

ارائه‌ی الگوریتم جدید مبتنی بر خوشه‌بند فازی جهت بخش‌بندی بافت‌های مغزی توام با تصحیح بایاس از روی تصاویر MRI

علی فهمی جعفرقلخانلو^{*}، موسی شمسی و مهدی بشیری باویل

چکیده

بخش‌بندی تصاویر MR گامی ضروری در برنامه‌ریزی جراحی و درمان است. غیریکنواختی شدت، شناخته شده تحت عنوان بایاس، یک آرتیفکت رایج در تصاویر MR بوده که باعث ایجاد چالش‌هایی در فرآیند بخش‌بندی بافت‌های مغزی می‌شود. این آرتیفکت به دلیل عواملی نظیر غیریکنواختی میدان مغناطیسی، حساسیت کوئل فرکانس رادیویی و آرتیفکت‌های اسکتر رخ داده که باعث ایجاد غیریکنواختی شدت داخل نواحی بافت همگن تصاویر مغزی می‌شود. جهت حل چالش مطرح شده، رویکرد جدید خوشه‌بند فازی مبتنی بر الگوریتم گستافسون-کسل ارائه می‌شود که با تخمین بایاس و کمینه کردن اثر نویز براساس تئوری اطلاعات نسبت به رویکردهای مبتنی بر الگوریتم فازی C- میانگین مقاوم به نویز و غیریکنواختی شدت است. در ابتدا مولفه‌ای تحت عنوان بایاس به تابع هزینه الگوریتم گستافسون-کسل اضافه می‌شود. در گام بعدی، جهت مقاوم بودن الگوریتم پیشنهادی به نویز، اطلاعات متقابل بین توزیع داده هر خوشه و داده‌ی خارج از خوشه بیشینه می‌شود. سرانجام، با به‌روزرسانی ماتریس کواریانس، ماتریس عضویت ضریب γ_i جهت حذف نمونه‌های نویزی، مولفه بایاس و مراکز خوشه فرآیند بخش‌بندی بافت‌های مغزی انجام می‌شود. نتایج آزمایش نشان می‌دهد که الگوریتم پیشنهادی در مقایسه با سایر روش‌های بخش‌بندی تصاویر MR تحت تغییرات غیریکنواختی شدت و الگوریتم‌های مبتنی بر فازی C- میانگین عملکرد بهتری در بخش‌بندی بافت‌های مختلف مغزی دارد.

کلید واژه‌ها

اصلاح بایاس، بخش‌بندی بافت‌های مغزی، تصویربرداری تشدید مغناطیسی، تئوری اطلاعات، خوشه‌بند گستافسون-کسل، غیریکنواختی شدت.

۱- مقدمه

تصویربرداری تشدید مغناطیسی (MRI) به دلیل توانایی در ارائه‌ی اطلاعات دقیق آناتومیکی، عملکرد غیرتهاجمی، نسبت سیگنال به نویز بالا، جداسازی بهتر نواحی بافت و همچنین ارائه‌ی تصاویر مقطعی با وضوح بالا جزء روش‌های پرکاربرد در تصویربرداری پزشکی است. بخش‌بندی تصاویر MR گامی ضروری در برنامه‌ریزی درمان و جراحی است. در کاربرد درمان، از الگوریتم‌های بخش‌بندی می‌توان به منظور ارزیابی رشد بافت‌های ناسالم نظیر تومور استفاده کرد. همچنین، در کاربردهای جراحی، الگوریتم‌های بخش‌بندی می‌توانند جهت مکان‌یابی بافت‌های مختلف نظیر ماده‌ی

این مقاله در فروردین‌ماه ۱۴۰۴ دریافت شد؛ در شهریورماه بازنگری و سپس پذیرفته گردید.

^۱ استادیار، گروه علوم مهندسی، دانشکده‌ی فناوری‌های نوین، دانشگاه محقق اردبیلی، نمین، ایران

رایانامه: a_fahmi@uma.ac.ir

^۲ استاد، گروه بیوالکترونیک، دانشکده‌ی مهندسی پزشکی، دانشگاه صنعتی سهند، تبریز، ایران

رایانامه: shamsi@sut.ac.ir

^۳ دانشجوی دکتری، گروه بیوالکترونیک، دانشکده‌ی مهندسی پزشکی، دانشگاه صنعتی سهند، تبریز، ایران

رایانامه: m_bashiri99@sut.ac.ir

نویسنده‌ی مسئول: علی فهمی جعفرقلخانلو

فرآیند بخش‌بندی بافت‌های مختلف مغزی می‌شوند که نیازمند اصلاح از تصاویر MRI هستند. Singh و همکاران [۸] جهت حل چالش‌های مربوط به نویز و مولفه‌ی بایاس، رویکرد مبتنی بر مشارکت اطلاعات مکانی و سطح خاکستری براساس ضریب فازی را ارائه کردند. یکی از چالش‌های اصلی الگوریتم FCM استاندارد در بخش‌بندی تصاویر MR این است که بین پیکسل‌های همسایه اصلاحی را در نظر نمی‌گیرد. Adhikari و همکاران [۹] روش FCM مکانی شرطی^{۱۱} (CSFCM) را جهت حل چالش مطرح شده ارائه کردند. Elazab و همکاران [۱۰] الگوریتم FCM مبتنی بر کرنل با تنظیم تطبیقی^{۱۲} (ARKFCM) را ارائه کردند. در این الگوریتم، کنترل و تنظیم تعادل بین خوشه‌بندی صاف و غیرصاف سخت بوده و از طرف دیگر این الگوریتم با مسئله‌ی بیش صاف‌شدگی در لبه‌ها و جزئیات تصویر مواجه است. Qiao و همکاران [۱۱] رویکرد مبتنی بر مدل مخلوط گوسین^{۱۳} (GMM) و خوشه‌بند K -میانگین را جهت بخش‌بندی ضایعه‌سکته مغزی از روی تصاویر MR مطرح کردند. به‌کارگیری الگوریتم‌های فراابتکاری یکی از محبوب‌ترین رویکردها جهت بخش‌بندی تصاویر پزشکی است. Verma و همکاران [۱۲] از بهینه‌سازی ازدحام ذرات^{۱۴} (PSO) و همچنین Tongbram و همکاران [۱۳] از الگوریتم بهینه‌ساز نهنگ^{۱۵} (WOA) جهت بهینه‌سازی مراکز خوشه الگوریتم FCM جهت بخش‌بندی بافت‌های مختلف مغزی از روی تصاویر MR استفاده کردند. Singh و همکاران [۱۴] رویکرد مبتنی بر FCM شهودی^{۱۶} (IFCM) و اطلاعات مکانی براساس فیلترگذاری تبدیل کسینوسی گسسته را جهت بخش‌بندی سریع تصاویر MR مغز انسان ارائه کردند. Solanki و Kumar [۱۵] رویکرد مبتنی بر الگوریتم FCM شهودی احتمالی (PIFCM) با محدودیت مکانی را جهت حل چالش‌های مربوط به توزیع نویز و عدم قطعیت بین مرزهای بافت نرم در تصاویر MR ارائه کردند. Kumar و همکاران [۱۶] خوشه‌بندی فازی با محدودیت صفحه K مبتنی بر اطلاعات مکانی محلی^{۱۷} (FBKPCS) را جهت بخش‌بندی تصاویر MR معرفی کردند.

معایب رویکردهای مطرح شده را می‌توان به صورت زیر خلاصه کرد:

الگوریتم MICO یک رویکرد مبتنی بر تنظیم سطح بوده که در آن تابع توقف لبه وابسته به اطلاعات گرادینان تصویر است. این فرآیند

خاکستری^۱ (GM)، ماده‌ی سفید^۲ (WM) و مایع مغزی-نخاعی^۳ (CSF) به‌کار گرفته شوند. غیریکنواختی شدت^۴ (INU) یک آرتیفکت رایج در تصاویر MR بوده که باعث ایجاد چالش‌هایی در ارزیابی تصاویر اخذ شده می‌شود. این آرتیفکت تحت عنوان بایاس نیز شناخته شده که در تصاویر MR به دلیل عواملی نظیر غیریکنواختی میدان مغناطیسی، حساسیت کوئل فرکانس رادیویی، ویژگی‌های بافت، عوامل مرتبط با بیمار و آرتیفکت‌های اسکنر رخ داده و باعث ایجاد غیریکنواختی شدت در داخل نواحی بافت همگن می‌شود. در این حالت، شدت سیگنال در کل تصویر MR غیریکنواخت شده و اعوجاج به وجود آمده باعث مبهم شدن جزئیات آناتومیکی شده که می‌تواند فرآیند بخش‌بندی بافت‌های مختلف مغزی را تحت تاثیر قرار دهد [۱،۲].

در سال‌های اخیر روش‌های مختلفی جهت رفع چالش‌های مربوط به بخش‌بندی تصاویر MR مغز انسان تحت نویز و تغییرات غیریکنواختی شدت ارائه شده است. Ahmed و همکاران [۳] عبارتی تحت عنوان میانگین همسایگی را به تابع هزینه خوشه‌بند فازی C -میانگین^۵ (FCM) اضافه کرده و براساس آن الگوریتم توسعه یافته‌ی FCM براساس اصلاح بایاس^۶ (BCFCM) را ارائه کردند. Ji و همکاران [۴] رویکرد مبتنی بر خوشه‌بند FCM امکانی اصلاح شده^۷ (MPFCM) را جهت تخمین مولفه‌ی بایاس و بخش‌بندی بافت‌های مختلف مغزی از روی تصاویر MR ارائه کردند. Li و همکاران [۵] رویکرد کمیته‌سازی انرژی مبتنی بر بهینه‌سازی مولفه‌ی درونی ضرب‌پذیر^۸ (MICO) را جهت تخمین غیریکنواختی شدت و بخش‌بندی بافت‌های مغزی طراحی کردند. در این روش، تصویر به دو مولفه ضرب شونده شامل تصویر واقعی (توصیف‌کننده ویژگی فیزیکی بافت تصویر) و مولفه غیریکنواختی شدت تجزیه می‌شود. MICO یک رویکرد مبتنی بر تنظیم سطح بوده که در آن از توابع پایه‌ای متعامد جهت تخمین غیریکنواختی شدت استفاده شده است. Kumari و Parakash [۶] رویکرد FCM مکانی مبتنی بر بهینه‌سازی امید ریاضی همراه با اصلاح بایاس^۹ (SFCMEMBC) را جهت بخش‌بندی بافت‌های مختلف مغزی ارائه کردند. Kumar و همکاران [۷] رویکرد FCM شهودی همراه با اصلاح بایاس و اطلاعات همسایگی مکانی^{۱۰} (BCIFCMSNI) را جهت بخش‌بندی بافت‌های مغزی مطرح کردند. آرتیفکت INU، نویز، و پیچیدگی‌های ساختاری باعث ایجاد چالش‌های مختلفی در

^{۱۱} Bias-Corrected Intuitionistic FCM with Spatial Neighborhood Information
^{۱۲} Conditional Spatial Fuzzy C-means
^{۱۳} Adaptive Regularized Kernel-based FCM
^{۱۴} Gaussian Mixture Model
^{۱۵} Particle Swarm Optimization
^{۱۶} Whale Optimization Algorithm
^{۱۷} Intuitionistic Fuzzy C-means
^{۱۸} Fuzzy Bounded K-Plane Clustering Based on Local Spatial Information

^۱ Grey Matter
^۲ White Matter
^۳ Cerebrospinal Fluid
^۴ Intensity non-Uniformity
^۵ Fuzzy C-means
^۶ Bias-Corrected Fuzzy C-means
^۷ Modified Probabilistic Fuzzy C-means
^۸ Multiplicative Intrinsic Component Optimization
^۹ Spatial FCM and Expectation Maximization with Bias Correction

مغزی را تحت تاثیر قرار می‌دهد. تابع هزینه جدید پیشنهادی با قابلیت جداسازی داده‌ها با توزیع غیرکروی، مولفه‌ی بایاس را تخمین زده و تصاویر MR را با دقت بالایی بخش‌بندی می‌کند.

