

# Gezgin Robotlarda Parçacık Süzgeci Tabanlı Konumlandırma Yönteminde Algılayıcı Veri Hassasiyeti Analizi

Sezcan Yılmaz<sup>1</sup>

Hilal Ezercan Kayır<sup>2</sup>

Burak Kaleci<sup>3</sup>

Osman Parlaktuna<sup>4</sup>

<sup>1</sup>Makina Mühendisliği Bölümü, Eskişehir Osmangazi Üniversitesi, Eskişehir  
<sup>2,3,4</sup>Elektrik-Elektronik Mühendisliği Bölümü, Eskişehir Osmangazi Üniversitesi, Eskişehir

<sup>1</sup>e-posta: sezcan@gmail.com

<sup>3</sup>e-posta: burakaleci@gmail.com

<sup>2</sup>e-posta: hezercan@ogu.edu.tr

<sup>4</sup>e-posta: oparlak@ogu.edu.tr

## Özetçe

Gezgin robotların kendilerine verilen görevleri tam olarak yerine getirebilmeleri için doğru konum bilgisine ihtiyaçları vardır. Algılayıcı verilerindeki gürültü nedeniyle doğru konumlandırma yapmak, çözümü oldukça zor bir problemdir. Bu problemin çözümünde olasılık tabanlı konumlandırma yaklaşımları kullanılan yöntemler arasındadır. Robotun başlangıç durumunda konumunu bildiği ve bilmediği durumlara göre konumlandırma probleminin çözüm yolları farklılaşmaktadır. Bayes tabanlı konumlandırma yöntemleri her iki başlangıç koşulu için de kullanılan çözüm yaklaşımlarındandır. Bayes tabanlı konumlandırma yaklaşımlarından en bilineni Parçacık Süzgeci'dir. Bu çalışmada, Parçacık Süzgeci tabanlı konumlandırma yönteminin algılayıcı veri hassasiyeti analizi yapılmıştır. Veri hassasiyeti değerlendirilmesinin algılayıcı modelinde kullanılan standart sapma ile ilişkisi analizlerle verilmiştir.

## 1. Giriş

Gezgin robotların kendilerine verilen görevleri tam olarak yerine getirebilmeleri için doğru konum bilgisine ihtiyaçları vardır. Konumlandırma, mevcut konum bilgilerinin algılayıcılar aracılığıyla ortamdan alınan bilgilerle birleştirilerek güncel ve doğru konum bilgisine ulaşmak olarak tanımlanır. Konum bilgisinin elde edildiği süreç iki farklı başlangıç koşuluna sahip olabilir: Robotların ilk konumlarını bilmedikleri ve bildikleri durumlar. Robotun başlangıç konumunu bilmediği durumda, ortam haritası ve algılayıcı bilgilerini kullanarak muhtemel konum bilgisini elde etmesi mümkündür. Bu problem küresel konumlandırma olarak tanımlanmaktadır [1]. Robot ilk konumunu bildiği durumda, zamanla oluşabilecek konum bilgisi sapmalarına karşı bu bilgiyi belirli aralıklarla güncellemelidir. Bu problem mevcut çalışmalarda konum takibi olarak anılmaktadır [2]. Bu çalışmada küresel konumlandırma problemi "Konumlandırma" ve konum takibi problemi "Seyrüsefer" olarak adlandırılmıştır.

Olasılık tabanlı konumlandırma yaklaşımları bahsedilen problemlerin çözümü için önerilen çalışmalar içindedir. Bu çalışmalardan en yaygın olarak bilinen ve kullanılan yöntem Kalman Süzgeci'dir [3]. Bu yaklaşımın dezavantajı, kullanılacak sistem modelinin doğrusal olmasını gerektirmesi ve robot konumunun tek modlu Gauss dağılımı ile gösterilmesidir. Bu sebeplerden dolayı, bu yöntem sadece seyrisfer problemi için kullanılabilir. Bu kısıtlamaların üstesinden gelmek için Bayes tabanlı konumlandırma yöntemleri önerilmiştir. Bu yöntemlerde robotun konumu çeşitli dağılımlar ile gösterilebilmektedir. Robotun ilk konumunu bilmediği durumlarda Bayes tabanlı

konumlandırma yöntemleri kullanılabilir. Bu yaklaşımlardan biri olan Markov yönteminde [4,5] hassas konum bilgisi hesaplamaları yapabilmek için yoğun bir hesaplama gerekmektedir. Bunun üstesinden gelmek için Parçacık Süzgeci konumlandırma yöntemleri önerilmiştir. Bu yöntemlerden en bilineni Monte-Carlo konumlandırma yöntemidir. Fox [6] çalışmasında bu yöntemin her iki problem için de kullanılabilirliğini göstermiştir. Bu yaklaşımlarda robot büyük örnek kümeleriyle konumunu belirledikten sonra, küçük örnek kümeleriyle bu bilgileri güncellemektedir.

