

ارائه یک روش سطوح همتراز فازی در ناحیه بندی خودکار تصاویر پزشکی

آسیه خسروانیان^۱، محمد رحمانی منش^۲، پرویز کشاورزی^۳، سعید مظفری^۴
دانشجوی دکتری مهندسی کامپیوتر، دانشگاه سمنان، a.khosravianian@semnan.ac.ir
استادیار دانشگاه سمنان، rahmanimanesh@semnan.ac.ir
دانشیار دانشگاه سمنان، pkeshavarzi@semnan.ac.ir
دانشیار دانشگاه سمنان، mozaffari@semnan.ac.ir

چکیده - در این مقاله، یک روش خودکار جهت ناحیه بندی تصاویر پزشکی ارائه می‌شود. تصاویر پزشکی، اغلب دارای ناهمگنی شدت روشنایی هستند، لذا الگوریتم‌های موجود در ناحیه بندی تصویر، در برخورد با این مسئله دچار شکست می‌شوند. در این مقاله یک روش ناحیه بندی جدید مبتنی بر الگوریتم سطوح همتراز و خوشه بندی فازی ارائه می‌شود. در روش پیشنهادی، با خوشه بندی محلی شدت روشنایی، مدل کردن شدت روشنایی به صورت ریاضی، به کارگیری الگوریتم سطوح همتراز و انتخاب منحنی اولیه با روش فازی، ناحیه بندی و اصلاح ناهمگنی شدت روشنایی به صورت هم‌زمان و کاملاً خودکار انجام می‌شود. نتایج اعمال روش پیشنهادی بر ۴ تصویر پزشکی برتری روش پیشنهادی نسبت به سایر روش‌های پیاده‌سازی شده در این موضوع را نشان می‌دهد.
کلیدواژه- الگوریتم سطوح همتراز، تصاویر پزشکی، فازی، ناحیه بندی خودکار

جلوگیری کند.

دستگاه‌های مختلفی به تصویربرداری بافت‌های بدن می‌پردازند از جمله تصویربرداری اشعه ایکس (X-ray، CT)، تشدید مغناطیسی (MRI)، سونوگرافی، توموگرافی کامپیوتری (PET) و غیره. یکی از مشکلات رایج در تصاویر پزشکی، ناهمگنی شدت روشنایی است. این پدیده به این معناست که شدت روشنایی در یک بافت خاص متغیر است و محدوده شدت روشنایی در بافت‌های مختلف مثلاً بین شیء و پس‌زمینه تصویر همپوشانی دارد. عامل اصلی این پدیده وجود نویز یا نقص در فرایند تصویربرداری است. به‌طور کلی این پدیده می‌تواند ناشی از دستگاه باشد مانند ناهمگنی در میدان مغناطیسی ایجاد شده و یا ناشی از بیمار باشد مانند آرتیفکت حرکتی یا نحوه قرارگیری بیمار در مگنت تصویربرداری که باعث می‌شود تصویر حاصل از نظر شدت روشنایی یکنواخت نباشد. این پدیده اغلب در تصاویر پزشکی مانند CT، MRI و سونوگرافی رخ می‌دهد که ناحیه بندی دقیق و انطباق صحیح تصویر را تحت تأثیر قرار می‌دهد [۱]. لازم به ذکر است که این پدیده محدود به تصاویر پزشکی نیست و در بسیاری تصاویر طبیعی نیز رخ می‌دهد.

