

RADAR DARBE İÇİ MODÜLASYONLARININ DERİN ÖĞRENME TABANLI SINIFLANDIRILMASI

RADAR INTRAPULSE MODULATION CLASSIFICATION BASED ON DEEP LEARNING

ÖZKAN AKBUNAR

DR. ÖĞR. ÜYESİ BARIŞ YÜKSEKKAYA

Tez Danışmanı

Hacettepe Üniversitesi

Lisansüstü Sınav Eğitim ve Öğretim Yönetmeliğinin
ELEKTRİK ELEKTRONİK MÜHENDİSLİĞİ Anabilim Dalı için öngördüğü
YÜKSEK LİSANS TEZİ olarak hazırlanmıştır.

2023

ÖZET

RADAR DARBE İÇİ MODÜLASYONLARININ DERİN ÖĞRENME TABANLI SINIFLANDIRILMASI

Özkan AKBUNAR

Yüksek Lisans, Elektrik Elektronik Mühendisliği Bölümü

Danışman: Dr. Öğr. Üyesi Barış YÜKSEKKAYA

Nisan 2023, 152 sayfa

Elektronik destek sistemleri için tehdit radar sinyallerinin kimliklendirilmesi son derece kritik bir öneme sahiptir. Radar sistemlerinde kullanılan darbe içi modülasyonları elektronik destek sistemleri tarafından tehdit radarlarının kimliklendirilmesinde kullanılmaktadır. Bu tez kapsamında, sinyal işleme ve derin öğrenme yöntemleri ile radar darbe içi modülasyonları sınıflandırılması çalışılmıştır. Derin öğrenme mimarisinin eğitimi ve testinde kullanılacak verilerin genelleştirilebilir olması için farklı parametreler ile sinyal üretebilen radar sinyal simülörü bilgisayar ortamında geliştirilmiştir. Üretilen radar sinyalleri Kısa-Zaman Fourier dönüşümü, Fourier Synchrosqueezed dönüşümü, Düzleştirilmiş Sözde Wigner-Ville dağılımı, Choi-Williams dağılımı ve çevrimisel durağan sinyal analizi gibi dönüşümlerden geçirilerek evrişimli sinir ağını eğitebilmek için kullanılarak modülasyon sınıflandırması gerçekleştirilmiştir. Analizler sonucunda 11 farklı faz ve frekans modüleli sinyalden oluşan veri seti ile 0 dB sinyal gürültü oranı değerinde %98 sınıflandırıcı başarımı elde edilmiştir.

Anahtar Sözcükler: Radar Darbe İçi Modülasyonu, Modülasyon Sınıflandırılması, Derin Öğrenme, Evrişimli Sinir Ağları

ABSTRACT

RADAR INTRAPULSE MODULATION CLASSIFICATION BASED ON DEEP LEARNING

Özkan AKBUNAR

Master of Science, Department of Electrical and Electronics Engineering

Supervisor: Asst. Prof. Barış YÜKSEKKAYA

April 2023, 152 page

Identification of threat radar signals is extremely important for electronic support systems. Radar intrapulse modulations are used by electronic support systems to identify radar systems. In this thesis, radar intrapulse modulations are classified using signal processing and deep learning techniques. A computer based radar signal simulator is designed to generate radar signals which are used to train and test a convolutional neural network. Short Time Fourier Transform, Fourier Synchrosqueezed Transform, Smoothed Pseudo Wigner Ville Distribution, Choi-Williams Distribution and Cyclostationary Signal Processing are applied to radar signals for feature extraction. After feature extraction, transformed signals are used to train and test convolutional neural network. Simulation results show that, %98 modulation classification performance is achieved at 0 dB signal to noise ratio.

Keywords: Radar Intrapulse Modulation, Modulation Classification, Deep Learning, Convolutional Neural Networks

TEŞEKKÜR

Bu tez çalışması boyunca benimle değerli bilgilerini ve desteğini paylaşan tez danışmanım Dr. Öğr. Üy Barış Yüksekkaya'ya teşekkür ederim.

Eğitim hayatım boyunca sevgi ve desteklerini esirgemeyen değerli annem Berrin TOKATLI ve abim Özcan AKBUNAR'a teşekkür ederim.

İçindekiler

	<u>Sayfa</u>
ÖZET	i
ABSTRACT	ii
TEŞEKKÜR	iii
İÇİNDEKİLER	iv
TABLOLAR	vi
ŞEKİLLER	viii
KISALTMALAR	xii
1 GİRİŞ	1
1.1 Tezin Katkıları	1
1.2 Organizasyon	2
2 RADAR DALGA BİÇİMLERİ	4
2.1 Radar İşaret Modeli	4
2.2 Radar Darbe İçi Modülasyonu	5
2.2.1 Doğrusal Frekans Modülasyonu.....	7
2.2.2 Üçgen LFM Modülasyonu.....	8
2.2.3 Basamaklı FM Modülasyonu	8
2.2.4 Barker Kod	9
2.2.5 Frank Kodu	10
2.2.6 P1 Kodu	11
2.2.7 P2 Kodu	12
2.2.8 P3 Kodu	12
2.2.9 P4 Kodu	13
3 RADAR DARBE İÇİ MODÜLASYONLARININ ANALİZİ	15
3.1 İşaret İşleme Yöntemleri	15
3.1.1 Kısa-Zaman Fourier Dönüşümü	15
3.1.2 Fourier Eşzamanlı Sıkıştırma Dönüşümü	21
3.1.3 Düzleştirilmiş Sözde Wigner-Ville Dağılımı	28

3.1.4 Choi-Williams Dağılımı	34
3.1.5 Çevrimsel Durağan Sinyal Analizi	41
3.2 Literatürde İşaret İşleme Yöntemleri ile İşaret Sınıflandırma	50
4 ÖĞRENME ALGORİTMALARI.....	53
4.1 YAPAY SİNİR AĞLARI	53
4.1.1 Aktivasyon Fonksiyonları	55
4.1.2 Optimizasyon Algoritmaları	60
4.2 Derin Öğrenme	63
4.3 Evrişimli Sinir Ağları	64
4.4 Literatürde Öğrenme Tabanlı Yöntemler ile İşaret Sınıflandırma	67
5 CNN MİMARİSİ İLE RADAR DARBE İÇİ MODÜLASYONLARININ SINIFLANDIRILMASI	69
5.1 Ön İşleme	69
5.2 Evrişimli Sinir Ağları	70
5.3 Veri Seti	71
6 BENZETİMLER	72
6.1 Kısa-Zaman Fourier Dönüşümü Sınıflandırıcı Sonuçları	73
6.2 Fourier Synchrosqueezed Dönüşümü Sınıflandırıcı Sonuçları	78
6.3 Düzleştirilmiş Sözde Wigner-Ville Dağılımı Sınıflandırıcı Sonuçları	83
6.4 Choi-Williams Dağılımı Sınıflandırıcı Sonuçları	88
6.5 Çevrimsel Durağan Sinyal Analizi Sınıflandırıcı Sonuçları	92
6.6 Eğitim ve Test Verileri SNR Değerlerinin Sınıflandırıcı Başarımına Etkisinin İncelenmesi	97
7 SONUÇ	125

TABLOLAR

	Sayfa
Tablo 2.1 Darbe İçi Modülasyonların Faz ve Frekans İfadeleri	5
Tablo 2.2 Barker Kod Yan Lob Seviyeleri	9
Tablo 6.1 Darbe İçi Modülasyonlar ve Kısaltmaları	72
Tablo 6.2 –20 dB SNR değerindeki STFT özniteliği performansı	109
Tablo 6.3 –20 dB SNR değerindeki FSST özniteliği performansı	109
Tablo 6.4 –20 dB SNR değerindeki SPWVD özniteliği performansı	110
Tablo 6.5 –20 dB SNR değerindeki CWD özniteliği performansı	110
Tablo 6.6 –20 dB SNR değerindeki SCF özniteliği performansı	111
Tablo 6.7 –10 dB SNR değerindeki STFT özniteliği performansı	111
Tablo 6.8 –10 dB SNR değerindeki FSST özniteliği performansı	112
Tablo 6.9 –10 dB SNR değerindeki SPWVD özniteliği performansı	112
Tablo 6.10 –10 dB SNR değerindeki CWD özniteliği performansı	113
Tablo 6.11 –10 dB SNR değerindeki SCF özniteliği performansı	113
Tablo 6.12 0 dB SNR değerindeki STFT özniteliği performansı	114
Tablo 6.13 0 dB SNR değerindeki FSST özniteliği performansı	114
Tablo 6.14 0 dB SNR değerindeki SPWVD özniteliği performansı	115
Tablo 6.15 0 dB SNR değerindeki CWD özniteliği performansı	115
Tablo 6.16 0 dB SNR değerindeki SCF özniteliği performansı	116
Tablo 6.17 10 dB SNR değerindeki STFT özniteliği performansı	116
Tablo 6.18 10 dB SNR değerindeki FSST özniteliği performansı	117
Tablo 6.19 10 dB SNR değerindeki SPWVD özniteliği performansı	117
Tablo 6.20 10 dB SNR değerindeki CWD özniteliği performansı	118
Tablo 6.21 10 dB SNR değerindeki SCF özniteliği performansı	118
Tablo 6.22 STFT özniteliği performansı - Eğitim 0 dB Test 10 dB	119
Tablo 6.23 STFT özniteliği performansı - Eğitim 10 dB Test 0 dB	119
Tablo 6.24 FSST özniteliği performansı - Eğitim 0 dB Test 10 dB	120

Tablo 6.25 FSST özniteliği performansı - Eğitim 10 dB Test 0 dB	120
Tablo 6.26 SPWVD özniteliği performansı - Eğitim 0 dB Test 10 dB	121
Tablo 6.27 SPWVD özniteliği performansı - Eğitim 10 dB Test 0 dB	121
Tablo 6.28 CWD özniteliği performansı - Eğitim 0 dB Test 10 dB	122
Tablo 6.29 CWD özniteliği performansı - Eğitim 10 dB Test 0 dB	122
Tablo 6.30 SCF özniteliği performansı - Eğitim 0 dB Test 10 dB.....	123
Tablo 6.31 SCF özniteliği performansı - Eğitim 10 dB Test 0 dB.....	123

ŞEKİLLER

	<u>Sayfa</u>	
Şekil 2.1	Frank Kod Faz Kayması, $M = 8$	10
Şekil 2.2	P1 Kod Faz Kayması, $M = 8$	11
Şekil 2.3	P2 Kod Faz Kayması, $M = 8$	12
Şekil 2.4	P3 Kod Faz Kayması, $M = 8$	13
Şekil 2.5	P4 Kod Faz Kayması, $M = 8$	14
Şekil 3.1	Barker STFT dönüşümü	16
Şekil 3.2	Frank STFT dönüşümü	16
Şekil 3.3	P1 STFT dönüşümü	17
Şekil 3.4	P2 STFT dönüşümü	17
Şekil 3.5	P3 STFT dönüşümü	18
Şekil 3.6	P4 STFT dönüşümü	18
Şekil 3.7	Tek Ton İşaret STFT dönüşümü	19
Şekil 3.8	Artan LFM STFT dönüşümü	19
Şekil 3.9	Azalan LFM STFT dönüşümü	20
Şekil 3.10	Üçgen LFM STFT dönüşümü	20
Şekil 3.11	Basamaklı FM STFT dönüşümü	21
Şekil 3.12	Barker FSST dönüşümü	22
Şekil 3.13	Frank FSST dönüşümü	23
Şekil 3.14	P1 FSST dönüşümü	23
Şekil 3.15	P2 FSST dönüşümü	24
Şekil 3.16	P3 FSST dönüşümü	24
Şekil 3.17	P4 FSST dönüşümü	25
Şekil 3.18	Tek Ton İşaret FSST dönüşümü	25
Şekil 3.19	Artan LFM FSST dönüşümü	26
Şekil 3.20	Azalan LFM FSST dönüşümü	26
Şekil 3.21	Üçgen LFM FSST dönüşümü	27

Şekil 3.22	Basamaklı FM FSST dönüşümü	27
Şekil 3.23	Barker SPWVD dönüşümü	29
Şekil 3.24	Frank SPWVD dönüşümü	29
Şekil 3.25	P1 SPWVD dönüşümü	30
Şekil 3.26	P2 SPWVD dönüşümü	30
Şekil 3.27	P3 SPWVD dönüşümü	31
Şekil 3.28	P4 SPWVD dönüşümü	31
Şekil 3.29	Tek Ton İşaret SPWVD dönüşümü	32
Şekil 3.30	Artan LFM SPWVD dönüşümü	32
Şekil 3.31	Azalan LFM SPWVD dönüşümü	33
Şekil 3.32	Üçgen LFM SPWVD dönüşümü	33
Şekil 3.33	Basamaklı FM SPWVD dönüşümü	34
Şekil 3.34	Barker CW dönüşümü	35
Şekil 3.35	Frank CW dönüşümü	36
Şekil 3.36	P1 CW dönüşümü	36
Şekil 3.37	P2 CW dönüşümü	37
Şekil 3.38	P3 CW dönüşümü	37
Şekil 3.39	P4 CW dönüşümü	38
Şekil 3.40	Tek Ton İşaret CW dönüşümü	38
Şekil 3.41	Artan LFM CW dönüşümü	39
Şekil 3.42	Azalan LFM CW dönüşümü	39
Şekil 3.43	Üçgen LFM CW dönüşümü	40
Şekil 3.44	Basamaklı FM CW dönüşümü	40
Şekil 3.45	Barker SCF dönüşümü	45
Şekil 3.46	Frank SCF dönüşümü	45
Şekil 3.47	P1 SCF dönüşümü	46
Şekil 3.48	P2 SCF dönüşümü	46
Şekil 3.49	P3 SCF dönüşümü	47
Şekil 3.50	P4 SCF dönüşümü	47
Şekil 3.51	Tek Ton İşaret SCF dönüşümü	48

Şekil 3.52	Artan LFM SCF dönüşümü	48
Şekil 3.53	Azalan LFM SCF dönüşümü	49
Şekil 3.54	Üçgen LFM SCF dönüşümü	49
Şekil 3.55	Basamaklı FM SCF dönüşümü	50
Şekil 4.1	YSA Yapısı	53
Şekil 4.2	YSA Nöron Yapısı	54
Şekil 4.3	Sigmoid Fonksiyonu	56
Şekil 4.4	Hiperbolik Tanjant Fonksiyonu	57
Şekil 4.5	ReLU Aktivasyon Fonksiyonu	58
Şekil 4.6	Leaky ReLU Aktivasyon Fonksiyonu	59
Şekil 4.7	Softmax Aktivasyon Fonksiyonu	60
Şekil 4.8	CNN Yapısındaki Evrişim İşlemi	65
Şekil 4.9	En Büyük Havuzlama İşlemi	66
Şekil 4.10	Ortalama Havuzlama İşlemi	66
Şekil 5.1	Sınıflandırıcı Mimarisi	69
Şekil 5.2	CNN Mimarisi	70
Şekil 6.1	STFT –20 dB Hata Matrisi	74
Şekil 6.2	STFT –10 dB Hata Matrisi	75
Şekil 6.3	STFT 0 dB Hata Matrisi	76
Şekil 6.4	STFT 10 dB Hata Matrisi	77
Şekil 6.5	FSST –20 dB Hata Matrisi	79
Şekil 6.6	FSST –10 dB Hata Matrisi	80
Şekil 6.7	FSST 0 dB Hata Matrisi	81
Şekil 6.8	FSST 10 dB Hata Matrisi	82
Şekil 6.9	SPWVD –20 dB Hata Matrisi	84
Şekil 6.10	SPWVD –10 dB Hata Matrisi	85
Şekil 6.11	SPWVD 0 dB Hata Matrisi	86
Şekil 6.12	SPWVD 10 dB Hata Matrisi	87
Şekil 6.13	Choi-Williams –20 dB Hata Matrisi	88
Şekil 6.14	Choi-Williams –10 dB Hata Matrisi	89

Şekil 6.15	Choi-Williams 0 dB Hata Matrisi	90
Şekil 6.16	Choi-Williams 10 dB Hata Matrisi	91
Şekil 6.17	SCF – 20 dB Hata Matrisi	93
Şekil 6.18	SCF – 10 dB Hata Matrisi	94
Şekil 6.19	SCF 0 dB Hata Matrisi	95
Şekil 6.20	SCF 10 dB Hata Matrisi	96
Şekil 6.21	STFT Eğitim 0 dB Test 10 dB Hata Matrisi	98
Şekil 6.22	STFT Eğitim 10 dB Test 0 dB Hata Matrisi	99
Şekil 6.23	FSST Eğitim 0 dB Test 10 dB Hata Matrisi	100
Şekil 6.24	FSST Eğitim 10 dB Test 0 dB Hata Matrisi	101
Şekil 6.25	SPWVD Eğitim 0 dB Test 10 dB Hata Matrisi	102
Şekil 6.26	SPWVD Eğitim 10 dB Test 0 dB Hata Matrisi	103
Şekil 6.27	Choi-Williams Eğitim 0 dB Test 10 dB Hata Matrisi	104
Şekil 6.28	Choi-Williams Eğitim 10 dB Test 0 dB Hata Matrisi	105
Şekil 6.29	SCF Eğitim 0 dB Test 10 dB Hata Matrisi	106
Şekil 6.30	SCF Eğitim 10 dB Test 0 dB Hata Matrisi	107
Şekil 6.31	İşaret İşleme Yöntemlerinin Zaman Maliyeti	124

KISALTMALAR

AdaGrad	: Adaptive Gradient	Uyarlanır Gradyan
Adam	: Adaptive Moment Estimation	Uyarlanır Moment Kestirimi
CAF	: Cyclic Autocorrelation Function	Çevrimsel Özilinti İşlevi
CDAE	: Convolutional Denoising Autoencoder	Evrişimsel Gürültü Arındırıcı Otokodlayıcı
CNN	: Convolutional Neural Network	Evrişimli Sinir Ağları
CTFD	: Cohen Class Time Frequency Distribution	Cohen Sınıfı Zaman Frekans Dağılımı
CWD	: Choi Williams Distributions	Choi Williams Dağılımı
FAM	: FFT Accumulation Method	FFT Biriktirme Yöntemi
FMCW	: Frequency Modulation Continuous Wave	Sürekli Dalga Frekans Modülasyonu
FSST	: Fourier Synchrosqueezed Transform	Fourier Eşzamanlı Sıkıştırma Dönüşümü
GSM	: Global System for Mobile Communication	Mobil İletişim için Küresel Sistem
Leaky ReLU	: Leaky Rectified Linear Unit	Sızdırılan Doğrultulmuş Doğrusal Birim
LFM	: Linear Frequency Modulation	Doğrusal Frekans Modülasyonu
LPI Radar	: Low Probability Intercept Radar	Dinlenmesi Düşük Olasılıklı Radar
LSTM	: Long Short Term Memory	Uzun Kısa Vadeli Hafıza Ağları
LTE	: Long Term Evolution	Uzun Süreli Gelişim

MLP	: Multi Layer Perceptron	Çok Katmanlı Algılayıcı
PSD	: Power Spectral Density	Güç Spektral Yoğunluğu
ReLU	: Rectified Linear Unit	Doğrultulmuş Doğrusal Birim
RKA	: Radar Cross Section	Radar Kesit Alanı
RMSProp	: Root Mean Squared Propagation	Kök Ortalama Karesel Yayılmı
RSTFT	: Reassigned Short Time Fourier Transform	Yeniden Atanmış Kısa Zaman Fourier Dönüşümü
SCF	: Spectral Correlation Function	Spektral Korelasyon Fonksiyonu
SNR	: Signal Noise Ratio	Sinyal Gürültü Oranı
SPWVD	: Smoothed Pseudo Wigner Ville Distribution	Düzleştirilmiş Sözde Wigner Ville Dağılımı
SSCA	: Strip Spectral Correlation Algorithm	Şerit Spektal Korelasyon Algoritması
STFT	: Short Time Fourier Transform	Kısa Zaman Fourier Dönüşümü
WCDMA	: Wideband Code Division Multiple Access	Genişbant Kod Bölмелii Çoklu Erişim
WVD	: Wigner Ville Distributions	Wigner Ville Dağılımı
YSA	: Artificial Neural Network	Yapay Sinir Ağları

1 GİRİŞ

Radar sistemlerinin hedef arama veya takip modunda çalışırken etraflarındaki pasif dinleme sistemleri (Radar İkaz Alıcı ve Elektronik Destek Sistemleri) tarafından tespit edilmeden çalışabilmeleri kritik bir husustur. Radar sistemleri pasif alıcı sistemler tarafından tespit edilememek için düşük güçlü darbeler göndermektedir. Radar denklemine göre bu düşük güçlü darbeler ile radar sisteminin tespit ve takip menzilini iyileştirmek için daha uzun darbe genişliğine sahip darbeler kullanılmalıdır. Darbe genişliğinin artmasına bağlı olarak radarın birbirine yakın iki hedefi ayırt etme ölçüyü olan menzil çözünürlüğü azalmaktadır. Radar sistemlerinde menzil çözünürlüğünü iyileştirmek için darbe içi modülasyon kullanılmaktadır. Darbe içi modülasyon uzun darbe genişliğine sahip darbelerin faz veya frekans bilgisinin modüle edilmesidir. Darbe içi modülasyon sonucunda elde edilen menzil çözünürlüğü iyileştirilmiş düşük güçlü sinyaller uzun mesafelerde hedefe ulaşabilmektedir.

Elektronik Destek sistemlerinin temel görevi tespit edilen radar sinyallerini kimliklendirmektir. Bu amaçla tespit edilen darbelerin darbe tanımlama kelimesi parametreleri belirlenmektedir. Darbe tanımlama kelimesi radyo frekansı, darbe genişliği, darbe geliş zamanı, darbe tekrarlama aralığı ve darbe geliş açısı parametrelerinden oluşmaktadır. Bu parametrelere ek olarak tehdit radarın kimliklendirilmesi için anten tarama tipi ve darbe içi modülasyon parametreleri yardımcı parametreler olarak kullanılmaktadır. Kulllanılan darbe içi modülasyonlar tehdite özel bir bilgi olduğu için bu bilginin çıkarılması tespit edilen darbenin tehdit ile ilişkilendirilmesinde kritik öneme sahiptir. Bu tez çalışması kapsamında radar sistemlerinde kullanılan darbe içi modülasyon parametresinin sınıflandırılması üzerine yapılan çalışmalar anlatılmaktadır.

1.1 Tezin Katkıları

Tez çalışmasında yapılan temel katkılar aşağıda verilmektedir.

- Radar darbe içi işaretlerini farklı parametrelerle üretebilecek kapsamlı bir işaret üretici tasarlanmıştır.

- Farklı işaret işleme teknikleri uygulanarak radar darbe içi işaretleri derin öğrenme tabanlı yaklaşım ile sınıflandırılmış ve performansları karşılaştırılmıştır.
- Test ve eğitim kümelerindeki işaretlerin sinyal gürültü oranı (Signal to Noise Ratio, SNR) değerlerinin sınıflandırma başarısına olan etkisi incelenmiştir.

1.2 Organizasyon

Tez çalışmasının organizasyonu şu şekildedir:

- Bölüm 1 tezin motivasyonu ve kapsamını sunmaktadır.
- Bölüm 2’de radar işaret modeli tanıtılmıştır. Radar işaretlerinde kullanılan darbe içi modülasyonlar tanımlanmıştır ve bu modülasyonların anlık faz ve frekans ifadeleri açıklanmıştır.
- Bölüm 3’te radar darbe içi modülasyonlarının tespiti için kullanılan yöntemler tanıtılmıştır. Kısa Zaman Fourier Dönüşümü (Short Time Fourier Transform, STFT), Fourier Eşzamanlı Sıkıstırma Dönüşümü (Fourier Synchrosqueezed Transform, FSST), Düzleştirilmiş Sözde Wigner-Ville Dağılımı (Smoothed Pseudo Wigner-Ville Dağılımı, SPWVD), Choi-Williams Dağılımı (Choi-Williams Distribution, CWD) ve çevrimisel durağan işaret analizi yöntemleri açıklanmıştır. Literatürde radar darbe içi modülasyonlarının analizinde kullanılan çalışmalarla yer verilmiştir.
- Bölüm 4’te öğrenme algoritmaları tanıtılmıştır. Yapay Sinir Ağları (YSA) yapıları, YSA yapılarında kullanılan aktivasyon fonksiyonları ve optimizasyon algoritmaları bu bölümde açıklanmaktadır. Derin öğrenme ve Evrişimli Sinir Ağları (Convolutional Neural Network, CNN) mimarisi ile ilgili bilgilere yer verilmiştir.
- Bölüm 5’tte radar darbe içi modülasyonlarının sınıflandırılması amacıyla bu çalışma kapsamında uygulanan ön işleme teknikleri ve CNN mimarisi açıklanmıştır. CNN yapısının eğitim ve testlerinde kullanılan veri seti tanıtılmıştır.

- Bölüm 6'da sınıflandırma işlemi sonucunda oluşan karmaşıklık matrisleri ve sınıflandırıcının performans metrikleri verilmiştir ve sınıflandırıcının farklı öznitelikler ile elde ettiği performanslar karşılaştırılmıştır.

2 RADAR DALGA BİÇİMLERİ

2.1 Radar İşaret Modeli

Radar sistemleri tarafından yakalanan alıcı çıkışındaki işaret moduleli radar işaretinin gürültüden oluşmaktadır. Alınan karmaşık temelbant işaret örnekleri

$$x(t) = a(t)e^{j\phi(t)} + n(t) \quad (2.1)$$

olarak modellenebilir. Eş. 2.1'de $a(t)$ işaretin zarfını, $\phi(t)$ işaretin anlık fazını, $n(t)$ sıfır ortalama karmaşık Gauss gürültüsünü ifade etmektedir. Pratikte radar sinyallerinde darbe sıkıştırma için kullanılan modülasyonlar faz ve frekans modülasyonları olarak ikiye ayrırlar. Faz modülasyonu kullanıldığından anlık faz

$$\phi(t) = 2\pi f_c t + \phi_0 + \sum_{k=1}^K \Delta\phi_k \quad t > t_{\phi_k} \quad (2.2)$$

olarak elde edilir. Eş. 2.2'de f_c taşıyıcı işaretin frekansını, $t > t_{\phi_k}$ k'inci faz atlamasının gerçekleştiği zamanı, ϕ_0 başlangıç fazını, $\Delta\phi_k$ faz atlama miktarını göstermektedir. Frekans modülasyonu da benzer şekilde yazılabilir.

$$\phi(t) = (2\pi f_c + \sum_{l=1}^L \Delta f_l)t + \phi_0 \quad t > t_{f_l} \quad (2.3)$$

Eş. 2.3'te t_{f_l} l'inci frekans atlamasının gerçekleşme zamanını, Δf_l frekans atlama miktarını göstermektedir.

Bu çalışmada yer alan Artan ve Azalan Doğrusal Frekans Modülasyonu (Linear Frequency Modulation, LFM), Üçgen LFM, Basamaklı Frekans Modülasyonu (Stepped Frequency Modulation, SFM), Barker, Frank, P1, P2, P3 ve P4 kodlu işaretlerin faz ve frekans ifadeleri Tablo 2.1'de verilmiştir. Tablo 2.1'de T darbe genişliğini, $j = 0, 1, \dots, M - 1$ frekans grup

numarasını, $i = 0, 1, \dots, M - 1$ frekans grubundaki örnek sayısını, M frekans grup sayısını, f_c taşıyıcı frekansını ve Δf modülasyon bant genişliğini ifade etmektedir.

Modülasyon Adı	$\phi_{i,j}(t)$	$f_{i,j}(t)$
LFM Artan	n/a	$f_c + \frac{\Delta F}{T}t$
LFM Azalan	n/a	$f_c - \frac{\Delta F}{T}t$
Üçgen LFM	n/a	$\begin{cases} f_0 + \frac{\Delta F}{T}t, & t \leq \frac{T}{2} \\ f_0 - \frac{\Delta F}{T}t, & t \geq \frac{T}{2} \end{cases}$
Basamaklı FM	n/a	$f_c + k\Delta F$
Barker	0 veya π	n/a
Frank	$\frac{2\pi}{M}(i-1)(j-1)$	n/a
P1	$\frac{-\pi}{M}[M - (2j-1)][(j-1)M + (i-1)]$	n/a
P2	$\frac{-\pi}{2M}[2i-1-M][2j-1-M]$	n/a
P3	$\frac{\pi}{N_c}(i-1)^2$	n/a
P4	$\frac{\pi}{N_c}[(i-1)^2 - \pi(i-1)]$	n/a
Tek Ton Modülasyon	n/a	n/a

Tablo 2.1 Darbe İçi Modülasyonların Faz ve Frekans İfadeleri

2.2 Radar Darbe İçi Modülasyonu

Radar sistemleri darbe radarı, darbe-Doppler radarı ve Sürekli Dalga Frekans Modülasyonu (Frequency Modulation Continuous Wave, FMCW) radar gibi farklı çeşitlerde olabilirler. Darbe ve darbe doppler radarlarında vericiden belirli dalga biçimine sahip drebeler gönderilir ve alıcı biriminden alınan yansıyan eko sinyallerinden hedef tespiti gerçekleştirilir. Hedef tespiti gerçekleştirildikten sonra radarın fonksiyonuna bağlı olarak hedefin menzil, hız ve açı gibi parametreleri kestirilir.

Radar vericisinden gönderilen darpeler ortamda ışık hızı ile hareket ederler. Darpeler radar ve hedef arasında iki yönlü bir iletme sahip olduğu için hedef menzili Eş. 2.4 ile hesaplanmaktadır.

$$R = \frac{ct}{2} \quad (2.4)$$

Eş. 2.4'te c ışık hızını, t darpelerin radar ile hedef arasındaki gidiş geliş süresini ifade etmektedir.

Menzil çözünürlüğü, radar sistemlerinde birbirine çok yakın iki hedefi ayırt edebilme ölçütür. Radar sistemi aralarındaki mesafe radarın darbe genişliğine karşılık gelen mesafeden daha küçük olan iki hedefi birbirinden ayırt edemez ve tek bir hedef varmış gibi tespit gerçekleştirir. Radar sisteminin menzil çözünürlüğünü

$$R_r = \frac{c\tau}{2} \quad (2.5)$$

şeklinde hesaplanır. Eş. 2.5'te τ darbe genişliğini ifade etmektedir. Radar sisteminin iki hedefi ayırt edebilmesi için $R > R_r$ olmalıdır. Menzil çözünürlüğü, radar vericisinden çıkan darpelerin darbe genişliği ile ilişkilidir. Darbe genişliği ne kadar az olursa radarın menzil çözünürlüğü o kadar iyi olmaktadır.

Radar menzil denklemi Eş. 2.6'da verilmektedir.

$$R = \left(\frac{P_t G^2 \lambda^2 \sigma}{(4\pi)^3 P_r} \right)^{\frac{1}{4}} \quad (2.6)$$

Radar menzil denkleminde P_t verici ortalama çıkış gücünü, G anten kazancını, λ dalga boyunu, σ hedef Radar Kesit Alanı (RKA) değerini ve P_r alınan güç seviyesini göstermektedir. P_t ortalama çıkış gücү vericinin tepe güç değerine, darbe genişliği ve darbe tekrarlama aralığına bağlıdır. Menzil çözünürlüğü arttırmak istenirse, darbe genişliği azaltılmalıdır ancak bunun sonucunda verici ortalama çıkış gücü azalır ve

radarın efektif olarak hedef tespiti ve izlemesi yapabileceği menzil azalmaktadır. Mevcut güç yükselticilerinin maksimum çıkış gücü limitleri ve soğutma ihtiyaçları göz önüne alındığında tepe güç değeri de çok fazla arttıramamaktadır. İkinci bir husus olarak tepe gücü arttırıldıkça radar işaretlerinin etrafında yer alan pasif dinleme sistemleri tarafından tespit edilebilirliği artmaktadır. Radar sistemi tarafından yapılan yayınların pasif sistemler tarafından algılanan güç seviyesi Eş. 2.7'de verilmektedir [1]. Eş. 2.7'de G_t radar anten kazancını, G_I pasif dinleme sistemi kazancını, R_I radar ile dinleme sistemi arasındaki mesafeyi ifade etmektedir.

$$P_{IR} = \frac{P_t G_t G_I \lambda^2}{(4\pi)^2 (R_I)^2} \quad (2.7)$$

Tepe güç değerini arttırmadan ve darbe genişliği değerini düşürmeden menzil çözünürlüğünü iyileştirebilmek için radar darbelerine darbe sıkıştırma uygulanmaktadır. Darbe sıkıştırma için radar darbelerine faz veya frekans modülasyonu uygulanmaktadır. Uygulanan temel darbe içi modülasyonlar

- Doğrusal Frekans Modülasyonu
- İkili Fazlı Kodlar
- Çoklu Fazlı Kodlar

şeklindedir. Darbe sıkıştmak için kullanılan modülasyon çeşitlerinin detayları aşağıda verilmektedir.

2.2.1 Doğrusal Frekans Modülasyonu

LFM radar işaretinin frekansı belirli bir zaman aralığında belirli bir bant genişliğini doğrusal olarak taramaktadır. LFM işaretinin anlık frekans ifadesi

$$f(t) = f_0 \pm \alpha t \quad (2.8)$$

olarak yazılımaktadır. Eş. 2.8'de α frekans artış/azalış hızını, f_0 başlangıç frekansını göstermektedir. Frekans artış/azalış hızı tarama başlangıç ve bitiş frekansına ve tarama süresine bağlıdır (Eş. 2.9).

$$\alpha = \frac{f_1 - f_0}{T} \quad (2.9)$$

Eş. 2.9'da f_1 bitiş frekansını, T tarama süresini göstermektedir.

2.2.2 Üçgen LFM Modülasyonu

Üçgen LFM modülasyonu artan ve azalan LFM işaretlerinin kombinasyonu şeklinde ifade edilebilir. Darbe genişliğinin yarısında taşıyıcı frekansı artarken diğer yarısında azalmaktadır.

$$f_i(t) = \begin{cases} f_0 + \alpha t, & t \leq \frac{T}{2} \\ f_0 - \alpha t, & t \geq \frac{T}{2} \end{cases} \quad (2.10)$$

2.2.3 Basamaklı FM Modülasyonu

SFM modülasyonunda işaretin taşıyıcı frekansı başlangıç frekansından başlayarak her adımda belirtilen atlama frekansı kadar artmaktadır. Basamaklı FM modülasyonunda sinyalin anlık frekansı

$$f_i(t) = f_0 + i\Delta f \quad (2.11)$$

olarak yazılabilir. Eş. 2.11'de $f_i(t)$ i. adımdaki anlık frekans değerini, f_0 başlangıç frekansı, Δf atlama frekansını göstermektedir.

2.2.4 Barker Kod

Barker kodu $+1$ ve -1 'lerden oluşan sonlu uzunluklu ($n \geq 2$) bir dizidir ($A = [a_0, a_1, \dots a_n]$) ve otokorelasyon fonksiyonu

$$r_k = \sum_{j=1}^{n-k} a_j a_{j+k} \quad (2.12)$$

şeklinde yazılabilir [1]. Otokorelasyon fonksiyonu $|r_k| \leq 1$ ve $r_{-k} = r_k$ ifadelerini sağlamaktadır. Barker kodlu işaretin fazı 0 veya π değerlerini alabilir. Barker kod sahip olduğu düşük yan lob seviyesinden dolayı radar sistemlerinde darbe sıkıştırma amacıyla kullanılmaktadır. Kod uzunluğuna bağlı olarak Barker kodlu işaretlerin yan lob seviyesi Tablo 2.2'de verilmektedir.

Kod Uzunluğu	Kod Elemanları	Tepe Yan lob Oranı (dB)
2	+-	-6.0
2	-+	-6.0
3	++-	-9.5
4	++-+	-12.0
4	+++-	-12.0
5	+++-+	-14.0
7	+++- - + -	-16.9
11	+++- - - + - - + -	-20.8
13	+++- + - - + + - + - +	-22.3

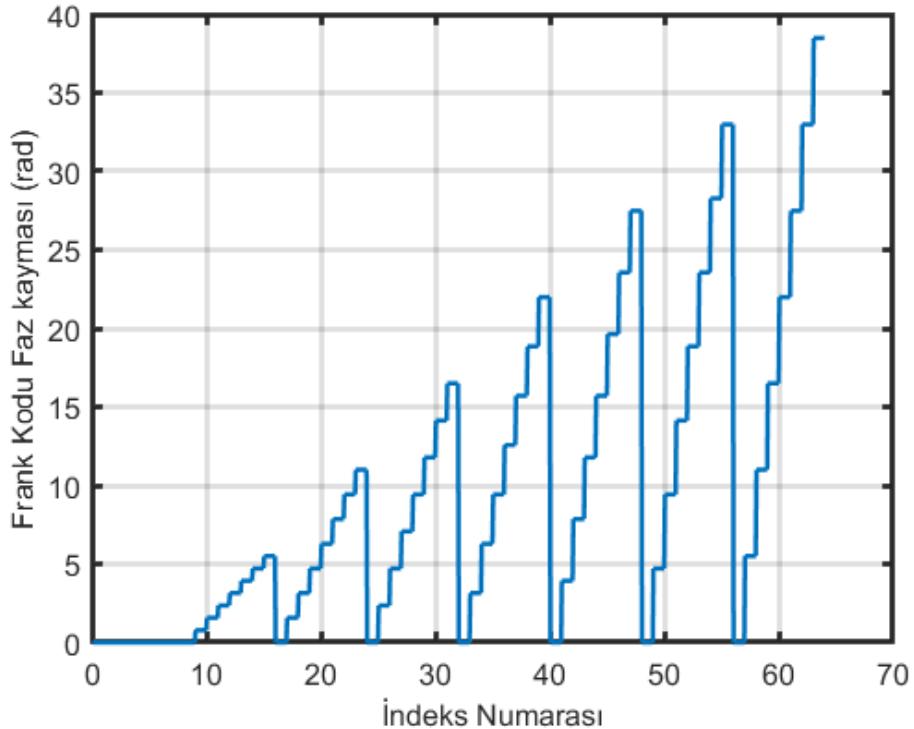
Tablo 2.2 Barker Kod Yan Lob Seviyeleri

2.2.5 Frank Kodu

Frank kod, radar sistemlerinde darbe sıkıştırmak için kullanılan çok fazlı bir modülasyon türüdür. Frank kodunda darbe genişliği M adet frekans grubuna ayrıılır ve her bir grup M adet alt darbeye ayrıılır. İlk grupta M alt darbenin fazı sıfırdır. Daha sonraki gruplarda ilk alt darpelerin fazı sıfırdır ve alt darbeden alt darbeye işaretin fazı $(j - 1)\frac{2\pi}{M}$ (j grup numarası olmak üzere) kadar artmaktadır [1]. Her bir alt darbenin anlık faz ifadesi Eş. 2.13'de verilmiştir.

$$\phi_{i,j} = \frac{2\pi}{M}(i-1)(j-1) \quad (2.13)$$

Eş. 2.13'te i grup içerisindeki alt darbe numarasını ($i = 1, 2, \dots, M$), j grup numarasını ($j = 1, 2, \dots, M$), $\phi_{i,j}$ j 'inci gruptaki i 'inci alt darbenin anlık fazını göstermektedir. Frank kodlu işaretlerin faz kayması Şekil 2.1'de verilmiştir.