Bu çalışmada, gezgin robotların konumuna karar vermesi ve konum bilgisinin güncellenmesi amacıyla Bayes tabanlı Parçacık Süzgeci kullanılmıştır. Önerilen yöntemde, kullanılan örnek sayısının sistem performansını etkilemeden azaltılması amacıyla pusula bilgisi kullanılmıştır [7]. Bununla beraber normalize edilmiş algılayıcı modeli ve algılayıcı modelinde kullanılan ışınların seçimi için iki farklı yaklaşım geliştirilmiştir [8]. Konumlandırma ve seyrisfer için Parçacık Süzgeci tabanlı konumlandırma yönteminin algılayıcı veri hassasiyeti analizi yapılmıştır. Veri hassasiyeti değerlendirilmesinin algılayıcı modelinde kullanılan standart sapma ile ilişkisi analizlerle verilmiştir.

Çalışmanın yapısı şu şekildedir: Bölüm 2'de, genel Bayes tabanlı konumlandırma yaklaşımı, Bölüm 3'te önerilen yöntem, Bölüm 4'te gerçekleştirilen uygulamalar, Bölüm 5'te önerilen yöntemin analizi ve Bölüm 6'da sonuçlar verilmektedir.

## 2. Bayes Tabanlı Konumlandırma Yöntemi

Bayes tabanlı konumlandırma yöntemi birbirini takip eden tahmin ve güncelleme adımlarından oluşur. Tahmin adımı, bir tümlevli yol sayacı ölçümü alındığında, önceki algılayıcı ve hareket verileri kullanılarak gerçekleştirilir. Güncelleme adımı ise, yeni bir algılayıcı bilgisi elde edildiğinde yapılır. Bu iki adım ardışık olarak tekrarlanarak konum bilgisi elde edilmektedir.

Bayes tabanlı konumlandırma yönteminin özel bir durumu olarak tanımlanan Parçacık Süzgeci,  $N$  adet örnekten oluşan bir  $M$  kümesinin dağılımı ile temsil edilir. Bu kümedeki her örnek  $x$  gibi bir durum vektörü ve  $w$  gibi bir ağırlık faktörü içerir,  $M = [x_j \ w_j]$ ,  $j = 1 \dots N$

Tahmin adımı, robotun hareketleri örnek kümeleriyle birleştirilir. Bu adımda, hareket modeli, yeni durum vektörlerini hesaplamak için kullanılır. Bu model, birbirini izleyen iki adım arasındaki mesafe ve açı bilgisini kullanır. Birbirini izleyen iki adım ise, gürültü içeren iki koordinat çifti ve bir yönelim bilgisi ile tanımlanır. Bu bileşenlerin her biri, kendi standart sapmalarını içeren Gauss dağılımlarla gösterilir [1].

Güncelleme adımı, algılayıcı modeli kullanılarak örneklerin ağırlıkları hesaplanır. Bu ağırlıklar örneklerin önemlerini belirtir. Bu noktada, algılayıcı ölçümlerinin kullanılarak örneklerin ağırlıklarının nasıl hesaplanacağı önem kazanmaktadır. Fox [9] toplam algılayıcı olasılığını hesaplamak için bir algılayıcı modeli önermiştir. Bu yöntemde algılayıcı modeli en yakın engele olan uzaklığı ortalama olarak alan bir Gauss dağılımı ile temsil edilir. Eğer birden fazla algılayıcı kullanılıyorsa, geleneksel algılayıcı modelinde her örnek için toplam algılayıcı olasılığı, tek tek algılayıcıların olasılıklarının çarpımı ile elde edilir.

Parçacık Süzgeci konumlandırma yönteminde son olarak tekrar örnekleme adı verilen bir işlem gerçekleştirilir. Bu işlemde örnekler ağırlıklarıyla ilişkili olarak tekrar dağıtılır. Parçacık Süzgeci konumlandırma yönteminde, bir tümlevli yol sayacı ölçümü alındığında, örneklerin durum vektörleri hesaplanır. Daha sonra yeni bir algılayıcı ölçümü ile robotun o anda bulunduğu konum ve yönelime bağlı olarak örneklerin doğru konum ve yönelimde olma olasılıkları hesaplanır. Bu noktada, yeni bir örnek kümesi elde etmek amacıyla, mevcut örnek kümesindeki örneklerin ağırlıkları temel alınarak tekrar örnekleme yapılır. Bu yaklaşımdaki ana fikir, diğer örneklerden daha yüksek olasılığa sahip dolayısıyla ağırlık faktörü büyük örneklerin hayatta kalmasıdır.

