

## ترکیب ماشین بردار پشتیبان و مدل‌های پیش آموزش دیده شبکه عصبی کانولوشن به منظور طبقه‌بندی تومورهای مغزی در تصاویر ام.آر.آی.

علیرضا بالوند<sup>1</sup>، علی حسین زاده کاشان<sup>2\*</sup>، عباس سقایی<sup>3</sup>

- 1- دانشجوی دکتری، گروه مهندسی صنایع، دانشکده فنی و مهندسی، دانشگاه آزاد اسلامی واحد علوم و تحقیقات، تهران، ایران
- 2- استادیار، گروه مهندسی صنایع، دانشکده مهندسی صنایع و سیستم‌ها، دانشگاه تربیت مدرس، تهران، ایران
- 3- دانشیار، گروه مهندسی صنایع، دانشکده فنی و مهندسی، دانشگاه آزاد اسلامی واحد علوم و تحقیقات، تهران، ایران

پذیرش: 1397/10/7

دریافت: 1397/3/16

### چکیده

به دلیل محل رشد تومورهای مغزی در سر انسان، معمولاً احتمال مرگ بر اثر این تومورها، شش برابر بیشتر از تومورهای دیگر است. سیستم‌های کامپیوتری را می‌توان برای کاهش تجویز درمان‌های نامناسب و کمک به متخصصان در تشخیص این بیماری استفاده کرد. در این مقاله از یک الگوریتم جدید به منظور تشخیص تومورها در 900 تصویر ام‌آر‌آی استفاده شده است. این الگوریتم مشتمل بر چهار فاز اصلی است که در فاز اول بعد از ورود داده‌ها عملیات پیش‌پردازش بر روی تصاویر با استفاده از روش یکسان‌سازی هیستوگرام انجام می‌شود. در فاز دوم با استفاده از دو مدل پیش آموزش دیده شبکه عصبی کانولوشن، استخراج ویژگی انجام می‌شود. استفاده از مدل‌های پیش آموزش دیده شبکه عصبی کانولوشن باعث می‌شود که ویژگی‌ها با کیفیت

بالاتر، نسبت به روش‌های سنتی از تصاویر استخراج شود. به علت ایجاد ویژگی‌های فراوان توسط مدل‌های شبکه عصبی کانولوشن، در فاز سوم از روش تحلیل مؤلفه‌های اصلی احتمالی به منظور کاهش ابعاد و وابستگی استفاده می‌شود که در نهایت 100 ویژگی اصلی از هر مدل استخراج می‌شود. در فاز چهارم طبقه‌بندی با استفاده از الگوریتم ماشین بردار پشتیبان انجام می‌شود. به منظور مقایسه نتایج، از سه شاخص ویژگی، حساسیت، و دقت استفاده شده است. نتایج مقایسه‌ای نشان می‌دهد که الگوریتم پیشنهادی عملکرد مناسبی در اکثر داده‌ها دارد.

**واژگان کلیدی:** یکسان‌سازی هیستوگرام؛ مدل‌های پیش‌آموزش‌دیده شبکه عصبی کانولوشن؛ تحلیل مؤلفه‌های اصلی احتمالی؛ ماشین بردار پشتیبان.

## 1- مقدمه

در سال‌های اخیر به دلیل رشد چشمگیر داده‌ها، ضرورت گسترش سیستم‌های کشف دانش از بین داده‌ها بسیار ضروری می‌باشد [1, 2]. در همین راستا چندین سیستم کمک پزشکی در زمینه تشخیص تومورهای مغزی ارائه شده است که با استفاده از کشف دانش از درون تصاویر تومورهای مغزی، می‌توانند به تشخیص این تومورها کمک نمایند. تومورهای مغزی حدود دو درصد تومورهای انسان را تشکیل می‌دهند، ولی به علت محل قرارگیری آن‌ها، مرگ‌ومیر در این زمینه شش برابر بیشتر از تومورهای دیگر است. به منظور شناسایی تومورهای مغزی روش‌های مختلفی وجود دارد. در میان این روش‌ها، تشخیص به کمک سیستم‌های کامپیوتری در سال‌های اخیر گسترش یافته است. یکی از روش‌های معمول در شناسایی تومورهای مغزی، تصویربرداری پزشکی است. پرکاربردترین آن‌ها شامل تصاویر ام‌آرآی و تصاویر سی‌تی است [3]. معمولاً تصاویر ام‌آرآی از لحاظ کارایی بالاتر و ارزیابی آسان‌تر، بیشتر استفاده می‌شود. تصاویر ام‌آرآی معمولاً به صورت تراکم پروتون<sup>1</sup>، T1- Weighted، T2- Weighted و فلیر<sup>2</sup> استفاده می‌شود [4]. فراوانی اطلاعات موجود در تصاویر ام‌آرآی، بسیار بیشتر از حوزه دید انسان است، زیرا سیستم‌های ام‌آرآی امروزی می‌تواند تصاویری برابر با 65,535 سطح خاکستری را ایجاد کند [5]. با توجه به حجم بالای داده‌ها، از

1. Proton Density

2. Flair

کامپیوتر در پردازش تصاویر ام‌آر‌آی و کشف دانش در چارچوب‌های ریاضی استفاده می‌شود.

الگوریتم‌های مربوط در زمینه پردازش تصاویر پزشکی معمولاً شامل پنج مرحله اصلی است. این پنج مرحله شامل پیش‌پردازش، قطعه‌بندی، استخراج ویژگی، کاهش ابعاد و طبقه‌بندی است [6]. پیش‌پردازش شامل مراحل از جمله حذف نویز و اصلاح مقادیر شدت است. تکنیک‌های قطعه‌بندی، پیکسل‌های مشابه را در کلاس‌های مختلف به وجود می‌آورد. با استفاده از تکنیک‌های استخراج ویژگی، تعدادی ویژگی از تصاویر استخراج می‌شود و با استفاده از تکنیک‌های کاهش ابعاد، میزان ابعاد و وابستگی در ویژگی‌ها کاهش می‌یابد. انتخاب تکنیک‌های مناسب در استخراج ویژگی و استفاده از طبقه‌بند‌های مناسب، بیشترین تأثیر را در دقت الگوریتم‌های طبقه‌بندی در تصاویر پزشکی دارند. همچنین استفاده از یک روش مناسب در زمینه قطعه‌بندی می‌تواند باعث ایجاد ویژگی‌های مناسب‌تری گردد.

