Journal of Soft Computing and Information Technology (JSCIT)
Babol Noshirvani University of Technology, Babol, Iran
Journal Homepage: jscit.nit.ac.ir
Volume 13, Number 4, Winter 2025, pp. 49-64
Received: 10/21/2024, Revised: 03/03/2025, Accepted: 03/09/2025

Segmentation of Brain Tissues in MRI Images Using Improved Gustafson-Kessel Clustering Algorithm

Ali Fahmi Jafargholkhanloo[1*], Mousa Shamsi[2] and Mahdi Bashiri Bawil[3]
1*- Department of Engineering Sciences, Faculty of Advanced Technologies, University of Mohaghegh Ardabili, Namin, Iran.
2- Department of Bioelectric, Faculty of Biomedical Engineering, Sahand University of Technology, Tabriz, Iran.
3- Department of Bioelectric, Faculty of Biomedical Engineering, Sahand University of Technology, Tabriz, Iran.
[1]a_fahmi@uma.ac.ir, [2]shamsi@sut.ac.ir, and [3] m_bashiri99@sut.ac.ir

Corresponding author's address: Ali Fahmi Jafargholkhanloo, Faculty of Advanced Technologies, University of Mohaghegh Ardabili, Namin, Iran.

Abstract- Magnetic Resonance Imaging (MRI) often suffers from noise and intensity non-uniformity (INU), making image segmentation a challenging task. The fuzzy c-means (FCM) algorithm is a popular clustering-based method for image segmentation, but it is sensitive to noise, and its convergence rate is influenced by data distribution. Traditional FCM approaches use the Euclidean distance, which does not account for the variation in data point distances within similar and compact clusters. To address these limitations, a new cost function is proposed for the Gustafson-Kessel (GK) clustering algorithm that utilizes the Mahalanobis distance for similarity measurement. This approach enhances robustness to noise and INU conditions compared to other FCM-based methods. Additionally, information theory is incorporated to further improve noise robustness and segmentation accuracy. Conventional GK clustering is typically affected by the choice of fuzziness value; hence, a membership function entropy is introduced to mitigate this issue. In the proposed algorithm, morphological reconstruction is used as a pre-processing step to reduce noise while preserving object contours. Experimental results on various MRI datasets demonstrate that the proposed algorithm performs well in segmenting multiple tissues under different noise and INU conditions.

Keywords- MRI Brain Segmentation, Information Theory, Gustafson-Kessel Clustering, White Matter, Grey Matter, Cerebrospinal Fluid.

مجله علمی رایانش نرم و فناوری اطلاعات
دانشگاه صنعتی نوشیروانی بابل
صفحه مجله: jscit.nit.ac.ir
جلد ۱۳، شماره ۴، زمستان ۱۴۰۳ ، صفحه ۴۹-۶۴
دریافت: ۱۴۰۳/۰۷/۳۰، بازنگری: ۱۴۰۳/۱۲/۱۳، پذیرش: ۱۴۰۳/۱۲/۱۹

بخش‌بندی بافت‌های مغزی از روی تصاویر MRI با استفاده از مدل بهبودیافته‌ی الگوریتم خوشه‌بند گستافسون-کسل

علی فهمی جعفرقلخانلو*[۱]، موسی شمسی[۲]، مهدی بشیری باویل[۳]
۱- گروه علوم مهندسی، دانشکده فناوری‌های نوین، دانشگاه محقق اردبیلی، نمین، ایران.
۲- گروه بیوالکتریک، دانشکده مهندسی پزشکی، دانشگاه صنعتی سهند، تبریز، ایران.
۳- گروه بیوالکتریک، دانشکده مهندسی پزشکی، دانشگاه صنعتی سهند، تبریز، ایران.
[1]a_fahmi@uma.ac.ir, [2]shamsi@sut.ac.ir, [3] m_bashiri99@sut.ac.ir

* نشانی نویسنده مسئول: علی فهمی جعفرقلخانلو، نمین، دانشگاه محقق اردبیلی، دانشکده فناوری‌های نوین، گروه علوم مهندسی.

چکیده- بخش‌بندی تصاویر MRI تحت تغییرات غیریکنواختی شدت و نویز یک مسئله‌ی چالش‌برانگیز است. الگوریتم فازی C-میانگین یکی از محبوب‌ترین الگوریتم‌های خوشه‌بندی بوده که نسبت به نویز حساس بوده و آهنگ همگرایی آن تحت تاثیر توزیع داده قرار دارد. این الگوریتم با به‌کارگیری فاصله‌ی اقلیدسی، تغییرات فاصله‌ی نقاط داده در خوشه‌های فشرده و مشابه را نادیده می‌گیرد. برای حل این چالش‌ها، تابع هدف جدیدی براساس اندازه‌گیری معیار تشابه از طریق فاصله‌ی ماهالانوبیس در خوشه‌بندی گستافسون-کسل ارائه می‌شود که نسبت به رویکردهای مبتنی بر فازی C-میانگین مقاوم به نویز و غیریکنواختی شدت است. همچنین، به‌منظور افزایش استحکام الگوریتم پیشنهادی به نویز و افزایش دقت بخش‌بندی بافت‌های مغزی، تئوری اطلاعات به‌کار گرفته می‌شود. الگوریتم گستافسون-کسل استاندارد معمولاً تحت تاثیر مقدار فازی‌شدگی قرار می‌گیرد. برای حل این مسئله، عبارت آنتروپی تابع عضویت به‌کار گرفته می‌شود. در الگوریتم پیشنهادی، جهت حل چالش‌های مربوط به نویز و حفظ بهتر جزئیات تصویر، رویکرد بازسازی مورفولوژیکی به‌عنوان یک مرحله‌ی پیش‌پردازش به‌کار گرفته می‌شود. نتایج نشان داد که روش پیشنهادی در مقایسه با روش‌های بخش‌بندی فازی قبلی یک الگوریتم دقیق برای بخش‌بندی بافت‌های چندگانه‌ی مغزی در سطوح مختلف نویز و غیریکنواختی شدت است.

واژه‌های کلیدی: بخش‌بندی ام‌آرآی مغز، تئوری اطلاعات، خوشه‌بندی گستافسون-کسل، ماده‌ی خاکستری، ماده‌ی سفید، مایع مغزی نخاعی.

۱- مقدمه

امروزه انواع مختلف روش‌های تصویرنگاری پزشکی شامل تصویربرداری مبتنی بر پرتو ایکس[۱]، برش‌نگاری با گسیل پوزیترون[۲] (PET)، برش‌نگاری محاسباتی[۳] (CT) و تصویربرداری تشدید مغناطیسی[۴] (MRI) در آنالیز تصویربرداری پزشکی به‌کار گرفته می‌شوند [۱]. مغز انسان از انواع مختلف بافت نرم شامل ماده‌ی سفید[۵] (WM)، ماده‌ی خاکستری[۶] (GM) و مایع مغزی نخاعی[۷] (CSF) تشکیل شده، به‌طوری که MRI ابزار مناسبی جهت ارزیابی بافت‌های مغزی است [۲]. کیفیت تصاویر MRI انسان کاملاً وابسته به سطح خاکستری بافت‌های ذکر شده است [۳]. جهت تشخیص دقیق انواع بیماری‌ها، وزن‌های مختلف تصاویر MRI از طریق اخذ ویژگی‌های خاص که انعکاس کننده‌ی کنتراست بافت نرم هستند، به‌کار گرفته می‌شوند. این وزن‌ها شامل T_1، T_2 و بازیابی معکوس مایع تضعیف شده[۸] (FLAIR) هستند. وزن T_1 جهت نمایش بافت‌های سالم با شدت روشنایی بالا و آسیب‌شناسی[۹] با شدت روشنایی پایین به‌کار گرفته می‌شود.

تصاویر مبتنی بر وزن T_2 آسیب‌شناسی با شدت روشنایی بالا را مشخص می‌کنند. وزن FLAIR جهت تشخیص ناحیه‌ی دارای ورم[۱۰] به‌کار گرفته می‌شود [۶-۴].

فرآیند بخش‌بندی یکی از چالش‌برانگیزترین مسائل در ارزیابی تصاویر پزشکی و شناسایی انواع بیماری‌ها است [۷]. تصاویر MRI معمولاً از انواع مختلف نویز، غیریکنواختی شدت [۱۱] (INU) و اثر جزئی حجم[۱۲] رنج می‌برند. این مسائل باعث می‌شوند که بخش‌بندی دستی مسئله‌ای چالش‌برانگیز باشد. بخش‌بندی دستی زمان‌بر بوده و می‌تواند به‌دلیل تغییرات درون-ناظر و بین-ناظر[۱۳]، یافته‌های متناقضی ایجاد کند [۹، ۸]. بنابراین، علوم رادیولوژی نیازمند رویکردی دقیق و خودکار جهت بخش‌بندی بافت‌های مغزی است. رویکردهای مختلفی نظیر روش‌های مبتنی بر آستانه‌گذاری، خوشه‌بندی، کانتور فعال و یادگیری عمیق جهت بخش‌بندی تصاویر پزشکی ارائه شده‌اند. روش‌های مبتنی بر آستانه‌گذاری [۱۲، ۱۱] فرآیند بخش‌بندی را از طریق محاسبه‌ی آستانه‌ی تک‌گانه و یا چندگانه انجام می‌دهند. این رویکردها عمل‌کرد مناسبی در حضور انواع اعوجاج، نویز و نوسانات مقدار سطح خاکستری ندارند [۱۳]. بخش‌بندی تصویر در روش‌های مبتنی بر کانتور [۱۵، ۱۴] از طریق بازسازی یک تابع انرژی انجام می‌شود. این رویکردها نیازمند کانتور اولیه و تنظیم پارامترهای زیاد بوده و معمولاً عمل‌کرد مناسبی در حضور انوع مختلف INU ندارند [۱۶]. از معایب اصلی رویکردهای مبتنی بر یادیگیری عمیق می‌توان به سرعت آموزش پایین، وابستگی به میزان داده و ساختار پیچیده‌ی آن‌ها اشاره کرد [۱۰]. یکی از محبوب‌ترین رویکردهای بخش‌بندی تصویر خوشه‌بندی بوده که یک مجموعه را به تعدادی خوشه با میزان تشابه بیشتر درون اعضا و تشابه کم‌تر با اعضای سایر خوشه‌ها جدا می‌کند. برای حل چالش‌های ذکر شده، تمرکز اصلی ما در این مطالعه بر روی روش‌های ارائه شده براساس خوشه‌بندی خواهد بود.

Li و همکاران [۱۷] رویکرد کمینه‌سازی انرژی مبتنی بر بهینه‌سازی مولفه‌ی درونی ضربی[۱۴] (MICO) را جهت تخمین غیریکنواختی شدت و بخش‌بندی بافت‌های مغزی طراحی کردند. در این روش، تصویر به دو مولفه ضرب شونده شامل تصویر واقعی (توصیف کننده ویژگی فیزیکی بافت تصویر) و مولفه غیریکنواختی شدت تجزیه می‌شود. MICO یک رویکرد مبتنی بر تنظیم سطح بوده که از توابع پایه‌ای متعامد جهت تخمین غیریکنواختی شدت استفاده کرده که در آن شرط توقف الگوریتم وابسته به اطلاعات گرادیان تصویر است. این فرآیند باعث می‌شود که تنها لبه‌های تعریف شده از طریق گرادیان بخش‌بندی شوند. این الگوریتم نسبت به مقداردهی اولیه و نویز ناشی از عدم وجود اطلاعات محلی حساس است [۱۸]. الگوریتم فازی C-میانگین[۱۵] (FCM) یکی از محبوب‌ترین روش‌های خوشه‌بندی نرم برای بخش‌بندی تصویر است. این الگوریتم برای بخش‌بندی تصاویر MRI به‌دلیل عدم درنظر گرفتن اطلاعات بین پیکسل‌های همسایه مناسب نیست. برای حل این چالش، Adhikari و همکاران [۱۹] رویکرد مبتنی بر FCM مکانی شرطی[۱۶] (CSFCM) را ارائه کردند. عیب اصلی الگوریتم CSFCM این هست که درجه‌ی عدم قطعیت احتمالی در تصاویر واقعی MRI را درنظر نمی‌گیرد. Elazab و همکاران [۲۰] الگوریتم FCM مبتنی بر هسته‌ی تنظیم شده به‌صورت وفقی[۱۷] (ARKFCM) را ارائه کردند. در این الگوریتم، کنترل و تنظیم تعادل بین خوشه‌بندی نرم و سخت مشکل است. همچنین، ARKFCM با مسئله‌ی بیش صاف‌شدگی در لبه‌ها و جزئیات تصویر مواجه است. رویکردهای مبتنی بر کرنل نظیر ARKFCM معمولاً برای داده‌های غیرکروی مناسب نبوده و پیچیدگی محاسباتی بالایی دارند. Qiao و همکاران [۲۲] پایگاه داده‌ی جدید MRI جهت بخش‌بندی ضایعه‌ی سکته‌ی ایسکمیک[۱۸] را معرفی کردند. فرآیند بخش‌بندی با استفاده از مدل مخلوط گوسین[۱۹] (GMM) و خوشه‌بند K-میانگین انجام گرفت. در تصاویر MRI، مسئله‌ی INU به‌دلیل غیریکنواختی در میدان مغناطیسی اتفاق می‌افتد که منجر به ایجاد مولفه ناخواسته‌ی فرکانس پایین تحت عنوان بایاس یا غیریکنواختی شدت می‌شود. Parakash و Kumari [۲۳] رویکرد FCM مکانی بیشنه‌سازی امید ریاضی همراه با اصلاح غیریکنواختی شدت[۲۰] (SFCMEMBC) را جهت حل چالش‌های اصلی در بخش‌بندی تصاویر MRI شامل نویز و INU ارائه کردند. این الگوریتم عمل‌کرد مناسبی در شرایط سطح پایین نویز و INU ندارد. سرعت همگرایی پایین و حساسیت به مقداردهی اولیه، از معایب اصلی الگوریتم GMM هستند. همچنین، در این رویکرد، توزیع داده به‌صورت گوسین فرض می‌شود، که ممکن است برای بعضی از داده‌ها مناسب نباشد.

