

## Parazit yankılı ortamda eşzamanlı konum belirleme ve harita oluşturma problemi için veri ilişkilendirme

---

**Haydar ANKİŞHAN<sup>\*1</sup>, Fikret ARI<sup>2</sup>**

<sup>1)</sup> *Başkent Üniversitesi, Teknik Bilimler Meslek Yüksekokulu, 06810, Ankara*

<sup>2)</sup> *Ankara Üniversitesi. Mühendislik Fakültesi. Elektronik mühendisliği. 06100. Ankara*

### Özet

*Veri ilişkilendirme problemi eşzamanlı konum belirleme ve harita oluşturma uygulamalarında öne çıkan bir problem olarak bilinmektedir. Literatürde veri ilişkilendirme probleminin çözümü için bir takım metotlar önerilmiştir. Bunlardan başarılı olanlar arasında olasılıksal veri ilişkilendirme yöntemleri bilinmektedir. Bu yöntemlerden birebir olasılıksal veri ilişkilendirme (Joint Probabilistic Data Association, JPDA) algoritması çoklu hedef izleme problemlerinin çözümünde beklenilen düzeyde başarı sağlayabilmektedir. Bu bilgiye ve bazı eşzamanlı konum belirleme ve harita oluşturma (Simultaneous Localization and Mapping, SLAM) uygulamalarına dayanarak bu çalışmada, statik parazit yankılı ortamlar için öznitelik tabanlı harita oluşturma ve konum belirleme probleminde veri ilişkilendirme probleminin çözümü için JPDA yöntemi uygulanmıştır. Daha önceki çalışmalarдан farklı olarak bu çalışmada, değişimiz çevre koşullarında SLAM probleminin çözümü için JPDA ile birlikte kestirici olarak kokusuz Kalman süzgeci (Unscented Kalman Filter, UKF) tercih edilmiştir. Çalışmanın sonuçları FastSLAM II tabanlı parçacık süzgeci, en yakın komşuluk ilişkili genişletilmiş (nearest neighbor (NN)-EKF) ve kokusuz (NN-UKF) Kalman süzgeçleri ile karşılaştırılmıştır. Deneysel çalışmalar JPDA tabanlı UKF' nin diğer yöntemlere nazaran aynı ortam koşullarında daha düşük ortalama kare hatasına sahip olduğunu ve kestirim belirsizliğini durumlarında daha başarılı olduğunu göstermiştir.*

**Anahtar Kelimeler:** Eşzamanlı konum belirleme ve harita oluşturma, kokusuz Kalman süzgeci, veri ilişkilendirme, birebir olasılıksal veri ilişkilendirme, olasılıksal veri ilişkilendirme

---

\*Yazışmaların yapılacak yazar: Haydar Ankıshan, hankishan@baskent.edu.tr. Tel: (312) 246 66 66/ 1224

## Data Association for Simultaneous Localization and Mapping in Clutter Environment

### Extended abstract

Robot or vehicle has been tried to build up a map and simultaneously localize its position within an unknown environment or to update its position and map which was called problem in the early of 1990. Smith et al. (1990) called his problem simultaneous localization and mapping (SLAM). They shows SLAM is general problem that while mapping the environments measurement noises statistically dependent on before their values and monotonically growing with map building, so robot/vehicle incorrectly localize their position and obtain environment mapping. There are several theoretical and applicable studies available in the literature.

There are some specific problems available with this method. For example, minimization of observation and measurement noises, increasing the number of object in the building environment and robot/vehicle remembering the occurrence of its position which is known as data association(correspondence) in the literature, etc...

Recent studies considering these problems and have tried to propose a solution with using different statistical methods based on Bayes theorem. While some of these studies trying to minimize the effects of observation noises on the mapping and position errors, some of them have developed algorithms to reduce the processing times cause of increasing the number of objects related environments causing problems in real-time applications (Montemerlo, M. et al 2001, Kim C. et al 2008). However, some studies have focused on the data association problem, which is known as remembering the occurrence of the robot/vehicle, in other words trying to solve the problem of uncertainty of the object location (Neira J. and Tardós J.D 2001, Rex H. Wong et al 2010). These studies can be listed as Kalman- based estimators, sequential monte carlo approaches, known as particle filters and their derivatives, and expectation maximization based estimators.

When observation noise statistically increases over time, measurement data can be obtained in complex and leads to formation of measurement uncertainty. SLAM method takes advantage of the hallmarks of an autonomous robot/vehicle location information while the surrounding the objects. If the landmarks

are obtained the correct information, position of autonomous robot/vehicle is used to obtain the correct measurement.

In some cases, the number of landmarks and to be close each other leads to the interference which landmark is arrival of the measurement landmarks. In this situations, declining the performance of estimators, leading to increase mean square error of mapping and positions of autonomous robot/vehicle, so SLAM problem causing the results in a number of uncertainties with improper obtaining building of the map and the vehicle's position and heading angle. In this case, there is a need for data association.

Successful data association is provided by observed measurement results from itself correctly association. In the SLAM problem, the estimator is able to forecast the new landmarks, recognize the false alarms (incorrect measurements) and follow the measurements correctly. The most basic algorithm for data association is nearest neighbor method. This method uses Mahalanobis distance during processing. Mahalanobis distance calculates the distance between measured and predicted observation. Algorithm accepts predicted target position closest to the measured position as valid measurement. According to observation measurement creating the acceptance region for next renewal of landmarks, acceptance region is referred to as gate. However, the measurement may not be associated with the nearest landmark, in NN filter not interested in this situation. Therefore, updated state vector may lead to divergence. It is also observed in dynamic environments, are not performing well (Rex H. Wong et al 2010).

If number of landmarks is very high and landmarks to be close to each other in noisy observations, NN algorithms do not give better results addressed in the previous studies. Because of this, predictive value of actual measurement from the nearest measurement is known as a reference to valid measurement in the gate. NN algorithm shortens the processing time and not used all the measurements to reach conclusions quickly, so the situation away from the optimal structure. Probabilistic data association (PDA) algorithm calculates the probability of being the target measurement all measurement in the gate. PDA calculates a combined value of innovation, as it tries to solve stochastic problem of uncertainty. Using the relational likelihood of hypothesis provides a unified innovation, and with it creates a unified valid gate.

During the operation, algorithm accepts the independent of target and not interfering neighboring landmarks. However, in SLAM problem landmarks are correlated with each other, make mutual interference cannot be ignored. Therefore, it is not suitable multiple object or target tracking and dynamic situations, or algorithm should be run for each target. This is a retreat for PDA and emphasizes joint PDA (JPDA) for multiple target tracking. JPDA has been developed for following all targets in a loop.

There are some studies available using JPDA for solving data association problem of SLAM in the literature. (Rex H. Wong et al 2010)' study used JPDA for solving of wireless sensor networks in SLAM problem and 3-scan JPDA algorithm was used. They said that on the basis of noisy sensor information and possible false repercussions that the signal has white noise and this leads to uncertainty in the position and angle of incoming signals. In other JPDA based approach proposed by Zhou et al. Their proposed method is measurement-oriented, using Depth-First-Search (DFS) algorithm for generation of hypothesis.

These studies have been generally used to solve the problem of data association in SLAM problem. However, performance of the algorithms use the filters is not covered. A number of comparisons were only made during the uncertainties. Proposed study taking into account previous studies have focused on

two new approaches on a more appropriate for SLAM problem. First, there is an alternative to be presented the problem of data association problem of SLAM in high noisy and uncertainty in feature-based environment. Developed algorithm for the problem of SLAM application is proposed for the first time used related environment and scenario. Another improvement is the used filter. Extended Kalman filter (EKF) is generally preferred in previous studies (Rex H. Wong et al 2010, Montemerlo, M. et al 2002). In this study, unscented Kalman filter (UKF) is considered to be more successful in minimizing observation noise problem in SLAM. UKF tries to estimate posteriori probability distribution of state by selecting a certain number of sigma points on probability distribution with a non-linear function. This method allows filter less time to make accuracy and processing speed than FastSLAM based particle filters. JPDA based UKF is for the first time used for SLAM problem in this study. The correct filter used with solution of the uncertainty of situation is thought to achieve the desired result is more favorable.

**Keywords:** Simultaneous Localization and Mapping, unscented Kalman Filter, data association, joint probabilistic data association.

## Giriş

Bilinmeyen bir ortamda robot veya özerk aracın tahmini çevre bilgisini kullanarak hem konumunu bulma, hem de bulunduğu çevrenin harmasını eş zamanlı olarak çıkarma bir problem olarak 90'lı yılların başında Smith ve ark. (1990) tarafından ortaya atılmıştır. Bu çalışmaya birlikte literatürde eş zamanlı konum belirleme ve harita oluşturma (Simultaneous localization and mapping, SLAM) bir problem olarak bilinmektedir. SLAM modelinde gözlemlenen farklı problemler mevcuttur. Modelde ölçüm gürültülerinin istatistikleri olarak bağımlı olmasından harita oluşturulurken gürültünün zamanla büyümesinin sonucunda haritanın ve robotun/ özerk aracın gezinim boyunca konumunun hatalı elde edilmesine yol açması bilinen genel bir problemdir. Literatürde bu problemin çözümüne bağlı olarak bir takım çalışmalar mevcuttur. Bunun yanı sıra haritası çıkarılacak bölgenin nesne sayısının artması ise bir başka problem olarak bilinmektedir. Diğer bir problem ise robotun / özerk aracın geçtiği yeri hatırlamasıdır, bu durum veri ilişkilendirme problemi olarak bilinmektedir.

