

**ÇOKLU ALICILAR KULLANARAK ÇEVİRİMİÇİ VE
ZAMAN UYUMSUZ DOĞRUSAL KİPLEME
SINIFLANDIRMASI**

**ONLINE AND ASYNCHRONOUS LINEAR
MODULATION CLASSIFICATION USING MULTIPLE
RECEIVERS**

EMRE EFENDİ

DOÇ. DR. BERKAN DÜLEK

Tez Danışmanı

Hacettepe Üniversitesi

Lisansüstü Eğitim-Öğretim ve Sınav Yönetmeliğinin

Elektrik ve Elektronik Mühendisliği Anabilim Dalı için Öngördüğü

YÜKSEK LİSANS TEZİ olarak hazırlanmıştır.

EMRE EFENDİ'nin hazırladığı “Çoklu Alıcılar Kullanarak Çevrimiçi ve Zaman Uyumsuz Doğrusal Kipleme Sınıflandırması” adlı bu çalışma aşağıdaki jüri tarafından ELEKTRİK VE ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI'nda YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

Doç. Dr. Tolga GİRİCİ

Başkan



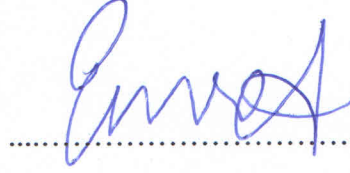
Doç. Dr. Berkan DÜLEK

Danışman



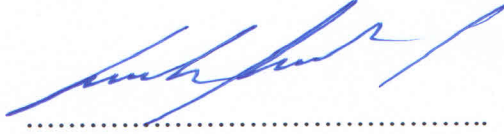
Prof. Dr. Emre AKTAŞ

Üye



Doç. Dr. Cenk TOKER

Üye



Dr. Öğr. Üyesi Mücahit K. ÜNER

Üye



Bu tez Hacettepe Üniversitesi Fen Bilimleri Enstitüsü tarafından YÜKSEK LİSANS TEZİ olarak / /..... tarihinde onaylanmıştır.

Prof. Dr. Menemşe GÜMÜŞDERELİOĞLU

Fen Bilimleri Enstitüsü Müdürü

ETİK

Hacettepe Üniversitesi Fen Bilimleri Enstitüsü, tez yazım kurallarına uygun olarak hazırladığım bu tez çalışmada,

- tez içindeki bütün bilgi ve belgeleri akademik kurallar çerçevesinde elde ettiğimi,
- görsel, işitsel ve yazılı tüm bilgi ve sonuçları bilimsel ahlak kurallarına uygun olarak sunduğumu,
- başkalarının eserlerinden yararlanılması durumunda ilgili eserlere bilimsel normlara uygun olarak atıfta bulunduğumu,
- atıfta bulunduğum eserlerin tümünü kaynak olarak gösterdiğimi,
- kullanılan verilerde herhangi bir değişiklik yapmadığımı,
- ve bu tezin herhangi bir bölümünü bu üniversite veya başka bir üniversitede başka bir tez çalışması olarak sunmadığımı

beyan ederim.

18 / 06 / 2019



EMRE EFENDİ

YAYINLANMA FİKRİ MÜLKİYET HAKLARI BEYANI


Enstitü tarafından onaylanan lisansüstü tezimin/raporumun tamamını veya herhangi bir kısmını, basılı (kağıt) ve elektronik formatta arşivleme ve aşağıda verilen koşullarla kullanıma açma iznini Hacettepe üniversitesine verdiğimi bildiririm. Bu izinle Üniversiteye verilen kullanım hakları dışındaki tüm fikri mülkiyet haklarım bende kalacak, tezimin tamamının ya da bir bölümünün gelecekteki çalışmalarda (makale, kitap, lisans ve patent vb.) kullanım hakları bana ait olacaktır.

Tezin kendi orijinal çalışmam olduğunu, başkalarının haklarını ihlal etmediğimi ve tezimin tek yetkili sahibi olduğumu beyan ve taahhüt ederim. Tezimde yer alan telif hakkı bulunan ve sahiplerinden yazılı izin alınarak kullanması zorunlu metinlerin yazılı izin alarak kullandığımı ve istenildiğinde suretlerini Üniversiteye teslim etmeyi taahhüt ederim.

Yükseköğretim Kurulu tarafından yayınlanan “*Lisansüstü Tezlerin Elektronik Ortamda Toplanması, Düzenlenmesi ve Erişime Açılmasına İlişkin Yönerge*” kapsamında tezim aşağıda belirtilen koşullar haricince YÖK Ulusal Tez Merkezi / H. Ü. Kütüphaneleri Açık Erişim Sisteminde erişime açılır.

- Enstitü / Fakülte yönetim kurulu kararı ile tezimin erişime açılması mezuniyet tarihimden itibaren 2 yıl ertelenmiştir.
- Enstitü / Fakülte yönetim kurulu gerekçeli kararı ile tezimin erişime açılması mezuniyet tarihimden itibaren ay ertelenmiştir.
- Tezim ile ilgili gizlilik kararı verilmiştir.

18 / 06 / 2019


(İmza)

EMRE EFENDİ

ÖZET

ÇOKLU ALICILAR KULLANARAK ÇEVİRİMİÇİ VE ZAMAN UYUMSUZ DOĞRUSAL KİPLEME SINIFLANDIRMASI

Emre EFENDİ

Yüksek Lisans, ELEKTRİK VE ELEKTRONİK MÜHENDİSLİĞİ Bölümü

Tez Danışmanı: Doç. Dr. Berkan DÜLEK

Haziran 2019, 82 Sayfa

Bu tez kapsamında, doğrusal kipleme türlerinin çoklu alıcılar kullanılarak sınıflandırılabilmesi için çevrimiçi ve zaman uyumsuz kipleme sınıflandırması yöntemleri geliştirilmiştir. Alıcı ve verici arasındaki zaman uyumsuzluğu, alıcıya ulaşan sinyalin örnekleme zamanına ait belirsizliği ifade eder ve bilinmeyen bir zaman kayması parametresi ile modellenenbilir. Zaman kaymasının yanı sıra, alıcı ve verici arasındaki kanal kazancını ve kanal fazını gösteren karmaşık kanal katsayısının da sınıflandırma öncesinde bilinmediği varsayılmıştır.

Önerilen kipleme sınıflandırması yöntemlerinde, ilk olarak bilinmeyen parametrelerin kestirilmesi ardından da sınıflandırma kararının verilmesi gerekmektedir. Bunun için olabilirlik tabanlı bir yaklaşım olan hibrit olabilirlik yaklaşımı kullanılmıştır. Hibrit olabilirlik yaklaşımında, ilk olarak alıcıdaki sinyalin olabilirlik fonksiyonunun, aday kipleme türlerinin her birinin yıldız kümesinde yer alan semboller üzerinden ortalaması alınır. Daha sonra ortalama olabilirlik fonksiyonunu enbüyüten parametre kestirimleri her aday kipleme türü için elde edilir. Son olarak, sınıflandırma kararı en yüksek olabilirlik skoruna sahip kipleme türü lehinde verilir.

Geliştirilen yöntemlerde bilinmeyen parametrelerin çevrimiçi kestirimini yapan bir yaklaşım benimsenmiştir. Bu yaklaşımda Titterington'ın çevrimiçi beklenti enbüyütme (Expectation Maximization, EM) algoritması kullanılmaktadır. Önerilen çevrimiçi yöntemlerde, bir sembole karşılık gelen dalgabiçimi alındıktan sonra zaman kaymasının mevcut kestirimi kullanılarak örneklenir. Elde edilen örneklerden gönderilen sembolün sonsal olasılık değerleri hesaplanır. Sonrasında ise elde edilen sonsal olasılık değerleri kullanılarak bilinmeyen parametrelerin güncellemeleri yapılır. Her yeni alınan sembol için bu işlem tekrarlanır. Önerilen yöntemle kipleme sınıflandırması kararı parametre kestirimleri ile paralel olarak gerçekleştirilebilir.

Önerilen çevrimiçi yöntemlerde parametre güncellemeleri sadece son örnek alınarak yapıldığı için alıcı ve verici arasındaki kanalın durumuna son derece duyarlıdır. Bu durumda çoklu alıcılar kullanılarak yaratılacak Sinyal Gürültü Oranı (Signal to Noise Ratio, SNR) çeşitliliği ile yöntemlerin başarılarının iyileştirilmesi sağlanmıştır. Çoklu alıcılar kullanılırken, alıcılardan bir tanesi elverişsiz kanal koşulları altında çalışırken bile diğer alıcılar tarafından gözlenen olumlu kanal koşulları sayesinde doğru kipleme sınıflandırması yapılabilir.

Önerilen çevrimiçi yöntemler, literatürde olabilirlik tabanlı zaman uyumsuz kipleme sınıflandırması yöntemlerinin olumsuz yönleri olan yüksek hafıza gereksinimi ve işlem karmaşıklığının azaltılmasını sağlamaktadır.

Çevrimiçi EM tabanlı yöntemlerin yanı sıra bilinmeyen parametre kestirimleri için Parçacık Sürü Optimizasyonu (Particle Swarm Optimization, PSO) algoritmasını kullanan hibrit olabilirlik tabanlı bir diğer kipleme sınıflandırması yöntemi de önerilmiştir.

Bu tez kapsamında önerilen zaman uyumsuz kipleme sınıflandırması yöntemlerinin farklı alıcı sayısı, SNR seviyesi ve bilinmeyen parametrelerin kestirimlerinin başlangıç değerlerine göre başarıları benzetim çalışmaları ile incelenmiştir. Önerilen yöntemlerin, orta ve yüksek SNR seviyelerinde, kanal parametrelerinin gerçek değerlerini bildiği varsayılarak sınıflandırma kararı veren kahin sınıflandırıcıya yakın başarı gösterdiği görülmüştür.

Anahtar Kelimeler: Kipleme Sınıflandırması, Beklenti Enbüyütme, Parçacık Sürü Optimizasyonu, Çevrimiçi, Zaman Uyumsuz

ABSTRACT

ONLINE AND ASYNCHRONOUS LINEAR MODULATION CLASSIFICATION USING MULTIPLE RECEIVERS

Emre EFENDİ

**Master of Science, Department of ELECTRICAL AND ELECTRONICS
ENGINEERING**

Supervisor: Assoc. Prof. Dr. Berkan DÜLEK

June 2019, 82 Pages

In this thesis, online and asynchronous modulation classification algorithms for multiple receivers are developed for recognition of linear modulation formats. The term asynchronous refers to the lack of timing synchronization between receiver and transmitter and can be modelled by a time offset. Besides the unknown time offset, complex channel coefficient which embodies the channel gain and channel phase between transmitter and receivers is also assumed unknown.

In the proposed modulation classification techniques, first above mentioned unknown parameters are required to be estimated and then classification decision is made by using estimates of the unknown parameters. To that end, hybrid likelihood based approach is adopted. In the hybrid likelihood based approach, likelihood function (LF) of the received signal is averaged separately over the distributions of the constellation points of every candidate modulation formats. Then, averaged LFs are maximized w.r.t. unknown parameters for each

candidate modulation format. The classification decision is made in favor of the modulation format with highest likelihood function score.

An online parameter estimation approach is adopted in the designed modulation classification techniques. In this approach, Titterington's online Expectation Maximization (EM) algorithm based parameter estimation is considered. In the proposed parameter estimation techniques, first the received signal is sampled with the current estimate of the time offset. Then, *a posteriori* probabilities are computed by using the obtained sample. Next, estimates of the unknown parameters are updated by using computed *a posteriori* probabilities. This procedure continues as the new waveforms are collected. After enough samples are collected the classification decision is made in favor of the modulation format with highest likelihood score.

The proposed parameter estimation approach is highly susceptible to the channel state due to its online processing. By using only last sample for the parameter update results in highly irregular parameter estimation in the channels with high noise content. To avoid this, a multiple receiver approach is adopted to benefit from the Signal to Noise Ratio (SNR) diversity due to independent channels between the transmitter and receivers. In a multiple receiver network, even if the channel conditions of the one of the receivers are sub optimal, correct classification decisions can be made due to the other receivers which experience more favorable channel conditions.

In the literature, asynchronous modulation classification algorithms are based on the batch processing of the waveform which increase the memory requirements and computational complexity of the algorithms. The proposed modulation classification algorithms by adopting an online parameter approach, reduce computational complexity and the memory requirements of the proposed algorithms significantly.

In this thesis, besides the proposed EM algorithm based methods, another asynchronous modulation classification technique which utilizes Particle Swarm Optimization (PSO) algorithm for the parameter estimation is proposed.

Performance evaluations of the proposed modulation classification techniques are done by the help of simulations for different average received SNRs, number of receivers and initial distances of the estimates of the unknown parameters to their true values. It is observed that,

proposed algorithms attain comparable performances with the clairvoyant classifier which has the perfect information of the unknown parameters in the mid to high SNR region.

Keywords: Modulation Classification, Expectation Maximization, Particle Swarm Optimization, Online, Asynchronous

TEŞEKKÜR

Bu tez çalışmasının gerçekleşmesinde bilgisi, deneyimi ve sabrıyla bana destek olan danışmanım Doç. Dr. Berkan DÜLEK'e

Yorum ve önerileri ile tezin içeriğinin geliştirilmesine yardımcı olan jüri üyelerine

Hayatımın her aşamasında olduğu gibi tezin hazırlanış sürecinde de maddi ve manevi desteklerini esirgemeyen anneme, babama ve kardeşime

Bu süreçte her zaman yanımda olan ve her türlü kahrımı çeken sevgilim Hannan'a

teşekkürü bir borç bilirim.

İÇİNDEKİLER

ÖZET	i
ABSTRACT	iii
TEŞEKKÜR	vi
İÇİNDEKİLER	viii
ŞEKİLLER	x
ÇİZELGELER	xi
KISALTMALAR	xii
SÖZLÜK	xiii
1. GİRİŞ	1
2. KİPLEME SINIFLANDIRMASI	5
2.1. Kipleme Sınıflandırması için Sistem Modeli	5
2.2. Kipleme Sınıflandırması Yöntemleri	5
2.2.1. Öznitelik Tabanlı Kipleme Sınıflandırması	6
2.2.2. Olabilirlik Tabanlı Kipleme Sınıflandırması	7
2.3. Beklenti Enbüyütme (EM) Algoritması Tabanlı Kipleme Sınıflandırması	9
2.3.1. EM Algoritması	9
2.3.2. Literatürdeki EM Algoritması Tabanlı Kipleme Sınıflandırması Yöntemleri	15
2.4. Zaman Uyumsuz Kipleme Sınıflandırması	19
3. ÇOKLU ALICILAR KULLANARAK ZAMAN UYUMSUZ KİPLEME SINIFLANDIRMASI	23
3.1. Problem Tanımı	23
3.2. Bilinmeyen Parametrelerin Toplu EM Algoritması ile Kestirimine Dayalı Sınıflandırıcı	27

3.3. Bilinmeyen Parametrelerin Çevrimiçi EM Algoritması ile Kestirimine Dayalı Sınıflandırıcı	29
3.4. Dağıtılmış Parametre Kestirimi ve Kipleme Sınıflandırması	33
3.4.1. Dağıtılmış ve Toplu EM Algoritması ile Parametre Kestirimine Dayalı Kipleme Sınıflandırıcı	35
3.4.2. Dağıtılmış ve Çevrimiçi EM Algoritması ile Parametre Kestirimine Dayalı Kipleme Sınıflandırıcı	37
3.5. Parçacık Sürü Optimizasyonu (PSO) ile Toplu Veriden Parametre Kestirimine Dayalı Hibrit Olabilirlik Tabanlı Sınıflandırıcı	39
4. NÜMERİK ÖRNEKLER	43
4.1. Çevrimiçi EM Algoritması Tabanlı Kipleme Sınıflandırma Yöntemlerinin Başarım Sonuçları	44
4.1.1. Çevrimiçi EM Algoritması Tabanlı Kipleme Sınıflandırması Yöntemlerinde Adım Boyu Seçimi	45
4.1.2. Çevrimiçi EM Algoritması Tabanlı Kipleme Sınıflandırması Yöntemlerinde Alıcı Sayısının Etkisi	49
4.1.3. Sonsal Olasılıklar Kullanılarak Gönderilen Sembollerin Elde Edilmesi	64
4.1.4. Bilinmeyen Darbe Biçiminin Kipleme Sınıflandırması Başarımı Üzerindeki Etkisi	65
4.1.5. Bilinmeyen Parametrelerin Başlangıç Kestirimlerinin Çevrimiçi Yöntemlerin Başarımı Üzerindeki Etkisi	66
4.2. PSO ile Toplu Veriden Parametre Kestirimine Dayalı Olabilirlik Tabanlı Sınıflandırıcının Başarım Sonuçları	70
5. SONUÇ	72
EKLER	80
EK 1 - Tezden Türetilmiş Yayınlar	80
EK 2 - ORJİNALLİK RAPORU	81
ÖZGEÇMİŞ	82

ŞEKİLLER

Şekil 3.1. Doğrusal kipleme türleri için zaman kaymasının çevrimiçi EM algoritması tabanlı en büyük olabilirlik kestiriminin yapılması.	31
Şekil 4.1. Çevrimiçi sınıflandırıcıların farklı adım boylarına göre başarımlar eğrileri. Aday kipleme türleri: 16-QAM, 32-QAM, 64-QAM	47
Şekil 4.2. Çevrimiçi sınıflandırıcıların farklı adım boylarına göre başarımlar eğrileri. Aday kipleme türleri: 8-PSK, 16-PSK, 8-QAM, 16-QAM	48
Şekil 4.3. Merkezi ve çevrimiçi kipleme sınıflandırmasında bilinmeyen parametrelerin kestirimlerindeki hatanın gönderilen sembollerin sayısına göre değişimi.	50
Şekil 4.4. İncelenen kipleme sınıflandırıcıların farklı alıcı sayıları için başarımlar eğrileri. Aday kipleme türleri: 16-QAM, 32-QAM ve 64-QAM.	51
Şekil 4.5. Çevrimiçi kipleme sınıflandırması yöntemlerinin farklı alıcı sayıları için başarımlar eğrileri. Aday kipleme türleri: 16-QAM, 32-QAM, 64-QAM.	53
Şekil 4.6. İncelenen sınıflandırıcıların 16-QAM, 32-QAM ve 64-QAM için koşullu başarımlar eğrileri.	55
Şekil 4.7. İncelenen kipleme sınıflandırıcıların farklı alıcı sayıları için başarımlar eğrileri. Aday kipleme türleri: 8-PSK, 16PSK, 8-QAM, 16-QAM.	58
Şekil 4.8. Çevrimiçi kipleme sınıflandırması yöntemlerinin farklı alıcı sayıları için başarımlar eğrileri. Aday kipleme türleri: 8-PSK, 16-PSK, 8-QAM, 16-QAM.	60
Şekil 4.9. İncelenen sınıflandırıcıların 8-PSK, 16-PSK, 8-QAM ve 16-QAM için koşullu başarımlar eğrileri.	62
Şekil 4.10. Merkezi ve çevrimiçi kipleme sınıflandırması yönteminde sonsal olasılıklar kullanılarak elde edilen sembol hata oranı farklı alıcı sayısı $K \in \{1, 3, 5, 9\}$ için verilmiştir.	65
Şekil 4.11. Çevrimiçi kipleme sınıflandırma yöntemlerinin farklı etek faktörleri için başarımlar eğrileri.	66
Şekil 4.12. Çevrimiçi kipleme sınıflandırması yöntemlerinin bilinmeyen parametrelerin başlangıç kestirimlerinin gerçek değerlere uzaklıklarına göre başarımlar eğrileri. Aday kipleme türleri: 16-QAM, 32-QAM, 64-QAM.	68
Şekil 4.13. Çevrimiçi kipleme sınıflandırması yöntemlerinin bilinmeyen parametrelerin başlangıç kestirimlerinin gerçek değerlere uzaklıklarına göre başarımlar eğrileri. Aday kipleme türleri: 8-PSK, 16-PSK, 8-QAM, 16-QAM.	69

Şekil 4.14. PSO tabanlı kipleme sınıflandırması yönteminin a) farklı alıcı sayıları için ve b) bilinmeyen parametrelerin başlangıç kestirimlerinin gerçek değerlerine olan uzaklıkları için başarımlar eğrileri. 71

ÇİZELGELER

Çizelge 4.1. Çevrimiçi ve merkezi kiplleme sınıflandırması yönteminin belirli bir doğru sınıflandırma olasılığına erişebilmesi için gereken SNR değerleri. Aday kiplleme türleri: 16-QAM, 32-QAM, 64-QAM.	53
Çizelge 4.2. Çevrimiçi ve dağıtılmış kiplleme sınıflandırması yönteminin belirli bir doğru sınıflandırma olasılığına erişebilmesi için gereken SNR değerleri. Aday kiplleme türleri: 16-QAM, 32-QAM, 64-QAM.	54
Çizelge 4.3. Çevrimiçi ve merkezi kiplleme sınıflandırması yöntemi için karıştırma matrisi. Ortalama alınan SNR 0 dB. Alıcı sayısı: $K = 5$	56
Çizelge 4.4. Çevrimiçi ve merkezi kiplleme sınıflandırması yöntemi için karıştırma matrisi. Ortalama alınan SNR 4 dB. Alıcı sayısı: $K = 5$	56
Çizelge 4.5. Çevrimiçi ve dağıtılmış kiplleme sınıflandırması yöntemi için karıştırma matrisi. Ortalama alınan SNR 0 dB. Alıcı sayısı: $K = 5$	57
Çizelge 4.6. Çevrimiçi ve dağıtılmış kiplleme sınıflandırması yöntemi için karıştırma matrisi. Ortalama alınan SNR 4 dB. Alıcı sayısı: $K = 5$	57
Çizelge 4.7. Çevrimiçi ve merkezi kiplleme sınıflandırması yönteminin belirli bir doğru sınıflandırma olasılığına erişebilmesi için gereken SNR değerleri. Aday kiplleme türleri: 8-PSK, 16-PSK, 8-QAM, 16-QAM.	59
Çizelge 4.8. Çevrimiçi ve dağıtılmış kiplleme sınıflandırması yönteminin belirli bir doğru sınıflandırma olasılığına erişebilmesi için gereken SNR değerleri. Aday kiplleme türleri: 8-PSK, 16-PSK, 8-QAM, 16-QAM.	60
Çizelge 4.9. Çevrimiçi ve merkezi kiplleme sınıflandırması yöntemi için karıştırma matrisi. Ortalama alınan SNR -4 dB. Alıcı sayısı: $K = 5$	63
Çizelge 4.10. Çevrimiçi ve merkezi kiplleme sınıflandırması yöntemi için karıştırma matrisi. Ortalama alınan SNR 0 dB. Alıcı sayısı: $K = 5$	63
Çizelge 4.11. Çevrimiçi ve dağıtılmış kiplleme sınıflandırması yöntemi için karıştırma matrisi. Ortalama alınan SNR -4 dB. Alıcı sayısı: $K = 5$	63
Çizelge 4.12. Çevrimiçi ve dağıtılmış kiplleme sınıflandırması yöntemi için karıştırma matrisi. Ortalama alınan SNR 0 dB. Alıcı sayısı: $K = 5$	64

KISALTMALAR

AWGN	: Additive White Gaussian Noise
AL	: Average Likelihood
CM	: Conditional Maximization
CR	: Cognitive Radio
ECM	: Expectation Conditional Maximization
EM	: Expectation Maximization
GEM	: Generalized Expectation Maximization
GL	: Generalized Likelihood
HL	: Hybrid Likelihood
LF	: Likelihood Function
MAPSK	: M-ary Amplitude and Phase Shift Keying
MIMO	: Multiple Input Multiple Output
MPSK	: M-ary Phase Shift Keying
MQAM	: M-ary Quadrature Amplitude Modulation
PDF	: Probability Density Function
PSO	: Particle Swarm Optimization
SNR	: Signal to Noise Ratio
SIMO	: Single Input Multiple Output
STR	: Square Timing Recovery
VCC	: Voltage Controlled Clock

SÖZLÜK

Ayrık	: Discrete
Beklenen Değer	: Expectation
Beklenti Enbüyütme	: Expectation Maximization
Beklenti Koşullu Enbüyütme	: Expectation Conditional Maximization
Bileşik Olasılık Yoğunluk Fonksiyonu	: Joint Probability Density Function
Bilişsel Radyo	: Cognitive Radio
Çok Girdili Çok Çıktılı	: Multiple Input Multiple Output
Dağıtılmış Karar Tümeleştirme	: Distributed Decision Fusion
Dağıtılmış Karar Tümeleştirme	: Distributed Decision Fusion
Dalgacık Dönüşümü	: Wavelet Transform
Destek Vektör Makineleri	: Support Vector Machines
Dördün Genlik Kipleme	: Quadrature Amplitude Modulation
En büyük olabilirlik	: Maximum Likelihood
En büyük olabilirlik Kestirimi	: Maximum Likelihood Estimate
Enbüyütme	: Maximization
Faz Kaydırmalı Kipleme	: Phase Shift Keying
Genlik ve Faz Kaydırmalı Kipleme	: Amplitude and Phase Shift Keying
Genelleştirilmiş Beklenti Enbüyütme	: Generalized Expectation Maximization
Genelleştirilmiş Olabilirlik	: Generalized Likelihood
Gözlenen	: Observed

Hibrit Olabilirlik	: Hybrid Likelihood
Kanal Durum Bilgisi	: Channel State Information
Karar Ağacı	: Decision Tree
Karar Tümlleştirme	: Decision Fusion
Kare Zamanlama Referansı Kazanımı	: Square Timing Recovery
Karekök Yükseltilmiş Kosinüs	: Root Raised Cosine
Koşullu Enbüyütme	: Conditional Maximization
Logaritmik Moment	: Cumulant
Marjinal Olasılık Yoğunluk Fonksiyonu	: Marginal Probability Density Function
Merkezi Karar Tümlleştirme	: Centralized Decision Fusion
Merkez Düğüm	: Center Node
Olabilirlik	: Likelihood
Olabilirlik Fonksiyonu	: Likelihood Function
Olabilirlik Tabanlı	: Likelihood Based
Ortalama Olabilirlik	: Average Likelihood
Örtük	: Latent
Öznelik Tabanlı	: Feature Based
Parçacık Sürü Optimizasyonu	: Particle Swarm Optimization
Sinir Ağları	: Neural Networks
Sinyal Gürültü Oranı	: Signal to Noise Ratio
Tek Girdili Çok Çıktılı	: Single Input Multiple Output
Zaman Kayması	: Time Offset

1. GİRİŞ

Kipleme sınıflandırması, haberleşme sinyalinin oluşturulmasında kullanılan kipleme türünün sinyal ve kanala ait parametre belirsizlikleri altında belirlenmesi problemidir [1, 2]. Kipleme sınıflandırması yöntemleri askeri ve sivil alandaki uygulamaları nedeniyle literatürde detaylı çalışılmış bir konudur. Kipleme sınıflandırmasının askeri alandaki kullanımına örnek olarak, yabancı bir sinyalin tespit edildikten sonra çözülebilmesi, engellenebilmesi veya kipleme türüne uygun sinyal bozma yöntemlerinin belirlenmesi verilebilir. Bunun yanında, dinamik olarak değişen kanal koşullarına göre kipleme türlerinin uyarlamalı olarak değiştirildiği bilişsel radyo (cognitive radio, CR) uygulamaları gibi sivil haberleşme konularında da önem arz etmektedir [1].

Literatürdeki kipleme sınıflandırması çalışmalarının çoğunluğunda alıcı ve verici arasında sembol zamanlama referansının bulunduğu varsayılmaktadır. Alınan sinyale ve kanala ait bilginin oldukça kısıtlı olacağı askeri kipleme sınıflandırması gibi uygulamalar için bu varsayım çoğu zaman geçerli değildir. Bu uygulamalarda, sembol zamanlama bilgisinin pilot sembol dizisi olmadan elde edilmesi gerekmektedir. Buna benzer elverişsiz koşullarda çalışabilen zaman uyumsuz kipleme sınıflandırması yöntemleri literatürde bulunmaktadır. Bu çalışmalarda zaman uyumsuzluğu, bilinmeyen bir zaman kayması parametresi ile modellenmiştir ve bu parametrenin kestirimi sınıflandırma kararı öncesinde yapılmıştır. Bu yöntemlerde parametre kestirimleri toplu veriden yapılmaktadır. Toplu veriden parametre kestirimine dayalı kipleme sınıflandırması yöntemlerinde belli sorunlar ortaya çıkmaktadır. İlk olarak zaman kayması kestiriminin elde edilebilmesi için alıcılara ulaşan dalgabiçiminin sık olarak örneklenerek hafızaya alınması ve kestirim işlemlerinin sonrasında devam etmesi gerekmektedir. Ek olarak parametre kestirimlerinin toplu veriden yapılması kipleme sınıflandırması yöntemlerinin işlem yükünü artırmaktadır. Ayrıca toplu veriden parametre kestirimleri yapılabilmesi için bütün verinin alıcıda toplanmış ve hafızaya alınmış olması gerekmektedir. Bu durum, kipleme sınıflandırması uygulamalarından gerçek zamanda kullanılmasını gerektiren uygulamalarda faydalanılamamasına sebep olmaktadır.

Bu tezde hafıza gereksinimi ve işlem yükü sorunlarının etkilerinin azaltılabilmesi için çevrimiçi parametre kestirimine dayalı hibrit olabilirlik (Hybrid Likelihood) tabanlı zaman uyumsuz kipleme sınıflandırması yöntemleri geliştirilmiştir. Zaman uyumsuzluğu bilinmeyen ka-

nal katsayısı parametresi ile modellenmiştir. Ek olarak alıcı ve verici arasındaki kanalın kazancını ve fazını modelleyen karmaşık kanal katsayısı parametresinin de bilinmediği varsayılmıştır. Hibrit olabilirlik tabanlı kipleme sınıflandırması yöntemlerinde alınan sinyalin olabilirlik fonksiyonunun ortalaması aday kipleme türülerinin her biri için yıldız kümesi diyagramlarını oluşturan sembollerin dağılımı üzerinden ayrı olarak alınır. Ardından ortalaması alınan olabilirlik fonksiyonu bilinmeyen parametrelere göre enbüyütülür ve sınıflandırma kararı en yüksek olabilirlik skoruna sahip kipleme türü lehinde verilir. Parametre kestirimlerinde Titterington'ın çevrimiçi Beklenti-Enbüyütme (Expectation - Maximization, EM) algoritması kullanılmıştır. Bu yöntemde, bir sembole karşılık gelen dalgabiçiminin alıcıya ulaşmasının ardından zaman kayması parametresinin mevcut kestirimi ile örneklenir. Daha sonra alınan örnekler kullanılarak gönderilen sembolün sonsal olasılıkları hesaplanır ve hesaplanan sonsal olasılıklar kullanılarak bilinmeyen parametrelerin kestirimleri güncellenir. Çevrimiçi yöntemler, alıcıya ulaşan yeni sembole karşılık gelen dalgabiçiminin güncel zaman kayması kestirimi ile örneklenmesi ile devam eder. Önerilen yöntemlerde alıcıya ulaşan dalgabiçimi her sembol için bir kez örneklenerek hafızaya alınır ve bu haliyle işlenir. Bu durum sık olarak örneklenmiş dalgabiçiminin hafızaya alınmasını gerektiren yöntemlere kıyasla hafıza gereksinimlerini azaltmaktadır. Ek olarak, parametre kestirimlerinde de sadece bir örneğin kullanılması tüm verinin kullanıldığı yöntemlerine kıyasla işlem yükünü hafifletmektedir. Çevrimiçi sınıflandırıcılarda parametre kestirimlerinin sadece son alınan örnek ile gerçekleştirilmesi sayesinde sınıflandırma kararı, parametre kestirimi ve veri örnekleme işlerine paralel olarak verilebilir.

Önerilen çevrimiçi kipleme sınıflandırması yöntemlerinde bilinmeyen parametrelerin kestirimlerinin çevrimiçi olarak yapılması Sinyal Gürültü Oranı'na (Signal to Noise Ratio, SNR) bağımlılığı artırmaktadır. Sadece son alınan örnek kullanılarak bilinmeyen parametrelerin kestirimlerinin yapılması yüksek gürültü altında kestirilen parametrelerin gerçek değerlerine yakınmasını zorlaştırmaktadır. Bu da optimal olmayan parametre kestirimlerine ve bunun doğrudan sonucu olarak vasat başarımlar seviyelerine neden olmaktadır. Bu sorunları aşmak için çoklu alıcılar kullanılmıştır. Vericiden gönderilen sinyalin bağımsız kanallardan çoklu alıcılara iletilmesi sayesinde SNR çeşitliliği oluşturulmuş ve başarımlar iyileşmeleri elde edilmiştir. Çoklu alıcılardan alınan verilerin tümleştirilmesine göre çevrimiçi yöntemler ikiye ayrılır. Bu yöntemlerden birincisi merkezi karar tümleştirme tabanlıdır. Merkezi ve çevrimiçi kipleme sınıflandırma yönteminde alıcılarda alınan örnekler merkez düğüm'e (Center Node)

iletilir ve merkez düğümde bütün alıcılardan alınan örnekler kullanılarak gönderilen sembolün sonsal olasılıkları hesaplanır. Ardından hesaplanan sonsal olasılıklar kullanılarak parametre kestirimleri güncellenir. Bu sayede düşük SNR altında çalışan alıcıların bilinmeyen parametre kestirimlerinin iyileştirilmesi sağlanır. İkinci yöntemde ise işlem yükünün daha da hafifletilebilmesi için dağıtılmış karar tümleştirme tabanlı bir yaklaşım benimsenmiştir. Dağıtılmış ve çevrimiçi sınıflandırıcıda, her alıcı için parametre kestirimleri ve sınıflandırma kararı kendi elde ettiği örnekler kullanılarak gerçekleştirilir. İlk olarak her alıcıda gönderilen sembolün sonsal olasılıkları yerel örnekler kullanılarak hesaplanır. Ardından parametre güncellemeleri bu sonsal olasılıklar kullanılarak yapılır. Parametre kestirimlerinin ardından her alıcı için yerel sınıflandırma kararı elde edilen parametre kestirimleri ve örnekler kullanılarak verilir. Sonrasında alıcıların yerel sınıflandırma kararları merkez düğüme iletilir ve merkez düğümde son sınıflandırma kararı en fazla alıcı tarafından yerel sınıflandırma kararı olarak iletilen kipleme türü lehinde verilir. Dağıtılmış sınıflandırıcıda SNR çeşitliliğinden merkezi sınıflandırıcıya kıyasla daha az faydalanılabilmektedir. Fakat merkezi ve çevrimiçi sınıflandırıcının işlem yükü dağıtılmış karar tümleştirme ile daha da azaltılabilmektedir. Buna ek olarak merkez düğümde odaklanan işlem yükünün alıcılar arasında dağıtılabilmesi de sağlanmıştır.