تاکنون روش‌های مختلفی در ناحیه بندی تصاویر دارای ناهمگنی شدت روشنایی ارائه شده است. در میان روش‌های پیشنهاد شده اخیر، روش سطوح همتراز به یکی از روش‌های محبوب تبدیل شده است. به‌طور کلی روش‌های سطوح همتراز می‌توانند به دودسته تقسیم شوند. مدل‌های مبتنی بر لبه و مدل‌های مبتنی بر منطقه. مدل‌های

۱-مقدمه

امروزه استفاده از روش‌های کامپیوتری برای تشخیص و درمان پزشکی به سرعت در حال رشد است. با پیشرفت تکنولوژی، تصاویر پزشکی به یکی از ابزارهای مهم تشخیصی برای پزشکان تبدیل شده است. تجزیه و تحلیل تصاویر پزشکی در تشخیص سریع و دقیق بیماری به پزشکان کمک می‌کند. استفاده از ابزارهای خودکار و نیمه خودکار نقش کلیدی در تشخیص و درمان بیماری‌ها دارد. تحقیق در ناحیه بندی تصویر سال‌هاست که مورد توجه محققان بوده است. هدف از ناحیه بندی تصویر این است که یک تصویر به مجموعه‌ای از مناطق معنادار، همگن و غیر همپوشان از ویژگی‌های مشابه مانند شدت روشنایی، رنگ یا بافت تقسیم شود. نتیجه ناحیه بندی یا یک برچسب یا مجموعه‌ای از خطوط است که مرزهای ناحیه را توصیف می‌کند. در حال حاضر ناحیه بندی تصویر، توسط پزشکان و رادیولوژیست‌ها به صورت دستی انجام می‌شود که وقت‌گیر، خسته کننده و مستعد خطا است. به‌علاوه روش‌های دستی قابل تکرار نیستند و نظر پزشکان در ناحیه بندی یک بافت خاص، ممکن است با یکدیگر متفاوت باشد. این امر لزوم روش‌های پردازش تصویر، برای کمک به جامعه پزشکی را نشان می‌دهد.

حجم زیاد تصاویر تولید شده در کلینیک‌ها، دلیل دیگری بر لزوم روش‌های کامپیوتری برای کمک به تشخیص زود هنگام بیماری است. به این ترتیب پزشک می‌تواند با اقدام به موقع از پیشرفت بیماری

سایه، $J: \Omega \rightarrow R$ تصویر واقعی و $n: \Omega \rightarrow R$ نشان‌دهنده نویز است. Ω دامنه تصویر است که توسط کانتور C به نواحی Ω_i تقسیم می‌شود. تصویر واقعی J در هر یک از نواحی Ω_i دارای مقادیر شدت روشنایی c_i است. n ، نویز گوسی با میانگین صفر و واریانس σ^2 فرض می‌شود.

در این روش، از اطلاعات محلی شدت روشنایی برای ناحیه بندی تصویر استفاده شده است. به این منظور اطراف هر نقطه $y \in \Omega$ یک همسایگی دایره‌ای به شعاع ρ در نظر گرفته می‌شود که به صورت زیر تعریف می‌شود:

$$O_y = \{x \mid |x - y| \leq \rho\} \quad (2)$$

ناحیه Ω_i در دامنه Ω ، یک ناحیه همسایه O_y ایجاد می‌کند که به صورت $\{O_y \cap \Omega_i: i = 1, \dots, N\}$ نشان داده می‌شود. تغییرات b در هر ناحیه ملازم است بنابراین، مقادیر $b(x)$ برای همه x ها در همسایگی دایره‌ای O_y تقریباً با $b(y)$ برابر است:

$$b(x) \approx b(y) \quad \text{for } x \in O_y \quad (3)$$

بنابراین داریم:

$$b(x)J(x) \approx b(y)c_i \quad \text{for } x \in O_y \cap \Omega_i \quad (4)$$

بنابراین بر اساس مدل تصویر در (۱) داریم:

$$I(x) \approx b(y)c_i + n(x) \quad (5)$$

for $x \in O_y \cap \Omega_i$

$n(x)$ نویز گوسی با میانگین صفر است؛ بنابراین شدت‌ها در یک مجموعه

$$I_y^i = \{I(x): x \in O_y \cap \Omega_i\} \quad (6)$$

خوشه‌ای با مرکز $m_i \approx b(y)c_i$ تشکیل می‌دهد که می‌تواند به عنوان نمونه‌هایی از توزیع گوسی با میانگین m_i در نظر گرفته شود. برای دسته‌بندی شدت‌های محلی، از الگوریتم K-Means استفاده شده است. به طور خاص برای شدت‌های $I(x)$ در همسایگی O_y الگوریتم K-Means یک فرایند تکراری، برای مینیمم کردن معیار خوشه‌بندی به فرم زیر است.

