



CB-MeMber filtresinin GM ve SMC gerçeklemelerinin sensör kontrolü performanslarının farklı ödül fonksiyonları için karşılaştırılması comparison of performances of GM and SMC implementations of CB-MeMber filter for sensor control

Ahmet GÜNEŞ*

¹D7 Suatlı Teknolojileri A.Ş., Ankara Üniversitesi Teknokent, Ankara, Türkiye.
ahmet.gunes@d-07.com

Geliş Tarihi/Received: 29.01.2018, Kabul Tarihi/Accepted: 18.10.2018
* Yazışılan yazar/Corresponding author

doi: 10.5505/pajes.2018.48344
Özel Sayı Makalesi/Special Issue Article

Öz

Bu çalışmada rastgele sonlu kümeler teorisi çerçevesinde geliştirilmiş olan kardinalitesi dengelenmiş çoklu Bernoulli filtresinin ardışık Monte Carlo ve Gaus karışımı gerçeklemeleri farklı sensör kontrolü uygulaması için karşılaştırılmıştır. Simülasyonlarda belirsizlik azaltılması ve bilgi kazanımına dayalı iki farklı ödül/ceza fonksiyonu kullanılmıştır. Bu fonksiyonlar, kısmen gözlemlenebilir Markov karar süreçleri yöntemi kullanılarak optimize edilmiş ve platformların bir sonraki hamlesi buna göre belirlenmiştir. Literatürde hali hazırda ardışık Monte Carlo gerçeklemeleri için kardinalitesi dengelenmiş çoklu Bernoulli filtresi ile sensör kontrolü alanında yayınlar bulunmaktadır. Ancak rastgele sonlu kümeler tabanlı filtrelerin Gaus karışımları üstüne fazla çalışma yoktur. Bu nedenle, algoritmaların Gaus karışımlarında da kullanılabilmesi için denklemler sunulmuştur. Bu iki farklı gerçekleştirme farklı sensörler ve farklı ödül/ceza fonksiyonları açısından simülasyonlarla karşılaştırılmıştır. Algoritmaların gerçek sistemlerde uygulandığında gösterecekleri performansları hakkında fikir vermesi açısından, çalışma süreleri sunulmuştur.

Anahtar kelimeler: Sensör kontrolü, Rastgele sonlu kümeler, Gaus karışımları

Abstract

In this work, sequential Monte Carlo and Gaussian mixture implementations of cardinality balanced multi-Bernoulli filter, developed under random finite set theory framework, are compared for sensor control application. In the simulations, two different types of reward/penalty functions are utilized. They are based on reduction of uncertainty and information gain. These functions are calculated using partially observable Markov decision processes framework. The sensors move according to the outputs of these functions. The formulations for sequential Monte Carlo methods can already be found in the literature. However, there is not much work done on Gaussian mixtures. Gaussian mixtures based formulations are presented in this work. These two different implementations are compared for different sensor types, reward/penalty functions. In order to give an idea on a possible implementation on a real application, run times of the algorithms are also presented.

Keywords: Sensor control, Random finite sets, Gaussian mixtures

1 Giriş

Otonom araçlar ve mobil sensörler, güvenlik, trafik, enerji tüketiminde verimlilik, çevre kirliliğinin önlenmesi, düşük gelirli insanların ulaşım probleminin çözülmesi gibi çok farklı alanlarda faydalı olması beklenen teknolojilerdir [1]. Otonom araçlarda ya da mobil sensörlerin çevredeki cisimlerle etkileşimlerinin değerlendirilmesi önemlidir. Otonom araçlarda dinamik veya statik engellerden kaçınma önemli olabilirken, mobil sensörlerle hem engellerden kaçınma hem de hedeflerin bulunup, takip edilmesi amaçlanabilir. Bu nedenlerle, engellerin, canlıların ve diğer dinamik varlıkların tespit ve takibi konusunda birçok çalışma yapılmıştır. Sensör kontrolü, otonom araçlar ve mobil sensör ağlarında platformların bir sonraki hamlesinin ne olacağına karar verilmesi için kullanılır. Sensör kontrolüyle mobil sensörlerin hedeflerini takip etmeleri için yapacakları en iyi manevranın, diğer bir deyişle hareket için verilecek en iyi komutun belirlenmesi hedeflenir. En iyi komut hedef parametreleri üzerinden tanımlanan bir maliyet veya ödül fonksiyonu ile hesaplanır. Tanımlanan maliyet fonksiyonların en küçük veya ödül fonksiyonlarının en büyük olmasını sağlayan komut belirlenir. Komutlar sürekli bir fonksiyon üzerinde tanımlanabileceği gibi ayrık bir komutlar kümesi, \mathcal{A} ,

içerisinden de seçilebilir. Maliyet veya ödül fonksiyonları belirlenirken parametre kestirimi için kullanılan filtrenin özelliklerinin de göz önünde bulundurulması gereklidir. Bayeşçi filtrelerde maliyet fonksiyonu genellikle güncellenmiş (*posterior*) hedef parametrelerinin kestirilen hedef parametreleri üzerinden tahmini yapılarak gerçekleştirilir.