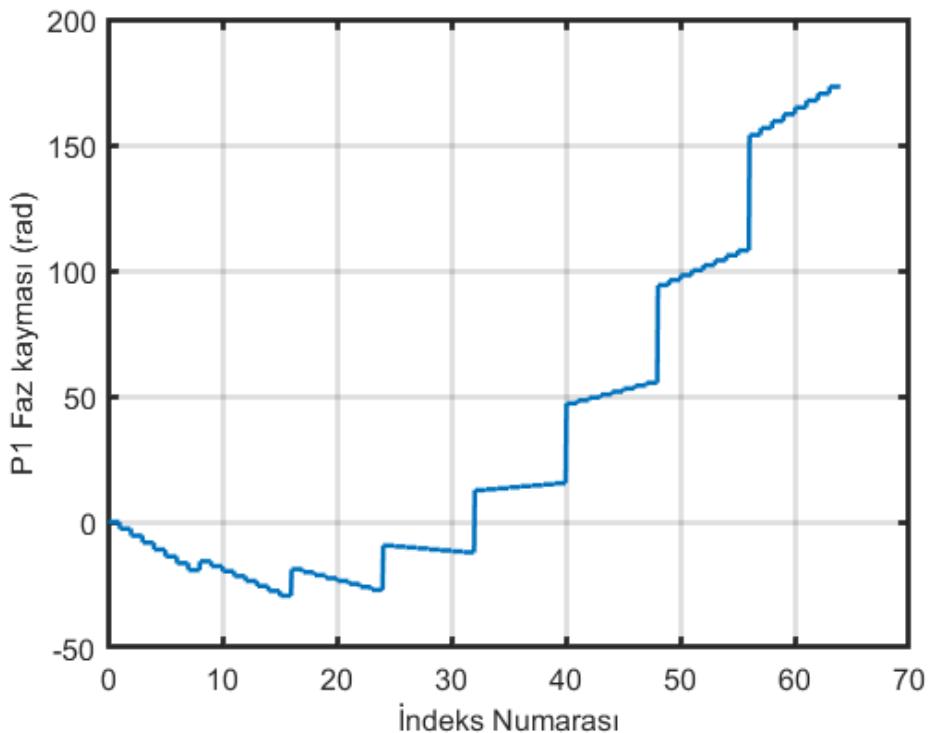
Şekil 2.1 Frank Kod Faz Kayması, $M = 8$

2.2.6 P1 Kodu

P1 kodu Frank kodu ile benzer şekilde darbe genişliği M adet frekans grubuna ayrılır ve her bir grup M adet alt darbeye ayrılır [1]. P1 kodlanmış işaretin sıkıştırma oranı M^2 'dir. Anlık faz ifadesi

$$\phi_{i,j} = \frac{-\pi}{M}(M - (2j - 1))((j - 1)M + (i - 1)) \quad (2.14)$$

olarak yazılmaktadır [1]. Eş. 2.14'te i grup içerisindeki alt darbe numarasını ($i = 1, 2, \dots, M$), j grup numarasını ($j = 1, 2, \dots, M$), $\phi_{i,j}$ j 'inci gruptaki i 'inci alt darbenin anlık fazını göstermektedir. P1 kodlu işaretlerin faz kayması Şekil 2.2'de verilmiştir.



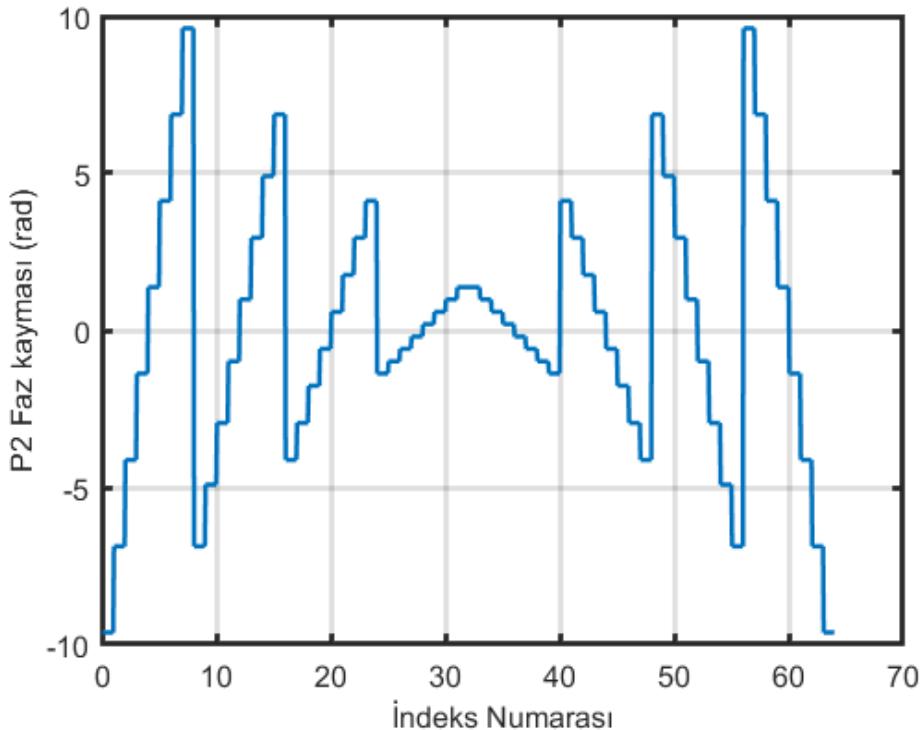
Şekil 2.2 P1 Kod Faz Kayması, $M = 8$

2.2.7 P2 Kodu

P2 kodu P1 kodları ile her grup için aynı faz artış değerine sahiptir ancak başlangıç fazları farklıdır. P2 kodlu işaretler için anlık faz ifadesi Eş. 2.15'te verilmektedir [1].

$$\phi_{i,j} = \frac{-\pi}{2M}(2i - 1 - M)(2j - 1 - M) \quad (2.15)$$

Eş. 2.15'te i grup içerisindeki alt darbe numarasını ($i = 1, 2, \dots, M$), j grup numarasını ($j = 1, 2, \dots, M$), $\phi_{i,j}$ j 'inci gruptaki i 'inci alt darbenin anlık fazını göstermektedir ve M çift sayı olması gereklidir. P2 kodlu işaretlerin faz kayması Şekil 2.3'te verilmiştir.



Şekil 2.3 P2 Kod Faz Kayması, $M = 8$

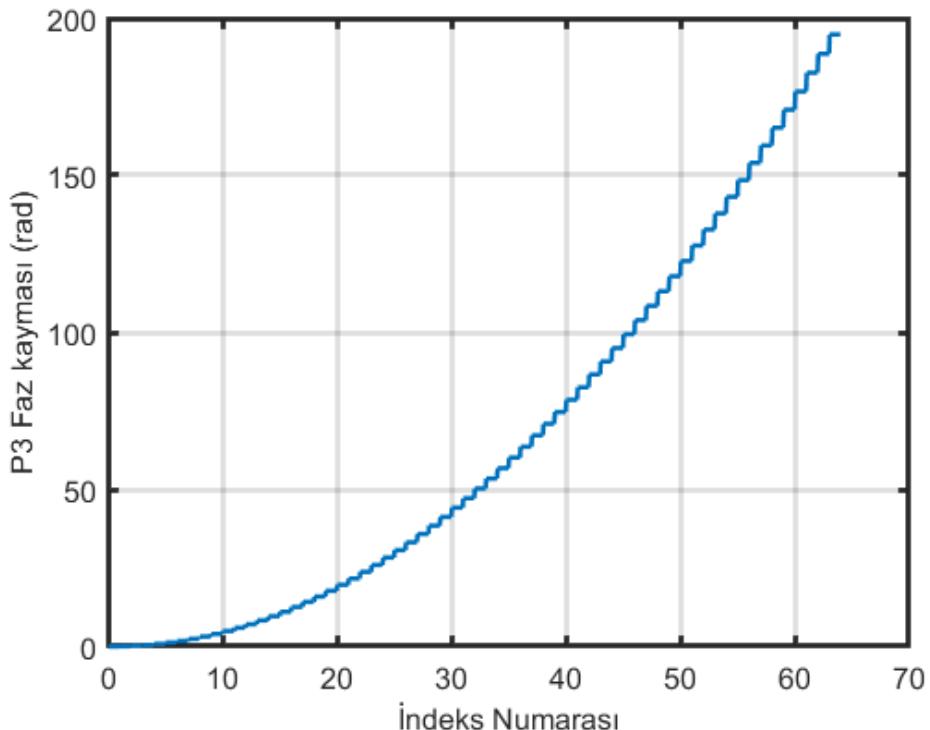
2.2.8 P3 Kodu

P3 kodu LFM işaretinin senkronize osilatör aracılığı ile temel banda indirilmesi ve sonrasında I ve Q bileşenlerinin örneklemesi ile elde edilir [1]. P3 kodunun i 'inci örneğinin

anlık fazı

$$\phi_i = \frac{\pi}{N_c}(i - 1)^2 \quad (2.16)$$

olarak hesaplanır [1]. Eş. 2.16'te ($i = 1, 2, \dots, N_c$) değerleri alabilir ve N_c sıkıştırma oranını ifade etmektedir. P3 kodlu işaretlerin faz kayması Şekil 2.4'te verilmiştir.



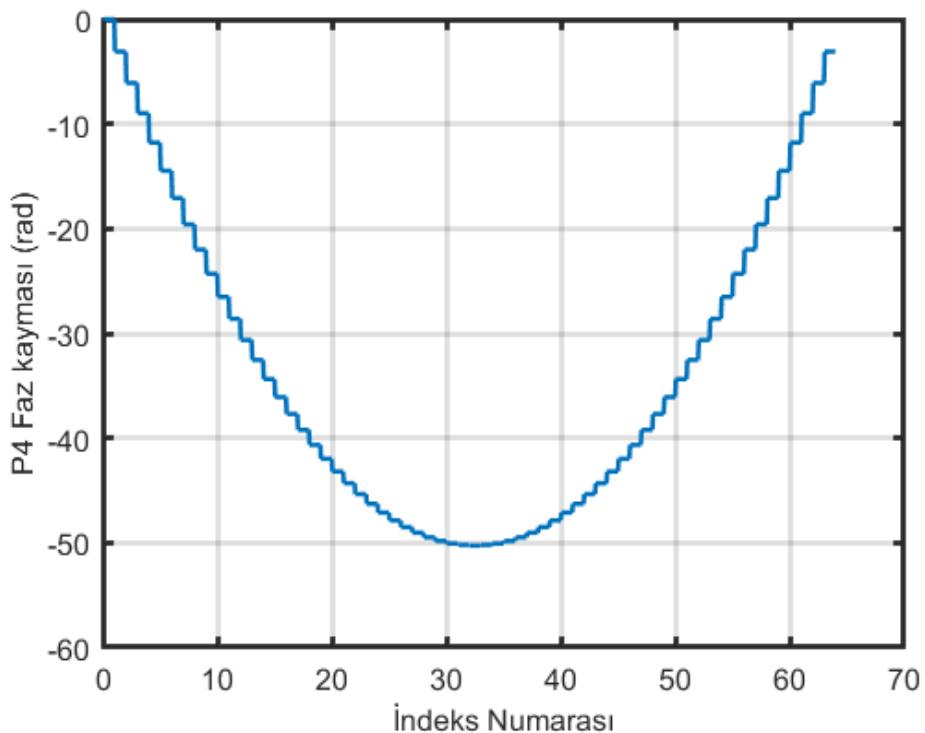
Şekil 2.4 P3 Kod Faz Kayması, $M = 8$

2.2.9 P4 Kodu

P4 kodu P3 koduna benzer şekilde LFM işaretinden türetilmiştir. P4 kodu üretmek için kullanılan lokal osilatörün I ve Q kanalları arasında offset bulunmaktadır. P4 kodu anlık faz ifadesi

$$\phi_i = \frac{\pi(i-1)^2}{N_c} - \pi(i-1) \quad (2.17)$$

olarak yazılımaktadır [1]. P4 kodlu işaretlerin faz kayması Şekil 2.5'te verilmiştir.



Şekil 2.5 P4 Kod Faz Kayması, $M = 8$

3 RADAR DARBE İÇİ MODÜLASYONLARININ ANALİZİ

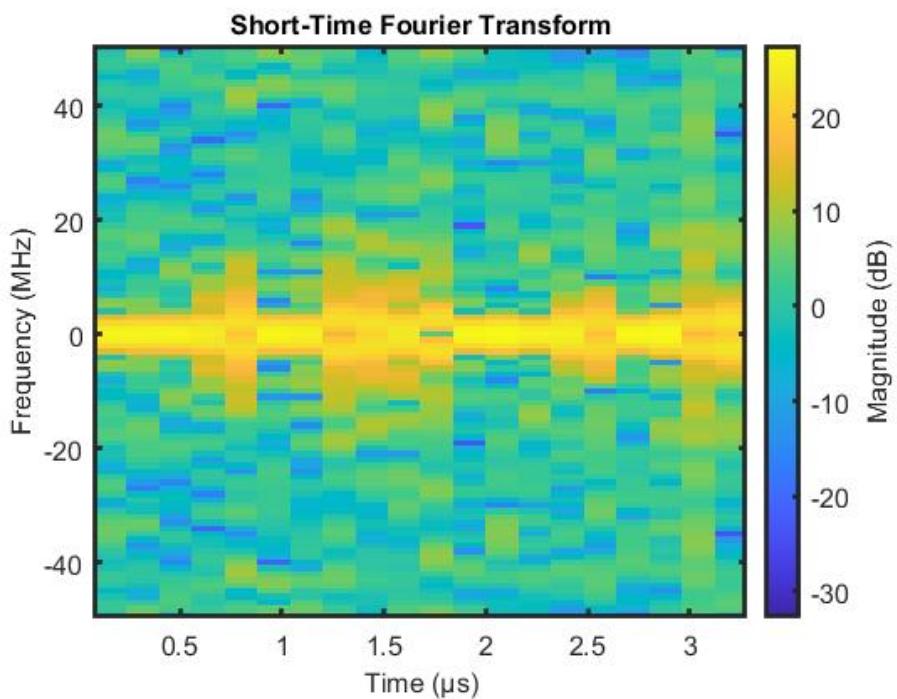
3.1 İşaret İşleme Yöntemleri

3.1.1 Kısa-Zaman Fourier Dönüşümü

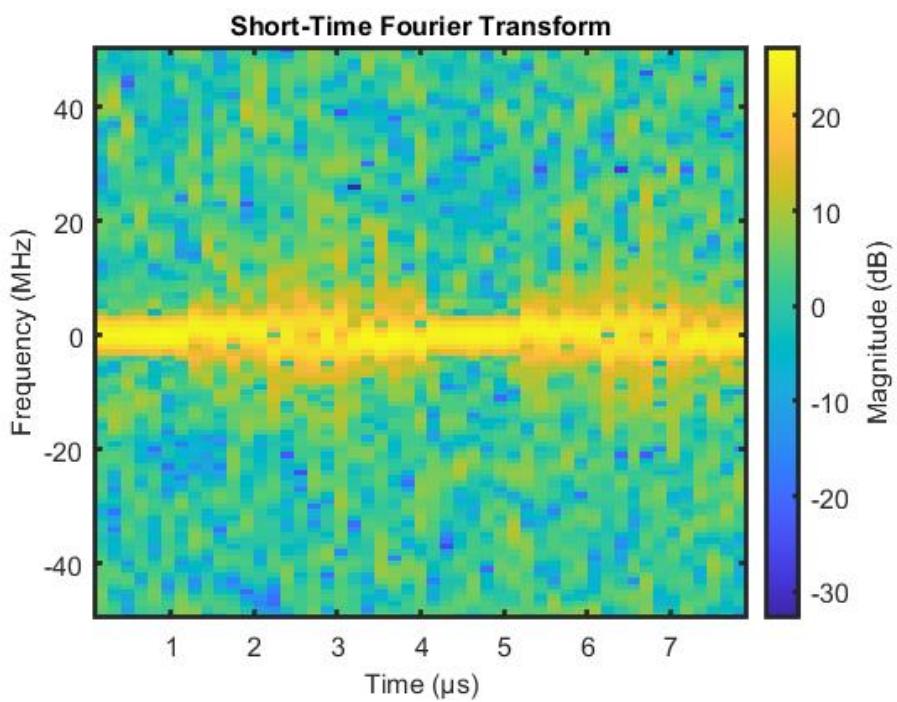
STFT zamanda durağan olmayan işaretlerin frekans bileşenlerini analiz etmek için kullanılan bir yöntemdir. STFT alınan işareti zaman pencerelerine ayırır ve her pencere üzerinde Hızlı Fourier Dönüşümü (Fast Fourier Transform, FFT) işlemi uygular [2]. Zaman penceresi olarak genel olarak Hamming, Hann, Kaiser veya Gaussian pencereler kullanılır. STFT işlemi sonucunda alınan işaretin zaman-frekans imgesi elde edilir. Matematiksel olarak

$$STFT(x[n]) = \sum_{n=-\infty}^{\infty} x[n]w[n-m]e^{-j\omega n} \quad (3.1)$$

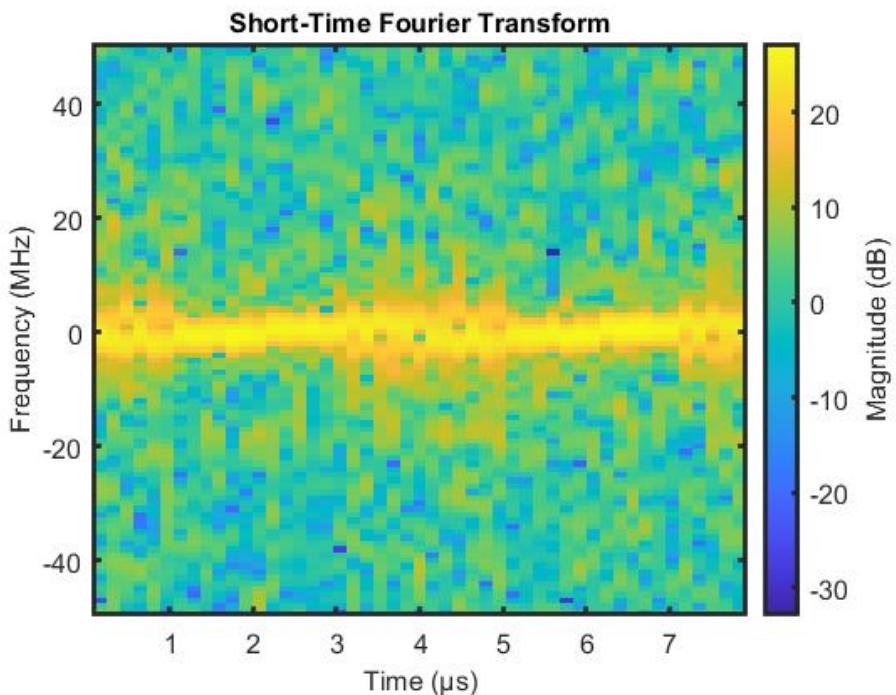
şeklinde ifade edilebilir. $w[n]$ pencere fonksiyonunu göstermektedir. STFT'de elde edilen zaman-frekans imgesinin çözünürlüğü kullanılan pencere tipi ve boyuna bağlıdır. Pencere boyutu kısa oldukça zaman çözünürlüğünü iyi olmakta iken, pencere boyutu arttıkça zaman çözünürlüğü kötüleşirken frekans çözünürlüğünü iyileşmektektir [2]. Bu çalışmada kullanılan işaretlerin STFT dönüşümleri 3.1 - 3.11 numaralı şekillerde verilmektedir.



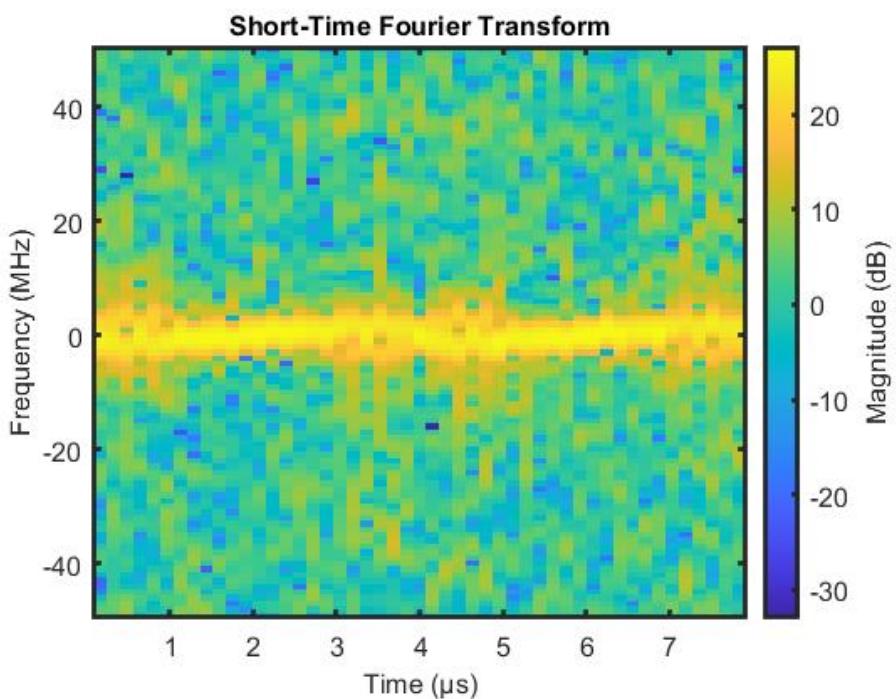
Şekil 3.1 Barker STFT dönüşümü



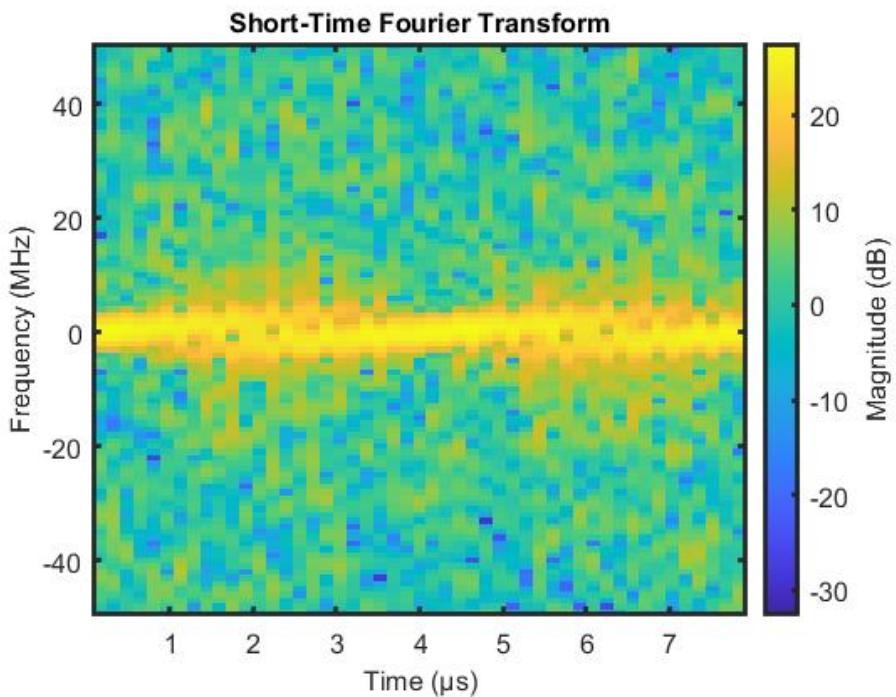
Şekil 3.2 Frank STFT dönüşümü



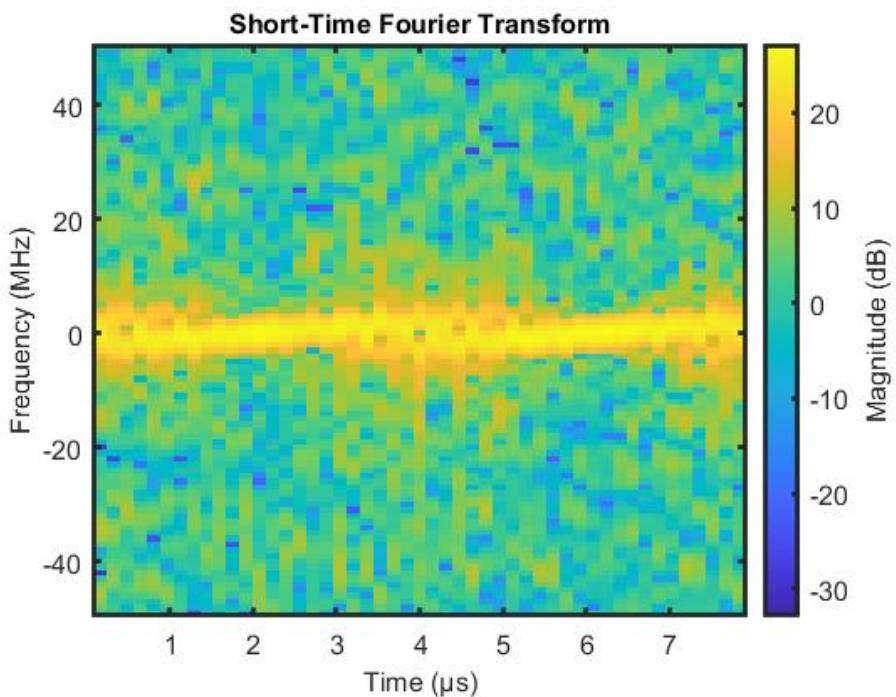
Şekil 3.3 P1 STFT dönüşümü



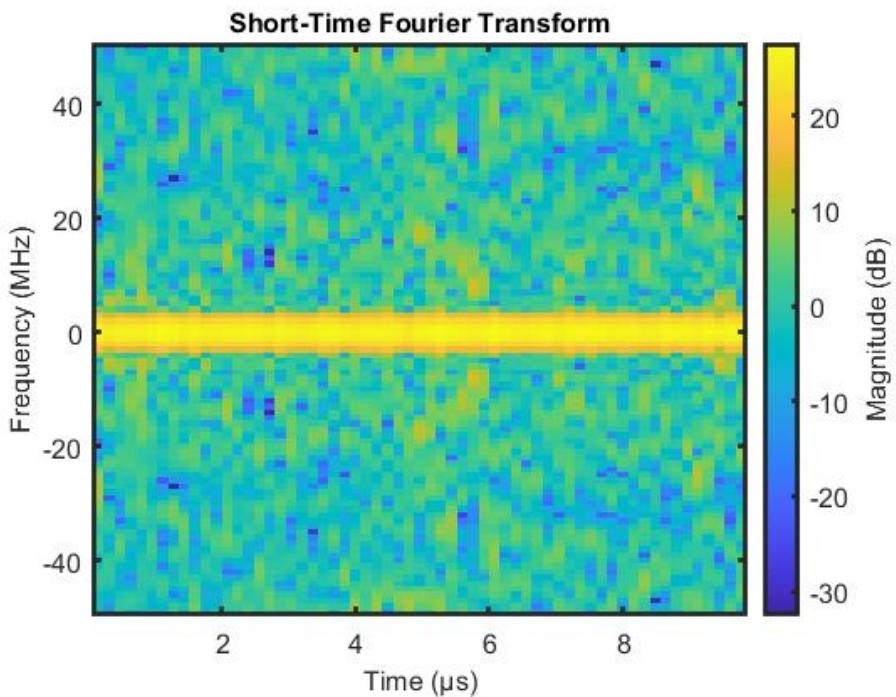
Şekil 3.4 P2 STFT dönüşümü



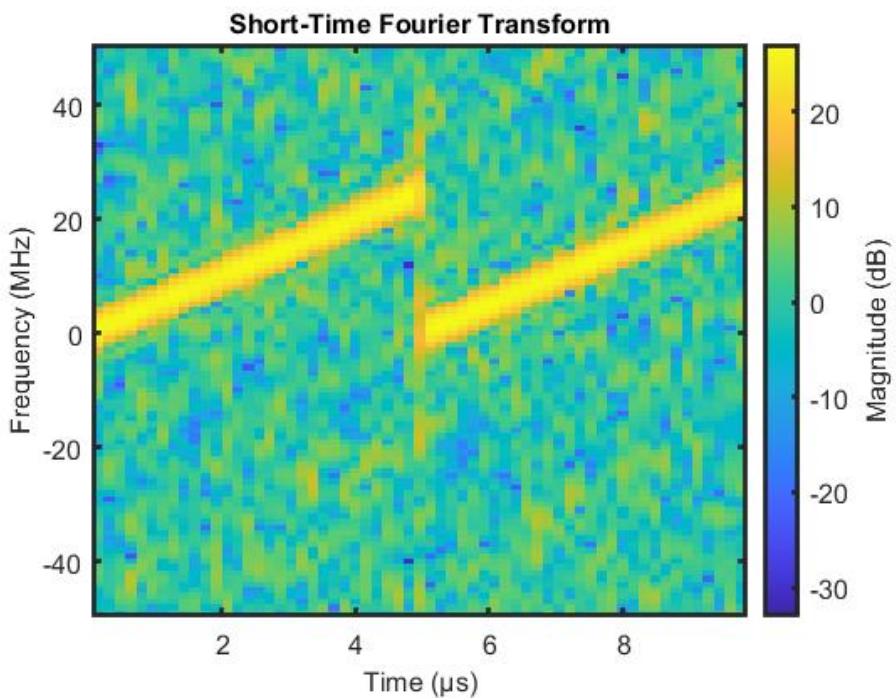
Şekil 3.5 P3 STFT dönüşümü



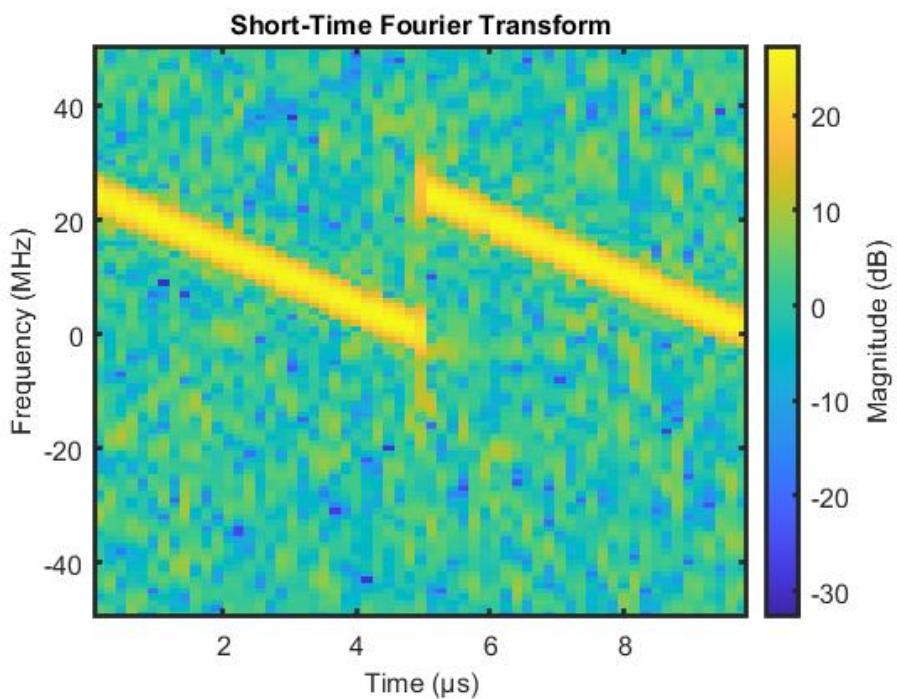
Şekil 3.6 P4 STFT dönüşümü



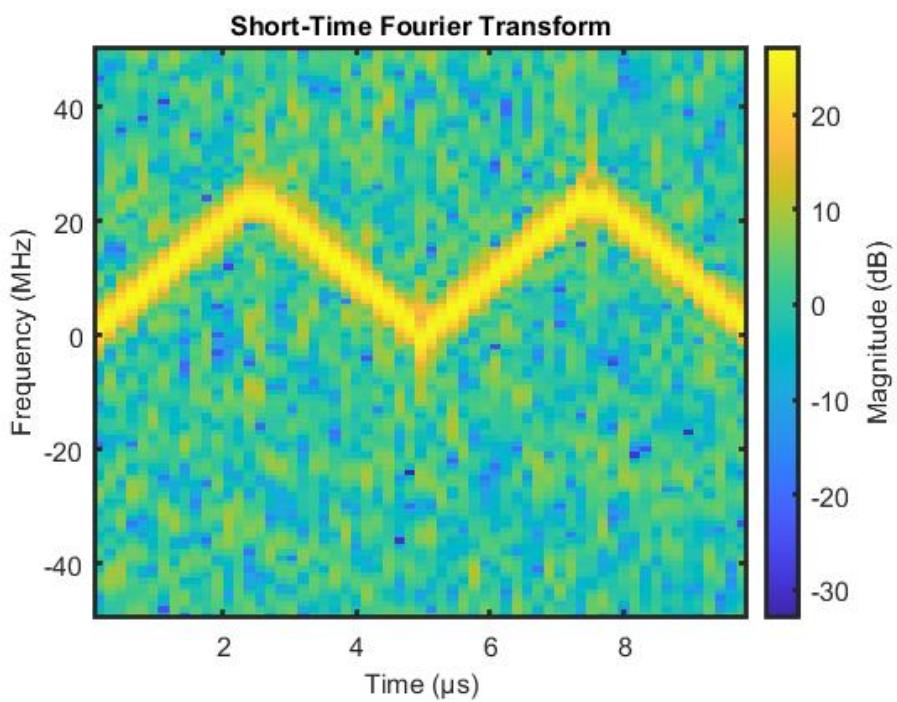
Şekil 3.7 Tek Ton İşaret STFT dönüşümü



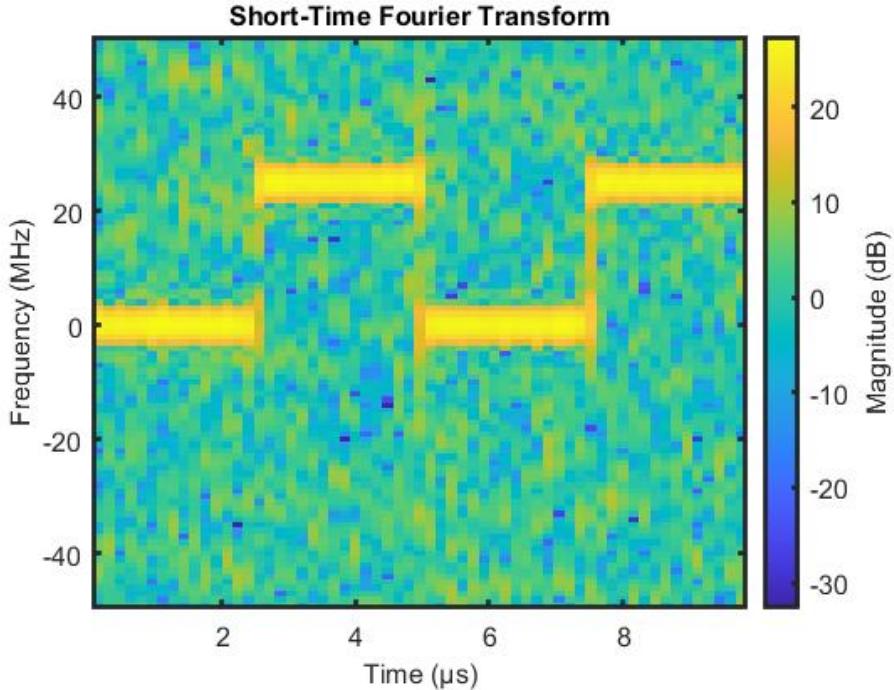
Şekil 3.8 Artan LFM STFT dönüşümü



Şekil 3.9 Azalan LFM STFT dönüşümü



Şekil 3.10 Üçgen LFM STFT dönüşümü



Şekil 3.11 Basamaklı FM STFT dönüşümü

3.1.2 Fourier Eşzamanlı Sıkıştırma Dönüşümü

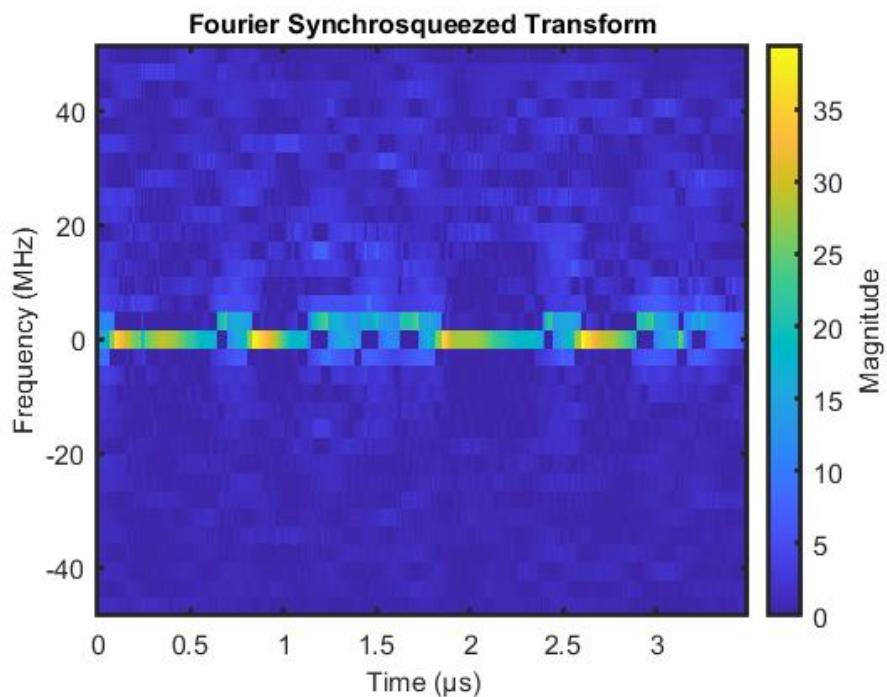
FSST (Fourier Synchrosqueezed Transform) çok bileşenli sinyallerin zaman-frekans dönüşümlerini elde etmek için kullanılan bir yöntemdir [3]. Sinyalleri zaman alanında lokalize ederek sinyalin frekans boyutundaki değişimlerini analiz eden bir yöntemdir. FSST frekans domeinde STFT katsayılarını üzerinde yeniden atama yaparak farklı sinyal çeşitleri arasında daha kolay ayırmak seyrek ve keskinleştirilmiş zaman-frekans imgeleri elde edilmektedir [4]. FSST STFT katsayılarını $(V_f(\eta, t))$, (η, t) 'den $(\omega_f(\eta, t), t)$ 'ye değiştirmektedir ve aşağıdaki gibi ifade edilmektedir.

$$T_f(\omega, t) = \frac{1}{g(0)} \int V_f(\eta, t) \delta(\omega - \omega_f(\eta, t)) d\eta \quad (3.2)$$

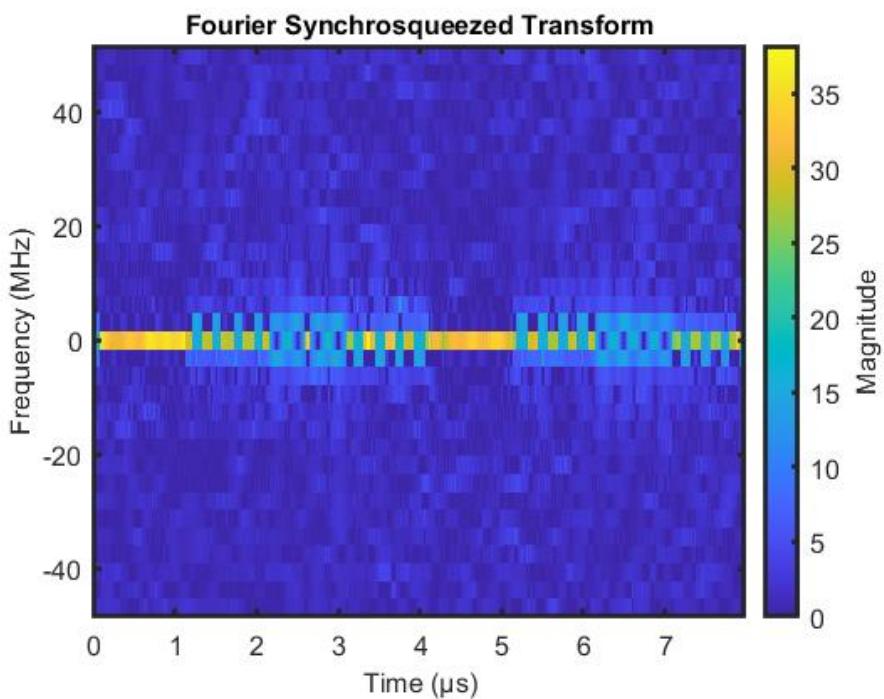
Eş. 3.2'de $g(0)$ ifadesi $g(t)$ kayan penceresinin $t = 0$ anındaki değeri, δ simbolü Dirac delta fonksiyonu ve $\omega_f(\eta, t)$ anlık frekans değerini ifade etmektedir (Eş. 3.3).

$$\omega_f(\eta, t) = \operatorname{Re} \left(\frac{1}{j2\pi V_f(\eta, t)} \frac{\partial V_f(\eta, t)}{\partial t} \right) \quad (3.3)$$

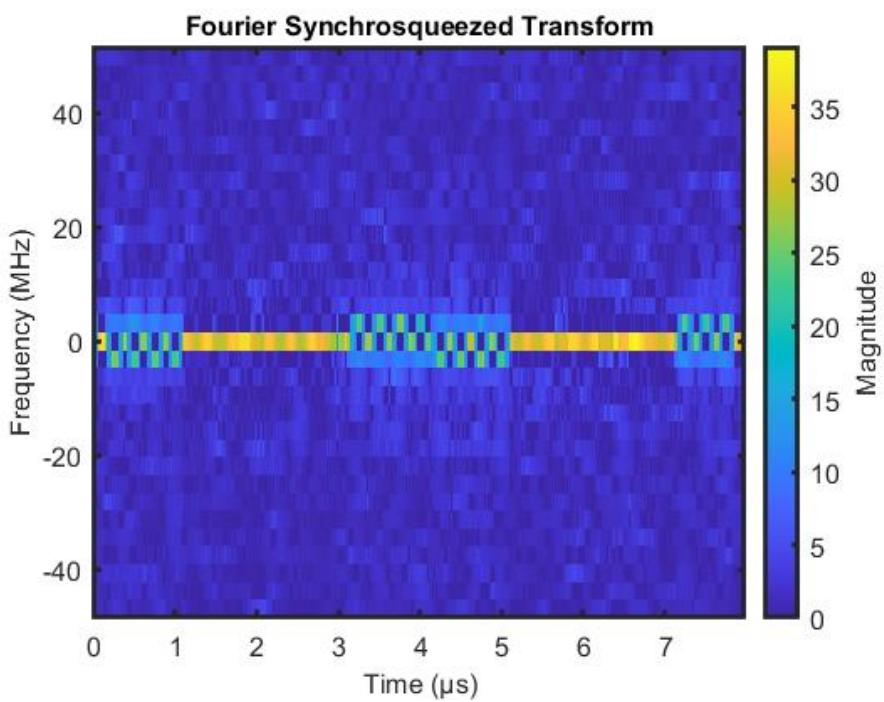
Bu çalışmada kullanılan işaretlerin FSST dönüşümleri 3.12 - 3.22 numaralı şekillerde verilmektedir.



