

## ارزیابی عملکرد ماشین یادگیر نهایی در قطعه‌بندی تصاویر

محمود امین‌طوسی\*، استادیار، سکینه خورسندی، دانشجوی کارشناسی ارشد، مهدی زعفرانیه، استادیار دانشکده ریاضی و علوم کامپیوتر. دانشگاه حکیم سبزواری. سبزواری. ایران.  
m.amintoosi@hsu.ac.ir, khoorsandi.sakineh93@gmail.com, mehdi.zaferanieh@gmail.com

چکیده - ماشین یادگیر نهایی (ELM) از جمله جدیدترین ابزارهای یادگیری ماشین است که استفاده‌های روزافزونی در کاربردهای متعدد حوزه یادگیری ماشین پیدا کرده است. مزیت اصلی این روش نسبت به شبکه عصبی پرسپترون چند لایه (MLP)، کم بودن زمان آموزش آن نسبت به این شبکه عصبی معروف است. در بسیاری از مقالات اصلی ماشین یادگیر نهایی، دقت این سیستم بیشتر از MLP گزارش شده است. در این مقاله برای ارزیابی این ادعا، دو نسخه از ماشین یادگیر نهایی در کاربرد قطعه‌بندی تصاویر با شبکه عصبی پرسپترون چند لایه مورد مقایسه قرار گرفته‌اند. آزمایشات مختلف بر روی پایگاه داده BSD و با در نظر گرفتن تعداد نورون‌های متفاوت در لایه پنهان انجام شده است. نتایج آزمایشات با معیارهای مختلف حاکی از آن بوده است که در حالت میانگین، خطای طبقه‌بندی شبکه عصبی پرسپترون چند لایه از ماشین یادگیر نهایی کمتر است؛ با این حال آموزش ماشین یادگیر نهایی بسیار سریعتر از MLP می‌باشد. با تعداد ۱۰۰ نورون در لایه پنهان، MLP، ۲.۵ درصد «صحت» بیشتری از ELM دارد، در حالیکه زمان آموزش MLP، ۱۵۵ برابر زمان آموزش ELM است. کلید واژه‌ها - قطعه‌بندی تصویر، ماشین یادگیر نهایی، ماشین یادگیر نهایی دو لایه پنهان، پرسپترون چند لایه

### ۱- مقدمه

شناسایی حرکات انسان [۴] سرعت و دقت یادگیری بسیار خوبی برای آن گزارش شده است. با توجه به بازدهی قابل توجه، سادگی و عملکرد تعمیم یافته ELM در حوزه‌هایی همچون مهندسی پزشکی، بینایی ماشین، شناسایی سیستم و کنترل رباتیک به کار گرفته شده است [۵].

مؤلفین، الگوریتم ELM را بر روی داده‌های مصنوعی (دو دسته داده که همپوشانی ندارند) اجرا کرده و به صحت صددرصد رسیده‌اند اما این شرایط ایده‌آل برای داده‌های واقعی عموماً برقرار نیستند. همچنین الگوریتم ELM و MLP بر روی مجموعه داده آیریس (گل‌های زنبق) انجام شد. در این مجموعه دادگان با تعداد ۱۰ نورون در لایه پنهان ELM عملکرد بهتری از MLP داشت. در حوزه قطعه‌بندی تصویر، کاربردی از آن در شناسایی گلبول‌های سفید خون [۶] به انجام رسیده و کارایی آن در مقایسه با ماشین بردار پشتیبان نشان داده شده است. تا آنجا که نگارندگان مطلع هستند تحقیق مدونی بر روی قابلیت ELM در حوزه قطعه‌بندی تصویر انجام نشده است. هدف این نوشتار بررسی این شیوه در قطعه‌بندی تصاویر، بر روی یکی از مجموعه دادگان مشهور در این حوزه و مقایسه آن با MLP می‌باشد. نسخه‌های متفاوتی از ELM وجود دارد. در این تحقیق نسخه پایه ELM و نسخه با دو لایه پنهان آن<sup>۵</sup> (TELM) برای مقایسه با MLP انتخاب شده‌اند. نتایج آزمایشات ما نشان می‌دهد که در حالت کلی دقت MLP نسبت به

