T.C.
KAYSERİ ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

# KURTOSİS MALİYET FONKSİYONU TABANLI KOMPLEKS DEĞERLİ İŞBİRLİKÇİ ADAPTİF FİLTRELEME

**Hazırlayan**
**Buket ÇOLAK GÜVENÇ**

**Danışman**
**Doç. Dr. Engin Cemal MENGÜÇ**

**Yüksek Lisans Tezi**

**Aralık 2021**
**KAYSERİ**

**T.C.**
**KAYSERİ ÜNİVERSİTESİ**
**LİSANÜSTÜ EĞİTİM ENSTİTÜSÜ**
**ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI**

# KURTOSİS MALİYET FONKSİYONU TABANLI KOMPLEKS DEĞERLİ İŞBİRLİKÇİ ADAPTİF FİLTRELEME

**(Yüksek Lisans Tezi)**

**Hazırlayan**
**Buket ÇOLAK GÜVENÇ**

**Danışman**
**Doç. Dr. Engin Cemal MENGÜÇ**

**Aralık 2021**
**KAYSERİ**

# BİLİMSEL ETİĞE UYGUNLUK

Bu tezin kendi çalışmam olduğunu, planlanmasından yazımına kadar hiçbir aşamasında etik dışı davranışımın olmadığını, tezdeki bütün bilgileri akademik ve etik kurallar içinde elde ettiğimi, tez çalışmasıyla elde edilmeyen bütün bilgi ve yorumlara kaynak gösterdiğimi ve bu kaynakları kaynaklar listesine aldığımı, tez çalışması ve yazımı sırasında patent ve telif haklarını ihlal edici bir davranışımın olmadığını beyan ederim.

Buket ÇOLAK GÜVENÇ

**T.C.**

**KAYSERİ ÜNİVERSİTESİ**

**Lisansüstü Eğitim Enstitüsü Müdürlüğü**

Anabilim Dalı : Elektrik-Elektronik Mühendisliği

Program Adı : Yüksek Lisans

Tez Başlığı : Kurtosis Maliyet Fonksiyonu Tabanlı Kompleks Değerli İşbirlikçi Adaptif Filtreleme

Yukarıda bilgileri verilen tez çalışmasının a) Giriş, b) Ana bölümler ve c) Sonuç kısımlarından oluşan (Kapak, Önsöz, Özet, İçindekiler ve Kaynakça hariç) toplam 72 sayfalık kısmına ilişkin 15/12/2021 tarihinde ***Turnitin*** intihal programından aşağıda belirtilen filtreleme uygulanarak alınmış olan özgünlük raporuna göre tezin benzerlik oranı**: % 10'** dır. Uygulanan filtrelemeler:

1- Giriş dahil
2- Ana Bölümler dahil
3- Sonuç dahil
4- Alıntılar dahil
5- Kapak hariç
6- Önsöz ve Teşekkür hariç
7- İçindekiler hariç
8- Kaynakça hariç
9- Özet hariç
10- Yedi (7) kelimeden daha az örtüşme içeren metin kısımları hariç

Kayseri Üniversitesi Lisansüstü Eğitim Enstitüsü Tez Önerisi Hazırlama, Tez Yazma ve Teslim Yönergesini inceledim ve bu yönergede belirtilen azami benzerlik oranlarına göre tez çalışmamın herhangi bir intihal içermediğini, aksinin tespit edileceği muhtemel durumlarda doğabilecek her türlü hukuki sorumluluğu kabul ettiğimi ve yukarıda vermiş olduğum bilgilerin doğru olduğunu beyan ederim.

Gereğini bilgilerinize arz ederim. 15/12/2021

**Hazırlayan** **Danışman**

Buket ÇOLAK GÜVENÇ Doç. Dr. Engin Cemal MENGÜÇ

## YÖNERGEYE UYGUNLUK

**“Kurtosis Maliyet Fonksiyonu Tabanlı Kompleks Değerli İşbirlikçi Adaptif Filtreleme”** adlı Yüksek Lisans Tezi, Kayseri Üniversitesi Lisansüstü Tez Önerisi ve Tez Yazma Yönergesi’ne uygun olarak hazırlanmıştır.

| **Hazırlayan** | **Danışman** |
| --- | --- |
| Buket ÇOLAK GÜVENÇ | Doç. Dr. Engin Cemal MENGÜÇ |

**Elektrik-Elektronik Mühendisliği ABD Başkanı**

Doç. Dr. Engin Cemal MENGÜÇ

# TEŞEKKÜR

Tez çalışmam boyunca, bilgi ve tecrübelerini benden esirgemeyen, iyi bir çalışma yapmam için elinden geleni yapan, kıymetli yol göstericiliği ve emeklerinden dolayı danışmanım sayın Doç. Dr. Engin Cemal MENGÜÇ'e teşekkürlerimi bir borç bilirim.

Bursiyeri olduğum, 121E324 kodlu TÜBİTAK 3501 Kariyer Geliştirme Programı kapsamındaki "Büyük Veri Akışları İçin Çevrimiçi Sansürleme Stratejisi Tabanlı Yeni Kompleks-Değerli Adaptif Sinyal İşleme Tekniklerinin Geliştirilmesi" isimli projenin sağladığı destek için teşekkür ederim.

Ayrıca, her koşulda en iyisini yapan, beni bugünlere getiren ilham kaynağım anneme; hayatım boyunca desteğini hissettiğim babama ve kardeşlerime sonsuz teşekkür ederim.

Son olarak, girdiğimiz bütün yollarda, gösterdiği sabır ve anlayışla yaptığı eşsiz yol arkadaşlığı için eşim Kemal GÜVENÇ'e teşekkür ederim.

Buket ÇOLAK GÜVENÇ

Kayseri, Aralık 2021

**KURTOSİS MALİYET FONKSİYONU TABANLI KOMPLEKS DEĞERLİ İŞBİRLİKÇİ ADAPTİF FİLTRELEME**

**Buket ÇOLAK GÜVENÇ**

**Kayseri Üniversitesi, Lisansüstü Eğitim Enstitüsü**
**Yüksek Lisans Tezi, Aralık 2021**
**Danışman: Doç. Dr. Engin Cemal MENGÜÇ**

# ÖZET

Bu tez çalışmasında, dairesel ve dairesel olmayan kompleks değerli sinyalleri etkili bir şekilde işlemek için CLMK ve ACLMK algoritmalarının bireysel avantajlarından faydalanarak iş birlikçi bir şekilde çalışabilen yeni bir adaptif konveks kombinasyon (ACC) önerilmiştir. Bu amaçla, ilk önce kompleks düzlemdeki genel hata sinyalinin kurtosisine dayalı maliyet fonksiyonu tanımlanmıştır ve ardından önerilen ACC'nin karıştırma parametresi güncelleme kuralını türetmek için maliyet fonksiyonu minimize edilmiştir. Önerilen ACC algoritması yeni karıştırma parametresi güncelleme kuralının yardımıyla, yakınsama oranı ve kararlı durum hatası açısından genel filtreleme başarımını iyileştirmek için filtrenin genel çıkışında, çalışma ortamının gereksinimine göre CLMK veya ACLMK'yı adaptif bir şekilde baskın hale getirmiştir. Ayrıca, önerilen ACC'deki karıştırma parametresinin değişimi, ele alınan sinyal veya sistemin karakteristik davranışı hakkında da bilgi vermiştir. İlk kez bu tez çalışmasında, adım büyüklüğü sınırını belirlemek için önerilen ACC'nin karıştırma parametresi güncelleme kuralının Lyapunov anlamında kararlılığı analiz edilmiştir. Öte yandan CLMK ve ACLMK algoritmalarının Lyapunov anlamındaki kararlılığı literatürde hala eksik olduğundan bu tez çalışması kapsamında bahsi geçen algoritmaların Lyapunov analizleri de detaylı olarak sunulmuştur. Kompleks düzlemdeki sistem tanımlama ve bir-adım-ileri tahmin senaryolarına ilişkin kapsamlı benzetimler, önerilen ACC'nin hem bu bahsedilen avantajlarını hem de geleneksel ACC'ye göre üstün başarımını desteklemiştir.

**Anahtar Kelimeler:** Adaptif dışbükey kombinasyon, Dairesel ve dairesel olmayan kompleks değerli sinyaller, En az ortalama kurtosis, Karıştırma parametresi, Lyapunov kararlılığı.

**COMPLEX-VALUED COLLABORATIVE ADAPTIVE FILTER BASED ON KURTOSIS COST FUNCTION**

**Buket ÇOLAK GÜVENÇ**

**Kayseri University, Institute of Graduate Education**
**Master Thesis, December 2021**
**Supervisor: Assoc. Prof. Dr. Engin Cemal MENGÜÇ**

# ABSTRACT

This thesis introduces a novel adaptive convex combination (ACC) of the complex-valued least mean Kurtosis (CLMK) and augmented CLMK (ACLMK) algorithms by inspiring their individual advantages to effectively process circular and noncircular complex-valued signals. For this purpose, the negated kurtosis-based cost function of the overall error signal in the complex domain is primarily defined and then is minimized to obtain the update rule of the mixing parameter for the proposed ACC. By iteratively updating the mixing parameter based on the mentioned Kurtosis cost function, the proposed ACC adaptively dominates the CLMK or ACLMK at its overall output according to the requirements of the filter operating environments in order to improve the overall filtering performance in terms of the convergence rate and steady-state error. The evoluation of the mixing parameter in the proposed ACC also gives information about the characteristic behavior of the considered signal or system. Moreover, for the first time in this thesis, the stability of the mixing parameter update rule of the proposed ACC is theoretically analyzed in the sense of Lyapunov to derive the step size bound. On the other hand, since the analyzes of the CLMK and ACLMK algorithms in the sense of Lyapunov are still missing in the literature, in the scope of this thesis, their Lyapunov analyses are also provided in detail. The comprehensive simulations on system identification and one-step ahead prediction scenarios in the complex domain support both the mentioned elegant properties of the proposed ACC and its superior performance over the existing ACC.

**Keywords:** Adaptive convex combination, Circular and noncircular complex-valued signals, Least mean kurtosis, Mixing parameter, Lyapunov stability.

# İÇİNDEKİLER

## KURTOSİS MALİYET FONKSİYONU TABANLI KOMPLEKS DEĞERLİ İŞBİRLİKÇİ ADAPTİF FİLTRELEME

BİLİMSEL ETİĞE UYGUNLUK ..... ii
TEZ İNTİHAL RAPORU TESLİM FORMU ..... iii
YÖNERGEYE UYGUNLUK ..... iv
KABUL VE ONAY ..... v
TEŞEKKÜR ..... vii
ÖZET ..... viii
ABSTRACT ..... viiii
İÇİNDEKİLER ..... ix
KISALTMALAR ..... xii
TABLOLAR LİSTESİ ..... xiii
ŞEKİLLER LİSTESİ ..... xiiii
GİRİŞ ..... 1

## BİRİNCİ BÖLÜM

## MATEMATİKSEL YÖNTEMLER VE KOMPLEKS DEĞERLİ GELENEKSEL ADAPTİF FİLTRELEME ALGORİTMALARI

1.1. ℂℝ Analiz (ℂℝ Calculus) ..... 5
1.2. Artırılmış İstatistik (Augmented Statistics) ..... 6
1.3. Lyapunov Kararlılık Teorisi ..... 8
1.4. CLMS Algoritması ..... 8
1.5. ACLMS Algoritması ..... 10
1.6. Geleneksel Adaptif Dışbükey Kombinasyon ..... 11
1.7. CLMK Algoritması ..... 13
1.8. ACLMK Algoritması ..... 15

## İKİNCİ BÖLÜM

## CLMK VE ACLMK ALGORİTMALARININ LYAPUNOV KARARLILIK ANALİZLERİ

2.1. CLMK Algoritmasının Lyapunov Kararlılık Analizi ..... 18
2.2. ACLMK Algoritmasının Lyapunov Kararlılık Analizi..... 20

## ÜÇÜNCÜ BÖLÜM

## ÖNERİLEN ADAPTİF KONVEKS KOMBİNASYON

3.1. Önerilen Adaptif Konveks Kombinasyonunun Tasarımı..... 22
3.2. Önerilen Karıştırma Parametresi Güncelleme Kuralının Lyapunov Kararlılık Analizi……25

## DÖRDÜNCÜ BÖLÜM

## BENZETİM SONUÇLARI

4.1. Sistem Tanımlama Senaryoları ..... 29
4.2.Tahmin Senaryoları..... 39

## BEŞİNCİ BÖLÜM

## SONUÇ

Sonuç……..…….48

KAYNAKÇA..... 51

ÖZGEÇMİŞ ..... 56

TEZ İNTİHAL RAPORU……58

# KISALTMALAR

| | |
|---|---|
| **LMS** | En Küçük Ortalama Kare (Least Mean Square) |
| **CLMS** | Kompleks değerli En Küçük Ortalama Kare (Complex-valued Least Mean Square) |
| **ACLMS** | Artırılmış Kompleks değerli En Küçük Ortalama Kare **(**Augmented Complex-valued Least Mean Square) |
| **LMK** | En Küçük Ortalama Kurtosis (Least Mean Kurtosis) |
| **CLMK** | Kompleks değerli En Küçük Ortalama Kurtosis (Complex-valued Least Mean Kurtosis) |
| **ACLMK** | Artırılmış Kompleks değerli En Küçük Ortalama Kurtosis (Augmented Complex-valued Least Mean Kurtosis) |
| **SL** | Kesin Lineer (Strictly Linear) |
| **WL** | Geniş Lineer (Widely Linear) |
| **ACC** | Adaptif Konveks Kombinasyon (Adaptive Convex Combination) |
| **MA** | Hareketli Ortalama (Moving Average) |
| **PDF** | Olasılık Yoğunluk Fonksiyonu (Probability Density Function) |
| **CRLS** | Kompleks değerli Özyinelemeli En Küçük Ortalama Kareler (Complex-valued Recursive Least Mean Squares) |

# TABLOLAR LİSTESİ

**Tablo 1.1.** *CLMS Algoritmasının Sözde Kodu*……...9

**Tablo 1.2.** *ACLMS Algoritmasının Sözde Kodu*……..10

**Tablo 1.3.** *Geleneksel ACC Yapısının Sözde Kodu*……..…...13

**Tablo 1.4.** *CLMK Algoritmasının Sözde Kodu*……...…15

**Tablo 1.5.** *ACLMK Algoritmasının Sözde Kodu*……...……..17

**Tablo 3.1.** *Önerilen ACC Algoritmasının Sözde Kodu*……...…...….25

**Tablo 4.1.** *SNR= 20 dB'de sistem tanımlama senaryoları için tüm algoritmaların ortalaması alınmış kararlı durum MSE değerleri*……..…….37

**Tablo 4.2.** *SNR= 10 dB'de sistem tanımlama senaryoları için tüm algoritmaların ortalaması alınmış kararlı durum MSE değerleri*…….....37

**Tablo 4.3.** *Tahmin Senaryoları 1, 2 ve 3 için Önerilen ACC'nin Standart Tahmin Kazanımları* $R_p$ *(dB)*……...…...48

# ŞEKİLLER LİSTESİ

**Şekil 1.1.** *Geleneksel ACC yapısı* .....11
**Şekil 3.1.** *Önerilen ACC yapısı*.....22
**Şekil 4.1.** *Senaryo 1 için önerilen ACC'nin SNR=20 dB'de (a) MSE (dB) eğrisi ve (b) karıştırma parametresi değişimi* .....31
**Şekil 4.2.** *Senaryo 1 için önerilen ACC'nin SNR=10 dB'de (a) MSE (dB) eğrisi ve (b) karıştırma parametresi değişimi*……...32
**Şekil 4.3.** *Senaryo 2 için önerilen ACC'nin SNR=20 dB'de (a) MSE (dB) eğrisi ve (b) karıştırma parametresi değişimi*……...33
**Şekil 4.4.** *Senaryo 2 için önerilen ACC'nin SNR=10 dB'de (a) MSE (dB) eğrisi ve (b) karıştırma parametresi değişimi*……...34
**Şekil 4.5.** *Senaryo 3 için önerilen ACC'nin SNR=20 dB'de (a) MSE (dB) eğrisi ve (b) karıştırma parametresi değişimi*……...35
**Şekil 4.6.** *Senaryo 3 için önerilen ACC'nin SNR=10 dB'de (a) MSE (dB) eğrisi ve (b) karıştırma parametresi değişimi*……...36
**Şekil 4.7.** *Tahmin senaryolarında kullanılan kompleks değerli sinyallerin geometrik görünümleri (a) AR(4) (b) Ikeda (c) Tremor sinyali 1 (d) Tremor sinyali 2* ……43
**Şekil 4.8.** *Senaryo 1 için önerilen ACC'nin (a) MSE (dB) eğrisi ve (b) karıştırma parametresi değişimi*……44
**Şekil 4.9.** *Senaryo 2 için önerilen ACC'nin (a) MSE (dB) eğrisi ve (b) karıştırma parametresi değişimi*……45
**Şekil 4.10.** *El Titreme Sinyali 1 için önerilen ACC'nin (a) MSE (dB) eğrisi ve (b) karıştırma parametresi değişimi*……..……46
**Şekil 4.11.** *El Titreme Sinyali 2 için önerilen ACC'nin (a) MSE (dB) eğrisi ve (b) karıştırma parametresi değişimi*……....……47

# GİRİŞ

Günümüzde modern bilgi kaynakları sürekli sinyaller ürettiğinden, bu sinyallerin işleme prosedürü, geçmiş veriler kullanılmadan *katı zaman kısıtlamaları altında anlık* gerçekleştirilmedir. Bu gereksinim, adaptif sinyal işlemenin temel yapı taşı olan akan verileri işleme yeteneğine sahip adaptif filtreleme tarafından karşılanır [1]-[3]. Pratik uygulamalarda genellikle reel ve kompleks değerli olmak üzere iki tür sinyal tipiyle karşılaşılır [4]. Reel değerli sinyaller sadece genlik bilgisi içerirken, radar, rüzgar, sonar vb. gibi kompleks değerli sinyaller hem genlik hem de faz bilgisi içerir [4]. Bununla birlikte, geleneksel adaptif filtreleme, genellikle kaynak bilgisi olarak sinyalin genliğini kullanır ve kompleks değerli sinyallere doğrudan uygulanamaz [4]. Bu nedenle, kompleks değerli sinyaller son zamanlarda adaptif filtrelemenin yeniden gözden geçirilmesinin yolunu açmıştır. Kompleks değerli sinyaller bazı önemli istatistiksel özelliklere sahiptir ve bu istatiksel özelliklerine göre dairesel veya dairesel olmayan sinyaller olarak tanımlanırlar [4]-[10]. Örneğin; bir sinyal, belirli bir rotasyon altında istatistiksel dağılımı değişmiyorsa dairesel; aksi halde dairesel olmayan sinyal olarak adlandırılır [4]-[10]. Bu tanımlar, kompleks istatistiklerin altında yatan ana fikri oluşturur. Bu tür sinyalleri adaptif olarak işlemek için, adaptif filtreleme algoritmalarının reel düzlemden kompleks düzleme genişletilmesi gerekir [4].

Bu bağlamda, ilk kompleks değerli adaptif filtreleme algoritması, Widrow ve diğerleri tarafından önerilen kompleks değerli en küçük ortalama kare (complex-valued least mean square, CLMS) algoritmasıdır [11]. Aslında, CLMS algoritması [11] reel değerli en küçük ortalama karenin (least mean square, LMS) tüm özelliklerini kompleks düzleme taşır. Örneğin, LMS'ye benzer şekilde, CLMS algoritması basit bir yapıya sahiptir ve giriş sinyalinin oto-korelasyon matrisinin (auto-correlation matrix) özdeğerlerine bağlı olması nedeniyle yakınsama hızı yavaştır [1], [3], [12]. Bir diğer kompleks değerli adaptif filtreleme algoritması, CLMS algoritmasına kıyasla hızlı yakınsama yeteneğine sahip olan kompleks değerli özyinelemeli en küçük kareler (complex-valued recursive least

mean squares, CRLS) algoritmasıdır [1]. Bu algoritma, matris tersi alma işleminden kaynaklanan hesaplama yükü dezavantajına sahiptir [1].

Bahsedilen bu kompleks değerli adaptif filtreleme algoritmaları aynı zamanda kesin lineer (strictly linear, SL) algoritmaları olarak da literatürde bilinmektedir. Bu algoritmaların ortak özellikleri; ikinci-dereceden istatistiksel bilgi olarak sadece kovaryans matrisi $\mathbf{C}_{\mathbf{xx}} = E\{\mathbf{x}\mathbf{x}^H\}$ bilgisini kullanması ve sadece dairesel sinyaller için optimal çözümler sağlamasıdır, burada $\mathbf{x}$, $H$ ve $E$ sıfır ortalama kompleks değerli rastgele vektörü, eşlenik devriği ve beklenen değeri sırasıyla temsil eder [3]-[5], [7], [9], [10]. Bununla birlikte, çoğu gerçek dünya uygulamasında, dairesel olmayan kompleks değerli sinyallerle de karşılaşılır [3]-[5], [9]. Bu nedenle, kompleks düzlemde bir adaptif filtreleme algoritması geliştirirken dairesel olmayan kompleks değerli sinyaller de dikkate alınmalıdır. Artırılmış istatistikler üzerine yapılan son çalışmalar, tek başına kovaryans matrisi $\mathbf{C}_{\mathbf{xx}}$'in kullanılmasının, kompleks değerli rastgele $\mathbf{x}$ vektörünün tüm ikinci-dereceden istatistiksel özelliklerini elde etmek için yeterli olmadığını göstermiştir ve bu çalışmalar, kompleks değerli dairesel olmayan sinyalleri analiz etmek için sözde kovaryans matrisi $\mathbf{P}_{\mathbf{xx}} = E\{\mathbf{x}\mathbf{x}^T\}$'in de dikkate alınması gerektiğini ispatlamıştır [3]-[5], [9].

Bu amaçla, artırılmış kompleks değerli $\mathbf{x}$ vektörü öncelikle $\mathbf{x}^a = [\mathbf{x}^T, \mathbf{x}^H]^T$ olarak tanımlanır ve daha sonra $\mathbf{x}$'e ait hem kovaryans hem de sözde kovaryans matrisleri, artırılmış kovaryans matrisi $\mathbf{C}_{\mathbf{x}^a\mathbf{x}^a} = E\{\mathbf{x}^a\mathbf{x}^{aH}\}$ içerisine yerleştirilir. Bu durumda, eğer $\mathbf{P}_{\mathbf{xx}} = \mathbf{0}$ ise $\mathbf{x}$ vektörü bir düzgün/ikinci-dereceden dairesel vektördür; aksi taktirde, düzgün olmayan/dairesel olmayan vektördür [3]-[5], [9]. Artırılmış istatistiklerin yardımıyla, artırılmış kompleks değerli adaptif filtreleme algoritmaları son zamanlarda hem dairesel hem de dairesel olmayan kompleks değerli sinyalleri işlemek için tasarlanmıştır. Aynı zamanda bu algoritmalara, geniş lineer (widely linear, WL) tabanlı adaptif filtreleme algoritmaları da denir [3]-[5], [13]-[20]. Artırılmış CLMS (augmented CLMS, ACLMS), CLMS algoritması ile aynı avantajlara sahip olmasından dolayı WL algoritmaları arasında en popüler olanıdır. ACLMS algoritması, dairesel olmayan kompleks değerli sinyaller için CLMS algoritmasından daha iyi bir başarım gösterirken, aynı kararlı durum hatasına CLMS'den daha yavaş yakınsar [4], [20]. Bu yavaş yakınsamanın ana nedeni, ACLMS algoritmasının WL yapısı nedeniyle CLMS

algoritmasından iki kat daha fazla hesaplama yüküne sahip olmasıdır [4], [20]. Bu gereksinimleri karşılamak için, literatürde [4], [13], [21], CLMS ve ACLMS algoritmalarının bireysel avantajlarını bir araya getiren, hem dairesel hem de dairesel olmayan kompleks değerli sinyalleri verimli bir şekilde işleyen geleneksel adaptif konveks kombinasyon (adaptive convex combination, ACC) önerilmiştir. Geleneksel ACC yapısı [4], [13], yakınsama hızı ve kararlı durum hatası açısından üstün başarım göstermesine rağmen, CLMS ve ACLMS algoritmalarının giriş sinyalinin özdeğerlerine bağımlılığından kaynaklanan yavaş yakınsamadan hala muzdariptir.

