

1. İNOVATİF TIP TEKNOLOJİLERİ VE YAPAY ZEKA KONGRESİ

26-27 Nisan 2024
Kütahya

KONGRE KİTABI

EDİTÖRLER

Prof. Dr. Ahmet Tekin
Dr. Öğr. Üyesi Can Özlü
Dr. Öğr. Üyesi Aycan Acet
Dr. Öğr. Üyesi Sema Üstündağ
Dr. Öğr. Üyesi Gamze Ünver
Dr. Öğr. Üyesi Nilüfer Köylüoğlu
Dr. Öğr. Üyesi Ahmet Güven

Derin Öğrenme Yöntemlerine Ön Faz Oluşturabilme Adına Yüksek Gürültü Seviyesine Sahip Medikal İmgelerin Konvansiyonel Yöntemlerle Grup Halinde Hizalandırılmaları

Baranalp ÖZTÜRK¹, Ahmet BAŞTUĞ²

1. Giriş ve Amaç

Grup bazında görüntü hizalama yöntemleri, birden fazla görüntünün hizalanmasının ve karşılaştırılmasının gerekli olduğu bilimsel ve endüstriyel uygulamalarda çokça uygulanmaktadır. Bu yöntemler, özünde her görüntüyü tek bir referans görüntüye hizalamak yerine, birden fazla görüntünün birlikte/birarada en iyi hizalanmasını sağlarlar [1, 2, 3, 4]. Oldukça kıymetli olan bu yöntemler, pek çok diğer sahada da geçerli olmakla birlikte, özellikle tıbbi görüntülemede, verilerin karmaşıklığı ve değişkenliğinin yanısıra, hizalama sürecinin kendine has ideal olmayan karakteristiklerinden dolayı da çeşitli ve de zorlu sorunlarla karşılaşmaktadırlar. Yine tüm sahalarda geçerli olacak şekilde, uygulama çeşitliliklerinin ve de saha sınırlamalarının, kaygıların, bütçe, zaman, insan kaynağı farklılıklarının çokluğu nedeniyle tercih edilen yöntemler özelinde de çeşitlilik oluşmaktadır [5]. Yine benzer nedenlerden, tercih edilen geliştirme/yazılım unsurları, programları da kurumların koşullarına bağlı olarak değişmektedirler.

Bildirinin bu ilk bölümünde bahsi geçirilen kritik unsurlar/bileşenler daha detaylı olarak ele alınacaktır. Devamında, grup halinde imge hizalamanın *gürültülü* imgelerde, *hizalama yapılmayan* ve sadece *tek bir imge üzerinden gürültü bastırımı yapılan* sonuçlarla kıyası yapıp, farklı durumlardaki dayanıklılığı görselleştirecektir.

En nihai sonuç ve tartışma bölümünde ise araştırmalarımız ve yazılım kullanım tecrübelerimiz dahilinde açıklama ve değerlendirmelerimizi yapıp gelecek çalışmalarımızda bize ışık tutacak öngörülerimizi ortaya koyacağız.

¹ Lisans Öğrencisi, Kütahya Sağlık Bilimleri Üniversitesi Bilgisayar Müh., baranalp.ozturk@ksbu.edu.tr

² Dr. Öğretim Üyesi, Kütahya Sağlık Bilimleri Üniversitesi Bilgisayar Müh., ahmet.bastug@ksbu.edu.tr, ORCID iD: <https://orcid.org/0009-0005-9396-8858>

1.1 Kullanım Alanları

Grup halinde görüntü hizalama yöntemleri, bilimsel ve endüstriyel alanlardaki görüntülerin analizlerini, karşılaştırılmalarını ve entegrasyonlarını kolaylaştıran yöntemlerdir. Karar verme, izleme ve optimizasyon amaçlarıyla kullanılabilirler. Bütün bu nedenlerden ve başkaca çokça nedenden dolayı aşağıdaki alanlarda kendisine yer bulmuştur.

1.1.1 Tıbbi Görüntüleme Örnekleri

Görüntü hizalama, tıbbi görüntüleme alanında önemli bir rol oynamaktadır. Hastalıkların teşhisinde, tedavi planlamasında ve hasta takibinde kritik öneme sahiptir. Özellikle, *grup tabanlı* hizalama yöntemleri, çoklu görüntü setlerinin bir arada değerlendirilmesini sağlayarak, hastalıkların daha doğru bir şekilde tanımlanmasına ve izlenmesine olanak tanır. En çok bilinen 3 uygulama alanı aşağıdaki gibidir.

Farklı Kişilerden Alınan Verilere Dayalı Analiz: İstatistiksel analiz ve anatomik farklılıkları anlamak için farklı hastalardan alınan görüntülerin hizalanması ilkesine dayanır [6].