Son zamanlarda yapılan çalışmalarında bu problemler göz önüne alınarak farklı Bayes tabanlı istatistiksel algoritmalar bir çözüm olarak önerilmiştir. Bu çalışmaların bir kısmı gözlem gürültülerinin etkisinin sonucu oluşan harita ve pozisyon hatalarını minimize etmeye çalışırken (Bailey T. 2001, Montemerlo M. ve Thrun S. 2002, Montemerlo, M. Ve ark., 2001 ), bazıları nesne sayısının artması sonucu gerçek zamanlı uygulamalarda karşılaşılan problemlerden işlem sürelerini azaltmaya yönelik algoritmalar geliştirmiştir (Montemerlo, M. ve ark 2001, Kim C. ve ark. 2008). Bazi çalışmalar ise veri ilişkilendirme problemi üzerinde durarak robot/ özerk aracın geçtiği yeri hatırlaması veya diğer bir deyişle nesne yeri belirsizliği problemini çözmeye çalışmışlardır (Neira J. ve Tardós J.D 2001, Rex H. Wong ve ark. 2010). Bu çalışmalarla farklı Bayes tabanlı kestirciler alternatif bir çözüm olarak sunulmuştur. Daha önce yapılan bu çalışmalar genel olarak; Kalman tabanlı

kestirciler, Sıralı Monte Carlo yaklaşımı olarak bilinen parçacık süzgeçleri ve bekleni en büyültme yöntemine dayanan kestirciler olarak sıralanabilmektedir.

SLAM uygulamalarında gözlem gürültüsünün istatistikleri olarak zamanla büyümesi ölçüm bilgilerinin de karmaşık bir şekilde elde edilmesine, ölçümlerde bir takım belirsizliklere yol açmaktadır. SLAM yöntemi robot/ özerk aracın konum bilgisini alırken çevredeki nesne işaretlerinden yararlanır. Nesne işaretlerinin doğru bir şekilde elde edilmesi aynı zamanda robotun/ özerk aracın konumunun da doğru bir ölçümle elde edilmesini sağlamaktadır.

Bazı durumlarda nesne işaretlerinin birbirine yakın olması ve sayısının fazla olması hangi ölçümün hangi nesne işaretinden geldiğinin karışmasına yol açmaktadır. Bu gibi durumlarda kestircilerin performansı düşmekte, hata kareleri ortalamasının yükselmesine yol açmakta, böylece SLAM probleminde haritanın hatalı oluşturulmasına ve aracın pozisyon ve başlık açısının hatalı elde edilmesine yol açarak bir takım belirsizlikler oluşmaktadır. Bu durumlarda veri ilişkilendirilmesine ihtiyaç duyulur.

Başarılı bir veri ilişkilendirme, gözlemlenmiş ölçümün kendisinden kaynaklanan durum hesabıyla doğru bir şekilde ilişkilendirmesiyle sağlanabilir. SLAM probleminde ise algoritma yeni nesne işaretlerini doğru bir şekilde tahmin edebilmeli (başlatıbmeli), yanlış ölçümleri algılayabilmeli, var olan ölçüm bilgilerini doğru bir şekilde takip edebilmelidir ( Rex H. Wong ve ark. 2010). Veri ilişkilendirmeyle ilgili en temel algoritma en yakın komşuluk (Nearest Neighbor-NN) algoritmasıdır. Bu algoritma işlem sırasında Mahalanobis mesafesini kullanır. Mahalanobis mesafesi nesnenin gözlemlenen ölçümü ve hesaplanan pozisyonu arasındaki mesafedir (Mahalanobis P.C. 1936). Algoritma tahmin edilen hedef pozisyonuna en yakın ölçüm değerini gerçek değer olarak kabul eder. Bir sonraki nesne işaretini yenilemesi için ölçüm kestirimine göre bir kabul bölgesi oluşturulur, kabul bölgesi kapı olarak adlandırılır. Fakat en yakın komşuluk ( NN ) süreceinde ölçüm ilişkili en yakın nesneden

gelmeyebilir, fakat süzgeç bu durumla ilgilenmez. Bu yüzden durum vektörü güncellenirken iraksamaya yol açabilmektedir. Aynı zamanda dinamik çevrelerde performansının iyi olmadığı gözlenmiştir (Rex H. Wong ve ark. 2010).

Birbirine yakın nesne sayısının çok olduğu ve yüksek gürültülü durumlarda *NN* algoritmasının performansının iyi sonuçlar vermediği daha önceki çalışmalarda dephinilmiştir (Rex H. Wong ve ark. 2010, Montemerlo, M. ve ark 2002). Bunun sebebinin kapı içerisindeki ölçümlerden en düşük mesafedeki kestirim değerinin gerçek ölçüm olarak anılmasıdır. *NN* algoritmasında sonuca çabuk varmak için işlem süresi kısaltılırken tüm verilerin kullanılmaması yapıyı optimal durumdan uzaklaştırır. Olasılıksal veri ilişkilendirme (Probabilistic Data Association, PDA) algoritması kapı içindeki bütün ölçümelerin hedef nesne olma olasılıklarını hesaplar. PDA bir birelilik inovasyon değeri hesaplar, bunun ile belirsizlik problemini olasılıksal olarak çözmeye çalışır. Hipotezlerin ilişkisel olasılığını kullanarak birelilik bir inovasyon sağlar ve bununla birlikte birelilik geçerlilik kapısını oluşturur. Algoritma çalışma esnasında her bir hedefi bağımsız kabul eder ve komşu hedeflerle karışmadığını farz eder. Öte yandan SLAM probleminde nesne işaretlerinin korelasyonu, bu hedeflerin karşılıklı iletişimini olduğundan göz arı edilemez (Rex H. Wong ve ark. 2010). Bu yüzden çoklu nesne veya hedef izleme ve dinamik durumlar için PDA algoritması uygun değildir, ya da algoritma her bir nesne işaretü için tekrar koşturulmalıdır. Bu PDA algoritması için SLAM uygulamalarında bir geri adım olarak kabul edilir ve bileşik PDA (Joint Probabilistic Data Association, JPDA) algoritmasının kullanılmasına olanak sağlar. Ortamda bulunan tüm nesne işaretlerinin PDA mantığıyla bir döngüde takip edilebilmesi için JPDA algoritması geliştirilmiştir.

Literatürde SLAM uygulamalarında veri ilişkilendirme problemine yönelik JPDA algoritmasını kullanan bazı çalışmalar mevcuttur (Rex H. Wong ve ark. 2010). Rex H. Wong ve ark. (2010) çalışmada kablosuz sensör şebekelerindeki SLAM

problemi için bu algoritmayı önermiştir ve 3-tarama JPDA yöntemini kullanmışlardır. Gürültülü sensör bilgisine dayanarak ve olası parazit yankılara bağlı olarak gelen sinyalin gürültülü olduğunu ve bunun da pozisyon ve açı ölçümünde belirsizliğe yol açtığını söylemektedirler. Rex H. Wong ve ark. (2010) çalışmalarında hareketli parazit yankılı ortamda ölçümleri parazit yankından ayırmannın zor olduğunu çünkü yeni nesne işaretlerinin belirsizlige yol açtığını göstermişlerdir. Diğer bir JPDA temelli yaklaşım ise Zhou B. and Bose N (1993) tarafından önerilmiştir. Zhou B. and Bose N (1993) önerdiği *Fast-JPDA* yöntemi ile birlikte “*Depth-first-search*” (DFS) yöntemi birleştirmiştir. Fakat çoklu hipotez izleme (Multiple Hypothesis Tracking, MHT) yönteminde olduğu gibi geri izleme temelli bir yöntem olduğu için veri ilişkilendirme hipotezleri burada geniş hesaplama maliyeti getirmiştir. Bu çalışmalar genel olarak SLAM probleminin veri ilişkilendirme sorununu çözmek için geliştirilen yaklaşımalar olmuşlardır, kullanılan algoritmalarla birlikte süzgeçlerin performanslarına dephinilmemiştir. Sadece belirsizlik esnasında bir takım karşılaştırmalar yapılmıştır.

