

دسته‌بندی تومورهای مغزی براساس تجزیه مولفه‌های اساسی تنک ساختاریافته و الگوریتم فاکتورگیری ماتریس غیرمنفی تنک

سمیرا مودتی*

چکیده

تعیین نوع تومور مغزی براساس پردازش تصاویر ام‌آرآی در کنار دانش پزشکی می‌تواند به تصمیم‌گیری درستی در مورد وضعیت بیمار منجر شود. در این راستا تشخیص خوش‌خیم یا بدخیم بودن تومور و انتخاب روش درمانی بر این اساس، به دلیل لزوم بررسی دقیق جزئیات بافت تومور و امکان بروز خطا می‌تواند به یک مبحث چالش برانگیز تبدیل شود. در این صورت پرداختن به این مسئله به کمک تکنیک‌های پردازش تصویر می‌تواند اهمیت بسیاری داشته باشد. در این مقاله، تشخیص مناسب نوع تومور به کمک ویژگی‌های بافتی و آماری تصویر و انتخاب بهترین بردار ویژگی صورت می‌گیرد. سپس از الگوریتم تحلیل مولفه‌های اساسی تنک ساختاریافته به منظور کاهش بُعد این دسته ویژگی‌ها استفاده می‌شود. در ادامه بردارهای ویژگی حاصل به منظور آموزش مدل‌های جامع بازنمایی‌کننده ساختار داده مربوط به هر نوع تومور مغزی به کمک الگوریتم فاکتورگیری ماتریس غیرمنفی تنک مورد استفاده قرار می‌گیرند. دسته‌بندی داده‌ها در روش پیشنهادی براساس مقدار نرخ انرژی محاسبه شده برای ضرایب تنک صورت می‌گیرد. همچنین نتایج این دسته‌بندی با نتایج حاصل از طبقه‌بندهای مبتنی بر شبکه عصبی و ماشین بردار پشتیبان مقایسه گردیده است. نتایج شبیه‌سازی‌ها نشان می‌دهد که روش پیشنهادی مبتنی بر ویژگی‌های ترکیبی آماری/بافتی قادر به دسته‌بندی انواع تومور مغزی با دقت بالا خواهد بود.

کلیدواژه‌ها

طبقه‌بندی تومور مغزی، ویژگی مبتنی بر بافت، ویژگی آماری، تجزیه مولفه‌های اساسی تنک ساختاریافته، الگوریتم فاکتورگیری ماتریس غیرمنفی تنک.

۱ مقدمه

مقایسه و براساس ویژگی‌های بافتی نواحی تصویر صورت می‌گیرد. برای تشخیص این ناهنجاری، مقایسه‌ای میان نیم‌کره سالم و بیمار با توجه به این نکته انجام می‌شود که تومور در نیم‌کره‌های متقارن قرار نمی‌گیرد. به طور معمول دو شیوه برای تشخیص تومور وجود دارد: تشخیص براساس ویژگی‌های محاسباتی و تشخیص براساس ویژگی‌های ظاهری. به منظور تعیین ویژگی‌های محاسباتی مانند انحراف معیار، شدت رنگ، آنتروپی و غیره از الگوریتم‌های کاربردی به منظور تشخیص تومور استفاده می‌شود [۵-۱]. به کمک ویژگی‌های محاسباتی می‌توان وجود یا عدم وجود بافت‌های ناهمگون در مغز را بررسی نمود. تصاویر پزشکی به طور عمده شامل ویژگی‌های ظاهری مغز مانند مایع مغزی نخاعی، بافت استخوانی جمجمه، ذرات خاکستری، سفید و نیز اطلاعات مربوط به کنتراست بافت، رزولوشن و موقعیت مکانی قرارگیری توده‌های بافتی می‌باشند. تشخیص براساس این ویژگی‌ها سطحی و ابتدایی است، اما نمی‌توان از اهمیت آن‌ها چشم‌پوشی کرد.

تشخیص نوع تومور مغزی به طور معمول توسط بررسی‌های پزشکی بر روی تصاویر حاصل از تصویربرداری رزونانس مغناطیسی یا ام‌آرآی صورت می‌گیرد. تصویربرداری ام‌آرآی یک روش پیشرفته پزشکی به منظور ثبت 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. این روال تشخیص شامل تفکیک بافت مغز از تومور و دسته‌بندی آن به عنوان خوش‌خیم و بدخیم است که پس از

این مقاله در آذرماه سال ۹۷ دریافت، در اردیبهشت‌ماه ۹۸ بازنگری و در شهریورماه همان سال پذیرفته شد.

* گروه مهندسی برق دانشگاه مازندران.

رایانامه: s.mavaddati@umz.ac.ir

ترکیب ویژگی‌های استخراجی از هیستوگرام تصویر، ماتریس هم‌رخداد سطوح خاکستری، ماتریس طول تکرار سطوح خاکستری^{۱۴} و نیز دسته‌بند ماشین بردار پشتیبان به منظور تشخیص تومورهای خوش‌خیم و بدخیم پیشنهاد شده است. در [۱۱]، الگوریتم دسته‌بندی تومورهای مغزی بر اساس شبکه عصبی احتمالی و ویژگی‌های ماتریس هم‌رخداد سطوح خاکستری و عملگرهای موفولوژی حاصل از ضرایب تبدیل موجک گسسته معرفی شده است. در [۱۲]، الگوریتم‌های مختلف ارائه شده برای طبقه‌بندی تومورهای مغزی بر اساس انواع ویژگی‌ها و دسته‌بندها مورد بررسی و مقایسه قرار گرفته است.

در [۱۳]، الگوریتمی به منظور تعیین مساحت و ناحیه تومور مغزی پیشنهاد شده است. در این روش پس از اعمال الگوریتم رشد تصویر و حذف نویز از آن، اثر چرخش سر حذف و با بکارگیری آنالیز تقارن، نواحی منتخب به عنوان مکان تومور مشخص می‌گردد. سپس، مساحت هریک از این نواحی محاسبه و نواحی دارای مساحت در محدوده مساحت نواحی تومورهای تصاویر آموزشی، به عنوان ناحیه اصلی تومور در نظر گرفته می‌شوند. در [۱۴]، تعیین نوع تومورهای بدخیم و نرمال مغزی بر اساس ویژگی‌های حاصل از ماتریس هم‌رخداد سطوح خاکستری و ویژگی‌های مبتنی بر شکل استخراجی از نواحی متصل تصویر انجام می‌گیرد. در این روش از نُه ویژگی آماری حاصل به منظور آموزش شبکه عصبی استفاده می‌شود. در بیشتر پژوهش‌های این حوزه، از ویژگی‌های استخراجی حاصل از ماتریس هم‌رخداد سطوح خاکستری استفاده می‌گردد که بر اهمیت این ویژگی بافتی/آماری در روال تعیین تومورهای مغزی تاکید دارد.

مشکل اساسی در روش‌های مطرح شده تاکنون، نرخ دقت پایین بوده است و روش‌های مختلف سعی به افزایش دقت دسته‌بندی داشته‌اند. در این مقاله نیز سعی شده است تا برپایه روش مبتنی بر مدل پیشنهادی و بکارگیری انواع ویژگی‌های مفید در این راستا، دقت دسته‌بندی تا حد ممکن افزایش یابد. در این مقاله از ترکیب ویژگی‌های مختلف آماری و بافتی که شامل ماتریس هم‌رخداد سطوح خاکستری نیز خواهد بود به منظور آموزش مدل‌های جامع بازنمایی‌کننده ساختار هر دسته تومور مغزی استفاده می‌گردد. سپس بُعد ویژگی‌های حاصل توسط الگوریتم تحلیل مولفه‌های اساسی تنک ساختاریافته^{۱۵} (SSPCA) کاهش یافته و از الگوریتم فاکتورگیری ماتریس غیرمنفی تنک^{۱۶} (SNMF) به منظور آموزش دسته ویژگی‌های کاهش بُعد یافته استفاده می‌گردد. در بخش دوم این مقاله، ویژگی‌های بافتی و آماری مورد استفاده در روال تشخیص تومورهای مغزی بررسی می‌شود. در بخش سوم الگوریتم SNMF مورد استفاده به منظور

در [۱]، از ویژگی‌های بافتی و شبکه عصبی احتمالی^۱ به منظور تشخیص تومورهای خوش‌خیم، بدخیم و نرمال استفاده شده است. در این الگوریتم از ضرایب تبدیل موجک در باندهای مختلف بهره گرفته شده است. در [۲]، دسته‌بندی چهار تومور استروسیتوم^۲، منژیوم^۳، کارسینوما^۴ و سارکوم^۵ به کمک ویژگی‌های مبتنی بر ماتریس هم‌رخداد سطوح خاکستری^۶، طبقه‌بند شبکه عصبی و الگوریتم بهینه‌سازی غیرخطی لونیبر-مارکارد^۷ صورت گرفته است. در [۳]، دسته‌بندی چهار نوع تومور سرطان مغز و استخوان به کمک ضرایب ماتریس هم‌رخداد سطوح خاکستری و شبکه عصبی پس‌انتشار گزارش شده است. دسته‌بندی تومورهای مغزی در [۴] به کمک ضرایب ماتریس هم‌رخداد سطوح خاکستری و نیز تبدیل کرولت گسسته سریع^۸ و با طبقه‌بند مبتنی بر شبکه عصبی احتمالی با توابع پایه شعاعی^۹ انجام شده است. در این مقاله، دسته‌بندی بر روی انواع تومور خوش‌خیم، بدخیم و نرمال صورت گرفته است. در [۵]، سعی شده است که به کمک تکنیک‌های پردازش تصویر و شبکه عصبی، سرعت و دقت یافتن تومورهای مغزی افزایش یابد. در این روش، ویژگی‌های مبتنی بر هیستوگرام از نواحی دارای تومور و نیز بخش‌های نرمال تصویر استخراج و سپس از شبکه عصبی به منظور تشخیص ناحیه دارای تومور بهره گرفته می‌شود.