شبکه‌های عصبی مصنوعی به عنوان یک راه حل مؤثر در طبقه بندی داده‌ها، بازشناسی الگو و تقریب توابع مورد استفاده قرار گرفته و می‌گیرد. مهم‌ترین مزیت در این شبکه‌ها، قابلیت یادگیری است [۱]. یکی از مرسوم‌ترین انواع شبکه‌های عصبی، شبکه پرسپترون چندلایه<sup>۱</sup> (MLP) است. روش پس انتشار خطا<sup>۲</sup> روش شناخته شده آموزش در این شبکه است. در این شیوه که یک متد گرادینت مرتبه اول برای بهینه‌سازی پارامتر است، گرادینت تابع هزینه با توجه به تمام وزن‌ها در شبکه محاسبه شده و وزن‌ها برای به حداقل رساندن تابع هزینه به روزرسانی می‌شوند. روش پس انتشار خطا از دو مشکل همگرایی آهسته و توقف در بهینه‌های محلی رنج می‌برد. افزایش سرعت و دقت الگوریتم آموزش شبکه عصبی از موضوعاتی است که تحقیقات متعددی را به خود معطوف نموده است.

هوانگ و همکاران [۲] الگوریتم یادگیری ساده‌ای بنام ماشین یادگیر نهایی<sup>۳</sup> (ELM<sup>۴</sup>) ارائه داده‌اند که سرعت یادگیری آن می‌تواند هزاران مرتبه سریعتر از الگوریتم‌های یادگیری همچون پس انتشار خطا باشد. از ELM برای کارهای طبقه‌بندی، رگرسیون، خوشه‌بندی و انتخاب ویژگی استفاده شده است. همچنین در کاربردهای مختلفی همچون طبقه‌بندی چهره [۳] و

<sup>۱</sup> Multi-Layer Perceptron

<sup>۲</sup> Error Back Propagation

<sup>۳</sup> برخی محققین آنرا ماشین یادگیر فرین ترجمه کرده‌اند.

<sup>۴</sup> Extreme Learning Machine

<sup>۵</sup> Two-hidden-layer Extreme Learning Machine (TELM)

که  $m$  تعداد نورون‌های لایه پنهان،  $\beta = [\beta_1, \beta_2, \dots, \beta_m]^T$  بردار وزن‌های خروجی و  $\mathbf{h}(\mathbf{x}) = [h_1(\mathbf{x}), \dots, h_m(\mathbf{x})]$  خروجی لایه پنهان با توجه به ورودی  $\mathbf{x}$  است.  $\mathbf{h}(\mathbf{x})$  در واقع داده را از فضای ورودی به فضای ویژگی ELM ( $\mathbf{H}$ ) نگاشت می‌کند، بنابراین  $\mathbf{h}(\mathbf{x})$  یک نگاشت ویژگی است. توابع خروجی متفاوتی برای نورون‌های پنهان وجود دارد. تابع بکار برده شده در این مقاله تابع سیگموئید  $g(\mathbf{x}, \theta) = \frac{1}{1 + \exp(-(\mathbf{w}^T \mathbf{x} + b))}$  است که  $\theta = \{\mathbf{w}, b\}$  پارامترهای تابع،  $g$  یک تابع غیر ثابت قطعه به قطعه پیوسته کراندار،  $\mathbf{w}$  بردار وزن ورودی با ابعاد  $(d \times 1)$  و  $b$  بایاس نورون‌های پنهان هستند. ماتریس خروجی لایه پنهان  $(\mathbf{H}_{n \times m})$  به صورت زیر تعریف می‌شود:

$$\mathbf{H} = \begin{bmatrix} g(\mathbf{w}_1^T \mathbf{x}_1 + b_1) & \dots & g(\mathbf{w}_m^T \mathbf{x}_1 + b_m) \\ \vdots & \vdots & \vdots \\ g(\mathbf{w}_1^T \mathbf{x}_n + b_1) & \dots & g(\mathbf{w}_m^T \mathbf{x}_n + b_m) \end{bmatrix} \quad (2)$$

