

# Parçacık süzgeci ile biyomedikal görüntü zaman serisi çakıştırma

## Biomedical image time series registration with particle filtering

A. Murat Yağcı\*, Ertunç Erdil†, A. Özgür Argunşah§, Devrim Ünay†, Müjdat Çetin†, Lale Akarun\* ve Fikret Gürgen\*

\*Bilgisayar Mühendisliği, Boğaziçi Üniversitesi, İstanbul, Türkiye

†Mühendislik ve Doğa Bilimleri Fakültesi, Sabancı Üniversitesi, İstanbul, Türkiye

§Champalimaud Neuroscience Programme, Champalimaud Centre for the Unknown, Lizbon, Portekiz

†Biyomedikal Mühendisliği, Bahçeşehir Üniversitesi, İstanbul, Türkiye

{murat.yagci, akarun, gurgen}@boun.edu.tr, {ertuncerdil, mcetin}@sabanciuniv.edu, ali.argunsah@neuro.fchampalimaud.org, devrim.unay@bahcesehir.edu.tr

**Özetçe** —Bu çalışmada, biyomedikal görüntü zaman serilerinin çakıştırılması için Parçacık süzgecini esas alan bir dizi yöntem önerilmiştir. Önem ağırlıklarını hesaplamak için bilgi kuramı ve parlaklık temelli bir yaklaşımla beraber, en parlak veya SIFT nirengi noktalarının bulunması temelli etkili ikinci bir tür yaklaşım daha uygulanmıştır. Kaba kuvvet çalışma arama, uygun amaç fonksiyonları kullanıldığından genellikle iyi sonuçlar üretmesine rağmen, arama uzayı büyündükçe hesaplamaya elverişsiz hale gelir. Tepe tırmanışı en iyileme yaklaşımları ise yerel en iyi çözümleri arar. Parçacık süzgeci rassallık kullanarak olası çözümleri temsil eden sonda dağılımı ardışık olarak günceller. Böylece yerel en iyilerden kaçabilir ve görüntü zaman serilerinin çakıştırılmasında daha gürbüz davranışabilir. Dendrit görüntüsü zaman serileri üzerinde olumlu ön sonuçlar elde edilmiştir.

**Anahtar Kelimeler**—*Biyomedikal görüntü çakıştırma; Bayesçi süzgeçleme; Sinir görüntüüsü analizi.*

**Abstract**—We propose a family of methods for biomedical image time series registration based on Particle filtering. The first method applies an intensity-based information-theoretic approach to calculate importance weights. An effective second group of methods use landmark-based approaches for the same purpose by automatically detecting intensity maxima or SIFT interest points from image time series. A brute-force search for the best alignment usually produces good results with proper cost functions, but becomes computationally expensive if the whole search space is explored. Hill climbing optimizations seek local optima. Particle filtering avoids local solutions by introducing randomness and sequentially updating the posterior distribution representing probable solutions. Thus, it can be more robust for the registration of image time series. We show promising preliminary results on dendrite image time series.

**Keywords**—*Biomedical image registration, Bayesian filtering, Neural image analysis.*

## I. GİRİŞ

Biyomedikal görüntü zaman serilerinin çakıştırılması bir çok görüntü analizi çalışmasında gereklili olan bir adımdır. Parlaklık esası yöntemi aynı veya farklı modalitelerden alınmış iki biyomedikal görüntünün çakıştırılmasında sıkılıkla uygulanmaktadır [1], [11]. Bu tür yaklaşılarda parlaklık esaslı bir amaç fonksiyonu, seçilen dönüşüm değiştirgelerine göre en iyilemeye çalışılarak, görüntüler arası doğru bir hizalama bulunması amaçlanır. Elle seçilen veya otomatik olarak bulunan nirengi noktaları üzerinden görüntü çakıştırma da biyomedikal görüntülere uygulanmıştır. Otomatik görüntü zaman serisi analizinde bu noktaların da otomatik olarak tespiti ve görüntü çiftlerindeki nokta eşleşmelerinin doğru olarak bulunması önemlidir.