Sensör kontrolünün konusu olan araçlar pratikte çok karmaşık ortamlarda bulduklarından çok sayıda cisim tespit edip, bunların kinematik vektörlerinin kestirimi yapabilecek yetkinlikte olmaları gerekmektedir. Sensör kontrolü algoritmaları çevredeki hedeflerin tespit ve takibinde kullanılan filtrelerden bağımsız tasarlanmaz. Çoklu hedef takibi sinyal işlemenin bir dalı olup askeri ve sivil, birçok farklı mühendislik disiplininde uygulamaları vardır. Rastgele Sonlu Kümeler (*Random Finite Sets*, RFS) tabanlı filtreler de bu alandaki en son geliştirilmiş olan ve çoklu hedef dağılımını RFS olarak modelleyen filtrelerdir [2]. Diğer filtrelere göre en önemli avantajlarından birisi hedef sayısı ve parametreleri ile ilgili hiç bir varsayım gerektirmeden çalışmalarıdır. Filtreler hedef kardinalitesini kendileri güncellerler. Bu avantajları neticesinde de, filtreler hedef tespit ve takibi açısından son yıllarda farklı alanlarda başarıyla uygulanmıştır [3][4]. RFS yaklaşımında her ölçüm ve her hedef sonlu sayıda elemanı olan rastgele kümelerin elemanları olarak değerlendirilirler. Ölçüm

ve hedeflerin birbirleriyle olan ilişkilerinde belirsizlik olan ve kargaşanın (*clutter*) olduğu durumlarda ölçüm ve hedeflerin RFS olarak modellenmesi sayesinde ardışık tahmin yapılması mümkündür. Ve bu en uygun tahminin denklemleri kapalı formda yazılabilir [2]. Ancak iç içe integrallerin alınması ihtiyacı dolayısıyla bu tip bir yaklaşımın hesap yükü çok fazla olacaktır. Pratik problemlerde bu formülasyonun kullanılabilmesi için bir takım sadeleştirmeler kullanılarak sonucun yaklaşık olarak hesaplandığı filtreler ortaya konulmuştur [2],[5]. Bu filtrelerden birisi de Kardinalitesi Dengelenmiş Çoklu Bernoulli (*Cardinality Balanced Multi-Bernoulli*, CB-MeMber) filtresidir [6]. MeMber filtresinin kardinalite tahminindeki hatasının giderilmesiyle oluşturulmuş olup birçok farklı probleme uygulanmıştır [2]-[4]. CB-MeMber filtresi, hedefin olup olmama olasılığının ve uzamsal dağılımının kestirimini yapar. Olasılık Hipotezi Yoğunluğu (*Probability Hypothesis Density*, PHD) filtresi de çok sayıda hedefin dağılımlarının birinci momenti ile çoklu hedef takibi yapılmasına dayanır [2]. PHD filtresinin CB-MeMber filtresine göre performansının daha düşük olduğu noktalardan birisi hedeflerin parametrelerinin kestiriminde her bir hedefin uzamsal olasılık yoğunluk fonksiyonunun birbirine karışmış halde olmasıdır. Bu durumdan dolayı PHD filtresinde her bir hedefin öncelikle öbikleme (*clustering*) işlemiyle ayrıştırılması gerekir. CB-MeMber filtresinde ise her bir olası hedef için bir Bernoulli RFS kullanılır ve dolayısıyla hedeflerin uzamsal konumları birbirine karışmaz.

RFS tabanlı filtreler, çoklu hedef tespit ve takip problemlerini tek bir formülasyonda birleştirdiğinden dolayı, sensör kontrolü uygulamalarında çevredeki engellerin tespiti, kinematik vektörlerinin kestirimi ve kaçınma gibi problemler için kullanılmaktadırlar [7]. Sensör kontrolündeki ödül/ceza fonksiyonları bilgi kazancının artırılması veya belirsizliğin azaltılmasını amaçlar. Bu fonksiyonlar, RFS tabanlı filtrelerde Renyi iraksaması ile, tahmini (*predicted*) ve güncellenmiş olasılık yoğunluklarının karşılaştırılmasıyla hesaplanmıştır [8],[9]. Riski azaltmaya dayalı başka bir ceza fonksiyonu da SMC-PHD filtresi için oluşturulmuştur [10]. Kısmi Gözlemlenebilir Markov Karar Süreçleri (*Partially Observable Markov Decision Processes*, POMDP) de RFS tabanlı filtrelerde çok tercih edilen bir yaklaşımdır [6]. Hedeflerin parametre kestirimindeki belirsizliğin azatılmasıyla çalışan bir başka çalışmada da mesafe ölçen sensörler kullanılmıştır [11].

Tüm RFS tabanlı filtrelerin gerçekleşmesinde iki çeşit yöntemden birisi kullanılır. Bunlardan birincisi parçacık filtresi veya ardışık Monte Carlo (*Sequential Monte Carlo*, SMC) yöntemidir [12]. SMC lineer olmayan sistemlerde ve/veya Gaus olmayan gürültü modellerinde yaygın olarak kullanılır [12], [13]. İkincisi uygulama yöntemi ise Kalman filtresine dayanan, Gaus karışımı (*Gaussian Mixtures*, GM) yöntemidir. GM'de birden fazla Gaus dağılımı ile daha karmaşık PDF'ler yaklaşık olarak hesaplanır. SMC her ne kadar doğrusal olmayan sistemlere daha uygun olsa da, GM çok daha az sayıda bileşen kullandığından hafıza ve hız yönünden daha üstündür. İki gerçekleştirme yöntemi birbirinden oldukça farklı problemler için uygun olsalar da yazarın bildiği kadarıyla, literatürde SMC tabanlı gerçeklemler bulunmakla birlikte RFS tabanlı filtrelerin iki gerçekleştirme türünün sensör kontrolü problemi açısından karşılaştırıldığı bir çalışma bulunmamaktadır. Ayrıca, SMC için belirtilen ödül veya ceza fonksiyonlarının implemetasyonu doğrudan GM için kullanılamaz. Bu çalışmada, sensör kontrolü için GM CB-MeMber filtresinin kullanılması

in için ödül fonksiyonları tanımlanmış ve simülasyonlarla başarımları gösterilmiştir. Sensör kontrolü problemi bir ve iki hedefli senaryolar için ele alınmış ve SMC ile GM gerçeklemleri ile sadece mesafe ve sadece kerteriz ölçen mobil sensörler için karşılaştırılmıştır. Yeni sunulan GM MeMber çözümü ile literatürdeki SMC MeMber tabanlı çözüm de sadece mesafe ölçen sensörlerin yanında sadece kerteriz ölçen sensör senaryoları için de karşılaştırılmıştır.