Bu çalışmada önerilen iyileştirme daha önce yapılan çalışmalar göz önünde bulundurularak SLAM probleminin çözümünde daha uygun iki yeni yaklaşım üzerine yoğunlaşmıştır. İlk olarak gürültülü ve yüksek belirsizliklere sahip öznitelik tabanlı haritalarda SLAM probleminin veri ilişkilendirme problemi için bir alternatif sunulmaktadır. SLAM problemi için geliştirilmiş bir JPDA algoritması ilgili senaryo için ilk defa önerilmektedir. JPDA algoritmasında bütünsel inovasyon matrisinin SLAM problemi çözümünde etkisinin büyük olduğu deneysel çalışmalar esnasında gözlemlenmiştir. Diğer bir iyileştirme ise kullanılan süzgeçtir. Daha önceki çalışmalarla genel olarak genişletilmiş Kalman süzgeci tercih edilmiştir (Rex H. Wong ve ark. 2010, Montemerlo, M. ve ark 2001 Bailey T. 2001). Bu çalışmada kokusuz Kalman süzgeci (Unscented Kalman filter, UKF) SLAM probleminin gözlem gürültüsünün minimize edilmesinde daha başarılı olacağı düşünülerek

tercih edilmiştir. UKF süzgeci deterministik bir yaklaşımıyla model durumunun soncul olasılığını dağılım üzerinde belirli sayıda sigma noktası seçerek doğrusal olmayan bir fonksiyonla tahmin etmeye çalışmaktadır. Bu yöntem süzgecin kestirim doğruluğunu ve işlem hızını FastSLAM tabanlı parçacık süzgeçlerinden daha kısa sürede yapmasına olanak sağlamaktadır. SLAM probleminin çözümünde Anışhan H. (2012), Kim C. ve ark. (2008), ve Bailey T. (2002) yapmış oldukları çalışmalarla bu süzgecin daha uygun sonuçlar verdiğiğini gözlemlemişlerdir. UKF ile birlikte geliştirilmiş JPDA algoritması bütünlük olarak SLAM problemi için bu çalışmada önerilmiştir. Çalışmada durum belirsizliğinin çözümü ve doğru süzgeç kullanımı ile istenilen uygun sonuca ulaşılacağı düşünülmüştür.

Çalışmanın ilerleyen bölümleri şu şekildedir; II, bölümde problem tanımı, III. bölümde veri ilişkilendirme hipotezleri, IV. bölümde kokusuz kalman süzgeci, V. bölümde deneyel sonuçlar ve tartışma, son olarak VI. bölümde sonuç ve değerlendirme yer almaktadır.

## Problem Tanımı

Bu bölümde parazit yankılı ortamda SLAM için veri ilişkilendirme algoritması anlatılacaktır. Bayes yapısıyla birlikte stokastik modelin soncul olasılığı

$$\frac{P\{x_k, m | Z_{0:k}, U_{0:k}, x_0\}}{P\{z_k | x_k, m\} P\{x_k, m | Z_{0:k-1}, U_{0:k}, x_0\}} \quad (1)$$

$$P\{z_k | Z_{0:k-1}, U_{0:k}\}$$

gösterilir. Burada  $x_k$  k anında robotun durumu,  $m$  ise global haritadaki gözlemlenen nesne işaretlerini (sınır taşları),  $Z_{0:k}$  ve  $U_{0:k}$  bütün ölçümler ve kontrol vektörünü göstermektedir.  $x_0$  ise robotun başlangıç durumunu vermektedir. Soncul olasılıkla gözlem modeli  $P\{z_k | x_k, m\}$  olarak gösterilir ve  $z_k, \{z_1, z_2, \dots, z_m\}_k$  k anındaki ölçümlerin toplamını verir ve ölçüm

$$z_k = h(x_k, m) + \delta_k \quad (2)$$

olarak modellenir. Burada  $\delta_k \sim N(0, Q_k)$ 'dır ve ölçüm tahmini

$$\hat{z} = h(\hat{x}_{k/k-1}) + \delta_k \quad (3)$$

olarak verilir. Ölçüm tahmini ve ölçümün farkı inovasyon vektörünü verir,

$$v = z - \hat{z} = z - h(\hat{x}_{k/k-1}) \quad (4)$$

ve inovasyon kovaryansı,

$$S = h(\hat{x}_{k/k-1}) \sum_v [h(\hat{x}_{k/k-1})]^T + Q_k \quad (5)$$

olarak verilir.  $h(\hat{x}_{k/k-1})$  ölçüm fonksiyonu,  $\Sigma_v$  durum kovaryansı ve  $\delta_k$  sıfır ortalamalı ölçümün beyaz gürültüsüdür,  $Q_k$  kovaryansına sahiptir. İstatistiksel geçerlilik kapısı gözlem ve en yakın ölçüm arasında eşleştirmeyi sağlar (Zhou B. and Bose N, 1993). Bu tanımdan yola çıkararak Mahalanobis mesafesi (ya da normalleştirilmiş inovasyon karesi- NIS),

$$M_x = v^T S^{-1} v \leq \gamma_n \quad (6)$$

olarak tanımlanır (Rex H. Wong ve ark. 2010). NIS serbestliğin  $N$  boyutu ile Chi-Kare ( $\chi^2$ ) dağılımına sahiptir.  $\gamma_n$  kapı eşik değeridir. NN süzgeci ölçümün gelen sinyalinin geçerliliğini test etmek için bu eşik değerini kullanır. Bütün olası ölçümler arasında hangisi nesnenin tahmin edilen değerine en yakın ise o geçerli ölçüm olarak atanır. Eğer çoklu hedeflerde NN süzgeçinde kapılar üst üste çakışırsa, sensör ölçümleri birbirinden bağımsız olsa bile belirsizlik durumu ortaya çıkar süzgeç bu durumda doğru veri ilişkilendirmesi yapamayabilir. Öznitelik tabanlı SLAM probleminde bütün sensör ölçümleri birbirinden bağımsız olsalar bile, tahmin edilen ölçümler robotun benzer pozisyon hatası tarafından istatistiksel olarak birbirile ilişkilidir. Bu durumdan, PDA çoklu hedef tahmini durumunu

çözemez, ya da tekrarlı olarak her bir hedef için sözgeç algoritması tekrar koşturulur. Çoklu hedef problemini çözmek için JPDA algoritmaları önerilmiştir.

Hedeflerin kümesi  $k$  anında  $X_k = \{x_1, x_2, \dots, x_n\}$  olarak düşünülürse, ilgili zamanda bu küme ile ilişkilendirilen geçerli ölçümllerin toplamı  $m$  olarak kabul edilir ve  $k$  anındaki ölçümller kümesi  $Z_k = \{z_1, z_2, \dots, z_M\}$  olarak yazılır. Burada her bir ölçüm ya hedeften ya da parazit yankından gelmektedir. Parazit yankı  $x_0$  olarak yazılır. Tahmin edilen hedef ölçümü  $\hat{z}_m^x$ , ölçüm  $m'$  in inovasyon vektörü ise

$$\tilde{z}_m^x = z_m - \hat{z}_x \quad (7)$$

olarak yazılır (Y.Bar-Shalom ve ark. 2009). Her bir  $x$  hedefi için birleştirilmiş (ağırlandırmış) inovasyon,

$$\tilde{z}^x = \sum_{m=1}^M \beta_m^x \tilde{z}_m^x \quad (8)$$

burada  $\beta_m^x$  hedef  $x$  ten gelen ilişkilendirilmiş olasılığı göstermektedir ve  $\beta_0^x$   $t$  anındaki ölçümllerin hiçbirisinin hedeften gelmediği olasılığı gösterir.

$$\beta_m^x = \sum_{\phi} P\{\Phi(k) | Z^k\} a_m^x(\Phi) \quad (9)$$

$$\beta_0^x = 1 - \sum_{m=1}^M \beta_m^x \quad (10)$$

burada  $m=1,2,\dots,M$ ;  $x=0,1,\dots,N$

$$a_m^x(\Phi) = \begin{cases} 1 & \text{ölçüm hedeften gelmektedir} \\ 0 & \text{ölçüm hedeften gelmemektedir} \end{cases} \quad (11)$$

burada  $\Phi(k)$  ilgili zamanda birleşik ilişkisel olayları gösterir ve

$$\Phi(k) = \bigcap_{m=1}^M \phi_m^x(k) \quad (12)$$

yazılır,  $\phi_m^x(k)$  bireysel ilişkisel olayı gösterir,  $\cap$  olayların kesişimini gösterir ve  $a_m^x(\Phi)$  geçerlilik matrisindeki ölçüm  $z$  ve hedef  $x$  arasındaki ilişkisel hipotezi gösterir,

$$\Omega = [a_m^x(\Phi)] \quad (13)$$

$$\Omega = \begin{matrix} & \begin{matrix} x_0 & x_1 & x_2 & \cdot & \dots & x_N \end{matrix} \\ \begin{matrix} 1 \\ \vdots \\ 1 \end{matrix} & \begin{pmatrix} a_1^1 & a_1^2 & \dots & a_1^N \\ a_2^1 & a_2^2 & \dots & a_2^N \\ \vdots & \vdots & \vdots & \vdots \\ a_M^1 & a_M^2 & \dots & a_M^N \end{pmatrix} \begin{matrix} z_1 \\ z_2 \\ \vdots \\ z_M \end{matrix} \end{matrix} \quad (14)$$

