



Classification of low probability of intercept radar waveforms using gabor wavelets

Halit Ergezer*

Mechatronics Engineering Department, Faculty of Engineering, Çankaya University, Ankara, 06790, Turkey

Highlights:

- LPI waveform classification without learning phase.
- Feature extraction using Wavelet transform, no need to images of same size.
- Satisfactory accuracy rate of classification compared to the state of the art methods.

Keywords:

- LPI radars
- Waveform classification
- Gabor Wavelet Transform
- Electronic Support Systems.

Article Info:

Research Article
Received: 18.08.2020
Accepted: 05.04.2021

DOI:

10.17341/gazimmfd.782311

Correspondence:

Author: Halit Ergezer
e-mail:
halitergezer@cankaya.edu.tr
phone: +90 312 233 1312

Graphical/Tabular Abstract

Low Probability of Intercept (LPI Radar) is a class of radar with specific technical characteristics that make it very difficult to intercept with electronic support systems and radar warning receivers. Because of their properties as low power, variable frequency, wide bandwidth, LPI radar waveforms are difficult to intercept by ESM systems. In recent years, studies on the classification of waveforms used by these types of radar have been accelerated. In this study, Time-Frequency Images (TFI) have been obtained from the LPI radars waveforms by using Choi-Williams Distribution method. From these images, feature vectors have been generated using Gabor Wavelet transform. In contrast to many methods in the literature, waveform classification has been performed by directly comparing the feature vectors obtained, without using any machine learning method.

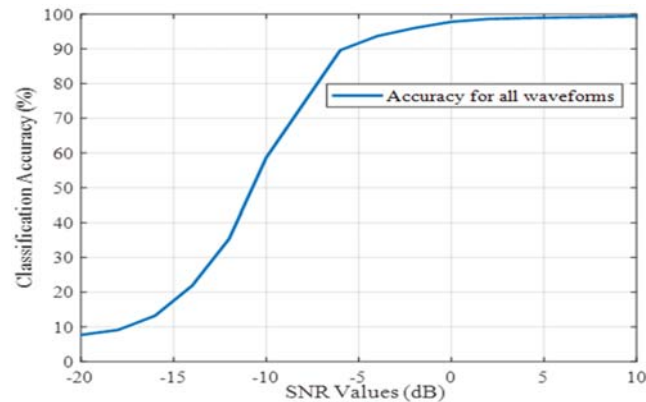


Figure A. Classification accuracy vs. SNR

Purpose: In this study, the purpose is to classify LPI radar waveforms by comparing their features extracted using Gabor Wavelets. Unlike many methods given in the literature our method does not require learning phase and reshaping of input signals which cause information loss.

Theory and Methods:

To recognize 13 different LPI waveforms (12 different modulation types and non-modulation), signals are sampled at a sampling rate of 20 kHz. Then, CWD is applied to the sampled data. The output CWD-TFI is automatically cropped according to the high energy regions on the image. Then, a total of 40 filters with 5 different frequencies and 8 different orientations have been calculated. TFIs are filtered by these filters to extract feature vectors. The classification can be done by finding similarity between feature vectors of test signals and feature vectors of signals in database. Then the matching score is calculated to assign a label to tested signals.

Results:

For the classification of LPI waveforms, a total of 13 different signal types have been produced by taking SNR values between -20 dB and 10 dB in 2 dB intervals. In the figure below, the overall classification accuracy of the proposed method.

Conclusion:

One of the advantages of our method over the methods given in the literature is that there is no need to re-sizing or re-shaping of different LPI waveforms to make the images the same size. The emphasis here is not on just filling in zero or the time spent on it, but attempts to reduce the size of the images to avoid computational complexity results the loss of distinctive features, especially for LPI signals with low SNR values. Another advantage of our method is that there is no learning phase, so classification can be done using feature vectors saved in the database.



Dinlenmesi düşük olasılıklı radar dalga biçimlerinin gabor dalgacık dönüşümü kullanarak sınıflandırılması

Halit Ergezer*^{ID}

Çankaya Üniversitesi, Mühendislik Fakültesi, Mekatronik Mühendisliği Bölümü, 06790, Türkiye

Ö N E Ç İ K A N L A R

- Öğrenme aşaması olmadan LPI dalga biçimi sınıflandırması.
- Wavelet dönüşümü kullanarak özellik çıkarma, aynı boyutta görüntülere gerek yoktur
- Son teknoloji yöntemlerle karşılaştırıldığında tatmin edici doğruluk oranı elde edilmiştir

Makale Bilgileri

Araştırma Makalesi

Geliş: 18.08.2020

Kabul: 05.04.2021

DOI:

10.17341/gazimmfd.782311

Anahtar Kelimeler:

LPI radar;
dalga biçimi sınıflandırma,
gabor dalgacık dönüşümü,
elektronik destek sistemleri

ÖZ

Dinlenmesi Düşük Olasılıklı Radar (Low Probability of Intercept – LPI Radar) elektronik destek sistemleri (Electronic Support Systems - ESM), radar ikaz alıcıları ile algılanmasını oldukça zorlaştıran bazı özel teknik karakteristiklere sahip bir radar sınıfıdır. Düşük güç, değişken frekans ve geniş bant genişliği gibi özelliklerinden dolayı, LPI radar dalga biçimlerinin, ESM sistemleri tarafından dinlenmesi zordur. Son yıllarda, bu tip radarların kullandıkları dalga biçimlerinin ESM algılayıcıları tarafından sınıflandırılmasına yönelik çalışmalar hız kazanmış durumdadır. Bu çalışmamızda, LPI radarların kullandıkları dalga biçimlerinden Choi-Williams Dağılım (CWD) yöntemi kullanılarak zaman-frekans görüntüleri (TFI) elde edilmiştir. Bu görüntülerden Gabor Dalgacık dönüşümü kullanılarak öznelik vektörleri oluşturulmuştur. Literatürde yer alan birçok yöntemin aksine herhangi bir makine öğrenmesi yöntemi kullanmadan doğrudan elde edilen öznelik vektörlerinin karşılaştırılması ile dalga biçimi sınıflandırması gerçekleştirilmiştir. Önerdiğimiz yöntem ile -20 dB ila 10 dB arasında 2'şer dB aralıklarla sınıflandırma doğrulukları elde edilmiş, -8 dB SNR değerine kadar makul sınıflandırma doğruluk oranlarında performans göstermiştir. Bazı sinyal tipleri için literatürde raporlanan en iyi sonuçlardan daha iyi sonuçlar elde edilmiştir. Tüm dalga biçimleri için elde edilen sonuçlar literatürde mevcut yöntemlerin sonuçlarıyla karşılaştırmalı olarak verilmiştir.

Classification of low probability of intercept radar waveforms using gabor wavelets

H I G H L I G H T S

- LPI waveform classification without learning phase
- Feature extraction using Wavelet transform, no need to images of same size
- Satisfactory accuracy rate of classification compared to the state of the art methods

Article Info

Research Article

Received: 18.08.2020

Accepted: 05.04.2021

DOI:

10.17341/gazimmfd.782311

Keywords:

LPI radar,
waveform classification,
gabor wavelet transform,
electronic support systems

ABSTRACT

Low Probability of Intercept (LPI Radar) is a class of radar with specific technical characteristics that make it very difficult to intercept with electronic support systems and radar warning receivers. Because of their properties as low power, variable frequency, wide bandwidth, LPI radar waveforms are difficult to intercept by ESM systems. In recent years, studies on the classification of waveforms used by these types of radar have been accelerated. In this study, Time-Frequency Images (TFI) has been obtained from the LPI radars waveforms by using Choi-Williams Distribution method. From these images, feature vectors have been generated using Gabor Wavelet transform. In contrast to many methods in the literature, waveform classification has been performed by directly comparing the feature vectors obtained without using any machine learning method. With the method we propose, classification accuracies were obtained at intervals of 2 dB between -20 dB and 10 dB and performed at reasonable classification accuracy rates up to -8 dB SNR value. Better results than the best reported in the literature were obtained for some signal types. The results obtained for all waveform types are given in comparison with the results of the existing methods in the literature.