Makalenin devamında, ikinci kısımda CB-MeMber filtresi genel olarak açıklanacaktır. Üçüncü kısımda sensör kontrolü problemi ele alınacak ve seçilen ödül fonksiyonları açıklanacaktır. Dördüncü kısımda simülasyon sonuçları sunulup, sonuçlar değerlendirilecek ve son kısımda da sonuçlar özetlenip gelecekte yapılacak işler anlatılacaktır.

2 CB-MeMber filtresi

RFS tabanlı filtreler hem hedefleri, hem de gözlemleri rastgele sonlu kümeler olarak değerlendirirler. Bu yaklaşıma göre, herhangi bir k anında n_k adet hedef ve m_k adet gözlemin kümeleri sırasıyla

$$\mathbf{X}_k = \{x_{k,1}, x_{k,2}, \dots, x_{k,n_k}\} \in \mathcal{F}(\mathcal{X}) \quad (1)$$

$$\mathbf{Z}_k = \{z_{k,1}, z_{k,2}, \dots, z_{k,m_k}\} \in \mathcal{F}(\mathcal{Z}) \quad (2)$$

şeklinde gösterilir. $\mathcal{F}(\mathcal{X})$ ve $\mathcal{F}(\mathcal{Z})$ de \mathcal{X} ve \mathcal{Z} 'nin sonlu sayıda elemanı olan alt kümeleridir. n_k ve m_k birbirine eşit olmak zorunda değildir. Zira sensörler kimi hedefleri tespit edemeyebilirler ve kargaşadan ötürü hatalı gözlemler de yapabilirler. RFS yaklaşımı kullanılarak sensör kontrolü için ihtiyaç duyulan belirsizlik ölçümü veya bilgi kazancı fonksiyonları yazılabilir.

RFS tabanlı filtreler temelde özyinelemeli (*recursive*) Bayesçi filtre denklemleriyle çalışırlar. Kestirilen ve elde edilen gözlemlere göre güncellenen çoklu hedef olasılık dağılımları sırasıyla

$$\begin{aligned} \pi_{k|k-1}(\mathbf{X}_k | \mathbf{Z}_{1:k-1}) \\ = \int f_{k|k-1}(\mathbf{X}_k | \mathbf{X}_{k-1}) \pi_{k-1|k-1}(\mathbf{X}_{k-1} | \mathbf{Z}_{1:k-1}) \end{aligned} \quad (3)$$

$$\pi_{k|k}(\mathbf{X}_k | \mathbf{Z}_{1:k-1}) = \frac{g_k(\mathbf{Z}_k | \mathbf{X}_k) \pi_{k|k-1}(\mathbf{X}_k | \mathbf{Z}_{1:k-1})}{\int g_k(\mathbf{Z}_k | \mathbf{X}) \pi_{k|k-1}(\mathbf{X} | \mathbf{Z}_{1:k-1}) \delta \mathbf{X}} \quad (4)$$

denklemleri ile elde edilir. Bu denklemlerdeki $f_{k|k-1}$ çoklu hedef geçiş yoğunluğu, g_k de çoklu hedef olabirliğidir (*likelihood*). (3) ve (4) denklemlerindeki integraller de küme integralleridir [2]. Bu integrallerin kapalı formları çok karmaşık ve hesap yükü çok fazladır. Bundan dolayı denklemlerin yaklaşık olarak hesaplanması için alternatif gerçekleştirme yöntemleri geliştirilmiştir. Bunlar GM ve SMC yöntemleridir.

CB-MeMber filtresi Sonlu Kümeler İstatistikleri (*Finite Set Statistics*, FISST) kullanılarak çok sayıda hedefin tespit ve takibi için geliştirilmiş RFS tabanlı bir filtredir [10],[14]. Diğer RFS tabanlı filtrelerde olduğu gibi CB-MeMber filtresi de hedef sayısını konusunda bir bilgiye ihtiyaç duymaz ve hedef sayısı kestirimini otomatik olarak, özyinelemeler ile yapar. MeMber RFS, birbirinden bağımsız birden fazla Bernoulli RFS'inin birleşiminden oluşur. Her bir Bernoulli RFS de

$$\pi(\mathbf{X}) = \begin{cases} 1 - r, & \mathbf{X} = \emptyset \\ r \cdot p(\mathbf{x}), & \mathbf{X} = \{\mathbf{x}\} \end{cases} \quad (5)$$

şeklinde yazılır [15]. Buradaki r söz konusu kümede bir elemanın olma olasılığı, $p(\mathbf{x})$ de hedefin uzamsal dağılım yoğunluk fonksiyonudur.

