



Determination Working Modes of Unmanned Aerial Vehicles (UAV) over Encrypted Wi-Fi Traffic Using Artificial Neural Networks

Cengiz SERTKAYA^{1,*} Osman COŞKUN²

¹Ostım Technical University, Faculty of Engineering, Department of Software Engineering, Ankara/Turkey

²Ostım Technical University, Institute of Natural and Applied Sciences, Department of Software Engineering, Ankara/Turkey

Graphical/Tabular Abstract

Article Info:

Research article
Received: 07.08.2021
Revision: 12.09.2021
Accepted: 20.09.2021

Highlights

- Artificial Neural Network Models.
- Principal Component Analysis.
- Data Mining.

Keywords

UAV Perception
Encrypted Wi-Fi Traffic
Artificial Neural Networks

In this study, models are proposed to determine operating modes of UAVs. In the proposed models, there are five step processes have been implemented.




Figure A. Applied process steps during the implementation of models

Purpose: This study, it is aimed to determine the different operating modes (One-Way Data Flow, Bi-Directional Data Flow) of UAVs. It is described how to apply data mining methods on the dataset of operating mode data obtained over Wi-Fi traffic. The dataset prepared for the application of artificial intelligence methods. The different model parameters of the Feed Forward and Back Propagation Artificial Neural Networks (FFBP ANN) are examined to understand how the model success is affected.

Theory and Methods: The proposed system's data obtained over Wi-Fi traffic. Data has been analyzed by using data mining methods such as data cleaning, principal component analysis and normalization. Then, four different FFBP ANN based artificial intelligence models are created. Developed models are explained in detail.

Results and Conclusion: In order to evaluate the success of the models, coefficient of determination (R), mean of squares of error (MSE) and accuracy methods are used. According to the results, the FFBP ANN model which includes two hidden layers with ten neurons, using the TRAINLM is the most successful model. The accuracy rate of this model is 99.29%. In addition, even if the same learning functions are used, it has been seen that the correct selection of system parameters such as the number of hidden layers and the number of neurons in these layers is important for the success of the models. In future studies, datasets obtained from other wireless connection technologies, including Bluetooth and GSM network communication technologies, can be created to determine the operating mode of UAVs. It has been suggested that different artificial intelligence methods can be applied to these datasets.



Determination Working Modes of Unmanned Aerial Vehicles (UAV) over Encrypted Wi-Fi Traffic using Artificial Neural Networks

Cengiz SERTKAYA^{1,*} Osman COŞKUN²

¹Ostim Teknik Üniversitesi, Mühendislik Fakültesi, Yazılım Mühendisliği Bölümü, Ankara/Türkiye

²Ostim Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Yazılım Mühendisliği Anabilim Dalı, Ankara/Türkiye

Abstract

Developing technology has also made the Unmanned Aerial Vehicles (UAV) widespread. While UAVs provide beneficial use in many sectors from engineering solutions to visual arts, they also come up with malicious uses and can even be used as a tool for committing crimes. Although the states are trying to register its use with legislation in order to prevent this problem, the problem has not been completely eliminated. The most important problem we face about UAVs is to be able to percept quickly and effectively for what purpose they are flying over a certain region. Although previous studies in the literature were partially successful in solving this problem, it could not be considered as an effective solution due to high costs and long detection time.

In this study, encrypted Wi-Fi traffic data of UAVs recorded in a circular area was used to determine the operating modes of UAVs. Since the amount of data and data processing speed are the most important factors in the detection of UAVs, data mining methods such as data cleaning, principal component analysis, and normalization were applied to the dataset. The operating modes of the UAVs were estimated with the feed-forward and back-propagation artificial neural networks selected as the artificial intelligence method and a 99.29% success rate was obtained.

Makale Bilgisi

Araştırma makalesi
Başvuru: 07.08.2021
Düzeltilme: 12.09.2021
Kabul: 20.09.2021

Keywords

UAV Perception
Encrypted Wi-Fi Traffic
Artificial Neural Networks

Anahtar Kelimeler

İHA Algılama
Şifrelenmiş Wi-Fi Trafik
Yapay Sinir Ağları

İnsansız Hava Araçlarının (İHA) Şifrelenmiş Wi-Fi Trafik Üzerinden Çalışma Modlarının Yapay Sinir Ağları Aracılığı İle Belirlenmesi

Özet

Gelişen teknoloji İnsansız Hava Araçları (İHA)'nın kullanımının yaygınlaşmasını sağlamıştır. İHA'lar mühendislik çözümlerinden görsel sanatlara kadar bir çok sektöre faydalı kullanım imkanı sağlarken aynı zamanda kötü amaçlı kullanımlarla da karşımıza çıkmakta, hatta suç işleme aracı olarak da kullanılabilir. Devletler bu sorunun önüne geçebilmek için mevzuatlar ile kullanımını kayıt altına almaya çalışıyor olsa da sorun tamamen ortadan kaldırılabilmemiş değildir. İHA'ların belirli bir bölge üzerinde hızlı ve etkin bir şekilde algılanabilmesi ve ne amaçla uçtuğunun tespit edilebilmesi karşımıza çıkan en önemli sorundur. Literatürde daha önce yapılan çalışmalar bu sorunun çözümünde kısmen başarılı olmuş olsa da yüksek maliyetler ve algılama süresi uzunluğu nedeniyle efektif bir çözüm olarak değerlendirilememiştir.