### 3. Önerilen Yöntem

Parçacık Süzgeci'nin konumlandırmada kullanılması durumunda, robot başlangıçta ortamda herhangi bir konumda olabileceğine inanır. Bu inanç doğrultusunda sistem, kullanacağı örnekleri tüm ortama düzgün olarak dağıtır. Parçacık Süzgeci'nin bu yapısı gereği robot kendini konumlandırana kadar sistem büyük örnek kümelerine ihtiyaç duyar. Bu durum ise hem hesaplama hem de hafıza açısından yüksek maliyetler oluşturmaktadır. Yapılan çalışmada [7] pusula kullanılarak sistem performansı etkilenmeden örnek kümesinin küçültülebileceği anlatılmıştır.

#### 3.1. Pusula Etkisi

Geleneksel Parçacık Süzgeci yaklaşımında örneklerin koordinatları  $x_s$  ve  $y_s$ , ortamın sınırları doğrultusunda bir aralıkta olurken, yönelimleri  $\theta_s$ , 0 ile  $2\pi$  arasında değişmektedir. Pusulanın kullanıldığı yöntemde ise yönelim uzayı küçültme faktörü,  $\delta_\theta$ , olarak tanımlanan değişken ile örneklerin yönelimlerinin sınırları belirlenmektedir. Örnek yönelimlerinin yeni aralığı  $\theta_p$  olarak adlandırılır.

Örneklerin durum uzayı  $X_s = [x_s, y_s, \theta_s]$  olsun,

$$\frac{P(X(x_s, y_s, \theta_p))}{P(X(x_s, y_s, \theta_s))} = \frac{\delta_\theta}{\pi} \quad (1)$$

Örnek kümesini küçültme katsayısı denklem (1) ile tanımlanmaktadır. Yeni örnek kümesinin boyutu mevcut örnek kümesinin boyutunun örnek kümesinin küçültme katsayısının çarpılması ile elde edilir.

#### 3.2. Normalize Edilmiş Algılayıcı Modeli

Parçacık Süzgeci konumlandırma yönteminde, örneklerin ağırlıkları algılayıcı modeli kullanılarak hesaplanır. Toplam algılayıcı olasılığının, her bir algılayıcı olasılığının çarpımıyla bulunduğu model geleneksel algılayıcı modeli (GAM) olarak adlandırılmaktadır [1].  $P_1(y_1|x), P_2(y_2|x), \dots, ve P_n(y_n|x)$ ,

sırasıyla  $n$  adet algılayıcı için algılayıcı olasılık değerleri olmak üzere bu model için toplam algılayıcı olasılığı denklem (2) ile ifade edilmektedir.

$$P_{GAM} = \prod_{i=1}^n P_i(y_i|x) \quad (2)$$

Algılayıcılardan elde edilen ölçüm değerleri en yakın engele olan uzaklıkları göstermektedir. Bu ölçüm değerleri doğru olabileceği gibi, algılayıcının içerdiği gürültüden dolayı ya da rassal olarak doğru değerden farklı olabilir. Bu durumda, doğru konumlandırmaya sahip olabilecek örneklerin ağırlıklarının belirlenen eşik değerinden daha düşük olması ve bu örneklerin elenmesi söz konusudur. Böylece sistemin konumlandırma yeteneği azalmaktadır. Yapılan çalışmada, algılayıcı ölçümü değerlerinin doğru değerden farklı olduğu durumlarda oluşabilecek olumsuzlukları giderebilmek için normalize edilmiş algılayıcı modeli (NAM) önerilmiştir. Belirtilen algılayıcı modelinde, toplam algılayıcı olasılığı, algılayıcı olasılık değerlerinin geometrik ortalaması olarak hesaplanmaktadır. Normalize edilmiş toplam olasılık denklem (3) ile verilmektedir.

$$P_{NAM} = \left( \prod_{i=1}^n P(y_i|x) \right)^{1/n} \quad (3)$$

Normalize etme işlemi, çok yüksek ve/veya çok düşük olasılık değerlerine sahip algılayıcıların sebep olacağı olumsuz etkileri azaltmaktadır. Olasılık değerlerinin bir kaçının hatalı olması durumunda dahi örneklerin hayatta kalmasını sağlamaktadır. Bu örneklerden yanlış konumlandırmaya sahip olanlar, işlemin gelecek adımlarında elenmektedir.