در [۶]، از ضرایب استخراج شده از ماتریس هم‌رخداد سطوح خاکستری و طبقه‌بند مبتنی بر K-نزدیکترین همسایه^{۱۰} به منظور دسته‌بندی تصاویر مربوط به تومورهای نرمال و غیرنرمال (خوش‌خیم و بدخیم) استفاده گردیده است. در [۷]، به منظور تشخیص تومورهای غیرنرمال مغزی، ضرایب استخراج شده از ماتریس هم‌رخداد سطوح خاکستری و خوشه‌بند K-میانگین فضایی^{۱۱} مورد استفاده قرار گرفته است. دسته‌بندی به کمک این ویژگی‌ها در [۸] به کمک شبکه عصبی صورت گرفته است. در [۹]، طبقه‌بندهای شبکه عصبی تابع پایه شعاعی و ماشین بردار پشتیبان^{۱۲} به منظور تشخیص تومورهای نرمال و غیرنرمال مغزی به کمک ویژگی‌های ماتریس هم‌رخداد سطوح خاکستری استخراجی از تصاویر ام‌آرآی و توموگرافی^{۱۳} بکار گرفته شده‌اند. در [۱۰]،

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 Support vector machine

¹³ Tomography

¹⁴ Gray-Level Run-Length Matrix (GRLM)

¹⁵ Sparse structured principal component analysis

¹⁶ Sparse non-negative matrix factorization

$$F(x, y) = \frac{2}{\sqrt{M \times N}} \alpha(x) \alpha(y) \sum_{i=0}^{M-1} \sum_{j=0}^{N-1} I(i, j) \times \cos\left(\frac{(2i+1)x\pi}{2M}\right) \times \cos\left(\frac{(2j+1)y\pi}{2N}\right)$$

$$\alpha(x), \alpha(y) = \begin{cases} \frac{1}{\sqrt{2}} & \text{if } x, y = 0 \\ 1 & \text{Otherwise} \end{cases} \quad (2)$$

۲-۳ تبدیل فوریه گسسته^۲

با بکارگیری تبدیل فوریه گسسته، تصویر به مولفه‌های سینوسی و کسینوسی تجزیه می‌شود و از حوزه مکان به حوزه فرکانس انتقال می‌یابد. بنابراین تصویر اصلی در مقیاس سطوح خاکستری توسط مجموعه نامحدودی از این توابع، تقریب زده می‌شود. تابع تبدیل فوریه برای یک تصویر ورودی I با ابعاد N×M، به صورت زیر قابل بیان است [۱۵]:

$$F(x, y) = \sum_{i=0}^{M-1} \sum_{j=0}^{N-1} I(i, j) e^{-i(x_{iM} + y_{jN})}$$

$$e^{ix} = \cos x + i \sin x \quad (3)$$

در این رابطه، F نمایانگر تصویر ورودی در حوزه فرکانس با همان ابعاد مکانی تصویر اولیه می‌باشد و شامل مجموعه‌ای از اعداد مختلط خواهد بود [۱۵].

۲-۴ الگوی باینری محلی^۳

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 [۱۸]. 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 [۱۸].

۲-۵ هیستوگرام گرادیان جهت‌دار^۴

یکی از روش‌های استخراج ویژگی در پردازش تصویر که در روال تشخیص اهداف بسیار کارا می‌باشد، هیستوگرام گرادیان جهت‌دار HOG است [۱۹]. در این الگوریتم، تعداد رخداد گرادیان در راستاهای مختلف در بخش‌های محلی تصویر محاسبه می‌گردد.

آموزش مدل و نیز الگوریتم SSPCA به منظور کاهش بُعد معرفی می‌گردند. الگوریتم پیشنهادی به منظور دسته‌بندی تومورهای مغزی در بخش چهارم ارائه می‌گردد. در بخش پنجم نتایج حاصل از بکارگیری روش پیشنهادی مورد ارزیابی قرار گرفته و در بخش آخر، نتیجه‌گیری در مورد پژوهش انجام شده صورت می‌گیرد.

۲ نحوه استخراج ویژگی

اولین مرحله در روال‌های دسته‌بندی متداول، گام پیش‌پردازش داده‌ها می‌باشد. در این مقاله ابتدا سطوح خاکستری داده‌های تصاویر ام‌آرآی حاصل و 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 بیان می‌گردد.

۲-۱ فیلتر گابور

یکی از ویژگی‌های حائز اهمیت در تحلیل مبتنی بر بافت تصویر، استفاده از ضرایب اندازه و فاز حاصل از اعمال فیلتر گابور به تصویر می‌باشد. به کمک این فیلتر خطی، مولفه‌های فرکانسی در راستاهای مختلف از تصویر محاسبه می‌شوند. محاسبه ضرایب در این راستاها، به منظور برقراری تمایز میان بافت‌های مختلف نواحی تصویر حائز اهمیت است [۱۵-۱۷]. تابع گابور دوبعدی G(x,y) به صورت زیر قابل بیان است:

$$G(x, y) = \frac{1}{2\pi\sigma_x\sigma_y} \exp\left[-\frac{1}{2}\left(\frac{x^2}{\sigma_x^2} + \frac{y^2}{\sigma_y^2}\right) + j\omega(x\cos\theta + y\sin\theta)\right] \quad (1)$$

در این رابطه σ_x و σ_y انحراف معیار در امتداد راستای x و y هستند. ω ، فرکانس و θ جهت مورد نظر می‌باشد. همچنین به منظور حذف اثر شدت روشنایی تصویر، مقدار ضرایب با فرکانس صفر برای هر خروجی تابع گابور نادیده گرفته می‌شود.

۲-۲ تبدیل کسینوسی گسسته^۱

به کمک این تبدیل، تصویر به باندهای مختلف فرکانسی تجزیه می‌شود که سیستم بینایی انسان به آن‌ها حساسیت زیادی نشان می‌دهد. این باندهای فرکانسی شامل سه باند فرکانسی پایین، میانه و بالا می‌باشد که ضرایب در نواحی باند فرکانسی پایین، بخش عمده‌ای از انرژی تصویر را شامل می‌شوند. این در صورتی است که ضرایب تبدیل در نواحی فرکانس بالا شامل حداقل میزان انرژی است. ضرایب تبدیل کسینوسی دوبعدی $F(x, y)$ برای یک تصویر ورودی I با ابعاد N×M شامل یک تصویر در حوزه فرکانس با همان ابعاد مکانی تصویر اولیه، به صورت زیر قابل محاسبه است [۱۵]:

² Discrete Fourier transform (DFT)

³ Local binary pattern (LBP)

⁴ Histogram of oriented gradients (HOG)

¹ Discrete cosine transform (DCT)

پارامترهای گشتاور مکانی استخراجی از تصویر است [۲۱]. این مجموعه ویژگی که شامل هفت ضریب گشتاور مکانی اول تا هفتم می‌باشد دارای این ویژگی است که مقادیر آن با چرخش تصویر در راستاهای مدنظر تغییر نمی‌کند. بنابراین این ضرایب در بحث تشخیص داده که چرخش در آن‌ها یکی از چالش‌های اساسی است بسیار حائز اهمیت خواهد بود.

۳ آموزش مدل و کاهش بُعد

در روش پیشنهادی از تکنیک آموزش مدل به منظور بازنمایی ساختار داده‌های دسته‌های مختلف استفاده می‌گردد. آموزش مدل در روش پیشنهادی توسط الگوریتم SNMF انجام می‌شود. در حقیقت ترکیب الگوریتم‌های کدگذاری تنک^۸ و روال فاکتورگیری ماتریس غیرمنفی^۹ (NMF) یک روال جدید آموزش مدل به نام روش فاکتورگیری ماتریس غیرمنفی تنک یا SNMF را بدست می‌دهد [۲۲-۲۴]. این تکنیک با توجه به اعمال قید تنکی در آن به بازنمایی تنک‌تری نسبت به الگوریتم آموزش مدل NMF منتهی می‌گردد. در SNMF از روش دیورژانس کولبک-لیبلر^{۱۰} تعمیم‌یافته به جای روش خطای میانگین مربعات به منظور تعیین خطای تقریب در بازنمایی استفاده می‌شود. همچنین به منظور آموزش مناسب مدل‌ها بر اساس بهترین ماتریس داده ورودی، پس از استخراج ویژگی‌ها از الگوریتم SSPCA به منظور کاهش بُعد داده‌های آموزش استفاده می‌گردد. در ادامه هر یک از الگوریتم‌ها معرفی می‌گردد.

۳-۱ کدگذاری تنک

در کدگذاری تنک، هر فریم داده یا یک تکه^{۱۱} از تصویر که یک ستون از ماتریس مشاهده‌ای خواهد بود می‌تواند به صورت ترکیب خطی از ستون‌ها یا اتم‌های واژه‌نامه یا مدل که پایه‌های فضایی هستند نمایش داده شود. در این روال تعیین می‌شود که مجموعه کدام یک از اتم‌ها و با چه ضریبی قابلیت بازنمایی هر فریم داده را دارند به نحوی که خطای تقریب در این بازنمایی تا حد ممکن کوچک باشد. ضرایب بازنمایی تمامی فریم‌های داده در ماتریسی به نام ماتریس ضرایب تنک H گردآوری می‌شود و این ماتریس خروجی الگوریتم SNMF ماتریس کدگذار تنک است. این ماتریس به این دلیل تنک نام دارد زیرا بسیاری از ضرایب آن به دلیل آنکه هر فریم داده می‌تواند تنها با تعداد محدودی از اتم‌های واژه‌نامه بازنمایی مناسب داشته باشد، صفر خواهند بود. این تعداد

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 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 [۱۹]. برای استخراج ویژگی در آزمایش‌های این مقاله از توصیف‌گر هیستوگرام گرادیان جهت‌دار با اندازه سلول ۸×۸ و اندازه بلوک ۲×۲ استفاده می‌شود.

