T.C.
ISPARTA UYGULAMALI BİLİMLER ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

YÜKSEK LİSANS TEZİ
ELEKTRİK ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

HAVA ARAÇLARINDA BUZLANMA DERECESİNİN TAHMİNİ İÇİN FARKLI ALGORİTMALARIN PERFORMANSLARININ KIYASLANMASI

Fatmanur ATEŞ

Danışman
Doç. Dr. Ramazan ŞENOL

ISPARTA - 2021

© 2021 [Fatmanur ATEŞ]

İÇİNDEKİLER

Sayfa

İÇİNDEKİLER i
ÖZET iii
ABSTRACT iv
TEŞEKKÜR v
ŞEKİLLER DİZİNİ vi
ÇİZELGELER DİZİNİ viii
SİMGELER VE KISALTMALAR DİZİNİ ix
1. GİRİŞ 1
2. KAYNAK ÖZETLERİ 4
3. MATERYAL VE YÖNTEM 9
3.1. Hava Araçlarında Buzlanma Kavramı 9
3.2. Hava Araçlarında Buzlanmaya Bağlı Kazalar 9
3.3. Hava Araçlarında Buzlanmayı Etkileyen Temel Faktörler 12
3.3.1. Sıvı su içeriği 12
3.3.2. Sıcaklık 13
3.3.3. Damlacık çapı 13
3.3.4. Bulutluluk 13
3.3.5. Birikim 13
3.4. Buzlanma Türleri 14
3.4.1. Saydam (camsı, şeffaf) buzlanma 14
3.4.2. Mat buzlanma 14
3.4.3. Karışık tip buzlanma 15
3.5. Buzlanma Risk Derecesi Tanımlaması 15
3.6. Buzlanmanın Uçuş Emniyetine Etkileri 16
3.6.1. Kanat stol (perdövites) 17
3.6.2. Kuyrukta buzlanma 19
3.6.3. Sürüklenme kuvveti 19
3.6.4. Kaldırma kuvveti 20
3.7. Buz Önleme (anti-icing) ve Buz Giderme (de-icing) Sistemleri 21
3.7.1. Buz önleme sistemleri (anti-icing) 21
3.7.2. Buz giderme sistemleri (de-icing) 22
3.8. Yapay Zekâ Algoritmaları 22
3.8.1. KNN algoritması (k nearest neighbor) 23
3.8.2. Yapay sinir ağları (artificial neural network) 24
3.8.3. Destek vektör makineleri (support vector machine) 27
3.8.3.1. Doğrusal destek vektör makineleri 28
3.8.3.2. Doğrusal olmayan destek vektör makineleri 30
3.8.4. Karar ağaçları (decision tree) 31
3.8.5. Ensemble yöntemler 32
3.8.5.1. Torbalama algoritması 32
3.8.5.2. Artırma algoritması 33
3.8.5.3. Rastgele orman (random forest) 34
3.8.6. Yapay zekâ algoritmalarında kullanılan k kat çapraz doğrulama yöntemi 34
3.9. Performans Değerlendirme Ölçütleri 35
3.10. Çalışmada Kullanılan Yöntem 36
3.10.1. Verisetinin oluşturulması 36
3.10.2. Yapay zekâ algoritmaları 37

3.10.2.1. Yapay sinir ağları 38
3.10.2.2. KNN komşu algoritması 38
3.10.2.3. Destek vektör makineleri 38
3.10.2.4. Karar ağaçları 39
3.10.2.5. Ensemble modellerden rastgele orman algoritması 39
3.10.2.6. Ensemble modellerden torbalama algoritması 40
3.10.2.7. Ensemble modellerden artırma algoritması 40
3.10.3. Kullanılan yazılım ve optimum yapay zekâ yönteminin belirlenmesi 40
3.10.4. Kurulan modelin STM32F4 discovery kartına gömülecek formata getirilmesi 44
4. BULGULAR 46
4.1. Yapay Zekâ Algoritmalarının Uygulama Sonuçları 46
4.1.1. Yapay sinir ağları uygulama sonuçları 46
4.1.2. KNN algoritması uygulama sonuçları 47
4.1.3. Destek vektör makineleri uygulama sonuçları 49
4.1.4. Karar ağaçları uygulama sonuçları 51
4.1.5. Ensemble yöntemlerden rastgele orman uygulama sonuçları 52
4.1.6. Ensemble yöntemlerden bagging algoritması 54
4.1.7. Ensemble yöntemlerden boosting algoritması 55
4.2. Veriseti Üzerinde Optimum Sonucu Veren Yöntemin Belirlenmesi 56
4.3. Yapay Zekâ Algoritmasının Giriş ve Çıkış Sonuçlarının İncelenmesi 56
4.4. Kurulan Modelin STM32F4 Discovery Kartına Aktarılması 61
5. TARTIŞMA VE SONUÇ 63
KAYNAKLAR 66
ÖZGEÇMİŞ 72

ÖZET

Yüksek Lisans Tezi

HAVA ARAÇLARINDA BUZLANMA DERECESİNİN TAHMİNİ İÇİN FARKLI ALGORİTMALARIN PERFORMANSLARININ KIYASLANMASI

Fatmanur ATEŞ

Isparta Uygulamalı Bilimler Üniversitesi
Lisansüstü Eğitim Enstitüsü
Elektrik Elektronik Mühendisliği Anabilim Dalı

Danışman: Doç. Dr. Ramazan ŞENOL

Hava araçlarında buzlanma geçmişten günümüze havacılık alanında en büyük tehditlerden biridir. Buzlanma, hava araçlarında kazalara ve buna bağlı olarak ölümlere ve yaralanmalara sebep olabileceği gibi, hava araçlarının uçuş performansları üzerinde de olumsuz etkilere sahiptir. Bu olumsuz etkileri ortadan kaldırmak ya da en aza indirmek amacıyla buz önleme sistemleri ve buz giderme sistemleri önerilmiştir ve bu yöntemler geliştirilmektedir. Buzlanmaya karşı geliştirilen bu yöntemler, hava araçlarında oluşan buzlanma derecesine göre çoğunlukla pilot tarafından çalıştırılıp kapatılmaktadır. Bu durum buzlanmadan kaynaklı kazalara, pilottan kaynaklı kazalarında dâhil olmasıyla daha fazla hava aracı kazasına sebep olmaktadır. Pilot kaynaklı hataları engellemek için buz giderme/buz önleme sistemlerini buzlanma risk derecesine göre açıp kapatan sistemler üzeride çalışılmıştır. Bu çalışmada da örnek bir uçak için buzlanma risk derecesinin tahmini sonucunda buz önleme/giderme sisteminin doğrudan çalışmasını sağlayabilecek yedi farklı yapay zekâ algoritması denenmiştir. %88.59 ile optimum buzlanma risk derecesi tahminini yapan boosting algoritması önce simulinkte gerekli modelleme yapılıp, çağırılmış ve farklı giriş değerlerinde buzlanma derecesi tahmini yapılmıştır. Simulinkte modellenen şema waijung bloksetler ilave edilerek STM32F4 Discovery kontrol kartına gömülmüş ve buzlanma tahmininin sonuçları rgb led yardımıyla gözlemlenmiştir. Çalışmanın sonunda hava araçlarında buzlanma tahmininde kullanılabilecek, hava araçlarında buz önleme ve buzdan koruma sistemlerinin otomatik olarak devreye alınmasını sağlayacak model önerilmiştir.

Anahtar Kelimeler: Hava araçlarında buzlanma, Yapay zekâ, STM32F4 discovery, Waijung blokset, Matlab, Simulink

2021, 72 sayfa

ABSTRACT

M.Sc. Thesis

COMPARISON OF THE PERFORMANCES OF DIFFERENT ALGORITHMS FOR ESTIMATING THE DEGREE OF ICING IN AIRCRAFT

Fatmanur ATEŞ

Isparta University of Applied Sciences
The Institute of Graduate Education
Department of Electrical Electronics Engineering

Supervisor: Assoc. Prof. Dr. Ramazan ŞENOL

Aircraft icing is one of the biggest threats to aviation from past to present. Icing can cause accidents in aircraft, resulting in deaths and injuries, as well as have negative effects on the flight performance of aircraft. In order to eliminate or minimize these negative effects, anti-icing systems and de-icing systems have been proposed and these methods are being developed. These methods developed against icing are mostly operated and turned off by the pilot, depending on the degree of icing on the aircraft. This situation causes more aircraft accidents, including icing-related accidents and pilot-related accidents. In order to prevent pilot-induced errors, systems that turn on/off the de-icing/anti-icing systems according to the degree of icing risk have also been studied. In this study, seven different artificial intelligence algorithms that can directly operate the ice prevention/removal system as a result of estimating the degree of icing risk for a sample aircraft are tested. The boosting algorithm, which makes the estimation of the optimum icing risk degree with 88.59%, was first made in the simulink and called, and the icing degree was estimated at different input values. The scheme modeled in Simulink was embedded in the STM32F4 Discovery control card by adding waijung blocks, and the results of icing prediction were observed with the help of RGB LEDs. At the end of the study, a model that can be used in the prediction of icing in aircraft and that will enable automatic activation of anti-icing and anti-icing systems in aircraft has been proposed.

Key Words: Aircraft icing, Artificial intelligence, STM32F4 discovery, Waijung blokset, Matlab, Simulink

2021, 72 pages

TEŞEKKÜR

Meslek hayatıma adım attığım günden bu yana her konuda beni yönlendiren, destek olan ve tezimin yürütülmesinde emeğini hiçbir zaman esirgemeyen tecrübesiyle bana yol gösteren kıymetli tez danışmanım sayın Doç. Dr. Ramazan Şenol'a, mesleki hayatımda karşılaştığım zorluklarda desteklerini esirgemeyen, kendileriyle çalışmaktan şeref duyduğum bölümümüzün değerli hocalarına teşekkürü borç bilirim.

Değerli fikirleri ile beni yönlendiren, akademik bilgimin gelişmesinde büyük emeği olan sayın hocam Dr. Öğr. Üyesi Bekir AKSOY'a, tez fikrimin oluşmasında yardımcı olan sayın Mustafa Melikşah ÖZMEN'e teşekkür ederim.

Tezimin her aşamasında beni yalnız bırakmayan, her konuda bana sabırla destek olan aileme sonsuz sevgi ve saygılarımı sunarım.

Fatmanur ATEŞ
ISPARTA, 2021

ŞEKİLLER DİZİNİ

Sayfa

Şekil 1.1. 1946-2019 yılları ve arasında uçak kazaları 1
Şekil 1.2. Pitot tüpü buzlanması 2
Şekil 3.1. Buzlanma oluşmuş hava aracı görüntüleri 9
Şekil 3.2. İskandinav havayollarına ait yolcu uçağı 10
Şekil 3.3. Kazakistan'daki uçak kazası 10
Şekil 3.4. ATR 72-201 yolcu uçağı kazası 11
Şekil 3.5. Kazaya karışan uçak ve kaza alanının görüntüsü 11
Şekil 3.6. Arjantin yakınlarında düşen uçak 12
Şekil 3.7. Uçak kanadında saydam buzlanma 14
Şekil 3.8. Uçak kanadında mat buzlanma 15
Şekil 3.9. Uçak kanadında karışık buzlanma 15
Şekil 3.10. Uçağa etki eden kuvvetler 17
Şekil 3.11. Bernoulli ilkesine göre uçak kanadında hız, basınç ilişkisi 18
Şekil 3.12. Farklı hücum açılarında kanat profilinin görünümü 18
Şekil 3.13. Uçaktaki kuyruk bölgesinin uçak dengesine etkisi 19
Şekil 3.14. Kuyrukta oluşan buzlanmanın uçak dengesine etkisi 19
Şekil 3.15. Sürüklenme kuvveti ile kaldırma kuvveti arasındaki ilişki 20
Şekil 3.16. ATR uçağının ortalama buz kalınlığının değişimine göre kaldırma kuvveti katsayısı değişimi 20
Şekil 3.17. Pnömatik botların çalışma mantığı 22
Şekil 3.18. KNN sınıflandırma örneği 23
Şekil 3.19. İnsandaki bir sinir hücresinin gösterimi 25
Şekil 3.20. İnsan sinir sisteminin matematiksel modeli 25
Şekil 3.21. Doğrusal olarak dağılan verilerin hiper düzlemle ayrılması 29
Şekil 3.22. Verilerin doğrusal olarak ayrılamadığı durumda DVM 30
Şekil 3.23. Doğrusal olmayan veri seti a) İki boyutta dağılım b) Üç boyutta dağılım 30
Şekil 3.24. Karar ağacı yapısı 32
Şekil 3.25. Torbalama algoritması 33
Şekil 3.26. Artırma algoritması çalışma şeması 34
Şekil 3.27. Çapraz doğrulama 35
Şekil 3.28. Fonksiyon bloğu yardımıyla yeni verilerin ensemble modellerden boosting algoritmasıyla sınıflandırılması 44
Şekil 3.29. STM32F4 kontrol kartı kullanılarak buzlanma tahmini 45
Şekil 4.1. YSA modelinden eğitim sonrası alınan gizli katmanla çıkış arası ağırlıklar 46
Şekil 4.2. YSA modelinden eğitim sonrası alınan gizli katmanla çıkış arası biaslar 46
Şekil 4.3. Yapay sinir ağlarıyla sınıflandırılmış veri setinin doğruluk matrisi 47
Şekil 4.4. Seçilen k değerleri için doğruluk sonuçları 48
Şekil 4.5. KNN doğruluk matrisi 49
Şekil 4.6. Kernel fonksiyonlarına göre doğruluk değişimi 50
Şekil 4.7. Destek vektör makineleri doğruluk matrisi 51
Şekil 4.8. Karar ağaçları doğruluk matrisi 52
Şekil 4.9. Farklı sayıda kullanılan karar ağaçlarında doğruluğun değişimi 53
Şekil 4.10. Rastgele orman algoritması doğruluk matrisi 53
Şekil 4.11. Ensemble yöntemlerden bagging algoritması doğruluk matrisi 54
Şekil 4.12. Ensemble yöntemlerden boosting algoritması doğruluk matrisi 55

Şekil 4.13. Fonksiyon bloğu yardımıyla 57
Şekil 4.14. Buzlanma derecesi sıfır durumu için örnek analiz..... 57
Şekil 4.15. Buzlanma derecesi bir durumu için örnek analiz..... 58
Şekil 4.16. Buzlanma derecesi iki durumu için örnek analiz..... 58
Şekil 4.17. Buzlanma derecesi üç durumu için örnek analiz 59
Şekil 4.18. Random girişlere göre buzlanma derecesi tahmini..... 60
Şekil 4.19. Random girişlere göre giriş ve çıkış grafikleri 60
Şekil 4.20. Buzlanma derecesi tahminin gözlendiği devre 61
Şekil 4.21. RGB led yardımı ile gözlemlenen buzlanma dereceleri (a) Buzlanma yok (b) Buzlanma derecesi 1 (hafif) (c) Buzlanma derecesi 2 (orta) (d) Buzlanma derecesi 3 (yoğun)..... 62

ÇİZELGELER DİZİNİ

Sayfa

Çizelge 3.1. Pilotlara göre buzlanma şiddeti tanımlaması 16
Çizelge 3.2. Meteoroloji uzmanlarına göre buzlanma şiddeti tanımlaması 16
Çizelge 3.3. İnsan sinir sisteminin YSA'daki karşılıkları 24
Çizelge 3.4. İkili sınıftan oluşan hata matrisi 35
Çizelge 3.5. Performans değerlendirme metrikleri 36
Çizelge 3.6. Çalışmada kullanılan veri seti örneği 37
Çizelge 3.7. Waijung blokları, bloğun yeri ve kısaca görevi 41
Çizelge 4.1. Sınıflandırma yöntemlerinin performans değerlendirme metrikleri ile değerlendirilmesi 56

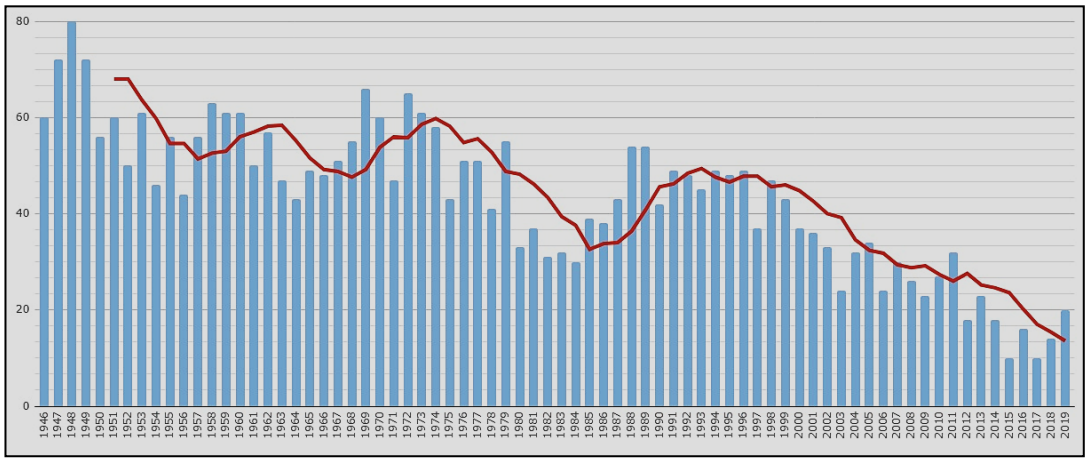
SİMGELER VE KISALTMALAR DİZİNİ

ADC	Analog-dijital dönüştürücü (analog to digital converter)
CL_{max}	Uçaklarda maksimum kaldırma kuvveti katsayısı
C^o	Santigrad derece
DP	Doğru pozitif
DVM	Destek vektör makineleri (support vector machine)
DY	Doğru negatif
g/m^3	Gram bölü metreküp
Hz	Hertz
İHA	İnsansız hava aracı (unmanned aerial vehicle)
KNN	K en yakın komşu (k nearest neighbor)
LWC	Sıvı su içeriği (liquid water content)
mm	Milimetre
PWM	Darbe genişlik modülasyonu (pulse width modulation)
YN	Yanlış negatif
YP	Yanlış pozitif
YSA	Yapay sinir ağları (artificial neural network)

1. GİRİŞ

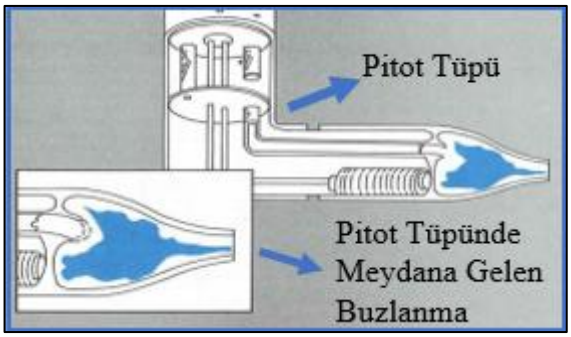
Teknolojinin hızla gelişmesi insan hayatına pek çok alanda kolaylıklar getirmiştir. Bu alanlardan birisi de ulaşımdır. Geçmişten günümüze bakıldığında ulaşım araçlarında değişimler olmaktadır. İnsanoğlu önce tekerleği icat etmiş ve bu icadın getirdiği kolaylık yeni icatların kapısını açmıştır. Buhar gücüyle ve benzinle çalışan motorların keşfedilmesi bu icadı modernleştirmiştir. Otomobiller, gemiler, uçaklar, gibi icatlarla günlük hayat daha kolaylaşmıştır. Ancak keşifler ile hayata geçirilen araçlarda yaşanılan kaza olayları yüzünden insanların hayati tehlikelerle karşılaşma oranları da artmıştır. İnsanoğlu bir taraftan hayatı kolaylaştırmak için keşifleri sürdürürken, diğer taraftan da bu keşiflerin beraberinde getirdiği yaralanma ve ölümleri azaltmaya çalışmaktadır.

Hava yolu ulaşımı, günümüzde insanların iş seyahati, tatil, akraba ziyareti, eğitim gibi sebeplerden ötürü kullanımını sıklıkla tercih ettiği ulaşım türüdür. Her ulaşım türünde olduğu gibi hava yolu ulaşımında da farklı nedenlerden kaynaklanan kazalar meydana gelmektedir. Şekil 1.1'de 1946 yılından 2019 yılına kadar geçen süreçte çeşitli sebeplerden kaynaklı kazalar mavi çubuk grafikle ve önceki beş yıla göre beş yıllık hareketli ortalama kırmızı çizgi ile verilmiştir. Kaza-kırımlarla ilgili bilgi "Aviation Safety Network" sitesinden alınmıştır. Bu siteden alınan bilgiler Avrupa ülkelerindeki oniki yolcu ve üzeri taşıma kapasitesine sahip uçakların kaza-kırım raporlarını içermektedir (Anonim, 2021a). Bu rapora göre 1946'dan 2019 yılına kadar olan süreçte uçak kazaların azaldığı görülmektedir (Anonim, 2021a).



Şekil 1.1. 1946-2019 yılları ve arasında uçak kazaları (Anonim, 2021a)

Hava aracı kazalarının önemli nedenlerinden birisini de buzlanma oluşturmaktadır. Buzlanmadan kaynaklı kazaların önüne geçebilmek için öncelikle buzlanmanın sebeplerinin tam olarak bilinmesi oldukça önemlidir. Buzlanmadan kaynaklı kazalarda pek çok etken vardır. Örneğin; bazı helikopterlerde buz algılama sistemi bulunmaz (Huber, 2013), pilot gözüyle buzlanmayı fark edememişse helikopter düşebilir. Farklı bir örnek vermek gerekirse, bir uçak için en önemli ekipmanlarından biri pitot tüpleri ve statik basınç deliğidir. Pitot tüpleri ve statik basınç deliği sayesinde havaya ait değerler alır. Pitot tüplerinin ve statik basınç deliğinin buzlanması havaya ait değerlerin yanlış alınmasına ve buna bağlı olarak uçağın kazasına sebep olabilir. Şekil 1.2.'de pitot tüpü buzlanması verilmiştir (Çoban, 2018). Buzlanmadan kaynaklı kazalara etki eden faktörlere bir başka örnek kanatlardaki buzlanma olabilir. Uçakların kanatlarının buzlanması uçağa etki eden ve uçağı dengede tutan kuvvet eşitliğini bozup uçağın kontrolünün kaybedilmesine ve kazaya sebep olabilir. Hatalar sadece hava aracı ekipmanlarından kaynaklanmaz, buzlanmadan kaynaklı pilot hataları da literatürde önemli oranda yer almaktadır. Buzlanma meydana geldiğinde pilot buz giderme sistemlerini geç devreye alabilir, bu durumda buzu çözmek veya söküp atmak için yeterli zaman olmayabilir ya da bu işlemi yapmak mümkün olmayabilir. Ayrıca pilot kalkış yapacağı esnada önceki uçuşunda meydana gelmiş uçak kanatlarındaki buzlanmayı görmeyip, kanatta var olan buzlanmayla kalkış yapıp kazaya sebep olabilir. Buzlanmadan kaynaklı kazaların önüne geçebilmek için tüm bu durumlar düşünülüp tedbir alınmalıdır.



Şekil 1.2. Pitot tüpü buzlanması (Çoban, 2018)

Buzlanmayı oluşturan atmosferik koşullardır ancak aynı koşullar farklı hava araçlarında farklı derecelerde buzlanmaya sebep olabilir. Yani buzlanma aslında hava aracı türüne, malzemesine, hızına gibi parametrelere bağlıdır. Bunun dışında

buzlanmaya etki eden faktörler, bulutluluk, damlacık büyüklüğü, sıvı su bileşeni, dışarıdaki havanın sıcaklığı, basınç gibi etkenlerdir (Vukits, 2002).

Tez çalışmasında buzlanma risk derecesi meteorolojik parametrelere bağlı olarak tahmin edilmiştir. Buzlanma risk derecesinin belirlenmesinde pek çok parametre etkili olmasına rağmen sıcaklık ve nem en çok belirleyici olan iki parametredir. Çalışmada buzlanma risk derecesi tahmininde parametre sayısı fazla tutulmuş ve daha hassas bir sınıflandırma yapılması amaçlanmıştır. Bu sebepten sıcaklık, nem, hava aracı sıcaklığı, yağış olmak üzere dört parametre ile buzlanma risk derecesi tahmin edilmiştir. Buzlanma risk derecesi tahmininde tek bir yapay zekâ yönteminin tahminine bağlı kalınmamış, literatürden farklı olarak buzlanma risk derecesinin belirlenmesinde k en yakın komşu algoritması (ing. k nearest neighbor), yapay sinir ağları (ing. artificial neural network), destek vektör makineleri (ing. support vector machine), karar ağaçları (ing. decision tree) ve topluluk ağaçlarından (ing. ensemble tree) rastgele orman, bagging ve boosting olmak üzere yedi farklı yapay zekâ uygulaması kullanılmıştır. Ayrıca uygulanan yapay zekâ yöntemlerinde 10 kat çaprazlama uygulanmıştır. Böylece 10 aşamada tüm veriseti test verisi olarak kullanılmış, doğrulukların ortalaması alınıp model doğruluğu belirlenmiş ve daha doğru bir sınıflandırma sonucunun bulunması amaçlanmıştır. Sınıflandırma için optimum yöntemi belirlemek adına değerlendirme işlemi tek bir performans değerlendirme metriği ile yapılmamış olup, değerlendirme sonuçları doğruluk (ing. accuracy), kesinlik (ing. precision), duyarlılık (ing. recall) ve F ölçütü (ing. F score) olmak üzere dört farklı değerlendirme metriği kullanılarak verilmiştir ve uygulanan yapay zekâ yöntemlerinden en optimum sınıflandırma yöntemi farklı değerlendirme metrikleri kullanılarak doğrulanmıştır. Yapay zekâ yöntemlerinin farklı değerlendirme metrikleri kullanılarak değerlendirilmesi de tez çalışmasında sunulmuştur. Uygulanan yapay zekâ algoritmalarından en doğru sonucu veren sınıflandırma yöntemi simulinkte kullanılabilecek şekilde modellenmiş ve farklı giriş değerleri için sonuçlar analiz edilmiştir. Ayrıca simülasyona ek olarak, STM32F4 discovery kontrol kartı içerisine gömülmüştür ve gerçekte problem üzerinde uygulanabilir düzeye getirilmiştir. STM32F4 kontrol kartı ile bu probleme çözüm getirilmesi tez çalışması ile gerçekleştirilmiştir.

2. KAYNAK ÖZETLERİ

Hava araçlarında buzlanma konusu pek çok alandan bilim insanının çalışma konusu olmuştur. Gerçekleştirilen akademik çalışmalar aşağda kronolojik sıralama ile verilmiştir.

Palacios vd. (2006), rotor kanatları için termal olmayan ultrasonik tabanlı bir buz önleme sistemi tanıtmışlardır. Ultrasonik dalgaların farklı frekans ve genliklerde buz bağlama dayanımına etkileri üzerine çalışmalar yapmışlardır. Uygulama sonuçlarını ve grafikleri vermişlerdir.

Aykan vd. (2011), F16 savaş uçağının uçuş sırasındaki kanat buzlanmalarını tespit ve teşhis etmeye ve kontrolünü sağlamaya çalışmışlardır. Uçağın buzlanma modelini kararlılık türevleri olarakta bilinen parametreler ile belirtmişler ve uçağın dinamik karakteristiklerinin Genişletilmiş Kalman Filtresi (EKF) innovasyon sürecindeki değişiklikleri izlenerek buzlanma tespiti yapmışlardır. Önce sistemi yapay sinir ağları (ing. YSA) ile eğitmişler daha sonra test etmişlerdir.

Boduroğlu (2014), Boeing 737-800 uçağının kanatları için uygulanabilen bir termal buz önleme sistemi üzerinde çalışmıştır. Termal buz önleme sistemleri; buzlanmaya maruz kalmış ya da kalacak olan kanat üzerine sıcak havanın üflenmesi mantığıyla çalışır. Çalışmada; farklı uçuş yüksekliklerinde, kabul edilmiş hava şartlarına göre, sınır tabaka denklemlerini kullanarak, buzlanmaya karşı gerekli olan ısı hesaplanmış ve buna göre sıcak hava üfleme kapasitesi elde edilmiştir.

