

تشخیص نوع تومور مغزی براساس مدل‌های فراکامل مبتنی بر ویژگی‌های بافتی و آماری

سمیرا مودتی^۱

۱- استادیار- دانشکده فنی و مهندسی - دانشگاه مازندران - بابلسر - ایران

s.mavaddati@umz.ac.ir

چکیده: تشخیص انواع تومور مغزی به کمک تصاویر ام‌آر‌آی در کنار دانش پزشکی می‌تواند به تصمیم‌گیری درستی در مورد وضعیت بیمار منتهی گردد. همچنین تشخیص خوش‌خیم یا بدخیم بودن تومور به دلیل لزوم بررسی جزئیات بافت و امکان خطای یکی از مسائل چالش برانگیز است. بنابراین پرداختن به این حوزه به کمک تکنیک‌های پردازش تصویر می‌تواند بسیار حائز اهمیت باشد. در این مقاله، به منظور تشخیص مناسب نوع تومور مغزی، انواع ویژگی‌های مختلف مبتنی بر بافت و مبتنی بر آمار مورد بررسی قرار گرفته و دسته‌ای از ویژگی‌های مناسب در این حوزه طبقه‌بندی مورد استفاده قرار می‌گیرد. سپس از تکنیک کدگذاری تنک و یادگیری واژه‌نامه به منظور آموزش مدل‌های فراکامل بازنمایی‌کننده مشخصات هر دسته داده استفاده می‌شود و دسته‌بندی داده‌ها براساس نرخ انرژی محاسبه شده ضرایب تنک صورت می‌گیرد. همچنین نتایج این دسته‌بندی با نتایج حاصل از دسته‌بندی‌های مبتنی بر شبکه عصبی و ماشین بردار پشتیبان مقایسه می‌گردد. نتایج شبیه‌سازی‌ها نشان می‌دهد که روش پیشنهادی مبتنی بر ویژگی‌های ترکیبی و آموزش مدل‌های فراکامل قادر به طبقه‌بندی مطلوب انواع تومور مغزی با دقت بالا خواهد بود.

واژه‌های کلیدی: تشخیص تومور مغزی، ویژگی مبتنی بر بافت، ویژگی مبتنی بر آمار، بازنمایی تنک، آموزش مدل فراکامل

نوع مقاله: پژوهشی

DOI: 10.52547/jiaeee.19.2.177

تاریخ ارسال مقاله: ۱۳۹۷/۰۷/۰۱

تاریخ پذیرش مشروط مقاله: ۱۳۹۸/۰۱/۱۴

تاریخ پذیرش مقاله: ۱۳۹۹/۰۱/۱۶

نام نویسنده‌ی مسئول: دکتر سمیرا مودتی

نشانی نویسنده‌ی مسئول: ایران - بابلسر - بلوار شهید ذوالفقاری - بلوار دانشگاه - پردیس دانشگاه - دانشکده فنی و مهندسی

۱- مقدمه

بررسی تصاویر ام‌آرآی توسط پزشک نقش اساسی را در تشخیص نوع تومور دارد. تشخیص تومور مغز عبارت است از تفکیک بافت مغز از تومور و دسته‌بندی آن به عنوان خوش‌خیم و بدخیم که پس از مقایسه و براساس ویژگی‌ها صورت می‌گیرد. برای تشخیص این ناهنجاری، مقایسه بین نیم‌کره سالم و بیمار با توجه به این نکته انجام می‌شود که تومور در نیم‌کره‌های متقارن قرار نمی‌گیرد. تصویربرداری رزونانس مغناطیسی یک روش پیشرفته پزشکی برای تولید تصاویر با وضوح بالا از اندام‌های بدن انسان، کشف ناهنجاری‌ها و بررسی پیشرفت ضایعات است و در نهایت از ویژگی‌های بدست آمده از این تصاویر، برای شناسایی مستقیم و طبقه‌بندی غدد و تومورها بهره گرفته می‌شود. تشخیص تومور به دو صورت انجام می‌شود: تشخیص براساس ویژگی‌های محاسباتی و تشخیص براساس ویژگی‌های ظاهری. در محاسبه ویژگی‌های محاسباتی از الگوریتم‌های کاربردی به منظور تشخیص تومور استفاده می‌گردد که به استخراج ویژگی‌هایی همچون انحراف معیار، شدت رنگ، آنتروپی و غیره منتهی می‌شود [۵-۱]. با کمک ویژگی‌های محاسباتی می‌توان به وجود یا عدم وجود بخش‌های ناهمگون با بافت مغز پی برد. ویژگی‌های ظاهری مغز یک بیمار در تصاویر پزشکی می‌تواند شامل مایع مغزی نخاعی، بافت استخوانی جمجمه، ذرات خاکستری و سفید، کنتراست بافت، رزولوشن و موقعیت مکانی قرارگیری توده‌های بافتی باشد. تشخیص بر اساس این ویژگی‌ها سطحی‌تر و ابتدایی‌تر است، اما نمی‌توان از اهمیت آن چشم‌پوشی نمود. در [۱]، یک الگوریتم تشخیص تومورهای خوش‌خیم، بدخیم و نرمال به کمک ویژگی‌های بافتی و شبکه عصبی احتمالی^۱ ارائه شده است. در این الگوریتم از ضرایب تبدیل موجک در باندهای مختلف استفاده می‌شود. در [۲]، دسته‌بندی چهار تومور استروستوم^۲، مننژیوم^۳، کارسینوما^۴ و سارکوم^۵ به کمک ویژگی‌های مبتنی بر ماتریس هم‌رخداد سطوح خاکستری^۶ به کمک شبکه عصبی و الگوریتم بهینه‌سازی غیرخطی لونبرگ-مارکوارت^۷ مورد بررسی قرار گرفته است. در [۳]، دسته‌بندی تومورهای سرطان مغز و استخوان به کمک ضرایب ماتریس هم‌رخداد سطوح خاکستری و شبکه عصبی پس انتشار انجام شده و نتایج برای چهار سطح از تومورها گزارش شده است. دسته‌بندی تومورهای مغزی در [۴] به کمک ضرایب ماتریس هم‌رخداد سطوح خاکستری و نیز تبدیل کرولت گسسته سریع^۸ و با دسته‌بند مبتنی بر شبکه عصبی احتمالی با توابع پایه شعاعی^۹ صورت گرفته است. دسته‌بندی بر روی انواع تومور خوش‌خیم، بدخیم و نرمال انجام شده است. در [۵]، با استفاده از ترکیب تکنیک‌های پردازش تصویر و شبکه عصبی سعی در افزایش سرعت و دقت یافتن تومورهای مغزی شده است. ویژگی‌های مبتنی بر هیستوگرام از نواحی تومور و نیز بخش‌های نرمال تصویر استخراج شده و سپس از شبکه عصبی به منظور تشخیص ناحیه دارای تومور بهره گرفته شده است. در [۶]، از ضرایب استخراج

شده از ماتریس هم‌رخداد سطوح خاکستری و دسته‌بند مبتنی بر K- نزدیکترین همسایه^{۱۰} به منظور دسته‌بندی داده‌های تومور نرمال و غیر نرمال استفاده می‌شود. در [۷]، از ضرایب استخراج شده از ماتریس هم‌رخداد سطوح خاکستری و خوشه‌بند K- میانگین فضایی^{۱۱} به منظور تشخیص تومورهای غیر نرمال مغزی استفاده شده است. این دسته‌بندی در [۸] به کمک شبکه عصبی صورت گرفته است. در [۹]، ویژگی‌های ماتریس هم‌رخداد سطوح خاکستری استخراج شده از تصاویر ام‌آرآی و توموگرافی^{۱۲} و نیز دسته‌بندهای شبکه عصبی تابع پایه شعاعی و ماشین بردار پشتیبان^{۱۳} به منظور تشخیص تومورهای نرمال و غیرنرمال مغزی بکار گرفته شده است. در [۱۰]، ترکیب ویژگی‌های استخراج شده از هیستوگرام، ماتریس هم‌رخداد سطوح خاکستری، ماتریس طول تکرار سطوح خاکستری^{۱۴} و نیز ماشین بردار پشتیبان به منظور شناسایی تومورهای خوش‌خیم و بدخیم مورد استفاده قرار گرفته است. در [۱۱]، یک الگوریتم دسته‌بندی تومورهای مغزی براساس شبکه عصبی احتمالی آموزش‌دیده به کمک ویژگی‌های ماتریس هم‌رخداد سطوح خاکستری و عملگرهای موفولوژی حاصل از ضرایب تبدیل موجک گسسته پیشنهاد شده است. در [۱۲]، الگوریتم‌های مختلف ارائه شده به منظور دسته‌بندی تومورهای مغزی براساس ویژگی‌ها و دسته‌بندهای مختلف مورد بررسی قرار گرفته و نتایج حاصل از تشخیص با یکدیگر مقایسه شده است. در [۱۳]، یک الگوریتم به منظور تشخیص مساحت و ناحیه تومور مغزی معرفی شده است. در این روش پس از اعمال رشد تصویر و حذف نویز، اثر چرخش سر حذف گردیده و با بکارگیری آنالیز تقارن، نواحی منتخب به عنوان مکان تومور تشخیص داده می‌شود. در ادامه، مساحت هر یک از این نواحی محاسبه و ناحیه‌ای که دارای مساحت مشخصی در محدوده مساحت نواحی تومورهای تصاویر آموزش داده شده باشد، به عنوان ناحیه اصلی تومور در نظر گرفته می‌شود. در [۱۴]، یک روش شناسایی تومورهای بدخیم و نرمال مغزی براساس ویژگی‌های حاصل از ماتریس هم‌رخداد سطوح خاکستری و ویژگی‌های مبتنی بر شکل استخراج شده از نواحی متصل تصویر ارائه شده است. در این روش از نه ویژگی معرفی‌شده در بخش‌های بعدی این مقاله به منظور آموزش شبکه عصبی بهره گرفته می‌شود.

