

یک ساختار یکپارچه برای اتوانکدر چندلایه به منظور آموزش ماشین یادگیری سریع عمیق

سید حمیدرضا موسوی^۱، مهدی افتخاری^۲، بهنام قوامی^۳^۱کارشناسی ارشد هوش مصنوعی، دانشگاه شهید باهنر کرمان.^۲دانشیار بخش مهندسی کامپیوتر، دانشگاه شهید باهنر کرمان، m.eftkhari@uk.ac.ir^۳دانشیار بخش مهندسی کامپیوتر، دانشگاه شهید باهنر کرمان.

چکیده

اخیرا تعداد زیادی الگوریتم بر پایه ی ماشین یادگیری سریع برای آموزش دادن ساختارهای شبکه های عصبی عمیق معرفی شده اند. اتوانکدر مبتنی بر ماشین یادگیری سریع یکی از این الگوریتم هاست که برای ایجاد ساختار چندلایه و تعیین پارامترهای هر لایه از مدل معرفی شده است. در الگوریتم آموزش اتوانکدر مبتنی بر یادگیری سریع، وزنهای در لایه اول به صورت تصادفی مقدار دهی می شوند که باعث ایجاد خطای بازسازی می شود. فرایند تکراری استفاده از این اتوانکدر ها منجر به پخش خطا در ساختار عمیق شده و منجر به کاهش کارایی کل مدل خواهد شد. در این مقاله یک اتوانکدر چندلایه برای تعیین پارامترهای یک شبکه عصبی عمیق ارائه شده است. همچنین یک الگوریتم نوین برای آموزش این مدل معرفی می شود که از پخش خطا جلوگیری می کند. به منظور افزایش کارایی مدل به جای مقداردهی تصادفی پارامترهای اولین از یک اتوانکدر تکرار شونده بهره می بریم که در یک فرایند تکراری پارامترهای اولین لایه را به بهترین حالت تعیین می کند. برای طبقه بندی داده ها به کمک ویژگی های استخراج شده، از یک ماشین یادگیری سریع تک لایه استفاده شده است. آزمایش ها برای طبقه بندی داده ها نشان می دهد که روش پیشنهادی میانگین دقت روی همه ی مجموعه داده ها را به ترتیب به میزان ۴٪، ۲۶٪، ۱۷٪ و ۳۱٪ نسبت به روشهای موجود بهبود داده است. برای نشان دادن کارایی اتوانکدر چندلایه از این مدل برای بازسازی تصاویر استفاده شده است و نتایج دیداری نشان دهنده ی کارایی بهتر روش پیشنهادی در بازسازی تصاویر می باشد.

کلیدواژه

ماشین یادگیری سریع، طبقه بندی، اتوانکدر، بازسازی تصاویر

مقدمه

چند لایه است. در این شبکه ها، ماتریس های تبدیل خطی مورد استفاده در روش های پیشین به تبدیل های غیر خطی تبدیل می شوند. این کار منجر به افزایش کارایی مدل روی داده های تست می شود. برای چندین دهه، برای طراحی یک سیستم یادگیری ماشین که قادر به تولید نمایش مناسبی از داده های خام باشد، تلاش قابل ملاحظه ای نیاز بود. در سال ۲۰۰۶، روش جدیدی برای استخراج خودکار ویژگی ها از داده های خام به کمک ماشین بلتزن محدود^۲ و اتوانکدر^۳ معرفی شد [۴]. این مدل ها برای آموزش یک شبکه عصبی سه لایه استفاده شده اند.

توانایی تعمیم دهی^۱ یک الگوریتم یادگیری ماشین وابسته به ویژگی های استخراج شده از مجموعه داده است. بنابراین مهندسی ویژگی ها برای نمایش یک ساختار برجسته از داده های خام بسیار حائز اهمیت است. به دلیل افزایش حجم پردازش برای داده های با ابعاد بالا، روش های کاهش بعد برای ایجاد نمایشی با ابعاد کمتر ایجاد شده اند [۱ و ۲ و ۳]. یکی از روش های پیشنهادی برای استخراج ویژگی های موثر از داده های خام، استفاده از شبکه های عصبی

^۳ Autoencoder^۱ Generalization^۲ Restricted Boltzmann machine


های خروجی به کمک کمینه کردن حداقل مربعات خطای تنظیم شده^{۱۲}، همچنان می تواند هر تابعی را با کمترین خطا تقریب بزند. علاوه بر این مسئله‌ی حداقل مربعات تنظیم شده‌ی خطا در ماشین یادگیری سریع، نسبت به حل مسئله‌ی برنامه ریزی غیر خطی در ماشین بردار پشتیبان و مشتق‌گیری‌های جزئی در روش پس‌انتشار خطا سریع‌تر حل می‌شود [۱۵ و ۱۶]. بنابراین ماشین یادگیری سریع منجر به افزایش قدرت تعمیم‌دهی و سرعت آموزش، نسبت به الگوریتم‌های ماشین بردار پشتیبان و پس‌انتشار خطا می‌شود. برای بهبود کارایی ماشین یادگیری سریع، گونه‌های مختلفی از آن ارائه شده است که از این جمله می‌توان به ماشین یادگیری سریع مبتنی بر رای‌گیری^{۱۳} [۱۷]، ماشین یادگیری سریع تنظیم شده^{۱۴} [۱۸]، ماشین یادگیری سریع مبتنی بر الگوریتم‌های فراابتکاری^{۱۵} [۱۹] و ماشین یادگیری سریع مبتنی بر تابع هسته^{۱۶} [۲۰] اشاره کرد. با وجود همه‌ی گونه‌های مختلف معرفی شده، یکی از ضعف‌های این مدل‌ها، ساختار تنک و تک لایه‌ی آن‌هاست که موجب کاهش کارایی آن‌ها نسبت به مدل‌های عمیق شده است. در سال ۲۰۱۳، یک ساختار عمیق مبتنی بر ماشین یادگیری سریع معرفی شد. پارامترهای هر لایه از این مدل با تکرار آموزش یک اتوانکدر در هر لایه تعیین می‌شوند [۲۱]. برای بهبود کارایی ماشین یادگیری سریع عمیق یک ساختار سلسله‌مراتبی برای یادگیری یک شبکه‌ی چند لایه ارائه شده است [۲۲]. این ساختار شامل دو فاز متفاوت است، در اولین فاز به کمک اتوانکدرهای متوالی، ویژگی‌های برجسته از داده‌های خام استخراج می‌شوند. در فاز دوم از یک ماشین یادگیری سریع ساده برای طبقه‌بندی استفاده شده است. در سایر روش‌ها الگوریتم یادگیری پارامترها براساس حل یک مسئله‌ی بهینه‌سازی بر اساس تابع تنظیم‌کننده‌ی نرم دو است. به منظور افزایش دقت طبقه‌بندی، با بهره‌گیری از یک ماشین یادگیری سریع دو لایه برای طبقه‌بندی داده‌ها، تعمیمی برای روش قبلی ارائه شده است [۲۳] به منظور جلوگیری از تصادفی بودن پارامترهای اولین لایه از اتوانکدر و با بهره‌گیری از توابع معکوس پذیر به عنوان تابع فعال‌سازی یک ساختار جدید برای اتوانکدرها معرفی شده است [۲۴]. این اتوانکدر در یک فرایند تکراری و با بهره