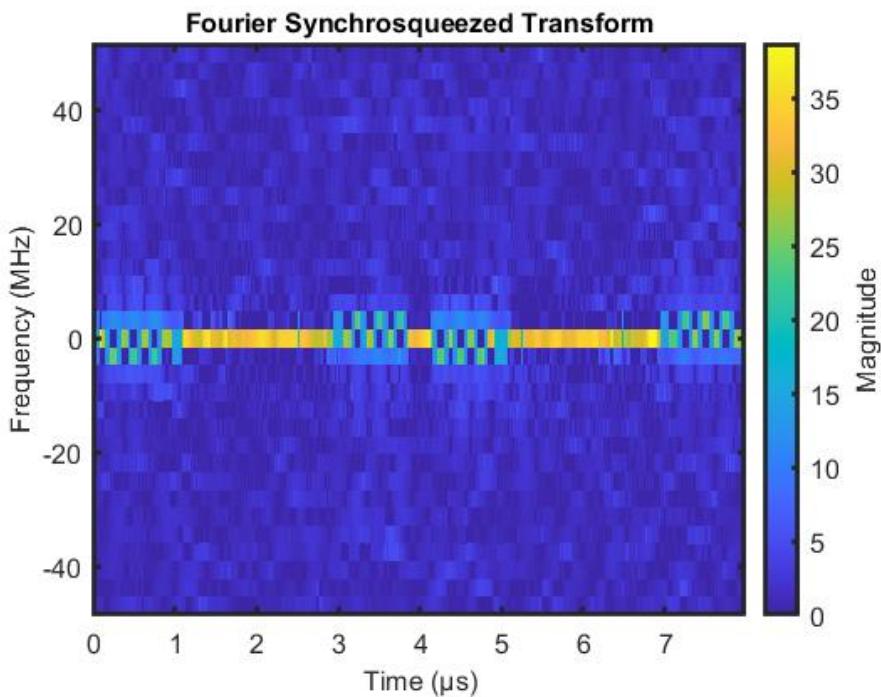
Şekil 3.12 Barker FSST dönüşümü



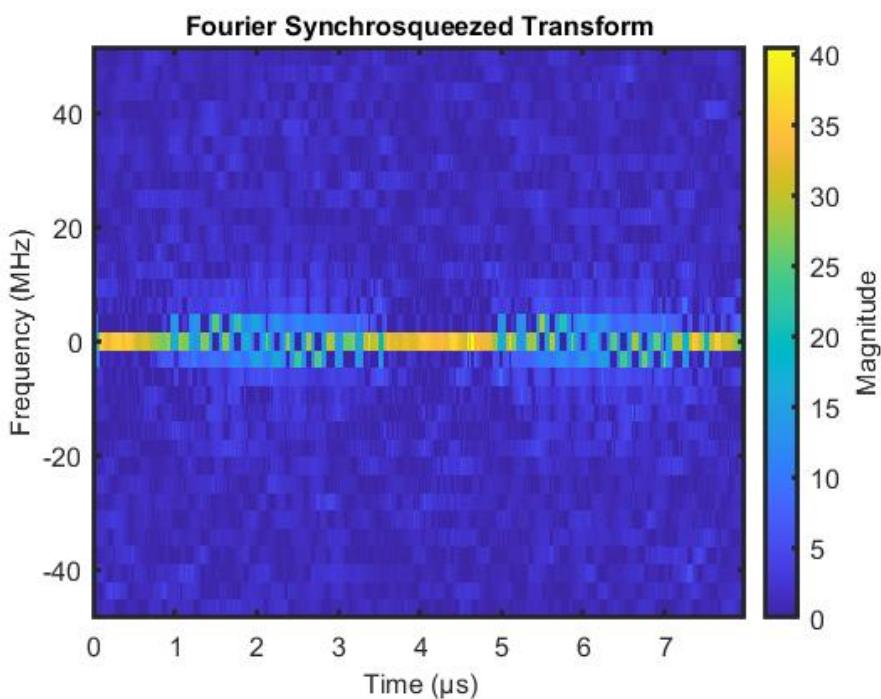
Şekil 3.13 Frank FSST dönüşümü



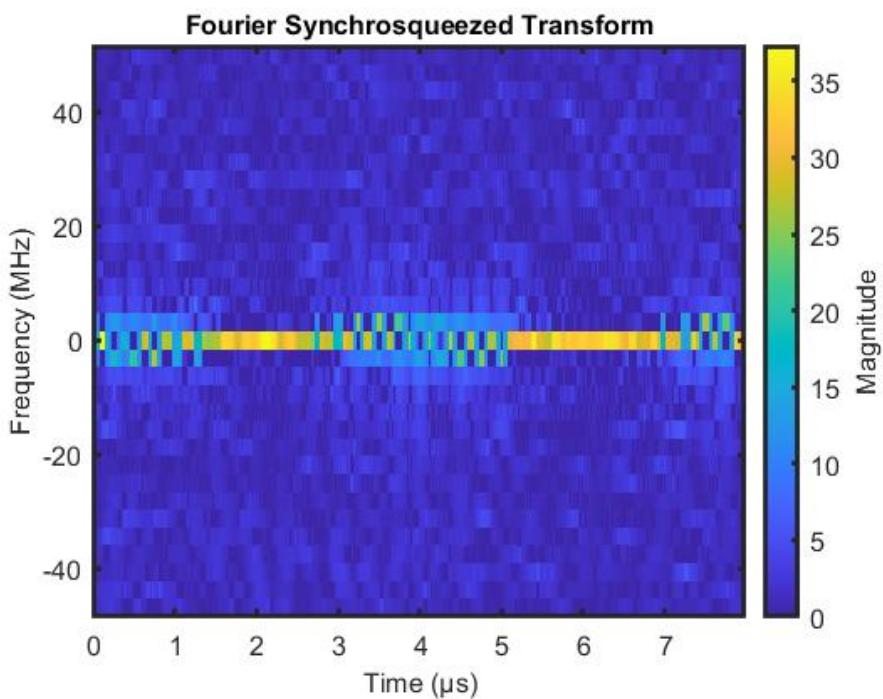
Şekil 3.14 P1 FSST dönüşümü



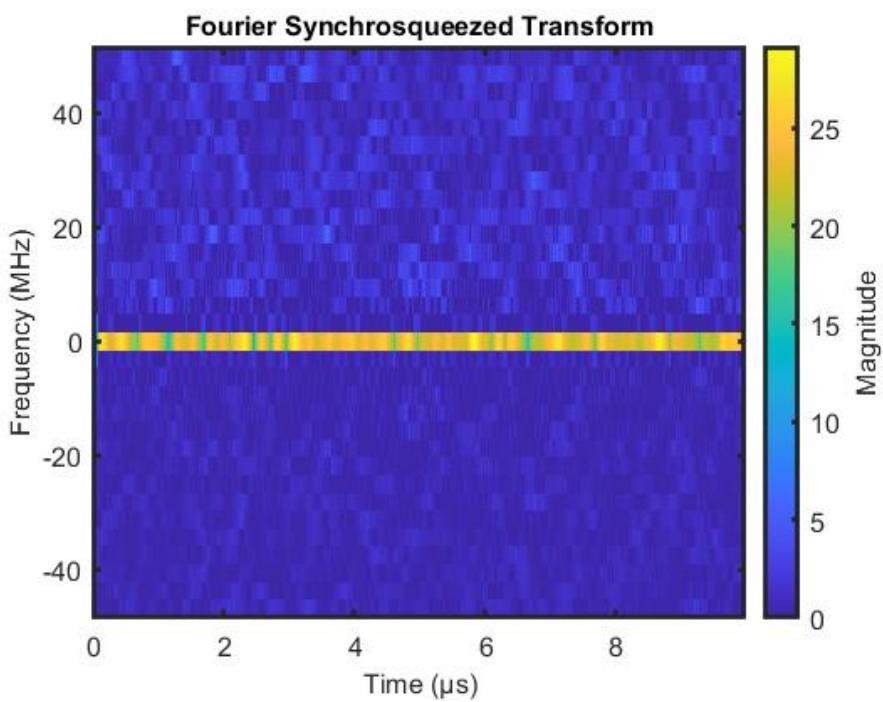
Şekil 3.15 P2 FSST dönüşümü



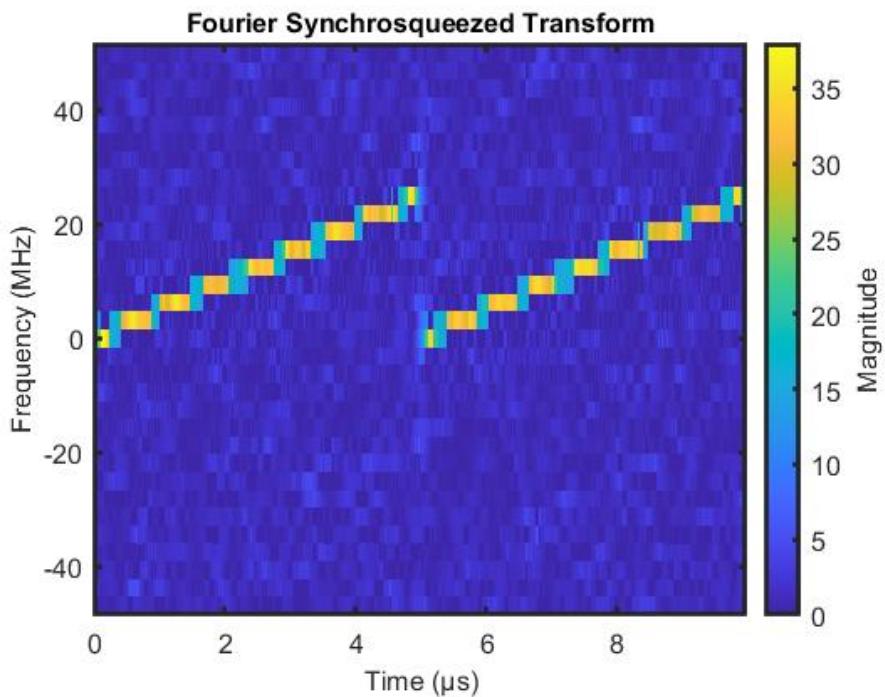
Şekil 3.16 P3 FSST dönüşümü



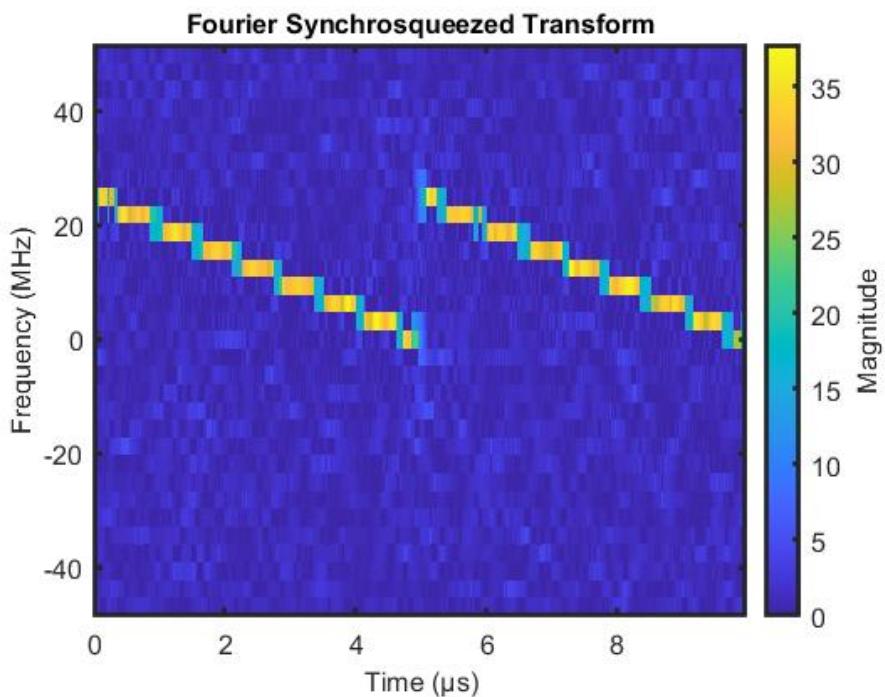
Şekil 3.17 P4 FSST dönüşümü



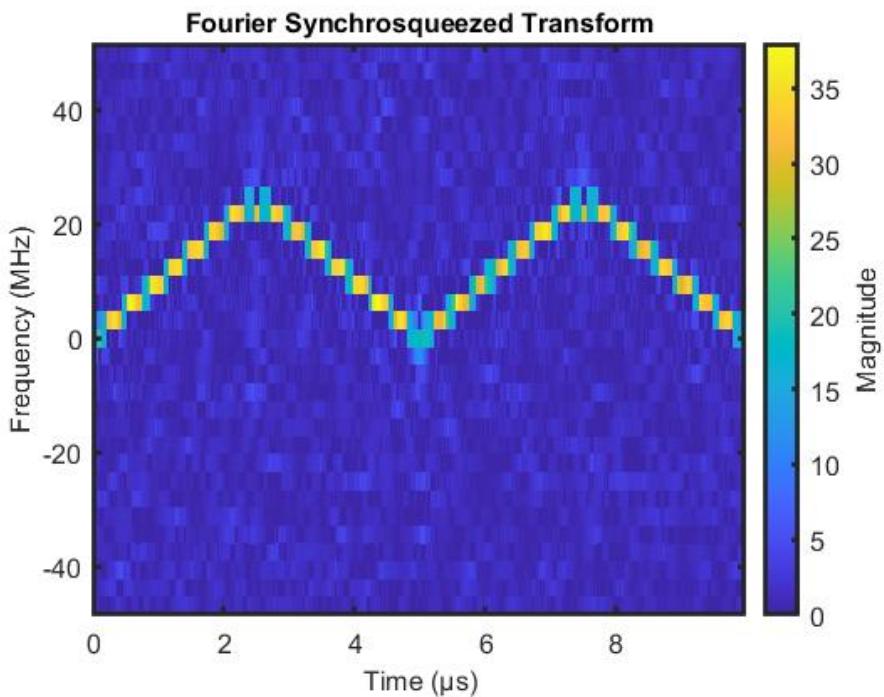
Şekil 3.18 Tek Ton İşaret FSST dönüşümü



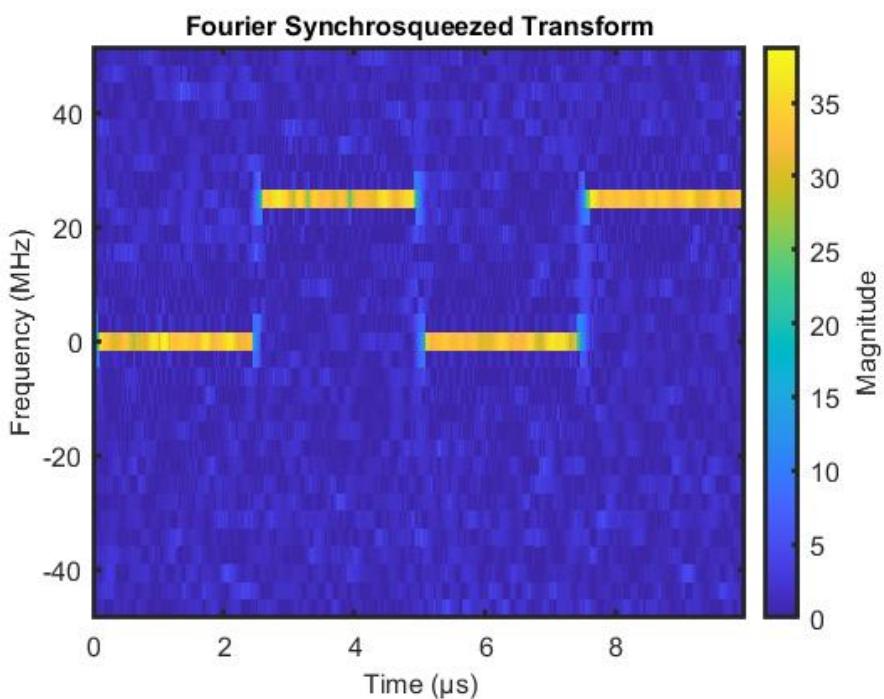
Şekil 3.19 Artan LFM FSST dönüşümü



Şekil 3.20 Azalan LFM FSST dönüşümü



Şekil 3.21 Üçgen LFM FSST dönüşümü



Şekil 3.22 Basamaklı FM FSST dönüşümü

3.1.3 Düzleştirilmiş Sözde Wigner-Ville Dağılımı

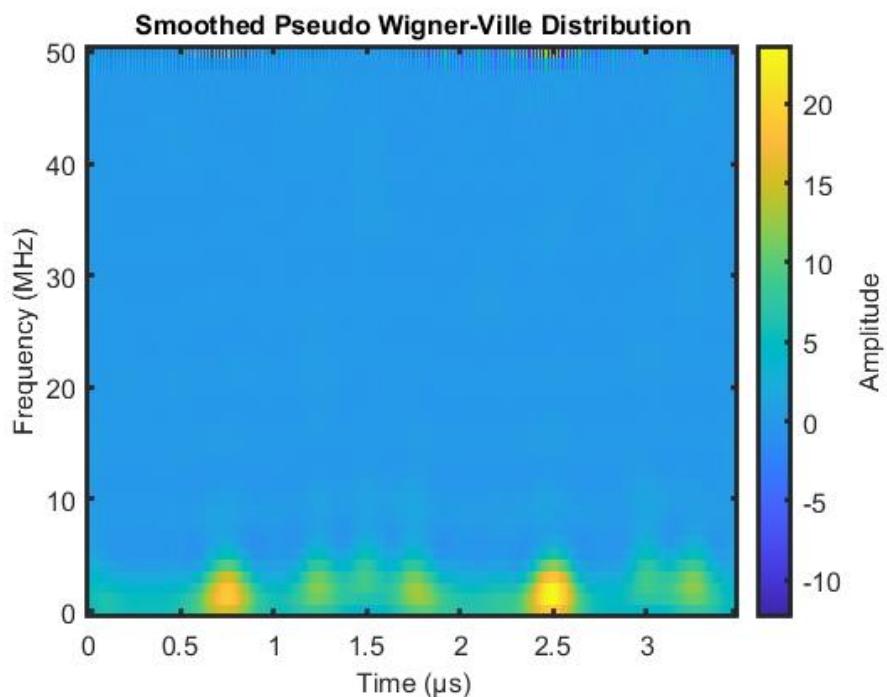
Girdi işaretinin, $x(t)$, Wigner-Ville dağılımı Eş. 3.4'teki gibi hesaplanmaktadır [5].

$$W_x(\omega, t) = \int_{-\infty}^{\infty} x(t + \frac{\tau}{2})x^*(t - \frac{\tau}{2})e^{-j\omega\tau} d\tau \quad (3.4)$$

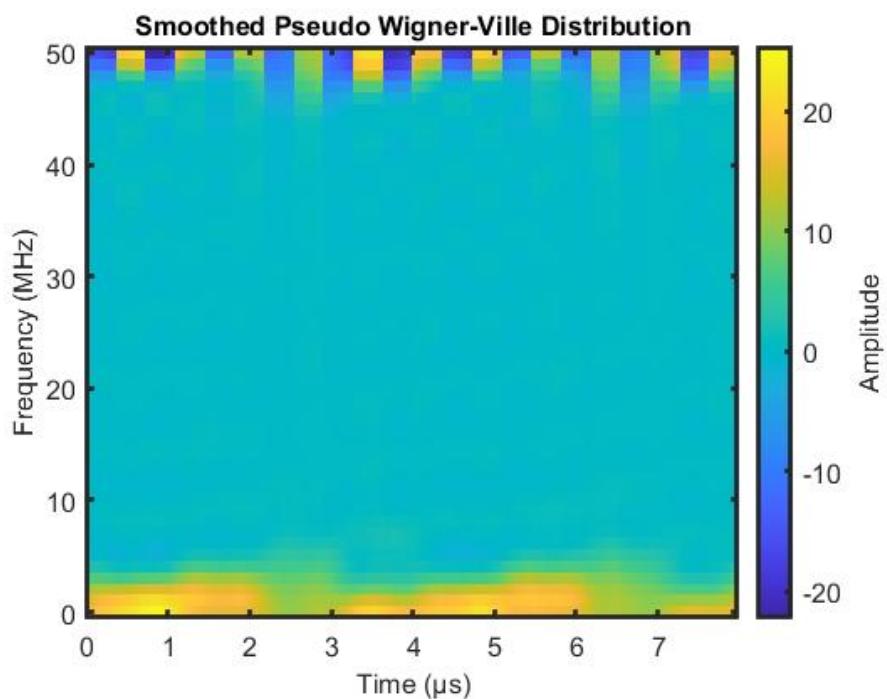
Eş. 3.4'te t zaman değişkenini, ω frekans değişkenini ifade etmektedir. WVD sonucunda oluşan zaman-frekans dönüşümleri çapraz terim girişimi içermektedir [6]. Çapraz terim girişimini azaltmak için WVD dönüşümü zaman ve frekans boyutlarında pencere fonksiyonları ile filtrelenerek Düzleştirilmiş Sözde Wigner-Ville Dağılımı (SPWVD) elde edilir [7]. İşaretlerin SPWVD dönüşümleri

$$W_x(\omega, t) = \int_{-\infty}^{\infty} g(t)H(f)x(t + \frac{\tau}{2})x^*(t - \frac{\tau}{2})e^{-j\omega\tau} d\tau \quad (3.5)$$

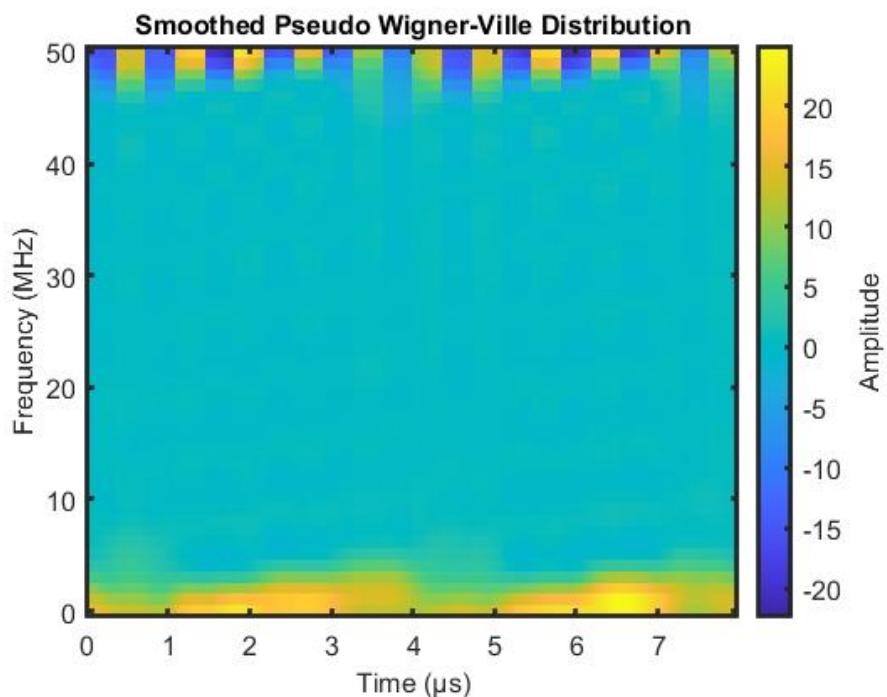
şeklinde hesaplanmaktadır. Eş. 3.5'te $g(t)$ ve $h(t)$ sırasıyla zaman ve frekans boyutu pencerelerini ifade etmektedir. Bu çalışmada kullanılan işaretlerin SPWVD dönüşümleri 3.23 - 3.33 numaralı şekillerde verilmektedir.



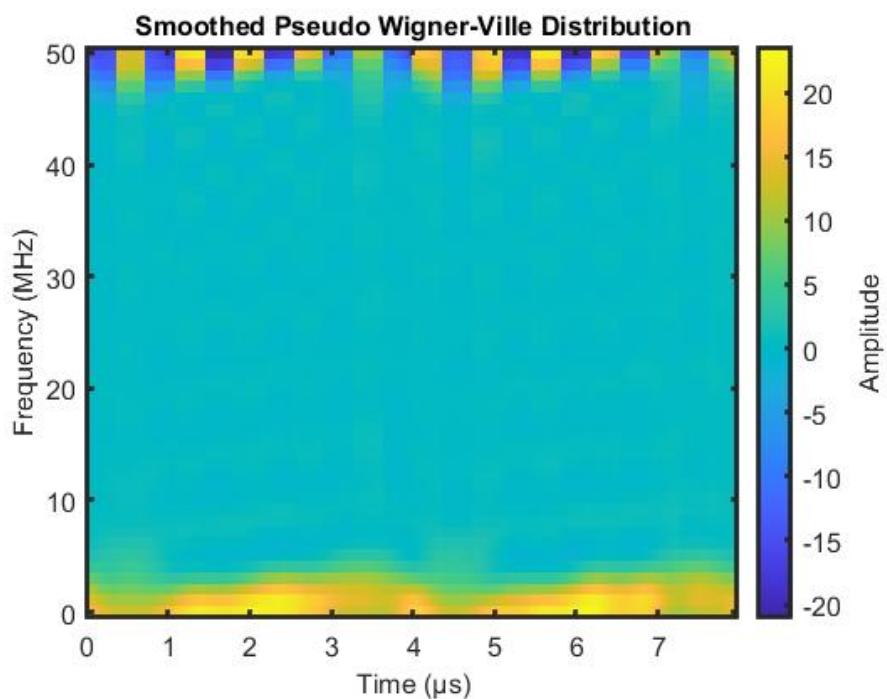
Şekil 3.23 Barker SPWVD dönüşümü



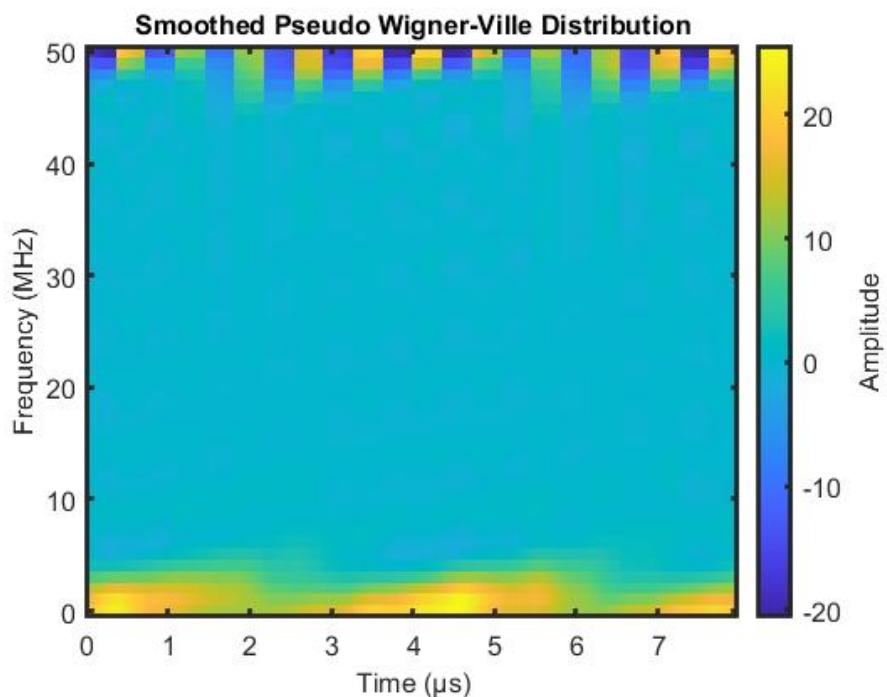
Şekil 3.24 Frank SPWVD dönüşümü



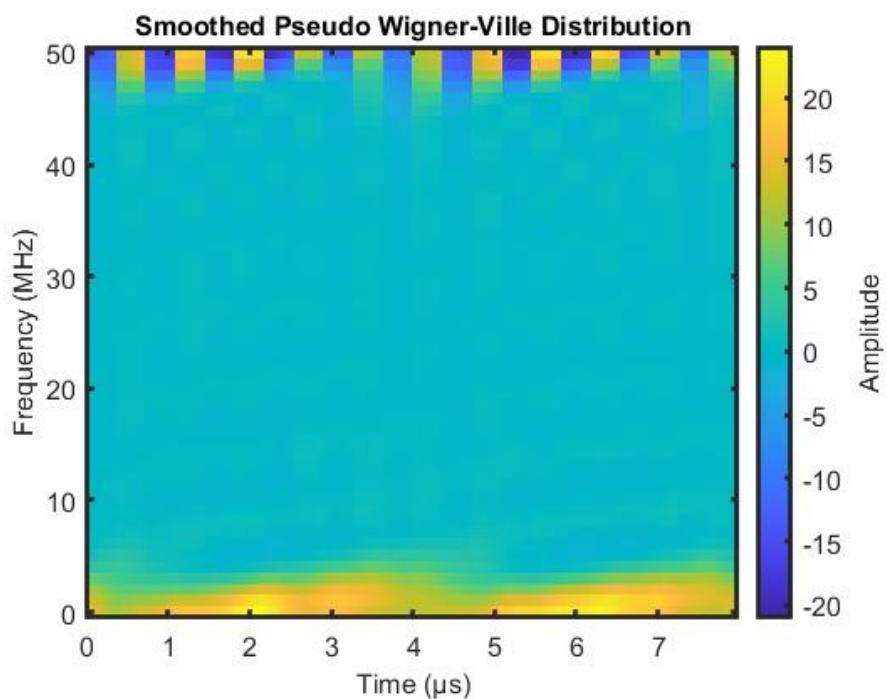
Şekil 3.25 P1 SPWVD dönüşümü



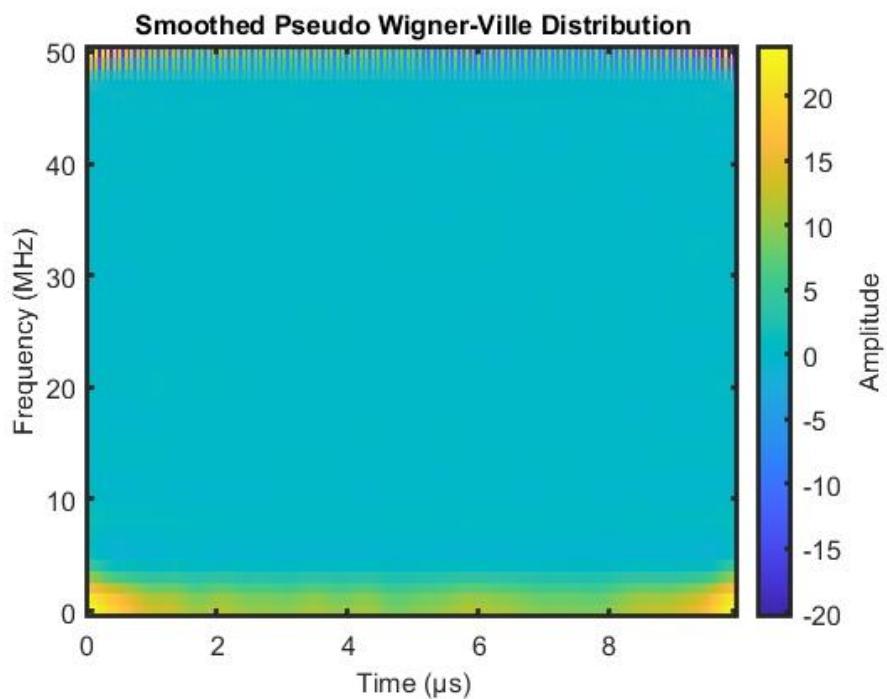
Şekil 3.26 P2 SPWVD dönüşümü



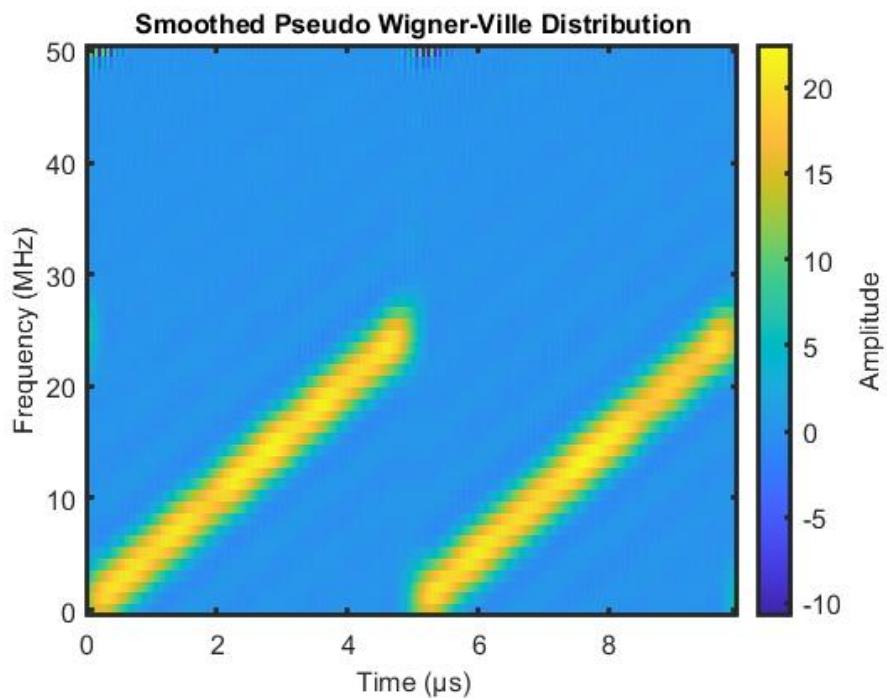
Şekil 3.27 P3 SPWVD dönüşümü



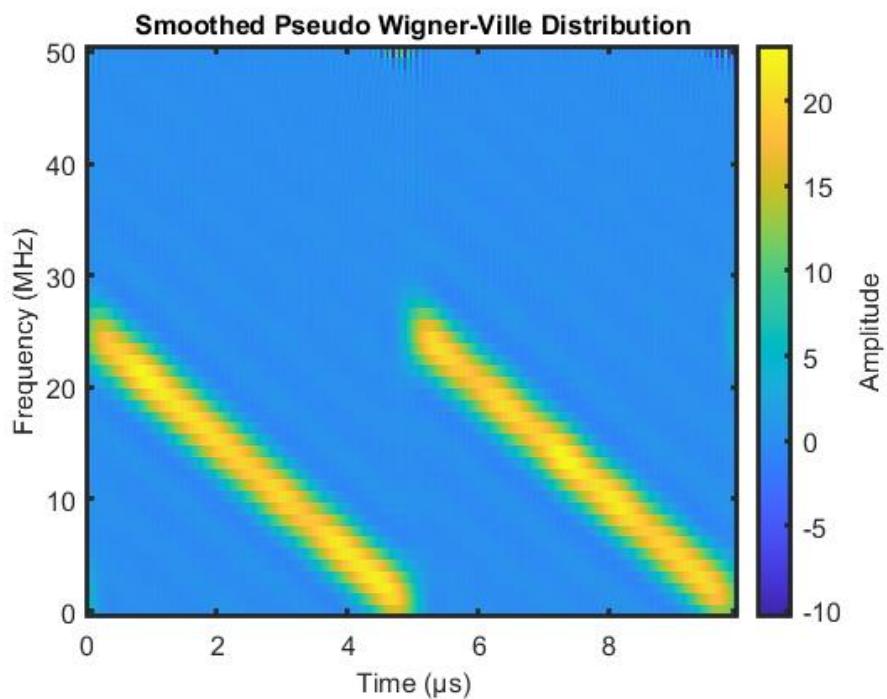
Şekil 3.28 P4 SPWVD dönüşümü



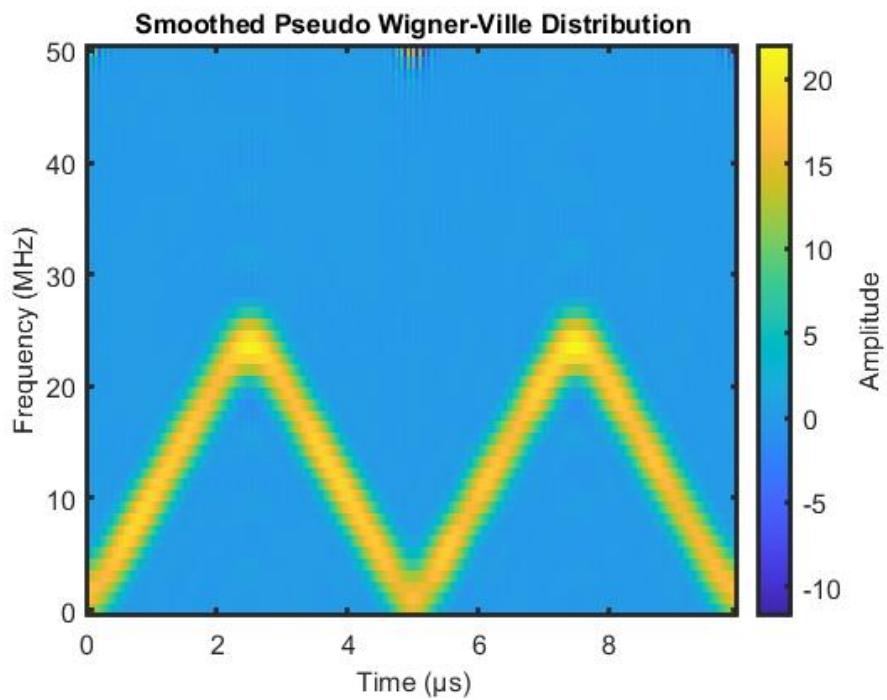
Şekil 3.29 Tek Ton İşaret SPWVD dönüşümü