Parçacık süzgeci (PS), Bayesçi karar kuramına dayalı, çok doruklu dağılımları ifade edebilen istatistikî bir benzetim yöntemidir [2]. Herhangi bir andaki gizli durum dağılımının gözlemlere dayalı olarak tahmin edilmesinde etkili bir yaklaşımdır. PS yerel en iyi çözümlerden kaçabilen rassal bir algoritma kullanır. Hareket takibi [3] ve görüntü çakıştırma [4] problemlerine uygulanmıştır.

Bu çalışmada, biyomedikal görüntü zaman serilerinin çakıştırılması için Parçacık süzgecini esas alan, parlaklık ve nirengi noktası temelli bir dizi yöntem önerilmiştir. Bu yöntemler global en iyi çözümlere yöneldiklerinden, art arda çakıştırmalar sırasında iki zaman diliminin yanlış çakışma riskini azaltarak, görüntü zaman serilerinin çakıştırılması için elverişli hale gelirler. Ayrıca, problem tanımına göre, bir önceki çalışmada elde edilen parçaçıklar, takip eden zaman diliminde başlangıç parçacık dağılımı olarak kullanılabilir. Çakıştırma işlemi için temel ve önerilen yöntemler bir sonraki kısımda detaylandırılmış ve PS önem ağırlığı hesabı için değişik yaklaşımlar önerilmiştir. Yöntemler floresan mikroskopî dendrit görüntülerini özelinde test edilmiş, deney sonuçları kısmında kaba kuvvet arama ve literatürdeki tepe tırmanışı yaklaşımlarına göre görüntü zaman serilerinin çakıştırılmasında daha elverişli olabilecekleri gösterilmiştir.

## II. YÖNTEMLER

### A. Kaba kuvvet arama ve tepe tırmanışı yaklaşımları

Kaba kuvvet (KK) bir yaklaşımla iki biyomedikal görüntü arasındaki doğru çakışmayı bulmak mümkündür. Problem tanımına göre ardışık veya iki farklı zaman diliminde olabilen sabit ve hareketli görüntü çifti, bir amaç fonksiyonunun değişkenleri olarak düşünülebilir. Önceden belirlenen bir dönüşüm aralığında bu fonksiyon en iyilenir. Uygun bir amaç fonksiyonu seçilebilirse yöntem doğru ve gürbüz sonuçlar üretmektedir. Ancak uygulamaya bağlı olarak hesaplama açısından çok çabuk verimsiz hale gelebilmektedir.

Biyomedikal görüntü işlemede kullanılan iyi bir amaç fonksiyonu bilgi kuramı temelli karşılıklı bilgi miktarıdır (mutual information veya MI) [1]. Sabit ve hareketli görüntünün parlaklıklarını temsil eden iki rassal değişken arasındaki MI, entropi ( $H$ ), cinsinden şu şekilde ifade edilir;  $MI(X, Y) = H(X) + H(Y) - H(X, Y)$ . Karşılıklı bilgi miktarının en büyütlenmesi için marginal entropilerin en yüksek, ortak entropinin en düşük olması gerekliliği biyomedikal görüntüler için istenilen bir durumdur [5].

MI fonksiyonun normalize edilmiş bir hali olan entropi ilinti katsayı (ECC),  $[0, 1]$  aralığında değerler ürettiğinden

daha kolay yorumlanabilir ve uygulamalarda sık olarak kullanılır.

$$ECC(X, Y) = \frac{2 \cdot MI(X, Y)}{H(X) + H(Y)} \quad (1)$$

Literatürde MI fonksiyonunun dönüşüm değiştirmelerine göre türevlenebilir yazımlarını kullanarak tepe tırmazı (TT) yapan en iyileme yöntemleri de bulunmaktadır [6], [7]. Bu yaklaşımalar, örneklem ve parametrik olmayan yöntemlerle marginal ve ortak entropileri tahmin ederek, gradyan inişi veya çıkış ile dönüşüm vektörünü en iyilemeye çalışır. Tepe tırmazı yaklaşımları çakıştırma işlemini hızlandırsa da, prensip olarak yerel en iyi çözümleri ararlar. Bu ise gürbütüsü etkilediğinden, görüntü zaman serilerinin çakıştırılmasında istenmeyen bir durumdur.