در این مقاله یک الگوریتم ترکیبی جدید به منظور طبقه‌بندی تومورهای مغزی در تصاویر ام‌آر‌آی معرفی می‌شود. این الگوریتم از چهار گام اصلی (بدون استفاده از قطعه‌بندی) مشتمل بر پیش‌پردازش، استخراج ویژگی‌ها، کاهش ابعاد، و طبقه‌بندی تشکیل شده است. از روش یکسان‌سازی هیستوگرام<sup>1</sup> به منظور پیش‌پردازش استفاده می‌شود. از مدل‌های پیش آموزش دیده شبکه عصبی کانولوشن<sup>2</sup> شامل مدل‌های الکسنت<sup>3</sup> و گوگلنت<sup>4</sup> به منظور استخراج ویژگی، و از تکنیک تحلیل مؤلفه‌های اصلی احتمالی<sup>5</sup> به منظور کاهش ابعاد بر روی ویژگی‌ها استفاده می‌شود. در نهایت به منظور طبقه‌بندی، الگوریتم ماشین بردار پشتیبان<sup>6</sup> استفاده می‌شود.

در ادامه این مقاله و در بخش دوم، مرور میانی نظری موضوع بررسی می‌شود و در بخش سوم، الگوریتم پیشنهادی شرح داده می‌شود. در بخش

---

1. Histogram Equalization  
2. Convolution Neural Network  
3. AlexNet  
4. GoogleNet  
5. Probabilistic Principal Component Analysis  
6. Support Vector Machine

چهارم، نتایج به‌کارگیری روش پیشنهادی ارائه و در بخش پنجم درباره نتایج به‌دست‌آمده بحث و نتیجه‌گیری می‌شود.

## 2- پیشینه تحقیق

روش‌های مختلفی به منظور پیش پردازش داده‌ها در تصاویر ام‌آرآی وجود دارد. یکی از فیلدهایی که کاربرد زیادی در پیش پردازش تصاویر ام‌آرآی دارد فیلد نرمالایز شدت روشنایی<sup>1</sup> نام دارد که در تجزیه و تحلیل بافتهای کمی و بهبود کنتراست تصاویر ضروری هستند. نبی زاده و کوبات [7] شش روش شامل مقیاس شدت<sup>2</sup>، نرمال سازی کشش کنتراست<sup>3</sup>، نرمال سازی هیستوگرام<sup>4</sup>، کشش هیستوگرام<sup>5</sup>، یکسان سازی هیستوگرام و نرمال سازی کرنل گوسی<sup>6</sup>، در فیلد نرمالایز شدت روشنایی معرفی شده است. بر اساس نتایج حاصل از مقاله لوئیزو و همکاران [8]، روش یکسان سازی هیستوگرام در تصاویر پزشکی نسبت به سایر روش‌ها، کارایی بهتری را داشته است.

استخراج ویژگی، فرایند تبدیل تصویر به گروهی از ویژگی‌ها اطلاق می‌شود. در زمینه استخراج ویژگی می‌توان الگوریتم‌های موجود در این حوزه را به دو دسته الگوریتم‌های سنتی<sup>7</sup> و الگوریتم‌های یادگیری عمیق<sup>8</sup> تقسیم کرد. در زمینه الگوریتم‌های سنتی استخراج ویژگی می‌توان به الگوریتم‌های ماتریس هم‌رخداد<sup>9</sup> و تبدیل موجک گسسته<sup>10</sup> اشاره کرد. استخراج ویژگی با استفاده از الگوریتم‌های ماتریس هم‌رخداد اولین بار توسط هارالیک و شانموگام [9] مطرح گردید. آنها در این مقاله 14 تکنیک آماری از جمله میزان وابستگی، آنتروپی، مجموع واریانس، همگنی، مجموع مربعات خطا و غیره را به منظور طبقه‌بندی معرفی کردند. تبدیل موجک گسسته به منظور استخراج ویژگی در تصاویر ام‌آرآی استفاده می‌شود که

- 
1. Intensity Normalization
  2. Intensity Scaling
  3. Contrast Stretch Normalization
  4. Histogram Normalization
  5. Histogram Stretching
  6. Gaussian Kernel Normalization
  7. Traditional algorithm
  8. Deep learning algorithm
  9. Gray-Level Co-Occurrence Matrix
  10. Discreet Wavelet Transform

یک ابزار قدرتمند بر پایه ریاضیات است [10]. در زمینه الگوریتم‌های استخراج ویژگی در حوزه یادگیری عمیق می‌توان از مدل‌های پیش آموزش دیده‌ی شبکه عصبی کانولوشن استفاده نمود. معروفترین این الگوریتم‌ها مدل الکسنت و گوگل نت می‌باشند که در سالهای اخیر به عنوان روش‌های کارآمد استخراج ویژگی مورد استفاده قرار می‌گیرند. با توجه به ایجاد ویژگی‌های با ابعاد بالا توسط روش‌های استخراج ویژگی، معمولاً از روش‌های مختلف کاهش ویژگی بدون از دست دادن اطلاعات مهم، به منظور کاهش این ویژگی‌ها استفاده می‌شود. روش‌های مختلفی به منظور کاهش ویژگی در مقاله زولنر و همکاران [11] معرفی شده است. این روش‌ها شامل ضریب همبستگی پیرسون<sup>1</sup>، تحلیل مولفه‌ی اصلی<sup>2</sup>، تجزیه و تحلیل مولفه‌ی مستقل<sup>3</sup> می‌شوند. این روش‌ها تاثیر بسیار اندکی بر روی دقت طبقه‌بندی می‌گذارند [12].

روش‌های طبقه‌بندی شامل روش‌های نظارت شده و روش‌های غیر نظارت شده است [6]. برخی از روش‌های نظارت شده شامل ماشین بردار پشتیبان<sup>4</sup>، K نزدیکترین همسایگی<sup>5</sup>، تحلیل تفکیک کننده‌ی خطی<sup>6</sup>، بیز ساده<sup>7</sup>، درخت تصمیم<sup>8</sup>، ماشین بردار پشتیبان بر اساس تابع کرنل شعاعی<sup>9</sup>، و رگرسیون لجستیک<sup>10</sup> می‌باشند. این روش‌ها به عنوان ابزارهای طبقه‌بندی در مقالات بسیاری مورد استفاده قرار گرفته‌اند.

در جدول 1، الگوریتم‌های مختلفی به منظور طبقه‌بندی به همراه دقت آنها در طبقه‌بندی نشان داده شده است. در این جدول روش‌های استخراج ویژگی به دو دسته الگوریتم‌های سنتی استخراج ویژگی از جمله ماتریس هم رخداد و تبدیل موجک گسسته و استخراج ویژگی با استفاده از مدل‌های یادگیری عمیق از جمله مدل‌های پیش آموزش دیده شبکه عصبی کانولوشن تقسیم شده است.