به‌کارگیری الگوریتم‌های فراابتکاری یکی از محبوب‌ترین رویکردها در ارزیابی تصاویر پزشکی است. Singh و همکاران [۲۴] بهینه‌سازی ازدحام ذرات چندهدفه[۲۱] (MOPSO) را جهت کاهش نویز و بخش‌بندی تصاویر MRI ارائه کردند. Gosh و همکاران [۲۵] الگوریتم کرم شب‌تاب آشوبناک[۲۲] (CFA) را جهت حل چالش مربوط به حساسیت الگوریتم FCM به مقداردهی اولیه معرفی کردند. حساسیت به تعداد نگاشت‌های آشوبناک عیب اصلی الگوریتم CFA است. در الگوریتم FCM، چالش بهینه‌سازی مکانی و تحت تاثیر قرار گرفتن سرعت همگرایی از طریق مقادیر اولیه

وجود دارد. الگوریتم FCM از دو طریق می‌تواند به‌عنوان یک مسئله‌ی بهینه‌سازی مطرح شود. (۱) درنظر گرفتن ماتریس عضویت به‌عنوان جمعیت اولیه برای هر عامل جستجو یک مسئله‌ی بهینه‌سازی گسسته است. (۲) درنظر گرفتن مراکز خوشه به‌عنوان جمعیت اولیه برای هر عامل جستجو یک مسئله‌ی بهینه‌سازی پیوسته است [۲۶]. Verma و همکاران [۲۷] الگوریتم FCM را به‌عنوان یک مسئله‌ی بهینه‌سازی پیوسته با استفاده از الگوریتم PSO (FCMPSO) جهت بخش‌بندی تصاویر MRI درنظر گرفتند. همچنین، Tongbram و همکاران [۲۸] الگوریتم بهینه‌سازی نهنگ[۲۳] را جهت بهینه‌سازی الگوریتم FCM (FCMWOA) در فضای پیوسته به‌کار بردند. Fahmi و Shamsi [۲۶] الگوریتم FCM را به‌عنوان یک مسئله‌ی بهینه‌سازی در فضای گسسته با استفاده از بهینه‌ساز گرگ خاکستری[۲۴] (FCMGWO) معرفی کردند. نتایج آزمایش نشان دادند که بهینه‌سازی در فضای گسسته عمل‌کرد بهتری نسبت به بهینه‌سازی در فضای پیوسته جهت بخش‌بندی تصویر دارد. عیب اصلی الگوریتم‌های فراابتکاری این است که زمان‌بر بوده و رویکردهای مبتنی بر جمعیت این الگوریتم‌ها نظیر PSO و FA نیازمند تنظیم دقیق پارامترهای ثابت جهت تعدیل فازهای اکتشاف و استخراج هستند. روش‌های آستانه‌گذاری کلاسیک مانند اتسو و آنتروپی کاپور برای تصاویر با تعداد آستانه‌های زیاد مناسب نیستند. Bandyopadhyay و همکاران [۲۹] بهینه‌سازی شاهین هریس هم‌دوستانه[۲۵] (AHHO) را جهت بخش‌بندی تصاویر MRI ارائه کردند. عیب اصلی الگوریتم AHHO این است که زمان زیادی را جهت انجام فرآیند بخش‌بندی صرف می‌کند. رویکردهای مبتنی بر آستانه‌گذاری نظیر AHHO مناسب برای تصاویر با دره‌های صاف نبوده و معمولاً از اطلاعات مکانی صرف‌نظر می‌کنند.

Kouhi و همکاران [۳۰] الگوریتم مقاوم FCM براساس ترکیب اطلاعات مکانی و ماتریس عضویت را جهت بخش‌بندی تصاویر MRI ارائه کردند. در این روش، تابع عضویت دو بار در هر تکرار از طریق اطلاعات مکانی محاسبه می‌شود. درنتیجه، پیچیدگی محاسباتی چالش اصلی این الگوریتم است. Tavakoli و همکاران [۳۱] رویکرد جدید FCM با استفاده از تخمین دوگانه از طریق مشارکت تصویر اصلی و اصلاح شده را جهت بخش‌بندی بافت‌های چندگانه‌ی مغزی ارائه کردند. Kumar و همکاران [۳۲] رویکرد مبتنی بر تصویر کرنل FCM با اطلاعات مکانی همسایگی را جهت کنترل نویز در فرآیند بخش‌بندی تصاویر MRI مطرح کردند. رویکردهای مبتنی بر تصویر معمولاً استحکام کافی در برابر نویز و داده‌های پرت را ندارند. Vinurajkumar و Anandhavelu [۳۳] الگوریتم بهبودیافته‌ی FCM از طریق اطلاعات هیستوگرام ماتریس عضویت را جهت بخش‌بندی WM از روی تصاویر MRI مبتنی بر وزن T_1 ارائه کردند. محدودیت اصلی این الگوریتم، وجود ناپیوستگی در نواحی WM و حساسیت به مقداردهی اولیه‌ی ماتریس عضویت است. فرآیند بخش‌بندی بافت‌های مغزی در حضور شرایطی نظیر نویز، اثر جزئی حجم و غیریکنواختی شدت موضوعی چالش‌برانگیز است. Kumar و همکاران [۳۴] روش FCM شهودی اصلاح شده‌ی غیریکنواختی شدت با اطلاعات همسایگی مکانی[۲۶] (BCIFCMSNI) را جهت حل مسائل ذکر شده ارائه کردند. Solanki و Kumar [۳۵] الگوریتم FCM شهودی احتمالی مبتنی بر محدودیت مکانی[۲۷] (PIFCMS) را جهت بخش‌بندی تصاویر MRI معرفی کردند. عیب اصلی الگوریتم‌های BCIFCMSNI و PIFCMS این است که دقت فرآیند بخش‌بندی تحت تاثیر پارامترهای تنظیم قرار می‌گیرد. Kumar و همکاران [۳۶] خوشه‌بندی فازی مرزی K-صفحه مبتنی بر اطلاعات مکانی[۲۸] (FBKPCS) را جهت بخش‌بندی تصاویر MRI معرفی کردند. عیب اصلی الگوریتم FBKPCS این است که نیازمند تنظیم پارامترهای مرز و مکانی هست. Mohammadi و همکاران [۳۷] رویکرد آب‌پخشان اصلاح شده و الگوریتم FCM را جهت بخش‌بندی مننژیوم[۲۹] براساس تصاویر MRI مبتنی بر وزن T_1 ارائه کردند.

در این مطالعه، جهت حل مسائل ذکر شده براساس مطالعات انجام شده، الگوریتم جدید خوشه‌بندی گستافسون-کسل بهبودیافته[۳۰] (IGK) جهت بخش‌بندی بافت‌های چندگانه‌ی مغزی با استفاده از تصاویر MRI مبتنی بر وزن T_1 ارائه می‌شود. الگوریتم پیشنهادی قادر به بخش‌بندی انواع تصاویر MRI با دقت بالا در برش‌های مختلف است. نوآوری اصلی این مطالعه می‌تواند به‌صورت زیر خلاصه شود:

- شکل هندسی داده در رویکردهای مبتنی بر FCM به‌صورت کروی درنظر گرفته شده که به‌صورت مکانی با تغییرات شکل خوشه تطبیق ندارند. این فرآیند باعث می‌شود که بخش‌بندی ناحیه CSF که از یک خوشه‌ی کوچک و فشرده تشکیل شده با مشکل مواجه شود. برای حل این چالش، به جای استفاده از فاصله اقلیدسی در رویکردهای مبتنی بر FCM از فاصله ماهالانوبیس جهت تخمین ماتریس کواریانس به‌منظور تطبیق الگوریتم پیشنهادی با تغییرات شکل خوشه استفاده می‌شود.
- بخش‌بندی بافت‌های مغزی در تصاویر MRI با وجود نویز و INU سخت است. برای حل این چالش، تئوری اطلاعات[۳۱]

به‌کار گرفته شد که باعث مقاوم شدن الگوریتم پیشنهادی در برابر نویز و تغییرات غیریکنواختی شدت می‌شود.

- رویکردهای مبتنی بر FCM و الگوریتم GK استاندارد نسبت به مقدار فازی شدگی (مقدار q) حساس هستند. برای حل این چالش، رویکرد مبتنی بر آنتروپی تابع عضویت به‌کار گرفته می‌شود.
- در الگوریتم پیشنهادی، جهت حل چالش‌های مربوط به نویز و حفظ بهتر جزئیات لبه تصویر، رویکرد بازسازی مورفولوژیکی[۳۲] (MR) به‌عنوان یک مرحله‌ی پیش‌پردازش به‌کار گرفته می‌شود.
- جهت ارزیابی الگوریتم IGK پیشنهادی، تصاویر MRI ۱۰ بیمار مراجعه کننده به مرکز تصویربرداری پزشکی گل‌گشت تبریز[۳۳] (GMICT) در مقطع‌های مختلف و ۴۱ تصویر MRI مغز از مجموعه داده‌های Brainweb با شرایط مختلف نویز و غیریکنواختی شدت به‌کار گرفته می‌شوند. نتایج آزمایش نشان می‌دهند که الگوریتم پیشنهادی عمل‌کرد خوبی در مقایسه با سایر روش‌های مقایسه شده برای بخش‌بندی بافت‌های مغزی دارد.

ساختار کلی مقاله به این صورت سازمان‌دهی می‌شود که در بخش ۲ کارهای مربوط به خوشه‌بندی FCM توصیف داده می‌شود. در بخش ۳ به ارائه‌ی الگوریتم پیشنهادی خواهیم پرداخت. بخش ۴ نتایج الگوریتم پیشنهادی و مقایسه‌ی عمل‌کرد آن با سایر الگوریتم‌ها را ارائه می‌دهد. سرانجام، در بخش ۵ به نتیجه‌گیری و ارائه‌ی پیشنهادها خواهیم پرداخت.

۲- مروری مختصر بر الگوریتم‌های FCM و GK

الگوریتم خوشه‌بندی FCM برای اولین بار توسط Bezdek [۳۸] جهت بهبود عمل‌کرد خوشه‌بند K-میانگین براساس رویکرد به‌کارگیری ماتریس عضویت μ_{ij} ارائه شد. برای یک تصویر داده شده‌ی $I(x,y)$ 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 jامین خوشه $(j=1, 2, \dots, c)$ وجود دارد. تابع هزینه در الگوریتم FCM با میزان فازی شدگی q $(q>1)$ براساس رابطه‌ی (۱) به‌صورت زیر تعریف می‌شود:

$$J_{FCM} = \sum_{i=1}^{N}\sum_{j=1}^{c} u_{ij}{}^{q}\left(x_i - v_j\right)^2 \qquad (۱)$$

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

$$u_{ij}{}^{t+1} = \frac{1}{\sum_{j=1}^{c}\left(\frac{\|x_i - v_k{}^{t}\|^2}{\|x_i - v_j{}^{t}\|^2}\right)^{\frac{2}{q-1}}} \qquad (۲)$$

$$v_j{}^{t+1} = \frac{\sum_{i=1}^{N}\left(\left(u_{ij}{}^{q}\right)^{t} x_i\right)}{\sum_{i=1}^{N}\left(u_{ij}{}^{q}\right)^{t}} \qquad (۳)$$

در الگوریتم FCM، خوشه‌ها به‌صورت کروی فرض می‌شوند. بنابراین، عمل‌کرد این الگوریتم زمانی مناسب خواهد بود که خوشه‌ها در داده تقریباً دارای ریخت و اندازه‌ی یکسانی باشند، اما الگوریتم GK برای تشخیص خوشه‌های ابر بیضوی شکل با اندازه و جهت‌گیری‌های متفاوت مناسب است [۴۰، ۳۹]. ویژگی اصلی الگوریتم GK تطبیق مکانی معیار فاصله با ریخت خوشه از طریق تخمین ماتریس کواریانس است [۴۱]. گستافسون و کسل [۴۲] یک مدل توسعه یافته از الگوریتم FCM را جهت شناسایی شکل‌های هندسی مختلف از طریق فاصله‌ی ماهالانوبیس به‌جای فاصله‌ی اقلیدسی پیشنهاد کردند. تابع هزینه‌ی این الگوریتم به‌صورت زیر بیان می‌شود:

$$J_{GK} = \sum_{i=1}^{N}\sum_{j=1}^{c} u_{ij}{}^{q}.\left(x_i - v_j\right)^{T}.A_j.\left(x_i - v_j\right) \qquad (۴)$$

که در آن A_j یک ماتریس مثبت متقارن است. با به‌کارگیری روش حاصل‌ضرب لاگرانژ، رابطه‌ی (۴) را می‌توان به یک مسئله بهینه‌سازی نامحدود تبدیل کرد که تابع هزینه زیر را کمینه می‌کند:

$$\begin{aligned} J_{GK} = \sum_{i=1}^{N}\sum_{j=1}^{c} u_{ij}{}^{q}.\left(x_i - v_j\right)^{T}.A_j.\left(x_i - v_j\right) \\ - \sum_{i=1}^{N}\lambda_i\left(\sum_{j=1}^{c} u_{ij} - 1\right) \\ + \sum_{j=1}^{c}\beta_j.\left(det\left(A_j\right) - \rho_j\right) \end{aligned} \qquad (۵)$$

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 درنظر گرفته می‌شود. ماتریس عضویت، مراکز خوشه و ماتریس کواریانس در یک فرآیند تکراری از طریق روابط زیر به‌روزرسانی می‌شوند:

$$u_{ij}{}^{t+1} = \left(\frac{(x_i - v_r{}^{t})^{T}.A_r{}^{t}.(x_i - v_r{}^{t})}{\sum_{j=1}^{c}\left(x_i - v_j{}^{t}\right)^{T}.A_j{}^{t}.\left(x_i - v_j{}^{t}\right)}\right)^{1/q-1} \qquad (۶)$$

$$v_j^{t+1} = \frac{\sum_{i=1}^{N} (u_{ij}^{q})^{t} . x_i}{\sum_{i=1}^{N} (u_{ij}^{q})^{t}} \quad (۷)$$

$$F_i^{t+1} = \frac{\sum_{i=1}^{N} (u_{ij}^{q})^{t} . (x_i - v_j^{t})^{T} . (x_i - v_j^{t})}{\sum_{i=1}^{N} (u_{ij}^{q})^{t}} \quad (۸)$$

$$A_j^{t+1} = \lambda_i . \left(det(F_i^{t})\right)^{\frac{1}{n}} . (F_i^{-1})^{t} \quad (۹)$$

