

# بهبود بخش بندی رایانه‌ای بافت‌های نرم مغزی از تصاویر تشدید مغناطیسی به کمک تبدیل موجک

محمود زیدآبادی، رضا آقایی زاده ظروفی، حمید سلطانیان زاده  
قطب کنترل و پردازش هوشمند، گروه برق و کامپیوتر، دانشکده فنی، دانشگاه تهران.  
تهران- خیابان کارگر شمالی - بالاتر از تقاطع جلال آل احمد  
[zeydabadi@yahoo.com](mailto:zeydabadi@yahoo.com)

## چکیده

ماده سفید، ماده خاکستری و مایع مغزی- نخاعی از اجزاء اصلی تشکیل دهنده مغز انسان هستند. جداسازی خودکار بافت‌های مغزی به دلیل اهمیت آناتومی و فیزیولوژیک این بافت‌ها، بسیار مهم و حیاتی است. عمل جداسازی بافت‌های مغزی، معمولاً بر روی تصاویر تشدید مغناطیسی انجام می‌شود. در این مقاله روشی بر اساس الگوریتم توسعه یافته پیشینه سازی امید ریاضی و به کمک تبدیل موجک‌ها به صورت مالتی رزولوشن، برای جدا سازی خودکار سه جزء اصلی تشکیل دهنده مغز انسان از روی تصاویر تشدید مغناطیسی ارائه شده است. از آنالیز مالتی رزولوشن برای بهبود نتایج استفاده شده است. به منظور ارزیابی عملکرد روش از حدود ۴۰۰۰ تصویر ساختگی و واقعی استفاده شده است.

واژه‌های کلیدی: بخش بندی خودکار، تصاویر تشدید مغناطیسی، الگوریتم پیشینه سازی امید ریاضی، تبدیل موجک.

## ۱- مقدمه

پردازش تصاویر پزشکی یکی از امور مرتبط با مهندسی پزشکی نوین می‌باشد. در کاربردهای تحقیقاتی، تشخیصی و درمانی مانند حجم سنجی مغز انسان، تعیین پیشرفت بیماری یا درمان و اعمال جراحی بر روی مغز انسان نیاز است که محل اجزاء تشکیل دهنده مغز انسان یعنی ماده سفید، ماده خاکستری و مایع مغزی نخاعی به نحوی مشخص گردد. جداسازی بافت‌های مغزی به طور معمول

از طریق جداسازی تصاویر گرفته شده از مغز به روش تشدید مغناطیسی صورت می‌پذیرد. استفاده از روش تصویربرداری تشدید مغناطیسی در تصویربرداری از مغز به دلایل ذیل در اولویت است [۱]: دقت بالای تصویربرداری، قدرت تشخیص خوب بافتهای نرم از یکدیگر، بی خطر بودن و تصویربرداری به روش غیر تهاجمی. معمولا به دلیل حیاتی بودن موضوع، کار جداسازی به طور دستی و توسط افراد متخصص انجام می‌شود. این کار معایب بزرگی مانند زمان بر بودن، نداشتن قابلیت تکرار پذیری، وابسته بودن به کاربر و صرف هزینه زیاد دارد. برای رفع این نواقص طراحی و پیاده سازی الگوریتم‌هایی که بتوانند بدون کمک انسان و یا حداقل با کم کردن دخالت او، کار جداسازی را انجام دهند ضروری است. اجرای الگوریتم‌های جداسازی بافت‌های مغزی توسط کامپیوتر مشکل زمان، هزینه و تکرار پذیر بودن عملیات را تا حد زیادی رفع می‌کند و اگر نتایج هم از نظر کلینیکی در حد قابل قبولی باشند کاملا بر روش دستی ارجحیت خواهند داشت. روش‌های زیادی برای حل مسئله جداسازی پیشنهاد شده‌اند که هر یک برای کاربرد مورد نظر از روش خاصی استفاده کرده‌اند. به عنوان مثال مرجع [۲] از اطلاعات زمینه‌ای و مرجع [۳] از اطلاعات پیکسل‌ها به طور مستقل برای جداسازی استفاده می‌کنند. مرجع [۴] تعدادی از روش‌های موجود برای جداسازی تصاویر پزشکی از جمله خوشه‌یابی فازی، شبکه‌های عصبی و مدل‌های تغییر شکل پذیر را به صورت پایه‌ای مورد بررسی قرار داده است. مشکل عمده برای ارزیابی روش‌های ارائه شده به منظور جداسازی تصاویر پزشکی عدم وجود یک معیار استاندارد برای بررسی دقت عملکرد این روش‌ها است. گر چه معمولا نمی‌توان تمام شرایط تصویربرداری واقعی را در یک شبیه‌سازی لحاظ کرد اما شبیه‌سازی‌های کامپیوتری می‌توانند نوعی از یک معیار استاندارد را ایجاد کنند. مجموعه تصاویر شبیه‌سازی شده‌ای که ما در این مقاله از آنها استفاده کرده‌ایم بسیاری از شرایط تصویربرداری واقعی را مانند سطوح مختلف نویز (noise)، ناهمگنی فضایی میدان RF و اثر جزء حجمی در نظر گرفته است [۵].