۲-۶ ماتریس هم‌رخداد سطوح خاکستری

پارامترهای استخراج شده از ماتریس هم‌رخداد سطوح خاکستری یکی دیگر از ویژگی‌های تعیین‌کننده خصوصیات بافت تصویر می‌باشد [۲۰]. 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 (۰°، ۴۵°، ۹۰°، ۱۳۵° و ۱۸۰°) 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^۱، همگنی^۲، بی‌شبهتی^۳، حداکثر مقدار فراوانی نسبی، همبستگی^۴ و آنتروپی^۵ می‌باشد. انتخاب همه یا بخشی از این ویژگی‌های آماری مرتبه دوم در روال پردازش تصویر مبتنی بر تحلیل بافت موثر خواهد بود [۲۰].

۲-۷ گشتاور مکانی^۶

ویژگی‌های آماری دیگر مورد بحث در زمینه پردازش تصویر که به علت غیرحساس بودن به چرخش^۷ بسیار حائز اهمیت می‌باشند،

¹ Contrast

² Homogeneity

³ Dissimilarity

⁴ Correlation

⁵ Entropy

⁶ Moment

⁷ Rotation-invariant

⁸ Linear sparse coding

⁹ Non-negative matrix factorization

¹⁰ Kullback-Leibler divergence

¹¹ Patch

N کوچکتر می‌باشد [۲۴]. به منظور اکتساب این ماتریس‌های تجزیه، می‌بایست مسئله بهینه‌سازی زیر حل گردد:

$$\min F(W, H) = \sum_{i,j} (I_{i,j} \log(I_{i,j} [WH]_{i,j}) - I_{i,j}) + [WH]_{i,j} \quad \text{s.t. } W, H \geq 0, \sum_l W_{(:,l)} = 1 \quad (6)$$

تابع هزینه الگوریتم NMF مبتنی بر روش دیورژانس کولبک-لیبلر تعمیم‌یافته است. در این مسئله، تنگی ماتریس ضرایب که تعیین کننده سرعت همگرایی الگوریتم است توسط معیار $\max_j \left(\sum_k h_{k,i} \right)$ مشخص می‌گردد. در این رابطه $h_{k,i}$ بیانگر هر سطر ماتریس ضرایب تنگ است. حل این مسئله با توابع هزینه دیگر، نسخه‌های متفاوت NMF را بدست می‌دهد.

۳-۳ الگوریتم SNMF

با بهره‌گیری از الگوریتم SNMF، بازنمایی تنگ‌تری با توجه به در نظر گرفتن قید تنگی در آن نسبت به الگوریتم NMF بدست می‌آید [۲۴-۲۲]. در این روش از دیورژانس کولبک-لیبلر تعمیم‌یافته میان I و WH به منظور تعیین خطای تقریب در تجزیه استفاده و مسئله بهینه‌سازی زیر نتیجه می‌گردد:

$$\min F(W, H) = \sum_{i,j} (I_{i,j} \log(I_{i,j} [WH]_{i,j}) - I_{i,j}) + [WH]_{i,j} + \alpha \sum_{k,j} h_{k,j} \quad \text{s.t. } W, H \geq 0, \sum_l W_{(:,l)} = 1 \quad (7)$$

α در این رابطه، ضریب وزندهی مربوط به بخش تنگی است. همچنین بروزسانی ستون‌های واژه‌نامه W و سطرهای ماتریس ضرایب تنگ به منظور حل این مسئله مقید به صورت زیر می‌باشد:

$$\begin{aligned} h_{k,j}^* &= (h_{k,j} \sum_i I_{i,j} w_{i,k} / \sum_i w_{i,l} h_{l,j}) / (1 + \alpha), \\ w_{i,k}^* &= (w_{i,k} \sum_j I_{i,j} h_{k,j} / \sum_j w_{i,l} h_{l,j}) / \sum_j h_{k,j} \\ w_{i,k}^{**} &= (w_{i,k}^* / \sum_l w_{i,l}^*) \end{aligned} \quad (8)$$

اگر در این رابطه $\alpha=0$ گردد، آنگاه الگوریتم SNMF به روال NMF تبدیل خواهد شد [۲۲].

۴-۳ الگوریتم SSPCA

الگوریتم تحلیل مولفه‌های اساسی، یک روش آماری به منظور استخراج ویژگی است که کاربرد زیادی در حوزه‌های مختلف پردازش تصاویر به منظور تحلیل داده‌ها دارد. روال انجام این تحلیل به این صورت است که مجموعه داده‌ها به مجموعه جدی‌دی از متغیرهای غیرهمبسته و دو به دو متعامد که مولفه‌های اصلی را تشکیل می‌دهند، تبدیل می‌شود که تنها تعداد

محدود اتم‌ها با پارامتر تنگی یا کاردینالیته^۱ مشخص می‌گردد. تصویر I به کمک کدگذاری تنگ به صورت زیر مدل می‌گردد:

$$I_m = WH \quad (4)$$

در این رابطه، یک ماتریس داده متشکل از تکه‌های مختلف تصویر I است. تصویر ورودی به بلوک‌های $I_{m \in M}$ تقسیم می‌گردد که M مختصات هر یک از تکه‌ها خواهد بود. به طور معمول ابعاد تکه‌ها، 8×8 در نظر گرفته می‌شود. در بازنمایی تنگ بیان می‌شود که ماتریس داده I_m می‌تواند با یک ترکیب خطی تنگ از اتم‌ها براساس رابطه (۴) کد گردد که در آن $W \in \mathbb{R}^{N \times L}$ یک مدل آموزش دیده یا واژه‌نامه است. واژه‌نامه W شامل L ستون یا اتم $\{W_l\}_{l=1}^L$ با نُرم واحد $\|W_{(:,l)}\|_1 = 1, \forall l = 1, \dots, L$ می‌باشد. همچنین ماتریس ضرایب K-تنگ H^2 با $L \gg K$ ، شامل ضرایب بازنمایی ماتریس داده تصویر I_m است [۲۴]. مسئله بازنمایی تنگ براساس بخش‌های خطای تقریب یا بازسازی و قید تنگی به صورت زیر قابل بیان است [۲۴]:

$$H^* = \underset{H}{\operatorname{argmin}} \|I - WH\|_1 \quad \text{s.t. } \|H\|_1 \leq K \quad (5)$$

همانطور که بیان شد تعداد ضرایب غیرصفر در ماتریس ضرایب تنگ H به صورت $\|H\|_1 = K$ مبین کاردینالیته مسئله است. روش‌های بکارگرفته شده به منظور بازنمایی تنگ در چگونگی تنظیم پارامترها تفاوت دارند و تنظیم نرخ تنگی می‌بایست با توجه به بُعد داده ورودی و با دقت انجام گیرد. در تنظیم این پارامتر باید توجه داشت که تنظیم نادرست به اغتشاش منبع^۲ یا اعوجاج منبع^۳ منجر نگردد. اغتشاش منبع زمانی رخ می‌دهد که مقدار این پارامتر بالا در نظر گرفته شود که موجب می‌گردد کدگذاری انبوه و نامناسبی با توجه به تعداد زیاد اتم‌های منتخب در بازنمایی هر فریم داده نتیجه شود. همچنین اعوجاج منبع زمانی ایجاد می‌شود که بازنمایی تنگ با نرخ تنگی پایین صورت گیرد. در نتیجه ترکیب خطی تعداد کم اتم‌ها برای بازنمایی تکه‌های تصویر کافی نخواهد بود و در این صورت خطای تقریب افزایش می‌یابد.

۲-۳ الگوریتم NMF

به کمک الگوریتم NMF یک آنالیز خطی چندمتغیره بر روی ماتریس مشاهده $I \in \mathbb{R}^{N \times M}$ انجام می‌شود که هر ستون این ماتریس شامل یک فریم مشاهده‌ای از داده ورودی می‌باشد. براساس این تجزیه ماتریس مشاهده‌ای به دو ماتریس واژه‌نامه $W \in \mathbb{R}^{N \times L}$ و ماتریس ضرایب تنگ $H \in \mathbb{R}^{L \times M}$ با مقادیر غیرمنفی به صورت $I = WH$ تجزیه می‌گردد که L از M و

¹ Cardinality

² K-sparse

³ Source confusion

⁴ Source distortion

⁵ Kullback-Leibler divergence

می‌شود. در این مقاله از الگوریتم SNMF به منظور آموزش مدل بهره گرفته می‌شود. مفهوم تنکی در این الگوریتم به این معنی است که هر تکه از داده تصویر ورودی تنها با ترکیب خطی از تعداد کم و معینی از اتم‌های آموزش دیده که مقدار آن با نرخ کاردینالیته تعیین می‌شود، قابل نمایش خواهد بود. روال پیشنهادی به منظور دسته‌بندی داده‌های مربوط به انواع تومور مغزی به کمک تصاویر ام‌آرآی بر اساس آموزش مدل به این صورت است که در ابتدا دسته ویژگی‌های مورد نظر از هر تکه داده استخراج می‌شود و مجموعه بردارهای تکه‌های مختلف تصویر در کنار یکدیگر، ماتریس داده ورودی را تشکیل می‌دهد. در ادامه با استفاده از الگوریتم SSPCA، کاهش بُعد دسته ویژگی‌ها صورت می‌گیرد. سپس به کمک الگوریتم SNMF، مدل جامع مرتبط با این ماتریس داده کاهش بُعد یافته حاصل می‌گردد. 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 ماتریس ضرایب تنک، یک دسته‌بندی 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 الگوریتم SNMF بر روی واژه‌نامه مرکب $D = [D_M \ D_G \ D_H]$ متشکل از واژه‌نامه‌های مرتبط با داده تومور مننژیوم D_M ، گلیوم D_G و هیپوفیز D_H با همان مقدار ضریب تنکی تنظیم شده در مرحله آموزش واژه‌نامه صورت می‌پذیرد:

$$X_M^*, X_G^*, X_H^* = \text{SNMF}(Y, [D_M \ D_G \ D_H]) \quad (9)$$

سپس انرژی ضرایب بازنمایی تنک حاصل بر روی هر واژه‌نامه D_M, D_G, D_H محاسبه می‌گردد:

$$E_M = \frac{1}{L} \sum_{l=1}^L X_{M,l}^{*T}, \quad E_G = \frac{1}{L} \sum_{l=1}^L X_{G,l}^{*T}, \quad E_H = \frac{1}{L} \sum_{l=1}^L X_{H,l}^{*T} \quad (10)$$

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 می‌شود. در این صورت انرژی بازنمایی بر روی واژه‌نامه‌های مختلف محاسبه و واژه‌نامه با بیشترین انرژی حاصل، کلاس داده ورودی را مشخص خواهد کرد. در این صورت نیازی به استفاده از سایر طبقه‌بندها نبوده و تخمین برچسب داده ورودی تنها به کمک استفاده از الگوریتم SNMF امکان‌پذیر می‌باشد.

