




Kabul Edilmiş Araştırma Makalesi (Düzenlenmemiş Sürüm)

Accepted Research Article (Uncorrected Version)

Makale Başlığı / Title

Bilişsel radyo uygulamaları için otomatik modülasyon sınıflandırma algoritmaları araştırması

A survey of automatic modulation classification algorithms for cognitive radio applications

Yazarlar / Authors

Hüseyin CUKUR1*, Ahmet SERBES2

Referans No / Reference No

PAJES-89896

DOI

10.5505/pajes.2018.89896

Bu PDF dosyası yukarıda bilgileri verilen kabul edilmiş araştırma makalesini içermektedir. Sayfa düzeni, dizgileme ve son inceleme işlemleri henüz tamamlanmamış olduğundan, bu düzenlenmemiş sürüm bazı üretim ve dizgi hataları içerebilir.

This PDF file contains the accepted research article whose information given above. Since copyediting, typesetting and final review processes are not completed yet, this uncorrected version may include some production and typesetting errors.



Bilişsel radyo uygulamaları için otomatik modülasyon sınıflandırma algoritmaları araştırması

A survey of automatic modulation classification algorithms for cognitive radio applications

Hüseyin CUKUR^{1*}, Ahmet SERBES²

^{1,2}Elektronik ve Haberleşme Mühendisliği Bölümü, Elektrik-Elektronik Fakültesi, Yıldız Teknik Üniversitesi, İstanbul, Türkiye.
hcukur@yildiz.edu.tr, aserb@yildiz.edu.tr

Geliş Tarihi/Received: 19.07.2018, Kabul Tarihi/Accepted: 13.12.2018
* Yazışılan yazar/Corresponding author

doi: 10.5505/pajes.2018.89896
Derleme Makalesi/Review Article

Öz

Bu çalışmada, farklı modülasyon tanıma tekniklerinin kapsamlı bir araştırması sistematik bir şekilde sunulmaktadır. Otomatik modülasyon tanımlama algoritmalarının genel iki sınıfı olan maksimum olabilirlik ve öznelik tabanlı yöntemler ayrıntılı olarak tartışılmaktadır. Çok sayıda makalenin modülasyon sınıflandırma problemlerine olan katkıları, derli toplu formlarda özetlenmiş ve bu sayede okuyucunun her tekniğin temel özelliklerini görmesi sağlanmaya çalışılmıştır. Çalışmanın sonunda ise, açık problemler ve gelecekteki araştırmalar için muhtemel yönler kısaca tartışılmaktadır.

Anahtar kelimeler: Otomatik modülasyon sınıflandırma, öznelik çıkarımı, maksimum olabilirlik teoremi, doğru sınıflandırma olasılığı

Abstract

In this study, a comprehensive investigation of different modulation recognition techniques is presented in a systematic way. Two general classes of automatic modulation identification algorithms, maximum likelihood and feature-based methods, are discussed in detail. The contributions to the problem of modulation classification of a large number of articles have been summarized in compact form, and it has been tried to ensure that the readers see the basic properties of each technique. At the end of the study, open problems and possible directions for future research are briefly discussed.

Keywords: Automatic modulation classification, Feature extraction, Maximum likelihood method, Probability of correct classification

1 Giriş

Başlangıçta Mitola [1] tarafından ortaya konan Bilişsel Radyo (Cognitive Radio, CR), Amerikan Federal İletişim Komisyonu (Federal Communications Commission, FCC) tarafından 2002 yılında ABD'deki frekans spektrumunun daha iyi kullanılmasını hedefleyen bir rapor yayınladığından beri iletişimde önemli bir araştırma alanı haline gelmiştir [2]. CR, kullanılmayan frekans bantlarını bularak ve kullanarak daha iyi spektrum kullanımı sağlayabilecek ümit vaat eden bir teknolojidir [1]. CR'nin önemli özellikleri, çevreyi algılamak, gözlemlere ve görev hedeflerine dayanarak karar verme yeteneğine sahip olması ve geçmiş deneyimlerden öğrendiği bilgileri gelecekteki karar alma süreçlerinde kullanmasıdır. Spektrum algılama, spektrum yönetimi, spektrum mobilitesi ve spektrum paylaşımı CR'nin asıl fonksiyonları olarak karşımıza çıkmaktadır.

Bilişsel Radyo Ağı (Cognitive Radio Network, CRN), mevcut ağ koşullarını gözlemleyebilen, planlayan, karar verebilen ve daha sonra bu koşullara göre hareket edebilen bir bilişsel süreç sahip bir CR düğümleri ağıdır. CRN, bu uyarlamalardan öğrenebilir ve uçtan uca hedefleri göz önünde bulundurarak gelecekteki kararları vermek için öğrendiği bu bilgileri kullanabilir [3, 4]. CRN, mevcut kaynakları (güç, bant genişliği, vb.) optimize etme ve ortam katmanına göre fiziksel katman dâhil olmak üzere protokol yığınının her katmanını uyarlama yeteneğine sahiptirler. Güvenli, güvenilir ve sorunsuz iletişim için çeşitli standartlar ve garantili hizmet kalitesi (Quality of Service, QoS) arasında birlikte işlerlik için ihtiyaçların olduğu askeri ve kamu güvenliği uygulamaları ile QoS'in servis kullanılabilirliğini, güvenilir ve hızlı veri aktarımını içerdiği ticari uygulamalar CRN'nin çeşitli potansiyel uygulamaları olarak karşımıza çıkmaktadır [5]. Buna ek olarak askeri ve kamu güvenliği uygulamaları için, CR'ler çok zorlu ortamlarda,

çok sayıda farklı unsur arasında, sıkışan saldırılara ve kötü niyetli müdahaleye karşı hassas olan sabit ve hareket halindeki iletişimlerini gerçekleştirmektedirler [6]. Askeri uygulamalarda, düşman sinyali hakkında hiçbir bilgi yoktur ve dolayısıyla CR'ye ait alıcının düşman sinyalinde kullanılan modülasyon formatını tanımlaması gerekir. Otomatik modülasyon sınıflandırması (Automatic Modulation Classification, AMC), alınan sinyaldeki modülasyon formatını tanımlayabilen bir sinyal işleme bileşenidir. Özellikle kör modülasyon tanıma olarak nitelendirilen ve gelen sinyal hakkında hiçbir bilgiye sahip olunmadan gerçekleştirilen AMC işlemi, birçok CR uygulaması açısından çok önemli bir yer tutmaktadır. AMC'nin özellikle askeri uygulamalarda önemli bir yeri vardır. Günümüzde kablosuz haberleşme, sahada en fazla kullanılan haberleşme yöntemidir. Haberleşen karşıt unsurların:

- Frekansını
- Konumunu
- modülasyon tipini
- anten sayısını
- kodlama yöntemini
- varsa şifresini

kestirmek her biri önemli birer problemdir. Bu tip teknolojilerin dahil edildiği elektronik izleme sistemlerinin üstünlüğü tartışılmaz bir gerçektir.

1.1 Otomatik Modülasyon Sınıflandırma

Vericinin, sinyallerin nasıl modüle edileceğini seçme özgürlüğü var iken, alıcının ise iletimin başarılı olabilmesi için sinyalin demodülasyonu için modülasyon tipi bilgisine sahip olması gerekmektedir. Aksi durumda orijinal mesaj işaretini geri elde etmek mümkün olmayabilir. Modülasyon tipini elde etmenin kolay bir yolu, iletim sırasında modülasyon tipi bilgisini de

alıcıya göndermektir. Böylece alıcılar, modülasyon hakkında bilgilendirilecek ve buna göre demodülasyon adımını gerçekleştireceklerdir. Bu strateji, her sinyal çerçevesindeki ekstra modülasyon bilgisine bağlı olarak spektrum verimliliğini düşürür. Kablesuz spektrumun son derece sınırlı ve değerli olduğu mevcut durumda, yukarıda belirtilen strateji yeterince verimli değildir. Ayrıca veri güvenliği açısından da kullanılan modülasyon türünün işaret ile birlikte gönderilmesi büyük bir sorun arz etmektedir. Bu nedenle de modülasyon tipi bilgisi alıcıya ekstrasıdan gönderilmemektedir.

AMC, ilk olarak, elektronik harp (EW), gözetleme ve tehdit analizinin, düşman haberleşme ünitelerini tanımlamak, parazit sinyallerini hazırlamak ve yakalanan sinyali kurtarmak için sinyal modülasyonlarının tanınmasını gerektirdiği askeri senaryolarda uygulanmıştır. AMC'nin ilk uygulamaları sinyallerin gözlem ve işleme ekipmanı yardımıyla mühendisler tarafından manuel olarak işlenmesiyle elle yapılmaktaydı. Fakat son 20 yılda geliştirilen birçok modülasyon sınıflandırıcısı, elektronik işlemciler aracılığıyla ve genellikle gelişmiş istatistiksel işaret işleme algoritmaları kullanılarak gerçekleştirilmektedir.

Mikroişlemcilerdeki gelişmeler sayesinde, alıcılar günümüzde hesaplama gücü açısından çok daha etkin hale gelmişlerdir ve böylece AMC algoritmalarının gerektirdiği sinyal işleme mümkün hale gelmiştir. Alınan sinyalin modülasyon tipinin otomatik olarak tanımlanmasıyla, vericide gönderilen mesaj işareti demodüle edilebilir ve gönderilmek istenen mesaj bilgisine ulaşılabilir. AMC, askeri ve askeri olmayan bilişsel radyo ve yazılım tanımlı radyo dâhil olmak üzere akıllı radyo sistemlerinin bir parçası haline gelmiştir. Şekil 1'de örnek bir AMC yapısı gösterilmektedir.

AMC için literatürde modülasyon tanıma, otomatik modülasyon tanıma, modülasyon tanımlama, modülasyon sınıflandırması ve otomatik modülasyon sınıflandırması gibi birçok alternatif terim kullanılmaktadır. Bununla birlikte literatürde çok özel problemlerin çözümü için farklı tanımlamalar kullanılmaktadır. Birçok literatürdeki bazı çalışmalar sadece bir modülasyon tipini belirlemeye yöneliktir. Örneğin, sadece PSK işaretlerinin tipi otomatik olarak tanınacaksa PSK sınıflandırması veya sadece QAM işaretlerinin kaçı olacağı otomatik olarak tanıınıyorsa M-QAM sınıflandırması gibi problem için başka isimler de kullanılmaktadır. Bu çalışmada, otomatik modülasyon sınıflandırması tanımını aynı soruna tutarlı bir referans olarak kullanılacaktır.

2007 yılında Octavia Dobre vd. tarafından ortaya konan ve modülasyon tanıma başlığı altındaki en çok atıf alan eser olan "Survey of automatic modulation classification techniques: classical approaches and new trends", bu derlemenin ortaya çıkmasında ilham olmuştur [7]. Ancak bu yayın, yayınlandığı tarih itibarı ile özellikle son 10 yılda ortaya konan yayınları içermemektedir. Bu makalede ise ağırlıklı olarak son yıllardaki

yayınlar yer almaktadır. Bunun yanında, Modülasyon Tanıma konusunun popülerliğinin son yıllarda gittikçe artması, özellikle bu konu hakkında Türkçe ele alınmış bir derleme ortaya koyma isteğinin de beraberinde getirmiştir. Bu eserin özellikle, bu konu hakkında çalışmak isteyen ve Türkçe kaynak arayışına girecek Türk akademisyen ve öğrenciler tarafından yararlı bir eser olarak faydalanılacağı düşünülmektedir.

1.2 AMC uygulamaları

Bu bölümde AMC'nin farklı askeri ve sivil sistemlerde nasıl kullanıldığı yakından incelenecektir.

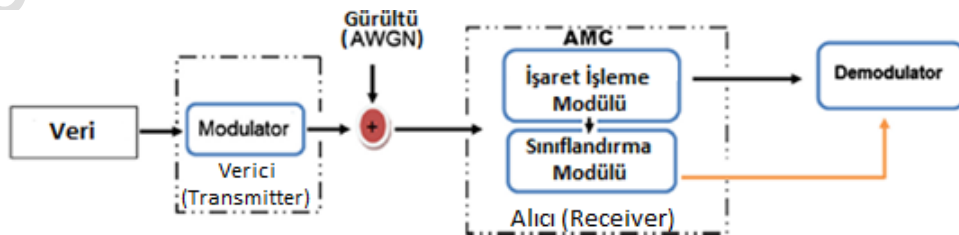
1.2.1 Askeri uygulamalar

AMC birçok askeri stratejide önemli bir role sahiptir. Modern EW üç ana bileşenden oluşmaktadır: elektronik destek (ES), elektronik saldırı (EA) ve elektronik koruma (EP) [8]. ES'de amaç radyo frekansı spektrumundan bilgi toplamaktır ve genellikle sinyal algılama başarılı bir şekilde başarılıktan sonra AMC'nin kullanıldığı yerdir. Elde edilen modülasyon bilgisi, EW'deki tüm bileşenlere uzanan çeşitli kullanımlara sahip olabilir. Askeri EW sistemlerine bir modülasyon sınıflandırıcısının nasıl dâhil edildiğinin bir örneği Şekil 2'de verilmiştir. Bu şekle göre antenden alınan işaret bir işaret algılayıcısından geçer. Eğer taranan spektrumda haberleşme işareti varsa, işaret algılayıcısı bu haberleşme işaretini temelbantta AMC bloğuna iletir. ES sürecinin bir sonraki aşamasında AMC algoritmaları ile işaretin modülasyon tipi belirlenir.