Zamansal Görüntü Dizisi Analizi: Bir hastalığın ilerlemesini, tedavi sonuçlarını ve zaman içinde ortaya çıkan değişiklikleri incelemek için aynı kişiden farklı zamanlarda elde edilen görüntülerin hizalanması ilkesine dayanır [7].

Farklı Sensörlerden Kaynaklı Görüntülerin Füzyonu: Birbirini tamamlayıcı görüntüleme yöntemlerini (MRI, CT, PET,vb) kullanarak teşhisi güçlendirmeye yönelik bir yaklaşımdır [8].

1.1.2 Sinir Bilimi Örnekleri

Beyin Haritalaması: Bu yöntem yapısal ve işlevsel beyin görüntülerinin bireyler arasında hizalanması ilkesine dayanır [9].

Beyin Gelişimi Çalışmaları: Bu yöntem beyin gelişimini incelemek ve nörolojik bozuklukları belirlemek için zaman içinde elde edilen farklı görüntülerin hizalanması ilkesine dayanır [10].

1.1.3 Biyomedikal Araştırma Örnekleri

Onkoloji: Kanser hastalarından alınan tıbbi görüntülerin, örneğin tümör büyümelerinin, hizalanması ilkesine dayanır [11].

Kardiyoloji: Miyokard fonksiyonunu gözlemleyip analiz etmek ve kardiyovasküler hastalıkları incelemek için farklı hastalardan alınan kalp görüntülerinin hizalanması ilkesine dayanır [12].

Ortopedi: Eklemleri analiz etmek ve ortopedik ameliyatlara planlamak için kas ve iskelet sistemi görüntülerinin hizalanması ilkesine dayanır [13].

1.1.4 Bilgisayarla Görme Örnekleri

Uzaktan Algılama: Uydu veya hava görüntülerinin, LIDAR taramalarının hizalanması vesilesiyle arazi sınıflandırması, zamanla ortaya çıkan değişikliklerin tespiti ilkesine dayanır [14].

Robotik: Robotlara monte edilmiş sensörlerden veya kameralardan gelen görüntülerin hizalanması vesilesiyle konumlama, haritalama ve navigasyon ihtiyaçlarını karşılamayı amaçlar [15].

Nesne Tanıma ve İzleme: Nesne tanıma, nesne takibi ve 3 boyutlu gerçekleştirme için sahne görüntülerinin farklı bakış açılarından hizalandırılmaları ilkesine dayanır [16].

Petrol ve Gaz Aramaları: Petrol/gaz kuyularından elde edilen sismik görüntüleri hizalama, yeraltı yapılarını haritalama ve sondaj operasyonlarını planlama için kullanılır [17].

1.1.5 İmalat ve Kalite Kontrol

Bu yöntem üretim süreçlerinde, üretimin farklı aşamalarından elde edilen ürünlerin görüntülerini hizalamak ve analiz etmek için grup bazında görüntü hizalanması ilkesine dayanır. Bir yandan da sağlıklı/referans ürünlerle üretimden elde edilen görüntüleri karşılaştırarak üretilen parçalardaki kusurların, tutarsızlıkların veya sapmaların tespit edilmesini sağlar [18].

1.2 Uygulamadaki Zorluklar

Tıbbi görüntülerin hizalanması bağlamında aşağıda listelenen zorlukların üstesinden gelebilmek için tıbbi görüntüleme, bilgisayarla görme, optimizasyon, makine öğrenimi ve klinik alan bilgisindeki uzmanlığı içeren çok disiplinli bir yaklaşım gerekmektedir.

Popülasyon Değişkenliği: Tıbbi görüntüleme verileri dahilinde genellikle bireyler arasında görüntüleme özelliklerinde önemli farklılıklar gösterir.

Hesap Karmaşıklığı: Grup bazında hizalama kapsamında, birden fazla görüntünün aynı anda hizalanmasını içermesinden dolayı ikili hizalama ile karşılaştırıldığında, hesaplama karmaşıklığı önemli ölçüde artabilir. Bu problem özellikle büyük veriyle çalışıldığında daha da artacaktır.

Çok Modlu Hizalama: Farklı görüntüleme yöntemlerinden (MRI, CT, PET) görüntülerin hizalanması durumunda, görüntülerin pozları, çözünürlükleri ve kontrastlarındaki farklılıklar problem teşkil edecektir.

Doğrusal Olmayan (Nonlinear) Bozulmalar: Tıbbi görüntülerdeki anatomik yapılar karmaşık ve de doğrusal olmayan bozulmalar içerebilir.

1.3 Teknolojinin Güncelinde Öne Çıkan İki Ayrı Yaklaşım

Önceki bölümlerde bahsi geçirilen uygulamaları hayata geçirebilmek ve zorlukların üstesinden gelebilmek adına aşağıda izah edileceği üzere *geleneksel ama oturmuş yöntemler* ile *modern ama yeterince olgunlaşmamış ya da ne yaptıkları çoğu zaman çok iyi anlaşılamayan yapay zeka yöntemleri* kullanılmaktadır.