اندکی از این مولفه‌های متعامد، بیشینه تغییرات موجود در داده اولیه را شامل می‌شوند. برای بکارگیری این تبدیل، ابتدا داده اولیه نرمالیزه می‌گردد و در ادامه ماتریس کوواریانس آن تشکیل می‌شود. سپس داده‌ها بر روی بردارهای ویژه که دو به دو متعامد هستند، تصویر شده و در فضای برداری جدیدی که این بردارهای ویژه، پایه‌های فضایی آن را تشکیل می‌دهند و واریانس داده‌ها در راستای این بردارها بیشینه است، مورد بررسی قرار می‌گیرند [۲۵].

الگوریتم PCA یک روش آماری به منظور کاهش بُعد داده می‌باشد. یک روش به منظور تخمین مولفه‌های اساسی با اعمال قید تنکی الگوریتم SPCA می‌باشد. این الگوریتم بر اساس روش LASSO^۱ و معیار رگرسیون پایه‌ریزی شده است و در آن کنترل قابل انعطافی بر روی شاخص تنکی مولفه‌های استخراجی وجود دارد [۲۶]. بکارگیری این روش موجب کاهش زمان محاسبات، دستیابی به مولفه‌های با واریانس بیشتر و افزایش توانایی در تعیین متغیرهای مهم مسئله می‌گردد. الگوریتم SSPCA یک تعمیم از الگوریتم SPCA است که در آن داده‌های با واریانس بیشتر به کمک قید تنکی و نیز برخی قیود ساختاری پیشین در نظر گرفته می‌شوند [۲۷]. یک فرم غیرمحدب از این تعمیم در [۲۸] ارائه شده است که به حل مسئله یادگیری واژه‌نامه تنک ساختاریافته می‌پردازد. SSPCA، یک روال موثر کاهش بلوک-مختصات^۲ با روابط بروزسانی فرم بسته را به منظور تجزیه بهتر داده بکار می‌گیرد. از آنجاییکه این الگوریتم دارای روال یادگیری واژه‌نامه محلی است نسبت به مسئله انسداد^۳ مقاوم خواهد بود.

۴ دسته‌بندی تصاویر ام‌آرآی در روش پیشنهادی

در گام اول تشخیص تومور از تصاویر ام‌آرآی در الگوریتم پیشنهادی، استخراج ویژگی برای هر دسته داده شامل مجموعه تصاویر مربوط به یک نوع تومور که نمونه‌هایی از آن در شکل (۱) نشان داده شده انجام می‌شود. این تصاویر مربوط به ۳ دسته تومور مغزی شامل تومورهای مننژیوم^۴، گلیوم^۵ و هیپوفیز^۶ است که از مجموعه تومورهای مغزی متداول می‌باشند. بلوک دیاگرام روش پیشنهادی در شکل ۲ نشان داده شده است. در ادامه بخش‌های مختلف روش پیشنهادی مورد بررسی دقیق قرار می‌گیرد. یکی از روش‌های موثر در دسته‌بندی تصاویر کلاس‌های مختلف داده استفاده از یک ساختار مشخص که در اصطلاح به آن آموزش مدل^۷ مدل گفته می‌شود، می‌باشد. به کمک این روال، برای هر دسته داده مربوط به یک نوع تومور مغزی یک مدل جامع آموزش داده

^۱Least absolute shrinkage and selection operator

^۲Block-coordinate descent algorithm


^۳Occlusion problem

^۴Meningioma

^۵Glioma

^۶Pituitary

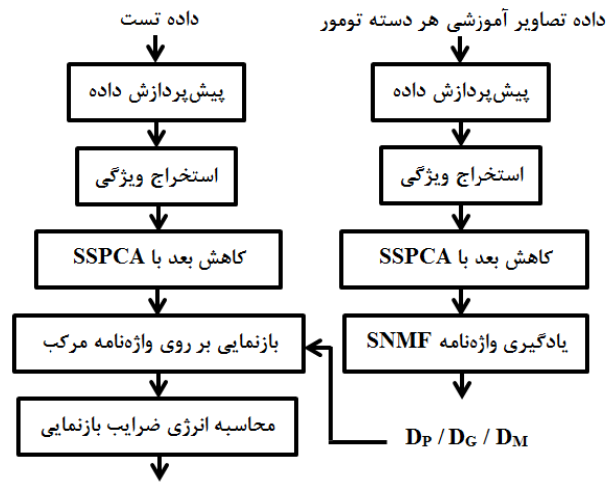
^۷Dictionary learning



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

غده گلیوم و ۹۳۰ تصویر مربوط به غده هیپوفیز می باشد. ابعاد این تصاویر ۵۱۲×۵۱۲ و اندازه پیکسلها ۰/۴۹×۰/۴۹ میلی متر مربع خواهد بود.

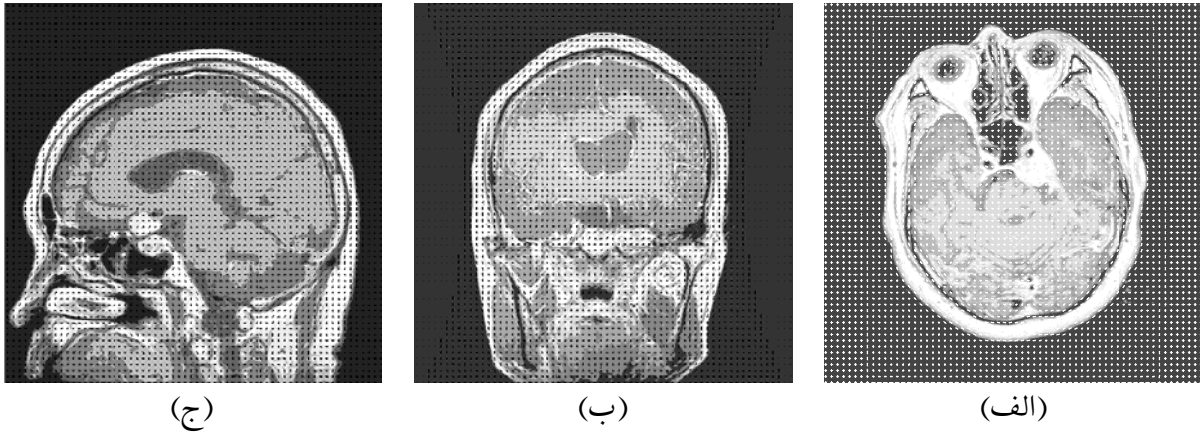
در روش پیشنهادی از آموزش واژه نامه به کمک الگوریتم SNMF به منظور دسته بندی انواع تومور مغزی استفاده گردیده است. در مرحله پیش پردازش تصاویر، در ابتدا ابعاد داده تصویر ورودی به یک هشتم یعنی ۶۴×۶۴ کاهش می یابد. سپس سطوح خاکستری هر تصویر ام آر آی حاصل محاسبه می گردد. در ادامه از ویژگی های مختلف معرفی شده در بخش ۲ به عنوان داده آموزشی استخراجی از تصاویر استفاده می شود. نرخ تنگی مورد نیاز در الگوریتم SNMF براساس مشاهدات تجربی حاصل از آزمایشات متوالی برای واژه نامه و ماتریس ضرایب تنگ به ترتیب به ۰/۸ و ۰/۶ تنظیم شده است. همچنین پارامتر تنگی در الگوریتم SSPCA و تعداد تکرارها به ترتیب به مقدار ۰/۵ و ۳۰۰ تنظیم گردیده است. این مقدار برای تنگی در این الگوریتم متعارف است و مقادیر کوچکتر یا بزرگتر ممکن است به بی ثباتی در راه حل منتهی گردد. ابعاد واژه نامه ها برای تمامی کلاس های داده تومور به بُعد ویژگی استخراجی از هر فریم که به عنوان هر ستون از ماتریس آموزش می باشد بستگی دارد.



برچسب نوع تومور مغزی
شکل ۲ بلوک دیاگرام روش پیشنهادی به منظور دسته بندی داده تومورهای مغزی مختلف.

۵ نتایج شبیه سازی

به منظور شبیه سازی نتایج حاصل از روش پیشنهادی، از مجموعه تصاویر ام آر آی در [۲۹] استفاده شده است. این تصاویر حاصل از تصویربرداری CE-MRI با T1-weighted است که از ۲۳۳ بیمار در طی سال های ۲۰۰۵ تا ۲۰۱۰ ثبت شده است. این مجموعه دادگان شامل ۳۰۶۴ تصویر از سه نوع تومور مغزی مننژیوم، گلیوم و هیپوفیز است که ۷۰۸ تصویر مربوط به غده مننژیوم، ۱۴۲۶ تصویر مربوط به



شکل ۳ نمونه‌ای از ویژگی‌های HOG استخراج شده از الف) تومور منزیوم. ب) تومور گلیوم. ج) تومور هیپوفیز.

