

یادگیری عمیق و کاربردهایش در پایش ماشینی سلامت

چکیده

یادگیری عمیق (DL)، با سرعت، از سال ۲۰۰۶ به یک مسیر تحقیقاتی در حال رشد تبدیل شده و پیشرفته‌ترین کارایی‌ها را در طیف وسیعی از زمینه‌ها از جمله تشخیص اشیا، بخش‌بندی تصویر، تشخیص گفتار و ترجمه ماشینی، بازتعریف می‌کند. در سیستم‌های تولیدی مدرن، پایش ماشینی سلامت‌های مبتنی بر داده به دلیل استقرار گسترده حسگرهای ارزان‌قیمت و اتصال آنها به اینترنت، محبوبیت زیادی دارد. در همین حال، یادگیری عمیق، ابزارهای مفیدی را برای پردازش و تحلیل این کلان داده‌های ماشینی، فراهم می‌کند. هدف اصلی این مقاله، بررسی و خلاصه کردن کار تحقیقاتی نوظهور یادگیری عمیق در پایش ماشینی سلامت است. پس از معرفی کوتاه تکنیک‌های یادگیری عمیق، استفاده از یادگیری عمیق در سیستم‌های پایش ماشینی سلامت، عمدتاً از جنبه‌های زیر بررسی می‌شوند: خود رمزگذار (AE) و انواع آن، ماشین‌های بولتزن محدود شده و انواع آن از جمله شبکه باور عمیق (DBN) و ماشین‌های بولتزن عمیق (DBM)، شبکه‌های عصبی کانولوشن (CNN) و شبکه‌های عصبی بازگشتی (RNN). علاوه بر این، یک مطالعه تجربی بر روی کارایی این رویکردها انجام شده که در آن داده‌ها و کد، به صورت آنلاین بوده است. در نهایت، برخی از روندهای جدید روش‌های پایش ماشینی سلامت مبتنی بر DL مورد بحث قرار می‌گیرند.

کلمات کلیدی: یادگیری عمیق، پایش ماشینی سلامت، داده‌های بزرگ

فهرست مطالب

۱. مقدمه
 ۲. یادگیری عمیق
 - ۲.۱. خود رمزگذارها (AE) و انواع آن
 - ۲.۱.۱. اضافه شدن پراکندگی
 - ۲.۱.۲. افزودن نویز زدایی
 - ۲.۱.۳. ساختار استکینگ
 - ۲.۲. RBM و انواع آن
 - ۲.۲.۱. شبکه باور عمیق
 - ۲.۲.۲. ماشین بولتزمن عمیق
 - ۲.۳. شبکه عصبی کانولوشن
 - ۲.۳.۱. کانولوشن
 - ۲.۳.۲. تجمیع (پولینگ)
 - ۲.۴. شبکه عصبی بازگشتی
 - ۲.۵. روش‌های بهینه‌سازی شبکه‌های عصبی
 ۳. کاربردهای یادگیری عمیق در پایش ماشینی سلامت
 - ۳.۱. AE و انواع آن برای پایش ماشینی سلامت
 - ۳.۲. RBM و انواع آن برای پایش ماشینی سلامت
 - ۳.۳. CNN برای پایش ماشینی سلامت
 - ۳.۴. RNN برای پایش ماشینی سلامت
 - ۳.۵. استخراج مشخصه خطا برای MHMS مبتنی بر DL
 - ۳.۵.۱. حوزه زمانی
 - ۳.۵.۲. حوزه فرکانس
 - ۳.۵.۳. حوزه زمانی-فرکانس
 ۴. ارزیابی‌های تجربی از تکنیک‌های مختلف DL
 - ۴.۱. جزئیات پیاده‌سازی
 - ۴.۲. نتایج تجربی
 ۵. خلاصه و مسیرهای آینده
- تصدیق
- منابع

مقدمه

اینترنت اشیا صنعتی (IoT) و تکنیک‌های مبتنی بر داده‌ها با قادر ساختن شبکه‌های رایانه‌ای برای جمع‌آوری حجم عظیمی از داده‌ها از ماشین‌هایی که به آنها متصل هست و تبدیل داده‌های ماشینی بزرگ به اطلاعات عملی، انقلابی در تولید ایجاد کرده‌اند [۱-۳]. به عنوان یک مولفه کلیدی در سیستم تولید مدرن، پایش ماشینی سلامت به طور کامل، انقلاب کلان داده را پذیرفته است. در مقایسه با مدل‌سازی از بالا به پایین ارائه شده توسط مدل‌های مبتنی بر فیزیک سنتی [۴-۶]، سیستم‌های پایش ماشینی سلامت داده محور، الگوی جدیدی از راه‌حل از پایین به بالا را برای تشخیص عیوب پس از وقوع خرابی‌های خاص (تشخیص) و پیش بینی شرایط کاری آینده و عمر مفید باقی‌مانده (پیش بینی)، پیشنهاد داده است [۷، ۱]. همانطور که همه می‌دانیم، شرایط کاری پیچیده و پر سر و صدا، مانعی برای ساخت مدل‌های فیزیکی می‌شود که مدل‌سازی سیستم‌های پیچیده دینامیکی را بسیار دشوار می‌سازد [۹، ۸]. اکثر این مدل‌های مبتنی بر فیزیک، نمی‌توانند با داده‌های اندازه‌گیری شده آنلاین به‌روزرسانی شوند، که در نتیجه اثربخشی و انعطاف‌پذیری آنها را محدود می‌کند. از سویی، با توسعه چشمگیر حسگرها، شبکه‌های حسگر و سیستم‌های محاسباتی، مدل‌های پایش ماشینی سلامت مبتنی بر داده، بسیار جذاب شده‌اند. برای استخراج دانش مفید و تصمیم‌گیری مناسب از کلان داده‌ها، تکنیک‌های یادگیری ماشینی به عنوان یک راه حل قدرتمند در نظر گرفته شده است. به عنوان داغ‌ترین شاخه فرعی یادگیری ماشینی، یادگیری عمیق می‌تواند به عنوان پلی برای اتصال کلان داده‌های ماشینی و پایش هوشمند ماشینی سلامت، عمل کند.

به عنوان شاخه‌ای از یادگیری ماشین، یادگیری عمیق، سعی می‌کند تا یک ارائه سلسله مراتبی را در پشت داده‌ها مدل‌سازی کند و الگوها را از طریق چندین لایه استکینگ از ماژول‌های پردازش اطلاعات در معماری‌های سلسله مراتبی طبقه بندی کند (پیش بینی). اخیراً، یادگیری عمیق، به طور موفقیت‌آمیزی در زمینه‌های مختلفی مانند بصری رایانه، تشخیص خودکار گفتار، پردازش زبان طبیعی، تشخیص صدا و بیوانفورماتیک، مورد استفاده قرار گرفته است [۱۰-۱۳]. در واقع، یادگیری عمیق، ایده جدیدی نیست و آن حتی به دهه ۱۹۴۰ بر می‌گردد [۱۵، ۱۴]. محبوبیت امروزه یادگیری عمیق می‌تواند به جنبه‌های زیر کمک کند:

- *افزایش قدرت محاسباتی:* ظهور واحد پردازشگر گرافیکی (GPU)، کاهش هزینه سخت افزار، زیرساخت نرم افزاری بهتر و اتصال سریعتر به شبکه، همه این موارد، زمان اجرای مورد نیاز الگوریتم‌های یادگیری عمیق را به میزان قابل توجهی کاهش می‌دهند. به عنوان مثال، همانطور که در [۱۶] گزارش شده، زمان مورد نیاز برای یادگیری یک شبکه باور عمیق چهار لایه با ۱۰۰ میلیون پارامتر آزاد می‌تواند از چند هفته به حدود یک روز کاهش یابد.

- *افزایش حجم داده‌ها*: شکی نیست که عصر کلان داده، در راه است. تقریباً همه فعالیت‌های ما دیجیتالی شده، توسط رایانه‌ها و حسگرها ضبط شده، به اینترنت متصل شده و در فضای ابری ذخیره می‌شوند. همانطور که در [۱] اشاره شد که در کاربردهای مرتبط با صنعت مانند انفورماتیک صنعتی و الکترونیک، تقریباً ۱۰۰۰ اگزابایت در سال تولید می‌شود و در ده سال آینده می‌توان یک افزایش ۲۰ برابری را متصور بود. مطالعه در [۳] پیش‌بینی می‌کند که ۳۰ میلیارد ماشین تا سال ۲۰۲۰ به هم متصل خواهند شد. بنابراین، حجم عظیمی از داده‌ها قادر به جبران افزایش پیچیدگی پشت یادگیری عمیق و بهبودی قابلیت تعمیم آن هستند.

- *تحقیقات یادگیری عمیق پیشرفته*: اولین نقطه عطف در یادگیری عمیق، روش پیش‌آموزشی به روشی بدون نظارت است [۱۷]، جایی که هینتون پیشنهاد داد که یک لایه در یک زمان از طریق ماشین بولتزمن محدود شده (RBM)، از قبل آموزش داده شود و سپس با استفاده از پس انتشار در سال ۲۰۰۷، تنظیم دقیق شود. آن ثابت شده که این برای آموزش شبکه‌های عصبی چند لایه، موثر است.

با توجه به قابلیت یادگیری عمیق برای پرداختن به داده‌ها در مقیاس بزرگ و یادگیری نمایش چندمقیاسی/چند سطحی/سلسله‌مراتبی، یادگیری عمیق می‌تواند راه حلی قدرتمند و موثر برای سیستم‌های پایش ماشینی سلامت (MHMS) باشد. MHMS مبتنی بر داده رایج، به طور معمول شامل بخش‌های کلیدی زیر است: طراحی ویژگی دست ساز، استخراج/انتخاب ویژگی و آموزش مدل. مجموعه مناسبی از ویژگی‌ها طراحی شده و سپس برای برخی از الگوریتم‌های یادگیری ماشین کم عمق شامل ماشین‌های بردار پشتیبان (SVM)، بیز ساده (NB)، رگرسیون لجستیک [۱۸-۲۰] ارائه می‌شود. همچنین مشخص شده که نمایش داده‌ها، که برای الگوریتم‌های یادگیری ماشینی، ارائه می‌شود، کارایی را محدود می‌کند [۲۱]. با این حال، طراحی ویژگی‌های مناسب و انجام انتخاب ویژگی، دشوار است. برای کم کردن این مشکل، روش‌های استخراج/انتخاب ویژگی، که می‌تواند به عنوان نوعی آمیختگی اطلاعاتی در نظر گرفته شود، بین طراحی ویژگی دست ساز و مدل‌های طبقه‌بندی/رگرسیون، انجام بگیرد [۲۲-۲۴]. با این حال، طراحی دستی ویژگی‌ها برای یک دامنه پیچیده به نیروی انسانی زیادی نیاز دارد و نمی‌توان آن را به صورت آنلاین به‌روزرسانی کرد. علاوه بر این، به تخصص قابل توجهی از کارورز نیز نیاز دارد که همیشه در دسترس نیست. در نهایت، سه مازول فوق شامل طراحی ویژگی، استخراج/انتخاب ویژگی و آموزش مدل، نمی‌توانند به طور مشترک بهینه شوند که در نتیجه ممکن است مانع از کارایی نهایی کل سیستم شود. هدف MHMS مبتنی بر یادگیری عمیق (MHMS مبتنی بر DL)، استخراج تمثال‌های سلسله‌مراتبی از داده‌های ورودی با ساخت شبکه‌های عصبی عمیق با چند لایه تغییرشکل‌های غیر خطی است. به طور شهودی،

عملیات یک لایه را می‌توان به عنوان تبدیل از مقادیر ورودی به مقادیر خروجی در نظر گرفت. بنابراین، استفاده از یک لایه می‌تواند نمایش جدیدی از داده‌های ورودی را بیاموزد و سپس، ساختار استکینگ چندین لایه می‌تواند MHMS را قادر سازد تا مفاهیم پیچیده را از مفاهیم ساده‌ای که می‌توان از ورودی خام ساخت، استنتاج کند. علاوه بر این، MHMS مبتنی بر DL به یک سیستم سرتاسری دست پیدا می‌کند که می‌تواند به طور خودکار بازنمایی‌های داخلی را از ورودی خام بیاموزد و اهداف را پیش‌بینی کند. در مقایسه با MHMS مبتنی بر داده‌های مرسوم، MHMS مبتنی بر DL برای طراحی ویژگی‌های دست ساز به نیروی انسانی و دانش گسترده نیاز ندارد. همه پارامترهای مدل از جمله ماژول ویژگی و ماژول طبقه بندی/رگرسیون الگو را می‌توان به طور مشترک، آموزش داد. بنابراین، مدل‌های مبتنی بر DL را می‌توان برای رسیدگی به پایش ماشینی سلامت با روشی بسیار کلی به کار برد. به عنوان مثال، این امکان وجود دارد که مدل آموزش دیده برای مشکل تشخیص عیب را بتوان، تنها با جایگزینی لایه بیشینه هموار همراه بالایی با یک لایه رگرسیون خطی که نیاز به آموزش مجدد دارد، برای پیش‌آگهی، استفاده کرد [۲۵]. مقایسه بین MHMS مبتنی بر داده‌های رایج و MHMS مبتنی بر DL در جدول ۱ ارائه شده است. یک تصویر سطح بالا از اصول و رای این سه نوع MHMS که در بالا مورد بحث قرار گرفت در شکل ۱ نشان داده شده است.

Table 1
Summary on comparison between conventional data-driven MHMS and DL-based MHMS.

MHMS	
Conventional Data-driven Methods	Deep Learning Methods
<i>Expert knowledge and extensive human labor required for Hand-crafted features</i>	<i>End-to-end structure without hand-crafted features</i>
<i>Individual modules are trained step-by-step</i>	<i>All parameters are trained jointly</i>
<i>Unable to model large-scale data</i>	<i>Suitable for large-scale data</i>

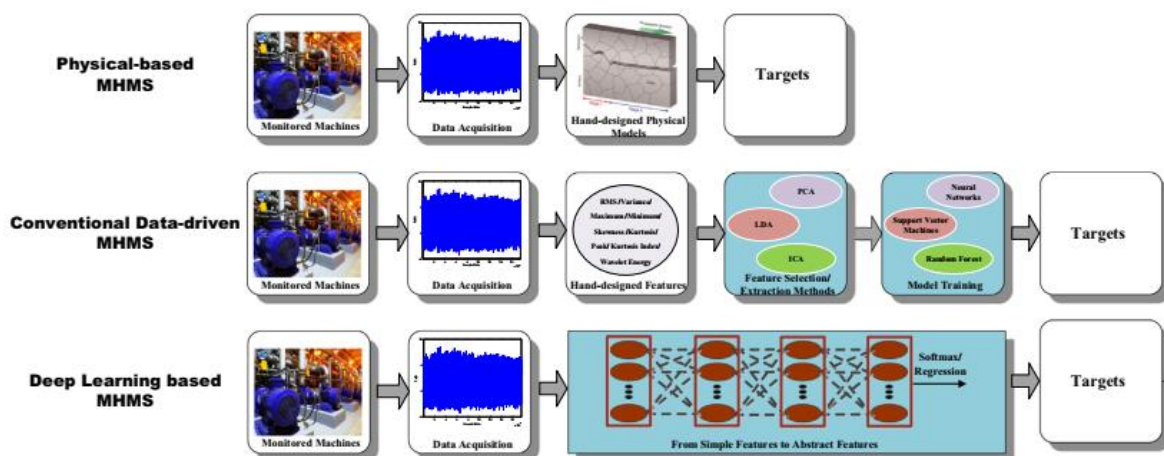


Fig. 1. Frameworks showing three different MHMS including Physical Models, Conventional Data-driven Models and Deep Learning Models. Shaded boxes denote data-driven components.

مدل‌های یادگیری عمیق دارای چندین نوع مختلف مانند خود رمزگذارها [۲۶]، شبکه باور عمیق [۲۷]، ماشین‌های بولتزمن عمیق [۲۸]، شبکه‌های عصبی کانولوشن [۲۹] و شبکه‌های عصبی بازگشتی [۳۰] می‌باشند. در طول سال‌های اخیر، محققان مختلف، موفقیت این مدل‌های یادگیری عمیق را در کاربرد پایش ماشینی سلامت نشان داده‌اند. این مقاله تلاش می‌کند یک نمای کلی از آخرین کارهای MHMS مبتنی بر DL ارائه دهد که بر فناوری‌های پیشرفته تأثیر می‌گذارد. در مقایسه با این مرزهای یادگیری عمیق از جمله بصری کامپیوتری و پردازش زبان طبیعی، جامعه پایش ماشینی سلامت در حال پیشرفت است و شاهد یک تحقیق در حال ظهور می‌باشد. بنابراین، هدف از این مطالعه، ارائه محققان و مهندسين در زمینه سیستم پایش ماشینی سلامت، دیدگاهی جهانی از این موضوع داغ و فعال و کمک به آنها در کسب دانش اولیه، به کارگیری سریع مدل‌های یادگیری عمیق و توسعه MHMS مبتنی بر DL جدید می‌باشد. ادامه این مقاله به شرح زیر تنظیم شده است. اطلاعات اولیه در مورد این مدل یادگیری عمیق که در بالا ذکر شد در بخش ۲ آورده شده است. سپس، بخش ۳ به بررسی کاربرد مدل‌های یادگیری عمیق در پایش ماشینی سلامت، می‌پردازد. در بخش ۴، یک مطالعه تجربی در یک کار پایش بینی خوردگی ابزار انجام شده است. در نهایت، بخش ۵، خلاصه‌ای از دستاوردهای اخیر MHMS مبتنی بر DL ارائه می‌کند و برخی از روندهای بالقوه یادگیری عمیق در پایش ماشینی سلامت را مورد بحث قرار می‌دهد. به عنوان یک مقاله مروری، یک بررسی جامع از تلاش‌های تحقیقاتی اخیر بر روی سیستم پایش ماشینی سلامت مبتنی بر یادگیری عمیق ارائه می‌شود تا تصویر کاملی از تحقیقات مرتبط با بهترین فناوری‌های روز را برای خوانندگان ارائه کند و نوآوری بالقوه در این زمینه را تقویت کند. علاوه بر این، پیاده‌سازی چندین MHMS مبتنی بر DL، که عمومی می‌باشد و محققان/مهندسان می‌توانند به سرعت این موضوع را درک کنند و به حوزه تحقیقات MHMS مبتنی بر DL کمک کند.