#### 3.3. Algılayıcı Modelinde Işın Seçimi

Konumlandırma ve seyrüsefer esnasında robotun doğru konum bilgisine sahip olabilmesi için sistemin ortamdan bilgi elde etmesi gerekmektedir. Bu bilgi, sisteme robotun algılayıcıları aracılığıyla sağlanır. Bu çalışmada,  $1^\circ$  çözünürlük ile 180 tane ışına sahip olan lazer uzaklıkölçer kullanılmıştır. Önerilen çözümde hesaplama yükünün azaltılması ve aynı zamanda robotun konumunun da doğru olarak bilinmesi için 180 lazer ışınından bazıları algılayıcı modelinde kullanılmak üzere seçilmektedir. Sistem belirlenen lazer ışınlarından elde ettiği verileri algılayıcı modelinde kullanarak örneklerin ağırlıklarına ve elenip elenmemelerine karar verir. Dolayısıyla sistemin konumlandırma ve seyrüseferi başarılı yapabilmesi ışın seçiminin doğru olmasına bağlıdır.


Başarılı bir şekilde konumlandırma yapılabilmesi için, robotun sağ, solu ve önünden belli açılarla elde edilen, ayırt edici bilgilere sahip ışınlar kullanılmalıdır. Sistemin kullanacağı ışın sayısına bağlı olarak, ışınların açıları belirlenmektedir.  $n$  tane lazer ışını için lazer tarama alanı  $180/n$  derece açılı  $n$  bölgeye ayrılır. Algılayıcı modelinde kullanılacak olan ışınlar ayrılan bölgelerin ortasına gelecek şekilde seçilmektedir.

Seyrüsefer esnasında ise, konumlandırmada kullanılan sabit açılarla sisteme yeterli bilgi sağlanamamaktadır. Bunu önlemek için algılayıcı modelinde rassal ışın seçimi önerilmektedir. Bu yaklaşımda da lazer tarama alanı  $n$  lazer ışını için  $180/n$  derece açılı  $n$  bölgeye ayrılmaktadır.

Kullanılacak olan ışınlar ilgili bölgelerden rassal olarak seçilmektedir. Bu ışınlar her adımda her bölge için yeniden belirlenmektedir.

### 3.4. Standart Sapmanın Etkisi

Algılayıcı modelinde kullanılan ışınlar, en yakın cisme olan uzaklıklarını ortalama olarak kabul eden bir Gauss dağılım ile modellenir. Şekil 1’de görüldüğü gibi çeşitli standart sapma değerleri için farklı Gauss dağılımları elde edilmektedir. Sistem, örneklerin doğru konumda olma olasılığını algılayıcı ölçümünün bu dağılımdaki değerine göre hesaplar. Algılayıcıdan elde edilen ölçüm değeri farklı standart sapma değerleri için, farklı olasılık değerlerine sahip olmaktadır. Dolayısıyla Gauss dağılımının standart sapması algılayıcı ölçüm hatasının nasıl değerlendirileceğine karar verir.



Şekil 1: Farklı standart sapma değerleri için Gauss dağılımı

Standart sapmanın düşük olması, sistemin algılayıcı ölçüm hatalarına hassasiyetini artırır. Bu durumda, düşük ölçüm hataları örneklerin doğru yerde olma olasılığını arttıracaktır. Bununla beraber standart sapmanın çok küçük olması, sistemi algılayıcı ölçüm hatalarına karşı gereğinden fazla hassas yapacağından, doğru konumun komşuluğundaki örneklerin yok olmasına sebep olabilir. Standart sapmanın büyük olması ise, sistemin geniş bir aralıktaki ölçüm hatalarına karşı benzer davranmasına neden olmaktadır. Bu durumda doğru konumdan çok uzaktaki örnekler ile doğru konumun komşuluğundaki örnekler yakın olasılıklara sahip olacaktır. Dolayısıyla sistem ortamdan yeterli bilgiyi aldığı halde, bu bilgiyi verimli olarak kullanamamaktadır. Bu durum, sistemin geç konumlandırma yapmasına sebep olmaktadır. Standart sapmanın çok büyük olduğu durumda, sistem tüm ölçüm hatalarına benzer şekilde davranmakta ve örneklerin olasılık değerleri sürekli birbirine yakın olmaktadır. Dolayısıyla sistem hiçbir zaman konumlandırma yapamayacaktır.

Konumlandırma esnasında, robotun gerçek konumunun komşuluğunda olan örneklerin hayatta kalması istenir. Bunu sağlamak için standart sapmanın çok düşük olmaması gerekir. Standart sapmanın büyük olduğu yerlerde ise sistem büyük ölçüm hatalarını bile göz ardı edebilmektedir. Bu noktada, kullanılacak standart sapma değerine karar vermek için konumlandırma başarısı göz önüne alınmalıdır.