Bu çalışmada İHA'ların çalışma modlarının tespiti için dairesel bir alanda kaydedilen, İHA'lara ait şifrelenmiş wi-fi trafiği verileri kullanılmıştır. Eldeki veri miktarı ve veri işleme hızı İHA'ların tespitinde en önemli etken olduğundan veriseti üzerinde veri temizleme, temel bileşen analizi ve normalizasyon gibi veri madenciliği metodları uygulanmıştır. Yapay zeka yöntemi olarak seçilen ileri beslemeli ve geri yayımlı yapay sinir ağları ile İHA'ların çalışma modları tahmin edilmiş ve %99,29 başarı oranı elde edilmiştir.

1. GİRİŞ (INTRODUCTION)

Günümüz dünyasında artan teknolojik gelişmeler ile yüksek teknoloji üreten ve ürünlerini ihraç eden ülkeler uluslararası rekabet açısından diğer ülkelerin önüne geçmektedir. Bununla beraber gelişen üretim

yöntemleri, yüksek teknolojili ürünlerin daha uygun fiyatlar ile son kullanıcılara ulaşmasına imkan sağlamıştır. Bu sayede yüksek teknolojiye ihtiyaç duyan otonom araçların kullanımı da yaygınlaşmaya başlamıştır [1].

İnsansız Hava Araçları (İHA), üzerinde kullanıcıyı taşımayan hava araçlarıdır. İHA'lar uzaktan kontrol edilebilir veya belirlenen uçuş güzergahında otonom şekilde uçabilirler. Önceleri bir hobi aracı olan İHA'lar günümüzde gelişerek farklı alanlarda kullanılmaya başlanmıştır. Askeri kullanımlarının yanı sıra, kargo dağıtımını yapan, tarımsal ilaçlama işlerinde kullanılan veya arama kurtarma faaliyetlerinde kullanılan İHA'lar bulunmaktadır. Kamera sistemi veya farklı donanımlar entegre edilebilen İHA'lar ise mühendislik çözümlerinden görsel sanatlara kadar bir çok sektörde uygulama aracı olarak kullanılmaktadır[2].

İHA teknolojilerine günümüzde kolaylıkla ulaşılabilmesi, yüksek hız ve hareket kabiliyetlerine sahip olmaları nedenleriyle kullanımı oldukça yaygındır. İHA'ların yaygın kullanımının bir sonucu olarak kötü amaçlı kullanım örnekleri de oldukça fazladır. Saldırı amaçlı kullanımlar, özel hayatın ihlali ve casusluk faaliyetleri başlıca problemler arasındadır[3]. Örneğin 2017 yılı Eylül ayında Amerika Birleşik Devletleri (ABD) ordusuna ait bir helikopter, İHA saldırısı sonucu düşürülmüştür[4]. Yine ABD'de 2016 yılı Nisan ayında bir İHA, ABD Massachusett'te bir kişinin görüntülerini kayıt ederken tespit edilmiştir[5]. Yine ABD'de Başkanlık Sarayı üzerinde görüntü kaydı yapan bir İHA yakalanmıştır[6]. Ülkemizde 2019 yılında gerçekleştirilen bir suç olayında İHA kullanılmıştır[7]. Yine ülkemizde 2020 yılı Ekim ayında Diyarbakır ilinde yasak bölge statüsündeki askeri üs üzerinde casusluk amaçlı uçurulan İHA yakalanmıştır[8].

Yerel yönetimler ve güvenlik güçleri İHA'ların kullanımını belli kaideler çerçevesinde denetim altına almaya çalışmaktadır. Amerika Federal Havacılık Dairesi(FAA) bu konuda bir yönetmelik yayınlamıştır[9]. Ülkemizde de Sivil Havacılık Genel Müdürlüğü (SHGM) yine benzer bir yaklaşımla İHA'ları bir kimlik numarası ile kayıt altına almaya başlamış ayrıca İHA pilotlarının da sertifikalandırarak kaçak uçuşların denetimi hususunda kararname yayınlamıştır [10]. Yapılan denetim çalışmaları mevcut sorunların ortadan kalkmasını amaçlasada, kamu güvenliği ve kişisel hakların ihlali gibi konular tamamen ortadan kalkmış değildir.

İHA'ların tespiti için literatürde yapılan bir çalışmada, askeri kökenli bir teknoloji olan Radar(Radio Detection And Ranging) yöntemi ile radyo dalgalarının yansması üzerinden uzaktaki nesnelere ve bu nesnelere hız, yön ve mesafesini tespit etmeye yarayan cihaz geliştirilmiştir[11]. Başka bir çalışmada Multi-array Lidar (Light Detection and Ranging) yöntemi ile hedefi çok dizili lazer ışığıyla aydınlatarak ve yansıyan darbeleri bir sensörle ölçerek nesneye olan mesafeyi belirleyen bir ölçme yöntemi kullanılmıştır[12]. Diğer çalışmada Akustik Sistem(Acoustic System) adı verilen bir yöntem ile İHA'ları pervane seslerinin farklılığından yola çıkarak algılama temelli bir sistem geliştirilmiştir[13]. Bahsi geçen yöntemler hali hazırda kullanılıyor olsa da İHA'ların sahip oldukları hız ve hareket kabiliyeti ve şehirlerin genel yapısındaki binalar, ağaçlar gibi etkenler ile İHA'ların görünürlük, izleme ve takip sorunları halen çözümlenememiş problemler olarak karşımıza çıkmaktadır. Bu problemlerin çözümünde insan zekasına yakın çözümler üretebilen ileri düzey yaklaşımlara ihtiyaç duyulmaktadır.


