgular, makine öğrenimi tabanlı aerodinamik katsayı tahmin modellerinin hava aracı tasarım süreçlerine entegre edilebileceğini ve mühendislerin karar verme süreçlerine katkı sağlayabileceğini göstermektedir.

6. SONUÇ VE ÖNERİLER

Tez çalışması kapsamında, makine öğrenimi ve derin öğrenme tabanlı modeller kullanılarak hava aracı kanat profillerinin aerodinamik katsayılarının tahmini gerçekleştirilmiş ve farklı algoritmaların performansları karşılaştırılmıştır. Elde edilen bulgular, derin öğrenme tabanlı modellerin aerodinamik katsayı tahmininde en yüksek doğruluğu sağladığını göstermektedir.

Model performansı analiz edildiğinde, CNN ve YSA modellerinin yüksek doğruluk sağladığı ancak eğitim süresinin klasik makine öğrenimi modellerine kıyasla daha uzun olduğu tespit edilmiştir. Bu durum, derin öğrenme modellerinin hesaplama maliyetleri açısından dikkatlice değerlendirilmesi gerektiğini ortaya koymaktadır. Bu sebeple, hesaplama maliyetlerinin düşürülmesi için daha optimize model yapılarının geliştirilmesi önerilmektedir. Klasik makine öğrenimi algoritmaları içinde XGBoost ve Rassal Orman (RF), aerodinamik kuvvetlerin tahmininde YSA ve CNN ile eğitilen modellere yakın bir performans göstermektedir. Bu modeller, derin öğrenme modellerine göre çok daha kısa eğitim sürelerine sahiptir. Ancak aerodinamik kuvvetlerin hatalı tespiti, tasarım süreci maliyetlerini artırmaktadır. Bir hava aracı tasarım sürecinde aerodinamik kuvvetlerin minimum hata ile tahmin edilmesi ve en ideal kanat profilinin yüksek doğrulukta tespit edilmesi, hava aracı uçuş maliyeti ve uçuş güvenliği için kritik önem arz etmektedir. Bu çalışma ışığında, ilerleyen araştırmalar için aşağıdaki öneriler sunulmaktadır:

- Veri seti çeşitliliğinin artırılması ve transonik hız değerlerinde tahminleme yapılması: Modelin genelleme yeteneğini artırmak amacıyla, yüksek hücum açıları ve transonik rejimlerde elde edilen analizler veri setine eklenmelidir.

- Aerodinamik kuvvetlerin tahmin edilebilmesi için daha derin sinir ağlarının kullanılması ve hiperparametre optimizasyon çalışmalarının gerçekleştirilmesi: CNN ve YSA gibi modeller aerodinamik kuvvetleri tahmin etmede başarılı olmuştur, ancak modelin doğruluğunu artırmak için daha derin ağ yapılarının kullanılması önerilmektedir. Tez çalışması kapsamında farklı hiperparametreler ile modeller eğitilmiş ve performansları değerlendirilmiştir. Gelecek çalışmalarda daha geniş

aralıklarda hiperparametreler kullanılarak, hiperparametre ve model optimazyonu gerçekleştirilmesi önerilmektedir.

- Üç boyutlu analizlerin modele eklenmesi: Bu çalışma yalnızca 2 boyutlu kanat profilleri ile gerçekleştirilmiştir. 3 boyutlu analizlerin dahil edilmesi, modelin gerçek hava aracı tasarım süreçlerine daha uygun hale gelmesini sağlayacaktır.

- HAD analizinde kullanılan farklı programlar ile veri seti üretilmesi ve performanslarının karşılaştırılması: Çalışma kapsamında sadece XFOIL programı kullanılarak elde edilen analizler üzerinden makine öğrenimi modelleri eğitilmiştir. Gelecek çalışmalarda aynı parametreler ve uçuş koşulları ile OpenFOAM, SU2 gibi farklı açık kaynak ve ANSYS Fluent, STAR-CCM+ gibi ücretli yazılımlar kullanılarak veri setleri üretilebilir, model performansları değerlendirilebilir.

Sonuç olarak, tez çalışması kapsamında makine öğrenimi tabanlı tahmin modellerinin hava aracı tasarım süreçlerinde kullanım potansiyeli değerlendirilmekte ve farklı makine öğrenimi algoritmalarının performanslarını karşılaştırılmaktadır. Gelecek çalışmalarda, daha geniş veri setleri, gelişmiş optimizasyon teknikleri ve hibrit modelleme yaklaşımları ile aerodinamik katsayı tahminlerinin doğruluğu artırılabileceği değerlendirilmektedir.

KAYNAKLAR

Ahmed, S., Kamal, K., Ratlamwala, T.A.H., Mathavan, S., Hussain, G., Alkahtani, M. and Alsultan, M.B.M., 2022, Aerodynamic analyses of airfoils using machine learning as an alternative to RANS simulation, *Applied Sciences*, 12(10), p.5194.

Andrés-Pérez, E., Salcedo-Sanz, S., Monge, F., and Pérez-Bellido, A., 2012, Efficient aerodynamic design through evolutionary programming and support vector regression algorithms, *Expert Systems with Applications*, 39(12), 10700–10708.

Andrés-Pérez, E., and Paulete-Periáñez, C., 2021, On the application of surrogate regression models for aerodynamic coefficient prediction, *Complex & Intelligent Systems*, 7(4), 1991–2021.

Balla, K., Sevilla, R., Hassan, O. and Morgan, K., 2021, An application of neural networks to the prediction of aerodynamic coefficients of aerofoils and Wings, *Applied Mathematical Modelling*, 96, pp.456-479.

