

# Akustik Algılayıcı Ağlarında Çarpan Çizgeleri Kullanarak Hedef Konumlandırma

## Target Localization in Acoustic Sensor Networks Using Factor Graphs

Murat Üney<sup>1,2</sup> ve Müjdat Çetin<sup>1</sup>

1. Mühendislik ve Doğa Bilimleri Fakültesi, Sabancı Üniversitesi

{[muratuney,mcetin](mailto:muratuney,mcetin@sabanciuniv.edu)}@sabanciuniv.edu

2. Elektrik ve Elektronik Mühendisliği Bölümü, Orta Doğu Teknik Üniversitesi

### Özetçe

*Bu çalışmada, düğümleri akustik yeğlilik ölçen duyuculara sahip bir algılayıcı ağının kapsama alanında bulunan ve akustik kaynak özelliği gösteren hedeflerin konumlarının saptanması problemi ele alınmıştır. Her bir hedef konumunun sonsal dağılımı, birleşik sonsal dağılımın çarpan çizgesi gösterimi üzerinde döngülü topla-çarp algoritmasına dayanan bir ileti geçme algoritması kullanılarak oluşturulmuştur. Sonsal dağılımlar oluşturulduktan sonra hedef konumlarının bu dağılımlar altındaki MAP ya da MMSE kestirimi ifadeleri hesaplanabilir. Bu yaklaşım daha önce önerilmiş olan dağıtık çıkarsama için bir bilgi mimarisinin uygulamasıdır. Böylece doğal olarak dağıtık olarak gerçekleştirilmeye uygun olması ve kolayca üretilebilen işlevlere dayanması nedeni ile bu yaklaşım algılayıcı ağlarının isterlerine uygun olma avantajına sahiptir.*

### Abstract

*We consider the problem of localizing targets which act as acoustic sources over a region covered by a sensor network in which each node is equipped with an acoustic intensity sensor. The a posteriori distribution of each target location is constructed through a message passing algorithm on the factor graph representation of the joint posterior which is based on the loopy sum product algorithm. After constructing the posteriors, it is possible to compute the MAP or MMSE estimation expressions of the target locations under these distributions. This approach is the application of an information architecture for distributed inference proposed before. Therefore it is naturally amenable to a distributed implementation and depending on functions which can be easily generated, it has the advantage of compliance with the requirements of sensor networks.*

### 1. Giriş

Algılayıcı ağları, kısıtlı sezim, hesap ve iletişim kapasitesine sahip çok sayıda aygıtın bir ağ oluşturması ile elde edilen sistemlerdir. Bir algılayıcı ağı uygulaması ele alınırken sistemin bu kısıtlı doğasından kaynaklanan isterlere cevap verebilecek çözümler aranmaktadır. Temel olarak, tüm

ölçümlerin bir merkezde toplanmasını gerektirmeyen “ağda işleme” paradigmasına uygun yaklaşımlar gerekmektedir [1]. Çizge modelleri tabanlı yaklaşımlar, hem problemleri istatistiksel modelleme ve çözmede prensipli olmakta, hem de bu gerekleri sağlamaya yatkınlık göstermektedir [2].

Algılayıcı ağları için sıklıkla ele alınan uygulamalardan bir tanesi gözetimdir [3]. Bu uygulamada algılayıcıların serpiştirildiği alan üzerinde hareket eden hedeflerin saptanması ve rotalarının belirlenmesi gerekmektedir. Rotaların bulunması, her bir zaman adımı için hedef konumlarının belirlenmesi ile olur. Böylece, bir aşamada konum kestirimi probleminin çözülmesi gerekmektedir.

Temel istatistiksel yaklaşım, konumların (ölçümlere koşullu) birleşik sonsal dağılım (SD) işlevinin bilinmesini gerektirir. Bu durumda her bir hedef sayısı ve hedef-algılayıcı kapsama kombinasyonu için bu işlevin hazırda olması gerekmektedir. Olası kombinasyon sayısı düşünülürse her biri için işlevin önceden hesaplanıp saklanması makul değildir. Bunun yerine dağılımın takip sırasında oluşturulabilmesi için ise o an geçerli olan hedef-algılayıcı kapsama durumuna uyarlı ve görece kolay hesaplamalar kullanan bir yöntem ihtiyacı vardır. Ayrıca, söz konusu yöntem sistem isterleriyle uyumlu olmalıdır.