Modülasyon tipi belirlendikten sonra işaret demodüle edilir. Elde edilen işaret şifrelenmişse bir sonraki aşamada şifresi kırılmaya çalışılır. Daha sonra ise işaret geri çatılarak istihbarat servisine iletmek üzere kaydedilip ve arşivlenebilir. Eğer karşı tarafın haberleşmesini kesmek istenirse AMC'den elde edilen modülasyon bilgisi kullanılarak sadece o haberleşme kanalına dar bantlı parazit sokulabilir. Böylece diğer haberleşme kanallarında rahatlıkla haberleşme yapılırken sadece istenilen kanallarda engelleme yapılabilir. Bunun yanında düşman birimlerinin ve bunların muhtemel konumlarının tanımlanmasında kullanılabilecek elektronik haritalama sistemi de hayati bilgiler sağlayabilir.

1.2.2 Sivil uygulamalar

Modülasyon şemasını ve hata düzeltmesinin kodlama oranını radyo bağlantısının kalitesine göre ayarlayabilme kabiliyeti olan link adaptasyonu AMC'nin en sık kullanıldığı sivil uygulamalardan biridir. Telsiz bağlantısının koşulları iyi ise, yüksek seviyeli verimli bir modülasyon şeması ve az miktarda hata düzeltmesi kullanılırken bu radyo kanalında yüksek bir veri iletimi sağlar.



Şekil 1: Haberleşme sistem modeli ve AMC.



Şekil 2: Askeri işaret istihbarat sistemi.

Radio kanalının koşulları zayıfsa, düşük seviyeli, daha sağlam bir modülasyon şeması kullanılır ve hata düzeltme miktarı artarak veri iletimi önemli ölçüde düşer. Daha önceden oluşturulan bir modülasyon havuzundan modülasyon seçimi, sistem gereksinimleri ve kanal koşullarına göre belirlenir. Örneğin, BPSK ve QPSK gibi daha düşük seviyeli ve daha güçlü modülasyonlar, sistem gürültülü ve karmaşık olduğu zaman, sistemin yüksek bağlantı güvenilirliğini sağlamak için sıklıkla seçilirler. 16-QAM ve 64-QAM gibi daha yüksek seviyeli ve daha etkili modülasyonlar ise, açık kanallarda yüksek hızlı iletime olan talebi karşılamak için seçilirler. Kullanılan uyarlamalı modülasyon modülü ile alıcı arasındaki tek iletişim, modülasyon aday havuzunun bilgisinin alıcıya bildirildiği sistem başlatılırken tamamlanır. Normal iletim sırasında uyarlamalı modülör iletişim akışında fazladan bilgi içermez. Link adaptasyon sisteminin alıcı ucunda, kanal tahmini diğer görevlerden önce gerçekleştirilir. Kanal statik ise, tahmin sadece ilk aşamada gerçekleştirilir. Kanal zamanla değişken ise, kanal durumu bilgisi (CSI) iletim boyunca düzenli olarak tahmin edilebilir. Tahmin edilen CSI ve diğer bilgiler daha sonra, CSI'nin modülasyon şemalarının seçimi için kullanılacağı vericiye geri beslenecektir. Daha da önemlisi, CSI modülasyon sınıflandırıcıya yardımcı olmak için gereklidir. AMC algoritmasına bağlı olarak, modülasyon sınıflandırmasını tamamlamak için farklı kanal parametreleri gereklidir. Normal olarak, kanal tahmininin doğruluğu, modülasyon sınıflandırıcısının performansı üzerinde önemli bir etkiye sahiptir. Ortaya çıkan modülasyon sınıflandırma kararı daha sonra uygun demodülasyon için yeniden yapılandırılabilir sinyal demodülatörüne beslenir. Modülasyon sınıflandırması doğruysa, doğru demodülasyon yöntemi mesajı yakalar ve başarılı iletimi tamamlar. Modülasyon sınıflandırması yanlışsa, mesaj demodülatörden kurtarılamayacağından tüm iletim başarısız olur. Link adaptasyonu sistemlerde AMC'nin önemini görmek zor değildir. Şekil 3'te link adaptasyonu işlemi için örnek bir yapı oluşturulmuştur.

2 Genel Modülasyon Sınıflandırma Yöntemleri

Tablo 1'den de görüleceği üzere AMC hakkında yirmi yıldan fazladır gerçekleştirilen araştırmalarda, çok sayıda algoritma ve yöntem ortaya çıkmıştır [9]. Literatürdeki modülasyon sınıflama yöntemleri genel olarak iki kategoriye ayrılabilir: olabilirlik tabanlı (LB) ve öznitelik tabanlı (FB) yöntemler. LB

yöntemler, en yüksek olabilirlik yöntemini kullanarak modülasyon sınıflandırmasını bir hipotez testine dönüştürür ve olasılık oranını bir eşik ile karşılaştırırlar. LB yöntemi Bayes sınıflandırmada en uygun dedektördür. Bununla birlikte, olabilirlik olasılığını elde etmek için, tüm kanal parametrelerinin birden kestirilmesi gerekir. Bu da işlem karmaşıklığını oldukça artırmaktadır. Örneğin, bir haberleşme sinyalinde K tane parametre varsa, arama uzayında N^K işlem karmaşıklığı ile arama yapmak gerekmektedir (N : İşaretin uzunluğu). Pratikte böyle bir işlem karmaşıklığını mantıklı bir tepki süresi içerisinde hesaplamak mümkün değildir. Bu nedenle LB temelli yöntemlerin çözümünde alternatif ve hızlı sonuç veren algoritmalara ihtiyaç vardır.


Öznitelik tabanlı yöntemler ise, ham sinyallerden çıkarılan öznitelikleri kullanır ve bir karar vermek için uygun sınıflayıcılar seçilir. Öznitelik tabanlı yöntemler çoğu durumda en uygun olmamasına rağmen, uygulanmasının kolay olması ve işarete ait parametrelerin bilgisine gerek olmayışı sayesinde sıklıkla kullanılmaktadırlar. Aslında, FB metodları ile gerçekleştirilecek uygun bir tasarım ile de yarı-optimum performans elde etmek mümkün olabilmektedir.

2.1 Olabilirlik Bazlı Yaklaşım

Yaygın olarak kullanılan sınıflandırma yöntemlerinden biri olarak LB yöntemler, gerekli tüm kanal bilgisinin bilindiği durumda sağladığı yüksek sınıflandırma doğruluğu ile ünlüdür [9]. LB yaklaşımı, modülasyon tipini tanımlamak için alınan sinyalin olabilirlik fonksiyonunu kullanır. Sinyal sınıflandırması, olasılık oranları oluşturularak ve daha sonra bir eşik karşı oranın karşılaştırılmasıyla modülasyon tipine karar verilmesiyle yapılır. Bir LB modülasyon sınıflandırıcısının ortak yaklaşımı iki aşamadan oluşur [7]. İlk adımda, gözlemlenen sinyal örnekleri ile her bir modülasyon hipotezi için olasılıklar hesaplanır. Olabilirlik işlevleri, seçilen sinyal modelinden türetilir ve azaltılmış hesaplama karmaşıklığının gerekliliğini yerine getirmek veya kooperatif olmayan ortamlarda uygulanabilir olmak üzere değiştirilebilir. İkinci adımda, farklı modülasyon hipotezlerinin olasılığı, sınıflandırma kararını sonuçlandırmak için karşılaştırılır. Daha önceki karar verme yöntemleri, iki hipotez arasındaki bir oran testi ile etkinleştirilir.

Tablo 1: Ayrıntılı literatür şeması.

Author(s)	Features	Modulations	Classifier(s)
Chung-Yu Huang ve Andreas Polydoros [25]	raw I/Q	MPSK	qLLR
J.A. Sills [9]		MPSK, MQAM	ML
Prokopios Panagiotou vd. [11]		16QAM-16PSK, V.29-16PSK ve 16QAM-V.29	Faz ve Veri GLRT
Wen Wei and Jerry M. Mendel [26]		PSK, PAM veya QAM	ML
Octavia A. Dobre vd. [27]		MPSK, MQAM	HLRT, qHLRT
Wei Su vd. [28]		MPSK, MQAM	ALRT
J. Lopatka ve M. Pedzisz [29]	HOM ve HOS	ASK, PSK, QAM ve FSK	Fuzzy Logic
Ananthram Swami ve Brian M. Sadler [30]		PAM, PSK, QAM	Asymptotic Threshold Analysis
M. L. D. Wong ve A. K. Nandi [31]		ASK2, ASK4, BPSK, QPSK, FSK2, FSK4, QAM16, V29, V32, QAM63	MLP
M. L. D. Wong ve A. K. Nandi [32]		ASK2, ASK4, BPSK, QPSK, FSK2, FSK4, QAM16, V29, V32, QAM64	ANN ve GP
Hsiao-Chun Wu vd. [33]		BPSK, QPSK, 4QAM, 16QAM, 64QAM	CRLB
Ataollah E. Shermeh ve Reza Ghazalian [34]		ASK4, ASK8, PSK2, PSK4, PSK8, Star-QAM8, V29, QAM32 ve QAM64	SVM
Muhammad Waqar Aslam vd. [35]	WT	BPSK, QPSK, QAM16, QAM64	GP ve kNN
K.C.Ho vd. [36]		PSK, FSK	Threshold Analysis
K. Hassan vd. [37]		FSK, ASK, PSK ve QAM	ANN
Octavia A. Dobre vd. [38]		QAM, PSK ve ASK	Match Filter
Octavia A. Dobre vd. [39]		4QAM ve 16QAM	Threshold Analysis
A. Fehske vd. [40]		BPSK, QPSK, BPSK, QPSK, FSK, MSK, AM	ANN
Barathram Ramkumar [41]	Çevrimsel Öznitelikler	ASK, PSK, QAM ve FSK	ML, HMM, ANN
Octavia A. Dobre vd. [42]		4-ASK, 8-ASK, BPSK, QPSK, 8-PSK, 16-PSK, 16-QAM, 32-QAM ve 64-QAM	Threshold Analysis
Octavia A. Dobre ve Robert Inkol [43]		AM, FSK, M-PSK, M-QAM, M-ASK, Mobile WiMAX OFDM	Threshold Analysis
Udit Satija vd. [59]		BPSK, QPSK, MSK ve FSK	ANN, kNN, LDA, NB, SVM
Udit Satija vd. [60]		BPSK, QPSK, MSK ve FSK	ANN, kNN, LDA, NB, SVM
Bijan G. Mobasseri [61]	Takımyıldızı	V.29, 8PSK ve 16QAM	ML
Negar Ahmadi, Reza Berangi [17]	Grafiği	QAM ve PSK	GP ve hierarchical clustering
S.-Z. Hsue ve Samir S. Soliman [62]	zero crossing	BPSK, QPSK, 8PSK, BFSK, 4FSK ve 8FSK	Threshold Analysis
Fanggang Wang ve Xiaodong Wang [63]	raw I/Q	4-QAM, 16-QAM, 64-QAM, 4-PSK, 8-PSK, 16-PSK	Kolmogorov-Smirnov Test
Jian Liu ve Qiang Luo [64]	Fractional Fourier	2ASK, 2FSK, BPSK ve 16QAM	Threshold Analysis
Sajjad Ahmed Ghauri vd. [65]	Gabor Filter	mPSK, mFSK ve mQAM	Gabor Filter
Udit Satija vd. [66]	S transform	BPSK, QPSK, MSK ve FSK	ANN, kNN, LDA, NB, SVM



Şekil 3: Link adaptasyonu işlemi için AMC yapısı.

