

## پیش‌بینی روزانه قیمت برق با استفاده از شاخص‌های تحلیل تکنیکال و ماشین بردار پشتیبان

مریم رضائی آبکنار<sup>۱</sup>، حسین هارون‌آبادی<sup>۲\*</sup>، ابراهیم خرم<sup>۳</sup>

۱- دانشجوی کارشناسی‌ارشد برق، گروه برق، واحد اسلامشهر، دانشگاه آزاد اسلامی، اسلامشهر، ایران، m\_rezaee77@yahoo.com

\* ۲- استادیار گروه برق، واحد اسلامشهر، دانشگاه آزاد اسلامی، اسلامشهر، ایران، haroonabadi@iaau.ac.ir

۳- استادیار گروه برق، واحد اسلامشهر، دانشگاه آزاد اسلامی، اسلامشهر، ایران، ebrahim.khorram@iaau.ac.ir

تاریخ دریافت: ۱۳۹۷/۱۱/۲۰ تاریخ پذیرش: ۱۳۹۷/۱۱/۲۹

**چکیده:** پیش‌بینی دقیق قیمت و بار مصرفی یکی از نیازمندی‌های ضروری بازیگران در بازار برق می‌باشد. سری زمانی قیمت برق به عنوان یک پدیده ذاتا تصادفی با عدم قطعیت بالا نسبت به بار شناخته می‌شود. از سوی دیگر ویژگی غیر ایستا و غیرخطی این سری زمانی، پیش‌بینی رفتار آینده آن را مشکل می‌سازد. با توجه به اینکه در بازارهایی همچون بازار سهام، با استفاده از تحلیل تکنیکال با آزمون قیمت‌های گذشته و حجم مبادلات، حرکت‌های آینده قیمت تا حدی قابل پیش‌بینی است، در این مقاله جهت پیش‌بینی قیمت برق از شاخص‌های تحلیل تکنیکال جهت تحلیل سری زمانی داده‌های بازار برق استفاده می‌شود. این شاخص‌ها به عنوان ویژگی‌های استخراجی از سری زمانی قیمت برق به رگرسیون ماشین بردار پشتیبان اعمال می‌شوند و قیمت برق در افق یک روزه بر روی داده‌های بازار Ontario محاسبه می‌شود.

**کلمات کلیدی:** پیش‌بینی قیمت، بازار برق، تحلیل تکنیکال، بردار ماشین پشتیبان.

### ۱- مقدمه

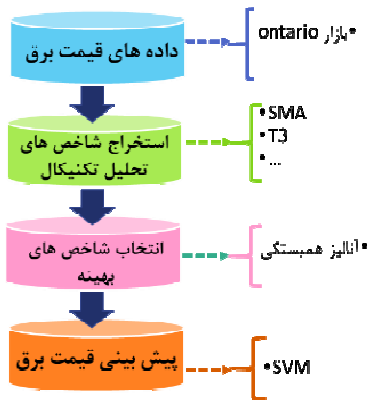
شناخته شده می‌شود. از سوی دیگر ویژگی غیرایستا و غیرخطی این سری زمانی پیش‌بینی رفتار آینده آن را مشکل ساخته است [۴]. لذا پیش‌بینی قیمت برق یک مساله چالش برانگیز در این حوزه است که توجه بسیاری از محققان را به سوی خود جلب کرده و تاکنون مدل‌های مختلفی جهت حل آن مطرح شده است [۱-۱۴]. از جمله این موارد می‌توان به مدل‌های چند عامله مانند تئوری بازی [۵-۶]، روش‌هایی که دینامیک قیمت برق را با استفاده از مدل‌سازی اثرات فاکتورهای اقتصادی و فیزیکی مهم بر روی قیمت برق توصیف می‌کند [۷-۸]، مدل‌های کمی و استوکاستیکی که ویژگی‌های آماری قیمت برق در طول زمان را کمی می‌کنند [۹]، رویکردهای آماری که تکنیک

پیش‌بینی قیمت و بار مصرفی انرژی الکتریکی یکی از شاخصهای اصلی سودآوری بازیگران در بازار برق می‌باشد. تولیدکنندگان توان، صنایع مرتبط، شرکت‌ها، سرمایه‌گذاران و معامله‌گران نیاز به این پیش‌بینی‌ها برای شرکت در این بازار دارند. همچنین سرویس دهندگان برق جهت تخمین مقدار باری که لازم است در لحظات خاصی در اختیار بگذارند به این پیش‌بینی نیازمندند. زیرا مصرف بار تا حدی به قیمت برق وابسته است. تنوع زیادی از تکنیک‌ها جهت حل مسائل پیش‌بینی بار معرفی شده است [۳-۱۱]. به طور کلی سری زمانی قیمت برق به عنوان یک پدیده ذاتا تصادفی با عدم قطعیت بالا

نتایج بدست آمده از پیش بینی قیمت برق گزارش شده است. در نهایت در بخش ۴، به جمع بندی و پیشنهاد جهت ادامه کار پرداخته شده است.

