



POLİTEKNİK DERGİSİ

JOURNAL of POLYTECHNIC



Evrişimli sinir ağı kullanarak dengesiz doppler radar verisinde hedef tespiti

Target detection in unbalanced doppler radar data using convolutional neural network

Yazar(lar) (Author(s)): Muhammed ERDOĞAN¹, Oktay YILDIZ²

ORCID¹: 0000-0003-0952-3206

ORCID²: 0000-0001-9155-7426

To cite to this article: Erdoğan M. ve Yıldız O., “Evrişimli sinir ağı kullanarak dengesiz doppler radar verisinde hedef tespiti”, *Journal of Polytechnic*, 27(4): 1317-1326, (2024).

Bu makaleye şu şekilde atıfta bulunabilirsiniz: Erdoğan M. ve Yıldız O., Evrişimli sinir ağı kullanarak dengesiz doppler radar verisinde hedef tespiti, *Politeknik Dergisi*, 27(4): 1317-1326, (2024).

Erişim linki (To link to this article): <http://dergipark.org.tr/politeknik/archive>

DOI: 10.2339/politeknik.1180081

Evrişimli Sinir Ağı Kullanarak Dengesiz Doppler Radar Verisinde Hedef Tespiti

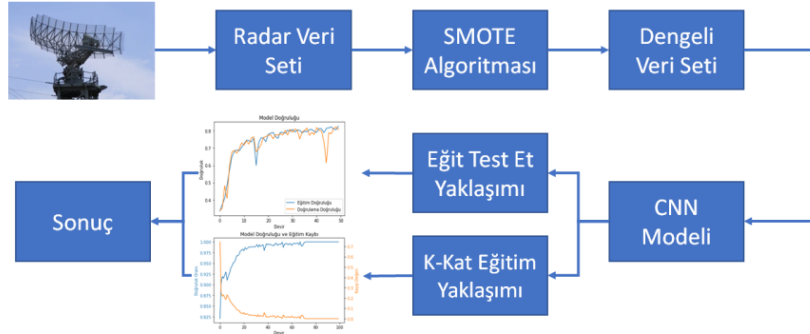
Target Detection in Unbalanced Doppler Radar Data Using Convolutional Neural Network

Önemli noktalar (Highlights)

- ❖ Doppler Radar verisi kullanılarak hedef tespit algoritması geliştirilmiştir. / A Target detection algorithm has been developed using Doppler Radar data.
- ❖ Sınıflandırma algoritmasında kullanılan eğitim yaklaşımları karşılaştırılmıştır. / The training approaches used in the classification algorithm are compared.
- ❖ Doppler radar veri seti SMOTE algoritması ile dengeli hale getirilmiştir. / The Doppler radar data set has been balanced with using SMOTE algorithm.

Grafik Özet (Graphical Abstract)

Doppler radarı veri seti dengeli hale getirildikten sonra CNN modeli iki farklı eğitim yaklaşımıyla eğitilerek sonuçlar değerlendirilir. / After the doppler radar data set is balanced, the CNN model is trained with two different training approaches and the results are evaluated.



Şekil. Doppler radar verisi ile hedef tespiti için oluşturulan yapı. / **Figure.** The framework which is implemented for target detection with Doppler radar data.

Amaç (Aim)

Doppler radar verisinin dengeli hale getirilmesi ve CNN modelinin eğitilmesi ile hedef sınıflandırmasının yapılması. / Balancing doppler radar data and training the CNN model for Target classification.

Tasarım ve Yöntem (Design & Methodology)

Ön işleme aşamasında SMOTE algoritması, sınıflandırma için CNN Modeli geliştirilmiştir. Eğit Test Et ve K-Kat eğitim yaklaşımı kullanılmıştır. / The SMOTE algorithm is used for pre-processing stage and a CNN model is developed for classification. Train-Test and K-Fold training approach is experimented.

Özgünlük (Originality)

Dengesiz Doppler Radarı verisi, SMOTE algoritması ile yeniden düzenlenmiş, K-Kat yaklaşımı ile CNN modeli oluşturulmuştur. / A Target classification framework is implemented which has stages SMOTE algorithm for balancing data set and a CNN model with K-Fold training approach.

Bulgular (Findings)

SMOTE algoritmasının eğitim başarısını artırdığı, K-Kat eğitim yaklaşımının eğit test et yaklaşımına göre daha başarılı olduğu görülmüştür. / It is experienced that, SMOTE algorithm increases the training accuracy and K-Fold approach is more successful than train-test approach.

Sonuç (Conclusion)

Dengesiz verinin sınıflandırılması ciddi bir problemdir. Gerçekleştirilen çalışmada belirlenen CNN model ile %99,9 sınıflandırma başarısına ulaşıldığı görülmüştür. / Classification of unbalanced data is a critical problem. The trained model is reached up to %99,9 accuracy.

Etik Standartların Beyanı (Declaration of Ethical Standards)

Bu makalenin yazar(lar)ı çalışmalarında kullandıkları materyal ve yöntemlerin etik kurul izni ve/veya yasal-özel bir izin gerektirmediğini beyan ederler. / The author(s) of this article declare that the materials and methods used in this study do not require ethical committee permission and/or legal-special permission.

Evrişimli Sinir Ağı Kullanarak Dengesiz Doppler Radar Verisinde Hedef Tespiti

Araştırma Makalesi / Research Article

Muhammed ERDOĞAN^{1*}, Oktay YILDIZ¹

¹Fen Bilimleri Enstitüsü, Bilgisayar Mühendisliği Ana Bilim Dalı, Gazi Üniversitesi, Türkiye

(Geliş/Received : 25.09.2022 ; Kabul/Accepted : 01.03.2023 ; Erken Görünüm/Early View : 14.06.2023)

ÖZ

Kritik öneme sahip askeri ve sivil yerleşkelerin korunması geçmişte olduğu gibi günümüzde önemini korumaktadır. Bu amaçla, çeşitli sensörler barındıran sistemler geliştirilmektedir. Sensörlerin sağladığı verilerden bilginin elde edilmesi donanımların en verimli şekilde kullanılması açısından önemlidir. Radar sistemleri keşif, gözetleme ve tespit amacıyla sıklıkla kullanılmaktadır. Radar ile tespit edilen nesnelerin sınıflandırılması amacıyla kural tabanlı ve makine öğrenmesi tabanlı yöntemler mevcuttur. Makine öğrenmesi tabanlı yaklaşımlarda uzman görüşüne gerek kalmadan zaman içerisinde hedef nesnenin karakteristik özellikleri model tarafından öğrenilir. Bu sebeple bu yöntemler kural tabanlı yöntemlere nazaran daha avantajlıdır. Gerçekleştirilen bu çalışmada, dengesiz Doppler Radarı verisi üzerinde İHA'ların diğer nesnelere ayırt edilmesi amacıyla hedef sınıflandırması yapılmıştır. Deneysel çalışmalarda en yüksek başarımla SMOTE kullanılarak dengeli hale getirilen veri setinde elde edilmiş, önerilen CNN modeli ile %99,99 doğruluğa ulaşılmıştır.

Anahtar Kelimeler: Radar, insansız hava aracı, SMOTE, evrişimli sinir ağları.

Target Detection in Unbalanced Doppler Radar Data Using Convolutional Neural Network

ABSTRACT

The protection of critically important military and civil settlements resumes its importance today as in the past. For this purpose, systems with various sensors are being developed. Extracting information from the data provided by the sensors is also important for the most efficient use of the hardware. Radar systems are frequently used for reconnaissance, surveillance and detection purposes. There are rule-based and machine learning-based methods for the classification of objects detected by radar. In machine learning-based approaches, the characteristics of the target object are learned by the model over time without the need for expert opinion. For this reason, these methods are more advantageous than rule-based methods. In this study, target classification was made on unstable Doppler Radar data in order to distinguish UAVs from other objects. In experimental studies, the highest performance was obtained in the data set balanced using SMOTE, and %99,99 accuracy was achieved with the proposed CNN model.