Seyrüsefer esnasında ise, robot konumunu yaklaşık olarak bildiği ve izlediği yolu daha az hatayla takip etmesi gerektiği için güvenilirliği yüksek ölçümlere ihtiyaç duymaktadır. Bunu sağlamak için standart sapmanın konumlandırma esnasında kullanılabileceği daha küçük olması gerekir. Standart sapmanın çok küçük olması ise robotun izlemesi gereken yoldan sapmasına neden olacaktır.

Normalize edilmiş ve geleneksel algılayıcı modelleri, algılayıcı modelinde sabit ve rassal ışın seçim yaklaşımları kullanılarak, standart sapmanın konumlandırma ve seyrüsefer başarısına etkisi Bölüm 5’te detaylı olarak incelenmektedir.

## 4. Uygulamalar

Önerilen yöntemin performansını göstermek amacıyla yapılan uygulamalar, Eskişehir Osmangazi Üniversitesi, Elektrik-Elektronik Mühendisliği, Yapay Zekâ ve Robotik Laboratuvarında gerçekleştirilmiştir. Çalışma ortamının genişliği 7300mm ve uzunluğu ise 8500mm’dir. Laboratuvar ortamı Şekil 2’de verilmiştir.




Şekil 2: ESOĞÜ Yapay Zekâ ve Robotik Laboratuvar ortamı

Uygulamalarda Pioneer P3-DX diferansiyel sürüş yapısına sahip gezgin robot platformu kullanılmıştır. Robot yüksek çözünürlüklü yol sayıcı ve Pentium tabanlı bilgisayara 16 sonar algılayıcı, bir SICK LSM200 lazer uzaklıkölçer, bir PTZ kamera ve pusulaya sahiptir [10].

Bu çalışmada, algılayıcı olarak lazer uzaklıkölçer kullanılmaktadır. Bu algılayıcı, 1° çözünürlük ile 180 adet ışın yaymaktadır. Önerilen algılayıcı modelinde, bu ışınlardan döndürülen mesafe bilgilerinden bazıları kullanılmaktadır. Işınlar birbirinden bağımsızdır ve her ışın tek bir algılayıcı olarak kabul edilmektedir.

Uygulamalar iki adımda gerçekleştirilmiştir. İlk adımda robot kendisine verilen rotayı izlemiş ve bu esnada 16 sonar, 180 lazer uzaklıkölçer, pusula verileri ile robotun pozisyon ve yönelim bilgileri kayıt edilmiştir. İkinci adımda ise elde edilen bu bilgiler önerilen konumlandırma yönteminde girdi olarak kullanılmıştır. Şekil 3’te laboratuvar ortamının haritası ve robotun izlediği rota verilmiştir. Şekilde gösterilen düz çizgiler robotun izlediği rotayı (önerilen yöntem kullanılarak elde edilmiştir), kesikli çizgiler ise tümlevli yol sayıcından alınan verileri göstermektedir.



Şekil 3: Laboratuvar ortamının haritası ve robotun izlediği rota

## 5. Analiz

Bu kısımda, Parçacık Süzgeci tabanlı konumlandırma yönteminde algılayıcı veri hassasiyetinin sistem performansına etkisini incelemek için öncelikle tanımlar verilmektedir.

KÖS (Konumlandırma Örnek Sayısı): Birim örnek uzayındaki örnek yoğunluğu. Bu çalışmada birim örnek uzayı konum ve yönelme için sırasıyla  $1m^2$  ve  $180^\circ$ 'dir.

SÖS (Seyrüsefer Örnek Sayısı): Seyrüsefer boyunca kullanılan örnek sayısı.

KAS (Konumlandırma Adım Sayısı): Doğru konumlandırmaya ulaşıldığı adım sayısı.

KBO (Konumlandırma Başarı Oranı): Başarılı konumlandırma sayısının test sayısına oranı. Örnekler herhangi bir nokta etrafında yeteri kadar yoğunlaştıkları zaman konumlandırma gerçekleşmiş kabul edilir. Konumlandırmanın başarılı sayılabilmesi için bu nokta ile robotun gerçek konumu arasındaki farka bakılır.

SBO (Seyrüsefer Başarı Oranı): Başarılı seyrüsefer sayısının test sayısına oranı. Başarılı seyrüsefer, istenilen yörünge için robot tarafından sapma olmaksızın takip edilmesidir.

OSH (Ortalama Seyrüsefer Hatası): Seyrüsefer boyunca yapılan ortalama hata.

Bu çalışmada verilen sonuçlar aynı şartlarda her test kümesi için yapılan 10 testin ortalamaları alınarak elde edilmiştir.

