

بِسْمِ اللَّهِ الرَّحْمَنِ الرَّحِيمِ

عبدالله
١٤٣٥



دانشگاه بین المللی امام رضا علیه السلام

دانشکده فنی و مهندسی

(گروه مهندسی برق)

پایان نامه دوره کارشناسی ارشد مهندسی مکترونیک

پیش بینی بار الکتریکی با استفاده از شبکه عصبی المان

استاد راهنما:

دکتر مجتبی بهنام تقدسی

نگارنده:

زینه نزار عبدالرزاق نعیمی

تابستان ۱۴۰۱



شناسه: FR03-
PR03-PG-02

فرم صورت-جلسه دفاع از پایان نامه کارشناسی ارشد (فرم 5)

به حول و قوه الهی و در سایه عنایات و توجهات خاص علی بن موسی الرضا علیه السلام در دانشگاه منسوب به نام این حضرت خاتم زینه نزار عبدالرزاق نعیمی رشته مهندسی مکترونیک به شماره دانشجویی 99417612 در تاریخ 1401/04/04 ساعت 10:00 محل پردیس رضوان توانست در حضور هیات محترم داوران از پایان نامه خود با عنوان زیر دفاع نماید.

تغییر عنوان: بلی خیر

عنوان نهایی: پیش بینی بار الکتریکی با استفاده از شبکه عصبی المان

هیات داوران پس از پرسش های لازم در زمینه علمی و تحقیقاتی ایشان، نتیجه را به شرح زیر اعلام می دارد:

1- پایان نامه در وضع فعلی الف) قابل قبول است ب) با اصلاحات جزئی قابل قبول است

ج) نیاز به تصحیحاتی دارد که پس از تأیید هیات داوران قابل قبول است

دبیرخانه آموزش دانشگاه
شماره: ۷۲۱۳
تاریخ: ۱۴۰۱/۰۴/۰۴

نمره اولیه		سقف نمره
به عدد	به حروف	دانشجویان تمامی رشته ها
18	هجده	18

2- پایان نامه نیاز به تکمیل دارد که بعد از دفاع مجدد نمره آن اعلام خواهد شد. (صورت جلسه مجدد صادر می گردد).

• دانشجوی موظف است حداکثر ظرف مدت روز، اصلاحات مندرج در فرم (FR06-PR03-PG-00) را به تأیید برساند. (حداکثر مهلت مجاز 30 روز)

اعضای هیات داوران	نام و نام خانوادگی	مرتبیه	نام دانشگاه	امضاء
استاد راهنما	بهنام تقدسی مجتبی	استادیار	دانشگاه بین المللی امام رضا (علیه السلام)	
استاد داور خارجی	قرشی خلیل آباد سید حسن	---	---	
استاد داور داخلی	طالبیان سیدرضا	استادیار	دانشگاه بین المللی امام رضا (علیه السلام)	
نماینده تحصیلات تکمیلی	طالبیان سیدرضا	استادیار	دانشگاه بین المللی امام رضا (علیه السلام)	

مدیریت محترم تحصیلات تکمیلی

به استحضار می-رساند، نمره نهایی پایان-نامه نامبرده، پس از بررسی و تأیید موارد زیر مطابق جدول ذیل محاسبه گردید. تأیید انجام اصلاحات مطرح شده در جلسه دفاع توسط استاد(ان) راهنما و استادان داور.

(فرم تأیید اصلاحات پایان نامه و مطابقت با شیوه نامه تدوین پایان نامه (FR06-PR03-PG-00) به پیوست ارائه می گردد).

محاسبه نمره مقاله (مقالات) چاپ یا پذیرفته شده در مجلات و همایش های معتبر ضمن تأیید استاد راهنما.

(فرم مرتبط که به تأیید مدیر پژوهشی رسیده است، به پیوست ارائه می گردد)

بررسی رعایت نکات و موارد شیوه نامه تدوین پایان نامه کارشناسی ارشد.

نمره اولیه		نمره دریافتی از مقاله		نمره نهایی	
به عدد	به حروف	به عدد	به حروف	به عدد	به حروف
181-	چهاره	-	-	181-	چهاره

امضای مدیر گروه



رئیس محترم اداره آموزش

لطفا نسبت به ثبت نمره پایان-نامه دانشجو اقدام لازم صورت پذیرد.





اینجانب زیننه نزار عبدالرزاق نعیمی دانشجوی دوره کارشناسی ارشد رشته مهندسی برق گرایش مهندسی مکترونیک دانشگاه بین المللی امام رضا علیه السلام، نویسنده پایان نامه با عنوان پیش بینی بار الکتریکی با استفاده از شبکه عصبی المان به راهنمایی دکتر مجتبی بهنام تقدسی متعهد می شوم:

- نتایج ارائه شده در این پایان نامه حاصل مطالعات علمی و عملی این جانب است و مسئولیت صحت و اصالت مطالب مندرج را به طور کامل بر عهده می گیرم.
- در خصوص استفاده از نتایج پژوهش های محققان دیگر به مرجع مورد نظر استناد شده است.
- تا کنون مطالب مندرج در این پایان نامه به منظور اخذ هیچ نوع مدرک یا امتیازی توسط اینجانب یا فرد دیگری به هیچ مرجعی تسلیم نشده است.
- کلیه حقوق معنوی این اثر، متعلق به دانشگاه بین المللی امام رضا (ع) است و مقالات مستخرج از پایان نامه، با یکی از دو نام زیر به چاپ خواهند رسید.
 - دانشگاه بین المللی امام رضا (ع) (دانشگاه امام رضا (ع))
 - Imam Reza International University (Imam Reza University)
- حقوق معنوی تمامی افرادی که در به دست آمدن نتایج اصلی پایان نامه تاثیرگذار بوده اند در مقالات مستخرج از پایان نامه رعایت خواهد شد.
- در خصوص استفاده از موجودات زنده یا بافت های آن ها برای انجام پایان نامه، کلیه ضوابط و اصول اخلاقی مربوط رعایت شده است.
- در کلیه مراحل انجام این پایان نامه که به حوزه اطلاعات شخصی افراد دسترسی یافته یا از آن استفاده نموده ام، اصل رازداری، ضوابط و اصول اخلاقی انسانی رعایت شده است.

تاریخ و نام و نام خانوادگی دانشجو زیننه نزار عبدالرزاق نعیمی

امضاء دانشجو

مالکیت نتایج و حق نشر

- کلیه حقوق معنوی این اثر و محصولات آن (مقالات مستخرج، برنامه های رایانه ای، نرم افزارها و تجهیزات ساخته شده) به دانشگاه بین المللی امام رضا علیه السلام تعلق دارد و بدون اخذ اجازه کتبی از دانشگاه قابل واگذاری به شخص ثالث نیست.
- استفاده از اطلاعات و نتایج این پایان نامه بدون ذکر مرجع مجاز نیست.

تقدیر و قدردانی

اندیشیدن و تفکر یکی از ویژگی‌های ممتاز انسان است و دانش و اندیشه دو بال ضروری پرواز به سوی قله‌های رفیع سعادت و کمال است؛ اندیشه و شرف نگری در راه کشف

لایه‌های علوم و فنون به ابتکار، خلاقیت و تولید علم می‌انجامد.

باشکرت از استاد محبتی به‌نام تقدسی که در تدوین این پایان‌نامه مرایاری فرمودند.

چکیده

در دنیای امروز بدون مصرف برق تقریباً تمام کارها مختل خواهد شد. از کارخانجات و نیروگاه‌های بزرگ گرفته تا کوچکترین وسایل درون یک آشپزخانه وابسته به مصرف برق می‌باشد. لذا برای داشتن یک برنامه و چشم‌انداز دقیق از میزان مصرف برق در هر کشوری بسیار حیاتی است. میزان مصرف بار الکتریکی یک مجموعه از داده‌های سری زمانی می‌باشد که مربوط به بازه‌های مختلف استفاده از برق می‌باشد. این بازه‌ها از دوره‌های کوتاه مدت مانند دوره‌های ساعتی یا روزانه گرفته تا دوره‌های بلند مدت مانند سالیانه می‌باشد. برای برنامه‌ریزی دقیق در مورد مصرف بار الکتریکی باید بتوان در حد امکان میزان مصرف بار در آینده را با توجه به داده‌های گذشته پیش‌بینی کرد. در این پایان‌نامه، ما از روش هوش مصنوعی برای پیش‌بینی بار الکتریکی در فواصل کوتاه مدت هفتگی و ماهانه استفاده کرده‌ایم. نوآوری ما در این کار استفاده از شبکه عصبی المان (ELMAN Network) می‌باشد. شبکه عصبی المان (ENN) یکی از شبکه‌های عصبی بازگشتی (RNN) است که در مقایسه با شبکه‌های عصبی سنتی دارای یک لایه جدید به نام لایه زمینه می‌باشد و ورودی‌های آن نسبت به شبکه‌های عصبی معمولی بیشتر است. ENN، برای حل مسائل پیش‌بینی توالی زمانی گسسته بسیار مناسب است. پارامترهای شبکه پیشنهادی با توجه داده‌ها و دوره پیش‌بینی تنظیم شده‌اند. در نهایت خطای پیش‌بینی با استفاده از روش پیشنهادی نسبت به سایر روش‌های مقاله مرجع که بر اساس شبکه LSTM است، کمتر شده است، به گونه‌ای که مقدار RMSE برای روش مقاله مرجع و روش پیشنهادی ما به ترتیب ۳۱۱,۴۴ و ۲۳۹,۷۴ می‌باشد.

واژه‌های کلیدی: مصرف بار الکتریکی؛ پیش‌بینی؛ شبکه عصبی؛ شبکه المان.

فهرست مطالب

۱	فصل اول: مقدمه
۱-۱	۱- مقدمه
۲-۱	۲- بیان مساله
۳-۱	۳- اهمیت و ضرورت پژوهش
۴-۱	۴- سؤال‌ها و فرضیات پژوهش
۵-۱	۵- چرخه‌های متعدد پیش بینی بار
۱-۵-۱	۱- پیش بینی به صورت بلند مدت
۲-۵-۱	۲- پیش بینی به صورت میان مدت
۳-۵-۱	۳- پیش بینی به صورت کوتاه مدت
۶-۱	۶- ساختار پایان نامه
۸	فصل دوم: مفاهیم پایه و مرور کارهای گذشته
۱-۲	۱- بررسی روش‌های پیش بینی به صورت کوتاه مدت بار
۱-۱-۲	۱- روش‌های رگرسیون
۲-۱-۲	۲- روش سری زمانی
۳-۱-۲	۳- سیستم‌های فازی
۴-۱-۲	۴- سیستم‌های خبره
۵-۱-۲	۵- شبکه‌های عصبی
۶-۱-۲	۶- روش روزهای مشابه
۷-۱-۲	۷- تبدیل موجک
۲-۲	۲- موارد مورد نیاز برای پیش بینی به صورت کوتاه مدت بار
۱-۲-۲	۱- دقت
۲-۲-۲	۲- سرعت
۳-۲	۳- شناسایی خودکار اطلاعات نادرست
۱-۳-۲	۱- واسط
۲-۳-۲	۲- دسترسی اتوماتیک به داده‌ها
۴-۲	۴- مشکلات در حال حاضر در پیش بینی به صورت کوتاه مدت بار
۱-۴-۲	۱- تعمیم تجربه کارشناسان
۲-۴-۲	۲- پیش بینی ایام غیر طبیعی
۳-۴-۲	۳- عدم دقت و خطا در اطلاعات پیش بینی وضع آب وهوا
۴-۴-۲	۴- عدم تعمیم پذیری به دلیل بیش برآزش
۵-۲	۵- ساختار شبکه عصبی
۱-۵-۲	۱- نرون با فقط یک ورودی عددی

۲۰	۲-۵-۲- ورودی نرون با یک بردار
۲۱	۳-۵-۲- ساختار شبکه عصبی
۲۱	۱-۳-۵-۲- شبکه تک لایه
۲۲	۲-۳-۵-۲- شبکه‌های چند لایه
۲۴	۴-۵-۲- شبکه عصبی پویا و ایستا
۲۴	۵-۵-۲- انواع مختلف شبکه عصبی از جهت برگشت پذیری
۲۵	۶-۵-۲- شبکه عصبی المان (ELMAN)
۲۷	۶-۲- مرور کارهای گذشته
۳۰	۷-۲- مقاله مرجع
۳۱	فصل سوم: روش پیشنهادی
۳۲	۱-۳- مقدمه
۳۳	۲-۳- مدلسازی شبکه عصبی برای پیش بینی بار الکتریکی
۳۳	۳-۳- روش پیشنهادی: پیش‌بینی بار در کوتاه مدت با استفاده از شبکه المان (ENN)
۳۵	۱-۳-۳- انتخاب تعداد لایه‌های مخفی
۳۵	۲-۳-۳- انتخاب تعداد نرون‌ها در هر لایه
۳۶	۳-۳-۳- تعیین تابع عملکرد نرون‌ها
۳۷	۴-۳- تعیین روش پیش‌بینی بار
۳۸	فصل چهارم: ارزیابی نتایج شبیه سازی
۳۹	۱-۴- مقدمه
۴۰	۲-۴- پایگاه داده
۴۰	۳-۴- نرمال سازی داده‌ها
۴۰	۴-۴- آموزش شبکه عصبی و نحوه ارائه اطلاعات به شبکه عصبی
۴۰	۵-۴- معیارهای ارزیابی
۴۱	۶-۴- نتایج شبیه سازی
۴۶	فصل پنجم: نتیجه‌گیری و پیشنهادات
۴۷	۱-۵- نتیجه‌گیری
۴۸	۲-۵- پیشنهادات
۴۹	منابع

فهرست جدول‌ها

جدول ۴-۱: مقایسه روش پیشنهادی با سایر روش‌ها با استفاده از معیار RMSE ۴۵

فهرست شکل‌ها

- شکل ۱-۱: تغییرات پیک بار بلندمدت سالانه شبکه سراسری، بین سال‌های ۱۳۷۰ تا ۱۳۸۴ و همچنین پیش بینی سال ۱۳۹۰ را نشان می‌دهد. ۵
- شکل ۱-۲: روند تغییرات پیک بار، میان مدت هفتگی از سال ۸۴ تا ۷۹ و همچنین پیش بینی هفتگی بار ۸۵ نمایش داده شده است. ۶
- شکل ۱-۳: نشان دهنده بار هفتگی ۷۹ تا ۸۴ و پیش بینی هفتگی بار ۸۵ نمایان است. ۶
- شکل ۱-۲: نشان دهنده ساختار شبکه عصبی است. ۱۸
- شکل ۲-۲: نرون با یک ورودی عددی [۲۷] ۱۸
- شکل ۳-۲: تابع انتقال هاردلیمیت [۲۷] ۱۹
- شکل ۴-۲: تابع انتقال خطی [۲۷] ۲۰
- شکل ۵-۲: شکل تابع لگاریتمی [۲۷] ۲۰
- شکل ۶-۲: مدل تورون با یک بردار به عنوان ورودی [۲۷] ۲۰
- شکل ۷-۲: نمایش یک لایه از نرون [۲۷] ۲۱
- شکل ۸-۲: شبکه ی تک لایه [۲۷] ۲۲
- شکل ۹-۲: نمایش ویژگی متمایز هر لایه از شبکه [۲۷] ۲۲
- شکل ۱۰-۲: شبکه ی چند لایه [۲۷] ۲۳
- شکل ۱۱-۲: یک نمونه از شبکه پیشخور ۲۴
- شکل ۱۲-۲: نمونه شبکه پسخور ۲۵
- شکل ۱۳-۲: دیاگرام کلی شبکه عصبی المان ۲۶
- شکل ۱-۳: دیاگرام شبکه المان پیشنهادی ۳۴
- شکل ۱-۴: بلوک دیاگرام روش پیشنهادی ۳۹
- شکل ۲-۴: مشخصات کلی شبکه عصبی المان پیشنهادی ۴۱
- شکل ۳-۴: نتایج پیش‌بینی بار مصرفی برای یک ماه ۴۲
- شکل ۴-۴: نتایج پیش‌بینی بار مصرفی برای یک هفته ۴۲
- شکل ۵-۴: نمودار رگرسیون برای پیش‌بینی ماهیانه ۴۳
- شکل ۶-۴: نمودار رگرسیون برای پیش‌بینی هفتگی ۴۳
- شکل ۷-۴: نمودار هیستوگرام خطا ۴۴
- شکل ۸-۴: نمودار همگرایی شبکه عصبی پیشنهادی ۴۴

فصل اول:

مقدمه

پیش‌بینی دقیق بار در برنامه‌ریزی و مدیریت نیروگاه‌ها، تأسیسات تولید و بهره‌برداری مقرون به صرفه شبکه‌های برق از اهمیت حیاتی برخوردار است. مصرف بار الکتریکی یک داده سری زمانی است که شامل دنباله‌ای از مشاهدات در فواصل زمانی منظم است که اجزای خطی و غیرخطی را در بر می‌گیرد. مؤلفه‌های اساسی که یک سری زمانی را توصیف می‌کنند عبارتند از: (۱) روند، که صعودی، نزولی یا وجود ندارد، (۲) فصلی بودن، که نوسانات دوره‌ای در سری‌های زمانی در یک دوره معین است، (۳) چرخه‌ها، که در آن بالا و پایین می‌رود. دوره ثابتی ندارند و در نهایت (۴) حرکت نامنظم که پس از توضیح روند، حرکات فصلی و چرخه‌ای باقی می‌ماند [۱]. مصرف برق معمولاً به دلیل عملکرد چندین وسیله الکتریکی و رفتار مصرف‌کننده بسیار تصادفی است که شناسایی این الگوهای مصرف سری‌های زمانی را دشوارتر می‌کند [۲].

مدل‌های آماری خطی سنتی مانند اتورگرسیو (AR)، میانگین متحرک (MA) و میانگین متحرک یکپارچه اتورگرسیو (ARIMA) با استفاده گسترده در چندین کاربرد صنعتی، خط پایه برای پیش‌بینی‌های سری زمانی باقی مانده‌اند [۳،۴]. مفروضات اساسی برای اجرای این مدل‌ها بر این واقعیت استوار است که سری‌های زمانی، ثابت و خطی در نظر گرفته می‌شوند و از توزیع آماری شناخته شده خاصی پیروی می‌کنند. به طور مشابه، چندین مدل یادگیری ماشین برای پیش‌بینی سری‌های زمانی به عنوان جایگزینی برای مدل‌های آماری پیشنهاد شده‌اند که می‌توانند غیرخطی بودن داده‌های سری زمانی را برطرف کنند. متداول‌ترین مدل‌های مورد استفاده رگرسیون بردار پشتیبان (SVR) و شبکه‌های عصبی مصنوعی (ANN) هستند که می‌توانند روابط پیچیده و عمدتاً غیرخطی بین بار الکتریکی و عوامل مرتبط را برای دستیابی به دقت بالاتر در مصرف انرژی مدل‌سازی کنند [۵،۶].

اگرچه معماری شبکه‌های عصبی در مقایسه با مدل‌های ARIMA در پرداختن به داده‌های توزیع شده غیرخطی و غیرعادی، که بیشتر در مسائل دنیای واقعی با آن مواجه می‌شوند، مزایای متعددی را ارائه می‌دهند، اما این اشکال را دارند که فرض می‌کنند همه ورودی‌ها و خروجی‌ها مستقل از یکدیگر هستند. حتی زمانی که با

داده‌های متوالی سروکار داریم. این فرض پتانسیل پیش‌بینی که در رابطه وابستگی بین داده‌های متوالی مصرف انرژی وجود دارد را حذف می‌کند. از این رو، بررسی وابستگی بین مصرف متوالی انرژی الکتریکی ضروری است.

۱-۲- بیان مساله

ساخت یک مدل دقیق پیش‌بینی بار الکتریکی نیاز به جستجوی یک پیکربندی بهینه دارد که شامل انتخاب تاخیر و تنظیم فرآیند یادگیری عمیق است. متأسفانه، این کار غیر پیش پا افتاده است که می‌تواند با استفاده از یک جستجوی جامع و روش‌های قطعی حل شود، به خصوص در زمینه داده‌های بزرگ. این مسئله نسبتاً سختی است که راه حل بهینه برای آن در زمان چند جمله ای یافت نمی‌شود. این سختی با پیچیدگی الگوهای داده مصرف برق بیشتر می‌شود. یکی از راه‌حل‌های جایگزین برای پیکربندی بهینه مدل‌های پیش‌بینی انرژی، استفاده از رویکردهای یادگیری ماشین بخصوص شبکه‌های عصبی بازگشتی و با مناسب برای سری‌های زمانی می‌باشد.

۱-۳- اهمیت و ضرورت پژوهش

پیش‌بینی کوتاه‌مدت بار الکتریکی نقش مهمی برای شرکت‌های خدمات شهری ایفا می‌کند، زیرا امکان عملکرد و مدیریت کارآمد شبکه‌های برق، تعادل بهینه بین تولید و تقاضا و همچنین کاهش هزینه‌های تولید را فراهم می‌کند. از آنجایی که حجم و تنوع داده‌های انرژی ارائه شده توسط سیستم‌های اتوماسیون ساختمان، کنتورهای هوشمند و سایر منابع به طور مداوم در حال افزایش است، مدل‌های یادگیری عمیق به یک رویکرد جذاب برای پیش‌بینی بار انرژی تبدیل شده اند.

۱-۴- سؤال‌ها و فرضیات پژوهش

آیا می‌توان با در نظر گرفتن مقدار مصرف بار الکتریکی در گذشته با دقت مناسبی بار مصرفی در آینده را پیش‌بینی کرد؟

آیا شبکه‌های عمیق قادر به پیش‌بینی بار الکتریکی با دقت مناسب هستند؟

در این کار برای پیش‌بینی مقدار مصرفی بار الکتریکی، بازه‌های زمانی، کوتاه مدت فرض می‌شوند.

۱-۵- چرخه‌های متعدد پیش بینی بار

از نظر مدت زمانی در سیستم‌های قدرت، پیش بینی بار به چند دوره تقسیم می‌شود:

بلندمدت بار، میان مدت بار و کوتاه مدت بار

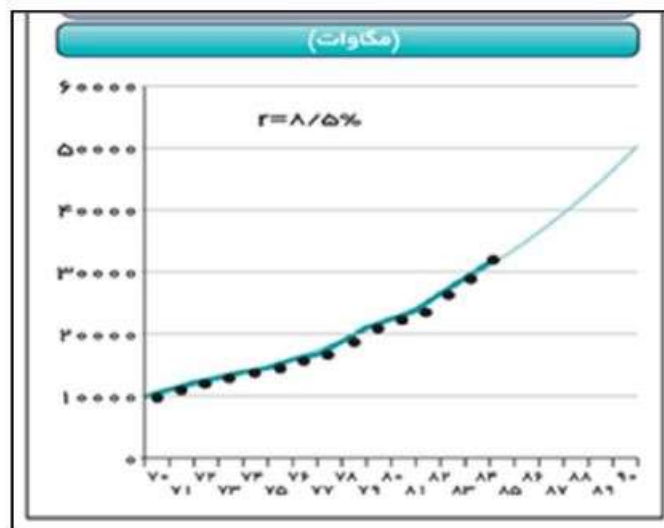
۱-۵-۱- پیش بینی به صورت بلند مدت

طول زمان این پیش بینی بین یک سال و گاهی چند دهه به طول می‌انجامد. و به منظور برنامه ریزی در دراز مدت صورت می‌گیرد. در این نوع پیش بینی، برنامه ریزی برای تبادل انرژی‌های الکتریکی با سازمان‌ها در سیستم متصل، در خصوص اندازه و نوع و مکان احداث نیروگاه، بستن یا ویرایش قراردادهای، نحوه گسترش شبکه، با توجه به توان و طول عمر نیروگاه‌های از پیش موجود و ترکیب توانایی‌های شبکه‌های توزیع و انتقال، قراردادهای بلند مدت تنظیم می‌شود.

با توجه به تغییرات اقتصادی در چند دهه، و تحولات بزرگی که رخ می‌دهد، نتایج پیش بینی قابل استناد نیست. در طول سال‌ها، هفته و روزها، در یک جامعه، عواملی چون رشد جمعیت، شرایط اقتصادی و اجتماعی بر مصرف بار، در بلند مدت تاثیر می‌گذارد. و آنچه ثابت باقی می‌ماند روند تغییرات بار است. توسعه شبکه از اهمیت بالایی در برآورد بار در این نوع پیش بینی برخوردار است. برای اینکه نوع بار پاسخگوی نیاز جامعه باشد باید ده سال زودتر برای افزایش خطوط توزیع و انتقال در شبکه موجود، همچنین افزایش تعداد نیروگاه‌ها، برنامه ریزی شود.

برای شناسایی عوامل تاثیرگذار بار مصرفی، مطالعات گسترده‌ای در زمینه روند تغییرات سالانه شبکه سراسری پیک بار در صنعت برق، باید صورت بگیرد.

در شکل (۱-۱) روند تغییرات سالانه شبکه سراسری پیک بار، در دراز مدت، از سال ۱۳۷۰ تا ۱۳۸۴ را توسط شرکت توانیر نشان می‌دهد [۷]. همچنین در این شکل بار مصرفی تا سال ۹۰ را، با توجه به توسعه کشور، و با مدل سازی روش ساده برازش نمایی، در سال با ضریب رشد بار ۸/۵ درصد، می‌توان پیش بینی کرد.



شکل ۱-۱: تغییرات پیک بار بلندمدت سالانه شبکه سراسری، بین سال‌های ۱۳۷۰ تا ۱۳۸۴ و همچنین پیش بینی سال ۱۳۹۰ را نشان می‌دهد.

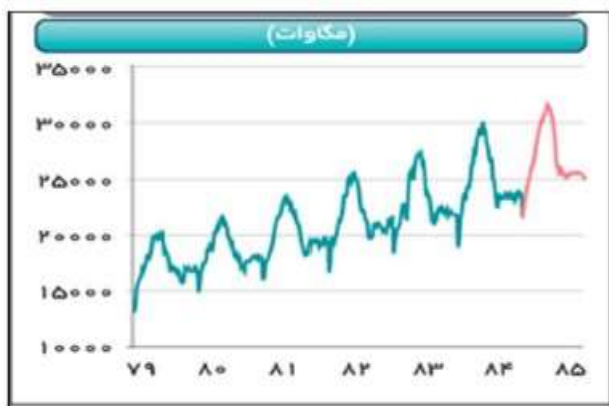
برخی پارامترها به افزایش دقت این مدل کمک می‌کند مثل: سرانه مصرف برق و جمعیت، رشد ناخالص ملی و تأثیر آن روی مصرفی و همچنین سیاست‌هایی مثل حمل و نقل برقی، چاه‌های کشاورزی برقی، گرایش و توسعه به سمت اتوماسیون.

۱-۵-۲- پیش بینی به صورت میان مدت

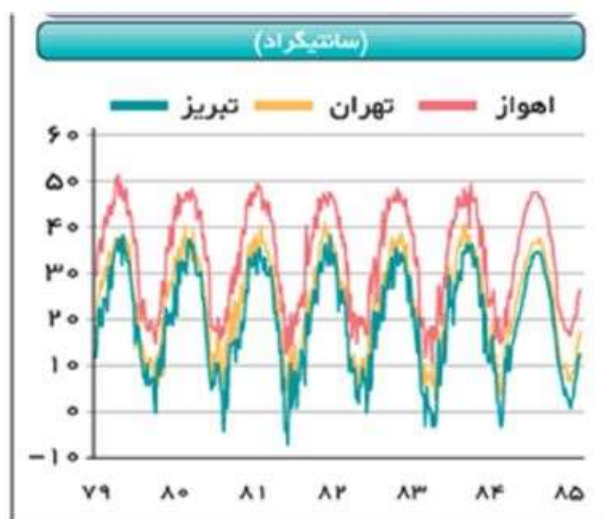
طول مدت زمان این دوره بین یک هفته تا یکسال و برنامه ریزی‌ها برای میان مدت شبکه است. و تصمیم گیری با مدنظرگرفتن عواملی چون: میزان آب ذخیره شده در مخزن‌ها، ترکیب و توان نیروگاه‌های موجود، میزان سوخت ذخیره شده، قرارداد سازمان‌ها در خصوص زمان و نحوه کارکرد نیروگاه‌های آبی و حرارتی، زمان بندی دقیق و بهینه برای تعمیرات و بازرسی شبکه و نیروگاه‌ها، تهیه ی سوخت، و مقدار انرژی الکتریکی قابل تبادل با سازمان‌ها، می‌شود. شکل بار و بار پایه ، دو مولفه ایست که برای تقسیم بندی بار در این مدل پیش بینی استفاده می‌شود. شکل بار به موجب تغییرات فصلی بار و رشد بار سالانه تأثیر بر روی بار پایه می‌گذارد.

شکل (۱-۲) روند تغییرات پیک بار به صورت میان مدت هفتگی از سال ۱۳۷۹ تا ۱۳۸۴، جمع آوری شده توسط شرکت توانیر، نشان می‌دهد [۷]. در این مدل، پیش بینی روی پیک بار چند شهر به عنوان درجه حرارت‌های متفاوت کشور (اهواز، تبریز و تهران) و برای ۵۲ هفته ۱۳۸۵، روی شبکه سراسری، شده است.

در این مدل پیش بینی، به عنوان پارامتر دما در چند سال گذشته، متوسط دمای سه شهر تهران، اهواز و تبریز، مورد نظراسست، شکل (۳-۱).



شکل ۱-۲: روند تغییرات پیک بار، میان مدت هفتگی از سال ۷۹ تا ۸۴ و همچنین پیش بینی هفتگی بار ۸۵ نمایش داده شده است.



شکل ۱-۳: نشان دهنده بار هفتگی ۷۹ تا ۸۴ و پیش بینی هفتگی بار ۸۵ نمایان است.

۱-۵-۳- پیش بینی به صورت کوتاه مدت

این مدل پیش بینی، بارساعتی برای زمان کم به صورت هفتگی، روزانه، چند ساعتی و ساعتی، و برای بهره بردن از سیستم قدرت استفاده می شود. مزایای این طرح شامل:

- ✓ برنامه ریزی خروج و ورود واحدها با در نظر گرفتن محدودیت های شبکه و تولید واحدها
- ✓ پخش بار به صورت بهینه

- ✓ ذخیره ایمن و مطمئن بر شبکه / آغاز به کار واحدهای مرتبط به پیک
- ✓ عدم اتصال برخی اتصالات داخلی همچنین کار به شکل جزیره ای
- ✓ هر لحظه سنجش سیستم
- ✓ تحلیل و تجزیه به وقوع پیوستن حوادث احتمالی
- ✓ فرستادن اختار قبلی برای کاهش بار به مصرف کنندگان به وسیله ی ارتباط جمعی و مشخص کردن

زمان حداکثر بار

- ✓ اعمال افزایش نرخ در زمان پیک بار برای مصرف کنندگان
- ✓ مطالعات پایداری شبکه و کوتاه
- ✓ فراهم آوردن داده ی لازم به منظور پخش بار اقتصادی
- ✓ منتخب ژنراتورها برای فعالیت
- ✓ مینیمم کردن هزینه ها با روشن یا خاموش کردن ژنراتورها
- ✓ جهت بهینه کردن میزان خروج آب از منبع ها، جدول زمان بندی آبی را تنظیم کردن
- ✓ بارگذاری خط های انتقال
- ✓ وجود هماهنگی بین خرید انرژی و زمان بندی

۱-۶- ساختار پایان نامه

در ادامه در فصل دوم با مفاهیم اساسی در مورد روش های پیش بینی کوتاه مدت بار الکتریکی و همچنین مرور کارهای گذشته بحث شده است. در فصل سوم روش پیشنهادی در این کار شرح داده شده است و در فصل چهارم نتایج شبیه سازی و مقایسه نتایج آورده شده است. در نهایت در فصل پنجم نتیجه گیری و پیشنهادات آورده شده است.

فصل دوم:

مفاهیم پایه و مرور کارهای گذشته

۲-۱- بررسی روش‌های پیش بینی به صورت کوتاه مدت بار

مدل بار عبارتی است که قانون رابطه ی بین دو روند را مشخص می کند. برای آینده روند بار بر مبنای ویژگی های متاثر در گذشته، روش های مختلفی جهت پیش بینی بار در شبکه، وجود دارد که همگی در اصل عملکرد یکسان و پیروی یک قانون می باشند.

تقسیم بندی برای پیش بینی بار به صورت کوتاه مدت، به دو روش است: ۱- روش هوش مصنوعی که در روش آماری مشخص کننده ی معادلات رابطه ی متغیر و بار است. ۲- روش آماری. در روش هوش مصنوعی، تلاش برای پیش بینی بار در آینده و به کار گیری از شیوه ی تفکر و یادگیری انسان از تجربه های گذشته است. برای سری های زمانی و رگرسیون خطی از روش آماری استفاده می شود. به دلیل عدم انعطاف پذیری ساختار روش آماری، امکان رسیدگی و ویژگی های بار، درایام غیر عادی و تعطیل وجود ندارد. از سری روش ها در هوش مصنوعی عبارتند از:

- فازی: با ایجاد یک سیستم فازی جهت حداقل کردن اشتباهات و ایجاد توابع عضویت، سعی در به وجود آوردن حالات غیرخطی بار، دارد. همچنین نیاز به کارشناس انسانی برای دریافت قوانین فازی دارد.
- شبکه عصبی مصنوعی: بدون نیاز به تعریف تجربیات انسانی، توانایی ایجاد شبکه بین مجموعه خروجی ها و ورودی ها را دارد، و مفید برای ارتباط غیرخطی میان عوامل موثر و بار می باشد، نقطه ضعف این روش پیش برآزش و زمان زیاد آموزش است. پیش برآزش زمانی رخ می دهد که در داده های آموزش، خطای آموزش کم ولی میزان خطای داده های تست زیاد باشد.
- سیستم خبره: از تجربیات اپراتورها، به صورت، اگر-آنگاه استفاده می کند. ولیکن گاهی تجربیات بصری و حسی است که قابل درک، به صورت قانون نیست.

چند نمونه از روش های مهم پیش بینی به صورت کوتاه مدت در زیر شرح داده می شود [۸].

۲-۱-۱- روش‌های رگرسیون^۱

این روش مهم ترین و اصلی ترین، در روش‌های آماری می‌باشد، و رابطه‌ی میان بار مصرفی و عواملی چون: نوع روز، آب و هوا، کلاس مصرف کننده، را روی مدل اعمال می‌کند.

به فرآیند بررسی رفتار گذشته یا یک سری زمانی و بررسی مدل سازی ریاضی، جهت پیش بینی رفتار آینده، رگرسیون می‌گویند. دو روشی که در این روش استفاده می‌شود عبارتند از:

الف) تطابق دادن توابع پیوسته ریاضی جهت حداقل کردن خطای کلی (آنالیز رگرسیون) از طریق داده‌ها واقعی.
ب) تطابق دادن اطلاعات با یک منحنی‌های گسسته یا دنبال برخطوط.

در پیش بینی به صورت کوتاه مدت، معمولاً از روش (ب) استفاده می‌شود. بار سیستم قدرت یک عملیات متغیر با زمان، به چهار بخش تقسیم می‌شود که عبارتند از:

- تغییرات فصلی که گرایش اصلی است: تغییرات سالانه یا ماهانه.
 - تغییرات دوره‌ای: طول مدت زمان، طولانی بوده و باعث تکرارالگوی بار در مدت ۲ یا ۳ سال یا بیشتر انجام می‌شود.
 - نوسانات تصادفی: دلیل اتفاق افتادن این نوسانات تغییرات ایام مختلف است، و بستگی به مدت زمان‌های متفاوت در هفته، برای سیستم قدرت را دارد. مثلاً روز اول هفته مشخصات آب هوایی و...متفاوتی دارد.
 - توابع رگرسیون: توانایی تطبیق دادن تابع $y=f(x)$ رابه نقاط (x_1, y_1) و (x_2, y_2) ، با حداقل مربع خطاها در نقاط را دارد.
- کار حداقل کردن خطا به علت، علامت کردن نشانگر برای تطبیق با کار انجام می‌شود. در مقاله‌های [۹-۱۲] در این باره بیشتر توضیح آمده است.

^۱ Regression method

۲-۱-۲- روش سری زمانی^۱

سری زمانی، دنباله ای از الگوها و مشاهدات روی متغیر است یعنی این روش طبق مدل خاص، پیش بینی بر رشد یک مجموعه متغیرها براساس زمان، بنا شده است. که رشد بار هر کشور یا منطقه می تواند دارای این ویژگی باشد. متغیرها در نقطه های مختلفی از زمان که اکثرا با فواصل مساوی هستند، وجود دارند و سری زمانی توصیف کننده فرآیند تولید دنباله است.

زمانی که، رفتار مراحل را با یک مدل خاص از ریاضی که توانایی توسعه برای آینده باشد، قابل توصیف باشد، می توانیم از پیش بینی سری زمانی استفاده کنیم. بنابراین مدل باید دربرگیرنده مشاهدات دور خوب و دقیق و همچنین متاثر از مشاهدات جدید و عدم تاثیر از تجربیات گذشته، در هر قسمت بازه ی زمانی باشد. از توابع غیر خطی یا خطی از زمان یا ترکیب مولفه های غیرخطی و یا خطی، برای پیش بینی سری زمانی بار در یک شهر یا منطقه، استفاده می شود.

در این روش، جهت پردازش مدل و خارج کردن داده های غلط از لیست که دچار خطاهای انتقال و ثبت شده اند، به جمع آوری عوامل متاثر در مصرف انرژی الکتریکی و همچنین اطلاعات آماری رشد بار، پرداخته می شود. روش حداقل مربعات خطا که از تخمین ضریب های a_0 و a_1 و ... و a_n برای مینیمال کردن سری مربعات خطا استفاده می شود، و بهترین روش پردازش مدل بر روی داده های زمان است. کاربردهای ای این روش در مراجع [۱۳-۱۵] آمده است.

۲-۱-۳- سیستم های فازی^۲

پژوهشی در سال ۱۹۶۵ در زمینه وصف قطعی نبودن غیراحتمالی توسط لطفی زاده منتشر و مجموعه فازی نام گذاری شد و شامل مجموع سیستم استنتاج فازی، محاسبات قانون اگر-آنگاه، مدل سازی فازی است. انسان در دنیای واقعی، قابلیت درک مفاهیم فازی (ناواضح، مبهم و دقیق)، مثل سرد، گرم، کوتاه، پیر و.. که به عدد خاصی اشاره ندارد، است و انسان در نتیجه گیری و تصمیمات خود مورد استفاده قرار می دهد. درحالی که سیستم اهل دقت و فقط قابل به درک اعداد است. به عنوان مثال عددی، قد افراد به دو دسته قد بلند (افراد

¹ Time series method

² Fuzzy systems

بالا ۱۸۰ سانتی متر) و قد کوتاه (افراد زیر ۱۸۰ سانتی متر)، تقسیم کنیم، فردی ۱۷۹ بود قد کوتاه تلقی می‌شد. با استفاده از تابع عضویت برای هر یک از صفات در مجموعه فازی، ارزش گذاری بین صفر و یک است. ذهن انسان بامنطق دیگری تصمیم گیری و کارهایش را انجام می‌دهد، پس جهت شروع، ابداع و ایجاد منطق‌های جدید و چند ارزشی نیازمند منطق فازی است.

سیستم فازی برمبنای قواعد و دانش است و قلب این سیستم بانک دانش متشکل از قواعد اگر-آنگاه است. پس برای شروع و ایجاد یک سیستم فازی، نیازمند اگر-آنگاه فازی، در خصوص اطلاعات حوزه مورد نظر و استفاده از دانش و تجربیات افراد خبره است. سپس بر اساس اصول و قواعد، قواعد را در یک سیستم واحد ترکیب می‌کنند [۱۶]. مزیت‌های منطق فازی به شرح زیر است:

- نیاز نداشتن یک مدل ریاضی جهت نگاشتن خروجی و ورودی‌ها
- نیاز نداشتن به ورودی‌های دقیق

با رعایت اصول و قواعد، سیستمی قوی جهت پیش بینی طراحی می‌شود که اکثرا نیازمند خروجی دقیق است. در مورد کاربرد این روش در مراجع [۱۷، ۱۸، ۱۹] آمده است.

۲-۱-۴- سیستم‌های خبره^۱

سیستم خبره به برنامه‌هایی گفته می‌شود که رفتار انسان را در یک زمینه ی خاص تقلید کند. با استفاده از اطلاعات ذخیره شده در این برنامه‌ها توسط استفاده کننده، اظهارنظر در خصوص یک موضوع خاص را بیان می‌کند. بنابراین این سیستم‌ها تا زمانی که مطابقت بین موضوع و پاسخ شما دریافت کنند از شما سوال می‌کنند. به طور کلی سیستم خبره، شامل برنامه‌های کامپیوتری می‌باشند که به حل مسائل در حوزه ی خاص و با استفاده از قواعد متخصصین، می‌پردازد. این سیستم از استنتاج و استدلال بر پایه استنباط ، نسبت با سایر برنامه استفاده می‌کند، در این روش‌ها ، با کمک آزمون و خطا می‌توان مسائل سخت تر و جواب رضایت مندتری رسید در حالی که برنامه‌های معمولی کاربردی دارای روش ثابت حل مسئله و الگوریتم می‌باشد.

^۱ Expert system

سیستم خبره بر این اساس است که تجربه و دانش افراد متخصص در حافظه ذخیره و در اختیار کاربرانی قرار دهد که نیاز دارند. سیستم پشتیبانی تصمیم متشکل شده از برنامه‌هایی است که چگونگی اعتقاد مدیر در انجام حل مسئله را منعکس کند. سیستم‌های خبره قابلیت فرصت تصمیم‌گیری دارد که از توانایی‌های مدیر بیشتر و همچنین قابلیت بیان دلیل جهت استفاده از یک راه حل است. اکثر اوقات ارزشمندتر از راه حل، بیان نحوه دست‌یابی به آن راه حل است. اطلاعاتی که به واسطه سیستم خبره استفاده می‌شود متنی و تشریحی بوده و برنامه‌های منطقی را استفاده می‌کند، ولی اطلاعاتی که به واسطه سیستم پشتیبانی تصمیم استفاده می‌شود عددی و برنامه‌ها به روش ریاضی، انجام می‌شوند. در کاربرد این روش برای پیش‌بینی بار در مراجع [۱۹] و [۲۰] توضیح داده شده است.

۲-۱-۵- شبکه‌های عصبی^۱

شبکه‌های عصبی برای استفاده از هوش انسانی، ده‌ها سال است که مورد حمایت قرار گرفته است. نخستین نرون مصنوعی توسط منطق دان والترپیتز و وارن مک کالوک (نروفیزبولوژیست) در سال ۱۹۴۳ ساخته شد. در دهه ۶۰ مردم مشتاق شبکه‌های عصبی شدند ولی در دهه ۸۰ توانایی‌های این شبکه‌ها، مورد توجه دانشمندان قرار گرفت.

با توجه به قابلیت استنتاج نتایج شبکه‌های عصبی از اطلاعات پیچیده، توانایی شناسایی گرایش و استخراج الگوهایی که برای کامپیوتر و انسان سخت است، را دارد.

از جمله توانایی‌های شبکه عصبی می‌توان، پاسخ به ورودی‌های غیرقابل پیش‌بینی به صورت عمومی، به دلیل شناسایی گسترده‌ی شناسایی الگو، نام برد. در هنگام ساخت، نرون‌ها توانایی آموزش شناسایی الگوهای ویژه‌ی مختلف را دارند و چنانچه در هنگام اجرا، ورودی با خروجی متفاوت باشد از سوابق الگوهای آموخته شده استفاده کرده و الگویی که دارای حداقل تفاوت با ورودی است را برمی‌گزینند. به دلیل پیچیدگی بسیار زیاد داخل نرون، ارائه مدل مصنوعی که دارای ویژگی‌های نرون طبیعی باشد بسیار مشکل است.

^۱ Neural network

در مرجع [۲۱] درباره ی کاربرد این روش به منظور پیش بینی بار اشاره شده است. در مقاله [۲۲] ترکیب شبکه عصبی مصنوعی با سری زمانی، و در [۲۳] ترکیب شبکه عصبی مصنوعی با منطق فازی آمده است.

۲-۱-۶- روش روزهای مشابه^۱

نقاط تشابه روزی که قرار است پیش بینی شود، با کاوش اطلاعات تاریخی در یک تا سه سال برای آن روز، در مقاله [۲۴] انجام می شود. خصوصیات مشترک مثل روز هفته، آب و هوا و تاریخ است. به منظور پیش بینی، بار روز مشابه در نظر گرفته می شود، همچنین می توان از رگرسیون که دربرگیرنده ایام مشابه می باشد، و ترکیب خطی، به جای به کارگیری داده های بار، برای پیش بینی مورد استفاده قرار داد.

۲-۱-۷- تبدیل موجک^۲

تجزیه ی سیگنال پیوسته به داده های فرکانسی آن که رزولوشن هریک با مقیاس آن برابر است، توسط مجموعه ای توابع ریاضی انجام می شود که به آن ویولت یا موجک می گویند. یک تابع برای تجزیه موجک، از توابع موجک پیروی می کند. موجک مادر از نمونه های مقیاس شده و انتقال یافته یک تابع با نوسانات شدید می را و طول متناهی هستند [۲۵].

در مقاله [۲۶] جهت بهبود کارکرد شبکه عصبی سنتی و مدل پیش بینی به صورت کوتاه مدت، برمبنای شبکه های موجک به منظور مدل سازی رفتار داینامیکی و غیر خطی سیستم بار، و ساخته شده با کمک از الگوریتم های محاسباتی تکمیلی شبکه سه لایه ای موجک، پیشنهاد شده است. همچنین این پیش بینی در مقایسه با شبکه های عصبی، بسیار سریع تر و دقیق تر هستند.

۲-۲- موارد مورد نیاز برای پیش بینی به صورت کوتاه مدت بار

واحد پیش بینی به صورت کوتاه مدت بار، معمولاً در سیستم های کنترل و مدیریت انرژی وجود دارد و باید مواردی چون سرعت، دسترسی اتوماتیک به اطلاعات، دقت، رابط کاربرپسند، نتیجه ی پیش بینی را به صورت اتوماتیک تولید و شناسایی خودبه خود داده بد، رادارا باشد [۸].

¹ Similary day method

² Wavelet

۲-۲-۱- دقت

دقت مهم ترین شرط در پیش بینی به صورت کوتاه مدت و اساس اطمینان در بازار برق و صنعت اقتصادی است. هدف اصلی این پایان نامه در این پیش بینی، حداکثر کردن دقت نتایج است [۸].

۲-۲-۲- سرعت

اصلی ترین نیاز سازمان‌ها پیش بینی با سرعت بالاست، متخصصین باید برای آموزش از تکنیک‌ها و الگوریتم‌های کوتاه استفاده کنند به طوری که پیش بینی یک روز آینده باید ۲۰ دقیقه به طول بی‌انجامد. همچنین استفاده از آخرین اطلاعات بار باعث افزایش دقت می‌شود [۸].

۲-۳- شناسایی خودکار اطلاعات نادرست

دستگاه‌های اندازه گیری جهت انتقال داده‌های اندازه گیری شده، درسیستم‌های قدرت مدرن قرار گرفته شده که این داده‌ها به مرکز کنترل توسط خطوط ارتباطی فرستاده می‌شوند. البته گاهی ارسال نادرست به مراکز اشتباه به دلیل مشکلات ارتباط یا اندازه گیری وجود دارد. وظیفه ی تشخیص داده‌های بد، در پیش بینی به صورت کوتاه مدت، توسط اپراتورهای سیستم‌های قدرت انجام می‌شود در صورتی که درسیستم‌های جدید این وظیفه به عهده ی سیستم‌های هوشمند است [۸].

۲-۳-۱- واسط

واسط‌های نرم افزاری که برای پیش بینی مورد استفاده قرار می‌گیرند باید به گونه ای راحت، آسان و عملی باشد که کاربر توسط واسط جدولی یا گرافیکی مدل پیش بینی را به راحتی توصیف کند و خروجی به صورت عددی و گرافیکی باشد [۸].

۲-۳-۲- دسترسی اتوماتیک به داده‌ها

پایگاه داده، مجموعه اطلاعات مربوط به آب و هوا و داده‌های بار می‌باشد. قابلیت دسترسی خودکار به اطلاعات ورودی، و همچنین پیش بینی وضع آب و هوا از طریق اینترنت یا هرپل ارتباطی، باید در پیش بینی به صورت کوتاه مدت باشد.

۲-۴- مشکلات در حال حاضر در پیش بینی به صورت کوتاه مدت بار

این پیش بینی مشکلات زیادی را دارد. برای بدست آوردن روابط بین متغیر خروجی و ورودی، در این سیستم‌ها از ساختار شبه شبکه عصبی یا تابع رگرسیون استفاده می‌شود، در صورت انتخاب نادرست ساختار شبکه یا رگرسیون، نتیجه ی پیش بینی قابل قبول نخواهد بود. به عنوان مثال استفاده از رابطه خطی برای خروجی و ورودی، در صورتی که مسئله از نوع درجه دوم باشد، نتیجه ضعیفی دارد. علاوه بر این باید از انتخاب پارامترهای خوب و مناسب و همچنین انتخاب تعداد مناسب متغیرهای ورودی، برای پیش بینی خوب استفاده کرد. با حذف متغیرهای بی تاثیر در رفتار بار دقت پیش بینی افزایش می‌یابد.

جهت سهولت بیان رابطه خروجی و ورودی در پیش بینی به صورت کوتاه مدت، از ابزار خوشه بندی و شناسایی مدل استفاده می‌شود. اطلاعات نمونه به چند خوشه تقسیم و هر خوشه دارای ساختار شبکه یا تابع مخصوص به خود، جهت نشان دادن ارتباط خروجی و ورودی است. در نتیجه نشان دادن خصوصیات دقیق سیستم در این روش، پیش بینی بهتری ارائه می‌شود، ولی همچنان برای ساختار شبکه یا تعیین فرم رگرسیون و خوشه بندی نیازمند داده‌های پیشینه مسئله برای هر خوشه است [۸].

۲-۴-۱- تعمیم تجربه کارشناسان

با تجربه کسب شده از کار با سیستم قدرت، متخصصین توانایی پیش بینی بار بهتری نسبت به کامپیوترها دارند، پس برای اینکه پیش بینی دارای قابلیت کسب تجربه باشد از سیستم‌های استنتاج فازی و خبره استفاده می‌شود، به دلیل پیش بینی مفهومی و احساسی متخصصین، تعریف قانون کار برای بانک اطلاعاتی این سیستم‌ها دشوار است [۸].

۲-۴-۲- پیش بینی ایام غیر طبیعی

به دلیل وجود نداشتن نمونه کافی و همچنین رفتار غیر معمول بار نسبت به روزهای طبیعی سال، پیش بینی برای روزهای غیر معمول سخت است. از روزهای غیر طبیعی می‌توان به ایام بعد و قبل از تعطیلات، ایام دارای اتفاق خاص، تغییر جو آب و هوا، تعطیلات پی در پی، تعطیلات عمومی، اشاره کرد. تجربیات حاکی از آن است

که پیش بینی در روزهای تغییر ناگهانی جو بسیار دشوار است. ترکیب دو ویژگی روزهای قبلی مشابه و نزدیک، کار سختی می‌باشد [۸].

۲-۴-۳- عدم دقت و خطا در اطلاعات پیش بینی وضع آب وهوا

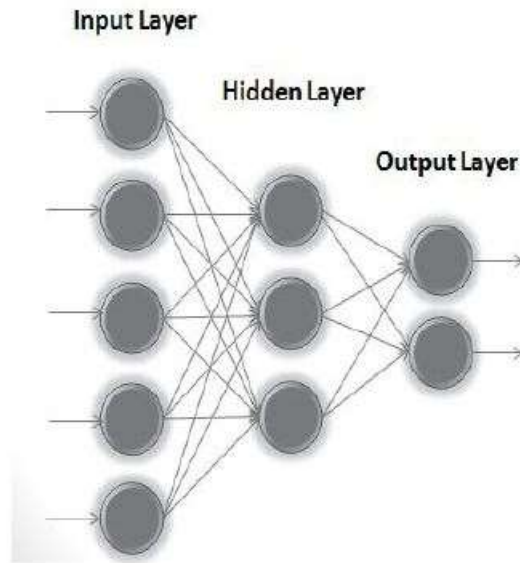
با توجه به اینکه آب وهوا در نتیجه پیش بینی بسیار موثر است و در چند دهه آخر بهبود یافته، آن را در مدل‌ها لحاظ می‌کنند. عواملی که موجب خطا و عدم دقت در پیش بینی می‌شود، عدم اطلاعات درست آب و هوا و توانایی نداشتن ارائه جزئیات داده‌های پیش بینی وضع آب و هوا است. داده‌های مربوط به پایین ترین دما، احتمال بارش، بالاترین دما، رطوبت متوسط، وضع هوا در شب و عصر و صبح، حداکثر سرعت باد، در نتیجه پیش بینی وضع آب وهوای یک روز طبیعی و عادی ثبت می‌شود. هر ساعت یا هر ۱۵ دقیقه، در روز ۲۴ یا ۹۶ می‌اطلاعات بار ثبت می‌شود. اطلاعات آب و هوایی که در این نقاط باشد، دارای دقت بیشتری هستند. در زمان‌های طولانی این اطلاعات به این مفصلی نیست و این یک نوع سختی در پیش بینی بار می‌باشد [۸].

۲-۴-۴- عدم تعمیم پذیری به دلیل بیش برآزش

بیش برآزش مشکلی فنی است و زمانی رخ می‌دهد که خطا برای اطلاعات تست بالا و خطای آموزش برای اطلاعات آموزش کم باشد. پیش بینی بار مرتبط با مجموعه ای از داده‌های تست و داده‌های آموزش است. داده‌های آموزشی، آموزش دیده شده قابلیت نمایش اصلی جهت پیش بینی اطلاعات آموزشی را دارند. عدم پیش بینی دقیق اطلاعات در آینده، و توانایی پیش بینی اطلاعات آموزشی در شبکه‌های عصبی، نقطه ضعف این شبکه است، در این حالت می‌گوینم پیش برآزش برای شبکه عصبی رخ داده است. بادر نظر گرفتن هدف پیش بینی به صورت کوتاه مدت بار مبتنی بر پیش بینی اطلاعات می‌آینده، باید جهت جلوگیری از پیش برآزش راه حل‌هایی مورد استفاده قرار گیرد [۸].

۲-۵- ساختار شبکه عصبی

شبکه عصبی متشکل شده از سه قسمت: لایه خروجی، لایه ورودی و لایه پنهان می‌باشد. لایه ورودی اطلاعات را دریافت می‌کند، لایه پنهان به برقراری ارتباط ورودی و خروجی می‌پردازد و با جهان خارج ارتباط ندارد. تولید اطلاعات توسط لایه خروجی، پس از پردازش شبکه صورت می‌پذیرد. شکل (۱-۲).

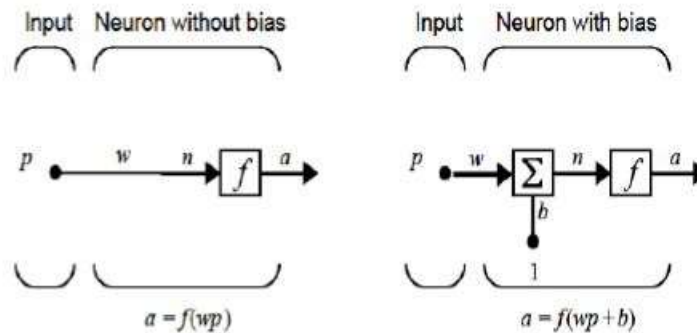


شکل ۲-۱: نشان دهنده ساختار شبکه عصبی است.

شبکه عصبی قادر به یادگیری روابط پیچیده بین بردارهای خروجی و ورودی، و مدل نمودن توابع غیرخطی هستند. این قابلیت باعث می‌شود در مسائل عملی مثل کنترل سیستم غیرخطی، تشخیص تطبیقی و پیش بینی مورد استفاده قرار بگیرند.

۲-۵-۱- نرون با فقط یک ورودی عددی

نرون نمایش داده شده در شکل (۲-۲) سمت چپ، متشکل شده از دو عنصر مهم، تابع انتقال f و وزن w است.



شکل ۲-۲: نرون با یک ورودی عددی [۲۷]

متغیر P به عنوان ورودی به نرون دریافت شده و طی ضرب در w وزن دار شده و پس از اعمال شدن در تابع f ، خروجی نمایان می‌شود. برای ایجاد نرون بایاس دار، به ساختار نرون، بایاس اضافه می‌شود، (شکل (۲-۲) سمت راست). ورودی بایاس همی‌شه 1 است. برای شیفت شدن تابع به سمت چپ، حاصل p ، w با مقدار بایاس جمع

می‌شود. تابع انتقال f آرگمان n را گرفته و خروجی n را تحویل می‌دهد همچنین این تابع، یک تابع سیگموئید^۱ و یا پلکانی^۲ است.


$$a = f(wp + b) \quad (۱-۲)$$

بر اساس انتخاب الگوریتم یادگیری و تابع محرک f توسط متخصص، پارامترهای b و w تنظیم می‌شوند. یادگیری به منظور تغییر b و w ، و مطابقت رابطه خروجی و ورودی نرون با هدف مشخص است [۲۷].

• توابع انتقال^۳

تابع انتقال، تابعی است غیرخطی یا خطی از n . از این تابع جهت تعیین ویژگی‌های نرون برای حل مسئله به کار گرفته می‌شود. در ادامه به چند نمونه تابع انتقال در شبکه عصبی می‌پردازیم.

✓ تابع انتقال هارد لیمیت



شکل ۲-۳: تابع انتقال هارد لیمیت [۲۷]

خروجی این تابع بستگی به n دارد و به شرح زیر است:

• $n < 0$ صفر

• $n \geq 0$ یک


این تابع ورودی را به دو کلاس دسته بندی می‌کند و در نرون‌های سازنده پرسپترون کاربرد دارد.

¹ Sigmoid

² Step Function

³ Transfer Function


✓ تابع انتقال خطی



شکل ۲-۴: تابع انتقال خطی [۲۷]

کاربرد این تابع برای تقریب در فیلترینگ خطی، استفاده می‌شود، و مقدار ورودی و خروجی یکسانی را دارد.

✓ تابع انتقال لگاریتمی



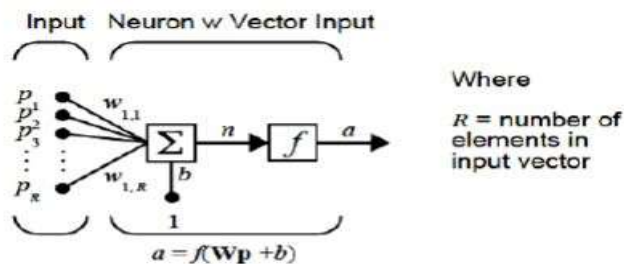
شکل ۲-۵: تابع لگاریتمی [۲۷]

این تابع در شبکه پس انتشار مورد استفاده قرار می‌گیرد. ورودی این تابع $-\infty$ و $+\infty$ است و برپایه فرمولی

خاص خروجی ۱ یا ۰ را برمی‌گرداند [۲۷].

۲-۵-۲- ورودی نرون با یک بردار

به عنوان عناصر بردار وزن W و p_1, p_2, \dots, p_R برای بردار ورودی p در نظر گرفته می‌شود.



شکل ۲-۶: مدل نرون با یک بردار به عنوان ورودی [۲۷]

جهت وزن دار کردن ورودی، ضرب ماتریسی روی بردارهای w و p انجام می‌دهیم. در نتیجه داریم:


$$n = w_{1,1}p_1 + w_{1,2}p_2 + \dots + w_{1,R}p_R + b \quad (2-2)$$

و در آخر ضرب p و w را با مقدار بایاس جمع می‌کنیم.

$$n = Wp + b \quad (3-2)$$

این نماد برای شبکه‌های دارای نرون‌های زیاد و چند لایه، بسیار ناخوانا و شلوغ است، در جهت سهولت و رفع

این مشکل مانند شکل (2-7) یک لایه از نرون را نمایش می‌دهیم:



شکل 2-7: نمایش یک لایه از نرون [27]

- یک لایه شبکه تشکیل شده از ترکیب بایاس‌ها، وزن‌ها، انجام عملیات جمع و ضرب و تابع انتقال، است.

- نماد تابع خاص استفاده شده جهت انتقال، در کادر تابع جای می‌گیرد [27].


2-5-3- ساختار شبکه عصبی¹

2-5-3-1- شبکه تک لایه

یک لایه شبکه متشکل شده از نرون یا نرون‌های کنار هم، شبکه‌ها متشکل شده از یک لایه یا چندین لایه

کنار هم. شبکه‌ای با یک لایه و با S نرون و R ورودی در شکل (2-8) نمایان است.

¹ Network Architecture



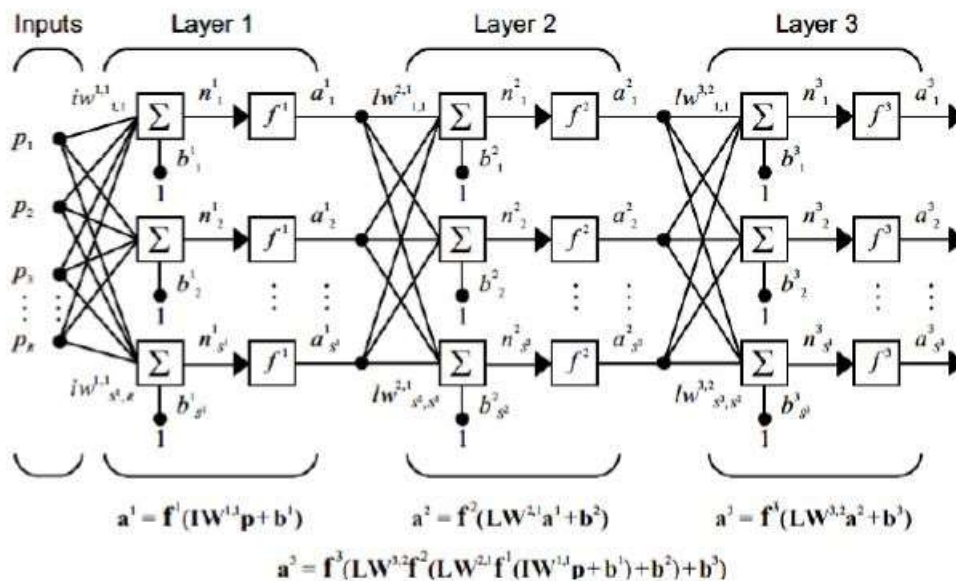
شکل ۲-۸: شبکه ی تک لایه [۲۷]

روند بدست آمدن خروجی، به صورت بردار در این شبکه بدین شرح است:

ابتدا به تمامی نرون‌های، ورودی را اعمال کرده، سپس قبل از اعمال به تابع انتقال، با بردار وزن‌ها ضرب وبا بایاس جمع شده است. برابری تعداد نرون S با تعداد ورودی R اهمیتی ندارد [۲۷].

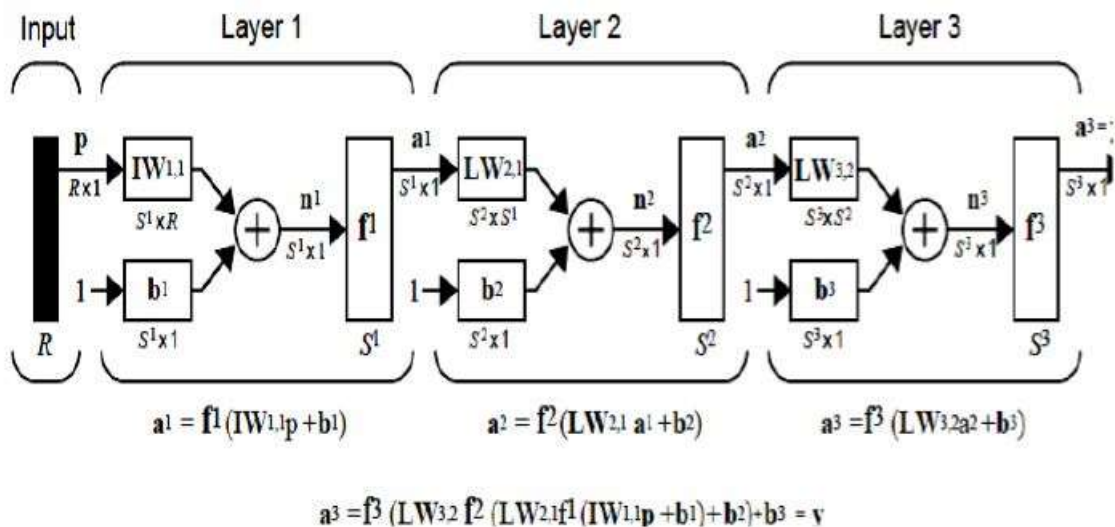
۲-۵-۳-۲- شبکه‌های چند لایه

هرکدام از لایه‌های شبکه دارای ویژگی‌های مختص به خود مثل: بردار بایاس، خروجی وماتریس وزن‌ها است که برای متمایز ساختن این ویژگی‌ها، از اعداد بالانویس استفاده می‌شود، شکل (۹-۲). هر شبکه می‌تواند دارای چند لایه و هر لایه دارای چند نرون باشد.



شکل ۲-۹: نمایش ویژگی متمایز هر لایه از شبکه [۲۷]

یک شبکه قابلیت این را دارد که نرون‌های متفاوتی در هر لایه داشته باشد، مثل شکل بالا، تعداد S^2 نرون در دومین لایه، تعداد S^3 نرون در سومین لایه، و تعداد S^1 نرون در اولین لایه با R^1 ورودی، را نمایش می‌دهد. هر لایه وظایف مختلفی دارند، و خروجی هر لایه، ورودی لایه بعد است. پس لایه میانی این شبکه با ورودی S^1 ، نرون‌های اولین لایه و S^2 نرون، با وزن W^2 و همچنین اندازه $S^2 * S^1$ ، به صورت شبکه یک لایه در نظر گرفت. ورودی لایه میانی، خروجی اولین لایه a^1 ، و خروجی لایه میانی a^2 است. آخرین لایه، خروجی شبکه را مشخص می‌کند که به آن لایه خروجی می‌گویند. و مابقی لایه‌ها، لایه مخفی هستند. در شکل بالا لایه سوم، لایه خروجی و اولین و دومین لایه، لایه مخفی است. برخی متخصصین لایه ورودی را به عنوان لایه جدا در نظرمی‌گیرند. برای آسان شدن کار شکل (۲-۶) را به صورت (۲-۱۰) نمایش می‌دهند.



شکل ۲-۱۰: شبکه‌ی چند لایه [۲۷]


هرچه تعداد لایه‌های شبکه بیشتر باشد، شبکه‌ای قدرتمند به وجود می‌آورد. برای تخمین زدن تابع منتخب با محدودیت نقاط ناپیوستگی، نیازمند شبکه‌ای با اولین لایه سیگموئید و دومین لایه خطی نیاز است. کاربرد این شبکه‌ی دولایه در شبکه پس از انتشار است [۲۷].

۲-۵-۴- شبکه عصبی پویا و ایستا^۲

در شبکه‌های رو به جلو^۳ یا ایستا خروجی به واسطه اتصالات پیشخور تعیین شده و فاقد اجزای تاخیری^۴ و پسخوردی^۵ می‌باشد. ولی در شبکه عصبی پویا خروجی بستگی به حالت شبکه، خروجی و ورودی‌های قبل و ورودی فعلی دارد. همچنین متشکل شده از دو دسته: شبکه‌هایی با اتصالات پسخوردی (شبکه‌های بازگشتی)^۶ و شبکه‌هایی با اتصالات پیشخور، هستند.

۲-۵-۵- انواع مختلف شبکه عصبی از جهت برگشت پذیری

شبکه رو به جلو یا پیشخور: مسیر پاسخ در این شبکه‌ها به صورت پیوسته پیشخور پردازش شده و امکان بازگشت نرون به لایه قبل وجود ندارد. سیگنال‌ها در این شبکه از سمت ورودی، وارد و به سمت خروجی هدایت می‌شوند و همین امر باعث عدم فیدبک و بازخورد شده است و خروجی در همان لایه تاثیرگذار نیست. پیام عصبی در بدن انسان قبل از رسیدن به آکسون، از دندریت به بدنه سلول می‌روند. پرسپترون یکی از ساده ترین‌های این شبکه است که در ادامه معرفی خواهیم کرد. این شبکه پیشخور در شکل (۱۱-۲) نمایان می‌باشد.



شکل ۲-۱۱: یک نمونه از شبکه پیشخور

شبکه‌های پسخور یا برگشتی: وجه تمایز این شبکه با پیشخور در این است که حتما یک یا چند سیگنال برگشتی در این شبکه، از یک نرون، به خودش یا نرون‌های لایه پیشین یا همان لایه راه دارد، و وجود فیدبک بدین معناست که خروجی آن نرون هم اکنون بستگی به خروجی همان نرون در گذشته و همچنین ورودی

¹ Dynamic Networks

² Static Networks


³ Feedforward

⁴ Delay

⁵ Feedback

⁶ Recurrent

هم اکنونش دارد. این شبکه‌ها توانایی درک بهتر رفتار پویایی و زمانی سیستم را دارند. این شبکه با توجه به چگونگی مسئله ایجاد می‌شوند و به تصحیح و تغییر پارامترها پس از مرحله یادگیری می‌پردازند. از آنجایی که شبکه برگشتی پویا است، بلای رسیدن به نقطه تعادل، به طور پیوسته وضعیت آنها تغییر می‌کند. سپس تا زمان تغییر ورودی، این تعادل ثابت می‌ماند. از ساده ترین شبکه‌های برگشتی می‌توان هاپفیلد^{۲۰} را نام برد. در شکل (۱۲-۲) به نمایش یک شبکه پسخور پرداختیم.




شکل ۱۲-۲: نمونه شبکه پسخور

۲-۵-۶- شبکه عصبی المان (ELMAN)

شبکه عصبی المان نوعی شبکه عصبی بازخوردی است. بر اساس لایه پنهان شبکه عصبی BP، یک لایه تعهدی^۱ را به عنوان اپراتور تاخیر، برای هدف حافظه اضافه می‌کند، به طوری که سیستم شبکه توانایی انطباق با ویژگی‌های دینامیکی متغیر با زمان را داشته باشد و پایداری جهانی قوی داشته باشد. شکل (۱۳-۲) ساختار شبکه عصبی المان را نشان می‌دهد

^۱ undertake layer



شکل ۲-۱۳: دیاگرام کلی شبکه عصبی المان

توپولوژی به طور کلی به چهار لایه تقسیم می‌شود: لایه ورودی، لایه پنهان، لایه تعهد و لایه خروجی. لایه Undertake برای به خاطر سپردن خروجی لایه پنهان استفاده می‌شود که می‌توان آن را به عنوان یک عملگر تاخیر گام مشاهده کرد. بر اساس شبکه BP، خروجی لایه پنهان با ورودی آن از طریق تاخیر و ذخیره لایه تعهد ارتباط برقرار می‌کند. این روش ارتباط به داده‌های تاریخی حساس است و شبکه بازخورد داخلی می‌تواند توانایی انتقال اطلاعات پویا را افزایش دهد. به خاطر سپردن حالت داخلی باعث می‌شود که آن تابع نگاشت پویا داشته باشد، که باعث می‌شود سیستم توانایی انطباق با ویژگی‌های متغیر زمان را داشته باشد.

فرض کنید با n ورودی، m خروجی، تعداد نورون‌های لایه پنهان و تعهد r باشد، وزن لایه ورودی به لایه پنهان w_1 ، وزن لایه Undertake به لایه پنهان w_2 ، وزن لایه پنهان به لایه خروجی برابر w_3 است. $u(k-1)$ ورودی شبکه عصبی، $x(k)$ خروجی لایه پنهان، $x_c(k)$ خروجی لایه Undertake و $y(k)$ خروجی شبکه عصبی است.

سپس داریم:

$$x(k) = f(w_2 x_c(k) + w_1 (u(k-1))) \quad (۴-۲)$$

که

$$x_c(k) = x(k - 1);$$

f تابع انتقال لایه پنهان است که معمولاً در تابع نوع S استفاده می‌شود. به این معنا که،

$$f(x) = (1 + e^{-x})^{-1} \quad (۵-۲)$$

g تابع انتقال لایه خروجی است که اغلب یک تابع خطی است. به این معنا که،

$$y(k) = g(w_3x(k)). \quad (۶-۲)$$

شبکه عصبی المان از الگوریتم BP برای اصلاح وزن‌ها استفاده می‌کند. خطای شبکه بصورت زیر است:

$$E = \sum_{k=1}^m (t_k - y_k)^2, \quad (۷-۲)$$

که در آن t بردار خروجی شی است.

۲-۶- مرور کارهای گذشته

معماری‌های عصبی عمیق اخیراً توانایی خود را در مدل‌سازی الگوهای زیربنایی پیچیده برای پیش‌بینی بار الکتریکی نشان داده‌اند. ژنگ و همکاران مدل LSTM را برای پیش‌بینی کوتاه‌مدت با استفاده از داده‌های سری زمانی بار الکتریکی تک متغیره پیچیده یک ساختمان مدرسه با غیر ایستایی قوی و غیر فصلی پیشنهاد کرده‌اند [۲۸]. مشخص شد که روش پیش‌بینی مبتنی بر LSTM از روش‌های دیگر، از جمله میانگین متحرک یکپارچه خودبازگشتی فصلی (SARIMA)، یک شبکه عصبی خودبازگشتی غیرخطی با ورودی‌های برون‌زا (NARX)، رگرسیون بردار پشتیبان (SVR) و یک شبکه عصبی پیش‌خور سنتی بهتر عمل می‌کند. نارایان و هیپیل از مدل LSTM برای پیش‌بینی بار الکتریکی کوتاه‌مدت با استفاده از داده‌های تاریخی ده ساله برای استان انتاریو در کانادا استفاده کردند و نتایج بسیار قابل اعتماد و قوی را گزارش کردند [۲۹]. به طور مشابه، مارینو و همکاران از دو معماری عمیق مختلف برای پیش‌بینی بار انرژی استفاده کرده‌اند، یک LSTM استاندارد و یک LSTM با معماری دنباله به دنباله که نتایج خوبی ایجاد کرد [۳۰].

چندین کار با استفاده از PSO برای بهینه‌سازی مدل‌های یادگیری ماشین در حوزه انرژی در ادبیات گزارش شده‌اند. وانگ و همکاران از مدل‌های پیش‌بینی هوشمند ترکیبی با استفاده از جستجوی فاخته و بهینه‌سازی ازدحام ذرات برای تنظیم پارامترهای مدل‌های SARIMA و SVR برای بهبود پیش‌بینی بار کوتاه‌مدت استفاده

کرده‌اند [۳۱]. نتایج نشان داد که حذف نویز تجزیه و تحلیل طیفی منفرد و بهینه‌سازی مبتنی بر هوش ازدحامی به طور موثر عملکرد مدل را بهبود می‌بخشد. اوزردم و همکاران از تکنیک ازدحام ذرات برای بهینه‌سازی یک شبکه عصبی پیش‌خور برای پیش‌بینی بار ساعتی عرضه‌شده توسط یک شرکت انرژی استفاده کرده‌اند و دریافته‌اند که هم شبکه‌های عصبی بهینه‌شده با ازدحام ذرات و هم شبکه‌های عصبی پس انتشار برای پیش‌بینی بار مرتبط هستند [۳۲]. علاوه بر این، شبکه‌های PSO منجر به همگرایی سریع‌تر می‌شوند. به طور مشابه، رن و همکاران، از یک رویکرد پیش‌بینی یکپارچه برای مصرف برق سالانه پکن استفاده کرده و PSO برای یافتن بهترین پارامترها برای مدل SVM استفاده شده است [۳۳].

چندین اثر منتشر شده با موفقیت از الگوریتم ژنتیک GA برای اهداف مختلف بهینه‌سازی استفاده کرده‌اند. ایسلام و همکارانش یک الگوریتم ژنتیک را برای بهینه‌سازی تعداد لایه‌ها و نورون‌ها در هر لایه برای یک شبکه عصبی مصنوعی آموزش‌دیده با الگوریتم پس انتشار پیاده‌سازی کرده‌اند. میانگین درصد خطای مطلق (MAPE) و زمان محاسباتی مدل پس از بهینه‌سازی توپولوژی ANN به طور قابل توجهی کاهش یافت [۳۴]. دفیلیپو و همکاران از GA برای انتخاب معماری و پارامترهای آموزشی مناسب با استفاده از شبیه‌سازی‌های تکاملی یک مدل شبکه عصبی برای پیش‌بینی بار برای شهری در برزیل استفاده کرده. دو پیش‌بینی سری زمانی ساده، یک روش خطی و یک شبکه عصبی با پارامترهای جستجوی شبکه‌ای به‌عنوان معیار استفاده شد. مشخص شد که روش مبتنی بر GA نتایج بسیار بهتری را با خطای MAPE کمتر نسبت به چهار معیار دیگر تولید می‌کند [۳۵].

اخیراً، مدل‌سازی سری‌های زمانی با استفاده از تکنیک LSTM برای مدل‌سازی توالی‌های پیچیده مانند بارهای الکتریکی که در آن یادگیری وابستگی‌های طولانی‌مدت و پیگیری آنچه در گذشته اتفاق می‌افتد ضروری است، محبوبیت پیدا کرده است. LSTM معماری شبکه عصبی بازگشتی (RNN) را با استفاده از یک سلول حافظه و مکانیزم دروازه‌ای که اجازه تنظیم جریان اطلاعات در سراسر شبکه را می‌دهد، اصلاح می‌کند. سریواستاوا و همکارش از LSTM برای پیش‌بینی انرژی خورشیدی استفاده کردند. نورون‌ها در لایه‌های اول و دوم برای هر دو مدل LSTM و ANN به صورت شبکه‌ای جستجو شدند و مشخص شد که یک مدل LSTM با پیکربندی

مناسب برای پیش‌بینی‌های روز آینده از رگرسیون تقویت‌کننده گرادیان و شبکه‌های عصبی پیش‌خور بهتر عمل می‌کند [۳۶]. لاگو و همکاران با استفاده از چهار مدل مختلف یادگیری عمیق، قیمت برق روز آینده را پیش‌بینی کرد. برای مقایسه معیار، ۲۳ مدل مختلف ارائه شده در ادبیات برای پیش‌بینی قیمت برق استفاده شد. روش‌های بهینه‌سازی بیزی برای انتخاب پارامترهای بهینه برای مدل‌های شبکه عصبی عمیق (DNN)، LSTM و واحد بازگشتی دروازه‌ای (GRU) استفاده شد. مشخص شد که مدل‌های DNN، LSTM و GRU به دقت پیش‌بینی دست یافته‌اند که از نظر آماری به طور قابل توجهی بهتر از سایر معیارها است [۳۷]. بندرا و همکاران یک مدل پیش‌بینی با استفاده از LSTM بر روی زیر گروه‌های سری زمانی مشابه با استفاده از دو مجموعه داده معیار ساخت. این رویکرد، خوشه‌هایی از یک سری مشابه را از مجموعه کلی سری‌های زمانی کشف کرد. تنظیم فرآیندهای LSTM مانند اندازه دوره، اندازه کوچک دسته ای و وزن منظم با استفاده از جستجوی شبکه در یک مجموعه اعتبار سنجی اضافی انجام شد [۳۸]. نتایج نشان داد که LSTM می‌تواند از روش‌های پیش‌بینی تک متغیره بهتر عمل کند، و زیرگروه‌بندی یک سری زمانی مشابه، دقت این مدل پایه LSTM را افزایش می‌دهد.

علاوه بر پیش‌بینی انرژی، LSTM و فراابتکاری در چندین حوزه دیگر مورد استفاده قرار گرفته‌اند و عملکرد برتر را با توجه به سایر مدل‌های یادگیری عمیق نشان داده‌اند. شیائو و یین یک شبکه عصبی LSTM ترکیبی را برای پیش‌بینی جریان ترافیک پیشنهاد کردند که برای مجموعه‌های جریان ترافیک بزرگ و کوچک بهینه‌سازی شده بود و به مقدار RMSE کمتری در مقایسه با سایر مدل‌های پایه دست یافت [۳۹]. رومن و همکاران از منطق فازی و یک بهینه ساز فراابتکاری، یعنی بهینه ساز گرگ خاکستری، برای رسیدگی به یک مشکل کنترل فرآیند غیرخطی استفاده کرد [۴۰]. ماهانی پور و همکاران یک الگوریتم جستجوی گرانشی (GSA)، یک الگوریتم مبتنی بر جمعیت برای ایجاد خودکار برنامه‌های رایانه‌ای و اعمال آن در رگرسیون نمادین (SR) و مشکل ساخت ویژگی (FC) را پیشنهاد کرده‌اند [۴۱]. لیو و همکاران یک روش پیش‌بینی کوتاه‌مدت انرژی باد را بر اساس تبدیل موجک گسسته و LSTM طراحی کردند و دقت پیش‌بینی افزایش یافته را در مقایسه با پنج معیار مختلف گزارش کردند [۴۲].

۲-۷- مقاله مرجع

در مقاله مرجع [۴۳]، استفاده از دو فراابتکاری تکاملی، یعنی یک الگوریتم ژنتیک (GA) و بهینه‌سازی ازدحام ذرات (PSO)، را برای مشکل بهینه‌سازی عملکرد یک مدل LSTM برای پیش‌بینی بار الکتریکی ارائه شده است. رویکرد این کار با رویکردهای پایه جایگزین مقایسه می‌شود که از تکنیک‌های پیشرفته‌ی یادگیری ماشین و همچنین یک مدل LSTM چند دنباله‌ای با پارامترهای تنظیم‌شده دستی از طریق آزمایش‌های گسترده استفاده می‌کنند. مقایسه نشان می‌دهد که استفاده از فراابتکاری برای پیکربندی بهینه پیش‌بینی بار الکتریکی، یک مدل LSTM چند دنباله‌ای را به دست آورده است که به طور قابل‌توجهی بهتر از مدل‌های معیار از جمله سایر تکنیک‌های یادگیری ماشین (به عنوان مثال، SVR، جنگل تصادفی، و ANN) و LSTM که به صورت دستی پیکربندی شده است، عمل می‌کند.

فصل سوم: روش پیشنهادی

یک موضوع اساسی و مهم در استفاده از سیستم‌های قدرت، پیش‌بینی کوتاه مدت بار الکتریکی است. با توجه به روابط غیر خطی بین بار الکتریکی و سایر عوامل تاثیر گذار بر پیش‌بینی بار الکتریکی، روش‌های سنتی و معمول مثل مدل‌های علت و معلول، تحلیل رگرسیون، فضای حالت و مدل‌های سری زمانی، معمولاً دارای جواب‌های با دقت بالایی نیستند.

یکی از راه‌های چشمگیر برای مدل کردن سیستم‌هایی که الگو ریاضی بخصوصی ندارند و یا الگو ریاضی آنها بی نهایت مشکل می‌باشد به کارگیری سیستم‌های هوشمند است. الگوریتم‌های هوشمند بر پایه برنامه ریزی تکاملی، سیستم‌های خبره، سیستم‌های فازی و شبکه‌های عصبی و ترکیبی از آنها مورد توجه قرار گرفته است. روش‌های شبکه عصبی از بین دیگر روش‌ها بخاطر شکل واضح، سادگی تحقق و نتیجه خوب توجهات بیشتری را به خود جلب کرده است.

شبکه‌های عصبی می‌توانند از بین داده‌های آموزشی ورودی و خروجی هر مدل نگاشت غیر خطی و مشکلی را آموزش دیده و ایجاد کنند. شبکه‌های عصبی دارای شمار زیادی واحدهای محاسباتی موازی است که می‌تواند با استفاده از سخت افزار و یا نرم افزار اجرا شود.

موضوع مهم در بکارگیری شبکه‌های عصبی به منظور پیش‌بینی بار الکتریکی، استفاده از شیوه مناسب برای یادگیری آن، بهره‌گیری از قالب مناسب برای این شبکه و آگاهی دقیق عوامل تاثیر گذار در اندازه بار الکتریکی مصرفی می‌باشد. این عوامل در حقیقت همان ورودی‌های شبکه عصبی می‌باشد، نتایج دستاورد از پیش‌بینی چنانچه که به درستی انتخاب نشوند از دقت کافی بهره‌مند نخواهد بود.

شبکه عصبی بازگشتی یکی از مهم‌ترین شبکه‌های عصبی است که به منظور پیش‌بینی کوتاه مدت بار الکتریکی به کار برده می‌شود. تفاوت میان پرسپترون چند لایه و شبکه عصبی بازگشتی همان در بکارگیری از لایه زمینه^۱ است. داده‌های قبلی توسط لایه زمینه حفظ می‌شود و خروجی لایه‌های پنهان، لایه زمینه نیز منتشر می‌شود.

^۱ Context Layer

۳-۲- مدل‌سازی شبکه عصبی برای پیش بینی بار الکتریکی

شبکه‌های عصبی بسیار تغییر پذیر می‌باشند، به گونه‌ای که طراحی یک مدل پیش بینی با شبکه‌های عصبی برای کاربردهای علمی کار راحتی نیست و گزینه‌های زیادی وجود دارد. پس در گام اول از پیش بینی، باید به مدل‌سازی شبکه‌های عصبی مورد نظر پردازیم. این مرحله حاوی بخش‌های زیر است:

۱. انتخاب نوع شبکه عصبی

۲. انتخاب تعداد لایه‌های مخفی

۳. انتخاب تعداد نرون‌ها در هر لایه

۴. انتخاب تابع عملکرد نرون‌ها

۳-۳- روش پیشنهادی: پیش‌بینی بار در کوتاه مدت با استفاده از شبکه المان


(ENN)

در این کار برای پیش بینی انرژی الکتریکی مصرف شده از شبکه عصبی المان استفاده می‌کنیم. شبکه عصبی المان (ENN) یکی از شبکه‌های عصبی بازگشتی (RNN) است. در مقایسه با شبکه‌های عصبی سنتی، ENN دارای ورودی‌های اضافی از لایه پنهان است که یک لایه جدید - لایه زمینه را تشکیل می‌دهد. بنابراین الگوریتم استاندارد پس انتشار (BP) مورد استفاده در ENN، الگوریتم پس انتشار المان (EBP) نامی ده می‌شود. ENN را می‌توان برای حل مسائل پیش بینی توالی زمانی گسسته استفاده کرد.

شبکه عصبی Back-Propagation (BP) دارای توانایی نگاشت غیرخطی قوی است و می‌توان آن را به راحتی توسط کامپیوتر تشخیص داد. با این حال، خود الگوریتم پس انتشار دارای عیوب بسیاری است، مانند سرعت همگرایی آهسته، به دام افتادن آسان در یک بهینه محلی و غیره. شبکه عصبی بازگشتی (RNN) با یک یا چند حلقه بازخورد برای حل مشکلات ذکر شده در بالا طراحی شده است. در مقایسه با شبکه‌های عصبی پیشخور، RNN پویا است، که این ویژگی باعث می‌شود RNN توانایی حافظه کوتاه مدت را داشته باشد. به عنوان یک نوع شبکه تکراری که دارای یک لایه زمینه به عنوان یک لایه خود ارجاع داخلی است، ENN به روشی نظارت شده با استفاده از الگوریتم محبوب انتشار برگشتی، بر اساس ورودی‌ها و اهداف داده شده به

شبکه، آموزش داده می‌شود. در همین حال، ENN می‌تواند سیستم‌های دینامی کی غیرخطی را مدل‌سازی کند و الگوهای متغیر با زمان را بیاموزد، بنابراین توانایی بسیار خوبی برای حل مسائل سری‌های زمانی گسسته دارد.

همانطور که در شکل (۳-۱) نشان داده شده است، شبکه عصبی المان دارای چهار لایه است: لایه ورودی، لایه پنهان، لایه زمینه و لایه خروجی. اتصالات بین لایه ورودی، لایه پنهان و لایه خروجی را می‌توان به عنوان یک شبکه پیشخور در نظر گرفت، این بخش شبیه به شبکه عصبی چند لایه سنتی است. علاوه بر سه لایه بالا، لایه دیگری به نام لایه زمینه وجود دارد، ورودی‌های این لایه از خروجی‌های لایه پنهان می‌آیند، لایه زمینه برای ذخیره مقادیر خروجی لایه مخفی دفعه قبل استفاده می‌شود، بنابراین به آن لایه زمینه می‌گویند.



شکل ۳-۱: دیاگرام شبکه المان پیشنهادی

بیان غیر خطی ENN به شرح زیر است:

$$y(k) = g(w^3 x(k)) \quad (1-3)$$

$$x(k) = f(w^1 x_c(k) + w^2(u(k-1))) \quad (2-3)$$

$$x_c(k) = x(k - 1) \quad (3-3)$$

در بالا، $x \in \mathbb{C}^{m \times 1}$ بردار خروجی، $y \in \mathbb{C}^{n \times 1}$ بردار میانی، $u \in \mathbb{C}^{r \times 1}$ بردار ورودی، و $x_c \in \mathbb{C}^{n \times 1}$ به ترتیب بردار حالت بازخورد است. w^3, w^2, w^1 وزن اتصال از لایه میانی به لایه خروجی، لایه ورودی به لایه میانی و لایه پذیرنده به لایه میانی را نشان می‌دهد. $g(x)$ تابع انتقال نورون خروجی ترکیبی خطی از خروجی لایه میانی است. $f(x)$ تابع انتقال نورون‌های لایه میانی است. معمولاً تابع سیگموئید را می‌پذیرد:

$$f(x) = \frac{1}{1 + e^{-x}} \quad (4-3)$$

تابع هدف ENN تابع خطا است که می‌تواند به صورت زیر بیان شود:

$$E(w) = \sum_{k=1}^n [y_k(w) - \tilde{y}_k(w)]^2 \quad (5-3)$$

که در آن $\tilde{y}_k(w)$ بردار خروجی است.

۳-۳-۱- انتخاب تعداد لایه‌های مخفی

شبکه‌های عصبی استفاده شده برای پیش‌بینی بار الکتریکی معمولاً حاوی یک لایه مخفی یا دو لایه مخفی می‌باشند. شبکه عصبی پرسپترون با یک لایه مخفی تایید شده است که توانایی ارزیابی هر تابع غیر خطی را دارد، اما در شبکه با دو لایه مخفی احتمال بیش‌برازش در موارد مربوط به پیش‌بینی سری‌های زمانی بیشتر می‌شود در نتیجه در این کار از یک لایه پنهان استفاده شده است.

۳-۳-۲- انتخاب تعداد نرون‌ها در هر لایه

همان‌گونه که پیش‌از این گفته شد شبکه عصبی از سه لایه ایجاد شده است: لایه خروجی، لایه ورودی و لایه میانی. هر یک از این لایه‌ها حاوی تعداد مشخصی نرون می‌باشند که در مدلسازی شبکه عصبی باید این تعداد مشخص شود.

نرون‌های لایه ورودی در حقیقت اشاره‌کننده به متغیرهای ورودی است و نرون‌های حقیقی به حساب نمی‌آیند. شمار نرون‌های ورودی به شمار متغیرهای ورودی ارتباط دارد.

ظرفیت آموزش شبکه را تعداد نرون‌های لایه میانی مشخص می‌کند. تعیین تعداد این نرون‌ها یک عمل اساسی و حیاتی در مدلسازی شبکه عصبی می‌باشد. اگر تعداد نرون‌ها در لایه میانی کم باشد، عمل یادگیری با موفقیت

انجام نمی‌شود. از سویی دیگر اگر این تعداد بسیار باشد پارامترهای شبکه زیاد می‌شود و جریان آموزش وقت گیر خواهد شد.

بنابراین در شیوه کارایی سیستم دیده می‌شود که تعیین تعداد نرون‌ها تا چه اندازه می‌تواند اثر گذار باشد. اصولاً این کار بواسطه روش سعی و خطا صورت می‌گیرد و یک شیوه سازگار و سیستماتیک برای این انتخاب وجود ندارد، آنگاه میزان کار شبکه با به کار بردن تعداد نرون‌های لایه میانی مورد بازبینی قرار می‌گیرد و شبکه‌ای برای این هدف برگزیده می‌شود که مینیمم ترین خطا در آن ایجاد شود.

داده‌هایی که باید پیش‌بینی شود نشان دهنده تعداد نرون‌ها در لایه خروجی است. معمولاً برای پیش‌بینی بار شبکه‌های عصبی یک نرون خروجی دارند. این یک خروجی مربوط به پیش‌بینی بار به صورت ساعتی یا روزانه می‌باشد.

۳-۳-۳- تعیین تابع عملکرد نرون‌ها

همان گونه که در قالب شبکه عصبی پرسپترون چند لایه دیده می‌شود هر نرون در این شبکه حاوی تابعی می‌باشد که تابع عملکرد نامی ده می‌شود. این تابع برای مدل‌سازی شبکه باید مشخص شود. برای نرون‌ها توصیف تابع عملکرد کار سختی نمی‌باشد. اگر به الگوریتم آموزش شبکه دقت شود، این مسئله معلوم می‌باشد که تابع عملکرد باید دارای رفتار غیر نزولی و مشتق پذیر باشد. تابع سیگموئید یک گزینه خوب برای تابع عملکرد می‌باشد. تابع لگاریتمی سیگموئید و تانژانت‌هایپربولیک دو تابع معمول دیگر می‌باشند.

Log-Sigmoid	$a = \frac{1}{1 + e^{-n}}$	$0 \leq a \leq 1$
Hyperbolic Tangent Sigmoid	$a = \frac{e^n - e^{-n}}{e^n + e^{-n}}$	$-1 \leq a \leq 1$

نوع تابع عملکرد بیشتر سرعت شبکه را تحت تاثیر قرار می‌دهد و با توجه به کاربرد خاص سیستم، این تابع تعیین می‌شود.

۳-۴- تعیین روش پیش‌بینی بار


هدف این پژوهش پیش‌بینی بار الکتریکی بصورت کوتاه مدت (دوره‌های هفتگی و ماهانه) می‌باشد. در پیش‌بینی بار الکتریکی بصورت کوتاه مدت در مقالات معتبر معمولاً دو شیوه اجرایی می‌شود. در روش اول فقط از داده‌های بار الکتریکی در گذشته استفاده می‌کنند ولی در روش دوم برخی پارامترهای دیگر مانند وضعیت آب و هوا، سرعت باد و یا نوع روز با توجه به تعطیل بودن یا نبودن نیز لحاظ می‌شود. با توجه به مشکلات بسیاری مانند جمع‌آوری داده‌ها و خطاهای انسانی که در روش دوم برای استفاده از سایر پارامترهای وجود دارد، در این کار ما فقط از داده‌های مربوط به گذشته بار الکتریکی استفاده می‌کنیم.

فصل چهارم:

ارزیابی نتایج شبیه سازی

۴-۱- مقدمه

همانطور که در فصل سوم شرح داده شد، هدف اصلی ما در این پایان نامه استفاده از شبکه عصبی المان برای پیش‌بینی بار الکتریکی در فواصل زمانی هفتگی و ماهانه می‌باشد. در این فصل به بررسی شبیه‌سازی روش پیشنهادی در نرم‌افزار متلب (MATLAB) ورژن ۲۰۲۱ و ارزیابی نتایج بدست آمده می‌پردازیم. در شکل (۱-۴) دیاگرام روش پیشنهادی با جزئیات مشاهده می‌شود. در ادامه هر بخش توضیح داده می‌شود. و در انتها نتایج ارائه می‌شود.



شکل ۴-۱: بلوک دیاگرام روش پیشنهادی

۴-۲- پایگاه داده

مجموعه داده در این کار از RTE Corporation، یک شرکت خدمات عمومی که شبکه انتقال برق فرانسه را اداره می‌کند، به دست آمده است [۴۲]. داده‌ها یک سری زمانی تک متغیره است که شامل نه سال داده مصرف برق نیم ساعته از سال ۲۰۰۸ تا ۲۰۱۶ بر حسب مگاوات (MW) برای یک کلان شهر فرانسه است.

۴-۳- نرمال سازی داده‌ها

پیش پردازش داده‌های خام شامل پاکسازی داده‌ها و نرمال سازی بوده است. داده‌ها در محدوده ۰ تا ۱ با استفاده از مقیاس بندی ویژگی مقیاس بندی شدند، زیرا مقادیر بزرگ می‌توانند یادگیری و همگرایی شبکه عصبی عمیق را کاهش دهند.

۴-۴- آموزش شبکه عصبی و نحوه ارائه اطلاعات به شبکه عصبی

در این کار برای آموزش شبکه عصبی از ۷۰ درصد داده‌ها استفاده شده است و روش پیش‌بینی بدین صورت است که برای پیش‌بینی بار مصرفی در هر روز از داده‌های ۴ روز قبل استفاده شده است. بدین معنی که ورودی شبکه عصبی داده‌های مصرف برق در ۴ روز گذشته در بازه‌های زمانی دلخواه می‌باشد. ابتدا شبکه با ۷۰ درصد از داده‌ها بدین صورت آموزش می‌بیند و سپس پیش‌بینی بصورت هفتگی و ماهانه بر روی ۳۰ درصد دیگر داده‌ها تست می‌شود.

۴-۵- معیارهای ارزیابی

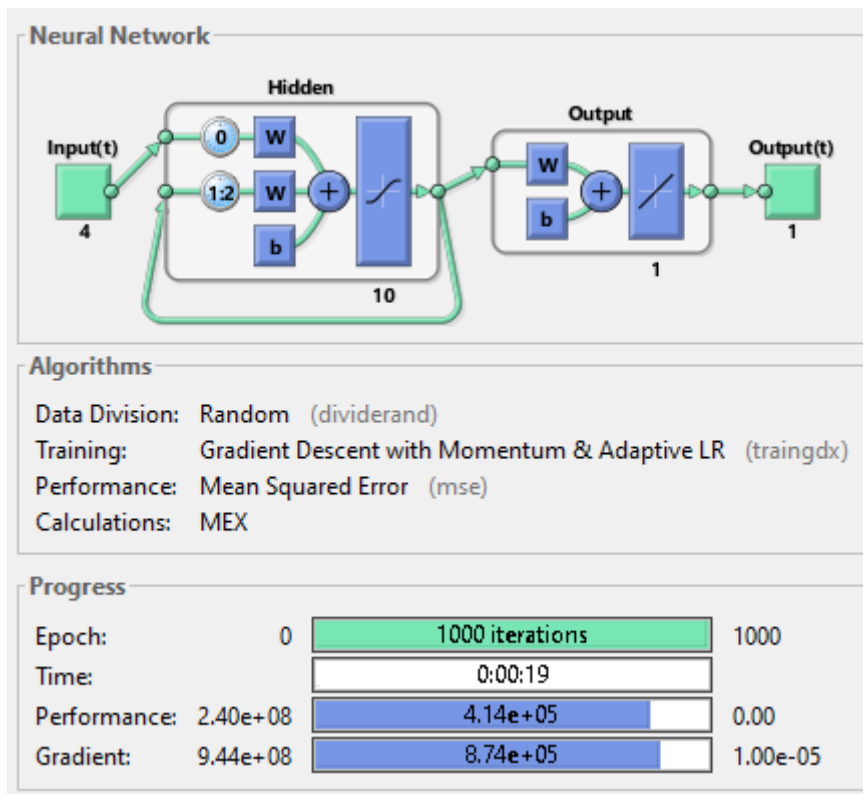
برای ارزیابی عملکرد مدل‌ها از معیارهای نمودار رگرسیون و ریشه میانگین مربعات خطا (RMSE) استفاده شده است:

$$RMSN = \frac{\sqrt{\sum_{i=1}^N (y_i - \hat{y}_i)^2}}{N} \quad (1-4)$$

که \hat{y}_i مصرف انرژی پیش‌بینی شده، y_i مصرف واقعی انرژی می‌باشد. RMSE این مزیت را دارد که عبارات خطای بزرگتر را جریمه می‌کند و دارای واحدهای مشابه مقدار پیش‌بینی شده است.


۴-۶- نتایج شبیه سازی

شبکه پیشنهادی در این کار همانطور که توضیح داده شد دارای ۴ گره ورودی است که با ۴ داده ورودی به عنوان تاخیر مطابقت دارد، ۱ گره خروجی مربوط به پیش بینی روز پنجم است و لایه پنهان دارای ۱۰ نورون می باشد. مشخصات شبکه پیشنهادی در شکل (۴-۲) نشان داده شده است.




شکل ۴-۲: مشخصات کلی شبکه عصبی المان پیشنهادی

نتایج پیش بینی بار مصرفی برای دوره یک ماه و یک هفتگی در شکل های (۴-۳) و (۴-۴) نشان داده شده است.




شکل ۴-۳: نتایج پیش‌بینی بار مصرفی برای یک ماه




شکل ۴-۴: نتایج پیش‌بینی بار مصرفی برای یک هفته

در ادامه در شکل‌های (۴-۵) و (۴-۶) نمودار رگرسیون برای پیش‌بینی ماهیانه و هفتگی آورده شده است. همانطور که مشخص است هر چه نقاط مشکلی بر روی نمودار به خط آبی (خط Fit) نزدیک‌تر باشند در نتیجه پیش‌بینی دقیق‌تر است و خطا کمتر می‌باشد.




شکل ۴-۵: نمودار رگرسیون برای پیش‌بینی ماهیانه




شکل ۴-۶: نمودار رگرسیون برای پیش‌بینی هفتگی

در شکل (۴-۷) هیستوگرام خطا نشان داده شده است و در شکل (۴-۸) نمودار همگرایی شبکه عصبی پیشنهادی آورده شده است. همانطور که مشخص است شبکه برای ۱۰۰۰ گام تکرار شده است اما تقریباً در ۱۰ گام اول به همگرایی رسیده است که نشان از قدرت شبکه پیشنهادی در پیش‌بینی بار مصرفی دارد.



شکل ۴-۷: نمودار هیستوگرام خطا



شکل ۴-۸: نمودار همگرایی شبکه عصبی پیشنهادی

در نهایت در جدول (۴-۱) مقایسه نتایج روش پیشنهادی با چندین روش ارائه شده در مقاله مرجع بررسی شده است. معیار مقایسه خطای RMSE می باشد. همانطور که مشخص است روش پیشنهادی دارای کمترین میزان خطا در مقایسه با سایر روش ها است.

جدول ۴-۱: مقایسه روش پیشنهادی با سایر روش ها با استفاده از معیار RMSE

روش	RMSE
LSTM_GA [43]	۳۱۱,۴۴
LSTM_PSO [43]	۳۴۲,۵۷
Multi-Seq LSTM [43]	۳۵۳,۳۸
Random Forest [43]	۴۳۷,۴۳
SVR [43]	۴۷۹,۸۷
ANN [43]	۷۲۵,۸۹
Extra Trees [43]	۴۹۲,۱۳
Proposed Method	۲۳۹,۷۴

فصل پنجم:

نتیجه‌گیری و پیشنهادات

۵-۱- نتیجه گیری

با توجه به نیاز حیاتی به یک برنامه ریزی و مدیریت کارآمد در زمینه تولید و مصرف انرژی الکتریکی یا همان برق، پیش‌بینی کوتاه مدت از مصرف برق بسیار ضروری است. پیش‌بینی کوتاه مدت مصرف برق این امکان را به تولید کنندگان و شرکت‌های خدمات شهری در این حوزه می‌دهد تا بتوانند در موارد خاص مانند زمان‌های پیک مصرف، از قطع برق جلوگیری کنند و همچنین هزینه‌های آنها نیز به شدت کاهش می‌یابد.

از آنجا که امروزه حجم و تنوع داده‌های مربوط به مصرف برق بسیار زیاد است و تمام منابعی که این داده‌ها را ارائه می‌کنند نیز دائماً در حال افزایش هستند در نتیجه باید برای پیش‌بینی از روش‌های پیشرفته هوش مصنوعی استفاده کرد. یکی از بهترین ابزارها در هوش مصنوعی برای پیش‌بینی شبکه‌های عصبی هستند که توانایی درک روابط خطی و غیر خطی را بین ورودی و خروجی شبکه دارند. از آنجاییکه داده‌های مربوط به مصرف برق از نوع سری زمانی هستند، باید از شبکه‌هایی استفاده کرد که بازگشتی باشند و برای داده‌های سری زمانی مناسب باشند.

ساخت یک مدل دقیق پیش‌بینی بار الکتریکی نیاز به جستجوی یک پیکربندی بهینه دارد که شامل انتخاب تاخیر و تنظیم فرآپارامتر یادگیری عمیق است. انتخاب مدل آموزش و همچنین پارامترهای ذکر شده کار راحتی نیست. در این پژوهش ما از شبکه عصبی بازگشتی المان استفاده کردیم و پارامترهای این شبکه را با توجه به نوع داده نوع مساله تنظیم کردیم. در این کار ما به پیش‌بینی کوتاه مدت در دو بازه زمانی هفتگی و ماهانه پرداختیم. معیار ارزیابی ما در این کار خطای RMSE برای پیش‌بینی بود که با توجه به نتایج بدست آمده در فصل چهارم روش پیشنهادی عملکرد بسیار بهتری نسبت به سایر روش‌ها داشته است که این مساله نشان از قدرت شبکه عصبی بازگشتی المان می‌باشد.

۵-۲- پیشنهادات

برای کارهای آینده می‌توان از پیشنهادات زیر استفاده کرد:

۱- استفاده از سایر شبکه‌های بازگشتی و تنظیم پارامترهای آنها مانند شبکه LSTM و یا GRN

۲- استفاده از روش‌های ترکیبی رگرسیون

۳- استفاده از اطلاعات جانبی مانند وضعیت آب و هوا برای پیش‌بینی بهتر

- [1] Wang, C.H.; Grozev, G.; Seo, S. Decomposition and statistical analysis for regional electricity demand forecasting. *Energy* 41, 313–325.2012
- [2] Chou, J.S.; Ngo, N.T. Time series analytics using sliding window metaheuristic optimization-based machine learning system for identifying building energy consumption patterns. *Appl. Energy* 177, 751–770.2016.
- [3] Hyndman, R.; Koehler, A.B.; Ord, J.K.; Snyder, R.D. *Forecasting with Exponential Smoothing: The State Space Approach*; Springer Science & Business Media: Berlin/Heidelberg, Germany, 2008.
- [4] Janacek, G. Time series analysis forecasting and control. *J. Time Ser. Anal.* 31, 229–303.2010.
- [5] Bontempi, G.; Taieb, S.B.; Le Borgne, Y.A. *Machine learning strategies for time series forecasting*. In European Business Intelligence Summer School; Springer: Berlin/Heidelberg, Germany, 62–77.2012.
- [6] Ahmed, N.K.; Atiya, A.F.; Gayar, N.E.; El-Shishiny, H. An empirical comparison of machine learning models for time series forecasting. *Econom. Rev.*29, 594–621.2010.
- [7] <http://www2.tavanir.org.ir/info/stat84/sanatfhtml/Load.htm>
- [8] Jingfei Yang, *Power System Short-term Load Forecasting*. Ph.D. thesis , Darmstadt University, Germany,2006.
- [9] O. Hyde, P.F. Hodnett., An Adaptable automated procedure for short-term electricity load forecasting, *IEEE Transactions on Power Systems*,.12, .84 – 93, 1997.
- [10] S. Ruzic, A. Vuckovic, N. Nikolic, Weather sensitive method for short-term load forecasting in electric power utility of Serbia, *IEEE Transactions on Power Systems*,.18,1586-1581. 2003.
- [11] Jie Wu, Jianzhou Wang , Haiyan Lu, Yao Dong, Xiaoxiao Lu., Short term load forecasting technique based on the seasonal exponential adjustment method and the regression model, *Energy Conversion and Management*,.70, 1–9 , 2013.
- [12] W. Charytoniuk, M.S. Chen, P.Van Olinda, Nonparametric regression based shortterm load forecasting, *IEEE Transactions on Power Systems*,13.725 – 730, 1998.
- [13] M.Y. Cho, J.C. Hwang, C.S. Chen., Customer short-term load forecasting by using ARIMA transfer function model, Proceedings of the International Conference on Energy Management and Power Delivery, *EMPD*,1,317 - 322,1995

- [14] H.T. Yang, C.M. Huang, C.L. Huang,. Identification of ARMAX model for short term load forecasting, An evolutionary programming approach, *IEEE Transactions on Power Systems*, 11,403 – 408, 1996. Germany, 2005
- [15] Jyi-Shing Roger Young,. ANFIS -adaptive-network-based fuzzy inference system, *IEEE Transactions on Systems, Man and Cybernetics*,23, 665 - 685.1993
- [16] S.J. Kiartzis, A. G. Bakirtzis,. *A Fuzzy expert system for peak load forecasting Application to the Greek power system*, 10th Mediterranean Electro technical Conference,1100-1097, 2000
- [17] V. Miranda, C. Monteiro,. Fuzzy inference in spatial load forecasting, *Power Engineering Winter Meeting*,2, 1063 – 1068 ,2000.
- [18] S.E. Skarman, M. Georgiopoulos,. *Short-term electrical load forecasting using a fuzzy ARTMAP neural network* , *Proceedings of the SPIE*,181 – 191, 1998.
- [19] K.L. Ho et al,Short-term load forecasting of Taiwan power system using a knowledge based expert system, *IEEE Transactions on Power Systems*,.5,.1214 - 1221, 1990.
- [20] S. Rahman, O. Hazim,. Load forecasting for multiple sites: development of an expert system-based technique, *Electric Power Systems Research*,39.161 - 169, 1996.
- [21] A.G.Bakirtzis, et al., A neural network short-term load forecasting model for the Greek power system, *IEEE Transactions on Power Systems*,11,858 – 863, 1996.
- [22] T.W.S. Chow, C.T. Leung, Nonlinear autoregressive integrated neural network model for short-term load forecasting, *IEE Proceedings, Generation, Transmission and Distribution*,143, 500 - 506, 1996.
- [23] A. Badri, Z. Ameli, A.Motie Birjandi, Application of Artificial Neural Networks and Fuzzy logic Methods for Short Term Load Forecasting, *2nd International Conference on Advances in Energy Engineering (ICAEE)*,14, ,1883–1888, 2012.
- [24] Y. He, et al. *Similar Day Selecting Based Neural Network Model and its Application in Short-Term Load Forecasting*, *Machine Learning and Cybernetics Proceedings of 2005 International Conference*, 4760 – 4763, 2005.
- [25] <http://en.wikipedia.org/wiki/Wavelet>
- [26] Y. Li, T. Fang,. *Wavelet and support vector machines for short – term electrical load forecasting* , *Proceedings of the International Conference on Wavelet Analysis and its Applications*,.399 - 404,2003.
- [27] Help Matlab. “*Neural Network Toolbox Design Book*”, H. Demuth, M. Beale, M. Hagan, Translator: Mostafa Kia.2010.

- [28] Zheng, J.; Xu, C.; Zhang, Z.; Li, X. *Electric load forecasting in smart grids using long-short-term-memory based recurrent neural network*. In Information Sciences and Systems (CISS). In Proceedings of the 51st Annual Conference, Baltimore, MD, USA, 22 March 2017; IEEE: Piscataway, NJ, USA, 1–6.2017.
- [29] Narayan, A.; Hipel, K.W. *Long short term memory networks for short-term electric load forecasting*. In Proceedings of the 2017 IEEE International Conference on Systems, Man, and Cybernetics (SMC) IEEE International Conference, Banff, AB, Canada, 5. 2573–2578.2017.
- [30] Marino, D.L.; Amarasinghe, K.; Manic, M. *Building energy load forecasting using deep neural networks*. In Proceedings of the IECON 2016-42nd Annual Conference of the IEEE Industrial Electronics Society, Florence, Italy, 23–26 October 2016; IEEE: Piscataway, NJ, USA, 7046–7051.2016.
- [31] Wang, J.; Jin, S.; Qin, S.; Jiang, H. *Swarm intelligence-based hybrid models for short-term power load prediction*. Math. Probl. Eng. 2014.
- [32] Ozerdem, O.C.; Olaniyi, E.O.; Oyedotun, O.K. Short term load forecasting using particle swarm optimization neural network. *Procedia Comput. Sci.*120, 382–393.2017.
- [33] Ren, G.; Wen, S.; Yan, Z.; Hu, R.; Zeng, Z.; Cao, Y. *Power load forecasting based on support vector machine and particle swarm optimization*. In Proceedings of the 2016 12th World Congress Intelligent Control and Automation (WCICA), Guilin, China, 12–15 June 2016; IEEE: Piscataway, NJ, USA, 2003–2008.2016.
- [34] Islam, B.U.; Baharudin, Z.; Raza, M.Q.; Nallagownden, P. *Optimization of neural network architecture using genetic algorithm for load forecasting*. In Proceedings of the 2014 5th IEEE International Conference Intelligent and Advanced Systems (ICIAS), Kuala Lumpur, Malaysia, 1–6.2014.
- [35] Defilippo, S.B.; Neto, G.G.; Hippert, H.S. *Short-term load forecasting by artificial neural networks specified by genetic algorithms—a simulation study over a Brazilian dataset*. In Proceedings of the XIII Simposio Argentino de Investigación Operativa (SIO)—JAIIO 44, Rosario, Santa Fe, 2015.
- [36] Srivastava, S.; Lessmann, S. A comparative study of, L.STM neural networks in forecasting day-ahead global horizontal irradiance with satellite data. *Sol. Energy* 162, 232–247.2018.
- [37] Lago, J.; De Ridder, F.; De Schutter, B. Forecasting spot electricity prices: Deep learning approaches and empirical comparison of traditional algorithms. *Appl. Energy* 221, 386–405. 2018.

- [38] Bandara, K.; Bergmeir, C.; Smyl, S. *Forecasting Across Time Series Databases using Long Short-Term Memory Networks on Groups of Similar Series*. arXiv, arXiv:1710.03222.2017.
- [39] Xiao, Y.; Yin, Y.; Hybrid, L. STM Neural Network for Short-Term Traffic Flow Prediction. *Information*, 10, 105.2019.
- [40] Roman, R.C.; Precup, R.E.; David, R.C. Second order intelligent proportional-integral fuzzy control of twin rotor aerodynamic systems. *Procedia Comput. Sci.* 139, 372–380.2018.
- [41] Mahanipour, A.; Nezamabadi-Pour, H. GSP: An automatic programming technique with gravitational search algorithm. *Appl. Intell.* 49, 1502–1516.2019.
- [42] Liu, Y.; Guan, L.; Hou, C.; Han, H.; Liu, Z.; Sun, Y.; Zheng, M. Wind Power Short Term Prediction Based on, L.STM and Discrete Wavelet Transform. *Appl. Sci.* 9, 1108.2019.
- [43] S. Bouktif, A. Fiaz, A. Ouni, M. A. Serhani, “Multi-Sequence LSTM-RNN Deep Learning and Metaheuristics for Electric Load Forecasting”, *Energies*, 13, 391; 2020.

Abstract

In today's world, almost all work will be disrupted without electricity consumption. From large factories and power plants to the smallest appliances in a kitchen, it depends on electricity consumption. Therefore, it is very vital to have an accurate plan and vision of the amount of electricity consumption in any country. The amount of electric load consumption is a set of time series data related to different periods of electricity use. These intervals range from short-term periods such as hourly or daily periods to long-term periods such as yearly. In order to accurately plan electric load consumption, it should be possible to predict the amount of load consumption in the future according to past data. In this thesis, we have used the artificial intelligence method to predict the electric load in short-term weekly and monthly intervals. Our innovation in this work is the use of ELMAN Network. Element Neural Network (ENN) is one of the Recurrent Neural Networks (RNN), which has a new layer called background layer compared to traditional neural networks, and its inputs are more than conventional neural networks. ENN is very suitable for solving discrete time series forecasting problems. The parameters of the proposed network are adjusted according to the data and forecast period. Finally, the prediction error using the proposed method has been reduced compared to other reference article methods that are based on the LSTM network, so that the RMSE value for the reference article method and our proposed method is 311.44 and 239.74, respectively.

Keywords: Electric Load Consumption; Prediction; Neural Network; Element Network.



Imam Reza International University

MS Thesis

Faculty of Engineering

Department of Electrical Engineering

Mechatronics

**Electric Load Forecasting Using the ELMAN Neural
Network**

Supervisor:

Dr. Mojtabi Behnam Taghdasi

By:

Zinah Nazar Abdulrazzaq Nuaimi

Summer 2022