همانطور که مشاهده می‌شود در اکثر روش‌های ارائه شده در این زمینه پردازشی، از ویژگی‌های استخراج شده از ماتریس هم‌رخداد سطوح خاکستری استفاده شده که نشان دهنده اهمیت این ویژگی بافتی در روال تشخیص تومورهای مغزی می‌باشد. در روش پیشنهادی همانطور که شرح داده می‌شود از ترکیب ویژگی‌های مختلف آماری و بافتی که شامل ماتریس هم‌رخداد سطوح خاکستری نیز می‌باشد به منظور آموزش مدل‌های جامع بازنمایی‌کننده خواص هر دسته تومور مغزی در نظر گرفته شده استفاده می‌گردد. همچنین در این روال آموزش، تنظیم مناسب پارامتر همدوسی مدنظر قرار می‌گیرد تا نتایج دسته‌بندی مناسبی بدست آید.



۳- نحوه استخراج ویژگی

اولین مرحله در تمامی روال‌های دسته‌بندی متداول، گام پیش‌پردازش داده‌ها می‌باشد. در این مقاله ابتدا سطوح خاکستری داده‌های تصاویر ام‌آرآی بدست آمده و سپس ابعاد این تصاویر کاهش می‌یابد. در ادامه استخراج ویژگی داده‌ها انجام می‌شود. دو دسته روش متداول در این حوزه مورد توجه قرار می‌گیرد. استخراج ویژگی مبتنی بر بافت تصویر و استخراج ویژگی به کمک مولفه‌های آماری تصویر. در ادامه روش‌های مختلف استخراج ویژگی مورد بررسی قرار می‌گیرد.

۳-۱- الگوی باینری محلی^{۲۱}

الگوریتم الگوی باینری محلی به عنوان یکی از روال‌های استخراج ویژگی مقاوم به طور وسیعی در زمینه‌های پردازش بافت بخش‌های تصویر به کار گرفته می‌شود [۲۰]. این توصیف‌کننده غیرحساس به چرخش به منظور استخراج ویژگی‌های بافت‌های مجاور در تحلیل تصاویر با طیف خاکستری مورد استفاده قرار می‌گیرد. این خصوصیت موجب می‌شود که تغییر موقعیت تومور در تصویر ام‌آرآی اثر نامطلوب کمتری بر جای بگذارد. الگوهای مختلفی برای محاسبه ضرایب کدهای باینری محلی وجود دارد که به انتخاب نوع همسایگی وابسته است. این همسایگی‌ها می‌توانند به صورت قطری یا دایره‌ای با شعاع‌های مختلف در نظر گرفته شوند [۲۰].

۳-۲- هیستوگرام گرادیان جهت‌دار^{۲۲}

یکی از روش‌های استخراج ویژگی در پردازش تصویر که در روال تشخیص اهداف بسیار کارا می‌باشد، هیستوگرام گرادیان جهت‌دار است [۲۱-۲۲]. در این الگوریتم، تعداد رخداد گرادیان در راستاهای مختلف در بخش‌های محلی تصویر محاسبه می‌گردد. این شمارش بر روی سلول‌های مختلفی که در بلوک‌های دارای همپوشانی در سطح تصویر در نظر گرفته می‌شود انجام می‌گیرد. به این صورت که در ابتدا

$$X^* = \arg \min_X \|I_m - DX\|_2^2 \text{ s.t. } \|X\|_0 \leq K \quad (2)$$

تصویر به بلوک‌های با ۵۰ درصد همپوشانی تقسیم و آنگاه هر بلوک به چهار سلول بخش‌بندی می‌گردد. سپس، اندازه و زاویه گرادیان در پیکسل‌های مجاور تصویر محاسبه می‌شود. در ادامه، یک هیستوگرام با ۹ جهت متشکل از زوایای مختلف گرادیان‌های موجود در آن سلول محاسبه می‌شود. مقادیر هر ستون شامل مجموع اندازه گرادیان‌هایی است که زاویه یکسانی با مقدار آن ستون دارند. در HOG می‌توان تنها از زوایای گرادیان در بازه ۰° تا ۱۸۰° برای ایجاد هیستوگرام بهره گرفت. باید توجه داشت که این توصیف‌گر نسبت به چرخش تغییرپذیر بوده اما تفاوت در شدت روشنایی تاثیر کمی در ویژگی‌های استخراج شده خواهد داشت [۲۲-۲۱]. برای استخراج ویژگی در آزمایش‌های این مقاله از توصیف‌گر

در بخش دوم این مقاله، الگوریتم یادگیری واژه‌نامه و بازنمایی تنک بیان می‌شود. ویژگی‌های بافتی و آماری مورد استفاده در روال دسته‌بندی در بخش سوم مورد بررسی قرار می‌گیرد. همچنین، الگوریتم پیشنهادی به منظور دسته‌بندی تومورهای مغزی در بخش چهارم ارائه می‌گردد. در بخش پنجم نتایج بدست آمده از بکارگیری روش پیشنهادی مورد ارزیابی و مقایسه قرار می‌گیرد. در بخش آخر نیز نتیجه‌گیری در مورد پژوهش انجام می‌شود.

۲- یادگیری واژه‌نامه و بازنمایی تنک

به کمک مفاهیم بازنمایی تنک و یادگیری واژه‌نامه می‌توان یک تصویر دیجیتال I را به صورت زیر مدل نمود:

$$I_m = DX \quad (1)$$

که I_m در این رابطه یک ماتریس داده متشکل از تکه‌های^{۱۵} مختلف تصویر ورودی I می‌باشد. تصویر ورودی به بلوک‌های $I_{m \in M}$ تقسیم می‌شود که M مختصات تکه‌ها و با ابعاد 8×8 خواهد بود. به کمک تکنیک بازنمایی تنک می‌توان ماتریس داده I_m را به کمک یک ترکیب خطی از اتم‌ها براساس رابطه (۱) کد نمود که در آن $D \in \mathbb{R}^{P \times L}$, $L > P$ یک واژه‌نامه فراکامل می‌باشد. منظور از واژه‌نامه فراکامل این است که تعداد ستون‌ها یا اتم‌ها چند برابر تعداد سطرها یا بعد فضای ویژگی مسئله خواهد بود. به نسبت تعداد ستون‌ها به سطرهای واژه‌نامه فراکامل، نرخ افزونگی^{۱۶} گفته می‌شود. واژه‌نامه D شامل L ستون یا اتم $\{d_i\}_{i=1}^L$ با نُرم واحد $\|d_{(i)}\|_2 = 1, \forall i = 1, \dots, L$ می‌باشد. همچنین ماتریس کدگذار K -تنک^{۱۷} X با $L \gg K$ شامل ضرایب بازنمایی ماتریس داده تصویر I_m است [۱۷-۱۵]. تنکی به این معنا است که هر بردار داده ورودی (هر ستون از ماتریس I) قابل کدگذاری توسط ترکیب خطی K اتم آموزش‌دیده بوده که به طور معمول K عدد کوچک است. بنابراین مسئله بازنمایی تنک به صورت زیر براساس بخش‌های خطای تقریب یا بازسازی و قید تنکی بیان می‌گردد [۱۷-۱۵]:

تعداد ضرایب غیرصفر در هر سطر از ماتریس ضرایب تنک X به صورت $\|x\|_0 = K$ بیان می‌شود که کاردینالیته^{۱۸} نام دارد. تکنیک یادگیری واژه‌نامه فراکامل و بازنمایی تنک برای اولین بار به منظور حذف نویز از داده تصویر ارائه و در ادامه الگوریتم K -SVD^{۱۹} پیشنهاد گردید که به نتایج مطلوبی در این زمینه منجر شد [۱۸]. یادگیری واژه‌نامه شامل دو مرحله کدگذاری تنک و بروزرسانی اتم‌ها است و به علت انعطاف‌پذیر بودن، روال کدگذاری تنک در آن با هر الگوریتم دلخواه قابل انجام می‌باشد. این الگوریتم‌ها براساس چگونگی تنظیم پارامترها، برای هر روش کدگذاری متفاوت می‌باشد. تنظیم نرخ تنکی باید با دقت انجام شود تا مقدار خطای تقریب از یک حد مطلوب افزایش پیدا نکند. گام بازنمایی تنک مورد استفاده در الگوریتم K -SVD، روش تعقیب تطابق متعامد^{۲۰} (OMP) می‌باشد [۱۸-۱۹].