Fenar (2016), çalışmasında uçaklarda meydana gelebilecek buzlanma risk derecesini yapay sinir ağları kullanarak tahmin ettirmeye çalışmıştır. Ortam sıcaklığı, havadaki su miktarı ve buzlanma derecesi ile önce yapay sinir ağları eğitilmiş sonrasında buzlanma derecesi tahmin ettirilmeye çalışılmıştır. Sınıflandırmada en optimum yöntemde R^2 için eğitim, tahmin ve test işlemi sonuçları sırasıyla 0.9992, 0.9901 ve 0.9918 olarak bulunmuştur. Sınıflandırmada en optimum yöntemde RMSE'ye göre değerlendirmede ise eğitim, tahmin ve test işlemi sonuçlarını 0.0425, 0.0410 ve 0.0420 olarak bulunmuştur.

Johansen ve Sorensen (2017), küçük insansız uçaklar için elektro termal tabanlı otonom buzlanma koruma sistemini önermişlerdir. Sistemlerinde hava taşıtlarının yüzeyinde bir elektro-termal kaynak, bir merkezi kontrol birimi ve birde önermiş oldukları buzlanma koruma çözümü bulunmaktadır. Kontrol ünitesinde, ortam atmosferik koşullarını ölçen yerleşik bir atmosferik sensör paketi bulunmaktadır. Buzlanma riski ortaya çıktığında kontrol algoritmalarının elektro-termal kaynaklara sağlanan enerjiyi kontrol etmesiyle ısı kontrolünü sağlamışlardır.

Kutlugün vd. (2017), akışkanlar dinamiği, bilimsel endeksler ve tıbbi konularda 3891 adet makale içeren 'classic3' veri setini kullanarak metinlerin türünü sınıflandırmışlardır. Metin türü belirleme işlemi için k en yakın komşu algoritmasını kullanarak hatalı durumları yapay sinir ağları ile ele alarak ve sınıflandırmada da ensemble bir yapı kullanarak ensemble metodunun başarımı artırılmıştır. KNN'de doğruluk oranı %88.326, YSA'da doğruluk oranı %89.164 iken ensemble metodun doğruluk oranı %95.776'a yükselmiştir.

Gliwa vd. (2018), Diamod DA42 uçağı için buzlanma önleme sisteminin otomatik olarak kontrol edilmesini sağlamışlardır. Matlab'in Fuzzy Logic Toolbox paketini kullanarak projelerini oluşturmuşlardır. Çalışmalarında hava sıcaklığı, bulut su içeriği, uçağın sıcaklığı ve yağış olmak üzere dört adet parametreyi dikkate almışlardır. İlk aşamada hava aracında oluşması muhtemel buz yoğunluğunu belirlemişler daha sonra buz önleme sistemini otomatik olarak ayarlamışlardır.

Akbal (2019), çalışmasında uçak kanadı üzerinde nümerik hesaplamaları kullanarak maksimum hava hızı görülen bölgede buz birikimi kalınlığı hesaplayıp buzun çeşidini belirlemiştir. Kanat üzerindeki kırağı buz birikiminin belli bir zamandan sonra camsı buza geçtiği süre ve camsı buza geçiş sürecinde yüzey üzerindeki su tabakasının kalınlığını hesaplamıştır.

Dökme (2019), buzlanma probleminin çözümü için kanat, kuyruk ve silindir geometrileri üzerinde buzlanma simülasyonu için Fortran, Techplot ve GetGraph Digitizer yazılımlarını kullanarak bilgisayar programı geliştirmiştir.

Vertuccio vd. (2019), esnek grafen film/kâğıt kullanarak uçak yüzeylerinde buzlanmayı önlemek için termal buzlanma önleme sistemi tasarlamışlardır. Tasarlamış oldukları esnek ısıtıcı kağıtla, yüksek mekanik özellikler sunarken, buz çözmeyi sağlamak için muadillerinden daha düşük güç kullanmışlar.

Duran ve Teke (2019), kara yolunda buzlanma olup olmadığını tespit eden akıllı yol durum sensörü tasarlamışlardır. Yapay zekâda giriş değerleri toprak sıcaklığı, hava sıcaklığı, hissedilen nem, hava basıncı ve yol yüzeyindeki iletkenlik değerleri alınmıştır, çıkış değerleri ise buzlu, kuru, ıslak, tuzlu-ıslak olmak üzere dört kategoride sınıflandırılmıştır. Yolda buzlanma tahmini yaptırmak için k en yakın komşu algoritmasını ve destek vektör makinelerini kullanıp sınıflandırma doğruluğu %99.68 olan k en yakın komşu algoritmasını tercih etmişlerdir. Destek vektör makinesinin sınıflandırma doğruluğunun ise %90.28 olduğunu ifade etmişlerdir. Ayrıca geliştirmiş oldukları model için Raspberry pi üzerinde gerçek zamanlı olarak uygulama yapmışlardır.

Gültepe (2019), çalışmasında Kastamonu Dataset üzerinde yapay sinir ağları (YSA), rastgele orman (random forest), k en yakın komşu (k nearest neighbor), lojistik regresyon (logistic regression), karar ağacı (decision tree), lineer regresyon (linear regression) ve basit bayes (naive bayes) algortimalarını kullanarak Kastamonu iline ait hava kirliliğini tahmin ettirmiştir. Kullanılan yapay zekâ algortimaları içerisinde rastgele orman algoritması ve karar ağaçları ile %99 doğruluk oranı ile en başarılı model olarak tespit etmişlerdir.

Hann (2020), doktora tez çalışmasında atmosferik buzlanmanın İHA'lar üzerindeki etkileri hakkındaki bilgileri artırmak amacıyla İHA'larda buzlanma problemine, özel buzlanma sorunlarına, buz birikiminin tahminine, buzlanmanın etkilerine, buzlanmadan korunma yöntemlerine ve aktif bir İHA için gerekli olan buz koruma sistemi için ne kadar enerji gereklidir sorusuna odaklanarak çözüm önerisi geliştirmeye çalışmıştır.

Li vd. (2020), XGBoost denetimli öğrenme algoritması kullanarak maksimum buz kalınlığı, buzlanma alanı ve buzlanma risk derecesi tahmini yapmışlardır. XGBoost modelinde sıvı su içeriği, damlacık çapı ve maruz kalma süresi giriş parametreleri

olarak belirlenmiştir. Buzlanma risk derecesi tahmini değerlendirmelerinde kesinlik, duyarlılık, F puanı ve doğruluk matrisini kullanmışlardır. 521 veriden, 512 veriyi doğru, 9 veriyi hatalı sınıflandırmışlardır. Kesinlik, duyarlılık ve F puanı değerlerini ise 0.95'in üzerinde değerler elde etmişlerdir.

Shen vd. (2020), hava aracı termal buz önleme sistemlerini simule etmek için ve hava damlacık akışı ve katı yüzeyin birleşik ısı transferini çözmek için; buzlanmayı önleyen yüzeydeki geri akış suyunun kütle ve sıcaklık transfer modelini, kabuğun sıcaklık denklemleriyle birleştirmişlerdir. Çalışmada ısı akışına dayalı olarak geliştirilen yöntemin; geri akış suyunun termodinamik modelini doğrudan çözebiliyorken, sıcaklığa dayalı yöntemleri daha yüksek hesaplama hızında çözüme ulaştığını belirtmişlerdir.

Göktaş ve Yağanoğlu (2020), kalp krizi tanısını tahmin etmeyi amaçlamışlardır. Kalp krizi tanısı koymada belirlenen 12 nitelik ve 303 olgu içeren veri seti üzerinde analiz yapmışlardır. Göğüs ağrısı tipi, egzersize bağlı anjin ve egzersize bağlı ST depresyonu niteliklerinin kalp krizi tanısıyla yüksek kolerasyona sahip olduğunu bulmuşlardır. Algoritma olarak C4.5 karar ağacı algoritması, k en yakın komşu algoritması, rastgele orman algoritması ve destek vektör makineleri olmak üzere dört farklı algoritma kullanmışlar kalp krizi tanısı %83.099 sınıflandırma doğruluğu ile en yüksek oranda C4.5 karar ağacı algoritması ile tespit konulmuştur.

Şenel (2020), çalışmasında kayısı iç çekirdeklerini yapay zekâ algoritmalarını kullanarak acı ve tatlı olarak sınıflandırmıştır. Sınıflandırma algoritması olarak k en yakın komşu, destek vektör makinesi, karar ağacı, rasgele orman, adaptive boosting, gaussian naive bayes ve çok katmanlı algılayıcı algoritmaları kullanılmıştır. Bu algoritmalardan k en yakın komşu algoritması, karar ağaçları, rastgele orman algoritması ve adaptive boosting %100 doğrulukla çekirdeklerin acı ve tatlı olma durumlarını tahmin etmiştir.

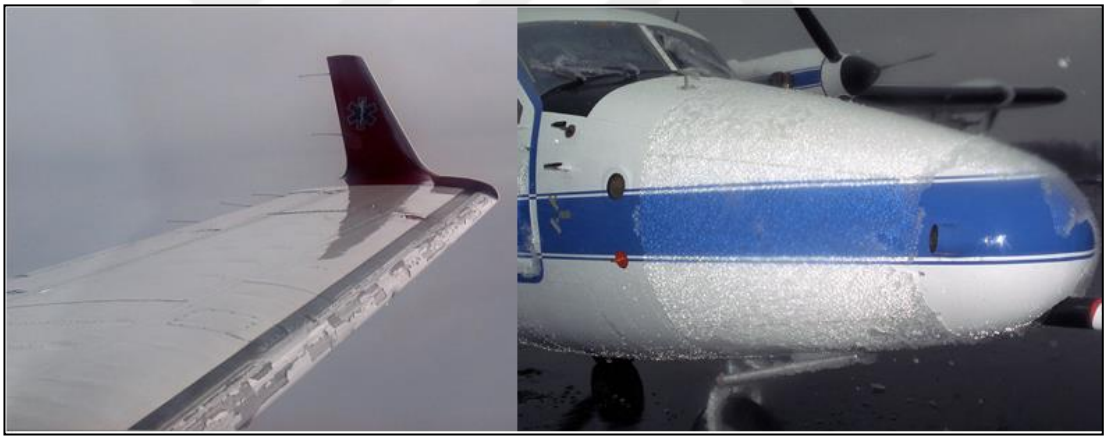
Yapay zekâ yöntemleri farklı verisetleri üzerinde birbirlerinin üzerinde optimum sonuç verebilirler. Bu çalışmada birden fazla yapay zekâ yöntemi denenmiş bu sayede verisetini sınıflandırmada en optimum yöntem belirlenmiştir. Ayrıca bu çalışmada sonuçlar birden fazla performans değerlendirme metriği ile değerlendirilmiş olup

doğruluk matrisleri verilmiştir. Aynı zamanda bu çalışma simulasyon ile birlikte modellenen sistemin bir kontrol kartı ile kullanımını da içermektedir. Kodlar STM32F4 discovery kontrol kartının içerisine gömülmüştür ve gerçek problem üzerinde uygulanabilecek durumdadır.

3. MATERYAL VE YÖNTEM

3.1. Hava Araçlarında Buzlanma Kavramı

Hava araçlarında buzlanma, meteorolojik koşullara bağlı olan atmosferik koşulların ortaya çıkardığı uçuş emniyetini riske atan önemli durumlardan biridir. Hava araçlarında buzlanma, hava aracı yerdeyken ya da havadayken oluşabilir (Çoban, 2018). Buzlanma hadisesi sadece kış mevsiminde meydana gelmez (Akbal vd., 2019). Buzlanma hava aracı tiplerine göre de farklı etkiler göstermektedir. Buzlanma hava aracı yüzeyinde ağırlık artışına sebep olmasından dolayı güç ve hızı düşürmektedir. Bu nedenle hava aracının kararlılığını ve kontrolünü bozarak kazalara sebep olabilmektedir. Buzlanma, sürüklenme kuvvetinde artışa sebep olarak hava aracının hızı düşürerek yakıt tüketimini artırmaktadır (Ünlü ve Hilmioğlu, 2017). Şekil 3.1'de buzlanma oluşmuş hava aracına ait görüntüler verilmiştir (Anonim, 2019).



Şekil 3.1. Buzlanma oluşmuş hava aracı görüntüleri (Anonim, 2019)

3.2. Hava Araçlarında Buzlanmaya Bağlı Kazalar

Hava araçlarında buzlanma ölüm ve yaralanmaların meydana geldiği çeşitli kazalara sebep olabilir. Kazalardan bazıları sebepleri ile aşağıda örnekler şeklinde verilmiştir.

27 Aralık 1991 yılında İskandinav havayollarına ait 751 sefer sayılı uçak, kanadındaki ince buz tabakasının fark edilememesi sebebiyle havalandıktan kısa süre sonra kanatların üzerindeki buz parçacıklarının motora girmesi sonucu motorların durmasına bağlı düşmüştür. Üç parçaya ayrılan uçakta tüm mürettebat ve yolcular kemerlerini

bağladıkları için kurtulmuşlardır. Uçağı görüntüsü Şekil 3.2'de verilmiştir (Anonim 2011).



Şekil 3.2. İskandinav havayollarına ait yolcu uçağı (Anonim 2011)

27 Aralık 2019 yılında Bek Air'in 2100 sefer sayılı uçuşu buzlanmadan kaynaklı kaza ile sonuçlanmıştır. Uçak Kazakistan'daki Almatı Havaalanından kalktıktan hemen sonra binaya çarpmıştır. 98 yolcu ve 5 mürettebatın olduğu uçakta 13 kişi hayatını kaybetmiş ve 6 kişi yaralanmıştır. Kazadan kurtulanlardan biri uçağın kanatlarında buz gördüğünü ve kanatların sarsılması sonucuyla kazanın gerçekleştiğini belirtmiştir. Şekil 3.3'te uçağın kazasına ilişkin görsel verilmiştir (Anonim, 2020).



Şekil 3.3. Kazakistan'daki uçak kazası (Anonim, 2020)

25 Aralık 1951'de Ankara'dan İstanbul'a giden Türk Hava Kuvvetlerine ait askeri uçak buzlanma nedeniyle düşüp yanmıştır. Douglas DC-3 tipi uçakta bulunan altı asker şehit düşmüştür.

2 Nisan 2012 tarihinde UTAir firmasına ait ATR 72-201 yolcu uçağı Rusya'nın Tyumen şehrinden havalandıktan kısa süre sonra düşerek üç parçaya bölünmüştür. 4 kabin ekibi ve 29 yolcu hayatını kaybetmiş 10 yolcuda yaralanmıştır. Uçağın kaza sebebi kayıtlara kaptan pilotunun uçağın kritik yüzeylerinde oluşan kar ve buz birikimlerine dikkat etmemesi sonucu gerçekleşmesi olarak geçmiştir. Uçağın enkazına ilişkin görüntüler Şekil 3.4'te verilmiştir (Çoban, 2020).



Şekil 3.4. ATR 72-201 yolcu uçağı kazası (Çoban, 2020)

11 Şubat 2018 yılında Saratov Hava yollarının 703 nolu uçuşunu yapan Antonov An-148-100B uçağı kalkıştan kısa bir süre sonra düşmüştür. Uçağın içinde bulunan 65'i yolcu 6'sı mürettebat olmak üzere 71 kişi ölmüştür. Soruşturmada yer alan bazı kaynaklara göre Moskova'dan kalkan uçağın pilotu, kazadan birkaç dakika önce hava trafik denetleyicilerine bir arızadan bahsetmiştir. Kaza, buzlanmadan ötürü pitot tüplerinin hava hızını doğru göstermemesinden ve mürettebatın hatalı karar vermesinden kaynaklı uçağın kontrolünü kaybetmelerinden meydana gelmiştir (Anonim, 2019; Anonim, 2021b). Şekil 3.5'te kazaya karışan uçak ve kaza alanının görüntüsü verilmiştir (Anonim, 2021b).



Şekil 3.5. Kazaya karışan uçak ve kaza alanının görüntüsü (Anonim, 2021b)

18 Mayıs 2011'de Sol Lineas Aereas'a ait Saab 340A tipi uçak Arjantin yakınlarında uçak gövdesinin şiddetli buzlanması ve buna bağlı olarak uçak kontrolünün

kaybedilmesi sonucu düşmüş ve 1'i çocuk, 3'ü mürettebat toplamda 22 kişi ölmüştür. Uçakta teknik bir kusur olmamasına rağmen buzlanma koşullarının çok şiddetli olmasından ötürü buz giderme sistemleri çalışmamıştır (Anonim, 2021c). Kazaya karışan uçak Şekil 3.6'da verilmiştir (Anonim, 2021c).



Şekil 3.6. Arjantin yakınlarında düşen uçak (Anonim, 2021c)

Literatürde hava araçlarına ilişkin buzlanmadan kaynaklı bazı kazalar yukarıda örneklenmiştir. Örneklerden de anlaşılacağı gibi buzlanma uçuş güvenliğini için oldukça önemli bir faktör olmasından dolayı hava araçlarında buzlanmayı etkileyen faktörlerin dikkatli bir şekilde incelenmesi oldukça önemlidir.

3.3. Hava Araçlarında Buzlanmayı Etkileyen Temel Faktörler

Hava araçlarında buzlanmada, buzlanmanın yoğunluğu, biçimi ve derecesinde birçok parametre vardır. Buzlanma olayının meydana gelmesinde en önemli iki parametre sıvı su içeriği ve hava sıcaklığıdır (Akbal, 2019). Buzlanmada önemli olan bazı parametreler aşağıda alt başlıklar altında incelenmiştir.

3.3.1. Sıvı su içeriği

Buz birikimi oranının belirlenmesinde oldukça önemli bir parametredir. Genel olarak bulutun tabanı ne kadar düşük ve sıcak olursa, su içeriği o kadar yüksek olur. Bulut içinde, ortalama sıvı-su içeriği rakımla birlikte maksimum bir değere yükselir ve sonra azalır (Air Weather Service, 1980). Birimi metreküp olup hava başına düşen su miktarıdır.

3.3.2. Sıcaklık

Buzlanmanın gerçekleşebilmesi için hava sıcaklığının da önemi büyüktür. Buzlanma genellikle 0 C^o ile -20 C^o arasında meydana gelirken, -20 C^o altı sıcaklıklarda çok az buzlanma olayı meydana gelir (Politovich, 2003). Sıcaklık -40 C^o altına düştüğünde hava sıcaklığı buz oluşturmak için çok düşük sıcaklığa sahip olacağından buzlanma görülmez. Tehlikeli buz şekilleri donma noktasına yakın sıcaklıklarda oluşur. Donma noktasına yakın sıcaklıklarda havadaki süper soğumuş su damlacıklarının oranı artar. Süper soğumuş su damlacıkları çarptıkları yüzeye yayılarak saydam buzu oluşturur. Süper soğumuş su damlacıkları 0 C^o'de donmayan -40 C^o'ye kadar sıvı formunu koruyabilen damlacıklardır (Fenar, 2016).

3.3.3. Damlacık çapı

Buluttaki su damlacıkları tekdüze aynı boyutta olmayıp farklı çaplara sahiptir. Toplam sıvı su içeriği, damlacıkların sayısını damlacık çapına göre sınıflandırılarak hesaplanabilir (Heinrich, 1991). Su damlacıklarının çapı genel olarak 10-50 mikron arasında değişmektedir. Damlacığın boyutunun artması buzlanma etkinliğini ve birikimini de artırmaktadır (Fenar, 2016).

3.3.4. Bulutluluk

Bulutların tabanı ne kadar düşük ve ne kadar sıcak olursa bulutun içerisindeki su miktarı da artar (Air weather service, 1980). Bulutun içerisindeki süper soğumuş su damlacıkları ise bulutun alt tabakasında daha fazla oranda bulunur. Bu sebeple bulut içerisinde yükselmek buzlanmanın etkinliğinin azalmasına neden olmaktadır (Fenar, 2016).

3.3.5. Birikim

Havadaki buharın veya nemin herhangi bir nedenle soğumak suretiyle yüzeyler üzerinde katılaşmasıyla buz oluşur (Çamalan, 2011). Buz kalınlığının artması sonucunda da birikim oluşur. Buzlanmanın etkinliğini etkileyen faktörlerden bir diğeri hava aracı yüzeyindeki birikimdir. Birikimde hava aracı yüzeyinin yapısı ve

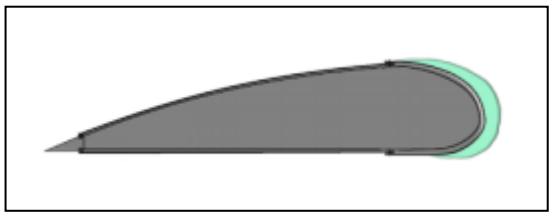
büyüklüğü su damlacıklarının tutunmasında oldukça etkili olmaktadır (Ünlü ve Hilmioğlu, 2017).

3.4. Buzlanma Türleri

Buzlanma türleri temelde mat buzlanma ve saydam buzlanma olmak üzere iki ana başlık altında incelenir. Ancak her ikisinin de bulunduğu karışık tip buzlanmada meydana gelebilir. Buzlanma türleri görünümüne ve şekline göre sınıflandırılmıştır.

3.4.1. Saydam (camsı, şeffaf) buzlanma

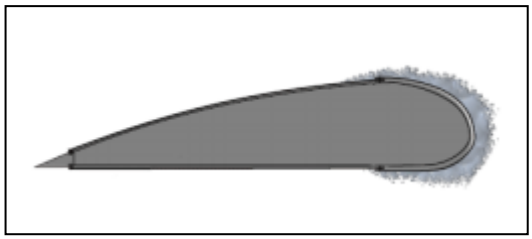
Saydam buzlanma aynı zamanda camsı buzlanma ve şeffaf buzlanma olarak da bilinmektedir. 0 C^o altındaki sıcaklıklarda büyük damlalar kanada çarptığı esnada bir kısmı donar, donmayan kısmı kanadın arka kısmına doğru akar ve akarken de hava kabarcığı kalmaz. Bu şekilde oluşan buza camsı buz adı verilir. Oldukça sert, yoğun ve sıktır. Hava aracı yüzeyinden atılması oldukça zordur ve hava aracının bütün yüzeyini kaplayabilen en tehlikeli buzlanma türü olup tespit edilmesi oldukça zordur. Hava aracının inişi ve kalkışı sırasında esnemeden dolayı kırılırsa motora hasar verebilir (Boduroğlu, 2014; Fenar, 2016; Ünlü ve Hilmioğlu, 2017). Şekil 3.7'de bir uçak kanadında oluşabilecek saydam buzlanma görseli verilmiştir (Anonim, 2015).



Şekil 3.7. Uçak kanadında saydam buzlanma (Anonim, 2015)

3.4.2. Mat buzlanma

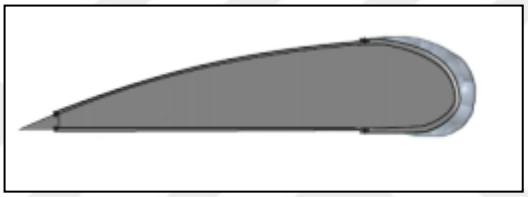
Buzun görünümü mat olup kara benzemektedir. Genellikle buzlanma önleyici sistemlerle ve buzlanma giderici sistemlerle önlenebilir. Çünkü mat buzlanma çeşidinin yapışkanlık özelliği düşüktür. Ancak hava aracı üzerinde uzun süre birikme olursa hava aracının uçuş emniyetini bozar (Boduroğlu, 2014; Fenar, 2016; Ünlü ve Hilmioğlu, 2017). Şekil 3.8'de mat buzlanma gösterilmiştir (Anonim, 2015).



Şekil 3.8. Uçak kanadında mat buzlanma (Anonim, 2015)

3.4.3. Karışık tip buzlanma

Hem saydam hem mat buz türünün hava aracı yüzeyinde birlikte oluşması ile meydana gelen buzlanma türüdür. Karışık buzlanmaya ait örnek bir görsel Şekil 3.9.'da verilmiştir (Anonim, 2015).



Şekil 3.9. Uçak kanadında karışık buzlanma (Anonim, 2015)

3.5. Buzlanma Risk Derecesi Tanımlaması

Hava araçlarında görülen buzlanma yoğunluğu farklı kategorilere ayrılmıştır. Buradaki amaç buzlanma ile ilgili tanımlama ve raporlama yapabilmektir. Buzlanmanın şiddetini belirleyebilmek için ABD Federal Havacılık Yönetimi (ing. Federal Aviation Administration) tarafından iz (ing. trace), hafif (ing. light), orta (ing. moderate) ve kritik (ing. severe) buzlanma olmak üzere dört kategori belirlenmiştir. Pilotlar tarafından kullanılan buzlanma indeksi şiddeti tanımlaması ile meteoroglar tarafından kullanılan buzlanma indeksi şiddeti tanımlaması birbirinden farklıdır. Bu kategoriler ve tanımlamalar Çizelge 3.1'de verilmiştir (Mingione, 1997; Çoban, 2018). Çizelge 3.1'deki sınıflandırma pek çok parametreye bağlıdır. Hava aracının büyüklüğüne, tipine gibi kategorilere göre farklılık gösterir. Aynı bölgede küçük bir hava aracında buzlanma görülebilirken, büyük bir hava aracında buzlanma görülmeyebilir. Buzlanmaya sıcaklık, nem, damlacık büyüklüğü gibi dış etkenlerde etki eder ancak bunların etki ölçüsü ile ilgili bilimsel net bir miktar bulunmamaktadır.

Çizelge 3.1. Pilotlara göre buzlanma şiddeti tanımlaması (Mingione, 1997; Çoban, 2018)

Buzlanma Kategorisi	Tanım
İz (trace)	Görülmesi zor olsa da fark edilebilen buzlanma derecesidir. Beyaz çizgi olarak görünür. Buzlanma durumu bir saatten fazla sürmediği müddetçe buz önleme ve buzdan koruma ekipmanlarının çalıştırılmasına gerek yoktur (Cao vd., 2018).
Hafif (light)	Hava aracında buzlanmanın 1 (bir) saatten fazla devam etmesi durumunda kanatların ön kenarında oluşan beyaz çizgi şeklindeki buzlanma genişlemeye başlar ve hava aracının performansı bu durumdan etkilenir. Bu yüzden buzdan koruma sisteminin çalıştırılması gerekir (Cao vd., 2018).
Moderate (orta)	Kısa süreli oluşacak bir buzlanma süresi bile çok tehlikelidir. Buz önleme sistemi ya da buzdan koruma sistemi ile buz birikimi önlenmeli ya da hava aracından sökülmelidir. Buzlanmayı engellemek orta düzeydeki buzlanmada irtifa ve yön değiştirmek gerekebilir. (Cao vd., 2018).
Kritik (severe)	Bu buzlanma türünde hava aracı bir an önce güvenli hava sahası şartlarına dönmelidir. İrtifa ya da yön değiştirmesi gerekir. Çünkü buzdan koruma ya da buz önleme ekipmanları çalıştırılsa bile buzlanma engellenemez ve buzlanmanın etkisi azaltılamaz (Cao vd., 2018).

Meteoroloji uzmanları ise buzlanma kategorisi tanımını bulut içerisindeki su miktarının metreküp başına ölçümü (ing. Liquid Water Content- LWC g/m^3) ile gerçekleştirilir (Cao vd., 2018). Çizelge 3.2'de meteoroloji uzmanlarına göre buzlanma şiddeti tanımlaması verilmiştir.