1. GİRİŞ (INTRODUCTION)

Dinlenmesi Düşük Olasılıklı Radar, düşman sistemleri tarafından, emisyonunun yakalanmasını zorlaştırmak, yakalanırsa da kullandığı modülasyon tipinin ve parametrelerinin tanımlanmasını önlemek amacıyla özel dalga biçimleri kullanan radar olarak tanımlanır [1] Kendini Elektronik Destek Sistemleri ve Radar İkaz Alıcılarından saklamak için, radar tespit menzili, önleme alıcılarının radar işaretini tespit menziline daha uzun olmalıdır. LPI radarların Elektronik Destek Sistemleri tarafından tespit edilmesi, kullanılan dalga biçiminin belirlenmesi ve buna karşı uygulanacak karşı tedbirlerin belirlenmesi oldukça önemli bir konudur. LPI radarlar tespit edilmelerini zorlaştıran düşük güç, geniş bant genişliği, değişken frekans gibi pek çok özelliğe sahiptirler. Bu radarların bu özellikleri dışında da dinlenmelerini ve tespit edilmelerini zorlaştıran özellikleri bulunmaktadır. Ancak bu çalışmamızda kullanılan dalga biçiminin tespit edilmesi için bir yöntem önerilmiştir. Radarın tespit edilmesi tehdit ortamında tek başına yeterli değildir, kullandığı yöntemlerin özellikle de dalga biçiminin tespit edilmesi bu tehditlere karşı savunma geliştirilmesi açısından oldukça önemlidir.

LPI dalga biçimlerinin sınıflandırılmasında bugüne kadar farklı yöntemler önerilmiştir. Doğrudan radar işaretlerinin ham ya da filtrelenmiş halini kullanan yöntemler de bulunmasına rağmen [2] çoğunlukla LPI radar işaretlerinin zaman-frekans dönüşümlerini kullanarak elde edilen görüntülerden sınıflandırma yapma yolu tercih edilmektedir. Zaman-frekans görüntülerini elde edebilmek için Choi Williams Dağılımı (CWD) [2-4], Wigner-Ville Dağılımı (WVD) [1, 4, 5], Radon-WVD [6], kısa süreli Fourier Dönüşümü (STFT) [7] ve ayrık Fourier Dönüşümü (DFT) [8] gibi farklı yöntemler önerilmiştir. WVD ve CWD otokorelasyonun kullandığı çift doğrusal zaman-frekans teknikleridir. Bu dönüşümlerde diğer dönüşüm yöntemlerinde olduğu gibi pencere tipi ve pencere boyutu gibi parametre belirlenmesine gerek olmaması ve bu dönüşümlerin gürültüye karşı gürbüzlükleri diğer dönüşüm yöntemlerine göre daha iyi olmaması sebebiyle tercih edilmektedir [1]. Ancak bu yöntemlerden WVD dönüşümünde çapraz terimler oluşmaktadır. Bu çapraz terimler sınıflandırma performansını düşürdüğünden TFI oluşturulmasında en çok kullanılan CWD'dir [3]. LPI radar sinyalleri çoğunlukla çok düşük SNR değerine sahiptir. CWD, davranış ölçekleme parametresinin [3] değeri değiştirilerek kolayca ayarlanabilir, bu da zaman frekansı çözünürlüğü ve çapraz dönem bastırması anlamına gelir. CWD, ölçeklendirme parametresi σ değeri ayarlanarak değiştirilebilir. Dolayısıyla CWD zaman-frekans dönüşümünde sınıflandırma performansını düşüren *hayalet terimler* yer almamaktadır.

Literatürdekilere benzer şekilde, çalışmamızda sınıflandırma için zaman-frekans görüntülerinin elde edilmesi için CWD kullanılmıştır. Literatürde verilen çoğu metodun aksine, aynı boyutlara getirilmesine gerek olmadan görüntüler

oluşturulmuştur. CWD'den TFI'lerin oluşturulması sırasında, görüntü kalitesini arttırmak için kullanılan parametreler ve piksel değerleri ayırt edici özellikleri netleştirmek için normalleştirilmiştir.

TFI'lar kullanarak LPI radar dalga biçimi sınıflandırması için literatürde çeşitli teknikler önerilmiştir. [3] Konvolüsyonel Sinir Ağlarını (CNN) kullanarak sınıflandırma yapmış ancak TFI boyutlarına bağlı olarak üstel olarak artan yüksek hesaplama gücü gereksiniminden dolayı araştırmacılar ardışık örneklerin ortalamasını alarak veri boyutunu düşürmeye çalışmışlardır. Ancak bu yöntem özellikle düşük SNR değerlerinde ayırt edicilik açısından önemli olabilecek bazı noktaların kaybedilmesine sebep olmaktadır. Ayrıca bu çalışmada faz uyumlu bir şekilde toplama yapıldığı belirtilmiştir [3]. Ancak ortalaması alınacak örnek sayısı arttırdığında faz uyumluluğunun gerçek uygulamalarda nasıl garanti altına alınacağı belirtilmemiştir. Bu alanda yapılan çalışmalar problemi diğer örüntü tanıma problemleri gibi ele almaktadırlar, hâlbuki burada ele alınan problem Radyo Frekans (RF) işaretlerin parametrelerinin çıkarılmasına yöneliktir. Dolayısıyla kamera ile elde edilen görüntülerle çalışıyormuş yaklaşımı ile sistem oluşturulması gerçek uygulamalarda karşılığı bulunmayacak yaklaşımlardır. Faz uyumluluğunun SNR'a etkisi de net bir şekilde henüz ortaya konulmamıştır. Bu alanda yapılan önemli çalışmalardan bir diğerinde ise TFI elde etmek için WVD kullanılmıştır [8]. Daha sonraları yapılan çalışmalarda WVD ile elde edilen TFI çapraz terimler geldiği ve bu terimlerin sınıflandırma başarımını düşürdüğü belirtilmiştir [5]. LPI dalga biçimi tanıma ve sınıflandırma alanındaki birçok çalışmanın sonuçlarını [6]'da verilen sonuçlarla kıyaslamaktadır. Ancak bu makalede sınıflandırılmaya çalışılan LPI radar dalga biçimi sayısı (T1-T4 sinyal tiplerini sınıflandırmaya dâhil etmeden çalışılmıştır) bu çalışmada ele alınan dalga biçimi sayısından daha azdır. TFI'lerden elde edilen, sinyalin görüntü içerisindeki konumu ve sinyalin genliği gibi verileri karar ağacı yapısı içerisinde kullanılarak sınıflandırma yapılmıştır [6]. LPI dalga biçimleri Sürekli Dalga (CW) işaretleri ve Darbeli Dalga (PW) işaretleri şeklinde de olabilir, hem CW hem de darbeli LPI işaretlerini tanımlamak ve sınıflandırmak için tek atışlı çoklu kutu detektörü (SSD) ve SSD kullanılmıştır [5]. Bahsedilen çalışmada, ilk aşamada herhangi bir sınıfa atanamayan sinyallerin sınıflarının belirlenmesi için ek bir sınıflandırıcı kullanılmıştır. Ancak, aynı ortalama güç değerine sahip CW ve Darbeli sinyalleri değerlendirdiğimizde; CW sinyalleri zaman dilimi boyunca sürekli bir eğri olarak TFI'de açıkça ayırt edilebilir ve izlenebilir. Bu, Darbeli sinyaller için geçerli değildir. Darbeli sinyaller için, TFI'nın belirli bölgelerinde yüksek yoğunluklu küçük bölgeler gözlenir. Çalışmamızda, sınıflandırma için CW sinyalleri dikkate alınmamıştır, ancak yaklaşımımız CW sinyallerine de uygulanabilir. Gabor Dalgacık Dönüşümü çoklu çözünürlüğe sahip filtreler gerçekleştirildiğinden bahsi geçen bölgelerin tespit edilmesi, işaretin darbeli ya da CW olmasından bağımsız olarak, mümkün olabilecektir. [4]'de algılayıcı, radyal temelli fonksiyonlar kullanan yapay sinir ağları kullanılarak

sınıflandırma yapılmaya çalışılmıştır. Sınıflandırma performansı diğer çalışmalara nispeten daha düşüktür. [9]'da ise görüntü füzyon algoritması önerilmiş ve öznelik çıkarmak için CNN kullanılmıştır. Ancak, [9] çok fazlı Frank kodunu sınıflandırmada hariç tutmuştur ki sonuçlar bölümünde verilen performanslardan da görüleceği gibi bu kodların diğer çok fazlı kodlarla arasındaki benzerlik sınıflandırma performansını oldukça etkilemektedir.