1.3.1 Konvansiyonel Bilgisayarlı Görü Yöntemleri

Yoğunluğa Dayalı Yöntemler: Hizalandırılan görüntülerdeki karşılık gelen piksellerin ya da voksellerin (3 boyutlu en küçük görüntü parçaları) yoğunluk (intensity) değerleri arasındaki benzerlik metriğinin optimize edilmesine dayanırlar [3].

Özellığe Dayalı Yöntemler: Hizalama işlemi için görüntülerdeki önemli noktaları veya yer işaretlerini kullanırlar. Kullanılan ortak özellikler arasında köşeler, kenarlar veya diğer ayırt edici görüntü özellikleri bulunur [19].

Optik Akı Yöntemleri: Görüntü özelliklerinin zaman içindeki hareketini izleme ilkesine dayanırlar [20].

Bu en bilinen yöntemlerden ayrı *B-Spline Deformasyonu*, *Serbest Biçimli Deformasyon (FFD)*, *Şablon Tabanlı Yöntemler*, *Karşılıklı Bilgi Maksimizasyonu*, *Çok Ölçekli Hizalama* ve *Grafik Tabanlı Yöntemler* şeklinde daha pek çok konvansiyonel yöntem vardır.

1.3.2 Gelişkin Derin Öğrenme Yöntemleri

Bildirinin ana temasını içermemelerinden dolayı, bu bölümde Gelişkin Derin Öğrenme Yöntemlerinin sadece isimleri listelenecektir [21]: *Evrışimli Sinir Ağları (CNN)*, *Siyam Ağları, Üretken Rekabetçi Ağlar (GAN)*, *Uzamsal Transformatör Ağları (STN)*, *Grafik Sinir Ağları (GNN)*, *Tekrarlayan Sinir Ağları (RNN)*.

1.3.3 İki Gruptaki Yöntemlerin Avantaj ve Dezavantajları

Konvansiyonel yöntemler genellikle tanımlı algoritmalara ve elle hazırlanmış özelliklere dayanır ve gerçek zamanlı veya kaynak kısıtlı uygulamalara oldukça uygundurlar. Köklü matematiksel ilkelere ve teorilere dayanmaktadırlar ve de bu durum algoritmaların anlaşılması ve geliştirilmesi için sağlam bir temel oluşturur. Öte yandan genellikle *manuel özellik* çıkarmaları gerektiğinden fazlaca emek gerektirirler. Bir yandan da başarımları büyük ölçüde manuel özelliklerin kalitesine bağlıdır. Bu manuel özellikler sınırlı temsile sebep olduklarından önemli değişkenlik veya karmaşıklık içeren senaryolarda performansları düşebilir; gerçek dünya sahnelerinin karmaşıklığıyla da baş etmekte zorlanabilirler.

Derin Öğrenme yöntemlerine gelecek olursak, manuel özellik mühendisliği ihtiyacı olmadığından *doğrudan ham verilerle* çalışabilirler. Bu uçtan uca öğrenme yaklaşımı, verilerdeki karmaşık kalıpları ve ilişkilerin yakalanmasını sağlayabilir. Derin öğrenme mimarileri esnek ve uyarlanabilir olup, minimum düzeyde değişiklik veya yeniden eğitim ile çok çeşitli bilgisayarlı görme görevlerine uygulanmalarına olanak tanır. Öte yandan, olumsuzluk adına derin öğrenme yöntemleri, yüksek performans elde etmek amacıyla eğitim için genellikle büyük miktarda etiketli veri gerektirir. Etiketli verilerin elde edilmesi pahalı, zaman alıcı veya mümkün olmayabilir. Derin öğrenme modelleri çoğunlukla kapalı sistemler olduklarından, elde ettikleri neticelerin yorumlanması veya açıklanması zor olabilir. Derin öğrenme modellerinin eğitimi, yüksek maliyetli hesaplamalar gerektirebilir ve GPU gibi özel donanımlar gerektirebilirler. Derin öğrenme modelleri, özellikle sınırlı veya gürültülü verilerle eğitildiklerinde datalarla aşırı uyum (overfitting) yapabilirler.