$$F_y = \sum_{i=1}^N \int_{O_y} |I(x) - m_i|^2 u_i(x) dx \quad (7)$$

در فرمول (۷)، m_i مرکز خوشه i -ام، u_i تابع عضویت ناحیه Ω_i است. در صورتی که $x \in \Omega_i$ باشد $u_i(x) = 1$ و اگر $x \notin \Omega_i$ آنگاه $u_i(x) = 0$ است. از آنجا که u_i تابع عضویت ناحیه Ω_i است می‌توان F_y را به صورت زیر بازنویسی کرد.

$$F_y = \sum_{i=1}^N \int_{\Omega_i \cap O_y} |I(x) - m_i|^2 dx \quad (8)$$

با توجه به معیار خوشه‌بندی در (۸) و تقریب مراکز خوشه با $m_i \approx b(y)c_i$ معیار خوشه‌بندی برای دسته‌بندی شدت‌ها در O_y به صورت زیر تعریف می‌شود:

مبتنی بر لبه از گرادینان تصویر برای هدایت کانتور اولیه استفاده می‌کنند که در تصاویر دارای مرز ضعیف دچار مشکل می‌شوند. از آنجا که اغلب تصاویر پزشکی دارای مرزهای ضعیف هستند، مدل‌های مبتنی بر لبه برای این تصاویر مناسب نیستند [۲]. مدل‌های مبتنی بر منطقه از یک توصیف‌کننده منطقه برای هدایت تکامل منحنی به سمت مرز شیء استفاده می‌کند. مدل‌های مبتنی بر منطقه کارایی بهتری در حضور نویز و مرزهای ضعیف دارند و نسبت به مدل‌های مبتنی بر لبه، حساسیت کمتری به مقداردهی اولیه دارند. با این حال، مدل‌های مبتنی بر منطقه سنتی با فرض همگن بودن شدت روشنایی عمل می‌کنند که برای تصاویر با ناهمگنی شدت روشنایی مناسب نیستند. لی و همکاران [۳] یک مدل سطوح همتراز جدید مبتنی بر خوشه‌بندی شدت محلی (LIC) پیشنهاد کردند که می‌تواند به صورت یک روش خوشه‌بندی محلی وزن دار K-Means برای ناهمگنی شدت روشنایی در نظر گرفته شود. این روش از اطلاعات میانگین برای ناحیه بندی تصویر استفاده می‌کند و نتایج نسبتاً قابل قبولی ارائه می‌دهد. در [۴] یک مدل کانتور فعال آماری محلی برای ناحیه بندی تصاویر با ناهمگنی شدت روشنایی و تصحیح میدان بایاس پیشنهاد شده است که عملکرد مناسبی داشته است. در [۵، ۶] یک تابع انرژی LBF با یک تابع کرنل برای استخراج دقیق اطلاعات محلی تصویر پیشنهاد شده است. در [۷] مدل مبتنی بر منطقه محلی چان-وسه می‌تواند به طور مؤثری تصاویر با ناهمگنی شدت روشنایی را ناحیه بندی کند. در [۸] یک روش سطوح همتراز سریع برای ناحیه بندی تصاویر با شدت روشنایی ناهمگن با یک پارامتر مقیاس وفقی پیشنهاد شده است. تابع انرژی پیشنهادی با سطوح همتراز دو فاز پیاده‌سازی شده است. در نهایت نتایج پیاده‌سازی شده بر تصاویر مصنوعی و تصاویر واقعی کارایی مدل را در دقت، کارایی و استحکام را نشان می‌دهد. در مقاله‌ای دیگر [۹] یک مدل کانتور فعال با عنوان ASACM مبتنی بر آنتروپی تصویر و دسته‌بندی کننده-semi naive Bayesian پیشنهاد شده است که می‌تواند به طور هم‌زمان ناحیه بندی و تخمین بایاس میدان را در تصاویر با ناهمگنی شدید شدت روشنایی انجام دهد. دیگر روش‌های ناحیه بندی تصاویر دارای ناهمگنی شدت روشنایی با الگوریتم سطوح همتراز در [۱۰-۱۶] آمده است.