شبکه عصبی و ماشین بردار پشتیبان^۳ بدون گام استخراج ویژگی و ویژگی و تنها با تکیه بر تکه‌های استخراج شده و اتم‌های آموزش دیده بر اساس آن در جدول (۱) گزارش شده است. به منظور یادگیری مدل در گام آموزش، از ۷۰٪ داده هر دسته تومور مغزی و در گام تست از مابقی تصاویر استفاده شده است. همانطور که بیان گردید، ارزیابی عملکرد روش‌های مختلف به کمک نرخ دقت دسته‌بندی تعیین می‌شود که توسط درصد داده‌های درست طبقه‌بندی شده به کل داده‌های تست محاسبه می‌گردد. نتایج دسته‌بندی روش پیشنهادی با دسته‌بندی‌های شبکه عصبی روبه جلو و ماشین بردار پشتیبان به ترتیب ارائه شده در مراجع [۸] و [۹] مقایسه گردیده است. پارامترهای بایاس و وزن در شبکه عصبی روبه جلو بر اساس الگوریتم گرادینت مزدوج مقیاس پذیر^۴ به روز می‌شوند. تابع انتقال انتقال لایه پنهان، تابع سیگموئید تانژانت هائپربولیک^۵ انتخاب و تعداد نورون‌ها برای هر لایه پنهان به ۳۵ لایه تنظیم شده است. در شبیه‌سازی SVM از کرنل خطی و روش بهینه‌سازی حداقل ترتیب^۶ به منظور یافتن خطوط جداساز استفاده شده است. همچنین بیشینه تکرارهای به منظور یافتن بهترین جداساز به ۱۵۰۰۰ تکرار تنظیم شده است.

نتایج حاصل از طبقه‌بندی هر سه کلاس داده تومورهای مغزی توسط دسته‌بندی‌های نام برده شده بر اساس تکه‌های استخراج شده از تصویر ورودی و بدون استخراج ویژگی در جدول (۲) بیان شده است. در محاسبه این نتایج از ماشین بردار پشتیبان چند کلاسه استفاده گردیده است [۳۰].

ارزیابی عملکرد الگوریتم‌ها به کمک نرخ دقت دسته‌بندی^۱ تعیین می‌شود که توسط درصد داده‌های درست طبقه‌بندی شده به کل داده‌های تست محاسبه می‌گردد. استخراج ویژگی در آزمایش‌های این بخش به کمک توصیف‌گر هیستوگرام گرادینت جهت‌دار HOG با اندازه سلول 8×8 با ۵۰ درصد همپوشانی و اندازه بلوک 2×2 صورت می‌گیرد. بعد ویژگی‌های مبتنی بر HOG برای تصویر پیش پردازش شده با ابعاد 64×64 برای ۹ بین و ۴ جهت مشخص شده برابر با ۱۷۶۴ می‌باشد. نمونه‌ای از این ویژگی‌های HOG استخراجی از تومورهای مورد بررسی در شکل (۳) نشان داده شده است. در ادامه استخراج ویژگی به کمک ضرایب LBP از نوع تغییرناپذیر با چرخش^۲ و با سلول‌های 2×2 غیرهمپوشان انجام می‌گیرد. بعد ویژگی‌های مبتنی بر LBP برای هر تصویر برابر با ۱۰ خواهد بود. همچنین به کمک با ویژگی‌های حاصل از ضرایب ماتریس هم‌رخداد سطوح 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 0° ، 45° ، 90° و 135° محاسبه و پارامترهای ذکر شده در این جهت‌ها حاصل می‌شوند. در نتیجه برای تصویر ورودی یک بردار ویژگی با ۳۶ ضریب حاصل می‌گردد. به کمک ضرایب ویژگی‌های مبتنی بر گشتاور مکانی نیز، هفت ضریب شاخص از هر تصویر ورودی استخراج می‌گردد که ویژگی اصلی این ضرایب مستقل از چرخش تصویر بودن خواهد بود.

نتایج حاصل از دسته‌بندی دو به دوی تصاویر تومور مغزی توسط طبقه‌بند پیشنهادی مبتنی بر آموزش مدل و نیز طبقه‌بندی‌های

³Support vector machine (SVM)

⁴Scaled conjugate gradient

⁵Hyperbolic tangent sigmoid

⁶Sequential minimal optimization

¹ Classification accuracy rate

² Rotation invariance

جدول ۱ درصد دقت دسته‌بندی دو به دوی تومورهای مغزی براساس سطوح خاکستری برای طبقه‌بندهای شبکه عصبی، ماشین بردار پشتیبان و روش پیشنهادی مبتنی بر مدل.

روش پیشنهادی	ماشین بردار پشتیبان [۹]	شبکه عصبی [۸]	
داده مننژیوم/گلیوم	۸۰/۸۷	۸۱/۲۳	۸۷/۱۳
داده گلیوم/هیپوفیز	۸۹/۳۲	۹۰/۵۱	۹۳/۰۶
داده مننژیوم/هیپوفیز	۸۹/۵۰	۸۸/۳۱	۹۲/۴۶

جدول ۲ درصد دقت دسته‌بندی تومورهای مغزی براساس سطوح خاکستری برای طبقه‌بندهای شبکه عصبی، ماشین بردار پشتیبان و روش پیشنهادی مبتنی بر مدل.


روش پیشنهادی	ماشین بردار پشتیبان [۹]	شبکه عصبی [۸]	
داده مننژیوم	۳۵/۹۲	۳۸/۱۵	۶۳/۷۶
داده گلیوم	۶۳/۱۶	۵۹/۶۲	۷۵/۲۳
داده هیپوفیز	۸۹/۲۵	۸۸/۷۶	۹۲/۱۷

ماتریس اندازه ضرایب گابور و یک ماتریس فاز ضرایب گابور با ابعاد یکسان با تصویر اولیه حاصل می‌گردد. این ماتریس ضرایب برای داده تومور مننژیوم در شکل (۴) نمایش داده شده است. ضرایب گابور در این بخش در چهار راستای 0° ، 45° ، 90° و 135° محاسبه می‌شوند. در شکل (۵)، ماتریس اندازه ضرایب گابور در جهت‌های نامبرده برای داده تومور مغزی مننژیوم در شکل (۴)، نشان داده شده که محتوای مولفه‌های فرکانسی در راستاهای مختلف را نشان می‌دهد. سپس مجموع عناصر سطری و ستونی این ماتریس‌ها به عنوان ضرایب ویژگی نهایی برای آموزش واژه‌نامه در نظر گرفته می‌شوند. تعداد اتم‌های واژه‌نامه W در نتایج این بخش با توجه به ابعاد ماتریس داده ورودی برابر با ۳۰۰ در نظر گرفته شده است. نتایج حاصل از دقت دسته‌بندی دو به دوی تومورها به کمک ویژگی معرفی شده برای طبقه‌بندهای مختلف شامل شبکه عصبی رو به جلو^۱ با ۳۵ لایه پنهان، ماشین بردار پشتیبان و مبتنی بر واژه‌نامه ناهمدوس در جدول (۳) آورده شده است. همچنین نتایج برای دسته‌بندی هر سه دسته تومور در جدول (۴) گزارش شده است. از آنجاییکه هر ماتریس ضرایب گابور ابعاد یکسان با ماتریس تصویر ورودی دارد بنابراین ابعاد ماتریس مبتنی بر ویژگی گابور داده مننژیوم/هیپوفیز، مننژیوم/گلیوم و گلیوم/هیپوفیز به ترتیب برابر با 4096×4996 ، 4096×9996 و 4096×6516 است که با ۲۰٪ کاهش بُعد، ۳۲۷۷ خواهد بود. مشاهده می‌شود که دسته‌بند پیشنهادی به کمک اندازه ضرایب گابور به نتایج مطلوبی دست پیدا کرده و این دسته ویژگی می‌تواند وجه تمایز مناسبی را میان داده‌ها برقرار نماید.


در ادامه، در کنار ویژگی اندازه ضرایب گابور از فاز ضرایب گابور نیز به همان صورت استفاده شده و بردار ضرایب نهایی مبتنی بر میانگین ستونی ماتریس‌های اندازه و فاز به منظور آموزش واژه‌نامه در کنار یکدیگر قرار می‌گیرند. نتایج حاصل از دقت دسته‌بندی سه دسته تومور به کمک این دسته ویژگی‌ها برای طبقه‌بندهای ذکر شده در کنار روش پیشنهادی در جدول (۵) آورده شده است. مشاهده می‌شود که نتایج حاصله پایین‌تر از نتایج بدست آمده به کمک سایر ویژگی‌های معرفی شده تاکنون است و این دسته ویژگی مرکب از اندازه و فاز ضرایب گابور قادر به جداسازی مناسب داده‌ها نمی‌باشد. ابعاد ماتریس داده ورودی در تشخیص داده مننژیوم/هیپوفیز، مننژیوم/گلیوم و گلیوم/هیپوفیز براساس ویژگی ترکیب اندازه و فاز ضرایب گابور به ترتیب برابر با 8192×4996 ، 8192×9996 و 8192×6516 است که پس از کاهش بُعد توسط الگوریتم SSPCA، بُعد هر یک از ماتریس‌های داده ورودی ۶۵۴۴ خواهد بود.