Özetlemek gerekirse, geleneksel ve derin öğrenme yöntemleri arasında yapılacak tercih, etiketli verilerin kullanılabilirliği, hesaplama kaynakları, yorumlanabilirlik gereksinimleri ve eldeki görevin karmaşıklığı gibi faktörlere bağlıdır. *Birinin diğerine üstünlüğünü iddia etmek doğru bir yaklaşım olmaz. Aslında belki de en ideal yaklaşım her ikisinin de peşi sıra bir arada kullanılmasıdır.*

2. Yüksek Gürültülü Medikal Görüntü Gruplarının Konvansiyonel Bir Yöntemle Hizalandırılması

Son yıllarda, tıbbi görüntüleme teknolojilerindeki gelişmeler, görüntü kalitesini ve elde edilen verilerin doğruluğunu önemli ölçüde artırmıştır. Lakin, eski ya da bir nedenden verimliliğini yitirmiş cihazlardan alınan ya da farklı zaman dilimlerinde veya farklı cihazlar tarafından üretilen görüntülerin hizalanması idealden uzak olup zorluklar içerecektir. Bu zorlukların üstesinden gelebilmek için geliştirilen grup tabanlı hizalama yöntemleri, bu görüntüler arasındaki sürekliliği ve tutarlılığı sağlamak amacıyla kritik bir işlev görecektir. MATLAB tarzı ticari yazılımlar veya açık kaynaklı yazılımlar kullanımıyla (örneğin SimpleElastix), bu yöntemlerin uygulanması, çeşitli tıbbi görüntüleme görevlerinde doğruluk ve verimliliği artırma potansiyeline sahiptir.

Bu bölümde ele aldığımız yazılımsal ve algoritmik çalışmanın amacı grup tabanlı hizalama süreçlerinin uygulanabilirliğini, etkinliğini ve tıbbi görüntüleme alanındaki potansiyel katkılarını sistematik bir şekilde incelemektir.

2.1 Yöntem

Yüksek miktarda gürültü içeren ya da ideal olmayan görüntü pozlamasından kaynaklı görüntü kayıplarının olduğu bir imge örneğine sahip olduğunda zaafiyeti gidermek adına aynı görselden çok daha fazla örneğe sahip olmak isteriz. Aynı ayrı incelemelerde her ne kadar birinin eksikliğini diğeri tamamlar noktada olabilecekse de daha iyisi hepsinin hizalanıp eş güdümlü hale getirilmesidir. Sinyal işleme sahasında çok iyi bilindiği üzere bir sinyal unsurundan çokça kopyanın ortalaması alındığında o oranda gürültü varyansı azalır. Lakin bu yalnızca 100% mertebede senkronizasyonun (bizim şu an ele aldığımız mevzuda hizalı olmanın) geçerli olduğu durumlarda doğrudur. Aksi taktirde, ortalama işlemi alındığında tek imgenin sağladığından çok daha kötü bir neticeyle karşı karşıya kalınabilir. Biz bu çalışmada, bu bağlamdaki kazanımları ve sınırlamaları simülasyon çalışmalarıyla gözlemlemek ve görselleştirmek istedik. Çalışmaya başlamadan önceki beklentilerimiz, gürültü varyansının yüksek olduğu veya görüntüler arasındaki *transitional* ya da *rotational* farklılıkların az olduğu durumlarda (simülasyonlarımızda sadece *rotation* kullandık) hizalamadan iyi bir kazanç elde edilebileceği, tersi yönde durumlarda ise kazancın çok azalabileceği ya da kayba dönebileceği noktasındadır.

Simulasyon ve Modelleme mahiyetinde sırasıyla şu aşamalardan oluşan bir yazılım/algoritma yapısı kurguladık:

Aşama 1: 8-bit çözünürlüklü gri-tonlu bir medikal imge okuduk.

Aşama 2: İkinci bir imge oluşturma adına daha önceden tanımlanan bir standart sapma ölçeğinde (örneğin $\sigma_n = 32$) ve de sıfır ortalamalı rastgele *Gaussian* gürültü ekledik.

Aşama 3: Şekil 1’de temsil edildiği üzere *Rotational* dönüşümlerle yine daha önceden tanımlı açısız dönme adımları (örneğin $\Delta_\theta = 0.2$ derece) mahiyetinde çokça yeni imge (örneğin, bir durumda 29 ilave görüntü kullandığımızda ilki orijinal imgeye göre 0.2, sonuncusu 5.8 derece dönmüş olacak şekilde) ürettik ve onlara da Aşama 2’de yapıldığı miktarlarda rastgele gürültü ekledik.

Aşama 4: Daha sonra kıyaslama yapma adına (iyi netice vermeyeceğini bilmemize rağmen) 3. aşamada elde edilen tüm görüntülerin ortalamasını alarak hizalanmamış bir imge daha elde ettik.

Aşama 5: Şekil 2’de temsil edildiği üzere Vishnevskiy et.al [22]’de anlatılan algoritmik yaklaşımla uyumlu olarak, 3. aşamada elde edilen çokça görüntünün grup halinde hizalanmasından ve akabinde *hizalanmış tüm imgelerin ortalamasının alınmasından* yeni bir imge daha elde ettik.