Bir eşikğin gerekliliği, gelişmiş sınıflandırma performansı sağlayabilecek başka bir optimizasyon problemine sebep verir ve bu eşikleri seçmek için daha fazla deneysel çaba anlamına gelmektedir. Karar vermenin daha sezgisel yaklaşımı ise, tüm adaylar arasında en yüksek olasılığı bulmak olacaktır. Örneğin, PSK veya QAM tipi sayısal modülasyonda alınan sinyal

$$r(t) = s(t) + n(t) \quad (1)$$

ile ifade edilir [10]. Burada $s(t)$ bir verici tarafından yayılan sinyal ve $n(t)$ 'de çift taraflı $\frac{N_0}{2}$ güç spektral yoğunluğuna sahip bir beyaz gaus gürültüsüdür. Verici tarafından iletilen $s(t)$

$$s(t) = A(t)\cos(w_c t + \theta_c + \phi(t)) = \text{Re}\{A(t)e^{j\phi(t)}e^{j(w_c t + \theta_c)}\} \quad (2)$$

ile ifade edilir [9]. $A(t)$ genlik, $\phi(t)$ faz, w_c taşıyıcı frekans ve θ_c ise faz ofsetidir. $s(t)$ 'ye ait kompleks zarf

$$s'(t) = A(t)e^{j\phi(t)} \quad (3)$$

olduğundan, gelen işaret N adet modülasyon çeşidinden birini temsil etmek zorundadır. $i = 0, 1, \dots, N - 1$ adet modülasyon sınıfı bulunmakta ve i sınıfına ait modülasyon sınıfında m_i olarak nitelenmektedir. Ayrıca m_i modülasyon türüne ait başlangıç olabilirlik oranı da $P[m_i]$ ile ifade edilecektir. Bilişsel radyo teknolojisine ait yazılım tabanlı radyo (SDR) kullanılarak farklı analog modülasyonlar (Çift Yan Bant (ÇYB), Tek Yan Bant (TYB) ve Geniş Bant Frekans Modülasyonu (WBFM)) ile modüle edilmiş sinyaller ise

$$s(t) = \begin{cases} A_c m(t), & \text{ÇYB-SC} \\ A_c (1 + m_a \hat{m}(t)), & \text{ÇYB-WC} \\ A_c [m(t) + j\hat{m}(t)], & \text{SSB-SC} \\ A_c + A_c m_a [m(t) + j\hat{m}(t)], & \text{SSB-WC} \\ k_f \int m(\tau) d\tau, & \text{WBFM} \end{cases} \quad (4)$$

denklemleri ile ifade edilir. A_c sinyal genliği, $m(t)$ mesaj sinyali, m_a modülasyon endeksi, $\hat{m}$ Hilbert dönüşümü, k_f frekans sapma katsayısı ve kısaltmalar SC ve WC ise sırasıyla 'bastırılmış taşıyıcı' ve 'taşıyıcılı' anlamına gelmektedir.

LB yöntemleri, sinyalin modülasyon tipini tanımlamak için bilinmeyen parametrelerin tahmin edilmesini/bilinmesini içerirler. Yapılan birçok çalışmada taşıyıcı frekans w_c , sembol oranı R_s , zamanlama ofseti t_d , taşıyıcı faz θ_c , darbe şekli $p(t)$ ve SNR γ ile ilgili parametrelerin başlangıçta bilindiği farzedilmektedir. Burada uyumlu filtre (matched filter) çıkışı ise

$$r'_n(t) = \int_{-\infty}^{\infty} r(t)e^{-j(w_c t + \theta_c)} \sqrt{\frac{2}{E_p}} p(t - nT_s - t_d) dt = r_{I,n} + jr_{Q,n} \quad (5)$$

ile ifade edilir [10]. Burada, $R_s = \frac{1}{T_s}$ sembol oranı, t_d bilinmeyen zamanlama ofseti $r_{I,n}$ ve $r_{Q,n}$ sırasıyla eşfazlı ve karesel bileşenler, $p(t)$ darbe şekli ve E_p ise darbe enerjisini vermektedir.

Demodüle sembol r_n 'e ait olasılık yoğunluk fonksiyonu (OYF), $m = m_i$ durumunda

$$p_r(r_{I,n}, r_{Q,n} | m = m_i) = \frac{1}{M(i)} \sum_{k=1}^{M(i)} \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{(r_{I,n} - \sqrt{E_s}\mu_{I,k})^2 - (r_{Q,n} - \sqrt{E_s}\mu_{Q,k})^2}{2\sigma^2}} \quad (6)$$

ile ifade edilir [10]. Burada $\mu_{Q,k} = \text{Re}\{\mu_k\}$, $\mu_{I,k} = \text{Im}\{\mu_k\}$ ve $\sigma = \frac{N_0}{2}$ ile elde edilir.

N adet modüle gelen işaret birlikte

$$r' = r_I + jr_Q = [r'_1, r'_2, \dots, r'_N] \quad (7)$$

ifade edilir [10]. Burada gelen işaret r' için OYF

$$p_{r'}(r_I, r_Q | m = m_i) = \prod_{n=1}^N p_r(r_{I,n}, r_{Q,n} | m = m_i) \quad (8)$$

denklemleri ile elde edilir. Maksimum olasılık kuralı, alınan sinyalin hangi modülasyon türüne ait olduğuna karar vermek için denklem 8 ile verilen OYF'yi kullanır. $p_{r'}(r_I, r_Q | m = m_i)$ değerini maksimum yapan $i = k$ değerine karşılık gelen m_k modülasyon türü sistemin tahminidir.

Literatürde üç tip LB tekniği sunulmuştur: Ortalama Olabilirlik Oranı Testi (ALRT) [10], Genelleştirilmiş Olabilirlik Oranı Testi (GLRT) [11] ve Hibrid Olabilirlik Oranı Testi (HLRT) [12].

2.2 Öznitelik Tabanlı Yaklaşım

FB yaklaşımı, alınan sinyalden anlamlı özniteliklerin çıkarılarak bu özniteliklerin bir sınıflandırma algoritması yardımıyla eğitilmesi esasına göre çalışır. Son zamanlarda gerçekleştirilen modülasyon sınıflandırması alanındaki çalışmaların büyük çoğunluğu FB yöntemleriyle gerçekleştirilmektedir. Bunun sebebi, LB yöntemlerine kıyasla daha yüksek performans ve daha düşük işlem karmaşıklığına sahip olmalarından kaynaklanmaktadır.

FB algoritmaları karar verme için sinyalin bazı özniteliklerini kullanırlar. Bu özniteliklerden bazıları [7]: işarete ait anlık frekans, faz ve genlik bilgisi [14], istatistiksel özellikler [15, 16], takımyıldız grafiği [17] ve çeşitli dönüşüm öznitelikleridir [18, 19, 20].

2.2.1 Anlık Zaman Bölgesi Öznitelikleri

Bu özellikler sinyalin genliğine, fazına veya frekansına dayanır. Bu parametrelerin anlık versiyonu, AMC'nin uygulanması için sıklıkla kullanılmaktadır [14]. Alınan bir sinyal $r(t)$ için anlık genlik,

$$a(t) = \sqrt{r^2(t) + r'^2(t)} = |z(t)| \quad (9)$$

olarak ifade edilebilir [14]. Burada $r'(t)$, $r(t)$ işaretinin Hilbert dönüşümüdür. Anlık faz ise,

$$\phi(t) = \text{unwrap}(\text{angle}(z(t))) - 2\pi f_c t \quad (10)$$

ile elde edilir [14]. Burada $\text{unwrap}(\text{angle}(z(t)))$, denklem 9 ile verilen $z(t)$ vektöründeki radyan faz bozulmalarını düzeltir.

Anlık frekans ise

$$\frac{1}{2\pi} \frac{d(\arg(z(t)))}{dt} \quad (11)$$

ile bulunur [14].

2.2.2 Takımyıldız Diyagramı

Takımyıldız grafiği, bir dijital modülasyon şeması ile modüle edilen bir sinyale ait bileşenlerin grafiksel bir temsidir. Sinyali, sembol örnekleme anlarında karmaşık düzlemde iki boyutlu bir dağılım şeması olarak gösterir. Kompleks düzlemde bu noktalar, belirli bir modülasyon şeması ile seçilebilecek olası sembollerini temsil ederler. Örneğin, QAM ve PSK sinyallerinin takımyıldız diyagramlarının geometrik şekli, bu noktaların şemalardaki nokta sayısı ve konumu nedeniyle birbirinden farklıdır. AMC çalışmalarında takımyıldız noktaları ve eşit genlik setleri arasındaki öklid mesafesi gibi özellikler kullanılarak, modülasyon türleri arası takımyıldız diyagramındaki farklara dayalı modülasyon tespiti gerçekleştirilmektedir [17].

2.2.3 İstatistiksel Özellikler

AMC için yaygın olarak kullanılan istatistiksel özellikler:

- Yüksek mertebeden istatistikleri (High order statistics, HOS),
- Döngüsel öznitelikler (Cyclostationarity features, CF) ve Döngüsel kümülantlar (Cyclostationarity cumulants, CC),
- Sıfır geçişi (Zero crossing, ZC).

HOS, gürültüye karşı direnç, faz dönüşüne dayanıklılık ve ayrıca sinyalin daha yüksek sıralı istatistiklerini gösteren önemli avantajlar sunmaktadır [15]. Yüksek mertebeden momentler (Higher order moments, HOM) ilk basamak HOS olarak karşımıza çıkmaktadır. Gelen $x(n)$ işaretine ait momentler

$$M_{p+q,p} = E[x(n)^p (x(n)^*)^q] \quad (12)$$

ile elde edilir [15] ve sinyalin kendisi ile konjugesinin sırasıyla p ve q dereceden güçlerinin çarpılması ile bulunur. İki veya daha fazla HOM kombinasyonu HOC verir. Örneğin, dördüncü dereceden kümülant

$$C_{42} = \text{cum}[x(n)x(n)x(n)^*x(n)^*] = E[|x(n)|^4] - |E[x(n)^2]|^2 - 2E^2[|x(n)|^2] \quad (13)$$

olarak ifade edilir [15].

Alınan sinyal $x(n)$ sıfır ortalamalı rasgele değişken olarak kabul edilir. Kümülanları öznitelik olarak kullanan modülasyon sınıflandırıcılar, rastgele bir değişkenin dağılımının şeklinin, örneğin denklem 13'deki gibi daha yüksek mertebeden kümülantlar ile karakterize edilebileceği fikrine dayanmaktadır [21]. Dördüncü dereceden kümülantlar, modülasyon sınıflandırıcılarında öznitelik olarak yaygın şekilde kullanılmaktadır.

Döngüsel durağan bir sürecin periyodik özelliklerini araştıran özellikler, yani alınan sinyalin döngüsel analizi, ilk olarak 1994 yılında Gardner tarafından ortaya atılmıştır [22]. Buna dayanarak, Spooner, Gardner ile işbirliği yaparak, farklı modülasyon tiplerinin spektrum görünümündeki çeşitliliği analiz etmeye çalışırken modülasyon sınıflaması için döngüsel analizi uygulamaya başladı.

İkinci dereceden döngüsel durağan bir $x(t)$ işaretinin özilişki fonksiyonu

$$R_x(t, t - \tau) = E[x(t)x^*(t - \tau)] \quad (14)$$

periyoiktir. Periyodik herhangi bir iřaret Fourier serisine aılabileceğinden öziliřki fonksiyonunun Fourier serisi

$$R_x(t, t - \tau) = \sum_{|a|} R_x^a(\tau) e^{j2\pi a(t - \frac{\tau}{2})} \quad (15)$$

yazılabilir [22]. Böylece Fourier serisi katsayıları da

$$R_x^a(\tau) = \lim_{T \rightarrow \infty} \frac{1}{T} \int_{-T/2}^{T/2} x(t + \frac{\tau}{2}) x(t - \frac{\tau}{2}) e^{-j2\pi a(t - \frac{\tau}{2})} dt \quad (16)$$

elde edilir [22]. Döngüsel öziliřki fonksiyonunun Fourier dönüşümü döngüsel güç spektrumu olarak da düşünölebilir ve

$$S_x^a(f) = \int_{-\infty}^{\infty} R_x^a(\tau) e^{-i2\pi f\tau} d\tau \quad (17)$$

bağıntısıyla bulunur [22].

2.2.4 Sıfır Geişleri

İřarete ait genlik değeriinin sıfır değeriinin altına ve üstüne yaptığı zıplamaların ölçümüdür. Alınan sinyalin ZC'lerinin sayısı, bazı işlem sonrası teknikler ile birlikte AMC için kullanılmıştır [23]. Örneğın PSK modöleli iřaretlerde ZC oranı sabitken, FSK modöleli sinyallerde ise bu oran değışiklik gösterir. Bu nedenle, ZC, PSK'yı FSK modölyasyon tipinden ayırt etmek için kullanılan özniteliklerden biri olarak kullanılabilir.

2.2.5 Çeşitli dönüşüm öznitelikleri

Fourier dönüşümü (Fourier transform, FT) ve dalgacık dönüşümü (Wavelet transform, WT) en çok kullanılan dönüşümler olarak karřımıza çıkmaktadır [24]. Bu dönüşümlerden önce ya da sonra iřaretlere, çeşitli ön işlemler yumuşatma (smoothing), medyan filtreleme ve normalizasyon uygulanabilmektedir. Özellikle WT'nin güröltünün etkilerini azaltma avantajını sunması ve WT'de zaman ile frekans bilgilerinin birlikte yer alması FT'ye göre daha fazla çalışmada kullanılmasına sebep olmuştur [25].

3 Literatür Taraması

Bu bölümde, AMC alanında yapılan çalışmalarla ilgili bir literatür taraması sunulacaktır. Yapılan literatür çalışmasında, son 25 yılda AMC alanında gerçekleştirilen neredeyse tüm eserler arasından özellikle çok atıf alan ve bundan sonraki gerçekleştirilecek çalışmalarda bizlere rehber olabileceğı düşünölen eserlerden bahsedilmeye çalışılmıştır. Literatür çalışması da aynı AMC metotları gibi iki başlık altında incelenecek ve sırasıyla LB ve FB metotları ile gerçekleştirilen çalışmalar özetlenecektir.

