



EEG Sinyallerinden EOG Gürültülerini Yok Etmek için Lineer ve Geniş Lineer Kompleks Değerli En Küçük Ortalama Kare Algoritmaları Tabanlı Bir Adaptif Gürültü Yok Etme Sistemi

ENGİN CEMAL MENGÜÇ^{1,*}, SALİM ÇINAR¹, NURETTİN ACIR²

¹Niğde Ömer Halisdemir Üniversitesi, Mühendislik Fakültesi, Elektrik-Elektronik Mühendisliği Bölümü, 51245, NİĞDE

²Bursa Teknik Üniversitesi, Doğa Bilimleri, Mimarlık ve Mühendislik Fakültesi, Elektrik-Elektronik Mühendisliği Bölümü, 16190, BURSA

Öz

Bu çalışmada, elektroensefalografi (EEG) sinyallerinden elektrookülografi (EOG) gürültülerinin çıkarılması için lineer ve geniş lineer kompleks değerli en küçük ortalama kare algoritmaları tabanlı bir adaptif gürültü yok etme sistemi tasarlanmıştır. Öncelikle veri kümesinde yer alan reel değerli EOG ve EEG sinyalleri (Fp1 ve Fp2), kompleks düzlemde bir kompleks değerli sinyal olarak modellenir. Daha sonra, önerilen gürültü yok etme sistemi kullanılarak EOG gürültüleri EEG sinyallerinden kompleks düzlemde yok edilir. Bu sinyallerin kompleks düzlemde ifade edilmesi; EOG gürültülerini, iki EEG kanalından aynı anda yok etmemizi sağlar. Ayrıca bu çalışmada; kompleks değerli EEG sinyalinin dairesel olmayan bir davranış sergilediği ve durumda geniş lineer kompleks değerli en küçük ortalama kare algoritmasının adaptif gürültü yok etme sisteminin başarımını, reel değerli ve kompleks değerli en küçük ortalama kare ve algoritmalarına kıyasla artırdığı gösterilmiştir. Benzetim sonuçları önerilen yaklaşımı desteklemektedir.

Makale Bilgisi

Başvuru: 22/08/2017

Düzeltilme: 21/11/2017

Kabul: 14/12/2017

Anahtar Kelimeler

Kompleks düzlem
Gürültü yok etme
Geniş lineer model

Keywords

Complex domain
Noise cancellation
Widely linear model

An Adaptive Noise Cancellation System Based on Linear and Widely Linear Complex Valued Least Mean Square Algorithms for Removing Electrooculography Artifacts from Electroencephalography Signals

Abstract

In this study, an adaptive noise cancellation (ANC) system based on linear and widely linear (WL) complex valued least mean square (LMS) algorithms is designed for removing electrooculography (EOG) artifacts from electroencephalography (EEG) signals. The real valued EOG and EEG signals (Fp1 and Fp2) given in dataset are primarily expressed as a complex valued signal in the complex domain. Then, using the proposed ANC system, the EOG artifacts are eliminated in the complex domain from the EEG signals. Expression of these signals in the complex domain allows us to remove EOG artifacts from two EEG channels simultaneously. Moreover, in this study, it has been shown that the complex valued EEG signal exhibits non-circular behavior, and in the case, the WL-CLMS algorithm enhances the performance of the ANC system compared to real-valued LMS and CLMS algorithms. Simulation results support the proposed approach.

1. GİRİŞ (INTRODUCTION)

Elektroensefalografi (EEG) sinyalleri, insan beyinin elektriksel davranışını temsil eden sinyallerdir ve insan kafatasına yerleştirilen elektrotlar yardımı ile ölçülür. Klinik uygulamalarda; genellikle EEG kayıtları, göz kırpmaya veya gözün sağ-sol hareketinden dolayı oluşan elektrookülografi (EOG) gürültüleri tarafından bozulmaya maruz kalır [1-3]. Buda EEG sinyallerinin yorumlanmasında, analizinde ve EEG sinyali tabanlı kontrol sistemlerinde (Örn. Beyin bilgisayar ara yüzü (Brain computer interface (BCI))) ciddi problemlere yol açmaktadır [1, 3]. EOG gürültülerinin EEG sinyalleri üzerindeki etkisinin azaltılmasındaki olası çözümlerden biri hastaya gözünü kırpmaması veya hareket ettirmemesi talimatının

*İletişim yazarı, e-mail: ecmenguc@ohu.edu.tr

verilmesidir [1]. Fakat böyle bir talimat, hasta üzerinde ikinci bir olayı tetikleyebilir. Bu yüzden EOG gürültülerinin sinyal işleme teknikleri yoluyla yok edilmesi, EEG sinyallerinin analizinde hayati bir role sahiptir. EEG sinyallerinden EOG gürültülerini yok etmek için standart yaklaşım, lineer sayısal filtrelerdir. Bu tip filtreler, tipik olarak 0.1 Hz alt kesim 70 Hz üst kesim frekansına sahiptir [2]. Fakat EOG gürültüsü ile EEG sinyallerinin frekans bantlarının örtüşmesi durumunda; bu tip lineer filtreleme yöntemleri, sinyallerin hem kanalları arasındaki fazın hem de genliklerinin bozulmasına sebep olur [2]. Ayrıca literatürde, hem zaman hem de frekans düzleminde regresyon-tabanlı yöntemler EEG sinyallerinden EOG gürültülerini yok etmek için önerilmiştir [2, 4, 5]. Fakat EEG ve EOG sinyalleri durağan olmayan sinyaller olduğu için bu tip yöntemler bu problemi çözmede yeterli değildir [1]. Bu yüzden, bu durağan olmayan sinyallerin değişimlerini takip edebilmek için adaptif filtrelerin kullanılması gerekmektedir. Bu kapsamda adaptif filtreler, adaptif gürültü yok etme (Adaptive noise canceller (ANC)) sistemi olarak, biyomedikal sinyallerden istenmeyen gürültüleri yok etmek için etkin ve yoğun bir şekilde literatürde kullanılmaktadır [2, 6-12].

Adaptif filtreler, önceden belirlenmiş bir başarımla ölçütüne göre filtre ağırlık katsayılarını uyarlayabilen ve bu yapıdan dolayı da hem durağan hem de durağan olmayan sinyallerin işlenmesine olanak sağlayan filtrelerdir. Bu tip filtreler, ağırlık katsayılarını güncellenebilmek için bir eniyileme algoritmasına ihtiyaç duymaktadırlar. Bu kapsamda, en yaygın kullanılan algoritmalar ise en küçük ortalama kare (LMS) ve özyinelemeli en küçük kare (RLS) tipi algoritmalar. LMS tipi algoritmalar, RLS tipi algoritmalarla göre bir çevrimde daha az hesap karmaşıklığına sahip olduğundan dolayı kolaylıkla gerçek zamanlı sistemlere adapte edilebilirler. Ayrıca belirtmek gerekir ki; bu tip adaptif filtre algoritmaları, hem giriş sinyali $x(k)$ 'nin hem de beklenen sinyal $d(k)$ 'nin genlik bilgisini kullanır. Bu yüzden reel düzlemde çalışan algoritmalar olarak ifade edilir. Ayrıca bu iki sinyal hem genlik ve hem de yön bilgisine sahip ise faz bilgisinin de dikkate alınması gerekir [13]. Faz bilgisi ise doğal olarak kompleks değerli sinyallerde mevcut olan bir bilgidir. Aynı zamanda bir kompleks değerli sinyal faz ve genlik veya reel ve imajiner olarak da ifade edilebilir [13]. Reel düzlemde tasarlanan bir LMS veya RLS tipi adaptif filtre algoritmaları, doğrudan kompleks değerli sinyallerin işlenmesinde kullanılamaz. Bu yüzden bu tip algoritmaların kompleks düzleme genişletilerek tasarlanması gerekir.

Literatürde, ilk olarak Widrow ve arkadaşları [14]; kompleks en küçük kare (Complex least mean square (CLMS)) önerilmiştir. Bu algoritma [14], klasik LMS algoritmasının, reel düzlemde kompleks düzleme genişletilmesidir ve kompleks sinyal işleme alanında geliştirilen ilk algoritmalarındandır (Örneğin, reel düzlemde kovaryans matrisi $E\{\mathbf{xx}^T\}$ şeklinde olurken, kompleks düzlemde $E\{\mathbf{xx}^H\}$ şekline dönüşür [13]). CLMS algoritması [14], basit yapısından dolayı literatürde dairesel sinyallerin işlenmesinde etkin şekilde kullanılmaktadır. Fakat bu algoritmanın başarımla, ele alınan sinyalin dairesel olmayan özellik göstermesi durumunda önemli ölçüde düşmektedir. Bunun sebebi ise kompleks düzlemde doğrudan tasarlanana adaptif filtre algoritmalarının (Örneğin, CLMS algoritması) sinyalin ikinci dereceden istatistiksel özelliklerinin tamamını dikkate almıyor olmasıdır. Yani bu tip algoritmalar, ikinci dereceden istatistiksel özellik olarak sadece sinyalin kovaryans matrisi bilgisini kullanırken sözde-kovaryans matrisi bilgisini dikkate almazlar.

