

## یک الگوریتم جدید میانگین C فازی متمرکز شده با کاربردی در قطعه بندی

### تصویر پزشکی

#### چکیده

قطعه بندی تصویر نقشی حیاتی در بسیاری از کاربردهای تصویربرداری پزشکی دارد. در این مقاله، الگوریتمی جدید برای قطعه بندی فازی داده ی تصویربرداری با تشدید مغناطیسی (MRI) مطرح می کنیم. این الگوریتم با تغییر دادن تابع هدف در الگوریتم میانگین C فازی مرسوم شناخته می شود. لازم به ذکر است که این تغییر با استفاده از مقیاس فاصله ی ناشی از هسته و جریمه ی فضایی در توابع عضویت انجام داده شده است. اولاً، فاصله ی اقلیدسی اصلی در FCM با یک فاصله ی ناشی از هسته جایگزین می شود و از این رو الگوریتم های متناظر استنتاج می شوند و الگوریتم میانگین C فازی متمرکز شده (KFCM) نامیده می شوند. نشان داده شده است که KFCM مقاوم تر از FCM است. در ادامه یک جریمه ی فضایی به تابع هدف در KFCM اضافه می شود. این کار به منظور جبران سازی برای ناهمگنی های شدت تصویر MR و ایجاد امکان برچسب زنی به یک پیکسل که تحت تاثیر همسایه هایش قرار گرفته، می باشد. عبارت جریمه به عنوان یک تنظیم کننده عمل می کند و دارای ضربی در محدوده ی صفر تا یک می باشد نتایج تجربی روی هر دو تصویر MR واقعی و مصنوعی نشان دادند که الگوریتم های مطرح شده، در زمانی که نویز و دیگر مصنوعات وجود داشته باشند، در مقایسه با الگوریتم های استاندارد عملکرد بهتری دارند.

**کلمات کلیدی:** قطعه بندی تصویر، میانگین های C فازی، روش هسته، فاصله ی ناشی از هسته، تصویر برداری با

تشدید مغناطیسی

## 1. دیباچه

با افزایش اندازه و تعداد تصاویر پزشکی، استفاده از کامپیوترها در ساده سازی پردازش و تحلیل آنها ضروری شده است. به طور خاص، به عنوان کار مشخص کردن ساختارهای کالبد شناختی و دیگر مناطق مطلوب، الگوریتم های قطعه بندی تصویر نقشی حیاتی در کاربردهای متعدد تصویربرداری پزشکی مانند تسویر حجم های بافت، تشخیص بیماری، مطالعه ی ساختار کالبد شناختی و جراحی ادغام شده با کامپیوتر دارند. به طور کلاسیک، قطعه بندی تصویر به عنوان بخش بندی کردن یک تصویر به مناطقی غیر مشترک و اصلی که متناسب با برخی ویژگی هایی مانند شدت و بافت هستند، تعریف می شود.

اکثر تحقیقات در قطعه بندی تصویر پزشکی، به خاطر مزایای تصویربرداری با تشدید مغناطیسی (MRI) نسبت به دیگر تصویربرداری تشخیصی، به استفاده ی آن برای تصاویر MR مربوط هستند و روش های زیادی برای قطعه بندی تصویر MR در دسترس وجود دارد. در میان آنها، روش های قطعه بندی فازی، مزایای قابل توجهی هستند چون می توانند به نسبت روش های قطعه بندی سخت اطلاعات بسیار بیشتری حفظ می کنند. به طور خاص، الگوریتم میانگین های C فازی (FCM)، به خوشه های فازی بدون برچسب، پیکسل تخصیص می دهد. بر خلاف روش های خوشه بندی سخت که پیکسل ها را مجبور می کند تا به طور منحصر به فرد تنها به یک کلاس تعلق داشته باشند، FCM امکان تعلق گیری پیکسل به خوشه های متعدد با تغییرات سطح عضویت را فراهم می کند. به خاطر انعطاف پذیری اضافی، FCM اخیرا به گستردگی در کاربردهای قطعه بندی تصویر MR استفاده شده است. اثبات شده، الگوریتم FCM سنتی که بر مبنای تشدید می باشد حتی در زمان هایی که روش های پیچیده ای مانند غیر پارامتری و روش های چند کاناله استفاده شده باشند، مشکل ساز است (به خاطر ناهمگنی شدت فضایی القا شده بوسیله ی سیم پیچ فرکانس رادیویی در تصویر MR). برای مدیریت کردن مسائل ناهمگنی، الگوریتم های متعددی بوسیله ی اضافه کردن گام های تصحیح پیش از قطعه بندی تصویر یا بوسیله ی مدل سازی تصویر به عنوان محصولی از تصویر اصلی و یک حوزه ی افزایشنده با تغییر نرم، مطرح شده اند. اخیرا، محققین زیادی اطلاعات فضایی را در الگوریتم FCM اصلی تلفیق کرده اند تا تصاویر را بهتر قطعه بندی نمایند. تولیاس و پاناس (Tolias