3.1 Literatürdeki LB Temelli Yöntemler

Chung-Yu Huang ve Andreas Polydoros tarafından 1995 yılında gerçekleştirilen "Likelihood Methods For MPSK Modulation Classification" çalışması [26], AMC problemine ML tabanlı önerilen ilk çalışmalardan biridir. MPSK modölyasyonlarının sınıflandırılması problemi için, olabilirlik fonksiyonu (Likelihood Functional, LF) ve yeni yaklaşımlara dayalı yeni algoritmalar (quasi-Log-Likelihood-Ratio, qLLR) önerilmiştir. Optimal LF sınıflandırıcısının performansı analitik olarak değeriendirilmiş ve elde edilen başarımın en iyiye çok yakın olduėu gösterilmiştir. Ayrıca, yeni qLLR sınıflandırıcısının uygulanmasına yönelik özyinelemeli algoritmaların, sınıflandırıcı karmaşıklığında önemli bir artışa neden olduėu belirtilmiştir.

1999 yılında J.A. Sills tarafından ortaya konan çalışmada ise [10], uyumlu (coherent) ve uyumsuz (noncoherent) koşullar altında PSK (BPSK, QPSK, 8PSK) ve QAM (16QAM, 32QAM, 64QAM) sinyalleri için otomatik modölyasyon sınıflandırması ele alınmaktadır. Sinyallerinin sınıflandırması için maksimum olabilirlik algoritması (Maximum- Likelihood Algorithm, ML) hem uyumlu hem de uyumsuz şartlar altında kullanılmıştır. Yöntemlerin performansı hata oranı, yanlış alarm oranı ve hesaplama karmaşıklığı açısından değeriendirilmiş ve modölyasyon türleri arasında karar vermek için kullanılan sembollerin sayısının ML tabanlı bir PSK/QAM tanıyıcı tasarımıında kritik bir parametre olduėu vurgulanmıştır. ML yönteminde modölyasyonlarda çok sayıda sembol kullanılmasının, hata olasılığını ve yanlış alarm olasılığını azaltacağı belirtilmiş ve daha az sembol kullanıldığı durumlarda yüksek sınıflandırma başarımı için daha yüksek SNR'ye ihtiyaç duyulacağı irdelenmiştir.

Prokopios Panagiotou vd. tarafından 2000 yılında gerçekleştirilen çalışmada ise [12], daha önce özellikle yüksek başarımı ile ön plana çıkan Average Likelihood Ratio Test (ALRT) ve ALRT'nin analitik zorlukları nedeniyle sadece optimal çözüme yaklaşımları olan qLLR ve Non-Coherent Pseudo-Maximum Likelihood (NC-PML) yöntemlerinin özellikle sabit olmayan zarf modölyasyonlarının sınıflandırmasında düşük sınıflandırma başarımı göstermelerine çözüm aranmıştır. Bu sorunu hafifletmek için, temeli ALRT ve Generalized Likelihood Ratio Test (GLRT) yöntemlerine dayanan iki yeni AMC algoritması geliştirilmiştir: Phase and Data GLRT (Ph&D-GLRT), Average Data - Maximum Phase (ADMP). Bu iki algoritmanın performansı, çeşitli modölyasyon çiftleri (16QAM-16PSK, V.29-16PSK ve 16QAM-V.29) için qLLR ve NC-PML ile karřılařtırılmış ve sabit olmayan zarf modölyasyonlarının sınıflandırılması problemi için önemli performans kazanımları elde edebileceğini göstermiştir.

2000 yılıındaki bir başka çalışmada ise [27], faz kaymalı anahtarlama (PSK), darbe genlik modölyasyonu (PAM), karesel genlik modölyasyonu (QAM) vb. herhangi bir dijital genlik-faz modölyasyonuna uygulanabilen ML sınıflandırıcısının teorik bir performans analizini geliştirilmeye çalışılmıştır. Teorik performans ölçümleri, tüm sinyal parametrelerinin yanı sıra güröltü gücünün bilindiğı ve ayrıca veri sembollerinin bağımsız ve darbe şeklinin dikdörtgen olduėu ideal bir durum altında elde edilmiştir. Asimptotik performans çalışması olan bu çalışmada, ML sınıflandırıcısının mevcut veri sembollerinin sayısı sonsuzluėa gittiğinde sıfır hata oranıyla herhangi bir sonlu kümedenme takımlarını sınıflandırabildiğı rastgele oluşturulmuş veriler kullanarak gösterilmiştir. Karřılařtırmalar SNR için 0 ila 15 dB arasında ve test sembolleri N = 100, 200 ve 1000 için gerçekleştirilmiş ve simölyasyonlar, her bir SNR ve her bir N değeri için gerçekleştirilmiştir. Bu sonuçlar, SNR'nin küçük olduėu durumlar haricinde, analizlerin ve simölyasyonların çok iyi eřleştiğini göstermektedir.

AMC alanında literatürde ismi sıkça geen ve bu alana çokca katkıda bulunmuş Octavia A. Dobre vd. tarafından 2009 yılında gerçekleştirilen bir çalışmada ise [28], lineer dijital modölyasyon sınıflandırması için olasılık tabanlı algoritmalar araştırılmış ve sinyal genliğı, faz ve güröltü gücü gibi parametrelerin bilinmediğı durumlar için Hibrit Olabilirlik Oranı Testi (HLRT) ve Quasi HLRT (QHLRT) tabanlı algoritmaların performansları incelenmiştir. Özellikle başarılı sonuçları ile ön plana çıkan ama çok yüksek karmaşıklıktan muzdarip olan HLRT yöntemine QHLRT yöntemi ile makul bir çözüm aranmıştır. QHLRT-tabanlı algoritmayı geliřtirmek için bilinmeyen parametrelerin

momentum (MoM) tahminleri araştırılmış ve kullanılmıştır. Bu algoritmanın BPSK ve QPSK modülasyonlu işaretleri sınıflandırma performansı, üst sınırlarla ve qLLR ve dördüncü mertebeden kümülan tabanlı algoritmalar ile karşılaştırılmıştır. Simülasyon sonuçlarına göre, MoM tahminleri tarafsız olduğunda, varyansı Cramer-Rao alt sınırı (Cramer-Rao Lower Bounds, CRLB) nispeten yakındır ve QHLRT-MoM makul bir performans sağlar. Özellikle kanal etkisinin olmadığı durumlarda QHLRT-MoM ve qLLR algoritmalarının PSK sinyallerini ayırt ederken benzer bir performans sağlamasına rağmen, QHLRT-MoM bu model uyumsuzluğu için daha kuvvetli olduğu vurgulanmıştır. Öte yandan, dördüncü derece / iki konjuge kümülan tabanlı algoritma, bu koşullar altında en sağlam olanıdır ve qLLR ile karşılaştırıldığında QAM modülasyonlarını ayırt etmek için başarıyla uygulanabilir olduğu görülmektedir. Ayrıca QHLRT'nin solma (fading) koşulları altında kabul edilebilir bir performans sağladığı gösterilmiş ve QHLRT'nin makul bir karmaşıklıkla iyi bir performans sergilediğini ve umut verici bir aday algoritması olduğu vurgulanmıştır. QHLRT-MoM, ortalama doğru sınıflandırma olasılıklarında $SNR > 10$ için hem qLLR hem de dördüncü mertebeden kümülan tabanlı algoritmaları geride bırakmaktadır. Fakat özellikle $SNR < 10$ için yöntemin sınıflandırma performansı ne yazıkki diğer tüm yöntemlerden daha kötü sonuçlar vermektedir.

Jefferson L. Xu vd. tarafından ortaya konan çalışmada ise [29], olasılık fonksiyonlarına dayanan otomatik modülasyon sınıflandırma yöntemlerine odaklanılmış ve olabilirlik oranı testinden (Likelihood Ratio Test, LRT) türetilen çeşitli sınıflandırma çözümlerini incelenmiştir. Genel olarak mevcut LRT'ye dayalı otomatik modülasyon sınıflandırıcıların, işarete ait frekans bant genişliği, gürültü gücü, taşıyıcı frekans kayması, taşıyıcı faz, sembol frekansı, sembol zamanlaması ve örnekleme zamanlama ofseti gibi parametrelerin kör tahmini de gerçekleştirecek bir yapıda olması gerekliliği üzerinde durulmuş ve kör parametre tahmin işlemi olmadan bu yöntemlerin düzgün çalışmayacağı belirtilmiştir. Özellikle yeterli sayıda parametre bilindiğinde ALRT yönteminin optimum çözüme en yakın sonuçları ortaya koyduğu lakin, gerçek zamanlı yazılım tabanlı radyo (Software Defined Radio, SDR) uygulamaları için LRT sınıflandırıcılarını uygulamak için karmaşıklık azaltma ve algoritmaları hızlandırıcı bazı adımlara ihtiyaç duyulduğu vurgulanmıştır.

3.2 Literatürdeki FB Temelli Yöntemler

Bu bölümde, AMC probleminin çözümü için FB metotlar ile gerçekleştirilen çalışmalar özetlenecektir. Teknolojinin gelişmesine paralel olarak bilgisayar ve işlemcilerde büyük gelişmeler olmuş ve buda FB-AMC yöntemlerinin sayısında ML yöntemlere göre büyük bir artış görülmesine sebep olmuştur. Özellikle son yıllarda gerçekleştirilen çalışmaların büyük çoğunluğunun FB yöntemler ile gerçekleştirilmesi sebebi ile, bu kısım için işaretlerden elde edilen bazı önemli özniteliklere ait altbaşlıklara ayrılma gereksinimi görülmüştür. Sırasıyla yüksek dereceli momentler ve kümülanlar, dalgacık dönüşümü, çevrimsel öznitelikler, takımyıldızı grafiği ve diğer yöntemler altbaşlıkları altında AMC probleminin üretilen çözümler ve gerçekleştirilen çalışmalar özetlenecektir.


3.2.1 Yüksek Dereceli Momentler ve Kümülanların Kullanıldığı Çalışmalar

2000 yılında Lopatka tarafından ortaya konan çalışmada [30], AWGN varlığında sinyalleri sınıflandırmak için yeni bir sayısal modülasyon tanıma algoritması sunulmuştur. Önerilen

sınıflandırıcı iki alt sistemden oluşur. Birincisi, gözlemlenen verilerden yararlı bilgiler çıkarır ve seçilen bir özellik alanına bir haritalama gözlem alanı olarak görülebilir. İkincisi, modülasyon tipinin üyeliğini gösteren bir model tanıyıcı alt sistemidir. Bulanık mantık ile işarete ait elde edilen genlik, faz ve frekansın istatistiksel momentleri eğitilmiş ve işaretlerin modülasyon türlerinin (ASK, PSK, QAM veya FSK) tespiti, sinyalin SNR, taşıyıcı fazı veya veri hızı hakkında bilgi sahibi olunmadığı halde tespit edilebilmiştir. Simülasyon sonuçları, önerilen özellikler ve algoritma setinin SNR'ye göre çok sağlam olduğunu kanıtlamıştır ancak yine de SNR'nin 5dB'den düşük olduğu durumlarda performansın oldukça düştüğü de gözlemlenmiştir.

Swami ve Sadler tarafından gerçekleştirilen ve FB-AMC alanında en çok atıf alan çalışma olan [31]'de sayısal modülasyon şemalarının sınıflandırılması için, temel dördüncü dereceden kümülanlara dayanan basit bir yöntem önerilmiştir. Kümülan bazı sınıflamanın, hiyerarşik bir şemada kullanıldığında özellikle etkili olduğu, küçük örnek büyüklüğü ile düşük sinyal-gürültü oranında alt sınıflara ayrılmayı mümkün kıldığı gösterilmiştir. Bu nedenle, yöntem istenirse bir ön sınıflandırıcı olarak kullanılabilirliği iddia edilmekte ve özellikle hesaplama karmaşıklığının veri örneklerinin sayısı olan N'ye eşit olduğu gösterilmektedir. Ayrıca kullanılan yöntemin taşıyıcı faz ve frekans kaymaları varlığında güçlü olduğu ve tekrarlı olarak uygulanabilecek bir altyapısı olduğu vurgulanmıştır. Teorik argümanlar, kapsamlı simülasyonlar ve mevcut yaklaşımlarla karşılaştırmalar yoluyla doğrulanmıştır. Şekil 4'te kümülanı dayalı hiyerarşik sınıflandırma şeması verilmiştir. Bu şema ve çalışma sırasında ortaya konan çeşitli eşik değerleri yardımıyla modülasyon bilgisi tahmini çok hızlı bir şekilde elde edilebilmektedir.

2001 yılında A.K. Nandi vd. tarafından gerçekleştirilen çalışmada ise [32], 90'ların sonlarından itibaren popüler hale gelen YSA ile modülasyon sınıflama probleminin çözüm aranmıştır. Toplamda 10 adet farklı modülasyon türünün herbirinden 3000 örnek toplanmış ve bu örnekler eşit sayıda eğitim, test ve doğrulama örneklerine ayrılmışlardır. Ardından işaretlere ait belirlenen spektral ve istatistik tabanlı özelliklerin kombinasyonları elde edilmiş ve MLP kullanılarak sınıflandırma işlemi gerçekleştirilmiştir. Deneyler sonunda özellikle $SNR=0dB$ 'de elde edilen %98'lik başarımlar SNR 'ın yükselmesi ile %100'e ulaşmıştır. $SNR=-5$ için ise sınıflama doğruluğu %90 olarak bulunmuştur.