Drela, M., 1989, XFOIL: An Analysis and Design System for Low Reynolds Number Airfoils, in Mueller, T.J. (ed.) *Low Reynolds Number Aerodynamics*. Berlin, Heidelberg: Springer, pp. 1–12.

Guo, X., Li, W. and Iorio, F., 2016, Convolutional neural networks for steady flow approximation, *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining (KDD '16)*, pp. 481–490.

Johnson, F.T., Tinoco, E.N. and Yu, N.J., 2005, Thirty years of development and application of CFD at Boeing Commercial Airplanes, Seattle, *Computers & Fluids*, 34(10), 1115-1151.

Li, Y., Chang, J., Kong, C. and Bao, W., 2022, Recent progress of machine learning in flow modeling and active flow control, *Chinese Journal of Aeronautics*, 35(4), 14-44.

Moin, H., Khan, H.Z.I., Mobeen, S. and Riaz, J., 2022, August, Airfoil's aerodynamic coefficients prediction using artificial neural network, *In 2022 19th International Bhurban Conference on Applied Sciences and Technology (IBCAST)* (pp. 175-182). IEEE.

Santos, M., Mattos, B. and Girardi, R., 2008, January, Aerodynamic coefficient prediction of airfoils using neural networks. *In 46th AIAA aerospace sciences meeting and exhibit* (p. 887).

Tinoco, E., 2008, November, Validation and minimizing CFD uncertainty for commercial aircraft applications, *In 26th AIAA Applied Aerodynamics Conference* (p. 6902).

Yetkin, S., Abuhanieh, S. and Yigit, S., 2024, Investigation on the abilities of different artificial intelligence methods to predict the aerodynamic coefficients, *Expert Systems with Applications*, 237, p.121324.

Yükselen A., Kanat Profillerinin Aerodinamiği, https://web.itu.edu.tr/yukselen/Uck351/05-%20Kanat%20profillerinin%20aerodinami%F0i.pdf, [Ziyaret Tarihi: 07.08.2024].

Yondo, R., Andrés, E. and Valero, E., 2018, A review on design of experiments and surrogate models in aircraft real-time and many-query aerodynamic analyses, *Progress in Aerospace Sciences*, 96, pp.23-61.

Wallach, R., de Mattos, B.S. and da Mota Girardi, R., 2006, Aerodynamic coefficient prediction of a general transport aircraft using neural network, *In 25th Congress of the International Council of the Aeronautical Sciences.*

EKLER

EK 1. Kanat Profili Parametrelerini Tanımlayarak XFOIL Programı ile Veri Seti Üreten Python Kodu

```
import csv
import os
import subprocess
import numpy as np
from funcs import *

#csv setup
header=['NACA', 'Alpha', 'CL', 'CD', 'CDp', 'CM', 'Top_Xtr', 'Bot_Xtr','Max Camber'
with open('output.csv', 'w', newline='') as f:
    writer = csv.writer(f)
    writer.writerow(header)

#define parameters
reynold = pow(10, 7)
a_init, a_final, a_step = 4, 14, 1

for velocity in np.arange(0.3, 0.8, 0.1):
    for max_camber in np.arange(0, 6, 1): #0 to 9.5%
        for max_camber_pos in np.arange(0, 60, 10): #0 to 90%
            for thickness in np.arange(1, 40, 3): #1 to 40%

                airfoil = get_airfoil(max_camber, max_camber_pos, thickness)
                try:
                    xfoil(velocity, airfoil, reynold, a_init, a_final, a_step)
                    #appends data into array
                    try:

                        to_add = np.loadtxt('polar_file.txt', skiprows=12)
                        rows = np.shape(to_add)

                        tmp_to_add = np.empty([to_add.shape[0],to_add.shape[1]+4])
                        if to_add.size != 0:
                            if len(rows) == 1:
                                naca = np.full((1), airfoil)
                            else:
                                naca = np.full((rows[0], 1), airfoil)
                            for i in range(to_add.shape[0]):
                                tmp_to_add[i] = np.append(to_add[i],(max_camber,max

                            to_add = np.hstack((naca, tmp_to_add))
                        #writes xfoil output to csv
                        with open('output.csv', 'a') as f:
                            np.savetxt(f, to_add, fmt = '%s', delimiter=',')
                    except Exception as ex:
                        print(ex)
                        print('polar_file.txt is empty')
                        continue
                except subprocess.TimeoutExpired as e:
                    print(str(e))
                    continue
```

İNTİHAL RAPORU İLK SAYFASI

Abdulsamet EKŞİ

ORİJİNALLİK RAPORU

%9	%7	%4	%5
BENZERLİK ENDEKSİ	İNTERNET KAYNAKLARI	YAYINLAR	ÖĞRENCİ ÖDEVLERİ

BİRİNCİL KAYNAKLAR

1	Submitted to The Scientific & Technological Research Council of Turkey (TUBITAK) Öğrenci Ödevi	%4
2	acikbilim.yok.gov.tr İnternet Kaynağı	%1
3	Submitted to Konya Necmettin Erbakan University Öğrenci Ödevi	<%1
4	katalog.ticaret.edu.tr İnternet Kaynağı	<%1
5	airkule.com İnternet Kaynağı	<%1
6	www.researchgate.net İnternet Kaynağı	<%1
7	silo.tips İnternet Kaynağı	<%1
8	www.tgs.com İnternet Kaynağı	<%1
9	acikerisim.sakarya.edu.tr	