

SID



سرویس های ویژه



سرویس ترجمه تخصصی



کارگاه های آموزشی



بلاگ مرکز اطلاعات علمی



عضویت در خبرنامه



فیلم های آموزشی

کارگاه های آموزشی مرکز اطلاعات علمی جهاد دانشگاهی



مباحث پیشرفته یادگیری عمیق؛
شبکه های توجه گرافی
(Graph Attention Networks)



کارگاه آنلاین آموزش استفاده از
وب آو ساینس



کارگاه آنلاین مقاله روزمره انگلیسی

پیش‌بینی بار الکتریکی کوتاه مدت با استفاده از ماشین بردار پشتیبان

محسن رنگین رخ^۱، علیرضا حاتمی^۲، حمیدرضا رشیدی کنگان^۲

^۱ دانشجوی کارشناسی ارشد، گروه مهندسی برق، دانشگاه بوعلی سینا، همدان
m.ranginrokh@basu.ac.ir

^۲ استادیار، گروه مهندسی برق، دانشگاه بوعلی سینا، همدان
hatamisharif@basu.ac.ir

^۲ استادیار، گروه مهندسی برق، دانشگاه بوعلی سینا، همدان
h.rashidykanan@basu.ac.ir

چکیده

پیش‌بینی دقیق بار یکی از نیازهای اساسی بازیگران بازار برق است. به علت تأثیر عوامل مختلف، بار دارای رفتار شدیداً غیرخطی است. یکی از روش‌های مناسب برای بررسی این نوع مسائل، روش ماشین بردار پشتیبان است که به طور موفقیت‌آمیزی در رگرسیون‌های غیرخطی استفاده شده است. در این مقاله با استفاده از روش ماشین بردار پشتیبان به پیش‌بینی کوتاه مدت بار پرداخته شده است. داده‌هایی که در اینجا برای پیش‌بینی بار مورد استفاده قرار گرفته است، داده‌های شبکه EUNITE می‌باشد که یک پایگاه داده استاندارد برای ارزیابی دقت روش‌های پیش‌بینی بار است. در این مقاله از خاصیت رفتار پریودیک استفاده شده است و با پیش‌پردازش روی داده‌های ورودی نتایج به دست آمده، بهبود یافته است. در پایان، نتایج به دست آمده با مقاله‌های دیگر که از داده‌های مشابه برای پیش‌بینی بار استفاده کرده‌اند، مقایسه شده است. نتایج بدست آمده نشان می‌دهد که از روش ارائه شده پیش‌بینی بهتری حاصل شده است. همچنین با مقایسه نتایج به دست آمده و نتایج حاصل از یک شبکه عصبی، دیده می‌شود که نتایج روش ماشین بردار پشتیبان نتایج بهتری است.

کلمات کلیدی

سیستم تولید و توزیع انرژی الکتریکی - پیش‌بینی بار - ماشین بردار پشتیبان - شبکه‌های عصبی

روش‌های مختلفی برای افزایش دقت پیش‌بینی مورد بررسی قرار گرفته‌اند [۲].

۱- مقدمه

در مقالات متعدد روش‌های مختلفی برای پیش‌بینی کوتاه مدت بار ارائه شده است که از این میان می‌توان به شبکه‌های عصبی [۴-۲۷،۷] و سیستم‌های خبره [۸،۹] و منطق فازی [۱۰،۱۱] روش هموار ساز نمایی [۱۶] و روش رگرسیون خطی [۱۷] و مدل اتورگرسور [۱۸] و مدل سری زمانی و همچنین مدل ARMA و ARMAX در [۱۹-۲۱] اشاره نمود. در این مقاله روشی که ارائه شده است و بحث بیشتری روی آن خواهد شد. تکنیک اصلی استفاده شده در حل آن، بردار ماشین پشتیبان می‌باشد. که یک روش یادگیری ماشین جدید می‌باشد.

پیش‌بینی دقیق میزان بار، یکی از نیازهای اساسی بازیگران در بازار برق است به طوری که سبب کاهش در هزینه بازیگران می‌شود. برای مثال عدم تخمین درست بار سبب انتخاب مقدار رزرو بیش یا کمتر از مقدار نیاز خواهد شد که در هر دو صورت سبب ضرر و زیان بازیگران خواهد شد. در مقدار بار مصرفی عوامل مختلفی نظیر شرایط آب و هوایی (مانند دما و رطوبت)، فعالیت‌های اجتماعی و فاکتورهای فصلی اثر گذار بوده و سبب می‌شود بار رفتاری به شدت غیرخطی داشته باشد [۱]. در طول سالیان گذشته،

$$R(f) = 1/2 w^T w + C.E(x, y, f) \quad (3)$$

E در بالا تابع تلفات می‌باشد و C پارامتری است که بر حسب حداقل کردن خطای تخمین و یکسان در نظر گرفتن وزن‌ها تنظیم می‌شود. در این مقاله از تابع تلفات حساس ε استفاده می‌شود. فرمول (3) را می‌توان به صورت زیر نوشت.