هدف از پژوهش حاضر ارائه یک روش کاملاً خودکار در ناحیه-بندی تصاویر پزشکی دارای ناهمگنی شدت روشنایی است.

۲- مواد و روش‌ها

۲-۱- خوشه‌بندی محلی شدت روشنایی (LIC)

در این روش [۳]، تصویر ورودی I به صورت زیر مدل می‌شود:

$$I = bJ + n \quad (1)$$

در فرمول (۱) $b: \Omega \rightarrow R$ نشان‌دهنده میدان بایاس یا تصویر

در فرمول (۱۳)، c ، تعداد خوشه‌ها را نشان می‌دهد. U_{ik} نشان‌دهنده تابع عضویت فازی است. m ، شاخص وزن تابع عضویت فازی است که معمولاً ۲ در نظر گرفته می‌شود. v ، مجموعه مراکز خوشه‌ها و φ یک نگاشت غیرخطی ضمنی است [۱۷]. تابع کرنل K به صورت زیر تعریف می‌شود:

$$(14)$$

$$\begin{aligned} & \|\varphi(x_k) - \varphi(v_i)\|^2 \\ &= (\varphi(x_k) - \varphi(v_i))^T (\varphi(x_k) - \varphi(v_i)) \\ &= \varphi(x_k)^T \varphi(x_k) - \varphi(v_i)^T \varphi(x_k) - \\ & \quad \varphi(x_k)^T \varphi(v_i) + \varphi(v_i)^T \varphi(v_i) \\ &= K(x_k, x_k) + K(v_i, v_i) - 2K(x_k, v_i) \end{aligned}$$

در این مقاله مطابق با [۱۷] از تابع کرنل شعاعی گوسی (GRBF) استفاده می‌شود که در فرمول (۱۵) نشان داده شده است.

$$K(x, y) = \exp\left(-\frac{\|x - y\|^2}{\sigma^2}\right) \quad (15)$$

با توجه به (۱۵) داریم:

$$K(x, x) = 1 \quad (16)$$

فرمول نهایی با جایگذاری به صورت زیر به دست می‌آید:

$$J_m = 2 \sum_{i=1}^c \sum_{k=1}^N U_{ik}^m (1 - K(x_k, v_i)) \quad (17)$$

پس از مینیمم کردن تابع هدف J_m مطابق با روش FCM، U_{ik} و v_i به ترتیب با فرمول‌های (۱۸) و (۱۹) به دست می‌آید.

$$U_{ik} = \frac{(1 - K(x_k, v_i))^{-1/m-1}}{\sum_{j=1}^c (1 - K(x_k, v_j))^{-1/m-1}} \quad (18)$$

$$v_i = \frac{\sum_{k=1}^N U_{ik}^m K(x_k, v_i) x_k}{\sum_{k=1}^N U_{ik}^m K(x_k, v_i)} \quad (19)$$

شبه کد KFCM در جدول ۱ نشان داده شده است.