### 5.1. Performans Faktörleri

Önerilen yöntemin başarısını irdelemek amacıyla kullanılan dört performans faktörü vardır. Konumlandırma performansı için KAS ve KBO, seyrüsefer performansı için SBO ve OSH kullanılmıştır.

Sistemin robot konumlandırmasını hızlı ve doğru yapması istenmektedir. Bunu yapmak için sistemin ortamdan bilgi elde etmesi gerekir. Sisteme ortamdan aktarılan bilgi çoğaldıkça robotun daha hızlı konumlandırılması beklenmektedir. Ortamın sağladığı bilgiler robotun kullandığı algılayıcılar ile sisteme aktarılır. Bu sebepten dolayı, kullanılan ışın sayısının artmasıyla robotun daha az adımda konumlandırılması beklenmektedir. Robotun hızlı konumlandırılması istenirken aynı zamanda doğru konum bilgisine ulaşılması da önemlidir. Bunu sağlamak için sistemin daha büyük örnek kümeleriyle çalışması gerekir.

Seyrüsefer esnasında da konumlandırmada olduğu gibi, sisteme bilgi aktarıldıkça, sistemin daha az hatayla ve konumunu kaybetmeden çalışması beklenmektedir. Bu sebepten dolayı, kullanılacak ışın sayısı ve örnek sayısının fazla olması her iki sistem performansını da iyileştirecektir.

### 5.2. Maliyet Analizi

Performans faktörleri incelenirken hem konumlandırma hem de seyrüsefer esnasında, kullanılan ışın ve örnek sayısının artmasıyla sistem performansının arttığı gözlemlenmiştir. Bununla beraber sistemin bu çok sayıda veriyi işlemesi için yüksek hesaplama ve hafıza kapasitesine sahip olması gerekmektedir. Yüksek hesaplama ve hafıza kapasite kullanımı gerçek zamanlı uygulamalar için engel teşkil etmektedir. Sistemin hem bu hesaplama yükünden kurtulması hem de performansının etkilenmemesi için uygun sayıda örnek ve ışın kullanılması gerekir. Bu değerleri belirlemek için konumlandırma ve seyrüsefer performans faktörleri göz önüne alınarak maliyet fonksiyonları geliştirilmiştir.

Maliyet fonksiyonları geliştirilirken toplam konumlandırma maliyeti, konumlandırmanın gerçekleştiği adıma kadar olan adımların maliyetlerinin toplamı olarak hesaplanmakta, seyrüsefer esnasında ise maliyet, sadece mevcut adım maliyeti olmaktadır. Hem konumlandırma hem de seyrüsefer için sistemin adım maliyeti şöyledir:

$$M_{Adım} = C_0 + C_1 * Işın Sayısı * Örnek Sayısı \quad (4)$$


Denklemden  $C_0$ , ön hazırlık süresi,  $C_1$  ise bir ışın ve bir örnek için gerekli işlem süresi olarak tanımlanmaktadır. Konumlandırma ve seyrüsefer için toplam maliyet fonksiyonları denklem (5) ve denklem (6) ile sırasıyla verilmiştir.

$$M_K = \max \left\{ \frac{KAS * M_{Adım}}{KBO}, \frac{M_{Gerçek}}{KBO} \right\} \quad (5)$$


Denklem (5)'de  $M_{Gerçek}$ , robotun bir adım ilerleme süresini belirtmektedir.

$$M_s = \frac{M_{Adım}}{SBO} \quad (6)$$

Konumlandırma Toplam Maliyeti (KTM)'nin KÖS ve ışın sayısına göre değişimi incelenmiştir. Şekil 4 ve Şekil 5'te verilen grafiklerde algılayıcı ölçüm hata standart sapması 400mm, sabit ışın seçim yöntemi ve geleneksel algılayıcı modeli kullanılmıştır. Şekil 4'te görüldüğü üzere KÖS değerleri 10, 20, 40 ve ışın sayısı 3 iken maliyet en düşük değerdedir. Şekillerde sağ sütundaki sayılar kullanılan ışın sayılarını belirtmektedir.




Şekil 4: Konumlandırma Toplam Maliyet-KÖS ve ışın sayısı grafiği



Şekil 5: KBO-KÖS ve ışın sayısı grafiği


Maliyetleri düşük olan bu iki KÖS değeri için Şekil 5'te verilen konumlandırma başarı oranı (KBO) göz önüne alındığında, KÖS için 40 değerinin seçilmesi sistemin hem düşük maliyetli hem de yüksek performanslı olmasını sağlamaktadır.

