

## تلفیق روش‌های یادگیری شات محدود جهت بهبود عملکرد طبقه‌بندی تصاویر با مجموعه داده‌های کم

علی بشیری<sup>۱</sup>، علی محمد لطیف<sup>۲\*</sup>

<sup>۱</sup> دانشجوی کارشناسی ارشد دانشکده مهندسی کامپیوتر، دانشگاه یزد، یزد، ایران

<sup>۲</sup> دانشیار دانشکده مهندسی کامپیوتر - بخش هوش مصنوعی، دانشگاه یزد، یزد، ایران

### چکیده

با وجود پیشرفت چشم‌گیر روش‌های هوش مصنوعی در سال‌های اخیر، همچنان نیاز به داده‌های فراوان برای یادگیری این روش‌ها مشاهده می‌شود. به منظور رفع این نیاز، الگوی جدید یادگیری ماشین به نام یادگیری شات محدود پیشنهاد شده است. یکی از روش‌های مطرح در این حوزه رویکرد شبکه‌های نمونه اولیه است که در واقع ترکیبی از روش‌های یادگیری متریک و فرا یادگیری است. در این شبکه‌ها، طبقه‌بند سعی می‌کند تا با توجه به تنها تعداد کمی از نمونه‌های هر کلاس جدید، نسبت به این کلاس‌ها تعمیم یابد. در این پژوهش سعی بر آن شد تا شکل تغییر یافته‌ای از شبکه‌های نمونه اولیه برای حل مساله طبقه‌بندی شات محدود پیشنهاد شود. در ابتدا به منظور بهبود عملکرد در شبکه‌های نمونه اولیه، به جای فاصله اقلیدسی از فاصله ماهالانویس برای اندازه‌گیری فاصله بین نمونه‌ها استفاده شد. این کار موجب بهبود عملکرد این شبکه‌ها در طبقه‌بندی تصاویر **omniglot** و **miniImageNet** شد به طوری که شبکه پیشنهادی توانست به ترتیب به دقت‌های ۹۹/۱٪ و ۶۸/۵٪ بر روی این دو مجموعه داده دست یابد. در بخش بعدی رویکردی کلی معرفی شد که می‌تواند معماری شبکه‌های عصبی کانولوشنی را با استفاده از الگوریتم ژنتیک به طور خودکار بهبود ببخشد. در این پژوهش از این رویکرد به طور خاص بر روی مجموعه داده‌های **omniglot** با معماری اولیه پیشنهادی در شبکه‌های نمونه اولیه استفاده شده است. در نهایت با استفاده از این رویکرد و جایگزینی معماری پیشنهادی آن با معماری اصلی شبکه نمونه اولیه دقت شبکه بهبود یافته و توانسته به دقت ۹۹/۵٪ دست یابد.

### مقاله پژوهشی

تاریخ دریافت:

۱۴۰۰/۱۱/۲

تاریخ پذیرش:

۱۴۰۱/۰۷/۱۰

کلیدواژه‌ها:

طبقه‌بندی، یادگیری شات محدود، فرایادگیری، یادگیری متریک

نویسنده مسئول:

alatif@yazd.ac.ir



10.22034/ABMIR.2022.2812:





## ۱- مقدمه

در سال‌های اخیر، به دلیل ظهور سیستم‌های محاسباتی قدرتمند، مجموعه داده‌های بزرگ [۱،۲]، مدل‌ها و الگوریتم‌های پیشرفته [۳]، هوش مصنوعی سرعت خود را افزایش داده تا شبیه انسان عمل کند و انسان را در بسیاری از زمینه‌ها شکست دهد.

روش‌های فعلی هوش مصنوعی با وجود اینکه در سال‌های اخیر پیشرفت چشمگیری در زمینه‌های مختلف داشته‌اند، اما نمی‌توانند خود را با چند نمونه آموزشی کم تعمیم و آموزش دهند. برنامه‌های موفقیت‌آمیز هوش مصنوعی متکی به یادگیری از داده‌های مقیاس بزرگ هستند. در مقابل، انسان‌ها با استفاده از آنچه در گذشته آموخته‌اند قادر به یادگیری سریع کارهای جدید هستند. به‌عنوان مثال، کودکی که چگونگی جمع کردن را یاد گرفته می‌تواند به‌سرعت دانش خود را برای یادگیری ضرب با چند مثال انتقال دهد. مثال دیگر این است که با توجه به چند عکس از یک غریبه، کودک به راحتی می‌تواند همان شخص را از میان تعداد زیادی عکس شناسایی کند.

برای حل این مساله باید به این سؤال پاسخ داد که چگونه می‌توان برنامه‌های رایانه‌ای را ساخت که به‌صورت تجربی و خودکار بهبود می‌یابند [۴]. به‌منظور پاسخ‌گویی به این سؤال و یادگیری از تعداد محدودی از نمونه‌های آموزشی برچسب زده‌شده، الگوی جدید یادگیری ماشین به نام یادگیری شات محدود [۵] پیشنهاد شده است. یادگیری شات محدود مبتنی بر این مفهوم است که می‌توان الگوریتم‌های قابل‌اعتمادی برای انجام پیش‌بینی بر روی مجموعه داده‌های حداقلی ایجاد کرد. از انگیزه‌های استفاده از این روش می‌توان به موقعیت‌های زیر اشاره کرد:

- هرگاه کمبود داده‌های تحت نظارت وجود داشته باشد، مدل‌های یادگیری ماشین اغلب قادر به انجام نرمال‌سازی قابل‌اعتماد نیستند.
- هنگام کار با یک مجموعه داده عظیم، برچسب‌گذاری صحیح داده‌ها پرهزینه است.

یکی از شیوه‌های رایج برای بهبود عملکرد و کارایی روش‌های موجود در حوزه‌های مختلف، ترکیب روش‌های مختلف با یکدیگر است. در زمینه یادگیری شات محدود نیز می‌توان از این شیوه بهره برد و روش‌های مختلف را باهم ترکیب کرد. یکی از روش‌های مطرح در این حوزه رویکرد شبکه‌های نمونه اولیه<sup>۱</sup> است که در واقع ترکیبی از روش‌های یادگیری متریک و فرایادگیری است. در این شبکه‌ها، طبقه‌بند سعی می‌کند تا با توجه به تنها تعداد کمی از نمونه‌های هر کلاس جدید، نسبت به این کلاس‌ها تعمیم یابد. در این پژوهش سعی بر آن شد تا شکل تغییر یافته‌ای از شبکه‌های نمونه اولیه برای حل مساله طبقه‌بندی شات محدود پیشنهاد شود. در ابتدا به‌منظور بهبود عملکرد در شبکه‌های نمونه اولیه، به‌جای فاصله اقلیدسی از فاصله ماهالانویس برای اندازه‌گیری فاصله بین نمونه‌ها استفاده شد. در بخش بعدی رویکردی کلی معرفی شد که می‌تواند معماری شبکه‌های عصبی کانولوشنی را با استفاده از الگوریتم ژنتیک به‌طور خودکار بهبود ببخشد. با استفاده از این رویکرد و جایگزینی معماری پیشنهادی آن با معماری اصلی شبکه نمونه اولیه دقت شبکه به‌گونه‌ای مطلوب بهبود یافت.

## ۲- یادگیری شات محدود

از آنجاکه یادگیری شات محدود یک زیرمجموعه در یادگیری ماشین است، قبل از تعریف آن بهتر است نگاهی به تعریف یادگیری ماشین در علوم کامپیوتری بیندازیم.

تعریف (۱) [۶]: طبق این تعریف اگر یک برنامه کامپیوتری بتواند با استفاده از کسب تجربه (E) در انجام برخی از وظایف که به آن محول شده است (T) بهبودی را در کارایی (P) سیستم ایجاد کند فرایند یادگیری صورت پذیرفته است.

به‌عنوان مثال یک کار طبقه‌بندی تصویر (T) را در نظر بگیرید. یک برنامه یادگیری ماشین می‌تواند دقت طبقه‌بندی (P) را از طریق تجربه (E) کسب‌شده توسط آموزش بر روی تعداد زیادی از تصاویر دارای برچسب بهبود بخشد. مثال دیگری که در این زمینه وجود دارد، برنامه رایانه‌ای آلفاگو<sup>۲</sup> است که قهرمان انسانی را در اجرای بازی باستانی (T) گو<sup>۳</sup> شکست داده است. این برنامه

<sup>3</sup> Go

<sup>1</sup> Prototypical Networks

<sup>2</sup> AlphaGo

### ۳-۱ روش‌های یادگیری متریک

در روش‌های یادگیری متریک هدف یادگیری نگاشتنی از تصاویر به یک فضای تعبیه‌شده است که در آن تصاویر از دسته‌های یکسان به هم نزدیک‌تر بوده و از دیگر دسته‌ها فاصله داشته باشند به امید آن‌که فضای ایجادشده در مورد دسته‌های دیده نشده هم صادق باشد.

