




# Radarsız Hücresindeki Güç Seviyelerini Kullanarak Rüzgar Türbini Paraziti İçerisindeki Hedeflerin Sınıflandırılması

## Classification of Targets Within Wind Turbine Clutter Using Power Level in Radar Range Cells

Umurcan SAN<sup>1\*</sup>  Ali ÖTER<sup>2</sup>  Ali KARA<sup>3</sup> 

<sup>1</sup>Millî Savunma Üniversitesi, Alparslan Savunma Bilimleri ve Millî Güvenlik Enstitüsü, Askerî Elektronik Sistemler Mühendisliği Ana Bilim Dalı, Ankara, Türkiye

<sup>2</sup>Gazi Üniversitesi, Teknoloji Fakültesi, Enerji Sistemleri Mühendisliği Bölümü, Ankara, Türkiye

<sup>3</sup>Gazi Üniversitesi, Mühendislik Fakültesi, Elektrik-Elektronik Mühendisliği Bölümü, Ankara, Türkiye

### Makale Bilgisi

Araştırma makalesi  
Başvuru: 07.04.2025  
Düzeltilme: 26.05.2025  
Kabul: 15.07.2025

### Önemli Noktalar

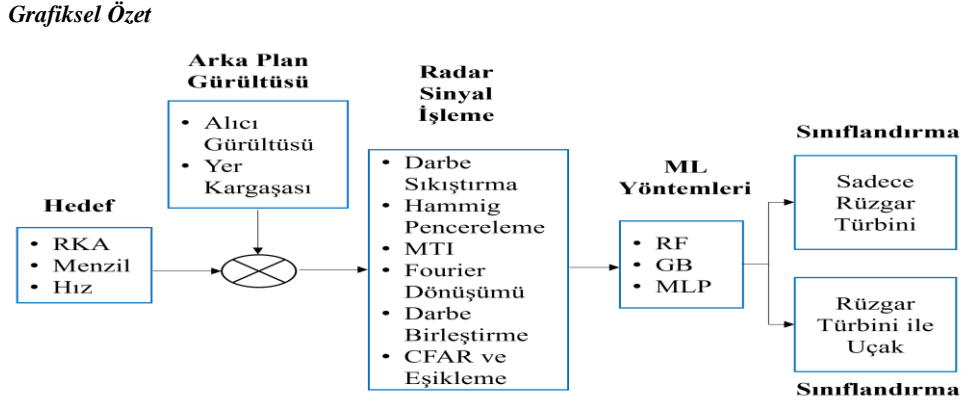
Radarsız hücrelerdeki güç seviyelerini kullanarak, iki hedef sınıfını güvenilir biçimde ayıran yapay zeka tabanlı yenilikçi bir yöntem önerilmiştir. RF, GB ve MLP sınıflandırıcılarıyla yapılan deneylerde, hedefler farklı hücrelerdeyken oldukça yüksek doğruluk sağlanmıştır. RF ve GB algoritmaları, hava trafiğinde önemli karar desteği sağlamaktadır.

### Anahtar Kelimeler

Radarsız  
Rüzgar Türbini  
Sınıflandırma

### Keywords

Radarsız  
Wind Turbine  
Classification



### Özet

Rüzgar türbini yoğunluğunun yüksek olduğu ve rüzgar türbinleri ile uçak arasındaki Radarsız Kesit Alanı (RKA) farkının büyük olduğu ortamlarda, rüzgar türbini parazitleri içerisinde tespit edilemeyen hedefler için, radarsız hücrelerdeki güç seviyelerine göre “sadece rüzgar türbini” ve “rüzgar türbini ile uçak” olmak üzere iki farklı hedef sınıfını ayırt etmeyi sağlayan bir sınıflandırma yaklaşımı önerilmiştir. RF, GB ve MLP sınıflandırıcılarıyla üç senaryoda yapılan değerlendirmelerde, hedefin türbinden farklı hücreye düştüğü durumlarda yüksek (~100%), aynı hücreye düştüğü durumlarda ise düşük (~50%) doğruluk elde edilmiştir. En iyi performans RF ve GB algoritmalarıyla sağlanmış olup bu yaklaşımın hava trafik kontrol personeline kaza kırım önleyici destek sağlaması amaçlanmaktadır.

### Abstract

In environments with high wind turbine density and significant differences in Radar Cross Section (RCS) between wind turbines and aircraft, a classification approach is proposed to distinguish between two target classes—“only wind turbine” and “wind turbine with aircraft”—based on power levels in radar range cells, particularly for targets that cannot be detected within wind turbine clutter. In evaluations conducted under three different scenarios using RF, GB, and MLP classifiers, high accuracy (~100%) was achieved when the aircraft and turbine appeared in different range cells, while accuracy dropped significantly (~50%) when both appeared in the same range cell. The best performance was observed with the RF and GB classifiers, and the proposed approach is intended to provide preventive support to air traffic control personnel to avoid potential aircraft incidents.

\*Corresponding author, e-mail: umurcan.san@msb.gov.tr

## 1. GİRİŞ (INTRODUCTION)

Tükenebilir enerji kaynaklarının azalması, enerji maliyetlerinin artışı, kaynaklardaki belirsizlikler ve çevre kirliliği gibi faktörler, birçok ülkeyi yenilenebilir enerji üretimine ve kullanımına yöneltmektedir. Bu bağlamda, rüzgar enerjisi son yıllarda en çok tercih edilen yenilenebilir enerji kaynaklarından biri haline gelmiştir.

Rüzgar türbinin; materyali, boyutu, şekli, rotor pozisyonu, radar frekansı, iletilen sinyalin türbine geldiği açı, alıcıdaki gözlem açısı, iletilen sinyalin ve alıcı antenin polarizasyonu bağlı olarak radar sistemlerinde sürekli değişen geniş bir RKA karakteristiği oluşturabilmektedir [1]. Radarların kullandığı S-bandı (2.7-2.9 GHz) ve L-bandı (1.3 GHz) frekanslarında yapılan elektromanyetik modelleme, bu boyutlardaki türbinlerin toplam RKA'sının 300.000 m<sup>2</sup>'ye kadar (55 dBm<sup>2</sup>) ulaşabileceğini göstermiştir. Sadece türbin kanatlarının RKA'sı her biri için 30.000 m<sup>2</sup> (45 dBm<sup>2</sup>) olabilmektedir [2].

Sabit yansıma kule ve türbin gövdesi tarafından üretilirken, dinamik yansıma dönen kanatlar tarafından oluşturulur. Ancak, bu dinamik yansımayı nicelleştirmek oldukça zordur; çünkü kanatların aerodinamik şekli, iç yapısındaki metalik ve metalik olmayan malzemeler ve üç farklı hareket türü (eğim, dikey ve yatay) gibi birçok faktör bu yansımayı etkilemektedir. Ayrıca, dönen kanatlar, elektromanyetik dalgaların kuleye ulaşmasını periyodik olarak engelleyebilir ve bu engellemeler, kuleden saçılan sinyalin genliğinin değişmesine neden olabilir. Doppler etkisi, dönen kanatlar tarafından üretilmekte olup kanatların dönüş hızı rüzgar hızına bağlı olarak değişirken, yönelimi de rüzgar

yönüne göre farklılık göstermektedir. Bunun yanı sıra, kanatların farklı bölümleri farklı radyal hızlara sahip olduğu için, radar sistemlerinde türbinlere ait geniş bir Doppler frekans spektrumu oluşabilir. Tüm bu faktörler, radar tarafından zamanla algılanan yansımanın miktarını değiştirerek karmaşık bir saçılma deseni oluşturmaktadır [3].

Rüzgar türbinlerinin hava trafik radar sistemleri üzerindeki olumsuz etkileri üç ana başlık altında incelenmektedir: kargaşa, hassasiyet kaybı ve gölgeleme.

**Kargaşa:** Türbinlerden kaynaklanan sabit ve dinamik yankıların radar ekranında gereksiz sinyaller oluşturarak sahte hedefler gibi görünmesine neden olur [4].

**Hassasiyet kaybı:** Rüzgar çiftliklerinin bulunduğu bölgede menzil ve açığı kapsayan bir alanda, hava hedeflerinin tespit olasılığının azalması olarak tanımlanmaktadır [2].

**Gölgeleme:** Rüzgar türbinlerinin radar dalgalarının geçişini fiziksel olarak engellemesi sonucu, türbinlerin arkasında veya yakınında bulunan hedeflerin algılanmasının zorlaşması şeklinde ortaya çıkmaktadır [5].

Bu etkiler arasında, dönen türbin kanatlarının uç hızlarının yavaş hareket eden uçaklarla karıştırılması [4], kargaşa haritası, irtifa hassasiyeti, azimut yan lobları, analog-dijital dönüştürücüler, darbe sıkıştırması, Doppler kargaşası ve Sabit Yanlış Alarm Oranı (CFAR) üzerindeki istenmeyen olumsuz etkiler nedeniyle gerçek hedef tespit hassasiyetinin azalması [2] ve yanlış hedef sınıflandırma gibi radar performansını doğrudan etkileyen faktörler bulunmaktadır [6]. Bu olumsuz etkiler, hava

trafik kontrolörlerinin uçakları doğru bir şekilde yönlendirmelerini zorlaştırabileceğinden uçuş güvenliğini tehlikeye atabilir ve sonucunda kaza kırım olayı oluşabilmektedir.

Rüzgar türbinlerinin radar sistemleri üzerindeki olumsuz etkilerini azaltmak veya ortadan kaldırmak için çeşitli teknik ve operasyonel çözümler geliştirilmiştir. Rüzgar türbinine yönelik; Radar Soğurucu Malzeme (RAM) kullanımı [7], fiziksel tasarımının değiştirilmesi [1,8], radar görüş hattından kaçınılması ve yerleşimi [9], radara yönelik; anten eğimi yönlendirme stratejisi, ek radar sistemleri [10], Hassasiyet-Zaman Kontrolü (STC), Menzil-Azimuth Sınırlaması (RAG) haritası, iz iliklendirme engellemesi, hız düzenlemesi, eş zamanlı hüzmeye işlemesi, gelişmiş CFAR ve Hareketli Hedef Göstergesi (MTI), iyileştirilmiş takip mekanizması, yatay hüzmeye genişliği ve menzil çözünürlüğü iyileştirilmesi, yüksek dinamik aralık, düşük menzil yan lob seviyesi, düşük iki yönlü anten hüzmeye yan lob seviyesi, Otomatik Olmayan Başlatma Bölgesi (NAİZ), plot/track filtreleme algoritmaları [11,12], CLEAN algoritması [11], düzenleyici kurumlara yönelik önlemler ve politikalar [13] uygulanabilir çözüm olarak önerilmektedir.

Olumsuz etki azaltma yöntemleri arasında, radar ve rüzgar türbini performansını ciddi şekilde düşürmeyecek, radarların mevcut tasarımlarında yüksek maliyetli modifikasyonlara ihtiyaç duymayacak çözümler ön plana çıkmaktadır. Bu bağlamda, maliyet etkin, performans açısından verimli ve güvenilir gereksinimlere uygun olarak geliştirilen sinyal işleme teknikleri ve hedef sınıflandırma algoritmaları dikkat çekmektedir. Dolayısıyla bahsedilen rüzgar türbininin olumsuz

etkisinin azaltılması çalışmaları her zaman uygulanabilir değildir.