Şekil 4: Kümülanı dayalı hiyerarşik sınıflandırma şeması.

[32]'deki çalışmanın devamı niteliğinde olan başka bir çalışmada ise [33], yazarlar ilk olarak bir önceki çalışmada kullandıkları modülasyon havuzunu genişletmişler, işaretlerden yeni istatistiksel özellikler elde etmişler ve kullandıkları MLP ağında geriye yayılma ve esnek geriye yayılma algoritmalarını kullanmışlardır. Gerçeklenen deneylerde esnek geriye yayılma ile SNR=0 için %99 sınıflama doğruluğuna ulaşılmış ayrıca esnek geriye yayılma algoritmasının geriye yayılma algoritmasına göre daha hızlı bir algoritma olduğu irdelenmiştir. Çalışmanın son bölümünde ise en iyileme algoritması olan genetik algoritma yardımıyla elde edilen öznelilikler arasından en anlamlı olanları seçilmeye çalışılarak boyut azaltılması yoluna gidilmiştir. Genetik algoritma ile yapılan boyut indirgeme ile toplamda elde edilen 17 adet öznelilik çeşitli boyutlara (15, 12, 11, 6) düşürülmüş ve örneğin elde edilen 6 öznelilik ile sınıflandırma işlemi gerçekleştirildiğinde SNR=0 için bütün özneliliklerin kullanıldığında elde edilen sınıflama doğruluğu olan %99 başarımla elde edilebilmiştir. SNR=-5 için ise ne yazıkki %93 başarımla elde edilebilmiş ve tüm öznelilikler kullanıldığında elde edilen %95 başarımların altında bir sınıflama doğruluğu elde edilebilmiştir.

Wu vd. tarafından 2008 yılında gerçekleştirilen çalışmada ise [34], çok yollu solma problemiyle mücadele etmek ve sağlam bir AMC planı tasarlamak için yeni bir HOS tabanlı kör kanal tahmin algoritması önerilmiştir. Kullanılan AMC algoritma yapısının en büyük avantajı olarak, AMC için gerekli olan temel özellikler dikkatli bir şekilde tasarlayarak, tam kanal bilgisinin (kanal dürtü yanıtı, stokastik kanal modeli, vb.) elde edilmek zorunda olunmayışı ve bu nedenle önerilen yönteminin pratikte uygulanabilir olacağı söylenebilir.

2010 yılında Shermeh ve Ghazalian ikilisinin ortaya koyduğu çalışmada [35], AMC problemi için çok sınıflı bir sınıflandırıcı olarak bir hiyerarşik destek vektörü makine tabanlı yapı önerilmiştir. Sayısal haberleşme sinyalinin tanınması için ise etkin özellikler olarak daha yüksek mertebeden momentler (sekize kadar) ve daha yüksek mertebeden kümülanlar (sekize kadar) önerilmiştir. Destek vektörü makinelerinin uygun çekirdek parametrelerini seçmek için ise genetik algoritma kullanılmış ve bu sayede AMC performansının verimli bir şekilde geliştiği gözlemlenmiştir. Simülasyon sonuçlarına göre, önerilen genetik algoritma-destek vektörü makine yönteminin çok düşük SNR'lerde bile farklı modülasyonların tanınması için yüksek bir başarı oranına sahip olduğunu göstermektedir. Ancak yinede çalışmada herbir modülasyon tipi için destek vektörü makinede kullanılan birbirinden farklı özneliliklerin elde edilmesinin uyarlamalı olmaması bu yöntem hakkındaki yapılabilecek en büyük eleştiridir.

Aslam vd. tarafından gerçekleştirilen çalışmada ise [36], IEEE 802.11a standartlarında sık tercih edilen BPSK, QPSK, QAM16 ve QAM64 sinyallerinin otomatik sınıflandırılması için genetik programlama ve k-en yakın komşuluk (k-Nearest Neighbor, kNN) algoritmasının kombinasyonunu içeren ve kümülan özneliliklerini kullanan bir AMC şeması önerilmiştir. kNN, eğitim aşamasında eğitim sırasında kişilerin fitness değerlendirilmesinde ve genetik programlama bireylerinin uygunluğunu değerlendirmek için kullanılmıştır. Ayrıca, test aşamasında, kNN, genetik programlama tarafından üretilen en iyi bireyin sınıflandırma performansının çıkarılması için kullanılmıştır. Çalışma, sınıflandırma doğruluğunu geliştirmek için iki aşamaya ayrılmış ve her aşama için iki ağaç oluşturulmuştur. İlk aşamada BPSK, QPSK ve QAM16/QAM64 sınıflandırmak için tek bir ağaç oluşturulur. İkinci aşamada ise

QAM16 ve QAM64 sınıflandırmak için başka bir ağaç oluşturulur. Böylece, özellikle birbirine çokca karışan QAM16 ve QAM64 için özel öznelilikler seçilmesine bağlı olarak bu iki sınıfın birbirine karışması minimize edilmiş ve geneldeki modülasyon tespit başarımları yükselmiştir. Genetik programlama-kNN yöntemi ile elde edilen sonuçlar Destek Vektör Makinesi ve Naif Bayes sınıflandırıcıları ile kıyaslanmış ve genetik programlama-kNN'nin daha başarılı olduğu ispatlanmıştır.

3.2.2 Dalgacık Dönüşümü Temelli Çalışmalar

Ho vd. tarafından 2000 yılında gerçekleştirilen çalışmada [37], gelen sinyale ait başlangıç bilgisine gerek olmadan, mPSK ve mFSK sinyallerinin tahmini için dalgacık dönüşümü bazlı modülasyon tanımlayıcısı önerilmiştir. Çalışmada kullanılan tanımlayıcı, girişin dalgacık dönüşümü büyüklüğünü alır ve modülasyon tiplerini ayırt etmek için farklı dalgacık örüntüleri kullanır. PSK'nın WT büyüklüğü faz değişikliklerinde piklere sahip bir DC seviyesi iken, FSK'nın çok aşamalı bir işlevi vardır. PSK ve FSK arasındaki ayırım, zirveleri çıkarmak için medyan filtrelemeden sonra WT büyüklük varyansının hesaplanmasıyla elde edilir. mPSK'nın tanımlanması, faz değişikliklerine bağlı farklı pik değerlerinin bulunmasıyla elde edilir ve mFSK, WT büyüklüğündeki DC seviyelerinin gözlemlenmesiyle tanımlanır. Gerçeklenen simülasyonlar, SNR=15dB'de 100 sembol ve ara frekansın yaklaşık 10 katı bir örnekleme oranı ile PSK ve FSK arasındaki tanımlama hatasının % 2'den az olduğunu ve mPSK ve mFSK'nın tanımlama doğruluğunun birbirine yakın ve %100 olduğu gösterilmiştir.

2010 yılındaki bir diğer WT tabanlı AMC çalışmasında ise [38], zaman ve frekansta sinyalin özelliklerini tam olarak ortaya koyma kabiliyetinden dolayı sürekli WT kullanılmıştır. İşaretlerden çıkarılan öznelilikler, sürekli WT'nin daha yüksek sıralı istatistiksel anlardır ve bu öznelilikler ile MSK, FSK, ASK, PSK, and QAM modülasyonlarının sınıflandırılması gerçekleştirilmiştir. Ayrıca esnek geri yayılım öğrenme algoritması kullanılarak eğitilmiş çok katmanlı bir ileri besleme ağda sınıflandırıcı olarak önerilmiştir. Önerilen algoritma, düşük SNR'lerde yüksek doğrulukla farklı modülasyon şemalarını tanıyabilmektedir ve SNR>4dB için ise yüksek tam sınıf modülasyon tanıma performansına sahiptir. Ayrıca, hem AWGN hem de birkaç solma kanalı modeli üzerinde yapılan işlemler test edilmiş ve sürekli WT tabanlı AMC işleminin mükemmel performans gösterdiğini görülmüştür. Çalışmada ortaya konan önemli katkılardan biride kullanılan dalgacık filtre türünün sistemin performansı üzerindeki etkisidir. Çalışma incelendiğinde, aynı şartlar altında (SNR = 1dB) farklı dalgacık aileleri kullanılarak elde edilen tam sınıf tanıma performanslarının birbirlerinden farklılıklar gösterdiği görülmektedir. Özellikle literatürde sıkça kullanılmakta olan Haar ve Daubechies filtrelerinin kullanılması ile elde edilen başarımların diğer birçok filtre ile elde edilenlerden daha düşük olduğu görülmektedir. Özellikle mevcut şartlar içerisinde "Meyer filtre" kullanımı ile elde edilen sonuçlar dalgacık ailesindeki bireyler arasında ki en yüksek sonuç olarak karşımıza çıkmaktadır.

3.2.3 Çevrimsel Özneliliklerin Kullanıldığı Çalışmalar

Dobre vd. tarafından 2003 yılında gerçekleştirilen bir çalışmada [39], bir örüntü tanıma çerçevesi içinde QAM, PSK ve ASK sinyalleri için sırasıyla dördüncü, altıncı ve sekizinci dereceden döngüsel kümülanlara (CC) dayanan homojen özellik vektörlerini kullanarak AMC problemine çözüm aramışlardır. Alıcıda temel bant sinyalinin CC'lerinin analizi

gerçekleştirilir ve özellik seçimi için kullanılır. Alıcıdaki temel bant sinyalinin döngü spektrumu, yükseltilmiş bir kosinüs darbe şekli için aşırı bant genişliğinin bir fonksiyonu olarak türetilir ve aşırı örnekleme faktörü üzerinde gerekli ve yeterli bir koşul elde edilir. İlk olarak gerçek ve karmaşık değerli takımyıldız sınıfları arasında ayırım yapan ve daha sonra seçilen sınıf içindeki modülasyon türlerini ayırt eden bir hiyerarşik sınıflandırma şeması, gelişmiş sınıflandırma performansı sağlayacağı gösterilmiştir. Ayrıca, dördüncü dereceden CC'ler, iki sınıf arasında ayırım yapmak için uygun istatistikler olduğu ve sekizinci derece CC'lerin ise her bir sınıftaki sinyalleri ayırt etmek için daha uygun öznelilikler olduğu vurgulanmıştır.

Dobre vd. tarafından 2004 yılında gerçekleştirilen bir başka çalışmada ise [40], QAM sinyallerinin otomatik olarak tanınması için güçlü yüksek mertebeden CC temelli özellikler önerilmiştir ve taşıyıcı faza, frekans kaymalarına ve darbe gürültüsüne bağlı sınıflandırma performansı bozulumu incelenmiştir. Önerilen sınıflandırıcının, ideal olmayan bir senaryo altında [39]'da önerilenlerden üstün olduğu gösterilmiştir. Bu çalışmada kullanılan algoritmanın avantajı olarak, taşıyıcı faz ve frekans kaymalarına olan sağlamlığı olduğu vurgulanmış ve ilk önce sinyal sınıfı formatını (M-QAM, M-PSK, vb.) tanımlayan ve daha sonra seçilen sınıf içindeki modülasyon sırasını (M) seçen bir hiyerarşik sınıflandırma şeması, sınıflandırıcı genelliğini arttırmak için kullanılabileceği irdelenmiştir.

Fehske vd. tarafından gerçekleştirilen bir çalışmada ise [41], döngüsel spektral analiz ve bir nöral ağ tarafından gerçekleştirilen örüntü tanıma dayalı iletişim sinyallerinin sınıflandırılması için bir yöntem önerilmiştir. Çalışma, taşıyıcı ve bant genişliği bilgisinin varlığı/yokluğu üzerinden iki farklı durum için gerçekleştirilmiştir. Her sinyal tipinin farklı özellikleri, döngüsel spektral analiz kullanılarak çıkarılmış ve bu özelliklere dayanarak sinyalleri sınıflandırmak için bir sinir ağı tasarlanmıştır. Simülasyonlarda, her iki durum için çeşitli gürültü koşullarında olağanüstü sınıflandırma performansları elde edilmiştir. Sinyal seti BPSK, QPSK, FSK, MSK, AM ile sınırlandırılmış, bir seferde iki veya daha fazla sinyalin mevcut olmadığı varsayılmıştır.

2009 yılında Ramkumar tarafından ortaya konulan çalışma ise [42], döngüsel özellik tespit algoritmalarına dayalı otomatik modülasyon sınıflandırması ile ilgili literatürdeki en fazla yayın alan review çalışması olmasıdır. Çalışmada ilk olarak modülasyon sınıflandırma algoritmalarının geniş sınıflarının kısa bir araştırmasıyla başlanmış ve daha sonra, makalenin ana konusunu, yani döngüsel özellikler kullanan AMC algoritmaları sunulmuştur. Basit öznelilik algoritmalarının, sinir ağları veya gizli Markov modelleri gibi sınıflandırıcılar ile nasıl kullanılabileceğini basit örneklerle anlatılmış ve toplamsal gürültü sınıflandırıcının performansına etkileri araştırılmıştır. Ayrıca, döngüsel spektrum tabanlı AMC'nin diğer AMC algoritmaları ile birlikte nasıl çalışabileceğini göstermek için AMC dördüncü dereceden kümülanlar bazında kısaca açıklanmıştır. Ayrıca, dağıtılmış algılama yöntemlerinin, modülasyon sınıflandırmasının güvenilirliğini artırma potansiyeline sahip oldukları vurgulanmış ve dağıtılmış sinyal tespiti ve sınıflandırması için döngüsel özellik tabanlı yöntemlerin kullanımı hakkında bazı sonuçlar sunulmuştur.