Bu çalışmamızda FMCW, Costas, BPSK, Frank, P1, P2, P3, P4, T1, T2, T3, T4 ve modülasyon olmayan işaretler sınıflandırma için kullanılmıştır. Choi-Williams Dağılımı kullanılarak oluşturulan zaman- frekans görüntülerinden [10, 11] Gabor Dalgacık dönüşümü kullanılarak öznelik vektörleri oluşturulmuştur. Literatürde yer alan birçok yöntemin aksine herhangi bir makine öğrenmesi yöntemi kullanmadan doğrudan elde edilen öznelik vektörlerinin karşılaştırması ile dalga biçimi sınıflandırması gerçekleştirilmiştir. Özellikle düşük SNR değerlerinde makine öğrenmesi yöntemlerinin başarısız olduğu yapılan çalışmaların sonuçlarından anlaşılmaktadır [13]. Sınıflandırma yapılan görüntülere bakıldığında LPI dalga biçimine ait belli özelliklerin insan gözü ile algılanabildiği anlaşılmaktadır. [14]'de memelilerin birincil görsel korteksinde bulunan bir takım özelliklerin Gabor Dalgacık Dönüşümü ile modellenebileceği belirtilmiştir. Gabor dalgacık dönüşümü yüz tanıma [15], cilt lezyonlarının sınıflandırılması [16], manyetik rezonans görüntülerinden beyin tümörü tespiti ve bölütlemesi [17] gibi birçok problemin çözümünde kullanılmıştır. Bilebildiğimiz kadarıyla şu ana kadar LPI dalga biçimlerinin sınıflandırılması probleminin çözümü için hiç kullanılmamıştır. Çalışmamız şu ana kadar çoğunlukla makine öğrenmesi yöntemi ile çözülmeye çalışılan bu problemi farklı bir yöntemle çözerek literatürde verilen doğruluk oranlarından bazı durumlarda daha iyi sonuçlar üretmiştir. Sonuçlar ve tartışmalar bölümünde detaylı olarak ele alınmıştır. İşlem karmaşıklığı açısından değerlendirildiğinde ise öğrenme aşaması bulunmaması veri tabanına yeni eklenecek her dalga biçiminin Gabor filtreleri ile filtrelenmiş hallerinin saklanması yeterli olacaktır. Öğrenme gerektiren yöntemlerde yeni verilerin elde edilmesi sonrası yeniden eğitime süreci olacaktır. Sınama aşamasında ise diğer yöntemlerle benzer sürelerle ihtiyaç duymakta ancak sınama sırasında TFI ve/veya LPI dalga biçiminde boyutlandırma ihtiyacı bulunmamaktadır.

2. LPI RADAR SİNYAL TİPLERİ (LPI RADAR SIGNAL WAVEFORMS)

Sınıflandırılacak LPI radar dalga biçimleri olarak [2]'de verilen ve literatürde [1, 3] ve [4] sınıflandırılmaya çalışılan dalga biçimleri olarak ele alınmıştır. Bu dalga biçimlerinin taban bant I (*In-phase*) ve Q (*Quadrature*) bileşenleri aşağıda verildiği gibi elde edilmiştir. Her bir dalga biçimi için Sinyal Gürültü Oranı (Signal-to-Noise Ratio - SNR) -20 dB'den 10 dB'ye kadar 2dB aralıklarla olacak şekilde 16 farklı SNR değeri için veri kümesi oluşturulmuştur.

2.1. Frekans Modülasyonlu Sürekli Dalga (Frequency Modulation Continuous Wave - FMCW)

Taban bant FMCW işaretlerinin I ve Q bileşenleri Eş. 1 ve Eş. 2 ile üretilmiştir [2].

$$I = A \cos \left(2\pi \left(f_0 \mp \frac{\Delta F}{2} \right) t \pm \frac{\Delta F}{2t_m} t^2 \right) \quad (1)$$

$$Q = A \sin \left(2\pi \left(f_0 \mp \frac{\Delta F}{2} \right) t \pm \frac{\Delta F}{2t_m} t^2 \right) \quad (2)$$

Bu denklemlerde $\left(f_0 \mp \frac{\Delta F}{2} \right) t \pm \frac{\Delta F}{2t_m} t^2$ frekans kaymasının arttığı işaretleri $\left(f_0 \mp \frac{\Delta F}{2} \right) t \pm \frac{\Delta F}{2t_m} t^2$ frekans kaymasının azaldığı işaretleri yaratmakta kullanılmaktadır. Denklemlerde A genliği f_0 taşıyıcı frekansını ifade etmektedir.

2.2. İkili Faz Kaydırmalı Anahtarlama (Binary Phase Shift Keying - BPSK)

Taşıyıcı frekansı f_0 olan ikil Barker Dizileri için taban bant işaretleri Eş. 3'de verildiği gibi üretilmiştir. $B = [b_0, b_1, \dots, b_n]$, $b_i \in \{-1, +1\}$.

$$I = A \cos \left(2\pi n \frac{f_0}{f_s} \right) * B, \quad (3)$$

$$Q = A \sin \left(2\pi n \frac{f_0}{f_s} \right) * B$$

n: Örnekleme indeksi, f_s : örnekleme frekansı.

2.3. COSTAS Modülasyonu (Costas Modulation)

[2]'de tanımlandığı gibi frekans modülasyonu değişik frekans vektörleri kullanılarak üretilmiştir (Eş. 4 ve Eş. 5). Burada tanımlanan frekans değerleri MHz olarak frekans kaymalarını ifade etmektedir.

$$f_1 = [3 \ 2 \ 6 \ 4 \ 5 \ 1], \quad f_2 = [5 \ 4 \ 6 \ 2 \ 3 \ 1], \quad f_3 = [2 \ 4 \ 8 \ 5 \ 10 \ 9 \ 7 \ 3 \ 6 \ 1]$$

$$I = A \cos(2\pi n f_i(l) n T_s) \quad (4)$$

$$Q = A \sin(2\pi n f_i(l) n T_s) \quad (5)$$

$i = 1, 2, 3$ and, $l = 1, 2, \dots, L_i$

L_i : frekans kayması vektörlerinin boyutudur. ($L_1 = 6$, $L_2 = 6$, $L_3 = 10$)

T_s : Örnekleme periyodu.

2.4. Çok Evreli (Polyphase)

Bu biçimdeki LPI işaretleri Frank kodlu, P1, P2, P3 ve P4 kodlu işaretlerdir [2]. Her biri için taban bant işaretleri Eş. 6 – Eş. 14 kullanılarak üretilmiştir.

$$FRANK: \quad \Phi(i, j) = \frac{2\pi}{N} (i - 1)(j - 1) \quad (6)$$

P1:

$$\Phi(i, j) = \frac{-\pi}{N}(N - (2j - 1))(j - 1)N + (i - 1) \quad (7)$$

P2:

$$\Phi(i, j) = \frac{-\pi}{2N}(2i - 1 - N)(2j - 1 - N) \quad (8)$$

i, j = 1...N.

