

HELİKOPTER ROTOR PALİNİN BURULMA OPTİMİZASYONU İÇİN FARKLI MAKİNE ÖĞRENMESİ YÖNTEMLERİNİN KARŞILAŞTIRILMASI

Emin Burak Özyılmaz* ve Mustafa Kaya†
Ankara Yıldırım Beyazıt Üniversitesi, Ankara

ÖZET

Reynolds Ortalamalı Navier-Stokes (RANS) denklemlerinin çözülmesi, helikopter rotor palleri üzerindeki aerodinamik yüklerin doğru bir şekilde tahmin edilmesi için önemlidir. Özellikle, kanat şekli optimizasyonunda birçok RANS çözümü elde edilerek yapılan hesaplama süreci oldukça zaman alıcıdır. Bu sürenin azaltılması için son dönemde benimsenen bir yaklaşım, makine öğrenmesi metotları gibi metamodeller kullanmaktır. İyi kurulmuş bir metamodelin, CFD çözümlerini başarılı bir şekilde taklit etmesi beklenir. Bu çalışmada, bir dizi CFD çözümüne dayalı olarak kullanılan farklı makine öğrenmesi teknikleri metamodel olarak kullanılıp karşılaştırılmıştır. CFD çözümleri, NUMECA International tarafından geliştirilen ticari çözücü FINE/Turbo ile hesaplanmıştır. Makine öğrenmesi modelleri, üretilen itki ve tork ile rotor pali boyunca burulma dağılımı arasındaki işlevsel ilişkiyi belirtmek üzere oluşturulmuştur. Burulmanın düzgün değişimi, 3-düğümlü kübik spline kullanılarak tanımlanmıştır. Toplamda 5 parametre, spline tanımı için girdi olarak düşünülmüştür. Optimum burulma dağılımı, bir referans helikopter rotor pali olan Caradonna-Tung helikopter rotor paline göre belirlenmiştir. İlgili optimizasyon durumları baz tork değerinde maksimum itme kuvveti olarak belirlenmiştir. Optimum durumlar, Doğrusal Regresyon, Destek Vektörü Regresyonu ve Yapay Sinir Ağları Regresyonu kullanılarak belirlenmiş ve karşılaştırması yapılmıştır. Bu çalışma sonunda helikopter rotor palinin ürettiği itki kuvveti kayda değer bir miktarda artırılmıştır.

GİRİŞ

Hesaplamalı akışkanlar dinamiği (HAD), havacılık ve otomotiv endüstrileri gibi çeşitli alanlarda tasarımların aerodinamik performansını analiz etmek ve iyileştirmek için yaygın olarak kullanılan bir araçtır[Kaya ve Elfarra, 2020]. Bilgisayar bilimi ve HAD uygulamalarındaki gelişmeler, tasarımların aerodinamik açıdan eniyilenmesine olanak sağlamıştır. Havacılık alanında helikopter rotor palleri söz konusu olduğunda, yüksek derecede vorteksli ve karmaşık akışların varlığı nedeniyle rotor pallerinin performansını iyileştirmek tasarımcılar için oldukça zorlayıcı bir görevdir[Elfarra, 2019].

*Araştırma Görevlisi, Havacılık ve Uzay Mühendisliği Böl., E-posta: eminburakozyilmaz@aybu.edu.tr