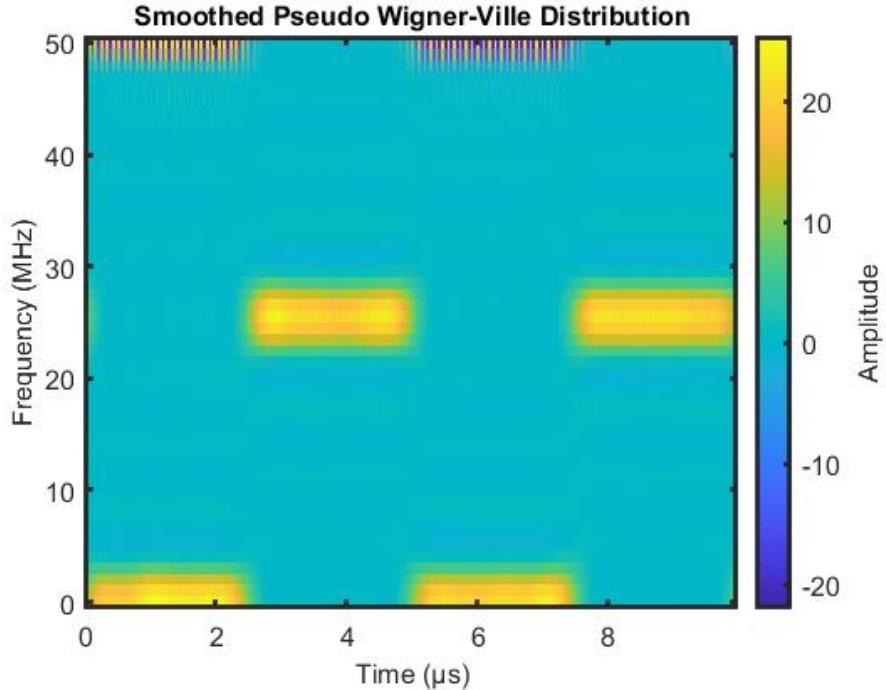
Şekil 3.30 Artan LFM SPWVD dönüşümü



Şekil 3.31 Azalan LFM SPWVD dönüşümü



Şekil 3.32 Üçgen LFM SPWVD dönüşümü



Şekil 3.33 Basamaklı FM SPWVD dönüşümü

3.1.4 Choi-Williams Dağılımı

Cohen sınıfı Zaman-frekans dönüşümleri için genel ifade

$$C_f(t, w, \phi) = \frac{1}{2\pi} \int \int \int e^{j(\xi\mu - \tau\omega - \xi t)} \phi(\xi, \tau) x(\mu + \frac{\tau}{2}) x^*(\mu - \frac{\tau}{2}) d\mu d\tau d\xi \quad (3.6)$$

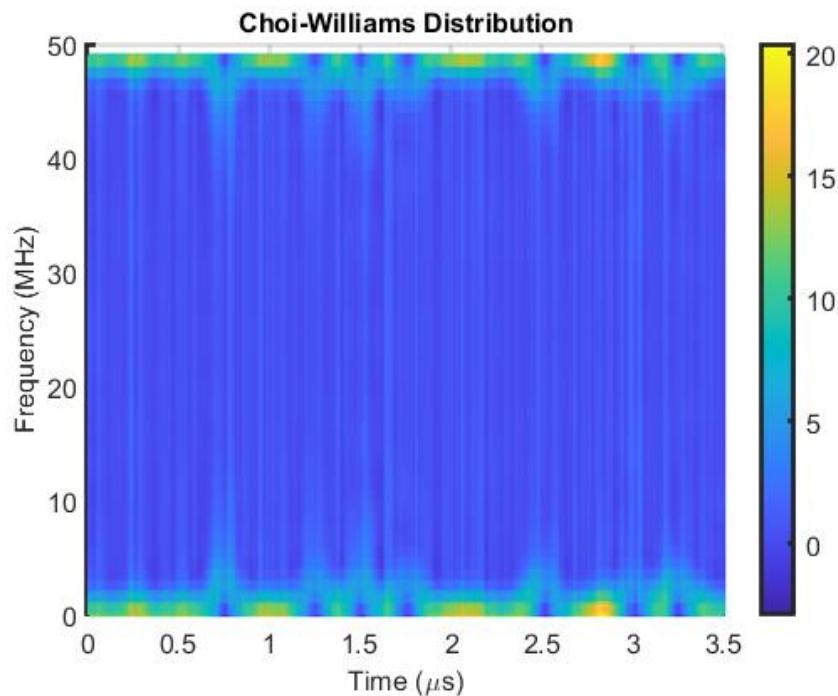
şeklinde yazılmaktadır [1]. $x(\mu)$ zaman boyutu işaretini, $\phi(\xi, \tau)$ çekirdek fonksiyonunu göstermektedir. WVD dönüşümünde çekirdek fonksiyonu $\phi(\xi, \tau) = 1$ olarak yazılmaktadır [5]. WVD dönüşümünde meydana gelen çapraz terim girişimini en küçültmek için CWD'de üstel çekirdek fonksiyonu kullanılmaktadır [8]. CWD çekirdek fonksiyonu Eş. 3.7'de yer almaktadır.

$$\phi(\xi, \tau) = e^{\frac{-\xi^2 \tau^2}{\sigma}} \quad (3.7)$$

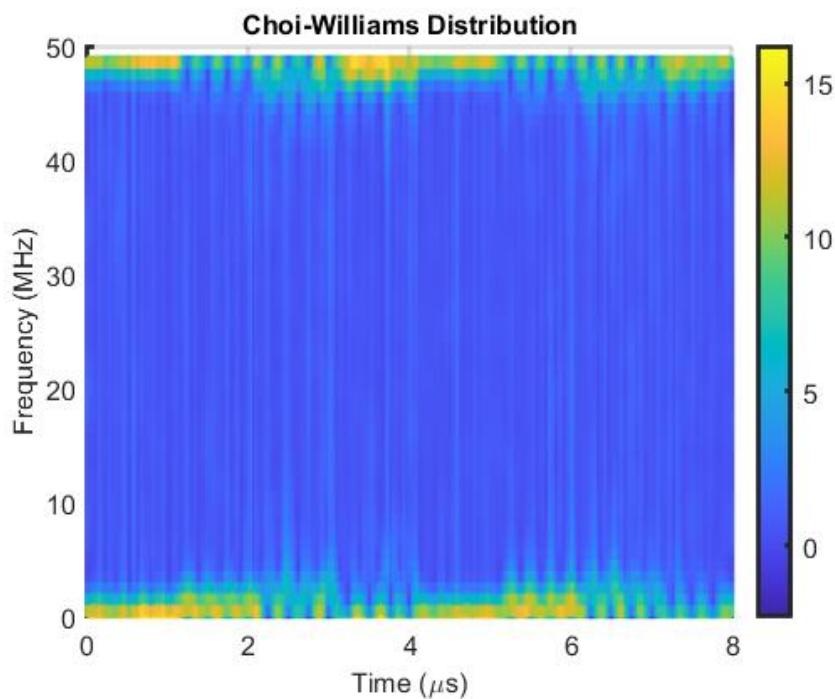
Eş. 3.7'de σ ölçeklendirme faktörüdür. Çekirdek fonksiyonu Eş. 3.6'da yerine yazılarak $x(t)$ işaretinin CWD'si

$$CWD_x(t, w) = \int_{\tau=-\infty}^{\infty} e^{-j\omega t} \left[\int_{\mu=-\infty}^{\infty} \sqrt{\frac{\sigma}{4\pi \tau^2}} e^{\frac{\sigma(\mu-t)^2}{4\tau^2} x(\mu + \frac{\tau}{2})x^*(\mu - \frac{\tau}{2})} d\mu \right] d\tau \quad (3.8)$$

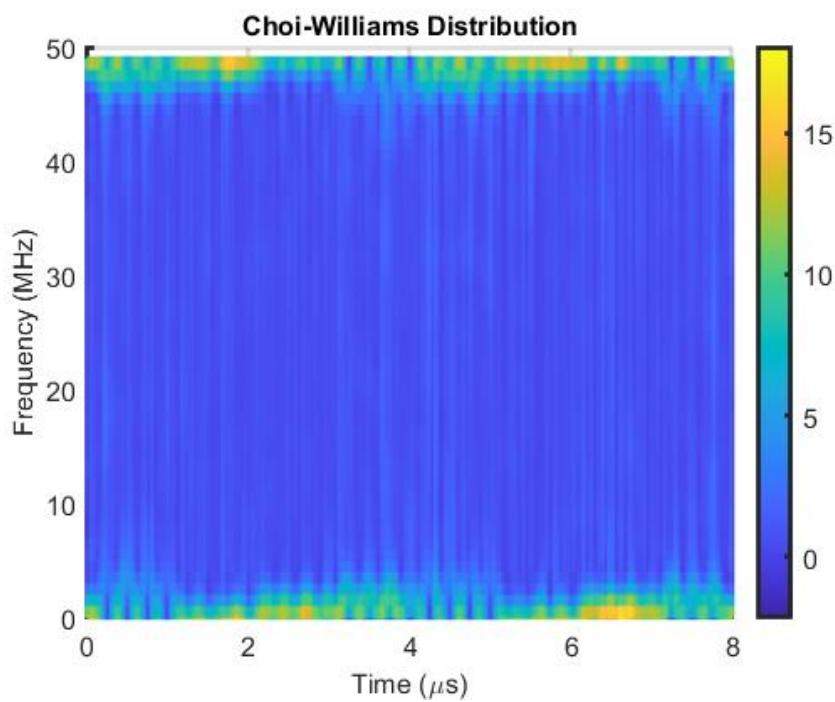
olarak yazılmaktadır [1]. Bu çalışmada kullanılan işaretlerin Choi-Williams zaman-frekans imgeleri 3.34 - 3.44 numaralı şekillerde verilmektedir.



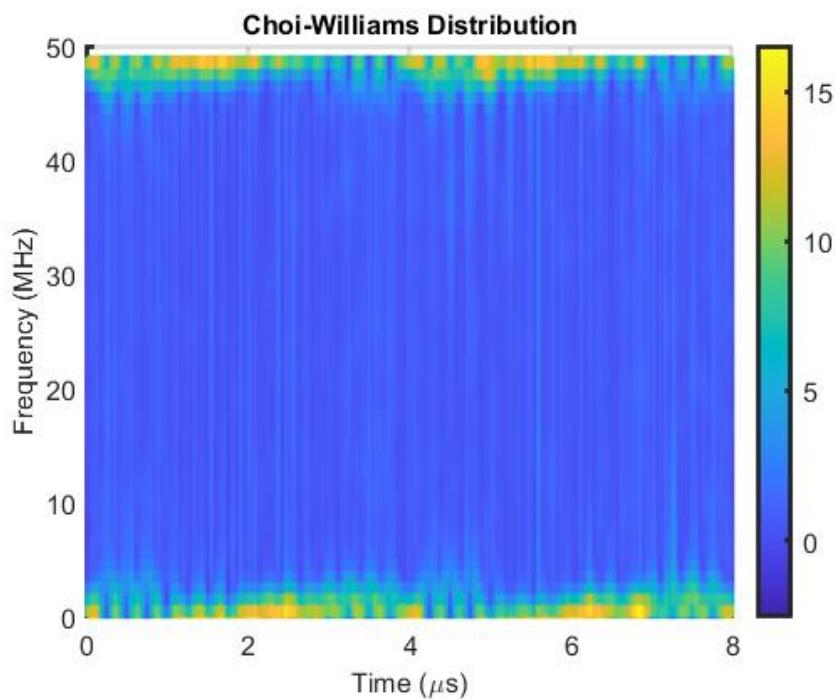
Şekil 3.34 Barker CW dönüşümü



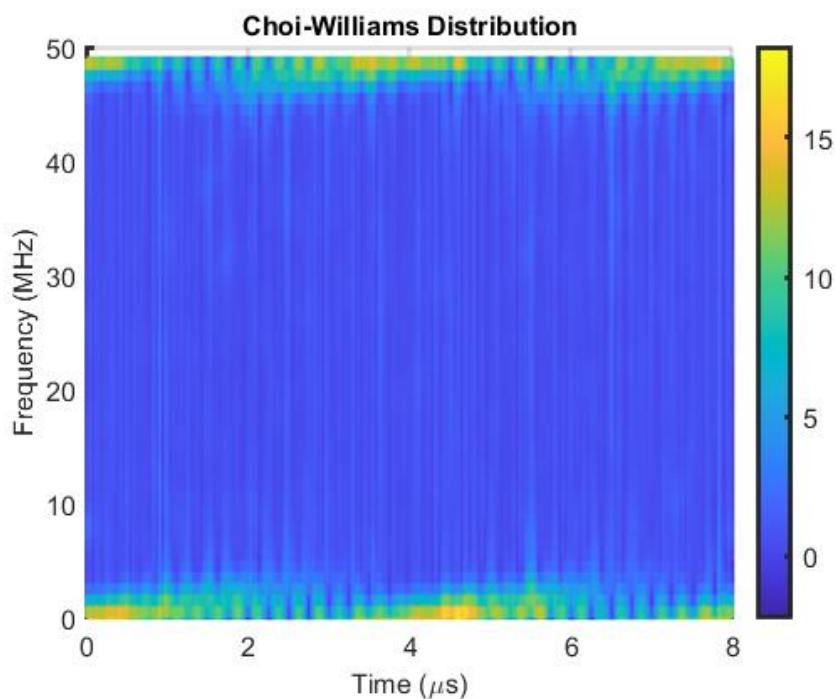
Şekil 3.35 Frank CW dönüşümü



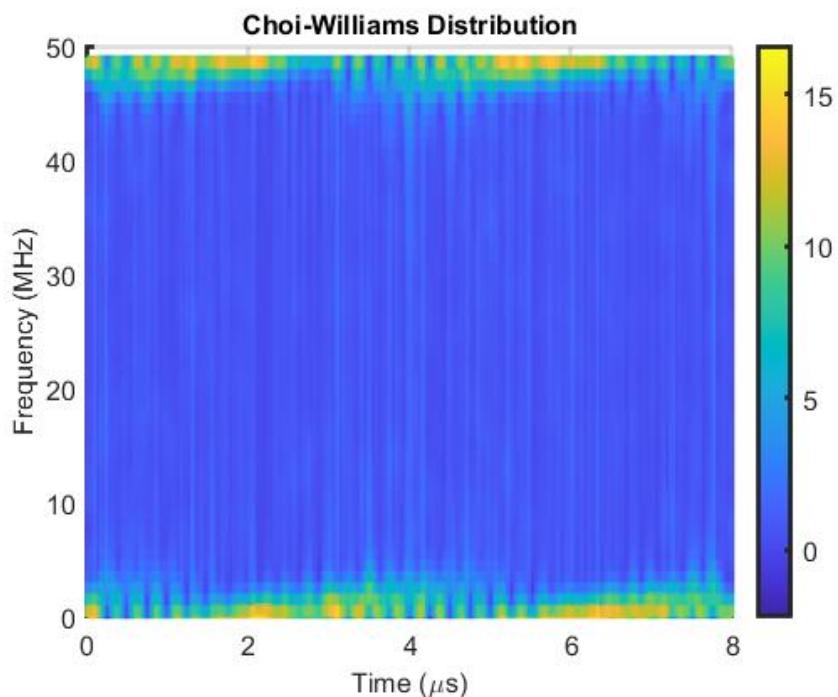
Şekil 3.36 P1 CW dönüşümü



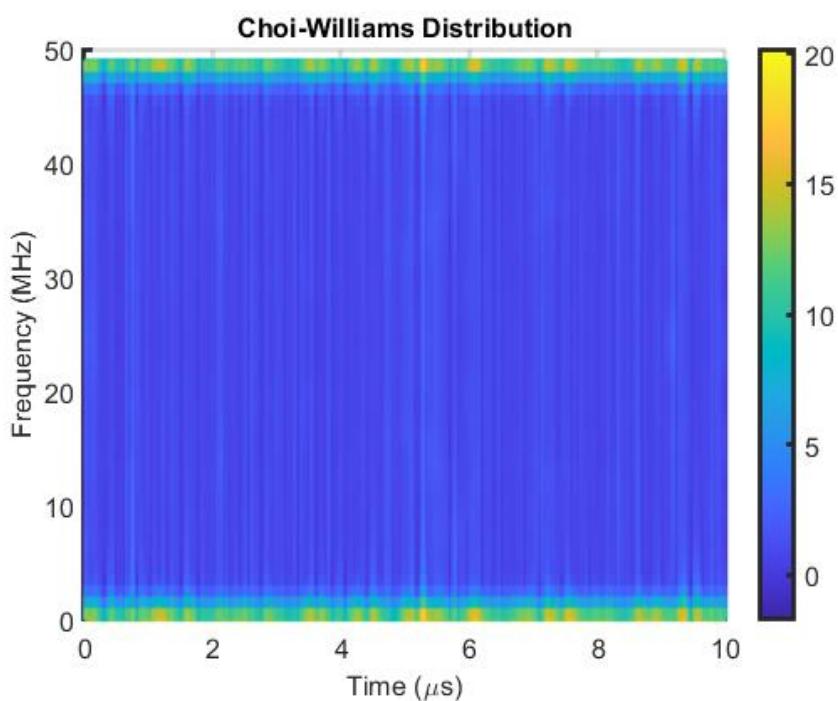
Şekil 3.37 P2 CW dönüşümü



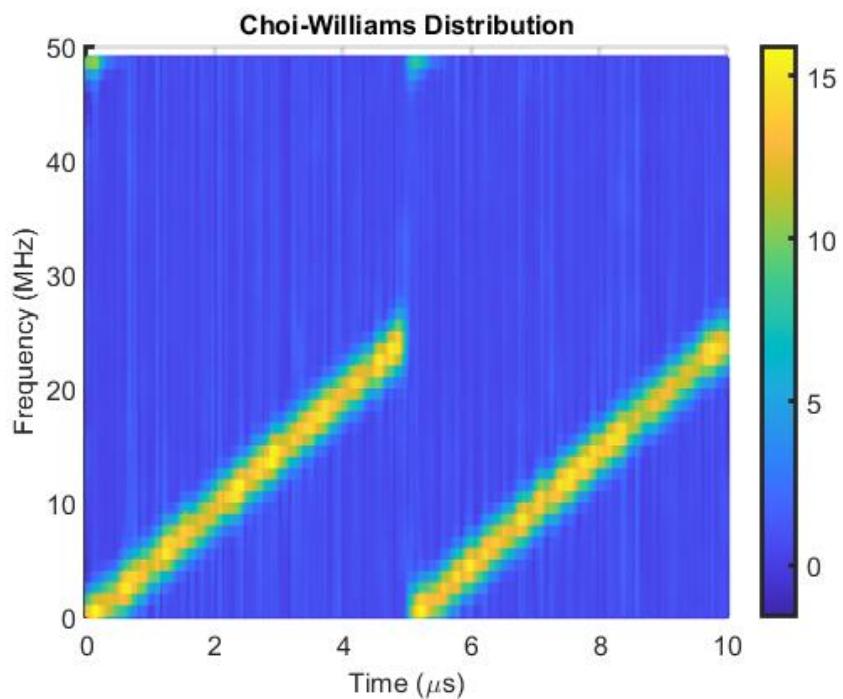
Şekil 3.38 P3 CW dönüşümü



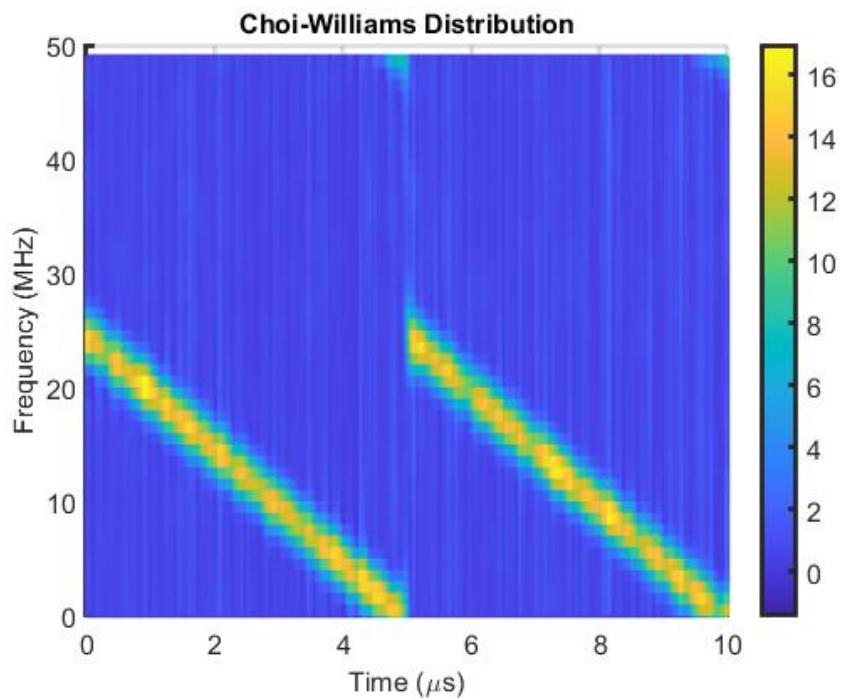
Şekil 3.39 P4 CW dönüşümü



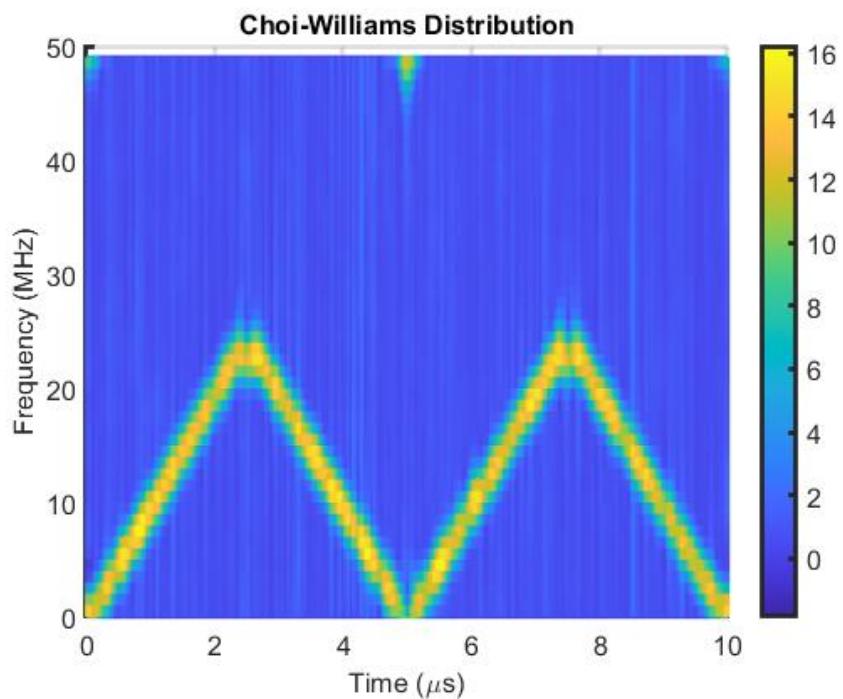
Şekil 3.40 Tek Ton İşaret CW dönüşümü



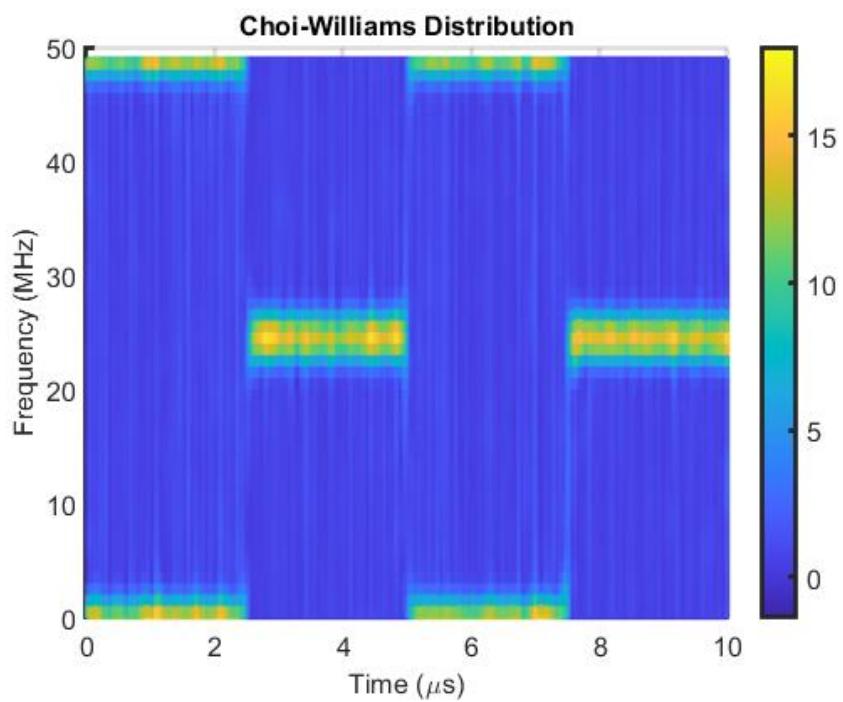
Şekil 3.41 Artan LFM CW dönüşümü



Şekil 3.42 Azalan LFM CW dönüşümü



Şekil 3.43 Üçgen LFM CW dönüşümü



Şekil 3.44 Basamaklı FM CW dönüşümü

3.1.5 Çevrimsel Durağan Sinyal Analizi

Çevrimsel durağan sinyal analizi sinyallerin içerisinde yer alan gizli periyodikleri ortaya çıkaran bir işaret işleme yöntemidir [9]. Sinyallerin içerisindeki gizli periyodikler taşıyıcı frekansı, bant genişliği ve kod oranı gibi parametreler açısından radar işaretleri için ayırt edici birer öznitelik ortaya çıkarmaktadır ve çevrimsel durağan işaret analizi ile bu periyodiklikler ortaya çıkarılmaktadır. İşaretlerin çevrimsel durağan özellikleri Çevrimsel Özilişki Fonksiyonu (Cyclic Autocorrelation Function, CAF) kullanılarak tanımlanabilmektedir. İkinci dereceden çevrimsel durağanlığı elde etmek için alınan işaret doğrusal olmayan dönüşüm uygulanarak özilişki fonksiyonu elde edilir.

$$R_x(\tau) = E[x(t + \frac{\tau}{2})x^*(t - \frac{\tau}{2})] \quad (3.9)$$

İkinci dereceden çevrimsel durağan sinyalin özilişki fonksiyonunun T zamanında periyodik olduğu bilinmektedir [10]. Özilişki fonksiyonunun Fourier serisi katsayıları

$$R_x^\alpha(\tau) = \lim_{T \rightarrow \infty} \frac{1}{T} \int_{-T/2}^{T/2} x(t)x^*(t - \tau)e^{-j2\pi\alpha t} dt \quad (3.10)$$

şeklindedir. Eş. 3.10'da $R_x(\tau)$ çevrimsel özilişki fonksiyonunu, α çevrimSEL frekans değerini göstermektedir. Sadece zaman bölgesinde çeşitli işaret analizleri yapmak tam anlamıyla sonuç vermeyebilir. Frekans bölgesinde de işaretlerin özelliklerini çıkarmak mümkündür. Kimi durumlar CAF yerine CAF'ın Fourier dönüşümü olan Spektral Korelasyon Fonksiyonu (Spectral Correlation Function, SCF) kullanılması daha uygundur. Güç spektral yoğunluğu ve özilişki fonksiyonu arasındaki bağlantıyı gösteren çevrimsel Wiener ilişkisi kullanılarak SCF fonksiyonu CAF'ın Fourier dönüşümü olarak yazılabilir [11].

$$S_x^\alpha(f) = \int_{-\infty}^{\infty} R_x^\alpha(\tau) e^{-i2\pi f\tau} d\tau \quad (3.11)$$

Eş. 3.11'de $S_x^\alpha(f)$ SCF'yi göstermektedir. $S_x^0(f)$ alınan işaretin güç spektral yoğunluğununa (Power Spectral Density, PSD) eşittir. Çevrimisel durağan karakter gösteren özniteliklerin çıkarılması yüksek hesaplama maliyeti gerektiren SCF fonksiyonu aracılığı ile gerçekleştirilir. SCF fonksiyonunu daha düşük hesaplama karmaşıklığı ile elde etmek için temelde iki yöntem önerilir: Zamanda Düzleştirme ve Frekansta Düzleştirme. [12]'de Zamanda Düzleştirme tabanlı ve çoklu işlemcilerle birlikte çalışmaya uyumlu olarak tasarlanan FFT Biriktirme Yöntemi (FFT Accumulation Method, FAM) ve Şerit Spektral Korelasyon Algoritması (Strip Spectral Correlation Algorithm, SSCA) yöntemleri verilmektedir. Bu çalışmada SCF fonksiyonunun hesaplanması için FAM kullanılmıştır.

FAM yöntemi SCF fonksiyonunu hesaplarken Eş. (3.12-3.15) kullanmaktadır.

$$S_{X_T}^{\alpha_i+q\Delta\alpha}(rL, f_j) = \sum_r X_T(rL, f_k) X_T^*(rL, f_l) g_c(n-r) e^{-j2\pi r q/P} \quad (3.12)$$

Eş. 3.12'de $S_{X_T}^{\alpha_i+q\Delta\alpha}$ SCF kestirimini, α_i çevrimisel frekansı değerini, f_j spektral frekansı, $X_T(rL, f_k)$ karmaşık demodülasyonu, $g_c(n)$ birim yükseklikli dikdörtgen pencereyi ifade etmektedir.

$$\alpha_i = f_k - f_l \quad (3.13)$$

$$f_j = \frac{(f_k + f_l)}{2} \quad (3.14)$$

$$X_T(n, f) = \sum_{r=-N'/2}^{N'/2} a(r) x(n-r) e^{-i2\pi f(n-r)T_s} \quad (3.15)$$

Eş. 3.15'te $a(r)$ Hamming penceresidir. FAM yönteminin adımları aşağıdaki gibidir.

- ***M* noktalı *L* örnek atlamalı data alt blokları**

Bu adımda alınan N uzunluklu işaret, her bir adımda L kadar kaydırılarak N' örnekli

P tane alt bloğa ayrılır. Burada $P = N/L$ olarak hesaplanır. $N' \times P$ boyutlu matris oluşturulur.

$$\begin{bmatrix} x(1) & x(L+1) & x(2L+1) & \cdots & x((P-1)L+1) \\ x(2) & x(L+2) & x(2L+2) & \cdots & x((P-1)L+2) \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ x(N') & x(L+N') & x(2L+N') & \cdots & x((P-1)L+N') \end{bmatrix}_{N' \times P} \quad (3.16)$$

- **Hamming Pencereleme**

Birinci adımda oluşturulan matrisin her bir sütunu Hamming penceresinden geçirilir. Hamming penceresinden geçirilen matris, işaret matrisinin her bir sütunu Hamming vektörü ile çarpılarak elde edilir.

$$\begin{bmatrix} h(1)x(1) & h(1)x(L+1) & h(1)x(2L+1) & \cdots & h(1)x((P-1)L+1) \\ h(2)x(2) & h(2)x(L+2) & h(2)x(2L+2) & \cdots & h(2)x((P-1)L+2) \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ h(N')x(N') & h(N')x(L+N') & h(N')x(2L+N') & \cdots & h(N')x((P-1)L+N') \end{bmatrix}_{N' \times P} \quad (3.17)$$

- **Zamanda Düzleştirme**

Hamming pencerelenmiş matrisin her sütünuna Fourier dönüşümü uygulanarak Zamanda Düzleştirme gerçekleştirilir.

$$\begin{bmatrix} X_{N'}(0, f_1) & X_{N'}(L, f_1) & X_{N'}(2L, f_1) & \cdots & X_{N'}((P-1)L, f_1) \\ X_{N'}(0, f_2) & X_{N'}(L, f_2) & X_{N'}(2L, f_2) & \cdots & X_{N'}((P-1)L, f_2) \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ X_{N'}(0, f_{N'}) & X_{N'}(L, f_{N'}) & X_{N'}(2L, f_{N'}) & \cdots & X_{N'}((P-1)L, f_{N'}) \end{bmatrix}_{N' \times P} \quad (3.18)$$

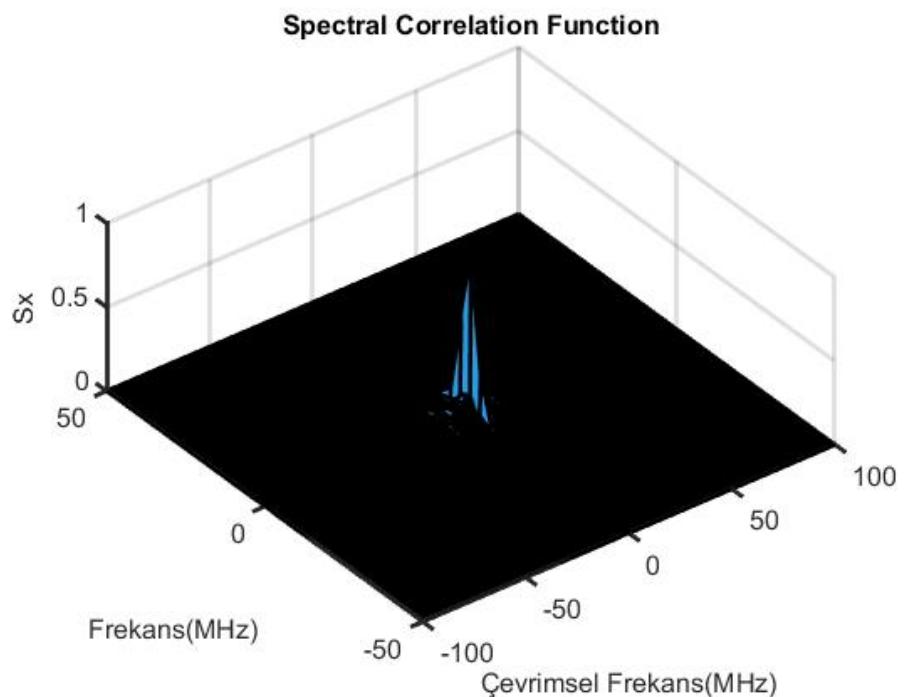
- **Üstel Çarpım ve Kanal Açma**

Birinci adımda işaret örneklerinin L kadar kaydırılmasından dolayı faz farkları oluşmaktadır. MATLAB programı fft.m fonksiyonu üçüncü adımda uygulanırken her bir sütunun zamanda 0 anından başladığını varsaymaktadır [13]. Bu nedenle faz ilişkisi kaybolmaktadır. Kaybolan faz bilgisini geri elde etmek için üstel çarpım gerçekleştirilir. Bu aşamadan sonra X_T elde edilir. 3.12 numaralı denklemde verildiği üzere kompleks çarpım yapılarak $N'^2 \times P$ boyutlu SCF matrisi elde edilir.