Çevrimiçi kipleme sınıflandırıcıların yanı sıra, verileri toplu şekilde işleyen hibrit olabilirlik tabanlı bir kipleme sınıflandırması yöntemi daha geliştirilmiştir. Bilinmeyen kanal katsayısı ve zaman kayması parametrelerinin kestiriminin toplu veriden yapılmasında Parçacık Sürü Optimizasyonu (Particle Swarm Optimization, PSO) yöntemi kullanılmıştır.

Önerilen kipleme sınıflandırması yöntemlerinin başarımları çeşitli ortalama alınan SNR seviyeleri, alıcı sayıları, bilinmeyen parametrelerin kestirimlerine atanan başlangıç değerlerinin gerçek değerlere uzaklıkları ve bilinmeyen darbe biçimleri için incelenmiştir. Çevrimiçi yöntemlerin, bilinmeyen parametrelerin kestirimlerinin gerçek değerlere yakın olduğu durumlarda orta ve yüksek SNR seviyelerinde optimuma yakın başarımlar elde ettikleri gözlenmiştir. Bunlara ek olarak önerilen çevrimiçi sınıflandırıcıların başarımlarında bilinmeyen darbe biçimlerinin kullanıldığı benzetimlerde belirgin bir düşüş gözlenmemiştir. Merkezi karar tümleştirme tabanlı çevrimiçi sınıflandırıcı kullanılarak yüksek SNR seviyelerinde verici tarafından gönderilen sembol dizisinin de sonsal olasılıklar kullanılarak elde edilebildiği gözlenmiştir. PSO tabanlı sınıflandırıcı kullanılarak gerçekleştirilen benzetimlerde önerilen yöntemin optimuma yakın sonuçlar elde ettiği gözlenmiştir.

Bu tezin akışı şu şekildedir: 2. bölümde kipleme sınıflandırması ile ilgili literatür özeti verilmiştir. İlk olarak kipleme sınıflandırması için sistem modeli anlatılmıştır. Ardından kipleme sınıflandırması yöntemleri özetlenmiştir. Sonrasında EM algoritması anlatılmıştır ve EM algoritması tabanlı kipleme sınıflandırması çalışmalarının özetleri verilmiştir. Son olarak literatürde zaman uyumsuz kipleme sınıflandırması üzerine yapılan çalışmalar anlatılmıştır. 3. bölümde literatürde zaman uyumsuz kipleme sınıflandırması yöntemleri anlatılmıştır. Bu bölümde ilk olarak zaman uyumsuz kipleme sınıflandırmasına özel sistem modeli verilmiştir. Ardından, literatürdeki toplu EM algoritmasına dayanan zaman uyumsuz kipleme sınıflandırması yöntemleri ve önerilen çevrimiçi kipleme sınıflandırması yöntemleri anlatılmıştır. Son olarak, PSO algoritması tabanlı zaman uyumsuz kipleme sınıflandırılması yöntemi anlatılmıştır. 4. bölümde önerilen yöntemlerin başarımı farklı SNR seviyeleri, alıcı sayıları, bilinmeyen parametrelerin başlangıç kestirimlerinin gerçek değerlerine uzaklıkları ve bilinmeyen darbe biçimi için incelemiştir. 5. bölümde benzetim çalışmaları ile elde edilen sonuçlar yorumlanmıştır.

2. KİPLEME SINIFLANDIRMASI

Bu bölümde, kipleme sınıflandırması yöntemleri ve bu yöntemlerin literatürdeki uygulamaları anlatılmaktadır. İlk olarak, kipleme sınıflandırması yöntemleri için sistem modeli verilmiştir. Sonrasında, kipleme sınıflandırmasında kullanılan yöntemler anlatılmıştır. Ardından, EM algoritması anlatılmış ve sonrasında ise literatürde bulunan EM algoritması tabanlı kipleme sınıflandırması yöntemleri özetlenmiştir. Bu bölümde son olarak zaman uyumsuz kipleme sınıflandırması üzerine literatürde yapılan çalışmalar anlatılmıştır.

2.1. Kipleme Sınıflandırması için Sistem Modeli

Kipleme sınıflandırması uygulamalarında karşılaşılan en önemli zorluk, sınıflandırıcıların sinyal veya kanal ile ilgili yeterli bilginin bulunmamasından kaynaklanmaktadır. Alıcıya ulaşan dalgabiçiminin sinyal ve kanal parametrelerine bağlı temelbant sinyal modeli aşağıda gösterilmiştir:

$$y(t) = h e^{j2\pi\Delta f t} \sum_{n=1}^N e^{j\phi_n} I_n g(t - nT - \tau) + \eta(t), \quad 0 \leq t \leq T_0 \quad (2.1)$$

burada, h karmaşık kanal katsayısı, Δf frekans kaymasını, $\{\phi_n\}_{n=1}^N$ zamana bağlı faz kaymasını, τ bilinmeyen zaman kaymasını, T_0 toplam haberleşme süresini, T bir sembol süresini, $N = T_0/T$ gönderilen sembol sayısını $\{I_n\}_{n=1}^N$ verici tarafından gönderilmiş sembol dizisini, $g(\cdot)$ kullanılan darbebiçimini ve $\eta(t)$ iki taraflı izgel güç yoğunluğu $N_0/2$ W/Hz küresel olarak simetrik, karmaşık Eklenir Gaussian Beyaz Gürültüyü (Additive White Gaussian Noise) göstermektedir. Kipleme sınıflandırma yöntemlerinde, sınıflandırma başarımını etkileyen sinyale ve kanala ait parametreler $\{h, \tau, \Delta f, T, \{\phi_n\}_{n=1}^N, \{I_n\}_{n=1}^N, N_0, g(\cdot)\}$ ile gösterilir. Literatürde, yukarıda bahsedilen kanal ve sinyal parametrelerinin bir kısmının bilinmediği durumlar için kipleme sınıflandırması yöntemleri önerilmiştir [3–15]. Bu yöntemlerde ağırlıklı olarak bilinmeyen parametrelerin sınıflandırma öncesi kestiriminin yapılması gerekmektedir [4–12, 14, 15]. Bazı yöntemlerde ise elde edilen temelbant sinyalinin işlenmesi sonucu kipleme sınıflandırması parametre kestirimi yapılmaksızın yapılmıştır [3, 13].

2.2. Kipleme Sınıflandırması Yöntemleri

Literatürdeki kipleme sınıflandırması üzerine yapılan çalışmalarda kullanılan teknikler temelde iki ana gruba ayrılmaktadır: Öznitelik tabanlı (Feature Based, FB) ve Olabilirlik Tabanlı (Likelihood Based - LB) yöntemler. Bu yöntemler birbirinden karar verme yapıları

ile ayrılır. Öznitelik tabanlı yöntemlerde, alınan sinyale ait ayırt edici özellikler belirlenir ve bu özniteliklerin değerleri aday kipleme türleri için değerleri hesaplanır. Sınıflandırma yöntemlerinde ilk olarak, alınan sinyalin öznitelik değerleri hesaplanır ve sonrasında bu değerler aday kipleme türlerinden çıkarılan değerler ile karşılaştırılarak sınıflandırma yapılır. Olabilirlik tabanlı yöntemlerde ise sınıflandırma kararı alıcıdaki sinyalin istatistiksel modeli verilir. Alınan sinyalin olabilirlik skoru her bir aday kipleme türünün vericide kullanıldığı kabul edilerek ayrı ayrı hesaplanır. Olabilirlik fonksiyonunu enbüyüten aday kipleme türü lehinde sınıflandırma kararı verilir [1,2]. Bu bölümün devamında, öznitelik tabanlı ve olabilirlik tabanlı yöntemler genel hatları ile anlatılacaktır.

2.2.1 Öznitelik Tabanlı Kipleme Sınıflandırması

Öznitelik tabanlı kipleme sınıflandırması yöntemlerinde, sinyalin oluşturulmasında kullanılan kipleme türü sinyalin belli özelliklerinde ayırt edici etkilerinin saptanması ile tespit edilir. Öznitelik tabanlı yöntemler iki aşamadan oluşmaktadır. Bunlar öznitelik çıkarma ve karar verme adımlarıdır. Öznitelik çıkarma adımında sınıflandırıcının tasarımında belirlenen sinyal öznitelikleri alınan sinyal için hesaplanır. Literatürde kipleme sınıflandırma yöntemlerinde sıklıkla kullanılan özniteliklere örnek olarak, farklı derecelerden logaritmik momentler (Cumulants) [3], alınan sinyalin Fourier Dönüşümü (Fourier Transform) [16], fazın olasılık yoğunluk fonksiyonunun (Probability Density Function, PDF) Fourier Dönüşümü (Fourier Transform) [17] alınan sinyalin dalgacık dönüşümünün (Wavelet Transform) varyansı [18,19] sayılabilir. Belirlenen özniteliklerin alıcıya ulaşan sinyal için hesaplanmasının ardından sınıflandırma adımında bir kipleme türü lehinde karar verilir. Sınıflandırma adımında kullanılan yöntemlere örnek olarak sinir ağları (Neural Networks) [20], karar ağacı (Decision Tree) yapıları [21] ve destek vektör makineleri (Support Vector Machine) [22] verilebilir.

Öznitelik tabanlı kipleme sınıflandırması yöntemleri, uygulaması kolay ve işlem karmaşıklığı düşük yöntemlerdir. Yanlış sınıflandırma oranını enküçültmeyen yöntemler olmadıklarından optimal değillerdir fakat sınıflandırma türleri için doğru şekilde tasarlandıklarında optimale yakın sonuçlar elde edilebilmektedir. Karşı taraftan, öznitelik tabanlı yöntemlerde sınıflandırılmak istenen kipleme türlerinin, sınıflandırıcının tasarımında belirlenmesi gerekmektedir. Belirlenen kipleme türlerine uygun öznitelikler seçilmeli ve aday kipleme türlerinin öznitelik değerlerinin teorik hesaplamalar ile veya eğitim verisi ile belirlenmesi gerek-

mektedir. Bu durum sınıflandırıcının ayırt edebileceği kipleme türlerini sınırlandırmasının yanında bu yöntemlerin uygulanabilirliğini azaltmaktadır [2].

2.2.2 Olabilirlik Tabanlı Kipleme Sınıflandırması

Olabilirlik tabanlı kipleme sınıflandırma yöntemlerinde, alınan sinyalin olabilirlik fonksiyonuna göre sınıflandırma yapılır. Bu yöntemlerde yanlış sınıflandırma olasılığı enküçültüldüğü için istatistiksel olarak optimal sonuçlar elde edilmektedir [11]. Fakat, optimal sonuçların elde edilebilmesi beraberinde yüksek işlem yükünü getirmektedir. Bilinmeyen parametre sayısı arttıkça daha da yükselen işlem yükü olabilirlik tabanlı yöntemlerde optimal altı sonuçlar elde etmesine neden olmaktadır [2].

Literatürde olabilirlik tabanlı kipleme sınıflandırma yöntemleri kendi içinde üç gruba ayrılır. Bunlar ortalama olabilirlik (Average Likelihood, AL), genelleştirilmiş olabilirlik (Generalized Likelihood, GL) ve hibrit olabilirlik (Hybrid Likelihood, HL) olarak adlandırılır. Ortalama olabilirlik, genelleştirilmiş olabilirlik ve hibrit olabilirlik yaklaşımları arasındaki fark bilinmeyen parametrelerin nasıl varsayıldığıdır [2, 11, 23–25].

Alıcıya ulaşan sinyal $\mathbf{y}(t)$ ile gösterilsin. Gönderilen sinyalin oluşturulmasında kullanılan kipleme türünün $i \in \{1, 2, \dots, L\}$ numaralı aday kipleme türü olduğu, hipotez H_i ile gösterilsin. H_i hipotezinin doğru olduğu varsayıldığında alınan sinyalin olabilirlik fonksiyonu $\Lambda(\mathbf{y}|\boldsymbol{\theta}, H_i)$ şeklinde gösterilir. Aynı şekilde, H_i hipotezinin doğru olduğu varsayıldığında ortalama olabilirlik, genelleştirilmiş olabilirlik ve hibrit olabilirlik yaklaşımları için olabilirlik fonksiyonları sırasıyla $\Lambda_{AL}^{(i)}(\mathbf{y}(t))$, $\Lambda_{GL}^{(i)}(\mathbf{y}(t))$ ve $\Lambda_{HL}^{(i)}(\mathbf{y}(t))$ şeklinde gösterilir. Burada bilinmeyen kanal ve sinyal parametreleri de $\boldsymbol{\theta}$ ile gösterilmektedir.

Ortalama Olabilirlik Yaklaşımı

Ortalama olabilirlik yaklaşımında bilinmeyen parametreler rasgele değişkenler olarak varsayılır. Alınan sinyalin olabilirlik fonksiyonunun bilinmeyen sinyal ve kanal parametrelerinin PDF'lerinin üzerinden ortalaması alınır. Ortalama olabilirlik yaklaşımında olabilirlik fonksiyonu

$$\Lambda_{AL}^{(i)}(\mathbf{y}) = \int \Lambda(\mathbf{y}|\boldsymbol{\theta}, H_i) p(\boldsymbol{\theta}|H_i) d\boldsymbol{\theta} \quad (2.2)$$

şeklinde ifade edilir. Burada $p(\boldsymbol{\theta}|H_i)$ bilinmeyen parametrelerin H_i hipotezinin doğru olduğu koşulu altındaki PDF'ini gösterir [23].

Ortalama olabilirlik tabanlı yöntemlerde, bilinmeyen parametrelerin gerçek dağılımlarının bilinmesi gerekmektedir. Kanal ve sinyale kısıtlı bilgiye sahip olduğu durumlarda önsel dağılım fonksiyonlarının bilinmesi her zaman mümkün olmamaktadır. Bunun yanında her bilinmeyen parametrenin dağılımları üzerinden ortalamasının alınması kipleme sınıflandırması yöntemlerinin işlem yükünü artırmaktadır [2, 24].

Genelleştirilmiş Olabilirlik Yaklaşımı

Genelleştirilmiş olabilirlik tabanlı yaklaşımlarda, ortalama olabilirlik yaklaşımının aksine bilinmeyen parametrelerin deterministik oldukları varsayılmıştır. Bilinmeyen parametrelerin kestirimleri, alıcıdaki sinyalin $i \in \{1, 2, \dots, L\}$ için H_i hipotezinin doğru olduğu koşulu altında, olabilirlik fonksiyonunu enbüyüten şekilde hesaplanır. Genelleştirilmiş olabilirlik tabanlı yaklaşım için olabilirlik fonksiyonu

$$\Lambda_{\text{GL}}^{(i)}(\mathbf{y}) = \arg \max_{\boldsymbol{\theta}} \Lambda(\mathbf{y}|\boldsymbol{\theta}, H_i) \quad (2.3)$$

şeklinde hesaplanır [2, 26].

Literatürde, genelleştirilmiş olabilirlik yaklaşımında gözlenen en ciddi sorun ise 16-QAM ve 64-QAM gibi veya 8-PSK ve 16-PSK gibi içiçe geçmiş yıldızkümesi dağılımlarına sahip kipleme türlerinin sınıflandırılmasının yapılamamasıdır [2, 11].

Hibrit Olabilirlik Yaklaşımı

Hibrit olabilirlik tabanlı yaklaşım ortalama olabilirlik ve genelleştirilmiş olabilirlik tabanlı yaklaşımların karışımı olarak görülebilir. Hibrit olabilirlik yaklaşımı tabanlı yöntemlerde bilinmeyenlerin bir kısmının (kanal kazancı, kanal faz kayması, zaman kayması, frekans kayması v.b.) deterministik bilinmeyenler olduğu varsayılırken bir kısmı (gönderilen sembol dizisi) rasgele değişken olarak varsayılmıştır. Hibrit olabilirlik tabanlı yaklaşımda alıcıdaki sinyalin olabilirlik fonksiyonunun ortalaması, bilinmeyen parametrelerin dağılımları üzerinden alınır. Ardından ortalaması alınan olabilirlik fonksiyonu deterministik sabitler olarak varsayılan parametrelere göre enbüyütülür. Hibrit olabilirlik fonksiyonu

$$\Lambda_{\text{HL}}^{(i)}(\mathbf{y}) = \arg \max_{\boldsymbol{\theta}_1} \int \Lambda(\mathbf{y}|\boldsymbol{\theta}_1, \boldsymbol{\theta}_2, H_i) p(\boldsymbol{\theta}_2|H_i) d\boldsymbol{\theta}_2 \quad (2.4)$$

şeklinde hesaplanır [7, 10, 11, 14, 15].

Hibrit olabilirlik yaklaşımı tabanlı sınıflandırıcıların kullanılması ile geliştirilmiş olabilirlik tabanlı sınıflandırıcıda görülen, yıldız kümesi diyagramları içiçe geçmiş kipleme türlerinin sınıflandırılmaması problemi aşılabılır. Aynı zamanda ortalama olabilirlik tabanlı yaklaşıma kıyasla da işlem karmaşıklığı azaltılmıştır.

İlgili yöntem için olabilirlik fonksiyonu bütün aday kipleme türleri için hesaplandıktan sonra, sınıflandırma kararı

$$\begin{aligned}
 j_{AL} &= \arg \max_{i' \in \{1, 2, \dots, L\}} \Lambda_{AL}^{(i')}(\mathbf{y}; \boldsymbol{\theta}) \\
 j_{GL} &= \arg \max_{i' \in \{1, 2, \dots, L\}} \Lambda_{GL}^{(i')}(\mathbf{y}; \boldsymbol{\theta}) \\
 j_{HL} &= \arg \max_{i' \in \{1, 2, \dots, L\}} \Lambda_{HL}^{(i')}(\mathbf{y}; \boldsymbol{\theta})
 \end{aligned} \tag{2.5}$$

şeklinde verilir [1, 2, 7, 10, 11, 14, 15, 25].

2.3. Beklenti Enbüyütme (EM) Algoritması Tabanlı Kipleme Sınıflandırması

Bu bölümde ilk olarak EM algoritması ve tezde kullanılan EM algoritması türleri ile ilgili teorik bilgi verilecektir. Ardından, literatürde kullanılan EM algoritması temelli kipleme sınıflandırması yöntemleri anlatılacaktır.

2.3.1 EM Algoritması

EM algoritması, örtük veriler barındıran ve bu nedenle tüm verilerin gözlenemediği durumlarda bilinmeyen parametrelerin en büyük olabilirlik kestirimlerinin (Maximum Likelihood Estimate) elde edilebilmesi için geliştirilmiş yinelemeli bir yöntemdir [27]. EM algoritması'nın her yinelemesi iki adımdan oluşur. Bunlar, Beklenti (Expectation, E) adımı ve Enbüyütme (Maximization, M) adımı olarak adlandırılır. E-adımında, örtük verilerin dağılımları üzerinden olabilirlik fonksiyonunun ortalaması alınır. Ardından ortalaması alınan olabilirlik fonksiyonu M-adımında bilinmeyen parametrelere göre enbüyütülür [28, 29].

EM algoritması literatürde, verilerin bir kısmının gözlenemediği uygulamalarda kullanılmasının dışında örüntü tanıma uygulamalarında analitik olarak çözümleri zorlu olan problemlerin basitleştirilmesi için de kullanılmaktadır [28]. Bu tez kapsamında EM algoritmasının kullanımı ikinci sınıfa dahil olmaktadır. Bu bölümün devamında, önerilen yöntemlerin daha kolay anlatılabilmesi için EM algoritması anlatılmıştır.

Toplu EM Algoritması ile Parametre Kestirimi

EM algoritmasında gözlenen ve örtük veri seti olmak üzere iki tür veri olduğu varsayılır. Gözlenen veri seti, tamamlanmamış veri seti olarak da adlandırılır ve $\mathbf{y} = \{\mathbf{y}_1, \mathbf{y}_2, \dots, \mathbf{y}_N\}^T$ ile ifade edilir. Örtük veri seti ise $\mathbf{z} = \{z_1, z_2, \dots, z_N\}$ ile gösterilir. Burada N , gözlenen veya örtük veri setinin toplam eleman sayısını belirtir. Gözlenen veri setinin herhangi bir n 'inci elemanı, \mathbf{y}_n ile ve buna karşılık gelen gözlenemeyen veri setinin n 'inci elemanı ise, z_n ile gösterilmiş olsun. Gözlenen ve gözlenemeyen veri setleri beraber tam veri setini oluşturur. Tam veri seti $\{\mathbf{y}, \mathbf{z}\}$ ile ifade edilir. Tam veri setinin koşullu bileşik olasılık yoğunluk fonksiyonu (Conditional Joint Probability Density Function)

$$p_{\theta}(\mathbf{y}, \mathbf{z}) = p(\mathbf{z}|\mathbf{y}, \theta) p_{\theta}(\mathbf{y}) \quad (2.6)$$

şeklinde ifade edilir. Burada θ bilinmeyen ve kestirilmek istenen parametreleri ifade eder. Koşullu bileşik olasılık yoğunluk fonksiyonu $p(\mathbf{y}, \mathbf{z}|\theta)$ daha sade bir gösterim olması açısından $p_{\theta}(\mathbf{y}, \mathbf{z}) = p(\mathbf{y}, \mathbf{z}|\theta)$ ile gösterilmiştir.

Bilinmeyen parametrelerin kestirimi için, tam veri seti olabilirlik fonksiyonu aşağıda verildiği şekilde tanımlanmıştır:

$$\Lambda(\theta) = p_{\theta}(\mathbf{y}, \mathbf{z}) \quad (2.7)$$

Sadece gözlenen veri setinin olabilirlik fonksiyonu ise $p_{\theta}(\mathbf{y})$ ile ifade edilir. Eşitlik (2.7)'de verilen tam veri setinin olabilirlik fonksiyonunun logaritmasının alınması sonucunda tam veri seti log-olabilirlik fonksiyonu (Log-Likelihood Function) elde edilir.

EM algoritması, E-adımı ve M-adımı olarak adlandırılan iki adımdan oluşur. Her yinelemede E-adımı ve M-adımının sırasıyla tekrarlanmasıyla bilinmeyen parametrelerin en büyük olabilirlik kestirimleri elde edilir. EM algoritması başlatılırken bilinmeyen ve kestirilmek istenen parametrelere başlangıç değerleri atanır. Sonrasında EM algoritması E-adımı ile başlar. E-adımında Eşitlik (2.7)'de verilen olabilirlik fonksiyonunun logaritmasının (tam veri seti log-olabilirlik fonksiyonunun) beklenen değeri örtük veri setinin dağılımı üzerinden aşağıda verildiği şekilde hesaplanır:

$$Q(\theta, \hat{\theta}_{t-1}) = \mathbb{E} \left\{ \log p_{\theta}(\mathbf{Y}, \mathbf{Z}) | \mathbf{Y} = \mathbf{y}, \hat{\theta}_{t-1} \right\} \quad (2.8)$$

burada $\mathbb{E}(\cdot)$ bir rasgele değişkenin beklenen değerin hesaplanması işlemini, θ_{t-1} bilinmeyen parametrelerin mevcut kestirimlerini ve $Q(\cdot)$ ise tam veri setinin log-olabilirlik fonksiyonunun beklenen değerinin hesaplanması sonucunda elde edilen, θ 'ya bağlı, enbüyütülmek

istenen fonksiyonu ifade eder. Rasgele deęişkenler $\mathbb{E}(\cdot)$ 'nin içinde büyük harfler ile gösterilmiştir. Eşitlik (2.8)'in sağ tarafında kalan ifade eęer örtük veri setinin dağılım fonksiyonu sürekli bir fonksiyon ise aşağıda verildięi gibi hesaplanır [28].

$$\mathbb{E} \left\{ \log p_{\theta}(\mathbf{Y}, \mathbf{Z}) | \mathbf{Y} = \mathbf{y}, \hat{\theta}_{t-1} \right\} = \int_{z \in \mathbb{Z}} \log p_{\theta}(\mathbf{y}, z) p(z | \mathbf{y}, \hat{\theta}_{t-1}) dz \quad (2.9)$$

burada \mathbb{Z} bilinmeyen parametrelerin alabileceęi bütün deęerleri içeren uzayı ifade eder. Eęer bilinmeyen veri seti ayrık dağılıma sahip ise integral işlemleri toplam ile deęiştirilir [30, Ch.9].

$$\mathbb{E} \left\{ \log p_{\theta}(\mathbf{Y}, \mathbf{Z}) | \mathbf{Y} = \mathbf{y}, \hat{\theta}_{t-1} \right\} = \sum_z \log p_{\theta}(\mathbf{y}, z) p(z | \mathbf{y}, \hat{\theta}_{t-1}) \quad (2.10)$$

Eşitlik (2.9)'da ve Eşitlik (2.10)'da verilen ifadelerde örtük verilerin marjinal olasılık yoğunluk'ları (Marginal Probability Density Function) $p(z | \mathbf{y}, \theta_{t-1})$ ile gösterilir.

EM algoritmasının M-adımında ise Eşitlik (2.8)'de elde edilen fonksiyonu en büyüten θ kestirimleri aşağıda verilen şekilde hesaplanır:

$$\hat{\theta}_t = \arg \max_{\theta} Q(\theta, \hat{\theta}_{t-1}) \quad (2.11)$$

EM algoritması daha sonra M-adımının sonunda algoritmanın durma koşulunun sağlanıp sağlanmadığını kontrol eder. Eęer sağlanmışsa EM algoritması sonlandırılır. Eęer durma koşulu sağlanamamışsa M-adımında elde edilen kestirimler ile yeniden E-adımına dönülür. E-adımında yeni parametre kestirimleri ile $p(z | \mathbf{y}, \theta_{t-1})$ ve $Q(\cdot)$ hesaplanır ve M-adımıyla devam eder [27–29] ve [30, Ch.9].

M-adımında bilinmeyen parametrelerin en büyük olabilirlik kestirimleri bazı karmaşık problemlerde doğrudan elde edilemeyebilir. Birden fazla bilinmeyen parametre olduğunda, hepsi için optimal kestirimi elde etmek işlem karmaşıklığını artırabilir veya Eşitlik (2.8)'i enbüyütecek analitik çözüm elde edilemeyebilir. Bu gibi problemlerde Genelleştirilmiş EM (Generalized EM, GEM) algoritması kullanılabilir [28]. GEM algoritmasında M-adımında bilinmeyen parametrelerin güncellenmeleri aşağıda verilen koşulu sağlayacak şekilde güncellenir:

$$Q(\hat{\theta}_t, \hat{\theta}_{t-1}) \geq Q(\hat{\theta}_{t-1}, \hat{\theta}_{t-1}) \quad (2.12)$$

GEM yönteminde elde edilen parametre kestirimlerinin, θ_t , Eşitlik (2.8)'de verilen $Q(\cdot)$ fonksiyonunun deęerinin artırmasını sağlaması gerekmektedir. EM algoritmasında olduğu gibi GEM algoritmasında da yerel veya global optimum noktaya yakınsanır fakat yakınsanan noktanın global optimum nokta olması bilinmeyen parametrelerin kestirimlerinin başlangıç deęerlerine baęlıdır [28].

Bir sonraki bölümde bir GEM algoritması olan ve bu tez içinde kullanılan ECM algoritması anlatılmıştır.

Beklenti Koşullu Enbüyütme (ECM) Algoritması

Bilinmeyen parametre vektörü θ birden fazla elemandan oluşuyorsa bazı karmaşık problemlerde Eşitlik (2.11)'de verilen bileşik enbüyütmeyi elde etmek işlem karmaşıklığını arttırmaktadır. Özellikle eğer bilinmeyen parametrelerinin bileşik güncellenme adımlarının kapalı formda elde edilemediği durumlarda bir GEM yöntemi olan ECM algoritması kullanılmaktadır. ECM algoritmasında Eşitlik (2.11)'de verilen M-adımı yerine her parametrenin sırasıyla enbüyütüldüğü Koşullu Enbüyütme (Conditional Maximization, CM) adımı kullanılır.

Bilinmeyen parametrelere karşılık gelen vektör $\theta = \{\theta_1, \theta_2\}^T$ şeklinde ifade edilsin. ECM algoritmasında, CM-adımı aşağıda verilmiştir:

$$\begin{aligned}\hat{\theta}_{1,t} &= \arg \max_{\theta_1} \mathbb{E} \left\{ \log p_{\theta}(\mathbf{Y}, \mathbf{Z}) | \mathbf{Y} = \mathbf{y}, \hat{\theta}_{1,t-1}, \hat{\theta}_{2,t-1} \right\} \\ \hat{\theta}_{2,t} &= \arg \max_{\theta_2} \mathbb{E} \left\{ \log p_{\theta}(\mathbf{Y}, \mathbf{Z}) | \mathbf{Y} = \mathbf{y}, \hat{\theta}_{1,t}, \hat{\theta}_{2,t-1} \right\}\end{aligned}\quad (2.13)$$

CM-adımındaki güncellemeler uygulandıktan sonra EM algoritmasında olduğu gibi algoritmanın bir noktaya yakınsayıp yakınsamadığı kontrol edilir. Eğer kabul edilebilir bir yakınsama sağlanamamışsa algoritma tekrardan, önce E-adımına ve sonrasında CM-adımına dönüp aynı işlemleri yeni parametre kestirimlerini kullanarak tekrarlar. ECM algoritmasında, E-adımı ve CM-adımı sırasıyla yinelenerek yerel veya global bir optimum noktaya yakınsama sağlanana kadar algoritma devam eder [31].

ECM algoritmasında olabilirlik fonksiyonu her parametre ayrı ayrı enbüyütüldüğü için EM algoritmasının M-adımındaki bileşik enbüyütmeden bahsetmek mümkün değildir. Fakat her CM-adımında, olabilirlik fonksiyonu ilgili bilinmeyen parametreye göre enbüyüterek kestirimler yapıldığından, GEM algoritmasındaki Eşitlik (2.12)'de verilen koşulu sağladığı görülebilir.

Titterington'ın Çevrimiçi EM Algoritması

Titterington'ın çevrimiçi EM algoritması, bilinmeyen parametrelerin kestirimlerinin veri setindeki her eleman için sırasıyla yapıldığı çevrimiçi bir EM algoritması yöntemidir. Çevrimiçi yöntemlerde, parametre güncellemelerinde veri setinin her elemanı sadece bir kez

kullanıldığı için, tüm veri üzerinden birden fazla yinelemeye ihtiyaç duyan toplu EM algoritmasına kıyasla işlem yükü azaltılmıştır.

Bu bölümde Titterington'ın çevrimiçi EM algoritmasının anlatımının kolaylaştırılması için ilk olarak, bir toplu EM algoritması olan Lange'nin gradyan tabanlı EM algoritması anlatılmıştır [32]. Lange'nin gradyan tabanlı algoritmasında Eşitlik (2.11)'de verilen M-adımı, aşağıda verilen Newton özyinelemesi tabanlı tırmanış adımı ile değiştirilmiştir:

$$\hat{\boldsymbol{\theta}}_t = \hat{\boldsymbol{\theta}}_{t-1} + \lambda_t \mathbf{J}^{(-1)}(\mathbf{y}, \boldsymbol{\theta}) \sum_{n=1}^N \mathbb{E} \{ \nabla_{\boldsymbol{\theta}} \log p_{\boldsymbol{\theta}}(\mathbf{Y}_n, \mathbf{z}_n) | \mathbf{Y}_n = \mathbf{y}_n \} |_{\boldsymbol{\theta}=\hat{\boldsymbol{\theta}}_{t-1}} \quad (2.14)$$

burada λ_t her özyinelemede azalan adım boyunu ifade eder ve ∇ bir fonksiyonun gradyanını belirtir. Eğer $n \in \{1, 2, \dots, N\}$ için y_n 'ler birbirinden bağımsız ise, Eşitlik (2.14)'te verilen $\mathbf{J}(\mathbf{y}, \boldsymbol{\theta})$ ise

$$\mathbf{J}(\mathbf{y}, \boldsymbol{\theta}) = \frac{1}{N} \sum_{n=1}^N \mathbf{J}(\mathbf{y}_n, \boldsymbol{\theta}) \quad (2.15)$$

şeklinde yazılabilir ve her n için $\mathbf{J}(\mathbf{y}_n, \boldsymbol{\theta})$

$$\mathbf{J}(\mathbf{y}_n, \boldsymbol{\theta}) = -\mathbb{E} \{ \nabla_{\boldsymbol{\theta}}^2 \log p_{\boldsymbol{\theta}}(\mathbf{Y}_n, \mathbf{Z}_n) | \mathbf{Y}_n = \mathbf{y}_n, \boldsymbol{\theta} \} \quad (2.16)$$

ile ifade edilir.