تکه‌های استخراج شده از تصویر 8×8 بوده و بنابراین بُعد مسئله ۶۴ می‌باشد. تعداد اتم‌های واژه‌نامه‌ها در این آزمایش با توجه به بُعد ماتریس آموزش به مقدار ۴۰۰ اتم تنظیم شده است. نتایج بدست آمده نشان می‌دهد که دسته‌بند پیشنهادی مبتنی بر آموزش مدل توانسته به نتایج بهتری در کلاس‌بندی داده تومور نسبت به شبکه عصبی و ماشین بردار پشتیبان دست پیدا نماید. ابعاد ماتریس داده ورودی در جداسازی داده مننژیوم/هیپوفیز، مننژیوم/گلیوم و گلیوم/هیپوفیز به ترتیب برابر با 4096×4996 ، 4096×9996 و 4096×6516 می‌باشد که در آن تعداد ستون‌ها برابر مجموع داده‌های آموزش کلاس‌ها است که ۷۰٪ کل داده‌های هر تومور مغزی می‌باشد و تعداد سطرها برابر حاصلضرب تمامی پیکسل‌ها است که با کاهش ابعاد به یک‌هشتم برابر با 64×64 می‌باشد. پس از کاهش بُعد ماتریس داده‌های ورودی توسط الگوریتم SSPCA، بُعد هر یک از ماتریس‌های داده ورودی با ۲۰٪ کاهش، ۳۲۷۷ خواهد بود. ضرایب اندازه و فاز حاصل از فیلتر گابور یکی از ویژگی‌های مهم در تحلیل بافت تصویر به کمک مولفه‌های فرکانسی استخراج شده از جهت‌های مختلف تصویر است. با اعمال هر فیلتر گابور در جهت مشخص شده به تصویر و یا یک ناحیه از آن، یک تصویر فیلترشده حاصل می‌شود. فیلتر یا موجک گابور از طریق گسترش و چرخش یک تابع گابور به دست می‌آید. خروجی هر تابع گابور در راستای مشخص شده، دو ماتریس ویژگی با ابعاد تصویر اولیه برای اندازه و فاز ضرایب است که می‌توان به کمک میانگین‌گیری از تمامی ماتریس ضرایب اندازه و فاز حاصل از راستاهای مختلف به صورت مجزا به دو ماتریس نهایی اندازه و فاز ویژگی‌های گابور دست پیدا نمود [۱۵-۱۷]. به کمک فیلتر گابور برای تصویر اولیه یک

¹ Feed forward neural network (FFNN)



شکل ۴ سطر اول: سمت راست) داده تصویر تومور مننژیوم. میانی) نمایشی از ماتریس اندازه ضرایب گابور. سمت چپ) نمایشی از ماتریس فاز ضرایب گابور. سطر دوم: سمت راست) داده تصویر تومور گلیوم. میانی) نمایشی از ماتریس اندازه ضرایب گابور. سمت چپ) نمایشی از ماتریس فاز ضرایب گابور. سطر سوم: سمت راست) داده تصویر تومور هیپوفیز. میانی) نمایشی از ماتریس اندازه ضرایب گابور. سمت چپ) نمایشی از ماتریس فاز ضرایب گابور.



شکل ۵ نمایشی از ماتریس اندازه ضرایب گابور برای داده تومور مننژیوم نمایش داده شده در شکل ۴ در جهت‌های: (الف) 0° (ب) 45° . (ج) 90° (د) 135° و فاز ضرایب گابور در جهت‌های: (ر) 0° (ز) 45° (س) 90° (ی) 135° .

هدف در این مقاله بررسی ویژگی‌های مهم استخراجی از مغزی است. بنابراین سعی شده تا نتایج حاصل از این ویژگی‌ها تحلیل و در نهایت دسته ویژگی مطلوب با قابلیت برقراری تمایز تصویر و تعیین میزان کارایی آن‌ها در حل مسئله تعیین نوع تومور

جدول ۳ درصد دقت دسته‌بندی دو به دوی تومورهای مغزی براساس ویژگی اندازه ضرایب گابور برای طبقه‌بندهای شبکه عصبی، ماشین بردار پشتیبان و روش پیشنهادی مبتنی بر مدل.

شبکه عصبی [۸]	ماشین بردار پشتیبان [۹]	روش پیشنهادی
۷۲/۱۴	۶۹/۸۱	داده مننژیوم/گلیوم ۷۹/۴۶
۸۳/۲۹	۸۸/۲۱	داده گلیوم/هیپوفیز ۹۰/۱۶
۸۶/۱۷	۸۹/۱۴	داده مننژیوم/هیپوفیز ۹۰/۸۷

جدول ۴ درصد دقت دسته‌بندی تومورهای مغزی براساس ویژگی اندازه ضرایب گابور برای طبقه‌بندهای شبکه عصبی، ماشین بردار پشتیبان و روش پیشنهادی مبتنی بر مدل.

شبکه عصبی [۸]	ماشین بردار پشتیبان [۹]	روش پیشنهادی
۵۱/۲۳	۵۲/۶۳	داده مننژیوم ۶۸/۲۲
۵۹/۶۹	۶۷/۱۵	داده گلیوم ۷۸/۱۴
۸۷/۱۴	۸۷/۲۳	داده هیپوفیز ۸۹/۹۲

جدول ۵ درصد دقت دسته‌بندی تومورهای مغزی براساس ویژگی اندازه و فاز ضرایب گابور برای طبقه‌بندهای شبکه عصبی، ماشین بردار پشتیبان و روش پیشنهادی مبتنی بر مدل.

شبکه عصبی [۸]	ماشین بردار پشتیبان [۹]	روش پیشنهادی
۴۹/۱۸	۴۹/۱۲	داده مننژیوم ۶۰/۱۳
۵۴/۲۲	۵۹/۸۱	داده گلیوم ۷۲/۵۴
۷۶/۰۶	۸۵/۱۲	داده هیپوفیز ۸۵/۳۲

جدول ۶ درصد دقت دسته‌بندی تومورهای مغزی براساس ضرایب DFT و DCT برای طبقه‌بندهای شبکه عصبی، ماشین بردار پشتیبان و روش پیشنهادی مبتنی بر مدل.

روش پیشنهادی	ماشین بردار پشتیبان	شبکه عصبی	ویژگی DCT
۵۶/۵۸	۵۳/۴۷	۵۱/۴۳	داده مننژیوم
۶۰/۲۳	۵۶/۷۲	۵۴/۲۶	داده گلیوم
۵۹/۶۱	۵۸/۲۵	۵۲/۳۳	داده هیپوفیز
۶۱/۳۶	۵۸/۴۲	۵۶/۲۴	داده مننژیوم
۶۲/۴۷	۶۰/۲۷	۵۸/۵۲	داده گلیوم
۶۰/۶۱	۵۷/۱۱	۵۵/۴۳	داده هیپوفیز

جدول ۷ درصد دقت دسته‌بندی دو به دوی تومورهای مغزی براساس ویژگی HOG برای طبقه‌بندهای شبکه عصبی، ماشین بردار پشتیبان و روش پیشنهادی مبتنی بر مدل.

شبکه عصبی [۸]	ماشین بردار پشتیبان [۹]	روش پیشنهادی
۹۲/۳۳	۹۳/۶۱	داده مننژیوم/گلیوم ۹۳/۸۶
۹۲/۵۴	۹۰/۷۶	داده گلیوم/هیپوفیز ۹۶/۴۳
۹۳/۲۸	۹۳/۳۶	داده مننژیوم/هیپوفیز ۹۵/۳۱

جدول ۸ درصد دقت دسته‌بندی تومورهای مغزی براساس ویژگی HOG برای طبقه‌بندهای شبکه عصبی، ماشین بردار پشتیبان و روش پیشنهادی مبتنی بر مدل.

بیشتر میان کلاس‌ها انتخاب گردد. در این راستا، نتایج حاصل از دسته‌بندی داده‌های تومور به کمک ویژگی استخراج شده از تبدیل فوریه گسسته DFT و تبدیل کسینوسی گسسته DCT در جدول (۶) نشان داده شده است. نتایج حاصل نشان می‌دهد که ترکیب این ویژگی‌ها در حل مسئله پیش رو به موفقیت مطلوبی دست نیافته است. تعداد اتم‌های واژه‌نامه L در نتایج این بخش با توجه به ابعاد ماتریس داده ورودی برابر با ۲۵۰ در نظر گرفته شده است. ابعاد ماتریس داده ورودی در تشخیص داده مننژیوم/هیپوفیز، مننژیوم/گلیوم و گلیوم/هیپوفیز براساس ویژگی DFT یا DCT به ترتیب برابر با ۴۰۹۶×۴۹۶ ، ۴۰۹۶×۹۹۹ و ۴۰۹۶×۶۵۱ است که پس از کاهش بُعد توسط الگوریتم SSPCA، بُعد هر یک از ماتریس‌های داده به ۳۲۷۷ کاهش می‌یابد. نتایج حاصل از دسته‌بندی دو به دو و نیز دسته‌بندی هر سه کلاس داده تومور براساس ویژگی HOG با بُعد مسئله ۱۷۶۴ برای طبقه‌بندهای شبکه عصبی، ماشین بردار پشتیبان و روش پیشنهادی مبتنی بر واژه‌نامه به ترتیب در جدول (۷) و (۸) آورده شده است.

تعداد اتم‌های واژه‌نامه‌ها در این آزمایش با توجه به بُعد ماتریس داده آموزش به مقدار ۲۵۰ اتم تنظیم شده است. در این آزمایش، ابعاد ماتریس داده ورودی در تشخیص داده مننژیوم/هیپوفیز، مننژیوم/گلیوم و گلیوم/هیپوفیز براساس ویژگی HOG به ترتیب برابر با ۱۷۶۴×۴۹۶ ، ۱۷۶۴×۹۹۹ و ۱۷۶۴×۶۵۱ است که پس از کاهش بُعد ماتریس داده‌های ورودی توسط الگوریتم SSPCA، بُعد هر یک از ماتریس‌های داده ورودی به ۱۴۱۲ کاهش می‌یابد. از آنجاییکه با انجام شبیه‌سازی‌ها این نتیجه حاصل شده است که این ویژگی به تنهایی برای دسته‌بندی این مسئله کافی نمی‌باشد، بنابراین دسته‌بندی براساس بردار ویژگی در ترکیب با سایر ویژگی‌ها مورد بررسی قرار گرفت. این ویژگی ترکیبی شامل ضرایب حاصل از الگوی باینری محلی LBP با بُعد ۱۰ برای هر داده تصویر و گشتاور مکانی^۱ با بُعد ۷ برای هر داده تصویر و نیز ۳۶ ویژگی حاصل از GLCM خواهد بود که نتایج دسته‌بندی براساس آن در جداول (۹) و (۱۰) بیان شده است. تعداد اتم‌های واژه‌نامه‌ها در این آزمایش به مقدار ۴۰۰ اتم تنظیم شده است. ابعاد ماتریس داده ورودی در این آزمایش به منظور تشخیص داده مننژیوم/هیپوفیز، مننژیوم/گلیوم و گلیوم/هیپوفیز براساس ویژگی HOG به ترتیب برابر با ۵۳×۴۹۶ ، ۵۳×۹۹۹ و ۵۳×۶۵۱ است که پس از کاهش بُعد ماتریس داده‌های ورودی توسط الگوریتم SSPCA به ۵٪، بعد هر یک از ماتریس‌های داده ورودی به ۵۰ کاهش یافته و بُعد^۱ با توجه به مجموع ۷ ضریب گشتاور مکانی، ۱۰ ضریب LBP و ۳۶ ضریب GLCM حاصل شده است.