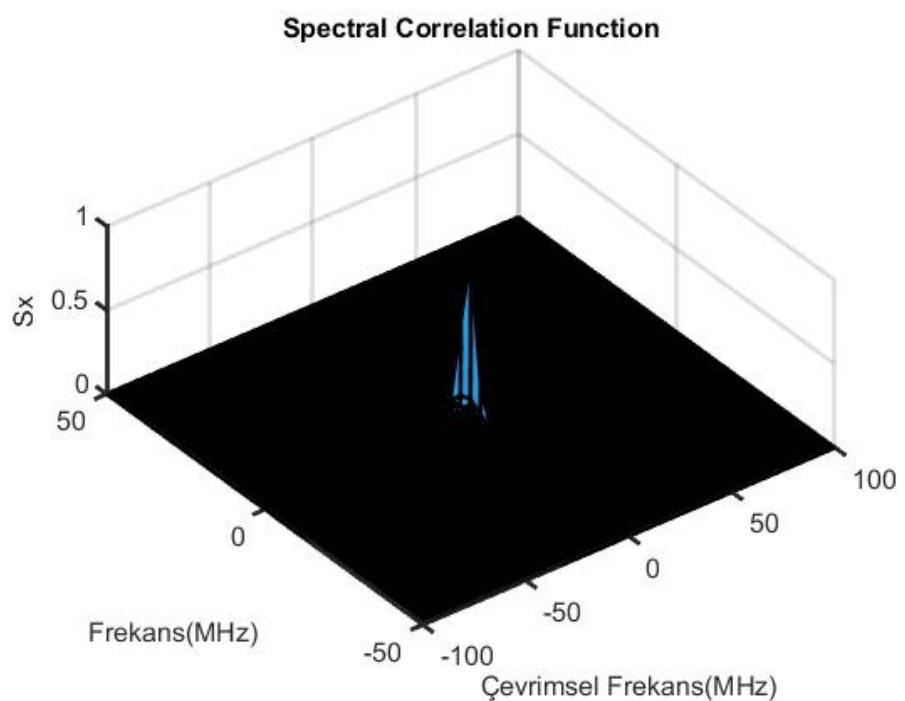
- **İkili Frekans Bölgesine Eşleme**

$N'^2 \times P$ boyutlu SCF matrisinin frekans ve çevrimsel frekans bölgesine ($f \times \alpha$) eşlennesi gerekmektedir. Eşleme sonucunda $(N' + 1) \times (2N + 1)$ boyutlu matris elde edilir. Matrisin satırları düzgelenmiş frekans bölgesini gösterirken sütunları düzgelenmiş çevrimsel frekans bölgesine karşılık gelmektedir. Bu adımda elde edilen normalize frekans değerleri almacın örnekleme frekansı ile çarpıldığında işaretin eşsiz özniteliklerini barındıran frekanslara karşılık gelmektedir. Bu öznitelikler kullanılarak işaretler hakkında bilgi elde edilebilir.

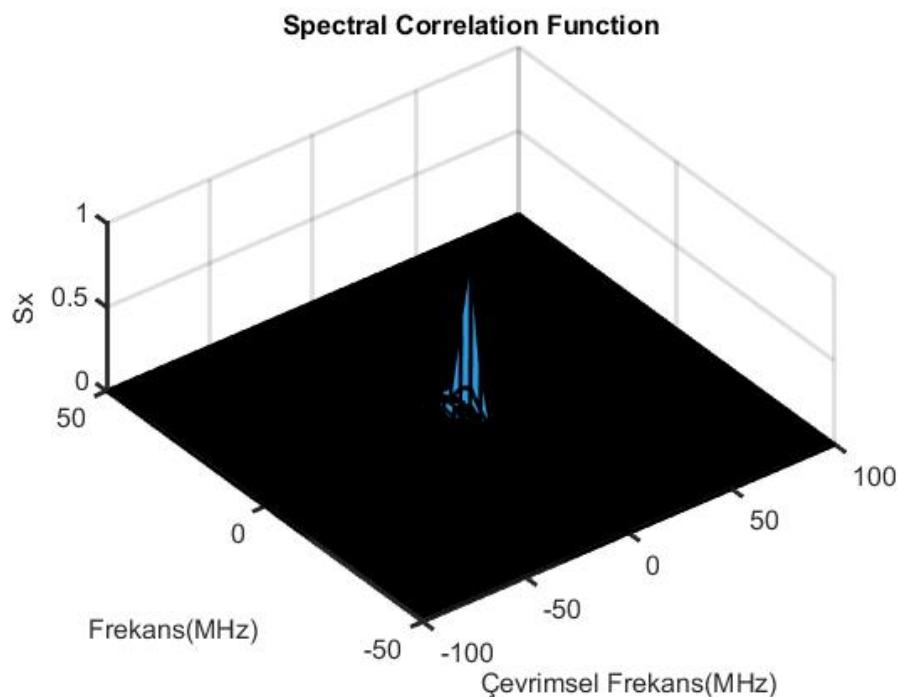
Bu çalışmada kullanılan işaretlerin SCF imgeleri 3.45 - 3.55 numaralı şekillerde verilmektedir.



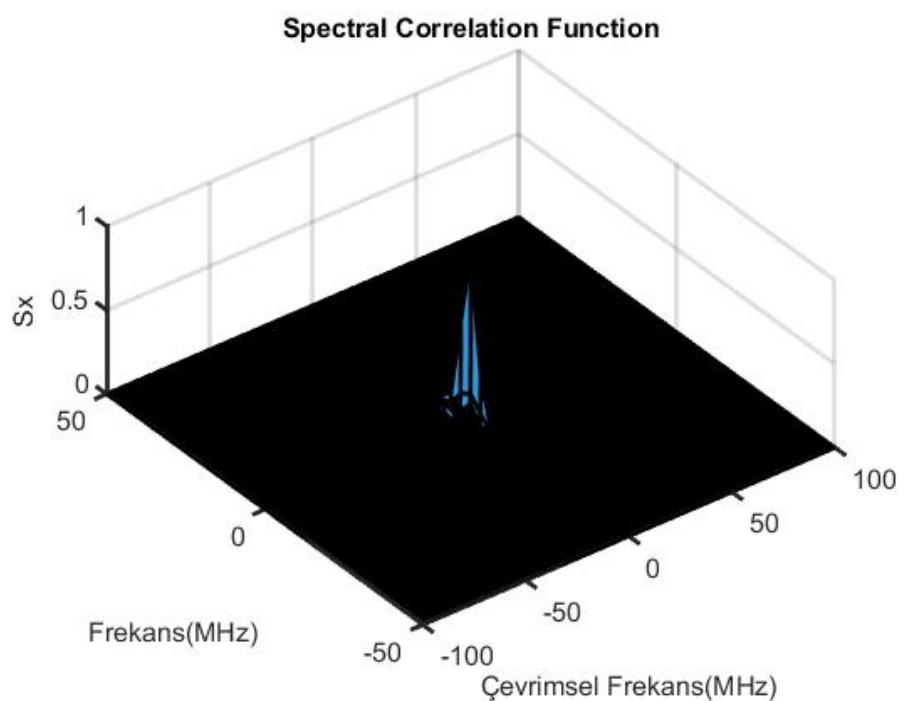
Şekil 3.45 Barker SCF dönüşümü



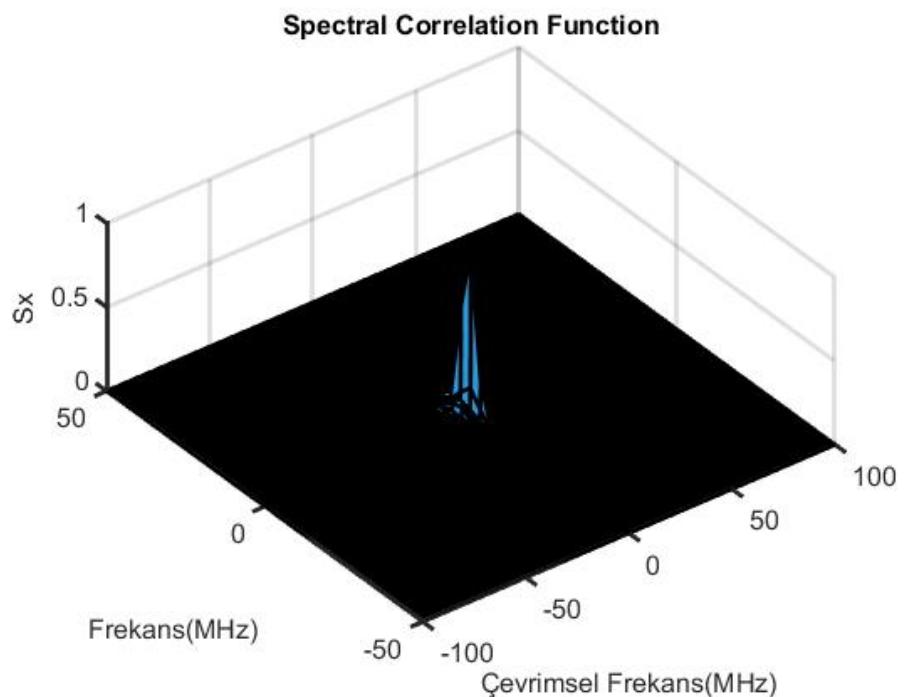
Şekil 3.46 Frank SCF dönüşümü



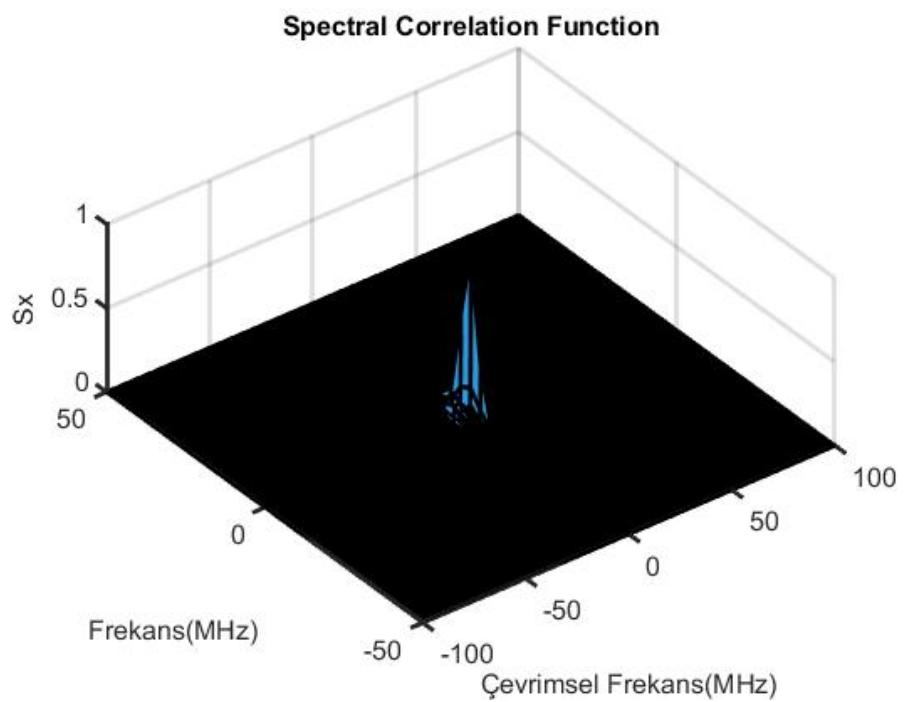
Şekil 3.47 P1 SCF dönüşümü



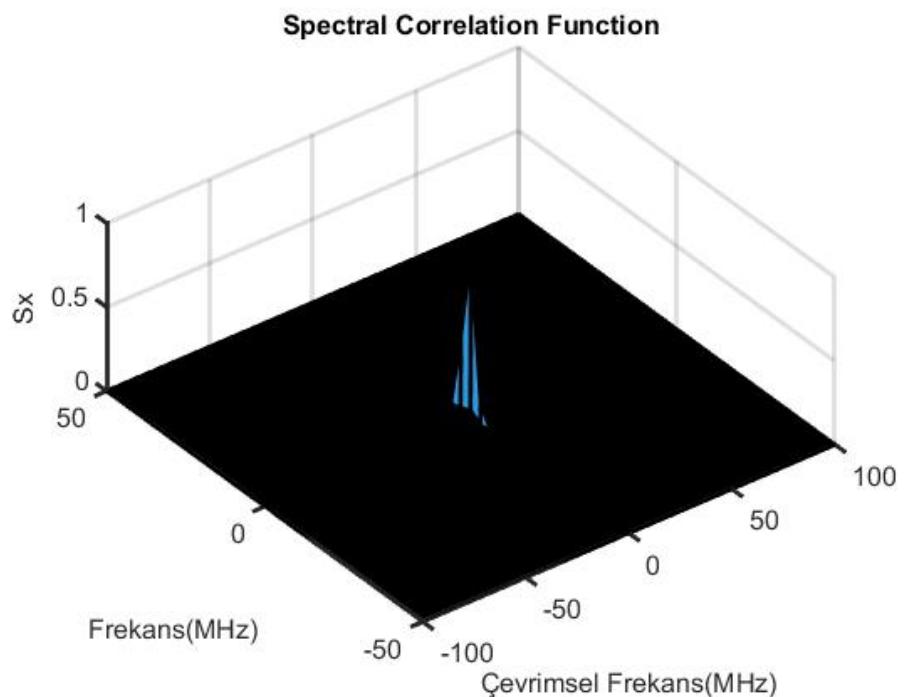
Şekil 3.48 P2 SCF dönüşümü



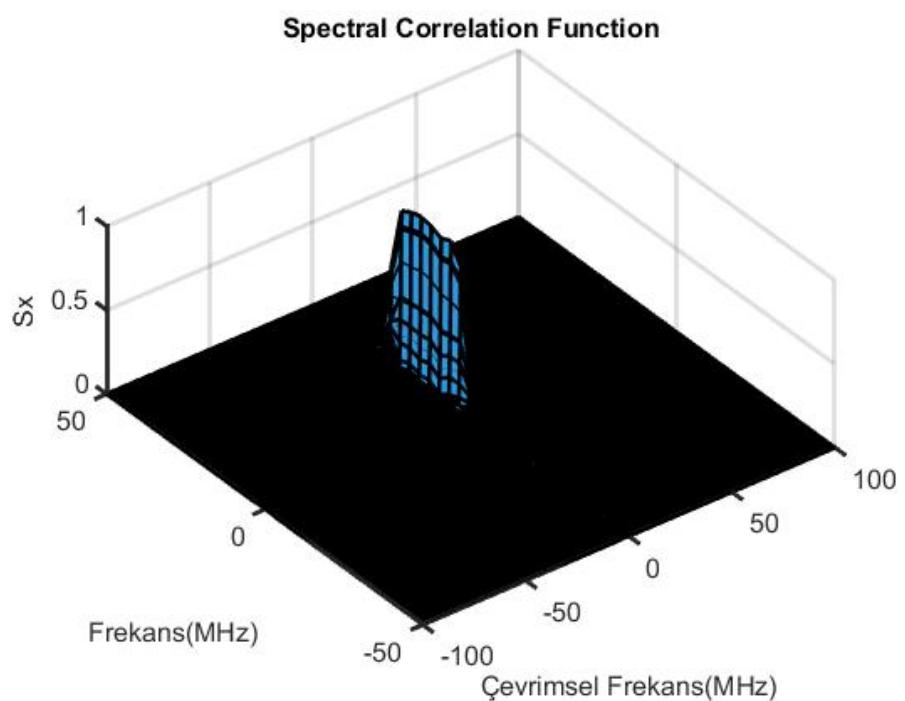
Şekil 3.49 P3 SCF dönüşümü



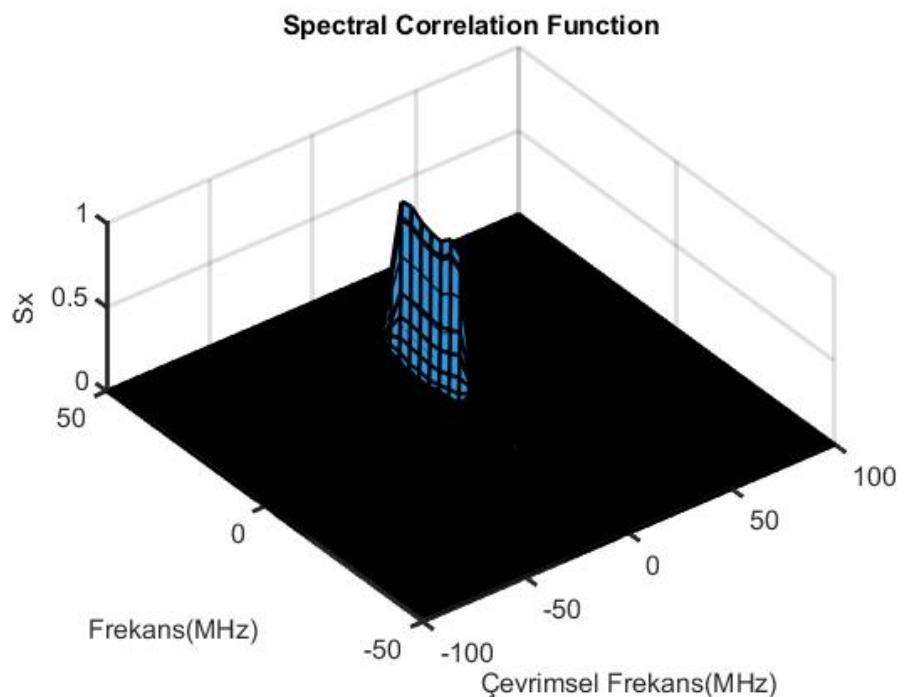
Şekil 3.50 P4 SCF dönüşümü



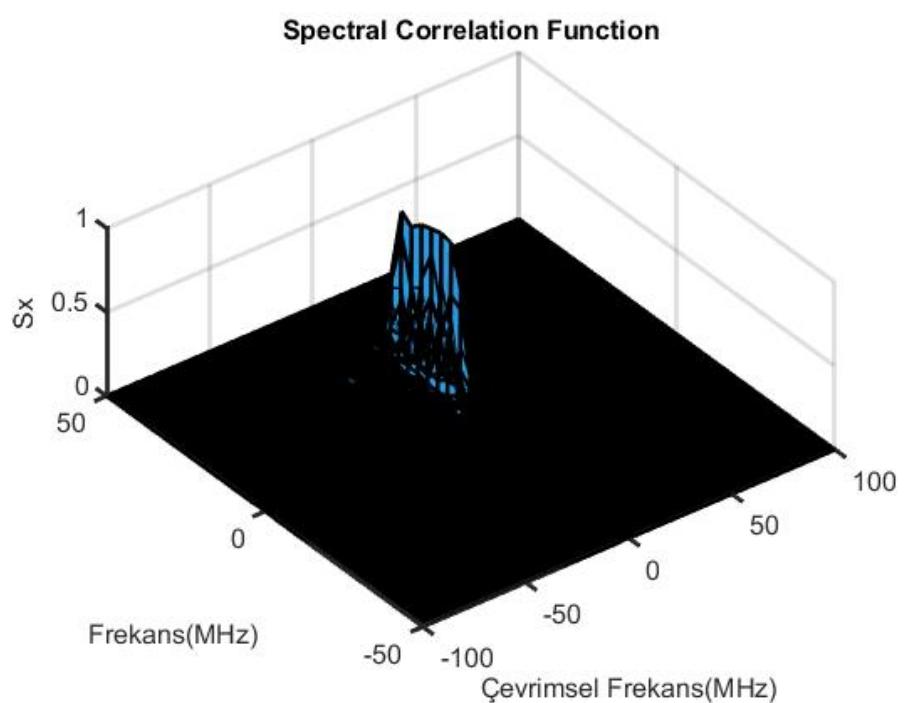
Şekil 3.51 Tek Ton İşaret SCF dönüşümü



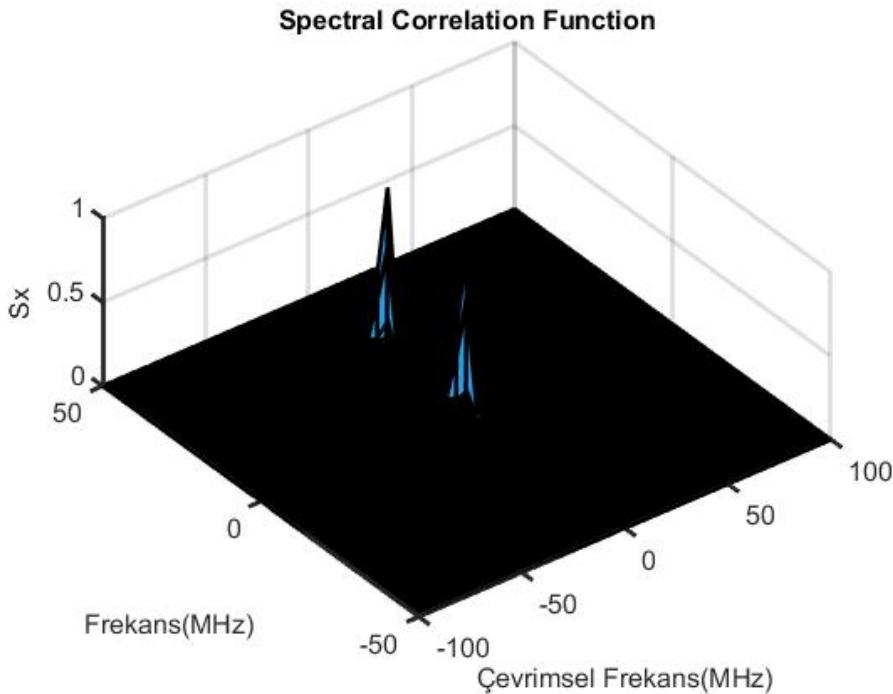
Şekil 3.52 Artan LFM SCF dönüşümü



Şekil 3.53 Azalan LFM SCF dönüşümü



Şekil 3.54 Üçgen LFM SCF dönüşümü



Şekil 3.55 Basamaklı FM SCF dönüşümü

3.2 Literatürde İşaret İşleme Yöntemleri ile İşaret Sınıflandırma

Radar işaretlerini sınıflandırmak için temel olarak olabilirlik tabanlı yöntemler ve öznitelik tabanlı yöntemler kullanılmaktadır. Olabilirlik tabanlı yöntemler doğru sınıflandırma olasılığını en büyütürler. Bu yöntemlerin hesaplama karmaşıklığı yüksektir ve yöntemlerin başarımı model uyumsuzluklarından etkilenmektedir [14, 15].

Öznitelik tabanlı yaklaşımlarda, işaretin modülasyon türünü tespit edebilmek için alınan işaretten çıkartılan öznitelikler kullanılmaktadır. Radar işaretlerini ayırt edebilmek için kullanılan öznitelikler STFT, FSST, WVD ve CWD gibi zaman-frekans dönüşümleri ve çevrimisel durağanlık sinyal analizi gibi yöntemlerdir.

[16]’da radar işaretlerinin tespiti ve sınıflandırılması problemi bütün olarak ele alınmıştır. Alınan işaretlerin STFT ile zaman-frekans imgeleri elde edilmiş olup, sonrasında Hough dönüşümü ile darbe tespiti gerçekleştirilmiştir. CNN tabanlı sınıflandırıcı ile işaretler sınıflandırılmış ve 10 dB SNR değerinde %93.73 başarı elde edilmiştir. [17] numaralı

çalışmada [16]'da kullanılan veri seti genişletilerek önerilen yöntemin performansı incelenmiştir.

FSST alınan radar işaretlerinin zaman-frekans imgeleri elde ederek radar işaretlerini sınıflandırmak için kullanılmaktadır [4, 18]. Bu iki çalışmada da LFM, İkili Faz Kaydırmalı Anahtarlama (Binary Phase Shift Keying, BPSK), Costas, Frank, P1, P2, P3 ve P4 işaretlerinden oluşan 8 sınıflık bir veri seti kullanılmıştır. İşaretlerin FSST öznitelikleri çıkarıldıkten sonra CNN tabanlı bir sınıflandırıcı ile sınıflandırma işlemi gerçekleştirilmişdir. Bu çalışmada FSST performansı CWD ile karşılaştırılmış ve %3 performans artışı raporlanmıştır.

[19] numaralı çalışmada 8 farklı radar modülasyon türünün sınıflandırılması için WVD ve CWD dağılımları özellik olarak kullanılarak Çok Katmanlı Algılayıcı (Multi Layer Perceptron, MLP) tabanlı bir sınıflandırıcı önerilmiştir. Yapılan analizlerde 6 dB SNR değerinde %98 sınıflandırma başarımı elde edilmiştir. [20]'de Düşük Olasılıklı Algılama (Low Probability Intercept, LPI) radar sinyallerinin analizinde CWD kullanılmıştır. İlk aşamada CWD ile alınan radar sinyallerinin zaman-frekans görüntüleri elde edilmiştir. İkinci aşamada zaman-frekans görüntüleri üzerinde radar sinyallerini tespit etmek için radyal entegrasyon yöntemi kullanılmıştır. Özellikle düşük SNR rejiminde önerilen yöntemin performansı düşmektedir.

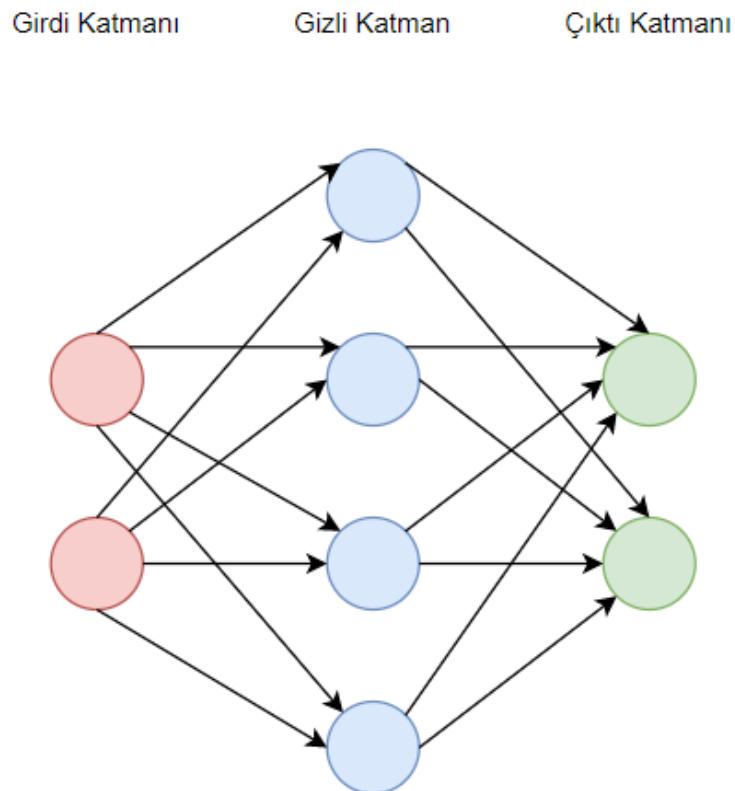
[21] numaralı çalışmada çoklu zaman kodlu LPI radar sinyallerinin analizi için çevimsel durağan sinyal analizi kullanılmıştır. Çoklu zaman kodlu sinyallerin SCF'si hesaplanarak sinyallerin taşıyıcı frekansı, bant genişliği ve kod oranı parametreleri %6'dan daha az bir kestirim hatası ile kestirilmiştir. [22] numaralı FAM ve SSCA algoritmaları ile alınan sinyal SCF'si hesaplanmış ve daha kapsamlı bir radar sinyal kümesi üzerinde çevimsel durağan sinyal analizi ile parametre kestirimi çalışması yapılmıştır. Faz modüleli sinyaller (BPSK, Frank, P1, P2, P3, P4 ve Frekans Kaydırmalı Anahtarlama (Frequency Shift Keying, FSK)/ Faz Kaydırmalı Anahtarlama (Phase Shift Keying, PSK), frekans atlamalı Costas kodlu sinyaller ve FMCW sinyallerin taşıyıcı frekansı, çip ve kod oranları ve bant genişliği parametreleri –6 dB ve 0 dB SNR değerlerinde kestirilmiştir. Kullanılan iki algoritma (FAM

ve SSCA) ile de FMCW haricindeki sinyallerinin parametrelerinin başarı ile kestirildiği ifade edilmektedir. Çevrimsel durağan sinyal analizi radyo sinyallerinin sınıflandırılmasında da kullanılmıştır. [23] ve [24] numaralı çalışmalarda radyo sinyallerinin SCF fonksiyonları öznitelik olarak kullanılmış ve CNN tabanlı bir yaklaşımla Mobil İletişim için Küresel Sistem (Global System for Mobile Communication, GSM), Genişbant Kod Bölмелİ Çoklu Erişim (Wideband Code Division Multiple Access, WCDMA) ve Uzun Süreli Gelişim (Long Term Evolution, LTE) sinyalleri sınıflandırılmıştır.

4 ÖĞRENME ALGORİTMALARI

4.1 YAPAY SINİR AĞLARI

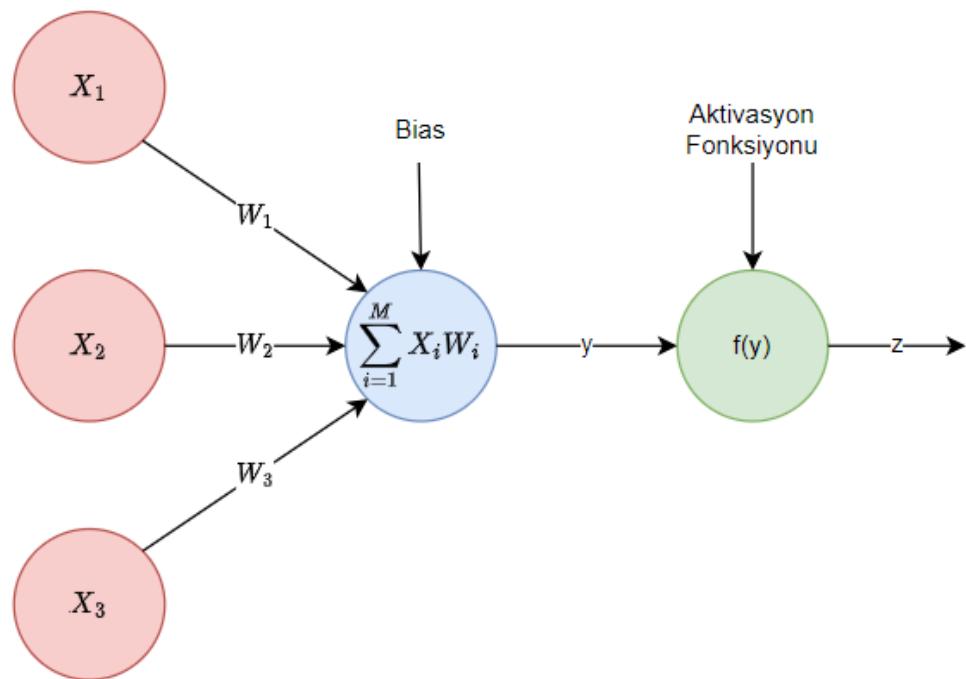
YSA biyolojik beyindeki nöronları modelleyen bir hesaplama sistemidir. YSA yapıları yapay nöron adı verilen çok sayıda bağlantılı birimden oluşmaktadır (Şekil 4.1). Nöronlar arasında kenar ismi verilen bağıntılar biyolojik beyindeki sinapslar gibi davranışarak bilginin bir nörondan diğerine iletilmesini sağlar. Kenarlar nöronlardan aldığıları değerlere ağırlıklandırma uygulayarak ilgili nörondan gelen bilginin öğrenme süreci üzerindeki etkisini belirlemektedir. Nöronlar girdi olarak aldığıları ağırlıklandırılmış değerleri aktivasyon fonksiyonu ismi verilen bir doğrusal olmayan fonksiyondan geçirerek çıktı üretirler.



Şekil 4.1 YSA Yapısı

YSA yapısında girdi katmanı, gizli katman ve çıktı katmanı olmak üzere 3 katman yer almaktadır (Şekil 4.1). Girdi katmanında yer alan nöron sayısı girdi verisinin boyutları kadar olmalıdır. Çıktı katmanı ise ilgili problemde yer alan sınıf sayısı kadar nöron içermelidir.

YSA yapılarında iki farklı öğrenme şekli gerçekleşmektedir. Gözetimsiz öğrenmede ise verilerin etiketi bulunmamaktadır, YSA yapısı verileri analiz ederek kümeler oluşturur. Gözetimli öğrenme YSA içerisindeki ağırlıkların hesaplanması etiketli verileri kullanmaktadır.



Şekil 4.2 YSA Nöron Yapısı

YSA mimarisinde yer alan nöronların genel yapısı Şekil 4.2'de verilmektedir. YSA'nın eğitimi aşamasında ileri besleme ve geri besleme algoritmaları kullanılmaktadır. İleri besleme algoritmasında girdiler kenarlar üzerindeki ağırlıklar ile ağırlanılarak toplanırlar. Toplama işleminin çıktısına bir ofset eklenerek elde edilen sonuç doğrusal olmayan aktivasyondan geçirilir ve çıktı hesaplanır.

$$z = f\left(\sum_{i=1}^M X_i W_i + \phi\right) \quad (4.1)$$

Eş. 4.1'de X_i girdi değerlerini, W_i ağırlık değerlerini, ϕ uygulanan ofseti, f aktivasyon fonksiyonunu ve z çıkış değerini göstermektedir.

Geri besleme algoritması hesaplanan çıkış değeri (z) ve hedeflenen çıkış değeri arasındaki farkı hesaplayarak hata oranını belirler. Hata oranı YSA yapısına geri beslenerek çıkış değeri ve hedeflenen çıkış değeri arasındaki hatayı minimize edecek katsayılar bulunmaktadır.

4.1.1 Aktivasyon Fonksiyonları

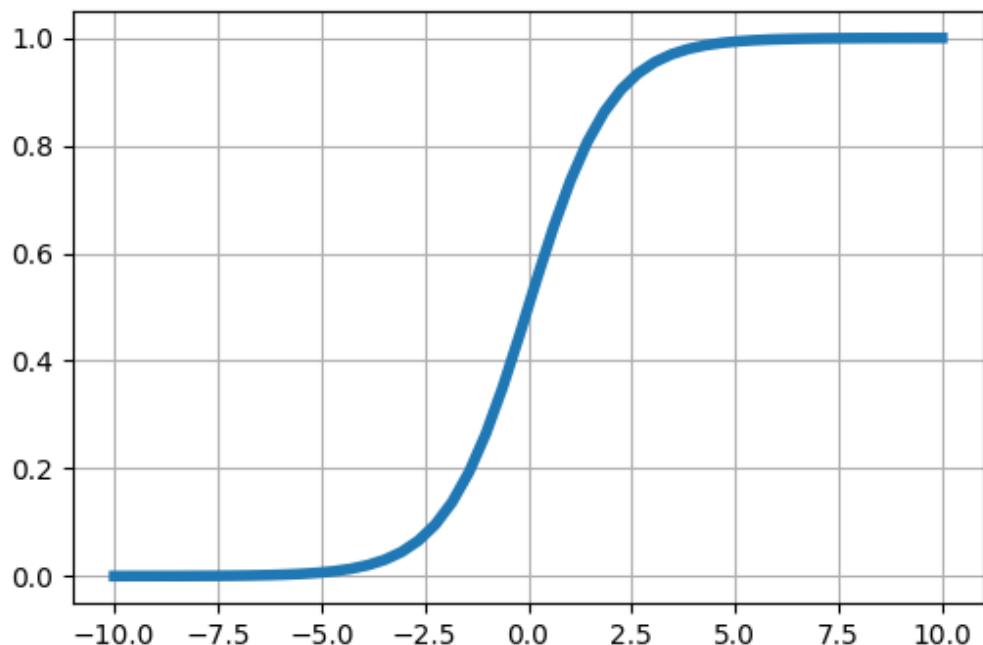
Aktivasyon fonksiyonları, YSA yapılarında girdi verilerine bir dönüşüm uygulayarak çıktı verilerini elde eden fonksiyonlardır [25]. Aktivasyon fonksiyonları yapay sinir ağlarının transfer fonksiyonu olarak da ifade edilebilmektedir. Aktivasyon fonksiyonları YSA yapısında hangi nöronların aktif hangi nöronların inaktif olacağını belirlemektedir. YSA yapılarında kullanılan aktivasyon fonksiyonları doğrusal ve doğrusal olmayan aktivasyon fonksiyonları olarak ikiye ayrılmaktadır. Verilerden kompleks ve karmaşık bilginin elde edilebilmesi için yaygın olarak doğrusal olmayan aktivasyon fonksiyonları kullanılmaktadır [25]. Bu bölümde literatürde yer alan doğrusal olmayan aktivasyon fonksiyonlarına yer verilmektedir.

- **Sigmoid Fonksiyonu**

Sigmoid fonksiyonu girdi değerlerini (0,1) arasına haritalayarak çıkış değerlerini hesaplar [25]. Sigmoid fonksiyonu türevlenebilir ve türevi her zaman pozitif olan bir fonksiyondur [26]. Sigmoid fonksiyonu matematiksel olarak aşağıdaki şekilde yazılmaktadır.

$$f(x) = \frac{1}{1 + e^{-x}} \quad (4.2)$$

Sigmoid fonksiyonu basit bir fonksiyon olması sebebiyle YSA yapılarında kullanılırken, sıfır merkezli olmaması ve kaybolan gradyan problemine sebep olması bu fonksiyonun dezavantajlı yönleridir [27]. Sigmoid fonksiyonu Şekil 4.3'te verilmektedir.