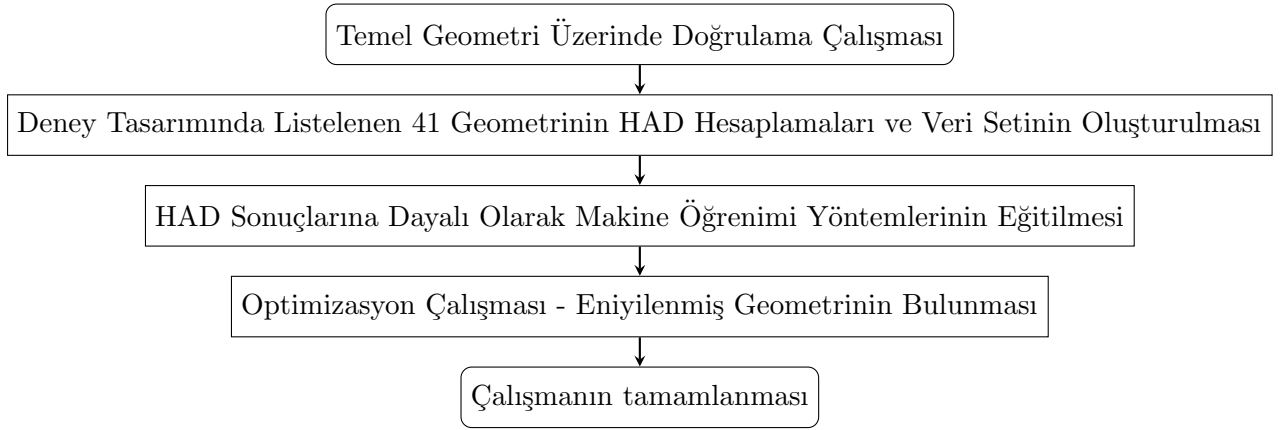
†Doç.Dr., Havacılık ve Uzay Mühendisliği Böl., E-posta: mkaya@aybu.edu.tr

Birçok araştırmacı, rotor palleri üzerinde aerodinamik şekil optimizasyonu ile eniyelenmiş sonuçları almak için optimizasyon prosedürleri sunmuştur[Renzoni, D'Alascio, Kroll, Peshkin, Hounjet, Boniface, 2022; Gecgel, 2009; Le Pape ve Beaumier, 2005]. Son on yılda, deneysel veya sayısal sonuçlar üzerinde meta veriler oluşturularak eniyelenmiş aerodinamik şekilleri aramanın daha kolay ve ucuz hale gelmesi için makine öğrenimi teknikleri optimizasyon prosedürlerine girmiştir[Renzoni, D'Alascio, Kroll, Peshkin, Hounjet, Boniface, 2022].

Rotor pali etrafındaki akışın vorteks ve karmaşık doğası nedeniyle aerodinamik optimizasyon zorlaşır [Elfara, 2019]. Bu süreci kolaylaştırmak için, veri odaklı aerodinamik şekil optimizasyon sürecinde makine öğrenimi yöntemleri aktif olarak kullanılmaktadır. Lineer Regresyon (LR), Destek Vektör Regresyonu (SVR), Yapay Sinir Ağları (ANN) gibi regresyon algoritmaları, helikopter rotor pallerinin itki tahmini için aerodinamik optimizasyon sürecinde kullanılmaktadır.

YÖNTEM

Helikopter rotor pali eniyemesinde kullanılan yöntem Şekil 1'de bir akış diyagramı olarak verilmiştir. Bu çalışmada süreç, sayısal yöntemin doğrulanması ile başlar ve veri setinin oluşturulmasıyla devam eder. Akış diyagramında, makine öğrenimi algoritmalarının eğitimi ve bir optimizasyon çalışması yapılması süreçte bulunan diğer ardışık adımlardır.




Şekil 1: Süreç akış diyagramı

En iyileme çalışmasındaki amaç, rotor palinin ürettiği itki kuvvetini en çoklayan ve bu sırada temel geometriden daha fazla tork üretmeyen eniyelenmiş geometrik şekli bulabilmektir. Rotor palinin şekli, pal boyunca burulma dağılımı değiştirilerek oluşturulmaktadır. Burulma açıları, rotor palinin kök, orta ve uç konumlarına karşılık gelen burulma açılarını değiştiren kübik spline yöntemi kullanılarak pal boyunca değiştirilmiştir. Box-Behnken deney tasarımı yöntemi, yapılacak sayısal analizlerin seçimini verimli bir şekilde yönetmek için uygulanmıştır ve böylece bir dizi örnek üretilmiştir[Cavazzuti, 2013]. Rotor palleri etrafındaki akışı hesaplamak için üç boyutlu Reynolds Ortalama Navier Stokes çözücüsü kullanılmıştır. Tüm analizler için açılma hızı 1750 devir/dakika olarak belirlenmiştir.