and panas) سیستمی بر مبنای اصول فازی مطرح کردند. این کار در جهت پیاده سازی پیوستگی فضایی روی FCM بوده است. آنها در مقاله ای دیگر از یک ثابت مثبت در جهت تغییر عضویت پیکسل مرکزی در یک پنجره ی  $3 \times 3$  استفاده کردند. فام (Pham) و همکارانش تابع هدف در الگوریتم FCM تغییر دادند تا حوزه ای ضرب کننده (حاوی اطلاعات مرتبه ی اول و دوم تصویر) را در نظر بگیرند. به همین ترتیب، احمد (Ahmed) و همکارانش الگوریتمی برای جبران سازی ناهمگنی تشدید و برچسب زنی یک پیکسل با در نظر گرفتن همسایه ی فوری آن مطرح کردند. رویکردی نسبتاً جدید توسط فام مطرح شد که برای جریمه کردن تابع هدف در جهت محدود کردن رفتار توابع عضویت، مشابه به روش های استفاده شده در تنظیمات و تئوری حوزه ی تصادفی مارکوف (MRF) بود.

از سوی دیگر، اخیراً در فعالیت یادگیری ماشین گرایشی به برای ساخت نسخه ای غیرخطی وجود دارد. (برای مثال SVM، KOCA و KFD). و این روش هسته برای خوشه بندی بدون نظارت به کار گرفته شده است. اگر چه یک نقطه ضعف برای این الگوریتم های خوشه بندی که از ارائه ی دوگانه برای نمونه های اولیه استفاده می کنند (به طوریکه هر نمونه ی اولیه به صورت یک جمع خطی مولفه های مجموعه داده ی بعد از ترسیم شدن، فرموله می شوند و در نتیجه پارامترهایی که باید بهینه شوند دیگر نمونه های اولیه ی اصلی نیستند بلکه ضرایبی می باشند که به طور خطی تجمیع گشته اند) این است که نمونه های اولیه ی خوشه بندی در فضای ویژگی با ابعاد بالا قرار دارند و در نتیجه نتایج خوشه بندی تعریفی شهودی و واضح در فضای اصلی نخواهند داشت. در این مقاله، یک الگوریتم میانگین C فازی متمرکز شده (KFCM) مطرح می شود. این الگوریتم برای جبران سازی چنین کمبودهایی می باشد و در ادامه برای قطعه بندی تصویر MR به کار برده شده است. این موضوع از طریق جاگزین کردن فاصله ی اقلیدسی اصلی در الگوریتم FCM با فاصله ی ناشی از هسته و اضافه کردن یک جریمه ی فضایی جدید نیز تشخیص داده شده است. عبارت جریمه به صورت تنظیم کننده عمل می کند و ضریبی که همراه با این عبارت است دارای محدوده ای از صفر تا یک است. نشان داده شده است که الگوریتم مطرح شده در مقایسه با الگوریتم های استاندارد مانند FCM، دارای نتایج قطعه بندی بهتری در تصاویر واقعی و شبیه سازی شده ای که با نویز و دیگر مصنوعات تخریب شده اند، می باشد.