به منظور ایجاد ساختاری با تعداد لایه‌های بیشتر، دو نوع شبکه عصبی عمیق به کمک ماشین بلتزن محدود ایجاد شده است که شبکه‌ی باور عمیق^۴ [۴] و ماشین بلتزن عمیق [۵] نام دارند. این شبکه‌های عمیق از نظر کارایی بر شبکه‌های با یک لایه‌ی مخفی غلبه می‌کنند، اما سرعت یادگیری برای آموزش این شبکه‌ها کم است [۴]. ساختارها و الگوریتم‌های متفاوتی برای افزایش کارایی این مدل‌ها استفاده شده است [۶ و ۷]. بنابراین شبکه‌های عصبی چند لایه با الگوریتم یادگیری تکراری می‌تواند برای استخراج ویژگی‌های موثر از داده‌های خام مورد استفاده قرار گیرند. یادگیری عمیق با استفاده از پردازش لایه به لایه داده‌ها سطوح نمایش متفاوتی از آن‌ها را تولید می‌کند. این الگوریتم‌ها با بهره‌گیری از چندین لایه، داده‌های با ابعاد بالا را به ویژگی‌های با ابعاد پایین‌تر نگاشت می‌کنند [۴ و ۶]. الگوریتم‌های تکراری مورد استفاده در یادگیری عمیق دارای نواقصی از جمله سرعت پایین همگرایی، قرار گرفتن در بهینه‌های محلی و حساس بودن به تنظیم پارامتر نرخ یادگیری^۵ است. با توجه به این نواقص، ایده استفاده از پارامترهای تصادفی در شبکه‌های عصبی نفوذ پیدا کرد. طبقه‌بندی تصادفی متفاوتی مبتنی بر شبکه‌های عصبی، برای طبقه‌بندی و رگرسیون ارائه شده است. از این جمله می‌توان به جنگل تصادفی^۶ [۹]، شبکه‌ی سریع^۷ [۱۰] و ماشین یادگیری سریع^۸ [۱۱] اشاره کرد. ماشین یادگیری سریع دارای نقاط قوتی نسبت به بقیه طبقه‌بندی تصادفی است. از جمله این نقاط قوت می‌توان به استفاده از آن‌ها در شبکه‌های چند لایه، استفاده در انواع شبکه‌های عصبی مانند شبکه‌های عصبی فازی و محدود نبودن به استفاده از ساختار پرسپترون^۹ چند لایه اشاره کرد. همچنین نرون‌های لایه مخفی در این مدل به صورت تصادفی و یا براساس محدودیت‌های بهینه‌سازی وابسته به مسئله مقداردهی می‌شوند. ماشین یادگیری سریع به واسطه‌ی سرعت یادگیری سریع و کارایی مورد قبول در سال‌های اخیر به طور وسیعی مورد مطالعه قرار گرفته‌اند [۱۲]. این الگوریتم یادگیری، کارایی قابل قبولی برای آموزش شبکه‌های عصبی با یک لایه‌ی مخفی داشته و در کاربردهای مختلفی مانند طبقه‌بندی چهره^{۱۰} [۱۳] و قطعه بندی تصاویر^{۱۱} [۱۴] به کار گرفته شده است. از نظر تئوری اثبات شده است که یک شبکه‌ی عصبی با یک لایه‌ی مخفی، با تولید تصادفی پارامترهای بین ورودی و لایه مخفی و تعیین وزن

۱۱ Image segmentation
۱۲ Regularized least square error
۱۳ voting-based ELM
۱۴ regularized ELM
۱۵ Evolutionary ELM
۱۶ Kernel-based ELM

۴ Deep belief network
۵ Learning rate
۶ Random forest
۷ Quick net
۸ Extreme learning machine
۹ perceptron
۱۰ Face classification

بر این ضعفها الگوریتم ماشین یادگیری سریع برای آموزش شبکه‌های عصبی معرفی شد. این روش نشان داد که با وجود نقش مهمی که نرون‌های لایه مخفی در آموزش شبکه عصبی دارند اما نیازی به تنظیم دقیق آن‌ها نیست [۱۱]. هدف از ارائه این الگوریتم یادگیری، اجتناب از روند یادگیری تکراری و زمان‌بر الگوریتم پس‌انتشار خطا و همچنین بهبود قابلیت تعمیم دهی شبکه‌ی عصبی است. در الگوریتم مبتنی بر مشتقات جزئی، پس از مقداردهی تصادفی اولیه به تمام پارامترهای مدل در فاز آموزش، مقادیر آن‌ها در یک فرایند تکراری بروزرسانی می‌شوند. با این حال در ماشین یادگیری سریع، در فاز آموزش پارامترهای اولین لایه به صورت تصادفی مقداردهی شده و هیچ بروزرسانی برای آن‌ها اعمال نمی‌شود و دقیقاً از همان مقادیر در فاز تست هم استفاده می‌شود. وزن‌های بین لایه مخفی و لایه خروجی با حل مسئله‌ی بهینه‌سازی براساس معیار کمترین مربعات خطا تعیین می‌شوند. به واسطه ساختار تنک و تکراری نبودن الگوریتم برای تنظیم پارامترها، سرعت یادگیری این روش نسبت به سایر روش‌ها بیشتر است. ساختار یک ماشین یادگیری سریع در شکل ۱ نشان داده شده است.



شکل ۱. ماشین یادگیری سریع تک لایه. X و Y به ترتیب نشان دهنده ورودی و خروجی شبکه هستند. W و β نشان دهنده پارامترهای اولین لایه و لایه‌ی خروجی.

