

Brain Tissue Segmentation Using Conditional Spatial Gustafson-Kessel Clustering

Ali Fahmi Jafargholkhanloo*, Mousa Shamsi, Mehdi Bashiri Bawil

Assistant Professor, Department of Engineering Sciences, Faculty of Advanced Technologies, University of Mohaghegh Ardabili, Namin, Iran., E-mails: a_fahmi@uma.ac.ir

Professor, Faculty of Biomedical Engineering, Sahand University of Technology, Tabriz, Iran, E-mails: shamsi@sut.ac.ir

PhD Student, Faculty of Biomedical Engineering, Sahand University of Technology, Tabriz, Iran, E-mails: m_bashiri99@sut.ac.ir

*means corresponding author

Abstract

The segmentation of brain tissues is a crucial step in evaluating morphological changes in various brain regions for the identification of different diseases. This process is influenced by factors such as noise and intensity non-uniformity. Fuzzy c-means clustering (FCM) is a widely used method for image segmentation but is sensitive to noise, and its convergence rate is affected by data distribution. FCM-based approaches typically use Euclidean distance for clustering, assuming a spherical distribution of data, which overlooks distance variations in similar and compact clusters. Additionally, varying levels of intensity non-uniformity can impact clustering performance. To address these limitations, this study presents the Conditional Spatial Gustafson-Kessel (CSGK) algorithm, which performs well in segmenting compact clusters such as cerebrospinal fluid (CSF) by considering data distribution in an elliptical space. The robustness of the conventional Gustafson-Kessel algorithm is enhanced by incorporating both local and global spatial information into a weighted membership function. Furthermore, a Wiener filter combined with wavelet transform (WFWT) is applied during preprocessing to reduce the sensitivity of input data to intensity non-uniformity. Experimental results demonstrate that CSGK is an accurate algorithm for segmenting multiple brain tissues across different levels of noise and intensity non-uniformity.

Keywords

Brain Tissue Segmentation, Fuzzy c-means Clustering, Gustafson-Kessel Clustering, Conditional Spatial Information, MRI images, Wiener Filter.

Introduction

The human brain is composed of three primary tissues: cerebrospinal fluid (CSF), gray matter (GM), and white matter (WM). These tissues play a vital role in quantitative brain analysis during diagnostic processes. The quality of MRI images depends on the gray levels of these tissues, which can help identify various brain diseases such as multiple sclerosis (MS), schizophrenia, and Alzheimer's disease. Accurately diagnosing these tissues presents a significant challenge for radiologists, and manual segmentation is often time-consuming. Therefore, there is a need for an accurate and efficient approach to segment different brain tissues.

Proposed Work and Methodology

This study presents an automatic method for segmenting multiple brain tissues in MRI images using the Conditional Spatial Gustafson-Kessel (CSGK) algorithm. The proposed approach incorporates spatial information by utilizing the interaction between neighboring pixels in the membership function. If neighboring pixels have similar features, the central pixel is assigned a higher probability of being grouped into the same cluster. To enhance robustness against noise and intensity non-uniformity, a Wiener filter combined with wavelet transform (WFWT) is used as a preprocessing step. Experimental results demonstrate that CSGK is an accurate algorithm for segmenting multiple brain tissues across different levels of noise and intensity non-uniformity.

Conclusion

FCM-based approaches use Euclidean distance for clustering, which disregards the variation in distances among data points within similar and compact clusters. CSF, which plays a crucial role in clearing metabolic waste from the brain, is typically considered a compact and small cluster. Using Euclidean distance can cause this cluster to be misclassified as another tissue type. Additionally, noise and intensity non-uniformity can impact the clustering process. The proposed CSGK algorithm addresses these issues and improves segmentation accuracy.

بخش‌بندی بافت‌های مغزی با استفاده از الگوریتم خوشه‌بندی گستافسون-کسل مبتنی بر اطلاعات مکانی شرطی

علی فهمی جعفرقلخانلو

استادیار، گروه علوم مهندسی، دانشکده‌ی فناوری‌های نوین، دانشگاه محقق اردبیلی، نمین، ایران.

موسی شمسی

استاد، گروه بیوالکتریک، دانشکده‌ی مهندسی پزشکی، دانشگاه صنعتی سهند، تبریز، ایران

مهدی بشیری باویل

دانشجوی دکتری، گروه بیوالکتریک، دانشکده‌ی مهندسی پزشکی، دانشگاه صنعتی سهند، تبریز، ایران

چکیده

بخش‌بندی بافت‌های مغزی گامی ضروری برای ارزیابی تغییرات مورفولوژیکی نواحی مختلف مغز جهت شناسایی انواع بیماری‌ها بوده که به عوامل متعددی مانند نویز و غیریکنواختی شدت روشنایی وابسته است. الگوریتم خوشه‌بندی فازی (FCM) یکی از محبوب‌ترین روش‌ها در فرآیند بخش‌بندی تصویر بوده که به نویز حساس بوده و سرعت همگرایی آن تحت تأثیر توزیع داده قرار می‌گیرد. همچنین، فرآیند خوشه‌بندی در رویکردهای مبتنی بر FCM با استفاده از فاصله اقلیدسی و در نظر گرفتن توزیع داده‌ها در فضای کروی انجام می‌شود. این معیار، تغییرات فاصله بین نقاط داده در خوشه‌های مشابه و فشرده را در نظر نمی‌گیرد. علاوه بر این، وجود غیریکنواختی شدت روشنایی در سطوح مختلف، عمل‌کرد فرآیند خوشه‌بندی را تحت تأثیر قرار می‌دهد. برای حل مسائل ذکر شده، در این مطالعه الگوریتم خوشه‌بندی گستافسون-کسل مبتنی بر اطلاعات مکانی شرطی (CSGK) ارائه می‌شود که با فرض توزیع داده در فضای بیضوی عمل‌کرد مناسبی در بخش‌بندی خوشه‌های فشرده نظیر مایع مغزی-نخاعی (CSF) دارد. جهت بهبود استحکام الگوریتم گستافسون-کسل استاندارد به نویز، از رویکرد ترکیبی اطلاعات محلی و سراسری در تابع عضویت استفاده شده است. همچنین، برای کاهش حساسیت داده‌های ورودی به غیریکنواختی شدت روشنایی، از فیلتر وینر به همراه تبدیل موجک (WFWT) در مرحله پیش‌پردازش تصاویر بهره گرفته شده است. نتایج نشان داد که الگوریتم CSGK روشی دقیق برای بخش‌بندی بافت‌های مغزی در سطوح مختلف نویز و غیریکنواختی شدت روشنایی است.

کلمات کلیدی

الگوریتم خوشه‌بندی فازی، الگوریتم خوشه‌بندی گستافسون-کسل، اطلاعات مکانی شرطی، بخش‌بندی بافت‌های مغزی، تصاویر MRI، فیلتر وینر.

نام نویسنده مسئول: دکتر علی فهمی جعفرقلخانلو

ایمیل نویسنده مسئول: a_fahmi@uma.ac.ir

تاریخ ارسال مقاله: ۱۴۰۳/۰۸/۰۵

تاریخ(های) اصلاح مقاله: ۱۴۰۳/۱۱/۰۲

تاریخ پذیرش مقاله: ۱۴۰۳/۱۲/۲۰

۱- مقدمه

آنالیز تصاویر پزشکی نقش اساسی در ارزیابی‌های کلینیکی ایفا می‌کند و در بسیاری از موارد وابسته به دقت فرآیند بخش‌بندی است. این فرآیند نواحی موردنظر برای ارزیابی رفتاری و تغییرات مورفولوژیکی نواحی مختلف را جهت شناسایی بیماری جدا می‌کند [۴-۱]. فرآیند بخش‌بندی در تصویربرداری تشدید مغناطیسی (MRI) وابسته به عوامل متعددی نظیر غیریکنواختی شدت روشنایی (INU)، نویز، نزدیکی بافت به یکدیگر و خصوصیات درونی بافت‌های مغزی است. INU اغلب باعث بخش‌بندی غیرصحیح بافت مغزی به دلیل همپوشانی بین محدوده‌های مختلف شدت بافت می‌شود [۵، ۱]. مغز انسان شامل سه نوع بافت مایع مغزی-نخاعی (CSF)، ماده خاکستری (GM) و ماده سفید (WM) بوده که نقش حیاتی در آنالیز کمی مغز در فرآیندهای تشخیص ایفا می‌کند. کیفیت تصاویر MRI وابسته به سطوح خاکستری این بافت‌ها بوده به‌طوری که انواع مختلف بیماری‌های مغزی نظیر تصلب پراکنده (MS)، اسکیزوفرنی و آلزایمر قابل شناسایی در این نواحی هستند [۹-۵].

تشخیص بافت‌های مختلف مغزی یک چالش اساسی برای رادیولوژیست‌ها محسوب می‌شود. در این فرآیند، بخش‌بندی دستی زمان‌بر بوده و می‌تواند به دلیل تغییرات درون-ناظر و برون-ناظر، یافته‌های متناقضی ایجاد کند. در نتیجه، رادیولوژیست‌ها نیازمند رویکردی دقیق جهت بخش‌بندی بافت‌های مختلف مغزی هستند. رویکردهای مختلفی نظیر روش‌های مبتنی بر آستانه‌گذاری، خوشه‌بندی، کانتور فعال و یادگیری عمیق جهت بخش‌بندی تصاویر پزشکی ارائه شده‌اند. روش‌های آستانه‌گذاری فرآیند بخش‌بندی را از طریق محاسبه آستانه‌ی تک‌گانه و یا چندگانه انجام می‌دهند. این رویکردها عمل کرد مناسبی در حضور آرتیفکت، نویز و نوسانات مقدار سطح خاکستری ندارند. بخش‌بندی تصویر در روش‌های مبتنی بر کانتور از طریق بازسازی یک تابع انرژی انجام می‌شود. این رویکردها نیازمند کانتور اولیه و تنظیم پارامترهای زیاد بوده و معمولاً عمل کرد مناسبی در حضور INU ندارند. از معایب اصلی رویکردهای مبتنی بر یادگیری عمیق می‌توان به سرعت آموزش پایین، وابستگی به میزان داده و ساختار پیچیده‌ی آن‌ها اشاره کرد. خوشه‌بندی یکی از محبوب‌ترین رویکردهای بخش‌بندی تصویر بوده که یک مجموعه را به تعدادی خوشه با میزان تشابه بیشتر درون اعضا و تشابه کم‌تر با سایر اعضای خوشه جدا می‌کند [۱۸-۱۱]. برای حل چالش‌های ذکر شده، تمرکز اصلی ما در این مطالعه بر روی روش‌های ارائه شده براساس خوشه‌بندی خواهد بود.

Li و همکاران [۵] رویکرد کمینه‌سازی انرژی مبتنی بر بهینه‌سازی مولفه‌ی درونی ضریبی (MICO) را جهت تخمین بایاس و بخش‌بندی بافت‌های مغزی ارائه کردند. Adhikari و همکاران [۱۹] الگوریتم خوشه‌بندی فازی (FCM) مبتنی بر اطلاعات شرطی (CSFCM) را جهت بهبود عمل کرد الگوریتم FCM استاندارد در بخش‌بندی تصاویر MRI ارائه کردند. Elazab و همکاران [۲۰] رویکرد FCM مبتنی بر هسته‌ی تنظیم شده به‌صورت افقی (ARKFCM) را جهت بخش‌بندی انواع بافت‌های مغزی از روی تصاویر MRI ارائه کردند. Bakhshali [۲۱] روش مقاوم و بهبود یافته‌ی FCM را جهت تخمین و اصلاح INU و کاهش اثر نویز براساس تئوری اطلاعات ارائه کرد. Moeskops و همکاران [۲۲] شبکه‌ی عصبی کانولوشنی (CNN) را جهت بخش‌بندی خودکار تصاویر MRI مغزی معرفی کردند. Ghosh و همکاران [۲۳] الگوریتم FCM بهبود یافته‌ی مکانی را جهت حل چالش‌های مربوط به نویز و INU در تصاویر MRI ارائه کردند. الگوریتم FCM استاندارد حساس به نویز و مقداره‌ی اولیه است.

بنابراین، در این روش، الگوریتم کرم شبتاب مبتنی بر آشوب (CFA) جهت حل مشکل ذکر شده به‌کار گرفته شد. Hassan و همکاران [۶] مدل مخلوط گوسین (GMM) فازی را به‌منظور بخش‌بندی مدالیته‌های تصویربرداری MRI و سونوگرافی ارائه کردند. Kouhi و همکاران [۱] الگوریتم مقاوم FCM را با ترکیب محدودیت مکانی و اطلاعات مکانی ماتریس عضویت برای بخش‌بندی بافت‌های مغزی معرفی کردند. یکی از معایب اصلی الگوریتم FCM استاندارد افتادن در کمینه‌های محلی است. برای حل این مسئله، Verma و همکاران [۲۴] بهینه‌سازی خوشه‌بند FCM با استفاده از الگوریتم ازدحام ذرات (FCMPSO) را جهت بخش‌بندی تصاویر MRI ارائه کردند. Tongbram و همکاران [۲۵] الگوریتم بهینه‌سازی نهنگ را جهت حل مشکلات ذکر شده‌ی الگوریتم FCM (FCMWOA) به‌کار گرفتند. الگوریتم FCM استاندارد به دلیل درنظر نگرفتن اطلاعات مکانی عمل کرد خوبی در حضور آرتیفکت‌های تصویربرداری ندارد. جهت حل این مشکل، Saouli و Chighoub [۲۶] اطلاعات مکانی ترکیبی را جهت بخش‌بندی تصاویر MRI تحت شرایط ذکر شده ارائه کردند. Kumar و همکاران [۲۷] رویکرد مبتنی بر تصویر هسته FCM با اطلاعات مکانی همسایگی را ارائه کردند. Khaled و همکاران [۲۸] رویکرد مبتنی بر یادگیری را جهت شناسایی اطلاعات مرزی به‌منظور بخش‌بندی تصاویر مغزی ارائه کردند. فرآیند بخش‌بندی بافت‌های مغزی در حضور شرایطی نظیر نویز، اثر جزئی حجم و بایاس موضوعی چالش‌برانگیز است. Kumar و همکاران [۲۹] روش FCM شهودی اصلاح شده‌ی بایاس با اطلاعات همسایگی مکانی (BCIFCMSNI) را جهت حل مسائل ذکر شده ارائه کردند.

الگوریتم FCM استاندارد حساس به نویز و مقداره‌ی اولیه است. جهت حل این مسئله، رویکردهای بهینه‌سازی FCM مانند FCMPSO و FCMWOA ارائه شدند. این روش‌ها عمل کرد مناسبی تحت شرایط مختلف INU ندارند. همچنین، روش FCMPSO نیازمند تنظیم پارامتر جهت متعادل کردن فازهای استخراج و اکتشاف است. این پارامترها می‌توانند دقت بخش‌بندی را تحت تاثیر قرار دهند. رویکردهای مبتنی بر هسته نظیر ARKFCM معمولاً برای داده‌ی غیرکروی مناسب نبوده و پیچیدگی محاسباتی بالایی دارند. در رویکردهای مبتنی بر تنظیم سطح نظیر MICO، تابع توقف لبه به گرادین تصویر وابسته بوده و باعث می‌شود که تنها شی‌های با لبه‌ی تعریف شده از طریق گرادین بتوانند بخش‌بندی شوند. در فرآیند بخش‌بندی براساس رویکردهای آستانه‌گذاری، معمولاً اطلاعات مکانی درنظر گرفته نمی‌شود و شدیداً به نویز و INU حساس هستند. شاخص عدم تشابه در روش‌های مبتنی بر FCM مانند CSFCM، ARKFCM و BCIFCMSNI معمولاً نماینده‌ی مناسبی برای خوشه‌های فشرده نیست. به‌کارگیری فاصله‌ی اقلیدسی در این رویکردها از تغییرات فاصله‌ی نقاط داده در خوشه‌های مشابه صرف‌نظر می‌کند. همچنین، عمل کرد رویکردهای مبتنی بر FCM معمولاً زمانی مناسب هستند که خوشه‌ها اندازه و ریخت یکسانی داشته باشند. جهت حل مشکلات ذکر شده، در این مطالعه، الگوریتم خوشه‌بندی گستافسون-کسل براساس اطلاعات مکانی شرطی (CSGK) برای بخش‌بندی بافت‌های مغزی براساس تصاویر MRI ارائه می‌شود. الگوریتم ارائه شده می‌تواند انواع تصاویر با دقت بالا را بخش‌بندی کند. نوآوری‌های اصلی مقاله به‌صورت زیر خلاصه می‌شود:

(۱) یک مسئله‌ی مهم به‌دلیل این واقعیت است که شدت تصاویر MRI در واحدهای تصادفی به‌دست می‌آید. این فرآیند اغلب منجر به این می‌شود که تفاوت در شدت تصاویر MRI بین پارامترهای اسکن و مطالعات بیشتر از

6 Multiple Sclerosis

7 Multiplicative Intrinsic Component Optimization

8 Conventional Spatial Fuzzy c-means

9 Conventional Spatial Gustafson-Kessel

1 Magnetic Resonance Imaging

2 Intensity non-Uniformity

3 Cerebrospinal Fluid

4 Grey Matter

5 White Matter

الگوریتم GK این است که اگر همبستگی بین پیکسل‌های همسایه در نظر گرفته نشود، فرآیند خوشه‌بندی دقت بالایی نخواهد داشت.

۲-۱- فیلتر وینر با رویکرد مشارکتی تبدیل موجک

وجود نویز و INU عمل کرد فرآیند خوشه‌بندی را تحت تاثیر قرار می‌دهد. به عبارت دیگر، خصوصیات توزیع داده از طریق نویز و INU تحت تاثیر قرار می‌گیرد. این فرآیند باعث ایجاد مشکلاتی می‌شود. اولاً، عمل کرد بخش‌بندی تحت شرایط مختلف نویز مناسب نخواهد بود. از طرف دیگر، تعداد تکرار برای رویکردهای مبتنی بر الگوریتم FCM برای یک تصویر نویزی بیشتر از تصویر بدون نویز خواهد بود. جهت حل مسائل ذکر شده، رویکرد WFWT به عنوان یک مرحله‌ی پیش‌پردازش برای الگوریتم CSGK جهت بهینه کردن ویژگی‌های توزیع داده اعمال می‌شود. فیلتر وینر جهت تخمین مقدار پیکسل از طریق میانگین پیکسل مکانی و واریانس پیکسل‌های همسایه اعمال می‌شود [۳۰]. در این فرآیند، مقدار میانگین مکانی μ و مقدار واریانس مکانی σ^2 برای پیکسل در مکان (k, r) تصویر نویزی N به صورت زیر محاسبه می‌شوند:

$$\mu(k, r) = \frac{1}{(2M+1)(2N+1)} \sum_{m=-M}^M \sum_{n=-N}^N N(k+m, r+n) \quad (۱)$$

$$\sigma^2(k, r) = \frac{1}{(2M+1)(2N+1)} \sum_{m=-M}^M \sum_{n=-N}^N N^2(k+m, r+n) - \mu^2(k+m, r+n) \quad (۲)$$

که در آن ابعاد هسته‌ی فیلتر به صورت $(2M+1) \times (2N+1)$ در نظر گرفته می‌شود. همچنین، ماتریس تصویر بازیابی شده $N(k, r)$ در مکان (k, r) از طریق رابطه‌ی (۳) محاسبه می‌شود:

$$N(k, r) = \mu(k, r) + \frac{\sigma^2(k, r)}{\sigma^2(k, r) + \sigma_N^2} (N(k, r) - \mu(k, r)) \quad (۳)$$

که در آن σ_N^2 واریانس تصویر نویزی است. در حالت کلی، براساس رویکرد الهام گرفته شده از [۳۱]، اختلاف بین تصویر اصلی و تصویر بازیابی شده (F) باید نزدیک به صفر باشد. همان‌طوری که در شکل ۲(ج) نیز نشان داده شده است، F شامل اطلاعاتی است که می‌تواند به صورت زیر تعریف شود:

$$F = S + N \quad (۴)$$

که در آن S و N به ترتیب نشان دهنده‌ی اطلاعات باقی مانده از تصویر اصلی و نویزی است. در این صورت، چالش اصلی تخمین S و اضافه کردن آن به تصویر ورودی است. برای این منظور، تبدیل موجک به کار گرفته می‌شود. این فرآیند می‌تواند به صورت زیر بیان شود:

$$W_F = W_S + W_N \quad (۵)$$

که در آن W_S و W_N به ترتیب تبدیل موجک مربوط به سیگنال باقی مانده و تصویر نویزی است.

همان‌طوری که در شکل ۲(د، و) نشان داده شده است، با اعمال تبدیل موجک بر روی F و استخراج k ، نویز بیشتری از تصویر کاهش می‌یابد. این فرآیند باعث می‌شود که الگوریتم CSGK ارائه شده به شرایط نویز و INU بیشتر مقاوم باشد. در این مطالعه، تبدیل موجک دوبعدی با موجک هار جهت فرآیند تجزیه‌ی و آستانه‌گذاری نرم جهت آستانه‌گذاری کردن ضرایب موجک به کار گرفته می‌شوند. همچنین، فرآیند تجزیه تا ۵ سطح انجام می‌شود.

تفاوت‌های بیولوژیکی واقعی مشاهده شده در تصاویر باشد. برای رفع این مشکل، رویکرد استانداردسازی شدت ارائه می‌شود.

(۲) برای مقابله با مشکلات نویز، ناهمگونی شدت (INU) و حفظ جزئیات تصویر، از رویکرد مبتنی بر تجزیه تفاضل تصویر اصلی با خروجی فیلتر وینر از طریق تبدیل موجک (WFWT^{۱۰}) و بازگرداندن محتویات اطلاعات باقی مانده به تصویر بازسازی شده به عنوان یک مرحله‌ی پیش‌پردازش استفاده شده است. (۳) الگوریتم CSGK ارائه شده یک روش بخش‌بندی جدید برای تصاویر MRI را با در نظر گرفتن ریخت‌های مختلف خوشه به صورت کروی به کار می‌برد. سایر الگوریتم‌های مبتنی بر FCM ریخت ابر-کروی را به کار می‌برند، در حالی که ریخت هندسی فراهم شده در CSGK به صورت بیضوی است. بنابراین، این رویکرد باعث می‌شود که الگوریتم ارائه شده با دقت بیشتری نسبت به سایر روش‌های مبتنی بر FCM فرآیند بخش‌بندی بافت‌های مغزی را در حضور شرایط مختلف نویز و INU انجام دهد. همچنین، روش ارائه شده به پارامترهای تنظیم کم‌تری نیاز دارد.

(۴) یک رویکرد شرطی برای فرآیند خوشه‌بندی ارائه شده است که در آن تعامل محلی بین پیکسل‌های مجاور در تابع عضویت به گونه‌ای ادغام شده است که اگر پیکسل‌های همسایه ویژگی‌های مشابهی داشته باشند، پیکسل‌های مرکزی باید احتمال بیشتری برای گروه‌بندی به همان خوشه با پیکسل‌های همسایه را داشته باشند. این فرآیند، متغیر شرطی مرتبط با هر پیکسل را در نظر گرفته که سطح مشارکت برای ساخت توابع عضویت و خوشه‌های مختلف را توصیف می‌کند. درواقع رویکرد شرطی باعث مقاوم شدن الگوریتم GK به نویز و آرتیفکت‌های تصویربرداری می‌شود.

(۵) عمل کرد الگوریتم CSGK پیشنهادی با اعمال آن بر روی ۱۰ بیمار که در مرکز تصویربرداری پزشکی گل‌گشت تبریز (GMIC^{۱۱}) تحت تصویربرداری قرار گرفته و ۴۱ تصویر MRI مغز از مجموعه داده‌های Brainweb با شرایط مختلف نویز و INU مورد ارزیابی قرار می‌گیرد.

۲- الگوریتم پیشنهادی

شاخص عدم تشابه در روش‌های مبتنی بر FCM معمولاً معیار مناسبی برای خوشه‌های فشرده نیست. به کارگیری فاصله‌ی اقلیدسی در این رویکردها، تغییر فاصله نقاط داده در خوشه‌های مشابه را نادیده می‌گیرد. درواقع، شکل هندسی داده در رویکردهای مبتنی بر FCM به صورت کروی در نظر گرفته شده که به صورت مکانی با تغییرات شکل خوشه تطبیق ندارند. بنابراین، گاهی اوقات چالش‌هایی در بخش‌بندی نواحی خوشه‌های فشرده و کوچک نظیر ناحیه مربوط به مایع مغزی-نخاعی ایجاد می‌شود. برای رفع این مشکلات، در این مطالعه الگوریتم CSGK پیشنهاد شده است. همان‌طوری که در شکل ۱ نشان داده شده است، در ابتدای الگوریتم پیشنهادی، رویکرد مشارکتی فیلتر وینر با تبدیل موجک برای رفع نویز و مشکلات INU اعمال می‌شود. هدف اصلی در این بخش، اعمال تبدیل موجک به تفاضل تصویر اصلی با خروجی حاصل از فیلتر وینر و بازگرداندن برخی اطلاعات باقی مانده به تصویر بازسازی شده جهت کاهش بیشتر نویز و کم اثر کردن INU است. در مرحله بعدی، به جای در نظر گرفتن توزیع داده در فضای کروی (با به کارگیری فاصله‌ی اقلیدسی)، رویکرد فضای بیضوی (به کارگیری فاصله‌ی مایلانوبیس) جهت مدل کردن توزیع داده‌ها به کار گرفته می‌شود. سپس، مراکز خوشه، ماتریس عضویت و ماتریس متقارن مثبت از طریق عملیات تکرار به روزرسانی می‌شوند. سرانجام، با اطلاعات به دست آمده برای مراکز خوشه و ماتریس عضویت از طریق رویکرد شرطی، فرآیند بخش‌بندی بافت‌های مغزی از روی تصاویر MRI انجام می‌شود. دلیل ارائه‌ی نسخه‌ی شرطی

^{۱۱} Golghasht Medical Imaging Center in Tabriz

^{۱۰} Wiener Filter Approach by Cooperating Wavelet Transform

در الگوریتم FCM، خوشه‌ها به صورت کروی فرض می‌شوند. بنابراین، عمل کرد این الگوریتم زمانی مناسب خواهد بود که خوشه‌ها در داده تقریباً دارای ریخت و اندازه‌ی یکسان باشند، اما الگوریتم GK برای تشخیص خوشه‌های ابر بیضی شکل با اندازه و جهت‌گیری‌های متفاوت مناسب است [۳۳، ۳۴]. تخمین ماتریس کواریانس است [۳۵]. تابع هزینه‌ی این الگوریتم به صورت زیر بیان می‌شود:

$$J_{GK} = \sum_{i=1}^N \sum_{j=1}^c \mu_{ij}^q \cdot (x_i - v_j)^T \cdot A_j \cdot (x_i - v_j) \quad (9)$$

که در آن A_j یک ماتریس مثبت متقارن است. با به کارگیری روش حاصل ضرب لاگرانژ، رابطه‌ی (۹) را می‌توان به یک مسئله بهینه‌سازی نامحدود تبدیل کرد که تابع هزینه زیر را کمینه می‌کند:


$$J_{GK} = \sum_{i=1}^N \sum_{j=1}^c \mu_{ij}^q \cdot (x_i - v_j)^T \cdot A_j \cdot (x_i - v_j) - \sum_{i=1}^N \lambda_i (\sum_{j=1}^c \mu_{ij} - 1) + \sum_{j=1}^c \beta_j \cdot (\det(A_j) - \rho_j) \quad (10)$$

۲-۲- الگوریتم خوشه‌بندی گستافسون-کسل براساس اطلاعات مکانی شرطی


الگوریتم خوشه‌بندی FCM برای اولین بار توسط Bezdek [۳۲] جهت بهبود عمل کرد خوشه‌بند K -میانگین براساس رویکرد به کارگیری ماتریس عضویت μ_{ij} ارائه شد. برای یک تصویر داده شده $I(x, y)$ با مقادیر خاکستری x_i ($i = 1, 2, \dots, N$) و مراکز خوشه $V = \{v_1, v_2, \dots, v_c\}$ یک مقدار عضویت برای هر پیکسل i در λ مین خوشه ($j = 1, 2, \dots, c$) وجود دارد. تابع هزینه در الگوریتم FCM با میزان فازی شدگی q براساس رابطه‌ی (۶) به صورت زیر تعریف می‌شود:

$$J_{FCM} = \sum_{i=1}^N \sum_{j=1}^c \mu_{ij}^q (x_i - v_j)^2 \quad (6)$$

ویژگی اصلی الگوریتم GK تطبیق مکانی معیار فاصله با ریخت خوشه از طریق



شکل ۱: بلوک-دیگرام الگوریتم پیشنهادی جهت بخش‌بندی بافت‌های مغزی از روی تصاویر MRI.



(الف)					(ب)					(ج)					(د)					(و)				
85	104	65	119	119	87	104	73	116	117	-2	0	-8	3	2	-1	-1	-5.1	2.8	0.7	84	103	59.9	121.8	119.7
52	64	95	137	114	59	68	97	129	112	-7	-4	-2	8	2	-2.9	-2.9	-2.1	5.7	0.7	49.1	61.1	92.9	142.7	114.7
45	78	122	140	99	57	79	119	133	99	-12	-1	3	7	0	-6.8	-1	2.9	3.2	0.5	38.2	77	124.9	143.2	99.5
55	84	131	123	54	58	86	126	120	61	-3	-2	5	3	-7	-3	-2	3.2	2.9	-6.5	52	82	134.2	125.9	47.5
72	133	135	115	76	73	129	127	113	79	-1	4	8	2	-3	0	0.8	4.4	0.1	-1.1	72	133.8	139.4	115.1	74.9

شکل ۲: مراحل رویکرد WFFT. (الف): تصویر نویزی، (ب): تصویر بازسازی شده از طریق اعمال فیلتر وینر، (ج): تصویر خروجی F ، (د): خروجی فرآیند تجزیه از طریق تبدیل موجک، (و): تصویر بازسازی شده‌ی نهایی با اضافه کردن اطلاعات مرحله‌ی (د) به مرحله‌ی (الف).

که در آن β_j نشان دهنده‌ی مجموعه ضرایب لاگرانژ است. همچنین، ρ_j نشان دهنده‌ی حجم خوشه بوده که معمولاً برای هر خوشه مقدار یک در نظر گرفته می‌شود. با صفر قرار دادن مشتق J_{GK} نسبت به ماتریس عضویت خواهیم داشت:

$$\frac{\partial J_{GK}}{\partial u_{ij}} = q \cdot \mu_{ij}^{q-1} \cdot (x_i - v_j)^T \cdot A_j \cdot (x_i - v_j) - \lambda_i = 0 \quad (11)$$

رابطه‌ی (۱۲) جهت به‌روزرسانی ماتریس عضویت به کار گرفته می‌شود:

تابع عضویت و مراکز خوشه در یک فرآیند تکراری در الگوریتم FCM به صورت زیر به‌روزرسانی می‌شوند:

$$\mu_{ij} = \frac{1}{\sum_{j=1}^c \left(\frac{\|x_i - v_j\|^2}{\|x_i - v_i\|^2} \right)^{\frac{2}{q-1}}} \quad (7)$$

$$v_j = \frac{\sum_{i=1}^N (\mu_{ij}^q x_i)}{\sum_{i=1}^N (\mu_{ij}^q)} \quad (8)$$

$$Z_{ij} = \frac{(\mu_{ij})^P \cdot (u_{ij})^L}{\sum_{j=1}^C (\mu_{ij})^P \cdot (u_{ij})^L} \quad (21)$$

$$W_j = \frac{\sum_{i=1}^N Z_{ij}^q \cdot x_i}{\sum_{i=1}^N Z_{ij}^q} \quad (22)$$

که در آن پارامترهای P و L کنترل کننده‌ی اهمیت نسبی توابع عضویت هستند. درواقع این پارامترها یک مصالحه بین مقادیر عضویت محلی و سراسری جهت بازسازی مقادیر عضویت نهایی و مراکز خوشه هستند. این دو پارامتر به صورت تجربی در مقادیر مختلف به کار گرفته شدند. نتایج نشان دادند که در حالت $P = L = 2$ مقدار کوچک در هر دو متغیرهای μ_{ij} و u_{ij} منجر به تغییر قابل توجه در مقدار عضویت Z_{ij} خواهد شد. این فرآیند اطمینان خواهد داد که اگر پیکسل‌های همسایه ویژگی‌های مشابه داشته باشند، پیکسل مرکزی باید احتمال بیشتری برای گروه‌بندی به همان خوشه با پیکسل‌های همسایه را داشته باشد. در ناحیه‌ی یکنواخت، پارامتر عضویت مکانی شرطی u_{ij} مشابه بوده و نتیجه‌ی خوشه‌بندی بدون تغییر خواهد ماند. با توجه به اینکه پیکسل نویزی متعلق به لبه است، این نواحی می‌تواند از طریق پیکسل‌های همسایگی اصلاح شود. بنابراین، این حالت باعث می‌شود که الگوریتم CSGK مقاوم به نویز و غیریکنواختی شدت روشنایی باشد. مراحل الگوریتم CSGK پیشنهادی به صورت زیر است:

مرحله ۱: تنظیم تعداد مراکز خوشه، مقداردهی اولیه برای ماتریس عضویت و تنظیم پارامترهای P و L .

مرحله ۲: محاسبه‌ی مراکز خوشه از طریق رابطه‌ی (۱۴).

مرحله ۳: محاسبه‌ی ماتریس کواریانس از طریق رابطه‌ی (۱۷).

مرحله ۴: محاسبه‌ی ماتریس عضویت از طریق رابطه‌ی (۱۲).

مرحله ۵: محاسبه‌ی مقدار عضویت مکانی شرطی از طریق رابطه‌ی (۱۸).

مرحله ۶: محاسبه‌ی مقدار عضویت وزن‌دار از طریق رابطه‌ی (۲۱).

مرحله ۷: محاسبه‌ی مراکز خوشه‌ی توأم از طریق رابطه‌ی (۲۲).

مرحله ۸: ادامه مراحل تا برقراری شرط $\max\{U^{(t)} - U^{(t+1)}\} < \varepsilon$.

مرحله ۹: به کارگیری متغیرهای Z_{ij} و W_j جهت انجام فرآیند بخش‌بندی.

۲-۳- استانداردسازی شدت

در سال‌های اخیر، مطالعات قابل توجهی در زمینه‌ی تصویربرداری عصبی انجام شده است. با این حال، استفاده از واحدهای روشنایی دلخواه و متفاوت در انواع اسکنرهای تصویربرداری تشدید مغناطیسی یک چالش اصلی به شمار می‌رود. این فرآیند منجر به کشف این موضوع شده است که تفاوت در شدت روشنایی MRI بین پارامترهای اسکن و مطالعات، بزرگ‌تر از تفاوت‌های بیولوژیکی واقعی مشاهده شده در تصاویر است. در نتیجه، استانداردسازی شدت‌های روشنایی تصاویر MRI جهت تجزیه و تحلیل دقیق تغییرات در طول زمان و یا بخش‌بندی بافت‌ها و ساختارهای مختلف بسیار مهم است. مسأله استانداردسازی شدت به طور گسترده‌ای در ادبیات با روش‌های مختلف پیشنهاد شده مطرح شده است [۳۶]. این رویکردها طیف گسترده‌ای از رویکردهای مبتنی بر هیستوگرام تا روش‌های آماری مانند min-max و z-score است. به عنوان مثال در [۳۷] روش White Stripe، که اعمال یک تبدیل Z-score به کل مغز با استفاده از پارامترهای تخمینی از یک زیر توزیع از ماده سفید با تظاهر طبیعی است، توسعه داده شد. این روش به ویژه برای مطالعات مربوط به اختلالات مغزی، مانند آسیب‌های MS مناسب است. زیرا به طور موثر ماده سفید را در بین افراد مختلف قابل مقایسه می‌کند. هر چند، مشاهده شده است که تغییرات باقی مانده در بین افراد هنوز در ماده سیاه وجود دارد. در حالی که

$$\mu_{ij} = \left(\frac{(x_i - v_j)^T \cdot A_j \cdot (x_i - v_j)}{\sum_{j=1}^C (x_i - v_j)^T \cdot A_j \cdot (x_i - v_j)} \right)^{1/q-1} \quad (12)$$

جهت به دست آوردن مراکز خوشه، از J_{GK} نسبت به v_j مشتق گرفته و برابر صفر قرار داده می‌شود. با حل معادله، رابطه‌ی (۱۴) به منظور به روزرسانی مراکز خوشه به کار گرفته می‌شود:

$$\frac{\partial J_{GK}}{\partial v_j} = -2 \sum_{i=1}^N \mu_{ij}^q \cdot (x_i - v_j) \cdot A_j = 0 \quad (13)$$

$$v_j = \frac{\sum_{i=1}^N \mu_{ij}^q \cdot x_i}{\sum_{i=1}^N \mu_{ij}^q} \quad (14)$$

در گام بعدی جهت به روزرسانی ماتریس عضویت، از J_{GK} نسبت به A_j مشتق گرفته و برابر صفر قرار داده می‌شود:

$$\begin{aligned} \frac{\partial J_{GK}}{\partial A_j} &= \sum_{i=1}^N \mu_{ij}^q \cdot (x_i - v_j)^T \cdot (x_i - v_j) - \\ &\sum_{i=1}^N \left(\lambda_i \cdot \frac{\partial}{\partial A_j} \left(\det(A_j) \right) \right) = \sum_{i=1}^N \mu_{ij}^q \cdot (x_i - v_j)^T \cdot (x_i - v_j) - \\ &\sum_{i=1}^N (\lambda_i \cdot \mu_{ij}^q \cdot A_j^{-1}) = 0 \end{aligned} \quad (15)$$

با حل رابطه‌ی (۱۵)، جواب متناظر برای ماتریس کواریانس به صورت زیر به روزرسانی می‌شود:

$$F_i = \frac{\sum_{j=1}^C \mu_{ij}^q \cdot (x_i - v_j)^T \cdot (x_i - v_j)}{\sum_{j=1}^C \mu_{ij}^q} \quad (16)$$

$$A_j = \lambda_i \cdot (\det(F_i))^{\frac{1}{n}} \cdot F_i^{-1} \quad (17)$$

در پردازش تصاویر MRI، پیکسل‌های همسایه به یکدیگر وابسته بوده و همبستگی زیادی دارند. در صورت در نظر نگرفتن همبستگی پیکسل‌های همسایه، الگوریتم FCM عمل کرد مناسبی در فرآیند خوشه‌بندی ندارد. بنابراین، در این مطالعه، رویکرد مشارکتی تعامل بین پیکسل‌های مجاور در تابع عضویت به کار گرفته می‌شود که اگر پیکسل‌های همسایه ویژگی‌های مشابهی داشته باشند، پیکسل‌های مرکزی باید احتمال بیشتری برای گروه‌بندی به همان خوشه با پیکسل‌های همسایه را داشته باشند. همچنین، به کارگیری اطلاعات مکانی جهت کاهش اثرات نویز و غیریکنواختی شدت روشنایی مناسب خواهد بود. الگوریتم CSGK متغیرهای شرطی را با فرض مقادیر $f_1, f_2, \dots, f_N$ برای تمامی پیکسل‌های $x_1, x_2, \dots, x_N$ در نظر می‌گیرد. متغیر f_N میزان دخالت پیکسل x_N در مقادیر نهایی ماتریس عضویت و خوشه‌های بازسازی شده را توصیف می‌کند. اولین متغیر مکانی شرطی در الگوریتم CSGK متغیر u_{ij} بوده که تعریف کننده‌ی تعلق پیکسل x_j به i امین خوشه بوده و به صورت زیر تعریف می‌شود:

$$u_{ij} = f_{ij} \cdot \mu_{ij} \quad (18)$$

$$0 \leq f_{ij} \leq 1 \quad (19)$$

که در آن به صورت زیر تعریف می‌شود:

$$f_{ij} = \frac{1}{M} \sum_{j \in N(x_N)} \mu_{ij} \quad (20)$$

که در آن $N(x_N)$ یک همسایگی مربعی با پیکسل مرکزی x_N و تعداد کل پیکسل‌های همسایه‌ی M است. همسایگی‌های بزرگ‌تر منجر به صاف شدگی بیشتر لبه‌ها و نرخ بالاتر طبقه‌بندی نادرست پیکسل‌ها می‌شود. در این مطالعه، جهت رسیدن به میزان همسایگی مطلوب، به صورت تجربی براساس آزمایش‌های مختلف، همسایگی مناسب $N(x_N) = 3 \times 3$ در نظر گرفته شد.

فرض می‌شود که مقادیر عضویت سراسری μ_{ij} و محلی u_{ij} مستقل از یکدیگر بوده و با ترکیب این دو پارامتر، متغیر عضویت وزن‌دار Z_{ij} و مرکز خوشه W_j به صورت زیر معرفی می‌شوند که مشارکت کننده‌ی اطلاعات محلی و سراسری هستند:

به کار گرفته می شود. این معیار به صورت زیر تعریف می شود:

$$DS(A, B) = \frac{2|A \cap B|}{|A| + |B|} \quad (24)$$

ضریب تشابه جاکارد جهت محاسبه ی میزان تشابه بین دو تصویر به کار گرفته شده و به صورت زیر تعریف می شود:

$$JS(A, B) = \frac{|A \cap B|}{|A \cup B|} \quad (25)$$

معیار CS جهت محاسبه ی امتیاز تطبیق کانتور بین تصاویر بخش بندی شده با استفاده از الگوریتم پیشنهادی و دستی به کار گرفته می شود. این معیار در محدوده ی [۰، ۱] بوده و به صورت زیر تعریف می شود:

$$CS = \frac{2.P^c.R^c}{P^c + R^c} \quad (26)$$

که در آن P^c و R^c به ترتیب نشان دهنده ی دقت و پوشش است. الگوریتمی بهترین عمل کرد را دارد که از لحاظ معیارهای JSC ، DSC و CMS بالاترین مقدار را داشته باشد.

عمل کرد الگوریتم پیشنهادی با الگوریتم های MICO، ARKFCM، FCM، FCMPSO، BCIFCMSNI و الگوریتم مقاوم و سریع FCM (FRFCM) [۴۵] مورد مقایسه قرار می گیرد. پارامترهای ثابت در این روش ها بر اساس مقادیر در نظر گرفته شده در مقاله انتخاب شده است. نتایج عمل کرد الگوریتم های مختلف در بخش بندی بافت های مغزی شامل WM، GM و CSF به ترتیب در جدول های ۱ الی ۳ آورده شده اند. نتایج جدول ۱ نشان می دهد که الگوریتم پیشنهادی تحت شرایط مختلف در معیارهای JS و CS بهترین عمل کرد را نسبت به سایر الگوریتم ها دارد. در معیار DS ، الگوریتم FRFCM عمل کرد بهتری را دارد. همچنین، نتایج نشان می دهند که در بخش بندی GM و CSF الگوریتم CSGK پیشنهادی نسبت به سایر الگوریتم ها بهترین عمل کرد را دارد.

جدول ۱- مقایسه ی عمل کرد الگوریتم پیشنهادی با سایر الگوریتم ها

در بخش بندی WM بر روی پایگاه داده ی BrainWeb.

معیار \ روش	$DS (\%) \uparrow$		$JS (\%) \uparrow$		$CS (\%) \uparrow$	
	٪۲۰	٪۴۰	٪۲۰	٪۴۰	٪۲۰	٪۴۰
	INU	INU	INU	INU	INU	INU
MICO	۸۴/۰۶	۸۴/۵۵	۷۲/۷۶	۷۳/۵۰	۷۷/۳۴	۷۸/۲۶
ARKFCM	۹۳/۱۱	۹۰/۶۳	۸۷/۱۹	۸۲/۹۷	۹۴/۲۷	۸۹/۸۰
FCMPSO	۶۲/۹۷	۷۱/۱۴	۵۱/۱۵	۵۹/۵۴	۷۳/۱۱	۷۵/۷۹
FCMWOA	۸۰/۳۵	۸۲/۲۰	۶۹/۳۱	۷۰/۸۸	۷۶/۹۲	۷۷/۷۶
BCIFCMSNI	۸۵/۷۶	۸۵/۲۵	۷۵/۴۴	۷۴/۹۷	۸۲/۱۳	۷۸/۶۶
FRFCM	۹۳/۵۲	۹۱/۷۹	۸۷/۸۸	۸۵/۱۹	۹۶/۶۶	۹۳/۲۵
CSGK	۹۲/۹۳	۹۱/۹۰	۸۸/۵۷	۸۵/۲۴	۹۷/۲۵	۹۳/۹۷

جدول ۲- مقایسه ی عمل کرد الگوریتم پیشنهادی با سایر الگوریتم ها

در بخش بندی GM بر روی پایگاه داده ی BrainWeb.

معیار \ روش	$DS (\%) \uparrow$		$JS (\%) \uparrow$		$CS (\%) \uparrow$	
	٪۲۰	٪۴۰	٪۲۰	٪۴۰	٪۲۰	٪۴۰
	INU	INU	INU	INU	INU	INU
MICO	۷۵/۰۴	۷۵/۶۹	۶۰/۳۳	۶۱/۲۰	۹۱/۹۰	۹۲/۲۰
ARKFCM	۷۷/۵۷	۷۴/۳۵	۶۵/۶۳	۶۱/۲۲	۹۵/۶۹	۹۴/۲۱
FCMPSO	۵۹/۱۵	۵۸/۸۲	۴۵/۴۵	۴۴/۶۶	۸۸/۴۰	۸۸/۲۲
FCMWOA	۶۷/۹۴	۶۸/۴۴	۵۳/۳۶	۵۳/۶۵	۹۱/۵۸	۹۱/۷۷
BCIFCMSNI	۶۹/۸۱	۶۷/۹۶	۵۵/۵۸	۵۵/۰۰	۹۳/۹۴	۹۱/۱۸
FRFCM	۸۶/۸۱	۸۵/۲۱	۷۶/۷۴	۷۴/۱۲	۹۴/۷۰	۹۳/۱۱
CSGK	۸۸/۸۱	۸۶/۳۴	۷۹/۹۳	۷۶/۰۲	۹۷/۷۴	۹۶/۲۵

روش های معمول استاندارد سازی شدت موفق در اصلاح تغییرات شدت جهانی مرتبط با محل اسکنر هستند، هنوز تفاوت فنی قابل توجهی بین اسکنرها وجود دارد، که به طور معمول به عنوان "اثر اسکن" شناخته می شود [۳۸]. این تغییرات فنی می تواند به عوامل مختلفی از جمله پارامترهای اسکن، تولید کنندگان اسکنر و قدرت میدان اسکنر مرتبط باشند.

به منظور پیدا کردن یک روش کاربردی تر، برخی مراجع قابل اعتماد در تصاویر می تواند به یک استاندارد سازی کامل کمک کند. در این مقاله، از باقی مانده های استفاده از یک روش استخراج مغز [۳۹] برای به دست آوردن مقادیر و مراجع قابل اعتماد ثابت در سراسر اسلایس ها و اسکن ها از بیماران، حتی در طول زمان، استفاده شده است. تا زمانی که ما از تصاویر T1 و T2-FLAIR استفاده می کنیم، ثابت شده است که پوست سر و جمجمه از روشن ترین مناطق هستند [۴۰، ۴۱]. به طور خلاصه، برای تصویر داده شده (I)، یک روش استخراج مغز در ابتدا مورد استفاده قرار می گیرد. یک تصویر باقی مانده (R) با اعمال ماسک مغز از I استخراج می شود. متوسط دهک اول و آخر شدت های R به عنوان حداقل و حداکثر مقادیر محاسبه می شود. در نهایت، I بر اساس این مقادیر با استفاده از روش min-max به صورت زیر استاندارد سازی می شود:

$$x' = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (23)$$

۳- نتایج پیاده سازی

به منظور ارزیابی عمل کرد الگوریتم پیشنهادی و مقایسه ی آن با سایر روش ها، از دو پایگاه داده ی MRI مغزی شامل BrainWeb [۴۲] و مرکز تصویربرداری پزشکی گلگشت تبریز استفاده شده است. برای پایگاه داده ی BrainWeb، از تصاویر مبتنی بر T1 تحت نویز ۹٪ و شرایط مختلف INU (۲۰٪ و ۴۰٪) در اسلایس های ۸۰ الی ۱۲۰ استفاده شده است. همچنین، در این مطالعه از داده های پژوهش جمع آوری شده شامل ۱۰ بیمار با تشخیص تحلیل سلول های عصبی که با استفاده از یک اسکنر TOSHIBA Vantage 1.5 Tesla در مرکز تصویربرداری پزشکی گلگشت تبریز استفاده شده است. پروتکل های اسکن MRI با روش های استاندارد انجام گردید. در این فرآیند، جهت اخذ تصویر T1 از زمان تکرار ۵۴۰ میلی ثانیه، زمان اکو ۱۵ میلی ثانیه، زاویه چرخش ۷۰ درجه، میدان دید ۲۳۰ در ۲۳۰ میلی متر، تعداد اسلایس ۱۸، اندازه وکسل ۰/۴۵ میلی متر و ضخامت اسلایس ۶ میلی متر استفاده شد. همچنین، جهت اخذ تصویر T2-FLAIR از زمان تکرار ۱۰۰۰۰ میلی ثانیه، زمان اکو ۱۰۰ میلی ثانیه، زمان برگردان ۲۵۰۰ میلی ثانیه، زاویه چرخش ۹۰ درجه، میدان دید ۲۳۰ در ۲۳۰ میلی متر، تعداد اسلایس ۲۰، اندازه وکسل ۰/۹ میلی متر و ضخامت اسلایس ۶ میلی متر استفاده شد. در نهایت، یک نرولوژیست به دقت تمام اسکن های بیماران را بررسی کرده است. در این مطالعه از تصاویر T1 و T2-FLAIR با اندازه های وکسل (۰/۴۵، ۰/۴۵) و (۰/۹، ۰/۹) و (۰/۹، ۰/۹) میلی متر استفاده شد. این پژوهش در کمیته اخلاق دانشگاه علوم پزشکی تبریز تصویب و رضایت نامه ای از همه شرکت کنندگان دریافت شد. بیماری پارکینسون یک بیماری تخریب کننده ی عصبی بوده که بر عمل کرد حرکتی بیمار تاثیر می گذارد. فرآیند درمان جراحی نیازمند اطلس مغز برای شناسایی است. علاوه بر دو پایگاه داده ی ذکر شده، جهت ارزیابی بهتر عمل کرد الگوریتم پیشنهادی از تصاویر MRI گروه بیماری پارکینسون شامل ۴۱ تصویر مبتنی بر وزن T1 (اسلایس ۸۰ تا ۱۲۰) نیز استفاده شده است [۴۳].

جهت ارزیابی عمل کرد الگوریتم ها در فرآیند بخش بندی، سه معیار تشابه دایس (DS)، جاکارد (JS) و تطبیق کانتور (CS) [۴۴] به کار گرفته می شوند. معیار DS جهت اندازه گیری درجه ی هم پوشانی بین دو تصویر بخش بندی شده با استفاده از الگوریتم پیشنهادی (A) و بخش بندی شده به صورت دستی (B)

جدول ۳- مقایسه‌ی عمل کرد الگوریتم پیشنهادی با سایر الگوریتم‌ها

در بخش‌بندی CSF بر روی پایگاه داده‌ی BrainWeb.

معیار روش	DS (%) ↑		JS (%) ↑		CS (%) ↑	
	٪۲۰	٪۴۰	٪۲۰	٪۴۰	٪۲۰	٪۴۰
	INU	INU	INU	INU	INU	INU
MICO	۸۲/۷۰	۸۳/۳۷	۷۰/۷۰	۷۱/۶۷	۹۵/۱۳	۹۵/۰۷
ARKFCM	۶۳/۱۰	۶۵/۹۸	۵۲/۱۲	۵۳/۵۹	۹۰/۴۱	۹۰/۵۰
FCMPSO	۶۵/۰۳	۶۵/۶۶	۵۱/۲۲	۵۲/۳۷	۸۸/۳۳	۸۸/۹۴
FCMWOA	۶۷/۳۴	۶۸/۰۱	۵۲/۶۲	۵۲/۸۰	۸۹/۳۵	۸۹/۸۰
BCIFCMSNI	۵۲/۰۹	۶۴/۲۶	۴۴/۰۷	۵۸/۸۹	۷۴/۶۴	۷۶/۳۳
FRFCM	۸۲/۱۵	۸۲/۱۳	۷۰/۱۰	۷۰/۰۶	۸۸/۵۱	۸۹/۱۹
CSGK	۸۸/۶۴	۸۷/۵۷	۷۹/۶۵	۷۷/۹۹	۹۷/۵۸	۹۷/۰۹

براساس نتایج جدول‌های ۱ الی ۳، مزایا و معایب روش‌ها را می‌توان به صورت زیر خلاصه کرد:


- الگوریتم MICO در بخش‌بندی بافت‌های GM و CSF عمل کرد خوبی داشته، ولی در بخش‌بندی بافت WM به خوبی عمل نمی‌کند. نتایج نشان می‌دهند که این الگوریتم عمل کرد مناسبی در شناسایی مرزهای بافت WM تحت نویز ۹٪ و شرایط مختلف INU برای تصاویر شبیه‌سازی شده‌ی BrainWeb ندارد. این الگوریتم در بخش‌بندی تصاویر مربوط به اسلایس‌های ۱۰۴ الی ۱۱۳ عمل کرد مناسبی ندارد. الگوریتم ARKFCM عمل کرد خوبی در بخش‌بندی WM داشته، ولی به خاطر عمل کرد نامناسب در اسلایس‌های ۹۹ الی ۱۰۴ برای بخش‌بندی بافت‌های GM و CSF کارآیی مناسبی ندارد. الگوریتم ARKFCM عمل کرد خوبی در بخش‌بندی WM داشته ولی برای بخش‌بندی بافت‌های GM و CSF به خوبی عمل نمی‌کند. همچنین، این الگوریتم با توجه به وابسته بودن به کرنل‌های غیرخطی سرعت همگرایی پایینی نیز دارد. رویکردهای مبتنی بر جمعیت (FCMPSO و FCMWOA) تحت شرایط پیچیده نویز و غیریکنواختی شدت روشنایی عمل کرد خوبی ندارند. براساس شکل ۳(د)، الگوریتم FCMPSO معمولاً کلاس پس‌زمینه را به اشتباه به بافت GM برچسب می‌زند. تحت شرایط مختلف تصویر، الگوریتم PSO نیازمند تنظیم متفاوت پارامترهای فاز استخراج و اکتشاف است. در مقابل، الگوریتم WOA به پارامترهای تنظیم نیازمند نیست. براساس شکل ۳(و)، الگوریتم FCMWOA برای خوشه‌های فشرده (یعنی CSF) به خوبی عمل نکرده و معمولاً بافت مایع مغزی-نخاعی را به اشتباه به کلاس پس‌زمینه و یا ماده‌ی خاکستری برچسب می‌زند. براساس بخش‌بندی بافت‌های مختلف مغزی در اسلایس‌های مختلف به این موضوع پی برده شد که، الگوریتم BCIFCMSNI عمل کرد مناسبی در بخش‌بندی اسلایس‌های ۱۰۹ الی ۱۲۰ نداشته و الگوریتم مناسبی برای بخش‌بندی خوشه‌ی فشرده یعنی CSF و GM نیست. نتایج نشان می‌دهند که دو الگوریتم FRFCM و CSGK عمل کرد خوبی در مقایسه با سایر روش‌ها دارند. الگوریتم FRFCM خوشه‌ها را در یک فضای کروی در نظر می‌گیرد و این فرآیند باعث می‌شود که برای خوشه‌های فشرده و با اندازه کوچک مثل بافت CSF مغزی عمل کرد خوبی نداشته باشد. در مقابل، الگوریتم CSGK پیشنهادی با در نظر گرفتن توزیع داده‌ها در یک فضای بیضوی توانسته این چالش را حل کند و در مقابل نویز و شرایط مختلف INU نیز مقاوم باشد.

همچنین، از ویژگی‌های بارز الگوریتم پیشنهادی می‌توان به این موضوع اشاره کرد که برای تمامی اسلایس‌ها (۸۰ الی ۱۲۰) عمل کرد خوبی داشته و سریع‌تر همگرا می‌شود.

- با توجه به اهمیت GM در تشخیص بیماری‌هایی نظیر ADHD و آلزایمر، الگوریتم‌های ارائه شده برای بخش‌بندی بافت‌های مغزی باید عمل کرد خوبی در بخش‌بندی ماده خاکستری داشته باشند. مطابق نتایج جدول ۲، الگوریتم پیشنهادی قادر به بخش‌بندی بافت GM تحت شرایط مختلف نویز و INU بوده و بهترین عمل کرد را از منظر سه معیار DS ، JS و CS در مقایسه با سایر الگوریتم‌های مقایسه شده دارد. براساس معیارهای DS و JS ، الگوریتم‌های FCMPSO، FCMWOA و BCIFCMSNI بدترین عمل کرد را در بخش‌بندی بافت GM دارند. الگوریتم FCMWOA نسبت به FCMPSO عمل کرد مناسبی را داشته و در شرایط سطح بالای INU نسبت به FCMPSO مقاوم‌تر است. دلیل عمل کرد نامناسب روش‌های FCMPSO و FCMWOA این است که در سطوح بالای نویز و INU در بعضی از تصاویر به اشتباه پس‌زمینه را به بافت GM برچسب می‌زنند. برخلاف سایر الگوریتم‌های مقایسه شده، به کارگیری رویکرد WFWT به عنوان یک مرحله‌ی پیش‌پردازش باعث مقاوم شدن الگوریتم CSGK پیشنهادی نسبت به نویز و INU شده است. الگوریتم BCIFCMSNI در اسلایس‌های ۸۰ الی ۸۵ و ۹۰ الی ۱۰۲ عمل کرد مناسبی داشته و برای سایر اسلایس‌ها گزینه‌ی مناسبی نیست و عملاً این شرایط باعث شده است که در حالت میانگین کل اسلایس‌ها عمل کرد مناسبی نداشته باشد. از منظر معیار CS الگوریتم ARKFCM عمل کرد مناسبی در بخش‌بندی بافت GM در سطوح بالا از INU داشته و از منظر سایر معیارها گزینه‌ی مناسبی برای بخش‌بندی بافت GM نیست. این الگوریتم از منظر پیچیدگی محاسباتی نیز هزینه‌ی بالایی دارد. همان‌طوری که به عنوان یک نمونه در شکل ۳(ی) نیز نشان داده شده است، الگوریتم FRFCM در بعضی از موارد کلاس بافت GM را به اشتباه به کلاس بافت WM برچسب می‌زند و این فرآیند باعث شده است که نسبت به الگوریتم پیشنهادی در بخش‌بندی GM داده‌های شبیه‌سازی شده‌ی BrainWb عمل کرد ضعیفی داشته باشد.
- با توجه به اینکه CSF نقش کلیدی در ارزیابی خونریزی در مغز و یا نخاع و همچنین آسیب‌های تروماتیک مغزی ایفا می‌کند، بخش‌بندی CSF باید با دقت بالایی انجام شود. ناحیه‌ی CSF در تصاویر MRI از یک خوشه‌ی فشرده و کوچک تشکیل شده است. در نتیجه، رویکردهای مبتنی بر FCM نمی‌تواند فرآیند بخش‌بندی این بافت مغزی را براساس فاصله‌ی اقلیدسی به خوبی انجام دهند. همان‌طوری که در شکل ۳ نیز نشان داده شده است، رویکردهای مبتنی بر FCM پیکسل‌های مربوط به بافت CSF را به صورت نادرست برچسب می‌زنند. این موضوع نشان می‌دهد که الگوریتم‌های مبتنی بر FCM برای خوشه‌های با اندازه و ریخت غیریکسان مناسب نیستند. نتایج آزمایش نشان می‌دهد که الگوریتم CSGK پیشنهادی با در نظر گرفتن توزیع داده‌ها در یک فضای بیضوی می‌تواند جهت آشکارسازی خوشه‌ها با اندازه‌ی غیریکسان و جهت‌گیری‌های مختلف مناسب باشد. مطابق نتایج جدول ۳، دو الگوریتم MICO و CSGK عمل کرد مناسبی در بخش‌بندی بافت CSF دارند. الگوریتم MICO معمولاً برای تصاویر با اسلایس‌های

فرآیند باعث می‌شود که این دو الگوریتم عمل کرد مناسبی نداشته باشند.

- همان‌طوری که در شکل ۴(ن) نیز نشان داده شده است، الگوریتم BCIFCMSNI معمولاً در برخی از تصاویر به اشتباه کلاس بافت GM را به عنوان کلاس بافت WM در نظر می‌گیرد. از منظر معیار CS نیز مقدار پایینی دارد و این موضوع نشان می‌دهد که این الگوریتم در شناسایی مرزهای بافت‌های مختلف مغزی عمل کرد مناسبی ندارد.
- الگوریتم‌های FRFCM و CSGK عمل کرد خوبی در بخش‌بندی بافت‌های مغزی بر روی تصاویر پایگاه داده‌ی مرکز تصویربرداری پزشکی گلگشت تبریز دارند. بافت CSF نقش حیاتی در پاک‌سازی مواد زائد متابولیک از مغز انسان دارد. الگوریتم FRFCM بخش‌بندی بافت CSF از منظر تمامی معیارهای اندازه‌گیری نسبت به الگوریتم پیشنهادی عمل کرد ضعیفی دارد و این موضوع نشان می‌دهد که رویکرد به‌کارگیری فاصله‌ی اقلیدسی گزینه‌ی مناسبی برای خوشه‌های فشرده با اندازه‌ی کوچک نیست.




شکل ۴- عمل کرد کیفی بخش‌بندی الگوریتم‌های مختلف بر روی تصاویر پایگاه داده‌ی مرکز تصویربرداری پزشکی گلگشت تبریز: (الف) تصویر ورودی، (ب) خروجی الگوریتم MICO، (ج) خروجی الگوریتم ARKFCM، (د) خروجی الگوریتم FCMPWOA، (و) خروجی الگوریتم FCMPWOA، (ن) خروجی الگوریتم BCIFCMSNI، (ی) خروجی الگوریتم FRFCM، (ه) خروجی الگوریتم CSGK پیشنهادی.

نتایج مقایسه‌ی کمی الگوریتم پیشنهادی با سایر الگوریتم‌های مقایسه شده بر روی تصاویر MRI گروه بیماری پارکینسون در جدول ۵ و همچنین مقایسه کیفی بر روی یک نمونه از تصاویر این پایگاه داده در شکل ۵ آورده شده است. عمل کرد انواع الگوریتم‌ها بر روی پایگاه داده‌ی گروه بیماری پارکینسون به صورت زیر خلاصه می‌شود:

- الگوریتم MICO عمل کرد خوبی در بخش‌بندی WM از منظر معیارهای DS و CS دارد. پایین بودن معیار DS برای این الگوریتم نشان می‌دهد که عمل کرد مناسبی در میزان تشابه به تصویر مرجع ندارد. در رویکردهای مبتنی بر بهینه‌سازی FCM با استفاده از الگوریتم‌های فراابتکاری، روش FCMPWOA در مقایسه با FCMPWOA عمل کرد خوبی در بخش‌بندی WM دارد. براساس شکل ۵(د)، الگوریتم FCMPWOA در بعضی از موارد به اشتباه کلاس

بالتر (۱۰۰ الی ۱۱۰) مناسب نبوده و همچنین براساس معیار JS نمی‌تواند مرز بافت‌های CSF را با جزئیات بیشتری آشکارسازی کند، این درحالی است که الگوریتم پیشنهادی با اختلاف دقت تقریباً ۹٪ عمل کرد بهتری نسبت به الگوریتم MICO از منظر شناسایی مرزهای بافت CSF مغزی دارد. نتایج جدول ۳ تایید می‌کند که الگوریتم CSGK پیشنهادی عمل کرد بهتری نسبت به سایر رویکردهای مبتنی بر FCM در بخش‌بندی خوشه‌های فشرده دارد به طوری که از منظر معیار DS در سطوح بالای نویز نسبت به الگوریتم FRFCM و رویکردهای مبتنی بر الگوریتم‌های فراابتکاری اختلاف ۵٪ و ۲۰٪ دارد. با توجه به در نظر گرفتن تغییرات غیریکنواختی شدت روشنایی در الگوریتم‌های MICO و BCIFCMSNI، این رویکردها به دلیل در نظر گرفتن فضای کروی خوشه‌ها عمل کرد مناسبی در بخش‌بندی CSF به عنوان یک خوشه فشرده در تصاویر MRI ندارد.



شکل ۳- عمل کرد کیفی بخش‌بندی الگوریتم‌های مختلف بر روی نمونه‌ای از تصویر پایگاه داده‌ی BrainWeb: (الف) تصویر ورودی با نویز ۹٪ و غیریکنواختی ۴۰٪، (ب) خروجی الگوریتم MICO، (ج) خروجی الگوریتم ARKFCM، (د) خروجی الگوریتم FCMPWOA، (و) خروجی الگوریتم FCMPWOA، (ن) خروجی الگوریتم BCIFCMSNI، (ی) خروجی الگوریتم FRFCM، (ه) خروجی الگوریتم CSGK پیشنهادی.

نتایج انواع متفاوت الگوریتم‌ها در بخش‌بندی بافت‌های مختلف مغزی بر روی تصاویر پایگاه داده‌ی مرکز تصویربرداری پزشکی گلگشت تبریز در جدول ۴ آورده شده است. مقایسه‌ی عمل کردی انواع الگوریتم‌ها بر روی این پایگاه داده به صورت زیر خلاصه می‌شود:

- نتایج پیاده‌سازی نشان می‌دهد که الگوریتم CSGK پیشنهادی بهترین عمل کرد را در بخش‌بندی بافت‌های مغزی بافت‌های مغزی داشته و نسبت به شرایط مختلف تخریب تصویر نیز مقاوم هست.
- رویکردهای مبتنی بر جمعیت (FCMPWOA و FCMPWOA) بدترین عمل کرد را در بخش‌بندی بافت‌های مغزی بر روی تصاویر واقعی MRI دارند. براساس شکل ۴(د)، در FCMPWOA، کلاس بافت WM معمولاً به اشتباه به کلاس بافت GM برچسب زده می‌شود. همچنین، مطابق شکل ۴(و)، در FCMPWOA، کلاس بافت CSF معمولاً به اشتباه به کلاس پس‌زمینه برچسب زده می‌شود. این

جدول ۴- مقایسه‌ی عمل کرد الگوریتم پیشنهادی با سایر الگوریتم‌ها در بخش‌بندی بافت‌های مغزی بر روی تصاویر پایگاه داده‌ی مرکز تصویربرداری پزشکی گلگشت تبریز.


معیار روش	DS (%) ↑			JS (%) ↑			CS (%) ↑		
	WM	GM	CSF	WM	GM	CSF	WM	GM	CSF
MICO	۸۰/۴۱	۶۲/۵۱	۷۶/۲۲	۶۸/۶۹	۴۶/۱۶	۶۲/۶۳	۷۵/۷۱	۸۹/۶۹	۹۱/۶۲
ARKFCM	۸۳/۳۱	۷۱/۴۳	۷۰/۶۸	۷۵/۷۲	۶۰/۹۵	۵۹/۱۱	۸۱/۳۳	۹۱/۷۷	۹۱/۴۱
FCMPPO	۸۴/۱۴	۶۷/۸۹	۶۲/۷۴	۷۵/۲۷	۵۶/۰۱	۵۱/۱۵	۷۹/۷۴	۸۹/۰۵	۸۴/۳۴
FCMWOA	۷۲/۶۳	۳۵/۲۳	۳۹/۲۶	۶۱/۰۱	۳۷/۱۳	۳۸/۳۷	۴۹/۳۲	۶۹/۷۱	۶۵/۹۹
BCIFCMSNI	۷۸/۲۳	۷۲/۸۹	۷۶/۸۱	۷۴/۶۹	۶۱/۱۳	۶۰/۱۲	۷۰/۷۸	۸۱/۱۳	۷۰/۱۵
FRFCM	۸۸/۲۰	۸۱/۴۶	۸۱/۶۳	۸۱/۳۹	۷۰/۳۴	۷۰/۴۹	۸۶/۶۳	۹۰/۶۶	۹۱/۱۲
CSGK	۸۸/۶۵	۷۹/۹۰	۸۸/۱۹	۷۹/۱۲	۶۸/۴۰	۷۹/۴۲	۸۶/۷۲	۹۲/۹۷	۹۷/۵۴

جدول ۵- مقایسه‌ی عمل کرد الگوریتم پیشنهادی با سایر الگوریتم‌ها در بخش‌بندی بافت‌های مغزی بر روی تصاویر MRI گروه پارکینسون [۴۳].

معیار روش	DS (%) ↑			JS (%) ↑			CS (%) ↑		
	WM	GM	CSF	WM	GM	CSF	WM	GM	CSF
MICO	۸۴/۸۸	۵۸/۰۰	۵۰/۰۰	۷۳/۹۵	۴۱/۵۸	۴۷/۸۷	۸۳/۸۰	۹۲/۹۳	۶۲/۵۶
ARKFCM	۹۲/۱۴	۸۳/۱۳	۶۶/۰۹	۹۰/۴۷	۷۷/۴۹	۵۰/۸۷	۹۴/۳۶	۹۵/۱۱	۹۴/۵۹
FCMPPO	۸۹/۹۳	۷۵/۷۸	۶۰/۰۵	۸۲/۸۷	۶۳/۲۰	۴۵/۶۷	۸۹/۸۱	۹۲/۰۰	۸۵/۱۷
FCMWOA	۸۷/۸۶	۶۱/۶۴	۵۵/۱۶	۷۹/۶۵	۴۸/۹۷	۴۰/۴۸	۸۵/۱۱	۹۳/۹۲	۸۶/۵۶
BCIFCMSNI	۸۷/۲۵	۵۸/۲۵	۴۲/۱۲	۷۷/۹۴	۴۲/۰۳	۴۳/۷۳	۸۹/۷۴	۹۳/۳۱	۵۲/۵۲
FRFCM	۹۳/۳۶	۸۵/۴۵	۷۱/۹۳	۹۰/۱۶	۷۸/۱۱	۵۷/۵۹	۹۵/۱۷	۹۵/۵۴	۹۳/۱۴
CSGK	۹۵/۶۲	۸۶/۰۳	۷۹/۸۰	۹۲/۸۴	۷۹/۷۲	۶۷/۵۵	۹۷/۱۱	۹۷/۹۴	۹۵/۷۷

پس‌زمینه را به کلاس WM برچسب می‌زند. هر دو الگوریتم FCMPPO و FCMWOA عموماً بر روی تصاویر گروه بیماران پارکینسون کلاس بافت GM را به اشتباه به کلاس بافت WM برچسب می‌زنند و این امر باعث عمل کرد ضعیف آن‌ها می‌شود. این فرآیند نشان می‌دهد که عمل کرد بخش‌بندی بافت‌های مغزی در الگوریتم‌هایی نظیر PSO به پارامترهای تنظیم در فرآیندهای استخراج و اکتشاف وابسته است. الگوریتم BCIFCMSNI بر روی تصاویر این پایگاه داده نیز مشابه دو پایگاه داده دیگر در اسلایس‌های بالاتر کارایی مناسبی نداشته و در بعضی از موارد به اشتباه کلاس بافت WM را به کلاس بافت GM برچسب می‌زند. دو الگوریتم FRFCM و CSGK پیشنهادی نسبت به سایر الگوریتم‌ها در بخش‌بندی بافت WM مغزی عمل کرد بهتری دارند. الگوریتم FRFCM در برخی از پیکسل‌ها که جزء کلاس WM بوده ولی شدت روشنایی کم‌تری دارد عموماً درست عمل نکرده و به اشتباه چنین پیکسل‌هایی را به کلاس بافت GM برچسب می‌زند. برخلاف FRFCM، الگوریتم CSGK پیشنهادی به دلیل فرض کروی بودن خوشه‌ها عمل کرد خوبی را برای این نوع پیکسل‌ها دارد.

از منظر معیارهای DS ، JS و CS که نشان دهنده دقت بخش‌بندی، میزان تشابه تصویر بخش‌بندی شده به تصویر مرجع و جزئیات اطلاعات مربوط به لبه‌ی تصویر هستند، الگوریتم‌های ARKFCM، FRFCM و CSGK پیشنهادی عمل کرد خوبی در بخش‌بندی بافت GM دارند. براساس شکل ۵، در بعضی از موارد الگوریتم FRFCM به اشتباه کلاس بافت GM را به کلاس WM



شکل ۵- عمل کرد کیفی بخش‌بندی الگوریتم‌های مختلف بر روی تصاویر MRI گروه بیماری پارکینسون [۴۳]: (الف) تصویر ورودی، (ب) خروجی الگوریتم MICO، (ج) خروجی الگوریتم ARKFCM، (د) خروجی الگوریتم FCMPPO، (و) خروجی الگوریتم FCMWOA، (ن) خروجی الگوریتم BCIFCMSNI، (ی) خروجی الگوریتم FRFCM، (ه) خروجی الگوریتم CSGK پیشنهادی.

CSF، برخلاف رویکردهای مبتنی بر FCM، از فاصله‌ی ماهالانویس به جای فاصله‌ی اقلیدسی استفاده شد. در مرحله‌ی نهایی، رویکرد مشارکتی برای تعامل بین پیکسل‌های مجاور در تابع عضویت به کار گرفته شد؛ به این صورت که اگر پیکسل‌های همسایه دارای ویژگی‌های مشابهی باشند، احتمال بیشتری برای گروه‌بندی پیکسل‌های مرکزی در همان خوشه با پیکسل‌های همسایه وجود داشته باشد. درواقع، درواقع رویکرد شرطی باعث مقاوم شدن الگوریتم GK به نویز و آرتیفکت‌های تصویربرداری شد. سرانجام، جهت ارزیابی عمل کرد الگوریتم پیشنهادی و مقایسه‌ی آن با سایر الگوریتم‌های مبتنی بر FCM سه پایگاه داده شامل تصاویر شبیه‌سازی شده‌ی BrainWeb، تصاویر پایگاه داده‌ی مرکز تصویربرداری پزشکی گلگشت تبریز و تصاویر گروه بیماران پارکینسون استفاده شدند. نتایج پیاده‌سازی نشان داد که الگوریتم CSGK پیشنهادی یک الگوریتم دقیق برای بخش‌بندی بافت‌های مغزی در سطوح مختلف نویز و INU بوده و در همه‌ی اسلایس‌ها عملکرد مناسبی دارد. در الگوریتم پیشنهادی، تعداد مراکز خوشه به صورت تجربی تنظیم شد. بنابراین، بررسی یک الگوریتم جدید GK که تعداد خوشه‌ها را به صورت خودکار تنظیم کند، می‌تواند به عنوان یک گام تحقیقاتی در آینده مطرح شود. همچنین، افزودن مولفه‌ی بایاس به تابع هزینه‌ی الگوریتم CSGK می‌تواند به عنوان موضوعی برای تحقیقات آینده در زمینه‌ی پردازش تصاویر MRI در نظر گرفته شود.

مراجع

- [1] A. Kouhi et al., "Robust FCM clustering algorithm with combined spatial constraint and membership matrix local information for brain MRI segmentation," *Expert Systems with Applications*, vol. 146, pp. 113159, 2020.
- [2] M. M. Emam et al., "A modified reptile search algorithm for global optimization and image segmentation: Case study brain MRI images," *Computers in biology and medicine*, vol. 152, pp. 106404, 2023.
- [3] R. Bandyopadhyay et al., "Segmentation of brain MRI using an altruistic Harris Hawks' Optimization algorithm," *Knowledge-Based Systems*, vol. 232, pp. 107468, 2021.
- [4] T. Akbarpour and S. Daneshvar., "Increasing the Quality of MRI and PET Images Fusion by Combination of Gabor Wavelet and Retina Model," *Tabriz Journal of Electrical Eng.*, vol. 45, no. 4, pp. 23-35, 2015.
- [5] C. Li, et al., "Multiplicative intrinsic component optimization (MICO) for MRI bias field estimation and tissue segmentation," *Magnetic resonance imaging*, vol. 32, no. 7, pp. 913-923, 2014.
- [6] M. Hassan et al., "Robust spatial fuzzy GMM based MRI segmentation and carotid artery plaque detection in ultrasound images," *Computer methods and programs in biomedicine*, vol. 175, pp. 179-192, 2019.
- [7] C. Singh et al., "An Intuitionistic Fuzzy C-Means and Local Information-Based DCT Filtering for Fast Brain MRI Segmentation," *Journal of Imaging Informatics in Medicine*, pp. 1-24, 2024.
- [8] S. Haghzad, "ISY: Improved Sugeno-Yasukawa Fuzzy Modelling Approach Using a Novel Clustering and Project Method for Input Partitioning," *Tabriz Journal of Electrical Eng.*, vol. 54, no. 3, pp. 355-362, 2024.
- [9] B. Jafrasteh et al., "Enhanced Spatial Fuzzy C-Means Algorithm for Brain Tissue Segmentation in T1 Images," *Neuroinformatics*, pp. 1-14, 2024.
- [10] C. Singh et al., "A novel approach for brain MRI segmentation and image restoration under intensity inhomogeneity and noisy conditions," *Biomedical Signal Processing and Control*, vol. 87, pp. 105348, 2024.
- [11] S. Natarajan and et al., "Minimally parametrized segmentation framework with dual metaheuristic optimisation algorithms and FCM for detection of anomalies in MR brain images," *Biomedical Signal Processing and Control*, vol. 78, pp. 103866, 2022.
- [12] E. H. Houssein et al., "Accurate multilevel thresholding image segmentation via oppositional Snake Optimization algorithm: Real cases with liver disease," *Computers in Biology and Medicine*, vol. 169, pp. 107922, 2024.
- [13] H. Essam et al., "An efficient multilevel thresholding segmentation method for thermography breast cancer imaging based on

برجسب می‌زند. الگوریتم‌های FCMPSO، FCMWOA و BCIFCMSNI تعداد بیشتری از پیکسل‌های مربوط به بافت GM را به بافت WM برجسب می‌زنند.

- براساس نتایج جدول ۵، الگوریتم CSGK پیشنهادی بهترین عمل کرد را در بخش‌بندی CSF نسبت به سایر الگوریتم‌های مقایسه شده دارد. الگوریتم‌های FRFCM و ARKFCM قابلیت رقابت با الگوریتم پیشنهادی را در بخش‌بندی بافت‌های WM و GM داشتند، ولی با توجه به اینکه این دو الگوریتم و سایر الگوریتم‌ها از فرض کروی بودن داده در فرآیند خوشه‌بندی استفاده کرده‌اند، عمل کرد خوبی در بخش‌بندی خوشه‌های فشرده مانند CSF در تصاویر MRI ندارند. بالا بودن معیار CS نشان می‌دهد که الگوریتم پیشنهادی با جزئیات بیشتری می‌تواند اطلاعات مربوط به لبه‌های کلاس CSF را بخش‌بندی کند. از منظر معیار S، الگوریتم پیشنهادی اختلاف بالای ۱۰٪ نسبت به تمامی الگوریتم‌های مقایسه شده داشته و این موضوع نشان می‌دهد که رویکرد فرض بیضی بودن شکل هندسی خوشه‌ها نسبت به فرض کروی بودن آن‌ها در رویکردهای مبتنی بر FCM باعث تشابه بیشتر خروجی بخش‌بندی به تصاویر مرجع شده است.

- نتایج پیاده‌سازی نشان می‌دهد که الگوریتم CSGK پیشنهادی بهترین عمل کرد را در بخش‌بندی بافت‌های مغزی مربوط به گروه بیماری پارکینسون داشته و می‌تواند به عنوان رویکردی مناسب در کاربردهای مربوط به تشخیص و درمان انواع بیماری مغزی از روی تصاویر MRI به کار گرفته شود.

۴- نتیجه‌گیری و ارائه‌ی پیشنهادات

بخش‌بندی بافت‌های مغزی گامی ضروری برای ارزیابی تغییرات مورفولوژیکی نواحی مختلف مغز جهت شناسایی انواع بیماری‌ها بوده که به عوامل متعددی مانند نویز و غیریکنواختی شدت روشنایی وابسته است. از سوی دیگر، بخش‌بندی دقیق بافت مایع مغزی نخاعی از اهمیت ویژه‌ای برای متخصصان جراحی مغز و اعصاب برخوردار است. الگوریتم‌های خوشه‌بندی مبتنی بر FCM از فاصله‌ی اقلیدسی برای خوشه‌بندی استفاده می‌کنند. این معیار، تغییر فاصله‌ی نقاط داده در خوشه‌های فشرده و مشابه را در نظر نمی‌گیرد. استفاده از فاصله‌ی اقلیدسی به دلیل فشردگی و کوچک‌تر بودن بافت CSF نسبت به سایر بافت‌های مغزی، می‌تواند باعث شود که در فرآیند خوشه‌بندی، این کلاس به اشتباه به دیگر کلاس‌ها برجسب زده شود. همچنین، وجود غیریکنواختی شدت روشنایی در سطوح مختلف، عملکرد فرآیند خوشه‌بندی را تحت تأثیر قرار می‌دهد. برای حل مشکلات ذکر شده، در این مطالعه، الگوریتم گستافسون-کسل مبتنی بر اطلاعات مکانی شرطی (CSGK) برای بخش‌بندی بافت‌های مغزی بر اساس تصاویر MRI ارائه شد. از مزیت اصلی الگوریتم CSGK پیشنهادی می‌توان به عدم نیاز به محاسبه‌ی فاصله‌ی بین پیکسل‌ها درون همسایگی‌های مکانی اشاره کرد. جهت بخش‌بندی بافت‌های مغزی، در ابتدا، از فیلتر وینر بر اساس تجزیه‌ی تبدیل موجک (WFWT) برای بازسازی بهتر تصویر و بخش‌بندی آن تحت شرایط مختلف نویز و غیریکنواختی شدت روشنایی، با حفظ جزئیات لبه استفاده شد. هدف اصلی از به‌کارگیری WFWT، اعمال تبدیل موجک به تفاضل تصویر اصلی با خروجی حاصل از فیلتر وینر و باز گرداندن برخی اطلاعات باقی‌مانده به تصویر بازسازی شده جهت کاهش بیشتر نویز و کم اثر کردن INU است. در مرحله‌ی بعدی، به جای فرض توزیع کروی بودن داده‌ها، فرض توزیع بیضی برای اندازه‌گیری معیار تشابه استفاده شد. درواقع، به منظور بخش‌بندی دقیق نواحی فشرده و کم حجم مثل

- [38] J. Fortin et al., "Harmonization of cortical thickness measurements across scanners and sites," *Neuroimage*, vol. 167, pp. 104-120, 2018.
- [39] M. Jenkinson et al., "FSL," *Neuroimage*, vol. 62, no. 2, pp. 782–790, 2012.
- [40] R. R. Edelman et al., "Clinical magnetic resonance imaging", vol. 1, WB Saunders, 2006.
- [41] C. Westbrook et al., "MRI in Practice", 4th ed. Chichester, England: Wiley-Blackwell, 2011.
- [42] "https://brainweb.bic.mni.mcgill.ca/cgi/brainweb1"
- [43] Y. Xiao et al. "A dataset of multi-contrast population-averaged brain MRI atlases of a Parkinson' s disease cohort," *Data Brief*, vol. 12, pp. 370–379, 2017.
- [44] A. F. Jafargholkhanloo and M. Shamsi, "Quantitative analysis of facial soft tissue using weighted cascade regression model applicable for facial plastic surgery," *Signal Processing: Image Communication*, 121, 117086, 2024.
- [45] L. Tao et al, "Significantly fast and robust fuzzy c-means clustering algorithm based on morphological reconstruction and membership filtering," *IEEE Transactions on Fuzzy Systems*, vol. 26, no. 5, pp. 3027-3041, 2018.
- improved chimp optimization algorithm," *Expert Systems with Applications*, vol. 185, pp. 115651, 2021.
- [14] M. Guoyuan and X. Yue, "An improved whale optimization algorithm based on multilevel threshold image segmentation using the Otsu method," *Engineering Applications of Artificial Intelligence*, vol. 113, pp. 104960, 2022.
- [15] T. Lang, T. Sauer, "Feature-Adaptive Interactive Thresholding of Large 3D Volumes," *arXiv preprint arXiv:2210.06961*, 2022.
- [16] D. Bin et al, "An active contour model based on shadow image and reflection edge for image segmentation," *Expert Systems with Applications*, vol. 238, pp. 122330, 2024.
- [17] C. Yiyang et al., "An active contour model for image segmentation using morphology and nonlinear Poisson's equation," *Optik*, vol. 287, pp. 170997, 2023.
- [18] H. Zia et al., "Active Contour Model for Image Segmentation," *Asia Conference on Advanced Robotics, Automation, and Control Engineering (ARACE)*, pp. 13-17, 2022.
- [19] S. K. Adhikari et al., "Conditional spatial fuzzy C-means clustering algorithm for segmentation of MRI images," *Applied soft computing*, vol. 34, pp. 758-769, 2015.
- [20] A. Elazab et al., "Segmentation of brain tissues from magnetic resonance images using adaptively regularized kernel-based fuzzy C-means clustering," *Computational and mathematical methods in medicine*, vol. 2015, no. 1, pp. 485495, 2015.
- [21] M. A. Bakhshali, "Segmentation and enhancement of brain MR images using fuzzy clustering based on information theory," *Soft Computing*, vol. 21, pp. 6633-6640, 2017.
- [22] P. Moeskops et al., "Automatic segmentation of MR brain images with a convolutional neural network," *IEEE transactions on medical imaging*, vol. 35, no. 5, pp. 1252-1261, 2016.
- [23] P. Ghosh et al., "Chaotic firefly algorithm-based fuzzy C-means algorithm for segmentation of brain tissues in magnetic resonance images," *Journal of Visual Communication and Image Representation*, vol. 54, pp. 63-79, 2018.
- [24] H. Verma et al., "A population-based hybrid FCM-PSO algorithm for clustering analysis and segmentation of brain image," *Expert systems with applications*, vol. 167, pp. 114121, 2021.
- [25] S. Tongbram et al., "A novel image segmentation approach using fem and whale optimization algorithm," *Journal of ambient intelligence and humanized computing*, pp. 1-15, 2021.
- [26] F. Chighoub R. Saouli, "Fully integrated spatial information to improve FCM algorithm for brain MRI Image segmentation," *Automatic Control and Computer Sciences*, vol. 56, no. 1, pp. 67-82, 2022.
- [27] D. Kumar et al., "Kernel picture fuzzy clustering with spatial neighborhood information for MRI image segmentation," *Soft Computing*, vol. 26, no. 22, pp. 12717-12740, 2022.
- [28] A. Khaled et al., "Learning to detect boundary information for brain image segmentation," *BMC bioinformatics*, vol. 23, no. 1, pp. 332, 2022.
- [29] D. Kumar et al., "Bias-corrected intuitionistic fuzzy c-means with spatial neighborhood information approach for human brain MRI image segmentation," *IEEE Transactions on Fuzzy Systems*, vol. 30, no. 3, pp. 687-700, 2020.
- [30] V. Göreke, "A novel method based on Wiener filter for denoising Poisson noise from medical X-Ray images," *Biomedical Signal Processing and Control*, vol. 79, pp. 104031, 2023.
- [31] B. K. Kumar, "Image denoising based on non-local means filter and its method noise thresholding," *Signal, image and video processing*, vol. 7, pp. 1211-1227, 2013.
- [32] J. C. Bezdek et al., "FCM: The fuzzy c-means clustering algorithm," *Comput. Geosci*, vol. 10, no. 2-3, pp. 191-203, 1984.
- [33] K. Raghu and J. Kim, "A note on the Gustafson-Kessel and adaptive fuzzy clustering algorithms," *IEEE Transactions on Fuzzy systems*, vol. 7, no. 4, pp. 453-461, 1999.
- [34] D. Dejan and I. Škrjanc, "Recursive clustering based on a Gustafson–Kessel algorithm," *Evolving systems*, vol. 2, no. 1, pp. 15-24, 2011.
- [35] B. R. P. J. Veen and U. Kaymak, "Improved covariance estimation for Gustafson-Kessel clustering," *IEEE International Conference on Fuzzy Systems*, vol. 2, 2002.
- [36] M. Shah et al., "Evaluating intensity normalization on MRIs of human brain with multiple sclerosis," *Med. Image Anal*, vol. 15, no. 2, pp. 267–282, 2011.
- [37] R. T. Shinohara et al., "Statistical normalization techniques for magnetic resonance imaging," *NeuroImage Clin*, vol. 6, pp. 9–19, 2014.