تابع هزینه‌ی ارائه شده برای الگوریتم GK در رابطه‌ی (۵) به مقدار q وابسته است. جهت اجتناب از این اثر تابع هزینه زیر معرفی می‌شود:

$$J_{GK'} = \sum_{i=1}^{N}\sum_{j=1}^{c} u_{ij} . (x_i - v_j)^{T} . A_j . (x_i - v_j) + \frac{1}{\alpha}\sum_{i=1}^{N}\sum_{j=1}^{c} u_{ij} . \ln(u_{ij}) \quad (۱۰)$$

که در آن پارامتر α کنترل کننده‌ی انتقال از خوشه‌بندی نرم به خوشه‌بندی سخت در طول فرآیند خوشه‌بندی است. با به‌کارگیری روش حاصل‌ضرب لاگرانژ، رابطه‌ی (۱۰) را می‌توان به یک مسئله بهینه‌سازی نامحدود تبدیل کرد که تابع هزینه زیر را کمینه می‌کند:

$$J_{GK'} = \sum_{i=1}^{N}\sum_{j=1}^{c} u_{ij} . (x_i - v_j)^{T} . A_j . (x_i - v_j) + \frac{1}{\alpha}\sum_{i=1}^{N}\sum_{j=1}^{c} u_{ij} . ln(u_{ij}) - \sum_{i=1}^{N} \lambda_i \left(\sum_{j=1}^{c} u_{ij} - 1\right) + \sum_{j=1}^{c} \beta_j . (det(A_j) - \rho_j) \quad (۱۱)$$

با گرفتن مشتق از رابطه‌ی (۱۱) نسبت به ماتریس عضویت، مراکز خوشه، ماتریس کواریانس و مساوی صفر قرار دادن رابطه‌های به‌دست آمده، توابع ذکر شده در یک فرآیند تکراری به‌صورت زیر به‌روزرسانی خواهند شد:

$$u_{ij}^{t+1} = \frac{e^{-\alpha (x_i - v_r^{t})^{T} . A_r^{t} . (x_i - v_r^{t})}}{\sum_{j=1}^{c} e^{-\alpha (x_i - v_j^{t})^{T} . A_j^{t} . (x_i - v_j^{t})}} \quad (۱۲)$$

$$v_j^{t+1} = \frac{\sum_{i=1}^{N} (u_{ij}^{q})^{t} . x_i}{\sum_{i=1}^{N} (u_{ij}^{q})^{t}} \quad (۱۳)$$

$$F_i^{t+1} = \frac{\sum_{i=1}^{N} (u_{ij}^{q})^{t} . (x_i - v_j^{t})^{T} . (x_i - v_j^{t})}{\sum_{i=1}^{N} (u_{ij}^{q})^{t}} \quad (۱۴)$$

$$A_j^{t+1} = \lambda_i . \left(det(F_i^{t})\right)^{\frac{1}{n}} . (F_i^{-1})^{t} \quad (۱۵)$$

۳- الگوریتم پیشنهادی

تابع هزینه‌ی الگوریتم IGK پیشنهادی برای بخش‌بندی تصاویر MRI به‌صورت زیر است:

$$J_{IGK} = \sum_{i=1}^{N}\sum_{j=1}^{c} \xi_i . u_{ij} . (x_i - v_j)^{T} . A_j . (x_i - v_j) + \frac{1}{\alpha}\sum_{i=1}^{N}\sum_{j=1}^{c} u_{ij} . \ln(u_{ij}) \quad (۱۶)$$

که در آن ξ_i ضریب وزنی اضافی بوده که نمونه‌های نویز را حذف می‌کند. این ضریب احتمال پیکسل‌های تصویر بوده و از طریق بیشینه‌سازی اطلاعات متقابل بین مقدار پیکسل‌ها و مراکز خوشه در فرآیند تکراری محاسبه می‌شود. با استفاده از روش حاصل‌ضرب لاگرانژ، رابطه‌ی (۱۶) را می‌توان به یک مسئله بهینه‌سازی نامحدود تبدیل کرد که تابع هزینه زیر را کمینه می‌کند:

$$J_{IGK} = \sum_{i=1}^{N}\sum_{j=1}^{c} \xi_i . u_{ij} . (x_i - v_j)^{T} . A_j . (x_i - v_j) + \frac{1}{\alpha}\sum_{i=1}^{N}\sum_{j=1}^{c} u_{ij} . \ln(u_{ij}) - \sum_{i=1}^{N} \lambda_i \left(\sum_{j=1}^{c} u_{ij} - 1\right) + \sum_{j=1}^{c} \beta_j . (det(A_j) - \rho_j) \quad (۱۷)$$

با صفر قرار دادن مشتق J_{IGK} نسبت به ماتریس عضویت خواهیم داشت:

$$\frac{\partial J_{IGK}}{\partial u_{ij}} = \xi_i . (x_i - v_j)^{T} . A_j . (x_i - v_j) + \frac{1}{\alpha}(1 + \ln(u_{ij})) - \lambda i = 0 \quad (۱۸)$$

از طرف دیگر می‌دانیم که:

$$j=1 cuij=1 \rightarrow j=1 ce-1 . e-\alpha\lambda i . e-\alpha . \xi i . xi-vjT . Aj . xi-vj=1 \quad (۱۹)$$

با ترکیب روابط (۱۸) و (۱۹)، ماتریس عضویت الگوریتم پیشنهادی در یک فرآیند تکراری به‌صورت زیر به‌روزرسانی خواهد

شد:

$$u_{ij}{}^{t+1} = \frac{e^{-\alpha.\xi_i.(x_i - v_r{}^t)^T.A_r{}^t.(x_i - v_r{}^t)}}{\sum_{j=1}^{c} e^{-\alpha.\xi_i.(x_i - v_j{}^t)^T.A_j{}^t.(x_i - v_j{}^t)}} \quad (۲۰)$$

جهت به‌دست آوردن مراکز خوشه، از J_{GK} نسبت به v_j مشتق گرفته و برابر صفر قرار داده می‌شود. با حل معادله (۲۱)، رابطه‌ی (۲۲) به‌منظور به‌روزرسانی مراکز خوشه به‌کار گرفته می‌شود:

$$\frac{\partial J_{IGK}}{\partial v_j} = -2\sum_{i=1}^{N} \xi_i.u_{ij}.(x_i - v_j).A_j = 0 \quad (۲۱)$$

$$v_j{}^{t+1} = \frac{\sum_{i=1}^{N} \xi_i.(u_{ij})^t.x_i}{\sum_{i=1}^{N} \xi_i.(u_{ij})^t} \quad (۲۲)$$

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

$$\begin{aligned}\frac{\partial J_{GK}}{\partial A_j} &= \sum_{i=1}^{N} \xi_i.u_{ij}.(x_i - v_j)^T.(x_i - v_j) \\ &\quad - \sum_{i=1}^{N}\left(\lambda_i.\frac{\partial}{\partial A_j}\left(det(A_j)\right)\right) \\ &= \sum_{i=1}^{N} \xi_i.u_{ij}.(x_i - v_j)^T.(x_i \\ &\quad - v_j) - \sum_{i=1}^{N}(\lambda_i.u_{ij}.A_j{}^{-1}) = 0\end{aligned} \quad (۲۳)$$

با حل رابطه‌ی (۲۳)، جواب متناظر برای ماتریس کواریانس به‌صورت زیر به‌روزرسانی می‌شود:

$$F_i{}^{t+1} = \frac{\sum_{i=1}^{N} \xi_i(u_{ij})^t.(x_i - v_j{}^t)^T.(x_i - v_j{}^t)}{\sum_{i=1}^{N}(u_{ij})^t} \quad (۲۴)$$

$$A_j{}^{t+1} = \lambda_i.\left(det(F_i{}^t)\right)^{\frac{1}{n}}.(F_i{}^{-1})^t \quad (۲۵)$$

در مرحله‌ی نهایی، اطلاعات متقابل بین توزیع ماتریس عضویت (U) و داده‌ی ورودی (X) جهت تخمین ξ_i به‌کار گرفته می‌شود. اطلاعات متقابل براساس تئوری اطلاعات می‌تواند به‌صورت زیر بیان شود [۴۳]:

$$\begin{aligned}F(X,U) &= F\left(\mathcal{E}(X), \mathcal{E}(X|U)\right) \\ &= \sum_{i=1}^{N}\sum_{j=1}^{c} \varepsilon_i\, \varepsilon_{j|i} \log\left(\frac{\varepsilon_{j|i}}{\sum_{i=1}^{N} \varepsilon_i \varepsilon_{j|i}}\right)\end{aligned} \quad (۲۶)$$

که در آن ε_i احتمال iامین پیکسل بوده و معادل با ξ_i است. همچنین، $\varepsilon_{j|i}$ معادل با u_{ij} است. درنتیجه، رابطه‌ی (۲۶) می‌تواند به‌صورت زیر اصلاح شود:

$$F(X,U) = \sum_{i=1}^{N}\sum_{j=1}^{c} \xi_i.u_{ij}.\log\left(\frac{u_{ij}}{\sum_{i=1}^{N} \xi_i.u_{ij}}\right) \quad (۲۷)$$

با به‌کارگیری روش حاصل‌ضرب لاگرانژ و درنظر گرفتن شرط $\sum_{i=1}^{N} \xi_i = 1$، رابطه‌ی (۲۷) می‌تواند به یک مسئله‌ی بهینه‌سازی نامحدود تبدیل شده که تابع هزینه‌ی زیر را کمینه می‌کند:

$$\begin{aligned}J = &\sum_{i=1}^{N}\sum_{j=1}^{c} \xi_i.u_{ij}.log\left(\frac{u_{ij}}{\sum_{i=1}^{N} \xi_i.u_{ij}}\right) \\ &+ \lambda\left(\sum_{i=1}^{N} \xi_i - 1\right)\end{aligned} \quad (۲۸)$$

جهت به‌دست آوردن ξ_i، معادله‌ی دیفرانسیل جزئی J نسبت به ξ_i محاسبه شده و برابر صفر قرار داده می‌شود:

$$-log(\xi_i) - 1 + \sum_{j=1}^{c} u_{ij}.log\,(u_{ij}) + \lambda = 0 \quad (۲۹)$$

سرانجام، براساس رابطه‌ی (۲۹) و شرط محدودکننده، ξ_i در یک فرآیند تکراری می‌تواند از طریق رابطه‌ی (۳۰) به‌روزرسانی شود:

$$\xi_i{}^{t+1} = \frac{exp\left(\sum_{j=1}^{c} u_{ij}{}^t.log\left(\frac{u_{ij}{}^t}{\sum_{i=1}^{N} \xi_i.u_{ij}{}^t}\right)\right)}{\sum_{i=1}^{N} exp\left(\sum_{j=1}^{c} u_{ij}{}^t.log\left(\frac{u_{ij}{}^t}{\sum_{i=1}^{N} \xi_i.u_{ij}{}^t}\right)\right)} \quad (۳۰)$$

با به‌کارگیری رابطه‌ی (۳۰)، الگوریتم IGK پیشنهادی نسبت به نویز مقاوم می‌شود. این فرآیند تا زمان برقراری شرط زیر اجرا می‌شود:

$$\begin{cases}\xi_i{}^{t+1} = \dfrac{f_i{}^t}{\sum_{i=1}^{N} f_i{}^t} \\ f_i{}^t = exp\left(\sum_{j=1}^{c} u_{ij}{}^t.log\left(\dfrac{u_{ij}{}^t}{\sum_{i=1}^{N} \xi_i{}^t.u_{ij}{}^t}\right)\right) \\ ln\left(\sum_{i=1}^{N} \xi_i{}^{t+1}.f_i{}^t\right) - ln\left(max\left(f_i{}^t\right)\right) < \delta\end{cases} \quad (۳۱)$$

که در آن δ یک مقدار کوچک بوده که معادل *1e-5* است. در الگوریتم پیشنهادی، سرعت همگرایی می‌تواند تحت تأثیر خصوصیات توزیع داده قرار بگیرد. درنتیجه، یک راهکار می‌تواند فیلتر کردن تصویر ورودی به‌عنوان یک مرحله‌ی پیش‌پردازش باشد. MR یک ابزار مناسب در پردازش تصویر برای پالایش، بخش‌بندی و استخراج ویژگی است [۴۴]. MR عمل‌گری مناسب

جهت بهینه کردن توزیع داده بدون درنظر گرفتن نوع نویز است. همچنین، نشان داده شده است که این عمل‌گر می‌تواند نتایج بهتری برای پالایش تصویر نسبت به فیلترهای میانه و میانگین ارائه دهد. این رویکرد قادر به حفظ کانتور شیء و کاهش نویز بدون دانش از نوع آن است [۴۵]. یک مربع ۳×۳ به‌عنوان المان ساختاری[۳۴] (SE) درنظر گرفته می‌شود. جهت بازسازی تصویر، الگوریتم بازسازی مقدار خاکستری سریع[۳۵] (FGR) [۴۶] به‌کار گرفته می‌شود.

بازسازی تصویر خاکستری با استفاده از عمل‌گر گسترش $\left(D_I^{(1)}(f)\right)$ با المان ساختاری صاف (K) به‌صورت زیر تعریف می‌شود:

$$D_I^{(1)}(f) = (f \oplus K) \wedge I \qquad (۳۲)$$

که در آن I و f به‌ترتیب تصویر اصلی در مقیاس خاکستری و تصویر نشان‌گر ($f \leq I$) هستند. ۸ توصیفی برای کمینه بودن است.

بازسازی تصویر خاکستری با استفاده از عمل‌گر فرسایش $\left(E_I^{(1)}(f)\right)$ با المان ساختاری صاف (K) به‌صورت زیر تعریف می‌شود:

$$E_I^{(1)}(f) = (f \ominus K) \vee I \qquad (۳۳)$$

که در آن I و f به‌ترتیب تصویر اصلی در مقیاس خاکستری و تصویر نشان‌گر ($f \geq I$) هستند. ۷ توصیفی برای بیشینه بودن است.