Keywords: Radar, unmanned aerial vehicle, SMOTE, convolutional neural networks.

1. GİRİŞ (INTRODUCTION)

Askeri veya sivil olarak kritik konumdaki tesis ve yerleşkeler günümüz şartların birçok yönden tehdit altındadır. Bu tür yerleşkelerin korunmasında çeşitli keşif ve gözetleme sistemleri kullanılmaktadır [1]. Bu sistemler çeşitli elektro optik ve radar sistemlerinden oluşmaktadır. Radarlar bu tür sistemlerde olası hedeflerin algılanması ve kullanıcının uyarılması açısından kritik öneme sahiptir [2-6, 13]. Kullandıkları teknikler ve amaçlarına göre ayrılan radarlar, cisimlerden yansıyan radyo dalgalarını algılayarak nesne tespiti yapmaktadırlar. Radarın nesnelere tespit etmesi pratikte tek başına yeterli değildir. Çünkü radar tarafından tespit

edilen nesnelerin küçük bir bölümü hedef kümesinde olup, hayatın olağan akışı içerisinde bulunan birçok nesne de (otomobil, insan ve insanlar topluluğu, hayvanlar vb.) radar tarafından algılanmaktadır [2-4]. Bu sebeple radar tarafından algılanan nesnelerin sınıflandırılması da bir o kadar önemlidir. Tespit edilen nesneler, mevcut veriler ışığında çeşitli yöntemlerle sınıflandırılmaktadırlar. Hedeflerin sınıflandırılması; operatörün algısını artırmak, kritik durumların tespiti, sistemsel alarmların oluşturulması vb. durumlar için önem arz etmektedir. Bu kapsamda nesnelerin sınıflandırılmasında kural tabanlı ve makine öğrenmesi tabanlı nesne sınıflandırma yaklaşımları öne çıkmaktadır.

*Sorumlu Yazar (Corresponding Author)
e-posta : muhammed.erdogan1@gazi.edu.tr

Kural tabanlı hedef sınıflandırma yaklaşımları deterministik olarak hedeflerin sınıflandırılması için oluşturulan kural setleri dahilinde sınıflandırma yapan yöntemlerdir. Bu tür yöntemler mevcut hedef listeleri göz önüne alınarak uzmanlar tarafından hazırlanmış kurallardır ve olası hedefleri göz ardı etmemek için yüksek yanlış alarm oranına sahiptir. Makine öğrenmesi tabanlı sınıflandırma yaklaşımlarında ise mevcut veri seti içerisindeki hedef sınıfları sınıflandırma algoritmalarına öğretilerek hedefe ait veriler ile sınıflandırılması hedeflenmektedir [1-3].

Radarlar ihtiyaca göre farklı boyutlarda ve menzillerde tasarlanmaktadır. Ürettikleri sinyallerin dalga boyları değiştirilerek ve baz aldıkları teknolojiler geliştirilerek, hedef kümesi içinde yer alan nesnenin fark edilmesi ve nesneye ait belirlenen karakteristiklerin artırılması amaçlanmaktadır [7]. Çok çeşitli radar tipleri bulunmasının yanında özellikle makine öğrenmesi tabanlı yöntemlerin başvurulduğu sistemlerde kullanılan radarlar genel olarak, doppler radarları, Sentetik Açıklıklı Radar (SAR), uzun menzil radarlar ve pasif radarlar olarak sınıflandırılabilirler [1, 2, 14, 15].

Doppler etkisini referans olarak geliştirilen radarlar doppler radarı olarak isimlendirilirler. Doppler etkisi, herhangi bir dalga üretici nesnenin hareket etmesi sonucu algılanan frekans ile gerçek frekans arasındaki oluşan sapmadır. Bu sapmanın ölçülmesi sonucunda nesnenin hızı hesaplanmaktadır. Doppler etkisinden faydalanılarak geliştirilen doppler radarları, nesne konumu tespiti yapmasının yanında tespit edilen nesnenin hızını da hesaplamaktadır.

Sentetik açıklıklı radar, hareketli platform üzerinde bulunan ve hareket halinde toplanan verileri elektronik ortamda birleştirilerek daha büyük donanımların tek seferde toplayacağı verileri toplayan radar türüdür. Sentetik açıklıklı radar, yeryüzü şekilleri ve beşeri yapılar gibi üç boyutlu yapıların, iki boyutlu resimlerini veya üç boyutları modellerini oluşturmak için kullanılırlar. Genellikle hava araçları veya uyduların üzerine monte edilmektedir. SAR verisi yansıdığı yüzey ve geometrisi hakkında bilgiler içermektedir.

Uzun menzil hava savunma radarları uzak mesafedeki hava hedeflerinin tespiti ve takibi için özel olarak geliştirilmiş radarlardır. Uzun menzilli hava savunma radarları, büyük hacimli hava platformlarının gözetlenmesi için anahtar sensörlerdir. Bununla birlikte düşük irtifa, hız ve Radar kesit alanı (Radar Cross Section) insanlı uçaklara kıyasla küçük hedeflerin tespitini zorlaştıran faktörlerdir. Sınıfın modern radarları, önemli mesafelerde fiziksel olarak küçük veya karakteristik yönünden RCS değeri azaltılmış hedeflerin tespiti için geliştirilmiş hassas sensörlerdir [1].

Pasif radarlar sinyal kaynağı olmayan, yalnızca alıcı bulunduran ve bu alıcı ile ortamdaki radyo dalgalarını işleyen radarlardır. Pasif radarlar, aktif radarlardan farklı olarak hedeften yansımaları için radyo sinyali yaymazlar. Bunun yerine hedeften yansıyan başka donanımlara ait radyo dalgalarını veya nesnenin kendisinin ürettiği radyo dalgalarını işleyerek nesne hakkında veri

üretmektedirler. Düşük maliyetli olmaları, sinyal yaymamaları sebebiyle görünürlüklerinin az olması ve radyo dalgası kirliliğe oluşturmamaları sebebiyle askeri ve sivil alanda sıklıkla başvurulan teknolojilerdendir [2]. Radar tabanlı sistemlerde hedef sınıflandırması için yapay zekâ tabanlı yaklaşımların kullanılması hata oranının azalması ve hedef kümesindeki nesnelere yaşanacak teknolojik değişikliklere adapte olabilmesi için önemlidir. Günümüzde askeri ve sivil sektörlerde bu alanda çalışmalar devam etmektedir.

Bu çalışma kapsamında hedef kümesi olarak belirlenen İHA'ların diğer nesnelere ayırt edilmesi amaçlanmıştır. Bunun için halka açık erişimi olan ve literatürdeki mevcut çalışmalarda [9] kullanılan veri seti ile deneysel çalışmalar yapılmış özgün ve etkili bir evrişimli sinir ağı modeli geliştirilmiştir. Veri setine ön işleme adımları uygulanarak ve farklı eğitim yaklaşımları ile deneysel çalışmalar yapılarak performans artırılması hedeflenmiştir.


Çalışmanın ikinci bölümünde radar sistemlerinde kullanılan mevcut hedef sınıflandırma aşamaları ve literatürdeki çalışmalar incelenmektedir. Üçüncü bölümde çalışma kapsamında kullanılan yöntemlerden bahsedilmektedir. Dördüncü bölümde gerçekleştirilen deneysel çalışmalardan bahsedilmektedir. Son bölüm olan beşinci bölümde ise mevcut yöntemler genel olarak özetlenip yapılan deneysel çalışmanın sonuçları değerlendirilmektedir.

