

Magnetic Resonance image segmentation by modified spatial FCM based on Gaussian function

(Research Note)

A. Biniaz^{1,2}, A. Abbasi³, M. Shamsi³

¹M.Sc Student, Faculty of Biomedical Engineering, Bio Electrical Group, Sahand University, Tabriz, Iran

² Faculty of Electronic Engineering, Islamic Azad University of Lamard, Fars, Iran

³ Assistant Professor, Faculty of Biomedical Engineering, Bio Electrical Group, Sahand University, Tabriz, Iran

shamsi@sut.ac.ir

Abstract

Segmentation divides an image to some subdivisions where which of ones has similar intensity gray levels. Among clustering methods fuzzy c-means (FCM) clustering has been frequently used for segmentation of medical images. However, this algorithm doesn't incorporate spatial neighborhood information in segmentation. This approach is very susceptible to nuisance factors. Therefore this paper proposes a Gaussian spatial FCM (gsFCM) to MR image segmentation. Proposed method has less sensitivity to noise specially in tissue boundaries, angles, and borders than spatial FCM (sFCM). Furthermore by the suggested algorithm a pixel which is a separate tissue from structurally point of view for example a tumor in primary stages of its appearance, has more chance to be a unique cluster. Applying quantitative assessments using Jaccard similarity index, Dice coefficient, and other validation functions on FCM, sFCM and gsFCM approaches show efficient performance of the proposed method. In this research the ISBR data bank is used for simulations. Moreover in medical applications getting patient condition and information with fast methods is very important especially in emergency circumstances. Therefore all effective agents in patient health must be fast even medical algorithms such as clustering ones. Hence in this paper to decrease the time of convergence considerably and decline the number of iterations significantly, cluster centroids are initialized by an algorithm.

Keywords: component, Segmentation, MR brain image, FCM, spatial information filtering, initial cluster centroids, Gaussian membership function.

* Corresponding author

Address: Mousa Shamsi, Faculty of Biomedical Engineering, Bio Electrical Group, Sahand University, Tabriz, Iran

Tel: +98 412 3459332

Fax: +98 412 3459332

E-mail: shamsi@sut.ac.ir

ناحیه‌بندی تصاویر MR مغز با استفاده از FCM بهبود یافته‌ی مکانی به کمک تابع گوسی : gsFCM (یادداشت فنی)

عباس بی‌نیاز^{۱،۲}، عطااله عباسی^۳، موسی شمس^{۳*}

^۱ کارشناس ارشد مهندسی پزشکی، بیوالکتریک، دانشگاه صنعتی سهند، تبریز، ایران

^۲ دانشکده‌ی مهندسی برق، دانشگاه آزاد اسلامی واحد لامرد، فارس، ایران

^۳ آزمایشگاه علوم اعصاب محاسباتی، گروه مهندسی پزشکی، دانشگاه صنعتی سهند

^۳ استادیار مهندسی پزشکی، بیوالکتریک، دانشگاه صنعتی سهند، تبریز، ایران

shamsi@sut.ac.ir

چکیده

بخش‌بندی تصویر را به بخش‌های مجزا تقسیم می‌کند که هر کدام از این بخش‌ها دارای سطوح روشنایی‌کنناختی هستند. از بین روش‌های موجود روش خوشه‌بندی‌فازی (fuzzy c-means clustering) دارای کاربرد وسیعی در ناحیه‌بندی تصاویر پزشکی است. عدم ادغام ویژگی‌های مکانی در FCM استاندارد، از معایب این روش در ناحیه‌بندی تصاویر تشدید مغناطیسی (MRI) (Magnetic Resonance Imaging) مغز انسان است؛ در این مقاله از روشی جدید برای بخش‌بندی و حذف نویز تصاویر MR با اعمال فیلتر مکانی گوسی در تابع عضویت فازی استفاده شده است. فیلتر مکانی مذکور، اثرات نویز در مرز بافت‌ها و زوایای تصویر را بصورت‌بینه‌ای مدیریت می‌کند؛ علاوه بر این پیکسلی که به لحاظ آناتومیکی بافت مجزا است مانند تومور در مراحل اولیه‌ی رشد، شانس بیشتری برای خوشه شدن دارد. در پایان آزمایشات که بر روی پایگاه داده ISBR انجام شده است کیفیت روش پیشنهادی توسط توابع اعتبارسنجیمتداول مانند شاخص جاکارد و ضریب دایس مورد ارزیابی قرار گرفته است. از طرف دیگر در کاربردهای پزشکی به خصوص در شرایط اورژانسی، ضرورت سرعت عمل تمام عوامل پزشکی امری اجتناب‌ناپذیر است و الگوریتم ناحیه‌بندی از این قاعده مستثنی نیست، لذا برای دستیابی به این مهم توسط الگوریتمی مرکز ثقل اولیه‌ی خوشه‌ها، مشخص می‌شود که زمان هم-گرایی تابع هزینه در FCM بهبود یافته‌ی مکانی گوسی، نسبت به FCM استاندارد تا حد قابل قبولی کاهش می‌یابد.

کلیدواژگان: اپیزودهای افت فشار خون حاد، پیش‌آگهی، ویژگی‌های فیزیولوژیکی، ویژگی‌های آشوبناک، انتخاب ویژگی، الگوریتم ژنتیک

عهددار مکاتبات

نشانی: تبریز، دانشگاه سهند تبریز، دانشکده بیوالکتریک

تلفن: ۰۴۱۲۳۴۵۹۳۳۲، دورنگار: ۰۴۱۲۳۴۵۹۳۳۲، پیام نگار: shamsi@sut.ac.ir

۱-مقدمه

هدف اصلی ناحیه‌بندی تقسیم بندی یک تصویر به بخش‌هایی است که پیکسل‌های هر ناحیه در ویژگی‌ها و خصوصیاتشان بیشترین تشابه را داشته باشند؛ که این همان مفهوم خوشه‌بندی است، حال اگر به خوشه‌های موجود برچسب زده شود عمل طبقه‌بندی انجام شده‌است [۱].