عمل‌گرهای بستن[۳۶] $\left(C_I^{(1)}(f)\right)$ و باز شدن[۳۷] $\left(O_I^{(1)}(f)\right)$ می‌توانند براساس عمل‌گرهای فرسایش و گسترش تعریف شوند. این عمل‌گرها عمل‌کرد بهتری نسبت به عمل‌گرهای مورفولوژیکی فرسایش و گسترش برای پالایش تصویر نشان می‌دهند [۴۴]. این بازسازی‌های مورفولوژیکی به‌صورت زیر تعریف می‌شوند:

$$C_I^{(1)}(f) = E_I^{(1)}\left(D_I^{(1)}(f)\right) \qquad (۳۴)$$

$$O_I^{(1)}(f) = D_I^{(1)}\left(E_I^{(1)}(f)\right) \qquad (۳۵)$$

ترتیب مراحل الگوریتم IGK پیشنهادی جهت بخش‌بندی تصاویر MRI به‌صورت زیر است:

مرحله ۱: به‌کارگیری رویکرد MR به‌عنوان مرحله‌ی پیش‌پردازش.

مرحله ۲: تنظیم تعداد مراکز خوشه، مقدار α، مقداردهی اولیه برای ماتریس عضویت و مراکز خوشه از طریق الگوریتم K-میانگین.

مرحله ۳: محاسبه‌ی ماتریس کواریانس از طریق رابطه‌ی (۲۴).

مرحله ۴: محاسبه‌ی نرم ماتریس از طریق رابطه‌ی (۲۵).

مرحله ۵: محاسبه‌ی ماتریس عضویت از طریق رابطه‌ی (۲۰).

مرحله ۶: محاسبه‌ی مقدار ξ_i از طریق رابطه‌ی (۳۰) تا زمان برقراری شرط موجود در رابطه‌ی (۳۱).

مرحله ۷: محاسبه‌ی مراکز خوشه طریق رابطه‌ی (۲۲).

مرحله ۸: اگر $max\{U^{(It)} - U^{(It+1)}\} < \varepsilon$، الگوریتم متوقف شده و در غیر این صورت به **مرحله ۳** بازگردد.

مرحله ۹: به‌کارگیری متغیرهای u_{ij} و v_j جهت انجام فرآیند بخش‌بندی.

۴- نتایج پیاده‌سازی

به‌منظور ارزیابی عمل‌کرد الگوریتم پیشنهادی و مقایسه‌ی آن با سایر روش‌ها، از دو پایگاه داده‌ی MRI مغزی شامل BrainWeb [۴۷] و مرکز تصویربرداری پزشکی گلگشت تبریز (GMICT) استفاده شده است. برای پایگاه داده‌ی BrainWeb، از تصاویر مبتنی بر T_1 تحت نویزهای ۳٪، ۹٪ و شرایط مختلف INU (۲۰٪ و ۴۰٪) در برش‌های ۸۰ الی ۱۲۰ استفاده شده است. همچنین، در این مطالعه از داده‌های پژوهش شامل ۱۰ بیمار با تشخیص تحلیل سلول‌های عصبی که با استفاده از یک اسکنر TOSHIBA Vantage 1.5 Tesla در مرکز تصویربرداری پزشکی گلگشت تبریز جمع‌آوری شده استفاده شده است. پروتکل‌های اسکن MRI با روش‌های استاندارد انجام گردید. در این فرآیند، جهت اخذ تصویر T_1 از زمان تکرار ۵۴۰ میلی ثانیه، زمان اکو ۱۵میلی ثانیه، زاویه چرخش ۷۰ درجه، میدان دید ۲۳۰ در ۲۳۰ میلی‌متر، تعداد برش ۱۸، اندازه وکسل ۰/۴۵ میلی‌متر و ضخامت برش ۶ میلی‌متر استفاده شد. همچنین، جهت اخذ تصویر T_2-FLAIR از زمان تکرار ۱۰۰۰۰ میلی‌ثانیه، زمان اکو ۱۰۰ میلی‌ثانیه، زمان برگردان ۲۵۰۰ میلی‌ثانیه، زاویه چرخش ۹۰ درجه، میدان دید ۲۳۰ در ۲۳۰ میلی‌متر، تعداد برش ۲۰، اندازه وکسل ۰/۹ میلی‌متر و ضخامت برش ۶ میلی‌متر استفاده شد. در نهایت، یک نرولوژیست به دقت تمام اسکن‌های بیماران را بررسی کرده است. در این مطالعه از تصاویر T_1 و T_2-FLAIR با اندازه‌های وکسل (۰/۴۵، ۰/۴۵، ۶) و (۰/۹، ۰/۹، ۶) میلی‌متر استفاده شد. این پژوهش در کمیته اخلاق دانشگاه علوم پزشکی تبریز تصویب و رضایت نامه‌ای از همه

شرکت کنندگان دریافت شد.

جهت ارزیابی عمل‌کرد الگوریتم‌ها در فرآیند بخش‌بندی، سه معیار تشابه دایس (*DS*)، جاکارد (*JS*) و تطبیق کانتور (*CS*) [۴۸] به‌کار گرفته می‌شوند. ضریب تشابه دایس جهت اندازه‌گیری درجه‌ی هم‌پوشانی بین دو تصویر بخش‌بندی شده با استفاده از الگوریتم پیشنهادی (A) و بخش‌بندی شده به‌صورت دستی (B) به‌کار گرفته می‌شود. این معیار به‌صورت زیر تعریف می‌شود:

$$DS(A,B) = \frac{2|A \cap B|}{|A| + |B|} \qquad (۳۶)$$

ضریب تشابه جاکارد جهت محاسبه‌ی میزان تشابه بین دو تصویر به‌کار گرفته شده و به‌صورت زیر تعریف می‌شود:

$$JS(A,B) = \frac{|A \cap B|}{|A \cup B|} \qquad (۳۷)$$

ضریب تطبیق کانتور جهت محاسبه‌ی امتیاز تطبیق کانتور بین تصویر بخش‌بندی شده با استفاده از الگوریتم پیشنهادی و تصویر بخش‌بندی شده به‌صورت دستی به‌کار گرفته می‌شود. این معیار در محدوده‌ی [۰،۱] بوده و به‌صورت زیر تعریف می‌شود:

$$CS = \frac{2.P^c.R^c}{P^c + R^c} \qquad (۳۸)$$

که در آن P^c و R^c به‌ترتیب نشان دهنده‌ی دقت و پوشش است. الگوریتمی بهترین عمل‌کرد را دارد که از لحاظ معیارهای *DSC*، *JSC* و *CMS* بالاترین مقدار را داشته باشد.

۴-۱- تنظیم پارامترها

در پیاده‌سازی عددی IGK و سایر روش‌ها، نیازمند تنظیم پارامترهای ثابت هستیم. در این مطالعه، سه پارامتر ضروری برای تمامی الگوریتم‌ها شامل میزان فازی‌شدگی، آستانه‌ی خطای کمینه و بیشینه‌ی تعداد تکرار به‌ترتیب به‌صورت $q=2$، $\eta = 10^{-5}$ و ۵۰ درنظر گرفته می‌شود. همچنین، تعداد مراکز خوشه برابر با ۴ برای کلاس‌های پس‌زمینه، WM، GM و CSF فرض می‌شود. عمل‌کرد الگوریتم پیشنهادی با الگوریتم‌های MICO، GMM، ARKFCM، FCMPSO، FCMWOA، FCMGWO، SFCMEMBC، BCIFCMSNI، الگوریتم سریع و مقاوم FCM (FRFCM) [۴۵] و FCM شعاعی (RFCM) [۴۹] مورد مقایسه قرار می‌گیرد. در الگوریتم MICO، درجه‌ی چندجمله‌ای لژاندر برابر $P=3$ درنظر گرفته می‌شود. در FCMPSO، براساس پارامترهای گزارش شده در [۲۷]، اندازه‌ی جمعیت (n)، وزن اینرسی (ω)، ضریب شناختی (c_1) و ضریب اجتماعی (c_2) به‌ترتیب برابر ۶۰، ۱، ۲ و ۲ تنظیم شده است. در الگوریتم‌های FCMWOA و FCMGWO، اندازه‌ی جمعیت برابر ۱۲ درنظر گرفته شده است. به جز سه پارامتر ضروری ذکر شده و تعداد مراکز خوشه، هیچ پارامتر ثابت دیگری برای ARKFCM وجود ندارد. در BCIFCMSNI براساس پارامترهای گزارش شده در [۳۴]، پارامتر خنثی کننده‌ی سوگنو برابر $\beta=1.7$ درنظر گرفته شده است. همچنین، پارامتر تنظیم مکانی و اندازه‌ی همسایگی هم در این الگوریتم به‌ترتیب برابر ۱/۵ و ۳ فرض شده است. در FRFCM، پارامتر *SE* برای رویکرد MR به‌صورت یک مربع در اندازه‌ی ۳×۳ درنظر گرفته شده است. در RFCM، براساس پارامترهای گزارش شده در [۵۰]، جهت کنترل نرخ کاهش ماتریس وزنی، پارامتر ξ به‌صورت $\xi=0.0008$ فرض شده است. همچنین، در این الگوریتم، سطوح نویز براساس انحراف معیار تصویر ورودی درنظر گرفته شده است. الگوریتم IGK پیشنهادی نیازمند تنظیم پارامتر α است. این مقدار برای پایگاه داده‌های BrainWeb و GMICT به‌صورت تجربی براساس آزمایش‌های مختلف به‌ترتیب برابر ۱۵ و ۳۰ درنظر گرفته می‌شود.

۴-۲- نتایج پیاده‌سازی بر روی پایگاه داده‌ی BrainWeb

عمل‌کرد بخش‌بندی برای تصاویر MRI مغزی مبتنی بر وزن T_1 پایگاه داده‌ی BrainWeb با سطوح مختلف نویز و INU بر روی برش‌های ۸۰ الی ۱۲۰ مشخص می‌شود. شکل ۱ نمونه‌ای از نتایج کیفی به‌دست آمده انواع الگوریتم‌ها را بر روی برش ۸۶ با سطح نویز ۹٪ و INU برابر ۴۰٪ نشان می‌دهد. عمل‌کرد الگوریتم‌های مختلف در بخش‌بندی WM، GM و CSF در سطوح ذکر شده برای نویز و INU به‌ترتیب در جدول‌های ۱ الی ۳ مشخص شده است. همچنین، میانگین معیار دایس برای WM، GM و CSF بر روی برش‌های ۸۰ الی ۱۲۰ در شکل ۲ نشان داده شده است.

براساس نتایج جدول ۱، الگوریتم IGK پیشنهادی بهترین عمل‌کرد را در بخش‌بندی WM نسبت به سایر الگوریتم‌های مقایسه شده دارد. براساس معیار CS، الگوریتم MICO عمل‌کرد مناسبی را در شناسایی مرز WM تحت شرایط نویز ۹٪ و INU برابر ۴۰٪ ندارد. این الگوریتم عمل‌کرد مناسبی را در در بخش‌بندی WM تحت شرایط نویز ۳٪ و INU برابر ۲۰٪ دارد. همچنین، شکل ۲ نشان می‌دهد که الگوریتم MICO کارآیی خوبی را برای مقطع‌های ۱۰۴ الی ۱۱۳ ندارد.

جدول ۱: مقایسه‌ی عمل‌کرد الگوریتم IGK پیشنهادی با سایر الگوریتم‌ها در بخش‌بندی WM بر روی پایگاه داده‌ی BrainWeb.