## ۲- تئوری روش پیشنهادی

شکل ۱ فرآیند کلی استفاده شده در این مقاله را نشان می‌دهد. همانطور که در این شکل مشخص است از سری داده‌های قیمت بازار برق، شاخص‌های تحلیل تکنیکال استخراج می‌گردند. سپس به منظور استخراج شاخص‌های بهینه از آنالیز همبستگی استفاده شده و در نهایت با استفاده از این شاخص‌های بهینه، قیمت برق توسط شبکه عصبی SVM پیش بینی می‌گردد. در ادامه به توضیح هر بخش پرداخته می‌شود.



شکل ۱ - فرآیند کلی روش پیشنهادی جهت پیش بینی قیمت برق

### ۲-۱- شاخص‌های تحلیل تکنیکال

تحلیل تکنیکال یا تحلیل فنی روشی برای پیش‌بینی و تحلیل قیمت‌ها از طریق مطالعه وضعیت گذشته بازار است. در این تحلیل از طریق بررسی تغییرات و نوسان‌های قیمت‌ها و حجم معاملات و عرضه و تقاضا می‌توان وضعیت قیمت‌ها در آینده را پیش‌بینی کرد. این روش تحلیلی در بازار ارزهای خارجی (FOREX)، بازارهای بورس اوراق بهادار، بازارهای نفت، طلا و دیگر فلزات گران‌بها کاربرد گسترده‌ای دارد. تحلیلگران تکنیکال ارزش ذاتی اوراق بهادار را اندازه‌گیری نمی‌کنند، در عوض از نمودارها و ابزارهای دیگر برای شناسایی الگوهایی که می‌تواند فعالیت آتی سهم را پیش‌بینی کنند، بهره می‌جویند [۱۵]. جدول (۱) شاخص‌های تحلیل تکنیکال مورد استفاده در این مقاله را به ترتیب بیان می‌کند.

های آماری پیش بینی را به کار می‌گیرند و تکنیک‌های هوش محاسباتی مانند شبکه‌های عصبی [۴ و ۱۰] روش‌های آماری غیرپارامتریک و غیرخطی که جهت توصیف رفتار پیچیده سری زمانی قیمت برق معرفی شده‌اند، اشاره نمود.

اگرچه امروزه محققان برای مساله پیش بینی دقیق، مدل‌های مختلفی را ارائه کرده‌اند، لیکن به دلیل عدم قطعیت بالا در زمینه پیش بینی قیمت برق به دلیل وجود انواع فاکتورهای مختلف مانند شرایط آب و هوایی، قیمت سوخت، از بین رفتن محیط زیست و ... ارتقا مدل‌ها جهت داشتن پیش بینی دقیق و تخمین عدم قطعیت‌ها مورد نیاز است. یکی از روش‌های ارتقا مدل‌های پیش-بینی، بهبود ویژگی‌هایی است که از سری زمانی قیمت برق استخراج می‌گردد [۱۴] و علاوه بر سری زمانی خام قیمت برق، به عنوان ورودی، به مدل داده می‌شود. در این تحقیق با توجه به شباهت بازار برق به سایر بازارهای اقتصادی، پیشنهاد استفاده از شاخص‌هایی که در تحلیل داده‌های بازار سهام استفاده می‌شوند در پیش بینی قیمت برق داده شده است. در واقع مساله‌ای که در این پژوهش به دنبال پاسخگویی به آن هستیم این است که "یا شاخص‌هایی که عمدتاً در حوزه بورس جهت پیش بینی قیمت سهام استفاده می‌شوند می‌توانند به بهبود پیش بینی در زمینه قیمت برق نیز کمک نمایند؟" اکثر تحقیقات انجام شده در زمینه پیش بینی قیمت برق، تنها از سری زمانی داده‌های گذشته قیمت برق جهت تخمین و پیش بینی قیمت برق استفاده می‌کنند. این در حالی است در بازارهایی همچون بازار سهام، با استفاده از تحلیل تکنیکال، با آزمون قیمت‌های گذشته و حجم مبادلات، قیمت را پیش بینی می‌کنند. اساس این تحلیل‌ها بر استفاده از نمودار و رابطه‌های ریاضی و هندسی متمرکز است تا بدین گونه روندهای کوچک و بزرگ بدست آیند. برای انجام این تحلیل شاخص‌های مختلفی همچون میانگین متحرک استفاده می‌شوند. همچنین نظر به مزایا و کارایی شبکه عصبی SVM در قیاس با بسیاری از روشهای محاسباتی هوشمند جهت طبقه بندی و پیش بینی قیمت، در این تحقیق از این شبکه عصبی استفاده می‌گردد.