Eşitlik (9)' dan,  $k$  zamanındaki tüm ölçümllerin birleşik olaylarının olasılığı eşitlik (15)' te verilmiştir.

$$\begin{aligned} P\{\Phi(k) | Z^k\} &= P\{\Phi(k) | Z(k), Z^{k-1}\} \\ &= \frac{1}{c} p(Z^k | \Phi(k), Z^{k-1}) P\{\Phi(k)\} \end{aligned} \quad (15)$$

Buradaki normalizasyon sabiti  $c$  ölçümllerin birleşik öncül yoğunluğu ve  $\Phi(k)$  daki bütün değerlerin toplamını göstermektedir. Birleşik olasılık yoğunluk fonksiyonu,

$$\begin{aligned} p(Z^k | \Phi(k), Z^{k-1}) &= \\ \prod_{m=0}^M p[z_m(k) | \phi_m^x(k), Z^{k-1}] & \end{aligned} \quad (16)$$

Hedef  $x$  ile ilişkilendirilen  $m$  ölçümünü, Gauss yoğunluğununa bağlı olduğundan

$$p[z_m(k) | \phi_m^x(k), Z^{k-1}] = \begin{cases} N(z_m; \hat{z}_m^x, S_m^x) & \text{eğer } a_m^x(\Phi) = 1 \\ A^{-1} & \text{eğer } a_m^x(\Phi) = 0 \end{cases} \quad (17)$$

Normal yoğunluk dağılım fonksiyonu,

$$\begin{aligned} N(z_m; \hat{z}_m^x, S_m^x) &= \\ P_G^{-1}(2\pi S_m^x)^{1/2} e^{\left(\frac{1}{2} \hat{z}_m^x (S_m^x)^{-1} (\hat{z}_m^x)^T\right)} & \end{aligned} \quad (18)$$

gösterilir. Burada  $P_G$  doğru ölçümllerin olasılığı,  $m$  hedef  $x'$  in kapısının içerisindeki ölçüm,  $\hat{z}_m^x$  ve  $S_m^x$  inovasyon vektörü ve kovaryansıdır. Ölçümler eğer herhangi bir hedefle ilişkilendirilmemezse o zaman ölçümller ilgili kapının dışında olacaktır ve hesaba katılmayacaktır. (15) eşitliğindeki ikinci faktör birleşik olayların öncül olasılığını vermektedir. Yanlış alarmların toplam sayısı  $m_0$  olarak tanımlanır. Doğru ölçümllerin sayısı  $m_c = M - m_0$  olarak verilir,  $M$  burada toplam geçerlilik alanı içerisindeki ölçümllerin sayısını vermektedir. Buradan öncül olasılık,

$$P\{\Phi(k)\} = \quad (19)$$

$$P\{\Phi(k) | \delta(\Phi), \varphi(\Phi)\} P\{\delta(\Phi), \varphi(\Phi)\}$$

İfade edilir. Burada  $\delta(\Phi)$  ikili düzende hedef algılama göstericisidir (1 ya da 0).

$$\delta_x(\Phi) = \sum_{m=1}^M \alpha_m^x(\Phi) \leq 1 \quad x = 1, \dots, N \quad (20)$$

ve  $\varphi(\Phi)$  olaydaki yanlış ölçümllerin sayısını vermektedir. Bütün hedefler ikili gösterici ilişkisine bağlı olarak tanımlanırsa  $\tau_m(\Phi)$  ilgili olayda  $m$  ölçümü ile bütün hedeflerin ilişkisini göstermektedir.

$$\tau_m(\Phi) = \sum_{x=1}^N \alpha_m^x(\Phi), m = 1, \dots, M \quad (21)$$

$$\varphi(\Phi) = \sum_{m=1}^M [1 - \tau_m(\Phi)] \quad (22)$$

(19)'un ikinci terimi;

$$P\{\delta(\Phi), \varphi(\Phi)\} = \prod_{t=1}^N (P_D)_t^\delta (1 - P_D)_t^{1-\delta} P_F(m_0) \quad (23)$$

İfade edilir. Burada  $P_F$  yanlış alarmlar için Poisson olasılık yoğunluk fonksiyonunu göstermektedir (Y. Bar-Shalom ve ark. 2009):

$$P_F(m_0) = e^{-\lambda A} \frac{(\lambda A)^{m_0}}{m_0!} \quad (24)$$

burada  $\lambda$  yanlış ölçümllerin uzaysal yoğunluğu ve  $A$  geçerlilik bölgesinin alanını vermektedir. Eşik değerinin de işleme katılımasıyla oluşturulan kapı bölgesinin alanı

$$A = \pi |\gamma S(k)|^{1/2} \quad (25)$$

olarak verilir. Buradan eşitlik (19)

$$P\{\Phi(k)\} = \frac{m_0!}{M!} e^{-\lambda A} \frac{\lambda A}{m_0!} \prod_{t=1}^N (P_D)_t^\delta (1 - P_D)_t^{1-\delta} \quad (26)$$

ölçüm eğer herhangi bir hedefle ilişkilendirilmemezse iki boyutlu uzaya gözlem  $A$  alanında düzgün dağılıma sahiptir denilir. Yanlış alarmlar için düzgün yoğunluk fonksiyonu  $m_0$ 'ın üstü olarak  $A - m_0$  gibi tanımlanır (Rex H. Wong ve ark. 2010). (17) ve (18) birleştirilerek (16) tekrar elde edilirse,

$$p(Z^k | \Phi(k), Z^{k-1}) = A^{-m_0} \prod_{m=1}^M N(z_m; \hat{z}_m^x, S_m^x) \quad (27)$$

(26) ve (27) ile (15) tekrar yazılrsa,

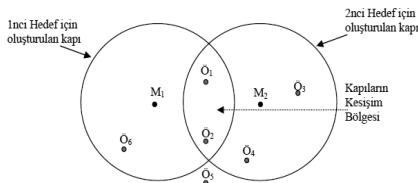
$$P\{\Phi(k) | Z^k\} = \frac{\lambda^{-m_0}}{c} \prod_{m=1}^M N(z_m; \hat{z}_m^x, S_m^x)_m^\tau \times \prod_{t=1}^N (P_D)_t^\delta (1 - P_D)_t^{1-\delta} \quad (28)$$

olarak tanımlanır.

### SLAM için İlişkisel Hipotez Oluşturulması

PDA algoritması parazit yankılı ortamda bir hedefin takibi için uygun sonuçlar verebilmektedir. Çoklu hedef takibi için literatürde JPDA algoritmaları önerilmiştir. Bu yöntemde ortamdaki bütün hedeflerin PDA mantığı ile bir döngüde takip edilmesi amaçlanmıştır. JPDA algoritması birden çok hedefin takibinin yanı sıra birbirine yakın seyreden veya kesişen hedeflerde de uygun

sonuçlar verebilmektedir (Pakfiliz, 2004, Y.Bar-Shalom ve ark. 2009). JPDA algoritmasında bilinen sayıdaki hedef izinin oluşturulması için ölçümün hedefle ilişkilendirilme ihtimalleri en son veri seti baz alınarak yapılır (Pakfiliz 2004). Birden fazla hedefin olduğu durumlarda karşılaşılan en önemli problem; iki veya daha fazla hedef için oluşturulan geçerlilik kapılarının kesişim bölgelerinin üst üste binerek kesişmesi problemdir. Bu gibi durumlarda sözgeç performansı azalmaktadır. Şimdi iki hedef ve alınan altı ölçüle oluşturulmuş geçerlilik matrisinden bahsedilirse şekil 1 oluşturulan kapı, ölçümler ve hedefleri göstermektedir.



*Şekil 1. Geçerlilik matrisi ve kümelenmesi  
(Pakşılız 2004).*

Bu senaryoya bağlı olarak oluşturulan geçerlilik matrisi (29)'daki gibi olacaktır.

$$\Omega = \begin{array}{|ccc|c|} \hline x_0 & x_1 & x_2 & \\ \hline 1 & 1 & 1 & z_1 \\ 1 & 1 & 1 & z_2 \\ \hline 1 & 0 & 1 & z_3 = \{a_z^x\} \\ 1 & 0 & 1 & z_4 \\ 1 & 0 & 0 & z_5 \\ 1 & 1 & 0 & z_6 \\ \hline \end{array} \quad (29)$$

Burada  $x_0$ ,  $x_1$  ve  $x_2$  hedefleri bilinirken, parazit yankı ya da yeni hedef olarak gösterilir. Bu matrisle dayanarak JPDA algoritmasında bazı kabuller yapılabilir:

- Bir ölçüm sadece bir hedeften gelebilir,
  - Herhangi bir hedef birden fazla ölçüme ilişkilendirilemez,
  - Parazit yankı durumu bu kuralla kısıtlanamaz.

Temel olarak bu kabullerde  $x_0$  sütunu hariç tutulur ve diğer sütunlar için bir sıradaki elemandan sadece bir eleman sorumlu olur.