Çizelge 3.2. Meteoroloji uzmanlarına göre buzlanma şiddeti tanımlaması (Cao vd., 2018)

Buzlanma Kategorisi	LWC g/m^3
İz (Trace)	< 0.1
Hafif (Light)	0.11-0.6
Orta (Moderate)	0.61-1.2
Kritik (Severe)	>1.2

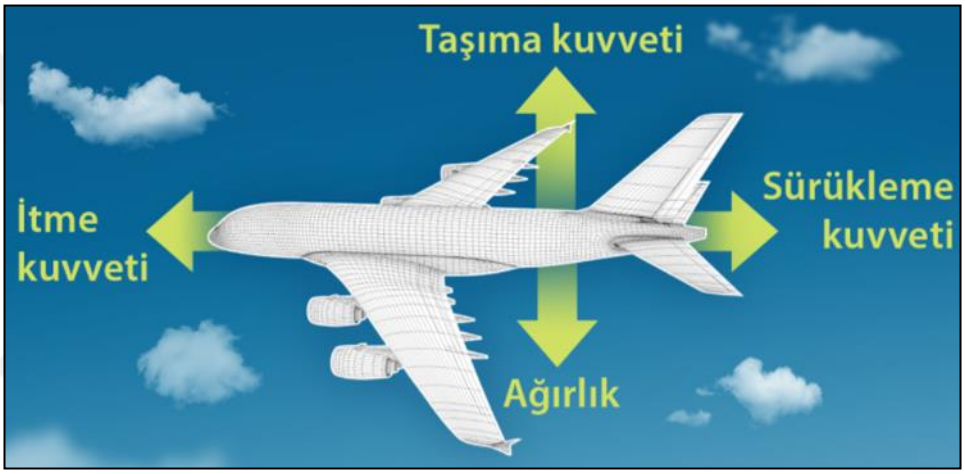
3.6. Buzlanmanın Uçuş Emniyetine Etkileri

Uçakta buzlanma uçağın çeşitli bölümlerinde meydana gelebilir ve her bir buzlanma uçuş emniyetini düşürür. Buzlanma uçak için uçağın düşmesi ve parçalanmasına kadar birçok olumsuz sonuca neden olabilir. Buzlanma, buz birikim yeri, miktarı ve türüne bağlı olarak uçak performansını ve yol tutuş özelliklerini farklı şekillerde etkileyebilir.

Bu yüzden buzun uçaklar üzerindeki tüm olası etkilerini sınıflandırmak oldukça zordur, ancak en yaygın etkileri kanat stol, kuyrukta buzlanma, sürüklenme kuvveti ve kaldırma kuvveti başlıkları olarak aşağıda incelenmiştir (Mingione, 1997).

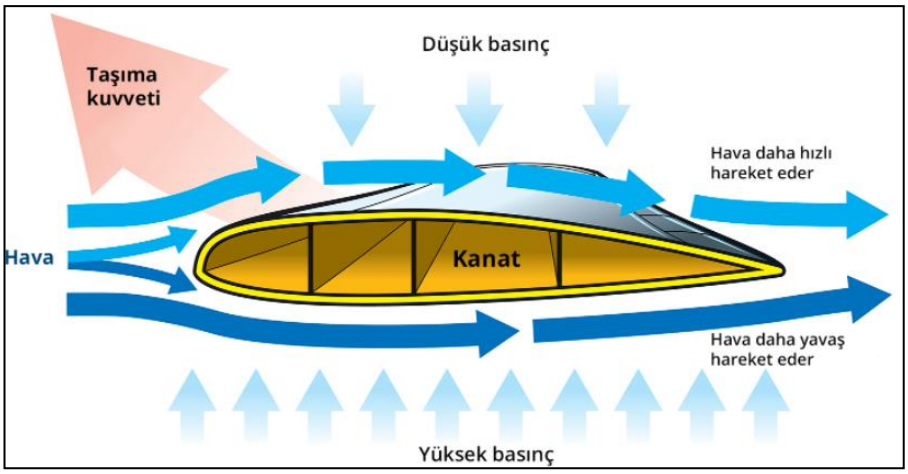
3.6.1. Kanat stol (perdövites)

Uçağa etki eden dört ana kuvvet vardır. Bu kuvvetler; uçağın gidiş yönünde olan itme kuvveti, uçağın gidişine ters etki eden sürüklenme kuvveti, uçağı yukarıya iten taşıma kuvveti, uçağı aşağı çeken ağırlık kuvvetidir. Şekil 3.10'da bu kuvvetler gösterilmiştir (Okatan, 2019).



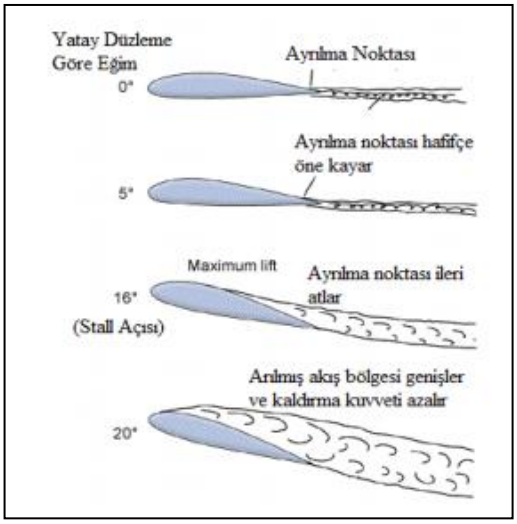
Şekil 3.10. Uçağa etki eden kuvvetler (Okatan, 2019)

Newton'un hareket yasalarına göre bir cisme etki eden bütün kuvvetler eşitlendiğinde cisim sabit hızda hareket eder. Buna göre uçakta yer çekimi kuvvetini dengeleyen, taşıma kuvvetidir. Sürüklenme kuvvetini dengeleyen ise itme kuvvetidir. Taşıma kuvveti Bernoulli ilkesine uygun olarak tasarlanan kanat yapıları sayesinde oluşur. Bernoulli ilkesi havanın hızının yüksek olduğu yerlerde basıncın düşük olduğunu, havanın hızının düşük olduğu yerlerde ise basıncın yüksek olduğunu ifade eder. Uçağın kanadı Bernoulli ilkesinden yararlanılarak üst kısmı daha bombeli alt kısmı ise daha düz tasarlanır. Böylece hava; kanadın üstünde daha hızlı akar ve düşük basınç sağlayarak kanadın altında daha yavaş akar ve yüksek basınç sağlar. Uçağın alt kanadı ile üst kanadı arasındaki basınç farkı uçağın kanatlarını yukarı doğru iten bir taşıma kuvveti oluşturur. Şekil 3.11'de bu durum yani Bernoulli ilkesinin uçak kanadına uygulanmış görseli verilmiştir (Okatan, 2019).



Şekil 3.11. Bernoulli ilkesine göre uçak kanadında hız, basınç ilişkisi (Okatan, 2019)

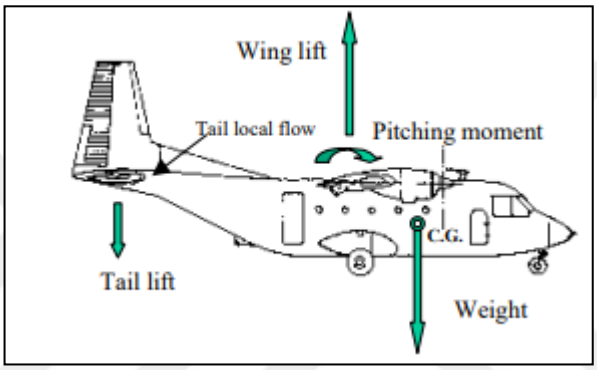
Uçağın uçuş performansını artırmak için kanat profili etrafında oluşan kaldırma kuvvetinin artırılması ve sürüklenme kuvvetinin azaltılması gerekmektedir. Bunu sağlamanın yöntemlerinden biri hücum açısını artırmaktır. Hücum açısı hava aracının hız vektörü ile kanat veter yönü arasında kalan açıdır. Hücum açısı artırıldığında kaldırma kuvveti de artar ancak bu açı belli bir değeri geçerse akım çizgileri kanat üzerinde tutunamaz. Hücum acısı arttıkça akım ayrılma noktası hücum kenarlarına yaklaşır ve 12-14 derece açıdan sonra akım ayrılması (ing. stol) başlar. Hücum açısının bu açı değerinin üzerinde olması sürüklenme kuvvetinin artışına kaldırma kuvvetinin düşmesine sebep olur (Genç vd., 2008). Kanatlarda oluşan az miktarda buzlanma bile uçağın hücum açısını değiştirebilir (Anonim, 2015). Şekil 3.12'de buzlanmaya bağlı olarak hücum açısının değişimi verilmiştir.



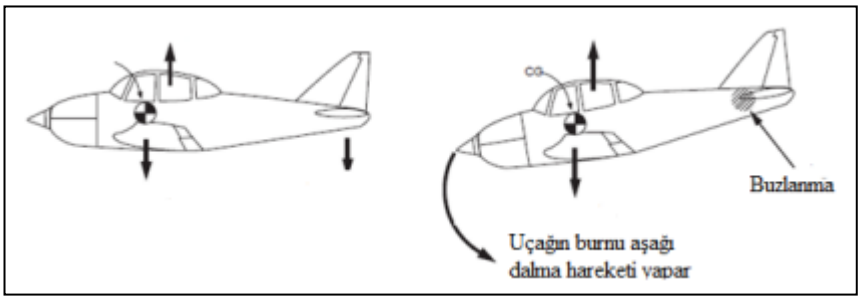
Şekil 3.12. Farklı hücum açılarında kanat profilinin görünümü (Fenar, 2016)

3.6.2. Kuyrukta buzlanma

Çoğu geleneksel uçaklarda uçağın ağırlık merkezi kanat aerodinamik merkezinin önünde yer alır. Bu nedenle, kanat kaldırma ve uçak ağırlığı, arka düzlem kuvveti tarafından dengelenen bir aşağı itme momenti oluşturur (Mingione, 1997). Arka düzlemde meydana gelecek olan bir buzlanma dengeyi değiştirir ve uçağın statik kararlılığını bozar. Şekil 3.13'de kuyruk bölgesinin uçağın dengesine etkisi gösterilmiştir. Şekil 3.14'de ise kuyrukta meydana gelen buzlanmanın etkisi görülmektedir (Fenar, 2016).



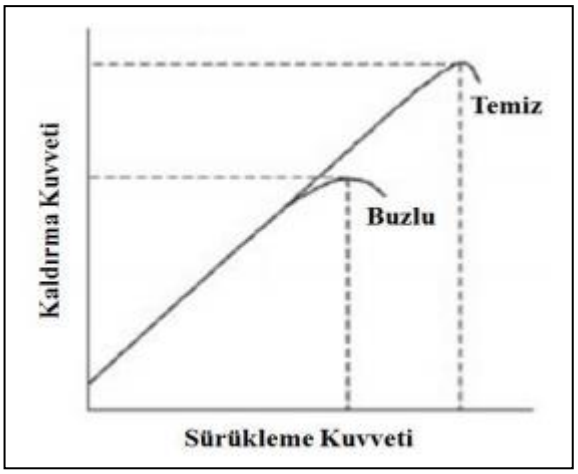
Şekil 3.13. Uçaktaki kuyruk bölgesinin uçak dengesine etkisi (Mingione, 1997)



Şekil 3.14. Kuyrukta oluşan buzlanmanın uçak dengesine etkisi (Fenar, 2016)

3.6.3. Sürüklenme kuvveti

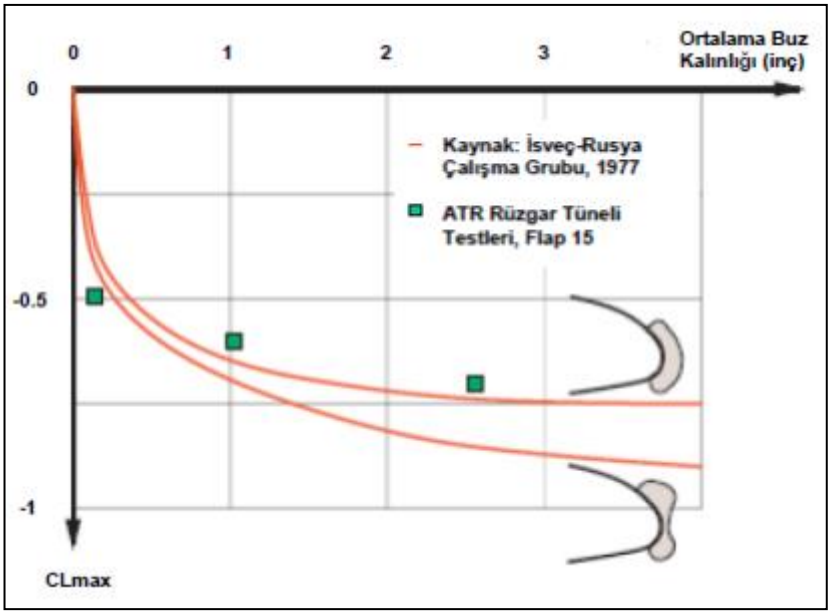
Buzlanma, sürüklenme kuvvetini artırır. Sürüklenme kuvvetinin artması uçağın hızını düşürür ve yakıt tüketimini artırır. Sürükleme kuvveti ile kaldırma kuvveti arasında Şekil 3.15'de verilen görseldeki gibi bir ilişki vardır (Paraschivoiu ve Saeed, 2005; Ünlü ve Hilmioğlu, 2017).



Şekil 3.15. Sürüklenme kuvveti ile kaldırma kuvveti arasındaki ilişki (Ünlü ve Hilmioğlu, 2017)

3.6.4. Kaldırma kuvveti

Hava araçlarında buzlanma, hava aracına etki eden kaldırma kuvvetinde ortalama %30' lara varan bir azalmaya neden olmaktadır. Literatürde yapılan ölçümlere göre buzlanma derecesinin azalmasıyla maksimum kaldırma kuvveti katsayısı (CLmax) da azalmaktadır. Şekil 3.16'da ATR Uçağının ortalama buz kalınlığının değişimine göre kaldırma kuvveti katsayısı değişimi verilmiştir (Boduroğlu, 2014).



Şekil 3.16. ATR uçağının ortalama buz kalınlığının değişimine göre kaldırma kuvveti katsayısı değişimi (Boduroğlu, 2014)

3.7. Buz Önleme (anti-icing) ve Buz Giderme (de-icing) Sistemleri

Buzlanma hava araçları için en büyük tehlikelerden birisidir. Geçmişte ve günümüzde buzlanmadan dolayı pek çok kaza gerçekleşmiştir. Uçaklarda bulunan buz önleme sistemleri, günümüzde bazı helikopterlerde de bulunmaktadır.

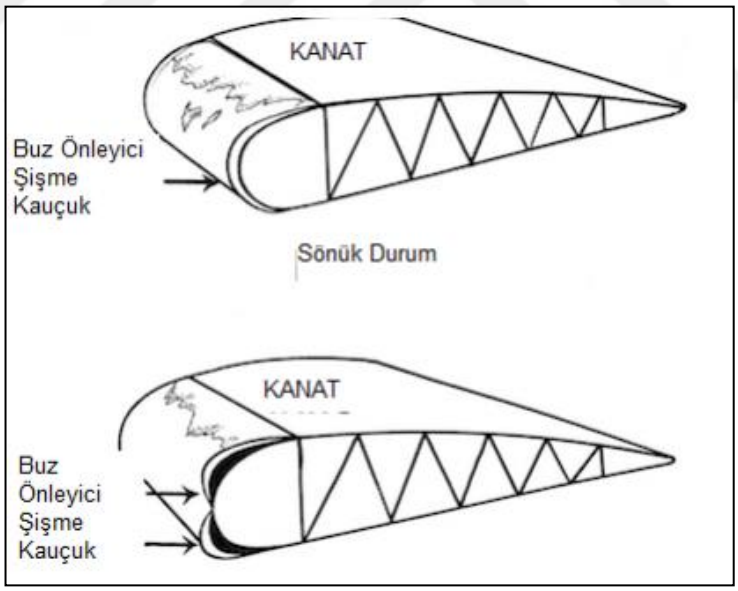
Buzdan koruma sistemleri; hava araçlarını hem yerde hem havada buzlanmadan koruma amacıyla kullanılmaktadır. Buz önleme sistemleri (ing. anti-icing) ve buz giderme sistemleri (ing. de-icing) olmak üzere iki başlık altında incelenir. Buz giderme sistemleri genellikle buzlanma koşullarıyla karşılaşıldıktan sonra çalışan bir sistemdir. Buzla kaplanmış yüzeydeki buzu gidermeyi amaçlar. Buz önleme sistemleri ise buzlanmaya karşı koruma sağlar. Bu nedenle ya buzlanma koşullarına girmeden hemen önce ya da hemen sonra kullanılır (Mingione, 1997).

3.7.1. Buz önleme sistemleri (anti-icing)

Buz önleme sistemleri uçak için etkili bir koruma sağlarken kullanıldıkları süre içerisinde oldukça çok enerji tüketmektedirler (Çoban, 2018). Uçaklarda buz oluşumunu engellemek için birkaç yöntem mevcuttur. Bu yöntemlerden en önemlisi motor tahliye havasının uçakta motor kaportaları ve kanat ön kenarları gibi geniş yüzeyde oluşabilecek buzlanmayı önleme amaçlı kullanılmasıdır. Ancak bu yöntemin dezavantajlarından biri uçağın itme miktarını azaltıp performansını düşürmesidir (Anonim, 2015). Kullanılan yöntemlerden bir diğeri ise suyun donma noktasını düşürücü akışkanların kullanılmasıdır. Bu yöntem temelde buz önleme için geliştirilmiş olsa da buz giderme sistemi olarak da kullanılabilir. Mevcut sistemlerde glikol bazlı bir sıvı kullanılır. Bu sıvı korunacak yüzeylere püskürtülerek suyun donma noktası düşürülerek buzlanma olayı önlenmektedir. Ancak akışkan tankı uçağın faydalı yükünü azaltır ve akışkan tedariğini sınırlandırır (Boduroğlu, 2014). Uçaklarda buz önleme amacıyla kullanılan bir diğer yöntem ise elektrikli buz önlemedir. Elektrik sistemleri normalde antenler, statik portlar, hava sıcaklığı probları, pitot tüpleri ve ön camlar gibi daha küçük alanlar için kullanılır (Anonim, 2015). Geniş yüzeylerde kullanılması yüksek güç tüketimine neden olduğu için tercih edilmez (Fenar, 2016).

3.7.2. Buz giderme sistemleri (de-icing)

Buz giderme sistemleri buzlanma koşulları ile karşılaşılınca çalıştırılır. Buz önleme sistemlerinin bazıları buz giderme sistemi olarak da kullanılır. Buzlanma gerçekleştikten sonra da suyun donma derecesini düşürücü sıvılar kullanılabilir ya da uçak yüzeyine sıcak hava uygulanabilir (Çoban, 2018). Buz gidermede en etkili yöntemlerden biri pnömatik bot kullanmaktır. Pnömatik botlar kauçuk tüplerden oluşur (Boduroğlu, 2014). Kanatların ön kenarları ve yatay ve dikey dengeleyiciler gibi kritik uçak yüzeylerine yapıştırılmış kauçuk tüplerin şişirilip oluşan buzları kırması mantığı ile çalışır (Mingione, 1997). Sistem çalışmadığı durumlarda hava akışının kesintiye uğramasını önlemek için bir vakum pompası tarafından sağlanan emme ile tüplerdeki hava emilir (Boduroğlu, 2014). Buz parçacıkları hava akışı ile kanattan temizlenir. Buz sistem sadece buzlanmayı gidermek için kullanılabilir (Mingione, 1997). Şekil 3.17'de pnömatik tüplerin aktif şekli ile normal şekli verilmiştir.



Şekil 3.17. Pnömatik botların çalışma mantığı (Boduroğlu, 2014)

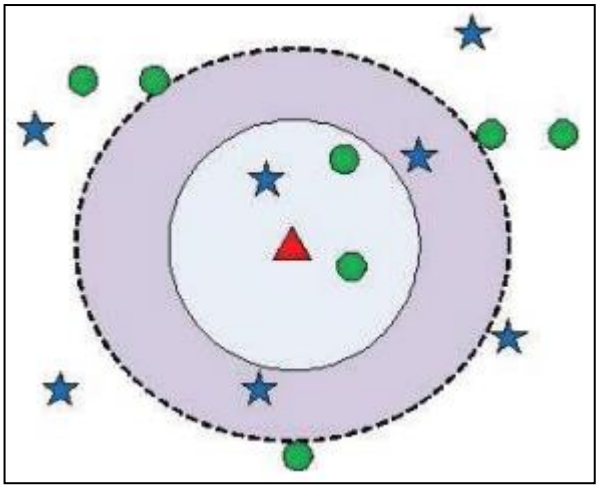
3.8. Yapay Zekâ Algoritmaları

Yapay zekâ; insana ait olan çözüm yolu bulma, anlama, bir anlam çıkartma, genelleme ve geçmişteki deneyimlerden öğrenme gibi özelliklerin bilgisayara veya bilgisayar destekli bir makineye kazandırılma çabasıdır (Öztürk ve Şahin, 2018). Bu amacı

gerçekleştirmek için pek çok algoritma literatüre kazandırılmıştır. Bunlardan bazıları tez kapsamında incelenip, uygulanacaktır.

3.8.1. KNN algoritması (k nearest neighbor)

KNN algoritması ilk olarak 1950'li yıllarda uygulanmıştır. Hem sınıflama hem regresyon için kullanılabilen denetimli bir algoritmadır. Diğer bir ifadeyle sınıfı bilinmeyen ağa yeni olarak dahil edilmiş bir veri, önce eğitim setindeki diğer veriler ile karşılaştırılır ve bir uzaklık ölçümü yapılır ardından hesaplanan uzaklığa göre henüz bir sınıfa atanamamış veriye en optimal sınıf bulunur ve o sınıfa veri dahil edilir. KNN de en önemli nokta uygun k değeri bulmaktır (Dilki ve Başar, 2020). Şekil 3.18'de bulunan KNN görseliyle örneklemek gerekirse, kırmızı şeklin hangi sınıfa ait olduğunu belirlemeye çalıştığımızı varsayalım. K komşu değeri üç seçilirse şeklin civarındaki en yakın üç komşusunun ikisinin yeşil birinin mavi olduğu görülecektir. Yeni veri yeşil olan sınıfa dahil edilir. K=5 seçildiği düşünülürse, en yakın beş komşunun üçü mavi, ikisi yeşildir. Bu durumda veri mavi sınıfa dahil edilir. Örnekten de anlaşılacağı gibi k değerinin seçimi oldukça önemlidir (Ayan, 2019).



Şekil 3.18. KNN sınıflandırma örneği (Ayan, 2019)

En yakın komşuyu bulmak için mesafe hesaplarında farklı yöntemler kullanılır. En sık kullanılan uzaklık ölçütü Euclidean'dır. Euclidean uzaklığı dışında Manhattan, Minkowski, Chebyshev gibi farklı uzaklık hesaplama ölçütleri de literatürde mevcuttur (Dilki ve Başar, 2020).

$$d_{öklid}(x,y) = \sqrt{\sum_{i=1}^{n}(x_i - y_i)^2} \quad (3.1)$$

$$d_{manhattan}(x,y) = \sum_{i=1}^{n}|x_i - y_i| \quad (3.2)$$

$$d_{chebyshev}(x,y) = max_i(|x_i - y_i|) \quad (3.3)$$

$$d_{minkovski}(x,y) = \sqrt[x]{\sum_{i=1}^{n}(x_i - y_i)^x} \quad (3.4)$$

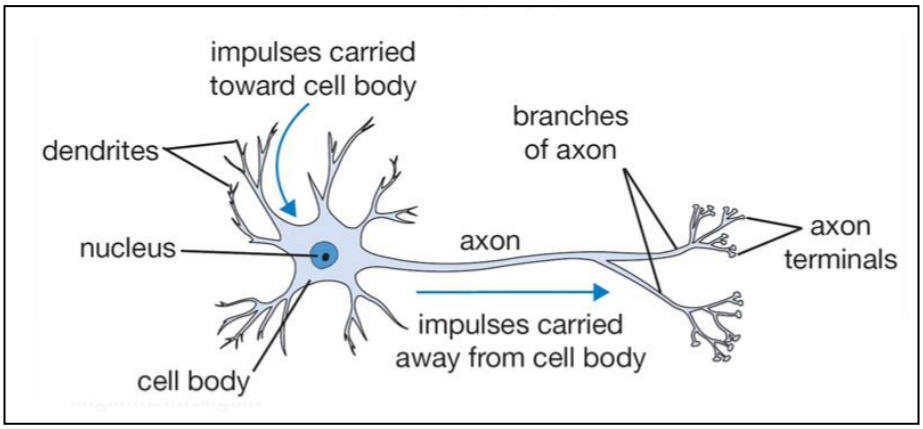
i = 1,2,3,4, …, n iken $x = (x1, x2, \dots, xn)$ ve $y = (y1, y2, \dots, yn)$ x ve y eksenlerinde noktalar olmak üzere aradaki uzaklık d ile gösterilirse; denklem 3.1 Öklid uzaklığını, denklem 3.2, Manhattan Uzaklığını, denklem 3.3 Chebyshev Uzaklığını, denklem 3.4 ise Minkowski Uzaklığına ait matematiksel eşitlikler verilmiştir (Kaya vd., 2018; Dilki ve Başar, 2020).

3.8.2. Yapay sinir ağları (artificial neural network)

Yapay sinir ağları (YSA), insan sinir sisteminin kendi kendine öğrenmesi, dış dünyayı anlaması, değerlendirmesi örnek alınarak tasarlanmış bir yapay zekâ mimarisidir. Bilim insanları insanda olan bu özelliklerin YSA vasıtasıyla makinelere kazandırılmasını amaçlamaktadırlar. İnsan sinir sisteminin yapısı ve bu yapıların YSA' daki karşılıkları Çizelge 3.3'de verilmiştir (Uslu, 2020). İnsan sinir hücresi ise Şekil 3.19'da gösterilmiştir.

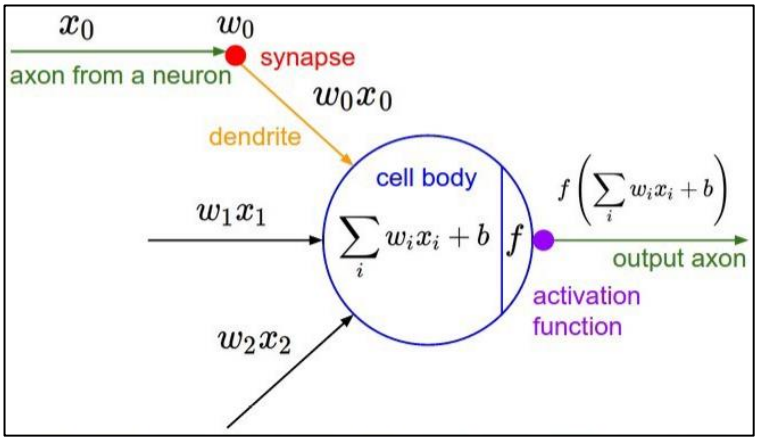
Çizelge 3.3. İnsan sinir sisteminin YSA'daki karşılıkları (Uslu, 2020)

İnsan Sinir Sistemi	**Yapay Sinir Ağı**
Nöron	İşlem Elemanı
Dentrit	Toplama Fonksiyonu
Hücre Gövdesi	Aktivasyon Fonksiyonu
Akson	Eleman Çıkışı
Sinaps	Ağırlıklar



Şekil 3.19. İnsandaki bir sinir hücresinin gösterimi (Kizrak, 2020)

Şekil 3.19'da verilen Akson (ing. axon), çıkış darbelerinin üretildiği elektriksel aktif gövdedir. Gövde üzerinde iletim tek yönlü olup sistemin çıkışıdır. Dentritler (ing. dendrites) ise elektriksel anlamda pasif olan kollardır ve diğer hücrelerden gelen işaretleri toplar. Sistemin girişidir. Sinaps (ing. synapse), bir hücrenin aksonunun diğer hücrelerin dentritlerle olan bağlantısını sağlamaktadır. Miyelin Tabaka (ing. myelin sheath), yayılma hızına etki eden yalıtım malzemesidir. Çekirdek (ing. nucleus) ise Akson boyunca işaretlerin periyodik olarak yeniden üretilmesini sağlar (Kizrak, 2020). İnsan sinir sistemi Şekil 3.20'de verildiği gibi matematiksel olarak modellenmesi ile YSA'nın yapısı ortaya çıkmaktadır.