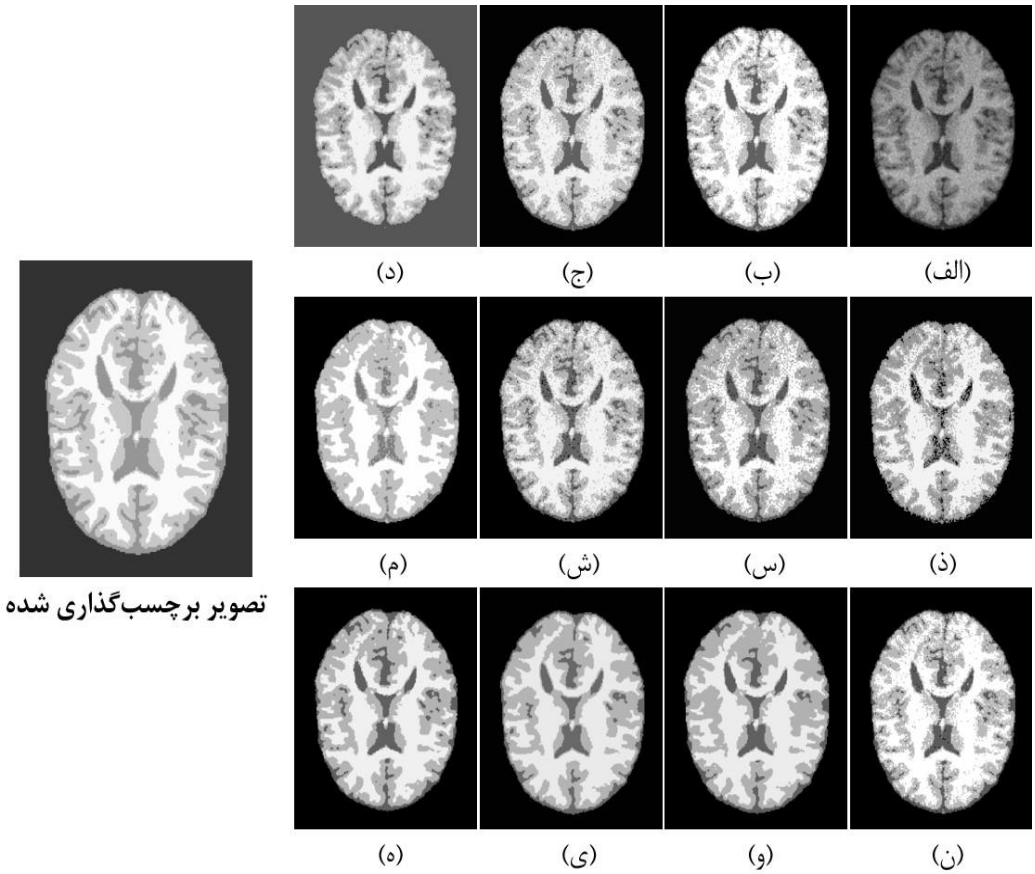
معیار / روش	*DS* (%) ↑				*JS* (%) ↑				*CS* (%) ↑			
	3% Noise		9% Noise		3% Noise		9% Noise		3% Noise		9% Noise	
	20% INU	40% INU	20% INU	40% INU	20% INU	40% INU	20% INU	40% INU	20% INU	40% INU	20% INU	40% INU
GK [۴۲]	۹۰/۲۸	۸۷/۴۹	۸۳/۶۶	۸۲/۱۶	۸۷/۸۵	۸۲/۵۷	۷۳/۰۵	۷۴/۸۲	۹۳/۱۳	۹۰/۴۵	۷۶/۷۹	۷۷/۸۰
MICO [۱۷]	۹۳/۳۰	۹۴/۲۴	۸۴/۰۶	۸۴/۵۵	۸۷/۸۶	۸۹/۶۱	۷۲/۷۶	۷۳/۵۰	۹۵/۲۰	۹۷/۱۵	۷۷/۳۴	۷۸/۲۶
GMM [۲۲]	۹۵/۶۸	۹۱/۹۴	۸۵/۴۳	۸۴/۵۹	۹۱/۷۵	۸۵/۱۳	۷۴/۷۰	۷۳/۳۹	۹۸/۳۸	۹۱/۰۳	۷۸/۴۴	۷۸/۲۰
ARKFCM [۲۰]	۹۴/۹۶	۹۲/۹۱	۹۳/۱۱	۹۰/۶۳	۹۱/۹۰	۸۶/۸۸	۸۷/۱۹	۸۲/۹۷	۹۸/۵۷	۹۳/۵۵	۹۴/۲۷	۸۹/۸۰
FCMPSO [۲۷]	۷۹/۶۲	۸۴/۸۰	۶۲/۹۷	۷۱/۱۴	۷۲/۴۸	۷۷/۸۱	۵۱/۱۵	۵۹/۵۴	۹۰/۹۶	۹۱/۳۴	۷۳/۱۱	۷۵/۷۹
FCMWOA [۲۸]	۹۱/۷۶	۸۸/۶۵	۸۰/۳۵	۸۲/۲۰	۸۵/۵۱	۸۱/۵۵	۶۹/۳۱	۷۰/۸۸	۹۲/۵۲	۸۷/۲۷	۷۶/۹۲	۷۷/۷۶
FCMGWO [۲۶]	۹۵/۶۳	۹۴/۰۹	۸۸/۰۵	۸۷/۳۴	۹۲/۰۲	۸۹/۵۵	۷۸/۶۹	۷۷/۵۷	۹۸/۶۰	**۹۷/۲۱**	۸۲/۸۵	۸۲/۸۴
SFCMEMBC [۲۳]	۹۵/۷۲	۹۴/۴۴	۹۳/۹۱	۹۱/۳۱	۹۱/۸۵	۸۹/۵۰	۸۸/۵۵	۸۵/۷۶	۹۸/۶۳	۹۶/۸۰	۹۸/۰۸	۹۳/۸۷
BCIFCMSNI [۳۴]	۸۸/۸۹	۸۴/۸۴	۸۵/۷۶	۸۵/۲۵	۸۱/۹۱	۷۶/۰۸	۷۵/۴۴	۷۴/۹۷	۸۰/۰۹	۶۹/۹۵	۸۲/۱۳	۷۸/۶۶
FRFCM [۴۵]	۹۴/۱۷	۹۴/۲۶	۹۳/۵۲	۹۱/۵۹	۹۱/۷۵	۸۹/۱۸	۸۷/۸۸	۸۵/۱۹	۹۷/۹۳	۹۵/۴۸	۹۶/۶۶	۹۳/۲۵
RFCM [۴۹]	۹۴/۳۶	۹۳/۱۹	۹۳/۷۹	۹۱/۱۷	۹۰/۶۳	۸۷/۲۹	۸۸/۸۴	**۸۵/۸۳**	۹۷/۲۶	۹۴/۱۴	۹۷/۰۵	۹۳/۴۱
IGK	**۹۶/۱۵**	**۹۴/۸۸**	**۹۳/۹۲**	**۹۱/۹۷**	**۹۳/۱۰**	**۸۹/۷۰**	**۸۸/۹۱**	۸۵/۳۶	**۹۸/۷۵**	۹۵/۱۰	**۹۸/۲۰**	**۹۳/۶۰**

جدول ۲: مقایسه‌ی عمل‌کرد الگوریتم IGK پیشنهادی با سایر الگوریتم‌ها در بخش‌بندی GM بر روی پایگاه داده‌ی BrainWeb.

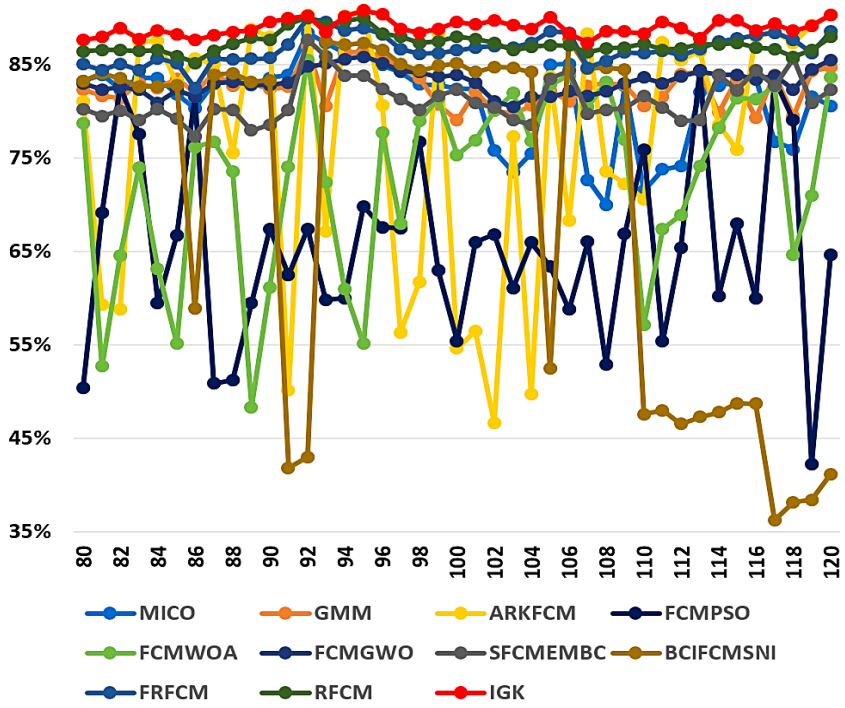
معیار / روش	*DS* (%) ↑				*JS* (%) ↑				*CS* (%) ↑			
	3% Noise		9% Noise		3% Noise		9% Noise		3% Noise		9% Noise	
	20% INU	40% INU	20% INU	40% INU	20% INU	40% INU	20% INU	40% INU	20% INU	40% INU	20% INU	40% INU
GK [۴۲]	۸۷/۸۶	۸۳/۷۱	۷۷/۶۱	۷۳/۵۹	۸۰/۷۱	۷۵/۰۲	۶۱/۴۶	۶۰/۷۰	۹۲/۲۶	۹۱/۲۶	۸۹/۶۳	۸۸/۶۸
MICO [۱۷]	۸۷/۵۲	۸۹/۱۰	۷۵/۰۴	۷۵/۶۹	۷۸/۳۰	۸۰/۶۱	۶۰/۳۳	۶۱/۲۰	۹۷/۶۰	۹۷/۳۶	۹۱/۹۰	۹۲/۲۰
GMM [۲۲]	۹۱/۸۰	۸۷/۴۴	۸۰/۰۲	۷۹/۱۳	۸۴/۸۸	۷۷/۷۶	۶۶/۷۸	۶۵/۵۴	**۹۸/۷۳**	۹۴/۴۸	۹۱/۸۴	۹۱/۳۳
ARKFCM [۲۰]	۸۴/۳۸	۷۸/۰۰	۷۷/۵۷	۷۴/۳۵	۷۵/۰۵	۶۶/۵۷	۶۵/۶۳	۶۱/۲۲	۹۷/۰۰	۹۵/۱۹	۹۵/۶۹	۹۴/۲۱
FCMPSO [۲۷]	۶۷/۳۴	۶۷/۸۶	۵۹/۱۵	۵۸/۸۲	۵۲/۲۸	۵۷/۲۲	۴۵/۴۵	۴۴/۶۶	۹۲/۶۳	۹۱/۶۴	۸۸/۴۰	۸۸/۲۲
FCMWOA [۲۸]	۷۸/۸۴	۷۶/۷۳	۶۷/۹۴	۶۸/۴۴	۶۸/۴۴	۶۵/۳۵	۵۳/۳۶	۵۳/۶۵	۹۵/۶۷	۹۳/۵۴	۹۱/۵۸	۹۱/۷۷
FCMGWO [۲۶]	۹۱/۳۹	**۹۰/۱۰**	۸۱/۰۳	۸۰/۳۳	۸۳/۳۷	۸۲/۱۷	۶۸/۱۳	۶۷/۱۵	۹۸/۶۲	**۹۸/۱۰**	۹۴/۱۶	۹۳/۸۰
SFCMEMBC [۲۳]	۸۴/۴۰	۸۳/۴۱	۸۳/۹۲	۸۲/۷۸	۷۳/۰۹	۷۱/۶۱	۷۲/۳۷	۷۰/۶۸	۹۲/۳۳	۹۱/۴۱	۹۳/۹۹	۹۲/۸۹
BCIFCMSNI [۳۴]	۶۸/۹۵	۶۶/۷۴	۶۹/۸۱	۶۷/۹۶	۶۱/۰۰	۵۸/۹۲	۵۵/۵۸	۵۵/۰۰	۸۹/۷۹	۸۴/۷۸	۹۳/۹۴	۹۱/۱۸
FRFCM [۴۵]	۸۹/۵۱	۸۸/۲۲	۸۶/۸۱	۸۵/۲۱	۸۱/۰۹	۷۸/۹۸	۷۶/۷۴	۷۴/۱۲	۹۴/۸۶	۹۳/۷۵	۹۴/۷۰	۹۳/۱۱
RFCM [۴۹]	۸۹/۲۷	۸۷/۱۳	۸۸/۲۵	۸۶/۰۱	۸۰/۶۶	۷۷/۲۱	۷۸/۸۰	۷۵/۲۲	۹۵/۰۴	۹۴/۰۸	۹۵/۴۱	۹۴/۱۹
IGK	**۹۲/۱۰**	۸۹/۷۳	**۸۸/۸۹**	**۸۶/۳۰**	**۸۵/۴۱**	**۸۲/۳۹**	**۷۹/۶۹**	**۷۵/۶۹**	۹۷/۷۷	۹۷/۶۹	**۹۷/۶۲**	**۹۶/۵۲**

جدول ۳: مقایسه‌ی عمل‌کرد الگوریتم IGK پیشنهادی با سایر الگوریتم‌ها در بخش‌بندی CSF بر روی پایگاه داده‌ی BrainWeb.

معیار / روش	*DS* (%) ↑				*JS* (%) ↑				*CS* (%) ↑			
	3% Noise		9% Noise		3% Noise		9% Noise		3% Noise		9% Noise	
	20% INU	40% INU	20% INU	40% INU	20% INU	40% INU	20% INU	40% INU	20% INU	40% INU	20% INU	40% INU
GK [۴۲]	۸۷/۰۴	۸۵/۲۶	۷۹/۵۸	۷۹/۱۰	۷۹/۳۳	۷۷/۶۹	۶۹/۴۰	۶۸/۸۵	۹۳/۳۳	۹۲/۰۳	۹۰/۵۶	۹۰/۶۲
MICO [۱۷]	۸۷/۴۴	۸۸/۴۴	۸۲/۷۰	۸۳/۳۷	۷۷/۸۹	۷۹/۴۴	۷۰/۷۰	۷۱/۶۷	۹۷/۶۳	**۹۸/۳۵**	۹۵/۱۳	۹۵/۰۷
GMM [۲۲]	۸۹/۸۰	۸۵/۴۴	۸۴/۵۲	۸۴/۰۸	۸۱/۶۶	۷۴/۹۲	۷۳/۲۷	۷۲/۶۰	**۹۸/۶۹**	۹۷/۰۳	۹۶/۴۶	۹۵/۸۵
ARKFCM [۲۰]	۶۷/۰۸	۶۴/۹۵	۶۳/۱۰	۶۵/۹۵	۵۶/۷۶	۵۳/۸۴	۵۲/۱۲	۵۳/۵۹	۹۳/۰۷	۹۱/۲۴	۹۰/۴۱	۹۰/۵۰
FCMPSO [۲۷]	۷۲/۴۱	۸۰/۳۹	۶۵/۰۳	۶۵/۶۶	۶۲/۲۷	۷۱/۵۶	۵۱/۲۲	۵۲/۳۷	۹۲/۶۲	۹۴/۷۸	۸۸/۳۳	۸۸/۹۴
FCMWOA [۲۸]	۷۵/۵۷	۷۴/۲۲	۶۷/۳۴	۶۸/۰۱	۶۲/۷۶	۶۱/۳۶	۵۲/۶۲	۵۲/۸۰	۹۲/۴۶	۹۱/۴۵	۸۹/۳۵	۸۹/۸۰
FCMGWO [۲۶]	۸۸/۶۵	۸۹/۵۰	۸۲/۵۶	۸۲/۱۸	۸۰/۰۷	۸۱/۱۹	۷۰/۳۸	۶۹/۸۳	۹۸/۳۴	۹۸/۲۱	۹۵/۱۴	۹۴/۹۱
SFCMEMBC [۲۳]	۶۰/۷۹	۶۱/۳۷	۶۷/۵۶	۶۸/۷۳	۴۳/۹۲	۴۴/۵۰	۵۱/۳۴	۵۲/۵۹	۸۳/۰۷	۸۲/۷۲	۸۷/۷۵	۸۸/۲۷
BCIFCMSNI [۳۴]	۵۷/۰۴	۴۷/۲۹	۵۲/۰۹	۶۴/۲۶	۴۹/۸۳	۵۱/۵۲	۴۴/۰۷	۵۸/۸۹	۷۳/۸۰	۵۹/۰۶	۷۴/۶۴	۷۶/۳۳
FRFCM [۴۵]	۸۲/۵۲	۸۳/۶۹	۸۲/۱۵	۸۲/۱۳	۷۰/۴۳	۷۲/۱۱	۷۰/۱۰	۷۰/۰۶	۸۷/۹۷	۸۸/۵۴	۸۸/۵۱	۸۹/۱۹
RFCM [۴۹]	۸۳/۷۳	۸۳/۶۲	۸۳/۸۰	۸۳/۰۸	۷۲/۰۷	۷۱/۹۲	۷۶/۱۶	۷۱/۱۸	۸۹/۰۰	۸۹/۵۲	۸۹/۹۸	۹۱/۰۲
IGK	**۹۰/۳۸**	**۸۹/۶۵**	**۸۸/۷۶**	**۸۷/۶۵**	**۸۲/۵۷**	**۸۱/۸۱**	**۷۹/۸۹**	**۷۷/۸۶**	۹۷/۷۰	۹۷/۵۲	**۹۷/۵۱**	**۹۷/۱۰**



شکل ۱: عمل‌کرد الگوریتم‌های مختلف در بخش‌بندی نمونه‌ای از تصاویر پایگاه داده‌ی Brainweb مربوط به برش ۸۶. (الف): تصویر اصلی با نویز ۹٪ و INU برابر ۴۰٪، (ب): خروجی MICO، (ج): خروجی GMM، (د): خروجی ARKFCM، (ذ): خروجی FCMPSO، (س): خروجی FCMWOA، (ش): خروجی FCMGWO، (م): خروجی SFCMEMBC، (ن): خروجی BCIFCMSNI، (و): خروجی FRFCM، (ی): خروجی RFCM، (ه): خروجی الگوریتم پیشنهادی.