Veri ilişkilendirme hipotezinin sayısı nesne işaretleri sayısı ve ölçümle exponansiyel olarak artış gösterdiğinden, ana nokta olaylar setinin performansı etkilemeden nasıl üretileceğidir.

Geleneksel olarak geçerlilik matrisi içerisinde sıfır olmayan elemanlardan geçerli birleşik hipotezler üretilerek yorucu araştırma algoritmaları kullanılmaktadır (Rex H. Wong ve ark. 2010). Bu metod hız ve hesaplama karmaşıklığı olmadığı durumlarda; yani SLAM problemini göz önüne alındığında nesne işaretlerinin sayısının az olduğunda uygun sonuçlar verebilmektedir. Öte yandan eğer geçerlilik matrisinde birlerin sayısı çok fazla olursa bu durum geçerliliğini yitirmektedir. Gerçek zamanlı uygulamalarda hız ve hafıza problemi olarak ortaya çıkmaktadır.

Daha önceki çalışmalarda DFS (Y.Bar-Shalom ve T. Fortman 1988) yöntemi mantıklı ilişkisel hipotezler kurulması için tercih edilmiştir. Bu çalışmada da DFS yönteminden yararlanılmıştır.

Şekil 1 tekrar incelenecek olursa altı ölçüm ve iki hedef olduğu bilinmektedir. Her bir ölçüm ya hedeflerden ya da parazit yankından gelmektedir. Bu yüzden her bir ölçüm için üç olasılık vardır ve 36 hipotez hesaplanması gerekmektedir. Bu hipotezlerin hepsi mantıklı olmayabilir, mantıklı hipotezler ortak olarak hariç tutulabilir ve DFS yöntemi bu işin çözümü için yardımcı olmaktadır. Detaylı bilgi için (B. Zhou, and N. Bose 1993)'e bakılabilir.

## **JPDA - UKF Güncelleme ve Tahmin Adımı**

$j$ 'inci hedefin durum güncellemesi  $x_{k|k}^j$  (Y. Bar-Shalom ve ark. 2009)'te verildiği gibi,

$$x_{k|k}^j = \beta_{0j} x_{k|k-1}^j + \sum_{i=1}^{m_j(k)} \beta_{ij} x_{k|k}^j(i) \quad (30)$$

Burada  $m_j(k)$   $j$ 'inci hedef için geçerli ölçümelerin sayısı,  $x_{k|k-1}^j$  durum tahmini,  $x_{k|k}^j(i)$   $i$ 'nci geçerli ölçümü kullanarak yapılan UKF güncellemesi ve  $\beta_{ij}$  ilgili ilişkisel olayları göstermektedir (Y. Bar-Shalom ve ark. 1995, 2009). Kovaryans için durum güncellemesi,

$$P_{k|k}^j = \beta_{0j} P_{k|k-1}^j + \sum_{i=1}^{m_j(k)} [P_{k|k}^j(i) + (x_{k|k}^j(i) - x_{k|k}^j)(x_{k|k}^j(i) - x_{k|k}^j)^T] \beta_{ij} \quad (31)$$

olarak hesaplanır. Durum tahmini  $x_{k|k-1}^j$ , kovaryansı  $P_{k|k-1}^j$ , tahmin edilen hedef ölçümü  $z_{k|k-1}^j$  ve onun inovasyon kovaryansı  $S_k^j$  UKF tahmin adımda detaylı olarak ek  $A'$  da anlatılmaktadır.

## Deneysel Çalışmalar ve Tartışma

Bu bölümde, daha önceden Tim Bailey (2002) tarafından geliştirilen yazılımdan yararlanılarak; iyileştirilmiş süzgeç yardımıyla yapılan benzetim çalışması ve diğer süzgeç modelleriyle yapılan karşılaştırmalar gösterilecektir. Bu çalışmada iki senaryo üzerinden uygulama gerçekleştirilmektedir; ilk uygulama SLAM'ın gürültülü ortamda noktasal nesne işaretleriyle birlikte gerçekleştirilen iç mekân uygulaması olarak bilinmekte, ikinci uygulama ise yine aynı ortamda gerçekleştirilecektir fakat ortamda rasgele durağan olarak dağıtılmış parazit yankılar mevcuttur. Her bir senaryo için işlem aşaması ise iki adımda gerçekleştirilecektir. İlk adım algılama; sinyal gürültü oranına (Signal to Noise Ratio-SNR) bağlı olarak, algılama olasılığı ( $P_D$ ), ve yanlış alarmların olasılığı ( $P_F$ )dır. Eğer SNR düşük olursa  $P_F$  tarafından  $P_D$  daha fazla etkilendiği görülmüştür (Rex H. Wong ve ark. 2010). İkinci adım ise haritalama ve veri ilişkilendirme algoritmaları üzerinde durmaktadır.

Kullanılan benzetim için ilgili sistem kontrol parametreleri; araç hızı 3m/sn, maksimum başlık açısı  $30^*\pi/180$  radyan, araç dingil mesafesi 4 metre, kontrol sinyalleri arası 0.025

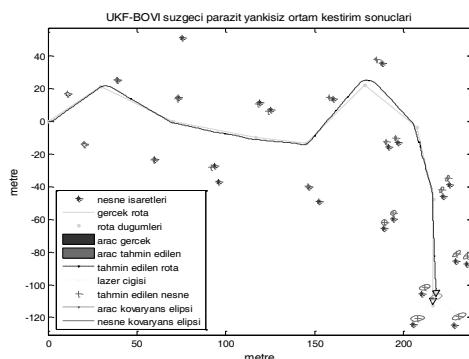
saniye olarak alınmıştır. Bunun yanı sıra kontrol ve ölçüm gürültüleri,

$$Q = \begin{bmatrix} 0.5^2 & 0 \\ 0 & [5*(\pi/180)]^2 \end{bmatrix} \quad (32)$$

$$R = \begin{bmatrix} 0.5^2 & 0 \\ 0 & [5*(\pi/180)]^2 \end{bmatrix} \quad (33)$$

olarak alınmıştır. Gözlem parametreleri olarak laser maksimum algılama mesafesi 30 metre, araç gözlemler arası tarama zamanı ise ortalama  $8*0.025$  saniye olarak belirlenmiştir. İlişkilendirme için kapı elips genişliği maksimum mesafe 5 metre, yeni gözlemlenen nesne işaretin minimum mesafe ise 25 metre olarak kabul edilmiştir. Çalışma esnasında alınan sensör bilgilerine  $\sigma^2=1$  olarak beyaz gürültü eklenmiştir.

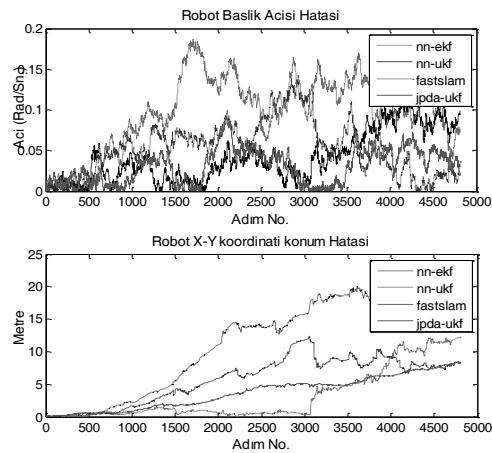
**Senaryo I:** İlk senaryo ortamda parazit yankılarının olmadığını kabul etmektedir. Kabul edilen kontrol ve ölçüm gürültüleri eşitlik (32) ve (33)'de verilmiştir. İlgili senaryo (0m,0m) noktasında bilinmeyen bir ortam için başlamakta (220m,-110m) noktasında bitmektedir. JPDA-UKF süzgecinin birbirine çok yakın nesne işaretli ortamda vermiş olduğu kestirim sonuçları şekil 2'de verilmiştir.



Şekil 2. JPDA -UKF algoritması ilgili senaryo kestirim değerleri.

**Senaryo I** için aracın pozisyon ve başlık hatası NN-EKF, NN-UKF, FastSLAM II ve JPDA -

UKF yöntemleriyle kıyaslandığında şekil 3, 4' teki gibi elde edilmiştir. Sonuçlar 50 monte carlo simülasyonu sonucunda elde edilmiştir.

