



Belirsiz beyin korteks modelinin durum ve parametre kestirimi State and parameter estimation of uncertain brain cortex model

Meriç ÇETİN^{1*}, Selami BEYHAN²

¹Bilgisayar Mühendisliği Bölümü, Mühendislik Fakültesi, Pamukkale Üniversitesi, Denizli, Türkiye.
mctetin@pau.edu.tr

²Elektrik-Elektronik Mühendisliği Bölümü, Mühendislik Fakültesi, Pamukkale Üniversitesi, Denizli, Türkiye.
sbeeyhan@pau.edu.tr

Geliş Tarihi/Received: 29.01.2018, Kabul Tarihi/Accepted: 26.09.2018

doi: 10.5505/pajes.2018.67674

* Yazışılan yazar/Corresponding author

Özel Sayı Makalesi/ Special Issue Article

Öz

Beyin korteksinin yaklaşık modeli, günümüzde başta epilepsi, Parkinson gibi hastalıklar olmak üzere birçok hastalığın tedavisinde kullanılmaktadır. Korteks matematiksel modeli kesin olduğu kabul edilmektedir. Fakat zamanla değişen parametreler, gürültü ve diğer bozucu etkilerden dolayı bu model her zaman geçerli değildir. Ayrıca bazı durumların ölçülmesi zor ve pahalı olmasından dolayı yazılım temelli yapılması hedeflenmiştir. Dolayısıyla, bu çalışmada, belirsizlik içeren beyin korteks modelinin durum ve parametre kestirimi farklı karakteristiklere sahip doğrusal-olmayan gözetleyiciler ile beraber yapılmaktadır. Sadece durum kestirimi [1] çalışmasında yapılmıştır. Doğrusal-olmayan gözetleyici genişletilmiş Kalman filtre (EKF), kayan kip gözetleyici (SMO) ve ayrıklaştırma temelli gradyan gözetleyici (DBGO) yaklaşımları tasarlanmıştır. Ölçülemeyen durum ve belirsizlik parametresi kestirimleri normal çalışma ve epileptik durumları için yapılmaktadır. Çünkü korteks model doğrusal-olmayan dinamiklere sahiptir fakat epilepsi esnasında kaotik bir davranışa sahiptir. Bu yüzden önce normal durum çalışma sonra nöbet durumu için tahminler yapılmaktadır. Sayısal benzetimlerde tasarlanan gözetleyicilerin başarılı şekilde ölçülemeyen durum ve parametre tahminlerini yaptığı gözlenmiştir. Tahmin sonuçları ve tahmin başarımlarını performansları tasarlanan gözetleyicileri gürültülü ve gürültüsüz durumlarda karşılaştırmak için verilmiştir.

Anahtar kelimeler: Korteks model, Doğrusal-olmayan gözetleyici, Durum ve parametre kestirimi, EKF, SMO, DBGO

Abstract

Nowadays, an approximate mathematical model of the brain cortex has been used for the treatment of the first epilepsy and Parkinson, and several diseases. It is assumed that the mathematical model of the cortex is an exact model. However, due to the time-varying parameters, noise and other disturbances, this model is not always valid. Moreover, since it is difficult and expensive to measure some states, software based solution is aimed here. Consequently, in this paper, state and parameter estimation of the brain cortex model are jointly achieved using nonlinear observers of different characteristics. The state estimation of the model was merely performed in [1]. As the nonlinear observers, extended-Kalman filter (EKF), sliding-mode observer (SMO) and discretization based gradient observer (DBGO) approaches are designed. The estimation of unmeasurable states and parameters are performed both for the epileptic and normal state of the mathematical model since the cortex model has normally nonlinear dynamics but it exhibits chaotic behavior in epileptic state. Therefore, the estimations are provided for first normal state, then epileptic state. In computational results, it is observed that the designed nonlinear observers resulted successful estimations for unmeasurable states and parameters. The estimation results and estimation performances are given to compare the nonlinear observers for noisy and noiseless cases.

Keywords: Cortex model, Nonlinear observer, State and parameter estimation, EKF, SMO, DBGO

1 Giriş

Günümüzde epilepsi ve Parkinson gibi rahatsızlıklar insanların gündelik yaşamını önemli şekilde etkilemektedir. Genel olarak epilepsi merkezi sinir sisteminde gerçekleşen tek bir rahatsızlık tipi olmayıp farklı beyinsel aktivite bozukluklarının nöbetlere dönüşmüş halidir. Bu yüzden sebebi kişiden kişiye değişmekte olup %50 den fazlasının sebebi bilinmemektedir. Epilepsi ve Parkinson gibi rahatsızlıkların tedavi edilebilmesi için beyinden alınan EEG sinyalleri analiz edilmektedir. EEG sinyalleri analizinden epilepsi esnasında sinirlerin aksiyon potansiyellerinin kaotik bir davranışı olduğu gözlenmiştir. Diğer bir ifade ile epilepsi rahatsızlığı sinir hücrelerinin iletiminde kontrol dışı bozulmalar olmasıdır. Beyin korteksinin mezoskopik seviyedeki yaklaşık matematiksel modeli [2], [3] çalışmalarında türetilmiştir. Kontrol teorisinde bilinen geri beslemeli kontrol yöntemleri aracılığıyla üretilen kontrol sinyalleri hastaya uygulanmaktadır. Epilepsi tedavisi (elektriksel uyartım veya optogenetik) için tasarlanan kontrol yöntemleri [4], korteksin kesin matematik modelinin varsayımı üzerine kuruludur. Uygulanan kontrol metotları, genellikle

çıkış hatasının minimizasyonu üzerinden tasarlanırken korteks modelinin tüm durumları dikkate alan çalışmalar henüz yaygın değildir. Çünkü tüm durumların ölçülmesi mümkün değildir. Bunun yanında, matematiksel modeldeki belirsizlikler ya da harici bozucular nedeniyle doğru ölçüm sonuçları her zaman mümkün olmayabilir ya da ölçümler gürültülü olabilir. Literatürde beyin korteks modelini kullanarak geri besleme mekanizması ile farklı kontrol [5]-[10] ve kestirim yöntemlerini [11], [12] içeren çalışmalar mevcuttur.

Karmaşık bileşenlerden oluşan kontrol sistemlerinin güvenliği ve güvenilirliği, sürecin performansını arttırmak için çok önemlidir. Sistemdeki belirsizlikler veya bozulmalar istenmeyen davranışlarına veya arızalarına neden olabilir. Bu koşullarda, ölçülen giriş ve çıkış sinyallerini kullanarak süreçteki hatanın veya belirsizliğin tespitini yapmak sistem modelinin tutarlılığını test etmek için gereklidir. Hataları tespit etmek için gözetleyici tasarımı, parametre kestirim yaklaşımı, frekans spektral analizi veya sinir ağı gibi tipik yöntemler kullanılmaktadır. [13] çalışmasına göre, belirsizlik veya arıza tespiti için en sık uygulanan teknikler parametre kestirimi ve gözetleyici temelli yöntemlerdir. Doğrusal/doğrusal-olmayan

gözetleyiciler veya Kalman filtreleme tabanlı yöntemler, durum ve parametre tahminleri için bilinen tekniklerdir. Bu çalışmada, belirsiz korteks dinamiğinin tek bir durum ölçümü ile diğer ölçülemeyen durumlarının ve parametrenin tahmin edilmesi için gözetleyici tasarımları yapılmıştır.

Doğrusal-olmayan gözetleyiciler durum ve parametre tahmininde izleme ve kontrol alanında önemli bir yere sahiptir. Sistemlere ait durumların ölçülmesinde sensör teknolojisi ne kadar gelişmiş olsa da sensörlerin sistem üzerindeki montajında ağırlık, boyut gibi problemlerden dolayı durum gözetleyicileri tercih edilmektedir. Bunun yanında durum veya parametre gözetleyicisi sadece yazılım ile yapılabileceğinden dolayı maliyet açısından önemlidir. Durum gözetleyicileri öncelikle doğrusal sistemler [14] için daha sonra doğrusal-olmayan sistemler [15] için genişletilmiştir. Durum gözetleyicilerine ihtiyacın artması ile beraber genişletilmiş-Luenberger (ELO) [16], genişletilmiş Kalman filtresi (EKF) [17], kayan-kip gözetleyici (SMO) [18], [19], yüksek-kazanç gözetleyicisi (HGO) [20], Takagi-Sugeno gözetleyicisi ve son zamanlarda geliştirilen ayrıklaştırma temelli gradyan gözetleyicisi (DBGO) [21]-[23] önerilmiştir ve uygulamalar yapılmıştır. Bu gözetleyicilerden, literatürde en sık kullanılanlardan genişletilmiş Kalman filtresi gürültülü ortamlarda hala iyi seviyede tahmin yapabilmesinden dolayı önemli bir yeri vardır. Kayan-kip gözetleyici ise matematiksel yapısı gereği sistemdeki belirsizliklere karşı gürbüzlük özelliği ile öne çıkmaktadır. Bunun yanında ayrıklaştırma temelli gradyan gözetleyici ise çok hızlı yakınsama özelliği ile literatürde önemli bir yeri olmuştur.