شکل ۲: مقایسه‌ی الگوریتم IGK پیشنهادی با سایر الگوریتم‌ها براساس میانگین معیار *DS* برای بافت‌های WM، GM و CSF در تمامی برش‌های تحت شرایط نویز ۹٪ و INU برابر ۴۰٪.

الگوریتم GMM فرض می‌کند که تمامی ویژگی‌ها در داده به‌صورت نرمال توزیع شده که این ویژگی نسبت به نویز و داده‌های پرت حساس است. جدول ۱ مشخص می‌کند که GMM قادر به بخش‌بندی WM تحت شرایط سطوح بالا از نویز و INU نیست. الگوریتم ARKFCM عمل‌کرد خوبی را در بخش‌بندی WM دارد، اما شکل ۲ نشان می‌دهد که این الگوریتم برای برش‌های ۹۹ الی ۱۰۴ مناسب نیست. FCMPSO نتایج خوبی را برای شرایط سطوح بالا از نویز و INU نشان نمی‌دهد. این الگوریتم در فازهای استخراج و اکتشاف حساس به نویز و پارامترهای ثابت است. در FCMPSO، کلاس پس‌زمینه معمولاً به‌صورت اشتباه به کلاس GM برچسب زده می‌شود. شکل ۲ نشان می‌دهد که FCMPSO برای برش‌های ۹۹ الی ۱۰۹ مناسب نبوده، درحالی که FCMWOA عمل‌کرد مناسبی در این مقطع‌ها نسبت به FCMPSO دارد. نتایج به‌دست آمده برای FCMGWO در بخش‌بندی تصاویر MRI نیز نشان می‌دهد که بهینه‌سازی الگوریتم FCM در فضای با بعد بالا عمل‌کرد بهتری نسبت به فضای با بعد پایین دارد.

همان‌طوری که در شکل ۱(ذ-ش) نیز نشان داده شده است، الگوریتم‌های FCMPSO و FCMWOA به اشتباه تعدادی از پیکسل‌های WM را به‌عنوان پیکسل‌های GM درنظر می‌گیرند، به‌طوری که این چالش در الگوریتم FCMGWO با بیان الگوریتم FCM به‌عنوان یک مسئله‌ی بهینه‌سازی گسسته برطرف شده است. الگوریتم SFCMEMBC عمل‌کرد مناسبی در بخش‌بندی WM دارد، اما این الگوریتم برای بخش‌بندی GM و CSF مناسب نیست. الگوریتم BCIFCMSNI نمی‌تواند اصلاح غیریکنواختی شدت را برای برش‌های ۱۰۹ الی ۱۲۰ انجام دهد. همچنین، براساس معیار JS به‌دست آمده از جدول ۱، این الگوریتم قادر به بخش‌بندی مناسب WM نیست. تحت شرایط مشخص شده برای نویز و INU، سه الگوریتم FRFCM، RFCM و IGK پیشنهادی عمل‌کرد خوبی را در بخش‌بندی WM نسبت به سایر الگوریتم‌ها دارند. به‌کارگیری تئوری اطلاعات و رویکرد MR باعث شده است که الگوریتم IGK پیشنهادی نسبت به الگوریتم‌های FRFCM و RFCM مقاوم‌تر باشد. براساس نتایج جدول ۱، معیار CS تایید می‌کند که الگوریتم IGK پیشنهادی لبه‌ها را با جزئیات بیشتر حفظ کرده و تطبیق کانتور مناسبی را در بخش‌بندی WM دارد.

همان‌طوری که در جدول ۲ مشخص شده است، الگوریتم پیشنهادی قادر به بخش‌بندی GM تحت شرایط مختلف نویز و INU بوده، به‌طوری که بهترین عمل‌کرد را از منظر معیارهای *DS* و *JS* نسبت به سایر الگوریتم‌ها دارد. این فرآیند نشان می‌دهد که IGK در بخش‌بندی GM مقاوم و با دقت بالا عمل می‌کند. براساس معیارهای *DS* و *JS*، الگوریتم MICO عمل‌کرد خوبی برای بخش‌بندی GM نداشته و نسبت به سطوح مختلف نویز و INU استحکام لازم را ندارد. براساس معیار *CS*، این الگوریتم کارآیی مناسبی را تحت شرایط نویز ۳٪ و سطوح بالای INU دارد. این موضوع نشان می‌دهد که الگوریتم MICO نیز همانند الگوریتم پیشنهادی می‌تواند مرز GM را با جزئیات بیشتر شناسایی کند. نکته‌ی مهم این است که الگوریتم MICO برای سطوح بالای نویز (۹٪) مقاوم نبوده و نمی‌تواند در مقایسه با الگوریتم پیشنهادی به‌خوبی GM را بخش‌بندی کند. ویژگی مهمی که IGK دارد این است که بالاترین معیارهای اندازه‌گیری را برای سطوح بالای نویز و INU در مقایسه با سایر الگوریتم‌های مقایسه شده دارد. نتایج نشان می‌دهند که در این سطوح براساس معیار *CS* الگوریتم پیشنهادی لبه را با جزئیات بیشتر حفظ می‌کند. به‌دلیل برچسب‌گذاری اشتباه کلاس پس‌زمینه به‌عنوان کلاس GM توسط FCMPSO، این الگوریتم بدترین عمل‌کرد را برای بخش‌بندی GM دارد. الگوریتم FCMWOA عمل‌کرد مناسبی را نسبت به FCMPSO در شرایط سطوح پایین نویز و INU داشته، ولی در سطوح بالا استحکام کافی ندارد. همان‌طوری که در شکل ۲ نشان داده شده است، BCIFCMSNI عمل‌کرد خوبی در برش‌های ۸۰ الی ۸۵ و ۹۲ الی ۱۰۲ داشته و عملاً گزینه‌ی مناسبی برای بخش‌بندی سایر مقطع‌ها نیست. همان‌طوری که در شکل ۱ نشان داده شده است، الگوریتم پیشنهادی پیکسل‌های GM را با جزئیات بیشتری بخش‌بندی می‌کند. نتایج الگوریتم‌های GMM و SFCMEMBC تایید می‌کنند که فرض توزیع نرمال برای بخش‌بندی GM مناسب نیست.

ناحیه‌ی CSF از خوشه‌های فشرده و کوچک تشکیل شده است. درنتیجه، رویکردهای مبتنی بر FCM نظیر الگوریتم‌های ARKFCM، FCMPSO، FCMWOA، SFCMEMBC و BCIFCMSNI نمی‌توانند براساس فاصله‌ی اقلیدسی عمل‌کرد مناسبی برای بخش‌بندی این ناحیه داشته باشند. براساس شکل ۱(و) آشکار است که الگوریتم FRFCM اشتباهاً CSF را به کلاس GM برچسب می‌زند. همان‌طوری که در جدول ۳ نیز نشان داده شده است، رویکردهای مبتنی بر FCM گزینه‌های مناسبی برای بخش‌بندی ناحیه‌ی CSF نیستند. این موضوع نشان می‌دهد که این رویکردها هنگامی که خوشه‌ها در داده شکل و اندازه‌ی یکسانی نداشته باشند ابزار مناسبی نیستند. همچنین، نتایج تأیید می‌کنند که الگوریتم IGK پیشنهادی رویکرد مناسبی برای آشکارسازی خوشه‌های بیضوی با ساختار غیرمشابه است.

روش‌های مبتنی بر یادگیری عمیق عمل‌کرد خوبی در بخش‌بندی تصاویر پزشکی دارند [۵۰]. ساختار اصلی عمل‌کرد این روش‌ها بر شبکه‌های عصبی پیچشی[۳۸] (CNN) استوار بوده که از موفق‌ترین این رویکردها می‌توان به شبکه‌های U-Net اشاره کرد. در ادامه این مطالعه، به‌منظور ارزیابی بیشتر و مقایسه‌ی عمل‌کرد الگوریتم پیشنهادی با رویکردهای مبتنی بر یادگیری عمیق، از مدل جدید SynthSeg استفاده می‌شود.

SynthSeg یک شبکه عصبی پیچشی بوده که برای بخش‌بندی تصاویر MRI مغزی با کنتراست و وضوح مختلف بدون نیاز به آموزش مجدد طراحی شده است. مدل‌های معمولی CNN اغلب به دلیل تغییرات در عواملی مانند وضوح و کنتراست، در تعمیم‌پذیری به حوزه‌های مختلف دچار مشکل می‌شوند [۵۱]. برای رفع این مسئله، SynthSeg از یک رویکرد تصادفی‌سازی حوزه در حین آموزش استفاده کرده که در آن داده‌های مصنوعی بر اساس مدل‌های بخش‌بندی شده تولید می‌شوند. با تصادفی‌سازی کامل کنتراست و وضوح این تصاویر مصنوعی، رویکرد SynthSeg در مقابل سطوح مختلف کنتراست مقاوم بوده و می‌تواند به‌طور مؤثر اسکن‌های واقعی از تصاویر مختلف پزشکی را بخش‌بندی کند. این روش امکان تجزیه و تحلیل مجموعه داده‌های بالینی بزرگ و ناهمگن را فراهم می‌کند. این روش تنها نیازمند برچسب‌های بخش‌بندی بوده و نیازی به تصاویر واقعی ندارد. این ویژگی باعث می‌شود مدل بتواند از برچسب‌هایی که با استفاده از روش‌های خودکار در جمعیت‌های مختلف به دست آمده‌اند، یاد بگیرد و در نتیجه در برابر انواع مختلف تغییرات مورفولوژیکی مقاوم شود. ارزیابی‌ها روی ۵۰۰۰ اسکن شامل شش روش تصویربرداری و ده وضوح مختلف نشان داده است که SynthSeg در مقایسه با شبکه‌های CNN نظارت شده‌ی سنتی، روش‌های تطبیق دامنه پیشرفته و روش‌های بخش‌بندی بیزی عمل‌کرد بهتری دارد. علاوه بر این، SynthSeg در پردازش MRI قلبی و اسکن‌های CT نیز عمل‌کرد خوبی داشته که نشان دهنده‌ی تطبیق‌پذیری بالای آن است [۵۱]. نسخه توسعه یافته‌ی این مدل امکان بخش‌بندی دقیق، پارسیلاسیون قشر مغز، تخمین حجم درون جمجمه‌ای و تشخیص خودکار خطاها را فراهم می‌کند. این نسخه برای پردازش داده‌های کلینیکی ناهمگن بهینه شده و در مطالعات بزرگ مانند تحلیل روند پیری بر روی ۱۴۰۰۰ اسکن عمل‌کرد موفقی داشته است [۵۲]. نتایج مقایسه عمل‌کرد الگوریتم پیشنهادی با روش SynthSeg در جدول ۴ آورده شده است. عموما نتایج هر دو الگوریتم در بخش‌بندی بافت‌های WM و GM شبیه به هم بوده ولی در بخش‌بندی CSF الگوریتم پیشنهادی به مراتب عمل‌کرد بهتری را دارد. نتایج نشان می‌دهد که الگوریتم پیشنهادی قابلیت رقابت با رویکردهای مبتنی بر یادگیری عمیق را داشته و حتی می‌تواند به‌عنوان یک روش مناسب جهت بخش‌بندی سایر تصاویر پزشکی نیز به‌کار گرفته شود. از مزیت اصلی الگوریتم پیشنهادی می‌توان به این موضوع اشاره کرد که برخلاف روش‌های یادگیری عمیق، نیازمند فرآیند پیچیده آموزش و گردآوری داده کلان آموزشی نبوده و پیچیدگی محاسباتی به مراتب پایین‌تری دارد.