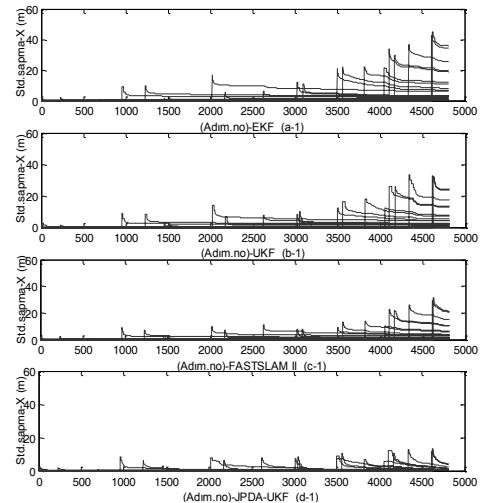


Şekil 3. Süzgeçler robot pozisyon ve başlık açısı ortalama kare hata kestirim sonuçları

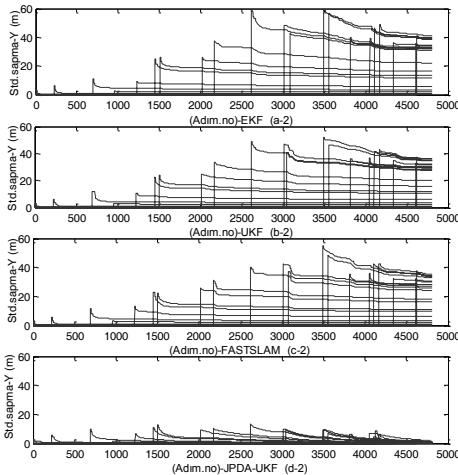
Şekil 3, dört süzgeçin yoğun gürültülü parazit yankının olmadığı ortamda ortalama kare hataları hakkında bize bilgiler vermektedir. Süzgeçler genel olarak 1500'ncü adıma kadar doğrusal ortalama kare hatası artışına sahipken, bu adımdan itibaren ortam şekil 2 ve 4' ten de görüleceği üzere, nesne işaretlerinin sayısının da paralel artışı ve belirsizliklerin artması sebebiyle hata kareleri farklı oranda ivme artışına girmiştir. Çünkü süzgeçler bu adımdan itibaren rotadaki (başlık açısı ve pozisyon değişiminin büyülükleyle alakalı olarak) dönmeler ve yeni kestirilen nesne işaretlerinin geçiş matrisinde yaratılan büyümeye etkisiyle gürültü ortamda minimum düzeyde oluşan hataların gürültünün istatistiksel olarak zamanla sistemde büyümesi sonucu SLAM hata ortalamasının büyümeye yol açmıştır.

Şekil 4 haritadaki bütün nesne işaretlerinin ilk kestiriminden itibaren harita boyunca güncellenmesi ve belirsizlik alanları hakkında bilgiler içermektedir (teorik olarak nesne işaretlerinin varyanslarının ilk kestirildiği andan itibaren değerlerinin sıfır doğru yaklaşması

gereklidir). Görüldüğü üzere süzgeçlerin X-Y koordinatındaki standart sapma değerleri, süzgeçlerin kestirim doğruluğu ile paralel sonuçlar vermektedir. Teorik olarak haritalama esnasında nesne işaretlerinin standart sapma değerleri süzgeçlerin kestirimini ve doğruluğuyla uygun aralıklarda daralmalıdır. Şekil 4' ten görüldüğü üzere en uygun minimizasyonu (monoton olarak standart sapma daralma olayı) JPDA-UKF süzgecinde görebilmekteyiz. Süzgeç zaman adımı ilerledikçe özellikle nesne işaretlerinin birbirine yakın olduğu durumlarda ilişkilendirmeyi diğer süzgeçlere göre daha başarılı yapabilmektedir, böylece kestirim doğruluğu olumlu yönde etkilenmektedir.



Şekil 4.(a). Bütün algılanan nesne işaretleri için nesne işaretleri konum kestiriminin bütün süzgeçler için standart sapma değerleri. Gözlemeği gibi nesne işaretleri pozisyonunda, ((a)-X koordinatındaki standart sapma değerleri) belirsizlik monoton olarak azalmaktadır.



*Şekil 4.(b). Bütün algılanan nesne işaretleri için nesne işaretleri konum kestiriminin bütün süzgeçler için standart sapma değerleri. Gözlemediği gibi nesne işaretleri pozisyonunda, ((b)-Y koordinatındaki standart sapma değerleri) belirsizlik monoton olarak azalmaktadır.*

Şekil 4, X-Y koordinatında hesaplanan her bir nesne işaretini ve akabinde yapılan korelasyonlu iyileştirme sonucunu vermektedir. Görüldüğü gibi JPDA-UKF süzgeci hariç süzgeçlerin harita güncellemesini istenilen uygun düzeyde yapamadıkları görülmektedir. Çünkü güncelleme nesne işaretlerinin de standart sapma değerlerinin sıfır yaklaşmasıyla sağlanmaktadır. Nesne işaretlerini ilgili adım aralığı içerisinde minimize edebilen ve harita güncellemesini en uygun aralıklarda yapabilen JPDA-UKF süzgeci olduğu şekil 3 ve 4' ten görülmektedir. Bunun yanı sıra ilgili süzgeçlerin hata kareleri ortalamaları ve başlık açısı hata ortalamaları tablo I' de verilmiştir.

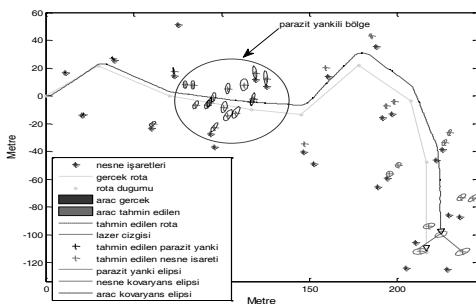
Açısal başlık hataları için yine konum hatası ve varyans minimizasyonu ile paralel olarak en uygun sonucu JPDA-UKF süzgecinde görmekteyiz.

*Tablo I. Robot başlık açı ve konum ortalama kare hataları*

Süzgeç	Açısal başlık hatalı	Konum hatası
NN-EKF	0.3101	3.3582
NN-UKF	0.2026	1.9287
FastSLAM II	0.2300	2.3915
JPDA-UKF	0.1747	1.7903

**Senaryo II.** Deneysel çalışmanın bu kısmında haritanın 4. düğümünde  $30 \times 30 \text{ m}^2$  lik bir alanda statik parazit yankı üretilmiştir. Parazit yankı önceliği (gelme olasılığı) 0.2, yoğunluğu  $CD=1/(30 \times 30)$  olarak alınmıştır. Kabul edilen kontrol ve ölçüm gürültülerini yine senaryo I' de olduğu gibi eşitlik (32) ve (33)' teki değerlerdir. İlgili senaryo (0m,0m) noktasında bilinmeyen bir ortam için başlamakta (220m,-110m) noktasında bitmektedir.

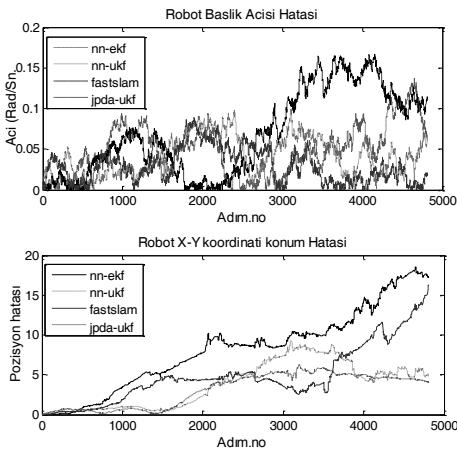
JPDA-UKF süzgecinin birbirine çok yakın nesne işaretli ortamda vermiş olduğu kestirim sonuçları şekil 2' de gösterilmiştir. Senaryo II için deneysel çıktılar 50 monte carlo simülasyonu yapılarak elde edilmiştir.



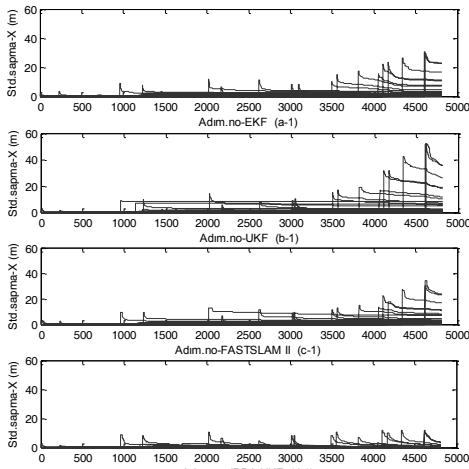
*Şekil 5. JPDA -UKF algoritması statik parazit yankılı ortamda SLAM problemi için kestirim sonuçları.*

Şekil 5' te senaryo I' deki gibi aynı gürültü oranına sahip statik parazit yankılı ortamda JPDA-UKF süzgecinin kestirim sonuçları verilmektedir. Süzgeç gerçek rotadaki 4. düşüme kadar ortalama bir hata ile ilerlemektedir, 4. düğümde parazit yankılarla karşılaşınca kestirim doğruluğunun asgari

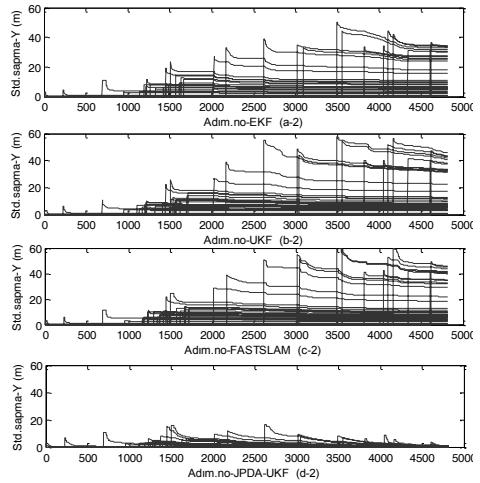
düzeyde etkilendiği görülmektedir. Senaryo ile ilgili bütün süzgeçlerin konum, açısal başlık hataları ve nesne işaretleri için hata kovaryansı standart sapma değerleri şekil 6 ve 7’ de verilmektedir.