ماتریس وزن‌های خروجی با روش معکوس تعمیم یافته به صورت  $\beta = \mathbf{H}^\dagger \mathbf{T}$  به دست می‌آید که  $\mathbf{H}^\dagger$  معکوس تعمیم یافته مور-پنروز ماتریس  $\mathbf{H}$  است. زمانیکه  $\mathbf{H}^T \mathbf{H}$  نامنفرد است  $\mathbf{H}^\dagger$  به صورت  $\mathbf{H}^\dagger = (\mathbf{H}^T \mathbf{H})^{-1} \mathbf{H}^T$  و زمانیکه  $\mathbf{H} \mathbf{H}^T$  نامنفرد است  $\mathbf{H}^\dagger$  به صورت  $\mathbf{H}^\dagger = \mathbf{H}^T (\mathbf{H} \mathbf{H}^T)^{-1}$  محاسبه می‌شود.

## ماشین یادگیر نهایی دو لایه

ماشین یادگیر نهایی دولایه (TELM) یکی از توسعه‌های ELM است که یک لایه پنهان به آن اضافه نموده و شیوه‌ای جدید را برای محاسبه پارامترهای لایه پنهان دوم بکار می‌گیرد. با توجه به مجموعه‌ای از  $n$  نمونه مجزای برچسب‌دار دلخواه  $\{(\mathbf{x}_i, \mathbf{t}_i) | \mathbf{x}_i \in \mathbb{R}^d, \mathbf{t}_i \in \mathbb{R}^k, i = 1, 2, \dots, n\}$  از دولایه پنهان دارای  $m$  نورون) و تابع خروجی لایه پنهان  $g(x)$  ابتدا وزن‌های ورودی و بایاس اولین لایه پنهان به طور تصادفی مقداردهی اولیه می‌شوند و خروجی مورد انتظار لایه پنهان دوم طبق رابطه  $\mathbf{H}_1 = \mathbf{T} \beta^\dagger$  محاسبه می‌شود. سپس ماتریس پنهان دوم هستند طبق رابطه  $\mathbf{W}_{HE} = [\mathbf{B}_1 \quad \mathbf{W}_H]$  که  $\mathbf{B}_1$  بایاس و  $\mathbf{W}_H$  وزن ورودی لایه پنهان دوم هستند طبق رابطه  $\mathbf{W}_{HE} = g^{-1}(\mathbf{H}_1^T) (\mathbf{H}_E^T)^\dagger$  به دست می‌آید که  $\mathbf{H}_E = [\mathbf{1} \quad \mathbf{H}]$  و "1" برداری با اندازه  $n \times 1$  و عناصر اسکالر 1 است،  $g^{-1}(\mathbf{x})$  معکوس تابع خروجی  $g(\mathbf{x})$  را نشان می‌دهد. خروجی واقعی لایه پنهان دوم با  $\mathbf{H}_1^T = g(\mathbf{W}_{HE} \mathbf{H}_E^T)$  بین لایه پنهان دوم و لایه خروجی با رابطه  $\beta_{new}^\dagger = \mathbf{H}_1^\dagger \mathbf{T}$  به دست می‌آید و خروجی TELM به صورت  $\mathbf{Y} = \mathbf{H}_2 \beta_{new}$  حاصل می‌شود [7].