Önerdiğimiz yöntem [4]’te sunulan çalışmadan esinlenmiştir. Söz konusu çalışmada algılayıcı ağları için bir çoklu algılayıcı çoklu hedef modeli önerilmektedir. Buradan yola çıkarak [5]’te algılayıcı ağlarında dağıtık çıkarsama için bir bilgi mimarisi önerilmiştir. Buna göre ele alınan problemin bir çizge model olan “çarpan çizgesi” [6] gösterimi oluşturulduktan sonra uygun bir çıkarsama algoritması kullanılır. Bu çalışmada hedef konumlandırma problemi için sözü edilen mimari kullanılmaktadır. Problem çarpan çizgesi ile ifade edildikten sonra, çizge üzerinde çıkarsama yapmak için döngülü topla-çarp algoritmasına dayanan bir ileti geçme algoritması (Message Passing Algorithm) uygulanır. Sonuç olarak aranan sonsal dağılımlar oluşturulur. Ardından bu dağılımlar üzerinden MAP ya da MMSE kestirimi ifadelerini hesaplamak mümkündür. Döngülü topla çarp yaklaşımı ile konumlandırma problemi için daha önce sergilenmiş bir sonuç, yazarların bilgisi dahilinde bulunmamaktadır.

### 2. Problem Tanımı

Ele aldığımız problemde bir  $K \subset \mathbb{R}^2$  bölgesinde  $x_i$ ,  $i=1, \dots, L$  konumlarında  $L$  adet algılayıcı platformu ve  $M$  tane hedef bulunmaktadır. Her bir platform akustik yeğlilik ölçmektedir ve ölçüm modeli

Bu çalışma TÜBİTAK’ın 105E090 ve Avrupa Komisyonu’ nun MIRG-CT-2006-041919 sayılı projeleri kapsamında desteklenmiştir. Ayrıca yazarlar M. K. Chu’ ya karşılıklı görüş alışverişindeki katkıları nedeni ile teşekkür eder.

$$y_i(t) = \sum_{j=1}^M A_j f(\|x_i - \theta_j(t)\|^\alpha) + n_i(t), \quad i=1, \dots, L \quad (1)$$

ile verilmiştir [7]. Burada  $\theta_j(t)$   $j$ 'inci hedefin  $t$  anındaki konumu,  $A_j$  hedef konumunda ölçülen nominal yeğinlik değeri ve  $n_i(t) \sim \mathcal{N}(0, \sigma_i^2)$  şeklindedir. Ayrıca  $\alpha$  akustik basınç dalgasının atmosferdeki yayılımı için sönümlenme katsayısı ve  $f$  negatif olmayan sayılar üzerinde  $f(0) = 1$  ve monoton azalan bir fonksiyondur. Bir  $T$  anında<sup>1</sup>, hedef konumlarının önsel dağılımları  $p_j(\theta_j)$   $j=1, \dots, M$  bilinmek üzere<sup>2</sup> bu değerlerin kestirimlerinin  $\{\hat{\theta}_j\}_{j \in \{1, \dots, M\}}$  elde edilmesini istemekteyiz.

Eşitlik (1) kullanılarak elde edilen tüm hedeflere koşullu algılayıcı gözlem olabilirlik (GO) işlevleri ve algılayıcı gürlütülerinin bağımsız süreçler olduğu kabulü ile birleşik sonral dağılım

$$p(\{\theta_j\}_{j \in \{1, \dots, M\}} | y_1, \dots, y_L) = \frac{\prod_{j=1}^L p_i(y_i | \{\theta_j\}_{j \in \{1, \dots, M\}}) \prod_{j=1}^M p_j(\theta_j)}{p(y_1, \dots, y_L)} \quad (2)$$

$$\propto \prod_{i=1}^L p_i(y_i | \{\theta_j\}_{j \in \{1, \dots, M\}}) \prod_{j=1}^M p_j(\theta_j)$$