در دهه‌های گذشته، روش‌های زیادی برای ناحیه‌بندی تصاویر MR مغز انسان انجام شده است. با استفاده از روش‌های آستانه‌گیری مرز بافت‌ها در محل دره جدا می‌شود؛ همچنین می‌توان چندین سطح آستانه برای ناحیه‌بندی انتخاب کرد [۲]. در روش رشد ناحیه نواحی بهم پیوسته مربوط به یک بافت مغز مانند تومور توسط معیاری از قبل تعریف شده، مثلاً اطلاعات روشنایی لب‌ها و... استخراج می‌شود [۳]؛ یکی از روش‌های متداول در ناحیه بندی مدل MRF (Markov Random Field) است که از روابط آماری برای ناحیه‌بندی تصاویر پزشکی استفاده می‌کند. این روش در نمایش ویژگی‌ها، شباهت زیادی به شبکه بیز (Bayesian network) دارد [۵،۴]. روش‌های دیگری مانند ناحیه‌بندی به کمک روش‌های فازی به ویژه روش خوشه‌بندی فازی (FCM) به طور گسترده‌ای در ناحیه‌بندی تصاویر مورد استفاده قرار گرفته‌اند [۷،۶]. دلایل اصلی این استفاده بوسیله تعریف فازی بودن برای تعلق هر پیکسل از تصویر به چند خوشه است. علاوه بر این ادغام ویژگی‌های مکانی تصویر در ناحیه‌بندی تاثیر زیادی بر روی کیفیت ناحیه‌بندی دارد. اعمال اطلاعات مکانی با استفاده از ویژگی‌های آماری پیکسل‌های همسایه در [۸] بررسی شده است. در این تحقیق برای هر کدام از پیکسل‌های همسایه یک تابع موثر در نظر گرفته شده است که به نوعی تابع همبستگی پیکسل‌های همسایه محاسبه می‌شود. روش ارائه شده در [۸] بگونه‌ای است که تابع عضویت فازی هر پیکسل را با توجه به تابع عضویت همان پیکسل و تمام پیکسل-

های موجود در همسایگی آن پیکسل و با استفاده از روش‌های آمار و احتمال محاسبه می‌شود. استفاده از روش‌های فازی بصورت ترکیبی با سایر الگوریتم‌های هوشمند همانند الگوریتم ژنتیک برای ادغام اطلاعات مکانی نیز در ناحیه‌بندی مفید است؛ استفاده از روش ترکیبی فازی و الگوریتم ژنتیک شدت بار محاسباتی الگوریتم را افزایش می‌دهد [۹].

در مقاله حاضر به یکی از شیوه‌های ناحیه‌بندی تصاویر بر مبنای خوشه‌بندی فازی با استفاده از اطلاعات مکانی sFCM (spatial FCM) اشاره می‌شود و نقاط ضعف روش اصلاح خواهد شد. الگوریتم sFCM نیز را با استفاده از عضویت مکانی پیکسل‌های همسایه، به صورت قابل ملاحظه‌ای کاهش می‌دهد؛ اما دارای معایب و نقایصی به خصوص در ناحیه‌بندی مرز بافت‌ها و زوایای تصویر است که با استفاده از الگوریتم پیشنهادی gsFCM (gaussian spatial FCM) مدیریت بیشتری روی مرزها و بافت‌های کوچک تصویر انجام خواهد شد.

این مقاله در بخش ۲-۱ تابع خوشه بندی فازی را معرفی می‌کند. در بخش ۲-۲ الگوریتم FCM استاندارد به کمک تابع مکانی بهبود می‌یابد و تابع sFCM معرفی خواهد شد. برای انجام ناحیه‌بندی بهینه در مرزها، زوایا و بافت‌های کوچک تصویر در بخش ۲-۳ الگوریتم gsFCM پیشنهاد می‌شود. بخش ۳-۱- روش‌های اعتبارسنجی متداول را معرفی می‌کند. و بخش ۳-۲ نتایج شبیه‌سازی را تحلیل و ارزیابی می‌کند.

۲- ناحیه‌بندی تصاویر MR مغز

۲-۱- خوشه‌بندی فازی FCM

خوشه‌بندی به معنی تعیین گروه‌هایی است که در یک مجموعه داده‌ی دسته‌بندی نشده قرار دارند. [۱۰] در

۲-۳-FCM مکانی گوسی

در این بخش تابع مکانی گوسی برای مدیریت بهتر مرزها، زوایا و ارگانسیم‌های کوچک‌تر مانند تومور در مراحل اولیه‌ی پیدایش، به صورت رابطه‌ی (۵) پیشنهاد می‌شود:

$$h_{ij} = \sum_{k \in N(x_j)} \sum_{l \in N(x_j)} \frac{1}{2\pi\sigma^2} e^{-\frac{k^2+l^2}{2\sigma^2}} u_{kl} \quad (5)$$

$N^f(x_j)$ در حقیقت یک همسایگی به شعاع r^f و مرکزیت پیکسل x_j و $k=0$ و $l=0$ است. u_{kl} عضویت فازی هر کدام از پیکسل‌های پنجره‌ی مربعی 5×5 را نشان می‌دهد اما تابع مکانی h_{ij} متوسط وزن‌دارشده‌ی عضویت‌های فازی در پنجره‌ای با محدوده‌ی همسایگی $N^f(x_j)$ را نمایش می‌دهد و $0.5 < \sigma < 2$. در گام بعد تابع مکانی و تابع عضویت در رابطه‌ی زیر ادغام شده و تابع عضویت جدید ایجاد می‌شود:

$$u_{ij}^q = \frac{u_{ij}^p \times h_{ij}^q}{\sum_{k=1}^n u_{ij}^p \times h_{ij}^q} \quad (6)$$

q و p پارامترهایی‌اند که تاثیر دو تابع مکانی و تابع عضویت را کنترل می‌کنند. تابع مکانی h_{ij} تابع عضویت اصلی را تقویت یا تضعیف می‌کند. تابع $sFCM_{p,q}$ مکانی (گوسی) با پارامترهای p و q بصورت $sFCM_{p,q}$ و $gsFCM_{p,q}$ نشان داده می‌شوند. مراحل شبیه‌سازی روش ارائه شده به این صورت است:

- ۱- تعیین تعداد خوشه‌ها (c)، درجه‌ی عضویت فازی ($m=2$) و اختصاص مقادیر اولیه‌ی کم به تابع عضویت فازی اولیه و مقادیر تصادفی کوچک به مراکز خوشه‌ها.
- ۲- بروزرسانی مرکز ثقل خوشه‌ها توسط رابطه‌ی ۲.
- ۳- بروزرسانی عضویت فازی توسط رابطه‌ی ۳.
- ۴- محاسبه‌ی تابع عضویت فازی جدید توسط رابطه- ۴

ی. ۶

- ۵- در صورت ارضای شرط خاتمه $\|v_i^{(t+1)} - v_i^{(t)}\| < \epsilon$ تصویر ناحیه‌بندی شود وگرنه برگشت به مرحله‌ی ۲.

روش فازی، هر یک از داده‌ها می‌تواند به چند خوشه با مقادیر عضویت متفاوت تعلق داشته باشد. مقدار عضویت هر داده در هر خوشه، نشانگر شباهت داده به خوشه است. اگر بردار داده‌های ورودی به صورت $X = \{x_1, x_2, \dots, x_n\}$ نشان داده شود. در این صورت تابع هزینه‌ی زیر باید توسط FCM کمینه شود [۱۱، ۱۲]:

$$J = \sum_{i=1}^n \sum_{j=1}^c u_{ij}^m \|x_j - v_i\|^2 \quad (1)$$

که در آن، u_{ij} میزان عضویت فازی داده x_j در خوشه‌ی i ام، v_i مرکز خوشه i ام، $\| \cdot \|$ نرم اندازه‌ی بردار، n تعداد پیکسل‌ها و m درجه‌ی عضویت فازی و برابر ۲ است. مقدار تابع عضویت u نشانگر احتمال تعلق هر پیکسل به یک خوشه است. توابع عضویت و مراکز خوشه‌ها در هر تکرار به وسیله‌ی روابط زیر بروزرسانی می‌شوند:

۲-۲-FCM مکانی

در تصاویر MR مغز انسان پیکسل‌های همسایه دارای شباهت زیادی در روشنایی هستند، در واقع احتمال این که پیکسل‌های همسایه متعلق به یک بافت یا خوشه باشند بیشتر است. استفاده از اطلاعات مکانی تصویر دارای اهمیت زیادی است که در FCM استاندارد مورد استفاده قرار نمی‌گیرد. برای استفاده از اطلاعات مکانی، تابع مکانی بصورت زیر تعریف می‌شود [۱]:

$$h_{ij} = \sum_{k \in N(x_j)} u_{ik} \quad (4)$$

در حقیقت یک همسایگی به شعاع r و مرکزیت پیکسل x_j است. مقدار r برابر ۲ است. بنابراین در این آزمایش از یک ماسک 5×5 استفاده می‌شود [۱]. تابع مکانی h_{ij} نیز احتمال تعلق پیکسل x_j به کلاستر i ام را نشان می‌دهد.

۲-۴- محاسبه‌ی مرکز ثقل اولیه‌ی خوشه‌ها

برای کاهش زمان انجام خوشه‌بندی فازی، مرکز ثقل اولیه خوشه‌ها توسط الگوریتم dist-max محاسبه می‌شود؛ بنابراین سرعت همگرایی خوشه‌بندی افزایش می‌یابد [۱۳]. برای خوشه‌بندی توسط روش sFCM ابتدا مرکز ثقل اولیه برای هر خوشه بکمک الگوریتم dist-max بدست می‌آید و در مرحله‌ی بعد با بهبود بخشیدن تابع FCM استاندارد بکمک ویژگی‌های مکانی، ناحیه‌بندی انجام می‌گیرد. مراحل الگوریتم dist-max برای تعیین مرکز ثقل اولیه‌ی هر خوشه در روش sFCM بصورت زیر آمده است:

گام اول: با فرض این که X یک داده‌ی p -بعدی باشد که بصورت $X = \{x_1, x_2, \dots, x_n\}$ تعریف شود؛ آنگاه m_k ها بصورت صعودی مرتب شود و $m_k = \frac{1}{p} \sum_{i=1}^p x_{ki}$ مقادیر k با تعداد داده‌های بردار ورودی متناظر است: $k=1, 2, \dots, n$

گام دوم: ماتریس داده‌های m_k مجدداً بصورت $X' = \{x'_1, x'_2, \dots, x'_n\}$ سازماندهی و برچسب گذاری شود؛ و داده‌ها به تعداد c گروه ($1 < c < n$) تقسیم شود بطوریکه $c-1$ امین گروه شامل $c-1$ امین t ($t = \frac{n}{c}$) داده از X' و c امین گروه شامل تمام داده‌های باقیمانده از X' باشند.

گام سوم: ماتریس فاصله‌ی اقلیدسی در هر گروه مشخص شود؛ اگر گروه i ام بصورت $x^i = [x'_1, x'_2, \dots, x'_N]$ تعریف شود. در این صورت ماتریس فاصله‌ی $N \times N$ بصورت $[d_{ij}^i]$ معرفی می‌شود و N تعداد عناصر گروه i ام است:

	x_1^k	x_2^k	...	x_N^k
x_1^k	d_{11}^k	d_{12}^k	...	d_{1N}^k
x_2^k	d_{21}^k	d_{22}^k	...	d_{2N}^k
.
x_N^k	d_{N1}^k	d_{N2}^k	...	d_{NN}^k

گام چهارم: ماکزیمم فاصله در هر گروه انتخاب شود. اگر گروه i ام دارای ماکزیمم فاصله‌ی d_{ij}^i باشد آنگاه مرکز ثقل اولیه یکلاستر i ام عبارتست از M_i ، که M_i متوسط X_k و X_j است. مراحل شبیه‌سازی در مقاله‌ی حاضر به این صورت است:

۱- تعیین تعداد خوشه‌ها (c)، درجه‌ی عضویت فازی ($m=2$) و اختصاص مقادیر اولیه‌ی کم به ماتریس عضویت فازی.

