

بخش بندی تصاویر MRI مغز با استفاده از الگوریتم خوشه بندی فازی KPFCM بهبود یافته

افشین شعیبی^۱، جلیل شیرازی^۲

^۱ دانشجوی کارشناسی ارشد مخابرات، دانشگاه آزاد اسلامی واحد گناباد

^۲ استادیار مخابرات، دانشگاه آزاد اسلامی واحد گناباد

نام و نشانی ایمیل نویسنده مسئول:

افشین شعیبی

چکیده

یکی از مهمترین مشکلات در تحلیل تصاویر پزشکی و از جمله تصاویر رزونانس مغناطیسی (MRI)، موضوع بخش بندی می باشد. رشد نامحدود و غیر قابل کنترل سلولی در مغز باعث ایجاد ناهنجاری های مغزی و از جمله تومور می شود. بیماریهای مغزی اگر تحت درمان مناسب و به موقع قرار نگیرند، می توانند باعث آسیب جدی در مغز شوند که گاهی ممکن است باعث مرگ بیمار شوند. هدف از بخش بندی تصاویر رزونانس مغناطیسی، بخش بندی تصویر با هدف جداکردن بافت های مختلف مغز می باشد. در این مقاله از یک الگوریتم خوشه بندی فازی PFCM مبتنی بر کرنل بهبود یافته جهت بخش بندی تصاویر رزونانس مغناطیسی مغز (MRI) استفاده شده است. نتایج تحقیق نشان می دهد دقت بخش بندی در روش پیشنهادی، در مقایسه با روش های مشابه فازی دارای دقت ۹۴٫۸۳ درصد است که دقت بالایی است.

واژگان کلیدی: بخش بندی، خوشه بندی، الگوریتم فازی KPFCM بهبود یافته، تصویر MRI مغز

مقدمه

بخش‌بندی تصویر یک پردازش میانی در مباحث پردازش تصویر است که نقش مهمی در تحلیل تصاویر پزشکی دارد. هدف اصلی از پروسه ناحیه بندی، افراز تصویر به نواحی معنادار می باشد. با توجه به اینکه تحقیقات زیادی در زمینه ناحیه بندی تصاویر پزشکی انجام شده است اما توسعه تحقیقات در این زمینه همچنان ادامه دارد. ناحیه بندی تصاویر پزشکی به دلیل ناهمگونی بافت، اثر حجم جزئی، نویز، آرتیفکت و تنوع ساختار بیماری‌های مختلف در بیماران گوناگون با مشکل مواجه است. علیرغم پیشرفت‌های قابل توجه در سال‌های اخیر و ارائه نسخه های توسعه یافته آن الگوریتم های ناحیه بندی، هنوز هم نمی توان مدل فعالی را معرفی نمود که به صورت ذاتی دارای ویژگی‌هایی چون مقاوم بودن در برابر نویز، سرعت بالا، بازسازی گسستگی‌های مرز و استخراج مرزهای ضعیف به ویژه در کنار مرزهای قوی باشد.

۱-۱ معرفی

پیشرفت تصویر برداری پزشکی و روش های تصویر برداری نقش مهمی در ارزیابی بیماران مبتلا به تومور مغزی ایفا می کند و نقش مهمی در برابر کمک به بیماران را دارد [1, 2]. در سال های اخیر ظهور روش های جدید تصویربرداری مانند اشعه ایکس، سونوگرافی، توموگرافی کامپیوتری و تصویربرداری رزونانس مغناطیسی نه تنها جنبه های دقیق و کامل تومورهای مغزی را به ما نشان می دهد. در میان این روش ها، تصاویر تشدید مغناطیسی به علت غیر تهاجمی بودن عملیات تهیه تصاویر و کنتراست خوب از بافت نرم بطور خاصی در برابر سایر روش های تصویر برداری مورد توجه قرار گرفته است [3]. این تصاویر اطلاعات ارزشمندی را در مورد شکل، اندازه و محل تومورهای مغزی، بدون قرار دادن فرد بیمار در معرض تابش یونیزاسیون بالا را برای ما فراهم می کند. پزشکان بالینی از روی تصاویر تشدید مغناطیسی تومورهای مغزی را ارزیابی و درمان می کنند. بنابراین ارزیابی تومورهای مغزی با روش های تصویربرداری در حال حاضر یکی از مسائل کلیدی از بخش های رادیولوژی است. در حال حاضر یکی از مشکلات پزشکان و رادیویست ها در تشخیص دقیق نواحی تومورهای مغزی هستند [4]. زیرا عواملی مانند نویز و همچنین عوامل انسانی باعث بروز خطا در تشخیص محل دقیق تومورهای مغزی می گردد. در این مقاله از یک روش جدید جهت بخش بندی اتوماتیک تصاویر رزونانس مغناطیسی با استفاده از خوشه بندی فازی KPFM بهبود یافته استفاده شده است. در ادامه این مقاله، در بخش ۲، الگوریتم FCM معرفی شده است. در بخش ۳، الگوریتم خوشه بندی FCM بهبود یافته ارائه خواهد شد. نتایج تجربی و مقایسه با سایر روش ها در بخش ۴ ارائه خواهد شد و در نهایت در بخش ۵، نتایج حاصل از الگوریتم پیشنهادی ارائه خواهد شد.

۲. الگوریتم خوشه بندی FCM

الگوریتم های خوشه بندی چون نیاز به داده های آموزش ندارند، به عنوان روش هایی بدون سرپرست شناخته شده اند [5]. مشابه با ناحیه بندی تصویر، خوشه یابی درگیر تقسیم یک مجموعه ای از شیء‌ها به گروه‌های (خوشه‌ها) است، بطوری که شیء‌ها در گروه یکسان نسبت به شیء‌ها در سایر گروه‌ها بیشتر به هم شبیه‌اند. اغلب، شباهت توسط یک مقیاس فاصله مثل فاصله اقلیدسی یا فاصله منهن متن مشخص می‌شود [6]. با تعداد مشخص از شاخه‌ها k و تعداد داده‌ها N ، ماتریس

$$U_{K \times N} = [u_{ik}], k = 1, \dots, C, \text{ and } i = 1, \dots, N \quad (1)$$

مجموعه داده را نمایش می‌دهد، بطوریکه u_{ki} داده x_i را در خوشه C_k توصیف می‌کند. خوشه بندی را سخت گوییم اگر u_{ki} فقط دو مقدار ۱ (متعلق است به) و ۰ (متعلق نیست به) داشته باشد که توسط توابع عضویت بولین مقدار دهی می‌شود، و نیز خوشه بندی را فازی گوییم اگر u_{ik} مقادیری بین صفر و یک داشته باشد که توسط توابع عضویت پیوسته مقدار دهی می‌شود. اگر v_k مرکز خوشه C_k باشد آنگاه v_k به صورت زیر محاسبه می‌شود:

$$v_k = \frac{\sum_{i=1}^N u_{ik} x_i}{\sum_{i=1}^N u_{ki}}, k = 1, \dots, C \quad (2)$$

معروف ترین الگوریتم خوشه بندی سخت، الگوریتم K-Means می باشد. در این الگوریتم، مقدار عضویت u_{ik} باید عبارت زیر را برآورده کند:

$$\forall k, \forall i, u_{ik} = \{0,1\}, \forall i, \sum_{k=1}^c u_{ik} = 1, \text{ and } \forall k, 0 < \sum_{i=1}^N u_{ki} < N. \quad (3)$$

با استفاده از جستجو یک تابع فاصله d_{ki} برای مثال، فاصله اقلیدسی

$$d_{ik} = ||X_i - V_k|| \quad (4)$$

است، سپس باید یک U پیدا کنیم که قید عضویت در رابطه (۵) را برآورده کند و تابع زیر را مینیمم کند.

$$J(U, V) = \sum_{k=1}^c \sum_{x_i \in C_k} d_{ki}^2. \quad (5)$$

یک روش رایج برای پیدا کردن U ، استفاده کردن از روش تکراری است که توسط لیوید پیشنهاد گردید. الگوریتم Fuzzy c-means یک تعمیمی از k-Means است [7]. برخلاف عضویت سخت در k-Means، این الگوریتم به نقاط داده اجازه می‌دهد به بیشتر از یک خوشه تعلق داشته باشند، که این یک درجه اطمینان عضویت به هر خوشه را نشان می‌دهد. مقدار عضویت u_{ik} باید برآورده کند:

$$\forall k, \forall i, 0 < u_{ik} < 1, \forall i, \sum_{k=1}^c u_{ik} = 1, \text{ and } \forall k, 0 < \sum_{i=1}^N u_{ki} < N. \quad (6)$$

که $\{v_i\}_{i=1}^c$ مراکز یا نمونه های اولیه از خوشه ها است و آرایه ی $\{u_{ki}\} (= U)$ نشان دهنده ی یک خوشه بندی ماتریس رضایت بخش زیر است:

$$U \in \left\{ u_{ik} \in [0,1] \mid \sum_{k=1}^c u_{ik} = 1, \forall k \text{ and } 0 < \sum_{i=1}^N u_{ik} < N, \forall i \right\} \quad (7)$$

به طوری که $m \geq 1$ درجه فازی بودن را کنترل می‌کند. اگر m نزدیک به ۱ باشد، آنگاه به خوشه با نزدیک‌ترین مرکز به نقطه، وزن بیشتری نسبت به سایر خوشه‌ها می‌دهد. هر چه m کوچک باشد به حالت فازی نزدیک می‌شویم و اگر m بزرگ باشد یک حالت سخت داریم. برخلاف عضویت سخت در k-means، مقدار عضویت و مراکز خوشه‌ها بصورت زیر محاسبه می‌شوند:

$$u_{ik}^{(t+1)} = \frac{d_{ik}^{-2/(m-1)}}{\sum_{j=1}^c d_{ij}^{-2/(m-1)}} \quad (8)$$

$$c_k^{(t+1)} = \frac{\sum_{i=1}^n (u_{ik}^{(t+1)})^m \vec{x}_i}{\sum_{i=1}^n (u_{ik}^{(t+1)})^m} \quad (9)$$

الگوریتم خوشه بندی FCM در این بخش مورد بررسی قرار گرفت. این الگوریتم برای داده های نویزی عملکرد مناسبی را ندارد. در ادامه به بررسی روش پیشنهادی می پردازیم.

۳. روش پیشنهادی

در قسمت قبل الگوریتم خوشه بندی FCM مورد بررسی قرار گرفت. این الگوریتم در دسته الگوریتم های خوشه بندی بدون کرنل قرار دارد. در ادامه ابتدا الگوریتم خوشه بندی PCM مورد بررسی قرار خواهد گرفت. در ادامه روش های مبتنی بر کرنل در خوشه بندی مورد بررسی قرار می گیرد و در نهایت روش پیشنهادی ارائه خواهد شد.

۳-۱. الگوریتم خوشه بندی PCM

کالر و همکاران [8] و [9] رهیافت فازی PCM را برای مقاوم نمودن FCM در برابر داده های پرت و نویز دار ارائه کردند. تابع هدف الگوریتم مورد نظر به صورت رابطه (۱۰) تعریف می شود.

$$J_f(X, U_f, C) = \sum_{i=1}^c \sum_{k=1}^n u_{ik}^m d_{ik}^2 + \sum_{i=1}^c \eta_i \sum_{j=1}^n (1 - u_{ij})^m \quad (10)$$

افزوده شدن عبارت دوم به رابطه فوق، مانع میل کردن تمام درجه عضویت ها به سمت صفر می شود. زیرا با کم کردن مقدار u_{ij} در عبارت اول معکوس آن یعنی $(1 - u_{ij})$ در عبارت دوم افزایش خواهد یافت. در رابطه فوق $\eta_i > 0, (i = 1, \dots, c)$ ثابتی است که برای هر خوشه باید تعریف شود تا تعادل بین دو عبارت را برقرار سازد. یعنی η_i آخرین نقطه مرز فازی هر خوشه را مشخص می نماید. پس با این پارامتر می توان میزان گسترش خوشه ها را کنترل نمود. برای مشخص نمودن شکل خوشه باید مقدار η_i تخمین زده شود:

$$\eta_i = \frac{\sum_{i=1}^n u_{ik}^m d_{ij}^2}{\sum_{i=1}^n u_{ik}^m} \quad (11)$$

در روش PCM با حذف محدودیت نرمالسازی، تعلق داده i تنها به فاصله بین همان داده و خوشه i وابسته است (و از فاصله داده تا خوشه های دیگر مستقل است). میزان تعلق داده به هر خوشه نیز بوسیله پارامتر η_i کنترل می شود. ما از این ایده در روش پیشنهادی خود در ادامه استفاده خواهیم کرد.

۳-۲. الگوریتم خوشه بندی KPFCM

در قسمت های قبل الگوریتم های خوشه بندی FCM و PCM مورد بررسی قرار گرفتند. این الگوریتم ها در دسته الگوریتم های خوشه بندی بدون کرنل قرار دارند. در ادامه مختصری در مورد روش های خوشه بندی مبتنی بر کرنل بحث خواهد شد. یک دسته ی مهم از روش های نوین در بینایی ماشین و به طور کلی هوش مصنوعی، روش های مبتنی بر کرنل می باشد [10]. کارایی این دسته از روش ها زمانی به خوبی مشخص می شود که با سایر الگوریتم های بینایی ماشین و هوش مصنوعی ترکیب می شوند. در روش های خوشه بندی فازی، استفاده از روش های کرنل تریک باعث توانایی الگوریتم در حذف نویز و تحلیل داده مورد نظر می باشد. الگوریتم KPFCM تعمیم یافته الگوریتم های FCM و PCM می باشد. الگوریتم KPFCM همان الگوریتم PCM فازی مبتنی بر کرنل می باشد [11]. تابع هدف الگوریتم PFCM بصورت زیر است.

$$(u, T, V) = \sum_{i=1}^c \sum_{k=1}^n (a u_{ik}^m + b t_{ik}^n) D_{ik}^2 + \sum_{i=1}^c \gamma_i \sum_{k=1}^n (1 - t_{ik})^m \quad (12)$$

فقط هسته گووسی در خوشه بندی های فازی به کار می رود، به دلیل این که برای هسته گووسی $K(x, x) = 1$ است بنابراین یک کرنل گووسی را می توان بصورت زیر تعریف کرد:

$$\begin{aligned} \|\Phi(x_k) - \Phi(v_i)\|^2 &= (\Phi(x_k) - \Phi(v_i))^T (\Phi(x_k) - \Phi(v_i)) \\ &= \Phi(x_k)^T \Phi(x_k) - \Phi(v_i)^T \Phi(x_k) - \Phi(x_k)^T \Phi(v_i) + \Phi(v_i)^T \Phi(v_i), \\ &= K(x_k, x_k) + K(v_i, v_i) - 2K(x_k, v_i) \end{aligned} \quad (13)$$

$$\|\Phi(x_k) - \Phi(v_i)\|^2 = 2(1 - K(x_k, v_i)) \quad (14)$$

با جایگذاری تابع کرنل (۱۴) در رابطه (۱۲) داریم:

$$J_{m,\eta}(U, T, V) = 2 \sum_{i=1}^c \sum_{k=1}^n (au_{ik}^m + bt_{ik}^\eta)(1 - k(x_k, v_i)) + \sum_{i=1}^c \gamma_i \sum_{k=1}^n (1 - t_{ik})^\eta \quad (15)$$

در این رابطه $a, b > 0$ و همچنین $m, \eta > 1$ و $\gamma_i > 0$ با محدودیت های داده شده، $J_{m,\eta}^\phi$ می تواند با استفاده از ضرب لاگرانژ حل شود. در اینجا به علت محدودیت های فضایی مشتق رابطه حذف شده است. بنابراین کاهش رابطه (۱۵) منجر به شرایط لازم زیر می شود که البته شرایط کافی نیستند و برای $J_{m,\eta}^\phi$ یک مینیمم محلی طبق روابط زیر بدست می آید.

$$u_{ik} = \frac{(1 - K(x_k, v_i))^{-1/(m-1)}}{\sum_{j=1}^c (1 - K(x_k, v_j))^{-1/(m-1)}} \forall i, k \quad (16)$$

$$t_{ik} = \left[1 + \frac{2b}{\gamma_i} (1 - k(x_k, v_i))^{-1/(m-1)} \right]^{-1} \forall i, k \quad (17)$$

و رابطه محاسبه مراکز بصورت زیر می باشد.

$$v_i = \frac{\sum_{k=1}^n (au_{ik}^m + bt_{ik}^\eta) k(x_k, v_i) X_k}{\sum_{k=1}^n (au_{ik}^m + bt_{ik}^\eta) k(x_k, v_i)} \quad (18)$$

در نهایت مقدار γ_i در تابع هدف KPFCM رابطه (۱۵) بصورت زیر محاسبه می شود.

$$\gamma_i = \frac{2 \sum_{k=1}^n (1 - k(x_k, v_i))}{\sum_{k=1}^n u_{ik}^m} \quad (19)$$

الگوریتم KPFCM در این قسمت مورد بررسی قرار گرفت. در ادامه به بررسی روش پیشنهادی IKPFCM پرداخته می شود.

۳-۳. الگوریتم خوشه بندی IKPFCM

در قسمت قبل الگوریتم خوشه بندی KPFCM مورد بررسی قرار گرفت. این الگوریتم در دسته الگوریتم های خوشه بندی مبتنی بر کرنل قرار دارد. الگوریتم خوشه بندی فازی KPFCM نسبت به داده های پرت دقت بالایی دارد. ما در این قسمت قصد داریم الگوریتم خوشه بندی فازی KPFCM را از لحاظ حساسیت به نویز بهبود دهیم. از رابطه (۱۴) چنین دریافت شد که نرم اقلیدسی در H می تواند با استفاده از تابع کرنل گووسی محاسبه شود. همچنین در [12, 13] نشان داده شده است که نسبت بسط کرنل گووسی توسط رابطه (۲۰) تعریف می شود.

$$\frac{\|\Phi(x) - \Phi(y)\|^2}{\|x - y\|^2} \quad (20)$$

اینجا دلالت بر این موضوع دارند که σ در کرنل گووسی رابطه (۱۴) نقش مهمی در پراکندگی داده کلاس ها دارد. با این وجود، اکثریت روش های خوشه بندی فازی که از روش های کرنل استفاده می کنند از مقادیر ثابت پارامترهای عرض گووسی خود استفاده کرده اند. با علم بر این موضوع که نسبت بسط توسط پارامتر عرض گووسی تعیین می شود و همچنین با احاطه بر این حقیقت که پارامتر، پراکندگی در کلاس داده را مشخص می کند، ما از واریانس پایگاه داده مورد نظر استفاده می کنیم تا σ را از رابطه (۱۴) تخمین بزنیم که این موضوع در رابطه (۲۱) نشان داده شده است.

$$\hat{\sigma} = \left[\frac{1}{n} \sum_{j=1}^n \|X_j - \bar{X}\|^2 \right]^{1/2} \quad (21)$$

که در رابطه فوق

$$\bar{X} = \frac{1}{n} \sum_{j=1}^n X_j \quad (22)$$

با تغییرات انجام شده در الگوریتم خوشه بندی KPFCM، الگوریتم خوشه بندی فازی KPFCM بهبود یافته IKPFCM ارائه شد. این الگوریتم برخلاف KPFCM دقت بالاتری برای حذف نویز تصاویر رزونانس مغناطیسی را از خود نشان می دهد. در ادامه نتایج تجربی در مورد الگوریتم پیشنهادی ارائه می شود.

۴. آزمایشات تجربی


در این بخش، آزمایشات انجام شده بر روی دو نوع تصاویر حقیقی کلینیکی و مجازی انجام شده است. جهت اعتبارسنجی الگوریتم پیشنهادی، الگوریتم پیشنهادی با شش الگوریتم خوشه بندی فازی مقایسه شده است. صحت بخش بندی در این مقاله براساس معیار JS انجام شده است که رابطه آن بصورت زیر است:

$$JS(S_1, S_2) = \frac{|S_1 \cap S_2|}{|S_1 \cup S_2|} = \frac{|S_1 \cap S_2|}{|S_1| + |S_2| - |S_1 \cap S_2|} \quad (23)$$

که در آن S_1 نشان دهنده ی مجموعه ای از پیکسل های متعلق به یک کلاس می باشد که با یک روش خاص یافت شده اند. و S_2 نشان دهنده ی مجموعه ای از پیکسل های در یک کلاس بسیار شبیه به تصویر تقسیم بندی شده ی مرجع می باشد. معیار استفاده شده در این قسمت برای دقت و صحت بخش بندی به معیار جاکارد معروف است. این معیار یکی از محبوب ترین معیارهای محاسبه دقت بخش بندی نیز می باشد.


۴-۱. آزمایش بر روی تصاویر مصنوعی مغز

آزمایشات زیر، با کمک گرفتن از دیتابیس شبیه سازی شده ی مغز انجام شده اند که شامل مجموعه حجم های MR واقعی است که از پایگاه داده BrainWeb دریافت شده است. آزمایش اول جهت بخش بندی یک تصویر T1 وزن دار با سایز 181×181 است. این تصویر به ۲٪ نویز گوسی آغشته شده است. شکل (۱)، یک تصویر T1 وزن دار را نشان می دهد.



شکل ۱: تصویر وزن دار T1 با واقعیت مجازی


همانطور که قبلا گفته شد، مغز انسان شامل سه بخش است. بنابراین تصویر را به ازای سه کلاس را باید بخش بندی کرد. شکل (۲)، نتایج بخش بندی تصویر مورد نظر با استفاده از الگوریتم IKPFCM به ازای ۳ کلاس را نشان می دهد.



شکل ۲: نتایج حاصل از الگوریتم IKPFCM. (الف): خوشه بندی به ازای ۴ کلاس، (ب): خوشه بندی به ازای ۳ کلاس، (ج): خوشه بندی به ازای ۲ کلاس

۴-۲. آزمایش بر روی تصاویر کلینیکی مغز

در این بخش از مقاله، از تصاویر کلینیکی حقیقی جهت بخش بندی استفاده شده است. جهت بخش بندی از تعدادی تصاویر حقیقی T1 و سایر ۱۸۱*۱۸۱ استفاده شده است و پس از جداسازی قسمت های مختلف مغز، میزان صحت بخش بندی بدست آمده است. در تصاویر واقعی، یک قسمت از تصویر به نام سلب مجمله باعث کاهش دقت بخش بندی و همچنین افزایش زمان اجرای الگوریتم می شود. بنابراین جهت آزمایش بر روی تصاویر واقعی، در گام اول باید سلب مجمله از تصویر مورد نظر حذف شود و در ادامه عمل بخش بندی تصویر با استفاده از الگوریتم خوشه بندی IKPFCM انجام شود. بنابراین در ادامه، عمل بخش بندی تصویر رزونانس مغناطیسی در شکل (۳) نشان داده شده است.



(الف)



(ب)

(ج)

(د)

(ه)

شکل ۳: نتایج حاصل از الگوریتم IKPFCM.

مشاهده می شود الگوریتم خوشه بندی فازی IKPFCM با دقت بالایی توانایی بخش بندی و حذف نویز تصاویر MR مغز را دارد. در جدول (۱) مقایسه نتایج دقت طبقه بندی الگوریتم پیشنهادی با سایر روش های خوشه بندی آمده است.

جدول ۱: مقایسه دقت بخش بندی الگوریتم پیشنهادی با سایر روش ها

ردیف	میزان طبقه بندی به ازای نویز گوسی ۲٪				
	نام الگوریتم	ماده سفید	ماده خاکستری	مابع مغزی نخاعی	میانگین دقت
۱	K-Means	۶۵	۶۰	۶۳	۶۲,۶۶
۲	FCM	۶۹	۶۵	۶۶	۶۶,۶۶
۳	PCM	۶۷	۶۸	۶۰	۶۵,۰۰
۴	PFCM	۷۴	۷۶	۷۱	۷۳,۶۶
۵	SFCM	۹۲	۸۶	۷۳	۸۳,۶۶
۶	KPFCM	۹۵	۹۰	۹۲	۹۲,۳۳
۷	IKPFCM	۹۷,۵	۹۴	۹۳	۹۴,۸۳