باقی این مقاله به صوت زیر دسته بندی شده است. در بخش 2 برخی مفاهیم بنیادی در مورد روش هسته به اختصار تشریح می شود. در بخش 3، KFCM از FCM اصلی بر پایه ی روش هسته استنتاج می شود. KFCM با محدودیت های فضایی در بخش 4 مطرح می شود تا تصاویر MR را قطعه بندی کند. برخی قیاس های تجربی در بخش 5 ارائه می شوند. در نهایت، بخش 6 نتیجه گیری ما را ارائه کرده و چندین مسئله برای کارهای آینده مطرح می کند.

## 2. روش هسته

در سال های اخیر، تعدادی ماشین یادگیرنده بر مبنای هسته مانند ماشین های بردار پشتیبانی (SVM)، تفکیک کننده ی هسته ی فیشر (KFD) و تحلیل مولفه ی اصلی هسته (KPCA) مطرح می شوند و کاربردهای موفقیت آمیزی مانند در شناسایی الگو و تقریب توابع یافته اند. فلسفه ای رایج در پشت این الگوریتم ها بر مبنای حقه ی (جانشینی) هسته ی پیش رو می باشد، بدین معنا که، اولاً با (به کارگیری) یک ترسیم غیرخطی، از فضای داده تا فضای ترسیم شده ی آینده  $(\Phi: X \rightarrow F(x \rightarrow \Phi(x)))$ ، یک مجموعه داده ی  $\{x_1, \dots, x_n\} \subseteq X$  (یک فضای ورودی با ابعاد کم) در فضای بالقوه ی آینده با ابعاد بالا یا ضرب داخلی F ترسیم می شود. هدف این کار تبدیل مسئله ی غیر خطی اصلی به یک مسئله ی خطی در ورودی فضای ورودی در یک مورد خطی بالقوه ی آن به جای فضای آینده با ابعاد بالا است، به طوریکه حل مسئله را همان طور که در کوور اثبات شده، ساده سازی می کند.

یک هسته در فضای آینده می تواند به عنوان تابع  $k$  زیر ارائه شد:

$$K(x, y) = \langle \Phi(x), \Phi(y) \rangle \quad (1)$$

که در آن  $\langle \Phi(x), \Phi(y) \rangle$  دلالت بر عملیات ضرب داخلی دارد.

نکته ای جالب درباره ی تابع کرنل این است که ضرب داخلی می تواند به طور ضمنی و بدون استفاده ی صریح یا حتی اطلاع از ترسیم  $\Phi$ ، در F محاسبه شود. پس هسته ها امکان ضرب های داخلی در فضاها را فراهم می کنند. یک ضرب داخلی در این فضاها نمی تواند هر محاسباتی را انجام دهد. سه تابع هسته ی استفاده شده در ادبیات علمی عبارتند از:

1) هسته ی تابع بنیادی شعاعی گوسی (GRBF)


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

2) هسته ی چند جمله ای

$$K(x, y) = (1 + \langle x, y \rangle)^d. \quad (3)$$

### 5. نتایج و مباحثه

در این بخش، برخی نتایج تجربی را برای مقایسه با عملکرد قطعه بندی الگوریتم های پیش رو (FCM و FCM) با محدودیت های فضایی (SFCM)، KFCM و KFCM با محدودیت های فضایی (SKFCM) تشریح کردیم.




