بررسی و مقایسه روش‌های یادگیری عمیق جهت پیش‌بینی بار شبکه هوشمند

سید محمد شبیری[۱] s.shobeiry@mail.sbu.ac.ir
علی اویسی کیان[۲] a.oveysikian@mail.sbu.ac.ir
[۱] کارشناس ارشد مهندسی برق قدرت دانشگاه شهید بهشتی تهران
[۲] کارشناس ارشد مهندسی برق قدرت دانشگاه شهید بهشتی تهران

چکیده: در طی یک دهه گذشته، صنعت آب و برق سرمایه گذاری های گسترده ای را در رابطه با شبکه های هوشمند داشته است. در شبکه هوشمند اطلاعات و انرژی در یک انتقال دو طرفه مبادله می شوند. شبکه هوشمند کاربردهای زیادی برای هوش مصنوعی مانند شبکه عصبی مصنوعی، یادگیری ماشین و یادگیری عمیق فراهم کرده است. اخیراً، یادگیری عمیق در بسیاری از زمینه ها مانند پیش بینی سری زمانی بار، موضوع جدیدی برای برنامه های هوش مصنوعی بوده است. در این پژوهش الگوریتم های متداول یادگیری عمیق استفاده شده برای مسئله پیش بینی بار در شبکه هوشمند و سیستم های قدرت معرفی و بررسی شده است و در نهایت چندین روش از نظر درصد کاهش خطای جذر میانگین مربعات مقایسه شده اند. هدف از این تحقیق، تحلیل کاربردهای مختلف یادگیری عمیق است که در پیش بینی بار سیستم های قدرت و شبکه هوشمند استفاده می شود.

کلیدواژه‌ها: *پیش بینی بار، شبکه هوشمند، شبکه عصبی مصنوعی، هوش مصنوعی، یادگیری عمیق.*

۱- مقدمه

یادگیری عمیق نوعی از یادگیری ماشینی است که لایه‌های پنهان داخلی عمیق‌تری دارد که به داخل شبکه می‌رسند. هدف آن ساختن دستگاه‌هایی مانند رایانه است که با تقلید از شبکه مغز انسان، همان‌طور که فکر می‌کند، فکر و درک کنند. هوش مصنوعی در بسیاری از صنایع برای فرآیندهای اتوماسیون مانند فعالیت خودکار، تشخیص تصویر و صدا، تصمیم‌گیری در زمینه‌های مهم و دستیاری در تحقیقات علمی موردبررسی قرار گرفته است. الگوریتم‌های یادگیری ماشین، الگوریتم‌های اساسی هوش مصنوعی هستند که برای گرفتن تصمیمات عقلانی از داده‌های خام، الگوهایی را استخراج می‌کنند. یکی از ساده‌ترین الگوریتم‌های یادگیری ماشین، رگرسیون لجستیک است[1]. الگوریتم‌های یادگیری ماشین به یادگیری نظارت‌شده و یادگیری بدون نظارت تقسیم می‌شوند. الگوریتم یادگیری نظارت‌شده بر روی مجموعه داده‌ای که دارای ویژگی‌ها و هر یک از این ویژگی‌ها مرتبط با یک برچسب است، اعمال می‌شود [1]. بااین‌حال، یک الگوریتم یادگیری بدون نظارت برای یک مجموعه داده استفاده می‌شود که دارای ویژگی‌های بسیاری به‌منظور یادگیری خواص مفید از ساختار مجموعه داده است [1]. مجموعه داده‌ها همیشه در الگوریتم‌های یادگیری به داده‌های آموزش و تست تقسیم می‌شود. مجموعه داده‌های آموزش به مدل کمک می‌کند تا از مجموعه داده‌های خام بیاموزد و مجموعه داده‌های تست به اعتبار خروجی مدل کمک می‌کند. محدودیت الگوریتم‌های یادگیری ماشین مدل‌های یادگیری ناکافی برای مجموعه داده‌های وسیع است. رویکرد دیگر هوش مصنوعی، یادگیری نماینده است که از یادگیری ماشین، توسعه‌یافته‌تر است. یادگیری ماشین به‌طور گسترده‌ای در پیش‌بینی بار در مقالات متفاوت و برنامه‌های مختلف استفاده می‌شود.