MeMber RFS'i oluşturan her bir Bernoulli RFS'i de yine i . Bernoulli RFS'inde bir hedefin var olma olasılığı, $r^{(i)} \in [0,1], i = 1, \dots, n_k$ ve uzamsal dağılım olasılık yoğunluk fonksiyonu, $p^{(i)}(\mathbf{x})$ ikilisiyle, $\{(r^{(i)}, p^{(i)})\}_{i=1}^{n_k}$ şeklinde gösterilebilir. Bir hedefin var olup olmadığı ya da tespit edilip edilmediği $r^{(i)}$, hedefin parametreleri ise $p^{(i)}$ sayesinde belirlenir. Bir hedeften tespit alınması durumunda $r^{(i)}$ değeri her adımda yükselir. MeMber RFS olasılık yoğunluk fonksiyonu da

$$\pi(\{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_{n_k}\}) = \pi(\emptyset) \sum_{i=1}^{n_k} \prod_{j=1}^{n_k} \frac{r^{(i)} p^{(i)}(\mathbf{x}_j)}{1 - r^{(i)}} \quad (6)$$

şeklinde gösterilir [16]. n_k değerinin tüm çoklu hedef dağılımını modelleyecek sayıda seçilmesi gerekir. Ancak filtrenin tespit ve takip edilecek hedef sayısı ile ilgili bir parametreye ihtiyacı yoktur. Boş kümenin RFS olasılık yoğunluğu fonksiyonu olan $\pi(\emptyset)$ de

$$\pi(\emptyset) = \prod_{j=1}^{n_k} (1 - r^{(j)}) \quad (7)$$

şeklinde hesaplanır.

MeMber filtresinin SMC ile gerçekleştirilmesinde k anında kestirilen çoklu hedef dağılımının parçacıklarla yaklaşık olarak gösterimi

$$\pi_{k|k-1}(\mathbf{X}_k | \mathbf{Z}_{1:k-1}) \approx \sum_{j=1}^M \sum_{i=1}^N \omega_k^{(i,j)} \delta_{\mathbf{x}_k^{(i,j)}}(\mathbf{X}_k) \quad (8)$$

şeklinde M filtre tarafından kestirilen hedef sayısı, N kullanılan parçacık sayısıdır. Buradaki $\delta_{\mathbf{x}_k^{(i,j)}}(\mathbf{X}_k)$ çoklu hedef Dirac delta fonksiyonudur.

Benzer şekilde GM gerçekleştirilmesinde de $\pi_{k|k-1}(\mathbf{X}_k | \mathbf{Z}_{1:k-1})$ yaklaşık olarak

$$\pi_{k|k-1}(\mathbf{X}_k | \mathbf{Z}_{1:k-1}) \approx \sum_{j=1}^M \sum_{l=1}^R \omega_k^l \mathcal{N}(\mathbf{x}; \mathbf{m}_k^l, \mathbf{P}_k^l) \quad (9)$$

şeklinde gösterilir. R her bir hedefin uzamsal dağılımını hesaplanması için kullanılan Gauss dağılımı adedir ve genellikle $R \ll N$ 'dir. GM gerçekleştirilmesinde çok daha az sayıda bileşen olduğundan, GM gerçekleştirilmesinin hesaplanması genellikle SMC gerçekleştirilmesinden hızlıdır. CB-MeMber filtresinin GM ve SMC yaklaşımlarıyla gerçekleştirmeleri ayrıntılı bir şekilde [14]'te bulunabilir.

GM gerçekleştirilmesi Kalman filtresinin adımlarıyla ilerler ve doğrusal olan sistemler için daha uygundur. Ancak Genişletilmiş Kalman Süzgeci (*Extended Kalman Filter*) formülasyonu kullanılarak doğrusal olmayan sistemlerde de kullanılabilir. Bu çalışmada da sensör ölçümleri doğrusal olmayan denklemlerle belirtildiğinden bu yaklaşım kullanılmıştır. SMC ise doğrusal olmayan sistemlerde de başarıyla kullanılabilir. Diğer taraftan PDF'in modellenmesi için çok fazla sayıda parçacık gerekebilir. Bu da hafıza ve hız açısından SMC'nin performansını düşürür.


3 Sensör kontrolü

Sensör kontrolünün amacı mobil bir aracın en doğru komutu seçmesi ve bunun sonucunda bir sonraki adımda daha avantajlı bir durumda olmasıdır. Daha avantajlı olma durumu matematiksel olarak belirlenmeli ve ölçülmelidir. Ödül ve ceza fonksiyonları bu amaçla belirlenir. Bu fonksiyonlar genel olarak bilginin artırılmasına veya belirsizliğin azaltılmasına göre belirlenirler [8],[11]. Bundan önceki çalışmada belirsizliğin azaltılmasını ölçen ödül fonksiyonlarına göre CB-MeMber filtresi ile sensör kontrolünün SMC ve GM uygulamalarının performansları değerlendirilmiştir [17]. Araç hareket maliyetlerinin nasıl belirleneceği ortaya konduktan sonra bu fonksiyona göre bir optimizasyon yapılması gerekir. POMDP bunun için bir altyapı sağlar [18]. Teorik olarak POMDP'de seçilebilecek hamlelerin sayısının sonsuz olmasına rağmen, pratik problemlerde gerçek zamanlı çalışabilmek için sensörlerin belirli yönlerde hareket edebileceği varsayılır. Bu sonlu sayıdaki hareket seçenekleri kümesine *kabul edilebilir kontrol komutları* adı verilir. Hangi komutun seçileceği bilginin artırılmasına dayalı bir fonksiyonda


$$a_k^* = \arg \max_{a \in \mathcal{A}} \{E[\mathcal{V}(a; \mathbf{X}_k)]\} \quad (10)$$

