



**İNSANSIZ HAVA ARACI (İHA) PERVANELERİN AERODİNAMİK
PERFORMANSININ ÇOK DOĞRULUKLU YÖNTEM İLE
MODELLENMESİ**

Hakan ÜNSAL

**YÜKSEK LİSANS TEZİ
OTOMOTİV MÜHENDİSLİĞİ ANA BİLİM DALI**

**GAZİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

KASIM 2024

ETİK BEYAN

Gazi Üniversitesi Fen Bilimleri Enstitüsü Tez Yazım Kurallarına uygun olarak hazırladığım bu tez çalışmada;

- Tez içinde sunduğum verileri, bilgileri ve dokümanları akademik ve etik kurallar çerçevesinde elde ettiğimi,
- Tüm bilgi, belge, değerlendirme ve sonuçları bilimsel etik ve ahlak kurallarına uygun olarak sunduğumu,
- Tez çalışmada yararlandığım eserlerin tümüne uygun atıfta bulunarak kaynak gösterdiğimi,
- Kullanılan verilerde herhangi bir değişiklik yapmadığımı,
- Bu tezde sunduğum çalışmanın özgün olduğunu,

bildirir, aksi bir durumda aleyhime doğabilecek tüm hak kayıplarını kabullendiğimi beyan ederim.

Hakan ÜNSAL

28/11/2024

İNSANSIZ HAVA ARACI (İHA) PERVANELERİN AERODİNAMİK OLARAK
PERFORMANSININ ÇOK DOĞRULUKLU YÖNTEM İLE MODELLENMESİ
(Yüksek Lisans Tezi)

Hakan ÜNSAL

GAZİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Kasım 2024

ÖZET

Bu çalışma, İnsansız Hava Araçları (İHA) için kullanılan pervanelerin aerodinamik performansının belirlenmesinde yapay sinir ağları (YSA) temelli bir yöntemi ele almaktadır. Çalışmanın odak noktası, yapay sinir ağları kullanarak simülasyon test verileri ile rüzgar tüneli test verilerinin entegrasyonu ve karşılaştırılmasıdır. İlk olarak, Python programlama dili kullanılarak, İHA pervaneleri için simülasyon test verileri belirli bir formata dönüştürülmüş ve bu veriler üzerinde yapay sinir ağları kullanılarak modeller geliştirilmiştir. Bu modeller yardımıyla rüzgar tüneli test verilerine karşılık gelen simülasyon sonuçları çıkarılmıştır. Ardından, gerçek verileri simüle etmek amacıyla rüzgar tüneli testlerinden elde edilen verilerle simülasyon için yapılan yapay sinir ağlarıyla oluşturulan model sonuçları karşılaştırılmıştır. Daha sonra rüzgar tüneli karşılığı olan simülasyon verileri ile rüzgar tüneli test verileri birlikte tekrar yapay sinir ağları kullanılarak modellenmiştir. Model performanslarına bakıldığında rüzgar tüneli modelleri ortalama olarak %99,81 oranda rüzgar tüneli verilerini doğru şekilde tahmin edebilmektedir. Elde edilen yapay sinir ağları modelleri ile rüzgar tüneli testine gitmeden, farklı pervane tiplerinin aerodinamik performansı hakkında önemli bilgiler elde edilmiştir. Bununla birlikte, Uluslararası Standart Atmosfer (ISA) koşullarına göre ISA formüllerinin eklenmesiyle, pervane verilerinin irtifaya göre değişen performansı da çıkarılmıştır. Bu sayede, farklı irtifa koşullarında pervanelerin itki ve güç gereksinimleri belirlenmiştir. Sonuç olarak, bu çalışma İHA pervanelerinin aerodinamik performansının daha hassas bir şekilde analiz edilmesine ve tasarımının optimize edilmesine olanak sağlamaktadır. Bu yaklaşım ile İHA pervanelerinin aerodinamik performansının çok doğruluklu bir şekilde modellenmesi sağlanmıştır. Rüzgar tüneli test verisi olmayan pervanelerin performansının belirlenmesi için önemli bir adım atılmıştır. Elde edilen veriler, İHA'ların tasarımı ve performansını optimize etmek için değerli bir kaynak oluşturmaktadır.

Bilim Kodu : 93008

Anahtar Kelimeler : İnsansız hava araçları (İHA), pervane, İHA motorları, makine öğrenmesi, yapay sinir ağları (YSA), rüzgar tüneli, simülasyon, itki sistemi

Sayfa Adedi : 157

Danışman : Prof. Dr. Mesut DÜZGÜN

AERODYNAMIC PERFORMANCE MODELING OF UNMANNED AERIAL
VEHICLE (UAV) PROPELLERS USING A MULTIFIDELITY METHOD

(M. Sc. Thesis)

Hakan ÜNSAL

GAZİ UNIVERSITY

GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCES

November 2024

ABSTRACT

This study focuses on a method based on artificial neural networks (ANN) for determining the aerodynamic performance of propellers used in Unmanned Aerial Vehicles (UAVs). The core of the study is the integration and comparison of simulation test data with wind tunnel test data using artificial neural networks. First, simulation test data for UAV propellers were converted into a specific format using the Python programming language, and modeling was conducted using artificial neural networks. With the help of these models, simulation results corresponding to the wind tunnel test data were derived. Then, to simulate real-world data, the results from the models created with artificial neural networks were compared with data obtained from wind tunnel tests. Following that, the simulated data corresponding to the wind tunnel tests were combined with the wind tunnel test data and modeled again using artificial neural networks. The performance of the models showed that wind tunnel models could predict wind tunnel data with an accuracy of 99.81%. With the ANN models developed, it became possible to obtain significant insights into the aerodynamic performance of different propeller types without conducting wind tunnel tests. Additionally, by incorporating International Standard Atmosphere (ISA) formulas, the performance of propellers under varying altitude conditions was determined, reflecting changes in thrust and power requirements. As a result, this study allows for more precise analysis of the aerodynamic performance of UAV propellers and optimization of their design. This approach provides highly accurate modeling of the aerodynamic performance of UAV propellers and marks a significant step in determining the performance of propellers without wind tunnel test data. The data obtained offer valuable insights for optimizing the design and performance of UAVs.

Science Code : 93008

Key Words : Unmanned aerial vehicles (UAVs), propeller, UAV engines, machine learning, artificial neural networks (ANN), wind tunnel, simulation, propulsion system

Page Number : 157

Supervisor : Prof. Dr. Mesut DÜZGÜN

TEŞEKKÜR

Bu tezin tamamlanmasında gösterdiği rehberlik, destek ve özveri için Yüksek Lisans Tez Danışmanım Sayın Prof. Dr. Mesut DÜZGÜN'e; tez dönemi boyunca manevi, psikolojik ve teknik bilgi olarak desteklerini esirgemeyen çok değerli abim Sayın İsmail Sadi CESUR'a; tez dönemi boyunca bana her türlü esneklik sağlayan ve desteğini esirgemeyen çok değerli takım liderim Sayın Ahmet Semih PARLAK'a; her türlü teknolojik imkan olarak katkı ve imkan sağlayan çok değerli şirketim HAVELSAN A.Ş.'ye ve bu dönemde her türlü maddi ve manevi destekleri için çok değerli aileme; son olarak, bu tez çalışmasını tamamlamama yardımcı olan herkese içten teşekkürlerimi sunarım.

İÇİNDEKİLER

	Sayfa
ÖZET	iv
ABSTRACT	v
TEŞEKKÜR	vi
İÇİNDEKİLER	vii
ÇİZELGELERİN LİSTESİ	ix
ŞEKİLLERİN LİSTESİ	xi
RESİMLERİN LİSTESİ	xvii
SİMGELER VE KISALTMALAR	xviii
1. GİRİŞ	1
2. İNSANSIZ HAVA ARAÇLARININ TARİHÇESİ	5
2.1. İnsansız Hava Araçları ve Kullanım Alanları	8
2.1.1. Havacılıkta kullanılan pervaneler ve tarihçesi	10
2.1.2. Pervane teorisi	13
2.2. Havacılıkta Rüzgar Tüneli Kullanımı	26
2.2.1. Rüzgar tüneli çeşitleri	30
2.2.2. Rüzgar tünellerinde akış benzerliği	35
2.2.3. Rüzgar tüneli ölçümleri	35
2.3. Yapay Sinir Ağları (YSA)	36
2.3.1. Yapay sinir ağlarının tarihçesi	37
2.3.2. Yapay sinir ağlarının özellikleri	39
2.3.3. Yapay sinir ağlarının uygulama alanları	41
2.3.4. Yapay sinir ağlarının yapısı	42
3. LİTERATÜR ARAŞTIRMASI	55
4. MATERYAL VE METOD	67
4.1. Pervane Modellenmesi	67
4.2. Simülasyon Pervane Veri Seti İncelenmesi ve Düzenlenmesi	67

Sayfa

4.3. Pervane Modeli Kurulma Hazırlıkları	75
4.3.1. Pervane modelinin Python’da oluşturulması	78
4.4. Rüzgar Tüneli Veri Seti İncelenmesi ve Yapay Sinir Ağı Modeli Kurma Hazırlıkları	125
4.4.1. Rüzgar tüneli “sport” tip pervane itki katsayısı modelinin eğitime hazırlanması ve parametrelerin belirlenmesi	128
4.4.2. Rüzgar tüneli “sport” tip pervane itki katsayısı modelinin eğitilmesi ve model çıktıları	132
4.4.3. Rüzgar tüneli “sport” tip pervane güç katsayısı modelinin eğitime hazırlanması ve parametrelerin belirlenmesi	133
4.4.4. Rüzgar tüneli “sport” tip pervane güç katsayısı modelinin eğitilmesi ve model çıktıları	137
4.4.5. Rüzgar tüneli “thin elektrik” tip pervane itki katsayısı modelinin eğitime hazırlanması ve parametrelerin belirlenmesi	139
4.4.6. Rüzgar tüneli “thin elektrik” tip pervane itki katsayısı modelin eğitilmesi ve model çıktıları	143
4.4.7. Rüzgar tüneli “thin elektrik” tip pervane itki katsayısı modelinin eğitime hazırlanması ve parametrelerin belirlenmesi	144
4.4.8. Rüzgar tüneli “thin elektrik” tip pervane itki katsayısı modelin eğitilmesi ve model çıktıları	148
4.5. Rüzgar Tüneli Yapay Sinir Ağı Modellerinin Karşılaştırılması	149
5. SONUÇ VE ÖNERİLER	151
KAYNAKLAR	153
ÖZGEÇMİŞ	157

ÇİZELGELERİN LİSTESİ

Çizelge	Sayfa
Çizelge 2.1. NATO UAS sınıflandırma	9
Çizelge 2.2. Rüzgar tüneli tiplerinin avantajları ve dezavantajları	34
Çizelge 2.3. YSA ile ilgili yapılan çalışmaların kronolojik sıralaması.....	38
Çizelge 2.4. YSA ve sinir hücrelerin benzerliği	44
Çizelge 2.5. YSA ile istatistiksel yöntemlerin benzerlikleri	44
Çizelge 4.1. StandartScaler ilk üç işlemi	77
Çizelge 4.2. “Sport” tip pervane için Ct tahmini yapmak için oluşturulan modelin yapısı ve özeti	81
Çizelge 4.3. Optimum model belirlemek için kullanılan “Epoch” sayıları ve modeller	85
Çizelge 4.4. “Epoch” Değerlerine göre “Sport” Ct model performanslarının kayıp fonksiyonlarına göre ve R^2 yöntemine göre karşılaştırılması	86
Çizelge 4.5. “Sport” tip pervane için Cp tahmini yapmak için oluşturulan modelin yapısı ve özeti	94
Çizelge 4.6. “Epoch” Değerlerine göre “Sport” Cp model performanslarının kayıp fonksiyonlarına göre ve R^2 yöntemine göre karşılaştırılması	95
Çizelge 4.7. “Thin Elektrik” tip pervane için Ct tahmini yapmak için oluşturulan modelin yapısı ve özeti	105
Çizelge 4.8. “Epoch” Değerlerine göre “Thin Elektrik” Ct model performanslarının kayıp fonksiyonlarına göre ve R^2 yöntemine göre karşılaştırılması.....	106
Çizelge 4.9. “Thin Elektrik” tip pervane için Cp tahmini yapmak için oluşturulan modelin yapısı ve özeti	115
Çizelge 4.10. “Epoch” Değerlerine göre “Thin Elektrik” Cp model performanslarının kayıp fonksiyonlarına göre ve R^2 yöntemine göre karşılaştırılması.....	116
Çizelge 4.11. Simülasyon veri setiyle oluşturulan 4 farklı modelin özellikleri ve R^2 performansı	125

Çizelge	Sayfa
Çizelge 4.12. Rüzgar tüneli “Sport” tip pervane için Ct tahmini yapmak için oluşturulan modelin yapısı ve özeti	129
Çizelge 4.13. Rüzgar tüneli “Sport” Ct tahmin modeli “Epoch” Değerlerine göre model performanslarının kayıp fonksiyonlarına göre ve R^2 yöntemine göre karşılaştırılması	130
Çizelge 4.14. Rüzgar tüneli “Sport” tip pervane için Cp tahmini yapmak için oluşturulan modelin yapısı ve özeti	134
Çizelge 4.15. Rüzgar tüneli “Sport” Cp tahmin modeli “Epoch” değerlerine göre model performanslarının kayıp fonksiyonlarına göre ve R^2 yöntemine göre karşılaştırılması	135
Çizelge 4.16. Rüzgar tüneli “Thin Elektrik” tip pervane için Ct tahmini yapmak için oluşturulan modelin yapısı ve özeti.....	140
Çizelge 4.17. Rüzgar tüneli “Thin Elektrik” Ct tahmin modeli “Epoch” değerlerine göre model performanslarının kayıp fonksiyonlarına göre ve R^2 yöntemine göre karşılaştırılması	141
Çizelge 4.18. Rüzgar tüneli “Thin Elektrik” tip pervane için Cp tahmini yapmak için oluşturulan modelin yapısı ve özeti.....	145
Çizelge 4.19. Rüzgar tüneli “Thin Elektrik” Cp tahmin modeli “Epoch” değerlerine göre model performanslarının kayıp fonksiyonlarına göre ve R^2 yöntemine göre karşılaştırılması	146
Çizelge 4.20. Rüzgar tüneli veri seti ve simülasyon tahmin veri seti kullanılarak oluşturulan “Sport” ve “Thin Elektrik” tip pervaneler için yapay sinir ağı modelleri	150

ŞEKİLLERİN LİSTESİ

Şekil	Sayfa
Şekil 2.1. Pervane çapı ölçümü.....	12
Şekil 2.2. Pervane hatve ölçümü.....	13
Şekil 2.3. Taşıyıcı diskten geçen hava	14
Şekil 2.4. Pervane geometrik hatvesi	18
Şekil 2.5. Pervane geometrik hatvesinin pervane performansına etkisi	19
Şekil 2.6. Pervane performansı üzerindeki hatve etkisi	19
Şekil 2.7. Pervane performansı üzerindeki hatve ve ilerleme oranı değişimi.....	20
Şekil 2.8. Pervaneye etki eden kuvvetler	20
Şekil 2.9. Pervane kanat bölümüne etki eden kuvvetler	23
Şekil 2.10. Pervane diskinin dairesel elemanı	24
Şekil 2.11. w 'nin dF etkisine paralel bileşeni.....	25
Şekil 2.12. Büyük uçak programları için rüzgâr tüneli test saatlerinin geçmişi	28
Şekil 2.13. Geçmişten günümüze kadar olan bazı uçak geliştirme programlarındaki rüzgar tüneli test saatleri	28
Şekil 2.14. Rüzgar tünelleri için Mach sayısı aralıkları.....	30
Şekil 2.15. Kapalı devre tipi rüzgar tüneli konsepti.....	30
Şekil 2.16. Açık devre tipi rüzgar tüneli konsepti	32
Şekil 2.17. Basınç salınımlı tip rüzgar tüneli konsepti	33
Şekil 2.18. Yapay sinir ağı model yapısı örneği	37
Şekil 2.19. Bir gizli katmana ve üç düğüme sahip bir sinir ağı örneği	40
Şekil 2.20. Sinir hücresi	43
Şekil 2.21. Yapay sinir hücresi	45
Şekil 2.22. Doğrusal aktivasyon fonksiyonu	47

Şekil	Sayfa
Şekil 2.23. Sigmoid fonksiyonu.....	48
Şekil 2.24. Çok katmanlı yapay sinir ağları.....	49
Şekil 2.25. Yapay sinir ağlarının sınıflandırılması	50
Şekil 2.26. Geri beslemeli yapay sinir ağları	51
Şekil 2.27. Öğretmeli öğrenme	52
Şekil 3.1. APC 14x10 Thin elektrik pervanesinin rüzgar tüneli performansı: (a) itme katsayısı, (b) güç katsayısı	55
Şekil 3.2. APC Pervaneler için analitik ve deneysel (a) itme ve (b) tork katsayıları.....	56
Şekil 3.3. Uçuş esnasında ölçülen pervane itki ve devri.....	58
Şekil 3.4. APC 8x8 Thin elektrik pervane için a) İtme Katsayısı (Ct) ve b) Güç katsayısı (Cp) karşılaştırmaları	60
Şekil 3.5. Farklı PWM değerleri için test edilen pervane seti için ilerleme oranının bir fonksiyonu olarak itme-güç oranı: (a) %40; (b) %60; (c) %80; (d) %90.....	61
Şekil 3.6. Pervane-uçak entegrasyonunda kullanılan çözümün kanatta oluşan kaldırma kuvvetine etkisinin karşılaştırılması.....	62
Şekil 3.7. Pervanesinin farklı yüksekliklerde 5 m/s rüzgar hızıyla itme kuvveti, a) 0,5 km; b) 3,6 km.....	63
Şekil 3.8. Deney, teori ve CFD metodları kullanılarak pervane performansının değerlendirilmesi.....	64
Şekil 3.9. XOAR 26x16 pervanesinin deneysel olarak ve HAM analiz yöntemi ile elde edilmiş itki katsayısı (Ct) değerlerinin karşılaştırılması	64
Şekil 4.1. “Sport” tip pervane RPM= 4 000, Hatve= 10, J= 0 için artan pervane çapına göre Ct (İtme Katsayısı Değişimi).....	69
Şekil 4.2. “Thin Elektrik” tip pervane RPM= 2 000, Hatve= 6, J= 0 için artan pervane çapına göre Cp (Güç Katsayısı Değişimi).....	70
Şekil 4.3. “Sport” tip pervane RPM= 2 000, Çap= 10, J= 0 için artan pervane hatvesine göre Ct (İtme Katsayısı Değişimi)	71
Şekil 4.4. “Thin Elektrik” tip pervane RPM= 3 000, Çap= 13, J= 0 için artan pervane hatvesine göre Cp (Güç Katsayısı Değişimi)	72

Şekil	Sayfa
Şekil 4.5. “Sport” 22x10 J-Cp Değerlerinin RPM’e göre değişim grafiği	73
Şekil 4.6. “Sport” 22x10 J-Ct Değerlerinin RPM’e göre değişim grafiği	73
Şekil 4.7. “Sport” 11x5 Pervanenin Ct için değişken RPM değerlerine göre a, b, c, d, e katsayıları.....	75
Şekil 4.8. “Sport” tip pervane Ct tahmin modeli 3 000 “Epoch”	83
Şekil 4.9. “Sport” tip pervane Ct tahmin modeli 2 000 “Epoch”	84
Şekil 4.10. “Sport” tip pervane Ct tahmin modeli 1 000 “Epoch”	84
Şekil 4.11. “Sport” Ct tahmin modeli Predictions-Real Values grafiği.....	87
Şekil 4.12. “Sport” Ct Modelin RPM’lere göre “a” değeri tahmin performansı	88
Şekil 4.13. “Sport” Ct Modelin RPM’lere göre “b” değeri tahmin performansı.....	89
Şekil 4.14. “Sport” Ct Modelin RPM’lere göre “c” değeri tahmin performansı	89
Şekil 4.15. “Sport” Ct Modelin RPM’lere göre “d” değeri tahmin performansı.....	90
Şekil 4.16. “Sport” Ct Modelin RPM’lere göre “e” değeri tahmin performansı	90
Şekil 4.17. “Sport” Tip pervane Ct tahmin modeli 11x5 Pervane 1 000 RPM model performansı	91
Şekil 4.18. “Sport” Tip pervane Ct tahmin modeli 22x10 Pervane 5 000 RPM model performansı	91
Şekil 4.19. “Sport” 22x10 Pervanenin Cp için değişken RPM değerlerine göre a, b, c, d, e, f katsayıları	93
Şekil 4.20. “Sport” Tip pervane Cp tahmin modeli 1 000 “Epoch”	96
Şekil 4.21. “Sport” Tip pervane Cp tahmin modeli 2 000 “Epoch”	96
Şekil 4.22. “Sport” Tip pervane Cp tahmin modeli 3 000 “Epoch”	97
Şekil 4.23. “Sport” Tip pervane Cp tahmin modeli 3 500 “Epoch”	97
Şekil 4.24. “Sport” Cp Tahmin modeli Predictions-Real Values grafiği	98
Şekil 4.25. “Sport” Cp Modelin RPM’lere göre “a” değeri tahmin performansı	99
Şekil 4.26. “Sport” Cp Modelin RPM’lere göre “b” değeri tahmin performansı	99

Şekil	Sayfa
Şekil 4.27. “Sport” Cp Modelin RPM’lere göre “c” değeri tahmin performansı	100
Şekil 4.28. “Sport” Cp Modelin RPM’lere göre “d” değeri tahmin performansı	100
Şekil 4.29. “Sport” Cp Modelin RPM’lere göre “e” değeri tahmin performansı	101
Şekil 4.30. “Sport” Cp Modelin RPM’lere göre “f” değeri tahmin performansı.....	101
Şekil 4.31. “Sport” Tip pervane Cp tahmin modeli 10x8 pervane 3 000 RPM model performansı	102
Şekil 4.32. “Thin Elektrik” 18x12 J-Cp değerlerinin RPM’e göre değişim grafiği	103
Şekil 4.33. “Thin Elektrik” 18x12 J-Ct değerlerinin RPM’e göre değişim grafiği	103
Şekil 4.34. “Thin Elektrik” 24x12 Pervanenin Cp için değişken RPM değerlerine göre a, b, c, d, e katsayıları	104
Şekil 4.35. “Thin Elektrik” tip pervane Ct tahmin modeli 1 000 “Epoch”	107
Şekil 4.36. “Thin Elektrik” tip pervane Ct tahmin modeli 2 000 “Epoch”	107
Şekil 4.37. “Thin Elektrik” tip pervane Ct tahmin modeli 3 000 “Epoch”	108
Şekil 4.38. “Thin Elektrik” Ct tahmin modeli Predictions-Real Values grafiği.....	109
Şekil 4.39. “Thin Elektrik” Ct Modelin RPM’lere göre “a” değeri tahmin performansı	110
Şekil 4.40. “Thin Elektrik” Ct Modelin RPM’lere göre “b” değeri tahmin performansı	110
Şekil 4.41. “Thin Elektrik” Ct Modelin RPM’lere göre “c” değeri tahmin performansı	111
Şekil 4.42. “Thin Elektrik” Ct Modelin RPM’lere göre “d” değeri tahmin performansı	111
Şekil 4.43. “Thin Elektrik” Ct Modelin RPM’lere göre “e” değeri tahmin performansı	112
Şekil 4.44. “Thin Elektrik” Tip pervane Ct tahmin modeli 10x5 Pervane 4 000 RPM model performansı.....	113
Şekil 4.45. “Thin Elektrik” 14x7 Pervanenin Cp için değişken RPM değerlerine göre a, b, c, d, e katsayıları	114
Şekil 4.46. “Thin Elektrik” tip pervane Cp tahmin modeli 1 000 “Epoch”	117

Şekil	Sayfa
Şekil 4.47. “Thin Elektrik” tip pervane Cp tahmin modeli 2 000 “Epoch”	117
Şekil 4.48. “Thin Elektrik” tip pervane Cp tahmin modeli 3 000 “Epoch”	118
Şekil 4.49. “Thin Elektrik” tip pervane Cp tahmin modeli 5 000 “Epoch”	118
Şekil 4.50. “Thin Elektrik” tip pervane Cp tahmin modeli 7 000 “Epoch”	119
Şekil 4.51. “Thin Elektrik” Cp tahmin modeli Predictions-Real Values grafiği	120
Şekil 4.52. “Thin Elektrik” Cp Modelin RPM’lere göre “a” değeri tahmin performansı	121
Şekil 4.53. “Thin Elektrik” Cp Modelin RPM’lere göre “b” değeri tahmin performansı	121
Şekil 4.54. “Thin Elektrik” Cp Modelin RPM’lere göre “c” değeri tahmin performansı	122
Şekil 4.55. “Thin Elektrik” Cp Modelin RPM’lere göre “d” değeri tahmin performansı	122
Şekil 4.56. “Thin Elektrik” Cp Modelin RPM’lere göre “e” değeri tahmin performansı	123
Şekil 4.57. “Thin Elektrik” Tip Pervane Cp tahmin modeli 5x3 Pervane 3 000 RPM model performansı	124
Şekil 4.58. “Thin Elektrik” Tip 14x7 pervanenin rüzgar tüneli Ct/Cp değerlerinin simülasyon model tahmininin karşılaştırılması	127
Şekil 4.59. “Sport” Tip 10x4 pervanenin rüzgar tüneli Ct/Cp değerlerinin simülasyon model tahmininin karşılaştırılması	127
Şekil 4.60. Rüzgar tüneli “Sport” tip pervane Ct tahmin modeli 1 000 “Epoch”	131
Şekil 4.61. Rüzgar tüneli “Sport” tip pervane Ct tahmin modeli 2 000 “Epoch”	131
Şekil 4.62. Rüzgar tüneli “Sport” Ct tahmin modeli Predictions-Real Values grafiği...	132
Şekil 4.63. Rüzgar tüneli “Sport” tip pervane Ct tahmin modeli 10x10 pervane 2 000 RPM model performansı	133
Şekil 4.64. Rüzgar tüneli “Sport” tip pervane Cp tahmin modeli 500 “Epoch”	136
Şekil 4.65. Rüzgar tüneli “Sport” tip pervane Cp tahmin modeli 1 000 “Epoch”	136
Şekil 4.66. Rüzgar tüneli “Sport” tip pervane Cp tahmin modeli 2 000 “Epoch”	137

Şekil	Sayfa
Şekil 4.67. Rüzgar tüneli “Sport” Cp tahmin modeli Predictions-Real Values grafiği.....	138
Şekil 4.68. Rüzgar tüneli “Sport” tip pervane Cp tahmin modeli 10x7 pervane 6 000 RPM model performansı.....	139
Şekil 4.69. Rüzgar tüneli “Thin Elektrik” tip pervane Ct tahmin modeli 500 “Epoch”	142
Şekil 4.70. Rüzgar tüneli “Thin Elektrik” tip pervane Ct tahmin modeli 1 000 “Epoch”	142
Şekil 4.71. Rüzgar tüneli “Thin Elektrik” Ct tahmin modeli Predictions-Real Values grafiği.....	143
Şekil 4.72. Rüzgar tüneli “Thin Elektrik” tip pervane Ct tahmin modeli 14x10 pervane 6 000 RPM model performansı	144
Şekil 4.73. Rüzgar tüneli “Thin Elektrik” tip pervane Cp tahmin modeli 500 “Epoch”	147
Şekil 4.74. Rüzgar tüneli “Thin Elektrik” tip pervane Cp tahmin modeli 1 000 “Epoch”	147
Şekil 4.75. Rüzgar tüneli “Thin Elektrik” Cp tahmin modeli Predictions-Real Values grafiği.....	148
Şekil 4.76. Rüzgar tüneli “Thin Elektrik” tip pervane Cp tahmin modeli 19x12 pervane 3 000 RPM model performansı	149

RESİMLERİN LİSTESİ

Resim	Sayfa
Resim 2.1. Uçan bomba	5
Resim 2.2. Kettering Bug.....	6
Resim 2.3. IAI – RQ-2 Pioneer.....	6
Resim 2.4. TUSAŞ-ANKA insansız hava aracı.....	7
Resim 2.5. VTOL İHA Havelsan Baha.....	10
Resim 2.6. Çin oyuncacı	11
Resim 2.7. Leonardo da Vinci’nin “Helikopteri”, 15. Yüzyıl	11
Resim 2.8. Yıllara göre pervaneler	12
Resim 2.9. Havacılıkta rüzgar tüneli uygulaması	27
Resim 2.10. Roket transonik rüzgar tüneli testi.....	36
Resim 3.1. APC pervane.	55
Resim 3.2. Pervane testleri için kullanılan rüzgar tüneli.....	59

SİMGELER VE KISALTMALAR

Bu çalışmada kullanılmış simgeler ve kısaltmalar, açıklamaları ile birlikte aşağıda sunulmuştur.

Simgeler

Açıklamalar

A	Pervane disk alanı
B	Pervane pal sayısı
C_D	Kanat kesitinin direnç katsayısı
C_d	Aerodinamik sürtünme katsayısı
C_L	Kanat kesitinin kaldırma katsayısı
C_m	Pervane Profili Moment katsayısı
C_p	Güç katsayısı
C_T	İtke katsayısı
Cl	Kaldırma kuvveti
Da	Pervane alanı
da	Pervane çapı
dF	Yerel sonsuz küçük itke
dL	Lift kuvveti
dN	Dikey moment
dQ	Tork
dr	Pervane kalınlığı
dS	Pervane yüzey alanı
F	İleri itke kuvveti
ft	Feet
J	Pervane ileri hız katsayısı
kg	Kilogram
km	Kilometre

Simgeler

Açıklamalar

m	Metre
mph	Saatte mil
n	Pervane şaft devri
n_{ideal}	İdeal verim
$n_p r$	Gerçek pervane verimi
P	Güç
p_0	Girişteki atmosfer basıncı
p_1	Aktüatör diskinin önündeki basınç
p_2	Aktüatör diskinin arkasındaki basınç
p_3	Çıkıştaki atmosfer basıncı
p_∞	Serbest akış basıncı
P_{ideal}	İdeal güç
$P_{şaft}$	Şaft gücü
Q	Toplam tork
S	Disk alanı
T	İtke kuvveti
U	Disk üzerindeki hava hızı
U_∞	Pervaneye gelen hava
U_s	Disk sonrası havanın hızı
V	Pervane hızı
V_0	Hava akış hızı
V_1	Aktüatör diskinin önündeki hız
V_2	Aktüatör diskinin arkasındaki hız
V_3	Çıkış hızı
V_∞	Serbest akış hızı / Uçağın ileri hızı
V_E	Toplam sonuç hızı

Simgeler**Açıklamalar**

V_R	Bileşke hız
V_T	Pervane uç hızı
V_{tip}	Pervane uç hızı
w	İndüklenen hız
wr	Açısal hız
α	Hücum açısı
α_i	İndüklenmiş hücum açısı
λ	Uç hız oranı
π	Pi sayısı
ρ	Hava yoğunluğu
σ	Yerel izdüşüm alanı oranı
σ_{ref}	Referans izdüşüm alanı oranı
ϕ	Kanat eğim açısı

Kısaltmalar**Açıklamalar**

ADALINE	Adaptif doğrusal eleman
AGL	Yerden yükseklik
AI	Yapay zeka
AR-GE	Araştırma ve Geliştirme
ART	Adaptif Rezonans Teorisi
BEM	Kanat Elemanı Teorisi
BEMT	Kanat Elemanı Momentum Teorisi
BLOS	Görüş hattı ötesi
CAD	Bilgisayar destekli çizim

Kısaltmalar**Açıklamalar**

CFD	Akışkanlar dinamiği analizi
DOF	Altı serbestlik derecesi
FOM	Başarım ölçüsü
HAD	Hesaplamalı akışkanlar dinamiği
HALE	Yüksek irtifa uzun havada kalış süresi
HAVELSAN	Hava Elektronik Sanayii A.Ş.
HEM	Hesaplamalı akışkanlar mekaniği
LOS	Görüş hattı
LVQ	Lineer vektör parçalama
MACH	Kütlenin hızının ses hızına oranı
MAE	Ortalama mutlak hata
MALE	Orta irtifa uzun havada kalış süresi
MSE	Ortalama karesel hata
MSL	Deniz seviyesinden yükseklik
NATO	Kuzey Atlantik Antlaşması Örgütü
OCR	Optik kamera tanıma
R2	Regresyon Analiz Yöntemi
RC	Radyo kontrol
RMSE	Karekök ortalama kare hata
RPM	Dakikada dönüş sayısı
TUSAŞ	Türk Havacılık ve Uzay Sanayii A.Ş.
UAS	İnsansız hava aracı sistemi
VTOL	Dikey Kalkış ve İniş
XFOİL	Kanat Profil Tasarım ve Analiz Programı
YSA	Yapay sinir ağı
YSH	Yapay sinir hücreleri

Kısaltmalar**Açıklamalar****İHA**

İnsansız hava aracı

İÖS

İtki ölçüm sistemi

1. GİRİŞ

Havacılık sektörü, insanlı ve insansız hava araçları dahil olmak üzere çeşitli hava araçlarının tasarımı, üretimi ve işletimiyle ilgili geniş bir alandır. Bu alandaki sürekli teknolojik ilerlemeler, havacılık endüstrisinin sürekli olarak dönüşmesine ve gelişmesine neden olmuştur. Günümüzde, havacılık sektöründeki araştırma ve geliştirme faaliyetleri, uçakların aerodinamik performansını artırmak, güvenliği sağlamak, enerji verimliliğini artırmak ve operasyonel maliyetleri azaltmak gibi bir dizi hedefe odaklanmıştır.