شکل 1 مقایسه نتایج تقسیم بندی بر روی یک تصویر مصنوعی خراب شده توسط 5٪ نویز گاوسی. الف) اصل تصویر،

ب) با استفاده از FCM، ج) با استفاده از KFCM، د) با استفاده از SFCM، و ه) با استفاده از SKFCM

چهار روش را در سه بستر آزمایش مختلف آزمودیم. اولی یک تصویر مصنوعی ساده است، دیگری مجموعه داده ی مغز شبیه سازی شده ی کلاسیک برای دانشگاه مک گیل می باشد و آخرین مورد قطعات واقعی MR است. تنها هسته ی گوسین RBF برای KFCM و SKFCM استفاده می شود و به خاطر محدوده ی پویای بزرگ مقدار پارامتر در SFCM، از مقدار پیشنهاد شده در 12 بهره می بریم.

تصویر مصنوعی در شکل 1a نشان داده می شود. این تصویر شامل یک الگوی دو کلاسی خراب شده با 5٪ نویز گوسی است. مقادیر تشدید دو کلاس به ترتیب صفر و 90 هستند و اندازه ی تصویر  $64 \times 64$  پیکسل می باشد. شکل 1b-e به ترتیب نتایج قطعه بندی در FCM و KFCM و SKFCM را نشان می دهد. در اینجا پارامتر  $\sigma$  را به صورت  $\sigma = 150$  قرار می دهیم (پهنای هسته ی RBF گوسی)،  $\alpha = 0.7$ ،  $m = 2$  و  $N_R = 8$  (یک پنجره ی  $3 \times 3$  حول هر پیکسل به جز خود پیکسل مرکزی، تمرکز یافته است). این مقادیر در ادامه ی این مقاله استفاده خواهد شد مگر اینکه مقداری صراحتاً مشخص شود. همان طور که در شکل 1b و c نشان داده شده، بدون محدودیت های فضایی، هیچکدام از FCM و KFCM نمی توانند دو کلاس را از هم جدا کنند، در حالیکه همان طور که در شکل 1d و e نشان داده شده، SFCM تقریباً و SKFCM کاملاً در تصحیح و طبقه بندی داده موفق بوده اند. به یاد داشته باشید که KFCM به خاطر تزریق هسته در مقایسه با FCM نیاز به زمان اجرایی بیشتری دارد و متناظراً، SKFCM کندتر از SFCM می باشد. معمولاً، الگوریتم های بدون هسته چندین برابر سریعتر از الگوریتم هایی با هسته های تزریق هستند.



شکل 2: مقایسه ی نتایج قطعه بندی در تصویر مصنوعی که با 5٪ نویز گوسی و ناهمگنی تشدید سنوسی تخریب شده است . A تصویر اصلی ، (b) با استفاده از FCM (c) با استفاده از SKFCM (d) با استفاده از SFCM و (e) با استفاده از SKFCM.

شکل 2a یک تصویر مصنوعی آزمایشی است که با نویز 5% و ناهمگنی تشدید، تخریب گشته و با تابع سینوسی شبیه سازی شده است. اشکال 2b-e به ترتیب نتایج FCM، SKFCM، SFCM و SKFCM را نشان می دهد. همانند شکل 1، SKFCM نیازمند به بهترین عملکرد قطعه بندی است. جدول 1 دقت قطعه بندی (SA) را در جهت بدست آمدن مقایسه ی کمی برای چهار روش در شکل های 1a و 2a می دهد. دقت قطعه بندی در این جدول به صورت جمع تعداد کل پیکسل های تقسیم شده بوسیله ی جمع تعداد پیکسل هایی که به درستی دسته بندی شده اند، تعریف می شود.