Radar sistemleri üzerindeki rüzgar türbini kaynaklı parazitlerin azaltılabilmesi veya tamamen ortadan kaldırılabilmesi için en kritik adımlardan biri, türbinlerin konumlarının hassas bir şekilde belirlenmesidir. Türbin pozisyonlarının yanlış tespit edilmesi ya da hiç belirlenememesi durumunda, uygulanacak etki azaltma algoritmalarının etkinliği düşecek ve bu durum radar sisteminde ilave karmaşalara yol açabilecektir. Bu bağlamda, radar verileri ile türbinlerden kaynaklanan saçılma sinyalleri arasındaki spektral ve mekansal farklılıklardan yararlanılması, Doppler çözünürlüğünün artırılması ve türbinlere yerleştirilen transponderler ile türbin konum bilgilerinin doğrulanması [14] gibi yöntemler öne çıkmaktadır. Ayrıca, radarın belirli taramalarında elde edilen verinin genlik ortalamasına dayalı olarak dinamik bir kargaşa haritasının oluşturulması [15], derin öğrenme ve görüntü işleme tekniklerinin kullanımıyla radar verilerinden rüzgar türbini sinyallerinin ayrıştırılması ve hedef sınıflandırma yöntemleri aracılığıyla radar sinyallerinden türbin konumlarının belirlenmesi gibi yaklaşımlar, rüzgar türbinlerinden kaynaklanan radar performans bozulmalarını minimize etmek adına önemli çözümler sunmaktadır.

Rüzgar türbinlerinin radar sistemleri üzerindeki etkilerini analiz etmek ve uygun etki azaltma yöntemlerini belirlemek amacıyla, ölçüm verilerinin yanı sıra genellikle benzetim araçlarından yararlanılmaktadır. Gerçek saha ölçümleri, yüksek maliyet, zaman gereksinimi ve kontrol edilemeyen çevresel faktörler nedeniyle

her zaman uygulanabilir olmayabilir. Özellikle türbinlerin sayısı, konumları, rotor hareketleri ve radar parametreleri gibi birçok değişkenin etkili olduğu karmaşık senaryolar için, benzetim araçları daha esnek ve düşük maliyetli bir çözüm sunmaktadır. Bu kapsamda, bilgisayar tabanlı yazılım araçları geliştirilerek farklı operasyonel koşulları modellemek ve rüzgar türbinlerinin radar sistemleri üzerindeki etkilerini detaylı olarak incelemek mümkün hale gelmiştir.

Bu yazılımlar, rüzgar türbini sinyal modelleme yaklaşımlarıyla, rüzgar türbinlerinden kaynaklanan radar yankılarını ve Doppler imzalarını gerçekçi saha senaryolarında modelleyerek, radar performansına olan etkilerini analiz edebilecek şekilde tasarlanmıştır. Böylece türbinlerin, radar sistemlerindeki yanlış alarm oranlarını artırma, hedef tespit hassasiyetini düşürme veya Doppler filtreleme süreçlerini olumsuz etkileme gibi problemlere nasıl yol açtığı değerlendirilebilir [14].

Bu çalışmada, konumları önceden belirlenmiş rüzgar türbinlerinin etkilerinin de dahil edildiği senaryolar kapsamında, radar I/Q verileri, sinyal modelleme yaklaşımıyla oluşturulmuş ve ilgili sinyal işleme adımları uygulanmıştır.

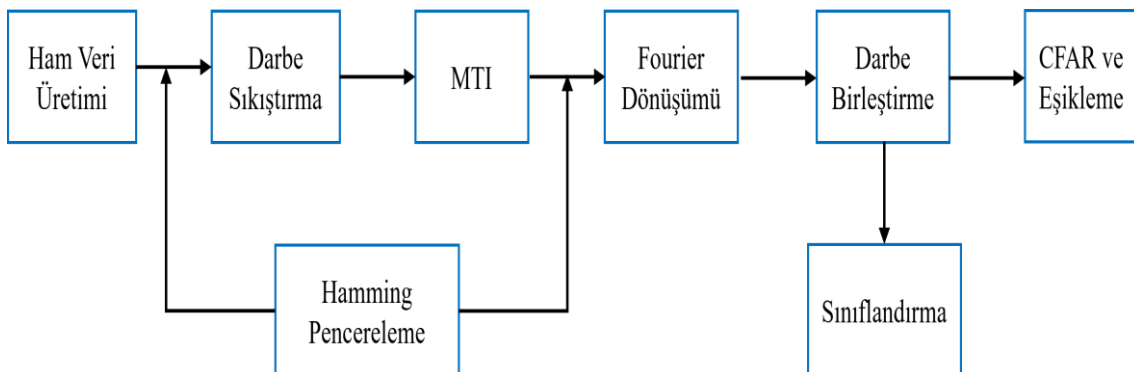
Çalışmanın ilk aşamasında, rüzgar türbini yoğunluğunun yüksek olduğu ve rüzgar türbinleri

ile uçak arasındaki RKA farkının büyük olduğu bir senaryoda, türbinlere ait menzil hücrelerindeki güç seviyelerinin CFAR eşik hesabına dahil edilmediği yöntemin etkinliği incelenmiştir. Yöntemin etkin olmadığı durumlarda, ikinci aşamada rüzgar türbini parazitleri içerisinde tespit edilemeyen hedefler için alternatif bir sınıflandırma süreci uygulanmıştır. Bu süreçte, tespit işlemi öncesinde, kargaşa arka plan bilgilerine bağlı olarak radar menzil hücrelerindeki güç seviyelerine göre "sadece rüzgar türbini" ve "rüzgar türbini ile uçak" olmak üzere iki farklı sınıfa ayrılması sağlanmıştır.

Önerilen yaklaşım, hava trafik kontrol personeline daha güvenilir ve verimli bir destek sağlamayı amaçlamaktadır. Gerçek sahada karşılaşılan bir senaryo modellenerek, radar menzil hücrelerindeki güç seviyelerine dayalı sınıflandırma yönteminin uygulanması literatürde bilindiği kadarıyla ilk kez gerçekleştirilmiş olup bu durum çalışmanın temel katkısını oluşturmaktadır.

## 2. ÖNERİLEN METHOD (PROPOSED METHOD)

Şekil 1'de görülen simülasyon konsepti, radar sinyal işleme adımları ve hedef sınıflandırma olmak üzere iki ana birimden oluşmaktadır.



Şekil 1: Simülasyon akış şeması.

Aşağıda, radar sinyal işleme adımlarının uygulanması ve sınıflandırma için gerekli veri setinin üretilmesi amacıyla kullanılan süreci özetleyen sözde kod yer almaktadır. Bu sözde kod, MATLAB ortamında yürütülen işlemleri kavramsal düzeyde temsil etmekte olup darbe üretimi, yankı sinyali oluşturulması, gürültü ve kargaşa eklenmesi, Hamming pencereleme, darbe sıkıştırma, 3 darbe iptal edici (MTI), 256 uzunlukta hızlı Fourier dönüşümü, 20 bağımsız darbe birleştirme, CFAR, eşikleme ve sınıflandırma verisinin hazırlanması gibi temel adımları içermektedir.

## **2.1. Sözde Kod: Radar Sinyal İşleme ve Sınıflandırma Süreci**

### **2.1.1. Radar Parametreleri Tanımlanır:**

Darbe süresi (T), bant genişliği (W), örnekleme frekansı (fs), PRF, taşıyıcı frekans, alınacak darbe ( $N_p$ ) sayısı tanımlanır.

### **2.1.2. LFM Darbe Sinyali Oluşturulur:**

Zaman ekseninde süresi T olan ve W bant genişliğinde bir cıvıltı sinyali Nyquist kuralına uygun olarak fs örnekleme oranında örneklenir.

### **2.1.3. Hedef Senaryosu Tanımlanır:**

Rastgele menzillerde ve sabit hızlarda hedefler yerleştirilir, her hedef için rastgele veya belirli SNR değerleri atanır.

### **2.1.4. Hedef Yankıları Oluşturulur:**

Her hedef için gecikme ve Doppler etkileri hesaba katılarak yankılar oluşturulur.

### **2.1.5. Termal Gürültü Eklenir:**

Sıfır ortalamalı kompleks Gauss gürültüsü şeklinde eklenir.

### **2.1.6. Kargaşa Sinyali Oluşturulur:**

Log-normal genlikli, üniform fazlı karmaşık gürültü, menzile bağlı zayıflama  $R^2$  ile ölçeklenir.

### **2.1.7. Toplam Sinyal Oluşturulur:**

Hedef yankıları, termal gürültü ve kargaşa birleştirilir.

### **2.1.8. Darbe Sıkıştırma Uygulanır:**

Alınan sinyal, gönderilen cıvıltı sinyalinin ters konjugesiyle eşleştirilir ayrıca Hamming pencere ile yan loblar bastırılır.

### **2.1.9. MTI Filtresi Uygulanır:**

Doppler frekansında düşük hızlı kargaşa bileşenlerini bastırmak için  $[1 \ -2 \ 1]$  şeklindeki darbe fark filtresiyle yavaş zaman üzerinde işlem yapılır.

### **2.1.10. Doppler FFT Uygulanır:**

Yavaş zaman ekseninde Doppler dönüşümü yapılır, ayrıca karmaşık değerli sinyalin karesi alınarak güç spektrumu elde edilir.

### **2.1.11. Darbe Birleştirme Yapılır:**

- Doppler eksenindeki tüm frekans hücreleri boyunca enerji toplanarak her bir menzil hücresi için toplam güç değeri hesaplanır.

- Rüzgar türbinlerinin radar sistemleri üzerindeki olumsuz etkilerini azaltmak veya ortadan kaldırmak amacıyla 2.1.12'nci adıma geçilerek türbinlere ait menzil hücrelerindeki güç seviyelerinin CFAR eşik hesabına dahil edilmediği yöntemin etkinliği incelenir.

- Yöntemin etkin olmadığı durumlarda, 2.1.13'üncü adıma geçilerek kargaşa arka plan bilgilerine bağlı olarak radar menzil hücrelerindeki güç seviyelerine göre "sadece

rüzgar türbini" ve "rüzgar türbini ile uçak" olmak üzere iki farklı sınıfa ayrılması sağlanır.

### 2.1.12. 1D CFAR ve Eşikleme İşlemi Uygulanır:

- Türbinlere ait menzil hücrelerindeki güç seviyeleri, CFAR eşik hesabına dahil edilmez.

- Her menzil hücresinin etrafındaki hücreler üzerinden ortalama gürültü seviyesi tahmin edilir. Bu işlemde hedef sinyalinin sızması için ortadaki test hücresi ve onunla komşu koruma hücreleri CFAR penceresinden hariç tutulur.

- Test hücresinin bu ortalama değere göre hedef içerip içermediği belirlenir.

### 2.1.13. Sınıflandırma Veri Seti Hazırlanır:

- Darbe birleştirme sonrası elde edilen menzil hücrelerine ait güç değerlerinden oluşan veriler kullanılarak sınıflandırma veri seti oluşturulur.