şeklinde elde edilir. Burada  $p_i(y_i | \{\theta_j\}_{j \in \{1, \dots, M\}})$ ,  $i=1, \dots, L$  işlevlerinin  $M$ 'nin farklı değerleri için bilinmesi çok makul değildir. Dikkat edilirse, tek hedef durumunda 3 boyutlu bir değer kümesi söz konusu olur iken ( $y \in \mathbb{R}, \theta \in \mathbb{R}^2$ ),  $M$  hedef için  $1+2M$  boyutlu bir değer kümesi söz konusudur. Ayrıca  $k$ 'inci hedef için MMSE kestirimi

$$\hat{\theta}_{k, MMSE} = \int \dots \int_{\theta_k \in K} \theta_k p(\{\theta_j\}_{j \in \{1, \dots, M\}} | y_1, \dots, y_L) d\theta_1 \dots d\theta_M \quad (3)$$

$$= \int_{\theta_k \in K} \theta_k p(\theta_k | y_1, \dots, y_L) d\theta_k$$

şeklinde kendi sonsal dağılımının bir işlevseli olacaktır.

Bu durumda eşitlik (3) ile ifade edilen kestirimde yer alan hedef sonsal dağılımlarını bulmak için dağıtık hesaplamaya uygun ve makul bir yöntem kullanmamız gerekmektedir.

### 3. Sonsal Dağılımların Hesaplanması

Çözüme gitmek için iki konuya dikkat çekmek isteriz. Bunlardan birincisi, hedefe belli bir değerden uzak olan algılayıcılara ait GO işlevlerinin sonsal dağılıma kaydadeğer bir katkı yapmayacağıdır<sup>3</sup>.  $A$  ve  $f$  biliniyorken, bir hedefin ne kadar yakınındaki algılayıcıların makul katkıda bulunacakları değerlendirilerek “hedefi sezen algılayıcılar kümesi” oluşturulabilir. Genel olarak  $j$ 'inci hedef için,  $\tilde{\theta}_j$   $p_j(\theta_j)$  dağılımı üzerinden bir kestirim ve  $\Delta$  yine bu dağılıma bağlı bir eşik olmak üzere  $j$ 'inci hedefi kapsayan algılayıcılar kümesi

$$L_j = \{i : i \in \{1, \dots, L\}, Af(\|x_i - \tilde{\theta}_j\|^\alpha) > \Delta\} \quad (4)$$

şeklinde oluşturulabilir.  $i$ 'inci algılayıcının kapsadığı hedefler kümesi ise

$$C_i = \{j : j \in \{1, \dots, M\}, i \in L_j\} \quad (5)$$

<sup>1</sup> Buradan sonra tüm tartışma  $T$  anı için olacaktır ve değerlerin zamana bağımlılığı gösterilmeyecektir.

<sup>2</sup> Önsel dağılım  $t < T$  için yapılan gözlemlerin bilgisini taşır ve takip algoritmalarının öngörüm adımının çıktısıdır [3].

<sup>3</sup> Bu, algılayıcıdaki SNR değerinin düşük olmasına karşılık gelir.

olarak tanımlanabilir. Bu durumda  $p_i(y_i | \{\theta_j\}_{j \in \{1, \dots, M\}}) \approx p_i(y_i | \{\theta_k\}_{k \in C_i})$  olur ve ifade (2)

$$p(\{\theta_j\}_{j \in \{1, \dots, M\}} | y_1, \dots, y_L) \propto \prod_{i=1}^L p_i(y_i | \{\theta_k\}_{k \in C_i}) \prod_{j=1}^M p_j(\theta_j) \quad (6)$$

halini alır. İfade (6)'n bir yaklaşım olması nedeni ile kestirim başarımında bir kayıp olacaktır. Ancak ifadeyi oluşturan işlevlerin tanım kümeleri görece daha düşük boyutlu olduğu için elde edilen hesaplama kazancı karşısında azımsanabilir [7]. Buna karşın eşitlik (1) ile verilen gözlem modeli için de

$$\sum_{j=1}^M A_j f(\|x_i - \theta_j\|^\alpha) \approx \sum_{j \in C_i} A_j f(\|x_i - \theta_j\|^\alpha) \quad (7)$$

şeklinde dir.