شکل 3 و 4 مقایسه ی نتایج قطعه بندی بین FCM، KFCM، SFCM و SKFCM را در زمانی که فانتوم MR با وزن T1 به کار برده شده باشد را ارائه می کند. مزایای استفاده از فانتوم دیجیتال به جای داده ی تصویر واقعی برای اعتبارسنجی روش های قطعه بندی، شامل دانش قبلی انواع بافت واقعی و کنترل روی پارامترهای تصویر مانند جهت، ضخامت برش، نویز و ناهمگنی تشدید می شود. اینجا در آزمایشاتمان از یک فانتوم با تفکیکی بالا و با وزن T1 و با ضخامت برش 1mm، 3% نویز و بدون ناهمگنی تشدید استفاده کرده ایم. دو برش در صفحه ی محوری با توالی 91 و 121، به ترتیب در شکل های 3a و 4a نشان داده می شوند. نتایج قطعه بندی در دو برش، با استفاده از چهار روش و با هشت کلاس به ترتیب در شکل های 3b-e و 4b-e نشان داده می شوند. جدول 2 امتیازات مقایسه ی کمی متناظر با شکل 3a را با استفاده از چهار روش با 8 کلاس ارائه داده است. به یاد داشته باشید که SFCM در حقیقت سه کلاس را پیدا کرده است اما چون کلاس 5 در مقایسه با سایر کلاس ها بسیار کوچک است لذا امتیاز آن در جدول 2 به صفر گرد می شود. امتیازات مقایسه (در 29 سطح کیفیت نیز نامیده شده است) برای هر الگوریتم و برای هر کلاس از طریق معادله ی پیش رو محاسبه می شود:

$$s_{ij} = \frac{A_{ij} \cap A_{refj}}{A_{ij} \cup A_{refj}} \quad (17)$$

که در آن  $A_{ij}$  مجموعه پیکسل های متعلق به  $j$  امین کلاس یافته شده بوسیله ی  $i$  امین الگوریتم را ارائه می کند و  $A_{refj}$  مجموعه پیکسل های متعلق به کلاس  $j$  ام در تصویر قطعه بندی شده ی منبع را نشان می دهد. در اینجا  $\alpha = 0.1$  را انتخاب کرده ایم چون نویز نسبتاً کوچک است. در چنین حالتی، FCM و SFCM نمی توانند به درستی تصاویر را دسته بندی کنند در حالیکه KFCM و SKFCM نتایج قطعه بندی رضایت بخشی را بدست می آورند.

شکل 5 و 6 مقایسه ی نتایج قطعه بندی بین ، SFCM، KFCM و SKFCM را در زمانی که روی برش های واقعی MR که با نویز گوسی 5٪ تخریب شده است، به کار برده شده باند را نشان می دهند. این تصاویر MR با وزن T1 با استفاده از یک تصویر ساز MR کلینیکی 1.5 تسلا سیگنال الکتریکی جامع با تفکیک داخل صفحه ی 0.94 mm2 بدست می آیند. شکل های 5a و 6a تصاویری که به صورت مصنوعی تخریب شده اند را نشان می دهند و اشکال 5b-e و 6b-e به ترتیب نتایج استفاده از FCM، KFCM، SFCM و SKFCM با سه کلاس هستند. جدول




3 امتیازات مقایسه‌ی متناظر را با استفاده از چهار روش با سه کلاس برای اشکال 5a و 6a ارائه کرده است. با توجه به تصاویر و جدول 3، می‌توانیم ببینیم که بدون محدودیت‌های فضایی، FCM و KFCM، هر دو به شدت تحت تاثیر نویز قرار گرفته‌اند در حالیکه SFCM به صورت جزئی و SKFCM تقریباً به طور کامل اثر نویز را حذف کرده‌اند.

**Table 1 Segmentation accuracy (SA %) of four methods on synthetic image**

	FCM	KFCM	SFCM	SKFCM
Fig. 1a	96.02	96.51	99.34	100
Fig. 2a	94.41	91.11	98.41	99.88

جدول 1: دقت قطعه‌بندی (SA) برای چهار روش در تصویر مصنوعی



شکل 3: مقایسه‌ی نتایج قطعه‌بندی در تصویر MR مغز شبیه‌سازی شده که با 3٪ نویز تخریب شده است. (A تصویر اصلی با وزن T1، (b) با استفاده از FCM، (c) با استفاده از KFCM، (d) با استفاده از SFCM و (e) با استفاده از SKFCM.