- Bu veri seti, 800 farklı durum (örnek) içerecek şekilde tasarlanmıştır.

- Temsil niteliğindeki bir veri örneği Şekil 7'de gösterilmiştir. Görselin okunabilirliğini artırmak amacıyla menzil eksenini 40 km ile sınırlandırılarak çizilmiştir. Ancak sınırlama yalnızca görsel amaçlıdır; işlenen veri seti radarın kapsadığı tüm menzil hücrelerini içermektedir.

### 2.1.14. Makine Öğrenimi Tabanlı Sınıflandırma Uygulanır:

- Bu çalışmada rüzgar türbinleri ile aynı ve farklı menzil hücrelerine düşen uçakların sınıflandırma performansları karşılaştırılmıştır. Bu amaçla 3 farklı senaryo (Senaryo 3.a, 3.b ve 3.c) tasarlanarak detaylı analiz yapılmıştır.

- Oluşturulan veri setlerinin %70'i eğitim, %30'u test için kullanılmıştır.

- RF (Random Forest), MLP (Multi-Layer Perceptron) ve GB (Gradient Boosting) yöntemleri ile sınıflandırma gerçekleştirilmiştir.

## 2.2. Radar Parametreleri

Bu çalışmada seçilen radar parametreleri Tablo 1'de sunulmuştur.

**Tablo 1:** Radar parametreleri.

Simülasyon Parametreleri	Değer	Birim
Frekans	3	GHz
Chirp Bant Genişliği	1	MHz
Darbe Süresi	90	$\mu s$
Örnekleme Frekansı	2	MHz
Darbe Tekrarlama Frekansı	1250	Hz
Birleştirilmiş Darbe Sayısı	20	-
MTI Filtre Tipi	3 Darbe İptal Edici	-
FFT Uzunluğu	256	-
CFAR Pencere Boyutu	23	-
CFAR Koruma Hücresi Boyutu	4	-
CFAR Referans Hücresi	18	-

## 2.3. Ham Veri Üretimi

Bu çalışmada kullanılan ATC radar verileri, gerçek ortamdan toplanmak yerine, fiziksel parametrelere dayalı olarak MATLAB ortamında geliştirilmiş bir simülasyon altyapısı ile yapay olarak üretilmiştir. Simülasyon süreci MATLAB üzerinde gerçekleştirildiği için, tüm işlemler ayrık zamanlı sinyaller üzerinden yürütülmüştür.

Simülasyonda ham radar verisinin oluşturulmasında; gönderilen LFM sinyalinin, hedeften yansdıktan sonra alınan yankısının menzil gecikmesi, Doppler frekansı, taşıyıcı frekans ve hedef SNR değeri gibi fiziksel büyüklüklerle modellenmesi esas alınmıştır. Gerçekçi bir radar ortamı elde edebilmek amacıyla, geri dönen sinyale beyaz Gauss alıcı gürültüsü ile birlikte log-normal dağılımlı yüzey kargaşası eklenmiş ve böylece zorlu çevresel

koşullar altında sistem performansının test edilebilmesi sağlanmıştır.

### 2.3.1. LFM Sinyal Üretimi

Gerçek radar vericisinin ürettiği modüle edilmiş karmaşık LFM sinyali aşağıdaki gibi tanımlanır [16]:

$$s(t) = \text{Rect}\left(\frac{t}{T}\right) \cdot e^{j2\pi(f_0 t + \frac{\mu}{2} t^2)} \quad (1)$$

Burada  $s(t)$  sürekli zamanlı karmaşık LFM sinyalini,  $T$  darbe süresini,  $t$  sürekli zaman değişkenini,  $f_0$  taşıyıcı frekansını,  $\mu = \frac{B}{T}$  civıltı oranını (frekans değişim hızını),  $B$  bant genişliğini,  $\text{Rect}\left(\frac{t}{T}\right)$  sinyalin sadece  $-\frac{T}{2} \leq t \leq \frac{T}{2}$  aralığında var olduğunu ifade eder.

Bu çalışmada ayrık zamanlı LFM sinyali şu şekilde elde edilmiştir:

$$s[n] = \exp\left(j\pi \frac{W}{T} \left(t_n - \frac{T}{2}\right)^2\right) \quad (2)$$

Burada  $s[n]$  ayrık zamanlı karmaşık LFM sinyalini,  $W$  bant genişliğini,  $T$  darbe süresini,  $t_n = n \cdot \frac{1}{f_s}$  örnekleme noktalarını,  $f_s$  örnekleme frekansını,  $N = T \cdot f_s$  örnek sayısını,  $n = 0, 1, \dots, N - 1$  örnek indeksleri ifade eder.

Simülasyon ortamında kullanılan sinyal, taşıyıcı frekans içermemektedir. Bunun sebebi, radar alıcılarında taşıyıcı frekansın karıştırıcı devrelerle ortadan kaldırılarak sinyalin temelbanda (sıfır frekansa) indirilmesidir. Bu sayede sayısal işlem (örneğin FFT, darbe sıkıştırma) daha düşük örnekleme frekanslarında ve daha az hesaplama yüküyle yapılabilir.

Teorik formülasyonlarda görülen dikdörtgen pencere ( $\text{Rect}$ ) fonksiyonu sinyalin zamanla sınırlı olduğunu gösterir. Ancak simülasyon ortamında sinyalin üretimi zaten belirli bir süreye

göre örneklendiği için ayrıca ( $\text{Rect}$ ) fonksiyonu kullanmaya gerek kalmamıştır.

### 2.3.2. Hedeften Gelen Radar Yankı Sinyalinin Modellenmesi

Simülasyon ortamında kullanılan hedef konumları, hızları ve SNR değerleri kullanıcı tarafından doğrudan tanımlanmıştır. Bu yaklaşım sayesinde farklı senaryolar oluşturularak radar performansı esnek bir şekilde değerlendirilebilmiştir. Simülasyon kapsamında radar tarafından 20 darbelik bir gönderim gerçekleştirilmiştir.

Bununla birlikte (3) eşitliğindeki SNR değerinin değişmesine neden olan parametrelere bakıldığında  $e^{-2aR_{max}}$  atmosferik zayıflama ve  $F^4$  yayılım faktörü etkileri simülasyonda dikkate alınmamıştır [17].

$$\begin{aligned} R_{max}^4 &= \frac{P_{av} G A p_a \sigma E_i(n) F^4 e^{-2aR_{max}}}{(4\pi)^2 k T_o F_n(B\tau) f_p \left(\frac{S}{N}\right)_1 L_f(n_e) L_s} \quad (3) \end{aligned}$$

Burada ayrıca  $R_{max}$  maksimum radar menziline,  $P_{av}$  ortalama iletim gücünü,  $G$  anten kazancını,  $A$  anten alanını,  $p_a$  anten açıklık katsayısını,  $\sigma$  RKA'yı,  $n$  darbe birleştirme sayısını,  $E_i(n)$  darbe birleştirme verimliliğini,  $a$  zayıflama katsayısını,  $k$  Boltzman sabitini,  $T_o$  standart sıcaklığını,  $F_n$  alıcı gürültü katsayısını,  $B$  alıcı bantgenişliğini,  $\tau$  darbe genişliğini,  $f_p$  darbe tekrarlama frekansını,  $\left(\frac{S}{N}\right)_1$  tek darbe tespiti için sinyal gürültü oranını,  $L_f(n_e)$  Swerling hedef modelinden dolayı dalgalanma kaybını,  $L_s$  ise sistem kaybını ifade eder.

Radar sistemine geri dönen yansıma sinyali, hedefin menzili, hızı ve taşıyıcı frekansı gibi parametrelere bağlı olarak modellenmiştir. Elde

edilen bu sinyal, bu çalışmada ayrık zamanlı olarak işlenmiş ve aşağıdaki eşitlikle ifade edilmiştir:

$$y[n, j] = A_i \cdot e^{-j2\pi f_0 \tau_i} \cdot e^{j2\pi f_{D_i} n \Delta t} \cdot e^{j\pi \mu (n \Delta t - \tau)^2} \quad (4)$$

Burada  $A_i = 10^{\frac{SNR(i)}{20}}$  i-nci hedefin SNR tabanlı genliğini,  $SNR(i)$  i-nci hedefin SNR değerini,  $f_0$  taşıyıcı frekansı,  $\tau_i = \frac{2r_i}{c+v_i}$  i-nci hedeften gelen gecikmeyi,  $r_i$  i-nci hedefin menziline,  $v_i$  i-nci hedefin hızını,  $c$  ışık hızını,  $f_{D_i} = \frac{2v_i f_0}{c}$  i-nci hedefin Doppler frekansını,  $\mu = \frac{B}{T}$  civıltı oranını,  $B$  bant genişliğini,  $T$  darbe süresini,  $\Delta t$  örnekleme aralığını,  $n$  örnek (menzil hücresi) indeksini,  $j$  darbe indeksini,  $i$  hedefi ifade eder.

Simülasyonlarda, radar ile rüzgar türbinleri arasında görüş hattı olduğu varsayılmış ve tüm rüzgar türbini segmentlerinin aynı çözünürlük hücresine nokta hedef olarak yerleştiği kabul edilmiştir.

### 2.3.3. Hedef Yankı Sinyaline Gürültü ve Kargaşanın Eklenmesi

Radar sistemlerinde alıcı gürültüsü genellikle bant sınırlı beyaz Gauss dağılımı (5) eşitliğiyle modellenmektedir [16].

$$f(x) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{(x-\mu)^2}{2\sigma^2}} \quad (5)$$

Burada  $f(x)$   $x$  noktasındaki fonksiyon değeri,  $\mu$  ortalama,  $\sigma$  standart sapma,  $\sigma^2$  varyans şeklinde ifade edilir.

Kargaşa, radar sinyallerinin istenmeyen nesnelere yansımaları sonucu oluşan parazit sinyaller olup yüzey kargaşası ve hacimsel kargaşası olarak iki ana kategoriye ayrılmaktadır. Yüzey kargaşası, ağaçlar, bitki örtüsü, yer şekilleri, yapay yapılar ve deniz yüzeyi (deniz

kargaşası) gibi nesnelere kaynaklanırken, hacimsel kargaşa genellikle yağmur, kar, kuş sürüleri ve atmosferik partiküllerden kaynaklanmaktadır [16]. Radar sistemlerinin kargaşa altındaki performansını değerlendirmek için geri saçılma katsayısının doğru bir şekilde tahmin edilmesi veya ölçülmesi kritik öneme sahiptir. Bir çözünürlük hücresinde veya hacim hücresinde yer alan kargaşa, rastgele faz ve genliklere sahip çok sayıda saçıcıdan oluştuğundan, geri saçılma katsayısı genellikle olasılık dağılım fonksiyonları kullanılarak istatistiksel olarak modellenmektedir [16]. Yüzey kargaşasının modellenmesinde en yaygın kullanılan olasılık dağılımı log-normal dağılımdır, çünkü birçok küçük saçıcıdan gelen sinyallerin çarpma etkisiyle değişmesi log-normal dağılımın karakteristiğine uygundur [16]. Log-normal dağılım, Gauss rastgele değişkenlerin logaritmasının normal dağılım göstermesi durumunda elde edilen bir dağılımdır.