Yine Dobre vd. tarafından gerçekleştirilen bir başka çalışmada ise [43], düz solma kanallarında doğrusal dijital modülasyonlar için tek ve çok antenli yüksek mertebeden CC bazı sınıflandırıcılar sunulmuştur. Önerilen tek-anten sınıflandırıcı, büyük bir modülasyon havuzuna uygulanabilen, bilinmeyen

faza ve zamanlama kaymasına karşı sağlamlık avantajına sahiptir. Ayrıca, çoklu anten sınıflandırıcı, mekânsal bir çeşitlilik şeması olarak seçim birleştirmeyi kullanarak solma etkisini azaltır. Bunun ayrıca, antenler arasındaki olası bir ilişkiye ve farklı solma seviyelerini temsil eden Rice (K) faktörünün varyasyonlarına karşı da güçlü olduğu gösterilmiştir. Çalışmada ayrıca, literatürde önerilen diğer sınıflandırıcılar ile adil bir karşılaştırma yapılmakta ve önerilen sınıflandırıcı etkinliğini kanıtlamaktadır. Ek olarak, yüksek mertebeli CC polispektra için analitik kapalı-biçimli ifadeler, solma kanalı, frekans ve zamanlama ofsetleri ve ilave Gauss gürültüsü tarafından etkilenen doğrusal dijital olarak modüle edilmiş sinyaller için türetilmiştir. Yükseltilmiş bir kosinüs darbe şekli için, döngü ve spektral frekans domenlerinde örtüşme (aliasing) işleminden kaçınmak için, aşırı örnekleme faktörü için gerekli ve yeterli bir koşul elde edilmiştir.

2012 yılında, yaygın modülasyon ve çoklu anten iletim şemalarının tanımlanması için bir döngü-temelli yaklaşım geliştirilmiştir [44]. Bu yaklaşım, analog, FSK, SCLD, OFDM ve blok-iletile SCLD (BT-SCLD) modülasyonlu sinyalleri engeller. Ayrıca, uzamsal çoğullama ve uzay-zaman blok kodu çoklu iletim anten şemalarının tanımlanması ele alınmıştır. Çalışmada, çeşitli n sayılarındaki dereceler ve q konjugasyon sayısı için iletişim sinyallerinin CC'leri ve CF'leri ile ilgili temel sonuçları özetlenmektedir. Yapılan çalışmadaki tanım ve önermelerde, solma ve Doppler yayılması gibi faz, frekans ve zamanlama kaymalarını ve kanal etkilerini içeren bir temel bant sinyal gösterimi dikkate alınmıştır.

En yüksek mertebeden istatistiklerin güvenilir tahminlerini elde etmek için daha uzun gözlem süreleri gerekli olduğundan, en düşük mertebeden CC'nin döngü frekansı alanı tarafından sağlanan ayırt edici bilgi, sinyal tanımlaması için özellikle önemlidir. [45, 46]'da, AM sinyallerinin sıfır CF ile birinci dereceden çevrimsellik sergilediği, M-FSK sinyallerinin ise modülasyon sırasına eşit olan CF'lerin sayısı ile birinci dereceden çevrimselliği gösterdikleri ve bunların frekans ayırma ve sembol alfabeye değerlerine bağlı olduğu gösterilmiştir. Buna ek olarak da, frekans kaymasının, CF'lerin eşit bir kaymasıyla sonuçlandığı belirtilmiştir. Diğer taraftan, sinyal takımyıldızındaki simetriye bağlı olarak, SCLD, BT-SCLD ve OFDM sinyallerinin birinci mertebeden çevrimsellik göstermediği sonucuna varılabilir. Bu nedenle, birinci mertebeye çevrimsellik AM (tek bir birinci mertebeden CF), M-FSK (M birinci dereceden CF'ler) ve SCLD, OFDM ve BT-SCLD sinyalleri (birinci mertebeden CF içermeyen) arasında ayırım yapmak için kullanılabilir. İkinci mertebeden/tek-konjuge çevrimsellik frekans seçici solma kanallarında SCLD, OFDM ve BT-SCLD sinyallerinin tanınmasına da uygulanabilir. SCLD sinyalleri için çevrimsellik, sembol süresinin $1/T$ karşılıklarının tamsayı katlarına eşit ve sıfır civarında geciktirilen CF'lere bağlı darbe şekli ile uyarılır. OFDM sinyalleri için ise, CP tarafından döngüsellüğün indüklenmesi, CF'lerin OFDM sembolünün süresinin karşılıklı tamsayı katlarına eşit olması ve yararlı sembol süresi etrafında gecikmesi ile sağlanır [47, 48]. Son olarak, BT-SCLD sinyalleri için, çevrimsellik hem darbe şekli hem de CP nedeniyle ortaya çıkar [49, 50]. Sıfır olmayan CC değerleri, CF'lerde sembol süresinin karşılıklı çarpımlarının tamsayılarına eşittir ve sıfıra yakın olarak geciktirir ve CF'ler, blok süresinin karşıtının tamsayı katlarına eşittir ve $\pm$ yararlı blok süresi etrafında ertelenir [49, 50]. OFDM sinyallerine benzer şekilde, mobil WiMAX ve LTE OFDM sinyalleri, sıfıra yakın gecikmelerde ve sıfıra yakın CC'lerde sıfır-olmayan CC'ler ile ikinci mertebeden çevrimsellik sergilerler (sırasıyla sembol ve CP ile indüklenen çevrimsellik) [51]. Ek olarak, mobil


WiMAX OFDM sinyalleri, pilot alt taşıyıcıların ve giriş bölümünün katkıda bulunduğu çevrimselliği gösterirken, referans sinyalleri LTE OFDM sinyallerinde döngüsellğe katkıda bulunurlar [51]. Bu nedenle, ikinci mertebeden çevrimsellik özellikleri, SCLD (sembolle indüklenen), BT-SCLD (sembol ve CP ile indüklenen) ve OFDM (CP-kaynaklı) modülasyon teknikleri ve mobil WiMAX (sembol, CP- ve giriş kaynaklı) ve LTE (sembol, CP- ve referans sinyali kaynaklı) gibi standart OFDM sinyallerini kullanarak sinyalleri tanımlamak için kullanılabilir. SCLD ve BT-SCLD modülasyonlu sinyallerin ve OFDM alt taşıyıcılarında kullanılan modülasyonun daha fazla tanımlanması, ikinci dereceden döngüsellüğün ayırt edici özellikler sağlamadığı göz önüne alındığında, yüksek dereceli CC'lerin kullanılmasını gerektirmektedir. Bu sinyallerin tanımlanması için [52]'de dördüncü, altıncı ve sekizinci derece CC'ler incelenmiştir. QPSK ve QAM gibi, sinyal takımıyıldızında 16 noktaya sahip bazı SCLD sinyallerinin tanımlanması için dördüncü dereceden CC'ler kullanılabilirken, sekizinci dereceden CC'ler ile ise QPSK ve 8-PSK arasında ayrımsal farklar ortaya çıkmıştır. Birinci mertebeden CF'lere kıyasla, bir frekans kaymasının varlığının ikinci mertebeden/bir-konjuge CF'ler üzerinde bir etkisi olmadığı dikkati çekmektedir. Daha önce tarif edilen çalışmalar, tekli veya çoklu alıcı antenleri kullanıldığında, tek bir verici anten için gerçekleştirilmiştir. Ayrıca, SM (spatial multiplexing) ve AL STBC (Alamouti space-time block code) gibi çok sayıda verici anten şemasını tanımlamak için çevrimsellik kullanılabilir.

İki alıcı anten için ikinci dereceden çevrimsellik uygulanabilirken [53, 54], tek bir alıcı anten için ise dördüncü dereceden istatistik gereklidir [49, 55]. STBC'ler için, iki antenle alınan sinyallerin ikinci dereceden / sıfır-konjuge CC'lerinin sıfır olmayan değerleri kod uzunluğu ile indüklenir [53-55]. Örneğin, sembol periyodu (ST4) 'ün dört kez blok uzunluğuna sahip AL STBC ve STBC için, CF'ler sırasıyla 1/2T ve 1/4T tamsayı katlarıdır [53, 54]. Ek olarak, CC piklerini veren

gecikmeler, AL STBC için $\pm T$, ST4 için $\pm T$, $\pm 2T$ ve $\pm 3T$, 'dir [53, 54]. Farklı kod uzunluklarına sahip kodları tanımlamak için farklı CF kombinasyonları kullanılabilir [53-55]. İkinci mertebeden/sıfır konjuge CF'lerin frekans kaymasının iki katı ile kaydırılmasında önemli bir noktadır. Sinyal tanımlaması için ilk adım, verici antenlerin sayısını tahmin etmek olmalıdır [56, 57] ve eğer birden fazla verici anteni varsa, iletim şemasını belirlemektir. Sonrasında modülasyon formatı ve diğer sinyal parametreleri tanımlanacaktır [45, 51, 58, 59]

Sinyal tipinin tanımlanması için çevrimselliğin uygulamasını gösteren bir blok diyagram Şekil 5'te sunulmuştur. Taşıyıcı, dalga şekli ve sembol zamanlaması kurtarma ve gürültü ve sinyal gücü kestirimi gibi ön işlem adımları gerektirmemesi, birinci ve ikinci mertebeden çevrimsellik tabanlı tanımlama algoritmalarının uygulanmasının basitleştirmiştir [45, 46, 49-51]. Diğer taraftan, yüksek mertebeden çevrimsellik tabanlı algoritmalarda, sinyal genliği ve dalga şekli geri kazanımının tahmin edilmesi de gerekmektedir [52].

2017 yılında Satija vd. tarafından ortaya konulan çalışmada ise [60], tamamlanmamış kompozit sözlük matrisi kullanarak seyrek sinyalin ayrışmasına dayanan yeni bir sınıflandırıcı önermişlerdir. Döngüsel öznitelik katsayıları, birincil kullanıcının veya sesin modülasyon formatının sınıflandırılması için özellikler olarak çıkarılmıştır. Önerilen sınıflandırıcı temel ilkesi, bu aşırı eksik sözlük kullanılarak, ℓ_1 normunu en aza indirmenin ardından, yeniden yapılandırılmış seyreklik katsayılarına dayanarak alınan sinyal modülasyon formatını sınıflandırmaktır. Dört modülasyon şeması (BPSK, QPSK, FSK ve MSK), düşük SNR'de sınıflandırılır ve sonuçlar, YSA, NB, k-NN, doğrusal diskriminant analizi, destek vektör makinesi gibi mevcut sınıflandırıcılar ile karşılaştırılmıştır. Özellikle gürültülü senaryoda ki sağlam sınıflandırma kabiliyeti nedeniyle önerilen sınıflandırıcının bilişsel radyo için uygun bir aday olduğu vurgulanmıştır.



Şekil 5: Sinyal tipinin tanımlanmasına çevrimsellik uygulanması.

2017 yılında Satija vd. tarafından ortaya konulan bir başka çalışmada ise [61], karışık Gauss ve darbe gürültüsü altında modülasyon şemalarını sınıflandırmak için yeni bir yöntem önerilmiştir. Döngüsel temelli modülasyon sınıflandırıcılarının doğrudan kullanımı, darbe gürültüsü modeli için uygun değildir, bu nedenle önerilen yöntem, darbe gürültüsünü ortadan kaldıran ve böylece modülasyon şemalarını doğru bir şekilde sınıflandırabilen seyrek sinyal ayrıştırma algoritmasının kullanılmasını içerir. Simülasyon sonuçlarından, döngüsel bazlı sınıflandırıcıların performansının, Gauss olmayan darbe gürültüsü varlığında önerilen algoritma kullanılarak önemli ölçüde iyileştirildiği kanıtlanmış ve aksine, yöntemin performansı seyrek sinyal ayrıştırma algoritması kullanılmadan önemli ölçüde azaldığıda gösterilmiştir. Her iki sonucun karşılaştırması, önerilen algoritmanın üstünlüğünün kanıtını vermektedir. Önerilen yöntemin etkinliğini göstermek için, karışıklık matrisi, çeşitli SNR değerleri ve dürtü gürültüsünün büyüklükleri altında BPSK, QPSK, MSK ve FSK dahil olmak üzere farklı modülasyon şemaları için formüle edilmiş ve algoritmanın sağlamlığı, seyrek sinyal ayrıştırma algoritmasının uygulanmasından önce ve sonra çeşitli sınıflandırıcılar, yani YSA, k-NN, doğrusal diskriminant analizi ve destek vektör makinesi tarafından doğrulanmıştır. Sonuçta, döngüsel özellikli modülasyon sınıflandırıcı performansının, önerilen yaklaşım kullanılarak Gauss olmayan dürtü gürültüsü altında muazzam bir şekilde geliştirilebileceği gösterilmiştir.