Son zamanlarda literatürde, CLMS [11], ACLMS [4] ve bunların geleneksel ACC versiyonunun [4], [13] bahsedilen problemlerini gidermek için, kompleks değerli en küçük ortalama kurtosis (complex-valued least mean kurtosis, CLMK) ve artırılmış CLMK (augmented CLMK, ACLMK) algoritmaları, Mengüç ve Acır tarafından sırasıyla [22] ve [20]'de yer alan çalışmalarda önerilmiştir. CLMK, ACLMK ve diğer versiyonları, çok çeşitli gürültü sinyallerine karşı güçlü gürbüzlükleri, üstün yakınsama ve kararlı durum başarımları nedeniyle, kompleks değerli adaptif sinyal işleme alanında [20], [22]-[28], [34] (özellikle sistem tanımlama, asenkron motorun parametre kestirimi, üç fazlı güç sistemlerinin frekans kestirimi, gerçek dünya sinyallerinin bir-adım-ileri tahmini, lineer olmayan adaptif filtreleme vb.) büyük ilgi görmüştür. Bunun nedeni, CLMK ve ACLMK algoritmalarının, Tanrıkulu ve Constantinides tarafından reel düzlem için önerilen en küçük ortalama kurtosis (least mean kurtosis, LMK) algoritmasına benzer şekilde; maliyet fonksiyonu olarak anlık karesi alınmış hata sinyali yerine kompleks düzlemde tanımlanan hata sinyalinin kurtosisini minimize etmesidir [29]. Bu maliyet fonksiyonu, CLMK ve ACLMK algoritmalarının, sıfır ortalamalı Gauss ortamları için sistem uyumsuzluğundan, ölçüm gürültü sinyalini ayırmasını ve Gauss olmayan gürültü sinyalleri için bile CLMS ve ACLMS algoritmalarından daha üstün bir başarım göstermesini sağlar [20], [27], [29]-[34]. Bununla birlikte, CLMS ve ACLMS algoritmalarına benzer şekilde, ACLMK algoritması dairesel olmayan kompleks değerli sinyaller için CLMK algoritmasından daha iyi başarım gösterirken, WL yapısı nedeniyle aynı kararlı durum hatasına CLMK'dan daha yavaş yakınsar [20].

Bu tez çalışmasında, dairesel ve dairesel olmayan kompleks değerli sinyalleri etkili bir şekilde işlemek için CLMK [22] ve ACLMK [20] algoritmalarının bireysel avantajlarından faydalanarak iş birlikçi şekilde çalışabilen yeni bir adaptif konveks

kombinasyonu (ACC) önerilmiştir. Bu amaçla, ilk önce kompleks düzlemdeki genel hata sinyalinin kurtosisine dayalı maliyet fonksiyonu tanımlanmıştır ve ardından önerilen ACC'nin karıştırma parametresi güncelleme kuralını türetmek için bu maliyet fonksiyonu minimize edilmiştir. Bu sayede, önerilen ACC, CLMK ve ACLMK algoritmalarını iş birlikçi bir şekilde çalışmasını sağlamıştır. Önerilen ACC, yeni karıştırma parametresi güncelleme kuralı yardımıyla, yakınsama oranı ve kararlı durum hatası açısından genel filtreleme başarımını iyileştirmek için filtrenin genel çıkışında çalışma ortamlarının gereksinimlerine göre CLMK veya ACLMK'yı adaptif bir şekilde baskın hale getirmiştir. Aynı zamanda, önerilen ACC'deki karıştırma parametresinin değişimi, ele alınan sinyal veya sistemin karakteristik davranışı hakkında önemli bilgiler verir. Örneğin karıştırma parametresi; dairesel sinyaller veya bilinmeyen SL sistemler için bir değerine yakınsarken, dairesel olmayan sinyaller veya bilinmeyen WL sistemler için sıfır değerine yakınsamıştır. Tüm bunlara ek olarak, ilk kez bu tez çalışmasında, adım büyüklüğü sınırını belirlemek için önerilen ACC'nin karıştırma parametresi güncelleme kuralının Lyapunov anlamında kararlılığı teorik olarak analiz edilmiştir. Öte yandan CLMK ve ACLMK algoritmalarının Lyapunov anlamındaki kararlılığı literatürde hala eksik olduğundan bu çalışma kapsamında bu algoritmaların Lyapunov analizleri de detaylı olarak sunulmuştur. Önerilen ACC'nin başarımı üç farklı sistem tanımlama ve üç farklı bir-adım-ileri tahmin senaryoları üzerinde kapsamlı bir şekilde yapılan benzetimler ile incelenmiştir. Yapılan benzetimler, önerilen ACC'nin hem belirtilen özelliklerini hem de [13]'te önerilen geleneksel ACC'ye göre üstün başarımını açıkça ortaya koymuştur.

Bu tez çalışmasının kısaca organizasyonundan bahsedilecek olursa: birinci bölümde önerilen algoritmanın tasarım sürecinde kullanılan matematiksel yöntemler ve kompleks değerli geleneksel adaptif filtreleme algoritmaları detaylı bir şekilde verilmiştir. İkinci bölümde, CLMK ve ACLMK algoritmalarının Lyapunov kararlık analizleri ilk defa bu tez çalışmasında ayrıntıları ile sunulmuştur. Üçüncü bölümde, CLMK ve ACLMK algortimalarının adaptif konveks kombinasyonu (ACC) önerilmiş ve ardından, bu ACC'ye ait önerilen karıştırma parametresi güncelleme kuralının Lyapunov kararlılık analizi yapılmıştır. Son olarak dördüncü bölümde, ACC algoritmasının başarımı, sistem tanımlama ve bir-adım-ileri tahmin senaryoları üzerinde kapsamlı bir şekilde değerlendirilmiştir.

# BİRİNCİ BÖLÜM

# MATEMATİKSEL YÖNTEMLER VE KOMPLEKS DEĞERLİ GELENEKSEL ADAPTİF FİLTRELEME ALGORİTMALARI

Bu bölümde; bu tez çalışmasında önerilen algoritmanın tasarım sürecinde kullanılan matematiksel yöntemler; sırasıyla $\mathbb{CR}$ analiz, artırılmış istatistik ve Lyapunov kararlılık teorisinden bahsedildikten sonra kompleks değerli geleneksel adaptif filtreleme algoritmaları olan CLMS, ACLMS, CLMK ve ACLMK algoritmaları detaylı bir şekilde sunulmuştur.

## 1.1. $\mathbb{CR}$ Analiz ($\mathbb{CR}$ Calculus)

$\mathbb{CR}$ analiz, holomorf olmayan kompleks değişkenli reel değerli fonksiyonların türevinin alınması için literatürde sıklıkla kullanılan bir yöntemdir. $\mathbb{CR}$ analizin daha iyi anlaşılması için holomorf fonksiyon kavramının tanıtılması gerekmektedir. Çünkü holomorf fonksiyonlar, kompleks düzlemde yapılan matematiksel analizlerin temel araçlarından biridir. Eğer bir fonksiyon, kompleks düzlem $\mathbb{C}$'de tanımlı açık alt kümesi $U$'nun her bir noktasında kompleks anlamda türevi alınabiliyorsa ve aldığı değerler yine $\mathbb{C}$ kompleks düzlem içinde yer alıyorsa holomorftur. Holomorf fonksiyonlar, sonsuz kere türevlenebilir ve Taylor serisi ile tanımlanabilir.

Eğer $f(z) = u(x, y) + jv(x, y), \quad f(z) : \mathbb{C} \to \mathbb{C}$ kompleks fonksiyonu, bir holomorf fonksiyon ise $u$ ve $v$'nin $x$ ve $y$'ye göre birinci-dereceden kısmi türevleri mevcuttur ve bu kısmi türevler aşağıdaki Cauchy-Riemann şartlarını sağlar [4], [42].

$$\frac{\partial u}{\partial x} = \frac{\partial v}{\partial y} \tag{1.1}$$

$$\frac{\partial u}{\partial y} = -\frac{\partial v}{\partial x} \tag{1.2}$$

Yukarıdaki Cauchy-Riemann şartlarını; kompleks değişkenler tarafından tanımlanan reel değerli fonksiyonlar yani holomorf olmayan fonksiyonlar sağlamaz. Bu sorunun üstesinden gelebilmek için, Wirtinger hesabı olarak da bilinen $\mathbb{CR}$ hesabı, reel değerli fonksiyonların kompleks değişkenlere göre türevini almak için matematiksel bir çerçeve sağlar. Hem $z$ hem de $z^*$'ye bağlı olan herhangi bir reel veya kompleks değerli fonksiyona uygulanabilir. Böylece, karmaşık değişkenlerin reel değerli bir fonksiyonu $f = f(z, z^*)$ için $\mathbb{R}$-türevi aşağıdaki gibi tanımlanır [4], [42]:

$$\left.\frac{\partial f}{\partial z}\right|_{z^*=\text{sabit}} = \frac{1}{2}\left(\frac{\partial f}{\partial z_r} - j\frac{\partial f}{\partial z_i}\right) \tag{1.3}$$

Benzer şekilde, $f = f(z, z^*)$ fonksiyonunun eşlenik $\mathbb{R}$-türevi ($\mathbb{R}^*$-türevi) aşağıdaki gibi tanımlanır:

$$\left.\frac{\partial f}{\partial z^*}\right|_{z=\text{sabit}} = \frac{1}{2}\left(\frac{\partial f}{\partial z_r} + j\frac{\partial f}{\partial z_i}\right) \tag{1.4}$$

Denklem (1.3.)'te tanımlanan $\mathbb{R}$-türevi, holomorf kompleks değerli fonksiyonlar için standart $\mathbb{C}$-türevine eşdeğerdir, (1.4.)'te tanımlanan eşlenik $\mathbb{R}$-türevi ise hem $z$ hem de $z^*$'ye bağlı olan gerçek değerli fonksiyonların türevlerini almak için kullanılır [4], [42].

### 1.2. Artırılmış İstatistik (Augmented Statistics)

Bu bölümde, tez çalışmasının daha iyi anlaşılabilmesi için artırılmış istatistikten bahsedilmiştir. Bir kompleks değerli rastgele vektöre ait ikinci dereceden istatiksel bilgilere ulaşabilmek için hem kovaryans hem de sözde-kovaryans matrislerinin birlikte incelenmesi gerekir.

Sıfır ortalamaya sahip bir kompleks değerli rastgele $\mathbf{x} \in \mathbb{C}^{Nx1}$ vektörü için her iki kovaryans matrisi aşağıdaki gibi tanımlanabilir [4]:

$$\mathbf{C}_{\mathbf{xx}} = E[\mathbf{x}\mathbf{x}^H] \tag{1.5}$$

$$\mathbf{P}_{\mathbf{xx}} = E[\mathbf{x}\mathbf{x}^T] \tag{1.6}$$

burada $\mathbf{C}_{\mathbf{xx}}$ ve $\mathbf{P}_{\mathbf{xx}}$, sırasıyla kovaryans ve sözde kovaryans matrislerini temsil eder. Kovaryans matrisi $\mathbf{C}_{\mathbf{xx}}$, kompleks düzlemdeki $\mathbf{x}$'in ikinci dereceden istatistiklerini tam olarak tanımlamak için yeterli değildir. Çünkü dairesel olmayan kompleks değerli sinyaller için $\mathbf{P}_{\mathbf{xx}} \neq 0$'dır. Bu yüzden, sözde kovaryans matris $\mathbf{P}_{\mathbf{xx}}$'in dikkate alınması gerekir. Bu bağlamda, hem $\mathbf{x}$ hem de $\mathbf{x}^*$'de doğrusal olan $\mathbf{x}$'in tüm ikinci dereceden istatistiksel özelliklerini dikkate alan WL model kullanılır [4]:

$$y = \mathbf{x}^T\mathbf{h} + \mathbf{x}^H\mathbf{g} \tag{1.7}$$

burada $y$, $\mathbf{h}$ ve $\mathbf{g}$ sırasıyla çıkışı, standart ve eşlenik ağırlık vektörlerini temsil eder. Ayrıca burada, $\mathbf{g} = 0$ olduğunda, (1.8) dairesel sinyaller için SL model olur:

$$y = \mathbf{x}^T\mathbf{h}. \tag{1.8}$$

Ardından, artırılmış kompleks değerli giriş vektörü $\mathbf{x}^a = [\mathbf{x}^T \mathbf{x}^H]^T \in \mathbb{C}^{2Nx1}$ kullanılarak, $\mathbf{x}$'in kovaryans ve sözde kovaryans matrislerinden elde edilen ikinci dereceden istatistiksel bilgiler, artırılmış kovaryans matrisi $\mathbf{C}_{\mathbf{x}^a\mathbf{x}^a} \in \mathbb{C}^{2Nx2N}$ içerisine aşağıdaki gibi yerleştirilir:

$$\mathbf{C}_{\mathbf{x}^a\mathbf{x}^a} = E[\mathbf{x}^a\mathbf{x}^{aH}] = \begin{bmatrix} \mathbf{C}_{\mathbf{xx}} & \mathbf{P}_{\mathbf{xx}} \\ \mathbf{P}^*_{\mathbf{xx}} & \mathbf{C}^*_{\mathbf{xx}} \end{bmatrix} \tag{1.9}$$

burada $\mathbf{P}_{\mathbf{xx}} = \mathbf{0}$ ise, $\mathbf{x}$ vektörü ikinci dereceden daireseldir, yani bu vektörün olasılık yoğunluk fonksiyonu kompleks düzlemdeki herhangi bir rotasyon altında değişmezdir. Ancak, gerçek dünya uygulamalarında, kompleks değerli sinyaller genellikle dairesel değildir ve bunların olasılık yoğunluk fonksiyonları (Probability Density Function, PDF) rotasyon altında değişime uğrarlar.

### 1.3. Lyapunov Kararlılık Teorisi

$x_k = 0$ herhangi bir dinamik sistemin denge noktası olarak düşünüldüğünde, $V(x_k)$, $x_k = 0$'i içeren $D \subset \mathbb{R}^n$ alanında bir fonksiyondur. Bu duruma göre, aşağıdaki koşullar mevcut olabilir [35], [41]:

**i)** $V(0) = 0$ için $x_k = 0$

**ii)** $V(x_k) > 0$ için $x_k \neq 0$

**iii)** $\Delta V_k = V(x_{k+1}) - V(x_k) \leq 0$ için $x_k \neq 0$

Yukarıdaki koşullar göz önüne alındığında Birinci ve ikinci koşullar sağlanırsa $V(x_k)$, *aday Lyapunov fonksiyonu* olarak tanımlanır. Tüm koşullar sağlanırsa, dikkate alınan sistemin çözümü *Lyapunov anlamında kararlıdır*. Ayrıca sistem, ilk iki koşulun yanı sıra $\nabla V(x_k) < 0$ koşulunu da sağlıyorsa, asimptotik kararlı olarak adlandırılabilir.

### 1.4. CLMS Algoritması

CLMS algoritması; Widrow ve diğerleri tarafından 1975'te geliştirilen SL tabanlı bir algoritmadır. Aslında bu algoritma, LMS algoritmasının kompleks-değerli uzantısıdır ve basit hesap yükü, kolay uygulama ve kararlılık gibi avantajlarından dolayı kompleks değerli sinyallerin işlenmesinde literatürde sıklıkla kullanılmaktadır. CLMS algoritması ağırlık vektörünü adaptif olarak güncellemeyi ve denklem (1.10)'daki $J_k$ maliyet fonksiyonunu en aza indirmeyi amaçlamaktadır [4], [11]:

$$J_{1,k} = \frac{1}{2} E\left\{\left|e_{1,k}\right|^2\right\} = \frac{1}{2} E\left\{e_{1,k} e_{1,k}^*\right\} \tag{1.10}$$

burada $e_k$ hata sinyalidir ve aşağıdaki gibi tanımlanır.

$$e_{1,k} = d_k - y_{1,k} \tag{1.11}$$

burada $d_k$ ve $y_k$ ise sırasıyla beklenen sinyal ve filtre çıkışını temsil eder.

Sonlu dürtü yanıtlı (Finite Impulse Response, FIR) filtre yapısı göz önüne alındığında, CLMS algoritması için SL model tabanlı filtrenin çıkışı şu şekilde tanımlanabilir:

$$y_{1,k} = \mathbf{x}_k^T \mathbf{w}_k \tag{1.12}$$

burada $\mathbf{w}_k \in \mathbb{C}^{Nx1}$ ağırlık vektörünü temsil eder.

Maliyet fonksiyonu $J_{1,k}$'nın ağırlık vektörü $\mathbf{w}_{1,k}$'ya göre minimizasyonundan, CLMS algoritmasının güncelleme kuralı aşağıdaki formda elde edilir:

$$\mathbf{w}_{k+1} = \mathbf{w}_k + \mu_1 e_{1,k}^* \mathbf{x}_k \tag{1.13}$$

burada $\mu_1$ ve $\mathbf{x}_k = \left[x_k, ..., x_{k-N+1}\right] \in \mathbb{C}^{Nx1}$ sırasıyla adım büyüklüğü parametresi ve giriş vektörüdür. CLMS algoritması, yalnızca ikinci-dereceden istatistiksel özellikleri içerir ve sadece kovaryans matrisi $\mathbf{C}_{\mathbf{xx}} = E\{\mathbf{x}_k \mathbf{x}_k^H\}$ bilgisini kullanarak dairesel kompleks değerli sinyaller için en uygun çözümü sunmaktadır, burada, $(\bullet)^H$ ve $E\{\bullet\}$ sırasıyla eşlenik transpoz ve beklenen değerdir. Bu algoritma, kompleks değerli dairesel sinyallerin işlenmesinde kendisinin WL versiyonuna kıyasla daha hızlı bir yakınsama dinamiği sergilemektedir. CLMS algoritması, yapısında tüm ikinci dereceden istatistiksel özellikleri içermediğinden, kompleks değerli dairesel olmayan sinyaller için optimalin altında bir başarım sergiler. Tablo 1.1'de, CLMS algoritmasının sözde kodu özetlenmektedir [4], [11].

**Tablo 1.1.** *CLMS Algoritmasının Sözde Kodu*

| |
|---|
| *Parametreler:* $\mu_1$ ve $N$ |
| *Başlangıç Koşulları:* $\mathbf{w}_0 = \mathbf{0} + j\mathbf{0}$ |
| *Veri:* $\{x_k, d_k\}_{k=1}^K$ |
| *Döngü:* $k = 1,\ 2, \ldots, K$ |
| $y_{1,k} = \mathbf{x}_k^T \mathbf{w}_k$ |
| $e_{1,k} = d_k - y_{1,k}$ |
| $\mathbf{w}_{k+1} = \mathbf{w}_k + \mu_1 e_{1,k}^* \mathbf{x}_k$ |
| *bitiş* |

### 1.5. ACLMS Algoritması

ACLMS algoritması, WL tabanlı bir algoritmadır ve bu algoritmada kullanılan FIR filtrenin çıkışı aşağıdaki gibi tanımlanır:

$$y_{2,k} = \mathbf{x}_k^T \mathbf{h}_k + \mathbf{x}_k^H \mathbf{g}_k \tag{1.14}$$

burada $\mathbf{h}_k \in \mathbb{C}^{Nx1}$ ve $\mathbf{g}_k \in \mathbb{C}^{Nx1}$ sırasıyla standart ve eşlenik ağırlık vektörünü temsil eder. Bu durumda $e_k$ hata sinyali ise aşağıdaki gibi tanımlanır:

$$e_{2,k} = d_k - \mathbf{x}_k^T \mathbf{h}_k - \mathbf{x}_k^H \mathbf{g}_k. \tag{1.15}$$

Denklem (1.10.)'da verilen maliyet fonksiyonu $J_k$ daha sonra denklem (1.15) kullanılarak $J_{2,k}$ olarak yeniden tanımlanır ve $\mathbb{CR}$ analiz (Wirtinger hesabı) [42] kullanılarak $\mathbf{h}_k$ ve $\mathbf{g}_k$'ye göre minimize edilir. Bu minimizasyonların sonucunda ise ACLMS algoritmasına ait aşağıdaki güncelleme kuralları elde edilir.

$$\mathbf{h}_{k+1} = \mathbf{h}_k + \mu_2 e_{2,k}^* \mathbf{x}_k \tag{1.16}$$

$$\mathbf{g}_{k+1} = \mathbf{g}_k + \mu_2 e_{2,k}^* \mathbf{x}_k^* \tag{1.17}$$

ACLMS algoritması, WL modeli kullanarak hem standart hem de eşlenik ağırlık vektörlerini adaptif olarak günceller. Bu özelliği sayesinde hem dairesel hem de dairesel olmayan kompleks-değerli sinyallerin verimli bir şekilde işlenmesini sağlar. ACLMS algoritması, WL yapısı nedeniyle CLMS algoritmasına göre iki katı hesaplama yüküne sahiptir. Bu da, ACLMS algoritmasının, CLMS algoritmasına kıyasla yalnızca kompleks değerli dairesel sinyaller için yavaş bir yakınsama hızına sahip olmasına neden olur. Tablo 1.2'de, ACLMS algoritmasının sözde kodu özetlenmektedir [4].

**Tablo 1.2.** *ACLMS Algoritmasının Sözde Kodu*

| |
|---|
| *Parametreler:* $\mu_2$ ve $N$ |
| *Başlangıç Koşulları:* $\mathbf{h}_0 = \mathbf{g}_0 = \mathbf{0} + j\mathbf{0}$ |
| *Veri:* $\{x_k, d_k\}_{k=1}^{K}$ |
| *Döngü*: $k = 1,\ 2, \ldots, K$ |
| $y_{2,k} = \mathbf{x}_k^T \mathbf{h}_k + \mathbf{x}_k^H \mathbf{g}_k$ |
| $e_{2,k} = d_k - \mathbf{x}_k^T \mathbf{h}_k - \mathbf{x}_k^H \mathbf{g}_k$ |
| $\mathbf{h}_{k+1} = \mathbf{h}_k + \mu_2 e_{2,k}^* \mathbf{x}_k$ |
| $\mathbf{g}_{k+1} = \mathbf{g}_k + \mu_2 e_{2,k}^* \mathbf{x}_k^*$ |
| *bitiş* |

### 1.6. Geleneksel Adaptif Dışbükey Kombinasyon

Kompleks düzlemdeki iş birlikçi adaptif bir sistem, içerdiği alt sistemlerin avantajlarını kullanarak daha iyi bir başarım elde etmek için geliştirilmiştir. Ayrıca literatürde bu tür iş birlikçi sistemler, adaptif dış bükey kombinasyon (adaptive convex combination, ACC) olarak da bilinmektedir. *Şekil 1.1*'de CLMS ve ACLMS algoritmalarını iş birlikçi şekilde çalışmasını sağlayan geleneksel ACC yapısı gösterilmektedir [1], [4], [12], [13].