İHA'lardan veri toplanmasına yönelik literatürde yapay zeka yöntemlerinin kullanıldığı çalışmalar bulunmaktadır. Yapılan bir çalışmada İHA'ların kullanıldığı hassas tarım uygulamalarında yapay zeka tabanlı görüntü işleme işlemi için İHA'lardan alınan görüntü verisi kullanılmıştır[14]. Diğer bir çalışmada İHA'lar üzerinden dinamik hedef takibi yapabilmek amacıyla alınan veriler üzerinde yapay zeka yöntemleri kullanılmıştır[15].

İHA'ların tespit edilmesi üzerine yapılan çalışmalar oldukça sınırlıdır. Yapılan bir çalışmada İHA'ların tespiti için için makine öğrenmesi metodlarından Yapay Sinir Ağları yöntemi (YSA) kullanılmıştır. Bu yöntemle İHA'ların çalışma modlarının tahmininde %92,5 başarı oranına ulaşılmıştır[16].

Bu çalışmada, İHA'ların farklı çalışma modlarının (Tek Yönlü Veri Akışı, Çift Yönlü Veri Akışı) tespitinin yapılması amaçlanmıştır. Wi-fi trafiği üzerinden elde edilmiş çalışma modu verileri üzerinde temizleme, temel bileşen analizi ve normalizasyon gibi veri madenciliği yöntemleri kullanılarak analizler gerçekleştirilmiştir. Ardından ileri beslemeli ve geri yayımlı YSA metoduna dayalı 4 ayrı yapay zeka modeli oluşturulmuştur. Geliştirilen modeller ile İHA'ların wifi trafiği verileri üzerinden çalışma modlarını tahmin edebilen özgün çözümler önerilmiştir.

2. MATERYAL VE METOTLAR (MATERIALS AND METHODS)

Modellerin geliştirilmesinden önce kullanılacak verilerin yapay zeka metodlarında kullanmaya uygun hale getirilmesi gerekmektedir. Bu amaçla Şekil 1’de verilen adımlar uygulanmıştır.



Şekil 1. Modellerin kurulması sırasında uygulanan adımlar

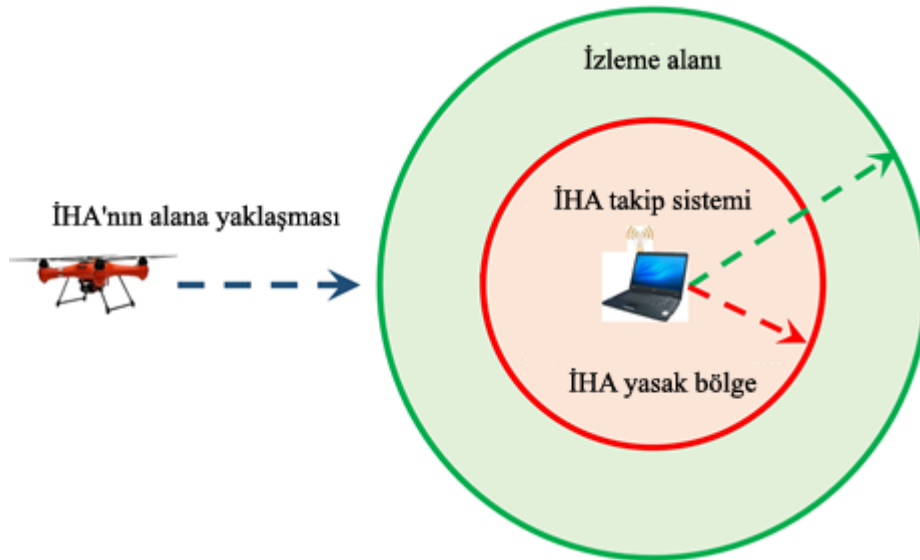
2.1. Veri Toplama (Data Collecting)

Bu çalışmada kullanılan veri seti, Kaliforniya Irvine Üniversitesine ait UCI makine öğrenmesi veritabanından elde edilmiştir. Veri setinde 2020 Nisan ayında toplanmış, üç farklı tip İHA’ya ait, veriler içermektedir. İHA’lar ortalama düzeyde kullanıcıların kullanabileceği cihazlar olup, marka ve modellerinin isimleri sırası ile ParrotBepot (1), DBPower UDI (2), DJI Spark (3) olarak adlandırılmaktadır[18]. Kullanılan İHA’ların görselleri Şekil 2’de gösterilmiştir.



Şekil 2. Veri setinde yer alan İHA türleri[18]

Veri toplama işlemi ağ trafiğinden veri elde etmeyi sağlayan Wireshark programı kullanılarak yapılmıştır. Wireshark programı bir ağ paket ve protokol analiz (sniffer) yazılımıdır. Bu sayede bir bilgisayar ağı üzerinde akan trafiğin yakalanmasına ve izlenmesine imkan sağlamaktadır. Veri toplama işleminde uygulanan senaryoda, merkezde konumlandırılmış Wi-fi anteni ile 70 metre çapındaki dairesel alanda gerçekleşen tüm Wi-Fi trafiği kaydedilmiştir[19]. Senaryo görseli Şekil 3’de gösterilmiştir.