$$\min 1/2 w^T w + C \sum_{i=1}^N (\xi_i + \xi_i^*) \quad (4)$$

قیود:

$$d_i - w^T \cdot \phi(x_i) - b \leq \varepsilon + \xi_i, \quad i = 1, 2, \dots, N$$

$$w^T \cdot \phi(x_i) - d_i + b \leq \varepsilon + \xi_i^*, \quad i = 1, 2, \dots, N$$

$$\xi_i, \xi_i^* \geq 0, \quad i = 1, 2, \dots, N$$



شکل (2) پارامترهای مورد استفاده در ماشین بردار پشتیبان [23]

که در آن x_i ورودی که با استفاده از تابع نگاشت ϕ به فضای ابعاد بالاتر برده می‌شود، d_i خروجی، C هزینه خطا و ξ_i خطای یادگیری پایین‌تر و ξ_i^* خطای یادگیری بالاتر است. در اینجا ξ_i و ξ_i^* متغیرهای کمکی برای غلبه بر قیود اجرا نشدنی در مسئله بهینه‌سازی فرمول (4) می‌باشد. برای حل مسئله بهینه‌سازی می‌توان از روش لاگرانژ استفاده نمود و تابع لاگرانژ را مطابق رابطه زیر نوشت.

$$L = R(f) - \sum_{i=1}^N (\eta_i \xi_i + \eta_i^* \xi_i^*) - \sum_{i=1}^N \alpha_i (\varepsilon + \xi_i - d_i + w^T \cdot \phi(x_i) + b) - \sum_{i=1}^N \alpha_i^* (\varepsilon + \xi_i^* + d_i - w^T \cdot \phi(x_i) - b) \quad (5)$$

در اینجا η_i ، η_i^* ، α_i و α_i^* ضرایب لاگرانژ هستند. شرایط لازم برای تعیین جواب بهینه به صورت زیر می‌باشد.

$$\frac{\partial L}{\partial w} = 0 \rightarrow w - \sum_{i=1}^N (\alpha_i - \alpha_i^*) \phi(x_i) = 0 \quad (6)$$

$$\frac{\partial L}{\partial d} = 0 \rightarrow \sum_{i=1}^N (\alpha_i^* - \alpha_i) \phi(x_i) = 0 \quad (7)$$

$$\frac{\partial L}{\partial \xi_i} = 0 \rightarrow \alpha_i + \eta_i = C, \quad i = 1, 2, \dots, N \quad (8)$$

$$\frac{\partial L}{\partial \xi_i^*} = 0 \rightarrow \alpha_i^* + \eta_i^* = C, \quad i = 1, 2, \dots, N \quad (9)$$

با توجه به معادلات (6) تا (9) نسبت به معادله (5) مسئله بهینه‌سازی به صورت زیر در می‌آید.

در این مقاله به صورت زیر عمل خواهد شد، در قسمت دوم به معرفی روش ماشین بردار پشتیبان پرداخته می‌شود و در قسمت سوم آنالیز داده‌های ارائه شده و تکنیک‌های بکار رفته شرح داده می‌شود؛ آماده‌سازی داده‌ها، آزمایش‌ها و نتایج مدل‌های مختلف در قسمت چهارم پرداخته می‌شود. سرانجام نتیجه گیری و مقایسه با شبکه عصبی در قسمت آخر نشان داده می‌شود.

2- ماشین بردار پشتیبان


ماشین بردار پشتیبان، یک طبقه‌بندی و ابزار رگرسیون است که ریشه‌های آن در نظریه یادگیری آماری واپنیک در سال (1995) است [12]. برخلاف ANN، که سعی می‌کند به تعریف پیچیدگی توابع از فضای ورودی بپردازد، ماشین بردار پشتیبان داده‌های غیر خطی را به فضایی با ابعاد بالاتر می‌برد. سپس از توابع خطی ساده برای ایجاد مرزهای جدا کننده خطی در فضای جدید استفاده می‌کند. از ویژگی‌های جذاب ماشین بردار پشتیبان این است که فرمولاسیون رگرسیون آن بر اساس مینیمم کردن ریسک ساختاری به جای مینیمم کردن ریسک تجربی است، به طوریکه عملکرد بهتری نسبت به الگوریتم‌های متداول دیگر مانند شبکه عصبی که ساختار آن بر اساس مینیمم کردن ریسک تجربی است دارد. روش ماشین بردار پشتیبان روشی غیر مستدل نمی‌باشد و به شدت بر روی فن آوری هوشمند تکیه نمی‌کند، و دارای یک ساختار با انعطاف‌پذیری بیشتری است [3، 13-15].