در نهایت، شکل 7 مقایسه ی نتایج قطعه بندی چهار روش روی تصویر MR با وزن T2 که با ناهمگنی های شدید جزئی تخریب شده است را نشان داده است. شکل 7a تصویر اصلی است و شکل 7b-e به ترتیب نتایج با استفاده از FCM، SKFCM، SFCM و SKFCM است. توجه داشته باشید که SKFCM در مقایسه با دیگر الگوریتم ها بسیار کمتر قطعه قطعه شده است و تلفیق محدودیت های فضایی در طبقه بندی تا حدی دارای مزیت تار کردن برخی از جزئیات را دارد اما SKFCM همان طور که در شکل 7d و e نشان داده شده، در مقایسه با SFCM نتایج بهتری داشته است.

## 6. نتیجه گیری

در این مقاله یک الگوریتم جدید میانگین C فازی متمرکز شده مطرح می شود و برای قطعه بندی تصویر MR به کار گرفته می شود. KFCM مقیاس ناشی از هسته ی جدیدی را در فضای داده اتخاذ می کند تا مقیاس نرم اقلیدسی اصلی را در FCM جایگزین کند و نمونه های اولیه ی خوشه بندی شده هنوز در فضای داده قرار دارند به طوری که نتایج خوشه بندی می تواند به طور مستقیم مجددا فرمول بندی و در فضای اصلی تفسیر شود. اثبات شده است که KFCM یک رویکرد خوشه بندی مقاوم در ضمیمه ی A است.

علاوه بر این، یک محدودیت فضایی روی تابع هدف KFCM اضافه کردیم تا تصاویر MR تخریب شده با نویز را به طور کارآمد قطعه بندی کند. اگر چه محدودیت فضایی استفاده شده در KFCM مشابه به محدودیت استفاده شده در 12 است، اما محدودیت ما ساده تر می باشد و از نظر محاسباتی گران قیمت نیست. دیگه چی؟، از آنجایی که فاصله ی القا شده از طرف RBF گوسی بین صفر و یک محدود شده است، لذا دقیقا مطابق با محدوده ی مقدار عضویت است؛ تنها نیاز داریم که ضریب تنظیم کننده را بین صفر و یک تنظیم کنیم تا اهمیت نسبی عبارت تنظیم کردن را کنترل نماییم.

نتایج نشان داده شده در این مقاله مقدماتی هستند و ارزیابی آزمایشگاهی بیشتری مورد نیاز می باشد. از آنجایی که تقریبا همه ی الگوریتم های FCM تغییر داده شده برای قطعه بندی تصویر بر مبنای اضافه کردن نوعی از عبارات

جریمه برای تابع هدف FCM اصلی می باشند لذا KFCM می تواند در روشی که به اندازه ای قابل قبول ساده است به کار گرفته شوند تا عملکرد این الگوریتم ها را بهبود ببخشند.

## ضمیمه ی A

اثبات اینکه KFCM که از هسته در معادله ی 2 استفاده می کند یک تخمین زننده ی مقاوم است.

اثبات: براساس هوبر (Huber)، چندین تخمین زننده ی مقاوم مانند  $M$ ،  $L$  و تخمین زننده ی  $R$  وجود دارد. در این بخش، تنها علاقه مند به تخمین زننده ی  $M$  هستیم و روند اثبات موجود در 23 را دنبال می کنیم. اجازه دهید تا  $\{x_1, x_2, \dots, x_n\}$  مجموعه داده ی مشاهده شده و  $\theta$  یک پارامتر نامعلوم ی باشد که باید تخمین زده شود. یک تخمین زننده ی  $M$  برای تخمین محلی می تواند از طریق حداقل سازی تابع هدف پیش رو ایجاد شود:

$$J(\theta) = \sum_{i=1}^n \rho(x_i - \theta) \quad (A.1)$$

که در آن  $\rho$  یک تابع است و در این اثبات به صورت  $1 - K(x, \theta)$  دیده می شود و تنها وابسته به  $(x_i - \theta)$  می باشد. در ادامه تخمین زننده ی  $M$  با حل کردن معادله ی پیش رو بدست می آید