مقالات و پژوهش‌های گسترده‌ای در حوزه یادگیری متریک انجام‌شده است [۹،۱۰] که در اینجا برخی از کارهای مرتبط با روش پیشنهادی را به‌طور خلاصه بیان می‌کنیم. در اولین مطالعات صورت گرفته در این حوزه، گلدبرگر و همکاران در سال ۲۰۰۴ مقاله‌ای تحت عنوان آنالیز مؤلفه‌های همسایگی (NCA) [۱۱] ارائه دادند که در آن سعی بر آن دارند که فاصله ماهالانویس را برای به حداکثر رساندن دقت  $K$  - نزدیک‌ترین همسایه (KNN) در فضای تبدیل‌شده، یاد می‌گیرد.

در پژوهش آن‌ها یک روش جدید برای یادگیری اندازه‌گیری فاصله ماهالانویس برای استفاده در الگوریتم طبقه‌بندی KNN پیشنهادشده است. در این الگوریتم تلاش بر این است تا دقت حاصل از الگوریتم KNN را به‌طور تصادفی بر روی مجموعه آموزشی به حداکثر برسانند. همچنین این روش می‌تواند یک تعبیه خطی با ابعاد کم از داده‌های دارای برچسب را یاد بگیرد که می‌تواند برای تجسم داده‌ها و طبقه‌بندی سریع مورد استفاده قرار گیرد. برخلاف سایر روش‌ها در آن زمان، مدل طبقه‌بندی آن‌ها غیر پارامتری است و هیچ فرضی در مورد شکل توزیع کلاس یا مرزهای بین آن‌ها وجود ندارد.

در سال ۲۰۱۷ مطالعه‌ای توسط جیک اسنل و همکاران [۱۲] به‌عمل آمده است که در آن شبکه‌های نمونه اولیه را برای حل مشکل طبقه‌بندی شات محدود پیشنهاد کردند. شبکه‌های نمونه اولیه یک فضای متریک را یاد می‌گیرند که در آن می‌توان طبقه‌بندی را با محاسبه فاصله هر نمونه از هر کلاس در بازنمایی اولیه انجام داد. تجزیه و تحلیل انجام‌شده توسط آن‌ها نشان می‌دهد که برخی از تصمیمات ساده در طراحی معماری شبکه می‌توانند پیشرفت چشمگیری نسبت به رویکردهای اخیر شامل انتخاب‌های پیچیده

رایانه‌ای با آموزش بر روی یک پایگاه داده (E) که از بازی حدود ۳۰ میلیون نفر از متخصصان انسانی و همچنین بازی مکرر با خود، میزان پیروزی (P) خود را در برابر حریفان بهبود می‌بخشد. خلاصه این مثال‌ها را می‌توان در جدول (۱) قابل مشاهده است.

تعریف (۲): یادگیری شات محدود نوعی از مسائل یادگیری ماشینی است (که توسط T و P مشخص می‌شود)، و در آن فقط تعداد محدودی از نمونه‌های آموزشی برچسب‌گذاری شده برای هدف T وجود دارد.

جدول (۱): نمونه‌هایی از مسائل یادگیری ماشینی بر اساس تعریف (۱)

وظیفه T	تجربه E	کارایی P
طبقه‌بندی تصاویر	تصاویر دارای برچسب در مقیاس بزرگ برای هر کلاس	دقت طبقه‌بندی
بازی باستانی گو	یک پایگاه داده حاوی حدود ۳۰ میلیون حرکت ثبت‌شده از متخصصان انسانی و سوابق بازی خود	نرخ برنده شدن

مسائل موجود در یادگیری شات محدود عمدتاً جز مسائل یادگیری ماشینی تحت نظارت ۱ هستند. به‌طور مثال، در مسئله طبقه‌بندی [۷]، طبقه بند یادگیری را تنها بر اساس تعداد کمی از نمونه‌های برچسب زده‌شده برای هر کلاس انجام می‌دهد.

طبقه‌بندی شات محدود یک طبقه‌بندی  $h$  را یاد می‌گیرد که برچسب  $y_i$  را برای هر ورودی  $x$  پیش‌بینی می‌کند. در مسائل طبقه‌بندی شات محدود معمولاً یک مسئله طبقه‌بندی به‌صورت  $N$ -way- $K$ -shot [۸] تعریف می‌شود، که در آن مجموعه آموزشی  $D_{train}$  شامل  $KN$  نمونه از کلاس‌های  $N$  است که در هر کلاس  $K$  نمونه وجود دارد.

### ۳- کارهای پیشین

اگرچه مرز روشی بین روش‌های یادگیری شات محدود وجود ندارد اما به‌طور کلی این روش‌ها را می‌توان به چهار دسته تقسیم کرد:

- روش‌های یادگیری متریک
- روش‌های فرا یادگیری
- روش‌های داده افزایی
- روش‌های مبتنی بر معنا

<sup>1</sup> Supervised

روی مجموعه داده‌های miniImageNet, tieredImageNet, CIFAR-10 و FC100 رسد.

### ۳-۳ روش‌های داده افزایی

به‌موازات ایجاد روش‌های فرا یادگیری، روش‌های داده افزایی مطرح شدند. روش‌های داده افزایی نیز بسیار محبوب هستند. ایده این روش‌ها این است که با تولید و تقویت داده‌های جدید سعی در جبران مجموعه داده‌های محدود شود.

گوو و همکارانش [۱۵] در سال ۲۰۱۷ یک مدل مولد زبان برای تولید جملات ساختگی جدید پیشنهاد کردند که ابتدا یک جمله اولیه را از مجموعه آموزشی به‌عنوان نمونه برداشته و سپس آن را در یک جمله جدید ویرایش می‌کند. در مقایسه با مدل‌های مولد زبان سنتی که جملات را به‌صورت از چپ به راست یا با نمونه‌برداری از جمله، از ابتدا ایجاد می‌کردند، مدل پیشنهادی آن‌ها ابهامات موجود در مدل‌سازی زبان را بهبود می‌بخشد و بر اساس ارزیابی انسانی، خروجی‌هایی باکیفیت بالاتر تولید می‌کند. علاوه بر این، این مدل یک بردار ویرایش شده نهفته ایجاد می‌کند که معانی قابل تفسیر مانند تشابه جملات و قیاس‌های سطح جمله را به تصویر می‌کشد.

### ۳-۴ روش‌های مبتنی بر معنا

در حال حاضر، روش‌های مبتنی بر معنا در حال افزایش هستند. از یادگیری صفر شات الهام گرفته شده‌اند که طبقه‌بندی فقط بر اساس توضیحات متنی یا ویژگی‌ها انجام می‌شود. درحالی‌که می‌توان از سوالات معنایی اضافه هنگامی که نمونه‌های بصری کمیاب هستند، کمک گرفت. یادگیری از یک یا چند نمونه بصری یکی از قابلیت‌های مهم انسان از بدو تولد است، اما هنوز هم برای سیستم‌های مدرن هوش مصنوعی یک چالش مهم است.

درحالی‌که پیشرفت‌های چشمگیری در یادگیری شات محدود از چند نمونه تصویر حاصل شده است، اما توجه کمتری به توضیحات کلامی که معمولاً هنگام ارائه یک شیء جدید به نوزادان ارائه می‌شود، شده است. شوارتز و همکاران [۱۶] در مقاله‌ای، بر نقش معنایی اضافی متمرکز شده‌اند که می‌تواند یادگیری بصری با تعداد کمی از تصاویر را به‌طور قابل‌توجهی تسهیل کند. با تکیه بر پیشرفت‌های اخیر در یادگیری شات محدود با اطلاعات معنایی

معماری و روش‌های فرا یادگیری، داشته باشند. در این پژوهش سعی بر آن شده است تا با مطالعه دقیق این کار و پیاده‌سازی آن، بتوان بهبودی بر روی این رویکرد ایجاد کرد.

### ۳-۲ روش‌های فرا یادگیری

روش‌های فرا یادگیری به‌جای این‌که بر روی مجموعه‌ای از نمونه اشیاء آموزش داده شوند، بر روی مجموعه‌ای از وظایف شات محدود، که به آن‌ها اپیزود هم گفته می‌شود، باهدف آموختن یک استراتژی یادگیری که امکان سازگاری با وظایف جدید را فراهم می‌آورد، آموزش داده می‌شوند.