İnsanlı ve insansız hava araçları, farklı amaçlar için tasarlanmıştır ve her birinin benzersiz avantajları vardır. İnsansız hava araçları, insanlı hava araçlarına göre çeşitli avantajlar sunar. Örneğin, İHA'lar, tehlikeli veya zorlu ortamlarda insanların risk almadan görevleri yerine getirmesine olanak tanırken, insanlı uçaklar genellikle daha büyük yükleri taşıma ve daha uzun menzillerde uçuş yapma yeteneğine sahiptir.

Havacılık sektörü, günümüzde hızla gelişen ve çeşitlenen teknolojilerle birlikte önemli bir dönüşüm yaşamaktadır. Bu dönüşümün en dikkat çekici unsurlarından biri, İnsansız Hava Araçları'nın kullanımının giderek artmasıdır. İHA'lar, geniş bir uygulama yelpazesine sahip olan, havacılık alanında önemli ve hızla büyüyen bir sektördür.

İHA'lar, askeri, sivil ve ticari alanlarda çeşitli amaçlarla kullanılmaktadır. Özellikle son yıllarda, İHA'lar askeri alanda keşif, gözetleme, hedef tespiti ve insansız hava saldırıları gibi görevlerde yaygın bir şekilde kullanılmaktadır. Bununla birlikte, sivil alanda da İHA'ların çeşitli uygulamaları bulunmaktadır. Örneğin, tarım alanında, çiftçilerin tarlalarını izlemesi, bitki hastalıklarını tespit etmesi ve tarım ilaçlarını püskürtmesi için İHA'lar kullanılmaktadır. Ayrıca, doğal afetlerin izlenmesi, yangın söndürme operasyonları, arama kurtarma faaliyetleri ve haritalama gibi çeşitli hizmetlerde de İHA'lar etkin bir şekilde kullanılmaktadır. Geleneksel hava araçlarına kıyasla daha düşük maliyetli, daha esnek ve daha verimli bir seçenek olarak İHA'lar, birçok uygulama alanında tercih edilmektedir.

Bunun yanı sıra İHA'ların tasarımı, bir dizi karmaşık mühendislik ve teknoloji disiplini içerir. İlk olarak, hedeflenen kullanım alanına uygun bir tasarım yapılmalıdır. Örneğin, askeri keşif görevleri için tasarlanan bir İHA ile tarım alanındaki gözetleme görevleri için tasarlanan bir İHA'nın farklı gereksinimlere sahip olması muhtemeldir. Tasarım

aşamasında, İHA'nın uçuş menzili, hızı, taşıma kapasitesi ve operasyonel yetenekleri gibi faktörler de dikkate alınmalıdır.

İHA'ların itki sistemleri, uçuş performansını belirleyen önemli unsurlardan biridir. İtki sistemi, İHA'nın havalanması, seyir halinde kalması ve istenilen rotada hareket etmesi için gerekli olan gücü sağlar. Bu sistem genellikle motorlar ve pervanelerden oluşur. İHA'larda kullanılan motorlar genellikle hafif, güçlü ve yakıt verimliliği yüksek olmalıdır. Elektrik motorları, içten yanmalı motorlara kıyasla daha sessiz ve çevre dostu bir seçenek olarak öne çıkmaktadır. Ancak elektrik motoruyla beraber gelecek olan batarya paketi ve buna bağlı ağırlık faktöründen dolayı elektrik motoru kullanılan İHA'lar havada kalış süresi olarak içten yanmalı motorlara göre daha az havada kalabilmektedir. İHA'larda motor seçimi tasarlanacak olan İHA'nın konseptine göre değişiklik göstermektedir. Motor seçiminden sonra motoru verimli ve optimum koşullarda kullanabilmek için de pervane seçilmesi gerekmektedir. Bunun için günümüzde çeşitli modellemeler, rüzgar tüneli testleri ve uçuş testleri yapılmaktadır.

İHA'ların tasarımı ve performansının değerlendirilmesi için rüzgar tüneli testleri ve simülasyonlar önemli bir rol oynar. Rüzgar tüneli testleri, İHA'nın aerodinamik özelliklerini belirlemek ve performansını optimize etmek için kullanılır. Ayrıca, simülasyonlar sayesinde farklı uçuş senaryoları modellenabilir ve İHA'nın davranışı önceden tahmin edilebilir. İHA'ların aerodinamik performansını etkileyen önemli bir unsurlardan biri de pervanelerdir. Pervaneler, motorun ürettiği gücü itiş kuvvetine dönüştürerek İHA'nın havada kalmasını sağlar. Bu nedenle, pervanelerin aerodinamik tasarımı, verimlilik ve gürültü gibi faktörler göz önünde bulundurularak dikkatle yapılmalıdır. İnsansız hava araçlarının pervane seçimi sürecinde, çeşitli yöntemler ve teknikler kullanılarak detaylı bir analiz yapılır. Bu analizlerin temelinde CAD, CFD analizleri, yapay sinir ağları, makine öğrenmesi, uçuş testleri ve rüzgar tüneli deneyleri gibi araştırma ve test yöntemleri yer alır. Bilgisayar destekli tasarım, pervane tasarımının bilgisayar ortamında gerçekleştirilmesini sağlar. Bu yöntem sayesinde pervane geometrisi, malzeme seçimi ve yapısal özellikler detaylı bir şekilde modellenabilir. Akışkanlar dinamiği analizleri, pervane tasarımının aerodinamik performansını değerlendirmek için kullanılır. Bu analizler, pervane üzerindeki hava akışını simüle ederek itme gücü, verimlilik ve tork gibi önemli parametreleri belirler.

Uçuş testleri, gerçek dünya koşullarında pervane performansını doğrulamak ve tasarımı optimize etmek için önemlidir. Bu testlerde İHA, farklı hava koşullarında ve yüksekliklerde uçurularak pervane performansı değerlendirilir. Son olarak, rüzgar tüneli deneyleri de pervane seçimi sürecinde kullanılır. Bu deneylerde, İHA pervanelerinin aerodinamik özellikleri farklı rüzgar koşullarında test edilerek performansları değerlendirilir. Bu çeşitli yöntemlerin entegrasyonu, en uygun pervane tasarımının belirlenmesinde ve İHA'nın optimum performansının sağlanmasında kritik öneme sahiptir.

Bu çalışmada İHA'ların pervanelerinin aerodinamik davranışlarını belirlemek için yapay sinir ağları ve makine öğrenmesi uygulamaları tercih edilmiştir. Yapay sinir ağları ve makine öğrenmesi gibi teknolojiler, simülasyonlarda ve veri analizinde önemli bir rol oynar. Yapay sinir ağları, karmaşık veri setlerinden öğrenme yeteneğine sahip yapay zekâ modelleridir. Makine öğrenmesi ise, algoritmaların veri setlerinden öğrenme ve örüntüleri tanıma yeteneğine dayanır. Bu teknolojiler, İHA tasarımında ve performans analizinde ve pervanelerin aerodinamik davranışlarının belirlenmesinde daha kesin sonuçlar elde etmek için kullanılır.

İnsansız hava araçları için pervanelerin aerodinamik performansını belirlemek amacıyla yapay sinir ağları kullanılarak veri setleri karşılaştırılacak ve gerçek ortamı temsil eden veriler elde edilmesine yönelik yöntemler izlenecektir. Odak noktası, İHA pervanelerinin simülasyon test verileri ile rüzgar tüneli test verilerinin entegrasyonu yapmak ve bunun sonucunda gerçeğe en yakın sonuca ulaşmaktır. İlk olarak, İHA pervaneleri için simülasyon test verileri, Python kullanılarak belirli bir formata dönüştürülüp yapay sinir ağlarıyla modellemeler gerçekleştirilecektir. Bu modellemelerin, gerçek dünya koşullarını simüle etmek için rüzgar tüneli test verileriyle karşılaştırılması yapılarak İHA pervanelerinin aerodinamik performansının anlaşılması amaçlanmaktadır. Bu yöntemlerle, İHA pervanelerinin aerodinamik performansının etkili bir şekilde modellenmesini ve değerlendirilmesini sağlamak için önemli bir adımdır. Bu çalışma ile, insansız hava araçlarının itki sistemlerinde kullanılan pervane seçimini belirlemek ve ardından uygun motoru seçebilmek mümkün olacaktır. Bu çalışmanın amacı, yapay sinir ağları temelli bir yöntemi kullanarak pervane ve motorun birlikte optimize edilmesi, insansız hava araçlarının aerodinamik performansını çeşitli yönlerden olumlu yönde etkilenmesini amaçlamaktadır. Öncelikle, bu optimize edilmiş sistemler, İHA'ların daha yüksek hızlara ulaşmasına ve daha uzun süre havada kalmasına olanak tanır. Bu durum, İHA'ların görev

süresini artırarak daha geniş operasyonel alanlarda kullanılmasını sağlar. Ayrıca, iyi tasarlanmış pervane ve motor kombinasyonları, İHA'ların daha iyi manevra kabiliyetine sahip olmasını sağlar, böylece çeşitli görevlerin daha etkili bir şekilde yerine getirilmesine olanak tanır. Bunun yanı sıra, optimize edilmiş sistemler daha az gürültü ve titreşim üretir, bu da İHA'ların sessiz ve stabil bir şekilde çalışmasını sağlar ve operasyonel olarak daha az dikkat çekici hale getirir. Son olarak, verimli bir şekilde çalışan pervane ve motorlar daha az enerji tüketir, bu da İHA'ların daha uzun mesafeleri katedebilmesini ve operasyonel maliyetlerin azalmasını sağlar. Bu nedenle, pervane ve motorun birlikte optimize edilmesi, İHA'ların genel performansını artırarak daha etkili ve verimli hale gelmesini sağlamaktadır.

2. İNSANSIZ HAVA ARAÇLARININ TARİHÇESİ

İnsansız hava araçları, temel olarak içerisinde pilot bulundurmayan uçan bir araçtır. İHA'nın kullanımı için otonom uçuş algoritmalarına veya uçuş anında kontrol edilebilecek uzaktan kumandaya ihtiyaç vardır. İHA'ların yeni geliştiği dönemlerde uçağın uçuş konumunu kontrol etmek için mekanik ve jiroskopik cihazlar kullanılmıştır. Resim 2.1.'de gösterilen ve daha çok Sperry "Uçuş Bomba" olarak bilinen Hewitt-Sperry Otomatik Uçağı, modern İHA'ların ve seyir füzelerinin atası olarak kabul edilmektedir. Uçuş görevi önceden tanımlanmış hedefleri vurma kapasitesine sahip olan jiroskop tabanlı bir mekanik otopilot tarafından kontrol edilmektedir [1].



Resim 2.1. Uçuş bomba [1]

Resim 2.2.'de görülen daha eski İHA olarak Kettering Bug hava torpidosu olarak adlandırılan İHA, radyo kontrollü olarak hareket kabiliyeti bulunan, yani uzaktan kumandalı, uçaktı. Jiroskopla stabilize edilmiş düz rota yerine dairesel bir rota da uçuş kabiliyetine sahiptir. Bundan sonra çok sayıda hedef İHA geliştirilmiştir. 1930'lu yıllarda askeri uçakların çoğu radyo kontrollü uçaklara dönüştürülmüştür. [2].



Resim 2.2. Kettering Bug [2]

Gözetleme ve keşif görevlerine uygun bir İHA'ların geliştirilmesi, elektronik ve haberleşme teknolojilerinin yeteri kadar gelişmemesinden dolayı soğuk savaşın sonlarına kadar kullanılamamıştır. Bu nedenle İHA uygulamaları uzun süre sınırlı kalmıştır. Bu uygulamalar dolanan mühimmatlar, seyir füzeleri ve hedef insansız hava araçları ana uygulamaların başını çekmektedir.

1970'lerin sonlarında ve 1980'lerde elektronik donanımlar ve bilgisayar teknolojisindeki gelişmelerle birlikte tam otonom/önceden tanımlı uçuş mümkün hale gelmiştir. Kompozit malzeme teknolojisi de geliştirilerek uçağın ağırlığının azaltılması, menzil ve dayanıklılığın artırılması sağlanmıştır. Resim 2.3.'de görülen IAI – RQ-2 İHA bu dönemden sonra gelişmiş İHA'lardan biridir. [3]



Resim 2.3. IAI – RQ-2 Pioneer [3]

1980'lerden itibaren birçok ülkenin ilgi duymaya başladığı İHA'lar, Bosna-Hersek, Kosova, Afganistan, Irak, Filistin, Lübnan, Yemen, Pakistan, Libya, Mali ve Suriye çatışma bölgelerinde kullanılarak savaş ortamlarında kendini kanıtlamayı başarmıştır. Başlarda sadece keşif ve gözetleme aracı olarak kullanılan İHA'lar zamanla silahlandırılarak her iki görevi yerine getirebilen başarılı bir savaş platformuna dönüşmüştür. İHA'ların gelişim sürecinin uçakların gelişim sürecine oldukça benzediği görülmektedir. İlk insanlı savaş uçakları bilindiği üzere keşif-gözetleme araçları olarak kullanılmaktaydı. Daha sonraki dönemlerde uçaklar küçük bombaların el ile veya mekanik olarak serbest bırakılması için kullanılmıştır. Modern İHA'lar da bir keşif-gözetleme platformu olarak ortaya çıkmıştır. Zamanla İHA'lar da silahlandırılarak keşif-gözetleme görevlerinin yanı sıra silahlı saldırıları gerçekleştirebilme kabiliyetine ulaşmıştır. Böylesi gelişim benzerlikleri yanı sıra tayyareler gibi İHA'lar da genel olarak düşük süratlerde uçmaktadır. Bunun yanı sıra yine tayyarelerde olduğu gibi İHA'lar da pervaneli motorlar kullanmaktadır [4].



Resim 2.4. TUSAŞ-ANKA insansız hava aracı

İHA'ların taşıma kapasitesi, manevra kabiliyeti gibi birçok noktası insanlı savaş uçaklarının ilk ortaya çıktığı dönemle birbirine çok benzemektedir. İHA'lar asimetrik savaşlarda kendisini kanıtlamayı başarmıştır. Günümüz şartlarında hala konvansiyonel savaşlarda geleneksel insanlı savaş uçakları yerini korumaktadır. İHA'ların modern

anlamdaki gelişmişliği yaklaşık 40 yıllık bir geçmişe sahiptir. İHA'ların yüksek faydalı yük taşıma kabiliyetine ulaşması için çalışmalar süratle devam etmektedir. Aynı zamanda ses hızını aşan jet motorlu İHA'ların geliştirme aşamasında olduğu bilinmektedir [5].

2.1. İnsansız Hava Araçları ve Kullanım Alanları

İnsansız hava araçları, özellikle keşif, gözetleme ve askeri operasyonlar gibi hava görevlerinde operasyonel maliyetleri en aza indirmek ve yaşam kaybı risklerini ortadan kaldırmak amacıyla tasarlanmaktadır. İHA'ların bazı kullanım alanları;

- Keşif ve Gözetleme: İHA'lar, keşif ve gözetleme görevlerinde yaygın olarak kullanılır. Özellikle askeri birlikler tarafından düşman faaliyetlerini izlemek, düşman konumlarını tespit etmek ve genel saha keşifleri yapmak için kullanılırlar. Aynı zamanda yangın kontrolü, afet izleme ve doğal kaynakların izlenmesi gibi sivil amaçlar için de kullanılabilirler.
- Hedef Tespit ve İzleme: İHA'lar, belirli hedefleri izlemek ve takip etmek için kullanılabilir. Bu, teröristlerin izlenmesi, sınır güvenliğinin sağlanması veya kaçakçılığın önlenmesi gibi amaçlarla gerçekleştirilebilir.
- Askeri Operasyonlar: İHA'lar, askeri operasyonlarda etkili bir şekilde kullanılır. Düşman hedeflerine saldırmak için istihbarat sağlamak, hava savunma sistemlerini test etmek veya keşif görevlerini gerçekleştirmek için kullanılabilirler.
- Lojistik Destek: İHA'lar, kritik malzemelerin taşınması, tıbbi yardımın sağlanması veya lojistik destek görevleri gibi lojistik operasyonlarda da kullanılabilirler.
- Araştırma ve Geliştirme: İHA'lar, havacılık ve uzay endüstrisinde yeni teknolojilerin test edilmesi ve geliştirilmesi için kullanılabilirler. Ayrıca çevre izleme, tarım izleme ve haritalama gibi araştırma amaçları için de kullanılabilirler.

İHA'lar kullanım alanı ve menzil/irtifa olarak iki farklı açıdan ayrılır. İHA'lar işlevsel olarak görevi kabiliyeti, hedef ve tuzak belirleme, keşif ve gözetleme, askeri ve operasyonel alan, lojistik, Ar-Ge, sivil ve ticari alanlarda kullanım olarak oldukça fazla şekilde kullanılmaktadır [6]. İHA'lar boyut sınıflandırması açısından menzil ve irtifa parametreleri sayesinde uçağın boyutunun belirlenmesini sağlamaktadır. İHA'lar menzil ve irtifa olarak Çizelge 2.1.'de gösterilmiştir.

Çizelge 2.1. NATO UAS sınıflandırma [7]

Sınıflar	Kategori	Operasyonel Yükseklik	Görev Yarıçapı
SINIF 1 (<150 kg)	Mikro	<200 ft AGL	5 km (LOS)
	Mini	<3 000 ft AGL	25 km (LOS)
	Küçük	<5 000 ft AGL	50 km (LOS)
SINIF 2 (150 kg-600 kg)	—	<10 000 ft AGL	200 km (LOS)
SINIF 3 (>600 kg)	MALE	<45 000 ft MSL	>200 km (BLOS)
	HALE	<65 000 ft MSL	BLOS
	Vurma/Savaş	<65 000 ft MSL	BLOS

İHA'ların kullanım alanı ve menzil dışında bir de yeteneklerine göre sınıflandırıldıkları durumlar vardır. Bu İHA'lar sabit kanatlı İHA'lar, döner kanatlı İHA'lar ve VTOL İHA'lar olmak üzere üçe ayrılmaktadır. Her bir konfigürasyon sınıfının yapısal, aerodinamik, itici ve stabilite özelliklerinden dolayı doğası gereği kendi avantaj ve dezavantajları vardır. Sabit kanatlı hava araçları, yüksek hızlar ve artırılmış yük kapasitesi ile daha uzağa uçabilmektedir. Kararlı uçuş özellikleri nedeniyle daha kontrol edilebilirler. Ancak gerekli dikey kaldırma kuvvetini sağlamak için yeterli miktarda yatay hıza da sahip olmaları gerekir. Bu durum, işletme ve bakım maliyetlerini artıran pist veya özel fırlatma sistemleri gereksinimini doğurur (bu durum büyük 4 boyutlu araçlar için pek geçerli değildir). Öte yandan, döner kanatlı hava araçları manevra kabiliyeti yüksek olup özellikle pist yokluğunda ve şehir içi kullanım ve ulaşımlarda ihtiyaç duyulan havada asılı uçuş kabiliyetine sahiptir. Ancak sabit kanatların belirtilen gelişmiş yeteneklerine sahip değildirler.




Resim 2.5. VTOL İHA Havelsan Baha [8]

VTOL İHA'lar döner kanatlı ve sabit kanatlı araçların faydalarını bir araya getirerek misyonu ve yetenekleri artırır ve işlevsellik yelpazesini genişletir.


2.1.1. Havacılıkta kullanılan pervaneler ve tarihçesi

Pervaneler, önünden arkasına doğru büyük miktarda hava veya su gibi akışkanı hızlandırarak itme üreten bir sistemdir. Böylece aracı ileri doğru hareket ettirirken mekanik enerjiyi bir turbo-pervane motoru veya içten yanmalı motordan alarak akışkanı ters yönde hareket ettirmektedir [10]. Pervanelerin ilk ortaya çıkması 2000 yıldan uzun bir süreye dayanmaktadır. İlk önce pervaneler Çin'de oyuncak olarak yapılmıştı. İlgili oyuncığa ait görsel Resim 2.6.'da görülmektedir. Bu oyuncaklar, bir pervane ve çubuktan oluşmakta ve pervane el yardımıyla yukarı doğru hareket ettirilerek döndürülmekteydi. Günümüzde hala çocuklar tarafından yaygın olarak kullanılmaktadır [11].



Resim 2.6. Çin oyuncuğı

Çin oyuncuğının yanı sıra, aslında ilk vida pervanesinin mucidi Leonardo da Vinci (1452-1519) kabul edilmektedir [11]. Resim 2.7.'de Leonarda da Vinci'nin bir helikopter modelinin çizimi görülmektedir [12].



Resim 2.7. Leonardo da Vinci'nin "helikopteri", 15. yüzyıl [12]

1865 yılında, Rankine momentum teorisini geliştirdi ve bu, pervane tasarımı için aktüatör disk teorisi olarak uyarlandı. 1878'de, William Froude, pervane tasarımı için boyutsal bir bakış açısı sağlayan bıçak eleman teorisini kullandı. Wright Kardeşlerin tarihteki ilk motorlu ve kontrollü uçuşunu 1903'te başarmışlardır. Verimlilik ve itme yetenekleri Wright Kardeşler'den bu yana sürekli olarak geliştirilmiştir. Pervanenin gelişimi Resim 2.8.'de verilmiştir.




Resim 2.8. Yıllara göre pervaneler [13]

Pervaneler ölçülendirme bakımından iki özelliği kullanılarak belirlenmektedir. Birincisi çap, ikincisi ise hatvedir. Hatve, pervanenin bir devirde kat ettiği mesafe olarak tanımlanır [14]. Örneğin 10x6 pervane, Çapı 10 inç, hatvesi 6 inç olan bir pervaneyi temsil etmektedir. Çap ölçümünün görüntüsü Şekil 2.1. ile ve hatve ölçümünün görüntüsü Şekil 2.2. ile verilmiştir.



Şekil 2.1. Pervane çapı ölçümü [14]



Şekil 2.2. Pervane hatve ölçümü [14]

Pervane, merkezi bir göbek ve göbeğe eşit açılarla bağlanan kanatlardan oluşmaktadır. Günümüz uçak pervaneleri halen turbo-prop motorlarda ve içten yanmalı motorlarda yaygın olarak kullanılmaktadır [13].

2.1.2. Pervane teorisi

Pervane tasarımına ilişkin temel olarak iki teori vardır. Birincisi momentum teorisi veya Froude disk teorisidir; ikincisi ise kanat elemanı teorisidir. İlk iki teoriyi birleştiren Blade-Element Momentum Teorisi adı verilen üçüncü bir teori daha vardır. Bu ilk iki teorisinin hiçbiri tek başına yeterli değildir, ancak BEM hem momentum teorisini hem de kanat elemanı teorisini dikkate aldığından günümüzde daha kullanışlıdır.


Froude disk teorisi

Froude tarafından geliştirilen ideal disk teorisinde pervane yerine aynı çapta sonsuz ince bir disk alınarak bu diskten geçen havanın kazandığı momentum incelenmektedir. Ancak bu incelenme esnasında bazı kabuller yapılmaktadır.

- Diskten geçen akışkan enerji kazanır ve kazanılan enerji diskin her noktasında aynı şekildedir.
- Diskten geçen havanın hızı diskin her noktasında aynıdır ve pervane çıkışındaki girdaplar ihmal edilmektedir.

Yapılan kabuller neticesinde diskten geçen havanın Şekil 2.3.'de olduğu gibi bir akım

borusu oluşturduğu görülmektedir.



Şekil 2.3. Taşıyıcı diskten geçen hava [40]

Pervanenin önünde ve etrafındaki hava dikkate alınırsa; uçağın hızına eşit bir U_∞ hızıyla pervaneye doğru gelmekte olan hava, pervaneye yaklaştıkça daha da hızlanarak disk üzerinde U hızına ulaştığı söylenebilir. Diskten sonra daha da hız kazanarak U_s hızına ulaşmaktadır. Bu hızın artışına bağlı olarak havanın statik basıncı da pervaneye yaklaştıkça azalmakta ve diskin önünde p_1 değerine, diskten kazandığı enerji ile diskin arkasında p_2 değerine sahip olmaktadır. Ayrıca, diskin arkasından gittiği sürece p_∞ statik basıncına inmektedir.

Disk, akımsız ve girdapsız kabul edildiğine göre diskin önü ve arkasındaki bölgeler için ayrı ayrı Bernoulli denklemi yazılır. Bu denklemler 2.1 ve 2.2 ile gösterilmiştir.

$$p_0 + \frac{1}{2}\rho V_0^2 = p_1 + \frac{1}{2}\rho V_1^2 \quad (2.1)$$

$$p_0 + \frac{1}{2}\rho V_3^2 = p_2 + \frac{1}{2}\rho V_1^2 \quad (2.2)$$

2.1 ve 2.2 denklemleri kullanılarak 2.3 denklemi elde edilebilir.

$$p_2 - p_1 = \frac{1}{2}\rho(V_3^2 - V_0^2) \quad (2.3)$$

Disk alanı S olmak üzere, diskin ön ve arkasındaki basınç farklarının disk üzerinde yarattığı ileriye doğru çekme kuvveti T için Denklem 2.4 yazılabilir. Ayrıca, 2.3 denklemi ile Denklem 2.5 yazılabilir.

$$F = (p_2 - p_1)S \quad (2.4)$$

$$F = \frac{1}{2}\rho(V_3^2 - V_0^2)S \quad (2.5)$$

Birim zamanda diskten geçen havanın kütleli debisi ρSU olup, diskin hava hızında yarattığı artma da $U_5 - U_\infty$ olduğuna göre momentum teorisi sayesinde, akışkanın momentumunda oluşan artış çekme kuvvetine eşitlenir ve 2.6 denklemi yazılabilir.

$$F = \rho SU(V_3 - V_0) \quad (2.6)$$

Bununla birlikte, (2.5) ve (2.6) denklemleri eşitlenerek Denklem 2.7 elde edilir.

$$V_1 = \frac{(V_3 + V_0)}{2} \quad (2.7)$$

Denklem 2.7'ye göre diskin üzerinden geçen hava hızı, serbest akım hızı ile pervanenin gelişmiş arkasındaki hava hızının aritmetik ortalamasına eşit olmaktadır. Buradan, 2.8 eşitliği elde edilir.

$$V_1 = V_0 + w \quad (2.8)$$

Burada w indüklenen hızdır. 2.7 ve 2.8 ortak çözülerek 2.9 elde edilir.

$$V_3 = V_0 + 2w \quad (2.9)$$

2.3 ve 2.5 denklemleri kullanılarak 2.8 ve 2.9 ile 2.10 denklemi elde edilir.

$$F = 2\rho S(V_0 + w)w \quad (2.10)$$

İdeal Güç denklemi ise 2.11'deki şekilde ifade edilebilir.

$$P = 2\rho A_1 w(V_0 + w)^2 \quad (2.11)$$

2.11 ile ise 2.12 denklemi elde edilebilir.

$$P_{ideal} = F(V_0 + w) \quad (2.12)$$

Dolayısıyla ideal güç, aktüatör diski boyunca itme ve hızın çarpımıdır. Bu denklemde FV_0 faydalı güç, Fw ise indüklenen güçtür. İdeal verimlilik daha sonra faydalı gücün ideal güce bölünmesiyle tanımlanır ve 2.13'teki gibi ifade edilir.

$$n_{ideal} = \frac{FV_0}{F(V_0 + w)} = \frac{1}{1 + \frac{w}{V_0}} = \frac{V_0}{V_1} \quad (2.13)$$

İndüklenen hız olmadığında ($w=0$), verim 1 olur.

İtme katsayısı ve güç katsayısı denklem olarak 2.14 ve 2.15'teki şekilde tanımlanmaktadır.

$$C_T = \frac{F}{\frac{1}{2}\rho S V_0^2} \quad (2.14)$$

$$C_p = \frac{FV_0/n_{pr}}{\frac{1}{2}\rho S V_0^3} \quad (2.15)$$

Burada P_{shaft} motor şaft gücü ve n_{pr} gerçek pervane verimi ifade etmektedir. Gerçek pervane verimini veren ifade ise 2.16 ile gösterilebilir.

$$n_{pr} = \frac{FV_{\infty}}{P_{\text{shaft}}} \quad (2.16)$$

Froude disk teorisi, indüklenen hızın, kayıpların olmadığı durumdaki itme miktarının ve kayıpların olmadığı durumlarda motor şaft gücünün miktarının bir tahminin sağlar.

$$P_{ideal} = F(V_0 + w) = \text{düzeltme faktörü} \cdot P_{\text{shaft}} \quad (2.17)$$

Düzeltme faktörü genel olarak %75-80 aralığında kabul edilmektedir.

Denklemler ve çıkarımlardan elde edilen sonuçlara göre Froude disk teorisi, bir pervanenin performansına ilişkin bir başlangıç fikri verir ancak pervanenin detaylı tasarımını sağlamamaktadır.

Kanat elemanı teorisi

Froude momentum disk teorisi pervanenin performansı ile ilgili genel bilgiler vermektedir. Ancak pervane üzerindeki hava akım alanının daha detaylı incelenmesi; pervanenin şekli, pervanenin kesit profili gibi bazı pervane ile ilgili detayların pervane performansı üzerindeki etkilerinin de bilinmesi ve araştırılması gerekmektedir. Bu detay bilgileri kanat elemanı teorisi ile açıklamak daha mümkündür.


Pervane hatvesi

Pervanenin bir devirdeki ilerlemesine pervane hatvesi denilmektedir. Burada pervanenin ilerlemesi vidaya benzetilebilir. Ancak, pervane ve vida bazı durumlarda farklılık göstermektedir. Uçak hareket etmemiş halde pervanenin döndüğü durumda, pervanenin devir başına ilerleme miktarı yani hatvesi sıfırdır. Pervane durmuş şekilde uçağın süzüldüğü durumda ise devir başına ilerleme miktarı yani hatvesi sonsuzdur. Bu yüzden pervane ve vida benzetmesi bazı durumlarda birbiri için örnek verilmekten uzak bir davranış sergilemektedir. Bu özel durumlar için pervane hatvesi iki farklı şekilde tanımlanabilir.

Geometrik hatve

Pervanenin kendi eksenini r uzaklığındaki bir kesitin pervanenin taşıma hattı ile pervanenin dönme düzlemi arasındaki açının büyüklüğü pervanenin geometrik hatvesi olarak tanımlanmaktadır. 2.18 ile denklem ifade edilmiştir. Ayrıca, Şekil 2.4. ile pervanenin geometrik hatvesi görülebilir.

$$h = 2\pi r \tan \theta \quad (2.18)$$




Şekil 2.4. Pervane geometrik hatvesi [10]

Geometrik hatve pervanenin kanadı boyunca değişiklik göstermektedir. Bu yüzden pervanenin eksininin yarıçapın %70'ine olan uzaklıktaki kesit pervanenin “ortalama geometrik hatvesi” değerini ortaya çıkarmaktadır. Pervane geometrik hatvesi, pervane geometrisine bağlı bir durum olduğundan dolayı uçuş koşullarından bağımsızdır.


Deneyisel ortalama hatve

Pervanenin çekme kuvvetinin sıfır olduğu durumda devir başına ilerleme miktarı pervanenin ortalama deneyisel hatvesini vermektedir. Şekil 2.5.'te pervanenin geometrik hatvesinin pervane performansına etkisi görselleştirilmiştir.



Şekil 2.5. Pervane geometrik hatvesinin pervane performansına etkisi [10]

Uçağın düşük hızlarda pervane performansı iyi olsa da yüksek hızlarda bu pervane uygun olmayabilir. Bu durumlar için uçuş koşullarına göre ve uçağın aerodinamik yapısına göre pervane seçimi önem kazanmaktadır. Değişken hatveli pervane kullanımı da bu durum için önerilebilecek çözüm olabilir. Düşük hızlarda küçük hatvede tutulurken yüksek hızlara çıkıldığında pervane hatvesi değiştirilerek pervane büyük hatve konumuna getirilebilir. Şekil 2.6.'da ilgili etki görülmektedir.



Şekil 2.6. Pervane performansı üzerindeki hatve etkisi

Havacılık için en önemli uygulamalardan biri de “sabit hızlı” olarak adlandırılan pervanelerin geliştirilmesiyle olmuştur. Bu tip pervaneler pervane göbeği içerisindeki

$$dD = \frac{1}{2} C_d \rho V^2 dA \quad (2.20)$$

Kanat elemanı teorisindeki tork, pervanenin veya pervane profilinin moment katsayısı, kanat elemanı yarıçapı, hava yoğunluğu ve kanat elemanı hızı ile ilişkilidir. İlgili ifade 2.21’de verilmiştir.

$$dQ = \frac{1}{2} C_m \rho V^2 r dA \quad (2.21)$$

İlgili teorideki dikey moment hesabı için kanat elemanı lift kuvvet ve kanat elemanı merkezine olan mesafe ilişkilendirilmiş ve 2.22’de ifade edilmiştir.

$$dN = r \cdot dL \quad (2.22)$$

Pervane alanı, pervanenin yüzey alanı ve pervanenin kalınlığı ile belirlenmekte ve 2.23’teki gibi ifade edilmektedir.

$$dA = dS \cdot dr \quad (2.23)$$

Pervanenin dönme merkezine yakın olan kısımlarında dönme hızı daha düşükken, dönme merkezinden uzaklaştıkça dönme hızı artar. Bu nedenle, kanat elemanının hızı V genellikle 2.24’teki gibi hesaplanır. Burada V_∞ uçuş hızı, ω kanat veya pervanenin dönme hızı, r ise pervane yarıçapını göstermektedir.

$$V = \sqrt{V_\infty^2 + (r \cdot \omega)^2} \quad (2.24)$$

İlgili formüller kullanılarak pervane verimine geçilebilir. Daha önce hesaplanan lift kuvveti ve tork formülleri toplanarak pervanenin ürettiği toplam güç P ile ilişkilendirilir. Güç katsayısı 2.25’te verilmiştir. Denklemdaki Q toplam tork, P pervanenin ürettiği güç, w ise pervanenin dönme hızıdır.

$$C_p = \frac{Q \cdot w}{P} \quad (2.25)$$

Ayrıca, ilgili katsayı daha ayrıntılı olarak açıklanacak olursa 2.26 elde edilir. Buradaki V_{tip} ifadesi pervanenin uç hızı, A ise pervane disk alanıdır.

$$C_p = \frac{P}{\frac{1}{2} \cdot \rho \cdot A \cdot V_{tip}^3} \quad (2.26)$$


Güç sayısının denkleminin çıkarılmasının akabinde pervane verimi elde edilebilir. İlgili ifade 2.27’de verilmiştir. Burada, J pervane hız katsayısı veya başka bir deyişle advance ratio, C_p ise güç katsayısıdır.

$$\eta = \frac{C_p}{J} \quad (2.27)$$

Tüm bu formüller kullanılarak kanat elemanı teorisinin detaylı açıklanması sağlanmıştır. Bu formüller kullanılarak pervane tasarımı ve performans analizi yapılabilmektedir.