$$J'(\theta) = \sum_{i=1}^n \phi(x_i - \theta) = 0 \quad (A.2)$$

که در آن  $\phi(x - \theta) = (\partial/\partial\theta)\rho(x - \theta)$ . اگر ما  $\rho(x - \theta) = (x - \theta)^2$  و  $\rho(x - \theta) = |x - \theta|$  را به ترتیب در نظر گرفته باشیم، تخمین زننده ی  $M$  آنها میانگین متناظر است و متوسط مجموعه داده ی نمونه ی معادله ی A.2 می تواند با مجددا نوشته شدن به صورت زیر حل گردد:

$$\sum_{i=1}^n w_i(x_i - \theta) = 0 \quad (A.3)$$

که در آن  $w_i = \phi(x_i - \theta)/(x_i - \theta)$ ، تابع وزن نامیده شده است. این معادله، تخمین زن را به صورت زیر می

دهد:

$$\hat{\theta} = \frac{\sum_{i=1}^n w_i x_i}{\sum_{i=1}^n w_i} \quad (\text{A.4})$$

که میانگین وزنی مجموعه داده ی نمونه است. به یاد داشته باشید که پاسخ ممکن است که با حل کردن معادله ی A.4 به شکل بسته برای  $\hat{\theta}$  نباشد. می توانیم از تکرار با نقطه ی ثابت یا بهینه سازی جایگزین استفاده کنیم تا پاسخ معادله ی A.4 را مکرراً بدست آوریم.

تابع تاثیر (IF) می تواند به ما برای ارزشگذاری تاثیر نسبی یک تخمین کمک کند. نشان داده شده است که تاثیر تخمین زننده ی M متناسب با تابع  $\phi$  آن است. اکنون ما IF را برای یک تخمین زننده ی M با معادله ی زیر داریم:

$$\text{IF}(x; F, \theta) = \frac{\phi(x - \theta)}{\int \phi'(x - \theta) dF_X(x)} \quad (\text{A.5})$$

که در آن  $F_X(x)$  نماد تابع توزیع X است. اگر یک IF برای یک تخمین زن نامحدود باشد از این رو، یک دورافتاده می تواند مشکل درست کند. مقیاس های متعدد مقاومت وجود دارند که از IF استنتاج گردیده اند و یکی از این مقیاس ها حساسیت خطای فاحش (GES) است که به صورت زیر تعریف می شود:

$$\gamma^* = \sup_x |\text{IF}(x; F, \theta)| \quad (\text{A.6})$$

کمیت می تواند بدترین تاثیر تقریبی را تفسیر کند که اضافه کردن جرم یک نقطه ی بسیار کوچک می تواند روی مقدار همراه با تقریب زننده داشته باشد.

## References

- [1] Pham DL, Xu CY, Prince JL. A survey of current methods in medical image segmentation. Ann. Rev. Biomed. Eng. 2000;2:315—37 [Technical report version, JHU/ECE 99— 01, Johns Hopkins University].
- [2] Wells WM, Grimson WEL, Kikinis R, Arrdrige SR. Adaptive segmentation of MRI data. IEEE Trans Med Imaging 1996;15: 429—42.
- [3] Bezdek JC, Hall LO, Clarke LP. Review of MR image segmentation techniques using pattern recognition. Med Phys 1993;20:1033—48.
- [4] Dawant BM, Zijdenbos AP, Margolin RA. Correction of intensity variations in MR image for computer-aided tissue classification. IEEE Trans Med Imaging 1993;12:770—81.
- [5] Johnson B, Atkins MS, Mackiewich B, Andson M. Segmentation of multiple sclerosis lesions in intensity corrected multispectral MRI. IEEE Trans Med Imaging 1996;15:154—69.
- [6] Pham DL, Prince JL. An adaptive fuzzy C-means algorithm for image segmentation in the presence of intensity inhomogeneities. Pattern Recognit Lett 1999;20(1):57—68.
- [7] Bezdek JC. Pattern recognition with fuzzy objective function algorithms. New York: Plenum Press; 1981.