SVR یک شیوه یادگیری جدید بر اساس SVM است. تابع زیر را در

نظر می‌گیریم

$$f(x) = w^T \cdot x + b \quad (1)$$

که در آن x ورودی، w بردار وزن و b دوره بایاس می‌باشد. مدل رگرسیون در فرمول (1) با استفاده از تابع نگاشت $\phi(\cdot)$ می‌تواند به صورت زیر در نظر گرفته شود.



شکل (1) تابع انتقال غیر خطی

$$f(x) = w^T \cdot \phi(x) + b \quad (2)$$

با استفاده از فرمول بالا داده‌های ورودی اصلی به فضای ابعاد بالاتر برده می‌شوند که در آن مسئله تفکیک‌پذیر غیرخطی در همین فضای جدید به تفکیک‌پذیر خطی تبدیل می‌شود. شکل (1) انتقال ورودی‌ها به فضایی با ابعاد بالاتر با استفاده از تابع انتقال غیر خطی را نشان می‌دهد.

همان‌طور که در فرمول (2) مشاهده می‌شود تابع نگاشت متأثر از بردار وزن w و بایاس b است. مقادیر مناسب برای این دو پارامتر از حداقل کردن خطای تخمین و یکسان در نظر گرفتن وزن‌ها به دست می‌آید. در واقع هدف اصلی، مینیمم کردن تابع زیر می‌باشد.

۳- شرح کار و آنالیز داده‌های ارائه شده

۳-۱- شرح کار

در این مقاله از داده‌های بار EUNITE که به صورت نیم ساعته برای دو سال ارائه شده، استفاده شده است. داده‌های مورد استفاده به بازه زمانی ۱۹۹۷-۱۹۹۸ بوده و شامل موارد زیر است [۲۶].

-تقاضای بار الکتریکی ثبت شده برای هر نیم ساعت
-دمای متوسط روزانه

MAPE درصد متوسط خطای کلی برای پیش‌بینی بار از نتایج طبق فرمول زیر به دست می‌آید.

$$MAPE = \frac{100}{n} \sum_{i=1}^n \left| \frac{L_i - \hat{L}_i}{L_i} \right| \quad (19)$$

در اینجا L_i و \hat{L}_i به ترتیب مقادیر واقعی و پیش‌بینی شده می‌باشد؛ و n در آن تعداد روزها برای پیش‌بینی می‌باشد.

قبل از تحقیق کردن در مورد حلی که ارائه شده است، به صورت خلاصه برخی ویژگی‌های بار مورد استفاده در این مقاله را ذکر خواهیم کرد. بار با دما نسبت عکس دارد یعنی هر چه دما بالا رود مصرف بار کم می‌شود و بالعکس. در روزهای تعطیل مصرف بار کمتر از روزهای کاری می‌باشد و در اولین روزهای کاری هفته مصرف بار نسبت به بقیه روزهای کاری دیگر معمولاً مصرف بار کمی بالاتر است. همچنین رویدادهای محلی، از جمله تعطیلات و جشن‌ها بر تقاضای بار تأثیر می‌گذارد. تأثیرات این وقایع معمولاً به شدت وابسته به آداب و رسوم منطقه است.

۳-۲- آماده‌سازی داده‌ها

در این مقاله از ۹۱۱ داده نیم ساعته به عنوان داده‌های تست و یادگیری استفاده شده است. از این تعداد ۸۶۳ داده را به عنوان داده یادگیری و ۴۸ داده را به عنوان تست در نظر گرفته شده. این کار را برای تمام نیم ساعت‌های یک روز انجام گرفته و سپس میانگین خطا را برای آن روز به دست آمده است.

برای پیش‌بینی بار ساعت آینده، از داده‌های بار روز قبل، هفته قبل، ماه قبل و سال گذشته استفاده شده است. همچنین ساعات نیز به عنوان یک دسته ورودی نیز در نظر گرفته شده است. همچنین پیش‌پردازی بر روی داده‌های یک روز مشخص انجام شده و اصطلاحاً نیز فرم و شکل خاصی از روز را به صورت داده ورودی در آورده و به بقیه ورودی‌ها اضافه شده است. داده‌های ورودی به این صورت می‌باشد: (۱) ساعت h ؛ (۲) بار ساعت $(h-1)$ ؛ (۳) بار روز قبل در ساعت h ؛ (۴) بار هفته قبل در ساعت h ؛ (۵) بار ماه قبل در ساعت h ؛ (۶) بار سال قبل در ساعت h ؛ (۷) دمای ساعت h ؛ (۸) پیش‌پردازی روی داده‌های روز مشخص. خروجی ما بار در ساعت h می‌باشد.

۴- تحلیل نتایج

در این مقاله برای ارزیابی خطا از معیار MAPE، متوسط درصد خطا، به شرح زیر استفاده می‌شود. برخی پارامترها خطای پیش‌بینی را تحت تأثیر قرار می-

$$\max -\frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N (\alpha_i - \alpha_i^*)(\alpha_j - \alpha_j^*) \phi_i(x) \phi_j(x) - \varepsilon \sum_{i=1}^N (\alpha_i - \alpha_i^*) + \sum_{i=1}^N d_i (\alpha_i - \alpha_i^*) \quad (10)$$

می‌توان گفت که:

$$\sum_{i=1}^N (\alpha_i - \alpha_i^*) = 0 \quad \alpha_i, \alpha_i^* \in [0, C]$$

با توجه به رابطه فوق لازم است $k(x_i, x_j) = \phi_i(x) \phi_j(x)$ که کرنل نامیده می‌شود مشخص باشد رابطه فوق را می‌توان به صورت زیر نوشت.

$$w = \sum_{i=1}^N (\alpha_i - \alpha_i^*) \phi(x_i) \quad (11)$$

$$w = \sum_{i=1}^N (\alpha_i - \alpha_i^*) k(x_i, x_j) + b \quad (12)$$

مقدار پارامتر b را با استفاده از شرط کوهن-تاکر (KKT) می‌توان به دست آورد. با توجه به شرط KKT رابطه زیر قابل حصول است.

$$\alpha_i (\varepsilon + \xi_i - d_i + w^T \cdot \phi(x_i) + b) = 0 \quad (13)$$

$$\alpha_i^* (\varepsilon + \xi_i^* - d_i - w^T \cdot \phi(x_i) - b) = 0$$

$$(C - \alpha_i) \xi_i = 0$$

$$(C - \alpha_i^*) \xi_i^* = 0 \quad (14)$$

با توجه به رابطه (۱۳) و (۱۴)، α_i و α_i^* نمی‌تواند به طور همزمان غیر صفر باشد و $\alpha_i \alpha_i^* = 0$ است. با توجه به بحث‌های ارائه شده می‌توان به نتایج زیر رسید.

$$\varepsilon - d_i + w^T \cdot \phi(x_i) + b \geq 0 \quad \text{and} \quad \xi_i = 0 \quad \text{if} \quad a_i < C \quad (15)$$

$$\varepsilon - d_i + w^T \cdot \phi(x_i) + b \leq 0 \quad \text{if} \quad a_i > C \quad (16)$$

با توجه به تجزیه و تحلیل‌های مشابه روی α_i^* ، رابطه زیر به دست می‌آید.

$$\max \left\{ -\varepsilon + d_i + w^T \cdot \phi(x_i) \mid a_i < C \text{ or } a_i^* > 0 \right\} \leq b \leq \min \left\{ -\varepsilon + d_i + w^T \cdot \phi(x_i) \mid a_i > 0 \text{ or } a_i^* < C \right\} \quad (17)$$

در رابطه فوق به طور متداول از تابع کرنل گاوسی (RBF)، به صورت $k(x_i, x_j) = \exp(-\gamma \|x_i - x_j\|^2 / 2\gamma^2)$ که در این تحقیق نیز تابع کرنل گاوسی به شکل زیر مورد استفاده قرار گرفته است.

$$k(x_i, x_j) = \exp(-\gamma \|x_i - x_j\|^2) \quad (18)$$

در اینجا γ پارامتر کرنل (RBF) است. در مدل ماشین بردار رگرسیون باید ۳ پارامتر C ، ε و پارامتر کرنل γ تعیین شوند که نقش مهمی در پیش‌بینی توسط ماشین بردار رگرسیون دارند. پارامتر C درجه ریسک تجربی SVR می‌باشد. ε عرض بازه خطا می‌باشد که در شکل (۱) نشان داده شده است. γ عرض تابع گاوسی از تابع کرنل است. در این مقاله، ابتدا پردازش‌های اولیه‌ای (پیش‌پردازش) روی داده‌های ورودی انجام شده است و از نرم افزار LIBSVM برای پیش‌بینی استفاده شده است که یک کتابخانه برای ماشین بردار پشتیبان بوده که بر اساس حداقل کردن مربع خطا عمل می‌کند [۲۲].

پردازش روی داده‌ها نشان می‌دهد. همان طور که ملاحظه می‌شود خطا از مقدار ۱/۸۰۱۷٪ به مقدار ۱/۲۸۲۹٪ کاهش یافته است که کاهش خطا قابل ملاحظه است.

جدول (۲) نتایج حاصل از اجرای SVM با داده‌های معمولی

پارامتر C	پارامتر ϵ	پارامتر γ	%MAPE
0.3	0.003	0.01	1.8017

جدول (۳) نتایج حاصل از اجرای SVM با داده‌های پیش‌پردازش شده

پارامتر C	پارامتر ϵ	پارامتر γ	%MAPE
1.06	0.0009	0.08	1.2829

جدول (۴) مقایسه نتایج مدل ارائه شده با مقاله‌های دیگری که از

داده‌های شبکه EUNITE برای پیش‌بینی استفاده نموده‌اند

روش‌های مختلف	%MAPE
SVM [3]	1.9824
SVM-GA [28]	1.93
Extended bayesian training [29]	1.75
Floating search + SVM [30]	1.70
CA_CA + LM + EA [31]	1.60
FFFB-MCANN [32]	1.58
ARMCRN [33]	1.57
SVR + local prediction [34]	1.52
SOFNN + Bi-level optimization [35]	1.40
مدل پیشنهادی	1.2829

همان طور که در جدول (۴) نشان داده شده است. روش مورد نظر به خاطر پیش‌پردازش روی داده‌های روز خاص و همچنین ورودی‌های دیگر نسبت به مقاله‌های دیگری که از همین داده‌های شبکه EUNITE برای پیش‌بینی استفاده نموده‌اند نتایج بهتری حاصل شده است.


برای مقایسه نتایج حاصل از ماشین بردار پشتیبان با دیگر روش‌ها، برنامه‌ای نیز با کد MATLAB برای پیش‌بینی با روش شبکه عصبی نوشته شده است. در جدول (۵) نتایج حاصل از پیش‌بینی بر حسب تعداد نرون‌های مخفی قابل مشاهده است. همان طور که ملاحظه می‌شود در بهترین حالت، خطا ۱/۹٪ می‌باشد که به مراتب بیشتر از خطای نشان داده شده در جدول (۱) است (قابل ذکر است که ورودی‌هایی که برای شبکه عصبی استفاده می‌شود همان ورودی‌هایی است که برای ماشین بردار پشتیبان استفاده شده است).

همان طور که مشاهده می‌شود در بهترین حالت‌ها و برای همین ورودی‌ها و خروجی‌ها که به ماشین بردار پشتیبان داده شده و البته با نرمالیزه کردن داده‌ها برای شبکه عصبی به صورت جداول (۵) و (۶) در می‌آید. قابل ذکر است که ماشین بردار پشتیبان نیازی به نرمالیزه کردن داده‌ها نداشته و نرمالیزه کردن داده‌ها تأثیری در نتایج به دست آمده ندارد. در جداول زیر بهترین حالت‌های هر کدام از این نرون‌ها نشان داده شده است که زمان آزمایش برای هر کدام از این نرون‌ها بین ۲۵ تا ۵۵ ثانیه است. در هنگامی که از داده‌های پیش‌پردازش شده برای شبکه عصبی استفاده کنیم ملاحظه می‌شود که خطای پیش‌بینی از ۱/۹۱۸٪ به ۱/۶۷٪ می‌رسد. پس نشان می‌دهد که پیش‌پردازش هم بر روی ماشین بردار پشتیبان و هم شبکه عصبی تأثیر گذار است و خطای پیش‌بینی را در هر دو پایین می‌آورد.

دهند. بنابراین به منظور بدست آوردن مدل «خوب»، باید این پارامترها باید به درستی انتخاب شوند. پارامترهایی که باید مشخص شوند عبارتند از:

- هزینه خطا C ؛
- عرض مقدار بازه ϵ ؛
- تابع نگاشت ϕ ؛

همانطور که ذکر شد کاری که در این مقاله انجام شده است و باعث شده که خطای پیش‌بینی کاهش یابد پیش‌پردازشی بر روی داده‌ها در یک روز خاص انجام شده است این پیش‌پردازش را می‌توان به این صورت شرح داد که ما تغییرات پریودی بار در یک روز خاص با توجه به شکل (۳) را در نظر گرفته‌ایم و به صورت جدول (۱) در آورده‌ایم. در این جدول همان طور که مشاهده می‌شود زمانی که بار هیچ تغییری از نظر صعودی و نزولی بودن نمی‌کند عدد یک را به آن اختصاص داده‌ایم. همچنین زمانی که بار در شکل مورد نظر صعودی می‌شود بر حسب میزان صعودی بودن و شیب آن عددی بالاتر از یک اختصاص می‌دهیم و زمانی که شیب بار نزولی می‌شود بر حسب میزان نزولی بودن آن و شیب نزولی شدن آن عددی پایین‌تر از یک در نظر می‌گیریم.



شکل (۳) تغییرات بار الکتریکی بر اساس تغییرات زمانی ساعتی در یک روز خاص

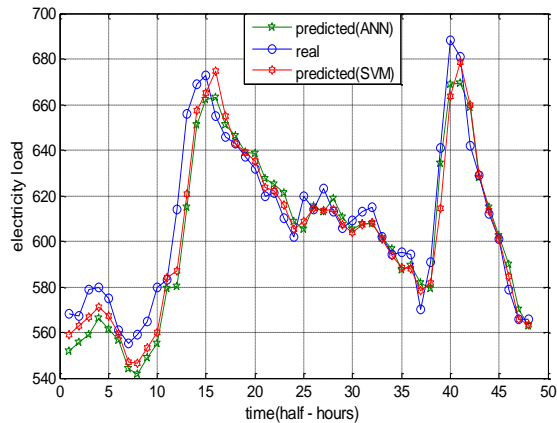
جدول (۱) پیش‌پردازشی (PP) که بر روی داده‌ها بر حسب ساعت (h) انجام شده و به صورت عددی به ورودی‌ها اضافه شده است

h	1	2	3	4	5	6	7	8
PP	0.95	1.6	1.05	0.75	0.2	0.7	1.2	1.3
h	9	10	11	12	13	14	15	16
PP	1.15	2.2	2.2	2.2	1.75	1.2	1.9	1.5
h	17	18	19	20	21	22	23	24
PP	0.85	0.75	0.75	0.4	1.05	0.45	0.6	1.9
h	25	26	27	28	29	30	31	32
PP	0.7	1.45	0.5	0.55	1.15	1.2	1.1	0.35
h	33	34	35	36	37	38	39	40
PP	0.6	1.05	0.95	-0.05	2	3	3	0.65
h	41	42	43	44	45	46	47	48
PP	-0.5	0.25	0.15	0.45	-0.1	0.33	1	1


با توجه به جدول (۱)، اعداد ۱ تا ۴۸ که به صورت ستونی و یک در میان می‌باشد، نیم ساعت‌های بار می‌باشند و اعداد زیر هر کدام از این نیم ساعت‌ها مقادیر پیش‌پردازش در نظر گرفته شده می‌باشد.

جدول (۲) و (۳) به ترتیب پارامترهای SVM و درصد خطا را حاصل از پیش‌بینی به کمک نرم افزار LIBSVM با داده‌های ورودی و با پیش-

پیش‌بینی با استفاده از ماشین بردار پشتیبان کمتر از خطای پیش‌بینی با استفاده از شبکه عصبی است.



شکل (۶) مقایسه بار واقعی و پیش‌بینی شده ساعتی با استفاده از ANN و SVM



شکل (۷) مقایسه خطای نرمالیزه شده ساعتی با استفاده از SVM و ANN

۵- نتیجه گیری

در این مقاله از روش SVM برای پیش‌بینی کوتاه مدت بار استفاده شده است. برای پیش‌بینی از نرم افزار LIBSVM استفاده شده است. به منظور بهبود نتایج، روی داده‌های ورودی پیش‌پردازش صورت گرفته است که منجر به کاهش خطای پیش‌بینی شده است. مقایسه نتایج روش ارائه شده با مقاله‌های دیگری که از داده‌های مشابه برای پیش‌بینی استفاده نموده‌اند، نشان می‌دهد که روش ارائه شده در این مقاله دارای خطای پیش‌بینی کمتری می‌باشد. همچنین مقایسه نتایج حاصل از روش شبکه عصبی و روش ماشین بردار پشتیبان حاکی از برتری روش ماشین بردار پشتیبان است.

مراجع

- [۱] گروه پژوهشی مطالعات سیستم، "مروری بر الگوریتم‌های طراحی شده جهت تهیه نرم افزار پیش‌بینی بار کوتاه مدت شبکه سراسری ایران، گزارش پروژه "خرید نرم افزار پیش‌بینی بار شرکت مدیریت شبکه برق ایران"، پژوهشکده برق، پژوهشگاه نیرو، شهریور ماه ۱۳۸۵
- [2] Rafal Weron, Modeling and Forecasting Electricity Loads and Prices, John Wiley & Sons Ltd, The Atrium, Southern

