


بِسْمِ اللَّهِ الرَّحْمَنِ الرَّحِيمِ



دانشگاه صنعتی شاهرود

دانشکده: کامپیوتر و فناوری اطلاعات

گروه: هوش مصنوعی

ناحیه‌بندی و فقی و نیمه‌نظارتی توهمور در تصاویر MRI

سعیده اسلامی

استاد راهنما:

دکتر مرتضی زاهدی

استاد مشاور:

دکتر رضا عزمی

پایان نامه ارشد جهت اخذ درجه کارشناسی ارشد

شهریور ۱۳۹۰

دانشگاه صنعتی شاهرود

دانشکده: مهندسی کامپیوتر و فناوری اطلاعات

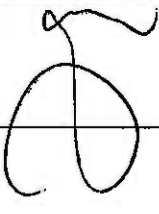
پایان نامه ارشد خانم سعیده اسلامی

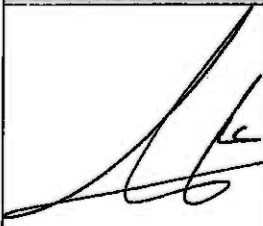
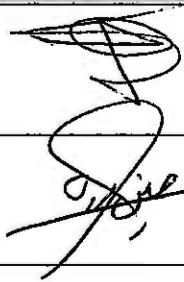
تحت عنوان:

ناحیه بندی و فقی و نیمه نظارتی تومور در تصاویر MRI

در تاریخ ۹۰/۶/۲۷ توسط کمیته تخصصی زیر جهت اخذ مدرک کارشناسی ارشد مورد ارزیابی و با

درجه عالی مورد پذیرش قرار گرفت.

امضاء	اسامید مشاور	امضاء	اسامید راهنما
غایب	نام و نام خانوادگی: دکتر رضا عزمی		نام و نام خانوادگی: دکتر مرتضی زاهدی
	نام و نام خانوادگی:		نام و نام خانوادگی:

امضاء	نماینده محاسبات تکمیلی	امضاء	اسامید داور
	نام و نام خانوادگی: مهندس علی دوست محمدی		نام و نام خانوادگی: دکتر حمید حسن پور
			نام و نام خانوادگی: دکتر حسین مروی
			نام و نام خانوادگی:
			نام و نام خانوادگی:

این پایان نامه را با نهایت سپاس و تشکر می‌کنم

به پدرم که با لطف و زحمات بی‌دینش مسیر شرف و خوشبختی را برایم هموار کرده است و به مادرم که دعای خالصانه‌اش

بدرقه راه و وجودش دگر می‌من است

و تقدیم می‌کنم

به خواهر عزیزم فرزانه که همواره مرهمون لطف و محبت خالصانه‌اش، ستم و خواهم بود

شکر و قدردانی

حال که به لطف و رحمت لایتناهی حضرت حق مراحل این پیمان نامه روبه اتمام نهاده بر خود لازم میدانم تا از همه کسانی که در

پیشبرد اهداف این پیمان نامه من ریاکاری نمودن سپاس و قدردانی به عمل آوردم.

ابتدا از زحمات و پشتیبانی بی دریغ و بی شائبه استاد ارجمندم جناب آقای دکتر زاهدی که راهنمایی این تحقیق را بر عهده داشتند

کمال شکر را دارم. بی شک بدون حمایت و هم فکری ایشان انجام این پیمان نامه مقدور نبود.

و نیز سپاس گذارم از استاد گرامی جناب آقای دکتر عزیزی که از هرگونه راهنمایی و مساعدت اینجانب در انجام پژوهش مضائقه

نکردند.

در پایان از اساتید گران قدر جناب آقای دکتر حسن پور و جناب آقای دکتر پویان که سعادت شاکردی ایشان را در دوره

کارشناسی ارشد داشته ام قدردانی کرده و از خداوند متعال برای این دو بزرگوار موفقیت و بهروزی مسألت دارم.

تعهد نامه

اینجانب سعیده اسلامی دانشجوی دوره کارشناسی ارشد رشته هوش مصنوعی دانشکده مهندسی فناوری اطلاعات و کامپیوتر دانشگاه صنعتی شاهرود نویسنده پایان نامه "ناحیه بندی وفقی و نیمه نظارتی تومور در تصاویر MRI" تحت راهنمایی آقای دکتر مرتضی زاهدی متعهد می شوم

- تحقیقات در این پایان نامه توسط اینجانب انجام شده است و از صحت و اصالت برخوردار است.
- در استفاده از نتایج پژوهش های محققان دیگر به مرجع مورد استفاده استناد شده است.
- مطالب مندرج در پایان نامه تا کنون توسط خود یا فرد دیگری برای دریافت هیچ نوع مدرک یا امتیازی در هیچ جا ارائه نشده است.
- کلیه حقوق معنوی این اثر متعلق به دانشگاه صنعتی شاهرود می باشد و مقالات مستخرج با نام "دانشگاه صنعتی شاهرود" و یا "Shahrood University of Technology" به چاپ خواهد رسید.
- حقوق معنوی تمام افرادی که در بدست آمدن نتایج اصلی پایان نامه تاثیرگذار بوده اند در مقالات مستخرج از پایان نامه رعایت می شود.
- در کلیه مراحل انجام این پایان نامه در مواردی که به حوزه اطلاعات شخصی افراد دسترسی یافته یا استفاده شده است، ضوابط و اصول اخلاقی رعایت شده است.

تاریخ امضا

مالکیت نتایج و حق نشر

کلیه حقوق معنوی این اثر و محصولات آن (مقالات مستخرج، کتاب، برنامه های رایانه ای، نرم افزارها و تجهیزات ساخته شده) متعلق به دانشگاه صنعتی شاهرود است. این مطلب باید به نحو مقتضی در تولیدات علمی مربوطه ذکر شود.

استفاده از اطلاعات و نتایج موجود در پایان نامه بدون ذکر مرجع مجاز نمی باشد.

چکیده

ناحیه‌بندی بافت مغز با هدف تفکیک دقیق بافت آسیب‌دیده یا بیمار مغز، یکی از مراحل اساسی در فرآیند تشخیص و درمان ناهنجاریهای بافت مغز است. اما ناحیه‌بندی عموماً توسط رادیولوژیست‌ها و متخصصین آنکولوژی به صورت دستی صورت می‌گیرد که ضمن خسته‌کننده و دشوار بودن از خطای انسانی نیز مصون نیست. پیچیدگی این فرآیند لزوم طراحی و استفاده از یک متد خودکار یا نیمه‌خودکار را مشخص می‌سازد.

مطلوب اینست که روشی که برای این منظور ارائه می‌شود، حتی‌الامکان بی‌نیاز از پارامترهای اولیه بوده و بتواند اطلاعات موردنیاز خود را از روی داده تخمین‌زده و تحت تاثیر نویز و تغییرات روشنایی در بافت‌ها قرار نگیرد.

در این پایان‌نامه یک روش ناحیه‌بندی نیمه‌نظارتی با استفاده از کلاسیفایر جنگل تصادفی ارائه می‌شود. متدهای نیمه‌نظارتی با تلفیقی از دو مدل آموزش نظارتی و غیرنظارتی کارآیی بهتری را نسبت به هر دو این روش‌ها ارائه می‌دهند. نظر به اینکه فراهم کردن داده‌های آموزشی برای یک کلاسیفایر نظارتی در کاربردهای پزشکی همانند ناحیه‌بندی بسیار دشوار است، استفاده از یک تکنیک نیمه‌نظارتی می‌تواند قسمت عمده‌ای از نیاز به چنین داده‌هایی را برطرف سازد. برای استخراج ویژگی‌ها بازه همسایگی جدیدی با استفاده از تئوری الگوریتم انتشار شایعه در حوزه ناحیه‌بندی تصویر و اعمال ترکیبی از قيود فضایی و محدودیت سطح روشنایی روی شرط همسایگی معرفی می‌شود. با استفاده از این همسایگی محلی و وقفی، تصویر به صورت اولیه ناحیه‌بندی می‌شود. محاسبه ویژگی‌های موردنظر با استفاده از این نواحی با دقت بسیار بالاتری نسبت به حالت غیروقفی صورت می‌پذیرد. الگوریتم جنگل تصادفی برای شناسایی ویژگیهای استخراج‌شده مورد استفاده قرار می‌گیرد. کلاسیفایر جنگل تصادفی تابحال چندان در حوزه ناحیه‌بندی MRI موردتوجه نبوده است اما این الگوریتم امتیازات ویژه‌ای از قبیل دقت بالا در عین سرعت پردازش بسیار بالا، توانایی کنترل مقادیر مفقودشده در بردار ویژگی و کنترل عدم توازن داده‌ها را دارد که آن را برای استفاده در یک سیستم ناحیه‌بندی تصویر به عنوان کلاسیفایر پیکسل‌ها بسیار مناسب می‌سازد. نتایج بدست‌آمده از پیاده‌سازی نهایی، درستی این ادعا را اثبات می‌کند. با وجود برابری نسبی نتایج بدست‌آمده از لحاظ دقت با متد MRF که تقریباً موفق‌ترین متد ناحیه‌بندی MRI محسوب می‌شود، زمان پردازش و محاسبات با استفاده از این متد بسیار کمتر از روش MRF است.

کلمات کلیدی - ناحیه‌بندی، تصویربرداری با تشدید مغناطیسی، آموزش نیمه‌نظارتی، وکسل، الگوریتم جنگل

تصادفی، قيود همسایگی، متد انتشار شایعه، الگوی باینری محلی.

فهرست مقالات مستخرج از پایان نامه

- [1] Saeideh Eslami, Morteza Zahedi, Reza Azmi “Brain Tissue Segmentation in MRI Images Using Random Forest Classifier and Gossip Based Neighborhood”, 3rd International Conference on Computer Technology and Development (ICCTD2011), 2011, Chengdu, China.
- [2] Morteza Zahedi, Saeideh Eslami, “Improvement of Random Forest Classifier through Localization for Persian Handwritten OCR”, International Conference on Advances in Information and Communication Technologies, (ICT 2011), 2011, Hamburg, Germany.
- [3] Saeideh Eslami, Morteza Zahedi, Reza Azmi, “The Improvement on MRI Segmentation using A Localized Random Forest”, World Conference on Information Technology, (WCIT 2011), 2011, Istanbul, Turkey.

فهرست مطالب

عنوان	صفحه
۱- فصل اول مقدمه	۱
۱-۱- مقدمه	۲
۲-۱- تصویر برداری با تشدید مغناطیسی (MRI)	۵
۳-۱- نحوه تصویربرداری دستگاه MRI	۶
۴-۱- تصویربرداری چندطیفی	۹
۵-۱- محدودیت‌های ناحیه‌بندی	۱۱
۶-۱- بروز مشکل ناهمگنی RF	۱۳
۱-۶-۱- رفع مشکل ناهمگنی RF	۱۴
۷-۱- مساله حجم جزئی	۱۵
۸-۱- عدم توازن داده‌ها	۱۵
۹-۱- تشریح نمونه داده‌های MRI	۱۵
۱۰-۱- رویکرد اصلی در روشهای ناحیه‌بندی	۱۹
۱-۱۰-۱- متدهای ناحیه بندی نظارتی (با ناظر)	۱۹
۲-۱۰-۱- متدهای ناحیه بندی غیر نظارتی (بدون ناظر)	۲۰
۳-۱۰-۱- متدهای ناحیه بندی نیمه نظارتی	۰۲
۴-۱۰-۱- متدهای ناحیه‌بندی مبتنی بر پردازش تصویر	۲۲
۱-۴-۱۰-۱- آستانه‌گیری	۳۲
۵-۱۰-۱- متدهای ناحیه‌بندی مبتنی بر شبکه عصبی	۲۳
۶-۱۰-۱- ناحیه‌بندی با استفاده از متدهای احتمالاتی	۲۵
۷-۱۰-۱- ناحیه‌بندی مبتنی بر کلاسترینگ فازی	۲۵
۱۱-۱- بیان موضوع و اهداف	۲۶
۲- فصل دوم آموزش نیمه‌نظارتی	۲۸
۱-۲- مقدمه	۲۹

۳۰	۲-۲- تکنیکهای آموزش نیمه نظارتی.....
۳۱	۳-۲- کلاس بندی نیمه نظارتی.....
۳۲	۱-۳-۲- تکنیک خودآموزی (self-training).....
۳۲	۱-۱-۳-۲- شبه کد الگوریتم خودآموزی.....
۳۳	۲-۳-۲- تکنیک همکار آموزشی (co-training).....
۳۵	۳-۳-۲- الگوریتم نیمه نظارتی مبتنی بر گراف.....
۲۵	۲-۳-۲- الگوریتم نیمه نظارتی EM.....
۳۶	۴-۲- کلاسترینگ محدود شده.....
۳۶	۵-۲- جمع بندی و بیان اهداف.....
۳۸	۳- فصل سوم الگوریتم جنگل تصادفی.....
۳۹	۱-۳- مقدمه.....
۳۹	۲-۳- جنگل تصادفی.....
۴۱	۳-۳- ویژگیهای الگوریتم جنگل تصادفی.....
۴۳	۴-۳- فرایند آموزش جنگل تصادفی.....
۴۶	۵-۳- مرحله پیش بینی.....
۴۶	۶-۳- شبه کد الگوریتم آموزش جنگل تصادفی.....
۴۸	۷-۳- تنظیم پارامترهای آموزش جنگل.....
۴۹	۸-۳- کلاسترینگ بوسیله جنگل تصادفی.....
۵۰	۹-۳- بهبود درصد شناسایی.....
۵۲	۱۰-۳- جمع بندی و بیان اهداف.....
۵۴	۴- فصل چهارم روش پیشنهادی برای ناحیه بندی محلی بافت مغز.....
۵۵	۱-۴- مقدمه.....
۵۵	۲-۴- ویژگیهای فضایی در مساله ناحیه بندی.....
۵۷	۳-۴- متد انتشار شایعه.....
۶۰	۴-۴- پیش ناحیه بندی مبتنی بر انتشار شایعه.....
۶۱	۵-۴- پیاده سازی مرحله پیش ناحیه بندی.....

۶۴	۶-۴- مرحله استخراج ویژگیها
۶۵	۷-۴- الگوی باینری محلی (LBP)
۶۷	۴-۷-۱- ویژگی LBP متقارن (CS-LBP)
۶۹	۴-۸- کلاس بندی
۷۴	۵- فصل پنجم بررسی نتایج
۷۵	۵-۱- مقدمه
۷۵	۵-۲- دیتابیس تصاویر
۷۷	۵-۳- ناحیه بندی با استفاده از ویژگی سطح خاکستری
۷۸	۵-۴- ناحیه بندی با بلوک بندی ساده
۸۱	۵-۵- استخراج ویژگی با اعمال متد انتشار روی تصویر به صورت محدود شده
۸۴	۵-۶- نتایج نهایی با استفاده از مرحله پیش ناحیه بندی گسترش یافته
۸۸	۵-۷- ناحیه بندی تومور
۹۰	۵-۸- آموزش نیمه نظارتی سیستم
۹۰	۵-۸-۱- مدل آموزشی انتقالی
۹۲	۵-۸-۲- مدل آموزشی استنتاجی
۹۴	۵-۹- مقایسه نتایج بدست آمده از ناحیه بندی با روش پیشنهادی با نتایج متد MRF
۹۶	۵-۱۰- بهبود شناسایی از طریق استفاده از جنگل تصادفی چندگانه
۹۷	۵-۱۱- جمع بندی
۹۸	۶- فصل ششم نتیجه گیری و پیشنهادات آینده
۹۹	۶-۱- جمع بندی
۱۰۰	۶-۲- روشها و نتایج
۱۰۱	۶-۳- پیشنهادات آینده
۱۰۴	۷- پیوست
۱۱۳	۸- مراجع

فهرست شکل‌ها

عنوان	صفحه
شکل (۱-۱) نمونه یک تصویر MRI مغزی [۲]	۲
شکل (۲-۱): ساختار ابتدایی دستگاه MRI	۷
شکل (۳-۱) نمایش زمانهای T_R و T_E [۲]	۸
شکل (۴-۱): نمایش مدل‌های مختلف نمایش تصویر توسط دستگاه MRI	۸
شکل (۵-۱): نمایش چندطیفی یک برش از بافت مغز	۱۰
شکل (۶-۱) نحوه تاثیر تومور بر تقارن بافت مغز	۱۱
شکل (۷-۱): نمودار گوسین ترکیبی مقادیر خاکستری سه بافت اصلی مغز	۱۲
شکل (۸-۱): نمایش اثر بایاس فیلد روی یک تصویر نمونه [۹]	۱۳
شکل (۹-۱): نمایش اثر حجم جزئی	۱۵
شکل (۱۰-۱): تشریح مساله ناحیه‌بندی پیش‌رو با استفاده از یک تصویر نمونه	۱۸
شکل (۱۱-۱): دو نمونه تصویر MRI از بافت مغزی حاوی تومور	۱۹
شکل (۱۲-۱): دسته بندی متدهای ناحیه بندی MRI [۲۶]	۲۲
شکل (۱-۲): نحوه تاثیر داده‌های آموزشی بدون برچسب درمرزهای تصمیم‌گیری [۲۵]	۳۰
شکل (۱-۳): کلاس بندی مبتنی بر Boosting	۴۰
شکل (۲-۳): کلاس بندی مبتنی بر Bagging	۴۱
شکل (۳-۳): کلاس بندی با درخت تصمیم‌گیری [۵۹]	۴۴
شکل (۱-۴): ورود عناصر متعلق به بافت‌های مختلف به بلوک ناحیه بندی	۵۷
شکل (۲-۴): بخش بندی یک شبکه به ۴ ناحیه مجزا با الگوریتم انتشار شایعه [۶۲]	۵۹
شکل (۳-۴): تعیین همسایگی‌های جدید با روش پیشنهادی	۶۲

فهرست شکل‌ها (ادامه)

عنوان	صفحه
شکل (۴-۴): برقراری ارتباط با روش دوست دوست [۷۲].....	۶۳
شکل (۵-۴): نتیجه پیش‌ناحیه‌بندی گسترش یافته.....	۶۴
شکل (۶-۴): محدوده همسایگی اطراف پیکسل مرکزی بر حسب شعاع R [۷۷].....	۶۵
شکل (۷-۴): نمایش ویژگی بافت با استفاده از CS-LBP [۷۷].....	۶۷
شکل (۸-۴): نحوه محاسبه LBP و CS-LBP برای یک پیکسل [۷۷].....	۶۸
شکل (۹-۴): هیستوگرام مقادیر LBP مربوط به ۳ بافت اصلی مغز.....	۶۹
شکل (۱-۵): ناحیه‌بندی با مقادیر خاکستری.....	۷۸
شکل (۲-۵): بهبود نتیجه ناحیه‌بندی روی بافت CSF پس از بلوک‌بندی.....	۸۱
شکل (۳-۵): مقایسه نتیجه حاصل از ناحیه‌بندی.....	۸۴
شکل (۴-۵): بخش‌بندی اولیه تصویر.....	۸۴
شکل (۵-۵): مقایسه نتیجه حاصل از ناحیه‌بندی.....	۸۷
شکل (۶-۵): مقایسه نتیجه ناحیه‌بندی.....	۸۷
شکل (۷-۵): نمودار بهبود نتایج کلاس‌بندی توسط جنگل تصادفی چندگانه.....	۹۷
شکل (۱-۶): حذف جزئیات مرزها در ناحیه‌بندی با متد MRF.....	۱۰۲

فهرست جدول‌ها

صفحه	عنوان
۱۰.....[۶]	جدول (۱-۱): جدول چگونگی نمایش بافندهای مختلف مغزی در تصاویر چندطیفی
۷۶.....	جدول (۱-۵): تفصیل مشخصات مجموعه تصاویر مورد استفاده
۸۰.....	جدول (۲-۵): میزان خطای ناحیه بندی با روش های ساده استخراج ویژگی
۸۲.....	جدول (۳-۵): نمودار نتایج ناحیه بندی به تفکیک بافت با استفاده از معیار ضریب Dice
۸۳.....	جدول (۴-۵): نتایج ناحیه بندی با مقادیر خاکستری و بلوک بندی ساده
۸۵.....	جدول (۵-۵): نتایج حاصل از ناحیه بندی توسط متد انتشار شایعه گسترش یافته
۸۷.....	جدول (۶-۵): مقایسه نتایج حاصل از ناحیه بندی به تفکیک بافت و روش استفاده شده
۸۹.....	جدول (۷-۵): تفکیک تومور از بافت سالم به روش بلوک بندی و روش پیشنهادی
۹۱.....	جدول (۸-۵): مدل آموزشی انتقالی
۹۳.....	جدول (۹-۵): مدل آموزشی استنتاجی
۹۴.....	جدول (۱۰-۵): مقایسه نتیجه ناحیه بندی توسط متد MRF و روش پیشنهادی

جدول کلمات اختصاری


RF	Random Forest
MRI	Magnetic Resonance Imaging
Voxel	Volumed pixel
GM	Gray Matter
WM	White Matter
CSF	CerebroSpinal Fluid
PD	Proton Density
EM	Expectation Maximization
FCM	Fuzzy C-Means
MRF	Markov Random Field
CRF	Conditional Random Field
CART	Classification And Regression Tree
LBP	Local Binary Pattern
CS-LBP	Center Symmetric Local Binary Pattern
GLCM	Gray-Level Co-occurrence Matrix

فصل اول

مقدمه

۱-۱- مقدمه

بافت مغز ترکیبی از چندین بافت متفاوت شامل ماده سفید^۱، ماده خاکستری^۲، مایع مغزی نخاعی^۳، رگ‌های خونی، استخوان، ماهیچه و بافت چربی است. کلاس‌بندی و تفکیک پیکسل‌های مربوط به بافت‌های سالم از بافت‌هایی نظیر توده تومور^۴، بافت ادم^۵، نکروز^۶ و غیره هدف اصلی در مقوله ناحیه‌بندی تصاویر MRI مغز محسوب می‌شود [۱].



شکل (۱-۰۰) نمونه یک تصویر MRI مغزی شامل بافت‌های اصلی مغزی و بافت چشم، سینوس و جمجمه [۲]

ناحیه‌بندی صحیح بافت مغز در درک آناتومی و نیز آسیب‌شناسی بافت مغز بسیار ضروری است. بررسی و تخمین کیفی فرآیند رشد تومور و تاثیر رفتار داروها در بهبود بیماری از جمله حیاتی‌ترین کاربردهای ناحیه‌بندی محسوب می‌شوند. در استفاده از رادیوتراپی بجای عمل جراحی برای درمان تومور، ناحیه‌بندی اهمیت ویژه‌ای می‌یابد. تاکید خاص روی دقت تفکیک به دلیل تشخیص بافت سالم اطراف تومور و حفظ آن از اشعه هنگام پرتوفکنی به تومور است. با در نظر گرفتن این موضوع،

¹ White Matter (WM)

² Gray Matter (GM)

³ Cerebrospinal Fluid (CSF)

⁴ Tumor volume

⁵ Edema

⁶ Necrosis

کیفیت و وضوح تصاویر اولیه نیز یکی از شرایط موفقیت محسوب می‌شود.

تصویربرداری به روش MRI¹، تکنیک بسیار متداولی است که بدون آسیب‌رسانی به بافت‌های زنده قادر است تصاویری با کیفیت بسیار بالا از بافت‌های نرم بدن تولید کند. نظر به کیفیت بالا و جزئیات تصویری که توسط MRI تولید می‌شود، روش بسیار ارزشمندی در تشخیص و تعیین روش درمان دسته‌ای از بیماری‌ها محسوب می‌شود. معمولاً یک نوع تصویر MRI به تنهایی درک کاملی از ابعاد، وسعت و سایر ویژگی‌های اساسی تومور ایجاد نمی‌کند؛ به همین دلیل ناحیه‌بندی غالباً با استفاده از ترکیب اطلاعات بدست‌آمده از چندین تصویر، بخصوص ترکیب سه تصویر T1²، T2³ و PD⁴ صورت می‌پذیرد. این تصاویر به سادگی از طریق تنظیم دو پارامتر مهم تصویربرداری با نام زمان آکو (پژواک)⁵ و زمان تکرار⁶ بدست می‌آیند.

ناحیه‌بندی تصاویر MRI و جداسازی بافت تومور معمولاً به صورت دستی توسط متخصصین رادیولوژی صورت می‌گیرد که فرآیند خسته‌کننده و زمان‌بری بوده و نتیجه حاصل همیشه تحت‌تاثیر خطای دید خواهد بود. از طرفی معمولاً نتیجه ناحیه‌بندی یک تصویر یکسان توسط دو متخصص باهم تفاوت قابل‌ملاحظه‌ای دارد. پیچیدگی و هزینه‌بر بودن این فرآیند نهایتاً اتوماتیک‌سازی ناحیه‌بندی را موضوع تحقیقات بسیاری قرار داده است [۳،۴].

در این پایان‌نامه ضمن معرفی و بررسی روش‌های متداول ناحیه‌بندی MRI، روش خود را که یک الگوریتم نیمه‌نظارتی و وقتی مبتنی بر کلاسیفایر جنگل تصادفی است، معرفی خواهیم نمود. برای افزودن قابلیت وقتی به سیستم، ما جنبه استخراج ویژگی‌ها و قیود همسایگی را به صورت محلی و باتوجه به داده، در نظر گرفتیم. به این ترتیب محدوده همسایگی ثابتی برای یک پیکسل در نظر گرفته-

¹ Magnetic Resonance Imaging

² T1-weighted

³ T2-weighted

⁴ Proton Density

⁵ Echo time (TE)

⁶ Repetition time (TR)

نشده و پیکسل‌های درون ناحیه اولیه‌ای که بعداً در اطراف پیکسل شکل خواهد گرفت به عنوان پیکسل‌های همسایه در تعیین مقدار این پیکسل استفاده خواهند شد. برای تعیین ناحیه مناسب استخراج ویژگی، متد انتشار شایعه را که در اصل یکی از روش‌های پخش داده در شبکه‌های توزیع-شده است، به حوزه ناحیه‌بندی تصویر وارد کردیم. امتیاز این نوع استخراج ویژگی در کلاس‌بندی دقیق‌تر و جزئی‌تر پیکسل‌های واقع در مرز بافت‌هاست که اغلب اشتباه کلاس‌بندی می‌شوند. استفاده از کلاسیفایر جنگل تصادفی برای طبقه‌بندی پیکسل‌ها با استفاده از ویژگی‌های فراهم‌شده این امتیاز را دارد که ضمن ارائه دقت بالا از سرعت خوبی نیز برخوردار است. این امکان استفاده از بردارهای ویژگی طولانی را در مواقع لزوم به ما می‌دهد بدون اینکه از لحاظ زمانی چالشی ایجاد شود. کلاسیفایر جنگل تصادفی خواص ویژه دیگری نیز دارد که بعداً به آن اشاره خواهد شد. برای کاهش نیاز به یک متخصص برای فراهم کردن داده آموزشی ناحیه‌بندی شده تصمیم گرفتیم کلاسیفایر را با متد نیمه-نظارتی آموزش دهیم. این متد می‌تواند قسمتی از آموزش سیستم را با استفاده از داده‌هایی که در ابتدا برچسب نخورده‌اند انجام دهد.

چالش‌های پیش‌روی مساله اتوماتیک‌سازی تفکیک بافت‌های مغزی در تصاویر MRI، روش‌های مقابله با ناهمگنی در سطح روشنایی بافت‌ها، معرفی اجمالی روش‌های متداول ناحیه‌بندی MRI و مشکلات هریک از این متدها در مقدمه این تحقیق تشریح خواهد شد. در فصل دوم به معرفی تکنیک-های آموزشی نیمه‌نظارتی خواهیم پرداخت. فصل سوم به تشریح الگوریتم جنگل تصادفی و نحوه آموزش آن می‌پردازد. در فصل چهارم روش پیشنهادی ما برای ناحیه‌بندی تصاویر MRI مغز معرفی شده و نحوه پیاده‌سازی مفهوم همسایگی محلی و آموزش نیمه‌نظارتی سیستم به تفصیل بحث خواهد شد. نتایج حاصل از پیاده‌سازی الگوریتم پیشنهادی و تفسیر نتایج در فصل پنجم و نهایتاً نتیجه‌گیری و پیشنهادات آینده برای بهبود سیستم در فصل ششم ارائه خواهد شد.

۱-۲- تصویر برداری با تشدید مغناطیسی (MRI)

اصطلاح MRI، مخفف کلمه لاتین "Magnetic Resonance Imaging" به معنی تصویربرداری با تشدید مغناطیسی است. هرچند در حدود ۴۰ سال از معرفی روش MRI می گذرد اما استفاده از آن به صورت کاربردی از آغاز دهه ۱۹۸۰ مطرح شد. اهمیت تصویربرداری MRI در پیشبرد علم پزشکی تا آنجاست که این روش تاکنون جوایز نوبل متعددی را نصیب مبدعین خود کرده است. برخلاف رادیوگرافی‌های معمولی x-Ray و یا CT، بدلیل استفاده از امواج رادیویی و مغناطیسی، MRI پرتوهای یونیزان و مضر ندارد.

در حال حاضر MRI به نحو موثری در تشخیص بسیاری از ضایعات و درمان بیماری‌ها بخصوص سرطان و نیز در درمان و دنبال کردن مسیر بیماری به کار می‌رود. از آنجا که اسکن MRI قادر است تصاویر واضحی را از بافت‌های نرم احاطه شده در بافت استخوانی فراهم سازد، در شناسایی تمام ناهنجاری‌های مغز و نخاع نظیر صدمات وارده به نخاع، تومورهای مغزی، خونریزی‌ها و سگته‌های مغزی مورد استفاده قرار می‌گیرد. غیر از بافت مغزی، MRI به طور گسترده‌ای در بررسی وضعیت تاندون‌ها، عضلات و آسیب‌های احتمالی به استخوان‌ها به کار می‌رود. امکان بررسی دقیق وضعیت اندام‌های درونی حفره شکم، قلب، گردش خون و تشخیص نواقص مادرزادی قلب نیز به راحتی توسط متد MRI امکان پذیر است.

یک مزیت مهم دیگر تصویربرداری به روش MRI بدست آوردن تصاویری سه بعدی از بافت مورد نظر است. زیرا با نگاشت بافت سه بعدی به فضای دوبعدی بدلیل محدودیت نمایش در این فضا اطلاعات با ارزشی راجع به وضعیت واقعی بافت از بین می‌رود. اکثر متدهای تصویربرداری متداول فاقد این ویژگی هستند.


۳-۱- نحوه تصویربرداری دستگاه MRI

با استفاده از میدان مغناطیسی و استفاده از مفهوم گرادیان در تنظیم قدرت میدان مغناطیسی تهیه تصاویر دو بعدی به این صورت امکان پذیر شد. این سیستم ساده، اساس روش تصویربرداری MRI است که برای اولین بار توسط آن امکان تفکیک آب معمولی از آب سنگین فراهم شد. با تکیه بر این ویژگی، از فراوانی آب در بدن برای تصویربرداری به روش MRI استفاده شد.

برای ایجاد یک تصویر سه بعدی، بدن از سه جهت تحت تابش یک میدان مغناطیسی دوار قرار می گیرد که شدت آن در حدود ۲۰۰۰۰-۳۰۰۰۰ برابر شدت میدان مغناطیس زمین است. هیدروژن-های دوقطبی موجود در آب تحت تاثیر میدان مغناطیسی در یک جهت به خط می شوند. چنانچه در این زمان امواج رادیویی با فرکانس معین برابر با فرکانس اسپین الکترون ها به بدن تابیده شود، هسته اتم هیدروژن برانگیخته می شود. حال با قطع میدان، نیروی محرک از هسته هایی که در اثر پدیده تشدید انرژی دریافت کرده و دامنه نوسان آنها افزایش یافته است، برداشته می شود. با بازگشت هسته ها به حالت اولیه انرژی بدست آمده به صورت امواج الکترومغناطیسی و گرما بازتابانده شده و توسط سیم-پیچ یا کوئل دستگاه دریافت می شود. از آنجا که بین محتوای آب بافت های متفاوت و همچنین بین محتوای آب بافت سالم و بافت بیمار تفاوت وجود دارد، زمان برگشت به حالت پایه در بافت های مختلف متفاوت است [۵]. امواج دریافتی پس از تبدیل به جریان الکتریکی تبدیل به تصویری از ناحیه تحت تابش خواهند شد. مبنای این تصاویر محل و قدرت سیگنال های ورودی است. در این جا آنچه ایجاد تصاویر را با این کیفیت بالا ممکن می سازد، استفاده از گرادیان است. گرادیان میدان مغناطیسی به جهتی که بیشترین نیروی میدان در آن راستا وارد می شود اطلاق می شود. برای تهیه تصاویر از قسمت مورد نظر باید گرادیان میدان مغناطیسی به این جهت هدایت شود.