Son zamanlarda ise kompleks değerli sinyallerin hem kovaryans hem de sözde-kovaryans matrisi bilgilerini yapısında barındıran geniş lineer model (Widely Linear (WL) Model) [15]'de yapılan çalışmada önerilmiştir. Yapılan bu çalışma ile standart lineer filtre modelinin dairesel sinyaller için yeterli olduğu, fakat düzensiz sinyaller için ise WL filtre modelinin uygun olduğu göstermiştir. Özellikle [16]'daki çalışmada, artırılmış kompleks istatistik kavramı ortaya konulmuştur ve bu kapsamda hem kovaryans matrisi hem de sözde-kovaryans matrisi, artırılmış kovaryans matrisi içerisinde birleştirilmiştir. Artırılmış kompleks istatistik yani geniş lineer model yaklaşımı, LMS tabanlı adaptif filtreleme algoritmalarının tasarımlarında oldukça yaygın ve etkin bir şekilde kullanılmıştır [14, 17-24]. Örneğin, [14, 17-24]'de yer alan çalışmalarda; WL (veya artırılmış) kompleks değerli LMS (WL-CLMS) algoritması, kompleks değerli dairesel ve dairesel olmayan sinyallerin işlenebilmesi için önerilmiştir. Ayrıca yapılan bu çalışmalar, WL-CLMS algoritmasının, dairesel olmayan kompleks değerli sinyallerde başarımla önemli ölçüde artırdığı fakat dairesel sinyallerde ise kendisinin lineer eşleniği olan CLMS algoritmasıyla benzer başarımla sergilediğini göstermektedir.

Bu çalışmada, EEG sinyallerinden EOG gürültülerinin çıkarılması için CLMS ve WL-CLMS algoritmaları tabanlı bir adaptif gürültü yok etme sistemi tasarlanmıştır. Öncelikle veri kümesinde yer

alan reel değerli EOG ve EEG sinyalleri (Fp1 ve Fp2), kompleks düzlemde bir kompleks sinyal olarak modellenmiştir. Daha sonra, önerilen gürültü yok etme sistemi kullanılarak EOG gürültüleri EEG sinyallerinden kompleks düzlemde yok edilmiştir. Bu sinyallerin kompleks düzlemde ifade edilmesi; EOG gürültülerini aynı anda iki EEG kanalından yok etmemizi sağlamıştır. Ayrıca bu çalışmada; kompleks değerli EEG sinyalinin dairesel olmayan bir davranış sergilediği gösterilmiş olup, WL-CLMS algoritmasının, reel değerli LMS ve CLMS algoritmalarına kıyasla başarımı artırdığı gözlemlenmiştir.

2. MATERYAL VE METOT (MATERIAL AND METHODS)

2.1. Kompleks rastgele vektörlerin istatistiği, düzenlilik ve dairesellik kavramları (Statistics of complex random vectors, properness and circularity concepts)

Bir kompleks değerli rastgele vektör $\mathbf{z} = \mathbf{z}_r + j\mathbf{z}_i$ 'in ikinci dereceden istatistiksel özelliklerinin tamamen tanımlanabilmesi için sırasıyla Denklem (1) ve (2)'de yer alan kovaryans ve sözde-kovaryans matrislerinin aşağıdaki gibi ifade edilmesi gerekir [14, 16, 25-28].

Kovaryans matrisi:

$$\mathbf{C}_{zz} = E\{\mathbf{z}\mathbf{z}^H\} = \mathbf{C}_{z_r, z_r} + \mathbf{C}_{z_i, z_i} + j(\mathbf{C}_{z_r, z_i}^T - \mathbf{C}_{z_i, z_r}). \quad (1)$$

Sözde-kovaryans matrisi:

$$\mathbf{P}_{zz} = E\{\mathbf{z}\mathbf{z}^T\} = \mathbf{C}_{z_r, z_r} - \mathbf{C}_{z_i, z_i} + j(\mathbf{C}_{z_r, z_i}^T + \mathbf{C}_{z_i, z_r}) \quad (2)$$

burada \mathbf{z}_r ve \mathbf{z}_i sırasıyla kompleks değerli rastgele \mathbf{z} vektörünün reel ve imajiner kısımlarını temsil etmektedir.

- Eğer \mathbf{z}_r ve \mathbf{z}_i 'ye ait kovaryanslar birbirine eşit ise (yani $\mathbf{C}_{z_r, z_r} = \mathbf{C}_{z_i, z_i}$) ve aynı zamanda \mathbf{z}_r ve \mathbf{z}_i arasındaki kovaryanslar birbirinin negatifi (yani $\mathbf{C}_{z_r, z_i} = -\mathbf{C}_{z_i, z_r}$) ise; Denklem (2)'de yer alan sözde kovaryans matrisi sıfır olarak elde edilir (yani $\mathbf{P}_{zz} = 0$ 'dır). Bu durumda, \mathbf{z} vektörü, *düzenli* yani *ikinci dereceden dairesel bir vektördür* [14, 28]. Aksi bir durum söz konusu olduğunda ise \mathbf{z} vektörü, *düzensiz* yani *ikinci dereceden dairesel olmayan bir vektördür* [14, 28].
- *Düzenlilik* veya *ikinci dereceden dairesellik*; kompleks değerli rastgele \mathbf{z} vektörünün ikinci dereceden istatistiksel özelliklerini tanımlarken, *dairelilik* ise kompleks değerli rastgele \mathbf{z} vektörünün olasılık yoğunluk fonksiyonu ile ilişkilidir [14, 28]. Bir kompleks değerli rastgele \mathbf{z} vektörünün olasılık yoğunluk fonksiyonu, her hangi bir rotasyona uğraması durumunda değişmiyorsa, \mathbf{z} *dairelidir* [14, 28].

2.2. Artırılmış istatistik (Augmented statistics)

Bir kompleks rastgele \mathbf{z} vektörüne ait ikinci dereceden istatistiksel özelliklerin tamamen tanımlanabilmesi için hem kovaryans hem de sözde-kovaryans matrisinin incelenmesi gerektiği bir önceki bölümde bahsedilmiştir [14]. Bu bölümde ise artırılmış istatistikten kısaca bahsedilecektir.

Öncelikle sıfır ortalamaya sahip bir kompleks rastgele \mathbf{z} vektörüne ait artırılmış kompleks vektör \mathbf{z}^a [14] aşağıdaki gibi ifade edilir:

$$\mathbf{z}^a = [\mathbf{z}^T, \mathbf{z}^H]^T. \quad (3)$$

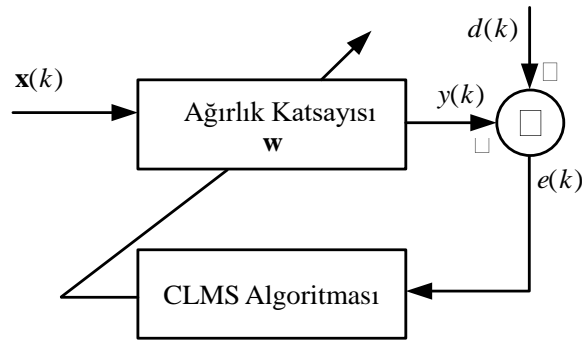
Böylece, \mathbf{z} 'e ait hem kovaryans hem de sözde kovaryans matrisi bilgisi, artırılmış kovaryans matrisi $\mathbf{C}_{z^a z^a}$ içerisine Denklem (4)'de ki gibi yerleştirilmiş olur:

$$\mathbf{C}_{z^a z^a} = E \begin{bmatrix} \mathbf{z} \\ \mathbf{z}^* \end{bmatrix} \begin{bmatrix} \mathbf{z}^H & \mathbf{z}^T \end{bmatrix} = \begin{bmatrix} E[\mathbf{z}\mathbf{z}^H] & E[\mathbf{z}\mathbf{z}^T] \\ E[\mathbf{z}^* \mathbf{z}^H] & E[\mathbf{z}^* \mathbf{z}^T] \end{bmatrix} = \begin{bmatrix} \mathbf{C}_{zz} & \mathbf{P}_{zz} \\ \mathbf{P}_{zz}^* & \mathbf{C}_{zz}^* \end{bmatrix} \quad (4)$$

Sonuç olarak; artırılmış kovaryans matrisi $\mathbf{C}_{z^a z^a}$, hem kovaryans hem de sözde kovaryans matrisi bilgisi içerdiğinden dolayı dairesel ve dairesel olmayan kompleks değerli sinyallerin ikinci dereceden istatistiksel özelliklerinin tamamını kapsadığı ortaya konulmuştur [14].