براساس پارامترهای تصادفی اولین لایه، تابع پیوسته و غیر خطی و همچنین به کاربردن استراتژی نرون‌های افزایشی، ماتریس خروجی لایه‌ی مخفی به کمک رابطه‌ی ۱ محاسبه می‌شود.

$$H = X \cdot W + b \quad (1)$$

در این رابطه، $X \in \mathbb{R}^{N \times d}$ ماتریس داده‌ی ورودی، $W \in \mathbb{R}^{d \times L}$ ماتریس وزن‌های تصادفی و $b \in \mathbb{R}^L$ بایاس لایه‌ی مخفی است. نمایش ماتریسی H به صورت زیر است.

$$H = \begin{bmatrix} g(X_{1,1} \cdot W_{:,1} + b_1) & \cdots & g(X_{1,L} \cdot W_{:,L} + b_L) \\ \vdots & \ddots & \vdots \\ g(X_{N,1} \cdot W_{:,1} + b_1) & \cdots & g(X_{N,L} \cdot W_{:,L} + b_L) \end{bmatrix}$$

گیری از دو تابع رمزگذار^{۱۷} و رمزگشا^{۱۸} بهترین پارامترهای هر لایه از مدل را تعیین می‌کند. با بهره‌گیری از این اتوانکدرهای ساده یک اتوانکدر چندلایه برای ساخت مجدد تصاویر و یک ماشین یادگیری سریع عمیق برای طبقه‌بندی داده‌ها ایجاد شده است. برای تعیین پارامترهای هر لایه از ماشین یادگیری سریع عمیق از یک اتوانکدر تک لایه استفاده شده است. تکرار این اتوانکدرها و استفاده از پارامترهای تصادفی در اولین لایه از آن‌ها موجب کاهش کارایی این مدل‌ها می‌شود.

در این مقاله یک ساختار جدید چند لایه برای اتوانکدرها معرفی شده است. این اتوانکدر چندلایه با بهره‌گیری از الگوریتم یادگیری جدید، پارامترهای هر لایه از مدل را تعیین می‌کند. برای عدم استفاده از پارامترهای تصادفی در تعیین پارامترهای اولین لایه از این ساختار از یک اتوانکدر جدید تکرار شونده استفاده شده است. این اتوانکدر در یک فرایند تکراری بهترین پارامترها را تعیین می‌کند. با تعیین پارامترهای هر لایه از اتوانکدر چندلایه، از این ساختار برای ساخت مجدد تصاویر استفاده شده است. همچنین با کمک پارامترهای تعیین شده یک ماشین یادگیری سریع ارائه شده است. این مدل موثرترین ویژگی‌ها را از داده‌های خام استخراج می‌کند. در نهایت برای طبقه‌بندی داده‌ها از یک ماشین یادگیری سریع ساده استفاده شده است. نتایج آزمایش‌ها برای حل مسئله‌ی طبقه‌بندی و بازسازی تصاویر نشان دهنده‌ی افزایش کارایی روش پیشنهادی نسبت به سایر روش‌های مشابه است.


در ادامه مقاله و در بخش دوم به مرور الگوریتم ماشین یادگیری سریع برای آموزش یک شبکه‌ی عصبی تک لایه می‌پردازیم. بخش سوم به مرور ساختار و الگوریتم ارائه شده برای ماشین یادگیری سریع عمیق اختصاص یافته است. در بخش چهارم ساختار و الگوریتم یادگیری پیشنهادی برای اتوانکدر چندلایه ارائه شده است. در بخش پنجم، ماشین یادگیری سریع عمیق برای طبقه‌بندی داده‌ها معرفی شده است. در بخش ششم به ارائه و تحلیل نتایج تجربی استخراج شده در روش پیشنهادی و مقایسه آن با سایر روش‌های مشابه می‌پردازیم. در پایان نتیجه‌گیری از روش پیشنهادی ارائه شده است.

ماشین یادگیری سریع

در سال‌های اخیر، شبکه‌های عصبی عمیق بر اساس الگوریتم یادگیری پس انتشار خطا آموزش داده می‌شدند [۲۵]. با این وجود، الگوریتم پس انتشار خطا با ضعف‌هایی مانند سرعت پایین همگرایی و قرار گیری در بهینه‌های محلی روبرو بود. برای غلبه

نمایش با بعد یکسان: ویژگی‌هایی با ابعاد یکسان با ورودی تولید می‌شود.

به منظور بهره‌گیری از ماشین یادگیری سریع برای آموزش یک اتوانکدر از داده‌های ورودی به عنوان برجسب‌های خروجی نیز استفاده می‌کنیم ($X = T$) [۲۱] ساختار اتوانکدر مبتنی بر ماشین یادگیری سریع در شکل ۲ نشان داده شده است.



شکل ۲. ساختار اتوانکدر مبتنی بر ماشین یادگیری سریع.

برای آموزش پارامترهای لایه‌ی خروجی اتوانکدر، از الگوریتم ارائه شده برای ماشین یادگیری سریع بهره می‌بریم. تفاوت الگوریتم یادگیری این ساختار با ماشین یادگیری سریع تک لایه این است که به جای برجسب‌های صحیح داده‌های آموزشی از خود داده‌های ورودی استفاده می‌کنیم. در نتیجه پارامترهای خروجی در این ساختار به کمک رابطه‌ی ۷ تعیین می‌شود.

$$\beta = H^+ \cdot X \quad (7)$$

به منظور ایجاد یک ساختار عمیق به کمک این اتوانکدرها، وزن‌های مربوط به هر لایه از ماشین یادگیری سریع عمیق براساس یک اتوانکدر تعیین می‌شود. ماشین یادگیری سریع عمیق ایجاد شده به کمک این روش ساختاری مشابه شکل ۳ دارد. شکل ۳ شامل دو قسمت است، در قسمت پایین یک ماشین یادگیری سریع عمیق مشخص شده است. این ساختار به منظور استخراج ویژگی‌های مهم از داده ورودی نیازمند پارامترهای موثری در هر لایه است. این پارامترها به صورت لایه به لایه از طریق یک اتوانکدر مبتنی بر ماشین یادگیری سریع (ELM-AE) که در شکل ۲ مشخص شده محاسبه میشوند. در قسمت بالا شکل ۳ این اتوانکدرها برای دو لایه مشخص شده اند [۲۱]. استفاده از اتوانکدرهای مجزا برای تعیین پارامترهای هر لایه از ماشین یادگیری سریع دارای ضعف‌هایی است.