بر این اساس در بخش ۲، تئوری روش پیشنهادی شامل توصیف روند کلی الگوریتم، تعریف و استخراج شاخص‌های تحلیل تکنیکال و روش مدلسازی توضیح داده می‌شود. در بخش ۳، مطالعات عددی و

جدول ۱- شاخص های تحلیل تکنیکال مورد استفاده

شماره ویژگی	نماد ویژگی	توصیف ویژگی
۱	SMA	میانگین متحرک ساده
۲	Short	میانگین متحرک سریع
۳	Long	میانگین متحرک آهسته
۴	RSI	شاخص قدرت نسبی
۵	APO	اسیلاتور قیمت مطلق
۶	EMA	میانگین متحرک نمایی
۷	TMA	میانگین متحرک زاویه‌ای
۸	DEMA	میانگین متحرک نمایی دوپل
۹	T <sub>۳</sub>	میانگین متحرک نمایی سه گانه نوع ۱
۱۰	TEMA	میانگین متحرک نمایی سه گانه نوع ۲
۱۱	WMA	میانگین متحرک وزن دار
۱۲	MACDhIS	واگرایی همگرایی میانگین متحرک
۱۳	Fastptk	استوکستیک سریع
۱۴	Spctk	استوکستیک
۱۵	Hhvts	باند بالا
۱۶	Llvts	باند پایین
۱۷	Mprcts	قیمت میانه
۱۸	MIDPNT	نقطه میانه
۱۹	Accts	باند شتاب
۲۰	Mom	مومنتوم
۲۱	CMO	اسیلاتور تغییر مومنتوم
۲۲	ROCP	نرخ تغییر
۲۳	ROC۱۰۰	درصد نرخ تغییر
۲۴	MAX	بیشینه
۲۵	MIN	کمینه
۲۶	STD	انحراف معیار
۲۷	Cloud	ایشیموکو
۲۸	LR	رگرسیون خطی
۲۹	TSF	پیش بینی سری زمانی
۳۰	ARO	اسیلاتور آرون
۳۱	WilliamsR	ویلیامز R%
۳۲	ATR	میانگین بازه صحیح
۳۳	NATR	میانگین بازه صحیح نرمال شده
۳۴	MiddleLine	خط وسط
۳۵	UpperBand	باند بالا
۳۶	LowerBand	باند پایین
۳۷	UpperBand۱	باند بالای نوع ۲

۳۸	LowerBand\	باند پایین نوع ۲
۳۹	PlusDM	شاخص جهت دار مثبت
۴۰	NegDM	شاخص جهت دار منفی
۴۱	DX	شاخص حرکت جهت دار
۴۲	ADXt	میانگین حرکت جهت دار
۴۳	CCI	شاخص کانال کالا

معین از مقادیر واقعی می‌باشند، را نادیده می‌گیرد [۱۷]. این تابع به صورت رابطه زیر تعریف می‌شود:

$$L(y, f(x)) = |y - f(x)|_{\varepsilon} = \begin{cases} 0 & \text{if } |y - f(x)| \leq \varepsilon \\ |y - f(x)| - \varepsilon & \text{if } |y - f(x)| > \varepsilon \end{cases} \quad (1)$$

بطوریکه در آن  $y$  داده‌های حقیقی،  $f(x)$  تابع رگرسیون و  $\varepsilon$  حد خطا می‌باشد. به عبارت دیگر این تابع خطا، مقادیر خطای کمتر از  $\varepsilon$  را در نظر نمی‌گیرد.

مسئله تقریب یک مجموعه از داده‌های زیر را در نظر می‌گیریم:

$$D = \{(x^1, y^1), \dots, (x^l, y^l)\}, \quad (x \in R^n, y \in R) \quad (2)$$

تابع رگرسیون به وسیله تابع زیر تخمین زده می‌شود.

$$f(x) = \langle \omega, x \rangle + b \quad (3)$$

که  $\langle \cdot \rangle$  علامت ضرب داخلی،  $\omega$  بردار نرمال و  $b$  ضریب بایاس هستند که باید از داده‌ها تخمین زده شوند. تابع بهینه رگرسیون به وسیله مینیمم تابع زیر بیان می‌گردد.

$$\phi(\omega, x) = \frac{1}{2} \|\omega\|^2 + C \sum_{i=1}^l (\xi_i^- + \xi_i^+) \quad (4)$$

با در نظر گرفتن قیود زیر

$$\text{subject to } \begin{cases} y_i - (\langle \omega, x_i \rangle + b) \leq \varepsilon + \xi_i \\ (\langle \omega, x_i \rangle + b) - y_i \leq \varepsilon + \xi_i^* \\ \xi_i, \xi_i^* \geq 0 \end{cases} \quad (5)$$

که  $C$  یک مقدار از پیش تعیین شده بوده و  $\xi_i^-$  و  $\xi_i^+$  متغیرهای شل هستند که قیود بالا و پایین خروجی سیستم را تعیین می‌کنند. اگر داده‌ها به صورت خطی مجزا از هم باشند یک سطح بهینه که داده‌ها را بدون خطا و با حداکثر فاصله میان صفحه و نزدیکترین نقاط آموزشی (بردارهای پشتیبان) تفکیک می‌نماید، مورد نظر است. اگر نقاط آموزشی را به صورت  $[x_i, y_i]$  و بردار ورودی  $x_i \in R^n$  تعریف