منظور ما از جداسازی خودکار تصویر، جداسازی آن به سه بخش ماده سفید، ماده خاکستری و مایع مغزی-نخاعی است. روشی که در پیش گرفته خواهد شد، پیکسل‌های (pixel) تصویر را از طریق شدت روشنایی آنها جداسازی می‌کند. این روش جداسازی از دسته روش‌های جداسازی بر پایه پیکسل است. مزیت این روش‌ها عدم پیچیدگی محاسباتی و سرعت نسبتا بالای اجرای آنهاست. بررسی‌ها نشان می‌دهند که در مقایسه با روش‌هایی که روابط مکانی بین پیکسل‌ها را هم در نظر می‌گیرند، روش‌های بر پایه پیکسل اغلب نتایج مشابه و یا حتی بهتری داشته‌اند [۶]. یکی از الگوریتم‌های شناخته شده که در روش‌های جداسازی بر پایه پیکسل و به منظور تخمین پارامترهای مجهول مدل تصویر به کار می‌رود، الگوریتم بیشینه سازی امید ریاضی (EM) است. در این مقاله با استفاده از این الگوریتم و به کمک تبدیل موجک‌ها (wavelet transform) روشی برای جداسازی تصاویر در حالت مالتی رزولوشن (multiresolution) ارائه می‌شود.

## ۲- روش

مدلی که در اینجا برای تصویر در نظر می‌گیریم مدل ترکیب توزیع‌های گوسی (Gaussian mixture) است. اساس این مدل بر این فرض است که هیستوگرام (histogram) تصویر را به صورت ترکیبی از توابع گوسی مستقل از هم در نظر می‌گیریم. تعداد توابع توزیع برابر با تعداد کلاس‌های در نظر گرفته شده برای تصویر است و هر توزیع با یک بردار پارامتر متشکل از میانگین و

واریانس مربوط به آن توزیع، مشخص می‌شود. با در نظر گرفتن  $M$  کلاس برای تصویر، مدل را می‌توان به زبان ریاضی این طور بیان کرد:

$$f(y_{ij} | \Phi) = \sum_{m=1}^M w_m G(y_{ij} | \theta_m) \quad (1)$$

که در اینجا  $\theta = \{w_1, \dots, w_M, \theta_1, \dots, \theta_M\}$  بردار پارامترهای مدل،  $\theta_m = [\mu_m, \sigma_m]$  بردار پارامتر مربوط به هر توزیع،  $G(\cdot)$  یک تابع گوسی،  $y_{ij}$  شدت روشنایی پیکسل واقع در محل  $(i, j)$  و  $w_m$  سهم هر تابع توزیع گوسی از کل مدل می‌باشد.