هیستوگرام گرادیان جهت‌دار با اندازه سلول 8×8 و اندازه بلوک 2×2 استفاده می‌شود.

۳-۳- ماتریس هم‌رخداد سطوح خاکستری

پارامترهای استخراج‌شده از ماتریس هم‌رخداد سطوح خاکستری یکی دیگر از ویژگی‌های تعیین‌کننده خصوصیات بافت تصویر می‌باشد [۲۳-۲۴]. اطلاعات بیان‌کننده بافت یک تصویر را می‌توان به کمک یک ماتریس با مقادیر فراوانی نسبی $P(i,j)$ محاسبه نمود که مقدار هر درایه با شماره سطر i و شماره ستون j نمایانگر تعداد همسایگی‌های اتفاق افتاده با مقدار سطح خاکستری یکسان در جهت‌های مختلف $(0^\circ, 45^\circ, 90^\circ, 135^\circ, 180^\circ)$ است. به طور معمول، ضرایب این ماتریس به صورت مستقیم به عنوان ویژگی به منظور دسته‌بندی در نظر گرفته نمی‌شود بلکه پارامترهای آماری حاصل از آن در تعیین محتوای بافت تصویر مورد استفاده قرار می‌گیرد. این پارامترها شامل میانگین، واریانس، انرژي، محدوده تغییرات مقادیر فراوانی نسبی، کنتراست^{۲۳}، همگنی^{۲۴}، بی‌شبهتی^{۲۵}، حداکثر مقدار فراوانی نسبی، همبستگی^{۲۶} و آنتروپی^{۲۷} می‌باشد. انتخاب همه یا بخشی از این ویژگی‌های آماری مرتبه دوم در روال پردازش تصویر مبتنی بر تحلیل بافت موثر خواهد بود [۲۳].

۳-۴- مومنت^{۲۸}

ویژگی‌های آماری دیگر مورد بحث در زمینه پردازش تصویر که به علت غیرحساس بودن به چرخش^{۲۹} بسیار حائز اهمیت می‌باشند، پارامترهای مومنت استخراجی از تصویر است [۲۵-۲۶]. این مجموعه ویژگی که شامل هفت ضریب مومنت اول تا هفتم می‌باشد دارای این ویژگی است که مقادیر آن با چرخش تصویر در راستاهای مدنظر تغییر نمی‌کند. بنابراین در بحث تشخیص اهداف که چرخش در آن‌ها یکی از چالش‌های اساسی است بسیار حائز اهمیت خواهد بود.

۴- دسته‌بندی تصاویر ام‌آرآی در روش پیشنهادی

به منظور تشخیص تومور از تصاویر ام‌آرآی در الگوریتم پیشنهادی، در ابتدا برای هر دسته داده شامل مجموعه تصاویر مربوط به یک نوع تومور که نمونه‌هایی از آن در شکل (۱) نشان داده شده است استخراج ویژگی صورت می‌گیرد. همانطور که مشاهده می‌شود تصاویر مربوط به ۳ دسته تومور مغزی مننژیوم^{۳۰}، گلیوم^{۳۱} و هیپوفیز^{۳۲} می‌باشد که از مجموعه تومورهای مغزی متداول می‌باشند. در ادامه بخش‌های مختلف روش پیشنهادی توضیح داده شده و مورد بررسی دقیق قرار می‌گیرد.


۴-۱- بازنمایی تنک در روش پیشنهادی

همانطور که بیان شد، دسته‌بندی مناسب تصاویر هر کلاس داده می‌تواند با استفاده از یک ساختار مشخص که در اصطلاح به آن آموزش واژه‌نامه^{۳۳} گفته می‌شود صورت پذیرد تا برای هر دسته داده مربوط به یک نوع تومور مغزی یک مدل جامع آموزش دیده بدست آید. مرحله ابتدایی در یادگیری واژه‌نامه، کدگذاری تنک داده است. به کمک این روال تعیین می‌شود که هر تکه داده تصویر ورودی توسط چند اتم اجازه بازنمایی خواهد داشت. مفهوم تنکی در این بازنمایی به این معنی است که هر تکه داده تنها با ترکیب خطی از تعداد کمی اتم که مقدار آن با نرخ کاردینالیته^{۳۴} تعیین می‌گردد، قابل نمایش خواهد بود. مرحله بعدی در این الگوریتم‌ها، بروزسانی اتم‌های واژه‌نامه براساس تکه‌های داده ورودی است. از آنجاییکه واژه‌نامه فراکامل می‌باشد و ابعاد حل مسئله بر طبق رابطه (۱) بالا خواهد بود، حل این مسائل توسط دستگاه‌های معادلات خطی فرومعین^{۳۵} که در آن تعداد معادلات خطی بسیار کمتر از پارامترها است انجام می‌شود. بنابراین روال طراحی واژه‌نامه شامل دو مرحله بازنمایی تنک و بروزسانی واژه‌نامه است. در گام اول با فرض واژه‌نامه ثابت که به صورت تصادفی از تکه‌های داده یا ضرایب تصادفی انتخاب می‌شوند، ضرایب بازنمایی تنک محاسبه شده و در گام دوم، اتم‌های واژه‌نامه براساس این ماتریس ضرایب تنک بروزسانی می‌شوند. تفاوت اساسی میان الگوریتم‌های متفاوت یادگیری واژه‌نامه در نحوه محاسبه ضرایب تنک می‌باشد. روش بازنمایی تنک مورد استفاده در این مقاله در این بخش توضیح داده می‌شود و در بخش بعد، الگوریتم آموزش واژه‌نامه مورد بررسی قرار می‌گیرد. در الگوریتم دسته‌بندی تومورهای مغزی پیشنهادی، از روش بازنمایی تنک^{۳۶} LARC استفاده می‌شود که تعمیمی از الگوریتم LARS^{۳۷} است. شرط توقف برای محاسبه ضرایب تنک در این الگوریتم بر این اساس است که مقدار همدوسی اتم‌ها با تکه‌های تصویر ورودی می‌بایست از یک حد مشخص از پیش تعیین شده با نام همدوسی مانده^{۳۸} بیشتر گردد [۲۸-۲۷]. در این صورت اتم‌ها به شرط همدوسی با تکه‌های داده به منظور بازنمایی مناسب‌تر محتوای مجموعه آموزشی در نظر گرفته می‌شوند.

ویژگی دیگر الگوریتم LARC این است که در آن از نرخ تنکی متغیر به جای نرخ ثابت که در اکثر روش‌های بازنمایی مورد استفاده قرار می‌گیرد بهره گرفته شده است. به این صورت که حد بالایی برای پارامتر تنکی K تعیین می‌گردد و به کمک آن بیان می‌شود که هر تکه داده می‌تواند حداکثر با K اتم بازنمایی شود. این روش بازنمایی در ابتدا به منظور بازنمایی تنک سیگنال گفتار ارائه گردید [۲۷]. بازنمایی تنک با تکیه بر این تکنیک می‌تواند به صورت زیر بیان گردد:

$$X^* = LRAC(D, X, K, Coh) \quad (3)$$





شکل (۱): نمونه تصاویر ام آر آی مربوط به تومورهای: سطر اول: مننژیوم، سطر دوم: گلیوم، سطر سوم: هیپوفیز. در این تصاویر محدوده تومورها با رنگ قرمز مشخص شده است

مجموعه‌ای از داده‌های آموزش است [۱۸]. هر تکه تصویر ورودی در این روش به کمک این الگوریتم با ترکیب خطی تنکی از ضرایب K اتم بازنمایی داده می‌شود. آنچه در نحوه یادگیری ساختار داده ورودی حائز اهمیت خواهد بود این است که با در نظر گرفتن پارامتر همدوسی میان داده-اتم که در بخش قبل به آن اشاره شد و نیز پارامتر همدوسی میان اتم‌ها می‌توان خطای تقریب در بازنمایی تنک را بر طبق رابطه (۱) تا حد امکان کاهش داد. در مورد همدوسی میان اتم‌های واژه‌نامه، باید به این نکته توجه داشت که کمترین همدوسی میان اتم‌های واژه‌نامه وجود داشته باشد تا پایه‌های فضایی تا حد ممکن مستقل از یکدیگر حاصل و بازنمایی برای نمایش محتوای تکه‌های داده به بهترین وجه صورت گیرد. اهمیت پرداختن به این پارامترها زمانی بیشتر می‌شود که داده‌های آموزش متعلق به کلاس‌های مختلف از نظر ساختاری شباهت زیادی به یکدیگر داشته باشند. در این صورت این ماکزیمم مقدار مطلق باید مقدار کوچکی داشته باشد تا مدل با پایه‌های فضایی تا حد ممکن مستقل حاصل گردد [۲۷]. با توجه به ابعاد بالای مسئله، به طور معمول طراحی و یافتن واژه‌نامه با این خصوصیت کار مشکلی خواهد بود و از روش‌های تقریبی به منظور دستیابی به واژه‌نامه ناهمدوس استفاده می‌شود. در حل تقریبی این مسئله باید به ماتریس گرام^{۴۲} واژه‌نامه $G = D^T D$ توجه شود زیرا اگر ماتریس گرام یک واژه‌نامه به فرم ماتریس یکه واحد باشد نشاندهنده آن است که اتم‌های آن واژه‌نامه تا حد ممکن مستقل خواهند بود [۲۸، ۳۰]. حل تقریبی برای هر ابعاد دلخواه از واژه‌نامه به منظور دستیابی به ماتریس گرام با این ویژگی مورد توجه قرار می‌گیرد که یکی از آن‌ها پس‌پردازش واژه‌نامه می‌باشد. در [۳۱]، یک روش چرخش و تصویر کردن تکرارشونده^{۴۳} (IPR) معرفی گردیده تا ماتریس گرام تا