Daha sade bir gösterim sağlanabilmesi için log-olabilirlik fonksiyonu, $\log p_{\boldsymbol{\theta}}(\mathbf{y}_n, \mathbf{z}_n)$, aşağıda verildiği gibi ifade edilsin:

$$q(\boldsymbol{\theta}) = \log p_{\boldsymbol{\theta}}(\mathbf{y}_n, \mathbf{z}_n) \quad (2.17)$$

Tezin devamı ile uyumlu olabilmesi açısından K bir çift sayı olsun. Bu durumda, Eşitlik (2.14)'te verilen gradyan tırmanış adımında tam veri setinin log-olabilirlik fonksiyonunun gradyanı aşağıdaki eşitlikte ifade edildiği şekilde elde edilir [33]:

$$\nabla_{\boldsymbol{\theta}} q(\boldsymbol{\theta}) = \frac{\partial q}{\partial \boldsymbol{\theta}} = \left[\frac{\partial q}{\partial \theta_1} \quad \frac{\partial q}{\partial \theta_2} \quad \cdots \quad \frac{\partial q}{\partial \theta_{K-1}} \quad \frac{\partial q}{\partial \theta_K} \right]^T \quad (2.18)$$

Tam veri setinin log-olabilirlik fonksiyonunun Hesse matrisinin hesaplanması

$$\nabla_{\boldsymbol{\theta}}^2 q(\boldsymbol{\theta}) = \frac{\partial^2 q}{\partial \boldsymbol{\theta} \partial \boldsymbol{\theta}^T} = \begin{bmatrix} \frac{\partial^2 q}{\partial \theta_1 \partial \theta_1} & \frac{\partial^2 q}{\partial \theta_1 \partial \theta_2} & \cdots & \frac{\partial^2 q}{\partial \theta_1 \partial \theta_{K-1}} & \frac{\partial^2 q}{\partial \theta_1 \partial \theta_K} \\ \frac{\partial^2 q}{\partial \theta_2 \partial \theta_1} & \frac{\partial^2 q}{\partial \theta_2 \partial \theta_2} & \cdots & \frac{\partial^2 q}{\partial \theta_2 \partial \theta_{K-1}} & \frac{\partial^2 q}{\partial \theta_2 \partial \theta_K} \\ \vdots & \vdots & \ddots & \vdots & \vdots \\ \frac{\partial^2 q}{\partial \theta_{K-1} \partial \theta_1} & \frac{\partial^2 q}{\partial \theta_{K-1} \partial \theta_2} & \cdots & \frac{\partial^2 q}{\partial \theta_{K-1} \partial \theta_{K-1}} & \frac{\partial^2 q}{\partial \theta_{K-1} \partial \theta_K} \\ \frac{\partial^2 q}{\partial \theta_K \partial \theta_1} & \frac{\partial^2 q}{\partial \theta_K \partial \theta_2} & \cdots & \frac{\partial^2 q}{\partial \theta_K \partial \theta_{K-1}} & \frac{\partial^2 q}{\partial \theta_K \partial \theta_K} \end{bmatrix}^T \quad (2.19)$$

şeklinde yapılır.

Gözlenen veri setinin log-olabilirlik fonksiyonunun gradyanı, tam veri setinin log-olabilirlik fonksiyonunun gradyanının örtük veri setinin dağılımı üzerinden alınan koşullu beklenen değerine eşittir [14, 27, 34].

$$\mathbb{E} \{ \nabla_{\boldsymbol{\theta}} \log p_{\boldsymbol{\theta}}(\mathbf{Y}_n, \mathbf{Z}_n) | \mathbf{Y}_n = \mathbf{y}_n, \boldsymbol{\theta} \} = \nabla_{\boldsymbol{\theta}} \log p_{\boldsymbol{\theta}}(\mathbf{y}_n) \quad (2.20)$$

Eğer tam veri setinin PDF'i üstel bir fonksiyon ise, $\mathbf{J}(\mathbf{y}_n, \boldsymbol{\theta})$ tam veri setinin Fisher enformasyon matrisine (Fisher Information Matrix, FIM) eşit olur [14, 34]. Tam veri setine ait FIM aşağıdaki eşitlikte belirtildiği şekilde hesaplanır:

$$\mathbf{I}(\boldsymbol{\theta}) = -\mathbb{E} \{ \nabla_{\boldsymbol{\theta}}^2 \log p_{\boldsymbol{\theta}}(\mathbf{Y}_n, \mathbf{Z}_n) \} \quad (2.21)$$

Eşitlik (2.20)'de ve Eşitlik (2.21)'de verilen düzenlemeler Eşitlik (2.14)'teki Newton özylemelemede ilgili yerlere yerleştirildiğinde yeni güncelleme ifadesi

$$\hat{\boldsymbol{\theta}}_t = \hat{\boldsymbol{\theta}}_{t-1} + \lambda_t \mathbf{I}^{-1}(\boldsymbol{\theta}) \sum_{n=1}^N \nabla_{\boldsymbol{\theta}} \log p_{\boldsymbol{\theta}}(\mathbf{y}_n) |_{\boldsymbol{\theta}=\hat{\boldsymbol{\theta}}_{t-1}} \quad (2.22)$$

halini alır.

Titterington'ın çevrimiçi EM algoritmasında ise Eşitlik (2.22)'de verilen güncelleme adımı, tam veri setindeki tek elemana bağlı olacak şekilde aşağıda gösterildiği şekilde güncellenir [35]:

$$\hat{\boldsymbol{\theta}}_n = \hat{\boldsymbol{\theta}}_{n-1} + \lambda_n \mathbf{I}^{-1}(\boldsymbol{\theta}) \nabla_{\boldsymbol{\theta}} \log p_{\boldsymbol{\theta}}(\mathbf{y}_n) |_{\boldsymbol{\theta}=\hat{\boldsymbol{\theta}}_{n-1}} \quad (2.23)$$

burada, özyineleme göstergesi i , veri setindeki elemanların sırasını belirten n göstergesi ile değiştirilmiştir. Daha farklı ifade etmek gerekirse, her yeni gözlenen veri elde edildiğinde Eşitlik (2.23) kullanılarak bilinmeyen parametrelerin kestirimleri güncellenecektir. Daha önce bahsedildiği gibi toplu EM algoritmasında tüm elde edilen veriler kullanılarak birden çok yineleme ile parametre kestirimleri elde edilirken çevrimiçi EM algoritması varyantlarında ise her elde edilen veri sadece bir kez bilinmeyen parametrelerin güncellenmesinde kullanılır. Bu durumda toplu EM algoritması yerine bir çevrimiçi EM algoritması kullanarak gereken işlem yükü azaltılabilir.

2.3.2 Literatürdeki EM Algoritması Tabanlı Kipleme Sınıflandırması Yöntemleri

Önceki bölümlerde anlatılan hibrit olabilirlik tabanlı sınıflandırıcının yapısı ile EM algoritmasının yapısı oldukça uyumludur. Yukarıda bahsedildiği üzere hibrit olabilirlik tabanlı yaklaşımda bilinmeyen parametrelerin bir kısmı deterministik bilinmeyenler olarak varsayılırken, kalanı rasgele değişkenler olarak varsayılmıştır ve dağılımları üzerinden olabilirlik fonksiyonunun ortalaması alınmıştır. Hibrit olabilirlik tabanlı yaklaşımlarda EM algoritması kullanılırken, rasgele değişkenler olarak varsayılan bilinmeyen parametreler, EM algoritmasının örtük verileri varsayılabilir. Deterministik parametreler ise EM algoritması ile enbüyütlecek parametreler olarak belirlenebilir. Bu uyum nedeniyle EM algoritması tabanlı hibrit olabilirlik yaklaşımları literatürde sıklıkla kullanılmıştır [6–12, 14, 15]. Bu çalışmalarda, gönderilen sembol dizisi veya bu sembol dizisini tanımlayan etiket verileri EM algoritmasının örtük verileri olarak belirlenmiştir. Gönderilen sembol dizisinin ait olabileceği aday kipleme türleri ve bu kipleme türlerinin yıldız kümesi diyagramları sınıflandırıcı tarafından bilinmektedir. Bu çalışmalarda, olabilirlik fonksiyonunun, örtük veriler olarak kabul edilen gönderilen sembol dizisinin dağılımları üzerinden ortalaması alınır. Daha sonra ortalaması alınan olabilirlik fonksiyonunu enbüyüten parametre kestirimleri yapılır. Bu bölümün devamında EM algoritmasının kullanıldığı kipleme sınıflandırması yöntemleri özetlenmiştir.

Tek alıcı ve tek vericinin olduğu durumlarda Gaussian olmayan gürültü altında çalışan EM algoritması tabanlı kipleme sınıflandırması yöntemi literatürde önerilmiştir [6]. Bu çalışmada bilinmeyen ve bir EM algoritması türü olan Beklenti Koşullu-Enbüyütme (Expectation Conditional Maximization, ECM) algoritması ile kestirmek istenen parametreler kanal katsayısı ve Gaussian olmayan gürültü parametreleridir. ECM algoritması detaylı ola-

rak 2.3.1. Bölümde anlatılmıştır. Özetlemek gerekirse EM algoritmasında her parametrenin birleşik olarak enbüyütüldüğü M-adımı yerini her bilinmeyen parametrenin sırasıyla enbüyütüldüğü Koşullu Enbüyütme (Conditional Maximization, CM) adımı alır. Gaussian olmayan gürültü bu çalışmada Gaussian karışım modeli kullanılarak oluşturulmuştur. Önerilen parametre kestirimi ve kipleme sınıflandırma yönteminin başarımları incelemeleri benzetimler yardımıyla farklı kanal sönümlenmeleri, alınan ortalama SNR değerleri için yapılmıştır.

Literatürdeki kipleme sınıflandırması çalışmalarının ağırlıklı bir kısmı tek alıcı ve tek verici olduğu durumlar için tasarlanmıştır. Bu durum alıcı ve verici arasındaki kanal koşullarının elverişsiz olduğu durumlarda kipleme sınıflandırması uygulamalarının başarımlarının düşmesine sebep olmaktadır. Olumsuz kanal koşullarına örnek olarak düşük SNR değerlerini veya az sayıda sembolün elde edilebildiği durumlar düşünülebilir. Tek alıcı kullanımı sebebiyle oluşan başarımları aşmak için birden fazla alıcı tarafından iletilen örnekler merkezi kaynaştırma (centralized fusion) ile birleştirilerek parametre kestirimi ve kipleme sınıflandırmasının yapıldığı bir yöntem önerilmiştir [7]. Bu çalışmada bilinmeyen parametreler olarak kanal kazançları, kanal fazları ve gürültü varyansları belirlenmiştir. Bilinmeyen parametrelerin kestirimi için EM algoritması kullanılmıştır. Merkezi kaynaştırmada, alıcıların topladıkları ve örnekledikleri gözlemleri merkez düğüme gönderdikleri varsayılmıştır. Merkez düğümde, tüm alıcılardan alınan örnekler kullanılarak alınan sembolün sonsal olasılıkları hesaplanmıştır. Daha sonra bu sonsal olasılıklar kullanılarak parametre güncellemeleri yapılmıştır. Önerilen yöntemin başarımları benzetimler yardımı ile incelenmiştir. Aday kipleme türleri olarak 16-QAM, 32-QAM ve 64-QAM seçilmiştir. Önerilen yöntemin başarımları ilk olarak ortalama alınan SNR değerine göre ve alıcı sayısına göre incelenmiştir. Daha sonra EM algoritmasının farklı durma koşullarında önerilen yöntemin doğru sınıflandırma olasılıkları incelenmiştir. Son olarak önerilen yöntem MoM tabanlı parametre kestirimi yöntemlerini kullanan hibrit olabilirlik benzeri (quasi-Hybrid Likelihood, qHL) sınıflandırıcılar ile karşılaştırılmıştır. Benzetim sonuçlarında, birden fazla alıcı kullanılarak oldukça yüksek başarımları elde edilebildiği gözlenmiştir.

Çok girdili çok çıktılı (Multiple Input Multiple Output, MIMO) bir sistem için EM algoritması tabanlı bir başka kipleme sınıflandırması yöntemi önerilmiştir [8]. EM algoritması ile kestirilmek istenen bilinmeyen parametreler MIMO sistemini oluşturan her alıcı ve verici arasındaki kanal katsayılarına karşılık gelen kanal matrisi ve gürültü varyansı olarak belirlenmiştir. Önerilen yöntemin başarımları analizi BPSK, QPSK ve 16-QAM için benzetimler

yardımı ile ortalama alınan SNR değerine göre ve gönderilen sembol sayısına göre incelenmiştir. Benzetimlerde MIMO sistemin 2 verici ve 4 alıcıdan oluştuğu varsayılmıştır. Bu çalışmanın devamı niteliğindeki bir çalışmada ise bilinmeyen parametrelerin EM algoritması ile kestiriminde başlangıç değerleri atanması için bulanık C-means kümeleme yöntemi önerilmiştir [9].

Birden fazla alıcı kullanılarak kipleme sınıflandırmasında bilinmeyen parametrelerin kestirimleri için dağıtılmış EM algoritması varyantı kullanılmıştır [10]. Bu çalışmada bilinmeyen parametreler kanal katsayıları ve gürültü varyansları olarak belirlenmiştir. Bu parametrelerin dağıtılmış EM algoritması ile kestiriminde her bir alıcının kendi komşuluğundaki alıcılar ile iletişim kurabildiği varsayılmıştır. Her alıcıda, alınan sembollerin sonsal olasılıkları, alıcının kendi gözlemlerine dayanarak hesaplanır. Daha sonra hesaplanan yerel istatistikler ortalama oydaşım süzgeci (average consensus filter) kullanılarak kaynaştırılır. Her alıcı sadece kendi komşuluğundaki alıcılar ile iletişim kurabildiğinden bu işlem sıralı bir şekilde birden fazla yineleme ile yapılabilmektedir. Yinelemeler tamamlandığında süzgeçten geçirilen yerel sonsal olasılıkların, bütün alıcılardaki gözlemler kullanılarak gönderilen sembol global sonsal olasılıklarına yakınsamasını sağlamıştır. Daha sonra bilinmeyen parametre kestirimlerinin güncellemesi, global sonsal olasılıklar kullanılarak yapılır. Önerilen dağıtılmış EM algoritmasında, ortalama oydaşım süzgeci'nin her E-adımında birden fazla kez yinelenmesi gerekmektedir. Önerilen yöntem içiçe iki yineleme gerektirdiğinden yüksek işlem yükü gerektirmektedir. Önerilen yöntemin başarımı benzetim çalışmaları ile farklı ortalama alınan SNR'ı değerleri ve ortalama oydaşım süzgeci yinelemeleri için incelenmiştir. Benzetim çalışmalarında ortalama oydaşım süzgeci yinelemeleri artırıldıkça önerilen dağıtılmış kipleme sınıflandırması yönteminin başarımı, merkezi alıcı ağı kullanılarak elde edilen başarıma yakınsamaktadır.

EM algoritması tabanlı kipleme sınıflandırması çalışmalarının büyük çoğunluğu toplu EM algoritması kullanılmaktadır. Bu yöntemlerde parametre kestirimleri bütün veriler kullanılarak bir kaç yinelemede elde edilmektedir. Bu yaklaşım önerilen yöntemlerin işlem yükünü artırmaktadır. Aynı zamanda parametre kestirimlerinin elde edilebilmesi için bütün veriler toplanmasının beklenmesi gerekmektedir. Literatürde, çevrimiçi EM algoritması varyantları kullanılarak hem parametre kestirimi için gereken işlem yükünün azaltıldığı, hem de istendiği takdirde veriler elde edilmeye devam ederken parametre kestirimlerinin elde edildiği kipleme sınıflandırması yöntemleri önerilmiştir [14, 15]. Bilinmeyen parametrelerin kesti-

rimleri için Titterington'ın ve Cappé'nin çevrimiçi EM algoritmalarını kullanan iki kipleme sınıflandırması yöntemi önerilmiştir [14]. Bu çalışmalarda alıcıların merkezi kaynaştırma yöntemi ile çalıştığı varsayılmıştır. Bilinmeyen parametreler, kanal katsayıları ve gürültü varyansları olarak belirlenmiştir. Önerilen yöntemlerin ikisinde de, parametre güncellemeleri, elde edilen her yeni sembol için gerçekleştirilmiştir. Yeni bir sembol alındıktan sonra merkez düğüme iletilmiş ve burada ilk olarak sonsal olasılıklar hesaplanmıştır. Daha sonra parametre güncellemeleri bu sonsal olasılıklar ile yapılmıştır. Bu yöntem kullanılarak, bilinmeyen parametrelerin kestirimi için gereken işlem yükü ciddi miktarda azaltılmıştır. Bunun nedeni, çevrimiçi parametre güncellemelerinde her alınan sembolün sadece bir kez kullanılarak parametre güncellemesine katkı yapması ile açıklanabilir. Önerilen yöntemler için benzetim çalışmaları farklı ortalama alınan SNR'ları, alıcı sayıları ve toplam alınan sembol sayıları için incelenmiştir. Sonuç olarak önerilen çevrimiçi EM algoritması tabanlı kipleme sınıflandırması yöntemlerinin, birden fazla alıcı olduğu durumlarda, toplu EM algoritması kullanan yöntemlere oldukça yakın başarımlar elde edebildikleri gözlenmiştir.

Dağıtılmış ve çevrimiçi EM algoritması tabanlı parametre kestirimine dayanan bir kipleme sınıflandırması yöntemi önerilmiştir [15]. Bilinmeyen parametreler kanal katsayıları ve gürültü varyansları olarak belirlenmiştir. Bilinmeyen parametrelerin kestirimlerinde Cappé'nin çevrimiçi EM algoritması, dağıtılmış alıcı ağı için uygulanarak kullanılmıştır. Bu çalışmada, her yeni sembol alınan dalgabiçiminden örneklendiğinde, gönderilen sembolün sonsal olasılıkları alıcılarda hesaplanmıştır. Daha sonra ortalama paydaşım süzgeci ile alıcıların sonsal olasılıkları kaynaştırılmıştır. Süzgecin uygulanmasından sonra alıcıların sonsal olasılıkları, global sonsal olasılıklara yakınsamıştır. Daha sonra bilinmeyen parametrelerin kestirimlerinin güncellemeleri yakınsanan global sonsal olasılıklar ile yapılmıştır. Bu çalışmada, [10]'da önerilen yöntemin çevrimiçi versiyonu olarak görülebilir. Toplu EM algoritmasına dayanan yöntemin özetinde bahsedilen yüksek işlem yükü çevrimiçi bir EM algoritması varyantı kullanılarak azaltılmıştır. Benzetim çalışmaları ile önerilen yöntemin başarımları incelenmiştir. Önerilen yöntemin, kahin sınıflandırıcı ile yakın değerler elde edebildiği gözlenmiştir.

EM algoritması tabanlı ve zaman-uyumsuz kipleme sınıflandırması yöntemleri ([11, 12]) oldukları için bir sonraki bölümde anlatılmıştır.

2.4. Zaman Uyumsuz Kipleme Sınıflandırması

Bu bölümde, zaman uyumsuz kipleme sınıflandırması uygulamaları için literatürdeki çalışmalar özetlenmiştir. Bir sayısal haberleşme sisteminde, alıcıya ulaşan sinyal bir sembol süresi ile periyodik bir şekilde $t_s = T + \tau$ ile örneklenmesi gerekmektedir. Burada T bir sembol süresine karşılık gelirken, τ ise alıcı ve verici arasındaki zaman uyumsuzluğundan kaynaklanan zaman kaymasıdır [36, CH.5.3]. Zaman kaymasının bilinmediği durumlarda alıcı ve verici arasında sembol zamanlama referansının bulunmadığı varsayılır. Bir başka ifadeyle, bir alıcıya ulaşan dalgabiçiminin ne zaman örneklenmesi gerektiği bilinemez. Bu durumlarda alınan dalgabiçiminden en iyi şekilde faydalanabilmek için τ ile belirtilen zaman kaymasının kestirimi, alınan örneğin kullanılacağı sistem için elzemdir.

Literatürdeki kipleme sınıflandırması çalışmalarının çoğunluğunda alıcı ve verici arasında sembol zamanlama referansının olduğu varsayılmıştır. Buna karşın, kipleme sınıflandırması uygulamalarının elverişsiz koşullar altında yapıldığı durumlarda, alıcı ve verici arasında sembol zamanlama referansı elde edilemeyebilir. Örnek vermek gerekirse, askeri kipleme sınıflandırması uygulamalarında toplanmakta olan sinyal ile ilgili kısıtlı bilgiye sahip olduğu için, gözü kapalı zamanlama referansı kazanımı (Blind timing recovery) yöntemlerinin kullanılması gerekmektedir. Kısıtlı ön bilgi ile uygulanan bu yöntemlerin sonucunda elde edilen örnekleme zamanı ile gerçek örnekleme zamanı arasında zaman kaymaları bulunabilir. Bunun yanında, eğer birden fazla alıcıdan oluşan bir sistem için zamanlama referansının elde edilmesi gerekiyorsa yüksek işlem karmaşıklığı dolayısıyla örnekleme zamanı tam olarak belirlenemeyebilir ve kestirilmesi gereken zaman kaymaları ortaya çıkabilir [11]. Literatürde, zaman kaymasının bilinmeyen bir parametre olarak alındığı hem olabilirlik tabanlı hem de öznitelik tabanlı kipleme sınıflandırması yöntemleri önerilmiştir. Bu yöntemlerde bilinmeyen zaman kaymasının kestirilmesi sonucunda elde edilen örnekler ile [4, 5, 11, 12] veya alınan dalgabiçiminin uygun bir şekilde işlenmesi ile [13] sınıflandırma kararı verilmektedir. Bu bölümün devamında literatürdeki zaman uyumsuz kipleme sınıflandırması çalışmaları özetlenmiştir.

Alınan sinyallerin 2. ve 4. dereceden logaritmik momentleri kullanılarak farklı derecelerden QAM kipleme türlerinin sınıflandırması yapılmıştır [4]. Bu çalışmada, aday kipleme türleri olarak 8 farklı QAM tipi belirlenmiştir. Bunlar: 8-QAM, 16-QAM, 16 APSK (bu çalışmada yıldız QAM olarak adlandırılmıştır), 32-QAM, 32-APSK, 64-QAM, 128-QAM ve 256QAM

kiplleme türleridir. Kiplleme sınıflandırması öncesinde bilinmediği varsayılan ve kestirilmesi gereken parametreler zaman kayması ve frekans kaymasıdır. Zaman kaymasının kestirimi için kare-zamanlama referansı kazanımı (Square Timing Recovery, STR) yöntemi kullanılmıştır [37]. Zamanlama referansı kazanımı gerçekleştirildikten sonra, elde edilen zaman kayması kestirimi ile, gönderilen dalga biçimi örneklenmiş ve daha sonra logaritmik momentleri hesaplanmıştır. Bu çalışmada bir karar ağacı yapısı ile kiplleme sınıflandırması aşamalı olarak yapılmaktadır. İlk olarak alınan sinyalin 2. dereceden logaritmik momentleri incelenir ve 8-QAM'e ait olmadığı incelenir. Daha sonra 4. dereceden logaritmik momentleri hesaplanıp hangi QAM tipine ait olduğu belirlenir. Bu çalışmanın olumsuz yönlerini sıralamak gerekirse: ilk olarak STR ile doğru zamanlama referansı kazanımı ve anlamlı sınıflandırma kararı verilebilmesi için yüksek sayıda sembol gönderilmesi gerekmektedir. Buna ek olarak önerilen yöntem sadece QAM tiplerinin sınıflandırılması için geliştirildiğinden sınırlı bir uygulama alanına sahiptir.

Hibrit olabilirlik-benzeri olabilirlik tabanlı bir yöntem önerilmiştir [5]. Bu çalışmada kanal kazancı, faz kayması ve zaman kayması bilinmeyen deterministik parametreler olarak varsayılmıştır. Bilinmeyen parametrelerin kestirimleri için düşük işlem karmaşıklığına sahip momentler yöntemi (Method of Moments, MoM) tabanlı parametre kestirimi benimsenmiştir. MoM tabanlı yöntemler isabetli parametre kestirimleri elde edebilmek için yüksek miktarda veriye ihtiyaç duyarlar. Bunun yanında, elde edilen kestirimler her zaman olabilirlik fonksiyonunu enbüyüten kestirimler olmaz. Bu durum, Hibrit olabilirlik-benzeri tabanlı kiplleme sınıflandırması yöntemlerin yüksek sembol sayılarına ihtiyaç duymalarına neden olur. Aynı zamanda olabilirlik fonksiyonunu enbüyüten kestirimler kullanılmadığından, hibrit olabilirlik tabanlı yöntemlere göre daha düşük başarımlar elde edilir. Önerilen yöntemin başarımların analizi BPSK, QPSK, 8-PSK, 16-QAM ve 64-QAM'den oluşan aday kiplleme türü kümesi ile yapılmaktadır. Önerilen yöntem, sınıflandırıcı önceden belirlenen kiplleme türleri için tasarlanmadığından aday kiplleme türü kümesi genişletilerek daha esnek bir şekilde çalıştırılabilir. Önerilen yöntemin olumsuz yönleri ise hem bilinmeyen parametrelerin kestirimleri ve hem de sınıflandırma için ayrı yüksek sayıda sembole ihtiyaç duymasındır.

Tek alıcının kullanılmasından kaynaklı başarımların kısıtlamalarının aşılabilmesi için çoklu alıcılar için zaman uyumsuz hibrit olabilirlik tabanlı kiplleme sınıflandırması yöntemi önerilmiştir [11]. Bu yöntemde kanal kazançları, kanal fazları ve zaman kaymalarının bilinmediği varsayılmıştır. Hibrit olabilirlik tabanlı sınıflandırıcının tasarımında bilinmeyen gönderilen

sembol dizisinin dağılımı üzerinden olabilirlik fonksiyonunun ortalaması alınmıştır. Sonrasında ortalaması alınan olabilirlik fonksiyonu, deterministik olduğu varsayılan bilinmeyen parametrelerin kestirimlerine göre enbüyütülür. Bilinmeyen parametrelerin kestirimleri için EM algoritması kullanılmıştır. EM algoritmasının başlangıç değerlerinin atanmasında benzetimli tavlama (Simulated Annealing) yöntemi kullanılmıştır. Önerilen yöntemde her alıcıdan alınan dalgabiçiminden elde edilen örnekleri kullanarak gönderilen sembolün sonsal olasılıklarını hesaplanır. Daha sonra parametre güncellemeleri bu sonsal olasılıklar kullanılarak güncellenir. Bilinmeyen parametrelerin kestirimleri elde edildikten sonra kipleme sınıflandırması kararı en yüksek olabilirlik fonksiyonu değeri olan aday kipleme türü yönünde verilir. Önerilen yöntemin başarımı benzetim çalışmalarında 8-PSK, 16-PSK, 8-QAM ve 16-QAM için incelenmiştir. Benzetimlerde parametre kestirimlerinin yapılabilmesi ve sınıflandırma kararının verilebilmesi için toplam 100 sembol kullanılmıştır. Bu sembol sayısı, literatürdeki diğer çalışmalara kıyasla oldukça düşük olmasına rağmen birden fazla alıcının kullanıldığı durumlarda oldukça yüksek başarımlar elde ettiği gözlenmiştir. Bunun nedeni tek alıcı için tasarlanan sınıflandırıcılarda, eğer alıcı kötü kanal koşulları altında çalışıyorsa kipleme sınıflandırması kararını hatalı verme olasılığı artar. Buna karşılık, birden fazla alıcıdan oluşan bir ağ düşünüldüğünde, bazı alıcılar kötü kanal koşullarına sahip olsalar dahi, daha uygun kanal koşullarına sahip alıcılardan alınan örneklerin sonsal olasılıkların hesaplanmasında olumlu katkıda bulunmaları ile daha doğru parametre güncellemeleri bütün alıcılar için yapılabilir. Önerilen yöntemin bilinmeyen parametrelerin başlangıç kestirimlerine ve farklı sembol sayılarına bağlı başarımları da bu çalışma içinde incelenmiştir. Bu çalışmanın yüksek başarımlarına rağmen bazı olumsuz yönleri olduğu söylenebilir. Bu çalışmada, toplu EM algoritması kullanılarak parametre kestirimleri yapıldığı için tüm veri setinin yinelemeli bir şekilde birden çok defa kullanılması gerekmektedir. Bu durumda, her yinelemede dalgabiçimleri tekrar örneklenmeli ve sonsal olasılıklar yeni alınan örnekler için tekrar hesaplanmalıdır. Her yinelemede yeni zaman kayması kestirimi ile yeni örneklerin alınabilmesi için bütün dalgabiçiminin sık olarak örneklenecek hafızaya alınması gerekmektedir. Bunun yanında, her yinelemede bütün veri setinin kullanılması işlem yükünü de ciddi oranda artırmaktadır.

Dağıtılmış karar tümleştirme ve hibrit olabilirlik tabanlı zaman uyumsuz bir kipleme sınıflandırması yöntemi önerilmiştir [12]. Bu çalışmada da bilinmeyen ve kestirilmek istenen parametrelerin kanal kazancı, kanal fazı ve zaman kayması olduğu varsayılmış bunların kestirimi için EM algoritması kullanılmıştır. Önerilen yöntemde, her alıcı bireysel olarak topladığı

dalgabiçimlerini kullanarak ilk olarak gönderilen sembollerin sonsal olasılıklarını hesaplar ve sonrasında hesaplanan sonsal olasılıklar ile parametre güncellemelerini yapar. Alıcılarda parametre güncellemeleri tamamlandıktan sonra yerel kipleme sınıflandırması kararları en yüksek olabilirlik değerine sahip kipleme türü lehinde verilir. Daha sonra her alıcı tarafından verilen sınıflandırma kararları bir merkez düğüme iletilir. Merkez düğüme kipleme sınıflandırması kararı en fazla alıcı tarafından seçilen kipleme türü sistemin nihai kararı olarak belirlenir. Benzetim çalışmalarında önerilen yöntemin yüksek SNR değerlerinde merkezi alıcı ağı kullanan EM tabanlı sınıflandırıcı ile benzer başarımları elde ettiği görülmüştür. Fakat düşük ve orta SNR seviyelerinde benzer başarımları elde edememiştir. Bunun nedeni ise merkezi alıcı ağına kıyasla dağıtılmış alıcı ağında, SNR çeşitliliğinden daha verimsiz şekilde faydalanılmasıdır. Yüksek SNR değerine sahip alıcılar ile kötü kanal koşulları altında çalışan alıcıların sınıflandırıcı üzerindeki etkisi aynı olduğu için yüksek başarımları ancak alıcıların çoğunluğu iyi kanal koşulları altında çalışıyorsa elde edilebilmektedir. Bunun yanında, önerilen yöntemin isabetli sonuçlar verebilmesi için alıcı sayısının aday kipleme türlerinden daha fazla olması gerekmektedir.

Dördüncü dereceden logaritmik moment tabanlı bir zaman uyumsuz kipleme sınıflandırması yöntemi önerilmiştir [13]. Bu çalışmada bilinmeyen zaman kaymasının kestirimi yapılmamıştır. Bunun yerine alınan dalgabiçiminin örneklenme sıklığı artırılarak tek girdili çok çıkıtlı (Single Input Multiple Output, SIMO) şekilde işlenmiştir. Alınan dalgabiçiminin yüksek sıklıkla örneklendirilmesi ile alıcıya ulaşan dalgabiçimi farklı altkanallara bölünmüştür. Daha sonra her altkanal için dördüncü dereceden logaritmik momentler hesaplanmıştır. Devamında, hesaplanan logaritmik momentlerin ortalaması alınmış ve sınıflandırma kararı bu ortalamayı kullanarak verilmiştir. Sınıflandırma için karşılaştırılan ve dördüncü dereceden logaritmik momentleri hesaplanan kipleme türleri BPSK, 4-PAM, QPSK, 16-QAM ve 64-QAM olarak belirlenmiştir. Kipleme türlerinin logaritmik momentlerinin sınıflandırma kararı öncesi belirlenmesi zorunluluğu önerilen yöntemin esnekliğini sınırlamaktadır. Bunun yanında alınan sinyali SIMO şeklinde örnekleyerek kullanmak öznelik tabanlı yöntemlerin avantajları arasında sayılan düşük işlem karmaşıklığını artırmaktadır.