در این ماتریس g نشان دهنده‌ی تابع فعال‌سازی است. از جمله این توابع می‌توان به تابع های sigmoid و relu اشاره کرد. برای بدست آوردن وزن‌های لایه‌ی خروجی (β)، مسئله بهینه سازی به صورت رابطه‌ی ۲ حل می‌شود.

$$\underset{\beta}{\text{minimize}}: \|H \cdot \beta - T\|_2^2 + \|\beta\|_2^2 \quad (2)$$

در این رابطه، $T \in \mathbb{R}^{N \times m}$ نشان دهنده‌ی ماتریس برجسب‌های صحیح داده‌های آموزشی است. با حل مسئله بهینه سازی ۲، مقدار پارامتر $\beta \in \mathbb{R}^{L \times m}$ از طریق رابطه‌ی ۳ بدست می‌آید.

$$\beta = H^+ \cdot T \quad (3)$$

برای محاسبه‌ی H^+ از روش پیش بینی متعامد^{۱۹} استفاده شده است. در این روش اگر ماتریس $H^T H$ غیر تکین باشد شبه معکوس^{۲۰} به کمک رابطه‌ی ۴ محاسبه می‌شود.

$$H^+ = \left(\frac{I}{C} + H^T H\right)^{-1} H^T \quad (4)$$

در غیر اینصورت اگر $H H^T$ غیر تکین باشد، شبه معکوس به کمک رابطه‌ی ۵ تعیین می‌شود.

$$H^+ = H^T \left(\frac{I}{C} + H H^T\right)^{-1} \quad (5)$$

پس از محاسبه‌ی پارامتر β ، پیش بینی مدل به کمک رابطه‌ی ۶ تعیین می‌شود.

$$Y = H \cdot \beta \quad (6)$$


در این رابطه پیش‌بینی خروجی به صورت $Y \in \mathbb{R}^{N \times m}$ خواهد بود. در این ماتریس هر سطر نشان دهنده‌ی احتمال حضور نمونه آموزشی در هر کلاس است. کلاسی که بیشترین احتمال را داشته باشد به عنوان کلاس پیش بینی شده توسط مدل در نظر گرفته می‌شود. پس از آموزش مدل و تعیین پارامترهای خروجی، از این مدل برای تعیین کارایی مدل استفاده می‌شود [۱۱].

اتوانکدر و ماشین یادگیری سریع چندلایه


اتوانکدرها ساختاری برای استخراج ویژگی از داده‌های خام به صورت بدون نظارت هستند [۲۴]. هدف اصلی یک اتوانکدر تولید ویژگی‌های موثر از داده‌های ورودی براساس سه نمایش مختلف است.

نمایش فشرده: ویژگی‌هایی با ابعاد پایین‌تر از داده‌های ورودی تولید می‌شود.

نمایش تنک: ویژگی‌هایی با ابعاد بیشتر از ابعاد داده ورودی تولید می‌شود.



شکل ۳. ماشین یادگیری سریع عمیق. پارامترهای هر لایه از این مدل به کمک اتوانکدرهای مشخص شده در بالای شکل مشخص تعیین می‌شوند.



شکل ۴. ساختار اتوانکدر چند لایه‌ی پیشنهادی

در این الگوریتم پارامتر بایاس به صورت یک سطر به ماتریس وزن اضافه می‌شود. در نتیجه ابعاد پارامترهای ورودی به صورت $W \in \mathbb{R}^{(d+1) \times L}$ خواهد بود. همچنین به منظور انجام ضرب ماتریسی و تطبیق ابعاد ستونی با مقدار ۱ به داده‌ی ورودی اضافه می‌شود در نتیجه ابعاد داده‌ی ورودی به صورت $X \in \mathbb{R}^{(N) \times (d+1)}$ است. پارامترهای آخرین تکرار به عنوان خروجی این الگوریتم خواهند بود.

پس از تعیین پارامترهای اولین لایه به کمک اتوانکدر تکرار شونده (W_1) ، خروجی لایه‌ی مخفی به کمک رابطه‌ی ۸ تعیین می‌شود.

$$H_1 = g(X \cdot W_1 + b_1) \quad (8)$$


با توجه به خروجی لایه‌ی مخفی و فرض عدم وجود سایر لایه در مدل وزن خروجی (β) ، را براساس آنچه در اتوانکدر تک لایه بیان شد طبق رابطه‌ی ۷ محاسبه می‌کنیم.

از جمله این ضعف‌ها می‌توان به پارامترهای تصادفی تولید شده در اولین لایه تمام اتوانکدرها و تجمع خطای بازسازی تمام اتوانکدرها و کاهش کارایی مدل اشاره کرد.

در ادامه به معرفی ساختار یکپارچه و چندلایه از اتوانکدرهای مبتنی بر ماشین یادگیری سریع خواهیم پرداخت. این اتوانکدر منجر به افزایش کارایی ماشین یادگیری سریع عمیق خواهد شد.

اتوانکدر با ساختار چند لایه

برای بهبود عملکرد ماشین یادگیری سریع عمیق، پارامترهای هر لایه از مدل به کمک یک اتوانکدر یکپارچه و چندلایه تعیین می‌شوند. ساختار اتوانکدر پیشنهادی در شکل ۴ نشان داده شده است. به منظور اجتناب از تولید تصادفی پارامترهای اولین لایه از ساختار اتوانکدر چند لایه، این پارامترها به کمک یک اتوانکدر تکرار شونده تعیین می‌شوند. ساختار اتوانکدر تکرار شونده در شکل ۵ نشان داده شده است. الگوریتم ۱ (RE-AE)، عملکرد این اتوانکدر را توصیف می‌کند. به منظور سهولت در محاسبات



شکل ۵. ساختار اتوانکدر تکرار شونده.

$$g^{-1}(H_2) = H_1 \cdot W_2$$

$$W_2 = H_1^+ \cdot g^{-1}(H_2)$$
 بر اساس پارامترهای بدست آمده خروجی لایه‌ی دوم (H_2) به کمک رابطه‌ی ۹ محاسبه می‌شود. در ادامه و قبل از اضافه کردن لایه سوم به ساختار، پارامتر β را براساس خروجی لایه دوم و براساس رابطه‌ی ۷ تعیین می‌کنیم. بر اساس فرایند بیان شده برای محاسبه‌ی پارامتر بین اولین و دومین لایه، می‌توان پارامترهای بین هر دو لایه‌ی مختلف را در مدل محاسبه کرد. با توجه محدودیت استفاده از تعداد نرون‌های برابر در هر لایه پس از پردازش داده‌های خام در چند لایه می‌توان از یک اتوانکدر تکرار شونده برای کاهش ابعاد داده استفاده کرد. الگوریتم ۲ فرایند استخراج ویژگی و بازسازی داده‌ی ورودی را به کمک این اتوانکدر چندلایه نشان می‌دهد.