۲. یادگیری عمیق

یادگیری عمیق که از شبکه عصبی مصنوعی نشات گرفته است، شاخه‌ای از یادگیری ماشینی است که توسط پردازش غیرخطی چندلایه، مشخص می‌شود و سعی می‌کند نمایش سلسله مراتبی داده‌ها را آموزش دهد. تا به امروز، معماری‌های مختلف از یادگیری عمیق وجود دارد و این موضوع تحقیقاتی به سرعت در حال رشد است، و در آن مدل‌های جدید حتی هر هفته توسعه می‌یابند. جامعه، کاملاً باز است و تعدادی آموزش یادگیری عمیق و کتاب با کیفیت خوب وجود دارد [۳۱، ۳۲]. بنابراین، تنها یک مقدمه کوتاه برای برخی تکنیک‌های اصلی یادگیری عمیق که در پایش ماشینی سلامت به کار گرفته شده، ارائه می‌شود. در ادامه، چهار سبک عمیق شامل خودرمزنگار ، RBM، CNN، RNN و انواع مربوط به آنها بررسی می‌شود.

۲.۱. خودرمزنگارها (AE) و انواع آن

به عنوان یک شبکه عصبی پیشخور، خودرمزنگار، از دو فاز شامل رمزگذار و رمزگشا تشکیل شده که برای یادگیری نمایش جدیدی از داده‌ها با تلاش برای بازسازی داده‌های ورودی طراحی شده است. رمزگذار، یک ورودی x را می‌گیرد و آن را از طریق نگاشت غیرخطی به صورت شکل زیر به یک ارائه پنهان h تبدیل می‌کند:

$$\mathbf{h} = \varphi(\mathbf{W}\mathbf{x} + \mathbf{b}) \quad (1)$$

در اینجا، φ یک تابع فعال سازی غیرخطی است. توابع فعال سازی رایج شامل بیشینه هموار (softmax)، relu ، tanh ، حلقوی (sigmoid) و غیره هستند. سپس، رمزگشا ارائه پنهان را به شکلی مشابه شکل زیر برای نمایش اصلی نگاشت (نقشه برداری) می‌کند:

$$\mathbf{z} = \varphi(\mathbf{W}'\mathbf{h} + \mathbf{b}') \quad (2)$$

پارامترهای مدل شامل $\theta = [\mathbf{W}, \mathbf{b}, \mathbf{W}', \mathbf{b}']$ برای به حداقل رساندن خطای بازسازی بین \mathbf{z} و \mathbf{x} بهینه شده‌اند. یکی از معیارهای رایج برای میانگین خطای بازسازی در مجموعه ای از نمونه داده N ، خطای مربع است و مسئله بهینه سازی مربوطه را می‌توان به صورت زیر نوشت:

$$\min_{\theta} \frac{1}{N} \sum_i \|\mathbf{x}_i - f_{\theta}(\mathbf{x}_i)\|_2^2 \quad (3)$$

که در اینجا \mathbf{x}_i نمونه i ام است. آن به وضوح نشان داده که AE را می‌توان به روشی بدون نظارت آموزش داد. ارائه پنهان h را می‌توان به عنوان نمایشی انتزاعی و معنادار برای نمونه داده x در نظر گرفت.

۲.۱.۱. اضافه شدن پراکندگی

برای جلوگیری از تبدیل آموخته شده به هویت و منظم کردن خودرمزنگارها، محدودیت پراکندگی بر واحدهای پنهان اعمال می‌شود [۳۳]. تابع بهینه سازی مربوطه به صورت زیر به روز می‌شود:

$$\min_{\theta} \frac{1}{N} \sum_i \|\mathbf{x}_i - f_{\theta}(\mathbf{x}_i)\|_2^2 + \beta \sum_j KL(p||p_j) \quad (4)$$

در اینجا، m اندازه لایه پنهان است، جمله دوم مجموع واگرایی KL بر روی واحدهای پنهان و β وزن کنترل کننده برای اصطلاح جریمه پراکندگی است. واگرایی KL در نوروں پنهان λ ام، به صورت زیر مشخص می‌شود:

$$KL(p||p_j) = p \log \left(\frac{p}{p_j} \right) + (1-p) \log \left(\frac{1-p}{1-p_j} \right) \quad (5)$$

که در اینجا، p میانگین هدف فعال سازی از پیش تعریف شده و p_j میانگین فعال سازی نوروں پنهان λ ام در کل مجموعه داده است. با توجه به کوچک بودن p ، اضافه کردن محدودیت پراکندگی می‌تواند ارائه پنهان آموخته شده را به یک ارائه پراکنده، تبدیل کند. بنابراین، نوع AE به عنوان خودرمزنگار پراکنده، نامگذاری شده است.

۲.۱.۲. اضافه شدن نویز زدایی

جدا از AE رایج، حذف نویز AE، یک نسخه خراب از داده‌ها را به عنوان ورودی در نظر می‌گیرد و آموزش می‌بیند که ورودی X تمیز را از نمونه خراب $X \sim$ خود، بازسازی یا نویز زدایی کند. متداول‌ترین نویز پذیرفته شده نویز حذفی یا نویز با پوشش باینری است که به طور تصادفی، کسری از ویژگی‌های ورودی را صفر می‌کند [۲۶]. نوع AE، خودرمنگار حذف نویز (DA) است که می‌تواند ارائه قوی‌تری را بیاموزد و از یادگیری تبدیل هویت، جلوگیری کند.

۲.۱.۳. ساختار استکینگ

چندین DA را می‌توان در کنار هم قرار داد تا یک شبکه عمیق را شکل دهند و با تغذیه خروجی‌های لایه l ام به عنوان ورودی برای لایه $(l+1)$ ام، ارائه‌هایی را بیاموزند [۲۶]. و بالطبع، آموزش، بصورت یک لایه حریصانه در طی زمان انجام می‌گیرد.

از آنجایی که خودرمنگار را می‌توان به روشی بدون نظارت آموزش داد، خودرمنگار، به ویژه خودرمنگار حذف نویز استکینگ (SDA)، می‌تواند یک راه حل موثر پیش آموزش را از طریق مقداردهی اولیه وزن شبکه عصبی عمیق (DNN) برای آموزش مدل ارائه دهد. پس از آموزش لایه‌ای SDA، پارامترهای خودرمنگار را می‌توان روی مقدار اولیه برای تمام لایه‌های پنهان DNN تنظیم کرد. سپس، تنظیم دقیق پایش شده برای به حداقل رساندن خطای پیش‌بینی بر روی داده‌های آموزشی برچسب‌گذاری شده، انجام می‌شود. معمولاً یک لایه رگرسیون/بیشینه هموار در بالای شبکه اضافه می‌شود تا خروجی آخرین لایه در AE را برای اهداف نشان دهد. کل فرآیند در شکل ۲ نشان داده شده است. پروتکل پیش‌آموزشی مبتنی بر SDA می‌تواند سبب این مساله شود که مدل‌های DNN در مقایسه با مقداردهی اولیه تصادفی دلخواه، قابلیت همگرایی بهتری داشته باشند. لازم به ذکر است، آموزش شبکه‌های عصبی عمیق به دلیل توابع فعال‌سازی غیرخطی \tanh یا سیگموئید معمولاً از مشکلات غیب شدن/انفجار، رنج می‌برد. بنابراین، آموزش بدون نظارت فعال شده توسط AE، معنادار و قدرتمند است. با این حال، فعال‌سازی relu که در سال ۲۰۱۲ پیشنهاد شد، این مشکل را برطرف کرد. آموزش نظارتی بر شبکه‌های عصبی عمیق مانند شبکه عصبی کانولوشن عمیق و شبکه عصبی بازگشتی، امکان پذیر شد (شکل ۳ را ببینید).

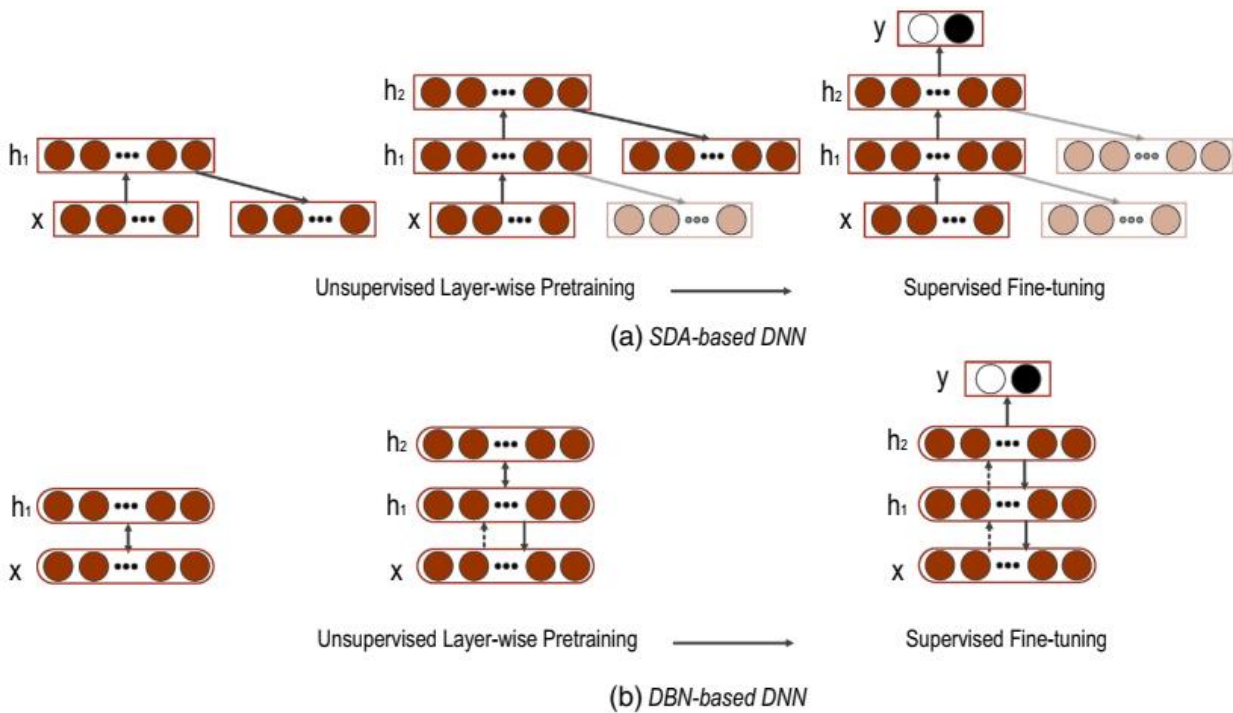


Fig. 2. Illustrations for unsupervised pre-training and supervised fine-tuning of SAE-DNN (a) and DBN-DNN (b).




Fig. 3. Frameworks showing RBM, DBN and DBM. Shaded boxes denote hidden units.

۲.۲. RBM و انواع آن

به عنوان یک شکل خاص از میدان تصادفی مارکوف، ماشین بولتزمن محدود شده (RBM)، یک شبکه عصبی دولایه است که یک نمودار دو بخشی را شکل می‌دهد که از دو گروه واحد شامل واحدهای مرئی V و واحدهای پنهان h ، تحت محدودیت وجود یک اتصال متقارن، تشکیل شده است. در بین واحدهای مرئی و واحدهای پنهان،

ارتباطی بین گره‌ها با یک گروه، وجود ندارد. با توجه به پارامترهای مدل $\theta = [\mathbf{W}, \mathbf{b}, \mathbf{a}]$ ، تابع انرژی را می‌توان به صورت زیر مشخص نمود:

$$E(\mathbf{v}, \mathbf{h}; \theta) = -\sum_{i=1}^I \sum_{j=1}^J w_{ij} v_i h_j - \sum_{i=1}^I b_i v_i - \sum_{j=1}^J a_j h_j \quad (6)$$

که در اینجا، w_{ij} وزن متصل بین واحد مرئی v_i است که عدد کل آن I است و واحد پنهان h_j که عدد کل آن به ترتیب J ، b_i و a_j است و آنها بیانگر اصطلاحات بایاس برای واحدهای مرئی و واحدهای پنهان هستند. توزیع مشترک بر روی تمام واحدها، بر اساس تابع انرژی $E(\mathbf{v}, \mathbf{h}; \theta)$ به صورت زیر محاسبه می‌شود:

$$p(\mathbf{v}, \mathbf{h}; \theta) = \frac{\exp(-E(\mathbf{v}, \mathbf{h}; \theta))}{Z} \quad (7)$$

در اینجا $Z = \sum_{\mathbf{h}, \mathbf{v}} \exp(-E(\mathbf{v}, \mathbf{h}; \theta))$ تابع تقسیم یا ضریب نرمالیدن است. سپس، احتمالات شرطی واحدهای پنهان و مرئی \mathbf{h} و \mathbf{v} را می‌توان به صورت زیر محاسبه کرد:

$$p(h_j = 1 | v; \theta) = \delta \left(\sum_{i=1}^I w_{ij} v_i + a_j \right) \quad (8)$$

$$p(v_i = 1 | v; \theta) = \delta \left(\sum_{j=1}^J w_{ij} h_j + b_i \right) \quad (9)$$

که در اینجا، δ به عنوان یک تابع لجستیک تعریف می‌شود، یعنی $\delta(x) = \frac{1}{1+\exp(x)}$. RBM. برای به حداکثر رساندن احتمال مشترک آموزش داده شده است. یادگیری \mathbf{W} از طریق روشی به نام واگرایی متضاد (CD) انجام می‌گیرد [۳۴].

۲.۲.۱. شبکه باور عمیق

شبکه باور عمیق (DBN) را می‌توان با روی هم انباشتن چندین RBM ساخت، که در آن خروجی لایه l ام (واحدهای پنهان) به عنوان ورودی لایه $(l+1)$ ام (واحدهای مرئی) استفاده می‌شود [۳۵]. مشابه SDA، DBN را می‌توان به روشی حریصانه و بدون نظارت لایه‌ای، آموزش داد. پس از پیش‌آموزش، پارامترهای این سبک عمیق را می‌توان با توجه به یک پروکسی برای احتمال ورود به سیستم DBN و یا با توجه به برچسب‌های داده‌های آموزشی با افزودن یک لایه بیشینه هموار به عنوان لایه بالایی تنظیم کرد که در شکل ۲(b)، نشان داده شده است.

۲.۲.۲. ماشین بولتزن عمیق

شبکه بولتزن عمیق (DBM) را می‌توان به عنوان یک RBM با ساختار عمیق در نظر گرفت که در آن واحدهای پنهان به جای یک لایه واحد در سلسله مراتبی از لایه‌ها گروه‌بندی می‌شوند [۲۸]. به دنبال محدودیت اتصال

RMBها، تنها، اتصال کامل بین لایه‌های بعدی وجود دارد و هیچ اتصالی درون لایه‌ها یا بین لایه‌های غیرمجاور، مجاز نیست. تفاوت اصلی بین DBN و DBM در این است که DBM یک مدل گرافیکی کاملاً بدون جهت است، در حالی که DBN، یک مدل ترکیبی جهت دار/غیر جهت دار است. جدا از DBN که می‌تواند به صورت لایه‌ای آموزش داده شود، DBM به عنوان یک مدل مشترک، آموزش داده می‌شود. بنابراین، آموزش DBM از نظر محاسباتی گرانتر از DBN است.

۲.۳. شبکه عصبی کانولوشن

شبکه‌های عصبی کانولوشن (CNN) در ابتدا توسط LeCun [۳۶] برای تصویر پردازش پیشنهاد شد که توسط دو ویژگی کلیدی یعنی وزن‌های مشترک فضایی و تجمیع (پولینگ) فضایی، مشخص می‌شود. مدل‌های CNN موفقیت خود را در برنامه‌های مختلف بصری کامپیوتری، نشان داده‌اند [۳۶-۳۸] که به طور معمول در آن داده‌های ورودی، دوبعدی هستند. همچنین CNN برای رسیدگی به داده‌های متوالی از جمله پردازش زبان طبیعی و تشخیص گفتار، معرفی شده است [۳۹،۴۰].