تصویربرداری به روش MRI امروزه بیش از سایر روش های تصویربرداری در دنیا رواج داشته و می تواند جایگزین شیوه های قبلی شود زیرا با توجه به دانش امروزه ما هیچ عارضه جانبی ندارد. یک

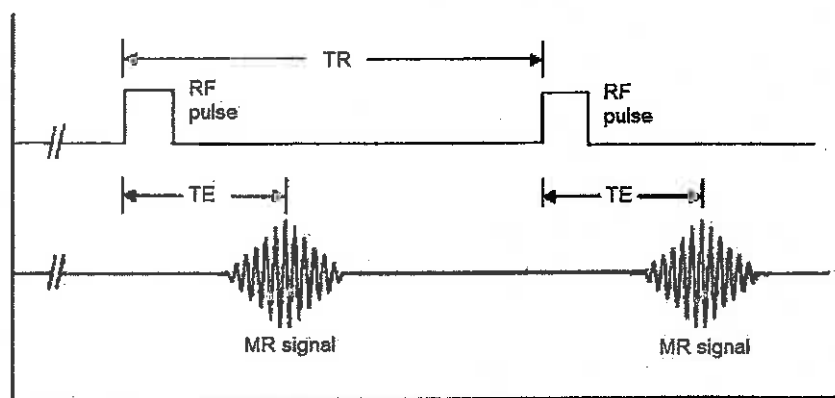
نمونه ساده از دستگاه تصویربرداری MRI با اجزای اصلی در شکل (۲-۱) نشان داده شده است.



شکل (۲-۰): ساختار ابتدایی دستگاه MRI^۱


در مرحله قطع میدان مغناطیسی، بازگشت هسته‌ها به حالت اولیه بسیار سریع و ناگهانی است؛ لذا سیگنالی که از خود ساطع می‌کنند نیز یک سیگنال کوتاه است. برای تحلیل بهتر سیگنال از یک سیگنال فرکانسی متناوب بجای یک پالس رادیویی استفاده می‌شود و هر بار پس از پایان یک پالس برای جلوگیری از برگشت سریع هسته‌ها، پالس دیگری پیش از خنثی شدن هسته‌ها بر آن‌ها وارد شده و آن‌ها را مجدداً به حالت برانگیخته برمی‌گرداند. از آن‌جا که زمان برگشت هسته‌ها در بافت‌های مختلف متفاوت است، فاصله زمانی بین دو پالس رادیویی شکل سیگنال ساطع شده از بدن بیمار را مشخص می‌کند. این فاصله زمان تکرار یا T_R خوانده می‌شود. از زمان شروع پالس رادیویی تا زمان نمونه‌برداری از سیگنال MR تابش شده از هسته‌ها، زمان اکو یا پژواک (T_E) نام دارد. شکل (۳-۱) به خوبی این مفهوم را نشان می‌دهد. برای هر نوع تصویر MRI این دو زمان به شیوه متفاوتی تنظیم می‌شوند.

¹ Available at " <http://universe-review.ca/R10-22-tomography.htm>"



شکل (۳-۰) نمایش زمان‌های T_E و T_R [۲]

تصاویر تولیدشده توسط دستگاه بر مبنای محور تصویربرداری به سه دسته محوری^۱، حلقوی^۲ و سهموی^۳ تقسیم می‌شوند. در این میان تصاویر حلقوی بیش از دو مدل دیگر عمومیت دارند. اما برای بدست آوردن دید سه‌بعدی نسبت به وضعیت مغز یا حجم تومور هر سه نوع تصویر استفاده می‌شود. شکل (۴-۱) نحوه برش مغزی را در هر یک از این تصاویر نمایش می‌دهد.



شکل (۴-۰): نمایش مدل‌های مختلف نمایش تصویر توسط دستگاه MRI: (الف) سهموی، (ب) حلقوی، (ج) محوری

¹ Axial

² Coronal

³ Sagittal

⁴ Available at "http://users.fmrib.ox.ac.uk/~stuart/thesis/chapter_3/section3_2.html"

۱-۴- تصویربرداری چندطیفی

سیگنال MRI برای هر نقطه تصویر حاوی سه مولفه است: چگالی پروتن^۱ در این نقطه، زمان برانگیختگی و زمان استراحت یا بازگشت که بترتیب با T1 و T2 نمایش داده می‌شود [۱]. از آنجا که اندازه T1 و T2 برای بافت‌های مختلف تفاوت دارد، از این دو زمان برای شناسایی بافت‌ها استفاده می‌شود.

زمان T1 به زمانی اطلاق می‌شود که هسته اتم برای برانگیخته شدن نیاز دارد و به همین ترتیب تصویر T1 تصویری است که در این زمان از بافت بدست می‌آید. در مقابل زمان T2 زمانیهایی است که هسته اتم برای بازگشت از حالت برانگیخته به حالت اولیه خود نیاز دارد. حال هر چه بافت مورد بررسی زمان برانگیخته شدن سریع‌تری داشته باشد در تصویر T1 روشن‌تر به نظر می‌رسد و هرچه این زمان طولانی‌تر باشد، بافت تیره‌تر نمایش داده می‌شود. در تصویر T2 هرچه زمان برگشت سریع‌تر باشد بافت تیره‌تر است و بالعکس. در تصاویر موسوم به PD میزان روشنایی بافت وابسته به چگالی پروتن در بافت است. چگالی پروتن در بافت‌هایی که آب بیشتری در خود دارند، بیشتر است؛ لذا این بافت‌ها در تصاویر PD روشن‌تر از سایرین هستند. معمولاً تصاویر T1 و T2 عکس هم هستند به این معنا که اغلب بافت‌هایی که در تصویر T1 روشن هستند، در تصویر T2 تیره ظاهر می‌شوند و بالعکس. از طرفی بافت‌هایی که بیشتر از آب تشکیل شده‌اند زودتر از سایرین به حالت پایه بر می‌گردند، در تصویر T2 روشن‌تر هستند. لذا وضعیت روشنایی بافت‌های متناظر در تصاویر T2 و PD به هم شبیه است. این مطلب در شکل (۱-۵) به خوبی نشان داده می‌شود.

¹ Proton Density (PD)



(ج)

(ب)

(الف)

شکل (۵-۰): نمایش چندطیفی یک برش از بافت مغز^۱: (الف) تصویر T1-weighted، (ب) تصویر T2-weighted، (ج) تصویر PD

دسته پردازش‌هایی که از یک نوع تصویر MR استفاده می‌کنند، پردازش‌های تک‌طیفی و پردازش‌هایی که از ترکیب اطلاعات چند تصویر مثلاً تصاویر T1، T2 و PD استفاده می‌کنند، پردازش‌های چندطیفی نام‌دارند. با توجه به پیچیدگی ناحیه‌بندی بافت مغز استفاده از پردازش‌های چندطیفی برای رسیدن به یک الگوریتم کارا ضروری است. هرچند حتی با وجود استفاده از تصاویر چندطیفی معمولاً یک متد کلاس‌بندی ساده در یک مرحله قادر به تفکیک برخی از بافت‌ها نظیر بافت چربی از ماده سفید یا مغز استخوان از ماهیچه نیست [۱]. جدول زیر نحوه نمایش بافت‌های مغزی را در این سه تصویر تشریح می‌کند.

جدول (۱-۰): جدول چگونگی نمایش بافت‌های مختلف مغزی در تصاویر چندطیفی [۶]


بافت	روشنایی سیگنال	دنباله تحریک
چربی، مایعات مغزی (آب خالص)	چگالی پروتونی بالا (روشن)	PD
کلسیم، هوا، بافت فیبروز، استخوان کورتیکال	چگالی پروتونی پایین (تاریک)	PD
چربی، مولکولهای حاوی چربی، مایعات پروتئین-دار	زمان T1 کوتاه (روشن)	T1
تومور، ادم، مایع مغزی نخاعی، آب خالص، التهاب	زمان T1 طولانی (تاریک)	T1
بافت‌های حاوی آهن	زمان T2 کوتاه (تاریک)	T2
تومور، ادم، مایع مغزی نخاعی، آب خالص، التهاب	زمان T2 طولانی (روشن)	T2

¹ Available at "http://www.grin.com/en/doc/281950/linear-spectral-unmixing-approaches-to-magnetic-resonance-image-classification"

برای بدست آوردن تصویر صحیحی از بافت مغز لازم است ناحیه بندی روی هر سه نوع تصویر اعمال شده و نتایج بدست آمده بعداً روی هم منطبق^۱ شود.

۲ ۵ محدودیت های ناحیه بندی

اتوماتیک سازی فرآیند ناحیه بندی تومور بدلیل تفاوت تومورها از لحاظ شکل ظاهری، ترکیب بافتی، موقعیت و اندازه در بیماران مختلف و نیز شباهت بین بافت تومور و بافت سالم بسیار پیچیده است. به این موارد میتوان این را افزود که تومور معمولاً با ادم همراه بوده و سبب تغییر شکل بافت اطراف خود می گردد که این روش هایی همانند تطابق الگو را دچار مشکل می کند. از بین رفتن تقارن بافت مغز توسط تومور در شکل (۱-۶) نشان داده شده است. بسته به موقعیت تومور این وضعیت در هر جای مغز ممکن است رخ دهد.



(ب)

(الف)


شکل (۲-۶) نحوه تاثیر تومور بر تقارن بافت مغز (الف) الگوی مغز سالم، (ب) مغز فرد بیمار (تومور و ادم تومور مشخص شده است) تومور سبب شده بافت اطراف به سمت دیگر فشرده شده و در نتیجه از حالت متقارن طبیعی خارج شوند.

علاوه بر این جابجایی احتمالی بیمار حین تصویربرداری ممکن است تشخیص مرزها را دشوار

سازد. به لحاظ تکنیکی شباهت و درهم آمیختگی روشنایی بافت های مختلف به یکدیگر و تفاوت

¹ Registration

کنتراست تصاویر مختلف MR نیز از عواملی است که بر پیچیدگی مساله می‌افزاید [۷]. در شکل (۷-۱) نمودار گوسین ترکیبی سه بافت اصلی مغز که با استفاده از توزیع روشنایی هریک از بافت‌ها محاسبه شده، نمایش داده شده است. همانطور که مشاهده می‌شود، در نمودار دره عمیقی وجود نداشته و توزیع گوسین این بافت‌ها با هم هم‌پوشانی دارد. لذا تصمیم‌گیری دقیقی در مورد نوع بافت‌ها بر این اساس امکان ندارد. این مشکل بیشتر بین دو بافت ماده سفید و ماده خاکستری قابل توجه است. از آنجا که این دو بافت قسمت اعظم مغز را تشکیل می‌دهند، خطا در شناسایی این دو برای متد ناحیه-بندی افت کیفیت زیادی بدنبال خواهد داشت.




شکل (۷-۰): نمودار گوسین ترکیبی مقادیر خاکستری سه بافت اصلی مغز

یک متد ناحیه‌بندی برای اینکه در مسائل پزشکی واقعی کاربرد داشته باشد، باید علاوه بر برخورداری از سرعت بالا، تا حد امکان بی‌نیاز از اپراتور و یا اطلاعات اولیه باشد. مقاوم‌بودن در برابر نویز و تغییرات ناخواسته در سطح روشنایی تصویر نیز از دیگر ویژگی‌های یک متد ناحیه‌بندی قدرتمند به‌شمار می‌رود. توانایی انطباق با هرگونه آناتومی مغز و یا هرگونه تومور احتمالی که در هر مکانی از تصویر ممکن است وجود داشته یا نداشته باشد نیز یک ضرورت برای چنین متدی محسوب می‌شود. در ادامه به متداول‌ترین مشکلات موجود در ناحیه‌بندی MRI اشاره کرده و آنها را تشریح خواهیم نمود.

۱-۶- بروز مشکل ناهمگنی RF^۱

یکی از مشکلات اساسی در تحلیل و آنالیز داده‌های MRI، غیریکنواختی یا ناهمگنی روشنایی بافت‌هاست. در این حالت روشنایی در نواحی مختلف یک بافت واحد یکسان نیست. بعبارتی نوعی سایه روی تصویر می‌افتد که شدت روشنی آن در طول تصویر کم و زیاد می‌شود. بروز این مساله یا در نتیجه تغییرات طبیعی در بافت موردبررسی و یا در نتیجه نقص در سیم‌پیچ دریافت‌کننده امواج مغناطیسی دستگاه، موسوم به کوئل RF است [۸]. بروز این پدیده در تصویر با نام ناهمگنی RF و یا اثر بایاس فیلد شناخته می‌شود.

بروز ناهمگنی در روشنایی بافت‌ها سبب بهم‌خوردن ویژگی‌های آماری داده MR و ایجاد تصویری غیرواقعی شده و ناحیه‌بندی بافت‌ها را به یک مساله پیچیده تبدیل میکند [۱]. هرچند این مساله اغلب برای پزشکان خبره در تشخیص اشکال جدی بوجود نمی‌آورد اما تقریباً همه متدهای اتوماتیک ناحیه‌بندی را گمراه می‌سازد. تصویر (۱-۸) اثر ناهمگنی و نحوه تغییر مقادیر را روی یک تصویر نمونه نشان می‌دهد. نحوه تاثیر بایاس فیلد روی تصاویر MRI نیز به همین صورت می‌باشد.



شکل (۸-۱): نمایش اثر بایاس فیلد روی یک تصویر نمونه: (الف) تصویر اصلی، (ب) تصویر نمایش داده‌شده، (ج) فیلتر اعمال‌شده روی تصویر [۹]

برای بررسی نحوه مغشوش‌شدن سیگنال باید اشاره کرد که سیگنال MR مشاهده‌شده به

صورت تئوریک با رابطه (۱-۱) تعریف می‌شود.

$$\forall k \in \{1, 2, \dots, N\} S_k = R_k \beta_k + N_k \quad (1-1)$$

^۱ RF Inhomogeneity

در این رابطه S_k سیگنال مشاهده شده، R_k سیگنال اصلی N_k ، نویز افزوده شده به سیگنال و B_k مقدار بایاس در وکسل k ام است که در سیگنال اصلی ضرب شده و آنرا دستخوش تغییر می‌سازد. اگر مقدار بایاس مشخص باشد تشخیص کلاس بافت به سادگی با استفاده از یک روش ناحیه‌بندی ساده روی تصویر اصلاح شده امکان‌پذیر است. به طور عکس چنانچه نوع بافت مشخص باشد می‌توان مقدار بایاس را به سادگی مشخص نمود. اما مساله اینست که معمولا هیچ اطلاعی نسبت به نوع بافت یا مقدار احتمالی بایاس از قبل معلوم نیست [۱۰،۱۱].

۱-۶-۱- رفع مشکل ناهمگنی RF

دشواری رفع ناهمگنی تصویر MR به این مساله برمی‌گردد که عوامل زیادی در آن دخیل هستند. میزان این ناهمگنی حتی در تصاویر مختلف متعلق به یک دستگاه تصویربرداری یکسان نیست. عبارتی این مقدار برای هر تصویر و از بیماری به بیمار دیگر متفاوت است. بنابراین اصلاح ناهمگنی باید به طور مجزا برای هر تصویری انجام شود [۸،۱۰]. توانایی سیستم در بدست آوردن بایاس مناسب برای هر تصویر و در نقاط مختلف آن می‌تواند به عنوان یکی از جنبه‌های سیستم وفقی مورد بررسی قرار گیرد.

برای رفع مشکل ناهمگنی رویکردهای متفاوتی مورد توجه بوده است. بسیاری از روشهای ناحیه‌بندی نظیر حوضچه^۱ اصولا پدیده ناهمگنی را نادیده گرفته و بدون اصلاح این نقیصه بافت‌ها را از یکدیگر تفکیک می‌کنند. واضح است که این رویکرد دقت کافی نداشته و احتمال خطای کلاس-بندی در آن بسیار بالاست [۱۱].

ممکن است الگوریتم ناحیه‌بندی با تکنیک لبه‌یابی نواحی همگن را از یکدیگر تفکیک کند. البته نتیجه این روش کاملا به کیفیت تصویر و دقت ناحیه‌بندی وابسته است [۱۲].

اما عمده روشهای پیشنهادی برای رفع ناهمگنی بدست‌آوردن تخمین صحیحی از مقدار بایاس


¹ Watershed

فیلد را برای اصلاح تصویر تولیدی مورد توجه قرار داده‌اند. در برخی روشهای تکرار شونده فازی اصلاح بایاس تصویر همزمان با ناحیه‌بندی آن امکان‌پذیر است [۱۲].

۷-۱- مساله حجم جزئی

یکی دیگر از پیچیدگی‌های ناحیه‌بندی نحوه برخورد با مساله حجم جزئی^۱ است. در این حالت یک وکسل^۲ ترکیبی از چند بافت مختلف مغزی است. بروز چنین پدیده‌ای یا بدلیل رزولوشن پایین تصویر است که سبب درهم آمیختگی بافت‌های مختلف می‌شود و یا دلیل آن وسعت سطح در نظر گرفته‌شده برای یک وکسل است؛ اما در هر صورت می‌تواند ویژگی‌های آماری داده نظیر میانگین و واریانس یا توزیع گوسین بافت‌ها را بهم بریزد [۱۳، ۱].

شکل (۱-۹) نحوه بروز مشکل حجم جزئی را بصورت یک نمونه بسیار ساده نمایش می‌دهد. یک وکسل از آن‌جا که شکل فیزیکی ثابتی دارد، در قسمت‌های مرزی می‌تواند چندین بافت را دربر بگیرد. برای کاستن احتمال بروز این مساله می‌توان سایز وکسل‌ها را کوچک‌تر در نظر گرفت تا محاسبات به‌صورت جزئی‌تری انجام شوند اما این کار حساسیت ویژگی‌های آماری در برابر نویز را نیز بالا خواهد برد.



شکل (۹-۱): نمایش اثر حجم جزئی الف) قسمتی از بافت مغز در مرز دو بافت مختلف ب) نمایی اغراق‌شده از وکسل واقعی ج) تصویر آن‌چه سیستم ناحیه‌بندی تفسیر می‌کند^۳

¹ Partial Voluming

² Voxel

³ Available at "<http://www.hindawi.com/journals/acisc/2011/786369/fig3>"

برای مقابله با این مشکل پیشنهاد می‌شود از هیستوگرام محلی بجای هیستوگرام کلی بافت‌ها یا از میدان مخفی مارکوف^۱ برای اطمینان از همگنی درون بافت‌های ناحیه‌بندی‌شده استفاده شود [۱]. علاوه بر این در متدهای مبتنی بر مدل از تطابق جزء به جزء اطلس بافت مغزی انسان روی تصویر مورد بررسی استفاده می‌شود. با مشخص بودن کلاس هر پیکسل این مشکل مرتفع می‌شود. البته روش‌های مبتنی بر اطلس در مورد بافت‌های مغزی که توازن آنها در نتیجه بروز یک ضایعه مثل تومور بهم خورده است کارا نیستند [۱۳].

۱-۸ - عدم توازن داده‌ها

این مساله اختصاص به ناحیه‌بندی MRI نداشته و کلا یکی از مشکلاتی است که برای کلاسیفایرها در کار با داده‌های واقعی رخ می‌دهد. در این حالت، نسبت نمونه‌های آموزشی یک یا چند کلاس نسبت به سایر کلاس‌ها بسیار ناچیز است که سبب می‌شود کلاسیفایر این داده‌ها به‌طور کامل فرانگرفته و بعداً هنگام کلاس‌بندی چنین داده‌هایی با آنها همانند نویز برخورد کند. این مساله انتخاب ویژگی‌های مناسب برای تشخیص هر یک از کلاس‌ها را نیز با مشکل مواجه می‌سازد [۱۴]. از آنجا که کلاس اقلیت (کوچکتر) درصد کمی از داده‌ها را شامل می‌شود، تشخیص غلط آنها تاثیر قابل توجهی روی درصد شناسایی کلی کلاسیفایر نخواهد گذاشت [۱۵] و چون کلاسیفایر بدنبال بالا بردن کارایی و دقت کلی کلاس‌بندی است، برای بهبود پاسخ به صورت جزئی تلاش نخواهد کرد. مقابله با این مشکل دو راه حل کلی دارد: استفاده از تابع هزینه و یا استفاده از تکنیک over-sampling (under-sampling).

در روش over-sampling تعدادی از داده‌های کلاس کوچکتر به‌طور راندوم انتخاب شده و به عنوان داده جدید دوباره به مجموعه آموزشی اضافه می‌شوند. هرچند over-sampling اطلاعات جدیدی راجع به داده به مجموعه اضافه نمی‌کند اما این روش احتمال آموزش بیش از حد داده‌های


¹ Markov Random Field

کپی شده را بالا می‌برد. از طرفی چنانچه حجم مجموعه داده‌ها زیاد باشد، این کار بار محاسباتی نسبتاً زیادی را به سیستم تحمیل می‌کند. بر عکس در تکنیک *under-sampling* تعدادی از داده‌های کلاس اکثریت از مجموعه داده‌ها حذف می‌شوند. ایراد اصلی این روش حذف ناخواسته تعدادی از داده‌های باارزش است. برای بهبود این دو روش کلی روشهایی همانند کاهش نمونه‌های کلاس اکثریت (بررگتر) همزمان با افزایش داده‌های کلاس اقلیت [۱۴] و یا استفاده از داده ساختگی به جای کپی مقادیر [۱۶] و تعدادی روش‌های ترکیبی پیشنهاد شده‌اند [۱۷].

در استفاده از روش تابع هزینه، به‌ازای خطای کلاس‌بندی جریمه‌ای در نظر گرفته می‌شود و کلاسیفایر باید این هزینه را می‌نیمم کند. با در نظر گرفتن هزینه بیشتر برای خطا در تشخیص کلاس کوچکتر، کلاسیفایر فرامی‌گیرد تا داده‌های این دسته را با دقت بیشتری کلاس‌بندی کند [۱۵].

۹-۱- تشریح نمونه داده‌های MRI

برای تشریح آنچه در ناحیه‌بندی تصاویر MRI مغزی به آن خواهیم پرداخت، نمونه‌ای از تصاویر مورد استفاده در شکل (۱-۱۰) نمایش آورده شده است. تصویر نمایش داده شده توسط یک متخصص رادیولوژی خبره ناحیه‌بندی شده است. مرجع این تصاویر دیتابیس معتبر IBSR است که حاوی چندین هزار تصویر MRI واقعی از مغز انسان است [۱۸]. تعدادی از این تصاویر توسط متخصصین رادیولوژی به صورت دستی برچسب‌گذاری شده‌اند. همانطور به عنوان نمونه‌ای از این تصاویر در شکل ملاحظه می‌شود، دو لایه غشای مغزی و ماده خاکستری بدلیل نزدیک بودن مقادیر با یکدیگر یکپارچه در نظر گرفته می‌شوند. لذا آموزش سیستم ناحیه‌بندی نیز باید به همین صورت انجام گیرد تا تصاویر از لحاظ دقت قابل تحلیل باشند.



شکل (۱۰۰۰) تشریح مساله ناحیه‌بندی پیش‌رو با استفاده از یک تصویر نمونه، (الف) تصویر MRI، (ب) نمونه ناحیه‌بندی شده تصویر

مایع مغزی نخاعی یکی از بافت‌های چالش برانگیز برای متد ناحیه‌بندی است. این بافت به لحاظ اینکه سطح بسیار کوچکی از تصویر مغز را اشغال می‌کند، عموماً توسط متد ناحیه‌بندی نادیده گرفته می‌شود. اما یکی از اساسی‌ترین مسائل تفکیک بافت سفید از بافت خاکستری است که از لحاظ سطح روشنایی به یکدیگر تا اندازه‌ای نزدیک بوده و در مرز بین دو بافت با یکدیگر آمیختگی دارند. همین مساله متد را در تصمیم‌گیری برای تخصیص برچسب به پیکسل‌ها با دشواری مواجه خواهد کرد. راه‌حل مقابله با مشکلات ذکر شده در بخش‌های قبل تشریح شد.

همانطور که قبلاً اشاره شد، تومور ممکن است در هر جای مغز تشکیل شود و شکل منظمی نیز ندارد. نکته مهم در مورد تومور که آن را قابل شناسایی می‌سازد، سطح روشنایی بسیار متفاوت آن از سایر بافت‌هاست. تومور در تصویر T1 روشن‌ترین ناحیه تصویر است. البته برای بهبود شناسایی تومور پیش از تصویربرداری ماده حاجبی به نام گادولینیوم به بیمار تزریق می‌شود که زمان تصویربرداری سبب روشنایی بیشتر محدوده تومور می‌شود. شکل (۱-۱۱) دو نمونه تومور مربوط به دو بیمار متفاوت را از دیتابیس IBSR را نمایش می‌دهد.



(ب)

(الف)

شکل (۱۱-۰) دو نمونه تصویر MRI بافت مغز حاوی تومور (با استفاده از ماده حاجب)

۱-۱۰-۱- رویکرد اصلی در روشهای ناحیه‌بندی

روش‌های دسته‌بندی متدهای ناحیه‌بندی متفاوتند. دسته‌بندی ممکن است بر اساس ویژگی‌های استفاده‌شده، تکنیک آموزشی استفاده‌شده و یا کلاسیفایر استفاده‌شده صورت گیرد. متدهای ناحیه‌بندی در یک دسته‌بندی اساسی برحسب تکنیک آموزشی به سه گروه اصلی متدهای نظارتی^۱، غیرنظارتی^۲ و نیمه‌نظارتی^۳ تقسیم می‌شوند. متدهای نظارتی برای ناحیه‌بندی نیازمند اپراتور یا استفاده از اطلاعات اولیه‌ای همانند تعداد کلاس‌ها هستند. در حالی که متدهای غیرنظارتی بطور اتوماتیک و بدون مداخله اپراتور اما با صرف زمان بسیار طولانی عمل می‌کنند. متدهای نیمه‌نظارتی که تلفیقی از الگوریتم‌های هر دو گروه محسوب می‌شوند، کارایی بهتری را نسبت به هر دو این روش‌ها ارائه می‌دهند.

۱-۱۰-۱-۱- متدهای ناحیه‌بندی نظارتی (با ناظر)

- تکنیک‌های نظارتی به توزیعی از داده‌ها و یا اطلاعاتی نظیر آن نیاز دارند. این روش‌ها در میان تکنیک‌های ناحیه‌بندی بالاترین سرعت را دارا هستند اما مشکل اساسی در مورد آنها نیاز به حجم قابل توجهی داده‌ی آموزشی و برچسب‌خورده است که فراهم نمودن آن گاهی مقدور نبوده و آموزش ناقص انجام می‌گیرد. موفق‌ترین روش‌های نظارتی که برای ناحیه‌بندی MRI به کار می‌رود

¹ Supervised

² Un-supervised

³ Semi-supervised

عموما مبتنی بر شبکه‌های عصبی چندلایه یا SVM و یا AdaBoost هستند [۱۹]. متدهای متداول دیگر در این دسته شامل متدهای احتمالاتی^۱ و متدهای مبتنی بر تکنیک‌های پردازش تصویر هستند.

۱-۱۰-۲- متدهای ناحیه بندی غیرنظارتی (بدون ناظر)

تکنیک‌های غیرنظارتی که به طور کلی متدهای کلاسترینگ^۲ نامیده می‌شوند، ساختار داده را به طور اتوماتیک و اغلب بدون نیاز به اطلاعات اولیه، تعیین می‌کنند. تکنیک‌های کلاسترینگ بیشتر مبتنی بر متد K-means، معادلات فازی، Fuzzy C-means و EM^۳ می‌باشد [۲۰, ۲۱]. روش k-means یکی از ساده‌ترین و متداول‌ترین روش‌های ناحیه‌بندی است که از نظر می‌نیمم مجذور میانگین خطا^۴ بهینه است [۲۰]. اما ایراد اصلی این روش استفاده از مقادیر خام داده و نادیده گرفتن روابط فضایی^۵ و همسایگی پیکسل‌هاست. لذا به راحتی تحت تاثیر نویز قرار گرفته و به‌تنهایی کاربردی در مسائل دنیای واقعی ندارد.

با وجود عدم استفاده از داده‌های برچسب‌گذاری شده، کارایی متدهای غیرنظارتی مناسب ارزیابی می‌شود؛ اما عموماً به زمان محاسبه زیادی نیاز دارند. در حال حاضر یکی از مطرح‌ترین متدهای این دسته میدان مخفی مارکوف^۶ است که نتایج رضایت‌بخشی را در ناحیه‌بندی MRI ارائه کرده- است [۲۲].

۱-۱۰-۳- متدهای ناحیه بندی نیمه نظارتی

آموزش به شیوه Semi-Supervised Learning (SSL) یا نیمه‌نظارتی تکنیکی است که در حد فاصل شیوه نظارتی و شیوه غیرنظارتی قرار می‌گیرد. در این شیوه، در مرحله آموزش هم از داده‌های

¹ Stochastic

² Clustering

³ Expectation Maximization

⁴ Minimum mean squared error

⁵ Spatial

⁶ Markov Random Field (MRF)

کلاس‌بندی شده و هم از داده‌های غیر کلاس‌بندی شده استفاده می‌شود. عموماً تعداد کمی از نمونه‌های آموزشی برچسب‌گذاری شده و تعداد بیشتری از داده‌ها فاقد برچسب می‌باشند. تحقیقات روی این شیوه نشان داده است که هرگاه در کلاسترینگ از تعداد کمی داده‌های برچسب‌دار برای هدایت فرآیند تشکیل کلاسترها استفاده شود، دقت آموزش بهبود قابل ملاحظه‌ای نسبت به حالت غیرنظارتی خواهد داشت. علاوه بر اینکه می‌توان تا اندازه‌ای از مزیت سرعت بالای روشهای نظارتی نیز استفاده نمود [۲۳, ۲۴].

روش‌های متفاوتی برای استفاده از اطلاعات اولیه موجود برای جهت‌دهی به کلاسترینگ داده‌ها وجود دارد. روش بذرباشی^۱ یا قراردادن داده‌های برچسب‌گذاری شده در میان سایر داده‌ها و روش آموزش معیار فاصله^۲ توسط داده‌های برچسب‌گذاری شده، متداول‌ترین این روشها به شمار می‌روند [۲۵].

تفاوت اصلی بین متدهای مختلف نیمه‌نظارتی در نحوه ترکیب اطلاعات بدست آمده از دو روش نظارتی و غیر نظارتی می‌باشد. بر این اساس متدهای نیمه‌نظارتی عمدتاً به دو دسته تقسیم میشوند:

- دسته‌ای که از معیارهای شباهت^۳ همانند فاصله اقلیدسی، Jensen-Shannon و غیره برای انتخاب کلاستر مناسب برای داده‌های کلاس‌بندی شده استفاده می‌کند. رویکرد این دسته الگوریتم‌ها بیشتر مشابه الگوریتم کلاسترینگ معمولی است [۲۳].

- دسته‌ای که از الگوریتم‌های جستجو برای یافتن کلاسترهای مناسب استفاده می‌کنند. عبارتی الگوریتم کلاسترها را طوری تنظیم می‌کند که با داده‌های کلاس‌بندی شده موجود مطابق باشند [۲۴]. سپس از کلاسترهای تشکیل شده برای کلاس‌بندی داده‌های کلاس‌بندی نشده استفاده می‌شود.

از آنجا که معمولاً اطلاعات اولیه‌ی خاصی در مورد کلاسترها وجود ندارد، آموزش به شیوه نیمه

¹ Seeding

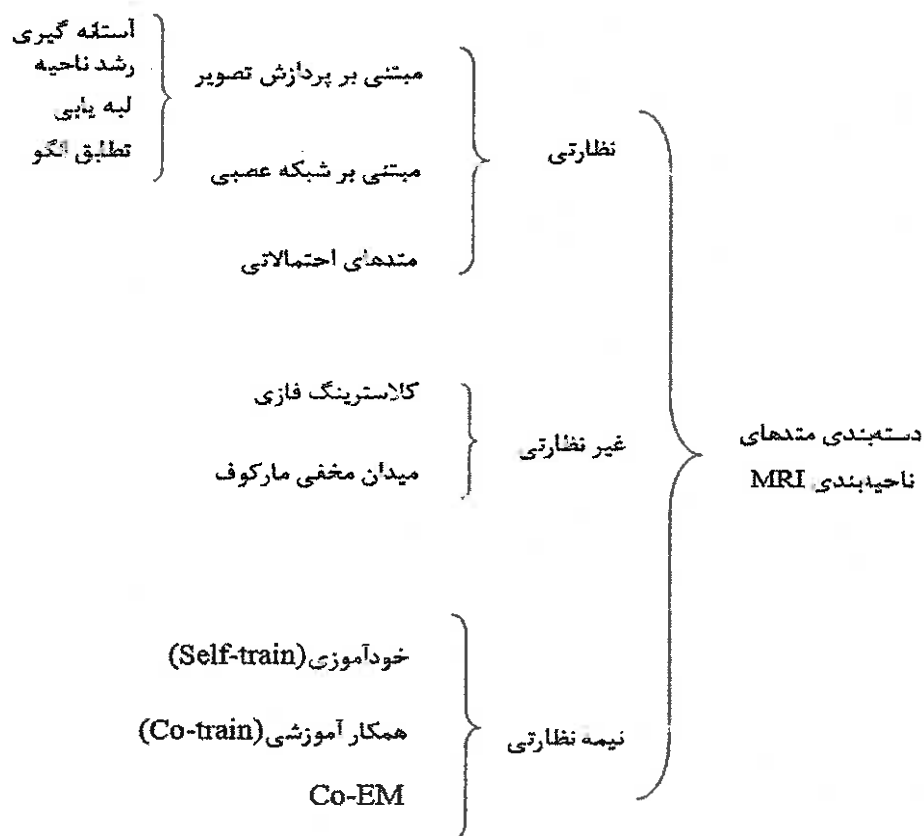
² Distance metric

³ Similarity measure

نظارتی بسیار مورد توجه قرار گرفته است.