3. KOMPLEKS DEĞERLİ VE GENİŞ LİNEER KOMPLEKS DEĞERLİ LMS ALGORİTMALARI (COMPLEX VALUED LMS AND WIDELY LINEAR COMPLEX VALUED LMS ALGORITHMS)

3.1. CLMS algoritması (CLMS algorithm)



Şekil 1. Lineer model tabanlı adaptif filtre blok diyagramı

Şekil 1'de bir lineer model tabanlı adaptif filtre blok diyagramı yer almakta olup, $\mathbf{x}(k) = [x(k), x(k-1), \dots, x(k-M)]^T \in \mathbb{C}^{M \times 1}$ filtre giriş sinyalini, $y(k) \in \mathbb{C}$ filtre çıkışını ve $d(k) \in \mathbb{C}$ ise beklenen sinyali temsil etmektedir. Şekil 1'de yer alan kompleks değerli hata sinyali $e(k) \in \mathbb{C}$ ise:

$$e(k) = d(k) - y(k) = e^r(k) + j e^i(k) \quad (5)$$

burada $e^r(k)$ ve $e^i(k)$ hata sinyalinin sırasıyla ait reel ve imajiner kısımları temsil etmektedir.

Kompleks değerli adaptif sonlu darbe cevaplı (finite impulse response (FIR)) filtreye ait çıkış sinyali $y(k)$ ise:

$$y(k) = \mathbf{w}^T(k) \mathbf{x}(k) \quad (6)$$

$$\mathbf{w}(k) = [w(k), w(k-1), \dots, w(k-M)]^T \quad (7)$$

burada $\mathbf{w}(k) \in \mathbb{C}^{M \times 1}$ kompleks değerli ağırlık vektörünü, M ise filtre derecesini ifade edilmektedir.

Böylece maliyet fonksiyonu Denklem (8)'de ki gibi tanımlanır:

$$J(k) = \frac{1}{2} |e(k)|^2 = \frac{1}{2} e^*(k)e(k). \quad (8)$$

Tanımlanan maliyet fonksiyonu, kompleks değerli ağırlık vektörü $\mathbf{w}(k)$ 'ya göre minimize edilecek olur ise Denklem (9)'da yer alan ifade elde edilir.

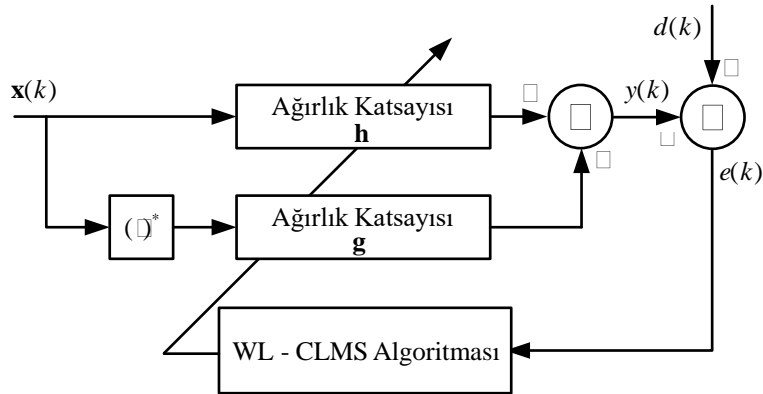
$$\begin{aligned} \nabla_{\mathbf{w}} J(k) &= \nabla_{\mathbf{w}_r} J(k) + j \nabla_{\mathbf{w}_i} J(k) = \frac{\partial J(k)}{\mathbf{w}_r(k)} + j \frac{\partial J(k)}{\mathbf{w}_i(k)} \\ &= -e(k) \mathbf{x}^*(k) \end{aligned} \quad (9)$$

Olasılıklı eğim adaptasyonu (stochastic gradient adaptation) kullanılarak, CLMS algoritmasına ait ağırlık vektörü güncelleme kuralı aşağıdaki gibi elde edilir:

$$\begin{aligned} \mathbf{w}(k+1) &= \mathbf{w}(k) - \mu \nabla_{\mathbf{w}} J(k) \Big|_{\mathbf{w}=\mathbf{w}(k)} \\ &= \mathbf{w}(k) + \mu e(k) \mathbf{x}^*(k) \end{aligned} \quad (10)$$

burada μ adım büyüklüğünü temsil etmektedir. Denklem (10)'dan da görüldüğü üzere, CLMS algoritması dairesel olan sinyallerin işlenmesinde en iyi çözümü sunar. Fakat CLMS algoritması, ikinci dereceden istatistiksel özelliklerin tamamını yapısında barındırmadığından dairesel olmayan sinyallerin işlenmesinde başarımı yetersizdir.

3.2. WL-CLMS algoritması (WL-CLMS algorithm)



Şekil 2. Geniş lineer model tabanlı adaptif filtre blok diyagramı

Geniş lineer model tabanlı adaptif filtre blok diyagramı Şekil 2'de yer almaktadır. Şekil 1'de olduğu gibi; $\mathbf{x}(k) \in \mathcal{F}^{M \times 1}$ giriş sinyalini, $y(k) \in \mathcal{F}$ filtre çıkışını ve $d(k) \in \mathcal{F}$ ise beklenen sinyali temsil etmektedir. Geniş lineer filtreye ait $e(k) \in \mathcal{F}$ kompleks değerli hata sinyali ise Denklem (11)'de verilmektedir.

$$\begin{aligned} e(k) &= d(k) - y(k) \\ &= d(k) - \mathbf{x}^T(k) \mathbf{h}(k) + \mathbf{x}^H(k) \mathbf{g}(k) \end{aligned} \quad (11)$$

burada $\mathbf{h}(k)=[h(k),h(k-1),\dots,h(k-M)]^T \in \mathbb{F}^{M \times 1}$ geniş lineer filtreye ait standart ağırlık vektörünü, $\mathbf{g}(k)=[g(k),g(k-1),\dots,g(k-M)]^T \in \mathbb{F}^{M \times 1}$ ise eşlenik ağırlık vektörünü temsil etmektedirler. Böylece maliyet fonksiyonu ise:

$$J(k) = \frac{1}{2} |e(k)|^2 = \frac{1}{2} e^*(k)e(k)$$

$$= \frac{1}{2} \left(d(k) - \mathbf{x}^T(k)\mathbf{h}(k) + \mathbf{x}^H(k)\mathbf{g}(k) \right)^* \left(d(k) - \mathbf{x}^T(k)\mathbf{h}(k) + \mathbf{x}^H(k)\mathbf{g}(k) \right). \quad (12)$$

Denklem (12)'den görüldüğü üzere; geniş lineer modelin yapısından dolayı maliyet fonksiyonu; hem standart ağırlık vektörü $\mathbf{h}(k)$ 'ya hem de eşlenik ağırlık vektörü $\mathbf{g}(k)$ 'ya bağlıdır. Aynı zamanda maliyet fonksiyonu $J(k)$, kompleks değişkenlerin reel değerli bir fonksiyonu olup, Cauchy-Riemann şartlarını sağlamaz ve kompleks düzlemde doğrudan türevi alınmaz. Bu problemin üstesinden gelenebilmesi için literatürde \mathbb{F}_j analiz [14] yöntemi kullanılmaktadır. \mathbb{F}_j analiz yöntemi kullanılarak hem standart ağırlık vektörü $\mathbf{h}(k)$ 'ya hem de eşlenik ağırlık vektörü $\mathbf{g}(k)$ 'ya göre kısmi türevler sırasıyla aşağıdaki elde edilir.