شبکه عصبی مصنوعی، شبکه عصبی استاندارد با یک‌لایه ورودی، یک‌لایه پنهان و یک‌لایه خروجی است. معماری یادگیری عمیق از سایر مدل‌های شبکه عصبی پیچیده‌تر است زیرا دارای لایه‌ها و محاسبات بیشتری است [1]. در اصل، یادگیری عمیق، شبکه‌های پیچیده‌ای ایجاد می‌کند که در بسیاری از رشته‌ها مانند بینایی رایانه، پردازش صوتی، پردازش زبان طبیعی، بیوانفورماتیک، امور مالی، سیستم‌های قدرت، شبکه‌های هوشمند و موارد دیگر

برای آنالیز نتایج کاربرد دارد. یادگیری عمیق یک مدل محاسباتی پیچیده است که در چندین لایه پنهان طراحی شده است و با استفاده از ویژگی‌هایی به‌عنوان ورودی به مدل یادگیری عمیق، داده‌ها را در انتزاعات مختلف نشان می‌دهد. الگوریتم‌های یادگیری عمیق برای کارهای مختلف یادگیری خصوصاً برای یادگیری بدون نظارت مورداستفاده قرار می‌گیرد. پیش‌بینی بار یکی از برنامه‌هایی است که در بسیاری از مقالات از الگوریتم‌های یادگیری عمیق بهره‌مند شده است. این مقاله مروری بر الگوریتم‌ها و روش‌های یادگیری عمیق را نشان می‌دهد که در پیش‌بینی بار شبکه هوشمند استفاده می‌شود.

۲- بررسی پیش‌بینی بار الکتریکی

چشم‌انداز شبکه هوشمند ایجاد شبکه‌ای قوی، قابل‌اعتماد، کارآمد و به حداقل رساندن هزینه‌های تولید است. هدف از شبکه هوشمند دستیابی به پیشرفت چشمگیر در افزایش استفاده از فناوری و ارتباطات با سرمایه‌گذاری در جریان دوطرفه برق‌رسانی و داده‌ها است. اثربخشی شبکه هوشمند به سه نقش اصلی متکی است: ۱) پیش‌بینی بار، ۲) قیمت‌گذاری پویا و ۳) مدیریت سمت تقاضا که می‌تواند به نگهداری و مدیریت مؤثر شبکه کمک کند. به‌طور خاص، پیش‌بینی بار یکی از مهم‌ترین عوامل در برنامه‌ریزی و بهره‌برداری از سیستم قدرت است. یکی از مهم‌ترین جنبه‌های اقتصاد و همچنین صنایع توسعه‌یافته پیش‌بینی بار برای سیستم‌های قدرت است. پیش‌بینی بار الکتریکی می‌تواند تحت تأثیر عوامل بسیاری باشد که می‌توانند الگوهای مصرفی بار را تغییر دهند. انواع مختلفی از مقالات پیش‌بینی بار وجود دارند که یادگیری عمیق را در سیستم‌های قدرت برای پیش‌بینی کوتاه‌مدت بار[۱] (STLF)، پیش‌بینی میان‌مدت بار[۲] (MTLF) و پیش‌بینی بلندمدت بار[۳] (LTLF) اعمال کرده‌اند. به‌طورکلی، پیش‌بینی بار می‌تواند تحت تأثیر بسیاری از عوامل مانند زمان، آب‌وهوا و نوع مشتری به‌ویژه برای مسائل STLF باشد [2]. بااین‌حال، پیش‌بینی MTLF و LTLF تابع داده‌های تاریخی برای مصرف برق به‌علاوه آب‌وهوا، تعداد مشتری، تعداد تجهیزات و داده‌های جمعیتی است [2]. STLF بیشتر برای بازه زمانی بین یک ساعت تا چند هفته موردمطالعه قرار گرفته است. STLF در کاربردهای مختلفی مانند کنترل زمان حقیقی، برنامه‌ریزی انتقال انرژی، پخش بار اقتصادی و پاسخ به تقاضا استفاده می‌شود [2]. MTLF می‌تواند برای طیف وسیعی از زمان، از یک ماه تا پنج سال به‌منظور برنامه‌ریزی برای نیروگاه‌های آینده نزدیک و نشان دادن پویایی سیستم قدرت در بازه زمانی مورداستفاده قرار گیرد. از LTLF به‌طور متوسط برای ۵ تا ۲۰ سال استفاده شده است. معمولاً از LTLF برای برنامه‌ریزی نیروگاه‌های تولیدی براساس اندازه و نوع به‌منظور برآوردن نیاز آینده و صرفه‌جویی در هزینه‌ها استفاده می‌شود [3].