K ، در این رابطه نرخ تنکی یا کاردینالیته متغیر و پارامتر Coh ، بیانگر میزان همدوسی مانده خواهد بود. در تنظیم نرخ کاردینالیته باید توجه داشت که تنظیم نادرست منجر به اغتشاش منبع^{۴۴} یا اعوجاج منبع^{۴۵} نگردد. اغتشاش منبع وقتی رخ می‌دهد که یک مقدار زیاد برای این پارامتر در نظر گرفته شود. این امر موجب می‌گردد که کدگذاری انبوه و نامناسبی با توجه به این تعداد زیاد اتم‌های منتخب نتیجه شود. از طرف دیگر اعوجاج منبع زمانی رخ می‌دهد که بازنمایی تنک با نرخ تنکی پایین انجام یا بازنمایی بسیار تنک باشد. به این معنی که ترکیب خطی اتم‌ها برای بازنمایی تکه‌های داده کافی نیست که در این صورت خطای تقریب افزایش می‌یابد. همچنین در انتخاب پارامتر Coh که بیانگر همدوسی میان اتم و داده می‌باشد باید توجه داشت که اگر مقدار این پارامتر زیاد انتخاب شود آنگاه موجب می‌شود که تنها اتم‌هایی که همدوسی بالاتر از این مقدار را دارند در واژه‌نامه شرکت داده شوند که تعداد آن‌ها کم بوده و ممکن است در طراحی واژه‌نامه فراکامل با نرخ افزونگی دلخواه مشکل ایجاد شود. همچنین اگر مقدار این پارامتر کم انتخاب شود آنگاه پارامتر همدوسی میان داده و اتم در طراحی اتم‌های واژه‌نامه همدوس با داده تاثیر چندانی نخواهد داشت.

۴-۲- آموزش واژه‌نامه در روش پیشنهادی

همانطور که بیان گردید، تکنیک یادگیری مدل به کمک واژه‌نامه‌ها یکی از روال‌های جدید بکارگرفته شده در حوزه‌های مختلف پردازشی مانند تشخیص پلاک خودرو می‌باشد [۲۹]. الگوریتم یادگیری واژه‌نامه مبتنی بر K -SVD^{۴۱}، یک روال مناسب برای آموزش اتم‌ها براساس

$$E_M = \frac{1}{L} \sum_{l=1}^L X_{M,l}^{*2}, E_G = \frac{1}{L} \sum_{l=1}^L X_{G,l}^{*2}, \quad (6)$$

$$E_P = \frac{1}{L} \sum_{l=1}^L X_{P,l}^{*2}$$

از آنجاییکه داده هر کلاس نباید بر روی اتم‌های واژه‌نامه‌های مربوط به کلاس‌های دیگر داده بازنمایی داشته باشند بنابراین اتم‌های از واژه‌نامه دیگر که بیشترین انرژی را در بازنمایی داده غیر از کلاس خود دارند حذف می‌شوند. این روال برای بازنمایی هر یک از سه کلاس داده انجام شده و اتم‌هایی که انرژی ضرایب تنک بیشتر از حد تعریف شده مشخصی در کدگذاری کلاس‌های غیرمرتبط دارند نادیده گرفته می‌شوند. با توجه به این روال، خطای دسته‌بندی داده کلاس‌های مختلف تا حد ممکن برطرف می‌گردد. میزان این آستانه انرژی با توجه به نتایج تجربی حاصل به میزان ۰/۳۵ تنظیم شده است.

۴-۳- روال پیشنهادی برای دسته‌بندی داده تومورهای مغزی

در آموزش واژه‌نامه این نکته حائز اهمیت خواهد بود که بتوان اتم‌های را به گونه‌ای آموزش داد که بیشترین میزان همدوسی با داده آموزش، کمترین میزان همدوسی با سایر اتم‌های یک واژه‌نامه و نیز با اتم‌های سایر کلاس‌های داده داشته باشند و نحوه رسیدن به این مهم در بخش‌های قبل توضیح داده شد. در این بخش روال پیشنهادی برای دسته‌بندی داده‌های مربوط به انواع تومور مغزی به کمک تصاویر ام‌آرآی براساس واژه‌نامه‌های ناهمدوس آموزش دیده مورد بررسی قرار می‌گیرد. در این مقاله به منظور طبقه‌بندی داده ورودی، دسته‌بندی‌های متداول مانند انواع شبکه‌های عصبی و ماشین بردار پشتیبان استفاده نمی‌شود بلکه پیشنهاد می‌گردد که با توجه به ویژگی‌های استخراج شده از الگوریتم کدگذاری تنک معرفی شده در بخش ۴-۱، یک دسته‌بند مبتنی بر آموزش واژه‌نامه طراحی و مورد استفاده قرار گیرد. روال آشکارسازی پیشنهادی به این صورت است که در ابتدا بازنمایی تنک تصویر ورودی به کمک روش LARC بر روی واژه‌نامه مرکب معرفی شده در بخش قبل با همان مقدار ضریب تنکی تنظیم شده برای هر واژه‌نامه در گام آموزش صورت می‌پذیرد. سپس انرژی ضرایب بازنمایی تنک حاصل بر روی هر واژه‌نامه D_M ، D_G و D_P محاسبه می‌شود. با توجه به اینکه اگر داده تصویر ورودی مربوط به هر نوع تومور مغزی باشد، انرژی بازنمایی بیشتری بر روی واژه‌نامه مربوطه دارد، بنابراین از معیار انرژی ضرایب تنک حاصل برای دسته‌بندی داده ورودی به کلاس مطلوب استفاده می‌گردد. بنابراین انرژی بازنمایی بر روی واژه‌نامه‌های مختلف مشابه با آنچه در رابطه (۶) بیان گردید محاسبه شده و واژه‌نامه با بیشینه انرژی حاصل، کلاس داده ورودی را مشخص خواهد کرد. در این صورت نیازی به استفاده از سایر دسته‌بندها نخواهد بود و تخمین برچسب داده ورودی تنها به کمک استفاده از تکنیک بازنمایی تنک امکان‌پذیر خواهد بود. بلوک دیاگرام

حد ممکن واحد برای هر واژه‌نامه بدست آید. در گام اول این روش، ضرایب غیرقطری ماتریس گرام توسط مجموعه قیودی که قیود ساختاری نامیده می‌شوند، آستانه‌گذاری شده و تعداد مقادیر ویژه غیرصفر آن محدود می‌گردد. در این آستانه‌گذاری، ضرایب غیرقطری که در حالت ایده‌آل ماتریس گرام می‌بایست صفر باشند به یک مقدار همدوسی تعیین شده μ_0 بسیار کوچک تنظیم می‌شوند تا نرم فریبیوسی^{۴۴} خطای میان ماتریس گرام و ماتریس یک واحد $\|G-I\|_F$ کاهش یابد. در ادامه مقادیر ویژه ماتریس گرام محدود می‌شود. این روال به کمک حفظ تنها N بزرگترین مقادیر ویژه صورت می‌پذیرد. در گام دوم از چرخش اتم‌های واژه‌نامه به کمک یک ماتریس متعامد^{۴۵} W استفاده می‌شود تا خطای تقریب با توجه به آستانه‌گذاری‌های انجام شده در مرحله اول افزایش نیابد. بنابراین با اعمال این ماتریس سعی می‌شود تا خطای $\|I-WDX\|_F$ کاهش یابد. این تکنیک در ابتدا به منظور بهبود روال بازسازی سیگنال موسیقی ارائه شد و در این مقاله به منظور بهبود روال آموزش واژه‌نامه‌های مورد استفاده در دسته‌بندی تومورهای مغزی مورد استفاده قرار می‌گیرد [۳۱].