$$\frac{\partial J(k)}{\partial \mathbf{h}^*(k)} = \frac{1}{2} \left(\frac{\partial J(k)}{\partial \mathbf{h}_r(k)} + j \frac{\partial J(k)}{\partial \mathbf{h}_i(k)} \right) = -e(k)\mathbf{x}^*(k) \quad (13)$$

$$\frac{\partial J(k)}{\partial \mathbf{g}^*(k)} = \frac{1}{2} \left(\frac{\partial J(k)}{\partial \mathbf{g}_r(k)} + j \frac{\partial J(k)}{\partial \mathbf{g}_i(k)} \right) = -e(k)\mathbf{x}(k) \quad (14)$$

Böylece standart ve eşlenik ağırlık vektörü güncelleme kuralı sırasıyla aşağıdaki gibi elde edilir:

$$\mathbf{h}(k+1) = \mathbf{h}(k) + \mu e(k)\mathbf{x}^*(k) \quad (15)$$

$$\mathbf{g}(k+1) = \mathbf{g}(k) + \mu e(k)\mathbf{x}(k). \quad (16)$$

Son olarak standart ve eşlenik ağırlık vektörleri, artırılmış ağırlık vektörü $\mathbf{w}^a(k)=[\mathbf{h}^T(k),\mathbf{g}^T(k)]^T$ içerisine yerleştirilerek, WL-CLMS algoritmasına ait güncelleme kuralı daha basit bir formda aşağıdaki gibi elde edilir:

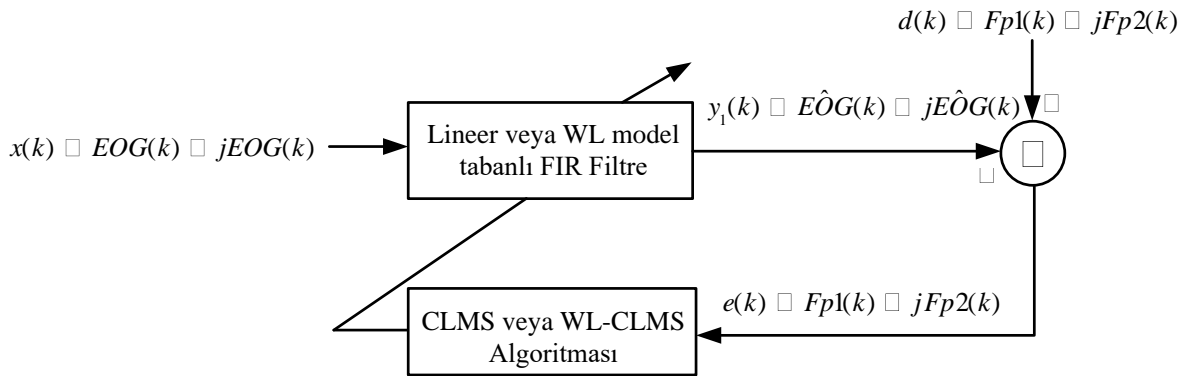
$$\mathbf{w}^a(k+1) = \mathbf{w}^a(k) + \mu e(k)\mathbf{x}^a(k) \quad (17)$$

burada $\mathbf{x}^a(k)=[\mathbf{x}^T(k),\mathbf{x}^H(k)]^T$ artırılmış giriş sinyalini temsil etmektedir.

4. EEG SİNYALLERİNDEN EOG GÜRÜLTÜLERİ YOK ETMEK İÇİN CLMS VE WL-CLMS ALGORİTMALARI TABANLI ÖNERİLEN ANC SİSTEMİ (THE PROPOSED ANC SYSTEM BASED ON CLMS AND WL-CLMS ALGORITHMS FOR REMOVING EOG ARTIFACTS FROM EEG SIGNALS)

Bu bölümde, EOG gürültülerinin EEG kayıtlarından çıkarılması için CLMS ve WL-CLMS tabanlı bir gürültü yok etme sistemi tasarlayacağız. Yapılan tasarımda, [19]'da ki çalışmadan farklı olarak, anlık olarak EOG gürültülerinin EEG sinyallerinden yok edilmesi amaçlanmaktadır. Bu çalışmada önerilen tasarım, kompleks düzlemde çalıştırılacağı için tek kanalda EOG gürültülerini yok etmek yerine, iki kanal da aynı anda EOG gürültülerinin yok edilmesini sağlayacaktır.

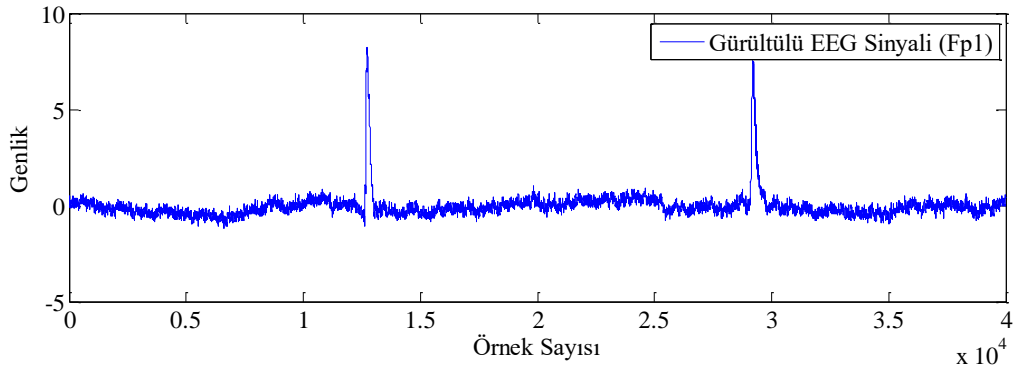
Şekil 3'de önerilen ANC sistemi yer almaktadır. Şekil 3'den görüleceği üzere, önerilen sistemin temel amacı; reel-değerli ve simetrik olarak yerleştirilmiş elektrotlardan alınan EEG sinyalleri (Örneğin Fp1 ve Fp2) kompleks düzlemde ifade edildikten sonra bu sinyallerin kompleks adaptif filtreler kullanılarak daha etkin bir şekilde işlenmesidir. Bunun için öncelikle simetrik elektrotlardan alınan reel-değerli EEG sinyalleri, reel ve imajiner bileşenlerin toplamı şeklinde ifade edilerek kompleks sinyal haline getirilmelidir [29]. Bu kapsamda, öncelikle beklenen sinyal $d(k)$; simetrik kanallardan alınan Fp1 ve Fp2 EEG sinyalleri kullanılarak, $d(k) = Fp1(k) + jFp2(k)$ şeklinde kompleks sinyal haline dönüştürülür. Daha sonra filtre giriş sinyali $x(k)$; bir elektrot vasıtasıyla alınan EOG sinyali kullanılarak $x(k) = EOG(k) + jEOG(k)$ şeklinde kompleks sinyal haline dönüştürülür. Önerilen sistemin ağırlık katsayıları CLMS veya WL-CLMS algoritmasıyla güncellenerek, önerilen ANC sistemin çıkışında, EOG gürültülerinden arındırılmış $e(k) = \hat{F}p1(k) + j\hat{F}p2(k)$ sinyali elde edilir. Sonuç olarak, simetrik elektrotlardan alınan reel-değerli EEG sinyalleri kompleks düzlemde ifade edilebilmektedir. Bu sayede kompleks değerli EEG sinyallerinin, ikinci dereceden istatistiksel özellikleri ve dairesellik dereceleri incelenebilecektir.



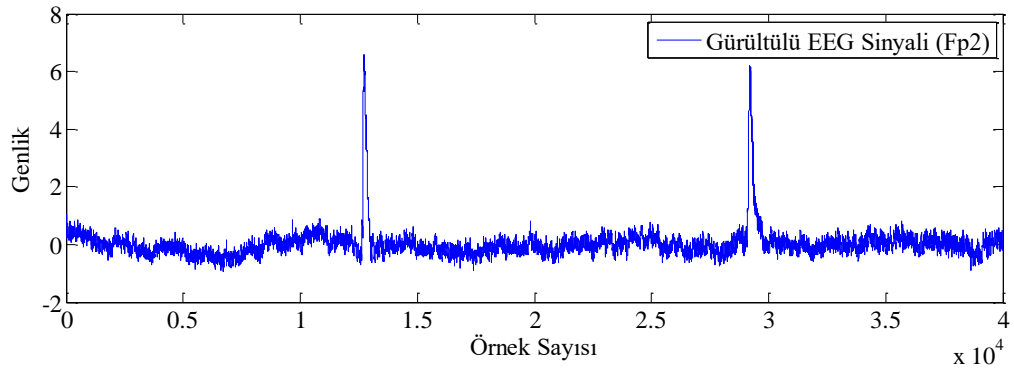
Şekil 3. Kompleks düzlemde EEG gürültü yok etme sistemi

5. BENZETİM SONUÇLARI VE TARTIŞMA (SIMULATION RESULTS AND DISCUSSION)

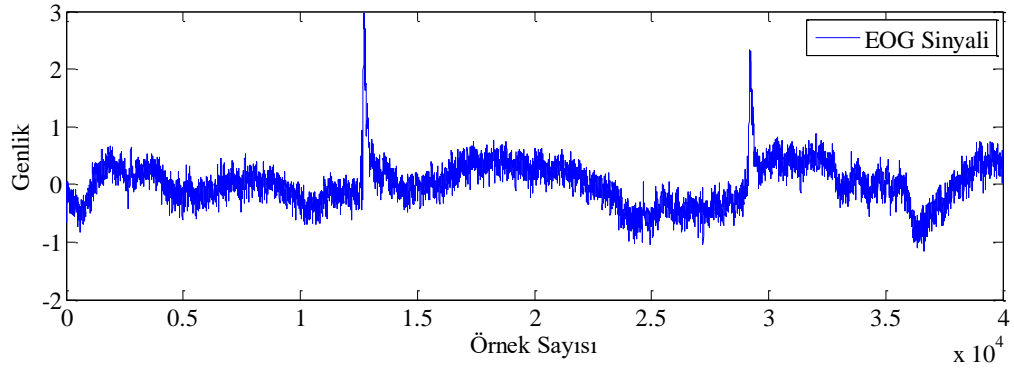
Bu bölümde, ANC sisteminin başarımını ölçmek için literatürde yaygın kullanılan ERP tabanlı beyin bilgisayar arayüz veri kümesi [30, 31] kullanılmıştır. Bu veri kümesinde ölçümler uluslararası 10-20 elektrot sistemi kullanılarak 64 kanaldan alınmıştır ve her bir verinin örnekleme hızı 2048 Hz'dir. Veri kümesinde 12 denekten alınan 237 ölçüm vardır. Yapılan çalışmada amacımız EEG sinyallerinin kompleks düzlemde adaptif olarak işlenmesidir. Pre-frontal lobda bulunan Fp1 ve Fp2 kanalları EOG sinyallerinin ölçüldüğü bölgeye çok yakın olduğundan gürültüden aşırı derecede etkilenmektedir [32]. Bu yüzden çalışmamızda, bu veri kümesi içerisinde her bir denek için; Fp1, Fp2 ve EOG kanallarından alınan ölçümler kullanılmıştır. Şekil 2'den de görüleceği üzere, önermiş olduğumuz ANC sisteminde, 50'inci dereceden bir FIR filtresi yapısı kullanılmıştır. ANC sisteminin ağırlık katsayıları ise CLMS ve WL-CLMS algoritmaları kullanılarak kompleks düzlemde güncellenmiştir. Aynı zamanda bu iki algoritmanın kompleks düzlemdeki başarımı, reel düzlemde işlem kabiliyetine sahip klasik LMS algoritmasıyla da karşılaştırılmıştır. Her üç algoritmaya ait adım büyüklüğü parametresi ise $\mu = 0.001$ seçilmiştir.



(a)



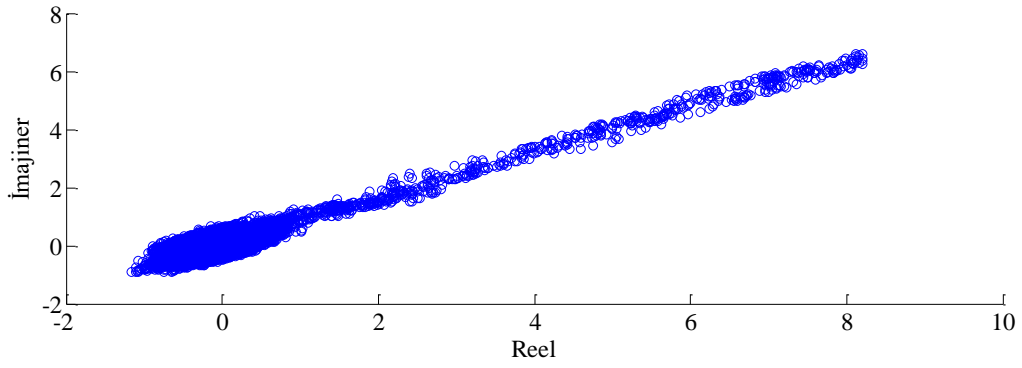
(b)



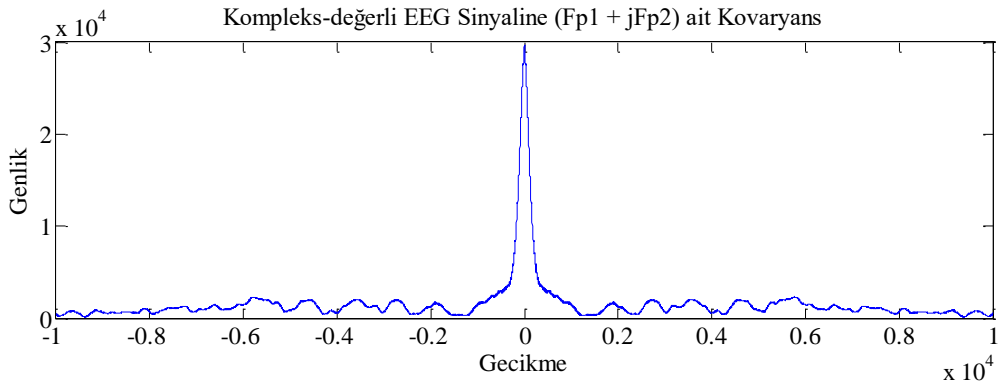
(c)

Şekil 4. Fp1 ve Fp2 kanallarından alınan gürültülü EEG sinyalleri ve EOG sinyali

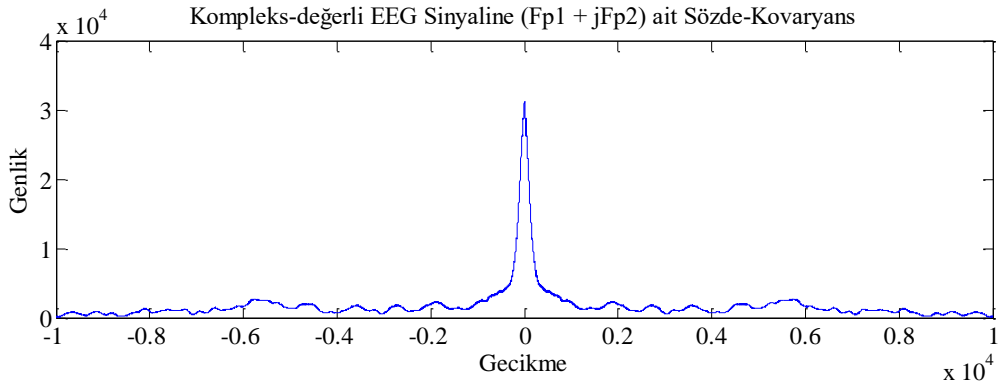
Şekil 4’de (a) ve (b)’de sırasıyla Fp1 ve Fp2 kanallarından alınan gürültülü EEG sinyalleri, Şekil 4 (c)’de ise EOG sinyali yer almaktadır. Fp1 ve Fp2 kanallarında mevcut olan EOG gürültüleri açık bir şekilde görülmektedir.



(a)



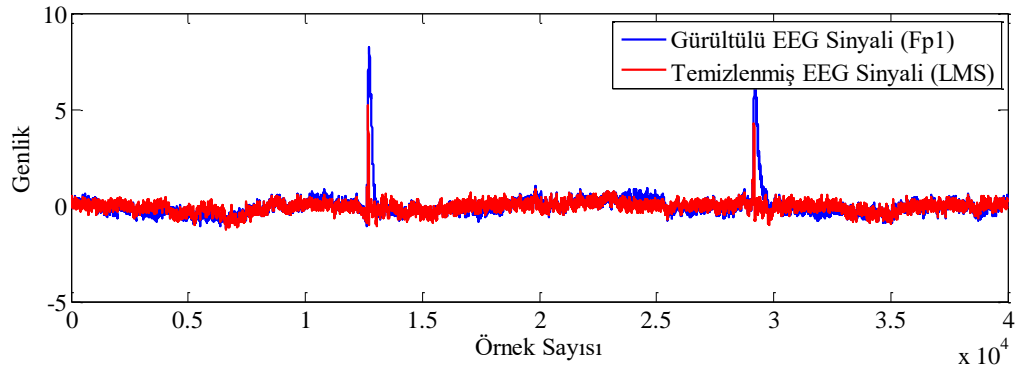
(b)



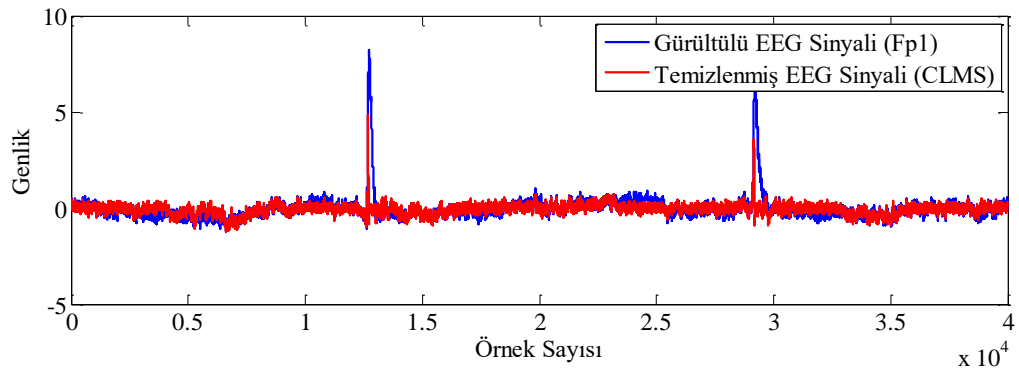
(c)

Şekil 5. a) Kompleks değerli EEG sinyali b) Sinyale ait kovaryans c) Sinyale ait sözde-kovaryans

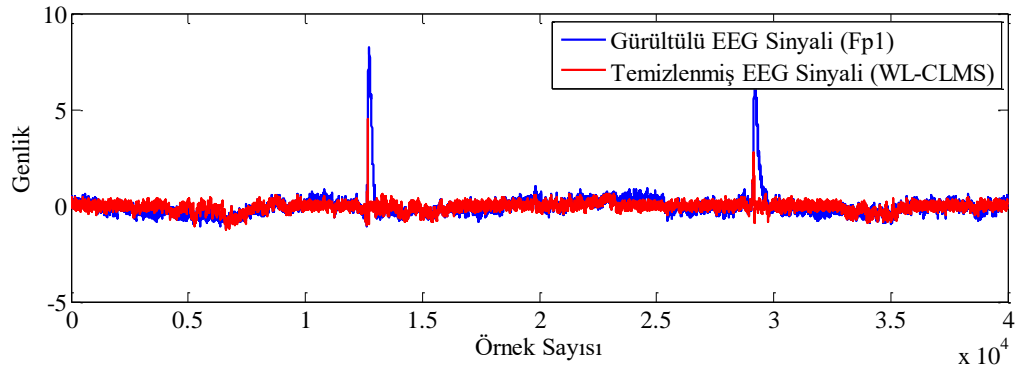
Şekil 5 (a)'da, Fp1 ve Fp2 kanalları kullanılarak kompleks düzlemde ifade edilen EEG sinyali ($Fp1 + jFp2$) ve Şekil 5 (b) ve (c)'de ise sırasıyla bu sinyale ait kovaryans ve sözde-kovaryans yer almaktadır. Şekil 5 (b) ve (c)'de, kompleks değerli EEG sinyalinin ikinci dereceden istatistiksel özellikleri incelendiğinde ise hem kovaryans hem de sözde-kovaryans bilgisi mevcut olduğu gözlemlenmiştir. Ayrıca bu sinyale ait dairesellik indeksi $r = 0.9502$ olarak hesaplanmıştır. Bu sonuçlar doğrultusunda bu kompleks sinyalin dairesel olmayan bir sinyal olduğu ortaya konulmuştur.



(a)

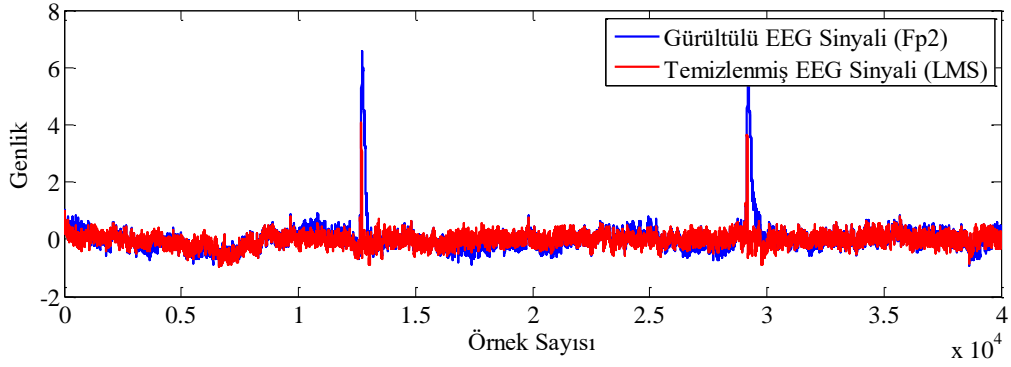


(b)

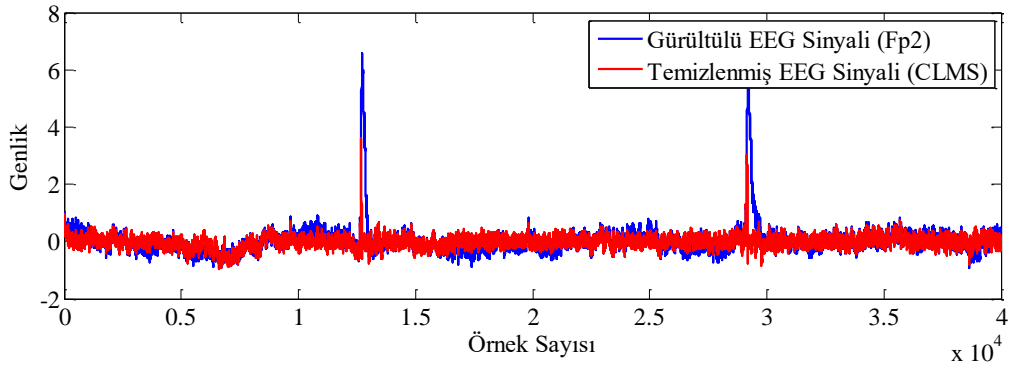


(c)

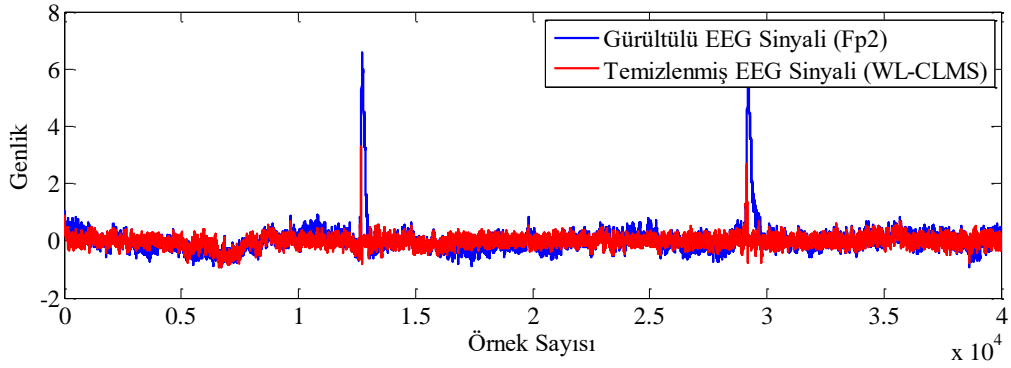
Şekil 6. Fp1 sinyali için algoritmaların sonuçları a) LMS b) CLMS c) WL-CLMS



(a)



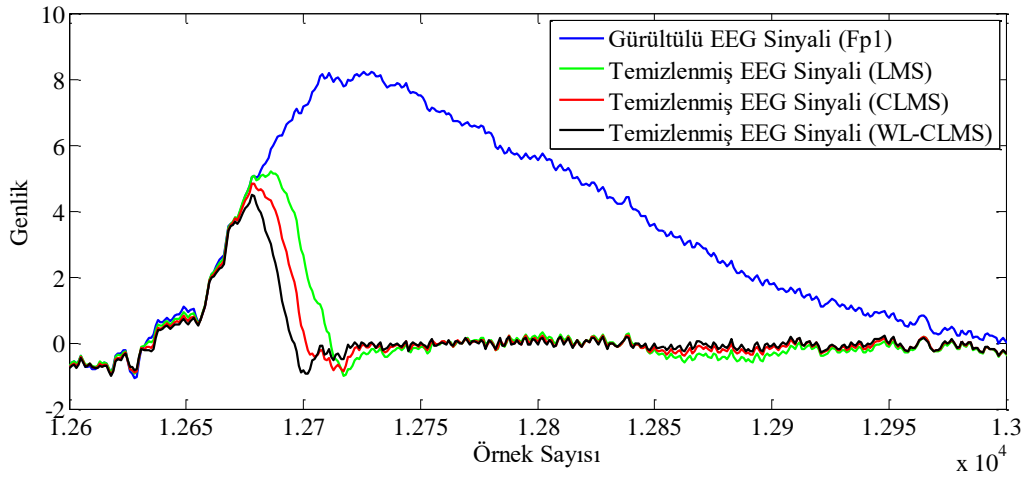
(b)



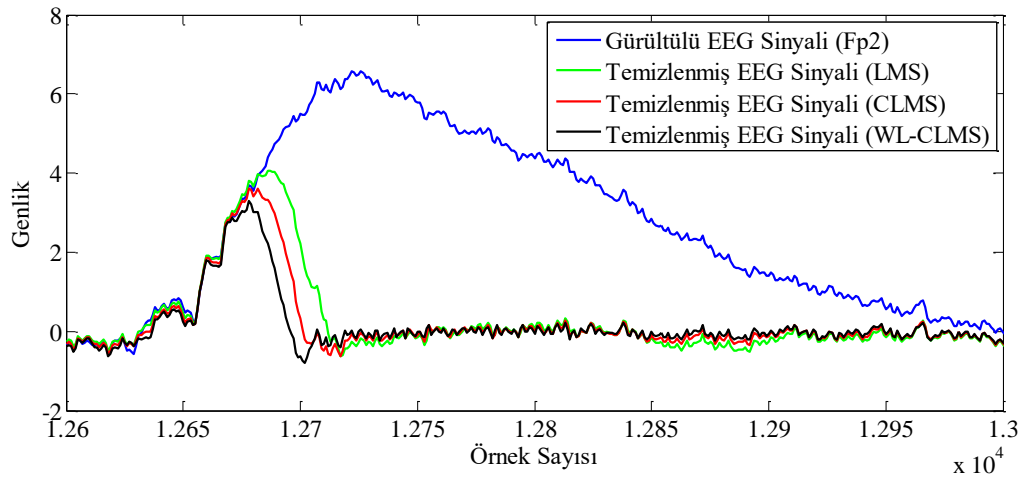
(c)

Şekil 7. Fp2 sinyali için algoritmaların sonuçları a) LMS b) CLMS c) WL-CLMS

Şekil 6 ve 7'de Fp1 ve Fp2 sinyalleri için adaptif filtre algoritmalarının sonuçları yer almaktadır. Şekil 3'den de görüleceği üzere, burada CLMS ve WL-CLMS algoritmaları kompleks değerli olduğundan ve beklenen değer ifadesi $d(k) = Fp1(k) + jFp2(k)$ olarak tanımlandığından dolayı bu algoritmalara ait ANC çıkışı $e(k) = \Re\{e(k)\} + j\Im\{e(k)\}$ fonksiyonunun reel ifadesi (yani $\Re\{e(k)\}$) $\Re\{e(k)\}$ 'i temsil ederken, imajiner ifadesi (yani $\Im\{e(k)\}$) $\Im\{e(k)\}$ 'yi temsil etmektedir. Ayrıca reel-değerli LMS algoritması Fp1 ve Fp2 sinyallerinin için ayrı ayrı çalıştırılmıştır. Şekil 6 ve 7'de yer alan sonuçlardan gözlemleneceği üzere algoritmalar EOG gürültülerini Fp1 ve Fp2 sinyallerinden büyük ölçüde yok etmiştir. Sonuçları daha iyi gözlemleyebilmek için ilk EOG gürültüsün olduğu kısım için başarımlar ayrıca Şekil 8'de verilmiştir.



(a)



(b)

Şekil 8. Algoritmaların sonuçları a) Fp1 b) Fp2

Şekil 8'den görüldüğü üzere CLMS ve WL-CLMS algoritmaları, klasik reel değerli algoritmalarından daha iyi sonuç vermiştir. Ayrıca belirtmek gerekir ki; kompleks değerli EEG sinyali dairesel olmayan bir sinyal olduğundan dolayı WL-CLMS algoritması diğer iki algoritmaya kıyasla, EEG sinyalinde mevcut olan EOG gürültülerini daha iyi bastırılmış ve daha hızlı bir şekilde orijinal EEG sinyalini takip etmiştir. WL-CLMS algoritmasının daha başarılı olmasının sebebi ise ikinci dereceden istatistiksel özelliklerin tamamını yapısında barındırıyor olmasıdır.

Tablo 1'de veri kümesindeki EOG kaynaklanan tepe değerlerin yok edilme başarımı verilmiştir. Tepe değer yok etme başarımının değerlendirilmesi için Korelasyon Katsayısı (KK) kullanılmıştır. Tüm veri kümesi için KK ve standart sapma (std) değerleri Tablo 1'de verilmiştir. KK değeri için öncelikle orijinal Fp1 ve Fp2 sinyallerinde mevcut olan tepe değerli bölgelerin sınırları görsel inceleme sonucunda belirlenmiştir. Çalışmada kullanılan algoritmalar tarafından temizlenmiş Fp1 ve Fp2 sinyalleri elde edilmiştir. Bu belirlenen sınırlar için, orijinal Fp1 ve Fp2 sinyalleri ile algoritmalar tarafından temizlenmiş Fp1 ve Fp2 sinyalleri arasındaki KK değeri hesaplanmıştır. KK değeri, orijinal ile temizlenmiş tepe değerli bölgelerin birbirine ne kadar benzediğini ifade etmektedir. Bu kapsamda, KK değerinin sıfıra yakın olması benzerliğin olmadığını yani tepe değerli bölgelerin yok edildiğini göstermektedir. Tablo 1'den görüldüğü üzere WL-CLMS algoritması daha düşük KK değerine sahiptir. Tablo 1'de, WL-CLMS algoritmasının tepe değerli bölgeleri diğer algoritmalara kıyasla daha iyi yok ettiği görülmektedir.

Yüzey elektrotları kullanılarak yapılan EEG ölçümlerinde, gürültüsüz EEG sinyallerinin ölçülmesi zordur. Bu nedenle sistem başarımının test edilmesi için bazı kabullerin yapılması gerekmektedir. Buradan hareketle EOG'den kaynaklanan tepe değerlerin olmadığı bölge gürültüsüz EEG sinyalleri olarak kabul edilebilir [32, 33]. Tablo 2'de veri kümesindeki EOG gürültülerinin olmadığı bölgelerde, algoritmaların orijinal sinyali takip edilme başarımına yer verilmiştir ve bu başarımlar kare hata (Root Mean Square Error (RMSE)) kullanılarak hesaplanmıştır. Tablo 2'den görüldüğü üzere bütün algoritmalara benzer RMSE başarımı sergilemiştir.

Tablo 1: Veri kümesindeki EOG'den kaynaklanan tepe değerlerin yok edilme başarımı

Algoritmalar	Fp1 (KK+std)	Fp2 (KK+std)
LMS	0.253 (± 0.178)	0.238 (± 0.228)
CLMS	0.129 (± 0.184)	0.132 (± 0.233)
WL-CLMS	0.043 (± 0.193)	0.061 (± 0.241)

Tablo 2: Veri kümesindeki EOG gürültülerinin olmadığı bölgelerde orijinal sinyalin takip edilme başarımı

Algoritmalar	Fp1 (RMSE+std)	Fp2 (RMSE+std)
LMS	0.382 (± 0.058)	0.439 (± 0.064)
CLMS	0.389 (± 0.059)	0.382 (± 0.082)
WL-CLMS	0.392 (± 0.056)	0.386 (± 0.075)

6. SONUÇ (CONCLUSION)

Bu çalışmada, EEG sinyallerinden EOG gürültülerinin yok edilmesi için CLMS ve WL-CLMS tabanlı bir ANC sistemi tasarlanmıştır. Öncelikle veri kümesinde yer alan reel değerli EOG ve EEG sinyalleri (FP1 ve FP2), kompleks düzlemde bir kompleks sinyal olarak ifade edilmiştir. Bu yaklaşım sayesinde her bir EEG kanalını ayrı ayrı dikkate almak yerine iki kanaldan ölçülmüş olan EEG sinyalleri kompleks düzlemde tanımlanmıştır. Böylece kompleks düzlemde çalışan CLMS ve WL-CLMS algoritmalarının kullanımına olanak sağlanmıştır. Elde edilen sonuçlarda, CLMS ve WL-CLMS algoritmalarının, reel düzlemde sinyal işleme kabiliyetine sahip olan reel değerli LMS algoritmasına göre başarımı dikkate değer bir şekilde artırdığı gözlemlenmektedir. Ayrıca WL-CLMS algoritmasının hem kompleks düzlemde çalışıyor olması hem de ikinci dereceden istatistiksel özelliklerin tamamının kullanıyor olması kendisinin lineer eşleniği olan CLMS algoritmasına göre başarımı daha da artırmıştır. Ayrıca belirtmek gerekir ki; önerilen ANC sistemi, EOG sinyalinin ölçülmesi durumunda kullanılabilir ve diğer simetrik kanallar için de kolaylıkla genişletilebilir.