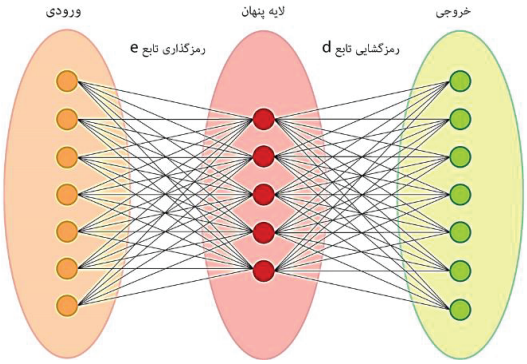
۳- روش‌های یادگیری عمیق برای پیش‌بینی بار

۳-۱- خودرمزنگار[۴]

خودرمزنگار یکی از شبکه‌های عصبی پیشخور است که برای کپی کردن نورون‌های ورودی در نورون‌های خروجی به‌وسیله انتقال نورون‌ها از یک یا چندلایه پنهان (h) مانند خودرمزنگارهای انباشته استفاده می‌شود [1]. قسمت‌های اصلی معماری شبکه خودرمزنگار بر اساس تابع رمزنگار $h = f(x)$ و یک رمزگشا برای بازسازی $\hat{x} = g(h)$ است. بنابراین، خروجی بازسازی‌شده $\hat{x} = g(f(x))$ است که داده ورودی را کپی می‌کند. بازنمایی ریاضی خودرمزنگار به شرح (۱) است:

$$\hat{x} = g(Wx + b) \qquad (۱)$$

که x ورودی است، W وزن‌ها، b بایاس است و g تابع فعال‌سازی است که می‌تواند سیگموئید باشد یا یک تابع خطی یکسوشده. «شکل۱» معماری ساده خودرمزنگار را برای سه لایه ورودی، پنهان و لایه خروجی نشان می‌دهد. این الگوریتم یادگیری معمولاً برای کاهش ابعاد، یادگیری ویژگی یا بازسازی داده‌های خراب استفاده می‌شود[1].



شکل۱: معماری الگوریتم یادگیری خودرمزنگار

[1] Short Term Load Forecasting
[2] Mid-term Load Forecasting
[۳] Long-term Load Forecasting
[۴] Auto encoder

۲-۳- شبکه عصبی بازگشتی[۱] (RNN)

شبکه عصبی بازگشتی اساساً پردازنده شبکه عصبی داده‌های متوالی است زیرا از حافظه داخلی برخوردار است تا وضعیت هر نورون در شبکه را با ورودی قبلی به‌روز کند. شبکه عصبی بازگشتی معمولاً با پس انتشار[۲] آموزش داده می‌شود. بااین‌حال، معمولاً به دلیل ناپدید شدن گرادیان نزولی ضعف دارد [4]. شبکه عصبی بازگشتی عمیق لایه‌های بیشتری را در معماری شبکه عصبی بازگشتی ایجاد می‌کند که مزایای قابل توجهی را ارائه می‌دهد [5]. گراف محاسباتی شبکه عصبی بازگشتی دارای N ورودی x^i متوالی و خروجی y^i متوالی هنگامی‌که زمان دنباله از t تا τ مشخص می‌شود [6]. در نمایش ریاضی زیر (روابط ۲ تا ۴) از گراف محاسباتی مدل شبکه عصبی بازگشتی، تعداد لایه به‌عنوان l از 1 تا N مشخص شده است. تابع فعال‌سازی مربوط به l به‌عنوان h_l نشان داده شده است:

$$a_1(t) = b_1 + W_1 \times h_1^{(t-1)} + U_1 \times x^{(t)} \quad (۲)$$

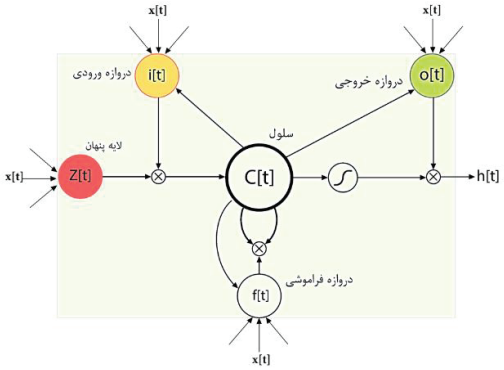
$$a_l(t) = b_1 + W_l \times h_l^{(t-1)} + U_l \times h_l^{(t)} \quad (۳)$$

$$y(t) = b_N + W_N \times h_N^{(t-1)} + U_N \times h_N^{(t)} \quad (۴)$$

که $x(t)$ ورودی است و $y(t)$ خروجی پیش‌بینی شده است.

۳-۳- حافظه کوتاه‌مدت بلند[۳] (LSTM)

همان‌طور که در بالا ذکر شد، مدل RNN در موضوع ناپدید شدن گرادیان نزولی ناکام است، بنابراین LSTM به‌منظور جبران ایراد آن طراحی شده است. LSTM به‌گونه‌ای طراحی شده است که یک حافظه طولانی‌مدت را فراهم می‌کند. در مدل LSTM خود حلقه‌های داخلی وجود دارد که برای ذخیره‌سازی اطلاعات استفاده می‌شود. پنج عنصر مهم در گراف محاسباتی LSTM وجود دارد: ۱) دروازه ورودی، ۲) دروازه فراموشی، ۳) دروازه خروجی، ۴) سلول، ۵) خروجی حالت. «شکل۲» مدل محاسباتی LSTM را در لایه سلول نشان می‌دهد و این‌ها با سلول‌های دیگر ترکیب می‌شوند تا مدل RNN را تشکیل دهند. عملیات گیت مانند خواندن، نوشتن و پاک کردن در حالت حافظه سلول انجام می‌شود [4]. معادلات (۵ تا ۱۰) بازنمایی ریاضی مدل LSTM را نشان می‌دهد.



شکل۲: سلول LSTM و گراف معماری آن

$$x_i = \sigma\left(x_t W_{x_i n} + h_{(t-1)} W_{x_i m} + b_i\right) \quad (۵)$$

$$x_f = \sigma\left(x_t W_{x_f n} + h_{(t-1)} W_{x_f m} + b_f\right) \quad (۶)$$

$$x_o = \sigma\left(x_t W_{x_o n} + h_{(t-1)} W_{x_o m} + b_o\right) \quad (۷)$$

$$U = \tanh\left(x_t W_{Un} + h_{(t-1)} W_{Um} + b_U\right) \quad (۸)$$

$$C_t = x_f \times C_{t-1} + x_i \times U \quad (۹)$$

$$h_t = x_o \times \tanh(U) \quad (۱۰)$$

که x_i ورودی دروازه ورودی است، x_f ورودی دروازه فراموشی است، x_o ورودی دروازه خروجی است، U سیگنال به‌روزرسانی است، C_t مقدار حالت در زمان t و h_t خروجی سلول LSTM است. با تصمیم گیت ورودی با استفاده از تابع سیگموئید با حالت روشن / خاموش می‌توان حالت حافظه را اصلاح کرد. اگر مقدار گیت ورودی بسیار کم و نزدیک صفر باشد، هیچ تغییری در حافظه سلول حالت C_t ایجاد نمی‌شود. LSTM انباشته شده[۴] در مدل شبکه می‌تواند به‌صورت چندین لایه LSTM نمایش داده شود.