şeklinde yazılabilir. Burada a_k^* seçilen hareket (*action*), \mathcal{A} tüm hareket olasılıklarının içinde olduğu kabul edilebilir kontrol komutlarının kümesi, \mathcal{V} hareket ve çoklu hedef parametresine bağlı bir fonksiyon, a değerlendirilecek her bir hareket, \mathbf{X}_k çoklu hedef durum vektörü kümesidir. \mathcal{V} fonksiyonu genellikle a 'ya ve \mathbf{X}_k 'e göre hesaplanan bir olası gözlem kümesi, \mathbf{Z}_{k+1} 'in hesaplanmasını da içerir. \mathbf{Z}_{k+1} , a hamlesinin yapılması durumunda ortaya çıkması beklenen çoklu hedef gözlemlerinin kümesidir. Bu optimizasyonda belirsizliğin azaltılması gibi bir yol izlenmesi durumunda max, yani fonksiyonun değerini büyütme yerine en küçük değeri bulmak amacıyla min kullanılmalıdır [11],[17].

Sensör kontrolü problemindeki temel mekanizma Şekil 1 ve Şekil 2'de gösterilmiştir. Buradaki örnekte belirsizliğin azaltılması esas alınmıştır. Siyah elipsler hedeflerin konumlarındaki belirsizliği göstermektedir. Sensörün hareket etmemesi durumunda bu belirsizlik sürekli olarak elips şeklinde kalacaktır. Ancak hedeflerin sensör kontrol algoritmasından çıktı olarak u_1 komutunu alması durumunda ise farklı bir noktadan gelen yeni ölçüm de Şekil 2'de gösterilmiştir. GM CB-MeMber filtresinin çıktısı güncelleme sonucunda kırmızı ve siyah Gauss kesişimindeki bölgeye yakın bir belirsizlik üretir. Sensör hareket etmeye devam ettikçe hedeflerin kestirimlerindeki beklenen hata daha da azalacaktır.



Şekil 1: Kerteriz ölçümü yapan bir sensörün hedefleri tespiti ve olası sensör komutları. Sensör s , hedefler h_1, h_2 ile gösterilmiştir. Hedeften alınan gözlem sonucunda Gauss dağılımları siyah çizgilerle çizilmiştir. Sensörün olası hareketleri $u_i, i = 0,1,2,3$ ile gösterilmiştir.



Şekil 2: Sensör kontrol komutu gerçekleştirildikten sonra yeni ölçüm alınması. Yeni gözlem ve dolayısıyla Gaus dağılımlarının beklenen yeni şekli kırmızı çizgilerle gösterilmiştir.

CB-MeMber filtresinde her bir hedef bir Bernoulli RFS ile gösterilir. Bernoulli RFS ise hedefin var olma olasılığı ve uzamsal olasılık dağılımından oluşur. Bundan dolayı \mathcal{V} fonksiyonu bu iki bileşeni de ele alacak şekilde oluşturulur. Belirsizliği azaltan (BA) ödül fonksiyonu

$$\mathcal{V}_{BA}(a; \mathbf{X}_k) = \eta \varepsilon_{|\mathbf{X}_k|}^2(a) + (1 - \eta) \varepsilon_{\mathbf{X}_k}^2(a) \quad (11)$$

şeklinde yazılabilir [11]. Burada $|\mathbf{X}_k|$, k anındaki çoklu hedef dağılımının kardinalitesidir. $\varepsilon_{|\mathbf{X}_k|}^2$ kestirilen hedef dağılımının kardinalitesinin normalize edilmiş hatası, $\varepsilon_{\mathbf{X}_k}^2$ de çoklu hedef dağılımının durum vektörlerinin kestiriminin hatasıdır.

(11)'deki fonksiyonun bileşenlerinin hesaplaması

$$\varepsilon_{|\mathbf{X}_k|}^2(a) = \sum_{i=1}^{n_k} [r_{k,u_k}^{(i)} (1 - r_{k,u_k}^{(i)})] \quad (12)$$

$$\varepsilon_{\mathbf{X}_k}^2(a) = \sum_{i=1}^{n_k} [r_{k,u_k}^{(i)} \zeta_{\mathbf{X}^{(i)}}^2(a_k)] / \sum_{i=1}^{n_k} r_{k,u_k}^{(i)} \quad (13)$$

ile yapılabilir. Buradaki $\zeta_{\mathbf{X}^{(i)}}^2$ Bernoulli bileşenlerinin uzamsal dağılımını ifade eder. Yani hedeflerin kinematik vektörlerinin kestiriminin belirsizliğini ifade eder.

(12) denklemini kullanarak Bernoulli dağılımlarının var olma olasılığının doğrudan konulması durumunda hesaplanabilirken, (13)'ün hesaplanması SMC veya GM gerçekleştirilmesi göre değişebilmektedir. SMC'deki hesaplamalardaki x koordinat eksenini doğrultusundaki belirsizlik her bir hedef için

$$\varepsilon_{x^{(i)}}^2(a) = \sum_{i=1}^{L_{k,u_k}^{(i)}} \left(\omega_{k,u_k}^i \mathbf{x}_{k,u_k}^i - \left(\sum_{j=1}^{N_{k,u_k}^{(i)}} \omega_{k,u_k}^j \mathbf{x}_{k,u_k}^j \right) \right) \quad (14)$$