در مسئله پیش رو واژه‌نامه‌های آموزش دیده برای هر کلاس داده می‌بایست تا حد ممکن مشابه نباشند و تمایز میان دسته‌های مختلف به خوبی برقرار باشد. بنابراین این ویژگی که اتم‌های واژه‌نامه‌های مرتبط با هر یک از کلاس‌ها کمترین میزان همدوسی را با اتم‌های واژه‌نامه‌های دیگر کلاس‌ها داشته باشند، حائز اهمیت خواهد بود. بنابراین آنچه مهم است این خواهد بود که آیا اتم‌های دارای ساختار مشابه در واژه‌نامه مرتبط با هر کلاس داده وجود دارد یا خیر. اگر شباهت میان اتم‌های آموزش دیده وجود داشته باشد آنگاه می‌بایست روالی به منظور کاهش این وابستگی اتخاذ شود. در روش پیشنهادی به منظور تصحیح این مشکل و کاهش همدوسی میان اتم‌های واژه‌نامه یک کلاس، در ابتدا یک واژه‌نامه مرکب $D=[D_M \ D_G \ D_P]$ متشکل از واژه‌نامه‌های مرتبط با داده تومور مننژیوم D_M ، گلیوم D_G و هیپوفیز D_P ساخته می‌شود. سپس کدگذاری تنک داده مربوط به هر نوع تومور بر روی این واژه‌نامه مرکب صورت می‌گیرد:

$$X_M^*, X_G^*, X_P^* = \text{LARC}(I, [D_M \ D_G \ D_P], \text{coh})$$

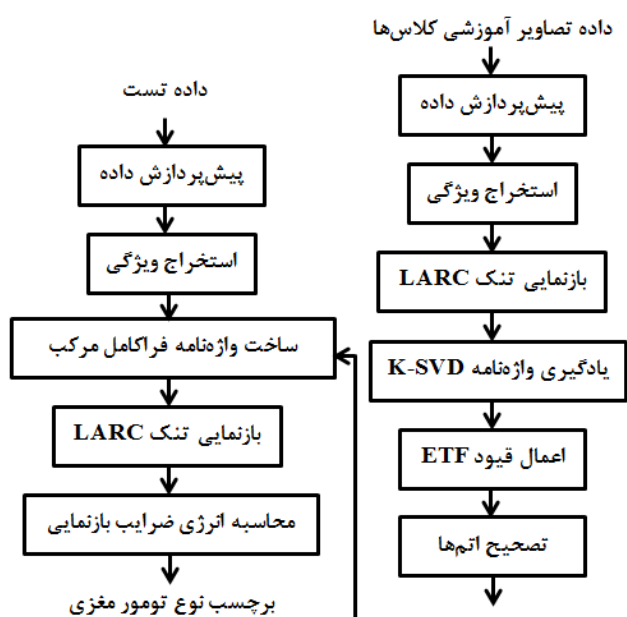
$$\rightarrow \arg \min_{X_M, X_G, X_P} \|I - [D_M \ D_G \ D_P] \begin{bmatrix} X_M \\ X_G \\ X_P \end{bmatrix}\|_F^2 \quad (5)$$

در این رابطه X_M^* و X_G^* و X_P^* به ترتیب بیانگر انرژی ضرایب بازنمایی تنک برای داده تومور مننژیوم، گلیوم و هیپوفیز می‌باشد. پارامتر coh نیز میزان همدوسی مانده را نشان می‌دهد. در ادامه انرژی ضرایب بازنمایی تنک مربوط به داده تومور مننژیوم E_M ، گلیوم E_G و هیپوفیز E_P محاسبه می‌گردد:



داده‌های هر کلاس استفاده شده و مابقی در روال تست و به منظور ارزیابی بکارگرفته شده است. ارزیابی عملکرد الگوریتم‌ها به کمک نرخ دقت دسته‌بندی^{۴۶} تعیین می‌شود که توسط درصد داده‌های درست طبقه‌بندی‌شده به کل داده‌های تست محاسبه می‌گردد. استخراج ویژگی در آزمایش‌های این بخش به کمک توصیف‌گر هیستوگرام گرادین جهت‌دار HOG با اندازه سلول ۸×۸ با ۵۰ درصد همپوشانی و اندازه بلوک ۲×۲ صورت می‌گیرد. بعد ویژگی‌های مبتنی بر HOG برای تصویر پیش‌پردازش شده با ابعاد ۶۴×۶۴ برای ۹ بین و ۴ جهت مشخص شده برابر با ۱۷۶۴ می‌باشد.

مقدار حد پایین همدوسی اتم-داده در الگوریتم LARC بکارگرفته شده با توجه به نتایج شبیه‌سازی‌های انجام شده برابر با ۰/۵ می‌باشد.



شکل (۲): بلوک دیاگرام روش پیشنهادی به منظور دسته‌بندی داده تومورهای مغزی مختلف


روش پیشنهادی شامل تمامی مراحل در گام آموزش و تست در شکل (۲) نشان داده شده است. این روش مشابه روش دسته‌بندی ارائه شده در [۳۲] می‌باشد که به منظور شناسایی ارقام برنج و تعیین اصالت آن‌ها مورد استفاده قرار گرفته است. در این دسته‌بندی، ویژگی‌های مختلف بافتی و آماری براساس مفاهیم بازنمایی تنک مورد بررسی و شبیه‌سازی قرار گرفت و بهترین بردار ویژگی مناسب برای این دسته‌بندی پیشنهاد گردید.

۵- شبیه‌سازی روش پیشنهادی

به منظور شبیه‌سازی نتایج حاصل از روش پیشنهادی، از مجموعه تصاویر ام‌آرآی دوبعدی استفاده شده است [۳۳]. این تصاویر حاصل از تصویربرداری CE-MRI با T1-weighted می‌باشند که در طی سال‌های ۲۰۰۵ تا ۲۰۱۰ از ۲۳۳ بیمار جمع‌آوری شده است. این مجموعه شامل ۳۰۶۴ تصویر از سه نوع تومور مغزی می‌باشد که ۷۰۸ تصویر مربوط به غده مننژیوم، ۱۴۲۶ تصویر مربوط به غده گلیوم و ۹۳۰ تصویر مربوط به غده هیپوفیز می‌باشد. ابعاد این تصاویر ۵۱۲×۵۱۲ بوده و اندازه پیکسل‌ها ۰/۴۹×۰/۴۹ میلی‌متر مربع است. در مرحله پیش‌پردازش روش پیشنهادی، ابتدا سطوح خاکستری هر تصاویر ام‌آرآی بدست آمده و سپس ابعاد تصویر به یک هشتم ابعاد اولیه کاهش می‌یابد.

۵-۱- جزئیات شبیه‌سازی

در روش پیشنهادی از آموزش واژه‌نامه به منظور دسته‌بندی انواع تومور مغزی استفاده می‌شود. در شبیه‌سازی‌های انجام شده از ویژگی‌های مختلف معرفی شده در بخش ۳ به عنوان داده آموزشی استخراج شده از تصاویر بهره گرفته می‌شود. نرخ تنکی مورد نیاز در کدگذاری تنک به کمک الگوریتم LARC بستگی به بعد داده آموزش داشته و برای هر روال استخراج ویژگی متفاوت می‌باشد. پارامتر همدوسی Coh که در روابط ۶ و ۸ مورد استفاده قرار گرفته اس در تمامی شبیه‌سازی‌ها به مقدار ۰/۲۵ تنظیم گردیده است. نرخ افزونگی برای واژه‌نامه‌های فراکامل تمامی کلاس‌های تومور مغزی بسته به نوع ویژگی‌ها تنظیم می‌گردد که بیان می‌کند هر واژه‌نامه‌ها با چه نرخ افزونگی، فراکامل خواهد بود. به منظور یادگیری واژه‌نامه در گام آموزش، از ۷۰٪



شکل (۳): نمونه‌ای از ویژگی‌های HOG استخراج شده از (الف) تومور مننژیوم، (ب) تومور گلیوم، (ج) تومور هیپوفیز

۵-۲- نتایج شبیه‌سازی

نمونه‌ای از ویژگی‌های HOG استخراج شده از تومورهای مورد بررسی در شکل (۳) نشان داده شده است. در ادامه استخراج ویژگی به کمک ضرایب LBP از نوع تغییرناپذیر با چرخش^{۴۷} و با سلول‌های ۲×۲ غیرهمپوشان انجام می‌شود. بعد ویژگی‌های مبتنی بر LBP برای هر تصویر برابر با ۱۰ خواهد بود. با استخراج ویژگی به کمک ضرایب ماتریس هم‌رخداد سطح خاکستری GLCM، پارامترهای مهم حاصل از آن مورد بررسی قرار می‌گیرد. این پارامترهای انتخابی شامل نه ویژگی میانگین، واریانس، انرژي، محدوده تغییرات مقادیر فراوانی نسبی، کنتراست، همگنی، حداکثر مقدار فراوانی نسبی، همبستگی و آنتروپی می‌باشند. ضرایب ماتریس هم‌رخداد سطح خاکستری در چهار جهت ۰°، ۴۵°، ۹۰° و ۱۳۵° محاسبه و پارامترهای ذکر شده در این جهت‌ها بدست می‌آیند. در نتیجه برای تصویر ورودی یک بردار ویژگی با ۳۶ ضریب حاصل می‌گردد.

به کمک ویژگی‌های مبتنی بر مومنت‌ها نیز، هفت ضریب شاخص از هر تصویر ورودی استخراج می‌شود که این ضرایب نیز مستقل از چرخش تصویر هستند. نتایج حاصل از طبقه‌بندی دو به دوی داده‌های تومور مغزی توسط دسته‌بند پیشنهادی مبتنی بر واژه‌نامه و نیز دسته‌بندهای شبکه عصبی و ماشین بردار پشتیبان بدون گام استخراج ویژگی و تنها با تکیه بر تکه‌های استخراج شده و اتم‌های آموزش دیده براساس آن در جدول (۱) گزارش شده است. تعداد لایه پنهان برای شبکه عصبی بکارگرفته شده ۳۵ می‌باشد.

نرخ تنکی برای ماتریس داده مبتنی بر سطوح خاکستری استخراج شده از تکه‌های تصویر ورودی در گام آموزش و تست به مقدار ۲۰ تنظیم شده است. همچنین نتایج حاصل از طبقه‌بندی هر سه کلاس داده تومورهای مغزی توسط دسته‌بندهای نام برده شده براساس تکه‌های استخراج شده از تصویر ورودی در جدول (۲) بیان شده است. در محاسبه این نتایج از ماشین بردار پشتیبان چند کلاسه استفاده شده است [۳۴]. تکه‌های استخراج شده از تصویر ۸×۸ بوده و بنابراین بعد مسئله ۶۴ می‌باشد. نرخ افزودگی برای واژه‌نامه‌های فراکامل با

ماتریس داده آموزش شامل این ضرایب به مقدار ۴ تنظیم شده است. نتایج حاصل نشان می‌دهد که کلاس‌بندی داده مورد نظر با تکیه بر دسته‌بند پیشنهادی مبتنی بر آموزش واژه‌نامه توانسته است به نتایج بهتری نسبت به شبکه عصبی و ماشین بردار پشتیبان دست پیدا نماید.

جدول (۱): درصد دقت دسته‌بندی دو به دوی تومورهای مغزی براساس سطوح خاکستری برای دسته‌بندهای شبکه عصبی، ماشین بردار پشتیبان و روش پیشنهادی مبتنی بر واژه‌نامه

روش پیشنهادی	ماشین بردار پشتیبان [۹]	شبکه عصبی [۸]	داده مننژیوم/گلیوم
۸۶/۶۵	۸۰/۸۷	۸۱/۲۳	
۹۲/۲۷	۸۹/۳۲	۹۰/۵۱	داده گلیوم/هیپوفیز
۹۱/۷۱	۸۹/۵۰	۸۸/۳۱	داده مننژیوم/هیپوفیز

جدول (۲): درصد دقت دسته‌بندی تومورهای مغزی براساس سطوح خاکستری برای دسته‌بندهای شبکه عصبی، ماشین بردار پشتیبان و روش پیشنهادی مبتنی بر واژه‌نامه

روش پیشنهادی	ماشین بردار پشتیبان [۹]	شبکه عصبی [۸]	داده مننژیوم
۶۱/۲۳	۳۵/۹۲	۳۸/۱۵	
۶۷/۵۹	۶۳/۱۶	۵۹/۶۲	داده گلیوم
۹۰/۸۸	۸۹/۲۵	۸۸/۷۶	داده هیپوفیز

جدول (۳): درصد دقت دسته‌بندی دو به دوی تومورهای مغزی براساس ویژگی HOG برای دسته‌بندهای شبکه عصبی، ماشین بردار پشتیبان و روش پیشنهادی مبتنی بر واژه‌نامه

روش پیشنهادی	ماشین بردار پشتیبان [۹]	شبکه عصبی [۸]	داده مننژیوم/گلیوم
۹۴/۵۴	۹۳/۶۱	۹۲/۳۳	
۹۵/۵۰	۹۰/۷۶	۹۲/۵۴	داده گلیوم/هیپوفیز
۹۴/۸۱	۹۳/۳۶	۹۳/۲۸	داده مننژیوم/هیپوفیز

جدول (۴): درصد دقت دسته‌بندی تومورهای مغزی براساس ویژگی HOG برای دسته‌بندهای شبکه عصبی، ماشین بردار پشتیبان و روش پیشنهادی مبتنی بر واژه‌نامه

روش پیشنهادی	ماشین بردار پشتیبان [۹]	شبکه عصبی [۸]	داده مننژیوم
۵۹/۶۷	۴۲/۲۳	۳۱/۳۵	
۸۹/۵۸	۷۸/۴۱	۷۶/۷۸	داده گلیوم
۹۴/۳۹	۹۲/۶۹	۹۰/۵۸	داده هیپوفیز

نتایج حاصل از دسته‌بندی دو به دو و کامل تومورهای مغزی براساس ویژگی HOG با بعد مسئله ۱۷۶۴ برای دسته‌بندهای شبکه عصبی، ماشین بردار پشتیبان و روش پیشنهادی مبتنی بر واژه‌نامه به ترتیب در جدول (۳) و (۴) آورده شده است. نرخ تنکی و نرخ افزودگی برای این ویژگی‌ها به ترتیب به مقدار ۱۰۰ و ۲ تنظیم شده است. از آنجاییکه با انجام شبیه‌سازی‌ها این نتیجه حاصل شد که این ویژگی به تنهایی برای دسته‌بندی در این مسئله کفایت نمی‌کند، بردار ویژگی حاصل در ترکیب با سایر ویژگی‌ها مورد استفاده قرار گرفت. این

جدول (۵): درصد دقت دسته‌بندی دو به دوی تومورهای مغزی براساس ویژگی‌های ترکیبی GLCM/MOM/LBP برای دسته‌بندهای شبکه عصبی، ماشین بردار پشتیبان و روش پیشنهادی

مبتنی بر واژه‌نامه

روش پیشنهادی	ماشین بردار پشتیبان [۹]	شبکه عصبی [۸]	
۷۹/۶۲	۷۰/۵۲	۷۳/۶۱	داده مننژیوم/گلیوم
۹۴/۲۲	۸۹/۶۵	۹۲/۳۶	داده گلیوم/هیپوفیز
۹۵/۳۱	۹۰/۳۶	۸۹/۵۴	داده مننژیوم/هیپوفیز

جدول (۶): درصد دقت دسته‌بندی تومورهای مغزی براساس ویژگی‌های ترکیبی GLCM/MOM/LBP برای دسته‌بندهای شبکه عصبی، ماشین بردار پشتیبان و روش پیشنهادی مبتنی بر واژه‌نامه

واژه‌نامه

روش پیشنهادی	ماشین بردار پشتیبان [۹]	شبکه عصبی [۸]	
۵۱/۷۰	۳۳/۷۴	۲۸/۳۵	داده مننژیوم
۷۳/۳۶	۵۹/۲۸	۵۷/۶۴	داده گلیوم
۹۶/۵۹	۹۳/۳۸	۹۰/۳۶	داده هیپوفیز

جدول (۷): درصد دقت دسته‌بندی دو به دوی تومورهای مغزی براساس ویژگی‌های ترکیبی GLCM/MOM/LBP/HOG برای دسته‌بندهای شبکه عصبی، ماشین بردار پشتیبان و روش پیشنهادی

مبتنی بر واژه‌نامه

روش پیشنهادی	ماشین بردار پشتیبان [۹]	شبکه عصبی [۸]	
۹۷/۷۷	۹۳/۳۷	۹۱/۲۴	داده مننژیوم/گلیوم
۹۹/۸۱	۹۵/۴۱	۹۶/۳۳	داده گلیوم/هیپوفیز
۹۹/۲۰	۹۶/۵۵	۹۵/۶۵	داده مننژیوم/هیپوفیز

جدول (۸): درصد دقت دسته‌بندی تومورهای مغزی براساس ویژگی‌های ترکیبی GLCM/MOM/LBP/HOG برای دسته‌بندهای شبکه عصبی، ماشین بردار پشتیبان و روش پیشنهادی

مبتنی بر واژه‌نامه

روش پیشنهادی	ماشین بردار پشتیبان [۹]	شبکه عصبی [۸]	
۷۹/۲۴	۶۱/۷۵	۶۹/۲۱	داده مننژیوم
۸۹/۶۵	۶۳/۳۲	۶۴/۷۶	داده گلیوم
۹۸/۱۳	۹۴/۱۱	۹۳/۱۲	داده هیپوفیز

جدول (۹): درصد دقت دسته‌بندی تومورهای مغزی براساس ویژگی‌های ترکیبی GLCM/MOM/LBP/HOG در روش پیشنهادی مبتنی بر واژه‌نامه و بدون گام تصحیح اتم‌ها

واژه‌نامه و بدون گام تصحیح اتم‌ها

روش پیشنهادی	روش پیشنهادی بدون گام تصحیح اتم‌ها	
۷۹/۲۴	۷۳/۱۲	داده مننژیوم
۸۹/۶۵	۸۴/۲۶	داده گلیوم
۹۸/۱۳	۹۵/۷۱	داده هیپوفیز

ویژگی ترکیبی شامل ضرایب حاصل از الگوی باینری محلی (LBP) با بعد ۱۰ برای هر داده تصویر و مومنت‌ها (Moments) با بعد ۷ برای هر داده تصویر و نیز ۳۶ ویژگی حاصل از GLCM خواهد بود که نتایج دسته‌بندی براساس آن در جداول (۵) و (۶) گزارش شده است. نتایج حاصل با تنظیم نرخ تنکی و نرخ افزونگی به ترتیب به مقدار ۱۰ و ۴ حاصل شده است. ابعاد ماتریس آموزش در هنگام استفاده از این ویژگی‌های ترکیبی با نام GLCM/HOG/LBP برای هر کلاس داده تومور مننژیوم، گلیوم و هیپوفیز به ترتیب برابر با ۵۳×۴۹۶ ، ۵۳×۹۹۹ و ۵۳×۶۵۱ می‌باشد.