هدف CNN یادگیری ویژگی‌های انتزاعی با لایه‌های کانولوشن متناوب و استکینگ و لایه‌های تجمیع شده است. در CNN، لایه‌های کانولوشن (هسته‌های کانولوشن)، چندین فیلتر موضعی را با داده‌های ورودی خام ترکیب و ویژگی‌های موضعی غیرمتغیر ترجمه را ایجاد می‌کنند و لایه‌های ادغامی بعدی، ویژگی‌هایی با طول ثابت بر روی پنجره‌های کشویی داده‌های ورودی خام همراه با رعایت چندین قانون مانند میانگین، ماکزیمم و غیره، استخراج می‌کنند. با توجه به اینکه 2D-CNN در تحقیقات قبلی و در مقایسه با 1D-CNN، به طور گسترده نشان داده شد، در اینجا، فقط جزئیات ریاضی مربوط به 1D-CNN، به شرح زیر ارائه می‌شود:

اولاً، فرض کنید که داده‌های ترتیبی ورودی $\mathbf{x} = [\mathbf{x}_1, \dots, \mathbf{x}_T]$ است که T طول دنباله و $\mathbf{x}_i \in \mathbb{R}^d$ در هر مرحله زمانی، قرار دارد.

۲.۳.۱. کانولوشن

حاصل ضرب نقطه‌ای بین بردار فیلتر $\mathbf{u} \in \mathbb{R}^{md}$ و ارائه بردار الحاقی $\mathbf{x}_{i+i-m-1}$ ، عملیات کانولوشن را به صورت زیر تعریف می‌کند:

$$c_i = \varphi(\mathbf{u} \cdot \mathbf{x}_{i+i-m-1} + b) \quad (10)$$

که در اینجا نشان دهنده حاصلضرب نقطه‌ای \mathbf{u} و b است که آنها به ترتیب عبارت بایاس و تابع فعال‌سازی غیرخطی را نشان می‌دهند. یک پنجره طولی است که از مرحله زمانی i شروع می‌شود و به شرح زیر است:

$$\mathbf{x}_{i+i-m-1} = \mathbf{x}_i \oplus \mathbf{x}_{i+1} \oplus \dots \oplus \mathbf{x}_{i+m-1} \quad (11)$$

در اینجا، \oplus عملیات الحاقی دو بردار است. همانطور که در معادله (۱۰) تعریف شد، مقیاس خروجی C_i را می‌توان به عنوان فعال شدن فیلتر u بر روی توالی مربوطه $\mathbf{x}_{t:t+m-1}$ در نظر گرفت. با کشیدن پنجره فیلترینگ از مرحله زمانی شروع تا مرحله زمانی پایانی، می‌توان یک نگاشت ویژگی را به صورت برداری ارائه داد:

$$\mathbf{c}_j = [c_1, c_2, \dots, c_{l-m+1}] \quad (12)$$

در اینجا، شاخص j نمایانگر فیلتر j ام است. آن مربوط به چند پنجره به صورت $\{\mathbf{x}_{1:m}, \dots, \mathbf{x}_{l-m+1:l}\}$ است.

۲.۳.۲. تجمیع (pooling)

لایه تجمیع می‌تواند طول نگاشت ویژگی را کاهش دهد، که می‌تواند تعداد پارامترهای مدل را بیشتر، به حداقل برساند. این عملیات تجمیع رایج شامل تجمیع ماکزیمم و میانگین است. در ادامه، تجمیع ماکزیمم به تفصیل توضیح داده شده است. ابرپارامتر لایه تجمیعی، طول تجمیع است که با s نشان داده می‌شود. عملیات ماکزیمم به این صورت است که یک مقدار بیش از مقادیر متوالی s در نگاشت ویژگی \mathbf{c}_j ، گرفته می‌شود. سپس، بردار ویژگی فشرده را می‌توان به صورت زیر بدست آورد:

$$\mathbf{h} = [h_1, h_2, \dots, h_{\lfloor \frac{l}{s} \rfloor}] \quad (13)$$

در اینجا، $h_j = \max(c_{(j-1)s}, c_{(j-1)s+1}, \dots, c_{js-1})$ است. سپس از طریق تناوب دو لایه بالا: لایه‌های کانولوشن و تجمیعی حداکثر، لایه‌های کاملاً متصل و یک لایه بیشینه هموار، به طور معمول به عنوان لایه‌های بالایی برای پیش‌بینی، اضافه می‌شوند. برای ارائه یک تصویر واضح، چارچوبی برای یک CNN یک لایه در شکل ۴، نمایش داده شده است.




Fig. 4. Illustrations for one-layer CNN that contains one convolutional layer, one pooling layer, one fully-connected layer, and one softmax layer.

۲.۴. شبکه عصبی بازگشتی

همانطور که در فرمول [۱۴] بیان شد، شبکه‌های عصبی بازگشتی (RNNها)، عمیق‌ترین شبکه‌های عصبی هستند که می‌توانند حافظه‌های دنباله‌ای با طول دلخواه را از الگوهای ورودی، تولید و آدرس‌دهی کنند. RNN، قادر به ایجاد ارتباط بین واحدهای ناشی از چرخه مستقیم هست. جدا از شبکه عصبی پایه، پرسپترون چندلایه که فقط می‌تواند از داده‌های ورودی برای بردارهای هدف، نقشه‌برداری انجام دهد، RNN قادر است از کل تاریخچه ورودی‌های قبلی به بردارهای هدف، نقشه‌برداری انجام دهد و اجازه می‌دهد تا حافظه ورودی‌های قبلی در وضعیت داخلی شبکه‌ها، نگهداری شود. RNNها را می‌توان از طریق پس انتشار در طول زمان برای وظایف پایش شده همراه با داده‌های ورودی متوالی و خروجی‌های هدف، آموزش داد [۴۲، ۳۰، ۴۱].

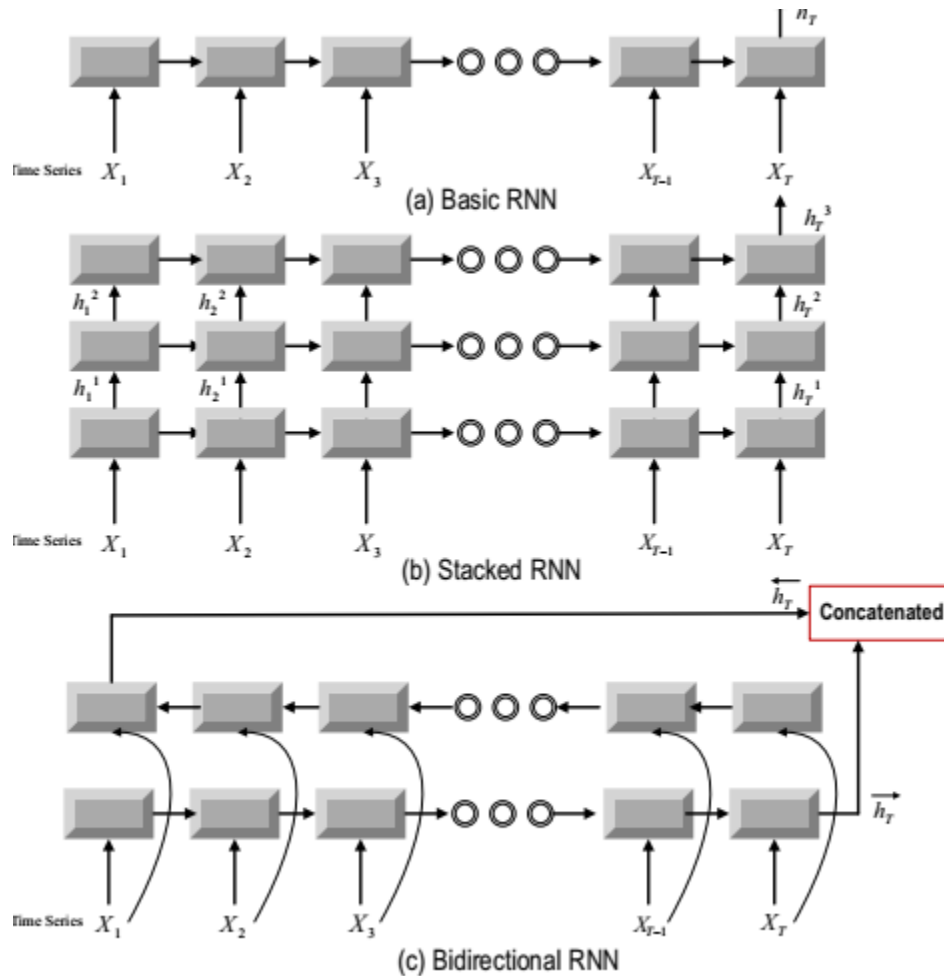


Fig. 5. Illustrations of normal RNN, stacked RNN and bidirectional RNN.

همانطور که در شکل ۵ (a) نشان داده شده، RNN می‌تواند داده‌های متوالی را با استفاده از حافظه داخلی خود آدرس‌دهی کند. تابع گذار تعریف شده در هر مرحله زمانی t ، اطلاعات زمان جاری x_t و خروجی پنهان قبلی h_{t-1} را می‌گیرد و خروجی پنهان فعلی را به صورت زیر به روز می‌کند:

$$\mathbf{h}_t = \mathbb{H}(\mathbf{x}_t, \mathbf{h}_{t-1}) \quad (14)$$

در اینجا، \mathbb{H} به عنوان تابع تبدیل غیرخطی و قابل تمایز، تعریف می‌شود. پس از پردازش کل توالی، خروجی پنهان در آخرین مرحله زمانی، یعنی h_T ، ارائه آموخته شده داده‌های ترتیبی ورودی است که طول آن T است. یک پرسپترون چندلایه معمولی (MLP) در بالا اضافه می‌شود تا ارائه به دست آمده h_T برای هدف را ترسیم کند. توابع مختلف گذار می‌توانند، به مدل‌های مختلف RNN منجر شوند. ساده‌ترین آنها RNN وانیلی است که به شرح زیر ارائه می‌شود:

$$\mathbf{h}_t = \varphi(\mathbf{W}\mathbf{x}_t + \mathbf{H}\mathbf{h}_{t-1} + \mathbf{b}) \quad (15)$$

که در اینجا، \mathbf{W} و \mathbf{H} نشان دهنده ماتریس‌های تبدیل و \mathbf{b} بردار بایاس است. و φ نشان دهنده تابع فعال سازی غیرخطی مانند توابع سیگموئید و \tanh است. با توجه به مساله گرادیان ناپدید شده در طول پس انتشار برای آموزش مدل، RNN وانیلی ممکن است وابستگی‌های طولانی‌مدت را ضبط نکند. بنابراین، حافظه بلندمدت (LSTM) و واحدهای بازگشتی گیتی (GRU) برای جلوگیری از ناپدید شدن یا انفجار خطاهای منتشر شده، ارائه شدند [۴۳-۴۷]. ایده اصلی پشت این گونه‌های پیشرفته RNN این است که گیت‌ها برای جلوگیری از مشکل وابستگی طولانی‌مدت معرفی شده و هر واحد تکراری را قادر می‌سازد تا وابستگی‌ها در مقیاس‌های زمانی مختلف را به‌طور سازگارانه، ضبط کند.

علاوه بر این توابع انتقال پیشنهادی پیشرفته، مانند LSTM و GRU، ساختار چندلایه و دو جهته بازگشتی، می‌تواند ظرفیت و انعطاف‌پذیری مدل را افزایش دهد. همانطور که در شکل ۵ (b) نشان داده شده، ساختار چند لایه می‌تواند خروجی پنهان یک لایه بازگشتی را قادر بسازد در طول زمان، منتشر شود و به عنوان داده ورودی برای لایه بازگشتی بعدی استفاده شود. همانطور که در شکل ۵ (c) نشان داده شده، ساختار برگشتی دو طرفه قادر است داده‌های دنباله را در دو جهت شامل مسیرهای جلو و عقب با دو لایه مخفی مجزا، پردازش کند. معادلات زیر تابع لایه پنهان مربوطه و به همین ترتیب فرآیندهای جلو و عقب را نشان می‌دهند.

$$\begin{aligned} \vec{\mathbf{h}}_t &= \vec{\mathbb{H}}(\mathbf{x}_t, \vec{\mathbf{h}}_{t-1}), \\ \overleftarrow{\mathbf{h}}_t &= \overleftarrow{\mathbb{H}}(\mathbf{x}_t, \overleftarrow{\mathbf{h}}_{t+1}). \end{aligned} \quad (16)$$

سپس، بردار نهایی h_T ، بردار الحاقی خروجی‌های فرآیندهای جلو و عقب است که به شرح زیر است:

$$\mathbf{h}_T = \vec{\mathbf{h}}_T \oplus \overleftarrow{\mathbf{h}}_1 \quad (17)$$

۲.۵. روش‌های بهینه‌سازی شبکه‌های عصبی

برای یادگیری پارامترهای بهینه برای مدل‌های شبکه عصبی، کاهش گرادیانی پرکاربردترین روش است. کاهش گرادیانی برای به حداقل رساندن یک تابع هدف $J(\theta)$ با به روز رسانی پارامترهای θ در جهت مخالف گرادیان تابع هدف $\nabla J(\theta)$ w.r.t به پارامترها انجام می‌شود، که در آن از نرخ یادگیری برای کنترل اندازه مراحل تا حصول یک حداقل، استفاده می‌شود. مروری بر روش‌های مختلف بهینه‌سازی کاهش گرادیانی برای مدل‌های یادگیری عمیق، در اینجا ارائه شده است [۴۸]. با این حال، یک نکته مشکل‌ساز این است که مقدار اولیه وزن بر همگرایی تأثیر می‌گذارد به طوری که لازم است طرح اولیه‌سازی پارامترهای مناسب برای مدل، انتخاب شود [۴۹].

۳. کاربردهای یادگیری عمیق در پایش ماشینی سلامت

سال‌های متوالی، MLP رایج، در زمینه پایش ماشینی سلامت استفاده می‌شود [۵۰-۵۳]. به تازگی، تکنیک‌های یادگیری عمیق در تعداد زیادی از سیستم‌های پایش ماشینی سلامت، بکار گرفته شده است. پیش‌آموزش لایه به لایه DNN بر اساس AE یا RBM می‌تواند آموزش DNN را تسهیل بخشد و قدرت تمایز آن را برای توصیف داده‌های ماشینی بهبود بخشد. CNN و RNN، مکانیزم ترکیبی پیشرفته‌تر و پیچیده‌تری را برای یادگیری بازنمایی از داده‌های ماشینی، ارائه می‌کنند. در این سیستم‌های MHMS مبتنی بر DL، لایه بالایی معمولاً اهداف را نشان می‌دهند. برای تشخیص جایی که در آن اهداف مقادیر گسسته هستند، لایه بیشینه هموار، اعمال می‌شود. برای پیش‌آگهی همراه با اهداف پیوسته، لایه رگرسیون خطی اضافه می‌شود. علاوه بر این، ساختار سرتاسری، MHMS مبتنی بر DL را قادر می‌سازد با نیروی انسانی کمتر و دانش متخصص ساخته شود، بنابراین این مدل‌ها به تجهیزات یا حوزه خاصی، محدود نمی‌شوند. در ادامه، بررسی مختصری در مورد MHMS مبتنی بر DL در این چهار سبک DL یعنی AE، RBM، CNN و RNN، صورت می‌گیرد.

۳.۱. AE و انواع آن برای پایش ماشینی سلامت

مدل‌های AE، به‌ویژه DA انباشته، می‌توانند نمایش‌هایی را از داده‌های ماشین به صورت خودکار یاد بدهند. سان و همکاران یک شبکه عصبی مبتنی بر AE یک لایه را برای طبقه‌بندی خطاهای موتور القایی، پیشنهاد کرد [۵۴]. با توجه به اندازه محدود داده‌های آموزشی، آنها برای جلوگیری از بیش‌برازش، متمرکز شدند. نه تنها تعداد لایه‌های پنهان بر روی ۱ تنظیم شد، بلکه تکنیک حذف که بخش‌هایی از نورون‌های خروجی را به‌طور تصادفی پنهان می‌کند، بر روی لایه پنهان اعمال شد. کل مدل در شکل ۶ نشان داده شده است. اکثر مدل‌های پیشنهادی بر اساس سبک‌های عمیق با انباشتن چند خودرمنزنگار هستند. به عنوان مثال، لو و همکاران، یک مطالعه تجربی

دقیق از خودمزننگارهای حذف نویز انباشته با سه لایه پنهان برای تشخیص عیب اجزای ماشین‌های دوار، پیشنهاد نمودند [۵۵]. به طور خاص، در آزمایش‌های آنها که شامل شرایط کاری واحد که داده‌های آموزش و آزمایش در یک شرایط عملیاتی مشترک هستند و داده‌های آزمایشی و آموزشی از دو شرایط عملیاتی متفاوت، نمونه برداری شدند، اثربخشی معماری عمیق، محدودیت پراکندگی و عملیات حذف نویز در مدل SDA ارزیابی شدند. آنها پیشنهاد کردند که سه لایه پنهان با معیار پراکندگی ۰.۱۵ و سطح تخریب ۰.۲۵، بهینه باشد. در [۵۶]، ساختارهای مختلف یک DNN مبتنی بر SAE دو لایه با تغییر اندازه لایه پنهان و احتمال پوشاندن آن طراحی شد و برای کارایی آنها در تشخیص عیب، ارزیابی شد.