۲- محاسبه‌ی مرکز ثقل اولیه‌ی خوشه‌ها توسط الگوریتم dist-max.

۳- بروزرسانی مرکز ثقل هر خوشه بکمک رابطه‌ی ۲

۴- بروزرسانی تابع عضویت فازی توسط رابطه‌ی ۳.

۵- محاسبه‌ی تابع عضویت جدید توسط رابطه‌ی ۵.

۶- در صورت ارضای شرط خاتمه $\|v_i^{(t+1)} - v_i^{(t)}\| < \varepsilon$ تصویر ناحیه‌بندی شود وگرنه به مرحله‌ی ۳ برگرد.

گام چهارم: ماکزیمم فاصله در هر گروه انتخاب شود. اگر گروه i ام دارای ماکزیمم فاصله‌ی d_{ij}^i باشد آنگاه مرکز ثقل اولیه یکلاستر i ام عبارتست از M_i ، که M_i متوسط X_k و X_j است.

مراحل شبیه‌سازی در مقاله‌ی حاضر به این صورت است:

۱- تعیین تعداد خوشه‌ها (c)، درجه‌ی عضویت فازی ($m=2$) و اختصاص مقادیر اولیه‌ی کم به ماتریس عضویت فازی.

۲- محاسبه‌ی مرکز ثقل اولیه‌ی خوشه‌ها توسط الگوریتم dist-max.

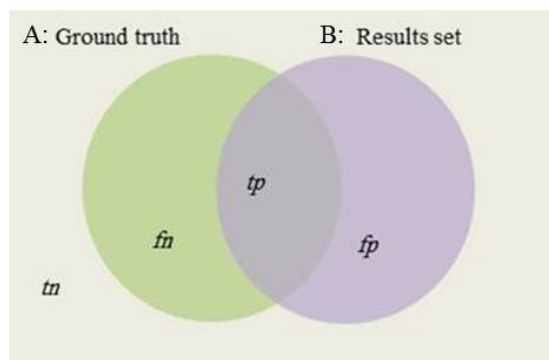
۳- بروزرسانی مرکز ثقل هر خوشه بکمک رابطه‌ی ۲

۴- بروزرسانی تابع عضویت فازی توسط رابطه‌ی ۳.

۵- محاسبه‌ی تابع عضویت جدید توسط رابطه‌ی ۵.

۶- در صورت ارضای شرط خاتمه $\|v_i^{(t+1)} - v_i^{(t)}\| < \varepsilon$ تصویر ناحیه‌بندی شود وگرنه به مرحله‌ی ۳ برگرد.

نزدیکی بیشتر به عدد یک در این دو شاخص کیفیت بهتر ناحیه‌بندی را نشان می‌دهد. A، مجموعه پیکسل‌های ناحیه‌بندی شده‌ی بافت هدف در تصویر استاندارد طلایی یا تصویر ناحیه‌بندی شده توسط متخصص نورولوژیست و B، مجموعه پیکسل‌های ناحیه‌بندی شده‌ی بافت هدف توسط الگوریتم است.



شکل ۱: همپوشانی بین استاندارد طلایی و نتایج الگوریتم.

علاوه بر این برای بررسی دقیق‌تر درستی ناحیه‌بندی، دو مشخصه‌ی حساسیت (Sensitivity) و ویژگی (Specificity) نیز بکار می‌روند. حساسیت را TPF (true positive fraction) و ویژگی را TNF (true negative fraction) نیز می‌نامند. این دو مشخصه بصورت زیر تعریف می‌شوند [۱۵]:

$$\text{Sensitivity} = \frac{tp}{tp + fn} \quad (9)$$

$$\text{Specificity} = \frac{tn}{tn + fp} \quad (10)$$

tp تعداد پیکسل‌هایی است که متعلق به کلاستر A هستند و درست ناحیه‌بندی شده‌اند. tn تعداد پیکسل‌هایی است که متعلق به کلاستر A نیستند و درست ناحیه‌بندی شده‌اند. fp تعداد پیکسل‌هایی است که متعلق به کلاستر A نیستند اما بصورت نادرست متعلق به کلاستر A در نظر گرفته شده‌اند و fn تعداد پیکسل‌هایی است که متعلق به کلاستر A هست اما به اشتباه جزئی از آن کلاستر ناحیه‌بندی نشده‌اند. بطور کلی میتوان نتیجه

۳- نتایج شبیه سازی

۳-۱- اعتبار سنجی روش


برای انجام تحقیق حاضر از تصاویر متعدد گرفته شده از یک پایگاه داده معتبر، استفاده می‌شود. همچنین منظور ارزیابی صحیح عملکرد الگوریتم پیشنهادی تصاویر فانتوم شبیه‌سازی شده‌ی تشدید مغناطیسی SPMR (Simulated Phantom MR)، تصاویر شبیه‌سازی شده‌ی تشدید مغناطیسی مغز SBMR (Simulated Brain MR) و تصاویر واقعی تشدید مغناطیسی مغز RBMR (Real Brain MR) استفاده شده است. این تصاویر، از نوع تصاویر ۸ بیتوزن T1 و با وضوح ۲۵۶×۲۵۶ پیکسل است. تصاویر پایگاه داده از سایت دانشگاه هاروارد IBSR (Internet Brain Segmentation Repository) به آدرس اینترنتی <http://www.cma.mgh.harvard.edu/ibsr/index.html> دانلود شده است. هر اسلایس از تصاویر مغز دارای ضخامت ۳٫۱ میلی‌متر است. این پایگاه داده شامل تصاویر استاندارد طلایی و تصاویر ناحیه‌بندی شده‌ی دستی توسط متخصص است.