- 
1. Pearson's Correlation Coefficients
  2. Principal Component Analysis
  3. Independent Component Analysis
  4. Support Vector Machine
  5. K-Nearest Neighbor
  6. Linear Discriminant Analysis
  7. Naive Bayes
  8. Decision Tree
  9. SVM with radial basis function based kernel
  10. Logistic Regression

جدول 1 مرور برخی از الگوریتم‌های طبقه‌بندی با استفاده از روش‌های سنتی استخراج ویژگی

سال	دقت (درصد)	الگوریتم	روش
1990	97	ماتریس هم رخداد+ الگوریتم ژنتیک +انفیس [13]	روش‌های سنتی استخراج ویژگی
2006	96/16	تبدیل موجک گسسته + ماشین بردار پشتیبان با کرنل خطی [14]	
2006	98	تبدیل موجک گسسته + ماشین بردار پشتیبان با کرنل چندجمله‌ای [14]	
2006	98	تبدیل موجک گسسته + ماشین بردار پشتیبان با کرنل شعاعی [14]	
2010	98/6	تبدیل موجک گسسته+ تحلیل مؤلفه‌های اصلی + K نزدیک‌ترین همسایه [15]	
2011	88/88	ماتریس هم رخداد+ تحلیل مؤلفه‌های اصلی + ماشین بردار پشتیبان [16]	
2014	100	ماتریس هم رخداد+ شبکه عصبی احتمالی- شبکه عصبی شعاعی [17]	
2015	100	تبدیل موجک گسسته + تحلیل مؤلفه‌های اصلی احتمالی + الگوریتم ادابوست با جنگل تصادفی [18]	استخراج ویژگی با استفاده از روش‌های پیش آموزش‌دیده
2018	99/76	(الکسنت، گوگل‌نت، Vgg-f) + gain ratio + ماشین بردار پشتیبان [19]	

### 3- الگوریتم پیشنهادی

روش پیشنهادی در این مقاله منجر به تشخیص تومورهای مغزی در تصاویر ام‌آرآی می‌شود. بر اساس فلوچارت مربوط به شکل (1)، الگوریتم موردنظر شامل چهار مرحله پیش‌پردازش، استخراج ویژگی، کاهش ابعاد و طبقه‌بندی است. استفاده از مدل‌های پیش آموزش‌دیده‌ی شبکه عصبی کانولوشن به منظور طبقه‌بندی تومورهای مغزی در تصاویر ام‌آرآی، ایده‌ی اصلی این مقاله است و این مطالعه را از سایر مطالعات در حوزه طبقه‌بندی تصاویر ام‌آرآی متمایز می‌سازد. در این مقاله از روش یکسان‌سازی هیستوگرام به منظور پیش‌پردازش، از شبکه عصبی کانولوشن به منظور استخراج ویژگی، از روش تحلیل مؤلفه‌های اصلی احتمالی به منظور کاهش ابعاد، و از الگوریتم ماشین بردار پشتیبان به منظور طبقه‌بندی در کلاس‌های مختلف استفاده می‌شود. در ادامه این بخش و در ابتدا، روش یکسان‌سازی هیستوگرام معرفی می‌گردد؛ در ادامه

مدل‌های پیش آموزش دیده شبکه عصبی کانولوشن بررسی می‌شود؛ سپس الگوریتم تحلیل مؤلفه‌های اصلی احتمالی تشریح و در نهایت الگوریتم ماشین بردار پشتیبان به منظور طبقه‌بندی چندکلاسه شرح داده می‌شود.

### 3-1- یکسان‌سازی هیستوگرام

فرایند تعدیل مقادیر شدت می‌تواند به صورت خودکار توسط یکسان‌سازی هیستوگرام انجام شود. در این روش هیستوگرام تصویر خروجی یکنواخت می‌گردد و باعث می‌شود یکنواختی تصویر تا حد ممکن افزایش یابد. یکسان‌سازی هیستوگرام بر اساس رابطه (1)، به ازای هر پیکسل محاسبه می‌شود:

$$h(v) = \text{round} \left( \frac{cdf(v) - cdf_{min}}{(w \times h) - 1} \right) \times (L - 1) \quad (1)$$

در رابطه (1)،  $h(v)$  مقدار هیستوگرام،  $cdf(v)$  مقدار تابع توزیع تجمعی مربوط به پیکسل  $v$ ،  $cdf_{min}$  کمترین مقدار تابع توزیع تجمعی،  $w$  عرض تصویر،  $h$  ارتفاع تصویر و  $L$  تعداد سطوح خاکستری استفاده شده که در بیشتر مواقع مقدار 256 را دارد.

### 3-2- شبکه عصبی کانولوشن

در حال حاضر محققانی که با هوش مصنوعی کار می‌کنند، مدل‌های یادگیری عمیق را به منظور ایجاد سیستم‌های محاسباتی قوی استفاده می‌کنند. در میان این مدل‌ها، شبکه‌های عصبی مصنوعی یکی از بهترین ابزارها می‌باشند. شبکه عصبی مصنوعی از یک مجموعه گره‌های غیرخطی که به صورت موازی در ارتباط با یکدیگر هستند، تشکیل شده است [20]. در میان شبکه‌های عصبی، شبکه‌های عصبی کانولوشن، به منظور استخراج ویژگی و طبقه‌بندی در زمینه یادگیری عمیق استفاده می‌شوند. هدف از طراحی شبکه‌های عصبی کانولوشن، مدل‌سازی دقیق از نحوه عملکرد سیستم بینایی انسان و ارتباط آن با ناحیه بینایی مغز است که وظیفه استخراج خودکار ویژگی‌های کلیدی، یادگیری