هر دو نسخه ELM بیشتر است اما زمان آموزش بیشتری را نیاز دارد. در ادامه، در بخش 2 مروری بر پرسپترون چند لایه، ماشین یادگیر نهایی و حالت دو لایه آن خواهیم داشت. در بخش 3 نتایج آزمایشات انجام شده خواهد آمد. بخش آخر نیز به نتیجه‌گیری اختصاص یافته است.

## 2- ماشین یادگیر نهایی

از آنجا که در این نوشتار ماشین یادگیر نهایی را با شبکه عصبی چند لایه مورد مقایسه قرار خواهیم داد، ابتدا به صورت مختصر مروری خواهیم داشت بر این شبکه عصبی و سپس ماشین یادگیر نهایی را ملاحظه خواهیم کرد.

### پرسپترون چند لایه

ساختار شبکه عصبی MLP به صورت چند لایه است که از یک لایه ورودی، یک لایه خروجی و حداقل یک لایه میانی تشکیل شده است. در آموزش شبکه‌های عصبی پرسپترون چند لایه از "قاعده پس انتشار خطا" استفاده می‌شود. در MLP نمونه‌ای به شبکه عرضه می‌شود و خروجی آن محاسبه می‌گردد، با مقایسه خروجی شبکه و مقدار واقعی، ضرایب وزنی شبکه به نحوی تغییر می‌یابد که در دفعات بعد خروجی درست‌تری حاصل شود. در الگوریتم پس انتشار خطا، مقادیر خطا ابتدا در واحدهای لایه خروجی محاسبه شوند و آنگاه به لایه‌های قبلی شبکه برای تغییر ضرایب وزنی واحدهای پیشین پس رانده شوند. در یک روند تکراری، تنظیم وزن‌ها به ازای هر نمونه آموزشی انجام می‌شود.

### ماشین یادگیر نهایی

ماشین یادگیر نهایی برای آموزش شبکه‌های عصبی پیشخور تک لایه پنهان با اجتناب از یک روش آموزش تکراری وقت‌گیر و هدف کاهش زمان آموزش و بهبود عملکرد تعمیم پیشنهاد شده است که در آن فقط وزن‌های خروجی بین لایه پنهان و لایه خروجی با روش حداقل مربعات منظم قابل تنظیم‌اند و پارامترهای لایه پنهان، یعنی وزن‌های ورودی بین لایه ورودی و لایه پنهان و همچنین بایاس‌ها، همزمان به طور تصادفی تولید می‌شوند و در طول فاز آموزش ثابت می‌مانند [5].

برای مجموعه‌ای از  $n$  نمونه مجزای برچسب‌دار دلخواه  $\{(\mathbf{x}_i, \mathbf{t}_i) | \mathbf{x}_i \in \mathbb{R}^d, \mathbf{t}_i \in \mathbb{R}^k, i = 1, 2, \dots, n\}$  تعداد نورون‌های لایه ورودی و  $k$  تعداد نورون‌های لایه خروجی است، تابع خروجی ELM (با فرض یک نورون خروجی) و به ازای هر نمونه آموزشی ورودی  $(\mathbf{x})$  همچون زیر فرموله‌بندی می‌شود:

$$f_m(\mathbf{x}) = \sum_{i=1}^m \beta_i h_i(x) = \mathbf{h}(\mathbf{x}) \beta \quad (1)$$