N : Taşıyıcı işaretin faz durumlarını ifade etmektedir. Frank, P1 ve P2 dalga biçimleri Eş. 4 ve Eş. 5'de verilen denklemlere, sırasıyla Eş. 6, Eş. 7 ve Eş. 8'de verilen faz durumlarının kullanılmasıyla elde edilmiştir.

$$I = A \cos(2\pi f_0 n T_s + \Phi(i, j)), \quad (9)$$

$$Q = A \sin(2\pi f_0 n T_s + \Phi(i, j)) \quad (10)$$

P3:

$$\Phi(k) = \frac{\pi}{N}(k - 1)^2 \quad (11)$$

P4:

$$\Phi(k) = \left(\frac{\pi}{N}(k - 1)^2 - \pi(k - 1) \right) \quad (12)$$

k = 1, ..., N

N : Faz durum sayısı

P3 ve P4 dalga biçimlerinin I ve Q bileşenleri aşağıdaki gibi oluşturulmuştur.

$$I = A \cos(2\pi f_0 n T_s + \Phi(k)) \quad (13)$$

$$Q = A \sin(2\pi f_0 n T_s + \Phi(k)) \quad (14)$$

2.5. Çok Zamanlı (Polytime)

Eş. 15'ten Eş. 18'e kadar, sırasıyla, T1-T4 dalga biçimleri için kullanılan modülasyon sinyalleri verilmiştir:

T1:

$$\Phi(t) = \text{mod} \left\{ \frac{2\pi}{N} \left[(mt - jT) \frac{jN}{T} \right], 2\pi \right\} \quad (15)$$

T2:

$$\Phi(t) = \text{mod} \left\{ \frac{2\pi}{N} \left[(mt - jT) \left(\frac{2j - m + 1}{T} \right) \frac{N}{2} \right], 2\pi \right\} \quad (16)$$

T3:

$$\Phi(t) = \text{mod} \left\{ \frac{2\pi}{N} \left[\frac{N\Delta F t^2}{2t_m} \right], 2\pi \right\} \quad (17)$$

T4:

$$\Phi(t) = \text{mod} \left\{ \frac{2\pi}{N} \left[\frac{N\Delta F t^2}{2t_m} - \frac{N\Delta F t}{2} \right], 2\pi \right\} \quad (18)$$

j = 0, 1, 2, ..., m-1

m : Frekans segmenti sayısı,

N : Faz durumu sayısı

T : Kod periyodu

Benzer şekilde tabant işareti I ve Q bileşenleri Eş. 19 ve Eş. 20'de verildiği gibi hesaplanabilir.

$$I = A \cos(2\pi f t T_s + \Phi(t)) \quad (19)$$

$$Q = A \sin(2\pi f t T_s + \Phi(t)) \quad (20)$$

3. ZAMAN-FREKANS GÖRÜNTÜLERİNİN ÜRETİLMESİ (TIME-FREQUENCY IMAGE GENERATION)

LPI radarların kullandığı dalga biçimleri Choi-Williams Dağılımı (CWD) kullanılarak [18] zaman-frekans görüntüleri (TFI) oluşturulmuştur.

CWD, farklı frekans bileşenlerine sahip sinyallerin zaman-frekans karakteristiklerini incelemenin en iyi yolu olarak ifade edilmiştir [19]. Wigner-Ville Dağılımı (WVD) çekirdek fonksiyonu (kernel function) olarak sabit değer kullanırken CWD üstel bir çekirdek fonksiyonu kullanır. Üstel çekirdek fonksiyonu, CWD'yi diğer dağılımlardan farklı kılar, böylelikle zaman-frekans dönüşümü sonrasında oluşan çapraz terimler azaltılmış olur.

CWD kullanarak zaman-frekans dönüşümü Eş. 21 ile elde edilir.

$$CWD_x(l, \omega) = 2 \sum_{\tau=-\infty}^{\infty} e^{-j2\omega\tau} G \quad (21)$$

$$G = \sum_{\tau=-\infty}^{\infty} \frac{1}{\sqrt{4\pi n^2/\sigma}} e^{-\frac{\sigma(\mu-l)^2}{4\tau^2}} x(\mu + \tau)x^*(\mu - \tau)$$

Burada l zaman indeksini, ω açısal frekansı, $x(\mu)$ LPI dalga biçimi sinyalini, $x^*(\mu)$ ise karmaşık eşleniğini ifade etmektedir. τ , çekirdek fonksiyonunun zaman gecikmesi değerini, σ ise ölçeklendirme faktörünü belirlemektedir [13].

Zaman-frekans dönüşümlerinin l ve ω değerlerine göre grafiğe dökülmesiyle zaman-frekans görüntüleri elde edilmektedir. Bu görüntülerden yüksek enerjili bölgeler otomatik olarak kesilebilir. Ancak önerdiğimiz yöntemde zaten yüksek enerjili bölgeler filtreler aracılığı ile çıkarıldığından bu yaklaşım kullanılmak zorunda değildir.

4. GABOR FİLTRELERİNİN OLUŞTURULMASI (FORMING GABOR FILTERS)

Daugman, memeli beyinlerinin görsel korteksindeki basit hücrelerin Gabor fonksiyonları ile modellenebileceği keşfinden hareketle Gabor Dalgacık dönüşümü ile görüntülerin filtrelenmesini önermiştir [20, 21]. Bir görüntü ile iki boyutlu Gabor fonksiyonu arasındaki bağlantının mutlak karesi, belirli bir yönde, belirli bir konum ve frekans etrafında yoğunlaşan bir yerel spektral enerji yoğunluğu vermektedir.

Çeşitli dalgacık tabanları arasında, Gabor fonksiyonlarının hem zaman hem de frekans alanlarında en uygun çözünürlüğü sağladığı belirtilmiştir [22]. Gabor dalgacık dönüşümü, hem çoklu çözünürlük hem de çoklu oryantasyon özelliklerine sahiptir ve yerel uzamsal frekansları ölçmek için idealdir. Örüntü tanıma problemlerinin çözümü için buzulmalara dayanıklı şekilde öznetelik sağladığından tercih edilmektedir.

[23] ve [24]'te doku bölütlemesi probleminde, [25]'te el yazısı tanıma probleminde, [26]'da parmak izlerinin tanınması için ve [27]'de hiperspektral görüntülerden öznelik çıkartılması için kullanılmıştır. Genel olarak, öznelik vektörü, farklı yönelim ve ölçekler için Gabor Dalgacık Dönüşümü filtrelerinin uygulanması ile çıkarılan özelliklerin birleştirilmesidir [28].

Gabor dalgacık dönüşümü iyi bir uzamsal yerelleştirme, yönlendirme ve frekans seçicilik özelliklerine sahiptir. Çoklu çözünürlük özelliklerine sahip bu filtreler TFI'ları filtrelemek için kullanılmıştır (ilgilenilen bir pikselin özellik vektörünü bulmak için, pikselin etrafındaki pikselardan oluşturulan görüntü ile filtrenin konvolüsyonunun alınmasıdır). 2D Gabor fonksiyonları, Gauss modüle edilmiş karmaşık sinüs eğrileridir ve aşağıdaki gibi tanımlanır:

$$\Psi_j(\mathbf{x}) = \frac{k_j^2}{\sigma^2} e^{-\frac{k_j^2 x^2}{2\sigma^2}} \left[e^{i\mathbf{k}_j \mathbf{x}} - e^{-\frac{\sigma^2}{2}} \right] \quad (22)$$

Her bir Ψ_j , bir Gauss fonksiyonuyla sarılı \mathbf{k}_j vektörüyle karakterize bir düzlem dalgasıdır, burada σ Gauss fonksiyonunun standart sapmasıdır. Bu denklemde $\exp(i\mathbf{k}_j \mathbf{x})$ terimi salınım yapan bölümü temsil etmekte, $\exp\left(-\frac{\sigma^2}{2}\right)$ terimi ise sabit değeri tazmin etmektedir.

Karakteristik dalga vektörü \mathbf{k}_j (23)'de verildiği gibi hesaplanır, j. Gabor filtresinin merkez frekansını verir.

$$\mathbf{k}_j = \begin{pmatrix} \mathbf{k}_{jx} \\ \mathbf{k}_{jy} \end{pmatrix} = \begin{pmatrix} \mathbf{k}_v \cos(\varphi_\mu) \\ \mathbf{k}_v \sin(\varphi_\mu) \end{pmatrix} \quad (23)$$

$$\mathbf{k}_v = 2^{\frac{v+2}{2}} \pi \quad \varphi_\mu = \frac{\mu\pi}{8}$$

Çalışmamızda 5 farklı frekans ve 8 farklı yönelime sahip toplam 40 filtre hesaplanmıştır (Şekil 2). Farklı frekans değerlerinde hesaplanan filtrelerin genlikleri Şekil 3'te gösterilmiştir. Gabor dalgacık dönüşümü için filtreler aşağıdaki denklem kullanılarak oluşturulmuştur.

$$g_{mn}(x, y) = a^{-m} g(x_a, y_a), \quad a > 1, \quad (24)$$

$$x_a = a^{-m}(x \cos(\theta) + y \sin(\theta))$$

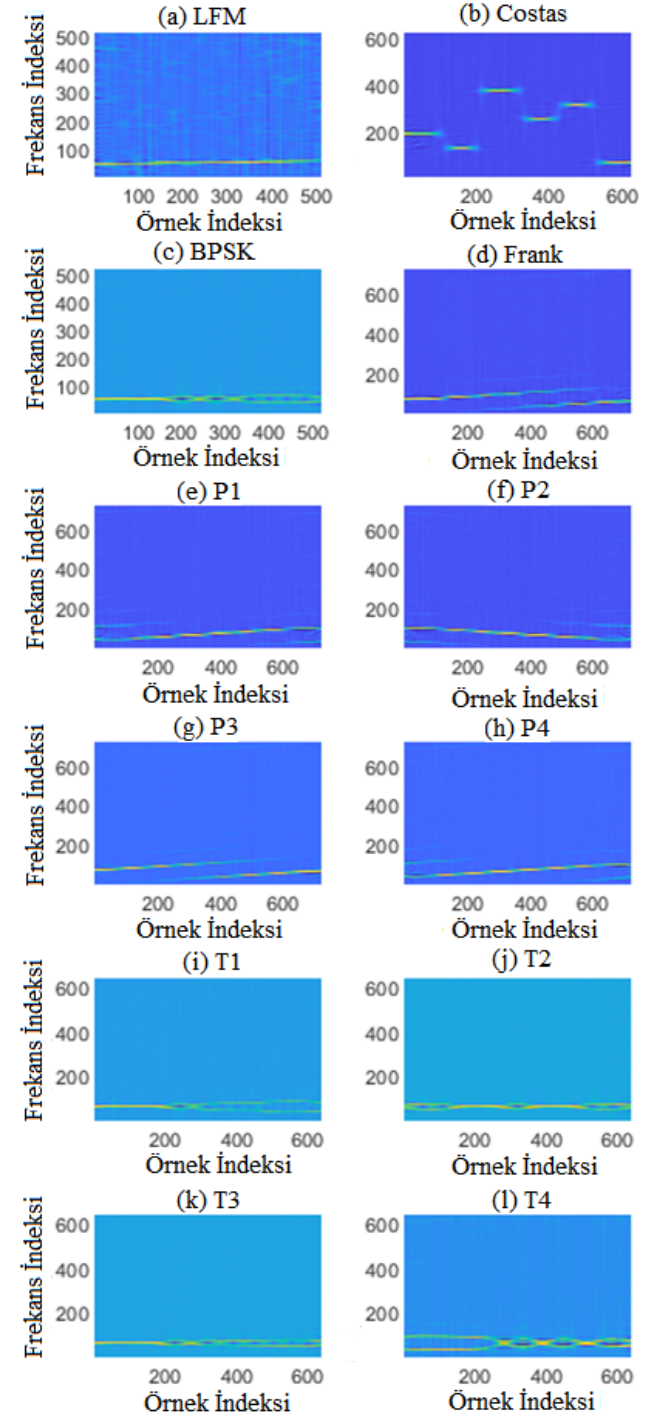
$$y_a = a^{-m}(-x \sin(\theta) + y \cos(\theta))$$

Burada, $\theta = \frac{n\pi}{K}$, (K farklı yönelim sayısı) ve a^{-m} ise ölçekleme için kullanılmıştır (a=2 olarak alınmıştır).

5. ÖZNETELİK VEKTÖRLERİNİN ÇIKARILMASI (FEATURE VECTOR EXTRACTION)


Öznelik vektörleri, TFI'ların Gabor Dalgacık Dönüşümü alınarak elde edilen 40 filtrelenmiş TFI'da yüksek enerjili noktaların bulunması ile elde edilmiştir. Çalışmanın temelini bu öznelik vektörlerinin karşılaştırması oluşturmaktadır. Referans olarak alınan TFI'lar için elde edilen öznelik vektörleri ile metodumuzu sınamak için kullanılacak LPI dalga biçimlerine ait TFI'lardan oluşturulan öznelik

vektörleri sonraki bölümde detayları verilmiş yöntem kullanılarak karşılaştırma yapılmıştır.




Şekil 1. Farklı LPI radar dalga biçimlerinin Zaman-Frekans dönüşümleri alınarak elde edilmiş görüntüler. (Images obtained by taking Time-Frequency conversions of different LPI radar waveforms).

Referans setinde yer alan her LPI işaretlerine ait TFI'larından Gabor Filtreleri uygulanarak elde edilen 40 filtrelenmiş TFI'ların her birinde yüksek enerjili noktaları (tepe noktaları)



Şekil 2. 5 farklı frekans (aşağıdan yukarıya değişmektedir) ve 8 farklı yönelime (soldan sağa değişmektedir) sahip Gabor filtrelerinin I bileşenleri.

(I components of Gabor filters with 5 different frequencies (changing from bottom to top) and 8 different orientations (changing from left to right)).



Şekil 3. Farklı frekans değerlerine sahip Gabor Filtrelerinin genlikleri. (Amplitudes of Gabor Filters with different frequency values).

seçmek için, görüntü bir $W \times W$ (W tek sayıdır) penceresi ile taranır. Merkez piksel değeri, penceredeki diğer tüm piksel değerlerinden daha büyükse ve tüm görüntüdeki ortalama piksel değerinin üstünde ise bu nokta kullanılarak yeni bir öznitelik vektörü oluşturulur. Öznitelik vektörleri $(u_{i,k})$, $\{x_k, y_k, r_{i,j}(x_k, y_k)\}$ şeklinde oluşturulur [15]. Burada (x_k, y_k) tepe değerinin koordinatını, $r_{i,j}(x_k, y_k)$ değeri ise filtrelenmiş 40 TFI'nın (x_k, y_k) koordinatındaki değerlerini belirtmektedir. Dolayısıyla her bir öznitelik vektörü 42 elemandan oluşmaktadır.

Farklı filtrelenmiş TFI'lerden aynı koordinatlarda öznitelik çıkması durumunda bunlardan sadece bir tanesi alınmaktadır. Çalışmamızda farklı pencere boyutları için yöntem denendikten sonra pencere boyutu $W=7$ olarak seçilmiştir. Farklı SNR değerlerine göre çıkartılan öznitelik vektör sayısı değişkenlik göstermektedir. Yüksek SNR değerine sahip LPI işaretleri için daha fazla sayıda öznitelik oluşmaktadır. Bu yöntemin literatürde verilen yöntemlere göre avantajlarından biri de sınıflandırmanın bütün adımlarında boyutlandırma ile ilgili problemlerle ilgili ekstra işlemci gücü harcanmasına ihtiyaç bulunmamasıdır. Örneğin; farklı LPI dalga biçimlerinin aynı boyutlara getirilmesi için sıfır doldurması (*zero padding*) yapılmasına ya da CNN uygulamasında olduğu gibi görüntülerin aynı boyuta getirilmesine gerek

yoktur. Burada vurgulanmak istenen sadece sıfır doldurulması veya bunun için harcanan zaman değil, işlem karmaşıklığının her zaman en büyük boyutlu TFI'ya göre belirlendiğidir. Çoğu zaman bu karmaşıklıktan kaçınmak için görüntülerin boyutlarının küçültülmesi yoluna gidilmesi bunun sonucu olarak da özellikle düşük SNR değerine sahip LPI işaretleri için ayırt edici özelliklerin kaybedilmesi sonucu ortaya çıkmaktadır.

5.1. Benzerlik Hesaplaması (Similarity Calculation)

Benzerlik hesaplamasında [11]'de verilen Eş. 25 benzerlik işlevi kullanılmıştır.

$$B_i(k, j) = \frac{\sum_{l=3}^{42} |u_{i,k}(l)| |u_{t,j}(l)|}{\sqrt{\sum_{l=3}^{42} |u_{i,k}(l)|^2 |u_{t,j}(l)|^2}} \quad (25)$$

$B_i(k, j)$, sınırlanmış LPI işaretine ait TFI'nın j . öznitelik vektörünün, $(u_{t,j})$, referans olarak alınan LPI işaretinin TFI'nın k . özellik vektörünün $(u_{i,k})$ benzerliğini temsil eder ve 0 ile 1 arasında değer alır. Eğer test edilen LPI işaretine ait j . öznitelik vektörü ile referans alınan LPI işaretine ait öznitelik vektörü aynı ise, $B_i(k, j) = 1$ olacaktır. Bu benzerlik hesaplaması referans alınan işaretlere ait öznitelik vektörleri

ile sınınan işaretlere ait tüm öznitelik vektörleri için uygulanmasına gerek yoktur. Öznitelik vektörlerinin ilk iki bileşeni vektörlerin oluşturulduğu filtrelenmiş TFI'ların koordinatlarını temsil etmektedir. Bu değerler birbirine yakın olan öznitelik vektörlerini kıyaslamak, birbirine yakın olmayan vektörlerin benzerliklerinin yanlış sonuçlar üretmesinin önüne geçmek için kullanılmaktadır. Yakınlık ölçümü için Öklid uzaklığı hesaplanmıştır. Eşik değeri olarak kıyaslama yapılan iki LPI işaretine ait TFI'ların köşegen uzunlukları toplamının yarısı bir katsayı ile çarpılarak elde edilmiştir. Benzetim çalışmalarımızda bu katsayı 0.08 olduğunda en iyi sonuçlar elde edilmiştir.

5.2. Eşleştirme Yöntemi (Matching Method)

Referans alınan LPI radar dalga biçimlerine ait TFI'ların öznitelik vektörleri ile sınınan dalga biçimine ait TFI öznitelik vektörlerinin benzerlik yönteminde verilen kriterlere uyanları kullanarak referans alınan görüntülerle sınınan görüntü arasındaki en yüksek benzerlik değeri belirlenir.

$$MB_{i,j} = \text{enbüyük}(B_i(k,j)) \quad (26)$$

$MB_{i,j}$; referans görüntünün, j . öznitelik vektörüne dayanarak sınınan görüntüye en yüksek benzerliğini belirtmektedir. Bir sonraki adımda bu benzerlik değerlerinin ortalamaları alınarak OMB_i değeri hesaplanmaktadır. OMB_i i. referans görüntüsünün sınınan görüntüye etraflı benzerlik değeri olarak tanımlanabilir ($0 \leq OMB_i \leq 1$). Ancak önceki adımlardan gelen elemeler ve MB bulunurken en büyük değerler alındığından 0'a yakın değerler almamaktadır. Referans kümesinde yer alan bir LPI dalga biçimi için sınına yapılırsa $OMB_i = 1$ olacaktır.

OMB, benzerlik için iyi bir ölçüt vermesine rağmen, öznitelik vektörlerinin sayısının da dikkate alınması gerekmektedir. Çünkü farklı SNR değerleri için öznitelik vektör sayısı oldukça farklı olabilmektedir. Ayrıca daha önceki bölümlerde belirtildiği gibi zaman-frekans dönüşümü sonrasında elde edilen görüntü boyutları da birbirinden farklı olabilmektedir. Bu sebeple, sınınan görüntünün her bir öznitelik vektörü için referans alınan görüntünün (26)'yı sağladığı da hesaplanmaktadır (C_i) [15]. Bu sayım sonucunun (C_i) referans görüntülerin toplam öznitelik vektör sayısına (N_i) oranı da kullanarak nihai benzerlik oranı elde edilmektedir.

$$NBO_i = \alpha (OMB_i) + \beta \left(\frac{C_i}{N_i}\right) \quad (27)$$

$$\alpha + \beta = 1, \quad \alpha > 0, \quad \beta > 0$$


Sınınan LPI işaretinden TFI elde edilir. Bu görüntüden Gabor Dalgacık dönüşümü ile elde edilen özniteliklerin veri tabanında yer alan LPI işaretlerine ait öznitelik vektörleri ile kıyaslanması sonucunda en yüksek NBO değerinin elde edildiği sınıf ile etiketlenir. Bu yöntem ile elde edilen sonuçlar aşağıdaki bölümde irdelenmiştir.

6. SONUÇLAR VE TARTIŞMALAR (RESULTS AND DISCUSSIONS)

LPI dalga biçimi sınıflandırması için 12 farklı modülasyon tipi ve modülasyon olmayan işaret olmak üzere toplam 13 farklı işaret tipi SNR değeri -20 dB ila 10 dB arasında 2'şer dB aralıklarla üretilmiştir. Üretilen işaretler beş eşit bölüme ayrılmıştır, her bölümde tüm SNR değerlerine sahip işaretler eşit sayıdadır. Bu beş bölümden her seferinde bir bölüm sınıflandırma performansını ölçmek için diğer dört bölüm ise karşılaştırma yapabilmek için veri tabanı işareti olarak kullanılmıştır. Sınıflandırma performansı beş bölümün her biri sınına için kullanılacak şekilde tekrar edilmiş, elde edilen sonuçların ortalaması genel performans olarak verilmiştir. Şekil 4'te SNR değerine göre sınıflandırma performansı verilmiştir. Toplamda 14 grafik (12 modülasyon, 1 modülasyonsuz ve tüm sınıflar) gösterilmesi gerektiğinden 4 farklı şekil ile sunulmuştur. Bu grafiklerden de gözlemleneceği üzere -6dB SNR değerinden daha küçük SNR değerleri için sınıflandırma doğruluğu hızlı bir şekilde düşüş göstermektedir. Bu genelleme Costas dalga biçimi için geçerli değildir. Şekil 1 de verilen zaman-frekans görüntülerine bakacak olursak Costas işareti için farklı bölgelere dağılmış enerji yoğunlukları bulunmaktadır. Uyguladığımız yöntem lokasyon ve yerel enerji yoğunluklarının karşılaştırılmasına dayalı olduğundan düşük SNR değerleri için de nispeten yüksek doğruluk değerleri elde edilebildiği değerlendirilmiştir.

Aşağıdaki şekillerde sınıflandırma performansının SNR değerine göre değişimi 13 farklı sınıf için verilmiştir. [5], literatürde şu ana kadar yapılmış çalışmalar arasında en yüksek doğruluk değerleri verilmiştir. Ancak [5]'te verilen sonuçlar bazı sinyal tipleri farklı ifade edilmiştir (P3 sinyali iki farklı gruba ayrılarak bir grubu P4 ile birlikte tek sınıf olarak kabul edilmiş, P3 sinyalinin diğer grubu P3 sınıfı olarak alınır). Dolayısıyla bütün sınıflar için ve genel doğruluk değerlerinin birebir bütün sınıflar için karşılaştırılması mümkün olamamaktadır. Ayrıca [5]'te verilen çalışmalarda "No signal" olarak bir sınıf daha verilmiş ve doğru sınıflandırılmayan bütün sinyallerin bu sınıfa atıldığı gözlemlenmektedir. Hâlbuki sinyal tipi belirleme safhasına ESM sistemlerinde sinyal varlığı tespit edildikten sonra geçilmektedir, dolayısıyla sinyal yok demek yerine ya sınıflandırıcının belirlendiği en yakın sınıfa atmak daha uygun olacaktır. Yaptığımız çalışmada her SNR değerine sahip işaretleri veri tabanı işareti olarak ele aldık, diğer çalışmalarda, [3, 5], 10 dB ila -6 dB SNR değerleri arasındaki işaretler eğitimde kullanılmıştır. Daha önce yaptığımız çalışmalarda gözlemlediğimiz düşük SNR değerlerini de eğitim setine dâhil ettiğimizde sınıflandırma performansı düşmektedir [30]. Bu sonuç [5]'te de açıkça ifade edilmiştir.

Önerdiğimiz yöntemin başarımlı sonuçlarının literatürdeki yöntemlerle karşılaştırılması Tablo-1'de verilmiştir. Karşılaştırmada bu alanda yapılan başlıca çalışmalar olan [3, 5, 6] ve [9] ele alınmıştır. Değerler incelendiğinden hiçbir yöntemin diğerine göre belirgin bir üstünlüğü bulunmamakla



Şekil 4. Farklı SNR değerlerin için sınıflandırma doğrulukları (a) BPSK, Costas, LFM, Frank, (b) P1, P2, P3 P4, (c) T1, T2, T3, T4 (d) No. Mod., Tüm sınıfların ortalaması. (Classification accuracies for different SNR values (a) BPSK, Costas, LFM, Frank, (b) P1, P2, P3 P4, (c) T1, T2, T3, T4 (d) No. Mod., Average of all classes.)

birlikte önerdiğimiz yöntem bazı dalga biçimleri için (Tablo 1'de kalın font ile belirtilmiştir) daha yüksek sonuçlar vermektedir.

Aşağıdaki tabloda (Tablo 1) literatürde verilen yöntemlerin en iyi sonuçlar ile bu makalede önerdiğimiz yöntemin en iyi sonuçlarını karşılaştırmalı olarak verilmiştir.

[3] 'te Karışıklık Matrisi -6dB SNR değerine sahip sonuçlar kullanılarak oluşturulmuştur, aynı yazarlar tarafından önerilen SSD metodunda [5] SNR değerlerine göre doğru sınıflandırma performansı grafik olarak verilmiştir ve Şekil 4'te sunulan sonuçlara yakın değerler raporlanmıştır. Bu iki çalışma sonuçlarına bakıldığında da sonradan yapılan çalışmada bazı durumlar için doğruluk değerleri daha düşüktür. LPI dalga biçimi sınıflandırmasında temel amaçlardan bir tanesi de düşük SNR değerlerinde de doğru sınıflandırma yapabilmektir. Bu anlamda incelendiğinde önerdiğimiz yöntemin -8 dB SNR değerine kadar makul sınıflandırma doğruluk oranlarında performans gösterdiği görülmektedir.

Referans [9]'da yapılan çalışmada, Frank, P1, P3 ve P4 kodlarını sınıflandırmak için farklı bir teknik önermektedir,

düşük SNR değerlerini de hesaplamalara dâhil ettiğinden doğruluk değerleri diğer tekniklerden daha düşüktür. [5] 'de önerilen LPI Radar Dalga Biçimi Tanıma tekniği P3 ve P4 sinyalleri için daha iyi sonuçlar vermektedir. Çoklu zaman sinyalleri için, özellikle T1, T2 ve T3 için, doğrulukta büyük farklar vardır. Elde ettiğimiz sonuçlar [5] 'teki sonuçlardan daha yüksektir. [6]'da sınıflandırma için daha yüksek SNR değerleri ve daha az sinyal türü kullanılmıştır ve sınıflandırma sonuçları daha düşüktür. Ancak bu alanda yapılan ana çalışmalardan bir tanesi olarak kabul edildiğinden sonuçları burada da verilmiştir. Tüm bu sonuçlara bakıldığında sinyal işleme ve makine öğrenmesi teknikleri ile özellikle -10dB altındaki SNR değerleri için sınıflandırma sonuçlarının yükseltilemeyeceği sonucuna varılabilir. Bu değerler ve daha düşük SNR değerleri yapılması gereken ESM sistemleri tarafında tasarlanacak donanım ve yazılımlarla işleme kazancı elde edilmesi olduğu değerlendirilmektedir.

Çalışmalarımız 3,7 GHz işlemciye ve 16 GB belleğe sahip bilgisayarda gerçekleştirilmiştir. Öznitelik çıkarma ve sınıflandırma işlemleri çok kısa sürelerde (<1s) gerçekleştirildiğinden karşılaştırma yapmak anlamlı olmadığından süre ölçümleri verilmemiştir.

Tablo 1. Önerilen yöntemin literatürdeki en yeni yöntemlerle kıyaslanması.
(Comparison of the proposed method with the newest methods in the literature.)

	Gabor Dalgacık Dönüşümü	[3] (CNN)	[9] (Fusion Image)	[5] (SSD)	[6] (Kishore)
BPSK	%95,7	%99,00	66,17%	98,00%	DA**
COSTAS	%98,14	99,00%	77,67%	99,00%	DA**
LFM	%97,84	94,00%	68,58%	99,00%	95,00%
FRANK	%97,82	89,00%		NA	85,00%
P1	%89,28	86,00%	65,83%	86,00%	85,00%
P2	%89,9	100%	68,08%	100%	95,00%
P3	%94,3	91,00%	64,5%	*98,00%	85,00%
P4	%93,61	85,00%	64,08%	91,00%	85,00%
T1	%95,95	97,00%	66,00%	84,00%	DA**
T2	%93,69	94,00%	94,50%	92,00%	DA**
T3	%92,59	95,00%	68,83%	91,00%	DA**
T4	%94,93	94,00%	DA**	99,00%	DA**
BFSK	DA**	DA**	DA**	DA**	95,00%
Modülasyon Yok	95,58%	DA**	DA**	DA**	95,00%

*[5]'te, P3 sinyalleri iki parça halinde değerlendirilmiş bu parçalardan bir tanesi P4 işaretleri ile bir sınıf olarak alınmıştır.

**DA: Değerlendirmeye Alınmamış.

7. SONUÇLAR (CONCLUSIONS)

Bu çalışmamızda Dinlenmesi Düşük Olasılıklı Radarların kullandığı dalga biçimlerinin sınıflandırılması için Gabor Dalgacık Dönüşümü yöntemi ile çıkartılan özneliklerin karşılaştırılmasına dayalı bir yöntem önerilmiştir. Literatürde yer alan birçok yöntemin aksine herhangi bir makine öğrenmesi yöntemi kullanılmamış, dalga biçimlerinin zaman-frekans dönüşümlerinde elde edilen görüntülerin Gabor Dalgacık Dönüşümü kullanılarak elde edilen öznelik vektörleri kullanılmıştır. Önerdiğimiz yöntemin en büyük avantajı her yeni LPI sinyali sınıflandırmasından sonra veri tabanına eklenecek öznelikler sayesinde tekrardan eğitime safhasının çalıştırılmasına ihtiyaç olmaması ve sınıflandırma yapabilmek için TFI'lara ön işlem uygulanmasına, dolayısıyla veri kaybına sebep olmamasıdır. LPI dalga biçimi sınıflandırmasında temelde iki farklı yöntem izlenmektedir; öğrenme algoritmalarına dayalı yöntemler [3, 31] ve sinyal özelliklerine dayalı kural tabanlı yöntemler [4, 6]. Her iki yöntemde de öznelik çıkarılması elzemdir, çünkü problem sadece ham verilerin kullanılarak çözülebilmesi mümkün olmayan bir problemdir [1]. Dolayısıyla Gabor Dalgacık yöntemi makine öğrenmesi yöntemlerine alternatif olarak değil, kural tabanlı ve öğrenme safhasına gerek kalmadan sınıflandırma yapılabilmesini mümkün kıldığını değerlendirdiğimiz, özneliklerin (özellikle lokal verilerin) çıkarılmasındaki başarımı sebebiyle kullanılmıştır. LPI dalga biçimi sınıflandırılması problemini diğer örüntü tanıma problemlerinden ayıran en önemli unsurların başında kritik görevlerde kullanım ihtiyacıdır. Bir yüz tanıma ya da parmak izi tanıma sistemi gibi değerlendirme yapmak doğru olmayacaktır, çünkü bazı durumlarda uzun görevler sırasında asli görevleri sistemi kullanarak karşı tedbir oluşturmak olan kişilerden sistemi eğitmelerini beklemek çok verimli olmayacaktır. Ayrıca, taktiksel olarak değişen parametrelere göre kullanıcının döngüde olmasını gerektirecek durumlar

olduğunda ya da yeni sinyal tipleri geldiğinde sınıflandırıcı yapısının hızlı bir şekilde adapte edilmesi gerekmektedir. Sürelerin kısa olması uygulanan yöntemin ESM'den Radar İkaz Alıcısına (Radar Warning Receiver – RWR) doğru gidildiğinde “yaklaşık gerçek zamanlı” olarak uygulanabilir olduğu sonucu çıkarılabilir.

KAYNAKLAR (REFERENCES)

1. Pace P.E., Detecting and Classifying Low Probability of Intercept Radar, Artech House, 2nd Edition, Norwood, MA, USA 2009.
2. Tao R., Li B., Sun H., Research Progress of the Algebraic and Geometric Signal Processing, Defence Technology, 9 (1), 40 – 47, 2013.
3. Kong S. H., Kim M., Hoang L.M., Kim E. Automatic LPI Radar Waveform Recognition Using CNN. IEEE Access. 6, 4207-4219, 2018.
4. Gulum T. Autonomous Non-Linear Classification of LPI Radar Signal Modulations, <https://calhoun.nps.edu/handle/10945/3302>; 2007 [erişim tarihi 23 November 2020].
5. Hoang L.M., Kim M., Kong S. H., Automatic Recognition of General LPI Radar Waveform Using SSD and Supplementary Classifier. IEEE Transactions on Signal Processing, 67 (13), 3516-3530, 2019.
6. Kishore T.R., Rao K.D., Automatic intrapulse modulation classification of advanced LPI radar waveforms. IEEE Trans. Aerosp. Electron. Syst., 53 (2), 901-914, 2017.
7. Tong X. Modelling and realization of real time electronic countermeasure simulation system based on SystemVue. Defence Technology, 16 (2). 470-486, 2020.
8. Deng B., Luan J., Cui S. Analysis of parameter estimation using the sampling-type algorithm of discrete

- fractional Fourier transform. *Defence Technology*, 10 (4), 321-327 2014.
9. Gao L., Zhang X., Gao J., You S., Fusion Image Based Radar Signal Feature Extraction and Modulation Recognition, *IEEE Access*, 7, 13135-13148, 2019.
 10. Choi H.I., Williams W. J. Improved time-frequency representation of multicomponent signals using exponential kernels. *IEEE Trans. Acoust., Speech, Signal Process.*, 37 (6), 862-871, 1989.
 11. Hollinger K.B., Code optimization for the Choi-Williams distribution for ELINT applications, <https://calhoun.nps.edu/handle/10945/4422>; 2009 [erişim tarihi: 24 September 2020].
 12. Liu Y., Xiao P., Wu H., Xiao W. LPI Radar Signal Detection Based on Radial Integration of Choi-Williams Time-Frequency Image, *Journal of Systems Engineering and Electronics*, 26 (5), 973-981, 2015.
 13. M. Lades, J Vorbruggen, J, Buhmann, J. Lange, von der Malsburg, and R. Wurtz, Distortion invariant object recognition in the dynamic link architecture, *IEEE Trans. Comput.*, 42 (3), 300-311, 1993.
 14. Liu Y., Xiao P., Wu H., Xiao W. LPI Radar Signal Detection Based on Radial Integration of Choi-Williams Time-Frequency Image, *Journal of Systems Engineering and Electronics*, 26 (5), 973-981, 2015.
 15. Daugman J.G., Complete Discrete 2-D Gabor Transform by Neural Networks for Image Analysis and Compression, *IEEE Trans. On Acoustics, Speech and Signal Processing*, 36 (7), 1169-1179, 1988.
 16. Kepenekci B., Tek, F.B., and Akar, G.B., Occluded face recognition based on Gabor wavelets, in *Proc. Int. Conf. Image Process.*, 293 – 296, 2002.
 17. Serte S., Demirel, H., Gabor wavelet-based deep learning for skin lesion classification, *Computers in Biology and Medicine*, 113, 103423, 2019.
 18. Nabizadeh N., Kubat M., Brain tumors detection and segmentation in MR images: Gabor wavelet vs. statistical features”, *Comput. Electr. Eng.*, 45, 286-301, 2015.
 19. Choi H.I., Williams W. J. Improved time-frequency representation of multicomponent signals using exponential kernels. *IEEE Trans. Acoust., Speech, Signal Process.*, 37 (6), 862-871, 1989.
 20. Hollinger K.B., Code optimization for the Choi-Williams distribution for ELINT applications, <https://calhoun.nps.edu/handle/10945/4422>; 2009, erişim tarihi: 24 September 2020.
 21. Daugman J., Two-dimensional spectral analysis of cortical receptive field profiles”. *Vision Research*, 20 (10), 847–856, 1980.
 22. Daugman J.G., Uncertainty relation for resolution in space, spatial frequency, and orientation optimized by two-dimensional visual cortical filters, *Journal of the Optical Society of America A*, 2 (7), 1160-1169, 1985.
 23. Shen, L. and Bai, L., A review of Gabor wavelets for face recognition, *Pattern Analysis Applications*, 9, 273-292, 2006.
 24. Jain A.K., Farrokhnia F., Unsupervised texture segmentation using Gabor filters, *Pattern Recognition*, 24 (12), 1167–1186, 1991.
 25. Weldon T.P., Higgins W.E., Dunn D.F., “Efficient Gabor filter design for texture segmentation. *Pattern Recognition*, 29 (12), 2005–2015, 1996.
 26. Hamamoto Y., Uchimura S., Watanabe M., Yasuda T., Mitani Y., Tomita S., A Gabor filter-based method for recognizing handwritten numerals.” *Pattern Recognition* 31 (4), 395–400, 1998.
 27. Lee C.J., Wang S.D., Fingerprint feature extraction using Gabor filters, *Electronics Letters*, 35 (4), 288–290, 1999.
 28. Hanbay K., Hyperspectral image classification using convolutional neural network and two dimensional complex Gabor transform, *Journal of the Faculty of Engineering and Architecture of Gazi University* 35 (1) 443-456, 2020.
 29. Rajadell O, Garca-Sevilla P, Pla F. Scale analysis of several filter banks for color texture classification, *Proceedings International Symposium Advances in Visual Computing: Part II*, 509-518, 2009.
 30. Bektaş, A., Ergezer, H., LPI Radar Waveform Classification Using Binary SVM and Multi-Class SVM Based on Principal Components of TFI, *Communications Faculty of Sciences University of Ankara Series A2-A3 Physical Sciences and Engineering*, 62 (2), 134-152, 2020.
 31. Lee, T.S. Image representation using 2D Gabor wavelets, in *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 18 (10), 959-971, 1996.
 32. Zhang M., Diao M., and Guo L., Convolutional neural networks for automatic cognitive radio waveform recognition, *IEEE Access*, 5, 11074–11082, 2017.