Temel Geometri Üzerinde Doğrulama Çalışması

Caradonna–Tung helikopter rotor pali[Caradonna ve Tung, 1981], optimizasyon çalışması için temel rotor pali olarak seçilmiştir ve rotor palinin bir gösterimi Şekil 2'de verilmiştir.

Temel geometri, deneysel sonuçlara karşı sayısal olarak deneysel koşulların sınır koşulu olarak belirlendiği üç boyutlu HAD analizi yapılarak doğrulanmıştır. Hesaplamalı akışkanlar dinamiği çözücüsü olarak üç boyutlu, sıkıştırılabilir bir sonlu hacimler çözücüsü olan FINE/Turbo



Şekil 2: Caradonna-Tung rotor palinin ön görünümü

kullanılmıştır. Bu doğrulama çalışmasında HAD analizinden elde edilen sonuçlar ile deneysel sonuçların iyi bir şekilde uyumlu olduğu görülmüştür. Deneysel ve sayısal hesaplamaların yer aldığı karşılaştırma tablosu Tablo 1'de verilmiştir.

Tablo 1: Deneysel ve HAD Sonuçlarının Karşılaştırması

	Tork	İtke
<i>Deneysel</i>	135 Nm	1150 N
<i>HAD</i>	136 Nm	1149 N
<i>Hata (%)</i>	0.7	0.1

Veri Setinin Oluşturulması

Makine öğrenmesi algoritmalarının eğitimi için girdi ve çıktı çiftlerinden oluşan bir veri seti gereklidir. Bu çalışmada girdi, helikopter rotor palinin burulma açılarının dağılımını tanımlayan beş değişkene sahip bir vektörken, çıktı değişkenleri üretilen itkiyi ve torku temsil etmektedir. Girdi ve çıktı değişkenleri Şekil 3'de verilmiştir.

$$\vec{x} = \begin{bmatrix} x^{(1)} \\ x^{(2)} \\ x^{(3)} \\ x^{(4)} \\ x^{(5)} \end{bmatrix} = \begin{bmatrix} \theta_{\text{kök}} \\ \theta_{\text{orta}} \\ \theta_{\text{uç}} \\ \left. \frac{d\theta}{dr} \right|_{\text{kök}} \\ \left. \frac{d\theta}{dr} \right|_{\text{uç}} \end{bmatrix} = \begin{bmatrix} \text{Rotor palinin kökündeki burulma açısı} \\ \text{Rotor palinin orta noktasındaki burulma açısı} \\ \text{Rotor palinin uçundaki burulma açısı} \\ \text{Rotor palinin kökündeki burulma eğimi} \\ \text{Rotor palinin uçundaki burulma eğimi} \end{bmatrix}$$

$$y_1(\vec{x}) = \text{Üretilen itki kuvveti}$$

$$y_2(\vec{x}) = \text{Üretilen Tork}$$

Şekil 3: Girdi ve çıktı değişkenleri

Kübik Spline ile Burulma Dağılımı:

Kübik spline, bir dizi kontrol noktası üzerinden geçen parça parça üçüncü dereceden polinomlardan oluşan bir splinedir. Bir kübik splinenin birinci ve ikinci türevleri her düğüm noktasında süreklidir ve bu, verinin düzgünlüğünü sağlar. Ayrıca, bir kübik spline oluşturulurken spline'in uç noktalarındaki birinci (veya ikinci ya da üçüncü) türevlerinin de bilinmesi gerekir.

Bu çalışmada, 3 düğüm noktası ($r_{\text{kök}}, r_{\text{orta}}$ ve $r_{\text{uç}}$) ve bunlara karşılık gelen 3 burulma açısı ($\theta_{\text{kök}}, \theta_{\text{orta}}, \theta_{\text{uç}}$) kullanılarak kübik spline oluşturulmuştur. Geleneksel (doğal) kübik spline'dan farklı olarak, kökte ve uçta birinci türevler verilmiştir. İlk düğüm noktasındaki birinci türev, yani $\left. \frac{d\theta}{dr} \right|_{\text{kök}}$ ve üçüncü düğüm noktasındaki birinci türev, yani $\left. \frac{d\theta}{dr} \right|_{\text{uç}}$, giriş vektöründe 4. ve 5. parametre olarak eklenmiştir.