Aşama 6: Esaslı/hedef kıyaslamayı yapma adına 2. aşamada elde ettiğimiz gürültülü görüntüyü *Gaussian* filtre (*blurring* işlemi) ile *denoising* işleminden geçirdik ve bir imge daha elde ettik. Bunu yaparken de adil olma adına, denemelerle en ideal *sigma* değerini (σ_f) bulup kullanarak gürültü bastırımı ile keskinlik koruma arasındaki dengeyi oluşturmaya çalıştık.

Bundan sonraki anlatımlarda faydalı olması adına 1. aşama çıktısına *orijinal* imge, 2. aşama çıktısına *gürültülü* imge, 4. aşama çıktısına *ortalama* imge, 5. aşama çıktısına *hizalanmış* imge, 6. aşama çıktısına da *gürültü bastırılmış* imge isimlendirmelerini yapacağız.



Şekil 1 Rotational Dönüşümlerle $\Delta_{\theta} = 0.2$ açısal adımlar



Şekil 2 Grup Halinde Hizalanma (referans görüntü hariç)

2.2 Simulasyon Sonuçları



Şekil 3 “Data_Seti_1”, Orijinal İmge.



Şekil 4 “Data_Seti_1”, Gürültülü İmge ($\sigma_n = 32$).



Şekil 5 “Data_Seti_1”, 29 İmgenin ($\Delta_{\theta} = 0.1$ derece) Ortalama İmgesi.



Şekil 6 “Data_Set1”, Gürültü Bastırılmış İmge ($\sigma_f = 2$).



Şekil 7 “Data_Seti_1”, 29 İmgenin ($\Delta\theta = 0.1$ derece) Hizalanmış İmgesi.



Şekil 8 “Data_Seti_2”; Orijinal İmge.



Şekil 9 “Data_Seti_2”; Gürültülü İmge ($\sigma_n = 32$).



Şekil 10 “Data_Seti_2”; 29 İmgenin ($\Delta\theta = 0.1$ derece) Ortalama İmgesi.



Şekil 11 “Data_Seti_2”; Gürültü Bastırılmış İmge ($\sigma_f = 2$).



Şekil 12 “Data_Seti_2”; ($\Delta\theta = 0,1$ derece) Hizalanmış İmgesi.




Şekil 13 “Data_Seti_3”; Sol, Orijinal ve Sağ, Gürültülü İmge ($\sigma_n = 18$).



Şekil 14 “Data_Seti_3”; Sol, Gürültü Bastırılmış İmge ($\sigma_f = 2$);

Sağ, 29 İmgenin ($\Delta_\theta = 0.2$ derece) Hizalanmış İmgesi.



Şekil 15 “Data_Seti_4”; Sol, Orijinal ve Sağ, Gürültülü İmge ($\sigma_n = 10$).



Şekil 16 “Data_Seti_4”; Sol, Gürültü Bastırılmış İmge ($\sigma_f = 2$);
Sağ, 29 İmgenin ($\Delta_\theta = 0.3$ derece) Hizalanmış İmgesi.

Yukarıda 4 ayrı data seti üzerinden elde edilen görsel neticeler paylaşılmıştır. Birinci data setinden *Şekil 3 ila Şekil 7* arasındaki neticeler, ikinci data setinden *Şekil 8 ila Şekil 12* arası neticeler, üçüncü data setinden *Şekil 13 ve Şekil 14*, dördüncü data setinden de *Şekil 15 ve Şekil 16* elde edilmiştir.

İlk iki data setinde (her bir data seti kendi içinde değerlendirilmelidir; bu iki data seti ortak parametrelere sahip oldukları için anlatımları da ortaklaştırılmıştır) *yüksek seviyede* bir gürültü miktarı ($\sigma_n = 32$) ve bir imgeden bir sonraki imgeye (ki bu 29 imge boyunca sürdürülmüştür) *düşük seviyede* bir dönme açısı adımı ($\Delta\theta = 0.1$ derece) seçilmiştir. Elde ettiğimiz bulgular şu şekildedir:

- $\Delta\theta$ açısının azlığından dolayı, tüm imgeler üzerinde işletilen grup temelli hizalama, *Şekil 7'den ve Şekil 12'den* anlaşılacağı üzere oldukça başarılı bir şekilde gerçekleşmiştir. Bu kanaate, imgelerin *keskinliğinin* (sharpness) yüksek olmasından dolayı varıyoruz.
- Bu başarılı hizalama sayesinde ve de her bir *girdi* imgesi özelindeki σ_n gürültü değeri *yüksek* tutulduğundan, yine *Şekil 7'den ve Şekil 12'den* anlaşılacağı üzere çıktı imgesinin gürültüsü oldukça iyi bir şekilde *bastırılmıştır*.
- Yine, *Şekil 7 ve Şekil 12* imgelerini *Şekil 5 ve Şekil 10* imgeleriyle kıyasladığımızda *keskinlik* seviyelerinin çok daha iyi olduğu görülmektedir. Burada ortaya çıkan keskinlik farkına *hizalama kazancı* şeklinde yaklaşabiliriz.
- Son olarak, *Şekil 7 ve Şekil 12* imgelerini *Şekil 6 ve Şekil 11* imgeleriyle kıyasladığımızda *gürültü* seviyelerinin çok daha az olduğu görülmektedir. Burada ortaya çıkan gürültü seviyesi farkına *gürültü bastırma kazancı* şeklinde yaklaşabiliriz. Burada vurgu yapmamız gereken konu; *Şekil 7 ve Şekil 12'de* doğaları gereği (daha önce de bahsedildiği üzere bir sinyal/görüntü unsurundan çokça kopyanın *ortalaması* alındığında, *sinyal/görüntü sayısı oranında* gürültü varyansı azalır), *implicit* (örtülü) bir şekilde gürültünün bastırıldığıdır. Burada yapılan gürültü bastırma işlemi aslında bir *temporal filtering* (zamanda filtreleme) işlemi olmaktadır. Kıyaslamada kullanılan *Şekil 6 ve Şekil 11'deki* elde edilen neticeler ise *explicit* (açık) bir şekilde yapılan *spatial filtering* (uzaysal filtreleme) gürültü giderme işlemidir. Lakin bu *en yüksek* gürültü bastırma kazancı, hizalamanın mükemmel olduğu durumlarda geçerli olacak olup, kazanç miktarı *hizalamadaki kayma miktarıyla* ve de *imgelerin sahip oldukları frekans bileşenlerinin yüksekliği ölçeğinde* azalabilecektir. En temel amaç gürültü bastırmak olduğunda, en ideal yaklaşım hem spatial hem de temporal filtrelemeyi bir arada kullanan yaklaşımlar türetmektir. Bu bağlamda da çokça farklı

yaklaşım benimsenebilir. Görüntüleri önce *spatial* filtreden geçirip sonrasında *temporal filtering* (hizalama sonrası zamansal ortalama) işleminden geçirmek bir yaklaşım olabilir. Bu işlemlerin sırasını tersine çevirmek bir başka alternatif yaklaşım olabilir. Daha ideali ise, bu işlemleri *spatiotemporal filtering* dahilinde birarada (*jointly*) yapmak olacaktır. En gelişkinlik adına da ilave bir katkı olarak RANSAC (Random Sample Consensus) kullanımıyla, görüntü dizisi içerisinde hizalamada uyumsuzluk oluşturanları devre dışı bırakmak akılcı bir yaklaşım olacaktır.

Üçüncü data setinde *orta seviyede* bir gürültü miktarı ($\sigma_n = 18$) ve bir imgeden bir sonraki imgeye (ki bu 29 imge boyunca sürdürülmüştür) yine *orta seviyede* bir dönme açısı adımı ($\Delta_\theta = 0.2$ derece) seçilmiştir. Her iki unsur da ele aldığımız hizalama yönteminin başarımı için gerekli ideal koşullardan bir miktar uzaklaştırılmış olduğundan, haliyle, *Şekil 14'den* de anlaşılacağı üzere, hizalama başarımları az seviyede oluşmuştur. *Spatial filtering* (uzamsal filtreleme) gürültü giderme işlemi ile kıyasladığımızda *gürültü performansı* bağlamında çok az geride kalmakla birlikte *keskinlik performansı* mahiyetinde hala oldukça daha iyi noktadadır. Lakin yavaş yavaş da olsa, hizalama kusurlarından kaynaklı yapısal kusurlar (*artifact*) ortaya çıkmaya başlamaktadır. Bu ara seviyeler bir nevi grup temelli hizalama yaklaşımının *kırılma* seviyeleridir.

Son olarak, dördüncü data setinde, *daha da azaltılmış seviyede* bir gürültü miktarı ($\sigma_n = 10$) ve *bir miktar daha artırılmış seviyede* bir dönme açısı adımı ($\Delta_\theta = 0.3$ derece) seçilmiştir. Her iki unsur da ele aldığımız hizalama yönteminin başarımı için gerekli ideal koşullardan oldukça fazla uzaklaştırılmış olduğundan, beklendiği üzere ve de *Şekil 16'dan* da anlaşılacağı üzere, hizalama başarımı artık düştüğü görülebilir noktadadır. *Spatial filtering* (uzamsal filtreleme) gürültü giderme işlemi ile kıyasladığımızda, *gürültü performansı* bağlamında da, *keskinlik performansı* mahiyetinde de çok daha kötü noktada olup hizalama kusurlarından kaynaklı yapısal kusurlar da (*artifact*) iyice ortaya çıkmış, fazlaca kopma ve kırılmalar olmuştur.