به منظور استفاده از تمامی ویژگی‌های آماری و مبتنی بر بافت بیان شده، یک دسته ویژگی ترکیبی از تمامی این ضرایب با نام GLCM/MOM/LBP/HOG محاسبه و به منظور دسته‌بندی مورد استفاده قرار گرفت. نتایج حاصل از این دسته ویژگی ترکیبی در جداول (۷) و (۸) به ترتیب برای دسته‌بندی دو به دوی تومورها و دسته‌بندی کلی تصاویر نشان داده شده است. ابعاد ماتریس آموزش در هنگام استفاده از این ویژگی‌های ترکیبی با نام GLCM/HOG/LBP برای هر کلاس داده تومور مننژیوم، گلیوم و هیپوفیز به ترتیب برابر با ۱۸۱۷×۴۹۶ ، ۱۸۱۷×۹۹۹ ، ۱۸۱۷×۶۵۱ می‌باشد. نتایج حاصل با نرخ تنکی و نرخ افزونگی به ترتیب به مقدار ۱۰۰ و ۲ بدست آمده است. نتایج بدست آمده نشان می‌دهد که بکارگیری ویژگی‌ها آماری مانند پارامترهای استخراج شده از ضرایب GLCM و مومنت‌ها، در کنار ویژگی‌های دیگر مبتنی بر بافت مانند LBP و HOG به نتایج مطلوبی در حوزه دسته‌بندی داده‌های تومور مغزی منتهی می‌گردد.

به منظور بررسی عملکرد گام تصحیح اتم‌های پیشنهاد شده در بخش قبل، نتایج حاصل از دسته‌بندی پیشنهادی مبتنی بر یادگیری مدل بدون گام تصحیح اتم‌ها در جدول (۹) گزارش شده که نشان می‌دهد که این گام و حذف اتم‌های با کارایی مشابه در بازنمایی داده ورودی، در افزایش دقت دسته‌بندی تاثیرگذار بوده است.

جدول (۱۰): مقدار همدوسی متقابل میان اتم-داده، همدوسی میان اتم‌های واژه‌نامه‌ها و همدوسی میان اتم‌های واژه‌نامه‌های مختلف برای روش

پیشنهادی

همدوسی واژه‌نامه‌های مختلف			همدوسی اتم‌های واژه‌نامه‌ها			همدوسی اتم-داده		
منزئوم / هیپوفیز	گلیوم / هیپوفیز	منزئوم / گلیوم	هیپوفیز	گلیوم	منزئوم	هیپوفیز	گلیوم	منزئوم
۰/۸۲	۰/۷۸	۰/۷۳	۰/۷۳	۰/۶۹	۰/۷۴	۰/۴۸	۰/۵۱	۰/۴۵
۰/۷۳	۰/۷۷	۰/۸۰	۰/۶۸	۰/۶۶	۰/۷۱	۰/۷۲	۰/۸۳	۰/۷۶
۰/۶۹	۰/۷۲	۰/۷۸	۰/۴۱	۰/۴۴	۰/۳۵	۰/۷۵	۰/۸۴	۰/۷۵
۰/۵۳	۰/۴۹	۰/۵۱	۰/۴۲	۰/۴۳	۰/۳۴	۰/۷۷	۰/۸۳	۰/۷۴

۶- نتیجه‌گیری

کاربردهای پزشکی یکی از زمینه‌های مهم عملکرد پردازش تصویر است و به جهت این اهمیت، در این مقاله به ارائه راهکاری به منظور دسته‌بندی تومورهای مغزی پرداخته شده است. در روش پیشنهادی از تکنیک‌های بازنمایی تنک و یادگیری واژه‌نامه به منظور محاسبه مدل‌های فراکامل بهره گرفته می‌شود و از ویژگی‌های حاصل از این مفاهیم در طراحی یک دسته‌بند برپایه مدل استفاده می‌گردد. روال پیشنهادی به منظور آموزش واژه‌نامه‌ها و نیز گام تصحیح اتم‌ها موجب یادگیری مدل‌های فراکاملی می‌گردد که در آن‌ها سه ویژگی بیشترین همدوسی میان اتم‌ها و داده، کمترین همدوسی میان اتم‌های یک واژه‌نامه و نیز کمترین میزان همدوسی میان اتم‌های یک واژه‌نامه نسبت به اتم‌های واژه‌نامه دیگر رعایت شده است. استخراج ویژگی در این مقاله به کمک ویژگی‌های مبتنی بر بافت و پارامترهای آماری مختلفی انجام شده و نتایج با یکدیگر مورد مقایسه قرار گردیده است. در نهایت این نتیجه حاصل شد که ترکیب ویژگی‌های آماری مبتنی بر مومنت‌ها و ماتریس هم‌رخداد سطوح خاکستری در کنار ویژگی الگوی باینری محلی و هیستوگرام گرادیان جهت‌دار توانسته است تا نتایج مناسب‌تری را به منظور دسته‌بندی تومورهای مغزی مشاهده شده در تصاویر ام‌آرآی نسبت به دسته‌بندهای مبتنی بر شبکه عصبی و ماشین بردار پشتیبان بدست دهد.

مراجع

- [1] Pauline, J., "Brain tumor classification using wavelet and texture based neural network", International Journal of Scientific & Engineering Research, Vol. 3, No. 10, 2012.
- [2] Zulpe, N., Pawar, V., "GLCM textural features for brain tumor classification", IJCSI International Journal of Computer Science Issues, Vol. 9, pp. 354-359, 2012.
- [3] Jain, S., "Brain cancer classification using GLCM based feature extraction in artificial neural network" International Journal of Computer Science & Engineering Technology Vol. 4, No. 7, pp. 966-970, 2013.
- [4] Preethi, G., Sornagopal, V., "MRI image classification using GLCM texture features", International Conference on Green Computing Communication and Electrical Engineering (ICGCCCE), Coimbatore, pp. 1-6, 2014.

همچنین تاثیر گام‌های بازنمایی تنک LARC، پس‌پردازش ETF^{FA} واژه‌نامه‌ها و نیز تصحیح اتم‌های واژه‌نامه‌های مختلف بر روی همدوسی متقابل میان اتم-داده، همدوسی میان اتم‌های یک واژه‌نامه‌ها و نیز همدوسی میان اتم‌های یک واژه‌نامه با سایر کلاس‌ها در جدول (۱۰) بیان شده است. همانطور که گزارش شده است نتایج پارامترهای همدوسی براساس واژه‌نامه آموزش‌دیده به کمک الگوریتم بازنمایی تنک مبتنی بر روش تعقیب تطابق متعامد OMP که در آن قیدی بر روی مقدار همدوسی‌ها لحاظ نشده است پایین‌تر از سایر الگوریتم‌ها می‌باشد. با بکارگیری روال بازنمایی تنک LARC که براساس افزایش قید همدوسی اتم-داده عمل نموده و در آن تنها اتم‌هایی که دارای قید همدوسی اتم-داده بیشتر از حد معینی باشند در تشکیل واژه‌نامه شرکت داده می‌شوند، نتایج این پارامتر افزایش داشته است که موجب کاهش خطای بازسازی سیگنال می‌گردد. کاهش این خطا در بازنمایی گام تست دسته‌بند بسیار تاثیرگذار است زیرا انرژی بازنمایی درست را افزایش داده و به تشخیص درست کلاس داده ورودی کمک می‌نماید. با افزودن گام پس‌پردازش واژه‌نامه به منظور دستیابی به واژه‌نامه‌های ETF ، همدوسی اتم‌های واژه‌نامه تا حد ممکن کاهش می‌یابد زیرا ماتریس گرام واژه‌نامه‌ها تا حد ممکن به ماتریس یک واحد نزدیک می‌شود. مقدار این پارامتر همدوسی با توجه به رابطه (۴) محاسبه شده است. در روش پیشنهادی از گام تصحیح اتم‌ها با توجه به اتم‌های سایر کلاس‌ها نیز استفاده شده است. در این گام بازنمایی تنک داده هر کلاس بر روی واژه‌نامه مرکب انجام می‌شود و سپس اتم‌های واژه‌نامه‌های سایر کلاس‌ها که انرژی بازنمایی زیادی در کد کردن داده کلاس مجاور دارند از واژه‌نامه حذف می‌شوند تا امکان بروز خطا در گام دسته‌بندی داده‌های تست به حداقل میزان ممکن برسد. میزان این حد انرژی همانطور که بیان گردید به $0/35$ برای هر سه واژه‌نامه تنظیم شده است. نتایج نشان می‌دهد که روش پیشنهادی که هر سه گام تصحیح میزان پارامتر همدوسی را شامل می‌شود توانسته است به مقادیر مطلوب همدوسی دست پیدا نماید.