Şekil 3.20. İnsan sinir sisteminin matematiksel modeli (Kizrak, 2020)

Perseptron (ing. perceptron), yapay sinir ağının en küçük parçası olarak bilinir. Aşağıdaki gibi lineer bir fonksiyonla ifade edilmektedir ve 1957 yılında Frank Rosenblatt tarafından tanımlanmıştır (Kizrak, 2020).

$$y = w * x + b \quad (3.5)$$

Denklemde y, girdiye ait skor değerini x, girdiyi ve b ise bias değerini ifade etmektedir. Maksimum performans için denklem 3.5 ile verilen y skor değeri en iyi değer yapılmalıdır. Bunun için w ve b parametreleri en iyi sonucu verecek şekilde ayarlanmalıdır (Kizrak, 2020). YSA doğrusal olmama, paralel çalışma, eksik verilerle çalışma, çok sayıda değişken ve parametre kullanma gibi özelliklere sahiptir. Ayrıca uyarlanabilir, öğrenebilir ve genelleme yapılabilir (Uslu, 2020). Bu özelliklerinden dolayı kontrol alanında da uygulamaları mevcuttur (Doğmuş, 2013; Bayram vd., 2013; Saenz – Aguirre vd., 2019; Ali vd., 2019).

YSA ile kontrol metodunun avantajları aşağıda maddeler halinde verilmiştir.

- YSA'lar birçok hücreden meydana gelir ve bu hücreler eş zamanlı olarak çalışarak karmaşık işlevleri yerine getirir. Diğer bir ifadeyle karmaşık işlevler birçok hücrenin eş zamanlı çalışması ile meydana getirilir. Süreç içerisinde bu hücrelerden herhangi biri işlevini yitirse dahi sistem güvenli bir şekilde çalışmasına devam edebilmektedir (Çayıroğlu, 2020).

- Eğitim esnasında kullanılan nümerik bilgilerden, problemin genel özellikleri elde edilir ve böylelikle eğitim sırasında kullanılmayan girdiler için de anlamlı yanıtlar üretilebilir (Çayıroğlu, 2020).

- Sadece lineer problemlerin değil nonlineer problemlerinde çözümününde de kullanılabilmektedir (Behrooz vd., 2018).

- Olayları öğrenerek benzer olaylar karşısında mantıklı karar verebilirler (Çayıroğlu, 2020).

- Bilgiler ağın tamamında saklanır. Hücrelerden bazılarının işlevini yitirmesi, anlamlı bilginin kaybolmasına neden olmaz (Çayıroğlu, 2020).

- YSA yapısı sayesinde daha önce görülmemiş örnekler hakkında bilgi üretebilirler (Çayıroğlu, 2020).

- Kendi kendine öğrenebilme ve organize etme yetenekleri vardır. YSA kullanılan uygulamalar kendi kendini eğitebilir (Çayıroğlu, 2020).

- YSA kullanılan uygulamalarda eksik bilgi ile çalışma söz konusu olabilir. Oluşacak performans kaybı eksik bilginin önemine bağlıdır (Çayıroğlu, 2020).

- Hata toleransına sahiptirler. YSA yapısının bazı hücreleri bozulsa bile hatalara karşı toleranslı çalışabilir (Çayıroğlu, 2020).

- YSA yapısı dereceli bozulma gösterir. Kurulan yapı zaman içerisinde yavaş ve göreceli bir bozulmaya uğrar (Çayıroğlu, 2020).

- Matematiksel olmayan modeller için kullanışlı yöntemlerdir (Behrooz vd., 2018).

YSA ile kontrol metodunun dezavantajları aşağıda maddeler halinde verilmiştir.

- Kurulan YSA yapısı için YSA yapısının belirlenmesinde belli bir kural yoktur. Uygun ağ yapısı deneyim ve deneme yanılma yolu ile belirlenmektedir (Çayıroğlu, 2020).

- YSA yapısının ihtiyaca cevap vermesi için eğitilmesi gerekir (Behrooz vd., 2018).

- Eğitim için fazla zaman harcanır (Behrooz vd., 2018).

- İyi bir tahmin için fazla miktarda veri gerekir (Behrooz vd., 2018).

- YSA'nın verdiği kararın neden ve nasıl olduğuna ilişkin bir açıklama yapamaması yönteme olan güveni azaltır (Çayıroğlu, 2020).

3.8.3. Destek vektör makineleri (support vector machine)

Destek vektör makineleri (ing. support vector machine - SVM) sınıflandırma işlemlerinde sıklıkla kullanılan yapay zekâ algoritmalarından biridir. 1960'lı yıllların sonunda Vladimir Vapnik ve Alexey Chervonenkis tarafından geliştirilmiştir (Coşkun,

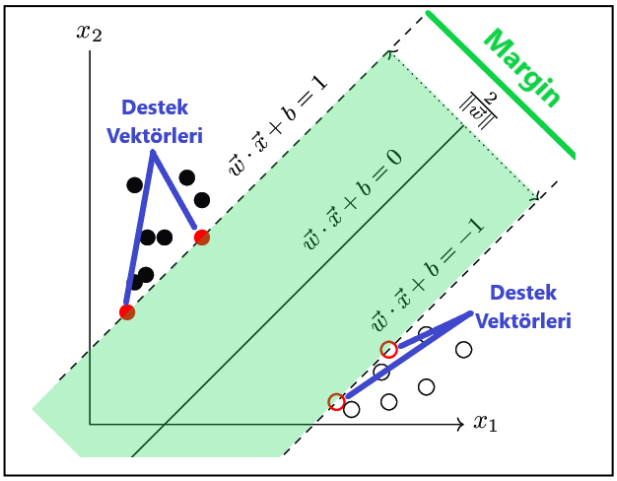
2016). Doğrusal ve doğrusal olmayan verisetlerini sınıflandırmak için kullanılmaktadır. Verilerin doğrusal olarak ayrılıp ayrılmamasına göre farklı yöntemleri içerir. Veriler doğrusal olarak tam ayrıştırılabiliyorsa veri sınıflarının belirlenmesinde hiper düzlem kullanılır, veriler doğrusal olarak ayrıştırılamıyorsa çekirdek fonksiyonları kullanılmaktadır (Metlek ve Kayaalp, 2020).

3.8.3.1. Doğrusal destek vektör makineleri

Doğrusal destek vektör makineleri, verileri doğrusal olarak ayrılabilen ve verileri doğrusal olarak ayrılamayan olmak üzere iki grupta ele alınabilir. Doğrusal olarak ayrılabilen verilere uygulanan destek vektör makineleri verisetlerindeki verilerin,

$$(x_1, y_1), (x_2, y_2), (x_3, y_3), \ldots, (x_m, y_m) \in R^n \text{ x } \{-1,1\} \quad (3.6)$$

olarak dağıldığı varsayılsın. Burada x_i, n boyutlu özellikler vektörünü, y_i ise etiketleri temsil eder. {-1,1} ifadesi ise +1 ile etiketlenmiş olan verinin bu sınıfa ait olduğunu, -1 ile etiketlenmiş olan verinin ise -1 sınıfına ait olduğunun bilgisini verir. Burada veri doğrusal olarak ayrılabildiğinden bir düzlem yardımıyla veri kümesinin aynı etiketlere sahip veriler birarada kalacak şekilde ayrıştırılması amaçlanır (Erdem, 2014). Şekil 3.21'de verilerin düzlem ise sınıflara ayrılma işlemi görselleştirilmiştir. Şekilde siyah olan noktalar bir sınıfı, beyaz olan noktalar ise diğer sınıfı simgeler, iki sınıfı birbirinden ayıran en doğru hiper düzlemi çizmek amaçlanır. Yeşil bölge marjin olarak adlandırılır. Marjin bölgesi ne kadar geniş olursa veri o kadar iyi ayrıştırılır (Akça, 2020). Hiper düzleme en yakın olan noktalar ise destek vektörleri olarak isimlendirilir.



Şekil 3.21. Doğrusal olarak dağılan verilerin hiper düzlemle ayrılması (Akça, 2020)

Şekil 3.21'de verilen hiper düzlem;

$$f(x) = w^T.x + b = 0 \tag{3.7}$$

Fonksiyonu ile tanımlanır. Burada w hiper düzlemin normalini ve ağırlık vektörünü temsil eder, b hiper düzlemin konumunu belirleyen doğrusal sapma değeridir, x ise hiper düzlem üzerinde olan herhangi bir noktadır. Marjini en büyük tutacak iki düzlemin fonksiyonları ise denklem 3.8 ve 3.9'da verilmiştir (Erdem, 2014).

$$w.x_1 + b = 1 \tag{3.8}$$

$$w.x_2 + b = -1 \tag{3.9}$$

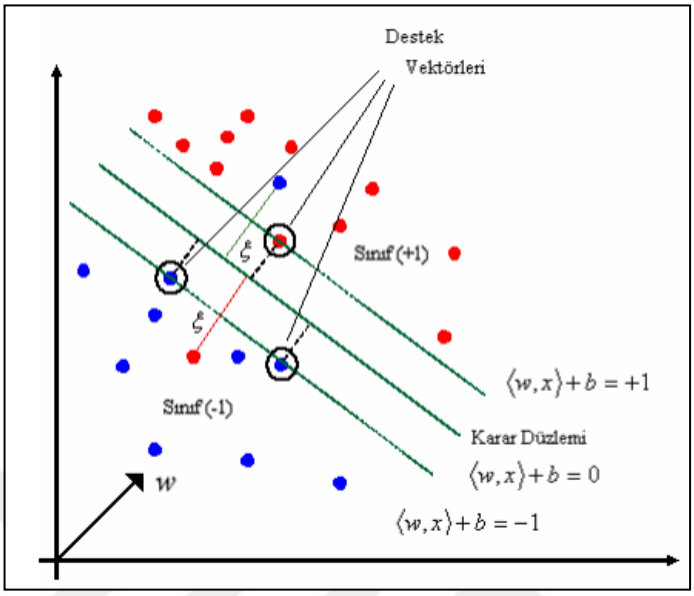
Denklem 3.8'den denklem 3.9'un çıkarılmasıyla marjin olarak adlandırılan maksimum aralık elde edilir. Denklem 3.10'da marjin olarak adlandırılan mesafeye ait matematiksel eşitlik verilmiştir (Erdem, 2014).

$$m = \frac{2}{\|w\|} \tag{3.10}$$

Veri setindeki veriler doğrusal olarak tamamen ayrılamıyorsa, ayrım için pozitif zayıflık değişkenlerinden faydalanılır. $\xi, i = 1,2,\dots,l$ olmak üzere destek vektör düzlemleri denklem 3.11 ve denklem 3.12'de verilen matematiksel eşitlikler ile ifade edilmektedir. Şekil 3.22'de verilerin doğrusal ayrılmama durumu görselleştirilmiştir (Eray, 2008).

$$y_i = +1\ için, w^T.x_i + b \geq +1 - \xi_i \quad \xi \geq 0 \tag{3.11}$$

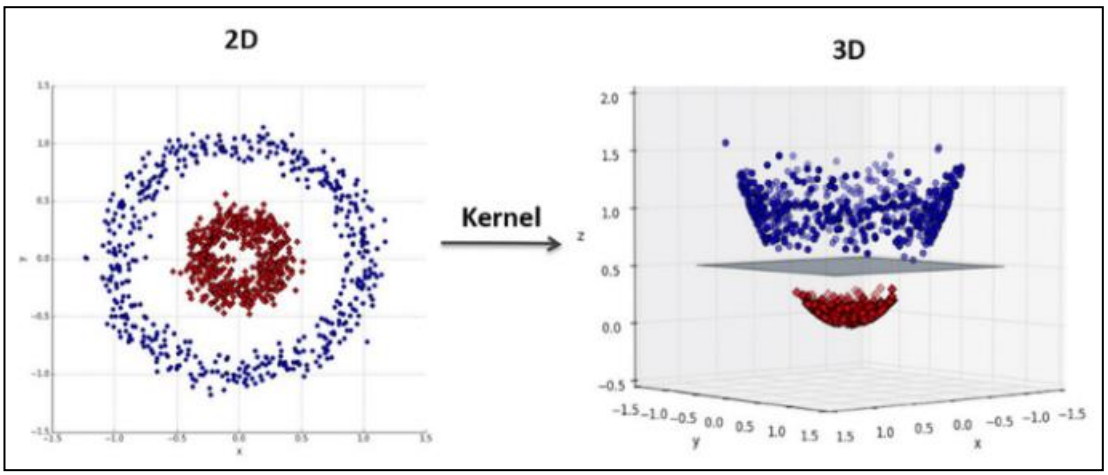
$$y_i = -1\ için, w^T.x_i + b \leq -1 + \xi_i \quad \xi \geq 0 \tag{3.12}$$



Şekil 3.22. Verilerin doğrusal olarak ayrılamadığı durumda DVM (Eray, 2008)

3.8.3.2. Doğrusal olmayan destek vektör makineleri

Doğrusal olmayan bir veri kümesinde destek vektör makineleri doğrusal olarak ayrılamazlar ve çekirdek numarası diye adlandırılan 'kernel trickler' kullanılır (Ulgen, 2017). Bu yöntem doğrusal olmayan verilerde doğruluğu artırmaktadır (Ulgen, 2017). Doğrusal olmayan veri setine ait görsel Şekil 3.23'de verilmiştir (Akça, 2020).



Şekil 3.23. Doğrusal olmayan veri seti a) İki boyutta dağılım b) Üç boyutta dağılım (Akça, 2020)

Şekilden görüldüğü gibi iki boyutlu dağılım bir doğru ile sınıflandırılamaz. Bunun için çekirdek fonksiyonları kullanılarak üç boyutta düzlem ile sınıflandırılabilir (Akça, 2020). Verilerin ayrılmasında önemli olan karar fonksiyonu denklem 3.13'te verilmiştir.

$$f(x) = \text{sign}\left(\sum_{i=1}^{N} \alpha_i y_i \phi(x)\phi(x_i) + b\right) \quad (3.13)$$

Veriler doğrusal olarak ayırt edilemediğinde yukarıdaki denklemdeki $\phi(x)\phi(x_i)$ skaler çarpımının yerine,

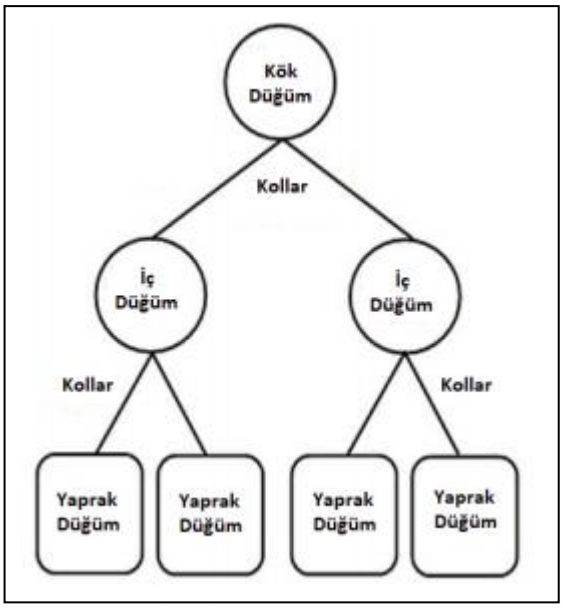
$$K\ (x_i, x_j)\ =\ \phi(x)\phi(x_i) \quad (3.14)$$

şeklinde verilen kernel fonksiyonları kullanılarak dönüşümler gerçekleştirilir (Güneren, 2015). α burada dual değişkenleri, $\phi(x_i)$ destek vektörleri, $\phi(x)$ özellik uzayındaki örüntü vektörünü ifade eder. En sık kullanılan kernel fonksiyonları denklem 3.15 ile denklem 3.18 arasında verilmiştir.

1. Doğrusal fonksiyon: $K\ (x_i, x_j)\ = (x_i^T x_j)$ (3.15)
2. Polinomiyal fonksiyon: $K\ (x_i, x_j)\ = (x_i x_j)^d$ (3.16)
3. Sigmoid fonksiyon: $K\ (x_i, x_j)\ = \tanh(k x_i x_j - \delta)$ (3.17)
4. Radyal tabanlı fonksiyon: $K\left(x_i, x_j\right) = \exp\left(-\gamma \left\| x_i - x_j \right\|^2\right), \gamma > 0$ (3.18)

3.8.4. Karar ağaçları (decision tree)

Sınıflandırma ve regresyon işlemlerinde sıklıkla kullanılan bir diğer yöntem karar ağaçlarıdır (Akça, 2020). Karar ağaçları, ağaç yapısı şeklinde oluşum göstermektedir. Kategorik ve nümerik verilerle çalışabilir ve kuralları basit olarak fade edilebilir (Akalın, 2020). Karar ağaçları köklerden, düğümlerden ve yapraklardan oluşur. Karar ağaçlarının ilk hücresini kök hücresi oluşturur. Gözlemler kökteki "evet" ya da "hayır" koşuluna göre sınıflandırılır. Daha sonra kök hücrelerinin altında düğümler yer alır. Gözlemler düğümler yardımıyla sınıflandırılır. Karar ağaçları algoritmasının en altında ise yapraklar bulunur. Yapraklar sınıflandırma sonucunu verir (Akça, 2020). Şekil 3.24'de karar ağaçlarının basitleştirilmiş görseli verilmiştir.



Şekil 3.24. Karar ağacı yapısı (Akça, 2020)

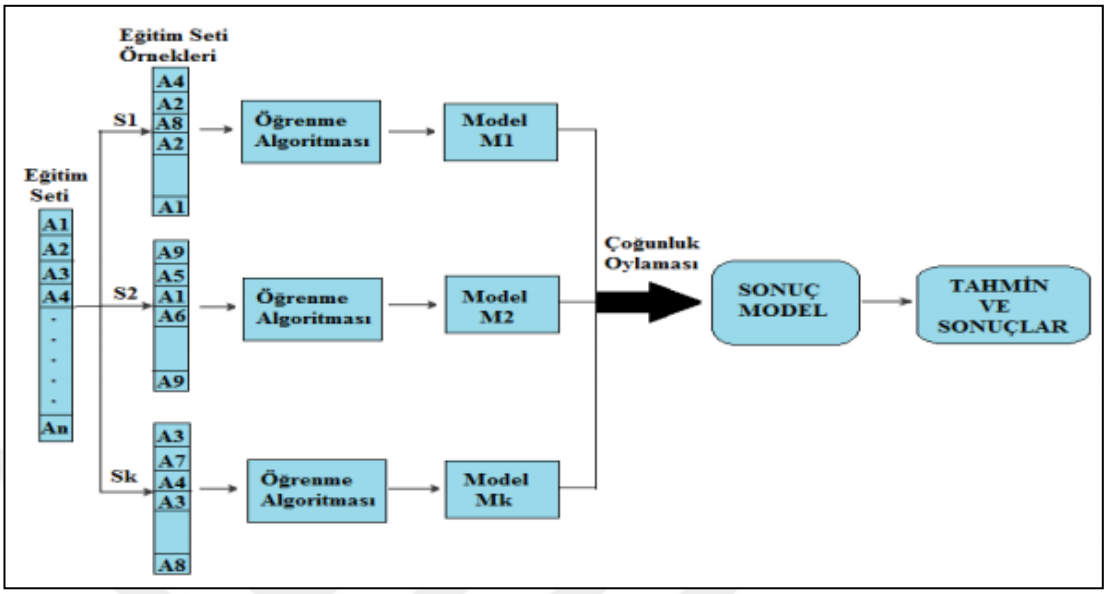
3.8.5. Ensemble yöntemler

Makine öğrenmesi yöntemleri içerisinde değerlendirilen ensemble yöntemler etkili bir öğrenme algoritmasına sahip olan yöntemlerdendir. Ensemble yöntemde tek bir model kullanılarak tahmin yapılmaz bunun yerine birden çok modelin birleştirilmesi ile tahmin işlemi gerçekleştirilir (Zhou, 2012; Tuğ Karoğlu, 2018). Ensemble yöntemlerde modelleri birleştirmede pek çok yol vardır. Tez çalışmasında torbalama (ing. bagging), artırma (ing. boosting) ve rastgele orman (ing. random forest) ensemble yöntemleri kullanılmıştır.

3.8.5.1. Torbalama algoritması

Breinman tarafından 1996 yılında önerilmiştir. Çalışma mantığı eğitim verisinin alt kümelere bölünmesiyle üretilmiş olan daha küçük verisetleri ile çalışmaktır. Burada eğitim verisinin farklı kombinasyonları üretilir ve birden fazla örneği oluşturulur. Bu algoritmada farklı eğitim setleri ile çalışılması başarılı sonuçlar elde edilmesini sağlar. Şekil 3.25'de yerine koyarak öğrenme topluluk modelinin çalışma mantığı görülmektedir. N adet eğitim setinden oluşan verisetinden alt veriseti oluşturulur. Yeni oluşturulan verisetleri de N örneğe sahiptir ancak rastgele seçimle eğitim setinin yerine konulmaktadır. Yani bazı örnekler bir oluşturulan bir alt verisetinin içinde yer almazken oluşturulan başka bir alt verisetinde birden fazla kez bulunabilir. Oluşturulan

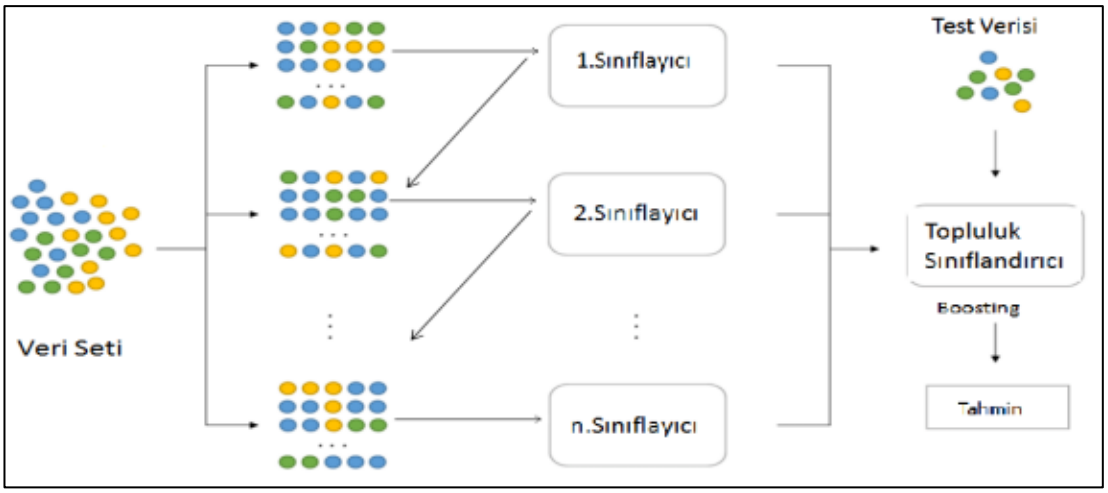
verisetleri eğitilerek bir sınıflandırıcı modeli oluşturulur. Sınıflandırma işlemi çoğunluk oylaması ile birleştirilerek sınıflandırma modeli oluşturulur (Güzel, 2018).



Şekil 3.25. Torbalama algoritması (Güzel, 2018)

3.8.5.2. Artırma algoritması

Artırma algoritması zayıf sınıflandırıcılardan güçlü sınıflandırıcılar elde etme mantığıyla çalışan topluluk sınıflandırıcı algoritmasıdır. Zayıf sınıflandırıcılar topluluğu çoğunluk oyu yöntemi kullanılarak birleştirilir (Kıvrak, 2021). 1996 yılında Robert Schapire ve Yoav Freund tarafından önerilen Adaboost algoritması boosting için örneklenecek olursa, burada ilk temel sınıflandırıcı eğitilir ve tahminler yapılarak yanlış sınıflandırılmış eğitimlerin ağırlıkları optimize edilmeye çalışılır. Bir sonraki aşamada ikinci temel sınıflandırıcıya verilerin ağırlıkları güçlendirilmiş olarak dâhil edilmektedir. Dizi mantığına göre bir çalışma söz konusudur. Bu şekilde işlemler son sınıflandırıcıya kadar devam eder. En son elde edilen başarı modelin başarısı olarak değerlendirilir. Şekil 3.26'da artırma algoritmasının çalışma mantığı görsel olarak verilmiştir (Gürmen, 2020).



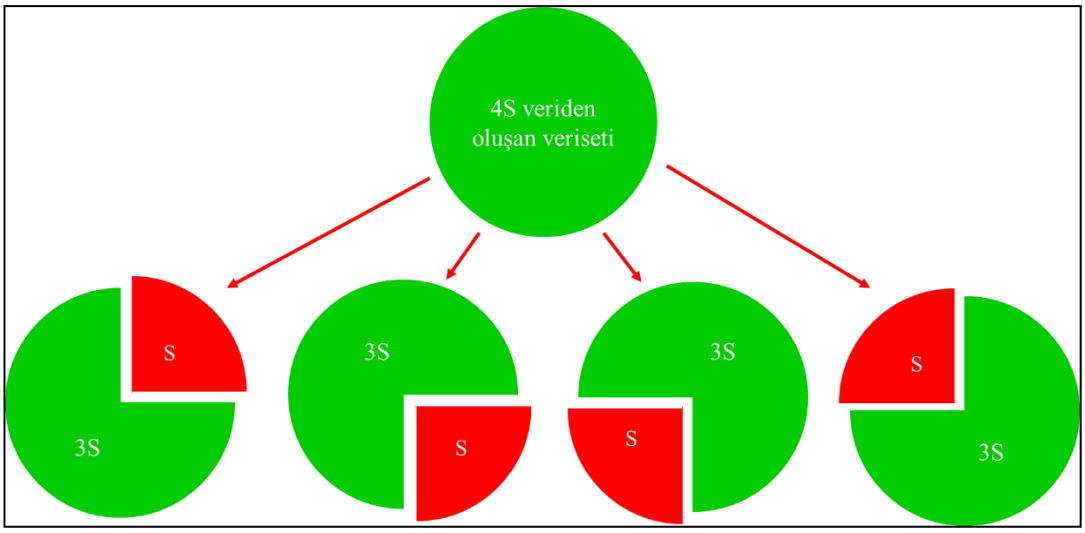
Şekil 3.26. Artırma algoritması çalışma şeması (Kıvrak, 2021)

3.8.5.3. Rastgele orman (random forest)

Rastgele orman içerisinde pek çok karar ağacını barındıran sınıflandırma ve regresyon algoritmalarından birisidir. 2001 yılında Breiman tarafından tanıtılmış bir modeldir (Breiman, 2001; Speiser vd., 2019). Rastgele orman algoritmasında veri setinden rassal olarak alt setler seçilir ve eğitilir. Alt setlerin eğitimi için karar ağaçları oluşturulur. Karar ağaçları veri setlerine göre tahminlerde bulunur ve tahminlerin ortalaması problemin sınıflandırılmasında etkili olmaktadır. Bu sebepten dolayı rastgele orman genellikle tek bir karar ağacına göre daha doğru sonuçlar vermektedir (Simsek, 2018; Speiser vd., 2019).

3.8.6. Yapay zekâ algoritmalarında kullanılan k kat çapraz doğrulama yöntemi

Sınıflandırma modellerini değerlendirmek için verisetinin bölünüp ağa verilmesi tekniğidir. K kat çapraz doğrulama kullanılan modellerde veri setinde bulunan her bir eleman eğitim ve test işlemleri için kullanılmış olmaktadır (Aydın vd., 2018). Örneklemek gerekirse; Şekil 3.27'deki gibi verisetinin 4S tane elemanı olduğu varsayılsın. K kat çapraz doğrulama değeri 4 seçilerek veriseti 4 parçaya bölünmektedir. 4 parçaya bölünen verisetinin herbir farklı S parçası test verisi olarak geri kalan 3S parçaları ise eğitim verisi olarak dört farklı döngüde uygulanır. 4 döngü sonucunda döngü sonuçlarına göre sistemin doğruluğu hesaplanmaktadır.