Şekil 6 ve Şekil 7'de verilen grafiklerde algılayıcı ölçüm hata standart sapması 200mm, sabit ışın seçim yöntemi ve geleneksel algılayıcı modeli kullanılmıştır. Bu şekillerde SBO'nun sıfır olduğu durumlarda Seyrüsefer Maliyet (SM) hesabı yapılamamıştır. Konumlandırmadaki benzer bir değerlendirme seyrüsefer için yapıldığında, ışın sayısı 3 iken bütün SÖS değerleri için maliyetin düşük olduğu Şekil 6'da görülmektedir.



Şekil 6: Seyrüsefer Maliyeti-SÖS ve ışın sayısı grafiği

Maliyetleri benzer olan SÖS değerleri için Şekil 7'deki Seyrüsefer Başarı Oranı (SBO) dikkate alınarak, SÖS için 200 ve ışın sayısı için 3 seçilmesinin uygun olacağı belirlenmiştir.



Şekil 7: SBO-SÖS ve ışın sayısı grafiği

Standart sapmanın etkisi incelenirken, bu alt bölümde belirlenen konumlandırma için KÖS, seyrüsefer için SÖS ve ışın sayısı değerleri kullanılacaktır.

### 5.3. Standart Sapmanın Etkisi


Algılayıcı modelinde standart sapma değeri, algılayıcı ölçüm hatasının nasıl değerlendirildiğini belirleyen unsurdur. Geleneksel ve normalize edilmiş algılayıcı modellerinde ışınların rassal veya sabit seçilmesi durumunda standart sapmanın etkisi bu alt kısımda irdelenmektedir. Bu kısımda kullanılan şekillerde R:Rassal ve S:Sabit ışın seçme yöntemleri, G:Geleneksel ve N:Normalize edilmiş algılayıcı modellerini temsil etmektedir.

#### 5.3.1. Konumlandırma

Standart sapmanın artmasıyla beraber bütün yöntemlerde KBO'nun arttığı, daha sonra tekrar azalmaya başladığı Şekil

8'de görülmektedir. Standart sapma değerinin çok düşük ve çok yüksek olduğu durumlarda KBO'nun düşük olduğu dikkat çekicidir. Standart sapmanın çok düşük olduğu değerlerde sistemin ölçüm hatalarına karşı hassasiyeti aşırı arttığı için ve çok yüksek olduğunda ise sistem hatalara karşı duyarsızlaşması sebebiyle konumlandırma başarısız olmaktadır.

Normalize edilmiş algılayıcı modelinde hatalı ölçümlere sahip algılayıcıların etkisi azaltıldığı için geleneksel algılayıcı modeline göre daha başarılı konumlandırma yapılmaktadır. Standart sapma değerinin artmasıyla KBO'nun arttığı ancak bu karakteristiğin değişmediği görülmektedir.




Şekil 8: KBO-standart sapma grafiği

Standart sapmanın artmasıyla tüm yöntemler için KAS değerinin arttığı Şekil 9'da görülmektedir. Bunun sebebi standart sapma değeri arttıkça sistemin geniş bir aralıktaki hatalara aynı tepkiyi veriyor olmasıdır. Dolayısıyla konumlandırmanın ihtiyaç duyduğu ayırt edici özellikleri sistem daha geç elde etmektedir.

Standart sapma değerinin artmasıyla normalize edilmiş ve geleneksel algılayıcı modellerindeki KAS değerleri arasında belirgin bir fark oluşmaya başlar. Normalize edilmiş algılayıcı modelinin doğası gereği, ayırt edici özelliğe sahip olabilecek çok düşük veya yüksek olasılık değerlerinin etkisini baskılaması, KAS değerinin daha fazla artmasına neden olmaktadır.

Sabit ışın seçim yönteminde KAS değeri rassal ışın seçim yöntemine göre genellikle daha düşüktür. Standart sapma değerinin artmasıyla normalize edilmiş algılayıcı modelinin kullanıldığı durumda ışın seçimi yöntemleri arasındaki fark azalmakta iken geleneksel algılayıcı modelinde bu fark artmaktadır. Bununla birlikte standart sapmanın artması modeller arasındaki genel karakteristiği değiştirmemektedir.




Şekil 9: KAS-standart sapma grafiği

### 5.3.2. Seyrüsefer

Seyrüsefer esnasında sistemin konumlandırmaya göre daha net bilgilere ihtiyaç duyması algılayıcı modelinde kullanılacak standart sapma değerinin daha düşük seçilmesini gerektirmektedir.

Standart sapmanın artmasıyla beraber bütün yöntemlerde SBO'nun arttığı, daha sonra tekrar azalmaya başladığı Şekil 10'da görülmektedir. Konumlandırmada olduğu gibi standart sapma değerinin çok düşük ve çok yüksek olduğu durumlarda SBO çok düşük kalmaktadır.