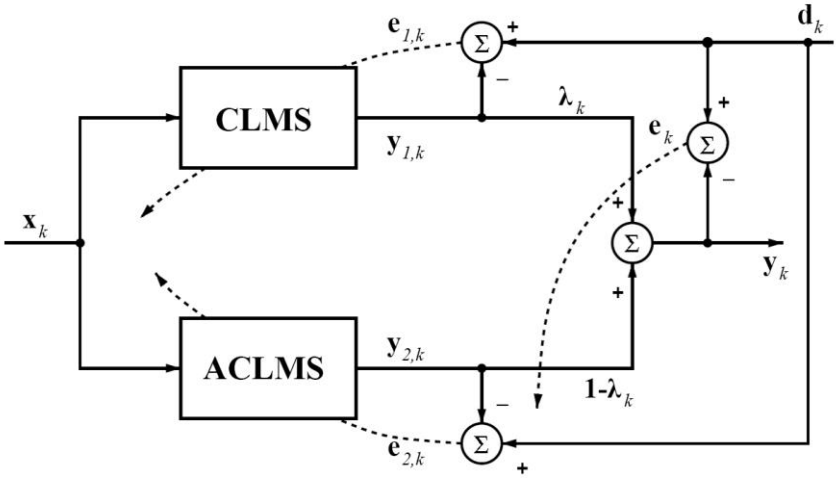


**Şekil 1.1.** *Geleneksel ACC yapısı*

Geleneksel ACC yapısı; CLMS ve ACLMS algoritmalarını birbirinden bağımsız bir şekilde çalıştırarak yerel anlık hata sinyalleri $e_{1,k}$ ve $e_{2,k}$ 'ne göre yerel çıkış sinyalleri $y_{1,k}$

ve $y_{2,k}$'yı üretir ve bu çıkış sinyallerinin konveks kombinasyonuna bağlı olarak genel çıkış sinyalini aşağıdaki gibi elde eder [1], [4], [12], [13], [36]:

$$y_k = \lambda_k y_{1,k} + (1-\lambda_k) y_{2,k} \tag{1.18}$$

burada $\lambda_k \in [0,1]$ karıştırma parametresini temsil eder ve hangi algoritmanın çıkışta ne kadar baskın olacağının kararını verir.

$$\lambda_{k+1} = \lambda_k - \mu_\lambda \nabla_\lambda J_k \tag{1.19}$$

burada $\mu_\lambda$ karıştırma parametresinin adım büyüklüğünü temsil etmektedir. Geleneksel ACC'ye ait hata sinyali ise aşağıdaki gibi tanımlanır [1], [4], [12], [13]:

$$e_k = d_k - \left[ \lambda_k y_{1,k} + (1-\lambda_k) y_{2,k} \right] \tag{1.20}$$

Daha sonra (1.20)'de verilen toplam hata sinyaline dayalı maliyet fonksiyonu şu şekilde tanımlanır:

$$J_k = \frac{1}{2}|e_k|^2 = \frac{1}{2} e_k e_k^*. \tag{1.21}$$

Tanımlanan bu maliyet fonksiyonu $J_k$, $\lambda_k$'ya göre aşağıdaki gibi minimize edilir:

$$\nabla_\lambda J_k\big|_{\lambda=\lambda_k} = \left\{ e_k \frac{\partial e_k^*}{\partial \lambda_k} + \frac{\partial e_k}{\partial \lambda_k} e_k^* \right\} \tag{1.22}$$

$$= -\Re\left\{ e_k^* (y_{1,k} - y_{2,k}) \right\} \tag{1.23}$$

burada $\nabla_\lambda J_k$, maliyet fonksiyonu $J_k$'nın gradyantıdır.

Son olarak, denklem (1.23) denklem (1.19)'da yerine yazılması ile karıştırma parametresinin güncelleme kuralı aşağıdaki gibi elde edilir:

$$\lambda_{k+1} = \lambda_k + \mu_\lambda \Re\left\{ e_k^* (y_{1,k} - y_{2,k}) \right\}. \tag{1.24}$$

Tablo 1.3'de, CLMS ve ACLMS algoritmalarının avantajlarını içeren geleneksel ACC yapısının sözde kodu özetlenmektedir.

**Tablo 1.3.** *Geleneksel ACC Yapısının Sözde Kodu*

---

*Parametreler:* $\mu_1$, $\mu_2$, $\mu_\lambda$, $0 \le \lambda_0 \le 1$ ve $N$

*Başlangıç Koşulları:* $\mathbf{w}_0 = \mathbf{0} + j\mathbf{0}$ ve $\mathbf{h}_0 = \mathbf{g}_0 = \mathbf{0} + j\mathbf{0}$

*Veri:* $\{x_k, d_k\}_{k=1}^{K}$

*Döngü:* $k = 1, 2, \ldots, K$

$y_{1,k} = \mathbf{x}_k^T \mathbf{w}_k$

$y_{2,k} = \mathbf{x}_k^T \mathbf{h}_k + \mathbf{x}_k^H \mathbf{g}_k$

$y_k = \lambda_k y_{1,k} + (1-\lambda_k) y_{2,k}$

$e_{1,k} = d_k - y_{1,k}$

$e_{2,k} = d_k - \mathbf{x}_k^T \mathbf{h}_k - \mathbf{x}_k^H \mathbf{g}_k$

$e_k = d_k - \left[ \lambda_k y_{1,k} + (1-\lambda_k) y_{2,k} \right]$

$\lambda_{k+1} = \lambda_k + \mu_\lambda \Re\left\{ e_k^* (y_{1,k} - y_{2,k}) \right\}$

$\mathbf{w}_{k+1} = \mathbf{w}_k + \mu_1 e_{1,k}^* \mathbf{x}_k$

$\mathbf{h}_{k+1} = \mathbf{h}_k + \mu_2 e_{2,k}^* \mathbf{x}_k$

$\mathbf{g}_{k+1} = \mathbf{g}_k + \mu_2 e_{2,k}^* \mathbf{x}_k^*$

*bitiş*

---

## 1.7. CLMK Algoritması

CLMK algoritması [22], kompleks düzlemde hata sinyalinin ikinci- ve dördüncü-dereceden istatistiksel özelliklerini içeren kurtosis tabanlı maliyet fonksiyonunu yinelemeli olarak minimize eder:

$$J_{1,k} = 3E^2\left\{ \left| e_{1,k} \right|^2 \right\} - E\left\{ \left| e_{1,k} \right|^4 \right\} = 3E^2\left\{ e_{1,k} e_{1,k}^* \right\} - E\left\{ e_{1,k} e_{1,k}^* e_{1,k} e_{1,k}^* \right\} \tag{1.25}$$

burada $e_{1,k}$, denklem (1.26)'da tanımlanan CLMK algoritmasının hata sinyalini temsil eder.

$$e_{1,k} = d_k - y_{1,k} = d_k - \mathbf{x}_k^T \mathbf{w}_k \tag{1.26}$$

burada $d_k$, $\mathbf{x}_k = [x_k, ..., x_{k-N+1}]^T$, $\mathbf{w}_k = [w_k, ..., w_{k-N+1}]^T$ ve $N$ sırasıyla beklenen sinyali, giriş vektörünü, ağırlık vektörünü ve sonlu dürtü cevabı (FIR) filtrenin derecesini temsil etmektedir. Literatürde bahsedildiği gibi [3], [4], (1.25)'deki maliyet fonksiyonu $J_{1,k}$, kompleks değerli değişkenlerin reel değerli bir fonksiyonu olduğundan, holomorf bir fonksiyon değildir. Bu nedenle, $J_{1,k}$'nın $\mathbf{w}_k^*$ ($\mathbf{w}_k = \text{sabit}$)'ye göre türevi doğrudan kompleks düzlemde alınamaz. Bu problemle başa çıkmak için Bölüm 1.1'de verilen $\mathbb{CR}$ analizi kullanılır [42], yani $J_{1,k}$'nin $\mathbf{w}_k^*$ ($\mathbf{w}_k = \text{sabit}$)'ye göre türevi şu şekilde alınır:

$$\hat{\nabla}_{\mathbf{w}^*} J_{1,k} = \frac{\partial J_{1,k}}{\partial \mathbf{w}_k^*} = \frac{1}{2}\left( \frac{\partial J_{1,k}}{\partial \mathbf{w}_{r,k}} + j \frac{\partial J_{1,k}}{\partial \mathbf{w}_{i,k}} \right) = -\left( 3E\left\{ e_{1,k} e_{1,k}^* \right\} - e_{1,k} e_{1,k}^* \right) e_{1,k} \mathbf{x}_k^* \tag{1.27}$$

burada $\hat{\nabla}_{\mathbf{w}^*} J_{1,k}$, $J_{1,k}$'nın gradyantının stokastik yaklaşımıdır.

Ardından, denklem (1.27) aşağıdaki stokastik yaklaşım kuralının içerisine yerleştirilerek, CLMK algoritması için $\mathbf{w}_k$ ağırlık vektörünün güncelleme kuralı şu şekilde elde edilebilir [22]:

$$\begin{aligned} \mathbf{w}_{k+1} &= \mathbf{w}_k - \mu_1 \hat{\nabla}_{\mathbf{w}^*} J_{1,k} \\ &= \mathbf{w}_k + \mu_1 \left( 3\hat{p}_{1,k} - e_{1,k} e_{1,k}^* \right) e_{1,k} \mathbf{x}_k^* \end{aligned} \tag{1.28}$$

burada $\mu_1$, CLMK algoritmasının adım büyüklüğünü temsil eden pozitif bir sabittir ve algoritmanın kararlı olmasını sağlayan önemli bir parametredir. Ayrıca, denklem (1.28)'te $\hat{p}_{1,k} = E\left\{ e_{1,k} e_{1,k}^* \right\}$, hata sinyalinin varyansını temsil eder ve gerçek zamanlı uygulamalar için $\hat{p}_{1,k}$ büyüklüğünün çevrimiçi olarak hesaplanması gerektiği unutulmamalıdır. Bu amaçla aşağıdaki özyineleme denklemi kullanılabilir [22]:

$$\hat{p}_{1,k} = \beta_1 \hat{p}_{1,k-1} + e_{1,k} e_{1,k}^* \tag{1.29}$$

burada $\beta_1 \in [0,1)$, CLMK algoritmasının unutma faktörüdür (forgetting factor).

*Açıklama:* CLMK algoritması, hızlı yakınsama dinamiği, hesaplama verimliliği ve çok çeşitli sinyallere karşı sağlamlığı gibi önemli avantajlara sahip olması nedeniyle

kompleks değerli dairesel sinyalleri işlemek için güçlü bir SL algoritmadır. Diğer SL tabanlı algoritmalara benzer şekilde, CLMK algoritması [22], WL karşılığı olan ACLMK [20] algoritması ile karşılaştırıldığında kompleks değerli dairesel sinyaller için hızlı bir yakınsama oranı sergilerken, kompleks değerli dairesel olmayan sinyaller için optimal olmayan sonuç üretir. Tablo 1.4'de, hesap yükü anlamında basit bir yapıya sahip olan CLMK algoritmasının sözde kodu özetlenmektedir. Ayrıca belirtmek gerekir ki bu algoritmanın Lyapunov anlamında kararlılığı henüz analiz edilmemiştir. Bu durum ilk defa bu tez çalışması kapsamında Bölüm 2'deki Önerme 1 ile analiz edilmiştir.

**Tablo 1.4.** *CLMK Algoritmasının Sözde Kodu*

| |
|---|
| *Parametreler:* $\mu_1$, $0 \le \beta_1 < 1$ ve $N$ |
| *Başlangıç Koşulları:* $\mathbf{w}_0 = \mathbf{0} + j\mathbf{0}$ ve $\hat{p}_{1,0} = 0$ |
| *Veri:* $\{x_k, d_k\}_{k=1}^{K}$ |
| *Döngü*: $k = 1, 2, \ldots, K$ |
| $y_{1,k} = \mathbf{x}_k^T \mathbf{w}_k$ |
| $e_{1,k} = d_k - y_{1,k}$ |
| $\hat{p}_{1,k} = \beta_1 \hat{p}_{1,k-1} + e_{1,k} e_{1,k}^*$ |
| $\mathbf{w}_{k+1} = \mathbf{w}_k + \mu_1 \left(3\hat{p}_{1,k} - e_{1,k} e_{1,k}^*\right) e_{1,k} \mathbf{x}_k^*$ |
| *bitiş* |

### 1.8. ACLMK Algoritması

ACLMK algoritması [20], WL model tabanlı bir algoritma olduğu için filtre çıkış sinyali $y_{2,k}$ ve hata sinyalli $e_{2,k}$ öncelikle şu şekilde tanımlanabilir:

$$y_{2,k} = \mathbf{x}_k^T \mathbf{h}_k + \mathbf{x}_k^H \mathbf{g}_k \tag{1.30}$$

$$e_{2,k} = d_k - y_{2,k} = d_k - \mathbf{x}_k^T \mathbf{h}_k - \mathbf{x}_k^H \mathbf{g}_k \tag{1.31}$$

burada $\mathbf{h}_k \in \mathbb{C}^{N\times 1}$ ve $\mathbf{g}_k \in \mathbb{C}^{N\times 1}$ sırasıyla $k$ anındaki standart ve eşlenik ağırlık vektörlerini temsil eder.

Bu tanımlamaların ardından, maliyet fonksiyonu $J_{2,k}$ şu şekilde tanımlanabilir:

$$J_{2,k} = 3E^2\left\{\left|e_{2,k}\right|^2\right\} - E\left\{\left|e_{2,k}\right|^4\right\} = 3E^2\left\{e_{2,k}e_{2,k}^*\right\} - E\left\{e_{2,k}e_{2,k}^*e_{2,k}e_{2,k}^*\right\} \tag{1.32}$$

CLMK algoritmasını [22] türetmek için izlenen metodoloji, ACLMK algoritması [20] içinde kullanılır ve maliyet fonksiyonu $J_{2,k}$, $\mathbb{CR}$ analizinin yardımıyla [42] standart $\mathbf{h}_k^*$ ve eşlenik $\mathbf{g}_k^*$ ağırlık vektörlerine göre minimize edilir:

$$\hat{\nabla}_{\mathbf{h}^*} J_{2,k} = \frac{\partial J_{2,k}}{\partial \mathbf{h}_k^*} = \frac{1}{2}\left(\frac{\partial J_{2,k}}{\partial \mathbf{h}_{r,k}} + j\frac{\partial J_{2,k}}{\partial \mathbf{h}_{i,k}}\right) = -\left(3E\left\{e_{2,k}e_{2,k}^*\right\} - e_{2,k}^*e_{2,k}\right)e_{2,k}\mathbf{x}_k^* \tag{1.33}$$

$$\hat{\nabla}_{\mathbf{g}^*} J_{2,k} = \frac{\partial J_{2,k}}{\partial \mathbf{g}_k^*} = \frac{1}{2}\left(\frac{\partial J_{2,k}}{\partial \mathbf{g}_{r,k}} + j\frac{\partial J_{2,k}}{\partial \mathbf{g}_{i,k}}\right) = -\left(3E\left\{e_{2,k}e_{2,k}^*\right\} - e_{2,k}^*e_{2,k}\right)e_{2,k}\mathbf{x}_k \tag{1.34}$$

burada sırasıyla $\hat{\nabla}_{\mathbf{h}^*} J_{2,k}$ ve $\hat{\nabla}_{\mathbf{g}^*} J_{2,k}$ maliyet fonksiyonu $J_{2,k}$'nın gradyantinin stokastik yaklaşımlarıdır.

Denklem (1.33) ve (1.34)'ü stokastik gradyan iniş kuralında yerine yazarak, ACLMK algoritması için standart $\mathbf{h}_k^*$ ve eşlenik $\mathbf{g}_k^*$ ağırlık vektörlerinin güncelleme kurallarını aşağıdaki gibi elde edebiliriz:

$$\mathbf{h}_{k+1} = \mathbf{h}_k - \mu_2\hat{\nabla}_{\mathbf{h}^*} J_{2,k} = \mathbf{h}_k + \mu_2\left(3\hat{p}_{2,k} - e_{2,k}^*e_{2,k}\right)e_{2,k}\mathbf{x}_k^* \tag{1.35}$$

$$\mathbf{g}_{k+1} = \mathbf{g}_k - \mu_2\hat{\nabla}_{\mathbf{g}^*} J_{2,k} = \mathbf{g}_k + \mu_2\left(3\hat{p}_{2,k} - e_{2,k}^*e_{2,k}\right)e_k\mathbf{x}_k \tag{1.36}$$

burada $\mu_2$, ACLMK algoritmasının adım büyüklüğüdür ve $\hat{p}_{2,k} = E\left\{e_{2,k}e_{2,k}^*\right\}$ ifadesi, hata sinyali $e_{2,k}$ kullanılarak aşağıdaki denklem yardımıyla hesaplanır [20]:

$$\hat{p}_{2,k} = \beta_2\hat{p}_{2,k-1} + e_{2,k}e_{2,k}^* \tag{1.37}$$

burada $\beta_2 \in [0,1)$, unutma faktörünü temsil eder.

Denklem (1.35) ve (1.36)'da verilen ACLMK algoritmasının güncelleme kuralının matematiksel gösterimini kolaylaştırmak için $\mathbf{h}_k$ ve $\mathbf{g}_k$ vektörleri, bir artırılmış ağırlık

vektörü $\mathbf{w}_k^a$ içerisinde birleştirilir. Dolayısıyla, ACLMK algoritması için artırılmış ağırlık vektörü $\mathbf{w}_k^a$ güncelleme kuralı aşağıdaki gibi elde edilir:

$$\mathbf{w}_{k+1}^a = \mathbf{w}_k^a + \mu_2 \left(3\hat{p}_{2,k} - e_{2,k}^* e_{2,k}\right) e_{2,k} \mathbf{x}_k^{a*} \tag{1.38}$$

burada $\mathbf{x}_k^a = \left[\mathbf{x}_k^T \mathbf{x}_k^H\right]^T \in \mathbb{C}^{2N\times 1}$ , artırılmış kompleks değerli giriş vektörünü temsil eder.

*Açıklama:* ACLMK algoritması WL yapısının sayesinde, sözde kovaryans $\mathbf{P}_{\mathbf{xx}} = E\{\mathbf{x}\mathbf{x}^T\}$ ve kovaryans $\mathbf{C}_{\mathbf{xx}} = E\{\mathbf{x}\mathbf{x}^H\}$ matrisleri [20] tarafından ortaklaşa tanımlanan artırılmış istatistikler olarak adlandırılan tüm ikinci-dereceden istatistiksel bilgileri kapsamlı bir şekilde kullanır. Bu nedenle, ACLMK algoritması hem dairesel hem de dairesel olmayan kompleks değerli sinyalleri kolayca işleme yeteneğine sahiptir. Ancak, Tablo 1.5'te sunulan ACLMK'nın sözde kodundan da görülebileceği gibi, bu algoritma WL yapısından dolayı yoğun hesaplama yüküne maruz kalmaktadır. Bu durum, ACLMK algoritmasının, CLMK algoritmasına [22] kıyasla yalnızca kompleks değerli dairesel sinyaller için yavaş bir yakınsama hızına sahip olmasına neden olur. Ne yazık ki, Lyapunov anlamında kararlılığı henüz analiz edilmemiştir. Bu amaçla, bu tez çalışması kapsamında Bölüm 2'de sunulan *Önerme 2* yapılmıştır.

**Tablo 1.5.** *ACLMK Algoritmasının Sözde Kodu*

| |
|---|
| *Parametreler:* $\mu_2$ , $0 \le \beta_2 < 1$ ve $N$ |
| *Başlangıç Koşulları:* $\mathbf{h}_0 = \mathbf{g}_0 = \mathbf{0} + j\mathbf{0}$ veya $\mathbf{w}_0^a = \mathbf{0} + j\mathbf{0}$ ve $\hat{p}_{2,0} = 0$ |
| *Veri:* . $\{x_k, d_k\}_{k=1}^K$ |
| *Döngü*: $k = 1, 2, \ldots, K$ |
| $y_{2,k} = \mathbf{x}_k^T \mathbf{h}_k + \mathbf{x}_k^H \mathbf{g}_k$ |
| $e_{2,k} = d_k - \mathbf{x}_k^T \mathbf{h}_k - \mathbf{x}_k^H \mathbf{g}_k$ |
| $\hat{p}_{2,k} = \beta_2 \hat{p}_{2,k-1} + e_{2,k} e_{2,k}^*$ |
| $\left.\begin{aligned} \mathbf{h}_{k+1} &= \mathbf{h}_k + \mu_2 \left(3\hat{p}_{2,k} - e_{2,k}^* e_{2,k}\right) e_{2,k} \mathbf{x}_k^* \\ \mathbf{g}_{k+1} &= \mathbf{g}_k + \mu_2 \left(3\hat{p}_{2,k} - e_{2,k}^* e_{2,k}\right) e_{2,k} \mathbf{x}_k \end{aligned}\right\}$ *veya* $\mathbf{w}_{k+1}^a = \mathbf{w}_k^a + \mu_2 e_{2,k} \mathbf{x}_k^{a*}$ |
| *bitiş* |

# İKİNCİ BÖLÜM

# CLMK VE ACLMK ALGORİTMALARININ LYAPUNOV KARARLILIK ANALİZLERİ

Bu bölümde, ilk defa bu tez çalışmasında CLMK ve ACLMK algoritmalarının Lyapunov anlamında kararlık analizi yapılmıştır.

## 2.1. CLMK Algoritmasının Lyapunov Kararlılık Analizi

Daha önce de belirtildiği gibi CLMK algoritmasının Lyapunov anlamında kararlılığı henüz analiz edilmemiştir. Literatürdeki bu açığı kapatmak için aşağıdaki önerme yapılmıştır.

*Önerme 1.* Denklem (1.28)'de yer alan CLMK algoritmasının güncelleme kuralı, adım büyüklüğü $\mu_1$ aşağıdaki gibi seçilirse Lyapunov anlamında asimptotik kararlıdır.

$$0 < \mu_1 < \frac{2}{\sigma_n^2 \left( \frac{2+\beta}{1-\beta} \right) \left\| \mathbf{x}_k \right\|_2^2} \tag{2.1}$$

*İspat 1.* Öncelikle CLMK algoritmasının hata sinyalinin bir fonksiyonu olan $V(e_{1,k}) = \left| e_{1,k} \right|^2$ fonksiyonu, aday Lyapunov fonksiyonu olarak seçilmiştir. Ardından, Bölüm 1.3'te verilen Lyapunov kararlılık teorisine göre, aşağıdaki koşulunun yerine getirilmesi gerekmektedir:

$$\Delta V_{1,k} = V(e_{1,k+1}) - V(e_{1,k}) = \left| e_{1,k+1} \right|^2 - \left| e_{1,k} \right|^2 < 0. \tag{2.2}$$

Bu amaç doğrultusunda, birinci-dereceden Taylor serisi açılımı kullanılarak, $e_{1,k+1}$ ve $e_{1,k}$ hata sinyalleri arasındaki ilişki şu şekilde ifade edebilir:

$$e_{1,k+1} = e_{1,k} + \Delta \mathbf{w}_k^T \frac{\partial e_{1,k}}{\partial \mathbf{w}_k} \tag{2.3}$$

$$= e_{1,k} + (\mu_{1,k} e_{1,k} \mathbf{x}_k^*)^T (-\mathbf{x}_k)$$

$$= e_{1,k} - \mu_{1,k} e_{1,k} \mathbf{x}_k^H \mathbf{x}_k$$

$$= e_{1,k}(1 - \mu_{1,k} \mathbf{x}_k^H \mathbf{x}_k) \tag{2.4}$$

burada $\mu_{1,k} = \mu_1(3\hat{p}_{1,k} - e_{1,k} e_{1,k}^*)$.

Denklem (2.4), denklem (2.2)'de yerine yazıldığında, denklem (2.5) elde edilir.

$$\Delta V_{1,k} = \left| e_{1,k}(1 - \mu_{1,k} \mathbf{x}_k^H \mathbf{x}_k) \right|^2 - \left| e_{1,k} \right|^2$$

$$= \left| e_{1,k} \right|^2 \left[ \left| 1 - \mu_{1,k} \left\| \mathbf{x}_k \right\|_2^2 \right|^2 - 1 \right]. \tag{2.5}$$

Lyapunov'un $\Delta V_{1,k} < 0$ şartını sağlamak için, denklem (2.5)'deki köşeli parantez içindeki terim şu şekilde olmalıdır:

$$\left| 1 - \mu_{1,k} \left\| \mathbf{x}_k \right\|_2^2 \right|^2 < 1. \tag{2.6}$$

Denklem (2.6) üzerinde bazı cebirsel işlemler yapıldığında, adım büyüklüğü parametresi $\mu_{1,k}$'nın alt ve üst sınırı aşağıdaki gibi elde edilir:

$$0 < \mu_{1,k} < \frac{2}{\left\| \mathbf{x}_k \right\|_2^2}. \tag{2.7}$$

Adım büyüklüğü $\mu_1$'in üst sınırını matematiksel olarak daha gözlemlenebilir bir hale getirebilmek için, aşağıdaki varsayımların yapılması gerekmektedir.

*Varsayım 1:* Bölüm 1.7'de bahsi geçen FIR filtrenin çıkışı, $\sigma_n^2$ varyanslı sıfır ortalamalı beyaz Gauss ölçüm gürültü sinyali $n_k$ tarafından bozulduğu ve bu sinyalin, giriş sinyaliyle istatistiksel olarak ilintisiz olduğu varsayılır.

*Varsayım 2:* Kararlı durumda aşırı hata (excess error), ölçüm gürültüsü $n_k$'dan daha küçük genliğe sahiptir. Bu nedenle, kararlı durumda anlık hata sinyali $e_k$, yaklaşık olarak $n_k$'ya eşit olduğu varsayılır.

*Varsayım 1* ve *2* altında, denklem (1.29)'daki $\mu_{1,k} = (3\hat{p}_k - e_k e_k^*)$ teriminin beklenen değeri şu sonucu verir [1], [2], [20]:

$$E\left\{\mu_{1,\infty}\right\} = E\left\{\mu_1(3\hat{p}_\infty - e_\infty e_\infty^*)\right\}$$

$$= \sigma_n^2\left(\frac{2+\beta_1}{1-\beta_1}\right). \tag{2.8}$$

Denklem (2.8), denklem (2.7) içerisine yazılırsa, CLMK algoritmasının adım büyüklüğü sınırlarını aşağıdaki gibi elde edilir:

$$0 < \mu_1 < \frac{2}{\sigma_n^2\left(\frac{2+\beta_1}{1-\beta_1}\right)\left\|\mathbf{x}_k\right\|_2^2}. \tag{2.9}$$

Denklem (2.9)'daki adım büyüklüğü sınırları, CLMK algoritmasının güncelleme kuralının her zaman Lyapunov anlamında kararlılığını sağlar.

### 2.2. ACLMK Algoritmasının Lyapunov Kararlılık Analizi

Burada ise ACLMK algoritmasının Lyapunov kararlılık analizi için aşağıdaki önerme yapılmıştır.

*Önerme 2:* Adım büyüklüğü $\mu_2$, aşağıdaki gibi seçilirse, ACLMK algoritmasının güncelleme kuralı Lyapunov anlamında asimptotik olarak kararlıdır:

$$0 < \mu_2 < \frac{2}{\sigma_n^2\left(\frac{2+\beta_2}{1-\beta_2}\right)\left\|\mathbf{x}_k^a\right\|_2^2}. \tag{2.10}$$

*İspat 2:* ACLMK algoritması için bir aday fonksiyon $V(e_{2,k}) = \left|e_{2,k}\right|^2$ tanımlandıktan sonra, CLMK algoritmasındakine benzer bir yol izlenerek ACLMK algoritmasının adım büyüklüğü $\mu_2$ 'nin sınırları şu şekilde elde edilir:

$$0 < \mu_2 < \frac{2}{\sigma_n^2 \left( \frac{2+\beta_2}{1-\beta_2} \right) \left\| \mathbf{x}_k^a \right\|_2^2} \tag{2.11}$$

Şu açıktır ki, ACLMK algoritması WL model yapısı sebebiyle CLMK algoritmasına kıyasla iki katı kadar ağırlık katsayısı içermektedir. Bu yüzden, ACLMK algoritmasının denklem (2.11)'deki adım büyüklüğü üst sınırı, CLMK algoritmasının denklem (2.9)'da verilen adım büyüklüğü üst sınırından daha küçüktür.

# ÜÇÜNCÜ BÖLÜM

# ÖNERİLEN ADAPTİF KONVEKS KOMBİNASYON

Bu bölümde; tez çalışmasında önerilen CLMK ve ACLMK algoritmalarının adaptif konveks kombinasyonunun (Adaptive convex combination of CLMK and ACLMK-ACC) tasarımından bahsedildikten sonra ACC'ye ait önerilen karıştırma parametresi güncelleme kuralının Lyapunov kararlılık analizi detaylı bir şekilde sunulmuştur.

## 3.1. Önerilen Adaptif Konveks Kombinasyonunun Tasarımı

Bu bölümde, CLMK ve ACLMK algoritmalarının bireysel avantajlarını iş birlikçi şekilde bir araya getiren ve böylece filtreleme başarımını arttıran adaptif bir konveks kombinasyon tasarımı yapılmaktadır. *Şekil 3.1.*'de CLMK ve ACLMK algoritmalarını iş birlikçi şekilde çalışmasını sağlayan ve ilk defa bu tez çalışmasında önerilen ACC yapısı gösterilmektedir.

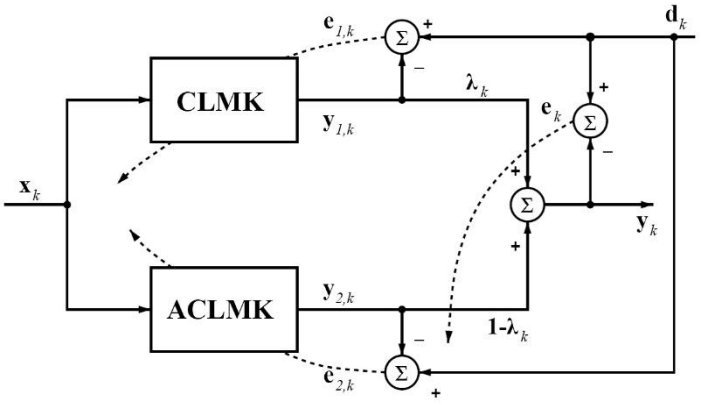


**Şekil 3.2.** *Önerilen ACC yapısı*

Önerilen ACC yapısı; CLMK ve ACLMK algoritmalarını birbirinden bağımsız bir şekilde çalıştırarak yerel anlık hata sinyalleri $e_{1,k}$ ve $e_{2,k}$'ya göre yerel çıkış sinyalleri $y_{1,k}$

ve $y_{2,k}$'yı üretir ve bu çıkış sinyallerinin konveks kombinasyonuna bağlı olarak genel çıkış ve hata sinyallerini aşağıdaki gibi elde eder:

$$y_k = \lambda_k y_{1,k} + (1-\lambda_k) y_{2,k}, \quad \lambda_k \in [0,1] \tag{3.1}$$

$$e_k = d_k - y_k = d_k - \left(\lambda_k y_{1,k} + (1-\lambda_k) y_{2,k}\right) \tag{3.2}$$

burada $\lambda_k \in [0,1]$ önerilen ACC yapısının karıştırma parametresini temsil eder ve hangi algoritmanın çıkışta ne kadar baskın olacağının kararını aşağıdaki stokastik yaklaşım tabanlı güncelleme kuralı yardımıyla gerçekleştirir:

$$\lambda_{k+1} = \lambda_k - \mu_\lambda \hat{\nabla}_\lambda J_k \tag{3.3}$$

Bu tez çalışmasında, literatürde yapılan çalışmalardan farklı olarak denklem (3.3)'de yer alan maliyet fonksiyonu $J_k$, genel hata sinyalinin kurtosisi olacak şekilde aşağıdaki gibi tanımlanır:

$$J_k = 3E^2\left\{|e_k|^2\right\} - E\left\{|e_k|^4\right\} = 3E^2\left\{e_k e_k^*\right\} - E\left\{e_k e_k^* e_k e_k^*\right\} \tag{3.4}$$

Ardından, bu tanımlanan maliyet fonksiyonu $J_k$, $\lambda_k$'ya göre adım adım aşağıdaki gibi minimize edilir:

$$\hat{\nabla}_\lambda J_k\Big|_{\lambda=\lambda(k)} = 6E\left\{e_k e_k^*\right\} \underbrace{\frac{\partial e_k e_k^*}{\partial \lambda_k}}_{\text{birinci kısım}} - \underbrace{\frac{\partial e_k e_k^* e_k e_k^*}{\partial \lambda_k}}_{\text{ikinci kısım}} \tag{3.5}$$

burada $\hat{\nabla}_\lambda J_k$, maliyet fonksiyonu $J_k$'nın gradyantının stokastik yaklaşımıdır ve denklem (3.5)'in birinci kısmı şu şekilde hesaplanır:

$$\frac{\partial e_k e_k^*}{\partial \lambda_k} = e_k \frac{\partial e_k^*}{\partial \lambda_k} + e_k^* \frac{\partial e_k}{\partial \lambda_k}$$

$$= -\left[e_k (y_{1,k} - y_{2,k})^* + e_k^* (y_{1,k} - y_{2,k})\right]$$

$$= -\Re\left(e_k (y_{1,k} - y_{2,k})^*\right) \tag{3.6}$$

ve denklem (3.5)'in ikinci kısmı ise şu şekilde hesaplanır:

$$\frac{\partial e_k e_k^* e_k e_k^*}{\partial \lambda_k} = e_k e_k^* \frac{\partial e_k e_k^*}{\partial \lambda_k} + e_k e_k^* \frac{\partial e_k e_k^*}{\partial \lambda_k}$$

$$= 2e_k e_k^* \frac{\partial e_k e_k^*}{\partial \lambda_k} = 2e_k e_k^* \left[ -\Re\left( e_k (y_{1,k} - y_{2,k})^* \right) \right]. \tag{3.7}$$

Denklem (3.6) ve (3.7), denklem (3.5)'de yerine yazılırsa, gradyant $\hat{\nabla}_\lambda J_k$ aşağıdaki hali alır:

$$\hat{\nabla}_\lambda J_k = -\left( 6E\left\{ e_k e_k^* \right\} - 2e_k e_k^* \right) \left[ \Re\left( e_k (y_{1,k} - y_{2,k})^* \right) \right]. \tag{3.8}$$

Son olarak; denklem (3.8), denklem (3.3)'de yerine yazılırsa önerilen karıştırma parametresi güncelleme kuralı aşağıdaki gibi elde edilir:

$$\lambda_{k+1} = \lambda_k + \mu_\lambda \left( 3\hat{p}_k - e_k e_k^* \right) \left[ \Re\left( e_k (y_{1,k} - y_{2,k})^* \right) \right] \tag{3.9}$$

burada $\mu_\lambda$, karıştırma parametresinin adım büyüklüğünü temsil eder ve denklem (1.29) ve (1.37)'ye benzer şekilde, $\hat{p}_k = E\left\{ e_k e_k^* \right\}$ ifadesi yinelemeli olarak aşağıdaki gibi hesaplanır:

$$\hat{p}_k = \beta \hat{p}_{k-1} + e_k e_k^* \tag{3.10}$$

burada $0 < \beta < 1$ unutma faktörüdür.

*Açıklama:* Önerilen ACC algoritmasının konveks bir fonksiyon olarak kalabilmesi için, karıştırma parametresinin 0 ile 1 arasında olması oldukça önemlidir. Bu nedenle, [4], [13], [36], [37]'de olduğu gibi $\lambda_k > 1$ ve $\lambda_k < 0$ olduğunda, karıştırma parametresi $\lambda_k$'ya kesin sınır (hard threshold) işlemi uygulanır. Önerilen ACC algoritmasının sözde kodunun verildiği Tablo 3.1'den de görüldüğü gibi, dairesel sinyaller için önerilen ACC'nin çıkışında CLMK algoritması hakimdir, yani $\lambda_k$ ifadesi, 1 değerine yakınsar. Öte yandan, dairesel olmayan sinyaller için, çıkışta ACLMK algoritması baskın hale gelir, yani $\lambda_k$ ifadesi, 0 değerine yaklaşır.

**Tablo 3.1.** *Önerilen ACC Algoritmasının Sözde Kodu*

*Parametreler:* $\mu_1$, $\mu_2$, $\mu_\lambda$, $0 \le \beta < 1$, $0 \le \beta_1 < 1$, $0 \le \beta_2 < 1$, $0 \le \lambda_0 \le 1$ ve $N$

*Başlangıç Koşulları:* $\mathbf{w}_0 = \mathbf{0} + j\mathbf{0}$, $\mathbf{h}_0 = \mathbf{g}_0 = \mathbf{0} + j\mathbf{0}$ (veya $\mathbf{w}_0^a = \mathbf{0} + j\mathbf{0}$), $\hat{p}_{1,0} = 0$, $\hat{p}_{2,0} = 0$ ve $\hat{p}_0 = 0$

*Veri:* $\{x_k, d_k\}_{k=1}^{K}$

*Döngü*: $k = 1, 2, \ldots, K$

$$y_{1,k} = \mathbf{x}_k^T \mathbf{w}_k$$

$$y_{2,k} = \mathbf{x}_k^T \mathbf{h}_k + \mathbf{x}_k^H \mathbf{g}_k$$

$$y_k = \lambda_k y_{1,k} + (1 - \lambda_k) y_{2,k}$$

$$e_{1,k} = d_k - y_{1,k}$$

$$e_{2,k} = d_k - y_{2,k}$$

$$e_k = d_k - \left(\lambda_k y_{1,k} + (1 - \lambda_k) y_{2,k}\right)$$

$$\hat{p}_{1,k} = \beta_1 \hat{p}_{1,k-1} + e_{1,k} e_{1,k}^*$$

$$\hat{p}_{2,k} = \beta_2 \hat{p}_{2,k-1} + e_{2,k} e_{2,k}^*$$

$$\hat{p}_k = \beta \hat{p}_{k-1} + e_k e_k^*$$

$$\lambda_{k+1} = \lambda_k + \mu_\lambda \left(3\hat{p}_k - e_k e_k^*\right)\left[\Re\left(e_k (y_{1,k} - y_{2,k})^*\right)\right]$$

$$\mathbf{w}_{k+1} = \mathbf{w}_k + \mu_1 \left(3\hat{p}_{1,k} - e_{1,k} e_{1,k}^*\right) e_{1,k} \mathbf{x}_k^*$$

$$\left.\begin{aligned} \mathbf{h}_{k+1} &= \mathbf{h}_k + \mu_2 \left(3\hat{p}_{2,k} - e_{2,k}^* e_{2,k}\right) e_{2,k} \mathbf{x}_k^* \\ \mathbf{g}_{k+1} &= \mathbf{g}_k + \mu_2 \left(3\hat{p}_{2,k} - e_{2,k}^* e_{2,k}\right) e_{2,k} \mathbf{x}_k \end{aligned}\right\} \text{veya } \mathbf{w}_{k+1}^a = \mathbf{w}_k^a + \mu_2 \left(3\hat{p}_{2,k} - e_{2,k}^* e_{2,k}\right) e_{2,k} \mathbf{x}_k^{a*}$$

*bitiş*

### 3.2. Önerilen Karıştırma Parametresi Güncelleme Kuralının Lyapunov Kararlılık Analizi

Denklem (3.9)'da yer alan önerilen karıştırma parametresi güncelleme kuralının Lyapunov kararlılık analizi bu bölümde incelenmektedir. Bölüm 1.3'de sunulan Lyapunov kararlılık analizine göre, önce kompleks değişkenlerin reel değerli ve pozitif tanımlı bir fonksiyonu olan bir aday Lyapunov fonksiyonu aşağıdaki gibi tanımlanabilir:

$$V(e_k) = |e_k|^2 . \tag{3.10}$$

Daha sonra, Lyapunov anlamında asimptotik kararlılık için gereklilik koşulunun sağlanması gerekir:

$$\Delta V_k = V(e_{k+1}) - V(e_k) = \left|e_{k+1}\right|^2 - \left|e_k\right|^2 < 0 \,. \tag{3.11}$$

Birinci dereceden Taylor serisi açılımı kullanılarak, denklem (3.11)'deki $e_{k+1}$ ve $e_k$ arasındaki ilişki şu şekilde ifade edilir:

$$e_{k+1} = e_k + \Delta\lambda_k \frac{\partial e_k}{\partial \lambda_k} \tag{3.12}$$

burada $\Delta\lambda_k = \lambda_{k+1} - \lambda_k$ ifadesi, denklem (3.9) kullanılarak aşağıdaki gibi ifade edilir:

$$\begin{aligned}
\Delta\lambda &= \lambda_{k+1} - \lambda_k \\
&= \mu_\lambda (3\hat{p}_k - e_k e_k^*)\left[\Re\left(e_k \left(y_{1,k} - y_{2,k}\right)^*\right)\right] \\
&= \mu_\lambda (3\hat{p}_k - e_k e_k^*)\left[e_k \left(y_{1,k} - y_{2,k}\right)^* + e_k^* \left(y_{1,k} - y_{2,k}\right)\right]
\end{aligned} \tag{3.13}$$

ve denklem (3.12)'deki kısmi türev $\partial e_k / \partial \lambda_k$ ise şu şekilde hesaplanır:

$$\frac{\partial e_k}{\partial \lambda_k} = -\left(y_{1,k} - y_{2,k}\right). \tag{3.14}$$

Denklem (3.13) ve (3.14), denklem (3.12)'de yerine yazıldığında hatalar arasındaki ilişki aşağıdaki gibi elde edilir:

$$\begin{aligned}
e_{k+1} &= e_k - \mu_\lambda (3\hat{p}_k - e_k e_k^*)\left[e_k \left(y_{1,k} - y_{2,k}\right)^* + e_k^* \left(y_{1,k} - y_{2,k}\right)\right]\left(y_{1,k} - y_{2,k}\right) \\
&= e_k - \mu_{\lambda,k} e_k \left(y_{1,k} - y_{2,k}\right)^* \left(y_{1,k} - y_{2,k}\right)\left[1 + \frac{e_k^*}{e_k} \frac{\left(y_{1,k} - y_{2,k}\right)}{\left(y_{1,k} - y_{2,k}\right)^*}\right] \\
&= e_k - \mu_{\lambda,k} e_k \left|y_{1,k} - y_{2,k}\right|^2 \left[1 + \frac{(e_k^*)^2}{\left|e_k^*\right|^2} \frac{\left(y_{1,k} - y_{2,k}\right)^2}{\left|\left(y_{1,k} - y_{2,k}\right)^*\right|^2}\right]
\end{aligned}$$

$$= e_k - \mu_{\lambda,k} e_k \left| y_{1,k} - y_{2,k} \right|^2 \left[ 1 + \text{sgn}^2(e_k^*) \text{sgn}^2(y_{1,k} - y_{2,k}) \right]$$

$$= e_k \left[ 1 - \mu_{\lambda,k} \left| y_{1,k} - y_{2,k} \right|^2 \left[ 1 + \text{sgn}^2(e_k^*) \text{sgn}^2(y_{1,k} - y_{2,k}) \right] \right] \quad (3.15)$$

burada $\mu_{\lambda,k} = \mu_\lambda (3\hat{p}_k - e_k e_k^*)$.

Denklem (3.15)'in yardımıyla, denklem (3.11) yeniden yazabilir:

$$\Delta V_k = \left| e_{k+1} \right|^2 - \left| e_k \right|^2$$

$$= \left| e_k \right|^2 \left| 1 - \mu_{\lambda,k} \left| y_{1,k} - y_{2,k} \right|^2 \left[ 1 + \text{sgn}^2(e_k^*) \text{sgn}^2(y_{1,k} - y_{2,k}) \right] \right|^2 - \left| e_k \right|^2$$

$$= \left| e_k \right|^2 \left[ \left| 1 - \mu_{\lambda,k} \left| y_{1,k} - y_{2,k} \right|^2 \left[ 1 + \text{sgn}^2(e_k^*) \text{sgn}^2(y_{1,k} - y_{2,k}) \right] \right|^2 - 1 \right]. \quad (3.16.)$$

Denklem (3.16) incelendiğinde, $\Delta V_k < 0$ gereklilik koşulunu sağlamak için, köşeli parantez içindeki terimin negatif tanımlı olması gerektiği açıkça görülmektedir ve $\mu_{\lambda,k}$ için çözüm adım adım aşağıdaki gibi sunulmaktadır:

$$\left| 1 - \mu_{\lambda,k} \left| y_{1,k} - y_{2,k} \right|^2 \left[ 1 + \text{sgn}^2(e_k^*) \text{sgn}^2(y_{1,k} - y_{2,k}) \right] \right|^2 < 1$$

$$-1 < 1 - \mu_{\lambda,k} \left| y_{1,k} - y_{2,k} \right|^2 \left[ 1 + \text{sgn}^2(e_k^*) \text{sgn}^2(y_{1,k} - y_{2,k}) \right] < 1$$

$$0 < \mu_{\lambda,k} < \frac{2}{\left| y_{1,k} - y_{2,k} \right|^2 \left[ 1 + \text{sgn}^2(e_k^*) \text{sgn}^2(y_{1,k} - y_{2,k}) \right]}. \quad (3.17)$$

Ardından $\mu_{\lambda,k} = \mu_\lambda (3\hat{p}_k - e_k e_k^*)$ ifadesi denklem (3.17)'de yerine yazılarak, adım büyüklüğü $\mu_\lambda$ 'nın alt ve üst sınırları şu şekilde elde edelir:

$$0 < \mu_\lambda < \frac{2}{(3\hat{p}_k - e_k e_k^*) \left| y_{1,k} - y_{2,k} \right|^2 \left[ 1 + \text{sgn}^2(e_k^*) \text{sgn}^2(y_{1,k} - y_{2,k}) \right]}. \quad (3.18)$$

Denklem (3.18)'de adım büyüklüğü $\mu_\lambda$ için matematiksel olarak daha izlenebilir bir üst sınırın elde edilebilmesi için Bölüm 2.1'de sunulan *Varsayım 1* ve *2*'nin kullanılması gerekir.

*Varsayım 1* ve *2* dikkate alındığında, denklem (3.18)'deki $3\hat{p}_k - e_k e_k^*$ ifadesinin beklenen değeri şu sonucu verir:

$$E\left\{3\hat{p}_\infty - e_\infty e_\infty^*\right\} = \sigma_n^2\left(\frac{2+\beta}{1-\beta}\right). \tag{3.19}$$

Daha sonra, denklem (3.19), denklem (3.18)'de yerine yazılırsa, adım büyüklüğünün üst sınırı aşağıdaki gibi daha sade hale getirilir:

$$0 < \mu_\lambda < \frac{2}{\sigma_n^2\left(\frac{2+\beta}{1-\beta}\right)\left|y_{1,k} - y_{2,k}\right|^2\left[1+\mathrm{sgn}^2(e_k^*)\,\mathrm{sgn}^2(y_{1,k} - y_{2,k})\right]}. \tag{3.20}$$

# DÖRDÜNCÜ BÖLÜM

# BENZETİM SONUÇLARI

Bu bölümde; tez çalışmasında önerilen ACC algoritmasının başarımı, sistem tanımlama ve bir-adım-ileri tahmin senaryoları üzerinde kapsamlı bir şekilde değerlendirilmiştir.

## 4.1. Sistem Tanımlama Senaryoları

Önerilen ACC'nin üstün başarımını göstermek için üç farklı sistem tanımlama senaryosu kurgulanmıştır ve önerilen ACC'nin ortalama kare hatası (Mean Square Error, MSE) (dB) ve ortalaması alınmış kararlı durum (averaged steady state) MSE'si; CLMS [11], ACLMS [4], CLMK [22], ACLMK [22] ve geleneksel ACC'ninki [13] ile karşılaştırılmıştır. Sistem tanımlama senaryosu 1'de, bilinmeyen sistem, denklem (4.1) ve (4.2) tarafından oluşturulmuştur ve dördüncü-dereceden kesin lineer hareketli ortalamaya (Strictly Linear-Moving Average, SL-MA (4)) sahip bir sistemdir:

$$d_k = \mathbf{x}_k^T \mathbf{w}_{o1} + n_k \text{ için } 1 \le k \le 2000 \tag{4.1}$$

$$d_k = \mathbf{x}_k^T \mathbf{w}_{o2} + n_k \text{ için } 2000 < k \le 4000 \tag{4.2}$$

burada $\mathbf{w}_{o1} = [6 - j6,\ 0.5 + j1,\ -2 + j1,\ 2 + j3]$ ve $\mathbf{w}_{o2} = -\mathbf{w}_{o1}$ bilinmeyen SL-MA (4) sisteminin optimum katsayılarıdır [38]. Sistem tanımlama senaryosu 2'deki bilinmeyen sistem, denklem (4.3) ve (4.4) tarafından oluşturulmuştur ve dördüncü dereceden geniş lineer hareketli ortalamaya (Widely Linear-MA, WL-MA (4)) sahip bir sistemdir:

$$d_k = \mathbf{x}_k^T \mathbf{h}_{o1} + \mathbf{x}_k^H \mathbf{g}_{o1} + n_k \text{ için } 1 \le k \le 2000 \tag{4.3}$$

$$d_k = \mathbf{x}_k^T \mathbf{h}_{o2} + \mathbf{x}_k^H \mathbf{g}_{o2} + n_k \text{ için } 2000 < k \le 4000 \tag{4.4}$$

burada optimum ağırlık katsayılar $\mathbf{h}_{o1} = [6 - j6,\ 0.5 + j1, -2 + j1,\ 2 + j3]$, $\mathbf{g}_{o1} = [0.2 - j0.2,\ 0.1 + j01,\ 2,\ j0.4]$, $\mathbf{h}_{o2} = -\mathbf{h}_{o1}$ ve $\mathbf{g}_{o2} = -\mathbf{g}_{o1}$ olarak belirlenmiştir [38].

Son olarak, sistem tanımlama senaryosu 3'teki bilinmeyen sistem, (4.1) ve (4.3) kullanılarak şu şekilde oluşturulmuştur:

$$d_k = \mathbf{x}_k^T \mathbf{w}_{o1} + n_k \text{ için } 1 \le k \le 2000 \tag{4.5}$$

$$d_k = \mathbf{x}_k^T \mathbf{h}_{o1} + \mathbf{x}_k^H \mathbf{g}_{o1} + n_k \text{ için } 2000 < k \le 4000 \tag{4.6}$$

burada optimum ağırlık katsayılar $\mathbf{w}_{o1} = [6 - j6,\ 0.5 + j1, -2 + j1,\ 2 + j3]$, $\mathbf{h}_{o1} = [6 - j6,\ 0.5 + j1, -2 + j1,\ 2 + j3]$ ve $\mathbf{g}_{o1} = [0.2 - j0.2,\ 0.1 + j01,\ 2,\ j0.4]$'dür.

Denklem (4.1)-(4.6)'da, bilinmeyen sistemler, birim varyanslı kompleks değerli çift beyaz dairesel Gauss giriş sinyali $\mathbf{x}_k$ ile beslenmiştir ve $\sigma_n^2 = 0.1$ ve $\sigma_n^2 = 0.01$ varyanslarına sahip kompleks değerli çift beyaz dairesel Gauss gürültü sinyali $n_k$ tarafından bozulmuştur. Tüm sistem tanımlama senaryoları için, ele alınan algoritmalarda kullanılan FIR filtrelerinin dereceleri bilinmeyen sistemlerinkiyle aynı olacak şekilde ayarlanmıştır. Tüm benzetim sonuçları, 200 bağımsız koşturmanın ortalaması alınarak üretilmiştir. Adil bir karşılaştırma için algoritmaların parametreleri şu şekilde seçilmiştir: (i) CLMS için $\mu_1 = 0.02$, (ii) ACLMS için $\mu_2 = 0.02$, (iii) CLMK için $\mu_1 = 4 \times 10^{-6}$, $\beta_1 = 0.995$ ve $\hat{p}_{1,0} = 0$, (iv) ACLMK için $\mu_2 = 4 \times 10^{-6}$, $\beta_2 = 0.995$ ve $\hat{p}_{2,0} = 0$, (v) Geleneksel ACC için $\mu_1 = \mu_2 = 0.02$, $\mu_\lambda = 5 \times 10^{-2}$ ve $\lambda_0 = 0.5$, ve (vi) Önerilen ACC için, $\mu_1 = \mu_2 = 4 \times 10^{-6}$, $\mu_\lambda = 1 \times 10^{-3}$, $\beta_1 = \beta_2 = 0.995$, $\beta = 0.95$, $\hat{p}_0 = \hat{p}_{1,0} = \hat{p}_{2,0} = 0$ ve $\lambda_0 = 0.5$.

*Şekil 4.1-Şekil 4.6*'da, sistem tanımlama senaryoları 1, 2 ve 3 için önerilen ACC'nin MSE (dB) eğrisi ve karıştırma parametresi değişimi sunulmuştur.

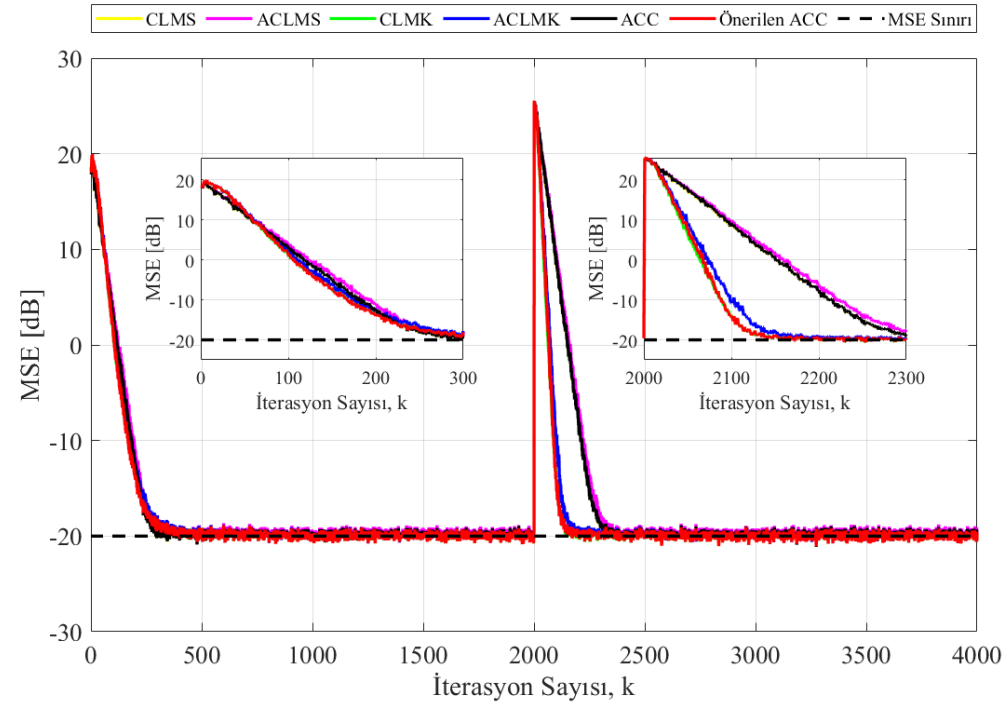


(a)

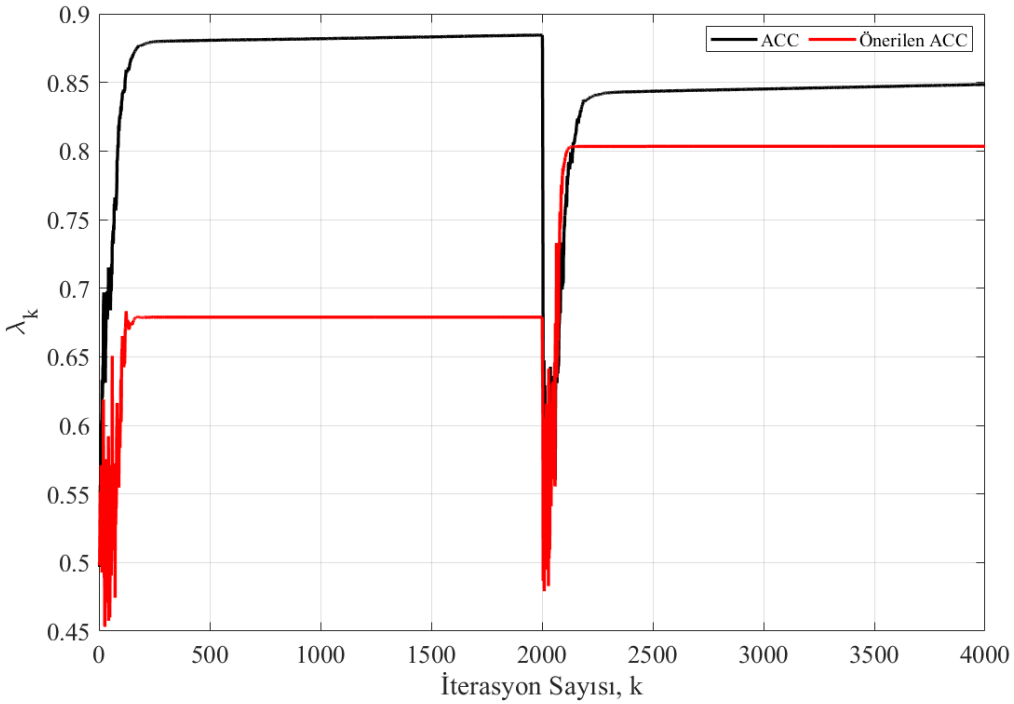


(b)

**Şekil 4.1.** *Senaryo 1 için önerilen ACC'nin SNR=20 dB'de (a) MSE (dB) eğrisi (b) karıştırma parametresi değişimi*

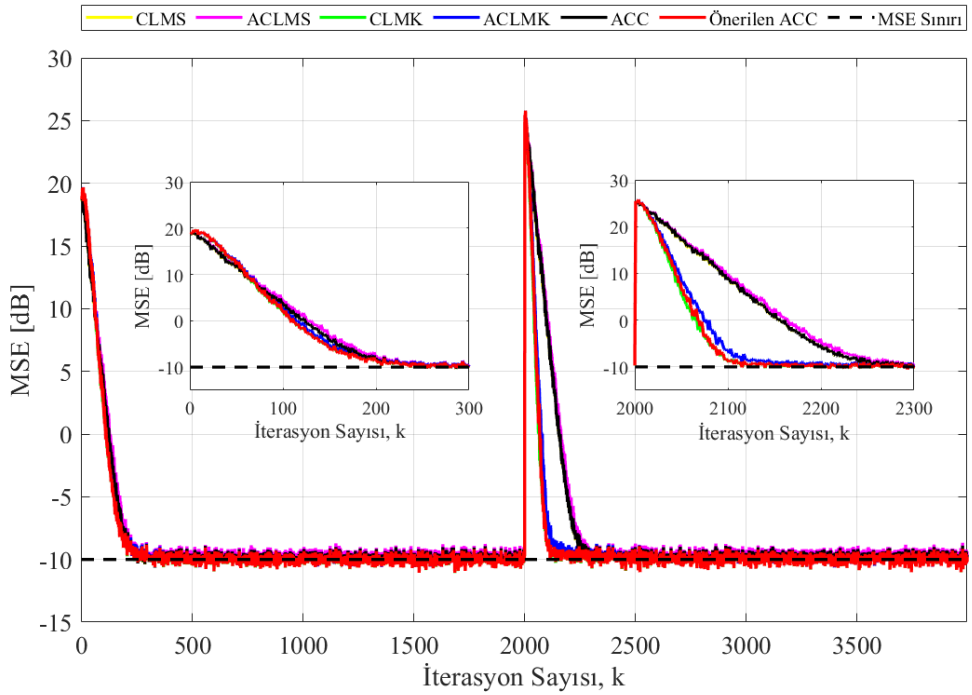


(a)

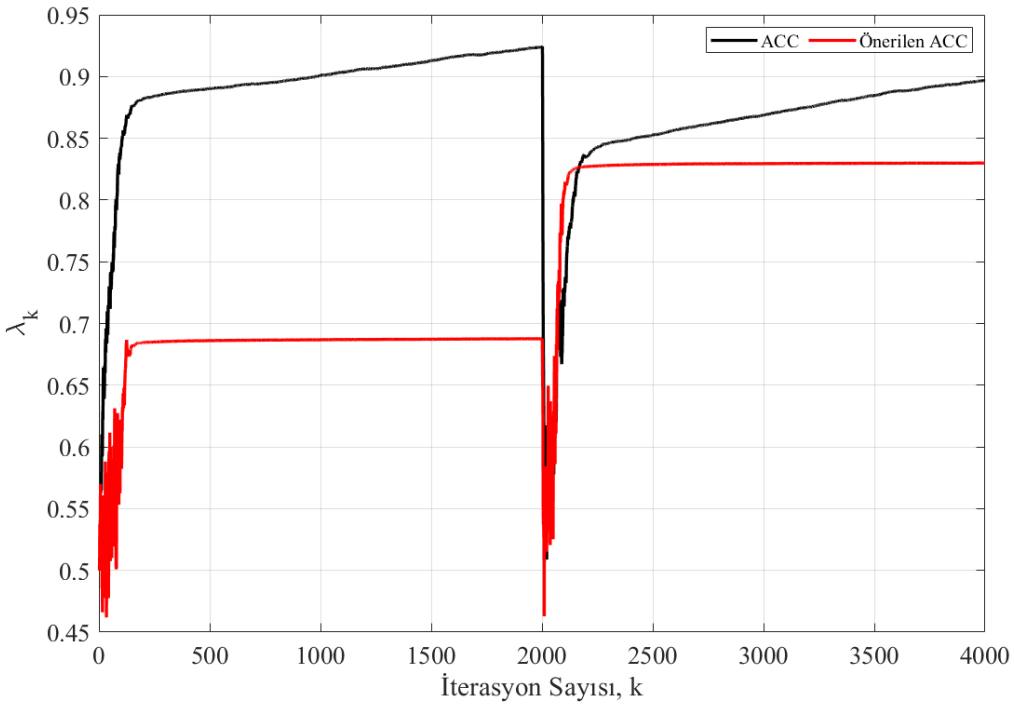


(b)

**Şekil 4.2.** *Senaryo 1 için önerilen ACC'nin SNR=10 dB'de (a) MSE (dB) eğrisi (b) karıştırma parametresi değişimi*

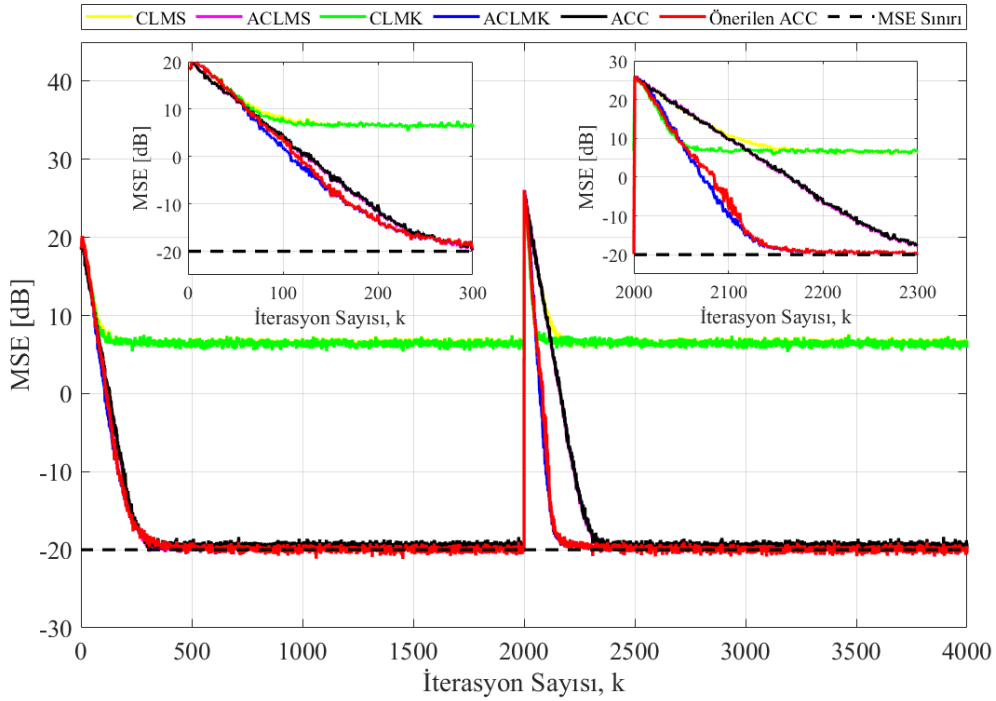


(a)

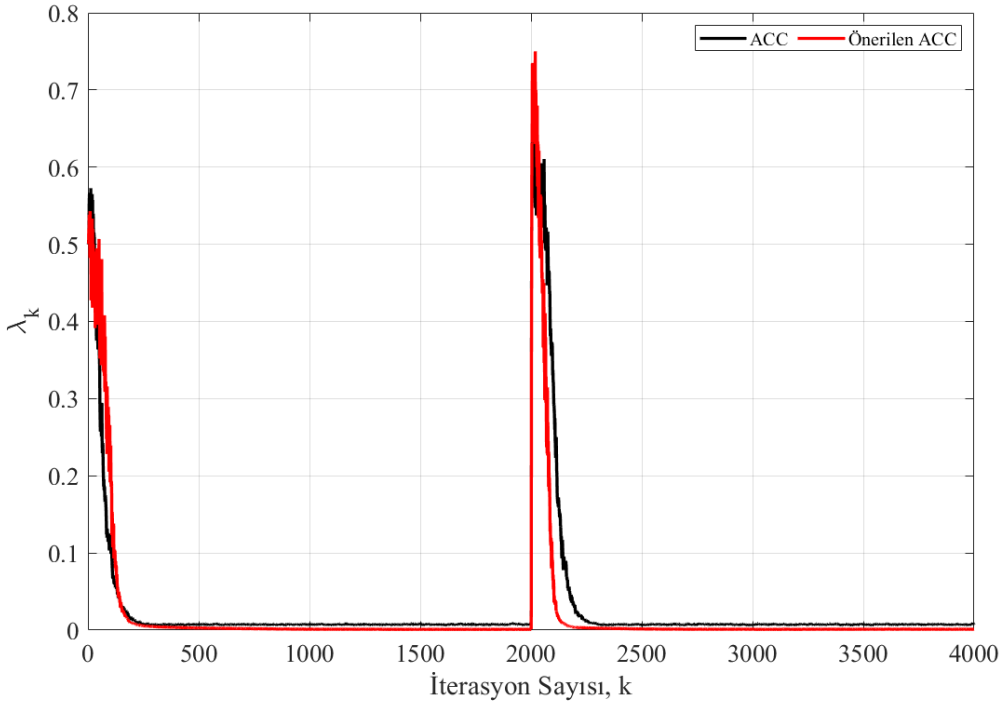


(b)

**Şekil 4.3.** *Senaryo 2 için önerilen ACC'nin SNR=20 dB'de (a) MSE (dB) eğrisi (b) karıştırma parametresi değişimi*

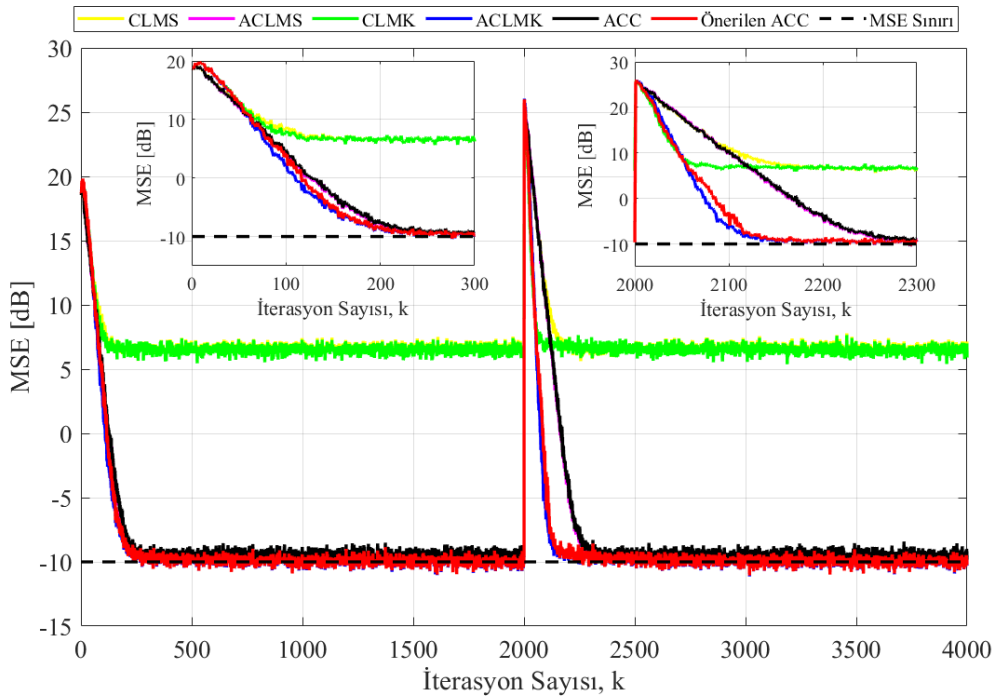


(a)

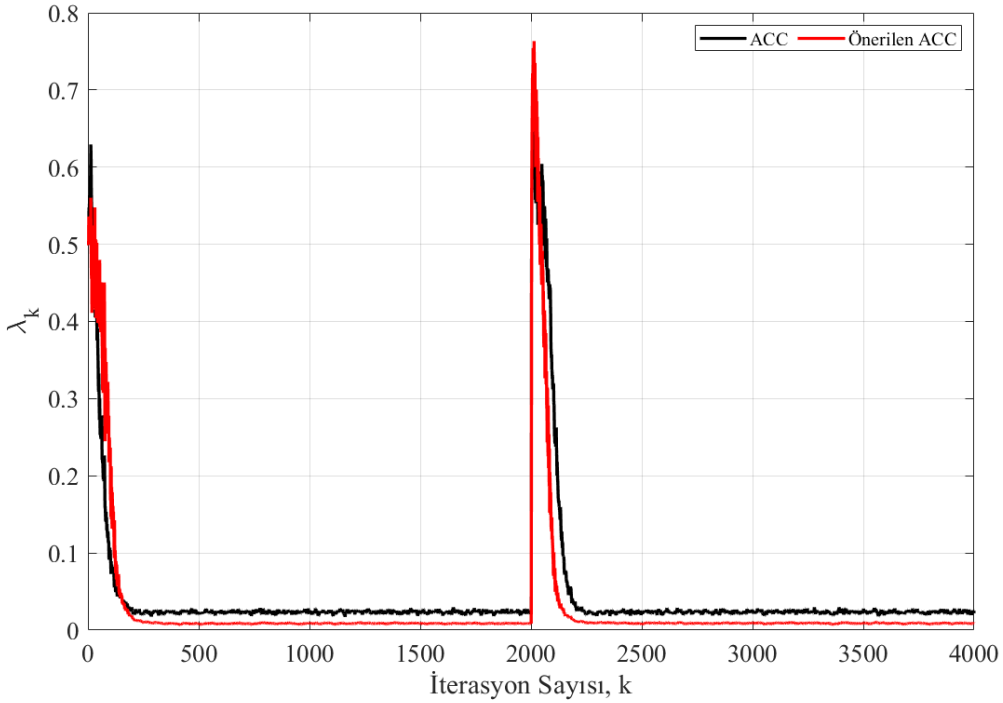


**Şekil 4.4.** *Senaryo 2 için önerilen ACC'nin SNR=10 dB'de (a) MSE (dB) eğrisi (b) karıştırma parametresi değişimi*

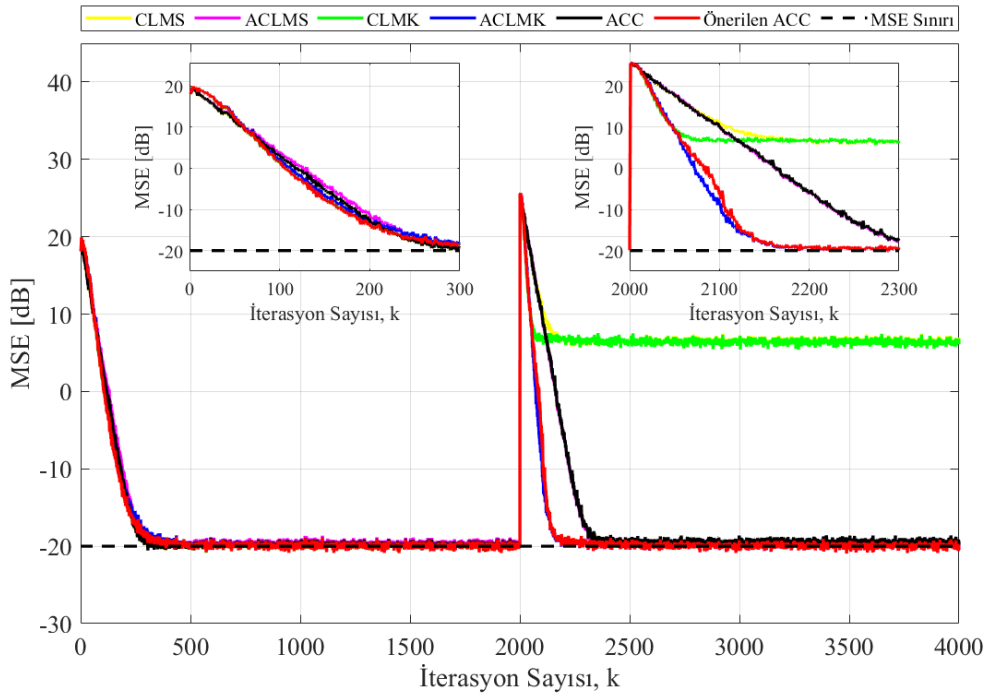


(a)