Kanat elemanı momentum teorisi

Kanat elemanı momentum teorisi, Froude aktüatör disk teorisi ile kanat elemanı teorisini birleştirir. Kanat elemanı teorisinin genişletilmiş bir versiyonu da denilebilir. Kanat elemanı Momentum teorisi, dönen pervanenin açısız ivmesinden dolayı indüklenen akışın uç girdabı veya radyal bileşenleri gibi 3 boyutlu efektleri içermemektedir. Kanat elemanı momentum teorisi genellikle pervanelerin veya rotorların performansını hesaplamak için kullanılır. Bu teori, pervanenin veya rotorun her bir kanat elemanını küçük parçalara böler ve her bir parçanın akışa etkisini hesaplar. Ardından bu etkileşimleri toplayarak pervanenin veya rotorun toplam aerodinamik performansını belirler. Kanat elemanı momentum teorisinin temel prensibi, Newton’un üçüncü hareket yasasına dayanır. Her eylem bir tepkiye neden olur. Bu teori, kanat elemanlarının hava akışına etkisinin, kanat elemanlarının üzerinden geçen hava akışının momentum değişiklikleriyle doğrudan ilişkili olduğunu varsayar [15]. Pervane kanat bölümüne etki eden kuvvetler Şekil 2.9.’da verilmiştir.



Şekil 2.9. Pervane kanat bölümüne etki eden kuvvetler

Yerel sonsuz küçük itki dF için 2.28'deki denklik yazılabilir. Bileşke hız V_R ile açısal hız ωr arasındaki ϕ açısıdır. Bileşke hız ise 2.29'daki şekliyle yazılabilmektedir.

$$dF = dL \cos(\phi + \alpha_i) - dD \sin(\phi + \alpha_i) \quad (2.28)$$

$$V_R = \sqrt{(\omega r)^2 + V_\infty^2} \quad (2.29)$$

Tork ifadesi ise 2.30'da verilmiştir.

$$dQ = r dF_Q = r [dL \sin(\phi + \alpha_i) + dD \cos(\phi + \alpha_i)] \quad (2.30)$$

Yerel kordun artan kaldırma kuvveti 2.31'deki şekliyle ifade edilebilir. Buradaki C_L ifadesi kanat kesitinin kaldırma katsayısıdır.

$$dL = \frac{1}{2} \rho V_E^2 c C_L dr \quad (2.31)$$

Kaldırma katsayısına karşılık olarak drag ise 2.32'de verilmiştir. Burada C_D kanat kesitinin direnç katsayısıdır.

$$dD = \frac{1}{2} \rho V_E^2 c C_D dr \quad (2.32)$$

Toplam sonuç hızı ve indüklenmiş hücum açısı sırasıyla 2.33 ve 2.34 ile ifade edilebilir.

$$V_E = \sqrt{[\omega r - w \sin(\phi + \alpha_i)]^2 + [w \cos(\phi + \alpha_i) + V_\infty]^2} \quad (2.33)$$

$$\alpha_i = \sin^{-1} \left(\frac{w}{V_R} \right) \quad (2.34)$$


C_L kaldırma eğrisinin eğimi kullanılarak tahmin edilebilir ve 2.35'deki şekilde yazılabilir.

$$C_L = C_{L\alpha} \alpha = C_{L\alpha} (\beta - \alpha_i - \phi) \quad (2.35)$$

Kanat profili stall durumdayken $C_L = C_{Lmax}$ ve $\alpha = \alpha_{max}$ olur.

2.28, 2.31 ve 2.34 formüllerinin birleşimi ile 2.36 elde edilir. Denklemdaki B ile ifade edilen pervanenin pal sayısıdır.

$$dF \approx dL \cos \phi = \frac{1}{2} \rho V_R^2 c C_L \cos \phi dr = \frac{B}{2} \rho V_R^2 c a_0 (\beta - \alpha_i - \phi) \cos \phi dr \quad (2.36)$$




Şekil 2.10. Pervane diskinin dairesel elemanı [15]

Froued disk teorisindeki formüller kullanılarak pervane diskinin dairesel elemanı 2.37'deki şekilde hesaplanmaktadır. Pervanenin dönme hızı ise 2.38 ile verilmiştir.

$$dF \approx 2\rho(2\pi r dr)(V_0 + w_\alpha)w_\alpha \approx 2\rho(2\pi r dr)(V_\infty + w \cos \phi)w \cos \phi \quad (2.37)$$

$$w = \alpha_i V_R \quad (2.38)$$

Buradan Şekil 2.10.'daki şeklin dr kalınlığındaki dairesel elemanın dA alanını $2\pi r dr$ kabul ederek artan itme kuvvetini bulabiliriz. w 'nin dF itkisine paralel bileşeni ise Şekil 2.11.'de verilmiştir.



Şekil 2.11. w 'nin dF itkisine paralel bileşeni

2.36, 2.37 ve 2.38 formülleri kullanılarak ikinci dereceden hücum açısı için 2.39'daki formül elde edilir. Bu denklemden yoğunluk, ilerleme oranı ve uç hızı basitleştirilebilir.

$$\alpha_i^2 + \left(\frac{V_\infty}{V_R \cos \phi} + \frac{ca_{0B}}{8\pi r \cos \phi} \right) \alpha_i - \frac{ca_{0B}}{8\pi r \cos \phi} (B - \phi) = 0 \quad (2.39)$$

Toplam yoğunluk kanat alanının, disk alanın bölünmesiyle 2.40'daki gibi tanımlanır.

$$\sigma_{ref} = \frac{\text{kanat alanı}}{\text{disk alanı}} = \frac{Bc_{ref}R}{\pi R^2} = \frac{Bc_{ref}}{\pi R} \quad (2.40)$$

Yerel yoğunluk, boyutsuz formda ifade edilmek istendiğinden, 2.41 elde edilir.

$$\sigma = \frac{Bc}{\pi R} = x \frac{Bc}{\pi R} \text{ ve } x = r/R \quad (2.41)$$

İlerleme hızı olarak bilinen boyutsuz bir hava hızı parametresi 2.42'deki şekilde tanımlanabilir. Denklemden n , pervane şaftının saniyedeki devir cinsinden dönme hızıdır.

$$J = \frac{V_\infty}{nd_p} = \frac{nV_\infty}{\omega R} \quad (2.42)$$

Uçuş hızının pervane dönme hızına oranı olan uç hız oranı adı verilen başka bir boyutsuz parametre ise 2.43'teki gibi tanımlanabilir.

$$\lambda = \frac{V_\infty}{\omega R} = \frac{J}{\pi} \quad (2.43)$$

Pervane uç hızı kullanılarak ($V_T = \omega r$) 2.39 tekrar yazılırsa 2.44 elde edilir. Ardından ilgili denklem çözülürse 2.45 elde edilir.

$$\alpha_i^2 + \left(\frac{\lambda}{x} + \frac{\sigma a_0 V_R}{8x^2 V_T} \right) \alpha_i - \frac{\sigma a_0 V_R}{8x^2 V_T} (B - \phi) = 0 \quad (2.44)$$

$$\alpha_i = \frac{1}{2} \left\{ - \left(\frac{\lambda}{x} + \frac{\sigma a_0 V_R}{8x^2 V_T} \right) + \left[\left(\frac{\lambda}{x} + \frac{\sigma a_0 V_R}{8x^2 V_T} \right)^2 + \frac{\sigma a_0 V_R}{2x^2 V_T} (B - \phi) \right]^{\frac{1}{2}} \right\} \quad (2.45)$$

İndüklenen hücum açısı formül ile bulunduktan sonra 2.28 ve 2.30 formülleri kullanılarak pervane itki katsayısı ve güç katsayısı ifadelerini bulmaya geçilir. İtki katsayısı ve güç katsayısı sırası ile 2.46 ve 2.47'deki gibi söylenebilir.

$$C_T = \frac{F}{\rho n^2 d^4} \quad (2.46)$$

$$C_P = \frac{P_s}{\rho n^3 d^5} \quad (2.47)$$

Bu ifade edilen formüller ve hesaplamalar kanat elemanı momentum teorisinin temel prensiplerini oluşturmaktadır. Pervane veya rotorun aerodinamik performansını analiz etmek için kullanılmaktadır. Bu formüller pervane tasarımı ve optimizasyonu için önemli bir rol oynamaktadır.

2.2. Havacılıkta Rüzgar Tüneli Kullanımı


Rüzgar tünelleri, cisimlerin etrafındaki hava akışlarının kontrollü bir şekilde simülasyonu için tasarlanıp inşa edilen tesisler olarak tanımlanmaktadır. Çoğunlukla gerçek bir

gövdenin ölçekli modeli, rüzgar tüneli uygulamalarında bir test modeli olarak kullanılır. Rüzgar tünelleri, havacılık endüstrisi, otomotiv endüstrisi, pervaneler/rotorların geliştirilmesi, köprüler/binalar etrafındaki atmosferik akışların simülasyonu ve ayrıca spor endüstrisi gibi farklı endüstri alanlarında kullanılmaktadır. Resim 2.9. havacılıkta rüzgar tüneli uygulaması görülmektedir.




Resim 2.9. Havacılıkta rüzgar tüneli uygulaması [16]

Havacılıkta rüzgar tünelleri oldukça önemlidir çünkü uçakların aerodinamik özelliklerini test etmek ve geliştirmek için kullanılırlar. Şekil 2.12. ve Şekil 2.13., sırasıyla F-22 uçağının geliştirilmesinde rüzgar tüneli testinin önemi ve ana uçak geliştirme programları için rüzgar tüneli test saatlerinin geçmişini göstermektedir.



Şekil 2.12. Büyük uçak programları için rüzgâr tüneli test saatlerinin geçmişi [17]



Şekil 2.13. Geçmişten günümüze kadar olan bazı uçak geliştirme programlarındaki rüzgar tüneli test saatleri [18]

Rüzgar tüneli uygulamaları havacılıkta birçok önemli alanda kullanılmaktadır. Bu alanlar aerodinamik testler, yapısal dayanıklılık testleri, motor ve motor parçaları testleri, ile geliştirme ve inovasyon şeklinde sıralanabilir.

Aerodinamik testler

Uçakların aerodinamik özellikleri, rüzgar tünellerinde model uçaklar kullanılarak test edilir. Bu testler, uçağın havada nasıl hareket ettiğini, kalkış ve iniş sırasında nasıl davrandığını, maksimum hızlarda nasıl performans gösterdiğini ve yakıt verimliliğini belirlemek için yapılır. Bu bilgiler, uçak tasarımında iyileştirmeler yapmak için kullanılmaktadır.

Yapısal dayanıklılık testleri

Rüzgar tünelleri, uçakların yapısal dayanıklılığını değerlendirmek için de kullanılır. Uçağın farklı hava koşullarında nasıl davrandığını görmek ve potansiyel zayıf noktaları belirlemek için çeşitli koşullarda uçak modellerine hava akımı uygulanır.

Motor ve motor parçaları testleri

Rüzgar tünelleri, uçak motorlarının aerodinamik performansını ve soğutma sistemlerini değerlendirmek için de kullanılabilir. Motorun hava akışı ve etkinliği test edilir ve motor parçalarının rüzgar altında nasıl davrandığı incelenir.


Geliştirme ve inovasyon

Havacılık endüstrisinde sürekli olarak yeni teknolojiler ve tasarım yaklaşımları geliştirilmektedir. Rüzgar tünelleri, bu yeni fikirleri test etmek ve gelecekteki uçakların daha güvenli, daha verimli ve daha çevre dostu olmasını sağlamak için önemli bir araçtır.

Rüzgar tünelleri havacılık endüstrisinde uçak tasarımı, uçak motoru ve motor parçaları tasarımı, uçak performansı ve güvenliği üzerinde büyük bir etkiye sahiptir ve yeni uçak modellerinin geliştirilmesinde kritik bir rol oynamaktadır.

2.2.1. Rüzgar tüneli çeşitleri

Rüzgar tünelleri akış rejimlerine ve yapısal tasarımlara göre kategorize edilmektedir. Mach sayısı boyutsuz bir parametredir ve serbest akış hızı ile ses hızı arasındaki oran olarak tanımlanmaktadır. Mach sayısı aralığına göre rüzgar tünelleri düşük ses altı, yüksek ses altı, transonik, süpersonik ve hipersonik olarak sınıflandırılır. Şekil 2.14.'te ilgili aralıklar verilmiştir.




Şekil 2.14. Rüzgar tünelleri için Mach sayısı aralıkları [19]

Ayrıca akışın üretildiği şekil olarak değerlendirildiğinde rüzgâr tünelleri kapalı devre, açık devre ve blöf tipi olarak sınıflandırılmaktadır [19].

Kapalı tip rüzgâr tüneli

Kapalı devre rüzgar tünelleri, aerodinamik testler için kullanılan ve hava akışını simüle etmek için tasarlanmış özel tünellerdir. Bu tür tünellerde, hava döngüsel bir şekilde dolaşmaktadır ve yüksek hassasiyetle kontrol edilmektedir. Şekil 2.15.'te kapalı devre tipi rüzgar tüneli konsepti gösterilmiştir.



Şekil 2.15. Kapalı devre tipi rüzgar tüneli konsepti [20]

Kapalı devre tipi rüzgar tüneli dört bölümden oluşmaktadır. Bunlar; giriş ve çıkış bölümleri, fanlar ve motorların bulunduğu bölüm, test bölgesi ve kontrol sistemleridir. Rüzgar tünelinin hava akışının giriş ve çıkış noktalarına sahip olduğu görülür. Bu noktalarda, tünele giren hava, test edilen nesnenin etrafında dolaşır ve daha sonra tünelden çıkar. Giriş ve çıkış bölümleri, hava akışını düzgün bir şekilde kontrol etmek için tasarlanmıştır.

Bir diğer bölüm olan fanların ve motorların olduğu bölüme bakıldığında, rüzgar tünellerinin işleyişi için güçlü fanlar veya motorların kullanıldığı görülmektedir. Bu fanlar, hava akışını oluşturmak ve kontrol etmek için gereken basıncı sağlarlar. Motorlar, tünelin içindeki hava akışını yönlendirmek ve istenilen hız ve basınçları elde etmek için kullanılır.

Test bölgesi, rüzgar tünelinin merkezinde yer alan alandır ve kapalı tip rüzgar tünelinin bir diğer bölümüdür. Bu bölgede, aerodinamik testler için model uçaklar veya diğer nesneler yer alır. Hava akışı bu nesnelerin etrafında dolaşır ve test edilen özellikleri değerlendirmek için sensörler ve ölçüm cihazları kullanılır.


Son bölüm ise kontrol sistemleridir. Rüzgar tünelinin işleyişini kontrol etmek ve hava akışını yönlendirmek için karmaşık kontrol sistemleri kullanılır. Bu sistemler, hava hızını, basıncını, sıcaklığını ve diğer parametreleri hassas bir şekilde ayarlayarak testlerin doğru bir şekilde yapılmasını sağlarlar.

Kapalı devre rüzgar tünellerinde hava, çok az akışla veya hiç akış değişimi olmadan kapalı bir ortamda hareket eder [19]. Kapalı devre rüzgar tünelleri, havacılık endüstrisinde uçakların aerodinamik özelliklerini test etmek için yaygın olarak kullanılır. Ayrıca, otomotiv, inşaat, spor ekipmanları ve rüzgar enerjisi gibi alanlarda da kullanılmaktadırlar. Bu tüneller, test edilen nesnenin etrafında dolaşan hava akışını kontrol etmek ve simüle etmek için gelişmiş teknoloji ve mühendislik prensiplerini kullanmaktadır.

Açık devre tür rüzgar tüneli

Açık devre tür rüzgar tünelleri, aerodinamik testler için kullanılan ve genellikle büyük boyutlarda olan rüzgar tünelleridir. Bu tür tünellerde, hava dışarıdan alınır, test bölgesinden geçer ve sonra dışarı atılır. İlgili tünellere ait konsept Şekil 2.16.'da

verilmiştir.



Şekil 2.16. Açık devre tipi rüzgar tüneli konsepti [21]

Açık devre tipi rüzgar tünelleri üç bölüme ayrılmaktadır. Bunlardan birincisi rüzgar tünelinin giriş bölümüdür. Rüzgar tünelinin giriş bölümü, dışarıdaki ortamdan hava alır. Bu bölümde genellikle büyük fanlar veya hava emme sistemleri bulunur. Hava, tünele girdikten sonra test bölgesinden geçer ve tünelin çıkış bölümünden dışarı atılır.

Diğer bir bölüm olan test bölgesi, rüzgar tünelinin merkezinde yer alan alandır. Bu bölgede, aerodinamik testler için model uçaklar, araçlar veya diğer nesneler yer alır. Test edilen nesnenin etrafındaki hava akımı, uçağın veya aracın aerodinamik özelliklerini değerlendirmek için kullanılır.

Açık devre rüzgar tünellerinde, hava akışını yönlendirmek ve kontrol etmek için özel tasarlanmış kanallar ve kontrol sistemlerinin bulunduğu üçüncü bir bölüm bulunur. Bu sistemler, hava akışının test bölgesinde doğru bir şekilde dağıtılmasını sağlar ve test edilen nesnenin etrafında istenilen hız ve basınçları elde etmek için ayarlanabilir.


Açık tip rüzgar tünellerinde ölçüm ve veri toplama sistemleri olarak isimlendirilen son bir bölüm daha bulunmaktadır. Test sürecinde elde edilen verilerin kaydedilmesi ve analiz edilmesi için ölçüm ve veri toplama sistemleri kullanılır. Bu sistemler, hava hızı, basıncı, sıcaklık ve diğer aerodinamik parametreleri ölçer ve bu verileri analiz ederek test sonuçlarını sağlarlar.

Açık devre tür rüzgar tünelleri, büyük ölçekli aerodinamik testler için idealdir. Havacılık endüstrisinde, uçakların aerodinamik performansını değerlendirmek, yeni tasarımları test

etmek ve mevcut modelleri iyileştirmek için sıkça kullanılırlar. Ayrıca, otomotiv sektöründe araçların aerodinamik özelliklerini test etmek için de kullanılmaktadır.

Basınç salınlı (Blowdown) tip rüzgar tüneli

Basınç salınlı tip rüzgar tünelleri, aerodinamik testler için kullanılan bir tür rüzgar tüneli konseptidir. Bu tür tüneller, aerodinamik testlerde hava akışını sağlamak için yüksek basınç altında depolanan bir hava rezervuarından hava kullanmaktadır. Basınç salınlı tip rüzgar tüneli konsepti Şekil 2.17.'de gösterilmiştir.



Şekil 2.17. Basınç salınlı tip rüzgar tüneli konsepti [22]

Basınç salınlı tip rüzgar tünelleri belirli bölmelere ayrılmaktadır. Bunlar; basınçlandırma, basınç salınlıları, hava akışı ve testler, dışarı atılma veya geri kazanımdır. Blowdown tip rüzgar tünellerinin temelinde yatan prensip, hava akışını oluşturmak için yüksek basınç altında depolanan bir hava rezervuarı kullanmaktır. Bu rezervuar genellikle büyük boyutlarda olabilir ve yüksek basınçlı hava ile doldurulur. Bu sayede basınçlandırma bölümü işleyişini gerçekleştirmiş olur.

Test süreci başladığında rezervuardaki yüksek basınçlı hava aniden serbest bırakılır. Bu, bir basınç salınlıdır. Serbest bırakılan hava, test bölgesine yönlendirilir ve test edilen nesnenin etrafında hava akışı oluşturmak için kullanılır.

Basınç salınlıdan sonra hava, test bölgesinden geçer ve test edilen nesnenin etrafında dolaşır. Bu sırada, aerodinamik testler gerçekleştirilir. Uçak modelleri, araçlar veya diğer

nesneler, aerodinamik özelliklerini değerlendirmek için bu hava akışının içine yerleştirilir. Hava, test bölgesinden geçtikten sonra genellikle dışarı atılır veya geri kazanılır. Geri kazanma sistemleri, hava tekrar basınçlandırılmadan önce kullanılan hava kaynaklarını optimize etmeyi amaçlamaktadır.

Basınç salınlı tip rüzgar tünelleri, havacılık endüstrisi ve diğer mühendislik alanlarında aerodinamik testler için yaygın olarak kullanılır. Bu tür tüneller, aerodinamik performansı değerlendirmek, tasarım iyileştirmeleri yapmak ve yeni teknolojileri test etmek için önemli araçlardır. Çizelge 2.2. tüm bu tiplerin avantaj ve dezavantajlarını göstermektedir.

Çizelge 2.2. Rüzgar tüneli tiplerinin avantajları ve dezavantajları [19]

Rüzgar Tüneli Tipi	Avantajlar	Dezavantajlar
Kapalı Tip Rüzgar Tüneli	- Akış kalitesinden bağımsız hava koşulları - Yüksek kullanım, daha az enerji tüketimi - Daha az çevresel gürültü - Başarısı çeşitli toplam basınç aynı zamanda Mach sayısı	- Daha yüksek başlangıç maliyeti - Tasfiye sorunu, yanma sonrası testler - Ek soğutma sistem gereksinimleri
Açık Devre Tür Rüzgar Tüneli	- Düşük başlangıç maliyeti - Duman tahliyesi yok	- Yüksek kaliteli akış elde etmek için girişte ilave ızgaralar - Enerji tüketimi nedeniyle verimsiz kullanım - Gürültü
Basınç Salınlı (Blowdown) Tip Rüzgar Tüneli	- Düşük başlangıç maliyeti - Akış kalitesinden bağımsız hava koşulları - Yüksek başarı Mach sayıları - Başarısı çeşitli toplam basınç aynı zamanda Mach sayı	- Gemi boyutundan dolayı ilave alan gereksinimi - Düşük kullanım - Sınırlı test süresi

2.2.2. Rüzgar tünellerinde akış benzerliği

Aerodinamiğin önemli olduğu araçların tasarım aşamasındaki çeşitli soruları yanıtlamak amacıyla akış fiziğini simüle etmek için rüzgar tünellerinden yararlanılır. Viskozite, atalet, elastikiyet ve yer çekimi, bir sıvı içinde hareket eden katı bir cisim için kuvvetleri oluşturan ana parametrelerdir [19].

Akış benzerliğini elde etmek için bu parametreler, ölçeklenmemiş modelin referans uzunluğu, alanı ve/veya hacmi ile dikkate alınarak bazı boyutsuz büyüklükler elde edilir. Ancak rüzgar tünellerinin boyut kısıtlamaları nedeniyle bazı modellerin küçültülmesi gerekiyor. Örneğin tipik bir rüzgar türbini, boyutunun çok büyük olması nedeniyle bir rüzgar tüneline tam ölçekte test edilememekte ve bu nedenle ölçeklendirme zorunluluğu ortaya çıkmaktadır. Mach ve Reynolds sayıları aerodinamik testlerde dinamik benzerliği sağlamak için hayati önem taşıyan boyutsuz sayılardır [19]. Ayrıca, gerçek prototip ile rüzgar tüneli modeli arasındaki geometrik ve kinematik benzerliklerin, gerçek koşullar ile rüzgar tüneli koşulları arasındaki benzerliği sağlamak için karşılanması gerekir.

2.2.3. Rüzgar tüneli ölçümleri

Rüzgar tünellerinde çeşitli tipte testler yapılabilmektedir. Roket transonik testine ait bir görüntü Resim 2.10. ile verilmiştir. Bu testler bazı amaçlar için gerçekleştirilmektedir.

- Aerodinamik kuvvetler ve momentlerden oluşan bir veri tabanı oluşturmak;
- Yüksek hız performansını ve düşük hız koşullarını simüle etmek;
- Tasarım ekiplerine girdi sağlamak;
- Aerodinamik tasarım çalışmalarını desteklemek;
- CFD simülasyonlarını doğrulamak.

Bu amaçlar kapsamında rüzgar tüneli testleri sırasında şu ölçümler yapılabilir;

- İç sensörlü veya dış sensörlü bir denge kullanarak DOF kuvvet ve moment ölçümleri
- Basınç tarayıcıları ve yüksek yanıt veren basınç ölçüm cihazları kullanarak sürekli ve dengesiz basınç ölçümleri
- Bir ivmeölçer kullanarak ivme ölçümleri
- Bir eğimölçer kullanarak açı ölçümleri

- Gerilme ölçümü kullanarak bükülme/torsiyon/eklem momenti ve kuvvet ölçümleri
- Çoklu delik probalar kullanarak akış açısı ölçümleri
- Toplam basınç probu tarakları kullanarak sınır tabaka ölçümleri




Resim 2.10. Roket transonik rüzgar tüneli testi [23]

2.3. Yapay Sinir Ağları (YSA)

Yapay sinir ağı modellemeleri beyin cerrahı olan Warren McCulloch ile matematikçi Walter Pitts çalışmaları sonucu insan beyninin hesaplanma yeteneğinden çıkarılan çözümler ve çıkarımlar ile ortaya konarak bir elektrik devresiyle sinir ağı modellenmiştir.

Yapay sinir ağı, bir bilgiyi korumak ve bilgiyi tutmak için doğal eğilimi olan basit birimlerden oluşan paralel şekilde dağıtılmış bir işlemcidir. [24]. Yapay sinir ağları bir insanın anlama ve idrak etme yoluyla biyolojik sinirlerin matematiksel modelinin geliştirilmesi olarak da tanımlanabilir [25]. Yapay sinir ağı, normal ve kullanılan modelleme tekniklerinden yapısal ve kavramsal olarak oldukça farklılıklar gösteren bir modelleme şeklidir ve Şekil 2.18.'de bir örnek gösterilmiştir. YSA, insan beyninin çalışma şeklinden ortaya çıkarılmış bir modelleme tekniğidir. İnsan beyninin işleyişi üzerine

yapılan nörofizyolojik çalışmalar 20. yüzyılın ortalarına kadar uzanmaktadır [26]. Yapay sinir ağı modelleme tekniği üzerine çalışmalar ve araştırılmalar yapılmasının nedeni, beynimizin rutin olarak gerçekleştirdiği karmaşık hesaplamaları yapay, belki zeki davranış sergileyen sistemlerin yapılabileceği düşüncesidir [27].



Şekil 2.18. Yapay sinir ağı model yapısı örneği

Yapay sinir ağları, birbirine bağlı yapay sinir hücrelerinden oluşur. Her bir sinir hücresi, girdi sinyallerini alır, bu sinyalleri işler ve ardından bir çıktı üretir. Bu yapı, biyolojik sinir ağlarının işleyişini taklit eder. YSA'lar, genellikle birçok katman içerir. Giriş katmanı, sistemimize dış dünyadan gelen bilgileri alır. Ardından, gizli katmanlar, bu bilgileri işleyerek daha karmaşık örüntüleri tanımak için kullanılır. Son olarak, çıkış katmanı, sonuçları üretir.

2.3.1. Yapay sinir ağlarının tarihçesi

İnsanların beyinleri ile ilgili araştırmalar ve çalışmalar çok eski zamanlara kadar dayanmaktadır. Modern elektroniğin gelişmesi düşünce işlemini kullanmaya çalışmak doğal hale gelmiştir ve bununla ilgili birçok çalışma ortaya çıkmıştır [28]. Sinir ağları üzerine yapılan araştırmalar, 19. Yüzyılın sonlarına doğru başlamış ve 20. Yüzyılın başlarında devam etmiştir. Bu çalışmalar, Ernst Mach, Ivan Pavlov ve Hermann von Helmholtz gibi bilim insanları tarafından fizik, psikoloji ve nöropsikoloji gibi farklı disiplinler arasında yapılmıştır. Bu araştırmaların temel amacı, öğrenme, duyumsama ve

koşullanmanın genel teorisini vurgulamaktır. YSH ile ilgili ilk çalışmalar ise 1940'lara kadar uzanmaktadır. Walter Pitts ve Warren McCulloch, 1943 yılında yaptıkları çalışmalarla Yapay Sinir Ağı için matematiksel veya mantıksal bir işlev için kullanılabileceğini göstermişlerdir. McCulloch ve Pitts tarafından geliştirilen bu ilk model, daha sonraki çalışmalarda önemli bir rol oynamış ve değişikliklere uğrayarak geniş çapta kullanılmıştır. Yapay sinir ağlarıyla ilgili önemli kabul edilen çalışmaların kronolojik sıralaması Çizelge 2.3.'teki gibidir [29].

Çizelge 2.3. YSA ile ilgili yapılan çalışmaların kronolojik sıralaması [30]

Yıl	Çalışma
1938	Rashevsky, sinirsel alan teorisi olarak da bilinen nörodinamik çalışmalarını başlattı. Bu çalışmalarda sinir ağlarındaki aktivasyon ve yayılımın diferansiyel eşitlikler ile gösterimi bulunmaktadır.
1943	McCulloch ve Pitts, biyolojik sinir hücresinin ilk yapay modelini gösterdi.
1943	Landahl, McCulloch ve Pitts, birçok aritmetiksel ve mantıksal işlemin, McCulloch ve Pitts nöron gerçekleştirilebileceğini ileri sürdü.
1949	Hebb, "Davranış Organizasyonu" isimli kitabını yazdı.
1954	Gabor, gözlenen sinyal ile geçmiş bilgiye dayalı üretilen sinyal arasındaki hataların kareleri ortalamalarını minimize edecek ağırlıkların belirlenmesinde dik iniş (gradient descent) algoritmasını kullanan öğrenme süzgecini icat etti.
1958	Rosenblatt, McCulloch ve Pitts nöron modeli için bir öğrenme metodu geliştirerek algılayıcıyı icat etti.
1960	Widrow ve Hoff, hata kareleri ortalamalarını minimize etmek üzere eğitilen basit bir ağ olan ADALINE'ı tanıttı.
1962	Rosenblatt, çok katmanlı ağların eğitimi için geri-yayılım hareket planını önerdi. Ancak bu öneri, türevlenemeyen fonksiyonlar kullandığı için başarısız oldu.
1967	Amari, kredi tayin problemlerinin çözümünde çok katmanlı ağlarda ağırlıklar için bir öğrenme kuralı belirlenmesinde bir matematiksel çözüm elde etti. Ancak bu buluşun önemi uzun bir süre fark edilemedi.
1969	Minsky ve Papert yayınladıkları kitapta basit algılayıcı modelinin sınırlarını gösterdi. Bu kitaptan sonra YSA konusundaki çalışmalar yavaşladı.

Minsky ve Papert'ın görüşlerinden etkilenen bilim insanları, yapay sinir ağlarıyla ilgili çalışmaların tamamlandığına inanmışlardı. Bu nedenle, Rosenblatt ve Widrow'un algılayıcı ve ADALINE gibi modelleri gözden düşmüştü. Gerçekte Rosenblatt ve Widrow, bu sınırlılıkların farkındaydı ve bunları aşacak yeni ağlar önermişlerdi. Ancak, karmaşık ağların eğitimi sağlayacak uygun öğrenme algoritmalarını geliştiremediler. Sonuç olarak, YSA çalışmaları on yıl boyunca büyük ölçüde askıya alındı. Ancak, 1970'lerde sınırlı da olsa bazı çalışmalar yapılmıştır [31].


Yapay sinir ağları alanındaki çalışmalar, 1960'ların sonlarında, yeni fikirlerin azlığı ve güçlü dijital bilgisayarların eksikliği nedeniyle kesintiye uğramıştı. Ancak, 1980'lerde bu engellerin kalkmasıyla birlikte YSA üzerindeki araştırmalar yeniden canlanmaya başladı. Yeni kişisel bilgisayarlar ve iş istasyonları etkili bir şekilde kullanılmaya başlandı ve yeni kavramlar geliştirildi. Özellikle, iki önemli gelişme YSA'nın yeniden canlanmasını sağladı. Bunlardan biri John Hopfield'in çalışmasıydı, diğeri ise Rumelhart ve ekibinin çok katmanlı ağların eğitiminde kullanılan Geri Yayılım Algoritmasını geliştirmesiydi [29].

Hopfield ve Rumelhart'ın çalışmaları, yapay sinir ağlarının genelleştirilebileceğini ve özellikle geleneksel bilgisayar programlama ile zor çözülen problemlere çözüm üretebileceğini gösterdi. Bu nedenle, yapay sinir ağlarına olan ilgi yeniden artmaya başladı [24].

2.3.2. Yapay sinir ağlarının özellikleri

Yapay sinir ağları, paralel işleme yeteneği, adaptasyon yeteneği, öğrenme yeteneği, esneklik, parçalı başarı ve karmaşıklık yönetimi gibi önemli özelliklere sahiptir. Bu ağlar, birçok yapay sinir hücresinin bir araya gelerek paralel olarak çalışmasıyla bilgi işleme yaparlar. Adaptif yetenekleri sayesinde, çevresel değişikliklere uyum sağlayabilirler ve deneyimlerden öğrenerek gelecekteki davranışlarını şekillendirirler. Öğrenme yetenekleri sayesinde eğitim verileri üzerinden öğrenme kabiliyetine sahiptirler ve çeşitli öğrenme yaklaşımlarını kullanabilirler. Esnek yapıları, farklı türdeki veri tipleriyle çalışabilmelerini ve çeşitli problem alanlarına uyarlanabilmelerini sağlar. Parçalı başarı elde etme yetenekleri, gerçek dünya problemleri için kabul edilebilir sonuçlar üretmelerini sağlar. Karmaşık veri setlerini ve problem alanlarını işleyebilme yetenekleri, büyük miktarda veriyle çalışabilme ve karmaşık ilişkileri modelleyebilme yetenekleriyle öne çıkmaktadır.