^۱Moments

جدول ۱۲ درصد دقت دسته‌بندی تومورهای مغزی براساس ویژگی‌های ترکیبی GLCM/MOM/LBP/HOG برای طبقه‌بندهای شبکه عصبی، ماشین بردار پشتیبان و روش پیشنهادی مبتنی بر مدل.

روش پیشنهادی	ماشین بردار پشتیبان [۹]	شبکه عصبی [۸]	داده مننژیوم
۶۱/۱۸	۴۲/۲۳	۳۱/۳۵	داده مننژیوم
۹۰/۰۷	۷۸/۴۱	۷۶/۷۸	داده گلیوم
۹۴/۵۱	۹۲/۶۹	۹۰/۵۸	داده هیپوفیز

روش پیشنهادی	ماشین بردار پشتیبان [۹]	شبکه عصبی [۸]	داده مننژیوم/گلیوم
۸۰/۲۳	۷۰/۵۲	۷۳/۶۱	داده مننژیوم/گلیوم
۹۵/۵۴	۸۹/۶۵	۹۲/۳۶	داده گلیوم/هیپوفیز
۹۵/۷۳	۹۰/۳۶	۸۹/۵۴	داده مننژیوم/هیپوفیز

جدول ۹ درصد دقت دسته‌بندی دو به دوی تومورهای مغزی براساس ویژگی‌های ترکیبی GLCM/MOM/LBP/HOG برای طبقه‌بندهای شبکه عصبی، ماشین بردار پشتیبان و روش پیشنهادی مبتنی بر مدل.

روش پیشنهادی	ماشین بردار پشتیبان [۹]	شبکه عصبی [۸]	داده مننژیوم
۸۰/۲۳	۷۰/۵۲	۷۳/۶۱	داده مننژیوم
۹۵/۵۴	۸۹/۶۵	۹۲/۳۶	داده گلیوم
۹۵/۷۳	۹۰/۳۶	۸۹/۵۴	داده هیپوفیز

جدول ۱۳ ماتریس درهم ریختگی حاصل از دسته‌بندی تومورهای مغزی براساس ویژگی‌های ترکیبی GLCM/MOM/LBP/HOG برای روش پیشنهادی مبتنی بر مدل.

روش پیشنهادی	داده مننژیوم	داده گلیوم	داده هیپوفیز
داده مننژیوم	۸۰/۰۹	۱۲/۵۶	۷/۳۵
داده گلیوم	۴/۶۳	۹۰/۴۴	۴/۹۳
داده هیپوفیز	۰/۸۵	۰/۹۱	۹۸/۲۴

جدول ۱۰ درصد دقت دسته‌بندی تومورهای مغزی براساس ویژگی‌های ترکیبی GLCM/MOM/LBP/HOG برای طبقه‌بندهای شبکه عصبی، ماشین بردار پشتیبان و روش پیشنهادی مبتنی بر مدل.

روش پیشنهادی	ماشین بردار پشتیبان [۹]	شبکه عصبی [۸]	داده مننژیوم
۵۹/۶۶	۳۳/۷۴	۲۸/۳۵	داده مننژیوم
۷۴/۲۵	۵۹/۲۸	۵۷/۶۴	داده گلیوم
۹۷/۰۵	۹۳/۳۸	۹۰/۳۶	داده هیپوفیز

ابعاد ماتریس داده ورودی در این آزمایش به منظور تشخیص داده مننژیوم/هیپوفیز، مننژیوم/گلیوم و گلیوم/هیپوفیز براساس ویژگی HOG به ترتیب برابر با ۱۸۱۷×۴۹۶ ، ۱۸۱۷×۹۹۹ و ۱۸۱۷×۶۵۱ است. بُعد ۱۸۱۷ با توجه به مجموع ۷ ضریب گشتاور مکانی، ۱۰ ضریب LBP و ۳۶ ضریب GLCM و ۱۷۶۴ ضریب HOG بدست آمده است. بُعد هر یک از ماتریس‌های داده ورودی پس از کاهش ۲۰٪ توسط الگوریتم SSPCA، به ۱۴۵۴ تقلیل پیدا کرده است.

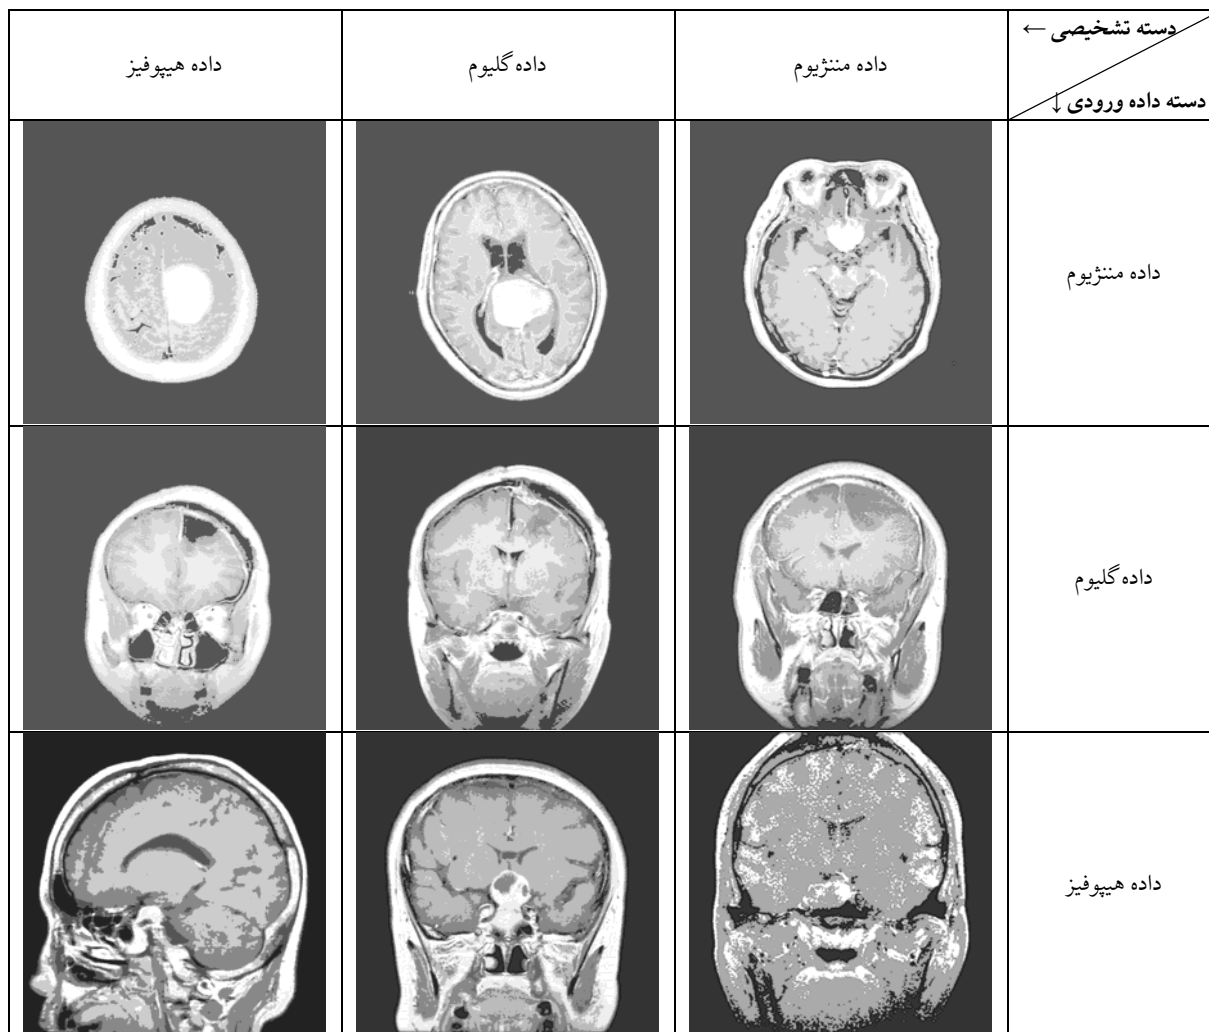
همچنین ماتریس درهم ریختگی^۱ حاصل از طبقه‌بندی سه دسته تومور مغزی براساس ویژگی ترکیبی GLCM/MOM/LBP/HOG به کمک روش پیشنهادی مبتنی بر مدل در جدول ۱۳ بیان گردیده است. در ادامه بررسی نتایج الگوریتم پیشنهادی، نمونه‌هایی از داده‌های دسته‌بندی شده به صورت درست و نادرست از انواع تومور مغزی مورد بحث به کمک روش پیشنهادی در شکل ۶ نشان داده شده که می‌توان با توجه به متفاوت بودن اندازه و جایگاه تومورها در تصاویر آموزش که موجب شباهت بیش از اندازه نمونه‌ها به یکدیگر می‌گردد و ممکن است پزشک را نیز در تشخیص دچار مشکل نماید، خطاهای رخ داده در دسته‌بندی را تا حدودی توجیه نمود. به منظور بررسی عملکرد گام کاهش بُعد به کمک الگوریتم SSPCA، نتایج حاصل از دسته‌بندی پیشنهادی مبتنی بر یادگیری مدل بدون گام کاهش بُعد براساس ویژگی‌های ترکیبی GLCM/MOM/LBP/HOG که بهترین نتایج را بدست داده در جدول (۱۴) گزارش شده است.