Şekil 3. Veri toplama sistemi senaryosu[18]

Veri toplama işlemi yapılırken İHA’ların tek yönlü veri akış trafiği ve çift yönlü veri akış trafiği izlenmiş ve kaydedilmiştir[18]. Wi-fi kullanılarak yapılan iletişimde cihazlar verileri farklı güvenlik seviyelerinde şifrelenerek gönderilmektedir. Şifrelenmiş bu veri paketlerinin boyutları üzerinden tahmin yapılarak İHA’ların çalışma modları tespit edilmiştir. Bu senaryolar uygulanarak elde edilen veri seti üzerinde “Özellik hesaplamalı bağımlılık grafiğini kullanarak büyük ölçekli maliyete duyarlı sınıflandırma” istatistik yöntemi kullanılmış, 26,600 satır ve 18 öznitelikten oluşan veri seti elde edilmiştir[20]. Öznitelikler ve açıklamaları Tablo 1’de gösterilmiştir.

Tablo 1. Veri seti öznitelikleri

No	Öznitelik	Açıklama
1	Size Mean	Tek Yönlü Wi-fi Trafığı Ortalama Değer
2	Size Median	Tek Yönlü Wi-fi Trafığı Ortanca Değer
3	Size MAD	Tek Yönlü Wi-fi Trafığı Ortalama Mutlak Sapma
4	Size STD	Tek Yönlü Wi-fi Trafığı Standart Sapma
5	Size Skewness	Tek Yönlü veri Trafığı Çarpıklık Değeri
6	Size Kurtosis	Tek Yönlü Wi-fi Trafığı Yığılma Değeri
7	Size Max	Tek Yönlü Wi-fi Trafığı En Büyük Değer
8	Size Min	Tek Yönlü Wi-fi Trafığı En Küçük Değer
9	Size Mean Square	Çift Yönlü Wi-fi Trafığı Kareler Ortalaması
10	Interval Mean	Çift Yönlü Wi-fi Trafığı Ortalama Değer
11	Interval Median	Çift Yönlü Wi-fi Trafığı Ortanca Değer
12	Interval Mad	Çift Yönlü Wi-fi Trafığı Ortalama Mutlak Sapma
13	Interval Std	Çift Yönlü Wi-fi Trafığı Standart Sapma
14	Interval Skewness	Çift Yönlü Wi-fi Trafığı Çarpıklık Değeri
15	Interval Kurtosis	Çift Yönlü Wi-fi Trafığı Yığılma Değeri
16	Interval Max	Çift Yönlü Wi-fi Trafığı En Büyük Değer
17	Interval Min	Çift Yönlü Wi-fi Trafığı En Küçük Değer
18	Interval Mean Square	Çift Yönlü Wi-fi Trafığı Kareler Ortalaması
19	UAV Type	İHA türü

2.2. Veri Temizliği (Data Cleaning)

Veri seti analizi sırasında uygulanması gereken adımlardan ilki veri kaydı sırasında hatalardan veya gürültüden kaynaklı verilerin tespit edilmesidir. Bu tür veriler modellerin başarısını olumsuz etkileyeceğinden veri setinden çıkarılmalıdır. Bu amaçla herbir öznitelik için veri değişim aralıklarını gösteren grafikler çizilerek incelenmiştir. Veri setini temsil etmediği düşünülen hatalı verilerin tespitinde pik yapmış olan veriler veri setinden çıkarılmıştır. Bu işlem sonucunda 396 adet satır veri setinden silinmiştir.

2.3. Temel Bileşen Analizi (Principal Component Analysis)

Temel bileşen analizi(PCA), yapay zeka modellerinin oluşturulmasında yaygın olarak kullanılan çok değişkenli bir istatistiksel yöntemdir. Bu yöntemde değişkenlerin arasındaki bağlantı, değişkenlerin doğrusal birleşimleri vasıtasıyla belirlenebilmektedir[21,22]. Bu çalışmada kullanılma amacı, giriş öznitelikleri ile çıkış öznitelikleri arasındaki ilişkinin ne düzeyde olduğunun ortaya çıkarılmasıdır. Analiz sonucunda ilişkinin düzeyi eşik değer altında olan giriş öznitelikleri belirlenerek veri setinden çıkarılmaktadır. Bu sayede model daha az sayıda giriş ile çalıştığından işleyeceği veri sayısı azalır ve daha hızlı sonuç üretebilmektedir[21]. Denklem 1’de yer alan formüle kullanılarak gerçekleştirilen PCA analizine göre elde edilen sonuçlar Tablo 2’de gösterilmektedir.

$$Corr(X, Y) = \frac{E(X-\mu_x)(Y-\mu_y)}{\sigma_x\sigma_y} \quad (1)$$

Burada E beklenen değer operatörünü, X ve Y beklenen μ_x ve μ_y değerlerine karşılık seçilen rastgele değerleri, σ_x ve σ_y ise standart sapma değerlerini ifade etmektedir.