## ۲-۲- ماشین بردار پشتیبان

ماشین بردار پشتیبان تکنیکی جدید از روش‌های یادگیری ماشین است که برای اولین بار در سال ۱۹۹۲ در کنفرانس COLT به وسیله وپنیک و همکارانش معرفی گردید. بر اساس مطالعات انجام شده ماشین بردار پشتیبان در پیش‌بینی‌ها نسبت به سایر شبکه‌های عصبی از دقت بالاتری برخوردار است [۱۶]. ویژگی مهم ماشین بردار پشتیبان این است که برخلاف الگوریتم‌های کلاسیک و رگرسیون‌های خطی که به وسیله مینیمم کردن قدر مطلق خطا یا توان دوم خطا عمل می‌کنند، آن‌ها ریسک عملیاتی را مینیمم می‌کنند [۱۶]. همچنین مزیت دیگر ماشین بردار پشتیبان این است که با استفاده از هسته‌های غیرخطی قادر به تصمیم‌گیری غیرخطی نیز می‌باشد. انتخاب هسته‌های مناسب برای ماشین بردار پشتیبان، منجر به برتری آن نسبت به سایر رویکردهای مبتنی بر تصمیم‌گیری خطی شده است.

مدل‌های ماشین‌های بردار پشتیبان به دو گروه عمده شامل مدل طبقه‌بندی ماشین بردار پشتیبان و مدل رگرسیون ماشین بردار پشتیبان تقسیم بندی می‌شوند. از مدل طبقه‌بندی ماشین بردار پشتیبان جهت حل مسائل طبقه‌بندی داده‌هایی که در کلاس‌های مختلف قرار می‌گیرند، استفاده می‌گردد و مدل رگرسیون ماشین بردار پشتیبان در حل مسائل پیش‌بینی و تخمین کاربرد دارد.

ماشین بردار پشتیبان در ابتدا برای شناسایی و طبقه‌بندی الگوها و سپس برای رگرسیون توسعه داده شد. همانگونه که بیان گردید ماشین بردار پشتیبان مبتنی بر مینیمم کردن ساختار ریسک می‌باشد که از تئوری آموزش آماری گرفته شده است. وپنیک برای کاربرد ماشین‌های بردار پشتیبان در مسائل رگرسیون از تابع خطایی استفاده کرد که خطاهایی که در یک  $\varepsilon$ -Insensitive به نام فاصله

$$R(f_i, y) = \frac{\text{cov}(f_i, y)}{\sqrt{\text{var}(f_i) \text{var}(y)}} \quad (8)$$

که در آن  $\bar{f}_i$ ، ویژگی  $\bar{y}$  و  $y$  خروجی که قیمت برق است. تخمین برای  $m$  نمونه به صورت زیر است:

$$R(f_i, y) = \frac{\sum_{k=1}^m (f_{k,i} - \bar{f}_i)(y_k - \bar{y})}{\sqrt{\sum_{k=1}^m (f_{k,i} - \bar{f}_i)^2 \sum_{k=1}^m (y_k - \bar{y})^2}} \quad (9)$$

که در آن  $f_{k,i}$  ویژگی  $\bar{y}$  برای نمونه  $k$ ام،  $y_k$  خروجی نمونه  $k$ ام و  $\square$  متوسط خروجی برای نمونه ها می باشد. برای بررسی ویژگی های بهینه از روش آنالیز همبستگی بر روی کل داده ها استفاده می-شود.

## ۲-۴-مدل پیش بینی

پیش بینی قیمت برق و بررسی آخرین روشهای موجود در این زمینه نشان می‌دهد که این روشها به سه دسته کلی مدل های تئوری، بازیها، مدل های شبیه ساز و مدل های سری زمانی تقسیم بندی می-شوند. در مدل های سری زمانی می توان به تقسیم بندی شامل مدل های آماری، مدل های هوش مصنوعی و مدل های رگرسیون اشاره نمود. مدل های سری زمانی به مقادیر گذشته پارامترهای تحت پیش بینی نیاز داشته و فرض بر این است که تغییرات موجود در داده ها، از الگوهای خاصی پیروی می کنند. مدل های سری زمانی ARIMA و GARCH دارای رویکرد خطی بوده و بسیار متداول هستند. از جمله مدل های سری زمانی غیرخطی می توان به شبکه عصبی پیشرو، شبکه های عصبی بازگشتی و ماشین بردار پشتیبان اشاره کرد.