### B. Parçacık süzgeci

Yukarıda bahsi geçen yaklaşılardaki sorunları gidermek için PS temelli bir dizi çakıştırma yöntemi önermektedir. Bu yöntemler makul sayıda döngü yaparak hızlı sonuçlar üretebilmekle beraber, başlangıç değerlerine takılmadan global en iyi çözüme yönelebilmektedir.

PS,  $p(s_t|z_{1:t})$  ile temsil edilen saklı bir çözümün  $t$ larındaki sonsal dağılımını tahmin etmek için rassal bir algoritma kullanmaktadır. Bu dağılım, hareketli parçacıklar ( $s_t^i$ ) kullanılarak modellenmekte ve bir dizi ölçüm verisiyle izlenebilmektedir. Bizim yaklaşımımda, olası bir çözüm vektörünü temsil eden her bir parçacık Gauss rassal adımlarıyla ilerleyerek hareketini geliştirmektedir;

$$s_t^i = s_{t-1}^i + \epsilon_{t-1}, \epsilon \sim \mathcal{N}(\mu, \Sigma). \quad (2)$$

Gözlemlerimiz,  $z_t = g(s_t, \eta_t)$ , gizli bir çözümün gürültülü ölçüm verisi olarak düşünülebilir. Sonsal dağılımı güncelleyen Bayes yaklaşımı ise aşağıdaki gibi yazılabilir;

$$p(s_t|z_{1:t}) \propto p(z_t|s_t)p(s_t|z_{1:t-1}). \quad (3)$$

Bu dağılımı benzetim ile belirlemenin bir yolu parçacıkların önemine göre ağırlıklandırıldığı PS yaklaşımıdır. Önem ağırlıkları kullanılarak, parçacık dağılımı belli bir yakınsamaya kadar döngüsel olarak güncellenmektedir. PS algoritması, parçacık kümesi, rassal hareket fonksiyonu ve parçacık önem ağırlıklarına bağlı olarak hareket ve ölçüm güncellemleri yapan iki aşamalı döngüsel bir algoritmadır.

Çakıştırma işlemi için PS temelli bir algoritma, Algoritma 1'de verilmiştir. Her bir parçacık,  $s_t^i$ , olası bir katı dönüşüm vektörünü,  $\mathbf{t} = [t_x \ t_y \ \theta]^T$ , temsil etmekte ve  $\mathbf{S}$  matrisinin sütunları ile gösterilmektedir. Farklı bir dönüşüm istenirse bu vektöre ilgili parametreler eklenebilir. Önem ağırlıkları ise ilerleyen alt bölümlerde ifade edileceği gibi parlaklık ve nokta temelli olarak farklı şekillerde tasarlanabilir. Algoritmda ağırlıklar bir olabilirlik fonksiyonu gibi davranışları ve  $[0, 1]$  arası değerler alan bulusal  $f(., .)$  fonksiyonu ile hesaplanmıştır. Her bir döngüde parçacıklar ağırlıkların birikimli olasılığından evrime (inversion) yöntemi ile yeniden örneklenmiştir. Algoritma 1 doğru çıkışmayı sağlayan dönüşüm vektörünü, nihai olarak

yakınsamış parçacık dağılımının beklenen değeri olarak tahmin etmektedir.

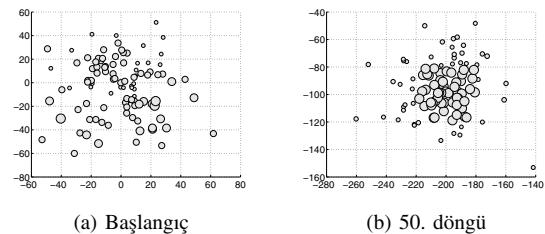
**Girdi:**  $\mathbf{I}_f$ : sabit görüntü,  $\mathbf{I}_m$ : hareketli görüntü,  $nPar$ : parçacık sayısı,  $nIter$ : döngü sayısı,  $\mathbf{M}$ : Gauss hareket modeli matrisi