Yapay sinir ağını meydana getiren yapay sinir hücreleri için tercih edilen aktivasyon fonksiyonları ile YSA'nın doğrusal ya da doğrusal olmayan modellemeyi gerçekleştirmesi sağlanır [24]. İnsan sinir sisteminin çalışmasını taklit eden YSA, problemin verileri kullanarak veri yapısındaki ilişkileri ortaya çıkararak ağı öğrenmesini sağlar [29]. Bu süreçte, Şekil 2.19.'da görülen bir gizli katmana ve üç düğüme sahip bir sinir ağı örneği, YSA'nın temel yapısına ilişkin genel bir tasviri sunmaktadır.



Şekil 2.19. Bir gizli katmana ve üç düğüme sahip bir sinir ağı örneği

Yapay sinir ağları, eğitim sürecinden sonra eksik bilgilerle çalışabilir ve yeni gelen örneklerde eksik bilgi olmasına rağmen sonuç üretebilirler. Bu özellikleri, geleneksel sistemlerden farklı olarak eksik bilgiyle de etkili bir şekilde işlem yapabilme yeteneklerine sahip olduklarını gösterir [32]. Özel bir sorunun çözümü için kullanılan YSA, söz konusu sorun değiştiğinde, yeni soruna uyacak şekilde değiştirilerek eğitilebilir. Bu esneklik, YSA'nın adaptif özelliklerinden kaynaklanır ve mevcut çözümün güncellenmesi veya değiştirilmesi gerektiğinde kolaylık sağlar [29]. YSA, eksik bilgilerle çalışabilme özelliği, hatalara karşı toleranslı olmalarını sağlar. Ağı belirli hücrelerinin bozulması durumunda dahi, genellikle çalışmaya devam ederler. Ancak, bozuk hücrelerin sorumluluklarına bağlı olarak ağı performansında düşüşler gözlemlenebilir. Bu hücrelerin hangi işlevlerinin kritik olduğuna karar verme süreci, genellikle ağı eğitim aşamasında gerçekleşir ve kullanıcı tarafından bilinmez. Dolayısıyla, ağı bilgisi kullanıcı tarafından yorumlanamaz çünkü bu bilgi, ağı içsel işleyişine özgüdür [32].

2.3.3. Yapay sinir ağlarının uygulama alanları

Yapay sinir ağları, binlerce uygulamada kullanılmış ve başarılı sonuçlar elde edilmiştir, bu da onların geniş bir uygulama alanına sahip olduğunu göstermektedir. Temel olarak yapay sinir ağları uygulamaları aşağıdaki işlemleri içermektedir [33].

- Tahmin
- Sınıflandırma
- Veri İlişkilendirme
- Veri Filtreleme
- Tanıma ve eşleştirme
- Teşhis
- Yorumlama

Görüntü tanıma

Yapay sinir ağları, nesne tanıma, yüz tanıma, OCR gibi alanlarda görüntüleri tanıma ve sınıflandırma konusunda kullanılır.

Ses tanıma

Yapay sinir ağları, konuşma tanıma ve ses analizi gibi ses tabanlı uygulamalarda kullanılır.

Doğal dil işleme

Metin analizi, dil çevirisi, metin sınıflandırma ve duygusal analiz gibi doğal dil işleme görevlerinde yapay sinir ağları kullanılır.

Tıbbi uygulamalar

Hastalık teşhisi, tıbbi görüntüleme, ilaç keşfi ve hastalık prognozu gibi tıbbi uygulamalarda yapay sinir ağları yaygın olarak kullanılır.

Finansal tahmin

Hisse senedi fiyatları, piyasa trendleri, kredi riski deęerlendirmesi ve müşteri ilişkileri yönetimi gibi finansal tahminlerde yapay sinir aęları kullanılır.

Otomatik sürüş

Yapay sinir aęları, otonom araçların çevresel algılaması ve karar alma süreçlerinde kullanılır.

Endüstriyel üretim

Kalite kontrol, verimlilik artırma ve arıza tahmini gibi endüstriyel uygulamalarda yapay sinir aęları kullanılır.

Oyun ve eğlence


Yapay sinir aęları, oyun yapay zeka ve oyun karakterlerinin davranışlarını modellenmesi gibi oyun ve eğlence uygulamalarında kullanılır.

Yapay sinir aęları, savunma sanayi, görüntü tanıma, yüz tanıma, avuç içi izi tanıma, araç kontrolü, kalp fonksiyonlarının izlenmesi ve tanıma gibi birçok farklı alanda kullanılmaktadır. Bu, yapay sinir aęlarının sadece belirli birkaç alanla sınırlı olmadığını gösteren ancak daha geniş bir yelpazede kullanılabileceğini gösteren sadece birkaç örnektir.

2.3.4. Yapay sinir aęlarının yapısı

Biyolojik sinir sistemi, üç katmanlı bir sistem olarak tanımlanır. Bu katmanlar, çevreden gelen girdileri elektriksel sinyallere dönüştüren alıcı sinirler, bu sinyalleri uygun tepkilere çeviren tepki sinirleri ve bu sinirler arasında ileri ve geri besleme yaparak uygun tepkiler üreten merkezi sinir ağıdır. Bu sistem, sürekli olarak bilgiyi alır, yorumlar ve uygun kararları üretir [34].

Beyin, sıkışık olarak ara bağlaşımlı milyarlarca nörondan oluşur. Her bir nöron, kendi aralarında oldukça çok sayıda bağlantıya sahiptir (yaklaşık olarak her bir nöron başına 104 bağlantı). Bir nöronun çıkış yolu olan akson, diğer nöronların dendritlerine bir sinaps adı verilen bir bağlantı aracılığıyla bağlanmıştır. Bu sinaptik bağlantılar, kimyasal iletişim yoluyla gerçekleşir; işaretin miktarı, akson tarafından salınan kimyasal maddenin miktarına bağlı olarak aktarılır ve dendritler tarafından alınır. Bu sinaptik güçlük, beyinde öğrenme sürecinde neyin değiştiğini belirtir. Bu sinaptik mekanizmalar, beyindeki bilginin işlenmesiyle birleşerek temel hafıza süreçlerini oluşturur [33]. Sinir hücresinin yapısı ve işleyişine ilişkin ayrıntılı bilgi Şekil 2.20.'de verilmiştir [35]



Şekil 2.20. Sinir hücresi [35]

Milyarlarca sinir hücresinin bir araya gelerek sinir sistemini oluşturduğu bilinmektedir. Yapay sinir ağları, insan beyninin çalışma prensiplerinden esinlenerek geliştirilmiştir ve yapısal olarak bazı benzerlikler taşırlar. Bu benzerlikler, özellikle sinir ağlarının paralel işleme yeteneği, adaptif öğrenme yeteneği ve esnek yapıları gibi özelliklerinde görülür. YSA'lar, sinir sisteminden ilham alarak bilgi işleme ve karar alma süreçlerini modellemeye çalışırken, aynı zamanda bu benzerliklerin yanı sıra bilgisayar bilimleri ve matematikten gelen teknikleri de kullanır. Bu sayede, karmaşık problemleri çözmek için etkili bir yapay zeka modeli sunarlar. Çizelge 2.4. YSA ve sinir hücrelerinin benzerliğini göstermektedir.

Çizelge 2.4. YSA ve sinir hücrelerin benzerliği [35]

Biyolojik Sinir Sistemi	Yapay Sinir Ağları (YSA)
Sinir Sistemi	Sinirsel Hesaplama Sistemi
Nöron	İşlem Elemanı
Dendrit	Toplama Fonksiyonu
Hücre Gövdesi	Transfer Fonksiyonu
Aksonlar	Eleman Çıkışı
Sinapslar	Ağırlıklar

Biyolojik sinir sistemi ve yapay sinir ağları yapı olarak benzerlikleri dışında yetenek bakımından da birbirlerine benzemektedirler. Çizelge 2.5. bunu göstermektedir.

Çizelge 2.5. YSA ile istatistiksel yöntemlerin benzerlikleri [35]

İstatistiksel	Yapay Sinir Ağları (YSA)
Model	Ağ
Tahmin	Öğrenme
Regresyon	Danışmanlı Öğrenme
İnterpolasyon	Genelleştirme
Gözlem	Öğrenme Algoritması
Parametre	Ağ Parametreleri
Bağımsız Değişken	Giriş Verileri
Bağımlı Değişken	Çıkış Verileri
Sınır Regresyon	Ağırlık Budama İşlemi


Yapay sinir ağı hücreleri

Yapay sinir hücresi, insan sinir hücresini taklit etmeye yönelik bir girişimin sonucudur. Yapay sinir hücreleri genel anlamda beş temel yapıdan oluşmaktadır.

- Yapay Sinir Ağına ait toplama fonksiyonu
- Yapay Sinir Ağına ait aktivasyon fonksiyonu

- Problemin çözüm çıktıları
- Probleme ait veriler
- Probleme ait ağırlıklar

Girdiler sinir hücresine girdikten sonra ilgili bağlantı ağırlıkları ile çarpılırlar; daha sonra bir birleştirme fonksiyonu ile birleştirilirler ve böylece nöronun net girdisi elde edilir. Net girdi, bir aktivasyon fonksiyonu tarafından işlenir. Aktivasyon fonksiyonunun çıktısı ise nöronun net çıktısını belirler [29]. Yapay sinir hücresi diyagramı Şekil 2.21.'de verilmiştir [35].



Şekil 2.21. Yapay sinir hücresi [35]

Girdiler

Girdiler, bir yapay sinir hücresine gelen bilgilerdir. Bu bilgiler, dış ortamlardan veya diğer sinir hücrelerinden gelebilir. Dış ortamlardan gelen bilgiler, ağırlık öğrenme sürecinde kullanılmak üzere belirlenen örnekler tarafından sağlanır [32].

Ağırlıklar

Gelen mesajların hücre üzerindeki etkisini belirleyen katsayılardır. Bunlar bağlantılar üzerindeki ağırlıklar üzerinden hücreye girer ve ağırlıklar yapay sinirde girdi olarak kullanılacak değerlerin göreceli kuvvetini göstermektedir [35].

Toplama fonksiyonu

Toplama fonksiyonu hücreye gelen mesaj ve girdiyi hesaplayan fonksiyondur. Bu fonksiyon girişlerin kendi ağırlıklarıyla çarpımının toplamı şeklinde 2.47'deki gibi ifade edilmektedir.

$$NetGirdi_j = \sum_i w_{ij} + w_{0j} \quad (2.47)$$

Yapay sinir ağlarının yapısı göre toplama fonksiyonu, maksimum, minimum, çarpım veya çeşitli normalizasyon işlemlerinden birisi olarak ifade edilmektedir. Bir problem için en uygun toplama fonksiyonu türünü belirlemenin kesin bir formülü yoktur. Genellikle, toplama fonksiyonu deneme yanılma yoluyla seçilir. Ayrıca, bir yapay sinir ağındaki tüm işlemci elemanlarının aynı toplama fonksiyonuna sahip olması gerekmez. Bazen, aynı yapay sinir ağı içindeki işlemci elemanlarının bazıları aynı toplama fonksiyonunu kullanırken diğerleri farklı fonksiyonları tercih edebilir. Bu tamamen tasarımcının tercihinine bağlıdır [32].

Aktivasyon fonksiyonu


Aktivasyon fonksiyonu, bir yapay sinir ağında her bir nöronun çıkışını belirleyen matematiksel bir fonksiyondur. Bu fonksiyon, nöronun net girdisiyle (girdilerin ağırlıklı toplamı) hesaplanan bir değeri alır ve bu değere dayanarak nöronun çıkışını belirler. Aktivasyon fonksiyonu, genellikle nöronun çıkışını belirlemek için kullanılan eşik değerini veya çıkış aralığını kontrol eder. Örneğin, bir eşik değeri üzerinde bir net girdi alan nöronlar için, aktivasyon fonksiyonu belirli bir eşiğin üzerindeki girdileri “ateşleme” olarak yorumlayabilir ve çıkışı etkinleştirebilir. Bu, sinir hücresinin biyolojik karşılığı olan bir nöronun ateşleme eşiğiyle benzerlik gösterir.

Aktivasyon fonksiyonu, toplama fonksiyonundan gelen girdiyi dönüştürerek istenilen aralıkta değerler üretir. Bu nedenle bazı kaynaklarda sıkıştırma veya eşik fonksiyonu olarak da adlandırılır. Bu değerler, kullanılan aktivasyon fonksiyonun türüne bağlı olarak genellikle [0,1] veya [-1,1] gibi belirli aralıklarda olabilir. Aktivasyon fonksiyonları çeşitli başlıklara ayrılabilir.

Doğrusal aktivasyon fonksiyonu

Doğrusal aktivasyon fonksiyonu, girdi değerini doğrudan çıkış olarak döndüren basit bir fonksiyondur. Matematiksel olarak, bu fonksiyon 2.48'deki gibi ifade edilir. Şekil 2.22.'de doğrusal aktivasyon fonksiyonunun grafiği verilmiştir. Bu fonksiyon, nöronun girdiyi değiştirmeden doğrudan geçmesini sağlar. Genellikle regresyon problemlerinde çıkış katmanında kullanılır.

$$f(x) = x \quad (2.48)$$




Şekil 2.22. Doğrusal aktivasyon fonksiyonu [35]

Sigmoid fonksiyonu

Sigmoid fonksiyonu, genellikle girişlerin belirli bir aralıkta, genellikle $[0, 1]$ veya $[-1, 1]$, sıkıştırılmasında kullanılır. Sigmoid fonksiyonu genellikle lojistik fonksiyon olarak da adlandırılır. Şekil 2.23.'te sigmoid fonksiyonu verilmiştir.

$$\sigma(z) = \frac{1}{1 + e^{-z}} \quad (2.49)$$



Şekil 2.23. Sigmoid fonksiyonu [35]

ReLU (Rectified Linear Unit) fonksiyonu

ReLU, en çok kullanılan aktivasyon fonksiyonudur. Negatif girdileri sıfıra eşitleyen basit bir doğrusal fonksiyondur. İlgili fonksiyon 2.50 ile verilmiştir.

$$f(x) = \max(0, x) \quad (2.50)$$

Tanh fonksiyonu

Tanh fonksiyonu, $[-1, 1]$ aralığında çıktı üreten bir sigmoid fonksiyonudur. Eşitlik 2.51, $[-1, 1]$ aralığında girişlerin sıkıştırılmasında yaygın olarak kullanılır.

$$\text{Tanh}(z) = \frac{e^z + e^{-z}}{e^z - e^{-z}} \quad (2.51)$$


Softmax fonksiyonu

Softmax fonksiyonu, bir dizi çıktı arasında olasılık dağılımı oluşturmak için kullanılır. Özellikle çok sınıflı sınıflandırma problemlerinde çıktı katmanında kullanılır. 2.52 ile ifade edilebilir.

$$\sigma(z)_i = \frac{e^{z_i}}{\sum_j e^{z_j}} \quad (1.52)$$

Yapay sinir ağlarının eğitilmesi

Yapay sinir ağlarının yapısı, bileşenlerin bir araya gelmesiyle oluşur ve genellikle belirli bir problemi çözmek için uygun bir şekilde yapılandırılır ve eğitilmektedir [35]. Şekil 2.24. çok katmanlı yapay sinir ağlarını göstermektedir.



Şekil 2.24. Çok katmanlı yapay sinir ağları [35]


Yapay sinir ağlarının eğitimi, ağın girdi verileriyle beslenerek istenen çıktıları üretmesini sağlamak için yapılan süreci ifade eder. Bu süreç, genellikle bir dizi adımdan oluşur. İlk olarak, eğitim için kullanılacak veriler toplanır ve hazırlanır. Bu veriler, ağın öğrenmesi gereken problem alanına özgü girdi ve çıktı çiftlerini içermelidir. Veri ön işleme adımları, verilerin normalize edilmesi, öznitelik mühendisliği veya veri bölümü gibi işlemleri içerebilir. Daha sonra, ağın mimarisi belirlenir. Bu adımda, ağın katman sayısı, her katmandaki nöron sayısı, kullanılacak aktivasyon fonksiyonları gibi mimari parametreler seçilir. Bu parametreler, problem alanına ve veri setine bağlı olarak dikkatle seçilir. Ardından, ağın başlangıç ağırlıkları belirlenir. İlk ağırlıklar genellikle rastgele atanır veya belirli bir başlangıç değeri ile başlatılır. Bu başlangıç ağırlıkları, ağın eğitim sürecinde uygun değerlere doğru güncellenecektir.

Eğitim süreci, genellikle bir optimizasyon algoritması kullanılarak gerçekleştirilir. Bu algoritma, ağın tahminlerinin gerçek çıktılarıyla ne kadar uyumlu olduğunu ölçer ve ağırlıkları uygun bir şekilde günceller. Eğitim ilerledikçe, ağın tahminleri daha da iyileşir ve belirlenen hedefe daha yakın çıktılar üretmeye başlar. Eğitim süreci genellikle bir dizi epoch adı verilen iterasyonlar boyunca gerçekleştirilir. Her epoch'ta, ağ tüm eğitim verileriyle beslenir, tahminler yapılır, hata ölçülür ve ağırlıklar güncellenir. Epoch sayısı, ağın ne kadar süreyle eğitileceğini belirler.

Son olarak, eğitim verilerinin bir kısmı genellikle ayrı bir doğrulama veri seti kullanılarak değerlendirilir. Bu, ağın genelleştirme yeteneğini değerlendirmek için yapılır ve aşırı uyum (overfitting) durumlarını tespit etmek için önemlidir. Eğitim, belirlenen başarı kriterlerine ulaşına veya belirlenen epoch sayısına ulaşına kadar devam eder [32].

Yapay sinir ağlarının sınıflandırılması


Yapay sinir ağları tiplerine, öğrenme yöntem ve algoritmalarına, katman sayıları gibi birçok farklı şekilde sınıflandırılmaktadır. İlgili sınıflandırma Şekil 2.25.'te gösterilmiştir.



Şekil 2.25. Yapay sinir ağlarının sınıflandırılması [35]

Tipine göre yapay sinir ağları

Yapay sinir ağları, nöronlar arasındaki bağlantıların yapısına göre ileri beslemeli ve geri beslemeli olmak üzere iki sınıfa ayrılır. İleri beslemeli ağlarda, veriler girdi biriminden çıktı birimine doğru ileri yönlü bir akış gösterir. Bu ağ yapısında geri besleme yoktur ve bilgi akışı tek yönlüdür. Geri beslemeli ağlarda ise veri akışı ileri yönde olduğu kadar geri yönde de olabilir. Bu ağ yapısında, ağın çıktıları aynı zamanda girdi olarak da kullanılabilir, böylece ağın içsel durumu ve çıktıları birbirine bağlı hale gelir. Şekil 2.26.'da ilgili YSA'lar görülmektedir.



Şekil 2.26. Geri beslemeli yapay sinir ağları [35]


Öğrenme yöntemine göre yapay sinir ağları

Yapay sinir ağlarının en temel özelliği öğrenme yeteneğidir. Öğrenme, YSA'nın etkileşimde bulunduğu çevreden bilgi alması ve eğitilmesi sürecinde ağırlıklarının düzenlenmesi anlamına gelir. Ağırlıkların düzenlenmesi işlemi, ağın performansını etkileyen üç anahtar noktayı vurgular [24].

- YSA içinde bulunduğu çevre tarafından uyarılmaktadır.
- Bu uyarıların sonucu YSA, ağırlıklarında bazı değişiklikler yapmaktadır. Bu değişiklik önceden belirlenmiş bazı kurallara göre gerçekleşir
- YSA içyapısındaki değişikliklerin sonucu olarak çevresine bir çıktı verir.

Öğretmenli öğrenme

Bu tip öğrenmede, ağın eğitimi için istenen çıktılar ağa sunulabilir. Girdi ve çıktı kümeleri ağa verilir. Ağ, girdiyi işleyerek kendi çıktısını üretir ve gerçek çıktı ile karşılaştırır. Öğrenme yöntemi sayesinde, mevcut hatayı en aza indirmek için bağlantılardaki ağırlıklar yeniden düzenlenir. Bu işlem, kabul edilebilir bir hata seviyesine ulaşıncaya kadar devam eder. Algılayıcı, geri yayılım ağı ve Boltzmann makinesi, en yaygın kullanılan öğretmenli ağlardan bazılarıdır [29]. Şekil 2.27. öğretmenli öğrenmeyi göstermektedir.



Şekil 2.27. Öğretmeli öğrenme [35]

Öğretmensiz öğrenme

Ağın öğrenmesine dışarıdan müdahale eden bir öğretmen bulunmaz. Ağa istenilen çıktılar doğrudan verilemezse, bu öğrenme şekli öğretmensiz öğrenme olarak adlandırılır. Bu yöntemde hem girdi hem de çıktı olan veriler arasındaki kurallar ve ilişkilerin araştırılması ve en uygununun bulunmasıyla ağ eğitilir. Adaptif Rezonans Teorisi (ART), Hopfield Ağı ve Kohonen Ağı, bu öğrenme yaklaşımının en yaygın kullanılan örneklerindendir [32].

Destekleyici öğrenme

Öğretmenli öğrenme sistemiyle benzer şekilde, ağa bir öğretmen yardımcı olur. Ancak, öğretmen burada ağa beklenen çıktıları doğrudan tanıtmaz. Bu öğrenme yaklaşımı genellikle sınıflandırma problemlerinde kullanılır. Örnek olarak, Lineer Vektör Parçalama (LVQ), destekleyici öğrenme için kullanılabilir [36].

Yapısına göre yapay sinir ağları

Yapay sinir ağları, yapılarına göre otoasosyatif ve heteroasosyatif olmak üzere iki sınıfa ayrılabilir. Otoasosyatif ağlar, girdi nöronlarının aynı zamanda çıktı nöronu olarak görev yaptığı ağlardır. Hopfield ağları bu türde bir örnektir. Heteroasosyatif ağlar ise farklı girdi ve çıktı nöronlarının bulunduğu ağ yapılarıdır. Algılayıcı, çok katmanlı algılayıcı ve Kohonen ağı, bu türdeki örneklerden bazılarıdır [30].

Katman yapısına göre yapay sinir ağıları

Yapay sinir ağıları, yapay sinir hücresinin oluşturduğu bir yapıya sahiptir. Benzer özellikleri paylaşan YSH'lerin oluşturduğu topluluğa katman denir. Örneğin, girdi sinir hücreleri girdi katmanını oluştururken, çıktı sinir hücreleri çıktı katmanını temsil eder. Eğer bir YSA tek bir katmandan oluşuyorsa, buna tek katmanlı YSA denir. Ancak birden fazla katmandan oluşuyorsa, bu yapıya çok katmanlı YSA adı verilir.

Genel olarak yapay sinir ağılarına baktığımızda, insan beyninin çalışma prensiplerinden ilham alarak tasarlanmış yapay bir zeka modelidir. Bu ağılar, girdi verilerini işleyerek karmaşık ilişkileri öğrenme yeteneğine sahiptir ve geniş bir uygulama alanına sahiptirler. Yapay sinir ağıları, özellikle büyük veri setlerinden karmaşık desenleri çıkarmak, sınıflandırma, regresyon, desen tanıma, tahmin ve karar verme gibi birçok görevde etkili bir şekilde kullanılabilirler. Bu ağılar, öğrenme yetenekleri sayesinde çeşitli endüstrilerdeki problemleri çözmek için güçlü bir araç haline gelmiştir.

Ancak, yapay sinir ağılarıyla çalışmanın bazı zorlukları da vardır. Özellikle, ağların karmaşık yapıları ve eğitim süreçlerinin yoğunluğu, bazı durumlarda eğitim verilerine ve parametrelerin ayarlanmasına bağlı olarak uzun sürebilir. Ayrıca, ağların aşırı uyum (overfitting) eğilimi ve veriye bağımlılığı gibi bazı riskleri de bulunmaktadır. Sonuç olarak, Yapay Sinir Ağları, çeşitli alanlarda etkili bir şekilde kullanılabilen güçlü bir makine öğrenimi aracıdır. Ancak, bu ağıları başarılı bir şekilde uygulamak için, doğru veri setlerinin seçilmesi, uygun mimari ve parametrelerin belirlenmesi, eğitim süreçlerinin dikkatlice yönetilmesi ve sonuçların doğru bir şekilde değerlendirilmesi gerekmektedir.


3. LİTERATÜR ARAŞTIRMASI

Gamble ve arkadaşları tarafından yapılan çalışmada, Reynolds sayısının pervane performansı üzerindeki etkileri araştırılmıştır. Pervanenin şekil, burulma ve kiriş gibi geometrik özelliklerinin büyük ölçüde Reynolds sayısına bağlı olduğu bulunmuştur. Rüzgar tüneli testlerinde, APC tarafından üretilen yüksek burulma mukavemeti için cam dolgulu epoksi içeren pervaneler kullanılır, bu durum Resim 3.1.'de görülmektedir [37].



Resim 3.1. APC Pervane


APC 18x12 ve APC 18x8 pervaneleri sırasıyla 400 000 ila 502 000 ve 1 080 000 ila 1 213 000 arasında değişen farklı Reynolds sayıları için 7 farklı dönme hızında test edilmiştir. Reynolds sayısı arttığında verimliliğin, itme katsayısının, güç katsayısının ve eğimin arttığı bulunmuştur. Şekil 3.1.'de bu sonuçlar, itme katsayısı ve güç katsayısının değişimiyle birlikte gösterilmektedir. APC 18x12 pervanesinin Reynolds sayısının 400 000'den (1 700 rpm) 1 155 000'e (4 850 rpm) çıkarılmasıyla veriminin %5 arttığı tespit edilmiştir. Çap sabit tutulurken hatve azaltıldığından aynı itme kuvvetinin daha düşük hızlarda üretildiği görülmektedir. Başka bir deyişle, hatve veya hatve/çap oranı arttıkça verimlilik artar ve pervane daha yüksek ilerleme oranlarında itme kuvveti üretir. Sonuç olarak deneysel sonuçlar Reynolds sayısının küçük pervaneler üzerinde güçlü bir etkiye sahip olduğunu göstermektedir. Bu nedenle tasarımcı Reynolds sayısını dikkate almalıdır.



Şekil 3.1. APC 14x10 Thin elektrik pervanesinin rüzgar tüneli performansı: (a) itme katsayısı, (b) güç katsayısı

Rüzgar testleri performans testleri sonucunda, belirli bir pervane çapı için eğimi arttıkça, itki, güç ve verim katsayısı eğrilerinin yukarı ve sağa kaydığı gözlemlendi. Bu gözlem, bir pervanenin ilerleme oranı arttıkça, itki, güç ve verim katsayılarının daha yüksek değerlere sahip olacağı bir eğilime işaret etmektedir, bu genel eğilim beklenen bir durumdur. Dikkat edilmesi gereken nokta, yüksek çap ve hatve oranına sahip pervaneler için performans eğrilerinin, pervane denge kapaklarının yapısal tasarımı tarafından belirlenen 80 ft/s hız sınırı nedeniyle eksik olduğudur. Benzer şekilde, belirli bir pervane çapı için eğimi arttıkça, statik (sıfır hız) itki ve güç katsayılarının arttığı beklenen bir durumdur. Bu çalışmada gerçek dünya ortamında pervanelerin farklı koşullarda nasıl bir davranış sergilediği odak noktası olmuştur [38].

Kanat elemanı momentum (BEM) modeli sunulmuş ve UAS pervaneleri için performans tahminlerinde kullanılmıştır. Sonlu düşük Reynolds sayılı pervanelerin dönme akışıyla ilgili benzersiz özellikleri yakalamak için BEM modeline bir dizi düzeltme önerilmiştir. Özellikle, XFOIL tarafından üretilen aerodinamik veri tabanının kullanımı, uç kaybı düzeltmeleri, Mach düzeltmeleri ve modelin açısız akış bileşenlerinin dahil edilmesi gibi düzeltmeler modelde yer almıştır. Şekil 3.2.'de APC pervaneleri için analitik ve deneysel itme ve tork katsayıları verilmiştir. Bu çalışmada ele alınan belirli pervane geometrileri için, BEM modeli tahminleri sabit hatveli pervaneler için beklenen genel eğilimleri takip etmektedir. BEM modeli bir dizi rüzgar tüneli testi ile doğrulanmıştır. Bu testlerden, tahmin edilen ve ölçülen teorik eğim arasında olumlu karşılaştırmalar yapılmıştır.



Şekil 3.2. APC Pervaneler için analitik ve deneysel (a) itme ve (b) tork katsayıları


Tam güç testleri, küçük ölçekli pervaneler üzerine yapılan önceki çalışmalarda yayınlanan sonuçlara benzer sonuçlar vermiştir. Pervane verimliliği üzerindeki ölçek etkilerini göstermek için yeni bir sabit Reynolds sayısı testi sunulmuştur. Deneysel ve model tabanlı performans ölçümleri arasındaki karşılaştırmalar yapılmıştır, küçük ölçekli itki sistemlerinin analizinde Reynolds bağımlılığının dahil edilmesinin önemine işaret etmektedir. Burada sunulan ve doğrulanan BEM modeli, UAS için pervane tasarımı için son derece kullanışlıdır, özellikle de bu pervanelerin çalışma Reynolds sayıları, viskoz etkilerin birinci derecede önemli olduğu düşük seviyededir. Ayrıca, UAS itki sistemi için genel güç modeli, UAS için yüksek sadakatli araç performans tahminlerini ve uçuş testleri ve rutin operasyonlar için araç performansının uçuş sırasında belirlenmesini sağlar [39].

Yapılan bu çalışmada mini uçak pervanelerinin performansları statik ve dinamik testlerle belirlenmiştir. Pervanelerin statik olarak performanslarını değerlendirmek için bir pervane test düzeneği tasarlanmış ve bunun montajı yapılmıştır. Aynı test düzeneği, rüzgar tüneli içine yerleştirilmiştir. Statik testlerde, dört farklı Turbotek pervanesine ait itki, güç ve verim değerleri, pervane dönme hızının bir fonksiyonu olarak elde edilmiştir. Elde edilen bu veriler, Turbotek firmasının hesap sonuçları, Hesaplamalı Akışkanlar Dinamiği (HAD) analizi ve statik test sonuçları ile karşılaştırılmıştır. Dinamik testlerde, bu dört Turbotek pervanesinin itki katsayısı, güç katsayısı ve verim değerlerinin ilerleme oranının bir fonksiyonu olarak değişimi elde edilmiştir. Bu deneysel sonuçlar, Turbotek firmasının yaptığı analitik ve HAD sonuçları ile karşılaştırılmış ve deneysel sonuçlar başarılı bulunmuştur [40].

Çalışmada, bir ticari uçağın yakıt tüketim performansı yapay sinir ağı modeli ile performansı analizi yapılmıştır. Burada veriler ileri beslemeli bir sinir ağı modellenmiş ve yüksek doğruluklu simülasyon verileriyle (operasyonel uçuş planları) eğitilmiştir. Daha sonra, Quick Access Recorder'dan gelen gerçek uçuş verileri, modelin hiperparametrelerini ayarlamak için kullanılmıştır. En az hataya sahip on model seçilerek, QAR verilerinin bir kısmı ile teste tabi tutulmuştur. Bu on model arasındaki istatistiksel karşılaştırma sonunda en iyi model seçilmiştir. Son olarak, yakıt tüketimi tahmin hataları üç sigma sınırını aşan uçuşlar için bir tanımlama süreci açıklanmıştır. Bu model sadece beş temel parametre (kalkış ağırlığı, hava mesafesi, ortalama seyir Mach sayısı, irtifa parametresi ve yakıt kilometre sapması) ile oluşturulmuş olsa da, modelin doğruluk düzeyi yüksek seviyededir. Ayrıca, çalışma anormal yakıt tüketiminin belirlenmesi için ek bir

yöntem önermektedir [41].

Andrew Gong ve arkadaşları (2006), Uçuş sırasında bir itme ölçüm sistemi tüm uçuş koşullarında itme ölçümünü doğrudan sağlayacak bir sistem geliştirmiştir. Bu, hem uçak hem de tahrik sistemi performansını ölçmenin basit ve doğru bir çözümünü sağlayacaktır. Bu çalışmanın amacı bir uçağın performansındaki en önemli faktör olan sürüklenme polar olmasından kaynaklı sürüklenme poları ve itmenin, uçağın tüm performans özelliklerinin hesaplanabileceği bir temeli oluşturmaktadır. Geleneksel performans değerlendirme yöntemleri, modelin çeşitli hava hızlarında ve saldırı açılarında geniş bir rüzgar tüneli testi gerektirir. Bu, zaman alıcı bir süreçtir ve genellikle pervane akımının kaldırma ve sürüklenme üzerindeki önemli etkilerini göz ardı eder. Bu çalışma, küçük bir elektrikli İHA'da prototip bir uçuş sırasında itme ölçüm sisteminin tasarımını, yapımını ve testini sunmaktadır. Gerilim ölçer montajının tasarımı ve testi açıklanmış, ardından kalibrasyon sonuçları ve İÖS'nin bir İHA hava çerçevesine entegrasyonu sunulmuştur. Şekil 3.3'te, uçuş esnasında ölçülen pervane itki ve devri sunulmaktadır. Son olarak, rüzgar tüneli ve uçuş testi sonuçları, uçuş sırasında yapılan itme ölçümlerine dayanarak uçak performans parametrelerinin bir tahmini ile sunulmaktadır [42].