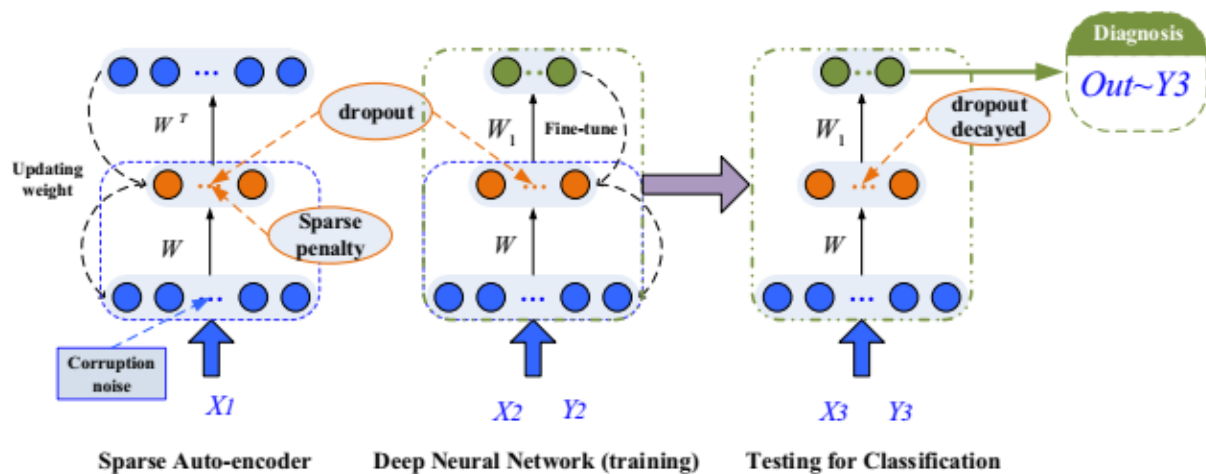


Fig. 6. Illustrations of the proposed sparse autoencoder for induction motor fault diagnosis in [54].

در آثار فوق، ویژگی‌های ورودی برای مدل‌های AE، سری‌های زمانی حسی خام هستند. بنابراین، ابعاد ورودی همیشه بیش از صد، حتی هزار است. ابعاد احتمالی بالا ممکن است به برخی نگرانی‌های بالقوه مانند هزینه محاسبات سنگین و بیش‌برازش ناشی از پارامترهای ابر مدل، منجر شود. بنابراین، برخی از محققان بر روی مدل‌های AE مبتنی بر ویژگی‌های استخراج‌شده از ورودی خام، تمرکز کردند. جیا و همکاران دامنه فرکانس داده‌های سری زمانی را به SAE، برای تشخیص ماشین‌های دوار، تغذیه نمودند [۵۷]، با در نظر گرفتن این مساله که دامنه فرکانس، می‌تواند نشان دهد که چگونه اجزای سازنده آن‌ها با فرکانس‌های گسسته توزیع می‌شوند و ممکن است نسبت به شرایط سلامت ماشین‌های دوار، متمایزتر باشند. در [۵۸]، سان و همکاران، از تکنیک‌های سنجش فشرده برای استخراج ویژگی‌های کم بعدی ناشی از سیگنال سری زمانی خام به عنوان ویژگی‌های ورودی در مدل‌های SAE-DNN، استفاده کردند. در [۵۹]، ژو و همکاران. سه SAE-DNN آبخاری پیشنهاد کردند که هر ماژول به ترتیب برای طبقه‌بندی پارتیشن حالت، طبقه‌بندی مکان منبع خطا و تشخیص شدت خطا، استفاده شدند. ویژگی‌های ورودی، ضرایب فرکانس بر اساس تبدیل فوریه سریع هستند. تان و همکاران از قاب

موجک دیجیتال و روش آستانه نرم غیرخطی، برای پردازش سیگنال ارتعاشی استفاده کرد و یک SAE را بر روی سیگنال از پیش پردازش شده برای تشخیص عیب یاتاقان غلتکی ساختند [۶۰].

زو و همکاران یک DNN مبتنی بر SAE را برای تشخیص عیب پمپ هیدرولیک همراه با ورودی به عنوان ویژگی‌های حوزه فرکانس پس از تبدیل فوریه، [۶۱] پیشنهاد کردند. در آزمایش‌ها، تکنیک فعال‌سازی relu و حذف تصادفی، مورد تجزیه و تحلیل قرار گرفت و نتایج تجربی نشان داده‌اند که در جلوگیری از ناپدید شدن گرادینان و بیش‌برازش، مؤثر است. در کار ارائه شده در [۶۲]، طیف‌نگار نرمال‌شده تولید شده توسط STFT سیگنال صوتی، DNN دو لایه مبتنی بر SAE را برای تشخیص عیب یاتاقان‌های دوار، تغذیه کردند. گالووی و همکاران یک DNN مبتنی بر SAE دو لایه را بر روی طیف‌نگارهای تولید شده از داده‌های ارتعاشی خام برای تشخیص خطای ارتعاش توربین کشندی (جزر و مدی) ساختند [۶۳]. یک DNN مبتنی بر SAE با ورودی به عنوان مؤلفه‌های اصلی داده‌های استخراج‌شده توسط تجزیه و تحلیل مؤلفه اصلی برای تشخیص خطای فضاپیما در [۶۴]، پیشنهاد شد. ویژگی‌های آماری چند دامنه‌ای از جمله ویژگی‌های حوزه زمان، ویژگی‌های حوزه فرکانس و ویژگی‌های حوزه زمان-فرکانس، به درون چارچوب SAE وارد شده‌اند که می‌تواند به عنوان یک نوع ترکیب ویژگی در نظر گرفته شود [۶۵]. به طور مشابه، ورما و همکاران هم از این سه ویژگی برای تغذیه DNN مبتنی بر SAE برای تشخیص عیب کمپرسورهای هوا استفاده کرد [۶۶] و صهبیب و همکاران، مدل SAE-DNN پیشنهادی بر اساس این سه ویژگی حوزه برای تشخیص خطای یاتاقان [۶۷] استفاده کردند. در [۶۸]، چن و همکاران، ویژگی‌های سه دامنه‌ای را وارد SAE کردند و ماشین بردار پشتیبان را به عنوان طبقه بندی کننده نهایی، پذیرفتند. برای غلبه بر مشکل بیش‌برازش، چن و همکاران، روش افزایش داده‌ها را با اضافه کردن نویز گاوسی به درون داده‌های آموزشی، اتخاذ کردند [۶۹].

به جز برای این ویژگی چند دامنه‌ای کاربردی، داده‌های چندحسی نیز توسط مدل‌های SAE، بررسی می‌شوند. ردی و همکاران از SAE برای یادگیری ارائه داده‌های سری زمانی خام برگرفته از چندین حسگر، برای تشخیص ناهنجاری و ابهام‌زدایی خطا در داده‌های پرواز استفاده کردند. برای پرداختن به داده‌های چندحسی، پنجره‌های همگام‌سازی شده، در ابتدا از طریق سری‌های زمانی چندوجهی همراه با همپوشانی، عبور داده شدند، و سپس پنجره‌های هر حسگر به عنوان ورودی برای SAE دنباله‌رو، به آن متصل شدند [۷۰]. در [۷۱]، SAE برای تجمیع داده‌های چندحسی به کار گرفته شد و DBN دنباله‌رو، برای تشخیص خطای یاتاقان به کار گرفته شد که نتایج امیدوارکننده‌ای به دست آمد. ویژگی‌های آماری در حوزه زمان و حوزه فرکانس استخراج‌شده از

سیگنال‌های ارتعاشی حسگرهای مختلف به‌عنوان ورودی برای یک SAE دو لایه با شبکه‌های عصبی محدود شده، به کار گرفته شد. بازنمایی‌های آموخته شده برای طبقه‌بندی الگو به درون یک شبکه باور عمیق، وارد شدند. علاوه بر این، برخی از انواع SAE رایج برای پایش ماشینی سلامت پیشنهاد شده یا معرفی شدند. در [۷۲]، تیروکووالورو و همکاران، یک چارچوب دو فازی پیشنهاد کرد که SAE فقط ارائه را یاد می‌گیرد و دیگر طبقه‌بندی‌کننده‌های استاندارد مانند SVM و الگوریتم جنگل تصادفی، طبقه‌بندی را انجام می‌دهند. به طور خاص، در ماژول SAE، ویژگی‌های دست ساز مبتنی بر FFT و تبدیل بسته موجک (WPT) به DNN مبتنی بر SAE، تغذیه شدند. پس از پیش‌آموزش و تنظیم دقیق پایش شده که شامل دو روش مجزا روش‌های تنظیم دقیق مبتنی بر بیشینه هموار و میانه، می‌باشد، آزمایش‌های گسترده بر روی پنج مجموعه داده شامل نظارت بر کمپرسور هوا، پایش مته‌ها، نظارت بر خطای یاتاقان و پایش صفحه فولادی، قابلیت تعمیم سیستم‌های پایش ماشینی سلامت مبتنی بر DL را نشان داده است. وانگ و همکاران یک خودرمنزنگار پراکنده پیوسته جدید (CSAE) را به عنوان یادگیری ویژگی بدون نظارت، برای تشخیص خطای ترانسفورماتور پیشنهاد کردند [۷۳].

جدا از AE پراکنده رایج، CSAE پیشنهادی آنها، واحد تصادفی را به تابع فعال سازی هر واحد مرئی اضافه کرد:

$$s_j = \varphi_j \left(\sum_i w_{ij} x_i + a_i + \sigma N_j(0, 1) \right) \quad (18)$$

که در اینجا، s_j خروجی مربوط به ورودی x_i و w_{ij} و a_i است. که پارامترهای مدل را نشان می‌دهند، φ_j تابع فعال‌سازی را نشان می‌دهد و آخرین عبارت $\sigma N_j(0, 1)$ ، واحد تصادفی اضافه شده است که یک گاوس با میانگین صفر با واریانس σ^2 است. یکپارچگی واحد تصادفی، قادر به تغییر جهت گرادیان و جلوگیری از بیش-برازش، است. مائو و همکاران یک نوع AE به نام خودرمنزنگار مبتنی بر ماشین یادگیری غایبی را برای تشخیص خطا استفاده کردند که بدون کاهش دقت در تشخیص خطا، کارآمدتر از مدل‌های رایج SAE، است [۷۴]. جدا از AE که از طریق پس انتشار، آموزش داده شد، تبدیل در فاز رمزگذار، به طور تصادفی ایجاد شد و تبدیل در فاز رمزگشا در یک مرحله از طریق برازش حداقل مربعات، آموخته شد [۷۵]. در [۷۶]، جیا و همکاران، به دو کاستی بالقوه پشت خودرمنزنگارهای سنتی مانند یادگیری ویژگی‌های مشابه و ویژگی‌های متغیر تغییر اشاره کردند که کارایی در استخراج ویژگی خودکار سیگنال‌های مکانیکی را مختل می‌کند. بنابراین، آنها خودرمنزنگار پراکنده نرمال شده (NSAE) را با افزودن واحدهای خطی اصلاح شده به عنوان تابع فعال‌سازی، کنار گذاشتن سوگیری و اتخاذ هنجار L2 به جای تابع واگرایی KL در فرمول‌بندی خودرمنزنگار، پیشنهاد کردند. سپس، یک شبکه اتصال محلی (LCN) که مقدار متوسط خروجی‌های NSAE را در بر می‌گیرد برای استخراج ویژگی‌های تغییر ناپذیر، استفاده شد. برای تطبیق ویژگی‌های سیگنال پیچیده، شائو و همکاران، تابع از دست دادن MSE اصلی را با

حداکثر آنتروپی همبسته در خودرمننگاری که خود طراحی کردند، جایگزین کرده و الگوریتم دسته ماهی‌های مصنوعی را برای انتخاب پارامترهای کلیدی آن اتخاذ کردند [۷۷]. در کار دیگر آنها، یک مدل گروهی از خودرمننگارها با ۱۵ تابع فعال سازی مختلف در [۷۸] پیشنهاد دادند، که در آن الگوی گروهی بر اساس رأی اکثریت با وزن‌های مختلف است. آنها همچنین یک طرح ترکیبی از دو خودرمننگار از جمله خودرمننگار حذف نویز (DAE) و خودرمننگار انقباضی (CAE) بر اساس طرح حفظ موقعیت (LPP) در [۷۹]، پیشنهاد کردند. لی و همکاران یک خودرمننگار همه مال برنده کاملاً متصل [۸۰] (FCWTA) را برای تشخیص خطای یاتاقان، پیشنهاد کردند. تازگی مدل آنها در دو جنبه نهفته است: یکی در مورد مجازی سازی طول عمر و تشخیص عمیق برای پراکندگی طبقه بندی خطای سیستم است که تنها k بزرگترین فعال ساز برای هر گره پنهان در بین تمام نمونه‌ها در یک دسته کوچک نگه داشته می‌شود و مورد دیگر، چارچوب گروهی است که سیگنال ورودی است و به چندین پنجره تقسیم می‌شود و هر پنجره برای به دست آوردن نتایج پیش بینی برای FCWTA، تغذیه می‌شود. در نهایت، یک روش رای گیری سبک برای ترکیب همه نتایج پیش بینی، اجرا شد.

علاوه بر این، لو و همکاران، بر تجسم ارائه آموخته شده توسط یک DNN مبتنی بر SAE دو لایه، که نمای جدیدی برای ارزیابی MHMS مبتنی بر DL ارائه می‌کند، تمرکز داشتند [۸۱]. در مقاله آنها، قدرت تمایز بازنمایی آموخته شده را می‌توان با افزایش لایه‌ها بهبود بخشید.

۳.۲. RBM و انواع آن برای پایش ماشینی سلامت

در این بخش، برخی از کارهای انجام شده در باب توسعه RBM برای یادگیری ارائه برگرفته از داده‌های ماشینی، بیان شده است. بیشتر کارهایی که در اینجا معرفی می‌شوند بر اساس شبکه‌های باور عمیق (DBN) هستند که می‌توانند یک شبکه عصبی عمیق (DNN) را از قبل آموزش دهند.

در [۸۲]، یک روش مبتنی بر RBM برای پیش‌بینی عمر مفید باقیمانده (RUL) پیشنهاد شد. لایه رگرسیون خطی در بالای RBM پس از پیش‌آموزش، برای پیش‌بینی ریشه میانگین مربعات آتی (RMS) و بر اساس یک سری زمانی تاخیری برگرفته از مقادیر RMS، اضافه شد. سپس RUL با استفاده از RMS پیش‌بینی شده و زمان کلی عمر یاتاقان، محاسبه شد. در کار دیگر خود [۸۳]، آنها از ساختار مشابهی استفاده کردند: DBN-FNN برای پیش‌بینی مستقیم مقدار RUL. لیائو و همکاران یک RBM جدید را برای یادگیری بازنمایی برای پیش‌بینی RUL ماشین‌ها، پیشنهاد کردند [۸۴]. در کار آنها، یک اصطلاح تنظیمی جدید برای مدل سازی روندپذیری گره‌های پنهان، به تابع هدف آموزشی RBM اضافه شد. سپس، الگوریتم نقشه خودسازماندهی بدون نظارت (SOM)، برای تبدیل ارائه آموخته شده توسط RBM تقویت شده برای یک مقیاس به نام ارزش سلامت،

اعمال شد. در نهایت، ارزش سلامت برای پیش‌بینی RUL از طریق یک الگوریتم پیش‌بینی زندگی مبتنی بر شباهت استفاده شد. در [۸۵]، یک رویکرد طبقه‌بندی بردار پشتیبان چندوجهی عمیق، برای تشخیص عیب گیربکس‌ها، پیشنهاد شد. در ابتدا، سه ویژگی بُعدی، شامل زمان، فرکانس و زمان-فرکانس برگرفته از سیگنال‌های ارتعاشی، استخراج شد. سپس، سه ماشین بولتزمن عمیق گاوسی-برنولی (GDBMS) به ترتیب برای پرداختن به سه روش فوق استفاده شد. در هر GDBMS، از لایه پیشینه هموار در بالا استفاده شده است. پس از پیش‌آموزش و فرآیندهای تنظیماتی دقیق، خروجی‌های احتمالی لایه‌های پیشینه هموار از این سه GDBMS توسط یک چارچوب طبقه‌بندی بردار پشتیبان (SVC)، برای پیش‌بینی نهایی ترکیب شدند. لی و همکاران یک GDBMS را به طور مستقیم بر روی ویژگی الحاقی شامل سه ویژگی بُعدی شامل زمان، فرکانس و زمان - فرکانس اعمال کرد و یک لایه پیشینه هموار را در بالای GDBMS برای تشخیص دسته‌های خطا قرار دادند [۸۶]. لی و همکاران یک DBM دو لایه را برای یادگیری بازنمایی عمیق پارامترهای آماری WPT سیگنال حسی خام برای تشخیص عیب گیربکس، اتخاذ کردند [۸۷]. در این کار با تمرکز بر همجوشی داده‌ها، دو DBM بر روی سیگنال‌های صوتی و ارتعاشی و الگوریتم جنگل تصادفی برای ترکیب ارائه‌های آموخته شده توسط این دو DBM، اعمال شد. شائو و همکاران، چندین RBM را برای تشخیص خطا در مدل DBM انباشته کردند، که ورودی آن، داده‌های حوزه فرکانس مبتنی بر تبدیل فوریه سریع (FFT) است [۸۸]. در [۸۹]، ژانگ و همکاران، از شبکه باور عمیق برای تشخیص تخریب پیچ ساچمه‌ای، استفاده کردند. ویژگی‌های ورودی به درون مدل DBN، طیف فرکانس ذوب شده سیگنال‌های حوزه زمانی مختلف در حسگرهای مختلف، می‌باشد. در [۹۰]، وانگ و همکاران، استفاده از ویژگی طیف پنجره کشویی (SWSF)، به عنوان ویژگی ورودی در مدل DBN برای تشخیص خطای هیدرولیک، پیشنهاد نمودند. در [۹۱]، ویژگی‌های آماری حوزه زمان و حوزه فرکانس، استخراج شده و به DBN وارد شدند. سپس، PSO-SVM بر روی خروجی‌های DBN برای تشخیص خطا اعمال شد. در [۹۲]، وانگ و همکاران. از دو RBM برای تشکیل یک مدل DBM برای پیش‌بینی نرخ حذف مواد در صیقل دادن، استفاده کردند. الگوریتم‌های بهینه‌سازی دسته‌ای ذرات (PSO) برای انتخاب ابر پارامترهایی مانند ساختار DBN و نرخ یادگیری، معرفی شدند. در [۹۳]، چن و همکاران، کارایی چندین مدل مبتنی بر DNN از جمله DBM، DBN و SAE را در چهار روش پیش پردازش مختلف مانند سیگنال حوزه زمانی خام، ویژگی حوزه زمان، ویژگی حوزه فرکانس و ویژگی حوزه زمان-فرکانس، بررسی کردند. آن، نشان داده شد که این سه مدل DNN در تشخیص خطا، قابل اعتماد و موثر هستند و مدل‌های DNN مبتنی بر داده‌های خام در مقایسه با سه روش پیش‌پردازش دیگر، بدتر عمل می‌کند. در [۹۴]، گائو و همکاران، ترکیبی از شبکه باور عمیق و شبکه عصبی

الهام گرفته از کوانتوم (QINN) را برای تشخیص خطای سیستم سوخت هواپیما، استفاده کردند. ویژگی‌های ورودی به درون DBN شامل ویژگی حوزه زمانی و ویژگی حوزه فرکانس است. خروجی‌های DBN به درون شبکه عصبی الهام گرفته از کوانتوم (QINN)، که برهم نهی خطی چندین DBN را با فواصل کوانتومی بکار می‌گیرد، وارد شد. در [۹۵]، او و همکاران، DBN را بر روی تصاویر ارتعاشی برای استخراج ویژگی‌ها، اعمال کرد و طبقه‌بندی نهایی را انجام داد. تصویر ارتعاش از سیگنال سنسور ارتعاشی تولید شد و هیستوگرام گرادیان‌های جهت دار (HOG) بر روی تصویر ارتعاش به عنوان ویژگی‌های ورودی در DBN دنباله‌رو، اعمال شد.