تصاویر در یک سیستم عصبی و همچنین حذف افزونگی‌های احتمالی را بر عهده دارد. شبکه عصبی کانولوشن نوعی از یادگیری عمیق است که چندین لایه کانولوشن<sup>1</sup> و پولینگ<sup>2</sup> دارد. لایه ورودی شبکه عصبی کانولوشن معمولاً یک تصویر با ابعاد دلخواه، و خروجی آن یک بردار ویژگی با تفکیک‌پذیری بالا و متناظر با کلاس‌های مختلف است. لایه‌های پنهان در این شبکه لایه کانولوشن، لایه پولینگ، و لایه اتصال کامل<sup>3</sup> است. ساختار ساده شبکه عصبی کانولوشن در شکل (2) نشان داده شده است. لایه کانولوشن شامل وزن‌ها و بایاس‌های قابل‌آموزش است که به صورت فیلتر با ابعاد و اعماق مختلف بر روی لایه‌های ورودی اعمال می‌شوند و یک نقشه ویژگی به ازای هر نمونه و هر فیلتر تولید می‌شود. با اتصال این نقشه‌های ویژگی به یکدیگر یک لایه کانولوشن تشکیل می‌شود. لایه پولینگ یک تابع نمونه‌برداری غیرخطی به همراه کاهش مقیاس است که می‌تواند توابعی مانند ماکزیمم‌گیری، میانگین‌گیری و حتی نرم‌کمترین مربعات باشد. اعمال این لایه به لایه ورودی باعث می‌شود که ابعاد لایه ورودی به تدریج کاهش یابد. لایه اتصال کامل، لایه نهایی دارای ویژگی‌های سطح بالا است و هر نورون در این لایه به یکی از نقشه‌های ویژگی در لایه قبلی متصل است.

دو روش برای استفاده از شبکه عصبی کانولوشن وجود دارد. روش اول فرایند آموزش با استفاده از یک مجموعه بزرگ داده انجام می‌شود و در روش دوم از روش‌های پیش آموزش‌دیده به منظور استخراج ویژگی استفاده می‌شود [19]. در این مطالعه از روش دوم استفاده می‌شود که در آن با استفاده از مدل‌های پیش آموزش‌دیده، فرایند استخراج ویژگی انجام می‌شود. مدل‌های پیش آموزش‌دیده استفاده‌شده در این مقاله شامل مدل الکسنت و گوگل‌نت است. ساختار کلی این مدل‌ها شبیه به هم است و تفاوت آن‌ها در سایز فیلترهای استفاده‌شده در لایه کانولوشن و تعداد عصب در لایه اتصال کامل است.

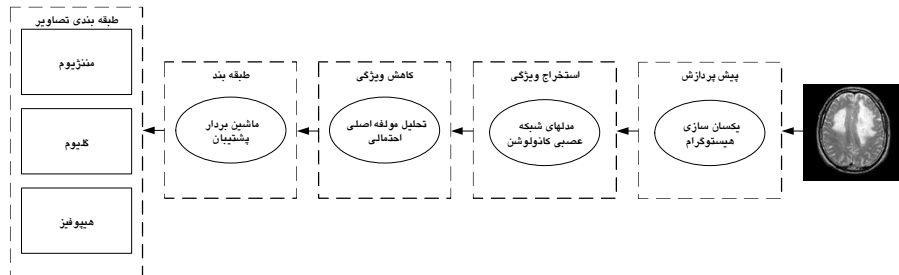
---

1. Convolution layer  
2. Pooling  
3. Fully-connected layer




**مدل الکسنت:** این مدل در سال 2012 به منظور آموزش و طبقه‌بندی داده‌های ImageNet در مقاله [21] معرفی شد. ImageNet شامل 1,2 میلیون تصویر  $256 \times 256$  است که در 1000 زیرمجموعه تقسیم شده است. بر اساس شکل (3) این مدل شامل پنج لایه کانولوشن، سه لایه پولینگ و دو لایه اتصال کامل است.

**مدل گوگلنت:** مدل گوگلنت در مقاله [22] معرفی شد و نسبت به مدل الکسنت عمیق‌تر و پیچیده‌تر است. در این مدل یک مفهوم جدید به اسم اینسپشن<sup>1</sup> معرفی شد. هر اینسپشن شامل شش لایه کانولوشن و یک لایه پولینگ است. بر اساس شکل (4)، مدل گوگلنت شامل دو لایه کانولوشن، سه لایه پولینگ و نه لایه اینسپشن است.



شکل 1 مدل پیشنهادی




شکل 2 ساختار ساده شبکه عصبی کانولوشن



شکل 3 ساختار مدل الکسنت

## 1. Inception



شکل 4 ساختار مدل گوگل‌نت

### 3-3- کاهش ابعاد

کاملاً مشخص است بردار استخراج‌شده از روش‌های الکسنت و گوگل‌نت به‌عنوان ویژگی دارای ابعاد زیادی است و منجر به افزایش میزان پیچیدگی محاسباتی و زمان محاسباتی در طبقه‌بندی می‌شود. عموماً تمام این ویژگی‌ها در طبقه‌بندی استفاده نمی‌شوند و استفاده از روش‌های کاهش ابعاد، باعث می‌شود که از میان ویژگی‌های به‌دست‌آمده، ویژگی‌های بهینه‌ی مؤثر که باعث دستیابی به بیشترین درصد صحت در تشخیص نمونه‌ها شده‌اند، انتخاب گردند. این روش‌ها تأثیر بسیار اندکی بر روی طبقه‌بندی می‌گذارند. در میان این روش‌ها، روش تحلیل مؤلفه‌های اصلی احتمالی به دلیل نمایش داده‌ها با حجم کم با فرم توزیع احتمالی از داده‌های حجیم، در این مطالعه مورد استفاده قرار می‌گیرد. این روش یک فرمول احتمالی از روش تحلیل مؤلفه‌های اصلی بر اساس یک مدل متغیر پنهان گاوسی است که اولین بار توسط تیپینگ و بیشاپ [23] معرفی شد. یکی از مزیت‌های روش تحلیل مؤلفه‌های اصلی احتمالی نسبت به روش تحلیل مؤلفه‌های اصلی این است که در مواردی که تعداد نمونه‌ها از ابعاد داده‌ها کمتر است، پیچیدگی محاسباتی در یافتن بردار ویژه را کاهش می‌دهد.