3.2.4 Takımyıldız Grafiğinin Kullanıldığı Çalışmalar

Takımyıldız diyagramı, dijital modülasyonların tasarımı ve değerlendirilmesi için tipki kümülant ve dalgacık dönüşümü gibi sıkça kullanılan geleneksel ve güçlü bir araçtır. Takımyıldız grafiği yaklaşımı ile alınan işarete ait olan bilgi, gürültü, kanal ve alıcı uyumsuzluğu gibi bozucu etkilerle deforme olsada takımyıldız şeklinde ifade edilebilir ve takımyıldızının geometrisi ile temsil edilir. Takımyıldız tabanlı modülasyon tanımlaması üç ana aşamada:

- takımyıldız şekli deformasyon modelleme,
- takımyıldızın yeniden inşası ve
- sonuç motor gelişimi

ile gerçekleştirilir.

Mobasseri tarafından gerçekleştirilen çalışmada [62], dijital modülasyon tanıma için sağlam bir imza olarak takımyıldız şeklini kullanmayı önerilmiştir. Bu çalışmada ilk olarak, bulanık C-kümelenme kümelenmesinin bilinmeyen takımyıldızın sağlam bir şekilde iyileşmesini sağlayabildiği gösterilmiştir. Bayes çıkarımını gerçekleştirmek için, yeniden yapılandırılmış takımyıldız, birçok değerli değerli homojen olmayan mekânsal rasgele alanla modellenir. Aday modülasyonlar için, karşılık gelen rasgele alanlar, off-line olarak modellenmiş ve ardından tipi bilinmeyen takımyıldız şekli daha önceki model oluşturma aşamasına dayanan bir ML kuralı ile sınıflandırılmıştır. Bu çalışmada takımyıldız merkezli bir yaklaşım kullanılması nedeniyle, analog modülasyonlar ele alınamamıştır. Aynı nedenden ötürü, sayısal modülasyonların isteğe bağlı boyutu önerilen algoritmanın parametrelerine dâhil edilir.

2008 yılında gerçekleştirilen çalışmada ise [18], genetik algoritma ve hiyerarşik kümeleme, alınan sinyalin takımyıldız diyagramını kullanarak, QAM ve PSK ailelerinin farklı modülasyon tiplerini sınıflandırmak için kullanılmıştır. Modülasyon seviyelerine eşit olan doğal kümeleri bulmak için genetik algoritma ve hiyerarşik kümeleme kullanarak

semboller sınıflandırılmıştır. Bu yaklaşımın ana avantajı, karar sınırlarının doğru bir şekilde tanımlanabilmesidir. Simülasyon sonuçları önerilen yöntemin gürültü varlığında yüksek bir başarı oranına sahip olduğu ve FSK gibi tek boyutlu modülasyon şemaları üzerinden kolaylıkla uygulanabileceğini gösterilmiştir. Bu yöntemin bir başka avantajı da, kümelerin nihai merkezlerini hesaplamak ve bu merkezlerin yerlerini bulmak için takımyıldız diyagramından faydalanılması ve QAM/PSK modülasyonlu işaretlerin yüksek sınıflama doğruluğu ile birbirinden ayrılabilmesidir.

3.2.5 Diğer Çalışmalar

1990 yılında Hsue ve Soliman tarafından ortaya konan çalışmada [63], sıfır geçiş teknikleri kullanılarak sabit zarf modülasyonlu sinyallerin modülasyon tiplerini otomatik olarak rapor eden bir modülasyon tanıyıcı geliştirilmiştir. Sıfır geçişli örnekleyici, bir sinyal koşullandırıcı olarak, geniş dinamik bir frekans aralığında doğru faz geçişi bilgisi sağlama avantajına sahiptir ve sıfır geçiş varyansı ile taşıyıcı-gürültü oranı (CNR) ve taşıyıcı frekansı gibi sinyal parametreleri tahmin edilebilir. Faz farkı ve sıfır geçiş aralığı histogramları modülasyon tanıma için özelliklerin rolünü oynar. Elde edilen simülasyon sonuçlarından, $SNR > 15$ dB için makul bir ortalama sınıflandırma olasılığının elde edilebileceği gösterilmektedir.

Fanggang Wang ve Xiaodong tarafından 2010 yılında gerçekleştirilen çalışmada ise [64], Kolmogorov-Smirnov (K-S) testine dayanan modülasyon sınıflandırmasına yeni bir yaklaşım önerilmiştir. K-S testi, uyumun iyiliğini ölçmek için parametrik olmayan bir yöntemdir. Temel izlek, alınan sinyalden türetilen bazı karar istatistiklerinin ampirik kümülatif dağılım fonksiyonunun (Empirical Cumulative Distribution Function, ECDF) hesaplanmasını ve her bir aday modülasyon formatı altında sinyalin CDF'leri veya ECDF'leri ile karşılaştırılmasını içerir. K-S tabanlı modülasyon sınıflandırıcılar, AWGN kanalı, düz solma kanalı, OFDM kanalı ve bilinmeyen faz ve frekans offsetleri ile birlikte Gauss olmayan gürültü kanalı dâhil olmak üzere çeşitli kanallar için geliştirilmiş ve hem QAM hem de PSK modülasyonlarının birbirinden ayrılması için kullanılmıştır. Kapsamlı benzetim sonuçları, geleneksel kümülant bazlı sınıflandırıcılar ile karşılaştırıldığında, önerilen K-S sınıflandırıcılarının üstün sınıflandırma performansı sağladığını, daha az sayıda sinyal örneği gerektirdiğini (bu sayede hızlıdır) ve çeşitli kanal bozukluklarına daha dayanıklı olduğunu ortaya koymaktadır.

Jian Liu ve Qiang Luo tarafından ortaya konan çalışmada [65], öznetelik çıkarımı alt sistemi ve sınıflandırıcı alt sistemine dayalı olarak bilişsel radyoda dijital modülasyon sınıflandırması için yeni bir modülasyon sınıflandırma algoritması önerilmiştir. Makalede, kesirli Fourier dönüşümünün (Fractional Fourier Transform, FRFT), sinyal ayrımında çok güçlü bir araç haline getiren özel özelliklerini teyit etmekte ve aynı zamanda, yeteneklerinden faydalanan bir algoritma içinde dalgacık dönüşümü ve FRFT'yi yerleştirerek modülasyon tanıma aralığını genişletmektedir. Önerilen algoritma ile alınan sinyalin dalgacık dönüşümü ve FRFT'den özellikleri çıkarılıp ve düşük AWGN ile rayleigh solma kanalları aracılığıyla incelenip alt SNR'lerde bile yüksek doğrulukta farklı modülasyon şemalarını tanıyabildiği gösterilmiştir.

Ghauri vd. tarafından 2014 yılındaki çalışmada [66], Gabor filtre ağı tabanlı bir yaklaşım, Gabor filtre ağının parametrelerini ayarlayarak sayısal modüle edilmiş sinyallerin özellik çıkarılması ve sınıflandırılması için kullanılmıştır. Dijital modüle edilmiş sinyallerin modülasyonu AWGN etkisi altında

yapılmış ve sınıflandırma amacı için PSK 2 ila 64, FSK 2 ila 64 ve QAM 4 ila 64 olmak üzere toplamda 18 farklı modülasyonun tespitine çalışılmıştır. Gabor filtre ağı iki katmanın ağ yapısını kullanır; Giriş katmanı olan birinci katman, uyarlanabilir özellik çıkarımı parçasını oluşturur ve ikinci katman, sinyal sınıflandırma kısmını oluşturur. Gabor atom parametreleri, Delta kuralı kullanılarak ve en düşük ortalama kare (LMS) algoritması kullanılarak Gabor filtresinin ağırlıklarının güncellenmesiyle ayarlanır. Simülasyon sonuçları, önerilen yeni modülasyon sınıflandırma algoritmasının, AWGN kanalı üzerindeki düşük sinyal gürültü oranına (SNR) yüksek sınıflandırma doğruluğuna sahip olduğunu göstermektedir.

Udit Satija vd. tarafından 2015 yılında ortaya konan çalışmada ise [67], farklı dijital modülasyon şemalarının YSA, SVM, LDA, NB ve kNN gibi farklı sınıflandırıcılar kullanarak sınıflandırılması için Stockwell dönüşümü (S-dönüşümü) temelli öznelikler sunulmuştur. S-dönüşümü, bir sinyalin zaman-frekansı veya uzaysal-frekans lokalizasyonunu sağlar. Gerçekleştirilen çalışmada S-dönüşümünün bu özelliği, farklı modülasyon şemaları için iyi diskriminant özellikler vemesini sağladığı görülmüştür. Sınıflandırma için iki basit özellik, yani enerji ve entropi kullanılmış ve farklı modülasyon şemaları yani BPSK, QPSK, FSK ve MSK'nın birbirinden ayırma başarımları gözlemlenmiştir. Sonuçlar, doğru sınıflandırma olasılığı, sınıflandırma doğruluğu dâhil olmak üzere performans matrisi ve 0 ila 20 dB arasında değişen SNR aralığı için hesaplama karmaşıklığı (zaman) içeren dalgacık dönüşümü temelli özellikler ile karşılaştırılmıştır. Sonuçlara dayanarak, S-dönüşümü tabanlı özelliklerin, daha iyi sınıflandırma doğruluğu ve daha az hesaplama karmaşıklığı ile dalgacık dönüşümü temelli özelliklerden daha üstün olduğu görülmüştür.

4 Sonuçlar

Kapsamlı bir literatür araştırmasına dayanarak, bu makalede otomatik modülasyon sınıflandırmasına (AMC), olasılık temelli (LB) ve özellik tabanlı (FB) yöntemlere ilişkin iki ana yaklaşımı özetlenmiş ve avantajlarını ve dezavantajlarını belirtilmiştir. LB yaklaşımı en iyi performans sağlamasına rağmen, bilinmeyen parametrelerin sayısı arttığında karar fonksiyonu için kesin bir analitik çözüm elde etmek zordur. Ayrıca, kapalı bir çözüm (closed-form solution) olduğunda, hesaplama karmaşıklığından dolayı sınıflandırıcının uygulanması zorlaşacaktır. FB yaklaşımında ise, modülasyon formatını tanımlamak için bazı sinyal özellikleri kullanılır. FB yöntemler en iyiye yakın olmasına rağmen, bu yöntemleri uygulamak daha basittir. Anlık genlik, faz, frekans, sinyal dalgacık dönüşümü ve momentler, kumulantlar ve anlık kumulantlar gibi sinyal istatistiklerini kullanan birçok AMC algoritması, diğer çeşitli tekniklerin yanı sıra kompakt bir şekilde sunulmuştur. Bir hiyerarşik sınıflandırma sisteminde, bu özelliklerin bazıları modülasyon sınıfını tanımlamak için kullanılabilir ve daha sonra her bir sınıf içinde modülasyon sırası belirlenebilir.

Bilinen AMC algoritmalarının çoğunun etkili bir şekilde uygulanması için doğru ön işlem gereklidir. Ekstrakt parametre tahmini için düşük karmaşıklıkla kör algoritmaların kullanılması AMC'de ilgi konusudur. Ayrıca, ön işlemeye daha az dayanan sınıflandırma yöntemlerinin geliştirilmesi (örneğin, derin öğrenme yöntemleri), daha fazla araştırılması gereken bir başka konudur. Tekli taşıyıcıya karşı çoklu taşıyıcı modülasyon tanıma, tekli ve çoklu iletim antenlerinden alınan sinyalin sınıflandırılması, uzay-zaman modülasyon formatının tanımlanması vb. gibi ortaya çıkan kablolu teknoloji problemlerinin bir sonucu olarak yeni AMC problemleri ve

bunlara dönük çözüm önerileri ortaya çıkmıştır. Şu anki geline nokta, bu problemlerin herbirinin çözümü için ayrı ayrı çözüm önerileri sunulmakta ve birçok problemin yada durumun çözümünü birlikte içeren çalışmalar ne yazık ki yer almamaktadır.