Tablo 2. PCA analizi sonuçları

No	Öznitelik	PCA
1	Size Mean	-0.001
2	Size Median	0.001
3	Size MAD	-0.002
4	Size STD	-0.008
5	Size Skewness	-0.025
6	Size Kurtosis	-0.011
7	Size Max	0.001
8	Size Min	-0.052
9	Size Mean Square	0.001
10	Interval Mean	0.255
11	Interval Median	0.442
12	Interval Mad	0.325
13	Interval Std	0.257
14	Interval Skewness	-0.026
15	Interval Kurtosis	0.013
16	Interval Max	0.361
17	Interval Min	-0.051
18	Interval Mean Square	0.310

PCA sonuçları ile birlikte giriş özniteliklerinin, çıkış özniteliği olan İHA türü arasında bulunan ilişki dereceleri görülmektedir. Öznitelik azaltma işlemi için belirlenen eşik değerin hangi değer olarak seçileceği yönünde literatürde standart bir yöntem bulunmadığı ve problem özgü seçilmesi gerektiği önerilmiştir[21]. Bu nedenle bu problem için eşik değeri 0.01 olarak seçilmiştir. Buna göre eşik değerin altında kalan, tabloda kırmızı ile işaretlenmiş, sırasıyla 1,2,3,4,7 ve 9 nolu öznitelikler verisetinden çıkarılmıştır.

PCA analizinin ardından elde kalan 12 giriş özniteliği için veri setinin son halinde özniteliklerin değişim aralıkları, ortalama ve standart sapma değerleri incelenmiş ve sonuçlar Tablo 3’de gösterilmiştir.

Tablo 3. PCA sonrası özniteliklerin min, max, ortalama ve standart sapma değerleri

No	Öznitelik	Min	Max	Ortalama	Standart Sapma
1	Size Skewness	-1,93	9,84	4	2,25
2	Size Kurtosis	-1,98	98	23,03	23,62
3	Size Min	0	0.008	0,007	0
4	Interval Mean	63,52	1675,72	747,56	0,32
5	Interval Median	0,20	761,06	352,09	514,34
6	Interval Mad	62	1676	864,56	657,85
7	Interval Std	0	1136,41	97,63	192,50
8	Interval Skewness	-9,70	9,84	-0,50	2,22
9	Interval Kurtosis	-2,01	98,01	4,63	14,08
10	Interval Max	68	1676	1121,86	657,78
10	Interval Min	61	1676	167,02	151,79
12	Interval Mean Square	63,98	1675,72	843,75	550,86

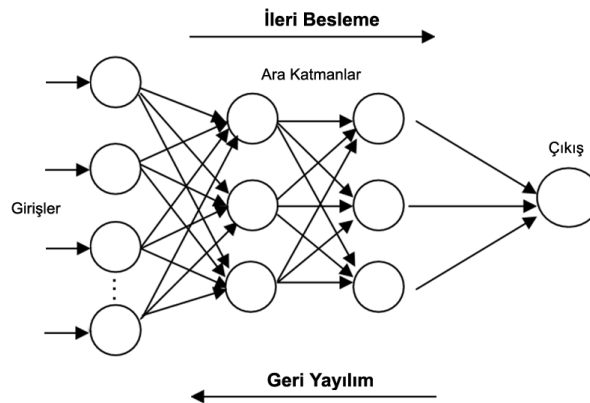
Özniteliklerin veri değişim aralıkları incelendiğinde birbirinden oldukça farklı olduğu görülmektedir. Bu tür bir durumda kurulacak yapay zeka model başarısını etkileyeceğinden özniteliklerin aynı değer aralığına getirilmesi önemlidir. Bu amaçla öznitelikler yapay zeka modellerine verilmeden önce normalizasyon işlemi uygulanarak özniteliklerin değer değişim aralığı 0-1 aralığına getirilmiştir. Normalizasyon işlemi için kullanılan formül Denklem 2’de gösterilmiştir.

$$N(x_i) = \frac{x_i - x_{min}}{x_{max} - x_{min}} \quad (2)$$

Burada x_i özneliğin orijinal değerini, $N(x_i)$ normalize sonucu oluşan değeri, x_{max} ve x_{min} sırasıyla özneliğin maximum ve minimum değerlerini ifade etmektedir

2.4. Yapay Sinir Ağları (Artificial Neural Networks)

Yapay sinir ağlarında (YSA) başarılı sonuç elde edebilmek için çözülmek istenen probleme özgü modelin seçilmesi ve öğrenme parametrelerinin doğru ayarlanması önemlidir. parametrelerin model seçimi problemin sonuçlarına doğrudan etki etmektedir. Var olan problemin nitelikleri ve daha önce yapılan benzer çalışmalardan edinilen bilgiler ışığında İleri Beslemeli ve Geri Yayılımlı (FFBP) yapay sinir ağı model olarak seçilmiştir. FFBP YSA yöntemi veri akışının hep ileri doğru olduğu, katmanlar arasında döngü bulunmayan yapay sinir ağı türüdür[16]. FFBP YSA yönteminin sembolik gösterimi Şekil 4’de gösterilmiştir.

**Şekil 4.** FFBP YSA yönteminin sembolik gösterimi

FFBP YSA yönteminde model girişine verilen öznitelikler üzerinden model çıkış özneliği arasında katmanlardaki ağırlık değerlerini belirleyerek bir formül oluşturulmaya çalışılır. Tahmin edilen ile gerçek

çıkış değeri arasındaki farkı minimize etmeye çalışacak şekilde geriye dönerek katmanlardaki ağırlık değerleri değiştirilir ve bu şekilde problemi ifade eden modeli oluşturmaya çalışmaktadır.

FFBP YSA modelinin kurulması ve simülasyon süreçlerinde Matlab programı kullanılmıştır. Oluşturulan modellerde çeşitli denemeler yapılarak en uygun modellerin ne kadar ara katmandan oluşacağı, katmanlardaki nöron sayısı, öğrenme fonksiyonu olarak hangisini kullanması gerektiği belirlenmiştir. En iyi sonuçların bu problem için Levenberg-Marquardt (TRAINLM) ve Momentumlu Gradyan İnişi (TRAINGDM) öğrenme fonksiyonları kullanılarak elde edildiği görülmüştür.

TRAINLM öğrenme fonksiyonu Levenberg-Marquardt optimizasyonuna göre ağırlık ve bias değerlerini güncelleyen bir ağ eğitim işlevidir. Fonksiyonun temelinde Levenberg-Marquardt algoritması yer almaktadır[23]. Parametrelerin güncelleme işleminin gerçekleştirilmesini ise bütün girdiler için hesaplanan hata vektörü ve Jacobian matrisi değerleri ile yapmaktadır. Fonksiyon içerisinde Denklem 3 ve 4'teki hesaplamalar yapılmaktadır[24].

$$e = \frac{1}{2} \sum (y_i - t_i) \quad (3)$$

Burada E , istenen y_i ile gerçekleşen t_i değerleri arasındaki hata toplamlarının kare kökünü ifade etmektedir.

$$w_{i+1} = w_i - [J^T J + \mu I]^{-1} J^T e \quad (4)$$

Burada bağlantının ağırlık değerini belirten w değeri hesaplanırken kullanılan, J Jacobian matrisini, μ sönümlenme terimini ve I kimlik matrisini ifade etmektedir.

TRAINLM fonksiyonu kullanan ağın eğitimi daha kısa sürede gerçekleşmektedir. Ağın genelinde iyileşme durduğunda eğitim sonlanmaktadır [16].

TRAINGDM öğrenme fonksiyonunda, adaptif öğrenme oranıyla radyan inişine göre ağırlık değerlerini güncelleyen bir ağ eğitim işlevidir. TRAINGDM fonksiyonunda öğrenme parametreleri belirlenirken ağın öğrenme hızının artırılması, öğrenme esnasında oluşabilecek osilasyonların giderilmesi ve lokal minimumlardan kaçılması gibi özelliklere sahiptir[25]. Fonksiyon hesaplanmasında Denklem 5 ve 6'daki formüller kullanılmaktadır[26].

$$D(w_t) = S f'(w_{t-1}) + M D(w_{t-1}) \quad (5)$$

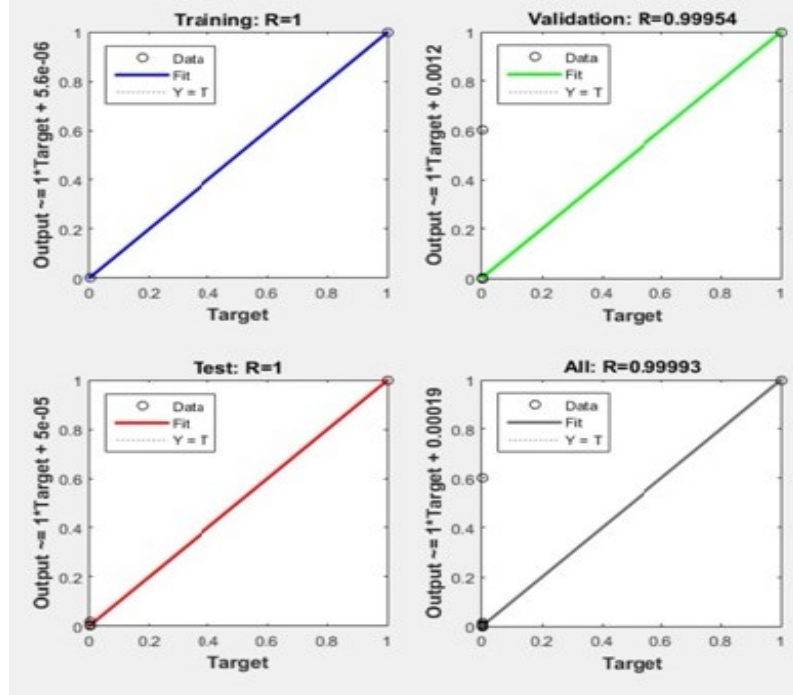
Burada D , w ağırlık değerinin t anındaki değişimini, S öğrenme oranını, M momentum değerini ifade etmektedir.

$$w_t = w_{t-1} - D(w_t) \quad (6)$$

Burada w ağırlık değerinin t anındaki değeri hesaplanmaktadır.

2.5. YSA Modellerinin Uygulanması (Application of ANN Models)

Modellerin kullanacağı toplam verisetinde, verilerin %60'ı eğitim, %40'ı test seti olmak üzere ayrılmıştır. Modellerin uygulanmasında Matlab programı kullanılmıştır. Yapılan denemeler sonucunda Matlab programında en iyi sonuçların elde edildiği, ara katmanlarında 10 nöron bulunan ve 2 ara katman sayısına sahip TRAINLM öğrenme fonksiyonunu kullananan modele ait, eğitim ve test simülasyon aşamalarını içeren görsel Şekil 5'te gösterilmektedir.