Şekil 3.3. Uçuş esnasında ölçülen pervane itki ve devri [42]

Çoğu İHA, 50 000 ila 100 000 arasında değişen düşük Reynolds sayılarında çalışan pervaneleri kullanmaktadır. Bu pervaneler için yeterli veri bulunmasa da, daha büyük uçaklar için pervanelerin performansı iyi belgelenmiştir. Bu nedenle bu çalışmada, bu tür pervanelerin testleri Illinois Üniversitesi, Urbana-Champaign'de gerçekleştirilmiş ve çapları 9 ila 11 inç arasında değişen 79 pervanenin performansı belirlenmiş ve statik itiş güçleri ölçülmüştür. Pervane testleri için kullanılan rüzgar tüneli Resim 3.2.'de verilmiştir. Illinois Üniversitesi, Urbana-Champaign'de alt ses hava tünelinin, 2.8 x 4.0 ft (0.853 x

1.219 m) dikdörtgen kesitli ve maksimum akış hızının 160 mph (71,53 m/s) olduğu bildirilmiştir [43].




Resim 3.2. Pervane testleri için kullanılan rüzgar tüneli [43]

Stephen A. Whitmore ve arkadaşının çalışmasında (2012), klasik bir birinci derece tasarım aracı olan birleşik kanat elemanı momentum teorisini tekrar ele almakta ve geliştirilmiş bir çözüm yöntemi sunmaktadır. Kanat eleman teorisi, bir pervane kanadını ayrımlar ve her elemanı ayrı ayrı analiz eder. Ancak, kanat eleman teorisi tek başına, akış alanının tamamlanması için gereken pervane kaynaklı giriş akış hızını tahmin etme yeteneğine sahip değildir. Kanat elemanı ve momentum teorileri birleştirilerek, birleştirilmiş bir düşük dereceli tahmin aracı olan kanat elemanı momentum teorisi oluşturulur. BEM teorisi, yerel indüklenmiş hızı hesaplamak için momentum teorisini kullanır ve bu bilgiyi kanat elemanı modeline dahil eder. Doğrusal olmayan BEM denklemlerine kapanış sağlamak için kullanılan geleneksel yöntem, küçük bir yerel saldırı açısı ve McCormick tarafından tüm kesitler boyunca düşük yerel indüklenmiş sürükleme varsayımlarını içerir. McCormick ayrıca, yerel indüklenmiş sürükleme miktarının yerel pervane itiş katsayısını sadece ihmal edilebilir derecede azalttığını varsayar. Bu varsayımlar, kapalı bir çözüm elde edilmesine izin verirken, yüksek ilerleme oranlarında ve bıçağın iç yarı uzunluğunda doğru olmadığı bilinmektedir.

Makale, bu hatalı ve basitleştirici varsayımlardan kaçınan doğrusal olmayan bir çözüm yöntemi sunar ve BEM modeli için bilinen analitik çözüm yöntemlerine genel bir iyileştirme sunar. İki BEM çözüm yöntemi kullanılarak yapılan hesaplamalar, küçük bir radyo kontrol (RC) uçağı pervanesi için toplanan rüzgar tüneli test verileriyle

karşılaştırılmıştır. Şekil 3.4. APC 8x8 Thin elektrik pervane için itki katsayısı ve güç sayısının karşılaştırmasını içermektedir. Çözüm yöntemleri karşılaştırılmış ve geleneksel lineer çözümün özellikle yüksek ilerleme oranlarında pervane performansını yüksek oranda tahmin ettiği gösterilmiştir [44].




Şekil 3.4. APC 8x8 Thin elektrik pervane için a) İtme Katsayısı (C_T) ve b) Güç katsayısı (C_P) karşılaştırmaları [44]

Hang Zhu ve arkadaşları (2021), Bu çalışmada rotorlu insansız hava araçları için bir pervane tasarımı için gereksinimleri ve pervane aerodinamik performansını hesaplamak için bir modelin analizini ortaya koymaktadır. Kanat eleman momentum teorisi temel alınarak, bir kanat elemanının aerodinamik kuvveti incelenir ve kullanılır. Simgesel NACA0012 airfoil modeli, modelin geçerliliğini doğrulamak için bir örnek olarak kullanılmaktadır. Bir pervane aerodinamik performansını test etmek için tasarlanmış ve inşa edilmiş bu deneysel sistem, APC pervanelerinin altı farklı pervane türünün aerodinamik performansını test etmek için kullanılır. Ayrıca, pervanelerin aerodinamik grafiklerini çizmek için üç pervane parametresinin (airfoil direnç gücü, indüklenmiş hız ve verimlilik) tek adımlı hesaplamalarını gerçekleştirmek için veri işleme yazılımı geliştirilmiştir. Deneyin sonuçları, pervanenin itme ve torkunun dönme hızı, pervane çapı ve pervane hatvesi ile arttığını göstermektedir. Çalışma sonucunda geliştirilen yeni sistem ve yazılım, pervane aerodinamik performans deney sisteminin tork ölçümünde daha hassas ve mevcut deneysel koşullar altında daha istikrarlı hale gelmesini sağlar. Pervane hızı, itme ve tork dahil olmak üzere deneysel veriler, APC pervanelerinin aerodinamik performansını analiz etmek için kullanılır. Deney için seçilen pervane, İHA'lar için en yaygın olarak kullanılan tiptir, bu da deneysel verilerin İHA'lar için pervane seçimine yardımcı olmak


konusunda daha ikna edici olmasını sağlar [45].

Zbigniew Czy ve arkadaşları (2021) yaptıkları çalışmada pervane geometrisinin pervanenin aerodinamik performansına etkisini araştırmıştır. Burada pervane performansını etkileyen faktörlerden biri de pervane hatvesidir. Bu parametre pervanenin bir dönüş sırasında ileri doğru hareket edeceği mesafeyi göstermektedir. Buradaki en önemli unsur pervane performansının en iyi olduğu noktadaki hatveyi belirlemektir. Bu çalışmada farklı hatveli pervanelerin aerodinamik performansının rüzgar tüneli ile test edip deneysel sonuçları belirlemektedir. Testler ses altı rüzgar tünelinde gerçekleştirilmiştir. Yapılan çalışma sonucunda, itme kuvveti, tork, güç, verimlilik ve itme-güç oranının boyutsuz katsayılarının değerlerini hesaplandı. Elde edilen sonuçlar, belirtilen katsayılar kriter olarak verildiğinde en uygun çözümün seçilmesine olanak sağlamaktadır. Daha yüksek hava akış hızları aralığında bir güç biriminden üretilen kuvvette bir azalma olduğunu gösterir, ancak yüksek hatveli pervaneler, daha yüksek hava akış hızı aralığında daha iyi sonuç verdiği gözlemlenmiştir. Şekil 3.5.'de farklı PWM değerleri için test edilen pervane seti için ilerleme oranının bir fonksiyonu olarak itme-güç oranını göstermektedir. [46].



Şekil 3.5. Farklı PWM değerleri için test edilen pervane seti için ilerleme oranının bir fonksiyonu olarak itme-güç oranı: (a) %40; (b) %60; (c) %80; (d) %90


Kelei Wang ve arkadaşları (2020) yaptıkları çalışmada pervane-uçak entegrasyonu için aerodinamik olarak performansın en yüksek performansa çıkarmayı amaçlayarak tasarım geliştirmiştir. Bu hibrit tasarım Pervane aerodinamiği için değişken doğruluklu modelleme, makul doğrulukla hesaplama verimliliği elde etmek için kullanılmıştır. Bu geliştirme hem kanadın kaldırma-sürüklenme oranında hem de pervane-kanat entegre aerodinamik verimliliğinde önemli iyileştirmeler elde etmektedir. Bu da aerodinamik olarak pervanenin performansını olumlu yönde etki etmektedir. Şekil 3.6.'da, pervane-uçak entegrasyonunda kullanılan çözümün kanatta oluşan kaldırma kuvvetine etkisinin karşılaştırılması sunulmaktadır [47].



Şekil 3.6. Pervane-uçak entegrasyonunda kullanılan çözümün kanatta oluşan kaldırma kuvvetine etkisinin karşılaştırılması [47]


Xiying Gong ve arkadaşları (2017) Yüksek irtifa pervanelerinin aerodinamik performans testleri için bir yer test sistemi tasarlanmıştır. Bu sistem stabil güç kaynağı, servo motorlar, gerilim-basınç sensörleri ile oluşturulan iki bileşenli denge, ultrasonik anemometre ve veri toplama modülünden oluşmaktadır. Bu sistem rüzgar tüneline simüle etmek için düşük hava yoğunluğunda ve farklı rüzgar koşullarında yüksek bir aracın üzerine yüklenerek testler gerçekleştirilmiştir. Bu çalışma yüksek irtifada pervane testi için yeni bir test yöntemi ortaya koymaktadır. Rüzgar tüneli test platformu olmayan veya rüzgar tüneli testine uygun olmayan, rüzgar türbinlerinin akışkan alan karakteristiği ve çıkış verimliliği gibi deneysel modeller de bu makalede açıklanan Araca monteli test platformuyla test

edilebilir. Şekil 3.7.'de, pervanenin farklı yüksekliklerde 5 m/s rüzgar hızıyla itme kuvveti sunulmaktadır [48].




Şekil 3.7. Pervanenin farklı yüksekliklerde 5 m/s rüzgar hızıyla itme kuvveti, a) 0,5 km; b) 3,6 km.

Lütfi Öner ve arkadaşları (2010) yaptıkları çalışmada klasik ve modern yöntemlerin pervane analizi için efektifliklerini incelemektedir. Klasik teorinin pala elemanı-basitleştirilmiş momentum teorisi ile temsil edilebileceği düşünülerek bu teorilerini denklemleri kullanılarak bir hesaplama aracı bilgisayar ortamında elde edilmiştir. Çeşitli pervaneler CFD yöntemi ile analiz edilmiştir. Analizler tasarım noktasında ve civarında (çeşitli ilerleme oranları ve oturma açılarında) yapılmıştır. Tasarım noktasındaki itki katsayısının hesaplanmasında iki yöntemin de başarılı olduğu tespit edilmiştir. Güç katsayısının hesabında ise klasik teori CFD yöntemine nazaran daha doğru sonuçlar verdiği görülmüştür. Tasarım noktasından uzaklaşıldıkça hata oranı her iki yöntem içinde doğruluk oranı artmıştır. Klasik teorinin aksine kesit karakteristiklerinin bilinmesine gerek yoktur. Şekil 3.8.'de, deney, teori ve CFD metodları kullanılarak pervane performansının değerlendirilmesi sunulmaktadır. Analiz sonuçlarında hem klasik teori hem de CFD yöntemi ile tasarım noktasında hata payı oldukça düşüktür. Fakat tasarım noktasından uzaklaşıldıkça her iki yöntemin de kusurları ortaya çıkmakta ve hata oranı yükselmektedir. Güç katsayısının hesaplanmasında kesit karakteristikleri deney verilerinden alındığı için klasik teori daha başarılı sonuçlar vermiştir [49].



Şekil 3.8. Deney, teori ve CFD metodları kullanılarak pervane performansının değerlendirilmesi

Oğuz Kaan Onay ve arkadaşları (2012) İHA kullanılmak üzere iki adet pervanenin tasarımından, analitik tabanlı bir yöntem kullanılarak yapılmış olan analiz sonuçlarından, HAM ile yürütülmüş analiz sonuçlarından ve performans test sonuçlarını karşılaştırmıştır. 2 adet İnsansız Hava Aracı pervanesinin rüzgar tüneline dinamik testleri gerçekleştirilmiş ve yapılmış olan HAM analiz sonuçları ile karşılaştırılmıştır. Çalışma sonunda CFD ile elde edilmiş veriler ile HAM analiz sonuçlarının yakında değer verdiği ortaya çıkarılmıştır. Bu da pervane optimizasyonu için HAM analiz yönteminin kullanılabileceğini ortaya koymaktadır. Şekil 3.9'da, XOAR 26x16 pervanesinin deneysel olarak ve HAM analiz yöntemi ile elde edilen itki katsayısı (C_t) değerlerinin karşılaştırılması sunulmaktadır [50].



Şekil 3.9. XOAR 26x16 pervanesinin deneysel olarak ve HAM analiz yöntemi ile elde edilmiş itki katsayısı (C_t) değerlerinin karşılaştırılması

Xiaojing Wu ve arkadaşları (2024) yaptıkları çalışmada İHA’da kullanılan elektrikli tahrik sisteminin pervane verimliliği üzerinde çalışma gerçekleştirmiştir. CFD ve Pervane Teorisi yöntemlerinin optimizasyon tasarımında doğruluk ile tasarım verimliliği arasındaki çelişki yaratabilmektedir. Bu yüzden çalışmada elektrikli uçak pervanelerinin optimizasyon tasarımı için çok doğruluklu yapay sinir ağı tabanlı bir optimizasyon çerçevesi tanımlanmıştır. Bu yöntem, yüksek doğruluklu CFD sayısal simülasyonlarına dayanmaktadır. Tasarım verimliliğini ve doğruluğunu artırmak için, az sayıda CFD simülasyonu ile daha yüksek model doğruluğu elde etmeyi amaçlayan düşük-yükseklik dereceli BEMT bilgisini birleştirmektedir. Kullanılan bu yöntem, pervanenin seyir halindeki verimliliğini CFD ve BEMT tarafından tasarlanmış olan %82,3’lük verim noktasından yeni kullanılan yöntem ile %87,1’e iyileştirmektedir. Yöntem, tek yükseklik dereceli optimizasyonlarla karşılaştırıldığında optimizasyon etkinliği ve verimliliğinde avantajlar gösterdiği ortaya çıkarılmıştır [51].

Burhan Pamuk yaptığı çalışmada, NACA 4412 kanat profili profiline sahip pervaneler CFD analiz yöntemini kullanılarak dört farklı hücum açısı için aerodinamik olarak modellemiştir. Bu pervaneler daha sonra farklı hız rejimlerinde aerodinamik olarak test edilmesi için rüzgar tüneline test edilmiştir. Yapılan CFD analiz ve rüzgar tüneli testleri sonucunda pervanelerin hücum açısı arttıkça pervane düzlemi önünde ve arkasında oluşan basınç farkı azaldığı görülmektedir. Bu da sürtünme katsayısını düşürmekte ve yüksek hızlarda avantaj sağlamaktadır fakat düşük hızlarda pervanenin ürettiği itki az olacağından hücum açısı etkin olması gerekmektedir [52].

4. MATERYAL VE METOD

Materyal ve metod bölümü çeşitli başlıklar halinde incelenmiştir.

4.1. Pervane Modellenmesi

İHA pervanelerinin çok doğruluk yöntemiyle yapay sinir ağı modelleriyle modellenmesi, havacılık ve uzay gibi alanlarda kullanılması oldukça önemlidir. Çok doğruluklu modelleme yöntemleri, farklı doğruluk seviyelerindeki veri veya modelleme tekniklerini bir araya getirerek daha doğru sonuçlar elde etmeyi amaçlar. Yapay sinir ağları hem yüksek hem de düşük doğruluklu modeller için veri odaklı bir yaklaşım sunmaktadır. Yüksek doğruluk gerektiren modeller için derin öğrenme teknikleri kullanılabilirken, düşük doğruluklu modeller için daha basit yapılara sahip YSA'lar yeterli olmaktadır. Oluşturulan yapay sinir ağı modellerinin gerçek dünya koşullarında ne kadar iyi performans gösterdiğini doğrulamak için deneysel testler ve doğrulama süreçleri de gereklidir. Bu tür bir çalışma, İHA pervanelerinin tasarımı ve optimize edilmesi sürecinde önemli bir rol oynayabilir. Bu çalışmada oluşturulan yapay sinir ağı modelleri performansları, pervanelerin rüzgar tüneli test sonuçlarıyla karşılaştırılmış ve doğrulama süreçleri gerçekleştirilmiştir.

4.2. Simülasyon Pervane Veri Seti İncelenmesi ve Düzenlenmesi

İHA pervanelerinin çok doğruluklu modelleme yöntemiyle modellenmesine geçilmeden önce kullanılacak verilerin belirlenmesi ve verilerin belirli bir formatta düzenlenmesi ve verilerin incelenmesi gerekmektedir. İlk önce veri olarak APC pervanelerinin “Thin Elektrik” ve “Sport” türündeki pervanelerinin simülasyon verileri modelleme için belirlenmiştir. Bu iki türün seçilmesinin sebebi “Sport” tip pervanelerin içten yanmalı motorlarda kullanılması, “Thin Elektrik” tip pervanelerinde elektrik motorlarında kullanılıyor olmasından dolayı hem elektrik motoru için hem de içten yanmalı motor için bu iki pervane tipi tercih edilmiştir.


Modelleme olarak ilk olarak simülasyon verisi olan “Sport” ve “Thin Elektrik” simülasyon verileri kendi içlerinde modellenecektir. Kendi içinde modellenen “Sport” ve “Thin

Electric” simülasyon verileri ile model yardımıyla rüzgar tüneli verisi olan “Sport” ve “Thin Elektrik” tip pervanelerde aynı çap ve hatvedeki pervanelerin verileri çıkarılacaktır. Daha sonra simülasyon ve rüzgar tüneli test verisi olan pervaneler ile birlikte model oluşturulacak en sonunda oluşturulan modeller ile “Sport” ve “Thin Elektrik” tip pervanelerde rüzgar tüneli verisi olmayan pervanelerinde verisi çıkarılabilecektir. Modeller oluşturulmadan önce veriler incelenecek ve modeller için gerekli veri düzenleme ve fonksiyonel fit işlemleri yapılacaktır. APC pervanelerinin verileri pervane üreticisi tarafından “FlightStream” simülasyon uygulamasıyla simülasyon verileri çıkarılmıştır. Bu veriler üretici tarafından paylaşılmaktadır. Bu verilerin içeriğinde modellemeye kullanılması için “Sport” pervane türünde 151 adet farklı çap ve hatve kombinasyonunda 1 000 RPM ve 45 000 RPM aralığında pervaneler ile ilgili veriler bulunmaktadır. Bunun yanında “Thin Elektrik” pervane tipinde 101 adet farklı çap ve hatve kombinasyonunda 1 000 RPM ve 45 000 RPM aralığında pervaneler ile ilgili veriler bulunmaktadır.

“Sport” ve “Thin Elektrik” tipteki pervane verileri *“RPM V J Pe Ct Cp PWR Torque Thrust PWR_W Torque_NM Thrust_N THR/PWR Mach Reyn FOM”* formatında yan yana olacak şekilde düzenlenmiştir.


“Sport” ve “Thin Elektrik” tipindeki farklı çap ve hatve kombinasyonlarındaki pervane verileri yukarıda belirtilen formatta veri düzeltilmesi yapıldıktan sonra “Sport” ve “Thin Elektrik” tip pervane verilerini incelemek için çeşitli grafikler kullanılarak incelenmiştir.

Şekil 4.1.’de “Sport” tip pervanelerde sabit RPM, sabit pervane hatve açısı ve sabit $J=0$ olduğu değerler için pervanenin çapı arttıkça C_t değerlerinin değişimi incelenmiştir. Pervane çapı arttıkça elde edilen C_t azaldığı görülmüştür. Bunun nedeni sabit hatve için pervane çapı arttığında pervanenin hava ile temas eden yüzey alanı artmış olur. Buda daha fazla hava direncine maruz kalmasına sebep olur ve C_t , C_p düşebilir.




Şekil 4.1. "Sport" tip pervane RPM= 4 000, Hatve= 10, J=0 için artan pervane çapına göre C_t (İtki Katsayısı Değişimi)

Şekil 4.2.'de "Thin Elektrik" tip pervaneler için sabit RPM, sabit pervane hatve açısı, sabit J=0 için pervanenin çapının artmasına göre güç katsayısı değişimi incelenmiştir. Pervane çapı arttıkça C_p ihtiyacının düştüğü görülmüştür. Pervaneler için sabit hatve durumunda pervane çapının artmasının özellikle aerodinamik verimliliği azaltacağı ve bundan dolayı da itki ve güç üretimini olumsuz etkileyecektir. İncelenen verilerdeki davranışların bu yönde olduğu ve doğru davranış gösterdikleri görülmüştür.




Şekil 4.2. "Thin Elektrik" tip pervane RPM= 2 000, Hatve= 6, J=0 için artan pervane çapına göre C_p (Güç Katsayısı Değişimi)

Şekil 4.3.'te sabit çap, sabit RPM, sabit J değerindeki verilerin davranışı incelenmiştir. Burada pervane sabit çapta pervane hatvesi arttığında C_t arttığı gözlemlenmiştir. Bunun nedeni pervane hatvesi arttığında, pervane kanatlarının etkin yüzey alanı artmasından kaynaklanmaktadır. Bu, hava akımına maruz kalan kanat yüzeyinin artması anlamına gelir. Daha fazla yüzey alanı, hava tarafından itilen kütlenin daha fazla itilmesine ve bu da daha fazla itki üretilmesine yol açar.



Şekil 4.3. "Sport" tip pervane RPM= 2 000, Çap= 10, J=0 için artan pervane hatvesine göre C_t (İtme Katsayısı Değişimi)


Pervane hatve açısı arttığında, hava akımına karşı gelen açı da artar. Bu, hava akımının daha etkin bir şekilde pervane kanatlarına çarpmasını sağlar, dolayısıyla daha fazla itme kuvveti ve güç üretilir. Ancak bu durum sadece sabit RPM ve sabit çap için geçerlidir. RPM veya hava hızı gibi diğer faktörler değişirse, sonuçlar farklı olabilir. Ancak incelenen veride hatve arttıkça C_t ve C_p değerlerinin artmasının verinin incelenmesi açısından verinin doğru davranış sergilediğini göstermektedir.




Şekil 4.4. "Thin Elektrik" tip pervane RPM= 3 000, Çap= 13, J=0 için artan hatvesine göre C_p (Güç Katsayısı Değişimi)

Şekil 4.3. ve Şekil 4.4.'te "Sport" ve "Thin Elektrik" tipteki pervanelerin farklı çap ve hatve kombinasyonları için $J-C_p$ değerlerinin farklı RPM değerlerine göre davranışları, bunun yanında $J-C_t$ değerlerinin farklı RPM değerlerine göre davranışları incelenmiştir. Grafik değerlendirmeleri sonucunda farklı çap ve hatve kombinasyonlarına göre $J-C_p$, $J-C_t$ değerlerinin RPM'lere göre nasıl bir davranış gösterdiğine göre fit fonksiyonu belirlenecektir. Burada J, hız, pervane rpm değeri ve pervane çapına göre değişmektedir.

Şekil 4.5. ve Şekil 4.6.'da 22x10 pervane için değerler incelenmiştir. Burada 22 değeri pervanenin inç cinsinden çapını 10 değeri de pervanenin inç cinsinden adımını (pitch) belirtmektedir. $J-C_t$ ve $J-C_p$ grafiklerinde J arttıkça itki katsayısı ve güç katsayısının düştüğü görülmüştür.



Şekil 4.5. “Sport” 22x10 J - C_p Değerlerinin RPM’e göre değişim grafiği



Şekil 4.6. “Sport” 22x10 J - C_t Değerlerinin RPM’e göre değişim grafiği

Şekil 4.6.’da örnek olarak verilen Sport tip pervaneye ait veriler dışında tüm Sport tip pervane verilerindeki C_t ve C_p değerlerinin J değerlerine göre farklı RPM’lere göre davranışları incelendiğinde polinomik bir davranış gösterdiği ve sürekli azalan olduğu gözlemlenmiştir.

Görsel olarak eğrilerin davranışları incelendiğinde polinom fonksiyonu (4.1) kullanılarak dördüncü derece bir fit atılmasının eğrilerin gösterdiği davranış olarak daha fazla esneklik sağlayacağı için daha doğru olacağı düşünülmüştür.


$$F(x) = a.x^4 + ab.x^3 + c.x^2 + d.x + e \quad (4.1)$$

a, b, c, d, e değerleri, belirli bir model fonksiyonu kullanılarak verilere en iyi uyan parametreler olarak fit işlemi ile bulunur.

Polinom fonksiyonu kullanılarak “Sport” ve “Thin Elektrik” tip pervaneler için farklı çap ve hatve kombinasyonlarında farklı RPM değerlerine göre a, b, c, d, e katsayılarının bulunması için J değerine göre fit işlemi gerçekleştirilir. Burada a, b, c, d, e katsayıları atılan fit eğrisini tanımlayan katsayılardır. Fit atılırken her bir RPM, çap ve hatve için J ve Ct/Cp değerleri belirlenmiştir.

Farklı pervane çap, hatve ve RPM değerlerine göre atılan fit sonucu çıkan a, b, c, d, e değerleri, polinom fonksiyonunda x yerine J yazılarak Ct veya Cp bulunmaktadır. Simülasyon modelleri için bu atılan fit işlemi kullanılacaktır. Örnek gösterim olarak 11 inç çapına ve 5 inç pervane adımına sahip pervane tercih edilmiştir.

Şekil 4.7.’de “Sport” ve “Thin Electric” pervane tipleri için her bir çap ve hatve kombinasyonuna göre değişken RPM değerleri için a, b, c, d, e katsayıları bulunmuştur. Bu katsayılar “.csv” uzantılı dosyaya yazdırılarak kaydedilmiştir.



Şekil 4.7. “Sport” 11x5 Pervanenin C_t için değişken RPM değerlerine göre a , b , c , d , e katsayıları

4.3. Pervane Modeli Kurulma Hazırlıkları

Model kurulması ve makine öğrenmesi için Python tercih edilmiştir. Makine öğrenmesi, Python dilinde bir dizi kütüphaneler kullanılarak gerçekleştirilmektedir.

Makine öğreniminden önce verilerin düzenlenmesi ve belirli düzenli bir formata getirilmesi gerekmektedir. Veri setindeki verilerin düzenlenmesi, verilerin incelenmesi ve analiz edilmesi, veriler için uygun fonksiyon fit işlemi gerçekleştirilmiştir. Model oluşturmadan önce modele öğretilecek giriş (input) değerleri ve modelin daha sonra kullanılarak almak istediğimiz çıkış (output) değerleri belirlenmiştir.

Input için “x” değerine karşılık olarak d , p , RPM belirlenmiştir. Burada “x” değeri modelin tahmin yapmak için kullandığı bağımsız değişkenlerdir.

Output olarak “y” değerine karşılık olarak a , b , c , d , e değerleri belirlenmiştir. Burada “y” değeri modelden çıkış hedefini temsil etmektedir. Bu hedefler modelin tahmin etmeye çalıştığı bağımlı değişkenlerdir.

Veri seti eğitim ve test kümelerine ayrılmıştır. X_{train} ve y_{train} olarak modelin eğitileceği eğitim kümeleri belirlenmiştir. Bunun yanında X_{test} ve y_{test} olarak test kümesi belirlenmiştir. Bu test kümeleri modelin performansının değerlendirilmesinde

kullanılacak olan verileri içermektedir. Literatürde çoğunlukla veri setinin %80 modelin eğitilmesi için eğitim kümesi, %20 modelin test edilmesi için test kümesi olarak bölmek kabul görmektedir.

Bu çalışma için eğitim seti üzerinde temel olarak modelleme işlemleri gerçekleştirilerek en doğru model performansı ve makine öğrenmesi algoritması bulunmaya çalışılmıştır.

Modeli eğitmek için kullanılacak veri seti büyük olduğundan dolayı ve modelin öğrenme yeteneğinin yüksek olması amaçlandığından eğitim seti için %90 veri seti, test seti içinde %10 veri seti ayrılmıştır.

Validation bölümü test veri setinden seçilmiştir. Bu, modelin eğitim verisi üzerinde aşırı overfitting yapmasını engellemeye yardımcı olur ve modelin yeteneğini artırmaktadır. Validation bölümünde model test veri seti sayesinde iyileştirilmeye çalışılır. Bunun için en hiper parametrik (hyperparameter tuning) uygulamalar denenerek model için en optimum ve yüksek doğruluklu sonucu vereceği durum bulunmaya çalışılır.

Validation parametresine için kullanılan X_{test} , test veri kümesindeki giriş özelliklerini içerirken ve y_{test} veri kümesi modelin çıkış hedeflerini içermektedir. Bu şekilde, her epoch sonunda modelin test verisi üzerindeki performansı değerlendirilir ve modelin eğitilmesi bu değerlendirmeye göre şekillendirilir.

Modele öğretilecek olan veri setleri model kurmadan önce literatürde görüldüğü gibi genellikle scaler işlemleri yapılmaktadır. Scaler işlemlerinin yapılmasının nedeni veri seti büyüklüğüne göre veri içerisinde değerler 0 ile 1 arasında değer alıyor olabilirken, bazı değerlerde çok daha büyük bir aralıkta değerler alabilir. Bunun dışında scaler işlemleri modelin overfitting yapmasını önleyebilir. Overfitting modelin çok fazla fit olup uyum sağlamasına ve yeni, görünmemiş veriye karşı kötü performans sergilemesidir. Scaler yöntemiyle, modelin overfitting durumları da modelin performansı artacağı için daha az olacaktır. Bu nedenlerden dolayı, scaler işlemleri makine öğrenimi modellerinin performansını artırmak ve doğru sonuçlar elde etmek için önemlidir.

Bu çalışma için StandartScaler yöntemi kullanılmıştır. Bu yöntem veri seti büyük olduğundan dolayı outlier değerlerin etkisini azaltır ve veriyi daha kararlı hale

getirmektedir. Bu yüzden modelin performansını artırmak için StandartScaler kullanılmıştır. StandartScaler yöntemi her verinin ortalama değerini 0 ve standart sapmasını 1 yaparak özellikler arasındaki farklılıkları dengeler. Bu işlem sonucunda veri setinin aynı ölçekte olmasını sağlar (4.2).

$$x_{scaled} = \frac{x - mean(x)}{std(x)} \quad (4.2)$$

Burada;

- x : Ölçeklendirecek veri
- X_{scaled} : Ölçeklendirilmiş veri
- $Mean(x)$: Verinin ortalaması
- $Std(x)$: Verinin standart sapması

Denklem 4.2’de her bir veri özelliği, o özelliğin ortalamasından çıkarılır ve standart sapmasına bölünerek ölçeklenir. StandartScaler işlemi X_{train} , X_{test} , y_{train} ve y_{test} veri setleri için uygulanır. X_{train} eğitim verisinin özelliklerini ölçeklendirerek her bir özelliği ayrı ayrı ortalama 0 ve standart sapması 1 olacak şekilde dönüştürür. X_{test} veri seti için modelin eğitilmesinden sonra modelin performansını değerlendirmek için kullanılacaktır. Test veri seti de modelin öğrenmesini değerlendirebilmek için aynı şekilde StandartScaler yöntemi ile ölçeklendirilir.

Çizelge 4.1. StandartScaler ilk üç işlemi

StandartScaler Öncesi X_{train}		
p (Hatve)	d (Çap)	RPM
4,5	10,5	1 000
4,5	10,5	2 000
4,5	10,5	3 000
StandartScaler Sonrası X_{train}		
-1,18697295	-0,67559799	-0,26098421
0,81122165	-0,20597828	0,37658234
-0,87955839	0,36800136	0,16406016

StandartScaler, her bir özelliği (sütun) ayrı ayrı ölçeklendirir. Bu nedenle, pervane çapı ve pervane hatvesi için Çizelge 4.1.'de belirtilen 10.5 ve 4.5 değeri burada her sütun için farklı bir ölçeklendirme sonucuna sahip olabilir. Özellikle, veri setindeki “p” ve “d” (Hatve ve Çap) sütunlarının değerleri, “RPM” sütunundaki değerlerden çok daha küçüktür. Bu durumda, StandartScaler her sütunu kendi içinde ölçeklendirir ve sonuç olarak 10.5 ve 4.5 değerleri her sütun için farklı bir ölçeklendirme sonucuna sahip olur.

Benzer şekilde, `y_train` ve `y_test` verilerinin ölçeklendirilmesi de aynı nedenlerle gerçekleştirilir. Ancak, hedef değişkenleri genellikle ayrı olarak ölçeklendirilir. Çünkü bu değişkenler tek boyutlu olduğundan dolayı aynı ölçekte tutmak modelin eğitimi ve tahminlerini daha istikrarlı hale getirir.

4.3.1. Pervane modelinin Python’da oluşturulması

Model kurulmadan önce veriler bir formatta düzenlenmiş ve modele uygun şekilde veri setleri hazırlanmıştır. Modeli hazırlamadan önce gerekli scaler işlemleri yapılmış ve veri setleri model için uygun hale gelmiştir. “Sport” tip pervane için C_t ve C_p için ayrı model, “Thin Electric” tip pervane verileri için C_t ve C_p olmak üzere toplam 4 adet yapay sinir ağı modelleri oluşturulacaktır.

Model oluşturulmaya başlanırken Python’da bulunan keras kütüphanesinde kullanılan Sequential model ile model oluşturulmaya başlanmıştır. Sequential model oluşturulmasının nedeni basit yapılı ve doğru sonuç veren bir model tipi olmasıdır.

Sequential model, yapay sinir ağı modelleri oluştururken model içindeki katmanlar sıralı bir şekilde eklenmektedir. Model içindeki katmanların sıralı olması model karmaşıklığını azaltmaktadır. Sequential modellerine katmak eklemek ve modeli derleme işlemleri kolay olduğundan dolayı en doğru sonucu verebilecek modeli belirleme süreci daha hızlı olabilmektedir.

Sequential model kullanılırken modelin öğrenme esnasında overfit olmaması için dropout regularizasyon tekniği koyulmuştur. Bu modelde dropout yöntemi her eğitimin iterasyonunda belirli bir oranda rastgele olarak modelin nöronlarını devre dışı bırakarak

çalışır. Bu sayede, her bir eğitim örneği için veri seti farklı bir mimari ile eğitilir ve nöronlar arasındaki bağımlılık azaltılır.