جدول ۱- شبه کد الگوریتم KFCM [۱۷]
1. Initialize $c, t_{max}, m > 1, \varepsilon > 0$ for positive constanths.
2. Initialize the membership matrix u_{ik}^0
3. For $t = 1$ to t_{max} do:
a) Update all prototype v_i^t with Eq.19
b) Update all membership u_{ik}^t with Eq. 18
c) Compute $E^t = \max_{i,k} u_{ik}^t - u_{ik}^{t-1} $, if $E^t \leq \varepsilon$, stop;
End

$$\mathcal{E}_y \quad (9)$$

$$= \sum_{i=1}^N \int_{\Omega_i \cap O_y} K(y - x) |I(x) - b(y)c_i|^2 dx$$

در فرمول (۹) $K(y - x)$ به عنوان یک تابع پنجره نامنفی معرفی می‌شود که به آن، تابع کرنل گفته می‌شود. برای $x \notin O_y$ ، $K(y - x) = 0$ است. با این تابع پنجره، معیار خوشه‌بندی \mathcal{E}_y می‌تواند به صورت زیر بازنویسی شود:

$$\mathcal{E}_y \quad (10)$$

$$= \sum_{i=1}^N \int_{\Omega_i} K(y - x) |I(x) - b(y)c_i|^2 dx$$

تابع معیار خوشه‌بندی محلی \mathcal{E}_y شدت‌ها در محدوده O_y داده شده $\{O_y \cap \Omega_i\}_{i=1}^N$ را دسته‌بندی می‌کند.

مقادیر کوچک‌تر \mathcal{E}_y ، دسته‌بندی بهتری را می‌دهد. پارتیشن بهینه $\{\Omega_i\}_{i=1}^N$ از دامنه Ω ، به عنوان یک تابع معیار خوشه‌بندی محلی \mathcal{E}_y برای همه y ها در دامنه Ω کمینه می‌شود؛ بنابراین، نیاز است که \mathcal{E}_y برای همه y ها در دامنه Ω کمینه شود. بدین منظور می‌توان تابع انرژی $E \triangleq \int \mathcal{E}_y dy$ را تعریف کرد.

$$E \quad (11)$$

$$\triangleq \int \left(\sum_{i=1}^N \int_{\Omega_i} K(y - x) |I(x) - b(y)c_i|^2 dx \right) dy$$

کمینه کردن این تابع انرژی در حالت معمول مشکل است. لذا از الگوریتم سطوح همتراز برای کمینه کردن آن استفاده شده است.

۲-۲- خوشه‌بندی فازی مبتنی بر هسته (KFCM)

به نقل از [۱۷] الگوریتم خوشه‌بندی C-Means فازی مبتنی بر کرنل، یک روش مقاوم به نویز است که در سال ۲۰۰۴ توسط Zhang و همکاران در مقاله [۱۸] ارائه شده است. در این مقاله، معیار فاصله اقلیدسی در روش C-Means فازی (FCM) با یک معیار مبتنی بر کرنل جایگزین شده است.

همان‌طور که در [۱۸] ذکر شده است، در FCM استاندارد، تابع هدف برای بخش‌بندی مجموعه داده $\{x_k\}_{k=1}^N$ به c خوشه با فرمول (۱۲) داده شده است.

$$J_m = \sum_{i=1}^c \sum_{k=1}^N U_{ik}^m \|x_k - v_i\|^2 \quad (12)$$

در فرمول (۱۲)، $\{v_i\}_{i=1}^c$ مراکز خوشه‌ها را نشان می‌دهد. در روش KFCM، این فرمول به صورت زیر تغییر یافته است.

$$J_m = \sum_{i=1}^c \sum_{k=1}^N U_{ik}^m \|\varphi(x_k) - \varphi(v_i)\|^2 \quad (13)$$

۲-۳- روش پیشنهادی

تصاویر انتخاب‌شده، تصاویر دارای ناهمگنی شدت روشنایی هستند که در شکل ۱ نشان داده شده است.




شکل ۱: الف- yeast cells، ب- vessel، ج- heart_ct، د- hand. خروجی حاصل از اجرای روش پیشنهادی (FLIC)، بر تصاویر انتخابی در شکل ۲ نشان داده شده است.