İkinci olarak  $k \in C_i$  olmak üzere  $k$ 'inci hedefin  $i$ 'inci algılayıcı üzerine etkisi  $y_i^k \triangleq A_k f(\|x_i - \theta_k\|^\alpha)$  olarak tanımlansın.  $i$ 'inci algılayıcının birleşik SD işlevine katkısı olan GO işlevi

$$p_i(y_i | \{\theta_k\}_{k \in C_i}) = p(y_i | \{y_i^k\}_{k \in C_i}) \prod_{k \in C_i} p_{ik}(y_i^k | \theta_k) \quad (8)$$

halini alır. Burada  $p_{ik}(y_i^k | \theta_k)$  tanım kümesi 3 boyutlu olan bir işlevdir ve  $p_{ik}(y_i^k | \theta_k) = \delta(y_i^k - A_k f(\|x_i - \theta_k\|^\alpha))$  şeklinde nominal yeğinlik  $A_k$  değeri aynı olan hedefler için aynıdır ( $A_k = A_i \Rightarrow p_{ik}(y_i^k | \theta_k) = p_{il}(y_i^k | \theta_k)$ ). Bunun yanında,  $n_i \sim \mathcal{N}(0, \sigma_i^2)$  olmak üzere  $p(y_i | \{y_i^k\}_{k \in C_i}) = \mathcal{N}(\sum_{k \in C_i} y_i^k, \sigma_i^2)$  olur ve tanım kümesi yüksek boyutlu olsa da gösterdiği simetri nedeni ile hesaplanması kolay bir işlevdir<sup>4</sup>.

Böylece birleşik SD işlevini, değer kümesi düşük boyutlu ve hesaplanması kolay işlevlerin çarpımı olarak

$$p(\{\theta_j\}_{j \in \{1, \dots, M\}} | y_1, \dots, y_L) \propto \prod_{j=1}^M p_j(\theta_j) \prod_{i=1}^L p(y_i | \{y_i^k\}_{k \in C_i}) \prod_{k \in C_i} p_{ik}(y_i^k | \theta_k) \quad (9)$$

şeklinde yazmış olduk. Eşitlik (3)'te görülen her bir hedef konumunun SD işlevinin hesaplanması ise birleşik SD işlevinin marjinallerinin bulunması ile olur. Literatürde “işlev çarpımlarını marjinalleştirme” problemi olarak da bilinen bu hesaplama için [6]'da çarpan çizgeleri gösterimi ve topla-çarp algoritması önerilmiştir.

#### 3.1. Çarpan Çizgeleri ve Döngülü Topla Çarp Algoritması

Çarpan çizgeleri, başka işlevlerin çarpımı olarak yazılabilen işlevleri temsil eden  $\mathcal{G} = (\mathcal{V}, \mathcal{E})$  şeklinde bipartit çizgelerdir. Döğümler  $v \in \mathcal{V}$  değişkenleri ya da çarpan işlevlerden birini, kenar kümesi  $\mathcal{E}$  ise döğümler arasında “argümandır” bağıntısını temsil eder. Örnek olarak bir  $g : X_1 \times X_2 \times X_3 \rightarrow \mathbb{R}$  işlevi  $f_A : X_1 \rightarrow \mathbb{R}$ ,  $f_B : X_1 \times X_2 \rightarrow \mathbb{R}$  ve  $f_C : X_2 \times X_3 \rightarrow \mathbb{R}$  iken

$$g(x_1, x_2, x_3) = f_A(x_1) f_B(x_1, x_2) f_C(x_2, x_3) \quad (10)$$

ise  $g$ 'yi temsil eden çarpan çizgesi Şekil 1'deki gibidir.

İşlev çarpımlarını marjinalleştirme problemi ise  $g$ 'nin marjinallerini hesaplama problemidir. Örnek olarak  $g$ 'nin  $x_1$  değişkeni üzerindeki özeti

$$g_1(x_1) = \sum_{x_2 \in X_2} \sum_{x_3 \in X_3} g(x_1, x_2, x_3) \quad (11)$$

<sup>4</sup>  $p(y_i | \{y_i^k\}_{k \in C_i})$  dağılımı  $\{y_i^k\}_{k \in C_i}$  argümanlarının tüm permütasyonları için aynı değeri alır.