در مطالعه‌ای فین و همکاران [۱۳] یک الگوریتم برای فرا یادگیری پیشنهاد کردند که یک مدل آگنستیک هست، به این معنی که با هر مدلی که با گرادیان نزولی آموزش داده می‌شود و برای انواع مسائل طبقه‌بندی، رگرسیون و یادگیری تقویتی مناسب است، سازگار هست. در این روش، پارامترهای مدل به‌طور صریح آموزش داده می‌شوند به‌طوری‌که تعداد کمی از مراحل گرادیان با مقدار کمی از داده‌های آموزشی از یک وظیفه جدید، عملکرد نرمال‌سازی خوبی را در آن کار ایجاد می‌کند. درواقع، این روش مدل را آموزش می‌دهد تا به‌راحتی تنظیم شود.

بسیاری از رویکردهای فرا یادگیری برای یادگیری شات محدود، به یادگیرنده‌های پایه ساده مانند طبقه بند نزدیک‌ترین همسایه متکی هستند. با این حال، حتی در روش‌های یادگیری شات محدود، پیش‌بینی کننده‌های خطی آموزش دیده شده با اختلاف می‌توانند عمومیت بهتری ارائه دهند.

لی و همکاران [۱۴] پیشنهاد کردند از این پیش‌بینی کننده‌ها خطی به‌عنوان یادگیرنده‌های پایه استفاده شود تا بازنمایی‌هایی را برای یادگیری شات محدود یاد بگیرد و نیز به‌خوبی مسئله میان اندازه ویژگی‌ها و کارایی را در میان طیف وسیعی از مجموعه داده‌های معیار نشان دهد. هدف آن‌ها یادگیری ویژگی‌های تعبیه‌شده‌ای است که به‌خوبی تحت یک طبقه‌بندی خطی برای دسته‌های جدید تعمیم می‌یابد. برای رسیدن به این هدف، از دو ویژگی طبقه بندهای خطی بهره استفاده شده است: مشتق‌گیری ضمنی از شرایط بهینه مسئله محدب و فرمول دوگان مسئله بهینه‌سازی. این رویکرد بانام MetaOptN توانسته است به بهترین میزان عملکرد رویکرد بر

تعبیه شده برای هر کلاس محاسبه می‌شوند. در شکل سمت راست نیز نمونه‌های اولیه صفر شات  $c_k$  با استفاده از نگاشت کلاس فراداده  $V_k$  تولید می‌شوند. در هر دو حالت، نقاط پرس وجوی تعبیه شده از طریق یک تابع بیشینه هموار بر اساس فواصل موجود تا نمونه‌های اولیه کلاس مطابق فرمول زیر طبقه‌بندی می‌شوند [۱۲]:

$$p_\phi(y = k|x) \propto \exp(-d(f_\phi(x), c_k)) \quad (1)$$



شکل (۲): شبکه‌های نمونه اولیه در سناریوهای چند شات و بدون شات [۱۲]

در این پژوهش، شبکه‌های نمونه اولیه فقط برای مسئله یادگیری شات محدود فرمول‌بندی و تنظیم شده است. ارتباطات با استفاده از شبکه‌های تطبیقی در محیط یک شات رسم شده‌اند و تابع فاصله اساسی مورد استفاده در مدل تحلیل می‌شود. به‌طور خاص، می‌توان شبکه‌های نمونه اولیه را به مسئله خوشه‌بندی ارتباط داد [۱۷] تا استفاده از میانگین هر کلاس به‌عنوان نمونه‌های اولیه را هنگامی که فاصله‌ها با یک واگرایی برگمن محاسبه می‌شوند را توجیه کرد.

در طبقه‌بندی شات محدود یک مجموعه پشتیبانی کوچک از  $N$  نمونه برچسب‌گذاری شده وجود دارد که به صورت  $\{(x_1, y_1), \dots, (x_N, y_N)\}$  نمایش داده می‌شود و در آن‌ها  $x_i \in R^D$  بردار ویژگی  $D$  بعدی یک نمونه و  $y_i \in \{1, \dots, K\}$  برچسب مربوطه است.  $S_k$  نشان‌دهنده مجموعه‌ای از نمونه‌های برچسب‌گذاری شده با کلاس  $k$  است.

شبکه‌های نمونه اولیه در واقع یک بازنمایی  $M$  بعدی برای هر  $c_k \in R^M$  یا نمونه اولیه از هر کلاس را از طریق تابع نگاشت  $f_\phi: R^D \rightarrow R^M$  با پارامترهای قابل یادگیری  $\phi$  محاسبه می‌کند. هر نمونه اولیه یک بردار میانگین از نقاط پشتیبانی تعبیه شده دارد که متعلق به کلاس خود اوست و از طریق رابطه زیر محاسبه می‌شود [۱۲]:

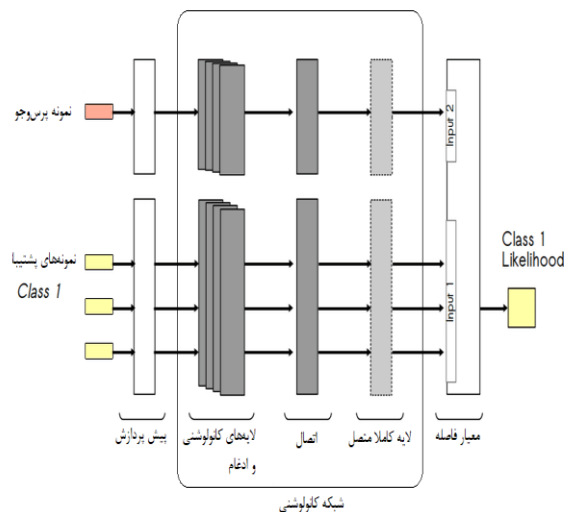
$$c_k = \frac{1}{|S_k|} \sum_{(x_i, y_i) \in S_k} f_\phi(x_i) \quad (2)$$

اضافی، آن‌ها نشان دادند که پیشرفت‌های بیشتر با استفاده از معنانشناسی غنی‌تر و منابع معنایی چندگانه امکان‌پذیر است. با استفاده از این ایده‌ها، آن‌ها توانستند نتایج جدیدی را بر روی مجموعه داده معیار miniImageNet به جامعه علمی ارائه دهند.

## ۴- روش پیشنهادی

از آن جا که روش پیشنهادی مبتنی بر روش شبکه‌های نمونه‌های اولیه است ابتدا بهتر است نگاهی کلی به این روش و چگونگی کارکرد آن انداخته شود.

رویکردی که در شبکه‌های نمونه اولیه [۱۲] مطرح شده است مبتنی بر این ایده است که یک خوشه‌بندی وجود دارد که در آن نقاط در اطراف یک نمایش نمونه اولیه منفرد برای هر کلاس قرار می‌گیرند. به‌منظور انجام این کار، شبکه یک نگاشت غیرخطی ورودی به فضای نگاشتی که با استفاده از شبکه عصبی ایجاد شده است را یاد می‌گیرد و یک نمونه اولیه کلاس را به‌عنوان میانگین مجموعه پشتیبانی آن در فضای نگاشت در نظر می‌گیرد. سپس طبقه‌بندی برای یک نقطه پرس وجوی جاسازی شده با پیدا کردن نمونه اولیه نزدیک‌ترین کلاس انجام می‌شود. نمودار جریان این شبکه در شکل (۱) آورده شده است. روش پیشنهادی این تحقیق بر دو بخش معیار فاصله و شبکه‌های کانولوشنی تمرکز دارد.



شکل (۱): نمودار جریان شبکه‌های نمونه اولیه

همان‌طور که در شکل (۲) سمت چپ مشاهده می‌کنید نمونه‌های اولیه شات محدود  $c_k$  به‌عنوان میانگین نمونه‌های پشتیبانی

از حالتی است که مستقل باشند. به این ترتیب به نظر می‌رسد که فاصله اقلیدسی وزن بیشتری به مشاهدات مرتبط با هم می‌دهد.

به این ترتیب اطلاع از مختصات یک نقطه می‌تواند در تعیین مختصات نقطه دیگر کمک کند و به این ترتیب آگاهی از مختصات یک نقطه می‌تواند برای جایگزین اطلاعات مربوط به نقطه دیگر باشد. در حالیکه در فاصله اقلیدسی درکی نسبت به این موضوع وجود ندارد و فاصله‌ها دوباره محاسبه شده و می‌تواند در مجموع، میانگین فاصله‌ها را تحت تأثیر قرار دهد. البته از آنجایی که متغیرها یا مؤلفه‌های مشخص شده در مؤلفه‌های اصلی مستقل از یکدیگر ایجاد می‌شوند، معمولاً این مشکل در این حالت بروز نمی‌کند.