Bu çalışmada, doğrusal-olmayan gözetleyiciler beyin korteks sisteminin matematiksel modelinin durum tahmini için tasarlanmıştır. Gerçek zamanlı uygulamalarda beyin korteks dinamiklerinin uygulanabileceği epilepsi, Parkinson ve benzeri rahatsızlıkların tedavisi için yaklaşık bir matematik modeli ortaya koymuştur. Beyin korteks modeli 14 durum ile ifade edilmiştir. Bu durumların birçoğunun hassas şekilde ölçülmesi neredeyse imkânsızdır. Bu yüzden gözetleyici tasarımı ve bunun sonuçlarının ileriki uygulamalarda faydalı olacağı düşünülmektedir. Bu kapsamda, bir mikro denetleyiciye gömülen gözetleyici temelli denetleyici algoritması vasıtasıyla hastalara uygulanabilecek elektriksel uyartım ya da optogenetik sinyalinin seviyesi belirlenebilecek ve hasta normal durumdan nöbet durumuna geçmeden önce oluşabilecek nörolojik etkilerin önüne geçilebilecektir. Özellikle epilepsi gibi yaşam standartlarını oldukça etkileyen rahatsızlıkların tedavisinde tüm durumların ölçülmesine gerek olmadan ya da modeldeki belirsizliklerin etkisini azaltan gözetleyici veya denetleyici tasarımı yapılabilecektir. Gözetleyici tasarımları normal durum ve epilepsi nöbeti için uygulanması ve karşılaştırılması açısından bu iki durum birleştirilmiştir. Yani normal durumda sinir iletimi devam ederken epilepsi nöbetine geçen hastanın korteks dinamikleri gözetleyiciler ile tahmin edilmiştir. İleriki çalışmalarda önerilen gözetleyici algoritmalarının bir mikro denetleyiciye gömülmesi Benzetimlerde tüm tahmin sonuçları en iyi başarımla performansı gösteren DBGO gözetleyici için gösterilmiştir ve toplam normalize ortalama karesel hata (NMSE) performansları karşılaştırılmıştır. Bunun yanında, gürültülü ve gürültüsüz durumlar için benzetimler ayrı ayrı yapılmıştır ve sonuçlar gösterilmiştir.

Çalışmanın devamında, Bölüm 2'de, doğrusal-olmayan gözetleyici yaklaşımları ve kaotik epilepsi davranışları

açıklanacaktır. Çalışmanın benzetim sonuçları ve karşılaştırmalara Bölüm 3'de yer verilecektir. Bölüm 4'de ise çalışmanın sonuçları ve gelecek çalışmalar anlatılmaktadır.

2 Yöntem

2.1 Genişletilmiş kalman filtre (EKF)

Gürültülü ve gürültüsüz ortamlarda durum ve parametre tahmini için en çok kullanılan yöntemlerden olan EKF tasarımında, doğrusal-olmayan süreç dinamiklerinin türevlenebilir olması gerekir. Süreç (process) ve ölçüm (measurement) fonksiyonlarının kısmi türevleri anlık tahmin civarındaki değerler ile doğrusallaştırılır [24], [25]. Böylece anlık tahmin değerleri ve matematiksel model kullanılarak durum tahmini yapılır. EKF'de gözetleyici başarımı, bilinen olumlu özelliklerin yanı sıra başlangıç değerlerine ve istatistiksel formdaki süreç ve ölçüm gürültü kovaryanslarının seçimine bağlıdır. Bu karakteristiklerdeki yanlış varsayımlar filtre başarımını kötüleştirir. Doğrusal-olmayan ayrık zamanlı dinamik bir sistemin durum uzayı modeli

$$\begin{aligned} \mathbf{x}[n+1] &= \mathbf{g}(\mathbf{x}[n], u[n]) + \mathbf{f}[n] + \mathbf{w}[n], \\ y[n+1] &= h(\mathbf{x}[n], u[n]) + v[n], \\ \mathbf{w} &\sim \mathcal{N}(0, Q), v \sim \mathcal{N}(0, R) \end{aligned} \quad (1)$$

ise $\mathbf{x}[n]$ N -boyutlu durum vektörünü, $u[n] \in \mathbb{R}$ giriş işaretini ve $y[n] \in \mathbb{R}$ de çıkış işaretini gösterir. $\mathbf{f}[n]$, sürekli veya parçalı-sürekli herhangi bir fonksiyon olarak varsayılır ve dinamiklerdeki bilinmeyen belirsizlikleri, sistem arızalarını, harici bozucuları veya bilinen olasılıksal dağılımları temsil eder. Rasgele değişkenler w ve v sırasıyla sistemin süreç gürültüsü ve ölçüm gürültüsüdür. Süreç ve ölçüm gürültüleri Q ve R gürültü kovaryans matrislerine sahip, sıfır ortalamalı normal dağılımlı beyaz gürültülerdir. EKF yapısının tahmin adımında durumlar dinamik modelle kestirilir, düzeltme adımında ise gözetleyici model ile düzeltilir. EKF'ye ait zaman güncelleme/tahmin adımının denklemleri aşağıdaki şekildedir.

$$\begin{aligned} \hat{\mathbf{x}}^-[n] &= \hat{\mathbf{g}}(\hat{\mathbf{x}}^-[n-1], u[n-1]) \\ \mathbf{P}^-[n] &= \mathbf{A}[n]\mathbf{P}^-[n-1]\mathbf{A}^T[n] + \mathbf{Q}, \end{aligned} \quad (2)$$

Ölçüm güncelleme/düzeltilme adımları ise şu şekildedir.

$$\begin{aligned} \mathbf{K}[n] &= \mathbf{P}^-[n]\mathbf{H}^T[n](\mathbf{H}[n]\mathbf{P}^-[n]\mathbf{H}^T[n] + \mathbf{R})^{-1}, \\ \hat{\mathbf{x}}[n] &= \hat{\mathbf{x}}^-[n] + \mathbf{K}[n](y[n] - h(\hat{\mathbf{x}}^-[n], u[n-1])), \\ \mathbf{P}[n] &= (\mathbf{I} - \mathbf{K}[n]\mathbf{H}[n])\mathbf{P}^-[n], \end{aligned} \quad (3)$$

Bu ifadelerde $\hat{\mathbf{x}}[n]$ durum tahmini vektörüdür. Burada $\hat{\mathbf{g}}$ ve h fonksiyonlarının \mathbf{x} ve u değişkenlerine göre türevlenebildiği varsayılmaktadır. Her örnekleme anında değişerek güncellenen $\mathbf{A}[n]$ ve $\mathbf{H}[n]$ matrisleri ise aşağıdaki şekilde hesaplanır.

$$\mathbf{A}[n] = \left. \frac{\partial \hat{\mathbf{g}}}{\partial \mathbf{x}} \right|_{\substack{\mathbf{x}=\mathbf{x}[n-1] \\ u=u[n-1]}} \quad \text{ve} \quad \mathbf{H}[n] = \left. \frac{\partial h}{\partial \mathbf{x}} \right|_{\substack{\mathbf{x}=\mathbf{x}[n-1] \\ u=u[n-1]}} \quad (4)$$

Genişletilmiş Kalman filtresinde durum tahmini sürecinde, x_n durumunun yinelemeli bir olasılıksal tahmini, standart Gauss yaklaşımı yöntemiyle elde edilir. Bilinmeyen belirsizlikler ve sistem arızalarının tahmini için eş zamanlı olarak sistemdeki ölçülemeyen durumları ve bilinmeyen parametreleri kestiren bir ortak Kalman filtre (Joint EKF-JoEKF) tercih edilebilir. JoEKF, bilinmeyen sistem durumları ve parametreleri için aşağıdaki gibi bir arttırılmış durum vektörüne ihtiyaç duyar [26]:

$$\mathbf{x}_n^{\text{aug}} = [\mathbf{x}_n^T \quad \mathbf{f}_n^T \quad \mathbf{w}_n^T \quad \mathbf{v}_n^T],$$

$$\mathbf{P}_n^{\text{aug}} = \begin{bmatrix} \mathbf{P}_n^x & 0 & 0 & 0 \\ 0 & \mathbf{P}_n^f & 0 & 0 \\ 0 & 0 & \mathbf{Q} & 0 \\ 0 & 0 & 0 & \mathbf{R} \end{bmatrix} \quad (5)$$

(5) eşitliğinde $\mathbf{P}_n^{\text{aug}}$ matrisi artırılmış durum değişkenlerine ait kovaryans matrislerini göstermektedir. Bu yapı sayesinde hata dinamiklerinin en aza indirgenmesi sağlanmış olur.