**Cıktı:**  $\hat{\mathbf{t}}$  : kestirilen dönüşüm vektörü

```
// Parçacıkları ilklendir, her bir sütun bir dönüşüm vektördür
 $\mathbf{S} = \begin{bmatrix} s_{11} & s_{12} & \dots \\ s_{21} & s_{22} & \dots \\ s_{31} & s_{32} & \dots \end{bmatrix}_{3 \times nPar};$ 
2 w önem ağırlıklarını ilklendir;
3 for  $it = 1$  to  $nIter$  do
    // hareket güncellemesi
4   foreach parçacık  $s^i$  in  $\mathbf{S}$  do
        // rassal hareket
5      $\mathbf{m} = rand(\mathbf{M})$ ;
6      $\mathbf{s}^i = \mathbf{s}^i + \mathbf{m}$ ;
        // ölçüm güncellemesi
7   foreach parçacık  $s^i$  in  $\mathbf{S}$  do
8      $\mathbf{I}_m^* = \text{dönüştür}(\mathbf{I}_m, \mathbf{s}^i)$ ;
9      $w^i = f(\mathbf{I}_f, \mathbf{I}_m^*)$ ;
        // ağırlıklarını normalize et
10   $\mathbf{w} = \mathbf{w} / sum(\mathbf{w})$ ;
        // parçacıkları ağırlık dağılımına göre yeniden örnekle
11   $\mathbf{S} = \text{örnekle}(\mathbf{S}, \mathbf{w}, nPar)$ 
    // Parçacık dağılımının beklenen değerini döndür
12 return  $\hat{\mathbf{t}} = \mathbf{w}\mathbf{S}^\top$ 
```

**Algoritma 1:** 2B katı dönüşüm için parçacık süzgeçli çakıştırma algoritması

Şekil 1 önem ağırlığı yüksek parçacıkların kısa sürede çözüm etrafında ulaşma haline geldiklerini göstermektedir. Algoritma 1'deki önem ağırlıklarını farklı şekilde hesaplayan, biyomedikal görüntü işlemeye uygun parlaklık ve nirengi noktası temelli yaklaşımlarımız ise aşağıda açıklanmıştır.



**Şekil 1.** Aralarında  $t_x = 100$  ve  $t_y = 200$  piksel öteleme olan iki görüntü için parçacık dağılımı ve ağırlıkları sırasıyla başlangıçta ve 50. döngü sonrasında kabarcık grafiği ile gösterilmiştir.

**1) Parlaklık temelli Parçacık süzgeci (PPS):** MI fonksiyonunu kullanan parlaklık temelli bir önem ağırlığı fonksiyonu tanımlamak mümkündür. Böyle bir fonksiyon [4]'de aşağıdaki gibi önerilmiştir;

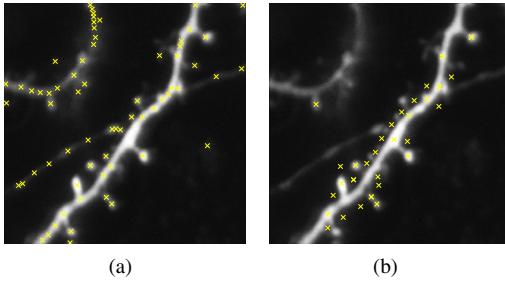
$$f(I_f, I_m) = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{(H(I_f) - MI(I_f, I_m))^2}{2\sigma^2}}. \quad (4)$$

MI normalize edilmemiş olduğundan ve  $\sigma$  değiştirmesini

belirleme zorlüğünden dolayı, biz bu fonksiyon yerine, denklem (1)'de verilen ve deneyel olarak daha iyi sonuçlar elde ettiğimiz ECC fonksiyonunun karesini kullanarak  $f(I_f, I_m)$  fonksiyonunu tahmin ettiğimiz.