جدول (۵) نتایج حاصل از اجرای شبکه عصبی با داده‌های معمولی


تعداد نرون مخفی	7	8	9	11	14	20
%MAPE	2.03	2	1.96	1.9	1.92	1.91

جدول (۶) نتایج حاصل از اجرای SVM با داده‌های پیش‌پردازش شده

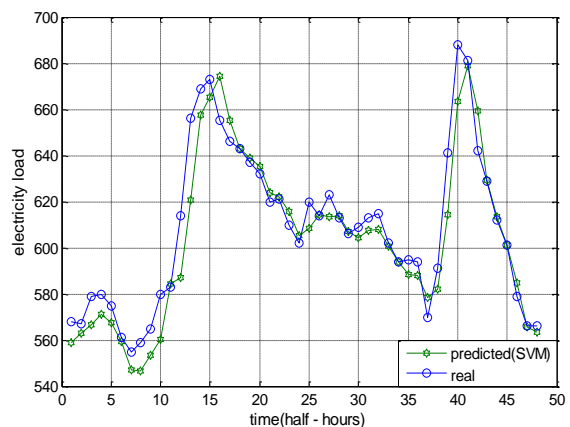
تعداد نرون مخفی	7	8	9	11	14	20
%MAPE	1.83	1.82	1.8	1.84	1.67	1.7

برای شبکه عصبی در بهترین حالت که در شکل (۴) قابل مشاهده است جواب آن ۱/۶۷٪ می‌شود. و در مقایسه با SVM بدتر است.

همان طور که در شکل (۴) و (۵) مشاهده می‌شود پیش‌بینی ماشین بردار پشتیبان در اوایل بهتر از ANN و در اواسط نیز پیش‌بینی بهتری را نسبت به ANN ارائه می‌دهد. شکل (۷) مقایسه کاملی از خطای پیش‌بینی که نرمالیزه شده است، توسط ماشین بردار پشتیبان و شبکه عصبی را به صورت واضح نشان می‌دهد.



شکل (۴) بار واقعی و پیش‌بینی شده با استفاده از ANN



شکل (۵) بار واقعی و پیش‌بینی شده با استفاده از SVM

برای مقایسه بیشتر بین SVM و شبکه عصبی و چگونگی پیش‌بینی هر دو نسبت به بار واقعی، به صورت نموداری هر سه با هم در شکل (۶) آورده شده است. که از شکل قابل تشخیص است که ماشین بردار پشتیبان پیش‌بینی بهتری را انجام داده است. خطای نرمالیزه به دست آمده از ماشین بردار پشتیبان و شبکه عصبی در شکل (۷) قابل مشاهده است. که با توجه به این شکل نیز می‌توان به این نتیجه رسید که در مجموع خطای ناشی از

- Discussion Paper no. 495, Department of Economics, Pontifical Catholic University of Rio de Janeiro, (2005).
- [19] Huang, S.-J., Shih, K.-R. Short-term load forecasting via ARMA model identification including non-Gaussian process considerations, *IEEE Transactions on Power Systems* 18, 673–679, (2003).
- [20] Amjady, N. Short-term hourly load forecasting using time-series modeling with peak load estimation capability, *IEEE Transactions on Power Systems* 16, 798–805, (2001).
- [21] Huang, C.-M., Huang, C.-J. and Wang, M.-L. A particle swarm optimization to identifying the ARMAX model for short-term load forecasting, *IEEE Transactions on Power Systems* 20, 1126–1133, (2005).
- [22] C.-C. Chang and C.-J. Lin. LIBSVM: A Library for Support Vector Machines. [Online]. Available: (2001). <http://www.csie.ntu.edu.tw/~cjlin/libsvm>
- [23] Vojislav K. Learning and soft computing—Support vector machines, *Neural Networks and Fuzzy Logic Models*. Massachusetts: The MIT Press; 2001.
- [24] Vapnik VN. The nature of statistical learning theory. London: Springer; 1999.
- [25] Vapnik, V., The Nature of Statistical Learning Theory. Springer Verlag, New York, USA, 1995.
- [26] <http://neuron.tuke.sk/competition/>.
- [27] A. Badri, Z. Ameli, A. Motie Birjandi. Application of Artificial Neural Networks and Fuzzy logic Methods for Short Term Load Forecasting. *Energy Procedia* 14, 1883 – 1888, (2012).
- [28] Abbas SR, Arif M. Electric load forecasting using support vector machines optimized by genetic algorithm. In: Proc IEEE multitopic conference (INMIC p. 395–99); December 2006.
- [29] Ferreira VH, Alves da Silva AP. Toward estimating autonomous neural network-based electric load forecasters. *IEEE Trans Power Syst*; 22(4):1554–62, 2007
- [30] Tao X, Renmu H, Peng W, Dongjie X. Input dimension reduction for load forecasting based on support vector machine. In: Proc IEEE int conference electric utility Deregulation, Restructuring and Power Technologies (DRPT), vol. 2. p. 510–14, April 2004.
- [31] Amjady N, Keynia F. Mid-term load forecasting of power systems by a new prediction method. *Energy Convers Manage*; 49(10):2678–87, 2008
- [32] Rashid T. Kechadi T. A practical approach for electricity load forecasting. In: Proc world acad sci eng technol conference, vol. 5p. 201–05, . April 2005.
- [33] Rashid T, Huang BQ, Kechadi MT, Gleeson B. Auto-regressive recurrent neural network approach for electricity load forecasting. *Int J Comput Intell*; 3(1):36–44, 2007
- [34] El-Attar EE, Goulermas JY, Wu QH. Forecasting electric daily peak load based on local prediction. In: Proc IEEE PES general meeting; p. 1–6, July 2009.
- [35] Mao H, Zeng XJ, Leng G, Zhai YJ, Keane JA. Short term and mid term load forecasting using a bilevel optimization model. *IEEE Trans Power Syst*; 24(2):1080–90, 2009.
- Gate, Chichester, West Sussex PO19 8SQ, England , (2006).
- [3] Chen, B.J., Chang, M.W. and Lin, C.J. Load forecasting using Support Vector Machines: A study on EUNITE Competition 2001, *IEEE Transactions on Power Systems* 19(4) , 1821–1830, (2004).
- [4] Khotanzad, A., Rohani, R.A., Lu, T.L., Abaye, A., Davis, M. and Maratukulam, D.J. ANNSTLF – A neural-network-based electric load forecasting system, *IEEE Transactions on Neural Networks* 8, 835–846, (1997).
- [5] Khotanzad, A., Rohani, R.A. and Maratukulam, D.J. (1998) ANNSTLF – Artificial neural network short-term load forecaster – Generation three, *IEEE Transactions on Neural Networks* 13, 1413– 1422, (1997).
- [6] Hippert, H.S., Bunn, D.W. and Souza, R.C. Large neural networks for electricity load forecasting: Are they overfitted? *International Journal of Forecasting* 21(3) , 425–434, (2005).
- [7] Taylor, J.W., de Menezes, L. and McSharry, P.E. A comparison of univariate methods for forecasting electricity demand up to a day ahead, *International Journal of Forecasting* 22(1) , 1–16, (2006).
- [8] Darbellay, G.A. and Slama, M. Forecasting the short-term demand for electricity – Do neural networks stand a better chance?, *International Journal of Forecasting* 16, 71–84, (2000).
- [9] Ho, K.L., Hsu, Y.Y., Chen, F.F., Lee, T.E., Liang, C.C., Lai, T.S. and Chen, K.K. Short-term load forecasting of Taiwan power system using knowledge based expert system, *IEEE Transactions on Power Systems* 5, 1214–1221, (1990).
- [10] Senjyu, T., Mandal, P., Uezato, K. and Funabashi, T. Next day load curve forecasting using hybrid correction method, *IEEE Transactions on Power Systems* 20(1) , 102–109, (2005).
- [11] Song, K.-B., Ha, S.-K., Park, J.-W., Kweon, D.-J. and Kim, K.-H. Hybrid load forecasting method with analysis of temperature sensitivities, *IEEE Transactions on Power Systems* 21(2) , 869– 876, (2006).
- [12] Vapnik, V.N. The Nature of Statistical Learning Theory. Springer Verlag, (1995).
- [13] Chen, B.J., Chang, M.W. and Lin, C.J. Load forecasting using Support Vector Machines: A study on EUNITE Competition 2001, *IEEE Transactions on Power Systems* 19(4) , 1821–1830, (2004).
- [14] Mohandes, M. Support Vector Machines for short-term electrical load forecasting, *International Journal of Energy Research* 26, 335–345, (2002).
- [15] Li, Y. and Fang, T. Wavelet and Support Vector Machines for short-term electrical load forecasting, *Proceedings of the Third International Conference on Wavelet Analysis and its Applications*. 1, 399–404, (2003a).
- [16] Taylor, J.W., de Menezes, L. and McSharry, P.E. A comparison of univariate methods for forecasting electricity demand up to a day ahead, *International Journal of Forecasting* 22(1) , 1–16, (2006).
- [17] Ružić, S., Vuckovic, A. and Nikolic, N. Weather sensitive method for short-term load forecasting in Electric Power Utility of Serbia, *IEEE Transactions on Power Systems* 18, 1581–1586, (2003).
- [18] Soares, L.J. and Medeiros, M.C. Modeling and forecasting short-term electricity load: A two-step methodology.

SID



سرویس های
ویژه



سرویس ترجمه
تخصصی



کارگاه های
آموزشی



بلاگ
مرکز اطلاعات علمی



عضویت در
خبرنامه



فیلم های
آموزشی

کارگاه های آموزشی مرکز اطلاعات علمی جهاد دانشگاهی



مباحث پیشرفته یادگیری عمیق؛
شبکه های توجه گرافی
(Graph Attention Networks)



کارگاه آنلاین آموزش استفاده از
وب آوساینس



کارگاه آنلاین مقاله روزمره انگلیسی