Rotor pali boyunca burulma dağılımını tanımlamak için kullanılan kübik spline'in matematiksel olarak ifade edilen özeti şu şekildedir:

$$\theta(r) = \begin{cases} \theta_1(r) = a_1(r - r_{\text{kök}})^3 + b_1(r - r_{\text{kök}})^2 + c_1(r - r_{\text{kök}}) + d_1 & \text{eğer } r_{\text{kök}} \leq r \leq r_{\text{orta}} \\ \theta_2(r) = a_2(r - r_{\text{kök}})^3 + b_2(r - r_{\text{kök}})^2 + c_2(r - r_{\text{kök}}) + d_2 & \text{eğer } r_{\text{orta}} \leq r \leq r_{\text{uç}} \end{cases} \quad (1)$$

Bilinmeyen katsayılar $a_1, b_1, c_1, d_1, a_2, b_2, c_2$ ve d_2 , aşağıdaki koşullara göre belirlenir:

$$\begin{aligned} \theta_1(r_{\text{kök}}) &= \theta_{\text{kök}} \\ \theta_1(r_{\text{orta}}) &= \theta_{\text{orta}} \\ \theta_2(r_{\text{orta}}) &= \theta_{\text{orta}} \\ \theta_2(r_{\text{uç}}) &= \theta_{\text{uç}} \\ \left. \frac{d\theta_1}{dr} \right|_{\text{orta}} &= \left. \frac{d\theta_2}{dr} \right|_{\text{orta}} \\ \left. \frac{d^2\theta_1}{dr^2} \right|_{\text{orta}} &= \left. \frac{d^2\theta_2}{dr^2} \right|_{\text{orta}} \\ \left. \frac{d\theta_1}{dr} \right|_{\text{kök}} &= \left. \frac{d\theta}{dr} \right|_{\text{kök}} \\ \left. \frac{d\theta_2}{dr} \right|_{\text{uç}} &= \left. \frac{d\theta}{dr} \right|_{\text{uç}} \end{aligned} \quad (2)$$

Bu denklem seti, kolayca çözülebilen 8 bilinmeyenli bir lineer sisteme yol açar.

Burulma dağılımlarının bulunarak veri seti için gereken girdi-çıkış çiftlerinin sayısı Box-Behnken deney tasarımı yöntemi kullanılarak belirlenmiştir. Box-Behnken deney tasarımı yöntemi, beş değişkenli bir girdi vektörü için 41 adet girdi-çıkış çifti önermektedir. Yüksek (y), düşük (d) ve orta (o) değerler için beş değişkenli Box-Behnken deney tasarımı örneği Tablo 2'de verilmiştir.

Tablo 2: 5 Değişkenli Box-Behnken Deney Tasarımı

Örnek No	D1	D2	D3	D4	D5
1	d	d	o	o	o
2	d	y	o	o	o
3	y	d	o	o	o
.
.
.
39	o	y	o	d	o
40	o	y	o	y	o
41	o	o	o	o	o

Bu çalışmada girdi değişkenlerinin yüksek, orta ve düşük seviyedeki değerleri aşağıdaki Tablo 3'teki gibi listelenmiştir.

Box-Behnken deney tasarımı yöntemi ile oluşturulan deneyler için uygun geometrik şekiller oluşturulmuş ve üç boyutlu HAD analizleri yapılarak üretilen itki kuvveti ve tork değerleri hesaplanmıştır. Tablo IV'te, veri setine ait on farklı örnek verilmiştir.