با اضافه کردن لایه‌ی دوم به مدل خروجی این لایه به کمک رابطه‌ی ۹ تعیین می‌شود.

$$H_2 = g(H_1 \cdot W_2) \quad (9)$$

در این رابطه به دنبال تعیین پارامتر بین اولین و دومین لایه (W_2) هستیم. بدین منظور خروجی لایه‌ی دوم (H_2)، را به کمک رابطه‌ی ۱۰ بدست می‌آوریم.

$$H_2 = \beta^+ \cdot T \quad (10)$$

با توجه به مقدار محاسبه شده برای خروجی دومین لایه با استفاده از رابطه‌ی ۱۰، پارامترهای بین اولین و دومین لایه (W_2) به کمک رابطه‌ی ۱۱ تعیین می‌شود.

ماشین یادگیری سریع عمیق براساس اتوانکدر پیشنهادی

با بهره‌گیری از پارامترهای استخراج شده برای هر لایه از اتوانکدر معرفی شده در بخش قبل می‌توان ویژگی‌های موثری از داده‌های خام استخراج کرد. شکل ۶ ساختار یک ماشین یادگیری سریع عمیق را نشان می‌دهد.

الگوریتم ۱ (RE-AE). اتوانکدر تکرار شونده

ورودی: مجموعه داده آموزشی $X \in \mathbb{R}^{N \times (d+1)}$. تعداد تکرار m ، تعداد

نرون‌های لایه‌ی مخفی (L)، $z=2$

خروجی: $\beta^{(m-1)}$ و $\beta^{(m)}$

۱- مقدار دهی تصادفی به پارامترهای ورودی $W \in \mathbb{R}^{(d+1) \times L}$

$$H^1 = g(W \cdot X) \quad -2$$

$$\beta^{(1)} = (H^1)^T \cdot X \quad -3$$

۴- تا زمانی که $j \neq m$ تکرار کن:

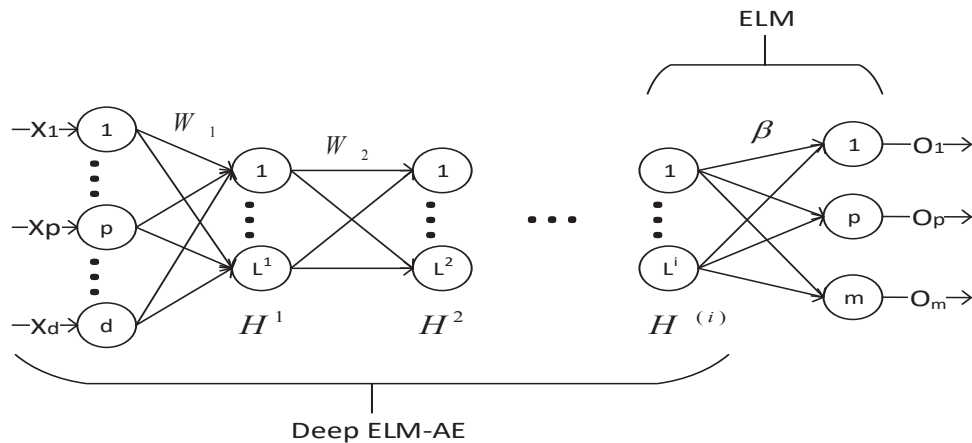
$$W = \beta^{(j-1)} \quad -5$$

$$H^{(j)} = g(W \cdot X) \quad -6$$

$$\beta^{(j)} = (H^{(j)})^T \cdot X \quad -7$$

۸- پایان حلقه

برگرداندن $\beta^{(m-1)}$ و $\beta^{(m)}$



شکل ۶. ماشین یادگیری سریع عمیق

طبقه‌بندی داده‌ها و بازسازی تصاویر بر روی مجموعه داده‌ی تست مشخص خواهد شد.

تصدیق آزمایشات

در این بخش کارایی روش پیشنهادی برای طبقه‌بندی داده‌های مختلف آزمایش شده است. تمامی آزمایش‌ها در محیط پایتون ۳٫۶ و بر روی ماشینی با پردازنده‌ی intel core i5 و ۸ گیگابایت حافظه اجرا شده است. روش پیشنهادی با سایر روش‌های مشابه در کاهش بعد و طبقه‌بندی داده‌ها که در ادامه معرفی شده‌اند مقایسه شده است.

- ماشین یادگیری سریع (ELM) [۱۱]
- ماشین یادگیری سریع عمیق مبتنی بر اتوانکدرهای ساده (ML-ELM) [۲۱]
- ماشین یادگیری سریع مبتنی بر توابع فعال‌سازی معکوس پذیر (AE-W_INV) [۲۴]
- ماشین یادگیری سریع دو لایه (T-ELM) [۲۶]

همچنین کارایی روش پیشنهادی در بازسازی تصاویر با سایر روش‌های مشابه مقایسه شده است.

برای مقایسه نتایج از مجموعه داده‌های رایج استفاده شده است. آزمایش‌ها بر روی ۴ مجموعه داده برای طبقه‌بندی و ۲ مجموعه داده تصویر مطابق جدول ۱ و جدول ۲ انجام شده است. جزئیات مربوط به مجموعه‌های داده استفاده شده در این مقاله در جداول مشخص شده است. آزمایش روی هر مجموعه داده را ۱۰ بار تکرار کرده‌ایم و میانگین دقت را محاسبه می‌کنیم. منظور از

در این ساختار ابتدا به کمک اتوانکدر معرفی شده موثرترین ویژگی‌ها از داده‌های خام استخراج می‌شود. برای طبقه‌بندی داده‌ها در این مدل از یک ماشین یادگیری سریع تک لایه مطابق شکل استفاده شده است. بنابراین اگر H_S ویژگی استخراج شده از اتوانکدر چندلایه باشد، پارامتر β به کمک رابطه‌ی ۱۲ تعیین می‌شود.

$$\beta = H_S \cdot T \quad (12)$$

در این رابطه $T \in \mathbb{R}^{N \times m}$ برچسب صحیح داده‌های آموزشی است. پارامترهای هر لایه از مدل به کمک اتوانکدر چندلایه و ماشین یادگیری سریع تک لایه و با بهره‌گیری از داده‌های آموزشی تعیین می‌شوند. کارایی ساختار ارائه شده برای