## ۲-۱ الگوریتم پیشینه سازی امید ریاضی

برای رسیدن به هدف بخش بندی با مسئله تخمین پارامترهای مدل روبرو هستیم. یک راه ممکن برای این تخمین، یافتن تابع پیشینه احتمال مدل ترکیبی می‌باشد. یکی از روشهای شناخته شده و معروف برای این کار الگوریتم EM می‌باشد [۷]. این الگوریتم از دو مرحله تشکیل شده است:

مرحله محاسبه امید ریاضی [۸]

بدلیل اینکه توابع توزیع گوسی به فرم نمایی هستند کار کردن با لگاریتم آنها ساده تر می‌باشد. در این مرحله امید ریاضی تابع لگاریتم احتمال به شرط تخمین فعلی از پارامترها و به صورت زیر محاسبه می‌شود:

$$c_{ijm}^{(t)} = \frac{w_m^{(t)} G(y_{ij} | \theta_m^{(t)})}{f(y_{ij} | \Phi^{(t)})} \quad (2)$$

که  $c_{ijm}^{(t)}$  احتمال تعلق پیکسل واقع در محل  $(i, j)$  از تصویر به کلاس  $m$ ،  $y_{ij}$  شدت روشنایی پیکسل واقع در محل  $(i, j)$  و  $G(y_{ij} | \theta_m^{(t)})$  احتمال پیکسل واقع در محل  $(i, j)$  به شرط تعلق به کلاس  $m$  می‌باشد. نشانه بالا نمای  $(t)$ ، نمایان گر مرحله تکرار  $t$  ام از الگوریتم می‌باشد و  $(0 \leq c_{ijm} \leq 1, \sum_m c_{ijm} = 1, \sum_i \sum_j c_{ijm} > 0)$ .

مرحله پیشینه سازی [۸]

با استفاده از داده های مرحله قبل داریم :

$$\mu_m^{(t+1)} = \frac{\sum_{i=1}^N \sum_{j=1}^N c_{ijm}^{(t)} y_{ij}}{\sum_{i=1}^N \sum_{j=1}^N c_{ijm}^{(t)}} \quad (3)$$

$$\sigma_m^{(t+1)} = \frac{\sum_{i=1}^N \sum_{j=1}^N c_{ijm}^{(t)} (y_{ij} - \mu_m^{(t+1)})^2}{\sum_{i=1}^N \sum_{j=1}^N c_{ijm}^{(t)}} \quad (4)$$

$$w_m^{(t+1)} = \frac{\sum_{i=1}^N \sum_{j=1}^N c_{ijm}^{(t)}}{N \times N} \quad (5)$$

$N$  تعداد سطرها یا ستون‌های تصویر است. بعد از اجرای الگوریتم و به دست آوردن تخمینی از پارامترهای مجهول مدل می‌توان با یک طبقه بندی ساده هر پیکسل را به کلاسی از تصویر نسبت دهیم به طوری که احتمال تعلق پیکسل مفروض به این کلاس بیشینه باشد. بیان این مطلب به زبان ریاضی فرمول زیر است:

$$m_{ij} = \arg \max_m (G(y_{ij}, \theta_m)) \quad (6)$$

از مشکلات الگوریتم EM عدم توانایی آن در به حساب آوردن روابط همسایگی پیکسل‌های تصویر است. این مشکل از مستقل فرض کردن توابع توزیع گوسی در مدل کردن تصویر ناشی می‌شود. در [۸] برای در نظر گرفتن روابط همسایگی پیشنهاد شده که یک عبارت جبران ساز خطا به مدل تصویر اضافه شود. در [۹] همین ایده به صورت مالتی رزولوشن پیاده شده است. علاوه بر این مشکل دیگری که از این فرض اولیه ناشی می‌شود این است که در عمل هیستوگرام هر تصویری را نمی‌توان به صورت ترکیبی از توابع گوسی در نظر گرفت. در بخش بعد روشی برای در نظر گرفتن معایب فوق و بهبود عملکرد الگوریتم ارائه می‌شود.