marjinali ile ifade edilir. Topla çarp algoritması ise  $g_1(x_1)$  işlevini eşitlik (10) bilinirken hesaplamanın etkin bir yoludur [6]. Buna göre düğümler hesaplama yapabilen ve komşuları ile iletişimi kurabilen bir yapı olarak düşünülür. Her adımda düğümler komşuları için iletiler hesaplanır. Söz konusu iletiler birer işlemdir ve  $x$  değişken düğümünden  $f$  ye bir ileti

$$m_{x \rightarrow f}(x) = \prod_{h \in n(x) \setminus f} m_{h \rightarrow x}(x) \quad (12)$$

ile verilir. Burada  $n(x)$ ,  $x$  değişken düğümünün komşu kümesidir. Bir işlev düğümü  $f$  den  $x$ ' e ileti ise

$$m_{f \rightarrow x}(x) = \sum_{-x} f(X) \prod_{y \in n(f) \setminus x} m_{y \rightarrow f}(y) \quad (13)$$


olarak hesaplanır. Burada  $X$  ile  $f$  işlevinin argüman kümesi ve  $-x$  ile  $x$  haricindeki tüm argümanların kümesi ifade edilmiştir.

İletişimi başlatmak için gerekli işlevlerin birer kestirimi kullanılabilir<sup>1</sup>. Değişken düğümleri, tüm komşularından ileti almışken bu iletileri çarptıkları zaman, çarpan çizgesinin ifade ettiği işlevin kendi değişkenleri için özetinin bir kestirimini bulurlar. Çarpan çizgesi ağaç ise bu kestirim sonlu adımda tam olarak gerçek değere eşit olur. Bu sonucu sağlayacak bir ileti çizgesi Tablo 1'de verilmiştir. İletiler uçlardaki düğümlerden başlar ve her bir düğüm ancak gerekli tüm iletileri aldıktan sonra ilgili komşusuna ileti hesaplar. Tüm komşularına ileti hesaplamış olan düğüm durur. Tüm iletişim bittiği zaman aranan marjinaler tam olarak hesaplanır; 3. adımın sonunda  $x_2$  düğümü bütün komşularından ileti almıştır ve bunların çarpımı  $g_2(x_2)$ ' ye eşit olur. Benzer şekilde 4. adımın sonunda  $g_1(x_1)$  ve 5. adımın sonunda  $g_3(x_3)$  hesaplanır.

Ele aldığımız problemde, çarpanlar ve çarpım eşitlik (9)' da görüldüğü gibi, olasılık dağılımları ve GO işlevleri şeklindedir. Bu durumda oluşan çarpan çizgesine eşdeğer bir Markov Rasgele Alanı vardır ve bu alan üzerindeki kanı yayılma (belief propagation) algoritması ile topla çarp algoritması eşdeğerdir [6]. Çarpan çizgesinin döngü içermesi durumunda eşitlik (12) ve (13)'te görülen iletiler hala tanımlıdır ancak aranan marjinal işlevlerinin sonlu adımda ve tam olarak bulunacağından bahsedemeyiz. Bu durumda ileti akışı özyineli şekilde devam ettirilerek yaklaşık doğru marjinal işlevler elde edilebilir [8]. Böylece marjinal dağılımların bulunması için özyineli bir algoritma elde edilmiş olur [9]. Ayrıca aynı adım içerisinde birden fazla düğümün ileti hesaplaması ile paralel bir işlevi elde edilir.

### 3.2. Çarpan Çizgesi ile Hedef Konumlandırma

Hedef konumlandırma probleminde ortaya çıkan çarpan çizgesini bir örnek ile sunacağız. 2 hedef ve 4 algılayıcı Şekil 2' deki gibi konumlandırılmış olsun. Algılayıcı 1 yalnız birinci, 3 yalnız ikinci hedeften, 2 ve 4 ise her ikisinden de işaret almaktadır. Bu durumda ifade (9)



Şekil 1: İfade (10)' u temsil eden çarpan çizgesi; değişken düğümleri daire, işlev düğümleri kare ile gösterilmiştir.

<sup>1</sup> Örnek olarak eşitlik (12) ve (13)'te çarpımdaki  $m_{h \rightarrow x}$  ve  $m_{y \rightarrow f}$  iletilerinden henüz alınmayan var ise birim işlev olarak seçilebilir.