از نظر روش آموزش کلاسیفایر، الگوریتم‌های نیمه‌نظارتی در چهار کلاس کلی خودآموزی^۱، همکارآموزی^۲، مبتنی بر گراف و EM قرار می‌گیرند [۲۵].

یک دسته‌بندی کلی از متدهای ناحیه‌بندی متداول در MRI با در نظر گرفتن تکنیک آموزش و کلاسیفایر (یا الگوریتم کلاسترینگ) مورد استفاده در شکل (۱-۱۲) نمایش داده شده است. تعدادی از این روش‌ها به اختصار در ادامه فصل بحث خواهند شد.



شکل (۱۲-۰): دسته‌بندی متدهای ناحیه‌بندی MRI [۲۶]

۱-۱۰-۴- متدهای ناحیه‌بندی مبتنی بر پردازش تصویر

روش‌های پردازش تصویری عمدتاً شامل روش‌های آستانه‌گیری^۳، استخراج کانتور^۴، لبه‌یابی^۱ و

^۱ Self-Training

^۲ Co-Training

^۳ Thresholding

^۴ Contour Extraction

مورفولوژی^۲ است. این روشها نیز بدلیل پارامتریک بودن و نادیده گرفتن اطلاعات اولیه تنها به صورت ترکیبی و یا به منظور اصلاح خطا پس از ناحیه‌بندی اصلی مورد استفاده قرار می‌گیرند.

روش تطابق الگو تقریباً متداول‌ترین متد این دسته است که نسبت به سایرین جدیدتر بوده و یک روش پایه محسوب نمی‌شود. تفکیک بافت مغز توسط این روش با استفاده از الگوی اطلس دیجیتال صورت می‌پذیرد که وضوح مرزها بیشتر بوده و با انطباق روی تصویر اصلی ناحیه‌بندی جزئی‌تری صورت می‌گیرد. متد تطابق الگو هرچند برای ناحیه‌بندی تصویر مغز سالم روش نسبتاً مناسبی محسوب می‌شود اما محاسبات نسبتاً سنگینی دارد و نیز برای تفکیک بافت غیرعادی کارآیی ندارد. اما این روش برای استخراج ویژگی‌های فضایی تاحدودی کارآیی دارد [۲۶].

۱-۱۰-۴-۱ آستانه‌گیری

آستانه‌گیری از تصویر یکی از پرکاربردترین و درعین حال از ساده‌ترین روش‌های ناحیه‌بندی تصویر است. آستانه‌گیری به صورت خام تنها در مسائل دو کلاسه کاربردی است. ضمن اینکه بدلیل استفاده صرف از مقادیر خام پیکسل‌ها، در برابر نویز و ناهمگنی در سطح روشنایی پیکسل‌ها آسیب‌پذیر و ناکارآمد است. یک راه‌حل می‌تواند استفاده از اطلاعات محلی نظیر اتصال^۳ و همسایگی و روشنایی محلی پیکسل‌ها باشد. به عبارتی بجای آستانه‌گیری سراسری از تصویر، آستانه‌گیری محلی^۴ مورد توجه قرار می‌گیرد. در این حالت، حد آستانه علاوه بر مقدار خاکستری پیکسل‌ها، $f(x, y)$ ، به $p(x, y)$ نیز وابستگی خواهد داشت که هر ویژگی محلی است که در تعیین آن پیکسل‌های اطراف نقطه مرکزی نیز دخالت داده‌شوند (همانند میانگین مقادیر پیکسل‌های دورتادور پیکسل (x, y)). چنانچه اندازه آستانه به مختصات مکانی پیکسل‌ها هم بستگی داشته‌باشد، حد آستانه پویا^۵ خوانده می‌شود [۲۷].

¹ Edge detection

² Morphology

³ Connectivity

⁴ Local

⁵ Dynamic

حد آستانه بهینه برای ناحیه‌بندی، برابر با مقدار یست که پراکندگی درون هر ناحیه را به حداقل برساند. به این ترتیب همگنی درون ناحیه حداکثر بوده و درصد خطا به حداقل می‌رسد. در [۲۸] روشی مبتنی بر تابع واگرایی^۱ ارائه شده است. با فرض حضور تنها دو ناحیه در تصویر، آستانه‌ای که مقدار تابع واگرایی هر دو کلاس را می‌نیمم کند به عنوان حد آستانه بهینه برای تفکیک دو بافت معرفی می‌شود. اگر داده‌های سطوح ۱ تا T را متعلق به کلاس اول و باقی داده‌ها را متعلق به کلاس دوم فرض کنیم، یک راه برای محاسبه حد آستانه تقریباً بهینه با استفاده از پراکندگی درون نواحی به صورت زیر است:

$$P_a(T) = \sum_{i=0}^T P(i) \quad (۲-۱)$$

$$P_b(T) = \sum_{i=T+1}^{255} P(i) \quad (۳-۱)$$

$$P(i) = h(i)/N \quad (۴-۱)$$

$$\frac{\partial}{\partial T} (\sigma_a^2(T) P_a(T) + \sigma_b^2(T) P_b(T)) = 0 \quad (۵-۱)$$

در این روابط T متغیر حد آستانه است که باید بهینه شود، P_a نسبت فراوانی داده‌های کلاس a به کل داده‌ها (احتمال اولیه کلاس a)، $h(i)$ هیستوگرام سطح i ام تصویر، N تعداد پیکسل‌های تصویر و $\sigma_a^2(T)$ واریانس یا پراکندگی درون کلاس a می‌باشد. با تعریف تابع واگرایی به صورت ضرب مقدار احتمال کلاس در پراکندگی درون داده‌های کلاس، مقدار این تابع باید بر حسب T می‌نیمم شود تا مقدار بهینه برای T بدست آید. این رابطه بر اساس این واقعیت است که اندازه فراوانی و یا پراکندگی داده‌های یک کلاس نسبت به کلاس دیگر، مکان آستانه را نیز تحت تاثیر قرار خواهد داد. مشکلاتی از قبیل نویز متغیر، وضوح ناکافی و مشترک بودن برخی سطوح خاکستری بین سطح شیء و پس‌زمینه تصویر باعث پیچیده‌شدن این روش برای استفاده در ناحیه‌بندی پزشکی می‌شوند.

¹ Divergence

۱-۱۰-۵- متدهای ناحیه‌بندی مبتنی بر شبکه عصبی

در روشهای مبتنی بر شبکه عصبی عموماً از شبکه SOM استفاده می‌شود تا به این وسیله نویز و کسل‌ها حفظ شود [۲۹]. به این ترتیب در خروجی شبکه برچسب داده‌هایی که به یکدیگر شباهت بیشتری دارند، از نرون‌های مجاور تولید می‌شوند. البته معمولاً یک سری روشهای بهبود و اصلاح نتیجه نیز پس از بدست آمدن پاسخ شبکه روی جواب اعمال می‌شود. پس از SOM، روشهای مبتنی بر شبکه های Fuzzy-LVQ و شبکه های عصبی چندلایه (MLP)^۱ عمومیت دارند [۲۶].

۱-۱۰-۶- ناحیه‌بندی با استفاده از متدهای احتمالاتی

نقطه مشترک تمامی متدهای احتمالاتی، ماکزیمم‌سازی چگالی احتمال شرطی تعلق هر یک از وکسل‌ها به یک بافت بخصوص است [۳۰]. تمامی این متدها به احتمالات اولیه وابسته هستند. متداول‌ترین متدهای این دسته در ناحیه‌بندی MRI، مبتنی بر کلاسیفایرهای ML و بیزین می‌باشند [۳۱، ۴].

۱-۱۰-۷- ناحیه‌بندی مبتنی بر کلاسترینگ فازی

متداول‌ترین الگوریتم کلاسترینگ، روش FCM^۲ و مشتقات آن می‌باشد که برای اولین بار توسط Hall, Bezdek و Clark در [۳۲] برای تفکیک بافت سالم مغز از بافت تومور بکار گرفته شد. نکته مهم در مورد کلاسترینگ فازی اینست که برچسب‌گذاری به صورت قطعی و سخت^۳ صورت نمی‌گیرد بلکه این کلاس‌بندی از نوع غیر قطعی یا به اصطلاح نرم^۴ است [۲۶].

در روش FCM ساده تعداد کلاسترها باید از پیش به نوعی مفروض باشد. البته بعداً از اطلاعاتی که درباره داده در حین عملیات بدست می‌آید، برای بهبود مرکز کلاسترها یا نتیجه کلاسترینگ

^۱ Multi-Layer Perceptron

^۲ Fuzzy C-Means

^۳ Hard

^۴ Soft

استفاده می‌شود. برای رفع مشکل تخمین اولیه تعداد کلاسترها، معمولاً تعداد کلاسترها چندین برابر تعداد کلاس‌های متداول موجود در بافت مغز در نظر گرفته می‌شود تا اطمینان حاصل شود که همه بافت‌ها منظور شده‌اند. اما این روش منجر به تفکیک بیش از اندازه بافت‌ها و تشکیل چندین کلاس مجزا برای یک بافت^۱ خواهد شد. عموماً استفاده از FCM نه به عنوان الگوریتم اصلی و بلکه به عنوان یک مرحله تکمیلی برای بهبود پاسخ پس از ناحیه بندی اولیه توسط متد دیگری نظیر SOM یا متدهای پردازش تصویر مطرح می‌شود [۲۶].

اما ایراد اصلی متد FCM، استفاده از مقادیر سطوح خاکستری پیکسلها به صورت خام و نادیده گرفتن روابط فضایی در تشکیل کلاسترهاست. به این ترتیب متد کاملاً در برابر نویز و ناهمگنی سطح روشنایی حساس و ناکارآمد است. اما این مشکل در تعدادی از مشتقات FCM نظیر KFCM_S و BCFCM از طریق استفاده از روابط همسایگی برطرف شده است [۳۰, ۳۳].

با وجود معایب برشمرده شده، متدهای مبتنی بر منطق فازی در مواجهه با عدم قطعیت از بهترین روش‌ها به شمار می‌روند. این خاصیت بخصوص در تفکیک و کسل‌های واقع در مرز بافت‌ها مفید است؛ زیرا وضوح پایین تصویر سبب درهم آمیختگی مرزها شده و در این شرایط کلاس بندی قطعی توسط کلاسیفایرهایی نظیر شبکه عصبی می‌تواند پر از خطا باشد.

۱-۱۱- بیان موضوع و اهداف

همانطور که در این فصل اشاره شد یکی از مهمترین چالش‌های پیش روی ناحیه بندی MRI، ناهمگنی در سطح روشنایی پیکسلهای تصویر است. به نحوی که نقاط درون یک بافت واحد، روشنایی یکسان نداشته و گاهی این اختلاف منجر به کلاس بندی ناصحیح پیکسلها می‌شود. از آنجا که ارزشمندترین ویژگی در چنین تصاویری همان سطح خاکستری پیکسلهاست، لزوم مقابله با این مشکل ضروریست.

¹ Over-segmentation

موفق‌ترین روشی که برای اصلاح یا کاهش اثر ناهمگنی (بایاس فیلد) پیشنهاد شده‌است، استخراج ویژگی‌های یک پیکسل با توجه به همسایگان آن است به نحوی که نویز احتمالی با رجوع به مقادیر همسایگان شناسایی و برطرف شود. در صورت استفاده از این راه‌حل تعریف مفهوم یا محدوده همسایگی برای یک پیکسل تاثیر قابل توجهی روی کیفیت ویژگی‌ها خواهد داشت. راه‌حل دیگر برای مقابله با مشکل ناهمگنی استفاده از ویژگی‌هایی است که نسبت به تغییرات روشنایی مقاوم هستند. با توجه به اثر مثبت هردو راه پیشنهادی، ما در این پروژه با ترکیب هردو روش موفق شدیم به بهبود خوبی در نتایج اولیه خود دست یابیم. روش پیشنهادی در فصل چهار شرح داده خواهد شد.


فصل دوم

آموزش نیمه نظارتی

اغلب در مسائل تعیین کلاس داده‌ها، اولویت انتخاب با کلاسیفایرهای نظارتی است که از سرعت و دقت بالایی برخوردارند؛ اما فراهم کردن داده آموزشی برچسب‌خورده که قسمت اساسی آموزش محسوب می‌شود همواره میسر نیست. از طرفی متدهای غیرنظارتی و کلاسترینگ با وجود سهولت استفاده بدلیل پیچیدگی محاسبات زمان پردازش بسیار طولانی دارند. از این رو اخیراً طراحی روش‌های آموزشی نیمه‌نظارتی با استفاده از ترکیب روش‌های نظارتی و روش‌های غیرنظارتی مورد توجه قرار گرفته‌است. این روشها قادرند با استفاده موثر از برچسب تعداد کمی داده برچسب‌دار و اطلاعات نهفته در انبوه داده‌های بدون برچسب برای کلاسیفایر یا الگوریتم کلاسترینگ مرزهای تصمیم‌گیری مناسبی را یافته و بخشی از مشکلات موجود در روش‌های نظارتی و غیرنظارتی را برطرف کنند (شکل ۱-۲). یک قابلیت مهم چنین روشی امکان پیاده‌سازی روی هر دو مدل آموزشی کلاس‌بندی و کلاسترینگ است.

بررسی و مطالعه روش‌های نیمه‌نظارتی دو دلیل عمده دارد: درک بهتر فرآیند یادگیری ماشین و نیز طراحی الگوریتم‌های یادگیری بهتر. هدف اصلی در آموزش نیمه‌نظارتی تعیین اینست که تاثیر ترکیب داده‌های برچسب‌خورده با داده‌های فاقد برچسب در بهبود کارایی یادگیری چیست و چگونه می‌توان الگوریتم‌هایی را برای استفاده از مزیت این نوع آموزش طراحی کرد [۳۴]. چنانچه در مساله‌ای تعداد داده‌های آموزشی برچسب‌خورده کافی نباشد آموزش ناقص انجام گرفته و مرزهای تصمیم‌گیری بسیار اختصاصی تنظیم می‌شوند. لذا کلاسیفایر قابلیت تعمیم کمی داشته و در مواجهه با داده جدید با مشکلات زیادی روبرو خواهد شد. حال چنانچه با دسته دیگری از داده‌ها، محدوده واقعی مقادیر داده‌ها را به کلاسیفایر آموزش دهیم، کلاسیفایر می‌تواند مرزهای خود را جابجا کرده و با داده تطابق بهتری پیدا کند. به علت محدودیت در تهیه داده برچسب‌دار این دسته جدید کلاس‌بندی نشده‌اند. لذا باید پیش از جابجایی مرزها برچسب‌هایی با ضریب اطمینان بالا را برای این داده‌ها فراهم نمود. روش

تخصیص برچسب به این داده‌ها و نحوه آموزش داده‌های جدید به کلاسیفایر موضوعی است که در تکنیک‌های نیمه‌نظارتی به عنوان مباحث اساسی مطرح می‌شود. در شکل (۱-۲) بهبود مرزهای تصمیم‌گیری پس از افزوده شدن داده‌های دسته دوم به داده‌های برچسب خورده به صورت ساده نمایش داده شده است.



شکل (۱-۲): نحوه تاثیر داده‌های آموزشی بدون برچسب در مرزهای تصمیم‌گیری: الف) داده‌های آموزشی اولیه (برچسب‌خورده و فاقد برچسب)، ب) مدل بدست‌آمده از آموزش با داده‌های برچسب‌خورده، ج) مدل بدست‌آمده از آموزش با هر دو مدل داده [۳۵]

الگوریتم‌های مبتنی بر آموزش نیمه‌نظارتی متعدد هستند که متدهای EM [۳۶]، روش‌های مبتنی بر گراف [۳۵]، خودآموزی [۳۹]^۲ و همکار آموزشی [۴۰]^۳ از مطرح‌ترین آن‌ها به‌شمار می‌روند.

در این فصل پس از معرفی اجمالی روش‌های کلی آموزش نیمه‌نظارتی، به نحوه انتخاب متد موردنظر خود در این پروژه و مسائل مربوط به آن خواهیم پرداخت.

۲-۲- تکنیک‌های آموزش نیمه‌نظارتی

اشاره شد که آموزش نیمه‌نظارتی روی هر دو مدل کلاسیفایرهای نظارتی و متدهای کلاسترینگ قابل اجراست. بر این اساس دو مدل آموزشی با عناوین کلاس‌بندی نیمه‌نظارتی و

¹ Transductive SVM

² Self-training

³ Co-training

کلاسترینگ محدود شده خواهیم داشت.

۲-۳- کلاس بندی نیمه نظارتی

همان کلاس بندی نظارتی است زمانی که علاوه بر داده های برچسب خورده از داده های فاقد برچسب نیز در آموزش استفاده شود. در مرحله اول سیستم کاملا به شیوه نظارتی معمول اما با داده های بسیار محدود آموزش می بیند. در مرحله دوم داده های برچسب نخورده وارد سیستم شده و از سیستم آموزش دیده برچسبی را دریافت می کنند. این داده ها سپس همانند داده های آموزشی برچسب خورده اولیه کلاسیفایر را آموزش می دهند. در حالت کلی حجم این داده ها بسیار بیشتر از داده های برچسب خورده است. مطلوب اینست که کلاسیفایر به نحوی آموزش ببیند که دقت و کارایی در حد کلاسیفایر نظارتی داشته باشد [۳۸].

آموزش سیستم به این شیوه ممکن است دو هدف تقریبا متفاوت را دنبال کند: برچسب گذاری داده های فاقد برچسب درون مجموعه آموزشی و یا کلاس بندی داده های تستی آینده سیستم. سیستم کلاس بندی نیمه نظارتی برحسب این که به چه منظوری مورد استفاده قرار گیرد با یکی از دو مدل یادگیری انتقالی^۴ [۴۱] و یا استنتاجی^۵ [۴۲] آموزش می بیند.

در مدل انتقالی داده هایی که به عنوان داده تستی به سیستم داده می شوند، از جنس داده های آموزشی هستند. از آن جا که آموزش سیستم با داده های مشابهی صورت گرفته است پیاده سازی این مدل پیچیدگی خاصی ندارد. در مدل استنتاجی داده ها از خارج وارد سیستم شده و تضمینی وجود ندارد که داده های جدید مشابه داده های مجموعه آموزشی باشند. این مدل یادگیری در مسائل دنیای واقعی مطرح می شود که امکان مواجهه با داده های نا آشنا وجود دارد لذا فرآیند آموزش این سیستم حساسیت بیشتری دارد. یک راه حل برای بالا بردن دقت کلاسیفایر دور ریختن داده های آموزشی است که با اطمینان بالا کلاس بندی نشده اند. بنابراین انتخاب داده آموزشی نسبت به مدل انتقالی سخت-

^۴ Transductive

^۵ Inductive

گیرانه‌تر انجام می‌شود.

پس از این دسته‌بندی جزئی‌تری نیز روی متدهای کلاس‌بندی نیمه‌نظارتی تعریف می‌شود که شامل چهار روش اصلی آموزش است. این چهار متد ممکن است با هدف پیاده‌سازی هر یک از سیستم‌های نیمه‌نظارتی انتقالی یا استنتاجی استفاده شوند. در ادامه به‌طور خلاصه این متدها را معرفی خواهیم‌نمود.

۲-۳-۱- تکنیک خودآموزی (self-training)

کلاسیفایر با قسمت کوچکی از داده‌های برچسب‌خورده آموزش می‌بیند. این کلاسیفایر سپس داده‌های برچسب‌نخورده را کلاس‌بندی می‌کند. داده‌هایی که به این صورت برچسب می‌خورند چنانچه شرط خاصی را ارضا کنند به‌همراه برچسب بدست‌آورده به داده‌های آموزشی افزوده می‌شوند. شرط ورود به داده‌های آموزشی اینست که احتمال صحت برچسب داده از ضریب اطمینان^۶ یا آستانه مشخصی بیشتر باشد.

حال کلاسیفایر با مجموعه آموزشی جدید مجدداً آموزش‌دیده و این فرآیند بارها تکرار می‌شود [۳۹].

۲-۳-۱- شبیه کد الگوریتم خودآموزی

$UN =$ داده برچسب‌نخورده

$L =$ داده برچسب‌خورده

تا زمانیکه $UN \neq \emptyset$

۱- کلاسیفایر C را با L آموزش بده

۲- از C برای کلاس‌بندی داده موجود در UN استفاده کن

۳- $X = 0$

^۶ Confidence score

برای هر داده $d \in UN$

۴- اگر ضریب اطمینان برچسب d $d \text{ confident} \geq T$ آنگاه d را به X اضافه کن $X = X \cup d$

پایان حلقه درونی (d)

۵- $L = L + X; UN = UN - X$

پایان حلقه ($UN = \emptyset$) [۳۹].

مدل از پیش‌بینی‌های انجام‌شده توسط خودش برای آموزش مجدد خودش بهره می‌برد. لذا فرض اولیه سیستم این است که تمام پیش‌بینی‌هایش یا لااقل قسمتی از آنها که ضریب اطمینان بالا داشتند، صحیح بوده است. برای اطمینان از کارکرد صحیح کلاسیفایر، از فاکتور کنترل‌کننده‌ای همانند T به عنوان می‌نیم ضریب اطمینان برای کنترل ورود داده‌های جدید به داده‌های آموزشی استفاده می‌شود. اندازه T عموماً برابر $1/2$ قرار داده می‌شود.

بزرگترین مزیت روش خودآموزی سادگی پیاده‌سازی آنست. علاوه بر این هیچ محدودیتی در استفاده از نوع کلاسیفایر نبوده و هر کلاسیفایری در این سیستم قابل استفاده است. اما در صورت انتخاب کلاسیفایر نامناسب یک تشخیص نادرست بعداً با ورود به مجموعه آموزشی اثر خود را تشدید کرده و خطای بیشتری بوجود خواهد آورد [۳۸].

۲-۳-۲- تکنیک همکار آموزشی (Co-training)

الگوریتم Co-training یا همکار آموزشی توسط Blum پیشنهاد شد [۴۰]. برای استفاده از این الگوریتم، ویژگی‌هایی که از داده استخراج می‌شوند باید قابلیت تفکیک به دو مجموعه مجزا را داشته باشند. داده‌هایی که با ضریب اطمینان بالا توسط یکی از کلاسیفایرها برچسب‌گذاری می‌شوند، می‌توانند با برچسب تخصیص یافته به عنوان داده آموزشی کلاسیفایر دوم استفاده شوند.

در این روش دو مجموعه ویژگی متفاوت از داده استخراج می‌شود که در حالت ایده‌آل کاملاً از

یکدیگر مستقل هستند و کلاس‌بندی با هر یک از این دو مجموعه ویژگی به‌تنهایی امکان‌پذیر است [۴۳]. ابتدا هر یک از این دو مجموعه ویژگی با استفاده از داده‌های برچسب‌گذاری شده موجود، یک کلاسیفایر مجزا را آموزش می‌دهند. سپس از قوی‌ترین پیش‌بینی هر کلاسیفایر روی نمونه‌های بدون برچسب برای برچسب‌گذاری آنها و افزودن این نمونه‌ها به سیستم به عنوان داده‌های آموزشی جدید استفاده می‌شود و این فرآیند تا افزوده‌شدن تمامی داده‌های بدون برچسب به مجموعه داده‌های آموزشی سیستم ادامه می‌یابد.

اساسی‌ترین نکته در Co-training نحوه انتخاب ویژگی است. این تکنیک تنها زمانی مفید است که ویژگی‌ها مستقل باشند و اگر هر دو کلاسیفایر روی تمامی داده‌ها اتفاق نظر داشته باشند، چنین استقلال وجود ندارد. عبارتی افزودن یک کلاسیفایر دیگر تنها زمانی توجیه دارد که به درک بیشتری از داده منجر شود. بصورتی که چنانچه یکی از کلاسیفایرها داده‌ای را به غلط کلاس‌بندی کرد این خطا توسط کلاسیفایر دیگر اصلاح شود [۴۳].

لذا این تکنیک به دو دیدگاه مستقل و متفاوت از داده نیاز دارد که هر یک از این دیدگاه‌ها با استفاده از یک مجموعه ویژگی متفاوت، داده را به صورت متفاوتی تعریف می‌کنند. اگر به بیان ریاضی باید:

$$\begin{aligned} P(x^{(1)} | y, x^{(2)}) &= P(x^{(1)} | y) \\ P(x^{(2)} | y, x^{(1)}) &= P(x^{(2)} | y) \end{aligned} \quad (1-2)$$

در این روابط $x^{(1)}$ و $x^{(2)}$ بترتیب مجموعه ویژگی‌های اول و دوم استخراج شده از داده x و y برچسبی است که هر یک از کلاسیفایرها مستقلاً به داده تخصیص می‌دهند. رابطه به‌سادگی بیان می‌کند که در صورت مستقل بودن مجموعه ویژگی‌ها از یکدیگر، این ویژگی‌ها در اندازه احتمال $(x^{(i)} | y)$ مربوط به کلاسیفایر دیگر هیچ تأثیری ندارند.

انتخاب مجموعه ویژگی‌ها برای دو کلاسیفایر می‌تواند به صورت کاملاً تصادفی صورت گیرد اما

در صورتیکه تعداد ویژگی‌ها به اندازه کافی زیاد نباشد، انتخاب تصادفی کارآیی قابل قبولی ندارد. در روش Co-train نیز نوع کلاسیفایرهای مورد استفاده اهمیتی ندارد. تنها مساله اساسی اینست که برای انتخاب داده آموزشی مناسب بتوان به نوعی پیش‌بینی انجام گرفته توسط کلاسیفایرها را ارزیابی و امتیازدهی کرد [۴۴].

۲-۳-۳- نیمه نظارتی مبتنی بر گراف

در این روش گرافی با استفاده از هر دو مجموعه داده آموزشی برچسب‌دار و بدون برچسب ساخته می‌شود. اندازه گراف تحت تاثیر حجم داده‌های بدون برچسب ممکن است خیلی بزرگ باشد. پس از تشکیل گراف، فرآیند آموزش با تخصیص برچسب داده‌های برچسب‌دار به لبه‌ها انجام می‌گیرد. وزن لبه بین داده برچسب‌خورده x_i و داده بدون برچسب x_j بیانگر میزان شباهت بین دو نمونه است و چنانچه W_{ij} (اندازه شباهت) خیلی بزرگ باشد برچسب این دو نمونه یکسان در نظر گرفته می‌شود. ارزیابی میزان شباهت بین دو نمونه معمولاً بر مبنای فاصله اقلیدسی بین داده‌ها و توسط تابع کرنل گوسین یا تابع پایه شعاعی صورت می‌گیرد.

$$W_{ij} = \exp\left(-\frac{\|x_i - x_j\|^2}{2\sigma^2}\right) \quad (۳-۲)$$

پارامتر σ متغیر پهنای باند بوده و کنترل نرخ افزایش و کاهش وزنها را در دست دارد. هرگاه تفاوت دو نمونه به سمت بینهایت سوق پیدا کند وزن مابین نیز به سمت صفر گرایش پیدا خواهد کرد. تشریح ساخت گراف به این صورت بسیار کلی است. چنانچه دانش کلی درباره نوع مساله از پیش وجود داشته باشد، با تعریف توابع فاصله، نحوه ارتباط و وزن‌دهی مناسب‌تر به لبه‌ها آموزش بهتری انجام می‌گیرد.

۲-۳-۴- الگوریتم نیمه نظارتی EM

الگوریتم احتمالاتی EM پیش‌تر به عنوان یک متد کلاسترینگ مطرح بوده است اما هم‌اکنون در نیمه نظارتی نیز استفاده می‌شود. مراحل آموزش در سیستم های نظارتی EM نیز از یک الگوی کلی مشابه سایر روش‌ها پیروی می‌کند. پس از آموزش اولیه کلاسیفایر با تعداد کمی نمونه‌های برچسب خورده، در یک فرآیند دو مرحله‌ای، کلاسیفایر آموزش‌دیده تعدادی داده فاقد برچسب را به صورت احتمالی برچسب می‌زند. این اولین مرحله الگوریتم یعنی تخمین (expectation) است. داده‌های جدید به همراه برچسب و احتمال مربوطه با داده‌های برچسب‌خورده اولیه کلاسیفایر را مجدداً آموزش می‌دهند. این مرحله دوم یا فاز ماکزیم‌سازی (maximization) است. سپس کلاسیفایر دوباره مراحل تخمین و ماکزیم‌سازی را تکرار می‌کند [۴۵].

۲-۴- کلاسترینگ محدودشده

این متد مشابه کلاسترینگ غیرنظارتی است با این تفاوت که این بار اطلاعات پیش‌فرضی به صورت محدود درباره کلاسترها به سیستم افزوده شده و جریان تشکیل کلاسترها را هدایت می‌کند. این اطلاعات معمولاً به صورت قیود "مرتبط است"^۷ و "مرتبط نیست"^۸ بین دو نمونه داده بیان می‌شود که به موجب آن دو نمونه باید در یک کلاستر قرار بگیرند یا نباید در یک کلاستر قرار بگیرند. همانطور که مشخص است برچسبی در کار نیست اما با استفاده از این ارتباطات، داده نهایتاً کلاستر مناسب خود را پیدا خواهد کرد [۳۸].

۲-۵- جمع‌بندی و بیان اهداف

در این فصل تکنیک‌های اصلی آموزش نیمه‌نظارتی معرفی شد. علت عمده محبوبیت روش نیمه‌نظارتی در مباحث یادگیری ماشین امکان استفاده از داده بدون برچسب در ارتقاء عملکرد

⁷ Must link

⁸ Must not link

کلاسیفایر است؛ مخصوصا اگر برچسب‌گذاری داده‌ها سخت یا زمان‌بر باشد. اما استفاده از شیوه آموزش نیمه‌نظارتی لزوماً منجر به افزایش دقت یا کارایی نمی‌شود. بهبود یا عدم بهبود کارایی کلاسیفایر بستگی به انتخاب مدل آموزش مناسب برای مساله و نیز کلاسیفایر متناسب با آن دارد. در واقع تمام زمانی که از جهت عدم نیاز به برچسب‌گذاری داده‌ها، ذخیره می‌شود بر نمی‌گردد. برای آموزش مفید باید زمان قابل‌توجهی را روی انتخاب مدل آموزشی، انتخاب ویژگی‌ها، توابع ارزیابی شباهت و غیره صرف کرد.

انتخاب مدل مناسب معمولاً از یک سری قواعد کلی پیروی می‌کند. برای مثال اگر ویژگی‌های مورد استفاده در مساله قابلیت تقسیم به دو یا چند گروه مستقل را دارند، تکنیک همکار آموزشی در این مورد کاراست. اگر شباهت بین داده‌های یک کلاس به راحتی توسط ویژگی‌ها یا معیارهای ارزیابی شباهت نشان داده می‌شود، می‌توان از مدل‌های مبتنی بر گراف استفاده کرد. برای داده‌هایی که مرز کلاس‌ها باهم درهم آمیختگی شدیدی دارد، مدل EM توصیه می‌شود.

اگر کلاسیفایر نظارتی که استفاده شده است، پیچیده بوده و به راحتی نمی‌توان آن را بهبود یا تغییر داد، مدل خودآموزی احتمالاً برای آموزش آن مناسب است [۳۵].

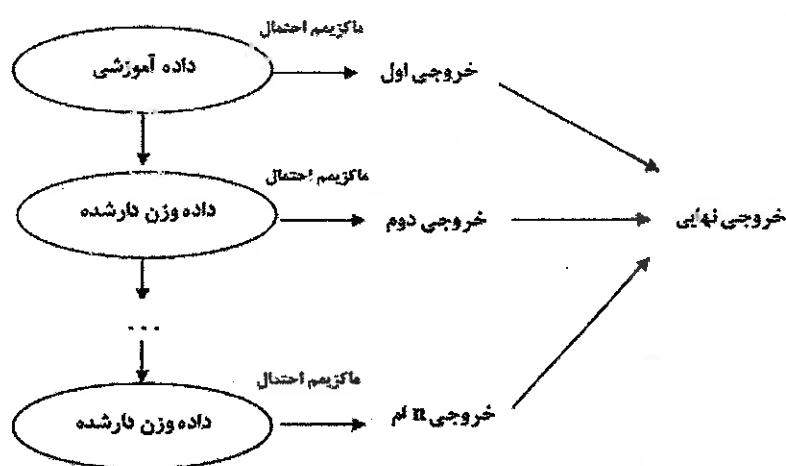
با توجه دشوار بودن تهیه داده آموزشی مناسب برای کاربردهای پزشکی، لزوم استفاده از شیوه نیمه‌نظارتی در چنین کاربردهایی کاملاً توجیه می‌شود. ما نیز در این پروژه سیستم خود را به شیوه نیمه‌نظارتی آموزش خواهیم داد. مدل مورد استفاده ما شیوه "خودآموزی" است. بنابراین سیستم از پیش‌بینی که توسط خودش انجام گرفته برای آموزش خود در مرحله بعدی استفاده می‌کند. این لزوم یک کلاس‌بندی حتی‌المکان دقیق را برای جلوگیری از انتشار خطا مشخص می‌سازد. تشریح این پیاده‌سازی و نتایج آن در فصل‌های بعد خواهد آمد.