Şekil 3.27. Çapraz doğrulama

3.9. Performans Değerlendirme Ölçütleri

Eğitilen modellerin değerlendirilmesinde performans değerlendirme metrikleri kullanılmaktadır. Performans değerlendirme metrikleri modellerin değerlendirmelerin sonuçlarına göre karşılaştırılmasını sağlar. Genellikle ikili sınıflandırma için oluşturulan hata matrisinin kullanılmasıyla elde edilir. Çizelge 3.4'de hata matrisi verilmiştir (Yavanoğlu, 2017). Çizelge 3.4'teki tabloda;

- Doğru pozitif; pozitif sınıfına ait doğru etiketlenmiş verileri,
- Doğru negatif; negatif sınıfına ait doğru etiketlenmiş verileri,
- Yanlış pozitif; negatif sınıfına ait yanlış etiketlenmiş verileri,
- Yanlış negatif; pozitif sınıfına ait yanlış etiketlenmiş verileri,

temsil etmektedir.

Çizelge 3.4. İkili sınıftan oluşan hata matrisi (Yavanoğlu, 2017)

		Tahmin Sınıfı	
		Pozitif	Negatif
Gerçek Sınıf	Pozitif	Doğru Pozitif (DP)	Yanlış Negatif (YN)
	Negatif	Yanlış Pozitif (YP)	Doğru Negatif (DN)

Sınıflandırma performanslarını değerlendirme için ise kullanılan değerlendirme metrikleri Çizelge 3.5'de verilmiştir (Yavanoğlu, 2017).

Çizelge 3.5. Performans değerlendirme metrikleri (Yavanoğlu, 2017)

Performans Değerlendirme Metriği	Formül	Tanım
Doğruluk (İng. Accuracy)	$\frac{DP + DN}{DP + YP + DN + YN}$	Pozitif ve negatif sınıflarına ait olan doğru sınıflandırılmış verilerin tüm verilere oranıdır.
Kesinlik (İng. Recall)	$\frac{DP}{DP + YN}$	Pozitif sınıfına ait olan doğru sınıflandırılmış verilerin pozitif sınıfına ait tüm verilere oranıdır.
Duyarlılık (İng. Precision)	$\frac{DP}{DP + YP}$	Pozitif sınıfına ait olan doğru sınıflandırılmış verilerin pozitif olarak etiketlenmiş tüm verilere oranıdır.
F Ölçütü (İng. F-Score)	$\frac{2 * Duyarlılık * Kesinlik}{Duyarlılık + Kesinlik}$	Performans değerlenirme ölçütlerinden duyarlılık ve kesinliği harmonik ortalamasıdır.

3.10. Çalışmada Kullanılan Yöntem

Tezin bu bölümünde çalışma için kullanılan yöntemler hakkında detaylı bilgiler verilecektir. Tezde ilk olarak veri seti oluşturularak daha sonra oluşturulan veri seti üzerinde farklı yapay zekâ yöntemleri uygulanmış ve hava araçlarında buzlanma risk derecesini en doğru bir şekilde bulan model belirlenmiştir. En doğru sonucu veren model simulinkte modellenmiş ve waijung blokset yardımıyla STM32F4 discovery kontrol kartına gömülmüştür. Verisetinin oluşturulması, kullanılan yapay zekâ metotları ve kurulan simulink şeması aşağıda alt başlıklar halinde verilmiştir.

3.10.1. Verisetinin oluşturulması

Tez çalışmasında buzlanma derecesi veri seti Gliwa ve arkadaşlarının Polonya Hava Kuvvetlerinin havacılık öğrencileri için kullanmış oldukları deneysel veriler temel alınarak literatür çalışmaları da göz önünde bulundurularak oluşturulmuştur. Veri seti

dört giriş, dört çıkışlıdır. Buzlanmaya etki eden en önemli parametreler; sıcaklık ve nemdir. Bu çalışmada sıcaklık, nem, hava aracı sıcaklığı ve yağış bilgisi göz önünde bulundurularak buzlanma derecesi tahmini yapılmıştır. Oluşturulan veri seti 3025 adet veri içermektedir. Dört giriş değeri için, çıkış bilgisinin buzlanma yok (0), izle (1), orta (2) ve kritik (3) olmak üzere dört sınıfa ait buzlanma risk derecesinin tahmini yapılmıştır. Çizelge 3.6'da veri setinin örnek bir bölümü verilmiştir.

Çizelge 3.6. Çalışmada kullanılan veri seti örneği

Giriş Parametreleri				**Çıkış Parametresi**
Yağış(mm)	**Hava Aracı Sıcaklığı (C^o)**	**Nem (gr/m^3)**	**Hava Sıcaklığı (C^o)**	**Buzlanma Derecesi**
-0,2	-29	-0,8	-55	0
-0,5	-28	-0,1	0	0
-0,8	-25	0,4	-50	2
-0,8	-15	0	20	1
-0,8	-30	0,5	-15	2
-0,1	-17	-0,5	-40	0
-0,5	-11	-0,2	-15	2
-0,2	-18	4,5	-2	3
-0,1	-25	5	15	1
-0,2	0	1,3	-2	3
1	48	1,1	-18	2
1,2	10	4	4	3
. . .	. . .	. . .	. . .	. . .
2,5	-23	0,9	-5	3
2,5	5	0	-55	2
2,5	2	4,8	-55	2
3,3	-14	1,3	10	1

3.10.2. Yapay zekâ algoritmaları

Tez çalışmasında buzlanma risk derecesi tahmini için yedi farklı yapay zekâ algoritması kullanılmıştır. Tez çalışmasında kullanılan yapay zekâ algoritmaları alt başlıklar şeklinde adım adım açıklanmıştır.

3.10.2.1. Yapay sinir ağları

Buzlanma risk derecesi tahmininde ilk olarak yapay sinir ağları kullanılmıştır. Yapay sinir ağı modeli aşağıdaki adımlar izlenerek kurulmuştur.

1. Veri seti matlaba tanıtılmıştır.
2. Giriş ve çıkışlar belirtilmiştir.
3. K kat çapraz doğrulama 10 olarak verilmiştir.
4. Farklı katman sayıları ve nöron sayıları denenerek en doğru sınıflandırma sonucu belirlenmeye çalışılmıştır.
5. Modelin ağırlık ve bias değerleri verilmiştir.
6. Performans değerlendirme metrikleri ile sonuçlar değerlendirilmiştir.
7. Doğruluk matrisi çizdirilmiştir.

3.10.2.2. KNN komşu algoritması

Buzlanma derecesi tahmininde ikinci olarak KNN algoritması uygulanmıştır. Sınıflandırma işleminde aşağıdaki adımlar izlenmiştir.

1. Veri seti matlaba tanıtılmıştır.
2. Giriş ve çıkışlar belirtilmiştir.
3. KNN için farklı k komşu değerleri kullanılarak komşu sayısı belirlenmiştir.
4. K kat çapraz doğrulama yapılmıştır bunun için “for” döngüsü oluşturulmuştur.
5. Model her k kat çapraz doğrulama değeri için eğitilmiştir.
6. Performans değerlendirme metrikleri ile sonuçlar değerlendirilmiştir.
7. Doğruluk matrisi çizdirilmiştir.

3.10.2.3. Destek vektör makineleri

Buzlanma derecesi tahmininde üçüncü olarak destek vektör makineleri uygulanmıştır. Sınıflandırma işleminde aşağıdaki adımlar izlenmiştir.

1. Veri seti matlaba tanıtılmıştır.
2. Giriş ve çıkışlar belirtilmiştir.
3. K kat çapraz doğrulama yapılmıştır bunun için “for” döngüsü oluşturulmuştur.
4. Model her k kat çapraz doğrulama değeri için eğitilmiştir, eğitim farklı kernel yapıları kullanılarak en doğru sonuç bulunmaya çalışılmıştır.
5. Performans değerlendirme metrikleri ile sonuçlar değerlendirilmiştir
6. Doğruluk matrisi çizdirilmiştir.

3.10.2.4. Karar ağaçları

Buzlanma derecesi tahmininde dördüncü yöntem olarak karar ağaçları uygulanmıştır. Sınıflandırma işleminde aşağıdaki adımlar izlenmiştir.

1. Veri seti matlaba tanıtılmıştır.
2. Giriş ve çıkışlar belirtilmiştir.
3. K kat çapraz doğrulama yapılmıştır bunun için “for” döngüsü oluşturulmuştur.
4. Model her k kat çapraz doğrulama değeri için eğitilmiştir ve doğruluk hesaplanmıştır.
5. Performans değerlendirme metrikleri ile sonuçlar değerlendirilmiştir.
6. Doğruluk matrisi çizdirilmiştir.

3.10.2.5. Ensemble modellerden rastgele orman algoritması

Buzlanma derecesi tahmininde denenen yöntemlerden bir diğeri rastgele orman algoritmasıdır. Sınıflandırma işleminde aşağıdaki adımlar izlenmiştir.

1. Veri seti matlaba tanıtılmıştır.
2. Giriş ve çıkışlar belirtilmiştir.
3. Algoritma için karar ağacı sayısı belirlenmiştir. Farklı karar ağacı sayıları kullanılarak sistemin doğruluğu artırılmaya çalışılmıştır.
4. K kat çapraz doğrulama yapılmıştır bunun için “for” döngüsü oluşturulmuştur.
5. Model her k kat çapraz doğrulama değeri için eğitilmiştir.
6. Performans değerlendirme metrikleriyle sonuçlar değerlendirilmiştir.
7. Doğruluk matrisi çizdirilmiştir.

3.10.2.6. Ensemble modellerden torbalama algoritması

Genel olarak sınıflandırma ağaçlarından iyi sonuçlar elde edildiği için doğruluk yükseltmek adına buzlanma derecesi tahmininde torbalama algoritmasıda uygulanmıştır. Sınıflandırma işleminde aşağıdaki adımlar izlenmiştir.

1. Veri seti matlaba tanıtılmıştır.
2. Giriş ve çıkışlar belirtilmiştir.
3. K kat çapraz doğrulama yapılmıştır bunun için "for" döngüsü oluşturulmuştur.
4. Model her k kat çapraz doğrulama değeri için eğitilmiştir.
5. Performans değerlendirme metrikleriyle sonuçlar değerlendirilmiştir.
6. Doğruluk matrisi çizdirilmiştir.

3.10.2.7. Ensemble modellerden artırma algoritması

Buzlanma derecesi tahmininde son olarak artırma algoritması kullanılmıştır. Sınıflandırma işleminde aşağıdaki adımlar izlenmiştir.

1. Veri seti matlaba tanıtılmıştır.
2. Giriş ve çıkışlar belirtilmiştir.
3. K kat çapraz doğrulama yapılmıştır bunun için "for" döngüsü oluşturulmuştur.
4. Model "AdaboostM2" kullanılarak kurulmuş ve her k kat çapraz doğrulama değeri için eğitilmiştir.
5. Performans değerlendirme metrikleriyle sonuçlar değerlendirilmiştir.
6. Doğruluk matrisi çizdirilmiştir.

3.10.3. Kullanılan yazılım ve optimum yapay zekâ yönteminin belirlenmesi

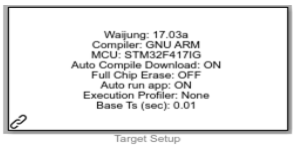
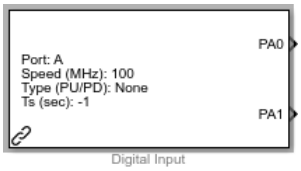
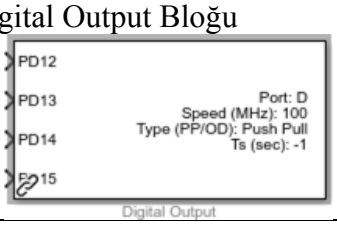
Çalışmada Matlab yazılım programı kullanılmıştır. Matlab kelimesinin açılımı İngilizce "MATrix LABoratuary" kelimesinden gelmektedir. İlk olarak Fortan dili ile Cleve Moler tarafından yazılmıştır. Şu anki sürümü MathWorks firması tarafından C dili ile yazılmıştır. Matlab, sayısal analiz, matris ve dizi işlemleri, sinyal işleme, algoritma geliştirme, C, C++, Java ve İnternet ile ilişik programlama ve grafiksel

kullanıcı arayüzü formlu program yazma gibi sayısal işlemleri kolaylıkla yapabilen bir yazılımdır (Uzunoğlu ve Onar, 2003).

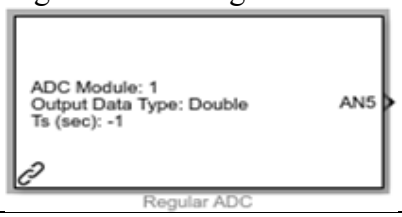
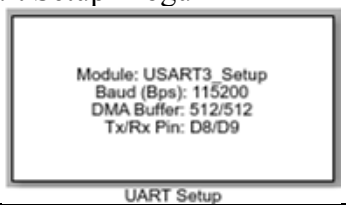
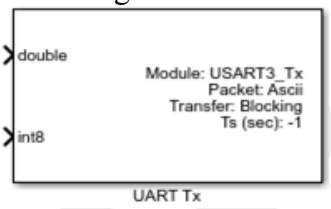
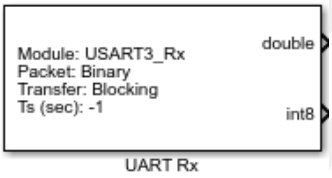
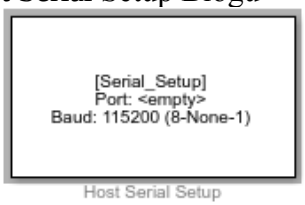
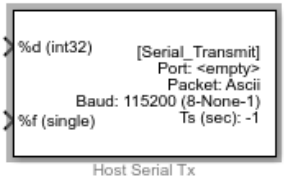
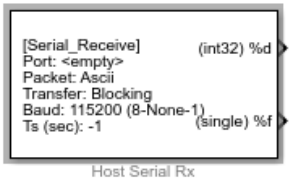
Çalışmada MATLAB komut satırında çalıştırılan modeller matlab/simulinkte simule edilmiştir. Simulink MATLAB ile birlikte bütünleşik olarak çalışan bir simülasyon ortamıdır. Karmaşık işlemleri tasarlama ve simülasyon yapma olanağı verir. Sürekli zamanlı ve ayrık zamanlı sistemleri veya her ikisini de içeren hibrit sistemleri desteklemektedir. İçinde birçok alt sistemi blok olarak barındırır ve sürükle-bırak yöntemiyle birçok sistem kurularak simule edilebilir. Simulink içerisinde zengin ve geliştirilebilen bir kütüphane yapısı bulundurmaktadır (Aydın, 2020)

MATLAB simulink ile simule edilen çalışma waijung bloksetler kullanılarak STM32F4 discovery kartına gömülmüştür. Waijung blok seti Tayvanlı bir firma olan Aimagin tarafından geliştirilmiştir. Waijung blok setler kullanılarak Simulink tabanlı uygulama geliştirmek mümkündür. Blok set "Waijung Bockset" internet sayfasından doğrudan indirilebilir. Blok setin basitliği ve uygulama geliştirme kapasitesi; programlama için tercih edilme sebeplerindendir (Kizir vd., 2019). Waijung blokları ve görevleri özet olarak Çizelge 3.7'de verilmiştir (Kizir vd., 2019).

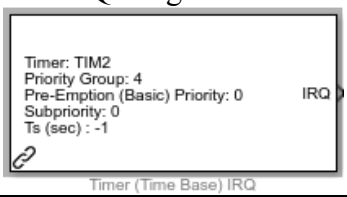
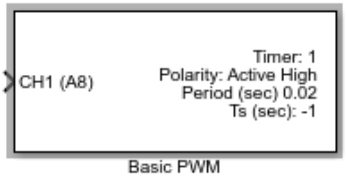
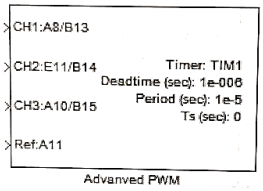
Çizelge 3.7. Waijung blokları, bloğun yeri ve kısaca görevi (Kizir vd., 2019)

Blok ismi ve blok	Bloğun açıklaması
Target Setup Bloğu 	STM32F4 kiti için derleme ve düzenleme işlemi yapılmasına olanak veren bloktur. Simulink içerisinde oluşturulan modeli koda dönüştürür.
Digital Input Bloğu 	STM32F4 kiti ile buton, anahtar gibi elemanlarla uygulama yapılabilmesi için bu bloğun eklenmesi gerekir. Elemanların göndermiş oldukları verilerin okunabilmesini sağlar. Uygulamada giriş pinlerini gösterir.
Digital Output Bloğu 	Uygulamada bu blok çıkış pinlerini temsil eder. Çıkış pini kullanıcı tarafından yapılabilir.

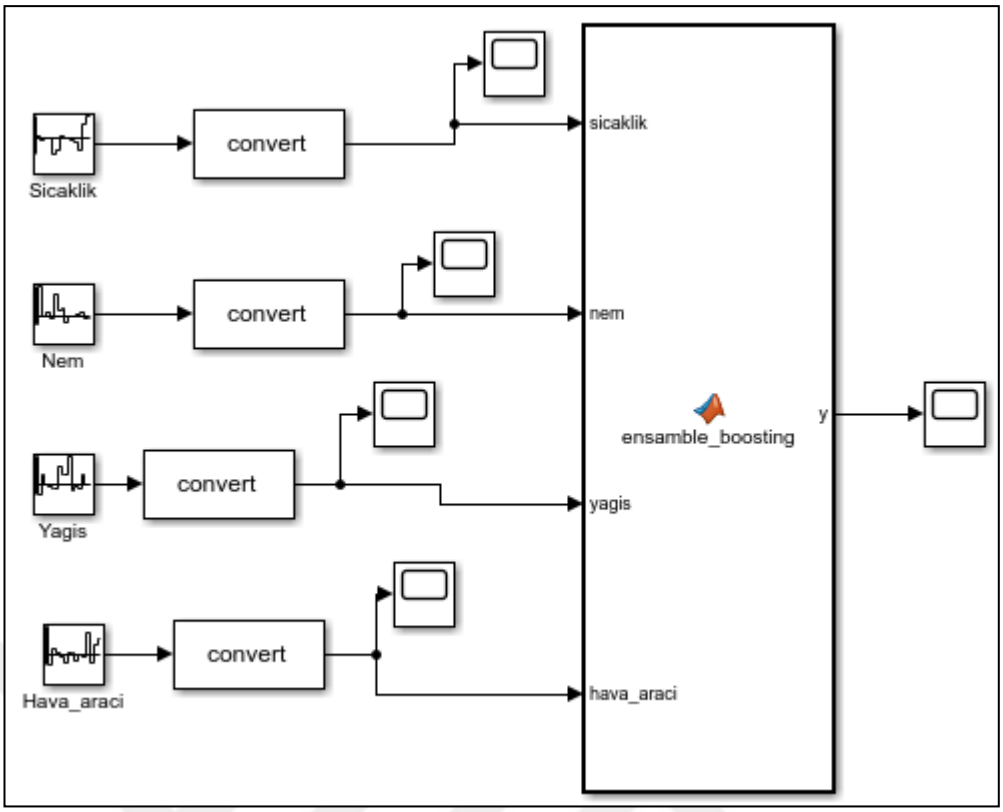
Çizelge 3.7. Waijung blokları, bloğun yeri ve kısaca görevi (Devam)

Regular ADC Bloğu 	Regular analog-dijital dönüştürücü (İng. Analog-Digital Converter ADC) Sıcaklık, basınç, nem gibi analog olarak girilen bilgileri dijitale dönüştürür. Regular ADC bloğunun çıkışı 0 ile 4095 arasında dijital değer verir. Bu sayı 12 bit çözünürlüğe karşılık gelir.
Uart Setup Bloğu 	STM32F4 uygulamalarında çift yönlü haberleşmeyi sağlar. Başka bir cihazdan veri almayı veya veri göndermeyi sağlar.
Uart Tx Bloğu 	STM32F4 kitinden başka bir cihaza veri gönderilmesi gerektiğinde kullanılması gereken bloktur.
Uart Rx Bloğu 	STM32F4 kartına veri alınması gerektiği uygulamalarda kullanılır.
Host Serial Setup Bloğu 	Uygulama yapılırken elde edilen veriler bilgisayarda gerçekleştirilmek isteniyorsa host serial setup bloğu kullanılmalıdır.
Host Serial Tx Bloğu 	STM32F4 kitinden anlık olarak veri gönderilmesi gerektiğinde host serial Tx bloğu kullanılır. Host Serial Tx bloğunun gönderdiği veriyi Uart Rx bloğu aldığı için iki bloğun parametreleri aynı olmalıdır.
Host Serial Rx Bloğu 	STM32F4 kitinden veri alınması gereken uygulamalarda Host Serial Rx bloğu kullanılmalıdır Uart Tx bloğu ile gönderilen veri Host serial Rx bloğu tarafından alınır.

Çizelge 3.7. Waijung blokları, bloğun yeri ve kısaca görevi (Devam)

Timer IRQ Bloğu 	Uygulamalarda asenkron zamanlayıcı kesmesi oluşturmak için Timer IRQ bloğu kullanılır.
Basic PWM Bloğu 	Temel darbe genişliği modülasyonu (İng. Basic PWM) bloğu ile kenar hizalı sinyalleri üretilir. Zamanlayıcı başına maksimum 4 PWM sinyali üretilebilir. Çalışma süresi boyunca PWM frekansı değiştirilemez.
Advanced PWM 	"Basic PWM" bloğu gibi PWM sinyali üretilir ayrıca bu blokla "dead time" yani ölü zaman da üretilebilir. En fazla 7 PWM sinyali üretilir.

Çalışmada yedi farklı yapay zekâ yöntemi uygulanmıştır. Uygulanan yöntemlerden en yüksek sınıflandırma doğruluğuna sahip olan modelin ensemble yöntemlerden boosting algoritmasının verdiği gözlenmiştir. Boosting algoritmasının eğitilmiş değerleri kaydedilmiş ve fonksiyon bloğu ile çağırılmıştır. İlk aşamada giriş değerlerini vermek için constant bloğu kullanılarak dört farklı buzlanma derecesi için tahmin yapılmıştır. Sonrasında rastgele sıralı diziler girişlere verilmiş sonuçlar scope'dan alınmıştır. Şekil 3.28'de rastgele sayılardan oluşturulan sıralı dizilerin giriş olarak verildiği tahminleme şeması verilmiştir.

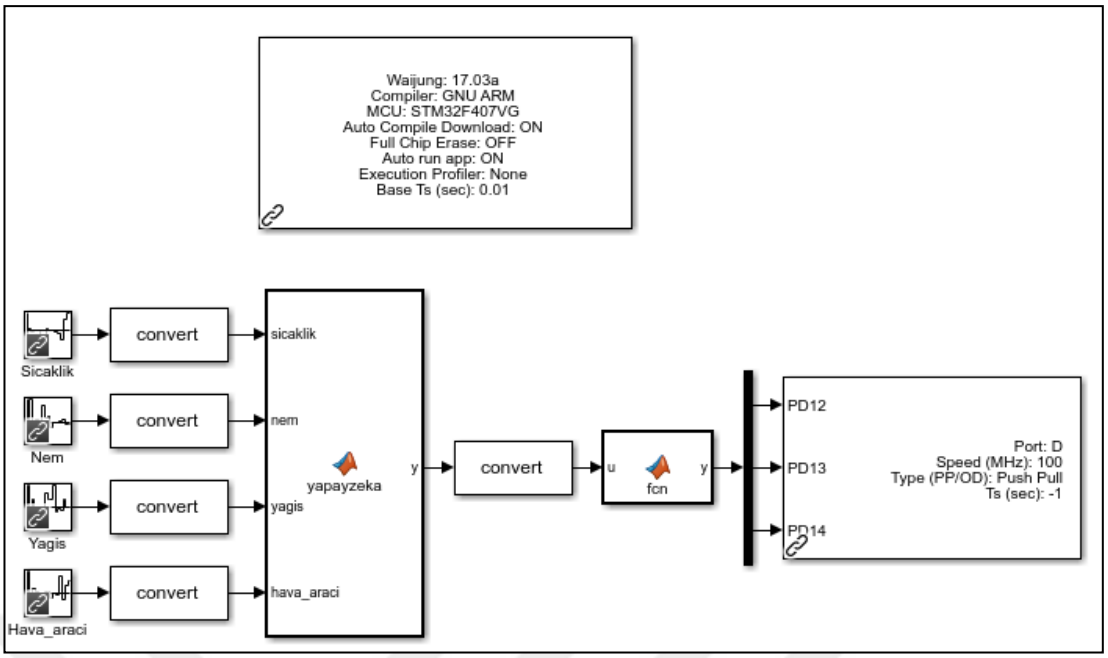


Şekil 3.28. Fonksiyon bloğu yardımıyla yeni verilerin ensemble modellerden boosting algoritmasıyla sınıflandırılması

3.10.4. Kurulan modelin STM32F4 discovery kartına gömülecek formata getirilmesi

Çalışmada son aşamada simulink şeması STM32F4 kontrol kartına gömülüp buzlanma derecesi tahmini RGB led üzerinden alınmıştır. Şekil 3.29'da STM32F4 kartına gömülen simulink blokları verilmiştir.

Şekil 3.29'da verilen şemada sıcaklık, nem, yağış ve hava aracı sıcaklığı parametreleri rastgele olarak dizi halinde girilmiş ve eğitilen yapay zekâ modeline göre çıkış tahmini yapılmıştır. Çıkış değeri için yeni bir fonksiyon bloğu içerisine bir switch-case yapısı yardımıyla buzlanma derecesi 0 iken led çıkış vermemesi, 1 iken ledin mavi olarak çıkış vermesi, 2 iken ledin yeşil olarak çıkış vermesi ve 3 iken ledin kırmızı olarak çıkış vermesi sağlanmıştır.



Şekil 3.29. STM32F4 kontrol kartı kullanılarak buzlanma tahmini

4. BULGULAR

Bu bölümde verisetine uygulanan yapay zekâ algoritmalarının sonuçları verilmiştir.