Tablo 1: Şekil 1' de görülen çarpan çizgesi için topla çarp algoritması ileti çizgelgesi.

Adım	İleti
1	$m_{f_A \rightarrow x_1}, m_{x_3 \rightarrow f_C}$
2	$m_{x_1 \rightarrow f_B}, m_{f_C \rightarrow x_2}$
3	$m_{f_B \rightarrow x_2}, m_{x_2 \rightarrow f_B}$
4	$m_{x_2 \rightarrow f_C}, m_{f_B \rightarrow x_1}$
5	$m_{f_C \rightarrow x_3}, m_{x_1 \rightarrow f_A}$


$$p(\theta_1, \theta_2 | y_1, y_2, y_3, y_4) \propto p_1(\theta_1) p_2(\theta_2) p(y_1 | y_1^1) p(y_2 | y_2^1, y_2^2) p(y_3 | y_3^2) p(y_4 | y_4^1, y_4^2) p_{11}(y_1^1 | \theta_1) p_{21}(y_2^1 | \theta_1) p_{22}(y_2^2 | \theta_2) p_{32}(y_3^2 | \theta_2) p_{41}(y_4^1 | \theta_1) p_{42}(y_4^2 | \theta_2) \quad (14)$$

şeklinde olur. Çarpan çizgesi ise Şekil 3' de görüldüğü gibidir. Değişkenler sürekli bir kümeden değer almaktadır. Bunlar için özetleme işlemindeki toplamlar tümlemlere dönüşür [6]. En az iki ortak hedefi sezen en az iki algılayıcı olduğu için çizge döngüler içermektedir. Gözlenen değer olan düğümler ( $y_1, y_2, y_3$  ve  $y_4$ ) komşu oldukları işlev düğümüne  $m_{y_i \rightarrow p(y_i | \{y_j^k\}_{k \in C_i})} = \delta(Y_i - y_i)$  şeklinde belirlemeci olduğunu ifade eden bir dağılımı ileti olarak gönderir. Burada  $Y_i$  ölçülen değeri ifade etmektedir. Eşdeğer olarak komşu işlev düğümlerinde parametre olarak yer alırlar.

Çizge üzerinde istatistiksel çıkarıma için önerdiğimiz algoritma döngülü topla-çarp algoritmasına dayanmaktadır. Uygulayacağımız ileti akışı [4]' de kullanılan yöntem ele alınarak oluşturulmuştur. Bu yöntemin karşılık geldiği ileti akışı özyinelemelerin her bir adımında tekrarlanmaktadır. Sözü edilen çalışmada istatistiksel çıkarım yanında iletişim ve hesaplama maliyeti en iyilemeye çalışılmakta ve özyineli bir işlevi incelenmemektedir. Her bir adımda ileti akışının aşamaları şu şekildedir; ilk önce gözlenen değerler  $Y_1, \dots, Y_L$  komşu  $p(y_i | \{y_j^k\}_{k \in C_i})$  düğümlerinde parametre olarak değerlendirilir ve her hedef önsel dağılım düğümü komşusuna ileti<sup>2</sup> gönderir. Bu ön aşamadan sonra özyinelemenin her bir adımında ileti akışı hedef konumu düğümlerinden başlar,  $p(y_i | \{y_j^k\}_{k \in C_i})$  düğümlerine doğru ilerler. Bu düğümler ileti aldıktan sonra hedef konumu değişkenlerini taşıyan düğümlere doğru bir akış başlar ve adım burada sonlanır.

Bu ileti akışı genel durum için Tablo 2' de verilmiştir. Bahsedilen ön aşama 0 ile gösterilmiştir. Dikkat edilir ise 3. aşamada hedef katkıları ile ilgili bilgi toplandıktan sonra 4. aşamada veri bütünleşmesi olmaktadır ve 6. aşamada güncel GO işlevleri ile hedef konumu dağılımları güncellenmektedir.

Bu yaklaşım iki temel avantaj getirmektedir. İlk olarak, çarpan çizgesinde yer alan işlevleri hesaplamak ve saklamak için gerekli kaynaklar algılayıcı ve hedef sayısı ile ölçeklenebilir. İkincisi olarak ise Tablo 2' de sunulan hesap adımları, hem tek merkezli hem de algılayıcı ağları gibi çoklu yapılarda dağıtık hesaplama uygundur.