- Mitsubishi Electric Research Laboratories, Cambridge, MA, 1994.
- [22] Dalal, N., Triggs, B. "Histograms of oriented gradients for human detection", In Proc. IEEE Comput. Soc. Conf. Comput. Vis. Pattern Recognit., Vol. 1, pp. 886-893, 2005.
- [23] Majumdar, S., Jayas, D. S., "Classification of cereal grains using machine vision: I. Morphology models", Transactions of the ASAE, Vol. 43, No. 6, pp. 1669-1675, 2000.
- [24] م. ابوالقاسمی، ح. آقایی نیا، ک. فائز، "پنهان‌شکنی تصویر براساس ویژگی‌های ماتریس هم‌وقوعی"، مجله مهندسی برق و الکترونیک ایران، جلد ۷، شماره ۱، ۱۵-۲۴، ۱۳۸۹.
- [25] Nixon, M., Aguado, A., "Feature Extraction & Image Processing", 2nd Edition, Academic Press, Cambridge, 2008.
- [26] Flusser, J., Suk, T., & Zitová, B., "Moments and moment invariants in pattern recognition", Chichester, West Sussex, U.K: J. Wiley, 2009.
- [27] Sigg, C. D., Dikk, T., Buhmann, J. M., "Speech enhancement using generative dictionary learning", IEEE Transactions on Audio, Speech and Language Processing, Vol. 20, No. 6, pp.1698-1712, 2012.
- [28] Efron, B., Hastie, T., Johnstone, I., Tibshirani, R., "Least angle regression", Ann. Stat., Vol. 32, pp. 407-499, 2004.
- [29] و. ابوالقاسمی، س. فردوسی، "یادگیری واژه نامه برای آشکارسازی محل پلاک خودرو"، مجله مهندسی برق و الکترونیک ایران، جلد ۲، شماره ۱۴، ۱۱۵-۱۲۵، ۱۳۹۶.
- [30] Tropp, J., Dhillon, I., Heath, R. J., Strohmer, T., "Designing structural tight frames via an alternating projection method", IEEE Trans. on Information Theory, Vol. 51, No.1, pp.188-209, 2005.
- [31] Barchiesi, D., Plumbley, M. D. "Learning incoherent dictionaries for sparse approximation using iterative projections and rotations", IEEE Transactions on Signal Processing, Vol. 61, No. 8, pp. 2055-2065, 2013.
- [32] Mavaddati, S., "Rice classification and quality detection based on sparse coding technique", International Journal of Engineering, Vol. 31, No. 11, pp. 1910-1917, 2018.
- [33] https://figshare.com/articles/brain_tumor_dataset/1512427.
- [34] Lauer, F., Guermeur, Y., "MSVMpack: a Multi-class Support Vector Machine Package", Journal of Machine Learning Research, Vol. 12, pp. 2269-2272, 2011.
- [5] اسمعیلی، ف.، و آزادیان، ح.، "تشخیص تومور مغزی با استفاده از روش های پردازش تصویر در تصاویر MRI"، کنفرانس ملی پژوهش های نوین در برق، کامپیوتر و مهندسی پزشکی، کازرون، دانشگاه آزاد اسلامی واحد کازرون، ۱۳۹۶.
- [6] Chavan, N.V., Jadhav, B.D., Patil, P.M., "Detection and Classification of Brain Tumors", International Journal of Computer Applications, Vol. 112, No. 8, 2015.
- [7] Udayabhanu, P., Anjaly, V., Padmarajan, S., "MRI brain image classification using GLCM feature extraction and probabilistic neural networks", IOSR Journal of Electronics and Communication Engineering, pp. 4-15, 2016.
- [8] Lekshmi, S., Ratheesh, I., "Classification of brain tumor using neural network", International Journal for Research in Applied Science & Engineering Technology (IJRASET), Vol. 4, No. 8, pp. 93-97, 2016.
- [9] Thamarachelvi, B., Yamuna, G., "Gray level co-occurrence matrix features based classification of tumor in medical images", ARPN Journal of Engineering and Applied Sciences, Vol. 11, No. 19, pp. 11403-11414, 2016.
- [10] Harshavardha, A., Babu, S., Venugopal, T., "Analysis of feature extraction methods for the classification of brain tumor detection", International Journal of Pure and Applied Mathematics, Vol. 117, No. 7, pp. 147-155.
- [11] Varuna, N., Kumar, T.N.R. "Identification and classification of brain tumor MRI images with feature extraction using DWT and probabilistic neural network", Brain Informatics, pp. 23-30, 2017.
- [12] Kapoor, L., "A survey on brain tumor detection using image processing techniques", 7th International Conference on Cloud Computing, Data Science & Engineering, pp. 582-585, 2017.
- [13] عبدالکریم، م.، درویشی، م.ت.، "تشخیص تومور مغزی با استفاده از تکنیک تقارن در پردازش تصویر"، دومین کنفرانس ملی مهندسی برق و کامپیوتر، تهران، موسسه آموزش عالی بصیر، ۱۳۹۶.
- [14] Kumar, S., Dharun, V.S., "Extraction of texture features using GLCM and shape features using connected regions" International Journal of Engineering and Technology (IJET), pp. 2926-2930, 2017.
- [15] Davis, G., Mallat, S., Zhang, Z., "Adaptive time-frequency decompositions", Optical-Engineering, Vol. 33, pp. 218-391, 1994.
- [16] Agarwal, A., Anandkumar, A., Jain, P., Netrapalli, P., Tandon, R., "Learning sparsely used overcomplete dictionaries", JMLR: Workshop and Conference Proceedings, Vol. 35, pp. 1-15, 2014.
- [17] Lee, H., Battle, A., Raina, R., Ng, A.Y., "Efficient sparse coding algorithms", Advances in Neural Information Processing Systems, 2006.
- [18] Aharon, M., Elad, M., Bruckstein, A., "K-SVD: An algorithm for designing overcomplete dictionaries for sparse representation", IEEE Trans. Signal Process, Vol. 54, No. 11, pp. 4311-4322, 2006.
- [19] Tropp, J.A., "Greed is good: Algorithmic results for sparse approximation", IEEE Trans. Inform. Theory, Vol. 50, pp. 2231-2242, 2004.
- [20] Ojala, T., Pietikäinen, M., "Unsupervised texture segmentation using feature distributions", Pattern Recognition, Vol. 32, No. 3, pp. 477-486, 1999.
- [21] William, T., Roth, M., "Orientation histograms for hand gesture recognition", Tech. Rep. TR94-03,

زیر نویس ها

¹ Probabilistic neural network (PNN)

² Astrocytoma

³ Meningioma

⁴ Metastatic bronchogenic carcinoma

⁵ Sarcoma

⁶ Gray level co-occurrence matrix (GLCM)

⁷ Levenberg Marquart

⁸ Fast discrete curvelet transform

⁹ Radial basis function

¹⁰ K-nearest neighbor (K-NN)

¹¹ Spatial K-means clustering

- ¹² Tomography
- ¹³ Support vector machine
- ¹⁴ Gray-Level Run-Length Matrix (GRLM)
- ¹⁵ Patch
- ¹⁶ Redundancy rate
- ¹⁷ K-sparse
- ¹⁸ Cardinality
- ¹⁹ K-Singular value decomposition
- ²⁰ Orthogonal Matching Pursuit
- ²¹ Local binary pattern (LBP)
- ²² Histogram of oriented gradients (HOG)
- ²³ Contrast
- ²⁴ Homogeneity
- ²⁵ Dissimilarity
- ²⁶ Correlation
- ²⁷ Entropy
- ²⁸ Moment
- ²⁹ Rotation-invariant
- ³⁰ Meningioma
- ³¹ Glioma
- ³² Pituitary
- ³³ Dictionary learning
- ³⁴ Cardinality
- ³⁵ Under-determined
- ³⁶ Least angle regression with coherence criterion (LARC)
- ³⁷ Least-angle regression (LARS)
- ³⁸ Residual coherence
- ³⁹ Source confusion
- ⁴⁰ Source distortion
- ⁴¹ K-Singular value decomposition
- ⁴² Gram matrix
- ⁴³ Iterative projection and rotation (IPR)
- ⁴⁴ Frobenius norm
- ⁴⁵ Orthogonal
- ⁴⁶ Classification accuracy rate
- ⁴⁷ Rotation invariance
- ⁴⁸ Equiangular tight frames