2. RADAR TABANLI SİSTEMLERDE HEDEF SINIFLANDIRMA (TARGET CLASSIFICATION IN RADAR-BASED SYSTEMS)

Radarlar, keşif gözetleme sistemlerinde sıklıkla başvurulan donanımlardandır. Kullandıkları teknolojiler açısından çeşitli gruplara ayrılmaktadırlar. Radarın elde ettiği verilerin işlenmesi ile nesne sınıflandırma, hedef takibi, aktivite sınıflandırma gibi çalışmalar yapmak mümkündür [3]. Şekil 1'de özetlendiği üzere, radar tarafından üretilen ham veriden, veri ön işleme yöntemleriyle öznelikler elde edilir. Nitelikler verideki hedefe ait ayırt edici özelliklerdir. Elde edilen nitelikler ile sınıflandırıcı algoritma eğitilmektedir. Eğitilen sınıflandırıcı algoritma elde edilen veri sayesinde nesne verisinin sınıfını tahmin etmektedir.

2.1. Veri Kümesi (Data set)

Veri, belirli kurallar çerçevesinde donanımdan alınan sinyallerdir. Kural tabanlı sistemlerde verinin işlenmesiyle, uzmanlar tarafından belirlenen kurallar dahilinde kullanıcı bilgilendirilir, uyarılır ve harekete geçirilir. Veri içerisindeki fark edilmemiş örüntüler mevcut veriden elde edilebilecek bilgilerdir.




Şekil 1. Ham veri ile hedef sınıflandırmanın şematik gösterimi. (The representation of target classification with raw data)

Sınıflandırıcı algoritmalar yeterli miktarda veri ile eğitildiklerinde bu kuralları ve örüntüleri öğrenir ve eğitim sonrasında elde edilen verileri işleyerek hedefin sınıflandırılmasını sağlar.

Mevcut halka açık veri setleri incelendiğinde radar verileri donanımın tipine göre farklılık göstermektedir. Örneğin MSTAR, halka açık olan bir SAR veri setidir [17]. SAR veri setleri genellikle MSTAR veri setinde olduğu gibi taranan bölgenin iki boyutlu görüntülerinden oluşur. Görüntü üzerindeki piksel değerleri hedefe ait karakteristik bilgiler içermektedir. Burada radar donanımının yaklaşım açısı, hedefi görüşü gibi etmenler değerlerde değişime sebep olmaktadır. Eğitim aşamasında bu tür parametrelerinde dahil edilmesi modelin başarımını artırmaktadır. Şekil 2’de MSTAR veri setindeki bazı sınıflara ait görseller ve radar görüntüleri verilmektedir.

hale getirilmesi gibi birçok yöntem ön işleme adımı olarak değerlendirilir. Sınıflandırıcı modelin optimum yapıya ulaşmasından sonra başarımı etkileyen en önemli faktör verinin kalitesidir. Bu sebeple ön işleme adımı oldukça kritiktir.

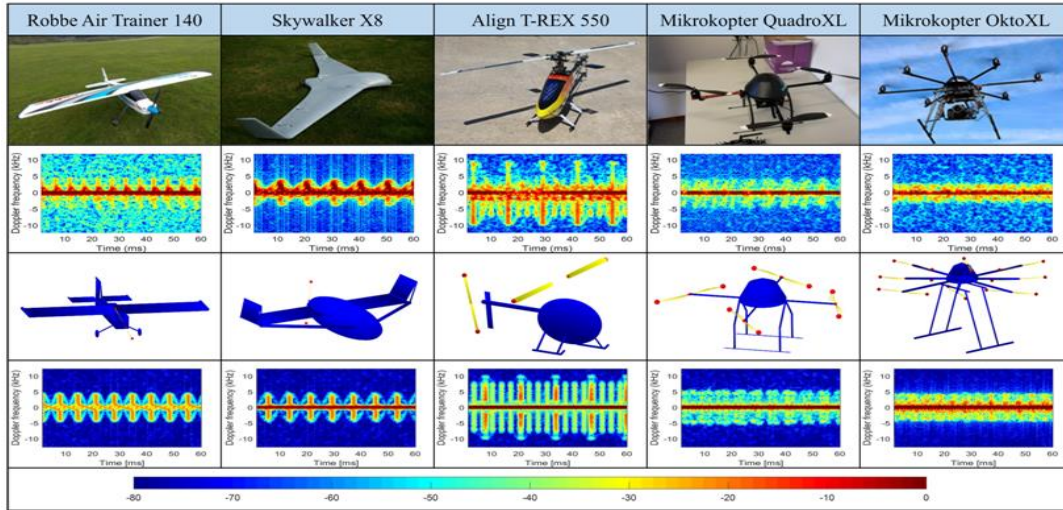


Şekil 2. MSTAR veri setindeki hedeflerin görselleri ve radar yansımaları. (Visual representation and radar reflection of target classes of MSTAR)

2.3. Sınıflandırma (Classification)

Sınıflandırma, belirli bir veri setini sınıflara ayırma işlemidir. Sınıflandırmada temel amaç yeni verilerin hangi sınıfa dahil olduğunu belirlemektir. Radar veri setleri ile sınıflandırıcı modellerin eğitilmesi ile nesnel sınıflandırılmaktadır.

Radar verisinin tipi ve sistemin gereksinimleri göz önüne alındığında kullanılan sınıflandırıcı model farklılık göstermektedir.



Şekil 3. 5 İHA modeline ait sırasıyla; görsel, ölçülen radar verisi spektrogramı, bilgisayar modeli, bilgisayar modelinden elde edilen radar verisinin spektrogramı [7]. (Picture, radar spectrogram, computer model and radar spectrogram of computer model of the 5 İHA model respectively)

2.2. Ön İşleme (Preprocessing)

Ön işleme, eğitilecek modelin başarımının artırılması amacıyla veriden en yüksek verimin alınması için uygulanan işlemlerdir. Ham verinin standartlaştırılması, matematiksel ve istatistiksel yöntemlerle işlenmesiyle niteliklerin elde edilmesi, gereksiz ve aykırı verilerin temizlenmesi, sınıflandırıcı modele katkısı olmayan niteliklerin veri setinden çıkarılması, veri setinin dengeli

Görüntü tabanlı veri setlerinde çoğunlukla derin öğrenme tabanlı yöntemler tercih edilirken, sayısal nitelikler içeren veri setlerinde ve işlem maliyetinin düşük olması istenen çalışmalarda Destek Vektör Makineleri (Support Vector Machine), k-En Yakın Komşu (k-nearest neighbors), karar ağacı vb. yöntemler tercih edilmektedir [1, 3- 6, 18-20].

Doppler radarı ile sınıflandırma ele alındığında, Doppler konsepti ilk olarak 2000 yılında Chen tarafından ortaya atılmıştır [3]. Doppler radarlarının elde ettiği veriler

incelendiğinde ve tespit edilen nesnelere sınıflara ayrıldığında, sınıfların kendine ait doppler imzaları olduğu görülmektedir. Doppler imzaları, hareket eden nesnelere periyodik olan kinetik karakteristiklerini yansıtmaktadır. Bu sayede nesneye ait doppler bilgileri ile nesnenin aktivitesi ve sınıfı belirlenebilir [3].

Çalışma [3-7]'de görüldüğü gibi doppler radarları askeri ve sivil alanlarda sıklıkla kullanılmaktadır. Öznitelik çıkarma yöntemleri makine öğrenmesi modelinin eğitimini standartlaştırma ve başarısını artırmak için başvurulan tekniklerdir. Doppler radarından elde edilen verilere uygulanabilen tekniklerden olan Kısa Zamanlı Fourier Dönüşümü (Short Time Fourier Transform) kullanılarak nesnenin iki boyutlu zaman sıklık grafiği oluşturulabilmektedir [3-7]. Bu yöntem ile spektrogramlardan frekansa bağlı olarak görüntü kareleri elde edilmektedir. Görüntü kareleri derlenerek veri setleri oluşturulmaktadır. Şekil 3'te 5 İHA'ya ait gerçek ve model görüntüleriyle beraber onlara ait spektrogramları verilmektedir.