4.1. Yapay Zekâ Algoritmalarının Uygulama Sonuçları

4.1.1. Yapay sinir ağları uygulama sonuçları

Verisetine yapay sinir ağları uygulanmış, gizli katman sayıları ve nöron sayıları değiştirilerek doğruluk artırılmaya çalışılmıştır. Veri setine 10 kat çapraz doğrulama yapılmıştır. En yüksek doğruluk gizli katman sayısı 1 iken ve katmandaki nöron sayısı ise 25 iken %63.57 olarak elde edilmiştir. Şekil 4.1'de gizli katman nöronları ile çıkış arası eğitilmiş ağırlık değerleri ve Şekil 4.2'de ise bias değerleri verilmiştir.

```
agirlik =

  Columns 1 through 9

    1.2668    1.5774    0.9060    0.4268   -1.0213   -0.3976   -0.0680    1.0052    0.0296
    0.3231    0.0433    0.3706    0.7660    0.6157    0.4562   -0.5295    0.1991    0.6059
   -0.5916   -0.8055    0.1042    0.1808   -0.0081   -1.0246   -0.3979    0.2009   -0.7218
   -0.6082   -0.9201   -1.2205   -0.4277    0.1131    0.5339    0.7799   -1.0081    0.3418

  Columns 10 through 18

    1.0367    0.4972    1.1099    0.2162    0.0287    0.5688    0.2717   -0.5277   -0.2666
   -0.1874   -0.2573   -0.8037    0.3122   -0.3303    1.2382   -0.7257    0.3134    0.3744
    0.1290    0.3718   -0.0001    0.3690    0.0498   -1.4562   -0.3607    0.3149   -0.1022
   -0.5946    0.3286   -0.0564   -0.6786    0.5439   -1.0398   -0.0802    0.3507   -0.7918

  Columns 19 through 25

   -1.7276   -0.3271   -0.0158   -1.2075    1.3739    0.1011    0.6201
   -0.9216    0.5228    0.5301   -0.2005    0.2707    0.3467   -0.7110
    1.2145    0.4713    0.2243   -0.1720   -0.6814   -0.3949   -0.2474
    1.0562    0.0683   -0.5739    0.5843   -1.3632   -0.2572   -0.1960
```

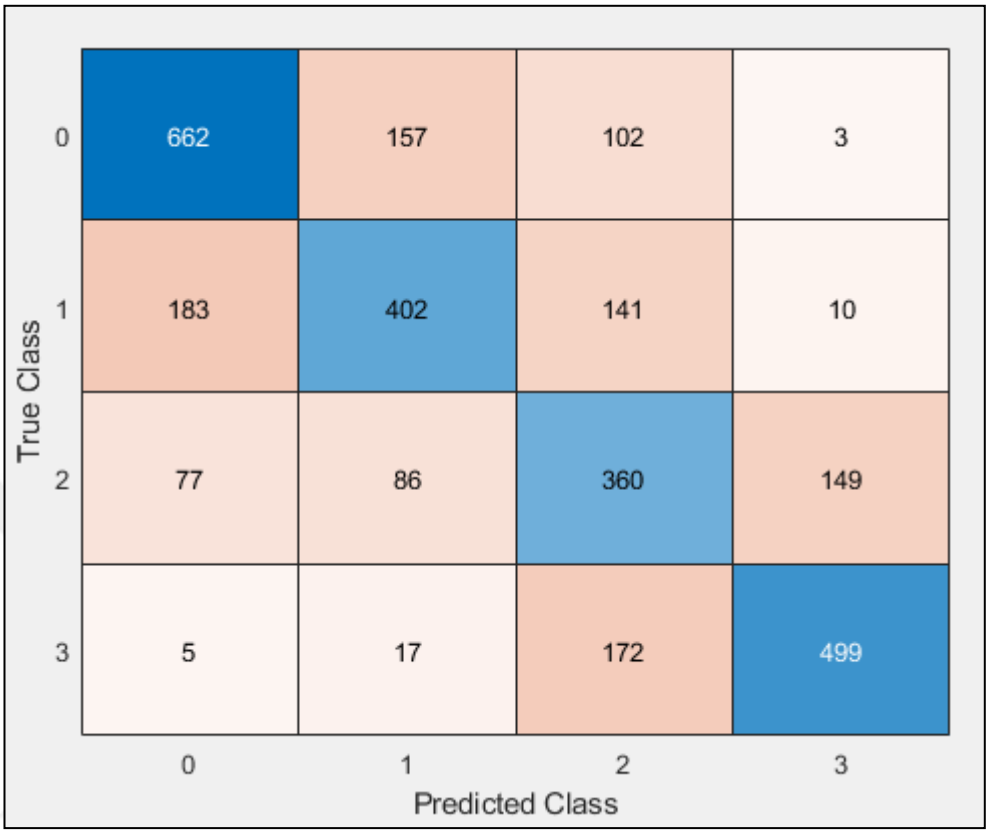
Şekil 4.1. YSA modelinden eğitim sonrası alınan gizli katmanla çıkış arası ağırlıklar

```
bias =

   -0.4282
   -0.0836
    1.0547
   -0.5430
```

Şekil 4.2. YSA modelinden eğitim sonrası alınan gizli katmanla çıkış arası biaslar

Sınıflandırma sonrası eğitime dair doğruluk matrisi çizdirilmiş ve doğruluk sonuçları Şekil 4.3'de verilmiştir.



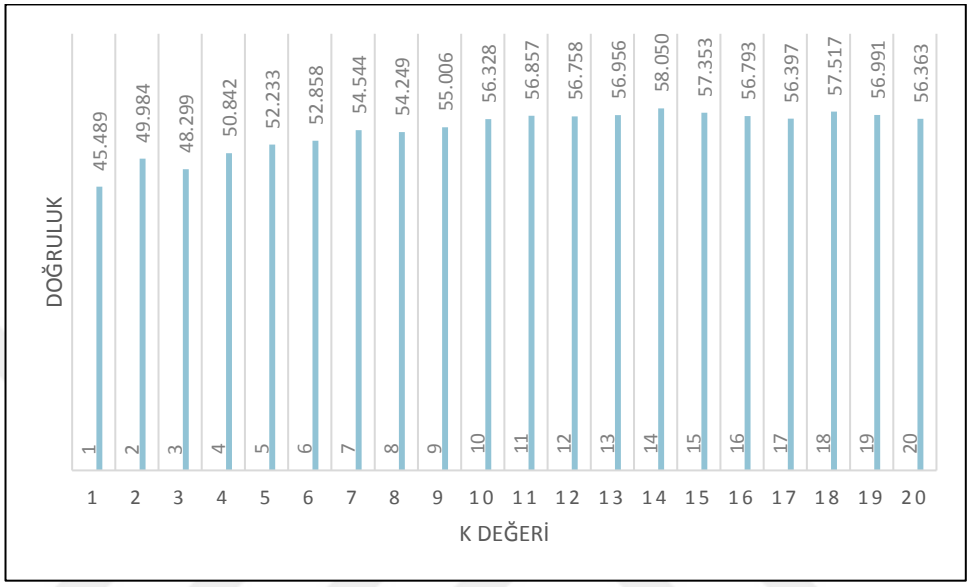
Şekil 4.3. Yapay sinir ağlarıyla sınıflandırılmış veri setinin doğruluk matrisi

Şekle göre; 0, 1, 2, 3 sırasıyla buzlanma yok, izle, hafif ve yoğun buzlanmayı temsil etmektedir. Uygulanan YSA algoritması buzlanma derecesi 0 olan 662 veriyi 0 olarak, 157 veriyi 1 olarak, 102 veriyi 2 olarak ve 3 veriyi 3 olarak sınıflandırmıştır. Buzlanma derecesi gerçekte 1 olan 402 veriyi 1 olarak, 183 veriyi 0 olarak, 141 veriyi 2 olarak ve 10 veriyi 3 olarak sınıflandırmıştır. Buzlanma derecesi 2 olan 360 veriyi 2 olarak, 77 veriyi 0 olarak, 86 veriyi 1 olarak ve 149 veriyi 3 olarak sınıflandırmıştır. Son olarak buzlanma derecesi gerçekte 3 olan 499 veriyi 3 olarak, 5 veriyi 0 olarak, 17 veriyi 1 olarak ve 172 veriyi ise 2 olarak sınıflandırmıştır. Toplamda 1923 veri doğru, 1102 veri ise yanlış sınıflandırılmıştır.

4.1.2. KNN algoritması uygulama sonuçları

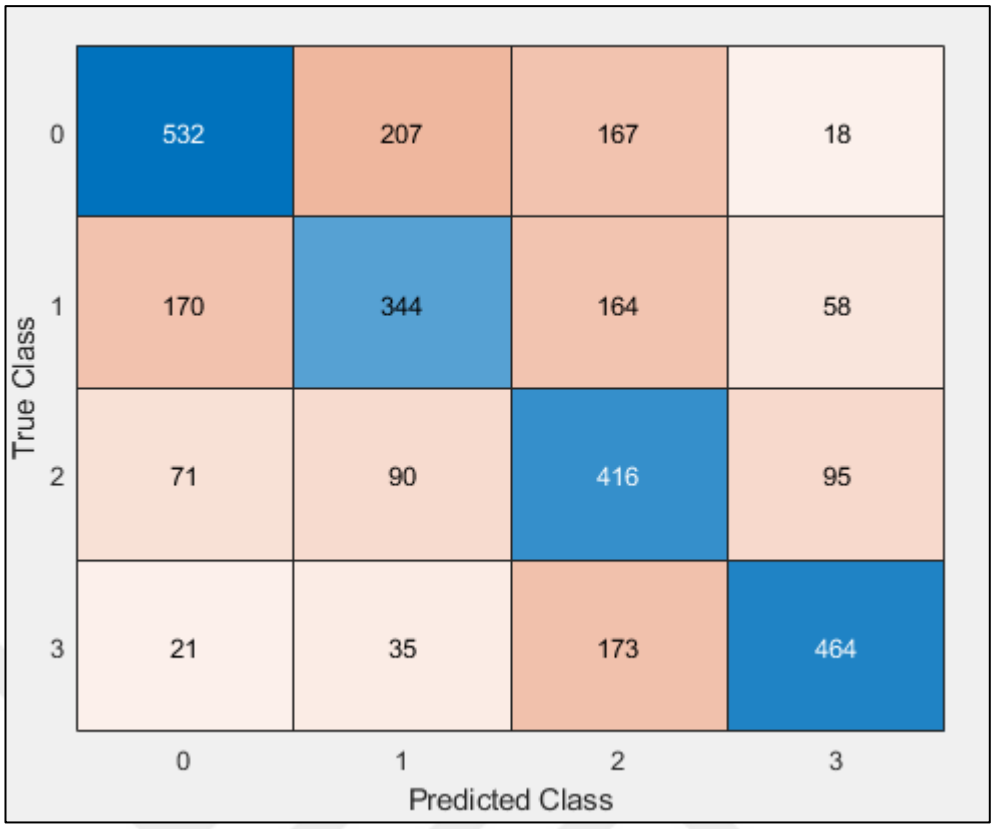
Verisetine ikinci aşamada KNN algoritması uygulanmıştır. Yöntemde ilk olarak k komşu değeri 1'den 20'ye kadar değiştirilmiş ve sistemin doğruluğu gözlenmiştir.

Burada amaç modelin hangi k komşu değerinde en iyi sonucu verdiğini bulmaktır. En yakın komşu hesaplamasında Öklid mesafesi kullanılmıştır. Verisetine 10 kat çapraz doğrulama yapılmıştır. 1'den 20'ye kadar değiştirilen k komşu değeri için elde edilen doğruluklar Şekil 4.4'de verilmiştir. K komşu değerinin 14 seçilmesi durumunda en yüksek doğruluk değeri %58.050'dir.



Şekil 4.4. Seçilen k değerleri için doğruluk sonuçları

Sınıflandırma sonucunda doğruluk matrisi çizdirilmiş ve Şekil 4.5'de verilmiştir.



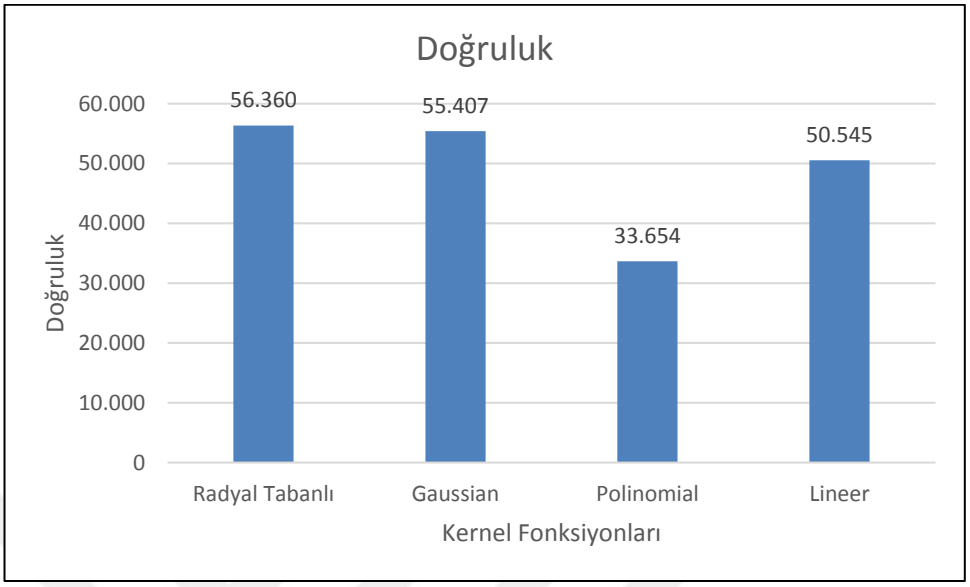
Şekil 4.5. KNN doğruluk matrisi

Şekle göre; 0, 1, 2, 3 sırasıyla buzlanma yok, izle, hafif ve yoğun buzlanmayı temsil etmektedir. Uygulanan KNN algoritması buzlanma risk derecesi 0 olan 532 veriyi 0 olarak, 207 veriyi 1 olarak, 167 veriyi 2 olarak ve 18 veriyi 3 olarak sınıflandırmıştır. Buzlanma risk derecesi gerçekte 1 olan 344 veriyi 1 olarak, 170 veriyi 0 olarak, 164 veriyi 2 olarak ve 58 veriyi 3 olarak sınıflandırmıştır. Buzlanma risk derecesi 2 olan 416 veriyi 2 olarak, 71 veriyi 0 olarak, 90 veriyi 1 olarak ve 95 veriyi 3 olarak sınıflandırmıştır. Son olarak buzlanma risk derecesi gerçekte 3 olan 464 veriyi 3 olarak, 21 veriyi 0 olarak, 35 veriyi 1 olarak ve 173 veriyi ise 2 olarak sınıflandırmıştır. Toplamda 1754 veri doğru, 1271 veri ise yanlış sınıflandırılmıştır.

4.1.3. Destek vektör makineleri uygulama sonuçları

Verisetine sonraki aşamada destek vektör makineleri uygulanmıştır. Kernel fonksiyonu değiştirilmiş ve doğruluk değişimi gözlenmiştir. Kernel fonksiyonu destek vektör makineleri ile kurulan modelin doğruluğunun değişmesinde etkili faktörlerden biridir. Verisetine 10 kat çapraz doğrulama yapılmıştır. Değiştirilen kernel fonksiyonları için elde edilen doğruluklar Şekil 4.6'da verilmiştir. Kernel

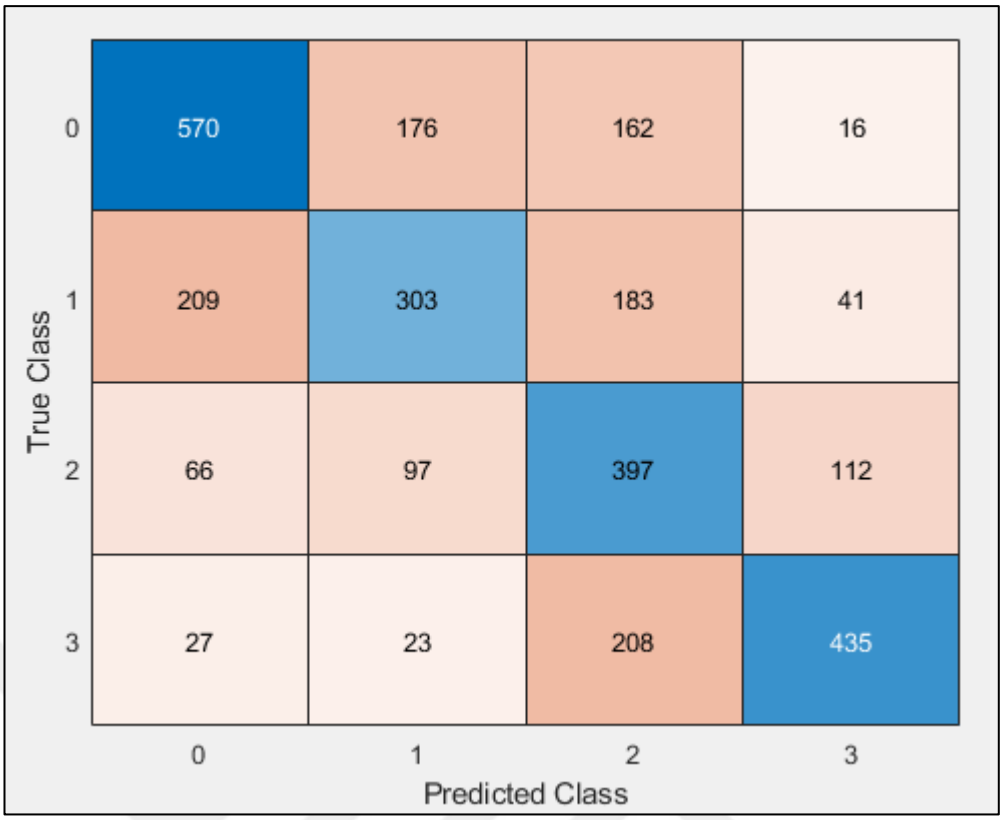
fonksiyonunun radyal tabanlı seçilmesi durumunda en yüksek doğruluk elde edilmiştir. Bu yöntem için en yüksek doğruluk değeri %56.360'dir.



Şekil 4.6. Kernel fonksiyonlarına göre doğruluk değişimi

Radyal tabanlı fonksiyona göre doğruluk matrisi çizdirilmiş ve Şekil 4.7'de verilmiştir.

Şekle göre; 0, 1, 2, 3 sırasıyla buzlanma yok, izle, hafif ve yoğun buzlanmayı temsil etmektedir. Uygulanan DVM algoritması buzlanma derecesi 0 olan 570 veriyi 0 olarak, 176 veriyi 1 olarak, 162 veriyi 2 olarak ve 16 veriyi 3 olarak sınıflandırmıştır. Buzlanma derecesi gerçekte 1 olan 303 veriyi 1 olarak, 209 veriyi 0 olarak, 183 veriyi 2 olarak ve 41 veriyi 3 olarak sınıflandırmıştır. Buzlanma derecesi 2 olan 397 veriyi 2 olarak, 66 veriyi 0 olarak, 97 veriyi 1 olarak ve 112 veriyi 3 olarak sınıflandırmıştır. Son olarak buzlanma derecesi gerçekte 3 olan 435 veriyi 3 olarak, 27 veriyi 0 olarak, 23 veriyi 1 olarak ve 208 veriyi ise 2 olarak sınıflandırmıştır. Toplamda 1705 veri doğru, 1320 veri ise yanlış sınıflandırılmıştır.

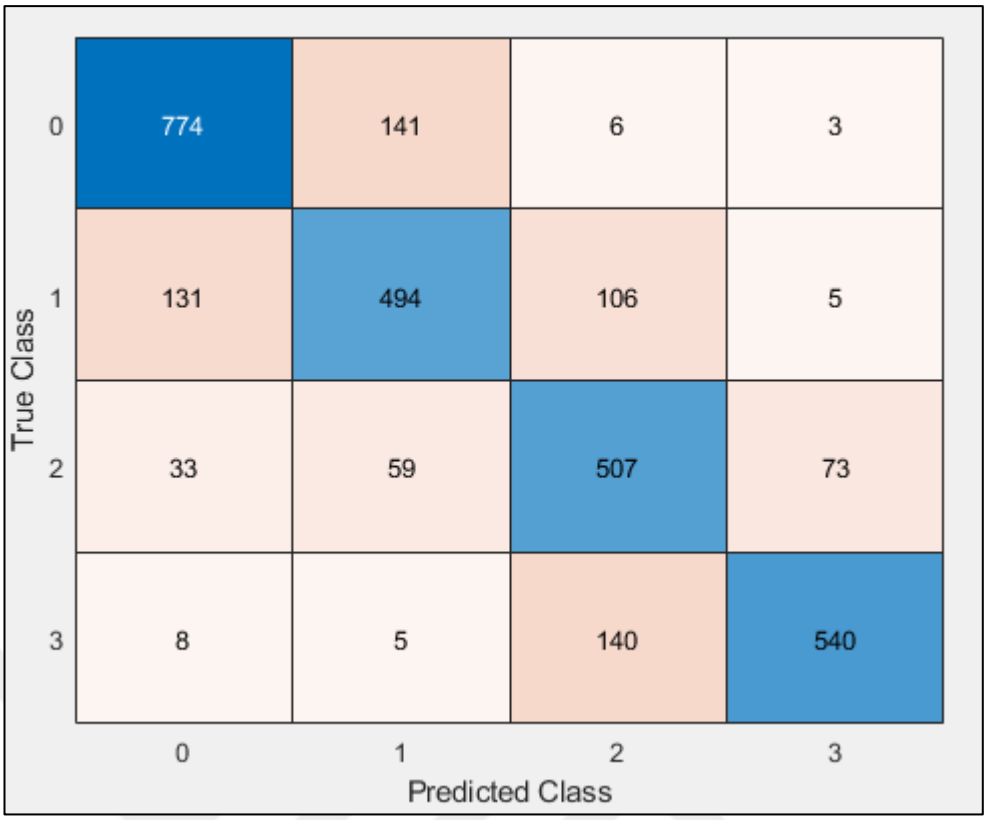


Şekil 4.7. Destek vektör makineleri doğruluk matrisi

4.1.4. Karar ağaçları uygulama sonuçları

Verisetine uygulanan dördüncü algoritma karar ağaçlarıdır. Verisetine 10 kat çapraz doğrulama yapılmıştır. %76.53 oranında doğruluk değeri elde edilmiştir ve doğruluk matrisi Şekil 4.8'de verilmiştir.

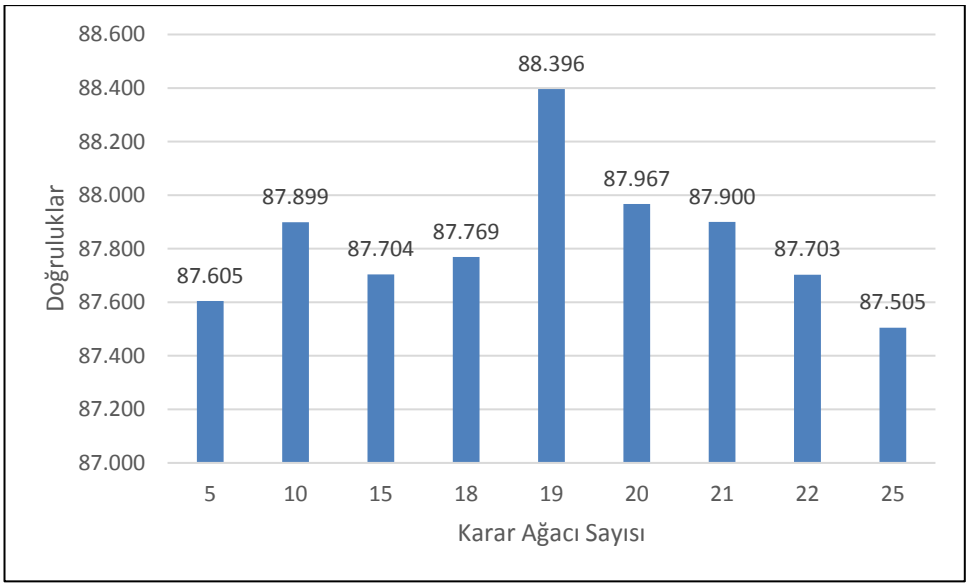
Şekle göre; 0, 1, 2, 3 sırasıyla buzlanma yok, izle, hafif ve yoğun buzlanmayı temsil etmektedir. Uygulanan karar ağaçları algoritması buzlanma derecesi 0 olan 774 veriyi 0 olarak, 141 veriyi 1 olarak, 6 veriyi 2 olarak ve 3 veriyi 3 olarak sınıflandırmıştır. Buzlanma derecesi gerçekte 1 olan 494 veriyi 1 olarak, 131 veriyi 0 olarak, 106 veriyi 2 olarak ve 5 veriyi 3 olarak sınıflandırmıştır. Buzlanma derecesi 2 olan 507 veriyi 2 olarak, 33 veriyi 0 olarak, 59 veriyi 1 olarak ve 73 veriyi 3 olarak sınıflandırmıştır. Son olarak buzlanma derecesi gerçekte 3 olan 540 veriyi 3 olarak, 8 veriyi 0 olarak, 5 veriyi 1 olarak ve 140 veriyi ise 2 olarak sınıflandırmıştır. Toplamda 2315 veri doğru, 710 veri ise yanlış sınıflandırılmıştır.



Şekil 4.8. Karar ağaçları doğruluk matrisi

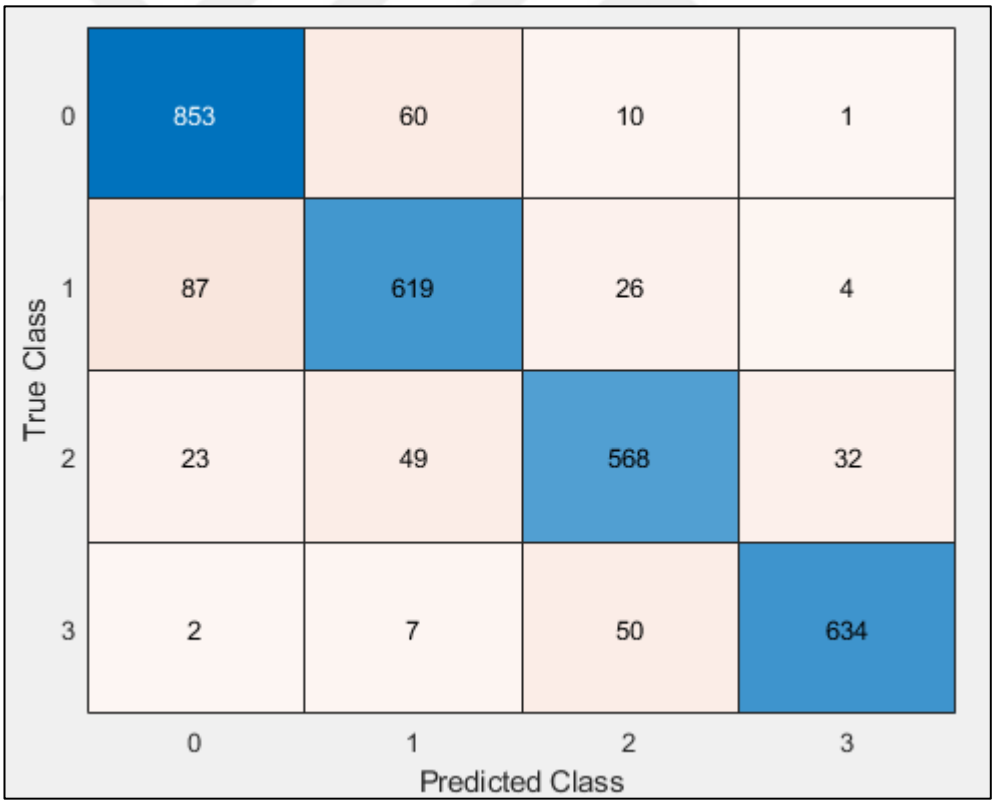
4.1.5. Ensemble yöntemlerden rastgele orman uygulama sonuçları

Verisetine uygulanan beşinci yapay zekâ algoritması rastgele orman algoritmasıdır. Algoritmanın içerisindeki karar ağaçları bulunmaktadır ve karar ağaçlarının sayısı doğruluğun değişmesinde etkilidir. Bu nedenle karar ağaçlarının sayısı değiştirilmiş ve sistemin doğruluğu gözlenmiştir. Verisetine 10 kat çapraz doğrulama yapılmıştır. Elde edilen doğruluklar Şekil 4.9'da verilmiştir. Karar ağaçı sayısının 19 seçilmesi durumunda en yüksek doğruluk elde edilmiştir ve değeri %88.396'dır.



Şekil 4.9. Farklı sayıda kullanılan karar ağaçlarında doğruluğun değişimi

Sınıflandırma sonucunda doğruluk matrisi çizdirilmiş ve Şekil 4.10'da verilmiştir.



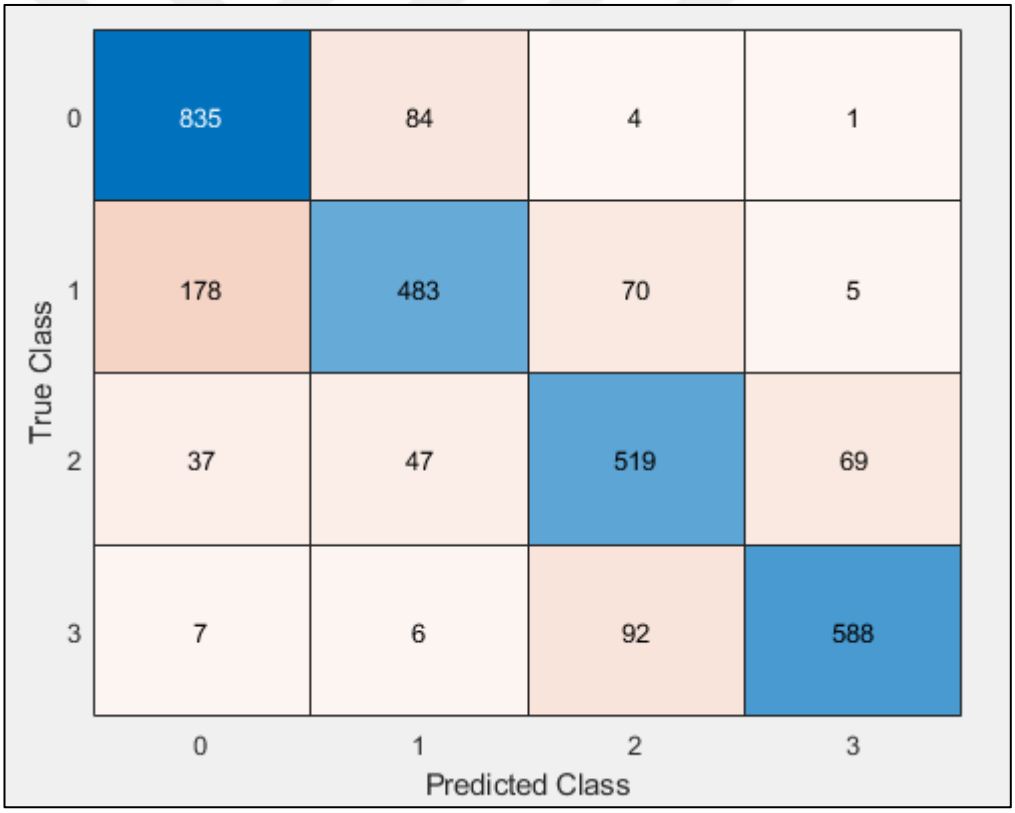
Şekil 4.10. Rastgele orman algoritması doğruluk matrisi

Şekle göre; 0, 1, 2, 3 sırasıyla buzlanma yok, izle, hafif ve yoğun buzlanmayı temsil etmektedir. Uygulanan rastgele orman algoritması buzlanma derecesi 0 olan 853 veriyi 0 olarak, 60 veriyi 1 olarak, 10 veriyi 2 olarak ve 1 veriyi 3 olarak sınıflandırmıştır.

Buzlanma derecesi gerçekte 1 olan 619 veriyi 1 olarak, 87 veriyi 0 olarak, 26 veriyi 2 olarak ve 4 veriyi 3 olarak sınıflandırmıştır. Buzlanma derecesi 2 olan 568 veriyi 2 olarak, 23 veriyi 0 olarak, 49 veriyi 1 olarak ve 32 veriyi 3 olarak sınıflandırmıştır. Son olarak buzlanma derecesi gerçekte 3 olan 634 veriyi 3 olarak, 2 veriyi 0 olarak, 7 veriyi 1 olarak ve 50 veriyi ise 2 olarak sınıflandırmıştır. Toplamda 2674 veri doğru, 351 veri ise yanlış sınıflandırılmıştır.

4.1.6. Ensemble yöntemlerden bagging algoritması

Verisetine uygulanan bir diğer algoritma bagging algoritmasıdır. Verisetine 10 kat çapraz doğrulama yapılmıştır. %80.16 oranında doğruluk elde edilmiştir ve doğruluk matrisi Şekil 4.11'de verilmiştir.



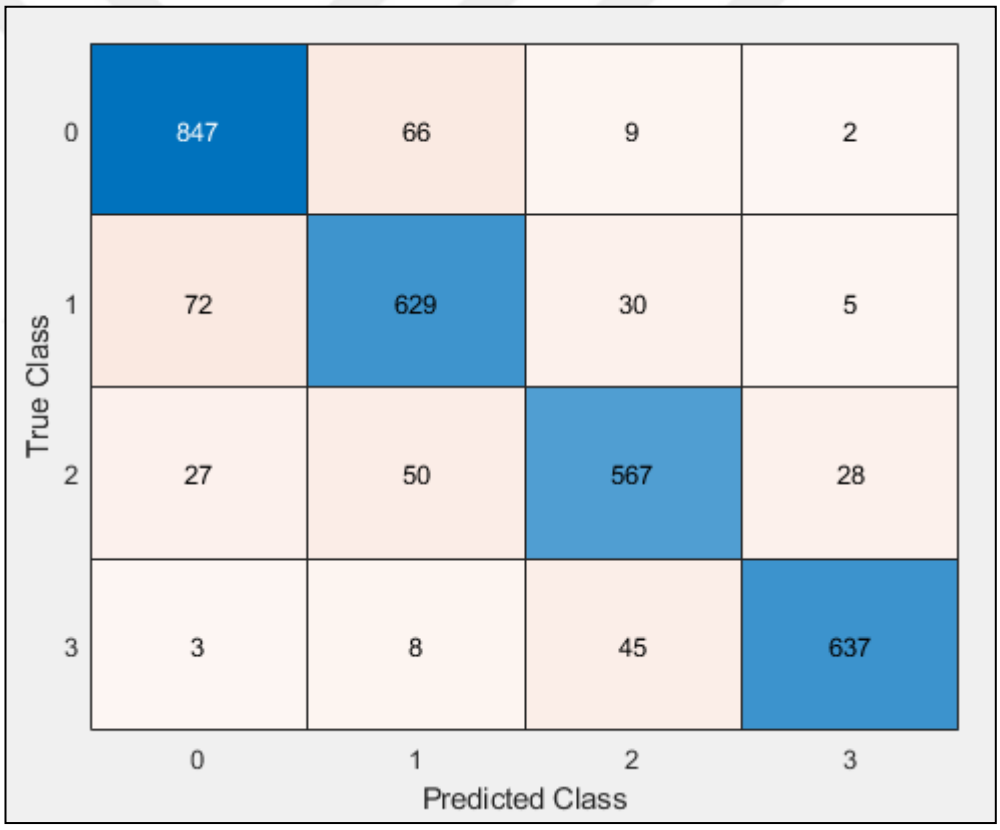
Şekil 4.11. Ensemble yöntemlerden bagging algoritması doğruluk matrisi

Şekle göre; 0, 1, 2, 3 sırasıyla buzlanma yok, izle, hafif ve yoğun buzlanmayı temsil etmektedir. Uygulanan karar ağaçları algoritması buzlanma risk derecesi 0 olan 835 veriyi 0 olarak, 84 veriyi 1 olarak, 4 veriyi 2 olarak ve 1 veriyi 3 olarak sınıflandırmıştır. Buzlanma risk derecesi gerçekte 1 olan 483 veriyi 1 olarak, 178

veriyi 0 olarak, 70 veriyi 2 olarak ve 5 veriyi 3 olarak sınıflandırmıştır. Buzlanma risk derecesi 2 olan 519 veriyi 2 olarak, 37 veriyi 0 olarak, 47 veriyi 1 olarak ve 69 veriyi 3 olarak sınıflandırmıştır. Son olarak buzlanma risk derecesi gerçekte 3 olan 588 veriyi 3 olarak, 7 veriyi 0 olarak, 6 veriyi 1 olarak ve 92 veriyi ise 2 olarak sınıflandırmıştır. Toplamda 2425 veri doğru, 600 veri ise yanlış sınıflandırılmıştır.

4.1.7. Ensemble yöntemlerden boosting algoritması

Verisetine son uygulanan algoritma ensemble yöntemlerden olan boosting algoritmasıdır. Verisetine 10 kat çapraz doğrulama yapılmıştır. %88.59 oranında doğruluk elde edilmiştir ve doğruluk matrisi Şekil 4.12'de verilmiştir.



Şekil 4.12. Ensemble yöntemlerden boosting algoritması doğruluk matrisi

Şekle göre; 0, 1, 2, 3 sırasıyla buzlanma yok, izle, hafif ve yoğun buzlanmayı temsil etmektedir. Uygulanan boosting algoritması buzlanma risk derecesi 0 olan 847 veriyi 0 olarak, 66 veriyi 1 olarak, 9 veriyi 2 olarak ve 2 veriyi 3 olarak sınıflandırmıştır. Buzlanma risk derecesi gerçekte 1 olan 629 veriyi 1 olarak, 72 veriyi 0 olarak, 30 veriyi 2 olarak ve 5 veriyi 3 olarak sınıflandırmıştır. Buzlanma risk derecesi 2 olan 567

veriyi 2 olarak, 27 veriyi 0 olarak, 50 veriyi 1 olarak ve 29 veriyi 3 olarak sınıflandırmıştır. Son olarak buzlanma risk derecesi gerçekte 3 olan 637 veriyi 3 olarak, 3 veriyi 0 olarak, 8 veriyi 1 olarak ve 45 veriyi ise 2 olarak sınıflandırmıştır. Toplamda 2680 veri doğru, 345 veri ise yanlış sınıflandırılmıştır.

4.2. Veriseti Üzerinde Optimum Sonucu Veren Yöntemin Belirlenmesi

Veriseti üzerinde yedi farklı yapay zekâ algoritması uygulanmıştır. Algoritmalar performans değerlendirme metrikleri ile değerlendirilerek sonuçlar Çizelge 4.1'de verilmiştir.

Çizelge 4.1. Sınıflandırma yöntemlerinin performans değerlendirme metrikleri ile değerlendirilmesi

Yapay Zekâ Algoritması / Performans değerlendirme metriği	YSA	KNN	DVM	Karar Ağacı	Rast. Orman	Bagging	Boosting
Duyarlılık (Recall)	0.6352	0.5904	0.5744	0.7656	0.8849	0.8034	**0.8867**
Kesinlik (Precision)	0.6296	0.5829	0.5618	0.7606	0.8811	0.7952	**0.8836**
Doğruluk (Accuracy)	0.6357	0.5805	0.5636	0.7653	0.8840	0.8017	**0.8859**
F Puanı (F score)	0.6324	0.5867	0.5680	0.7631	0.8830	0.7993	**0.8851**

Çizelge 4.1'e göre verisetini sınıflandırmada en iyi yöntem ensemble yöntemlerden boosting algoritması olarak belirlenmiştir. Ensemble modellerden boosting algoritması için duyarlılık %88.67, kesinlik %88.36, doğruluk %88.59 ve F puanı %88.51 olarak bulunmuştur.

4.3. Yapay Zekâ Algoritmasının Giriş ve Çıkış Sonuçlarının İncelenmesi

Tez çalışmasının bir sonraki aşamasında en iyi sonucu veren algoritma ile Simulinkte bir dizi analiz yapılmıştır. MATLAB programının editör dosyasında yazılan kodlarla sistem eğitilmiş ve en iyi modeli veren algoritma kaydedilmiştir. Bir fonksiyon bloğu yardımı ile eğitilen ve kaydedilen model çağrılmış ve farklı girişler için çıkışlar tahmin

ettirilmiştir. Şekil 4.13'de kaydedilen modeli fonksiyon bloğu yardımıyla çağıran kod verilmiştir.

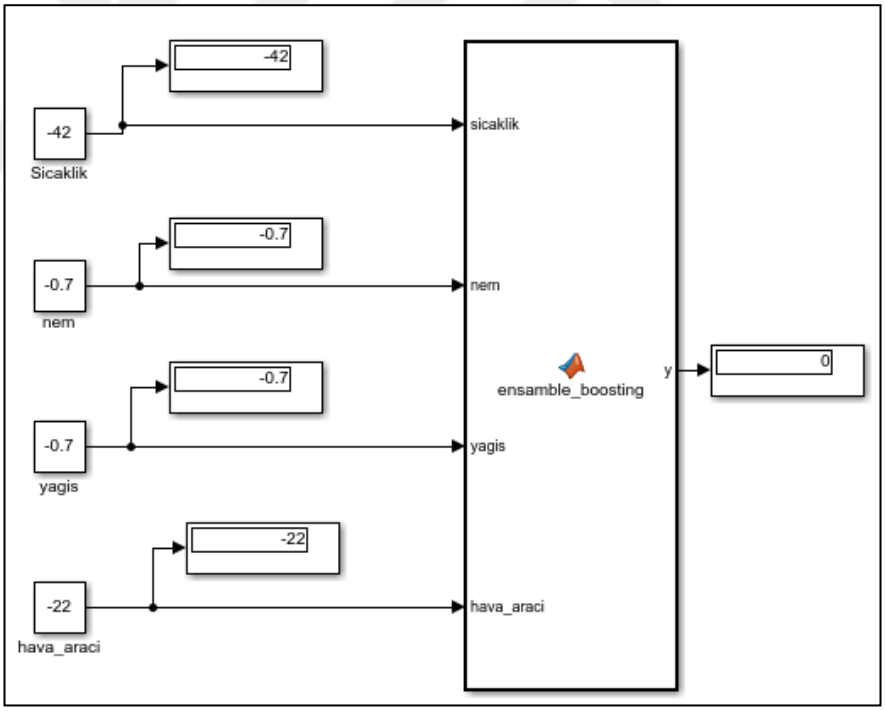
```
function y = ensamble_boosting(sicaklik,nem,yagis,hava_araci)

Mdl = loadLearnerForCoder('ensemble_boosting_2');

y = predict(Mdl, [yagis hava_araci nem sicaklik])
```

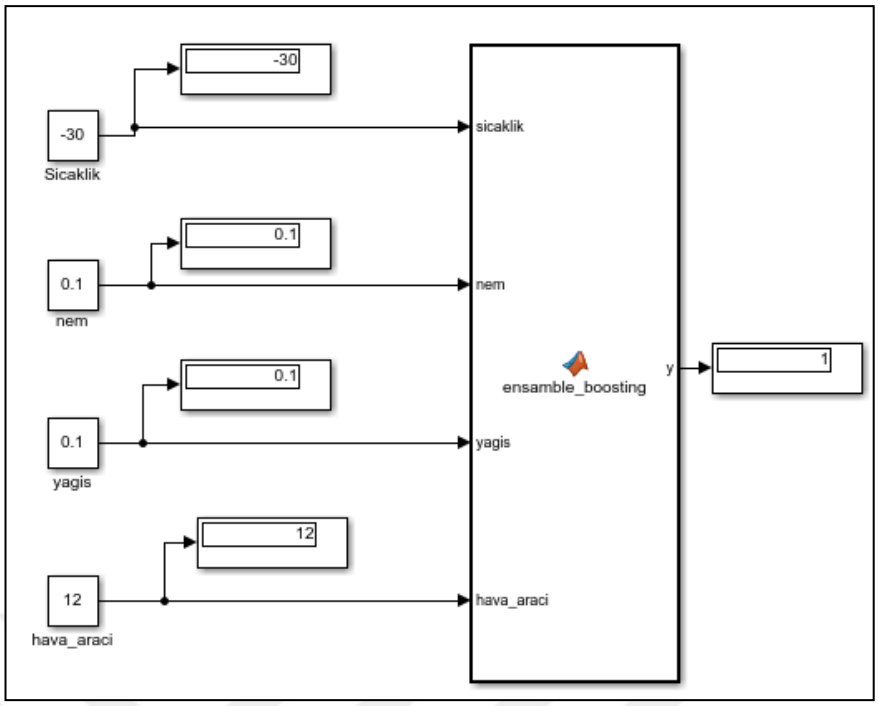
Şekil 4.13. Fonksiyon bloğu yardımıyla

Şekil 4.14. – 4.17. arası constant bloğu ile girilen farklı giriş değerinin display bloğu ile gözlenmesi örneklemektedir. Şekil 4.14'de buzlanma derecesi sıfırı vermesi gereken giriş verileri girilmiş ve sınıflandırma sonucu displayde buzlanma derecesinin sıfır olduğu gözlenmiştir. Boosting algoritması buzlanma derecesini doğru tahmin etmiştir.



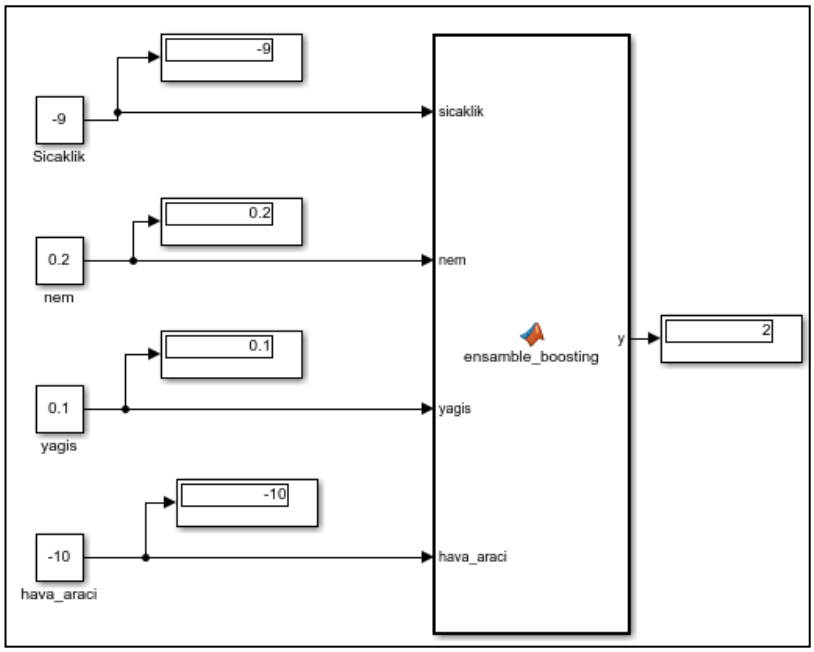
Şekil 4.14. Buzlanma derecesi sıfır durumu için örnek analiz

Şekil 4.15'de buzlanma derecesi biri vermesi gereken giriş verileri girilmiş ve sınıflandırma sonucu displayde buzlanma derecesinin bir olduğu gözlenmiştir.



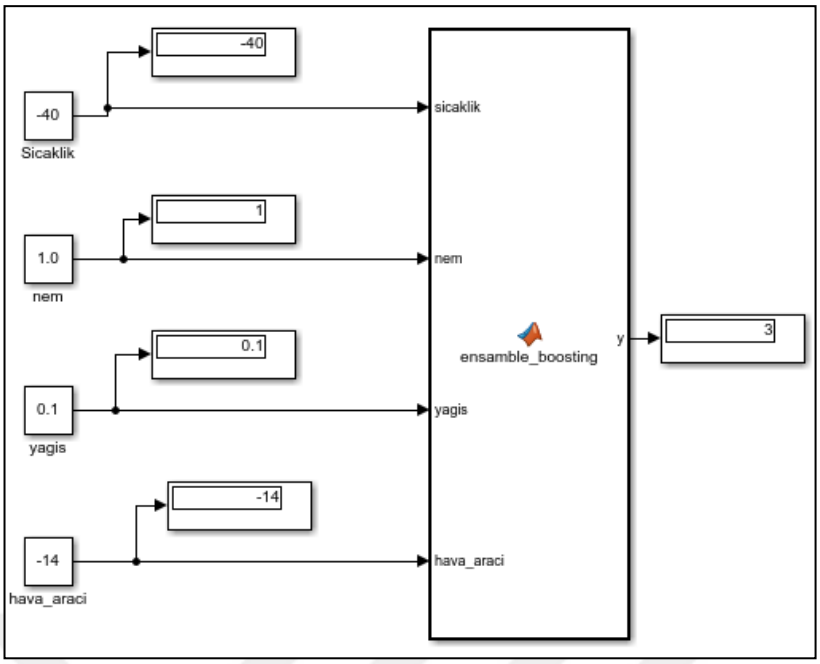
Şekil 4.15. Buzlanma derecesi bir durumu için örnek analiz

Şekil 4.16'da buzlanma derecesinin iki yani orta düzeyde olmasını sağlayacak giriş verileri girilmiş ve sınıflandırma sonucu displayde buzlanma derecesinin iki olduğu gözlenmiştir.



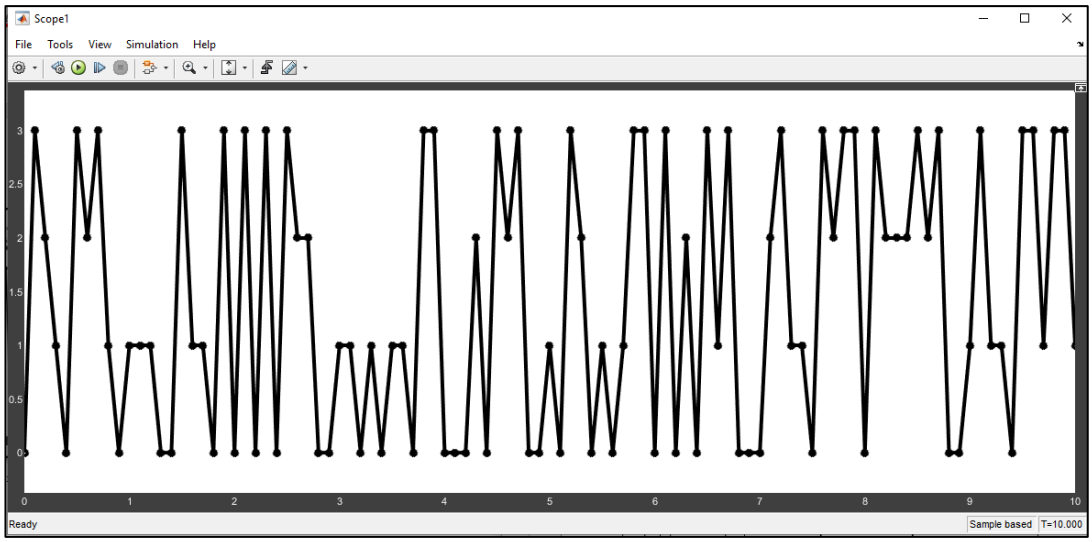
Şekil 4.16. Buzlanma derecesi iki durumu için örnek analiz

Şekil 4.17'de buzlanma derecesinin üç olması gerektiği giriş verileri girilmiş ve sınıflandırma sonucu displayde buzlanma derecesinin üç olduğu gözlenmiştir.

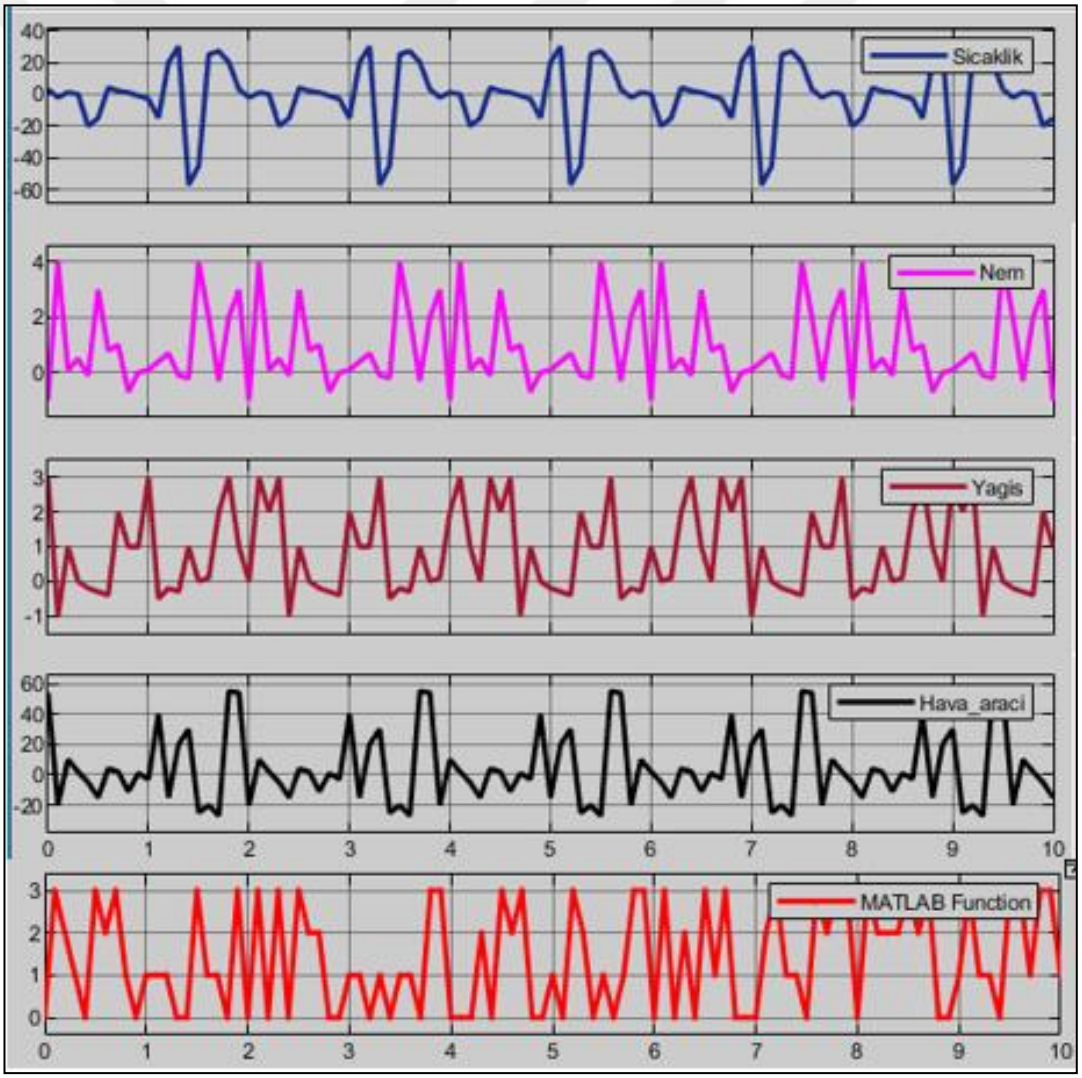


Şekil 4.17. Buzlanma derecesi üç durumu için örnek analiz

Çalışmada sonraki aşamada simulinke gömülen yapay zekâ algoritması için giriş değerleri "Repeating Sequence Stair" bloğu yardımıyla rastgele olarak belirlenmiştir. Şekil 3.29'da gösterilen simulink şemasında örnekleme zamanı 0,1 olarak seçilmiştir. Simulasyon süresi boyunca tekrarlı şekilde girişe verilen rastgele sıcaklık değerleri [3 -2 1 0 -20 -15 4 2 1 -1 -3 -15 20 30 -57 -45 25 27 20] olarak, rastgele nem değerleri [-1 4 0.1 0.5 -0.1 3 0.8 1 -0.7 0 0.1 0.4 0.7 -0.1 -0.2 4 2 -0.3 2 3] olarak, rastgele yağış değerleri [3 -1 1 0 -0.2 -0.3 -0.4 2 1 1 3 -0.5 -0.2 -0.3 1 0 0.1 2 3 1 0 3 2] olarak ve rastgele hava aracı sıcaklığı değerleri ise [54 -20 10 2 -5 -15 4 2 -11 1 -3 40 -15 20 30 -25 -20 -27 55] olarak verilmiştir. Sümulasyon süresi 10 sn olarak belirlenmiştir. Giriş değerlerine göre buzlanma derecesi tahminleri ise şekil 4.18.'de verilmiştir. Giriş değerlerinin sonucunda tahmin edilen buzlanma derecesi 'marker' kullanılarak şekilde vurgulanmıştır. Şekil 4.18'de yatay eksen simulasyon süresini dikey eksen ise buzlanma risk derecelerini göstermektedir. Şekil 4.19'da ise giriş parametrelerine göre çıkışta oluşmuş buzlanma risk dereceleri grafikleri verilmiştir.