۵. نتایج

در این مقاله یک چهارچوب کلی از الگوریتم خوشه بندی فازی IKPFCM ارائه شد تا بتواند الگوریتم خوشه بندی فازی FCM اصلی را از لحاظ دقت بخش بندی و مقاومت در برابر نویز ارتقا دهد. مشاهده شد روش پیشنهادی جهت بخش بندی تصاویر MR مجازی و حقیقی مغز نسبت به سایر الگوریتم خوشه بندی دارای دقت بالاتری است. بنابراین الگوریتم پیشنهادی توانایی بالایی در بخش بندی تصاویر پزشکی و از جمله تصاویر MR مغز دارد. همچنین روش پیشنهادی در حذف نویز تصاویر رزونانس مغناطیسی مغز بسیار موفق عمل می کند.

منابع و مراجع

- [1] E. A. El-Dahshan, H. M. Mohsen, K. Revett and A.M. Salem. (2014). Computer-aided diagnosis of human brain tumor through MRI: A survey and a new algorithm. *Expert Systems with Applications*. Vol. 41, PP. 5526–5545.
- [2] K. Somasundaram. T. Kalaiselvi. (2011). "Automatic brain extraction methods for T1 magnetic resonance images using region labeling and morphological operations", *ELSEVIER, Computers in Biology and Medicine* 41, pp. 716-725.
- [3] Demirhan, A., & Guler, I. (2011). Combining stationary wavelet transform and selforganizing maps for brain MR image segmentation. *Engineering Applications of Artificial Intelligence*, 24(2), 358–367.
- [4] Cabezas, M., Oliver, A., Llado, X., Freixenet, J., & Cuadra, M. B. (2011). A review of atlas-based segmentation for magnetic resonance brain images. *Computer Methods and Programs in Biomedicine*, 104(3), 158–177.
- [5] E. Abdel-Maksoud, M. Elmogy and R. Al-Awadi. (2015). Brain tumor segmentation based on a hybrid clustering technique. *Egyptian Informatics Journal*. Vol. 1, PP. 1-11.
- [6] Noreen, N., Hayat, K., & Madani, S. A. (2011). MRI segmentation through wavelets and fuzzy c-means. *World Applied Sciences Journal*, 13, 34–39 (Special Issue of Applied Math).
- [7] J. C. Bezdek, L. O. Hall, and L. P. Clarke, "Review of MR image segmentation techniques using pattern recognition," *Med. Phys*, vol. 20, pp. 1033-1048, 1993.
- [8] R.Krishnapuram and J.M. Keller, "A Possibilistic Approach to Clustering," *IEEE Transaction on Fuzzy Systems*, 1(2):98-110, 1993.
- [9] K.P. Detroja et al., "A Possibilistic Clustering Approach to Novel Fault Detection and Isolation," *Journal of Process Control*, 16(10): 1055-1073, 2006.
- [10] D. Q. Zhang and S. C. Chen, "A novel kernelized fuzzy c-means algorithm with application in medical image segmentation," *Artificial Intelligence in Medicine*, vol. 32, pp. 37-50, 2004.
- [11] D. Q. Zhang, et al., "Kernel-based fuzzy clustering incorporating spatial constraints for image segmentation," in *Proc. of the 2th Int. Conf. on Mach. Lear. And Cyb.*, pp. 2189-2192 Vol. 4, 2003.
- [12] S. Zhou, H. Liu, and F. Ye, "Variant of Gaussian kernel and parameter setting method for nonlinear SVM," *Neurocomputing*, vol. 72, no. 13–15, pp.2931–2937, 2009.
- [13] M. Gong, Y. Liang, J. Shi, W. Ma, and J. Ma, "Fuzzy C-means clustering with local information and kernel metric for image segmentation," *IEEE Transactions on Image Processing*, vol. 22, no. 2, pp. 573–584, 2013.