### ۳- آزمایشات و نتایج تجربی

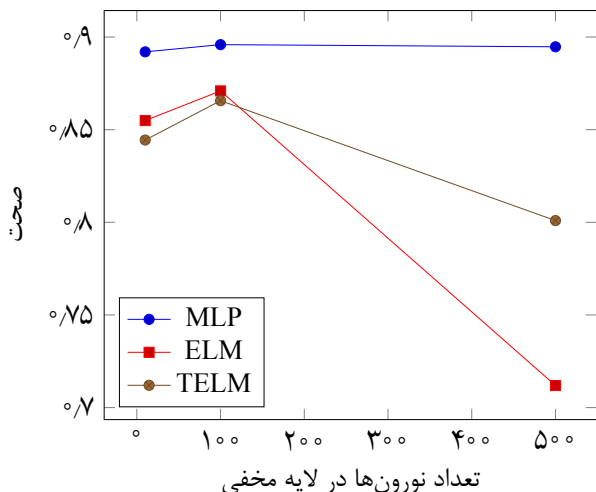
در این بخش عملکرد الگوریتم‌های MLP، ELM و TELM در کاربرد قطعه‌بندی تصاویر مورد مقایسه قرار خواهد گرفت. به این منظور از مجموعه دادگان BSD<sup>۶</sup> استفاده شده است. اکثر تصاویر این مجموعه با بیشتر از دو برجسب قطعه‌بندی شده‌اند اما از آنجا که در این مقاله فقط حالت دو کلاسی مورد بررسی قرار گرفته است، لذا از بین تصاویر موجود فقط ۱۵ تصویر که قطعه‌بندی دو کلاسی داشتند انتخاب شده‌اند. ستون دوم با عنوان «تصویر اصلی» در جدول ۱ - که شامل نتایج بصری است - این تصاویر را نشان می‌دهند.

برای ایجاد داده‌های آموزشی از روش تعاملی<sup>۷</sup> استفاده شده است. در هر تصویر علامت‌هایی برای مشخص کردن قسمت‌هایی از نواحی زمینه و پیش زمینه توسط کاربر مشخص می‌شود پیکسل‌های آموزشی از ناحیه زمینه با رنگ سیاه و پیکسل‌های آموزشی از ناحیه پیش زمینه با رنگ سفید مشخص شده‌اند. در این تحقیق این نواحی با چند خط سیاه و سفید روی تصویر مشخص شده‌اند که این نواحی به عنوان داده‌های آموزشی به شبکه‌های مورد بحث داده شده است.


ستون سوم از جدول مقایسات بصری نمایش دهنده «نقاط آموزشی» در تصویر مربوطه است. تصاویر اصلی دارای ابعاد  $321 \times 481$  هستند و این تصاویر هم‌اندازه با تصاویر اصلی هستند. به صورت میانگین حدود ۳ درصد پیکسل‌ها به عنوان داده آموزشی در نظر گرفته شده‌اند. تصاویر موجود در این پایگاه داده توسط افراد مختلف قطعه‌بندی شده و به عنوان داده‌های درست در تحقیقات مورد استفاده قرار گرفته‌اند و نتایجشان تحت عنوان «جواب واقعی»<sup>۸</sup> در ستون چهارم از جدول ۱ آورده شده است.

به منظور حفظ هماهنگی در مقایسات، هر ۳ شبکه با شرایط یکسان (تعداد نورون‌های ورودی، پنهان و خروجی یکسان) مورد مقایسه قرار گرفته‌اند. همه مقایسات در محیط محاسباتی متلب R2012a بر روی سیستم با واحد پردازش مرکزی Intel(R) Core(TM) i3-4010U CPU 1.70GHz و حافظه داخلی ۴GB اجرا شده‌اند. متناظر با هر پیکسل، مقادیر شدت رنگ RGB تمامی پیکسل‌ها در یک همسایگی  $3 \times 3$  آن، واریانس همسایگی و گرادیان‌های افقی و عمودی آن به عنوان ویژگی‌های هر پیکسل مورد استفاده قرار گرفته است.

آزمایشات روی شبکه‌های عصبی مورد بحث با تعداد ۱۰، ۱۰۰ و ۵۰۰ نورون در لایه پنهان انجام شده است. به منظور مقایسه نتایج از مقایسات بصری و کمی استفاده شده است. برای هر یک از



شکل ۱: مقایسه میانگین «صحت» روش‌های مختلف در تعداد نورون‌های لایه پنهان مشخص شده.