*2) En parlak nirengi noktaları temelli Parçacık süzgeci (PNPS):* Zaman serilerindeki görüntülerde nirengi noktalarının bulunması, önem ağırlıklarının çakıştırılacak görüntü çiftindeki nokta eşleşmeleri cinsinden yazılmasına olanak sağlar. Bu yaklaşım parlaklık temelli yöntemden daha hızlı çalışmaktadır. Ancak, nirengi noktalarının otomatik olarak bulunup, doğru şekilde eşleştirilmesi problemi çözülmelidir. Biz bu aşamada, en parlak bölgelerin bulunması ve SIFT temelli iki farklı yöntem geliştirdik.

Nirengi noktaların bulunması için ilk yöntemimiz, verilen bir görüntüde en parlak bölgeleri temsil eden noktaların bulunmasına dayalıdır. Örneğin, dendrit floresan mikroskopı görüntülerinde, floresan seviyeleri görüntü zaman serisi boyunca değişse bile, diken (spine) gibi kısımlar çoğu zaman en parlak bölgeler olarak görülmektedir. Bölgesel en parlak noktalar basit bir eşikleme ile bulunamayabilir. Bunun yerine, döngüsel morfolojik bir geriçatma algoritması olan Genişletilmiş en parlak bölge dönüşümünü (Extended maxima transform veya *EMAX*) [8] önermektedir. Bu dönüşüm  $I$  parlaklık görüntüsünün, seçilen bir zıtlık değerine ( $h$ ) bağlı olarak en parlak bölgelerini sefer [9]. Geriçatmalı genleşme ( $\delta$ ) kullanarak ifade edilir;  $HMAX_h(I) = R_I^\delta(I - h)$ . *EMAX*, *HMAX* dönüşümünün yerel en parlak bölgeleridir. Bu bölgeler, uygulamaya göre, örneğin, piksel alanı veya en-boy oranına göre seçilerek merkez noktalarına (centroid) indirgenebilir. Bu noktalar Şekil 2(a)'da gösterildiği gibi önemli nirengi noktaları olarak kabul edilebilir.



Şekil 2. (a) En parlak nirengi noktaları (b) SIFT nirengi noktaları

Sabit ve hareketli görüntüdeki en parlak nirengi noktalarının eşleştirilmesi için şöyle bir yaklaşım kullandık; Algoritma 1'in 8. satırında, hareketli görüntüyü temsil eden nirengi noktalarına,  $i$ 'nci parçacığın temsil ettiği dönüşüm uygulandıktan sonra, her iki görüntüde belli bir komşulukta bulunan en yakın nirengi noktaları eşleştirdi.  $n_f$  ve  $n_m$  sırasıyla sabit ve hareketli görüntüdeki nirengi noktası sayıları ve  $n_{fm}$  eşleşen nokta sayısı olmak üzere, PS için parçacık önem ağırlığı aşağıdaki gibi tahmin edilebilir;

$$f(I_f, I_m) = \frac{n_{fm}}{\min(n_f, n_m)}. \quad (5)$$

*3) SIFT nirengi noktaları temelli Parçacık süzgeci (SNPS):* Diğer bir nirengi noktası temelli yaklaşım olarak, Şekil 2(b)

de gösterildiği gibi anlamlı nirengi noktaları bulabilen SIFT nokta bulucusunu [10] kullandık.

Sabit ve hareketli görüntüde bulunan SIFT noktaları 128 boyutlu bir tanımlama vektörü ile temsil edilmektedir. İki görüntü arasında eşleşen noktaları bulmak amacıyla ilk olarak sabit görüntüdeki her bir nokta ( $p_k$ ) için, hareketli görüntüde ona en yakın nokta ( $p_l$ ) ve ikinci en yakın nokta ( $p_m$ ), tanımlama vektörleri arasındaki kosinus ( $\cos$ ) benzerliğine bakılarak bulunur. Eğer  $r \cdot \cos(p_k, p_l) \geq \cos(p_k, p_m)$  ise  $p_k$  ve  $p_l$  eşleştirilmektedir. Burada  $r$ ,  $[0, 1]$  aralığında değer alan ve kullanıcı tarafından belirlenen bir uzaklık kabul oranını temsil etmektedir. Bu işlem sonucunda hala kalmış olması muhtemel aykırı eşleşmeler ise en iyi  $n$  eşleşme seçilerek giderilir.