عملکرد الگوریتم BCGKIT پیشنهادی با نه روش مبتنی بر خوشه‌بند فازی که جزء روش‌های قوی در بخش‌بندی تصاویر پزشکی بوده مقایسه شده است. نتایج کیفی و کمی نشان می‌دهند که الگوریتم پیشنهادی عملکرد خوبی در بخش‌بندی بافت‌های مختلف مغزی از روی تصاویر MR دارد.

ساختار کلی مقاله به این صورت سازمان‌دهی می‌شود که در بخش ۲ به مروری مختصر بر توصیف الگوریتم‌های FCM و GK پرداخته می‌شود. در بخش ۳ الگوریتم پیشنهادی ارائه خواهد شد. بخش ۴ نتایج الگوریتم پیشنهادی و مقایسه‌ی عملکرد آن با سایر الگوریتم‌ها را ارائه می‌دهد. سرانجام در بخش ۵، به نتیجه‌گیری و ارائه‌ی پیشنهادات پرداخته خواهد شد.

۲- توصیف الگوریتم‌های FCM و GK

الگوریتم FCM اولین بار توسط Bezdek [۱۷] براساس رویکرد به‌کارگیری ماتریس عضویت μ_{ij} ارائه شد. برای یک تصویر داده شده $I(x,y)$ با مقادیر خاکستری $Y_i \in R^d, i = 1, \dots, N$ تعداد پیکسل‌ها و d تعداد ویژگی‌ها برای هر پیکسل) و مراکز خوشه $C = \{C_1, C_2, \dots, C_K\}$ یک مقدار عضویت برای هر پیکسل i در Z امین خوشه $(j=1, 2, \dots, K)$ وجود دارد. تابع هزینه در الگوریتم FCM با میزان فازی شدگی $m (m > 1)$ براساس رابطه‌ی ۱ به‌صورت زیر تعریف می‌شود:

$$J_{FCM} = \sum_{i=1}^N \sum_{j=1}^K U_{ij}^m (Y_i - C_j)^2 \quad (1)$$

تابع عضویت و مراکز خوشه به‌صورت زیر به‌روزرسانی می‌شوند:

$$U_{ij}^{\tau+1} = \frac{1}{\sum_{j=1}^K \left(\frac{\|Y_i - C_j^\tau\|^2}{\|Y_i - C_j^{\tau-1}\|^2} \right)^{\frac{2}{m-1}}} \quad (2)$$

$$C_j^{\tau+1} = \frac{\sum_{i=1}^N ((U_{ij}^m)^\tau Y_i)}{\sum_{i=1}^N (U_{ij}^m)^\tau} \quad (3)$$

که در آن τ نشان دهنده‌ی اندیس تکرار فعلی است.

الگوریتم FCM خوشه‌ها را به‌صورت کروی فرض کرده و در صورت یکسان نبودن اندازه و ریخت خوشه‌ها عملکرد مناسبی نخواهد داشت [۱۹، ۱۸]. برای حل این مشکل، گستافسون و کسل [۲۰] مدل بهبود یافته از الگوریتم FCM را از طریق به‌کارگیری فاصله‌ی ماهالانوبیس به‌جای فاصله‌ی اقلیدسی جهت تشخیص

تنها لبه‌های تعریف شده از طریق گرادیان را بخش‌بندی می‌کند. عیب اصلی الگوریتم CSFCM این هست که درجه‌ی عدم قطعیت احتمالی در تصاویر واقعی MR را در نظر نمی‌گیرد. الگوریتم ARKFCM برای داده‌های غیرکروی مناسب نبوده و پیچیدگی محاسباتی بالایی نیز دارد. از معایب اصلی رویکردهای مبتنی بر مدل مخلوط نظیر GMM می‌توان به سرعت همگرایی پایین و حساسیت به مقداردهی اولیه اشاره کرد. در رویکرد SFCMEMBC، توزیع داده به‌صورت گوسین فرض شده که ممکن است برای بعضی از داده‌ها مناسب نباشد. عیب اصلی روش‌های FCMPSO و FCMWOA این است که زمان‌بر بوده و نیازمند تنظیم دقیق پارامترهای ثابت جهت تعدیل فازهای اکتشاف و استخراج است. عیب اصلی الگوریتم‌های BCIFCMSNI و PIFCMS این است که دقت فرآیند بخش‌بندی بافت‌های مختلف مغزی تحت تاثیر پارامترهای تنظیم است. چالش اصلی در الگوریتم FBKPCS تنظیم پارامترهای مرزی و مکانی است. جهت حل مشکلات مطرح شده، الگوریتم جدید خوشه‌بند فازی مبتنی بر روش گستافسون-کسل^۱ (GK) جهت اصلاح بایاس مبتنی بر تئوری اطلاعات^۲ (BCGKIT) ارائه می‌شود. نوآوری‌های الگوریتم پیشنهادی به‌صورت زیر خلاصه می‌شود:

- الگوریتم‌های مبتنی بر FCM (مانند ARKFCM، CSFCM، BCIFCMSNI) توزیع داده را براساس معیار فاصله‌ی اقلیدسی به‌صورت کروی در نظر می‌گیرند. این فرآیند باعث می‌شود که خوشه‌های کم‌حجم و فشرده (مانند کلاس CSF در تصاویر MR) به اشتباه به کلاس‌های دیگر برچسب زده شده و دقت بخش‌بندی داده‌ی مربوط به این کلاس‌ها کاهش پیدا کند. برای این منظور، الگوریتم GK به‌کار گرفته می‌شود که با فرض بیضوی بودن توزیع داده براساس معیار فاصله‌ی ماهالانوبیس عملکرد خوبی در تمییز خوشه‌های کم‌حجم و فشرده دارد.
- الگوریتم‌های مبتنی بر FCM در کنار اصلاح بایاس معمولاً به توزیع‌های مختلف نویز مقاوم نیستند. جهت افزایش دقت بخش‌بندی و بهبود عملکرد خوشه‌بندی رویکرد مبتنی بر تئوری اطلاعات به‌کار گرفته می‌شود. به‌کارگیری این رویکرد باعث می‌شود که الگوریتم BCGKIT پیشنهادی بتواند لبه‌ها را با جزئیات بیشتری در اثر فرآیند بخش‌بندی تحت شرایط مختلف نویز و غیریکنواختی شدت حفظ کند. در این فرآیند، اطلاعات متقابل^۳ بین توزیع داده هر خوشه و داده‌ی خارج از خوشه بیشینه می‌شود.
- مولفه‌ی بایاس مقادیر شدت پیکسل‌ها در تصاویر MR را تغییر داده و دقت فرآیند بخش‌بندی بافت‌های مختلف

^۳ Mutual Information

^۱ Gustafson-Kessel

^۲ Bias Correction using Gustafson-Kessel based on Information Theory

۳- الگوریتم پیشنهادی

ایده اصلی تمامی رویکردهای مبتنی بر FCM جهت تخمین و اصلاح مولفه‌ی بایاس از رابطه‌ی ۱۲ استنباط شده است. این رویکردها عموماً به دلیل فرض کروی بودن توزیع خوشه‌ها عملکرد مناسبی در بخش‌بندی نواحی کم‌حجم و فشرده مانند CSF ندارند. این امر باعث می‌شود که این رویکردها کارایی مناسبی در بخش‌بندی بافت‌های مختلف مغز از روی تصاویر MR تحت تغییرات غیریکنواختی شدت نداشته باشند. برای حل این چالش، از فاصله ماهالانویس به جای فاصله اقلیدسی همراه با مولفه‌ی بایاس جهت مدل‌سازی خوشه‌های بیضوی استفاده می‌شود. همچنین، جهت مقاوم کردن الگوریتم پیشنهادی به نویز، پارامتر γ_i نیز در نظر گرفته شده که از طریق تئوری اطلاعات تخمین زده می‌شود. در نتیجه، در الگوریتم پیشنهادی رابطه‌ی ۱۲ به صورت زیر اصلاح می‌شود:

$$J_{BCGKIT}(U, C, \beta) = \sum_{i=1}^N \sum_{j=1}^K \gamma_i \cdot U_{ij}^m \cdot (y_i - C_j - \beta_i)^T \cdot \sum_j \cdot (y_i - C_j - \beta_i) \quad (13)$$

رابطه‌ی ۱۳ را می‌توان به صورت یک مسئله‌ی بهینه‌سازی نامحدود بیان کرد که تابع هزینه زیر را کمینه می‌کند:

$$J_{BCGKIT}(U, C, \beta) = \sum_{i=1}^N \sum_{j=1}^K \gamma_i \cdot U_{ij}^m \cdot (y_i - C_j - \beta_i)^T \cdot \sum_j \cdot (y_i - C_j - \beta_i) - \sum_{i=1}^N \lambda_i \left(\sum_{j=1}^K U_{ij} - 1 \right) + \sum_{j=1}^K \alpha_j \cdot (\det(\Sigma_j) - \rho_j) \quad (14)$$

با صفر قرار دادن مشتق $J_{BCGKIT}(U, C, \beta)$ نسبت به ماتریس عضویت خواهیم داشت:

$$\frac{\partial J_{BCGKIT}}{\partial U_{ij}} = m \cdot \gamma_i \cdot U_{ij}^{m-1} \cdot (y_i - C_j - \beta_i)^T \cdot \sum_j \cdot (y_i - C_j - \beta_i) - \lambda_i = 0 \quad (15)$$