Dropout işlemi modelin her gizli katmanına koyulacaktır. Literatürde genellikle 0,1-0,5 gibi değerler seçilmektedir. Model oluştururken bu değer Dropout (0,1) seçilmiştir. Bu, her eğitim iterasyonunda rastgele seçilen bir alt kümesi hariç tutularak yapılır. Bu nedenle, her eğitim iterasyonunda farklı bir alt küme hariç tutulur. Dropout (0,1) ifadesi her eğitim iterasyonunda her nöronun çıkışının, eğitim sırasında %10 olasılıkla rastgele kapatılacağını belirtir. Bu işlem her katman için iterasyonda tekrarlanır.

Model kurulmaya başlanırken giriş katmanı belirlenir. Veri seti karmaşık ve büyük olduğu için giriş katmanı için nöron sayısı 256 olarak tercih edilmiştir. Bunun sebebi veri setini modele öğretirken daha karmaşık yapıdan dolayı modelin performansının düşmemesidir. Aynı zamanda modelin hızlı öğrenmesi ve verimli olarak çalışması da nöron sayısı ile bağlantılı olduğundan dolayı nöron sayısı yüksek bir giriş katmanı tercih edilmiştir. Birçok katmanın çıktısını kabul eden bir katmanın geometrisini oluştururken denge oluşturmak için genellikle 2'nin üstel bir kuvveti seçilebilmektedir. Bu, verilerin boyutunu etkili bir şekilde işlemek için gereken bir pratiktir.

Diğer katmanlar oluştururken veri setinin karmaşıklığı, model kapasitesi, modelin overfitting durumuna gelmemesi ve bilgisayar durumları göz alınarak deneme yanılma yöntemleriyle oluşturulmuştur. Oluşturulan modelde giriş ve çıkış katmanı dahil toplamda 5 adet katman vardır. Çıkış katmanı hariç, giriş katmanı ve diğer katmanlar 256 nöron ve 0,1 Dropout katmanlarından oluşmaktadır. Çıkış katmanı olarak 5 nöronlu oluşan bir katman tercih edilmiştir.

Oluşturulan her katmanda aktivasyon fonksiyonu olarak ReLU kullanılmıştır. ReLU, negatif girişleri sıfır olarak döndürürken, pozitif girişleri aynen geçirmektedir. Bu basit yapısından dolayı modelin hesaplamasının hızlı olmasını sağlamaktadır. ReLU aktivasyon fonksiyonu genellikle daha iyi bir genelleme performansına sahiptir. Model, özellikle büyük veri setleriyle eğitildiğinde, daha iyi bir performans gösterir ve overfitting durumundan kaçınmış olur. Ayrıca ReLU fonksiyonu negatif bölgesinde sabit bir değer döndürdüğü için sıfır merkezli olmayan bir fonksiyondur. Buda modelin öğrenmesini çeşitlendirebilir.

Literatür arařtırmalarında da yapay sinir ağı modelleri oluřtururken çoęu modelde dięer aktivasyon fonksiyonları arasından ReLU tercih edildięi görölmüřtür. Bu alıřma için oluřturulan modelde her katman için ReLU aktivasyon fonksiyonu tercih edilmiřtir.

Model katmanları oluřturduktan sonra modelin derlenmesi ve kayıp fonksiyonu belirlenmiřtir. Yapay sinir aęları modellerinde derlenmesi için optimizasyon algoritması kullanılmaktadır. Bu optimizasyon algoritmaları modelin eęitim verilerine daha iyi uymasını saęlamak için model parametrelerini ayarlamaktadır. Optimizasyon algoritmaları aynı zamanda model için kullanılan kayıp fonksiyonunu minimize etmeye alıřmaktadır. Bu, modelin tahminlerinin gerek deęerlere daha yakın olmasını saęlamaktadır. Optimizasyon algoritması modelin eęitim sürecini hızlandırıp daha iyi sonuçlar elde etmede kullanılmaktadır. Oluřturulan modelde optimizasyon algoritması olarak “adam” tercih edilmiřtir. Bunun sebebi “Adam” her model parametresi için ayrı ayrı uyarlanmış bir öęrenme oranı kullanmaktadır.

Bu, farklı parametrelerin farklı hızlarda güncellendięi anlamına gelmektedir ve eęitim sürecini optimize etmiř olur. “Adam”, momentum ve adım boyutu gibi ek ayarlamalar içermektedir. Bu ayarlar, modelin eęitimini daha stabil hale getirmektedir. Genellikle yapay sinir aęları modelleri için kullanıldığında tercih edilen bir optimizasyon algoritmasıdır ve model oluřtururken tercih edilmiřtir.

Model katmanları, Dropout, aktivasyon fonksiyonu ve optimizasyon algoritmaları belirlendikten sonra kayıp fonksiyonu seilmesi kalmıřtır.

Kayıp fonksiyonu bir makine öęrenimi tahminlerinin gerek deęerlerden ne kadar uzak olduęunu gösteren bir metriktir. Modelin eęitimi sırasında, kayıp fonksiyonu modelin performansını deęerlendirir ve modelin parametrelerini güncellemek için kullanılmıřtır. Genellikle literatürde de göröldüęü gibi modelin tahmin yeteneęi ne kadar fazlaysa, kayıp fonksiyonu o kadar düşük olması beklenir.

Kayıp fonksiyonu modelin parametrelerini güncellemek için optimizasyon algoritmaları tarafından kullanılmaktadır. Optimizasyon algoritmaları kayıp fonksiyonun azaltılması için model parametrelerini ayarlar.

Oluşturulan model de kayıp fonksiyonu olarak MSE kullanılmıştır. Bu kayıp fonksiyonu literatürde ve çalışmalarda yaygın olarak kullanılan ve özellikle yapay sinir ağı oluştururken regresyon problemlerinde sıkça kullanılan bir kayıp fonksiyonudur. MSE kayıp fonksiyonu 4.4’te görülmektedir.

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (4.4)$$

Burada:

- n veri noktalarının sayısını,
- y_i gerçek değerleri,
- $\hat{y}_i$ tahmin edilen değerleri temsil etmektedir.

MSE, tahminler ile gerçek değerler arasındaki farkların karesini alır ve bu değerlerin ortalamasını alarak kayıp hesaplamaktadır.

Çizelge 4.2.’de kurulan modelin katman ve gizli katmanları sonucunda oluşan modelin yapısı görülmektedir. Bu katmanlarda bulunan nöron sayısı veri setine göre belirlenmiştir.

Çizelge 4.2. “Sport” tip pervane için C_t tahmini yapmak için oluşturulan modelin yapısı ve özeti

“Sport Tip” C_t Sequential Model		
Katman (Tip)	Çıkış Şekli	Parametre
Dense (Katman)	256	1 024
Dropout	256	0
Dense (Katman)	256	65 792
Dropout	256	0
Dense (Katman)	256	65 792
Dropout	256	0
Dense (Katman)	256	65 792
Dropout	256	0
Dense (Katman)	5	1285
Total Parametre = 199 942		Trainable Parametre = 199 942

Modeli eğitmeye başlamadan önce parametre ayarları belirlenmiş ve parametre ayarları yapılmıştır. Model eğitmek için kullanılacak olan veri seti çok büyük olduğundan dolayı “batch_size” kullanılmıştır. “Batch_size” modelin eğitim sırasında veri setinin iterasyonundaki örnek sayısını belirtmektedir. Veri seti çok büyük olduğundan dolayı bellek kullanımı ve işlem süresini azaltmak için “batch_size= 64” olarak belirlenmiştir. Bu veri setinin her “epochs” döngüsünde veri seti 64’lük mini parçalara bölünerek modele öğretim işlemi olacaktır. “batch_size” belirlenmesi model performansını etkileyebileceği için bellek kullanımı ve model performansı göz önüne alınarak 64 belirlenmiştir.

Oluşturulan yapay sinir ağı modeli için bir “Epoch” sayısı belirlenmesi gereklidir. “Epoch” terimi bir makine öğrenimi modelinin eğitilmesi sırasında tüm eğitim veri setinin model tarafından kaç kez kullanılacağını belirten bir parametredir. “Epoch” değeri ne kadar yüksekse, model daha uzun süre eğitilir ve daha fazla öğrenme gerçekleştirir. Ancak “Epoch” değerini yüksek bir değer seçmek modelin overfit olmasına yol açabilir. “Epoch” değeri literatürde genellikle anlatıldığı ve kullanıldığı gibi deneme yanılma yöntemiyle belirlenmektedir. “Epoch” değeri küçük değerden başlanarak farklı “Epoch” değerine göre modelin performansları karşılaştırılır. Genellikle büyük veri setlerini daha fazla eğitmeye ihtiyaç duyar bu yüzden “Epoch” değeri genellikle yüksek seçilir.


Oluşturduğumuz model için deneme yanılma yöntemiyle en optimum “Epoch” değerinin 3 000 olduğu belirlenmiştir. Yani modelimiz tüm eğitim veri setini 3 000 kez kullanarak öğrenecektir. Validation parametresi de daha önce bahsedildiği gibi “X_test” ve “y_test” olarak belirlenmiştir. Tüm parametreler belirlendikten sonra modeli eğitme işlemi başlamıştır.

Sport tip pervane itki katsayısı (C_t) modelinin eğitime hazırlanması ve parametrelerin belirlenmesi


“Thin Elektrik” ve “Sport” tip pervanelerin C_t ve C_p değerlerini bulmak amacıyla 4 farklı model oluşturulmuştur. Bu modeller farklı “Epoch” değerleri kullanılarak deneme yanılma yöntemiyle modellerin en başarılı olduğu “Epoch” değeri bulunmuştur ve modeller o “Epoch” değerine göre veri setiyle eğitilmiştir.

Modeller eğitildikten sonra modeller ile ilgili görselleştirme için grafikler kullanılmıştır. İlk olarak “Loss” ve “Validation Loss” grafiği çizilerek modelin eğitimi sırasında eğitim ve validation veri setlerine karşı model performansına bakılmıştır. Burada model performansı “Epoch” değerine göre overfit olabileceği için uygun “Epoch” sayısı bulmak için 1 000, 2 000 ve 3 000 “Epoch” değerleri denenmiş ve uygun “Epoch” değeri belirlenmiştir.


Şekil 4.8., Şekil 4.9. ve Şekil 4.10. “Loss-Validation Loss” grafikleri incelendiğinde “Loss” sonucu modelin eğitim veri setine uygulanan kayıp fonksiyonu ile gerçek çıktılar arasındaki farkı göstermektedir. “Validation Loss” sonucu modelin doğrulama veri setine uygulanan kayıp fonksiyonudur.



Şekil 4.8. “Sport” tip pervane Ct tahmin modeli 3 000 “Epoch”



Şekil 4.9. “Sport” tip pervane C_t tahmin modeli 2 000 “Epoch”



Şekil 4.10. Sport” tip pervane C_t tahmin modeli 1 000 “Epoch”

Bu sonuç modelin eğitim veri setine aşırı uyum sağlayıp sağlamadığını değerlendirmek için kullanılmaktadır. “Loss-Validation Loss” grafikleri incelendiğinde ideal durumda belirli bir “Epoch” değerinden sonra Loss ve Validation Loss sonuçları üst üste gelerek azalmaya devam etmesi gerekmektedir. Ancak, bir noktadan sonra “Loss” düşmeye devam ederken “Validation Loss” artmaya başlarsa, model overfit davranış göstermeye başladığı gözlemlenebilir.

Şekil 4.8., Şekil 4.9. ve Şekil 4.10. Grafikleri incelendiğinde “Epoch” değeri 1 000’den fazla olduğunda yani 2 000 ve 3 000 “Epoch” için olan “Loss” ve “Validation Loss” birbirinde ayrılarak “Loss” azalmaya devam ederken “Validation Loss” ayrılarak artmaya başlamıştır. Burada “Sport” tip pervane C_t tahmin modeli için en uygun “Epoch” değerinin 1 000 olduğu görülmektedir.

Çizelge 4.3. ve 4.4.’te modelin öğrenme sonucu performanslarına bakılmıştır. Burada model performansı kayıp fonksiyonları ve R^2 skoruna göre karşılaştırılmıştır. Bu karşılaştırma sonucunda model için en uygun “Epoch” sayısı belirlenmiş ve modelin eğitilme işlemi tamamlanmıştır.

Çizelge 4.3. Optimum model belirlemek için kullanılan “Epoch” sayıları ve modeller

Model No	Model Türü	Katmanlarda Bulunan Nöron Sayısı	Epoch Değeri	Katman Sayısı	Kayıp Fonksiyonu
1	“Sport” C_t Tahmin Modeli	256	1 000	5	MSE
2	“Sport” C_t Tahmin Modeli	256	2 000	5	MSE
3	“Sport” C_t Tahmin Modeli	256	3 000	5	MSE

Çizelge 4.4. “Epoch” Değerlerine göre “Sport” Ct model performanslarının kayıp fonksiyonlarına göre ve R^2 yöntemine göre karşılaştırılması

Model No	Model Türü	Epochs	MAE	MSE	RMSE	R^2
1	“Sport” Ct Tahmin Modeli	1 000	0,07658598	0,020980655	0,27674172	0,97716268
2	“Sport” Ct Tahmin Modeli	2 000	0,06815506	0,021718502	0,26106525	0,97590614
3	“Sport” Ct Tahmin Modeli	3 000	0,07105544	0,023027681	0,26656226	0,97489554


3 farklı “Epoch” değerine göre modelin eğitilmesi sonucunda model performansları değerlendirilmiştir. Burada “Epoch” sayısı arttıkça modelin performansı düştüğü gözlemlenmiştir. R^2 değeri, modelin verilere ne kadar iyi uyduğunu gösterir ve 0 ile 1 aralığında olur. R^2 değeri 1’e ne kadar yakınsa modelin verilere daha iyi uyum sağladığı anlamına gelmektedir. “Epoch” değerlerine göre Loss-Validation ve model sonuçları grafikleri de göz önüne alındığında “Epoch” değeri 1 000 değerini aştığında modelin overfit davranışta gösterdiği gözlemlenmiştir.

Bu yüzden model parametreleri olarak birinci modelin parametreleri alınacaktır. “Sport” Ct tahmin modelinin veri setiyle eğitilmesi için kullanılacak olan hiperparametreler şunlardır;

- 5 Katman
- 1 Giriş Katmanı, 3 Katman, 1 Çıkış Katmanı
- Batch size 64
- 1 000 Epochs,
- Çıkış Katmanı hariç katmanlarda 256 Nöron
- Mean Squared Error (MSE) Kayıp Fonksiyonu
- ReLU Aktivasyon Fonksiyonu
- Adam Optimizasyon Algoritması
- Standart Scaler
- Validation (X_{test} , y_{test})

Sport tip pervane modelinin eğitilmesi ve model çıktıları


“Sport” Ct Tahmin Modeli belirlenen hiper parametreler ile eğitilmiştir. Veri setiyle eğitilen modelin çıktıları grafikler yardımıyla gözlemlenmiştir. Şekil 4.11.’de model eğitimi bittikten sonra model performansını değerlendirmek için grafik çizilmiştir. “Predictions-Real Values” grafikleri genellikle model veri setiyle eğitildikten sonra gözlemlenir. Bu grafik, modelin ne kadar iyi çalıştığını ve tahminlerin gerçek değerlere ne kadar yakın olduğunu değerlendirmek için kullanılır. Şekil 4.11.’de tahmin edilen değerler ile gerçek değerler arasındaki ilişkiyi göstermektedir. Bu grafik sonuçları incelendiğinde çoğunlukla tahmin edilen değerler ile gerçek değerler birbirine yakın olduğu koşulda, grafik üzerinde bu iki değer için noktalar çizgi gibi gözükmeleri gerekmektedir. “Sport” Ct tahmin modeli “Predictions-Real Values” grafiği incelendiğinde grafikteki noktaların çizgi formunu oluşturduğu bazı noktaların çizgi formu dışında gözükmese de yoğunluk olarak noktaların çizgi formunda toplandığı görülmektedir. Bu sonuç veri setiyle eğitilen modelin tahmin değerleri ile gerçek değerlerin çok yakın olduğunu bize göstermektedir.




Şekil 4.11. “Sport” Ct tahmin modeli Predictions-Real Values grafiği

Veri setiyle eğitilen modelde çıktı olarak a , b , c , d , e değerlerini modelin tahmin yapması beklenmektedir. Bu tahmin edilen a , b , c , d , e değerlerine göre de değişen pervane ve hatvelere göre farklı RPM'ler için C_t tahmini yapılmış olacaktır.


Şekil 4.12., Şekil 4.13., Şekil 4.14., Şekil 4.15. ve Şekil 4.16. grafikleri incelendiğinde polinom fonksiyon için veri seti ile eğitilerek oluşturulan modelin tahminleri, modele eğitimi başlamadan önce RPM'lere göre atılan fit değerleri yakın olduğu görülmektedir. Burada pervanenin farklı çap ve hatve kombinasyonlarına göre değişken RPM'ler için a , b , c , d , e katsayı değerleri oluşturulan model ile elde edilebilmektedir. Model yardımıyla farklı RPM'ler için tahmin edilen a , b , c , d , e değerleri için kullanılan fonksiyon yardımıyla farklı J değerlerine göre C_t değerleri hesaplanır. Bu hesaplanan C_t değerleri veri setinden bulunmayan yeni bir J değeri için C_t tahmini elde etmek için kullanılacaktır.




Şekil 4.12. “Sport” C_t Modelin RPM'lere göre “a” değeri tahmin performansı




Şekil 4.13. “Sport” C_t Modelin RPM’lere göre “b” değeri tahmin performansı



Şekil 4.14. “Sport” C_t Modelin RPM’lere göre “c” değeri tahmin performansı




Şekil 4.15. “Sport” Ct Modelin RPM’lere göre “d” değeri tahmin performansı




Şekil 4.16. “Sport” Ct Modelin RPM’lere göre “e” değeri tahmin performansı

Model yardımıyla tahmin edilen a , b , c , d , e fonksiyon katsayı değerleri ile fonksiyon kullanılarak farklı pervane çap, hatve ve RPM değerlerine göre modelin C_t tahmin performansını değerlendirmek için grafikler çizilmiştir. Örnek olarak 11 inç pervane çapına ve 5 inç pervane adımına sahip pervane Şekil 4.17. ve Şekil 4.18.’de gösterilmiştir.



Şekil 4.17. “Sport” Tip pervane C_t tahmin modeli 11x5 Pervane 1 000 RPM model performansı



Şekil 4.18. “Sport” Tip pervane C_t tahmin modeli 22x10 Pervane 5 000 RPM model performansı

Şekil 4.17. ve Şekil 4.18.’de “Sport” tip pervane C_t tahmin model performansı incelenmiştir. Gerçek veri ile tahmin edilen verinin grafik üzerinde üst üste geldiği

görülmüştür. Buda model performansının farklı tip ve pervane ve RPM'ler için gerçek veriye çok yakın değerler tahmin ettiğini ve modelin performansının çok iyi olduğunu göstermektedir.

“Sport” tip pervane C_t tahmin modeli başarılı bir şekilde oluşturulduktan sonra simülasyon verileri için 3 adet daha model oluşturulması gerekmektedir. Geriye kalan 3 model “Sport” tip C_p tahmin modeli, “Thin Elektrik” C_t tahmin modeli, “Thin Elektrik” C_p tahmin modelleri oluşturulacaktır. Simülasyon verileri için modeller oluşturulduktan sonra rüzgar tüneli verisi olan pervanelerin karşılığı simülasyon modellerinden çıkarılarak rüzgar tüneli için model oluşturulmaya geçilecektir.


Sport tip pervane güç katsayısı (C_p) modelinin eğitime hazırlanması ve parametrelerin belirlenmesi

“Sport” tip pervane C_p tahmin modeli oluştururken yine model oluştururken C_p verileri için fit atılmıştır. Fit işlemi için 4.5 denkliği kullanılmıştır.

$$F(x) = a \cdot x^5 + ab \cdot x^4 + c \cdot x^3 + d \cdot x^2 + e \cdot x + f \quad (4.5)$$

C_p veri seti için a, b, c, d, e, f değerleri, polinom fonksiyonu kullanılarak verilere en iyi uyan parametreler olarak fit işlemi ile bulunur. Burada a, b, c, d, e, f katsayıları atılan fit eğrisini tanımlayan katsayılardır. Fit atılırken her bir RPM, çap ve hatve için J ve C_p değerleri belirlenmiştir. Burada farklı pervane çap, hatve ve RPM değerlerine göre atılan fit sonucu çıkan a, b, c, d, e, f değerleri, polinom fonksiyonunda x yerine J yazılarak C_p bulunmaktadır.

Şekil 4.19.'da örnek olarak “Sport” 22x10 pervane için her bir çap ve hatve kombinasyonuna göre değişken RPM değerleri için a, b, c, d, e, f katsayıları bulunmuştur. Bu katsayılar .csv uzantılı dosyaya yazdırılarak kaydedilmiştir.



Şekil 4.19. “Sport” 22x10 Pervanesinin C_p için değişken RPM değerlerine göre a, b, c, d, e, f katsayıları

Sport tip pervane güç katsayısı (C_p) modelinin eğitime hazırlanması ve parametrelerin belirlenmesi

“Sport” tip pervane C_p veri seti için fit işlemi gerçekleştirildikten sonra, model parametreleri belirlenmiştir. Model parametreleri belirlenirken “Sport” tip pervane C_t tahmin modeli için kullanılan parametrelerde göz önünde bulundurularak parametreler belirlenmiştir.

“Sport” C_p tahmin modelinin veri setiyle eğitilmesi için kullanılacak olan hiperparametreler şunlardır;

- 5 Katman
- 1 Giriş Katmanı, 3 Katman, 1 Çıkış Katmanı
- Batch size 128
- 1 000 Epochs,
- Çıkış Katmanı hariç katmanlarda 256 Nöron
- Mean Squared Error (MSE) Kayıp Fonksiyonu
- ReLU Aktivasyon Fonksiyonu
- Adam Optimizasyon Algoritması

- Standart Scaler
- Validation (X_{test} , y_{test})

Bu parametreler ile model eğitilerek model çıktıları gözlemlenmiştir. Model performansına göre parametreler değiştirilebilir ve yeni model kurulabilir. “Sport” tip pervane için C_p tahmini yapmak için oluşturulan modelin yapısı ve özeti Çizelge 4.5. ile verilmiştir.

Çizelge 4.5. “Sport” tip pervane için C_p tahmini yapmak için oluşturulan modelin yapısı ve özeti

“Sport Tip” C_p Sequential Model		
Katman (Tip)	Çıkış Şekli	Parametre
Dense (Katman)	256	1 024
Dropout	256	0
Dense (Katman)	256	65 792
Dropout	256	0
Dense (Katman)	256	65 792
Dropout	256	0
Dense (Katman)	256	65 792
Dropout	256	0
Dense (Katman)	5	1 285
Total Parametre = 199 942		Trainable Parametre = 199 942


“Sport” tip pervane C_p tahmin modeli oluşturulduktan sonra veri seti kullanılarak model eğitilmiştir. Modele uygun “Epochs” sayısı yine deneme yanılma yöntemiyle belirlenecektir. Modelin overfit olmadığı noktadaki “Epoch” seçilecektir. “Epoch” Değerlerine göre “Sport” C_p model performanslarının kayıp fonksiyonlarına göre ve R^2 yöntemine göre karşılaştırılması Çizelge 4.6. ile verilmiştir.

Çizelge 4.6. “Epoch” Değerlerine göre “Sport” C_p model performanslarının kayıp fonksiyonlarına göre ve R^2 yöntemine göre karşılaştırılması


Model No	Model Türü	Epochs	MAE	MSE	RMSE	R^2
1	“Sport” C_p Tahmin Modeli	1 000	0,113650164	0,03376242	0,33712040	0,93645643
2	“Sport” C_p Tahmin Modeli	2 000	0,096302056	0,02140052	0,31032573	0,95785928
3	“Sport” C_p Tahmin Modeli	3 000	0,083826924	0,01667836	0,28952879	0,96819425
4	Sport” C_p Tahmin Modeli	3 500	0,093630874	0,02217496	0,30599162	0,956501655

“Sport” tip pervane C_p tahmin modeli için kullanılan “Epoch” değerlerine göre modellerin performansları karşılaştırılmıştır. Çizelge 4.6.’ya baktığımızda performans ölçütlerine göre ve kayıp fonksiyon sonuçlarına göre üçüncü modelin daha düşük MSE, RMSE ve MAE değerlerine sahip olduğu ve aynı zamanda en yüksek R^2 değerine sahip olduğu görülüyor. Bu nedenle üçüncü modelin diğer “Epoch” değerleri için oluşturulan modellere göre daha iyi performans gösterdiği görülmektedir.


Şekil 4.20., Şekil 4.21., Şekil 4.22. ve Şekil 4.23.’te “Sport” tip pervane C_p tahmin modeli için farklı “Epoch” değerlerindeki model performansları karşılaştırıldıktan sonra bu modeller için overfit durumu olup olmama durumları da gözlemlenmiştir. Bunun için “Loss-Validation Loss” grafikleri incelendiğinde model öğrenme performansı en iyi “Epoch” değeri 3 000 olan modelde görülmüştür. Farklı “Epoch” değerleri için “Loss-Validation Loss” incelendiğinde 3 000 “Epoch” değerinde Loss ve Validation Loss değerleri üst üste gelmeye başlamıştır. Modellerin kayıp fonksiyonlarına göre performansları ve “Loss-Validation” grafikleri incelendiğinde en iyi performans gösterecek olan üçüncü model seçilmiştir.




Şekil 4.20. “Sport” Tip pervane C_p tahmin modeli 1 000 “Epoch”



Şekil 4.21. “Sport” Tip pervane C_p tahmin modeli 2 000 “Epoch”



Şekil 4.22. “Sport” Tip pervane C_p tahmin modeli 3 000 “Epoch”




Şekil 4.23. “Sport” Tip pervane C_p tahmin modeli 3 500 “Epoch”

Sport tip pervane güç katsayısı (C_p) modelinin eğitilmesi ve model çıktıları

“Sport” C_t Tahmin Modeli belirlenen hiperparametreler ve “Epoch” değeri ile eğitilmiştir. Veri setiyle eğitilen modelin çıktıları grafikler yardımıyla gözlemlenmiştir.

Şekil 4.24.’te “Sport” C_p tahmin modeli “Predictions-Real Values” grafiği incelendiğinde grafikteki noktaların çizgi formunu oluşturduğu çok nadir olarak noktaların çizgi formu


dışında olduğu görülmektedir. Bu sonuç veri setiyle eğitilen modelin tahmin değerleri ile gerçek değerlerin çok yakın olduğunu bize göstermektedir. Veri setiyle eğitilen “Sport” tip pervane C_p tahmin modelinde çıktı olarak a , b , c , d , e , f değerlerini modelin tahmin yapması beklenmektedir. Bu tahmin edilen a , b , c , d , e , f değerlerine göre de değişen pervane ve hatvelere göre farklı RPM’ler için güç katsayısı tahmini yapılmış olacaktır.




Şekil 4.24. “Sport” C_p Tahmin modeli Predictions-Real Values grafiği

Şekil 4.26., Şekil 4.27., Şekil 4.28., Şekil 4.29. ve Şekil 4.30. incelendiğinde polinom fonksiyonda bilinmeyen olan a , b , c , d , e , f değerleri için “Sport” tip pervane veri setiyle eğitilerek oluşturulan modelin tahminleri, model oluşturulmadan önce 5.dereceden polinom fonksiyon ile atılan fit değerlerine 22x10 pervanesine göre yakın olduğu görülmektedir. Bu modelde “Sport” tip pervanelerin farklı çap ve hatve kombinasyonlarına göre değişken olan RPM değerleri için a , b , c , d , e , f katsayı değerlerini model ile tahmin edilebilmektedir. Oluşturulan model ile farklı RPM değerleri için tahmin edilen a , b , c , d , e , f katsayı değerleri 5. dereceden polinom fonksiyonda yerine yazılarak farklı J değerleri


için C_p değerleri hesaplanır. Model yardımıyla hesaplanan C_p değerleri veri setinde bulunmayan yeni bir J değeri için C_p değeri hesaplayabilmektedir.




Şekil 4.25. “Sport” C_p Modelin RPM’lere göre “a” değeri tahmin performansı




Şekil 4.26. “Sport” C_p Modelin RPM’lere göre “b” değeri tahmin performansı




Şekil 4.27. “Sport” C_p Modelin RPM’lere göre “c” değeri tahmin performansı



Şekil 4.28. “Sport” C_p Modelin RPM’lere göre “d” değeri tahmin performansı




Şekil 4.29. “Sport” C_p Modelin RPM’lere göre “e” değeri tahmin performansı



Şekil 4.30. “Sport” C_p Modelin RPM’lere göre “f” değeri tahmin performansı

“Sport” tip pervane C_p tahmin modeliyle tahmin edilen a , b , c , d , e , f 5. dereceden polinom fonksiyon katsayı değerleri ile fonksiyon kullanılarak farklı pervane çap, hatve ve

RPM değerlerine göre modelin C_p tahmin performansını değerlendirmek için grafikler çizilmiştir. Şekil 4.31.’de modelin tahmin performansı incelendiğinde gerçek veri seti ile model yardımıyla tahmin edilen değerlerin üst üste geldiği görülmüştür. Bu grafik değerlendirildiğinde oluşturulan “Sport” tip pervane C_p tahmin modelinin çok iyi performans gösterdiğini göstermektedir.




Şekil 4.31. “Sport” Tip pervane C_p tahmin modeli 10x8 pervane 3 000 RPM model performansı


Thin elektrik tip pervane itki katsayısı (C_t) modelinin eğitime hazırlanması ve parametrelerin belirlenmesi

“Thin Elektrik” tip pervane C_t modeli oluşturmadan önce “Thin Elektrik” pervanelerin veri seti incelenmiştir. “ $J-C_t$ ” ve “ $J-C_p$ ” grafikleri çizilerek veri setinin davranışı gözlemlenmiştir.

Şekil 4.32. ve Şekil 4.33. incelendiğinde görsel olarak eğrilerin davranışları incelendiğinde polinom fonksiyon kullanılarak dördüncü derece fonksiyon kullanılarak bir fit atılmasının eğrilerin gösterdiği davranış olarak daha fazla esneklik sağlayacağı için daha doğru olacağı düşünülmüştür (4.6).



Şekil 4.32. "Thin Elektrik" 18x12 J - C_p değerlerinin RPM'e göre değişim grafiği




Şekil 4.33. "Thin Elektrik" 18x12 J - C_t değerlerinin RPM'e göre değişim grafiği

$$F(x) = a \cdot x^4 + ab \cdot x^3 + c \cdot x^2 + d \cdot x + e \quad (4.6)$$

Fonksiyon kullanılarak a , b , c , d , e değerleri, belirli bir model fonksiyonu kullanılarak verilere en iyi uyan parametreler olarak fit işlemi ile bulunur. Fit işlemi gerçekleştirildikten sonra a , b , c , d , e fonksiyon katsayıları farklı RPM değerleri için fit işlemi sayesinde çıkarılmıştır.

Şekil 4.34.’te örnek olarak “Thin Elektrik” 24 inç pervane çapı ve 12 inç pervane adımına sahip pervane için C_t tahmin modeli oluşturmadan önce her bir çap ve hatve kombinasyonuna göre değişken RPM değerleri için dördüncü derece polinom fonksiyon için a , b , c , d , e katsayıları bulunmuştur. Bu katsayılar .csv uzantılı dosyaya yazdırılarak kaydedilmiştir.



Şekil 4.34. “Thin Elektrik” 24x12 Pervanesinin C_p için değişken RPM değerlerine göre a , b , c , d , e katsayıları

Thin elektrik tip pervane itki katsayısı (C_t) modelinin eğitime hazırlanması ve parametrelerin belirlenmesi

“Thin Elektrik” tip pervane için C_t veri seti üzerinde fit işlemi gerçekleştirildikten sonra, model parametreleri belirlendi. Bu parametrelerin belirlenmesinde, daha önce oluşturulan “Sport” tip pervaneler için oluşturulan C_t/C_p tahmin modellerinde kullanılan parametreler göz önünde bulunduruldu.

“Thin Elektrik” tip pervane C_t tahmin modeli için kullanılan hiperparametreler aşağıdaki gibidir:

- 5 Katman
- 1 Giriş Katmanı, 3 Katman, 1 Çıkış Katmanı

- Batch size 64
- 2 000 Epochs,
- Çıkış katmanı hariç katmanlarda 256 Nöron
- Mean Squared Error (MSE) Kayıp Fonksiyonu
- ReLU Aktivasyon Fonksiyonu
- Adam Optimizasyon Algoritması
- Standart Scaler
- Validation (X_test, y_test)
- Test size %1

Bu hiperparametreler ile model eğitimi yapılacaktır. Ancak model çıktılarına göre hiperparametrelerde değişiklik olabilir. Çizelge 4.7. “Thin Elektrik” tip pervane için Ct tahmini yapmak için oluşturulan modelin yapısı ve özetini göstermektedir.

Çizelge 4.7. “Thin Elektrik” tip pervane için Ct tahmini yapmak için oluşturulan modelin yapısı ve özeti

“Thin Elektrik” Ct Sequential Model		
Katman (Tip)	Çıkış Şekli	Parametre
Dense (Katman)	256	1 024
Dropout	256	0
Dense (Katman)	256	65 792
Dropout	256	0
Dense (Katman)	256	65 792
Dropout	256	0
Dense (Katman)	256	65 792
Dropout	256	0
Dense (Katman)	5	1 285
Total Parametre = 199 682		Trainable Parametre = 199 685


“Thin Elektrik” tip pervane için Ct tahmini yapmak amacıyla oluşturulan model, veri setiyle eğitilecektir. Modelin eğitiminde, overfit olma durumunun önlenmesi için uygun “Epochs” sayısı deneme yanılma yöntemiyle belirlenecektir. Modelin overfit olmadığı noktada ve Loss-Validation Loss değerlerinin üst üste gelmeye başladığı noktaki “Epoch”

değeri seçilerek model oluşturulacaktır. Çizelge 4.8. ile “Epoch” değerlerine göre “Thin Elektrik” Ct model performanslarının kayıp fonksiyonlarına göre ve R^2 yöntemine göre karşılaştırılması verilmiştir. Çizelge 4.8. incelendiğinde farklı “Epochs” değerlerine göre eğitilen modellerin kayıp fonksiyon ve R^2 çıktıları görülmektedir. Burada MSE ve R^2 değerleri incelendiğinde tablodaki ikinci model için MSE değeri daha düşük R^2 değeri daha yüksek olduğu görülmektedir. Bu sonuçlar ikinci modelin daha iyi performans gösterdiğini gösterir.