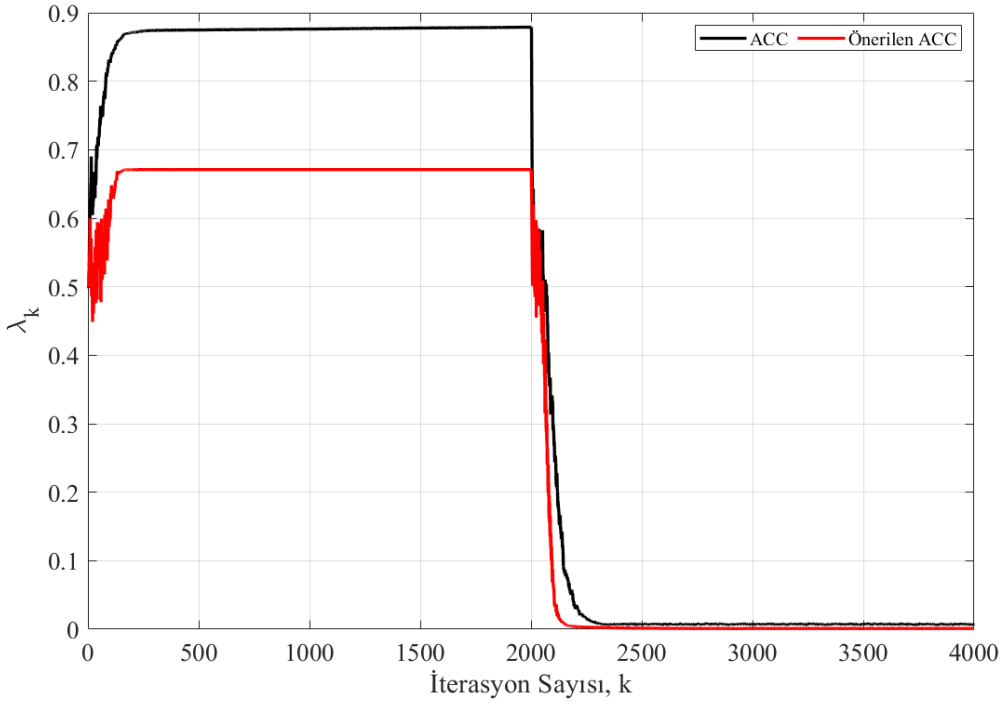


(b)

**Şekil 4.5.** *Senaryo 3 için önerilen ACC'nin SNR=20 dB'de (a) MSE (dB) eğrisi (b) karıştırma parametresi değişimi*

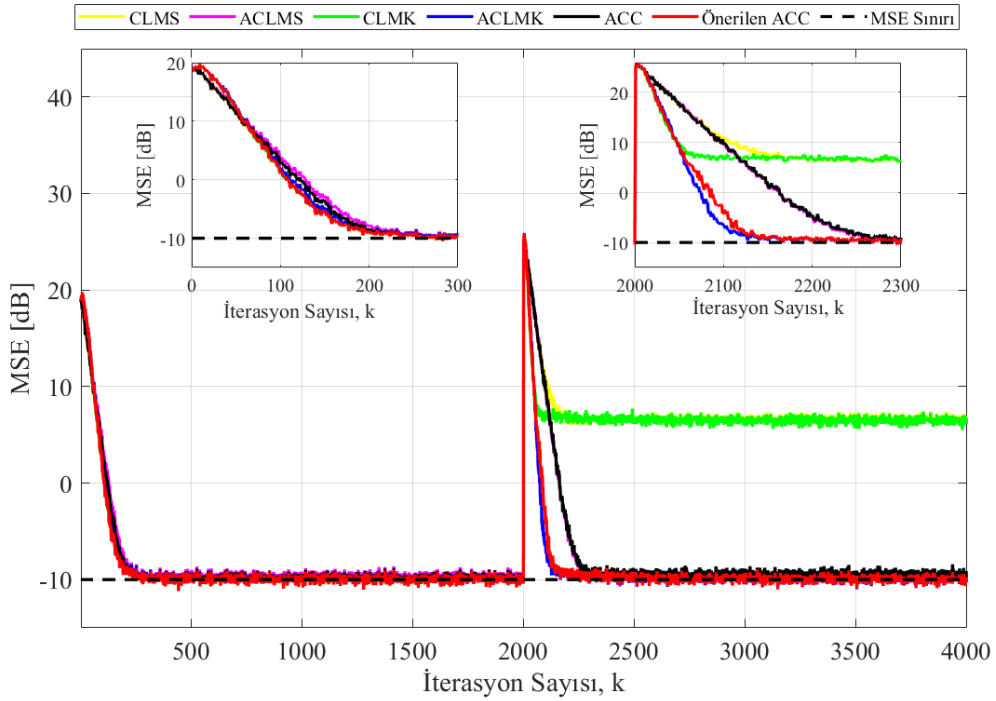


(a)

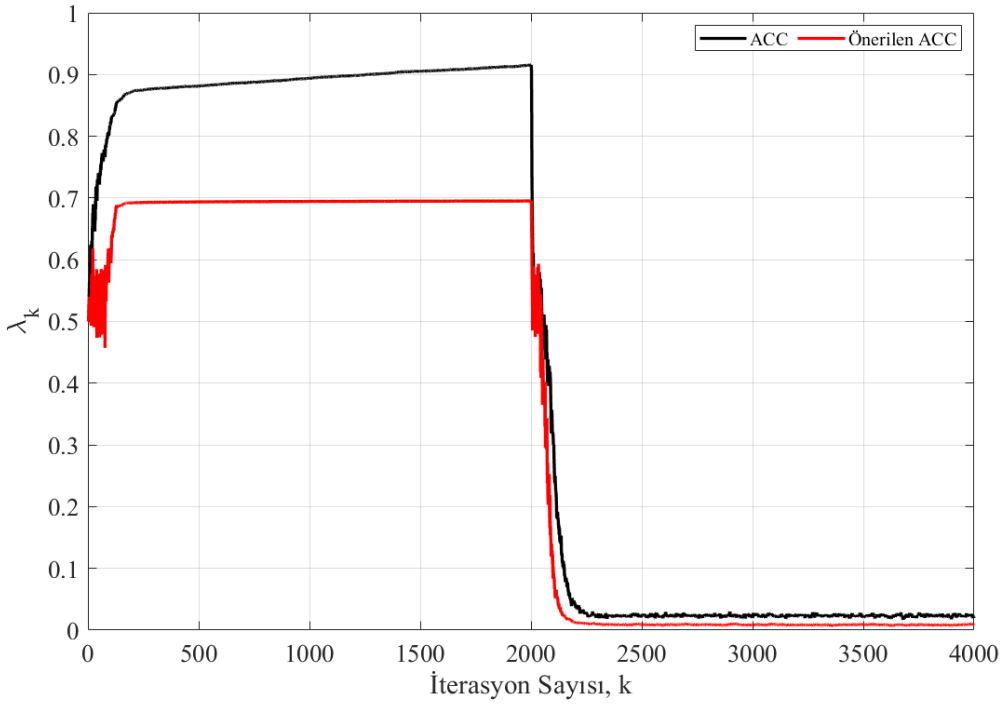


(b)

**Şekil 4.6.** *Senaryo 3 için önerilen ACC'nin SNR=10 dB'de (a) MSE (dB) eğrisi (b) karıştırma parametresi değişimi*

**Tablo 4.1.** *SNR= 20 dB gürültü seviyesinde sistem tanımlama senaryoları için tüm algoritmaların ortalaması alınmış kararlı durum MSE değerleri*

| Senaryolar | Aralıklar | Gürültünün Varyansı | CLMS | ACLMS | CLMK | ACLMK | ACC | Önerilen ACC |
|---|---|---|---|---|---|---|---|---|
| 1 | $1 \le k \le 2000$ | $\sigma_n^2 = 0.01$ | 0.0104 | 0.0109 | 0.0101 | 0.0102 | 0.0104 | **0.0101** |
| | $2000 < k < 4000$ | $\sigma_n^2 = 0.01$ | 0.0104 | 0.0109 | 0.0100 | 0.0101 | 0.0104 | **0.0100** |
| 2 | $1 \le k \le 2000$ | $\sigma_n^2 = 0.01$ | 4.5010 | 0.0109 | 4.3966 | 0.0102 | 0.0115 | **0.0102** |
| | $2000 < k < 4000$ | $\sigma_n^2 = 0.01$ | 4.4940 | 0.0109 | 4.3904 | 0.0101 | 0.0115 | **0.0101** |
| 3 | $1 \le k \le 2000$ | $\sigma_n^2 = 0.01$ | 0.0104 | 0.0109 | 0.0101 | 0.0102 | 0.0104 | **0.0101** |
| | $2000 < k < 4000$ | $\sigma_n^2 = 0.01$ | 4.4952 | 0.0109 | 4.3913 | 0.0101 | 0.0115 | **0.0101** |

**Tablo 4.2.** *SNR= 10 dB gürültü seviyesinde sistem tanımlama senaryoları için tüm algoritmaların ortalaması alınmış kararlı durum MSE değerleri*

| Senaryolar | Aralıklar | Gürültünün Varyansı | CLMS | ACLMS | CLMK | ACLMK | ACC | Önerilen ACC |
|---|---|---|---|---|---|---|---|---|
| 1 | $1 \le k \le 2000$ | $\sigma_n^2 = 0.1$ | 0.1039 | 0.1087 | 0.1001 | 0.1006 | 0.1040 | **0.1002** |
| | $2000 < k < 4000$ | $\sigma_n^2 = 0.1$ | 0.1045 | 0.1092 | 0.1007 | 0.1012 | 0.1046 | **0.1007** |
| 2 | $1 \le k \le 2000$ | $\sigma_n^2 = 0.1$ | 4.5910 | 0.1089 | 4.4868 | 0.1008 | 0.1146 | **0.1013** |
| | $2000 < k < 4000$ | $\sigma_n^2 = 0.1$ | 4.5843 | 0.1087 | 4.4826 | 0.1007 | 0.1144 | **0.1013** |
| 3 | $1 \le k \le 2000$ | $\sigma_n^2 = 0.1$ | 0.1044 | 0.1091 | 0.1006 | 0.1011 | 0.1045 | **0.1007** |
| | $2000 < k < 4000$ | $\sigma_n^2 = 0.1$ | 4.5849 | 0.1087 | 4.4828 | 0.1008 | 0.1145 | **0.1014** |

Önerilen ACC'nin başarımını daha iyi değerlendirmek amacıyla, Tablo 4.1 ve 4.2'de tüm algoritmaların sırasıyla SNR=20 dB ve SNR=10 dB gürültü seviyelerinde ortalaması alınmış kararlı durum başarımları gösterilmiştir. Şekil 4.1-4.6 ve Tablo 4.1-4.2'de verilen benzetim sonuçları dikkate alınarak aşağıdaki yorumları yapılmıştır:

- Sistem tanımlama senaryosu 1'de, $1 \le k \le 2000$ aralığı için tüm algoritmalar hemen hemen aynı yakınsama dinamiklerini göstermiştir ki bu da beklenen bir durumdur çünkü (4.1)'deki bilinmeyen sistem SL modeline dayanmaktadır. Bununla birlikte, $2000 < k < 4000$ aralığı için, (4.2)'deki gibi bilinmeyen sistemin ağırlık katsayıları negatif değerleriyle aniden değiştirildiğinde, önerilen ACC, bu değişiklikleri doğru bir şekilde izlemiş ve yeni karıştırma parametresi güncelleme kuralı sayesinde, CLMK algoritmasının genel filtre çıkışında baskın olmasını sağlayarak geleneksel ACC'den daha hızlı yakınsama oranını göstermiştir.

- Sistem tanımlama senaryosu 2 için, (4.2) ve (4.3)'deki bilinmeyen sistemler WL modeline tabanlıdır. Bu nedenle, $1 \le k \le 4000$ aralığı için önerilen ACC, geleneksel ACC, ACLMK ve ACLMS, MSE (dB) ve yakınsama oranı açısından CLMS ve CLMK'dan daha iyi başarım göstermektedir. İlk senaryoya benzer şekilde, özellikle $2000 < k < 4000$ için önerilen ACC, karıştırma parametresini yeni güncelleme kuralına göre adaptif bir şekilde ayarlayarak ACLMK'ya yakın bir davranış sergilemiştir. Böylece önerilen ACC, istenen MSE (dB) sınırına çok hızlı bir şekilde yakınsamakta ve geleneksel ACC'den daha düşük bir kararlı durum MSE (dB) sağlamaktadır.

- Sistem tanımlama senaryosu 3, CLMK ve ACLMK'nın avantajlarından iş birliği içinde yararlanan yeni karıştırma parametresi sayesinde önerilen ACC'nin üstün başarımını açıkça ortaya koymaktadır. Önerilen ACC, hem $1 \le k \le 4000$ hem de $2000 < k < 4000$ için, geleneksel olana kıyasla yüksek doğrulukla bilinmeyen sistemlerin karakteristik özelliklerine uyarlanmıştır.

- Önerilen ACC'de $\lambda_k$ karıştırma parametresinin değişimi, düşünülen bilinmeyen sistemlerin karakteristik davranışı hakkında da önemli bir bilgi sağlamıştır. Örneğin, SL bilinmeyen sistemler için karıştırma parametresi $\lambda_k$ bire yakınsarken, WL bilinmeyen sistemler için sıfıra yaklaşmıştır (bkz. *Şekil 4.1-4.6*).

- Ayrıca, Tablo 4.1 ve 4.2'den de anlaşıldığı gibi, önerilen ACC'nin, senaryolarda kurgulanan bilinmeyen sistemlerin gereksinimlerine göre toplam çıkışında baskın olan CLMK veya ACLMK'nınkiyle karşılaştırılabilir ortalaması alınmış kararlı durum MSE değerleri ürettiği gözlemlenmiştir. Tüm bu sonuçlar incelendiğinde, önerilen ACC, geleneksel ACC'den daha üstün ortalaması alınmış kararlı durum MSE değerlerine sahip olduğu gözlemlenmiştir.

### 4.2.Tahmin Senaryoları

Önerilen ACC'nin bir-adım-ileri tahmin başarımı, dairesel ve dairesel olmayan kompleks değerli sinyaller üzerinde MSE (dB), standart tahmin kazancı $R_p$ (dB) ve mutlak hata açısından test edilmiştir ve CLMK [22] ve ACLMK [20]'nın tahmin başarımı ile karşılaştırılmıştır. Bu kapsamda kurgulan tahmin senaryolarında kullanılan kompleks değerli sinyaller aşağıdaki gibidir:

$$d_k = 1.79d_{k-1} - 1.85d_{k-2} + 1.27d_{k-3} - 0.41d_{k-4} + n_k \tag{5.7}$$

burada $n_k$, kompleks değerli rastgele düzgün (uniform) dağılıma sahip dairesel gürültü sinyalidir.

Tahmin senaryosu 2 için, dairesel olmayan kompleks değerli kaotik Ikeda haritası [4] kullanılmıştır. Bu sinyale ait denklem aşağıda verilmiştir:

$$d_k = u_k + jv_k \tag{5.8}$$

burada $t_{k-1} = 0.4 - 6/(1+u_{k-1}^2 + v_{k-1}^2)$, $u_k = 1 + 0.8\left[u_{k-1}\cos(t_{k-1}) - v_{k-1}\sin(t_{k-1})\right]$, $v_k = 0.8\left[u_{k-1}\sin(t(k-1)) + v_{k-1}\cos(t(k-1))\right]$, $u(0) \sim N(0, 0.1)$ ve $v(0) \sim N(0, 0.1)$.

Son olarak, tahmin senaryosu 3'te, sağ ve sol ellere ait iki farklı iki-boyutlu (two dimentional) patolojik dinlenme titremeleri (pathological resting tremor), tek tur gerçek dünya sinyalleri olarak kullanılmıştır. Bu sinyaller "Motus Bioengineering Inc." veri setinden [40] (veri seti içerisinde "ChProb3b" ve "ChProb3c" olarak adlandırılmıştır) [40] indirilmiş ve kompleks alanda şu şekilde tanımlanmıştır [39]:

$$d_k = T_k^{RH} + jT_k^{LH} \tag{5.9}$$

burada $T_k^{RH}$ ve $T_k^{LH}$ sırasıyla sağ ve sol dinlenme titremelerini temsil eder.

Tüm tahmin senaryoları için, bu çalışmada koşturulan algoritmalarda kullanılan FIR filtrelerin dereceleri $N = 10$ olarak ayarlanmıştır. Senorya 1 ve 2'ye ait benzetim sonuçları, 500 bağımsız koşturmanın ortalaması alınarak üretilmiştir.

Adil bir karşılaştırma için tahmin senaryolarındaki algoritmaların parametreleri şu şekilde ayarlanmıştır: (i) CLMK için $\mu_1 = 4.5\times10^{-5}$, $\beta_1 = 0.995$, ve $\hat{p}_{1,0} = 0$, (ii) ACLMK için $\mu_2 = 4.5\times10^{-5}$, $\beta_2 = 0.995$, $\hat{p}_{2,0} = 0$ (iii) Önerilen ACC için $\mu_1 = \mu_2 = 4.5\times10^{-5}$, $\mu_\lambda = 1\times10^{-3}$, $\beta_1 = \beta_2 = 0.995$, $\beta = 0.95$, $\hat{p}_0 = \hat{p}_{1,0} = \hat{p}_{2,0} = 0$, ve $\lambda_0 = 0.5$. Öte yandan, gerçek dünyadaki patolojik dinlenme titremelerini içeren tahmin senaryosu 3 için tüm algoritmaların sadece adım büyüklüğü değerleri $\mu_1 = \mu_2 = 5\times10^{-3}$ olarak değiştirilmiştir.

*Şekil 4.7*, tahmin senaryolarında dikkate alınan sinyallerin geometrik görünümlerini göstermektedir. *Şekil 4.7*'de görüldüğü gibi, AR(4) sinyali dairesel bir davranışa sahiptir ve diğer üç sinyal ise dairesel olmayan sinyallerdir. *Şekil 4.8* ve *4.9*, sırasıyla tahmin senaryoları 1 ve 2 için önerilen ACC'nin MSE (dB) eğrilerini ve $\lambda_k$ karıştırma parametresi $\lambda_k$ 'nın değişimlerini gösterirken, *Şekil 4.10* ve *4.11*, tahmin senaryosu 3'te kullanılan el titreme sinyalleri için önerilen ACC'nin mutlak hata eğrilerini ve karıştırma parametresi $\lambda_k$ 'nın değişimlerini göstermektedir. Bu sonuçlara ek olarak, tüm tahmin senaryoları için önerilen ACC'nin standart tahmin kazancı $R_p$ (dB) değerleri Tablo 4.3'te sunulmuştur. Standart tahmin kazancı $R_p$, dB cinsinden $R_p = 10\log10\left(\sigma_d^2/\hat{\sigma}_e^2\right)$ denklemi kullanılarak hesaplatılmıştır ve burada $\sigma_d^2$ ve $\hat{\sigma}_e^2$ sırasıyla beklenen sinyalin ve tahmin edilen hata sinyalinin varyanslarını temsil etmektedir.

*Şekil 4.8-4.11* ve Tablo 4.3'te verilen benzetim sonuçlarına göre aşağıdaki yorumlar yapılmıştır:

- Önerilen ACC, tahmin senaryosu 1'de, hızlı bir yakınsama oranı elde etmek için ilk aşamada ACLMK'yı tercih ederken, yakınsama sonrasında daha iyi bir kararlı durum MSE (dB) başarımı sağlamak için CLMK'yı tercih etmiştir. Böylece, önerilen ACC, hem CLMK hem de ACLMK'dan daha iyi bir tahmin başarımı göstermiştir.

- Önerilen ACC, tahmin senaryosu 2'de, Ikeda sinyali dairesel olmayan bir dağılıma sahip olduğundan, ACLMK algoritmasınınkiyle aynı olan ama CLMK'dan daha üstün bir MSE (dB) başarımı sergilemiştir.

- Önerilen ACC, tahmin senaryosu 3'te, iki gerçek dünya el titreme sinyali için, yeni karıştırma parametresi güncelleme kuralının yardımıyla, mutlak hata başarımı açısından CLMK ve ACLMK'dan daha iyi başarım göstermiştir.

- Önerilen ACC'deki karıştırma parametresi $\lambda_k$'nın değişimi, ele alınan sinyallerin karakteristik davranışı hakkında da bilgi vermektedir. Örneğin, karıştırma parametresi $\lambda_k$, dairesel sinyaller için bire yakınsar, dairesel olmayan sinyaller için sıfıra yaklaşır (bkz *Şekil 4.8-4.11*).

- Son olarak, Tablo 4.3'de, önerilen ACC, standart tahmin kazancı $R_p$ (dB) açısından özellikle senaryo 1 ve 3 için tahmin başarımını önemli ölçüde artırmıştır. Senaryo 2'de ise önerilen ACC'nin tahmin kazancı ACLMK'nınkiyle hemen hemen aynıdır.

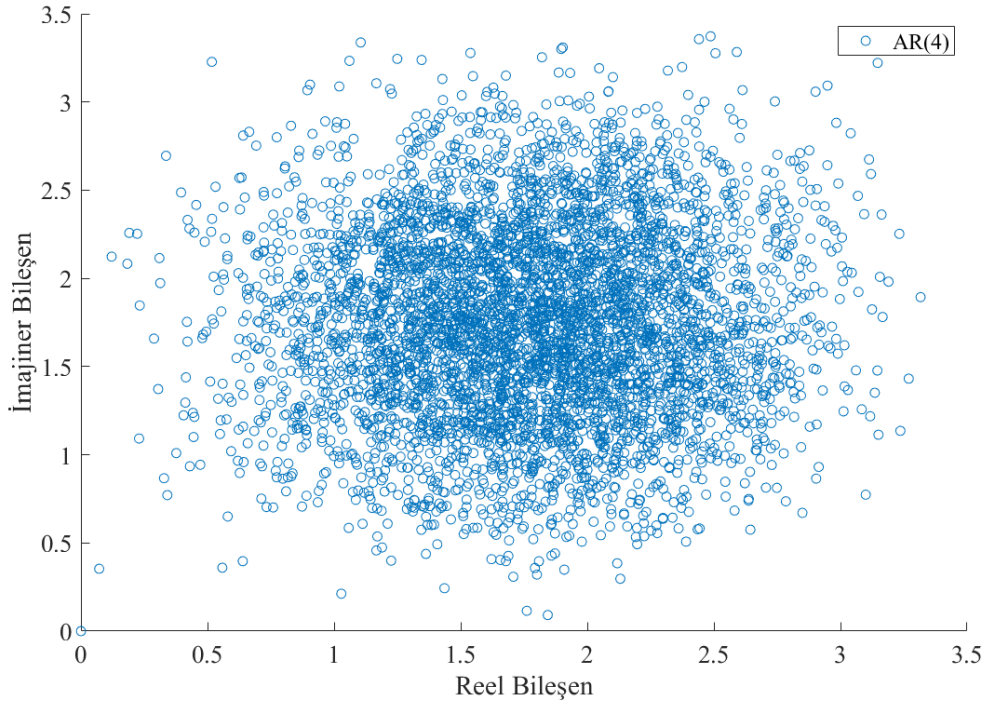
AR(4)
İmajiner Bileşen
Reel Bileşen
0
0.5
1
1.5
2
2.5
3
3.5

(a)

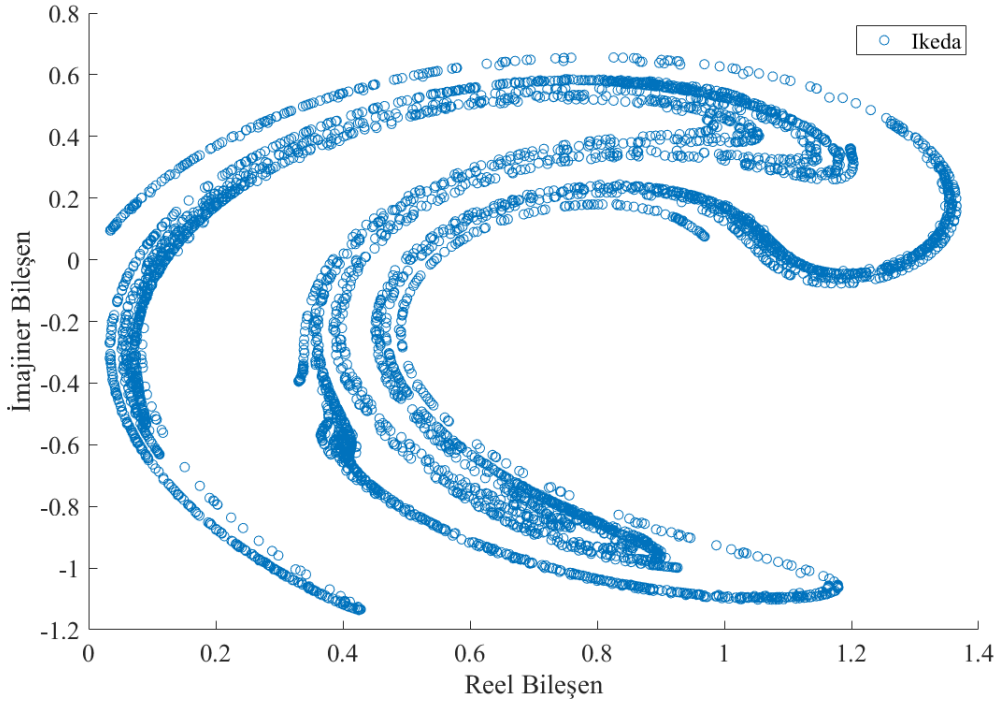
Ikeda
İmajiner Bileşen
Reel Bileşen
0.8
0.6
0.4
0.2
0
-0.2
-0.4
-0.6
-0.8
-1
-1.2
0
0.2
0.4
0.6
0.8
1
1.2
1.4

(b)

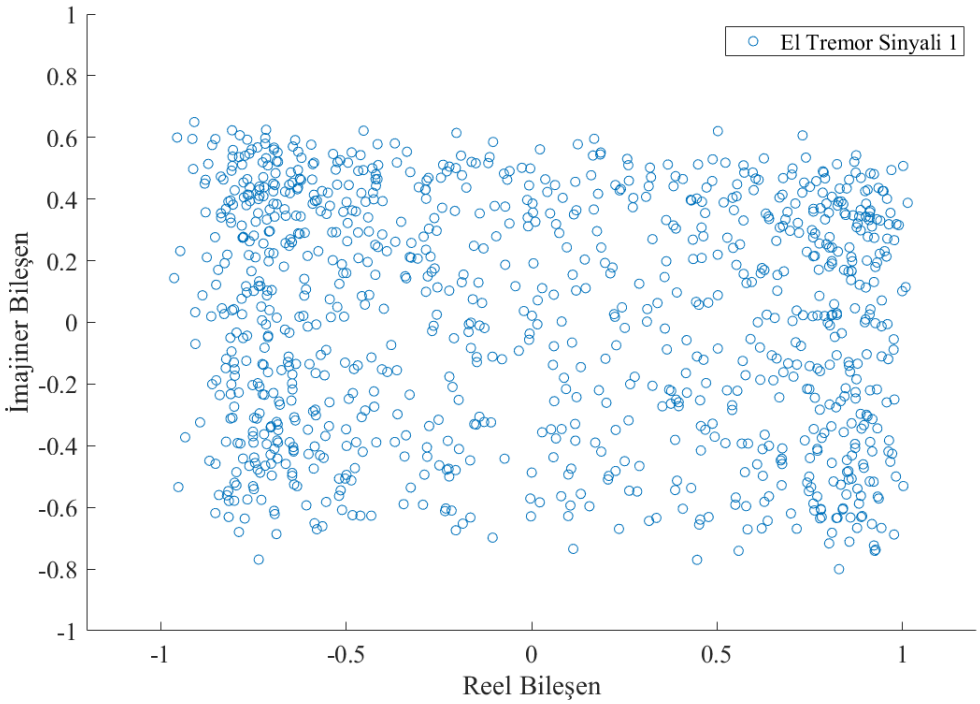


(c)

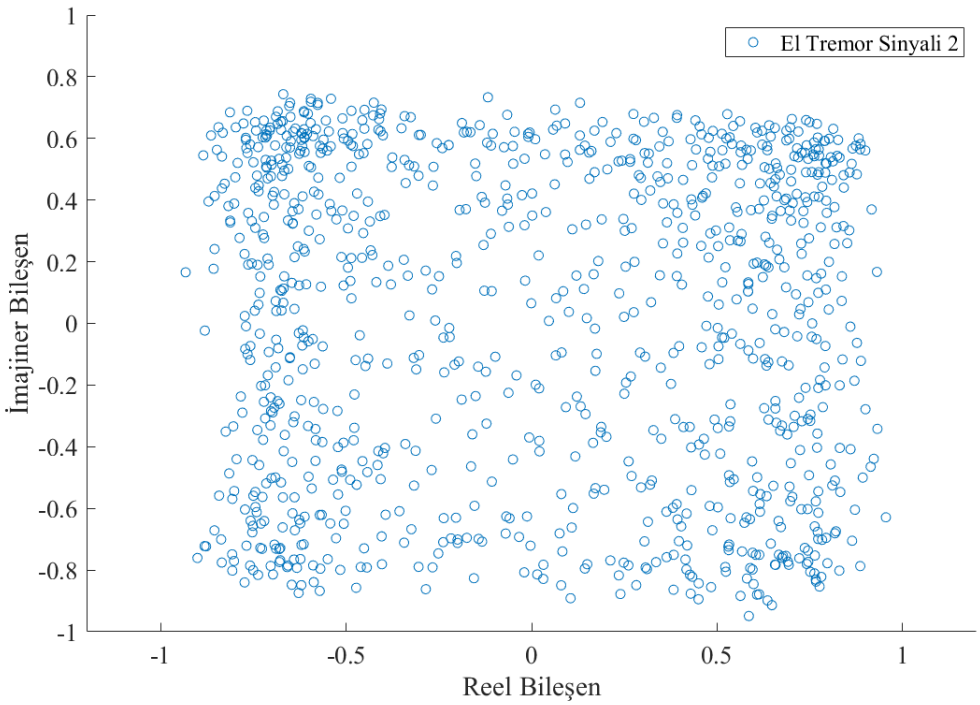


(d)

**Şekil 4.7**. *Tahmin senaryolarında kullanılan kompleks değerli sinyallerin geometrik görünümleri (a) AR(4) (b) Ikeda (c) Tremor sinyali 1 (d) Tremor sinyali 2*

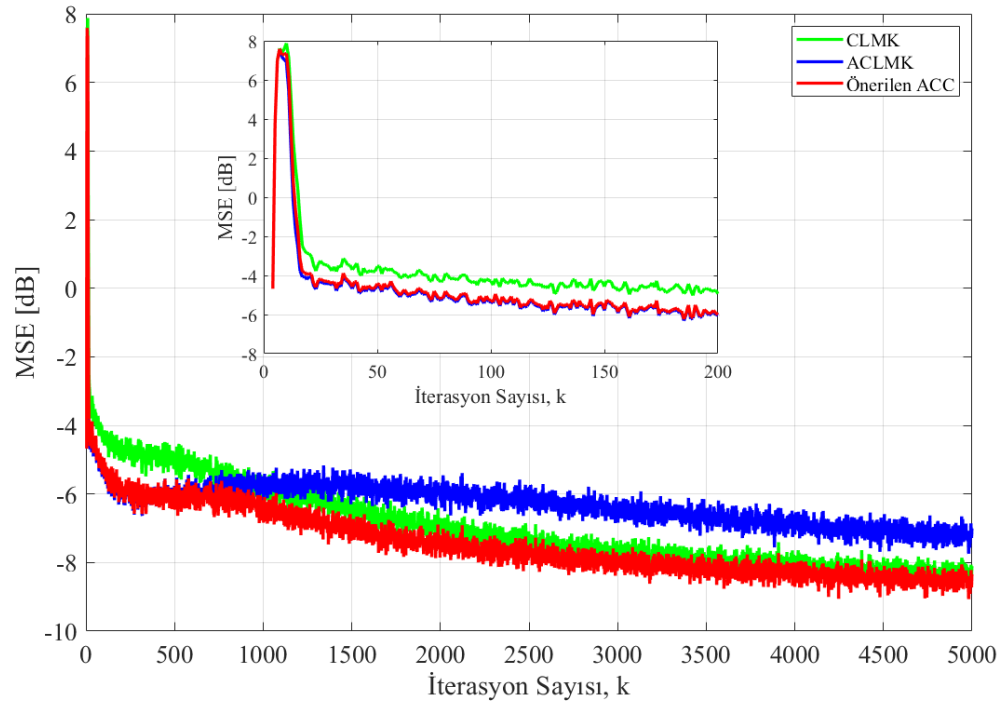


(a)

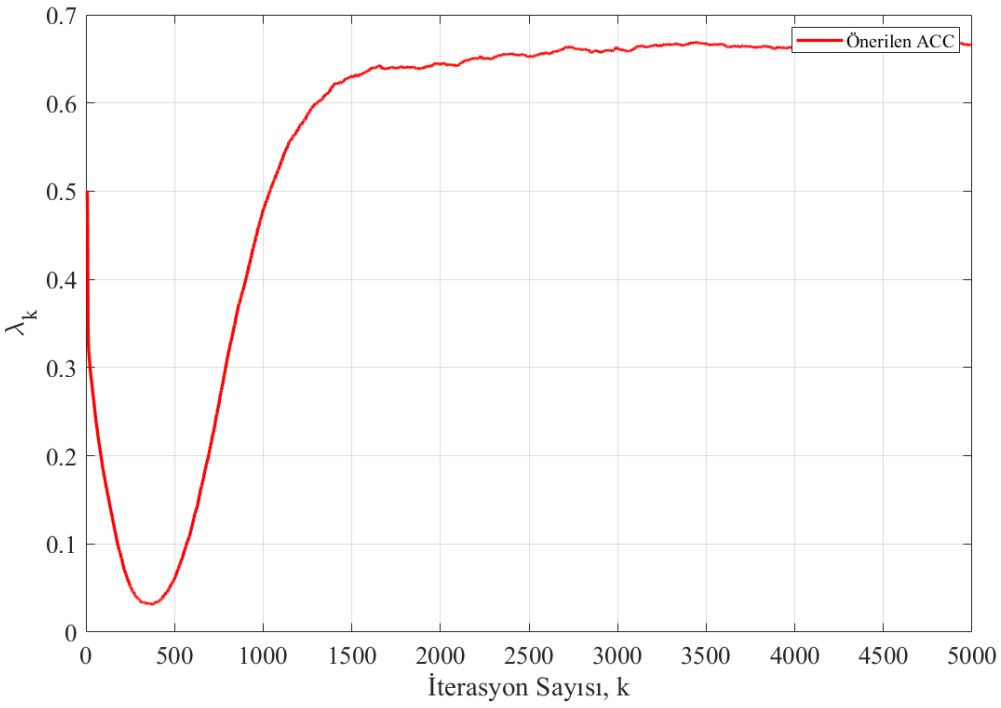


(b)

**Şekil 4.8**. *Senaryo 1 için önerilen ACC'nin (a) MSE (dB) eğrisi (b) karıştırma parametresi değişimi*

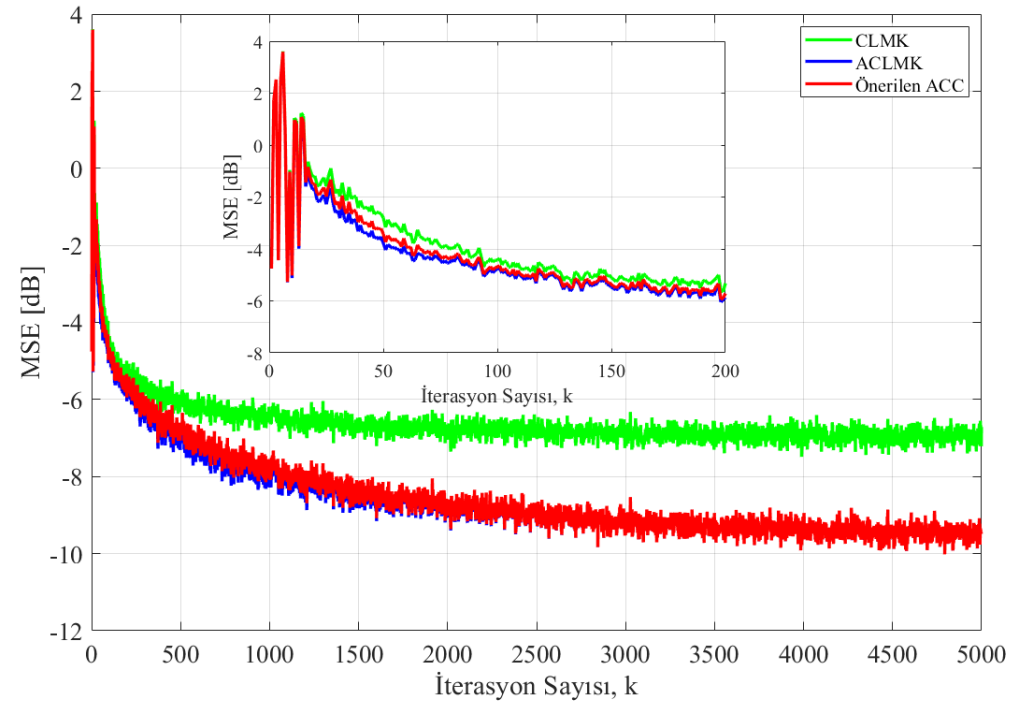


(a)

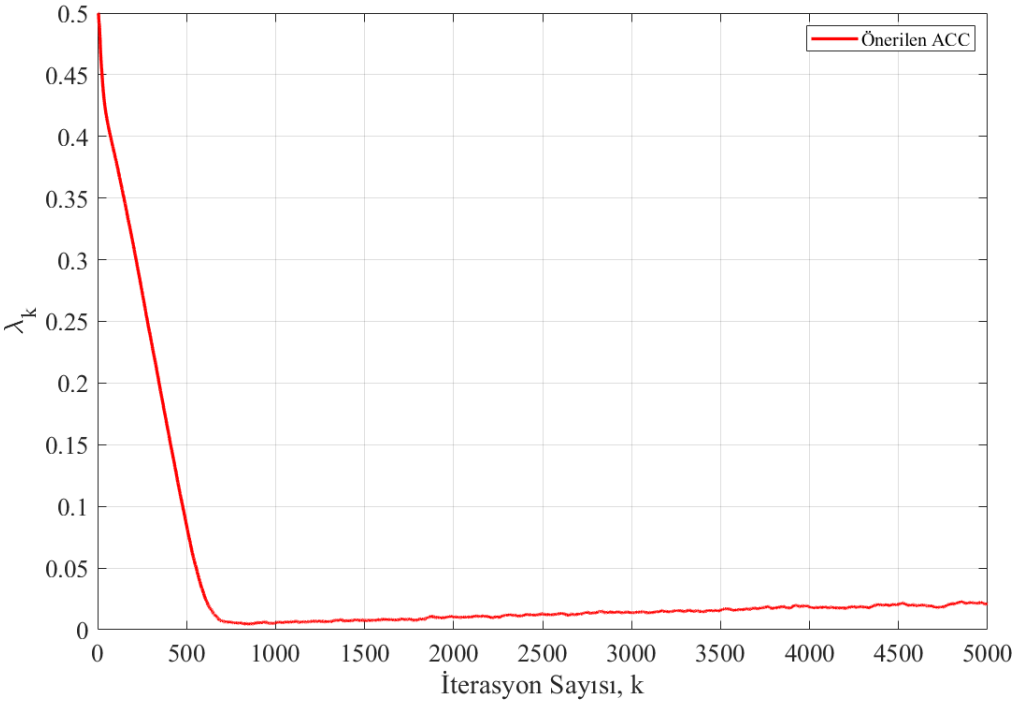


(b)

**Şekil 4.9.** *Senaryo 2 için önerilen ACC'nin (a) MSE (dB) eğrisi (b) karıştırma parametresi değişimi*

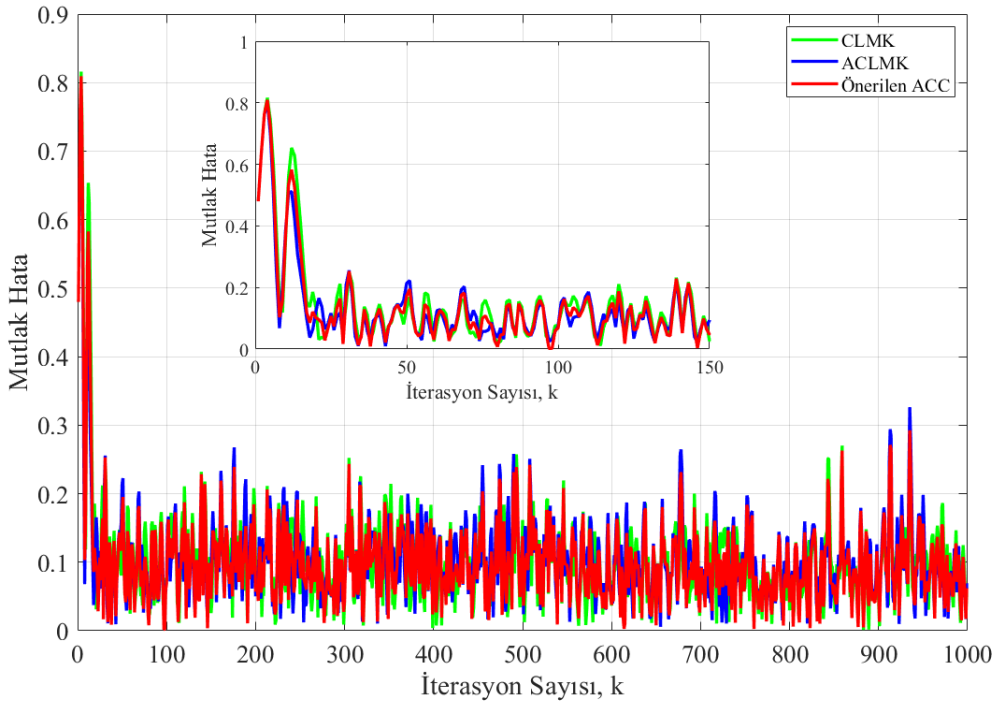


(a)

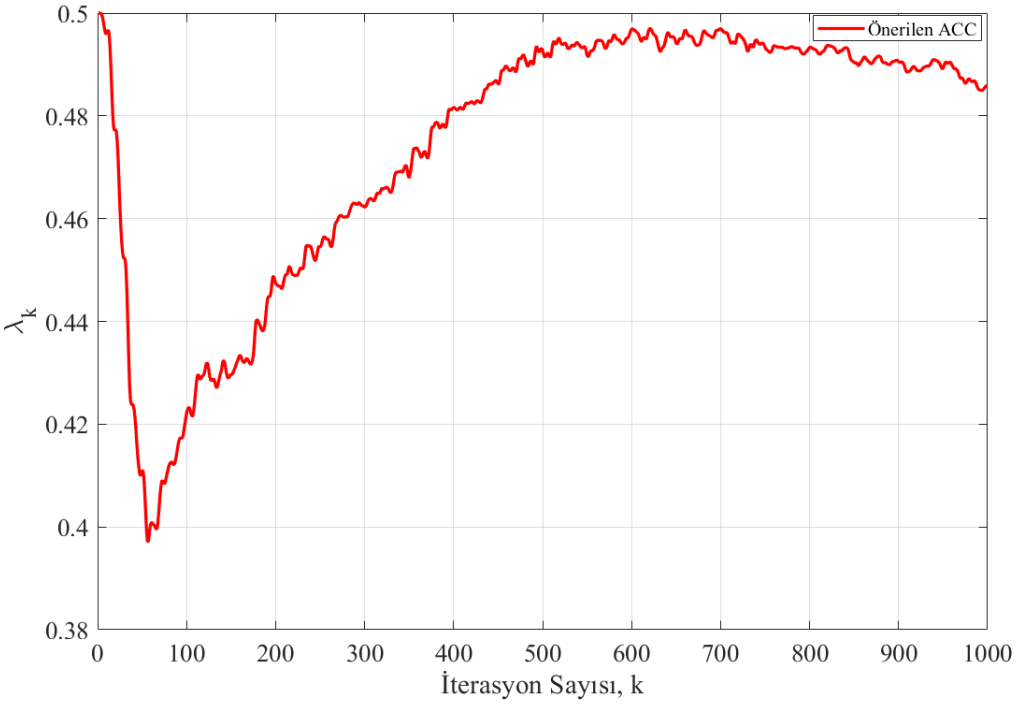


(b)