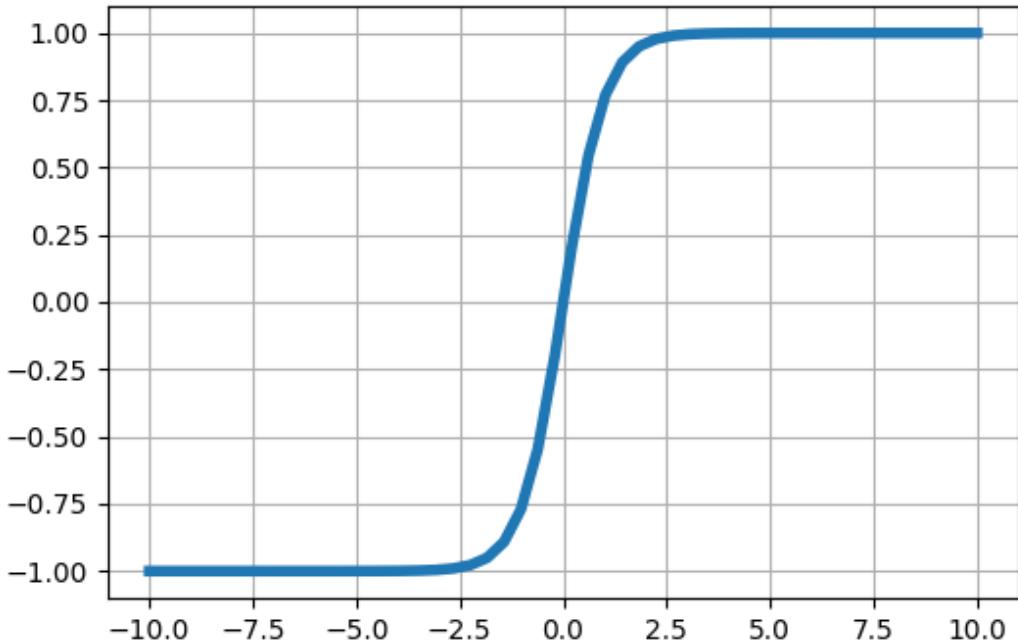


Şekil 4.3 Sigmoid Fonksiyonu

- **Hiperbolik Tanjant Fonksiyonu**

Hiperbolik tanjant (\tanh) fonksiyonu girdi değerlerini $(-1,1)$ arasına haritalayan bir aktivasyon fonksiyonudur [25]. Sigmoid fonksiyonundan farklı olarak \tanh fonksiyonu sıfır merkezli olduğu için geri besleme algoritmasında daha iyi çalışmaktadır [27]. Ayrıca çok katmanlı YSA'larda \tanh fonksiyonu sigmoid fonksiyonuna göre daha iyi başarı göstermektedir [28]. Sigmoid aktivasyon fonksiyonuna benzer şekilde kaybolan gradyan problemine sebep olmaktadır. Matematiksel olarak \tanh fonksiyonu aşağıdaki gibi yazılmaktadır (Eş. 4.3) ve Şekil 4.4'te verilmektedir..

$$f(x) = \frac{1 - e^{-2x}}{1 + e^{-2x}} \quad (4.3)$$



Şekil 4.4 Hiperbolik Tanjant Fonksiyonu

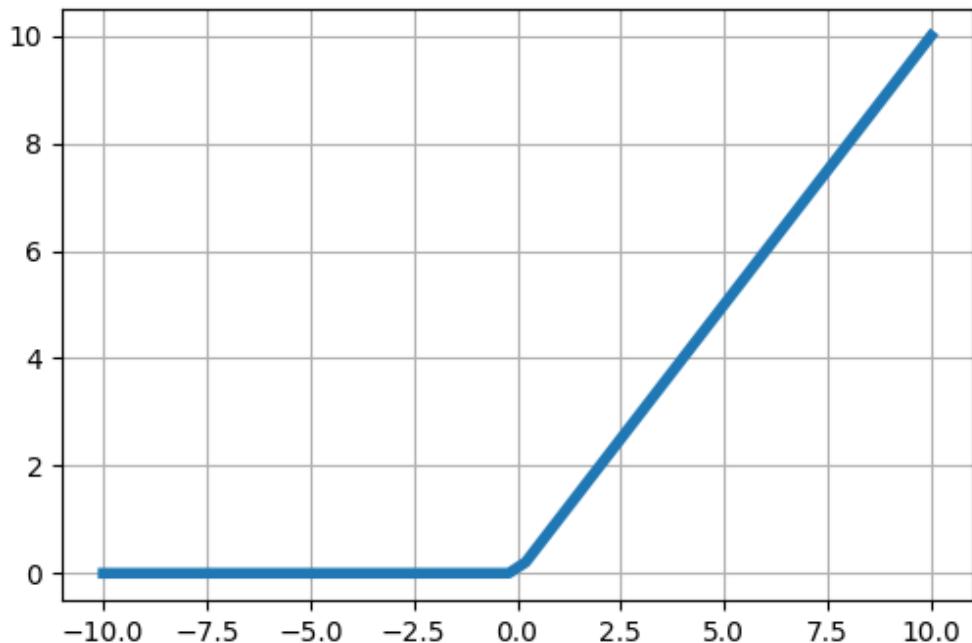
- **ReLU Fonksiyonu**

ReLU derin öğrenme mimarilerinde en yaygın olarak kullanılan aktivasyon fonksiyonudur [29]. ReLU aktivasyon fonksiyonu 2010 yılında Nair ve Hinton tarafından önerilmiştir [30]. ReLU aktivasyon fonksiyonunun matematiksel ifadesi Eş. 4.4'te verilmektedir.

$$f(x) = \max(0, x) \quad (4.4)$$

Sigmoid ve tanh fonksiyonlarından farklı olarak üstel ve bölme işlemleri olmadığından dolayı ReLU aktivasyon fonksiyonu bu fonksiyonlara göre daha hızlı bir fonksiyondur [27]. ReLU aktivasyon fonksiyonu sıfırdan büyük değerler için doğrusal özellik gösterdiği için gradyan tabanlı yöntemler ile en iyilemesi kolaydır. ReLU

aktivasyon fonksiyonu sıfırdan küçük girdileri sıfıra eşitlediği için tanh ve sigmoid fonksiyonlarında gözlemlenen gradyan kaybolması problemini önlemektedir ancak bu durum aynı zamanda en önemli dezavantajlarından biri olan nöronların ölmesine sebep olmaktadır [27]. ReLU aktivasyonu fonksiyonu Şekil 4.5'te verilmektedir.



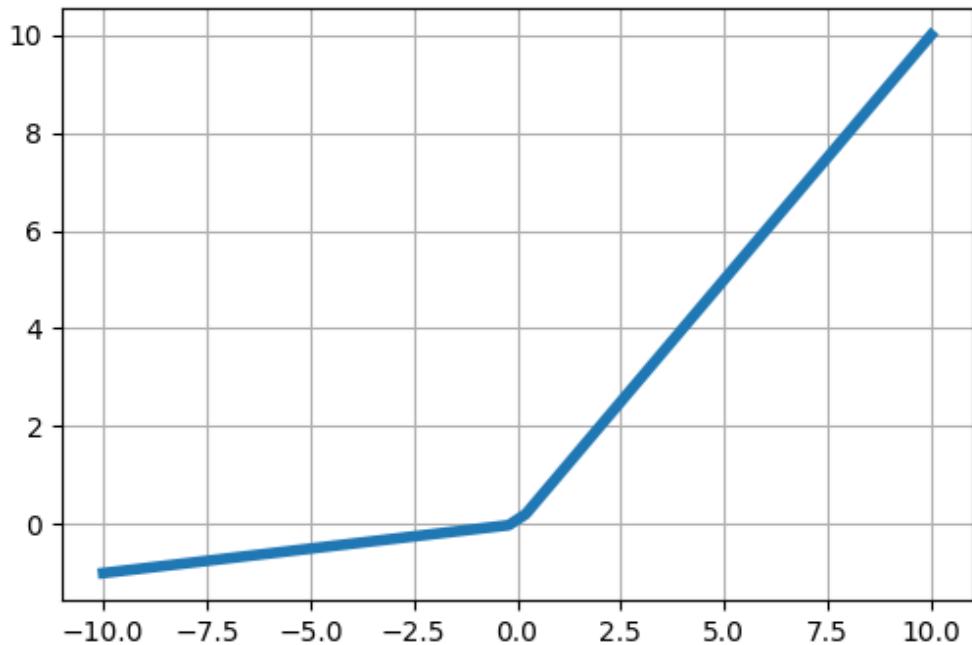
Şekil 4.5 ReLU Aktivasyon Fonksiyonu

- **Leaky ReLU Fonksiyonu**

Leaky ReLU aktivasyon fonksiyonu ReLU fonksiyonundaki ölü nöron problemine çözüm olarak 2013 yılında önerilmiştir [31]. Leaky ReLU negatif bölgede ReLU'dan farklı olarak sıfır yerine küçük bir α değerleri ile girdiyi çarparak çıktı oluşturmaktadır. Bu sayede YSA'nın eğitimi aşamasında gradyan sıfır olmamakta ve ölü nöron problemi oluşmamaktadır [27]. Leaky ReLU aktivasyon fonksiyonunun matematiksel ifadesi aşağıdaki gibi yazılmaktadır.

$$f(x) = \max(\alpha x, x) \quad (4.5)$$

Leaky ReLU aktivasyonu fonksiyonu $\alpha = 0.1$ değeri için Şekil 4.6'da verilmektedir.



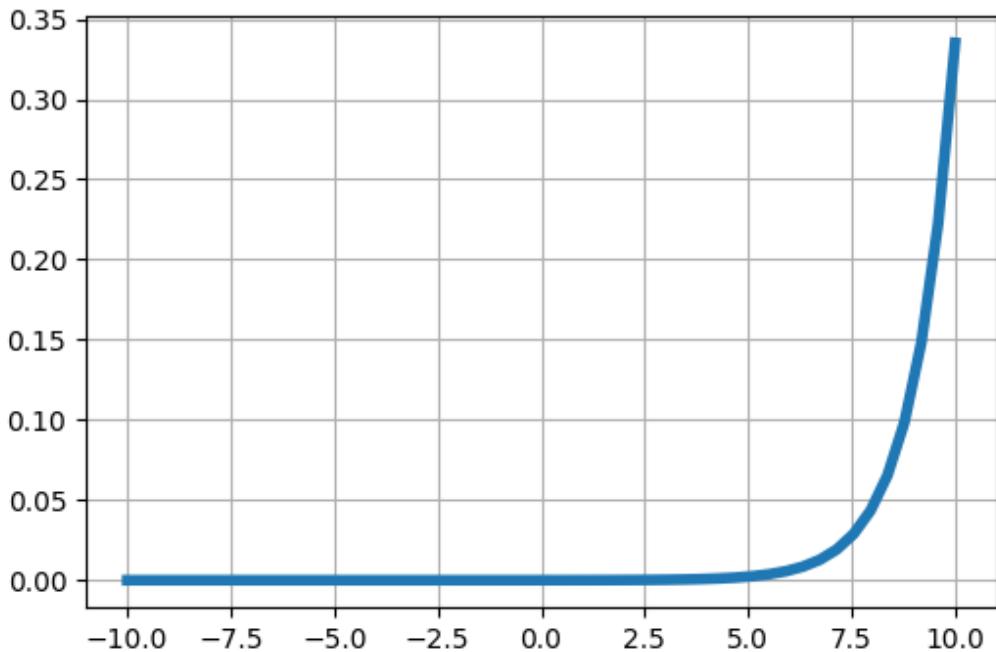
Şekil 4.6 Leaky ReLU Aktivasyon Fonksiyonu

- **Softmax Fonksiyonu**

Softmax aktivasyon fonksiyonu gerçek sayılarından oluşan vektörlerin olasılık dağılımlarını hesaplar [25]. Hesaplanan olasılıkların toplamı 1'e eşittir. Softmax fonksiyonunun ifadesi aşağıdaki şekilde yazılabilir.

$$f(x_i) = \frac{e^{x_i}}{\sum_{j=1}^K e^{x_j}} \quad (4.6)$$

Softmax fonksiyonu çok değişkenli sınıflandırma problemlerinde kullanılmaktadır [27]. Softmax fonksiyonu Şekil 4.7'de verilmektedir.



Şekil 4.7 Softmax Aktivasyon Fonksiyonu

4.1.2 Optimizasyon Algoritmaları

YSA mimarilerindeki öğrenme sürecinde geri besleme algoritması kullanılmaktadır. Geri besleme algoritması eğitim aşamasında kullanılan örneklerin hata fonksiyonunu en küçültecek edecek şekilde YSA parametrelerini hesaplamaktadır [32]. Problemin tanımı matematiksel olarak aşağıdaki gibi yazılabilmektedir [32].

$$\min_{\theta} \frac{1}{N} \sum_{i=1}^N L(y^i, f(x^i, \theta)) \quad (4.7)$$

Eş. 4.7'de N eğitim aşamasında kullanılan örnek sayısını, L hata fonksiyonunu, x^i i 'inci örneğin girdi öznitelik vektörünü, θ YSA eşleştirme parametrelerini ve y^i gerçek çıkış

değerini ifade etmektedir. L hata fonksiyonu karesel hata şeklinde aşağıdaki gibi yazılabilir.

$$L(\theta) = \frac{1}{2N} \sum_{i=1}^N (y^i - f(x^i, \theta))^2 \quad (4.8)$$

Bu bölümde Eş. 4.8'de yer alan hatayı en küçültecek θ değerlerini bulmak için kullanılabilecek optimizasyon algoritmaları anlatılmaktadır.

- **Gradyan İnişi**

Gradyan inişi en eski ve yaygın olarak kullanılan en iyileme algoritmasıdır [32]. Bir sonraki adımın parametreleri, hata fonksiyonu gradyanlarının negatif yönünde hareket edecek şekilde güncellenmektedir.

$$\theta_{j+1} = \theta_j - \eta \frac{\partial L(\theta)}{\partial \theta_j} \quad (4.9)$$

Eş. 4.9'da yer alan η parametresi öğrenme oranını göstermektedir. Öğrenme oranı hata fonksiyonunun en küçük değerine ulaşabilmek için gerekli yineleme sayısını etkilemektedir.

- **Rasgele Gradyan İnişi**

Veri seti boyutlarına bağlı olarak ortaya çıkan yüksek hesaplama karmaşıklığını ortadan kaldırmak için Rasgele Gradyan İnişi algoritması önerilmiştir [33]. Bu yöntemde parametreleri güncellerken hesaplanan gradyan değerleri eğitim kümesinden tek bir örnek için hesaplanmaktadır. Eş. 4.8'de verilen hata fonksiyonu tek bir örnek için aşağıdaki gibi yazılmaktadır.

$$L^i(\theta) = \frac{1}{2}(y^i - f(x^i, \theta))^2 \quad (4.10)$$

Eş. 4.10'daki hata fonksiyonu kullanılarak parametreler aşağıdaki gibi güncellenmektedir.

$$\theta_{j+1} = \theta_j + \eta(y^i - f(x^i, \theta))x^i \quad (4.11)$$

- **AdaGrad**

Gradyan tabanlı en iyileme algoritmalarında sabit bir öğrenme oranı belirleyebilmek zor olduğu için adaptif olarak öğrenme oranı belirlenebilmesi amacıyla AdaGrad algoritması önerilmiştir [32]. AdaGrad önceki adımlardaki gradyan değerlerinin kümülatif toplamına bakarak öğrenme hızını adaptif olarak ayarlamaktadır [34]. AdaGrad algoritmasında öğrenme hızı güncellemesinde kullanılan matematiksel ifadeler aşağıda yer almaktadır.

$$g_t = \frac{\partial L(\theta_t)}{\partial \theta} \quad (4.12)$$

$$V_t = \sqrt{\sum_{i=1}^t (g_i)^2 + \epsilon} \quad (4.13)$$

$$\theta_{j+1} = \theta_j - \eta \frac{g_t}{V_t} \quad (4.14)$$

Yukarıdaki ifadelerde yer alan θ_t terimi t anındaki parametreleri, g_t terimi t anındaki gradyan değerini ve V_t terimi t anına kadar olan gradyanların kümülatif toplamına eşittir. Eş. 4.14'te yer alan η parametresi genel olarak 0.01 olarak kullanılır [32]. AdaGrad algoritmasının en önemli dezavantajı t anı arttıkça gradyan değerlerinin toplamının büyümESİdir, böylece parametreler efektif olarak güncellenememektedir [32].

- **RMSProp**

RMSProp yöntemi 2012 yılında Geoffrey Hinton tarafından önerilmiştir [35]. AdaGrad algoritmasında eğitim süresi arrtıkça gradyanların kümülatif toplamının çok büyük olması sonucu ortaya çıkan öğrenme hızının sıfıra gitmesi problemine çözüm olarak önerilmiştir [32]. RMSProp AdaGrad yönteminden farklı olarak geçmişteki bütün gradyan değerlerini kullanmamaktadır. Belirli bir zaman aralığındaki gradyan değerlerini ve üstel kayan ortalama yöntemini kullanarak ikinci dereceden kümülatif

moment, V_t , değerini aşağıdaki şekilde hesaplamaktadır [32].

$$V_t = \sqrt{\beta V_{t-1} + (1 - \beta) g_t^2} \quad (4.15)$$

Eş. 4.15'te β parametresi üstel azalma parametresidir. Hesaplanan V_t değeri Eş. 4.14'de yerine yazılarak parametreler güncellenir.

- **Adam**

Adam algoritması adaptif öğrenme hızı ve momentum yöntemlerini kullanarak parametre güncellemesi yapan bir en iyileme yöntemidir [36]. Öğrenme hızı parametresini ayarlamak için üstel azalan gradyanların ortalaması, m_t ve üstel azalan gradyanların karelerinin ortalaması, V_t değerlerini kullanarak parametreleri güncellemektedir. m_t ve V_t parametreleri aşağıdaki gibi hesaplanmaktadır [32].

$$m_t = \beta_1 m_{t-1} + (1 - \beta_1) g_t \quad (4.16)$$

$$V_t = \sqrt{\beta_2 V_{t-1} + (1 - \beta_2) g_t^2} \quad (4.17)$$

Eş. 4.16 ve Eş. 4.17'de yer alan β_1 ve β_2 parametreleri üstel azalma parametreleridir. [36] numaralı çalışmada β_1 ve β_2 parametreleri için sırasıyla 0.9 ve 0.999 değerleri önerilmiştir. Parametre güncellemesi için nihai formül aşağıda verilmektedir [32].

$$\theta_{t+1} = m_t - \eta \frac{\sqrt{1 - \beta_2}}{1 - \beta_1} \frac{m_t}{V_t + \epsilon} \quad (4.18)$$

Eş. 4.18'deki ϵ parametresi için önerilen değer 10^{-8} olarak verilmiştir [36].

4.2 Derin Öğrenme

Derin öğrenme, insanlarda olduğu gibi örnekler üzerinden bilgisayarlara ne yapması gerektiğini öğreten bir makine öğrenmesi teknigidir. Derin öğrenme derin sinir ağları olarak da isimlendirilmektedir. Normal yapay sinir ağları 2-3 katmandan oluşmakta iken, derin

öğrenme mimarilerindeki katman sayısı çok daha fazladır. Derin öğrenmenin matematiksel temelleri 1980'lere dayanmaktadır, ancak o tarihlerde yeterli miktarda etiketli veri ve hesaplama gücü olmadığı için derin öğrenme mimarilerinin başarımı kısıtlıydı.

Son yıllarda büyük veri ve grafik işlemci birimlerinde gerçekleşen gelişmeler doğrultusunda derin öğrenme modelleri çok fazla sayıda problemi yüksek doğrulukla çözebilen yapılar haline gelmiştir. Büyük veri kavramı ile derin öğrenme mimarilerinin eğitimi için gerekli olan kapsamlı etiketli veri setleri oluşmuştur. Yüksek performanslı grafik işlemci birimleri paralel hesaplama yöntemlerini kullanarak derin öğrenme mimarilerinin eğitim sürelerini ciddi oranda kısaltmışlardır.

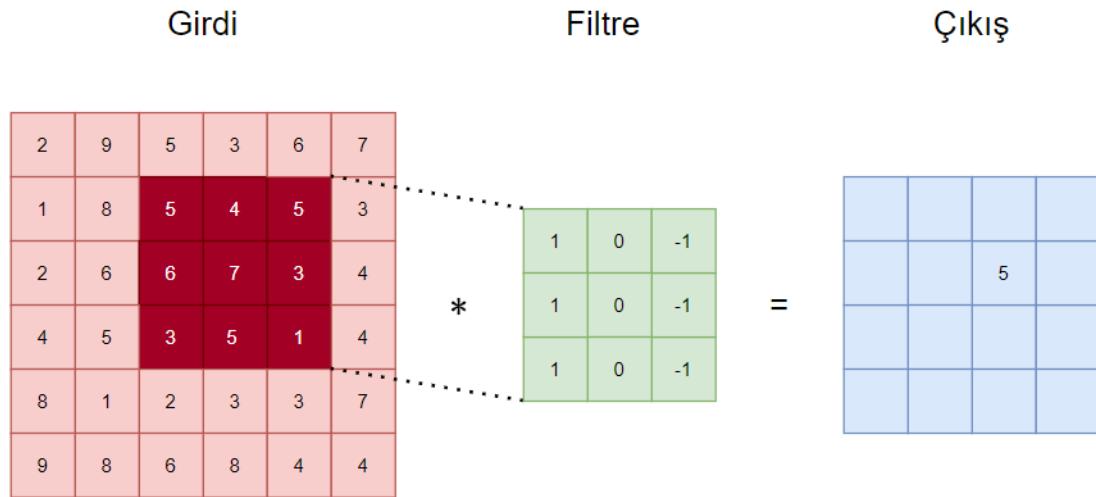
Bu gelişmeler doğrultusunda derin öğrenme mimarileri otonom sürüş, havacılık ve savunma, medikal cihazlar ve elektronik gibi pek çok farklı sektörde yaygın olarak kullanılmaya başlamıştır.

4.3 Evrişimli Sinir Ağları

CNN özellikle görüntü tanıma ve sınıflandırmak için kullanılan bir derin öğrenme mimarisidir. CNN mimarisi 2 boyutlu görüntülerini girdi olarak alarak girdinin hangi sınıf'a ait olduğunu olasılıksal olarak çıktı verir. CNN mimarisi iki aşamadan oluşmaktadır; öznitelik çıkarımı ve sınıflandırma. Öznitelik çıkarımı aşamasında evrişim ve havuzlama katmanları kullanılmaktadır. Evrişim katmanında girdi olarak alınan görüntüler farklı filtreler ile evrişim işleminden geçirilerek yüksek seviyeli öznitelik haritası çıkarılır.

$$h[i, j] = \sum_{p=1}^m \sum_{l=1}^n w_{p,l} X_K[i + p - 1, j + l - 1] \quad (4.19)$$

Eş. 4.19'da $w_{p,l}$ $m \times n$ boyutlu filtre matrisinin p 'inci satır ve l 'inci sütundaki eleman, X_K ise $w_{p,l}$ ile evrişim işleminden geçirilen görüntülerin elemanlarını göstermektedir. Evrişim operasyonu Şekil 4.8'de verilmektedir.



Şekil 4.8 CNN Yapısındaki Evrişim İşlemi

Evrişim katmanından sonra işlemsel karmaşıklığı ve eğitim süresini azaltmak ve aktivasyonları özellik konumlarına daha az duyarlı hale getirerek ezberlemenin (overfitting) önüne geçmek için havuzlama katmanı kullanılmaktadır. Havuzlama işlemi en büyük havuzlama veya ortalama havuzlama gibi çeşitlere sahiptir. En büyük havuzlama ve ortalama havuzlama örnekleri sırasıyla Şekil 4.9 ve Şekil 4.10'da verilmektedir.

2	9	5	3
1	8	8	4
2	6	6	7
4	5	3	5

9	8
6	7

Şekil 4.9 En Büyük Havuzlama İşlemi

2	9	5	3
1	8	8	4
2	6	6	7
4	5	3	5

5	5
4.25	5.25

Şekil 4.10 Ortalama Havuzlama İşlemi

$1 \leq a \leq u$ ve $1 \leq b \leq v$ olmak üzere $u \times v$ boyutlu en büyük havuzlama işlemi

$$g[i, j] = \max h[i + a - 1, j + b - 1] \quad (4.20)$$

şeklinde yazılabilir. Öznitelik çıkarımı aşaması tamamlandıktan sonra, havuzlama katmanı çıktısı tek boyutlu bir vektör haline getirilerek tamamen bağlı katmana girdi olarak verilir. Sınıflandırma işlemi tamamen bağlı katman içerisinde gerçekleştirilmektedir.

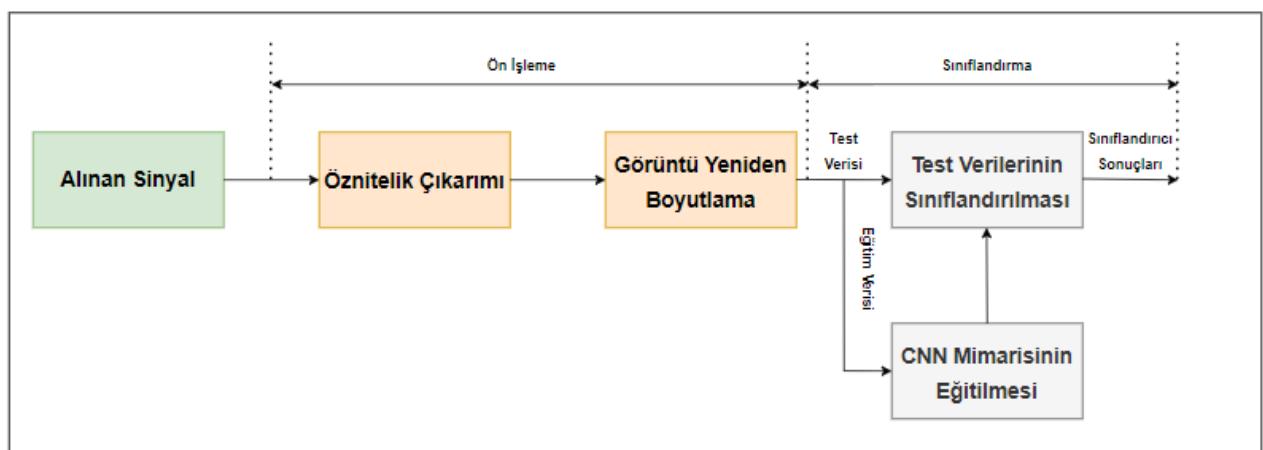
4.4 Literatürde Öğrenme Tabanlı Yöntemler ile İşaret Sınıflandırma

Son yıllarda sinyal sınıflandırma probleminin çözümü için makine öğrenmesi ve derin öğrenme tabanlı yaklaşımlar sıkılıkla kullanılmıştır. [37] numaralı çalışmada sayısal modülasyonların sınıflandırılması ve girişim tespiti için CNN tabanlı bir sınıflandırıcı önerilmiştir. Öznitelik olarak işaretlerin I/Q verisi, genlik/faz vektörü ve FFT kullanılarak geleneksel yöntemlerden daha iyi başarı elde edilmiştir. CNN tabanlı yaklaşımlar ile radar işaretleri de sınıflandırılmaktadır [16, 17, 38–44]. [38] ve [39] numaralı çalışmalarında CTFD ile radar işaretlerinin zaman-frekans görüntüleri elde edilerek sınıflandırma yapılmıştır. [38]’de CTFD sonrasında zaman-frekans görüntüsü üzerindeki gürültüyü azaltmak için 2 boyutlu Wiener filtreleme, aradeğerleme ve Otsu yöntemi kullanılmıştır. Önerilen yöntem 12 sınıfından oluşan bir veri seti ile test edilmiştir ve -6 dB SNR değerinde %96.1 sınıflandırma başarımı elde edilmiştir. [39]’da gürültü azaltmak için CDAE yapısı kullanılmıştır. Bu yöntemle -9 dB’de %95 sınıflandırıcı performansı elde edilmiştir. [40] numaralı çalışmada transfer öğrenmesi ile önceden eğitilmiş CNN mimarileri ile radar işaretlerini sınıflandırılmıştır. CWD ile radar işaretlerinin zaman-frekans imgeleri elde edildikten sonra VGG16 [45], ResNet50 [46], Inception-ResNetV2 [47], DenseNet [48] ve MobileNetV2 [49] CNN mimarileri sınıflandırıcı olarak kullanılmıştır. [41] numaralı çalışmada Yeniden Atanmış Kısa Zaman Fourier Dönüşümü (Reassigned Short Time Fourier Transform, RSTFT) öznitelikleri kullanılarak CNN ile radar işaretleri sınıflandırılmıştır. [41]’de radar işaretlerini sınıflandırmak için öznitelik füzyonu gerçekleştirmiştir. Alınan işaretlerin RSTFT zaman-frekans imgeleri ve anlık faz bileşenleri kullanılarak CNN yapısı eğitilmiş ve

İşaretler sınıflandırılmıştır. [43] numaralı çalışmada öznitelik olarak alınan işaretlerin WVD dağılımları kullanılmıştır. WVD görüntüleri çıkarılan işaretler gürültü azaltmak amacıyla Wiener filtresinden geçirildikten sonra CNN yapısı ile sınıflandırılmıştır ve -8 dB SNR değerinde %96.17 sınıflandırma başarımı elde edilmiştir. [44]'te WVD ile zaman-frekans görüntüleri elde edilerek CNN tabanlı sınıflandırılma gerçekleştirilmiştir.

5 CNN MİMARİSİ İLE RADAR DARBE İÇİ MODÜLASYONLARININ SINIFLANDIRILMASI

Bu çalışmada radar darbe içi sinyallerini sınıflandırmak için kullanılan yöntemlerin blok şeması Şekil 5.1'de verilmiştir. Alınan radar sinyalleri ön işleme aşamasında öznitelik çıkarımı ve yeniden boyutlandırma bloklarında işlenerek CNN mimarisine girdi olacak şekilde getirilmektedir. Ön işleme aşamasından sonra verilerin %80'i eğitim aşamasında, %20'si test aşamasında kullanılmak amacıyla bölünmüştür. CNN mimarisi eğitildikten sonra elde edilen model parametreleri ile test verileri sınıflandırılmış ve alınan radar sinyallerinin darbe içi modülasyonları tespit edilmiştir.



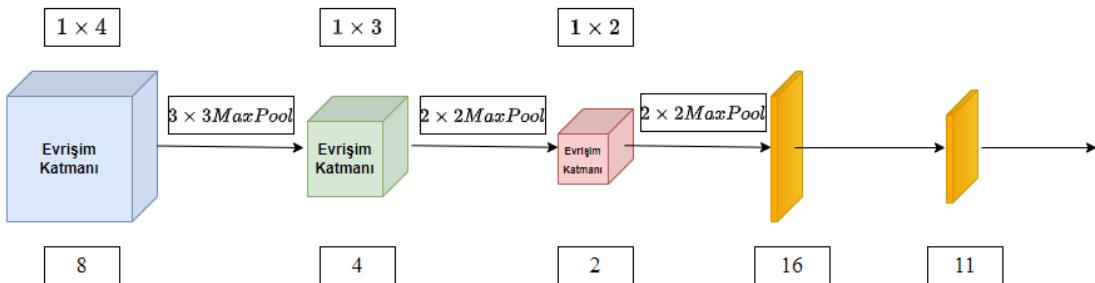
Şekil 5.1 Sınıflandırıcı Mimarisi

5.1 Ön İşleme

Görüntü Ön İşleme aşamasında STFT, FSST, PSWVD ve CWD yöntemleri ile radar işaretlerinin zaman-frekans dönüşümleri ve çevrimisel durağan işaret analizi ile SCF'si hesaplanmıştır. CNN yapısının hesaplama karmaşıklığını azaltabilmek için elde edilen zaman-frekans ve SCF görüntüleri yeniden boyutlandırılmıştır. Yeniden boyutlandırma işlemi sırasında bikübik interpolasyon kullanılarak görüntüler 48×48 boyutuna getirilerek CNN yapısına girdi olarak verilmiştir.

5.2 Evrişimli Sinir Ağları

Şekil 5.2' de önerilen CNN mimarisi ardışık olarak 3 adet evrişim ve 3 adet havuzlama katmanlarından oluşmaktadır. Evrişim katmanları sırasıyla 8, 4 ve 2 adet 1×4 , 1×3 ve 1×2 boyutlu filrelerden oluşmaktadır. CNN mimarilerindeki genel anlayış katmanlardaki filtre sayısının artması şeklinde olmasına rağmen [50] numaralı çalışmada olduğu gibi öğrenilen parametre sayısının ve hesaplama zamanının çok fazla olmasının önüne geçmek için katmanlardaki filtre sayısının azaldığı bir mimari kullanılmıştır.



Şekil 5.2 CNN Mimarisi

Ayırt edici ozniteliklerin çıkarılması için her bir evrişim kanalının çıkışında α değeri 0.1 olan LeakyRelu aktivasyon fonksiyonu kullanılmıştır. Havuzlama katmanında eğitim süresini hızlandırmak ve ezberlemenin önüne geçmek için birinci evrişim katmanından sonra 3×3 , diğer katmanlardan sonra 2×2 en büyük havuzlama kullanılmıştır. Sınıflandırma işlemi iki tam bağlantılı katman kullanılarak tamamlanmaktadır. Birinci tam bağlantılı katman 16 adet ikinci tam bağlantılı katman 11 adet nörondan oluşmaktadır. Tam bağlantılı katmanlar çıkışında softmax aktivasyon fonksiyonu kullanılarak her bir sınıfı ait ardıl olasılıklar hesaplanır. Bu olasılık değerleri kullanılarak alınan işaretin darbe içi modülasyonuna karar verilir.

5.3 Veri Seti

Bu çalışmada kullanılan veri seti MATLAB ([13]) ortamında sentetik olarak üretilmiştir. Önerilen yöntemin genelleştirilebilirliğini sağlamak için üretilen işaretler farklı darbe genişliği, çip sayısı, SNR değeri ve bant genişliği değerlerine sahip olacak şekilde üretilmiştir. Üretilen işaretlerin darbe genişliği (5-15) μs arasında değişmektedir. Faz kodlu işaretlerin için kullanılan çip genişliği 0.25 μs , çip sayısı 16, 36 veya 64 olarak belirlenmiştir. LFM işaretlerin tarama bant genişliği 20-25 MHz arasında rasgele olarak seçilmiştir. Basamaklı FM dalgaformu için frekans adımları 20-25 MHz arasında rasgele seçilmiş ve basamak sayısı 2 olarak alınmıştır. Her bir sınıf'a ait 3000 adet işaret üretilmiştir. Bu işaretlerin 2100 tanesi eğitimde, 300 tanesi doğrulama ve 600 tanesi test aşamasında kullanılmıştır.

6 BENZETİMLER

Bölüm 5.3'te belirtilen parametreler ile -20 dB, -10 dB, 0 dB ve 10 dB SNR değerlerinde radar işaretleri üretilmiştir. Bu SNR değerlerinin seçilmesinin sebebi darbe içi modülasyonların yoğun olarak kullanıldığı LPI radar sistemlerinin düşük çıkış güçlerine sahip olmasıdır. Bu sebeple -20 dB ve -10 dB düşük SNR seviyesi, 0 dB orta seviye ve 10 dB SNR değeri yüksek güçlü işaretleri modellemek için seçilmiştir. Üretilen işaretlerin sırasıyla STFT, FSST, SPWVD ve CWD zaman-frekans imgeleri ve SCF fonksiyonları oluşturularak Şekil 5.2'deki CNN mimarisi ile radar işaretleri sınıflandırılmıştır.

Bu çalışmada kullanılan radar darbe içi işaretleri ve karmaşıklik matrislerinde yer alan kısaltmalar arasındaki ilişki Tablo 6.1'de verilmektedir.

Modülasyon Adı	Kısaltma
Barker	Barker
Frank	Frank
P1	P1
P2	P2
P3	P3
P4	P4
Tek Ton Modülasyon	SCM
LFM Artan	ULFM
LFM Azalan	DLFM
Üçgen LFM	UDLFM
Basamaklı FM	SFM

Tablo 6.1 Darbe İçi Modülasyonlar ve Kısaltmaları

6.1 Kısa-Zaman Fourier Dönüşümü Sınıflandırıcı Sonuçları

Öznitelik olarak STFT kullanıldığından elde edilen karmaşıklık matrisleri -20 dB, -10 dB, 0 dB ve 10 dB değerleri için sırasıyla Şekil Şekil 6.1, 6.2, Şekil 6.3 ve Şekil 6.4'te verilmiştir. SNR değeri -20 dB olduğunda başarım $\%33$ olarak elde edilmiştir. -10 dB SNR değerinde $\%80$ sınıflandırıcı başarımı elde edilmiş olup, modelin çoklu faz kodlu işaretleri sınıflandırmakta hata yaptığı görülmektedir. Çoklu faz kodlu modülasyona sahip olan işaretlerin faz değişiminden kaynaklanan frekans değişimi zaman-frekans imgelerinde çok belirgin olmadığından dolayı model bu işaretleri düşük SNR bölgesinde ayırmakta zorlanmıştır. Frekans modülasyonlu işaretler ise düşük SNR değerinde bile yeterli ayırt ediciliğe sahip oldukları için başarı ile sınıflandırılmışlardır. SNR değeri arttıkça zaman-frekans imgeleri daha belirgin hale geldiği için sınıflandırıcı başarımı artmaktadır. STFT özniteliği 0 dB ve 10 dB SNR değerlerinde sırasıyla $\%97$ ve $\%100$ sınıflandırıcı başarımı elde edilmiştir. 0 dB SNR değerinde de yapılan hatalar faz kodlu işaretlere aittir. Modelin özellikle P1, P2 ve P4 kodlu işaretlerde hata yaptığı gözlemlenmiştir.