Şekil 6. Süzgeçler robot pozisyon ve başlık açısı ortalama kare hata kestirim sonuçları.



Şekil 7. (a). Bütün algılanan nesne işaretleri için nesne işaretleri konum kestiriminin bütün süzgeçler için standart sapma değerleri, X-koordinatı; a) NN-EKF, b) NN-UKF, c) FastSLAM II, ve d) JPDA-UKF



Şekil 7.(b). Bütün algılanan nesne işaretleri için nesne işaretleri konum kestiriminin bütün süzgeçler için standart sapma değerleri, Y-koordinatı; a) NN-EKF, b) NN-UKF, c) FastSLAM II, ve d) JPDA-UKF.

Tablo II. Parazit yankılı ortamda süzgeç hata kareleri ortalama sonuçları.

Süzgeç	Açısal başlık hatalı	Konum hatalı
NN-EKF	0.3217	3.4630
NN-UKF	0.2045	1.9520
FastSLAM II	0.2623	2.2075
JPDA-UKF	0.1806	1.8634

Şekil 6,7 ve tablo II’deki sonuçlar kullanılan dört adet süzgeç için parazit yankılı ortamda kestirim sonuçlarını göstermektedir. Sonuçlar senaryo I ile karşılaştırılırsa özellikle gerçek rotatin 4. düzümüne karşılık gelen 30x30 m’lik bölgede (şekil 5’te gösterilmektedir) kestirciler statik parazit yankılarla karşılaşmışlardır. Bu bölge detaylı olarak incelendiğinde süzgeçlerin kestirim değerlerinin ortalama kare hataları da bu bölgeden itibaren belirgin olarak büyümeye, yanlış harita oluşumu ve pozisyon kestirimine yol açtığı gözlenmektedir. Aynı zamanda, algılama esnasında süzgeçler parazit yankılarının olduğu bölgeden geçerken nesne işaretlerinin de standart sapma değerlerinde bir miktar artış

olduğu, yani belirsizlik durumunun yükseldiği görülmektedir. Bu beklenen bir durumdur; süzgeçlerin performansları bu bölgede olumsuz yönde etkilenmektedir.

Tablo II' ye bakıldığında aynı ortam ve gürültüler göz önünde bulundurulduğunda hata kareleri ortalamalarında bir miktar artış olduğu görülmektedir. Aynı zamanda benzetim çalışması esnasında kestirim doğruluğu bütün süzgeçlerde düşerken işlem süreleri açısından *senaryo I* ile rakamsal olarak büyük bir değişim olmadığı gözlenmiştir. Öte yandan JPDA-UKF süzgencinin parazit yankılı ortamdan geçerken bir miktar yavaşladığı görülmüştür. Bunun sebebi JPDA-UKF algoritması veri ilişkilendirmesi yaparken kapilar içerisindeki tahmin edilen en yakın komşu kestirim değerine değil de yine kapının içerisindeki bütün olası ölçümü aday tahmin değeri olarak gördüğünden süzgeç bu bölgede işlem süresi olarak diğer süzgeçlerden daha fazla çalışmaktır, bu ise olumsuz etkilenmesine yol açmaktadır. Fakat bu durumun süzgeçin kestirim doğruluğuna yansımadığı görülmektedir.

*Senaryo II*' de ortam gürültüsünün yoğun olması, yani SNR değerinin yüksek olması süzgeçlerin parazit yankından daha az etkilendiğini deneysel çalışmalar esnasında göstermektedir. SNR değerinin düşük olduğu parazit yankılı ortamda ise süzgeçlerin daha fazla etkilendiği görülmektedir. Bunların yanı sıra *senaryo I* ile benzer kestirim sonuçları elde edilebilmiştir; nesne konumlarının yakın olduğu belirsizliğin yüksek olduğu durumlarda süzgeçlerin performansının düşüğü görültürken, JPDA-UKF süzgencinde bu durum en az etki altında kalınarak belirsizliği minimize edebildiği görülmüştür. Şekil 7-(a, b)' de süzgeçlerin *senaryo II* için nesne işaretini standart sapma değerleri görülmektedir. Yine ilk senaryoda olduğu gibi bu parazit yankılı ortamda da kullanılan süzgeçlerin içerisinde en uygun standart sapma değerini minimize edebilme kabiliyetini JPDA-UKF süzgencinin sağladığı görülmektedir.

## Sonuçlar

Bu çalışmada SLAM probleminin bilinen iki yetersizliği üzerinde durulmuş, iki farklı yöntem kullanılarak problem için bir çözüm önerilmiştir. Çalışmada dört adet veri ilişkilendirmesi yapabilen süzgeç kullanılmıştır; bunlardan genişletilmiş ve kokusuz Kalman süzgeçleri en yakın komşuluk ilişkisi algoritmasıyla veri ilişkilendirmesi yaparken FastSLAM II algoritması ise Raoblockwellized parçacık süzgeçlerinin örnekleme yönteminden yararlanmaktadır. Bu metodlara alternatif olarak bu çalışmada SLAM problemi için JPDA yöntemi UKF ile birlikte kullanılarak bir çözüm önerilmiştir.

Deneysel çalışmalar için iki senaryo üretilmiştir; birinci senaryoda yoğun ölçüm ve gözlem gürültüsü altında, parazit yankının olmadığı, fakat birbirine çok yakın nesne işaretlerinin bulunduğu bir ortam tasarılmıştır. İkinci senaryoda ise aynı ortamda statik parazit yankılarının olduğu varsayılmıştır. Sonuçlar ilk senaryo için karşılaştırıldığında en düşük hata kareleri ortalamasını JPDA-UKF süzgencinin verdiği gözlenmiştir. Bunun yanı sıra JPDA-UKF nesne işaretlerinin belirsizliğinin yüksek olduğu durumlarda nesne işaretlerinin standart sapmasını minimize ederek doğru nesne işaretlerinin konum bilgisine ulaşabilmistiştir. Diğer süzgeçler de veri ilişkilendirme problemini çözebilmış fakat nesne işaretlerinin belirsizliğini JPDA-UKF kadar minimize edememişlerdir. İkinci senaryo için sonuçlar incelendiğinde birinci senaryoya paralel sonuçlar elde edilmişdir, fakat JPDA süzgencinin zamansal işlem bakımından parazit yankılı ortamdan geçerken işlem süresinin normal duruma göre uzadığı görülmektedir.

Çalışmalar SLAM probleminin çözümü için önerilen JPDA-UKF süzgencinin hem hata kareleri ortalaması açısından uygun sonuçlar verdiği, hem de veri ilişkilendirme problemi için bir çözüm olabileceğini göstermiştir.

## Ek A

Bu kısımda UKF süzgeci için JPDA algoritmasının modellenmesi üzerinde durulacaktır. JPDA algoritması UKF ile entegre edildiğinde yine Y. Bar-Shalom (2009)'dan yararlanılacaktır. UKF süzgeci iki aşamadan oluşmaktadır. Tahmin ve güncelleme olarak gösterilebilir. UKF süzgeci tahmin esnasında doğrusal olmayan bir fonksiyon aracılığıyla soncul dağılım üzerinden belirli duruma paralel oranda sigma noktalarıyla dönüşümü sağlayarak tahmin edebilmektedir. Hedef durumunu *Unscented Transform* (UT) (S. J. Julier and J. K. Uhlmann, 2004 ) yardımıyla sıralı olarak verilen gözlemden ( $z_k$ ) tahmin ederek ölçüm güncellemesine devam edebilmektedir.  $j$ 'nci hedefin  $i$ 'nci ölçümü çıkarılan ölçüm ( $z_{i,k}$ ) olarak kabul edilirse;