Şekil 2: Örnek senaryo; hedefler artı, algılayıcılar kare, hedef işaretlerinin etki alanı daire ile gösterilmiştir.

<sup>2</sup> Tek komşulu bu düğümlerde hesaplanan ileti her zaman aynıdır.


#### 4. Benzetim Örnekleri

Benzetimlerde sürekli değişkenler nicemlenerek tümlemlere toplama ile yaklaşılmıştır. İlk olarak konum değişkeni için bir ızgara seçilmiş, ardından bu konumlara karşılık gelen  $y_i^k$  değerleri hesaplanıp nicemlenmiştir. Önsel dağılımlar olarak sadece hedef-algılayıcı kapsama ilişkilerini yansıtan birbiçim dağılımlar kullanılmıştır. Sonuçta elde edilen SD işlevlerini en büyük yapan değerler MAP, dağılımların ağırlık ortalamaları MMSE kestirimi olarak adlandırılmıştır.

Akustik yeğinlik uzaklık bilgisi taşımaktadır ve kompakt bir SD için en az üç farklı konumlandırılmış algılayıcıya ihtiyaç vardır. Bölüm 3.2’ de verilen senaryoda (senaryo 1) her hedef için iki algılayıcı ortak olmak üzere bu koşul sağlanmaktadır. Nicemlemelerden sonra doğrudan bir yaklaşımda SD değerinin bir merkezde  $2^{47}$ ’den fazla noktada bilinmesi gerekirken Şekil 3’teki gibi dağıtılmış tüm işlevler için toplam  $2^{21}$ ’den az olmaktadır. Hata kriteri olarak konum hata vektörlerinin norm ortalaması kullanılmıştır.  $A_1=A_2=10$  ve  $\sigma = 1$  için 60 Monte Carlo denemesi sonucu olan ortalama hata kriteri-özyineleme adımı grafiği MAP ifadesi için Şekil (4a)’da, MMSE ifadesi için Şekil (4b)’de görülmektedir. Önerilen yöntem bir kaç adım içerisinde hatayı makul düzeylere indirmektedir. İkinci örnekte ise senaryoya 1. hedefi kapsayan bir algılayıcı daha eklenmiştir. Senaryo 2 için benzer şekilde elde edilen sonuçlar yine Şekil (4a) ve (4b)’de sergilenmiştir. Dikkat edilir ise hata kriteri hedefler daha fazla algılayıcı tarafından kapsandıkça düşmektedir.

#### 5. Sonuçlar

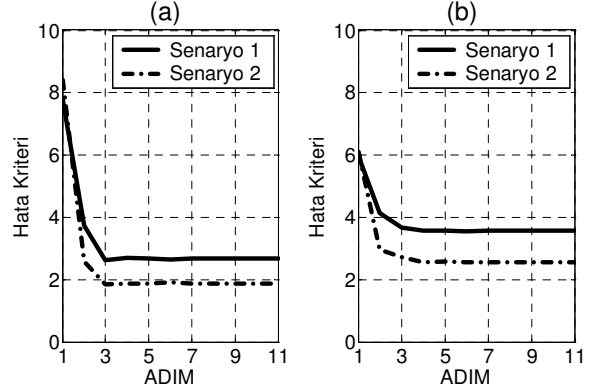
Bu bildiride algılayıcı ağları ile hedef konumlandırma problemi ele alındı. Hedef-algılayıcı kapsama ilişkileri kullanılarak konumların sonsal dağılımlarının bulunması problemi, düğümlerindeki işlevler kolayca üretilebilen çarpan çizgilerinde döngülü topla-çarp algoritması ile çözüldü. Böylece algılayıcı ağları üzerinde dağıtık olarak çalışabilecek bir yapı elde edildi. Bu yaklaşım daha önce önerilen bir bilgi mimarisinin konumlandırma problemine uygulamasıdır. Bu dağılımlar üzerinden hedef konumlarının MAP ya da MMSE kestirim ifadeleri hesaplanarak elde edilen sonuçlar, çok iyi olmayan önsel dağılımlar durumunda bile makuldür. İleriki aşamalarda sürekli tanım kümesinde dağılımların temsili için örneklemeye dayalı yöntemler kullanılabilir. Bunun yanında yöntem bir takip algoritması ile birleştirilerek daha geniş bir senaryo içerisinde, manevra yapan hedeflerden kaynaklanan kötü önsel dağılım durumlarındaki başarımlar gözlenebilir.