		Barker	Frank	P1	P2	P3	P4	SCM	ULFM	DLFM	UDLFM	SFM	
Genuine Signals	Barker	463		8	13	2	11	6	14	23	13	22	25
	Frank	4	129	30	60	73	32	41	59	59	75	38	
	P1	3	66	73	105	47	111	34	27	61	32	41	
	P2	3	54	53	101	39	131	27	36	65	34	57	
	P3	6	122	26	37	112	32	32	54	74	64	41	
	P4	6	56	65	98	46	119	29	37	51	41	52	
	SCM	3	40	15	13	18	16	389	12	37	16	41	
	ULFM	9	41	13	34	22	28	13	168	138	100	34	
	DLFM	5	52	10	23	19	18	17	80	252	92	32	
	UDLFM	7	46	22	37	27	23	13	81	153	159	32	
	SFM	4	45	17	58	25	31	35	38	63	59	225	

Şekil 6.1 STFT –20 dB Hata Matrisi

		Barker	Frank	P1	P2	P3	P4	SCM	ULFM	DLFM	UDLFM	SFM	
		Tahmin Edilen İşaretler											
Genuine Signals	Barker	567	8	2	4	6	3	7	0	0	2	1	
	Frank	13	494	0	2	86	3	2	0	0	0	0	
	P1	7	7	146	140	1	297	1	0	0	0	1	
	P2	13	4	112	215	1	249	4	0	0	0	2	
	P3	6	86	0	1	505	0	2	0	0	0	0	
	P4	7	0	116	106	2	365	1	0	1	0	2	
	SCM	1	3	1	2	5	0	587	0	0	0	1	
	ULFM	0	0	0	0	0	0	0	599	0	1	0	
	DLFM	2	1	0	0	0	0	0	0	1	595	1	
	UDLFM	7	0	0	0	0	0	0	1	1	1	591	
	SFM	1	0	0	1	1	1	1	0	0	0	595	

Şekil 6.2 STFT –10 dB Hata Matrisi

	Barker	Frank	P1	P2	P3	P4	SCM	ULFM	DLFM	UDLFM	SFM	
Gercek Isaretler	597	1	0	1	0	0	1	0	0	0	0	
	Barker	Frank	P1	P2	P3	P4	SCM	ULFM	DLFM	UDLFM	SFM	Tahmin Edilen Isaretler
Barker	597	1	0	1	0	0	1	0	0	0	0	
Frank	1	595	0	1	3	0	0	0	0	0	0	
P1	1	1	470	77	0	51	0	0	0	0	0	
P2	1	0	28	562	0	9	0	0	0	0	0	
P3	0	1	0	0	599	0	0	0	0	0	0	
P4	0	0	22	3	1	574	0	0	0	0	0	
SCM	0	1	0	1	0	0	598	0	0	0	0	
ULFM	0	0	0	0	0	0	0	599	0	0	0	1
DLFM	0	0	0	0	0	0	0	0	600	0	0	
UDLFM	0	0	0	0	0	0	0	0	0	600	0	
SFM	0	0	0	0	0	1	0	0	0	0	599	

Şekil 6.3 STFT 0 dB Hata Matrisi

	Barker	Frank	P1	P2	P3	P4	SCM	ULFM	DLFM	UDLFM	SFM	
Gercek Isaretler	600	0	0	0	0	0	0	0	0	0	0	0
Barker												
Frank	0	600	0	0	0	0	0	0	0	0	0	0
P1	0	0	600	0	0	0	0	0	0	0	0	0
P2	0	0	0	600	0	0	0	0	0	0	0	0
P3	0	0	0	0	600	0	0	0	0	0	0	0
P4	0	0	0	0	0	600	0	0	0	0	0	0
SCM	0	0	0	0	0	0	600	0	0	0	0	0
ULFM	0	0	0	0	0	0	0	600	0	0	0	0
DLFM	0	0	0	0	0	0	0	0	600	0	0	0
UDLFM	0	0	0	0	0	0	0	0	0	600	0	0
SFM	0	0	0	0	0	0	0	0	0	0	600	0
	Barker	Frank	P1	P2	P3	P4	SCM	ULFM	DLFM	UDLFM	SFM	
Tahmin Edilen Isaretler												

Şekil 6.4 STFT 10 dB Hata Matrisi

6.2 Fourier Synchrosqueezed Dönüşümü Sınıflandırıcı Sonuçları

FSST özniteliği için -20 dB, -10 dB, 0 dB ve 10 dB SNR değerlerindeki karmaşıklık matrisleri sırasıyla Şekil 6.5, Şekil 6.6, Şekil 6.7 ve Şekil 6.8'da verilmektedir. Dört farklı SNR değerinde sırasıyla %43, %85, %98 ve %100 sınıflandırıcı başarımı elde edilmiştir. Özellikle düşük SNR değerlerinde çoklu faz kodlu işaretleri ayırt etmede FSST diğer özniteliklerden çok daha başarılı sınıflandırma yapmaktadır. Barker, Frank, P1, P2, P3 ve P4 kodlu faz modülasyonları beş farklı öznitelik için -10 dB SNR değerinde incelendiğinde FSST bu sınıflar için %75 sınıflandırma başarımı göstermektedir. Faz modüleli işaretlerde STFT %63, SPWVVD %58, CWD %53 ve SCF %38 başarım göstermiştir. FSST düşük SNR değerinde birbirine benzer zaman-frekans imgelerine sahip olan Artan LFM, Azalan LFM ve Üçgen LFM işaretlerinde hata yapmaktadır. SNR değeri arttıkça zaman-frekans imgeleri daha ayırt edilebilir hale geldiği için STFT özniteliğine benzer şekilde sınıflandırıcı başarımı artmaktadır.

		Tahmin Edilen İşaretler											
		Barker	Frank	P1	P2	P3	P4	SCM	ULFM	DLFM	UDLFM	SFM	
Genuine Signals	Barker	598	0	0	0	0	0	2	0	0	0	0	
	Frank	0	246	15	38	137	31	0	37	25	16	55	
	P1	0	38	145	140	34	116	0	28	15	27	57	
	P2	0	46	134	137	29	128	0	27	13	28	58	
	P3	0	190	17	20	185	23	0	34	38	38	55	
	P4	0	34	153	132	29	134	0	34	17	25	42	
	SCM	4	0	0	0	0	0	596	0	0	0	0	
	ULFM	0	68	14	25	29	33	0	175	66	128	62	
	DLFM	0	60	11	33	19	39	0	96	133	143	66	
	UDLFM	0	52	13	30	31	43	0	120	88	156	67	
	SFM	0	42	18	20	21	35	0	29	36	41	358	

Şekil 6.5 FSST –20 dB Hata Matrisi

	Barker	Frank	P1	P2	P3	P4	SCM	ULFM	DLFM	UDLFM	SFM	
Gerçek İşaretler	599	0	0	0	0	0	1	0	0	0	0	
Barker												
Frank	0	578	0	0	20	0	0	0	0	0	2	
P1	0	1	304	78	0	215	0	0	0	1	1	
P2	0	0	193	243	0	164	0	0	0	0	0	
P3	0	48	0	0	552	0	0	0	0	0	0	
P4	0	1	153	45	0	401	0	0	0	0	0	
SCM	1	0	0	0	0	0	599	0	0	0	0	
ULFM	0	1	0	0	0	0	0	580	8	11	0	
DLFM	0	0	0	0	0	0	0	5	578	17	0	
UDLFM	0	1	1	0	1	0	0	17	21	558	1	
SFM	0	1	0	0	0	0	0	0	0	0	599	
Tahmin Edilen İşaretler	Barker	Frank	P1	P2	P3	P4	SCM	ULFM	DLFM	UDLFM	SFM	

Şekil 6.6 FSST –10 dB Hata Matrisi

	Barker	Frank	P1	P2	P3	P4	SCM	ULFM	DLFM	UDLFM	SFM	
Gercek Isaretler	600	0	0	0	0	0	0	0	0	0	0	0
	Barker	Frank	P1	P2	P3	P4	SCM	ULFM	DLFM	UDLFM	SFM	Tahmin Edilen Isaretler
Barker	600	0	0	0	0	0	0	0	0	0	0	0
Frank	0	599	0	0	1	0	0	0	0	0	0	0
P1	0	0	545	32	0	23	0	0	0	0	0	0
P2	0	0	26	571	0	3	0	0	0	0	0	0
P3	0	0	0	0	600	0	0	0	0	0	0	0
P4	0	0	30	3	0	567	0	0	0	0	0	0
SCM	0	0	0	0	0	0	600	0	0	0	0	0
ULFM	0	0	0	0	0	0	0	600	0	0	0	0
DLFM	0	0	0	0	0	0	0	0	600	0	0	0
UDLFM	0	0	0	0	0	0	0	0	0	600	0	0
SFM	0	0	0	0	0	0	0	0	0	0	600	0

Şekil 6.7 FSST 0 dB Hata Matrisi

Gercek Isaretler	Barker	Frank	P1	P2	P3	P4	SCM	ULFM	DLFM	UDLFM	SFM	
Tahmin Edilen Isaretler												
Barker -	600	0	0	0	0	0	0	0	0	0	0	0
Frank -	0	600	0	0	0	0	0	0	0	0	0	0
P1 -	0	0	600	0	0	0	0	0	0	0	0	0
P2 -	0	0	0	600	0	0	0	0	0	0	0	0
P3 -	0	0	0	0	600	0	0	0	0	0	0	0
P4 -	0	0	0	0	0	600	0	0	0	0	0	0
SCM -	0	0	0	0	0	0	600	0	0	0	0	0
ULFM -	0	0	0	0	0	0	0	600	0	0	0	0
DLFM -	0	0	0	0	0	0	0	0	600	0	0	0
UDLFM -	0	0	0	0	0	0	0	0	0	600	0	0
SFM -	0	0	0	0	0	0	0	0	0	0	600	0

Şekil 6.8 FSST 10 dB Hata Matrisi

6.3 Düzleştirilmiş Sözde Wigner-Ville Dağılımı Sınıflandırıcı Sonuçları

SPWVD özniteliği için karmaşık matrisleri 6.9-6.12 numaralı şekillerde verilmiştir. SPWVD özniteliği sınıflandırıcı başarımları -20 dB, -10 dB, 0 dB ve 10 dB SNR değerleri için sırasıyla %40, %77, %93 ve %99'dur. SPWVD STFT ve FSST'de mevcut olan zaman-frekans çözünürlüğünden daha iyi bir çözünürlüğe sahip olduğundan dolayı frekans modülasyonlu işaretlerde daha iyi başarı elde etmiştir. Düşük SNR değerlerinde ise diğer özniteliklere benzer şekilde faz kodlu işaretlerin sınıflandırılmasında performans kaybı gözlemlenmektedir.

	Barker	Frank	P1	P2	P3	P4	SCM	ULFM	DLFM	UDLFM	SFM
Güçlü İşaretler	486	14	3	8	11	5	22	15	11	13	12
Frank	30	74	39	50	92	115	31	47	33	39	50
P1	47	54	57	89	50	147	17	46	22	30	41
P2	30	34	61	92	52	157	20	48	35	19	52
P3	27	98	26	33	133	81	27	55	30	37	53
P4	40	47	58	86	40	177	8	41	37	24	42
SCM	14	13	0	7	12	8	334	59	47	62	44
ULFM	16	19	11	14	23	14	53	367	26	34	23
DLFM	7	10	6	15	16	28	53	50	343	42	30
UDLFM	12	16	8	17	30	31	61	42	40	294	49
SFM	13	38	20	42	31	46	24	35	36	41	274
Tahmin Edilen İşaretler											

Şekil 6.9 SPWVD –20 dB Hata Matrisi

		Barker	Frank	P1	P2	P3	P4	SCM	ULFM	DLFM	UDLFM	SFM		
		Tahmin Edilen İşaretler												
Genuine Symbols	Symbol	Count												%
		546	11	3	3	12	6	16	0	2	1	0		
Frank	-	8	435	3	6	139	1	5	0	0	0	3		
P1	-	7	2	168	170	5	247	1	0	0	0	0		
P2	-	2	5	138	228	4	222	1	0	0	0	0		
P3	-	7	138	0	2	449	0	3	0	0	1	0		
P4	-	6	2	154	160	0	277	1	0	0	0	0		
SCM	-	26	0	0	0	6	0	565	0	0	2	1		
ULFM	-	1	0	0	0	0	0	3	596	0	0	0		
DLFM	-	2	0	0	0	0	0	0	0	598	0	0		
UDLFM	-	3	0	0	0	0	0	1	0	0	596	0		
SFM	-	2	1	0	0	0	1	1	0	0	0	595		

Şekil 6.10 SPWVD –10 dB Hata Matrisi

	Barker	Frank	P1	P2	P3	P4	SCM	ULFM	DLFM	UDLFM	SFM	
Gercek Isaretler	594	2	0	0	0	0	3	1	0	0	0	
	0	596	0	1	1	0	2	0	0	0	0	
P1	0	0	417	24	0	159	0	0	0	0	0	
P2	0	1	73	471	0	54	1	0	0	0	0	
P3	0	5	0	0	595	0	0	0	0	0	0	
P4	0	0	103	13	0	484	0	0	0	0	0	
SCM	1	0	0	0	0	0	599	0	0	0	0	
ULFM	0	0	0	0	0	0	0	600	0	0	0	
DLFM	0	0	0	0	0	0	0	0	600	0	0	
UDLFM	0	0	0	0	0	0	0	0	0	600	0	
SFM	0	0	0	0	0	0	0	0	0	0	600	
	Barker	Frank	P1	P2	P3	P4	SCM	ULFM	DLFM	UDLFM	SFM	
Tahmin Edilen Isaretler												

Şekil 6.11 SPWVD 0 dB Hata Matrisi

	Barker	Frank	P1	P2	P3	P4	SCM	ULFM	DLFM	UDLFM	SFM	
Gercek Isaretler	600	0	0	0	0	0	0	0	0	0	0	
	Barker	Frank	P1	P2	P3	P4	SCM	ULFM	DLFM	UDLFM	SFM	Tahmin Edilen Isaretler
Barker	600	0	0	0	0	0	0	0	0	0	0	
Frank	0	600	0	0	0	0	0	0	0	0	0	
P1	0	0	518	10	0	72	0	0	0	0	0	
P2	0	0	2	598	0	0	0	0	0	0	0	
P3	0	1	0	0	599	0	0	0	0	0	0	
P4	0	0	0	0	0	600	0	0	0	0	0	
SCM	0	0	0	0	0	0	600	0	0	0	0	
ULFM	0	0	0	0	0	0	0	600	0	0	0	
DLFM	0	0	0	0	0	0	0	0	600	0	0	
UDLFM	0	0	0	0	0	0	0	0	0	600	0	
SFM	0	0	0	0	0	0	0	0	0	0	600	

Şekil 6.12 SPWVD 10 dB Hata Matrisi

6.4 Choi-Williams Dağılımı Sınıflandırıcı Sonuçları

Choi-Williams Dağılımına ait karmaşık matrisleri 6.13-6.16 numaralı şekillerde verilmiştir. CWD özniteliği başarımları ise sırasıyla %30, %73, %95 ve %100 olarak elde edilmiştir. CWD özniteliği de diğer zaman-frekans dönüşümlerine benzer şekilde frekans modüleli radar işaretlerini düşük SNR değerlerinde bile başarılı bir şekilde sınıflandırabilirken çoklu faz kodlu radar işaretlerinde hata oranı artış göstermektedir.

	Barker	Frank	P1	P2	P3	P4	SCM	ULFM	DLFM	UDLFM	SFM
Gerçek İşaretler	430	8	18	14	19	6	62	11	3	14	15
F rank	38	47	42	53	43	73	54	76	41	77	56
P1	35	25	50	69	35	81	70	56	42	66	71
P2	29	22	45	75	31	90	66	77	39	65	61
P3	22	42	30	54	57	77	70	78	37	71	62
P4	24	24	53	67	36	101	68	70	41	69	47
SCM	48	10	25	39	10	61	281	41	10	29	46
ULFM	8	16	12	16	39	38	20	291	38	67	55
DLFM	10	19	21	31	19	48	16	93	209	78	56
UDLFM	5	17	10	31	27	35	30	67	56	269	53
SFM	10	14	35	36	25	49	40	70	41	93	187
Tahmin Edilen İşaretler											

Şekil 6.13 Choi-Williams –20 dB Hata Matrisi

		Barker	Frank	P1	P2	P3	P4	SCM	ULFM	DLFM	UDLFM	SFM	
		Tahmin Edilen İşaretler											
Gercek İşaretler	Barker	486	34	15	7	12	8	33	2	0	0	3	
	Frank	24	413	3	3	144	0	11	1	0	0	1	
	P1	26	4	226	147	1	188	5	0	0	1	2	
	P2	19	4	212	190	0	167	6	0	1	1	0	
	P3	23	157	1	1	413	0	5	0	0	0	0	
	P4	22	3	231	136	2	201	5	0	0	0	0	
	SCM	45	8	5	9	1	1	530	0	0	0	1	
	ULFM	1	0	1	0	0	0	0	598	0	0	0	
	DLFM	2	0	1	1	1	0	0	0	595	0	0	
	UDLFM	3	0	0	0	0	0	0	0	0	597	0	
	SFM	5	0	2	0	1	1	0	0	0	1	590	

Şekil 6.14 Choi-Williams –10 dB Hata Matrisi

	Barker	Frank	P1	P2	P3	P4	SCM	ULFM	DLFM	UDLFM	SFM	
Gercek Isaretler	596	2	0	1	0	0	1	0	0	0	0	
	3	596	0	0	1	0	0	0	0	0	0	
P1	1	0	402	46	0	151	0	0	0	0	0	
P2	0	0	47	539	0	14	0	0	0	0	0	
P3	0	0	0	0	600	0	0	0	0	0	0	
P4	0	0	34	4	0	562	0	0	0	0	0	
SCM	1	0	0	0	0	0	599	0	0	0	0	
ULFM	0	0	0	0	0	0	0	600	0	0	0	
DLFM	0	0	0	0	0	0	0	0	600	0	0	
UDLFM	2	0	0	0	0	0	0	0	0	598	0	
SFM	0	0	0	0	0	0	0	0	0	0	600	
	Barker	Frank	P1	P2	P3	P4	SCM	ULFM	DLFM	UDLFM	SFM	Tahmin Edilen Isaretler

Şekil 6.15 Choi-Williams 0 dB Hata Matrisi

	Barker	Frank	P1	P2	P3	P4	SCM	ULFM	DLFM	UDLFM	SFM	
Gercek Isaretler	600	0	0	0	0	0	0	0	0	0	0	0
	Barker	Frank	P1	P2	P3	P4	SCM	ULFM	DLFM	UDLFM	SFM	Tahmin Edilen Isaretler
Barker	600	0	0	0	0	0	0	0	0	0	0	0
Frank	0	600	0	0	0	0	0	0	0	0	0	0
P1	0	0	600	0	0	0	0	0	0	0	0	0
P2	0	0	2	598	0	0	0	0	0	0	0	0
P3	0	0	0	0	600	0	0	0	0	0	0	0
P4	0	0	0	0	0	600	0	0	0	0	0	0
SCM	0	0	0	0	0	0	600	0	0	0	0	0
ULFM	0	0	0	0	0	0	0	600	0	0	0	0
DLFM	0	0	0	0	0	0	0	0	600	0	0	0
UDLFM	0	0	0	0	0	0	0	0	0	600	0	0
SFM	0	0	0	0	0	0	0	0	0	0	600	0

Şekil 6.16 Choi-Williams 10 dB Hata Matrisi

6.5 Çevrimsel Durağan Sinyal Analizi Sınıflandırıcı Sonuçları

Radar işaretlerini sınıflandırmak için SCF özniteliği kullanıldığı zaman elde edilen karmaşıklık matrisleri Şekil 6.17, Şekil 6.18, Şekil 6.19 ve Şekil 6.20'te yer almaktadır. SCF radar işaretlerini ayırt edebilmek için gerekli olan zamansal bilgileri içermediği için sınıflandırıcı başarımı diğer özniteliklere göre daha düşük kalmaktadır. SCF diğer özniteliklerden farklı olarak zaman-frekans bilgisini içermediği için frekans modüleli işaretlerde de düşük bir sınıflandırıcı performansı göstermektedir. Ancak hatalı kararlarda da faz ve frekans modüleli işaretleri birbirine karıştırmamaktadır.

Genuine Symbols		Barker	Frank	P1	P2	P3	P4	SCM	ULFM	DLFM	UDLFM	SFM
		538	8	0	6	4	1	41	1	0	1	0
Frank	- 16	358	41	26	76	12	3	27	16	25	0	
P1	- 11	328	36	30	91	11	1	38	21	32	1	
P2	- 15	350	39	27	88	10	0	27	15	28	1	
P3	- 5	360	37	18	94	10	3	17	20	33	3	
P4	- 9	349	42	29	77	12	1	34	18	28	1	
SCM	- 60	1	0	0	0	0	539	0	0	0	0	
ULFM	- 2	270	21	5	40	5	0	83	73	99	2	
DLFM	- 3	231	15	5	45	4	0	97	94	104	2	
UDLFM	- 1	270	11	11	46	1	1	82	85	91	1	
SFM	- 1	372	28	8	73	8	1	35	28	38	8	

Şekil 6.17 SCF –20 dB Hata Matrisi

Gercek Isaretler		Barker	Frank	P1	P2	P3	P4	SCM	ULFM	DLFM	UDLFM	SFM	
		568	1	1	2	0	5	16	1	0	0	6	
Barker -	568	1	1	2	0	5	16	1	0	0	0	6	
Frank -	10	195	69	39	171	102	1	2	0	0	0	11	
P1 -	9	71	161	78	67	205	0	2	0	0	0	7	
P2 -	6	104	153	72	79	175	0	4	1	0	0	6	
P3 -	8	190	74	41	173	94	1	0	0	0	0	19	
P4 -	7	56	161	63	85	222	0	1	0	0	0	5	
SCM -	32	1	0	0	0	0	565	0	0	0	0	2	
ULFM -	2	0	0	0	0	0	0	464	62	72	0		
DLFM -	0	0	0	0	0	0	0	166	335	99	0		
UDLFM -	0	0	0	0	0	0	0	319	160	119	0		
SFM -	0	23	2	4	6	2	7	1	1	0	554		
		Barker	Frank	P1	P2	P3	P4	SCM	ULFM	DLFM	UDLFM	SFM	Tahmin Edilen Isaretler

Şekil 6.18 SCF –10 dB Hata Matrisi

		Barker	Frank	P1	P2	P3	P4	SCM	ULFM	DLFM	UDLFM	SFM
		Tahmin Edilen İşaretler										
Gercek Isaretler		570	11	6	2	4	7	0	0	0	0	0
Barker -		570	11	6	2	4	7	0	0	0	0	0
Frank -		3	282	14	32	258	11	0	0	0	0	0
P1 -		2	4	207	113	15	259	0	0	0	0	0
P2 -		1	27	179	181	39	173	0	0	0	0	0
P3 -		0	135	15	17	413	20	0	0	0	0	0
P4 -		0	5	204	96	25	270	0	0	0	0	0
SCM -		0	0	0	0	0	0	599	0	0	0	1
ULFM -		0	0	0	0	0	0	0	489	57	54	0
DLFM -		0	0	0	0	0	0	0	24	538	38	0
UDLFM -		1	0	0	0	0	0	0	82	142	375	0
SFM -		0	0	0	0	0	0	17	0	0	0	583

Şekil 6.19 SCF 0 dB Hata Matrisi

		Barker	Frank	P1	P2	P3	P4	SCM	ULFM	DLFM	UDLFM	SFM
Gerek İ işaretleri	Barker	597	1	1	0	0	1	0	0	0	0	0
	Frank	0	425	0	2	173	0	0	0	0	0	0
	P1	0	0	336	73	2	189	0	0	0	0	0
	P2	0	4	70	462	1	63	0	0	0	0	0
	P3	0	68	0	1	531	0	0	0	0	0	0
	P4	0	1	193	34	1	371	0	0	0	0	0
	SCM	0	0	0	0	0	0	600	0	0	0	0
	ULFM	0	0	0	0	0	0	0	562	26	12	0
	DLFM	0	0	0	0	0	0	0	27	561	12	0
	UDLFM	0	0	0	0	0	0	0	12	15	573	0
	SFM	0	0	0	0	0	0	0	0	0	0	600

Şekil 6.20 SCF 10 dB Hata Matrisi

6.6 Eğitim ve Test Verileri SNR Değerlerinin Sınıflandırıcı Başarımına Etkisinin İncelenmesi

SNR değerinin sınıflandırıcı başarımı üzerindeki etkisini incelemek için farklı SNR değerlerine sahip eğitim ve test verileri oluşturulmuştur ve farklı öznitelikler için önerilen sınıflandırıcının başarımı incelenmiştir. Bu çalışma kapsamında SNR değerleri 0 dB ve 10 dB olarak belirlenmiştir. Farklı SNR değerleri ile elde edilen karmaşıklık matrisleri 6.21 - 6.30 numaralı şekillerde verilmektedir. 0 dB SNR değeri ile eğitilen model 10 dB SNR değerine sahip test veri ile test edildiğinde sınıflandırıcı performansı ciddi bir şekilde etkilenmemektedir. Bu durumun aksine, eğitim verisinin SNR değeri yüksek, test verisinin SNR değeri düşük olduğunda sınıflandırıcının performansında ciddi bir azalma gözlemlenmektedir. Bu çalışmada kullanılan beş öznitelik arasında kullanılan verilerin SNR değerlerinin farklı olmasından en az etkilenen öznitelik FSST olmuştur.

	Barker	Frank	P1	P2	P3	P4	SCM	ULFM	DLFM	UDLFM	SFM	
Gercek Isaretler	-3000	0	0	0	0	0	0	0	0	0	0	0
	Barker	Frank	P1	P2	P3	P4	SCM	ULFM	DLFM	UDLFM	SFM	Tahmin Edilen Isaretler
Barker	-3000	0	0	0	0	0	0	0	0	0	0	0
Frank	0	3000	0	0	0	0	0	0	0	0	0	0
P1	0	0	2430	36	0	0	534	0	0	0	0	0
P2	0	0	0	2449	0	0	551	0	0	0	0	0
P3	340	0	0	0	2589	0	71	0	0	0	0	0
P4	0	0	0	0	0	1042	1958	0	0	0	0	0
SCM	0	0	0	0	0	0	3000	0	0	0	0	0
ULFM	0	0	0	0	0	0	0	3000	0	0	0	0
DLFM	0	0	0	0	0	0	0	0	2943	57	0	0
UDLFM	0	0	0	0	0	0	0	0	0	3000	0	0
SFM	0	0	0	0	0	0	0	0	0	0	3000	0

Şekil 6.21 STFT Eğitim 0 dB Test 10 dB Hata Matrisi

	Barker	Frank	P1	P2	P3	P4	SCM	ULFM	DLFM	UDLFM	SFM	
Gereklilik İşaretleri	- 2914	10	6	23	10	7	16	3	2	0	9	
Frank - 565	2009	2	34	79	2	111	13	1	36	148		
P1 - 449	28	1868	235	6	330	78	0	6	0	0	0	
P2 - 394	7	594	1836	1	100	66	0	0	0	0	2	
P3 - 126	274	0	0	2224	0	65	3	1	28	279		
P4 - 521	10	580	51	11	1792	30	0	5	0	0	0	
SCM - 482	298	9	10	249	56	1856	0	2	0	38		
ULFM - 203	28	60	21	11	0	0	2650	4	16	7		
DLFM - 88	2	115	0	46	0	0	2	2747	0	0		
UDLFM - 13	26	27	5	14	0	0	63	3	2835	14		
SFM - 9	58	1	0	148	0	5	0	15	5	2759		
	Barker	Frank	P1	P2	P3	P4	SCM	ULFM	DLFM	UDLFM	SFM	Tahmin Edilen İşaretler

Şekil 6.22 STFT Eğitim 10 dB Test 0 dB Hata Matrisi

	Barker	Frank	P1	P2	P3	P4	SCM	ULFM	DLFM	UDLFM	SFM	
Gercek Isaretler	-2999	0	0	0	0	0	1	0	0	0	0	
	Barker	Frank	P1	P2	P3	P4	SCM	ULFM	DLFM	UDLFM	SFM	Tahmin Edilen Isaretler
Barker	-2999	0	0	0	0	0	1	0	0	0	0	
Frank	0	3000	0	0	0	0	0	0	0	0	0	
P1	0	0	3000	0	0	0	0	0	0	0	0	
P2	0	0	0	3000	0	0	0	0	0	0	0	
P3	0	0	0	0	3000	0	0	0	0	0	0	
P4	0	0	0	0	0	3000	0	0	0	0	0	
SCM	0	0	0	0	0	0	3000	0	0	0	0	
ULFM	0	0	0	0	0	0	0	3000	0	0	0	
DLFM	0	0	0	0	0	0	0	0	3000	0	0	
UDLFM	0	0	0	0	0	0	0	0	0	3000	0	
SFM	0	0	0	0	0	0	0	0	0	0	3000	

Şekil 6.23 FSST Eğitim 0 dB Test 10 dB Hata Matrisi

	Barker	Frank	P1	P2	P3	P4	SCM	ULFM	DLFM	UDLFM	SFM	
Gereklilik İşaretleri	-2990	0	2	0	0	0	8	0	0	0	0	0
Frank -	0	2987	0	1	12	0	0	0	0	0	0	0
P1 -	0	3	2863	62	0	72	0	0	0	0	0	0
P2 -	0	36	803	2114	0	44	0	0	0	0	0	3
P3 -	0	66	0	0	2932	0	0	0	0	2	0	0
P4 -	0	5	1218	46	0	1731	0	0	0	0	0	0
SCM -	3	0	0	0	0	0	2997	0	0	0	0	0
ULFM -	0	15	5	0	1	0	0	2850	0	129	0	0
DLFM -	0	3	5	8	7	0	6	5	2820	146	0	0
UDLFM -	0	19	3	25	8	0	2	15	31	2896	1	0
SFM -	0	0	0	0	0	0	0	0	0	0	3000	
	Barker	Frank	P1	P2	P3	P4	SCM	ULFM	DLFM	UDLFM	SFM	
	Tahmin Edilen İşaretler											

Şekil 6.24 FSST Eğitim 10 dB Test 0 dB Hata Matrisi

	Barker	Frank	P1	P2	P3	P4	SCM	ULFM	DLFM	UDLFM	SFM	
Gercek Isaretler	-2702	7	69	222	0	0	0	0	0	0	0	0
	Barker	Frank	P1	P2	P3	P4	SCM	ULFM	DLFM	UDLFM	SFM	Tahmin Edilen Isaretler
Barker	-2702	7	69	222	0	0	0	0	0	0	0	0
Frank	0	3000	0	0	0	0	0	0	0	0	0	0
P1	0	0	2006	0	0	994	0	0	0	0	0	0
P2	0	0	0	3000	0	0	0	0	0	0	0	0
P3	0	0	0	0	3000	0	0	0	0	0	0	0
P4	0	0	0	0	0	3000	0	0	0	0	0	0
SCM	0	0	0	0	0	0	3000	0	0	0	0	0
ULFM	0	0	0	0	0	0	0	3000	0	0	0	0
DLFM	0	0	0	0	0	0	0	0	3000	0	0	0
UDLFM	0	0	0	0	0	0	0	0	0	3000	0	0
SFM	0	0	0	0	0	0	0	0	0	0	3000	0

Şekil 6.25 SPWVD Eğitim 0 dB Test 10 dB Hata Matrisi

		Barker	Frank	P1	P2	P3	P4	SCM	ULFM	DLFM	UDLFM	SFM
		Tahmin Edilen İşaretler										
Genuine Signals	Barker	2551	196	35	45	46	37	40	5	24	16	5
	Frank	133	1952	0	732	25	0	155	0	0	0	3
	P1	63	140	2042	221	45	479	2	0	8	0	0
	P2	99	210	1094	1360	12	203	20	0	2	0	0
	P3	16	420	0	94	2185	0	239	0	3	9	34
	P4	52	159	1273	139	52	1318	0	0	7	0	0
	SCM	144	416	132	433	300	5	1374	29	66	60	41
	ULFM	0	0	0	0	6	0	0	2992	0	2	0
	DLFM	78	0	0	0	0	0	0	0	2922	0	0
	UDLFM	0	0	0	0	23	0	0	0	0	2977	0
	SFM	0	0	0	0	24	0	7	0	0	0	2969

Şekil 6.26 SPWVD Eğitim 10 dB Test 0 dB Hata Matrisi

	Barker	Frank	P1	P2	P3	P4	SCM	ULFM	DLFM	UDLFM	SFM	
Gercek Isaretler	-2934	53	0	10	0	0	3	0	0	0	0	
	0	3000	0	0	0	0	0	0	0	0	0	
P1	0	0	2998	1	0	1	0	0	0	0	0	
P2	0	0	0	3000	0	0	0	0	0	0	0	
P3	0	431	0	0	2569	0	0	0	0	0	0	
P4	0	0	222	0	0	2778	0	0	0	0	0	
SCM	0	0	0	0	0	0	3000	0	0	0	0	
ULFM	0	0	0	0	0	0	0	3000	0	0	0	
DLFM	0	0	0	0	0	0	0	0	3000	0	0	
UDLFM	0	0	0	0	0	0	0	0	0	3000	0	
SFM	0	0	0	0	0	0	0	0	0	0	3000	
Tahmin Edilen Isaretler	Barker	Frank	P1	P2	P3	P4	SCM	ULFM	DLFM	UDLFM	SFM	

Şekil 6.27 Choi-Williams Eğitim 0 dB Test 10 dB Hata Matrisi

	Barker	Frank	P1	P2	P3	P4	SCM	ULFM	DLFM	UDLFM	SFM	
Gereklilikler	-2782	24	4	1	122	12	22	16	2	15	0	
Frank	-1032	1624	0	4	328	0	10	1	0	0	1	
P1	-924	20	145	5	57	1843	2	0	4	0	0	
P2	-861	14	63	280	64	1711	3	0	4	0	0	
P3	-143	43	0	0	2807	0	1	3	0	2	1	
P4	-598	2	14	2	58	2326	0	0	0	0	0	
SCM	-733	116	0	0	809	0	1338	2	0	0	2	
ULFM	-15	0	0	0	16	0	0	2969	0	0	0	
DLFM	-178	0	0	0	4	0	0	1	2814	3	0	
UDLFM	-68	0	0	0	21	0	0	0	0	2911	0	
SFM	-167	0	0	0	119	0	1	0	1	9	2703	
	Barker	Frank	P1	P2	P3	P4	SCM	ULFM	DLFM	UDLFM	SFM	Tahmin Edilen İşaretler

Şekil 6.28 Choi-Williams Eğitim 10 dB Test 0 dB Hata Matrisi

	Barker	Frank	P1	P2	P3	P4	SCM	ULFM	DLFM	UDLFM	SFM	
Gercek Isaretler	3000	2990	3000	3000	2968	2987	5	84	47	28	25	
Tahmin Edilen Isaretler	0	0	0	0	0	0	2830	1361	150	142	0	
Barker	0	0	0	0	0	0	0	0	0	0	0	0
Frank	0	0	0	0	0	0	10	0	0	0	0	0
P1	0	0	0	0	0	0	0	0	0	0	0	0
P2	0	0	0	0	0	0	0	0	0	0	0	0
P3	0	0	0	31	0	1	0	0	0	0	0	0
P4	0	0	13	0	0	0	0	0	0	0	0	0
SCM	0	0	0	0	0	0	2830	0	0	0	165	
ULFM	0	0	0	17	0	0	0	1361	51	0	1487	
DLFM	0	0	0	0	0	0	0	150	901	0	1902	
UDLFM	0	0	0	0	0	0	0	142	75	5	2750	
SFM	0	0	0	0	0	0	0	0	0	0	2975	

Şekil 6.29 SCF Eğitim 0 dB Test 10 dB Hata Matrisi

Gercek Isaretler	Barker	Frank	P1	P2	P3	P4	SCM	ULFM	DLFM	UDLFM	SFM	
Tahmin Edilen Isaretler												
Barker -	1039	0	0	0	1	15	0	0	0	0	1945	
Frank -	0	0	0	0	0	49	0	0	0	0	2951	
P1 -	28	0	0	0	0	1458	0	0	0	0	1514	
P2 -	3	0	0	0	0	995	0	0	0	0	2002	
P3 -	0	0	0	0	1	84	0	0	0	0	2915	
P4 -	12	0	0	0	0	1505	0	0	0	0	1483	
SCM -	0	0	0	0	0	0	0	0	0	0	3000	
ULFM -	2795	0	0	0	0	2	0	0	49	9	145	
DLFM -	1560	0	0	0	0	0	0	0	1083	322	35	
UDLFM -	2633	0	0	0	0	0	0	0	91	261	15	
SFM -	0	0	0	0	0	0	0	0	0	0	3000	

Şekil 6.30 SCF Eğitim 10 dB Test 0 dB Hata Matrisi

Sınıflandırıcı modellerinin performansı Kesinlik (Π), Duyarlılık (Ψ), F1-Skor parametreleri ile belirlenir. Kesinlik, pozitif olarak sınıflandırılan değerlerin其实kaç tanesinin pozitif olduğunu ifade etmektedir. Kesinlik değeri yanlış pozitif tahminlemenin maliyetinin yüksek olduğu durumlarda önem arz etmektedir.

$$\Pi = \frac{\xi}{\xi + v} \quad (6.1)$$

Eş. 6.1'de ξ doğru pozitif ve v yanlış pozitif değerlerini göstermektedir. Duyarlılık, pozitif olarak sınıflandırmamız gereken değerlerin ne kadarının pozitif olarak sınıflandırıldığını ifade bir metriktir. Duyarlılık değeri yanlış negatif tahminlemenin maliyetinin yüksek olduğu modellerde önemli bir parametredir.

$$\Psi = \frac{\xi}{\xi + \mu} \quad (6.2)$$

Eş.6.2'de μ yanlış negatif değerini göstermektedir. F1-skor, kesinlik ve duyarlılık metriklerinin harmonik ortalamasıdır ve bir sınıflandırıcı modelinin doğruluğu için genel bir ölçü verir.

$$F_1\text{-score} = 2 \times \frac{\Pi \times \Psi}{\Pi + \Psi} \quad (6.3)$$

Önerilen sınıflandırıcının -10 dB, 0 dB ve 10 dB değerlerindeki performans parametreleri Tablo 6.2-6.21'da verilmektedir. Eğitim ve test verilerinin farklı SNR değerlerine sahip oldukları durumda elde edilen performans parametreleri ise 6.22 - 6.31 numaralı tablolarda verilmektedir.