Tablo 3: Değişkenlerin Düşük, Orta ve Yüksek Değerleri

Değişken	Düşük	Orta	Yüksek
$\theta_{kök}$	-5.0	5.0	15.0
θ_{orta}	-5.0	5.0	15.0
$\theta_{uç}$	-5.0	5.0	15.0
$\frac{d\theta}{dr} \Big _{kök}$	-15.0	0.0	15.0
$\frac{d\theta}{dr} \Big _{uç}$	-15.0	0.0	15.0

Tablo 4: Veri setine ait on farklı örnek

D1	D2	D3	D4	D5	İtki(N)	Tork(Nm)
0	5	-5	-5	0	2233	321
0	5	5	-5	15	1371	211
0	5	-5	5	15	1323	152
0	15	5	-5	0	1241	198
15	5	5	-5	0	1227	186
0	15	-5	5	0	1205	144
15	5	-5	5	0	1204	138
0	-5	-5	5	0	1204	134
-15	5	5	-5	0	1189	179
-15	5	-5	5	0	1188	135
0	-5	5	-5	0	1160	172

Uygulanan Makine Öğrenimi Yöntemleri

Bu çalışmada elde edilen veri setine uygun metamodeller oluşturmak ve veri setini bir fonksiyon olarak tanımlayabilmek üzere makine öğrenmesi yöntemleri kullanılmıştır. Bu yöntemler, Doğrusal Regresyon, Destek Vektörü Regresyonu (SVR) modeli ve Yapay Sinir Ağları (ANN) regresyon modelleridir. Uygulanan regresyon modelleri için algoritmalar Python ortamında uygulanmış ve Scikit-Learn kütüphanesi kullanılmıştır.

Doğrusal Regresyon:

Doğrusal regresyon, bağımlı değişken y ile birden fazla bağımsız değişken içeren \vec{x} arasındaki ilişkiyi modellemek için kullanılan temel bir makine öğrenimi tekniğidir. Bağımsız değişkenler ile bağımlı değişken arasında doğrusal bir ilişki olduğunu varsayar.

Doğrusal regresyon modeli şu şekilde temsil edilebilir:

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_n x_n + \epsilon \quad (3)$$

burada:

- y , bağımlı değişkeni (Çıktı),
- x_1, x_2, \dots, x_n , bağımsız değişkenleri (Girdi vektörü elemanları),
- $\beta_0, \beta_1, \beta_2, \dots, \beta_n$, katsayıları,
- ϵ , hata terimini ifade etmektedir.

Doğrusal regresyon, basit ama güçlü bir makine öğrenimi tekniğidir ve regresyon görevleri için yaygın olarak kullanılır. Yorumlanabilir sonuçlar sağlar ve uygulaması kolaydır.

Destek Vektör Regresyonu:

Destek vektör regresyonu (SVR), bağımlı değişken y ile birden fazla bağımsız değişken içeren \vec{x} arasındaki ilişkiyi modellemek için kullanılan bir makine öğrenimi tekniğidir. Destek vektör regresyonu, eğitim verileri etrafında maksimum marja sahip bir hiperdüzlem bulmayı amaçlar ve tahmin hatalarında bir miktar toleransa (ϵ) izin verir.

Destek vektörü regresyon modeli şu şekilde temsil edilebilir:

$$y = \vec{w} \cdot \vec{x} + b \quad (4)$$

burada:

- w , ağırlık vektörünü,
- x , değişken vektörünü,
- b , ön yargı katsayısını ifade etmektedir.

Destek vektör regresyonu modeli ayrıca marjın dışındaki ve marjın içindeki noktaları marjdan olan uzaklıklarına orantılı bir faktörle cezalandıran bir kayıp fonksiyonu içerir. Bu kayıp fonksiyonu, tahmin hatasını minimize ederken marjı maksimize etmeyi amaçlayan bir kısıtlı optimizasyon problemi çözerek eğitilir. Bu optimizasyon problemi, kuadratik programlama veya gradyan inişi gibi teknikler kullanılarak çözülebilir ve genellikle şu şekilde ifade edilir:

$$\text{en küçük} \quad \frac{1}{2} \|\vec{w}\|^2 + C \sum_{i=1}^m (\xi_i^+ + \xi_i^-)$$