فصل سوم

الکوریتم جنگل تصادفی

پیشنهاد شده است. دو تکنیک Boosting و Bagging که بر همین مبنا ارائه شده‌اند، متداول‌ترین نوع ساختارهای تجمعی به‌شمار می‌روند.

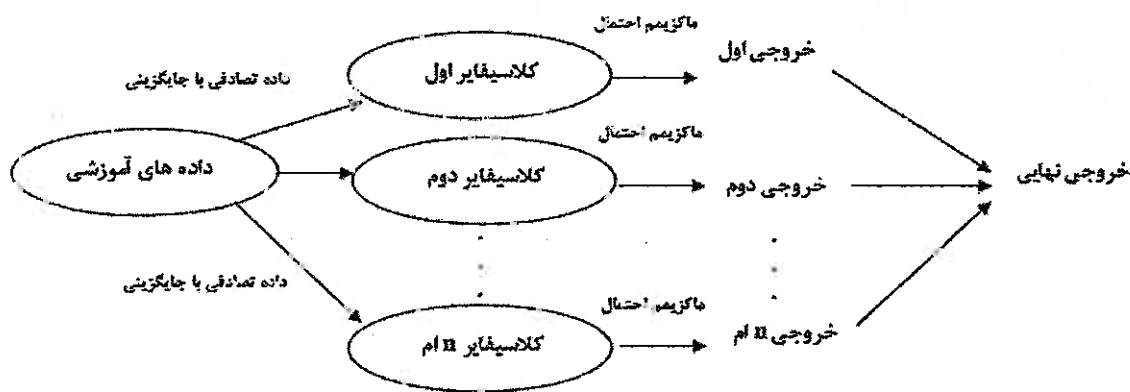
در متدهایی نظیر AdaBoost که شاخه‌ای از روش کلی Boosting [۵۲] محسوب می‌شود، کلاسیفایرها بدنبال هم قرار می‌گیرند و هر یک نتیجه بدست‌آمده از کلاسیفایر ماقبل خود را بهبود می‌بخشد تا نهایتاً آخرین خروجی از کلاسیفایر آخر تولید شود [۵۳]. بنابراین تنها کلاسیفایری که خروجی نهایی آن از سایرین مستقل بوده و تنها به ویژگی‌ها و ورودی اصلی وابسته است، کلاسیفایر اول است. این عملیات موازی نبوده و عملکرد هر کلاسیفایر به کلاسیفایر طبقه ماقبل خود بستگی دارد. بهبود خروجی متلاً ممکن است با وزن‌دار کردن ورودی‌ها و افزایش وزن داده‌هایی که عموماً اشتباه کلاس‌بندی می‌شوند، همراه با کاستن از وزن سایر داده‌ها صورت‌گیرد [۵۴]. این کار اعمال نوعی تابع هزینه به کلاسیفایر است تا جریمه کلاس‌بندی غلط برای داده‌هایی که اغلب اشتباه تفسیر می‌شوند بیشتر باشد. شکل (۱-۳) ساختار ابتدایی کلاسیفایرهای مبتنی بر این تکنیک را نشان می‌دهد.



شکل ۱-۳ کلاس‌بندی مبتنی بر Boosting

در نقطه مقابل، تکنیک Bagging [۵۵] ساختاری را می‌سازد که در آن کلاسیفایرها نه‌پشت-سرهم و بلکه درکنارهم قرار می‌گیرند. ورودی در آن واحد به تمامی کلاسیفایرها داده می‌شود و

هر کلاسیفایر داده را مستقل از سایرین طبقه‌بندی می‌کند. در نتیجه یک ساختار موازی بوجود می‌آید که حداقل سرعت پردازش آن بسیار بالاتر از شیوه Boosting است [۴۶]. این ساختار به صورت ساده در شکل (۲-۳) نشان داده شده است.



شکل (۲-۳): کلاس‌بندی مبتنی بر Bagging

۳-۳- الگوریتم جنگل تصادفی

جنگل تصادفی یک کلاسیفایر تجمعی قدرتمند برگرفته از ساختار Bagging و شامل کلاسیفایرهای ضعیف درخت تصمیم‌گیری است. در الگوریتم‌های مبتنی بر تکنیک Bagging، هر کلاسیفایر مجموعه داده آموزشی مربوط به خود را استفاده می‌کند. بنابراین در جنگل تصادفی نیز هر یک از درختان حاضر در جنگل به طور مستقل و کاملاً تصادفی نمونه‌های آموزشی خود را از بین نمونه‌های موجود انتخاب می‌کند. از طرفی هیچ مجموعه یا ترکیب ثابتی از ویژگی‌ها در کلاس‌بندی مورد استفاده قرار نمی‌گیرد. بلکه در تک‌تک نودهای درخت تعدادی از ویژگی‌ها بصورت تصادفی انتخاب شده و یک ترکیب تصادفی از این متغیرها، داده‌ها را طبقه‌بندی خواهد کرد. این موضوع در مورد تمامی درختان حاضر در جنگل صدق می‌کند [۵۶]. از آن‌جا که نمونه‌برداری داده‌ها با جایگزینی صورت می‌گیرد، ممکن است تعدادی از داده‌های آموزشی یک درخت تکراری باشند و در مقابل تعدادی از داده‌ها (به طور نسبی حدود $1/3$ مجموع داده‌ها) در آموزش درخت شرکت داده نشوند.

درخت تصمیم‌گیری جزء گروه کلاسیفایرهایی است که به راحتی دچار مشکل "آموزش بیش

از حد^۲ می‌شود. اما در صورت کنترل تعداد درختان جنگل، چنین احتمالی در جنگل تصادفی به دلیل انتخاب تصادفی داده‌ها و ویژگی‌ها تقریباً منفی است [۵۶].

دلیل عمده قدرت جنگل تصادفی همان انتخاب تصادفی داده‌ها و ویژگی‌هاست [۵۱]. با تولید ترکیبات تصادفی متعدد از ویژگی‌ها توسط درختان حاضر در جنگل و انتخاب ترکیبات تقریباً بهینه برای کلاس‌بندی، امید این می‌رود که نهایتاً ویژگی‌های اصلی در مجموعه داده‌ها شناسایی شده و میزان تاثیر ویژگی‌های نامربوط در نتیجه کلاس‌بندی کاهش یابد. انتخاب تصادفی ویژگی‌ها، امکان جایگزینی مقادیر مفقودشده در برخی بردارهای ویژگی را نیز فراهم می‌کند [۵۷]. مشکل ویژگی مفقوده در داده‌های واقعی مشکل نسبتاً شایعی است. با توجه به این که در آموزش جنگل، ویژگی‌های حاضر در بردار ویژگی همواره به صورت تصادفی انتخاب می‌شوند، فقدان مقدار برای یک یا چند ویژگی محدود در تعدادی از داده‌ها کارآیی کلی کلاسیفایر را تحت تاثیر قرار نمی‌دهد. در چنین مواردی می‌توان میانگین مقدار همین ویژگی‌ها از داده‌های دیگری در کلاس یکسان را جایگزین مقادیر مفقوده کرد.

از طرفی در صورت وجود عدم توازن شدید بین داده‌های آموزشی، کارآیی کلی جنگل چندان تحت تاثیر قرار نمی‌گیرد که این یکی از امتیازات بسیار مهم دیگر آن محسوب می‌شود [۵۸].

این شیوه استفاده از بردار ویژگی و داده آموزشی، استفاده از کلاسیفایرهای متعدد درون بدنه جنگل را توجیه می‌کند زیرا سبب می‌شود این درختان آموزش متفاوت، تصمیم‌گیری‌های متفاوت و در نتیجه کارآیی متفاوتی داشته باشند. علت این نوع انتخاب داده تصحیح خطای یک درخت در کلاس‌بندی توسط سایر درخت‌های تصمیم‌گیرنده است.

درخت برای تمامی داده‌ها چگالی شرطی احتمال تعلق به هر یک از کلاس‌ها را محاسبه می‌کند و کلاس‌بندی نهایی را بر اساس رای‌گیری از ماکزیمم این احتمالات انجام می‌دهد. بنابراین

² Overtraining

کلاس‌بندی توسط جنگل تصادفی از نوع قطعی^۳ نبوده و احتمالاتی است. این ویژگی می‌تواند در مواجهه با ابهامی که در مرز بافت‌ها وجود دارد، بسیار مفید باشد.

۳-۴- فرایند آموزش جنگل تصادفی

با شروع آموزش جنگل، یک کپی از تمام داده‌های آموزشی به‌همراه برچسب این داده‌ها در آن واحد به تمام درخت‌ها ارسال می‌شوند. سپس هر درخت حدود $\frac{2}{3}$ از داده‌های دریافتی را به صورت تصادفی برای آموزش انتخاب می‌کند. مابقی داده‌ها^۴ بعداً برای تست اعتبارسنجی درخت استفاده می‌شوند. برای تصمیم‌گیری درباره داده‌هایی که به یک نود می‌رسند، مجموعه‌ای از ویژگی‌ها به‌طور تصادفی انتخاب‌شده و پس از تولید ترکیبات مختلف این ویژگی‌ها به‌طور تصادفی، یک ترکیب خطی از آن‌ها برای تعیین آستانه کلاس‌بندی در این نود استفاده خواهد شد. با تعیین آستانه مناسب، یک تست باینری مشابه رابطه (۱-۳) روی داده انجام‌شده و به شاخه مناسب (زیردرخت T_L یا T_R) فرستاده می‌شود [۵۰].

$$f^{\tau_{low}, \tau_{up}, \theta}(x_k) = \begin{cases} T_R & \tau_{low} \leq \theta(x_k) < \tau_{up} \\ T_L & otherwise \end{cases} \quad (1-3)$$


تابع $\theta(\cdot)$ تابع محاسبه ویژگی‌های استخراج‌شده از پیکسل X_k است. هیچ محدودیتی روی تعریف تابع θ وجود ندارد؛ اما بطور معمول θ همان سطح خاکستری محلی پیکسل، میانگین، تابع مکان یا رابطه فضایی پیچیده‌تری است. در غیر این صورت، θ جمع بردار ضرایب تصادفی را در بردار ویژگی هر نود، به ازای هر داده یا پیکسل X_k محاسبه می‌کند. مقادیر τ_{up} و τ_{low} حدود آستانه‌ی طبقه‌بندی در یک نود مفروض هستند. در این رابطه $f^{\tau_{low}, \tau_{up}, \theta}(x_k)$ زیر درختی است که پس از بررسی تمام پارامترهای τ_{up} و τ_{low} و θ برای طبقه‌بندی داده X_k انتخاب می‌شود.

بسته به توزیع داده‌ها و آستانه انتخاب‌شده، تعداد سطوح تصمیم‌گیری متفاوت است. هرچه

³ Hard labelling

⁴ Out of bag

ترکیب مناسب‌تری از ویژگی‌ها انتخاب شوند و کلاس‌های مختلف در فضای داده از یکدیگر منفک‌تر باشند، برای طبقه‌بندی نهایی تصمیم‌گیری‌های کمتر و نهایتاً پردازش کمتری موردنیاز است. شکل (۳-۳) یک درخت ساده را نمایش می‌دهد که با استفاده از آستانه‌ها یا مرزهای تصمیم‌گیری x_1'' ، x_1' ، x_2' و x_2'' داده‌های رسیده را طبقه‌بندی می‌کند. این درخت در شرایط تقریباً ایده‌آل ترسیم شده است به طوری که هر یک از حدود آستانه تعیین‌شده لااقل برای دو کلاس، حد آستانه بهینه محسوب می‌شوند.



شکل (۳-۳): کلاس‌بندی با درخت تصمیم‌گیری: الف) فضای داده‌ها و مرز بین کلاس‌ها، ب) ساختار کلاسیفایر [۵۹]

برخلاف انتخاب تصادفی ویژگی‌ها، تعداد ویژگی‌های مورد استفاده در هر نود ثابت و عموماً برابر مجذور بعد داده‌هاست. پس از تولید چندین ترکیب متفاوت از ویژگی‌های انتخاب شده، از متدی همانند نرخ بهره^۵، ReliefF [۶۰] یا ناخالصی Gini^۶ برای ارزیابی میزان شایستگی یا بهینگی نقطه شکست (آستانه) تولید شده توسط هریک از ترکیب‌ها در یک نود استفاده می‌شود [۴۸]. عموماً معیار مورد استفاده به تبعیت از الگوریتم درخت تصمیم CART، معیار Gini است که محاسبه آن مطابق رابطه (۲-۳) صورت می‌گیرد [۶۱]:

^۵ Gain ratio

^۶ Gini impurity

$$Gini = \sum_{i=0,1} p_i (1 - p_i) \quad (2-3)$$

(Pi نماینده نسبت فراوانی داده‌های کلاس 1 موجود در یک نود به کل داده‌های حاضر در این

نود است.)

شاخص ناخالصی Gini بیانگر احتمال عدم صحت کلاس‌بندی است و در بهترین حالت کلاس-

بندی داده‌ها نسبت به Gini حاصل از سایر کلاس‌بندی‌های ممکن، می‌نیم خواهد بود. هم‌زمان با

ادامه تفکیک داده‌ها، میزان شاخص طبقه‌به‌طبقه کاهش یافته و اندازه آن در نودهای فرزند نسبت به

والد خود کمتر است. لذا بهترین ترکیب متغیرها برای کلاس‌بندی در هر نود آنست که بیشترین

تفاوت بین مقدار شاخص را در دو نود والد و فرزند بوجود آورد یا مقدار ناخالصی را تا حد امکان کاهش

دهد [۶۲].

لذا با فرض اینکه هر حد آستانه t داده‌ها را به دو زیرشاخه t_L و t_R بشکند و P_L و P_R به-

ترتیب برابر N_L/N و N_R/N (نسبت تعداد داده‌های منتقل شده به این زیرشاخه‌ها) باشند، درخت

آستانه‌ای را انتخاب می‌کند که مقدار رابطه $Gini(t) - P_L Gini(t_L) - P_R Gini(t_R)$ را ماکزیمم کند

تا بهترین جداسازی صورت گیرد. در این رابطه $Gini(t)$ اندازه ناخالصی در نود والد است ($P(t)=1$)

و هریک از $P_L Gini(t_L)$ و $P_R Gini(t_R)$ نیز بیانگر میزان ناخالصی در زیردرخت‌های چپ و راست

هستند. ماکزیمم شدن مقدار رابطه به معنای حداکثر اختلاف ناخالصی در نود والد نسبت به ناخالصی

در فرزندان خود است. در نودهایی که داده‌های باقیمانده همگی متعلق به یک کلاس باشند، اندازه

ناخالصی صفر است [۶۲].

روند شکستن به سطح بعدی تا زمانی که درجه ناخالصی در یک نود به صفر می‌رسد، تکرار

خواهد شد. در برگ‌ها طبقه‌بندی با انتخاب کلاس بوجود آورنده ماکزیمم احتمال پسین به عنوان کلاس

داده انجام می‌پذیرد. کلاس بندی نهایی داده با مکانیزم رای‌گیری از نتیجه کلیه درختها صورت می-

گیرد [۶۳].

در طول فرآیند آموزش از طریق می‌نیم کردن پارامتر ناخالصی، تابع θ و مقادیر τ_{low}, τ_{up} برای هر نود بهینه می‌شوند. برگهای درخت زمان آموزش مدام بروز شده و توزیع کلاس‌ها، $P_{l_t}(L(x)=c)$ را مطابق با داده‌هایی که دریافت کرده‌اند، ثبت می‌کنند [۶۲]. $L(x)$ به کلاس داده x و l_t به برگ‌های درخت t ام اشاره می‌کند)

۳-۵- مرحله پیش‌بینی

هنگامی که داده‌های جدید $T_{test} = \{x_k\}$ به جنگل ارائه می‌شود، هر داده x_k همزمان در تمامی درخت‌ها پخش شده و با گذر از مرحله تست نودهای میانی به نود نهایی l_t خواهد رسید ($t \in \{1, \dots, T\}$). در این زمان احتمال $P_{l_t}(L(x)) = b$ برای داده در تمامی درخت‌ها محاسبه شده و نهایتاً احتمال تعلق داده به کلاس مفروض b از رابطه زیر تعیین می‌شود:

$$p(L(x)=b) = \frac{1}{T} \sum_{t=1}^T p_{l_t}(L(x)=b) \quad (3-3)$$

بسته به نوع تست انجام شده در هر یک از نودهای گذردهنده داده x_k ، احتمال تعلق به کلاس b در هر یک از درخت‌ها مقادیر متفاوتی را اختیار خواهد کرد اما کلاس نهایی داده برابر است با $b^* = \arg \max_b p_b(x)$ و یا میانگین احتمال محاسبه شده توسط تمام درخت‌ها [۶۳].

۳-۶- شبه کد الگوریتم آموزش جنگل تصادفی

برای تولید جنگلی با c کلاسیفایر و برای مجموعه داده D

شروع

برای i از ۱ تا c تکرار کن:

۱- به صورت تصادفی و با جایگزینی مجموعه داده D_i با N_i عضو را از داده‌های آموزشی (D)

انتخاب کن.

۲- یک نود ریشه بساز.

۳- تابع $BuildTree(N_i)$ را فراخوانی کن.

پایان حلقه (i)

پایان شبه کد آموزش

شبه کد تابع $BuildTree(N)$

۱- اگر N داده همگی در یک کلاس قرار می گیرند:

الف-۱- برگرد.

و گرنه

ب-۱- به طور تصادفی $x\%$ از ویژگی ها را انتخاب کن.

۲- ترکیبی از ویژگی ها (F) را که بالاترین مقدار بهره اطلاعات را دارد انتخاب کن.

۳- f -تا نود فرزند (N_1, N_2, \dots, N_f) برای N داده بساز که در هر یک F مقادیر (F_1, F_2, \dots, F_f)

را اختیار می کند.

برای j از ۱ تا f

۴- در هر نود N_j مجموعه D_j را قرار بده. (D_j داده هایی از مجموعه N تایی هستند که

مقدار ترکیب F آن ها برابر F_j است)

۵- $BuildTree(N_j)$ را فراخوانی کن.

پایان حلقه (j)

پایان شبه کد $BuildTree$

این الگوریتم یک جنگل تصادفی با درخت‌های چندگانه می‌سازد. در صورت استفاده از ساختار استاندارد جنگل، درخت‌های تصمیم‌گیری باینری هستند لذا در کلاس‌بندی هر نود تنها از دو محدوده مقدار برای کلاس‌بندی داده‌های هر نود استفاده می‌شود؛ پس $f=2$ [۶۴].

۳-۷- تنظیم پارامترهای آموزش جنگل

پارامترهای دخیل در میزان کارایی و دقت الگوریتم RF عمدتاً عبارتند از تعداد درختان تصمیم‌گیری، سطح شکست درختان، ماکزیمم تعداد مجاز داده باقیمانده در نود و تعداد ویژگی‌های مورد استفاده در هر نود برای محاسبه آستانه در این نود.

هرچند الگوریتم به انتخاب مقدار صدر درصد بهینه برای متغیرهای فوق حساس نیست اما به طور خاص انتخاب مقادیر نامناسب برای تعداد متغیرهای طبقه‌بندی‌کننده می‌تواند به کاهش دقت منجر شود. زیرا با افزایش متغیرها احتمال استفاده از متغیرهای تکراری و در نتیجه تصمیم‌گیری‌های تکراری نیز افزایش خواهد یافت. با وجود این تا کنون هیچ تحقیق معتبری روی تنظیم پارامترهای جنگل انجام نشده و تعیین آنها مطابق روابط پیش‌فرض صورت می‌گیرد [۵۷، ۵۶]. متداول‌ترین مقداری که برای تعداد متغیرهای طبقه‌بندی‌کننده در نظر گرفته می‌شود برابر مجذور تعداد کل ویژگی‌هاست. این مقدار هرچند کاملاً بهینه نیست اما به بهینه اصلی نزدیک است [۵۶].

اشاره شد که احتمال آموزش بیش‌ازحد در جنگل تصادفی بسیار پایین است اما منتفی نیست. به همین دلیل ساینز جنگل به صورت کنترل‌شده تعیین می‌شود. عموماً برای مسائلی با بعد ۲۰ ویژگی ۱۵۰-۱۰۰ درخت برای آموزش مناسب کافیست. مسائلی با بعد حدود ۱۰۰ ویژگی به بیش از ۵۰۰ درخت برای آموزش نیاز ندارند. از آنجا که عملیات پردازش در سطح جنگل به صورت موازی اجرا می‌شود، افزایش تعداد درختان جنگل منجر به افزایش زمان پردازش نمی‌شود. لذا رشد زمان محاسبات به افزایش بعد مساله یا تعداد نمونه‌های آموزش برمی‌گردد.

ماکزیمم سطح شکست درخت عامل دیگری است که تاثیر متوسطی روی افزایش یا کاهش دقت کلاسیفایر دارد. به طور پیش فرض جنگل در هیچ سطحی شکسته نمی شود و کلاس بندی تا زمانی که یک یا دو نمونه داده در هر نود باقی مانده باشد، ادامه می یابد. چنانچه ویژگی ها به اندازه کافی قدرت تمایز نمونه ها را داشته باشند، می توان کلاس بندی را در سطوح بالاتری متوقف کرد. از این پس تمام داده هایی که در یک نود قرار بگیرند متعلق به یک کلاس فرض می شوند.

ماکزیمم تعداد مجاز داده باقیمانده در هر نود نیز اثر مشابه سطح شکست دارد. این مقدار به طور پیش فرض ۱ در نظر گرفته می شود؛ یعنی هیچ دو داده ای در یک نود باقی نمی ماند و تصمیم گیری به سطح دیگری منتقل می شود. گاهی روی ماکزیمم نود باقیمانده در هر نود محدودیتی وجود نداشته و رشد شاخه زمانی متوقف می شود که مقدار بهره اطلاعات^۷ و یا ناخالصی Gini به حداقل خاصی برسد [۵۹]. میزان کارایی جنگل در قبال تغییر این دو پارامتر اخیر رفتار ثابت و قابل پیش بینی نشان نمی دهد. کاهش یا افزایش دقت در این مرحله بسته به نوع ویژگی های انتخاب شده برای کلاس بندی است.

۳-۸- کلاسترینگ بوسیله جنگل تصادفی

جنگل تصادفی را نمی توان مستقیما در کلاسترینگ به کاربرد. ولی می توان از برخی مقادیر خاص که توسط جنگل برای تمام داده ها محاسبه می شود نظیر استفاده از معیار شباهت^۸ یا "میزان نزدیکی"^۹ در یک الگوریتم کلاسترینگ استفاده کرد.

وقتی داده ای توسط یک برگ به صورت نهایی کلاس بندی می شود یعنی این داده بیشترین شباهت را با داده آموزشی که در این نود کلاس بندی شده، دارد. لذا چنانچه دو داده توسط یک برگ

⁷ Information Gain

⁸ Similarity

⁹ Proximity

کلاس‌بندی شوند، میزان نزدیکی آنها یک واحد افزایش می‌یابد. پس از جمع مقدار نزدیکی بین این دو داده در سایر درختان و نرمال‌سازی نتیجه، ماتریس بدست‌آمده می‌تواند توسط یک الگوریتم کلاسترینگ به‌طور مثال مبتنی بر گراف یا شبکه استفاده‌شود [۶۵, ۶۶]. میزان تفاوت داده‌ها که از رابطه (۳-۴) محاسبه می‌شود نیز می‌تواند به‌جای میزان نزدیکی و یا در کنار آن ارتباطات بین نودهای چنین گرافی را تشکیل دهد.

$$DISSIM_{ij} = \sqrt{1 - SIM_{ij}} \quad (۳-۴)$$

۳-۹- بهبود درصد شناسایی

یک راه افزایش نسبی میزان شناسایی صحیح، بدست‌آوردن پارامترهای تقریباً بهینه جنگل برای مساله موردبررسی است. همان‌طور که اشاره‌شد تابحال هیچ تحقیق استانداردی روی تنظیم پارامترهای الگوریتم جنگل برای بهینه‌سازی کارایی آن صورت نگرفته‌است اما برای بهبود عملکرد الگوریتم برخی محققین با دستکاری جزئی روی ساختار جنگل یا نحوه آموزش آن به نتایج جالبی رسیده‌اند. مثلاً انتخاب تابع جداساز هر نود بصورت تصادفی نتایجی تقریباً با همان دقت الگوریتم اولیه تولید می‌کند. هرچند درخت‌ها در چنین ساختاری کلاسیفایرهای بسیار ضعیفی خواهندشد اما امکان بوجود آمدن تصمیم‌گیری‌های تکراری و همبستگی بین درخت‌ها نیز تقریباً به صفر می‌رسد [۶۷].

از طرف دیگر دقت کلی جنگل با تضعیف یا حذف اثر کلاسیفایرهای ضعیف بهبود می‌یابد. به‌این منظور پس از شناسایی درخت‌هایی که قسمت عمده داده‌ها را به غلط کلاس‌بندی می‌کنند از یک مکانیزم وزن‌دهی برای تقویت اثر درخت‌های قوی‌تر استفاده می‌شود. ادعا شده‌است که این روش هیچ‌گاه بدتر از جنگل معمولی عمل نمی‌کند [۵۱].

ترکیب ایده الگوریتم AdaBoost با کلاسیفایر جنگل تصادفی نیز منجر به تولید کلاسیفایر قدرتمندتری خواهدشد. در اینجا بجای استفاده از یک جنگل، از چندین جنگل تصادفی استفاده می‌شود که هر یک نتیجه قبلی را تقویت می‌کنند [۶۲].

افزایش نرخ بازشناسی جنگل روی مجموعه داده‌های نامتوازن راحت‌تر از کلاسیفایرهای دیگر انجام می‌شود زیرا جنگل برای پیاده‌سازی هردو متد نمونه‌برداری و می‌نیم‌سازی تابع هزینه ساختار مناسبی دارد.

در زمان نمونه‌برداری تصادفی احتمال اینکه داده‌های کلاس کوچکتر اصلاً انتخاب نشوند یا تعداد ناچیزی از آن‌ها انتخاب شوند، بالاست لذا پیشنهاد می‌شود نمونه‌برداری از کلاس‌ها به صورت نکه‌به‌تک صورت‌گیرد و هم‌زمان با *over-sampling* داده‌های کلاس کوچکتر، *under-sampling* روی داده‌ها کلاس بزرگتر اعمال شود.

برای استفاده از تابع هزینه ساختاری به نام جنگل تصادفی وزن‌دار پیشنهاد شده است. از آنجا که زمان نمونه‌برداری کلاس‌های پرتعداد شانس بیشتر برای انتخاب دارند، باید برای خطای کلاس-بندی جریمه سنگین‌تری در نظر گرفته شود. به این منظور به هر کلاس وزنی تعلق می‌گیرد. وزن کلاس اقلیت بیشتر از سایرین در نظر گرفته می‌شود که به معنی هزینه بیشتر در صورت تشخیص غلط است. در مرحله ساخت و آموزش درخت‌ها، این اوزان با وزن‌دار کردن تابع *Gini*، در تعیین نقطه آستانه دخالت می‌کنند. زمان تعیین کلاس داده نیز وزن‌ها در مقدار احتمال شرطی کلاس‌ها تاثیر گذاشته و این جریان را هدایت می‌کنند [۵۸].

درختان در جنگل تصادفی عموماً ساختار باینری دارند با این حال قادر به حل مسائل چندکلاسه هستند. کلاس‌بندی نودها در هر نود با استفاده از یک تابع *Gini* انجام می‌شود اما این تابع برای تمام کلاس‌ها بهینه نیست. در نتیجه تعدادی از داده‌ها با سطوح کمتر و تعدادی دیگر با سطوح بیشتری کلاس‌بندی می‌شوند. برای این مسائل درختان چندگانه نیز وجود دارند که ما یک جنگل را با چنین ساختاری پیاده کردیم. استفاده از این درختان سطوح تصمیم‌گیری را کاهش می‌دهد. چندگانگی در هر نود با استفاده از چندین تابع *Gini* صورت می‌گیرد. در مرحله اول کلاس‌های مشابه با هم یکی در نظر گرفته شده و به‌ازای هر یک از این دسته‌های جدید یک تابع *Gini* استفاده می‌شود.

در هنگام آموزش در سطح اول داده‌های هر دسته تابع Gini مربوط به دسته خود را بهینه می‌کنند. سپس در سطوح بعدی که دسته‌بندی کلی انجام شد مطابق با ساختار جنگل معمولی (باینری) داده‌های متعلق به کلاس‌های مختلف از یکدیگر تفکیک می‌شوند. بسته به اینکه حدکثر چند کلاس در یک دسته قرار بگیرند (d)، ماکزیمم تعداد سطوح درختان جنگل برابر d خواهد بود. در زمان تست داده از سمت چپ به شاخه‌ای هدایت می‌شود که از مقدار آستانه آن کمتر باشد و در غیر این صورت با سایر آستانه‌ها مقایسه می‌شود. دسته‌بندی اولیه‌ای که در مرحله اول روی داده‌ها انجام می‌گیرد خطای کلاس‌بندی نهایی را کاهش می‌دهد.

۳-۱۰- جمع‌بندی و بیان اهداف

در این فصل به معرفی کلاسیفایر جنگل تصادفی، نحوه آموزش و تشریح پارامترهای آن پرداختیم. کلاسیفایر جنگل تصادفی ویژگی‌های منحصر به فردی دارد. ساختار جنگل تصادفی به اندازه کلاسیفایرهای نظیر SVM و شبکه‌های چندلایه عصبی پنهان نبوده و می‌توان به راحتی به پارامترهای درخت دسترسی پیدا کرده و بهترین ویژگی‌ها را برای کلاس‌بندی مشخص نمود [۵۰]. در بسیاری از مسائل، قدرت تعمیم جنگل تصادفی بسیار بهتر از SVM یا سایر کلاسیفایرهای مطرح است [۶۱]. قدرت شناسایی جنگل به‌طور تقریباً یکنواخت با افزایش تعداد درختان، افزایش می‌یابد اما بدلیل خطر آموزش بیش‌ازحد، این افزایش کنترل شده‌است. در ضمن جنگل خود می‌تواند میزان ضریب اطمینان پیش‌بینی‌های خود را تخمین بزند.

جنگل تصادفی را بعداً به‌عنوان کلاسیفایر در بخش ناحیه‌بندی مورد استفاده قرار خواهیم داد. از آنجا که ناحیه‌بندی تصویر از طریق کلاس‌بندی پیکسل‌ها انجام می‌شود، انتخاب نوع ویژگی و نحوه استخراج آن بطوری که بتواند خواص مقاومت به نویز و ناهمگنی را حفظ کند بسیار اساسی است. قبلاً اشاره شد که یکی از راه‌های مقابله با هر دو اثر نویز و ناهمگنی استفاده از روابط همسایگی و میزان تأثیری است که همسایگان یک پیکسل بر مقدار آن می‌گذارند. لذا باید ویژگی‌های توصیف‌کننده

ناحیه اطراف پیکسل برای جنگل از روش مناسبی استخراج شود. یک نکته اساسی در این جا تعیین اینست که کدام همسایه روی برجسب گذاری یک پیکسل تاثیرگذار باشد و از مداخله کدام یک جلوگیری شود. این نکته برای مقابله با اثر نامطلوب حجم جزئی است. به این منظور می توان پیش از استخراج ویژگی ها نوعی بخش بندی یا پیش ناحیه بندی را روی تصویر اعمال کرده و محدوده امن استخراج ویژگی ها را برای کلیه پیکسل ها تعیین نمود.

فصل چهارم

روش پشه‌ادی برای ناحیه بندی محلی بافت مغز

۲-۱- مقدمه

قسمت مهمی از مشکلات پیش‌روی متد ناحیه‌بندی MRI به مخدوش‌شدن مقادیر پیکسل‌ها توسط عوامل داخلی و خارجی مربوط می‌شود؛ همانند نویزی که در نتیجه حرکت بیمار در حین پروسه طولانی تصویربرداری به تصویر وارد شده و وضوح مرز بافت‌ها را از بین می‌برد [۷]. تفاوت سطوح خاکستری یا شدت روشنایی تصاویر از یک بیمار به بیمار دیگر در نتیجه تغییر پارامترهای تصویربرداری دستگاه، امکان مقایسه تصاویر را با یکدیگر دشوار می‌سازد. از طرفی نقص هسته مغناطیسی دستگاه تصویربرداری باعث بروز اثر بایاس فیلد یا ناهمگنی در روشنایی تصویر و تولید نتایج نامعتبر خواهد شد. لذا استفاده از دانش اولیه همانند اطلس و یا یافتن روابطی میان عناصر تصویر برای استخراج ویژگی‌ها و جبران خطای ناشی از ناهمگنی ضروریست. همانطور که اشاره شد یکی از راه‌های متداول برای مقابله با این اثر استفاده از اطلاعات فضایی و روابط همسایگی است [۶۸].