### ۳- روش پیشنهادی

#### ۳-۱ توسعه الگوریتم EM

اساس استفاده از الگوریتم EM در مدل ترکیب گوسی بر این فرض واقع شده است که هیستوگرام تصویر شامل ترکیبی از چند تابع توزیع گوسی می‌باشد. در عمل شدت روشنایی پیکسل‌های متعلق به یک بافت خاص می‌تواند توزیع‌های متفاوت و غیر گوسی داشته باشند که فرض گوسی بودن آنها می‌تواند منجر به ایجاد خطا در نتیجه جداسازی بافت‌ها بشود. لذا این ایده که به ذهن می‌رسد که توزیع‌های غیر گوسی را به طریقی و تا حد امکان به یک توزیع گوسی شبیه کرد. یکی از روش‌های شناخته شده برای این کار استفاده از تبدیل باکس-کاکس (Box-Cox transformation) [۱۰] می‌باشد. این تبدیل به صورت زیر تعریف می‌شود:

$$y_{ij}^{(\lambda)} = \begin{cases} \frac{y_{ij}^\lambda - 1}{\lambda}, & 0 < \lambda \\ \log_e y_{ij}, & \lambda = 0 \end{cases} \quad (7)$$

که  $y_{ij}^{(\lambda)}$  شدت روشنایی تبدیل یافته و  $\lambda$  پارامتر تبدیل می‌باشد. برای استفاده از این شدت روشنایی جدید، در روابط (۲) تا (۶) به جای  $y_{ij}$  از  $y_{ij}^{(\lambda)}$  استفاده می‌کنیم. برای تخمین پارامتر  $\lambda$  از طریق الگوریتم EM باید تابع لگاریتم احتمال شدت روشنایی تبدیل یافته، در هر مرحله نسبت به  $\lambda$  بیشینه شود. این تابع احتمال به صورت زیر است [۱۱]:

$$L \propto \sum_{i=1}^N \sum_{j=1}^N \log_e \left\{ \sum_{m=1}^M w_m \cdot G(y_{ij}^{(\lambda)} | \theta_m) \right\} \quad (8)$$

از آنجا که بیشینه سازی مشتقات جزئی تابع احتمال فوق از روش تکراری نیوتن دشوار است لذا برای یافتن یک  $\lambda$  بهینه در عمل مقادیر متفاوت  $\lambda$  را در یک بازه مثلا (۰-۳) در نظر گرفته و به ازای هر مقدار تابع احتمال حساب شده و از طریق  $\lambda$  ای که بزرگترین تابع احتمال را موجب می شود محاسبه می کنیم.

### ۳-۲ در نظر گرفتن روابط مکانی

ما برای در نظر گرفتن روابط همسایگی بین پیکسل های تصویر از ماهیت آنالیز مالتی رزولوشن استفاده کردیم. به این ترتیب که در آنالیز مالتی رزولوشن می توان یک نوع رابطه پدر فرزندی (parent-child) بین پیکسل های تصاویر با رزولوشن های متفاوت ایجاد کرد. تصویر با رزولوشن پایین تر حاوی پیکسل های پدر و تصویر با رزولوشن بالاتر حاوی پیکسل های فرزند می باشد. هر پیکسل پدر با چهار پیکسل فرزند همسایه در رزولوشن بالاتر مرتبط می باشد. برای ایجاد یک تصویر با رزولوشن پایین تر از تبدیل مویجک گسسته دو بعدی استفاده کردیم. با اعمال این تبدیل بر روی تصویر اصلی چهار تصویر با اندازه های یک چهارم تصویر اصلی حاصل می شوند که یکی از آنها نسخه ای از تصویر اصلی است که حاوی جزئیات تصویر نبوده و مانند آن است که یک فیلتر پایین گذر بر روی تصویر اصلی اعمال کرده باشیم. این تصویر را تصویر تقریبی می نامیم. بقیه تصاویر حاوی جزئیات تصویر اصلی در جهت های افقی، عمودی و قطری می باشند. از آنجا که تصویر تقریبی تصویری شبیه به تصویر اصلی اما بدون برخی جزئیات و در اندازه ای کوچکتر می باشد لذا انتظار می رود که نتیجه عملیات جداسازی روی این تصویر هم یک نسخه کوچکتر و شبیه به نتیجه جداسازی روی تصویر اصلی باشد. در نتیجه با ترکیب نتایج جداسازی روی هر دو تصویر می توان از برخی خطاها که در اثر وجود نویز ایجاد شده اند کاست. به منظور ترکیب نتایج برای هر کدام وزنی در نظر گرفته می شود به صورتی که روابط زیر در نظر گرفته شوند: فرض کنید که نتیجه جداسازی تصویر اصلی را با  $S1(x, y)$ ، نتیجه جداسازی تصویر تقریبی را با  $S2(x', y')$  و نتیجه حاصل از ترکیب آنها را با  $S(x, y)$  نمایش دهیم. اگر  $S1(x, y) = S2(x', y')$  باشد یعنی پیکسل پدر از تصویر تقریبی و پیکسل فرزند از تصویر اصلی به یک کلاس تعلق داشته باشند آنگاه  $S(x, y) = S1(x, y)$  و اگر  $S1(x, y) \neq S2(x', y')$  آنگاه  $S(x, y) = S2(x', y')$ .