Sinyalin niteliklerinin belirlenmesi ve arka plan gürültülerinden kurtulmak amacıyla, spektrogramlar üzerinde boyut azaltımı yapılmaktadır [3]. Temel Bileşen Analizi (Principal Component Analysis) iyi bilinen öznitelik çıkarım ve boyut azaltma yöntemlerindedir [3, 4]. Bu tekniğin bir türevi olan 2D2PCA (Two-Directional Two-Dimensional Principal Component Analysis), piksellerden oluşan iki boyutlu spektrogramlar üzerinde oldukça etkilidir. 2D2PCA bu sebeple birçok çalışmada kullanılmaktadır [3]. Radar verisinin iki boyutlu hale getirilmesi için STFT kullanılması yanında alternatif olarak başka yöntemlerde mevcuttur. Örneğin çalışma [4]'te Hızlı Fourier Dönüşümü (Fast Fourier Transform), OS-CFAR algoritması ve kalman filtresinden oluşan bir yapı kullanılmaktadır. Bu yapının STFT'ye göre özellikle çoklu hedeflerin belirlenmesinde daha etkili olduğu belirtilmektedir. Çalışma [8]'de mikro doppler imzalarının karakterize edilirken zaman sıklık analizinin elde edilmesi için Gabor dönüşümü, Wigner-Ville dönüşümü, Cohen'nin zaman sıklık dağılımı ve EMD (Empirical-Mode Decomposition)'nin zaman sıklık analizi için kullanıldığı ve bu yöntemlerin etkili olduğu belirtilmektedir.

Doppler verisi analizi ile elde edilen spektrogramlar sayesinde nesnelere veya nesne hareketlerinin sınıflandırması yapılabilmektedir. Çalışma [3]'de SVM, kNN ve Evrimsel Sinir Ağları (Convolutional Neural Network) algoritmaları, nesne ve hareket sınıflandırma için kullanılmaktadır. Çalışmadaki sonuçlar incelendiğinde CNN algoritmasının oldukça başarılı olduğu görülmektedir. Ancak CNN algoritması diğerlerine nazaran daha maliyetli olması sebebiyle kendisine alternatif arayışlar çalışmalarda yer bulmaktadır. Çalışma [3]'te SVM ve kNN algoritmasının eğitiminde kullanılan verilere 2D2PCA öznitelik çıkarım yönteminin uygulanmasıyla algoritmaların başarı oranı oldukça yükselmekte ve CNN algoritmasıyla rekabet edebilecek seviyelere gelmektedir.

Spektrogram analizi yapılan diğer çalışmalarda [4, 5] sınıflandırıcı olarak CNN algoritması ön plana çıkmaktadır. Ayrıca derin öğrenme tabanlı diğer ağ yapıları da (Residual CNN, LSTM destekli RNN) çalışmalarda başvurulan sınıflandırıcı yapılarıdır. Bu duruma örnek olarak çalışma [7]'de 5 mini-İHA'ya ait ölçüm sonucunda ve benzetim yöntemiyle elde edilmiş radar spektrogramları ile çeşitli senaryolardaki modeller eğitilmektedir. Eğitilen modeller çeşitli parametrelere ait CNN ağları ve bir adet LSTM destekli RNN ağıdır. Çalışma kapsamında farklı mini-İHA modellerinden radar verileri toplanmakta ve modeller eğitilmektedir. Çalışmada aynı mini-İHA'lar bilgisayar ortamında modellenerek simüle edilmekte ve bu modeller üzerinden radar verileri toplanmaktadır. Çalışmada [7] dikkat çeken nokta, simüle veriler ile eğitilecek bir modelin gerçek radar verisini tahmininde kullanılıp kullanılmayacağıdır. Bu amaç doğrultusunda geliştirilecek modelin, birçok yönden avantaj sağlayacağı belirtilmektedir [7]. Ancak modelin eğitim başarısı incelendiğinde, simülasyon üzerinden elde edilen veri ile eğitilen modellerin başarısı, gerçek veri ile eğitilen sınıflandırıcı modeller karşısında oldukça başarısız olduğu görülmektedir. Bu çalışma sayesinde makine öğrenmesi modellerinin eğitiminde veri kalitesinin modelin eğitiminde ne kadar etkili olduğu ortaya konulmaktadır. STFT kullanılarak elde edilen spektrogramlar görsel olarak sınıfa ait ayırt edici özellikleri içerisinde barındırmaktadır.

Spektrogramlar ile derin öğrenme tabanlı yöntemler eğitilebilmektedir. Buna ek olarak spektrogramlardaki ayırt edici özellikler çeşitli yöntemlerle elde edilebilmektedir. Elde edilen sayısal ve kategorik niteliklerle de derin öğrenme tabanlı yöntemlerinden farklı sınıflandırıcılar eğitilmekte ve kullanılabilir. Çalışma [8]'de bu duruma örnek olarak, STFT ile sınıflara ait doppler verileri spektrogramlar haline getirilmekte ve çeşitli yöntemlerle 12 farklı nitelik elde edilmektedir. Nitelikler ile NB (Naive Bayes), k-NN ve karar ağacı sınıflandırıcıları eğitilmektedir. Elde edilen nitelikler Tablo 1'de verilmektedir.

Son yıllarda gerçekleştirilen mevcut çalışmalar incelendiğinde doppler radarı ile yapılan çalışmalarda çoğunlukla STFT kullanılarak radar verilerinin spektrogramlarının elde edilmesi amaçlanmaktadır. Ancak bu yöntemle çıkarımda bulunmak için çoğunlukla uzun zaman aralıklı radar verilerine ihtiyaç duyulmaktadır [6]. Dahası, zaman sıklık çözünürlüğündeki kısıtlamalar STFT tabanlı yöntemleri sınırlamaktadır. Bu sorunlara çözüm olması açısından mikro-doppler radar verisi ile yapılan çalışmalarda STFT tabanlı yöntemlerden farklı olarak mikro-doppler imzalarının analizinde fourier tabanlı olmayan zaman sıklık analizi yöntemleri tercih edilmektedir.

Çizelge 1. Çalışma [8]'de spektrogramlardan elde edilen nitelikler.(Extracted features obtained from the spectrogram in study [8])

Nitelik Numarası	Nitelik Açıklaması
1	Doppler Bant Genişliği Orta Noktası
2	Doppler Ağırlık Merkezi Orta Noktası
3	Doppler Bant Genişliği Standart Sapması
4	Doppler Ağırlık Merkezi Standart Sapması
5	İlk Tekil Sağ Vektör Standart Sapması
6	İlk Tekil Sağ Vektör Orta Noktası
7	İlk Tekil Sol Vektör Standart Sapması
8	İlk Tekil Sol Vektör Orta Noktası
9	U Matris Piksellerinin Standart Sapması
10	U Matris Köşegeninin Orta Noktası
11	U Matris Piksellerinin Toplamı
12	V Matris Piksellerinin Toplamı

Bu amaçla çalışma [6]'da EMD kullanılmaktadır. Bu yöntem sayesinde Tablo 2'de verilen nitelikler görüntü karelerinden farklı olarak sayısal ve kategorik veriler olmaları sebebiyle farklı sınıflandırıcıların kullanılmasına olanak sağlamaktadır.