شکل ۲: مقایسه میانگین «حساسیت» روش‌های مختلف در تعداد نورون‌های لایه پنهان مشخص شده.

۱۵ تصاویر الگوریتم‌های MLP، ELM و TELM ۱۰ مرتبه اجرا شده‌اند و تصویر متناظر با اجرای دارای بیشترین «صحت» برای تعداد ۱۰۰ نورون پنهان در جدول ۱ آمده است.<sup>۹</sup> از معیارهای صحت (Accuracy)، حساسیت (Sensitivity)، نرخ مثبت کاذب (False Positive Rate) و نرخ منفی کاذب (False Negative Rate) به منظور ارزیابی دقت روش‌ها استفاده شده و زمان آموزش (Training Time) آن‌ها نیز مورد سنجش قرار گرفته است. به منظور مقایسه بهتر، میانگین مقادیر هر یک از الگوریتم‌های MLP، ELM و TELM بر روی تمام ۱۵ تصاویر براساس تعداد نورون‌های مختلف در لایه پنهان در شکل‌های ۱، ۲، ۳، ۴ و ۵ آمده است. مقادیر ذکر شده در نتایج، میانگین ۱۰ مرتبه اجراست.

<sup>۹</sup> به ازای تعداد ۱۰ و ۵۰۰ نورون در لایه پنهان نیز نتایج تولید شده‌اند که به جهت اختصار در اینجا نیامده است.


<sup>۶</sup> <https://www2.eecs.berkeley.edu/Research/Projects/CS/vision/grouping/resources.html>

<sup>۷</sup> interactive


<sup>۸</sup> Ground Truth

جدول ۱: مقایسه خروجی قطعه‌بندی روش‌های مختلف با ۱۰۰ نورون در لایه مخفی. خطوط سفید و سیاه در تصاویر ستون دوم نمایش‌دهنده نقاط آموزشی هستند. ستون سوم، قطعه‌بندی واقعی (جواب مرجع) و سه ستون آخر خروجی سه شیوه موردنظر را نشان می‌دهند.

ردیف	تصویر اصلی	نقاط آموزشی	جواب واقعی	MLP	ELM	TELM
۱						
۲						
۳						
۴						
۵						
۶						
۷						
۸						
۹						
۱۰						
۱۱						
۱۲						
۱۳						
۱۴						
۱۵						



شکل ۴: مقایسه میانگین «نرخ منفی کاذب» روش‌های مختلف در تعداد نورون‌های لایه پنهان مشخص شده.



شکل ۳: مقایسه میانگین «نرخ مثبت کاذب» روش‌های مختلف در تعداد نورون‌های لایه پنهان مشخص شده.

### ۱-۳- تجزیه و تحلیل نتایج

نتایج بصری حکایت از آن دارند که در حالت کلی، هر سه شبکه با ۱۰۰ نورون در لایه پنهان، بهترین خروجی‌ها را داشته‌اند. برای مقایسه دقیق‌تر مقادیر معیارهای کمی را مورد مذاقه قرار می‌دهیم.

#### معیار صحت

با ملاحظه نمودار ۱ که میانگین همه را نشان می‌دهد مشخص است که با افزایش تعداد نورون‌های لایه پنهان، کارایی شبکه عصبی MLP به میزان کمی بیشتر شده است. اما در خصوص ELM و TELM نمی‌توان به صورت قاطع نظر داد. با افزایش تعداد نورون‌های لایه پنهان از ۱۰ به ۱۰۰، کارایی هر دو روش بهتر شده و تا حدودی زیادی به کارایی MLP نزدیک شده است، اما با افزایش تعداد این نورون‌ها به ۵۰۰ نورون، کارایی هر دو به شدت افت کرده است. نکته اصلی که در ادامه خواهیم دید آن است که افزایش کارایی MLP در حالت ۱۰۰ نورون در لایه پنهان به اندازه دو نیم درصد بیشتر از ELM به بهای ۱۵۵ برابر شدن زمان آموزش بدست آمده است.