Şekil 5. Matlab YSA eğitim simülasyonu

Şekil 5 incelendiğinde öğrenme sürecinin ideal şartlarda tamamlandığı görülmektedir. Burada regresyon(R) değerinin 1'e yaklaşması hedeflenerek simülasyon devam ettirilmektedir. 1'e ne kadar yakın olursa ilgili süreç okadar başarılıdır[27]. Test grafiğinde görüldüğü üzere tahmin aşaması da başarılı bir şekilde gerçekleşmiştir

3. SONUÇLAR VE TARTIŞMA (RESULTS AND CONCLUSION)

Modellerin başarı değerlendirmesinin yapılması amacıyla determinasyon katsayısı(R), hata karelerinin ortalaması(MSE) ve doğruluk (accuracy) yöntemleri kullanılmıştır. Simülasyon sonrası test verileri için elde edilen bu değerler Tablo 4'de gösterilmektedir.

Tablo 4. Geliştirilen YSA modelleri ve başarı değerleri

Model No	Öğrenme Fonksiyonu	Nöron Sayısı	Ara Katman Sayısı	R	MSE	Doğruluk
1	TRAINGDM	10	2	0,55	0,43	56,29
2	TRAINGDM	100	3	0,74	0,18	81,59
3	TRAINLM	250	2	0,74	0,18	81,59
4	TRAINLM	100	2	0,98	0,01	98,10
5	TRAINLM	10	2	0,99	0,007	99,29

Elde edilen sonuçlara göre, FFBP YSA modellerinden TRAINLM öğrenme fonksiyonunu kullanan 2 ara katmanı olan ve her bir ara katmanda 10 nörona sahip model %99,29 doğruluk oranıyla en başarılı model olmuştur

Bu çalışmada yüksek teknoloji ürünlerinden olan ve son yıllarda kullanımı oldukça yaygın hale gelen İHA'ların çalışma modlarının tespiti için, üç farklı İHA modeline ait kablosuz trafik verileri analiz

edilmiştir. Veriler üzerinde gerçekleştirilen analiz yöntemleri ile kablosuz ağ trafiği verilerinin yapay zeka modellerine verilmeden önce uygulanması gereken adımlar açıklanmıştır.

Çalışmada ileri beslemeli ve geri yayımlı YSA metodu kullanılarak farklı öğrenme algoritmaları ve ara katman değerleri üzerinden modeller oluşturulmuştur. En iyi başarının elde edildiği modelde %99,29 gibi oldukça yüksek bir doğruluk oranına ulaşılmıştır. Bu değerlere göre geliştirilen model kullanılarak İHA çalışma modlarının başarılı şekilde tahmin edilebileceği gösterilmiştir.

Ayrıca çalışmada aynı öğrenme fonksiyonları kullanılsa dahi ara katman sayısı ve bu katmanlardaki nöron sayısı gibi sistem parametrelerinin doğru seçilmesinin model başarısında önemli olduğu görülmüştür. Nitekim aynı öğrenme fonksiyonuna sahip olmasına karşın sistem parametrelerinin farklı seçilmesi 3 ve 4 nolu modellerde başarı oranını etkilemiştir.

Günümüzde gelişen teknoloji ile birlikte henüz yaygın olmasa da wi-fi dışında farklı kablosuz iletişim teknolojileri de İHAlarda kullanılmaya başlanmıştır. Bu anlamda ileriki çalışmalarda İHA'ların çalışma modu tespitinde, içinde bluetooth ve GSM şebekesi iletişim teknolojilerinin de olduğu, bu teknolojilere ait ağ bilgilerinin yer aldığı verisetleri oluşturulabilir. Bu veriler üzerinde yapay sinir ağı modelleri oluşturulabilir. Ayrıca farklı yapay zeka metodları da uygulanarak sonuçlar karşılaştırılabilir.

KAYNAKLAR (REFERENCES)

- [1] Erdiñ Z., Aydınbaş G., Yüksek Teknoloji Ürünleri İhracı ve Belirleyicileri: Panel Veri Analizi, International Social Mentality and Researcher Thinkers Journal, No. 30 (2020) 496-507.
- [2] Mohamed N., Al-Jaroodi J., Jawhar I., Idries A., Mohammed F., Unmanned Aerial Vehicles Applications In Future Smart Cities, Technological Forecasting & Social Change, 153 (2020) 119293.
- [3] Altawy R., Youssef A.M., Security, Privacy, and Safety Aspects of Civilian Drones: A Survey, ACM Transactions on Cyber-Physical Systems, 1(2) (2016) 1-25.
- [4] NYPOST, Civilian Drone Crashes Into Army Helicopter, <https://nypost.com/2017/09/22/army-helicopter-hit-by-drone>.
- [5] RT, Peeping Drone: UAV Hovers Outside Of Massachusetts Teen's Bedroom Window, <https://www.rt.com/usa/341404-drone-privacy-teenager-window>.
- [6] NYTIMES, White House Drone Crash Described As A U.S. Worker's Drunken Lark, <https://www.nytimes.com/2015/01/28/us/white-house-drone.html>.
- [7] CNNTURK, Ankara'da Lüks Villadan 4 Milyon Liralık Hırsızlık... Günlerce Drone İle İzlemişler, <https://www.cnnturk.com/turkiye/ankarada-luks-villadan-4-milyon-liralik-hirsizlik-gunlerce-drone-ile-izlemisler>.
- [8] CNNTURK2, Atatürk Havalimanı Üzerine Drone Uçaran Kişiyeye Hapis Cezası Verildi, <https://www.cnnturk.com/turkiye/ataturk-havalimani-uzerine-drone-ucaran-kisiye-hapis-cezasi-verildi>.
- [9] FAA, Federal Aviation Administration, <https://www.faa.gov>.
- [10] İHAY, İHA Yönetmeliği, http://web.shgm.gov.tr/documents/sivilhavacilik/files/mevzuat/sektorel/talimatlar/SHT-IHA_WEB.pdf.
- [11] Moses A., Rutherford M.J., Valavanis K.P., Radar-Based Detection and identification for Miniature Air Vehicles, IEEE International Conference on Control Applications (CCA) Part of 2011 IEEE Multi-Conference on Systems and Control, Denver, 28-30 (2011) 933-940.