همچنین برای ارزیابی ناحیه‌بندی توسط الگوریتم FCM پیشنهادی در این مقاله از شاخص تشابه جاکارد Jaccard Similarity Index (JSI) استفاده شده است و نتایج حاصل شده بکمک الگوریتم FCM بهینه شده با نتایج ناحیه‌بندی توسط الگوریتم FCM و FCM مقایسه شده است. شاخص JSI بصورت زیر تعریف میشود:

$$SI = \frac{|A \cap B|}{|A \cup B|} \quad (7)$$

علاوه بر شاخص تشابه جاکارد در متون علمی از ضریب تشابه دایس (Dice Similarity Coefficient) نیز برای ارزیابی کیفیت ناحیه‌بندی استفاده می‌شود [۱۵]؛ ضریب تشابه DSC بصورت زیر تعریف می‌شود [۱۴]:

$$DSC = \frac{2 \times |A \cap B|}{|A| + |B|} \quad (8)$$



شکل ۲: الف- تصویر فانتوم MR، آغشته شده به نویز؛ ب- تصویر استاندارد طلایی؛ نتایج ناحیه بندی به کمک الگوریتم های ج-FCM، د- $sFCM_{1,1}$ ، ه- $sFCM_{0,2}$ ، و- $sFCM_{1,1}$ ، ز- $gsFCM_{0,2}$.

برای انجام پژوهش، مراحل شبیه سازی روی تصاویر فانتوم و تصاویر واقعی MR انجام شده است و در پایان نتایج حاصل از شبیه سازی بصورت کیفی و کمی مقایسه شده اند. شکل ۲-الف تصویر فانتوم MR با وزن T1 که از پایگاه داده ISBR دانلود شده را نشان می دهد؛ این شکل آغشته به نویز رایس است. تصویر استاندارد طلایی در شکل ۲-ب دیده می شود. نتایج ناحیه بندی به کمک الگوریتم های FCM استاندارد، $sFCM_{1,1}$ ، $sFCM_{0,2}$ ، $gsFCM_{1,1}$ و $gsFCM_{0,2}$ در شکل های ۲-ج تا

گرفت که $tp+tn+fp+fn=N$ تعداد پیکسل های تصویر است.

برای ارزیابی بهتر ناحیه بندی از درصد ناحیه بندی کمتر از حد، درصد ناحیه بندی بیش از حد و درصد نادرست ناحیه بندی نیز استفاده می شود؛ که در آن UnS (Under Segmentation) درصد پیکسل هایی را نشان می دهد که به اشتباه بعنوان کلاستر A در نظر گرفته شده اند؛ OvS (Over Segmentation) درصد پیکسل هایی از کلاستر A را نشان می دهد که به اشتباه جز آن در نظر گرفته نشده اند؛ InS (Incorrect Segmentation) درصد کلی پیکسل هایی را نشان می دهد که به اشتباه برای یک کلاستر ناحیه بندی شده اند [۱۶]:

$$UnS = \frac{fp}{n} \times 100. \quad (11)$$



$$OvS = \frac{fn}{p} \times 100. \quad (12)$$

$$InS = \frac{fp + fn}{N} \times 100. \quad (13)$$

در این حالت n تمام پیکسل های متعلق به کلاستر A است $(n=tp+fn)$ و p تمام پیکسل های خارج از کلاستر A است $(p=tn+fp)$. بدین ترتیب N تمام پیکسل های معلق به یک تصویر است $(N=n+p)$.

۳-۲- نتایج شبیه سازی

در این پژوهش الگوریتم FCM استاندارد و بهبود یافته آن sFCM، که اطلاعات مکانی را در تابع عضویت فازی ادغام می کند، شبیه سازی شده اند. از آنجایی که sFCM توانایی کمی در مدیریت مرزها، زوایا و ارگانیسیم های کوچک دارد الگوریتم جدیدی به نام gsFCM پیشنهاد شد.



شکل ۳: الف- تصویر شبیه سازی شده MR مغز آغشته شده به نویز؛ ب- تصویر استاندارد طلایی؛ نتایج ناحیه بندی به کمک الگوریتم های ج- FCM، د- $sFCM_{1,1}$ ، ه- $sFCM_{0,2}$ ، و- $gsFCM_{1,1}$ ، ز- $gsFCM_{0,2}$.


عملکرد الگوریتم پیشنهادی بر روی تصاویر واقعی MR مغز انسان، نیز مورد بررسی قرار گرفت. شکل ۴-الف تصویر MR واقعی با وزن T1 را نشان می دهد که به نویز رایس آغشته شده است و شکل ۴-ب، تصویر ناحیه بندی شده توسط متخصص است. عملکرد الگوریتم FCM استاندارد، $sFCM_{1,1}$ ، $sFCM_{0,2}$ ، $gsFCM_{1,1}$ و $gsFCM_{0,2}$ به ترتیب در شکل های ۴-ج تا ۴-ز قابل مشاهده است؛ تفاوت الگوریتم پیشنهادی $gsFCM$ و

۲-زبه تصویر کشیده شده اند. الگوریتم $gsFCM_{1,1}$ نتایج قابل قبول تری را نسبت به $sFCM_{1,1}$ به خصوص در مرز بافت ها ارائه کرده است؛ و الگوریتم $gsFCM_{0,2}$ نیز به همین صورت دارای عملکرد مناسب تری نسبت به $sFCM_{0,2}$ در مرز بافت های تصویر است.