در این فصل پس از بحث مختصر درباره نحوه استخراج اطلاعات ناحیه‌ای، روشی را برای استخراج ویژگی‌های فضایی ارائه خواهیم داد که کیفیت و دقت ویژگی‌های استخراج‌شده برای پیکسل-های تصویر را بهبود خواهد داد. با استفاده از این روش ما به بهبود قابل‌توجهی در مرزبندی بافت‌ها در تصاویر مورد استفاده خود رسیدیم.

۲-۴- ویژگی‌های فضایی در مساله ناحیه‌بندی

مساله ناحیه‌بندی تصویر MR مشاهده شده، I ، در سه کلاس {ماده سفید (WM)، ماده خاکستری (GM) و مایع مغزی نخاعی (CSF)} به صورت تخصیص کلاس با ماکزیمم احتمال به هر یک از وکسل‌های تصویر تعریف می‌شود. خروجی این عملیات تصویر برچسب‌گذاری شده I^* با برچسب‌های {CSF, GM, WM} است. خواهیم داشت:

$$L^* : \Omega \rightarrow \{CSF, GM, WM\} \quad (1-4)$$

$$L^* = \arg \max_L \log P(L | I) = \arg \max_L \log P(I | L) + \log P(L)$$

با فرض اینکه کلاس پیکسل‌ها از یکدیگر مستقل باشد:

$$\log P(I | L) = \sum_{x \in \Omega} \log P(I(x) | L(x)) \quad (2-4)$$


و برای احتمالات اولیه هر کلاس

$$\log P(L) = \sum_{x \in \Omega} \log U(L(x)) + \sum_{x,y} V(L(x), L(y)) \quad (3-4)$$

در این رابطه، U تابع مکان و V تابع میزان تاثیر فضایی پیکسل‌های مجاور بر کلاس یکدیگر است [۶۹]. یافتن چگونگی تاثیر بایاس فیلد بر مقدار احتمال $P(I | L)$ مساله‌ایست که روش‌های حذف اثر بایاس فیلد به آن می‌پردازند.

ابتدایی‌ترین و متداول‌ترین راه محاسبه ویژگی‌های محلی در فضای اطراف یک پیکسل، بلوک-بندی ساده تصویر و محاسبه ویژگی موردنظر از روی پیکسل‌های احاطه‌شده در بلوک به ازای پیکسل مرکزی بلوک است. متداول‌ترین ویژگی‌های محلی با ترکیب مقدار خاکستری پیکسل و اطلاعات مکانی و فاصله‌ای در مختصات اقلیدسی یا قطبی بدست می‌آیند [۶۱، ۷۰، ۷۱].

سیستم همسایگی $n \times n$ اغلب برای استخراج ویژگی‌های مکانی درون محدوده همگن بافت کافیت؛ اما در نقاط نزدیک به مرز بافت‌ها بدلیل بروز مساله حجم جزئی یا partial voluming استفاده از این همسایگی ثابت منجر به تولید ویژگی‌های مکانی نادرست خواهد شد. شکل (۱-۴) این مشکل را به خوبی تصویر می‌کند. همانطور که مشاهده می‌شود، بلوک 2×2 که روی مرز بافت لغزنده می‌شود هر دو بافت را دربر می‌گیرد. چنانچه بعنوان مثال از ویژگی مد یا میانگین ناحیه برای ساختن بردار ویژگی استفاده شود، نتیجه غیرقابل پیش‌بینی خواهد بود.



شکل (۴-۱): ورود عناصر متعلق به بافت‌های مختلف در بلوک ناحیه‌بندی و دستکاری مقادیر

به منظور اصلاح نحوه استخراج ویژگی در این پروژه پیشنهاد می‌شود با اعمال محدودیت بیشتر روی مفهوم همسایگی و تبدیل بازه همسایگی به یک بازه منطبق با داده، اطلاعات مورد نیاز برای تصمیم‌گیری در مورد هر پیکسل تصویر از همسایگانی با قابلیت اعتماد بالاتر استخراج شود. به عبارتی بلوکی که روی تصویر لغزانده می‌شود همه پیکسل‌های مجاور یک پیکسل مرکزی را در محاسبه بردار ویژگی دخالت نخواهد داد.

به این منظور ما با اعمال تغییرات جزئی روی متد انتشار شایعه^۱ از آن به عنوان یک الگوریتم تعیین همسایگی در مرحله پیش ناحیه‌بندی استفاده نمودیم. ناحیه‌بندی حاصل تا حدی اثر ناهمگنی را خنثی می‌سازد اما این همسایگی محلی و جدید، ورودی سیستم برای استخراج ویژگی‌های مقاوم در برابر تغییرات روشنایی خواهد بود. اطلاعات بدست‌آمده از این نواحی برای کلاس‌بندی نهایی به الگوریتم جنگل تصادفی داده می‌شود.

۴-۳ - متد انتشار شایعه

متد انتشار شایعه یک روش پخش اطلاعات شناخته‌شده در شبکه‌های توزیع‌شده و انتقال داده بوده و برگرفته از نحوه انتشار شایعه در یک جامعه است. به این ترتیب که هر داده همانند یک شایعه مدل می‌شود و عاملی که از شایعه مطلع است آن را در شبکه پخش کرده و به اطلاع عامل‌های مجاور می‌رساند. این عامل‌ها نیز به نوبه خود آن را منتشر خواهند ساخت. در صورت اطلاع پیشاپیش نود

^۱ Gossiping

مجاور از شایعه، تمایل عامل برای پخش شایعه کم شده و رفته رفته این روند متوقف خواهد شد [۷۲].
تعمیم کاربرد این الگوریتم در ناحیه بندی تصویر تا کنون به صورت محدود مورد توجه بوده است [۷۰].
انتشار اطلاعات توسط این متد عموماً از دو الگوی کلی "انتشار تک عاملی"^۲ (یکی به همه) و
یا "انتشار چند عاملی"^۳ (همه به همه) پیروی می کند. در الگوی تک عاملی همیشه تنها یک نود مایل
به انتشار اطلاعات (push) و سایر نودها مایل به دریافت اطلاعات از نود منتشرکننده و برورسانی
وضعیت خود (pull) هستند. در الگوی چندعاملی همه نودهای موجود در شبکه مایل به انتشار
اطلاعات به مجاورین خود یا سایر نودهای شبکه هستند [۷۳].

طبق پروتکل انتشار فراگیر یا اپیدمیک که تقریباً متداول ترین پروتکل انتشار شایعه محسوب
می شود در هر مرحله انتشار، نودهای شبکه در یکی از دو وضعیت مبتلا شده^۴ و مستعد پذیرش^۵ قرار
می گیرند. نود "مبتلا" اطلاعات جدید را در اختیار داشته و می تواند آنرا در شبکه پخش کند. نودی که
در وضعیت "مستعد" بسر می برد هنوز از شایعه جدید مطلع نشده است. این نودها بصورت تصادفی
توسط نود مبتلا انتخاب شده و اطلاعات جدید را دریافت می کنند. نودهایی که مدت طولانی در
وضعیت مستعد باقی بمانند خود با یک درخواست pull اطلاعات جدید را از نزدیکترین نود مبتلا
دریافت خواهد کرد [۷۳].

کاربرد این الگوریتم در شبکه های انتقال داده بیشتر منحصر به نحوه انتقال داده بوده است اما
در [۷۴] پیشنهاد شده است برای بخش بندی^۶ شبکه های بیسیم از روشی مشابه الگوریتم انتشار شایعه
استفاده شود. در چنین ساختاری شبکه به نواحی تقسیم می شود که درون هر ناحیه خاصیتی مشترک
وجود دارد. این خاصیت مشترک محدوده امواج رادیویی است که توسط سنسور موجود در هر نود
شبکه دریافت می شود. نحوه ارزیابی شباهت دو الگو در این سنسورها مورد بحث ما نیست اما بخش -

² Single-piece dissemination


³ Multi-piece dissemination

⁴ Infected


⁵ Susceptible

⁶ Partitioning

بندی و ایجاد ارتباط میان نودها بر مبنای این شباهت از روشی مشابه الگوریتم شایعه پیروی می‌کند. الگوریتم به‌طور مداوم اجرا شده و هر نود در فواصل زمانی مشخصی به اصطلاح بیدار شده و فرصت می‌یابد تا ارتباطات خود را بازبینی کند. در نتیجه تکرار الگوریتم، ارتباطات منطقی بین نودهای شبکه مطابق تصویر (۲-۴) شکل می‌گیرد که آن را به نواحی مجزایی تقسیم می‌کند.



(ب)



(الف)

شکل (۲-۴): بخش‌بندی یک شبکه به چهار ناحیه مجزا با الگوریتم انتشار شایعه، الف) شبکه اولیه متشکل از چهار ناحیه مجزای، ب) نواحی و ارتباطات شکل گرفته پس از بخش‌بندی [۶۲]

برای تعیین قدرت ارتباط بین دو نود مفروض r و d چنانچه فاصله محدوده مقادیر آن‌ها که توسط تابعی همانند $D(.)$ ارزیابی می‌شود، از آستانه مشخصی کمتر باشد، دو نود همسایه تلقی شده و ارتباط بین آنها تقویت و در غیر این صورت تضعیف می‌شود.

تعیین نودهای مرتبط و برقراری ارتباطات قوی بین این نودها را در حوزه تصویر برای بخش‌بندی تصویر به نواحی استفاده می‌کنیم که پیکسل‌های درون هر ناحیه در مقادیر یک ویژگی، مشترک یا بسیار به هم نزدیک هستند. با توجه به همسایگی پیکسل‌های درون ناحیه، تاثیر آن‌ها روی مقادیر یکدیگر بیش از سایر پیکسل‌های تصویر خواهد بود. بنابراین چنین ناحیه‌ای می‌تواند برای استخراج ویژگی‌های فضایی هر پیکسل درون ناحیه مورد استفاده قرار گیرد.

۴-۴- پیش ناحیه بندی مبتنی بر انتشار شایعه

چنانچه الگوی انتشار تک‌عاملی را مورد توجه قرار دهیم و برچسب یک پیکسل در تصویر را همان شایعه فرض کنیم، با این پیکسل به عنوان یک هسته انتشار برخورد می‌شود. پیکسل باید برچسب خود را که نشان‌دهنده وضعیت شدت روشنایی در این محدوده است به سایر پیکسل‌ها و بالاخص مجاورین خود اطلاع دهد. بنابر تئوری الگوریتم انتشار شایعه این برچسب باید بدون استثنا به تمامی همسایگان منتسب شود. پرواضح است که چنین انتسابی اصولاً از هدف ناحیه‌بندی دور است. لذا در وهله اول انتشار تنها به پیکسل‌های نزدیک هسته محدود می‌شود.

انتخاب هر نود جدید به عنوان هسته با احتمال برابر $1/n$ صورت گرفته و برچسب جدیدی به آن منتسب می‌شود. در صورت انتخاب مجدد یک هسته، شماری از همسایگان از برچسب آن مطلع هستند. چنین وضعیتی احتمال انتخاب این نود را در مراحل بعدی کاهش می‌دهد. اطلاع همسایگان از برچسب پیکسل مرکزی به معنای اینست که رفته‌رفته ناحیه همگنی اطراف این نود شکل می‌گیرد. در اینجا چگونگی تعریف مفهوم همسایگی کیفیت نتیجه نهایی را مشخص خواهد کرد چراکه حتی در صورت قائل شدن محدودیت فیزیکی روی نودهای دریافت‌کننده اطلاعات هسته، انتساب بی‌قید و شرط برچسب به همسایگان هسته در مرز بین بافتها سبب ناحیه‌بندی نادرست خواهد شد.

لذا ما در اینجا با اعمال محدودیت کوچکی روی همسایگی، انتساب شایعه به پیکسل همسایه را منوط به مجاورت فیزیکی با پیکسل مرکزی و نیز قرار داشتن در محدوده سطح روشنایی (خاکستری) این پیکسل خواهیم نمود. لازم به ذکر است که تغییر روشنایی روی سطح تصویر ام آر آی به صورت تدریجی رخ می‌دهد. لذا نقاط مجاور بشرطی که اصولاً متعلق به یک بافت باشند تفاوت روشنایی قابل-ملاحظه‌ای نخواهند داشت.

در صورتیکه همسایگان هسته از برچسب آن اطلاعی نداشته باشند، شانس انتخاب این نود در تکرارهای بعدی الگوریتم افزایش می‌یابد زیرا به نظر می‌رسد در این محدوده ناحیه با سرعت خوبی رشد

خواهد کرد (بعبارتی شایعه با سرعت پخش می‌شود) از طرفی چنانچه همسایگان یک پیکسل قبلا از برچسب آن مطلع شده باشند، شانس انتخاب آن طبق رابطه (۴-۴) کاهش می‌یابد تا کم‌کم انتشار شایعه از طریق آن متوقف شود [۷۰].

$$p = \left[1 - \left(\frac{|N_{infected}|}{|N_g|} \right) \right] \times |N_g| \quad (4-4)$$

در رابطه بالا $N_{infected}$ نودهای "مبتلا شده"، N_g محدوده همسایگی و $| \cdot |$ اندازه یک مجموعه را مشخص می‌کند. نودهایی که در دورهای متوالی همچنان برچسب جدیدی دریافت نکنند، برچسب نزدیکترین همسایه خود را بشرط شباهت سطح خاکستری دریافت خواهند کرد.

۴-۵- پیاده‌سازی مرحله پیش‌ناحیه‌بندی


بحث اصلی در پیاده‌سازی متد انتشار شایعه، نحوه گسترش شایعه از هسته مرکزی به سایر پیکسل‌هاست. در مراحل اولیه انتخاب هسته بدون پیش‌فرض صورت گرفته و شانس انتخاب تمامی پیکسل‌ها تقریباً یکسان است. با انتخاب هسته جدید دو امکان متصور است. چنانچه هسته پیش از این توسط هیچ یک از همسایگان خود برچسب‌گذاری نشده باشد، برچسب جدیدی دریافت کرده و خود ناحیه‌جدیدی را تشکیل می‌دهد. اما در صورتیکه هسته مرکزی قبلا برچسب‌گذاری شده باشد، ناحیه فعلی را توسعه خواهد داد. با هربار انتخاب یک پیکسل به عنوان هسته ناحیه از امتیاز آن برای انتخاب مجدد کاسته می‌شود تا علاوه بر این که فرصت در اختیار سایر پیکسل‌ها قرار داده می‌شود، الگوریتم پس از دفعات تکرار معقولی به وضعیت پایدار برسد.

پیکسل‌هایی که در دفعات تکرار متعدد توسط هیچ هسته‌ای انتخاب نشده و در وضعیت مستعد باقی بمانند، با ارسال درخواست pull، از نزدیکترین هسته که با خود پیکسل در یک سطح روشنایی قرار بگیرد، برچسبی را دریافت می‌کنند.

میزان انتشار برچسب در سطح تصویر به نوع ویژگی بستگی دارد که از نواحی استخراج خواهد شد. برای کاستن اثر بایاس فیلد مطلوبست که نواحی حتی‌الامکان کوچک بوده و سطح روشنایی در

سطح ناحیه تغییر ناچیزی داشته باشد. مناسب تر است ویژگی های ابتدایی نظیر میانگین یا مد ناحیه که در برابر تغییرات روشنایی مقاوم نیستند، روی نواحی کوچکتری محاسبه شوند. برای این ویژگی ها همسایگی از مدل بلوک بندی تصویر با بلوک های کوچک $n \times n$ محدودتر است. همین محدودیت از ورود پیکسل های متعلق به بافت های متفاوت به درون ناحیه جلوگیری کرده و برای میانگین ناحیه بخصوص در اطراف لبه ها و مرز بافت ها مقدار دقیق تری بدست خواهد آمد.

شکل (۳-۴) نتیجه اعمال این روش را روی یک تصویر نمونه نشان می دهد.



(ب)

(الف)

شکل (۳-۴): تعیین همسایگی های جدید با روش پیشنهادی: الف) تصویر اولیه از بافت مغز، ب) تصویر نتیجه شده از اعمال متدانتشار شایعه به منظور بخش بندی اولیه


این تصویر نمونه ای از پیش ناحیه بندی یا بخش بندی تصویر است زمانی که نواحی برای رشد با محدودیت زیادی مواجه باشند. در این حالت، انتشار برچسب از هر پیکسل تنها به همسایگان بلافاصلش صورت می گیرد و سپس متوقف شده و هسته جدیدی انتخاب می شود. نتیجه این سیاست تقریباً مشابه بلوک بندی است.

برای کوچک نگه داشتن محدوده همسایگی، ماکزیمم مجاز تغییرات روشنایی درون هر ناحیه کوچک در نظر گرفته می شود. با اعمال محدودیت روشنایی روی پیکسل های درون یک بازه همسایگی، اندازه روشنایی درون این بازه تقریباً ثابت است. از آنجا که تغییرات روشنایی تصویر در نتیجه ناهمگنی به صورت تدریجی و نه دفعتاً رخ می دهد، اثر آن در یک بازه کوچک تقریباً قابل چشم پوشی است.

این الگوریتم ساده در مورد ویژگی های نظیر میانگین و کمترین و بیشترین مقدار که چندان به

سایز ناحیه وابسته نیستند، بخوبی پاسخگوست. اما عملیاتی نظیر هیستوگرام گرفتن روی نواحی کوچک بی معنی است.

برای بدست آوردن الگوی کلی یک بافت نیاز است تا نواحی گسترده تر شوند. به همین دلیل در حالت دوم الگوریتم پیش ناحیه بندی گسترش یافته پیش از محاسبه ویژگی های فضایی روی تصویر اعمال می شود. برچسب هسته مرکزی در وهله اول به همسایگان بلا فصل هسته اطلاع داده می شود. برای گسترش ناحیه هر یک از همسایگانی که به ناحیه پیوسته اند به نوبه خود این برچسب را منتشر خواهند ساخت. روند بررسی همسایگی برای پیکسل های مجاور آن ها نیز تکرار می شود و در صورت ارضای شروط تعیین شده، پیکسل های مجاور به ناحیه اضافه می شوند.



شکل (۴-۴): برقراری ارتباط با روش دوست دوست [۷۲]

اما این شیوه انتساب اولیه که طبق قاعده دوست دوست [۷۲] صورت می گیرد ممکن است باعث ایجاد تناقضاتی در مرز تلاقی نواحی اصلی با یکدیگر شود. به این صورت که با گسترش ناحیه، سطوح خاکستری که به ناحیه وارد می شوند گسترده تر می شود. در این حالت ممکن است شرایطی رخ دهد که پیکسل جدید نسبت به پیکسل مجاور خود شرط ورود به ناحیه را برآورده باشد اما مقدار آن از مقدار خاکستری هسته مرکزی بسیار دور باشد. در این نواحی شرایط برای بروز اثر بایاس فیلد و تغییر ویژگی های آماری فراهم می شود. ضمن اینکه این فاصله به راحتی برای مقادیر مرزی سبب بروز خطای ناحیه بندی می شود. برای جلوگیری از گسترش بیش از حد ناحیه اعمال محدودیت فاصله مقداری تا هسته مرکزی ناحیه برای هر پیکسل جدید نیز ضروری است.

تصویر (۴-۵) نتیجه ناحیه‌بندی با این روش را نمایش می‌دهد.



(ب)

(الف)

شکل (۴-۵): اعمال پیش‌ناحیه‌بندی گسترش‌یافته روی تصویر مغز، (الف) تصویر اولیه، (ب) نتیجه ناحیه‌بندی

۴-۶- مرحله استخراج ویژگی‌ها

ویژگی‌هایی که برای ناحیه‌بندی تصاویری نظیر MRI استفاده می‌شوند یا باید بر اساس روابط همسایگی محاسبه شوند تا نسبت به تغییرات ناگهانی روشنایی مقاوم باشند و یا ویژگی باید ذاتا نسبت به تغییرات روشنایی مقاوم باشد.

چنانچه الگوریتم مورد استفاده اصولا برای ناحیه‌بندی طراحی شده باشد، خود قادر به ادراک روابط فضایی و همسایگی بوده و تاندازه‌ای در برابر نویز مقاوم است. بعنوان مثال متد MRF که اخیرا در ناحیه‌بندی MRI به‌وفور مورد استفاده قرار گرفته است، خود به‌خوبی قادر است اثر ناهمگنی و نویز را تقلیل داده و ناحیه‌بندی دقیقی روی تصاویر اعمال کند. اما جنگل تصادفی یک کلاسیفایر است و خودبخود رابطه‌ای را از روی تصویر استخراج نمی‌کند. بنابراین کارآیی جنگل به کیفیت ویژگی‌هایی بستگی دارد که با آن آموزش داده می‌شود.

ویژگی‌هایی که بطور متداول در ناحیه‌بندی تصویر مورد استفاده قرار می‌گیرند چندان متنوع نبوده و عمدتا شامل سطح خاکستری، ویژگی‌های بافتی، و ویژگی‌های فضایی هستند.

ویژگی مقدار خاکستری یا سطح روشنایی ارزشمندترین ویژگی در پردازش تمامی تصاویر محسوب می‌شود. پس از آن ویژگی بافت، تقریبا اساسی‌ترین ویژگی محسوب می‌شود که تغییرات سطوح خاکستری را بین پیکسل‌های مجاور نمایش می‌دهد. رادیولوژیست‌ها نیز بسیاری از تشخیص-

های خود را با استفاده از همین ویژگی انجام می‌دهند. از متداول‌ترین ویژگی‌های بافتی می‌توان به هیستوگرام، ویژگی "طول قطعه"^۷ و ماتریس هم‌رخداد اشاره کرد. ویژگی‌های هیستوگرام توزیع روشنایی را در سطح تصویر توصیف می‌کنند و می‌توان ویژگی‌هایی از قبیل میانگین و انحراف معیار سطوح خاصی را نیز از روی آن محاسبه کرد.

ماتریس هم‌رخداد سطح خاکستری^۸ (GLCM) توسط Harlick در [۷۵] برای تعریف ویژگی-های بافتی معرفی شد. این ماتریس روابط مکانی پیکسل‌ها در سطح خاکستری را بررسی می‌کند. توابع این ماتریس، به وسیله محاسبه این‌که چگونه دو پیکسل با مقادیر روشنایی مشخص در تصویر با رابطه فضایی خاصی (از نظر فاصله و زاویه) ظاهر می‌شوند، بافت تصویر را تشخیص می‌دهند. لذا ماتریس هم‌رخداد تصویر هم یک ویژگی بافتی و هم یک ویژگی فضایی محسوب می‌شود.

ویژگی "الگوی باینری محلی"^۹ نیز علاوه بر این‌که یک ویژگی بافت محسوب می‌شود، یک ویژگی فضایی نیز هست. این ویژگی با استفاده از اختلاف عناصر همسایه اثر تغییرات روشنایی را حذف می‌کند.


۴-۷- الگوی باینری محلی (LBP)

عملگر LBP یک عملگر قدرتمند برای تحلیل یا شناسایی بافت محسوب می‌شود [۷۶]. توانایی این ویژگی در مقابله با تغییرات سطح روشنایی و نیز سادگی و سرعت محاسبه بردار ویژگی، آن را در زمینه شناسایی چهره، شناسایی متن، مدل‌سازی پس‌زمینه و نظیر آن بسیار پرکاربرد ساخته است. بردار ویژگی LBP، برای هر پیکسل بافت خاکستری محلی آن را با استفاده از پیکسل‌های محصور در محدوده همسایگی‌اش توصیف می‌کند. همانطور که در تصویر (۴-۶) نشان داده شده است بازه همسایگی بر حسب شعاع R به صورت زیر تعریف می‌شود.

^۷ Run-length

^۸ Gray-level co-occurrence matrix

^۹ Local Binary Pattern(LBP)



R=1.0, P=4

R=1.0, P=8

R=1.5, P=12

شکل (۴-۶): محدوده همسایگی اطراف پیکسل مرکزی برحسب شعاع R [۷۷]

مجموعه P پیکسلی که در فاصله R از هسته مرکزی g_c قرار گرفته‌اند، در تعیین مقدار محلی بافت هسته شرکت دارند. فاصله بین پیکسل مرکزی g_c و هریک از پیکسل‌های تعریف‌شده در بازه همسایگی، به صورت باینری کدشده و نهایتاً مقدار LBP برای پیکسل مرکزی g_c از رابطه (۴-۵) محاسبه می‌شود:

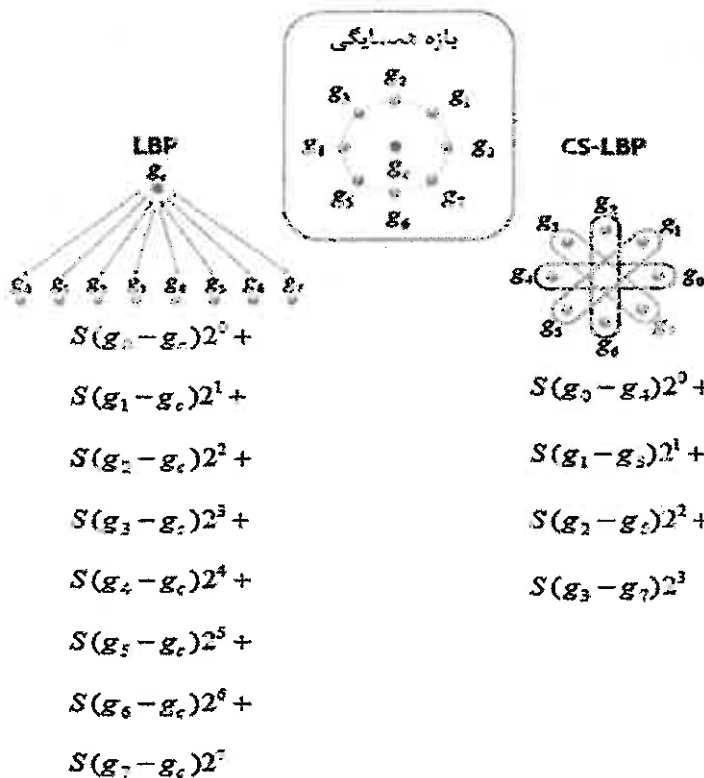
$$LBP_{P,R} = \sum_{P=0}^{P-1} S(g^P - g^c) 2^P \quad (۴-۵)$$

$$S(x) = \begin{cases} 1, & x \geq 0 \\ 0, & x < 0 \end{cases} \quad (۴-۶)$$

مقدار تابع باینری فاصله (S) برای دو پیکسل g_p و g_c در صورتی که اختلاف مقدار خاکستری بین دو پیکسل از حدآستانه معلوم (عموماً صفر) تجاوز کند ۱ و در غیر این صورت صفر است. معمولاً ویژگی LBP به صورت خام استفاده نمی‌شود. برای توصیف بافت تصویر یا ناحیه از مقادیر LBP محاسبه‌شده به صورت سراسری یا محلی هیستوگرام گرفته می‌شود. تعداد الگوهای مختلفی که توسط LBP تولید می‌شود به اندازه بازه همسایگی وابسته است که در صورت استفاده از همسایگی متداول ۸ تایی ($R=1$) الگوی باینری محلی قادر است ۲۵۶ الگو یا مقدار مختلف تولید کند. لذا طول بردار هیستوگرام LBP برابر ۲۵۶ خواهد بود [۷۷].

۴-۷-۱- ویژگی LBP متقارن (CS-LBP)


با توجه به تعدد الگوهای متفاوتی که توسط LBP تولید می‌شود طول بردار ویژگی آن نسبتاً طولانی است؛ لذا گاهی بجای آن از ویژگی^{۱۰} CS-LBP یا LBP متقارن استفاده می‌شود [۷۷]. محاسبات LBP متقارن ساده‌تر بوده و بجای محاسبه فاصله هریک از پیکسل‌های همسایه نسبت به پیکسل مرکزی، فاصله هر دو همسایه متقارن نسبت به مرکز با یکدیگر سنجیده می‌شود. به این ترتیب محاسبات مورد نیاز نصف شده و تنها ۱۶ (۲^۴) الگوی مختلف از آن تولید می‌شود. تصویر (۴-۷) نحوه محاسبه LBP و LBP متقارن را به خوبی نمایش می‌دهد.



شکل (۴-۷): نحوه محاسبه LBP و CS-LBP برای یک پیکسل [۷۷]

ویژگی LBP متقارن نیز همانند LBP استاندارد خواص مقاومت به تغییرات نوری را در خود حفظ کرده است [۷۸]. محاسبه این ویژگی روی تصویر بافت مغز، تصویر نشان داده‌شده در شکل (۴-۸) ب را نتیجه داد.

¹⁰ Center Symmetric Local Binary Pattern



(الف)

(ب)

شکل (۸-۴): نمایش ویژگی بافت با استفاده از CS-LBP، الف) تصویر بافت مغزی، ب) نمایش تصویر CS-LBP

همانطور که در تصویر (۸-۴) مشخص می‌شود الگوی LBP تولیدشده به‌ازای هریک از بافت‌ها،

از الگوی تولیدشده برای سایر بافت‌ها کاملاً متمایز است.


شکل (۹-۴) هیستوگرام مقادیر LBP را برای هریک از بافت‌های سه‌گانه مغزی (ماده سفید،

ماده خاکستری و مایع مغزی نخاعی) نمایش می‌دهد. تعیین محدوده نواحی با استفاده از نمونه


ناحیه‌بندی‌شده تصویر که توسط متخصصین فراهم‌شده، صورت‌گرفته است. هرچند این نمودارها به-

ازای تصویر خاصی ترسیم شده‌اند، اما هیستوگرام LBP برای نواحی متناظر در سایر تصاویر از همین

الگوی کلی پیروی می‌کند.




(ب)



(ج)



(الف)



(د)

شکل (۴-۹) هیستوگرام مقادیر LBP مربوط به سه بافت اصلی مغز: (الف) تصویر نمونه، (ب) هیستوگرام بافت CSF، (ج) هیستوگرام بافت سفید، (د) هیستوگرام بافت خاکستری

۴-۸- کلاس بندی

پس از محاسبه بردار ۱۶ تایی (یا ۲۵۶ تایی) هیستوگرام برای هر ناحیه بدست آمده از مرحله انتشار شایعه، بردار ویژگی از ترکیب سطح خاکستری هر پیکسل و هیستوگرام ناحیه، ساخته شده و

به همراه برچسب آموزشی به کلاسیفایر تزریق می‌شود. تعداد نمونه‌های آموزشی با فرض در دسترس نبودن برچسب همه داده‌ها محدود در نظر گرفته می‌شود.

برای استفاده از تکنیک نیمه‌نظارتی، مجموعه دوم داده‌های آموزشی بدون برچسب استفاده خواهد شد. شیوه خاص آموزشی که برای پیاده‌سازی انتخاب شد، شیوه نیمه‌نظارتی خودآموزی است. لذا کلاسیفایر از برچسبی که خود به داده‌ها تخصیص می‌دهد برای گسترش مجموعه آموزشی استفاده خواهد کرد.

برای یک نمونه داده کافیسیت تا با احتمال مشخصی درست کلاس‌بندی شود تا به عنوان داده-آموزشی به سیستم افزوده شود. آستانه اطمینان را معمولاً به‌سادگی $1/2$ در نظر می‌گیرند. به این ترتیب چنانچه داده با چگالی احتمال شرطی بیش از $1/2$ به کلاس خاصی نزدیک باشد، متعلق به کلاس اعلام می‌شود. در صورت بروز تصادم بین مقادیر، احتمال ماکزیمم به عنوان کلاس نهایی داده انتخاب می‌شود. داده‌هایی که با اطمینان کلاس‌بندی نشوند از دور خارج می‌شوند.

۴-۹- شبه‌کد روش پیشنهادی

در مرحله اول تصویر توسط متد شایعه برای استخراج ویژگی‌ها بخش‌بندی خواهد شد. در این مرحله انتخاب هر هسته برای گسترش ناحیه به وضعیت قبلی آن بستگی دارد. چنانچه اطراف هسته ناحیه همگنی شکل گرفته باشد احتمال انتخاب آن اندک خواهد بود. در روال *Gossip_Partition*، *seed* پیکسلی است که در حال حاضر ناحیه را گسترش می‌دهد و *Centre* هسته مرکزی ناحیه است. مقادیر آستانه تعیین‌شده رشد ناحیه را کنترل می‌کنند. برای نمایش نوده‌های همسایه که از آخرین برچسب مطلع هستند از نماد *Infected* (مبتلا) و برای نودهایی که هنوز برچسب را دریافت نکرده‌اند از نماد *Susceptible* (مستعد پذیرش) استفاده می‌کنیم. روال *Gossip_Partition* یک روال بازگشتی است و مجدداً توسط پیکسل‌های جدید ناحیه فراخوانی می‌شود. پس از اینکه بخش‌بندی تصویر به پایان رسید چنانچه هنوز نودی مانده باشد که برچسب نخورده، برچسب نزدیکترین همسایه-

اش را دریافت می‌کند. مجدداً تاکید می‌شود که هدف از مرحله بخش‌بندی ناحیه‌بندی تصویر نبوده و هدف تعیین نواحی مناسب برای استخراج ویژگی‌های فضایی به‌ازای هر پیکسل است. پس از مرحله بخش‌بندی و استخراج ویژگی، آخرین روال آموزش و تست کلاسیفایر جنگل تصادفی برای ناحیه‌بندی نهایی تصویر است.