Şu kısıtlamalar altında:

$$\begin{aligned} \langle \vec{w}, \vec{\phi}(\vec{x}_i) \rangle + b - y_i &\leq \epsilon + \xi_i^+ \\ y_i - \langle \vec{w}, \vec{\phi}(\vec{x}_i) \rangle - b &\leq \epsilon + \xi_i^- \\ \xi_i^+, \xi_i^- &\geq 0 \quad \text{for } i = 1, 2, \dots, m \end{aligned}$$

burada:

- $\|\vec{w}\|^2$, ağırlık vektörünün normunun karesini,
- C , marjı maksimize etmek ile tahmin hatasını minimize etmek arasındaki dengeyi kontrol eden düzenleme parametresini,
- ξ_i^+ ve ξ_i^- , tahmin hatalarında bir miktar toleransa izin veren gevşeme değişkenlerini ifade etmektedir.

Destek vektör regresyonu, özellikle doğrusal olmayan ilişkiler veya yüksek boyutlu verilerle çalışırken regresyon görevleri için güçlü bir makine öğrenimi tekniğidir. Eğitim verileri etrafında maksimum marja sahip hiperdüzlemi bularak, görünmeyen verilere iyi genelleme yapar ve aşırı uyumu önler.

Yapay Sinir Ağları Regresyonu:

Yapay Sinir Ağları (ANN), insan beynindeki nöronlardan esinlenerek geliştirilmiş bir modelleme yöntemidir. Bu ağlar, çok katmanlı yapıları sayesinde karmaşık veri ilişkilerini öğrenebilir.

Yapay Sinir Ağı Bileşenleri:

- Giriş Katmanı (Input Layer): Giriş katmanı, modelin alacağı veri özelliklerinden oluşur. Her bir nöron, bir özelliği temsil eder.
- Gizli Katmanlar (Hidden Layers): Bu katmanlar, giriş katmanından gelen veriyi işler ve daha karmaşık özellikleri öğrenir. Genellikle, birden fazla gizli katman kullanılır.
- Çıkış Katmanı (Output Layer): Bu katman, modelin verdiği tahmini çıkışı üretir.

Matematiksel Açıklama: Yapay Sinir Ağları, her bir katmandaki nöronlar arasında ağırlıklar (w) ve biaslar (b) kullanarak veri üzerinde işlem yapar. Her bir nöronun çıktısı, girişlerin ağırlıklı toplamının bir aktivasyon fonksiyonundan geçirilmesiyle elde edilir.

Bir ANN'deki her bir gizli katman için çıkış şu şekilde hesaplanır:

$$z^{(l)} = W^{(l)} \cdot a^{(l-1)} + b^{(l)} \quad (5)$$

Burada:

- $z^{(l)}$: l katmanındaki nöronların ağırlıklı toplamıdır.
- $W^{(l)}$: l katmanındaki ağırlık matrisidir.
- $a^{(l-1)}$: Önceki katmandaki aktivasyon çıktısıdır.
- $b^{(l)}$: l katmanındaki bias vektörüdür.

Bu ağırlıklı toplam daha sonra bir aktivasyon fonksiyonuna (σ) sokulur:

$$a^{(l)} = \sigma(z^{(l)}) \quad (6)$$

Çıkış katmanında ise, regresyon problemi olduğu için genellikle doğrusal bir aktivasyon fonksiyonu kullanılır:

$$\hat{y} = W^{(L)} \cdot a^{(L-1)} + b^{(L)} \quad (7)$$

Burada:

- \hat{y} : Modelin tahmin ettiği çıktıdır.
- $W^{(L)}$: Son katmandaki ağırlık matrisidir.
- $a^{(L-1)}$: Son gizli katmandaki aktivasyon çıktısıdır.
- $b^{(L)}$: Son katmandaki bias vektörüdür.

Değerlendirme Metrikleri:

Regresyon modellerinin performansı, ortalama mutlak hata (MAE), karekök ortalama karesel hata (RMSE) ve determinasyon katsayısı (R^2) gibi çeşitli metriklerle değerlendirilebilir. MAE, sürekli değişkenler için kullanılır. Bu metrik, Denklem 8'de verilmiştir.