برای بررسی دقیق تر، در شکل ۳-الف تصویر شبیه سازی شده MR مغز با وزن T1 مورد بررسی قرار گرفت این تصاویر به نویز رایس آغشته شده است. تصویر ناحیه بندی شده MR مغز (استاندارد طلایی) در شکل ۳-ب دیده می شود. عملکرد الگوریتم های FCM استاندارد، $sFCM_{1,1}$ ، $sFCM_{0,2}$ ، $gsFCM_{1,1}$ و $gsFCM_{0,2}$ به ترتیب در شکل های ۳-ج تا ۳-ز دیده می شود. عملکرد مناسب $gsFCM$ نسبت به FCM استاندارد و $sFCM$ در مرز بافت ها و زوایای تصویر در این شکل قابل مشاهده است. عملکرد تابع گوسی در مرزهای تصویر بگونه ای است که با اعمال ضرایب نامساوی در تابع عضویت فازی با توجه به تفاوت فاصله ی پیکسل های همسایه از پیکسل مرکزی ناحیه بندی دقیق تری را ارائه می دهد. فاصله ی متفاوت پیکسل های همسایه از پیکسل مرکزی اثر پایداری در ناحیه بندی بهینه دارد. اثرگذاری متفاوت پیکسل های همسایه برای احتساب روشنایی جدید پیکسل مرکزی، باعث می شود که تخمین دقیق تری از روشنایی پیکسل مربوطه در اختیار باشد.

دهد. اگر لازم باشد با دقت بیشتری درستی ناحیه‌بندی بررسی شود، می‌توان نتایج TPF، TNF را بررسی کرد. در هر دو کمیت نزدیکتری بیشتر به عدد یک، کیفیت بهتر ناحیه‌بندی را نشان می‌دهد. همچنین درصد پیکسل‌هایی از بافت هدف که به اشتباه ناحیه‌بندی شده است (UnS)، درصد پیکسل‌هایی از بافت غیر هدف که به اشتباه بعنوان بافت هدف در نظر گرفته می‌شود (OVS) و درصد کل پیکسل‌هایی که بدرستی ناحیه‌بندی نشده‌اند (InS) در جدول ارائه شده است. نزدیکی بیشتر به عدد صفر در این سه کمیت کیفیت بهتر ناحیه‌بندی را نشان می‌دهد. جدول ۲ و ۳ نتایج کمی آزمایش‌ها را بر روی تصاویر شبیه‌سازی شده MR و همچنین تصاویر واقعی MR نشان می‌دهند: این نتایج مربوط به قشر خاکستری مغز است. در تابع گوسی پیشنهاد شده برای ادغام اطلاعات مکانی میزان اثرگذاری تابع گوسی بستگی به میزان σ دارد. افزایش σ باعث نزدیک شدن ضرایب تابع گوسی در همسایگی یک پیکسل به هم می‌شود؛ در نتیجه با نزدیک شدن ضرایب همسایگی در الگوریتم پیشنهادی، gsFCM، شباهت بیشتری به الگوریتم sFCM پیدا می‌کند. پیشنهاد می‌شود که σ در بازه $0.5 < \sigma < 1.5$ در نظر گرفته شود تا نتایج مطلوب تری بدست آید. این بازه از روش آزمون و خطا انتخاب شده است؛ هرچند با افزایش نویز می‌توان مقدار σ را افزایش داد. جدول ۴ میزان اثر گذاری σ را به ازای مقادیر متفاوت آن در ناحیه‌بندی قشر خاکستری مغز بررسی می‌کند.

الگوریتم sFCM به لحاظ عملکردی به خصوص در مرز بافت‌ها قابل مشاهده است.



شکل ۴: الف- تصویر واقعی MR. مغز؛ ب- تصویر ناحیه‌بندی شده توسط متخصص؛ نتایج ناحیه‌بندی به کمک الگوریتم‌های ج- FCM، د- sFCM_{1,1}، ه- sFCM_{0,2}، و- gsFCM_{1,1}، ز- gsFCM_{0,2}.

برای ارزیابی کمی کیفیت ناحیه‌بندی روی تصاویر متعدد از توابع مختلفی استفاده شده است. جدول ۱ عملکرد الگوریتم پیشنهادی را در مقایسه با تکنیک‌های معرفی شده بر روی فانتوم MR نشان می‌دهد. بیشترین نزدیکی به عدد یک در شاخص تشابه جاکارد JSI و ضریب تشابه دایس D ناحیه‌بندی بهتری را نشان می‌-

جدول ۱: ارزیابی روش پیشنهادی بر روی تصاویر فانتوم MR.

	تصویر MR فانتوم				
	FCM	sFCM _{1,1}	sFCM _{0,2}	gsFCM _{1,1}	gsFCM _{0,2}
JSI	۰,۸۳۸۵	۰,۸۸۰۸	۰,۹۱۹۳	۰,۸۸۰۸	۰,۹۲۰۶
D	۰,۹۱۲۱	۰,۹۹۳۶	۰,۹۵۸۰	۰,۹۳۶۶	۰,۹۵۸۶
TPF	۰,۸۹۴۶	۰,۹۰۷۸	۰,۹۲۷	۰,۹۰۸۴	۰,۹۲۹۹
TNF	۰,۹۹۴۴	۰,۹۹۷۴	۰,۹۹۹۳	۰,۹۹۷۴	۰,۹۹۹۱
UnS(%)	۰,۶۰۵	۰,۲۷۷۸	۰,۰۷۴	۰,۲۸۲	۰,۰۹۱
OvS(%)	۱۰,۵	۹,۲۱	۷,۳۰	۹,۱۵	۷,۰۰
InS(%)	۱,۴۲	۱,۰۱۹	۰,۶۷۴	۱,۰۱۹	۰,۶۶۵

جدول ۲: ارزیابی روش پیشنهادی بر روی تصاویر MR شبیه‌سازی شده.