روش های سنتی مانند بیزین و دلتا به دلیل مشکلات پیاده سازی، بار محاسباتی بالا و فرضیات همراه با شکی که در خصوص توزیع داده می کنند، کاربرد محدودی دارند. از سوی دیگر روش های چون شبکه عصبی، مشکلاتی مانند یافتن نقطه بهینه کلی را دارند. در این بین، قابلیت هایی از جمله در نظر گرفتن حداقل کلی برخلاف شبکه های پرسپترون که حداقل های محلی را در نظر می گیرند، تضمین همگرایی برخلاف برخی از شبکه های عصبی و کارایی در بسیاری از مسائل واقعی، SVM ها را به روشی کارآمد جهت طبقه بندی مناسب برای پیش بینی قیمت تبدیل نموده است. SVM ها نگاشتی غیرخطی از داده ها به فضای چند بعدی را ایجاد می کنند و

کنیم، در حالتی که داده ها به صورت خطی قابل تفکیک باشند، معادله به صورت زیر است.

$$y = f(x) = \text{sign} \left[ \sum_{i=1}^N y_i \alpha_i (x_i, x) + b \right] \quad (6)$$

که در آن  $y$  خروجی معادله و  $y_i$  ارزش طبقه نمونه آزمایشی  $x_i$  می باشد. بردار  $x = (x_1, x_2, \dots, x_n)$  نشان دهنده یک داده ورودی و بردارهای  $x_i, i = 1, 2, \dots, N$  بردارهای پشتیبان هستند. اگر داده ها به صورت خطی قابل تفکیک نباشند، می توان با اعمال پیش پردازش، نمونه ها را به فضایی بالاتر برد. در این حالت رابطه (۶) به رابطه (۷) تغییر می یابد:

$$y = f(x) = \text{sign} \left[ \sum_{i=1}^N y_i \alpha_i K(x_i, x) + b \right] \quad (7)$$

تابع  $K(x_i, x)$  تابع کرنلی است که برای ایجاد ماشین های با انواع مختلفی از سطوح غیرخطی در فضای داده ها، ضرب های داخلی تولید می کند. برای مدل رگرسیون ماشین بردار پشتیبان از کرنل های مختلفی استفاده می شود که عبارتند از خطی، درجه دوم، گوسی و چند جمله ای. در ساخت یک مدل کارآمد ماشین بردار پشتیبان، پارامترهای مدل باید با استفاده از یک روش بهینه سازی به طور دقیق محاسبه گردند. این پارامترها عبارتند از:


- نوع تابع کرنل
- پارامتر تابع کرنل  $\sigma^2$
- پارامتر تنظیم کننده C
- پارامتر دقت  $\epsilon$  مربوط به حداکثر خطا در ناحیه Insensitive-  $\epsilon$  یا حداکثر شعاع لوله واقع در اطراف تابع رگرسیون

## ۲-۳-انتخاب ویژگی

تاکنون روشهای مختلفی جهت انتخاب ویژگی ارائه شده است. یکی از روش های مناسب در زمانی که هدف، رگرسیون داده- هاست، روش آنالیز همبستگی می باشد. در روش آنالیز همبستگی می توان از بین دو ویژگی با همبستگی مشخص یکی را حذف کرد و این حذف می تواند بر اساس یک سطح آستانه برای مقدار همبستگی بین ویژگی ها یا برای تعدادی ویژگی های حذفی از بین کل مجموعه انجام شود. ضریب همبستگی پیرسون از رابطه زیر بدست می آید [۱۸]:


متحرک نمایی ارائه شده است. شکل ۳ عملکرد این شاخص ها را نشان می دهد. همانطور که دیده می شود  $T3$  قدرت نرم سازی بیشتری داشته و TEMA سرعت بیشتری نسبت به میانگین متحرک نمایی معمولی دارد.

از شاخص های استخراج شده در قسمت قبل با استفاده از روش آنالیز همبستگی ۳۹ شاخص باقی می ماند که به عنوان ورودی به ماشین بردار پشتیبان داده می شوند.



شکل ۲- الگوریتم مورد استفاده برای آموزش، و تست روش

پیشنهادی



شکل ۳- مقایسه دو روش مختلف بدست آوردن میانگین سه گانه

نیازی به دانستن توزیع داده ها در آنها نیست. از این رو در این مقاله از این مدل همراه با کرنل RBF استفاده شده است. با توجه به کرنل در نظر گرفته شده، SVM مربوطه دو پارامتر که یکی عدد ثابت و دیگری ضریب موجود در تابع نمایی است را دارا می باشد. برای دستیابی به نتایج مناسب لازم است که پارامترهای مربوط به SVM تنظیم و بهینه شود. بهینه سازی باید به گونه ای باشد که تابع هزینه را حداقل نماید. در اینجا تابع هزینه ای که قصد حداقل کردن آن را داریم میانگین مربعات خطا بین مقدار پیش بینی شده و مقدار واقعی قیمت برق است. الگوریتم پیاده سازی شده به صورت شکل ۲ است. همانطور که دیده می شود داده های هر ماه به صورت جداگانه بارگذاری می شوند. بنابراین الگوریتم ۱۲ بار برای  $j=1,2,\dots,12$ ; Month(j) اجرا می گردد. در ابتدا داده ها با استفاده از تابع zscore هنجار می شود به گونه ای که میانگین آنها صفر و انحراف معیار آنها یک گردد. در هر بار اجرا، ۷۰٪ داده ها به عنوان داده آموزش که از آنها برای آموزش SVM استفاده می شود و ۳۰٪ آنها به عنوان داده تست مورد استفاده قرار می گیرد. پس از آموزش SVM، داده های تست به شبکه داده شده و میانگین مربع خطا برای آن محاسبه می گردد.

### ۳- مطالعات عددی

دادگان مورد استفاده برای تحلیل های این تحقیق مربوط به دادگان قیمت برق بازار برق Ontario می باشد [۱۹]. این قیمت ها مربوط به سال ۲۰۱۰ در ماه های مختلف است که قیمت برق بسته شده را به صورت ساعتی نشان می دهند. جهت آموزش و ارزیابی روش پیشنهادی، لازم است داده ها به دو دسته آموزش و تست دسته بندی شود برای این کار از ۷۰٪ داده ها به عنوان داده آموزش و از ۳۰٪ باقی مانده به عنوان داده تست استفاده می شود. برای مثال در داده های قیمت برق، داده های مربوط به ۲۴ روز آن به عنوان داده آموزش و ۶ روز دیگر به عنوان داده تست در نظر گرفته می شود.

هر یک از شاخص های مطرح شده در جدول (۱) از روی سری زمانی داده قیمت برق با پنجره زمانی ۱۵ ساعت استخراج می گردد. برای مثال همانطور که در جدول مشخص است، چندین شکل مختلف برای میانگین گیری سه گانه معرفی شده است که یکی از آنها جهت بهبود عمل هموارسازی و دیگری جهت بهبود تاخیر موجود در میانگین

### ۳-۱- پیش بینی براساس داده های ساعتی

به منظور پیش بینی قیمت برق به صورت ساعتی، از الگوریتم مورد استفاده در شکل ۲ استفاده می‌شود.

شکل ۴ خروجی قیمت برق توسط SVM (نمودار قرمز) و قیمت برق واقعی (نمودار آبی) را برای داده های آموزش و تست به ازای ماه اول ( $j=1$ ) نشان می دهد.

سپس الگوریتم موجود در شکل ۲ برای تمام ماهها اجرا می‌شود. بطوریکه  $Z$  از ۱ تا ۱۲ تنظیم می‌گردد. جدول (۲) مقدار خطای RMSE به ازای ماههای مختلف سال را نشان می دهد.

همانطور که از جدول (۲) مشخص است میانگین خطا بر روی همه ماههای سال برابر  $0/1311$  و بازه تغییرات از  $0/1001$  تا  $0/1429$  می- باشد. مشخص است که کمترین خطا مربوط به ماه جولای است. پس از آن کمترین خطا مربوط به ماه آگوست و بیشترین خطا مربوط به ماه سپتامبر است. لذا فصول مختلف تاثیری بر کاهش یا افزایش خطای پیش بینی نداشته است. شکل ۵ نمودار قیمت برق را برای دو ماه با کمترین و بیشترین خطا در جدول (۲) نشان می دهد.

### ۳-۲- پیش بینی براساس داده های روزانه:

نتایج بخش قبل بر اساس داده های موجود در یک ساعت قبل بود. در صورتی که بخواهیم افق پیش بینی را بیشتر کنیم، پیش بینی را بر اساس داده های یک روز قبل انجام می دهیم. در این حالت مقدار خطای RMSE برای هر ماه مطابق جدول (۳) بدست می‌آید.

مقایسه جداول (۲) و (۳) نشان می دهد که برای همه ماهها، با افزایش افق پیش بینی، خطای پیش بینی افزایش می‌یابد. با این وجود این افزایش برای همه ماهها ثابت نیست؛ به گونه ای که هنگامی که افق پیش بینی ساعتی است، ماه مارس بیشترین خطا را دارد، در حالی که در افق پیش بینی یک روزه، ماه سپتامبر بیشترین خطا را به خود اختصاص داده است.

### ۴- نتیجه گیری و پیشنهادات:

در این مقاله جهت پیش بینی قیمت برق از شاخصهای تحلیل تکنیکال جهت تحلیل سری زمانی داده های برق با استفاده از شبکه عصبی SVM و روش بهینه یابی اجتماع ذرات استفاده شد. پیش

بینی با افق یک ساعته و یک روزه بر روی داده های بازار Ontario نتایج زیر را به دنبال داشت:

۱- استفاده از شاخص های تحلیل تکنیکال به عنوان ورودی در مدل SVM قادر به تخمین خوبی از قیمت برق می باشد.

۲- خطای پیش بینی رابطه ای با فصلی که آن ماه در آن قرار گرفته است نداشته و مشاهده می‌گردد که بیشترین و کمترین خطا در دو ماه متوالی رخ می‌دهند.

۳- خطای پیش بینی هنگامی که افق پیش بینی یک روزه است بیش از خطای افق یک ساعته می‌باشد؛ که نتیجه قابل انتظاری است. با این وجود، این افزایش برای همه ماهها ثابت نیست.


در راستای تکمیل نتایج این تحقیق، پیشنهادات زیر مطرح می‌گردد:

۱- استفاده از دادگان بازارهای دیگر جهت بررسی الگوریتم پیشنهاد شده در این مقاله

۲- بررسی فصلی دادگان علاوه بر تحلیل ماهانه آنها و استفاده از شاخص های تحلیل تکنیکال با پنجره زمانی متناسب با آن، مثلا میانگین گیری متحرک با پنجره زمانی چند روزه.

۳- بررسی نحوه ترکیب شاخص های تحلیل تکنیکال کوتاه مدت (پنجره زمانی چند ساعته) و بلند مدت (پنجره زمانی چند روزه)

۴- استفاده از سایر روش های انتخاب شاخص های بهینه به خصوص هنگامی که تعداد شاخص ها افزایش می‌یابند.

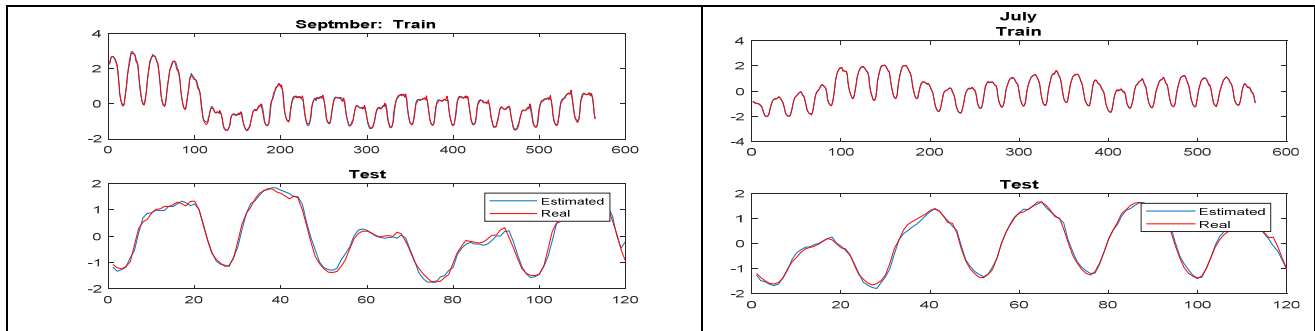


شکل ۴- قیمت برق توسط SVM (نمودار قرمز) و قیمت برق واقعی (نمودار آبی) برای داده های آموزش (شکل بالا) و تست (شکل پایین) در ماه ژانویه

سال ۲۰۱۰

جدول ۲- مقدار خطای RMSE برای ماه‌های مختلف سال ۲۰۱۰ (افقی پیش بینی یک ساعته) برای هر ماه

ماه	خطای RMSE	ماه	خطای RMSE	ماه	خطای RMSE
January	۰/۱۲۵۳	May	۰/۱۲۹۹	September	۰/۱۴۲۹
February	۰/۱۳۹۱	June	۰/۱۲۹۰	October	۰/۱۲۶۰
March	۰/۱۸۲۴	July	۰/۱۰۰۱	November	۰/۱۲۳۲
April	۰/۱۳۱۶	August	۰/۱۰۵۰	December	۰/۱۳۹۲



شکل ۵- قیمت برق توسط SVM (نمودار قرمز) و قیمت برق واقعی (نمودار آبی) برای داده‌های آموزش (شکل بالا)

و تست (شکل پایین) برای ماه جولای و سپتامبر سال ۲۰۱۰

جدول ۳- مقدار خطای RMSE برای ماه‌های مختلف سال ۲۰۱۰ (افقی پیش بینی یک روزه) برای هر ماه

ماه	خطای RMSE	ماه	خطای RMSE	ماه	خطای RMSE
January	۰/۲۶۰۱	May	۰/۳۹۱۶	September	۰/۶۰۵۴
February	۰/۴۰۵۰	June	۰/۷۴۵۲	October	۰/۲۵۴۷
March	۰/۵۶۳۵	July	۰/۳۶۶۴	November	۰/۳۲۳۴
April	۰/۳۸۳۶	August	۰/۲۶۶۸	December	۰/۴۱۴۳

## مراجع:

[۳] S. Nitin Anand, A. Khosravi, and B. Ketan Panigrahi.

"Prediction interval estimation of electricity prices using PSO-tuned support vector machines." IEEE Transactions on Industrial Informatics ۱۱.۲ (۲۰۱۵): ۳۲۲-۳۳۱.

[۴] O. Abedini, N. Amjady, M. shafie-khah, J.P.S Catalao, "Electricity price forecast using combinatorial neural network trained by a new stochastic search method," Energy conversion and management, vol. ۱۰۵, pp. ۶۴۲-۶۵۴, ۲۰۱۵.

[۱] A. Khosravi and S. Nahavandi, "Load forecasting using interval type-۲ fuzzy logic systems: Optimal type reduction," IEEE Trans. Ind. Informat., vol. ۱۰, no. ۲, pp. ۱۰۵۵-۱۰۶۳, May ۲۰۱۴.