از طرف دیگر می‌دانیم که:

$$\sum_{j=1}^K U_{ij} = 1 \rightarrow (\lambda_i)^{\frac{1}{m-1}} \cdot \left(\frac{1}{\sum_{j=1}^K m \cdot \gamma_i \cdot D_{ij}} \right)^{\frac{1}{m-1}} = 1 \quad (16)$$

$$D_{ij} = (y_i - C_j - \beta_i)^T \cdot \sum_j \cdot (y_i - C_j - \beta_i) \quad (17)$$

با ترکیب روابط ۱۶ و ۱۷، ماتریس عضویت الگوریتم پیشنهادی در یک فرآیند تکراری به صورت زیر به روزرسانی می‌شود:

$$U_{ij} = \left(\frac{(y_i - C_r - \beta_i)^T \cdot \sum_r \cdot (y_i - C_r - \beta_i)}{\sum_{j=1}^K (y_i - C_j - \beta_i)^T \cdot \sum_j \cdot (y_i - C_j - \beta_i)} \right)^{1/m-1} \quad (18)$$

جهت به دست آوردن مراکز خوشه، از $J_{BCGKIT}(U, C, \beta)$ نسبت به C_j مشتق گرفته و برابر صفر قرار داده می‌شود. با حل معادله ۱۹، رابطه‌ی ۲۰ جهت به روزرسانی مراکز خوشه به کار گرفته می‌شود:

$$\frac{\partial J_{BCGKIT}}{\partial C_j} = -2 \sum_{i=1}^N \gamma_i \cdot U_{ij}^m \cdot (y_i - C_j - \beta_i) \cdot \sum_j = 0 \quad (19)$$

خوشه‌های ابر بیضوی شکل با اندازه و جهت‌گیری‌های متفاوت ارائه کردند. تابع هزینه‌ی این الگوریتم به صورت زیر بیان می‌شود:

$$J_{GK} = \sum_{i=1}^N \sum_{j=1}^K U_{ij}^m \cdot (Y_i - C_j)^T \cdot \sum_j \cdot (Y_i - C_j) \quad (4)$$

که در آن \sum_j یک ماتریس مثبت متقارن است. با به کارگیری روش حاصل ضرب لاگرانژ، رابطه‌ی ۴ را می‌توان به یک مسئله بهینه‌سازی نامحدود تبدیل کرد که در آن تابع هزینه زیر کمینه می‌شود:

$$J_{GK} = \sum_{i=1}^N \sum_{j=1}^K U_{ij}^m \cdot (Y_i - C_j)^T \cdot \sum_j \cdot (Y_i - C_j) - \sum_{i=1}^N \lambda_i \left(\sum_{j=1}^K U_{ij} - 1 \right) + \sum_{j=1}^K \alpha_j \cdot (\det(\Sigma_j) - \rho_j) \quad (5)$$

که در آن α_j نشان دهنده‌ی مجموعه ضرایب لاگرانژ، ρ_j نشان دهنده‌ی حجم خوشه بوده که معمولاً برای هر خوشه مقدار یک در نظر گرفته می‌شود. ماتریس عضویت، مراکز خوشه و ماتریس کواریانس در یک فرآیند تکراری به صورت زیر به روزرسانی می‌شوند:

$$U_{ij}^{\tau+1} = \left(\frac{(Y_i - C_r^\tau)^T \cdot \sum_r \cdot (Y_i - C_r^\tau)}{\sum_{j=1}^K (Y_i - C_j^\tau)^T \cdot \sum_j \cdot (Y_i - C_j^\tau)} \right)^{1/m-1} \quad (6)$$

$$C_j^{\tau+1} = \frac{\sum_{i=1}^N (U_{ij}^m)^\tau \cdot Y_i}{\sum_{i=1}^N (U_{ij}^m)^\tau} \quad (7)$$

$$F_i^{\tau+1} = \frac{\sum_{i=1}^N (U_{ij}^m)^\tau \cdot (Y_i - C_j^\tau)^T \cdot (Y_i - C_j^\tau)}{\sum_{i=1}^N (U_{ij}^m)^\tau} \quad (8)$$

$$\Sigma_j^{\tau+1} = \lambda_i \cdot (\det(F_i^\tau))^{\frac{1}{n}} \cdot (F_i^{-1})^\tau \quad (9)$$

مولفه‌ی بایاس در تصاویر MR به عنوان غیریکنواختی شدت به صورت مولفه‌ای ضرب شونده مدل می‌شود. تخمین بایاس و اصلاح آن باعث بهبود دقت فرآیند بخش‌بندی بافت‌های مخالف مغز می‌شود. مولفه‌ی بایاس به صورت زیر مدل می‌شود [۲۱]:

$$Y_i = X_i \cdot B_i, \forall i \in \{1, 2, \dots, N\} \quad (10)$$

که در آن Y_i i امین پیکسل مشاهده شده تصویر MR، X_i i امین پیکسل تصویر واقعی و B_i مولفه‌ی بایاس برای i امین پیکسل است. مولفه‌ی بایاس را می‌توان به صورت یک عبارت جمع شونده از طریق فضای لگاریتمی مدل کرد:

$$\begin{cases} \log(Y_i) = \log(X_i) + \beta_i, \forall i \in \{1, 2, \dots, N\} \\ y_i = \log(Y_i), \beta_i = \log(B_i) \end{cases} \quad (11)$$

ایده‌ی اصلی جهت تخمین مولفه‌ی بایاس توسط Ramathilagama و همکاران [۲۲] به صورت زیر مطرح شد:

$$J_{FCM}(U, C, \beta) = \sum_{i=1}^N \sum_{j=1}^K U_{ij}^m (y_i - C_j - \beta_i)^2 \quad (12)$$

رابطه‌ی ۱۲ خطای کل بین داده‌های بایاس دار و مدل بازسازی شده را از طریق وزن دهی بر اساس درجه‌ی عضویت اندازه‌گیری می‌کند. به عبارت دیگر، این رابطه با تخمین همزمان متغیرهای مراکز خوشه، ماتریس عضویت و مولفه‌ی بایاس و تحلیل تصویر در فضای لگاریتمی فرآیند بخش‌بندی تصویر MRI توام با تصحیح بایاس را امکان‌پذیر می‌سازد.

سرانجام، براساس رابطه‌ی ۲۹ و شرط محدود کننده، γ_i در یک فرآیند تکراری می‌تواند از طریق رابطه‌ی ۳۰ به‌روزرسانی شود:

$$\gamma_i = \frac{\exp\left(\sum_{j=1}^K U_{ij} \cdot \log\left(\frac{U_{ij}}{\sum_{i=1}^N \gamma_i \cdot U_{ij}}\right)\right)}{\sum_{i=1}^N \exp\left(\sum_{j=1}^K U_{ij} \cdot \log\left(\frac{U_{ij}}{\sum_{i=1}^N \gamma_i \cdot U_{ij}}\right)\right)} \quad (30)$$

با به‌کارگیری رابطه‌ی ۳۰، الگوریتم BCGKIT پیشنهادی نسبت به نویز مقاوم شده و تا زمان برقراری شرط زیر اجرا می‌شود:

$$\gamma_i^{\tau+1} = \frac{f_i^\tau}{\sum_{i=1}^N f_i^\tau} \quad (31)$$

$$f_i^\tau = \exp\left(\sum_{j=1}^K U_{ij} \cdot \log\left(\frac{U_{ij}^\tau}{\sum_{i=1}^N \gamma_i^\tau \cdot U_{ij}^\tau}\right)\right) \quad (32)$$

$$\ln\left(\sum_{i=1}^N \gamma_i^{\tau+1} \cdot f_i^\tau\right) - \ln(\max(f_i^\tau)) < \delta \quad (33)$$

که در آن δ یک مقدار کوچک بوده که معادل $1e-5$ است.

ترتیب مراحل الگوریتم BCGKIT پیشنهادی جهت بخش‌بندی بافت‌های مختلف مغز از روی تصاویر MR تحت غیریکنواختی شدت به‌صورت زیر است:

مرحله ۱: اخذ تصویر MR و انجام عملیات مورفولوژیکی جهت حذف حجمه به‌عنوان مرحله‌ی پیش‌پردازش.

مرحله ۲: تنظیم تعداد مراکز خوشه، مقداردهی اولیه برای ماتریس عضویت، مراکز خوشه از طریق الگوریتم K - میانگین و مولفه‌ی بایاس β_i (مقادیر کوچک تصادفی در محدوده‌ی $[0, 1]$). مقداردهی اولیه‌ی توزیع γ_i به‌صورت $\gamma_i^0 = 1/(W \times H)$ که در آن W و H اندازه‌ی تصویر است. تنظیم مقدار فازی شدگی m که معمولاً در رویکردهای خوشه‌بند فازی مقدار $m = 2$ در نظر گرفته می‌شود.

مرحله ۳: محاسبه‌ی ماتریس کواریانس از طریق روابط ۲۴ و ۲۵.

مرحله ۴: محاسبه‌ی ماتریس عضویت از طریق رابطه‌ی ۲۳.

مرحله ۵: محاسبه‌ی مقدار γ_i از طریق رابطه‌ی ۳۰ تا زمان برقراری شرایط موجود در روابط ۳۱ الی ۳۳.

مرحله ۶: تخمین مولفه‌ی بایاس از طریق رابطه‌ی ۲۲.

مرحله ۷: محاسبه‌ی مراکز خوشه از طریق رابطه‌ی ۲۰.

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

مرحله ۹: مقدار لگاریتم پیکسل‌ها از بایاس به‌دست آمده کسر شده و تابع نمایی مقدار پیکسل تصویر اصلاح شده و مولفه‌ی بایاس محاسبه می‌شود.

مرحله ۱۰: به‌کارگیری متغیرهای U_{ij} ، C_j و مولفه‌ی بایاس جهت انجام فرآیند بخش‌بندی.