PS algoritmasına dönersek, parçacığın temsil etiği dönüşüm hareketli görüntüye uygulandığında, daha evvelden sabit görüntü ile eşleşmiş noktalar arasındaki toplam uzaklığın minimum olmasını beklemektedir. Bu sebeple  $d(., .)$  Manhattan uzaklığı olmak üzere, ilgili parçacığın ağırlığını aşağıdaki şekilde tahmin eden bir fonksiyon tanımlanmıştır;

$$f(I_f, I_m) = \frac{1}{1 + \sum_{j=1}^n d(p_k^j, p_l^j)}. \quad (6)$$

### III. DENEY SONUÇLARI

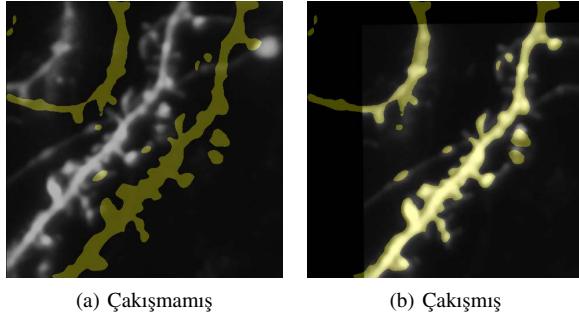
Bahsi geçen tüm temel ve önerilen yöntemler Matlab'da yazılarak test edildi. Tepe tırmanışı yöntemi ise C++ ve ITK [11] fonksiyonları kullanarak yazıldı.

Bu çalışmadaki deney sonuçları iki fotonlu floresan mikroskopbundan elde edilen dendrit kesit görüntülerinin çakıştırılmasıyla elde edilmiştir. Görüntü veritabanı Champalimaud Center for the Unknown kurumu tarafından sağlanmıştır. Deneyler için sırasıyla 54, 42 ve 38 adet  $1024 \times 1024 \times 30$  görüntü yığını içeren 3 adet zaman serisi veri kümesi kullanılmıştır. Görüntüler yığma ekseni boyunca en parlak değer seçilerek 2B'ye dönüştürülmüştür. Nihai deney girdileri ortanca süzgeci uygulamış 8 bitlik gri tonlamalı görüntülerdir. Dendrit görüntülerini özelinde 2B'ye indirgeme ve katı dönüşüm varsayımi pratik sonuçlar üreterek, diken gibi kısımların analizine olanak sağlamaktadır.

Kaba kuvvet çakıştırma yöntemi, ECC temelli amaç fonksiyonu kullanarak doğru ve gürbüz sonuçlar üretmektedir. Algoritma yeniden görüntü boyutlandırmalı ve iki aşamalı olarak koşturulmuştur. Kaba arama aşamasında, geniş bir aralıktı ve geniş adımlarla sadece öteleme için en iyi dönüşüm aranmaktadır, hassas aramada ise daha dar bir aralıktı tam arama yapılmaktadır. Ancak, bu algoritma en doğru sonuçları üretse de çok yavaş çalışabilmektedir. Algoritmanın sonuçlarını diğer elde ettiğimiz sonuçlarla kıyaslama amaçlı kullandık.

Tepe tırmanışı algoritması olarak ITK'da yazılmış etkili bir yaklaşım kullanılmıştır [7]. Sonuçlar, 10000 örneklemme sayısı ve 500 döngü ile elde edilmiştir. Özellikle sabit ve hareketli görüntü arasında dönüşümün fazla olduğu durumlarda yerel en iyi çakışmalar bulunduğu görülmüştür. Bu durum Tablo I'deki standart sapma değerlerine yansımıştır. Durumun aşılması için kullanılabilecek aşamalı çözümler algoritmanın koşma süresini daha da artıracaktır.