şeklinde hesaplanır [11]. y koordinat eksenini doğrultusundaki belirsizlikler de benzer şekilde hesaplanır. $N_{k,u_k}^{(i)}$ bir Bernoulli RFS'inin yaklaşık gösteriminde kullanılan parçacık sayısıdır. (13)'ün GM ile hesaplanmasında dağılımların kestirim belirsizliği ölçüsü olarak hata kovaryans matrisi değerlendirilmiştir [17]. Hata kovaryans matrisinin dağılımı ne kadar yoğunlaşmışsa dağılımdaki belirsizlik o kadar azdır. Bunun matematiksel olarak tanımlanmasında ise matrislerin özdeğerleri ile kullanılmıştır [17].

$$\varepsilon_{\mathbf{X}_k}^2(a) = \sum_{i=1}^{R_{k,u_k}^{(i)}} (\omega_{k,u_k}^i |\lambda_{k,u_k}^i|) \quad (15)$$

Buradaki $M_{k,u_k}^{(i)}$ bir Bernoulli RFS'inin modellenmesinde kullanılan Gaus dağılımı adedi ve λ kovaryans matrisinin özdeğerleridir. Özdeğerlerin küçülme ölçüsü olarak çarpma yerine toplama kullanılmasının nedeni ise bir doğrultuda belirsiz olmasına rağmen bir doğrultuda çok sıkışan dağılımların istenilen dağılım yoğunlaşmasını sağlamamasıdır.

Bilginin artıp artmadığı istatistiksel olarak bilgi ölçümü için kullanılan normlarla hesaplanabilir. Bu normlar arasında Kullback-Leibler, Renyi ıraksaması bulunur [19]. Bilgi kazancının (BK) tanımlandığı ödül fonksiyonu Renyi ıraksaması kullanılarak

$$\mathcal{V}_{BK}(a; \mathbf{X}_k) = \frac{1}{\alpha - 1} \log \left\{ \frac{1}{[p_{k|k-1}(\mathbf{Z}_k | \mathbf{Z}_{1:k-1}, a)]^\alpha} \times \int [g_k(\mathbf{Z}_k | \mathbf{X}_k, u)]^\alpha \pi_{k|k-1}(\mathbf{X}_k | \mathbf{Z}_{1:k-1}) \delta \mathbf{X}_k \right\} \quad (16)$$

şeklinde tanımlanabilir [8]. $p_{k|k-1}(\mathbf{Z}_k | \mathbf{Z}_{1:k-1}, a)$ da

$$p_{k|k-1}(\mathbf{Z}_k | \mathbf{Z}_{1:k-1}, a) = \int g_k(\mathbf{Z}_k | \mathbf{X}_k, u) \pi_{k|k-1}(\mathbf{X}_k | \mathbf{Z}_{1:k-1}) \delta \mathbf{X}_k \quad (17)$$

şeklinde tanımlanabilir. (17)'nin SMC gerçekleştirilmesi de her bir hedef için

$$\mathcal{D}(a) \approx \frac{1}{\alpha - 1} \log \frac{\sum_{i=1}^{N_{k,u_k}^{(j)}} \omega_{k|k-1}^i [g_k(\mathbf{Z}_k | \mathbf{X}_{k|k-1}^i, u)]^\alpha}{\left[\sum_{i=1}^{N_{k,u_k}^{(j)}} \omega_{k|k-1}^i g_k(\mathbf{Z}_k | \mathbf{X}_{k|k-1}^i, u) \right]^\alpha} \quad (18)$$

ile yapılabilir. Bu işlemin GM gerçekleştirilmesi de benzer şekilde aşağıdaki gibi yapılır.

$$\mathcal{D}(a) \approx \frac{1}{\alpha - 1} \log \frac{\sum_{i=1}^{R_{k,u_k}^{(j)}} \omega_{k|k-1}^i [g_k(\mathbf{Z}_k | \mathbf{X}_{k|k-1}^i, u)]^\alpha}{\left[\sum_{i=1}^{R_{k,u_k}^{(j)}} \omega_{k|k-1}^i g_k(\mathbf{Z}_k | \mathbf{X}_{k|k-1}^i, u) \right]^\alpha} \quad (19)$$

4 Simülasyonlar

2000 × 2000 m²'lik bir alanda simülasyon yapılmaktadır. Hedefler sabit hızla hareket etmektedir. Her bir Monte Carlo koşulunda simülasyon sahasının ortasındaki 1000 × 1000 m²'lik alanda rastgele bir konumda hedefler oluşturulmaktadır. Hedeflerin hızı da düzgün rastgele dağılımla $v = \mathcal{U}(0,10)$ m/s olarak seçilmektedir. Her bir senaryo cinsi için 50 Monte Carlo koşumu yapılmıştır. Hedeflerin tespit olasılığı $p_D = 0.98$, tespit edilen hedeflerin hayatta kalma olasılığı da $p_S = 0.99$ 'dur.


SMC gerçekleştirilmesinde, doğan hedeflerin dağılımını modellemek için tüm simülasyon sahasında 2000 parçacık oluşturulur. Ayrıca her bir Bernoulli RFS'de $M = 2000$ parçacıkla yaklaşık olarak hesaplanmaktadır. GM gerçekleştirilmesinde de her bir GM için $R = 10$ Gaus dağılımı kullanılmaktadır. Başlangıç için

$10^6 \mathbf{I}_{4 \times 4}$ şeklinde bir kovaryans matrisi tanımlanmıştır. $\mathbf{I}_{4 \times 4}$ dört boyutlu birim matristir.