### 3-3-1- روش تحلیل مؤلفه‌های اصلی احتمالی

تحلیل مؤلفه‌های اصلی احتمالی مبتنی بر یک مدل خطای ایزوتروپیک است. این مدل به دنبال یافتن ارتباط بین بردار مشاهدات ( $y$ ) با  $p$  بعد، و بردار  $k$  بعدی متغیرهای لیتنت<sup>1</sup> ( $x$ ) است. متغیر ( $x$ ) دارای توزیع حاشیه‌ای نرمال با میانگین صفر و واریانس یک است. این مدل بر اساس رابطه (2) تعریف می‌شود:

1. ?????????????

$$y^t = W * x^t + \mu + \varepsilon \quad (2)$$

جایی که  $y$  بردار مشاهدات سطری،  $x$  بردار متغیرهای لیتنت،  $\varepsilon$  یک متغیر سطری است که نشان‌دهنده‌ی خطاهای تصادفی است. بردار مشاهدات  $y$ ، با توجه به مقادیر متغیرهای لیتنت  $X$ ، به صورت شرطی مستقل هستند. بنابراین متغیرهای لیتنت، رابطه بین بردار مشاهدات و متغیرهای خطا را توضیح می‌دهند که تغییرات منحصر به یک  $y_i$  خاص است. ماتریس  $W$  یک ماتریس  $p$  در  $k$  است که متغیرهای لیتنت و مشاهدات را در برمی‌گیرد و متغیر  $\mu$  یک بردار سطری است که شامل میانگین هر متغیر است. تحت این مدل،

$$y \sim N(\mu, W * W^T + \nu * I(K)) \quad (3)$$

با توجه به رابطه (3) هیچ راه‌حل تحلیلی برای تخمین  $\nu$  و  $W$  وجود ندارد، بنابراین آن‌ها با استفاده از روش حداکثر درست‌نمایی با استفاده از الگوریتم  $EM^1$  تعیین می‌شوند که جزئیات این الگوریتم در مقاله [23] توضیح داده شده است. در همگرایی این الگوریتم، ستون‌های  $W$  یک سری بردارهای زیرمجموعه را تشکیل می‌دهند که یک ماتریس متعامد است. تحلیل مؤلفه‌های اصلی احتمالی ضرایب متعامد را با استفاده از فرایند یافتن زیرمجموعه بردارهای متعامد از  $W$  که در یک زیر فضای خاص قرار دارند، به دست می‌آورد.


### 3-4- ماشین بردار پشتیبان برای طبقه‌بندی چند کلاس متفاوت

ایده اساسی ماشین بردار پشتیبان بر مبنای ساختار یک ابر صفحه بهینه می‌باشد که حداکثر جداسازی برای دو کلاس را ایجاد می‌کند. در مسائل طبقه‌بندی باینری، مجموعه داده‌های آموزش عضو اعداد حقیقی  $x_i \in R$  و بردار وابستگی دارای

---

1. Latent variables  
1. Expectation-Maximization

مقادیر باینری  $y_i \in \{-1, 1\}$  است. ایده‌ی اصلی یک طبقه‌بندی با ماشین بردار پشتیبان، در شکل (5) مشخص شده است. این شکل ساده‌ترین حالت را نشان می‌دهد که در آن بردارهای داده که با علامت ستاره و دایره نشان داده شده‌اند را می‌توان توسط یک فوق صفحه از هم جدا کرد. در چنین حالتی می‌توان فوق صفحه‌های بسیاری برای جداسازی دو کلاس تعیین نمود. در بین تمام این فوق صفحه‌ها، طبقه بند ماشین بردار پشتیبان، فوق صفحه‌هایی را تعیین می‌کند که بیشترین حاشیه را داشته باشند. در حالت کلی‌تر زمانی که داده‌ها به صورت خطی قابل تفکیک نباشند از یک تبدیل غیرخطی برای نگاشت کردن بردار داده به یک فضای بالاتر (فضای ویژگی) استفاده می‌شود. برای اینکه انتقال به فضای با ابعاد بالاتر باعث خطای بیش برآزش نشود، ماشین بردار پشتیبان از تابع کرنل استفاده می‌کند. کرنل‌های متداول و پرکاربرد شامل کرنل‌های چندجمله‌ای و تابع پایه‌ای شعاعی می‌باشد که در جدول (2) نمایش داده شده است.



شکل 5 ساختار ساده ماشین بردار پشتیبان در طبقه‌بندی باینری

جدول 2 انواع کرنل در ماشین بردار پشتیبان

فرمول	کرنل
$G(x_1, x_2) = e^{-x_1 - x_2^2}$	تابع پایه‌ای شعاعی (RBF)
$G(x_1, x_2) = x_1^T x_2$	خطی
$G(x_1, x_2) = (1 + x_1^T x_2)^p$	چندجمله‌ای

برای گسترش کاربرد ماشین بردار پشتیبان به منظور طبقه‌بندی چند کلاس مختلف، سه روش اصلی پیشنهاد شده است که این روش‌ها به سه دسته کلی روش OAA (One-Against-All)، روش OAO (One-Against-One)، روش AAO (All-At-Once) تقسیم‌بندی می‌شوند [24]. در این مقاله از روش OAO استفاده می‌شود. در روش OAO، یک ماشین بردار پشتیبان به منظور طبقه‌بندی، کلاس‌ها را به  $\frac{n \times (n-1)}{2}$  کلاس باینری تقسیم می‌کند. بنابراین برای ساختن یک ماشین بردار پشتیبان برای طبقه‌بندی کلاس  $k$ th و کلاس  $l$ th مسئله زیر حل می‌شود:

$$\min Q_p(\mathbf{W}^{kl}, b^{kl}, \xi^{kl}) = \frac{1}{2}(\mathbf{W}^{kl})^T (\mathbf{W}^{kl}) + C \sum_{i=1}^m \xi_i^{kl}$$

Subject to: (4)

$$\begin{aligned} (\mathbf{W}^{kl})^T \cdot \phi(\mathbf{x}_i) + b^{kl} &\geq 1 - \xi_i^{kl}, \text{ if } y_i = k, \\ (\mathbf{W}^{kl})^T \cdot \phi(\mathbf{x}_i) + b^{kl} &\geq -1 + \xi_i^{kl}, \text{ if } y_i = 1, \\ \xi_i^{kl} &\geq 0, i = 1, \dots, m \text{ and } k, l = 1, \dots, n. \end{aligned}$$

بر اساس رابطه (4)،  $\mathbf{W}$  برابر با ماتریس وزن‌ها با  $n$  بعد،  $b$  به‌عنوان بایاس می‌باشد که  $\mathbf{W}$  و  $b$ ، شکل و موقعیت ابر صفحه را تعیین می‌کنند.  $\xi = \{\xi_1, \dots, \xi_m\}$  متغیرهای کمکی می‌باشند و  $C$  ضریب پنالتی است که تعادل بین پیچیدگی مدل و خطای طبقه‌بندی را برقرار می‌کند. مقدار بالای  $C$  باعث ایجاد بیش برآزش خواهد شد.  $\phi(\mathbf{x}_i)$  یک تبدیل غیرخطی است که نمونه را به یک فضای

نقطه‌ای با ابعاد بزرگ‌تر به نام فضای ویژگی تبدیل می‌کند.  $i = 1, \dots, m$  تعداد رکوردهای داده‌های تست و  $n$  نشان‌دهنده‌ی تعداد ابعاد داده می‌باشد.  $y_i$  به‌عنوان برچسب داده‌های آموزش در نظر گرفته می‌شود.