**Şekil 4.10.** *El titreme sinyali 1 için önerilen ACC'nin (a) mutlak hata eğrisi (b) karıştırma parametresi değişimi*

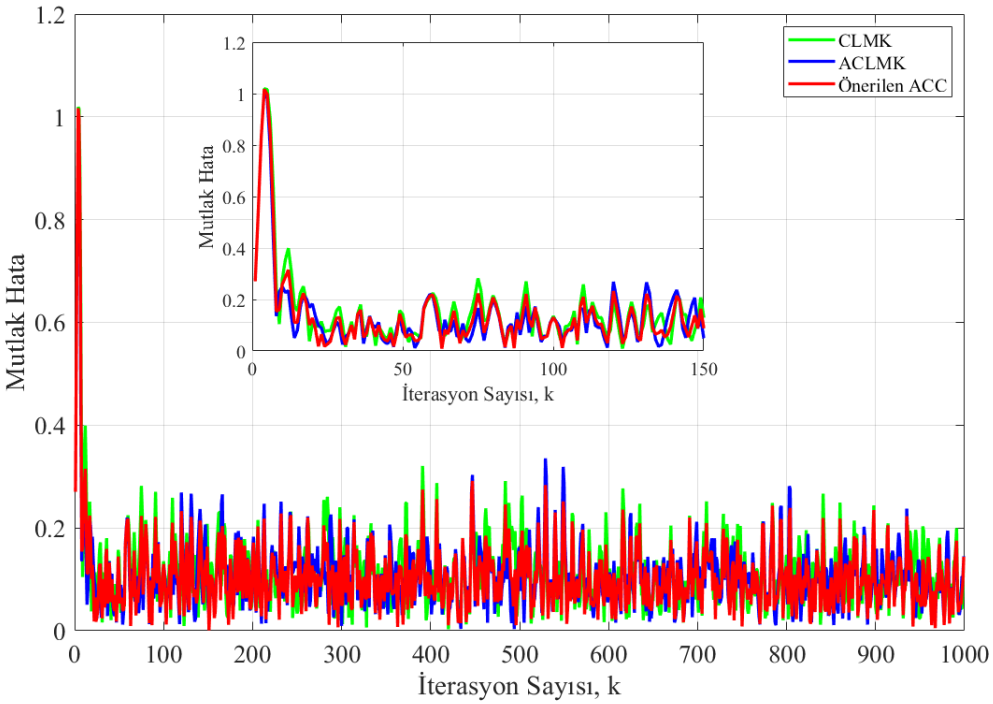


(a)

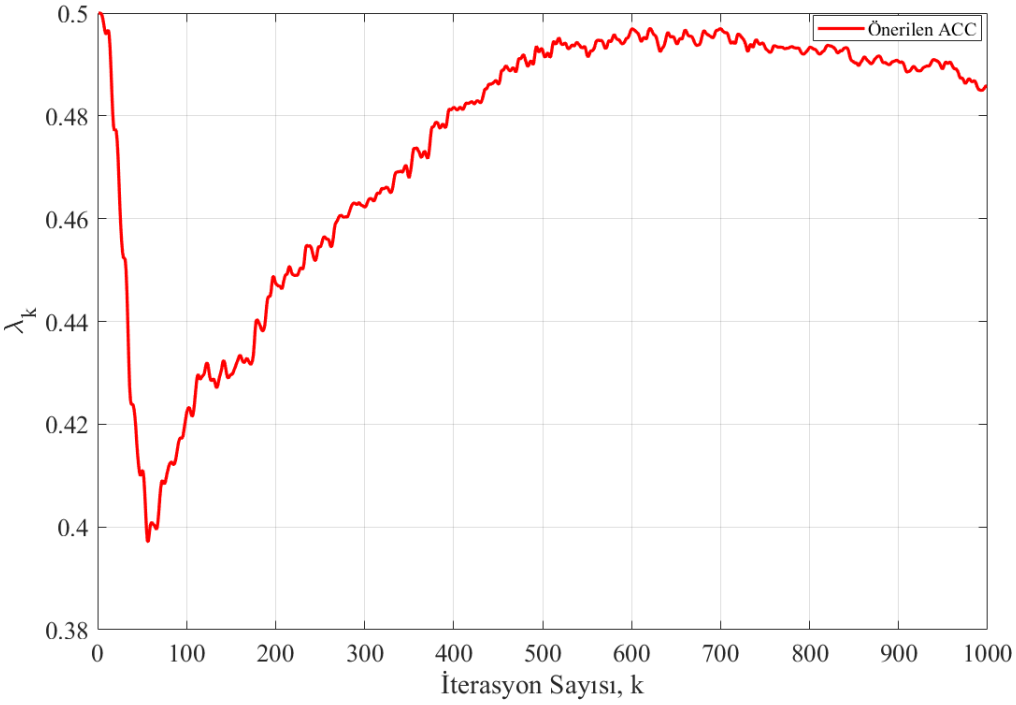


(b)

**Şekil 4.11.** *El titreme sinyali 2 için önerilen ACC'nin (a) mutlak hata eğrisi (b) karıştırma parametresi değişimi*

**Tablo 4.3.** *Tahmin Senaryoları 1, 2 ve 3 için Önerilen ACC'nin Standart Tahmin Kazanımları* $R_p$ *(dB)*

| Algoritmalar | Tahmin Senaryosu 1 | Tahmin Senaryosu 2 | Tahmin Senaryosu 3 | |
|---|---|---|---|---|
| | Dairesel ARMA(4) | Dairesel olmayan Ikeda | El Tremor Sinyali 1 | El Tremor Sinyali 2 |
| **CLMK** | 4.2104 | 2.6413 | 15.2412 | 14.7236 |
| **ACLMK** | 3.7018 | 4.4239 | 15.4948 | 15.4448 |
| **Önerilen ACC** | **4.7451** | **4.3503** | **15.6909** | **15.5079** |

# BEŞİNCİ BÖLÜM

# SONUÇ

Bu tez çalışmasında, geleneksel ACC yapısının dezavantajlarını elimine eden, dairesel ve dairesel olmayan kompleks değerli sinyalleri etkili bir şekilde işleyen, CLMK [22] ve ACLMK [20] algoritmalarının bireysel avantajlarından iş birlikçi bir şekilde faydalanan yeni bir adaptif konveks kombinasyon (ACC) önerilmiştir. Bu amaçla, ilk önce kompleks düzlemdeki genel hata sinyalinin kurtosisine dayalı maliyet fonksiyonu tanımlanmıştır ve ardından önerilen ACC'ye ait yeni bir karıştırma parametresi güncelleme kuralı türetmek için bu maliyet fonksiyonu minimize edilmiştir. Bu sayede, önerilen ACC, CLMK ve ACLMK algoritmalarının iş birlikçi bir şekilde çalışmasını sağlamıştır. Önerilen ACC, yeni karıştırma parametresi güncelleme kuralı yardımıyla, yakınsama oranı ve kararlı durum hatası açısından genel filtreleme başarımını iyileştirmek için filtrenin genel çıkışında çalışma ortamlarının gereksinimlerine göre CLMK veya ACLMK'yı adaptif bir şekilde baskın hale getirmiştir. Aynı zamanda, önerilen ACC'deki karıştırma parametresinin değişimi, ele alınan sinyal veya sistemin karakteristik davranışı hakkında önemli bilgiler vermiştir. Örneğin karıştırma parametresi; dairesel sinyaller veya bilinmeyen SL sistemler için bir değerine yakınsarken, dairesel olmayan sinyaller veya bilinmeyen WL sistemler için sıfır değerine yakınsamıştır.

Öte yandan CLMK ve ACLMK algoritmalarının Lyapunov anlamındaki kararlılığı literatürde hala eksik olduğundan bu çalışma kapsamında bu algoritmaların Lyapunov analizleri yapılmıştır. Bunun için öncelikle bir aday Lyapunov fonksiyonu tanımlandıktan sonra gerekli cebirsel işlemler yapılmış ve ardından CLMK ve ACLMK algoritmalarının

adım büyüklüğü sınırları sırasıyla denklem (2.9) ve (2.11)'de belirlenmiştir. Belirlenen bu adım büyüklüğü sınırları, CLMK ve ACLMK algoritmasının güncelleme kuralının hangi aralıklarda Lyapunov anlamında kararlı olacağını göstermiştir. Tüm bunlara ek olarak, ilk defa bu tez çalışmasında, önerilen ACC'nin karıştırma parametresi güncelleme kuralının Lyapunov anlamında kararlılığı teorik olarak analiz edilmiştir. Önerilen ACC'nin Lyapunov anlamında kararlığını sağlayan adım büyüklüğü sınırları ise denklem (3.20)'deki gibi bulunmuştur.

Önerilen ACC'nin üstün başarımını göstermek için üç farklı sistem tanımlama senaryosu kurgulanmıştır ve önerilen ACC'nin MSE (dB) ve ortalaması alınmış kararlı durum MSE'si; CLMS, ACLMS, CLMK, ACLMK ve geleneksel ACC'ninki ile karşılaştırılmıştır. Ayrıca, önerilen ACC'nin bir-adım-ileri tahmin başarımı dairesel ve dairesel olmayan kompleks değerli sinyaller üzerinde MSE (dB), standart tahmin kazancı $R_p$ (dB) ve mutlak hata açısından test edilmiştir ve CLMK ve ACLMK'nın tahmin başarımı ile karşılaştırılmıştır. Bu tahmin senaryolarında kompleks değerli sinyaller AR(4), Ikeda ve tremor sinyalleri olarak seçilmiştir. Böylece, önerilen ACC'nin başarımı üç farklı sistem tanımlama ve üç farklı bir-adım-ileri tahmin senaryoları üzerinde kapsamlı bir şekilde yapılan benzetimler ile incelenmiştir. Yapılan benzetimler, önerilen ACC'nin literatürdeki geleneksel ACC'ye göre üstün özelliklere sahip olduğunu ve daha iyi bir başarım sergilediğini açıkça ortaya koymuştur.

Sonuç olarak, bu tez çalışmasında CLMK ve ACLMK algoritmalarının avantajlarını etkin bir şekilde kullanan yeni bir ACC yapısı tasarlanmış ve başarımı analiz edilmiştir. Önerilen bu yapı, hem SL hem de WL yapıları kullandığından aslında lineer problemler için daha uygundur. Gelecek çalışmalarda, bu önerilen yapının içerisine kesin lineer olmayan (Strictly nonlinear, SNL) ve geniş lineer olmayan (Widely nonlinear, WNL) modeller entegre edilerek, kompleks değerli lineer olmayan dairesel ve dairesel olmayan sinyallerin işlenmesine olanak sağlanacaktır.

# KAYNAKÇA


[1] S. Haykin, *Adaptive Filter Theory*, 4th ed. Englewood Cliffs, NJ, USA: Prentice-Hall, 2002.

[2] A. H. Sayed, *Fundamentals of Adaptive Filtering*, 1st ed. John Wiley & Sons, 2003.

[3] T. Adali and S. Haykin. *Adaptive Signal Processing: Next Generation Solutions*, John Wiley & Sons, Vol. 55, 2010.

[4] D. P. Mandic and S. L. Goh, *Complex Valued Nonlinear Adaptive Filters: Noncircularity, Widely Linear and Neural Models*. New York, NY, USA: Wiley, 2009.

[5] T. Adali, P. J. Schreier, and L. L. Scharf, "Complex-valued signal processing: The proper way to deal with impropriety", *IEEE Transactions on Signal Processing*, vol. 59, no. 11, ss. 5101–5125, 2011.

[6] E. Ollila, "On the circularity of a complex random variable", *IEEE Signal Processing Letter*, vol. 15, ss. 841–844, 2008.

[7] B. Picinbono, "On circularity", *IEEE Transactions on Signal Processing*, vol. 42, ss. 3473–3482, 1994.

[8] B. Picinbono and P. Chevalier, "Widely linear estimation with complex data", *IEEE Transactions on Signal Processing*, vol. 43, no. 8, ss. 2030–2033, 1995.

[9] P. J. Schreier and L. L. Scharf, "*Statistical Signal Processing of Complex-Valued Data: The Theory of Improper and Noncircular Signals*", Cambridge, UK: Cambridge Univ. Press, 2010.

[10] P. J. Schreier and L. L. Schar, "Second-order analysis of improper complex random vectors and processes", *IEEE Transactions on Signal Processing*, vol. 51, no. 3, ss. 714–725, 2003.

[11] B. Widrow, ,J. McCool, and M. Ball, “The complex LMS algorithm”, *Proceedings of the IEEE*, 63(4), ss. 719–720, 1975.

[12] S. C. Douglas and D. P. Mandic, “Performance analysis of the conventional Complex LMS and Augmented Complex LMS algorithms”, *International Conference on Acoustics, Speech, and Signal Processing (ICASSP), Speech, Signal Processing*, 2010, ss. 3794–3797.

[13] B. Jelfs, D. P. Mandic, and S. C. Douglas, “An adaptive approach for the identification of improper complex signals”, *Signal Processing*, vol. 92, ss. 335–344, 2012.

[14] P. Chevalier and A. Blin, “Widely linear MVDR beam formers for the reception of an unknown signal corrupted by noncircular interferences”, *IEEE Transactions on Signal Processing*, 55(11), ss. 5323–5336, 2007.

[15] A. Khalili and A. Rastegarnia, “Tracking analysis of augmented complex least mean square algorithm”, *International Journal of Adaptive Control and Signal Processing*, vol. 30, no. 1, ss. 106–114, 2016.

[16] A. Khalili, A. Rastegarnia, W. M. Bazzi, and Z. Yang, “Derivation and analysis of incremental augmented complex least mean square algorithm”, *IET Signal Processing*, vol. 9, no. 4, ss. 312–319, Nov. 2014.

[17] Z. Shan and T. P. Yum, “A conjugate augmented approach to direction-of-arrival estimation”, *IEEE Transactions on Signal Processing*, vol. 53, no. 11, ss. 4104-4109, Nov. 2005.

[18] Y. Xia, S. C. Douglas, and D. P. Mandic, “Adaptive frequency estimation in smart grid applications: exploiting noncircularity and widely linear adaptive estimators”, *IEEE Signal Processing*, vol. 29, no. 5, ss. 44–54, 2012.

[19] Y. Xia and D. P. Mandic, “Widely linear adaptive frequency estimation of unbalanced three-phase power systems”, *IEEE Transactions on Instrumentation and Measurement*, vol. 61, no. 1, ss. 74–83, 2012.

[20] E. C. Mengüç and N. Acır, "An augmented complex-valued least-mean kurtosis algorithm for the filtering of noncircular signals", *IEEE Transactions on Signal Processing*, vol. 66, no. 2, ss. 438–448, 2018.

[21] B. Jelfs, S. Javidi, P. Vayanos, and D. P. Mandic, "Characterisation of Signal Modality: Exploiting Signal Nonlinearity in Machine Learning and Signal Processing", *Journal of Signal Processing Systems*, vol 61, no.1, ss. 105–115, 2010.

[22] E. C. Mengüç and N. Acır, "Complex-valued least mean kurtosis adaptive filter algorithm", *IEEE 23rd Signal Processing and Communications Applications Conference*, ss. 325–328, 2016.

[23] E. Zerdali and E. C. Mengüç, "Novel complex-valued stator current-based MRAS estimators using different adaptation mechanisms", *IEEE Transactions on Instrumentation and Measurement*, vol. 68 no. 10, ss. 3793-3795, 2019.

[24] N. Gebeyehu, H. Zhao, and Y. Xia, "Robust frequency estimation of unbalanced power system using a phase angle error based least mean kurtosis algorithm", *International Journal of Electrical Power & Energy Systems*, vol. 110, ss. 795-808, 2019.

[25] N. Gebeyehu L., H. Zhao, and Y. Xia, "Widely linear least mean kurtosis-based frequency estimation of three-phase power system", *IET Generation, Transmission & Distribution*, vol. 14, no. 6, ss. 1159-1167, 2019.

[26] N. Gebeyehu and H. Zhao, "Magnitude-cum-phase angle error-based WL adaptation for frequency estimation of three-phase power system", *Electronics Letters*, vol. 55, no.4, ss. 218-220, 2019.

[27] E. C. Mengüç¸ and N. Acır, "Kurtosis-based crtrl algorithms for fully connected recurrent neural networks", *IEEE Transactions on Neural Networks and Learning Systems*, vol. 29, no. 12, ss. 6123–6131, 2018.

[28] E. C. Mengüç, "A novel fully complex nonlinear adaptive finite ımpulse response filter algorithm", *Gazi Üniversitesi Fen Bilimleri Dergisi Part C: Tasarım ve Teknoloji*, vol. 7, no.1, ss. 1-11, 2019.

[29] O. Tanrikulu and A. G. Constantinides, “Least-mean kurtosis: A novel higher-order statistics based adaptive filtering algorithm”, *Electronics Letters*, vol. 30, no. 3, ss. 189–190, 1994.

[30] N. J. Bershad and J. C. Bermudez, “Stochastic analysis of the least mean kurtosis algorithm for Gaussian inputs”, *Digital Signal Processing*, vol.54, ss. 35-45, 2016.

[31] P. I. Hübscher and J. C. Bermudez, “A model for the behavior of the least mean kurtosis (LMK) adaptive algorithm with Gaussian inputs”, *International Telecommunications Symposium*, 2002.

[32] E. C. Mengüç, N. Acır and D. P. Mandic, “Widely linear quaternion-valued least-mean kurtosis algorithm”, *IEEE Transactions on Signal Processing*, vol. 68, ss. 5914-5922, 2020.

[33] E. C. Mengüç, “Novel quaternion-valued least-mean Kurtosis adaptive filtering algorithm based on the GHR calculus”, *IET Signal Processing*, vol. 12, no.4, ss. 486-495, 2019.

[34] B. Çolak Güvenç and E. C. Mengüç, “Tracking performance of CLMK algorithm in abruptly changing environments”, *International Congress on Art and Design Research and Exhibition*, Niğde, Türkiye, 21 - 22 Haziran 2021, ss.1-9, 2021.

[35] E. C. Mengüç and N. Acır, “An augmented complex-valued Lyapunov stability theory based adaptive filter algorithm”, *Signal Processing*, vol. 137, ss. 10–21, 2017.

[36] B. Çolak Güvenç and E. C. Mengüç, “An alternative mixing parameter update rule for complex-valued collaborative adaptive filter structures”, *3rd International Turkic World Congress on Science and Engineering*, Niğde, Türkiye, 14-15 Haziran 2021, ss.1-11, 2021.

[37] C. C. Amadi, B. Ujang, A. Sali, and F. Hashim, “Collaborative adaptive filtering approach for the identification of complex-valued improper signals”, *Circuits, Systems, and Signal Processing*, vol. 38, no. 8, ss. 3860–3879, 2019.

[38] C. Jahanchahi, S. Kanna, and D. P. Mandic, “Complex dual channel estimation: Cost effective widely linear adaptive filtering”, *Signal Processing*, vol. 104, ss. 33–42, 2014.

[39] B. Çolak Güvenç ve E. C. Mengüç, “Patolojik dinlenme tremorlerinin kompleks düzlemde adaptif tahmini”, *Avrupa Bilim ve Teknoloji Dergisi*, 2021, (Kabul edildi).

[40] G. N. Reeke, Modeling in the Neurosciences: From Biological Systems to Neuromimetic Robotics, CRC Press, Erişim Tarihi: 19 Kasım 2021, 2005, [online] Erişilebilir: https://www.motusbioengineering.com/

[41] H. K. Khalil, *Nonlinear Systems*. Prentice Hall, 2002.

[42] W. Wirtinger, “Zur formalen theorie der funktionen von mehr komplexen veränderlichen”, *Mathematische Annalen*, vol. 97 no.1, ss. 357-375, 1927.

# ÖZGEÇMİŞ

## KİŞİSEL BİLGİLER

**Adı Soyadı:** Buket ÇOLAK GÜVENÇ

**Uyruğu:** Türkiye (T.C.)

## EĞİTİM

| **Derece** | **Kurum** | **Mezuniyet Tarihi** |
|---|---|---|
| Yüksek Lisans | Kayseri Üniversitesi, Elektrik-Elektronik Mühendisliği | 2021 |
| Lisans | Erciyes Üniversitesi, Elektrik-Elektronik Mühendisliği | 2017 |
| Lise | Çankaya Hürriyet Anadolu Lisesi, Ankara | 2011 |

## İŞ DENEYİMLERİ

| **Yıl** | **Kurum** | **Görev** |
|---|---|---|
| 2021-Halen | Kayseri Üniversitesi, Elektrik-Elektronik Mühendisliği Bölümü | Araştırma Görevlisi |
| 2017-2018 | TAV Havalimanları Holding A.Ş. | Saha Mühendisi |

## YAYINLAR

### SCI, SSCI VE AHCI İndekslerine Giren Dergilerde Yayınlanan Makaleler

1. B. Çolak Güvenç and E. C. Mengüç, "An adaptive convex combination of CLMK and ACLMK algorithms for processing complex-valued signals", Signal Processing, 2021. *(Değerlendirme Aşamasında).*

### Diğer Dergilerde Yayınlanan Makaleler

1. B. Çolak Güvenç ve E. C. Mengüç, "Patolojik dinlenme tremorlerinin kompleks düzlemde adaptif tahmini", Avrupa Bilim ve Teknoloji Dergisi, 2021, *(Kabul edildi).*

**Hakemli Kongre / Sempozyum Bildiri Kitaplarında Yer Alan Yayınlar**

1. B. Çolak Güvenç and E. C. Mengüç, “Tracking performance of CLMK algorithm in abruptly changing environments”, International Congress on Art and Design Research and Exhibition, Niğde, Türkiye, 21 - 22 Haziran 2021, ss.1-9, 2021.

2. B. Çolak Güvenç and E. C. Mengüç, “An alternative mixing parameter update rule for complex-valued collaborative adaptive filter structures”, 3rd International Turkic World Congress on Science and Engineering, Niğde, Türkiye, 14-15 Haziran 2021, ss.1-11, 2021.

# KURTOSİS MALİYET FONKSİYONU TABANLI KOMPLEKS DEĞERLİ İŞBİRLİKÇİ ADAPTİF FİLTRELEME

*Yazar* Buket Çolak Güvenç

**Gönderim Tarihi:** 15-Ara-2021 10:01PM (UTC+0300)
**Gönderim Numarası:** 1731366243
**Dosya adı:** Buket_YL_Tez_Son_Hali_15_12_2021.pdf (2.69M)
**Kelime sayısı:** 11217
**Karakter sayısı:** 67952

# KURTOSİS MALİYET FONKSİYONU TABANLI KOMPLEKS DEĞERLİ İŞBİRLİKÇİ ADAPTİF FİLTRELEME

ORİJİNALLİK RAPORU

| %10 | %8 | %7 | %3 |
|---|---|---|---|
| BENZERLİK ENDEKSİ | İNTERNET KAYNAKLARI | YAYINLAR | ÖĞRENCİ ÖDEVLERİ |

BİRİNCİL KAYNAKLAR

| | | |
|---|---|---|
| 1 | acikerisim.nigde.edu.tr:8080<br>İnternet Kaynağı | %2 |
| 2 | enstitu.kayseri.edu.tr<br>İnternet Kaynağı | %1 |
| 3 | dergipark.gov.tr<br>İnternet Kaynağı | %1 |
| 4 | Submitted to Erciyes Ãniversitesi<br>Öğrenci Ödevi | <%1 |
| 5 | Aydin Kurnaz. "The differential transform approximation for the system of ordinary differential equations", International Journal of Computer Mathematics, 6/1/2005<br>Yayın | <%1 |
| 6 | dergipark.org.tr<br>İnternet Kaynağı | <%1 |
| 7 | Mark Cannon. "MPC for Stochastic Systems", Lecture Notes in Control and Information Sciences, 2007<br>Yayın | <%1 |

| | | |
|---|---|---|
| 8 | Engin Cemal Menguc, Nurettin Acir. "An Augmented Complex-Valued Least-Mean Kurtosis Algorithm for the Filtering of Noncircular Signals", IEEE Transactions on Signal Processing, 2018<br>Yayın | <%1 |
| 9 | www.docme.ru<br>İnternet Kaynağı | <%1 |
| 10 | b-ok.org<br>İnternet Kaynağı | <%1 |
| 11 | planttissuecultur.blogspot.com<br>İnternet Kaynağı | <%1 |
| 12 | Submitted to The Scientific & Technological Research Council of Turkey (TUBITAK)<br>Öğrenci Ödevi | <%1 |
| 13 | manasbis.manas.edu.kg<br>İnternet Kaynağı | <%1 |
| 14 | zl3gp.co.nz<br>İnternet Kaynağı | <%1 |
| 15 | car-fleet.cz<br>İnternet Kaynağı | <%1 |
| 16 | Engin Cemal Mengüç. "Novel quaternion_valued least_mean kurtosis adaptive filtering algorithm based on the GHR calculus", IET Signal Processing, 2018<br>Yayın | <%1 |