ضرایب ترکیب به طور تجربی و به اندازه ۰,۶ و ۰,۴ برای تصویر تقریبی و اصلی انتخاب شدند. ترکیب نتایج به این شکل باعث ایجاد خطا در لبه های تصویر می شود به این دلیل که در مجاورت لبه ها اغلب پیکسل ها متعلق به دو یا چند کلاس متفاوت می باشند در نتیجه چهار پیکسل همسایه فرزند که مجاور یک لبه هستند به احتمال زیاد در یک کلاس قرار نمی گیرند و لذا تعیین وضعیت تعلق آنها به کلاس های تصویر از روی وضعیت پیکسل پدر در تصویر تقریبی همراه با خطا می گردد. برای رفع این نقیصه باید از ترکیب نتایج در لبه های تصویر جلوگیری کنیم. ما برای یافتن لبه های تصویر از عملگر کنی (Canny operator) استفاده کردیم. این عملگر تصویر سطح خاکستری را به عنوان ورودی دریافت می کند و در خروجی تصویری می دهد که حاوی لبه های موجود در تصویر است. نحوه کار این عملگر به صورت چند مرحله ای می باشد. این تشخیص دهنده لبه نسبت به تشخیص دهنده های متداول این مزیت را دارد که لبه های تشخیص داده شده به صورت کانتورهای بسته بوده و علاوه بر این با تنظیم دو آستانه می توان آن را کنترل کرد. به این ترتیب پس از اعمال این عملگر بر روی تصاویر تقریبی و اصلی تصاویر جدیدی حاصل می شوند که فقط حاوی لبه ها هستند. با استفاده از اطلاعات این تصاویر از محل لبه ها آگاهی یافته و لذا عمل ترکیب را در نقاطی انجام می دهیم که روی لبه ها نباشند.