۴- نتایج پیاده‌سازی

در این مطالعه، داده‌های شبیه‌سازی شده و واقعی جهت ارزیابی عملکرد الگوریتم پیشنهادی و مقایسه‌ی آن با سایر روش‌ها به‌کار گرفته می‌شوند. داده‌ی شبیه‌سازی شده تحت تأثیر مولفه بایاس با میانگین صفر و شدت ۵۰٪ مشابه مقاله [۷] قرار گرفته تا عملکرد

$$C_j = \frac{\sum_{i=1}^N \gamma_i \cdot U_{ij}^m \cdot (y_i - \beta_i)}{\sum_{i=1}^N \gamma_i \cdot U_{ij}^m} \quad (20)$$

جهت به‌دست آوردن مولفه‌ی بایاس، از $J_{BCGKIT}(U, C, \beta)$ نسبت به β مشتق گرفته و برابر صفر قرار داده می‌شود. با حل معادله ۲۱، رابطه‌ی ۲۲ جهت به‌روزرسانی مولفه‌ی بایاس به‌کار گرفته می‌شود:

$$\frac{\partial J_{BCGKIT}}{\partial \beta_i} = -2 \sum_{i=1}^N \gamma_i \cdot U_{ij}^m \cdot (y_i - C_j - \beta_i) \cdot \sum_j = 0 \quad (21)$$

$$\beta_i = y_i - \frac{\sum_{j=1}^K U_{ij}^m \cdot C_j \cdot \sum_j}{\sum_{j=1}^K U_{ij}^m \cdot \sum_j} \quad (22)$$

در گام بعدی جهت به‌روزرسانی ماتریس کواریانس، از J_{BCGKIT} نسبت به \sum_j مشتق گرفته و برابر صفر قرار داده می‌شود:

$$\frac{\partial J_{BCGKIT}}{\partial \sum_j} = \sum_{i=1}^N \gamma_i \cdot U_{ij}^m \cdot (y_i - C_j - \beta_i)^T \cdot (y_i - C_j - \beta_i) - \sum_{i=1}^N \left(\lambda_i \cdot \frac{\partial}{\partial \sum_j} (\det(\sum_j)) \right) \quad (23)$$

$$= \sum_{i=1}^N \gamma_i \cdot U_{ij}^m \cdot (y_i - C_j - \beta_i)^T \cdot (y_i - C_j - \beta_i) - \sum_{i=1}^N (\lambda_i \cdot U_{ij}^m \cdot \sum_j^{-1}) = 0$$

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

$$F_i = \frac{\sum_{i=1}^N \gamma_i \cdot U_{ij}^m \cdot (y_i - C_j - \beta_i)^T \cdot (y_i - C_j - \beta_i)}{\sum_{i=1}^N U_{ij}^m} \quad (24)$$

$$\sum_j = \lambda_i \cdot (\det(F_i))^{1/n} \cdot F_i^{-1} \quad (25)$$

در مرحله‌ی نهایی، اطلاعات متقابل بین توزیع ماتریس عضویت (U) و داده‌ی ورودی (y) جهت تخمین γ_i به‌کار گرفته می‌شود. اطلاعات متقابل براساس تئوری اطلاعات به‌صورت زیر بیان می‌شود [۲۳]:

$$F(y, U) = F(\mathcal{E}(y), \mathcal{E}(y|U)) = \sum_{i=1}^N \sum_{j=1}^K \mathcal{E}_i \mathcal{E}_{j|i} \log\left(\frac{\mathcal{E}_{j|i}}{\sum_{i=1}^N \mathcal{E}_i \mathcal{E}_{j|i}}\right) \quad (26)$$

که در آن \mathcal{E}_i احتمال γ_i پیکسل بوده و معادل با γ_i است. همچنین، $\mathcal{E}_{j|i}$ معادل با U_{ij} است. در نتیجه، رابطه‌ی ۲۶ می‌تواند به‌صورت زیر اصلاح شود:

$$F(y, U) = \sum_{i=1}^N \sum_{j=1}^K \gamma_i \cdot U_{ij} \cdot \log\left(\frac{U_{ij}}{\sum_{i=1}^N \gamma_i \cdot U_{ij}}\right) \quad (27)$$

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

$$J = \sum_{i=1}^N \sum_{j=1}^K \gamma_i \cdot U_{ij} \cdot \log\left(\frac{U_{ij}}{\sum_{i=1}^N \gamma_i \cdot U_{ij}}\right) + \lambda \left(\sum_{i=1}^N \gamma_i - 1\right) \quad (28)$$

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

$$-\log(\gamma_i) - 1 + \sum_{j=1}^K U_{ij} \cdot \log(U_{ij}) + \lambda = 0 \quad (29)$$

$$DS(I_1, I_2) = \frac{2|I_1 \cap I_2|}{|I_1| + |I_2|} \quad (34)$$

ضریب تشابه جاکارد جهت محاسبه‌ی میزان تشابه بین دو تصویر I_1 و I_2 به کار گرفته شده و به صورت زیر تعریف می‌شود:

$$JS(I_1, I_2) = \frac{|I_1 \cap I_2|}{|I_1 \cup I_2|} \quad (35)$$

ضریب تطبیق کانتور جهت محاسبه‌ی امتیاز تطبیق کانتور بین تصویر بخش‌بندی شده به صورت خودکار و تصویر بخش‌بندی شده به صورت دستی به کار گرفته می‌شود. این معیار در محدوده‌ی [۰, ۱] بوده و به صورت زیر تعریف می‌شود:

$$CS = \frac{2.P.R}{P+R} \quad (36)$$

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

۱-۴- تنظیم پارامتر الگوریتم‌ها

در پیاده‌سازی عددی الگوریتم‌ها، نیازمند تنظیم پارامترهای ثابت هستیم. در این مطالعه، سه پارامتر ضروری برای تمامی الگوریتم‌ها شامل میزان فازی‌شدگی، آستانه‌ی خطای کمینه و بیشینه‌ی تعداد تکرار به ترتیب به صورت $m=2$ ، $\varepsilon = 10^{-5}$ و 50 در نظر گرفته می‌شود. همچنین، تعداد مراکز خوشه برابر با 4 شامل کلاس‌های پس‌زمینه، WM ، GM و CSF است. عملکرد الگوریتم $BCGKIT$ پیشنهادی با الگوریتم‌های GMM ، $ARKFCM$ ، $FCMPSO$ ، $FCMWOA$ ، $SFCMEMBC$ ، $BCIFCMSNI$ ، $FBKPCS$ مورد مقایسه قرار می‌گیرد. دو الگوریتم سریع و مقاوم فازی C -میانگین 3 (FRFCM) [۲۵] و فازی C -میانگین باقی مانده (RFCM) [۲۶] جزء الگوریتم‌های قوی در زمینه‌ی بخش‌بندی تصویر هستند که براساس نتایج مطرح شده نسبت به انواع نوین مقاوم هستند. در نتیجه، جهت ارزیابی بهتر، عملکرد الگوریتم پیشنهادی با این دو الگوریتم نیز مورد مقایسه قرار می‌گیرد. در $FCMPSO$ ، براساس پارامترهای گزارش شده در [۱۲]، اندازه‌ی جمعیت (n)، وزن اینرسی (ω)، ضریب شناختی (c_1) و ضریب اجتماعی (c_2) به ترتیب برابر 60 ، 1 ، 2 و 2 تنظیم شده است. در الگوریتم $FCMWOA$ ، اندازه‌ی جمعیت برابر 12 در نظر گرفته شده است. به جز سه پارامتر ضروری ذکر شده و تعداد مراکز خوشه، هیچ پارامتر ثابت دیگری برای الگوریتم $ARKFCM$ مطرح نیست. در $BCIFCMSNI$ براساس پارامترهای گزارش شده در [۷]، پارامتر خشی کننده‌ی سوگنو، پارامتر تنظیم مکانی و اندازه‌ی همسایگی به ترتیب برابر با 1.7 ، $1/5$ و 3 در نظر گرفته شده است. در $FRFCM$ ، پارامتر المان ساختاری 0 (SE) برای رویکرد بازسازی مورفولوژیکی 1 (MR) به صورت یک مربع در اندازه‌ی 3×3 در نظر گرفته شده است. در

الگوریتم در حضور غیریکنواختی شدت بررسی شود. داده‌های واقعی شامل مرکز تصویربرداری پزشکی گلگشت تبریز^۱ (GMICT) و OASIS^۲ [۲۳] بوده که هیچ بایاس مصنوعی به آن‌ها اضافه نشده است. در این داده‌ها، میزان غیر یکنواختی شدت طبیعی و حداقل بوده و الگوریتم پیشنهادی در شرایط فقدان بایاس، تخمین آن را صفر و در صورت وجود مقدار حداقل، برآورد حداقلی ارائه می‌دهد. پایگاه داده‌ی GMICT شامل ۱۰ بیمار با تحلیل رونده‌ی عصبی بوده که با استفاده از یک اسکنر 1.5 TOSHIBA Vantage Tesla جمع‌آوری شده است. اسکن MRI با روش‌های استاندارد انجام شده است. در این فرآیند، جهت اخذ تصویر T_1 از زمان تکرار 540 میلی‌ثانیه، زمان اکو 15 میلی‌ثانیه، زاویه‌ی چرخش 70 درجه، میدان دید 230 در 230 میلی‌متر، تعداد برش 18 و ضخامت برش 6 میلی‌متر استفاده شده است. همچنین، جهت اخذ تصویر T_2 -FLAIR، زمان تکرار 10000 میلی‌ثانیه، زمان اکو 100 میلی‌ثانیه، زمان برگردان 2500 میلی‌ثانیه، زاویه‌ی چرخش 90 درجه، میدان دید 230 در 230 میلی‌متر، تعداد برش 20 ، اندازه‌ی وکسل $0.9/0.9$ میلی‌متر و ضخامت برش 6 میلی‌متر به کار گرفته شده‌اند. در این مطالعه از تصاویر T_1 و T_2 -FLAIR با اندازه‌های وکسل $(0.45/0.45)$ ، $(0.9/0.9)$ و $(6.0/6.0)$ میلی‌متر استفاده شده است. تمامی تصاویر پایگاه داده توسط متخصص نورولوژیست برجسب‌گذاری شده‌اند. این پژوهش در کمیته اخلاق دانشگاه علوم پزشکی تبریز تصویب شد و رضایت نامه‌ای از همه شرکت کنندگان دریافت شد. پایگاه داده‌ی OASIS شامل مجموعه تصاویر مقطعی از 16 فرد سالم و مبتلا به بیماری آلزایمر خفیف یا متوسط در محدوده‌ی سنی 18 الی 96 سال است. همچنین، تمامی شرکت کنندگان راست دست هستند. برای هر فرد 3 یا 4 اسکن MRI مبتنی بر وزن T_1 به دست آمده است. پایگاه داده شامل تصاویر برجسب‌گذاری شده نیز است. در این مطالعه، از تصاویر 10 فرد به صورت تصادفی در برش‌های 80 الی 130 استفاده شده است. باتوجه به اینکه در بخش‌بندی انواع بافت‌های مغزی به دنبال شناسایی پیکسل‌های WM ، GM و CSF هستیم. در هر دو پایگاه داده‌ی MRI تعداد مراکز خوشه به صورت دستی برابر 4 در نظر گرفته می‌شود که یکی از مراکز خوشه برای پیکسل‌های مربوط به پس‌زمینه است. به منظور ارزیابی عملکرد تمامی الگوریتم‌ها در فرآیند بخش‌بندی تصاویر شبیه‌سازی شده و واقعی، سه معیار تشابه دایس (DS)، جاکارد (JS) و تطبیق کانتور (CS) [۲۴] به کار گرفته می‌شوند. ضریب تشابه دایس جهت اندازه‌گیری درجه‌ی هم‌پوشانی بین دو تصویر بخش‌بندی شده به صورت خودکار (I_1) و بخش‌بندی شده به صورت دستی (I_2) به کار گرفته می‌شود. این معیار به صورت زیر تعریف می‌شود:

^۴ Residual Fuzzy C-means

^۵ Structure Element


^۶ Morphological Reconstruction

^۱ Golghasht Medical Imaging Center, Tabriz

^۲ Open Access Series of Imaging Studies

^۳ Fast and Robust Fuzzy C-means

عملکرد بهتری دارد. در این فرآیند الگوریتم BCIFCMSNI در تخمین مولفه‌ی بایاس تحت نویز گوسین کارایی مناسبی نداشته است. از این نتیجه می‌توان این موضوع را استنباط کرد که عموماً رویکردهای مبتنی بر FCM به دلیل کروی فرض کردن ریخت خوشه‌ها، کارایی مناسبی در تخمین مولفه‌ی بایاس و بخش‌بندی داده در شرایط مختلف ندارند. همچنین، رویکرد مبتنی بر SFCMEMBC نیز در تخمین مولفه‌ی بایاس و بخش‌بندی داده‌ی دو کلاسه عملکرد مناسبی نداشته است. رویکردهای مبتنی بر مدل مخلوط عموماً با فرض توزیع گوسین داده فرآیند بخش‌بندی را انجام می‌دهند. این در حالی است که توزیع گوسین گزینه‌ی مناسبی برای داده‌های با شرایط پیچیده نیست. در بخش‌بندی تصویر شبیه‌سازی شده تحت مولفه‌ی بایاس و نویزهای پواسون و اسپکل دو الگوریتم BCIFCMSNI و BCGKIT پیشنهادی بهترین کارایی را نسبت به سایر الگوریتم‌های مقایسه شده دارند.




شکل ۲: عملکرد الگوریتم‌های مختلف در بخش‌بندی تصویر شبیه‌سازی شده تحت مولفه‌ی بایاس و نویز گوسین. (الف): تصویر شبیه‌سازی شده همراه با مولفه بایاس، (ب): تصویر آغشته به نویز گوسین، (ج): خروجی الگوریتم GMM، (د): خروجی الگوریتم ARKFCM، (ه): خروجی الگوریتم FCMPPO، (و): خروجی الگوریتم FCMWOA، (ز): خروجی الگوریتم SFCMEMBC، (ح): خروجی الگوریتم BCIFCMSNI، (ط): خروجی الگوریتم FBKPCS، (ی): خروجی الگوریتم FRFCM، (ک): خروجی الگوریتم RFCM، (ل): خروجی الگوریتم BCGKIT پیشنهادی.

در تصویربرداری MR، داده‌ها در ابتدا در فضای K که نمایانگر حجم بافت‌ها بوده ثبت می‌شود. به دلیل مختلط بودن این داده‌ها، نویز در فضای K در هر دو بخش حقیقی و موهومی به صورت گوسین با میانگین صفر و واریانس یکسان مدل می‌شود. جهت بازسازی تصویر، مقدار اندازه‌ی تصویر از طریق تبدیل غیرخطی بر روی بخش‌های حقیقی و موهومی به‌کار گرفته می‌شود. در اثر این فرآیند، توزیع نویز گوسین به توزیع نویز رایسین^۱ با واریانس یکسان

RFCM، براساس مقادیر گزارش شده در [۲۶]، به‌منظور کنترل نرخ کاهش ماتریس وزنی، پارامتر ξ به صورت $\xi=0.0008$ فرض شده است. همچنین، در این الگوریتم، سطوح نویز براساس انحراف معیار تصویر ورودی در نظر گرفته شده است. در الگوریتم FBKPCS دو پارامتر کلیدی تحت عنوان مرز و پارامتر مکانی وجود دارد که براساس مقادیر گزارش شده در [۱۶] به ترتیب $0/5$ و $0/3$ در نظر گرفته شده‌اند.

۲-۴- نتایج پیاده‌سازی بر روی تصویر شبیه‌سازی شده


برای نشان دادن عملکرد الگوریتم پیشنهادی در بخش‌بندی و تخمین مولفه‌ی بایاس، از تصویر شبیه‌سازی شده دو کلاسه همراه با مولفه‌ی بایاس جمع‌شونده با میانگین صفر استفاده شده است. نتایج کیفی الگوریتم پیشنهادی در شکل ۱ نشان داده شده است. ناحیه مستطیلی مشخص شده در شکل ۱ (الف) بیشترین تغییرات غیریکنواختی شدت را نسبت به سایر نواحی دارد. برای ارزیابی بهتر کارایی الگوریتم پیشنهادی، همان طوری که در شکل ۱ (ب) نیز نشان داده شده است، یک نویز گوسین با میانگین صفر و واریانس $0/1$ به تصویر همراه با مولفه‌ی بایاس اضافه شده است. نتیجه کیفی نشان می‌دهد که الگوریتم پیشنهادی توانسته است مولفه‌ی بایاس (شکل ۱ (ج)) را با دقت بالایی تخمین بزند. همچنین، مقایسه‌ی کیفی عملکرد الگوریتم پیشنهادی با سایر رویکردهای مبتنی بر FCM در بخش‌بندی تصویر شبیه‌سازی شده تحت مولفه‌ی بایاس و نویزهای گوسین، پواسون و اسپکل به ترتیب در شکل‌های ۲ الی ۴ نشان داده شده است.



شکل ۱: نمایی از فرآیند تخمین مولفه‌ی بایاس با استفاده از الگوریتم پیشنهادی. (الف): تصویر اصلی همراه با مولفه‌ی بایاس (ناحیه قرمز رنگ نشان دهنده بیشترین تغییرات غیریکنواختی شدت است)، (ب): تصویر آغشته به نویز گوسین، (ج): خروجی تخمین مولفه‌ی بایاس، (د): خروجی تصویر بخش‌بندی شده با استفاده از الگوریتم پیشنهادی.

نتایج کیفی نشان دهنده کارایی بهتر الگوریتم پیشنهادی نسبت به سایر رویکردهای مبتنی بر FCM تحت تغییرات غیریکنواختی شدت و انواع نویز است. همچنین، نتایج کمی الگوریتم‌های مختلف در بخش‌بندی تصویر شبیه‌سازی شده تحت شرایط ذکر شده در جدول (۱) آورده شده است. اعداد گزارش شده برای تمامی الگوریتم‌ها نتیجه‌ی میانگین ۵۰ بار تکرار است. میانگین و واریانس نویز اسپکل به ترتیب برابر با 0 و $0/05$ در نظر گرفته شده است. در بخش‌بندی تصویر شبیه‌سازی شده تحت مولفه‌ی بایاس و نویز گوسین، الگوریتم پیشنهادی با اختلاف بیشتری نسبت به سایر الگوریتم‌ها

انواع نویز مقاوم نیستند. رویکردهای مبتنی بر کرنل نظیر ARKFCM در جزئیات لبه‌های تصویر تحت مولفه‌ی بایاس موفق نیستند. روش‌های مبتنی بر خوشه‌بندی K -صفحه نظیر FBKPCS بر اساس اتصال اولیه‌ی صفحه با مرکز در بخش‌بندی انواع مختلف تصاویر تحت شرایط مختلف نویز عملکرد خوبی دارند، اما در مقابل تغییرات غیریکنواختی شدت یا مولفه‌ی بایاس مقاوم نیستند. الگوریتم FRFCM بر اساس نتایج گزارش شده در [۲۵] یک الگوریتم سریع و مقاوم در مقابل نویزهای مختلف بوده ولی به دلیل ماهیت فرض‌کروی بودن ریخت خوشه‌ها در رویکردهای مبتنی بر FCM عملکرد مناسبی در بخش‌بندی تصاویر تحت تغییرات غیریکنواختی شدت ندارد. در الگوریتم RFCM، از طریق عبارت تنظیم، مقاوم بودن الگوریتم به نویزهای مختلف تضمین می‌شود. عیب اصلی الگوریتم RFCM این است که برای تخمین هر نویز باید عبارت تنظیم مربوط به توزیع آن نویز در نظر گرفته شود. از طرف دیگر، وجود اعوجاجی تحت عنوان غیریکنواختی شدت باعث پیچیده شدن عبارت تنظیم می‌شود. در مقابل الگوریتم پیشنهادی نیازمند عبارت تنظیم برای نویزهای مختلف نبوده و بر اساس تئوری اطلاعات و در نظر گرفتن مولفه‌ی بایاس در تابع هزینه‌ای با فرض بیضوی بودن ریخت خوشه‌ها مقاوم در برابر تغییرات غیریکنواختی شدت و نویزهای مختلف است.




شکل ۴: عملکرد الگوریتم‌های مختلف در بخش‌بندی تصویر شبیه‌سازی شده تحت مولفه‌ی بایاس و نویز اسپکل. (الف): تصویر شبیه‌سازی شده همراه با مولفه بایاس، (ب): تصویر آغشته به نویز اسپکل، (ج): خروجی الگوریتم GMM، (د): خروجی الگوریتم ARKFCM، (ه): خروجی الگوریتم FCMPWOA، (و): خروجی الگوریتم FCMPWOA، (ز): خروجی الگوریتم SFCMEMBC، (ح): خروجی الگوریتم FBKPCS، (ط): خروجی الگوریتم BCIFCMSNI، (ک): خروجی الگوریتم FRFCM، (ل): خروجی الگوریتم BCGKIT پیشنهادی.

در کل تصویر تبدیل می‌شود. تابع چگالی احتمال برای نویز رایسین به صورت زیر مدل می‌شود [۲۷]:

$$p(I; A, \sigma) = \frac{I}{\sigma^2} \exp\left(-\frac{I^2 + A^2}{2\sigma^2}\right) I_0\left(\frac{AI}{\sigma^2}\right) \quad (37)$$

که در آن I ، A ، σ و I_0 به ترتیب نشان دهنده‌ی شدت تصویر مشاهده شده، شدت سیگنال واقعی بدون نویز، انحراف معیار نویز و تابع بسط اصلاح شده از نوع اول و مرتبه صفر است. با توجه به عملکرد خوب الگوریتم پیشنهادی در حضور نویزهای گوسین، پواسون و اسپکل، در ادامه به بررسی عملکرد آن در حضور نویز رایسین می‌پردازیم. نتایج کیفی الگوریتم پیشنهادی برای نویز رایسین با مقادیر مختلف انحراف معیار در شکل ۵ نشان داده شده است. عملکرد بخش‌بندی الگوریتم پیشنهادی برای تمام معیارهای JS ، DS و CS در حضور نویز رایسین با مقادیر $\sigma = 5$ و $\sigma = 10$ (شکل ۱ الف، ب) برابر ۱۰۰٪ است. همچنین، این مقادیر در حالت $\sigma = 25$ به ترتیب ۹۹/۵۹٪، ۹۹/۱۸٪ و ۸۵/۴۲٪ است.



شکل ۵: عملکرد الگوریتم‌های مختلف در بخش‌بندی تصویر شبیه‌سازی شده تحت مولفه‌ی بایاس و نویز پواسون. (الف): تصویر شبیه‌سازی شده همراه با مولفه بایاس، (ب): تصویر آغشته به نویز پواسون، (ج): خروجی الگوریتم GMM، (د): خروجی الگوریتم ARKFCM، (ه): خروجی الگوریتم FCMPWOA، (و): خروجی الگوریتم FCMPWOA، (ز): خروجی الگوریتم SFCMEMBC، (ح): خروجی الگوریتم FBKPCS، (ط): خروجی الگوریتم BCIFCMSNI، (ک): خروجی الگوریتم FRFCM، (ل): خروجی الگوریتم BCGKIT پیشنهادی.

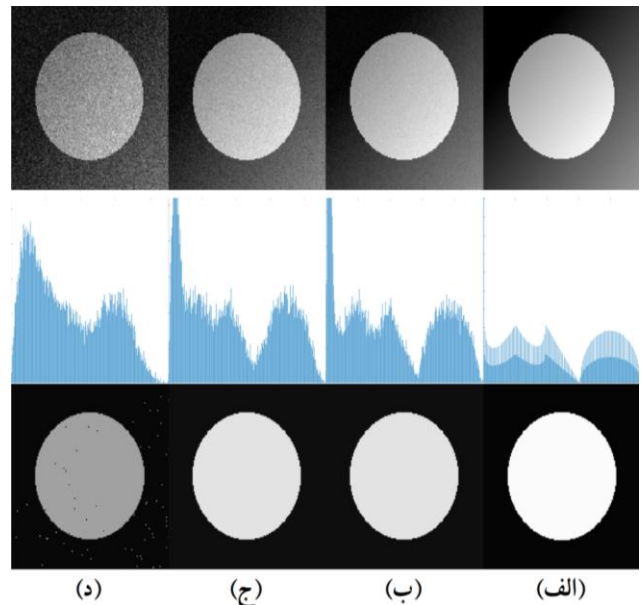
به عنوان یک نتیجه‌گیری کلی بر اساس نتایج الگوریتم‌های مختلف در بخش‌بندی تصویر دو کلاسه شبیه‌سازی شده تحت مولفه‌ی بایاس و انواع نویز می‌توان چنین بیان کرد که رویکردهای مبتنی بر الگوریتم‌های فراابتکاری در بخش‌بندی تصویر تحت غیریکنواختی شدت عملکرد مناسبی نداشته و باید مولفه‌ی بایاس نیز در تابع هزینه در نظر گرفته شود. همچنین، این رویکردها در برابر

جدول ۱: مقایسه‌ی کارایی الگوریتم BCGKIT پیشنهادی با سایر روش‌ها در بخش‌بندی تصویر شبیه‌سازی شده تحت مولفه‌ی بایاس و نویزهای مختلف.

معیار روش	نویز گوسین			نویز پواسون			نویز اسپیکل		
	DS (%) ↑	JS (%) ↑	CS (%) ↑	DS (%) ↑	JS (%) ↑	CS (%) ↑	DS (%) ↑	JS (%) ↑	CS (%) ↑
GMM [۱۱]	۹۲/۶۱	۸۶/۲۴	۳۱/۵۰	۹۸/۴۶	۹۶/۹۶	۶۳/۱۹	۷۹/۱۹	۶۵/۵۵	۲۱/۳۶
ARKFCM [۱۰]	۹۰/۳۸	۸۲/۴۶	۳۹/۵۱	۹۴/۸۹	۹۰/۲۷	۶۲/۲۴	۹۳/۹۵	۸۸/۵۹	۴۶/۴۷
FCMPSO [۱۲]	۹۰/۰۳	۸۱/۸۷	۲۷/۸۷	۹۱/۳۲	۸۴/۰۳	۳۷/۶۴	۸۹/۲۹	۸۰/۶۵	۲۴/۸۴
FCMWOA [۱۳]	۹۰/۹۹	۸۲/۸۰	۳۰/۸۳	۹۱/۱۴	۸۳/۷۲	۳۷/۹۶	۸۹/۶۱	۸۱/۱۸	۲۴/۴۶
SFCMEMBC [۶]	۸۹/۴۲	۸۳/۲۳	۵۵/۶۷	۹۴/۸۶	۹۰/۴۶	۵۰/۳۶	۹۴/۱۶	۸۸/۶۱	۳۷/۳۵
BCIFCMSNI [۷]	۹۲/۳۵	۸۹/۴۶	۵۸/۳۲	۹۹/۹۵	۹۹/۹۳	۹۹/۹۱	۹۸/۳۲	۹۶/۷۰	۷۲/۹۲
FBKPCS [۱۶]	۹۰/۰۴	۸۱/۸۸	۲۹/۰۹	۹۱/۷۸	۸۴/۸۱	۴۲/۷۴	۹۰/۱۳	۸۲/۰۳	۲۷/۷۷
FRFCM [۲۵]	۹۱/۱۰	۸۳/۶۶	۵۲/۲۳	۹۱/۶۲	۸۴/۵۳	۶۸/۸۰	۹۰/۹۷	۸۳/۴۴	۴۵/۸۰
RFCM [۲۶]	۷۸/۶۸	۶۴/۸۶	۵۰/۱۳	۶۹/۵۹	۵۳/۳۶	۳۰/۷۸	۷۳/۰۵	۵۷/۵۴	۳۸/۱۳
BCGKIT	۹۹/۶۸	۹۹/۳۵	۸۸/۹۲	۱۰۰	۱۰۰	۱۰۰	۹۷/۳۸	۹۴/۸۹	۶۶/۹۷

الگوریتم BCGKIT پیشنهادی رویکرد مناسبی برای بخش‌بندی خوشه‌های کم‌حجم و فشرده است.

بر اساس نتایج جدول (۲)، رویکردهای مبتنی بر بهینه‌سازی خوشه‌بند FCM با استفاده از الگوریتم‌های فراابتکاری (FCMPSO و FCMWOA) نسبت به سایر الگوریتم‌ها عملکرد ضعیفی را در بخش‌بندی بافت‌های مختلف مغزی دارند. دلایل اصلی این امر را می‌توان به‌طور خلاصه در دو قسمت بیان کرد. برخی از الگوریتم‌های فراابتکاری مبتنی بر جمعیت مانند PSO وابسته به تعدادی مقادیر ثابت جهت تعدیل فازهای استخراج و اکتشاف هستند. عموماً این پارامترها نیازمند تنظیم شدن برای پایگاه داده‌های مختلف هستند. همچنین، ماهیت کروی فرض کردن ریخت خوشه‌ها در الگوریتم FCM باعث می‌شود که عملکرد مناسبی در نواحی فشرده نداشته باشند. همان‌طوری که در شکل ۶ (ه، و) نیز نشان داده شده است، بافت‌های GM و CSF به اشتباه به سایر کلاس‌ها برچسب زده شده‌اند. بر اساس نتایج به‌دست آمده، الگوریتم‌های SFCMEMBC و BCIFCMSNI عملکرد مشابهی داشته و همان‌طوری که در شکل ۶ (ز، ح) نشان داده شده است در برخی از موارد بافت WM را به اشتباه به‌عنوان بافت GM در نظر می‌گیرند. الگوریتم‌های FBKPCS و BCGKIT پیشنهادی بهترین کارایی را در بخش‌بندی بافت‌های مختلف مغزی دارند. در هر سه معیار ارزیابی الگوریتم پیشنهادی نسبت به الگوریتم FBKPCS توانسته دقت بخش‌بندی را در حدود ۲٪ بهبود بخشد. بین این دو الگوریتم چندین تفاوت اساسی وجود دارد. (۱) سرعت همگرایی الگوریتم FBKPCS در مقایسه با الگوریتم پیشنهادی آهسته‌تر است. (۲) الگوریتم FBKPCS نیازمند تنظیم پارامترهای ثابت بوده، درحالی که در الگوریتم پیشنهادی پارامتر تنظیمی وجود ندارد. (۳) الگوریتم پیشنهادی پیچیدگی محاسباتی کمتری نسبت به الگوریتم FBKPCS دارد. (۴) در اثر وجود بیشتر مولفه‌ی بایاس و انواع مختلف نویز، الگوریتم FBKPCS عملکرد مناسبی نخواهد داشت. در تمامی معیارهای ارزیابی، الگوریتم‌های FRFCM و RFCM عملکرد ضعیفتری در مقایسه با الگوریتم پیشنهادی دارند. این موضوع نشان می‌دهد که



شکل ۵: نمایی از فرآیند بخش‌بندی تصویر تحت مولفه بایاس و نویز رایسین با استفاده از الگوریتم BCGKIT پیشنهادی. (الف): تصویر دارای بایاس به همراه توزیع هیستوگرام و تصویر مرجع، (ب): تصویر دارای بایاس آغشته به نویز با $\sigma = 5$ ، (ج): تصویر دارای بایاس آغشته به نویز با $\sigma = 10$ ، (د): تصویر دارای بایاس آغشته به نویز با $\sigma = 25$.

۳-۴- نتایج پیاده‌سازی بر روی پایگاه داده‌ی GMICT

مقایسه‌ی کیفی عملکرد الگوریتم پیشنهادی با سایر الگوریتم‌های مبتنی بر FCM در بخش‌بندی بافت‌های مختلف مغزی بر روی یک نمونه از تصویر پایگاه داده‌ی GMICT در شکل ۶ نشان داده شده است. همچنین، مقایسه‌ی کمی الگوریتم‌های مختلف در بخش‌بندی تصاویر پایگاه داده‌ی GMICT در جدول (۲) آورده شده است. نتایج نشان می‌دهد که الگوریتم پیشنهادی در تمامی معیارهای ارزیابی شده نسبت به سایر رویکردهای مبتنی بر FCM مقایسه شده بالاترین مقدار را دارد. این موضوع نشان دهنده‌ی عملکرد مناسب الگوریتم پیشنهادی در بخش‌بندی بافت‌های مختلف مغز از روی تصاویر MR تحت تغییرات غیریکناختی شدت است. بالا بودن شاخص‌های ارزیابی در بخش‌بندی بافت CSF مغز نشان می‌دهد که


جدول ۲: مقایسه‌ی کارایی الگوریتم BCGKIT پیشنهادی با سایر روش‌ها در بخش‌بندی تصاویر پایگاه داده‌ی GMICT.