الگوریتم ۲. اتوانکدر چندلایه

ورودی: مجموعه داده آموزشی $X \in \mathbb{R}^{N \times (d+1)}$ ، تعداد لایه‌ها با نرون‌های یکسان k ، پارامتر تنظیم C ، $z=2$ ، تعداد نرون‌ها L ، تعداد تکرار m

خروجی: ویژگی‌های استخراج شده (H_S) و داده‌ی بازسازی شده (X_{re})

$$W_0, W_1 = RE - AE(X, m, L) - 1$$

$$H_1 = g(W_1 \cdot X) - 2$$

۳- تا زمانی که $z \neq S$ تکرار کن:

$$\beta = H_{z-1}^+ \cdot T - 4$$

$$H_z = \beta^+ \cdot T - 5$$

$$W_j = H_{z-1}^+ \cdot g^{-1}(H_j) - 6$$

$$H_j = g(H_{z-1} \cdot W_j) - 7$$

$$j = j + 1 - 8$$

۹- پایان حلقه

$$X_{re} = H_S \cdot -10$$

برگرداندن (H_S) و (X_{re})

برای کاهش ابعاد مطابق آنچه در جدول ۳ مشخص شده است، ابعاد داده‌ها به اندازه تعداد کلاس‌ها کاهش داده می‌شود. شکل ۷ نشان دهنده ی دقت روش پیشنهادی و سایر روش‌های نام برده شده براساس کاهش ابعاد متفاوت، روی مجموعه داده MNIST است. جدول ۳ نشان دهنده‌ی مقایسه‌ی دقت طبقه‌بندی روش پیشنهادی و سایر روش‌ها است. در ساختار ماشین یادگیری سریع ساده از یک لایه مخفی با تعداد نرون‌های برابر با تعداد کلاس‌ها در هر مجموعه داده استفاده شده است. در مدل ماشین یادگیری سریع عمیق مبتنی بر اتوانکدر و همچنین مدل مبتنی بر توابع فعال سازی معکوس پذیر از چهار لایه استفاده شده است که تعداد نرون‌های هر لایه به صورت (تعداد کلاس‌ها، ۵۰۰، ۵۰۰، ۵۰۰) است. در ساختار ماشین یادگیری سریع دو لایه، تعداد نرون‌ها در هر لایه برابر با تعداد کلاس‌ها در نظر گرفته شده است. ساختار روش پیشنهادی در این مقاله برای کاهش ابعاد از سه لایه با تعداد نرون برابر با ۵۰۰ استفاده کرده و در انتها برای ایجاد شرایط مشابه با سایر روش‌ها، ابعاد ویژگی‌ها را به کمک یک اتوانکدر تکرارشونده به تعداد کلاس‌ها تغییر داده است. بنابراین تعداد نرون‌ها در هر لایه از مدل پیشنهادی به صورت (تعداد کلاس‌ها، ۵۰۰، ۵۰۰، ۵۰۰) تنظیم شده است.

میانگین دقت طبقه بندی، میانگین نسبت تعداد داده‌هایی است که درست طبقه بندی شده اند به کل داده‌ها در ۱۰ اجرای متفاوت است. نمودار شکل ۷ نشان دهنده دقت مدل در ۱۰ بار اجرای آزمایش برای مجموعه داده‌های مختلف است. این نمودار نشان می‌دهد که واریانس دقت مدل در آزمایشات متعدد خیلی کم بوده و در نتیجه مدل دارای ویژگی قابلیت اطمینان است. برای روش پیشنهادی مقدار پارامتر C از مجموعه $\{2^{-10}, \dots, 2^{10}\}$ و بر اساس اعتبارسنجی متقاطع انتخاب می‌شود.

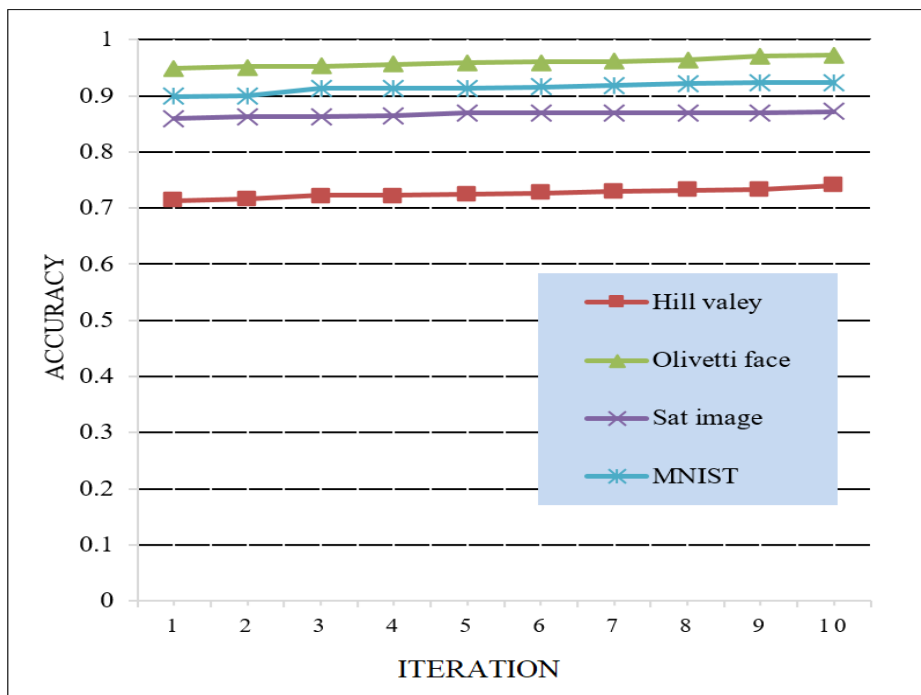
جدول ۱. مشخصات مجموعه داده‌ها

مجموعه داده	تعداد ویژگی‌ها	تعداد داده‌های آموزشی	تعداد داده‌های تست
Sat image	۳۷	۴۴۳۵	۲۰۰۰
Duke	۷۱۲۹	۲۹	۱۵
Hill valley	۱۰۱	۶۰۶	۶۰۶
USPS	۲۵۶	۷۲۹۱	۲۰۰۷

برای نشان دادن برتری روش پیشنهادی در کاهش ابعاد داده و همچنین نشان دادن بهبود دقت طبقه‌بندی، کارایی روش پیشنهادی با سایر روش‌های نام برده شده مقایسه شده است.