Bu çalışmada, sensör kontrolü yapılırken POMDP ile 8 ana yön değerlendirilmiştir. Her bir senaryoda dört sensör kullanılmıştır. Bunlar SMC ve GM gerçeklemeleri kullanılarak (16) ve (11) denklemlerindeki ödül fonksiyonlarına göre hamlelerini belirleyen sensörlerdir. Sensörlerin adları da bu parametrelere göre kısaltma şeklinde belirtilmiştir; bilgi kazancını ölçen ödül fonksiyonu için IG (*Information Gain*), belirsizliği azaltan ödül fonksiyonu için UR (*Uncertainty Reduction*) kullanılmıştır.

Sonuçların değerlendirilmesinde, kestirilen kardinalite hatası ve en iyi örüntü altı eşleştirilmesi (*Optimal Subpattern Assignment*, OSPA) metriği olarak kullanılmıştır. OSPA çoklu hedef takibinde de yaygın olarak kullanılan bir metriktir [20]. Metriğin normu, $p = 2$, kesme (*cutoff*) değeri ise $c = 100$ olarak belirlenmiştir.

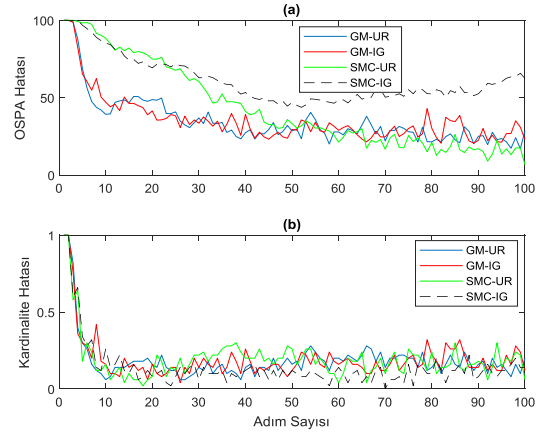
Tüm senaryoda, sadece mesafe ölçen dört mobil sensör, birbirinden bağımsız olarak, tek başlarına tek bir hedefi takip etmektedirler. İlk senaryonun simülasyon sonuçları Şekil 3'te gösterilmektedir. Şekil 3(a)'da görüldüğü üzere GM tabanlı sensörlerin OSPA hatası SMC'lere göre daha yüksektir. Bunun nedeni, kardinalite hatasının yüksek olmasıdır. Hedeflerin tespit edilmesindeki hata göz önünde bulundurulmadığında GM gerçeklemelerinin hedef parametrelerinin kestirimini daha doğru yaptığı değerlendirilmektedir. Ancak GM gerçeklemesinde doğan hedefler için oluşturulan dağılımların sahanın ortasına odaklanmasından da kaynaklanan hedefi kaybetme durumu olduğu görülmektedir. Bu durumun doğan dağılımların gelen tespitlere göre uyarlamalı olarak oluşturulmasıyla giderilmesi ihtimali de bulunmaktadır.




Şekil 3: Sadece mesafe ölçen mobil sensörlerle bir hedefli simülasyon sonuçları. (a): OSPA, (b): Kardinalite hataları.

İkinci senaryo yine tek hedefli olmakla birlikte sensörler kerteriz ölçen tiptedir. Bu tür sensörlerde hedeflerin tespitinin doğru yapıldığı yine Şekil 4(b)'de görülmektedir. Bu sonuçlara göre SMC ve GM gerçeklemeleri arasında performans farkı olmadığı gibi iki gerçeklemenin OSPA hataları da birbirine çok yakındır.

Diğer senaryolarda hedeflerin sayısı ikiye çıkarılmıştır. Şekil 5'te sadece mesafe ölçen sensörlerin hataları gösterilmektedir. Burada GM gerçeklemeleri SMC'lere göre OSPA metriğine göre belirgin bir şekilde daha kötü performans göstermiştir. Ancak hedef sayısı kestiriminde durum birinci senaryodakine benzemektedir.




Şekil 4: Sadece kerteriz ölçen mobil sensörlerle bir hedefli simülasyon sonuçları. (a): OSPA, (b): Kardinalite hataları.



Şekil 5: Sadece mesafe ölçen mobil sensörlerle iki hedefli simülasyon sonuçları. (a): OSPA, (b): Kardinalite hataları.

Son olarak da iki hedefli bir senaryo sadece kerteriz ölçen sensörlerin kullanıldığı bir senaryoda simülasyon yapılmıştır ve sonuçları Şekil 6'da sunulmuştur. Burada da sensörlerin performansları birbirine yakın çıkmıştır. Ancak SMC-IG sensörü OSPA performansındaki düşüklükle diğer sensörlerden ayrılmıştır.



Şekil 6: Sadece kerteriz ölçen mobil sensörlerle iki hedefli simülasyon sonuçları. (a): OSPA, (b): Kardinalite hataları.

GM ve SMC gerçeklemlerinin süre cinsinden ortalama koşum süresi de Tablo 1'de verilmiştir. Koşumlar Intel i7-4510U işlemcili, 16 GB belleği olan bir sistemde MATLAB ortamında yapılan simülasyonların ortalamaşı alınarak ölçülmüştür. Beklendiği üzere GM gerçeklemleri SMC'den daha hızlıdır. İki ödül/kazanç fonksiyonu arasında ise önemli bir fark olmadığı görülmektedir.

Tablo 1: GM ve SMC gerçeklemlerinin her bir iterasyonunun saniye birimiyle süreleri. IG bilgi kazancı, UR ise belirsizlikteki azaltmayı hedefleyen fonksiyonların performansını göstermektedir.