معیار روش	DS (%) ↑			JS (%) ↑			CS (%) ↑		
	WM	GM	CSF	WM	GM	CSF	WM	GM	CSF
GMM [۱۱]	۸۱/۱۸	۷۰/۲۷	۹۳/۸۵	۷۰/۶۲	۵۸/۲۶	۷۰/۷۷	۷۳/۳۲	۸۵/۱۳	۹۴/۴۵
ARKFCM [۱۰]	۸۳/۳۱	۷۱/۴۳	۷۰/۶۸	۷۵/۷۲	۶۰/۹۵	۵۹/۱۱	۸۱/۳۳	۹۱/۷۷	۹۱/۴۱
FCMPSO [۱۲]	۸۴/۱۴	۶۷/۸۹	۶۲/۷۴	۷۵/۲۷	۵۶/۰۱	۵۱/۱۵	۷۹/۷۴	۸۹/۰۵	۸۴/۳۴
FCMWOA [۱۳]	۷۲/۶۳	۳۵/۲۳	۳۹/۲۶	۶۱/۰۱	۳۷/۱۳	۳۸/۳۷	۴۹/۳۲	۶۹/۷۱	۶۵/۹۹
SFCMEMBC [۶]	۷۶/۴۴	۷۳/۰۵	۷۴/۷۴	۷۳/۵۲	۶۲/۶۶	۵۹/۶۸	۶۹/۴۹	۷۹/۶۹	۷۹/۳۶
BCIFCMSNI [۷]	۷۸/۲۳	۷۲/۸۹	۷۶/۸۱	۷۴/۶۹	۶۱/۱۳	۶۰/۱۲	۷۰/۷۸	۸۱/۱۳	۷۰/۱۵
FBKPCS [۱۶]	۸۸/۲۵	۸۲/۷۲	۸۶/۰۴	۸۱/۹۱	۷۲/۷۰	۷۶/۷۸	۹۰/۴۸	۹۳/۲۰	۹۵/۹۵
FRFCM [۲۵]	۸۸/۲۰	۸۱/۴۶	۸۱/۶۳	۸۱/۳۹	۷۰/۳۴	۷۰/۴۹	۸۶/۶۳	۹۰/۶۶	۹۱/۱۲
RFCM [۲۶]	۸۹/۹۷	۸۱/۳۶	۸۰/۰۵	۸۲/۳۹	۶۹/۴۰	۶۷/۱۴	۸۷/۲۹	۹۱/۳۱	۸۹/۵۲
BCGKIT	۹۰/۷۱	۸۴/۱۱	۸۹/۰۲	۸۳/۸۹	۷۴/۸۵	۸۱/۵۰	۹۲/۱۴	۹۵/۱۱	۹۷/۲۳

رویکرد استفاده از فاصله‌ی اقلیدسی معمولاً راهکار مناسبی برای خوشه‌های فشرده با اندازه‌ی کوچک نیست. یکی از موضوعات مهم در بخش‌بندی تصاویر پزشکی حفظ جزئیات لبه‌های تصویر است که معیار CS برای سنجش این موضوع به‌کار گرفته می‌شود. نتایج کمی و کیفی نشان می‌دهد که الگوریتم پیشنهادی با بالاترین مقدار CS نسبت به سایر روش‌ها در کنار بخش‌بندی نواحی مختلف بافت مغزی جزئیات لبه را حفظ کرده و تطبیق کانتور بهتری انجام می‌دهد.

۴-۴- نتایج پیاده‌سازی بر روی پایگاه داده‌ی OASIS

مقایسه‌ی کیفی عملکرد الگوریتم‌های مختلف مبتنی بر خوشه‌بند فازی در بخش‌بندی بافت‌های مختلف مغزی بر روی یک نمونه از تصویر MR پایگاه داده‌ی OASIS برای برش ۹۵ در شکل ۷ نشان داده شده است. همچنین، مقایسه‌ی کمی الگوریتم‌های ذکر شده در بخش‌بندی تصاویر پایگاه داده‌ی OASIS برای میانگین نتایج ۱۰ نمونه در برش‌های ۸۰ الی ۱۳۰ در جدول (۳) آورده شده است. الگوریتم GMM (شکل ۷ ج)) برخی از نواحی WM را به اشتباه به کلاس GM برچسب زده و همچنین در اکثر تصاویر ناحیه‌ی CSF را به اشتباه به عنوان بافت GM در نظر می‌گیرد. الگوریتم ARKFCM (شکل ۷ د)) جزء روش‌هایی است که ضعیف‌ترین عملکرد را در بخش‌بندی ناحیه‌ی CSF داشته و در برخی از تصاویر به اشتباه بطن‌های مغزی را به کلاس پس‌زمینه برچسب می‌زند. الگوریتم‌های فراابتکاری مبتنی بر جمعیت PSO و WOA در بهینه‌سازی خوشه‌بند FCM جهت بخش‌بندی تصاویر MR پایگاه داده‌ی OASIS موفق نبوده و مشابه الگوریتم ARKFCM عموماً در بخش‌بندی کلاس CSF کارایی مناسبی ندارند. همان‌طوری که در شکل ۷ ی) نیز نشان داده شده است، الگوریتم‌های FRFCM و RFCM در بخش‌بندی بافت‌های WM و GM موثر عمل کرده ولی در تشخیص پیکسل‌های مربوط به کلاس CSF به‌طور مناسب عمل نمی‌کنند. همچنین، الگوریتم FRFCM در برخی از موارد بافت‌های بطن مغز




شکل ۶: عملکرد الگوریتم‌های مختلف در بخش‌بندی بافت‌های مختلف مغز بر روی نمونه‌ای از تصویر MR پایگاه داده‌ی GMICT. (الف): تصویر اصلی، (ب): تصویر برچسب‌گذاری شده، (ج): خروجی الگوریتم GMM، (د): خروجی الگوریتم ARKFCM، (ه): خروجی الگوریتم FCMPSO، (و): خروجی الگوریتم FCMWOA، (ز): خروجی الگوریتم SFCMEMBC، (ح): خروجی الگوریتم BCIFCMSNI، (ط): خروجی الگوریتم FBKPCS، (ی): خروجی الگوریتم FRFCM، (ک): خروجی الگوریتم RFCM، (ل): خروجی الگوریتم پیشنهادی، (م): تخمین بایاس با SFCMEMBC، (ن): تخمین بایاس با BCIFCMSNI، (س): تخمین بایاس با الگوریتم پیشنهادی.

جدول ۳: مقایسه‌ی کارایی الگوریتم BCGKIT پیشنهادی با سایر روش‌ها در بخش‌بندی تصاویر پایگاه داده‌ی OASIS.

معیار روش	DS (%) ↑			JS (%) ↑			CS (%) ↑		
	WM	GM	CSF	WM	GM	CSF	WM	GM	CSF
GMM [۱۱]	۹۰/۳۵	۸۲/۶۱	۷۹/۴۱	۸۲/۶۲	۷۱/۶۰	۶۸/۳۳	۹۳/۷۵	۹۳/۷۵	۸۰/۲۰
ARKFCM [۱۰]	۹۴/۶۰	۷۴/۷۱	۶۲/۱۳	۸۹/۸۹	۶۱/۸۷	۴۹/۵۹	۹۷/۳۵	۹۳/۳۴	۸۱/۲۹
FCMPSO [۱۲]	۹۵/۳۴	۸۳/۴۰	۷۱/۵۳	۹۱/۱۶	۷۲/۶۸	۵۸/۱۷	۹۸/۱۱	۹۵/۹۴	۸۷/۶۱
FCMWOA [۱۳]	۸۶/۴۶	۷۸/۳۹	۶۷/۸۶	۸۷/۷۷	۶۷/۱۱	۴۶/۶۴	۸۵/۴۳	۸۸/۹۰	۸۰/۹۳
SFCMEMBC [۶]	۷۳/۸۲	۷۲/۱۵	۷۶/۳۴	۷۲/۱۶	۶۳/۷۶	۶۱/۵۱	۷۱/۳۲	۸۲/۴۶	۸۱/۵۰
BCIFCMSNI [۷]	۷۹/۷۱	۷۳/۷۲	۷۸/۹۶	۷۵/۵۳	۶۳/۹۱	۶۲/۲۳	۷۳/۸۱	۸۴/۹۶	۷۳/۲۵
FBKPCS [۱۶]	۹۳/۵۲	۸۳/۱۴	۷۱/۷۰	۹۰/۴۸	۷۲/۴۹	۵۹/۵۹	۹۶/۳۵	۹۵/۲۵	۸۷/۷۷
FRFCM [۲۵]	۹۲/۸۱	۸۲/۶۰	۷۲/۹۷	۸۸/۲۰	۷۰/۸۰	۶۱/۳۶	۹۵/۲۹	۹۵/۳۸	۸۸/۵۰
RFCM [۲۶]	۹۳/۲۳	۸۰/۳۰	۶۹/۸۵	۸۸/۱۶	۶۷/۷۴	۵۶/۱۵	۹۵/۵۴	۹۳/۹۷	۸۶/۲۳
BCGKIT	۹۵/۴۲	۸۶/۴۱	۸۱/۱۹	۹۱/۳۱	۷۶/۶۷	۷۰/۷۹	۹۸/۲۹	۹۶/۵۸	۹۰/۱۴

را به اشتباه به سایر کلاس‌ها برچسب می‌زند. نتایج موردنظر نشان می‌دهد که عموماً رویکردهای مبتنی بر FCM در بخش‌بندی خوشه‌های با ریخت فشرده و کم‌حجم کارایی مناسبی ندارند. همان‌طوری که در جدول (۳) نیز قابل مشاهده است، الگوریتم‌های BCGKIT و FBKPCS پیشنهادی بهترین عملکرد را در بخش‌بندی بافت‌های مختلف مغزی بر روی تصاویر MR پایگاه داده‌ی OASIS دارند. معیارهای ارزیابی نشان می‌دهند که الگوریتم پیشنهادی در حدود ۲٪ با دقت بیشتری کلاس‌های WM و GM را بخش‌بندی می‌کند. این در حالی است که در شناسایی پیکسل‌های مربوط به ناحیه‌ی CSF یک اختلاف تقریباً ۱۰٪ بین الگوریتم FBKPCS و پیشنهادی وجود داشته و الگوریتم BCGKIT به دلیل بیضوی فرض کردن ریخت خوشه‌ها بهترین عملکرد را در بخش‌بندی بافت CSF دارد. الگوریتم BCIFCMSNI پایین‌ترین معیار CS را در بخش‌بندی بافت‌های مختلف مغزی دارد. این موضوع نشان می‌دهد که این الگوریتم تطبیق کانتر مناسبی نداشته و در حفظ جزئیات لبه کارایی مناسبی ندارد. همچنین، در تصاویر واقعی با شرایط پیچیده ویژگی‌های تصویر نیازمند تنظیم دقیق پارامتر است. این در حالی است که الگوریتم پیشنهادی در پایگاه داده‌های مختلف نیازمند تنظیم پارامتر نیست. براساس نتایج جدول (۳)، الگوریتم SFCMEMBC از منظر میانگین معیار JS به بافت موردنظر کمترین مقدار را دارد. این موضوع نشان می‌دهد که پیکسل‌های متمایز شده براساس الگوریتم موردنظر شباهت کمتری به پیکسل‌های تصویر مرجع دارد. در مقابل، الگوریتم BCGKIT پیشنهادی با دارا بودن بالاترین معیارهای ارزیابی (میانگین تقریبی ۸۸٪، ۸۰٪ و ۹۵٪ به ترتیب برای معیارهای DS، JS و CS) در بین الگوریتم‌های مقایسه شده، از منظر میزان شباهت نتیجه به دست آمده به تصویر مرجع و همچنین از منظر تطبیق کانتر بهترین عملکرد را در بین خوشه‌بندهای مبتنی بر فازی دارد.