3. Sonuç ve Tartışma

Bu bildiride önce grup halinde görüntü hizalama konusunun alt yapısını oluşturduktan sonra yaptığımız yazılımsal ve algoritmik çalışmaları ve sonuçlarını sunduk. Konvansiyonel yaklaşımlar kapsamında ele alınan bu örnekler ve benzeri çalışmalar daha da gelişkin derin öğrenme tarzı çalışmalara ön zemin hazırlama (preprocessing) mahiyetinde kullanılabilecek yöntemler olarak da görülebilir.

Derin öğrenme her ne kadar iyi uygulandığında state-of-the-art mahiyetinde rol sergileyebilecek olsa da kapalı, yaptıkları çok iyi anlaşılıp yorumlanamayan bir yanı olmasından dolayı ve de çoğu zaman çok pahalıya gelebilecek şekilde ve de data toplama esnasında zaman gerektirecek şekilde meşakkatli olacağından; zorlukları fazla, pek çok vakit kullanılmayacak bir yaklaşım olacaktır. Aslında her bilgisayarlı görüntü çalışmasının, hele ki yapay sinir ağları içeren derin öğrenme yönteminin, daha kararlı ve başarılı olmasını sağlayacak çokça ön data işleme fazları vardır. Bir yapay sinir ağları içeren ve grup temelli görüntü hizalama yapan derin öğrenme yönteminin kullanabileceği ön faz işlemler arasında görüntülerin gürültülerini azaltma/bastırma, histogram eşitleme, görüntüleri kesme/kırpma ve veriler üzerinde yapılabilecek veri büyütme (data augmentation), veri dengeleme gibi işlemler olabileceği gibi bu çalışmada örnekleri gösterildiği gibi bizzat bir konvansiyonel grup temelli görüntü hizalama işlemi de bir nevi işi önden kabaca kotararak derin öğrenme yönteminin ortaya koyması gereken eforu ve data ihtiyacını ya da model karmaşıklığını azaltacaktır. Bir başka faydası da konvansiyonel yaklaşımlarla bir nevi daha bir saha hakimiyeti olacağından akabindeki derin öğrenme yönteminin de neler yapabileceği konusunda daha az belirsizlik olacaktır.

Bu bildiri, bir nevi, grup bazında görüntü hizalama yöntemlerinin gereksinimlerini ve zorluklarını anlamaya yönelik ve de gelişkin derin öğrenme yöntemlerine başlamadan önce konvansiyonel yöntemleri iyi anlamak ve uygulamalar noktada olmanın önemini vurgulamaya yönelik yazılım çalışmalarını ihtiva eder olmuştur. Gelecek çalışmalar mahiyetinde önce bu çalışmaları daha da olgunlaştırıp daha sonra da bu çalışmaları derin öğrenme yöntemlerine taşımak amaçladıklarımız arasındadır. Bir başka üzerine eğilmeyi düşündüğümüz mevzu da verilerin toplandığı kamera, sensör ya da başkaca görüntüleme teknolojilerinde -çalışmalarımız sadece medikal sahaya sınırlı değildir- çokça kaynaktan alınan görüntülerin/datanın en sağlıklı olarak ne şekilde *birarada alınabileceği* konusudur. Literatürde çokça kameradan ya da bir kameradan çokça farklı zamanlarda alınan görüntülerin kaynağında ya da da kaynaklarında en sağlıklı şekillerde alınabilmeleri (*acquisition*), içsel ve dışsal kamera parametrelerinin (*intrinsic ve extrinsic*) daha iyi kestirilebilmeleri kamera sistemleri özelinde “bundle adjustment” adı altında ayrı bir konuyu oluşturmaktadır [23]. Bundle adjustment ve grup temelli görüntü hizalama biraraya getirildiğinde kaynağında görüntülerin en sağlıklı şekilde bir arada üretilmelerinden, sonrasında bir arada değerlendirilebilmelerine kadar tüm zincirde verimliliği en üst düzeye çıkarmak amaçlanabilir. Oldukça sofistike sistemsel yaklaşımlar ihtiva edecek

olmalarına rağmen, bu tarz yaklaşımlar ileriki yıllarda yapmayı düşünebileceğimiz çalışmalar için bize ışık tutar noktadadır.

Anahtar Kelimeler: Grup bazında görüntü hizalama; medikal görüntü analizi; zaman görüntü dizisi analizi; multimodal görüntü füzyonu.

KAYNAKÇA

1. A. Bartoli, "Groupwise Geometric and Photometric Direct Image Registration," in *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 30, no. 12, pp. 2098-2108, Dec. 2008
2. Huizinga, W., Poot, D. H., Guyader, J. M., Klaassen, R., Coolen, B. F., van Kranenburg, M., ... & Klein, S. (2016). PCA-based groupwise image registration for quantitative MRI. *Medical image analysis*, 29, 65-78.
3. Wu, G., Jia, H., Wang, Q., & Shen, D. (2011). SharpMean: groupwise registration guided by sharp mean image and tree-based registration. *NeuroImage*, 56(4), 1968-1981.
4. Geng, X., Christensen, G. E., Gu, H., Ross, T. J., & Yang, Y. (2009). Implicit reference-based group-wise image registration and its application to structural and functional MRI. *Neuroimage*, 47(4), 1341-1351.
5. Alam, F., Rahman, S. U., Din, A. U., & Qayum, F. (2018). Medical image registration: Classification, applications and issues. *JPMI*, 32(4), 300.
6. Hu, Y., Gibson, E., Ahmed, H. U., Moore, C. M., Emberton, M., & Barratt, D. C. (2015). Population-based prediction of subject-specific prostate deformation for MR-to-ultrasound image registration. *Medical image analysis*, 26(1), 332-344.
7. Cazoulat, G., Owen, D., Matuszak, M. M., Balter, J. M., & Brock, K. K. (2016). Biomechanical deformable image registration of longitudinal lung CT images using vessel information. *Physics in Medicine & Biology*, 61(13), 4826.
8. Slomka, P. J., & Baum, R. P. (2009). Multimodality image registration with software: state-of-the-art. *European journal of nuclear medicine and molecular imaging*, 36, 44-55.
9. Toga, A. W., & Thompson, P. M. (2001). The role of image registration in brain mapping. *Image and vision computing*, 19(1-2), 3-24.
10. Gholipour, A., Kehtarnavaz, N., Briggs, R., Devous, M., & Gopinath, K. (2007). Brain functional localization: a survey of image registration techniques. *IEEE transactions on medical imaging*, 26(4), 427-451.
11. Oh, S., & Kim, S. (2017). Deformable image registration in radiation therapy. *Radiation oncology journal*, 35(2), 101.
12. Makela, T., Clarysse, P., Sipila, O., Pauna, N., Pham, Q. C., Katila, T., & Magnin, I. E. (2002). A review of cardiac image registration methods. *IEEE Transactions on medical imaging*, 21(9), 1011-1021.
13. Ma, B., & Ellis, R. E. (2003). Robust registration for computer-integrated orthopedic surgery: laboratory validation and clinical experience. *Medical image analysis*, 7(3), 237-250.
14. Yang, K., Pan, A., Yang, Y., Zhang, S., Ong, S. H., & Tang, H. (2017). Remote sensing image registration using multiple image features. *Remote Sensing*, 9(6), 581.
15. Pomerleau, F., Colas, F., & Siegwart, R. (2015). A review of point cloud registration algorithms for mobile robotics. *Foundations and Trends® in Robotics*, 4(1), 1-104.
16. Uenohara, M., & Kanade, T. (1995). Vision-based object registration for real-time image overlay. *Computers in Biology and Medicine*, 25(2), 249-260.

17. Fomel, S., Backus, M. M., DeAngelo, M. V., Murray, P. E., & Hardage, B. A. (2003, May). Multicomponent seismic data registration for subsurface characterization in the shallow Gulf of Mexico. In *Offshore Technology Conference* (pp. OTC-15117). OTC.
18. Li, T., Pan, Q., Gao, L., & Li, P. (2017). Differential evolution algorithm-based range image registration for free-form surface parts quality inspection. *Swarm and Evolutionary Computation*, 36, 106-123.
19. Wu, G., Wang, Q., Jia, H., & Shen, D. (2012). Feature-based groupwise registration by hierarchical anatomical correspondence detection. *Human brain mapping*, 33(2), 253-271.
20. Yang, D., Li, H., Low, D. A., Deasy, J. O., & El Naqa, I. (2008). A fast inverse consistent deformable image registration method based on symmetric optical flow computation. *Physics in Medicine & Biology*, 53(21), 6143.
21. Haskins, G., Kruger, U., & Yan, P. (2020). Deep learning in medical image registration: a survey. *Machine Vision and Applications*, 31(1), 8.
22. Vishnevskiy, Valery, Tobias Gass, Gabor Szekely, Christine Tanner, and Orcun Goksel. "Isotropic Total Variation Regularization of Displacements in Parametric Image Registration." *IEEE Transactions on Medical Imaging* 36, no. 2 (February 2017): 385–95. <https://doi.org/10.1109/TMI.2016.2610583>.
23. Konolige, K., & Agrawal, M. (2008). FrameSLAM: From bundle adjustment to real-time visual mapping. *IEEE Transactions on Robotics*, 24(5), 1066-1077.