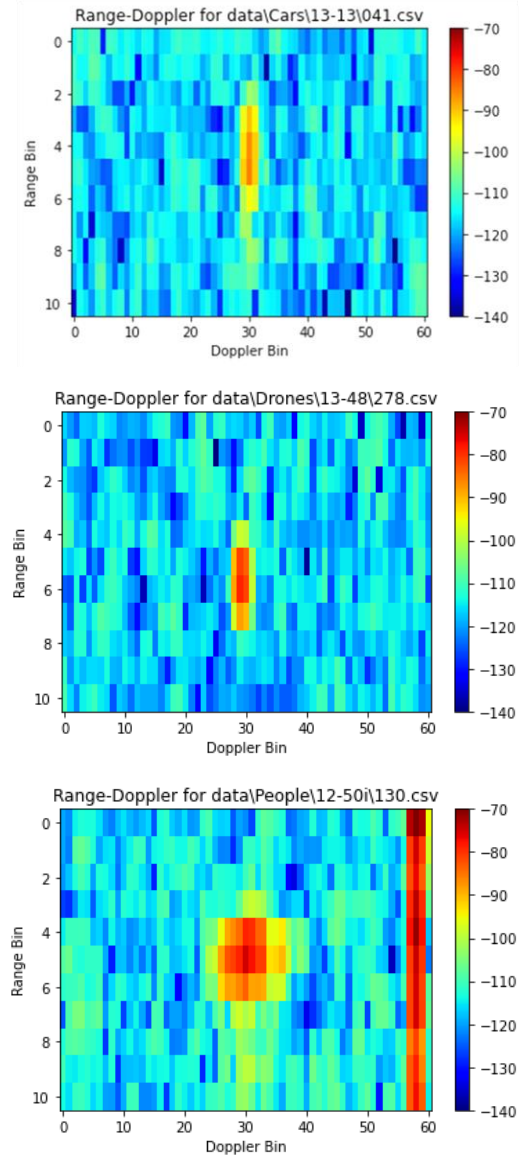
Çizelge 2. Çalışma [6]'da elde edilen nitelikler.(Extracted features in study [6])

Nitelik Numarası	Nitelik Açıklaması
1	Sıfırdan Geçiş Sayısı
2	Normalleştirilmiş Sinyal Enerjisi
3	Standart Sapma Değeri
4	Entropi Değeri
5	İki Birleştirilmiş IMF'nin Entropisi
6	Normalleştirilmiş En Yüksek-Ortalama Farkı
7	İki Frekans Tepesi arası Mesafe
8	Sıfırdan Geçiş Sayısı Oranı

3. YÖNTEM (METHOD)

Doppler radar verisi kullanılarak nesne sınıflandırma yapılan birçok çalışma mevcuttur. Bu çalışmada ise halka açık olarak sunulmuş bir veri seti kullanılmaktadır. Veri seti üç sınıfa (İHA, insanlar, araba) ait doppler verisi içermektedir [9]. Şekil 4'te veri setinde bulunan sınıflara ait örnekler verilmektedir.

Veri seti, doppler hücresi başına farklı mesafe aralıklarındaki sinyal gücünü içeren iki boyutlu grafiklerden oluşmaktadır. Sinyal gücü nesneden yansıyan dalganın, alıcı tarafından algılanan büyüklüğü ile hesaplanmaktadır.



Şekil 4. Yukarıdan aşağıya sırasıyla otomobil, İHA ve insana ait örnek doppler verileri.(Samples of the doppler data automobile, UAV and people respectively)

Her sınıf görsel olarak farklı karakteristiğe sahiptir. İlk olarak İHA'lar düşük RCS'ye sahiptir bu yüzden sinyal gücü düşüktür. Ayrıca küçük ve kompakt olmaları sebebiyle sinyal gücü az sayıda hücre tarafından algılanmaktadır. İkinci olarak arabalar, büyük ve metal olmaları sonucunda büyük RCS'ye sahiptir. Farklı hızlarda, hareketli parçalarının olmaması sebebiyle ortalama sinyal gücü birkaç doppler hücresi tarafından algılanmaktadır. Son olarak insan sınıfındaki örneklerde, ortalama sinyal gücünde ve mesafe bazında daha az yayılmış yansımaya sahiptirler. Hareket halindeki kol ve bacaklar bulunması doppler hücrelerinde çeşitli geniş aralıkta sinyal değerleri elde edilmektedir [9]. Sınıflar arasındaki bu karakteristik farklılıklar sınıflandırıcı modellerin eğitilmesinde önemli yer almaktadır.

Eğitim aşamasında veri setinin dengeli olması eğitimin kalitesini artıran bir etmendir. Veri setindeki örneklerin sınıflara göre dağılımı dengesiz olduğu durumlarda modelin tahmininde eğilimlere sebep olarak başarımın düşmesine sebebiyet verebilmektedir. Dengeleme amacıyla örneklerin azaltılması veya artırılması için çeşitli algoritmalar mevcuttur. İki çok sınıftan oluşan veri setlerinin dengeli hale getirilmesinde kendini birçok çalışmada kanıtlamış olan SMOTE algoritması tercih edilmektedir [10-12].

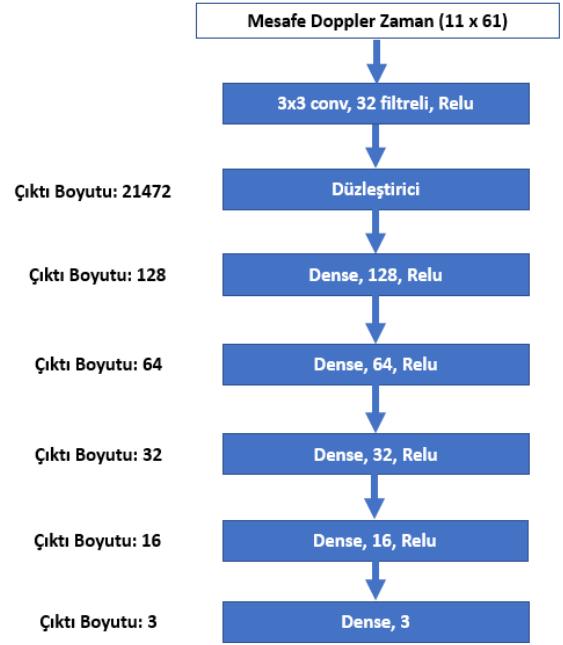
Bu çalışmada SMOTE algoritması, mevcut veri setinin oransal olarak dengeli hale getirmek için azınlık olan sınıflara ait örneklerden rastgele seçimler yaparak onları çoğaltmaktadır.

CNN derin öğrenmenin bir alt dalıdır. Genellikle görsel verinin analiz edilmesi için başvurur. Sıklıkla kullanıldıkları alanlar; resim ve video teşhisi, önerici sistemlerde görüntü sınıflandırma, tıbbi görüntü analizi ve doğal dil işleme olarak sıralanabilir. CNN'ler, hiyerarşik gösterimleri doğrudan ham veri girişinden otomatik olarak öğrenme yetenekleri nedeniyle görüntü tanıma ve sınıflandırmada yaygın olarak kullanılmaktadır [3]. Genel olarak bir CNN üç tipik katman içerir: Evrişim katmanları, havuz katmanları ve tam bağlantılı katmanlar. Bir evrişim katmanı, ağırlı girdinin farklı bölümleri üzerindeki uzamsal kalıpları algılamasına ve bir havuz katmanının girdinin öteleme değişmezliğini öğrenmesini sağlar. Tam bağlantılı katmanlar, ağda öğrenme gerçekleştirmek için birkaç evrişim ve havuz katmanından sonra yerleştirilir [3].

Çalışma kapsamında 7 katmanlı sinir ağından oluşan model ile eğitim gerçekleştirilmektedir. Mevcut güncel çalışmaların derlenmesi sonucu sinir ağına ait hiper parametreler ilk halini almıştır. Sonrasında sinir ağındaki hiper parametreler deneysel yöntemlerle ayarlanmıştır. Sinir ağı Şekil 5'te verildiği gibi son halini almıştır. İki boyutlu evrişim katmanında filtre parametresi 32 olarak ayarlanmaktadır. Filtreler parametresi, o katmandaki evrişimli filtrelerin sayısını ayarlamaktadır. Bu filtreler, belirtilen yöntem kullanılarak küçük, rastgele değerlere ayarlanmaktadır. Sinir ağına eğitimi sırasında, filtreler kaybı en aza indirecek şekilde güncellenmektedir. Bu sayede eğitim boyunca filtreler, kenarlar ve dokular gibi belirli özellikleri algılamayı öğrenmektedirler. Filtre boyutu (kernel size) 3x3 olarak ayarlanmaktadır. Bu parametre filtreler elde edilirken örneklem üzerinde dolaşacak çerçevenin boyutunu ifade etmektedir. Dolgulama (padding) parametresi aynı (same) tercih edilmektedir. Böylece filtrelemeye verilen girdi matrisinin boyutu ile çıktı matrislerinin boyutunun aynı olması sağlanmaktadır. Bu katmandaki son hiper parametre olarak aktivasyon fonksiyonu relu (Rectified Linear Unit) olarak ayarlanmaktadır. Relu tercih edilmesini sebebi literatürdeki çalışmalarda sıklıkla tercih edilmesinin yanında işlem maliyetinin düşük olmasıdır.

Dense katmanları, düzenli olarak derin olarak bağlantılı sinir ağı katmanıdır. En yaygın ve sık kullanılan katmandır. Bu katmanın çıktısı vektördür. Birbirine

tamamen bağlı olan katman aracılığıyla vektör boyutu giderek azaltılır. Böylece son aşamada sınıf sayısı boyutunda bir vektör elde edilir. Bu katmanlardaki aktivasyon fonksiyonu hiper parametresi relu'dur.



Şekil 5. Geliştirilen evrişimli sinir ağına gösterimi (Demonstration of the developed convolutional network model.)

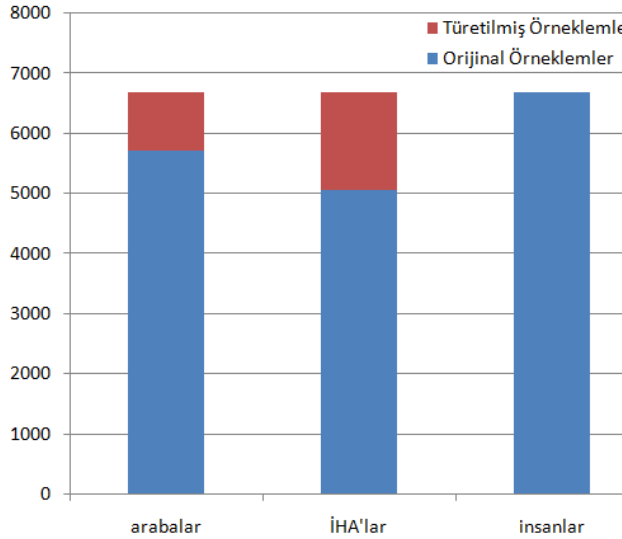
Eğitim amacıyla iki farklı yaklaşım denenmektedir: Eğitim test et ve k-Kat yaklaşımı. Geleneksel olarak isimlendirilebileceğimiz ilk yaklaşımda oransal olarak bölütlere ayrılan veri seti modelin eğitilmesi için kullanılmaktadır. Ardından test verisi üzerinden tahminleme yapılarak modelin başarısı ortaya konulmaktadır. K-kat eğitim yaklaşımında ise veri seti k adet parçaya bölünmekte ve her bir parça hem eğitim hem test verisi olarak kullanılmaktadır.

4. DENEYSEL ÇALIŞMALAR (EXPERIMENTAL STUDIES)

Bu çalışma kapsamında konu hakkında güncel çalışmaların değerlendirilmesi sonucunda doppler radarından elde edilmiş veri seti ile özgün bir sınıflandırıcı model geliştirilmesi amaçlanmıştır. Bu kapsamda çalışma [9]'da kullanılan ve halka açık bir şekilde erişilebilen veri seti ile deneysel çalışmalar yapılmıştır.

Veri setinde 17485 adet örneklem bulunmaktadır. Veri Setindeki örneklerin dağılımı %32,71 otomobil, %28,97 İHA ve %38,32 insanlara aittir [9]. Çalışmada veri dağılımının dengeli olduğu ve sinir ağlarının eğitimi için uygun olduğu belirtilmektedir. Bu çalışmada ise veri setinin daha dengeli hale getirilmesi için dengeleme

yöntemlerinden olan SMOTE yöntemi test edilmekte ve kullanılmaktadır. SMOTE kullanıldığında, kullanılmadığı duruma göre %1-2 başarıyı artırdığı görülmektedir. SMOTE ile veri setindeki örneklerin dağılımı eşitlenmektedir. Şekil 6'da orijinal veri seti ve SMOTE algoritmasıyla dengeleme işlemi yapıldıktan sonra örneklerin dağılımı grafik olarak verilmektedir.



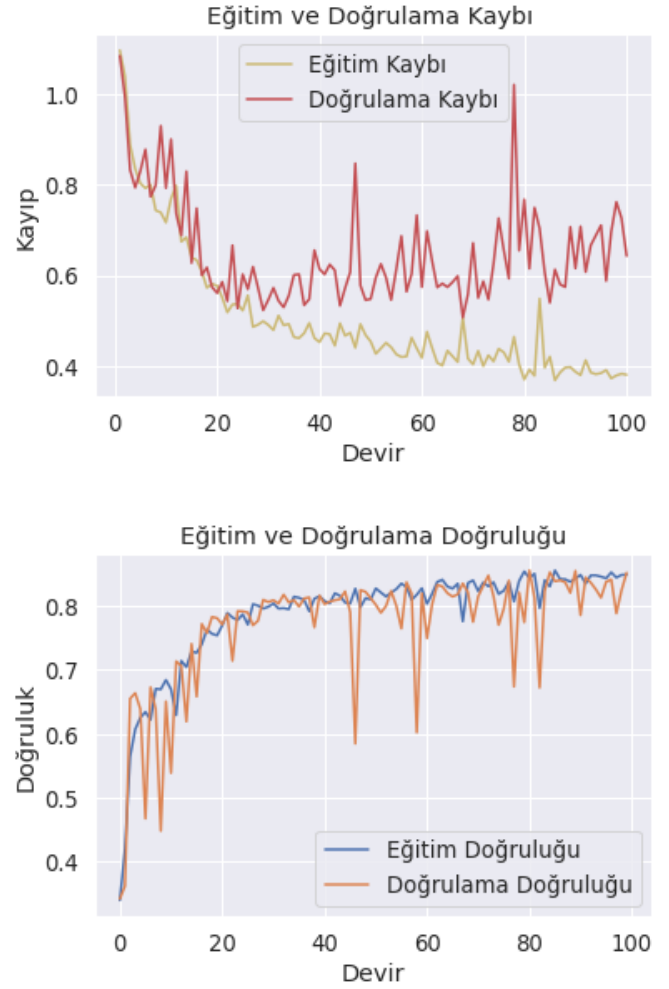
Şekil 6. SMOTE ile veri setinin dengeli hale getirilmesi sonucu örneklerin dağılımı. (The distribution of samples as a result of balancing the data set with SMOTE.)