GM \ SMC	Mesafe Sensörleri	Kerteriz Sensörleri
IG	0.3657	0.1105
UR	0.0426	0.0685
UR	0.1819	0.1010
UR	0.0435	0.0739

5 Sonuç

Bu çalışmada CB-MeMber filtresinin, bilgi kazancı ve belirsizlik azaltımını hedefleyen iki farklı ödül fonksiyonuyla sensör kontrolü performansı, GM ve SMC gerçeklemleri için değerlendirilmiştir. Simülasyonlarda literatürde en çok karşılaşılan sensör tipleri olan sadece mesafe ve sadece kerteriz ölçebilen sensörler esas alınmıştır. Yapılan simülasyonlar kardinalite ve OSPA metrikleri açısından değerlendirildiğinde, arada çok büyük bir fark olmamakla birlikte SMC gerçeklemlerinin genel olarak biraz daha başarılı olduğu görülmüştür. Kerteriz ve mesafe ölçen sensörler karşılaştırıldığında da kerteriz ölçen mobil sensörler metrikler açısından daha üstün performans göstermiştir. Bununla beraber GM gerçeklemlerinin de hız açısından SMC'den daha üstün olduğu görülmüştür.

Bu çalışmada simülasyon ortamında test edilen algoritmaların tasarlanan otonom araçlarda da kullanılması planlanmaktadır. Ayrıca sensör kontrolü algoritmaların geliştirilerek karşılaşılan engellerle ilgili sınırlamaların getirilmesi gerekmektedir. Daha sonraki adımda da mobil sensörlerin sürü halinde çalıştırılması yönünde faaliyetlere devam edilmesi planlanmaktadır.

6 Kaynaklar

- [1] Litman T. "Autonomous vehicle implementation predictions: Implications for transport planning," Victoria Transport Policy Institute, Canada, Technical Report, 2017.
- [2] Mahler RPS. *Statistical Multisource-Multitarget Information Fusion*. Boston, USA, Artech House, 2007.
- [3] Gunes A, Guldogan MB. "Joint underwater target detection and tracking with the Bernoulli filter using an acoustic vector sensor". *Digital Signal Processing*, 48, 246-258, 2016.
- [4] Guldogan MB. "Consensus Bernoulli filter for distributed detection and tracking using multi-static Doppler shifts". *IEEE Signal Processing Letters*, 21, 672-676, 2014.

- [5] Ristic BT. *Particle Filters for Random Set Models*. Springer, 2013.
- [6] Gostar AK, Hoseinnezhad R, Bab-Hadiashar A. "Multi-Bernoulli sensor control for multi-target tracking". *IEEE 8th International Conference on Intelligent Sensors, Sensor Networks and Information Processing*, Melbourne, Australia, 2-5 April 2013.
- [7] Zhang D, Xie Z, Li P, Yu J, Chen X, "Real-time navigation in dynamic human environments using optimal reciprocal collision avoidance," *IEEE International Conference on Mechatronics and Automation*, Beijing, China, 2-5 August 2015.
- [8] Ristic B, Vo BN. "Sensor control for multi-object state-space estimation using random finite sets". *Automatica*, 46(11), 1812-1818, 2010.
- [9] Ristic B, Vo B-N, Clark D. "A note on the reward function for PHD filters with sensor control". *IEEE Transactions on Aerospace and Electronic Systems*, 47(2), 1521-1529, 2011.
- [10] Gomes-Borges ME, Maltese D, Vangeeghe P, Duflos E. "A risk-based sensor management using random finite sets and POMDP". *IEEE International Conference on Information Fusion*, Xi'an, China, 10-13 June 2017.
- [11] Gostar AK, Hoseinnezhad R, Bab-Hadiashar A. "Multi-Bernoulli sensor control via minimization of expected estimation errors". *IEEE Transactions on Aerospace and Electronic Systems*, 51(3), 1762-1773, 2015.
- [12] Arupampalam M, Maskell S, Gordon N, Clapp T. "A tutorial on particle filters for online nonlinear/non-Gaussian Bayesian tracking". *IEEE Transactions on Signal Processing*, 50, 174-188, 2002.
- [13] Candy CV. *Bayesian Signal Processing: Classical, Modern, and Particle Filtering Methods*. Wiley, 2016.
- [14] Ristic BT, Vo BN, Cantoni. "The cardinality balanced multi-target multi-Bernoulli filter and its implementations". *IEEE Transactions on Signal Processing*, 57(2), 409-423, 2008.
- [15] Ristic B, Vo BT, Vo BN. "A tutorial on Bernoulli filters: Theory, implementation and applications". *IEEE Transactions on Signal Processing*, 61, 3406-3430, 2013.
- [16] Vo B-T, Vo B-N, Cantoni A. "On multi-Bernoulli approximations to the Bayes multi-target filter". *International Symposium on Information Fusion*, Xi'an, China, October 2007.
- [17] Gunes A. "CB-MeMber filtresi ile sensör kontrolünün GM ve SMC implementasyonlarının karşılaştırılması". *Türk Otomatik Kontrol (TOK) Toplantısı*, İstanbul, Türkiye, 2017.
- [18] Kaelbling LS, Littman ML, Cassandra AR. "Planning and acting in partially observable stochastic domains". *Artificial Intelligence*, 101(1), 99-134, 1998.
- [19] Hero AO, Kreucher, CM, Blatt D. *Foundations and Applications of Sensor Management*. Springer, 2007.
- [20] Schuhmacher D, Vo BT, Vo BN. "A Consistent Metric for Performance Evaluation of Multi-Object Filters". *IEEE Transactions on Signal Processing*, 3447 - 3457, 2008.