2.2 Ayrıklaştırma temelli gradyan gözetleyici (DBGO)

Sürekli zamanlı doğrusal-olmayan N -boyutlu bir sistemin durum denklemleri (1) eşitliğinde olduğu gibi vektörel formda $\mathbf{x} = \mathbf{g}(\mathbf{x}, u)$, $y = h(\mathbf{x}, u)$ $\mathbf{x} \in \mathfrak{R}^N$, $u \in \mathfrak{R}$ şeklinde verilsin. n , $t = nT_s$ zamanındaki örnekleme periyodu olmak üzere bir sonraki örnekleme adımına ait $x_i[n+1]$ ve $y_i[n+1]$ ifadeleri 4. mertebeden Runge-Kutta algoritması ile aşağıdaki gibi tahmin edilebilir.

$$\begin{aligned} \mathbf{x}[n+1] &= \hat{\mathbf{g}}(\mathbf{x}[n], u[n]) \\ &= \mathbf{x}[n] + \frac{1}{6}(\mathbf{k}_1 + 2\mathbf{k}_2 + 2\mathbf{k}_3 + \mathbf{k}_4) \\ \hat{y}[n+1] &= h(\mathbf{x}[n+1], u[n]) \end{aligned} \quad (6)$$

burada

$$\begin{aligned} \mathbf{k}_1 &= T_s \mathbf{g}(\mathbf{x}[n], u[n]), \\ \mathbf{k}_2 &= T_s \mathbf{g}(\mathbf{x}[n] + 0.5\mathbf{k}_1, u[n]), \\ \mathbf{k}_3 &= T_s \mathbf{g}(\mathbf{x}[n] + 0.5\mathbf{k}_2, u[n]), \\ \mathbf{k}_4 &= T_s \mathbf{g}(\mathbf{x}[n] + \mathbf{k}_3, u[n]). \end{aligned} \quad (7)$$

Bu ifadeler sürekli zamanlı bir sistemin ayrık zamanlı modelinde durum tahmini için kullanılabilir. Bunun için gradyan-azalan metodunda anlık çıkış ölçümleri kullanılarak tahminleme işlemi aşağıdaki gibi gerçekleştirilir.

$$\begin{aligned} \mathbf{x}[n+1] &= \mathbf{x}[n] - \frac{\partial E[n+1]}{\partial \mathbf{x}[n]}, \\ \hat{y}[n+1] &= h(\mathbf{x}[n+1], u[n]) \end{aligned} \quad (8)$$

$e[n]$, çıkış tahmin hatasını ($y[n] - \hat{y}[n]$) göstermek üzere $e[n]$ 'i en aza indirecek amaç fonksiyonu $E[n] = \frac{1}{2} \mathbf{e}[n]^2$ şeklinde tanımlanır. Amaç fonksiyonunun sistem durumlarına göre türevi

$$\begin{aligned} \frac{\partial E[n+1]}{\partial \mathbf{x}[n]} &= \frac{\partial E[n+1]}{\partial \hat{y}[n+1]} \frac{\partial \hat{y}[n+1]}{\partial \mathbf{x}[n]}, \\ &= -\mathbf{e}[n+1] \frac{\partial h[n+1]}{\partial \mathbf{x}[n+1]} \frac{\partial \mathbf{x}[n+1]}{\partial \mathbf{x}[n]} \end{aligned} \quad (9)$$

şeklinde (9) eşitliğinde çıkış değerinin her bir duruma göre türevinin alınması ile Jakobiyen matrisi (\mathbf{J}_x) elde edilir. Sistemin ayrık-zamanlı modeli kullanılarak elde edilen $\frac{\partial \mathbf{x}[n+1]}{\partial \mathbf{x}[n]}$ terimi DBGO yapısında oldukça önemli bir rol oynar. Jakobiyen matrisinin türev bileşenleri, RK algoritmasına dayalı ayrıklaştırılmış modelin zaman güncellemesi kullanılarak çıkarılabilir.

$$\mathbf{J}_x[n] = \frac{\partial^T h}{\partial \mathbf{x}} \Big|_{\mathbf{x}=\mathbf{x}[n+1]} \frac{\partial \mathbf{x}[n+1]}{\partial \mathbf{x}[n]}, \quad (10)$$

Burada,

$$\frac{\partial \mathbf{x}[n+1]}{\partial \mathbf{x}[n]} = \mathbf{I} + \frac{1}{6} \left(\frac{\partial K_1}{\partial \mathbf{x}[n]} + 2 \frac{\partial K_2}{\partial \mathbf{x}[n]} + 2 \frac{\partial K_3}{\partial \mathbf{x}[n]} + \frac{\partial K_4}{\partial \mathbf{x}[n]} \right) \quad (11)$$

(11) eşitliği için gereken sistem durumlarına göre türevler

$$\begin{aligned} \frac{\partial K_1}{\partial \mathbf{x}[n]} &= T_s \frac{\partial \mathbf{g}}{\partial \mathbf{x}[n]} \Big|_{\substack{x[n]=x[n], \\ u[n]=u[n]}}, \\ \frac{\partial K_2}{\partial \mathbf{x}[n]} &= T_s \left[\frac{\partial \mathbf{g}}{\partial \mathbf{x}[n]} (I + 0.5 \frac{\partial K_1}{\partial \mathbf{x}[n]}) \right] \Big|_{\substack{x[n]=x[n]+0.5K_1, \\ u[n]=u[n]}}, \\ \frac{\partial K_3}{\partial \mathbf{x}[n]} &= T_s \left[\frac{\partial \mathbf{g}}{\partial \mathbf{x}[n]} (I + 0.5 \frac{\partial K_2}{\partial \mathbf{x}[n]}) \right] \Big|_{\substack{x[n]=x[n]+0.5K_2, \\ u[n]=u[n]}}, \\ \frac{\partial K_4}{\partial \mathbf{x}[n]} &= T_s \left[\frac{\partial \mathbf{g}}{\partial \mathbf{x}[n]} (I + \frac{\partial K_3}{\partial \mathbf{x}[n]}) \right] \Big|_{\substack{x[n]=x[n]+K_3, \\ u[n]=u[n]}} \end{aligned} \quad (12)$$

şeklinde hesaplanır. \mathbf{J}_x matrisi ve Levenberg-Marquardt (LM) yönü kullanılarak durumları güncellemede gerekli düzeltme terimi $\delta_x[n+1] = -(\mathbf{J}_x^T \mathbf{J}_x + \mu_x \mathbf{I})^{-1} \mathbf{J}_x^T \mathbf{e}[n+1]$ olarak bulunur. Burada, $\mathbf{I}_{N \times N}$ şeklindeki birim matris ve μ_x terimi LM yönü hesaplamasında Dik-iniş (Steepest-Descent) ve Newton yönleri arasında seçim yapılmasını sağlayan anahtarlama terimidir. Bu aşamadan sonra DBGO durum güncellemesi

$$\begin{aligned} \mathbf{x}[n+1] &= \mathbf{x}[n] + \delta_x[n+1], \\ \hat{y}[n+1] &= h(\mathbf{x}[n+1], u[n]) \end{aligned} \quad (13)$$

şeklinde gerçekleştirilebilir. Doğrusal-olmayan sistemin RK modeli, sadece sistemin durumlarına ait tahmin vektörünü üretmek amacıyla kullanılmaz, aynı zamanda sistemdeki parametre değişimlerine yada sistem arızalarına uyum sağlamak için model-tabanlı parametre tahmin bloğunda da kullanılabilir. Sistem dinamiklerinde belirsizlik yada dış kaynaklı arıza gibi bozucu etkiler mevcutsa geleneksel kontrol yöntemleri ile sistemi kontrol etmek kolay olmayabilir. Bu durumda belirsizliğin yada arızanın etkisini bastırmak için teorik olarak iyi tasarlanan, sağlam ve model-tabanlı gözetleyiciler tercih edilebilir. Bu çalışmada, n zaman indisinde giriş/çıkış sinyallerinin bilindiği varsayılarak doğrusal-olmayan sistem durumlarının tahmini ile birlikte sistemi etkileyebilecek belirsizliklerin ve sistem arızalarının eş zamanlı kestirimi amaçlanmıştır. Bilinmeyen ve ölçülemeyen bu parametrelerin bulunması için öncelikle sistemin daha sonraki zaman indisine ait $\mathbf{x}[n+1]$ değerleri tahmin edilir daha sonra parametrelerle ilişkili olan tahmin hataları vektörü aşağıdaki gibi güncellenir:

$$\mathbf{e} = \begin{bmatrix} e_1 \\ e_2 \\ \vdots \\ e_N \end{bmatrix} = \begin{bmatrix} x_1[n+1] - \hat{x}_1[n+1] \\ x_2[n+1] - \hat{x}_2[n+1] \\ \vdots \\ x_N[n+1] - \hat{x}_N[n+1] \end{bmatrix}. \quad (14)$$

\mathbf{e} vektörü bilinmeyen sistem arızalarının tahmini için gerekli olan \mathbf{J}_f jakobyen vektörünün hesabında kullanılır. Bilinmeyen parametrelere göre parçalı türevlerinden oluşan \mathbf{J}_f vektörü:

$$\mathbf{J}_f = \begin{bmatrix} \frac{\partial e_1}{\partial \mathbf{f}} \\ \frac{\partial e_2}{\partial \mathbf{f}} \\ \vdots \\ \frac{\partial e_N}{\partial \mathbf{f}} \end{bmatrix} = - \begin{bmatrix} \frac{\partial \hat{x}_1[n+1]}{\partial \mathbf{f}} \\ \frac{\partial \hat{x}_2[n+1]}{\partial \mathbf{f}} \\ \vdots \\ \frac{\partial \hat{x}_N[n+1]}{\partial \mathbf{f}} \end{bmatrix} \quad (15)$$

şekindedir. Bilinmeyen belirsizlikler ve sistem arızalarının tahmini için güncelleme kuralı:

$$\begin{aligned} \mathbf{f}[n+1] &\leftarrow \mathbf{f}[n] + \Delta\mathbf{f}[n] \\ \Delta\mathbf{f}[n] &= -(\mathbf{J}_f^T \mathbf{J}_f + \mu_f \mathbf{I})^{-1} \mathbf{J}_f^T \mathbf{e} \end{aligned} \quad (16)$$

şekindedir. Bu aşamadan sonra, \mathbf{J}_f tanımındaki $\frac{\partial \hat{x}_1[n+1]}{\partial \mathbf{f}}, \dots, \frac{\partial \hat{x}_N[n+1]}{\partial \mathbf{f}}$ parçalı türevler:

$$\begin{aligned} \frac{\partial \hat{x}_i[n+1]}{\partial \mathbf{f}} &= \frac{\partial (\hat{x}_i[n] + \mathbf{K})}{\partial \mathbf{f}} \\ &= \frac{1}{6} \left(\frac{\partial K_1}{\partial \mathbf{f}} + 2 \frac{\partial K_2}{\partial \mathbf{f}} + 2 \frac{\partial K_3}{\partial \mathbf{f}} + \frac{\partial K_4}{\partial \mathbf{f}} \right) \end{aligned} \quad (17)$$

şeklinde olur. Burada

$$\begin{aligned} \frac{\partial K_1}{\partial \mathbf{f}} &= T_s \left. \frac{\partial \mathbf{g}}{\partial \mathbf{f}} \right|_{\substack{x[n]=x[n], \\ u[n]=u[n]}}, \\ \frac{\partial K_2}{\partial \mathbf{f}} &= T_s \left[\frac{\partial \mathbf{g}}{\partial \mathbf{f}} + \frac{1}{2} \frac{\partial \mathbf{g}}{\partial \mathbf{x}} \frac{\partial K_1}{\partial \mathbf{f}} \right] \bigg|_{\substack{x[n]=x[n]+0.5K_1, \\ u[n]=u[n]}}, \\ \frac{\partial K_3}{\partial \mathbf{f}} &= T_s \left[\frac{\partial \mathbf{g}}{\partial \mathbf{f}} + \frac{1}{2} \frac{\partial \mathbf{g}}{\partial \mathbf{x}} \frac{\partial K_2}{\partial \mathbf{f}} \right] \bigg|_{\substack{x[n]=x[n]+0.5K_2, \\ u[n]=u[n]}}, \\ \frac{\partial K_4}{\partial \mathbf{f}} &= T_s \left[\frac{\partial \mathbf{g}}{\partial \mathbf{f}} + \frac{\partial \mathbf{g}}{\partial \mathbf{x}} \frac{\partial K_3}{\partial \mathbf{f}} \right] \bigg|_{\substack{x[n]=x[n]+K_3, \\ u[n]=u[n]}} \end{aligned} \quad (18)$$

Sonuç olarak, sistemin RK modeli kullanılarak uyarlamalı kestirim mekanizması içinde çevrimiçi belirsizlik ve arıza kestirimi yapılabilir.

2.3 Kayan-Kip gözetleyici (SMO)

Kayan-kip gözetleyici, sonlu zamanlı ve hızlı yakınsama, belirsizliklerle ilgili gürbüzlük ve kararlılık gibi özellikleriyle geniş bir uygulama alanına sahiptir. Hem doğrusal-olmayan sistemlerde hem de özel uygulama modellerinde durum ve parametre tahmininde SMO'nun teorik ve pratik gözetleyici gelişmelerindeki etkisi artarak devam etmektedir [27]. [19], [27] çalışmalarında SMO'nun doğrusal geri besleme elemanları, gözetleyici olarak tanımlanabilmiş ve gürbüzlüğü geliştirecek bu elemanların genliğinin etkisi tartışılmıştır. Bu sayede SMO, doğrusal-olmayan etkilere karşı üstün bir başarımlı gösterebilir. Slotine'nin çalışmasında [19] verilen doğrusal-olmayan n. mertebeden bir sistem formu

$$\mathbf{x}^{(n)} = \mathbf{g}(\mathbf{x}, u) \quad (19)$$

şekindedir. $\mathbf{g}(\mathbf{x}, u)$, sistem durumlarının fonksiyonu olan doğrusal-olmayan vektör fonksiyonudur. Burada x_1 durumunun tek kullanılabilir ölçüm değeri olduğu varsayılırsa SMO aşağıdaki gibi tasarlanır.

$$\begin{aligned} \hat{x}_1[n] &= -h_1 \varepsilon_1[n] + \hat{x}_2 - d_1 \text{sign}(\varepsilon_1[n]), \\ \hat{x}_2[n] &= -h_2 \varepsilon_1[n] + \hat{x}_3 - d_2 \text{sign}(\varepsilon_1[n]), \\ &\vdots \\ \hat{x}_N[n] &= -h_N \varepsilon_1[n] + \hat{\mathbf{g}} - d_N \text{sign}(\varepsilon_1[n]) \end{aligned} \quad (20)$$

Burada $\varepsilon_1[n] = \hat{x}_1[n] - x_1[n]$ ölçüm hatası ve $\hat{\mathbf{g}}$ fonksiyonu $\mathbf{g}(\mathbf{x}, \mathbf{t})$ 'nin bir kestirimidir. h_i katsayıları, d_i değerlerinin sıfır olduğu asimtotik hatanın azalmasını garantileyen klasik Luenberger gözetleyici için seçilen katsayılar gibidir. Hata dinamikleri (21) denklem takımıyla verilir.

$$\begin{aligned} \dot{\varepsilon}_1 &= -h_1 \varepsilon_1[n] + e_2 - d_1 \text{sign}(\varepsilon_1[n]) \\ \dot{\varepsilon}_2 &= -h_2 \varepsilon_1[n] + e_3 - d_2 \text{sign}(\varepsilon_1[n]) \\ &\vdots \\ \dot{\varepsilon}_N &= -h_N \varepsilon_1[n] + \Delta \mathbf{g} - d_N \text{sign}(\varepsilon_1[n]) \end{aligned} \quad (21)$$

burada $\Delta \mathbf{g} = \hat{\mathbf{g}} - \mathbf{g}$ ifadesinin $d_N \geq |\Delta \mathbf{g}|$ şeklinde sınırlı olduğu varsayılır. Kayma koşulu $(d/dt)(\varepsilon_1)^2$ aşağıdaki bölgede başlarılır.

$$\begin{aligned} e_2 &\leq d_1 + h_1 \varepsilon_1, & \varepsilon_1 > 0 \\ e_2 &\geq -d_1 + h_1 \varepsilon_1, & \varepsilon_1 < 0 \end{aligned} \quad (22)$$

(21) denkleminde $e_1 = 0$ üzerinde bir kayma kipi elde edildiğinde bunu $e_2 - d_1 \text{sign}(e_1) = 0$ takip eder. Bu yüzden

$$\begin{aligned} \dot{\varepsilon}_2 &= e_3 - \frac{d_2}{d_1} e_2 \\ &\vdots \\ \dot{\varepsilon}_N &= \Delta \mathbf{g} - \frac{d_N}{d_1} e_2 \end{aligned} \quad (23)$$

olur. [28] çalışmasında bahsedildiği üzere kayan-kip gözetleyici, belirsizlik yada sistem arızaları gibi bilinmeyen parametre veya harici bozucuları kestirmek için şu şekilde tasarlanabilir:

$$\dot{\hat{x}}_i = f_i^T \mathbf{g}_i(\mathbf{x}) \quad (24)$$

Burada f_i^T , kestirilmesi gereken bilinmeyen belirsizlikleri yada sistem arızalarını, $\mathbf{g}_i(\mathbf{x})$ ise doğrusal-olmayan bağımsız fonksiyonları temsil etmektedir. Kayan-kip gözetleyici yapısı bilinmeyen bu parametreleri kestirmek için

$$\begin{aligned} \dot{\hat{x}}_i &= \hat{f}_i^T \mathbf{g}_i(\mathbf{x}) + \mathbf{d}_i^T |\mathbf{g}_i(\mathbf{x})| z_i \\ \dot{\hat{f}}_i &= \gamma \mathbf{d}_i^T |\mathbf{g}_i(\mathbf{x})| z_i \\ z_i &= \text{sign}(e_i) = \begin{cases} 1, & \text{for } e_i > 0 \\ -1, & \text{for } e_i < 0 \end{cases} \end{aligned} \quad (25)$$

şeklinde tasarlanmalıdır. Burada e_i kestirim hatası, γ pozitif bir sabit sayı ve $\mathbf{d}_i^T = [d_1 \dots d_N]$ kayma yüzeyinin sıfıra yakınsaması için seçilen uygun sabitlerdir. Bu gözetleyicinin yakınsaklık ve kararlılık koşulları [27]'de türetilerek ispatlanmıştır.

2.4 Korteks matematiksel modeli

Beyin korteksinin, beyin davranışlarını araştırmak ve rahatsızlık durumlarını analiz etmek üzere uygun bir matematiksel model ile ifade edilmesi devam eden önemli çalışmalardandır. Kortikal alandaki teoriler, birbirine bağlı diferansiyel denklemlerin eşleştirilmiş kümeleri [29], [30], doğrusal-olmayan sıradan diferansiyel denklemlerin birleştirilmiş kümeleri [31], [32] olarak ve daha yakın zamanlarda doğrusal-olmayan kısmi diferansiyel denklemlerin birleştirilmiş kümesi [33], [34] olarak geliştirilmiştir. Merkezi korteksin elektriksel aktivitesini temsil eden CM model, stokastik parçalı diferansiyel eşitlikleri (SPDEs) içeren farklı durumlarla ifade edilmiştir. Bu modelin stokastik ve doğrusal-olmayan davranışı göz önünde bulundurularak epilepsi, uyku ve anestezi gibi Elektroensefalografi (EEG-Electroencephalography) temelli uygulamalar ve araştırmalar yapılabilmektedir. [35] çalışmasında SPDEs şeklinde ikinci mertebeden terimlerle sunulan korteks modeli, [3] çalışmasında 14 adet birinci mertebeden adi diferansiyel

denklemler (ODE) daha basit bir sistem şekline dönüştürülmüştür:

$$\begin{aligned}
\dot{h}_e &= [(h_e^{rest} - h_e) + \psi_{ee}(h_e)I_{ee} + \psi_{ie}(h_e)I_{ie}]/\tau_e, \\
\dot{h}_i &= [(h_i^{rest} - h_i) + \psi_{ei}(h_i)I_{ei} + \psi_{ii}(h_i)I_{ii}]/\tau_i, \\
\dot{I}_{ee} &= J_{ee}, \\
\dot{J}_{ee} &= -2\gamma_e J_{ee} - \gamma_e^2 I_{ee} \\
&+ [N_{ee}^\beta S_e(h_e) + \phi_e + p_{ee}]G_e \gamma_e e + \Gamma_1, \\
\dot{I}_{ei} &= J_{ei}, \\
\dot{J}_{ei} &= -2\gamma_e J_{ei} - \gamma_e^2 I_{ei} \\
&+ [N_{ei}^\beta S_e(h_e) + \phi_i + p_{ei}]G_e \gamma_e e + \Gamma_2, \\
\dot{I}_{ie} &= J_{ie}, \\
\dot{J}_{ie} &= -2\gamma_i J_{ie} - \gamma_i^2 I_{ie} + [N_{ie}^\beta S_i(h_i) + p_{ie}]G_i \gamma_i e + \Gamma_3, \\
\dot{I}_{ii} &= J_{ii}, \\
\dot{J}_{ii} &= -2\gamma_i J_{ii} - \gamma_i^2 I_{ii} + [N_{ii}^\beta S_i(h_i) + p_{ii}]G_i \gamma_i e + \Gamma_4, \\
\dot{\phi}_e &= \chi_e, \\
\dot{\chi}_e &= -2\bar{\nu}\Lambda_{ee}\chi_e - (\bar{\nu}\Lambda_{ee})^2 \phi_e \\
&+ \bar{\nu}\Lambda_{ee}N_{ee}^\alpha \left(\frac{\partial}{\partial t} + \bar{\nu}\Lambda_{ee}\right)S_e(h_e), \\
\dot{\phi}_i &= \chi_i, \\
\dot{\chi}_i &= -2\bar{\nu}\Lambda_{ei}\chi_i - (\bar{\nu}\Lambda_{ei})^2 \phi_i \\
&+ \bar{\nu}\Lambda_{ei}N_{ei}^\alpha \left(\frac{\partial}{\partial t} + \bar{\nu}\Lambda_{ei}\right)S_e(h_e),
\end{aligned} \quad (26)$$

Burada e ve i alt indisleri sırasıyla uyarıcı (excitatory) ve önleyici (inhibitory) nöron popülasyonlarını belirtir. Bu indis gösterimine göre, h_e (mV) değişkeni bir nöron popülasyonu için ortalama gövde potansiyelinin (excitatory mean soma potential) uyarılmasını, h_i (mV) değişkeni ise kısıtlanmasını ifade eder. I_{ee} (mV) değişkeni, uyarıcı popülasyondan gelen girdiler nedeniyle uyarıcı popülasyonun postsinaptik (postsynaptic) aktivasyonu, I_{ei} (mV) değişkeni ise önleyici popülasyonun postsinaptik aktivasyonudur. Benzer şekilde, I_{ie} (mV) değişkeni önleyici popülasyondan gelen girdilerden dolayı uyarıcı popülasyonun postsinaptik aktivasyonu I_{ii} (mV) değişkeni ise önleyici popülasyonun postsinaptik aktivasyonudur. ϕ_e (s^{-1}) ve ϕ_i (s^{-1}) değişkenleri sırasıyla uyarıcı ve önleyici popülasyonlarına kortikokortiküler (corticocortical) girdilerdir. Γ_j terimleri ise stokastik girdilerdir. Ayrıca $\psi_{jk}(h_k) = \frac{h_j^{ev} - h_k}{|h_j^{ev} - h_k^{rest}|}$, ($j, k \in e, i$) terimleri


$$I_{jk} \text{ girişleri için ağırlık faktörleridir. } S_e(h_e) = \frac{S_e^{max}}{1 + \exp[-g_e(h_e - \theta_e)]}$$

$$\text{ve } S_i(h_i) = \frac{S_i^{max}}{1 + \exp[-g_i(h_i - \theta_i)]} \text{ fonksiyonları, gövde potansiyelinin}$$


uyaran hızına eşleştiren sigmoid fonksiyonlarıdır. Korteks modele ait parametreler Şekil 1'de, patolojik parametrelere göre korteks modelin normal ve epileptik sinir iletimi ise Şekil 2'de sunulmuştur. Normal durumda model doğrusal-olmayan davranış iken epileptik durumda sistem kaotik davranış göstermektedir. Lyapunov üstelinin pozitif olduğu [3] çalışmasında gösterilmiştir. Benzetim çalışmalarında hem normal hem de epileptik sinir iletimi durumları birleştirilerek gözetleme yapılmıştır. Normal durumdan epileptik duruma geçiş patolojik parametreler p_{ee} ve G_e değerlerinin değiştirilmesi ile elde edilmiştir. Burada amaç aynı zamanda hastanın nöbete geçerkenki durumların gösterilmesi ve tahmin edilmesidir.

τ_e	Membran zaman sabiti	0.04s
τ_i	Membran zaman sabiti	0.04s
h_e^{rest}	Dayanma gerilimi	-70mV
h_i^{rest}	Dayanma gerilimi	-70mV
h_e^{ev}	Tersinme gerilimi	45mV
h_i^{ev}	Tersinme gerilimi	-90mV
p_{ee}	Uyarıcı popülasyona korteks altı dürtü girişi	1100s ⁻¹
p_{ie}	Uyarıcı popülasyona korteks altı dürtü girişi	1600s ⁻¹
p_{ei}	Kısıtlayıcı popülasyona korteks altı dürtü girişi	1600s ⁻¹
p_{ii}	Kısıtlayıcı popülasyona korteks altı dürtü girişi	1100s ⁻¹
Λ_{ee}	Kortikokortiküler ters-uzunluğu	0.04mm ⁻¹
Λ_{ei}	Kortikokortiküler ters-uzunluğu	0.065mm ⁻¹
γ_e	Uyarıcı postsinaptik potansiyelinin nörotransmitter hız sabiti	300s ⁻¹
γ_i	Kısıtlayıcı postsinaptik potansiyelinin nörotransmitter hız sabiti	65s ⁻¹
G_e	Uyarıcı postsinaptik potansiyelin tepe genişliği	0.18mV
G_i	Kısıtlayıcı postsinaptik potansiyelin tepe genişliği	0.37mV
$N_{ee}^\beta, N_{ei}^\beta$	Lokal sinaptik bağlantı sayısı	3034
$N_{ie}^\beta, N_{ii}^\beta$	Lokal sinaptik bağlantı sayısı	536
N_{ee}^α	Uzak uyarıcı popülasyondan toplam sinaptik bağlantı sayısı	4000
N_{ei}^α	Uzak uyarıcı popülasyondan toplam sinaptik bağlantı sayısı	2000
$\bar{\nu}$	Ortalama aksonal iletim hızı	7000mm.s ⁻¹
S_e^{max}, S_i^{max}	Sigmoid fonksiyonunun en büyük değeri	100s ⁻¹
θ_e, θ_i	Sigmoid fonksiyonunun büküm noktası potansiyeli	-60mV
g_e	Büküm noktasında sigmoid eğimi	0.28(mV) ⁻¹
g_i	Büküm noktasında sigmoid eğimi	0.14 (mV) ⁻¹

Şekil 1: Korteks model parametreleri.



a) Normal durumda h_e potansiyeli ($p_{ee} = 1100, G_e = 0.18mV$).



b) Epileptik durumda h_e potansiyeli ($p_{ee} = 54800, G_e = 0.1mV$).

Şekil 2: Patolojik parametreye göre korteks potansiyeli.

Bein korteks modeli, bazı patolojik koşullar altında kaotik dinamiğe sahip olan çok karmaşık bir modeldir. Şekil 2'den görüleceği üzere normal bir sinir iletiminde h_e (mV) potansiyeli bir denge noktasında olsa da epileptik durumda periyodik salınımlar göstermektedir. Epileptik salınımlar hastanın travma geçirdiğini ifade etmektedir. Böyle bir durumda, travmatik membran potansiyelini kararlı hale getirmek için uygun bir kontrol sinyali üretmek gerekir. Çeşitli denetleyicilerle gözetleyici temelli yapılacak bu süreç sonucunda elektriksel veya optogenetik bir uyarıma ihtiyaç duyulur. Önerilen yöntem sayesinde, korteks modelin dinamikleri gürültülü/gürültüsüz ya da belirsiz koşulların

bulduğu ortamlarda dahi yeterince doğru kestirilebilirse modele uygulanacak kontrol işaretine daha fazla güvenilebilir. Bu durumda elde edilen uyartım işareti tedavi amaçlı kullanılacağı için hastanın yaşam kalitesi oldukça iyileşecektir.

2.5 Gözetleyici tasarım parametrelerinin seçimi

Tatmin edici bir gözetleyici performansı için tasarlanan gözetleyicilere ait parametreler makul bir arama uzayında taranarak (grid-search) en uygun değerlerine ayarlanmıştır. Seçilen parametreler en uygun değerlerinde kullanıldıkları için gözetleyici temelli yapılacak herhangi bir uygulamada başarımın doğrudan artması beklenmektedir. Beyin korteks modelindeki sistem durumlarının ve belirsizlik fonksiyonunun tahmini için gereken parametreler sırasıyla şu şekilde seçilmiştir:

- i) DBGO için $\mu_x = 1e - 3, \mu_f = 1e - 5$.
- ii) SMO için $\mathbf{h}_{1:N} = 1e - 3$ (14 adet), $\mathbf{d}_{1:N} = 1e - 5$ (14 adet).
- iii) EKF için $\mathbf{P}_x = 1e4\mathbf{I}_{N \times N}, \mathbf{P}_f = 1e7\mathbf{I}_{N \times N}, \mathbf{Q} = 1e6, \mathbf{R} = 1e - 2\mathbf{I}_{N \times N}$.

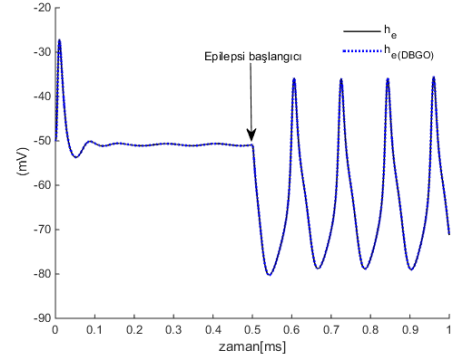
Bu çalışmadaki bilinmeyen giriş olarak kabul edilen belirsizlik fonksiyonu; harici bozuculardan, sistem arızalarından yada gürültülerden kaynaklandığı varsayılarak $f(t) = 30 + 10 \sin(5t/1000)$ şeklinde seçilmiştir.

3 Benzetim sonuçları


Benzetim sonuçları gürültülü ve gürültüsüz tahmin olmak üzere iki gruba ayrılmaktadır. Deneysel çalışmalarda belirsizlik tahmini de yapılacağı için durumlardan h_e 'nin ölçülebildiği varsayılmıştır. Arda kalan 13 durum ise gözetleyiciler ile tahmin edilmektedir. Bu noktada önemli olan durumun, korteks aktivasyon potansiyelini ifade eden h_e olduğu unutulmamalıdır. Normal ve epileptik durumda önemli derecede değişmektedir.

Gürültü sinyali yapay olarak h_e durumuna eklenmiştir. Gürültüyü h_e durumuna uygulamanın amacı hem çıkış olması hem de model dinamiklerindeki birçok durumda bu sinyalin bulunmasıdır. Sinyal-gürültü oranı (SNR) ise 25 dB olarak seçilmiştir. Daha yüksek gürültülerde gözetleyicilerin performansları düşmektedir. Daha düşük gürültü oranlarında ise tahmin başarımları çok daha yüksektir. Gürültü eklemenin amacı ise gözetleyicilerin gürültülü ortamdaki tahminlerinin karşılaştırılmasıdır. Gürültülü ortamda başarılı olması demek gerekli olan sensör ihtiyacını başarılı şekilde karşılamış olması demektir. Diğer bir ifadeyle izleme ve geribesleme kontrol çalışmalarında gürültüden fazla etkilenmeden doğru tahminler yapabilmesi sonucunda epilepsi vb. rahatsızlıklar daha kolay tedavi altına alınacaktır.


Sonuçlarda öncelikle ölçülen durum olan h_e 'ye ait gürültüsüz tahmin sonuçları tasarlanan 3 gözetleyici için Şekil 3'de, gürültülü tahmin sonuçları ise Şekil 4'de verilmiştir. Her iki durumda da başlangıçtaki yakınsama oranları hızlıdır ve sonuçlar ölçülen duruma göre elde edildiği için beklendiği üzere doğru tahminleme yapılmıştır. Ayrıca gürültülü ortamlarda EKF ve önerilen DBGO metotları SMO'ya göre başarılı şekilde gözetleme yapmaktadır.



DBGO ile h_e tahmini.




SMO ile h_e tahmini.




EKF ile h_e tahmini.


Şekil 3: Gürültüsüz durumda tüm h_e tahmin sonuçları.



DBGO ile h_e tahmini.



SMO ile h_e tahmini.



EKF ile h_e tahmini.

Şekil 4: Gürültülü durumda tüm h_e tahmin sonuçları.

Tablo 1'de gürültüsüz,

Tablo 2'de ise gürültülü korteks modelin tüm durumlarının (14 adet) tahmin sonuçlarına ait toplam normalize ortalama karesel hata değerleri verilmiştir.


Tablo 1: Gürültüsüz ortamda durum tahmini ile ilgili performans değerleri.

Metot	NMSE
DBGO	2.13e-4
SMO	0.333
EKF	8.65e-4


Tablo 2: Gürültülü ortamda durum tahmini ile ilgili performans değerleri.

Metot	NMSE
DBGO	3.24e-4
SMO	0.425
EKF	9.30e-4


Tablo değerlerine göre gürültülü ve gürültüsüz ortamda en iyi DBGO gözetleyicisi tahmin başarımı sağladığı için Şekil 5'te korteks modelin geriye kalan 13 durumunun, DBGO ile tahmin sonuçları verilmiştir.




h_i



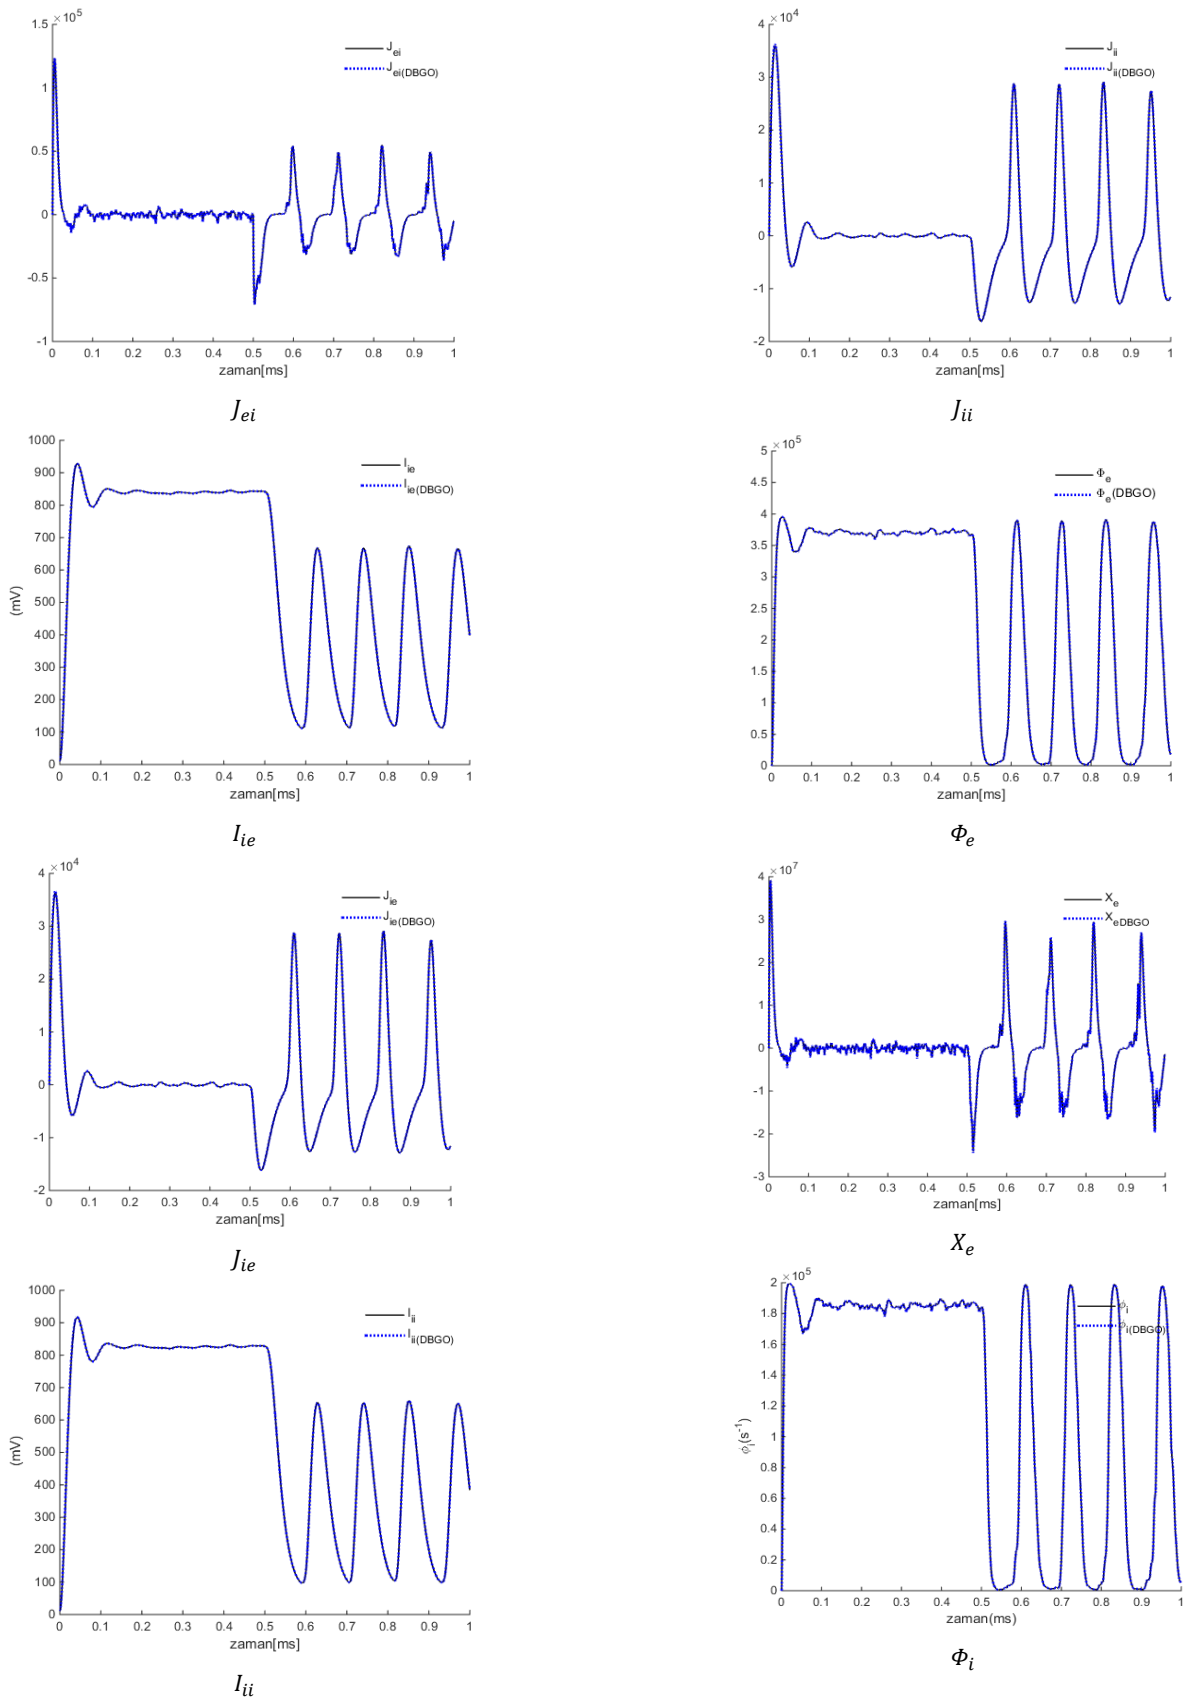
I_{ee}




J_{ee}




I_{ei}





Şekil 5: DBGO ile gürültülü ortamda tahmin sonuçları.

Bu davranıştaki bir belirsizliği en iyi şekilde tahmin eden gözetleyici durum tahminlerinde olduğu gibi DBGO gözetleyicisidir. Belirsizlik fonksiyonunun DBGO ile tahmin sonucu Şekil 6'da görülmektedir. DBGO tahminleme performansının yanısıra tasarım parametrelerinin seçimindeki ekonomik özelliği sayesinde bu türden bir sistemin bilinmeyen parametreleri ve ölçülemeyen durumlarının tahmininde tercih edilebilir ve geribeslemeli kontrol çalışmalarında kullanılabilir.



Şekil 6: DBGO ile belirsizlik fonksiyonu tahmin sonucu.

4 Sonuçlar

Bu çalışmada, beyin korteks dinamiğinin mezoskopik kortikal elektriksel aktivitesinin matematiksel modeli, epilepsi, parkinson ve benzeri gibi nörolojik hastalıklarda nöbete geçiş esnasında ölçülemeyen sistem durumlarının tahmini için araştırılmıştır. Bu amaçla üç farklı doğrusal-olmayan gözetleyici (EKF, DBGO, SMO) tasarlanmıştır. Tahmin sürecinde, ölçülemeyen sistem durumlarının ve belirsizlik fonksiyonunun gürültü varlığında dahi en uygun değerlerde elde edildiği gözlenmiştir. Bu kapsamda, EKF ve DBGO gözetleyicilerinin hem gürültülü hem de gürültüsüz ortamda yakın performanslar sağladığı görülmektedir. DBGO gözetleyicisi, gürültülü ortamda da başarılı olması ve tasarımının kolay olması ile öne çıkmaktadır. SMO'da genel olarak performans sonuçları daha kötüdür, ayrıca tasarım parametresi çok fazladır. Bu sonuçlara bakılarak en uygun değerlere sahip gözetleyicinin korteks stabilizasyonu için tercih edilebileceği söylenebilir. Devam eden çalışmamızda korteks modelde durum ve parametre tahmini temelli epilepsi kontrolü yapılacaktır.

5 Kaynaklar

- [1] Çetin M, Beyhan S. "Gözetleyici Temelli Beyin Korteks Model Durum Tahmini". *Otomatik Kontrol Türk Milli Komitesi*, İstanbul, Türkiye, 21-23 Eylül 2017.
- [2] Traub, RD, Contreras D, Cunningham MO, Murray H, LeBeau FE, Roopun A, Whittington MA. "Single-column thalamocortical network model exhibiting gamma oscillations, sleep spindles, and epileptogenic bursts". *Journal of Neurophysiology*, 93(4), 2194-2232, 2005.
- [3] Kramer MA, Szeri AL, Sleight JW, Kirsch HE. "Mechanisms of seizure propagation in a cortical model". *Journal of Computational Neuroscience*, 22(1), 63-80, 2007.
- [4] Giridharan RS, Cheung CC, Rubchinsky LL. "Effects of electrical and optogenetic deep brain stimulation on synchronized oscillatory activity in parkinsonian basal ganglia". *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 25(11), 2188-2195, 2017.
- [5] Tsakalis K, Chakravarthy N, Sabesan S, Iasemidis LD, Pardalos PM. "A feedback control systems view of epileptic seizures". *Cybernetics and Systems Analysis*, 42(4), 483-495, 2006.
- [6] Chakravarthy N, Tsakalis K, Sabesan S, Iasemidis L. "Homeostasis of brain dynamics in epilepsy: A feedback control systems perspective of seizures". *Annals of Biomedical Engineering*, 37(3), 565-585, 2009.
- [7] Lopour B, Szeri AJ. "A model of feedback control for the charge-balanced suppression of epileptic seizures". *Journal of Computational Neuroscience*, 28(3), 375-387, 2010.
- [8] Mirzaei A, Ozgoli S, Jajarm AE. "Chaotic analysis of the human brain cortical model and robust control of epileptic seizures using sliding mode control". *Systems Science & Control Engineering*, 2(1), 216-227, 2014.
- [9] Selvaraj P, Sleight JW, Kirsch HE, Szeri AJ. "Closed-loop feedback control and bifurcation analysis of epileptiform activity via optogenetic stimulation in a mathematical model of human cortex". *Physical Review E*, 93(1), 012416, 2016.
- [10] Wang J, Niebur E, Hu J, Li X. "Suppressing epileptic activity in a neural mass model using a closed-loop proportional-integral controller". *Scientific Reports*, 6, 2016.
- [11] Lopez-Cuevas A, Castillo-Toledo B, Medina-Ceja L, Ventura-Mejia C. "State and parameter estimation of a neural mass model from electrophysiological signals during the status epilepticus". *NeuroImage*, 113, 374-386, 2015.
- [12] Escuain-Poole L, Garcia-Ojalvo J, Pons AJ. "Extracranial estimation of neural mass model parameters using the unscented Kalman filter". *arXiv: 1708.05282*, 2017.
- [13] Simani S, Fantuzzi C, Patton RJ. "Model-based fault diagnosis techniques". *Model-based Fault Diagnosis in Dynamic Systems Using Identification Techniques*, 19-60, 2003.
- [14] Luenberger D. "Observers for multivariable systems". *IEEE Transactions on Automatic Control*, 11(2), 190-197, 1966.
- [15] Thau EE. "Observing the state of nonlinear systems". *International Journal of Control*, 17, 471-479, 1973.
- [16] Birk J, Zeitz M. "Extended-Luenberger observer for nonlinear multivariable systems". *International Journal of Control*, 47(6), 1823-1836, 1988.

- [17] Cox H. "On the estimation of state variables and parameters for noisy dynamic systems". *IEEE Transactions on Automatic Control*, 9(1), 5-12, 1964.
- [18] Drakunov SV. "An adaptive quasioptimal filter with discontinuous parameters". *Automatic Remote Control*, 44(9), 1167-1175, 1983.
- [19] Slotine JJ, Hedrick JK, Misawa EA. "On sliding observers for nonlinear systems". *Journal of Dynamic Systems, Measurement and Control*, 109, 245-252, 1987.
- [20] Gauthier JP, Hammouri H, Othman S. "A simple observer for nonlinear systems applications to bioreactors". *IEEE Transactions on Automatic Control*, 37(6), 875-880, 1992.
- [21] İplikci S. "Runge-Kutta model-based adaptive predictive control mechanism for non-linear processes". *Transactions of the Institute of Measurement and Control*, 35(2), 166-180, 2013.
- [22] Beyhan S. "Runge-Kutta model-based nonlinear observer for synchronization and control of chaotic systems". *ISA Transactions*, 52(4), 501-509, 2013.
- [23] Cetin M, Beyhan S, İplikci S. "Soft sensor applications of RK-based nonlinear observers and experimental comparisons". *Intelligent Automation & Soft Computing*, 23(1), 109-116, 2017.
- [24] Simon D. *Optimal State Estimation: Kalman, H-Infinity, and Nonlinear Approaches*, John Wiley & Sons, 2006.
- [25] Kalman RE. "A new approach to linear filtering and prediction problems". *Journal of Basic Engineering*, 82(1), 35-45, 1960.
- [26] Çetin M, Beyhan S. "Adaptive Stabilization of Uncertain Cortex Dynamics under Joint Estimates and Input Constraints", *IEEE Transactions on Circuits and Systems II: Express Briefs*, doi: 10.1109/TCSII.2018.2855450, 2018.
- [27] Spurgeon SK. "Sliding mode observers: a survey". *International Journal of Systems Science*, 39(8), 751-764, 2008.
- [28] Al-Hosani K, Utkin VI. "Parameters estimation using sliding mode observer with shift operator". *Journal of the Franklin Institute*, 349(4), 1509-1525, 2012.
- [29] Nunez PL, Srinivasan R. "Electric fields of the brain: the neurophysics of EEG". *Oxford University Press*, USA, 2006.
- [30] Wilson HR, Cowan JD. "A mathematical theory of the functional dynamics of cortical and thalamic nervous tissue". *Kybernetik*, 13(2), 55-80, 1973.
- [31] Freeman WJ. "Mass action in the nervous system", 1975.
- [32] Yao Y, Freeman WJ. "Model of biological pattern recognition with spatially chaotic Dynamics". *Neural networks*, 3(2), 153-170, 1990.
- [33] Jirsa VK, Haken H. "Field theory of electromagnetic brain activity". *Physical Review Letters*, 77(5), 960, 1996.
- [34] Robinson PA, Rennie CJ, Wright JJ. "Propagation and stability of waves of electrical activity in the cerebral cortex". *Physical Review E*, 56(1), 826, 1997.
- [35] Liley DT, Cadusch PJ, Wright JJ. "A continuum theory of electro-cortical activity". *Neurocomputing*, 26, 795-800, 1999.