- [12] Salhi M., Boudriga N., Multi-Array Spherical LIDAR System for Drone Detection, 22nd International Conference on Transparent Optical Networks (ICTON), (2020), doi-10.1109/ICTON51198.2020.9203381.
- [13] Sedunov A., Haddad D., Salloum H., Sutin A., Sedunov N., Yakubovskiy A., Stevens Drone Detection Acoustic System and Experiments in Acoustics UAV Tracking, IEEE International Symposium on Technologies for Homeland Security (HST), USA, (2019), doi- 10.1109/HST47167.2019.9032916.
- [14] Ampatzidis Y., Partel V., Costa L., Agroviz: Cloud-Based Application To Process, Analyze And Visualize UAV Collected Data For Precision Agriculture Applications Utilizing Artificial Intelligence, Computers and Electronics in Agriculture 174 (2020) 105457, doi-10.1016/j.compag.2020.105457.
- [15] Chithapuram C., Kumar A., Artificial Intelligence Guidance for Unmanned Aerial Vehicles in Three Dimensional Space, International Conference on Contemporary Computing and Informatics (IC3I), Mysore India, (2014), doi-10.1109/IC3I.2014.7019634.
- [16] Alipour-Fanid A., Dabaghchian M., Wang N., Wang P., Zhao L., Zeng K., Machine Learning-Based Delay-Aware UAV Detection and Operation Mode Identification over Encrypted Wi-Fi Traffic, IEEE CNS International Workshop On Cyber-Physical Systems Security (CPS-Sec), USA, (2019), doi-10.1109/TIFS.2019.2959899.
- [17] UCI, Unmanned Aerial Vehicle (UAV) Intrusion Detection Data Set, <https://archive.ics.uci.edu/ml/datasets/Unmanned+Aerial+Vehicle+%28UAV%29+Intrusion+Detection>.
- [18] Banerjee U., Ashutosh V., Mukul S., Evaluation of the Capabilities of WireShark as a tool for Intrusion Detection, International Journal of Computer Applications 6-7 (2010), doi-10.5120/1092-1427.
- [19] McGregor A., Hall M., Lorier P., Brunskill J., Flow Clustering Using Machine Learning Techniques, Lecture Notes in Computer Science, 3015 (2004) 205-214.
- [20] Li Q., Alipour-Fanid A., Slawski M., Ye Y., Wu L., Zeng K., Zhao L., Large-scale Cost-aware Classification Using Feature Computational Dependency Graph, IEEE Transactions on Knowledge and Data Engineering, 33-5 (2021) 2029-2044.
- [21] Sertkaya C., Yurtay N., Artificial Immune System Based Wastewater Parameter Estimation, Turkish Journal of Electrical Engineering & Computer Sciences, 26 (2018) 3356- 3366.
- [22] Yıldız K., Çamurcu Y., Veri Madenciliğinde Temel Bileşenler Analizi ve Negatifsiz Matris Çarpanlarına Ayırma Tekniklerinin Karşılaştırmalı Analizi, Akademik Bilişim'10, (2010).
- [23] Çizmeçi, H., Atila, Ü., Karaş, İ. R., Yapay Sinir Ağları Kullanılarak Yükseköğretimde Öğrenci Adaylarının Başarı Durumlarının Tahmin Edilmesi, Karabük Üniversitesi 20. Akademik Bilişim 2018 Konferansı, (2018) 183–186.
- [24] Arthur, C. K., Temeng, V. A., Ziggah, Y. Y., Performance Evaluation of Training Algorithms in Backpropagation Neural Network Approach to Blast-Induced Ground Vibration Prediction. Ghana Mining Journal, 20-1 (2020) 20–33.
- [25] Qian N., On The Momentum Term İn Gradient Descent Learning Algorithms, Neural Networks 12 (1999) 145-151.
- [26] GDM, Gradient Descent With Momentum from Scratch, <https://machinelearningmastery.com/gradient-descent-with-momentum-from-scratch>
- [27] Ozkan M. T., Kaygısız M., Elipsel Delikli Plakalarda Oluşan Gerilmelerin Tanımlanması ve Yapay Sinir Ağları ile Tahmini, GU J Sci, Part C, 4-3 (2016) 135-145.