#### معیار حساسیت

نمودار ۲ نشان می‌دهد که افزایش تعداد نورون‌های لایه پنهان کارایی شبکه عصبی MLP را افزایش داده است اما ELM و TELM بهترین کارایی را در حالت ۱۰۰ نورون در لایه پنهان داشته‌اند. با این تعداد نورون در لایه مخفی هر دو نسخه ELM کارایی بیشتری از MLP داشته‌اند.

#### معیار نرخ مثبت کاذب

باید دقت داشت که هر چه مقدار این معیار کمتر باشد بهتر است. با ملاحظه نمودار ۳ مشخص است که افزایش تعداد نورون‌های لایه پنهان معیار «نرخ مثبت کاذب» شبکه ELM و TELM را افزایش داده (کارایی کمتر) در حالیکه شبکه عصبی MLP با افزایش تعداد نورون‌های لایه پنهان، کارایی بیشتری داشته است. در همه حالات MLP خطای کمتری نسبت به هر دو روش ELM داشته است.

#### معیار نرخ منفی کاذب

این معیار نیز هر چه مقدار آن کمتر باشد بهتر است. با ملاحظه نمودار ۴ مشخص می‌شود که در حالت‌های ۱۰ نورون و ۵۰۰ نورون در لایه پنهان، شبکه عصبی MLP خطای کمتری داشته و افزایش تعداد نورون‌های لایه پنهان «نرخ منفی کاذب» شبکه عصبی MLP را کاهش داده است ولی برای دو شیوه دیگر، بهترین کارایی در حالت ۱۰۰ نورون در لایه پنهان بوده است. بهترین کارایی متعلق به TELM بوده است.

#### معیار زمان آموزش

از نمودار ۵ که میانگین همه را نشان می‌دهد مشخص است که افزایش تعداد نورون‌های لایه پنهان، زمان آموزش شبکه عصبی MLP را به میزان زیادی افزایش می‌دهد، در حالیکه زمان آموزش ELM و TELM تقریباً وابسته به تعداد نورون‌ها لایه پنهان نیست و نسبتاً ثابت مانده است.

**تعداد نورون‌های لایه پنهان**، در این پژوهش تعداد نورون‌های لایه پنهان ELM سه مقدار خاص انتخاب و آزمایشات بر روی آنها انجام شده بود. پیدا کردن مقدر بهینه این تعداد نورون‌ها می‌تواند موضوع تحقیق آتی باشد.


**تاثیر تعداد نمونه‌های آموزشی در عملکرد شبکه**، در کار حاضر حدود ۳ درصد تصویر به عنوان داده آموزشی در نظر گرفته شده است. تاثیر تغییر حجم داده‌های آموزشی در عملکرد شبکه‌ها در این نوشتار مورد بررسی قرار نگرفته است.

**مجموعه آموزشی مجزا**، در این تحقیق داده‌های آموزشی از خود تصویر اخذ شده‌اند، این رویه در روش‌های تعاملی مرسوم است، اما می‌توان تولید مجموعه آموزشی با روش‌ها یا از تصاویر دیگر را نیز مورد توجه قرار داد.

**استفاده از تصاویر بیشتر**، در کار حاضر از برخی از تصاویر یک مجموعه دادگان استفاده شد. برای جامع‌تر بودن مبحث می‌توان پایگاه داده‌های دیگری را نیز استفاده کرد.