#### 4- تجزیه و تحلیل نتایج

در این بخش به منظور ارزیابی نتایج، در ابتدا تصاویر ام‌آرآی و ویژگی‌های آن‌ها شرح داده می‌شود. در ادامه دقت طبقه‌بندی الگوریتم ماشین بردار پشتیبان با استفاده از ویژگی‌های الکسنت و گوگل‌نت به صورت تکی مقایسه می‌شود. در نهایت ویژگی‌های الکسنت و گوگل‌نت با هم ترکیب شده و دقت طبقه‌بندی محاسبه و با ویژگی‌های تکی مقایسه می‌شود. پارامترهای الگوریتم طبقه‌بندی ماشین بردار پشتیبان بر اساس جدول (3) تنظیم شده است.

جدول 3 تنظیم شاخص الگوریتم‌های طبقه بند

تنظیمات شاخص‌ها	الگوریتم
ضریب تابع پناستی = 1.0 نوع کرنل = خطی اپسیلون = 1.0E-12	ماشین بردار پشتیبان

#### 4-1- تصاویر ام‌آرآی

در این مقاله به منظور ایجاد یک پایگاه داده معتبر، تعدادی تصاویر ام‌آرآی از وبسایت دانشگاه پزشکی جنوبی گوانگژو چین [25] جمع‌آوری شده است. این گروه تصاویر شامل 3064 تصویر T1-weighted است که از 233 بیمار جمع‌آوری شده است. در این تصاویر سه نوع تومور شامل مننژیوم، گلیوم، و تومور هیپوفیز شناسایی شده است. با توجه به پیچیدگی محاسباتی بالا، از هر گروه از تصاویر، 300 تصویر انتخاب شده است. همچنین به منظور تقسیم‌بندی تصاویر به داده‌های آموزش و تست، از روش اعتبار سنجی متقاطع استفاده شده است که در این روش تعداد فولدها برابر سه در نظر گرفته می‌شود. بر اساس این روش، داده‌ها به سه زیرمجموعه مجزا تقسیم‌بندی می‌شوند که در هر تکرار یک زیرمجموعه از داده‌ها

به‌عنوان داده‌های تست، دو زیرمجموعه به‌عنوان داده آموزش و در نهایت میانگین خطای هر سه فولد به‌عنوان خطای نهایی طبقه‌بندی در نظر گرفته می‌شود. در شکل (6) نمونه‌ای از تصاویر ام‌آرآی و همچنین نوع تومور به همراه کلاس آن مشخص شده است. اندازه تمامی تصاویر  $227 \times 227$  است.




شکل 6 انواع تومورهای مغزی

#### 2-4- یکسان‌سازی هیستوگرام

در شکل (7)، تصویر سمت چپ نشان‌دهنده‌ی تصویر اصلی، و تصویر سمت راست بعد از به‌کارگیری روش یکسان‌سازی هیستوگرام ایجاد شده است. در این مرحله، عملیات پیش‌پردازش با استفاده از روش یکسان‌سازی هیستوگرام بر روی کلیه تصاویر ام‌آرآی انجام می‌شود.

تصویر بهبودیافته      تصویر اصلی



شکل 7 پیش‌پردازش تصویر با استفاده از روش یکسان‌سازی هیستوگرام

#### 3-4- الکسنت

در این بخش کارایی طبقه‌بندی در ماشین بردار پشتیبان در داده‌های مختلف، بر مبنای سه شاخص دقت طبقه‌بندی، حساسیت، و ویژگی، بر اساس نتایج حاصل از

ماتریس کانفیوژن اندازه‌گیری می‌شود. فرمول‌ها برای محاسبه اندازه کارایی در روابط (5)، (6) و (7) ارائه شده است.

$$\text{Specificity} = TN / (TN + FP) \quad (5)$$

$$\text{Sensitivity} = TP / (TP + FN) \quad (6)$$

$$CA = (TP + TN) / (TP + TN + FP + FN) \quad (7)$$

$TP$  نشان‌دهنده‌ی تعداد پیش‌بینی‌های صحیح مربوط به همان کلاس،  $TN$  نشان‌دهنده‌ی پیش‌بینی‌های صحیح مربوط به غیر از کلاس فعلی،  $FP$  نشان‌دهنده‌ی تعداد پیش‌بینی نادرست مربوط به همان کلاس، و  $FN$  نشان‌دهنده‌ی تعداد پیش‌بینی نادرست مربوط به کلاس‌های دیگر است.

ویژگی‌های الکسنت شامل 4096 ویژگی استخراج شده است که در سه کلاس طبقه‌بندی شده‌اند. با توجه به اینکه در مجموع، 4096 ویژگی از مدل الکسنت از 900 تصویر ام‌آرآی استخراج شده است، در نهایت 100 ویژگی اصلی با استفاده از روش تحلیل مؤلفه‌های اصلی احتمالی انتخاب می‌شود و یک پایگاه داده با 900 سطر و 100 ستون به دست می‌آید که سطرها نشان‌دهنده تعداد تصاویر و ستون‌ها نشان‌دهنده تعداد ویژگی‌ها است که به‌عنوان اطلاعات ورودی به ابزارهای طبقه‌بندی محسوب می‌شوند. نتایج مربوط به شاخص‌های ویژگی، حساسیت و دقت، که از عملکرد الگوریتم ماشین بردار پشتیبان در هر سه فولد بدست آمده است، در جدول (4) نمایش داده شده است. نتایج جدول (4) بر اساس نتایج مربوط به ماتریس کانفیوژن مربوط به شکل (8) می‌باشد که نتایج حاصل در این ماتریس کانفیوژن بر اساس داده‌های الکسنت به‌علاوه الگوریتم تحلیل مؤلفه‌های اصلی احتمالی بدست آمده است. نتایج مقایسه‌ای بر اساس میانگین شاخص‌ها در جدول (4) نشان می‌دهد که در هر سه فولد، در شاخص ویژگی 75 درصد، در شاخص حساسیت مقدار 61 درصد، و در شاخص دقت مقدار 70 درصد به دست آمده است.