5 Kaynaklar

- [1] Mitola J. Cognitive radio: An integrated agent architecture for software defined radio. Doktora Tezi, Royal Inst. Technol. (KTH), Stockholm, Sweden, 2000.
- [2] Federal Communications Commission. "Spectrum policy task force". USA, 02-135, 2002.
- [3] Bayrakdar ME, Çalhan A. "Artificial bee colony-based spectrum handoff algorithm in wireless cognitive radio networks". *International Journal of Communication Systems*, 31(5), e3495, 2018.
- [4] Bayrakdar, ME, Çalhan A. "Non-preemptive Queueing Model of Spectrum Handoff Scheme Based on Prioritized Data Traffic in Cognitive Wireless Networks". *ETRI Journal*, 39(4), 558-569, 2017.
- [5] Perlman B, Laskar J, Lim K. "Fine-tuning commercial and military radio design". *IEEE Microwave Magazine*, 9, 95-106, 2008.
- [6] Ball S, Ferguson A. "Consumer applications of cognitive radio defined networks". *IEEE DYSpan*, 518-525, Baltimore, Maryland, USA, 2005.
- [7] Dobre OA, Abdi A, Bar-Ness Y, Su W. "Survey of automatic modulation classification techniques: classical approaches and new trends". *Journal of IET Communication*, 1(2), 137-156, 2007.
- [8] Poisel AR. *Introduction to Communication Electronic Warfare Systems*. Artech House, Norwood, MA, 2008.
- [9] Hong L, Ho KC. "An antenna array likelihood modulation classifier for bpsk and qpsk signals". *IEEE Conference on Military Communications*, 647-651, Anaheim, CA, 2002.
- [10] Sills JA. "Maximum-likelihood modulation classification for PSK/QAM". *IEEE Military Communication Conference*, 217-220, Atlantic City, NJ, USA, 1999.
- [11] Hazza A, Shoaib M, Saleh A, Fahd A. "Classification of digitally modulated signals in presence of non-Gaussian HF noise". *7th International Symposium on Wireless Communication System*, 815-819, York, UK, 2010.
- [12] Panagiotou P, Anastasopoulos A, Polydoros A. "Likelihood ratio tests for modulation classification". *IEEE Military Communications Conference*, 670-674, Los Angeles, CA, USA, 2000.
- [13] Hong L, Ho KC. "BPSK and QPSK modulation classification with unknown signal level". *IEEE Military Communications Conference*, 976-980, Los Angeles, CA, USA, 2000.
- [14] Azzouz EE, Nandi AK. *Automatic Modulation Recognition of Communication Signals*. Norwell, MA, USA, Kluwer Academic, 1996.
- [15] Soliman SS, Yang Y. "Statistical moments based classifier for MPSK signals". *Global Telecommunication Conference*, 72-76, Phoenix, AZ, USA, USA 1991.
- [16] Gardner WA, Spooner CM. "Signal Interception: Performance Advantages of Cyclic Feature Detectors". *IEEE Transactions on Communications*, 40(1), 149-159, 1992.
- [17] Gulati S, Bhattacharjee R. "Automatic blind recognition of noisy and faded digitally modulated MQAM signals". *Annual India Conference*, 1-6, New Delhi, India, 2006.
- [18] Ahmadi N, Berangi R. "Modulation classification of QAM and PSK from their constellation using Genetic Algorithm

- and hierarchical clustering". *3rd International Conference on Information and Communication Technologies: From Theory to Applications*, 1-5, Damascus, Syria, 2008.
- [19] Vito LD, Rapuano S, Villanacci M. "Prototype of an automatic digital modulation classifier embedded in a real-time spectrum analyzer". *IEEE Transaction on Instruments*, 59(10), 2639-2651, 2010.
 - [20] Yuan J, Zhao-Yang Z, Pei-Liang Q. "Modulation classification of communication signals". *IEEE Military Communication Conference*, 1470-1476, Monterey, CA, USA, 2004.
 - [21] Liu P, Ji XJ, Zhao G Q. "Asynchronous classification of digital modulations in multipath flat-fading channel using fourth-order cumulant". *IEEE 13th International Conference on Signal Processing*, 1435-1439, Chengdu, China, 2016.
 - [22] Gardner WA, Spooner CM. "The cumulant theory of cyclostationary time-series". *IEEE Transactions on signal processing*, 42(12), 3387-3408, 1994.
 - [23] Vito LD, Rapuano S. "Validating a method for classifying digitally modulated signals". *Jornal of Measurement*, 42(3), 427-435, 2009.
 - [24] Hazza A, Shoaib A, Alshebeili SA, Fahad A. "An overview of feature-based methods for digital modulation classification". *1st International Conference on Communications Signal Processing and their Applications*, 1-6, Sharjah, United Arab Emirates, 2013.
 - [25] Maliatsos K, Vassaki S, Constantinou P. "Interclass and intraclass modulation recognition using the wavelet transform". *IEEE 18th International Symposium on Personal, Indoor and Mobile Radio Communications*, 1-5, Athens, Greece, 2007.
 - [26] Huan CY, Polydoros A. "Likelihood methods for MPSK modulation classification". *IEEE Transactions on Communications*, 43(234), 1493-1504, 1995.
 - [27] Wei W, Mendel JM. "Maximum-likelihood classification for digital amplitude-phase modulations". *IEEE transactions on Communications*, 48(2), 189-193, 2000.
 - [28] Hameed, F, Dobre OA, Popescu DC. "On the likelihood-based approach to modulation classification". *IEEE Transactions on Wireless Communications*, 8(12), 5884 - 5892, 2009.
 - [29] Xu JL, Su W, Zhou M. "Likelihood-ratio approaches to automatic modulation classification". *IEEE Transactions on Systems, Man, and Cybernetics*, 41(4), 455-469, 2011.
 - [30] Lopatka J, Pedzisz M. "Automatic modulation classification using statistical moments and a fuzzy classifier". *5th International Conference on Signal Processing Proceedings*, Beijing, China, 21-25 August 2000.
 - [31] Swami A, Sadler BM. "Hierarchical digital modulation classification using cumulants". *IEEE Transactions on communications*, 48(3), 416-429, 2000.
 - [32] Wong MLD, Nandi AK. "Automatic digital modulation recognition using spectral and statistical features with multi-layer perceptrons". *6th IEEE International Symposium on Signal Processing and its Applications*, 2, 390-393, Kuala Lumpur, Malaysia, 13-16 August 2001.
 - [33] Wong MLD, Nandi AK. "Automatic digital modulation recognition using artificial neural network and genetic algorithm". *Signal Processing*, 84(2), 351-365, 2004.
 - [34] Wu HC, Saquib M, Yun Z. "Novel automatic modulation classification using cumulant features for communications via multipath channels". *IEEE Transactions on Wireless Communications*, 7(8), 3098 - 3105, 2008.
 - [35] Shermeh AE, Ghazalian R. "Recognition of communication signal types using genetic algorithm and support vector machines based on the higher order statistics". *Digital Signal Processing*, 20(6), 1748-1757, 2010.
 - [36] Aslam MW, Zhu Z, Nandi AK. "Automatic modulation classification using combination of genetic programming and KNN". *IEEE Transactions on wireless communications*, 11(8), 2742-2750, 2012.
 - [37] Ho KC, Prokopiou W, Chan Y. "Modulation identification of digital signals by the wavelet transform". *IEE Proceedings-Radar, Sonar and Navigation*, 147(4), 169-176, 2000.
 - [38] Hassan K, Dayoub I, Hamouda W, Berbineau M. "Automatic modulation recognition using wavelet transform and neural networks in wireless systems". *EURASIP Journal on Advances in Signal Processing*, 2010(42), 532898, 2010.
 - [39] Dobre OA, Bar-Ness Y, Su W. "Higher-order cyclic cumulants for high order modulation classification". *IEEE Military Communications Conference*, 1, 112-117, Boston, MA, USA, 13-16 October 2003.
 - [40] Dobre OA, Bar-Ness Y, Su W. "Robust QAM modulation classification algorithm using cyclic cumulants". In *Wireless Communications and Networking Conference*, 2, 745-748, Atlanta, GA, USA, 21-25 March 2004..
 - [41] Fehske A, Gaedert J, Reed JH. "A new approach to signal classification using spectral correlation and neural networks". *First IEEE International Symposium on New Frontiers in Dynamic Spectrum Access Networks*, 144-150, Baltimore, MD, USA, 8-11 November 2005.
 - [42] Ramkumar B. "Automatic modulation classification for cognitive radios using cyclic feature detection". *IEEE Circuits and Systems Magazine*, 9(2), 27-45, 2009.
 - [43] Dobre OA, Abdi A, Bar-Ness Y, Su W. "Cyclostationarity-based modulation classification of linear digital modulations in flat fading channels". *Wireless Personal Communications*, 54(4), 699-717, 2010.
 - [44] Dobre OA, Inkol R. "Blind signal identification: Achievements, trends, and challenges". *9th International Conference on Communications*, 349-352, Bucharest, Romania, 21-23 June 2012.
 - [45] Dobre OA, Rajan S, Inkol R. "Joint signal detection and classification based on first-order cyclostationarity for cognitive radios". *EURASIP Journal on Advances in Signal Processing*, 2009(7), 656719, 2009.
 - [46] Wang H, Dobre OA, Li C, Inkol R. "M-FSK signal recognition in fading channels for cognitive radio". *IEEE Radio and Wireless Symposium*, 375-378, Santa Clara, CA, USA, 15-18 January 2012.
 - [47] Punchihewa A, Zhang Q, Dobre OA, Spooner C, Rajan S, Inkol R. "On the cyclostationarity of OFDM and single carrier linearly digitally modulated signals in time dispersive channels: Theoretical developments and application". *IEEE Transactions on Wireless Communications*, 9(8), 2588-2599, 2010.
 - [48] Dobre OA, Venkatesan R, Popescu DC. "Second-order cyclostationarity of mobile WiMAX and LTE OFDM signals and application to spectrum awareness in cognitive radio systems". *IEEE Journal of Selected Topics in Signal Processing*, 6(1), 26-42, 2012.
 - [49] Qiyun Z, Dobre OA, Rajan S. "Cyclostationarity Approach for the Recognition of Cyclically Prefixed Single Carrier Signals in Cognitive Radio". *IEEE International Conference On Communications*, 1-6, Cape Town, South Africa, 23-27 May 2010.
 - [50] Zhang Q, Dobre OA, Rajan S, Inkol R. "Cyclostationarity approach to joint blind estimation of CP-SCLD block

- transmission parameters for cognitive radio". *IEEE Symposium on New Frontiers in Dynamic Spectrum*, 1-5, Singapore, 6-9 April 2010.
- [51] Bouzegzi A, Ciblat P, Jallon P. "New algorithms for blind recognition of OFDM based systems". *Signal Processing*, 90(3), 900-913, 2010.
- [52] Gardner WA, Spooner CM. "The cumulant theory of cyclostationary time series Part I: foundation: Part II: development and application". *IEEE Transaction on Signal Processing*, 42, 3387-3429, 1994.
- [53] Marey M, Dobre OA, Inkol R. "Cyclostationarity-based blind classification of STBCs for cognitive radio systems". *IEEE International Conference on Communications*, 1715-1720, 2012.
- [54] Eldemerdash YA, Dobre OA, Marey M, Inkol R. "Fourth-order moment-based identification of SM and Alamouti STBC for cognitive radio". *IEEE International Conference on Communications*, 1737-1741, 2012.
- [55] Marey M, Dobre OA, Inkol R. "Classification of space-time block codes based on second-order cyclostationarity with transmission impairments". *IEEE Transactions on Wireless Communications*, 11(7), 2574-2584, 2012.
- [56] Somekh O, Simeone O, Bar-Ness Y, Su W. "Detecting the number of transmit antennas with unauthorized or cognitive receivers in MIMO systems". *IEEE Military Communications Conference*, 1-5, Orlando, FL, USA, 29-31 October 2007.
- [57] Tarokh V, Jafarkhani H. "A differential detection scheme for transmit diversity". *IEEE journal on selected areas in communications*, 18(7), 1169-1174, 2000.
- [58] Oner M, Jondral F. "On the extraction of the channel allocation information in spectrum pooling systems". *IEEE Journal on Selected Areas in Communications*, 25(3), 2007.
- [59] Zhang Q, Dobre OA, Rajan S, Inkol R. "On the second-order cyclostationarity for joint signal detection and classification in cognitive radio systems". *Canadian Conference on Electrical and Computer Engineering*, 204-208, St. John's, NL, Canada, 3-6 May 2009.
- [60] Satija U, Ramkumar B, Manikandan MS. "A novel sparse classifier for automatic modulation classification using cyclostationary features". *Wireless Personal Communications*, 96(3), 4895-4917, 2017.
- [61] Satija U, Mohanty M, Ramkumar B. "Cyclostationary Features Based Modulation Classification in Presence of Non Gaussian Noise Using Sparse Signal Decomposition". *Wireless Personal Communications*, 96(4), 5723-5741, 2017.
- [62] Mobasser BG. "Digital modulation classification using constellation shape". *Signal processing*, 80(2), 251-277, 2000.
- [63] Hsue SZ, Soliman SS. "Automatic modulation classification using zero crossing". In *IEE Proceedings F (Radar and Signal Processing*, 137(6), 459-464, 1990.
- [64] Wang F, Wang X. "Fast and robust modulation classification via Kolmogorov-Smirnov test". *IEEE Transactions on Communications*, 58(8), 2324-2332, 2010.
- [65] Liu J, Luo Q. "A novel modulation classification algorithm based on daubechies5 wavelet and fractional fourier transform in cognitive radio". *IEEE 14th International Conference on Communication Technology*, 115-120, Chengdu, China, 9-11 November 2012.
- [66] Ghauri SA, Qureshi IM, Cheema TA, Malik AN. "A novel modulation classification approach using Gabor filter network". *The Scientific World Journal*, 2014.
- [67] Satija U, Mohanty M, Ramkumar B. "Automatic modulation classification using S-transform based features". *2nd International Conference on Signal Processing and Integrated Networks*, 708-712, Noida, India, 19-20 February 2015.