*UKF tahmin aşaması,*

UKF tahmin aşaması soncul durumdan sigma noktalarının hesaplanmasıyla başlar, sigma nokta matrisi,

$$\chi_{k-1|k-1}^j = [\chi_{k-1|k-1}^j(0), \dots, \chi_{k-1|k-1}^j(2n_x)]$$

ve buradan,

$$\begin{aligned} \chi_{k-1|k-1}^j &= [\chi_{k-1|k-1}^j, \chi_{k-1|k-1}^j + \tilde{P}_{k-1|k-1}^j, \\ &\quad \chi_{k-1|k-1}^j - \tilde{P}_{k-1|k-1}^j] \\ \tilde{P}_{k-1|k-1}^j &= \sqrt{(n_x + \varsigma) P_{k-1|k-1}^j} \end{aligned} \quad (34)$$

hesaplanır. Burada  $\varsigma$  ölçekte parametresi ve  $\tilde{P}_{k-1|k-1}^j$  ölçeklenmiş durum kovaryans matrisinin Cholesky faktörizasyonunu verir.  $X_{k-1|k-1}^j$  ise  $n_x * n_x$  boyutlu bir matristir, sütunları  $x_{k-1|k-1}^j$ , e eşittir. Sigma noktaları durum geçiş eşitliği üzerinden dağıtılsa,

$$\tilde{\chi}_{k-1|k-1}^j = [f(\chi_{k-1|k-1}^j(0)), \dots, f(\chi_{k-1|k-1}^j(2n_x))],$$

elde edilir ve kokusuz ağırlıkları kullanılarak durum vektörleri tahmin edilir (S. J. Julier and J. K. Uhlmann, 2004)

$$x_{k|k-1}^j = \sum_{n=0}^{2n_x} w_n \tilde{\chi}_{k|k-1}^j(n) \quad (35)$$

burada tahmin durum kovaryansı durum gürültü kovaryans matrisi eklenerek bulunur,

$$\begin{aligned} P_{k|k-1}^j &= Q_k + \sum_{n=0}^{2n_x} w_n (\tilde{\chi}_{k|k-1}^j(n) - x_{k|k-1}^j) \\ &\quad (\tilde{\chi}_{k|k-1}^j(n) - x_{k|k-1}^j)^T \end{aligned} \quad (36)$$

Burada  $Q_k$  durum gürültü kovaryans matrisidir. Dağıtılmış durum ve kovaryans hesabı kullanılarak durum gürültü işleminin etkisi göz önüne alınarak sigma noktaları tekrar çizilirse,

$$\begin{aligned} X_{k-1|k-1}^j &= [x_{k|k-1}^j, X_{k|k-1}^j + \tilde{P}_{k|k-1}^j, \\ &\quad X_{k|k-1}^j - \tilde{P}_{k|k-1}^j] \\ \tilde{P}_{k|k-1}^j &= \sqrt{(n_x + \varsigma) P_{k|k-1}^j} \end{aligned} \quad (37)$$

elde edilir ve gözlem

$$\gamma_{k|k-1}^j = [h(\chi_{k|k-1}^j(0)), \dots, h(\chi_{k|k-1}^j(2n_x))]$$

gözlem vektörünü verir. Gözlem ve gözlem vektörünün kovaryans matrisi,

$$z_{k|k-1}^j = \sum_{n=0}^{2n_x} w_n \gamma_{k|k-1}^j(n) \quad (38)$$

$$\begin{aligned} S_k^j &= R_k + \sum_{n=0}^{2n_x} w_n (\gamma_{k|k-1}^j(n) - z_{k|k-1}^j) \\ &\quad (\gamma_{k|k-1}^j(n) - z_{k|k-1}^j)^T \end{aligned} \quad (39)$$

olarak verilir (Y. Bar-Shalom 2009).

*UKF Güncelleme,*

$i$ 'nci ölçüme bağlı olarak hesaplanan inovasyon  $z_k(i) - z_{k|k-1}^j$ , durum vektörü ve tahmin edilen durum kovaryans matrisi güncellenme aşamasında,

$$\begin{aligned} x_{k|k}^j(i) &= x_{k|k-1}^j + W_k^j(z_k(i) - z_{k|k-1}^j) \\ P_{k|k}^j &= P_{k|k-1}^j - W_k^j S_k^j (W_k^j)^T \end{aligned} \quad (40)$$

olarak verilir. Burada Kalman kazancı (S. J. Julier and J. K. Uhlmann, 2004) gibi hesaplanır,

$$\begin{aligned} W_k^j &= \sum_{n=0}^{2n_x} w_n (\chi_{k|k-1}^j(n) - x_{k|k-1}^j), \\ (\chi_{k|k-1}^j(n) - x_{k|k-1}^j)^T (S_k^j)^{-1} \end{aligned} \quad (41)$$

## Kaynaklar

- Bailey T., (2002). *Mobile robot localization and mapping in extensive outdoor environments*, Ph.D. dissertation, Univ. Sydney, Sydney, NSW, Australia.
- Bailey T., (2003), *Constrained Initialization for Bearing-Only SLAM*, IEEE International Conference on Robotics and Automation.
- Bosse M., Leonard J., and Teller S., Leonard J., Tardos J. D., Thrun S., and Choset H., Eds., (2002). *Large-scale CML using a network of multiple local maps*, in Workshop Notes of the ICRA Workshop on Concurrent Mapping and Localization for AutonomousMobile Robots (W4), Washington, D.C.
- Guivant J. and Nebot E., (2001). *Optimization of the simultaneous localization and map-building algorithm and real-time implementation*, IEEE Trans. Robot. Automat., vol. 17, no. 3, pp. 242–257.
- Kim C., Sakthivel, R. ; Chung, W.K., ( 2008) *Unscented FastSLAM: A Robust and Efficient Solution to the SLAM Problem*. IEEE Transaction on Robotics, pp 808 – 820.
- Kuipers B. J. ve Byun Y.-T., (1991), *A robot exploration and mapping strategy based on a semantic hierarchy of spatial representations*, Journal of Robotics and Autonomous Systems, 8: 47-63.
- Mahalanobis, Prasanta Chandra (1936). *On the generalised distance in statistics*. Proceedings of the National Institute of Sciences of India 2 (1): 49–55. Retrieved 2012-05-03.
- Montemerlo, M. Thrun, S. Koller, D. ve Wegbreit, B (2002), *FastSLAM: A factored solution to the simultaneous localization and mapping problem*, Proceedings of the AAAI National Conference on Artificial Intelligence, 593–598.
- Montemerlo M. and Thrun S., (2003). *Simultaneous localization and mapping with unknown data association using fastSLAM*, in Proc. IEEE Int. Conf. Robot. Automat., Taipei, Taiwan, pp. 1985–1991.
- Montemerlo M., Thrun S., Koller D., and Wegbreit B., (2003). *FastSLAM2.0: An improved particle filtering algorithm for simultaneous localization and mapping that provably converges*, in Proc. 18th Int. Joint Conf. Artif. Intell., Acapulco, Mexico.
- Neira J. ve Tardós J.D., (2001), *Data association in stochastic mapping using the joint compatibility test*, IEEE Trans. Robot. Automat., 17( 6), 890–897.
- Norgaard M., Poulsen N., ve Ravn O., (2000), *New Developments in State Estimation for Nonlinear Systems*, Automatica, 36(11):1627–1638.
- Pakfiliz A.G., (2004), Development of A Probabilistic Tracking Algorithm for Maneuvering Targets in Cluttered Environment, Ph.D. thesis, Ankara University, 270 p.,
- R. Smith, M. Self, and P. Cheeseman. *Estimating uncertain spatial relationships in robotics*. In I. J. Cox and G. T. Wilfong, editors, *Autonomous Robot Vehicles*, pages 167{193. Springer, 1990.
- Rex H. Wong, Jizhong Xiao and Samleo L. Joseph, *A Robust Data Association for Simultaneous Localization and Mapping in Dynamic Environments*, Proceedings of the 2010 IEEE International Conference on Information and Automation June 20 - 23, Harbin, China
- S. J. Julier and J. K. Uhlmann, (2004), *Unscented Filtering and nonlinear estimation*,” Proc. IEEE, vol. 92, no. 3, pp. 401–422, Mar.
- Thrun S., Fox D., and Burgard W., (1998). *A probabilistic approach to concurrent mapping and localization for mobile robots*, Mach. Learn., vol.31, pp. 29–53.
- Thrun S.,(2002). *Robotic mapping: A survey. Exploring Artificial Intelligence in the New Millennium*. The Morgan Kaufmann Series in Artificial Intelligence (Hardcover) by Gerhard Lakemeyer (Editor), Bernhard Nebel (Editor). ISBN ISBN-10: 1558608117.
- Williams S. B., Newman P., Dissanayake G., and Durrant-Whyte H., (2000) *Autonomous underwater simultaneous localization and map building*, in Proc. IEEE Int. Conf. Robot. Automat., San Francisco, CA, vol. 2, pp. 1792–1798.

*Eşzamanlı Konum Belirleme ve Harita Oluşturma Problemi için Veri İlişkilendirme*

- Williams S., Dissanayake G., and Durrant-Whyte H. F., (2001). *Towards terrain-aided navigation for underwater robotics*, Adv. Robot., vol. 15, no. 5, pp. 533–550.
- Y. Bar-Shalom and T. Fortmann, *Tracking and Data Association*, Academic Press, 1988,
- Y. Bar-Shalom and X. Rong Li, *Multitarget-Multisensor Tracking: Principles and Techniques*. Storrs, CT: YBS Publishing, 1995,
- Y. Bar-Shalom, F. Daum, and J. Huang, *The probabilistic data association filter*, IEEE Control Syst. Mag., vol. 29, no. 6, pp. 82–100, Dec.2009.
- Zhou B. and Bose N.( 1993), *Multitarget Tracking in clutter:Fast Algorithm for Data Association*, IEEE Transaction on Aerospace and Electronics,

# mühendislikdergi