- مرحله اول بخش‌بندی

مقادیر ماکزیمم اختلاف (Th) و اختلاف از مرکز ($Centre_Th$) را مقداردهی اولیه کن.

برای $10 \times size(Image)$ تکرار کن

۱- یک هسته تصادفی انتخاب کن ($seed = rand(x, y)$)

۲- یک مقدار تصادفی تولید کن ($rand = new(rand)$)

۳- اگر $prob(seed) < rand$ مجدداً از ۲ شروع کن // هسته‌ای که قبلاً انتخاب شده

۴- $Centre = seed$

۵- روال $Gossip_Partition(seed, Centre, Th, Centre_Th)$ را فراخوانی کن

پایان حلقه

۶- اگر $\exists x, y \rightarrow Infected(Image(x, y) = 0)$ آن‌گاه

$label(x, y) = label(nearest_neighbor(x, y))$ (برای نودهایی که در انتهای کار

برچسب نخورده‌اند)

روال $Gossip_Partition(seed, Centre, Th, Centre_Th)$

۱- $Num_infected = 0$

۲- اگر $selected(seed) = 1$ آنگاه

۱-۲- $label(seed) = prev_label(seed)$

۲-۲- وگرنه $label(seed) = new_label(seed)$ و $selected(seed) = 1$

برای $\forall N_g \in neighbor(seed)$ تکرار کن

۳- اگر $distance(Ng, Centre) < Centre_Th$ و $distance(Ng, seed) < Th$

۳-۱- اگر $Susceptible(Ng) = 1$ آنگاه

۳-۱-۱- $label(N_g) = label(seed)$ و $Susceptible(N_g) = 0$

$Infected(N_g) = 1$

۳-۱-۲- $Gossip_Partition(N_g, seed, Th, Centre_Th)$ را فراخوانی کن

۳-۲- وگرنه $Num_infected = Num_infected + 1$

پایان حلقه (N_g)

۴- $prob(seed) = (Num_infected - |neighbor(seed)|) / Num_infected$

۵- بازگشت به روال اصلی

- مرحله دوم استخراج ویژگی

روال $Feature_Extraction$

برای $i=1$ تا $\#(different_labels)$ تکرار کن // (به تعداد نواحی که تولید شد)

۱- $current_label = i$

۲- $region(current_label) = \emptyset$

برای هر پیکسل x, y تصویر تکرار کن

۳- $region(current_label) = region(current_label) + (x, y)$

بشرطی که $label(x, y) = current_label$

پایان (x, y)

پایان حلقه i

برای هر پیکسل x, y تصویر تکرار کن

$$feature_vector(x, y) = Image(x, y) + LBP_histogram(region) \rightarrow region \supseteq (x, y) \quad -f$$

مرحله نهایی کلاس‌بندی و انتساب برچسب به پیکسل‌ها توسط جنگل تصادفی

روال این قسمت قبلاً توضیح داده شده است.

فصل پنجم

بررسی نتایج

۵-۱- مقدمه

پس از معرفی متد پیشنهادی در فصل چهارم، نهایتاً در این فصل به بررسی نتایج بدست آمده از پیاده سازی الگوریتم و مقایسه آن با نتایج بدست آمده از پیاده سازی متد MRF خواهیم پرداخت. قسمتی از این فصل نیز به بررسی میزان افزایش کارایی با استفاده از روش محلی پیشنهادی اختصاص دارد.

الگوریتم پیشنهادی ما در دو قسمت ناحیه بندی محدود با استفاده از ویژگی های محلی ساده و ناحیه بندی گسترش یافته با استفاده از ویژگی LBP بررسی خواهد شد. پس از آن در ادامه فصل نتایج حاصل از آموزش کلاسیفایر با تکنیک نیمه نظارتی خودآموزی، ارائه شده و به بررسی میزان کارایی تکنیک از طریق مقایسه نتایج با کلاسیفایر نظارتی خواهیم پرداخت. مقایسه بین نتایج بدست آمده از روش ما با نتایج ناحیه بندی متد MRF بخش دیگری از این فصل خواهد بود.

الگوریتم های مورد استفاده با استفاده از Matlab نسخه R2009a روی سیستم اینتل با پردازنده ۲.۵۳ Ghz و حافظه ۴ گیگابایت پیاده سازی و بررسی شده است.

۵-۲- دیتابیس تصاویر

به منظور ارائه نتایج معتبر و قابل مقایسه و ارزیابی با سایر روش های پیشنهادی، ما در این پایان نامه تصاویر مورد استفاده خود را از مرجع استاندارد IBSR تهیه کرده ایم که معتبرترین مرجع تصاویر MRI مغزی در تحقیقات مرتبط به شمار می رود [۱۸].

این دیتابیس حاوی تصاویر شبیه سازی شده T1 و T2 با تومور (اندازه ها و اشکال متغیر) و بدون تومور با درصد ناهمگنی مشخص نیز می باشد که بدلیل موجود نبودن نمونه استاندارد ناحیه بندی شده آن ها، در تحقیق ما قابل استفاده نبود.

اولین مجموعه تصویر مورد استفاده، مجموعه 20_Normals_T1_weighted است که حاوی

تصاویر T1-weighted واقعی از اسکن مغزی ۲۰ فرد بزرگسال با مغز سالم و متقارن است. از هر نفر در این مجموعه حدود ۴۰ برش مغزی وجود دارد که مجموعاً این قسمت از دیتابیس حاوی بیش از ۸۰۰ تصویر T1 از MRI مغز با ضخامت حدود ۳.۱ میلی متر می‌باشد. تمامی تصاویر این مجموعه توسط متخصص رادیولوژی به صورت دستی ناحیه‌بندی شده‌اند که معیار سنجش و ارزیابی دقت الگوریتم ما (GT)^۱ محسوب می‌شود.

مجموعه دوم تصاویر اسکن مغزی T1-weighted از ۴۳ فرد سالم است بطوری که از هر فرد ۱۸ اسکن مختلف وجود دارد. ضخامت این تصاویر حدود ۱.۵ میلی متر است. نمونه ناحیه‌بندی شده نیز موجود است.

مجموعه سوم و چهارم مورد استفاده تصاویر واقعی از تومور مغزی در ۲ بیمار و نمایش رشد تدریجی توده تومور در طول ۱۰ سال است. کل تصاویر این دو مجموعه حدود ۳۰۰ تاست که از این تعداد حدود ۵۰ تصویر حاوی تومور هستند. لازم بذکر است که تعداد کلاس‌ها با محاسبه پس‌زمینه در تصاویر ناحیه‌بندی شده از مغز افراد سالم ۴ تا و در مغز افراد بیمار ۵ تا (شامل تومور) می‌باشد. در تصاویر این دو مجموعه تنها مرز تومور از بافت عادی علامت‌گذاری شده است؛ لذا مرجع استاندارد برای مشخص‌سازی محدوده سایر بافت‌ها از یکدیگر فراهم نشده است.

جدول (۵-۱): تفصیل مشخصات مجموعه تصاویر مورد استفاده در ناحیه‌بندی

نام مجموعه	نوع تصاویر	تعداد نمونه	تعداد بافت-های مغزی	پارامترهای تصویر برداری
20_Normals_T1_weighted	T1-weighted 3D Coronal	20	3	1.5 tesla Simens, General TR = 40,50 msec TE = 8, 9 msec In plane = 1.0 mm Slice Ths. = 3.1 mm
788_6.img	T1-weighted Coronal Axial	43	3	1.5 Tesla General Slice Ths. = 3.0 mm Matrix = 256x256

¹ Ground Truth

ادامه جدول (۱-۵): تفصیل مشخصات مجموعه تصاویر مورد استفاده در ناحیه‌بندی

126_1.img	T1-weighted Coronal Axial (Gadolinium)	1	4	1.5 Tesla General In Plane= 0.93 mm Slice Ths.= 3.0 mm Matrix = 256x256
536_32.img	T1-weighted Axial (Gadolinium)	1	4	1.5 Tesla General In Plane= 1.01 mm Slice Ths.= 1.80 mm Matrix = 256x256


در تصاویر مجموعه اول و دوم مجموعه از تصویر حذف شده‌است و نیازی به پردازش اضافی وجود ندارد. در مجموعه سوم بافت مجموعه مغز را احاطه کرده است که برای جلوگیری از بروز خطا به روش watershed (حوضچه) و توسط نرم‌افزار متلب پیش از ناحیه‌بندی حذف می‌شود. از آن جا که استخوان مجموعه نسبت به بافت اطراف خود بسیار روشن‌تر است و یک لبه قوی را تشکیل می‌دهد، به‌راحتی توسط الگوریتم حوضچه که تقریباً یک الگوریتم لبه‌یاب محسوب می‌شود، شناسایی و سپس حذف خواهد شد.

هریک از مجموعه تصاویر فوق توسط دستگاه‌های مختلف و با تنظیمات متفاوتی ثبت شده‌اند لذا محدوده سطح روشنایی به‌ازای هریک از بافت‌ها در تصاویر دستگاه‌های مختلف بایکدیگر تا اندازه‌ای متفاوت است. در ضمن سایز یک تصویر در تمامی مجموعه تصاویر نام برده شده برابر 256×256 است که برای جلوگیری از محاسبات اضافی، قسمت اعظم پس‌زمینه این تصاویر حذف شده و تصاویر با اندازه 150×150 ذخیره می‌شوند.

۵-۳- ناحیه‌بندی با استفاده از ویژگی سطح خاکستری

در مرحله اول ناحیه‌بندی ویژگی مورد استفاده سطح خاکستری ساده و بردار ویژگی تک‌بعدی است. لذا چون ویژگی‌های دیگری وجود ندارد تا ترکیب مناسبی از آن‌ها تولید شود، جنگل تصادفی ناحیه‌بندی تصاویر را با آستانه‌گذاری چندگانه (۴ محدوده به‌ازای هریک از بافت‌ها و پس‌زمینه) انجام

می‌دهد. آموزش سیستم نیز با مقادیر خاکستری تصاویر آموزشی انجام می‌گیرد و جنگل نیز بعداً تصاویری که با این مقادیر سازگار باشند را شناسایی می‌کند. نتیجه ناحیه‌بندی به این صورت کاملاً به اندازه مقادیر و میزان ناهمگنی در سطح تصویر و نیز میزان درهم آمیختگی مقادیر بافت‌های مختلف وابسته است. شکل (۵-۱) نمونه‌ای از این نتایج را نشان می‌دهد.



شکل (۵-۱): ناحیه‌بندی با مقادیر خاکستری

توجه به پاسخ‌بدست‌آمده مشخص می‌سازد که ویژگی سطح خاکستری به‌تنهایی برای کلاس-بندی تاچه حد قابل‌اطمینان است.

۵-۴ - ناحیه‌بندی با بلوک‌بندی ساده

در این مرحله ضمن بررسی اثر بهبود کارایی پس از بلوک‌بندی تصویر، ویژگی‌های فضایی متفاوتی برای بلوک‌ها محاسبه می‌شود. ساده‌ترین بردار ویژگی بلوک، مقدار خاکستری نرمال‌شده و میانگین مقادیر نرمال‌شده برای بلوک‌های 3×3 و 5×5 است.

سپس تاثیر بلوک‌بندی با استفاده از برداری از ویژگی‌های فضایی GLCM بررسی می‌شود. از ماتریس هم‌رخداد تصویر حدود ۳۰ ویژگی GLCM قابل‌محاسبه است [۷۵] که ما از ۲۰ ویژگی متداول‌تر نظیر میانگین، واریانس، انرژی، همبستگی و همگنی استفاده کردیم. پس از بررسی این ویژگی‌ها در ناحیه‌بندی به‌صورت مجزا مشخص شد که تعدادی از آن‌ها برای ناحیه‌بندی به هیچ‌وجه مناسب نیستند. لذا چندین ترکیب مناسب از این ویژگی‌ها را شناسایی و در ناحیه‌بندی استفاده کردیم.

برای انتخاب ترکیبات مناسب از ویژگی‌های GLCM در ناحیه‌بندی از الگوریتم ژنتیک برای تولید ترکیبات متفاوت و ارزیابی آن‌ها استفاده شد. ارزیابی هر بردار ویژگی یا کروموزوم با تابع برازندگی که در [۷۹] پیشنهاد شده است مطابق رابطه (۵-۱) انجام می‌گیرد.

$$Fitness(Chromosome) = Accuracy \times 4^{10} + 0.4 \times zeros \quad (1-5)$$

که در رابطه بالا Accuracy دقت بدست‌آمده از کلاسیفایر با استفاده از یک رشته کروموزوم و zeros تعداد صفرها در کروموزوم یا تعداد ویژگی‌های انتخاب‌نشده از مجموع ۲۰ ویژگی GLCM موجود است. با نسبت‌دادن ضریب بالایی همانند 4^{10} به متغیر Accuracy اولویت در انتخاب یک رشته ویژگی با میزان دقتی است که در ناحیه‌بندی با استفاده از این رشته ویژگی حاصل می‌شود. حال هرچه تعداد متغیرهای بکار رفته در رشته کمتر باشد، یعنی قدرت متغیر انتخابی بالاتر بوده است. لذا با نسبت‌دادن امتیاز پایین به طول رشته (ضریب ۰.۴) متغیرهای GLCM مناسب برای ناحیه‌بندی را از لحاظ قدرت شناسایی می‌کنیم.

پس از بررسی محاسبه میزان کارایی ترکیبات مختلف، بهترین ترکیب ویژگی‌ها برای ناحیه‌بندی استفاده شد. این ویژگی‌ها پس از بلوک‌بندی تصویر با بلوک‌های 3×3 برای هر پیکسل محاسبه می‌شود. مناسب‌ترین رشته ترکیبات بدست‌آمده با استفاده از الگوریتم ژنتیک و رابطه (۵-۱) در پیوست پایان‌نامه ارائه شده است.

دقت حاصل از ناحیه‌بندی به روش متداول بلوک بندی روی تصاویر مجموعه 20_Normals_T1_weighted با استفاده از ضریب Dice [۸۰] و انطباق پیکسل به پیکسل تصویر نتیجه‌شده از ناحیه‌بندی با تصویر ناحیه‌بندی شده مرجع در جدول (۵-۲) نمایش داده شده است. دقت شناسایی بدست‌آمده توسط این ویژگی‌ها هنوز نسبت به دقت حدود ۹۴٪ متدهایی نظیر MRF بسیار پایین است. اما هدف از این قسمت بررسی میزان بهبود نتایج پس از استفاده از ویژگی‌های فضایی ساده و چگونگی عکس‌العمل جنگل تصادفی به این ویژگی است. چنانچه یک کلاسیفایر قوی به


استفاده از ویژگی‌های فضایی پاسخ مثبتی نشان ندهد، برای استفاده در ناحیه‌بندی مناسب نیست. لذا یک کلاسیفایر خوب لزوماً یک ناحیه‌بند قوی نخواهد بود.

جدول ۲-۵ میزان خطای ناحیه‌بندی با روش‌های ساده استخراج ویژگی

نوع بافت	CSF (مایع مغزی و نخاعی)	GM (ماده خاکستری)	WM (ماده سفید)	میانگین خطا
نحوه استخراج ویژگی	خطای ناحیه‌بندی به تفکیک بافت با استفاده از معیار ضریب Dice			
مقادیر خاکستری خام	0.999052	0.033688	0.590214	0.5409846
بلوک بندی ساده با بلوک‌های 3x3 (میانگین و مقدار خاکستری نرمال- شده)	0.871924	0.173477	0.450675	0.498692
بلوک بندی ساده با بلوک‌های 3x3 و بردار ویژگی GLCM (با استفاده از تمام ویژگی‌ها)	0.852831	0.179225	0.367504	0.473186

همانطور که مشاهده می‌شود، پس از بلوک‌بندی خطای تشخیص بافت خاکستری افزایش یافته- است. این مساله به این دلیل است که با استفاده از مقادیر خام، تقریباً تمام تصویر یا قسمت بیشتر آن به عنوان بافت خاکستری شناسایی می‌شود. لذا احتمال اینکه پیکسلی متعلق به این بافت غلط شناسایی شود بسیار پایین است. اما کارآمدی بلوک‌بندی و ویژگی‌های فضایی باتوجه به بهبود قابل توجه در شناسایی بافت سفید و مایع مغزی (CSF)، و نهایتاً بهبود شناسایی کلی بافت مغز مشخص می‌شود.

یک نمونه از این نتایج در شکل زیر ملاحظه می‌شود.



شکل (۵-۲) بهبود نتیجه ناحیه‌بندی روی بافت CSF پس از بلوک‌بندی (الف) ناحیه‌بندی مطلوب (ب) ناحیه‌بندی با مقادیر خاکستری (ج) ناحیه‌بندی با میانگین نرمال شده بلوک‌های 3×3 ، بافت سفید چندان تغییری نکرده است.

درصد شناسایی بافت مغز توسط ویژگی‌های GLCM (میانگین، واریانس و مجموع مربعات) با درصد شناسایی آن‌ها توسط ویژگی میانگین یا مد ساده بلوک تقریباً برابر است. اختلاف نسبتاً ناچیز بین مقادیر ناشی از سادگی بیش از حد روابط فضایی در میانگین بلوک و در نظر نگرفتن وضعیت روشنایی پیکسل‌های مجاور نسبت به یکدیگر است.

در این جدول خطای ناحیه‌بندی با استفاده از ۲۰ ویژگی GLCM اعلام شده است. برای بدست آوردن ترکیب مناسب GLCM برای ناحیه‌بندی همانطور که اشاره شد از الگوریتم ژنتیک استفاده شد. بر این اساس ترکیب ویژگی‌های مجموع میانگین، مجموع واریانس، مجموع مربعات و مجموع آنتروپی می‌تواند دقت ناحیه‌بندی را به ۰.۸۸ ارتقا دهند. ترکیب مناسب دیگر، برداری متشکل از سه ویژگی مجموع میانگین، مجموع واریانس و مجموع مربعات است که دقتی برابر ۰.۸۷ درصد دارد. ۲۰ ویژگی GLCM استخراج شده و همچنین نحوه محاسبه این ویژگی‌ها در پیوست پایان‌نامه ذکر شده است.

۵-۵- استخراج ویژگی با اعمال متد انتشار روی تصویر به صورت محدود شده

در دومین مرحله برای مقایسه میزان افزایش کارایی ناحیه‌بندی با بکارگیری متد پیش‌ناحیه‌بندی (بخش‌بندی) مبتنی بر انتشار شایعه، از آن به صورت محدود شده استفاده می‌شود. مقدار

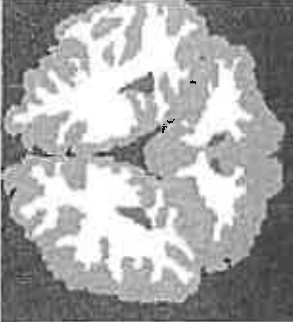
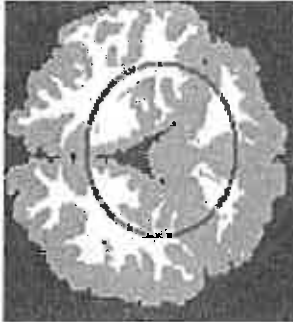


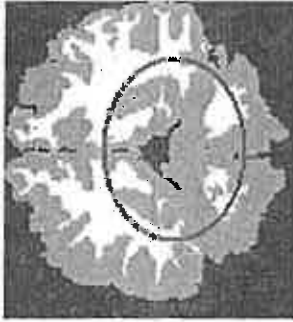
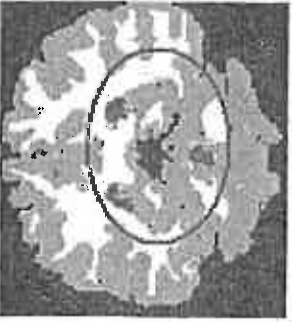

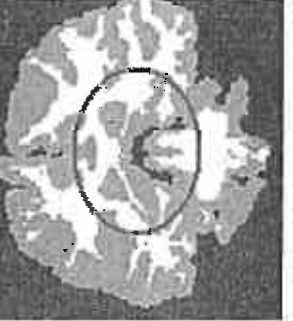

خاکستری هر پیکسل درون ناحیه بدست آمده توسط میانگین و واریانس ناحیه نرمال می شود. بردار ویژگی برای هر پیکسل متشکل از عناصر ساده مقدار خاکستری نرمال شده، مد مقادیر نرمال شده ناحیه و کمترین و بیشترین عنصر درون ناحیه است. حد آستانه تغییرات در این مرحله کوچک نگه داشته می شود (۵-۷ واحد) تا با توجه به حساسیت نوع ویژگی به تغییرات روشنایی، مقادیر آماری بدست آمده دستکاری نشوند. جدول (۳-۵) دقت ناحیه بندی را روی ۹ تصویر نمونه به تفکیک بافت ناحیه بندی شده با استفاده از ضریب Dice نشان می دهد.

جدول (۳-۵): نمودار نتایج دقت ناحیه بندی به تفکیک بافت با استفاده از معیار ارزیابی ضریب Dice (درصد شناسایی صحیح)


شماره تصویر IBSR	مقدار خاکستری				بلوک های 3x3				روش انتشار شایعه محدود			
	ضریب Dice											
	GM	WM	CSF	میانگین	GM	WM	CSF	میانگین	GM	WM	CSF	میانگین
1_24_3.png	0.94	0.89	0.23	0.68	0.87	0.71	0.46	0.67	0.85	0.79	0.72	0.79
1_24_10.png	0.97	0.30	0.17	0.48	0.92	0.73	0.50	0.71	0.93	0.81	0.68	0.80
1_24_15.png	0.95	0.71	0.26	0.64	0.89	0.84	0.47	0.73	0.92	0.88	0.75	0.84
2_4_3.png	0.93	0.65	0.25	0.61	0.80	0.75	0.47	0.67	0.84	0.87	0.73	0.81
2_4_10.png	0.91	0.85	0.36	0.70	0.86	0.76	0.55	0.72	0.86	0.89	0.77	0.82
2_4_15.png	0.90	0.88	0.37	0.70	0.81	0.80	0.46	0.70	0.85	0.87	0.66	0.78
4_8_7.png	0.93	0.67	0.40	0.66	0.87	0.78	0.51	0.72	0.91	0.89	0.69	0.83
4_8_10.png	0.92	0.36	0.40	0.56	0.84	0.79	0.49	0.70	0.89	0.86	0.79	0.83
4_8_15.png	0.94	0.66	0.30	0.63	0.86	0.84	0.47	0.72	0.90	0.91	0.79	0.86
میانگین	0.93	0.65	0.30	0.62	0.86	0.78	0.49	0.71	0.88	0.85	0.73	0.82

نمونه ای از نتایج بدست آمده به صورت تصویری در جدول (۴-۵) نمایش داده شده است.

جدول (۴-۵): مقایسه نتایج حاصل از ناحیه‌بندی با مقادیر خاکستری و انتشار شایعه (محدود)

ناحیه‌بندی مطلوب	سطح خاکستری	انتشار شایعه محدود
		
		
		


همانطور که از نتایج مشخص می‌شود، پس از اعمال مرحله پیش‌ناحیه‌بندی، بافت CSF توسط جنگل حداقل تا ۵۰٪ شناسایی می‌شود. در تصاویر بالا خطای ناحیه‌بندی روی بافت سفید اندکی افزایش یافته است که در صورت استفاده از ویژگی‌های فضایی پیچیده‌تر این موارد اصلاح خواهد شد. البته میانگین شناسایی بافت سفید در مجموع افزایش می‌یابد. عمده این افزایش مربوط به تصاویری است که بافت سفید در آن‌ها اصلاً شناسایی نمی‌شود و یا خیلی کم تشخیص داده می‌شود. نمونه‌ای از چنین تصاویری در شکل (۳-۵) آورده شده است.



شکل (۳-۵): مقایسه نتیجه حاصل از ناحیه‌بندی: (الف) تصویر اولیه، (ب) ناحیه‌بندی مطلوب، (ج) با مقادیر خاکستری، (د) بلوک بندی، (ه) انتشارشایعه

۵-۶- نتایج نهایی با استفاده از مرحله پیش‌ناحیه‌بندی گسترش یافته

در آخرین مرحله ناحیه‌بندی با استفاده از ویژگی الگوی باینری و پیش‌ناحیه‌بندی (بخش بندی) گسترش یافته انجام می‌شود. نتایج حاصل از بخش بندی گسترش یافته روی یک تصویر نمونه در شکل (۴-۵) نمایش داده شده است. همانطور که مشاهده می‌شود هیچ یک از نواحی از مرز نواحی اصلی عبور نمی‌کنند.



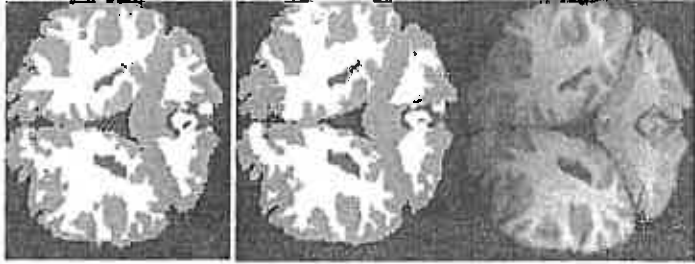
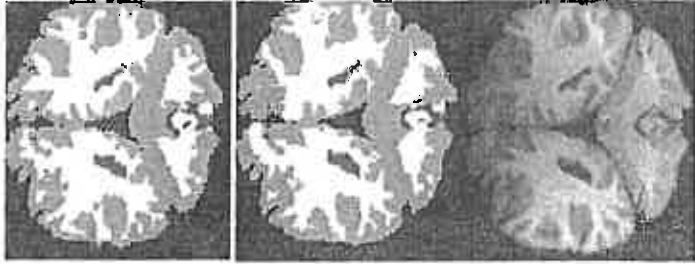
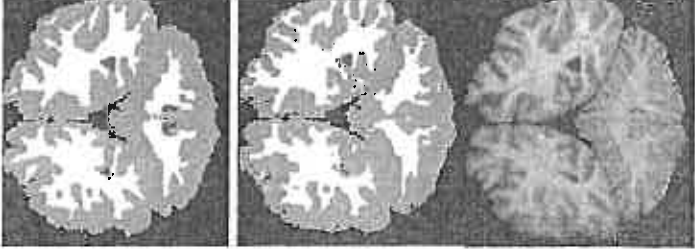
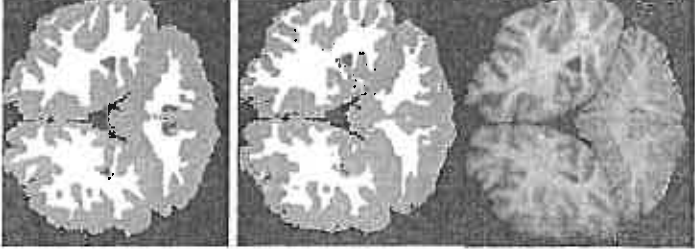
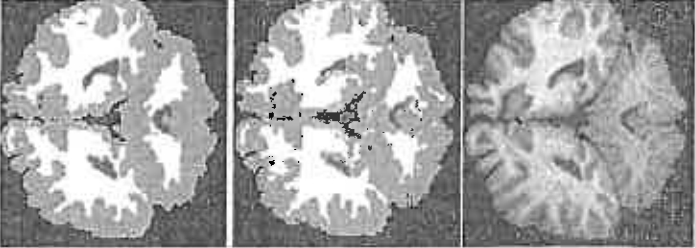
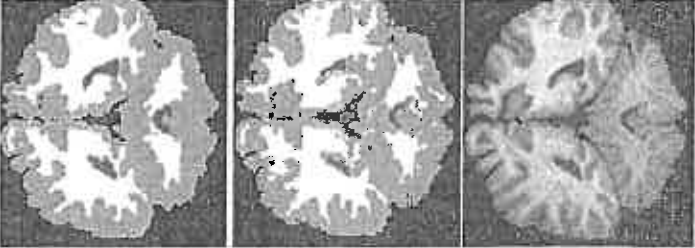
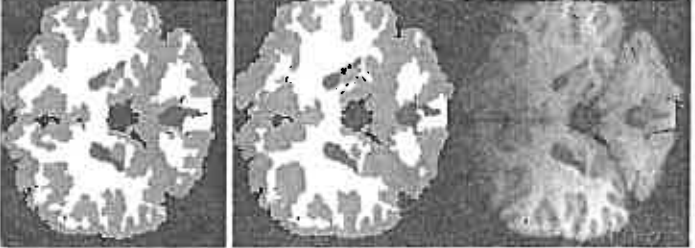
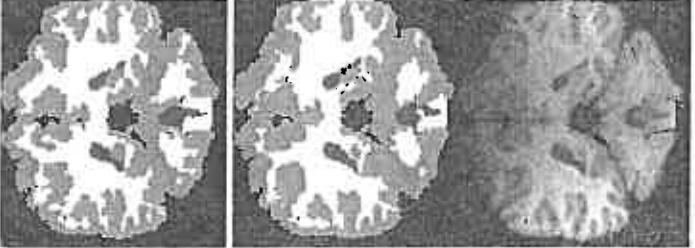
(الف) (ب)

شکل (۴-۵): بخش بندی اولیه تصویر: (الف) تصویر اصلی، (ب) تصویر بخش بندی شده



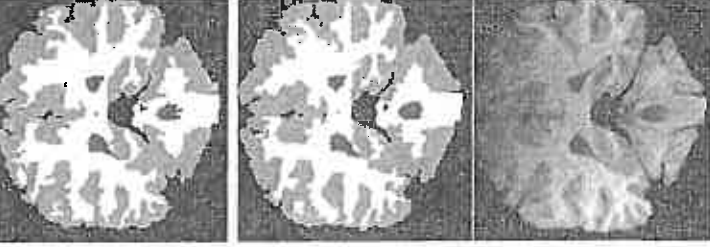
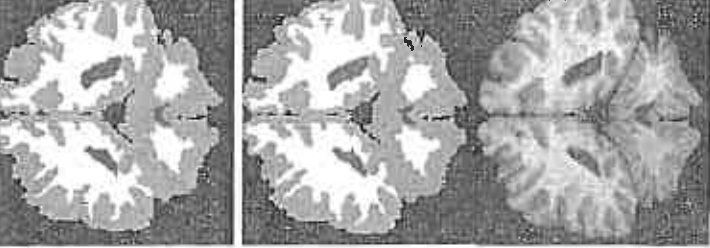
برای اینکه هیستوگرام LBP روی ناحیه معنی دار باشد، ناحیه باید رشد یافته تر باشد لذا اندازه آستانه در این زمان بزرگتر در نظر گرفته می‌شود و به پیکس‌های مجاور هسته نیز اجازه گسترش ناحیه داده می‌شود. برای جلوگیری از رشد بی‌رویه ناحیه از آستانه دوم نیز برای حفظ فاصله با مقدار هسته استفاده می‌شود. جدول (۵-۵) بهترین نتایج بدست آمده توسط این الگوریتم را نمایش می‌دهد.

همانطور که مشاهده می‌شود پارگی و لکه‌هایی که در بلوک‌بندی روی تصویر بوجود می‌آید، در این نتایج وجود ندارد. ضمن این‌که بافت CSF حداقل تا ۸۵٪ شناسایی می‌شود. میزان حفظ جزئیات تصویر تا اندازه‌ای به آستانه مورد استفاده در بخش‌بندی وابسته است.

جدول (۵-۵): نتایج حاصل از ناحیه‌بندی توسط متد انتشار شایعه (گسترش یافته با استفاده از LBP)


شماره تصویر IBSR	ناحیه‌بندی مطلوب	نتیجه ناحیه‌بندی	متوسط خطا
1_24_3.png			0.03
1_24_10.png			0.09
1_24_15.png			0.05
2_4_10.png			0.03

ادامه جدول (۵-۵): نتایج حاصل از ناحیه‌بندی توسط متد انتشار شایعه (گسترش یافته با استفاده از LBP)

2_4_15.img		0.03
4_8_10.img		0.02
2_4_3.img		0.01
4_8_15.img		0.01
میانگین		0.03


تصویر زیر مقایسه‌ای بین کیفیت تصویر بدست آمده از استخراج ویژگی با انتشار محدود و

استخراج ویژگی با انتشار گسترش یافته را نشان می‌دهد.