Deneyel çalışma kapsamında 7 katmanlı sinir ağından oluşan model ile eğitim gerçekleştirilmektedir. Katmanlarda aktivasyon fonksiyonu olarak relu tercih edilmiştir. Şekil 5'te sinir ağı modeli özetlenmektedir.

Model üzerinde iki farklı eğitim yaklaşımı gerçekleştirilmektedir. İlk yaklaşım olan eğitim test et yaklaşımında veri setinin %20'lik kısmı test amaçlı, %80'lik bölümün %20'lik kısmı doğrulama verisi olarak kullanılmaktadır. Veri Setinin geriye kalan kısmı ile de eğitim gerçekleştirilmektedir.

Şekil 7'de bu eğitime ait başarı ve kayıp grafikleri verilmektedir. Eğitilen model %82 doğruluğa ulaşmaktadır. Modelin test verisi ile yaptığı tahminler göz önüne alındığında %81 doğruluğa ulaştığı görülmüştür.


Test verisi üzerinden gerçekleştirilen tahminleri içeren karmaşıklık matrisi Şekil 8'de verilmektedir.






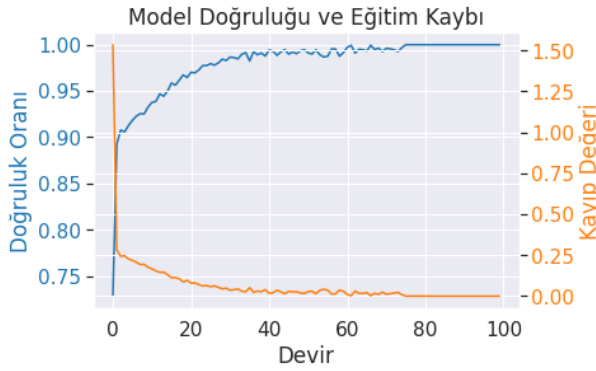

Şekil 3. Eğitim sonucunda elde edilen kayıp ve doğruluk grafikleri. (Loss and accuracy graphs obtained as a result of training.)

Yanlış tahminler incelendiğinde arabaların İHA olarak tahmin edilmesinin diğer yanlış tahminlere göre fazla olduğu görülmektedir. Buna göre veri seti içerisindeki araba ve İHA'lara ait örneklerin benzerlik içerdiği düşünülebilir.

İkinci öğrenme yaklaşımında ise k-kat (k-fold) kullanılmaktadır. Aynı sinir ağı modeli 5-kat veri seti ile eğitilmektedir. 20, 50, 100 devir sonunda sırasıyla %96,18, %98,24, %99,98 eğitim başarımına ulaşılmaktadır. Şekil 9'da eğitime ait devir sayısına göre kayıp ve doğruluk oranı grafiği verilmektedir. Grafik göz önüne alındığında tahmin edilebileceği doğrultuda devir sayısının artırılması ile öğrenme başarımı artış göstermektedir. Lakin devir sayısının artırılması beraberinde işlem maliyeti getirmektedir.



Şekil 4. Test verisi ile elde edilen karmaşıklık matrisi.(The confusion matrix obtained with the test data.)



Şekil 5. 5-Kat Çapraz doğrulama yaklaşımı ile 100 devirli eğitim sonucunda sırasıyla her katın modele ait kayıp ve doğruluk oranı grafikleri.(Loss and accuracy rate graphs of the model for each fold respectively, as a result of 100 epochs of training with a 5-fold cross validation approach.)

Öğrenme ivmesi belli bir devir sayısından sonra azalmaktadır. Bu aşamada işlem maliyeti göz önüne alındığında 50 devirli eğitimin pratikte yeterli olabileceği değerlendirilmektedir.

Tablo 3'te model eğitimi sonucunda katların elde ettiği doğruluk oranı ve kayıp değerleri verilmektedir. Tablodaki değerlerden tüm katların yüksek başarımla elde ettiği görülmektedir. Ayrıca değerlerin birbirine yakın olması modelin kararlılığı ortaya koymaktadır.

Çizelge 3. 5-Kat çapraz doğrulama sonucunda tüm katlara ait elde edilen değerler.(The values reached for all folds as a result of 5-fold cross validation.)

Kat Numarası	Doğruluk Oranı	Kayıp Değeri
1	%99,46	0,0151
2	%99,99	0,0003
3	%99,00	0,0292
4	%99,99	0,0004
5	%99,99	0,0004
Ortalama	%99,68	0,0009

Tablo 4'te eğitim yaklaşımına göre model metriklerindeki değişim verilmektedir. Verilen metrikler

göz önüne alındığında eğitim yaklaşımlarının ortaya koyduğu performans fark edilmektedir.

Çizelge 4. Eğitim yaklaşımlarının karşılaştırılması (Comparison of training approaches.)

Eğitim Yaklaşımı	Doğruluk Oran	Kayıp Değeri
<i>Eğit Test Et</i>	%84,68	0,3830
<i>K-Kat Çapraz Doğrulama (Ort)</i>	%99,68	0,0009

Tablo 5'te verildiği üzere radar veri setinin halka sunulduğu çalışmada önerilen model DopplerNet %99,48 doğruluğa ulaştığı belirtilmektedir. Veri seti ile test edilen, NasNetMobile %97,69, MobileNetV2 %98,94 doğruluğa ulaşmaktadır [9]. Önerilen modelin eğitim sonuçları ve literatürdeki sonuçlar göz önüne alındığında daha yüksek doğruluk oranına erişildiği görülmektedir.

Çizelge 5. Aynı veri seti ile gerçekleştirilen literatürdeki çalışmalar (Studies in the literature carried out with the same data set)

Model	Doğruluk Oran
<i>DopplerNet</i>	%99,48
<i>NasNetMobile</i>	%97,67
<i>MobileNetV2</i>	%98,94
<i>Önerilen CNN</i>	%99,68

5. SONUÇ (CONCLUSION)

Radar donanımları keşif ve gözetleme sistemlerinde sıklıkla başvurulan donanımlardandır. Sivil ve askeri alanlarda erken ihbar yeteneğinin temel unsuru olmasının yanında, hedef tespiti, takibi ve sınıflandırma konularında oldukça başarılı donanımlardır.

Radar teknolojisi, performans ve sistem gereksinimleri göz önüne alındığında tercih edilen yöntem ve yaklaşımlar farklılık göstermektedir. Genellikle derin öğrenme tabanlı yaklaşımların tercih edildiği söylenebilir. Birçok çalışmada başarısını kanıtlamış olan derin öğrenme tabanlı yaklaşımlar radar teknolojilerinde bu açıdan kendine yer bulmuş durumdadır.

SVM, k-NN ve karar ağacı algoritmaları, incelenen çalışmalarda öne çıkan öğrenme yaklaşımlarındandır. Birçok çalışmada derin öğrenme tabanlı yöntemlere alternatif olarak sunulan algoritmalar, özellikle zaman kritik olan ve yüksek işlem maliyetini karşılayamayacak sistemlerde kullanımı önerilmektedir. Uygun ön işleme ve nitelik çıkarım yöntemleri ile beraber kullanıldıklarında bu algoritmaların da derin öğrenme tabanlı yaklaşımlar kadar yüksek başarımlar gösterdikleri görülmektedir.