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (8)$$

burada:

- n : Gözlem sayısı
- y_i : Gözlemlenen değerler
- \hat{y}_i : Tahmin edilen değerler

RMSE, kare hataların ortalamasının karekökünü almak için kullanılır. Bu RMSE metriği, Denklem 9'da verilmiştir.

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (9)$$

Burada:

- n : Gözlem sayısı
- y_i : Gözlemlenen değerler
- \hat{y}_i : Tahmin edilen değerler

R^2 değeri, bir regresyon modelinin veri setindeki değişkenliği ne kadar iyi açıkladığını gösteren istatistiksel bir ölçüdür ve Denklem 10'da verilmiştir.

$$R^2 = 1 - \frac{\sum (y_i - \hat{y}_i)^2}{\sum (y_i - \bar{y})^2} \quad (10)$$

Burada:


- y_i : Gözlemlenen değerler
- \hat{y}_i : Tahmin edilen değerler
- \bar{y} : Gözlemlenen değerlerin ortalaması

Eniyileme Çalışması

Modeller oluşturulduktan sonra, girdi ve çıktı arasında analitik olarak tanımlanmış bir fonksiyon elde edilir. Bu bilinen analitik fonksiyonun ekstremumu, burulma parametreleri üzerinde herhangi bir kısıtlama olmadığından, ilk türevini sıfıra eşitleyerek kolayca bulunabilir:

$$\frac{dy^*(\vec{x})}{d\vec{x}} = 0 \quad (11)$$

Eniyileme problemi denklem 12'de tanımlanmıştır. Bu çalışmada izin verilen en yüksek tork değeri temel geometrinin sahip olduğu tork değeri olan 135 Nm'dir ve bu değere sahip en yüksek itki değeri araştırılmaktadır. $\mathbf{1}_b$ ve \mathbf{u}_b , eniyileme çalışmasının alt ve üst sınırlarını ifade eder ki bu sınırlar girdi değişkenlerinin yüksek ve düşük değerleridir.



Şekil 4: Eniyilenmiş rotor palı burulma dağılımları

En büyük $y_1(\vec{x})$, $\vec{x} \in R^n$

Şu kısıtlamalar altında:

$$y_2(\vec{x}) \leq 135$$

$$\vec{l}_b \leq \vec{x} \leq \vec{u}_b$$

(12)

UYGULAMALAR VE DEĞERLENDİRME

Eniyileme çalışması, Doğrusal Regresyon, Destek Vektörü Regresyonu ve Yapay Sinir Ağları Regresyonu tarafından oluşturulan metamodeller temel alınarak gerçekleştirilmiştir. Eniyilenmiş sonuçlar, Denklem 12 tarafından tanımlanan uygunluk bölgesinde belirlenmiştir. Denklem 12'deki alt ve üst sınır kısıtlamaları, deney tasarımının en küçük ve en büyük değerleridir. Kullanılan yöntemlerin her biri için makine öğrenmesi ve optimizasyon çalışması yapılmış ve temel geometrinin tork değerini üretirken en fazla itki kuvvetini üreten 3 farklı rotor palı üretilmiş ve HAD analizi gerçekleştirilmiştir. Doğrusal regresyon modelinde elde edilen en yüksek itki miktarı modelden elde edilen veriye göre 1230 N, Destek Vektörü Regresyonu modeli için 1258 N ve Yapay Sinir Ağları Regresyonu modeli için ise 1235 N olarak bulunmuştur. Yapılan HAD analizleri ile bu elde edilen veriler karşılaştırıldığında Doğrusal Regresyon modelinde 1208 N(%1.78 sapma), Destek Vektörü Regresyonu modelinde 1230 N(%2.22 sapma) ve Yapay Sinir Ağları Regresyonu modelinde 1236 N(%0.08 sapma) elde edilmiştir. Tablo 5 eniyilenmiş değişkenlerle birlikte en büyük itki değerlerini vermektedir. Tablo incelendiğinde, yapay sinir ağları regresyonu modeli ile itkinin yaklaşık %7.5 artırdığı görülmektedir. Şekil 4'te oluşturulan rotor pallerinin pal boyunca burulma dağılımları gösterilmiştir. Buna göre Yapay Sinir Ağları regresyonu ve Destek Vektörü Regresyonu ile elde edilen rotor pallerinin geometrileri özellikle kanadın ortasından itibaren birbirine çok yakın çıkmıştır.