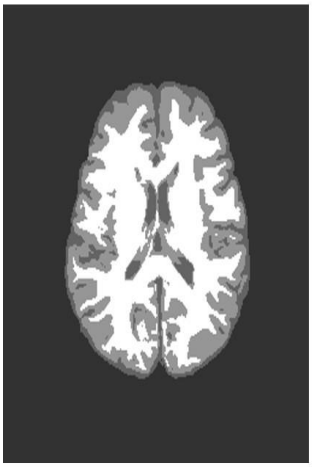
۴-۳- نتایج پیاده‌سازی بر روی پایگاه داده‌ی GMICT

نتایج انواع متفاوت الگوریتم‌ها در بخش‌بندی بافت‌های مختلف مغزی بر روی تصاویر پایگاه داده‌ی مرکز تصویربرداری پزشکی گلگشت تبریز در جدول ۵ آورده شده است. همچنین، شکل ۳ نتایج کیفی به‌دست آمده‌ی انواع الگوریتم‌ها بر روی نمونه‌ای از تصویر این پایگاه داده را نشان می‌دهد. مقایسه‌ی عمل‌کردی انواع الگوریتم‌ها بر روی این پایگاه داده به‌صورت زیر خلاصه می‌شود:

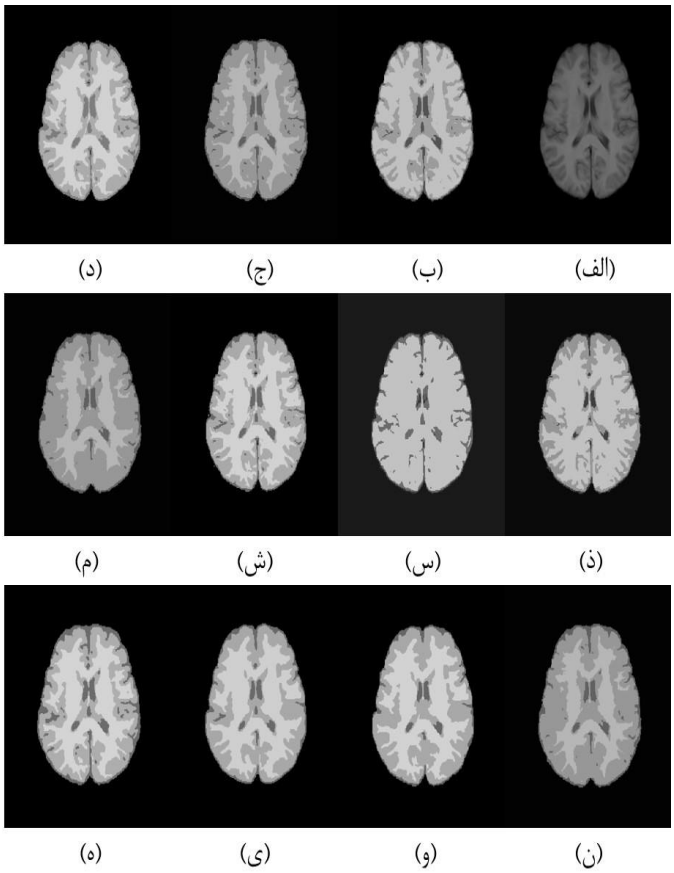
نتایج نشان می‌دهند که الگوریتم پیشنهادی از منظر معیار *DS* بهترین عمل‌کرد را نسبت به سایر الگوریتم دارد. همچنین، بالا بودن تمامی معیارها در بخش‌بندی CSF نشان می‌دهد که الگوریتم IGK گزینه‌ی مناسبی برای خوشه‌بندی داده با خوشه‌ها فشرده است. رویکردهای مبتنی بر جمعیت بدترین عمل‌کرد را در بخش‌بندی بافت‌های مغزی بر روی تصاویر واقعی MRI دارند. براساس شکل ۳(ذ)، در FCMPSO، کلاس بافت GM معمولاً به اشتباه به کلاس بافت WM برچسب زده می‌شود. همچنین، مطابق شکل ۳(س)، در FCMWOA، کلاس بافت CSF معمولاً به اشتباه به سایر کلاس‌ها برچسب زده می‌شود. این فرآیند باعث می‌شود که این دو الگوریتم عمل‌کرد مناسبی نداشته باشند. الگوریتم FCMGWO نسبت به دو الگوریتم همتای خود عمل‌کرد بهتری داشته، به‌طوری که این الگوریتم در بخش‌بندی WM از منظر معیارهای *JS* و *CS* بهترین عمل‌کرد را نسبت به سایر الگوریتم‌ها دارد. این موضوع نشان می‌دهد که بیان الگوریتم FCM به‌عنوان یک مسئله‌ی بهینه‌سازی گسسته کارآیی بهتری نسبت به بیان آن به‌عنوان یک مسئله‌ی بهینه‌سازی پیوسته دارد. همان‌طوری که در شکل ۳(ن) نیز نشان داده شده است، الگوریتم‌های BCIFCMSNI و SFCMEMBC معمولاً عمل‌کرد مشابهی دارند و در برخی از تصاویر به اشتباه کلاس بافت WM را به‌عنوان کلاس بافت GM درنظر می‌گیرند. از منظر معیار *CS* نیز مقدار پایینی دارند و این موضوع نشان می‌دهد که این الگوریتم‌ها در شناسایی مرزه بافت‌های مختلف مغزی عمل‌کرد مناسبی ندارد.

جدول ۴: مقایسه‌ی عمل‌کرد الگوریتم IGK پیشنهادی با رویکرد مبتنی بر یادگیری عمیق در بخش‌بندی بافت‌های مغزی.

White Matter												
معیار / روش	*DS* (%) ↑				*JS* (%) ↑				*CS* (%) ↑			
	3% Noise		9% Noise		3% Noise		9% Noise		3% Noise		9% Noise	
	20% INU	40% INU	20% INU	40% INU	20% INU	40% INU	20% INU	40% INU	20% INU	40% INU	20% INU	40% INU
SynthSeg	۹۴/۷۱	۹۴/۷۳	۹۳/۳۳	**۹۳/۴۵**	۹۰/۰۴	**۹۰/۰۸**	۸۷/۵۹	**۸۷/۸۰**	۹۷/۷۴	**۹۷/۷۳**	۹۶/۵۳	**۹۶/۷۷**
IGK	**۹۶/۱۵**	**۹۴/۸۸**	**۹۳/۹۲**	۹۱/۹۷	**۹۳/۱۰**	۸۹/۷۰	**۸۸/۹۱**	۸۵/۳۶	**۹۸/۷۵**	۹۵/۱۰	**۹۸/۲۰**	۹۳/۶۰
Grey Matter												
معیار / روش	*DS* (%) ↑				*JS* (%) ↑				*CS* (%) ↑			
	3% Noise		9% Noise		3% Noise		9% Noise		3% Noise		9% Noise	
	20% INU	40% INU	20% INU	40% INU	20% INU	40% INU	20% INU	40% INU	20% INU	40% INU	20% INU	40% INU
SynthSeg	۸۸/۴۰	۸۸/۳۹	۸۶/۹۰	**۸۷/۱۰**	۷۹/۲۷	۷۹/۲۴	۷۶/۸۷	**۷۷/۲۰**	۹۶/۳۶	۹۶/۳۵	۹۵/۵۸	۹۵/۶۸
IGK	**۹۲/۱۰**	**۸۹/۷۳**	**۸۸/۸۹**	۸۶/۳۰	**۸۵/۴۱**	**۸۲/۳۹**	**۷۹/۶۹**	۷۵/۶۹	**۹۷/۷۷**	**۹۷/۶۹**	**۹۷/۶۲**	**۹۶/۵۲**
Cerebrospinal Fluid												
معیار / روش	*DS* (%) ↑				*JS* (%) ↑				*CS* (%) ↑			
	3% Noise		9% Noise		3% Noise		9% Noise		3% Noise		9% Noise	
	20% INU	40% INU	20% INU	40% INU	20% INU	40% INU	20% INU	40% INU	20% INU	40% INU	20% INU	40% INU
SynthSeg	۷۹/۰۴	۷۸/۹۵	۷۹/۶۸	۷۹/۷۲	۶۵/۳۹	۶۵/۲۸	۶۶/۲۹	۶۶/۳۳	۹۵/۰۲	۹۴/۹۸	۹۴/۷۲	۹۴/۷۲
IGK	**۹۰/۳۸**	**۸۹/۶۵**	**۸۸/۷۶**	**۸۷/۶۵**	**۸۲/۵۷**	**۸۱/۸۱**	**۷۹/۸۹**	**۷۷/۸۶**	**۹۷/۷۰**	**۹۷/۵۲**	**۹۷/۵۱**	**۹۷/۱۰**



تصویر برچسب‌گذاری شده



شکل ۳: عمل‌کرد الگوریتم‌های مختلف در بخش‌بندی نمونه‌ای از تصاویر پایگاه داده‌ی مرکز تصویربرداری پزشکی گلگشت تبریز. (الف): تصویر اصلی، (ب): خروجی MICO، (ج): خروجی GMM، (د): خروجی ARKFCM، (ذ): خروجی FCMPSO، (س): خروجی FCMWOA، (ش): خروجی FCMGWO، (م): خروجی SFCMEMBC، (ن): خروجی BCIFCMSNI، (و): خروجی FRFCM، (ی): خروجی RFCM، (ه): خروجی الگوریتم پیشنهادی.

جدول ۵: مقایسه‌ی عمل‌کرد 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
GK [۴۲]	۸۱/۴۸	۷۱/۳۵	۸۰/۲۴	۷۰/۶۸	۶۰/۰۱	۶۱/۳۵	۷۹/۰۳	۸۸/۱۶	۹۱/۰۵
MICO [۱۷]	۸۰/۴۱	۶۲/۵۱	۷۶/۲۲	۶۸/۶۹	۴۶/۱۶	۶۲/۶۳	۷۵/۷۱	۸۹/۶۹	۹۱/۶۲
GMM [۲۲]	۸۱/۱۸	۷۰/۲۷	۹۳/۸۵	۷۰/۶۲	۵۸/۲۶	۷۰/۷۷	۷۳/۳۲	۸۵/۱۳	۹۴/۴۵
ARKFCM [۲۰]	۸۳/۳۱	۷۱/۴۳	۷۰/۶۸	۷۵/۷۲	۶۰/۹۵	۵۹/۱۱	۸۱/۳۳	۹۱/۷۷	۹۱/۴۱
FCMPSO [۲۷]	۸۴/۱۴	۶۷/۸۹	۶۲/۷۴	۷۵/۲۷	۵۶/۰۱	۵۱/۱۵	۷۹/۷۴	۸۹/۰۵	۸۴/۳۴
FCMWOA [۲۸]	۷۲/۶۳	۳۵/۲۳	۳۹/۲۶	۶۱/۰۱	۳۷/۱۳	۳۸/۳۷	۴۹/۳۲	۶۹/۷۱	۶۵/۹۹
FCMGWO [۲۶]	۸۹/۲۲	۸۱/۷۵	۸۳/۱۸	**۸۲/۶۲**	۷۲/۳۵	۷۱/۰۴	**۹۰/۷۴**	۹۱/۳۵	۹۴/۱۸
SFCMEMBC [۲۳]	۷۶/۴۴	۷۳/۰۵	۷۴/۷۴	۷۳/۵۲	۶۲/۶۶	۵۹/۶۸	۶۹/۴۹	۷۹/۶۹	۷۹/۳۶
BCIFCMSNI [۳۴]	۷۸/۲۳	۷۲/۸۹	۷۶/۸۱	۷۴/۶۹	۶۱/۱۳	۶۰/۱۲	۷۰/۷۸	۸۱/۱۳	۷۰/۱۵
FRFCM [۴۵]	۸۸/۲۰	۸۱/۴۶	۸۱/۶۳	۸۱/۳۹	۷۰/۳۴	۷۰/۴۹	۸۶/۶۳	۹۰/۶۶	۹۱/۱۲
RFCM [۴۹]	۸۹/۹۷	۸۱/۳۶	۸۰/۰۵	۸۲/۳۹	۶۹/۴۰	۶۷/۱۴	۸۷/۲۹	۹۱/۳۱	۸۹/۵۲
IGK	**۹۰/۳۹**	**۸۲/۵۲**	**۸۴/۹۸**	۸۰/۶۸	**۷۳/۹۰**	**۷۲/۶۸**	۸۳/۲۲	**۹۲/۵۷**	**۹۵/۴۴**

الگوریتم FRFCM در بخش‌بندی بافت CSF از منظر تمامی معیارهای اندازه‌گیری نسبت به الگوریتم پیشنهادی عمل‌کرد ضعیفی دارد و این موضوع نشان می‌دهد که رویکرد به‌کارگیری فاصله‌ی اقلیدسی گزینه‌ی مناسبی برای خوشه‌های فشرده با اندازه‌ی کوچک نیست.

الگوریتم RFCM براساس هر سه معیار ارزیابی عمل‌کرد خوبی در بخش‌بندی WM و GM داشته، اما در شناسایی مرزهای ناحیه‌ی CSF عمل‌کرد مناسبی در مقایسه با الگوریتم IGK پیشنهادی ندارد. همان‌طوری که در شکل ۳(و، ی) نیز نشان داده شده است، الگوریتم‌های FRFCM و RFCM معمولاً به اشتباه پیکسل‌های مربوط به CSF در نواحی فشرده و کوچک به سایر کلاس‌ها برچسب می‌زند، اما الگوریتم پیشنهادی با به‌کارگیری فاصله‌ی ماهالانوبیس به‌جای فاصله‌ی اقلیدسی و همچنین اعمال رویکرد تئوری اطلاعات، بهترین عمل‌کرد را در بخش‌بندی CSF نسبت به سایر الگوریتم‌ها دارد.