## مراجع

- [1] D. E. Rumelhart, G. E. Hinton, and R. J. Williams, "Learning representations by back-propagating errors," *Nature*, vol.323, no.Oct, pp.533-536+, 1986.
- [2] G.-B. Huang, Q.-Y. Zhu, and C. K. Siew, "Extreme learning machine: Theory and applications.," *Neurocomputing*, vol.70, no.1-3, pp.489-501, 2006.
- [3] A. A. Mohammed, R. Minhas, Q. M. Jonathan Wu, and M. A. Sid-Ahmed, "Human face recognition based on multidimensional pca and extreme learning machine.," *Pattern Recogn.*, vol.44, pp.2588-2597, Oct. 2011.
- [4] R. Minhas, A. Baradarani, S. Seifzadeh, and Q. M. Jonathan Wu, "Human action recognition using extreme learning machine based on visual vocabularies.," *Neurocomput.*, vol.73, pp.1906-1917, June 2010.
- [5] G. Huang, G.-B. Huang, S. Song, and K. You, "Trends in extreme learning machines: A review," *Neural Networks*, vol.61, pp.32-48, 2015.
- [6] C. Pan, D. S. Park, Y. Yang, and H. M. Yoo, "Leukocyte image segmentation by visual attention and extreme learning machine.," *Neural Comput. Appl.*, vol.21, pp.1217-1227, Sept. 2012.
- [7] B. Qu, B. F. Lang, J. J. Liang, A. K. Qin, and O. D. Crisalle, "Two-hidden-layer extreme learning machine for regression and classification.," *Neurocomputing*, vol.175, pp.826-834, 2016.



شکل ۵: مقایسه میانگین «زمان آموزش» روش‌های مختلف در تعداد نورون‌های لایه پنهان مشخص شده.

## ۴- نتیجه گیری و کارهای آتی

تاکنون مقایسه‌ای در خصوص عملکرد ELM در قطعه‌بندی تصویر و براساس پایگاه داده‌های مشهور صورت نگرفته است. در این مقاله دو نسخه مشهور ELM و شبکه عصبی MLP روی پایگاه داده BSD و در حالت دو کلاسی مورد مقایسه قرار گرفت. مقایسات با تعداد نورون‌های مختلف در لایه پنهان انواع شبکه‌های مورد بحث انجام پذیرفت. نتایج به صورت دیداری و همچنین بر اساس معیارهای «صحت»، «حساسیت»، «ترخ مثبت کاذب»، «ترخ منفی کاذب» و «زمان آموزش» مورد ارزیابی قرار گرفتند. بر اساس نتایج بدست آمده، در حالت ۱۰۰ نورون در لایه پنهان، هر سه شبکه کارایی نسبتاً خوبی داشتند. در این وضعیت، در حالیکه صحت MLP فقط حدود ۲۵٪ از ELM بیشتر است، اما زمان آموزش آن ۱۵۵ برابر زمان آموزش ELM است. وضعیت مشابهی در خصوص TELM برقرار است. لذا اگر در کاربرد مدنظر قطعه‌بندی، زمان آموزش از اهمیت بالایی برخوردار باشد و بتوان از مختصر کاهش دقت چشم‌پوشی نمود، ماشین یادگیر نهایی (ELM) انتخاب بهتری نسبت به MLP می‌باشد.

از دیگر نتایج این تحقیق بررسی ادعای سرعت زیاد ماشین یادگیر نهایی می‌باشد. در مرجع [۲] ذکر شده است که سرعت یادگیری ELM می‌تواند هزاران مرتبه سریعتر از الگوریتم‌های یادگیری شبکه پیشخور سنتی همچون پس انتشار خطا باشد، اما مطابق آزمایشات انجام شده در این تحقیق، حداقل برای مسئله قطعه‌بندی تصویر، چنین نتیجه‌ای حاصل نشد؛ سرعت یادگیری ELM با تعداد ۱۰ نورون پنهان، ۱۰۰ نورون پنهان و ۵۰۰ نورون پنهان به ترتیب برابر ۴۰۲، ۱۵۵ و ۵۰ مرتبه سریعتر از الگوریتم پس انتشار خطا در MLP می‌باشد.

موارد زیر می‌تواند موضوعات تحقیقات بیشتر در این زمینه باشد: