

کاربرد مدل‌های یادگیری عمیق در پیش‌بینی سری‌های زمانی اقتصادی - اجتماعی مورد کاوی: سری زمانی اوج بار مصرفی خانگی

نجمه نشاط* (استادیار)

گروه مهندسی صنایع (سیستم‌ها)، دانشگاه مپد

محسن سرداری زارچی (استادیار)

گروه مهندسی کامپیوتر، دانشگاه مپد

هاشم محلوچی (استاد)

دانشکده مهندسی صنایع، دانشگاه صنعتی شریف

مهندسی صنایع و مدیریت شریف، تابستان ۱۳۹۹ (۱۳۹۹-۱۳۶-۱) شماره ۱/۲، صص ۱۱۱-۱۰۳

این مطالعه به بررسی کارایی پیکره‌بندی مختلف شبکه‌های یادگیری عمیق (رویکرد برتر در مدل‌سازی و تخمین سری‌های زمانی اقتصادی - اجتماعی) در حوزه‌ی پیش‌بینی می‌پردازد. در این مطالعه به منظور ملموس‌سازی رویکرد پیشنهادی از مدل‌سازی و پیش‌بینی اوج بار مصرفی خانگی در قالب موردکاوی استفاده شده است. نتایج حاکی از برتری توپولوژی شبکه ترکیبی از تمام متصل و بازگشتی بود که این برتری با توجه به ماهیت غیرخطی و پیچیده، وابستگی‌های قوی به داده‌های دوره‌های قبلی و همچنین وجود درجات متفاوتی از تأخیر در متغیرهای برون‌زای مسئله کاملاً توجیه‌پذیر است. نظر به این‌که در این مدل متغیرهای برون‌زای مدل (نماینده‌ی شرایط مختلف جوی) و متغیرهای مصنوعی (نماینده‌ی شرایط مختلف زمانی) نیز لحاظ شده است، از استواری قابل قبولی نسبت به مدل‌های ارائه شده در مطالعات قبلی برخوردار است.

واژگان کلیدی: شبکه‌های عصبی عمیق، پیش‌بینی، شبکه‌های تمام‌متصل، مدل عمیق ترکیبی، بار اوج مصرفی.

۱. مقدمه

طی سه دهه‌ی گذشته، برنامه‌ریزی سیستم‌های انرژی نقش مهمی را در سیاست‌گذاری بلندمدت اجتماعی و اقتصادی ایفا کرده است. از دیدگاه اقتصادی، انرژی یکی از عوامل تولید برای توسعه‌ی جوامع حیاتی است و عرضه و تقاضای آن برای امنیت ملی و تولید اقتصادی هر کشوری بسیار مهم است. سیستم‌های انرژی جزء جدایی‌ناپذیر سیستم‌های اجتماعی - اقتصادی جوامع هستند و برهم‌کنش‌های دوسویه‌ی متعددی با اقتصاد، جامعه و محیط زیست دارند. برای نمونه تقابلات انرژی - اقتصاد شامل موارد زیر است:

--- تغییرات در انعطاف‌پذیری قیمت و تقاضای انرژی و همچنین تأثیر فعالیت کلان اقتصادی بر تقاضای انرژی در طول زمان؛

--- تأثیرات هزینه‌ی انرژی بر بهره‌وری نیروی کار، شکل‌گیری سرمایه، مصرف انرژی و در نتیجه رشد اقتصادی در طولانی مدت؛

* نویسنده مسئول

تاریخ: دریافت ۱۳۹۸/۶/۵، اصلاحیه ۱۳۹۸/۹/۱۹، پذیرش ۱۳۹۸/۱۰/۴.

DOI:10.24200.J65.2019.54014.2029

neshat@meybod.ac.ir
sardari@meybod.ac.ir
mahlooji@sharif.edu

--- تأثیرات سیاست انرژی بر پدیده‌های محیط زیستی مانند تغییرات اقلیمی، موجودی منابع، زیست‌بوم و سلامت انسان؛

--- تأثیر سیاست بلندمدت انرژی بر رفاه و تساوی حقوق (برای مثال از طریق تغییر الگوهای اشتغال) که همچنین می‌تواند به عنوان تعاملات انرژی - اجتماع معرفی شود.

با توسعه‌ی سریع اجتماعی - اقتصادی و رشد جمعیت، برنامه‌ریزی سیستم‌های انرژی با چالش‌های بزرگی مواجه شده است. فقدان سوخت‌های فسیلی و آلودگی‌های محیط زیست مرتبط با توسعه‌ی انرژی از مسائل دشوار به حساب می‌آیند و تولید و مصرف سوخت فسیلی در گرم شدن جهانی و باران‌های اسیدی نقش دارد. بنابراین، یک راه حل برای حفظ محیط زیست مدیریت مصرف انرژی در بخش‌های مختلف مصرف است. در این راستا یکی از گام‌های مؤثر پیش‌بینی دقیق میزان مصرف و برنامه‌ریزی برای تولید مطابق با آن است. این موضوع به توازن بین تأمین انرژی و بخش‌های مصرف کمک می‌کند، منابع انرژی و فناوری‌ها را در چارچوبی کلی یکپارچه می‌کند، از اقتصاد و محیط زیست و توسعه‌ی سیاسی پایدار حمایت می‌کند،

و سیستمی برای پشتیبانی تصمیم‌گیری برای سیاست‌گذاران ایجاد می‌کند.

مطالعات قبلی حاکی از آن است که بیشترین سهم در مصرف انرژی را بخش خانگی به خود اختصاص داده است و از جمله مقولاتی است که توسط دانشگاهیان و مدیران عملیاتی مورد اقبال و توجه خاص قرار گرفته است.^[۱] با توجه به این که هدف اصلی شبکه‌های توزیع برق پاسخ‌گویی به تقاضای بار خانگی با کیفیت مطلوب است و از سویی بار سیستم پارامتری است که تقریباً تمام عملکرد سیستم را تحت تأثیر خود قرار می‌دهد، برنامه‌ریزان سیستم در همان مراحل اولیه باید تا آنجا که روش‌ها و ابزارهای کمی به آنها امکان می‌دهد، به مقدار واقعی این کمیت نزدیک شوند و بر اساس آخرین و دقیق‌ترین نتایج، کار برنامه‌ریزی شبکه‌ی توزیع را آغاز کنند. پیش‌بینی صحیح بار علاوه بر صرفه‌جویی در هزینه‌های سرمایه‌گذاری، امکان برنامه‌ریزی بهتر برای توسعه‌ی نیروگاه‌ها و شبکه‌های انتقال و توزیع را فراهم می‌آورد. یکی از مسائل حائز اهمیت در بهره‌برداری و توسعه‌ی بهینه‌ی شبکه‌های برق، اطلاع از رشد بار و تقاضای برق در سال‌های آینده است. متأسفانه در بخش توزیع به دلیل طراحی‌های غیرمهندسی و عدم آینده‌نگری در سطوح بالای کاری شاهد مشکلات زیادی از جمله تلفات و افت ولتاژ هستیم که سرچشمه‌ی این مشکلات عدم وجود برنامه برای پیش‌بینی نیازهای آینده‌ی شبکه است. چه بسا شبکه‌هایی که بدون در نظر گرفتن پارامترهای آینده‌نگری طراحی شده‌اند و با گذشت زمان و رشد بار کارایی لازم را نداشته‌اند و تلفات و افت ولتاژ در آنها به شدت افزایش یافته است که این خود باعث افزایش سرمایه‌گذاری (افزایش هزینه‌ی تولید انرژی تلف شده و هزینه‌ی مربوط به افزایش ظرفیت سیستم‌های تولید، انتقال و توزیع انرژی الکتریکی برای تأمین تلفات) می‌شود. اولین قدم در انجام یک طرح بهینه‌سازی شبکه‌ی توزیع، پیش‌بینی دقیق بار مصرفی روزانه است.

در این مطالعه، به منظور ملموس‌سازی مراحل مدل‌سازی و پیاده‌سازی و همچنین اثبات عملی قابلیت مدل پیشنهادی از موردکامی در حوزه‌ی بار مصرفی خانوار استفاده شده است. در پیشینه رویکردهای مختلفی از آماری تا هوش محاسباتی برای پاسخ دادن به مسائل پیش‌بینی بار مصرفی پیشنهاد شده است. در یک دسته‌بندی کلی می‌توان تمام این روش‌های مورد استفاده در حوزه‌ی پیش‌بینی بار مصرفی را به دو دسته‌ی کلی روش‌های انفرادی^۱ و ادغامی^۲ تقسیم کرد. روش‌های انفرادی خود نیز به سه دسته‌ی آماری^۳، علی معلولی^۴ و هوش محاسباتی^۵ تقسیم می‌شوند. روش‌های آماری قادرند تا روابط پویای بین مقادیر قبلی مصرف و مقدار مصرف پیش‌بینی شده را مدل کنند: این مدل‌ها عبارت‌اند از:

مدل‌های (AR)^{[۲]۶}، (DSHW)^{[۳]۷}، (ARX)^۸، (TARX)^{[۴]۹}، (GARCH)^{[۷]۱۰}، (ARIMA)^{[۶]۱۱}، (SN)^{[۹]۱۲}؛^{[۱۱]۱۰} (SARIMA)^{[۱۳]۱۳}؛ مدل‌های (TF)^{[۱۴]۱۴}

مدل‌های ترکیبی که از ادغام دو یا چند رویکرد نتیجه می‌شوند انواع مختلفی از جمله مدل‌های wavelet-based دارند که در مطالعاتی که توسط کونجو و همکاران^[۱۵] و همچنین تان و همکاران^[۱۶] و یانگ و همکاران^[۱۷] انجام شده است، به آنها اشاره شده است.

رویکردهای علی معلولی بر مدل‌سازی روابط پویا بین رگرسورهای علی معلولی و مقادیر پیش‌بینی شده‌ی مصرف تمرکز دارند. مدل‌های علی معلولی مبتنی بر روش‌های برازش بر اساس حداقل مربعات به منظور پیش‌بینی مقادیر بار مصرفی بر حسب رگرسورها (از جمله دما و میزان رطوبت و غیره) هستند. انواع مختلف مدل‌های علی معلولی عبارت‌اند از Non-linear regression (NLR)^[۲۱-۱۸] Logit Logistic regression (LoR) /^[۲۲] که بیشترین فزوانی در به‌کارگیری را در این دسته به خود اختصاص داده‌اند.

اغلب مسائلی که در سیستم‌های اقتصادی - اجتماعی وجود دارند، همانند مسائل پیش‌بینی بار مصرفی دارای ماهیت غیرخطی‌اند و یکی از ضعف‌های این رویکردها آن است که فقط قادر به مدل کردن رفتار خطی‌اند. در شرایطی که الگوهای قوی از وابستگی به مقادیر قبلی در داده‌ها وجود داشته باشند یا روابط بین رگرسورها و مقدار هدف غیرخطی باشند، این رویکردها کارآمدی خود را از دست خواهند داد. همچنین این رویکردها غالباً نتایج قابل قبولی در پیش‌بینی کوتاه‌مدت و میان‌مدت کسب می‌کنند و ناتوان از پیش‌بینی بلندمدت خواهند بود. البته نباید نادیده گرفت که منطق شفاف و ماهیت جعبه سفید بودن آنها ممکن است در برخی موارد مورد توجه و اولویت قرار گیرد.

روش‌های هوش محاسباتی از قبیل شبکه‌های عصبی مصنوعی (ANN)^{۱۵} و روش ماشین بردار پشتیبان (SVM)^{۱۶} در این حوزه‌ی تحقیقاتی به دلیل ماهیت غیرخطی و همچنین توانایی استخراج ویژگی‌های نهفته در داده‌ها به کرات مورد استفاده قرار گرفته‌اند. اکنون برای پیش‌بینی مصرف انرژی در یک کشور از شبکه‌های عصبی مصنوعی استفاده کرد. در این مطالعه یک مدل چندلایه‌ی پرسپترون بر حسب چهار مؤلفه‌ی شرایط جوی، داده‌های قبلی (تأخیری)، مقدار شاخص تولید ناخالص داخلی و ظرفیت تولید توسعه داده شد.^[۲۳]

نتایج مقایسه‌ی به دست آمده از داده‌های سال‌های ۱۲ تا ۱۶ تا ۲۰ نشان داد که مدل شبکه‌ی عصبی مصنوعی نسبت به مدل رگرسیون خطی و ماشین بردار پشتیبان بهتر عمل می‌کند. در سال ۲۰۱۴ کیلاشاک و همکارانش تقاضای انرژی را برای بخش صنعتی بر حسب مؤلفه‌هایی چون قیمت حامل‌های انرژی و تولید ناخالص داخلی با استفاده از مدل‌های شبکه‌ی عصبی مصنوعی و مدل رگرسیونی انجام دادند. نتایج تجربی نشان از برتری مدل شبکه‌ی عصبی مصنوعی بر مدل رگرسیونی با توجه به شاخص‌های صحت و دقت تخمین داشت.^[۲۴] عابدینی و همکاران شبکه‌ی عصبی مجهز به جستجوی احتمالی را به منظور بهینه‌سازی پارامترهای مدل پیشنهاد دادند و نتایج پیش‌بینی را با نتایج شبکه‌ی پرسپترون چندلایه و شبکه‌های echo-state و شبکه wavelet transform مقایسه کردند.^[۲۵] مطالعه‌ی مشابهی توسط گاجونیکرک و همکاران در سال ۲۰۱۷ انجام شد. نتایج در هر دو مطالعه برتری شبکه‌ی عصبی مجهز به جستجوی احتمالی را نسبت به روش‌های دیگر مذکور نشان دادند.^[۲۶]

اخیراً حل مسائل پیش‌بینی تقاضا با استفاده از مدل‌های یادگیری عمیق مورد توجه خاص قرار گرفته است. روش‌های یادگیری عمیق عموماً در بستر شبکه‌های عصبی عمیق شکل می‌گیرند. شبکه‌های عصبی عمیق در مقایسه با شبکه‌های عصبی ANNs، دارای تعداد لایه‌های بیشتر، توابع فعال‌سازی متفاوت و همچنین روش‌های آموزش کارآمدتری‌اند؛ از جمله متداول‌ترین آنها شبکه‌های عصبی عمیق پیچشی، تمام‌متصل و برگشتی هستند. در حوزه‌ی پیش‌بینی تقاضای بار، ون و همکاران یک مدل جدید یادگیری عمیق را برای پیش‌بینی کوتاه‌مدت تقاضای پیش‌بینی کردند. شبکه‌های عصبی همگشتی (CNN)^{۱۷} برای استخراج مؤلفه‌هایی که دارای الگوهای تاریخی بودند، استفاده شدند.^[۲۷] شی و همکاران یک رویکرد یادگیری عمیق برای پیش‌بینی تقاضای برق در دو سطح ادغامی منطقه‌ی و سطح غیرادغامی خانگی پیشنهاد دادند. بر اساس نتایج تجربی، شبکه‌های عصبی بازگشتی (RNN)^{۱۸} بهتر از مدل‌های شبکه‌ی عصبی مستقیم برای پیش‌بینی کوتاه‌مدت عمل کردند.^[۲۸] علاوه بر آن، رحمان و همکاران یک شبکه‌ی RNN برای پیش‌بینی تقاضای برق خانگی و ساختمان‌های تجاری پیشنهاد دادند.^[۲۹] کونگ و همکاران یک مدل مبتنی بر یادگیری عمیق با اعمال اثرات مصرف وسایل خانگی برای پیش‌بینی مصرف کوتاه‌مدت ارائه دادند. نتایج حاکی از آن بود که مصرف شدیداً به رفتار خانوارها

جَوّی و الگوهای مصرف، وابسته است. شرایط جَوّی شامل دما، ایزولگی نور خورشید، رطوبت و سرعت باد در جهت‌های مختلف است.^[۳۲] به دلیل ماهیت همبستگی داده‌های بار مصرفی خانوارها به لحاظ زمانی، لازم است تا در پیش‌بینی میزان مصرف، متغیرهای برون‌زا (شرایط جَوّی و غیره) و همچنین اطلاعات قبلی میزان مصرف (داده‌های تأخیردار) در پیش‌بینی لحاظ شوند.


از آن‌جا که در این پژوهش سعی شده است تا توپولوژی‌های مختلف مدل‌های یادگیری عمیق (انفرادی) ارائه و بررسی شود، در ادامه مهم‌ترین مدل‌های شبکه‌های عصبی عمیق به اختصار معرفی می‌شوند و سپس مدل‌های ادغامی پیشنهاد می‌شوند؛ در ادامه به تشریح این مدل‌ها پرداخته می‌شود.

۱.۲. شبکه‌های عصبی عمیق تمام متصل

شبکه‌های عصبی عمیق تمام متصل یا مترانک ۲۱ به شبکه‌های پیش‌بینی ۲۲ گفته می‌شود که در آن نرون‌های هر لایه مستقیماً به تمام نرون‌های لایه‌ی بعدی وصل‌اند. این نوع شبکه، از جمله پرکاربردترین شبکه‌های عصبی در حوزه‌ی یادگیری عمیق است. هر چند شبکه‌های عصبی عمیق تمام متصل از لحاظ توپولوژی بسیار شبیه شبکه‌های عصبی سنتی مانند مدل‌های چندلایه‌ی پرسپترون هستند، بر خلاف شبکه‌های سنتی، این قابلیت را دارند که تعداد لایه‌های پنهان بیشتری داشته باشند. افزایش لایه‌های پنهان در شبکه‌های سنتی باعث به وجود آمدن مشکلاتی همچون حفظ الگو و ناپدید شدن گرادیان^[۲۳] در طول آموزش می‌شود؛ اما در شبکه‌های عصبی عمیق با تغییر توابع فعال‌سازی و استفاده از روش‌هایی مانند نمونه‌های بیرونی^[۲۴] این مشکلات تا حدودی حل شده است. نمونه‌ی از شکل شبکه‌ی عصبی تمام‌متصل عمیق در شکل ۱ نمایش داده شده است.

۲.۲. شبکه‌های عصبی عمیق بازگشتی

شبکه‌های عصبی عمیق بازگشتی از مهم‌ترین مدل‌های مورد استفاده برای پیش‌بینی سری‌های زمانی یا الگوهای مبتنی بر گذشته‌اند. وجه مشخصه‌ی مدل‌های عصبی عمیق بازگشتی آن است که قادرند تا الگوهای وابستگی (تأخیردار)^[۲۵] را از طریق سازوکار بازگشتی خود در نظر بگیرند. در این دسته از مدل‌ها دانش جمعی از دوره‌های قبلی به استفاده از چرخه‌ها به دوره‌های بعد منتقل می‌شود و برای پیش‌بینی دوره‌های بعدی استفاده می‌شود. همان‌طور که در شکل ۲ دیده می‌شود t input بیان‌گر مقادیر ورودی و t State بیان‌گر وضعیت در بازه‌ی زمانی t است Output



شکل ۱. طرح‌واره‌ی از توپولوژی شبکه‌ی عصبی تمام‌متصل عمیق.

بستگی دارد. همچنین مدل‌های RNN هر چند که در مقایسه با مدل‌های پرسپترون عملکرد بهتری برای پیش‌بینی نشان داده‌اند، اما ناتوان از مدل کردن وابستگی طولانی مدت (تأخیردار) بین داده‌ها به دلیل مشکل بیش‌برازش^[۲۶] هستند.

اخیراً بدی و توشنیوال یک مدل شبکه‌ی عصبی بازگشتی و یک مدل ماشین بردار پشتیبان برای پیش‌بینی میزان بار مصرفی یکی از مناطق هند پیشنهاد دادند.^[۲۷] در این مطالعه، نویسندگان سعی کرده‌اند تا به منظور اعمال پویایی‌های موجود در مدل، داده‌ها را خوشه‌بندی کنند و به تفکیک هر خوشه، مدل منحصر به فردی توسعه دهند. نتایج مورد کاوی حاکی از آن مطلب بود که مدل یادگیری عمیق در حد معناداری بهتر از شبکه‌ی عصبی ساده‌ی بازگشتی و ماشین بردار پشتیبان برای پیش‌بینی کوتاه مدت میزان مصرف بار عمل خواهد کرد.

۱.۱. تعریف مسئله و شکاف تحقیقاتی

بدون شک آن‌چه در هر مسئله‌ی پیش‌بینی معیار و هدف قرار می‌گیرد، دقت و صحت پیش‌بینی است. یکی از به‌روزترین مطالعات در حوزه‌ی پیش‌بینی بار مصرفی (در زمان انجام تحقیق) توسعه‌ی یک مدل شبکه‌ی عصبی بازگشتی توسط بدی و توشنیوال بود.^[۲۸] در این مطالعه پیشنهاد شد تا برای بهبود دقت پیش‌بینی در تحقیقات آتی اثر متغیرهای غیرخطی و خطی برون‌زای مدل مثل شرایط جَوّی در مدل یادگیری عمیق لحاظ شود. یکی از ضعف‌های این مقاله استفاده از خوشه‌بندی برای توسعه‌ی مدل‌های «متعددی» از یادگیری عمیق برای پوشش تمام شرایط پیش‌بینی مثل فصول مختلف و روزهای مختلف هفته است؛ به طوری که هر مدل فقط می‌تواند برای شرایطی خاص و تعریف شده مورد استفاده قرار گیرد.

در این تحقیق، با در نظر گرفتن قابلیت بالای شبکه‌های عصبی یادگیری عمیق در پیش‌بینی بار، مدل‌های ترکیبی از توپولوژی‌های مختلف شبکه‌های عصبی عمیق بررسی می‌شود تا مدل دقیق‌تر برای پیش‌بینی بار مصرفی خانوارها ارائه شود. این مدل‌های ترکیبی ۱. به دلیل قابلیت بالای برازش قادرند روابط غیرخطی پیچیده‌ی موجود در مسئله را مدل کنند؛ ۲. برخلاف مدل‌های عصبی مصنوعی معمولی به دلیل داشتن لایه‌های مختلف بیشتر و استفاده از بازخورد،^[۲۹] قادرند تا الگوهای تأخیردار طولانی مدت را در مدل لحاظ کنند و همچنین؛ ۳. به منظور افزایش استواری مدل‌های پیشنهادی، متغیرهای برون‌زای مدل (نماینده شرایط مختلف جَوّی) و متغیرهای دامی (بیان‌گر شرایط مختلف زمانی) نیز در توسعه‌ی آنها لحاظ شده‌اند. بنابراین، سؤالات اصلی تحقیق عبارت‌اند از:

آیا به‌کارگیری متغیرهای مؤثر برون‌زا در مدل‌های اتورگرسیو می‌تواند در افزایش قدرت پیش‌بینی آنها نقش داشته باشد؟


میزان کارایی هر کدام از توپولوژی‌های مدل‌های شبکه‌ی عصبی عمیق در پیش‌بینی بار مصرفی کدام است؟

آیا تفکیک متغیرهای مؤثر برون‌زا با الگوهای وابستگی (تأخیردار) متفاوت و مدل‌سازی آنها به صورت شبکه‌های موازی در قالب یک مدل ترکیبی می‌تواند منجر به افزایش قدرت پیش‌بینی شود؟

۲. مدل‌های شبکه‌ی عصبی عمیق برای پیش‌بینی بار

مصرفی:

طبق مطالعات قبلی میزان مصرف کوتاه‌مدت برق خانگی به عواملی چون شرایط جَوّی، الگوهای مصرف روزانه و ماهانه‌ی مصرف‌کنندگان و اثرات تعاملی بین شرایط



شکل ۴. طرح‌واره‌ی از سازوکار فیلترسازی تک بعدی که هر ۵ داده‌ی متوالی به یک داده‌ی جدید تبدیل می‌شود.

مدل‌های GRU سبب شده است تا آموزش در این مدل‌ها سریع‌تر اتفاق بیفتد. به صورت یک اصل کلی، هر کجا نیاز به مدل پیچیده‌تر داشته باشیم، از LSTM و هر کجا به مدل سریع‌تر نیاز داشته باشیم از GRU استفاده می‌کنیم.

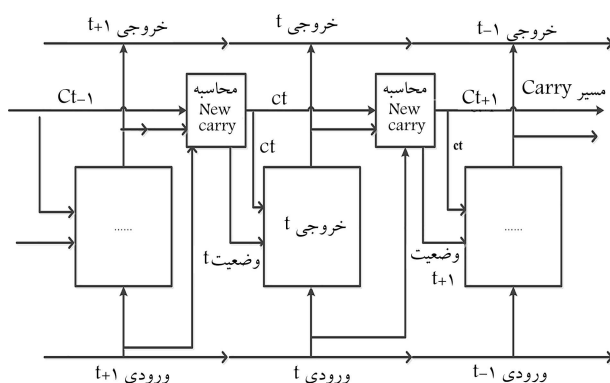
۳.۲. شبکه‌های عصبی عمیق کانولوشنال (CNN) ۲۹

ایده‌ی استفاده از مدل‌های CNN ابتدا برای پردازش تصویر مطرح شد. در این حالت با کانوالو^{۳۰} کردن یک فیلتر دوبعدی بر روی تصویر، یک سری از اطلاعات خاص از تصویر استخراج می‌شود که بعداً این اطلاعات توسط لایه‌های بعدی پردازش می‌شوند. به همین ترتیب از فیلترهای یک بعدی یا چندبعدی نیز می‌توان استفاده کرد تا داده‌ها یا سری‌های زمانی به غیر از تصویر را پردازش و سپس خروجی را مدل کرد. مثلاً در شکل ۴ با اعمال یک فیلتر یک بعدی بر روی داده‌ی ورودی، هر ۵ داده‌ی متوالی به یک داده‌ی جدید تبدیل می‌شود. برای نمونه، ساده‌ترین فیلتر ممکن است که یک فیلتر میانگین‌گیر باشد که میانگین هر ۵ عدد متوالی را محاسبه می‌کند. نکته‌ی مهم در شبکه‌های CNN این است که مقدار فیلتر یا به عبارتی نوع فیلتر، در آموزش توسط خود سیستم شبکه‌ی عصبی آموزش دیده می‌شود.

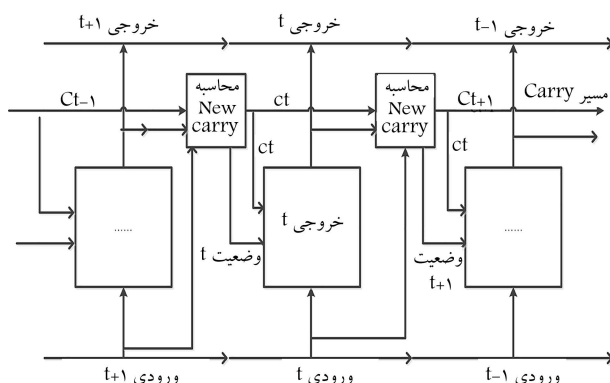
۴.۲. مدل پیشنهادی

با مراجعه به پیشینه‌ی پژوهش مدل‌های یادگیری عمیق در حوزه‌ی پیش‌بینی سری‌های زمانی می‌توان به وضوح به برتری مدل‌های یادگیری عمیق ترکیبی در پیش‌بینی سری‌های زمانی نسبت به مدل‌های ساده پی برد. در این پژوهش با توجه به قابلیت‌های شبکه‌های بازگشتی عمیق و شبکه‌های تمام متصل عمیق، یک مدل با ادغام این دو شبکه‌ی عمیق طراحی، پیاده‌سازی و بررسی شده است. مدل ادغامی پیشنهادی، به دلیل داشتن قابلیت‌هایی چون حافظه‌ی بلندمدت برحسب میزان تأخیر در هر کدام از متغیرهای برون‌زا و همچنین تعداد لایه‌های بیشتر و کاملاً متصل قابلیت بارز بهتری از خود نشان می‌دهند. از این رو برای پیش‌بینی بار مصرفی، توپولوژی‌های مختلف شبکه‌های یادگیری عمیق و همچنین ترکیبی از آنها بررسی شده است. ورودی‌ها به این مدل شامل داده‌های بار مصرفی گذشته، متغیرهای برون‌زا (بیان‌گر شرایط جوّی) و متغیرهای مصنوعی (بیان‌گر شرایط زمانی داده‌های مورد استفاده) می‌باشد. در شکل ۵ نمای کلی مدل ترکیبی نمایش داده شده است.

مدل ترکیبی پیشنهادی، از شبکه‌های عصبی عمیق بازگشتی برای مدل کردن سوابق داده‌ها و از شبکه‌های عصبی عمیق تمام‌متصل برای ایجاد مدل غیرخطی بهره می‌برد. در مدل ادغامی، تمام متغیرهایی که به نوعی وابسته به داده‌های زمان



شکل ۲. طرح‌واره‌ی از سازوکار محاسبه‌ی خروجی در یک شبکه‌ی بازگشتی ساده (RNN).



شکل ۳. طرح‌واره‌ی از سازوکار محاسبه‌ی خروجی در یک شبکه‌ی بازگشتی LSTM.

مقدار خروجی در بازه‌ی زمانی t را نشان می‌دهد. وضعیت موجود t State بر اساس مقدار ورودی t و وضعیت قبلی $t-1$ State تعیین می‌شود. به بیان ریاضی این سازوکار طبق رابطه‌ی ۱ و شکل ۲ انجام می‌گیرد:

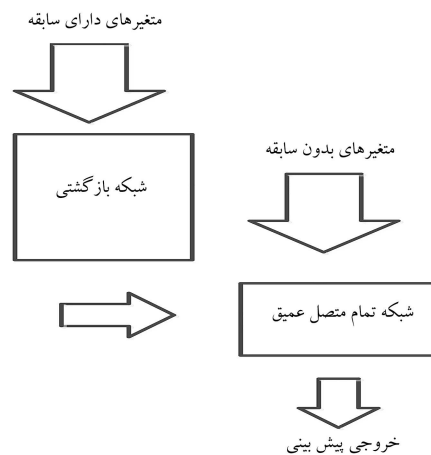
$$output_t = f_{\theta}(W \times input_t + U \times state_t + b_o) \quad (1)$$

از آن‌جا که مدل‌های RNN مجهز به سازوکار بازگشتی‌اند، قادرند تا وابستگی‌های تأخیردار کوتاه‌مدت را مدیریت و در مدل پیش‌بینی لحاظ کنند؛ اما چنان‌چه این وابستگی‌ها دارای تأخیر طولانی مدت باشند، این قابلیت بسیار کم‌رنگ خواهد شد.^[۳۳] به منظور مقابله با این ضعف، مدل‌های یادگیری عمیق حافظه‌ی طولانی کوتاه‌مدت LSTM^{۲۶} طراحی و اخیراً مورد استفاده‌ی گسترده قرار گرفته‌اند. در این مدل‌ها نگاشت‌های تکمیلی از ورودی‌ها به منظور بهره‌گیری از اطلاعات مورد نیاز ورودی‌های قبلی (تأخیردار) اتفاق می‌افتد. این ویژگی یکی از ضروریات در مدل‌سازی سری‌های زمانی اقتصادی - اجتماعی و پیش‌بینی آنها از جمله پیش‌بینی بار مصرفی است (مطابق شکل ۳).

معماری مدل‌های LSTM شبیه همان ساختار مدل‌های پرسپترون معمولی است که شامل یک سلول حافظه و سه گذرگاه ورودی، خروجی و فراموشی^{۲۷} است. این گذرگاه‌ها وظیفه‌ی مدیریت جریان را در سراسر شبکه به عهده دارند. سلول‌های حافظه مجهز به واحد ثبت خطای ثابت برای جبران نقص حافظه‌ی کوتاه مدت در شرایطی‌اند که تأخیرها طولانی مدت باشند. نوع دیگری از شبکه‌های عصبی بازگشتی، مدل‌های یادگیری بازگشتی دروازه‌ی (GRU)^{۲۸} هستند که سازوکاری کاملاً شبیه به مدل‌های LSTM دارند، با این تفاوت که ساختار تا حدی ساده‌تر

جدول ۱. اطلاعات آماری متغیرهای برونزا و بار «روزانه‌ی» مدل.

ردیف	نام متغیر	مقدار کمینه	مقدار بیشینه	مقدار متوسط
۱	دمای کمینه	-۱۸٫۴۰	۲۱٫۸۰	۳٫۶
۲	دمای بیشینه	-۲٫۰۰	۳۷٫۴۰	۲۲٫۲۷
۳	رطوبت کمینه	-۱٫۷۰	۹۹٫۰۰	۱۹٫۲۳
۴	رطوبت بیشینه	۴٫۰۰	۱۰۰٫۰۰	۶۴٫۱۹
۵	متوسط رطوبت	۵٫۰۰	۹۵٫۰۰	۴۱٫۴۷
۶	بارندگی	۰٫۰۰	۴۲٫۶۰	۰٫۶۲
۷	بارش برف	۰٫۰۰	۳۴٫۸۰	۰٫۱۳
۸	بارش برف تجمعی	۰٫۰۰	۴۲٫۶۰	۰٫۷۵
۹	ارتفاع برف	۰٫۰۰	۱۱٫۳۰	۰٫۰۵
۱۰	جهت باد (۰۳)	۰٫۰۰	۳۶۰٫۰۰	۲۰۶٫۲۰
۱۱	سرعت باد (۰۳)	۰٫۰۰	۱۳٫۰۰	۱٫۸۱
۱۲	جهت باد (۰۹)	۰٫۰۰	۳۶۰٫۰۰	۱۸۴٫۴۳
۱۳	سرعت باد (۰۹)	۰٫۰۰	۱۶٫۰۰	۴٫۰۲
۱۴	جهت باد (۱۵)	۰٫۰۰	۳۲۰٫۰۰	۲۰۷٫۱۴
۱۵	سرعت باد (۱۵)	۰٫۰۰	۱۸٫۰۰	۴٫۰۰
۱۶	بیشینه‌ی جهت باد	۴٫۰۰	۳۹۰٫۰۰	۲۰۵٫۸۶
۱۷	بیشینه‌ی سرعت باد	۱٫۰۰	۳۵٫۰۰	۱۰٫۴۰
۱۸	میزان بار مصرفی	۸۴٫۰۰	۳۵۵٫۸۹	۲۱۲٫۸۱
۱۹	میزان اوج	۱۶۱٫۶۴	۳۵۵٫۸۹	۲۶۲٫۶۰



شکل ۵. طرح‌واره‌ی کلی مدل ترکیبی عمیق از شبکه‌های عصبی بازگشتی و تمام‌متصل.

قبل هستند، در ابتدا با شبکه‌ی عصبی بازگشتی پردازش می‌شوند و سپس خروجی آن به همراه متغیرهای غیروابسته به داده‌های گذشته به یک شبکه‌ی عصبی عمیق تمام متصل وارد می‌شوند. در پایان، خروجی شبکه‌ی عصبی تمام متصل مقدار پیش‌بینی بار اوج خانگی است.

۳. مطالعه‌ی موردی

در این بخش مدل‌های مختلف یادگیری عمیق در پیش‌بینی مقدار بار مصرف خانگی بررسی شده است. در این بررسی از مقادیر بار مصرفی ساعتی شهر شهکرد به عنوان داده‌های مسئله استفاده شده است. برای پیاده‌سازی مدل‌های یادگیری عمیق از زبان برنامه‌نویسی پایتون و کتابخانه‌ی یادگیری عمیق Keras استفاده شده است.

۳.۱. داده‌های مورد مطالعه

داده‌های استفاده شده در این پژوهش مربوط به بار اوج مصرف خانگی از پایگاه داده‌های برق مصرفی خانوارهای شهکرد واقع در استان چهارمحال و بختیاری طی سال‌های ۱۳۹۴ تا ۱۳۹۷ است. اطلاعات مورد استفاده در این موردکدای شامل میزان مصرف ساعتی و شرایط آب‌وهوایی (دما، رطوبت، سرعت باد و...) است. این اطلاعات که شامل ۱۹ متغیر است در جدول ۱ به همراه مقدار کمینه، بیشینه و متوسط روزانه گزارش شده است. متغیرهای مؤثر برونزا بر اساس مطالعات قبلی [۱۸، ۱۹، ۲۳] و همچنین نظرات افراد خبره در شرکت توزیع برق استان چهارمحال و بختیاری جمع‌آوری شده است؛ در حالی که یکی از قابلیت‌های برجسته‌ی شبکه‌های عصبی عمیق، تنظیم ضرایب شبکه بر اساس میزان تأثیرگذاری متغیرهای برونزای مدل است؛ به طوری که متغیرهایی که در عمل تأثیرگذاری کمتری دارند، پس از آموزش شبکه، اتصالات آنها ضرایب کمتری به خود خواهند گرفت.

اطلاعات جدول ۱ به دو طریق جمع‌آوری می‌شوند: ۱. از طریق تابلوهای کنترل که به پست‌ها متصل است تا اطلاعات را به توزیع منتقل کند، پس قسمت توزیع با استفاده از نرم‌افزار، اطلاعات را به مدیریت تقاضا منتقل می‌کند و ۲. از طریق مودم‌هایی که به پست‌ها وصل می‌شود و اطلاعات به نرم‌افزار فرستاده می‌شوند و سرور دسترسی مستقیم به آنها ندارد.

با توجه به مطالعات قبلی و همچنین تحلیل روند داده‌ها این نتیجه حاصل

می‌شود که الگوهای مصرف روزانه و ساعتی بر حسب فصل، ساعات شبانه‌روز، روز هفته و وضعیت تعطیلی متفاوت است. برای نمونه مقدار بار مصرفی در تابستان هر سال دارای بیشترین مقدار است.

از این رو با هدف مدل‌سازی این تغییرات، شش متغیر مصنوعی^{۳۱} به مدل اضافه شد. ۲۴ ساعت شبانه‌روز بر اساس نظر خبرگان شرکت توزیع برق استان چهارمحال و بختیاری و ملاحظات عملیاتی و فنی به عنوان یک متغیر مصنوعی با سه سطح کم‌باری، میان‌باری و پرباری مشخص شد. به همین طریق روزهای هفته با هفت سطح و اطلاعات فصل از طریق دو متغیر مصنوعی که نشان‌دهنده‌ی شماره‌ی ماه و روز است، تعریف شدند. بر اساس مطالعات قبلی^{۱۴} یک متغیر مصنوعی که بیان‌گر وضعیت تعطیلی هر روز است، نیز به مدل اضافه شد.

۳.۲. شاخص‌های ارزیابی

طبق مطالعات موجود در پیشینه دو شاخص جذر متوسط مربعات خطا (RMSE)^{۳۲} و شاخص متوسط درصد خطای مطلق (MAPE)^{۳۳} به عنوان قوی‌ترین و متداول‌ترین شاخص‌ها در ارزیابی کیفیت برازش مورد استفاده قرار می‌گیرند.^[۲۰] شاخص MAPE طبق رابطه‌ی ۲ برابر با متوسط قدرمطلق اختلاف بین مقدار واقعی و مقدار پیش‌بینی شده توسط مدل است.

$$MAPE\% = \frac{100}{N} \sum_{i=1}^N \left(\frac{|A_i - F_i|}{A_i} \right) \quad (2)$$

شاخص RMSE نیز طبق رابطه‌ی ۳ مربعات خطای پیش‌بینی یا به عبارتی فاصله‌ی بین مقدار واقعی و مقدار پیش‌بینی شده توسط مدل را محاسبه می‌کند و سپس جذر

متوسط آن را بر می‌گرداند.

$$MAPE\% = \sqrt{\frac{1}{N} \sum_{i=1}^N (A_i - F_i)^2} \quad (3)$$

۳.۳. ارزیابی عملکرد مدل‌های یادگیری عمیق

به منظور ارزیابی مدل پیشنهادی و مقایسه آن با سایر مدل‌ها، از زبان برنامه‌نویسی پایتون نسخه ۳٫۷ به همراه کتابخانه یادگیری عمیق Keras ۲٫۲ با پشتیبانی TensorFlow ۱٫۱۰ برای پیاده‌سازی الگوریتم‌های یادگیری عمیق تمام مدل‌ها استفاده شده است. همچنین در پیاده‌سازی‌ها از کتابخانه‌های دیگر همچون Scikit-learn, NumPy, Openpyxl, Matplotlib برای خواندن داده‌های ورودی، تجزیه و تحلیل نتایج و نمایش آن‌ها استفاده شده است. اجرای مدل‌های پیاده‌سازی شده و ارزیابی آن‌ها بر روی یک رایانه با کارت گرافیک GTX ۱۰۶۰، پردازنده ۶۱۰۰ - i۳، حافظه ۱۲ گیگابایت و سیستم عامل لینوکس Ubuntu صورت پذیرفته است.

در این پژوهش ابتدا چهار مدل پایه از شبکه‌های عصبی عمیق متفاوت شامل ۱. مدل تمام متصل عمیق، ۲. مدل بازگشتی عمیق LSTM، ۳. مدل بازگشتی عمیق GRU و ۴. مدل عمیق CNN پیاده‌سازی شد و نتایج ارزیابی و تحلیل شد. این مدل‌ها، ابتدا با استفاده از ۷۵ درصد از داده‌های موجود (سه سال نخست از داده‌ها) آموزش داده شده‌اند و سپس با استفاده از ۲۵ درصد از داده‌های باقی‌مانده (سال چهارم)، مدل‌ها آزموده و بررسی شده‌اند. نتایج عملکرد مدل‌های مذکور در جدول ۲ ارائه شده است.

از نتایج نیز قابل استنتاج است که هر چند شبکه‌های عصبی کانولوشنال در مباحثی همچون بینایی ماشین دارای دقت به نسبت بالایی هستند، برای برآزش مدل‌های مبتنی بر زمان دارای دقت کمتری نسبت به سایر روش‌ها می‌باشند. به همین دلیل می‌توان این‌گونه نتیجه گرفت که استفاده از توپولوژی کانولوشن نمی‌تواند اطلاعات دقیق‌تری نسبت به سایر شبکه‌های عصبی در مقوله‌ی پیش‌بینی فراهم کند.

در شرایط استفاده از شبکه‌های عصبی عمیق پایه‌ی، بهترین عملکرد توسط مدل شبکه‌ی عصبی عمیق تمام متصل به دست آمده است. دلیل این امر را می‌توان به این موضوع مرتبط دانست که در تخمین بار مصرفی، ترکیب غیرخطی متغیرهای برون‌زا در قالب یک مدل به صورت مناسب‌تری می‌تواند در مدل‌های تمام متصل فرمول‌بندی شود. شبکه‌های عصبی بازگشتی GRU و LSTM در حالت پایه دارای دقتی نزدیک به شبکه‌ی تمام متصل دارند که این امر نشان‌دهنده‌ی این است که بهره‌گیری از حافظه‌ی گذشته تقریباً به اندازه‌ی استفاده از متغیرهای برون‌زا مؤثر است.

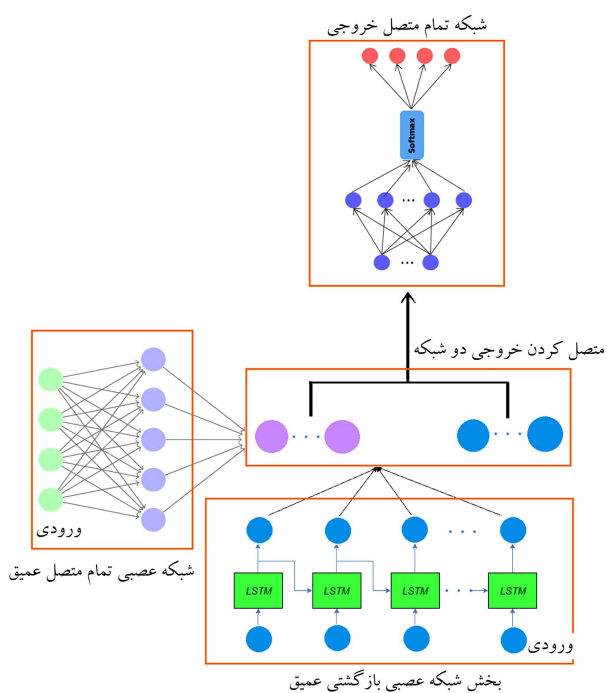
جدول ۲. مقایسه‌ی مقادیر شاخص‌های ارزیابی عملکرد برای پیش‌بینی بار مصرف خانگی برای مدل‌های پایه‌ی عصبی عمیق.

مدل	خطای MAPE		خطای RMSE	
	آموزش	آزمون	آموزش	آزمون
CNN	۱۶٫۷۸	۱۶٫۹۹	۲۱٫۷۲	۲۱٫۹۰
GRU	۶٫۹۱	۷٫۸۰	۱۱٫۹۱	۹٫۸۹
Fully Connected	۶٫۳۱	۷٫۳۱	۱۱٫۵۹	۹٫۵۱
LSTM	۶٫۶۲	۷٫۳۴	۱۱٫۴۱	۹٫۶۸

همان‌طور که در قسمت ۴.۲ بیان شد، در این پژوهش یک مدل ترکیبی مبتنی بر شبکه‌های بازگشتی عمیق و شبکه‌های تمام متصل عمیق پیشنهاد شده است تا از مزایای این دو نوع از شبکه به صورت هم‌زمان استفاده شود. برای ترکیب این دو مدل از ساختاری بر اساس شکل ۵ استفاده شده است.

در این پژوهش، مدل پیشنهادی بر اساس نوع شبکه‌ی بازگشتی به دو صورت پیاده‌سازی شده است. مدل نخست از ترکیب شبکه‌ی بازگشتی LSTM و شبکه‌ی عصبی تمام متصل است که آن را به اختصار LSTM+Full می‌نامیم. مدل دوم مدل GRU+Full است که ترکیبی از شبکه‌ی بازگشتی GRU و شبکه‌ی عصبی تمام متصل است. در شکل ۶ ساختار LSTM+Full نشان داده شده است. همان‌طور که در شکل مشخص است، مدل دارای دو ورودی است. یک ورودی مربوط به داده‌های وابسته به تاریخچه است که وارد یک شبکه‌ی عصبی بازگشتی LSTM می‌شود. ورودی دوم مربوط به داده‌های غیروابسته به زمان است که به یک شبکه‌ی عصبی تمام متصل عمیق وارد می‌شود. خروجی دو شبکه‌ی بازگشتی و تمام متصل سپس به کمک یک لایه‌ی اتصال^{۳۴} به هم وصل و سپس توسط یک شبکه‌ی تانس متصل به خروجی وصل می‌شود. برای پیاده‌سازی ساختار GRU+Full مشابه شکل ۶ عمل می‌شود، با این تفاوت که در قسمت شبکه‌ی عصبی بازگشتی، یک شبکه‌ی GRU قرار می‌گیرد.

نتایج این دو مدل ترکیبی در جدول ۳ نمایش داده شده است. همان‌طور که مشخص است، با ترکیب شبکه‌های بازگشتی با شبکه‌ی تمام متصل می‌توان دقت



شکل ۶. ساختار مدل LSTM + Full.

جدول ۳. مقایسه‌ی مقادیر شاخص‌های ارزیابی عملکرد برای پیش‌بینی بار مصرف خانگی برای مدل‌های پایه‌ی عصبی عمیق.

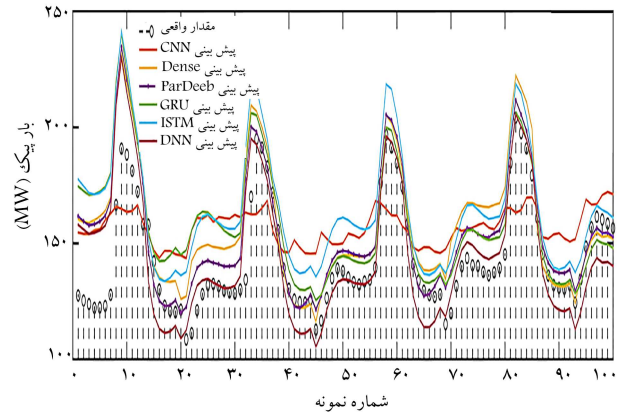
مدل	خطای MAPE		خطای RMSE	
	آموزش	آزمون	آموزش	آزمون
GRU+Full	۶٫۵۵	۷٫۴۲	۱۱٫۳۴	۹٫۶۸
LSTM+Full	۶٫۱۵	۷٫۲۲	۱۱٫۲۶	۹٫۲۴

۴. نتیجه‌گیری

با توجه به اهمیت برنامه‌ریزی سیستم‌های انرژی در سیاست‌گذاری‌های بلند مدت اقتصادی و اجتماعی ایران و همچنین اهمیت تولید بهیمنی انرژی به‌عنوان یکی از عوامل حیاتی توسعه، مأموریت این تحقیق شناسایی و معرفی رویکرد برتر در پیش‌بینی بیک بار مصرفی خانوارهای ایرانی تعریف شد. مطالعات قبلی حاکی از آن است که بیشترین سهم مصرف انرژی در بخش خانگی اتفاق می‌افتد و این موضوع سبب شده است تا پیش‌بینی بار مصرفی خانوارها بیشترین سهم را در پژوهش‌های مرتبط به خود اختصاص دهد. هر چند که طیف گسترده‌ی از رویکردهای مدل‌سازی و پیش‌بینی در پژوهش‌های داخلی و خارجی وجود دارد، مطالعات اخیر از برتری مدل‌های هوش محاسباتی در این حوزه خبر می‌دهد. دارا بودن ویژگی‌هایی چون ماهیت غیرخطی و پیچیده و همچنین وجود الگوهای قوی از وابستگی به مقادیر قبلی در داده‌ها موجب شده است تا مدل‌های مبتنی بر هوش محاسباتی گوی سبقت را از رقبا برابند و در صدر قرار گیرند. با عنایت به این نکته که مدل‌های هوش مصنوعی خود نیز دارای توپولوژی‌های متفاوت و عملکردهای متفاوتی برای کاربردهای مختلف هستند، در این تحقیق انواع مدل‌های یادگیری عمیق بازگشتی LSTM و GRU، مدل تمام‌متصل و همچنین ترکیب آنها برای اولین بار برای سری زمانی بار مصرفی بررسی و مقایسه شد. نتایج برای داده‌های جمع‌آوری شده از ایران حاکی از این موضوع بود که شبکه‌ی بازگشتی LSTM ترکیبی با شبکه‌های تمام‌متصل می‌تواند با خطای MAPE برابر با ۷٫۲۲ درصد و خطای RMSE برابر با ۱۱٫۲۶ به‌عنوان توپولوژی برتر در برآزش سری زمانی بار مصرفی معرفی و استفاده شود. این برتری می‌تواند ۱. نشان‌دهنده وجود الگوهای وابستگی قوی بین داده‌های پیش‌بینی شده و داده‌های قبلی در سری زمانی مذکور؛ ۲. وجود روابط غیرخطی نسبتاً پیچیده بین متغیرهای برون‌زای مدل (شرایط جوی) و متغیر پاسخ مسئله و ۳. متفاوت بودن تأخیرهای زمانی در سری‌های زمانی ورودی به مدل باشد.

نتیجه‌گیری نهایی از مقایسه‌ی نتایج ارزیابی عملکرد مدل‌های پیشنهادی در این مطالعه را می‌توان به شرح زیر خلاصه کرد:

- استفاده از متغیرهای مؤثر برون‌زا و دامی در مدل‌های اتورگرسیو می‌تواند منجر به افزایش قدرت آنها در پیش‌بینی شود.
- تفکیک متغیرهای مؤثر برون‌زا با الگوهای وابستگی (تأخیردار) متفاوت و مدل‌سازی آنها به‌صورت شبکه‌های موازی در قالب یک مدل ترکیبی می‌تواند منجر به افزایش قدرت پیش‌بینی شود.
- به‌دلیل وجود روابط غیرخطی پیچیده در مدل سری زمانی بار مصرفی خانوارها، رویکردهای هوش محاسباتی پیش‌بینی دقیق‌تری نسبت به دیگر رویکردها ارائه خواهند داد.



شکل ۷. نتایج پیش‌بینی ۴ مدل پایه و دو مدل ترکیبی در مقایسه با داده‌های واقعی برای ۱۰۰ نمونه‌ی نخست آزمون.

بهتری را به دست آورد. دلیل بهبود به دست آمده این است که هم حافظه‌ی شبکه‌های بازگشتی و هم ترکیب غیرخطی متغیرهای برون‌زا هم‌زمان مورد استفاده قرار می‌گیرند.

با در نظر گرفتن پارامترهای MAPE و RMSE در فاز آموزش و آزمون، همان‌طور که در جدول ۲ و جدول ۳ مشهود است، شبکه‌ی بازگشتی LSTM عموماً دارای دقت بهتری نسبت به شبکه‌ی بازگشتی GRU است. علت این امر این است که شبکه‌های عصبی GRU دارای ساختار ساده‌تر نسبت به شبکه‌های LSTM هستند. از این رو شبکه‌های عصبی GRU دارای سرعت بیشتر در آموزش‌اند، اما فقط می‌توانند ساختارهای حافظه‌ی ساده‌تری را مدل کنند و هنگامی که ساختار مورد مطالعه نسبتاً پیچیده باشد، توپولوژی LSTM بهتر از GRU عمل می‌کند. با وجود این، باید این نکته را نیز در نظر داشت که شبکه‌های LSTM به زمان بیشتری برای آموزش نیاز دارند. بنابراین اگر زمان آموزش برای ما اهمیت داشته باشد یا بخواهیم پردازش کمتری داشته باشیم، مدل مبتنی بر شبکه‌ی GRU می‌تواند کمک کننده باشد.

به‌منظور مشاهده‌ی عملکرد کلی ۴ مدل پایه و ۲ مدل ترکیبی، عملکرد این مدل‌ها برای ۱۰۰ نمونه‌ی نخست داده‌ی آزمون در شکل ۷ نمایش داده شده است. همان‌طور که در شکل قابل مشاهده است مدل‌های پایه‌ی عصبی عمیق در مقایسه با مقادیر واقعی دارای میانگین مربعات خطای پیش‌بینی و متوسط درصد خطای مطلق بیشتری در مقایسه با مدل‌های ادغامی هستند. این اختلاف را می‌توان به تفکیک متغیرهای برون‌زا بر حسب میزان تأخیر در مدل‌سازی مرتبط دانست. این برتری برای داده‌هایی که نزدیک به میانگین هستند، ملموس‌تر است.

پانوشته‌ها

1. stand-alone
2. hybrid
3. statistical
4. casual
5. computational intelligence
6. autoregressive
7. double seasonal holt-winter

8. autoregressive with exogenous inputs
9. threshold ARX
10. generalized autoregressive conditional heteroscedasticity based
11. autoregressive integrated moving average
12. semi/nonparametric
13. seasonal autoregressive integrated moving average
14. transfer function
15. artificial neural network
16. support vector machine
17. convolution neural network

18. recurrent neural network
19. over-fitting
20. feedback
21. dense
22. feed forward
23. vanishing gradient
24. dropout
25. historical dependency pattern
26. long short term memory (LSTM)
27. forget gate
28. gated recurrent Unit
29. convolutional neural network
30. convolve
31. dummy
32. root mean square error
33. mean absolute percentage error
34. concatenated layer

منابع (References)

1. Amara, F., Agbossou, K., Dubé, Y. and et al. "A residual load modeling approach for household short-term load forecasting application", *Energy Build*, **187**, pp. 132-143, (2019) <https://DOI.org/10.1016/j.enbuild.2019.01.009>
2. Cruz, A., Muñoz, A., Zamora, J.L. and et al. "The effect of wind generation and weekday on spanish electricity spot price forecasting. electr", *Power Syst. Res*, **81**, pp. 1924-1935, (2011) <https://DOI.org/10.1016/j.epsr.2011.06.002>
3. Weron, R. and Misiorek, A. "Forecasting spot electricity prices: a comparison of parametric and semiparametric time series models", *Int. J. Forecast.*, *Energy Forecasting*, **24**, pp. 744-763, (2008) <https://DOI.org/10.1016/j.ijforecast.2008.08.004>
4. Misiorek, A., Trueck, S. and Weron, R. "Point and interval forecasting of spot electricity prices: linear vs. non-linear time series models", *Stud. Nonlinear Dyn. Econom*, **10**(3), pp. 1-36, (2006) <https://DOI.org/10.2202/1558-3708.1362>
5. Diongue, A.K., Guégan, D. and Vignal, B. "Forecasting electricity spot market prices with a k-factor GI-GARCH process", *Appl. Energy*, **86**, pp. 505-510, (2009) <https://DOI.org/10.1016/j.apenergy.2008.07.005>
6. Garcia, R.C., Contreras, J., Akkeren, M. and et al. "A GARCH forecasting model to predict day-ahead electricity prices", *IEEE Trans. Power Syst*, **20**, pp. 867-874, (2005) <https://DOI.org/10.1109/TPWRS.2005.846044>
7. Knittel, C.R. and Roberts, M.R. "An empirical examination of restructured electricity prices", *Energy Econ*, **27**, pp. 791-817, (2005) <https://DOI.org/10.1016/j.eneco.2004.11.005>
8. Diongue, A.K., Guégan, D. and Vignal, B. "Forecasting electricity spot market prices with a k-factor GI-GARCH process", *Appl. Energy*, **86**, pp. 505-510, (2009) <https://DOI.org/10.1016/j.apenergy.2008.07.005>
9. Yang, Z., Ce, L. and Lian, L. "Electricity price forecasting by a hybrid model, combining wavelet transform, ARMA and kernel-based extreme learning machine methods", *Appl. Energy*, **190**, pp. 291-305, (2017) <https://DOI.org/10.1016/j.apenergy.2016.12.130>
10. Vilar, J.M., Cao, R. and Aneiros, G. "Forecasting next-day electricity demand and price using nonparametric functional methods", *Int. J. Electr. Power Energy Syst*, **39**, pp. 48-55 (2012) <https://DOI.org/10.1016/j.ijepes.2012.01.004>
11. Weron, R. and Misiorek, A. "Forecasting spot electricity prices: a comparison of parametric and semiparametric time series models", *Int. J. Forecast.*, *Energy Forecasting*, **24**, pp. 744-763, (2008) <https://DOI.org/10.1016/j.ijforecast.2008.08.004>
12. Jeong, K., Koo, C. and Hong, T. "An estimation model for determining the annual energy cost budget in educational facilities using SARIMA (seasonal autoregressive integrated moving average) and ANN (artificial neural network)", *Energy*, **71**, pp. 71-79, (2014) <https://DOI.org/10.1016/j.energy.2014.04.027>
13. Wang, Y., Wang, J., Zhao, G. and et al. "Application of residual modification approach in seasonal ARIMA for electricity demand forecasting: a case study of China", *Energy Policy, Special Section: Frontiers of Sustainability*, **48**, pp. 284-294, (2012) <https://DOI.org/10.1016/j.enpol.2012.05.026>
14. Nogales, F.J., Contreras, J., Conejo, A.J. and et al. "Forecasting next-day electricity prices by time series models", *IEEE Trans. Power Syst*, **17**, pp. 342-348, (2002) <https://DOI.org/10.1109/TPWRS.2002.1007902>
15. Kyung-Bin-Song, Young-Sik Baek. "Short-term load forecasting for the holidays using fuzzy linear regression method", *IEEE Trans. Power Syst*, **20**, pp. 96-101, (2005) <https://DOI.org/10.1109/TPWRS.2004.835632>
16. Tan, Z., Zhang, J., Wang, J. and et al. "Day-ahead electricity price forecasting using wavelet transform combined with ARIMA and GARCH models", *Appl. Energy*, **87**, pp. 3606-3610, (2010) <https://DOI.org/10.1016/j.apenergy.2010.05.012>
17. Yang, Z., Ce, L. and Lian, L. "Electricity price forecasting by a hybrid model, combining wavelet transform, ARMA and kernel-based extreme learning machine methods", *Appl. Energy*, **190**, pp. 291-305, (2017) <https://DOI.org/10.1016/j.apenergy.2016.12.130>
18. Bilgili, M., Sahin, B., Yasar, A. and et al. "Electric energy demands of Turkey in residential and industrial sectors. Renew", *Sustain. Energy Rev*, **16**, pp. 404-414, (2002) <https://DOI.org/10.1016/j.rser.2011.08.005>
19. Ghiassi, M. and Nangoy, S. "A dynamic artificial neural network model for forecasting nonlinear processes. Comput", *Ind. Eng., Collaborative e-Work Networks in Industrial Engineering*, **57**, pp. 287-297, (2009) <https://DOI.org/10.1016/j.cie.2008.11.027>
20. Tsekouras, G.J., Dialynas, E.N., Hatziaargyriou, N.D. and et al. "A non-linear multivariable regression model for midterm energy forecasting of power systems", *Electr. Power Syst. Res*, **77**, pp. 1560-1568, (2007) <https://doi.org/10.1016/j.epsr.2006.11.003>
21. Kazemi, A., Shakouri, H.G., Menhaj, M.B. and et al. "A hierarchical fuzzy linear regression model for forecasting agriculture energy demand: a case study of Iran", *In 2011 3rd International Conference on Information and Financial Engineering*, **12**, pp. 19-24 (2011).

22. Zhang, M., Mu, H., Li, G. and et al. "Forecasting the transport energy demand based on PLSR method in China", *Energy*, **34**, pp. 1396-1400, (2009) <https://DOI.org/10.1016/j.energy.2009.06.032>
23. Ekonomou, L. "Greek long-term energy consumption prediction using artificial neural networks", *Energy, ECOS*, **35**, pp. 512-517, (2010) <https://DOI.org/10.1016/j.energy.2009.10.018>
24. Kialashaki, A. and Reisel, J.R. "Development and validation of artificial neural network models of the energy demand in the industrial sector of the United States", *Energy*, **76**, pp. 749-760, (2014) <https://DOI.org/10.1016/j.energy.2014.08.072>
25. Abedini, O. and Amjady, N. "Short-term load forecast of electrical power system by radial basis function neural network and new stochastic search algorithm", *Int. Trans. Electr. Energy Syst*, **26**, pp. 1511-1525, (2016) <https://DOI.org/10.1002/etep.2160>
26. Gajowniczek, K. and Ząbkowski, T. "Electricity forecasting on the individual household level enhanced based on activity patterns", *PLOS ONE* 12, e0174098, (2017) <https://DOI.org/10.1371/journal.pone.0174098>
27. Wang, J., Zhu, S., Zhang, W. and et al. "Combined modeling for electric load forecasting with adaptive particle swarm optimization", *Energy, Demand Response Resources: the US and International Experience*, **35**, pp. 1671-1678, (2010) <https://DOI.org/10.1016/j.energy.2009.12.015>
28. Shi, H., Xu, M., Ma, Q. and et al. "A whole system assessment of novel deep learning approach on short-term load forecasting", *Energy Procedia, Proceedings of the 9th International Conference on Applied Energy*, **142**, pp. 2791-2796, (2017) <https://DOI.org/10.1016/j.egypro.2017.12.423>
29. Rahman, A., Srikumar, V. and Smith, A.D. "Predicting electricity consumption for commercial and residential buildings using deep recurrent neural networks", *Appl. Energy*, **212**, pp. 372-385, (2018) <https://DOI.org/10.1016/j.apenergy.2017.12.051>
30. Kong, W., Dong, Z.Y., Hill, D.J. and et al. "Short-term residential load forecasting based on resident behaviour learning", *IEEE Trans. Power Syst*, **33**, pp. 1087-1088, (2018) <https://DOI.org/10.1109/TPWRS.2017.2688178>
31. Bedi, J. and Toshniwal, D. "Deep learning framework to forecast electricity demand", *Appl. Energy*, **238**, pp. 1312-1326, (2019) <https://doi.org/10.1016/j.apenergy.2019.01.113>
32. Elamin, N. and Fukushige, M. "Modeling and forecasting hourly electricity demand by SARIMAX with interactions", *Energy*, **165**, pp. 257-268, (2018) <https://DOI.org/10.1016/j.energy.2018.09.157>
33. He, W., "Load forecasting via deep neural networks. procedia Comput", *Sci, 5th International Conference on Information Technology and Quantitative Management, ITQM*, **122**, pp. 308-314, (2017) <https://DOI.org/10.1016/j.procs.2017.11.374>
34. Yang, Z., Ce, L. and Lian, L. "Electricity price forecasting by a hybrid model, combining wavelet transform, ARMA and kernel-based extreme learning machine methods", *Appl. Energy*, **190**, pp. 291-305, (2017) <https://DOI.org/10.1016/j.apenergy.2016.12.130>