۴-۳- شبکه عصبی کانولوشنی[۵] (CNN)

---

۱ Recurrent Neural Network
۲ Backpropagation
۳ Long Short Term Memory
۴ Stacked LSTM
5 Convolutional Neural Network

CNN یک شبکه عصبی پیشخور است که از ساختار سلول‌های عصبی انسان تقلید می‌کند. این نوع از یادگیری عمیق به‌طور گسترده‌ای در پردازش‌های دیداری و شنیداری، تشخیص فیلم و پردازش زبان طبیعی کاربرد دارد. CNN معمولاً برای پردازش توپولوژی داده‌های شبکه استفاده می‌شود [1]. ساختار داده‌های سری زمانی، یک شبکه یک‌بعدی در یک‌فاصله زمانی است و ساختار داده‌های تصویر یک شبکه دوبعدی از پیکسل‌ها است [1]. عملکرد ریاضی کانولوشن حداقل در یکی از لایه‌های CNN بکار رفته است [1]. عملکرد کانولوشن در پردازش سیگنال به‌طورکلی در (۱۱) شرح داده شده است:

$$s(t) = (x * w)(t) = \int x(a)w(t-a)\,da \qquad (۱۱)$$

که x ورودی نامیده می‌شود، w فیلتر کرنل و s خروجی است که نگاشت ویژگی برای زمان مداوم t نامیده می‌شود. عملکرد کانولوشن زمان گسسته به شرح (۱۲) است:

$$s(t) = (x * w)(t) = \sum_{a=-\infty}^{\infty} x(a)w(t-a)\,da \qquad (۱۲)$$

برای تصویر دو بعدی I و یک فیلتر کرنل دوبعدی K ، کانولوشن، به‌صورت (۱۳) همبستگی متقابل نامیده می‌شود[1]:

$$s(i.j) = (I * K)(i.j) = \sum_{m}\sum_{n} I(i+m.j+n)K(m.n) \qquad (۱۳)$$

به‌طورمعمول، CNN از سه لایه اصلی تشکیل شده است که معماری شبکه را ایجاد می‌کنند. لایه اول دارای چندین لایه کانولوشنی موازی است، لایه دوم مرحله آشکارسازی است که دارای فعال‌ساز خطی یکسوشده است و مرحله سوم لایه تابع کاهش اندازه[۱] است [1].

۳-۵- ماشین بولتزمن محدود[۲] (RBM)

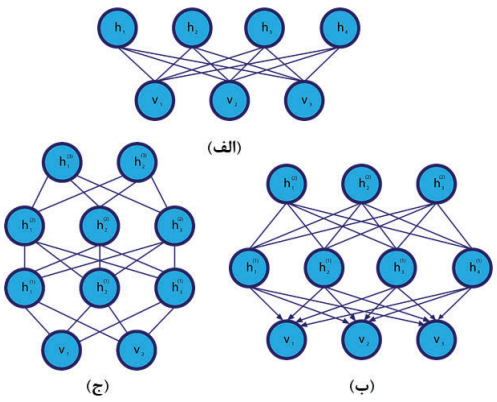
RBM یکی از مشهورترین مدل‌های احتمالاتی عمیق است که مدل‌های گرافیکی احتمالی بدون جهت هستند [1]. RBM دارای دو لایه اصلی است که قسمت اول ورودی‌های قابل مشاهده و لایه دوم حاوی متغیرهای پنهان است. معمولاً، RBM به‌منظور ایجاد لایه‌های عمیق‌تر با ساختن یکی از قسمت‌ها روی دیگر قسمت‌ها، انباشته می‌شود. «شکل۳» قسمت الف یک RBM ساده برای مدل گرافیکی احتمالی بدون جهت دو لایه را نشان می‌دهد.