- [8] Toliyas YA, Panas SM. On applying spatial constraints in fuzzy image clustering using a fuzzy rule-based system. *IEEE Signal Proc Lett* 1998;5(10):245—7.
- [9] Toliyas YA, Panas SM. Image segmentation by a fuzzy clustering algorithm using adaptive spatially constrained membership functions. *IEEE Trans Syst, Man, Cybernet Part A* 1998;28(3):359—69.
- [10] Liew AWC, Leung SH, Lau WH. Fuzzy image clustering incorporating spatial continuity. *IEE Proc Vis Image Signal Proc* 2000;147(2):185—92.
- [11] Ahmed MN, Yamany SM, Mohamed N, Farag AA, Moriarty T. A modified fuzzy C-means algorithm for bias field estimation and segmentation of MRI data. *IEEE Trans Med Imaging* 2002;21(3):193—9.
- [12] Pham DL. Fuzzy clustering with spatial constraints. In: *Proceedings of the IEEE International Conference on Image Processing*, New York, USA, August, 2002.
- [13] Cristianini N, Taylor JS. *An introduction to SVMs and other kernel-based learning methods*. Cambridge University Press; 2000.
- [14] Vapnik VN. *Statistical learning theory*. New York: Wiley; 1998.
- [15] Scholkopf B. *Support vector learning*. R. Oldenbourg Verlag; 1997.
- [16] Scholkopf B, Smola AJ, Muller KR. Nonlinear component analysis as a kernel eigenvalue problem. *Neural Comput* 1998;10(5):1299—319.
- [17] Roth V, Steinhage. Nonlinear discriminant analysis using kernel functions. In: *Advances in neural information processing systems*, vol. 12. 2000, pp. 568—74.
- [18] Hur AB, Horn D, Siegelmann HT, Vapnik V. Support vector clustering. *J Mach Learn Res* 2001;2:125—37.
- [19] Girolami M. Mercer kernel-based clustering in feature space. *IEEE Trans Neural Networks* 2002;13(3):780—4.
- [20] Zhang DQ, Chen SC. Fuzzy clustering using kernel methods. In: *Proceedings of the International Conference on Control and Automation*, Xiamen, China, June, 2002.
- [21] Cover TM. Geometrical and statistical properties of systems of linear inequalities in pattern recognition. *IEEE Trans Electron Comput* 1965;14:326—34.
- [22] Muller KR, Mika S et al. *An introduction to kernel-based learning algorithms*. *IEEE Trans Neural Networks* 2001; 12(2):181—202.
- [23] Wu KL, Yang MS. Alternative c-means clustering algorithms. *Pattern Recognit* 2002;35:2267—78.
- [24] Huber PJ. *Robust statistics*. New York: Wiley; 1981.
- [25] Dave RN, Krishnapuram R. Robust clustering method: a unified view. *IEEE Trans Fuzzy Syst* 1997;5(2):270—93.
- [26] Leski J. Towards a robust fuzzy clustering. *Fuzzy sets and systems*. Corrected proof, available online, 8 February 2003, in press.
- [27] Chapelle O, Haffner P, Vapnik V. Syms for histogram-based image classification. *IEEE Trans Neural Networks* 1999; 10(5):1055—65.
- [28] Kwan RKS, Evans AC, Pike GB. An extensible MRI simulator for post-processing evaluation. *Visualization in biomedical computing (VBC'96)*. *Lecture notes in computer science*, vol. 1131. Springer-Verlag; 1996. pp. 135—40.
- [29] Lin C.T, Lee C.S.G. Real-time supervised structure/parameter learning for fuzzy neural network. In: *Proceedings of the 1992 IEEE International Conference on Fuzzy Systems*, San Diego, CA, pp. 1283—90.
- [30] Masulli F, Schenone A. A fuzzy clustering based segmentation system as support to diagnosis in medical imaging. *Artif Intell Med* 1999;16(2):129—47