ما و همکاران، با استفاده از DNN مبتنی بر DBN، این چارچوب را برای ارزیابی تخریب تحت یک آزمایش عمر شتاب‌دهنده یاتاقان [۹۶] ارائه کردند. ویژگی آماری، ریشه میانگین مربع (RMS) با توزیع ویبول، می‌تواند از نوسانات پارامتر آماری جلوگیری کند و ویژگی‌های حوزه فرکانس به عنوان ورودی خام استخراج شد. علاوه بر ارزیابی دقت طبقه‌بندی نهایی، الگوریتم t-SNE برای تجسم ارائه آموخته‌شده DBN و خروجی‌های هر لایه در DBN اتخاذ شد. آنها دریافتند افزودن لایه پنهان می‌تواند قدرت تمایز را در ارائه آموخته شده، افزایش دهد. شائو و همکاران، برای تشخیص عیب موتور القایی DBN را در [۹۷] پیشنهاد نمودند. همانطور که در شکل ۷ نشان داده شد، تبدیل فوریه سریع بر روی داده‌های سری زمانی خام اعمال شد و ویژگی حوزه فرکانس به مدل‌های DBN وارد شد. فو و همکاران از شبکه‌های باور عمیق برای نظارت بر وضعیت‌ها استفاده کرد [۹۸]. در کار ارائه شده، سه مجموعه ویژگی مختلف از جمله سیگنال ارتعاش خام، ضریب سپستروم فرکانس مل (MFCC) و ویژگی‌های موجک، به عنوان سه ورودی مختلف متناظر به DBN، وارد شدند که قادر به دستیابی به کارایی مقایسه‌ای قوی بر روی سیگنال ارتعاشی خام بدون استفاده از بسیاری از ویژگی‌های مهندسی آن بودند. تامیلسلوان و همکاران یک مدل طبقه‌بندی وضعیت سلامت مبتنی بر DBN چند حسی را پیشنهاد کردند. این مدل در مسائل رده‌بندی معیار و دو کاربرد تشخیص سلامت شامل تشخیص سلامت موتور هواپیما و تشخیص سلامت ترانسفورماتور توان الکتریکی تأیید شد [۹۹، ۱۰۰]. تائو و همکاران یک طرح ترکیبی اطلاعات چندحسگر مبتنی بر DBN را برای تشخیص عیب یاتاقان [۱۰۱] پیشنهاد کردند. در مرحله اول، ۱۴ ویژگی آماری حوزه زمان استخراج شده از سه سیگنال ارتعاشی که توسط سه حسگر به عنوان یک بردار ورودی برای مدل DBM به دست آمده، به هم متصل شدند. در طول پیش آموزش، یک مقدار آستانه از پیش تعریف شده برای تعیین تعداد تکرار آن معرفی شد. در [۱۰۲]، یک بردار ویژگی متشکل از اندازه‌گیری بار و سرعت، ویژگی‌های حوزه زمان و ویژگی‌های حوزه فرکانس، به درون DNN مبتنی بر DBN برای تشخیص خطای گیربکس، وارد شد. در کار [۱۰۳]، گان و همکاران، یک شبکه تشخیص سلسله مراتبی برای تشخیص الگوی خطا یاتاقان‌های المان غلتان متشکل از دو فاز

متوالی را ساخته که در آن ابتدا چهار مکان خطای مختلف (از جمله یک وضعیت سلامتی) شناسایی شدند و سپس شدت‌های گسسته خطا در هر شرایط خطا طبقه‌بندی شدند. در هر فاز، ویژگی‌های انرژی باند فرکانسی تولید شده توسط WPT برای طبقه‌بندی الگو به DNN مبتنی بر DBN، وارد شد. در [۱۰۴]، از قبل، سیگنال‌های ارتعاش خام برای تولید تصویر دو بعدی و بر اساس تکنیک‌های بازسازی همه‌جهته (ODR)، پردازش شدند و سپس، توصیفگر هیستوگرامی گرادیان اصلی (HOG) روی تصویر تولید شده اعمال شد و بردار آموخته‌شده به DBN، برای تشخیص خودکار سیستم‌های روتور یا تاقان گرد، داده شد. ژانگ و همکاران، مجموعه-ای از DBN‌ها با بهینه‌سازی تکاملی چند هدفه را بر روی الگوریتم تجزیه (MOEA/D)، برای تشخیص خطا با داده‌های حسی چند متغیره، پیشنهاد دادند [۱۰۵]. DBN‌ها با معماری‌های مختلف را می‌توان به صورت دسته‌کننده پایه در نظر گرفت و MOEA/D برای تنظیم وزن‌های گروهی برای دستیابی به یک رابطه جایگزین بین دقت و تنوع، معرفی شد. سپس ژانگ و همکاران، این چارچوب ذکر شده را برای یک کار پیش‌آگهی خاص، یعنی تخمین RUL سیستم مکانیکی، گسترش دادند [۱۰۶].

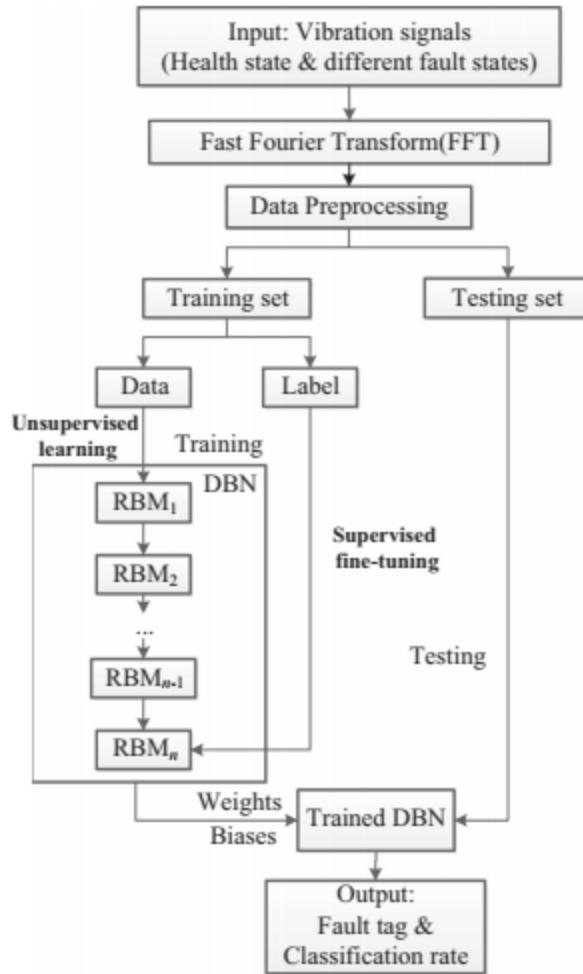


Fig. 7. Illustrations of DBN for induction motors fault diagnosis in [97].

۳.۳. CNN برای پایش ماشینی سلامت

در برخی سناریوها، داده‌های ماشینی را می‌توان در قالب دو بعدی مانند طیف زمان-فرکانس ارائه کرد، در حالی که در برخی سناریوها، آنها در قالب یک بعدی، یعنی سری‌های زمانی هستند. بنابراین، مدل‌های CNN می‌توانند یک ارائه پیچیده و قوی را از طریق لایه کانولوشنی خود بیاموزند. به طور شهودی، فیلترها در لایه‌های کانولوشن می‌توانند الگوهای موضعی را در داده‌های خام استخراج کنند و با روی هم قرار دادن این لایه‌های کانولوشن می‌توان، الگوهای پیچیده‌تری ساخت. لیو و همکاران، یک شبکه عصبی کانولوشن سری زمانی جابجا شده (-DTS CNN) را برای تشخیص عیب ماشین الکتریکی پیشنهاد کردند [۱۰۷]. در کار آنها، یک لایه سری زمانی به هم خورده برای جابجایی سیگنال مکانیکی ورودی یک بعدی به یک ماتریس خروجی، معرفی شد. عملیات DTS، شهودی است و چندین سیگنال رهگیری شده از سیگنال اصلی برای تشکیل یک ماتریس مرتب شده‌اند. سپس،

یک مدل CNN عمیق رایج، استفاده شد. در [۱۰۸]، CNN دوبعدی برای تشخیص عیب گیربکس معرفی شد. همانطور که در شکل ۸ نشان داده شده، تجزیه و تحلیل موجک برای انتقال ورودی حسی خام به درون تصاویر دوبعدی زمان-فرکانس انجام شد و یک شبکه عصبی کانولوشن عمیق برای تشخیص عیب گیربکس، به کار گرفته شد. یانسنس و همکاران از یک مدل دوبعدی CNN برای شناسایی شرایط ماشین‌های دوار چهار دسته استفاده کردند که ورودی، نتایج DFT دو سیگنال شتاب‌سنج برگرفته از دو حسگر بود که عمود بر یکدیگر قرار گرفتند. بنابراین ارتفاع ورودی، تعداد سنسورهاست. مدل اتخاذ شده CNN شامل یک لایه کانولوشن و یک لایه کاملاً متصل تشکیل شده است. سپس، لایه بیشینه هموار بالایی برای طبقه‌بندی استفاده شد [۱۰۹].

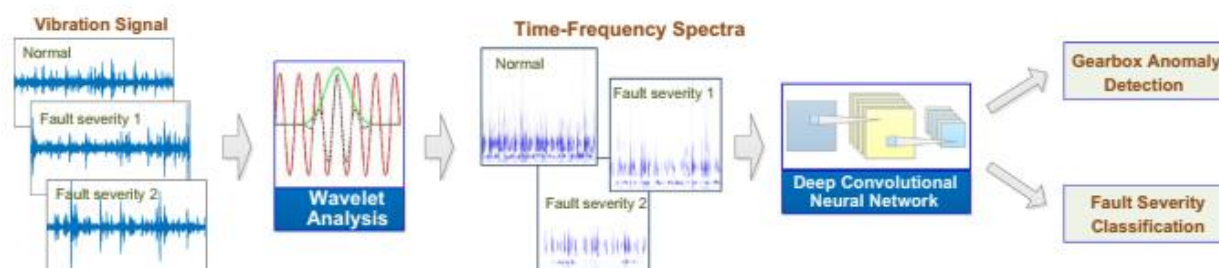


Fig. 8. Illustrations of the proposed 2D-CNN for gearbox fault detection in [108].

لو و همکاران داده‌های سری زمانی خام را به درون یک نقشه دوبعدی بر اساس درج لغزشی که اندازه آن ۲۰ در ۲۰ است، بازآرایی کرد [۱۱۰]. در [۱۱۱]، بابو و همکاران، یک شبکه عصبی کانولوشن عمیق دوبعدی را برای پیش‌بینی RUL سیستم بر اساس سری‌های زمانی متغیر نرمال شده بر گرفته از سیگنال‌های حسگر ساختند، که در آن یک بُعد ورودی دوبعدی، همانطور که در [۱۰۹]، گزارش شده، تعداد حسگرها است. در این مدل، میانگین تجمیع به جای تجمیع حداکثر، اتخاذ شد. از آنجایی که RUL یک مقدار پیوسته است، از رگرسیون خطی در لایه بالایی استفاده شد. دینگ و همکاران یک شبکه کانولوشن عمیق (ConvNet) را پیشنهاد کردند که در آن تصویر انرژی بسته موجک (WPE)، برای تشخیص عیب یاتاقان اسپیندل، به عنوان ورودی استفاده شد [۱۱۲]. برای کشف کامل ارائه سلسله مراتبی، یک لایه چندمقیاسی بعد از آخرین لایه کانولوشن اضافه شد که خروجی‌های آخرین لایه کانولوشنی و خروجی‌های لایه تجمیع قبلی را به هم متصل می‌کند. گوو و همکاران یک شبکه عصبی کانولوشن عمیق تطبیقی سلسله مراتبی (ADCNN) [۱۱۳] را پیشنهاد کردند. ابتدا، داده‌های سری زمانی ورودی به عنوان یک بردار سیگنال به یک ماتریس 32×32 تبدیل شد که از قالب ورودی رایج که توسط LeNet [۱۱۴] اتخاذ شده، پیروی می‌کند. علاوه بر این، آنها یک چارچوب سلسله مراتبی برای تشخیص الگوهای خطا و اندازه خطا، طراحی کردند. در ماژول تصمیم‌گیری الگوی خطا، اولین ADCNN برای تشخیص

نوع عیب، به کار گرفته شد. در لایه ارزیابی اندازه خطا، بر اساس هر نوع خطا، از ADCNN با ساختار مشابه برای پیش‌بینی اندازه عیب استفاده شد. در اینجا، مکانیسم طبقه‌بندی هنوز استفاده می‌شود. مقدار پیش‌بینی شده f به‌عنوان مجموع احتمال اندازه‌های خطای معمولی به صورت زیر تعریف می‌شود:

$$f = \sum_{j=1}^c a_j p_j \quad (19)$$

در اینجا، $[p_1, \dots, p_c]$ ، توسط لایه بیشینه هموار بالایی تولید می‌شود، که نشان‌دهنده امتیاز احتمالی است که هر نمونه به اندازه هر کلاس تعلق دارد و a_j اندازه خطا مربوط به اندازه خطای j ام است. سان و همکاران، تبدیل موجک پیچیده درختی دوگانه (DTCWT) را برای تبدیل سیگنال سری زمانی خام به یک نقشه دو بُعدی، اتخاذ کردند، که می‌تواند تغییرناپذیری شیفت و فرکانس را مهار و نقشه دو بُعدی را به مدل‌های CNN وارد کند [۱۱۵]. در [۱۱۶]، یک CNN پیشرفته برای تشخیص عیب ماشین آلات پیشنهاد شد. برای پیش پردازش داده‌های ارتعاش، از موجک مورلت برای تجزیه سیگنال ارتعاشی و به دست آوردن مقیاس موجک، استفاده شد. سپس، درون یابی دو خطی برای ترسیم مقیاس تراکمی به یک تصویر در مقیاس خاکستری با اندازه 32×32 استفاده شد. علاوه بر این، انطباق واحد خطی اصلاح شده و حذف، کارایی تشخیص مدل را افزایش داد. چن و همکاران یک CCN دو بُعدی را برای تشخیص عیب گیربکس اتخاذ کرد که در آن ماتریس ورودی با اندازه 16×16 برای CNN، توسط بردار حاوی ۲۵۶ ویژگی آماری از جمله مقادیر RMS، انحراف استاندارد، چولگی، کشیدگی، فرکانس چرخش و بار اعمال شده، تغییر شکل داده شد [۱۱۷]. علاوه بر این، ۱۱ ساختار مختلف CNN به صورت تجربی در آزمایش‌هایشان، مورد ارزیابی قرار گرفتند. وایمر و همکاران، یک مطالعه جامع از پیکربندی‌های مختلف طراحی CNN عمیق را برای تشخیص عیب بصری انجام داد [۱۱۸]. در یک استفاده ویژه: بازرسی نوری صنعتی، دو جهت پیکربندی مدل، شامل عمق (افزودن لایه کانولوشن) و عرض (افزایش تعداد فیلترها)، مورد بررسی قرار گرفت. پیکربندی بهینه که به صورت تجربی تأیید شده در جدول ۲ ارائه شده است. در [۱۱۹]، CNN در زمینه تشخیص خطاهای کوچک اولیه ژنراتور بادی با پیشنهاد کنترل‌شده (FSCWG)، استفاده شد که در آن ماتریس ورودی 784×784 ، شامل داده‌های ارتعاش شفت ورودی ژنراتور (افقی) و داده‌های ارتعاش شفت خروجی ژنراتور (عمودی) در مقیاس زمانی، بود. در [۱۲۰]، یو و همکاران، از ماشین بردار پشتیبانی به عنوان دسته‌کننده ویژگی‌های استخراج‌شده توسط CNN برای تشخیص عیب ماشین‌های دوار استفاده کردند. در کار لی، آنها CNN را برای طبقه‌بندی و تشخیص عیب در فرآیندهای تولید نیمه هادی، اتخاذ کردند [۱۲۱]. ماتریس ورودی دو بُعدی در مدل CNN با محور زمان پردازش و محور متغیر حسگر همراه بود و فیلتر فقط در امتداد محور زمان

پردازش، لغزش داشت. عملیات تجمیع بعدی بر روی محور زمان برای هر نگاشت ویژگی، انجام شد. در [۱۲۲]، ون و همکاران، ابتدا سیگنال سری زمانی خام ورودی را با نمونه‌برداری تصادفی بخش‌هایی از سیگنال خام، به تصویر دوبعدی تبدیل کرد. آنها تصویر دوبعدی را به درون ساختار دوبعدی CNN که بسیار کلاسیک است، یعنی Lenet-5 CNN، وارد کردند. مدل آنها در سه کار تشخیص ماشینی مختلف از جمله تشخیص عیب یاتاقان موتور، تشخیص عیب پمپ گریز از مرکز خودپرایمینگ و تشخیص عیب پمپ هیدرولیک پیستون محوری، به نتایج بسیار امیدوارکننده‌ای دست یافت.