Şekil 10: SBO-standart sapma grafiği

Standart sapma değerinin artmasıyla OSH değerinin arttığı Şekil 11'de görülmektedir. Buna ilaveten, algılayıcı modelleri arasındaki fark da standart sapmanın artmasıyla beraber artmaktadır.

Normalize edilmiş algılayıcı modeli çok yüksek veya çok düşük olasılık değerlerine sahip algılayıcı ölçümlerini baskılamaktadır. Bu model robotun algılayıcıları yardımıyla ortamdan yeterli bilgi sağladığı halde bu bilgiyi verimli bir şekilde kullanamamaktadır. Bu sebeple geleneksel algılayıcı modeli daha az takip hatasıyla rotanın izlenmesini sağlamaktadır.

Düşük standart sapma değerlerinde sabit ışın seçimi, yüksek standart sapma değerlerinde ise rassal ışın seçimini daha yüksek OSH sağlamaktadır.



Şekil 11: OSH-standart sapma grafiği

## 6. Sonuçlar

Bu çalışmada, geleneksel ve normalize edilmiş algılayıcı modellerinde ve bu modellerde rassal ve sabit ışın seçim yöntemleri için algılayıcı veri hassasiyeti analizi yapılmıştır. Veri hatasının değerlendirilmesinde standart sapma değerinin doğrudan etkili olduğu yapılan analizlerle gözlemlenmiştir. Standart sapma değerinin düşük olması durumunda sistemin hataya karşı duyarlı olduğu, yüksek olduğunda ise sisteme gerekli bilgiyi vermediği görülmüştür. Konumlandırma ve seyrüsefer esnasında standart sapma değerinin seçimi bu iki durum arasında sistem performans faktörleri göz önüne alınarak yapılmalıdır.

Standart sapma değerinin konumlandırmada KBO ve KAS, seyrüseferde SBO ve OSH performans faktörlerine göre detaylı analizi yapılmıştır. Analiz aşamasında geliştirilen maliyet fonksiyonları ile sistemin başarısı ve hesaplama yükü arasındaki ilişki verilmiştir. Bu fonksiyonların sonucunda bulunan örnek ve ışın sayıları standart sapmanın önerilen yöntemler üzerindeki etkisi analiz edilirken kullanılmıştır.

## 7. Kaynakça

- [1] H. Choset ve arkadaşları, "Principles of Robot Motion: Theory, Al Algorithms and Implementation", the MIT Press, 2005
- [2] L. Marchetti, G. Grisetti ve L. Iocchi, "A Comparative Analysis of Particle Filter based Localization Methods", *10th RoboCup International Symposium*, Bremen, Germany, 2006.
- [3] J.S. Gutmann, W.Burgard, D.Fox, ve K.Konolige, "An experimental comparison of localization methods", *Proceedings of the 1998 IEEE/RSJ Intl. Conference on Intelligent Robots and System*, Victoria, Canada, 1998.
- [4] L. Kaelbling, A. Cassandra, and J. Kurien, "Acting under uncertainty: Discrete bayesian models for mobile-robot navigation", *Proceedings of the 1996 IEEE/RSJ Intl. Conference on Intelligent Robots and System*, Osaka, Japan, 1996.
- [5] W. Burgard, A. Derr, D. Fox, and A. Cremers, "Integrating global position estimation and position tracking for mobile robots: the DynamicMarkov Localization approach" *Proceedings of the 1998 IEEE/RSJ Intl. Conference on Intelligent Robots and System*, Victoria, Canada, 1998.
- [6] D. Fox ve arkadaşları, "Monte-Carlo Localization: Efficient Position Estimation for Mobile Robots", *Proceedings of the National Conference on Artificial Intelligence (IAAA)*, Orlando, USA, 1999.
- [7] S. Yılmaz, H.E. Kayır, B. Kaleci, O. Parlaktuna, "A New Approach to Improve the Success Ratio and Localization Duration of a Particle Filter Based Localization for Mobile Robots", *6th International Conference on Electrical and Electronics Engineering*, Bursa, Türkiye, 2009
- [8] S. Yılmaz, H.E. Kayır, B. Kaleci, O. Parlaktuna, "Gezgin Robotlarda Parçacık Süzgeci Tabanlı Konumlandırma ve Seyrüsefer Yöntemi", *Otomatik Kontrol Ulusal Kongresi*, İstanbul, Türkiye, 2009.
- [9] D. Fox, W. Burgard ve S.Thrun, "Markov Localization for Mobile Robots in Dynamic Environments", *Journal of Artificial Intelligence Research (JAIR)*, vol:11, pp.391-457, 1999.
- [10] www.mobilerobots.com, 2009.