جدول ۱۱ درصد دقت دسته‌بندی دو به دوی تومورهای مغزی براساس ویژگی‌های ترکیبی GLCM/MOM/LBP/HOG برای طبقه‌بندهای شبکه عصبی، ماشین بردار پشتیبان و روش پیشنهادی مبتنی بر مدل.

روش پیشنهادی	ماشین بردار پشتیبان [۹]	شبکه عصبی [۸]	داده مننژیوم/گلیوم
۹۷/۱۶	۹۳/۳۷	۹۱/۲۴	داده مننژیوم/گلیوم
۹۹/۳۶	۹۵/۴۱	۹۶/۳۳	داده گلیوم/هیپوفیز
۹۹/۳۱	۹۶/۵۵	۹۵/۶۵	داده مننژیوم/هیپوفیز

به منظور استفاده از تمامی ویژگی‌های آماری و مبتنی بر بافت مورد بحث در بخش ۳، 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 (۱۱) و (۱۲) به ترتیب برای دسته‌بندی دو به دو و دسته‌بندی کلی تومورها نشان داده شده است. تعداد اتم‌های ویژه‌نامه‌ها در این آزمایش با توجه به بُعد ماتریس داده به مقدار ۳۰۰ تنظیم شده است. نتایج بدست آمده نشان می‌دهد که بکارگیری ویژگی‌ها آماری مانند پارامترهای استخراج شده از ضرایب GLCM و گشتاور مکانی، در کنار ویژگی‌های دیگر مبتنی بر بافت مانند LBP و HOG به نتایج مطلوبی در حوزه دسته‌بندی داده‌های تومور مغزی منتهی می‌گردد.

^۱Confusion matrix



شکل ۶ نمایشی از نمونه‌های درست و نادرست دسته‌بندی شده انواع تومور مغزی به کمک روش پیشنهادی.

بردار پشتیبان پیشنهادی در [۹] به اندک زمان کمتری نسبت به روش پیشنهادی به منظور طبقه‌بندی داده‌ها نیازمند است اما دقت دسته‌بندی آن در اکثر ویژگی‌های بکارگرفته شده کمتر از سایر الگوریتم‌ها می‌باشد.

جدول ۱۴ درصد دقت دسته‌بندی تومورهای مغزی براساس ویژگی‌های ترکیبی GLCM/MOM/LBP/HOG در روش پیشنهادی مبتنی بر مدل و روش پیشنهادی بدون گام کاهش بُعد.

روش پیشنهادی	روش پیشنهادی بدون گام کاهش بُعد	روش پیشنهادی
۸۰/۰۹	۷۴/۱۴	داده منتریوم
۹۰/۴۴	۸۴/۸۹	داده گلیوم
۹۸/۲۴	۹۶/۳۲	داده هیپوفیز

جدول ۱۵ بررسی زمانی (بر حسب ثانیه) الگوریتم‌های دسته‌بندی تومورهای مغزی و الگوریتم پیشنهادی براساس ویژگی ترکیبی.

روش پیشنهادی	ماشین بردار پشتیبان [۹]	شبکه عصبی [۸]
مبتنی بر مدل	۲۸۰	۱۹۳
۲۹۸		

این نتایج نشان می‌دهد که بکارگیری این الگوریتم و کاهش بُعد داده ورودی، در افزایش دقت دسته‌بندی تاثیر مناسبی خواهد داشت. قابل ذکر است که روش پیشنهادی با استفاده از مدل‌های جامع بازنمایی‌کننده خصوصیات هر دسته داده براساس ویژگی‌های بافتی و آماری آن‌ها به کمک الگوریتم SNMF و نیز بکارگیری الگوریتم کاهش بُعد SSPCA به منظور حذف ویژگی‌های با خصوصیت عدم متمایزکنندگی قادر به تفکیک انواع تومورهای مغزی با دقت بالا می‌باشد و می‌تواند یاری‌گر علم پزشکی در حوزه تشخیص و درمان بیماری باشد.

به منظور بررسی زمانی الگوریتم‌های مورد بررسی، از یک سیستم با مشخصات ویندوز ۶۴ بیتی، Core i5 و 3.2GHz CPU بهره گرفته شده است. نتایج برای آموزش ۷۰٪ داده هر دسته تومور و ۳۰٪ داده تست بر حسب ثانیه در جدول ۱۵ آورده شده است. نتایج حاصل نشان می‌دهد که دسته‌بندی داده‌های تومور مغزی مبتنی بر شبکه عصبی [۸] می‌تواند در کمترین زمان به دقت‌های گزارش شده دست پیدا نماید. از طرفی روش پیشنهادی به دلیل بکارگیری مدل‌های فراکامل و جامع که موجب دستیابی به نتایج مطلوبی در گام دسته‌بندی می‌شود به زمان بیشتری برای آموزش واژه‌نامه‌ها نیاز دارد. همچنین دسته‌بندی براساس ماشین

۶ نتیجه‌گیری

یکی از زمینه‌های مهم کارایی الگوریتم‌های مبتنی بر بینایی ماشین، کاربردهای پزشکی است. به همین علت، این مقاله به ارائه روشی به منظور تشخیص نوع تومورهای مغزی می‌پردازد تا بتواند به پزشکان در تشخیص مناسب نوع تومور و شروع درمان کمک نماید. در روش پیشنهادی از الگوریتم فاکتورگیری ماتریس غیرمنفی تنک برای آموزش مدل براساس ویژگی‌های استخراجی از داده‌های تصویر ورودی و از الگوریتم تحلیل مولفه‌های اساسی تنک ساختاریافته به منظور کاهش بُعد این دسته ویژگی‌های منتخب استفاده می‌شود. استخراج ویژگی در این مقاله به کمک ویژگی‌های مبتنی بر بافت و ویژگی‌های آماری مختلف صورت می‌گیرد و نتایج بکارگیری ترکیب ویژگی‌ها با یکدیگر مقایسه می‌گردد. نتیجه حاصل به این صورت است که ترکیب ویژگی‌های بافتی مبتنی بر الگوی باینری محلی و هیستوگرام گرادیان جهت‌دار در کنار ویژگی‌های آماری مبتنی بر گشتاور مکانی و ماتریس هم‌رخداد سطوح خاکستری توانسته است نتایج مناسبی را به منظور تشخیص نوع تومورهای مغزی نسبت به دسته‌بندهای مبتنی بر شبکه عصبی و ماشین بردار پشتیبان بدست دهد.

مراجع

- [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, 2017.
- [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.
- [۱۳] 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] Nixon, M., Aguado, A., "Feature Extraction & Image Processing for Computer Vision", Third Edition, Academic Press, 2012.
- [16] Mathur, N. P., Gupta, S. K., "Performance analysis of feature extraction techniques for facial expression recognition", International Journal of Computer Applications, Vol. 166, No. 1, pp. 1-3, 2017.
- [17] Nixon, M., Aguado, A., "Feature Extraction & Image Processing", 2nd Edition, Academic Press, Cambridge, 2008.
- [18] Zhang, B., Gao, Y., Zhao, S., Liu, J., "Local derivative pattern versus local binary pattern: face recognition with high-order local pattern descriptor", IEEE Transactions on Image Processing, Vol. 19, No. 2, pp. 533-544, 2010.
- [19] 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.
- [20] Clausi, D. A., "An analysis of co-occurrence texture statistics as a function of gray level quantization", Can. J. Remote Sensing, Vol. 28, No. 1, pp. 45-62, 2002.
- [21] Flusser, J., Suk, T., Zitová, B., "Moments and moment invariants in pattern recognition", Hichester, West Sussex, U.K: J. Wiley, 2009.
- [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 (ICGCCEE), Coimbatore, pp. 1-6, 2014.
- [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.

- [27] Jenatton, R., Obozinski, G., Bach, F., "Structured Sparse Principal Component Analysis", In Proceedings of the 13th International Conference on Artificial Intelligence and Statistics, Sardinia, Italy, 2010.
- [28] Jenatton, R., Audibert, J.Y., Bach, F. "Structured variable selection with sparsity-inducing norms", Technical report, arXiv:0904.3523, 2009.
- [29] https://figshare.com/articles/brain_tumor_dataset/1512427
- [30] Lauer, F., Guermeur, Y., "MSVMpack: a Multi-class Support Vector Machine Package", Journal of Machine Learning Research, Vol. 12, pp. 2269-2272, 2011.
- [22] Liu, W., Zheng, N., Lu, X., "Non-negative matrix factorization for visual coding", ICASSP, pp. 293-296, 2003.
- [23] Hoyer, P.O., "Non-negative matrix factorization with sparseness constraints", Journal of Machine Learning Research, Vol. 5, No. 11, pp. 1457-1469, 2004.
- [24] Lee, D. D., Seung, H. S., "Algorithms for non-negative matrix factorization", Advances in Neural Information Processing Systems, MIT Press: Cambridge, MA, Vol. 13, 2001.
- [25] Jolliffe, I.T., Principal Component Analysis, Springer, 2nd edition, 2002.
- [26] Zou, H., Hastie, T., Tibshirani, R. "Sparse principal component analysis", Journal of Computational and Graphical Statistics, Vol. 15, pp. 265-286, 2006.



سمیرا مودتی مدارک کارشناسی و کارشناسی ارشد خود را به ترتیب در سال‌های ۱۳۸۶ و ۱۳۸۹ از دانشگاه مازندران در رشته مهندسی برق- الکترونیک دریافت کرد. ایشان درجه دکترای خود را در سال ۱۳۹۵ از دانشگاه صنعتی امیرکبیر در رشته مهندسی برق- الکترونیک اخذ نمود.

وی هم‌اکنون استادیار گروه مهندسی برق دانشگاه مازندران است. زمینه‌های پژوهشی مورد علاقه ایشان عبارت است از: پردازش سیگنال گفتار، پردازش سیگنال تصویر، بهینه‌سازی و هوش مصنوعی.