Çizelge 4.8 “Epoch” Değerlerine göre “Thin Elektrik” Ct model performanslarının kayıp fonksiyonlarına göre ve R^2 yöntemine göre karşılaştırılması

Model No	Model Türü	Epochs	MAE	MSE	RMSE	R^2
1	“Thin Elektrik” Ct Tahmin Modeli	1 000	0,053557896	0,00950610	0,2314257	0,989563567
2	“Thin Elektrik” Ct Tahmin Modeli	2 000	0,049799937	0,00868807	0,2231589	0,990751634
3	“Thin Elektrik” Ct Tahmin Modeli	3 000	0,064339681	0,02053448	0,2536527	0,978242248


Şekil 4.35., Şekil 4.36. ve Şekil 4.37. incelendiğinde “Epochs” değeri 1 000, 2 000, 3 000 değerleri için veri setiyle eğitilen modellerin Loss-Validation Loss grafikleri görülmektedir. Bu grafiklere baktığımızda “Epochs” değeri 2 000 olduğunda Loss-Validation Loss eğrilerinin tam üst üste geldiği görülmektedir. Burada “Epochs” değeri 3 000 olan model için Loss-Validation Loss grafiğinde eğriler üst üste gözüксе de modelin kayıp fonksiyon performansı ve R^2 Değerleri “Epochs” değeri 2 000 için daha kötü performans sergilediği görülmektedir. “Thin Elektrik” tip pervane Ct tahmin modeli için “Epochs” değeri 2 000 belirlenmiş ve veri setiyle birlikte model eğitilmiştir.



Şekil 4.35. “Thin Elektrik” tip pervane Ct tahmin modeli 1 000 “Epoch”




Şekil 4.36. “Thin Elektrik” tip pervane Ct tahmin modeli 2 000 “Epoch”



Şekil 4.37. “Thin Elektrik” tip pervane C_t tahmin modeli 3 000 “Epoch”


Thin elektrik tip pervane itki katsayısı (C_t) modelinin eğitilmesi ve model çıktıları

“Thin Elektrik” C_t Tahmin Modeli belirlenen hiperparametreler ve “Epoch” değeri 2 000 ile eğitilmiştir. Modelin eğitilmesi sonucu çıktılar grafiksel olarak gösterilmiştir. Şekil 4.38. “Thin Elektrik” tip pervane için C_t tahmin modelinin “Predictions-Real Values” grafiği incelendiğinde, grafikteki noktaların genellikle bir çizgi oluşturduğu ve nadiren noktaların çizgi dışında kaldığı görülmektedir. Bu durum, modelin eğitildiği veri setiyle gerçek değerler arasında çok yakın tahminler yaptığını göstermektedir. “Thin Elektrik” tip pervane için C_t tahmin modelinin çıktıları arasında, modelin a , b , c , d , e gibi değerleri tahmin etmesi beklenmektedir. Bu tahmin edilen değerlere göre değişen çap ve hatvelere sahip pervaneler için farklı RPM değerlerinde C_t tahminleri gerçekleştirilecektir.




Şekil 4.38. “Thin Elektrik” C_t tahmin modeli Predictions-Real Values grafiği


Şekil 4.39., Şekil 4.40., Şekil 4.41., Şekil 4.42. ve Şekil 4.43. incelendiğinde polinom fonksiyonda bilinmeyen olan a , b , c , d , e değerleri için “Thin Elektrik” tip pervane C_t veri setiyle eğitilerek oluşturulan modelin tahmin çıktıları alınmıştır. Bu grafikler incelendiğinde grafiklerde eğrilerin tam üst üste olmadığı görülebilmektedir. Ancak bunun genel C_t tahmin performansını düşüren bir farklılık değildir. Gerçek veri seti değerleri ve tahmin değerleri 0 değerine çok yakın olduğu için modelin C_t tahmin performansının her şekilde iyi olması beklenmektedir.




Şekil 4.39. “Thin Elektrik” Ct Modelin RPM’lere göre “a” değeri tahmin performansı




Şekil 4.40. “Thin Elektrik” Ct Modelin RPM’lere göre “b” değeri tahmin performansı



Şekil 4.41. “Thin Elektrik” Ct Modelin RPM’lere göre “c” değeri tahmin performansı




Şekil 4.42. “Thin Elektrik” Ct Modelin RPM’lere göre “d” değeri tahmin performansı



Şekil 4.43. “Thin Elektrik” C_t Modelin RPM’lere göre “e” değeri tahmin performansı

Eğitilen modelde “Thin Elektrik” tip pervanelerin farklı çap ve hatve kombinasyonlarına göre değişken olan RPM değerleri için a , b , c , d , e katsayı değerlerini model ile tahmin edilebilmektedir. Oluşturulan model ile farklı RPM değerleri için tahmin edilen a , b , c , d , e katsayı değerleri 4.dereceden polinom fonksiyonda yerine yazılarak farklı J değerleri için C_t değerleri hesaplanır. Model yardımıyla hesaplanan C_t değerleri veri setinde bulunmayan yeni bir J değeri için C_t değeri hesaplayabilmektedir.

Şekil 4.44. incelendiğinde modelin veri setindeki farklı J değerlerine göre C_t karşılıkları ile farklı J değerlerine göre tahmin ettiği C_t değerlerinin aynı olduğu görülmektedir. Buradan “Thin Elektrik” tip pervane C_t tahmin modeli performansının iyi olduğunu söyleyebiliriz.




Şekil 4.44. “Thin Elektrik” Tip pervane C_t tahmin modeli 10x5 Pervane 4000 RPM model performansı

Thin elektrik tip pervane güç katsayısı (C_p) modelinin eğitime hazırlanması ve parametrelerin belirlenmesi

Şekil 4.32. incelendiğinde veri seti davranışı sürekli azalan bir davranış göstermektedir. Bu yüzden fit atmak için dördüncü dereceden polinom fonksiyon tercih edilmiştir. Dördüncü dereceden polinom fonksiyon veri seti davranışlarına göre daha esneklik sağlayacağından dolayı tercih edilmiştir (4.7).

$$F(x) = a.x^4 + ab.x^3 + c.x^2 + d.x + e \quad (4.7)$$

Şekil 4.45.’te 4.7 fonksiyonu kullanılarak a , b , c , d , e değerleri veri setine göre fit atma işlemi ile bulunmuştur. Bu a , b , c , d , e değerleri farklı çap ve hatve için değişken RPM değerlerine göre fit işlemi sonucu bulunmuştur.



Şekil 4.45. “Thin Elektrik” 14x7 Pervanesinin C_p için değişken RPM değerlerine göre a , b , c , d , e katsayıları

Farklı çap ve hatve için değişken RPM değerlerine göre bulunan dördüncü derece polinom fonksiyon için a , b , c , d , e katsayıları .csv uzantılı dosyaya yazdırılarak kaydedilmiştir.

Dördüncü dereceden polinom fonksiyonu için fit işlemi gerçekleştirdikten sonra yapay sinir ağı modeli oluşturulacaktır. Bu model oluşturulmadan önce modelin parametreleri belirlenmiştir. Bu parametreler daha önce oluşturulan “Sport” tip pervane C_t/C_p modelleri ve “Thin Elektrik” tip pervane C_t modeli parametreleri baz alınarak belirlenmiştir.

“Thin Elektrik” tip pervane C_p tahmin modeli için kullanılan hiperparametreler aşağıdaki gibidir:

- 5 Katman
- 1 Giriş Katmanı, 3 Katman, 1 Çıkış Katmanı
- Batch size 64
- 2 000 Epochs,
- Çıkış Katmanı hariç katmanlarda 256 Nöron
- Mean Absolute Error (MAE) Kayıp Fonksiyonu
- ReLU Aktivasyon Fonksiyonu

- Adam Optimizasyon Algoritması
- Standart Scaler
- Validation (X_{test} , y_{test})
- Test size %1

Belirlenen parametreler ile yapar sinir ağı modeli eğitilecektir. Ancak model çıktısına göre hiperparametreler değişiklik gösterebilir. Çizelge 4.9., “Thin Elektrik” tip pervane için C_p tahmini yapmak için oluşturulan modelin yapısı ve özetini göstermektedir.

Çizelge 4.9. “Thin Elektrik” tip pervane için C_p tahmini yapmak için oluşturulan modelin yapısı ve özeti


“Thin Elektrik” C_p Sequential Model		
Katman (Tip)	Çıkış Şekli	Parametre
Dense (Katman)	256	1 024
Dropout	256	0
Dense (Katman)	256	65 792
Dropout	256	0
Dense (Katman)	256	65 792
Dropout	256	0
Dense (Katman)	256	65 792
Dropout	256	0
Dense (Katman)	5	1 285
Total Parametre = 199 685		Trainable Parametre = 199 685

Oluşturulan yapay sinir ağı modeli daha önce oluşturulan modellerden referans alınarak oluşturulmuştur. “Thin Elektrik” tip pervane için C_p tahmini yapmak için kullanılacaktır. Modelin parametrelerine göre ve eğitildiği “Epochs” değerine göre deneme yanılma yöntemi ile modelin optimum noktası belirlenecektir. Modelin overfit olmadığı noktada ve modelin performansının farklı “Epochs” değerine göre performansının iyi olduğu noktadaki model seçilecektir. İlk önce model için belirlenen parametreler kullanılacak farklı “Epochs” değerlerindeki performanslarına bakılmıştır.


Çizelge 4.10.'da “Thin Elektrik” tip pervane C_p tahmin modeli için farklı “Epochs” değerlerinde modelin performansı değerlendirilmiştir. Burada MSE ve R^2 değerlerine baktığımızda MSE için en düşük değer R^2 içinde en büyük değer baz alınması gerekmektedir. Bu noktalar baz alındığında 3. Modelin daha iyi performans gösterdiği görülmektedir. MSE, modelin gerçek değerlerle ne kadar uyumlu olduğunu ölçerken, R^2 değeri ise modelin veri setindeki varyasyonun ne kadarını açıklayabildiğini gösterir. Bu iki metrik, modelin genel performansını değerlendirmek için yeterli olmaktadır.

Çizelge 4.10. “Epoch” Değerlerine göre “Thin Elektrik” C_p model performanslarının kayıp fonksiyonlarına göre ve R^2 yöntemine göre karşılaştırılması


Model No	Model Türü	Epochs	MAE	MSE	RMSE	R^2
1	“Thin Elektrik” C_p Tahmin Modeli	1 000	0,03993897	0,00524780	0,1998473	0,9899794831
2	“Thin Elektrik” C_p Tahmin Modeli	2 000	0,04101020	0,00444197	0,20250977	0,9918586200
3	“Thin Elektrik” C_p Tahmin Modeli	3 000	0,04109595	0,003551351	0,20272137	0,993549436
4	“Thin Elektrik” C_p Tahmin Modeli	5 000	0,04703225	0,0054036079	0,216869190	0,9902345891
5	“Thin Elektrik” C_p Tahmin Modeli	7 000	0,04801759	0,004305178	0,21912916	0,99276080




Şekil 4.46. “Thin Elektrik” tip pervane C_p tahmin modeli 1 000 “Epoch”




Şekil 4.47. “Thin Elektrik” tip pervane C_p tahmin modeli 2 000 “Epoch”



Şekil 4.48. “Thin Elektrik” tip pervane C_p tahmin modeli 3 000 “Epoch”



Şekil 4.49. “Thin Elektrik” tip pervane C_p tahmin modeli 5 000 “Epoch”




Şekil 4.50. “Thin Elektrik” tip pervane C_p tahmin modeli 7 000 “Epoch”

Farklı “Epochs” değerlerine göre modellerin Loss-Validation Loss performansları incelenmiştir. Burada Loss-Validation Loss grafiğinde eğitim ve doğrulama kayıpları birbirine yakın olmasa da R^2 değerinin yüksek olması, modelin eğitim verilerine iyi uyum sağladığını ve doğrulama verilerinde iyi bir performans sergilediğini gösterir. Yani, modelin genel olarak iyi bir tahmin yeteneği olduğunu ve veriler arasındaki ilişkiyi iyi bir şekilde açıkladığını gösterir. Bu durum, Loss-Validation Loss grafiğindeki eğilimin modelin performansını değerlendirmek için tek başına yeterli değildir. Bu yüzden model performansını değerlendirmek için kayıp fonksiyonları ve R^2 sonuçlarına da bakılıp öyle karar verilmektedir. Bu çıktılar sonucunda en iyi performanslı modelin üçüncü model olduğu kararlaştırılmıştır. “Thin Elektrik” pervane tipi için C_p veri seti üçüncü model parametreleri ve “Epochs” değeri ile eğilecektir.

Thin elektrik tip pervane güç katsayısı (C_p) modelinin eğitilmesi ve model çıktıları


Model için parametre ve “Epochs” değerleri belirlendikten sonra “Thin Elektrik” C_p Tahmin Modeli veri seti ile eğitilmiştir. Şekil 4.51.’de “Thin Elektrik” tip pervane için C_p tahmin modelinin “Predictions-Real Values” grafiği incelendiğinde, grafikteki noktaların genellikle bir çizgi oluşturduğu ve nadiren noktaların çizgi dışında kaldığı görülmektedir.

Bu durum, modelin eğitildiği veri setiyle gerçek değerler arasında çok yakın tahminler yaptığını göstermektedir.




Şekil 4.51. “Thin Elektrik” C_p tahmin modeli Predictions-Real Values grafiği


Model çıktısı olarak a , b , c , d , e değerleri tahmin etmesi beklenmektedir. Farklı çap ve hatve değerlerine göre değişken RPM’ler için a , b , c , d , e değerleri için tahmin performansı incelenmiştir. Şekil 4.52., Şekil 4.53., Şekil 4.54., Şekil 4.55. ve Şekil 4.56. incelendiğinde, polinom fonksiyonunda yer almayan a , b , c , d , e değerleri için “Thin Elektrik” tip pervane C_p veri setiyle eğitilerek oluşturulan modelin tahmin çıktıları alınmıştır. Bu grafikler incelendiğinde, eğrilerin tam olarak üst üste olmadığı görülmektedir. Ancak bu durum, genel C_p tahmin performansını olumsuz etkilemez. Çünkü dördüncü derece polinom fonksiyonda a , b , c , d , e değerleri yazıldığında fonksiyonun değişken değerlerine göre C_p değeri farklılık göstermektedir. Fonksiyon katsayısı olan a , b , c , d , e değerleri 0 değerine çok yakın olduğundan dolayı, modelin C_p tahmini performansının genel olarak iyi olması beklenir.




Şekil 4.52. “Thin Elektrik” C_p Modelin RPM’lere göre “a” değeri tahmin performansı




Şekil 4.53. “Thin Elektrik” C_p Modelin RPM’lere göre “b” değeri tahmin performansı



Şekil 4.54. “Thin Elektrik” C_p Modelin RPM’lere göre “c” değeri tahmin performansı




Şekil 4.55. “Thin Elektrik” C_p Modelin RPM’lere göre “d” değeri tahmin performansı



Şekil 4.56. “Thin Elektrik” C_p Modelin RPM’lere göre “e” değeri tahmin performansı

Şekil 4.57. incelendiğinde eğitim verisiyle eğitilen modelin gerçek değerleri ile tahmin ettiği değerlerin çok yakın olduğu görülmektedir. Model tahmin “Thin Elektrik” tip pervane C_p tahmini için kullanılacaktır.



Şekil 4.57. “Thin Elektrik” Tip Pervane C_p tahmin modeli 5x3 Pervane 3 000 RPM model performansı

Simülasyon veri setiyle oluşturulan yapay sinir ağı modellerinin değerlendirilmesi

Simülasyon veri setiyle toplam 4 adet yapay sinir ağı modelleri oluşturulmuştur. Bu modeller “Sport” tip pervane için C_t/C_p tahmin modeli ve “Thin Elektrik” tip pervane için C_t/C_p tahmin modelleridir. Çizelge 4.11.’de simülasyon veri setiyle oluşturulan modeller ile rüzgar tüneli veri setindeki pervanelerin farklı çap ve hatve kombinasyonlarındaki değişken RPM değerlerine karşılık gelen C_t/C_p değerleri bulunacaktır. Bu bulunan değerler veri seti olarak kaydedilecektir. Bu değerler bulunduktan sonra rüzgar tüneli veri seti ve Simülasyon modellerinden gelen veri setleri kullanılarak rüzgar tüneli için yapay sinir ağı modelleri oluşturulacaktır.

Çizelge 4.11. Simülasyon veri setiyle oluşturulan 4 farklı modelin özellikleri ve R^2 performansı

Model Veri Seti	Model Adı	Epochs Sayısı	Katman Sayısı	Katmandaki Nöron Sayısı	Kayıp Fonksiyonu	R^2 Performansı
Sport	“Sport” C_t Tahmin Modeli	1 000	5	256	MSE	0,97716268
Sport	“Sport” C_p Tahmin Modeli	3 000	5	256	MSE	0,96819425
Thin Elektrik	“Thin Elektrik” C_t Tahmin Modeli	2 000	5	256	MSE	0,990751634
Thin Elektrik	“Thin Elektrik” C_p Tahmin Modeli	3 000	5	256	MAE	0,993549436

4.4. Rüzgar Tüneli Veri Seti İncelenmesi ve Yapay Sinir Ağı Modeli Kurma Hazırlıkları


Rüzgar Tüneli veri seti olan farklı pervane çap ve hatve kombinasyonlarındaki değişken RPM'lere göre C_t/C_p değerleri daha önce simülasyon veri setini model oluşturmadan önce düzenlendiği gibi düzenlenmiştir. Bu veri Seti “Sport” tip pervane rüzgar tüneli için C_t/C_p ve “Thin Elektrik” tip pervane rüzgar tüneli C_t/C_p olarak ayrılmıştır. Bu veri setinde belirlenen farklı kombinasyonlardaki çap ve hatve için RPM değerlerine karşılık gelen simülasyon değerleri simülasyon modelleri yardımıyla çıkarılmıştır. Simülasyon tahmin veri seti ile rüzgar tüneli tahmin veri seti RPM, pervane çapı, pervane hatvesi sabit olacak şekilde bu değerlere karşılık gelen C_t ve C_p karşılıkları yan yana yazılmıştır. Böylelikle Simülasyon tahmin veri seti ve Rüzgar tüneli veri seti birleştirilerek tek bir veri seti ortaya çıkarılmıştır.

Rüzgar tüneli modelleri oluşturulmadan önce veriler incelenecek ve modeller için gerekli veri düzenleme işlemleri yapılmıştır.


APC pervanelerinin rüzgar tüneline testleri yapılan değişken çap ve hatve kombinasyonlarındaki pervanelerin modellemede kullanılması için “Sport” pervane türünde 30 adet farklı çap ve hatve kombinasyonunda 1 000 RPM ve 10 000 RPM aralığında pervaneler ile ilgili rüzgar tüneline yapılan gerçek test verileri bulunmaktadır. Bunun yanında “Thin Electric” pervane tipinde 34 adet farklı çap ve hatve kombinasyonunda 1 000 RPM ve 10 000 RPM aralığında pervaneler ile ilgili rüzgar tüneline yapılan gerçek test verileri bulunmaktadır.

Simülasyon tahmin verisi ile rüzgar tüneli test verisi yan yana yazılmıştır. “Sport” ve “Thin Electric” tipteki pervane verileri “*RPM J V Ct Ct_Predicted Cp, Cp_Predicted Type d p*” formatında yan yana olacak şekilde düzenlenmiştir. Burada Ct ve Cp olarak belirtilen değerlerin altına rüzgar tüneli veri setindeki farklı çap ve hatve kombinasyonlarındaki pervanelerin Ct ve Cp değerleri, Ct_Predicted ve Cp_Predicted değerlerin altına da Simülasyon modelleri ile tahmin edilen rüzgar tüneli karşılığındaki farklı kombinasyonlardaki pervane çap ve hatvelerine göre olan Ct ve Cp değerleri gelecektir.

Rüzgar tüneli veri seti ile Simülasyon tahmin veri seti değerleri birbirleriyle karşılaştırılarak incelenmiştir. Şekil 4.58. ve Şekil 4.59.’da rüzgar tüneli veri setiyle, simülasyon tahmin veri seti karşılaştırıldığında farklı çap ve hatve kombinasyonlarındaki değişken RPM değerlerine göre yakın davranış gösterdiği görülmektedir. Bu iki veri seti birlikte model oluşturmak için kullanılacaktır. Burada Predicted_Ct ve Predicted_Cp değerleri simülasyon modellerinin rüzgar tüneli veri setine göre tahmin sonuçlarıdır.



Şekil 4.58. “Thin Elektrik” Tip 14x7 pervanenin rüzgar tüneli C_t/C_p değerlerinin simülasyon model tahmininin karşılaştırılması



Şekil 4.59. “Sport” Tip 10x4 pervanenin rüzgar tüneli C_t/C_p değerlerinin simülasyon model tahmininin karşılaştırılması

4.4.1. Rüzgar tüneli “sport” tip pervane itki katsayısı modelinin eğitime hazırlanması ve parametrelerin belirlenmesi

Rüzgar tüneli veri setiyle, Simülasyon tahmin veri seti birleştirilerek tek bir veri seti oluşturulmuştur. İlk olarak “Sport” tip pervane için rüzgar tüneli ve simülasyon tahmin veri seti kullanılarak bir model oluşturulacaktır.

Model oluşturulmadan önce modelin eğitim sürecinde kullanılacak olan bağımsız değişkenler belirlenmiştir. Bu değişkenler X_{train} veri setidir. X_{train} veri seti için “ RPM J $Predicted_Ct$ $Diameter$ $Pitch$ V ” değerleri kullanılacaktır. Bu değerler modele girdi olarak verilen özelliklerdir ve modelin bu özelliklerden yararlanarak rüzgar tüneli için Ct değerini tahmin etmesine yardımcı olur.

X_{train} olarak bu değerlerin seçilmesinin nedeni bu değerlerin pervane performansını belirleyen temel faktörler olmasıdır. RPM , J , $Diameter$, $Pitch$ ve V pervanenin performansını doğrudan etkileyen önemli özelliklerdir. Tahmin edilen Ct değerini belirleyen bu faktörlerin model tarafından öğrenilmesi önemlidir. Burada $Predicted_Ct$ değerinin kullanılması da daha önce simülasyon modellerinden “Sport” Ct tahmin modelinden rüzgar tüneli çap ve hatve için RPM değerlerine karşılık gelen değerdir. Bu değer modelde kullanılması Ct tahmininde güçlü bir öngörücü olacaktır.

Y_{train} eğitim seti modelin eğitim sürecinde öğrenmeye çalıştığı bağımlı değişkendir. Bu yüzden y_{train} için Ct kullanılacaktır.

Modelin hiperparametreleri belirlenirken daha önce simülasyon tahmin modelleri için kullanılan parametrelerin yanında deneme yanılma yöntemiyle parametreler son halini almıştır.

Rüzgar Tüneli “Sport” tip pervane Ct tahmin modeli için kullanılan hiperparametreler aşağıdaki gibidir:

- 5 Katman
- 1 Giriş Katmanı, 3 Katman, 1 Çıkış Katmanı
- Batch size 16
- 1 000 Epochs,
- Çıkış Katmanı hariç katmanlarda 256 Nöron

- Mean Squared Error (MSE) Kayıp Fonksiyonu
- ReLU Aktivasyon Fonksiyonu
- Adam Optimizasyon Algoritması
- Standart Scaler
- Validation (X_{test} , y_{test})
- Test size %1

Belirlenen parametreler ile rüzgar tüneli için yapar sinir ağı modeli eğitilmiştir. Çizelge 4.12. rüzgar tüneli “Sport” tip pervane için C_t tahmini yapmak için oluşturulan modelin yapısı ve özetini gösterir.

Çizelge 4.12. Rüzgar tüneli “Sport” tip pervane için C_t tahmini yapmak için oluşturulan modelin yapısı ve özeti

Rüzgar Tüneli “Sport” C_t Sequential Model		
Katman (Tip)	Çıkış Şekli	Parametre
Dense (Katman)	252	1 764
Dropout	252	0
Dense (Katman)	168	42 504
Dropout	168	0
Dense (Katman)	84	14 196
Dropout	84	0
Dense (Katman)	42	3 570
Dropout	42	0
Dense (Katman)	1	43
Total Parametre = 62 077		Trainable Parametre = 62 077


Rüzgar tüneli C_t tahmin için oluşturulan yapar sinir ağı modeli için katman sayıları ve katmanda bulunan nöron sayıları daha önce oluşturulan simülasyon modelleri referans alınarak deneme yanılma yöntemiyle modelin en iyi performans sergileyeceği en optimum değerler olacak şekilde ayarlanmıştır. Oluşturulan model “Epochs” değerlerine göre modelin en iyi performans gösterdiği nokta belirlenecektir. Buna göre “Epochs” değeri belirlenecektir.

Çizelge 4.13.'te 2 farklı “Epochs” değerlerine göre modellerin kayıp fonksiyon ve R^2 performansları incelendiğinde 1. Model daha düşük kayıp fonksiyon performansı ve R^2 skoruna sahiptir. Bu 1. Modelin daha iyi performans gösterdiğini göstermektedir. “Epochs” sayısı değerlendirirken 1000 “Epochs” için modelin performansı oldukça iyi olduğundan dolayı daha fazla “Epochs” değerine ihtiyaç olmadığı görülmektedir.


Çizelge 4.13. Rüzgar tüneli “Sport” C_t tahmin modeli “Epoch” Değerlerine göre model performanslarının kayıp fonksiyonlarına göre ve R^2 yöntemine göre karşılaştırılması

Model No	Model Türü	Epochs	MAE	MSE	RMSE	R^2
1	Rüzgar Tüneli “Sport” C_t Tahmin Modeli	1 000	0,032211390	0,001689722	0,17947532	0,99833180
2	Rüzgar Tüneli “Sport” C_t Tahmin Modeli	2 000	0,056139356	0,0077393565	0,23693745	0,993742881

Şekil 4.60. ve Şekil 4.61.'de Loss-Validation Loss grafikleri incelendiğinde Loss ve Validation Loss değerleri 1 000 “Epochs” değerinde üst üste geldiği görülmektedir. Bu durumda modelin overfit olmadığı görülmektedir. Modelin eğitimi sırasında karşılaşılan kayıp değerlerinin düşük ve stabil olması, modelin hem eğitim hem de doğrulama aşamalarında iyi çalıştığını göstermektedir. Bu durum, modelin yeni verilere karşı da iyi sonuçlar verebileceğini öngörmeye yardımcı olmaktadır. Grafikler değerlendirildiğinde model performansı 1 000 “Epochs” değeri için iyi performans gösterdiğinden dolayı rüzgar tüneli C_t tahmin modeli için 1.model tercih edilecektir. Rüzgar tüneli veri seti ile birinci model eğitilecektir.




Şekil 4.60. Rüzgar tüneli “Sport” tip pervane C_t tahmin modeli 1 000 “Epoch”



Şekil 4.61. Rüzgar tüneli “Sport” tip pervane C_t tahmin modeli 2 000 “Epoch”


4.4.2. Rüzgar tüneli “sport” tip pervane itki katsayısı modelinin eğitilmesi ve model çıktıları

Rüzgar tüneli C_t tahmin modeli için belirlenen hiperparametreler ve “Epochs” değerinden sonra yapay sinir ağı modeli veri setiyle eğitilmiştir. Şekil 4.62. Predictions-Real Values grafiği incelendiğinde grafiğin doğrusal ilişki gösterdiği görülmektedir. Bu, modelin tahminlerinin gerçek değerlere oldukça yakın olduğunu ve modelin performansının çok iyi olduğunu göstermektedir. Noktaların ideal doğru etrafında düzenli bir şekilde dağılmış olması, model tahminlerinin tutarlılığını ve modelin genel olarak veri setini iyi öğrendiğini göstermektedir.



Şekil 4.62. Rüzgar tüneli “Sport” C_t tahmin modeli Predictions-Real Values grafiği

Yapay sinir ağı modeli kullanarak modelin veri setiyle beraber performansı değerlendirilmiştir. Şekil 4.63.’te rüzgar tüneli “Sport” C_t tahmin modeli performansı incelendiğinde modelin performansının gerçek veri setiyle neredeyse aynı olduğu görülmektedir. Burada modelin tahmin performansının iyi olduğu ve farklı pervane kombinasyonları içinde iyi bir tahmin yapacağı öngörülmektedir.



Şekil 4.63. Rüzgar tüneli “Sport” tip pervane C_t tahmin modeli 10x10 pervane 2 000 RPM model performansı

4.4.3. Rüzgar tüneli “sport” tip pervane güç katsayısı modelinin eğitime hazırlanması ve parametrelerin belirlenmesi

Rüzgar tüneli “Sport” C_p tahmin modeli oluşturmak için rüzgar tüneli veri seti ve simülasyon tahmin veri seti kullanılmıştır. Model oluştururken ve model parametreleri belirlenirken daha önce oluşturulan simülasyon ve rüzgar tüneli modelleri referans alınmıştır.

Rüzgar Tüneli “Sport” tip pervane C_p tahmin modeli için kullanılan hiperparametreler aşağıdaki gibidir:

- 5 Katman
- 1 Giriş Katmanı, 3 Katman, 1 Çıkış Katmanı
- Batch size 4
- 500 Epochs,
- Çıkış Katmanı hariç katmanlarda 256 Nöron

- Mean Squared Error (MSE) Kayıp Fonksiyonu
- ReLU Aktivasyon Fonksiyonu
- Adam Optimizasyon Algoritması
- Standart Scaler
- Validation (X_{test} , y_{test})
- Test size %1

Belirlenen parametreler modelin tahmin performansına ve Loss-Validation Loss grafiğine göre değişkenler baz alınarak belirlenmiştir. Bu hiperparametrelere göre yapar sinir ağı modeli eğitilmiştir. Çizelge 4.14., rüzgar tüneli “Sport” tip pervane için C_p tahmini yapmak için oluşturulan modelin yapısı ve özetini içermektedir.

Çizelge 4.14. Rüzgar tüneli “Sport” tip pervane için C_p tahmini yapmak için oluşturulan modelin yapısı ve özeti

Rüzgar Tüneli “Sport” C_p Sequential Model		
Katman (Tip)	Çıkış Şekli	Parametre
Dense (Katman)	252	1 764
Dropout	252	0
Dense (Katman)	168	42 504
Dropout	168	0
Dense (Katman)	84	14 196
Dropout	84	0
Dense (Katman)	42	3 570
Dropout	42	0
Dense (Katman)	1	43
Total Parametre = 62 077		Trainable Parametre = 62 077

Rüzgar tüneli C_p tahmin için oluşturulan yapar sinir ağı model yapısı önceki modeller baz alınarak model yapısı oluşturulmuştur. Modelin en iyi performansı vermesi için farklı “Epochs” değerleri kurulan model yapısı için denenmiştir.


Çizelge 4.15.’te farklı “Epochs” değerleri ile eğitilen modeller incelenmiştir. Bu İncelenen modeller arasında, Model 1 en düşük MSE’ye ve en yüksek R^2 ’ye sahiptir. Bu durum,

model 1'in diğer modellere göre daha iyi performans gösterdiğini göstermektedir. İncelenen "Epochs" değerlerine göre modeller gayet iyi performans gösterdiği için karşılaştırma için "Epochs" sayısı 2 000 ile sınırlandırılmıştır.


Çizelge 4.15. Rüzgar tüneli "Sport" C_p tahmin modeli "Epoch" değerlerine göre model performanslarının kayıp fonksiyonlarına göre ve R^2 yöntemine göre karşılaştırılması

Model No	Model Türü	Epochs	MAE	MSE	RMSE	R^2
1	Rüzgar Tüneli "Sport" C_p Tahmin Modeli	500	0,03589336	0,002298777	0,189455449	0,997517669
2	Rüzgar Tüneli "Sport" C_p Tahmin Modeli	1 000	0,05087223	0,00520541	0,225548752	0,99659612
3	Rüzgar Tüneli "Sport" C_p Tahmin Modeli	2 000	0,043748091	0,00403422	0,20916044	0,996350194


Şekil 4.64., Şekil 4.65. ve Şekil 4.66.'da farklı "Epochs" değerleri için modellerin Loss-Validation Loss grafikleri incelendiğinde grafiklerin hemen hemen benzer davranış gösterdiği gözükmemektedir. Şekil 4.64.'te "Epochs" değeri 500 olan grafiğin Loss ve Validation Loss değerleri tam üst üste örtüşmese de modelin performansı açısından bunun bir önemi yoktur. Çünkü Loss ve Validation loss değerlerinin üst üste gelmemesi, genellikle modelin iyi genelleştirme yapabildiğini ve overfitting olmadığını gösterir. Bu durum, modelin eğitim verilerine aşırı uyum sağlamadığını ve yeni verilerle iyi performans gösterebileceğini göstermektedir.



Şekil 4.64. Rüzgar tüneli “Sport” tip pervane C_p tahmin modeli 500 “Epoch”



Şekil 4.65. Rüzgar tüneli “Sport” tip pervane C_p tahmin modeli 1 000 “Epoch”




Şekil 4.66. Rüzgar tüneli “Sport” tip pervane C_p tahmin modeli 2 000 “Epoch”

Modellerin kayıp fonksiyon performansları ve R^2 sonuçlarının yanında Loss-Validation Loss grafikleri incelendiğinden iyi performans gösteren modelin birinci model olduğu görülmektedir. Rüzgar tüneli “Sport” C_p tahmin modeli için birinci model eğitilecektir.