Table 2
Summary on configurations of CNN-based MHMS.

	Proposed Models	Configurations of CNN Structures*
2D CNN	<i>Liu's work [107]</i>	Input[10 × 512] – 16C[3 × 4] – 16C[3 × 4] – 16P[2 × 2] – 32C[3 × 4] – 32C[3 × 4] – 32P[2 × 2] – FC[+] – FC[+]
	<i>Janssens's work [109]</i>	Input[5120 × 2] – 32C[64 × 2] – FC[200]
	<i>Babu's work [111]</i>	Input[27 × 15] – 8C[27 × 4] – 8P[1 × 2] – 14C[1 × 3] – 14P[1 × 2]
	<i>Ding's work [112]</i>	Input[32 × 32] – 20C[7 × 7] – 20P[2 × 2] – 10C[6 × 6] – 10P[2 × 2] – 6P[2 × 2] – FC[185 – 24]
	<i>Guo's work [113]</i>	Input[32 × 32] – 5C[5 × 5] – 5P[2 × 2] – 10C[5 × 5] – 10P[2 × 2] – 10C[2 × 2] – 10P[2 × 2] – FC[100] – FC[50]
	<i>Wang's work [116]</i>	Input[32 × 32] – 64C[3 × 3] – 64P[2 × 2] – 64C[4 × 4] – 64P[2 × 2] – 128C[3 × 3] – 128P[2 × 2] – FC[512]
	<i>Chen's work [117]</i>	Input[16 × 16] – 8C[5 × 5] – 8P[2 × 2]
	<i>Weimer's work [118]</i>	Input[32 × 32] – 64C[3 × 3] – 64P[2 × 2] – 128C[3 × 3] – 128P[2 × 2] – FC[1024 – 1024]
	<i>Dong's work [119]</i>	Input[784 × 784] – 12C[10 × 10] – 12P[2 × 2] – 24C[10 × 10] – 24P[2 × 2] – FC[200]
	<i>You's work [120]</i>	Input[32 × 32] – 5C[5 × 5] – 5P[2 × 2] – 10C[5 × 5] – 10P[2 × 2] – 10C[2 × 2] – 10P[2 × 2] – FC[100]
1D CNN	<i>Ince's work [126]</i>	Input[240] – 60C[9] – 60P[4] – 40C[9] – 40P[4] – 40C[9] – 40P[4] – FC[20]
	<i>Abdeljaber's work [127]</i>	Input[128] – 64C[41] – 64P[2] – 32C[41] – 32P[2] – FC[10 – 10]
	<i>Zhang's work [130]</i>	Input[2048] – 16C[64] – 16P[2] – 4[32C[3] – 32P[2]] – FC[100]
	<i>Sun's work [132]</i>	Input[799] – 100C[200] – 100P[20]

* The symbol Input, C, P and FC denote the raw input, convolutional layer, pooling layer and Fully-connected layer, respectively. Here, + denotes the undisclosed hyperparameter in the corresponding paper.

در [۱۲۳]، CNNهای مختلف آموزش دیده بر روی حسگرهای مختلف بر اساس تئوری Dempster-Shafer ارتقا یافته برای بدست آوردن پیش بینی نهایی، ترکیب شدند. نقشه‌های ریشه میانگین مربع از تبدیل فوریه سریع برگرفته از داده‌های حسی، به عنوان ویژگی‌های ورودی برای مدل‌های CNN استخراج شد. در [۱۲۴]، سینگ و همکاران، از تجزیه مدل تجربی مجموعه (EEMD) برای تجزیه ورودی حسی خام به توابع حالت ذاتی (IMF) با معیارهای انتخاب بر اساس الگوریتم‌های توابع مدل ترکیبی (CMF)، که به عنوان ویژگی‌های ورودی برای مدل‌های CNN بکار گرفته شد، استفاده کردند. در [۱۲۵]، تبدیل فوریه کوتاه‌مدت، تبدیل موجک و تبدیل هیلبرت-هوانگ برای تولید ورودی‌های تصویر در مدل CNN خود، اتخاذ شد.

همانطور که در بخش ۲.۳ بررسی شد، CNN همچنین می‌تواند برای سیگنال سری زمانی یک بُعدی اعمال شود و عملیات مربوطه به تفصیل شرح داده شده است. در [۱۲۶]، CNN یک بُعدی با موفقیت بر روی داده‌های سری زمانی خام برای تشخیص خطای موتور توسعه یافت، که در آن استخراج ویژگی و طبقه بندی با هم تجمیع شدند. عبدالجابر و همکاران CNN یک بُعدی پیشنهادی بر روی سیگنال ارتعاشی نرمال شده، پیشنهاد دادند که

می‌تواند تشخیص آسیب مبتنی بر ارتعاش و محلی سازی آسیب ساختاری را در زمان واقعی، انجام دهد. مزیت این رویکرد توانایی آن در استخراج ویژگی‌های حساس به آسیب بهینه و به طور خودکار از سیگنال‌های شتاب خام است که نیازی به پیش پردازش اضافی یا رویکردهای پردازش سیگنال، ندارد [۱۲۷]. جینگ و همکاران، کارایی CNN یک‌بعدی در انواع داده‌های مختلف از جمله داده‌های زمان خام، داده‌های طیف فرکانس، داده‌های زمان-فرکانس و چندین ویژگی دست ساز برای تشخیص عیب گیربکس و CNN، را بررسی کردند و بهترین کارایی را با طیف ویژگی به دست آورد [۱۲۸]. در [۱۲۹]، ژانگ و همکاران، CNN پیشنهادی همراه با تداخل آموزشی (TICNN) را برای تشخیص خطای یاتاقان که ورودی آن سیگنال سری زمانی خام است، بکار بردند. برای تقویت داده‌ها، هسته با تغییر نرخ خروج به سیگنال ورودی اعمال شد و اندازه دسته به اندازه تعداد انواع خطا، تعیین شد که می‌تواند توانایی تعمیم مدل آموزش‌دیده را بهبود بخشد. با توجه به این دو اصلاح، مدل پیشنهادی آنها توانست در محیط‌های نویز دار و محیط متغیر، دقت بالا و کارایی پایدار، داشته باشد. در [۱۳۰]، شبکه‌های عصبی کانولوشن عمیق همراه با هسته‌های لایه اول گسترده (WDCNN) توسط ژانگ و همکاران پیشنهاد شدند. روش پیشنهادی از سیگنال‌های ارتعاشی خام به عنوان ورودی استفاده کرد (افزایش داده‌ها برای تولید ورودی‌های بیشتر استفاده شد) و هسته‌های گسترده را در اولین لایه کانولوشن برای استخراج ویژگی‌ها و سرکوب نویز با فرکانس بالا، اعمال کرد. هسته‌های کانولوشن کوچک در لایه‌های قبلی برای نگاشت غیرخطی چند لایه استفاده شدند. تکنیکی به نام عادی سازی دسته‌ای تطبیقی [۱۳۱] که پارامترها در نرمال سازی دسته ای بر اساس نمونه های آزمایشی تنظیم می شدند، برای بهبود توانایی تطبیق دامنه مدل اجرا شد.

جدا از کارهای قبلی که در آن CNN‌های پایش شده، پذیرفته شدند، سان و همکاران، یک مدل یادگیری با ویژگی متمایز کانولوشن را برای تشخیص عیب موتور القایی [۱۳۲] پیشنهاد کردند. همانطور که در شکل ۹ نشان داده شده، یک سبک تجمیع کانولوشن پیش‌خور، پیشنهاد شده که در آن فیلترهای موضعی توسط شبکه عصبی پس‌رو (BPNN) از قبل یاد می‌گیرند. سپس، ارائه آموخته شده برای طبقه‌بندی شرایط خطا به SVM، وارد شدند. از آنجایی که فیلترهای موضعی توسط BPNN، آموخته می‌شوند، معماری تجمیع کانولوشن زیر می‌تواند ویژگی‌های متمایز و ثابت را از داده‌های ارتعاشی خام، به سرعت استخراج کند. داده‌های ورودی سیگنال ارتعاشی یک‌بعدی است به طوری که کار آنها نیز متعلق به CNN یک‌بعدی است. در [۱۳۳]، کابرا و همکاران، خودرمنگار کانولوشن (CAE) را برای مقداردهی اولیه پارامترهای مدل CNN، تحت نظارت خود، اتخاذ کردند. در CAE، رمزگذار شامل کانولوشن و تجمیع حداکثر است در حالی که رمزگشا شامل غیرتجمیع به عنوان تکرار افقی و عمودی مقدار فعال سازی و کانولوشن است. هدف آموزشی CAE، به عنوان فاصله اقلیدسی، تعریف شد.

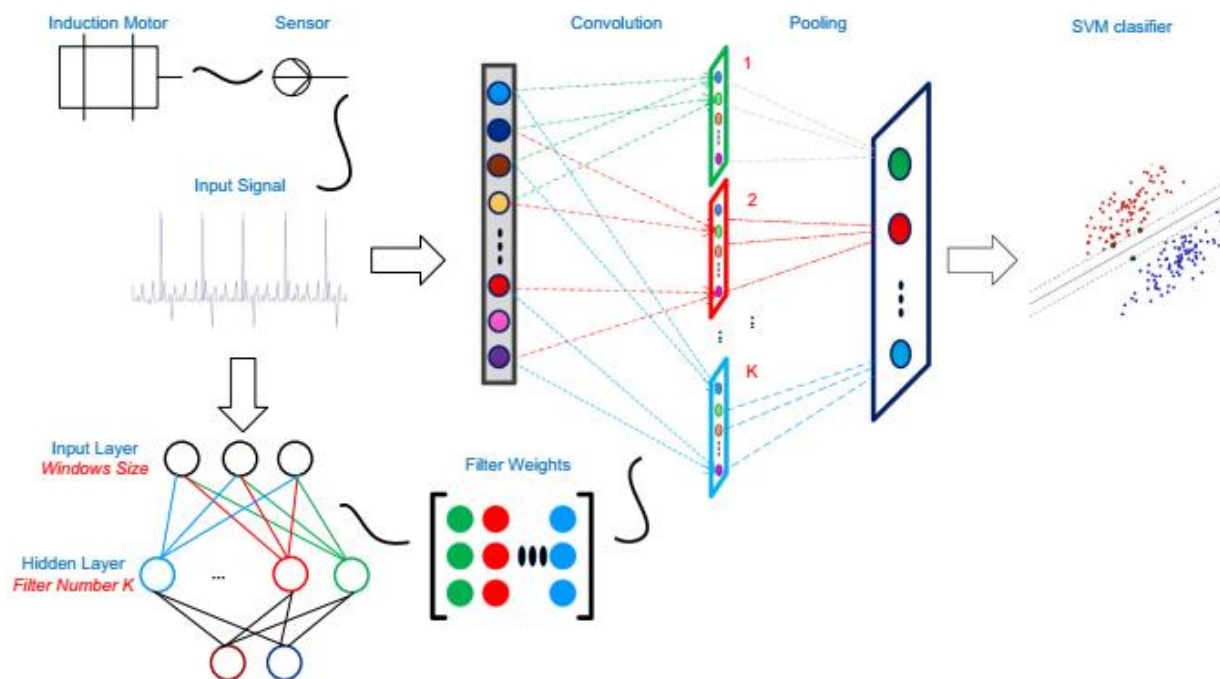


Fig. 9. Illustrations of the proposed unsupervised CNN for induction motor fault diagnosis in [132].

در [۱۳۴]، ژائو و همکاران، CNN را با استفاده از اتصالات کانولوشن در ساختار فایل تصادفی مولد مارکوف به درون DBN، تجمیع کردند. علاوه بر این، واحدهای مرئی گاوسی برای ساخت این مدل، معرفی شدند. ورودی مدل، داده‌های فشرده‌شده‌ای بود که توسط خودمزننگار به‌عنوان ارائه‌های پنهان آموخته شد. دسته‌کننده پیشینه هموار، برای تشخیص خطای یاتاقان استفاده شد.

در [۱۳۵]، ژائو و همکاران، گونه‌ای از شبکه‌های باقیمانده عمیق به نام شبکه‌های باقیمانده عمیق با ضرایب موجک وزن‌دار پویا (DRN + DWWC) را توسعه دادند. ورودی‌های مدل، یک سری ضرایب بسته موجک در باندهای فرکانسی مختلف است. DRN، شامل چندین بلوک ساختمانی باقیمانده به عنوان پشته‌ای از چندین لایه کانولوشن، نرمال‌سازی‌های دسته‌ای (BNs)، تابع فعال‌سازی relu و یک میانبر هویتی، بود. در DRN سنتی، لایه‌های وزن‌دهی پویا برای اعمال وزن‌های پویا برای نگاشت ویژگی ورودی طراحی شده و عناصر در هر ردیف در نگاشت ویژگی دارای وزن مشابهی هستند. استفاده از لایه‌های وزن‌دهی پویا با تأکید بر مشارکت‌های مختلف ضرایب بسته موجک در باندهای فرکانسی مختلف، متمرکز بود. در [۱۳۶]، پان و همکاران، یک مدل جدید CNN به نام LiftingNet را برای طبقه‌بندی خطا، پیشنهاد کردند که بر اساس CNN و تبدیل موجک نسل دوم (SGWT) بود. ماژول اصلی در LiftingNet، شامل لایه تقسیم، لایه پیش‌بینی و لایه به‌روزسانی، بود. لایه تقسیم، توالی ورودی را به یک سری زوج و یک سری فرد تقسیم کرد. سپس، لایه‌ها را پیش‌بینی و به‌روزسانی

می‌کند تا با استفاده از اندازه‌های مختلف هسته، ارائه‌های ورودی را در مقیاس‌های مختلف، یاد بگیرند. پس از استکینگ ماژول‌های فوق، لایه تجمیع حداکثر و لایه کاملاً متصل برای یادگیری ارائه نهایی، بکار گرفته شد. تأیید شده که LiftingNet می‌تواند عنصر گذرا و با فرکانس بالا را از طریق لایه پیش‌بینی یاد بگیرد و عنصر تدریجی و با فرکانس کم را از طریق لایه به روز رسانی، رمزگذاری کند. علاوه بر این، هسته‌های بزرگ و توابع غیرخطی، قادر به فیلتر کردن نویز بودند.

برای ارائه یک نمای کلی در مورد همه این مدل‌های CNN فوق که با موفقیت در حوزه MHMS به کار گرفته شدند، سبک آنها در جدول ۲ خلاصه شده است. برای توضیح، از اختصارات استفاده شده، ساختار CNN اعمال شده در کار ویمر [۱۱۸] به صورت ورودی $[32 \times 32] - 64C[3 \times 3] - 64P[2 \times 2] - 128C[3 \times 3]$ ، نشان داده شده است. آن، بدین معنی است که داده‌های دوبعدی ورودی 32×32 است و CNN در ابتدا ۲ لایه کانولوشن را همراه با طراحی مشابه که تعداد فیلتر آن ۶۴ و اندازه فیلتر، 3×3 ، است بکار می‌گیرد، سپس، یک لایه تجمیع حداکثر که اندازه تجمیع آن 2×2 است را روی هم قرار می‌دهد، سپس ۳ لایه کانولوشن با همان طرح که تعداد فیلترها ۱۲۸ و اندازه فایل 3×3 است اعمال می‌کند، سپس یک لایه تلفیقی که اندازه تجمیع آن 2×2 است را اعمال می‌کند. در نهایت از دو لایه کاملاً متصل استفاده می‌کند که تعداد نورون‌های پنهان هر دو، ۱۰۲۴ است. لازم به ذکر است که اندازه لایه خروجی، با توجه به اینکه برای کار خاص می‌باشد و معمولاً به تعداد دسته‌ها تنظیم می‌شود، در اینجا، مشخص نشده است.