شکل ۷: عملکرد الگوریتم‌های مختلف در بخش‌بندی بافت‌های مختلف مغز بر روی نمونه‌ای از تصویر MR پایگاه داده‌ی OASIS در برش ۹۵. (الف): تصویر اصلی، (ب): تصویر برچسب‌گذاری شده، (ج): خروجی الگوریتم GMM، (د): خروجی الگوریتم ARKFCM، (ه): خروجی الگوریتم FCMPSO، (و): خروجی الگوریتم FCMWOA، (ز): خروجی الگوریتم SFCMEMBC، (ح): خروجی الگوریتم BCIFCMSNI، (ط): خروجی الگوریتم FBKPCS، (ی): خروجی الگوریتم FRFCM، (ک): خروجی الگوریتم RFCM، (ل): خروجی الگوریتم پیشنهادی، (م): تخمین بایاس با SFCMEMBC، (ن): تخمین بایاس با BCIFCMSNI، (س): تخمین بایاس با الگوریتم پیشنهادی.

۵- نتیجه‌گیری و ارائه‌ی پیشنهادها

مولفه‌ی بایاس معمولاً به دلیل عواملی نظیر غیریکنواختی میدان مغناطیسی و حساسیت کوپل فرکانس رادیویی در تصاویر MR وجود داشته به طوری که فرآیند بخش‌بندی تصویر را تحت تاثیر قرار می‌دهد. در این مطالعه رویکرد مبتنی بر خوشه‌بند فازی با استفاده از الگوریتم GK و تئوری اطلاعات جهت تخمین مولفه‌ی بایاس یا غیریکنواختی شدت و بخش‌بندی بافت‌های مختلف مغزی ارائه شد. الگوریتم BCGKIT پیشنهادی برخلاف رویکردهای مبتنی بر FCM که یک فاصله‌ی اقلیدسی را برای خوشه‌های با ریخت کروی به کار می‌برند، با فرض بیضوی بودن ریخت خوشه‌ها از یک فاصله‌ی ماهالانوبیس برای بخش‌بندی تصاویر MR استفاده می‌کند که در تشخیص خوشه‌های فشرده و کم‌حجم عملکرد بهتری در مقایسه با رویکردهای خوشه‌بندی مبتنی بر FCM دارد. این فرآیند باعث بهبود دقت بخش‌بندی بافت‌های فشرده و کم‌حجم نظیر CSF می‌شود. همچنین، براساس تئوری اطلاعات جهت مقاوم بودن الگوریتم پیشنهادی به نویز، اطلاعات متقابل بین توزیع داده‌ی هر خوشه و داده‌ی خارج از خوشه بیشینه می‌شود. نتایج به دست آمده از تصاویر واقعی و شبیه‌سازی شده نشان می‌دهد که الگوریتم پیشنهادی می‌تواند داده‌های با غیریکنواختی شدت، آغشته به نویز، فشرده و کم‌حجم را با دقت بالایی خوشه‌بندی کند. همچنین، نتایج تأیید کردند که الگوریتم پیشنهادی در تمامی برش‌های داده‌ی MRI کارایی خوبی داشته و قادر به حفظ جزئیات بیشتر لبه‌های تصویر در فرآیند بخش‌بندی بافت‌های مختلف مغزی است. الگوریتم BCGKIT پیشنهادی به عنوان یک روش کارآمد در توسعه‌ی ابزارهای هوش مصنوعی می‌تواند برای کاربردهای مختلف در پردازش تصاویر MR به کار گرفته شود.

به کارگیری ماتریس کواریانس در الگوریتم پیشنهادی باعث افزایش پیچیدگی محاسباتی می‌شود. مشابه رویکردهای مبتنی بر FCM، الگوریتم پیشنهادی نیز به فرآیند مقداردهی اولیه حساس بوده و ممکن است در کمینه محلی بیافتد. همچنین، ساختار فضایی پیکسل‌ها به طور مستقیم در تابع هزینه‌ی پیشنهادی لحاظ نشده است. در ادامه جهت استحکام بیشتر الگوریتم پیشنهادی به نویز، در نظر گرفتن اطلاعات همسایگی پیکسل‌ها می‌تواند مطرح باشد. بیان الگوریتم پیشنهادی براساس رویکردهای احتمالی نیز می‌تواند جهت بهبود دقت فرآیند بخش‌بندی مطرح باشد. به کارگیری الگوریتم‌های فراابتکاری در به روزرسانی پارامترهای الگوریتم پیشنهادی می‌تواند راهکار مناسبی جهت حل مشکلات مربوط به افتادن در کمینه محلی باشد.

مراجع

- [2] W. Lingfeng and C. Pan, "Image-guided regularization level set evolution for MR image segmentation and bias field correction," *Magnetic resonance imaging*, vol. 32, no. 1, pp. 71-83, 2014.
 - [3] A. Mohamed N et al, "A modified fuzzy c-means algorithm for bias field estimation and segmentation of MRI data," *IEEE transactions on medical imaging*, vol. 21, no. 3, pp. 193-199, 2002.
 - [4] J. Ze-Xuan, Q. Sun, and D. Xia, "A modified possibilistic fuzzy c-means clustering algorithm for bias field estimation and segmentation of brain MR image," *Computerized Medical Imaging and Graphics*, vol. 35, no. 5, pp. 383-397, 2011.
 - [5] C. Li, J. C. Gore and 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, 2024.
 - [6] R. Meena Prakash and 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.
 - [7] 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.
 - [8] S. Chandan 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.
 - [9] 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.
 - [10] 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.
 - [11] J. Qiao et al, "Data on MRI brain lesion segmentation using K-means and Gaussian Mixture Model-Expectation Maximization," *Data in brief*, vol. 27, pp. 104628, 2019.
 - [12] 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.
 - [13] S. Tongbram et al, "A novel image segmentation approach using fcm and whale optimization algorithm," *Journal of ambient intelligence and humanized computing*, pp. 1-15, 2021.
 - [14] S. Chandan et al, "An Intuitionistic Fuzzy C-Means and Local Information-Based DCT Filtering for Fast Brain
- [1] M. Pranaba K et al, "Intensity inhomogeneity correction in brain MRI: a systematic review of techniques, current trends and future challenges," *Neural Computing and Applications*, vol. 37, pp. 1821-1838, 2025.

- [27] D. Pankaj et al, "A novel method for removing Rician noise from MRI based on variational mode decomposition", *Biomedical Signal Processing and Control*, vol. 69, pp. 102737, 2021.



علی فهیمی جعفرقلخانلو مدرک کارشناسی ارشد و دکتری خود را به ترتیب در سال‌های ۱۳۹۶ و ۱۴۰۱ در رشته مهندسی پزشکی گرایش بیوالکتریک از دانشگاه صنعتی تبریز (سهند) اخذ کرد. در حال حاضر استادیار دانشگاه محقق اردبیلی، دانشکده‌ی فناوری‌های نوین، گروه علوم مهندسی است. زمینه‌های پژوهشی مورد علاقه ایشان پردازش تصاویر پزشکی و سیگنال‌های حیاتی، آنالیز مبتنی بر تصویر جراحی‌های زیبایی چهره، هوش مصنوعی و یادگیری ماشین هستند.



موسی شمسی دوره کارشناسی را در دانشگاه تبریز در سال ۱۳۷۴ در رشته مهندسی برق-الکترونیک و دوره‌های کارشناسی ارشد و دکتری را به ترتیب در سال ۱۳۷۸ و ۱۳۸۷ در دانشگاه تهران و در رشته مهندسی پزشکی-بیوالکتریک به پایان رسانده است و اکنون استاد تمام دانشکده مهندسی پزشکی دانشگاه صنعتی تبریز (سهند) هستند. زمینه تخصصی ایشان پردازش سیگنال و تصاویر پزشکی، هوش مصنوعی و یادگیری ماشین است.



مهدی بشیری باویل دانش‌آموخته مهندسی پزشکی مقاطع کارشناسی ارشد از دانشگاه تهران و دکتری از دانشگاه صنعتی تبریز (سهند) است. زمینه‌های پژوهشی وی شامل هوش مصنوعی، یادگیری ماشین، پردازش تصویر، علوم اعصاب و کاربردهای مهندسی در پزشکی است. پژوهش‌های اخیر ایشان عمدتاً بر پردازش تصاویر MRI مغز با هدف تحلیل بیماری‌های تحلیل‌برنده عصبی نظیر مولتیپل اسکلروزیس (MS) متمرکز است. از جمله دستاوردهای علمی وی می‌توان به مقالات منتشرشده در حوزه تقسیم‌بندی بافت‌های مغزی، تحلیل خودکار سیر بیماری‌های مغزی و شبیه‌سازی پیش از عمل در جراحی‌های چهره اشاره کرد.

- MRI Segmentation," *J Digit Imaging. Inform. Med*, vol. 37, pp. 2287–2310, 2024.
- [15] S. Rinki and 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.
- [16] P. Kumar et al, "Fast and robust spatial fuzzy bounded k-plane clustering method for human brain MRI image segmentation," *Applied Soft Computing*, vol. 133, pp. 109939, 2023.
- [17] S. Mohammadi et al, "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.
- [18] R. Krishnapuram 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.
- [19] D. Dovžan and I. Škrjanc, "Recursive clustering based on a Gustafson–Kessel algorithm," *Evolving systems*, vol. 2, no. 1, pp. 15–24, 2011.
- [20] D. E. Gustafson and 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.
- [21] W. Zhimin et al, "An adaptive spatial information-theoretic fuzzy clustering algorithm for image segmentation," *Computer Vision and Image Understanding*, vol. 117, no. 10, pp. 1412–1420, 2013.
- [22] S. Ramathilagam et al, "Modified fuzzy c-means algorithm for segmentation of T1–T2-weighted brain MRI," *Journal of Computational and Applied Mathematics* vol. 235, no. 6, pp. 1578–1586, 2011.
- [23] D. S. Marcus et al, "Open Access Series of Imaging Studies (OASIS): cross-sectional MRI data in young, middle aged, nondemented, and demented older adults," *Journal of cognitive neuroscience*, vol. 19, no. 9, pp. 1498–1507, 2007.
- [24] 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.
- [25] 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.
- [26] C. Wang et al, "Residual-driven fuzzy C-means clustering for image segmentation," *IEEE/CAA Journal of Automatica Sinica*, vol. 8, no. 4, pp. 876–889, 2020.