	تصویر شبه سازی شده ی MR مغز				
	FCM	sFCM _{1,1}	sFCM _{0,2}	gsFCM _{1,1}	gsFCM _{0,2}
JSI	۰,۷۸۷۱	۰,۸۱۸۸	۰,۸۲۰۴	۰,۸۱۹۲	۰,۸۳۲۷
D	۰,۸۸۰۹	۰,۹۰۰۳	۰,۹۰۱۳	۰,۹۰۰۶	۰,۹۰۸۷
TPF	۰,۸۶۹۴	۰,۸۹۹۴	۰,۸۹۹۹	۰,۸۹۷۸	۰,۹۰۸۸
TNF	۰,۹۸۸۰	۰,۹۸۸۷	۰,۹۸۸۸	۰,۹۸۹	۰,۹۸۹۵
UnS(%)	۱,۳۵	۱,۲۷	۱,۲۵	۱,۲۴۲	۱,۱۸
OvS(%)	۱۳,۰۵	۱۰,۰۵	۱۰,۰۰	۱۰,۲۱	۹,۱۱
InS(%)	۲,۶۹	۲,۲۸	۲,۲۵	۲,۲۷	۲,۰۹

جدول ۳: ارزیابی روش پیشنهادی بر روی تصاویر MR واقعی مغز


	تصویر واقعی MR مغز				
	FCM	sFCM _{1,1}	sFCM _{0,2}	gsFCM _{1,1}	gsFCM _{0,2}
JSI	۰,۷۶۴۶	۰,۸۱۳۸	۰,۷۸۲۴	۰,۸۰۲۴	۰,۸۳۳۳
D	۰,۸۶۶۶	۰,۸۹۷۳	۰,۸۷۷۹	۰,۸۹۰۴	۰,۹۰۹۰
TPF	۰,۸۱۱۲	۰,۸۶۵۷	۰,۸۵۲۲	۰,۸۸۸۹	۰,۸۸۱۱
TNF	۰,۹۹۳۷	۰,۹۹۳۴	۰,۹۹۰۸	۰,۹۹۳۷	۰,۹۹۴۰
UnS(%)	۰,۶۹۹۰	۰,۷۳۱۳	۱,۰۲	۰,۶۹۳۹	۰,۶۵۸
OvS(%)	۱۸,۸۷	۱۳,۴۲	۱۴,۷۷	۱۴,۸۹	۱۱,۸۸
InS(%)	۲,۵۶	۲,۰۳۷	۲,۴۳	۲,۱۵	۱,۸۱

جدول ۴: بررسی تاثیر مقادیر متفاوت σ در الگوریتم gsFCM_{0,2} برای ناحیه‌بندی تصاویر واقعی MR.

	$\sigma=0.3$	$\sigma=0.5$	$\sigma=0.8$	$\sigma=1$	$\sigma=1.5$	$\sigma=2.5$
JSI	۰,۷۷۲۰	۰,۸۰۳۰	۰,۸۳۳۳	۰,۸۲۸۱	۰,۸۰۵۹	۰,۷۹۲۱
D	۰,۸۷۱۳	۰,۸۹۰۷	۰,۹۰۹۰	۰,۹۰۶	۰,۸۹۲۵	۰,۸۸۴
TPF	۰,۸۲۰۰	۰,۸۵۱۱	۰,۸۸۱۱	۰,۸۷۸۷	۰,۸۶۶۹	۰,۸۵۸۷
TNF	۰,۹۹۳۶	۰,۹۹۳۸	۰,۹۹۴۰	۰,۹۹۳۷	۰,۹۹۲۲	۰,۹۹۱۳
UnS(%)	۰,۷۱۲۶	۰,۶۸۷۱	۰,۶۵۸	۰,۷۰۰۷	۰,۸۶۷	۰,۹۶۴۳
OvS(%)	۱۷,۹۹	۱۴,۸۸	۱۱,۸۸	۱۲,۱۲	۱۳,۳۰	۱۴,۱۲
InS(%)	۲,۴۹	۲,۱۴	۱,۸۱	۱,۸۷	۲,۱۴	۲,۳۱

داده شده‌اند. در این شکل تاثیر استفاده یا عدم استفاده از الگوریتم dist-max در زمان اجرا و نیز تعداد تکرارهای gsFCM بر روی تصاویر مختلف قابل مشاهده است.

زمان مورد نیاز برای اجرای الگوریتم gsFCM، به مرکز ثقل اولیه‌ی خوشه‌ها بستگی زیادی دارد. در شکل ۷- زمان اجرا و تعداد دفعات تکرار الگوریتم gsFCM نشان



شکل ۵: زمان سپری شده و تعداد تکرارها توسط gsFCM در صورت استفاده یا عدم استفاده از الگوریتم dist-max بر روی تصاویر مختلف.

خوشه‌ها محاسبه شد؛ در نتیجه زمان همگرایی و تعداد تکرارهای gsFCM کاهش یافت.

۴- نتیجه گیری

خوشه‌بندی فازی یکی از روش‌های بدون سرپرست است که استفاده‌ی فراوانی در ناحیه‌بندی تصاویر MR مغز انسان داشته است. این نوع تصاویر در حوزه‌ی مکان بهم پیوستگی بالایی دارند، اما اطلاعات مکانی آنها در تابع FCM استاندارد مورد استفاده قرار نگرفته است. بنابراین حضور نویز و سایر عوامل مزاحم تا حد زیادی ناحیه‌بندی را مختل می‌کند. در این مقاله اطلاعات مکانی در دو فاز متفاوت به تابع FCM استاندارد اعمال شد. این اطلاعات در فاز نخست بصورت تابع مکانی خطی روی عضویت فازی دخالت داده شد و تابع sFCM معرفی گردید؛ و در فاز دوم اطلاعات مکانی با استفاده از تابع گوسی بر روی یک همسایگی از عضویت فازی اعمال شد. عملکرد مطلوب الگوریتم gsFCM پیشنهادی در مرزها و زوایای تصاویر واقعی و شبیه‌سازی شده MR، که از پایگاه داده ISBR جمع آوری شد، مورد بحث و بررسی قرار گرفت و نتایج کمی شبیه سازی با استفاده از تکنیک‌های معرفی شده در قالب جدول و نمودار ارائه شد. همچنین پس از معرفی FCM مکانی گوسیا gsFCM، با استفاده از الگوریتمی مرکز ثقل اولیه