۳.۴. RNN برای پایش ماشینی سلامت

اکثر داده‌های ماشینی به داده‌های حسگر، متعلق هستند که در سری‌های زمانی طبیعی، هستند. مدل‌های RNN از جمله LSTM و GRU به‌عنوان یک نوع سبک محبوب برای مدیریت داده‌های متوالی با توانایی در رمزگذاری اطلاعات زمانی، پدیدار شده‌اند. به تازگی، این مدل‌های پیشرفته RNN، برای کاهش مشکل آموزش ورای RNN وانیلی برای نظارت ماشینی بر سلامت، پیشنهاد شده‌اند. در [۱۳۷]، یوان و همکاران، سه مدل RNN شامل مدل‌های وانیلی RNN، LSTM و GRU را برای تشخیص عیب و پیش‌آگهی موتور هواپیما، بررسی کردند. آنها دریافتند که این مدل‌های پیشرفته RNN و LSTM و GRU از RNN وانیلی بهتر، کار می‌کنند. مشاهدات جالب دیگر این بود که مدل گروهی سه نوع RNN فوق، کارایی LSTM را افزایش نداد. ژائو و همکاران یک ارزیابی تجربی از سیستم پایش ماشینی سلامت مبتنی بر LSTMs را در آزمون خوردگی ابزار ارائه کردند [۱۳۸]. مدل LSTM اعمال شده، داده‌های حسی خام را در بردارها رمزگذاری کرد و خوردگی ابزار مربوطه را پیش‌بینی کرد. ژائو و همکاران سپس یک مدل یادگیری عمیق پیچیده‌تر را با ترکیب CNN و LSTM به نام شبکه‌های

حافظه کوتاه‌مدت دو جهته کانولوشن (CBLSTM) طراحی کردند [۱۳۹]. همانطور که در شکل ۱۰ نشان داده شده، CNN برای استخراج ویژگی‌های موضعی قوی برگرفته از ورودی متوالی استفاده شد و سپس LSTM دو جهته برای رمزگذاری اطلاعات زمانی در این خروجی متوالی CNN، استفاده شد. در نهایت، لایه‌های استکینگ کاملاً متصل و لایه رگرسیون خطی برای پیش‌بینی مقدار هدف اضافه شدند. در آزمایش خوردگی ابزار، مدل پیشنهادی توانست از چندین روش پایه پیشرفته از جمله مدل‌های رایج LSTM، بهتر عمل کند. جدا از مدل‌های یادگیری ویژگی خودکار قبلی، ژائو و همکاران، یک رویکرد ترکیبی، پیشنهاد کردند که طراحی ویژگی‌های دست ساز را با یادگیری ویژگی‌های خودکار برای پیش‌بینی سلامتی، ترکیب می‌کند [۱۴۰]. همانطور که در شکل ۱۱ نشان داده شده، ویژگی‌های پنجره‌های سری‌های زمانی ورودی، استخراج شده و به یک شبکه GRU دو جهته تقویت شده، وارد شد. شبکه دو جهته پیشرفته GRU، شامل دو ماژول از جمله GRU دو جهته و میانگین وزنی ویژگی، است. مدل پیشنهادی آنها در سه کار پیش‌بینی سلامتی، پیش‌بینی خوردگی ابزار، تشخیص عیب گیربکس و تشخیص اولیه عیب یاتاقان، اثربخشی و تعمیم رویکرد ترکیبی پیشنهادی در طراحی ویژگی‌های دست‌ساز و یادگیری ویژگی‌های خودکار را نشان داده است. در [۱۴۱]، مالهوترا، ساختار بسیار جالبی را برای پیش‌بینی RUL پیشنهاد کرد. آنها، یک ساختار رمزگذار-رمزگشا مبتنی بر LSTM، طراحی کردند، که رمزگذار مبتنی بر LSTM، در ابتدا یک توالی ورودی چند متغیره را به یک بردار با طول ثابت تبدیل می‌کند و سپس، رمزگشای LSTM از بردارها برای تولید توالی هدف، استفاده می‌کند. وقتی صحبت از پیش‌بینی RUL می‌شود، مفروضات آنها این است که مدل را می‌توان در ابتدا در سیگنال خام مربوط به رفتار عادی در یک روش بدون نظارت، آموزش داد. سپس، خطای بازسازی را می‌توان برای محاسبه شاخص سلامت (HI) استفاده کرد، که آن، سپس برای تخمین RUL استفاده می‌شود. آن، ذاتی است که خطای بزرگ بازسازی مربوط به یک وضعیت ناسالم ماشین باشد.




Fig. 10. Illustrations of the proposed Convolutional Bi-directional Long Short-Term Memory Networks in [139].

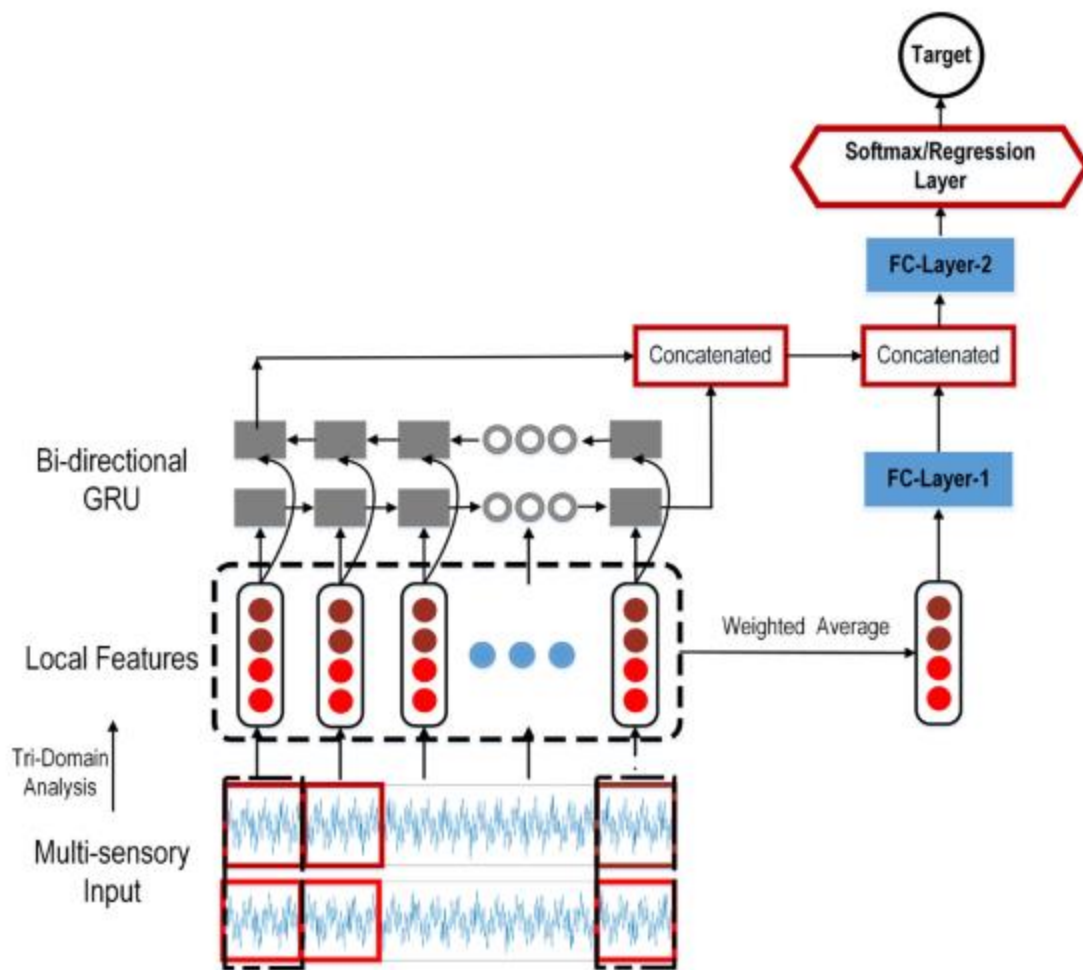


Fig. 11. Illustrations of the proposed Local Feature-based Gated Recurrent Unit Networks in [140].

۳.۵. استخراج مشخصه (ویژگی) خطا برای MHMS مبتنی بر DL

در جلسات فوق، کاربردهای مختلف روش‌های یادگیری عمیق در سیستم‌های پایش ماشینی سلامت، بررسی شده است. می‌توان دریافت که استخراج ویژگی یا پیش پردازش ویژگی در کارهای خاصی مورد نیاز است. اگرچه یادگیری عمیق می‌تواند بازنمایی‌ها را از ابتدا بیاموزد، داده‌های حسی نویز دار بدست‌آمده از ماشین‌ها، کانولوشن در سیستم‌های عامل ماشین و نمونه‌های داده ناکافی، همگی باعث می‌شوند قبل از تغذیه داده‌های خام برای مدل‌های DL، استخراج مشخصه خطا اعمال شود. علاوه بر این، سیگنال حسی نادر و ناسازگار، به عنوان مثال، برون هشته، ممکن است تأثیر غیرقابل پیش بینی بر سیستم مکانیکی غیرخطی و واقعی داشته باشد [۱۴۲-۱۴۴]. استخراج مناسب مشخصه خطا می‌تواند این اثر منفی برون هشته را کاهش دهد. بنابراین، خلاصه‌ای از این تکنیک‌های استخراج ویژگی که در آثار فوق اتخاذ شده‌اند، به شرح زیر ارائه می‌شوند:

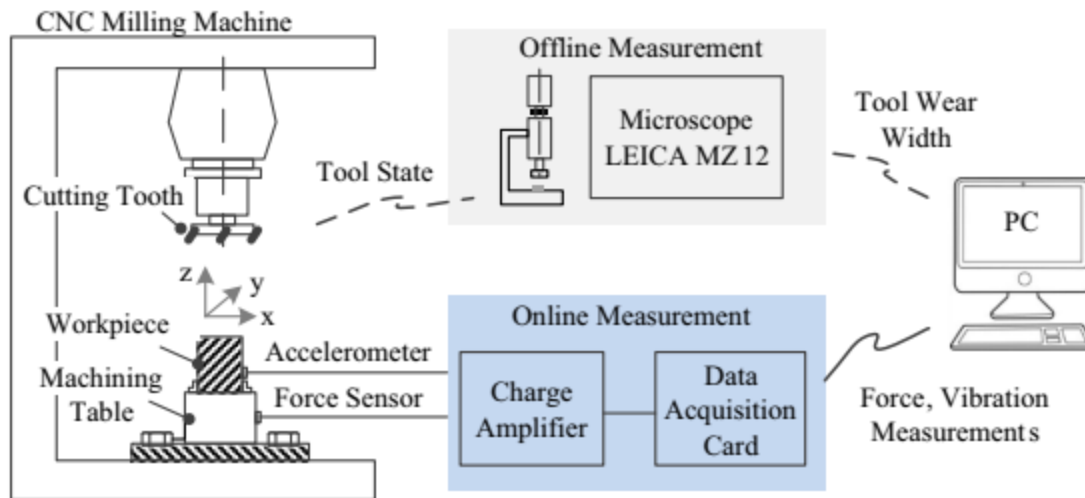


Fig. 12. Schematic of the experimental setup for tool wear prediction [23].

۳.۵.۱. حوزه زمان

داده‌های حسی خام در ماهیت سیگنال سری زمانی هستند. بنابراین، برخی از ویژگی‌های حوزه زمانی آماری را می‌توان به عنوان ویژگی‌های متمایز وارد شده به سیستم‌های DL، استخراج کرد. میانگین، ریشه میانگین مربع (RMS)، انحراف معیار و واریانس، به دفعات استفاده شد. با توجه به سیگنال ثابت، چولگی و کشیدگی نیز به عنوان ویژگی‌های ورودی استخراج شد.

۳.۵.۲. حوزه فرکانس

به دلیل وجود تکان‌های دوره‌ای در چندین خطای ماشینی، مولفه‌های فرکانس غالب، ویژگی‌های اطلاعاتی و متمایز هستند. FFT (تبدیل فوریه سریع) می‌تواند برای تبدیل سیگنال‌های ارتعاشی حوزه زمانی به سیگنال‌های حوزه فرکانس، اعمال شود. فرکانس میانگین، فرکانس واریانس ریشه، چولگی طیفی و کشیدگی طیفی به عنوان مومنت‌های مرتبه اول، مرتبه دوم، مرتبه سوم و مرتبه چهارم طیف فوریه، می‌تواند به عنوان ویژگی محاسبه کرد. لازم به ذکر است که ارائه حوزه فرکانس معمولاً برای سیگنال ثابت استفاده می‌شود.

۳.۵.۳. حوزه زمان-فرکانس

ویژگی‌های حوزه فرکانس-زمان برای سیگنال‌های غیرثابت، مفید هستند. تبدیل فوریه کوتاه مدت، تبدیل/تجزیه موجک و تجزیه مدل تجربی (EMD)، به طور گسترده برای تبدیل سیگنال یک بُعدی به سیگنال دوبعدی زمان و فرکانس، استفاده می‌شود.

علاوه بر این، چندین روش استخراج ویژگی را در این سه حوزه بالا ارائه کردیم که در بخش بعدی با جزئیات بیشتر، توضیح داده خواهد شد.

۴. ارزیابی های تجربی تکنیک های مختلف DL

در این بخش، یک ارزیابی سیستماتیک از این مدل های یادگیری عمیق که در بالا و در مورد وظایف پایش ماشینی سلامت ارائه شده، خواهیم داشت. به طور خاص، وظیفه سنجش خوردگی ابزار، معرفی شده است.

۴.۱. جزئیات پیاده سازی

توصیف مجموعه داده: مجموعه داده ها از یک ماشین CNC با سرعت بالا و در طول عملیات آسیاب خشک، نمونه برداری شد و نمودار شماتیک پلت فرم آزمایشی آن در ۱۲ نشان داده شده است. تنظیمات آزمایشی دقیق را می توان در [۱۴۵] یافت، که در آن هفت حسگر شامل نیرو و ارتعاش، هر کدام در سه جهت و AE-RMS قرار داده شده است. مقدار حقیقت مبنا با استفاده از میکروسکوپ LEICA MZ12 برای اندازه گیری هر فلوت جداگانه پس از اتمام هر سطح، یعنی هر تعداد برش، به دست آمد. مدل های یادگیری ماشینی برای پیش بینی ساییدگی واقعی پهلو از روی داده های حسی، اتخاذ می شوند. سه رکورد کاتر جداگانه با نام های c1، c4 و c6 موجود است و هر رکورد شامل ۳۱۵ نمونه داده است.

در آزمایش های ما، c4 به عنوان داده های آزمایشی استفاده می شود در حالی که سایر رکوردهای c1 و c6 به عنوان داده های آموزشی استفاده می شوند. با توجه به ابعاد بالای سیگنال سری زمانی خام، ابتدا استخراج ویژگی اعمال می شود. هفت نوع ویژگی شامل حوزه زمان، حوزه فرکانس و حوزه زمان-فرکانس طراحی شده که در جدول ۳ آمده است.

Table 3
List of Extracted Features.

Domain	Features	Expression
Statistical	RMS	$z_{rms} = \sqrt{\frac{1}{n} \sum_{i=1}^n z_i^2}$
	Variance	$z_{var} = \frac{1}{n} \sum_{i=1}^n (z_i - \bar{z})^2$
	Maximum	$z_{max} = \max(z)$
	Skewness	$z_{skew} = E[(\frac{z-\mu}{\sigma})^3]$
	Kurtosis	$z_{kurt} = E[(\frac{z-\mu}{\sigma})^4]$
	Peak-to-Peak	$z_{p-p} = \max(z) - \min(z)$
Frequency	Spectral Skewness	$f_{skew} = \sum_{i=1}^k k(\frac{f_i - \bar{f}}{\sigma_f})^3 S(f_i)$
	Spectral Kurtosis	$f_{kurt} = \sum_{i=1}^k k(\frac{f_i - \bar{f}}{\sigma_f})^4 S(f_i)$
Time-Frequency	Wavelet Energy	$E_{WT} = \sum_{i=1}^N wt_{\phi}^2(i)/N$

در اینجا، ویژگی انرژی موجک، انرژی تجزیه بسته موجک ۸ سطحی با استفاده از db1 است که مربوط به ضریب موجک با انرژی بالاتر می باشد و آن مربوط به فرکانس مشخصه ماشین است. با در نظر گرفتن هفت حسگر استفاده

شده، ابعاد بردار ویژگی دست ساز، ۷۰ است. برای LSTM و CNN، داده‌های ورودی تانسور هستند به طوری که داده‌ها به ترتیب به ۲۰ پنجره تقسیم می‌شوند و سپس برای استخراج ویژگی می‌روند. برای مدل‌های دیگر مانند SVM، داده‌های ورودی، بردار است به طوری که کل سری زمانی به درون استخراج ویژگی‌ها، وارد می‌شود. بنابراین، ما دو نوع ویژگی استخراج شده داریم، یکی به شکل ۷۰*۲۰ و دیگری به شکل ۷۰.