۵- نتیجه‌گیری و ارائه‌ی پیشنهادها

رویکردهای مبتنی بر FCM از فاصله‌ی اقلیدسی در فرآیند خوشه‌بندی استفاده می‌کنند. این معیار از تغییرات فاصله‌ی نقاط داده در خوشه‌های مشابه و فشرده صرف‌نظر می‌کند. از طرف دیگر، وجود نویز و INU فرآیند خوشه‌بندی را تحت تأثیر قرار می‌دهد. برای حل چالش‌های ذکر شده، تابع هدف جدیدی براساس اندازه‌گیری معیار تشابه از طریق فاصله‌ی ماهالانوبیس در الگوریتم خوشه‌بند GK ارائه شد که نسبت به رویکردهای مبتنی بر FCM مقاوم به نویز و INU است. الگوریتم IGK پیشنهادی نیازی به محاسبه‌ی فاصله‌ی بین پیکسل‌ها درون همسایگی مکانی و خوشه‌بندی ندارد. در ابتدا، به‌عنوان یک مرحله‌ی پیش‌پردازش، جهت حفظ جزئیات بیشتر تصویر و همچنین حل چالش‌های مربوط به سرعت همگرایی، بازسازی مورفولوژکی به‌کار گرفته شد. در مرحله‌ی بعدی، جهت افزایش دقت فرآیند بخش‌بندی و استحکام الگوریتم پیشنهادی به نویز، تئوری اطلاعات به‌کار گرفته شد. با توجه به اینکه الگوریتم GK استاندارد نسبت به پارامتر فازی‌شدگی (q) حساس است، در مرحله‌ی بعدی تابع هزینه جدیدی براساس تئوری اطلاعات و آنتروپی معرفی شد. در مرحله‌ی نهایی با تخمین توابع عضویت، مراکز خوشه، ماتریس کواریانس و ضریب وزنی کاهش نویز (ξ_i) در یک فرآیند تکراری، بخش‌بندی چندگانه‌ی بافت‌های مغزی براساس تصاویر MRI مبتنی بر وزن T_1 مربوط به پایگاه داده‌های BrainWeb و مرکز تصویربرداری پزشکی گلگشت تبریز انجام گرفت. نتایج آزمایش نشان دادند که الگوریتم IGK پیشنهادی یک الگوریتم دقیق برای بخش‌بندی تصاویر MRI بوده که در مقایسه با رقبای خود نسبت به سطوح مختلف نویز و INU مقاوم است. همچنین، نتایج تأیید کردند که الگوریتم پیشنهادی عمل‌کرد مناسبی در تمامی مقطع‌ها

داشته و قادر به حفظ جزئیات بیشتر لبه‌های تصویر در فرآیند بخش‌بند است. عیب اصلی الگوریتم پیشنهادی این است که به پارامتر کنترل کننده‌ی انتقال از خوشه‌بندی نرم به خوشه‌بندی سخت (α) حساس است. پارامتر موردنظر در این مطالعه به‌صورت تجربی انتخاب شده است. برای حل این مشکل، به‌کارگیری الگوریتم‌های فراابتکاری جهت پیدا کردن مقدار بهینه‌ی α برای هر تصویر می‌تواند در آینده مطرح باشد.

مراجع

[1] S. Kollem, C. R. Prasad, J. Ajayan, V. Malathy, A. Subbarao, "Brain tumor MRI image segmentation using an optimized multi-kernel FCM method with a pre-processing stage," Multimedia Tools and Applications, vol. 82, no. 14, pp. 20741-20770, 2023.

[2] S. Alagarsamy, V. Govindaraj, A. Senthilkumar, "Automated brain tumor segmentation for MR brain images using artificial bee colony combined with interval type-II fuzzy technique," IEEE Transactions on Industrial Informatics, vol. 19, no. 11, pp. 11150-11159, 2023.

[3] C. Singh, S. K. Ranade, D. Kaur, A. Bala, "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.

[4] J. Lyu, X. Chen, S. A. AlQahtani, M. S. Hossain, "Multi-modality MRI fusion with patch complementary pre-training for internet of medical things-based smart healthcare," Information Fusion, vol. 107, pp. 102342, 2024.

[5] N. Aboubakr, M. Popova, J. L. Crowley, "Color-based fusion of mri modalities for brain tumor segmentation," In Proceedings of International Conference on Medical Imaging and Computer-Aided Diagnosis Medical Imaging and Computer-Aided Diagnosis, pp. 89-97, 2021.

[6] Y. Fei, G. Wei, S. Zongxi, "Medical image fusion based on feature extraction and sparse representation," International journal of biomedical imaging, vol. 1, pp. 3020461, 2017.

[7] M. Hassan, I. Murtza, A. Hira, S. Ali, S, K. Kifayat, "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.

[8] S. Natarajan, V. Govindaraj, Y. Zhang, P. R. Murugan, K. Balasubramanian, K. Kandasamy, K. Ejaz, "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.

[9] I. Khatri, D. Kumar, A. Gupta, A, "A noise robust kernel fuzzy clustering based on picture fuzzy sets and KL divergence measure for MRI image segmentation," Applied Intelligence, vol. 53, no. 13, pp. 16487-16518, 2023.

[10] E. H. Houssein, N. Abdalkarim, K. Hussain, E. Mohamed, E, "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.

[11] E. H. Houssein, M. M. Emam, A. A. Ali, A. A, "An efficient multilevel thresholding segmentation method for thermography breast cancer imaging based on improved chimp optimization algorithm," Expert Systems with Applications, vol. 185, pp. 115651, 2021.

[12] G. Ma, 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.

[13] T. Lang, T. Sauer, "Feature-Adaptive Interactive Thresholding of Large 3D Volumes," arXiv preprint arXiv:2210.06961, 2022.

[14] B. Dong, G. Weng, Q. Bu, Z. Zhu, J. Ni, "An active contour model based on shadow image and reflection edge for image segmentation," Expert Systems with Applications, vol. 238, pp. 122330, 2024.

[15] Y. Chen, L. Wu, G. Wang, H. He, G. Weng, H. Chen, H, "An active contour model for image segmentation using morphology and nonlinear Poisson's equation," Optik, vol. 287, pp. 170997, 2023.

[16] H. Zia, A. Niaz, K. N. Choi, K. N, "Active Contour Model for Image Segmentation," In Asia Conference on Advanced Robotics, Automation, and Control Engineering (ARACE), 2022.

[17] C. Li, J. C. Gore, C. Davatzikos, "Multiplicative intrinsic component optimization (MICO) for MRI bias field estimation and tissue segmentation," Magnetic resonance imaging, vol. 32, no. 7, pp. 913-923, 2014.

[18] P. D. Dunning, H. A. Kim, "Introducing the sequential linear programming level-set method for topology optimization," Structural and Multidisciplinary Optimization, vol. 51, pp. 631-643, 2015.

[19] S. K. Adhikari, J. K. Sing, D. K. Basu, M. Nasipuri, "Conditional spatial fuzzy C-means clustering algorithm for segmentation of MRI images," Applied soft computing, vol. 34, pp. 758-769, 2015.

[20] A. Elazab, C. Wang, F. Jia, J. Wu, G. Li, Q. Hu, "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] J. Song, Z. Zhang, Z, "A modified robust FCM model with spatial constraints for brain MR image segmentation," Information, vol. 10, no. 2, pp. 74, 2019.

[22] J. Qiao, X. Cai, Q. Xiao, Z. Chen, P. Kulkarni, C. Ferris, ... S. Sridhar, "Data on MRI brain lesion segmentation using K-means and Gaussian Mixture Model-Expectation Maximization," Data in brief, vol. 27, pp. 104628, 2019.

[23] R. Meena Prakash, R. Shantha Selva Kumari, "Spatial fuzzy C means and expectation maximization algorithms with bias correction for segmentation of MR brain images," Journal of medical systems, vol. 41, pp. 1-9, 2017.

[24] M. Singh, A. Verma, N. Sharma, "Multi-objective noise estimator for the applications of de-noising and segmentation of MRI data," Biomedical Signal Processing and Control, vol. 46, pp. 249-259, 2018.

[25] P. Ghosh, K. Mali, S. K. Das, "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.

[26] A. F. Jafargholkhanloo, M. Shamsi, "Cephalometry analysis of facial soft tissue based on two orthogonal views applicable for facial plastic surgeries," Multimedia Tools and Applications, vol. 82, no. 20, pp. 30643-30668, 2023.

[27] H. Verma, D. Verma, P. K. Tiwari, "A population-based hybrid FCM-PSO algorithm for clustering analysis and segmentation of brain image," Expert systems with applications, vol. 167, pp. 114121, 2021.

[28] S. Tongbram, B. A. Shimray, L. S. Singh, N. Dhanachandra, "A novel image segmentation approach using fcm and whale optimization algorithm," Journal of ambient intelligence and humanized computing, pp. 1-15, 2021.

[29] R. Bandyopadhyay, R. Kundu, D. Oliva, R. Sarkar, "Segmentation of brain MRI using an altruistic Harris Hawks' Optimization algorithm," Knowledge-Based Systems, vol. 232, pp. 107468, 2021.

[30] A. Kouhi, H. Seyedarabi, A. Aghagolzadeh, "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.

[31] M. Tavakoli-Zaniani, Z. Sedighi-Maman, M. H. F. Zarandi, "Segmentation of white matter, grey matter and cerebrospinal fluid from brain MR images using a modified FCM based on double estimation," Biomedical Signal Processing and Control, vol. 68, pp. 102615, 2021.

[32] D. Kumar, I. Khatri, A. Gupta, R. Gusain, "Kernel picture fuzzy clustering with spatial neighborhood information for MRI image segmentation," Soft Computing, vol. 26, no. 22, pp. 12717-12740, 2022.

[33] S. Vinurajkumar, S. Anandhavelu, "An Enhanced Fuzzy Segmentation Framework for extracting white matter from T1-weighted MR images," Biomedical Signal Processing and Control, vol. 71, pp. 103093, 2022.
[34] D. Kumar, R. K. Agrawal, P. Kumar, "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.
[35] R. Solanki, D. Kumar, "Probabilistic intuitionistic fuzzy c-means algorithm with spatial constraint for human brain MRI segmentation," Multimedia Tools and Applications, vol. 82, no. 22, pp. 33663-33692, 2023.
[36] P. Kumar, R. K. Agrawal, D. Kumar, "Fast and robust spatial fuzzy bounded k-plane clustering method for human brain MRI image segmentation," Applied Soft Computing, vol. 133, pp. 109939, 2023.
[37] S. Mohammadi, S. Ghaderi, K. Ghaderi, M. Mohammadi, M. H. Pourasl, "Automated segmentation of meningioma from contrast-enhanced T1-weighted MRI images in a case series using a marker-controlled watershed segmentation and fuzzy C-means clustering machine learning algorithm," International Journal of Surgery Case Reports, vol. 111, pp. 108818, 2023.
[38] J. C. Bezdek, R. Ehrlich, W. Full, "FCM: The fuzzy c-means clustering algorithm," Computers & geosciences, vol. 10, no. 2, pp. 191-203, 1984.
[39] R. Krishnapuram, 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.
[40] D. Dovžan, I. Škrjanc, "Recursive clustering based on a Gustafson–Kessel algorithm," Evolving systems, vol. 2, no. 1, pp. 15-24, 2011.
[41] R. Babuka, P. J. Van der Veen, U. Kaymak, "Improved covariance estimation for Gustafson-Kessel clustering," In IEEE World Congress on Computational Intelligence, vol. 2, pp. 1081-1085, 2022.
[42] D. E. Gustafson, W. C. Kessel, "Fuzzy clustering with a fuzzy covariance matrix," In IEEE conference on decision and control including the 17th symposium on adaptive processes, pp. 761-766, 1979.
[43] Z. Wang, Q. Song, Y. C. Soh, K. Sim, "An adaptive spatial information-theoretic fuzzy clustering algorithm for image segmentation," Computer Vision and Image Understanding, vol. 117, no. 10, pp. 1412-1420, 2013.
[44] L. Tao et al, "Adaptive morphological reconstruction for seeded image segmentation," IEEE Transactions on Image Processing, vol. 28, no. 11, pp. 5510-5523, 2019.
[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.
[46] V. Luc, "Morphological grayscale reconstruction in image analysis: applications and efficient algorithms," IEEE transactions on image processing, vol. 2, no. 2, pp. 176-201, 1993.
[47] http://www.bic.mni.mcgill.ca/brainweb/ (Brainweb Simulated Brain Database)
[48] A. F. Jafargholkhanloo, M. Shamsi, "Quantitative analysis of facial soft tissue using weighted cascade regression model applicable for facial plastic surgery," Signal Processing: Image Communication, vol. 121, pp. 117086, 2024.
[49] C. Wang, W. Pedrycz, Z. Li, M. Zhou, "Residual-driven fuzzy C-means clustering for image segmentation," IEEE/CAA Journal of Automatica Sinica, vol. 8, no. 4, pp. 876-889, 2020.
[50] R. Wang et al, "Medical image segmentation using deep learning: A survey," IET Image Process, vol. 16, no. 5, pp. 1243–1267, 2022.
[51] B. Billot et al, "SynthSeg: Segmentation of brain MRI scans of any contrast and resolution without retraining," Med. Image Anal, vol. 86, no. 102789, p. 102789, 2023.
[52] B. Billot et al, "Robust machine learning segmentation for large-scale analysis of heterogeneous clinical brain MRI datasets," Proc. Natl. Acad. Sci. U. S. A, vol. 120, no. 9, p. e2216399120, 2023.

پاورقی‌ها:

[1] X-ray
[2] Positron Emission Tomography
[3] Computed Tomography
[4] Magnetic Resonance Imaging
[5] White Matter
[6] Grey Matter
[7] Cerebrospinal Fluid
[8] Fluid-Attenuated Inversion Recovery
[9] Pathology
[10] Edema
[11] Intensity non-Uniformity
[12] Partial Volume Effect
[13] Intra-Observer and Inter-Observer
[14] Multiplicative Intrinsic Component Optimization
[15] Fuzzy c-means
[16] Conditional Spatial FCM
[17] Adaptive Regularized Kernel-based FCM
[18] Ischemic Stroke
[19] Gaussian Mixture Model
[20] Spatial FCM and Expectation Maximization with Bias Correction
[21] Multi-Objective Particle Swarm Optimization
[22] Chaotic Firefly Algorithm
[23] Whale Optimization Algorithm
[24] Grey Wolf Optimization
[25] Altruistic Harris Hawk Optimization
[26] Bias-Corrected Intuitionistic FCM with Spatial Neighborhood Information
[27] Probabilistic Intuitionistic FCM Base on Spatial Constraint
[28] Fuzzy Bounded K-Plane Clustering Based on Local Spatial Information
[29] Meningioma
[30] Improved Gustafson-Kessel
[31] Information Theory
[32] Morphological Reconstruction
[33] Golgasht Medical Imaging Centra
[34] Structure Element
[35] Fast Grey Value Reconstruction
[36] Closing Operation
[37] Opening Operation
[38] Convolutional Neural Network