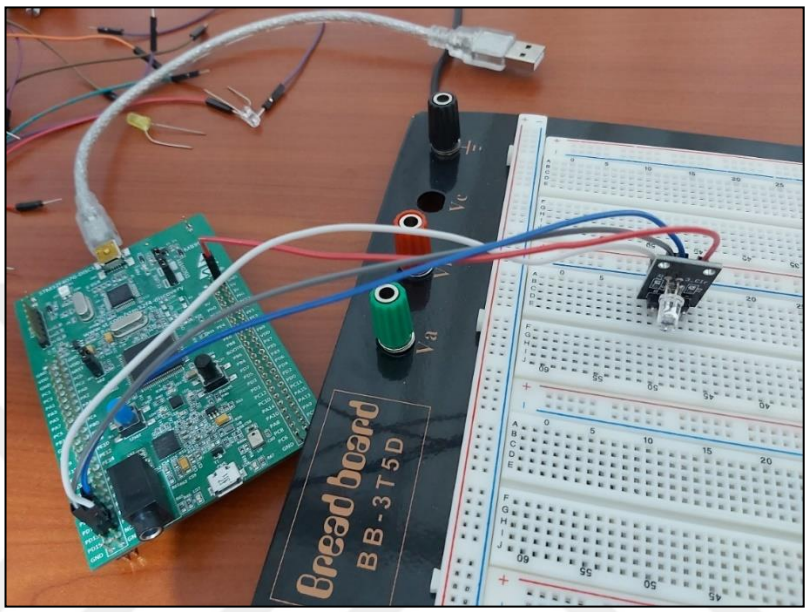
Şekil 4.18. Random girişlere göre buzlanma derecesi tahmini



Şekil 4.19. Random girişlere göre giriş ve çıkış grafikleri

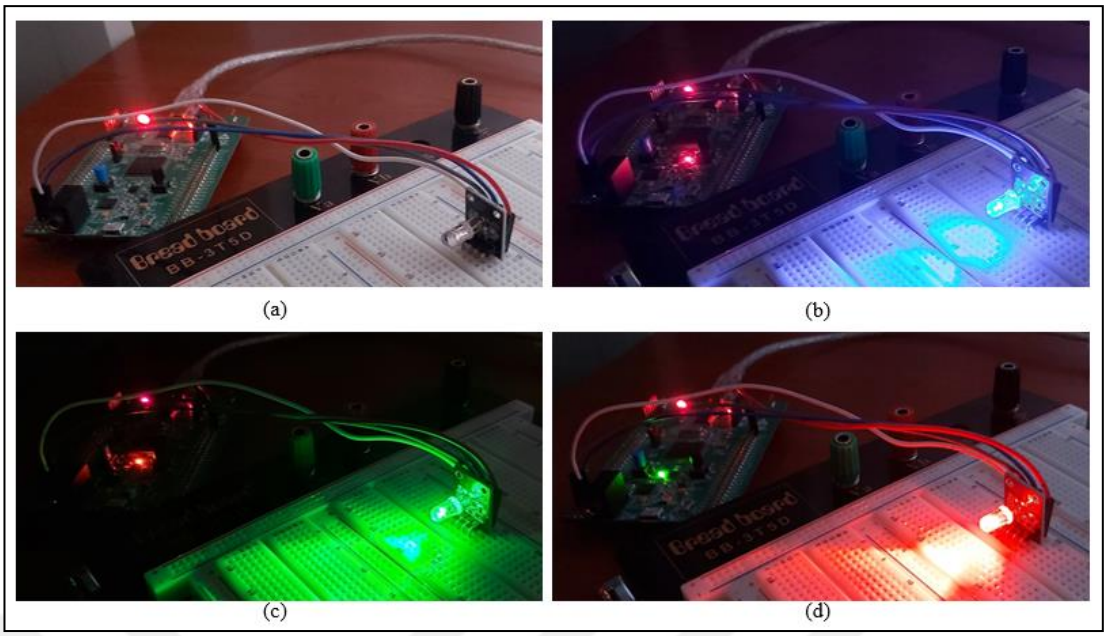
4.4. Kurulan Modelin STM32F4 Discovery Kartına Aktarılması

MATLAB/Simulink'te simule edilen bloklar waijung blokset kullanılarak STM32F4 kartına gömülmüştür. Buzlanma derecesinin kontrol kartından gözlemlenebilmesi için kullanılan devre Şekil 4.20'de verilmiştir.



Şekil 4.20. Buzlanma derecesi tahminin gözlendiği devre

MATLAB workspacede yazılan kodlar fonksiyon bloğu yardımıyla simulinkten çağırılmış ve waijung blokset yardımıyla da STM32F4 kartına gömülmüştür. Şekil 4.21'de verilen devre üzerinden de buzlanma derecesi tahmini rastgele giriş değerlerine göre RGB led yardımıyla gözlenmiştir. Şekil 4.21'de her buzlanma derecesi için örnek görseller verimliştir.



Şekil 4.21. RGB led yardımı ile gözlemlenen buzlanma dereceleri (a) Buzlanma yok (b) Buzlanma derecesi 1 (hafif) (c) Buzlanma derecesi 2 (orta) (d) Buzlanma derecesi 3 (yoğun)

5. TARTIŞMA VE SONUÇ

Hava araçlarında buzlanma günümüzde havacılık alanında kazaların en önemli sebeplerinden biridir. Tez çalışmasında örnek bir hava aracından alınmış sıcaklık, nem, yağış ve hava aracı sıcaklığı gibi verilerden yola çıkılarak buzlanma risk derecesi belirlenmeye çalışılmıştır. Çalışma kısaca şu şekilde özetlenebilir;

1. Literatür kapsamlı olarak taranmıştır.
2. Veriseti literatürdeki çalışmalardan belirlenmiştir.
3. Yapay sinir ağları, KNN algoritması, karar ağaçları, destek vektör makineleri, ensemble yöntemlerden rastgele orman, bagging ve boosting modelleri oluşturulmuştur.
4. Oluşturulan veri seti modellerle eğitilmiş ve performans değerlendirme metrikleri kullanılarak performansı en yüksek model belirlenmiştir. Tez çalışmasında en yüksek performansta sınıflandırma doğruluğu ensemble modellerden boosting algoritmasıyla elde edilmiştir. Boosting algoritmasının duyarlılığı %88.67, kesinliği %88.36, doğruluğu %88.59 ve F puanı %88.51 olarak bulunmuştur.
5. Boosting algoritması eğitilmiş parametreleri kaydedilmiş ve simulinkteki fonksiyon bloğu aracılığıyla simulinkten girilebilecek yeni giriş verilerinde tahmin amaçlı kullanılabilmesi amacıyla çağrılmıştır. Simulinkten rastgele girişler verilip buzlanma derecesi tahmini sınıflandırmada en iyi performansa sahip olan boosting algoritmasıyla yapılmış ve grafiklerle sonuçlar gösterilmiştir.
6. Simulinkte simule edilen model waijung blokset kütüphanesindeki bloklar yardımı ile STM32F4 discovery kartına gömülmüştür. Buzlanma tahmini kart çıkışına bağlanan RGB led yardımı ile gözlenmiştir.

Çalışma sonunda gerçekte problem üzerinde çözüm olarak uygulanabilecek şekilde buzlanma risk derecesini tahmin eden sistem tasarlanmış, simülasyonu yapılmış ve çalışır şekilde kontrol kartına gömülmüştür. Buzlanma risk derecesinin tahmin edilmesiyle buz önleme ve buzdan koruma sistemleri devreye alınabilir ve pilottan kaynaklı buzlanma kazalarının önüne geçilebilir.

Çalışmada literatürde bulunan çalışmalar incelenmiş ve buzlanma derecesi tahmininde en belirleyici iki parametrenin sıcaklık ve nem olduğu gözlenmiştir. Buzlanma derecesi tahmininde bunun yanında farklı parametreler kullanılmıştır. Fenar (2016), yüksek lisans tezinde buzlanma derecesi tahmininde sıcaklık, nem ve donma noktası olmak üzere üç parametre kullanmış, Gliwa vd. (2018), buzlanma risk derecesi tahmininde sıcaklık, nem, hava aracı sıcaklığı ve yağış parametrelerini kullanmışlardır. Li vd. (2020), buzlanma risk derecesi tahmininde sıvı su içeriği, damlacık çapı ve maruz kalma süresini giriş parametresi olarak almışlardır. Tez çalışmasında giriş parametreleri fazla tutulmaya çalışılmış ve sıcaklık, nem, hava aracı sıcaklığı ve yağış olarak belirlenmiştir.

Buzlanma risk derecesi tahmini için literatürde kullanılan algoritmalar incelenmiştir. Fenar (2016), yüksek lisans tezinde yapay sinir ağları üzerine çalışmış farklı yapay sinir ağı mimarileri uygulayarak buzlanma risk derecesi tahmini yapmıştır. Gliwa vd. (2018), çalışmalarında bulanık mantık ile buzlanma risk derecesi ve yoğunluğu tahmini yapmışlardır. Li vd. (2020), XGBoost denetimli öğrenme algoritmasını kullanmışlardır. Tez çalışmasında ise yapay sinir ağları, KNN algoritması, destek vektör makineleri, karar ağacı, rastgele orman, bagging ve boosting algoritmaları buzlanma risk derecesi tahmininde denenmiş ve optimum yöntem belirlenmeye çalışılmıştır. Literatürde kullanılmayan farklı yapay zekâ yöntemleri de denenmiştir. Bu çalışma için en optimum yöntem boosting algoritması ile belirlenmiştir.

Buzlanma risk derecesi tahmini sonuçları literatürdeki çalışmalarda farklı değerlendirme ölçütleri kullanılarak değerlendirilmiştir. Fenar (2016), 470 adet veri kullanmıştır ve çalışmasını R^2 ve RMSE'ye göre değerlendirmiştir. Sınıflandırmada en optimum yöntemde R^2 için eğitim, tahmin ve test işlemi sonuçları sırasıyla 0.9992, 0.9901 ve 0.9918 sonuçlarını elde etmiştir. Sınıflandırmada en optimum yöntemde RMSE'ye göre değerlendirmede ise eğitim, tahmin ve test işlemi sonuçlarını 0.0425, 0.0410 ve 0.0420 olarak bulmuştur. Li vd. (2020), buzlanma risk derecesi tahmininin sonuçlarını sınıflandırma sonucundaki sınıflara göre vermişlerdir. 521 veriden, 512 veriyi doğru, 9 veriyi hatalı sınıflandırmışlardır. Kesinlik, duyarlılık ve F puanı değerlerini ise 0.95'in üzerinde değerlerde elde etmişlerdir. Tez çalışmasında buzlanma risk derecesi tahmininde dört önemli parametre kullanılmıştır. En optimum

sınıflandırma yönteminin duyarlılığı %88.67, kesinliği %88.36, doğruluğu %88.59 ve F puanı %88.51 olarak bulunmuştur.

Buzlanma risk derecesi tahmini yapan çalışmalar incelenmiş ve uygulanma durumları gözden geçirilmiştir. Gliwa vd. (2018), buzlanma risk derecesi tahmininde bulanık mantık yöntemini kullanmışlardır. Yöntemlerinde buzlanma risk derecesi ile birlikte, buzlanma yoğunluğunu da gösteren simulasyon grafiklerine yer vermişlerdir, ancak çalışmada sadece simulasyon yapılmış olup uygulaması verilmemiştir. Buzlanma risk derecesi sınıflandırmada tek bir yöntemi yani bulanık mantığı kullanmışlardır. Aykan vd. (2011), çalışmalarında bir F16 uçağında sadece buzlanmanın varlığını tespit ettirmişlerdir. Buzlanmanın varlığında güvenli uçuşu sağlatmışlardır. Fenar (2016), çalışmasında YSA ile buzlanma derecesi sınıflandırma sonuçlarını simulasyon olarak vermiştir. Tez çalışmasında buzlanma risk derecesi sınıflandırmasında denenen her yapay zekâ yönteminin doğruluk matrisleri verilmiş, optimum sonucu veren yapay zekâ yöntemi için simulasyon sonuçları verilmiştir. Ayrıca kod waijung bloksetler kullanılarak STM32F4 kontrol kartına gömülmüş ve gerçek problem üzerinde uygulanabilecek formata getirilmiştir.

KAYNAKLAR

Air Weather Service, (1980). Forecasters' guide on aircraft icing. *Air Weather Service Rep. AWS/TR-80/001*, 58. (Available from U.S. Air Force, Scott AFB, IL 62225).

Akalın, F. (2020). *İnce Bağırsak Görüntüleri Üzerinde Sezgisel Algoritma Teknikleri ile Polip Teşhisi.* (Yüksek Lisans Tezi, Sakarya Üniversitesi Fen Bilimleri Enstitüsü)

Akbal, Ö. (2019). *Uçaklarda Buzlanmanın Nümerik Olarak İncelenmesi ve Uçuş Profili Boyunca Hava Tahmin Modeli Uygulaması.* (Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü)

Akça, M.F. (2020). Karar Ağaçları (Makine Öğrenmesi Serisi-3). https://medium.com/deep-learning-turkiye/karar-ağaçları-makine-öğrenmesi-serisi-3-a03f3ff00ba5 (Son erişim tarihi: 23.01.2021)

Akça, M.F. (2020). Nedir Bu Destek Vektör Makineleri? (Makine Öğrenmesi Serisi-2). https://medium.com/deep-learning-turkiye/nedir-bu-destek-vektör makineleri-makine-öğrenmesi-serisi-2-94e576e4223e, (Son erişim tarihi: 23.04.2021)

Ali, T., Mohamed, A.Y. & Abaid, E.H. (2019). Control of induction motor drive using artificial neural network. *Journal of Engineering and Computer Science (JECS)*, *15*(2), 1-7.

Anonim, (2011). Scandinavian Airlines Flight 751. https://en.wikipedia.org/wiki/Scandinavian_Airlines_Flight_751#/media/File: Scandinavian_Airlines_Flight_751_wreckage2.png (Son erişim tarihi: 02.04.2021)

Anonim, (2015). Advisory Circular. https://www.faa.gov/documentLibrary/media/Advisory_Circular/AC_91-74B.pdf (Son erişim tarihi: 27.05.2021)

Anonim, (2019). Icing conditions. https://en.wikipedia.org/wiki/Icing_conditions (Son erişim tarihi: 02.04.2021)

Anonim, (2020). Bek Air'ın 2100 sefer sayılı uçuşu. https://tr.wikipedia.org/wiki/Bek_Air%27ın_2100_sefer_sayılı_uçuşu (Son erişim tarihi: 02.04.2021)

Anonim, (2021a). Aviation Safety Network. https://aviation-safety.net/database/ (Son erişim tarihi: 01.04.2021)

Anonim, (2021b). Saratov Airlines Flight 703. https://en.wikipedia.org/wiki/Saratov_Airlines_Flight_703 (Son erişim tarihi: 02.04.2021)

Anonim, (2021c). Sol Líneas Aéreas Flight 5428. https://en.wikipedia.org/wiki/Sol_Líneas_Aéreas_Flight_5428 (Son erişim tarihi: 02.04.2021)

Ayan, Ş.B. (2019). *Yüz Görüntülerinden Kırışıklık Tespiti Ve Sınıflandırılmasıyla Yaş Tahmini Algoritması Geliştirilmesi.* (Yüksek Lisans Tezi, Tobb Ekonomi ve Teknoloji Üniversitesi Fen Bilimleri Enstitüsü)

Aydın, İ. (2020). *Benzetim ve Modelleme Matlab Simulink.* https://docplayer.biz.tr/16731135-Bmu-421-benzetim-vemodelleme-matlab-simulink-ilhan-aydin.html (Son erişim tarihi: 25.06.2020)

Aydın, İ., Sevi, M. & Salur, M.U. (2018). *Detection of Fake Twitter Accounts with Machine Learning Algorithms*. In 2018 International Conference on Artificial Intelligence and Data Processing (IDAP), Malatya, 1-4. Doi: https://doi.org/10.1109/IDAP.2018.8620830

Aykan, R., Hacıyev, Ç. & Çalışkan, F. (2011). EKF ve Yapay Sinir Ağları ile Uçak Kanat Buzlanmalarının Tespiti ve Yeniden Şekillendirilebilir Kontrol. *İTÜ DERGİSİ/d*, *5*(2), 122-132.

Behrooz, F., Mariun, N., Marhaban, M.H. & Mohd Radzi, M.A. & Ramli, A.R. (2018). Review of Control Techniques for HVAC Systems—Nonlinearity Approaches Based on Fuzzy Cognitive Maps. *Energies*, *11*(3), 495. Doi: https://doi.org/10.3390/en11030495

Boduroğlu, K. (2014). *Uçaklarda Aerodinamik Yapısal ve Sistemsel Problemlere Yol Açan Donma Probleminin İrdelenmesi.* (Yüksek Lisans Tezi, Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü)

Breiman, L. (2001). Random Forests. *Machine Learning*, *45*(1), 5-32. Doi: https://doi.org/10.1023/A:1010933404324

Cao, Y., Tan, W. & Wu, Z. (2018). Aircraft icing: An ongoing threat to aviation safety. *Aerospace science and technology*, *75*, 353-385. Doi: https://doi.org/10.1016/j.ast.2017.12.028

Coşkun, H. (2016). *Ekstrasistol kalp seslerinin destek vektör makineleriyle sınıflandırılmasına yönelik android uygulaması geliştirilmesi.* (Yüksek Lisans Tezi, Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü)

Çamalan, İ. (2011). JAA ATPL Eğitimi. http://ibrahimcamalan.weebly.com/uploads/1/3/3/8/13385466/13_buzlanma.pdf (Son erişim tarihi: 02.06.2021)

Çayıroğlu, İ. (2020). Yapay Sinir Ağları. http://www.ibrahimcayiroglu.com/dokumanlar/ilerialgoritmaanalizi/ilerialgoritmaanalizi-5.hafta-yapaysiniraglari.pdf (Son erişim tarihi: 08.06.2020)

Çoban, R. (2018). *Havacılık Sektöründe Buzlanma Riski Üzerine Bir Uçak Kazası Araştırması.* Havacılık Emniyeti Yönetimi Sistemi Sempozyumu Ankara-Türkiye, 261-287.

Dilki, G. & Başar, Ö.D. (2020). İşletmelerin İflas Tahmininde K-En Yakın Komşu Algoritması Üzerinden Uzaklık Ölçütlerinin Karşılaştırılması. *İstanbul Ticaret Üniversitesi Fen Bilimleri Dergisi, 19*(38), 224-233.

Doğmuş, O., Yılmaz, Ş., Keçecioğlu, F., Yılmaz, A. & Özer, Z. (2013). *Tekstil Fabrikası Maketinin Nem ve Sıcaklığının Yapay Sinir Ağı ile Kontrolü.* Otomatik Kontrol Ulusal Toplantısı, TOK2013, Malatya, 26-28.

Dökme, R. (2019). *Kanat Profili Üzerinde Oluşan Buzun İki Boyutta Matematiksel Modellenmesi ve Sayısal Çözümü.* (Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü)

Duran, F. & Teke, M. (2019). Akıllı Yol Durum Sensörü Tasarımı. *Uluslararası Mühendislik Araştırma ve Geliştirme Dergisi, 11*(1), 396-401. Doi: https://doi.org/10.29137/umagd.510777

Eray, O. (2008). *Destek Vektör Makineleri ile Ses Tanıma Uygulaması.* (Yüksek Lisans Tezi, Pamukkale Üniversitesi Fen Bilimleri Enstitüsü)

Erdem, E.S. (2014). *Ses Sinyallerinde Duygu Tanıma ve Geri Erişimi.* (Yüksek Lisans Tezi, Başkent Üniversitesi Fen Bilimleri Enstitüsü)

Fenar, S. (2016). *Uçaklarda Uçuş Esnasında Meydana Gelebilecek Buzlanma Risk Derecesinin YSA Kullanılarak Tahmin Edilmesi.* (Yüksek Lisans Tezi, Erciyes Üniversitesi Fen Bilimleri Enstitüsü)

Genç, M.S., Özışık, G. & Kahraman, N. (2008). Düz flaplı NACA0012 Kanat Profilinin Aerodinamik Performansının İncelenmesi. *Isı Bilimi ve Tekniği Dergisi, 28*(1), 1-8.

Gliwa, W., Grzesik, N. & Kuźma, K. (2018). *Fuzzy logic controller design for the anti-icing system in the DA42 diamond aircraft.* In AIP Conference Proceedings (p. 020017). AIP Publishing LLC. Doi: https://doi.org/10.1063/1.5066479

Göktaş, M.E. & Yağanoğlu, M. (2020). Veri Bilimi Uygulamalarının Hastalık Teşhisinde Kullanılması: Kalp Krizi Örneği. *Journal of Information Systems and Management Research, 2*(2), 26-32.

Gültepe, Y. (2019). Makine Öğrenmesi Algoritmaları ile Hava Kirliliği Tahmini Üzerine Karşılaştırmalı Bir Değerlendirme. *Avrupa Bilim ve Teknoloji Dergisi,* (16), 8-15. Doi: https://doi.org/10.31590/ejosat.530347

Güneren, H. (2015). *Destek Vektör Makineleri Kullanarak Gömülü Sistem Üzerinde Yüz Tanıma Uygulaması.* (Yüksek Lisans Tezi, Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü)

Gürmen, C. (2020). *Saldırı Tespit Sistemleri İçin Makine Öğrenme Yöntemlerinin Performans Karşılaştırması.* (Yüksek Lisans Tezi, Harran Üniversitesi Fen Bilimleri Enstitüsü)

Güzel, S. (2018). *Veri Madenciliğinde Sınıflandırma Algoritmaları Kullanılarak Hepatit Hastalığının Tespiti.* (Yüksek Lisans Tezi, Kahramanmaraş Sütçü İmam Üniversitesi Fen Bilimleri Enstitüsü)

Hann, R. (2020). *Atmospheric Ice Accretions, Aerodynamic Icing Penalties, and Ice Protection Systems on Unmanned Aerial Vehicles.* (Doctoral Thesis, Norweigian University of Science and Technology)

Huber, M. (2013). Icing In Helicopters? Land Right Away. https://www.ainonline.com/aviation-news/general-aviation/2013-03-04/icing-helicopters-land-right-away (Son erişim tarihi: 29.05.2021)

Johansen, T.A. & Sorensen, K.L. (2017). *Flight test results for autonomous icing protection solution for small unmanned aircraft.* In 2017 International Conference on Unmanned Aircraft Systems (ICUAS). June 13-16, Miami, 971-980. Doi: https://doi.org/10.1109/ICUAS.2017.7991301

Kaya, D., Türk, M. & Kaya, T. (2018). Examining the Effect of Dimension Reduction on EEG Signals by K-Nearest Neighbors Algorithm. *El-Cezerî J. Sci. Eng, 5*, 591-595.

Kıvrak, M. (2021). *Sınıflandırma Problemlerinde Topluluk Öğrenme Yöntemlerinin İncelenmesi ve Küçük Hücreli Dışı Akciğer Kanseri Verileri Üzerine Bir Uygulaması.* (Doktora Tezi, İnönü Üniversitesi Sağlık Bilimleri Enstitüsü)

Kizir, S., Yaren, T. & Kelekçi, E. (2019). *Matlab Simulink Destekli Gerçek Zamanlı Kontrol.* Ankara, Seçkin yayınları.

Kizrak, M.A. (2020). Şu Kara Kutuyu Açalım: Yapay Sinir Ağları. https://ayyucekizrak.medium.com/şu-kara-kutuyu-açalim-yapay-sinir-ağları-7b65c6a5264a (Son erişim tarihi: 08.06.2020)

Kutlugün, M.A., Çakır, M.Y. & Kiani, F. (2017). *Yapay Sinir Ağları ve K-En Yakın Komşu Algoritmalarının Birlikte Çalışma Tekniği (Ensemble) ile Metin Türü Tanıma.* İstanbul: XXII. Türkiye'de Internet Konferansı (inet'tr17), Kasım Bahçeşehir Üniversitesi.

Li, S., Qin, J., He, M. & Paoli, R. (2020). Fast Evaluation of Aircraft Icing Severity Using Machine Learning Based on XGBoost. *Aerospace, 7*(4), 36. Doi: https://doi.org/10.3390/aerospace7040036

Metlek, S. & Kayaalp, K. (2020). *Makine öğrenmesinde, teoriden örnek matlab uygulamalarına kadar destek vektör makineleri.* İksad Publishing House, Ankara.

Mingione, G., Barocco, M., Denti, E., Bindi, F.G. & French, D.G.A.C. (1997). *Flight in icing conditions.* University of Pisa

Okatan, A. (2019). Uçaklar Havada Nasıl Hareket Eder? https://bilimgenc.tubitak.gov.tr/makale/ucaklar-havada-nasil-hareket-eder (Son erişim tarihi: 26.05.2021)

Öztürk, K. & Şahin, M. E. (2018). Yapay sinir ağları ve yapay zekâ'ya genel bir bakış. *Takvim-i Vekayi*, *6*(2), 25-36.

Palacios, J.L., Smith, E.C., Gao, H. & Rose, J.L. (2006). Ultrasonic shear wave anti-icing system for helicopter rotor blades. *In Annual Forum Proceedings-American Helicopter Society, 1492*. American Helicopter Society, Inc.

Politovich, M.K. (2003). Aircraft icing. *Encyclopedia of Atmospheric Sciences, 358*(1776), 68-75.

Saenz-Aguirre, A., Zulueta, E., Fernandez-Gamiz, U., Lozano, J. & Lopez-Guede, J.M. (2019). Artificial neural network based reinforcement learning for wind turbine yaw control. *Energies, 12*(3), 436. Doi: https://doi.org/10.3390/en12030436

Shen, X., Guo, Q., Lin, G., Zeng, Y. & Hu, Z. (2020). Study on Loose-coupling Methods for Aircraft Thermal Anti-Icing System. *Energies, 13*(6), 1463. Doi: https://doi.org/10.3390/en13061463

Simsek, H.K. (2018). *Makine Öğrenmesi Dersleri 5a: Random Forest (Sınıflandırma).* https://medium.com/data-science-tr/makine-öğrenmesi-dersleri-5-bagging-ve-random-forest-2f803cf21e07 (Son erişim tarihi: 23.04.2021)

Speiser, J.L., Miller, M.E., Tooze, J. & Ip, E. (2019). A comparison of random forest variable selection methods for classification prediction modeling. *Expert systems with applications, 134*, 93-101. Doi: https://doi.org/10.1016/j.eswa.2019.05.028

Şenel, F.A. (2020). Makine Öğrenmesi Algoritmaları Kullanılarak Kayısı İç Çekirdeklerinin Sınıflandırılması. *Bitlis Eren Üniversitesi Fen Bilimleri Dergisi, 9*(2), 807-815. Doi: https://doi.org/10.17798/bitlisfen.586042

Tuğ Karoğlu, T. (2018). *Lisans Yerleştirme Sınavında Yerleşme Başarısının Karar Ağaçlarına Göre 'Baggıng' Ve 'Boostıng' Yöntemleriyle Sınıflandırılması.* (Doktora Tezi, Van Yüzüncü Yıl Üniversitesi Fen Bilimleri Enstitüsü)

Ulgen, E.K. (2017). Makine Öğrenimi Bölüm-4 (Destek Vektör Makineleri). https://medium.com/@k.ulgen90/makine-öğrenimi-bölüm-4-destek-vektör-makineleri-2f8010824054, (Son erişim tarihi: 23.04.2021)

Uslu, M. (2020). Yapay Sinir Ağları (YSA) nedir? https://kod5.org/yapay-sinir-aglari-ysa-nedir/ (Son erişim tarihi: 08.06.2020)

Uzunoğlu, M. & Onar, Ö.Ç. (2003). *Her Yönü ile Matlab.* Ali Kızıl.

Ünlü, D. & Hilmioğlu, N. (2017). Uçaklarda Buzlanma ve Buzlanmayı Önleyecek Yöntemler. *Sürdürülebilir Havacılık Araştırmaları Dergisi, 2*(2), 75-80. Doi: https://doi.org/10.23890/SUHAD.2017.0204

Vertuccio, L., De Santis, F., Pantani, R., Lafdi, K. & Guadagno, L. (2019). Effective de-icing skin using graphene-based flexible heater. *Composites Part B: Engineering, 162*, 600-610. Doi: https://doi.org/10.1016/j.compositesb.2019.01.045

Vukits, T. (2002). *Overview and risk assessment of icing for transport category Aircraft and components.* In 40th AIAA Aerospace Sciences Meeting & Exhibit, January 14-17, Reno, 811. Doi: https://doi.org/10.2514/6.2002-811

Yavanoğlu, Ö. (2017). *Stilistik Özellikler Kullanılarak Yazar Tanıma İşinde Yapay Sinir Ağlarının Başarımının Değerlendirilmesi: Türkçe Köşe Yazıları.* (Yüksek Lisans Tezi, Hacettepe Üniversitesi Fen Bilimleri Enstitüsü)

Zhou, Z.H. (2012). *Ensemble Methods: Foundations and Algorithms.* CRC Press, United States of America.

ÖZGEÇMİŞ

Adı Soyadı :

Doğum Yeri ve Yılı :

Medeni Hali :

Yabancı Dili :

E-posta :

Taranmış Fotoğraf (3.5cm x 3cm)

Eğitim Durumu

Lise :

Lisans :

Mesleki Deneyim