Tablo 6.2 –20 dB SNR değerindeki STFT özniteligi performansi

SNR	Öznitelik	İşaret	Kesinlik (Π)	Duyarlılık (Ψ)	F1-Skor
–20 dB	STFT	Barker	0.90	0.77	0.83
		Frank	0.20	0.22	0.21
		P1	0.22	0.12	0.16
		P2	0.18	0.17	0.17
		P3	0.26	0.19	0.22
		P4	0.22	0.20	0.21
		SCM	0.60	0.65	0.63
		ULFM	0.27	0.28	0.28
		DLFM	0.26	0.42	0.32
		UDLFM	0.23	0.27	0.25
		SFM	0.36	0.38	0.37
		Ortalama	0.34	0.33	0.33

Tablo 6.3 –20 dB SNR değerindeki FSST özniteligi performansi

SNR	Öznitelik	İşaret	Kesinlik (Π)	Duyarlılık (Ψ)	F1-Skor
–20 dB	FSST	Barker	0.99	1.00	1.00
		Frank	0.32	0.41	0.36
		P1	0.28	0.24	0.26
		P2	0.24	0.23	0.23
		P3	0.36	0.31	0.33
		P4	0.23	0.22	0.23
		SCM	1.00	0.99	1.00
		ULFM	0.30	0.29	0.30
		DLFM	0.31	0.22	0.26
		UDLFM	0.26	0.26	0.26
		SFM	0.44	0.60	0.50
		Ortalama	0.43	0.43	0.43

Tablo 6.4 –20 dB SNR değerindeki SPWVD özniteligi performansı

SNR	Öznitelik	İşaret	Kesinlik (Π)	Duyarlılık (Ψ)	F1-Skor
–20 dB	SPWVD	Barker	0.67	0.81	0.74
		Frank	0.18	0.12	0.15
		P1	0.20	0.10	0.13
		P2	0.20	0.15	0.17
		P3	0.27	0.22	0.24
		P4	0.22	0.30	0.25
		SCM	0.51	0.56	0.53
		ULFM	0.46	0.61	0.52
		DLFM	0.52	0.57	0.54
		UDLFM	0.46	0.49	0.48
		SFM	0.41	0.46	0.43
		Ortalama	0.37	0.40	0.38

Tablo 6.5 –20 dB SNR değerindeki CWD özniteligi performansı

SNR	Öznitelik	İşaret	Kesinlik (Π)	Duyarlılık (Ψ)	F1-Skor
–20 dB	CWD	Barker	0.65	0.72	0.68
		Frank	0.19	0.08	0.11
		P1	0.15	0.08	0.11
		P2	0.15	0.13	0.14
		P3	0.17	0.10	0.12
		P4	0.15	0.17	0.16
		SCM	0.36	0.47	0.41
		ULFM	0.31	0.49	0.38
		DLFM	0.38	0.35	0.36
		UDLFM	0.30	0.45	0.36
		SFM	0.26	0.31	0.29
		Ortalama	0.28	0.30	0.29

Tablo 6.6 – 20 dB SNR değerindeki SCF özniteligi performansi

SNR	Öznitelik	İşaret	Kesinlik (Π)	Duyarlılık (Ψ)	F1-Skor
–20 dB	SCF	Barker	0.81	0.90	0.85
		Frank	0.12	0.60	0.20
		P1	0.13	0.06	0.08
		P2	0.16	0.05	0.07
		P3	0.15	0.16	0.15
		P4	0.16	0.02	0.04
		SCM	0.91	0.90	0.91
		ULFM	0.19	0.14	0.16
		DLFM	0.25	0.16	0.19
		UDLFM	0.19	0.15	0.17
		SFM	0.42	0.01	0.03
		Ortalama	0.32	0.29	0.26

Tablo 6.7 – 10 dB SNR değerindeki STFT özniteligi performansi

SNR	Öznitelik	İşaret	Kesinlik (Π)	Duyarlılık (Ψ)	F1-Skor
–10 dB	STFT	Barker	0.91	0.95	0.93
		Frank	0.82	0.82	0.82
		P1	0.39	0.24	0.30
		P2	0.46	0.36	0.40
		P3	0.83	0.84	0.84
		P4	0.40	0.60	0.48
		SCM	0.97	0.98	0.97
		ULFM	1.00	1.00	1.00
		DLFM	1.00	0.99	0.99
		UDLFM	0.99	0.99	0.99
		SFM	0.98	0.99	0.99
		Ortalama	0.80	0.80	0.80

Tablo 6.8 – 10 dB SNR değerindeki FSST özniteligi performansı

SNR	Öznitelik	İşaret	Kesinlik (Π)	Duyarlılık (Ψ)	F1-Skor	
–10 dB	FSST	Barker	0.99	0.99	0.99	
		Frank	0.91	0.96	0.94	
		P1	0.47	0.51	0.49	
		P2	0.66	0.40	0.50	
		P3	0.96	0.92	0.94	
		P4	0.51	0.67	0.58	
		SCM	0.99	0.99	0.99	
		ULFM	0.96	0.97	0.97	
		DLFM	0.95	0.96	0.96	
		UDLFM	0.95	0.93	0.94	
		SFM	0.99	1.00	1.00	
		Ortalama	0.85	0.85	0.85	

Tablo 6.9 – 10 dB SNR değerindeki SPWVD özniteligi performansı

SNR	Öznitelik	İşaret	Kesinlik (Π)	Duyarlılık (Ψ)	F1-Skor	
–10 dB	SPWVD	Barker	0.89	0.91	0.90	
		Frank	0.73	0.73	0.73	
		P1	0.36	0.28	0.31	
		P2	0.40	0.38	0.39	
		P3	0.74	0.75	0.75	
		P4	0.37	0.47	0.41	
		SCM	0.95	0.94	0.94	
		ULFM	1.00	0.99	1.00	
		DLFM	1.00	1.00	1.00	
		UDLFM	0.99	0.99	0.99	
		SFM	0.99	0.99	0.99	
		Ortalama	0.77	0.77	0.77	

Tablo 6.10 – 10 dB SNR değerindeki CWD özniteligi performansi

SNR	Öznitelik	İşaret	Kesinlik (Π)	Duyarlılık (Ψ)	F1-Skor	
–10 dB	CWD	Barker	0.74	0.81	0.77	
		Frank	0.66	0.69	0.68	
		P1	0.32	0.38	0.35	
		P2	0.39	0.32	0.35	
		P3	0.72	0.69	0.70	
		P4	0.36	0.34	0.34	
		SCM	0.89	0.88	0.89	
		ULFM	1.00	1.00	1.00	
		DLFM	1.00	0.99	1.00	
		UDLFM	1.00	1.00	1.00	
		SFM	0.99	0.98	0.99	
		Ortalama	0.73	0.73	0.73	

Tablo 6.11 – 10 dB SNR değerindeki SCF özniteligi performansı

SNR	Öznitelik	İşaret	Kesinlik (Π)	Duyarlılık (Ψ)	F1-Skor	
–10 dB	SCF	Barker	0.88	0.95	0.91	
		Frank	0.30	0.33	0.31	
		P1	0.26	0.27	0.26	
		P2	0.24	0.12	0.16	
		P3	0.30	0.29	0.29	
		P4	0.28	0.37	0.32	
		SCM	0.96	0.94	0.95	
		ULFM	0.48	0.77	0.59	
		DLFM	0.60	0.56	0.58	
		UDLFM	0.41	0.20	0.27	
		SFM	0.91	0.92	0.92	
		Ortalama	0.51	0.52	0.51	

Tablo 6.12 0 dB SNR değerindeki STFT özniteligi performansı

SNR	Öznitelik	İşaret	Kesinlik (Π)	Duyarlılık (Ψ)	F1-Skor
0 dB	STFT	Barker	1.00	1.00	1.00
		Frank	0.99	0.99	0.99
		P1	0.90	0.78	0.84
		P2	0.87	0.94	0.90
		P3	0.99	1.00	1.00
		P4	0.90	0.96	0.93
		SCM	1.00	1.00	1.00
		ULFM	1.00	1.00	1.00
		DLFM	1.00	1.00	1.00
		UDLFM	1.00	1.00	1.00
		SFM	1.00	1.00	1.00
		Ortalama	0.97	0.97	0.97

Tablo 6.13 0 dB SNR değerindeki FSST özniteligi performansı

SNR	Öznitelik	İşaret	Kesinlik (Π)	Duyarlılık (Ψ)	F1-Skor
0 dB	FSST	Barker	1.00	1.00	1.00
		Frank	1.00	1.00	1.00
		P1	0.91	0.91	0.91
		P2	0.94	0.95	0.95
		P3	1.00	1.00	1.00
		P4	0.96	0.95	0.95
		SCM	1.00	1.00	1.00
		ULFM	1.00	1.00	1.00
		DLFM	1.00	1.00	1.00
		UDLFM	1.00	1.00	1.00
		SFM	1.00	1.00	1.00
		Ortalama	0.98	0.98	0.98

Tablo 6.14 0 dB SNR değerindeki SPWVD özniteligi performansı

SNR	Öznitelik	İşaret	Kesinlik (Π)	Duyarlılık (Ψ)	F1-Skor
0 dB	SPWVD	Barker	1.00	0.99	0.99
		Frank	0.99	0.99	0.99
		P1	0.70	0.70	0.70
		P2	0.93	0.79	0.85
		P3	1.00	0.99	1.00
		P4	0.69	0.81	0.75
		SCM	0.99	1.00	0.99
		ULFM	1.00	1.00	1.00
		DLFM	1.00	1.00	1.00
		UDLFM	1.00	1.00	1.00
		SFM	1.00	1.00	1.00
		Ortalama	0.94	0.93	0.93

Tablo 6.15 0 dB SNR değerindeki CWD özniteligi performansı

SNR	Öznitelik	İşaret	Kesinlik (Π)	Duyarlılık (Ψ)	F1-Skor
0 dB	CWD	Barker	0.99	0.99	0.99
		Frank	1.00	0.99	1.00
		P1	0.83	0.67	0.74
		P2	0.91	0.90	0.91
		P3	1.00	1.00	1.00
		P4	0.77	0.94	0.84
		SCM	1.00	1.00	1.00
		ULFM	1.00	1.00	1.00
		DLFM	1.00	1.00	1.00
		UDLFM	1.00	1.00	1.00
		SFM	1.00	1.00	1.00
		Ortalama	0.95	0.95	0.95

Tablo 6.16 0 dB SNR değerindeki SCF özniteligi performansi

SNR	Öznitelik	İşaret	Kesinlik (Π)	Duyarlılık (Ψ)	F1-Skor
0 dB	SCF	Barker	0.99	0.95	0.97
		Frank	0.61	0.47	0.53
		P1	0.33	0.35	0.34
		P2	0.41	0.30	0.35
		P3	0.55	0.69	0.61
		P4	0.36	0.45	0.40
		SCM	0.97	1.00	0.99
		ULFM	0.82	0.82	0.82
		DLFM	0.73	0.90	0.80
		UDLFM	0.80	0.63	0.70
		SFM	1.00	0.97	0.98
		Ortalama	0.69	0.68	0.68

Tablo 6.17 10 dB SNR değerindeki STFT özniteligi performansi

SNR	Öznitelik	İşaret	Kesinlik (Π)	Duyarlılık (Ψ)	F1-Skor
10 dB	STFT	Barker	1.00	1.00	1.00
		Frank	1.00	1.00	1.00
		P1	1.00	1.00	1.00
		P2	1.00	1.00	1.00
		P3	1.00	1.00	1.00
		P4	1.00	1.00	1.00
		SCM	1.00	1.00	1.00
		ULFM	1.00	1.00	1.00
		DLFM	1.00	1.00	1.00
		UDLFM	1.00	1.00	1.00
		SFM	1.00	1.00	1.00
		Ortalama	1.00	1.00	1.00

Tablo 6.18 10 dB SNR değerindeki FSST özniteligi performansi

SNR	Öznitelik	İşaret	Kesinlik (Π)	Duyarlılık (Ψ)	F1-Skor
10 dB	FSST	Barker	1.00	1.00	1.00
		Frank	1.00	1.00	1.00
		P1	1.00	1.00	1.00
		P2	1.00	1.00	1.00
		P3	1.00	1.00	1.00
		P4	1.00	1.00	1.00
		SCM	1.00	1.00	1.00
		ULFM	1.00	1.00	1.00
		DLFM	1.00	1.00	1.00
		UDLFM	1.00	1.00	1.00
		SFM	1.00	1.00	1.00
		Ortalama	1.00	1.00	1.00

Tablo 6.19 10 dB SNR değerindeki SPWVD özniteligi performansi

SNR	Öznitelik	İşaret	Kesinlik (Π)	Duyarlılık (Ψ)	F1-Skor
10 dB	SPWVD	Barker	1.00	1.00	1.00
		Frank	1.00	1.00	1.00
		P1	1.00	0.86	0.93
		P2	0.98	1.00	0.99
		P3	1.00	1.00	1.00
		P4	0.89	1.00	0.94
		SCM	1.00	1.00	1.00
		ULFM	1.00	1.00	1.00
		DLFM	1.00	1.00	1.00
		UDLFM	1.00	1.00	1.00
		SFM	1.00	1.00	1.00
		Ortalama	0.99	0.99	0.99

Tablo 6.20 10 dB SNR değerindeki CWD özniteligi performansi

SNR	Öznitelik	İşaret	Kesinlik (Π)	Duyarlılık (Ψ)	F1-Skor
10 dB	CWD	Barker	1.00	1.00	1.00
		Frank	1.00	1.00	1.00
		P1	1.00	1.00	1.00
		P2	1.00	1.00	1.00
		P3	1.00	1.00	1.00
		P4	1.00	1.00	1.00
		SCM	1.00	1.00	1.00
		ULFM	1.00	1.00	1.00
		DLFM	1.00	1.00	1.00
		UDLFM	1.00	1.00	1.00
		SFM	1.00	1.00	1.00
		Ortalama	1.00	1.00	1.00

Tablo 6.21 10 dB SNR değerindeki SCF özniteligi performansi

SNR	Öznitelik	İşaret	Kesinlik (Π)	Duyarlılık (Ψ)	F1-Skor
10 dB	SCF	Barker	1.00	1.00	1.00
		Frank	0.85	0.71	0.77
		P1	0.56	0.56	0.56
		P2	0.81	0.77	0.79
		P3	0.75	0.89	0.81
		P4	0.59	0.62	0.60
		SCM	1.00	1.00	1.00
		ULFM	0.94	0.94	0.94
		DLFM	0.93	0.94	0.93
		UDLFM	0.96	0.96	0.96
		SFM	1.00	1.00	1.00
		Ortalama	0.85	0.85	0.85

Tablo 6.22 STFT özniteliği performansı - Eğitim 0 dB Test 10 dB

SNR	Öznitelik	İşaret	Kesinlik (Π)	Duyarlılık (Ψ)	F1-Skor
0 dB-10 dB	STFT	Barker	0.90	1.00	0.95
		Frank	1.00	1.00	1.00
		P1	1.00	0.81	0.90
		P2	0.99	0.82	0.89
		P3	1.00	0.86	0.93
		P4	1.00	0.35	0.52
		SCM	0.49	1.00	0.66
		ULFM	1.00	1.00	1.00
		DLFM	1.00	0.98	0.99
		UDLFM	0.98	1.00	0.99
		SFM	1.00	1.00	1.00
		Ortalama	0.94	0.89	0.89

Tablo 6.23 STFT özniteliği performansı - Eğitim 10 dB Test 0 dB

SNR	Öznitelik	İşaret	Kesinlik (Π)	Duyarlılık (Ψ)	F1-Skor
10 dB-0 dB	STFT	Barker	0.51	0.97	0.67
		Frank	0.73	0.67	0.70
		P1	0.57	0.62	0.60
		P2	0.83	0.61	0.70
		P3	0.79	0.74	0.77
		P4	0.78	0.60	0.68
		SCM	0.83	0.62	0.71
		ULFM	0.97	0.88	0.92
		DLFM	0.99	0.92	0.95
		UDLFM	0.97	0.95	0.96
		SFM	0.85	0.92	0.88
		Ortalama	0.80	0.77	0.78

Tablo 6.24 FSST özniteliği performansı - Eğitim 0 dB Test 10 dB

SNR	Öznitelik	İşaret	Kesinlik (Π)	Duyarlılık (Ψ)	F1-Skor
0 dB-10 dB	FSST	Barker	1.00	1.00	1.00
		Frank	1.00	1.00	1.00
		P1	1.00	1.00	1.00
		P2	1.00	1.00	1.00
		P3	1.00	1.00	1.00
		P4	1.00	1.00	1.00
		SCM	1.00	1.00	1.00
		ULFM	1.00	1.00	1.00
		DLFM	1.00	1.00	1.00
		UDLFM	1.00	1.00	1.00
		SFM	1.00	1.00	1.00
		Ortalama	1.00	1.00	1.00

Tablo 6.25 FSST özniteliği performansı - Eğitim 10 dB Test 0 dB

SNR	Öznitelik	İşaret	Kesinlik (Π)	Duyarlılık (Ψ)	F1-Skor
10 dB-0 dB	FSST	Barker	1.00	1.00	1.00
		Frank	0.95	1.00	0.97
		P1	0.58	0.95	0.73
		P2	0.94	0.70	0.80
		P3	0.99	0.98	0.98
		P4	0.94	0.58	0.71
		SCM	0.99	1.00	1.00
		ULFM	0.99	0.95	0.97
		DLFM	0.99	0.94	0.96
		UDLFM	0.91	0.97	0.94
		SFM	1.00	1.00	1.00
		Ortalama	0.93	0.91	0.92

Tablo 6.26 SPWVD özniteliği performansı - Eğitim 0 dB Test 10 dB

SNR	Öznitelik	İşaret	Kesinlik (Π)	Duyarlılık (Ψ)	F1-Skor
0 dB-10 dB	SPWVD	Barker	1.00	0.90	0.95
		Frank	1.00	1.00	1.00
		P1	0.97	0.67	0.79
		P2	0.93	1.00	0.96
		P3	1.00	1.00	1.00
		P4	0.75	1.00	0.86
		SCM	1.00	1.00	1.00
		ULFM	1.00	1.00	1.00
		DLFM	1.00	1.00	1.00
		UDLFM	1.00	1.00	1.00
		SFM	1.00	1.00	1.00
		Ortalama	0.97	0.96	0.96

Tablo 6.27 SPWVD özniteliği performansı - Eğitim 10 dB Test 0 dB

SNR	Öznitelik	İşaret	Kesinlik (Π)	Duyarlılık (Ψ)	F1-Skor
10 dB-0 dB	SPWVD	Barker	0.81	0.85	0.83
		Frank	0.56	0.65	0.60
		P1	0.45	0.68	0.54
		P2	0.45	0.45	0.45
		P3	0.80	0.73	0.76
		P4	0.65	0.44	0.52
		SCM	0.75	0.46	0.57
		ULFM	0.98	1.00	0.99
		DLFM	0.96	0.97	0.97
		UDLFM	0.97	0.99	0.98
		SFM	0.97	0.99	0.98
		Ortalama	0.76	0.75	0.75

Tablo 6.28 CWD özniteliği performansı - Eğitim 0 dB Test 10 dB

SNR	Öznitelik	İşaret	Kesinlik (Π)	Duyarlılık (Ψ)	F1-Skor
0 dB-10 dB	CWD	Barker	1.00	0.98	0.99
		Frank	0.86	1.00	0.93
		P1	0.93	1.00	0.96
		P2	1.00	1.00	1.00
		P3	1.00	0.86	0.92
		P4	1.00	0.93	0.96
		SCM	1.00	1.00	1.00
		ULFM	1.00	1.00	1.00
		DLFM	1.00	1.00	1.00
		UDLFM	1.00	1.00	1.00
		SFM	1.00	1.00	1.00
		Ortalama	0.98	0.97	0.98

Tablo 6.29 CWD özniteliği performansı - Eğitim 10 dB Test 0 dB

SNR	Öznitelik	İşaret	Kesinlik (Π)	Duyarlılık (Ψ)	F1-Skor
10 dB-0 dB	CWD	Barker	0.37	0.92	0.53
		Frank	0.88	0.54	0.67
		P1	0.64	0.05	0.09
		P2	0.95	0.09	0.17
		P3	0.64	0.94	0.76
		P4	0.39	0.78	0.52
		SCM	0.97	0.45	0.61
		ULFM	0.99	0.99	0.99
		DLFM	1.00	0.94	0.97
		UDLFM	0.99	0.97	0.98
		SFM	1.00	0.90	0.95
		Ortalama	0.80	0.69	0.66

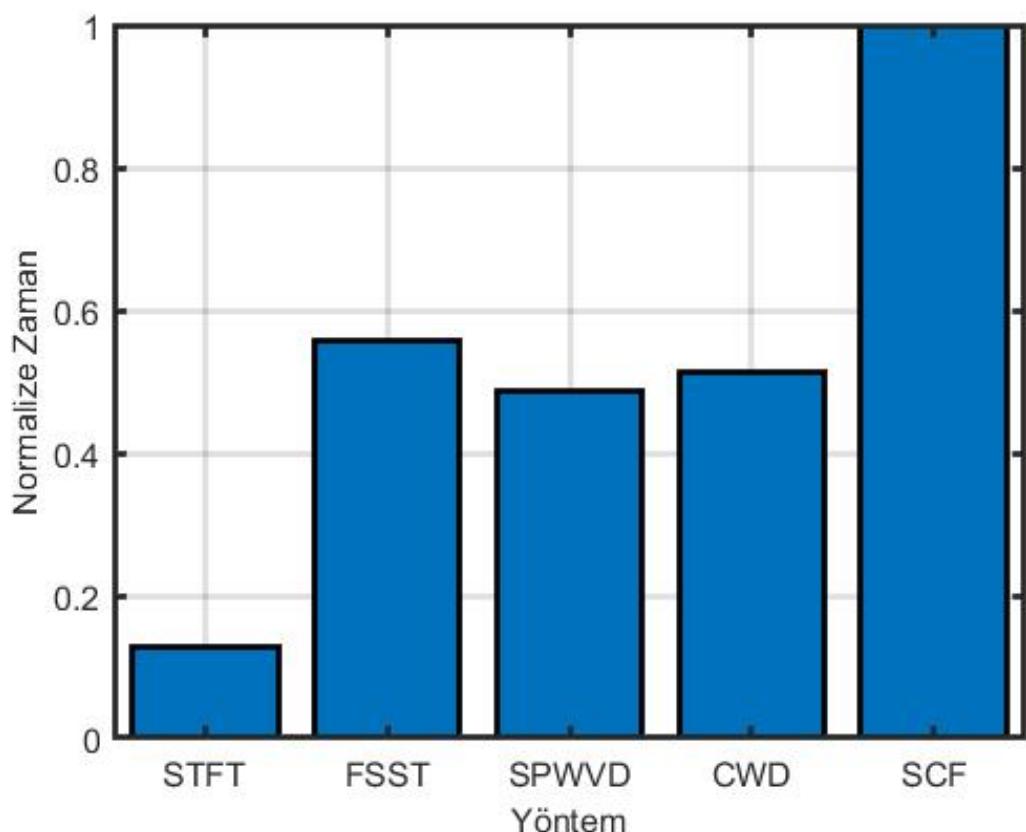
Tablo 6.30 SCF özniteliği performansı - Eğitim 0 dB Test 10 dB

SNR	Öznitelik	İşaret	Kesinlik (Π)	Duyarlılık (Ψ)	F1-Skor
0 dB-10 dB	SCF	Barker	0.17	1.00	0.29
		Frank	NaN	0.00	NaN
		P1	NaN	0.00	NaN
		P2	NaN	0.00	NaN
		P3	0.00	0.00	NaN
		P4	0.00	0.00	NaN
		SCM	1.00	0.94	0.97
		ULFM	0.82	0.45	0.59
		DLFM	0.88	0.30	0.45
		UDLFM	1.00	0.002	0.003
		SFM	0.32	0.99	0.48
		Ortalama	0.38	0.33	0.25

Tablo 6.31 SCF özniteliği performansı - Eğitim 10 dB Test 0 dB

SNR	Öznitelik	İşaret	Kesinlik (Π)	Duyarlılık (Ψ)	F1-Skor
10 dB-0 dB	SCF	Barker	0.13	0.35	0.19
		Frank	NaN	0.00	NaN
		P1	NaN	0.00	NaN
		P2	NaN	0.00	NaN
		P3	0.5	3e-4	6e-4
		P4	0.37	0.50	0.42
		SCM	NaN	0.00	NaN
		ULFM	NaN	0.00	NaN
		DLFM	0.89	0.36	0.51
		UDLFM	0.44	0.09	0.15
		SFM	0.16	0.52	0.24
		Ortalama	0.19	0.17	0.14

Şekil 6.31'de bu çalışmada kullanılan işaret işleme yöntemlerinin zaman maliyetleri verilmektedir. Zaman değerleri en yüksek maliyete sahip olan SCF yöntemine göre normalize edilerek verilmiştir. Şekilden görüldüğü üzere FSST, SPWVD ve CWD yöntemleri yaklaşık olarak aynı zaman maliyetine sahiptir. STFT en düşük zaman maliyetine sahip yöntem olmuştur.



Şekil 6.31 İşaret İşleme Yöntemlerinin Zaman Maliyeti

7 SONUÇ

Pasif radar dinleme sistemlerinde tehdit radarlarının kimliklendirmesi için darbe içi modülasyon parametresinin tespiti önem arz etmektedir. Özellikle darbe tanımlama kelimesi içerisinde yer alan parametreler birden fazla tehdite işaret edebilmektedir. Tehdit radarlarını kimliklendirmek için darbe tanımlama kelimesindeki parametrelerin yeterli olmadığı durumlarda darbe içi modülasyon parametresi kullanılabilmektedir. Darbe İçi modülasyon parametresinin tespiti için farklı sinyal işleme ve öğrenme tabanlı algoritmalar kullanılmaktadır. Bu çalışma kapsamında literatürde farklı alanlarda kullanılan algoritmalar radar darbe içi modülasyon sınıflandırmasında kullanılmış ve performans karşılaştırmaları yapılmıştır.

Öncelikle bu algoritmaların performans analizlerinde kullanılacak kapsamlı bir veri seti bilgisayar simülasyonu ortamında üretilmiştir. Çeşitli faz ve frekans modüleli işaretleri içeren 11 sınıfı bir veri seti üretilmiştir. Algoritmaların performanslarını farklı sinyal parametreleri ile inceleyebilmek için veri setindeki sinyaller farklı darbe genişliği, çip sayısı, SNR değeri, bantgenişliği değerlerine sahip olacak şekilde üretilmiştir. Veri setindeki her bir sınıfa ait 3000 adet sinyal üretilmiştir. Bütün sinyallere ön işleme aşamasında farklı sinyal işleme teknikleri uygulanmıştır ve CNN yapısı kullanılarak sinyalin modülasyon tipi tespit edilmiştir.

Bu çalışma kapsamında ön işleme aşamasında Kısa Zaman Fourier Dönüşümü, Fourier Synchrosqueezed Dönüşümü, Düzleştirilmiş Sözde Wigner-Ville Dağılımı, Choi-Wiiliams Dağılımı ve Çevrimsel Durağan Sinyal Analizi gibi sinyal işleme yöntemleri kullanılmıştır. Ön işleme aşamasından sonra elde edilen görüntüler CNN yapısına girdi olarak verilerek sınıflandırma gerçekleştirilmiştir.

STFT, FSST, PSWVD ve CWD öznitelikleri kullanılarak sınıflandırma gerçekleştirildiğinde -10 dB SNR değerinde sırasıyla %80, %85, %77 ve %73 sınıflandırıcı başarımı elde edilmiştir. Bu özniteliklerin çoklu faz kodlu modülasyona sahip olan işaretlerin faz değişiminden kaynaklanan frekans değişimi zaman-frekans imgelerinde çok belirgin

olmadığından dolayı, modelin bu işaretleri düşük SNR bölgesinde ayırmakta zorlandığı görülmüştür. SNR değeri arttıkça zaman-frekans imgelerinin ayırt ediciliği arttığında dolayı 0 dB SNR değerinde 4 öznitelik için en düşük %94 ve 10 dB SNR değerinde en düşük %99 başarıım elde edilmiştir. SCF radar işaretlerini ayırt edebilmek için gerekli olan zamansal bilgileri içermediği için sınıflandırıcı başarımı diğer özniteliklere göre daha düşük kalmaktadır. SCF diğer özniteliklerden farklı olarak zaman-frekans bilgisini içermediği için frekans modüleli işaretlerde de düşük bir sınıflandırıcı performansı göstermektedir.

SNR değerinin sınıflandırıcı başarımı üzerindeki etkisini incelemek için farklı SNR değerlerine sahip eğitim ve test verileri oluşturulmuştur ve farklı öznitelikler için önerilen sınıflandırıcının başarımı incelenmiştir. Eğitim seti SNR değeri düşük, test seti SNR değeri yüksek olduğunda sınıflandırıcı performansı ciddi bir şekilde etkilenmemektedir. Bu durumun aksine, eğitim verisinin SNR değeri yüksek test verisinin SNR değeri düşük olduğunda sınıflandırıcının performansında ciddi bir azalma gözlemlenmektedir. Bu çalışmada kullanılan beş öznitelik arasında kullanılan verilerin SNR değerlerinin farklı olmasından en azından etkilenen öznitelik FSST olmuştur.

Düşük SNR değerinde zaman-frekans imgesini kullanan yöntemler modülasyon tiplerini ayırt etmekte benzer davranışlılardır. Frekans değişimi zamana bağlı olarak ifade edildiği için frekans modülasyonuna sahip işaretler düşük SNR değerinde bile başarılı şekilde ayırt edilebilmiştir. Faz bilgisinin değişimi zaman-frekans imgelerinde ayırt ediciliğe sahip olmadığı için faz modülasyonlu işaretler birbirine karıştırılmıştır. Düşük SNR değerlerinde faz modülasyonu işaretleri en iyi ayırt edebilen öznitelik FSST olmuştur ancak frekans modülasyonlu işaretlerde ise STFT daha iyi başarıım göstermiştir. SNR değeri arttıkça zaman-frekans imgeleri daha belirgin bir hale geldiği için yüksek SNR değerinde bütün zaman-frekans tabanlı yöntemler çok başarılı şekilde modülasyon tiplerini ayırt edebilmektedir. Düşük SNR değerine sahip işaretlerde faz modülasyonlu işaretler için FSST frekans modülasyonlu işaretler için STFT kullanılması önerilmektedir.

Gelecek çalışmalarda öznitelik füzyonu ile hem faz hem de frekans modülasyonlu işaretleri aynı anda düşük SNR değerlerinde başarı ile ayırt edebilecek yöntemler üzerine çalışılabilir.

Ek olarak, CNN mimarisinin yanında Uzun Kısa Vadeli Hafıza Ağları (Long Short Term Memory, LSTM) mimarisi gibi farklı derin öğrenme yapıları kullanılarak modülasyon tipi sınıflandırılabilir.

KAYNAKLAR

- [1] Phillip E Pace. *Detecting and classifying low probability of intercept radar*. Artech house, **2009**.
- [2] Cohen Leon. Time-frequency analysis: theory and applications. *USA: Prentice Hall, 1995*.
- [3] Thomas Oberlin, Sylvain Meignen, and Valérie Perrier. The fourier-based synchrosqueezing transform. In *2014 IEEE international conference on acoustics, speech and signal processing (ICASSP)*, pages 315–319. IEEE, **2014**.
- [4] Gyuyeol Kong and Visa Koivunen. Radar waveform recognition using fourier-based synchrosqueezing transform and cnn. In *2019 IEEE 8th International Workshop on Computational Advances in Multi-Sensor Adaptive Processing (CAMSAP)*, pages 664–668. IEEE, **2019**.
- [5] Leon Cohen. Time-frequency distributions-a review. *Proceedings of the IEEE*, 77(7):941–981, **1989**.
- [6] Jechang Jeong and William J Williams. Kernel design for reduced interference distributions. *IEEE Transactions on Signal Processing*, 40(2):402–412, **1992**.
- [7] Franz Hlawatsch, Thulasinath G Manickam, Rüdiger L Urbanke, and William Jones. Smoothed pseudo-wigner distribution, choi-williams distribution, and cone-kernel representation: Ambiguity-domain analysis and experimental comparison. *Signal Processing*, 43(2):149–168, **1995**.
- [8] H-I Choi and William J Williams. Improved time-frequency representation of multicomponent signals using exponential kernels. *IEEE Transactions on Acoustics, Speech, and Signal Processing*, 37(6):862–871, **1989**.
- [9] William A Gardner. Exploitation of spectral redundancy in cyclostationary signals. *IEEE Signal processing magazine*, 8(2):14–36, **1991**.

- [10] Georgios B Giannakis and VK Madisetti. Cyclostationary signal analysis. In *Digital Signal Processing Handbook*, volume 31, pages 1–17. Citeseer, **1998**.
- [11] William A Gardner and Chad M Spooner. The cumulant theory of cyclostationary time-series. i. foundation. *IEEE Transactions on signal processing*, 42(12):3387–3408, **1994**.
- [12] Randy S Roberts, William A Brown, Herschel H Loomis, and JR H E L H. Computationally efficient algorithms for cyclic spectral analysis. *IEEE Signal Processing Magazine*, 8(2):38–49, **1991**.
- [13] MATLAB. *version 7.10.0 (R2010a)*. The MathWorks Inc., Natick, Massachusetts, **2010**.
- [14] Fahed Hameed, Octavia A Dobre, and Dimitrie C Popescu. On the likelihood-based approach to modulation classification. *IEEE Transactions on Wireless Communications*, 8(12):5884–5892, **2009**.
- [15] Prokopios Panagiotou, Achilles Anastasopoulos, and A Polydoros. Likelihood ratio tests for modulation classification. In *MILCOM 2000 Proceedings. 21st Century Military Communications. Architectures and Technologies for Information Superiority (Cat. No. 00CH37155)*, volume 2, pages 670–674. IEEE, **2000**.
- [16] Ersin Yar, Mehmet Burak Kocamis, Adnan Orduyilmaz, Mahmut Serin, and Murat Efe. A complete framework of radar pulse detection and modulation classification for cognitive ew. In *2019 27th European Signal Processing Conference (EUSIPCO)*, pages 1–5. IEEE, **2019**.
- [17] Adnan Orduyilmaz, Ersin Yar, Mehmet Burak Kocamis, Mahmut Serin, and Murat Efe. Machine learning-based radar waveform classification for cognitive ew. *Signal, Image and Video Processing*, 15(8):1653–1662, **2021**.

- [18] Gyuyeol Kong, Minchae Jung, and Visa Koivunen. Waveform recognition in multipath fading using autoencoder and cnn with fourier synchrosqueezing transform. In *2020 IEEE International Radar Conference (RADAR)*, pages 612–617. IEEE, **2020**.
- [19] Jarmo Lundén and Visa Koivunen. Automatic radar waveform recognition. *IEEE Journal of Selected Topics in Signal Processing*, 1(1):124–136, **2007**.
- [20] Yongjian Liu, Peng Xiao, Hongchao Wu, and Weihua Xiao. 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**.
- [21] Raja Kumari Chilukuri, Hari Kishore Kakarla, and K Subbarao. Estimation of modulation parameters of lpi radar using cyclostationary method. *Sensing and Imaging*, 21(1):1–20, **2020**.
- [22] Antonio F Lime Jr. Analysis of low probability of intercept (lpi) radar signals using cyclostationary processing. Technical report, NAVAL POSTGRADUATE SCHOOL MONTEREY CA, **2002**.
- [23] Kürşat Tekbiyik, Özkan Akbunar, Ali Riza Ekti, Ali Görçin, and Güneş Karabulut Kurt. Multi-dimensional wireless signal identification based on support vector machines. *IEEE Access*, 7:138890–138903, **2019**.
- [24] Kürşat Tekbiyik, Özkan Akbunar, Ali Rıza Ekti, Ali Görçin, Güneş Karabulut Kurt, and Khalid A Qaraqe. Spectrum sensing and signal identification with deep learning based on spectral correlation function. *IEEE Transactions on Vehicular Technology*, 70(10):10514–10527, **2021**.
- [25] Sagar Sharma, Simone Sharma, and Anidhya Athaiya. Activation functions in neural networks. *towards data science*, 6(12):310–316, **2017**.
- [26] Jun Han and Claudio Moraga. The influence of the sigmoid function parameters on the speed of backpropagation learning. In *International workshop on artificial neural networks*, pages 195–201. Springer, **1995**.

- [27] Chigozie Nwankpa, Winifred Ijomah, Anthony Gachagan, and Stephen Marshall. Activation functions: Comparison of trends in practice and research for deep learning. *arXiv preprint arXiv:1811.03378*, **2018**.
- [28] Bekir Karlik and A Vehbi Olgac. Performance analysis of various activation functions in generalized mlp architectures of neural networks. *International Journal of Artificial Intelligence and Expert Systems*, 1(4):111–122, **2011**.
- [29] Prajit Ramachandran, Barret Zoph, and Quoc V Le. Searching for activation functions. *arXiv preprint arXiv:1710.05941*, **2017**.
- [30] Vinod Nair and Geoffrey E Hinton. Rectified linear units improve restricted boltzmann machines. In *Icmi*. **2010**.
- [31] Andrew L Maas, Awni Y Hannun, Andrew Y Ng, et al. Rectifier nonlinearities improve neural network acoustic models. In *Proc. icml*, volume 30, page 3. Citeseer, **2013**.
- [32] Shiliang Sun, Zehui Cao, Han Zhu, and Jing Zhao. A survey of optimization methods from a machine learning perspective. *IEEE transactions on cybernetics*, 50(8):3668–3681, **2019**.
- [33] Herbert Robbins and Sutton Monro. A stochastic approximation method. *The annals of mathematical statistics*, pages 400–407, **1951**.
- [34] John Duchi, Elad Hazan, and Yoram Singer. Adaptive subgradient methods for online learning and stochastic optimization. *Journal of machine learning research*, 12(7), **2011**.
- [35] Geoffrey Hinton, Nitish Srivastava, and Kevin Swersky. Neural networks for machine learning lecture 6a overview of mini-batch gradient descent. *Cited on*, 14(8):2, **2012**.
- [36] Diederik P Kingma and Jimmy Ba. Adam: A method for stochastic optimization. *arXiv preprint arXiv:1412.6980*, **2014**.

- [37] Merima Kulin, Tarik Kazaz, Ingrid Moerman, and Eli De Poorter. End-to-end learning from spectrum data: A deep learning approach for wireless signal identification in spectrum monitoring applications. *IEEE Access*, 6:18484–18501, **2018**.
- [38] Zhiyu Qu, Xiaojie Mao, and Zhian Deng. Radar signal intra-pulse modulation recognition based on convolutional neural network. *IEEE Access*, 6:43874–43884, **2018**.
- [39] Zhiyu Qu, Wenyang Wang, Changbo Hou, and Chenfan Hou. Radar signal intra-pulse modulation recognition based on convolutional denoising autoencoder and deep convolutional neural network. *IEEE Access*, 7:112339–112347, **2019**.
- [40] Bunlong Lay and Alexander Charlish. Classifying lpi signals with transfer learning on cnn architectures. In *2020 Sensor Signal Processing for Defence Conference (SSPD)*, pages 1–5. IEEE, **2020**.
- [41] Fatih Cagatay Akyon, Yasar Kemal Alp, Gokhan Gok, and Orhan Arikan. Classification of intra-pulse modulation of radar signals by feature fusion based convolutional neural networks. In *2018 26th European Signal Processing Conference (EUSIPCO)*, pages 2290–2294. IEEE, **2018**.
- [42] Pavel Itkin and Nadav Levanon. Ambiguity function based radar waveform classification and unsupervised adaptation using deep cnn models. In *2019 IEEE International Conference on Microwaves, Antennas, Communications and Electronic Systems (COMCAS)*, pages 1–6. IEEE, **2019**.
- [43] Weijian Si, Chenxia Wan, and Zhian Deng. Intra-pulse modulation recognition of dual-component radar signals based on deep convolutional neural network. *IEEE Communications Letters*, 25(10):3305–3309, **2021**.
- [44] Chao Wang, Jian Wang, and Xudong Zhang. Automatic radar waveform recognition based on time-frequency analysis and convolutional neural network.

- In *2017 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, pages 2437–2441. IEEE, **2017**.
- [45] Karen Simonyan and Andrew Zisserman. Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv:1409.1556*, **2014**.
- [46] Kaiming He, Xiangyu Zhang, Shaoqing Ren, and Jian Sun. Deep residual learning for image recognition. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, pages 770–778. **2016**.
- [47] Christian Szegedy, Sergey Ioffe, Vincent Vanhoucke, and Alexander A Alemi. Inception-v4, inception-resnet and the impact of residual connections on learning. In *Thirty-first AAAI conference on artificial intelligence*. **2017**.
- [48] Gao Huang, Zhuang Liu, Laurens Van Der Maaten, and Kilian Q Weinberger. Densely connected convolutional networks. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, pages 4700–4708. **2017**.
- [49] Mark Sandler, Andrew Howard, Menglong Zhu, Andrey Zhmoginov, and Liang-Chieh Chen. Mobilenetv2: Inverted residuals and linear bottlenecks. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, pages 4510–4520. **2018**.
- [50] Fatih Cagatay Akyon. *Deep learning in electronic warfare systems: automatic pulse detection and intra-pulse modulation recognition*. Ph.D. thesis, Bilkent University, **2020**.