ترکیب ماشین بردار پشتیبان و مدل‌های پیش ... \_\_\_\_\_ علیرضا بالوند و همکاران

جدول 4 نتایج شاخص‌های ویژگی، حساسیت و دقت در داده الکس نت + تحلیل مؤلفه‌های اصلی احتمالی بر اساس ماتریس کانفیوژن

فولد	مجموع داده	ویژگی (درصد)	حساسیت (درصد)	دقت (درصد)
1	الکس نت + تحلیل مؤلفه‌های اصلی احتمالی	73	57	67
2		76	58	70
3		76	68	73
میانگین				
		75	61	70

#### 4-4- گوگل‌نت

این داده‌ها شامل 1000 ویژگی استخراج شده از مدل گوگل‌نت است که شامل یک پایگاه داده با 900 سطر و 1000 ستون است که سطرها نشان‌دهنده تعداد تصاویر و ستون‌ها نشان‌دهنده تعداد ویژگی‌ها است. این ویژگی‌ها با استفاده از روش تحلیل مؤلفه‌های اصلی احتمالی به 100 ستون کاهش یافته است که باعث کاهش پیچیدگی محاسباتی و افزایش سرعت طبقه‌بندی می‌شود.

جدول 5 نتایج شاخص‌های ویژگی، حساسیت، و دقت در داده گوگل‌نت + تحلیل مؤلفه‌های اصلی احتمالی بر اساس ماتریس کانفیوژن

فولد	مجموع داده	ویژگی (درصد)	حساسیت (درصد)	دقت (درصد)
1	گوگل‌نت+تحلیل مؤلفه‌های اصلی احتمالی	90	96	92
2		98	95	97
3		95	94	94/67
میانگین				
		94	95	95

جدول (5) نشان‌دهنده‌ی عملکرد طبقه‌بندی در الگوریتم ماشین بردار پشتیبان است. در این جدول شاخص‌های ویژگی، حساسیت و دقت به ترتیب مقادیر 94 درصد، 95 درصد، و 95 درصد را نشان می‌دهد. این مقادیر بر اساس ماتریس‌های کانفیوژن مربوط به شکل (9) محاسبه شده‌اند. در این شکل عملکرد طبقه‌بندی الگوریتم ماشین

بردار پشتیبان در قالب ماتریس‌های کانفیوژن در هر سه فولد بر اساس داده‌های گوگل‌نت به‌علاوه تحلیل مؤلفه‌های اصلی احتمالی، نشان داده شده است.

#### 4-5- داده‌های ترکیبی

این داده‌ها شامل 5096 ویژگی است که ترکیبی از مدل الکسنت و گوگل‌نت است. این پایگاه داده شامل 900 سطر و 5096 ستون است که با استفاده از روش تحلیل مؤلفه‌های اصلی احتمالی، تعداد 100 ویژگی اصلی از این ویژگی‌ها شناسایی شده است که سطرها نشان‌دهنده تعداد تصاویر و ستون‌ها نشان‌دهنده‌ی تعداد ویژگی‌ها است.

جدول 6 نتایج شاخص‌های ویژگی، حساسیت و دقت در داده گوگل‌نت + تحلیل مؤلفه‌های اصلی احتمالی بر اساس ماتریس کانفیوژن

فولد	مجموع داده	ویژگی (درصد)	حساسیت (درصد)	دقت (درصد)
1	ترکیبی+تحلیل	92/5	93	92/67
2	مؤلفه‌های اصلی	97	98	98
3	احتمالی	98	97	97
میانگین				
		95/83	96	95/89


جدول (6)، نشان‌دهنده‌ی عملکرد طبقه‌بندی در الگوریتم ماشین بردار پشتیبان است. بر اساس این جدول، شاخص‌های ویژگی، حساسیت، و دقت به ترتیب مقادیر 95/83 درصد، 96 درصد، و 95/89 درصد را نشان می‌دهد. مقادیر این شاخص‌ها بر اساس ماتریس‌های کانفیوژن مربوط به شکل (10) محاسبه شده‌اند. در شکل (10)، عملکرد داده‌های ترکیبی در قالب ماتریس‌های کانفیوژن در هر سه فولد نشان داده شده است.

شکل (11) میانگین خطای طبقه‌بندی در ماشین بردار پشتیبان در کلیه داده‌ها را نشان می‌دهد. رنگ خاکستری نشان‌دهنده‌ی میانگین ویژگی طبقه‌بند، رنگ نارنجی نشان‌دهنده‌ی میانگین مقادیر حساسیت، و رنگ آبی میانگین دقت را نشان می‌دهد. ستون سمت راست در این شکل عملکرد طبقه‌بندی در ویژگی‌های الکسنت به‌علاوه تحلیل مؤلفه‌های اصلی احتمالی، ستون میانی، میانگین خطای طبقه‌بندی با استفاده از ویژگی‌های گوگل‌نت به‌علاوه تحلیل مؤلفه‌های اصلی احتمالی، و ستون سمت چپ میانگین خطای طبقه‌بندی با استفاده از ویژگی‌های ترکیبی به‌علاوه تحلیل مؤلفه‌های


اصلی احتمالی را نشان می‌دهد. با توجه به نتایج به دست آمده در مجموع می‌توان گفت که ویژگی‌های ترکیبی عملکرد بهتری را در طبقه‌بندی نسبت به ویژگی‌های گوگل نت و الکسنت در هر سه شاخص داشته است.




شکل 8 نتایج ماتریس‌های کانفیوژن در سه فولد مربوط به داده‌های الکسنت + تحلیل مؤلفه‌های اصلی احتمالی



شکل 9 نتایج ماتریس‌های کانفیوژن در سه فولد مربوط به داده‌های گوگل نت + تحلیل مؤلفه‌های اصلی احتمالی



شکل 10 نتایج ماتریس‌های کانفیوژن در سه فولد مربوط به داده‌های الکسنت + گوگل نت + تحلیل مؤلفه‌های اصلی احتمالی



شکل 11 مقایسه عملکرد طبقه بند ماشین بردار پشتیبان در سه شاخص ویژگی، حساسیت و دقت در داده‌های مختلف

## 5- بحث و نتیجه‌گیری

در این مقاله یک الگوریتم جدید به منظور طبقه‌بندی تومورهای مغزی در تصاویر ام‌آرآی معرفی شد که شامل 900 تصویر ام‌آرآی بود. این الگوریتم در چهار فاز اصلی اجرا می‌شد. در فاز اول به منظور پیش‌پردازش، از یکسان‌سازی هیستوگرام استفاده شد. در فاز دوم به منظور استخراج ویژگی از تصاویر، از مدل‌های پیش آموزش دیده شبکه عصبی کانولوشن شامل الکسنت، گوگل‌نت و ترکیب الکسنت و گوگل‌نت استفاده شد. با توجه به ایجاد ویژگی‌های فراوان توسط روش‌های استخراج ویژگی، از تکنیک تحلیل مؤلفه‌های اصلی احتمالی، به منظور کاهش ابعاد در ویژگی‌ها استفاده شد که در نهایت 100 ویژگی اصلی از هر روش شناسایی شد. به منظور طبقه‌بندی، از الگوریتم ماشین بردار پشتیبان استفاده شد. در این مقاله به منظور تقسیم داده‌ها به داده‌های آموزش و تست، از روش اعتبار سنجی متقاطع استفاده شد که در آن تعداد فولد برابر سه در نظر گرفته شد. برای تجزیه و تحلیل نتایج از میانگین سه شاخص ویژگی، حساسیت و دقت در هر سه فولد استفاده شد. این نتایج با استفاده از ماتریس‌های کانفیوژن مربوط به هر فولد محاسبه شدند. نتایج

به دست آمده نشان داد که طبقه‌بند ماشین بردار پشتیبان در مجموع دقت 70% را در داده‌های الکس‌نت به همراه تحلیل مؤلفه‌های احتمالی، دقت 95% را در داده‌های گوگل‌نت به همراه تحلیل مؤلفه‌های احتمالی، و دقت 96% را در داده‌های ترکیبی به همراه تحلیل مؤلفه‌های احتمالی، فراهم نمود که مقایسه بین شاخص‌ها نشان داد که ویژگی‌های ترکیبی، عملکرد بهتری در طبقه‌بندی در هر سه شاخص نسبت به سایر ویژگی‌ها داشت.

## 6- منابع

- [1] Broofer, A., A. Rezaeyan, and S. Shokoohyar. (2016), Identifying the customer behavior model in life insurance Sector using data mining. *Management Research in Iran*. 20(4): p. 65-94.
- [2] Khadivar, A. and F. Majibian. (2018), Workshops Clustering Using a Combination Approach of Data Mining and MCDM. *Modern Researches in Decision Making*. 3(2): p. 107-128.
- [3] Ramakrishnan, T. and B.J.P.R.L. Sankaragomathi. (2017), A professional estimate on the computed tomography brain tumor images using SVM-SMO for classification and MRG-GWO for segmentation. 94: p. 163-171.
- [4] Zhang, N., et al. (2011), Kernel feature selection to fuse multi-spectral MRI images for brain tumor segmentation. *Computer Vision and Image Understanding*. 115(2): p. 256-269.
- [5] Ortiz, A., et al. (2013), Two fully-unsupervised methods for MR brain image segmentation using SOM-based strategies. *Applied Soft Computing*. 13(5): p. 2668-2682.
- [6] Mohan, G. and M.M. Subashini. (2018), MRI based medical image analysis: Survey on brain tumor grade classification. *Biomedical Signal Processing and Control*. 39: p. 139-161.
- [7] Nabizadeh, N. and M. Kubat. (2015), Brain tumors detection and segmentation in MR images: Gabor wavelet vs. statistical features. *Computers & Electrical Engineering*. 45: p. 286-301.

- [8] Loizou, C.P., et al. (2009), Brain MR image normalization in texture analysis of multiple sclerosis. *Information Technology and Applications in Biomedicine*, 2009. ITAB 2009. 9th International Conference on: p. 1-5.
- [9] Haralick, R.M. and K. Shanmugam. (1973), Textural features for image classification. *IEEE Transactions on systems, man, and cybernetics*,(6): p. 610-621.
- [10] Daubechies, I.(1992), Ten lectures on wavelets. SIAM.
- [11] Zöllner, F.G., K.E. Emblem, and L.R. Schad. (2012), SVM-based glioma grading: optimization by feature reduction analysis. *Zeitschrift für medizinische Physik*. 22(3): p. 205-214.
- [12] Dash, M. and H. Liu. (1997), Feature selection for classification. *Intelligent data analysis*. 1(1-4): p. 131-156.
- [13] Dean, B.L., et al. (1990), Gliomas: classification with MR imaging. *Radiology*. 174(2): p. 411-415.
- [14] Chaplot, S., L. Patnaik, and N. Jagannathan. (2006), Classification of magnetic resonance brain images using wavelets as input to support vector machine and neural network. *Biomedical Signal Processing and Control*. 1(1): p. 86-92.
- [15] El-Dahshan, E.-S.A., T. Hosny, and A.-B.M. Salem. (2010), Hybrid intelligent techniques for MRI brain images classification. *Digital Signal Processing*. 20(2): p. 433-441.
- [16] Marshkole, N., B.K. Singh, and A. Thoke. (2011), Texture and shape based classification of brain tumors using linear vector quantization. *International Journal of Computer Applications*. 30(11): p. 21-23.
- [17] Preethi, G. and V. Sornagopal. (2014), MRI image classification using GLCM texture features. *2014 International Conference on Green Computing Communication and Electrical Engineering (ICGCCEE)*: p. 1-6.
- [18] Nayak, D.R., R. Dash, and B. Majhi. (2016), Brain MR image classification using two-dimensional discrete wavelet transform and AdaBoost with random forests. *Neurocomputing*. 177: p. 188-197.

- [19] Vogado, L.H., et al. (2018), Leukemia diagnosis in blood slides using transfer learning in CNNs and SVM for classification. *Engineering Applications of Artificial Intelligence*. 72: p. 415-422.
- [20] Hassan zadeh, A., M.h. Ghanbari, and S. Elahi. (2012), Classification of mobile banking users by data mining approach: Comparison between artificial neural networks and naïve bayes techniques. *Management Research in Iran*. 16(2): p. 57-71.
- [21] Krizhevsky, A., I. Sutskever, and G.E. Hinton. (2012), Imagenet classification with deep convolutional neural networks. *Advances in neural information processing systems*: p. 1097-1105.
- [22] Szegedy, C., et al. (2015), Going deeper with convolutions. *Proceedings of the IEEE conference on computer vision and pattern recognition*: p. 1-9.
- [23] Tipping, M.E. and C.M. Bishop. (1999), Probabilistic principal component analysis. *Journal of the Royal Statistical Society: Series B (Statistical Methodology)*. 61(3): p. 611-622.
- [24] Bae, M.H., T. Wu, and R. Pan. (2010), Mix-ratio sampling: Classifying multiclass imbalanced mouse brain images using support vector machine. *Expert Systems with Applications*. 37(7): p. 4955-4965.
- [25] Cheng, J. (brain tumor dataset. School of Biomedical Engineering Southern Medical University, Guangzhou, China. [https:// github.com/ chengjun583/ brainTumorRetrieval](https://github.com/chengjun583/brainTumorRetrieval).