جدول ۲. مجموعه داده‌ی تصاویر

مجموعه داده	تعداد ویژگی‌ها	تعداد تصاویر	تعداد کلاس‌ها
MNIST	۷۸۴	۷۰۰۰۰	۱۰
Olivetti face	۴۰۹۶	۴۰۰	۴۰



شکل ۷: دقت مدل پیشنهادی در ۱۰ بار تکرار آزمایش روی ۴ مجموعه داده

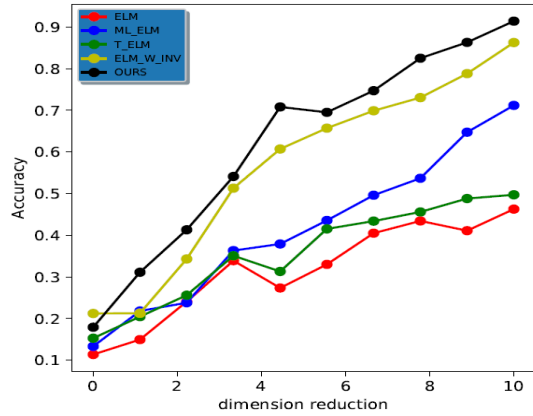
جدول ۳. مقایسه نتایج طبقه بندی روش های مختلف (میانگین : میانگین دقت در زمان تست)

Proposed method	AE-W-INV	T-ELM	ML-ELM	ELM	میزان کاهش ابعاد	مجموعه داده
میانگین	میانگین	میانگین	میانگین	میانگین		
۰/۹۱۴۲	۰/۸۶۲۶	۰/۴۹۷۰	۰/۷۱۱۷	۰/۴۶۲۶۲	۷۸۴→۱۰	MNIST
۰/۸۶۷۰	۰/۸۵۱۷	۰/۶۹۲۴	۰/۸۸۵۱	۰/۶۷۹۱	۳۶→۷	Sat image
۰/۸۶	۰/۶۰۵۵	۰/۴۸۶۶	۰/۵۴۶۶	۰/۴۳۹۰	۷۱۲۹→۲	Duke
۰/۷۲۶۰	۰/۹۰۱۵	۰/۵۲۷۹	۰/۵۴۹۰	۰/۵۱۹۶	۱۰۱→۲	Hill valley
۰/۹۰۴۳	۰/۹۲۰۷	۰/۶۲۳۴	۰/۸۴۷۰	۰/۵۹۰۵	۲۵۶→۱۰	USPS
۰/۹۶	۰/۹۲۲۰	۰/۷۵۸۰	۰/۷۶۶۸	۰/۷۲۴۰	۴۰۹۶→۴۰	Olivetti face
۰/۸۸۶	۰/۷۹۷۱	۰/۷۱۲۵	۰/۶۲	۰/۵۳۴۰	۷۱۲۹→۱۰	Leu
۰/۸۷۳۹	۰/۸۳۳۷	۰/۶۱۳۹	۰/۷۰۳۷	۰/۵۶۴۱	← میانگین کلی روی همه داده ها	

روشهای موجود بهبود داده است. در این قسمت به بررسی بازسازی مجدد تصاویر به کمک روش پیشنهادی و سایر روش‌های مشابه می‌پردازیم. روش پیشنهادی در این مقاله برای بازسازی تصاویر با روش‌های موجود مانند اتوانکدر ساده مبتنی بر ماشین یادگیری سریع که از یک لایه مخفی با ۵۰۰ نرون استفاده می‌کند [۲۱] و اتوانکدر مبتنی بر توابع فعال‌سازی معکوس پذیر [۲۴] مقایسه شده است. شکل ۸ نشان دهنده خروجی تصاویر بازسازی شده روی مجموعه داده MNIST است. که همانگونه که مشخص است روش پیشنهادی بر دو روش نام برده شده غلبه می‌کند. شکل ۹ خروجی تصاویر بازسازی شده روی مجموعه داده Olivetti-face را نشان می‌دهد. که این نتایج نیز نشان از برتری روش پیشنهادی دارد.



نتیجه گیری

ماشین یادگیری سریع الگوریتمی کارا برای آموزش شبکه‌های عصبی با یک لایه مخفی است. برای افزایش کارایی و حل مسائل پیچیده‌تر نیازمند ساختاری عمیق مبتنی بر این الگوریتم هستیم. روش‌های ارائه شده برای تعیین پارامترهای هر لایه از شبکه‌ی عصبی عمیق از یک اتوانکدر منحصر به فرد استفاده می‌کند.





شکل ۷. مقایسه دقت ساختار پیشنهادی و سایر روش‌ها روی مجموعه داده MNIST. محور افقی مشخص کننده ی ابعاد کاهش یافته و محور عمودی دقت مدل است.

شکل ۶ ساختار ماشین یادگیری سریع عمیق را نشان می‌دهد که در مدل استفاده شده برای آزمایش از ۴ لایه از این مدل با تعداد نرون‌های بیان شده استفاده شده است. در انتها، برای طبقه‌بندی داده‌ها بر مبنای ویژگی‌های استخراج شده در تمامی روش‌ها از یک ماشین یادگیری سریع با ۵۰۰ نرون در لایه مخفی استفاده شده است. آخرین ردیف از جدول ۳ نشان می‌دهد که روش پیشنهادی میانگین دقت روی همه ی مجموعه داده‌ها را به ترتیب به میزان ۰.۴٪، ۰.۲۶٪، ۰.۱۷٪ و ۰.۳۱٪ نسبت به



شکل ۸. تصاویر بازسازی شده. از بالا به پایین: (ا): تصاویر تصادفی از مجموعه داده اصلی. (ب): تصاویر بازسازی شده به کمک یک اتوانکدر تک لایه. (ج): تصاویر بازسازی شده به کمک اتوانکدر مبتنی بر توابع فعال‌سازی معکوس پذیر (د) تصاویر بازسازی شده به کمک روش پیشنهادی



شکل ۹. تصاویر بازسازی شده. از بالا به پایین: (ا): تصاویر تصادفی از مجموعه داده اصلی. (ب): تصاویر بازسازی شده به کمک یک اتوانکدر تک لایه. (ج): تصاویر بازسازی شده به کمک اتوانکدر مبتنی بر توابع فعال سازی معکوس پذیر (د) تصاویر بازسازی شده به کمک روش پیشنهادی