#### ۴- نتایج

برای بررسی عملکرد روش پیشنهادی دو نوع آزمایش انجام دادیم، یکی بر روی تصاویر ساختگی و دیگری بر روی تصاویر واقعی. در آزمایش اول از تصاویر تشدید مغناطیسی مغز انسان که توسط شبیه ساز برین وب (brainweb) [۱۲] ایجاد شده‌اند استفاده کردیم. از آنجا که در این آزمایش مدل آناتومیکی یا تصاویر استاندارد از قبل مشخص هستند لذا می‌توان یک بررسی کمی از عملکرد روش پیشنهادی در شرایط مختلف به انجام رساند. لازم به ذکر است که شبیه ساز اولیه که در [۱۲] مورد استفاده قرار گرفته است به دلیل ماهیت گسسته مجموعه داده‌ها (فانتوم)، لبه‌های کاملاً واضحی در مرز بین بافت‌ها ایجاد می‌کند که باعث می‌شود اثر جزء حجمی به درستی مدل نشود. در عوض ما از مدلی استفاده کردیم که شامل یک فانتوم فازی (Fuzzy phantom) می‌باشد و اثر جزء حجمی را کاملاً در نظر گرفته است. مجموعه تصاویر در [۵] موجود است. برای آزمایشات ما دو دسته تصاویر را در نظر گرفتیم، اول تصاویری بدون ناهمگنی میدان RF و با میزان نویز بین ۱ تا ۹ درصد و دوم همان دسته تصاویر اول و این بار با ۴۰ درصد ناهمگنی میدان RF. شکل ۱ نمونه‌ای از این تصاویر همراه با نتایج جداسازی را نشان می‌دهد. علاوه بر تصاویر شبیه سازی شده برای بررسی عملکرد روش پیشنهادی در شرایط واقعی لازم بود که از تصاویر حقیقی نیز استفاده شود. به این منظور از یک مجموعه تصاویر واقعی که شامل ۲۰ مورد تصاویر MR مغزی می‌باشد استفاده شد. این تصاویر که بر روی شبکه جهانی اینترنت و در دسترس عموم قرار دارد توسط مرکز آنالیز بیمارستان همه منظوره ماساچوست [۱۳] تهیه شده است. این بانک اطلاعاتی علاوه بر تصاویر فوق نتایج جداسازی این تصاویر توسط متخصص و نیز پنج خودکار دیگر را در دسترس قرار داده است. این دسته تصاویر دارای کیفیت‌های متفاوت از نظر میزان کنتراست، نویز و ناهمگنی فضایی می‌باشند. در بدترین حالت کنتراست پایین و ناهمگنی فضایی نسبتاً زیادی مشاهده می‌شود. تصاویر با طول و عرض ۲۵۶ و عموماً ۶۴ تصویر برای هر حالت می‌باشند. تصاویر استاندارد شامل چهار ناحیه ماده سفید؛ ماده خاکستری مایع مغزی نخاعی و پس زمینه می‌باشند که به ترتیب با شدت روشنایی ۲۵۴، ۱۹۲، ۱۲۸ و ۰ مشخص شده‌اند. شکل ۲ نمونه‌ای از این تصاویر همراه با نتایج جداسازی را نشان می‌دهد. شکل ۳ مقایسه عملکرد روش پیشنهادی را با شش روش دیگر نشان می‌دهد. شاخصی که برای مقایسه نتایج بخش بندی استفاده شده، به صورت زیر تعریف می‌شود و به ضریب تانیموتو (Tanimoto) معروف است:

$$I_2(k) = \frac{n_{a \cap b}(k)}{n_{a \cup b}(k)} \quad (9)$$

که  $n_{a \cap b}(k)$  تعداد پیکسل‌هایی است که هم توسط روش خودکار و هم توسط شخص متخصص در کلاس  $k$  طبقه بندی شده‌اند و  $n_{a \cup b}(k)$  تعداد پیکسل‌هایی هستند که توسط روش خودکار و یا توسط شخص متخصص به کلاس  $k$  طبقه بندی شده‌اند.


#### ۵- نتیجه گیری

در این مقاله روشی بر پایه الگوریتم EM توسعه یافته برای جداسازی بافت‌های اصلی مغز از روی تصاویر تشدید مغناطیسی ارائه شد. عملکرد روش پیشنهادی بر روی دو دسته تصاویر شبیه سازی شده و واقعی نشان داده شد. از نظر دیداری نتایج بسیار شبیه به

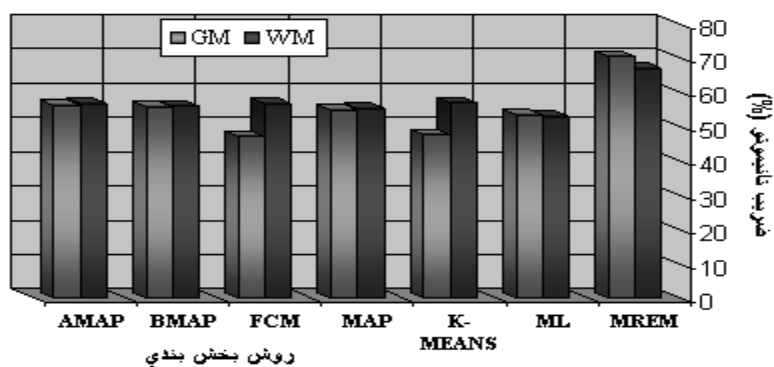
تصاویر استاندارد می‌باشند. مقایسه با چند روش دیگر در مورد تصاویر واقعی، کیفیت عملکرد روش پیشنهادی را تایید می‌کند. برای ادامه کار تعیین تطبیقی و خودکار ضرایب ترکیب مورد نظر می‌باشد.