Tablo 5: Eniyilenmiş itki değerleri için rotor pali geometrileri

Model Adı	$\frac{d\theta}{dr}$ _{kök}	$\theta_{kök}$	θ_{orta}	$\theta_{uç}$	$\frac{d\theta}{dr}$ _{uç}	Model İtki (N)	Model Tork (Nm)	İtki Artışı (%)
Doğrusal Regresyon	-5.318	-5	-5	6.551	15	1208	133.3	5.13
Destek Vektörü Regresyonu	5.136	-3.286	-3.651	2.764	-2.884	1230	136.8	7.05
Yapay Sinir Ağları Regresyonu	5.780	-5	-3.380	1.84	-0.132	1235	136	7.48

SONUÇ

Bu araştırmada, Caradonna-Tung helikopter pervanesinin burulma dağılımı, kök, orta açıklık ve uç noktalarındaki burulma açılarına göre tanımlanan kübik spline'lar kullanılarak optimize edilmiştir. Ayrıca, kök ve uç noktalarındaki burulma açıları değişim oranı da dikkate alınmıştır. Optimizasyon, Doğrusal Regresyon, Destek Vektör Regresyonu ve Yapay Sinir Ağı Regresyonu gibi makine öğrenimi algoritmalarıyla oluşturulmuş metamodeller kullanılarak gerçekleştirilmiştir. Yapay Sinir Ağları Regresyon modeli diğer modellere göre optimizasyonda çok daha az sapma göstermiştir. Daha sonra ise sırasıyla Doğrusal Regresyon ve Destek Vektörü Regresyon modelleri gelmektedir. Bu makine öğrenmesi ve optimizasyon çalışması sonucunda temel geometrinin tork değeri değişmeden ürettiği itki miktarı yüzde yedi buçuk oranında artırılmıştır. İleriki çalışmalarda modellerin eniyileme için uygun alan dışındaki noktaları tahmin etme performansı araştırılacaktır. Bir başka fikir olarak rotor pallerinin burulma dışındaki parametreleri de sürece dahil edilerek çok daha yüksek performanslı geometriler aranabilir.

Kaynaklar

- Caradonna, F. X., Tung, C, 1981. *Experimental and analytical studies of a model helicopter rotor in hover (NASA Technical Memorandum 81232)*. Army Aeromechanics Laboratory's hover test facility.,
- Cavazzuti, M., 2013. *Optimization Methods: From Theory to Design*. Springer Berlin Heidelberg,
- Elfarra, M.A., 2019. *Optimization of helicopter rotor blade performance by spline-based taper distribution using neural networks based on CFD solutions*. *Engineering Applications of Computational Fluid Mechanics*, 13(1), 833-848. DOI: 10.1080/19942060.2019.1648322
- Gecgel, M., 2009. *Modeling and simulation of coaxial helicopter rotor aerodynamics (Doctoral dissertation)*. ProQuest database.
- Kaya, M. ve Elfarra, M.A., 2020. *Taper stacking for the aerodynamic performance of wings*. *Aircraft Engineering and Aerospace Technology*, Vol. 92 No. 7, pp. 1101-1110. <https://doi.org/10.1108/AEAT-12-2019-0257>
- Le Pape, A., ve Beaumier, P., 2020. *Numerical optimization of helicopter rotor aerodynamic performance in hover*. *Aerospace Science and Technology*, 9, 191-201.
- Ozyilmaz, E.B., Kaya, M., ve Elfarra, M.A., 2022. *Investigation of Flapping Wings as an Alternative to Axial Flow Fans*. *AIAA SCITECH 2022 Forum*, January 2022.
- Renzoni, R., D'Alascio, A., Kroll, N., Peshkin, D., Hounjet, M., Boniface, J. C., 2000. *A common European Euler code for the analysis of the helicopter rotor flowfield*. *Progress in Aerospace Sciences*, 36, 437-485.