3. ÇOKLU ALICILAR KULLANARAK ZAMAN UYUMSUZ KİPLEME SINIFLANDIRMASI

Bu bölümde kipleme sınıflandırması için tez kapsamında önerilen yöntemler anlatılmıştır. İlk olarak sınıflandırma için kullanılacak olan hibrit olabilirlik tabanlı sınıflandırıcı anlatılmıştır. Hibrit olabilirlik tabanlı sınıflandırıcı için bilinmeyen parametrelerin kestirimleri kapalı formda elde edilememektedir. Literatürde bu problemin çözümü için önerilen toplu EM algoritması tabanlı zaman uyumsuz kipleme sınıflandırması yöntemi özetlenmiştir [11]. Ardından, toplu EM algoritmasının kullanılması sonucu ortaya çıkan hafıza gereksinimleri ve işlem yükünün azaltılabilmesi için Titterington'ın çevrimiçi EM algoritması tabanlı parametre kestirimi yöntemi önerilmiştir. İşlem yükünün daha da azaltılabilmesi için dağıtılmış karar tümleştirme yöntemi ile sınıflandırma kararı veren hibrit olabilirlik tabanlı sınıflandırıcı özetlenmiştir. Literatürde önerilen dağıtılmış ve toplu EM algoritması tabanlı kipleme sınıflandırması yöntemi özetlenmiştir [12]. Ardından dağıtılmış alıcı ağı için Titterington'ın çevrimiçi EM algoritması tabanlı parametre kestirimi yöntemi önerilmiştir. Son olarak, parametre kestirimleri için PSO algoritması tabanlı yöntem önerilmiştir. Bu bölümün devamında, dağıtılmış kipleme sınıflandırması için Titterington'ın çevrimiçi EM algoritması tabanlı parametre kestirim yöntemi önerilmiştir. Bu bölümde son olarak PSO algoritması tabanlı toplu kipleme sınıflandırması yöntemi önerilmiştir.

3.1. Problem Tanımı

Bilinmeyen ve bağımsız tekdüze kanal sönümlenmelere ve zaman kaymalarına maruz kalan, bir doğrusal kipleme türü ile kiplenmiş iletişim sinyali K adet alıcıdan oluşan bir alıcı ağı tarafından toplanıyor olsun. Herhangi bir k 'inci alıcıdaki temelbant sinyali aşağıdaki eşitlikte verildiği şekilde gösterilir [36, Ch. 5]:

$$y_k(t) = h_k \sum_n I_n g(t - nT - \tau_k) + \eta_k(t), \quad 0 \leq t \leq T_0 \quad (3.1)$$

$k = 1, \dots, K$ için, burada:

- h_k bilinmeyen karmaşık kanal katsayısıdır¹. h_k iletişim aralığı süresince $([0, T_0])$ sabit kalır.

¹ h_k , k 'inci alıcı ve verici arasındaki kanal sönümlenmesinin, taşıyıcı gücünün, darbe şekli enerjisinin ve artık faz kaymasının tümünün etkilerini ifade eder.

- T_0 toplam iletişim aralığını ifade eder. Bir sembol aralığını gösteren T 'nin tam katıdır ($N = T_0/T$). Toplam gönderilen sembol sayısı N ile gösterilir.
- I_n , n 'inci sembol aralığında iletilen ve aday kipleme türlerinden biri olan \mathcal{X} 'den rasgele olarak seçilen, bilinmeyen karmaşık bir iletişim semboldür.
- $g(\cdot)$ temelbanttaki darbe şeklindedir. $g(\cdot)$ birim enerjiye sahiptir ($\mathcal{E}_g = \int_{-\infty}^{\infty} g^2(t)dt = 1$).
- $\tau_k \in [0, T)$, verici ve alıcı arasındaki zaman uyumsuzluğunu ifade eden zaman kaymasıdır. Zaman kayması bir sembol süresinden daha uzun olamaz.
- $\eta_k(\cdot)$ iki taraflı izgel güç yoğunluğu $N_0/2$ W/Hz olan durağan, dairesel olarak simetrik, karmaşık, Eklenir Beyaz Gauss Gürültü'yu (Additive White Gaussian Noise, AWGN) ifade eder.

Literatürdeki daha önceki çalışmalara benzer olarak sembol süresi T , darbe biçimi $g(\cdot)$ ve taşıyıcı frekansının bilindiği varsayılmıştır [2–6, 10, 11, 25, 38], . Alıcı k için bilinmeyen parametreleri ihtiva eden vektör $\theta_k = (h_k, \tau_k)$ ile gösterilir. Kestirilmek istenen ve bütün alıcıların bilinmeyen parametrelerini içeren, bilinmeyen parametre vektörü de $\theta = (\theta_1, \dots, \theta_K)$ ile ifade edilir. Kipleme sınıflandırması için dikkate alınan aday kipleme türleri $\{\mathcal{X}_\ell\}_{\ell=1}^L$ ile gösterilir. Aday kipleme türlerinden \mathcal{X}_ℓ , toplam M_ℓ adet eş olasılıklı yıldız kümesi noktalarından oluşmaktadır. \mathcal{X}_ℓ 'in yıldız kümesi noktaları $\{\mu_1^{(\ell)}, \dots, \mu_{M_\ell}^{(\ell)}\}$ ile gösterilir. Bütün aday kipleme türlerinin sıfır ortalamaya sahip olduğu kabul edilmiştir. Aday kipleme türü \mathcal{X}_ℓ 'ün ortalama enerjisi $\mathcal{E}^{(\ell)} = \sum_{m=1}^{M_\ell} |\mu_m^{(\ell)}|^2 / M_\ell$ ile ifade edilir. Bu tezde tanımlanan problem, yukarıda belirtilen bilinmezlikler altında $\{y_k(t)\}_{k=1}^K$ 'yi oluşturan kipleme türünün doğru olarak tespit edilmesidir.

Bu problemin çözümü için hibrit olabilirlik yaklaşımı benimsenmiştir. hibrit olabilirlik yaklaşımında, alınan işaretin olabilirlik fonksiyonunun aday kipleme türlerinin sembollerinin dağılımı üzerinden ortalaması alınır. Elde edilen, her aday kipleme türü için ortalaması alınmış olabilirlik fonksiyonu da bilinmeyen parametrelere göre enbüyütülür. Daha sonra, en yüksek olabilirlik skoruna sahip aday kipleme türü sınıflandırıcı tarafından seçilir. Olabilirlik fonksiyonunu vermeden önce daha sade bir gösterim sağlanabilmesi için

$$s_k(t; \theta_k) = h_k \sum_n I_n g(t - nT - \tau_k) \quad (3.2)$$

olsun. Eğer verici tarafından iletilen sembol serisi, $\mathbf{I} = \{I_n\}_{n=1}^N$, biliniyorsa olabilirlik fonksiyonu aşağıda verildiği gibi ifade edilebilir [36, Ch. 5], [11]:

$$\Lambda(\boldsymbol{\theta}) = \exp \left\{ -\frac{1}{N_0} \sum_{k=1}^K \int_0^{T_0} |y_k(t) - s_k(t; \boldsymbol{\theta}_k)|^2 dt \right\}. \quad (3.3)$$

Verici tarafından n 'inci sembol aralığında gönderilmiş olan, k 'inci alıcıya ulaşan dalgabiçiminden alınan sembol $y_{k,n}(\tau_k)$ ile gösterilir ve aşağıda verildiği şekilde örneklenir:

$$y_{k,n}(\tau_k) = \int_{-\infty}^{\infty} y_k(t) g^*(t - nT - \tau_k) dt \quad (3.4)$$

Verici tarafından n 'inci sembol aralığında gönderilen sembolün, tüm alıcılara ulaşan dalgabiçimlerinden alınan örnekleri $\mathbf{y}_n = (y_{1,n}(\tau_1), \dots, y_{K,n}(\tau_K))$ ile gösterilir. Tüm alıcılara ulaşan dalgabiçimlerinden, tüm iletişim aralığı süresince gönderilen semboller için alınan bütün örnekler ise $\mathbf{y} = (\mathbf{y}_1, \mathbf{y}_2, \dots, \mathbf{y}_N)$ ile ifade edilir. Bunlara ek olarak, $g_n = \int_{-\infty}^{\infty} g^*(t) g(t + nT) dt$ olsun. Eşitlik (3.4)'te verilen örnekleme ifadesinde, darbe biçiminin sonlu süreye sahip olduğu ve darbe biçimi süresinin (T_p) toplam iletişim süresi T_0 'a oranla çok daha kısa olduğu ($T_p \ll T_0$) varsayıldığı için integralin sınırları, eksi sonsuzdan artı sonsuza gidecek şekilde uzatılmıştır. Öyle ki, iletişim aralığının başında gönderilen bir sembolün iletişim aralığının sonunda gönderilen bir sembole etkisi gözardı edilebilir [11]. Bu varsayımlar göz önüne alındığında Eşitlik (3.3)'te verilen temelbanttaki olabilirlik fonksiyonu aşağıda verildiği gibi tekrar yazılabilir:

$$\Lambda(\boldsymbol{\theta}) = C \exp \left\{ \frac{1}{N_0} \left(\sum_{n=1}^N \sum_{k=1}^K 2\text{Re} \left\{ I_n^* h_k^* y_{k,n}(\tau_k) \right\} - \sum_{n=1}^N \sum_{m=1}^M \sum_{k=1}^K I_n^* I_m g_{n-m} |h_k|^2 \right) \right\}, \quad (3.5)$$

burada C , bilinmeyen parametre vektörü $\boldsymbol{\theta}$ 'ya bağlı olmayan sabit bir sayıdır ve $(\cdot)^*$ işlemi bir karmaşık sayının eşleniğinin alınmasını ifade eder. Nyquist'in sıfır sembollerarası karpışma kuralını sağlayabilen bir darbe biçimi için $g_n \approx \delta[n]$ olarak varsayılabilir. Burada $\delta[n]$ Kronecker simgesidir [36]. Bu durumda aşağıda verilen sadeleştirmeye gidebiliriz:

$$\sum_n \sum_m \sum_{k=1}^K I_n^* I_m g_{n-m} |h_k|^2 \approx \sum_{n=1}^N |I_n|^2 \sum_{k=1}^K |h_k|^2. \quad (3.6)$$

Bununla beraber, Eşitlik (3.6)'da verilen düzenlemenin, Eşitlik (3.5)'de kullanılmasıyla olabilirlik fonksiyonu aşağıda verildiği gibi ifade edilebilir:

$$\Lambda(\boldsymbol{\theta}) = C \exp \left\{ \frac{1}{N_0} \left(\sum_{n=1}^N \sum_{k=1}^K 2\text{Re} \left\{ I_n^* h_k^* y_{k,n}(\tau_k) \right\} - \sum_{n=1}^N |I_n|^2 \sum_{k=1}^K |h_k|^2 \right) \right\} \quad (3.7)$$

Hibrit olabilirlik tabanlı sınıflandırıcılarda, olabilirlik fonksiyonunun aday kipleme türü \mathcal{X}_ℓ 'in yıldız kümesi noktalarının dağılımı üzerinden ortalaması alınır. Olabilirlik fonksiyonu üstel bir fonksiyon olduğu için, yerine log-olabilirlik fonksiyonu tercih edilmiştir. Aday kipleme türünün yıldız kümesi noktaları üzerinden ortalaması alınmış log-olabilirlik fonksiyonu aşağıda verilmiştir²:

$$\begin{aligned} \log p_{\boldsymbol{\theta}}^{(\ell)}(\mathbf{y}) &= \sum_{n=1}^N \log p_{\boldsymbol{\theta}}^{(\ell)}(\mathbf{y}_n) = \log C - N \log M_\ell \\ &+ \sum_{n=1}^N \log \left(\sum_{m=1}^{M_\ell} \exp \left\{ \frac{2}{N_0} \sum_{k=1}^K \operatorname{Re} \left\{ (\mu_m^{(\ell)})^* h_k^* y_{k,n}(\tau_k) \right\} \right. \right. \\ &\quad \left. \left. - \frac{1}{N_0} |\mu_m^{(\ell)}|^2 \sum_{k=1}^K |h_k|^2 \right\} \right). \end{aligned} \quad (3.8)$$

burada üst indis (ℓ), olabilirlik fonksiyonunun beklenen değerinin, gönderilen sembollerin \mathcal{X}_ℓ kipleme türüne ait olduğu koşulu altında \mathcal{X}_ℓ 'i oluşturan sembolün dağılımı üzerinden alındığını belirtir.

Hibrit olabilirlik tabanlı sınıflandırıcıda, bilinmeyen parametrelerin gerçek değerlerine sahip olunmadığı için bilinmeyen parametrelerin en büyük olabilirlik kestirimlerini kullanır. Bilinmeyen parametre vektörü, $\boldsymbol{\theta}$ 'nın, aday kipleme türü \mathcal{X}_ℓ 'i oluşturan sembollerin dağılımı üzerinden ortalaması alınan olabilirlik fonksiyonunu enbüyüten kestirimleri

$$\hat{\boldsymbol{\theta}}^{(\ell)} = \arg \max_{\boldsymbol{\theta}} \log p_{\boldsymbol{\theta}}^{(\ell)}(\mathbf{y}) \quad (3.9)$$

şeklinde hesaplanır. Aday kipleme türlerine göre hesaplanan en büyük olabilirlik kestirimleri kullanarak, hibrit olabilirlik tabanlı sınıflandırıcıda her aday kipleme türü için log-olabilirlik fonksiyonlarının değerleri hesaplanır. Bu hesaplama sonucunda en büyük log-olabilirlik fonksiyonu sonucunu sağlayan kipleme türü \mathcal{X}_j yönünde karar verilir. hibrit olabilirlik tabanlı sınıflandırıcının karar yapısı birleşik hipotez sınaması yapısı olarak da görülebilir.

$$j = \arg \max_{\ell \in \{1, \dots, L\}} \log p_{\hat{\boldsymbol{\theta}}^{(\ell)}}^{(\ell)}(\mathbf{y}) \quad (3.10)$$

Buradaki problem, bilinmeyen parametrelerin en büyük olabilirlik kestirimlerinin kapalı formda elde edilmesinin çok karmaşık olmasıdır. Buna çözüm olarak literatürde hibrit ola-

²Tezin devamında, sabit bir sayıya karşılık gelen C gösterimi sadeleştirmek adına kaldırılmıştır. Skalar bir sabit olan C , bilinmeyen parametrelere bağlı olmadığından ve her aday kipleme türü için aynı olduğundan tezin devamında bir etkisi yoktur.

bilirlik yaklaşımı tabanlı kipleme sınıflandırması yöntemlerinde sıklıkla kullanılan EM algoritması benimsenmiştir. Bundan sonraki bölümde toplu EM algoritması kullanılarak bilinmeyen parametrelerin kestirimi anlatılmıştır.

3.2. Bilinmeyen Parametrelerin Toplu EM Algoritması ile Kestirimine Dayalı Sınıflandırıcı

EM algoritması, 2.3.1. bölümde anlatıldığı üzere gözlenen ve örtük verilerin bulunduğu durumlarda bilinmeyen parametrelerin en büyük olabilirlik kestirimlerinin elde edilebilmesi için kullanılmaktadır. Hibrit olabilirlik sınıflandırıcı için bilinmeyen parametrelerin kestiriminde her örneklenen sembole karşılık bir örtük etiket verisinin olduğunu varsaydığımızda parametre kestirimi problemi yinelemeli bir şekilde çözülebilecek bir hale getirilebilir. Aday kipleme türü $\mathcal{X}^{(\ell)}$ 'in alıcıda kullanıldığı varsayımı altında, EM algoritması için Örtük veri seti $\mathbf{z} = \{\mathbf{z}_1^{(\ell)}, \dots, \mathbf{z}_N^{(\ell)}\}$ ile ifade edilir ve her $\mathbf{z}_n^{(\ell)} = (z_n^{(\ell),1}, \dots, z_n^{(\ell),M_\ell})$ ile gösterilsin. Eğer vericide kullanılan kipleme türü \mathcal{X}_ℓ ve bu kipleme türünün de m . yıldız kümesi noktası ($I_n = \mu_m^{(\ell)}$) n 'inci sembol zaman aralığında gönderilmişse $z_n^{(\ell),m} = 1$ olur. Aksi takdirde, $r \neq m$ için $z_n^{(\ell),r} = 0$ olarak alınır. EM algoritması için tam veri seti $\{\mathbf{y}, \mathbf{z}^{(\ell)}\}$ ile gösterilir. Tam veri setinin log-olabilirlik fonksiyonu aşağıda verildiği şekilde ifade edilir:

$$\log p_{\boldsymbol{\theta}}^{(\ell)}(\mathbf{y}, \mathbf{z}^{(\ell)}) = \sum_{n=1}^N \log p_{\boldsymbol{\theta}}^{(\ell)}(\mathbf{y}_n, \mathbf{z}_n^{(\ell)}) \quad (3.11)$$

Herhangi bir gönderilen n 'inci sembol için $\log p_{\boldsymbol{\theta}}^{(\ell)}(\mathbf{y}_n, \mathbf{z}_n^{(\ell)})$

$$\begin{aligned} \log p_{\boldsymbol{\theta}}^{(\ell)}(\mathbf{y}_n, \mathbf{z}_n^{(\ell)}) &= -\log M_\ell + \frac{1}{N_0} \sum_{m=1}^{M_\ell} z_n^{(\ell),m} \\ &\times \left(\sum_{k=1}^K \left(2\text{Re} \left\{ (\mu_m^{(\ell)})^* h_k^* y_{k,n}(\tau_k) \right\} - |\mu_m^{(\ell)}|^2 |h_k|^2 \right) \right). \end{aligned} \quad (3.12)$$

ile ifade edilir.

EM algoritmasının bir yinelemesini oluşturan E-adımı ve M-adımı aşağıda verilmiştir:

$$\mathbf{E}\text{-adımı: } Q^{(\ell)}(\boldsymbol{\theta}; \hat{\boldsymbol{\theta}}_{t-1}^{(\ell)}) = \mathbb{E} \left\{ \log p_{\boldsymbol{\theta}}^{(\ell)}(\mathbf{Y}, \mathbf{Z}^{(\ell)}) \mid \mathbf{Y} = \mathbf{y}, \hat{\boldsymbol{\theta}}_{t-1}^{(\ell)} \right\}$$

$$\mathbf{M}\text{-adımı: } \hat{\boldsymbol{\theta}}_t^{(\ell)} = \arg \max_{\boldsymbol{\theta}} Q^{(\ell)}(\boldsymbol{\theta}; \hat{\boldsymbol{\theta}}_{t-1}^{(\ell)}).$$

burada t , EM algoritmasının kaçınıcı yineleme içinde olduğuna karşılık gelen göstergedir ve $\hat{\boldsymbol{\theta}}_{t-1}^{(\ell)}$ bilinmeyen parametrelerin bir önceki yineleme sonucunda elde edilen kestirimleridir.

E-adımında, tam veri setinin log-olabilirlik fonksiyonunun koşullu beklenen değeri örtük veri setinin dağılımı üzerinden hesaplanır. Bu problemde, örtük veri seti ayrık bir dağılıma sahip olduğu için $Q^{(\ell)}(\boldsymbol{\theta}; \hat{\boldsymbol{\theta}}_{t-1}^{(\ell)})$, Eşitlik (2.10) kullanılarak hesaplanır. E-adımının ardından M-adımında, bilinmeyen parametrelerin en büyük olabilirlik kestirimleri, ortalaması alınmış log-olabilirlik fonksiyonunu enbüyütecek şekilde bulunur. Bilinmeyen parametrelerin mevcut kestirimlerine $\hat{\boldsymbol{\theta}}_{t-1}^{(\ell)}$ 'e eşit olduğu varsayımı altında gönderilen semboller birbirinden bağımsızdır. Bu durumda, tam veri log-olabilirlik aşağıda verildiği şekilde ifade edilir:

$$Q^{(\ell)}(\boldsymbol{\theta}; \hat{\boldsymbol{\theta}}_{t-1}^{(\ell)}) = \sum_{n=1}^N Q_n^{(\ell)}(\boldsymbol{\theta}; \hat{\boldsymbol{\theta}}_{t-1}^{(\ell)}), \quad (3.13)$$

burada herhangi bir n 'inci sembol için $Q_n^{(\ell)}(\boldsymbol{\theta}; \hat{\boldsymbol{\theta}}_{t-1}^{(\ell)})$

$$Q_n^{(\ell)}(\boldsymbol{\theta}; \hat{\boldsymbol{\theta}}_{t-1}^{(\ell)}) = -\log M_\ell + \frac{1}{N_0} \sum_{m=1}^{M_\ell} w_{n,t}^{(\ell),m} \times \left(\sum_{k=1}^K \left(2\text{Re} \left\{ (\mu_m^{(\ell)})^* h_k^* y_{k,n}(\tau_k) \right\} - |\mu_m^{(\ell)}|^2 |h_k|^2 \right) \right), \quad (3.14)$$

ile gösterilir. Burada, $w_{n,t}^{(\ell),m}$, t numaralı yinelemede ve n 'inci sembol aralığında gönderilen sembolün $\mu_m^{(\ell)} \in \mathcal{X}_\ell$ olmasının sonsal olasılığını ifade eder ve aşağıda verildiği gibi hesaplanır:

$$w_{n,t}^{(\ell),m} = \frac{\exp \left\{ - \sum_{k=1}^K \frac{|y_{k,n}(\hat{\tau}_{k,t-1}^{(\ell)}) - \hat{h}_{k,t-1}^{(\ell)} \mu_m^{(\ell)}|^2}{N_0} \right\}}{\sum_{m'=1}^{M_\ell} \exp \left\{ - \sum_{k=1}^K \frac{|y_{k,n}(\hat{\tau}_{k,t-1}^{(\ell)}) - \hat{h}_{k,t-1}^{(\ell)} \mu_{m'}^{(\ell)}|^2}{N_0} \right\}}. \quad (3.15)$$

Bilinmeyen parametrelerin birlikte enbüyütülmesinin karmaşıklığından dolayı, bir GEM türü olan ECM algoritması tercih edilmiştir [11]. ECM algoritmasında, M-adımı yerine, her bilinmeyen parametrenin kestiriminin sırasıyla yapıldığı Eşitlik (2.13)'te gösterilen, CM-adımı kullanılmıştır. Bilinmeyen parametrelerin kestirimi için CM-adımı aşağıda verilmiştir:

$$\hat{h}_{k,t}^{(\ell)} = \frac{\sum_{n=1}^N \alpha_{n,t}^{(\ell)} y_{k,n}(\hat{\tau}_{k,t-1}^{(\ell)})}{\sum_{n=1}^N \beta_{n,t}^{(\ell)}}, \quad (3.16a)$$

$$\hat{\tau}_{k,t}^{(\ell)} = \arg \max_{0 \leq \tau_k < T} \text{Re} \left\{ \sum_{n=1}^N \alpha_{n,t}^{(\ell)} (\hat{h}_{k,t}^{(\ell)})^* y_{k,n}(\tau_k) \right\}, \quad (3.16b)$$

$k = 1, \dots, K$ için, burada

- $\alpha_{n,t}^{(\ell)} = \sum_{m=1}^{M_\ell} w_{n,t}^{(\ell),m} (\mu_m^{(\ell)})^*$
- $\beta_{n,t}^{(\ell)} = \sum_{m=1}^{M_\ell} w_{n,t}^{(\ell),m} |\mu_m^{(\ell)}|^2$

ile hesaplanır.

Devam etmeden önce bu tezin konusu olduğu üzere çevrimiçi EM algoritması kullanımının nedenini vurgulamak için bazı noktaların altı çizilmelidir. Bunlardan ilki, Eşitlik (3.16b)'de verilen optimizasyon için alınan dalgabiçiminin sık olarak örneklenmiş şekilde hafızada tutulması gerekmektedir. Zaman kaymasının mevcut yinelemedeki değeri kullanılarak hafızada tutulan sık olarak örneklenmiş dalgabiçiminden yeni N adet örnekten oluşan yeni bir veri seti her yinelemede tekrar tekrar oluşturulur. Bu durumda, toplu EM algoritması kullanılarak gönderilmiş olan N sembole karşılık gelen N örnekten çok daha fazla hafızaya ihtiyaç duyulmasına sebep olur. Hafıza gereksinimi, zaman kaymasının nasıl bir netlik ile kestiriminin yapılmak istendiğine göre değişir. Bir başka önemli konu ise bu bölümde anlatılan EM tabanlı parametre kestiriminde, toplam iletişim aralığında alınan sembollerin sonsal olasılıkları her yinelemede tekrar güncellenmelidir. Bu işlem bütün gözlenen veri seti kullanılarak birden çok yineleme halinde yapılmaktadır. En nihayetinde, her yinelemede bütün verilerin tekrar tekrar kullanılması, bilinmeyen parametrelerin kestirimi için gereken işlem yükünü ciddi miktarda arttırır. Bu iki konu göz önünde tutularak, yüksek hafıza gereksinimi ve işlem yükünden EM algoritmasının çevrimiçi varyantının kullanılmasıyla kısmen kaçınılabılır. Çevrimiçi EM algoritmalarında, bir sembol aralığında alınan dalgabiçimi sadece bir kez örneklenir. Elde edilen örneğin sonsal olasılığı sadece bir kez hesaplanır ve bilinmeyen parametrelerin güncellemeleri yapılır. Bilinmeyen parametrelerin kestirimlerinin güncellemeleri, her örneklenen yeni sembol için ardışık olarak yapılır. Sonuç olarak, yukarıda bahsedilmiş olan hafıza ve işlem gücü gereklilikleri çevrimiçi EM algoritmaları ile aşılabilir. Bunun için önerilen, Titterington'ın çevrimiçi EM algoritması tabanlı bilinmeyen parametre kestirimi ve kipleme sınıflandırması yöntemi bir sonraki bölümde anlatılmıştır.

3.3. Bilinmeyen Parametrelerin Çevrimiçi EM Algoritması ile Kestirime Dayalı Sınıflandırıcı

Titterington'ın çevrimiçi EM algoritmasında M-adımının yerini (3.17)'de gösterilen stokastik gradyan tırmanış adımı alır [34, 35, 39].

$$\hat{\boldsymbol{\theta}}_n^{(\ell)} = \hat{\boldsymbol{\theta}}_{n-1}^{(\ell)} + \lambda_n \mathbf{I}^{-1}(\boldsymbol{\theta}) \nabla_{\boldsymbol{\theta}^*} \log p_{\boldsymbol{\theta}}^{(\ell)}(\mathbf{y}_n) \Big|_{\boldsymbol{\theta}=\hat{\boldsymbol{\theta}}_{n-1}^{(\ell)}}, \quad (3.17)$$

burada parametre kestirimlerinin güncellemeleri yeni semboller alındıkça yapılacağı için yineleme belirteci t , örnekleme belirteci n ile değiştirilir ve $(\lambda_n)_{n=1}^{\infty}$ artı değerli adım boyudur. Eşitlik (2.21)'de belirtilen tam veri setinin Fisher enformasyonu matrisi, aday kipleme türü

\mathcal{X}_ℓ 'in kullanıldığı varsayımı altında n 'inci sembol aralığına karşılık gelen tam veri seti için $\{\mathbf{y}_n, \mathbf{z}_n^{(\ell)}\}$ aşağıda verildiği şekilde hesaplanır:

$$I(\boldsymbol{\theta}) = -\mathbb{E} \left\{ \nabla_{\boldsymbol{\theta}^*, \boldsymbol{\theta}}^2 \log p_{\boldsymbol{\theta}}^{(\ell)}(\mathbf{Y}_n, \mathbf{Z}_n^{(\ell)}) \mid \mathbf{Y}_n = \mathbf{y}_n \right\}. \quad (3.18)$$

Fisher özdeşliğinden faydalanarak tam veri setinin logaritmik olabilirlik fonksiyonunun gradyanının beklenen değeri ile gözlenen logaritmik olabilirlik fonksiyonunun gradyanının birbirine eşit olduğu varsayılabilir. Fisher özdeşliği, n 'inci sembol aralığına karşılık gelen tam veri seti için aşağıdaki eşitlikte gösterilmiştir:

$$\nabla_{\boldsymbol{\theta}^*} \log p_{\boldsymbol{\theta}}^{(\ell)}(\mathbf{y}_n) = \mathbb{E} \left\{ \nabla_{\boldsymbol{\theta}^*} \log p_{\boldsymbol{\theta}}^{(\ell)}(\mathbf{Y}_n, \mathbf{Z}_n^{(\ell)}) \mid \mathbf{Y}_n = \mathbf{y}_n \right\}. \quad (3.19)$$

Bir başka deyişle, bilinmeyen parametrelerin kestirimlerinin güncellenmeleri, son alınan gözlenen verinin log-olabilirlik fonksiyonunun gradyanını, tam veri setinin Fisher enformasyon matrisi ile ağırlıklandırılması ile yapılır.

Eşitlik (3.17)'de verilen parametre kestirim güncellemesinin bilinmeyen kanal katsayısı parametresi için uygulaması ilk olarak anlatılmıştır. Karmaşık kanal katsayısı kestirimi için gözlenen veri log-olabilirlik fonksiyonunun gradyanı aşağıda verildiği şekilde hesaplanır:

$$\left. \frac{\partial \log p_{\boldsymbol{\theta}}^{(\ell)}(\mathbf{y}_n)}{\partial h_k^*} \right|_{\boldsymbol{\theta} = \hat{\boldsymbol{\theta}}_{n-1}^{(\ell)}} = \frac{\alpha_n^{(\ell)} y_{k,n}(\hat{\tau}_{k,n-1}^{(\ell)}) - \beta_n^{(\ell)} \hat{h}_{k,n-1}^{(\ell)}}{N_0}, \quad (3.20)$$

burada

$$\alpha_n^{(\ell)} = \sum_{m=1}^{M_\ell} w_n^{(\ell),m} (\mu_m^{(\ell)})^*, \quad (3.21a)$$


$$\beta_n^{(\ell)} = \sum_{m=1}^{M_\ell} w_n^{(\ell),m} |\mu_m^{(\ell)}|^2, \quad (3.21b)$$

$$w_n^{(\ell),m} = \frac{\gamma_n^{(\ell),m}}{\sum_{m'=1}^{M_\ell} \gamma_n^{(\ell),m'}}, \quad (3.21c)$$

$$\gamma_n^{(\ell),m} = \exp \left\{ -\frac{1}{N_0} \sum_{k=1}^K \left| y_{k,n}(\hat{\tau}_{k,n-1}^{(\ell)}) - \hat{h}_{k,n-1}^{(\ell)} \mu_m^{(\ell)} \right|^2 \right\}, \quad (3.21d)$$

ve $\boldsymbol{\theta}$ 'dan bağımsız olarak tam veri setinin log-olabilirlik fonksiyonunun karmaşık kanal katsayısı parametresi için ikinci dereceden türevi

$$\frac{\partial^2 \log p_{\boldsymbol{\theta}}^{(\ell)}(\mathbf{y}_n, \mathbf{z}_n^{(\ell)})}{\partial h_k^* \partial h_k} = -\frac{1}{N_0} \sum_{m=1}^{M_\ell} z_n^{(\ell),m} |\mu_m^{(\ell)}|^2, \quad (3.22)$$



Şekil 3.1: Doğrusal kipleme türleri için zaman kaymasının çevrimiçi EM algoritması tabanlı en büyük olasılık kestiriminin yapılması.

ile elde edilir. Eşitlik (3.22)'nin beklenen değerinin bulunması aşağıda verilen eşitliklerde gösterilmiştir:

$$-\mathbb{E} \left\{ \frac{\partial^2 \log p_{\theta}^{(\ell)}(\mathbf{y}_n, \mathbf{z}_n^{(\ell)})}{\partial h_k^* \partial h_k} \right\} = \frac{1}{N_0} \sum_{m=1}^{M_\ell} \frac{|\mu_m^{(\ell)}|^2}{M_\ell} = \frac{\mathcal{E}_\ell}{N_0}, \quad (3.23)$$

ve

$$\frac{\partial^2 \log p_{\theta}^{(\ell)}(\mathbf{y}_n, \mathbf{z}_n^{(\ell)})}{\partial h_j^* \partial h_k} = 0, \quad j \neq k \quad \text{için.} \quad (3.24)$$

Alıcı k için karmaşık kanal katsayısı güncellenmesi

$$\hat{h}_{k,n}^{(\ell)} = \hat{h}_{k,n-1}^{(\ell)} + \frac{\lambda_n}{\mathcal{E}_\ell} \left(\alpha_n^{(\ell)} y_{k,n}(\hat{\tau}_{k,n-1}^{(\ell)}) - \beta_n^{(\ell)} \hat{h}_{k,n-1}^{(\ell)} \right). \quad (3.25)$$

ile elde edilir.

Stokastik gradyan güncelenmesinde adım boyu, $0 < \lambda_n < 1$, $\sum_{n=1}^{\infty} \lambda_n = \infty$, ve $\sum_{n=1}^{\infty} \lambda_n^2 < \infty$ koşullarını sağlıyorsa, Eşitlik(3.25) kullanılarak bir yerel veya global optimum değere kesinlikle yakınsanacaktır [34]. Azalan artı değerli adım boyu önerilen yöntem içinde, $\kappa \in [1/2, 1]$ aralığında $\lambda_n = \lambda_0/n^\kappa$ ile ayarlanır. Elde edilen kanal katsayısı kestirimleri, aşağıda verilen Polyak-Ruppert ortalamasının kullanılması ile iyileştirilebilir [40,41].

$$\bar{h}_{k,n}^{(\ell)} = \frac{1}{n - n_0} \sum_{j=n_0+1}^n \hat{h}_{k,j}^{(\ell)}, \quad n \geq 1 \quad (3.26)$$

Zaman kayması kestiriminin çevrimiçi bir şekilde elde edilmesi kanal katsayısı kestirimi ile benzer bir biçimde yapılabilir. Eşitlik (3.13) ve Eşitlik (3.16b) göz önünde bulundurularak, τ_k için $Q^{(\ell)}(\boldsymbol{\theta}, \hat{\boldsymbol{\theta}}_{t-1}^{(\ell)})$ fonksiyonunu enbüyütecek koşullar aşağıda verilmiştir:

$$\begin{aligned} & \frac{dQ^{(\ell)}(\boldsymbol{\theta}, \hat{\boldsymbol{\theta}}_{t-1}^{(\ell)})}{d\tau_k} \\ &= \text{Re} \left\{ \sum_{n=1}^N \alpha_{n,t}^{(\ell)} (\hat{h}_{k,t}^{(\ell)})^* \frac{d}{d\tau_k} \int_{-\infty}^{\infty} y_k(t) g^*(t - nT - \tau_k) dt \right\} \\ &= \text{Re} \left\{ \sum_{n=1}^N \alpha_{n,t}^{(\ell)} (\hat{h}_{k,t}^{(\ell)})^* \frac{d}{d\tau_k} [y_{k,n}(\tau_k)] \right\} = 0 \end{aligned} \quad (3.27)$$

Şekil 3.1’de verilen kaydırma döngüsü zaman kayması kestiriminin güncellenebilmesi için kullanılabilir. Şekil 3.1’de, toplam işareti, Σ ile gösterilen kutucuk, yinelemeli olarak kayan pencere toplamı yapan bir döngü süzgeci olarak çalışır. Döngü toplamının gerçek kısmı gerilim-kontrollü saate (Voltage-Controlled Clock, VCC) girdi olarak sunulur. VCC aldığı girdiye göre zaman kayması güncellemesini gerçekleştirir. Önerilen yapı, kararlı yönlendirilen döngü ile zaman kestirimi yönteminin benzeridir [36, Ch. 5.3].

Önerilen Titterington’ın çevrimiçi EM algoritması tabanlı parametre kestirimi yöntemini özetlemek gerekirse: n ’inci sembolün iletimini takiben alıcılar tarafından kaydedilen dalgabıçımı zaman kayması kestirimlerinin mevcut değerine göre örneklenir. Bütün alıcılarda örneklenen veriler kullanılarak gönderilen sembol’e ait sonsal olasılıkları Eşitlik (3.21c) kullanılarak hesaplanır. Sonrasında, ilk olarak Eşitlik (3.25) kullanılarak kanal katsayısı kestirimleri güncellenir. Daha sonra, zaman kayması kestirimi Şekil 3.1’de verilen döngü kullanılarak güncellenir. Önerilen yöntem, daha sonra yeni alınan $n + 1$. sembol için aynı adımları tekrar ederek devam eder. Yeterli veri toplandığında, Eşitlik (3.10)’da verilen hibrit olabirlik tabanlı sınıflandırıcıyı kullanarak, kipleme sınıflandırması kararı verilir. Verici ve alıcı arasında zaman uyumsuzluğunun bulunduğu bir kipleme sınıflandırması uygulamasında Titterington’ın çevrimiçi EM algoritması varyantını kullanarak bilinmeyen parametrelerin kestirimi için önerilen yöntem, Algoritma 1’de özetlenmiştir.

Şimdiye kadar önerilen EM tabanlı bilinmeyen parametre kestirimi yöntemleri (hem toplu hem çevrimiçi) alıcıların merkezi bir yapıda çalıştığı varsayılarak anlatılmıştır. Merkezi alıcı ağında, alıcılara ulaşan dalgabıçımından alınan örnekler merkez düğüme gönderilir ve işlemler merkez düğümde yapılır. Bu durumda alıcılar ile merkez düğüm arasında yoğun bir veri

Algoritma 1 Zaman uyumsuz kipleme Sınıflandırması için merkezi ve çevrimiçi EM algoritması tabanlı parametre kestirimi

for Her aday kipleme türü için $\ell \in \{1, 2, \dots, L\}$ **do**

Başlangıç değerlerini ata: $\hat{h}_{k,0}^{(\ell)}, \hat{\tau}_{k,0}^{(\ell)} \quad \forall k \in \{1, 2, \dots, K\}$.

end for

$\lambda_n = \lambda_0/n^\kappa$ 'da adım boyunun ayarlanması için λ_0 ve κ değerlerini ayarla $\lambda_n = \lambda_0/n^\kappa$

for $n = 1, 2, \dots, N$ **do**

E-adımı:

for Her aday kipleme türü için $\ell \in \{1, 2, \dots, L\}$ **do**

Örnekleri elde et: $\{y_{k,n}(\hat{\tau}_{k,n-1}^{(\ell)})\}_{k=1}^K$

Eşitlik (3.21d)'yi kullanarak hesapla: $\{\gamma_n^{(\ell),m}\}_{m=1}^{M_\ell}$

Eşitlik (3.21c)'yi kullanarak hesapla: $\{w_n^{(\ell),m}\}_{m=1}^{M_\ell}$

Eşitlik (3.21b)'yi kullanarak hesapla: $\beta_n^{(\ell)}$

Eşitlik (3.21a)'yi kullanarak hesapla: $\alpha_n^{(\ell)}$

end for

M-adımı:

for Her kipleme türü için $\ell \in \{1, 2, \dots, L\}$ **do**

Eşitlik (3.25)'i kullanarak güncelle: $\{\hat{h}_{k,n}^{(\ell)}\}_{k=1}^K$

Şekil 3.1'de verilen takip döngüsünü kullanarak güncelle: $\{\hat{\tau}_{k,n}^{(\ell)}\}_{k=1}^K$

end for

end for

iletiminin bulunması gerekmektedir. Ek olarak bütün işlemlerin bir merkez düğümde yapılacağından, işlem yükü merkez düğümde yoğunlaştırmaktadır. İşlem yükünün alıcılar arasında dağıtılabilmesi, alıcı ve merkez düğüm arasındaki iletişim gereksiniminin azaltılabilmesi ve işlem yükünün daha da düşürülebilmesi için dağıtılmış karar tümleştirme tabanlı kipleme sınıflandırması yöntemleri bir sonraki bölümde anlatılmıştır.

3.4. Dağıtılmış Parametre Kestirimi ve Kipleme Sınıflandırması

Bu bölümde, dağıtılmış karar tümleştirme yaklaşımı ile alıcılara ulaşan sinyallerden elde edilen verilerin kullanıldığı dağıtılmış kipleme sınıflandırması yöntemleri anlatılacaktır. Her alıcıda, alıcıya ulaşan sinyal kullanılarak bilinmeyen parametrelerin kestirimleri yapılır. Ardından alıcılar, kendi aldıkları örnekleri ve kestirdiği parametreleri kullanarak bir yerel kip-

leme sınıflandırması kararı verir. Alıcıların yerel kipleme sınıflandırması kararları bir merkez düğüme iletilir ve merkez düğüme en fazla alıcı tarafından yerel kipleme sınıflandırması kararı olarak iletilen kipleme türü lehinde karar verilir [12].

Herhangi bir k 'inci alıcı için temelbanttaki sinyal modeli Eşitlik (3.1)'de verilmiştir. Vericide kullanılan kipleme türünün \mathcal{X}_ℓ olduğu varsayımı altında, k 'inci alıcıya ulaşan sinyalin log-olabilirlik fonksiyonu aşağıda verilmiştir:

$$\begin{aligned} \log p_{\boldsymbol{\theta}_k}^{(\ell)}(\mathbf{y}_k(\tau_k)) &= \sum_{n=1}^N \log p_{\boldsymbol{\theta}_k}^{(\ell)}(\mathbf{y}_{k,n}) = \log C - N \log M_\ell \\ &+ \sum_{n=1}^N \log \left(\sum_{m=1}^{M_\ell} \exp \left\{ \frac{2}{N_0} \operatorname{Re} \left\{ (\mu_m^{(\ell)})^* h_k^* y_{k,n}(\tau_k) \right\} \right. \right. \\ &\quad \left. \left. - \frac{1}{N_0} |\mu_m^{(\ell)}|^2 |h_k|^2 \right\} \right). \end{aligned} \quad (3.28)$$

burada $\mathbf{y}_k = (y_{k,1}(\tau_k), \dots, y_{k,N}(\tau_k))$, alıcı k 'ye ulaşan sinyalden örneklenen bütün sembolleri gösterir. Alıcı k için bilinmeyen parametrelerin ($\boldsymbol{\theta}_k$ 'nin) en büyük olabilirlik kestirimleri aşağıda verilen şartı sağlayacak şekilde bulunur:

$$\hat{\boldsymbol{\theta}}_k^{(\ell)} = \arg \max_{\boldsymbol{\theta}_k} \log p_{\boldsymbol{\theta}_k}^{(\ell)}(\mathbf{y}_k) \quad (3.29)$$

Parametre kestirimleri elde edildikten sonra k 'inci alıcının yerel sınıflandırma kararı

$$j_k = \arg \max_{\ell \in \{1, \dots, L\}} \log p_{\hat{\boldsymbol{\theta}}_k^{(\ell)}}^{(\ell)}(\mathbf{y}_k) \quad (3.30)$$

şeklinde en yüksek log-olabilirlik fonksiyonu değerine sahip kipleme türü yönünde verilir. Sonrasında, yerel sınıflandırma kararları merkez düğüme gönderilir. Merkez düğüme alıcı ağının nihai sınıflandırma kararı, en fazla alıcı tarafından tercih edilen kipleme türü lehinde verilir.

$$\hat{j} = f(\{j_k\}_{k=1}^K) \quad (3.31)$$

burada $f(\cdot)$ fonksiyonunun işlevi, en fazla alıcı tarafından yerel sınıflandırma kararı olarak merkez düğüme iletilen kipleme türünü seçmektir. Dğıtilmiş alıcı ağında parametre kestirimlerinin alıcılarda toplu EM algoritması ile elde edilmesi bu bölümün devamında özetlenmiştir [12].

3.4.1 Dağıtılmış ve Toplu EM Algoritması ile Parametre Kestirimine Dayalı Kipleme Sınıflandırıcı

Dağıtılmış alıcı ağında, alıcı k 'nin bilinmeyen parametrelerinin en büyük olasılık kestirimleri sadece k 'inci alıcıya ulaşan sinyalden alınan örnekler kullanılarak elde edilir. EM algoritmasının örtük verileri 3.2. Bölümde gösterildiği gibi $\mathbf{z}^{(\ell)}$ ile gösterilsin. Örtük veri seti, $\mathbf{z}^{(\ell)}$, verici tarafından gönderilen sembole ait etiket verileri olarak görülebileceğinden bütün alıcılar için aynıdır. Vericide \mathcal{X}_ℓ 'in kullanıldığı varsayıldığında, alıcı k için tam veri seti $\{\mathbf{y}_k, \mathbf{z}^{(\ell)}\}$ ile gösterilir. Alıcı k için tam veri setinin log-olasılık fonksiyonu aşağıda verildiği şekilde gösterilir:

$$\log p_{\boldsymbol{\theta}_k}^{(\ell)}(\mathbf{y}_k, \mathbf{z}^{(\ell)}) = \sum_{n=1}^N \log p_{\boldsymbol{\theta}_k}^{(\ell)}(y_{k,n}(\tau_k), \mathbf{z}_n^{(\ell)}), \quad (3.32)$$

burada her $\log p_{\boldsymbol{\theta}_k}^{(\ell)}(y_{k,n}(\tau_k), \mathbf{z}_n^{(\ell)})$

$$\begin{aligned} \log p_{\boldsymbol{\theta}_k}^{(\ell)}(y_{k,n}(\tau_k), \mathbf{z}_n^{(\ell)}) &= -\log M_\ell + \frac{1}{N_0} \sum_{m=1}^{M_\ell} z_n^{(\ell),m} \\ &\times \left(2\text{Re} \left\{ (\mu_m^{(\ell)})^* h_k^* y_{k,n}(\tau_k) \right\} - |\mu_m^{(\ell)}|^2 |h_k|^2 \right). \end{aligned} \quad (3.33)$$

olarak ifade edilir. EM algoritmasının E-adımında, k 'inci alıcının aldığı işaretin, bilinmeyen parametrelerin bir önceki yinelemedeki değerlerinin ve gönderilen sembollerin \mathcal{X}_ℓ kipleme türünden seçildiği varsayıldığında koşullu log-olasılık fonksiyonunun gönderilen sembollerin dağılımı üzerinden ortalaması alınır. Burada alıcı k için E-adımı ve M-adımı

$$\mathbf{E}\text{-adımı: } Q_k^{(\ell)}(\boldsymbol{\theta}_k; \hat{\boldsymbol{\theta}}_{k,t-1}^{(\ell)}) = \mathbb{E} \left\{ \log p_{\boldsymbol{\theta}_k}^{(\ell)}(\mathbf{Y}_k, \mathbf{Z}^{(\ell)}) \mid \mathbf{Y}_k = \mathbf{y}_k, \hat{\boldsymbol{\theta}}_{k,t-1}^{(\ell)} \right\}$$

$$\mathbf{M}\text{-adımı: } \hat{\boldsymbol{\theta}}_{k,t}^{(\ell)} = \arg \max_{\boldsymbol{\theta}_k} Q_k^{(\ell)}(\boldsymbol{\theta}_k; \hat{\boldsymbol{\theta}}_{k,t-1}^{(\ell)}).$$

ile ifade edilir. Burada, mevcut yinelemedeki bilinmeyen parametrelerin kestirimleri için gönderilen semboller birbirinden bağımsızdır. Bu durumda, E-adımındaki $Q_k(\cdot)$ fonksiyonu aşağıda verilen eşitlikte gösterilmiştir:

$$Q_k^{(\ell)}(\boldsymbol{\theta}_k; \hat{\boldsymbol{\theta}}_{k,t-1}^{(\ell)}) = \sum_{n=1}^N Q_{k,n}^{(\ell)}(\boldsymbol{\theta}_k; \hat{\boldsymbol{\theta}}_{k,t-1}^{(\ell)}) \quad (3.34)$$

Burada her $Q_{k,n}^{(\ell)}(\boldsymbol{\theta}_k; \hat{\boldsymbol{\theta}}_{k,t-1}^{(\ell)})$

$$Q_{k,n}^{(\ell)}(\boldsymbol{\theta}_k; \hat{\boldsymbol{\theta}}_{k,t-1}^{(\ell)}) = -\log M_\ell + \frac{1}{N_0} \sum_{m=1}^{M_\ell} w_{k,n,t}^{(\ell),m} \times \left(2\text{Re}\left\{ (\mu_m^{(\ell)})^* h_k^* y_{k,n}(\tau_k) \right\} - |\mu_m^{(\ell)}|^2 |h_k|^2 \right) \quad (3.35)$$

olarak ifade edilir. Verici tarafından kullanılan kipleme türünün \mathcal{X}_ℓ olduğu varsayımı altında, n 'inci sembol aralığında $\mu_m^{(\ell)} \in \mathcal{X}_\ell$ 'in gönderilmesinin sonsal olasılığı aşağıda verilen şekilde hesaplanır.

$$w_{k,n,t}^{(\ell),m} = \frac{\exp\left\{-\frac{|y_{k,n}(\hat{\tau}_{k,t-1}^{(\ell)}) - \hat{h}_{k,t-1}^{(\ell)} \mu_m^{(\ell)}|^2}{N_0}\right\}}{\sum_{m'=1}^{M_\ell} \exp\left\{-\frac{|y_{k,n}(\hat{\tau}_{k,t-1}^{(\ell)}) - \hat{h}_{k,t-1}^{(\ell)} \mu_{m'}^{(\ell)}|^2}{N_0}\right\}}. \quad (3.36)$$

Her alıcı kendine ait sonsal olasılıkları hesapladıktan sonra parametre kestirimlerinin güncellemeleri yapılır. Zaman kayması bir fonksiyon içinde kullanıldığındna, parametre güncelleme eşitliğıkapalı formda elde edilememektedir. Bu durumda bileşik enbüyütmenin mümkün olmaması dolayısıyla EM algoritması yerine ECM algoritması tercih edilmişmiştir. Bilinmeyen parametrelerin kestirimlerinin, CM-adımındaki güncellemeleri aşağıda verilen eşitlikler kullanılarak gerçekleştirilir:

$$\hat{h}_{k,t}^{(\ell)} = \frac{\sum_{n=1}^N \alpha_{k,n,t}^{(\ell)} y_{k,n}(\hat{\tau}_{k,t-1}^{(\ell)})}{\sum_{n=1}^N \beta_{k,n,t}^{(\ell)}}, \quad (3.37a)$$

$$\hat{\tau}_{k,t}^{(\ell)} = \arg \max_{0 \leq \tau_k < T} \text{Re}\left\{ \sum_{n=1}^N \alpha_{k,n,t}^{(\ell)} (\hat{h}_{k,t}^{(\ell)})^* y_{k,n}(\tau_k) \right\}, \quad (3.37b)$$

$k = 1, \dots, K$ için, buradaki $\alpha_{k,n,t}^{(\ell)}$ ve $\beta_{k,n,t}^{(\ell)}$ aşağıda verilmiştir:

- $\alpha_{k,n,t}^{(\ell)} = \sum_{m=1}^{M_\ell} w_{k,n,t}^{(\ell),m} (\mu_m^{(\ell)})^*$
- $\beta_{k,n,t}^{(\ell)} = \sum_{m=1}^{M_\ell} w_{k,n,t}^{(\ell),m} |\mu_m^{(\ell)}|^2$

Önceki bölümlerde değinildiğı üzere, bilinmeyen parametrelerin tüm veriler toplandıktan sonra işlenmeye başlanması hafıza gereksinimlerini ve gereken işlemci kapasitesini artırmaktadır. Bu gereksinimler dağıtılmış alıcı ağında daha fazla önem arz etmektedir. Sonraki bölümde, işlem yükü ve hafıza gereksinimlerinin azaltılabilmesi için çevrimiçi EM algoritması tabanlı dağıtılmış kipleme sınıflandırması yöntemi önerilmiştir.

3.4.2 Dağıtılmış ve Çevrimiçi EM Algoritması ile Parametre Kestirimine Dayalı Kipleme Sınıflandırıcı

Dağıtılmış karar tümleştirme tabanlı çevrimiçi sınıflandırıcı için stokastik gradyan adımı herhangi bir k 'inci alıcı için aşağıda verildiği şekilde gösterilir:

$$\hat{\boldsymbol{\theta}}_{k,n} = \hat{\boldsymbol{\theta}}_{k,n-1} + \lambda_n \mathbf{I}^{-1}(\boldsymbol{\theta}_k) \nabla_{\boldsymbol{\theta}_k^*} \log p_{\boldsymbol{\theta}_k}^{(\ell)}(y_{k,n}(\tau_{k,n})) \Big|_{\boldsymbol{\theta}_k = \hat{\boldsymbol{\theta}}_{k,n-1}^{(\ell)}}, \quad (3.38)$$

burada, n gönderilmiş sembol belirteçidir. k 'inci alıcı tarafından n 'inci sembol aralığında alınan ve örneklenen sembole karşılık gelen tam veri seti Fisher enformasyon matrisi aşağıda verilmiştir:

$$I(\boldsymbol{\theta}_k) = -\mathbb{E} \left\{ \nabla_{\boldsymbol{\theta}_k^*, \boldsymbol{\theta}_k}^2 \log p_{\boldsymbol{\theta}_k}^{(\ell)}(Y_{k,n}(\tau_{k,n}), \mathbf{Z}_n^{(\ell)} | Y_{k,n}(\tau_{k,n}) = y_{k,n}(\tau_{k,n})) \right\}. \quad (3.39)$$

Bölüm 3.3'te tartışıldığı üzere, Fisher özdeşliğine göre, gözlenen verinin log-olabilirlik fonksiyonunun gradyanı ile, aynı sembole ait tam veri setinin log-olabilirlik fonksiyonunun gradyanının koşullu beklenen değerinin birbirine eşittir.

$$\nabla_{\boldsymbol{\theta}_k^*} \log p_{\boldsymbol{\theta}_k}^{(\ell)}(y_{k,n}(\tau_{k,n})) = \mathbb{E} \left\{ \nabla_{\boldsymbol{\theta}_k^*} \log p_{\boldsymbol{\theta}_k}^{(\ell)}(Y_{k,n}(\tau_{k,n}), \mathbf{Z}_n^{(\ell)} | Y_{k,n}(\tau_{k,n}) = y_{k,n}(\tau_{k,n})) \right\}. \quad (3.40)$$

Herhangi bir k 'inci alıcı için kanal katsayısı kestirimi, Eşitlik (3.38)'deki özyinelemeye uygun şekilde, aşağıda verildiği şekilde güncellenir:

$$\hat{h}_{k,n}^{(\ell)} = \hat{h}_{k,n-1}^{(\ell)} + \frac{\lambda_n}{\mathcal{E}_\ell} \left(\alpha_{k,n}^{(\ell)} y_{k,n}(\hat{\tau}_{k,n-1}^{(\ell)}) - \beta_{k,n}^{(\ell)} \hat{h}_{k,n-1}^{(\ell)} \right) \quad (3.41)$$

burada

$$\alpha_{k,n}^{(\ell)} = \sum_{m=1}^{M_\ell} w_{k,n}^{(\ell),m} (\mu_m^{(\ell)})^*, \quad (3.42a)$$

$$\beta_{k,n}^{(\ell)} = \sum_{m=1}^{M_\ell} w_{k,n}^{(\ell),m} |\mu_m^{(\ell)}|^2, \quad (3.42b)$$

$$w_{k,n}^{(\ell),m} = \frac{\gamma_{k,n}^{(\ell),m}}{\sum_{m'=1}^{M_\ell} \gamma_{k,n}^{(\ell),m'}}, \quad (3.42c)$$

$$\gamma_{k,n}^{(\ell),m} = \exp \left\{ -\frac{1}{N_0} \left| y_{k,n}(\hat{\tau}_{k,n-1}^{(\ell)}) - \hat{h}_{k,n-1}^{(\ell)} \mu_m^{(\ell)} \right|^2 \right\}. \quad (3.42d)$$

burada $w_{k,n}^{(\ell),m}$, k 'inci alıcıya ulaşan sinyalden alınan örnek kullanılarak hesaplanan, aday kipleme türü \mathcal{X}_ℓ 'e ait $\mu_m^{(\ell)}$ 'in n 'inci sembol aralığında gönderilmesinin sonsal olasılığıdır.

Alıcı k ile vericinin arasındaki zaman kaymasının en büyük olabilirlik kestiriminin aşağıdaki eşitlikte belirtilen koşulu sağlaması gerekmektedir:

$$\begin{aligned}
& \frac{dQ_k^{(\ell)}(\boldsymbol{\theta}_k, \hat{\boldsymbol{\theta}}_{k,t-1})}{d\tau_k} \\
&= \text{Re} \left\{ \sum_{n=1}^N \alpha_{k,n,t}^{(\ell)} (\hat{h}_{k,t}^{(\ell)})^* \frac{d}{d\tau_k} \int_{-\infty}^{\infty} y_k(t) g^*(t - nT - \tau_k) dt \right\} \\
&= \text{Re} \left\{ \sum_{n=1}^N \alpha_{k,n,t}^{(\ell)} (\hat{h}_{k,t}^{(\ell)})^* \frac{d}{d\tau_k} [y_{k,n}(\tau_k)] \right\} = 0
\end{aligned} \tag{3.43}$$

Bölümde 3.3'te zaman kaymasının elde edilmesine benzer olarak, Şekil 3.1'de verilen takip döngüsü her alıcı için ayrı olarak uygulanarak zaman kaymaları alıcılarda ayrı ayrı bulunabilir. Tek fark Şekil 3.1'de verilen takip döngüsünde $\alpha_k^{(\ell)}$ hesaplanırken kullanılan sonsal olasılıklar Eşitlik (3.15)'de ifade edildiği üzere tüm alıcılara ulaşan dalgabiçimlerinden alınan örnekler kullanılarak yapılır. Dağıtılmış alıcı ağı varsayıldığında ise $\alpha_k^{(\ell)}$ yerine, Eşitlik (3.42a)'da verildiği gibi hesaplanan $\alpha_{k,n}^{(\ell)}$ kullanılır. Buradaki fark, Eşitlik (3.42)'de görüldüğü üzere, $\alpha_{k,n}^{(\ell)}$ hesaplanırken kullanılan sonsal olasılıklar, her alıcı tarafından sadece alıcıya ulaşan dalgabiçiminden alınan örnekler kullanılarak Eşitlik (3.42c)'de verildiği gibi hesaplanır.

Dağıtılmış karar tümleştirme tabanlı kipleme sınıflandırması için önerilen çevrimiçi parametre kestirimi yöntemi bu bölümde anlatılmıştır ve Algoritma 2'de özetlenmiştir. Kısa şekilde tekrar etmek gerekirse: Alıcılar, verici tarafından gönderilen iletişim sinyallerini alır ve zaman kayması kestiriminin mevcut kestirimine göre örnekler. Daha sonra, gönderilen sembolün sonsal olasılıkları her alıcı tarafından kendi topladığı dalgabiçiminden alınan örneğe göre hesaplanır. Devamında, sonsal olasılıklar kullanılarak Eşitlik (3.42a) kullanılarak $\alpha_{k,n}^{(\ell)}$ ve Eşitlik (3.42b) kullanılarak $\beta_{k,n}^{(\ell)}$ hesaplanır. Sonrasında, kanal katsayıları, $\hat{h}_{k,n}^{(\ell)}$, Eşitlik (3.41) kullanılarak güncellenir. Her alıcı, kanal katsayısının kestirimini yaptıktan sonra, güncel $\hat{h}_{k,n}^{(\ell)}$ ve $\alpha_{k,n}^{(\ell)}$ değerlerini kullanarak zaman kaymasını Şekil 3.1'de verilen takip döngüsü ile günceller. Yeterince sembol topladığına karar verildiğinde her alıcı kendi sınıflandırma kararını yerel gözlemlerine ve parametre kestirimlerine göre verir. Daha sonra alıcıların yerel sınıflandırma kararları merkez işlemciye gönderilir ve burada Eşitlik (3.31) kullanılarak en fazla alıcı tarafından tercih edilen kipleme türü alıcı ağının kararı olarak seçilir.

Algoritma 2 Zaman uyumsuz kipleme sınıflandırması için dağıtılmış ve çevrimiçi EM algoritması tabanlı parametre kestirimi

for Her aday kipleme türü için: $\ell \in \{1, 2, \dots, L\}$ **do**

Başlangıç değerlerini ata: $\hat{h}_{k,0}^{(\ell)}, \hat{\tau}_{k,0}^{(\ell)} \quad \forall k \in \{1, 2, \dots, K\}$.

end for

$\lambda_n = \lambda_0/n^\kappa$ ile adım boyunun ayarlanması için λ_0 ve κ değerlerini ayarla

for $n = 1, 2, \dots, N$ **do**

for $k = 1, 2, \dots, K$ **do**

E-adımı:

for Her aday kipleme türü için $\ell \in \{1, 2, \dots, L\}$ **do**

Örnekleri elde et: $\{y_{k,n}(\hat{\tau}_{k,n-1}^{(\ell)})\}$

Eşitlik (3.42d)'yi kullanarak hesapla: $\{\gamma_{k,n}^{(\ell),m}\}_{m=1}^{M_\ell}$

Eşitlik (3.42c)'yi kullanarak hesapla $\{w_{k,n}^{(\ell),m}\}_{m=1}^{M_\ell}$

Eşitlik (3.42b)'yi kullanarak hesapla: $\beta_{k,n}^{(\ell)}$

Eşitlik (3.42a)'yı kullanarak hesapla: $\alpha_{k,n}^{(\ell)}$

end for

M-adımı:

for Her aday kipleme türü için $\ell \in \{1, 2, \dots, L\}$ **do**

Eşitlik (3.41)'i kullanarak güncelle: $\{\hat{h}_{k,n}^{(\ell)}\}_{k=1}^K$

Şekil 3.1'deki takip döngüsünü ve Eşitlik (3.42a)'yı kullanarak güncelle:

$\{\hat{\tau}_{k,n}^{(\ell)}\}_{k=1}^K$

end for

end for

end for

3.5. Parçacık Sürü Optimizasyonu (PSO) ile Toplu Veriden Parametre Kestirimine Dayalı Hibrit Olabilirlik Tabanlı Sınıflandırıcı

Bilinmeyen parametrelerin kestirimi için PSO algoritması tabanlı bir yöntem bu tez çalışması kapsamında önerilmiştir [42]. PSO algoritması Eşitlik (3.8)'de verilen dışbükey fonksiyonun çözümü için takip edilebilir yinelemeli bir çözüm sunmaktadır. Bilinmeyen parametrelerin en büyük olabilirlik kestirimleri, P sayıda parçacık kullanılarak elde edilir. Her parçacık, bilinmeyen parametrelerin kestirimlerinin güncel değerlerine karşılık parçacık ko-

numu ve parametre kestirimlerin güncellenmesindeki değişime karşılık gelen parçacık hızı ile tanımlanır. Parçacık p 'nin t 'inci yinelemedeki konumu, $\hat{\boldsymbol{\theta}}_t^{(\ell),p} = (\hat{\boldsymbol{\theta}}_{1,t}^{(\ell),p}, \dots, \hat{\boldsymbol{\theta}}_{K,t}^{(\ell),p})$ ile gösterilir. Herhangi bir k 'inci alıcı için bilinmeyen parametrelerin kestirimleri, parçacık p için, $\hat{\boldsymbol{\theta}}_{k,t}^{(\ell),p} = (\hat{h}_{k,t}^{(\ell),p}, \hat{\tau}_{k,t}^{(\ell),p})$ ile gösterilir. Parçacıkların hızı, $p = 1, 2, \dots, P$ için $\mathbf{v}_t^{(\ell),p}$ ile ifade edilmiştir.

Önerilen PSO tabanlı yöntem, parçacık konumlarını (veya bilinmeyen parametre kestirimlerinin) rasgele ilklendirilmesi ile başlatılır. Her yinelemede, sık olarak örneklenmiş temelbant dalgabiçimlerinden, her bir parçacığın barındırdığı mevcut zaman kayması kestirimleri kullanılarak, her alıcı için N örnek alınır. p 'inci parçacığın t 'inci yinelemedeki zaman kayması kestirimleri kullanılarak, k alıcıya ulaşan dalgabiçiminden alınan N örnek

$$\mathbf{y}_{k,t}^{(\ell),p}(\hat{\tau}_{k,t}^{(\ell),p}) = (y_{k,t,1}^{(\ell),p}(\hat{\tau}_{k,t}^{(\ell),p}), \dots, y_{k,t,N}^{(\ell),p}(\hat{\tau}_{k,t}^{(\ell),p})) \quad (3.44)$$

şeklinde gösterilir. Burada, dalgabiçiminin örneklenmesi aşağıda verildiği şekilde gerçekleştirilir:

$$y_{p,k,n}^{(\ell),t}(\hat{\tau}_{k,t}^{(\ell),p}) = \int_{-\infty}^{\infty} y_k(t)g(t - nT - \tau_{p,k}^{(\ell),t})dt \quad (3.45)$$

Alıcılara ulaşan dalgabiçimlerinden, p 'inci parçacığın t 'inci yinelemedeki zaman kayması kestirimleri kullanılarak alınan bütün örnekler aşağıda verildiği şekilde gösterilir:

$$\mathbf{y}_t^{(\ell),p} = (\mathbf{y}_{1,t}^{(\ell),p}, \dots, \mathbf{y}_{K,t}^{(\ell),p}) \quad (3.46)$$

Dalgabiçimlerinin örneklenmesinin ardından, gönderilen sembollerin \mathcal{X}_ℓ kipleme türüne ait olduğu koşulu altında ortalama log-olabilirlik fonksiyonu Eşitlik (3.8)'de gösterildiği şekilde hesaplanır:

$$\Upsilon_t^{(\ell),p} = \log p_{\hat{\boldsymbol{\theta}}_t^{(\ell),p}}^{(\ell)}(\mathbf{y}_t^{(\ell),p}) \quad (3.47)$$

Her parçacığın ortalama log-olabilirlik fonksiyonu hesapladıktan sonra, parçacıkların t yineleme içinde, bireysel en yüksek log-olabilirlik fonksiyonu değerini elde ettiği yineleme aşağıda verildiği şekilde belirlenir:

$$\zeta^{(\ell),p} = \arg \max_{t' \in \{1, \dots, t\}} \Upsilon_{t'}^{(\ell),p}. \quad (3.48)$$

Parçacığın bireysel en yüksek değeri aşağıda verildiği şekilde kaydedilir:

$$\bar{\Upsilon}^{(\ell),p} = \Upsilon_{\zeta_p^{(\ell)}}^{(\ell),p} \quad (3.49)$$

Parçacık p için, bireysel en yüksek log-olabilirlik skorunun gözlendiği parametre kestirimleri (parçacık konumu)

$$\bar{\boldsymbol{\theta}}^{(\ell),p} = \hat{\boldsymbol{\theta}}_{\zeta^{(\ell),p}}^{(\ell),p} \quad (3.50)$$

şeklinde kaydedilir.

Daha sonra, mevcut yinelemeye kadar herhangi parçacık tarafından elde edilmiş global en yüksek log-olabilirlik fonksiyonu değeri bulunur. Bunun için, parçacıkların bireysel en yüksek log-olabilirlik fonksiyonları arasından en yüksek skoru elde eden parçacık aşağıda verildiği şekilde bulunur:

$$\rho^{(\ell)} = \arg \max_{p' \in \{1, \dots, P\}} \bar{\Upsilon}^{(\ell),p'} \quad (3.51)$$

Global en yüksek log-olabilirlik fonksiyonu değeri aşağıda verildiği gibi kaydedilir:

$$\tilde{\Upsilon}^{(\ell)} = \bar{\Upsilon}^{(\ell),\rho^{(\ell)}}, \quad (3.52)$$

Global en yüksek log-olabilirlik fonksiyonu değerinin elde edildiği bilinmeyen parametre kestirimleri aşağıda verildiği şekilde belirlenir:

$$\check{\boldsymbol{\theta}}^{(\ell)} = \bar{\boldsymbol{\theta}}^{(\ell),\rho^{(\ell)}} \quad (3.53)$$

Global en yüksek log-olabilirlik fonksiyonunun değeri ve konumu belirlendikten sonra parçacık hızları ve devamında parçacık konumları (parametre kestirimleri) aşağıda verildiği sırayla hesaplanır. İlk olarak mevcut yineleme için parçacık hızları aşağıda verildiği şekilde hesaplanır:

$$\mathbf{v}_{t+1}^{(\ell),p} = \frac{1}{3} \left(\mathbf{v}_t^{(\ell),p} + \varrho_t^{(\ell),p} \left(\check{\boldsymbol{\theta}}^{(\ell)} - \hat{\boldsymbol{\theta}}_t^{(\ell),p} \right) + \xi_t^{(\ell),p} \left(\bar{\boldsymbol{\theta}}^{(\ell),p} - \hat{\boldsymbol{\theta}}_t^{(\ell),p} \right) \right) \quad (3.54)$$

Daha sonra parametre kestirimlerini veren parçacık konumları aşağıda verildiği şekilde güncellenir:

$$\hat{\boldsymbol{\theta}}_{t+1}^{(\ell),p} = \hat{\boldsymbol{\theta}}_t^{(\ell),p} + \mathbf{v}_{t+1}^{(\ell),p}, \quad (3.55)$$

burada, $\varrho_t^{(\ell),p}$ ve $\xi_t^{(\ell),p}$, $[0, 1]$ aralığında birörnek dağılıma sahip rasgele değişkenlerdir. Parametre güncellemeleri tamamlandıktan sonra eğer durma kriteri sağlanmamışsa, güncellenmiş parametre kestirimleri kullanılarak yeni örnekler elde edilir ve yöntem devam eder. PSO kullanılarak kipleme sınıflandırması için bilinmeyen parametrelerin kestirimi, Algoritma 3'te özetlenmiştir.

Algoritma 3 Zaman uyumsuz kipleme sınıflandırması için PSO tabanlı parametre kestirimi

for Her kipleme türü için $\ell \in \{1, 2, \dots, L\}$ **do**

for Her parçacık p için **do**

 Parçacık konumlarına başlangıç değerlerini ata, $\hat{\theta}_p^{(\ell),1}$

 Parçacık hızlarını sıfır olarak başlat: $\mathbf{v}_p^{(\ell),1} = \mathbf{0}$.

end for

 Ayarla: $t = 1$

while Durma koşulu sağlanmamışken **do**

for Her parçacık için **do**

 Eşitlik (3.45)'i kullanarak alıcılara ulaşan dalgabiçimlerini her $n = (1, 2, \dots, N)$ için örnekle: $\mathbf{y}_p^{(\ell),t}$.

 Eşitlik (3.47)'yi kullanarak hesapla: $\Upsilon_t^{(\ell),p}$.

 Eşitlik (3.48)'i ve Eşitlik (3.49)'u kullanarak bul: $\bar{\Upsilon}^{(\ell),p}$.

 Eşitlik (3.48)'i ve Eşitlik (3.50)'yi kullanarak bul: $\bar{\theta}^{(\ell),p}$.

end for

 Eşitlik (3.51)'i ve (3.52)'yi kullanarak bul: $\check{\Upsilon}^{(\ell)}$.

 Eşitlik (3.51)'i ve (3.53)'ü kullanarak bul: $\check{\theta}^{(\ell)}$.

for Her parçacık için **do**

 Eşitlik (3.54)'ü kullanarak parçacık hızını güncelle.

 Eşitlik (3.55)'i kullanarak parçacık konumunu güncelle.

end for

$t = t + 1$.

end while

end for.

4. NÜMERİK ÖRNEKLER

Bu bölümde, tez kapsamında önerilen yöntemlerin başarımları benzetim çalışmaları yardımı ile incelenmiştir. Yapılan incelemeler iki farklı aday kipleme türü kümesi için yapılmıştır. Bütün aday kipleme türlerinin sıfır ortalamaya ($\mathbb{E}\{I_n\} = 0$) ve birim enerjiye ($\mathbb{E}\{I_n^2\} = 1$) sahip olduğu varsayılmıştır. Önerilen yöntemlerin başarımlarını ölçütü olarak ortalama doğru sınıflandırma olasılığı kullanılmıştır. Ortalama doğru sınıflandırma olasılığı hesaplanırken, ilk olarak aday kipleme türlerinden herbirinin kendilerine özel koşullu doğru sınıflandırma olasılıkları bulunmuş daha sonra bulunan koşullu doğru sınıflandırma olasılıklarının ortalaması alınarak ortalama doğru sınıflandırma olasılığı elde edilmiştir. Bir aday kipleme türüne ait koşullu doğru sınıflandırma olasılığı, aday kipleme türüne ait semboller kullanılarak gerçekleştirilen toplam 2000 Monte Carlo benzetimi sonunda bulunur. Benzetimlerde, $K \in \{1, 3, 5, 9\}$ adet alıcıdan oluşan alıcı ağları varsayılmıştır. Her bir Monte Carlo benzetiminde kullanılan sembol dizisinin yanında, kanal katsayıları, zaman kaymaları ve gürültü örnekleri kendi olasılık dağılımlarına rasgele oluşturulmuştur. Bir Monte Carlo benzetiminde, toplam $N = 500$ sembol, simetrik olarak sonlu $T_p = 8T$ darbe süresine sahip, izgel etek faktörü $\alpha = 0.3$ olan kök yükseltilmiş-kosinüs (Root Raised-Cosine, RRC) darbe biçimi ile dairesel olarak simetrik karmaşık AWGN kanallardan iletilmiştir. Verici ve alıcılar arasındaki kanalların birbirinden bağımsız olduğu varsayılmıştır. Bu kanallar, kanal kazancı $|h_k|$ ve kanal fazı $\angle h_k$ ile tanımlanır. Kanal kazancı, kanal katsayısını mutlak değeri ($|h_k|$) ile gösterilir ve ölçek parametresi $\sigma = 1$ olan bir Rayleigh rasgele değişken ile modellenir. Kanal fazı, sembollere etki eden faz kaymasını ifade eder ve $[-\pi, \pi)$ üzerinden birörnek bir dağılıma sahip rasgele değişken olarak varsayılır. Zaman kaymaları, $[0, T)$ aralığı üzerinde birörnek dağılıma sahiptir. Kanal katsayıları ve zaman kaymaları her Monte Carlo benzetiminde belirtilen, kendi dağılımlarına göre her alıcı için ayrı olarak rasgele bir şekilde oluşturulmaktadır. Benzetim çalışmalarında gönderilen sembol dizisinin birim enerjiye sahip olduğu varsayıldığından, SNR değerleri aşağıda verildiği gibi ifade edilir:

$$\mathbb{E}\{|h_k|^2\}/N_0 = \sigma^2/N_0 \quad (4.1)$$

burada σ Rayleigh dağılımının ölçek parametresidir ve benzetimlerde $\sigma = 1$ olarak belirlenmiştir. Bu durumda ortalama alınan SNR $1/N_0$ ile ifade edilir ve N_0 'ı değiştirerek farklı ortalama alınan SNR değerleri benzetimlerde ayarlanır.

Benzetimlerde, bir sembol aralığına karşılık gelen dalgabiçiminin modellenebilmesi için dalgabiçiminin her sembol aralığında 100 (örnek/sembol) kez örneklediği varsayılmıştır. Bu durumda zaman kayması değeri bir sembol aralığında olması gerektiğinden $[0, 100)$ aralığındadır. Zaman kaymasının kestirimi sürecinde önerilen çevrimiçi yöntemlerde Şekil 3.1’de verilen takip döngüsü kullanılmaktadır. Takip döngüsünde, VCC’ye iletilen girdi kullanılarak zaman kayması kestirimi güncellenir. Benzetimlerde VCC girdisi eğer artı değerli bir sayıysa zaman katsayısının kestirimi 1 birim artırılır. Eğer eksi değerli bir sayı VCC girdisi olarak sunulmuşsa, zaman kayması kestirimi 1 birim eksiltilerek güncellenir. Önerilen yöntemlerde zaman kayması kestiriminin tamamen çevrimiçi bir şekilde elde edilmesinin sağlanması için takip döngüsünde sadece en son alınan örnek kullanılarak zaman kaymasının kestirimi güncellenir. Başka bir ifadeyle takip döngüsünde yer alan ve döngü süzgecinin olarak kullanılan toplam işlemi kaldırılır. Bunun yerine, sadece en son alınan örnek kullanılarak elde edilen verinin gerçek kısmı VCC girdisi olarak kullanılır.

4.1. Çevrimiçi EM Algoritması Tabanlı Kipleme Sınıflandırma Yöntemlerinin Başarım Sonuçları

Bu tez kapsamında 3.2. ve 3.4.2. Bölümlerde önerilen Titterington’ın çevrimiçi EM algoritması tabanlı kipleme sınıflandırması yöntemlerinde bilinmeyen parametre kestirimlerine ilk değerlerin atanması, yöntemlerin başlayabilmesi için gerekmektedir. Benzetimlerde, bilinmeyen parametrelerin gerçek değerlerinin üzerine kontrollü bir şekilde eklenen rasgele gürültü ile kestirime ilk değerlerin atanması sağlanır. Daha açık şekilde anlatmak gerekirse, k numaralı alıcı için kanal katsayısı kestiriminin ilk değeri aşağıda verildiği şekilde atanır:

$$\hat{h}_{k,0}^{(\ell)} = h_k + cz_k \quad (4.2)$$

burada z_k sıfır ortalamalı ve varyansı 1 olan dairesel olarak simetrik Gaussian dağılıma sahip bir rasgele değişkendir ve c ise bilinmeyen kanal katsayısı kestirimlerinin başlangıç değerinin gerçek değerine olan ortalama uzaklığını ayarlayan gerçek değere sahip kontrol parametresidir. Zaman kaymalarının kestirimlerinin ilk değeri ise

$$\hat{\tau}_{k,0}^{(\ell)} = \tau_k + u_k \quad (4.3)$$

ile yapılır. Burada u_k ise $[-T/4, T/4]$ aralığında bir örnek dağılıma sahip bir rasgele değişkendir.

EM algoritması tabanlı kipleme sınıflandırması yöntemlerinin yüksek başarımları elde edebilmeleri için bilinmeyen parametrelerin başlangıç kestirimlerinin gerçek değerlerine yakın olması gerekmektedir [11]. Aksi takdirde EM algoritması tabanlı yöntemler global optimum parametre kestirimleri yerine, bir yerel optimum noktaya yakınsayabilir. Bunun sonucunda da doğru sınıflandırma olasılığı düşmektedir. Literatürdeki bazı çalışmalarda, toplu EM algoritması tabanlı kipleme sınıflandırması yöntemlerinin başarımlarının artırılması için, öEM algoritması başlatılmadan önce bilinmeyen parametrelerin ilk kestirimlerinin elde edilmesi için veri tabanlı yöntemler uygulanmaktadır [9, 11]. Bu çalışmalarda, bilinmeyen parametrelerin ilk kestirimlerinin yapılabilmesini mümkün kılan, önerilen yöntemlerde toplu EM algoritması kullanılması ve çalışmaya başlamadan önce bütün verilerin hazır bulunmasıdır. Bu tez kapsamında önerilen kipleme sınıflandırması yöntemleri bir çevrimiçi EM algoritmasına dayandığı için veri tabanlı başlangıç kestirimlerinin elde edilmesi mümkün değildir. Bu nedenle, önerilen çevrimiçi yöntemler için, hibrit bir başlangıç değer atama yöntemi benimsenmiştir. Bu yöntemde az sayıda sembole karşılık gelen dalgabıçımı hafızaya alınır ve toplu EM algoritması kullanılarak işlenir. Az miktarda veriyle toplu EM algoritması kullanılarak elde edilen bilinmeyen parametre kestirimleri daha sonra Algoritma 1 ve Algoritma 2'de özetlenen merkezi ve dağıtılmış çevrimiçi parametre kestirimi yöntemlerinde bilinmeyen parametrelerin başlangıç değerleri olarak kullanılır. Uygulanan benzetimlerde ilk 20 sembole karşılık gelen dalgabıçımı toplu EM algoritması ile işlenerek çevrimiçi sınıflandırıcılar için bilinmeyen parametrelerin kestirimlerinin başlangıç değerleri elde edilmiştir.

4.1.1 Çevrimiçi EM Algoritması Tabanlı Kipleme Sınıflandırması Yöntemlerinde Adım Boyu Seçimi


Önerilen çevrimiçi kipleme sınıflandırması yöntemlerinde adım boyu ve Polyak-Ruppert ortalamasının nereden başladığı belirtilmemiştir. Bu bölümde, farklı adım boyu ve Polyak-Ruppert ortalamasının önerilen merkezi ve dağıtılmış yöntemler üzerindeki etkileri incelenmiştir. Aday kipleme türleri olarak 16-QAM, 32-QAM ve 64-QAM belirlenmiştir. Kanal katsayısı parametrelerinin başlangıç değerleri Eşitlik (4.2) kullanılarak rasgele başlatılırken, kontrol parametresi $c = 0.1$ olarak belirlenmiştir. Toplam gönderilen sembol sayısı $N = 500$ olarak ayarlanmıştır.

Önerilen çevrimiçi yöntemlerde, azalan adım boyu


$$\lambda_n = \frac{\lambda_0}{n^\kappa} \quad (4.4)$$

ile ayarlanmıştır. Burada $\lambda_0 = 1$ olarak alınmış ve farklı adım genişlikleri $\kappa \in \{0.5, 0.6, 0.8, 1\}$ için ayarlanmıştır. Her κ değeri için, Eşitlik (3.26)'da verilen Polyak-Ruppert ortalamasının $n_0 = 50$, $n_0 = 250$ ve $n_0 = 450$ olmak üzere üç değerden başlatıldığı varsayılmıştır. Bir başka ifadeyle, Eşitlik (3.26)'da verilen Polyak-Ruppert ortalamasının $n_0 = 50$, $n_0 = 250$ ve $n_0 = 450$ olmak üzere üç farklı n_0 değerinden başlatıldığı durumların herbiri, $\kappa \in \{0.5, 0.6, 0.8, 1\}$ ile ayarlanan farklı adım-genişlikleri için incelenmiştir. Şekil 4.1a'da alıcı sayısı $K = 1$, Şekil 4.1b'de alıcı sayısı $K = 3$, Şekil 4.1c'de alıcı sayısı $K = 5$ ve Şekil 4.1d'de alıcı sayısı $K = 9$ için Polyak-Ruppert ortalaması $n_0 = 450$ 'den başlar-ken önerilen merkezi ve dağıtılmış kipleme sınıflandırması yöntemlerinin ortalama alınan SNR'a göre başarımı $\kappa \in \{0.5, 0.6, 0.8, 1\}$ için gösterilmiştir. Çevrimiçi ve dağıtılmış yöntemler $K = 1$ için aynı olduklarından bu durumlarda sadece merkezi yöntemler gösterilmiştir. Polyak-Ruppert ortalamasının $n_0 = 50$ 'den ve $n_0 = 250$ 'den başlatıldığı durumlarda belirgin bir başarımlar farkı gözlenmemiştir ve bu nedenle bu durumların başarımlar eğrileri dahil edilmemiştir. Birbirine oldukça yakın başarımlar eğrileri elde edilmiş olsa da en iyi sonuçlar $n_0 = 450$ için gözlenmiştir. Adım boyunu kontrol eden κ parametresi için ise en yüksek doğru sınıflandırma olasılıkları bütün Polyak-Ruppert ortalamaları için $\kappa = 0.5$ olarak ayarlandığında elde edilmiştir.

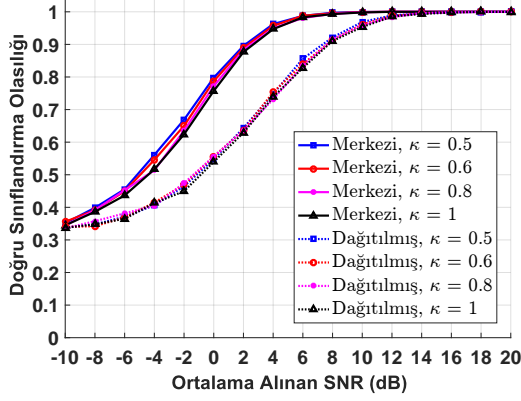
Polyak-Ruppert ortalamasının başlangıç noktası ve adım boyunu düzenleyen κ parametrelerinin başka aday kipleme türleri dizisi kullanıldığındaki değişimlerinin gözlenmesi için 8-PSK, 16-PSK, 8-QAM ve 16-QAM kipleme türlerinden oluşan dizi kullanılmıştır. Bu aday kipleme türleri dizisi için farklı adım-genişlikleri $\kappa \in \{0.5, 0.6, 0.8, 1\}$ için denenmiştir. Her farklı κ değeri için de Polyak-Ruppert ortalaması $n_0 = 50$, $n_0 = 250$ ve $n_0 = 450$ 'den başlatılmıştır. Çevrimiçi sınıflandırıcıların başarımlar seviyelerinde çeşitli n_0 değerleri için belirgin bir fark, bu aday kipleme türleri kümesi için de gözlenmemiştir. Şekil 4.2'de Polyak-Ruppert ortalamasının $n_0 = 450$ 'den başladığı durumda önerilen çevrimiçi sınıflandırıcıların ortalama alınan SNR'a göre doğru sınıflandırma olasılığı grafikleri $\kappa \in \{0.5, 0.6, 0.8, 1\}$ ve $K \in \{1, 3, 5, 9\}$ için verilmiştir. Diğer aday kipleme türü kümesinde olduğu gibi burada da en yüksek başarımlar adım boyu $\kappa = 0.5$ olarak ayarlandığında ve Polyak-Ruppert ortalaması $n_0 = 450$ 'den başladığında görülmüştür.



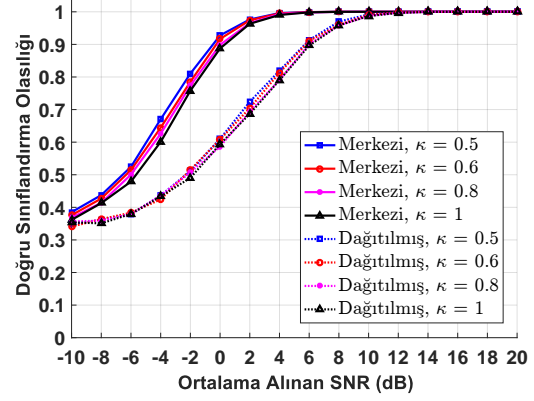
(a) Alıcı sayısı $K = 1$



(b) Alıcı sayısı $K = 3$




(c) Alıcı sayısı $K = 5$




(d) Alıcı sayısı $K = 9$


Şekil 4.1: Merkezi (düz çizgi ile gösterilmiştir) ve dağıtılmış (kesik çizgi ile gösterilmiştir) çevrimiçi kipleme sınıflandırması yöntemlerinin farklı adım boyları ve alıcı sayıları $K \in \{1, 3, 5, 9\}$ için ortalama alınan SNR'a göre doğru sınıflandırma olasılığı grafikleri gösterilmiştir. Polyak-Ruppert ortalaması $n_0 = 450$ 'den başlatılmıştır. Uygulanan adım-genişlikleri $\kappa \in \{0.5, 0.6, 0.8, 1\}$ değerleri ile ayarlanmıştır. Aday kipleme türleri: 16-QAM, 32-QAM, 64-QAM.




(a) Alıcı sayısı $K = 1$



(b) Alıcı sayısı $K = 3$



(c) Alıcı sayısı $K = 5$



(d) Alıcı sayısı $K = 9$

Şekil 4.2: Merkezi (düz çizgi ile gösterilmiştir) ve dağıtılmış (kesik çizgi ile gösterilmiştir) çevrimiçi kipleme sınıflandırması yöntemlerinin farklı adım boyları ve alıcı sayıları $K \in \{1, 3, 5, 9\}$ için ortalama alınan SNR'a göre doğru sınıflandırma olasılığı grafikleri gösterilmiştir. Polyak-Ruppert ortalaması $n_0 = 450$ 'den başlatılmıştır. Uygulanan adım-genişlikleri $\kappa \in \{0.5, 0.6, 0.8, 1\}$ değerleri ile ayarlanmıştır. Aday kipleme türleri: 8-PSK, 16-PSK, 8-QAM, 16-QAM.

Şekil 4.1’de ve Şekil 4.2’de gözlenebileceği üzere önerilen çevrimiçi kipleme sınıflandırması yöntemleri en iyi başarımlarını $\kappa = 0.5$ ve $n_0 = 450$ olarak ayarlandığında elde etmişlerdir. Bu değerler için bilinmeyen kanal katsayısı ve zaman kayması kestirimlerinin alınan sembollere göre değişimi sırasıyla Şekil 4.3a ve Şekil 4.3b’de verilmiştir. Ortalama alınan SNR 0 dB, alıcı sayısı $K = 9$ ve gerçek kipleme türü bu örnek içinde 64-QAM olarak belirlenmiştir. Kanal katsayısı kestirimlerinin gerçek değerleri ile aralarındaki hatanın incelenmesi

$$e_h(n) = \frac{1}{K} \sum_{k=1}^K |h_k - \hat{h}_{k,n}^{(\ell)}|^2 \quad (4.5)$$

kullanılarak yapılır. Benzer şekilde zaman kayması parametresinin kestiriminin hatası da aşağıda verildiği şekilde incelenir:

$$e_\tau(n) = \frac{1}{K} \sum_{k=1}^K |\tau_k - \hat{\tau}_{k,n}^{(\ell)}|^2 \quad (4.6)$$

Şekil 4.3’te verilen örnekte, ilk 20 örnek başlangıç değerlerinin hesaplanması için kullanıldığı için sabit gösterilmiştir. Kanal katsayısı kestirimlerinin yaklaşık olarak 200. örnek alındıktan sonra bir noktaya yakınsadığı fakat salınımların devam ettiği gözlenmektedir. Benzer şekilde kanal katsayısı kestirimlerinin ise 400. örnekten sonra bir noktaya yakınsamasının sağlandığı gözlenmiştir.

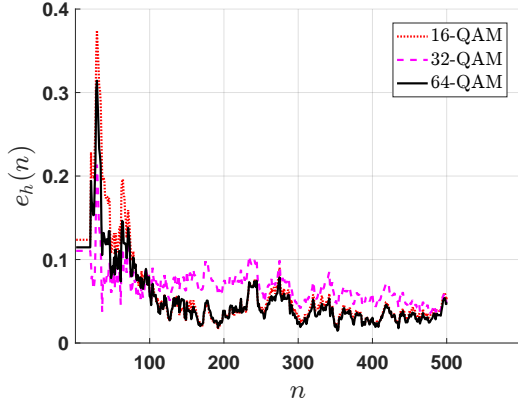
Bu tezin devamındaki benzetim çalışmaları sunulurken en iyi sınıflandırma başarımının sağlandığı $\kappa = 0.5$ ve $n_0 = 450$ kullanılmıştır.

4.1.2 Çevrimiçi EM Algoritması Tabanlı Kipleme Sınıflandırması Yöntemlerinde Alıcı Sayısının Etkisi

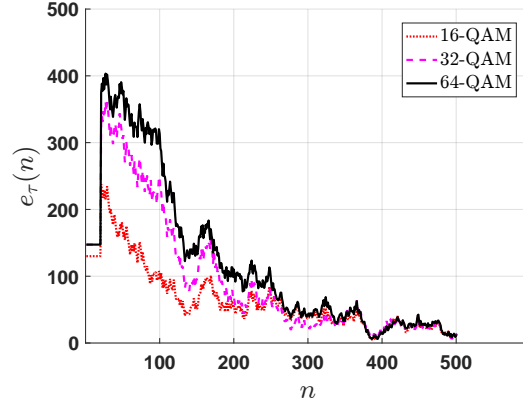
Bu bölümde Algoritma 1 ve Algoritma 2’de özetlenen çevrimiçi kipleme sınıflandırması yöntemlerinin diğer sınıflandırma yöntemlerine göre ve alıcı sayısına başarımları incelenmiştir.

16-QAM, 32-QAM ve 64-QAM Kipleme Türleri İçin Başarım İncelemesi

İlk olarak aday kipleme türleri olarak 16-QAM, 32-QAM ve 64-QAM seçilmiştir. Bilinmeyen parametrelerin kestirimlerinin başlangıç değerlerinin atanmasında kontrol parametresi $c = 0.1$ olarak belirlenmiştir. Bir önceki bölümde anlatıldığı üzere azalan adım boyu, $\kappa = 0.5$ kullanılarak ayarlanmıştır ve Polyak-Ruppert ortalamasının alınmasına $n_0 = 450$ ’den başlanmıştır. Başarım incelenmesinde kullanılan diğer kipleme sınıflandırması yöntemleri,



(a) Kanal Katsayısı




(b) Zaman Kayması


Şekil 4.3: Merkezi ve çevrimiçi kipleme sınıflandırması yönteminde bilinmeyen parametrelerin kestirimlerindeki hatanın alınan sembollere göre değişimi verilmiştir. Alıcı sayısı $K = 9$, ortalama alınan SNR 0 dB ve gerçek kipleme türü 64-QAM'dir.

önerilen merkezi ve dağıtılmış çevrimiçi yöntemlerin, toplu EM algoritmasını kullanan versiyonları ve kahin (Literatürde clairvoyant sınıflandırıcı olarak anılmaktadır. [10, 11]) sınıflandırıcıdır. Kahin sınıflandırıcı, diğer yöntemler tarafından bilinmeyen parametrelerin gerçek değerine sahiptir. Bu nedenle kahin sınıflandırıcı ile diğer sınıflandırıcılar arasındaki fark bilinmeyen parametrelerin kestirimlerinin gerçek değerlerine olan uzaklık ile artmaktadır. Şekil 4.4a, Şekil 4.4b, Şekil 4.4c ve Şekil 4.4d'de sırasıyla alıcı sayısı $K \in \{1, 3, 5, 9\}$ iken kahin sınıflandırıcı (mavi), merkezi toplu EM algoritması tabanlı (kırmızı), dağıtılmış EM algoritması tabanlı (mor), merkezi ve çevrimiçi (siyah) ve dağıtılmış ve çevrimiçi yöntemler için başarımlar eğrileri verilmiştir. Beklendiği gibi en iyi başarımlar bütün alıcı sayıları ve SNR değerleri için kahin sınıflandırıcı tarafından elde edilmiştir. Önerilen çevrimiçi kipleme sınıflandırması yöntemleri ile kahin sınıflandırıcı arasındaki başarımlar farkı alıcı sayısı arttıkça ve SNR değeri düştükçe önerilen iki sınıflandırıcı için de daha bariz olmaktadır. Eğer alıcı sayısı $K = 3$ veya daha büyük bir sayı ise önerilen çevrimiçi yöntemler yüksek SNR değerlerinde kahin sınıflandırıcısının başarımlarına erişebilmektedir.

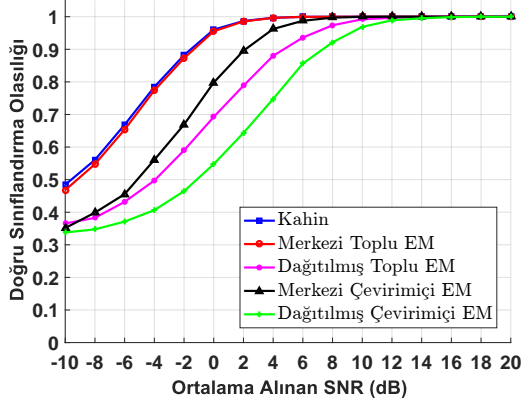
Kipleme sınıflandırması yöntemlerinin Şekil 4.4'te verilen başarımlar eğrileri incelendiğinde, alıcı sayısının artması ile doğru sınıflandırma olasılığının yükseldiği gözlenmiştir. Bunun nedeni çoklu alıcıların kullanılması ile alınan sinyaller arasında SNR çeşitliliği yaratılabilmesidir. Örnek olarak, $K = 1$ alıcı için merkezi ve çevrimiçi sınıflandırıcı kullanılarak %100 doğru sınıflandırma olasılığına erişilemez iken $K = 3$ alıcı kullanılarak %100'e yakın doğru



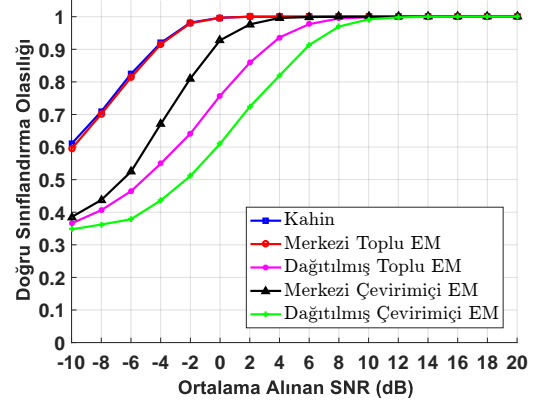
(a) Alıcı Sayısı $K = 1$



(b) Alıcı Sayısı $K = 3$



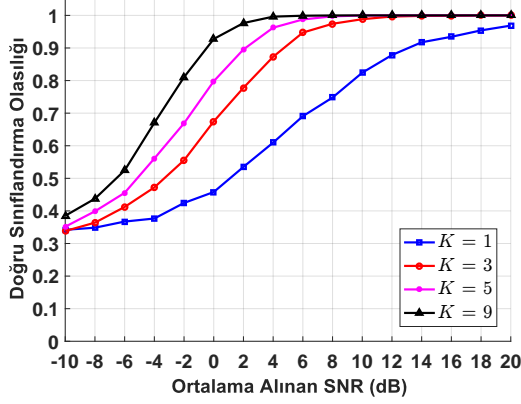
(c) Alıcı Sayısı $K = 5$



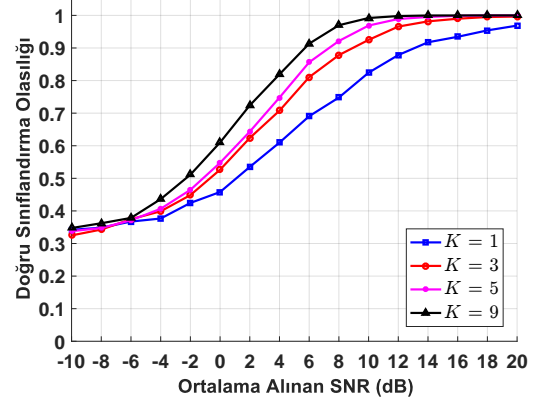
(d) Alıcı Sayısı $K = 9$

Şekil 4.4: Merkezi (siyah) ve dağıtılmış (yeşil) çevirimiçi EM tabanlı kipleme sınıflandırması yöntemlerinin ortalama alınan SNR'a göre doğru sınıflandırma olasılığı grafikleri farklı alıcı sayısı $K \in \{1, 3, 5, 9\}$ için verilmiştir. Ayrıca kahin sınıflandırıcı (mavi) ile toplu EM algoritması tabanlı merkezi (kırmızı) ve dağıtılmış (mor) kipleme sınıflandırması yöntemleri de Şekillere dahil edilmiştir. Aday kipleme türleri: 16-QAM, 32-QAM ve 64-QAM.

sınıflandırma olasılığına 12 dB SNR'da, $K = 9$ alıcı için ise aynı başarımlı seviyesi 4 dB SNR'da elde edilmiştir. Dağıtılmış ve çevrimiçi kipleme sınıflandırması yöntemi ile de benzer şekilde başarımlı iyileşmeleri elde edilmiştir. Alıcı sayısı $K = 1$ için %100'e yakın doğru sınıflandırma olasılığı elde edilememiştir. Alıcı sayısı $K = 3$ olduğunda %100'e yakın doğru sınıflandırma olasılığı 18 dB SNR'da, $K = 9$ için ise 12 SNR'da gözlenmiştir. Merkezi ve dağıtılmış çevrimiçi kipleme sınıflandırması yöntemlerinin $K \in \{1, 3, 5, 9\}$ alıcı sayısı için ortalama alınan SNR değerine karşılık doğru sınıflandırma olasılığı grafikleri sırasıyla Şekil 4.5a ve 4.5b'de verilmiştir. Burada, çevrimiçi sınıflandırıcılar için en belirgin başarımlı artışı alıcı sayısının $K = 1$ 'den $K = 3$ 'e çıkması ile gerçekleşmiştir. Ek olarak, çevrimiçi kipleme sınıflandırıcılar kullanılarak %95, %90, %85 ve %80 doğru sınıflandırma olasılığının elde edilebilmesi için gereken SNR değerleri Çizelge 4.1 ve Çizelge 4.2'de verilmiştir. Şekil 4.4, Çizelge 4.1 ve Çizelge 4.2'de gözlenebileceği üzere önerilen merkezi yöntemde artan alıcı sayısı ile elde edilen başarımlı iyileşmesi dağıtılmış ve çevrimiçi sınıflandırıcıya kıyasla daha yüksek seviyelerdedir. Örnek olarak, 8 dB'de alıcı sayısının $K = 1$ 'den $K = 3$ 'e çıkarılması ile merkezi ve çevrimiçi sınıflandırıcıda doğru sınıflandırma olasılığı %22.6 artarken, dağıtılmış ve çevrimiçi sınıflandırıcının doğru sınıflandırma olasılığı %13 civarında artmaktadır. Benzer şekilde %95 doğru sınıflandırma olasılığının merkezi ve çevrimiçi sınıflandırıcı ile elde edilebilmesi için $K = 1$ alıcı için 18 SNR gerekirken, $K = 3$ alıcı için 7 dB SNR gerekmektedir. Dağıtılmış ve çevrimiçi sınıflandırıcı için ise $K = 3$ alıcı ile 11 dB SNR altında %95 doğru sınıflandırma olasılığı elde edilebilir. Bu fark, çoklu alıcıların kullanılmasıyla elde edilen SNR çeşitliliğinden merkezi yöntemlerde daha verimli faydalanılmasından kaynaklanmaktadır. Dağıtılmış yöntemlerde SNR çeşitliliği sadece sınıflandırma kararı aşamasında kullanılır. Yüksek SNR'a sahip olan alıcıların ve düşük SNR'a sahip alıcıların sınıflandırma kararı üzerindeki etkisi aynıdır. Merkezi yöntemlerde ise farklı SNR'lara sahip alıcılarda elde edilen örnekler merkez düğümde sonsal olasılıkların hesaplanmasında kullanılır. Daha sonra parametre kestirimlerinin yapılmasında bu sonsal olasılıklar kullanılır. Bu sayede, düşük SNR seviyesine sahip alıcıların parametre kestirimlerinde de daha yüksek SNR'a sahip alıcıların etki etmesi ve parametre kestirimlerinin daha isabetli olması sağlanır. Sonuç olarak daha isabetli parametre kestirimleri kullanılarak daha yüksek doğru sınıflandırma olasılıkları elde edilmiştir.



(a) Merkezi



(b) Dağıtılmış

Şekil 4.5: Merkezi ve dağıtılmış çevrimiçi kipleme sınıflandırması yöntemlerinin ortalama alınan SNR'a karşılık doğru sınıflandırma olasılığı grafikleri farklı alıcı sayısı $K \in \{1, 3, 5, 9\}$ için verilmiştir. Aday kipleme türleri: 16-QAM, 32-QAM, 64-QAM.

İstenen doğru sınıflandırma olasılığı

	0.95	0.90	0.85	0.80
$K = 1$	18 dB	13 dB	11 dB	10 dB
$K = 3$	7 dB	5 dB	4 dB	2 dB
$K = 5$	3 dB	2 dB	1 dB	0 dB
$K = 9$	1 dB	0 dB	-1 dB	-2 dB

Çizelge 4.1: Çevrimiçi ve merkezi kipleme sınıflandırması yönteminin belirli bir doğru sınıflandırma olasılığına erişebilmesi için gereken SNR değerleri. Aday kipleme türleri: 16-QAM, 32-QAM, 64-QAM.


İstenen doğru sınıflandırma olasılığı

	0.95	0.90	0.85	0.80
$K = 1$	18 dB	13 dB	11 dB	10 dB
$K = 3$	11 dB	9 dB	7 dB	6 dB
$K = 5$	9 dB	7 dB	6 dB	5 dB
$K = 9$	8 dB	6 dB	5 dB	4 dB


Çizelge 4.2: Çevrimiçi ve dağıtılmış kipleme sınıflandırması yönteminin belirli bir doğru sınıflandırma olasılığına erişebilmesi için gereken SNR değerleri. Aday kipleme türleri: 16-QAM, 32-QAM, 64-QAM.

Bu tez kapsamında önerilen kipleme sınıflandırması yöntemlerinin sınıflandırma başarımlarının daha detaylı incelenebilmesi için aday kipleme türlerine özel koşullu doğru sınıflandırma olasılıkları incelenmiştir. 16-QAM, 32-QAM ve 64-QAM aday kipleme türlerine ait koşullu kipleme sınıflandırması başarımları sırasıyla Şekil 4.6a, Şekil 4.6b ve Şekil 4.6c’de $K = 5$ alıcı için gösterilmiştir. Buna ek olarak merkezi ve dağıtılmış çevrimiçi kipleme sınıflandırması yöntemlerinin karıştırma matrisleri $K = 5$ alıcı için, 0 dB ve 4 dB SNR değerleri için Çizelge 4.3, Çizelge 4.4, Çizelge 4.5 ve Çizelge 4.6’da verilmiştir. Karıştırma matrislerinde, bir aday kipleme türü için 2000 Monte Carlo simülasyonunda her aday kipleme türü lehinde verilen karar sayısı verilmektedir. Örnek olarak, $K = 5$ alıcı için, 0 dB SNR altında 16-QAM kipleme türünün kullanıldığı varsayıldığında merkezi ve çevrimiçi kipleme sınıflandırması yöntemi 2000 Monte Carlo simülasyonunun 1287’sinde 16-QAM, 89’unda 32-QAM ve 624’ünde 64-QAM lehinde karar vermiştir.


Çevrimiçi kipleme sınıflandırması yöntemlerinin 32-QAM kipleme türünün sınıflandırmasında diğer kipleme türlerine göre daha yüksek başarı elde ettikleri gözlenmektedir. Bunun nedeni 32-QAM kipleme türünün yıldız kümesi diyagramının 16-QAM ve 64-QAM türünün yıldız kümesi diyagramlarından farklılık göstermesidir. Bu kipleme türünün sınıflandırılması yanlış yapıldığında, merkezi alıcı ağına sahip yöntemin kararını 64-QAM lehinde, dağıtılmış yöntemin ise kararını 16-QAM kipleme türünün sınıflandırıcı tarafından seçildiği gözlenmiştir.




(a) Doğru kipleme türü: 16-QAM



(b) Doğru kipleme türü: 32-QAM



(c) Doğru kipleme türü: 64-QAM



(d) Ortalama

Şekil 4.6: Önerilen merkezi (siyah) ve dağıtılmış (yeşil) çevrimiçi kipleme sınıflandırması yöntemlerinin 16-QAM, 32-QAM ve 64-QAM kipleme türleri için ortalama alınan SNR'a göre koşullu doğru sınıflandırma olasılığı grafikleri verilmiştir. Alıcı sayısı $K = 5$ olarak belirlenmiştir. Ayrıca kahin sınıflandırıcı (mavi) ile toplu EM algoritması tabanlı merkezi (kırmızı) ve dağıtılmış (mor) kipleme sınıfları yöntemleri de grafiklere dahil edilmiştir.

		Sınıflandırıcının kararı			
		16-QAM	32-QAM	64-QAM	Toplam
Gerçek kiplleme türü	16-QAM	1287	89	624	2000
	32-QAM	27	1856	117	2000
	64-QAM	143	212	1645	2000

Çizelge 4.3: Çevrimiçi ve merkezi kiplleme sınıflandırması yöntemi için karıştırma matrisi. Ortalama alınan SNR 0 dB. Alıcı sayısı: $K = 5$.

		Sınıflandırıcının kararı			
		16-QAM	32-QAM	64-QAM	Toplam
Gerçek kiplleme türü	16-QAM	1869	6	125	2000
	32-QAM	1	1944	55	2000
	64-QAM	11	28	1961	2000

Çizelge 4.4: Çevrimiçi ve merkezi kiplleme sınıflandırması yöntemi için karıştırma matrisi. Ortalama alınan SNR 4 dB. Alıcı sayısı: $K = 5$.

Merkezi ve çevrimiçi kiplleme sınıflandırması yöntemi 16-QAM kiplleme türünün sınıflandırmasında kendisi için en düşük başarı seviyesini elde etmiştir. Çizelge 4.3 ve Çizelge 4.4'ün 16-QAM'e karşılık gelen ilk satırı incelendiğinde, yanlış karar verildiğinde çoğunlukla verilen kararın 64-QAM olduğu gözlenmiştir. Buna karşılık dağıtılmış ve çevrimiçi yöntemde ise 16-QAM kiplleme türü için 32-QAM'den sonraki en iyi ikinci başarı seviyeleri elde edilmiştir. Burada, düşük SNR seviyelerinde (0 dB SNR) yanlış sınıflandırma kararı verildiğinde bu karar çoğunlukla 32-QAM lehinde olurken, orta SNR seviyelerinde (4 dB SNR veya daha yüksek) yanlış kiplleme sınıflandırması kararı genellikle 64-QAM yönünde verilmektedir.

Verici tarafından kullanılan kiplleme türü 64-QAM olarak belirlenirse, dağıtılmış kiplleme sınıflandırması yöntemleri son derece kötü sınıflandırma başarısı elde etmektedir. Yanlış kiplleme kararları, çoğunlukla 32-QAM lehinde verilmektedir. Buna karşılık çevrimiçi ve merkezi yöntem ise 32-QAM'den sonraki en iyi sınıflandırma başarılarını 64-QAM kiplleme türü için gerçekleştirmektedir. Dağıtılmış yöntemle benzer şekilde yanlış kiplleme sınıflandırması kararları 32-QAM lehinde verilmektedir.

		Sınıflandırıcının kararı			
		16-QAM	32-QAM	64-QAM	Toplam
Gerçek kiplleme türü	16-QAM	1054	545	401	2000
	32-QAM	329	1575	96	2000
	64-QAM	628	715	657	2000


Çizelge 4.5: Çevrimiçi ve dağıtılmış kiplleme sınıflandırması yöntemi için karıştırma matrisi. Ortalama alınan SNR 0 dB. Alıcı sayısı: $K = 5$.

		Sınıflandırıcının kararı			
		16-QAM	32-QAM	64-QAM	Toplam
Gerçek kiplleme türü	16-QAM	1248	311	441	2000
	32-QAM	67	1902	31	2000
	64-QAM	257	406	1337	2000


Çizelge 4.6: Çevrimiçi ve dağıtılmış kiplleme sınıflandırması yöntemi için karıştırma matrisi. Ortalama alınan SNR 4 dB. Alıcı sayısı: $K = 5$.

8-PSK, 16-PSK, 8-QAM ve 16-QAM Kiplleme Türleri İçin Başarım İncelemesi


İncelenen yöntemlerin başka bir aday kiplleme türü kümesi varsayıldığında başarımlarındaki değişimlerin gözlenebilmesi için 8-PSK, 16-PSK, 8-QAM ve 16-QAM kullanılarak benzetim çalışmaları tekrar edilmiştir. İncelenen kahin sınıflandırıcı (mavi), merkezi ve toplu EM algoritması tabanlı (kırmızı), dağıtılmış ve toplu EM algoritması tabanlı (mor), çevrimiçi ve merkezi (siyah) ve çevrimiçi ve dağıtılmış (yeşil) kiplleme sınıflandırması yöntemlerinin ortalama alınan SNR'a göre başarımları eğrileri değişen alıcı sayıları $K \in \{1, 3, 5, 9\}$ için sırasıyla Şekil 4.7a, Şekil 4.7b, Şekil 4.7c ve Şekil 4.7d'de gösterilmiştir. İncelenen bütün kiplleme sınıflandırması yöntemlerinin bu aday kiplleme türü kümesi ile her alanda daha iyi başarımlar elde ettikleri gözlenmiştir. Bunun nedeni, 8-QAM ve 16-QAM kiplleme türlerinin yıldız kümesi diyagramının diğer kiplleme türlerine göre farklı olmasından dolayı kiplleme sınıflandırması işleminin kolaylaşması ile açıklanabilir. Bunun dışında bu aday kiplleme türü kümesi için de kahin sınıflandırıcı beklendiği gibi en iyi başarımları elde etmiştir. Önerilen kiplleme türlerinin ikisi için de ortalama alınan SNR'ın artması ile orantılı olarak artan başarımları eğrileri elde edilmiştir.



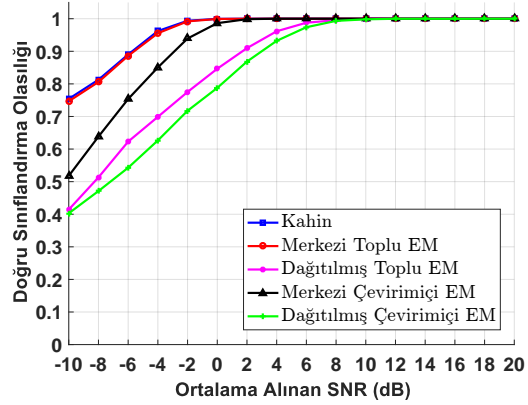
(a) Alıcı sayısı, $K = 1$



(b) Alıcı sayısı, $K = 3$



(c) Alıcı sayısı, $K = 5$



(d) Alıcı sayısı, $K = 9$


Şekil 4.7: Merkezi (siyah) ve dağıtılmış (yeşil) çevrimiçi EM tabanlı kipleme sınıflandırması yöntemlerinin ortalama alınan SNR'a göre doğru sınıflandırma olasılığı grafikleri farklı alıcı sayısı $K \in \{1, 3, 5, 9\}$ için verilmiştir. Ayrıca kahin sınıflandırıcı (mavi) ile toplu EM algoritması tabanlı merkezi (kırmızı) ve dağıtılmış (mor) kipleme sınıflandırması yöntemleri de şekillere dahil edilmiştir. Aday kipleme türleri: 8-PSK, 16PSK, 8-QAM, 16-QAM.

İstenen doğru sınıflandırma olasılığı


	0.95	0.90	0.85	0.80
$K = 1$	14 dB	10 dB	8 dB	6 dB
$K = 3$	4 dB	2 dB	1 dB	-1 dB
$K = 5$	2 dB	0 dB	-2 dB	-3 dB
$K = 9$	-1 dB	-3 dB	-4 dB	-5 dB

Çizelge 4.7: Çevrimiçi ve merkezi kipleme sınıflandırması yönteminin belirli bir doğru sınıflandırma olasılığına erişebilmesi için gereken SNR değerleri. Aday kipleme türleri: 8-PSK, 16-PSK, 8-QAM, 16-QAM.

Bu aday kipleme türleri kümesi için de, incelenen kipleme sınıflandırması yöntemlerinin başarımlarının alıcı sayısının artmasıyla iyileştiği Şekil 4.7’de gözlenmiştir. Çevrimiçi dağıtılmış ve merkezi kipleme sınıflandırması yöntemlerinin farklı alıcı sayıları için ortalama alınan SNR’a göre başarımlar eğrileri sırasıyla Şekil 4.8a ve Şekil 4.8b’de gösterilmiştir. Buna ek olarak, %95, %90, %85 ve %80 doğru sınıflandırma olasılığı için gereken SNR değerleri merkezi ve dağıtılmış yöntemler için sırasıyla Çizelge 4.7 ve Çizelge 4.8’de verilmiştir. Yöntemlerin başarımlar iyileşmeleri çoklu alıcılar kullanarak elde edilen SNR çeşitliliğinden kaynaklanmaktadır. Bir önceki bölümde tartışıldığı üzere en belirgin artışı yine alıcı sayısının $K = 1$ ’den $K = 3$ ’e çıkması ile gözlenmiştir. Bunun nedeni SNR çeşitliliğinin elde edilmesidir. Merkezi sınıflandırıcının artan alıcı sayısı ile elde ettiği başarımlar iyileşmesi dağıtılmış yöntemlere göre daha belirgin düzeydedir. Örnek vermek gerekirse, ortalama alınan SNR’ın 0 dB olduğu durumlarda alıcı sayısının $K = 1$ ’den $K = 3$ ’e çıkmasıyla merkezi ve çevrimiçi sınıflandırıcının doğru sınıflandırma olasılığı %25.9 artarken, dağıtılmış ve çevrimiçi sınıflandırıcı için bu artış %10.4 olarak gerçekleşmiştir. Benzer olarak Çizelge 4.7 ve 4.8 incelendiğinde belirli bir doğru sınıflandırma olasılığı elde edilebilmesi için gereken SNR seviyesinde en belirgin düşüş $K = 1$ ’den $K = 3$ ’e çıktığında gözlenmiştir. Örnek olarak merkezi ve çevrimiçi sınıflandırıcı için %95 doğru sınıflandırma olasılığının elde edilebilmesi için $K = 1$ alıcı için 14 dB SNR gerekirken $K = 3$ alıcı için 4 dB SNR gerekmektedir. Dağıtılmış ve çevrimiçi sınıflandırıcı için ise $K = 3$ alıcı için 8 dB SNR altında %95 doğru sınıflandırma olasılığı elde edilebilmektedir.



(a) Merkezi



(b) Dağıtılmış

Şekil 4.8: Merkezi ve dağıtılmış çevrimiçi kipleme sınıflandırması yöntemlerinin ortalama alınan SNR'a karşılık doğru sınıflandırma olasılığı grafikleri farklı alıcı sayısı $K \in \{1, 3, 5, 9\}$ için verilmiştir. Aday kipleme türleri: 8-PSK, 16-PSK, 8-QAM, 16-QAM.

İstenen doğru sınıflandırma olasılığı

	0.95	0.90	0.85	0.80
$K = 1$	14 dB	10 dB	8 dB	6 dB
$K = 3$	8 dB	6 dB	4 dB	2 dB
$K = 5$	7 dB	5 dB	3 dB	1 dB
$K = 9$	5 dB	3 dB	2 dB	0 dB


Çizelge 4.8: Çevrimiçi ve dağıtılmış kipleme sınıflandırması yönteminin belirli bir doğru sınıflandırma olasılığına erişebilmesi için gereken SNR değerleri. Aday kipleme türleri: 8-PSK, 16-PSK, 8-QAM, 16-QAM.

İncelenen kiplleme sınıflandırması yöntemlerinin bu yeni aday kiplleme türü kümesi ile daha detaylı incelenebilmesi için aday kiplleme türlerine ait koşullu kiplleme sınıflandırması başarımları incelenmiştir. $K = 5$ alıcı sayısı için, 8-PSK, 16-PSK, 8-QAM veya 16-QAM verici tarafından kullanıldığında incelenen kiplleme sınıflandırması yöntemlerinin ortalama alınan SNR'a göre başarımlar eğrileri sırasıyla Şekil 4.9a, Şekil 4.9b, Şekil 4.9c ve Şekil 4.9d'de gösterilmiştir. Ek olarak, $K = 5$ alıcı sayısı ve -4 dB ve 0 dB ortalama alınan SNR değeri için, çevrimiçi kiplleme sınıflandırması yöntemlerinin karıştırma matrisleri Çizelge 4.9, Çizelge 4.10, Çizelge 4.11 ve Çizelge 4.12'de verilmiştir.


Şekil 4.9c ve karıştırma matrisleri incelendiğinde, 8-QAM kiplleme türünün sınıflandırmasının oldukça yüksek kesinlik ile yapılabildiği gözlenmektedir. Bunun nedeni 8-QAM kiplleme türünün yıldız kümesi diyagramının düşük SNR seviyelerinde dahi sınıflandırıcılar tarafından ayrıştırılabilir olmasından kaynaklanmaktadır. Karıştırma matrisleri incelendiğinde, yanlış sınıflandırma kararının belirgin bir kiplleme türü lehinde verilmediği gözlenmektedir.

Çevrimiçi kiplleme sınıflandırması yöntemlerinin 16-QAM kiplleme türünün sınıflandırılmasında, 8-QAM'den sonraki en yüksek başarımlar seviyelerini elde ettikleri gözlenmiştir. Yanlış kiplleme sınıflandırması kararı verildiğinde önerilen iki yöntem için de ağırlıklı olarak 8-PSK ve 16-PSK sınıflandırıcılar tarafından tercih edilmiştir. 8-PSK ve 16-PSK'nın seçilmesi ise yaklaşık olarak aynı olasılığa sahiptir.


8-PSK kiplleme türünün sınıflandırılmasında, merkezi ve dağıtılmış çevrimiçi kiplleme sınıflandırması yöntemleri için, en fazla yanlış sınıflandırma kararı 16-PSK kiplleme türünün seçilmesi ile yapılmıştır. Bunun nedeni 8-PSK ve 16-PSK'nın yıldız kümesi diyagramlarının benzer olmasından kaynaklanmaktadır. Benzer şekilde 16-PSK kiplleme türü kullanıldığında da yanlış sınıflandırma kararları genellikle 8-PSK lehinde verilmektedir. Vericide, 8-PSK kiplleme türü kullanıldığında çevrimiçi ve dağıtılmış sınıflandırıcı için 16-PSK'ya kıyasla daha yüksek doğru sınıflandırma olasılığı elde edilmiştir. Merkezi ve çevrimiçi sınıflandırıcı için ise 16-PSK kiplleme türünün sınıflandırılması daha yüksek kesinlik ile yapılabilmektedir.




(a) Doğru Kipleme Türü: 8-PSK



(b) Doğru Kipleme Türü: 16-PSK



(c) Doğru Kipleme Türü: 8-QAM



(d) Doğru Kipleme Türü: 16-QAM

Şekil 4.9: Önerilen merkezi (siyah) ve dağıtılmış (yeşil) çevrimiçi kipleme sınıflandırması yöntemlerinin 8-PSK, 16-PSK, 8-QAM ve 16-QAM kipleme türleri için ortalama alınan SNR'a göre koşullu doğru sınıflandırma olasılığı grafikleri verilmiştir. Alıcı sayısı $K = 5$ olarak belirlenmiştir. Ayrıca kahin sınıflandırıcı (mavi) ile toplu EM algoritması tabanlı merkezi (kırmızı) ve dağıtılmış (mor) kipleme sınıfları yöntemleri de grafiklere dahil edilmiştir.

		Sınıflandırıcının kararı				
		8-PSK	16-PSK	8-QAM	16-QAM	Toplam
Gerçek kipleme türü	8-PSK	1020	856	8	121	2000
	16-PSK	678	1171	3	148	2000
	8-QAM	7	18	1957	18	2000
	16-QAM	95	78	6	1821	2000

Çizelge 4.9: Çevrimiçi ve merkezi kipleme sınıflandırması yöntemi için karıştırma matrisi. Ortalama alınan SNR -4 dB. Alıcı sayısı: $K = 5$.

		Sınıflandırıcının kararı				
		8-PSK	16-PSK	8-QAM	16-QAM	Toplam
Gerçek kipleme türü	8-PSK	1531	453	1	15	2000
	16-PSK	190	1799	0	11	2000
	8-QAM	0	0	1996	4	2000
	16-QAM	4	7	0	1989	2000

Çizelge 4.10: Çevrimiçi ve merkezi kipleme sınıflandırması yöntemi için karıştırma matrisi. Ortalama alınan SNR 0 dB. Alıcı sayısı: $K = 5$.

		Sınıflandırıcının kararı				
		8-PSK	16-PSK	8-QAM	16-QAM	Toplam
Gerçek kipleme türü	8-PSK	836	594	167	403	2000
	16-PSK	759	627	174	440	2000
	8-QAM	42	36	1877	45	2000
	16-QAM	265	210	223	1302	2000

Çizelge 4.11: Çevrimiçi ve dağıtılmış kipleme sınıflandırması yöntemi için karıştırma matrisi. Ortalama alınan SNR -4 dB. Alıcı sayısı: $K = 5$.

		Sınıflandırıcının kararı				Toplam
		8-PSK	16-PSK	8-QAM	16-QAM	
Gerçek kiplleme türü	8-PSK	1245	586	30	139	2000
	16-PSK	933	921	26	120	2000
	8-QAM	7	8	1979	6	2000
	16-QAM	76	83	40	1801	2000


Çizelge 4.12: Çevrimiçi ve dağıtılmış kiplleme sınıflandırması yöntemi için karıştırma matrisi. Ortalama alınan SNR 0 dB. Alıcı sayısı: $K = 5$.

Önerilen merkezi ve dağıtılmış çevrimiçi kiplleme sınıflandırması yöntemleri için bazı genellemeler uygulanan benzetim çalışmaları sonucunda yapılabilir. İlk olarak, Algoritma 1’de özetlenen merkezi ve çevrimiçi kiplleme sınıflandırması yöntemi eğer aday kiplleme türleri benzer yıldız kümesi diyagramına (Örnek olarak: 16-QAM ve 64-QAM veya 8-PSK ve 16-PSK) sahip ise, yüksek dereceli kiplleme türünü daha yüksek bir oranla ile doğru sınıflandırabilir. Bir diğer gözlem ise dağıtılmış ve çevrimiçi kiplleme sınıflandırması yöntemi, benzer yıldız kümesi diyagramına sahip kiplleme türlerini sınıflandırırken, düşük dereceli kiplleme türünü daha yüksek kesinlik elde edebilmektedir.

4.1.3 Sonsal Olasılıklar Kullanılarak Gönderilen Sembollerin Elde Edilmesi

Çevrimiçi kiplleme sınıflandırması yöntemlerinde, bilinmeyen parametrelerin kestirimlerinin güncellenmesi yeni örneklenen sembollerin sonsal olasılıkları hesaplanılarak yapılır. Bu durumda, sonsal olasılıklar kullanılarak gönderilen semboller de elde edilebilmektedir. Merkezi çevrimiçi kiplleme sınıflandırması yönteminin sonsal olasılıklar kullanılarak elde edilen semboller için sembol hata oranı (Symbol Error Rate) 16-QAM, 32-QAM ve 64-QAM’den oluşan aday kiplleme türü kümesi için Şekil 4.10a’da ve 8-PSK, 16-PSK, 8-QAM ve 16-QAM için Şekil 4.10b’de verilmiştir. Düşük ve orta SNR seviyelerinde yüksek sembol hata oranı iki aday kiplleme türü kümesi için de ortaya çıkmaktadır. Yüksek SNR seviyelerinde ise birden fazla alıcı kullanıldığı durumlarda sembollerin belirlenmesinde de yüksek başarımlar yakalanabilmektedir. Kiplleme sınıflandırması başarımında gözlemlendiği gibi, 8-PSK, 16-PSK, 8-QAM ve 16-QAM’den oluşan aday kiplleme türü kümesi için sembol hata oranı 16-QAM, 32-QAM ve 64-QAM’den oluşan kümeye kıyasla daha düşüktür. Örnek vermek gerekirse $K = 9$ alıcı kullanılarak %1’in altında sembol hata oranı elde edebilmek için, aday

kiplleme türleri 16-QAM, 32-QAM ve 64-QAM ise 12 dB, eğer aday kiplleme türleri 8-PSK, 16-PSK, 8-QAM ve 16-QAM ise 10 dB ortalama alınan SNR deęerine ihtiya duyulmaktadır. Bunun yanında sınıflandırma ile benzer şekilde alıcı sayısı arttıka sembol hata oranı da dūşmektedir. Bunun nedeni de oklu alıcılar kullanılarak elde edilen SNR eşitlilięidir.



(a) Aday kiplleme türleri:

{16-QAM, 32-QAM, 64-QAM}.

(b) Aday kiplleme türleri:


{8-PSK, 16-PSK, 8-QAM, 16-QAM}.

Şekil 4.10: Merkezi ve evrimii kiplleme sınıflandırması yönteminde sonsal olasılıklar kullanılarak elde edilen sembol hata oranı farklı alıcı sayısı $K \in \{1, 3, 5, 9\}$ için verilmiştir.

4.1.4 Bilinmeyen Darbe Biiminin Kiplleme Sınıflandırması Başarımı Üzerindeki Etkisi

Bu bölümde, merkezi ve dağıtılmış evrimii kiplleme sınıflandırması yöntemlerinin başarımları darbe biimi parametrelerinin bilinmedięi durumlarda incelenmiştir. Vericiden gönderilen sinyalin oluşturulmasında izgel etek faktörü $\alpha = 0.3$ olan kök yükseltilmiş kosinüs dalgabiiminin kullanıldığı varsayılmıştır. İzgel etek faktörü alıcılarda bilinmemektedir. Bu nedenle, alıcılara ulaşan sinyallere izgel etek faktörleri $\alpha = 0.1$, $\alpha = 0.3$, $\alpha = 0.5$ ve $\alpha = 0.7$ olan kök yükseltilmiş kosinüs darbe biimleri için uyumlu süzgeler sırasıyla uygulanmıştır. Aday kiplleme türleri 16-QAM, 32-QAM, 64-QAM ve alıcı sayısı $K = 5$ olduęu durumda evrimii kiplleme sınıflandırması yöntemlerinin bilinmeyen izgel etek faktörleri $\alpha \in \{0.1, 0.3, 0.5, 0.7\}$ için başarımlar eğrileri Şekil 4.11a'da gösterilmiştir. 8-PSK, 16-PSK, 8-QAM ve 16-QAM aday kiplleme türlerinin ve alıcı sayısının $K = 5$ olduęu benzetimlerde elde edilen evrimii kiplleme sınıflandırma yöntemlerinin farklı izgel etek faktörlerine $\alpha \in \{0.1, 0.3, 0.5, 0.7\}$ sahip darbebiimleri için ortalama alınan SNR'a karşılık doęru sınıflandırma olasılıęı grafikleri Şekil 4.11b'de verilmiştir. İki aday kiplleme türü kümesi için de

farklı izgel etek faktörünün çevrimiçi yöntemlerin sınıflandırma başarımı üzerindeki etkisinin oldukça düşük düzeyde olduğu gözlenmiştir.



(a) Aday kipleme türleri:

{16-QAM, 32-QAM, 64-QAM}.

(b) Aday kipleme türleri:

{8-PSK, 16-PSK, 8-QAM, 16-QAM}.

Şekil 4.11: Çevrimiçi kipleme sınıflandırma yöntemlerinin farklı izgel etek faktörleri $\alpha \in \{0.1, 0.3, 0.5, 0.7\}$ için ortalama alınan SNR değerine göre doğru sınıflandırma olasılığı verilmiştir. Gerçek izgel etek faktörü: $\alpha = 0.3$. Alıcı sayısı: $K = 5$.


4.1.5 Bilinmeyen Parametrelerin Başlangıç Kestirimlerinin Çevrimiçi Yöntemlerin Başarımı Üzerindeki Etkisi

Bu bölümde, kanal katsayısı parametresinin başlangıç değerinin gerçek değerine uzaklığına göre önerilen kipleme sınıflandırması yöntemlerinin başarımları incelenmiştir. Bu bölüme kadar önerilen yöntemler ile ilgili incelemeler $c = 0.1$ için yapılmıştır. Bu bölümde $c \in \{0.1, 0.2, 0.3, 0.4, 0.5\}$ değerleri için önerilen çevrimiçi kipleme sınıflandırması yöntemlerin başarımları iki farklı aday kipleme türü kümesi için incelenmiştir.


İlk olarak aday kipleme türü kümesinin 16-QAM, 32-QAM ve 64-QAM'den oluştuğu varsayılmıştır. Bu dizi için önerilen merkezi ve dağıtılmış çevrimiçi kipleme sınıflandırması yöntemlerinin ortalama alınan SNR'a göre başarımları eğrisi farklı alıcı sayıları $K \in \{1, 3, 5, 9\}$ ve kontrol parametreleri $c \in \{0.1, 0.2, 0.3, 0.4, 0.5\}$ için sırasıyla Şekil 4.12a, Şekil 4.12b, Şekil 4.12c ve Şekil 4.12d'de verilmiştir. Beklendiği gibi kanal katsayısı kestirimlerinin başlangıç değeri, kanal katsayılarının gerçek değerlerinden uzaklaştıkça önerilen iki yöntemde de başarımları düşüşleri gözlenmektedir. Önerilen yöntemler için alıcı sayısı K arttıkça, kanal katsayısı

parametrelerinin başlangıç noktalarının etkisinde azalmalar gözlenmiştir. Bunun nedeni de alıcı sayısı arttıkça bazı alıcıların başlangıç kestirimlerinin gerçek değere yakın olmasından kaynaklanmaktadır. İyi başlangıç değerlerine sahip alıcılar, gönderilen sembolün sonsal olasılıklarının hesaplanmasında olumlu etki yaparak diğer alıcıların da bilinmeyen kanal katsayısı kestirimlerinin daha sağlıklı yapılabilmesini sağlar. Bu nedenle, her alıcının kendi sonsal olasılıklarını hesapladığı çevrimiçi ve dağıtılmış kipleme sınıflandırması yöntemlerinde, artan alıcı sayısı sınıflandırma başarısını, merkezi alıcı ağını kullanan yöntemle kıyasla daha az geliştirebilmektedir. Bir diğer önemli gözlem ise düşük ortalama alınan SNR seviyelerinde farklı c değerlerinin etkileri yüksek SNR değerlerine kıyasla sınırlı kalmaktadır. Bunun nedeni ise önerilen iki yöntemde de kullanılan EM algoritmasının yakınsama özelliğinden kaynaklanmaktadır. EM ve EM varyantı olan (GEM, ECM) algoritmalar, bir yerel optimum noktaya yakınsamayı garantiler fakat bu yakınsanan noktanın global optimum noktası olup olmadığı bilinmeyen parametrelerin başlangıç değerlerine bağlıdır [11, 28]. Yüksek SNR değerlerinde, yerel optimum noktaları daha belirgindir. Yerel optimum noktaları bastırarak düzeyde bir gürültü olmadığından EM algoritması tabanlı yöntemlerin bir yerel optimum noktaya yakınsaması ihtimali artmaktadır. Düşük SNR değerlerindeki yüksek gürültü, yerel optimum noktalarını yumuşatabildiği için EM algoritması tabanlı parametre kestirimi aşamalarında global optimum noktaya yakınsayabilmiştir.


İkinci olarak 8-PSK, 16-PSK, 8-QAM ve 16-QAM'den oluşan aday kipleme türü kümesi için önerilen yöntemlerin, bilinmeyen kanal katsayısı kestirimlerinin başlangıç değerlerine göre incelenmesi ele alınmıştır. Önerilen merkezi ve dağıtılmış çevrimiçi kipleme sınıflandırması yöntemlerinin ortalama alınan SNR'a göre başarımları eğrileri farklı alıcı sayıları $K \in \{1, 3, 5, 9\}$ ve kontrol parametreleri $c \in \{0.1, 0.2, 0.3, 0.4, 0.5\}$ için sırasıyla Şekil 4.13a, Şekil 4.13b, Şekil 4.13c ve Şekil 4.13d'de verilmiştir. Bu kipleme türü kümesi kullanıldığında, önerilen merkezi ve çevrimiçi yöntemin, değişen c değerlerinden çok daha az etkilendiği gözlenmiştir. Önerilen dağıtılmış ve çevrimiçi kipleme sınıflandırması yöntemi için ise artan c 'nin etkisinin çok daha sınırlı olduğu gözlenmiştir. Bunun nedeni ise 8-PSK, 16-PSK, 8-QAM ve 16-QAM'den oluşan aday kipleme türü kümesinin, 16-QAM, 32-QAM ve 64-QAM'e göre birbirinden daha farklı yıldız kümesi diyagramına sahip olması ile açıklanabilir. Kanal katsayısının gerçek değerinden uzak olduğu durumlarda bile yıldız kümesi diyagramlarının farklılıklarından dolayı sonsal olasılıklar çok daha iyi şekilde hesaplanabilir. Bu nedenle farklı c değerlerinden daha az etkilenmektedir.




(a) Alıcı sayısı, $K = 1$



(b) Alıcı sayısı, $K = 3$




(c) Alıcı sayısı, $K = 5$




(d) Alıcı sayısı, $K = 9$


Şekil 4.12: Merkezi (düz çizgi ile gösterilmiştir) ve dağıtılmış (kesikli çizgi ile gösterilmiştir) çevrimiçi kipleme sınıflandırması yöntemlerinin farklı kontrol parametresi değerleri $c \in \{0.1, 0.2, 0.3, 0.4, 0.5\}$ ve farklı alıcı sayıları $K \in \{1, 3, 5, 9\}$ için ortalama alınan SNR'a göre doğru sınıflandırma olasılığı grafikleri. Aday kipleme türleri: 16-QAM, 32-QAM, 64-QAM.




(a) Alıcı sayısı, $K = 1$



(b) Alıcı sayısı, $K = 3$



(c) Alıcı sayısı, $K = 5$



(d) Alıcı sayısı, $K = 9$

Şekil 4.13: Merkezi (düz çizgi ile gösterilmiştir) ve dağıtılmış (kesikli çizgi ile gösterilmiştir) çevrimiçi kipleme sınıflandırması yöntemlerinin farklı kontrol parametresi değerleri $c \in \{0.1, 0.2, 0.3, 0.4, 0.5\}$ ve farklı alıcı sayıları $K \in \{1, 3, 5, 9\}$ için ortalama alınan SNR'a göre doğru sınıflandırma olasılığı grafikleri. Aday kipleme türleri: 8-PSK, 16-PSK, 8-QAM, 16-QAM.

4.2. PSO ile Toplu Veriden Parametre Kestirimine Dayalı Olabilirlik Tabanlı Sınıflandırıcının Başarım Sonuçları

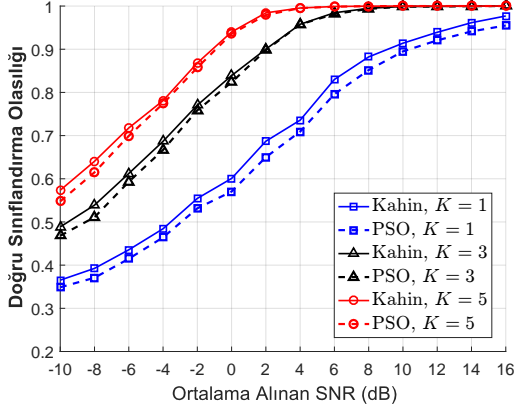
Bu bölümde, önerilen PSO algoritması tabanlı toplu kipleme sınıflandırması yönteminin başarımını 1000 Monte Carlo benzetimi üzerinden incelenmiştir. Bu kipleme sınıflandırması yönteminin başarım incelemesinin yapılabilmesi için aday kipleme türleri kümesinin 8-PSK, 16-PSK, 8-QAM ve 16-QAM'den oluştuğu varsayılmıştır. Parçacıkların başlangıç konumu ile ifade edilen bilinmeyen parametrelerin kestirimlerinin başlangıç değerleri rasgele bir şekilde ayarlanmıştır. Bilinmeyen parametrelerden kanal katsayısı kestirimlerinin başlangıç değerleri

$$\hat{h}_{k,p}^{(\ell),1} = h_k + cz_k \quad (4.7)$$


ile atanmıştır. Burada c kontrol sabiti ve z_k ise bir rasgele değişkendir. z_k 'nin dağılımı gerçek ve sanal kısmı için ayrı ayrı yapılmıştır. Gerçek kısmı $[-\text{Re}\{h_k\}/2, \text{Re}\{h_k\}/2]$ üzerinden birörnek dağılıma sahip olup, sanal kısmı ise $[-\text{Im}\{h_k\}/2, \text{Im}\{h_k\}/2]$ üzerinden birörnek dağılıma sahiptir. z_k 'nin gerçek kısmı ile sanal kısmı birbirinden bağımsızdır. Zaman kayması ise $\hat{\tau}_{k,p}^{(\ell),1} = \tau_k + u_k$ ile başlatılır. Burada u_k , $[-\tau_k/2, \tau_k/2]$ aralığında birörnek dağılıma sahip bir rasgele değişkendir.

Önerilen PSO tabanlı kipleme sınıflandırması yönteminin başarım incelemesi, alıcı sayısı $K \in \{1, 3, 5\}$, kontrol sabiti $c = 1$, gönderilen sembol sayısı $N = 100$ ve parçacık sayısı $P = 20$ için yapılmıştır. Önerilen PSO tabanlı kipleme sınıflandırması yöntemin, ortalama alınan SNR'a göre başarım eğrisi (kırmızı) Şekil 4.14a'da kahin sınıflandırıcı (mavi) ile birlikte verilmiştir. Önerilen yöntemin Kahin sınıflandırıcı ile oldukça yakın başarımlar elde ettiği benzetimler sonucunda gözlenmiştir. Özellikle orta ve yüksek SNR değerleri için neredeyse aynı başarım önerilen PSO tabanlı yöntem ile yakalanabilmektedir. Düşük SNR değerlerinde de sınıflandırıcılar arasındaki fark her zaman %4'ten düşük sonuçlanmaktadır. Kahin sınıflandırıcı ile önerilen PSO tabanlı yöntem arasındaki başarım farkı bilinmeyen parametrelerin kestirimlerinin gerçek değerlerine olan uzaklıklarından kaynaklanmaktadır. Bu durumda bilinmeyen parametrelerin kestirimlerinin gerçek değerlerine oldukça yakın şekilde yapılabildiği söylenebilir.

Önerilen PSO tabanlı kipleme sınıflandırması yönteminin, merkezi ve dağıtılmış toplu EM algoritması tabanlı kipleme sınıflandırması yöntemleri ile $c \in \{1, 2\}$ için karşılaştırılması Şekil 4.14b'de verilmiştir. Bu benzetimlerde, PSO'da kullanılan parçacık sayısı $P = 20$,



(a)



(b)

Şekil 4.14: a) Önerilen PSO tabanlı kipleme sınıflandırması yönteminin (kesikli çizgi ile gösterilmiştir) ve kahin sınıflandırıcının (düz çizgi ile gösterilmiştir) ortalama alınan SNR'a göre başarımlar eğrileri $K \in \{1, 3, 5\}$ için verilmiştir. Parçacık sayısı $P = 20$, kontrol sabiti $c = 1$, gönderilen sembol sayısı $N = 100$ olarak belirlenmiştir. b) Önerilen PSO tabanlı kipleme sınıflandırması yönteminin farklı $c \in \{1, 2\}$ değerleri için ortalama alınan SNR'a göre başarımlar eğrisi verilmiştir. Ayrıca kahin sınıflandırıcının ve diğer EM algoritması tabanlı toplu kipleme sınıflandırması yöntemlerinin başarımlar eğrileri de dahil edilmiştir. Alıcı sayısı $K = 5$, gönderilen sembol sayısı $N = 100$ ve parçacık sayısı $P = 20$ olarak ayarlanmıştır.

toplam alıcı sayısı $K = 5$ ve gönderilen sembol sayısı $N = 100$ olarak ayarlanmıştır. Önerilen yöntem, Eşitlik (4.7)'de verilen ifadede bulunan $c \in \{1, 2\}$ değerlerinden kısıtlı düzeyde etkilenecek bütün SNR değerleri için kahin sınıflandırıcıya oldukça yakın başarımlar elde etmiştir. Bunun yanında, PSO tabanlı önerilen kipleme sınıflandırması yöntemi ile, hem merkezi hem dağıtılmış toplu EM algoritması tabanlı kipleme sınıflandırması yöntemlerine kıyasla daha yüksek doğru sınıflandırma oranı elde edilebildiği gözlenmiştir.

5. SONUÇ

Kiplleme sınıflandırması hem sivil hem de askeri olmak üzere geniş uygulama alanı olan bir konudur. Bu uygulamalarda kiplleme sınıflandırması yöntemlerinin kullanılabilirliğinin artırılması için elverişsiz koşullarda çalışmak üzere tasarlanmış kiplleme sınıflandırması yöntemlerine ihtiyaç vardır. Bu tezde, alıcı ve verici çifti arasında zamanlama referansının sağlanamadığı ve bilinmeyen bir kanal belirsizliği altında çalışabilecek kiplleme sınıflandırması yöntemleri önerilmiştir. Bu yöntemlerde hibrit olabilirlik tabanlı bir yaklaşım benimsenmiştir. Hibrit olabilirlik tabanlı yaklaşımlarda, alıcıya ulaşan sinyalin olabilirlik fonksiyonunun bilinmeyen sembol dizisinin dağılımı üzerinden ortalaması alınır. Ardından ortalama olabilirlik fonksiyonunu enbüyüten bilinmeyen parametre kestirimleri elde edilir. Bu tezde Titterington'ın çevrimiçi EM algoritması kullanılarak parametre kestirimlerinin veriler gelmeye devam ettikçe güncellemelerinin yapılacağı bir yaklaşım kullanılmıştır. Bu yaklaşımda alıcılara ulaşan sinyal zaman kayması parametresinin mevcut kestirimi ile örneklenir. Daha sonra bu örnekler kullanılarak gönderilen sembolün sonsal olasılıkları hesaplanır ve hesaplanan sonsal olasılıklar kullanılarak parametre güncellemeleri yapılır. Alıcılara ulaşan yeni dalgabiciyi güncellenen zaman kayması ile örneklenerek önerilen yöntem devam eder.

Önerilen yöntemlerin çevrimiçi yapısı nedeni ile parametre kestirimlerinin gerçek değere yakınlıkları SNR'a bağlı olarak oldukça değişmektedir. Düşük SNR altında sadece son örnek kullanılarak güncellemeler yapıldığında, sinyalin içerdiği yüksek gürültü nedeni ile parametre kestirimlerinin gerçek değerlerine yakınsaması zorlaşmaktadır. SNR'ın çevrimiçi yöntemler üzerindeki etkisinin düşürülebilmesi için çoklu alıcılar kullanılmıştır. Verici üzerinden gönderilen sembol dizisinin birbirinden bağımsız kanallardan geçerek alıcılara iletildiği varsayıldığında, ortaya çıkan SNR çeşitliliği nedeniyle yöntemlerin başarımları iyileştirilmiştir. Çevrimiçi kiplleme sınıflandırıcılar karar tümleştirme yapıları ile birbirinden ayrılır. Algoritma 1'de özetlenen birinci yöntemde merkezi karar tümleştirme ile alınan örnekler işlenmiştir. Burada alıcılarda elde edilen örnekler bir merkez düğüme gönderilmektedir. Merkez düğümde bütün örnekler kullanılarak gönderilen sembolün sonsal olasılıkları hesaplanır ve bilinmeyen parametrelerin kestirimleri güncellenir. Ardından zaman kayması parametrelerinin güncel değerleri alıcılara iletilir ve önerilen yöntem yeni alınan örnek ile devam eder. Burada alıcılar ile merkez düğüm arasında çift yönlü ve devamlı bir iletişim sağlanması gerekmektedir. Bu gereklilikten kaçınmak için ise dağıtılmış karar tümleştirme yöntemi Al-

goritma 2’de özetlenen yöntemde kullanılmıştır. Dağıtılmış ve çevrimiçi parametre kestiriminde, alıcılara ulaşan dalgabiçimi, mevcut zaman kayması kestirimi ile örneklenir. Alınan örnek kullanılarak sonsal olasılıkların hesaplanması ve bilinmeyen parametrelerin güncellenmesi her alıcıda ayrı olarak gerçekleştirilir. Alıcıya ulaşan yeni sinyalin güncel zaman kayması kestirimi örneklenmesi ile dağıtılmış ve çevrimiçi kipleme sınıflandırması yöntemi devam eder. Bu yöntemde ise sonsal olasılıkların alıcılarda ayrı hesaplanması nedeniyle SNR çeşitliliğinden verimli olarak faydalanılamamaktadır. Bu durum belli bir başarımlı kaybını beraberinde getirmektedir.

Çevrimiçi kipleme sınıflandırması yöntemleri kullanılarak 2.3.2’de anlatılan ve hibrit olabirlik tabanlı kipleme sınıflandırması yöntemlerinde gözlenen hafıza ve işlem yükü sorunları azaltılmıştır. Literatürdeki, zaman uyumsuz kipleme sınıflandırması yöntemlerinin dalgabiçimini sık olarak örneklenmiş şekilde hafızada tutması gerekmektedir. Bu durum alıcı için bir hafıza gereksinimini beraberinde getirir. Ek olarak, bilinmeyen parametrelerinin kestirimlerinin elde edilmesinde dalgabiçiminden alınan bütün örneklerin yinelemeli bir şekilde kullanılması işlem yükünü de artırmaktadır. Bu sorunlar alıcı sayısı ile doğru orantılı olarak artmaktadır. Önerilen yöntemlerde bu sorunlar çevrimiçi parametre kestirimi ile azaltılmıştır. Alıcıya ulaşan bir sembole karşılık gelen dalgabiçimi, bir kez alıcılarda örneklenir ve parametre güncellemeleri bu örnek ile yapılır. Bu sayede, bir sembole karşılık gelen dalgabiçimini sık örneklenmiş olmak hafızaya almak yerine sadece bir kez örneklenmesi yeterli olmaktadır. Yukarıda bahsedildiği üzere parametre güncellemesi için her yinelemede bütün örneklerin kullanılması yerine parametre güncellemeleri sadece son örnek kullanılarak yapıldığı için işlem yükünün de azaltılması sağlanmıştır. Ayrıca, EM algoritması tabanlı sınıflandırıcıların bir sonucu olarak, sonsal olasılıklar kullanılarak gönderilen sembol dizisi de elde edilebilmektedir.

Bu tez kapsamında geliştirilen çevrimiçi sınıflandırıcıların başarımları farklı aday kipleme türleri kümeleri için benzetim çalışmaları ile incelenmiştir. Benzetimlerde farklı ortalama alınan SNR seviyeleri, alıcı sayıları, bilinmeyen dalga biçimi etkisi ve parametre kestirimlerinin başlangıç değerlerinin gerçek değerlerine uzaklıklarına göre doğru sınıflandırma olasılığındaki değişimler gözlenmiştir. Çevrimiçi sınıflandırıcılar birden fazla alıcının kullanıldığı durumlarda orta ve yüksek SNR seviyelerinde %100’e yakın doğru sınıflandırma olasılığına ulaşabilmektedir. Sınıflandırıcıların daha düşük başarımlar elde ettikleri 16-QAM, 32-QAM ve 64-QAM’den oluşan aday kipleme türü kullanıldığı durumlarda dahi $K = 5$

alıcı için merkezi ve çevrimiçi sınıflandırıcı 8 dB’de, dağıtılmış ve çevrimiçi sınıflandırıcı ise 14 dB’de %100 doğru sınıflandırma olasılığına erişebilmektedir. Benzetim çalışmalarında dağıtılmış sınıflandırıcılar kullanılarak belli bir doğru sınıflandırma oranını yakalayabilmek için merkezi sınıflandırıcılara kıyasla daha yüksek SNR değerlerine ihtiyaç duyulduğu gözlenmiştir. Yüksek SNR seviyelerinde, çevrimiçi sınıflandırıcıların başarımlarının toplu veriden parametre kestirime dayanan sınıflandırıcılara ve kahin sınıflandırıcıya denk olduğu gözlenmiştir. Azalan hafıza gereksinimleri ve işlem yükü düşünüldüğünde bu SNR seviyelerinde çevrimiçi kipleme sınıflandırması yöntemlerinin uygulanabilirliği artmaktadır. Önerilen çevrimiçi yöntemlerin sınıflandırma başarımı izgel etek faktörü bilinmeyen kök yükseltilmiş kosinüs darbe biçimleri için incelenmiştir ve belirgin başarımların kayıpları gözlenmemiştir. Çevrimiçi ve merkezi sınıflandırıcının yüksek alıcı sayısı ve yüksek SNR değerleri için doğru sınıflandırma kararı verebilmelerinin yanısıra gönderilen sembollerin de doğru biçimde elde edilebildiği gözlenmiştir. Örneğin, alıcı sayısı $K = 5$ olduğu durumlarda 14 dB altında sembol hata oranının %1’in altında olduğu gözlenmiştir. Bunlara karşılık, çevrimiçi sınıflandırıcıların bilinmeyen parametrelerin başlangıç kestirimlerinden ciddi oranda etkilendiği gözlenmiştir. Bu durum, EM algoritmasından kaynaklanmaktadır. Kestirimi yapılmak istenen parametrelerin başlangıç değerlerinin bilinmeyen parametrelerin gerçek değerlerinden uzaklaştığı durumlarda EM algoritması yerel optimum noktalara yakınsayabilmektedir. Çevrimiçi sınıflandırıcılar kullanılarak yüksek başarımlar elde edilebilmesi için iyi başlangıç değerlerinin sağlanması gerekmektedir.

Önerilen çevrimiçi kipleme sınıflandırıcılara ek olarak toplu verinin kullanıldığı bir zaman uyumsuz kipleme sınıflandırması yöntemi daha önerilmiştir. Bu yöntemde, hibrit olabilirlik tabanlı yaklaşım benimsenmiş ve parametre kestirimi için PSO algoritması kullanılmıştır. PSO tabanlı zaman uyumsuz kipleme sınıflandırması için parametre kestirimi Algoritma 3’te özetlenmiştir. Burada alıcılarda sık biçimde örneklenmiş dalgabiçiminin merkez düğümüne gönderildiği varsayılmıştır. Daha sonra alıcılar için mevcut zaman kayması kestirimleri ile sık olarak örneklenmiş dalgabiçiminden sembol sayısı kadar örnek alınmıştır. Bu örnekler kullanılarak parametre kestirimleri yinelemeli bir şekilde gerçekleştirilmiştir. Parametre kestirimlerinin ardından, sınıflandırma kararı hibrit olabilirlik tabanlı sınıflandırıcı kullanılarak verilmiştir.

PSO tabanlı kipleme sınıflandırma yönteminin başarımı farklı SNR seviyeleri, alıcı sayıları ve bilinmeyen parametrelerin başlangıç kestirimleri için incelenmiştir. Benzetim çalış-

malarında kahin sınıflandırıcıya yakın başarımları elde edilebilmiştir. Buna ek olarak merkezi ve dağıtılmış toplu EM algoritması tabanlı sınıflandırıcılardan daha yüksek başarımları elde edilebildiği de gözlenmiştir. Fakat PSO kullanılarak parametre kestirimlerinin yapılması yüksek hafıza gereksinimini ve işlem yükünü beraberinde getirmektedir. İlk olarak dalgabıçımının her parçacığa ait zaman kayması kestirimleri ile örneklenmesi nedeniyle hafıza gereksinimleri parçacık sayısı ile doğru orantılı olarak artmaktadır. Bunun yanında alınan örnekler kullanılarak parametre kestirimlerinin her parçacık için yapılması bir yinelemedeki işlem yükünü parçacık sayısı ile paralel olarak artırmaktadır.

Gelecek çalışmalarda, zaman uyumsuzluğun yanı sıra frekans uyumsuzluğu altında çalışabilen kipleme sınıflandırması yöntemleri geliştirilebilir. Bundan farklı olarak, bilinmeyen parametrelerin gerçek değerlerinin zamanla değiştiği durumlarda önerilen çevrimiçi kipleme sınıflandırması yöntemlerinin başarımları incelenebilir. Son olarak, bilinmeyen parametrelerin kestirimlerinin başlangıç değerlerinin atanabilmesi için yöntemler geliştirilebilir.

KAYNAKLAR

- [1] Z. Zhu and A. K. Nandi, *Automatic modulation classification: principles, algorithms and applications*. John Wiley & Sons, 2015.
- [2] O. A. Dobre, A. Abdi, Y. Bar-Ness, and W. Su, “Survey of automatic modulation classification techniques: classical approaches and new trends,” *IET Commun.*, vol. 1, pp. 137–156, Apr. 2007.
- [3] A. Swami and B. M. Sadler, “Hierarchical digital modulation classification using cumulants,” *IEEE Trans. Commun.*, vol. 48, pp. 416–429, Mar. 2000.
- [4] Q. Shi, Y. Gong, and Y. L. Guan, “Asynchronous classification of high-order QAMs,” in *Proc. IEEE Wirel. Commun. Netw. Conf. (WCNC)*, pp. 1188–1193, 31 Mar-3 Apr, 2008.
- [5] W. C. Headley and C. R. C. M. da Silva, “Asynchronous classification of digital amplitude-phase modulated signals in flat-fading channels,” *IEEE Trans. Commun.*, vol. 59, pp. 7–12, Jan. 2011.
- [6] V. G. Chavali and C. R. C. M. da Silva, “Maximum-likelihood classification of digital amplitude-phase modulated signals in flat fading non-Gaussian channels,” *IEEE Trans. Commun.*, vol. 59, pp. 2051–2056, Aug. 2011.
- [7] O. Ozdemir, R. Li, and P. K. Varshney, “Hybrid maximum likelihood modulation classification using multiple radios,” *IEEE Commun. Lett.*, vol. 17, pp. 1889–1892, Oct. 2013.
- [8] Z. Zhu and A. K. Nandi, “Blind modulation classification for MIMO systems using Expectation-Maximization,” in *Proc. IEEE Mil. Commun. Conf. (MILCOM)*, pp. 754–759, Oct 2014.
- [9] Z. Zhu and A. K. Nandi, “Modulation classification in MIMO fading channels via expectation maximization with non-data-aided initialization,” in *Proc. IEEE Int. Conf. Aco. Spe. Sig. Proc. (ICASSP)*, pp. 3014–3018, April 2015.

- [10] B. Dulek, O. Ozdemir, P. K. Varshney, and W. Su, "Distributed maximum likelihood classification of linear modulations over nonidentical flat block-fading Gaussian channels," *IEEE Trans. Wirel. Commun.*, vol. 14, pp. 724–737, Feb. 2015.
- [11] O. Ozdemir, T. Wimalajeewa, B. Dulek, P. K. Varshney, and W. Su, "Asynchronous linear modulation classification with multiple sensors via generalized EM algorithm," *IEEE Trans. Wirel. Commun.*, vol. 14, pp. 6389–6400, Nov 2015.
- [12] T. Wimalajeewa, J. Jagannath, P. K. Varshney, A. Drozd, and W. Su, "Distributed asynchronous modulation classification based on hybrid maximum likelihood approach," in *Proc. IEEE Mil. Commun. Conf. (MILCOM)*, pp. 1519–1523, IEEE, 2015.
- [13] P. Liu, X.-J. Ji, and G.-Q. Zhao, "Asynchronous classification of digital modulations in multipath flat-fading channel using fourth-order cumulant," in *Int. Conf. Signal Process. (ICSP)*, pp. 1435–1439, IEEE, 2016.
- [14] B. Dulek, "Online hybrid likelihood based modulation classification using multiple sensors," *IEEE Trans. Wirel. Commun.*, vol. 16, no. 8, pp. 4984–5000, 2017.
- [15] B. Dulek, "An online and distributed approach for modulation classification using wireless sensor networks," *IEEE Sensors J.*, vol. 17, no. 6, pp. 1781–1787, 2017.
- [16] Z. Yu, Y. Q. Shi, and W. Su, "M-ary frequency shift keying signal classification based on discrete Fourier transform," in *Proc. IEEE Mil. Commun. Conf. (MILCOM)*, vol. 2, pp. 1167–1172, IEEE, 2003.
- [17] P. C. Sapiano, J. Martin, and R. Holbeche, "Classification of PSK signals using the DFT of phase histogram," in *Proc. IEEE Int. Conf. Aco. Spe. Sig. Proc. (ICASSP)*, vol. 3, pp. 1868–1871, IEEE, 1995.
- [18] L. Hong and K. Ho, "Identification of digital modulation types using the wavelet transform," in *Proc. IEEE Mil. Commun. Conf. (MILCOM)*, vol. 1, pp. 427–431, IEEE, 1999.
- [19] K. Hassan, I. Dayoub, W. Hamouda, and M. Berbineau, "Automatic modulation recognition using wavelet transform and neural networks in wireless systems," *EURASIP J. Adv. Signal Process.*, vol. 2010, no. 1, p. 532898, 2010.

- [20] A. K. Nandi and E. E. Azzouz, "Algorithms for automatic modulation recognition of communication signals," *IEEE Trans. Commun.*, vol. 46, no. 4, pp. 431–436, 1998.
- [21] C.-S. Park, J.-H. Choi, S.-P. Nah, W. Jang, and D. Y. Kim, "Automatic modulation recognition of digital signals using wavelet features and SVM," in *Int. Conf. Advanced Commun. Technol.*, vol. 1, pp. 387–390, IEEE, 2008.
- [22] L.-X. Wang, Y.-J. Ren, and R.-H. Zhang, "Algorithm of digital modulation recognition based on support vector machines," in *Proc. IEEE Int. Conf. on Mach. Learn. Cybern.*, vol. 2, pp. 980–983, IEEE, 2009.
- [23] L. Hong and K. Ho, "Classification of BPSK and QPSK signals with unknown signal level using the Bayes technique," in *Proc. IEEE Int. Symp. Circuits Syst.*, vol. 4, pp. IV–IV, IEEE, 2003.
- [24] P. Panagiotou, A. Anastasopoulos, and A. Polydoros, "Likelihood ratio tests for modulation classification," in *Proc. IEEE Mil. Commun. Conf. (MILCOM)*, vol. 2, pp. 670–674, 2000.
- [25] O. A. D. F. Hameed and D. C. Popescu, "On the likelihood-based approach to modulation classification," *IEEE Trans. Wirel. Commun.*, vol. 8, pp. 5884–5892, Dec. 2009.
- [26] N. E. Lay and A. Polydoros, "Per-survivor processing for channel acquisition, data detection and modulation classification," in *Proc. Asilomar Conf. Sig., Sys. Comp.*, vol. 2, pp. 1169–1173, 31 Oct-2 Nov 1994.
- [27] A. P. Dempster, N. M. Laird, and D. B. Rubin, "Maximum likelihood from incomplete data via the EM algorithm," *J. Royal Stat. Soc. B*, vol. 39, no. 1, pp. 1–38, 1977.
- [28] J. A. Bilmes, "A gentle tutorial of the EM algorithm and its application to parameter estimation for Gaussian mixture and hidden Markov models," *Int. Computer Science Inst.*, vol. 4, no. 510, p. 126, 1998.
- [29] M. A. T. Figueiredo and A. Jain, "Unsupervised learning of finite mixture models," *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 24, pp. 381–396, Mar. 2002.
- [30] C. M. Bishop, *Pattern recognition and machine learning*. Springer, 2006.

- [31] R. Horaud, F. Forbes, M. Yguel, G. Dewaele, and J. Zhang, “Rigid and articulated point registration with expectation conditional maximization,” *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 33, no. 3, pp. 587–602, 2010.
- [32] K. Lange, “A gradient algorithm locally equivalent to the EM algorithm,” *J. R. Statist. Soc. B*, vol. 57, no. 2, pp. 425–437, 1995.
- [33] A. Van Den Bos, “Complex gradient and hessian,” *IEE Proc. Vision, Image and Signal Process.*, vol. 141, pp. 380–383, Dec 1994.
- [34] O. Cappe and E. Moulines, “On-line expectation-maximization algorithm for latent data models,” *J. R. Statist. Soc. B*, vol. 71, no. 3, pp. 593–613, 2009.
- [35] D. M. Titterton, “Recursive parameter estimation using incomplete data,” *J. R. Statist. Soc. B*, vol. 46, pp. 257–267, 1984.
- [36] J. G. Proakis, *Digital Communications*. New York: McGraw-Hill, 4 ed., 2001.
- [37] M. Oerder and H. Meyr, “Digital filter and square timing recovery,” *IEEE Trans. Commun.*, vol. 36, no. 5, pp. 605–612, 1988.
- [38] V. G. Chavali and C. R. C. M. da Silva, “Classification of digital amplitude-phase modulated signals in time-correlated non-Gaussian channels,” *IEEE Trans. Commun.*, vol. 61, pp. 2408–2419, June 2013.
- [39] S. Wang and Y. Zhao, “Almost sure convergence of Titterton’s recursive estimator for mixture models,” *Statist. Probab. Lett.*, vol. 76, no. 18, pp. 2001–2006, 2006.
- [40] B. T. Polyak and A. B. Juditsky, “Acceleration of stochastic approximation by averaging,” *SIAM J. Cont. Optim.*, vol. 30, no. 4, pp. 838–855, 1992.
- [41] D. Ruppert, “Efficient estimations from a slowly convergent Robbins-Monro process,” tech. rep., School of Operations Research and Industrial Engineering, Cornell University, Ithaca, 1988.
- [42] R. Eberhart and J. Kennedy, “A new optimizer using particle swarm theory,” in *Proc. 6th Int. Symp. Micromachine Human Sci.*, (Nagoya, Japan), pp. 39–43, Oct, 1995.

EKLER

EK 1 - Tezden Türetilmiş Yayınlar

E. Efendi and B. Dulek, "Automatic classification of linear modulations using multiple receivers in the presence of symbol timing uncertainty.", *Electron. Lett.*, 2019.

DOI: 10.1049/el.2019.0915



HACETTEPE ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
YÜKSEK LİSANS/DOKTORA TEZ ÇALIŞMASI ORJİNALLİK RAPORU

HACETTEPE ÜNİVERSİTESİ
FEN BİLİMLER ENSTİTÜSÜ
ELEKTRİK VE ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI BAŞKANLIĞI'NA

Tarih: 10/07/2019

Tez Başlığı: Çoklu Alıcılar Kullanarak Çevrimiçi ve Zaman Uyumsuz Doğrusal Kipleme Sınıflandırması

Yukarıda başlığı gösterilen tez çalışmamın a) Kapak sayfası, b) Giriş, c) Ana bölümler d) Sonuç kısımlarından oluşan toplam 76 sayfalık kısmına ilişkin, 10/07/2019 tarihinde tez danışmanım tarafından *Turnitin* adlı intihal tespit programından aşağıda belirtilen filtrelemeler uygulanarak alınmış olan orijinallik raporuna göre, tezimin benzerlik oranı % 4'tür.

Uygulanan filtrelemeler:

- 1- Kaynakça hariç
- 2- Alıntılar hariç
- 3- 5 kelimededen daha az örtüşme içeren metin kısımları hariç

Hacettepe Üniversitesi Fen Bilimleri Enstitüsü Tez Çalışması Orjinallik Raporu Alınması ve Kullanılması Uygulama Esasları'nı inceledim ve bu Uygulama Esasları'nda belirtilen azami benzerlik oranlarına göre tez çalışmamın herhangi bir intihal içermediğini; aksinin tespit edileceği muhtemel durumda doğabilecek her türlü hukuki sorumluluğu kabul ettiğimi ve yukarıda vermiş olduğum bilgilerin doğru olduğunu beyan ederim.

Gereğini saygılarımla arz ederim.

Tarih ve İmza

Adı Soyadı: Emre Efendi
Öğrenci No: N16124342
Anabilim Dalı: Elektrik ve Elektronik Mühendisliği
Programı: Tezli Yüksek Lisans
Statüsü: Y.Lisans Doktora Bütünleşik Dr.

10/07/2019

DANIŞMAN ONAYI

UYGUNDUR.

(Doç. Dr. Berkan Dülek)

ÖZGEÇMİŞ

Kimlik Bilgileri

Adı Soyadı : Emre Efendi
Doğum Yeri : Söke/Aydın
Doğum Tarihi : 25.10.1991
Medeni Hali : Bekar
Yazışma Adresi : Kavaklıdere Mah. Bardacık Sok. No: 8/8
Çankaya, Ankara
Telefon : 0554 433 4309
Elektronik Posta Adresi : eefendi@ee.hacettepe.edu.tr
Yabancı dili : İngilizce

Eğitim Durumu

Lisans : Hacettepe Üniversitesi, Elektrik ve Elektronik Mühendisliği
Bölümü Ankara (2010 - 2016)
Yüksek Lisans : Hacettepe Üniversitesi, Elektrik ve Elektronik Mühendisliği
Bölümü Ankara (2016 - ...)
Doktora : -

İş Tecrübesi

2017 - ... : Araştırma Görevlisi, Hacettepe Üniversitesi Elektrik ve
Elektronik Mühendisliği Bölümü, Ankara.