رویکردهای مقایسه‌ای: این روش‌های زیر با هم مقایسه می‌شوند:

* SVR خطی: رگرسیون بردار با پشتیبانی خطی، که ویژگی‌های ورودی آن، ویژگی‌های استخراج شده کل سری‌های زمانی است. مدت تنظیم بر روی ۱ تنظیم شده است.

* RBF SVR: پشتیبانی از رگرسیون برداری با هسته RBF، که ویژگی‌های ورودی آن ویژگی‌های استخراج شده از کل سری زمانی است. مدت تنظیم به ۱ تنظیم شده است.

* الگوریتم جنگل تصادفی: رگرسیون جنگل تصادفی که ویژگی‌های ورودی آن ویژگی‌های استخراج شده از کل سری‌های زمانی است. تعداد برآوردگر ۵۰ و حداکثر عمق درخت تصمیم، ۲ تنظیم شده است.

* شبکه عصبی: شبکه عصبی که ویژگی‌های ورودی آن ویژگی‌های کل سری زمانی استخراج شده است. شبکه عصبی شامل دو لایه پنهان است که اندازه آنها به ترتیب ۷۰ و ۱۴۰ است. برای جلوگیری از بیش‌برازش، لایه از قلم افتاده با احتمال پوشاندن ۰.۲ بر روی آخرین لایه اعمال می‌شود.

* خودرمننگار: خودرمننگار که ویژگی‌های ورودی آن ویژگی‌های استخراج شده از کل سری‌های زمانی است. تابع زیان پیش آموزش، خطای میانگین مربع است. اندازه لایه‌های مخفی در پیش آموزش، به ترتیب ۱۰۰ و ۱۴۰ می‌باشد. در آموزش نظارت شده یک لایه با سایز ۹۰۰ به دنبال این دو لایه مخفی اضافه می‌شود.

* نويز زدایی خودرمننگار: نويز زدایی خودرمننگار که ویژگی‌های ورودی آن، ویژگی‌های استخراج شده از کل سری زمانی است. در مقایسه با خودرمننگار رایج، یک نويز خروجی روی ویژگی‌های ورودی با احتمال پوشاندن ۰.۰۱ اضافه می‌شود.

* DBN: شبکه باور عمیق که ویژگی‌های ورودی آن ویژگی‌های استخراج شده از کل سری‌های زمانی است. اندازه لایه‌های مخفی به ترتیب ۱۰۰ و ۱۴۰ است.

* CNN: شبکه عصبی کانولوشن که ویژگی‌های ورودی آن ویژگی‌های ترتیبی هستند. دو لایه کانولوشن یک-بُعدی با اندازه پنجره ۳ اتخاذ شده است. و اندازه لایه‌های مخفی آنها ۱۰۰ و ۱۴۰ تنظیم می‌شود. سپس یک لایه تجمیع حداکثر، اضافه می‌شود که بعد از آن یک لایه کاملاً متصل با اندازه ۹۰۰ و یک لایه از قلم افتاده که احتمال پوشاندن آن ۰.۲ است، اضافه می‌شود.

* LSTM: شبکه حافظه بلند مدت که ویژگی‌های ورودی آن ویژگی‌های ترتیبی هستند. ما دو لایه تکراری را روی هم انباشته کردیم که اندازه لایه‌های مخفی آنها روی ۱۰۰ و ۱۴۰ تنظیم شده است. یک لایه کاملاً متصل با اندازه ۹۰۰ و یک لایه حذفی با احتمال پوشاندن ۰.۲، اضافه می‌شود.

* LSTM دو جهت: شبکه حافظه کوتاه مدت دو جهت که ویژگی‌های ورودی آن ویژگی‌های ترتیبی هستند. در مقایسه با LSTM، داده‌ها در دو جهت به LSTM دو طرفه وارد می‌شوند: از ابتدا تا انتها و از انتها به ابتدا. علاوه بر این، مجموعه داده و کد، منتشر شده است. به دلیل مشکل حفظ حریم خصوصی و نگرانی احتمالی حق نسخه برداری، ما فقط ویژگی‌های استخراج شده را برای این داده‌ها به جای سری‌های زمانی خام، ارائه می‌کنیم. از آنجایی که تقریباً تمام مدل‌های یادگیری عمیق نیاز به مقداردهی اولیه پارامتر تصادفی دارند، همه مدل‌های مقایسه‌ای، پنج بار اجرا شدند. در اینجا، ما دو معیار، شامل میانگین خطای مطلق (MAE) و میانگین مربعات خطا (MSE) را اتخاذ می‌کنیم.

$$MAE = \frac{1}{n} \sum_{i=1}^n |\tilde{y}_i - y_i| \quad (20)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (\tilde{y}_i - y_i)^2} \quad (21)$$

در اینجا، y_i و \tilde{y}_i درست هستند و عمق خوردگی، بیش از حد پیش‌بینی می‌شود.

۴.۲. نتایج تجربی

کارایی همه روش‌های مقایسه شده، در جدول ۴ نشان داده شده است. علاوه بر این، نتایج رگرسیون همگی در شکل ۱۳ نشان داده شده است. در این بخش، ما سعی می‌کنیم به کاربرد مدل‌های یادگیری عمیق در وظایف پایش ماشینی سلامت اشاره کنیم. لازم به ذکر است که به دلیل تنظیمات پیش فرض انتخاب ابرپارامتر و حجم کم داده‌ها، ارتقا مدل‌های یادگیری عمیق در مقایسه با روش‌های سنتی چندان زیاد نیست. با این حال، همانطور که در جدول ۴ نشان داده شده، هنوز هم می‌توان دریافت که مدل‌های یادگیری عمیق بهتر از این مدل‌های یادگیری ماشینی رایج، عمل می‌کنند. علاوه بر این، به دلیل پیش‌آموزش، خودرمنزنگار، قادر به دستیابی کارایی بهتری نسبت به شبکه عصبی است. با این حال، DBN کمی بدتر از شبکه عصبی عمل کرد، که ممکن است اینطور توضیح داده شود که آموزش DBN به دلیل نمونه‌برداری مورد نیاز در هر لایه، سخت است. ورود نویز از قلم افتاده، کارایی خودرمنزنگارهای نویزدا را بیشتر بهبود می‌بخشد. اگرچه CNN، LSTM و Bi-LSTM، کمی بدتر از خودرمنزنگار نویزدا، عمل می‌کنند، انتخاب ابرپارامتر، با توجه به کانولوشن این مدل‌ها، ممکن است

کارایی آنها را افزایش دهد. در مورد LSTM، LSTM دو جهته بهتر از LSTM عمل می‌کند. این بدان معنی است که پردازش دو طرفه سیگنال سری زمانی برای پایش ماشینی سلامت، مناسب می‌باشد.

Table 4
The Results of all the approaches in tool wear prediction under the two criteria including MAE and MSE.

Method	MAE	MSE
Linear SVR	13.7	248.9
RBF SVR	17.6	402.9
Random Forest	14.4 ± 0.2	289 ± 5.9
Neural Network	11.5 ± 1.2	191.6 ± 26.8
Auto-encoder	11.2 ± 1.9	185 ± 41.9
Denoising Auto-encoder	9.3 ± 1.8	143.5 ± 40.4
DBN	11.7 ± 1.3	194.6 ± 34.2
LSTM	11.0 ± 2.5	193.9 ± 65.3
Bi-directional LSTM	10.6 ± 1.9	191.5 ± 56.1
CNN	11.0 ± 1.3	197.2 ± 30.9

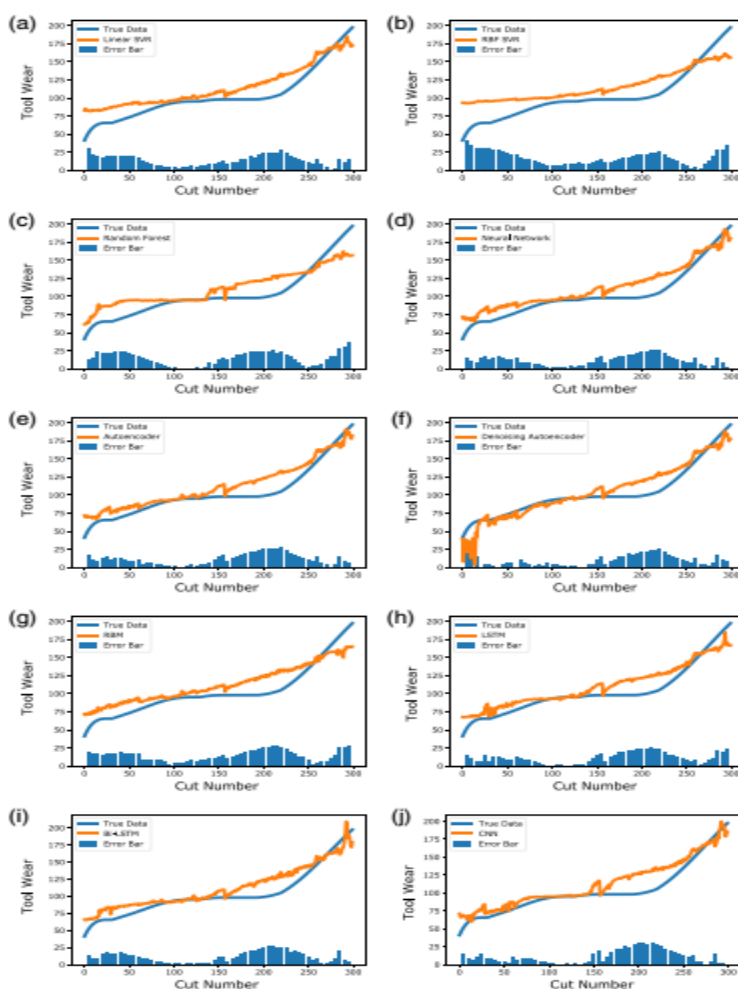


Fig. 13. Regression Result of All Compared Methods. (a) Linear SVR, (b) RBF SVR, (c) Random Forest, (d) Neural Network, (e) Autoencoder, (f) Denoising Autoencoder, (g) DBN, (h) LSTM, (i) Bi-directional LSTM, (j) CNN

* در مقایسه با مدل‌های یادگیری ماشینی رایج، مدل‌های یادگیری عمیق قادر به دستیابی کارایی برتر در زمینه پایش ماشینی سلامت هستند.

* پیش آموزش در خودرمننگار می تواند کارایی نظارت بر سلامت ماشین را ارتقا ببخشد.

* تکنیک نوپوزدایی برای نظارت بر سلامت ماشین مفید است.

* LSTM, CNN و انواع آنها می توانند، نظارت بر سلامت ماشین را انجام دهند. با این حال، به دلیل پیچیدگی مدل، انتخاب ابرپارامتر برای دستیابی به کارایی جدیدترین تکنولوژی، مورد نیاز است.

۵. خلاصه و مسیرهای آینده

در این مقاله، ما یک نمای کلی نظامند از پیشرفته ترین MHMS مبتنی بر DL، ارائه کردیم. یادگیری عمیق، به عنوان زیرشاخه یادگیری ماشینی و به عنوان پلی بین داده های ماشینی بزرگ و MHMS مبتنی بر داده عمل می کند. بنابراین، در پنج سال گذشته، آنها در کارهای مختلف پایش ماشینی برای سلامت، استفاده شده اند. این MHMS مبتنی بر DL پیشنهادی بر اساس چهار دسته از سبک DL خلاصه می شوند: مدل های خودرمننگار، مدل های ماشین های بولترمن محدود شده، شبکه های عصبی کانولوشن و شبکه های عصبی بازگشتی. از آنجایی که تحقیقات MHMS مبتنی بر DL به سرعت در حال رشد است، امیدواریم پیام های مربوط به قابلیت های این تکنیک های DL، به ویژه یادگیری ارائه برای داده های پیچیده ماشینی و پیش بینی هدف برای وظایف مختلف پایش ماشینی سلامت، به خوانندگان منتقل شود. از طریق این کارهای قبل، می توان دریافت که MHMS مبتنی بر DL به نیروی انسانی زیاد و دانش تخصصی نیاز ندارد؛ به عنوان مثال، ساختار سرتاسری (انتها به انتها) قادر است داده های ماشینی خام را به اهداف، ترسیم کند. بنابراین، استفاده از مدل های یادگیری عمیق به انواع خاصی از ماشین ها محدود نمی شود، که آن می تواند یک راه حل کلی برای رسیدگی به مشکلات پایش ماشینی سلامت باشد. علاوه بر این، برخی از روندهای تحقیقاتی و جهت گیری های بالقوه تحقیقات آینده به شرح زیر ارائه شده است:

* مجموعه داده بزرگ منبع (متن) باز: با توجه به پیچیدگی عظیم مدل در ورای روش های DL، کارایی MHMS مبتنی بر DL، به شدت به مقیاس و کیفیت مجموعه داده ها بستگی دارد. از سویی، عمق مدل DL، توسط مقیاس مجموعه داده ها، محدود می شود. در نتیجه، مدل معیار CNN برای تشخیص تصویر، ۱۵۲ لایه دارد که می تواند توسط مجموعه داده بزرگ ImageNet که حاوی بیش از ده میلیون تصویر حاشیه نویسی شده است، پشتیبانی شود [۱۴۶, ۱۴۷]. در مقابل، مدل های DL پیشنهادی برای MHMS ممکن است تا ۵ لایه پنهان را روی هم قرار دهند. و مدل آموزش داده شده در چنین مجموعه داده های بزرگی می تواند مقداردهی اولیه مدل برای وظیفه/مجموعه داده خاص تابعه، باشد. بنابراین، طراحی و انتشار مجموعه داده های ماشینی در مقیاس بزرگ معنادار است.

* استفاده از شناخت حوزه: یادگیری عمیق یک کلید اساسی برای همه مشکلات پایش ماشینی برای سلامت نیست. شناخت حوزه می‌تواند به موفقیت استفاده از مدل‌های DL در پایش ماشینی سلامت کمک کند. به عنوان مثال، استخراج ویژگی‌های متمایز می‌تواند اندازه مدل‌های DL دنبال‌شده را کاهش دهد و اصطلاح منظم‌سازی مناسب برای کار خاص، می‌تواند کارایی نهایی را افزایش دهد [۸۴].

* تجسم مدل و داده: تکنیک‌های یادگیری عمیق، به‌ویژه شبکه‌های عصبی عمیق، به عنوان مدل‌های جعبه سیاه در نظر گرفته شده‌اند، یعنی مکانیسم‌های محاسباتی درونی آن‌ها غیرقابل توضیح است. تجسم ارائه آموخته‌شده و مدل کاربردی، می‌تواند بینش‌هایی را در مورد این دست مدل‌های DL ارائه دهد و سپس بینش‌های به دست آمده توسط این نوع تعاملات، می‌تواند ساخت و پیکربندی مدل‌های DL را برای مشکلات پیچیده پایش ماشینی سلامت، تسهیل کند. برخی از تکنیک‌های تجسم‌سازی از جمله مدل t-SNE برای تجسم داده‌های با ابعاد بالا [۱۴۸] و تجسم فعال‌سازی‌های تولید شده توسط هر لایه و ویژگی‌های هر لایه از یک DNN از طریق بهینه‌سازی تنظیم شده [۱۴۹]، پیشنهاد شدند.

* یادگیری عمیق انتقال یافته: یادگیری انتقالی، سعی می‌کند دانش آموخته شده در یک حوزه را در حوزه متفاوت اما مرتبط، اعمال کند [۲۵]. این جهت تحقیق، در پایش ماشینی سلامت، معنی‌دار است، زیرا برخی از مشکلات پایش ماشینی سلامت دارای داده‌های آموزشی کافی هستند در حالی که سایر حوزه‌ها، فاقد داده‌های آموزشی هستند. مدل‌های یادگیری ماشینی از جمله مدل‌های DL آموزش دیده در یک حوزه را می‌توان به حوزه دیگر منتقل کرد. برخی از کارهای قبلی با تمرکز بر استخراج ویژگی‌های انتقال یافته/کاهش ابعاد، انجام شده است [۱۵۰، ۱۵۱]. در [۱۵۲]، اندازه‌گیری حداکثر میانگین اختلاف (MMD) که اختلاف بین حوزه منبع و هدف را ارزیابی می‌کند به تابع هدف شبکه‌های عصبی عمیق، اضافه شد.

* کلاس نامتوازن: توزیع طبقاتی داده‌های ماشینی در زندگی واقعی معمولاً از یک توزیع به شدت چوله (اریب) پیروی می‌کند که در آن بیشتر نمونه‌های داده به دسته‌های کمی تعلق دارند. به عنوان مثال، تعداد داده‌های خطا، بسیار کمتر از داده‌های سلامت، در تشخیص خطا است. برخی از مدل‌های یادگیری ماشینی پیشرفته از جمله SVM و ELM، برای رسیدگی به این مشکل نامتوانی در پایش ماشینی سلامت، پیشنهاد شده‌اند [۱۵۳، ۱۵۴]. اخیراً روش‌های جالبی برای بررسی کاربرد یادگیری عمیق در مسائل کلاس نامتوازن، توسعه یافته‌اند، که شامل مدل‌های CNN با نمونه‌گیری مجدد کلاس یا آموزش حساس به هزینه [۱۵۵] و یکی کردن روش‌های بوت استرپ و مدل CNN است [۱۵۶].

اعتقاد بر این است که در آینده، یادگیری عمیق، بیشتر و موثرتر، به ویژه در عصر داده‌های ماشینی بزرگ، بر پایش ماشینی سلامت تاثیر می‌گذارد.