۳-۶- شبکه باور عمیق[۳] (DBN)

معماری DBN دارای چندین لایه از واحدهای پنهان است که به‌عنوان RBM انباشته شده با چند لایه پنهان شناخته می‌شوند که با استفاده از الگوریتم پس انتشار[۴] آموزش داده می‌شوند [7]. اصولاً واحدهای اتصال در معماری DBN بین هر واحد در یک لایه با هر واحد در لایه بعدی قرار دارد، بااین‌حال هیچ اتصال داخلی برای هر واحد لایه وجود ندارد [1]. «شکل۳» قسمت ب، DBN را برای پیکربندی سه لایه، دو لایه پنهان و یک لایه قابل مشاهده نشان می‌دهد که در آن دو لایه بالایی بدون جهت هستند اما، اتصال بین همه لایه‌های دیگر باید به سمت لایه داده هدایت شود [1]. به‌طورکلی، یک DBN با RBM با لایه‌های پنهان‌تر است، بااین‌حال، RBM معمولاً فقط یک لایه پنهان دارد.

۳-۷- ماشین بولتزمن عمیق[۵](DBM)

شبکه عصبی DBM مانند معماری RBM است اما دارای متغیرهای پنهان و لایه‌های بیشتر از RBM است. همچنین، DBM برخلاف DBN است زیرا معماری DBM به‌طور کامل ارتباطات بدون جهت بین متغیر در تمام لایه‌ها دارد، مانند یک‌لایه قابل‌مشاهده و چند لایه پنهان دارد[1]. «شکل۳» قسمت ج معماری شبکه عصبی DBM را برای سه لایه پنهان و یک لایه قابل مشاهده نشان می‌دهد.



[۱] Pooling
[۲] Restricted Boltzmann Machine
[3] Deep Belief Network
[۴] Backpropagation
[۵] Deep Boltzmann Machine

شکل ۳: معماری‌های مختلف را نشان می‌دهد. الف) RBM با اتصالات بدون جهت بین ورودی‌های قابل مشاهده و متغیرهای پنهان. ب) DBN با اتصالات جهت‌دار به سمت ورودی‌های قابل مشاهده و سایر اتصالات بدون جهت برای لایه‌های مخفی. ج) DBM با اتصالات بدون جهت برای یک لایه ورودی قابل مشاهده و چند لایه مخفی.

۴- نتایج و بحث

در بیشتر مقالات، خطای جذر میانگین مربعات[۱] RMSE برای ارزیابی عملکرد روش پیشنهادی در مقایسه با سایر روش‌های موجود استفاده می‌شود. RMSE معمولاً برای تعیین خطای دقت پیش‌بینی استفاده می‌شود. معادله عملکرد روش‌های یادگیری عمیق استفاده شده به شرح (۱۴) است:

$$RMSE(y.x) = \sqrt{\frac{1}{N}\sum_{n=1}^{N}(y-x)^2} \qquad (۱۴)$$

که x سری زمانی ورودی اندازه‌گیری شده است، y سری زمانی خروجی پیش‌بینی شده و N تعداد نمونه‌های سری زمانی هستند. در «جدول۱»، بیشتر مقالات مورد بررسی از نظر مقایسه روش پیشنهادی در هر مقاله و روش معیار رایج، خلاصه شده است. همچنین «جدول۱» درصد کاهش RMSE را در مقایسه با روش‌های دیگر نشان می‌دهد. در «جدول۱»، کاهش RMSE در روش گروه DBN و رگرسیون بردار پشتیبان[۲] (SVR) در مقایسه با شبکه عصبی فازی[۳] (FNN) قابل توجه است. علاوه بر این، روش شبکه عصبی بازگشتی عمیق استخراج شده[۴] (PDRNN) در مقایسه با ARIMA کاهش بسیار خوبی را نشان می‌دهد. همچنین، CNN با دسته‌بندی k-means درصد بسیار زیادی از کاهش RMSE را نشان داده است.

جدول۱. درصد کاهش RMSE در مقایسه با روش پیشنهادی و روش معیار رایج

درصد کاهش RMSE	روش پیشنهادی	روش معیار رایج
۵/۵۱	Auto encoder & LSTM [8]	MLP
۱۹/۲	PDRNN [6]	ARIMA
۷/۷	CNN [1]	NN
۱۲/۳	CNN with k-means [9]	CNN
۲۱/۲	DBN & SVR [10]	FNN

۵- نتیجه‌گیری

تکنیک‌های هوش مصنوعی در دهه گذشته برای فرآیندهای اتوماسیون و تصمیمات هوشمند توسعه یافته‌اند. الگوریتم‌های یادگیری ماشینی نظارت شده و نظارت نشده، یادگیری بازنمایی و یادگیری عمیق برای بسیاری از برنامه‌ها در مسائل هوش مصنوعی در زمینه‌های مختلف از جمله دید رایانه‌ای، علوم اعصاب، مهندسی زیست پزشکی و سیستم‌های قدرت اعمال شده است. در این مقاله روش‌های معروف یادگیری عمیق که برای پیش‌بینی بار شبکه هوشمند مورد استفاده قرار گرفته است، بررسی شده است و در نهایت چندین روش از نظر درصد کاهش RMSE مقایسه شده‌اند. بسیاری از این الگوریتم‌های یادگیری با موفقیت به تجزیه‌وتحلیل پیش‌بینی و وضعیت بهتر مسائل پیش‌بینی یادگیری ماشین و شبکه‌های عصبی نزدیک شده‌اند.

مراجع

[1] I. Goodfellow, Y. Bengio, and A. Courville, Deep Learning. MIT Press, 2016, http://www.deeplearningbook.org.

[2] S. Khatoon, Ibraheem, A. Kr, and P. Singh, “Effects of various factors on electric load forecasting,” in *International Conference (PIICON), in 2014 6th IEEE Power India*, 2014.

[3] M. T. Haque and A. Kashtiban, “Application of neural networks in power systems; a review,” *Power*, vol. 2005, 2000.

[4] D. L. Marino, K. Amarasinghe, and M. Manic, “Building energy load forecasting using deep neural networks,” in *Industrial Electronics Society, IECON 2016-42nd Annual Conference of the IEEE*. IEEE, 2016, pp. 7046–7051.

[5] P.-F. Pai and W.-C. Hong, “Support vector machines with simulated annealing algorithms in electricity load forecasting,” *Energy Conversion and Management*, vol. 46, no. 17, pp. 2669–2688, 2005.

[6] H. Shi, M. Xu, and R. Li, “Deep learning for household load forecasting–a novel pooling deep rnn,” *IEEE Transactions on Smart Grid*, 2017.

[۱] Root Mean Square Error

[۲] Support Vector Regression

[۳] Fuzzy Neural Network

[۴] Pooling Deep Recurrent Neural Network

[7] S. Ryu, J. Noh, and H. Kim, "Deep neural network based demand side short term load forecasting," *Energies*, vol. 10, no. 1, p. 3, 2016.

[8] A. Gensler, J. Henze, B. Sick, and N. Raabe, "Deep learning for solar power forecasting? An approach using auto encoder and lstm neural networks," *in Systems, Man, and Cybernetics (SMC), 2016 IEEE International Conference* on. IEEE, 2016, pp. 002 858–002 865.

[9] X. Dong, L. Qian, and L. Huang, "Short-term load forecasting in smart grid: A combined cnn and k-means clustering approach," in *Big Data and Smart Computing (Big Comp), 2017 IEEE International Conference on*. IEEE, 2017, pp. 119–125.

[10] X. Qiu, L. Zhang, Y. Ren, P. N. Suganthan, and G. Amaratunga, "Ensemble deep learning for regression and time series forecasting," in *Computational Intelligence in Ensemble Learning (CIEL), 2014 IEEE Symposium on*. IEEE, 2014, pp. 1–6.