4.4.4. Rüzgar tüneli “sport” tip pervane güç katsayısı modelinin eğitilmesi ve model çıktıları


Rüzgar tüneli veri seti kullanılarak oluşturulacak olan C_p tahmin model belirlenen hiperparametreler ve “Epochs” değerinden sonra yapay sinir ağı modeli veri setiyle eğitilmiştir.

Şekil 4.67. Predictions-Real Values grafiği incelendiğinde grafikteki noktaların gösterdiği davranışa göre modelin ve tahminlerinin tutarlılığını bunun yanında modelin genel olarak veri setini iyi öğrendiğini göstermektedir.



Şekil 4.67. Rüzgar tüneli “Sport” C_p tahmin modeli Predictions-Real Values grafiği

Rüzgar tüneli veri seti ile eğitilen model ile farklı kombinasyonlarda pervane ve RPM değerlerine göre modelin performansı incelenmiştir. Şekil 4.68.’de modelin tahmin yeteneği incelendiğinde değişken J değerlerine göre C_p tahminlerinin veri setindeki değerlere yakın bir tahmin yaptığı görülmektedir.



Şekil 4.68. Rüzgar tüneli “Sport” tip pervane C_p tahmin modeli 10x7 pervane 6 000 RPM model performansı

4.4.5. Rüzgar tüneli “thin elektrik” tip pervane itki katsayısı modelinin eğitime hazırlanması ve parametrelerin belirlenmesi

“Thin Elektrik” tip pervane C_t tahmini modeli oluşturulurken, başlangıçta rüzgar tüneli veri seti ve simülasyon tahmin veri seti kullanılmıştır. Modelin kurulması ve parametrelerinin belirlenmesi sürecinde önceki simülasyon ve rüzgar tüneli modelleri temel alınmıştır.

“Thin Elektrik” tip pervane C_t tahmini modeli için belirlenen başlangıç hiperparametreleri aşağıda belirtilmiştir:

- 5 Katman
- 1 Giriş Katmanı, 3 Katman, 1 Çıkış Katmanı
- Batch size 16
- 500 Epochs,
- Çıkış Katmanı hariç katmanlarda 256 Nöron

- Mean Absolute Error (MAE) Kayıp Fonksiyonu
- ReLU Aktivasyon Fonksiyonu
- Adam Optimizasyon Algoritması
- Standart Scaler
- Validation (X_{test} , y_{test})
- Test size %1

Belirlenen parametreler ile yapay sinir ağı modeli yapısı kurulacaktır. Bu parametrelere göre yapay sinir ağı modeli eğitilecektir. Modelin performansına göre parametreler değiştirilebilir. Çizelge 4.16. rüzgar tüneli “Thin Elektrik” tip pervane için C_t tahmini yapmak için oluşturulan modelin yapısı ve özetini göstermektedir.

Çizelge 4.16. Rüzgar tüneli “Thin Elektrik” tip pervane için C_t tahmini yapmak için oluşturulan modelin yapısı ve özeti

Rüzgar Tüneli “Thin Elektrik” C_t Sequential Model		
Katman (Tip)	Çıkış Şekli	Parametre
Dense (Katman)	252	1 764
Dropout	252	0
Dense (Katman)	168	42 504
Dropout	168	0
Dense (Katman)	84	14 196
Dropout	84	0
Dense (Katman)	42	3 570
Dropout	42	0
Dense (Katman)	1	43
Total Parametre = 62 077		Trainable Parametre = 62 077


Model yapısı önceki modeller ile referans alınarak belirlenmiştir. Belirlenen yapıda daha önce eğitilen modellerin yüksek tahmin performansı gösterdiği görülmüştür. Bu model yapısı ile en iyi performansı verecek olan “Epochs” sayısı deneme yanılma yöntemiyle belirlenmiştir.

Çizelge 4.17.’de farklı “Epochs” değerlerine göre eğitilen modellerin performansı karşılaştırılmıştır. İki model arasında karşılaştırma yaparken, genellikle daha düşük hata değerlerine sahip olan model daha iyi olarak kabul edilmektedir. Dolayısıyla, bu durumda, 500 epoch değerine sahip olan Model 1’in MAE, MSE, RMSE ve R² değerlerinin daha düşük olduğunu görülmektedir. Model veri setini düşük “Epochs” sayılarında da iyi performansla öğrendiği için yüksek “Epochs” değerlerine gerek görülmemiştir.


Çizelge 4.17. Rüzgar tüneli “Thin Elektrik” Ct tahmin modeli “Epoch” değerlerine göre model performanslarının kayıp fonksiyonlarına göre ve R² yöntemine göre karşılaştırılması

Model No	Model Türü	Epochs	MAE	MSE	RMSE	R ²
1	Rüzgar Tüneli “Thin Elektrik” Ct Tahmin Modeli	500	0,03377714	0,0018278	0,18378559	0,99827756
2	Rüzgar Tüneli “Thin Elektrik” Ct Tahmin Modeli	1 000	0,04106794	0,00286244	0,20265226	0,9974655550

Loss-Validation Loss grafikleri incelendiğinde Loss değerleri ile Validation Loss değerlerinin benzer davranış gösterdiği gözükmemektedir. Bu davranışlar diğer modellere göre çok stabil olmasa da modellerin veri setini öğrenme performansı oldukça iyidir. Şekil 4.69. incelendiğinde modelin eğitim sürecinde genel olarak iyi bir öğrenme performansı gösterdiğini ve overfitting (aşırı uyum) sorununun olmadığını görülmektedir. Eğitim ve doğrulama kayıpları arasındaki fark az olduğu için, modelin hem eğitim verilerine hem de doğrulanmamış verilere iyi genelleme yaptığı söylenebilir. Ancak, eğitim kaybının dalgalanması, öğrenme oranının (learning rate) çok yüksek olabileceğine veya bazı eğitim örneklerinin model tarafından zorlandığını göstermektedir. Ama genel olarak modelin tahmin performansının iyi olacağı görülmektedir. Veri seti ile eğitilmesi için 1.model yani “Epochs” değeri 500 olan model tercih edilecektir.




Şekil 4.69. Rüzgar tüneli “Thin Elektrik” tip pervane C_t tahmin modeli 500 “Epoch”



Şekil 4.70. Rüzgar tüneli “Thin Elektrik” tip pervane C_t tahmin modeli 1 000 “Epoch”


4.4.6. Rüzgar tüneli “thin elektrik” tip pervane itki katsayısı modelin eğitilmesi ve model çıktıları

Oluşturulan model yapısı ve belirlenen hiperparametreler kullanılarak belirlenen model ile rüzgar tüneli veri seti kullanılarak eğitilecektir. Yapay sinir ağı modeli eğitim veri seti ile eğitildikten sonra modelin performansı incelenecektir. Şekil 4.71.’de Predictions-Real Values grafiğine bakıldığında, grafikte belirgin bir doğrusal ilişki olduğu gözlemlenir. Bu durum, modelin tahminlerinin gerçek değerlere oldukça yakın olduğunu ve modelin performansının oldukça iyi olduğunu modelin veri setini öğrenmede iyi performans gösterdiğini işaret etmektedir.



Şekil 4.71. Rüzgar tüneli “Thin Elektrik” C_t tahmin modeli Predictions-Real Values grafiği

Veri seti ile eğitilen yapay sinir ağı modeli tahmin performansı incelenmiştir. Şekil 4.72.’de model tahminleme performansı gerçek veriler ile oldukça yakın performans göstermektedir. Model performans çıktısı olarak modelin hem veri setindeki pervane kombinasyonlarını hem de veri setinde olmayan pervane kombinasyonlarını iyi derecede tahmin edebileceğini göstermektedir.



Şekil 4.72. Rüzgar tüneli “Thin Elektrik” tip pervane C_t tahmin modeli 14x10 pervane 6 000 RPM model performansı

4.4.7. Rüzgar tüneli “thin elektrik” tip pervane itki katsayısı modelinin eğitime hazırlanması ve parametrelerin belirlenmesi

Rüzgar tüneli “Thin Elektrik” C_p tahmin modeli oluştururken daha önce oluşturulan simülasyon ve rüzgar tüneli tahmin modelleri referans alınmıştır. Veri seti olarak rüzgar tüneli “Thin Elektrik” veri seti kullanılmıştır.

Rüzgar tüneli “Thin Elektrik” C_p yapay sinir ağı tahmin modeli için model için aşağıdaki hiperparametreler belirlenmiştir.

- 5 Katman
- 1 Giriş Katmanı, 3 Katman, 1 Çıkış Katmanı
- Batch size 16
- 1 000 Epochs,
- Çıkış Katmanı hariç katmanlarda 256 Nöron
- Mean Absolute Error (MAE) Kayıp Fonksiyonu

- ReLU Aktivasyon Fonksiyonu
- Adam Optimizasyon Algoritması
- Standart Scaler
- Validation (X_{test} , y_{test})
- Test size %1

Belirlenen parametrelere göre yapay sinir ağı model yapısı kurulacaktır. Bu model yapısı daha önce iyi performans gösteren simülasyon ve rüzgar tüneli veri seti ile oluşturulan yapay sinir ağı modellerinin yapısı baz alınarak oluşturulmuştur. Çizelge 4.18. ile rüzgar tüneli “Thin Elektrik” tip pervane için C_p tahmini yapmak için oluşturulan modelin yapısı ve özeti verilmiştir.

Çizelge 4.18. Rüzgar tüneli “Thin Elektrik” tip pervane için C_p tahmini yapmak için oluşturulan modelin yapısı ve özeti

Rüzgar Tüneli “Thin Elektrik” C_p Sequential Model		
Katman (Tip)	Çıkış Şekli	Parametre
Dense (Katman)	252	1 764
Dropout	252	0
Dense (Katman)	168	42 504
Dropout	168	0
Dense (Katman)	84	14 196
Dropout	84	0
Dense (Katman)	42	3 570
Dropout	42	0
Dense (Katman)	1	43
Total Parametre = 62 077		Trainable Parametre = 62 077

Daha önce oluşturulan yapay sinir ağı modelleri için katman ve nöron sayısı yeterli olduğu görülmüştür. Bu yüzden rüzgar tüneli “Thin Elektrik” C_p tahmin modeli yapısı içinde daha fazla katman ve nöron sayısına ihtiyaç duyulmamıştır.


Oluşturulan model yapısı ile farklı “Epochs” değerleri ile model eğitilmiştir. “Epochs” değerleri modelin tahmin performansına göre deneme yanılma yöntemiyle belirlenmiştir.

Çizelge 4.19.'da oluşturulan model yapısı ile farklı “Epochs” değerleri için modelin performansı incelenmiştir. Modelin düşük “Epochs” sayısı ile eğitilmesinde modelin iyi bir performans gösterdiği görülmektedir. Bu yüzden daha fazla “Epochs” değerine ihtiyaç yoktur. Çizelge 4.18.'de 500 ve 1 000 “Epochs” değerleri ile eğitilen modeller karşılaştırılmıştır. Bu iki model incelendiğinde modellerin kayıp fonksiyon performansı ve R^2 skoru incelendiğinde birbirlerine çok yakın performans gösterdiği görülmektedir. İkinci modelin R^2 performansı olarak çok yakın olmasına rağmen daha yüksek olması tahmin modeli eğitilmesi için 2.model tercih edilmiştir.


Çizelge 4.19. Rüzgar tüneli “Thin Elektrik” C_p tahmin modeli “Epoch” değerlerine göre model performanslarının kayıp fonksiyonlarına göre ve R^2 yöntemine göre karşılaştırılması

Model No	Model Türü	Epochs	MAE	MSE	RMSE	R^2
1	Rüzgar Tüneli “Thin Elektrik” C_p Tahmin Modeli	500	0,0309182	0,00173574	0,17498080	0,99818197
2	Rüzgar Tüneli “Thin Elektrik” C_p Tahmin Modeli	1 000	0,03059107	0,00196366	0,17490302	0,99820711

Şekil 4.73. ve Şekil 4.74. Loss-Validation Loss grafikleri incelendiğinde ikinci modelin grafiği veri setini öğrenme sürecinde genel olarak iyi bir öğrenme performansı gösterdiği görülmektedir. İkinci modelin Loss-Validation Loss grafiği incelendiğinde Loss ve Validation-Loss değerlerinin artış göstermediği bu yüzden overfitting (aşırı uyum) sorununun olmadığını görülmektedir. Modelin Eğitim ve doğrulama kayıpları arasındaki fark az olduğu için, modelin hem eğitim verilerine hem de doğrulanmamış verilere iyi genelleme yaptığı söylenebilmektedir.



Şekil 4.73. Rüzgar tüneli “Thin Elektrik” tip pervane C_p tahmin modeli 500 “Epoch”




Şekil 4.74. Rüzgar tüneli “Thin Elektrik” tip pervane C_p tahmin modeli 1 000 “Epoch”

Rüzgar tüneli “Thin Elektrik” C_p tahmin modeli için kayıp fonksiyon performansı, R^2 skoru ve Loss-Validation Loss grafiği göz önüne alındığında 1 000 “Epochs” değerine sahip olan ikinci modelin veri setiyle eğitilmesine ve tahmin modeli olarak kullanılmasına karar verilmiştir.


4.4.8. Rüzgar tüneli “thin elektrik” tip pervane itki katsayısı modelin eğitilmesi ve model çıktıları

Modelin hiperparameterleri ve “Epochs” değeri belirlendikten sonra rüzgar tüneli veri seti ile model eğitilmiştir. Yapay sinir ağı modeli eğitildikten sonra modelin tahmin performansı incelenmiştir. Şekil 4.75., Predictions-Real Values grafiği incelendiğinde tahmin ve gerçek değerler arasında doğrusal ve lineer bir ilişki olduğu görülmektedir. Bu ilişki modelin veri setini iyi öğrenmede iyi bir performans gösterdiğini göstermektedir.



Şekil 4.75. Rüzgar tüneli “Thin Elektrik” C_p tahmin modeli Predictions-Real Values grafiği

Veri seti ile eğitilen yapay sinir ağı modeli tahmin performansı incelenmiştir. Şekil 4.76.'da modelin tahmin performansı incelendiğinde farklı RPM değerlerine göre ve farklı pervane kombinasyonlarına göre gerçek veri ile tahmin edilen veri arasında iyi performans gösterdiği görülmektedir. Modelin veri setinde bulunan gerçek veriyi ve veri setinde bulunmayan veriyi tahmin etmedeki performansının çok iyi ve gerçeğe çok yakın sonuçlar vermektedir. Bu model rüzgar tüneli “Thin Elektrik” C_p tahmin modeli için kullanılacaktır.



Şekil 4.76. Rüzgar tüneli “Thin Elektrik” tip pervane C_p tahmin modeli 19x12 pervane 3 000 RPM model performansı

4.5. Rüzgar Tüneli Yapay Sinir Ağı Modellerinin Karşılaştırılması

Rüzgar tüneli veri seti kullanılarak dört adet yapay sinir ağı modeli oluşturulmuştur. Simülasyon veri seti ile oluşturulan dört adet yapay sinir ağı modelinin rüzgar tüneli veri setinde bulunan pervane kombinasyonlarına göre değişken RPM'lere göre C_t ve C_p değerleri simülasyon modelleri ile tahmin edilmiştir. Bu tahmin edilen veri seti rüzgar tüneli veri seti ile birleştirilerek rüzgar tüneli modelleri için tek bir veri seti meydana gelmiştir. Bu oluşturulan veri seti hem rüzgar tüneli verilerini hem de rüzgar tüneli için

simülasyon tahmin verilerini kapsamaktadır. Buradan tek bir veri seti kullanarak gerçekçi test verisi olan rüzgar tüneli modellerine geçiş yapılmıştır. Bu oluşturulan rüzgar tüneli modelleri rüzgar tüneline gitmeden rüzgar tüneli test verisi olmayan pervane kombinasyonlarının farklı RPM değerleri için C_t ve C_p bulunmasına yardımcı olacaktır.

Çizelge 4.20.'de oluşturulan 4 adet yapay sinir ağı modelleri incelendiğinde MAE, MSE ve RMSE gibi hata metrikleri oldukça düşük seviyede olduğu görülmektedir. Bu metrikler modelin tahminleri gerçek değerlere oldukça yakın olduğunu göstermektedir. Ayrıca, R^2 skoru olarak dört modelde 1'e çok yakındır. Buda modellerin veri setine çok iyi şekilde uyum sağladığı ve tahminlerinin gerçek değerlerle tam olarak örtüştüğü anlamına gelmektedir.

Çizelge 4.20. Rüzgar tüneli veri seti ve simülasyon tahmin veri seti kullanılarak oluşturulan “Sport” ve “Thin Elektrik” tip pervaneler için yapay sinir ağı modelleri

Model Türü	Epochs	MAE	MSE	RMSE	R^2
Rüzgar Tüneli “Sport” C_t Tahmin Modeli	1 000	0,032211390	0,001689722	0,17947532	0,99833180
Rüzgar Tüneli “Sport” C_p Tahmin Modeli	500	0,03589336	0,002298777	0,189455449	0,997517669
Rüzgar Tüneli “Thin Elektrik” C_t Tahmin Modeli	500	0,03377714	0,0018278	0,18378559	0,99827756
Rüzgar Tüneli “Thin Elektrik” C_p Tahmin Modeli	1 000	0,030591069	0,00196366	0,17490302	0,99820711

5. SONUÇ VE ÖNERİLER

Bu çalışma, İnsansız Hava Aracı pervanelerinin performansını tahmin etmek amacıyla simülasyon ve rüzgar tüneli verilerini kullanarak yapay sinir ağı ile modelleme üzerine odaklanmıştır. İlk aşamada, YSA kullanılarak pervanelerin simülasyon ile elde edilen veriler ile simülasyon modelleri oluşturulmuştur. Bu süreçte oluşturulan simülasyon modelleri, simülasyon verileri ile karşılaştırılarak modellerin tahmin yeteneği ortaya çıkarılmıştır. Bu karşılaştırma ile simülasyon yapay sinir ağı modeli doğrulanmıştır ve yüksek derecede benzer sonuçlar elde edilmiştir. Burada “Sport” tip pervane için C_t ve C_p model sonuçları sırasıyla %97,71 ve 96,81, “Thin Elektrik” tip pervane için C_t ve C_p model sonuçları sırasıyla %99 ve %99,35 olarak performans göstermektedir. Bu sonuçlar gerçek veri olan 1 değerine çok yakındır ve modellerin veri setini yüksek performansla öğrendiğini göstermektedir. Daha sonra simülasyon modelleri kullanılarak rüzgar tüneli testlerinde pervane verilerine karşılık gelen simülasyon için pervanelerin verileri simülasyon modeli yardımıyla oluşturulmuştur. Sonrasında, bu doğrulanmış simülasyon model verileri ve rüzgar tüneli verileri kullanılarak yeni rüzgar tüneli yapay sinir ağı modelleri geliştirilmiştir. Bu modeller “Sport” tip rüzgar tüneli modeli için C_t ve C_p model sonuçları sırasıyla 99,83 ve 99,75, “Thin Elektrik” tip rüzgar tüneli modeli C_t ve C_p için sırasıyla %99,82 ve 99,82 olarak yüksek derecede rüzgar tüneli veri setine uyum sağladığını göstermektedir. YSA modelinin hem simülasyon hem de rüzgar tüneli verilerine yakın sonuçlar vermesi, modelin doğruluğunu ve geçerliliğini pekiştirmiştir. Bu durum, YSA’nın İHA pervane performans analizlerine olan uygunluğunu ve doğruluğunu ortaya koymuştur. Aynı zamanda, YSA kullanılarak rüzgar tüneli testleri yapılmaksızın İHA pervanelerinin performans verileri başarılı bir şekilde tahmin edilebilmiştir. Bu, sadece zaman ve maliyet açısından büyük tasarruf sağlamakla kalmamış, aynı zamanda İHA tasarım süreçlerini de hızlandırmıştır. Model doğruluğu, simülasyon ve rüzgar tüneli verileri ile yapılan kıyaslamalar sonucu yüksek güvenilirlik göstermiştir. Geliştirilmiş olan YSA modelleri, İHA pervanelerinin analiz ve tasarım süreçlerinde pratik ve ekonomik bir araç olarak kullanılabilecektir.

Gelecekte yapılacak çalışmalar ve pratik uygulamalar için çeşitli önerilerde bulunmak yararlı olacaktır. İlk olarak, model performansını daha da artırmak amacıyla daha geniş ve çeşitli pervane veri setleri kullanılabilir. Farklı İHA pervane geometrileri ve işletme

koşullarını içeren veriler, modelin genelleme yeteneğini artıracaktır. Ayrıca, hiperparametre optimizasyonu yapılarak modelin performansı daha da iyileştirilebilir. Diğer makine öğrenimi algoritmaları, örneğin destek vektör makineleri veya karar ağaçları, kullanılarak farklı yöntemlerin sonuçları kıyaslanabilir ve YSA modeline alternatifler oluşturulabilir. Geliştirilen modelin gerçek dünya uygulamalarında, özellikle İHA projelerinde test edilmesi, modelin pratik uygulanabilirliğini değerlendirmek için önemlidir. Bunun yanı sıra, YSA modelleri pervane tasarım yazılımlarına veya simülasyon araçlarına entegre edilerek tasarım sürecinin daha etkin hale getirilmesi sağlanabilir. Bu çalışma çok disiplinli yaklaşımlarla genişletilerek aerodinamik, yapısal ve termal analizlerin de entegre edildiği daha kapsamlı modeller geliştirilmesine olanak tanıyabilir. Bu sayede yalnızca İHA pervane performans analizleri değil, genel anlamda uçağın farklı mühendislik alanlarında YSA tabanlı modellemelerin potansiyel kullanımı da artırılabilir.

YSA modellerinin performansını değerlendirmek amacıyla, rüzgar tüneli ve simülasyon verileri kullanılarak geliştirilmiş YSA modelleri, öncelikle mevcut verisi olan pervaneler için uygulanmıştır. Bu veriler kullanılarak YSA modelleri oluşturulmuş ve modelin tahminleri ile karşılaştırılarak yüksek derecede doğruluk gözlemlenmiştir. Ancak, verisi olmayan pervaneler için tahmin yaptığımızda modelin tahmin performansı iyi olmasına rağmen model tarafından tahmin edilen performans verilerinin doğruluğunu değerlendirmek amacıyla, bu pervanelerin gelecekte rüzgar tüneli testlerine tabi tutulması önerilmektedir. Bu testlerin sonuçları, modelin farklı ve yeni pervane tasarımları üzerindeki geçerliliğini ve güvenilirliğini doğrulamak için kullanılacaktır. Bu ileriye dönük çalışmalar, YSA modellerinin genel uygulanabilirliğini ve güvenilirliğini daha da pekiştirecektir. Böylece, İHA pervane performansının tahmini ve optimizasyonu için pratik ve güvenilir bir araç olarak YSA modelleri daha da benimsenebilir.

KAYNAKLAR

1. İnternet: Parsch, A. (2005, Mayıs). *Directory of U.S. Military Rockets and Missiles, Sperry "Flying Bomb"*. Web: <http://www.designation-systems.net/dusrm/app4/sperry-fb.html>, Son Erişim Tarihi: 11/04/2024.
2. İnternet: Parsch, A. (2005, Mayıs). *Directory of U.S. Military Rockets and Missiles, Kettering Bug*. Web: <http://www.designation-systems.net/dusrm/app4/bug.html>, Son Erişim Tarihi: 11/04/2024.
3. İnternet: Parsch, A. (2005, Mayıs). *Directory of U.S. Military Rockets and Missiles, RQ-2 Pioneer*. Web: <http://www.designation-systems.net/dusrm/app2/q-2.html>, Son Erişim Tarihi: 11/04/2024.
4. Karaağaç, C. (2016). Geleceğin hava kuvvetleri: 2016-2050 sektör değerlendirme raporu. *ThinkTech*, STM.
5. Jurily, I. (2021). *Havacılığın 110 yıllık tarihi gelişimi ve teknik evrimi.*, Ankara: Akademisyen Kitabevi, 50-70.
6. İnternet: The UAV (2023, Haziran). *UAV types*. Web: <http://www.theuav.com>. Son Erişim Tarihi: 12/04/2024.
7. NATO (2009). *UAS classification guide*. Amerika: NATO.
8. İnternet: HAVELSAN A.Ş (2022, Mart). *Baha*. Web: <https://www.havelsan.com.tr/sektorler/egitim-ve-simulasyon/robotik-ve-otonom-sistemler/b30>, Son Erişim Tarihi: 11/04/2024.
9. İnternet: Türk Havacılık ve Uzay Sanayii (2018, Ocak). *Anka*. Web: <http://www.tai.com.tr/urun/anka>, Son Erişim Tarihi: 21/04/2024.
10. Yükselen, M.A. (2014). *Pervane Teorisi*, Aerodynamics Ders Notu, Uçak ve Uzay Bilimleri Fakültesi, Uçak Mühendisliği Bölümü, İstanbul Teknik Üniversitesi. Türkiye.
11. İnternet: Aerospaceweb (2014, Ağustos). *Helicopter theory - early history, earlyhelicopter history*. Web: <http://www.aerospaceweb.org/design/helicopter/history.shtml>. Son Erişim Tarihi: 15/04/2024.
12. İnternet: Science and Society Picture Library (2015 Kasım). *Leonardo da Vinci Helicopter*. Web: <http://www.scienceandsociety.co.uk>. Son Erişim Tarihi: 15/04/2024.
13. Greatrix, D.R. (2014). *Powered Flight: The Engineering of Aerospace Propulsion (İki Bin On İkinci Baskı)*, Department of Aerospace Engineering, Ryerson University, Toronto, Almanya: Springer Yayınevi, 63-69.

14. Gamble, D.E. (2009). *Automated Dynamic Propeller Testing at Low Reynolds Numbers*, Yüksek Lisans Tezi, Oklahoma State Üniversitesi, Amerika.
15. İnternet: Sydney Üniversitesi (2006). *Aerodynamic for Students Glauert Blade Element Theory, Analysis of Propellers Glauert Blade Element Theory*. Web: <http://www.ewp.rpi.edu/hartford/~ernesto/F2012/EP/MaterialsforStudents/McCosker/Aerodynamics-for-Students-GlauerBEM.pdf>. Son Erişim Tarihi: 17/04/2024.
16. İnternet: NASA (2015, Temmuz), *Wind Tunnel*. Web: <https://www.nasa.gov/general/wind-tunnel/>. Son Erişim Tarihi: 17/04/2024.
17. Melanson, M., Arrington, A., & Cahill, D. (2015). Best practices in wind tunnel testing., AIAA Professional Development Course.
18. Melanson M. (2008). *AIAA Aerospace Sciences Meetings and Exhibit*. AIAA-2008, 830-483.
19. Barlow, J. B., Rae, W. H. ve Pope A. (1999). *Low Speed Wind Tunnel Testing* (Üçüncü Baskı). Hoboken: John Wiley and Sons Yayınevi.
20. Calautit, J.C., Hughes, B. (2014). Integration and application of passive cooling within a wind tower for hot climates. *HVAC&R Research*, (20)7, 722-730.
21. Husain, Z., Abdullah, M.Z. ve Yap, T.C. (2005). Two-dimensional analysis of tandem/staggered airfoils using computational fluid dynamics. *International Journal of Mechanical Engineering Education*, 33(3), 195-207.
22. İnternet: AutoEvolution (2022). *Automotive Wind Tunnels Making Aerodynamic Cars*. Web: <https://www.autoevolution.com/news/automotive-wind-tunnels-making-aerodynamic-cars-23250.html>. Son Erişim Tarihi: 20/04/2024.
23. İnternet: NASA (2017, Nisan). *Wind Tunnel*. Web: <https://www.nasa.gov/learning-resources/for-kids-and-students/what-are-wind-tunnels-grades-k-4/>. Son Erişim Tarihi: 20/04/2024.
24. Haykin, S. (1994). *Neural Networks: A Comprehensive Foundation*. Kanada: Prentice Hall Yayınevi, 220-251.
25. Fausett, L. V. (1994). *Fundamentals of Neural Networks: Architectures, Algorithms, and Applications*. Amerika: Prentice Hall Yayınevi.
26. Maier, H. R., Dandy, G. C. (2000). Neural networks for the prediction and forecasting of water resources variables: a review of modelling issues and applications, *Environmental Modelling and Software*, 15(1), 101-124.
27. Sağiroğlu, Ş., Beşdok, E. ve Erle, M. (2003). *Mühendislikte Yapay Zeka Uygulamaları* (Birinci Baskı). Kayseri: Ufuk Yayıncılık, 1-426.
28. Elmas, Ç. (2006). *Yapay Zeka Uygulamaları*. Ankara: Seçkin Yayıncılık, 1-476.

29. Hamzaelebi, C. (2011). *Yapay Sinir Ađları Tahmin Amalı Kullanımı Matlab ve Neurosolutions Uygulamalı*. Bursa: Ekin Kitabevi Yayınları, 1-133.
30. Mehrotra, K., Mohan, C.K. ve Ranka, S. (1997). *Elements of Artificial Neural Networks*. Amerika: Mıt Press, 1-360.
31. Hagan, M. T., Demuth, H. B., Beale, M. H., Jesus, D.O. (2014). *Neural Network Design* (İkinci Baskı). Amerika: Hagan Press, 1-423.
32. Öztemel, E. (2003). *Yapay Sinir Ađları* (Birinci Baskı). İstanbul: Papatya Bilim, 1-232.
33. Duman, N. (2006). *Yapay Sinir Ađları ve Bir Uygulama*, Yüksek Lisans Tezi, Cumhuriyet Üniversitesi Sosyal Bilimler Enstitüsü, Sivas, Türkiye.
34. Baş, N. (2006). *Yapay Sinir Ađları Yaklaşımı ve Bir Uygulama*, Yüksek Lisans Tezi, Mimar Sinan Güzel Sanatlar Üniversitesi Fen Bilimleri Enstitüsü, İstanbul, Türkiye.
35. Es, H. (2013). *Yapay Sinir Ađları ile Türkiye Net Enerji Talebi*, Yüksek Lisans Tezi, Gazi Fen Bilimleri Enstitüsü, Ankara, Türkiye.
36. Bayır, F. (2006). *Yapay Sinir Ađları ve Tahmin Modellemesi Üzerine Bir Uygulama*, Yüksek Lisans Tezi, İstanbul Sosyal Bilimler Enstitüsü, İstanbul, Türkiye.
37. Gamble, D.E. (2009), *Automated Dynamic Propeller Testing at Low Reynolds Numbers*, Yüksek Lisans Tezi, Oklahoma State University, Amerika.
38. Dantsker, O.D., Caccamo, C., Deters, R.W. ve Selig, M.S. (2022). *Performance Testing of APC Electric Fixed-Blade UAV Propellers*. AIAA. Şikago, Amerika, 2022-4020.
39. McCrink, M.H. ve Gregory, J.W. (2015). *Blade Element Momentum Modeling for Low-Re Small UAS Electric Propulsion Systems*. AIAA. Dallas, Amerika, 2015-3296.
40. Bağe, M. (2014), *Design and Performance Evaluations of the Propeller of a UAV*, Yüksek Lisans Tezi, Orta Dođu Teknik Üniversitesi, Ankara, Türkiye.
41. Demirhan, O. (2022), *Identification of the Abnormal Fuel Consumption in a Commercial Flight by an Artificial Neural Network Surrogate Model*, Orta Dođu Teknik Üniversitesi, Ankara, Türkiye.
42. Gong, A., Maunder, H. ve Verstraete, D. (2017). *Development of an insight thrust measurement system for UAVs*. AIAA. Atlanta, Amerika.
43. Brandt, J. B., Selig, M. S. (2011). Propeller performance data at low Reynolds numbers (AIAA Paper No. 2011-1255). Presented at the AIAA Aerospace Sciences Meeting, Orlando, .

44. Whitmore, S.A., Merrill, R.S. (2012). *Nonlinear Large Angle Solution of the Blade Element Momentum Theory Propeller Equations*, Journal of Aircraft, 49(4), 1126-1134.
45. Hang, Z., Jiang, Z., Zhao, H., Pei, S., Li, H. ve Lan, Y. (2021). Aerodynamic Performance of Propellers for Multicopter Unmanned Aerial Vehicles: Measurement, Analysis, and Experiment, *Shock and Vibration*, 2021(1), 9538647.
46. Zbigniew, C., Karpiński, P. ve Skiba, K. (2021). Experimental study of propellers for the electric propulsion system, *2021 IEEE 8th International Workshop on Metrology for AeroSpace (MetroAeroSpace)*.
47. Wang, K., Zhou, Z., Zhongyun, F. ve Guo, J. (2021). Aerodynamic design of tractor propeller for high performance distributed electric propulsion aircraft, *Chinese Journal of Aeronautics*, 34(10), 20-35.
48. Gong, X., Zhang, L. (2017). *A New Method for Aerodynamic Test of High Altitude Propellers*. Microarticle, Xi'an ASN Technology Group Co.
49. Öner, L., Yükselen, M.A. (2010). *Pervane Analizi*. III. Ulusal Havacılık ve Uzay Konferansı, Eskişehir, Türkiye.
50. Onay, O.K., Khalilov, J., Ostovan, Y. ve Çete, A.R. (2012). *İnsansız Hava Aracı Pervanelerinin Tasarım, Analiz ve Test Yeteneklerinin Geliştirilmesi*. IV. Ulusal Havacılık ve Uzay Konferansı, İstanbul, Türkiye.
51. Wu, X., Zuo, Z., Ma, L. ve Zhang, W. (2024). *Multi-fidelity neural network-based aerodynamic optimization framework for propeller design in electric aircraft*. Aerospace Science and Technology, 146(2), 108963.
52. Pamuk, B. (2012). *Pervane Modellenmesi*, Yüksek Lisans Tezi, Ondokuz Mayıs Üniversitesi Fen Bilimleri Enstitüsü, İstanbul, Türkiye.



Gazili olmak ayrıcalıktır