در این شکل، اولین ستون سمت راست تصویر اصلی را نشان می‌دهد و دیگر ستون‌ها به ترتیب خروجی حاصل از روش KFCM، LIC و روش پیشنهادی FLIC را نشان می‌دهد. همان‌طور که در شکل ۲ نشان داده شده است، روش ترکیبی FLIC نتایج بهتری نسبت به روش LIC به تنهایی داشته است. به علاوه روش پیشنهادی قادر است بایاس فیلد را به‌طور هم‌زمان تخمین بزند که در شکل ۳ مشاهده می‌شود.

شکل ۳: تخمین و تصحیح بایاس در روش پیشنهادی


به‌منظور ارزیابی کارایی روش پیشنهادی از ارزیابی کیفی استفاده شده است و خروجی حاصل از FLIC با روش‌های چان-وسه [۲۰]، RSF [۲۱] و LIC [۳] در شکل ۴ مقایسه شده است.



روش LIC، علی‌رغم نتایج قابل قبولی که در مقاله [۳] به آن اشاره شده است دارای اشکالاتی است از جمله، این روش حساس به انتخاب منحنی اولیه است و با تغییر منحنی اولیه، نتایج حاصل از ناحیه بندی دستخوش تغییر می‌شود و ممکن است در مینیمم محلی قرار گیرد؛ بنابراین در مواردی نتایج نادرست در تخمین بایاس میدان و ناحیه بندی دقیق دارد. به علاوه انتخاب منحنی اولیه به صورت دستی، یک روش ناحیه بندی نیمه‌خودکار را نتیجه می‌دهد. از آنجاکه در این مقاله، هدف دستیابی به یک ناحیه بندی کاملاً خودکار است، لذا سعی می‌شود با این چالش مقابله شود. به این منظور از روش KFCM به شرحی که گذشت، برای انتخاب کانتور اولیه در روش LIC استفاده می‌شود روش حاصل FLIC نامیده می‌شود. در این روش، ابتدا تصویر ورودی، توسط روش فازی ذکر شده ناحیه بندی می‌شود و نتایج ناحیه بندی به‌عنوان منحنی اولیه به الگوریتم LIC ارائه می‌شود. منحنی اولیه حاصل از ناحیه بندی تقریبی انجام شده، توسط روش سطوح هم‌تراز تکامل داده می‌شود تا در نهایت یک روش ناحیه بندی دقیق و بدون دخالت کاربر را نتیجه دهد.

۱- یافته‌ها

روش پیشنهادی، با استفاده از کامپیوتری با سیستم‌عامل ویندوز ۷، حافظه ۴ گیگابایتی، پردازشگر Core i5 و نرم‌افزار متلب نسخه ۲۰۱۸ شبیه‌سازی شده است. به منظور بررسی کارایی روش پیشنهادی از ۴ تصویر پزشکی [۱۹ و ۱۰] استفاده شده است. پارامترهای مدل KFCM مطابق با [۱۷] تنظیم شده است به این ترتیب پارامترهای m و σ ثابت در نظر گرفته شده است. پارامتر c که تعداد خوشه‌ها را نشان می‌دهد در هر تصویر متفاوت است به‌عنوان مثال این پارامتر در تصویر دست، ۲ در نظر گرفته شده است. در روش LIC از الگوریتم سطوح هم‌تراز دو فاز استفاده شده است؛ بنابراین $N=2$ در نظر گرفته شده است. پارامتر σ ، مطابق با [۳]، عدد ۴ در نظر گرفته شده است. تعداد تکرارهای الگوریتم ۱۰۰ در نظر گرفته شده است.