KAYNAKLAR (REFERENCES)

- [1] Kumar A., Ahamed S.R., Removal of EOG artifacts from single channel EEG signals using combined singular spectrum analysis and adaptive noise canceler. IEEE sensor Journal, 16: 23 (2016), 8279-8287.
- [2] Guerrero-Mosquera C., Nvaia-Vazquez A., Automatic removal of ocular artefacts using adaptive filtering and independent component analysis for electroencephalogram data. IET Signal Processing, 6: 2 (2010) 99-106.
- [3] Fatourech M., Bashashati A., Ward R.K., Birch G.E., EMG and EOG artifacts in brain computer interface systems: A survey, Clinical Neurophysiology, 118: 3 (2007) 480–494.
- [4] Verleger R., Gasser T., Möcks J., Correction of EOG artifacts in event-related potentials of the EEG: Aspects of reliability and validity. Psychophysiology, 19: 4 (1982), 472-480.

- [5] Woestenburg J.C., Verbaten M.N., Slangen J.L., The removal of the eye-movement artifact from the EEG by regression analysis in the frequency domain, *Biol. Psychol.*, 16:1 (1983), 127-147.
- [6] Svensson O., Tracking of changes in latency and amplitude of the evoked potential by using adaptive LMS filters and exponential averagers, *IEEE Transactions on Biomedical Engineering*, 40: 10, (1993) 1074-1079.
- [7] James C.J., Hagan M. T., Jones R.D., Bones P.J., Carroll G.J., Multireference adaptive noise canceling applied to the EEG, *IEEE Transactions on Biomedical Engineering*, 44: 8, (1997) 775-779.
- [8] Sriraam N., Eswaran C., An Adaptive Error Modeling Scheme for the Lossless Compression of EEG Signals, *IEEE Transactions on Information Technology in Biomedicine*, 12: 5, (2008) 587-594.
- [9] Deneux T., Faugeras O., EEG-fMRI Fusion of Paradigm-Free Activity Using Kalman Filtering, *Neural Computation*, 22: 4, (2010) 906–948.
- [10] Ahirwal M., Kumar K., A., Singh G.K., EEG/ERP Adaptive Noise Canceller Design with Controlled Search Space (CSS) Approach in Cuckoo and Other Optimization Algorithms, *IEEE/ACM Transactions on Computational Biology and Bioinformatics*, 10: 6, (2013) 1491–1504.
- [11] Maddirala A.K., Shaik R.A., Removal of EOG Artifacts From Single Channel EEG Signals Using Combined Singular Spectrum Analysis and Adaptive Noise Canceller, *IEEE Sensors Journal*, 16: 23, (2016) 8279–8287.
- [12] Kim C.S., Sun J., Liu D., Wang Q., Paek S.G., Removal of ocular artifacts using ICA and adaptive filter for motor imagery-based BCI, *IEEE/CAA Journal of Automatica Sinica*, (2017), Doi: 10.1109/TCBB.2013.119.
- [13] Mandic D.P., Goh V.S.L., *Complex Valued Nonlinear Adaptive Filters: Noncircularity, Widely Linear and Neural Models*. John Wiley & Sons, 2009.
- [14] Widrow B., McCool J., Ball M., The complex LMS algorithm, *Proceedings of the IEEE*, 63: 4 (1975) 719-720.
- [15] Picinbono B., Chevalier P., Widely linear estimation with complex data. *IEEE Transactions on Signal Processing*, 43: 8 (1995), 2030-2033.
- [16] Schreier P.J., Scharf L.L., Second-order analysis of improper complex random vectors and processes. *IEEE Transactions on Signal Processing*, 51: 3 (2003), 714-725.
- [17] Douglas S.C., Widely-linear recursive least-squares algorithm for adaptive beamforming. In *IEEE International Conference on Acoustics, Speech and Signal Processing*, 2009, 2041-2044.
- [18] Javidi S., Pedzisz M.S., Goh P., Mandic, D.P. The augmented complex least mean square algorithm with application to adaptive prediction problems. In the *ICognitive Information Processing Systems Conference*, 2008.
- [19] Douglas S.C., Mandic D.P., Performance analysis of the conventional complex LMS and augmented complex LMS algorithms. In *2010 IEEE International Conference on Acoustics Speech and Signal Processing (ICASSP)*, 2010, 3794-3797.
- [20] Jelfs B., Mandic D.P., Douglas S.C. An adaptive approach for the identification of improper complex signals. *Signal Processing*, 92: 2 (2012), 335-344.
- [21] Xia Y., Mandic D.P., Sayed A.H., An Adaptive Diffusion Augmented CLMS Algorithm for Distributed Filtering of Noncircular Complex Signals. *IEEE Signal Processing Letters*, 18: 11 (2011), 659-662.

- [22] Xia Y., Douglas S.C., Mandic D.P., Widely linear adaptive frequency estimation in three-phase power systems under unbalanced voltage sag conditions. In *The 2011 International Joint Conference on Neural Networks (IJCNN)*, 2011, 1700-1705.
- [23] Shi Y.M., Huang L., Qian C., So H.C., Shrinkage Linear and Widely Linear Complex-Valued Least Mean Squares Algorithms for Adaptive Beamforming, *IEEE Transactions on Signal Processing*, 63: 1, (2015) 119–131.
- [24] Zhang Y., Xiao S., Huang D., Sun D., Liu L., Cui H., 1 0-norm penalised shrinkage linear and widely linear LMS algorithms for sparse system identification, *IET Signal Processing*, 11: 1, (2017) 86–94.
- [25] Neeser F.D., Massey J.L., Proper complex random processes with applications to information theory. *IEEE Transactions on Information Theory*, 39: 4 (1993), 1293-1302.
- [26] Pavon M., A new formulation of stochastic mechanics, *Physics Letters A*, 209: 3-4 (1995), 143-149.
- [27] Picinbono B., Bondon P., Second-order statistics of complex signals. *IEEE Transactions on Signal Processing*, 45: 2 (1997), 411-420.
- [28] Adali T., Schreier P.J., Scharf L.L., Complex-valued signal processing: The proper way to deal with impropriety. *IEEE Transactions on Signal Processing*, 59:11 (2011), 5101-5125.
- [29] Javidi S., Mandic D.P., Took C.C, Cichocki A., S. Kurtosis based blind source extraction of complex noncircular signals with application in EEG artifact removal in real-time. *Frontiers in Neuroscience*, 5: 105 (2011), 1-18.
- [30] Goldberger A.L., Amaral L.A.N., Glass L., Hausdorff J.M., Ivanov P.C., Mark R.G., Stanley H.E., *PhysioBank, PhysioToolkit, and PhysioNet components of a new research resource for complex physiologic signals*. *Circulation*, 101: 23 (2000), 215-220.
- [31] Citi L., Poli R., Cinel C., Documenting, modelling and exploiting P300 amplitude changes due to variable target delays in Donchin's speller. *Journal of Neural Engineering*, 7: 5 (2010), 056006.
- [32] Wang Z., Xu P., Liu T., Tian Y., Lei X., Yao D., Robust removal of ocular artifacts by combining Independent Component Analysis and system identification. *Biomedical Signal Processing and Control*, 10 (2014), 250–259.
- [33] Çınar S., Acır N, A novel system for automatic removal of ocular artefacts in EEG by using outlier defection methods and independent component analysis. *Expert Systems with Applications*, 68 (2017), 36-44.