## ۶- مراجع


- 1- Liang, Z.P., Lauterbur, P.C., “*Principles of Magnetic Resonance Imaging, A signal processing perspective*”, IEEE Press, New York, 2000.
- 2- Held, K., Kops, E.R., Krause, B.I., Wells, W.M., Kikinis, R. and Muller-Granter, “Markov Random Field Segmentation of MR Brain Images”, *IEEE Trans. Med. Imag.*, vol. 16, 1997, pp.878-886.
- 3- Schnack, H.G., Hulshoffpol, H.E., “Automated Separation of Gray and White Matter from MR Images of The Human Brain”, *NeuroImage*, vol. 13 , 2001, pp. 230-237.
- 4- Bankman, I.N., “Handbook of Medical Imaging, Processing and Analysis”, Academic Press, New York, 2000.
- 5- <http://www.bic.mni.mcgill.ca/brainweb/> (2003)
- 6- Atkins, M.S., Siu, K., Law, B., Orchard, J., Rosenbaum, W., “Difficulties of T1 Brain MRI Segmentation Techniques”, *Proceedings of SPIE Conference on Medical Imaging*, 2002, pp. 1837-1844.
- 7- Moon, T.K., “The Expectation Maximization Algorithm”, *IEEE Signal Processing Magazine*, November 1996, pp. 47-60.
- 8- Ambroise, C., Govaert, G., “Spatial Clustering and The EM Algorithm”, *Conference Proceedings of International Workshop on Mixtures*, France, 1995, pp. 17-25.
- 9- Saeed, M., Karl, W.C., Nguyen, T.Q., Rabiee, H.R., “A New Multiresolution Algorithm for Image Segmentation”, *Proceedings of ICASSP98*, pp. 2753-2756, 1998.
- 10- Box, G.E.P., Cox, D.R., “An Analysis of transformation”, *Journal of the Royal Statistical Society, Series B*, vol. 26, 1964, pp. 211-246.
- 11- Juin, D.L., “MR Brain Image Segmentation by Adaptive Mixture Distribution”, *Proceeding of the ICONIP*, vol. 1, 2002, pp.216-218.
- 12- Kwan, R.K.S., Evans, A.C., and Pike, G.B., “An Extensible MRI Simulator for Post Processing Evaluation,” in *Lecture Notes in Computer Science. Berlin, Germany: Springer-Verlag*, vol. 1131, 1996, pp. 1-14.
- 13- <http://www.cma.mgh.harvard.edu/ibsr> (2003)



شکل ۱- تصاویر شبیه سازی شده [۵] و نتایج بخش بندی آنها. (a)-(c) تصاویر شبیه سازی شده با نویز ۹ درصد و ۴۰ درصد میزان ناهمگنی میدان RF، (d)-(f) تصاویر ماده خاکستری استاندارد، (g)-(k) تصاویر ماده سفید استاندارد و (l)-(n) نتایج بخش بندی توسط روش پیشنهادی. مشابهت بین نتایج روش پیشنهادی و تصاویر استاندارد مشهود است.



شکل ۲- مقایسه عملکرد روش پیشنهادی (MREM) با شش روش بخش بندی خود کار دیگر روی تصاویر واقعی [۱۳]. روش پیشنهادی با میانگین ۶۷٪ برای ماده خاکستری و ۷۱٪ برای ماده سفید، بر روش های دیگر برتری کامل دارد.



شکل ۳- تصاویر واقعی [۱۳] و نتایج بخش بندی آنها. ردیف بالا تصاویر اصلی، ردیف وسط بش بندی توسط متخصص و ردیف پایین نتایج بخش بندی توسط روش پیشنهادی. از دیدگاه کلینیکی نتایج متخصص و روش پیشنهادی مشابهت قابل توجهی دارند.