شکل (۵-۵): مقایسه نتیجه حاصل از ناحیه‌بندی:الف) تصویر اولیه ب) تصویر ناحیه‌بندی مرجع ج) انتشار شایعه محدود، د) انتشار شایعه گسترش یافته

دقت ناحیه‌بندی دو تصویر در بافت سفید تقریباً یکسان است بجز در قسمتی که با دایره قرمز مشخص شده است. این قسمت در تصویر اصلی کمی تیره‌تر از بافت سفید مرکز تصویر است. این تفاوت مقداری احتمالاً بدلیل اثر بایاس فیلد است اما بهر حال روش دوم که از ویژگی مقاوم به تغییرات روشنایی استفاده می‌کند این قسمت را بهتر شناسایی کرده است. اما با مقایسه نتیجه بدست آمده از روش انتشار شایعه محدود با نتیجه بدست آمده از ناحیه‌بندی با سطح خاکستری که در شکل (۶-۵) نشان داده شده است، می‌توان نتیجه گرفت که بهر حال این متد نیز می‌تواند تا اندازه‌ای در برابر تغییرات روشنایی کارایی خود را حفظ کند.



شکل (۶-۵) مقایسه نتیجه ناحیه‌بندی توسط الف) مقدار خاکستری، ب) انتشار شایعه محدود

میزان دقت ناحیه‌بندی با استفاده از ضریب Dice روی کلیه بافت‌ها در جدول (۶-۵) تشریح

شده است.

جدول (۵-۶): مقایسه نتیجه حاصل از ناحیه‌بندی به تفکیک بافت روی روش استفاده شده


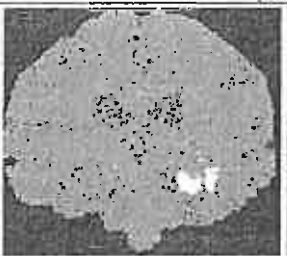
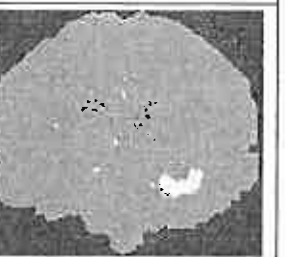

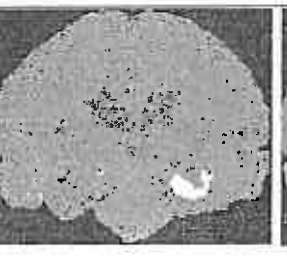


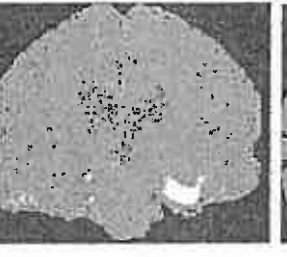
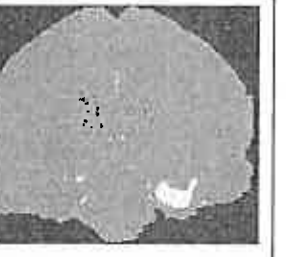


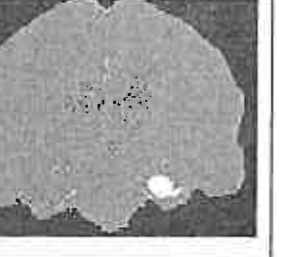


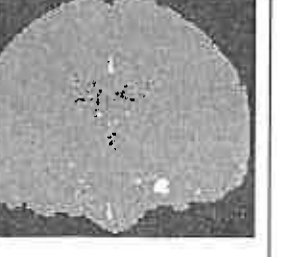
نوع بافت	CSF	GM	WM	میانگین
نوع روش استخراج ویژگی	خطای ناحیه‌بندی به تفکیک بافت با استفاده از معیار ضریب Dice			
مقادیر خاکستری	0.999052	0.033688	0.590214	0.590984
بلوک بندی	0.887924	0.173477	0.450675	0.50402
انتشار شایعه محدود (ضریب آستانه ۷)	0.310460	0.193481	0.157966	0.220635
انتشار شایعه گسترش یافته (ضریب آستانه ۷؛ فاصله از مرکز ۱۰)	0.10077	0.086759	0.072958	0.0866313
انتشار شایعه گسترش یافته (ضریب آستانه ۵؛ فاصله از مرکز ۷)	0.113795	0.0821455	0.0732744	0.0894383

۵-۷- ناحیه‌بندی تومور

بافت مغزی در تصاویر توموردار موجود در IBSR به‌طور کامل ناحیه‌بندی نشده و تنها مرز تومور از بافت سالم تعیین شده‌است. به‌دلیل موجود نبودن مرجع استاندارد برای تفکیک سایر بافت‌ها از یکدیگر، ناحیه‌بندی در این قسمت تبدیل به یک مساله سه‌کلاسی شامل پس‌زمینه، بافت تومور و بافت غیر تومور می‌شود. تومور در تصاویر T1 مغزی، یک ناحیه بسیار روشن است که از لحاظ سطح روشنایی تفاوت زیادی با سایر بافت‌ها دارد. تزریق ماده گادولینیوم که بیش از تصویربرداری داخل رگ‌ها تزریق می‌شود نیز کنتراست این بافت را در تصاویر T1 نسبت به اطراف خود بالا می‌برد. لذا ناحیه‌بندی تومور به اندازه تفکیک سه بافت عادی مغز پیچیده نبوده و دقت آن بسیار بالاتر است. به‌طوری که ویژگی میانگین ناحیه برخلاف تفکیک سه بافت اصلی مغز، در این مورد نتایج رضایت‌بخشی را تولید می‌کند. متدی که قادر باشد بافت مغز را به‌خوبی تفکیک کند حتما در این مورد نتایج دقیقتری را ارائه خواهد داد. جدول (۵-۷) نتیجه ناحیه‌بندی این بافت را با استفاده از بلوک‌بندی و

روش پیشنهادی ما نشان می‌دهد. بدلیل طولانی بودن قسمتی از نتایج در پیوست نمایش داده شده-
 است. لازم‌به‌ذکر است که قسمتی از خطای شناسایی بدلیل تبدیل مساله به سه کلاسی و اجماع
 بافت‌های متفاوت در یک کلاس است.

جدول (۵-۷): تفکیک تومور از بافت سالم مغز به روش بلوک‌بندی و روش پیشنهادی

شماره تصویر	تصویر اصلی	بلوک بندی	روش پیشنهادی
536_88_25			
536_88_26			
536_88_27			
536_88_29			
536_88_30			

۵-۸- آموزش نیمه نظارتی سیستم

قبلا اشاره شد که الگوریتم جنگل تصادفی برای آموزش به شیوه نیمه نظارتی قابلیت‌های زیادی دارد. مهمترین مساله در آموزش نیمه نظارتی، تصمیم‌گیری درمورد افزودن داده‌های جدید به مجموعه آموزشی است. در اینجا تعیین ضریب اطمینان نقش مهمی در کارآیی سیستم نهایی خواهد داشت زیرا ورود داده‌های نامناسب به مجموعه سبب تشدید خطا روی کلاس‌بندی داده‌های آینده خواهد شد. از آنجا که الگوریتم جنگل تصادفی کلاس‌بندی را به صورت احتمالاتی انجام می‌دهد، می‌توان از احتمال نهایی صحت برچسب داده که جنگل برای کلاس‌بندی داده محاسبه می‌کند به عنوان ضریب اطمینان استفاده کرد. معمولا چنانچه داده با اطمینان بیش از $1/2$ تعیین کلاس شده باشد، به اندازه کافی قابلیت استفاده در آموزش سیستم را داراست. بنابراین پس از مرحله اول آموزش جنگل تصادفی که توسط داده‌های برچسب‌خورده مرجع صورت می‌گیرد، تست سیستم روی داده‌های جدید انجام می‌شود. داده‌هایی که با احتمال کافی ($P < 1/2$) درست کلاس‌بندی شده باشند، به همراه برچسبی که از کلاسیفایر جنگل دریافت کرده‌اند، وارد مجموعه آموزشی می‌شوند. پس از افزودن هر داده جدید یا هرچند داده جدید کلاسیفایر با داده‌های آموزشی مجددا آموزش دیده و مقادیر آستانه کلاس‌بندی در نودها خود را با داده‌های جدید تطبیق می‌دهد و سپس داده‌های جدید را کلاس‌بندی خواهد کرد. برای آموزش سیستم خود به شیوه نیمه نظارتی، ما از روش خودآموزی استفاده کرده و سیستم را در دو مدل انتقالی و استنتاجی پیاده‌سازی نمودیم.

۵-۸-۱- مدل آموزشی انتقالی

در یک سیستم انتقالی داده‌ای از خارج مجموعه وارد سیستم نمی‌شود و سیستم کفایت داده‌های بدون برچسب خود را شناسایی کند. این داده‌ها شباهت زیادی به داده‌های مجموعه آموزشی دارند؛ بنابراین کلاس‌بندی آنها پیچیدگی خاصی ندارد.

برای بررسی میزان افزایش یا کاهش شناسایی با روش نیمه نظارتی، کلاسیفایر کاملا نظارتی را

با مجموعه آموزشی و داده‌های تستی یکسان در تمامی مراحل با کلاسیفایر جدید مقایسه کردیم.

مجموعه آموزشی مورد استفاده در این مرحله تصاویر مجموعه 788_6.img هستند که قسمتی

از آن به عنوان داده آموزشی در مرحله اول کلاسیفایر را آموزش می‌دهد و از قسمت دیگری از آن

برای تست سیستم استفاده می‌شود که در صورتیکه با ضریب اطمینان بیش از ۱/۲ توسط جنگل

کلاس‌بندی شوند، از آن‌ها برای آموزش مجدد جنگل استفاده می‌شود. آموزش مجدد سیستم پس از

تست هر سه تصویر جدید انجام می‌گیرد. با در نظر گرفتن این که سایز تصاویر ۱۵۰x۱۵۰ است، هر سه

تصویر حاوی ۶۷۵۰۰ پیکسل یا داده جدید است. از این تعداد هر داده‌ای که با اطمینان برچسب-

گذاری نشود دور ریخته می‌شود. جدول (۵-۸) نمودار درصد ناحیه‌بندی صحیح (کلاس‌بندی پیکسل-

ها) را پس از آموزش سیستم به شیوه نیمه‌نظارتی انتقالی روی هر سه بافت خاکستری (GM)،

سفید (WM) و مایع مغزی نخاعی (CSF) نشان می‌دهد.

جدول (۵-۸): دقت شناسایی در مدل آموزشی انتقالی (ضریب اطمینان برابر ۱/۲)

شماره مرحله	مجموعه داده		نیمه‌نظارتی			نظارتی		
	تعداد تصاویر آموزشی برچسب خورده	تعداد تصاویر آموزشی فاقد برچسب	نرخ شناسایی GM	نرخ شناسایی WM	نرخ شناسایی CSF	نرخ شناسایی GM	نرخ شناسایی WM	نرخ شناسایی CSF
۱	30	50	0.89	0.83	0.81	0.92	0.89	0.87
۲	20	50	0.87	0.82	0.81	0.88	0.88	0.83
۳	20	60	0.87	0.84	0.81	0.87	0.88	0.83
۴	20	70	0.88	0.85	0.83	0.87	0.86	0.81

نکته جالب در نتایج اینست که با کاهش حجم داده‌های آموزشی اولیه در مرحله ۲، افت نتیجه در سیستم نیمه‌نظارتی به اندازه کلاسیفایر نظارتی نیست. که این به معنای افزایش قدرت تعمیم کلاسیفایر است.

نکته جالب دیگر افزایش دقت کلاسیفایر نیمه‌نظارتی با افزایش حجم داده برچسب‌نخورده و با ثابت نگه‌داشتن مجموعه آموزشی اولیه است. درحالی‌که این کار افت نسبتاً ناچیزی را در کلاسیفایر نظارتی سبب می‌شود. دلیل نتیجه بدست‌آمده این اتفاق ساده است که تعداد داده‌های آموزشی برای سیستم نیمه‌نظارتی افزایش پیدا کرده است و چون داده‌های تستی و آموزشی هر دو متعلق به یک مجموعه داده هستند، افزایش داده‌های آموزشی، درصد شناسایی را بهبود می‌دهد. در این میان قدرت کلاسیفایر نقش تعیین‌کننده‌ای در میزان این افزایش خواهد داشت. از طرفی در سیستم نظارتی به‌طور طبیعی با افزایش تعداد داده‌های تستی چون مجموعه آموزش بیشتری نمی‌بیند، خطای شناسایی رشد پیدا خواهد کرد.

۵-۸-۲- مدل آموزشی استنتاجی

سیستم استنتاجی باید توانایی کلاس‌بندی داده‌هایی نسبتاً متفاوت از مجموعه آموزشی خود را داشته‌باشد. کلاس‌بندی این داده‌ها باید به‌اندازه کافی دقیق باشد تا بتوان این مجموعه جدید را به آموزش سیستم وارد کرد. برای اطمینان از صحت برچسب‌ها می‌توان ضریب اطمینان را حتی‌الامکان به یک نزدیک کرد.

دینابیس IBSR حاوی چندین مجموعه تصویر است که هر یک با دستگاه و پارامترهای متفاوت تصویربرداری ثبت شده‌اند. بنابراین می‌توان از یک مجموعه به عنوان مجموعه آموزشی و از دیگری به عنوان داده جدید استفاده کرد.

پس از کلاس‌بندی هر سه تصویر جدید، داده‌هایی که با احتمال ۷۵٪ یا ۲/۳ درست کلاس‌بندی شوند به مجموعه آموزشی افزوده شده و جنگل دوباره آموزش می‌بیند.

ناگفته نماند این کار خطای کلاس‌بندی را روی برخی نمونه‌های قبلی افزایش می‌دهد اما بطور کلی قابلیت بازشناسی سیستم را بهبود می‌دهد زیرا حجم کلی داده‌هایی که بعداً توسط جنگل شناسایی می‌شوند این خطا را جبران می‌کند. جدول (۹-۵) نمودار نتایج ناحیه‌بندی (کلاس‌بندی پیکسل‌ها) را پس از آموزش سیستم به شیوه نیمه‌نظارتی استنتاجی روی هر سه بافت مغز نشان می‌دهد.

- مجموعه داده آموزشی: 788_6.img

- مجموعه داده جدید: T1_20 Normal

جدول (۹-۵): دقت شناسایی بافت‌ها در مدل آموزشی استنتاجی (ضریب اطمینان ۲/۳)

شماره مرحله	مجموعه داده		نیمه‌نظارتی			نظارتی		
	تعداد تصاویر آموزشی برچسب خورده	تعداد تصاویر آموزشی فاقد برچسب	نرخ شناسایی GM	نرخ شناسایی WM	نرخ شناسایی CSF	نرخ شناسایی GM	نرخ شناسایی WM	نرخ شناسایی CSF
۱	30	50	0.81	0.78	0.74	0.84	0.83	0.79
۲	20	50	0.80	0.78	0.73	0.84	0.82	0.77
۳	20	60	0.82	0.79	0.75	0.82	0.81	0.76
۴	20	70	0.85	0.82	0.77	0.80	0.80	0.76

نکته بسیار جالب‌توجه در این نتایج اینست که نرخ شناسایی روی داده‌های جدید در سیستم


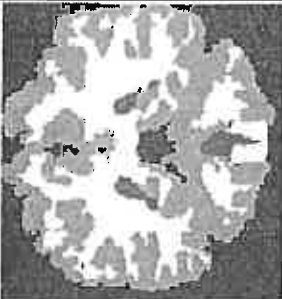
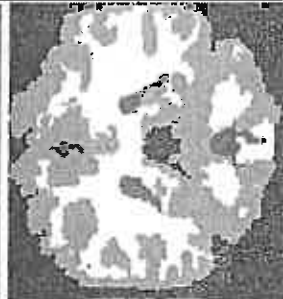





نیمه‌نظارتی با افزایش داده‌های جدید بهبود می‌یابد در حالی که در یک سیستم نظارتی با افزایش

داده‌های تستی جدید نرخ شناسایی معمولاً کاهش می‌یابد. دلیل رشد نرخ شناسایی در سیستم نیمه-نظارتی، ورود داده‌های جدید به مجموعه آموزشی است. این داده‌ها با داده‌هایی که بعداً قرار است توسط سیستم شناسایی شود مشابهت داشته و سیستم به‌مرور این شباهت را تشخیص خواهد داد. درحالی‌که در سیستم نظارتی هیچ داده جدیدی وارد داده‌های آموزشی نشده و سیستم این داده‌ها را فراموش می‌گیرد.



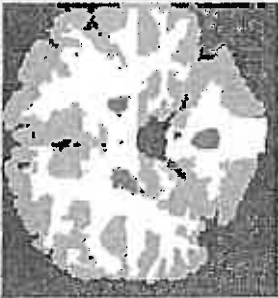

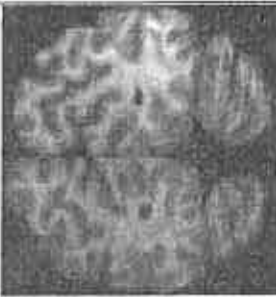
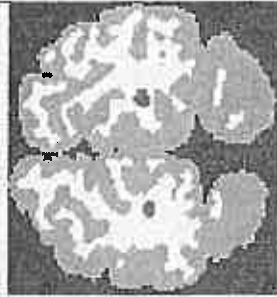



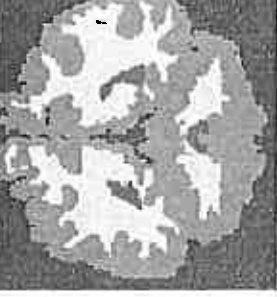






۵-۹- مقایسه نتایج بدست آمده از ناحیه‌بندی با روش پیشنهادی با نتایج متد MRF

در این قسمت با نمایش چند تصویر نمونه به مقایسه نتایج ناحیه‌بندی حاصل از پیاده‌سازی دو متد MRF و روش پیشنهادی خود خواهیم پرداخت. تصاویری که در جدول (۵-۱۰) نمایش داده شده‌اند مطابق با تصاویر جدول (۵-۵) هستند.

جدول (۱۰-۵) مقایسه نتیجه ناحیه‌بندی حاصل از متد MRF و روش پیشنهادی

تصویر اصلی	ناحیه‌بندی مطلوب	ناحیه بندی با روش پیشنهادی	ناحیه‌بندی با متد MRF
			
			

ادامه جدول (۵-۱۰) مقایسه نتیجه ناحیه‌بندی حاصل از متد MRF و روش پیشنهادی


تصویر اصلی	ناحیه‌بندی مطلوب	ناحیه بندی با روش پیشنهادی	ناحیه‌بندی با متد MRF
			
			
			
			

همانطور که مشاهده می‌شود جزئیات تصویر ناحیه‌بندی در تصویر حاصل از متد MRF بسیار بیشتر از تصویر حاصل از متد پیشنهادی ماست. به عنوان مثال بافت‌هایی شبیه رگ‌ها و لایه کورتکس

مغز که در تصاویر ناحیه‌بندی شده مرجع، بدلیل محدودیت دید رادیولوژیست با بافت خاکستری یکپارچه می‌شود، توسط این متد از بافت خاکستری تفکیک می‌شود که مزیت مهمی برای این متد محسوب می‌شود. اما چنانچه ناحیه‌بندی تا این سطح از جزئیات موردنظر نباشد، به‌نظر می‌رسد روش ما علاوه از برخورداری از سرعت بسیار بالا از دقت کافی نیز برخوردار است. از آن‌جا که ناحیه‌بندی تصاویر MRF مستقل از تصاویر مرجع انجام می‌شود، امکان مقایسه نتایج بدست‌آمده از دو متد به صورت درصدی وجود ندارد. اما به‌لحاظ مقایسه از نظر سرعت باید اشاره کرد که آموزش و تست در روش ما برای ۶۰ تصویر ۱۵۰ × ۱۵۰ با بردار ویژگی به طول ۲۵۶ (۵ تصویر آموزشی و باقی تصاویر تستی) و با حضور ۷۰ کلاسیفایر در جنگل مجموعاً به زمانی حدود ۶۰ ثانیه نیاز دارد. در حالیکه هر تصویر برای ناحیه‌بندی توسط متد MRF به حدود ۲۰ ثانیه زمان نیاز دارد. به عبارتی ناحیه‌بندی ۵۵ تصویر به زمانی تقریباً برابر ۱۱۰۰ ثانیه نیاز دارد. بنابراین به‌نظر می‌رسد انتخاب متد باید بر اساس درجه جزئیات موردنیاز در تصویر ناحیه‌بندی شده انجام گیرد و چنانچه ناحیه‌بندی مطابق با تصویر مرجع مطلوب باشد، روش ما به‌لحاظ دقت کافی و سرعت مناسب انتخاب صحیحی است.

۵-۱۰- بهبود شناسایی از طریق استفاده از جنگل تصادفی چندگانه

ما پیشنهاد خود مبنی بر استفاده از یک جنگل تصادفی چندگانه را به‌طور آزمایشی در مساله شناسایی حروف دست‌نویس فارسی نیز بکار بردیم. با استفاده از یک بردار ویژگی با طول ۸۱، مرحله آموزش و تست سیستم جمعاً حدود ۵۰ دقیقه برای مجموعه‌ای شامل ۱۶۵۰ تصویر باینری آموزشی و ۱۱۸۰ تصویر باینری تستی به‌طول می‌انجامد. نمودار زیر میزان بهبود شناسایی حروف دست‌نویس فارسی را از طریق این متد نمایش می‌دهد.



شکل (۵-۷) نمودار بهبود نتایج توسط جنگل تصادفی چندگانه، خطوط منقطع درصد خطا را با جنگل استاندارد و خطوط

پیوسته درصد خطا را با بکار بستن متد چندگانه هم‌زمان با افزایش تعداد درختان جنگل نشان می‌دهد.

این جنگل چندگانه روی ویژگی سطح خاکستری بدلیل تک‌بعدی بودن کارایی ندارد. برای

بردار ۲۵۶ تایی ویژگی هیستوگرام LBP زمان محاسبات یک مشکل اساسی است که با وجود افزایش

دقت بدست‌آمده توجیهی ندارد. زیرا زمان آموزش جنگل برای یک تصویر 150×150 بیش از یک

ساعت به‌طول خواهد انجامید.

۵-۱۱- جمع‌بندی

در ابتدای این فصل برای بررسی بهبود ناحیه‌بندی با استخراج ویژگی از نواحی تعیین‌شده

توسط متد انتشار شایعه بجای روش متداول که از بلوک‌بندی برای استخراج ویژگیها استفاده می‌شود،

نتایج اعمال این روش‌ها روی چندین تصویر نمایش داده‌شده و جداول آن نیز تشریح شد.

پس از ناحیه‌بندی تصاویر، آموزش سیستم را به‌شیوه نیمه‌نظارتی انجام دادیم که این کار

باتوجه به دشواربودن تهیه داده برچسب‌خورده واقعی کاملاً توجیه می‌شود. تنها مساله اساسی در این

بین تعیین کلاسیفایر مناسب و متد آموزشی نیمه‌نظارتی است. با توجه به نتایج بدست‌آمده از این

بخش آموزش صحت انتخاب کلاسیفایر جنگل تصادفی و متد خودآموزی برای این منظور تایید می-

شود.

فصل ششم

نتیجہ گیری و پیشہ اداات

۶-۱- جمع‌بندی

ناحیه‌بندی اتوماتیک تصاویر واقعی از بافت مغزی یک مبحث پیچیده و چالش‌برانگیز است. عمده این چالش مربوط به نحوه برخورد با مسائل مربوط به نویز و ناهمگنی و یا عدم توازن در فراوانی داده‌هاست.

تکنیک‌های ساده استخراج ویژگی برای مرزهای پیچیده با در نظر گرفتن احتمال *partial voluming* (حجم جزئی) و ابهام مرزها کارا نبوده و باید از روش دقیق‌تری برای محاسبه ویژگی‌ها بخصوص در پیکسل‌های مرزی استفاده کرد.

راه‌حل پیشنهادی ما برای رفع این مشکل، پیش‌ناحیه‌بندی تصویر است؛ به نحوی که استخراج ویژگی‌ها برای هر پیکسل از روی همسایگانی متعلق به کلاس بافت خود پیکسل صورت گیرد. به این ترتیب پیکسل‌های نامربوط فرصت دستکاری مقادیر واقعی را کمتر پیدا خواهند کرد. به این منظور یک بخش‌بندی وفقی و ساده مبتنی بر الگوریتم انتشار شایعه پیش از مرحله اصلی روی تصویر اعمال می‌شود. بردارهای ویژگی‌های مورد استفاده کلاسیفایر، از روی نواحی تعیین شده در این مرحله محاسبه می‌شوند. اعمال این مرحله به معنای برچسب‌گذاری تصویر نیست؛ بلکه تنها محدوده مناسب برای استخراج ویژگی برای هر پیکسل با استفاده از پیکسل‌هایی متعلق به بافت خود پیکسل تعیین می‌شود. با اعمال محدودیت‌های مکانی و مقداری، نوعی محدوده همسایگی انعطاف‌پذیر برای هر پیکسل تعریف می‌شود تا از ورود عناصر نامربوط و تاثیر ناهمگنی جلوگیری شود.

میزان گستردگی یک ناحیه بسته به نوع ویژگی است که از روی آن محاسبه می‌شود. برای ویژگی‌های ساده‌تر که در برابر ناهمگنی روشنایی آسیب‌پذیرتر هستند، نواحی کوچکتر ضریب اطمینان بالاتری دارند. درون چنین نواحی تغییرات روشنایی قابل توجه نبوده و می‌توان اثر بایاس فیلد را نادیده گرفت. چنانچه محدودیت‌های گسترش کمتری برای ناحیه در نظر گرفته شود، ویژگی مورد استفاده باید در برابر تغییرات روشنایی یا بروز نویز مقاومت داشته باشد.

لازم به ذکر است که هدف اصلی متد پیشنهادی صرفاً افزایش میزان دقت نهایی نیست بلکه هدف ارائه روشی برای بهبود استخراج ویژگی‌هاست به نحوی که علاوه بر مقاومت در برابر تغییرات ناخواسته روشنایی، بردارهای ویژگی‌ها را در نقاط مبهم مرزی به نحو دقیق تری محاسبه کند.

کلاس‌بندی پیکسل‌ها برای ناحیه‌بندی نهایی با استفاده از الگوریتم جنگل تصادفی انجام می‌شود که تاکنون بصورت بسیار محدود در مساله ناحیه‌بندی تصاویر پزشکی مورد استفاده قرار گرفته است. با این وجود ویژگی‌های خاص الگوریتم جنگل از قبیل سرعت پردازش بالا و توانایی حفظ کارایی با وجود مقادیر مفقوده^۱ در بردار ویژگی، این الگوریتم را به عنوان یک کلاسیفایر قدرتمند برای ناحیه‌بندی تصویر بسیار مناسب ساخته است.

آموزش سیستم ناحیه‌بندی به شیوه نیمه‌نظارتی تمهیدی برای جبران کمبود داده‌های آموزشی برچسب‌گذاری شده است. زیرا در کاربرد پزشکی واقعی ضمانتی برای در دسترس بودن داده آموزشی که به نحو مناسبی برچسب‌گذاری شده باشد، وجود ندارد.

۶-۲- روشها و نتایج

وفق پذیري یک سیستم از جهات مختلفی مورد بحث قرار می‌گیرد. در این پایان‌نامه پیشنهاد شد استخراج ویژگی‌های فضایی با توجه داده تحت ناحیه‌بندی و بدون در نظر گرفتن پیش-فرض‌های متداول صورت‌گیرد. به این ترتیب هر پیکسل همسایگی مخصوص به خود را داشته و ویژگی‌های فضایی مناسب برای آن از روی این همسایگی محاسبه می‌شود.

برای بررسی افزایش کارایی از طریق روش پیشنهادی، استخراج ویژگی‌ها به شیوه متداول بلوک‌بندی تصویر و سپس از طریق پیش‌ناحیه‌بندی با متد انتشار شایعه بصورت محدود و نهایتاً به صورت گسترش یافته انجام گرفت. دقت حدود ۹۲ درصد به‌طور میانگین صحت روش را تأیید می‌کند. دقت‌های مشابه با روش‌هایی همانند MRF نیز گزارش شده است اما ویژگی بسیار مهم این روش

¹ Missing value

سرعت بسیار بالای پردازش درعین دقت بسیار بالا است. سرعت سیستم نهایی در حدود ۱/۱۴ سیستم ناحیه‌بندی مبتنی بر MRF است.

۶-۳- پیشنهادات آینده

۱- اتوماتیک‌سازی تعیین مقدار آستانه

آستانه ناحیه‌بندی (بخش‌بندی) برای مرحله انتشارشایعه در حال حاضر بصورت دستی و با توجه به داده صورت می‌گیرد. به عبارتی آستانه‌ای که از روی داده آموزشی تعیین شده ممکن است برای داده دیگری بهینه نباشد. در این صورت ممکن است برخی نواحی به اندازه کافی رشد نکرده و هیستوگرام مقادیر LBP آن‌ها اطلاعات مفیدی نداشته باشد. در چنین وضعیتی از سطح خاکستری پیکسل که جزئی از بردار ویژگی است نیز کمک گرفته می‌شود. هرچند چنین نواحی در تصویر معدودند اما یک توسعه مناسب روی سیستم فعلی می‌تواند اتوماتیک‌سازی تعیین مقدار آستانه مرحله بخش‌بندی (پیش‌ناحیه‌بندی) باشد.

برای اتوماتیک‌سازی این مرحله پیشنهاد می‌شود در مرحله آموزش با استفاده از بازخوردی که از کلاسیفایر نهایی مورد استفاده (جنگل تصادفی) بدست می‌آید و با محاسبه خطای کلاس‌بندی در هر ناحیه، با توجه به نرخ افزایش یا کاهش خطا نسبت به مرحله قبل، اندازه آستانه با ضریب مشخصی همانند α کم یا زیاد شده و این فرآیند تا زمانی که خطا به حد مطلوب برسد ادامه یابد.

نحوه کار این الگوریتم تقریباً مشابه الگوریتم نزول گرادیان^۱ خواهد بود. چگونگی دستکاری یا اندازه ضریب تغییر آستانه (α) در هر مرحله موضوعی است که نیاز به بررسی بیشتری دارد. با بدست آمدن بهترین آستانه به ازای هر تصویر می‌توان امید داشت که ویژگی‌های فضایی برای هر پیکسل تصویر به بهترین وجه استخراج شده‌اند.


^۱ Gradient descent

۲- استفاده از جنگل تصادفی در ناحیه‌بندی به‌روش کلاسترینگ

قبلا اشاره شد که جنگل تصادفی به‌روش خود اندازه شباهت میان داده‌ها را محاسبه می‌کند و این مقادیر را می‌توان به عنوان یک معیار شباهت در کلاسترینگ داده‌ها استفاده نمود. چنانچه هیچ مجموعه تصویر ناحیه‌بندی‌شده معتبری برای آموزش یک کلاسیفایر موجود نباشد، به‌ناچار ناحیه‌بندی باید به‌روش کلاسترینگ صورت پذیرد. از آن‌جا که محاسبه شباهت بین داده‌ها توسط جنگل سریعتر از محاسبه دوبه‌دو شباهت بین داده‌ها در کلاسترینگ معمولی صورت می‌گیرد، می‌توان با این روش سرعت ناحیه‌بندی مبتنی بر کلاسترینگ را تا حدودی افزایش داد. میزان افزایش یا کاهش دقت ناحیه‌بندی با مقادیر شباهتی که توسط جنگل محاسبه می‌شود، منوط به پیاده‌سازی روش و بررسی نتایج بدست‌آمده است.

۳- بهبود دقت ناحیه‌بندی متد MRF با محاسبه همسایگی به روش انتشار شایعه

محدوده همسایگی در متد MRF برای استخراج ویژگی‌های فضایی هر پیکسل همان بازه همسایگی ۸ تایی متداول (شیوه بلوک‌بندی اطراف پیکسل) است. این راه ورود عناصر بافت‌های متفاوت را به بردار ویژگی پیکسل‌های نزدیک به مرز بافت باز می‌کند. لذا با وجودیکه دقت کلی متد MRF نسبت به متدهای غیرنظارتی ناحیه‌بندی، بالاتر است ولی مرز بافت‌ها در این متد نسبت به سایر متدها تا اندازه‌ای حالت smooth شده دارد.



شکل (۱-۰) حذف جزئیات مرزها در ناحیه‌بندی با متد MRF (الف) تصویر اولیه، (ب) ناحیه‌بندی مرجع، (ج) ناحیه‌بندی بدست‌آمده از MRF

مسئله چنانچه ویژگی‌های فضایی برای پیکسل‌ها به‌روشنی محاسبه شوند خطای نواحی مرزی کاهش پیدا خواهد کرد. لذا قدم بعدی ما استفاده از متد انتشار شایعه برای یافتن همسایگانی با ضریب اطمینان بالا برای هر پیکسل و بررسی میزان افزایش دقت ناحیه بندی به این شیوه خواهد بود.

۴- بررسی عملکرد ویژگی‌های بافتی به صورت ترکیبی

ویژگی‌های بافتی ویژگی‌های ارزشمندی هستند. ویژگی‌های بافتی مورد استفاده ما در این پروژه الگوی باینری محلی است. پیش از این دقت بدست آمده از ناحیه بندی با ترکیبی از ویژگی‌های GLCM نیز بررسی شد. یک راه دیگر برای بهبود ناحیه بندی یافتن ترکیب مناسبی از ویژگی‌های بافتی نظیر الگوی باینری، GLCM و ویژگی‌های دیگری نظیر طول قطعه^۱ است.

^۱ Run-length

پوست

۱- معیارهای ارزیابی بردارهای ویژگی

الف) شاخص Gini

اگر مجموعه T مجموعه داده‌ای شامل n کلاس مختلف باشد، شاخص Gini برابر است با

$$Gini = \sum_{i=1}^n p_i (1 - p_i) = 1 - \sum_{i=1}^n p_i^2$$

در این رابطه P_i نماینده نسبت فراوانی داده‌های کلاس i موجود در مجموعه T به کل داده‌های

حاضر در این مجموعه داده است. پس از شکستن مجموعه T به دو زیرمجموعه T_1 و T_2 بترتیب با

N_1, N_2 داده شاخص Gini برای T تبدیل میشود به

$$gini_{split}(T) = \frac{N_1}{N} gini(T_1) + \frac{N_2}{N} gini(T_2)$$

بهترین حالت جداسازی دو مجموعه زمانی صورت گرفته می‌گیرد که $gini_{split}(T)$ را می‌نیمم

سازد [۸۱].

ب) شاخص بهره اطلاعات

مقدار شاخص بهره اطلاعات برخلاف شاخص Gini با افزایش خلوص داده‌های یک مجموعه

افزایش می‌یابد. طبق تعریف شاخص بهره اطلاعات برابر است با:

اندازه اطلاعات بعد از تقسیم - اندازه اطلاعات قبل از تقسیم = بهره اطلاعات

بهره اطلاعات با استفاده از معیار دیگری به نام آنتروپی محاسبه می‌شود. آنتروپی نیز خود

معیاری از درجه ناخالصی داده‌های یک مجموعه است که برای مجموعه داده T شامل n کلاس

مختلف به صورت زیر محاسبه می‌شود:

$$H(T) = -\sum_{i=1}^n p_i \log_2 p_i$$

طبق این رابطه هرگاه داده‌های یک مجموعه تنها متعلق به یک کلاس باشند، مقدار آنتروپی

مجموعه صفر است. اگر آنتروپی را همان مقدار اطلاعات مجموعه داده در نظر بگیریم، سپس X را

داده‌ای در مجموعه T و $value(x, a)$ را مقدار ویژگی a برای داده x فرض کنیم، آنگاه بهره اطلاعات پس از طبقه‌بندی داده‌ها توسط ویژگی a برابر خواهد بود با :

$$IG(T, a) = H(T) - \sum_{v \in value(a)} \frac{|\{x \in T \mid value(x, a) = v\}|}{|T|} \cdot H(\{x \in T \mid value(x, a) = v\})$$

در این رابطه $H(\cdot)$ آنترپی یک مجموعه داده، IG بهره اطلاعات، $| \cdot |$ اندازه مجموعه و

$values(a)$ مقادیر متفاوتی است که ویژگی a می‌تواند اختیار کند [۸۲].

ج) شاخص نرخ بهره اطلاعات

نرخ بهره، شاخص دیگری است که برای ارزیابی ویژگی‌ها استفاده شده و طبق رابطه زیر تعریف

می‌شود.

$$GR(T, a) = - \sum \frac{|\{x \in T\}|}{|T|} \times \log_2 \left(\frac{|\{x \in T\}|}{|T|} \right)$$

در این رابطه $|\{x \in T\}|$ تعداد داده‌هایی است که پس از طبقه‌بندی داده‌ها توسط متغیر a در

یک کلاس قرار می‌گیرد. از ترکیب دو شاخص نرخ بهره و بهره اطلاعات شاخص سومی با نام نرخ بهره

اطلاعات تولید می‌شود که نسبت به دو شاخص اصلی تشکیل‌دهنده خود بطور گسترده‌تری در ارزیابی

بردارهای ویژگی مورد استفاده قرار می‌گیرد [۸۲].

$$IGR(T, a) = IG/GR$$


۲- ویژگی‌های GLCM

مقادیر ماتریس هم‌رخداد برای یک تصویر طبق رابطه زیر تعریف می‌شوند. در این رابطه d

فاصله پیکسل مرکزی از همسایگانش، θ زاویه بین پیکسل مرکزی و پیکسل همسایه و $f(x, y)$

تصویر مورد بررسی است.

$$P(i, j; d, \theta) = \# \left\{ \begin{array}{l} (x_1, y_1)(x_2, y_2) \mid f(x_1, y_1) = i, f(x_2, y_2) = j, \\ \mid (x_1, y_1) - (x_2, y_2) \mid = d, \langle (x_1, y_1), (x_2, y_2) \rangle = \theta \end{array} \right\}$$



شکل پیوست ۱-۰۰ محدوده همسایگی بر حسب فاصله $d=1$ و θ برابر ۴ زاویه ۰، ۴۵، ۹۰ و ۱۳۵ درجه

برای محاسبه ویژگی‌های GLCM برای ماتریس هم‌رخداد $P(m,n)$ و G سطح خاکستری

متفاوت درون محدوده همسایگی روابط زیر استفاده می‌شود [۷۵].

جدول پیوست ۱-۱: توابع محاسبه ویژگی‌های GLCM

نام ویژگی	رابطه محاسبه
Variance	$\sum_i (i - \mu_x)^2 P_x(i)$ <p>Where</p> $P_x(m) = \sum_{n=1}^G p(m,n)$
Energy(angular second)	$\sum_{m=0}^{G-1} \sum_{n=0}^{G-1} P(m,n)^2$
Entropy	$-\sum_{m=0}^{G-1} \sum_{n=0}^{G-1} P(m,n) \log P(m,n)$
Contrast	$\frac{1}{(G-1)^2} \sum_{m=0}^{G-1} \sum_{n=0}^{G-1} (m-n)^2 P(m,n)$

ادامه جدول پیوست ۱-۱ (توابع محاسبه ویژگی‌های GLCM)

نام ویژگی	رابطه محاسبه
Correlation	$\frac{\sum_{m=0}^{G-1} \sum_{n=0}^{G-1} mnP(m, n) - \mu_x \mu_y}{\sigma_x \sigma_y}$ <p>Where</p> $\mu_x = \sum_{m=0}^{G-1} m \sum_{n=0}^{G-1} p(m, n)$ $\mu_y = \sum_{n=0}^{G-1} n \sum_{m=0}^{G-1} p(m, n)$ $\sigma_x = \sum_{m=0}^{G-1} (m - \mu_x)^2 \sum_{n=0}^{G-1} p(m, n)$ $\sigma_y = \sum_{n=0}^{G-1} (n - \mu_y)^2 \sum_{m=0}^{G-1} p(m, n)$
Homogeneity	$\sum_{m=0}^{G-1} \sum_{n=0}^{G-1} \frac{p(m, n)}{(1 + m - n)}$
Dissimilarity	$\sum_{m=0}^{G-1} \sum_{n=0}^{G-1} m - n P(m, n)$
Correlation	$\frac{\sum_{m=0}^{G-1} \sum_{n=0}^{G-1} (mn)P(m, n) - \mu_x^2}{\sigma_x^2}$
Sum Average	$\sum_{m=2}^{2G} mp_{x+y}(m)$ <p>Where</p> $p_{x+y}(k) = \sum_{m=1}^G \sum_{n=1}^G p(m, n)$ <p style="text-align: center;"><small>$m+n=k, k=1, \dots, 2G$</small></p>
Sum Variance	$\sum_{m=2}^{2G} (m - (\text{sum entropy}))^2 p_{x+y}(m)$

ادامه جدول بیوست ۱-۱ (توابع محاسبه ویژگی‌های GLCM)

نام ویژگی	رابطه محاسبه
Sum Entropy	$-\sum_{m=2}^{2G} p_{x+y}(m) \log\{p_{x+y}(m)\}$
Sum of Squares	$\left(\sum_{m=0}^{G-1} (m - \mu_x)^2 \sum_n P(m, n)\right) \left(\sum_{n=0}^{G-1} (n - \mu_y)^2 \sum_m P(m, n)\right)$ <p>Where</p> $\mu_x = \sum_{m=0}^{G-1} m \sum_{n=0}^{G-1} p(m, n)$ $\mu_y = \sum_{n=0}^{G-1} n \sum_{m=0}^{G-1} p(m, n)$
Maximum Probability	$\max(P(m, n)) \forall (m, n)$
Inverse Difference Moment	$\sum_{m=0}^{G-1} \sum_{n=0}^{G-1} \frac{P(m, n)}{(1 + (m - n)^2) / G^2}$
Inverse Difference	$\sum_{m=0}^{G-1} \sum_{n=0}^{G-1} \frac{P(m, n)}{(1 + m - n) / G}$

۳- جدول خطای ناحیه‌بندی با استفاده از بردار ویژگی GLCM

جدول بیوست ۱-۲: خطای کلی ناحیه‌بندی با استفاده از بردار GLCM

شماره ویژگی	نام ویژگی استفاده شده در ناحیه‌بندی	درصد خطای کلی
1	Energy	0.921374
2	Entropy	0.935843
3	Correlation	0.90133
4	Auto Correlation	0.140277
5	Contrast	0.936890
6	Cluster Prominence	0.916664
7	Cluster Shade	0.936853
8	Dissimilarity	0.924104
9	Homogeneity	0.935731
10	Maximum Probability	0.925001
11	Sum Average	0.142109
12	Sum Variance	0.141426
13	Sum of Squares	0.141736

ادامه جدول پیوست ۱-۲: (خطای کلی ناحیه‌بندی با استفاده از بردار GLCM)

شماره ویژگی	نام ویژگی استفاده شده در ناحیه‌بندی	درصد خطای کلی
14	Sum Entropy	0.915056
15	Difference variance	0.937301
16	Difference Entropy	0.924029
17	Information measure of Correlation	0.945938
18	Inverse Difference	0.935731
19	Inverse Difference Normalized	0.935881
20	Inverse Difference Moment Normalized	0.935955

جدول پیوست ۱-۳: (خطای کلی ناحیه‌بندی با ویژگی‌های ترکیبی GLCM)

ترکیب ویژگی‌ها (با ذکر شماره ویژگی)	درصد خطای کلی
1-20	0.47
11,12,13	0.130328
11,12,13,14	0.123616

۲- ضریب Dice

درصد انطباق بین دو مجموعه A و B با استفاده از ضریب Dice

$$Dice\ Coeff = \frac{2 \times (A \cap B)}{|A| + |B|}$$


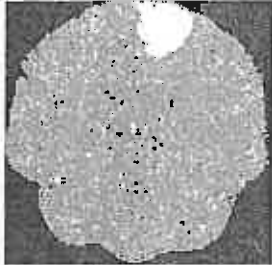


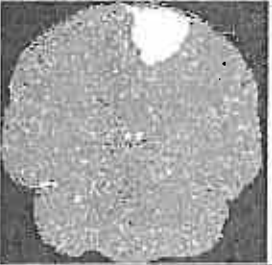
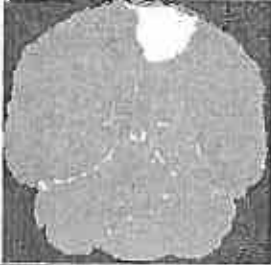

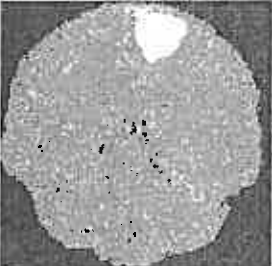


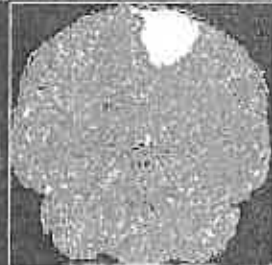

$$0 \leq Dice\ Coeff \leq 1$$

این رابطه معادل درصد انطباق پیکسل به پیکسل دو تصویر A و B است که در صورت تطابق صد درصد برابر یک و در صورت عدم شباهت کامل صفر خواهد بود. برای ارزیابی نتایج بدست‌آمده از ناحیه‌بندی توسط این ضریب A را معادل تصویر مرجع، B را معادل تصویر نتیجه و |·| برابر اندازه یا تعداد پیکسل‌های تصویر A یا B خواهد بود [۸۰].


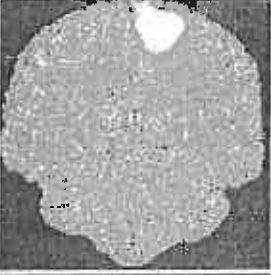


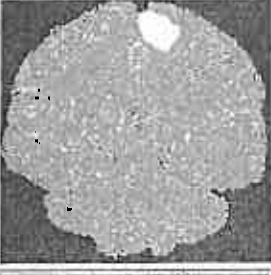


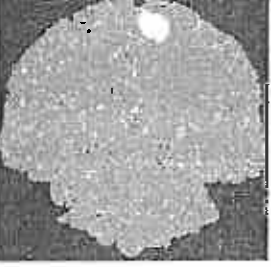

۵- ادامه نتایج ناحیه بندی تومور

ادامه نتایج ناحیه بندی تومور از فصل پنجم

جدول پیوست ۴۰۰: ناحیه بندی تومور

شماره تصویر	تصویر اصلی	بلوک بندی	روش پیشنهادی
126_10_7			
126_10_8			
126_10_9			
126_10_14			

ادامه جدول پیوست ۴۰۰: ناحیه بندی تومور

شماره تصویر	تصویر اصلی	بلوک بندی	روش پیشنهادی
126_10_18			
126_10_20			
126_10_21			

برج



- [1] Tasdizen T., Weinstein D., and Lee J. N., (2004) "Automatic Tissue Classification for the Human Head from Multispectral MRI", SCI Institute, Technical Report, UUSCI-2004-001, University of Utah
- [2] White, Stuart C., Michael J. Pharoah (2008), "Oral Radiology Principles and Interpretation", 6th ed. Mosy Publication.
- [3] Ahmed M., Mohammad D. B., (2008), "Segmentation of Brain MR Images for Tumor Extraction by Combining Kmeans Clustering and Perona-Malik Anisotropic Diffusion Model", **International Journal of Image Processing**, 2(1).
- [4] Popuria K., Cobzasb D., Jagersandb M., Shaha S. L., Murthac A., (2009), "3D variational brain tumor segmentation on a clustered feature set", Proceedings of SPIE 7259.
- [5] Bernstein M. A., King K. E., Zhou X. J., Fong W., (2005), "Handbook of MRI Pulse Sequences", Medical Physics, 32(5).
- [6] S. Y. Lee, Y. K. Ham, Y. H. Kim, R.H. Park , (2003), "Automatic Segmentation of Multi-Spectral MR Brain Images Using a Neuro-Fuzzy Algorithm", **Neuro-Fuzzy Pattern Recognition**, pp. 227-247.
- [7] Germonda L., Dojatb M., Taylorc C., Garbaya C., (2000), "A Cooperative Framework for Segmentation of MRI Brain Scans", **Artificial Intelligence in Medicine**. 20(1), pp. 77-93.
- [8] Hernández J. A., Mora M. L., Schiavi E., Toharia P., (2004), "RF Inhomogeneity Correction Algorithm in Magnetic Resonance Imaging", **Lecture Notes in Computer Science**, vol. 3337, pp. 1-8.
- [9] Sebastián M. T. G., (2009) "Contributions to Brain MRI Processing and Analysis", Department of Computer Science and Artificial Intelligence in partial fulfillment of the requirements for the degree of Doctor of Philosophy, The University of the Basque Country.
- [10] Vovk U., Pernus F., Likar B., (2007), "A Review of Methods for Correction of Intensity Inhomogeneity in MRI", **IEEE Transactions on Medical Imaging**, 26(3), pp. 405 – 421.
- [11] Abdurrahim, S. H. (2004), "Segmentation of Magnetic Resonance Brain Images Using Watershed Algorithm", Masters thesis, University Putra Malaysia.

- [12] Ahmed M.N., Yamany S.M., Farag A.A., Moriarty T., (1999), "Bias Field Estimation and Adaptive Segmentation of MRI Data Using a Modified Fuzzy C-Means Algorithm", Proceedings of IEEE International Conference on Computer Vision and Pattern Recognition.
- [13] Frost J.J., Meltzer C.C., Zubieta J.K., Links J.M., Brakeman P., Stumpf M.J., Kruger M., (1995), "MR-based Correction of Partial Volume Effects in Brain PET Imaging ", Proceedings of the 2nd International Meeting on Quantification of Brain Function.
- [14] Gong R., (2010), "A Segmentation and Re-balancing Approach for Classification of Imbalanced Data", PHD Thesis, University of Cincinnati.
- [15] Kotsiantis S., Kanellopoulos D., Pintelas P., (2006), "Handling imbalanced datasets: A review", **GESTS International Transactions on Computer Science and Engineering**, Vol.30.
- [16] Haibo H., Yang B., Garcia E.A., Shutao L., (2008), "ADASYN: Adaptive synthetic sampling approach for imbalanced learning", IEEE World Congress on Computational Intelligence, pp 1322 –1328.
- [17] Chawla N.V., Bowyer K.W., Hall L.O., Kegelmeyer W.P., (2002), "SMOTE: Synthetic Minority Over-Sampling Technique," Journal of Artificial Intelligence Research, vol. 16, pp. 321-357.
- [18] Provided by the Center for Morphometric Analysis at Massachusetts General Hospital, available at <http://www.cma.mgh.harvard.edu/ibsr/>
- [19] Clarke L.P., Velthuizen R.P., Phuphanich S., Schellenberg J.D., Arrington J.A., Silbiger M., (1993), "MRI: Stability of three supervised segmentation techniques", **Magnetic Resonance Imaging**, vol. 11, pp. 95-106.
- [20] Kannan S.R., (2008), "A new segmentation system for brain MR images based on fuzzy techniques", **Applied Soft Computing**.
- [21] Ruan S., Moretti B., Fadili J., Bloyet D., (2001), "Segmentation of Magnetic Resonance Images using Fuzzy Markov Random Fields", **Proceedings of International Conference on Image Processing**, vol. 3, p.1051.
- [22] Yousefi S., Zahedi M., Azmi R., (2010), "Brain Tumor Segmentation in 3D MRIs Using an Improved Markov Random Field Model", International Conference on Signal and Information Processing ICSIP.

- [23] Grira N., Crucianu M., Boujemaa N., (2004), "Unsupervised and semi-supervised clustering: a brief survey; A Review of Machine Learning Techniques for Processing Multimedia Content", Report of the MUSCLE European Network of Excellence (FP6).
- [24] Basu S., Banerjee A., Mooney R.J., (2002), "Semi-supervised clustering by seeding", Proceedings of the Nineteenth International Conference on Machine Learning, ICML.
- [25] Abney S., (2008), "Semi-supervised learning for computational linguistics", Chapman and Hall, London, UK.
- [26] Ardizzone E., Pirrone R., Gambino O., Peri D., (2002), "Two Channels Fuzzy C-Means Detections of Multiple Sclerosis Lesions in Multispectral MR Images", **International Conference on Image Processing**, pp. 345–348.
- [27] Deb S., (2009), "Robotics Technology and Flexible Automation", Tata McGraw-Hill Education, ISBN: 0070077916.
- [28] Sankura B., Sezgin M., (2001), "Image Thresholding Techniques: A Survey over Categories", **Pattern Recognition**.
- [29] Reddick W. E., Glass J. O., Cook E. N., Elkin D., Deaton R. J., (1997), "Automated Segmentation and Classification of Multispectral Magnetic Resonance Images of Brain Using Artificial Neural Networks", *IEEE Transactions on Medical Imaging*, 16(6).
- [30] Ahmed M.N., Yamany S.M., Mohamed N.A., Farag A.A., Moriarty T., (2002), "A modified fuzzy c-means algorithm for bias field estimation and segmentation of MRI data", **IEEE Transactions on Medical Imaging**, 21(3).
- [31] Marroquín J. L., Vemuri B.C., Botello S., Calderón F., (2002), "An Accurate and Efficient Bayesian Method for Automatic Segmentation of Brain MRI", 7th European Conference on Computer Vision (ECCV 2002), vol (4) pp: 560-574.
- [32] Bezdek J.C., Hall L.O., Clarke L.P., (1993), "Review of MR Image Segmentation Techniques using Pattern Recognition", **Medical Physics**, 20(4), pp.1033-48.
- [33] Cai W., Chen S., Zhang D., (2007), "Fast and Robust Fuzzy C-Means Clustering Algorithms Incorporating Local Information for Image Segmentation", **Pattern Recognition**. 40 (7), pp. 825–838.
- [34] Xiaojin Zhu, Goldberg A. B., (2009), "Introduction to Semi-Supervised Learning", Morgan & Claypool Publishers.
- [35] Zhu X., (2008), "Semi-Supervised Learning Literature Survey", **Computer Sciences TR 1530**, University of Wisconsin – Madison.

- [36] Chapelle O., Chi M., Zien A., (2006), "A Continuation Method for Semi-Supervised SVMs", In Proceeding of the 23rd International Conference on Machine Learning, (ICML).
- [37] Wang L., Shen X., Pan W., (2007), "On Transductive Support Vector Machines, Prediction and Discovery", **American Mathematical Society**.
- [38] Altun Y., McAllester D., Belkin M., "Maximum Margin Semi-Supervised Learning for Structured Variables", **Advances in Neural Information Processing Systems**, vol. 18.
- [۳۹] رضا عزمی، بشری پیشگو، نرگس نوروزی، محمدرض کیوانپور، ارائه یک چارچوب تجمیعی در یادگیری به روش نیمه‌نظارتی، شانزدهمین کنفرانس ملی سالانه انجمن کامپیوتر ایران، ۱۳۸۹
- [40] Blum A., Mitchell T., (1998), "Combining labeled and unlabeled data with co-training". In: Proceedings of the 11th Annual Conference on Computational Learning Theory, pp. 92–100.
- [41] Sindhwani V., Niyogi P., Belkin M., (2005), "Beyond the Point Cloud: From Transductive to Semi-supervised Learning", **Machine Learning**, Proceedings of the Twenty-Second International Conference (ICML 2005).
- [42] Haffari G., (2005), "A Survey on Inductive Semi-Supervised Learning". Technical report, School of Computing Science, Simon Fraser University.
- [43] Krogel M. A., Scheffer T., (2004) "Multi-Relational Learning, Text Mining, and Semi-Supervised Learning for Functional Genomics". **Machine Learning**, vol. 57, pp. 61–81.
- [44] Orlitz L. G., Menze B. H., Weber M. A., Kelm B. M., Hamprecht F. A., (2009), "Semi-Supervised Tumor Detection in Magnetic Resonance Spectroscopic Images Using Discriminative Random Fields", Proceedings of MICCAI Workshop on Probabilistic Models for Medical Image Analysis.
- [45] He S., Gildea D., "Self-training and Co-training for Semantic Role Labeling", The University of Rochester Computer Science Department, Rochester, New York, Technical Report 891
- [46] Breiman L., (1998), "Arcing classifiers", **The Annals of Statistics**, vol. 24, PP: 801-849.
- [47] Freund Y., Schapire R. E., (1995), "A Decision-Theoretic Generalization of on-Line Learning and an Application to Boosting", **Journal of Computing System Science**, 55(1), pp 119-139.
- [48] Bernard S., Heutte L., Adam S., (2009), "Towards a Better Understanding of Random Forests through the Study of Strength and Correlation", Proceedings of the Intelligent

computing 5th international conference on Emerging intelligent computing technology and applications, (ICIC).

- [49] Kim S. H., Lee J. H., Ko B. C., Nam J. Y., (2010), "X-ray Image Classification Using Random Forests with Local Binary Patterns", ICMLC.
- [50] Geremia E., Menze Bjoern H., Clatz O., Korukglu E., Ender, Criminisi, A., Avache, N., (2010), **Spatial decision forests for MS lesion segmentation in multi-channel MR images**, Medical Image Computing and Computer-Assisted Intervention (MICCAI).
- [51] Cutler A., Zhao G., (2001), "PERT – Perfect Random Tree Ensembles", **Computing Science and Statistics**, vol. 33, pp. 490-497.
- [52] Schapire R., (1990), "Strength of Weak Learnability", **Machine Learning**, vol. 5, pp: 197-227.
- [53] Freund Y., Schapire R., (1996), "Experiments with a new boosting algorithm", **Machine Learning: Proceedings of the 13th International Conference**, pp. 148-156.
- [54] Shirai S., Kudo M., Nakamura A., (2009), "Comparison of Bagging and Boosting Algorithms on Sample and Feature Weighting", Proceeding of MCS '09 Proceedings of the 8th International Workshop on Multiple Classifier Systems.
- [55] Breiman L., (1996), "Bagging predictors", **Machine Learning**, vol. 24, PP: 123–140.
- [56] Breiman L., (2001), "Random forests", **Machine Learning**, vol. 45, PP 5–32.
- [57] Shi T., Horvath S., (2006), "Unsupervised Learning with Random Forest Predictors", **Journal of Computational and Graphical Statistics**, vol. 15(1), PP: 118-138(21).
- [58] Chen C., Liaw A., Breiman L., (2004), "Using Random Forest to Learn Imbalanced Data", Technical report, Department of Statistics, University of California, Berkeley.
- [59] Chaoa, Wen H., Chena, You Y., Linc, Sheng H., Shihd, Yen Y., Tsange S., (2009) "Automatic segmentation of magnetic resonance images using a decision tree with spatial information", **Computerized Medical Imaging and Graphics**, pp: 111–121.
- [60] Robnik M., Kononenko S., Kononenko I., (1999), "Attribute Dependencies, Understandability and Split Selection in Tree Based Models", Proceedings of the Sixteenth International Conference on Machine Learning (ICML 1999), pp: 344-353.
- [61] Loh W.Y., (2008), "Classification and Regression Tree Methods", (In Encyclopedia of Statistics in Quality and Reliability, Ruggeri, Kenett and Faltin (eds.), pp. 315–323, Wiley.
- [62] Boinee, P., De Angelis, A., Foresti, G. L., (2006)," Meta Random Forests". **International Journal of Information and Mathematical Sciences**.

- [63] Menza R B., Kelm H., Masuch B.M., Himmelreich, R. U., Bachert P., Petrich W., F.A. Hamprecht, (2009), "A Comparison of Random Forest And Its Gini Importance With Standard Chemometric Methods For The Feature Selection And Classification of Spectral Data", BMC.
- [64] Sirikulviriyaya N., Sinthupinyo S., (2011), "Integration of Rules from a Random Forest", International Conference on Information and Electronics Engineering (IPCSIT), vol. 6.
- [65] Ashton E. A., Berg M. J., Parker K. J., Weisberg J., Chen Ch. W., Ketonen L., (1995), "Segmentation and Feature Extraction Techniques with Applications to MRI Head Studies", **Magnetic Resonance in Medicine**. 33(5):670-7.
- [66] Lu K.C., Yang D.L., (2010), "Scalable Clustering for Mining Local-Correlated Clusters in High Dimensions and Large Datasets", **Fundamenta Informaticae - Intelligent Data Analysis in Granular Computing archive**, 98(1).
- [67] Robnik M., (2004), "Improving Random Forests", **Machine Learning**, ECML, Springer.
- [68] Dou, W., Runan S., Chen Y., Bloyet, D., Constans, Jean M., (2007), "A Framework of Fuzzy Information Fusion for the Segmentation of Brain Tumor Tissues on MR Images", **Image and Vision Computing**, vol. 25, pp. 164–171.
- [69] Anbeek P, Vincken KL, Van Osch MJP, Bisschops RHC, Van Der Grond J., (2004), "Probabilistic Segmentation of Brain Tissue in MR Imaging", **NeuroImage**, vol (21), pp:1037–4427.
- [70] Yousefi S., Azmi R., Zahedi M., (2011), "Optimization Approaches in Markov Random Field Model: A Comparative Survey for MR Image Segmentation Case Study". **Middle-east journal of scientific researches**, 7(6), pp. 1024-1029.
- [71] Greenspan H, Ruf A, Goldberger J., (2006), "Constrained Gaussian mixture model framework for automatic segmentation of MR brain images". **IEEE Transactions on Medical Imaging**, 25(9), pp: 1233–45.
- [72] Dell'Amico M., Roudier Y., (2009), "A Measurement of Mixing Time in Social Networks", 5th International Workshop on Security and Trust Management (STM).
- [73] Bakhshi R., Cloth L., Fokkink W., Hayerkort B., (2009), "Mean-field Framework for Performance Evaluation of Push-Pull Gossip Protocols", **Advances in Quantitative Evaluation of Systems - QEST**.

- [74] Bicocchi N., Mamei M., Zambonelli F., (2007), "Self-organizing Spatial Regions for Sensor Network Infrastructures", Proceedings of 21th International Conference on Advances of Information Networking and Application Workshop (AINAW).
- [75] Haralick R.M., Shanmugam K., Dinstein I., (1973). 'Textural Features for Image Classification', IEEE Transactions on Systems, Man and Cybernetics.No 6. - PP. 610–621
- [76] Heikkilä M., Pietikäinen M., Schmid C., (2009), "Description of interest regions with local binary patterns. Pattern Recognition", 42(3), pp: 425-436.
- [77] Ko B.C., Kim S.H., Nam J.Y., (2011), "X-ray Image Classification Using Random Forests with Local Wavelet-Based CS-Local Binary Patterns", **Imaging Informatics in Medicine**.
- [78] Unay D., Ekin A., Cetin M., Jasinski R., Ercil A., (2007), Robustness of Local Binary Patterns in Brain MR Image, Analysis Proceedings of the 29th Annual International, Conference of the IEEE EMBS.
- [79] Sun Z., Bebis G., Xiaojing Y., Louis S.J., (2002)," Genetic feature subset selection for gender classification: A comparison study", IEEE Workshop on Applications of Computer Vision.
- [80] Grzegorz K., Daniel M., Knight K., (2003), "Cognates Can Improve Statistical Translation Models", Proceedings of Human Language Technology Conference of the North American Chapter of the Association for Computational Linguistics (HLT-NAACL). pp 46–48
- [81] Tam, M.Y., Persky J., (1982), "Regional Convergence and National Inequality". The Review of Economics and Statistics 64 (1).
- [82] Harris Jr. E., (2001), "Information Gain versus Gain Ratio: A Study of Split Method Biases", International Symposium on Artificial Intelligence and Mathematics.

Abstract

The automatic segmentation of brain images is a fundamental part in many medical treatments and investigations including diagnosis, locating and tracing of tumor growth, delineation of unhealthy tissues and deciding over the type of medical treatment plan. The extraction of tumors is commonly done manually by radiology experts and is known to be very tiresome and erroneous. Hence the automation of segmentation has become the subject of interest in many medical studies. Automatic segmentation of brain tissues involves many challenges due to the diversity of the location and general shape of brain tumors, their diverse range of intensities or the ambiguity of tissue bounds and partial voluming along the boundaries. Some deficiencies in RF coil also can distort the real image values. Robustness of the method against intensity artifacts and noises is inevitable for the sake of its future success.

In this thesis we propose an automatic semi-supervised segmentation algorithm using the random forest classifier. Semi-supervised trained classifiers are specifically beneficial in medical applications where providing the classifier with the experts' labeled training data is laborious.

The most important feature in any segmentation algorithm is the intensity levels of voxels which can be easily distorted by intensity inhomogeneity and noise. Regarding the particular application of the system, interference of prior knowledge such as spatial constraints or deformable atlases will enhance its accuracy. In order to extract reliable features, we propose to modify the neighborhood term and define a flexible and adaptive neighborhood named the Gossiping-based neighborhood system. The idea is to impose both spatial and intensity constraints to partition the image into primary regions where pixels inside each region are close neighbors and belong to the same class with high probability. Extracting spatial features inside the region bounds prevents irrelevant pixels to mutilate statistical features of the region.

The extracted features are to be used with random forest classifier for final segmentation. The RF classifier has rarely been notified in MRI segmentation however the classifier's traits such as high speed and accuracy, the ability to handle large feature vectors and missing values and the probability-based decision making make it very appropriate to use in the problem of segmentation and modeling ambiguity around the borders. The brain scans segmentation with random forest showed promising results

using the gossip-based region growing algorithm compared to the non-adaptive traditional feature extraction. Although being trained in a semi-supervised mode, the final classifier's segmentation accuracy on about 800 different MRI slides is as high as most of recently proposed brain segmentation methods which means a noticeable increase in accuracy regarding the volume of testing dataset.

Key-words: Segmentation, Magnetic Resonance Imaging, Semi-supervised training, Voxel, Random forest classifier, Spatial constraints, Gossiping algorithm, Local binary pattern



Shahrood University of Technology
Faculty Computer Engineering & Information Technology
M. Sc. Thesis

**Adaptive and Semi-supervised Segmentation
of Brain Tumors in MRI Images**

Saeideh Eslami

Supervisor:
Dr. Morteza Zahedi

Advisor:
Dr. Reza Azmi

September 2011