Şekil 3: İfade (14)’ü temsil eden çarpan çizgesi; değişken düğümleri daire, işlev düğümleri kare ile gösterilmiştir. Kalın daireler gözlem düğümleri, kalın kareler ise ileti akışını başlatan düğümleri göstermektedir.

Tablo 2: Konumlandırma problemi için çarpan çizgesi üzerinde her bir adımda kullanılan ileti çizelgesi.

Aşama	İleti
0	$\{m_{p_j(\theta_j) \rightarrow \theta_j}\}_{j \in \{1, \dots, M\}}, \{m_{y_i \rightarrow p(y_i   \{y_i^k\}_{k \in C_i})}\}_{i \in \{1, \dots, L\}}$
1	$\{m_{\theta_k \rightarrow p_{ik}(y_i^k   \theta_k)}\}_{k \in C_i}\}_{i \in \{1, \dots, L\}}$
2	$\{m_{p_{ik}(y_i^k   \theta_k) \rightarrow y_i^k}\}_{k \in C_i}\}_{i \in \{1, \dots, L\}}$
3	$\{m_{y_i^k \rightarrow p(y_i = Y_i   \{y_i^k\}_{k \in C_i})}\}_{i \in C_i}\}_{i \in \{1, \dots, L\}}$
4	$\{m_{p(y_i = Y_i   \{y_i^k\}_{k \in C_i}) \rightarrow y_i^k}\}_{i \in C_i}\}_{i \in \{1, \dots, L\}}$
5	$\{m_{y_i^k \rightarrow p_{ik}(y_i^k   \theta_k)}\}_{k \in C_i}\}_{i \in \{1, \dots, L\}}$
6	$\{m_{p_{ik}(y_i^k   \theta_k) \rightarrow \theta_k}\}_{k \in C_i}\}_{i \in \{1, \dots, L\}}$



Şekil 4: Örnek senaryo 1 ve 2 için hata kriteri-özyineleme adımı grafiği (a) MAP, (b) MMSE kestirimi.

#### 6. Kaynakça

- [1] J. Liu, J. Reich, and F. Zhao, "Collaborative in-network processing for target tracking", *EURASIP Journal on Applied Signal Processing*, 23(4):378-391, Mart 2003.
- [2] M. Çetin, L. Chen, J. W. Fisher III, A. T. Ihler, R. L. Moses, M. J. Wainwright, ve A. S. Willsky, "Distributed fusion in sensor networks: A graphical models perspective", *IEEE SP Mag.*, 23(4):42-55, Tem. 2006.
- [3] J. Liu, M. Chu, and J. Reich, "Multiple target tracking in distributed sensor networks", *IEEE SP Mag.*, 24(3):37-46, Mayıs 2007.
- [4] M. Chu, *A Hierarchical Framework for Constructing Computationally Efficient Algorithms for Distributed Inference Problems*, Ph.D. Tezi, EECS Dept. MIT, 2003.
- [5] M. Chu, S. Mitter ve F. Zhao, "An Information Architecture for Distributed Inference in Ad Hoc Sensor Networks", *41st Allerton Conference*, Ekim 2003.
- [6] F. R. Kschischang, B. Frey ve H. A. Loeliger, "Factor graphs and the sum product algorithm", *IEEE Trans. On Info. Theory*, 47(3):498-519, Şubat 2001.
- [7] M. Chu, S. Mitter, ve F. Zhao, "Distributed multiple target tracking and data association in ad hoc sensor networks", *Int. Conf. On Info. Fusion*, Temmuz 2003.
- [8] A. Ihler, J. W. Fisher III ve A. S. Willsky, "Loopy belief propagation: Convergence and effects of message errors", *Journal of Mach. Learning R.*, 6:905-936, Mayıs 2006.
- [9] J. Moura, J. Lu, ve M. Kleiner, "Intelligent sensor fusion: A graphical model approach", *ICASSP03*, Nisan 2003.