PS yaklaşımı yüksek doğruluklu ve gürbüz ön sonuçlar üretmiştir. Doğru çakışmayı üreten dağılıma kısa sürede yakınsamaktadır. Tüm deneylerde 100 parçacık ve 50 döngü ilklendirme değerleri kullanılmıştır. Parçacık hareketi sıfır ortalama bir Gauss dağılımı ile rassal yürüyüş olarak modellenmiş ve deney veri kümelerinin geneline uygun sabit standart sapma değerleri seçilmiştir. SIFT nirengi noktalı yaklaşımında  $n$  eşleşmelerin %20'si ve  $r = 0.9$  olarak belirlenmiştir. PS kullanarak örnek bir hizalama Şekil 3'te gösterilmiştir.



Şekil 3. PS ile çakıştırma örneği. Görüntü çiftlerinden biri görsellik amacıyla Otsu yöntemiyle eşiklenmiş ikili görüntüdür.

Algoritmaların geometrik çakışma doğruluğu ve koşma süreleri ile ilgili sonuçlar her üç veri kümesi için Tablo I'de karşılaştırılmıştır.  $t_x$  ve  $t_y$  piksel,  $\theta$  derece cinsinden olmak üzere, her bir yöntem için dönüşüm değiştirmelerinin kaba kuvvet çakıştırma sonuçları ile arasındaki ortalama mutlak değer farkı hata ölçüsü (MAE) olarak verilmiştir. MAE üzerinden standart sapma da belirtilmiştir. Ayrıca her bir veri kümesindeki amaca uygun çakışma oranı (RP) yüzde olarak alan uzmanı tarafından belirtilmiştir. Koşma süreleri (T), 2GHz çift çekirdek işlemcili 32-bitlik sisteme Matlab R2011b, gcc 4.4.3 ve ITK 3.20 kullanarak ölçülmüştür. Herhangi bir yazılım paralelleştirmesi kullanılmamıştır. Kaba kuvvet çakıştırma süresi, seçilen arama aralığına göre dramatik olarak değişimlektedir. Aralıklar deneylerde tam doğruluğu sağlamak amacıyla yeterince geniş tutulmuştur. Zaman serilerinden 30'ar çakıştırma örneği alınmış ve  $\alpha = 0.025$  seçilerek tek kuyruklu eşli  $t$ -testi uygulanmıştır. Genel olarak PNPS ve SNPS hataları arasındaki fark istatistik olarak anlamlı olmamakla beraber, TT ve PPS ile karşılaştırıldıklarında bu yöntemlerden daha üstün olabildikleri görülmektedir.

#### IV. VARGILAR

Parçacık süzgecini esas alan, parlaklık ve nirengi noktası temelli bir dizi biyomedikal görüntü çakıştırma yöntemi önerilmiştir. Sunulan ön sonuçlar, PS temelli yöntemin görüntü zaman serilerinin çakıştırılmasında yüksek doğruluklu ve gürbüz bir yaklaşım olarak kullanabilirliğini göstermektedir.

Bu çalışmada PS yaklaşımı en temel hali ile kullanılmış olup, yaklaşım örneğin genetik algoritma ve sürü en iyilemesi gibi yöntemlerden esinlenerek daha da güçlü hale

Yöntem	$t_x$		$t_y$		$\theta$		RP	T (sn)
	MAE	$\sigma$	MAE	$\sigma$	MAE	$\sigma$		
KK	0	0	0	0	0	0	%100	126,31
TT	18,37	20,63	9,90	12,39	<b>0,36</b>	0,76	%81	32,05
PPS	6,47	5,10	10,77	7,14	0,45	0,37	%91	16,42
PNPS	10,21	7,53	6,34	5,08	0,82	0,60	%83	<b>4,65</b>
SNPS	<b>5,47</b>	4,51	<b>5,21</b>	4,01	0,61	0,47	<b>%94</b>	6,66

Yöntem	$t_x$		$t_y$		$\theta$		RP	T (sn)
	MAE	$\sigma$	MAE	$\sigma$	MAE	$\sigma$		
KK	0	0	0	0	0	0	%100	121,13
TT	11,73	27,97	21,18	59,74	0,65	2,42	%83	31,52
PPS	19,95	15,39	8,95	5,63	<b>0,41</b>	0,29	%83	16,25
PNPS	<b>5,44</b>	5,98	<b>5,88</b>	5,88	0,88	1,15	<b>%98</b>	<b>2,94</b>
SNPS	5,61	5,94	7,17	5,79	0,90	1,02	%93	6,34