Bu çalışmada, alıcı gürültüsü sıfır ortalama ve birim varyansa sahip karmaşık Gauss modeli ile modellenirken, radar sinyallerindeki yüzey kargaşasının gerçekçi bir şekilde modellenmesi amacıyla log-normal dağılım kullanılmıştır.

Log-normal dağılım oluşturmak amacıyla ilk olarak, Gauss rastgele değişkenler üretilmiş ve radar sistemlerinde dB üzerinden çalışıldığı için log-normal dönüşüm uygulanarak yüzey kargaşasının güç seviyeleri (6) eşitliği ile oluşturulmuştur.

$$X = 10^{\frac{Y}{10}} \quad (6)$$

Burada  $Y$  normal dağılıma sahipse log normal dönüşüm sonucu  $X$  elde edilir. Ardından, rastgele faz bileşenleri eklenerek, kargaşanın radar

sinyalinde gözlenen Doppler etkisine uygun hale gelmesi sağlanmıştır. Daha sonra, kargaşanın güç spektrumu Gauss şeklinde zorlanmış ve Fourier dönüşümü kullanılarak spektral korelasyon eklenmiştir, böylece radarın gerçek dünyada algıladığı spektral özellikler korunmuştur.

Simülasyonda, hem tüm sinyal boyunca hem de ilk menzil hücresinde Kargaşa-Gürültü Oranı (CNR) değeri 20 dB olarak belirlenmiştir. Daha sonra, kargaşa sinyali ilk menzil hücresinden itibaren menzile bağlı olarak  $R^2$  oranında azaltılmış, böylece gerçek radar ortamında kargaşanın menzil boyunca değişimini yansıtacak şekilde ölçeklendirilmiştir.

Son olarak, alıcı gürültüsü ve kargaşa sinyali radar sinyaline eklenerek simülasyonun gerçekçilik düzeyi artırılmış; bu sayede radarın kargaşa altındaki performansı ve hedef tespit yeteneği analiz edilmiştir. Bu çalışmada alıcıda oluşan toplam sinyal  $y_g[n]$  şeklinde ifade edilmiştir.

#### 2.4. Hamming Pencereleme

Radar ve genel sinyal işleme uygulamalarında kullanılan bir ağırlıklandırma tekniğidir. Temel amacı, sonlu uzunluktaki sinyallerin uç noktalarında oluşabilecek yan lobları bastırarak, işlenecek sinyalin hem zaman hem de frekans alanında daha temiz bir yapıya kavuşmasını sağlamaktır. Hamming penceresinin matematiksel ifadesi şu şekilde ifade edilir:

$$w[n] = 0.54 - 0.46 \cos\left(\frac{2\pi n}{N-1}\right) \quad 0 \leq n \leq N-1 \quad (7)$$

Burada  $w[n]$  n-ci örnekteki pencere katsayısını,  $N$  pencere uzunluğunu ifade eder.

Uygulamada sinyal, eşitlik (8) ile ağırlıklandırılır.

$$x_h[n] = h[n].w[n] \quad (8)$$

Burada  $x_h[n]$  Hamming pencerelemiş sinyali,  $h[n]$  pencereleme sinyali,  $h[n] = s^*[-n]$ ,  $s^*[-n]$  ise gönderilen ayrık zamanlı LFM sinyalinin eşlenik ve zamanda tersi alınmış halini,  $w[n]$  Hamming pencere katsayılarını, . karşılıklı elaman çarpımını ifade eder. Burada pencere boyutu, pencereleme sinyalinin matris boyutu kadardır. Bu çalışmada darbe sıkıştırma aşamasından önce LFM sinyaline pencereleme yapılmıştır. Bu, menzil doğrultusunda ortaya çıkabilecek yan lobların bastırılmasını sağlamıştır. Ayrıca Doppler frekans analizi öncesinde yavaş zaman (darbe) eksenindeki sinyale uygulanmıştır. Bu işlem, Doppler spektrumundaki yan lobların azaltılmasını ve hedeflerin daha net ayrılmasını sağlamıştır.

#### 2.5. Darbe Sıkıştırma

Radar darbe sıkıştırması, genellikle bir eşleşmiş filtre kullanılarak gerçekleştirilen bir işlemdir. Bu işlem, radar tarafından alınan sinyalin darbe genişliğini azaltarak daha iyi menzil çözünürlüğü ve SNR sağlar. Bu işlem, oluşturulan radar ham verilerinin hızlı zaman boyutunda yürütülür. Beyaz gürültü varsayımı altında, sürekli zamanlı filtre çıkışı şu şekilde ifade edilir [18]:

$$y(t) = x(t) * h(t) \quad (9)$$

$y(t)$  darbe sıkıştırma sonucu elde edilen sinyali,  $x(t)$  hedeften yansıyan sinyali,  $*$  konvolüsyon işlemini ve  $h(t) = a.s^*(T_p - t)$  gönderilen LFM sinyalin eşlenik ve zaman tersi alınmış halini,  $s(t)$  gönderilen LFM sinyali,  $s^*$  karmaşık eşleniği ifade eder. Burada  $a$  eşlenik filtre çıkışının genliğini belirleyen bir katsayı

olup SNR açısından önemsiz kabul edildiğinden çoğu analizde ihmal edilmektedir. Nedensellik koşullarını karşılamak için  $T_p$ 'nin giriş sinyalinin süresinden uzun olması gerekir [18].

Bu çalışmadaki ayrık zamanlı filtre çıkışı şu şekilde ifade edilir.

$$y_{ds}[n] = y_g[n] * x_h[n] \quad (10)$$

Burada  $y_{ds}[n]$  darbe sıkıştırma sonucu elde edilen sinyali,  $y_g[n]$  alıcıda oluşan toplam sinyali (hedef+gürültü),  $x_h[n]$  Hamming pencerelemiş sinyali ifade eder.

## 2.6. MTI

Radar sistemlerinde sabit arka plan yansımalarını engelleyerek hareketli hedefleri saptamak için kullanılan bir tekniktir. Bu operasyon çoğunlukla darbe iptal edici filtreler kullanılarak yavaş zaman boyutunda gerçekleştirilir. Bu çalışmada üç darbeli iptal edici kullanılmıştır. Darbe iptal edici yapılar düşük geçişli filtre olarak işlev görür ve sıfır-doppler ve çevresindeki frekans bölgelerini iptal eder. Kullanılan filtrenin ayrık zamanlı darbe cevabı şu şekilde ifade edilir [16]:

$$h_m[n] = \delta[n] - 2\delta[n-1] + \delta[n-2] \quad (11)$$

Burada  $h_m[n]$  MTI filtresinin darbe cevabını,  $\delta[n]$  ayrık zamanlı birim darbe fonksiyonunu,  $n$  darbe indeksini ifade ederken bu yapı filtre olarak uygulandığında bu çalışmadaki çıkış sinyali şu şekilde ifade edilir:

$$y_m[n] = y_{ds}[n] * h_m[n] \quad (12)$$

$y_m[n]$  MTI sonucu elde edilen sinyali,  $y_{ds}[n]$  darbe sıkıştırma sonucu elde edilen sinyali, \* konvolüsyon işlemini,  $h_m[n] = [1 - 2 \ 1]$  matrisini ifade eder.

## 2.7. Fourier Dönüşümü

Fourier dönüşümü, zaman domaindeki sinyallerin frekans domaine dönüştürülmesini sağlayan temel bir matematiksel araçtır. Radar sistemlerinde, alınan sinyallerin analiz edilmesi ve işlenmesi için yaygın olarak kullanılan bu dönüşüm, özellikle menzil, hız ve yön belirleme gibi kritik bilgilerin çıkarılmasında önemli bir rol oynar. Fourier dönüşümünün farklı boyutlardaki (1D, 2D, 3D) versiyonları, radar sinyal işleme sürecinde çeşitli amaçlarla uygulanmaktadır.

1D Fourier Dönüşümü, sinyalin yalnızca tek bir ekseninde frekans bileşenlerine ayrılmasıdır. Radar sistemlerinde genellikle yavaş zaman (darbe sayısı) ekseninde uygulanarak hedefin doppler frekansı, yani hız bilgisi elde edilir. Alternatif olarak, hızlı zaman ekseninde uygulanırsa menzil frekansı analizi yapılabilir [19].

2D Fourier dönüşümü, sinyalin hem hızlı zaman hem yavaş zaman eksenlerinde frekans bileşenlerine ayrılmasıdır. Radar uygulamalarında bu dönüşümle, aynı anda hem menzil (hızlı zaman) hem de hız (yavaş zaman) bilgisi elde edilir [19].

3D Fourier dönüşümü, üç boyutta (örneğin hızlı zaman, yavaş zaman ve faz açısı) uygulanarak hedefin üç boyutlu konum ve hareket bilgilerinin analiz edilmesine olanak tanır. Bu dönüşüm genellikle faz dizili vb. radar (phased-array radar) sistemlerinde kullanılmaktadır.

Bu çalışmada 1D Fourier dönüşümü uygulanmıştır. Yavaş zaman ekseninde gerçekleştirilen dönüşüm ile hedefin Doppler frekansı, yani hız bilgisi elde edilmiştir. Bu çalışmada Fourier dönüşümü eşitlik (13) ile elde edilmiştir.

$$y_f[n] = FFT(y_m[n] \cdot h_f[n]) \quad (13)$$

Burada  $y_f[n]$  Fourier dönüşümü uygulanmış sinyali,  $FFT$  Fourier dönüşümünü,  $y_m[n]$  MTI sonucu elde edilen sinyali,  $h_f[n]$  Hamming pencere katsayılarını ifade eder. Ayrıca darbe birleştirme adımında, sinyalin güç değerlerinin toplanması amacıyla eşitlik (14) kullanılmıştır.

$$y_{fg}[n] = y_f[n] \cdot y_f^*[n] \quad (14)$$

Burada  $y_{fg}[n]$  güç spektrumunu,  $y_f[n]$  Fourier dönüşümü uygulanmış sinyali,  $y_f^*[n]$  Fourier dönüşümü uygulanmış sinyalinin eşleniğini ifade eder.

### 2.8. Darbe Birleştirme

Radar sistemlerinde zayıf hedeflerden gelen sinyalleri güçlendirmek ve SNR'yi artırmak için kullanılan bir tekniktir. Radar, genellikle hedeflerden gelen yansımaları tespit etmek için birden fazla darbe gönderir ve alır. Bu darbelerden elde edilen sinyallerin birleştirilmesi (entegrasyonu), rastgele gürültünün etkisini azaltırken hedef sinyali güçlendirmeye yardımcı olur.

Bu çalışmada bağımsız darbe birleştirme kullanılmış olup radar tarafından alınan ardışık yankıların faz bilgisi dikkate alınmadan sadece Doppler ekseninde güçleri toplanmıştır. Bu işlemin çıkışı şu şekilde ifade edilir:

$$y_{ab}[n] = \sum_{k=1}^N y_{fg_k}[n] \quad (15)$$

$y_{fg_k}[n]$   $k$ -inci darbede  $n$ -inci menzil hücrendeki sinyali,  $N$  toplam darbe sayısını,  $y_{ab}[n]$  ise menzil hücresi  $n$  için entegre edilmiş toplam güç çıktısını ifade eder.

### 2.9. CFAR ve Eşikleme

Radar, arka plan gürültüsü ve sinyal gücü sürekli değişen ortamlarda çalıştığı için, sabit bir eşik değeri kullanmak yanlış alarm oranlarını artırabilir veya zayıf hedeflerin algılanmasını zorlaştırabilir. Hücre Ortalama Sabit Yanlış Alarm Oranı (CA-CFAR), her çözünürlük hücresi için çevresel gürültü seviyesine bağlı olarak eşik değerini dinamik bir şekilde belirleyerek sabit yanlış alarm oranı sağlamayı amaçlar. Şekil 2'de bir CA-CFAR yapısının 1D formu gösterilmiştir. Tespit eşiği, Test Altındaki Hücrenin (CUT) (Radarın belirli bir mesafedeki bir hedefin varlığını belirlemek için incelediği hücredir.) yanındaki referans hücrelerdeki (arka plan gürültü seviyesini tahmin etmek için kullanılır.) ortalama gücü  $Z$  kullanılarak değerlendirilir. Tespit sürecinde yanlış alarmları düzenlemek için kullanılan marj, şekilde  $K_o$  ile belirtilmiştir. Şekilde gösterilen koruma hücreleri, test altındaki hedef sinyalinin bu hücrelere sızıntı yapması ihtimali dikkate alınarak ortalama müdahale değerlendirmesinden hariç tutulmuştur. Eğer  $Y_1 \geq K_o Z$  ise hedef var olarak işaretlenmektedir [16].

Uygulamada radar sinyali üzerinde kayan bir pencere kullanılır. Bu pencere, referans hücrelerin yerini belirler ve bu hücrelerin ortalamasını alır. Bunun için genellikle konvolüsyon işlemi kullanılır.

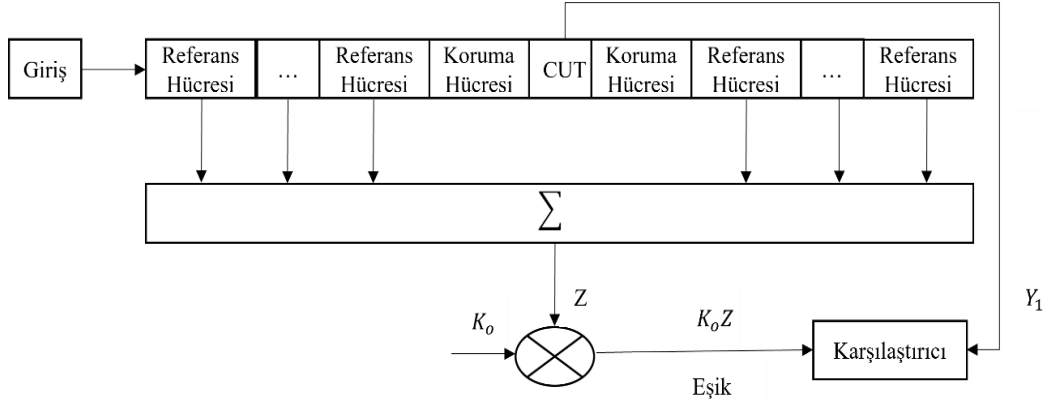
$$y_{cfar}[n] = y_{ab}[n] * CFAR[n] \quad (16)$$

Burada  $y_{cfar}[n]$  CFAR uygulanmış sinyali,  $y_{ab}[n]$  darbe birleştirme uygulanmış sinyali,  $CFAR[n]$  CFAR filtresini (Bu çalışmada kullanılan CFAR penceresi  $1 \times 23$  boyutundadır. 1-9 ve 15-23 aralığındaki hücreler, ortalama güç

hesaplanmasında kullanılmak üzere  $1/18$  değerini alırken; 10–14 aralığındaki hücreler ise test ve koruma hücreleri olduğundan, hedef sinyalinin eşiği etkilememesi amacıyla 0 değerine sahiptir.) temsil eder.

Bu çalışma kapsamında, Doppler-filtresi uygulanmış menzil eksenindeki sinyaller üzerine 1D CA-CFAR algoritması uygulanmıştır. Bu

işlemede, her çözünürlük hücresi için çevresindeki referans hücrelerden ortalama gürültü seviyesi hesaplanmış, bu değer üzerine sabit yanlış alarm oranına göre belirlenen eşik katsayısı uygulanarak adaptif bir tespit eşiği oluşturulmuştur. Eşik değeri ile ölçülen sinyal karşılaştırılmış ve eşik üzeri değerler hedef olarak işaretlenmiştir.



Şekil 2: CA-CFAR.

## 2.10. ML Yöntemleri

Makine öğrenimi, büyük veri setlerinden anlamlı bilgiler çıkararak tahmin ve sınıflandırma yapmayı amaçlayan bir disiplindir. Sınıflandırma problemleri, genellikle denetimli öğrenme teknikleriyle çözülür. En yaygın kullanılan yöntemler arasında RF, GB ve yapay sinir ağları olarak bilinen MLP yer almaktadır. Bu yöntemler tıp, finans, güvenlik ve pazarlama gibi birçok alanda kullanılmaktadır. ML tabanlı sınıflandırma, büyük veri çağında önemli bir rol oynamakta ve karar destek sistemlerinden otomatik süreçlere kadar geniş bir yelpazede kullanılmaktadır. Model seçiminde dikkatli olunmalı, farklı algoritmaların performansı karşılaştırılmalı ve en iyi sonuçları elde etmek için sürekli iyileştirme çalışmaları yapılmalıdır. Bu çalışmada kullanılan ML modelleri aşağıda kısaca tanımlanmıştır.

**Random Forest (RF):** Çok sayıda karar ağacını bir araya getirerek çalışan sınıflandırma ve regresyon için kullanılan bir topluluk öğrenme yöntemidir. Her bir karar ağacı farklı rastgele örnekler ve özelliklerle eğitilir. Sınıflandırma sırasında, her karar ağacı bağımsız bir tahmin yapar ve en fazla oyu alan sınıf nihai tahmin olarak belirlenir. Çoğunluk oylama formülü kullanılarak, her ağacın tahmin ettiği sınıf hesaplanır ve en fazla destek alan sınıf nihai karar olarak atanır.  $K$  tur eğitim sonucunda, bir sınıflandırma modeli dizisi  $\{h_1(X), h_2(X), \dots, h_k(X)\}$  elde edilir ve bu modeller bir çok sınıflı sınıflandırma sistemi oluşturmak için birleştirilir. Sistemin nihai sınıflandırma sonucu, basit çoğunluk oylama yöntemi kullanılarak belirlenir. Son sınıflandırma kararı şu şekilde ifade edilir [20]:

$$H(x) = \arg \max_Y \sum_{i=1}^K I(h_i(x) = Y) \quad (17)$$

Burada  $H(x)$  nihai toplu sınıflandırma modeli,  $h_i$  tek bir karar ağacının sınıflandırma modeli,  $Y$  çıktı sınıfı,  $I(\cdot)$  gösterge fonksiyonu olup karar ağaçlarının belirli bir sınıfı seçtiğini ifade eder.

**Gradient Boosting (GB):** Karar ağaçlarını aşamalı olarak eğiten bir öğrenme yöntemidir. Her yeni ağaç, bir önceki ağaçların yaptığı hataları düzeltecek şekilde optimize edilir. Bu süreç, modelin her iterasyonda daha doğru tahminler yapmasını sağlar. GB, kayıp fonksiyonunu minimize etmek için Gradyan İnişi yöntemini kullanır. Modelin hata oranını azaltmak amacıyla, bir önceki karar ağacının hataları analiz edilir ve yeni model, bu hataların negatif gradyanına yönlendirilerek güncellenir. Böylece, modelin doğruluğu her adımda iyileşir. Boosting tekniği, her yeni modelin hata azaltmaya odaklanan bir düzeltme modeli gibi çalışmasını sağlar. Aşamalı ekleme yöntemi sayesinde model giderek daha güçlü hale gelir. Ancak, aşırı öğrenmeyi önlemek için model belirli bir hata eşliğine ulaştığında eğitim süreci durdurulur. Bu yaklaşım, modelin genelleme yeteneğini artırarak bilinmeyen verilere karşı daha başarılı tahminler yapmasını sağlar. GB'nin en önemli avantajlarından biri, uygulanabilirliğinin kolay ve aynı zamanda güçlü bir model olmasıdır. Aykırı değerlere karşı dayanıklı olup karmaşık ve farklı türde verilerle etkili bir şekilde çalışabilir. Bu özellikleri sayesinde, geniş bir kullanım alanına sahip olup özellikle büyük veri setleri üzerinde başarılı sonuçlar elde edebilir. GB'nin nasıl çalıştığını ve modelin nasıl oluşturulduğunu açıklayan genel matematiksel ifadesi şu şekilde tanımlanır [21]:

$$F_m(x) = \sum_{m=0}^M \gamma_m h_m(x) \quad (18)$$

Burada  $F_m(x)$  GB modelinin  $m$ . iterasyondaki toplam tahmin fonksiyonu,  $M$  GB modelinde kullanılan toplam zayıf öğrenici sayısı,  $h_m(x)$   $m$ . adımda oluşturulan karar ağacı modeli,  $\gamma_m$  öğrenme oranı ile ölçeklendirilmiş model katsayısıdır.

**Multi-Layer Perceptron (MLP):** Bir tür yapay sinir ağı modelidir. Yapay sinir ağları, geçmişte meydana gelen eğilimlere dayalı tahmin araçlarıdır. Girdi verilerini işleyerek, ağırlıklar ve aktivasyon fonksiyonları yardımıyla doğrusal olmayan ilişkileri öğrenir ve özellikle derin öğrenme uygulamalarında yaygın olarak kullanılır. MLP'nin temel çalışma prensibi, ileri yayılım süreci ve katmanlar arasındaki bilgi akışının matematiksel ifadesi şu şekilde tanımlanır [22]:

$$x_{[l,i]} = \sigma_{[l,i]} \left( \sum_{j=1}^{N_{[l-1]}} \omega_{[l-1,j],[l,i]} x_{[l-1,j]} + b_{[l,i]} \right) \quad (19)$$

Burada  $x_{[l,i]}$   $l$ 'inci katmandaki  $i$ 'inci düğümün aktivasyon çıktısını,  $\sigma_{[l,i]}$   $l$ 'inci katmandaki  $i$ 'inci düğümün aktivasyon fonksiyonu,  $N_{[l-1]}$   $(l-1)$ 'inci katmandaki toplam nöron sayısını,  $\omega_{[l-1,j],[l,i]}$   $(l-1)$ 'inci katmandaki  $j$ 'inci düğüm ile  $l$ 'inci katmandaki  $i$ 'inci düğüm arasındaki bağlantı ağırlığını,  $x_{[l-1,j]}$   $(l-1)$ 'inci katmandaki  $j$ 'inci düğümün aktivasyon çıktısı,  $b_{[l,i]}$   $l$ 'inci katmandaki  $i$ 'inci düğümün önyargı terimini ifade eder.

## 2.11. Değerlendirme Kriterleri

Makine öğrenimi ve istatistikte kullanılan performans ölçütleri, bir modelin sınıflandırma başarısını değerlendirmek için önemli

metriklerdir. Bu ölçütler, genellikle karışıklık matrisi kullanılarak hesaplanır.

**Doğruluk:** Modelin doğru tahmin ettiği örneklerin, tüm örnekler içerisindeki oranını ifade eder. Tüm sınıflar için genel başarıyı ölçer.

$$Doğruluk = \frac{TP + TN}{TP + TN + FP + FN} \quad (20)$$

**Kesinlik:** Modelin pozitif olarak tahmin ettiği verilerin gerçekten pozitif olup olmadığını ölçer. Yanlış pozitiflerin etkisini değerlendirir.

$$Kesinlik = \frac{TP}{TP + FP} \quad (21)$$

**Duyarlılık:** Modelin gerçek pozitifleri ne kadar doğru tespit ettiğini gösterir.

$$Duyarlılık = \frac{TP}{TP + FN} \quad (22)$$

**F1-Skoru:** Kesinlik ve duyarlılık arasındaki dengeyi ölçen bir metriktir. Özellikle sınıflar arasında dengesizlik olduğunda tercih edilir.

$$F1 - Score = 2x \frac{Kesinlik \times Duyarlılık}{Kesinlik + Duyarlılık} \quad (23)$$

Denklemlerde TP (doğru pozitif), FP (yanlış pozitif), TN (doğru negatif), FN (yanlış negatif) şeklinde kullanılmıştır [23].

### 3. BULGULAR (RESULTS)


Bu çalışma kapsamında oluşturulan senaryoların özeti Tablo 2’de sunulmuştur.

**Tablo 2:** Simülasyonda kullanılan senaryolar.

Senaryo	Senaryo Tanımı ve Parametreleri	Yöntem
1	16-18 km arasında 3 rüzgar türbini, 19 km’de 1 uçak bulunmaktadır. Her senaryo çalıştırıldığında, her bir rüzgar türbini ile uçak arasındaki RKA farkı rastgele atanarak -20 dB aralığında olacak şekilde ayarlanmaktadır.	CFAR
2	16-20 km arasında 9 rüzgar türbini, 28 km’de 1 uçak bulunmaktadır. Her senaryo çalıştırıldığında, her bir rüzgar türbini ile uçak arasındaki RKA farkı rastgele atanarak 30-40 dB aralığında olacak şekilde ayarlanmaktadır.	CFAR
3.a	16-20 km arasında 9 rüzgar türbini, 16-30 km arasında 1 uçak yer almaktadır. Her senaryo çalıştırıldığında, uçağın konumu rastgele belirlenmekte ve her bir rüzgar türbini ile uçak arasındaki RKA farkı rastgele atanarak 30-40 dB aralığında olacak şekilde ayarlanmaktadır.	Sınıflandırma
3.b	16-20 km arasında yer alan 9 rüzgar türbini ile aynı menzil hücrelerine karşılık gelecek şekilde, aynı mesafelerde 1 uçak yer almaktadır. Her senaryo çalıştırıldığında, uçağın konumu rastgele belirlenmekte ve her bir rüzgar türbini ile uçak arasındaki RKA farkı rastgele atanarak 30-40 dB aralığında olacak şekilde ayarlanmaktadır.	Sınıflandırma
3.c	16-20 km arasında 9 rüzgar türbini, 23-30 km arasında yani farklı menzil hücrelerinde 1 uçak yer almaktadır. Her senaryo çalıştırıldığında, uçağın konumu rastgele belirlenmekte ve her bir rüzgar türbini ile uçak arasındaki RKA farkı rastgele atanarak 30-40 dB aralığında olacak şekilde ayarlanmaktadır.	Sınıflandırma


**Senaryo 1:** Rüzgar türbini yoğunluğunun yüksek olduğu ve rüzgar türbinleri ile uçak arasındaki RKA farkının büyük olduğu bir ortamda, 16, 17, 18 km’de (193, 207, 220 menzil hücresi) 3 rüzgar türbini ile 19 km’de 1 uçak bulunduğu; türbinler ile uçak arasındaki RKA farkının yaklaşık 20 dB

olduğu varsayılmıştır. İlgili senaryo Şekil 3’te gösterilmektedir. Senaryo 2’de yapılacak çalışmaya altyapı hazırlaması amacıyla bu senaryo özelinde önerilen CFAR aşaması ve yalnızca bu senaryo için radar sinyal işleme sonuçları sunulmuştur.



Şekil 3: Senaryo 1'in betimlenmiş hali.

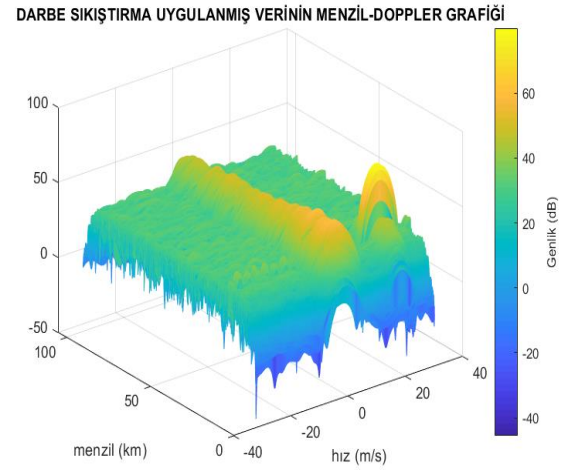
Senaryo 1 kapsamında oluşturulan 1 (bir) veriye ait sinyal işleme adımlarının sonuçları aşağıda sunulmuştur. Şekil 4, hedeflerden yansıyan ancak henüz hiçbir işleme tabi tutulmamış ham radar verisini göstermektedir. Bu aşamada LFM darbesi gönderilmiş; hedef konumları, Doppler frekansları ve SNR değerleri gibi fiziksel parametrelere göre yansıyan sinyaller modellenmiştir. Buna ek olarak, yüzey kaynaklı kargaşa ve alıcı termal gürültüsü eklenmiştir. Elde edilen grafik, menzil-hız düzleminde sinyal genliklerini görselleştirerek hedef sinyallerinin parazit ile iç içe olduğu ham durumu yansıtmaktadır.



Şekil 4: Ham veri.

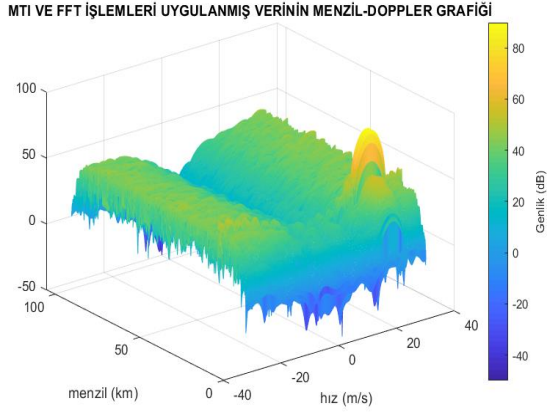
Şekil 5'te görüldüğü üzere, sinyallere darbe sıkıştırma işlemi uygulanmıştır. Darbe sıkıştırma ile gerçekleştirilen bu işlem, yankıların zamansal

olarak daralmasını sağlayarak menzil çözünürlüğünü artırır. Grafikte, hedef yankılarının daha dar bir menzil aralığında ve daha yüksek genlikte gözlemlendiği, dolayısıyla arka plan paraziti içinden daha kolay ayırt edilebildiği görülmektedir.




Şekil 5: Darbe sıkıştırma.

Şekil 6'da darbe sıkıştırılmış veriye, MTI filtresi ve ardından Doppler ekseninde FFT uygulanmıştır. MTI işlemi sabit hedefleri bastırır ve yalnızca hareketli hedefleri ön plana çıkarır. FFT işlemi ile yavaş zaman ekseninde frekans çözümlemesi yapılmış ve hedeflerin hızları Doppler frekansı üzerinden ayrıştırılmıştır. Bu sayede hem menzil hem de hız ekseninde hedef ayırımı sağlanmıştır.



**Şekil 6:** MTI.

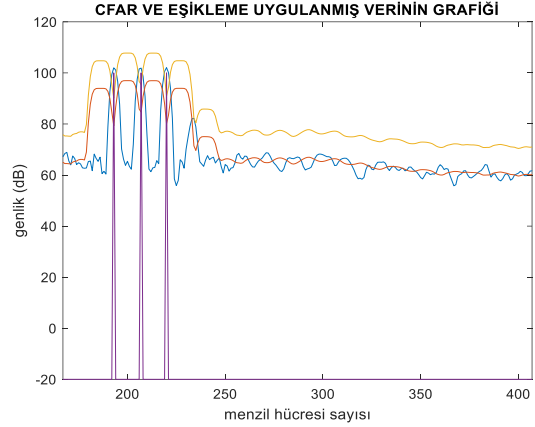
Şekil 7’de, nonkoherent darbe birleştirme uygulanmış verilere ait grafik sunulmaktadır. Güç değerleri üzerinden gerçekleştirilen bu işlem, SNR’yi artırarak hedef yankılarını belirginleştirmiştir. Çalışmada görsellik amacıyla menzil eksenini [10 30] km ve menzil hücresi [167 407 (14 ve 32 km’ye denk gelen menzil hücreleri)] aralığında sınırlandırılmış; ancak işlenen veri seti tüm menzil eksenini ve hücrelerini kapsamaktadır.



**Şekil 7:** Darbe birleştirme.


Şekil 8, CFAR ve eşikleme algoritmasının uygulanmış hâlini göstermektedir. Burada CA-CFAR algoritması kullanılarak her menzil hücresi için adaptif eşik değerleri hesaplanmış, ardından bu eşik ile hedef tespiti gerçekleştirilmiştir. Grafikte, sinyal genliği ile

birlikte eşik seviyesi ve tespit edilen hedefler birlikte gösterilmiştir. Ancak bu aşamada, rüzgar türbinlerinin bulunduğu bölgelerdeki birkaç hücrenin eşik seviyesini yükseltmesi nedeniyle uçak tespiti yapılamamıştır.



**Şekil 8:** Rüzgar türbinleri hesaba katıldığında CFAR ve eşikleme.

Şekil 9’da ise önerilen geliştirilmiş CFAR yöntemi uygulanmıştır. Bu yöntemde, eşik hesaplaması sırasında yalnızca türbin hücreleri değil, bunların önündeki ve arkasındaki beşer menzil hücresi (toplamda yaklaşık 800 metre) de hesaplama dışı bırakılmıştır. Böylece, özellikle rüzgar türbini yoğunluğunun düşük olduğu ve RKA farkının küçük olduğu durumlarda uçak hedeflerinin başarıyla tespit edildiği gözlemlenmiştir.




**Şekil 9:** Rüzgar türbinleri hesaba katılmadığında CFAR ve eşikleme.

Rüzgar türbini yoğunluğunun yüksek olduğu ve rüzgar türbinleri ile uçak arasındaki RKA farkının büyük olduğu bir ortamda önerilen CFAR yönteminin etkinliğinin incelenmesi amacıyla Senaryo 2 ele alınmıştır.

**Senaryo 2:** Gerçek sahada karşılaşılan rüzgar türbini yoğunluğunun yüksek olduğu ve rüzgar türbinleri ile uçak arasındaki RKA farkının büyük olduğu bir ortamda, 16, 16.5, 17, 17.5, 18, 18.5,

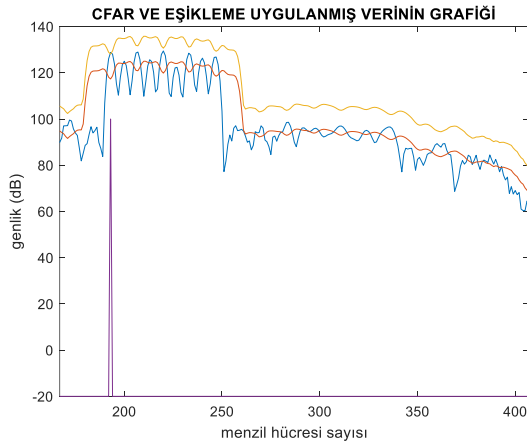
19, 19.5 ve 20 km'de (193, 200, 207, 213, 220, 227, 233, 240, 247 mesafe hücreleri) 9 rüzgar türbini ile 28 km'de (353 mesafe hücresi) bir uçak bulunduğu; türbinler ile uçak arasındaki RKA farkının 30-40 dB arasında değiştiği varsayılmıştır. İlgili senaryo Şekil 10'da gösterilmektedir. Bu senaryo altında uçak, 16-30 km aralığında tespit edilememiştir.




**Şekil 10:** Senaryo 2'nin betimlenmiş hali.

Senaryo 2 sonucunda, rüzgar türbinlerinin birbirine yakın konumda olması ve CFAR eşliğinin yükselmesi nedeniyle Şekil 11'de yalnızca 1 adet rüzgar türbini tespit edilmiştir.

Önerilen yöntemde, radarın 25 km'ye kadar olan bölgedeki hücreleri ihmal edilse bile, gerçek hava hedefine ait izlerin tespit edilemediği Şekil 12'de gözlemlenmiştir.



**Şekil 11:** Rüzgar türbinleri hesaba katıldığında CFAR ve eşikleme.




**Şekil 12:** Rüzgar türbinleri hesaba katılmadığında CFAR ve eşikleme.

Senaryo 2 kapsamında uçakların tespit edilememesi, ATC personeline destek için makine öğrenimi tabanlı sınıflandırma çalışmalarının önemini ortaya koymuştur.

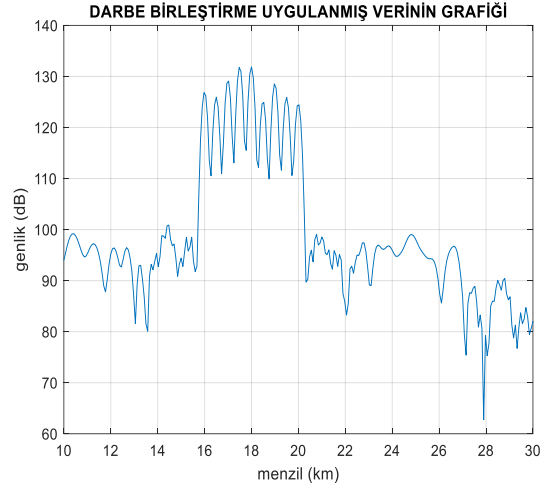
Bu doğrultuda, sınıflandırma yönteminin etkinliğini değerlendirmek üzere Senaryo 3 ele alınmıştır.

**Senaryo 3:** Bu çalışma özelinde rüzgar türbini ile aynı ve farklı menzil hücrelerine düşen uçakların sınıflandırma performansındaki farklılıkları incelemek amacıyla 3 farklı senaryo (Senaryo 3.a, 3.b ve 3.c) üzerinden detaylı bir çalışma gerçekleştirilmiştir. Bu senaryolardaki veri seti, %70'i eğitim ve %30'u test olmak üzere ayarlanmıştır. Örnek bir veriye ait görseller, Şekiller (13-15)'de sunulmuştur.


Bu veri seti radar sinyal işleme adımlarından biri olan darbe birleştirme işlemi sonrasında elde edilen sinyallerin güç değerleri temel alınarak 800 farklı durumu temsil edecek şekilde oluşturulmuştur. Bu veri setleriyle MATLAB üzerinden 3 farklı ML yöntemi ile sınıflandırma yapılmıştır.



**Şekil 13:** Senaryo 3.a kapsamında oluşturulan örnek bir sinyal.




**Şekil 14:** Senaryo 3.b kapsamında oluşturulan örnek bir sinyal.



**Şekil 15:** Senaryo 3.c kapsamında oluşturulan örnek bir sinyal.

**Senaryo 3.a:** İlgili senaryo Şekil 16'da gösterildiği üzere, 16-20 km menzil aralığında 9 rüzgar türbini ve 16-30 km aralığında farklı mesafelerde konumlandırılmış 1 uçak içeren yapı temel alınarak oluşturulmuştur. Bu senaryoya göre, eğitim verisi amacıyla 350 adet farklı sinyal üretilmiştir. Tablo 3'de sunulan sınıflandırıcıların hiperparametreleri, bu 350 adet sinyal üzerinden uygulanan çapraz doğrulama yöntemiyle belirlenmiş; ardından en uygun parametrelerle sınıflandırıcılar yeniden tüm eğitim verisi (350 sinyal) kullanılarak eğitilmiş ve sonrasında farklı 150 adet test verisi üzerinde performansları değerlendirilmiştir.




Şekil 16: Senaryo 3.a'nın betimlenmiş hali.

Sınıflandırıcıların hiperparametre değerleri Tablo 3'de sunulmuştur.

**Tablo 3:** Sınıflandırıcıların hiperparametre değerleri.

Modeller	En İyi Parametreler
RF	NumTrees=100
	MinLeafSize=1
	MaxNumSplits=200
MLP	HiddenLayerSize= 24
	LearningRate=11
GB	NumLearningCycles=50
	MinLeafSize=5
	MaxNumSplits=29

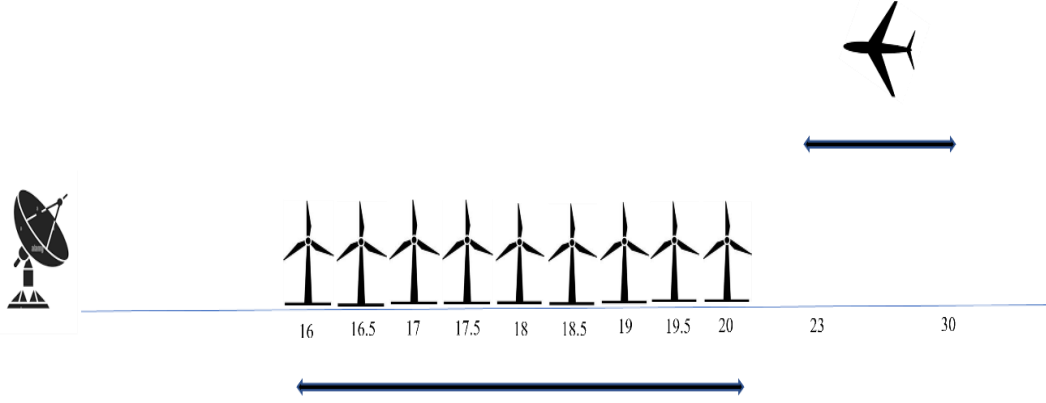
**Senaryo 3.b:** İlgili senaryo Şekil 17'de gösterildiği üzere, 16-20 km menzil aralığında 9 rüzgar türbini ve aynı menzil aralığında (aynı menzil hücrelerinde) farklı mesafelerde konumlandırılmış 1 uçak içeren yapı temel alınarak oluşturulmuştur. Bu senaryoya göre, test amacıyla 150 adet farklı radar sinyali üretilmiştir. Senaryo 3.a kapsamında eğitilen sınıflandırıcıların performansı, bu test verileri üzerinde değerlendirilmiştir.



Şekil 17: Senaryo 3.b'nin betimlenmiş hali.

**Senaryo 3.c:** İlgili senaryo Şekil 18'de gösterildiği üzere, 16-20 km menzil aralığında 9 rüzgar türbini ve 23-30 km (farklı menzil hücrelerinde) aralığında farklı mesafelerde konuşlandırılmış 1 uçak içeren yapı temel alınarak oluşturulmuştur. Bu senaryoya göre, test

amacıyla 150 adet farklı radar sinyali üretilmiştir. Senaryo 3.a kapsamında eğitilen sınıflandırıcıların performansı, bu test verileri üzerinde değerlendirilmiştir. Senaryo 3 kapsamındaki sınıflandırıcıların performans metrikleri Tablo 4'de sunulmuştur.



Şekil 18: Senaryo 3.c'nin betimlenmiş hali.

Tablo 4: Senaryo 3 kapsamındaki sınıflandırıcıların performans metrikleri.

Senaryolar	Modeller	Doğruluk	Kesinlik	Duyarlılık	F1-Score
Senaryo 3.a	RF	0.5067	1	0.0133	0.0263
	MLP	0.50667	0.51515	0.22667	0.31481
	GB	0.51333	1	0.026667	0.051948
Senaryo 3.b	RF	0.5067	1	0.0133	0.0263
	MLP	0.5	0.5	0.21333	0.29907
	GB	0.54667	0.64	0.21333	0.32
Senaryo 3.c	RF	1	1	1	1
	MLP	0.89333	0.82418	1	0.90361
	GB	1	1	1	1

Model performansı senaryoya göre büyük farklılık göstermektedir.

Senaryo 3.a ve 3.b'de tüm modellerin düşük performans göstermesi, rüzgar türbinlerinin uçaklara kıyasla daha büyük boyutlara sahip olması ve anlık oryantasyona bağlı olarak zamanla değişen yüksek RKA (30-40 dB) karakteristikleri sergilemesi nedeniyle, ilgili senaryoların veri açısından zorluk içerebileceğini düşündürmektedir.

Senaryo 3.c'de modeller mükemmel performans göstermiştir, bu da veri kümesinin belirgin

ayrılımlar içerebileceğini dolayısıyla modelin burada daha iyi çalıştığını göstermektedir.

GB modeli genel olarak MLP ve RF'ye kıyasla daha iyi doğruluk sağlamıştır, ancak modelin başarısı senaryoya bağlı olarak değişmektedir. RF modeli, Senaryo 3.c dışında diğer senaryolarda zayıf bir performans sergilemiştir. MLP, Senaryo 3.a ve 3.b'de düşük performans gösterse de Senaryo 3.c'de en yüksek doğruluk oranına ulaşmıştır.

#### 4. TARTIŞMA (DISCUSSION)

Radar sistemlerinde rüzgar türbini kaynaklı parazitlerin giderilmesi ve hava hedeflerinin doğru sınıflandırılması, literatürde farklı yaklaşımlar ile ele alınmıştır. Bu çalışmada önerdiğimiz yöntem, diğer çalışmalardaki yöntemlerle kıyaslanmış olup ilgili çalışmaların özeti Tablo 5’de sunulmuştur. Başarım açısından kıyaslandığında önerilen yöntem, belirli durumlarda yüksek doğruluk sağlasa da, rüzgar türbinleri ile aynı menzil hücrelerinde bulunan uçaklar için sınıflandırma başarımı düşmektedir.

Diğer çalışmalar, özellikle mikro-Doppler ve STFT tabanlı yaklaşımlar, bu tür durumlarda daha yüksek başarı elde edebilmiştir. Senaryo ve uygulanabilirlik açısından kıyaslandığında önerilen yöntem, yüksek RKA farkı ve türbin yoğunluğu içeren karmaşık bir senaryoda test edilmiştir, bu da yöntemin zorlu koşullarda nasıl performans gösterdiğini ortaya koymaktadır. Diğer çalışmalar genellikle daha sadeleştirilmiş senaryolar kullanmış, bu da karşılaştırmalı değerlendirmede önemli bir fark yaratmaktadır.

**Tablo 5:** İlgili çalışmaların özeti.

Makale	Etki Giderme yöntemi	Başarım/Sonuç	Senaryo/Tartışma
<b>Önerilen Yöntem</b>	Radar menzil hücrelerindeki güç seviyelerine dayalı arka plan hedef sınıflandırması	RF, MLP ve GB sınıflandırıcıları ile rüzgar türbinleri ile farklı menzil hücrelerine düşen uçaklar yüksek doğrulukla (~%100) sınıflandırılırken, rüzgar türbinleri ile aynı menzil hücrelerine düşen uçakların sınıflandırma performansının (~%50) oldukça düşük olduğu gözlemlenmiştir	Rüzgar türbini yoğunluğunun ve RKA farkının görece yüksek olduğu bir ortamda
[6]	Mikro-doppler tabanlı arka plan hedef sınıflandırması	Bayes ile %91.2 ve PNN ile %94.9 doğrulukla sınıflandırmanın mümkün olduğu görülmüş	Hedeflerin geri dönüş sinyalleri ayrı ayrı incelenip sınıflandırma yapılmış
[15]	CFAR aşaması kapsamında rüzgar türbinlerinin bulunduğu menzil hücrelerindeki güç seviyelerinin eşik hesabına dahil edilmemesi	Türbinlerin dinamik bir gürlüğe haritasına dayalı olarak eşik hesabına dahil edilmediğinde, çoklu yansımadaki güzel sonuçlar vermiş	Rüzgar türbini yoğunluğunun ve RKA farkının görece az olduğu ortamda rüzgar türbinlerinin yaklaşık 1 deniz mili önünde ve arkasındaki hedefin tespiti
[24]	Mikro-doppler verilerinin Rayleigh dağılımındaki sapmaların ölçülmesi üzerine arka plan hedef sınıflandırması	Orta ve düşük çözünürlüklü radar sistemlerinde, istatistiksel yaklaşımlar sayesinde, yoğun parazit alanlarında bile hedef sınıflandırması %75.8 doğruluk ile yapılmış	Hedeflerin geri dönüş sinyalleri ayrı ayrı incelenip sınıflandırma yapılmış
[25]	Kısa Zaman Fourier Dönüşüm tabanlı arka plan hedef sınıflandırması	Rüzgar türbini karmaşasında "hedef var" ve "hedef yok" durumlarının ayrımı %95 başarı oranıyla sınıflandırılmış	Basitleştirilmiş bir sinyal ve radar modeli seçilerek, rastgele belirlenen parametre konfigürasyonlarına dayalı veri setleri oluşturulmuş

#### 5. SONUÇLAR (CONCLUSIONS)

Rüzgar türbini yoğunluğunun yüksek olduğu ve rüzgar türbinleri ile uçak arasındaki RKA farkının büyük olduğu durumlarda, türbinlere ait menzil hücrelerindeki güç seviyeleri CFAR

aşamasında ihmal edilse bile gerçek hava hedefine ait izler tespit edilememiştir.

Radar menzil hücrelerindeki güç seviyelerine dayalı olarak rüzgar türbinleri ile farklı menzil hücrelerine düşen uçakların, makine öğrenimi yöntemleriyle “sadece rüzgar türbini” ve “rüzgar

türbini ile uçak" şeklinde yüksek performansta, ancak rüzgar türbinleri ile aynı menzil hücrelerine düşen uçaklar ise çok düşük performansta sınıflandırılmıştır.

Sınıflandırma yaklaşımının performansını artırmak amacıyla, senaryoların çeşitlendirilmesi ve veri setinin büyütülmesi hedeflenmektedir. Daha fazla hedef-türbin kombinasyonunun ve farklı geometrik yerleşimlerin modellenmesiyle sınıflandırma algoritmalarının genelleme yeteneğinin artırılması planlanmaktadır. Ayrıca, sınıflandırma yaklaşımının performansını daha da iyileştirmek amacıyla hedefin hızı, hareket vektörü, ivmesi, frekans imzası, irtifası, zamanla değişen radar kesit alanı ve polarizasyon bilgisi gibi ek özelliklerin de veri füzyonu teknikleriyle sisteme entegre edilmesi öngörülmektedir. Bu iyileştirme ile özellikle yoğun hava trafiğine sahip bölgelerde, hava trafik kontrolörlerinin uçakları daha güvenli ve etkin şekilde yönlendirebilmesi hedeflenmektedir.

#### TEŞEKKÜR (ACKNOWLEDGMENTS)

Bu araştırma hiçbir dış finansman almamıştır.

#### YAZAR KATKILARI (AUTHOR CONTRIBUTIONS)

**Umutkan SAN:** Kavramsal tasarım, Metodoloji, Yazma, Düzenleme, Kaynaklar.

**Ali ÖTER:** Gözden geçirme, Denetim, Onaylama.

**Ali KARA:** Gözden geçirme, Denetim, Onaylama.

#### ÇIKAR ÇATIŞMALARI (CONFLICTS OF INTEREST)

Yazarlar, herhangi bir çıkar çatışması olmadığını beyan eder.

#### KAYNAKLAR (REFERENCES)

- [1] C. Ton, "Radar cross section (RCS) simulation for wind turbines," 2013.
- [2] C. Jackson, "Windfarm characteristics and their effect on radar systems," in IET International Conference on Radar Systems 2007, 2007: IET.
- [3] F. Darcy and D. de la Vega, "A methodology for calculating the interference of wind farm on weather radar," in 2009 Loughborough Antennas & Propagation Conference, 2009: IEEE, pp. 665-667.
- [4] R. R. Ohs, G. J. Skidmore, and G. Bedrosian, "Modeling the effects of wind turbines on radar returns," in 2010-MILCOM 2010 Military Communications Conference, 2010: IEEE, pp. 272-276.
- [5] E. Aarholt and C. A. Jackson, "Wind farm gapfiller concept solution," in The 7th European Radar Conference, 2010: IEEE, pp. 236-239.
- [6] O. Karabayır, S. M. Yücedağ, O. M. Yücedağ, A. F. Coşkun, and H. A. Serim, "Micro-Doppler-based classification study on the detections of aerial targets and wind turbines," in 2016 17th International Radar Symposium (IRS), 2016: IEEE, pp. 1-4.
- [7] L. Rashid and A. Brown, "Radar cross-section analysis of wind turbine blades with radar absorbing materials," in 2011 8th European Radar Conference, 2011: IEEE, pp. 97-100.
- [8] J. Pinto, J. Matthews, and G. Sarno, "Stealth technology for wind turbines," IET radar, sonar & navigation, vol. 4, no. 1, pp. 126-133, 2010.

- [9] L. Claudepierre, R. Douvenot, A. Chabory, and C. Morlaas, "Assessment of the shadowing effect between windturbines," in 2015 9th European Conference on Antennas and Propagation (EuCAP), 2015: IEEE, pp. 1-4.
- [10] C. Jackson and M. Butler, "Options for mitigation of the effects of wind farms on radar systems," in IET International Conference on Radar Systems 2007, 2007: IET.
- [11] L. Sergey, O. Hubbard, Z. Ding, H. Ghadaki, J. Wang, and T. Ponsford, "Advanced mitigating techniques to remove the effects of wind turbines and wind farms on primary surveillance radars," in 2008 IEEE radar conference, 2008: IEEE, pp. 1-6.
- [12] A. Thomsen et al., "Air traffic control at wind farms with TERMA SCANTER 4000/5000," in 2011 IEEE RadarCon (RADAR), 2011: IEEE, pp. 247-252.
- [13] D. De la Vega, J. C. Matthews, L. Norin, and I. Angulo, "Mitigation techniques to reduce the impact of wind turbines on radar services," *Energies*, vol. 6, no. 6, pp. 2859-2873, 2013.
- [14] O. Karabayir, S. M. Yucedag, A. F. Coskun, O. M. Yucedag, H. A. Serim, and S. Kent, "Wind turbine signal modelling approach for pulse Doppler radars and applications," *IET Radar, Sonar & Navigation*, vol. 9, no. 3, pp. 276-284, 2015.
- [15] s. Jia, s. Wu, and s. Wang, "Recognition and supression of wind farm clutter via dynamic clutter map," in 2012 IEEE 11th International Conference on Signal Processing, 2012, vol. 3: IEEE, pp. 1949-1952.
- [16] B. R. Mahafza, *Radar systems analysis and design using MATLAB*. Chapman and Hall/CRC, 2005.
- [17] M. I. Skolnik, *Introduction to radar systems*. McGraw-hill New York, 1980.
- [18] O. KARABAYIR, "Investigation of wind turbine effects on radar performance " Ph.D. THESIS, Department of Electronics and Communications Engineering Telecommunications Engineering Programme, Istanbul Technical University, 2016.
- [19] A. H. Özcan, S. Baykut, D. S. Şahinkaya, and İ. K. Yalçın, "Micro-doppler effect analysis of single bird and bird flock for linear FMCW radar," in 2012 20th Signal Processing and Communications Applications Conference (SIU), 2012: IEEE, pp. 1-4.
- [20] D. Yuan, J. Huang, X. Yang, and J. Cui, "Improved random forest classification approach based on hybrid clustering selection," in 2020 Chinese Automation Congress (CAC), 2020: IEEE, pp. 1559-1563.
- [21] M. Massaoudi, A. Darwish, S. S. Refaat, H. Abu-Rub, and H. A. Toliyat, "UHF partial discharge localization in gas-insulated switchgears: Gradient boosting based approach," in 2020 IEEE Kansas Power and Energy Conference (KPEC), 2020: IEEE, pp. 1-5.
- [22] S. S. Tabib and A. A. Jalali, "Modelling and prediction of internet time-delay by feed-forward multi-layer perceptron neural network," in Tenth International Conference on Computer Modeling and Simulation (uksim 2008), 2008: IEEE, pp. 611-616.

- [23] A. Vırt and A. Öter, "Kardiyovasküler Hastalıkların Derin Öğrenme Algoritmaları İle Tanısı," Gazi Üniversitesi Fen Bilimleri Dergisi Part C: Tasarım ve Teknoloji, vol. 12, no. 4, pp. 902-912, 2024.
- [24] C. Neumann and H. Senkowski, "Automatic Target Recognition for short time observation radars," in 2013 14th International Radar Symposium (IRS), 2013, vol. 2: IEEE, pp. 592-596.
- [25] M. Dietlein and T. Mahr, "Classification of Targets and Wind Turbine Clutter in Pulse-Doppler Radar Spectra Using a Group of Neural Networks," in 2019 20th International Radar Symposium (IRS), 2019: IEEE, pp. 1-10.