خروجی حاصل از FLIC

خروجی حاصل از LIC

خروجی حاصل از KFCM

تصویر اصلی

شکل ۲: خروجی حاصل از روش پیشنهادی




خروجی حاصل از FLIC

تصویر پس از اصلاح بایاس

تخمین بایاس

تصویر اصلی

شکل ۳: تخمین و تصحیح بایاس در روش پیشنهادی



خروجی حاصل از روش
FLIC

خروجی حاصل از روش
CV: Chan-Vesse
دو سطر اول برگرفته
از [۱۰]

خروجی حاصل از روش RSF
دو سطر اول برگرفته از [۱۰]


خروجی حاصل از روش LIC
دو سطر اول برگرفته از [۱۰]

تصویر اصلی و منحنی اولیه

شکل ۴: مقایسه خروجی روش پیشنهادی با روش های LIC, RSF, CV

روشنایی ضعیف عمل می‌کند. روش RSF حساس به انتخاب منحنی اولیه است همچنین قادر به حذف بایاس از تصاویر دارای ناهمگنی شدت روشنایی نیست. روش LIC نیز حساس به انتخاب منحنی اولیه و اندازه ناحیه محلی است. به علاوه روش‌های ذکر شده نیمه خودکار هستند و نیازمند مداخله کاربر است.

همان‌طور که در شکل ۴ مشاهده می‌شود روش پیشنهادی، خروجی قابل قبولی داشته است ضمن اینکه این روش، یک روش خودکار است که حساس به انتخاب منحنی اولیه نیست. حساسیت به انتخاب منحنی اولیه به این معناست که با تغییر شکل یا مکان منحنی نتیجه ناحیه بندی متفاوت می‌شود (شکل ۵). روش چان-وسه در برخورد با تصاویر دارای ناهمگنی شدت



شکل ۵: حساسیت به انتخاب منحنی اولیه در روش های CV، RSF و LIC [۱۰]

ناحیه بندی خودکار بدون مداخله کاربر از این جهت حائز اهمیت است که می‌تواند در شرایط خستگی یا عدم تجربه کافی پزشک، به وی در تشخیص بهتر بیماری کمک کند. به‌علاوه نرم‌افزارهای طراحی شده بر اساس نتایج حاصل از این پژوهش می‌تواند در آموزش دانشجویان پزشکی، به‌خصوص کارشناسان رادیولوژی مورد استفاده قرار گیرد.

از معایب روش پیشنهادی این است که در ناحیه بندی تصاویر رنگی موفق عمل نمی‌کند. از آنجاکه اکثر تصاویر پزشکی، خاکستری هستند این مسئله مشکلی ایجاد نمی‌کند.

روش FLIC ارائه شده در این پژوهش، یک روش سطوح همتراز دو فاز است. پیشنهاد می‌شود به‌عنوان کار آینده این روش را به سطوح همتراز چند فاز گسترش داد. همچنین می‌توان از دیگر روش‌های فازی برای انتخاب منحنی اولیه استفاده کرد.

۴- نتیجه‌گیری

در این مقاله یک روش جدید سطوح همتراز فازی با عنوان FLIC ارائه شد.

روش حاصل که ترکیب دو روش LIC و KFCM بود، قادر است تصاویر دارای ناهمگنی شدت روشنایی را بدون مداخله کاربر و به‌صورت کاملاً خودکار ناحیه بندی کند که از مزایای روش پیشنهادی در این پژوهش است. همچنین FLIC قادر است ناحیه بندی و تخمین بایاس را به‌صورت هم‌زمان انجام دهد. لازم به ذکر است که انتخاب دقیق‌تر منحنی اولیه توسط روش فازی باعث افزایش سرعت و دقت در ناحیه بندی تصویر شده است. از دیگر مزایای روش پیشنهادی این است که پارامترهای این روش، برای تصاویر مختلف ثابت بوده و نیاز به تغییر ندارد. این امر مؤید قدرت تعمیم روش پیشنهادی است.

مراجع

[3] Li, C., et al., A level set method for image segmentation in the presence of intensity inhomogeneities with application to MRI. IEEE Transactions on Image Processing, 2011. 20(7): p. 2007.

[4] Zhang, K., et al., A local active contour model for image segmentation with intensity inhomogeneity. arXiv preprint arXiv:1305.7053, 2013.

[5] C. Li, C. Kao, J. Gore, Z. Ding, "Implicit active contours driven by local binary fitting energy," In: IEEE Conference on Computer Vision and Pattern Recognition, 2007, pp. 1-7.

[1] George, M.M., S. Kalaivani, and M. Sudhakar, A non-iterative multi-scale approach for intensity inhomogeneity correction in MRI. Magnetic resonance imaging, 2017. 42: p. 43-59.

[2] Min, H., et al., A polynomial piecewise constant approximation method based on dual constraint relaxation for segmenting images with intensity inhomogeneity. Pattern Recognition, 2018. 73: p. 15-32.

- [18] Zhang, D.-Q. and S.-C. Chen, A novel kernelized fuzzy c-means algorithm with application in medical image segmentation. *Artificial intelligence in medicine*, 2004. 32(1): p. 37-50.
- [19] Alipour, S. and J. Shanbehzadeh, Fast automatic medical image segmentation based on spatial kernel fuzzy c-means on level set method. *Machine vision and applications*, 2014. 25(6): p. 1469-1488.
- [20] Chan, T. and L. Vese. An active contour model without edges. in *International Conference on Scale-Space Theories in Computer Vision*. 1999. Springer.
- [21] C. Li, C.-Y. Kao, J.C. Gore, Z. Ding, Minimization of region-scalable fitting energy for image segmentation, *IEEE Trans. Image Process.* 17 (10) (2008) 1940–1949.
- [6] Li, C., et al., Minimization of region-scalable fitting energy for image segmentation. *IEEE transactions on image processing: a publication of the IEEE Signal Processing Society*, 2008. 17(10): p. 1940.
- [7] Liu, S. and Y. Peng, A local region-based Chan–Vese model for image segmentation. *Pattern Recognition*, 2012. 45(7): p. 2769-2779.
- [8] Huang, G., H. Ji, and W. Zhang, A fast level set method for inhomogeneous image segmentation with adaptive scale parameter. *Magnetic resonance imaging*, 2018.
- [9] Cai, Q., et al., An adaptive-scale active contour model for inhomogeneous image segmentation and bias field estimation. *Pattern Recognition*, 2018.
- [10] Feng, C., D. Zhao, and M. Huang, Image segmentation and bias correction using local inhomogeneous intensity clustering (LINC): a region-based level set method. *Neurocomputing*, 2017. 219: p. 107-129.
- [11] Guo, Z.-z., et al., Local Motion Intensity Clustering (LMIC) Model for Segmentation of Right Ventricle in Cardiac MRI Images. *IEEE Journal of Biomedical and Health Informatics*, 2018.
- [12] Li, C., et al. MRI tissue classification and bias field estimation based on coherent local intensity clustering: A unified energy minimization framework. in *International conference on information processing in medical imaging*. 2009. Springer.
- [13] Li, C., J.C. Gore, and C. Davatzikos, Multiplicative intrinsic component optimization (MICO) for MRI bias field estimation and tissue segmentation. *Magnetic resonance imaging*, 2014. 32(7): p. 913-923.
- [14] Tu, X., et al., MR image segmentation and bias field estimation based on coherent local intensity clustering with total variation regularization. *Medical & biological engineering & computing*, 2016. 54(12): p. 1807-1818.
- [15] Zhang, K., et al., A level set approach to image segmentation with intensity inhomogeneity. *IEEE transactions on cybernetics*, 2016. 46(2): p. 546-557.
- [16] Zhang, H., X. Ye, and Y. Chen, An efficient algorithm for multiphase image segmentation with intensity bias correction. *IEEE Transactions on Image Processing*, 2013. 22(10): p. 3842-3851.
- [17] Rastgarpour, M., S. Alipour, and J. Shanbehzadeh. Improved fast two cycle by using KFCM clustering for image segmentation. in *Proceedings of the 7th International Multiconference of Engineers and Computer Scientists*. 2012.