Yöntem	$t_x$		$t_y$		$\theta$		RP	T (sn)
	MAE	$\sigma$	MAE	$\sigma$	MAE	$\sigma$		
KK	0	0	0	0	0	0	%100	128,74
TT	14,36	35,80	9,87	13,75	0,37	1,01	%95	30,29
PPS	7,68	6,47	8,35	8,26	0,42	0,36	%95	17,12
PNPS	3,35	2,31	3,32	2,42	0,40	0,30	%100	<b>4,88</b>
SNPS	<b>2,32</b>	1,76	<b>2,41</b>	2,34	<b>0,30</b>	0,22	<b>%100</b>	9,17

Tablo I. ÜÇ DEĞİŞİK GÖRÜNTÜ ZAMAN SERİSİ İÇİN KATI DÖNÜŞÜMLÜ ÇAKIŞTIRMA DOĞRULUK ÖLÇÜMÜ VE KOŞMA SÜRELERİ

getirilebilir [2]. Ayrıca deney sonuçları varsayılan ilklendirme değerleri ile elde edilmiş olup, veriye özel ilklendirme yapıldığında çakıştırma hatalarının azaldığı gözlemlenmiştir.

Yaptığımız deneylerde, nirengi noktası temelli yöntemler daha yüksek doğruluklu sonuçları daha hızlı üretmiştir. Bu yöntemlerin, 3B analiz ve daha fazla değiştirebilir dönüşümler için de daha uygun olabileceği düşünülmektedir.

#### TEŞEKKÜR

Analiz verilerini sağlayan Champalimaud Centre for the Unknown araştırmacıları Dr. Yazmin Ramiro-Cortes ve Dr. Inbal Israeli'ye teşekkür ederiz.

#### KAYNAKÇA

- [1] Bankman, I., "Handbook of Medical Image Processing and Analysis", Academic Press, 2008.
- [2] X. Zhang, X., Hu, W., ve Maybank S., "A Smarter Particle Filter", LNCS, Computer Vision - ACCV, Cilt 5995, Sayfa 236-246, 2009.
- [3] Yilmaz, A., Javed, O. ve Shah, M., "Object tracking: A survey", ACM Comput. Surv., Cilt 38-4, art. no. 13, 2006.
- [4] Arce-Santana, Edgar R. and Campos-Delgado, D. U. ve Alba, A., "Image Registration Guided by Particle Filter", Springer LNCS Advances in Visual Computing, Cilt 5875, Sayfa 554-563, 2009.
- [5] Wells III W. M., Maes F. ve Pluim J. P. W., "Information theoretic similarity measures for image registration and segmentation", MICCAI 2009 Tutorial, 2009.
- [6] Wells III W. M., Viola P., Atsumi H., Nakajima S. ve Kikinis R., "Multi-modal volume registration by maximization of mutual information", Medical Image Analysis, Cilt 1, Sayfa 35-51, 1996.
- [7] Mattes D., Haynor, D. R., Vesselle, H., Lewellen, T. K. ve Eubank, W., "PET-CT image registration in the chest using free-form deformations", IEEE Transactions on Medical Imaging, Cilt 22 (1), Sayfa 120-128, 2003.
- [8] Soille, P., Morphological Image Analysis: Principles and Applications, 2. baskı, Springer-Verlag, NY, 2003.
- [9] Erdil, E., Yagci, A.M., Argunsah, A.O., Ramiro-Cortes, Y., Hobbiss, A.F., Israeli, I. ve Unay, D., "A tool for automatic dendritic spine detection and analysis. Part I: Dendritic spine detection using multi-level region-based segmentation", In proc. Image Processing Theory, Tools and Applications, IPTA, 2012.
- [10] Lowe, D.G., "Distinctive image features from scale-invariant keypoints", Int. Journal of Computer Vision, Cilt 60(2), Sayfa 91-110, 2004.
- [11] Ibanez, L. ve Schroeder, W., The ITK Software Guide 2.4, Kitware Inc., 2005.