Deneyel çalışma kapsamında Şekil 5'te özetlenen bir sinir ağı modellenmektedir. Kullanılan halka açık veri SMOTE tekniği ile dengeli hale getirildikten sonra geliştirilen sinir ağı iki farklı şekilde eğitilmiştir. Eğitim ve test et yaklaşımıyla eğitilen model %82 eğitim başarımına ulaşmıştır. Test verisi ile elde edilen karmaşık matris doğrultusunda %81 civarında doğruluğa ulaşıldığı görülmüştür. İkinci eğitim yaklaşımı olarak k-kat çapraz doğrulama yöntemi kullanılmıştır. Bu yöntemde 5 parçaya bölünen veri setinin her bir parçasının test, geri kalan kısmının ise eğitim seti olarak kullanılmasıyla 5 kez eğitilmesi sağlanmaktadır. Bu yöntemle aynı sinir ağı modeli eğitildiğinde %99,98 doğruluğa ulaşılmıştır. Literatürdeki çalışmalar ile karşılaştırıldığında önerilen modelin daha yüksek doğruluk değeri elde ettiği görülmektedir. Buna modelin yapısı ve veri setine uygulanan dengeleme işleminin faydası sonucu olduğu değerlendirilmektedir.

Bunların sonucunda radar verisiyle nesne sınıflandırma yapılarak İHA'ların tespit edilmesinde hata oranı daha düşük hale getirilmiştir. İki yaklaşıma ait sonuçlar incelendiğinde k-kat çapraz doğrulama yönteminin daha başarılı olduğu söylenebilir. Eğitim süresi göz önüne alındığında bu yöntemin daha maliyetli olduğu bilinmektedir. Ancak devir sayısının ilk yöntemle nazaran daha düşük olduğu denemelerde bile daha yüksek başarımlar elde edildiği grafiklerden anlaşılabilmektedir.

İleriki aşamalarda mevcut parametrelerin değiştirilmesi ile aynı başarımlara daha az maliyetle erişmek üzerine çalışma yapılabilir. K-kat çapraz doğrulama yöntemi kadar başarılı ancak maliyet yönünden daha az masraflı yöntemlerin tespit edilmesi amaçlanabilir.

TEŞEKKÜR (ACKNOWLEDGEMENT)

Bu çalışma kapsamındaki değerli desteklerinden ötürü ASELSAN ve ASELSAN Akademi'ye teşekkürlerimizi sunarız.

ETİK STANDARTLARIN BEYANI (DECLARATION OF ETHICAL STANDARDS)

Bu makalenin yazarları çalışmalarında kullandıkları materyal ve yöntemlerin etik kurul izni ve/veya yasal-özel bir izin gerektirmediğini beyan ederler.

YAZARLARIN KATKILARI (AUTHORS' CONTRIBUTIONS)

Muhammed ERDOĞAN: Deneyleri yapmış ve sonuçlarını analiz etmiştir. Makalenin yazım işlemini gerçekleştirmiştir.

Doç. Dr. Oktay YILDIZ: Deney sonuçlarını analiz etmiştir.

ÇIKAR ÇATIŞMASI (CONFLICT OF INTEREST)

Bu çalışmada herhangi bir çıkar çatışması yoktur.

KAYNAKLAR (REFERENCES)

- [1] B. Torvik, K. E. Olsen and H. Griffiths, "Classification of Birds and UAVs Based on Radar Polarimetry", *IEEE Geoscience and Remote Sensing Letters*, 13(9): 1305-1309, (2016).
- [2] A. Manno-Kovacs, E. Giusti, F. Berizzi and L. Kovács, "Image Based Robust Target Classification for Passive ISAR", *IEEE Sensors Journal*, 19: 268-276, (2019).
- [3] F. Luo, S. Poslad and E. Bodanese, "Human Activity Detection and Coarse Localization Outdoors Using Micro-Doppler Signatures", *IEEE Sensors Journal*, 19(18): 8079-8094, (2019).
- [4] A. Angelov, A. Robertson, R. Murray-Smith and F. Fioranelli, "Practical Classification of different moving targets using automotive radar and deep neural networks", *IET Radar, Sonar & Navigation*, 12(10): 1082-1089, (2018).
- [5] X. Mou, X. Chen, N. Su and J. Guan, "Motion classification for radar moving target via STFT and convolution neural network", *The Journal of Engineering*, 2019(19): 6287-6290, (2019).
- [6] B. Oh, X. Guo, F. Wan, K. Toh and Z. Lin, "Micro-Doppler Mini-UAV Classification Using Empirical-Mode Decomposition Features", *IEEE Geoscience and Remote Sensing Letters*, 15(2): 227-231, (2018).
- [7] A. Huizing, M. Heiligers, B. Dekker, J. de Wit, L. Cifola and R. Harmanny, "Deep Learning for Classification of Mini-UAVs Using Micro-Doppler Spectrograms in Cognitive Radar", *IEEE Aerospace and Electronic Systems Magazine*, 34(11): 46-56, (2019).
- [8] F. Fioranelli, M. Ritchie, S. Z. Gürbüz and H. Griffiths, "Feature Diversity for Optimized Human Micro-Doppler Classification Using Multistatic Radar", *IEEE Transactions on Aerospace And Electronic Systems*, 53(2): 640-654, (2017).
- [9] Roldan, I., del-Blanco, C., Duque de Quevedo, Á., Ibañez Urzaiz, F., Gismero Menoyo, J., Asensio López, A., Berjón, D., Jaureguizar, F. and García, N., "DopplerNet: a convolutional neural network for recognising targets in real scenarios using a persistent range-Doppler radar", *IET Radar, Sonar & Navigation*, 14(4): 593-600, (2020).
- [10] K. Polat, "A Hybrid Approach to Parkinson Disease Classification Using Speech Signal: The Combination of SMOTE and Random Forests", *2019 Scientific Meeting on Electrical-Electronics & Biomedical Engineering and Computer Science (EBBT)*, İstanbul, 1-3 (2019)
- [11] W. Feng, W. Huang and W. Bao, "Imbalanced Hyperspectral Image Classification With an Adaptive Ensemble Method Based on SMOTE and Rotation Forest With Differentiated Sampling Rates", *IEEE Geoscience and Remote Sensing Letters*, 16(12): 1879-1883, (2019).
- [12] J. Wei, Z. Lu, K. Qiu, P. Li and H. Sun, "Predicting Drug Risk Level from Adverse Drug Reactions Using SMOTE and Machine Learning Approaches", *IEEE Access*, 8: 185761-185775, (2020).
- [13] C. Will, P. Vaishnav, A. Chakraborty and A. Santra, "Human Target Detection, Tracking, and Classification Using 24-GHz FMCW Radar", *IEEE Sensors Journal*, 19(17): 7283-7299, (2019).
- [14] S. Chen, H. Wang, F. Xu and Y. Jin, "Target Classification Using the Deep Convolutional Networks for SAR Images", *IEEE Transactions on Geoscience And Remote Sensing*, 54(8): 4806-4817, (2016).
- [15] H. Zhu, W. Wang and R. Leung, "SAR Target Classification Based on Radar Image Luminance Analysis by Deep Learning", *IEEE Sensors Letters*, 4(3): 1-4, (2020).
- [16] J. Wang, T. Zheng, P. Leia and X. Bai, "Ground Target Classification in Noisy SAR Images Using Convolutional Neural Networks", *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 11(11): 4180-4192, (2018).
- [17] S. Chen, H. Wang, F. Xu and Y. -Q. Jin, "Target Classification Using the Deep Convolutional Networks for SAR Images", *IEEE Transactions on Geoscience and Remote Sensing*, 54(8): 4806-4817, (2016).
- [18] İ. Türkoğlu ve A. Arslan, "Darbeli radarlarda hedef sınıflama için AR modelinin güç spektrumu ve yapay sinir ağı temelli özellik çıkarma yöntemi", *Politeknik Dergisi*, 5: 121-127, (2002).
- [19] S. Özden, M. Dursun, A. Aksöz ve A. Saygın, "Prediction and Modelling of Energy Consumption on Temperature Control for Greenhouses", *Politeknik Dergisi*, 22: 213-217, (2019).
- [20] M. Çalıřan, M. Talu, "Comparison of methods for determining activity from physical movements," *Politeknik Dergisi*, 24: 17-23, (2021).