مشکل دوم و اساسی هنگام استفاده از فاصله اقلیدسی، محاسبه میانگین و انحراف استاندارد داده‌ها است. اگر واقعاً مجموعه داده شامل نقاط پرت باشد، میانگین و انحراف استاندارد را تحت تأثیر خود قرار داده و محاسبات را دچار مشکل می‌کند. توجه داشته باشید که داده‌های پرت واقعاً متعلق به توزیع اصلی داده‌ها نیستند. مقادیرهای پرت ممکن است بر اثر خطای اندازه‌گیری یا موارد خاص به وجود آمده باشند که نمی‌توانند گویای رفتار واقعی و دائمی پدیده تصادفی باشند. برای خروج از این بحران از فاصله ماهالانویس استفاده می‌کنیم.

از دیگر اعضای واگرایی برگمن فاصله ماهالانویس هست که سعی شد در این پژوهش به جای فاصله اقلیدسی از این معیار به عنوان معیار فاصله برای خوشه‌بندی ورودی‌ها در رویکرد شبکه‌های نمونه اولیه استفاده شود. این تابع فاصله توسط چاندار ماهالانویس، دانشمند و آمارشناسی هندی در سال ۱۹۳۶ میلادی معرفی شد.

شیوه محاسبه فاصله ماهالانویس برای برداری از نقطه‌های  $x = (x_1, x_2, x_3, \dots, x_N)^T$  به صورت زیر است. در فرمول ۴ از نماد  $D_M$  برای نمایش فاصله نقطه  $X$  از توزیعی با بردار میانگین  $\mu$  و ماتریس واریانس-کواریانس  $S^2$  استفاده شده است [۱۲].

$$D_M(x) = \sqrt{(x - \mu)^T S^{-1} (x - \mu)} \quad (4)$$

از آنجا که در مسائل یادگیری شات محدود تعداد داده‌ها کم بوده و از طرفی فاصله ماهالانویس نیازمند معکوس ماتریس کواریانس داده‌ها است این نگرانی ایجاد می‌شود که ماتریس حاصل دچار

با توجه به تابع فاصله  $d: R^M \times R^M \rightarrow [0, +\infty)$  شبکه‌های نمونه اولیه یک توزیع بر روی کلاس‌ها برای نقطه پرس‌وجو  $x$  ایجاد می‌کنند که این توزیع بر اساس یک تابع بهینه هموار<sup>۱</sup> بر روی فاصله نسبت به نمونه‌های اولیه در فضای موجود عمل می‌کند. تابع این توزیع در فرمول ۳ آورده شده است [۱۲]. در این فرمول  $k$  تعداد کلاس‌های درست در فضای ایجاد شده است.

$$p_\varphi(y = k|x) = \frac{\exp(-d(f_\varphi(x), c_k))}{\sum_{k'} \exp(-d(f_\varphi(x), c_{k'}))} \quad (3)$$

فرایند یادگیری با به حداقل رساندن منفی لگاریتم احتمال  $J(\varphi) = -\text{Log} p_\varphi(y = k|x)$  از کلاس درست  $k$  به وسیله الگوریتم بهینه‌سازی گرادینان نزولی تصادفی پیش می‌رود. اپیزودهای آموزشی با انتخاب تصادفی زیرمجموعه‌ای از کلاس‌ها از مجموعه داده آموزشی و سپس انتخاب زیرمجموعه‌ای از نمونه‌ها در هر کلاس برای عمل به عنوان مجموعه پشتیبانی که به عنوان نقاط پرس‌وجو عمل می‌کنند، مورد استفاده قرار می‌گیرند.

#### ۴-۱ رویکرد پیشنهادی اول: جایگزینی معیار فاصله

اولین رویکردی که در این پژوهش مورد آزمایش قرار گرفته است استفاده از فاصله ماهالانویس به جای فاصله اقلیدسی است. همان‌طور که در نمودار جریان شبکه نمونه اولیه نشان داده شد پس از اینکه نمونه‌های ورودی از طریق یک شبکه کانولوشنی به یک فضای تعبیه‌شده نگاشت شدند حالا نوبت به خوشه‌بندی آن‌ها با استفاده از یک طبقه بند می‌رسد. هر طبقه بند نیاز به یک معیار فاصله برای اندازه‌گیری فاصله بین نقاط پرس‌وجو تا نماینده هر کلاس که به آن نمونه اولیه گفته می‌شود دارد.

در نسخه اصلی شبکه‌های نمونه اولیه [۱۲] از معیار فاصله اقلیدسی برای انجام این کار استفاده شده است. بنا به دلایلی که در ادامه توضیح داده خواهد شد، فاصله ماهالانویس جایگزین فاصله اقلیدسی شد. دو مشکلی اساسی هنگام استفاده از فاصله اقلیدسی وجود دارد. مشکل اول ناشی از وجود رابطه یا همبستگی بین محورهای است. اگر مقادیرهای مربوط به محور افقی و عمودی با یکدیگر ارتباط یا همبستگی داشته باشند، فاصله اقلیدسی بزرگ‌تر

<sup>1</sup> Softmax

معماری تکامل یافته به CNN ها برای دستیابی به عملکرد خوب در حل وظایف مختلف کمک کند. علاوه بر این، توسعه عملگرهای انتخاب، ترکیب و جهش مرتبط که می‌توانند با استراتژی‌های رمزگذاری ژن طراحی شده معماری‌ها کنار بیایند، الزامی است. الگوریتم ۱ ساختار روش پیشنهادی را تشریح می‌کند. در الگوریتم پیشنهادی، با دادن معماری CNN ورودی، اندازه جمعیت و تعداد نسل‌ها، الگوریتم از طریق یک سری فرآیندهای تکاملی شروع به کار می‌کند و در نهایت یک معماری بهبود یافته برای CNN ورودی کشف می‌کند.

#### الگوریتم ۱: چارچوب الگوریتم پیشنهادی

**Input:** input CNN architecture, population size  $P$ , number of generation  $G$ .

**Output:** optimized input CNN architecture.  
population = generate\_population(num\_pop)

**For**  $t \leftarrow 0$  to  $G$  **do**

**For**  $k \leftarrow 0$  to population **do**

Select two individual from  $P_t$ ;

Generate a new individual  $i_k$  using crossover;

Randomly apply soft mutation to  $i_k$ ;

Evaluate the fitness of  $i_k$ ;

Evolve  $P_t$  with  $i_k$ ;

**End for**

$P_{t+1} \leftarrow P_t$

**End for**

Select the best individual from  $p_t$  and decode it the corresponding CNN architecture.

در ابتدا، جمعیت اولیه با استفاده از تابع generate\_population به‌طور تصادفی ساخته می‌شود. این تابع جمعیت اولیه را بر اساس یکسری مقادیر اولیه از پیش تعریف شده برای هر کروموزوم به‌طور تصادفی می‌سازد. سپس، تکامل برای تعداد ورودی نسل‌ها شروع می‌شود.

در هر مرحله از تکامل، یک فرزند جدید محاسبه می‌شود، بر روی مجموعه داده‌های داده شده ارزیابی می‌شود و با جمعیت تولید شده در مرحله قبل مقایسه می‌شود. به‌طور خاص، هر فرد از فرزندان جدید، که معماری خاصی از CNN را رمزگذاری می‌کند، با انتخاب دو فرد از جمعیت، و سپس ترکیب آن‌ها با استفاده از عملگرهای ژنتیکی تولید می‌شود. پس از آن، فرد جدید مورد ارزیابی

تکنیکی<sup>۱</sup> شود، اما در عمل سعی شد تا داده‌ها را در هر اپیزود به گونه‌ای تقسیم کرد که ماتریس کواریانس دچار این مشکل نشود. نکته دیگری که در این زمینه مطرح است این است که استفاده از فاصله ماهالانویس به دلیل وجود ماتریس کواریانس داده‌ها می‌تواند مقداردهی اولیه پارامترها را تسهیل نماید.

استفاده از فاصله ماهالانویس به جای فاصله اقلیدسی و ایجاد یکسری تغییرات دیگر در معماری و الگوریتم پیشنهادی شبکه‌های نمونه اولیه باعث شد تا در بعضی از آزمایش‌ها نتایج بهتری نسبت به روش پیشنهادی اسنل و همکاران اتخاذ شود که در فصل بعد نتایج حاصل از آن را ارائه داده و با نتایج بقیه روش‌ها مقایسه خواهیم کرد.

#### ۴-۲ رویکرد پیشنهادی دوم: طراحی خودکار شبکه

##### عصبی کانولوشنی

شبکه‌های عصبی کانولوشنی (CNN) در سال‌های اخیر موفقیت قابل توجهی در وظایف تشخیص تصویر به دست آورده‌اند و در برنامه‌های بینایی کامپیوتری مختلف اعمال می‌شوند [۱۸]. این شبکه‌ها به‌طور قابل توجهی دقت را در وظایف طبقه‌بندی تصویر بهبود بخشیدند. با این حال، طراحی چنین شبکه‌هایی نیاز به دانش غنی از حوزه شبکه‌های عصبی کانولوشنی دارد. از آنجاکه عملکرد CNN ها به شدت به داده‌های بررسی شده متکی است، محدودیت‌های عمده‌ای برای این روش طراحی وجود دارد.

با توجه به چالش‌های موجود در زمینه طراحی شبکه‌های عصبی کانولوشنی بهتر است رویکردی را ارائه داد تا این شبکه‌ها را به‌صورت خودکار طراحی نماید. در رویکرد پیشنهادی دوم، سعی بر آن شده است تا یک روش فرا ابتکاری کارآمد با استفاده از الگوریتم ژنتیک برای بهبود خودکار معماری یک شبکه‌های عصبی کانولوشنی معین برای رسیدگی ارائه شود. هدف از استفاده از این رویکرد در شبکه‌های نمونه اولیه بهبود عملکرد شبکه عصبی کانولوشنی تعبیه شده در این شبکه‌ها است.

برای دستیابی به این هدف، لازم است تا یک رمزگذار انعطاف‌پذیر ژن طراحی شود که حداکثر طول بلوک‌های ساختمانی در CNN را محدود نمی‌کند. با این طرح رمزگذاری ژن، انتظار می‌رود که

<sup>1</sup> Singularity

در این رابطه  $f_i$  نشان‌دهنده میزان برازندگی ورودی  $i$  و  $p_i$  احتمال انتخاب ورودی  $i$  را نشان می‌دهد.

#### ▪ عملگر ترکیب

عملگر ترکیب با ترکیب بخش‌هایی از دو فرد منتخب، فرد جدیدی تولید می‌کند. عملگر متقاطع الگوریتم پیشنهادی از متقاطع یک نقطه‌ای در الگوریتم‌های ژنتیک سنتی الهام گرفته شده است. در این عملیات ابتدا هر فرد والد به‌طور تصادفی به دو قسمت تقسیم می‌شود و سپس با گرفتن قسمت اول از یک والدین و قسمت دوم از دیگری یک فرد جدید به دست می‌آید.

#### ▪ عملگر جهش

همان‌طور که اشاره شد عملگر جهش باعث ایجاد تنوع ژنتیکی در بین افراد می‌شود و تلاش می‌کند تا از همگرایی الگوریتم ژنتیک به حداقل محلی جلوگیری کند. در روش پیشنهادی برای پیاده‌سازی این عملگر از تغییر تعداد تکرارها در فرایند یادگیری مدل استفاده شد. به این صورت متغیر تصادفی تعریف شد که اگر مقدار آن از حد مشخصی کمتر باشد تعداد تکرارهای فرایند یادگیری به‌طور تصادفی بین ۱ تا ۱۰ گام افزایش می‌یابد. در فصل بعد به بررسی نحوه پیاده‌سازی این رویکرد و نتایج حاصل از آن پرداخته خواهد شد.

#### ▪ جمع‌بندی

در این بخش به بررسی شبکه‌های نمونه اولیه که در واقع مدل اصلی مورد استفاده در این پژوهش است، پرداخته شد و به جزئیات پیاده‌سازی آن به تفکیک بخش‌های مختلف مورد بررسی قرار گرفتند. همان‌طور که مشاهده شد این شبکه از دو بخش شبکه عصبی کانولوشنی و یک طبقه‌بند متریک به‌منظور انجام عملیات طبقه‌بندی تصاویر استفاده می‌کند.

در ادامه سعی شد تا با استفاده از دو رویکرد پیشنهادی، یعنی تغییر معیار فاصله و استفاده از الگوریتم ژنتیک در بهبود ساختار شبکه عصبی کانولوشنی شبکه نمونه اولیه، عملکرد این شبکه را بهبود ببخشیم.

در رویکرد اول با توجه به دلایل مطرح‌شده و توجه به این نکته که استفاده از فاصله ماهالانویس به دلیل وجود ماتریس کواریانس داده‌ها می‌تواند مقداردهی اولیه پارامترها را تسهیل نکند، معیار

قرار می‌گیرد و با جمعیت مقایسه می‌شود. جمعیت افراد انتخابی باقی‌مانده به نسل بعدی از جمعیت فعلی تبدیل می‌شوند.

#### ▪ استراتژی رمزگذاری

چهار بلوک مختلف (به‌عنوان مثال، لایه کانولوشن، لایه ادغام، لایه حذف و لایه کاملاً متصل) در معماری CNN وجود دارد. بنابراین، آن‌ها باید در یک فرد برای تکامل رمزگذاری شوند. از آنجاکه هدف از انجام این رویکرد استفاده از آن به‌طور خاص در شبکه نمونه اولیه و بر روی مجموعه داده Omniglot است سعی بر آن شد تا از معماری پیشنهادی آن الگوریتم برای بهبود پارامترهای آن استفاده کرد.

#### ▪ ارزیابی شایستگی

هدف از ارزیابی شایستگی ارائه یک معیار کمی از کیفیت یک فرد است. از آنجایی‌که الگوریتم پیشنهادی به حل وظایف طبقه‌بندی تصویر می‌پردازد، خطای طبقه‌بندی بهترین استراتژی برای محاسبه تناسب یک فرد است. برای محاسبه خطای طبقه‌بندی، لازم است مجموعه داده اصلی را به یک مجموعه آموزشی  $D_{train}$  و یک مجموعه اعتبارسنجی  $D_{val}$  تقسیم کرده و سپس هر فرد را در  $D_{train}$  آموزش داده و سپس آن را روی  $D_{val}$  آزمایش کرد. در نهایت بهترین فرد، فردی است که کمترین مقدار تابع هزینه یا بیشترین مقدار دقت را بر روی مجموعه داده اعتبارسنجی داشته باشد.


#### ▪ عملگر انتخاب

عملگر انتخاب تصمیم می‌گیرد که کدام افراد از جمعیت برای تولید فرزندان جدید در هر تکرار استفاده شوند. روش‌های مختلفی برای انجام این کار وجود دارد. در این رویکرد از روش چرخ رولت که یکی از معروف‌ترین آن‌ها است استفاده می‌کنیم. در این روش هر یک از کروموزوم‌ها بسته به میزان شایستگی احتمال انتخاب شدن دارند. به‌عبارت‌دیگر هر چه یک کروموزوم بهتر باشد احتمال انتخاب شدن آن برای تولید نسل بعدی بیشتر است و برعکس هر چه کروموزوم بدتر باشد، احتمال انتخاب شدن آن برای تولید نسل بعدی کمتر است. رابطه ۴ نحوه انتخاب فرد توسط چرخ رولت را نشان می‌دهد [18].

$$p_i = \frac{f_i}{\sum_{j=1}^N f_j} \quad (4)$$



در این پژوهش روش اسنل و همکارانش دنبال شده است [12]. این کار با تغییر اندازه تصاویر در مقیاس خاکستری به  $1 \times 28 \times 28$  و افزایش کلاس کاراکترها به وسیله چرخش‌های متعدد ۹۰ درجه انجام شد. از ۱۲۰۰ کاراکتر به علاوه چرخش (در مجموع ۸۰۰ کلاس) برای آموزش و از مابقی تصاویر به همراه چرخش برای آزمایش استفاده شد. معماری که توسط اسنل و همکاران معرفی شد، از چهار بلوک متحرک تشکیل شده است. هر بلوک شامل ۶۴ فیلتر  $3 \times 3 \times 3$  کانولوشن، لایه نرمال‌سازی دسته‌ای، یک تابع غیرخطی ReLU و یک لایه ادغام  $2 \times 2$  هست. شمای کلی این بلوک‌های می‌توانید در شکل ۳ مشاهده کنید.



شکل (۳): شمای کلی بلوک‌های کانولوشنی

هنگامی که این شبکه با این معماری روی تصاویر Omniglot 28  $\times$  اعمال می‌شود، منجر به ایجاد فضای خروجی ۶۴ بعدی خواهد شد. در این پیاده‌سازی از یک رمزگذار یکسان هم برای نقاط پشتیبانی و هم برای پرس‌وجو استفاده شده است. در نهایت مدل پیشنهادی از طریق الگوریتم بهینه‌سازی آدام<sup>۱</sup> آموزش دیده شد. نرخ یادگیری اولیه ۳-۱۰ و تعداد قسمت‌های<sup>۲</sup> اجرایی شبکه ۲۰۰ بار در نظر گرفته شده است. همچنین به منظور مقایسه عملکرد روش پیشنهادی با دیگر روش‌های موجود در حوزه یادگیری شات محدود که همگی تنها بر اساس دقت روش خود را ارزیابی کرده‌اند در این پژوهش نیز از معیار دقت برای این منظور استفاده شد. در ادامه شبکه‌های نمونه اولیه با استفاده از فاصله ماهالانویس بجای فاصله اقلیدسی در سناریوهای ۱ شات و ۵ شات با اپیزودهای آموزشی شامل ۶۰ کلاس و ۵ نقطه پرس‌وجو در هر کلاس آموزش داده شد. طبق نتایج حاصل شده دریافت شد که مطابقت دادن عکس آموزشی با عکس آزمایشی و استفاده از کلاس‌های بیشتر در هر اپیزود آموزشی، مفید است.

اندازه‌گیری فاصله در طبقه بند شبکه تغییر داده شد. البته باید توجه داشت به دلیل استفاده از معکوس ماتریس کواریانس داده‌ها در فاصله ماهالانویس سربار محاسباتی زیادی به شبکه متحمل می‌شود.

در رویکرد پیشنهادی دوم، یعنی استفاده از الگوریتم ژنتیک در بهبود ساختار شبکه عصبی کانولوشنی، سعی شد تا با استفاده از الگوریتم ژنتیک پارامترهای مختلف شبکه عصبی پیشنهادی مانند تعداد لایه‌های کانولوشنی، اندازه فیلترها، توابع فعال‌سازی، الگوریتم بهینه‌سازی را به طور خودکار پیش‌بینی و در شبکه استفاده کرد. سپس هر شبکه‌ای که بیشترین دقت طبقه‌بندی را بر روی مجموعه داده‌ها داشت به عنوان شبکه بهینه انتخاب شده و در شبکه اصلی نمونه‌های اولیه استفاده خواهد شد. این رویکرد یک رویکرد کلی خواهد بود که برای سایر کاربردها نیز قابل استفاده است.

## ۵- ارزیابی روش پیشنهادی

در این پژوهش ارزیابی‌ها بر روی دو مجموعه داده Omniglot و MiniImageNet نسخه ILSVRC2012 انجام شده است. خلاصه‌ای از مشخصات این مجموعه داده‌ها در جدول (۲) آورده شده است.

جدول (۲): مجموعه داده‌های تصویر برای محک زدن رویکردهای

یادگیری شات محدود

مجموعه داده	توصیف	وضوح تصاویر
Omniglot	۱۶۲۳ کاراکتر دست‌نویس مختلف از ۵۰ زبان مختلف. ۲۰ نمونه برای هر یک از ۱۶۲۳ کاراکتر	۱۰۵×۱۰۵
MiniImageNet	زیرمجموعه Imagenet. تصاویر دنیای واقعی. ۳۸۴۰۰ تصویر آموزشی، ۱۲۰۰۰ تصویر تست و ۹۶۰۰ تصویر اعتبار سنجی	۵۰۰×h

رویکرد اول: تغییر معیار فاصله در الگوریتم شبکه نمونه اولیه

<sup>2</sup> Epoch

<sup>1</sup> Adam

نتایج حاصل از رویکرد پیشنهادی با پژوهش‌های پایه مختلف، از جمله آمار عصبی [23]، Meta - Learner LSTM [22]، MAML [13] و هر دو نسخه تنظیم دقیق و تنظیم‌نشده شبکه‌های تطبیقی [19] مقایسه شد. نتایج به‌دست‌آمده در جدول ۳ نشان داده شده است و همان‌طور که مشاهده می‌کنید با روش‌های مشابه موجود در این مجموعه داده قابل‌رقابت است.

جدول (۳): دقت طبقه‌بندی یادگیری شات محدود بر روی مجموعه داده Omniglot

در ادامه روش پیشنهادی با روش پایه‌ای که توسط راوی و لاروشل گزارش شده است مقایسه می‌شود [20]، که شامل یک رویکرد ساده از نزدیک‌ترین همسایه بر ویژگی‌هایی است که یک شبکه طبقه‌بندی در ۶۴ کلاس آموزشی آموخته است. روش‌های پایه دیگر که روش پیشنهادی با آن‌ها مقایسه شد عبارتند از دو نوع شبکه‌های منطبق (معمولی و FCE) و Meta-Learner LSTM هستند که به‌خوبی تنظیم‌نشده‌اند. همان‌طور که در جدول ۴ مشاهده می‌شود، شبکه نمونه اولیه پیشنهادی با جایگزینی معیار فاصله توانسته است تا نسبت به شبکه‌های نمونه اولیه دقت طبقه‌بندی را هم در ۱ شات و هم در ۵ شات بهبود ببخشد.

جدول (۴): دقت‌های طبقه‌بندی شات محدود بر روی مجموعه داده miniImageNet

داده Omniglot

مدل	معیار فاصله	دقت 5-way		دقت 20-way	
		۱ شات	۵ شات	۱ شات	۵ شات
آمار عصبی [۲۳]	کسینوسی	۹۸٪/۱	۹۹٪/۵	۹۳٪/۲	۹۸٪/۱
MAML [۱۳]	-	۹۸٪/۷	۹۹٪/۹	۹۵٪/۸	۹۸٪/۹
شبکه‌های تطبیقی [۱۹]	کسینوسی	۹۸٪/۱	۹۸٪/۹	۹۳٪/۸	۹۸٪/۵
شبکه‌های تطبیقی [۱۹]	-	۹۷٪/۹	۹۸٪/۷	۹۳٪/۵	۹۸٪/۷
شبکه‌های نمونه اولیه [۱۲]	اقلیدسی	۹۸٪/۸	۹۹٪/۷	۹۶٪/۰	۹۸٪/۹
روش پیشنهادی	ماهالانویس	۹۸٪/۹	۹۹٪/۶	۹۷٪/۱	۹۹٪/۱

مدل	معیار فاصله	دقت 5-way	
		۱ شات	۵ شات
فرا یادگیرنده LSTM [23]	-	۴۳٪/۴۴	۶۰٪/۶۰
MAML [13]	-	۴۸٪/۷۰	۶۳٪/۱۵
شبکه‌های تطبیقی [19]	کسینوسی	۴۳٪/۴۰	۵۱٪/۰۹
شبکه‌های تطبیقی FCE [19]	کسینوسی	۴۳٪/۵۶	۵۵٪/۳۱
شبکه‌های نمونه اولیه [12]	اقلیدسی	۴۹٪/۷۰	۶۸٪/۲۰
روش پیشنهادی	ماهالانویس	۴۹٪/۶۹	۶۸٪/۵۰

مجموعه داده miniImageNet که در اصل توسط وینلز و همکارانش [7] ارائه شده از مجموعه داده بزرگ‌تر ImageNet 12 ILSCVR استخراج شده است [24]. تقسیمات<sup>۱</sup> مورد استفاده توسط وینلز و همکارانش شامل ۶۰۰۰۰ تصویر رنگی با اندازه ۸۴×۸۴ هست که این تعداد داده در ۱۰۰ کلاس که هر کدام شامل ۶۰۰ نمونه تصویر است، تقسیم‌بندی شده‌اند. در آزمایش‌های انجام‌شده در این پژوهش، از تقسیمات معرفی شده توسط راوی و لاراشل [20] به‌منظور مقایسه مستقیم با الگوریتم‌های سطح بالا برای یادگیری شات محدود استفاده می‌شود.

تقسیمات آن‌ها از مجموعه متفاوتی از ۱۰۰ کلاس استفاده می‌کند که به ۶۴ کلاس آموزشی، ۱۶ کلاس اعتبارسنجی و ۲۰ کلاس

<sup>1</sup> Split

آموزشی و اعتبارسنجی به ترتیب ۵۰۰۰۰ و ۱۰۰۰۰ است و اندازه هر تصویر ۳۲×۳۲ است. پس از اطمینان از صحت اجرایی بودن کار، روش پیشنهادی بر روی مجموعه داده اصلی شبکه یعنی مجموعه داده Omniglot بررسی شد. از آنجاکه این مجموعه داده به‌منظور یادگیری و آزمایش بر روی روش‌های یادگیری شات محدود توسعه داده شده است لذا فرایند یادگیری آن نیز متفاوت از مجموعه داده‌های دیگر است.


در الگوریتم پیشنهادی، انتخاب پارامترها با کیفیت راه‌حلی که فرد می‌خواهد به دست آورد، منابع محاسباتی موجود و اندازه مجموعه داده در نظر گرفته شده تعیین می‌شود. مصالحه بین این مشخصات، زمان محاسباتی مورد نیاز الگوریتم برای همگرایی به یک راه‌حل را مشخص می‌کند. به‌طور خاص، اگر منابع محاسباتی موجود فقط محدود باشد، زمان محاسباتی مورد نیاز الگوریتم پیشنهادی ممکن است چالش‌برانگیز شود.

هر شبکه عصبی کانولوشنی پارامترهای متعددی دارد که می‌توان توسط الگوریتم ژنتیک مقدار آن‌ها را بهبود بخشید. اما در این پژوهش پارامترهای انتخابی که به‌عنوان کروموزوم‌های الگوریتم ژنتیک در نظر گرفته شده‌اند، به شرح زیر می‌باشند:

- تعداد فیلترهای هر بلوک
- اندازه فیلترها
- نرخ یادگیری
- گام حرکت
- تابع فعال‌سازی
- تعداد تکرارها در فرایند یادگیری

هر یک از این پارامترها به‌عنوان کروموزوم‌های الگوریتم ژنتیک در نظر گرفته می‌شود که در هر بار اجرا الگوریتم مدل را به یکی از مقادیر مختلف برای آن‌ها آموزش می‌دهد و دقت حاصل از آن را به‌عنوان میزان شایستگی آن مدل در نظر می‌گیرد. با این کار مدل با بهترین مقادیر برای پارامتر به‌عنوان مدل نهایی معرفی می‌شود.

الگوریتم پیشنهادی بر روی یک معماری پایه CNN برای مجموعه داده Omniglot آزمایش شده و CNN حاصل ارائه و تحلیل می‌شود. معماری CNN مورد استفاده برای تکامل شامل ۴ بلوک پی‌درپی است که در هر بلوک تعدادی لایه کانولوشنی، لایه



شکل (۴): مقایسه تأثیر معیار فاصله و تعداد کلاس‌ها در هر قسمت آموزشی بر دقت طبقه‌بندی ۵ کلاس برای شبکه نمونه اولیه و شبکه‌های پیشنهادی ما بر روی مجموعه داده

#### miniImageNet

در ادامه سعی بر آن شد تجزیه و تحلیل بیشتری انجام شود تا تأثیر معیار فاصله و تعداد کلاس‌های آموزشی در هر قسمت بر عملکرد شبکه‌های نمونه اولیه و روش پیشنهادی تعیین شود.

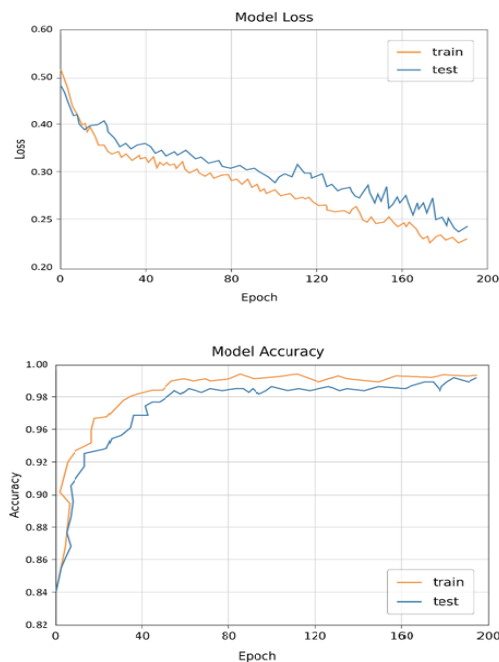
در شکل (۴) فاصله اقلیدسی را در مقابل فاصله ماهالانویس و اپیزودهای آموزشی ۵ کلاس در مقابل ۲۰ کلاس در سناریوهای ۱ شات و ۵ شات با ۱۵ نقطه پرس‌وجو در هر کلاس در هر اپیزود مقایسه می‌شود. همان‌طور که در شکل مشخص است ۲۰ کلاس به دقت بیشتری نسبت به ۵ کلاس دست پیدا می‌کند و افزایش دشواری طبقه‌بندی ۲۰ کلاس به شبکه کمک می‌کند تا بهتر تعمیم یابد، زیرا مدل را مجبور می‌کند در فضای تعبیه شده تصمیمات دقیق‌تری اتخاذ کند. همچنین استفاده از فاصله ماهالانویس عملکرد را تا حد قابل‌قبولی در مقایسه با فاصله اقلیدسی بهبود می‌بخشد.

رویکرد دوم: طراحی خودکار معماری بلوک‌های کانولوشنی در این رویکرد، ابتدا روش پیشنهادی به‌طور آزمایشی بر روی کار طبقه‌بندی تصویر با استفاده از مجموعه داده CIFAR-10 [25] آزمایش شد که در آن تعداد کلاس‌ها ۱۰ است. تعداد تصاویر

۹۸٪/۵	کسینوسی	شبکه‌های تطبیقی [19]
۹۸٪/۷	-	شبکه‌های تطبیقی [19]
۹۸٪/۹	اقلیدسی	شبکه‌های نمونه اولیه [12]
۹۹٪/۵	اقلیدسی	روش پیشنهادی

شکل (۶): نمودارهای دقت و هزینه شبکه نمونه اولیه با معماری


پیشنهادی بر روی مجموعه داده Omniglot



با جایگزینی مدل پیشنهادی با مدل اصلی دقت شبکه نمونه اولیه به ۹۹/۵٪ افزایش پیدا کرد. این نتیجه نشان می‌دهد که با تغییر معماری شبکه CNN الگوریتم شبکه نمونه اولیه می‌تواند تا حد قابل قبولی دقت خود را بر مجموعه داده Omniglot افزایش دهد. نتایج به دست آمده در جدول ۵ نشان داده شده است و همان‌طور که مشاهده می‌کنید با روش‌های مشابه موجود در این مجموعه داده قابل رقابت است.

استفاده از مدل شبکه عصبی کانولوشنی ایجاد شده توسط الگوریتم پیشنهادی در شبکه‌های نمونه اولیه توانست به دقت ۹۹٪/۵ و زیان<sup>۱</sup> ۲٪/۳ در ۲۰۰ دوره آموزشی دست یابد. منحنی‌های دقت و زیان در شکل ۶ نشان داده شده است.

نرمال‌سازی، لایه ادغام و لایه کاملاً متصل است. هدف نهایی این روش پیدا کردن پارامترهای بهینه برای لایه‌های هر بلوک است. نتایج حاصل از آزمایش نشان می‌دهد که مدل شبکه عصبی کانولوشنی پایه در صورت داشتن پارامترهایی به تعداد ۱۲۸ فیلتر با اندازه ۳\*۳\*۳، گام حرکت ۱، نرخ یادگیری ۰/۰۰۳، تابع فعال‌سازی relu در ۴۰۰ تکرار توانست بهترین نتیجه را بر روی مجموعه داده Omniglot خواهد داشت که دقتی در حدود ۰/۹۳ خواهد داشت. مدل CNN حاصل که توسط الگوریتم پیشنهادی تولید شده است، پس از آموزش برای ۳۰۰ دوره، بر روی مجموعه داده‌ای با ۲۰ کلاس که در هر کلاس ۵ داده وجود دارد (20 way-5 shot)، دقتی در حدود ۹۳٪ بر روی مجموعه داده آزمایشی دارد که در شکل ۵ قابل مشاهده است.



شکل (۵): دقت حاصل از مدل پیشنهادی بر روی مجموعه داده

Omniglot

پس از اینکه مدل بهینه توسط الگوریتم پیشنهاد شد حال بایستی این معماری پیشنهادی را با معماری اصلی در شبکه‌های نمونه اولیه جایگزین کرده و شبکه را مجدداً آموزش داده و نتایج را مورد بررسی قرار دهیم. از آنجاکه مدل پیشنهادی توسط الگوریتم فقط به صورت 20 way-5 shot مورد بررسی قرار گرفته است لذا در شبکه‌های نمونه اولیه هم فقط به همین صورت مورد بررسی قرار داده شده است و از روش 1 shot چشم‌پوشی شد.

جدول ۵: دقت طبقه‌بندی یادگیری شات محدود با استفاده از

معماری پیشنهادی بر روی مجموعه داده Omniglot

مدل	معیار فاصله	دقت 20way-5 shot
آمار عصبی [23]	کسینوسی	۹۸٪/۱
MAML [13]	-	۹۸٪/۹

<sup>1</sup> Loss

ببخشد. همچنین به دلیل استفاده از معکوس ماتریس کواریانس داده‌ها در فاصله ماهالانویس سربار محاسباتی زیادی به شبکه متحمل می‌شود که با توجه به بهبود نه‌چندان چشم‌گیر در عملکرد شبکه، لذا استفاده از آن چندان به‌صرفه نخواهد بود.

## References

- [1] M. A. Turing, Computing machinery and intelligenc. *Mind* 59, 236, 433–433, 1950.
- [2] J. Deng, W. Dong, R. Socher, L.J. Li, K. Li and L. Fei-Fei. ImageNet, A large-scale hierarchical image database. *Computer Vision and Pattern Recognition*. 248–255, 2009.
- [3] A.Krizhevsky, I. Sutskever, and G. E. Hinton. ImageNet classification with deep convolutional neural networks, *Neural Information Processing Systems*, 1097–1105, 2012.
- [4] M. Mohri, A. Rostamizadeh, and A. Talwalkar. *Foundations of machine learning*, MIT Press, 2018.
- [5] S.Kadam, V.Vaidya, Review and Analysis of Zero, One and Few Shot Learning Approaches, *Intelligent Systems Design and Applications*, 100-112, 2018.
- [6] S. Hochreiter and J. Schmidhuber, Long short-term memory, *Neural Computation*, 1735–1780, 1997.
- [7] O. Vinyals, C. Blundell, T. Lillicrap, D. Wierstra, et al. Matching networks for one shot learning. *In Advances in Neural Information Processing Systems*. 3630–3638, 2016.
- [8] C. Finn, P. Abbeel, and S. Levine. Model-agnostic meta-learning for fast adaptation of deep networks. *In International Conference on Machine Learning*. 1126–1135, 2017.
- [9] Aurélien Bellet, Amaury Habrard, and Marc Sebban. A survey on metric learning for feature vectors and structured data, 2013.
- [10] Brian Kulis. Metric learning: A survey. *Foundations and Trends in Machine Learning*, 5(4):287–364, 2012.
- [11] Jacob Goldberger, Geoffrey E. Hinton, Sam T. Roweis, and Ruslan Salakhutdinov. Neighbourhood components analysis. *In Advances in Neural Information Processing Systems*, pages 513–520, 2004.
- [12] J. Snell, K. Swersky, and R. S. Zemel. Prototypical networks for few-shot learning. *In Advances in Neural Information Processing Systems*. 4077–4087, 2017.
- [13] Chelsea Finn, Pieter Abbeel, Sergey Levine; “Model-agnostic meta-learning for fast adaptation

## ۶- نتیجه‌گیری

به‌طور کلی هدف از این پژوهش ترکیب روش‌های یادگیری متریک و فرا یادگیری با یکدیگر و بررسی عملکرد این روش ترکیبی بر روی مجموعه داده‌های مختلف بود. برای این منظور رویکرد شبکه‌های نمونه اولیه به‌عنوان روش مبنا در نظر گرفته شد که در واقع یکی از پرکاربردترین روش‌ها برای انجام این کار است. سپس سعی شد هر دو بخش متریک و اپیزودیک (فرا یادگیری) این شبکه را به‌طور اصولی و علمی مورد بازبینی و تغییر قرار داده شود تا به نتایج مطلوب‌تری دست‌یافت.

در ادامه سعی شد تا با استفاده از دو رویکرد پیشنهادی، یعنی تغییر معیار فاصله و استفاده از الگوریتم ژنتیک در بهبود ساختار شبکه عصبی کانولوشنی شبکه نمونه اولیه، عملکرد این شبکه را بهبود ببخشیم.

در رابطه با رویکرد اول، نتایج به‌دست‌آمده نشان می‌دهد که این روش نتوانسته به‌طور چشمگیری دقت طبقه‌بندی شبکه را بهبود ببخشد. همچنین به دلیل استفاده از معکوس ماتریس کواریانس داده‌ها در فاصله ماهالانویس سربار محاسباتی زیادی به شبکه متحمل می‌شود که با توجه به بهبود نه‌چندان چشم‌گیر در عملکرد شبکه، لذا استفاده از آن چندان به‌صرفه نخواهد بود.

به‌طور کلی هدف از این پژوهش ترکیب روش‌های یادگیری متریک و فرا یادگیری با یکدیگر و بررسی عملکرد این روش ترکیبی بر روی مجموعه داده‌های مختلف بود. برای این منظور رویکرد شبکه‌های نمونه اولیه به‌عنوان روش مبنا در نظر گرفته شد که در واقع یکی از پرکاربردترین روش‌ها برای انجام این کار است. سپس سعی شد هر دو بخش متریک و اپیزودیک (فرا یادگیری) این شبکه را به‌طور اصولی و علمی مورد بازبینی و تغییر قرار داده شود تا به نتایج مطلوب‌تری دست‌یافت.

در ادامه سعی شد تا با استفاده از دو رویکرد پیشنهادی، یعنی تغییر معیار فاصله و استفاده از الگوریتم ژنتیک در بهبود ساختار شبکه عصبی کانولوشنی شبکه نمونه اولیه، عملکرد این شبکه را بهبود ببخشیم.

در رابطه با رویکرد اول، نتایج به‌دست‌آمده نشان می‌دهد که این روش نتوانسته به‌طور چشمگیری دقت طبقه‌بندی شبکه را بهبود



- of deep networks.”, Proceedings of the 34th International Conference on Machine Learning - Volume 70, Pages 1126-1135, 2017.
- [14] Kwonjoon Lee, Subhransu Maji, Avinash Ravichandran, Stefano Soatto; “Meta-Learning with Differentiable Convex Optimization.”, The IEEE Conference on Computer Vision and Pattern Recognition, 2019.
- [15] Kelvin Guu, Tatsunori B. Hashimoto, Yonatan Oren and Percy Liang; “Generating Sentences by Editing Prototypes.”, Transactions of the Association for Computational Linguistics, Volume 6, p.437-450, 2018.
- [16] Eli Schwartz, Leonid Karlinsky, Rogerio Feris, Raja Giryes, Alex M. Bronstein; “Baby steps towards few-shot learning with multiple semantics.”, arXiv:1906.01905v1 [cs.CV], 2019.
- [17] Arindam Banerjee, Srujana Merugu, Inderjit S Dhillon, and Joydeep Ghosh. Clustering with bregman divergences. *Journal of Machine Learning Research*, 6(Oct):1705–1749, 2005.
- [18] D. Goldberg and J. Holland, Genetic algorithms and machine learning, *Machine Learning*, vol. 3, 95-99, 1988.
- [19] Oriol Vinyals, Charles Blundell, Tim Lillicrap, Daan Wierstra, et al. Matching networks for one shot learning. In *Advances in Neural Information Processing Systems*, pages 3630–3638, 2016.
- [20] Sachin Ravi and Hugo Larochelle. Optimization as a model for few-shot learning. *International Conference on Learning Representations*, 2017.
- [21] Christian Szegedy, Wei Liu, Yangqing Jia, Pierre Sermanet, Scott Reed, Dragomir Anguelov, Dumitru Erhan, Vincent Vanhoucke, and Andrew Rabinovich. Going deeper with convolutions. In *IEEE Computer Vision and Pattern Recognition*, pages 1–9, 2015.
- [22] Chelsea Finn, Pieter Abbeel, and Sergey Levine. Model-agnostic meta-learning for fast adaptation of deep networks. *International Conference on Machine Learning*, 2017.
- [23] Harrison Edwards and Amos Storkey. Towards a neural statistician. *International Conference on Learning Representations*, 2017.
- [24] L. van d. Maaten and G. Hinton, Visualizing data using t-sne, *Journal of Machine Learning Research*, 2579–2605, 2008.
- [25] A. Krizhevsky, Learning multiple layers of features from tiny images, Technical report, 2009.

## Integration of few-shot learning methods to improve image classification performance with small data sets

Ali Bashiri, Ali Mohammad Latif\*

<sup>1</sup>Computer Engineering Department, Yazd University, Yazd, Iran

### Article Information

#### Original Research Paper

#### Received:

2022 January 22

#### Accepted:

2022 October 02

#### Keywords:

Classification, few-shot learning, meta-learning, metric learning

#### Corresponding Author\*:

alatif@yazd.ac.ir

### Abstract

Despite the significant advancement of artificial intelligence methods in recent years, there is still a need for a lot of data to learn these methods. To meet this need, a new machine learning model called Few-shot learning has been proposed. One of the methods in this field is the prototypical networks approach, which is actually a combination of metric learning and meta-learning methods. In these networks, the classifier tries to generalize to these classes according to only a small number of samples of each new class. In this study, an attempt was made to propose a modified form of the prototype networks to solve the finite shot classification problem. Initially, in order to improve the performance of the prototype networks, instead of the Euclidean distance, the Mahalanobis distance was used to measure the distance between the samples. This improved the performance of these networks in classifying omniglot and miniImageNet images so that the proposed network was able to achieve 99.1% and 68.5% accuracy on these two datasets, respectively. The next section introduces a general approach that can automatically improve the architecture of convolutional neural networks using a genetic algorithm. In this research, this approach has been used specifically on omniglot datasets with the proposed primary architecture in prototype networks. Finally, by using this approach and replacing the proposed architecture with the main architecture of the prototype network, the network accuracy was improved and was able to achieve 99.5% accuracy.



10.22034/ABMIR.2022.2812:

E-ISSN: [2821-2037](https://doi.org/10.22034/ABMIR.2022.2812) /© 2023. Published by Yazd University This is an open access article under the CC BY 4.0 License (<https://creativecommons.org/licenses/by/4.0/>).