مراجع

- [1] K. Chuang, H. Tzeng, S. Chen, J. Wu, and T. Chen, "Fuzzy c-means clustering with spatial information for image segmentation," *Computerized Medical Imaging and Graphics*, vol. 30, pp. 9-15, 2006.
- [2] P. K. Sahoo, S. Soltani, and A. Wong, "A survey of thresholding techniques," *Computer vision, graphics, and image processing*, vol. 41, pp. 233-260, 1988.
- [3] R. M. Haralick and L. G. Shapiro, "Image segmentation techniques," *Computer vision, graphics, and image processing*, vol. 29, pp. 100-132, 1985.
- [4] I. I. T. MODEL, "Unsupervised Texture Segmentation Using Markov Random Field Models".
- [5] L. Lin, D. Garcia-Lorenzo, C. Li, T. Jiang, and C. Barillot, "Adaptive pixon represented segmentation (APRS) for 3D MR brain images based on mean shift and Markov random fields," *Pattern Recognition Letters*, vol. 32, pp. 1036-1043, 2011.
- [6] W. Cai, S. Chen, and D. Zhang, "Fast and robust fuzzy c-means clustering algorithms incorporating local information for image segmentation," *Pattern Recognition*, vol. 40, pp. 825-8, 2007, 38.
- [7] W. Cai, S. Chen, and D. Zhang, "Fast and robust fuzzy c-means clustering algorithms incorporating local information for image segmentation," *Pattern Recognition*, vol. 40, pp. 825-838, 2007.

- brain MRI," *Journal of Computational and Applied Mathematics*, vol. 235, pp. 1578-1586, 2011.
- [23] A. Demirhan and İ. Güler, "Combining stationary wavelet transform and self-organizing maps for brain MR image segmentation," *Engineering Applications of Artificial Intelligence*, vol. 24, pp. 358-367, 2011.
- [24] P. Anbeek, K. L. Vincken, G. S. van Bochove, M. J. P. van Osch, and J. van der Grond, "Probabilistic segmentation of brain tissue in MR imaging," *NeuroImage*, vol. 27, pp. 795-804, 2005.
- [25] M. Forouzanfar, N. Forghani, and M. Teshnehlab, "Parameter optimization of improved fuzzy c-means clustering algorithm for brain MR image segmentation," *Engineering Applications of Artificial Intelligence*, vol. 23, pp. 160-168, 2010.
- [8] H. Van Lung and J.-M. Kim, "A generalized spatial fuzzy c-means algorithm for medical image segmentation," in *Fuzzy Systems, 2009. FUZZ-IEEE 2009. IEEE International Conference on*, 2009, pp. 409-414.
- [9] R. Venkateswaran and S. Muthukumar, "Genetic Approach on Medical Image Segmentation by Generalized Spatial Fuzzy C-Means Algorithm," in *2010 IEEE International Conference on Computational Intelligence and Computing Research*, pp. 210-213.
- [10] K. Chuang, H. Tzeng, S. Chen, J. Wu, and T. Chen, "Fuzzy c-means clustering with spatial information for image segmentation," *Computerized Medical Imaging and Graphics*, vol. 30, pp. 9-15, 2006.
- [11] P. K. Sahoo, S. Soltani, and A. Wong, "A survey of thresholding techniques," *Computer vision, graphics, and image processing*, vol. 41, pp. 233-260, 1988.
- [12] R. M. Haralick and L. G. Shapiro, "Image segmentation techniques," *Computer vision, graphics, and image processing*, vol. 29, pp. 100-132, 1985.
- [13] I. I. T. MODEL, "Unsupervised Texture Segmentation Using Markov Random Field Models".
- [14] L. Lin, D. Garcia-Lorenzo, C. Li, T. Jiang, and C. Barillot, "Adaptive pixon represented segmentation (APRS) for 3D MR brain images based on mean shift and Markov random fields," *Pattern Recognition Letters*, vol. 32, pp. 1036-1043, 2011.
- [15] W. Cai, S. Chen, and D. Zhang, "Fast and robust fuzzy c-means clustering algorithms incorporating local information for image segmentation," *Pattern Recognition*, vol. 40, pp. 825-838, 2007.
- [16] W. Cai, S. Chen, and D. Zhang, "Fast and robust fuzzy c-means clustering algorithms incorporating local information for image segmentation," *Pattern Recognition*, vol. 40, pp. 825-838, 2007.
- [17] H. Van Lung and J.-M. Kim, "A generalized spatial fuzzy c-means algorithm for medical image segmentation," in *Fuzzy Systems, 2009. FUZZ-IEEE 2009. IEEE International Conference on*, 2009, pp. 409-414.
- [18] R. Venkateswaran and S. Muthukumar, "Genetic Approach on Medical Image Segmentation by Generalized Spatial Fuzzy C-Means Algorithm," in *2010 IEEE International Conference on Computational Intelligence and Computing Research*, pp. 210-213.
- [19] R. B. Dubey, M. Hanmandlu, S. K. Gupta, and S. K. Gupta, "The Brain MR Image Segmentation Techniques and use of Diagnostic Packages," *Academic Radiology*, vol. 17, pp. 658-671, 2010.
- [20] Z.-X. Ji, Q.-S. Sun, and D.-S. 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, pp. 383-397, 2011.
- [21] D. L. Pham, "Spatial models for fuzzy clustering," *Computer Vision and Image Understanding*, vol. 84, pp. 285-297, 2001.
- [22] S. Ramathilagam, R. Pandiyarajan, A. Sathya, R. Devi, and S. R. Kannan, "Modified fuzzy c-means algorithm for segmentation of T1-T2-weighted