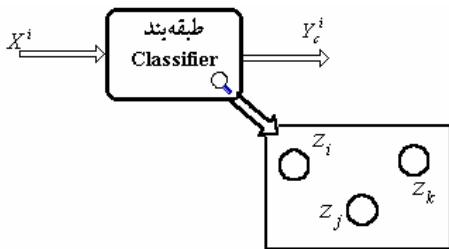
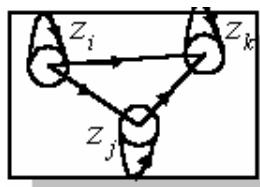


# تعیین رفتار طبقه‌بندها با کلیشه تصمیم مبتنی بر مدل مخفی مارکوف

هادی صدوقی یزدی



شکل ۱: تعیین رفتار متغیرهای  $z_i$ ,  $z_j$  و  $z_k$  که جزوی از طبقه‌بند می‌باشند.



شکل ۲: تعیین رفتار متغیرهای  $z_i$ ,  $z_j$  و  $z_k$  با استفاده از مدل مخفی مارکوف.

همان‌طور که در شکل ۱ دیده می‌شود، رفتار متغیرهای  $z_i$ ,  $z_j$  و  $z_k$  که سه متغیر از طبقه‌بند هستند، در پاسخ طبقه‌بند به ورودی‌های مختلف در افزایش کارآیی طبقه‌بند می‌تواند استفاده شود. ارتباط هر متغیر انتخابی همچون  $z_j$  با ورودی، می‌تواند با یک سیستم غیرایرانی غیرخطی مدل شود. در این مقاله احتمال وقوع متغیر انتخابی  $z_j$  با یک مدل  $\lambda$  به صورت  $P(z_j|\lambda)$  را مرتبط می‌کنیم و سپس از آن برای بهبود کارآیی تصمیم‌روی خروجی طبقه‌بند  $Y_c^i$  استفاده می‌کنیم.

مدل  $\lambda$  یک مدل مخفی مارکوف می‌باشد که ارتباط بین متغیرهای (همچون  $z_i$ ,  $z_j$  و  $z_k$ ) انتخابی را تعیین می‌کند. این مدل برای سه متغیر انتخابی شکل ۱ در شکل ۲ نشان داده است.

- به طور کلی این مقاله دارای سه نوآوری و نکته برگسته می‌باشد:
- (الف) بررسی نحوه عملکرد یک طبقه‌بند آموزش‌دهنده یا رفتار طبقه‌بند با استفاده از کلیشه تصمیم.
- (ب) ارائه یک کلیشه تصمیم جدید مبتنی بر مدل مخفی مارکوف.
- (ج) افزایش کارآیی یک طبقه‌بند با افزودن نتایج رفتار طبقه‌بند به تصمیم‌گیری نهایی.

در ادامه این بخش، مطالعات و تحقیقات محققین در زمینه نوآوری‌های انجام‌شده مرور می‌شود تا جایگاه و اهمیت مقاله ارائه شده، بیشتر روشن شود.

## ۲-۱ مرور کارهای پیشین

این مقاله دارای ۲ دیدگاه افزایش کارآیی و مدل‌کردن رفتار طبقه‌بند است. بنابراین در مرور بر کارهای انجام‌شده این دو جنبه بررسی می‌شود.

**الف- دیدگاه افزایش کارآیی طبقه‌بند**  
نکاتی وجود دارد که محققین را بر آن داشته تا در جهت افزایش کارآیی طبقه‌بندها تلاش کنند. از جمله آنها می‌توان به نویزی بودن داده‌ها

چکیده: مطالعه رفتار طبقه‌بندها از دیدگاه بررسی خطاهای آنها و ارائه راه حل مناسب برای کاهش خطأ و افزایش کارآیی طبقه‌بندها مورد توجه است. عملکرد ضعیف سیستم شناسایی به دلایل تعداد کم نمونه‌های یادگیری، نویز در داده‌ها، استفاده از ویژگی‌های شکننده به دلیل عدم آگاهی کامل و تسلط کافی بر نوع الگو و استفاده از عملگرهای نامناسب در تعیین پاسخ سیستم، کاهش نرخ شناسایی در تصمیم‌گیری نهایی را به دنبال دارد. با ارائه مدل مناسب آماری برای رفتار یا پاسخ یک سیستم شناسایی، می‌توان عملکرد سیستم شناسایی را بهبود داد.

در این مقاله یک کلیشه تصمیم جدید که با استفاده از مدل مخفی مارکوف ایجاد می‌شود، رفتار نرون‌های یک شبکه عصبی پس انتشار خطأ را، مدل می‌کند. در روش‌های موجود ارتباط بین نرون‌ها و تأثیر متقابل آنها در پاسخ به یک الگو مد نظر قرار نمی‌گیرد. ولی عملاً نرون‌های یک شبکه عصبی با اجزای یک طبقه‌بند، با هم بیان کننده عملکرد آن در مقابل یک الگو هستند. بنابراین، با استفاده از یک کلیشه تصمیم جدید مبتنی بر مدل مخفی مارکوف، ارتباط بین نرون‌های شبکه عصبی و نحوه پاسخ آن به نمونه‌های یادگیری، مدل می‌گردد تا از آن در شناسایی الگوهای جدید استفاده شود. روش جدید در مدل‌کردن رفتار طبقه‌بند، در سه کاربرد شناسایی ارقام دستنویس فارسی، تشخیص ترافیک عادی در شبکه‌های اطلاع‌رسانی و شناسایی نوع وسیله نقلیه آزمون می‌شود و افزایش قابل توجهی در نرخ شناسایی طبقه‌بند به دست می‌دهد.

**کلید واژه:** رفتار طبقه‌بند، شناسایی الگو، کلیشه تصمیم، مدل مخفی مارکوف، شبکه عصبی پس انتشار خطأ.

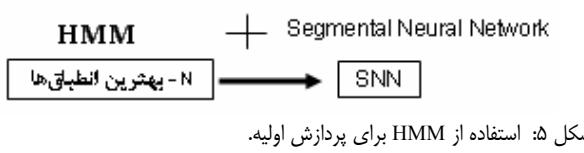
## ۱- مقدمه

در ایجاد طبقه‌بندها بر اساس یادگیری روش آموزش، انتظار می‌رود طبقه‌بند پس از دیدن چندین نمونه یادگیری از هر کلاس، نمونه‌های آزمون را با نرخ قابل قبول درست تشخیص دهد. نوع طبقه‌بند به کار رفته، ساختار آن، نحوه تصمیم‌گیری روش خروجی طبقه‌بند، شرایط اوایله استفاده شده در ایجاد حالات اولیه در بعضی طبقه‌بندها مثل شبکه‌های عصبی و مدل مخفی مارکوف، از جمله مواردی است که در طراحی طبقه‌بندها مورد توجه محققین است [۱].

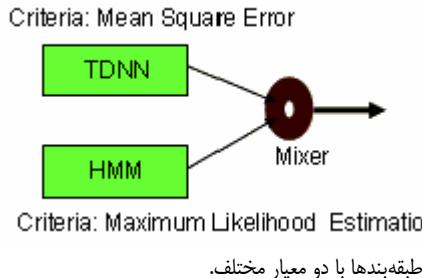
## ۱-۱ انگیزه

یک طبقه‌بند آموزش‌دهنده، به عنوان یک سیستم پیچیده است که می‌تواند به ورودی‌ها پاسخ دهد. اگر پاسخ سیستم به نمونه  $i$  کلاس  $c$  ام را با  $Y_c^i$  نشان دهیم و ورودی سیستم را  $X^i$  فرض کنیم (که هر دو بردار هستند)، می‌توان نحوه عملکرد طبقه‌بند و پاسخ اجزای آن را به عنوان اطلاعات مناسب در تصمیم‌گیری طبقه‌بند به کار برد. این مقاله در تاریخ ۱ اسفند ماه ۱۳۸۴ دریافت و در تاریخ ۲۲ مرداد ماه ۱۳۸۶ بازنگری شد.

هادی صدوقی یزدی، گروه الکترونیک، دانشکده فنی و مهندسی، دانشگاه تربیت معلم سبزوار، توحید شهر سبزوار، کد پستی ۳۹۷ (email: sadoghi@sttu.ac.ir).



شکل ۵: استفاده از HMM برای تقطیع سیگنال خروجی طبقه‌بند TDNN با سلول‌های LSTM.



شکل ۶: تلفیق طبقه‌بندها با دو معیار مختلف.

HMM برای شناسایی داده می‌شود. در اینجا مدل مخفی مارکوف به عنوان یک طبقه‌بند مطرح است.

کمک مدل مخفی مارکوف به<sup>۳</sup> SNN در شناسایی گفتار پیوسته از جمله تلفیق مدل مخفی مارکوف و شبکه‌های عصبی است [۱۸]. در شناسایی گفتار پیوسته یک راه حل برای کاهش خطا جستجوی N-gram بهترین انتباقي به جای یک انتباقي می‌باشد. سپس با استفاده از NLP این N جمله پردازش و اختباری با بالاترین امتیاز به دست می‌آید. در این کار از HMM برای تقطیع N-gram بهترین استفاده می‌شود سپس این تکه‌ها با شبکه SNN شناسایی می‌شود. در نهایت، نتیجه شناسایی نهایی شبکه SNN با مدل مخفی مارکوف تلفیق می‌شود. بنابراین در این روش، نتیجه مدل مخفی مارکوف و شبکه عصبی به عنوان دو طبقه‌بند، ترکیب می‌شوند (شکل ۵).

Mungkin است فقط نتایج حاصله از این دو طبقه‌بند ترکیب شود. در [۱۹] نتیجه حاصل از طبقه‌بند شبکه عصبی<sup>۴</sup> TDNN با HMM ترکیب می‌شود یعنی از دید ترکیب طبقه‌بندها<sup>۵</sup> این دو طبقه‌بند با دو ماهیت متفاوت در یادگیری، کارآیی بیشتری به دست می‌دهند. شبکه عصبی با معیار<sup>۶</sup> MSE آموزش داده می‌شود در حالی که مدل مخفی مارکوف با معیار<sup>۷</sup> MLE<sup>۸</sup> آموزش می‌یابند (شکل ۶).

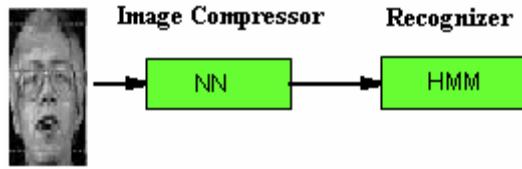
شبکه عصبی برای تخمین پارامترها مناسب است حال آنکه مدل مارکوف در مدل کردن ساختار یک فرآیند و ارتباط بین حالات آن، کارآیی دارد. با استفاده از شبکه‌های عصبی تابع توزیع یک فرآیند تخمین زده می‌شود، این قابلیت شبکه‌های عصبی باعث شده از آن برای تخمین تابع توزیع هر حالت مدل مخفی مارکوف استفاده کنند [۸]، [۲۰] و [۲۱].

مشخص کردن حالات و تقطیع سری زمانی نیازمند روش‌هایی چون کوانتیزاسیون برداری و خوشبندی است که به این منظور از شبکه‌های بدون راهنمای استفاده می‌شود [۲۲].

ترکیب دینامیک چند طبقه‌بند مدل مخفی مارکوف در شناسایی الگو با شبکه عصبی<sup>۹</sup> MLP منجر به افزایش کارآیی سیستم شناسایی می‌شود.



شکل ۳: استفاده از HMM برای تقطیع سیگنال خروجی طبقه‌بند TDNN با سلول‌های LSTM.



شکل ۴: استفاده از شبکه عصبی به عنوان فشرده‌ساز تصویر به یک بردar ویژگی کوچکتر و استفاده از HMM برای طبقه‌بندی تصویر چهره.

و تعداد کم داده‌های یادگیری و فراگیرنودن آنها اشاره کرد. با وجود نویزی‌بودن داده‌ها و کافی‌بودن آنها، خوشبندی داده‌ها و پیداکردن آمارگان درست از آنها دچار مشکل می‌شود [۲]. همچنین به دلیل کافی‌بودن داده‌های آموزش، مدل فراگیری تولید نمی‌شود، به این منظور از تخمین‌گر یا هموارساز روی داده‌های آموزش استفاده می‌شود [۳] و [۴]. یکی دیگر از راه حل‌ها برای افزایش کارآیی طبقه‌بند، تلفیق آنها با یکدیگر است [۵] تا [۷].

Rosshای تلفیق شبکه عصبی و مدل مخفی مارکوف روش‌های مختلفی برای تلفیق مدل مخفی مارکوف با شبکه عصبی ارائه شده است که می‌توان آنها را از دیدگاه‌های گوناگون دسته‌بندی کرد:

- استفاده از قابلیت‌های شبکه‌های عصبی در افزایش کارآیی مدل‌های مخفی مارکوف [۸] تا [۱۲].

- شکل‌دهی ساختار مدل مخفی مارکوف با الهام از شبکه‌های عصبی [۱۳] و [۱۴].

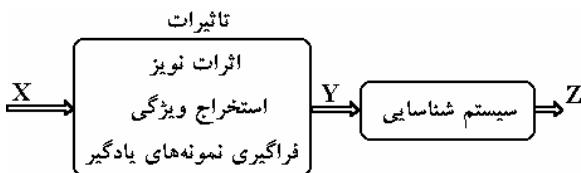
- ترکیب طبقه‌بندهای شبکه عصبی و مدل مخفی مارکوف [۸]، [۱۱]، [۱۲] و [۱۴].

در سال‌های اخیر نیز تلفیق این دو طبقه‌بند مورد توجه محققین بوده است. در [۱۵]، خروجی یک شبکه عصبی<sup>۱۰</sup> TDNN که از سلول‌های LSTM استفاده می‌کند به HMM داده می‌شود تا در اتاق ضبط ویدئویی برای شناسایی حالات گوینده به کار رود. شبکه عصبی TDNN معمولی قادر به یادآوری اطلاعات خلیل دور نیست یا به عبارتی دارای حافظه کوتاه‌مدت است که برای رفع این مشکل از سلول‌هایی با نام LSTM استفاده شده است. برای تقطیع فریم‌ها برای تشخیص شروع و انتهای هر رویداد نیاز به مدل مخفی مارکوف است که از یک HMM روسی خروجی شبکه عصبی فوق استفاده شده است (شکل ۳).

در [۱۶] از مدل مخفی مارکوف با توانایی مدل کردن دینامیک اطلاعات و از یک شبکه عصبی فازی با توانایی استنتاج فازی برای تشخیص ژست حرکات دست انسان استفاده شده است. به دلیل اینکه شبکه عصبی فازی قابلیت یادگیری داده‌های زمانی را ندارد و HMM نیز دارای قابلیت استنتاج فازی نیست، ترکیب این دو طبقه‌بند دارای نتایج بهتری نسبت به هر کدام می‌باشد. در [۱۷] از شبکه عصبی برای تبدیل تصویر به یک بردar ویژگی کوچکتر استفاده می‌شود (شکل ۴). پس از یادگیری شبکه عصبی برای شناسایی تصاویر چهره، هر تصویر چهره به یک بردar بسیار کوچکتر از ورودی کاهش می‌باید و این خروجی به

3. Segmental Neural Network
4. Natural Language Processing
5. Time Delay Neural Network
6. Hidden Markov Model
7. Classifier Fusion
8. Mean Square Error
9. Maximum Likelihood Estimation
10. Multi-Layer Perceptron

1. Time Delay Neural Network
2. Long Short-Term Memory



شکل ۸: اثرات مختلف باعث تغییر سیگنال اصلی X قبل از اعمال به سیستم شناسایی می‌شوند.

از آن به عنوان یک آستانه برای تشخیص وضعیت غیر عادی استفاده می‌شود.

در کار قبلی انجام شده توسط مؤلف [۲۸]، رفتار عادی رانندگان با استفاده از مدل مخفی مارکوف و یک پایگاه داده مکانی-زمانی مدل شده است. در این مقاله نیز از مدل مخفی مارکوف برای تعیین رفتار استفاده می‌شود ولی رفتار یک طبقه‌بند با یک کلیشه مناسب مبتنی بر مدل مخفی مارکوف مدل می‌شود که باعث افزایش نرخ شناسایی طبقه‌بند می‌شود. ایجاد کلیشه تصمیم<sup>۴</sup> با مدل مخفی مارکوف به نحوی که رفتار طبقه‌بند لحاظ شود نوآوری دیگر این مقاله است. این کلیشه با ذخیره کردن رفتار طبقه‌بند در پاسخ به نمونه‌های یادگیر باعث افزایش کارآیی تصمیم‌گیری نهایی می‌شود.

فرمول‌بندی روش پیشنهادی در بخش ۲ ارائه می‌شود. بخش ۳ به اعمال این روش در شناسایی ارقام دست‌نویس فارسی اختصاص دارد و بخش ۴ شامل نتیجه‌گیری است.

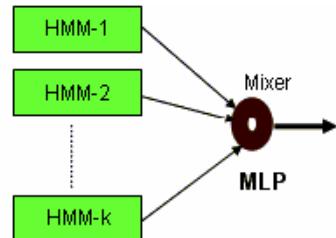
## ۲- فرمول‌بندی روش پیشنهادی

شبکه عصبی پس‌انتشار خطای یک روش کارا در شناسایی الگو است. در این روش استقرایی، چند نکته باید توجه شود. جامع‌بودن داده‌ها یکی از نکات است، یعنی در بحث شناسایی الگو، انواع متنوع الگو در یادگیری استفاده شوند. نکته دیگر وجود نویز با داده‌ها است. دو نوع نویز سنجش و فرآیند تبدیل در مبحث شناسایی الگو می‌توان نام برد.

نویز سنجش در هنگام اخذ الگو برای اعمال به سیستم شناسایی با الگو ترکیب می‌شود. به عنوان مثال در گرفتن تصویر با اسکنر، همواره نویزی که عموماً گوسی است به تصویر اضافه می‌شود که منشأ آن سیستم الکترونیکی و سنسورهای اخذ تصویر است. در دریافت تصاویر از دوربین‌های ویدئویی نیز این موضوع دیده می‌شود. به طوری که فریم‌های دریافتی از دوربین از یک صحنه ثابت با هم متفاوتند که منشأ آن نیز نویز ناشی از سیستم اپتیکی و الکترونیکی دوربین است.

نویز فرآیند تبدیل، ناشی از تبدیلاتی است که روی سیگنال دریافتی قبل از اعمال به سیستم شناسایی انجام می‌شود. مثلاً برای شناسایی تصویر ارقام و کلمات در سیستم‌های OCR<sup>۵</sup>، معمولاً از تصاویر دوستطحی استفاده می‌شود که برای به دست آوردن آنها از تصاویر زنگی یا سطوح خاکستری نیاز به عمل دوستطحی کردن<sup>۶</sup> است که نوعی تبدیل است.

مشکل دیگر در شناسایی الگو نداشتن اطلاعات کافی در استخراج ویژگی‌های مناسب برای سیستم شناسایی (شبکه عصبی) می‌باشد. بنابراین این مشکلات سبب کاهش کارآیی سیستم شناسایی می‌شود. همان‌طور که در شکل ۸ دیده می‌شود این مشکلات سبب می‌شوند بجای اعمال ورودی X به سیستم شناسایی بردار Y به آن اعمال شود.



شکل ۷: استفاده از MLP به عنوان تلفیق‌گر طبقه‌بندهای مارکوفی.

در [۲۳] علاوه بر تعیین نتیجه طبقه‌بندهای مدل مخفی مارکوف، پارامترهای آنها به طور دینامیک با استفاده از یک فیدبک از MLP به دست می‌آید. یک نوع دیگر استفاده از MLP با HMM استفاده از آن به جای عملگر ماکریم در تعیین نتیجه نهایی و تشخیص الگو در خروجی مدل‌های مخفی مارکوف است (شکل ۷). به عبارت بهتر، عموماً تعلق بیشتر یک سری زمانی به یکی از مدل‌های HMM برای شناسایی الگو استفاده می‌شود. جایگزینی این روش با یک MLP نتایج بهتری به دست می‌دهد [۲۴].

**ب- دیدگاه مدل‌کردن رفتار طبقه‌بند**  
همان‌طور که ملاحظه شد در انواع ترکیب‌های طبقه‌بندهای HMM<sup>۱</sup> NN<sup>۲</sup> از فواید آنها برای پوشش ضعف هر کدام استفاده شده است. ولی در هیچ‌کدام از مقالات فوق الذکر و موارد مشابه دیگر به نحوه عملکرد و پاسخ یک طبقه‌بند NN یا رفتار آن، با استفاده از HMM اشاره نشده است. که در این مقاله برای اولین بار به این کار پرداخته می‌شود.

مدل HMM توانایی مدل‌کردن رفتار را دارد، چون رفتار یک فرآیند زمانی و غیرایستان است و مدل مارکوف با یادگیری بیزین<sup>۳</sup> این قابلیت را ایجاد می‌کند، بنابراین شاهد کاربرد وسیع مدل مخفی مارکوف در این زمینه‌ها هستیم. در [۲۵] چگونگی نمایش مهارت‌های انسان با یک مدل پارامتری HMM بررسی شده است که شامل بخش‌های زیر است:

- انتخاب یک ساختار مناسب برای HMM برای مدل‌کردن مهارت مورد نظر.

- جمع‌آوری داده‌های یادگیری مربوط به نوع مهارتی که باید یاد گرفته شود.

- یادگیری پارامترهای مدل با استخراج مناسب ویژگی‌هایی از مهارت. همچنین در [۲۶] تعامل در رفتار بین انسان‌ها مدل شده است. در این کار از تصاویر ویدئویی اجزای بدن ریدیابی شده و سپس با توجه به مسیر حرکت این اجزا توسط یک مدل مخفی مارکوف تعامل بین این اجزای بدن، مدل می‌شود. رشته‌ای از موقعیت‌های کنترلی که روی کانتور تصویر انسان تعیین می‌شود، به عنوان ورودی به مدل استفاده می‌شود.

- از مدل مخفی مارکوف برای تعیین رفتار عادی در صحنه ترافیک نیز استفاده می‌شود [۲۷]. تعیین رفتار عادی در تحلیل صحنه ترافیک دارای بخش‌های زیر است:

- استخراج ویژگی: از ویژگی شار نوری، ویژگی حرکت در صحنه به دست می‌آید.

- سیستم شناسایی: یک مدل مخفی مارکوف برای شناسایی و مدل‌کردن وضعیت عادی استفاده شده است.

- معیار تعلق به وضعیت عادی: با توجه به نمونه‌های یادگیر حاصل درست‌نمایی<sup>۷</sup> به مدل مخفی مارکوف به دست می‌آید و

4. Decision Template

5. Optical Character Recognition

6. Binarization

1. Neural Network

2. Bayesian Learning

3. Likelihood

که  $f_Z(Z)$  فاکتور نرمالیزه‌کننده و  $P_\lambda(\lambda)$  احتمال پیشین مدل  $\lambda$  است که به نوع الگو بستگی دارد و در کاربردهای مختلف با استفاده از نمونه‌های یادگیر تعیین می‌شود، البته در بسیاری از کاربردها برای همه کلاس‌ها با اثر یکسان در نظر گرفته می‌شود.

سرانجام باید  $\lambda$  به نحوی محاسبه شود کهتابع توزیع  $f_{Z|\lambda}(Z|\lambda)$  ماکریم شود که برابر است با

$$f_{Z|\lambda}(Z|\lambda) = \sum_s f_{Z|s,\lambda}(Z|s,\lambda) P_{Z|\lambda}(Z|\lambda) \quad (2)$$

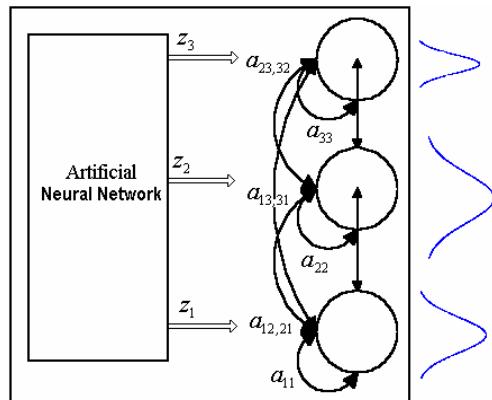
که  $f_{Z|s,\lambda}(Z|s,\lambda)$ تابع توزیع مشاهده  $Z$  روی رشته حالت  $s$  از مدل  $\lambda$  است. یک روش جستجوی پارامترهای بهینه مدل  $\lambda$  برای ماکریم کردن  $f_{Z|\lambda}(Z|\lambda)$  روش بام-ولش<sup>۵</sup> است (توضیحات بیشتر محاسبه  $f_{Z|\lambda}(Z|\lambda)$  با روش بام-ولش در [۲۹] آمده است).

مدل به دست آمده  $f_{Z|\lambda}(Z|\lambda)$  به عنوان یک کلیشه تصمیم استفاده می‌شود. یک نکته قابل توجه برای به دست آوردن کلیشه تصمیم یا مدل رفتار نمونه‌های خروجی شبکه عصبی، داده‌های یادگیری به کار رفته است. اگر از همان داده‌هایی که شبکه عصبی آموزش دیده استفاده شود پارامترهای مناسبی برای  $\lambda$  به دست نمی‌آید یعنی توابع توزیع  $f_{Z|s,\lambda}(Z|s,\lambda)$  با فرض گوسی‌بودن با یک انحراف معیار بسیار کوچک‌تر از مقدار واقعی نتیجه می‌شود که به دلیل تعداد کم نمونه‌های یادگیر نیز می‌باشد. بنابراین برای حل این مشکل از یک دسته داده یادگیر ثانویه که شبکه عصبی با آن آموزش ندیده، استفاده می‌شود و با آنها پارامترهای  $\lambda$  محاسبه می‌شود.

بیان دیگر ایده پیشنهادی آنست که می‌توان هر نمونی از شبکه را انتخاب کرد و ارتباط بین آنها را مدل کرد. فرض کنید اولین الگوی یادگیری ثانویه به شبکه داده شود و نمونه‌های مورد نظر پاسخ بدھند (با توجه به وزن‌های آموزش دیده شبکه عصبی). ارتباط بین آنها با یک مدل مارکوف تمام‌اتصال باید مدل شود که قادر به بیان ارتباط مناسبی بین پاسخ هر نمون است. بنابراین اگر تمامی الگوهای شبکه عصبی داده شوند، نمونه‌های انتخابی پاسخ‌هایی خواهند داد و ارتباط بین آنها به صورت مناسبی با مدل مارکوف قابل مدل کردن است. نتیجه کار آنست که نحوه عملکرد نمونه‌ها روی نمونه‌های یادگیری به عنوان یک دانش اضافی در مرحله آزمون قابل استفاده خواهد بود که در مدل مارکوف این دانش ذخیره شده است.

## ۲-۲ استفاده از کلیشه تصمیم مبتنی بر مدل مخفی مارکوف در تصمیم‌گیری شبکه عصبی

حال باید از کلیشه تصمیم به دست آمده ( $L(z) = f_{Z|\lambda}(Z|\lambda)$ ) که روی نمونه‌های یادگیر ثانویه شکل گرفته است در افزایش کارآیی شبکه عصبی در پاسخ به نمونه‌های آزمون استفاده کرد. اگر فرآیند تصمیم روی خروجی شبکه عصبی با  $D(Z)$  نشان داده شود از کلیشه تصمیم برای افزایش کارآیی آن استفاده می‌شود. در مسئله طبقه‌بندی چند کلاسی چندین کلیشه تصمیم به دست می‌آید، یعنی برای نمونه‌های یادگیری چندین کلاس یک کلیشه تصمیم حاصل می‌شود. بنابراین ابتدا پس از ورود هر نمونه آزمون خروجی شبکه حاصل می‌شود ( $Z$ )، سپس  $Z$  به مجموعه کلیشه‌های تصمیم داده می‌شود و تعلق بیشتر به هر کلیشه  $(\arg_k \max)$  طبق رابطه زیر نوع کلاس آن را تعیین می‌کند



شکل ۹: ساختار روش پیشنهادی در تعیین مدل آماری نمونه‌های خروجی شبکه عصبی.

تأثیرات نشان داده شده در شکل فوق ممکن است بسته به الگو تغییر کند، یعنی یک فرآیند غیرایستان باشد، همچنین یک مدل پیچیده در خروجی تولید کند ( $Z$ ) که به سادگی با آن نتوان به نوع الگو پی برد. بنابراین مدل مناسبی برای نتیجه‌گیری درست از سیستم شناسایی لازم است تا سیستم شناسایی به خوبی توصیف شود. این توصیف یا پیش‌گفته است. بنابراین هدف آنست که مدلی برای تعیین رفتار سیستم شناسایی به دست آید.

دو نوع مدل معین و آماری مطرح هستند که مدل مخفی مارکوف برای توصیف رفتار سیستم مورد مطالعه در این مقاله، مناسب است. مسائل گفته شده در فوق، شباهت زیادی به موارد موجود در سیگنال‌های چون صوت و ویدئو دارد که مدل مخفی مارکوف (HMM) در حل این مسائل موفق بوده است. این موضوع از ۱۹۶۰ تاکنون به اثبات رسیده است. بنابراین در این مقاله از HMM به صورت زیر در تعیین رفتار یک طبقه‌بند شبکه عصبی پس انتشار خطأ و بهبود کارآیی آن استفاده می‌شود.

## ۲-۳ ارائه یک مدل آماری در تعیین رفتار شبکه عصبی

شبکه عصبی پس انتشار خطأ پس از آموزش، به ورودی‌ها پاسخی می‌دهد که ناشی از نوع ویژگی، نویز ترکیبی با الگو، تنواع داده‌های یادگیری و تبدیلات انجام‌شده روی الگوها قبل از اعمال به شبکه است. در این مقاله رفتار نمونه‌های خروجی یک شبکه عصبی پس انتشار خطأ، مدل می‌شود.

در شکل ۹ روش پیشنهادی به تصویر در آمده است که شامل رابطه احتمالی تمام‌اتصال، بین نمونه‌های خروجی شبکه عصبی، همچنین تابع توزیع هر نمون خروجی می‌باشد. هدف پیدا کردن یک ساختار بیزین<sup>۳</sup> با احتمالات گذر مارکوفی و درست‌نمایی مشاهدات هر نمون برای نمونه‌های خروجی شبکه عصبی آموزش دیده است. هر نمون به عنوان یک حالت<sup>۴</sup> از مدل مخفی مارکوف در نظر گرفته می‌شود و مدل  $\lambda$  با رشته مشاهدات  $Z$  که پاسخ شبکه عصبی به ازای هر نمونه ورودی است ایجاد می‌شود. یک تابع توزیع روی مجموعه رشته حالات با استفاده از قانون بیز به صورت زیر ایجاد می‌شود

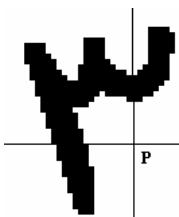
$$P_{\lambda|Z}(\lambda|Z) = \frac{1}{f_Z(Z)} f_{Z|\lambda}(Z|\lambda) P_\lambda(\lambda) \quad (1)$$

1. Hidden Markov Model

2. Full Connected

3. Bayesian Structure

4. State



شکل ۱۱: نحوه محاسبه ویژگی مکان مشخصه برای نقطه P.

در صد از نمونه‌های یادگیری دیده شده، نرون اول با میانگین ۰/۵۱ و نرون دوم با میانگین ۰/۴۷ ظاهر می‌شوند. ولی در مورد الگوی دوم این احتمال گذر لزوماً با الگوی اول برابر نیست و این وجه تمایزی بین دو الگو است.

### ۱-۳ شناسایی ارقام دستنویس

باشناسی حروف و ارقام و کلمات دستنویس شاخه‌ای از باشناسی الگو است که تحقیقات گسترده‌ای را به خود اختصاص داده و هنوز در حال تحول است. تحقیقات در این زمینه از حدود ۴۰ سال پیش آغاز شده و هم‌اکنون کاربردهای مختلفی از جمله بازناسایی آدرس‌های پستی و خواندن اتوماتیک چک‌های بانکی پیدا کرده است. روش‌های مختلفی برای بازناسایی استفاده شده است که از جمله آنها می‌توان به روش‌های آماری، ساختاری و روش‌های شبکه عصبی و فازی اشاره کرد. در زمینه بازناسایی حروف فارسی و عربی نیز کارهای زیادی انجام شده است [۳۰] [۳۹].

هدف این بخش از مقاله، آزمون روش پیشنهادی روی یک مجموعه داده غنی از ارقام دستنویس فارسی شامل ۲۱۱۰ نمونه برای ده رقم ۰ تا ۹ می‌باشد. به دلیل حجم زیاد داده‌ها، آموزش شبکه عصبی به سختی انجام می‌گیرد که برای حل این مشکل از هر نمونه رقم ۳۰۰ تا به طور انفاقی انتخاب شد که ۱۳۰ تا برای یادگیری شبکه عصبی و ۶۰ نمونه گروه یادگیری ثانویه برای ایجاد کلیشه‌های مدل مارکوفی و ۱۱۰ تای دیگر برای آزمون روش پیشنهادی استفاده می‌شوند. تعدادی از ارقام دستنویس در شکل ۱۰ نشان داده شده‌اند.

در ادامه به ویژگی استخراج شده از تصویر ارقام دستنویس اشاره می‌کنیم.

### ۱-۳-۱ ویژگی مکان مشخصه

ویژگی مکان مشخصه برای هر پیکسل سفید تصویر و معمولاً در راستاهای عمودی و افقی تعریف می‌شود. همان‌طور که در شکل ۱۱ آمده است، بردار مکان مشخصه برای هر پیکسل سفید در راستاهای عمودی و افقی از تعداد تقاطع با بدنه سیاه نویسه، به دست می‌آید. اگر تعداد قطع بدنه را به ۲ محدود کنیم، یک عدد چهار رقمی در مبنای ۳ برای تعداد تقاطع در جهات چهارگانه راست، بالا، چپ و پایین به صورت زیر در مبنای ۱۰ حاصل می‌شود

$$\begin{aligned} CuttingNumber = & RightNumOfCut \times 3^0 \\ & + TopNumOfCut \times 3^1 \\ & + LeftNumOfCut \times 3^2 \\ & + DownNumOfCut \times 3^3 \end{aligned} \quad (5)$$

مثالاً برای شکل ۱۱ ویژگی مکان مشخصه برای نقطه P برابر است با

$$\begin{aligned} CuttingNumber = & 0 \times 3^0 + 1 \times 3^1 + 0 \times 3^2 \\ = & (0\ 1\ 0)_3 = 12 \end{aligned}$$

Digits	۰	۱	۲	۳	۴	۵	۶	۷	۸	۹
۰	۱	۲	۳	۴	۵	۶	۷	۸	۹	۰
۱	۱	۲	۳	۴	۵	۶	۷	۸	۹	۱
۲	۱	۲	۳	۴	۵	۶	۷	۸	۹	۲
۳	۱	۲	۳	۴	۵	۶	۷	۸	۹	۳
۴	۱	۲	۳	۴	۵	۶	۷	۸	۹	۴
۵	۱	۲	۳	۴	۵	۶	۷	۸	۹	۵
۶	۱	۲	۳	۴	۵	۶	۷	۸	۹	۶
۷	۱	۲	۳	۴	۵	۶	۷	۸	۹	۷
۸	۱	۲	۳	۴	۵	۶	۷	۸	۹	۸
۹	۱	۲	۳	۴	۵	۶	۷	۸	۹	۹

شکل ۱۰: نمونه‌ای از تصاویر ارقام دستنویس فارسی.

$$Class = \arg_k \max(f_{Z|\lambda}(Z|\lambda_k)) , \quad k = 1, 2, \dots, N \quad (3)$$

که در عبارت فوق  $N$  تعداد کلاس‌ها است. نتیجه نهایی تصمیم ترکیب  $L(Z)$  حاصل از کلیشه‌های تصمیم و  $D(Z)$  حاصل از نتیجه شبکه عصبی است. در این مقاله نوع این ترکیب بررسی نمی‌شود و با رابطه زیر این ترکیب به سادگی انجام می‌شود. جالب آنست که در آزمایش‌های انجام‌شده روش پیشنهادی با همین ترکیب ساده ضرب، بهبود قبل توجهی در نتایج به دست می‌دهد که نشان‌دهنده کارآیی کلیشه پیشنهادی در ایجاد مدل رفتار طبقه‌بند است

$$C(Z) = L(Z) \times D(Z) = Z f_{Z|\lambda}(Z|\lambda_k) \quad (4)$$

سرانجام تصمیم نهایی به صورت زیر روی  $C(Z)$  صورت می‌گیرد

$$Class = \arg_k \max(C(Z)) , \quad k = 1, 2, \dots, N \quad (5)$$

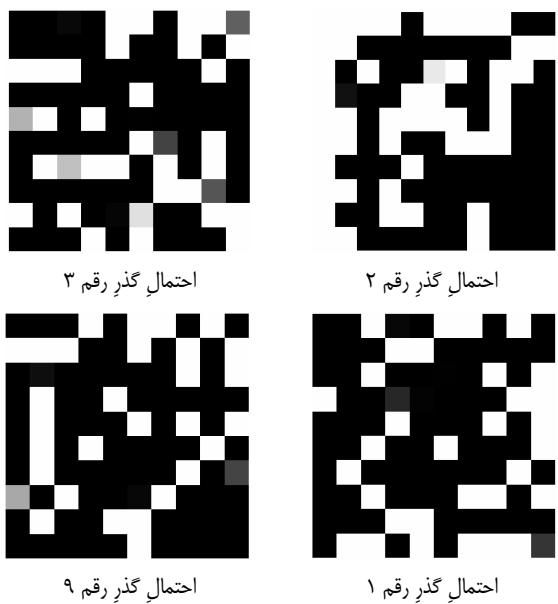
که  $\arg_k \max$  یعنی پیدا کردن پاسخی با حداقل مقدار روی  $N$  کلیشه مارکوفی به دست آمده و نتیجه شبکه عصبی. قابل توجه است که در این مقاله توابع توزیع فوق‌الذکر از نوع گوسی در نظر گرفته شده‌اند و مدل مارکوف به کار رفته گستته است.

در بخش بعدی مدل رفتار طبقه‌بندها در سه کاربرد مختلف با استفاده از کلیشه تصمیم مبتنی بر مدل مخفی مارکوف آزمون می‌شود.

### ۳- بررسی روش پیشنهادی با آزمون آن روی چند کاربرد

این بخش به بررسی کارآیی روش پیشنهادی اختصاص دارد. کاربردهای شناسایی ارقام دستنویس فارسی، شناسایی نوع خودرو از روی تصویر دریافتی و تشخیص ترافیک عادی در شبکه‌های اطلاع‌رسانی برای آزمون کارآیی روش پیشنهادی بررسی می‌شوند. قبل از آزمون روش، مثالی برای روشن‌ترشدن روش پیشنهادی ارائه می‌شود.

مثال: اگر به دلایلی چون نویز و نوع ویژگی و شباهت بین الگوها (در اینجا سه الگو برای شناسایی مدنظر است)، شبکه عصبی در تصمیم‌گیری بین الگوها برای الگوی اول، پاسخ‌هایی با میانگین ۰/۰۲، ۰/۴۷، ۰/۵۱ بددهد میانگین نرون اول و دوم بسیار نزدیک است و به کمک کلیشه تصمیم مبتنی بر میانگین و انحراف معیار خطای طبقه‌بندی زیاد می‌شود. ولی اگر ارتباط بین این سه نرون مدنظر قرار بگیرد الگوی شماره ۱ دارای رفتار منحصر به فرد خود است. مثلاً احتمال گذر از حالت اول با میانگین ۰/۵۱ به حالت دوم با میانگین ۰/۴۷ برابر با ۰/۷۸ باشد یعنی در



شکل ۱۲: شباهت بین دو رقم ۲ با ۳ در فضای مکان مشخصه و شباهت ارقام ۹ با ۱.

حال برای هر پیکسل سفید یک عدد در مبنای ۱۰ به دست می‌آید که بین صفر تا ۸۰ است. سرانجام، فراوانی هر رقم صفر تا ۸۰ یک بردار عنصری تشکیل می‌دهد که با نرمالیزه کردن عناصر این بردار به تعداد نقاط سفید، بردار مکان مشخصه به دست می‌آید.

### ۳-۱-۳ شناسایی تصویر ارقام دستنویس فارسی با سیستم پیشنهادی

برای مقایسه بهتر روش پیشنهادی با نتایج به دست آمده از شبکه عصبی، شبکه عصبی به طور جداگانه با نمونه‌های یادگیری اولیه و ثانویه آموزش داده می‌شود و نتایج آن با سیستم پیشنهادی مقایسه می‌گردد.

برای هر رقم یک کلیشه طبق (۲) به دست می‌آید. ده کلیشه مبتنی بر مدل مخفی مارکوف در تصمیم‌گیری نهایی استفاده می‌شوند. نرخ شناسایی تصویر ارقام با استفاده از شبکه عصبی ۴٪/۸۹,۳ لایه، به دست می‌آید که با استفاده از نتیجه کلیشه‌های به دست آمده از (۲) و تلقیق آنها با خروجی شبکه عصبی ((۴)) به ۹۳,۸۵٪ افزایش می‌یابد که با توجه به تعداد قابل توجه نمونه‌های آزمون ۱۱۰۰ نمونه، نتیجه قابل ملاحظه‌ای است. افزایش ۴,۵۵ درصدی روی تعداد زیاد نمونه‌های آزمون سیار حائز اهمیت است و نشان‌دهنده کارآیی کلیشه مارکوفی است.

اما سؤال پیش می‌آید که چرا این کلیشه مارکوفی باعث افزایش کارآیی شده است و در چه مواردی، احتمالات بین حالات در کلیشه مارکوفی به شبکه عصبی کمک می‌کند؟

برای پاسخ به این سؤال به ماتریس کارآیی شبکه عصبی مراجعه می‌کنیم و ملاحظه می‌شود که در مواردی همچون شکل ۱۲ خط رخ داده است.

از طرفی به احتمالات گذر کلیشه مارکوفی ارقام (۲ و ۳) و (۱ و ۹) نیز نگاهی می‌اندازیم (شکل ۱۳). ملاحظه می‌شود که احتمال گذر رقم ۱ و ۹ و ۲ و ۳ با وجود شباهت‌هایی، دارای تفاوت‌هایی هستند که باعث بهبود کارآیی سیستم پیشنهادی می‌شود.

### ۳-۲-۳ شناسایی رفتار عادی شبکه اطلاع‌رسانی

در این بخش، ترافیک عادی شبکه با استفاده از یک شبکه عصبی پس انتشار خط رخ مدل می‌شود به طوری که می‌توان از آن در تشخیص نفوذ استفاده کرد. ملاحظه می‌شود با افزودن کلیشه تصمیم مبتنی بر مدل مخفی مارکوف به شبکه عصبی که به تشخیص پروتکل‌های شبکه می‌پردازد، افزایش قابل توجهی در نرخ شناسایی به دست می‌آید.

### ۳-۲-۱ جایگاه شناسایی رفتار عادی در تشخیص نفوذ

نفوذ<sup>۱</sup>، مجموعه اقدامات غیرقانونی است که صحت و دسترسی به یک منبع را به خطر می‌اندازد. به منظور مقابله با نفوذ به سیستم‌ها و شبکه‌های کامپیوتری، روش‌های گوناگونی تحت عنوان روش‌های تشخیص نفوذ<sup>۲</sup> ارائه شده است. هدف از تشخیص نفوذ جلوگیری از استفاده غیرمجاز، سوء استفاده و آسیب‌رساندن به سیستم‌ها و شبکه‌های

3. Misuse Detection

4. Anomaly Detection

5. Agent

6. Log Files

1. Intrusion

2. Intrusion Detection

برای ایجاد نماهای رفتار عادی میزبان‌های شبکه از مدل میزبان استفاده می‌شود. از هر دو دسته ویژگی‌های ذاتی سرویس و ویژگی‌های آماری-زمانی برای تعیین رفتار عادی استفاده می‌شود. یادآوری می‌گردد، مجموعه ویژگی‌های استخراج شده برای هر اتصال شبکه، یک نمونه را تشکیل می‌دهند. این نمونه‌ها به عنوان ورودی به سیستم شناسایی داده می‌شوند تا رفتار عادی مدل شوند.

### ۳-۴ سیستم شناسایی پیشنهادی رفتار عادی ترافیک شبکه

در این بخش از مقاله، از شبکه عصبی پس انتشار خطاب برای مدل کردن سرویس‌های smtp، http و auth استفاده می‌شود. سپس از سیستم پیشنهادی برای شناسایی رفتار عادی استفاده می‌شود و نتایج بدست آمده با نتایج حاصل از شناسایی با شبکه عصبی مقایسه می‌شود که برتری قابل توجهی، سیستم پیشنهادی نشان می‌دهد.

۱۰۱۶ نمونه برای مدل کردن این سرویس‌ها استفاده می‌شود که از این تعداد ۴۰۰۰ نمونه برای یادگیری شبکه عصبی و ۲۳۴۰ نمونه به عنوان دسته یادگیری ثانویه برای محاسبه پارامترهای مدل مخفی مارکوف هر کلاس و باقیمانده برای آزمون استفاده می‌شوند.

برای مقایسه بهتر روش پیشنهادی با نتایج به دست آمده از شبکه عصبی، شبکه عصبی به طور جداگانه با نمونه‌های یادگیری اولیه و ثانویه آموزش داده می‌شود و نتایج آن با سیستم پیشنهادی مقایسه می‌گردد. در نمونه‌های آزمون شبکه عصبی ۴ لایه موفق به شناسایی ۴ نوع سرویس پیشنهادی با کلیشه آماری (۲) و تلفیق نتیجه کلیشه‌های تصمیم ((۳)) با (۴) نرخ شناسایی ۸۷٪ درصد به دست می‌آید. افزایش قابل توجه ۱۱٪ درصدی نشان‌دهنده کارآئی کلیشه تصمیم مبتنی بر مدل مخفی مارکوف است. بنابراین تعیین رفتار یک طبقه‌بند در مرحله یادگیری نتیجه خوبی در افزایش کارآئی پاسخ طبقه‌بند در مرحله آزمون نشان می‌دهد.

### ۳-۵ شناسایی وسائل نقلیه در صحنه ترافیک

در این بخش از مقاله سیستم پیشنهادی در شناسایی ۵۴۰ تصویر اخذشده از دو دیدگاه جلو و عقب ماشین‌ها آزمون می‌شود. برای شناسایی از ویژگی‌های ماشین ویژه استفاده می‌شود. این کار برای هر دو دیدگاه جلو و عقب ماشین‌ها انجام می‌گردد.

سیستم‌های مراقبت بینایی در صحنه‌های ترافیک عموماً شامل الگوریتم‌های آشکارسازی، ردیابی و طبقه‌بندی [۴۸] تا [۵۱] است. از جمله وظایف سیستم‌های مراقبت، شناسایی خاطری در صحنه است که شامل تشخیص نوع ماشین و خواندن پلاک است. مجموعه تصاویر جمع‌آوری شده به نحوی است که مشابه تصاویر سیستم‌های مراقبت است. این سیستم‌ها پس از تشخیص خاطری که عموماً بر اساس سرعت غیر مجاز یا عبور از محل‌های منوعه است با استفاده از دوربین‌های چند عکس، از فاصله نزدیک گرفته می‌شود سپس توسط کاربر یا اتوماتیک پلاک خوانده می‌شود. در سیاری از موارد مخدوش‌بودن یا خوانابودن شماره پلاک، خواندن پلاک را دچار مشکل می‌کند که در این موقع تشخیص نوع خودرو به عنوان اطلاعات اضافی در تعیین خاطری مؤثر است. که این بخش از مقاله علاوه بر اینکه این هدف را دنبال می‌کند، برای آزمون روش پیشنهادی نیز به دلیل پایگاه تصویر قابل توجه، مناسب به نظر می‌رسد.

میزبان از رکوردهای ردیابی سیستم عامل، رخدادهای سیستمی، و یا اطلاعات مربوط به برنامه‌های کاربردی (از قبیل فایل‌های رخدادهای سرویس‌گرهای وب) به عنوان منابع اطلاعاتی استفاده می‌شود. NIDES [۴۰] و ComputerWatch [۴۲] دو نمونه از سیستم‌های تشخیص نفوذ مبتنی بر میزبان هستند.

در سیستم‌های تشخیص نفوذ مبتنی بر شبکه، از ترافیک شبکه به عنوان منبع اصلی اطلاعات استفاده می‌شود. در این سیستم‌ها معمولاً کارت واسطه شبکه<sup>۱</sup> در وضعیت promiscuous قرار داده می‌شود، بدین ترتیب سیستم تشخیص نفوذ قادر است تا همه ترافیک شبکه که از سگمنت شبکه‌اش عبور می‌کند را ملاحظه کند. مزایای سیستم‌های تشخیص نفوذ مبتنی بر شبکه عبارتند از: هیچ سرباری به سرویس‌گرهای شبکه تحمیل نمی‌کنند، برای کاربران شبکه شفاف هستند، حملاتی مانند جلوگیری از سرویس را می‌توانند تشخیص دهند که سیستم‌های تشخیص نفوذ مبتنی بر میزبان به راحتی قادر به شناسایی آنها نمی‌باشند. NSM [۴۳] یک سیستم تشخیص نفوذ مبتنی بر شبکه است که در دانشگاه کالیفرنیا ساخته شده است.

در سیستم‌های تشخیص نفوذ مبتنی بر میزبان و شبکه، از هر دو منابع اطلاعاتی میزبان و منابع اطلاعاتی شبکه برای تشخیص نفوذ استفاده می‌شود. DIDS [۴۴] و EMERALD [۴۵] دو نمونه از سیستم‌های تشخیص نفوذ مبتنی بر میزبان و شبکه هستند.

### ۳-۶ استخراج ویژگی از ترافیک شبکه

به منظور ایجاد نماهای ترافیک عادی شبکه، اولین و مهم‌ترین اقدام، تعیین ویژگی‌های مهم موجود در بسته‌های ارسالی در شبکه است تا با تأکید بر آنها، بسته‌ها به نحو پالایش شده‌ای در نظر گرفته شوند. با نگاهی به اطلاعات موجود در بخش سرآیند<sup>۲</sup> بسته‌ها (و بدون در نظر گرفتن اطلاعات محتوایی موجود در آنها) می‌توان ویژگی‌های آدرس مبدأ، آدرس مقصد، پورت مبدأ، پورت مقصد، نوع بسته (داده یا کترنلی)، تعداد بایت‌های داده را از بسته‌های ارسالی در شبکه استخراج نمود. ویژگی‌های استخراج شده از هر بسته برای ایجاد نماهای ترافیک عادی شبکه کافی نیستند و نمی‌توان از آنها مستقیماً در روش‌های یادگیری استفاده کرد. بنابراین باید از روی کلیه بسته‌های ارسالی در شبکه، رکوردهای اتصال تشکیل شوند. هر رکورد اتصال حاوی اطلاعاتی از قبیل زمان شروع اتصال، طول مدت اتصال، تعداد بسته‌های ارسالی از هر طرف، تعداد بایت‌های داده ارسالی از هر طرف، وضعیت خاتمه‌یافتن اتصال، و سرویس درخواستی اتصال است.

با استفاده از اطلاعات به دست آمده از اتصالات شبکه، می‌توان دسته‌های متفاوتی از ویژگی‌ها را از روی این اطلاعات استخراج نمود. این ویژگی‌ها برای ایجاد نماهای رفتار عادی سرویس‌ها و میزبان‌های شبکه استفاده می‌شود. این ویژگی‌ها عبارتند از: ویژگی‌های ذاتی سرویس و ویژگی‌های آماری-زمانی.

برای ایجاد نماهای ترافیک عادی شبکه و آزمون روش پیشنهادی، از مجموعه داده‌های جمع‌آوری شده توسط مرکز IRIS [۴۶] استفاده شد. این داده‌ها مربوط به ترافیک عادی شبکه مذبور بودند و با استفاده از ابزار tcpcdump [۴۷] جمع‌آوری شدند. از این داده‌ها برای ایجاد نماهای رفتار عادی سرویس‌ها و میزبان‌های شبکه فوق استفاده می‌شود. بدین منظور، برای ایجاد نماهای رفتار عادی سرویس‌های شبکه از مدل ترافیک و

1. Network Interface Card

2. Header



شکل ۱۵: تبدیل ویژگی در حوزه ویژگی برای ۱۵ نمونه یادگیری و ۳ انتخاب با PCA از ۹۰ نمونه یادگیری دید جلو (تصویر سمت راست) و دید عقب ماشین‌ها (تصویر سمت چپ).

ورودی شبکه عصبی، تصویر خودرو در فضای ویژه می‌باشد.  
برای روشن‌شدن روش، ماتریس پروجکشن ماشین ویژه را بررسی بیشتری می‌کنیم.

#### ساخت ماتریس پروجکشن ماشین ویژه

یک مجموعه یادگیری شامل ۹۰ تصویر ۶ گروه و سایل نقلیه رنو، پژو GLX ۴۰۵ سی‌ال، ماتیز، پراید، پژو ۲۰۶ می‌باشد. این نمونه‌ها در ایجاد فضای ویژه استفاده می‌شوند و با انتخاب بردارهای ویژه متناظر با مقادیر ویژه بزرگ‌تر اطلاعات مناسب‌تر انتخاب می‌شوند که در طبقه‌بندی بهتر مؤثرند همچنین طبقه‌بند با پارامترهای کمتری نیاز است. در شکل ۱۵ نیز ۳ ماشین ویژه ملاحظه می‌شود. البته برای دید جلو و عقب هر کدام جداگانه ماشین‌های ویژه استخراج می‌شوند.

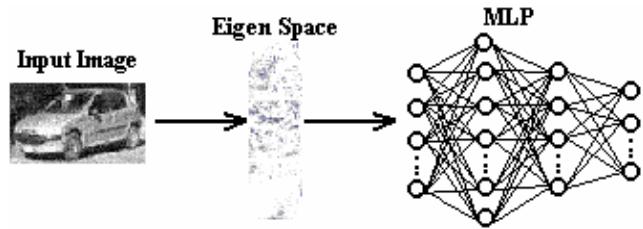
ماتریس پروجکشن  $P$  به دست آمده از ماشین‌های ویژه در انتقال تصاویر ورودی در یادگیری شبکه عصبی و آزمون به کار می‌رود.

#### آموزش شبکه عصبی

یک شبکه عصبی ۴ لایه در یادگیری ماشین‌های ویژه به کار می‌رود. کاهش تعداد ویژگی با PCA از ۹۰ به ۳ تغییر محسوسی در نرخ شناسایی دو شبکه عصبی به کار رفته برای دو دید از جلو و عقب ندارد. نرخ شناسایی روی ۹۰ نمونه آزمون %۹۰ برای دید از جلو و %۸۳/۳ برای دید از عقب ماشین‌ها به دست آمد. حال آنکه با استفاده از سیستم پیشنهادی یعنی تلفیق ۶ کلیشه مارکوفی برای دید از جلو با شبکه عصبی به روش پیش‌گفته منجر به افزایش قابل توجه ۳/۴ درصدی در نرخ شناسایی می‌شود و ایجاد ۶ کلیشه مارکوفی برای دید از عقب نرخ شناسایی را تا ۸۸/۵٪ افزایش می‌دهد که افزایش ۵/۲ درصدی نشانه کارآیی سیستم پیشنهادی است.

## ۴- نتیجه‌گیری

کاربرد وسیع مدل مخفی مارکوف در شناسایی سری‌های زمانی، آن را به عنوان ابزار توانمند در مدل‌کردن ارتباط بین اجزای اصلی یک الگوی پیچیده تبدیل کرده است. مطالعه رفتار طبقه‌بندها برای کاهش خطای در تصمیم‌گیری برای اولین بار با کمک مدل مخفی مارکوف مورد توجه این مقاله قرار گرفت. با ارائه مدل مناسب آماری برای رفتار یا پاسخ یک سیستم شناسایی، می‌توان عملکرد سیستم شناسایی را بهبود داد. بنابراین، یک کلیشه تصمیم جدید که با استفاده از مدل مخفی مارکوف ایجاد شد،



شکل ۱۴: سیستم شناسایی نوع خودرو.

در کاربرد شناسایی چهره روشنی برای نمایش چهره بر اساس PCA وجود دارد. ایده اصلی عبارت از تجزیه تصاویر صورت به تصاویر مشخصه به نام چهره‌های ویژه<sup>۳</sup> می‌باشد. این چهره‌های ویژه بردارهای عمود بر هم از زیر فضای خطی به نام Face Space می‌باشند. شناسایی با پروژکشن یک تصویر جدید به این فضا و مقایسه آن با تصاویر ذخیره شده در این فضا انجام می‌شود [۵۲] و [۵۳]. در شناسایی نوع خودرو نیز، مشابه روش شناسایی تصویرت در فضای ویژه، ماشین ویژه تعریف می‌شود. سپس ویژگی‌های کاهش‌یافته با PCA شناسایی می‌شوند.

#### ۳-۳-۳ ماشین ویژه

شناسایی در فضای ویژه دارای دو مرحله یادگیری و شناسایی است. در هر دو مرحله باید تصویر ورودی به فضای ویژه نگاشت گردد. ابتدا فضای ویژه را بررسی می‌کنیم.

#### ساخت فضای ویژه

در این مرحله تصویر هر ماشین دارای  $N$  پیکسل را با یک بردار  $\Gamma$  می‌توان نشان داد. برای  $M$  نمونه یادگیر  $\{ \Gamma_i | i = 1, \dots, M \}$  و متوسط این بردارها برابر است با:  $\Psi = 1/M \sum_{i=1}^M \Gamma_i$  اختلاف هر نمونه با مقدار متوسط نیز برابر است با:  $\Phi_i = \Gamma_i - \Psi, i = 1, \dots, M$ . از این  $M$  نمونه یادگیر از  $\Phi_i$  یک ماتریس به دست می‌آید که مقادیر ویژه و بردارهای ویژه کواریانس این ماتریس در ایجاد فضای ویژه استفاده می‌شوند.

$$A = [\Phi_1, \dots, \Phi_M] \quad (6)$$

$$C = AA^T \quad (7)$$

بردارهای ویژه ماتریس  $C$  برابر ( $v_i | i = 1, \dots, M$ ) می‌باشند. از این  $M$  بردار  $L$  تایی متناظر با  $L$  مقدار ویژه بزرگ‌تر را انتخاب می‌کنیم. ماتریس شامل بردارهای ویژه انتخاب شده  $B = \{v_i | i = 1, \dots, L\}$  است که هر بردار  $v_i$  به طول  $M$  می‌باشد و ابعاد ماتریس  $B$  است. ماتریس پروجکشن به فضای ویژه برابر است با

$$P = AB \quad (8)$$

حال هر تصویر ورودی با استفاده از ماتریس پروجکشن  $P$  به فضای ویژه انتقال می‌یابد. در (۹) تصویر ورودی  $I$  پس از حذف مقدار میانگین  $\Psi$  از آن در ماتریس پروجکشن ضرب می‌شود و به فضای ویژه منتقل می‌گردد

$$\Omega = P^T (I - \Psi) \quad (9)$$

هر نمونه در فضای ویژه برای یادگیری و آزمون استفاده می‌شود.

#### ۳-۳-۲ سیستم شناسایی ماشین

سیستم به کار رفته در شناسایی ماشین مطابق شکل ۱۴ است. با توجه به مطالب پیش‌گفته، از نمونه‌های یادگیری فضای ویژه ساخته می‌شود.

1. Principal Component Analysis
2. EigenFace

- in *Advances in Neural Information Processing Systems 2*, pp. 211-217, 1990.
- [15] S. Reiter, B. Schuller, and G. Rigoll, "A combined LSTM - RNN - HMM-approach for meeting event segmentation and recognition," in *IEEE Int. Conf. on Acoustics, Speech and Signal Processing, ICASSP 2006*, vol. 2, pp. 14-19, May 2006.
- [16] X. Wang and G. Dai, "A novel method to recognize complex dynamic gesture by combining HMM and FNN models," in *Proc. IEEE Symposium on Computational Intelligence in Image and Signal Processing, CIISP 2007*, pp. 13-18, Apr. 2007.
- [17] B. Vitoantonio, D. Domenico, C. Lucia, and M. Giuseppe, "Pseudo 2D hidden markov models for face recognition using neural network coefficients," in *Proc. IEEE Workshop on Automatic Identification Advanced Technologies*, pp. 107-111, Jun. 2007.
- [18] G. Zavaliagkos, Y. Zhao, R. Schwartz, and J. Makhoul, "A hybrid segmental neural net/hidden markov model system for continuous speech recognition," *IEEE Trans. on Speech and Audio Processing*, vol. 2, no. 1, pt. II, pp. 151-160, Jan. 1994.
- [19] C. Dugast, L. Devillers, and X. Aubert, "Combining TDNN and HMM in a hybrid system for improved continuous - speech recognition," *IEEE Trans. on Speech and Audio Processing*, vol. 2, no. 1, part II, pp. 217-223, Jan. 1994.
- [20] N. Morgan and H. Bourlard, "Continuous speech recognition using multilayer perceptrons with hidden markov models," in *Proc. IEEE Conf. Acoust. Speech, Signal Process.*, pp. 413-416, Albuquerque, NM, US, Apr. 1990.
- [21] Y. Bengio, R. D. Mori, G. Flammia, and R. Kompe, "Global optimization of a neural network - hidden markov model hybrid," *IEEE Trans. on Neural Network*, vol. 3, no. 2, pp. 252-259, Mar. 1992.
- [22] G. Rigoll, "Maximum mutual information neural networks for hybrid connectionist - HMM speech recognition systems," *IEEE Trans. on Speech and Audio Processing*, vol. 2, no. 1, pt. II, pp. 175-184, Jan. 1994.
- [23] M. Robinson, M. R. Azimi-Sadjadi, and J. Salazar, "Multi - aspect target discrimination using hidden markov models and neural networks," *IEEE Trans. on Neural Networks*, vol. 16, no. 2, pp. 447-459, Mar. 2005.
- [24] S. B. Cho, "Neural - network classifiers for recognizing totally unconstrained handwritten numerals," *IEEE Trans. on Neural Network*, vol. 8, no. 1, pp. 43-53, Jan. 1997.
- [25] J. Yang, Y. Xu, and C. S. Chen, "Hidden markov model approach to skill learning and its application to tele robotics," *IEEE Trans. on Robotics and Automation*, vol. 10, no. 5, pp. 621-631, Oct. 1994.
- [26] N. Johnson, A. Galata, and D. Hogg, "The acquisition and use of interaction behavior models," in *IEEE Computer Society Conf. on Computer Vision and Pattern Recognition*, pp. 866-871, Jun. 1998.
- [27] M. Brand and V. Kettner, "Discovery and segmentation of activities in video," *IEEE Trans. Pattern Analysis and Machine Intelligence*, vol. 22, no. 8, pp. 844-851, Aug. 2000.
- [۲۸] ه. صدوقی بزدی، م. لطفی زاد، ا. کبیر و م. فتحی، "مدل تعاملی برای تعیین عادی بودن رفتار انفرادی راننده،" *نشریه فنی و مهندسی مدرس*، شماره ۳۰، صص. ۲۱-۳۸، زمستان ۱۳۸۶.
- [29] S. Vaseghi, *Advanced Signal Processing and Digital Noise Reduction*, John Wiley & Sons Ltd, 1996.
- [30] C. Y. Suen, M. Berthod, and S. Mori, "Automatic recognition of handprinted characters the state of the art," in *Proc. IEEE*, vol. 68, no. 4, pp. 469-487, Apr. 1980.
- [31] K. Badie and M. Shimura, "Machine recognition of Arabic cursive scripts," in *Pattern Recognition in Practice*, E. S. Gelsema and L. N. Kanal (eds.), pp. 315-323, North Holland Publishing Company, 1980.
- [۳۲] و. جوهری مجذ و س. م. رضوی، "بازشناسی فازی ارقام دستنویس فارسی،" مجموعه مقالات اولین کنفرانس ماشین بیانی و پردازش تصویر ایران، صص. ۱۴۴-۱۵۱، دانشگاه بیرجند، اسفند ۱۳۷۹.
- [۳۳] ا. کبیر و ر. عزمی، "ارائه دو الگوریتم برای شناسایی حروف چاپی فارسی،" مجموعه مقالات سومین کنفرانس سالانه بین المللی انجمن کامپیوتر ایران، صص. ۹۱-۹۷، دانشگاه علم و صنعت ایران، دی ۱۳۷۶.
- [34] K. Massruri and E. Kabir, "Recognition of hand - printed farsi characters by a fuzzy classifier," in *Proc. of ACCV'95*, vol. 2, pp. 607-610, Singapore, Dec. 1995.
- [۳۵] و. دستپاک و ر. صفابخش، "شناسایی حروف و علائم تایپی فارسی با استفاده از نهادها،" مجموعه مقالات سومین کنفرانس مهندسی برق ایران، کامپیوتر، صص. ۱۹۸-۲۰۶، دانشگاه علم و صنعت ایران، اردیبهشت ۱۳۷۴.

توانست رفتار نرون‌های یک طبقه‌بند شبکه عصبی پس انتشار خطا را مدل کند. عملاً نرون‌های یک شبکه عصبی یا اجزای یک طبقه‌بند، با هم بیان کننده عملکرد آن در مقابل یک الگو هستند. بنابراین، با استفاده از یک کلیشه تصمیم جدید مبتنی بر مدل مخفی مارکوف، ارتباط بین نرون‌های شبکه عصبی و نحوه پاسخ آن به نمونه‌های یادگیر، مدل شد و از آن در شناسایی الگوهای جدید استفاده شد. روش جدید در مدل کردن رفتار طبقه‌بند، در شناسایی ارقام دستنویس فارسی، تشخیص ترافیک عادی در شبکه‌های اطلاع‌رسانی و شناسایی نوع وسیله نقلیه آزمون شد و افزایش قابل توجهی در نرخ شناسایی طبقه‌بند به دست آمد. در بررسی‌های انجام‌شده، نشان داده شد که وجود اطلاعاتی همچون احتمال گذر در هر کلیشه از جمله علل افزایش کارآیی شبکه عصبی می‌باشد.

## ۵- تشکر و قدردانی

از جناب آقای دکتر احسان‌اله کبیر و دکتر افسین ابراهیمی و شرکت هدی سامانه برای در اختیار گذاشتن مجموعه تصاویر ارقام دستنویس فارسی، از جناب آقای دکتر مهدی آبادی برای در اختیار گذاشتن مجموعه داده پروتکل‌های شبکه اطلاع‌رسانی و از جناب آقای مهندس امیری برای جمع‌آوری تصاویر خودروها کمال تشکر را دارم.

## مراجع

- [1] R. Duda, P. Hart, and D. Stork, *Pattern Classification*, New York: John Wiley & Sons, 2001.
- [2] H. Sameti, H. Sheikhzadeh, L. Deng, and R. L. Brennan, "HMM-based strategies for enhancement of speech signals embedded in nonstationary noise," *IEEE Trans. on Speech and Audio Processing*, vol. 6, no. 5, pp. 445-455, Sep. 1998.
- [3] H. R. Kim and H. S. Lee, "Postprocessor using fuzzy vector quantiser in HMM - based speech recognition," *Electronics Letters*, vol. 27, no. 22, pp. 1998-2000, Oct. 1991.
- [4] Y. Bengio, R. D. Mori, G. Flammia, and R. Kompe, "Global optimization of a neural network - hidden markov model hybrid," *IEEE Trans. on Neural Networks*, vol. 3, no. 2, pp. 252-259, Mar. 1992.
- [5] C. Dugast, L. Devillers, and X. Aubert, "Combining TDNN and HMM in a hybrid system for improved continuous - speech recognition," *IEEE Trans. on Speech and Audio Processing*, vol. 2, no. 1, part II, pp. 217-223, Jan. 1994.
- [6] C. A. Shipp and L. I. Kuncheva, "Relationship between combination methods and measures of diversity in combining classifiers," *Information Fusion*, vol. 3, no. 2, pp. 135-148, Jun. 2002.
- [7] I. Bloch, "Information combination operators for data fusion: a comparative review with classification," *IEEE Trans. on Systems, Man, and Cybernetics - Part A: Systems and Humans*, vol. 26, no. 1, pp. 52-67, Jan. 1996.
- [8] H. Bourlard and C. J. Wellekens, "Link between markov models and multilayer perceptrons," *IEEE Trans. on Pattern Analysis and Machine Intelligence*, vol. 12, no. 12, pp. 1167-1178, Dec. 1990.
- [9] Y. Bengio, R. Cardin, R. D. Mori, and Y. Normandi, "A hybrid coder for hidden markov models using a recurrent neural network," in *Proc. IEEE Conf. Acoust., Speech, Signal Process.*, pp. 537-540, Albuquerque, NM, US, Apr. 1990.
- [10] M. Franzini, K. F. Lee, and A. Waibel, "Connectionist viterbi training: a new hybrid method for continuous speech recognition," in *Proc. IEEE Conf. Acoust., Speech, Signal Process.*, pp. 425-428, Albuquerque, NM, US, Apr. 1990.
- [11] L. T. Niles and H. F. Silverman, "Combining hidden markov models and neural network classifiers," in *Proc. IEEE Conf. Acoust. Speech, Signal Process.*, pp. 417-420, Albuquerque, NM, US, Apr. 1990.
- [12] S. J. Young, "Competitive training in hidden markov models," in *Proc. IEEE Conf. Acoust. Speech, Signal Process.*, pp. 681-684, Albuquerque, NM, US, Apr. 1990.
- [13] J. N. Hwang, J. A. Viontzos, and S. Y. Kung, "A systolic neural network architecture for hidden markov models," *IEEE Trans. Acoust. Speech, Signal Process.*, vol. 37, no. 12, pp. 1967-1979, Dec. 1989.
- [14] J. S. Bridle, "Training stochastic model recognition algorithms as networks can lead to maximum, mutual information of parameters,"

- [45] P. G. Neumann and P. A. Porras, *Experience with EMERALD to Date*, First USENIX Workshop on Intrusion Detection and Network Monitoring, Santa Clara, CA, Apr. 1999.
- [46] Information Exploration Shootout, URL: <http://iris.cs.uml.edu:8080/network.html>, 1998.
- [47] V. Jacobson, C. Leres, and S. McCanne, Tepdump, <ftp://ftp.ee.lbl.gov>, 1998.
- [48] E. Prez " Image processing for intelligent transportation systems: application to road sign recognition," in *Smart Imaging Systems*, pp. 207-232, 1st ed., Bellingham, Washington: SPIE Press Monograph, 2001.
- [49] B. Bhana, "Automatic target recognition: state of the art survey," *IEEE Trans. Aerospace Electron System*, vol. 22, no. 4, pp. 364-379, Jul. 1986.
- [50] B. Dasarathy, "Information processing for target recognition from autonomous vehicles," in *Proc SPIE Electro-Opt Tech Autonomous Vehicles*, vol. 219, pp. 86-93, Feb. 1980.
- [51] B. Bhana and T. Jones, "Image understanding research for automatic target recognition," *IEEE Aerospace Electron System Magazine*, vol. 10, no. 8, pp. 15-22, Oct. 1993.
- [52] M. A. Turk and A. P. Pentland, "Face recognition using eigenfaces," in *Proc. IEEE Conf. on Computer Vision and Pattern Recognition*, pp. 586-591, Jun. 1991.
- [53] D. Terrieri, "The eigenspace separation transform for neural network classifiers," *Neural Networks*, vol. 12, pp. 419-427, Apr. 1999.
- [۳۶] م. فیضی و ر. ثانی, "تشخیص حروف دستنویس فارسی", "مجموعه مقالات اولین کنفرانس سالانه انجمن کامپیوتر ایران", ، صص. ۱۰۳-۱۱۰، دانشگاه صنعتی شریف، دی ۱۳۷۴
- [۳۷] م. فتحی و ع. برومدنیا, "شناسایی ارقام و حروف مجازی فارسی در شبیه‌ساز نور غیر یکنواخت", "مجموعه مقالات اولین کنفرانس سالانه انجمن کامپیوتر ایران", ، صص. ۱۰۲-۹۶، دانشگاه صنعتی شریف، دی ۱۳۷۴
- [۳۸] ک. فائز، ع. ختنزاد و م. شیرعلی شهرضا, "تشخیص حروف و ارقام دستنویس فارسی با استفاده از گشتاورهای شبیه‌زنیکی و به کمک شبکه‌های عصبی", "مجموعه مقالات سومین کنفرانس مهندسی برق ایران", صص. ۲۴۱-۲۴۰، دانشگاه علم و صنعت ایران، اردیبهشت ۱۳۷۴
- [۳۹] ن. ساداتی و ب. نظری, "استفاده از منطق فازی در تشخیص ارقام دستنویس فارسی", "مجموعه مقالات سومین کنفرانس مهندسی برق ایران", صص. ۲۴۷-۲۴۶، دانشگاه علم و صنعت ایران، اردیبهشت ۱۳۷۴
- [40] D. Anderson, T. F. Lunt, H. Javitz, A. Tamaru, and A. Valdes, Detecting Unusual Program Behavior Using the Statistical Component of the Next - generation Intrusion Detection Expert System (NIDES), Technical Report, SRI International, May 1995.
- [41] H. Debar, M. Becker, and D. Siboni, "A neural network component for an intrusion detection system," in *Proc. of the 1992 IEEE Computer Society Symposium on Research in Security and Privacy*, pp. 240-250, Oakland, CA, May 1992.
- [42] C. Dowell and P. Ramstedt, "The computer watch data reduction tool," in *Proc. of the 13th National Computer Security Conf.*, pp. 99-108, Washington, DC, Oct. 1990.
- [43] L. T. Heberlein, G. Dias, K. Levitt, B. Mukherjee, J. Wood, and D. Wolber, "A network security monitor," in *Proc. of the 1990 IEEE Symposium on Research in Security and Privacy*, pp. 296-304, Oakland, CA, May 1990.
- [44] S. R. Snapp, J. Brentano, G. Dias, T. Goan, L. T. Heberlein, C. Ho, K. Levitt, B. Mukherjee, S. Smaha, T. Grance, D. Teal, and D. Mansur, "DIDS (Distributed Intrusion Detection System) - motivation, architecture, and an early prototype," in *Proc. of the 14th National Computer Security Conf.*, pp. 167-176, Washington, DC, US, Oct. 1991.

هادی صادوقی یزدی تحصیلات خود را در مقطع کارشناسی در سالهای ۱۳۶۸ از دانشگاه فردوسی و کارشناسی ارشد و دکتری خود را بترتیب در سالهای ۱۳۷۳ و ۱۳۸۴ از دانشگاه تربیت مدرس اخذ کرده است. هم اکنون استادیار دانشگاه فردوسی مشهد و تربیت معلم سبزوار می‌باشد. زمینه‌های تحقیقاتی مورد علاقه ایشان عبارتند از: فیلترهای وقوعی و شبکه‌های عصبی، بهینه سازی در پردازش سیگنال، محاسبات نرم و کاربردهای آن.