- neural networks," *science*, vol. 313, pp. 504-507, 2006.
- [5] R. Salakhutdinov and H. Larochelle, "Efficient learning of deep Boltzmann machines," in *Proceedings of the thirteenth international conference on artificial intelligence and statistics*, 2010.
- [6] Y. Bengio, P. Lamblin, D. Popovici and H. Larochelle, "Greedy layer-wise training of deep networks," in *Advances in neural information processing systems*, 2007.
- [7] P. Vincent, H. Larochelle, I. Lajoie, Y. Bengio and P.-A. Manzagol, "Stacked denoising autoencoders: Learning useful representations in a deep network with a local denoising criterion," *Journal of machine learning research*, vol. 11, pp. 3371-3408, 2010.
- [8] Y. LeCun, Y. Bengio and G. Hinton, "Deep learning," *nature*, vol. 521, p. 436, 2015.
- [9] L. Breiman, "Random forests," *Machine learning*, vol. 45, pp. 5-32, 2001.
- [10] H. White, "An additional hidden unit test for neglected nonlinearity in multilayer feedforward networks," in *Proceedings of the international joint conference on neural networks*, 1989.
- [11] G.-B. Huang, Q.-Y. Zhu and C.-K. Siew, "Extreme learning machine: theory and applications," *Neurocomputing*, vol. 70, pp. 489-501, 2006.
- [12] G.-B. Huang, D. H. Wang and Y. Lan, "Extreme learning machines: a survey," *International journal of machine learning and cybernetics*, vol. 2, pp. 107-122, 2011.
- [13] A. A. Mohammed, R. Minhas, Q. M. J. Wu and M. A. Sid-Ahmed, "Human face recognition based on multidimensional PCA and extreme learning machine," *Pattern Recognition*, vol. 44, pp. 2588-2597, 2011.
- به دلیل استفاده از پارامترهای تصادفی در اولین لایه هر اتوانکدر و استفاده از اتوانکدر منحصر به فرد در هر لایه از مدل این روش‌ها کارایی مورد قبولی ندارند. در این مقاله ساختار یکپارچه و الگوریتمی کارا برای یک اتوانکدر چندلایه معرفی شد. این ساختار با جلوگیری از استفاده اتوانکدر منحصر به فرد برای تعیین پارامترهای هر لایه از مدل، منجر به افزایش کارایی ماشین یادگیری سریع عمیق می‌شود. همچنین به منظور عدم استفاده از پارامترهای تصادفی در اولین لایه از اتوانکدر چندلایه‌ی پیشنهادی از یک اتوانکدر تکرار شونده استفاده شده است. این اتوانکدر در یک فرایندی تکراری بهترین پارامترها برای اولین لایه از مدل را تعیین می‌کند. یکی از کاربردهای اتوانکدرها توانایی آن‌ها در بازسازی تصاویر است. از اتوانکدر چندلایه‌ی پیشنهادی نیز در بازسازی تصاویر استفاده شده است. نتایج طبقه‌بندی داده‌ها و همچنین بازسازی تصاویر نشان می‌دهد که روش پیشنهادی کارایی قابل قبول و بهتری نسبت سایر روش‌های مشابه دارد.

مراجع

- [1] Z. Fu, K. Ren, J. Shu, X. Sun and F. Huang, "Enabling personalized search over encrypted outsourced data with efficiency improvement," *IEEE transactions on parallel and distributed systems*, vol. 27, pp. 2546-2559, 2016.
- [2] Z. Zhou, Y. Wang, Q. M. J. Wu, C.-N. Yang and X. Sun, "Effective and efficient global context verification for image copy detection," *IEEE Transactions on Information Forensics and Security*, vol. 12, pp. 48-63, 2017.
- [3] B. Gu and V. S. Sheng, "A Robust Regularization Path Algorithm for nu - Support Vector Classification," *IEEE Transactions on neural networks and learning systems*, vol. 28, pp. 1241-1248, 2017.
- [4] G. E. Hinton and R. R. Salakhutdinov, "Reducing the dimensionality of data with

- extreme learning machine for big data," *IEEE intelligent systems*, vol. 28, pp. 31-34, 2013.
- [22] J. Tang, C. Deng and G.-B. Huang, "Extreme learning machine for multilayer perceptron," *IEEE transactions on neural networks and learning systems*, vol. 27, pp. 809-821, 2016.
- [23] K. Phurattanapapin and P. Horata, "Extended hierarchical extreme learning machine with multilayer perceptron," in *Computer Science and Software Engineering (JCSSE), 2016 13th International Joint Conference on*, 2016.
- [24] Y. Yang and Q. M. J. Wu, "Multilayer extreme learning machine with subnetwork nodes for representation learning," *IEEE transactions on cybernetics*, vol. 46, pp. 2570-2583, 2016.
- [25] D. E. Rumelhart, G. E. Hinton and R. J. Williams, "Learning representations by back-propagating errors," *nature*, vol. 323, p. 533, 1986.
- [26] B.-Y. 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.
- [14] A. D. Andrushia and R. Thangarajan, "Visual attention-based leukocyte image segmentation using extreme learning machine," *International Journal of Advanced Intelligence Paradigms*, vol. 7, pp. 172-186, 2015.
- [15] G.-B. Huang, L. Chen, C. K. Siew and others, "Universal approximation using incremental constructive feedforward networks with random hidden nodes," *IEEE Trans. Neural Networks*, vol. 17, pp. 879-892, 2006.
- [16] G.-B. Huang, M.-B. Li, L. Chen and C.-K. Siew, "Incremental extreme learning machine with fully complex hidden nodes," *Neurocomputing*, vol. 71, pp. 576-583, 2008.
- [17] J. Cao, Z. Lin, G.-B. Huang and N. Liu, "Voting based extreme learning machine," *Information Sciences*, vol. 185, pp. 66-77, 2012.
- [18] W. Deng, Q. Zheng and L. Chen, "Regularized extreme learning machine," in *Computational Intelligence and Data Mining, 2009. CIDM'09. IEEE Symposium on*, 2009.
- [19] Q.-Y. Zhu, A. K. Qin, P. N. Suganthan and G.-B. Huang, "Evolutionary extreme learning machine," *Pattern recognition*, vol. 38, pp. 1759-1763, 2005.
- [20] M. Pal, A. E. Maxwell and T. A. Warner, "Kernel-based extreme learning machine for remote-sensing image classification," *Remote Sensing Letters*, vol. 4, pp. 853-862, 2013.
- [21] L. L. C. Kasun, H. Zhou, G.-B. Huang and C. M. Vong, "Representational learning with