[۲] C. Borges, Y. Penya, and I. Fernandez, "Evaluating combined load forecasting in large power systems and smart grids," IEEE Trans. Ind. Informat., vol. ۹, no. ۳, pp. ۱۵۷۰-۱۵۷۷, Aug. ۲۰۱۳.

[۱۵] [www.tradingtechnologies.com](http://www.tradingtechnologies.com)

[۱۶] V, Vladimir. *The nature of statistical learning theory*. Springer science & business media, ۲۰۱۳

[۱۷] B. Debasish, S. Pal, and D. Ch Patranabis. "Support vector regression." *Neural Information Processing-Letters and Reviews* ۱۱.۱۰ -۲۰۳-۲۲۴, ۲۰۰۷

[۱۸] W. Lo, Andrew, H., Mamayasky and J. Wang, "Foundations of technical analysis: computational algorithm, statistical inference and empirical implementation". *The Journal of finance*, ۵۵(۴), ۱۷۰۵-۱۷۶۵, ۲۰۰۰.

[۱۹] [www.pjm.com](http://www.pjm.com)

[۵] Z. Hu, L. Yang, Z. Wang, , D. Gan, ,W. Sun & K. Wang. *A game-theoretic model for electricity markets with tight capacity constraints*. *International Journal of Electrical Power and Energy Systems*, ۳۰, ۲۰۷-۲۱۵. ۲۰۰۸

[۶] A. A. Ladjici, A. Tiguercha, &, M. Boudour. *Nash equilibrium in a two-settlement electricity market using competitive coevolutionary algorithms*. *International Journal of Electrical Power and Energy Systems*, ۵۷, ۱۴۸-۱۵۵. ۲۰۱۴

[۷] V. Gonzalez, J. Contreras & D. W. Bunn. *Forecasting power prices using a hybrid fundamental-econometric model*. *IEEE Transactions on Power Systems*, ۲۷(۱), ۳۶۳-۳۷۲, ۲۰۱۲

[۸] D.Liebl, *Modeling and forecasting electricity spot prices: a functional data perspective*. *Annals of Applied Statistics*, ۷(۳), ۱۵۶۲-۱۵۹۲, ۲۰۱۳

[۹] J. W. Taylor, *Triple seasonal methods for short-term electricity demand forecasting*. *European Journal of Operations Research*, ۲۰۴, ۱۳۹-۱۵۲, ۲۰۱۰

[۱۰] P, Ioannis P., and A. S. Dagoumas. "Day-ahead electricity price forecasting via the application of artificial neural network based models." *Applied Energy* ۱۷۲: ۱۳۲-۱۵۱, ۲۰۱۶

[۱۱] Weron. R, "Electricity price forecasting: A review of the state-of-the-art with a look into the future." *International Journal of Forecasting* ۳۰.۴: ۱۰۳۰-۱۰۸۱, ۲۰۱۴

[۱۲] A. Khosravi, S. Nahavandi, D. Creighton, and A. Atiya, "Lower upper bound estimation method for construction of neural network-based prediction intervals," *IEEE Trans. Neural Netw.*, vol. ۲۲, no. ۳, pp. ۳۳۷-۳۴۶, Mar. ۲۰۱۱.

[۱۳] G. Pierre, Y. Goude, and R. Nedellec. "Additive models and robust aggregation for GEFCom probabilistic electric load and electricity price forecasting." *International Journal of Forecasting* ۳۲.۳: ۱۰۳۸-۱۰۵۰, ۲۰۱۶

[۱۴] O. Abedinia, N. Amjady, H. Zareipour, "A new feature selection technique for load and price forecast of electrical power systems", *IEEE Transactions on Power Systems*, Vol. ۳۲.۱: ۶۲-۷۴, ۲۰۱۷.

# Forecasting Daily Electricity Market Price using Technical Analysis Indices and Support Vector Machine

Maryam Rezaei<sup>۱</sup>, Hossein Haroonabadi<sup>۲,\*</sup> and Ebrahim Khorram<sup>۲</sup>

<sup>۱</sup> Student of Electrical Engineering, Islamshahr Branch, Islamic Azad University, Islamshahr, Iran

<sup>۲</sup> Department of Electrical Engineering, Islamshahr Branch, Islamic Azad University, Islamshahr, Iran

**Abstract:** Forecasting the electricity price is important for electricity market players. Time series of the electricity price -as an inherently random phenomenon- have high uncertainty relative to the load. On the other hand, the non-stationary and non-linear characteristics of this time series make its forecasting difficult. On markets like the stock market, one can somehow forecast future price movements using technical analyses along with testing past prices and the volume of transactions. Therefore, this paper uses technical analysis indices for analyzing the time series data of the electricity market to forecast the electricity price. These indices are used as features extracted from time series of electricity price and applied to a Support Vector Machine (SVM) regression, through which the electricity price is predicted on daily horizon on Ontario electricity market.

**Keywords:** Price forecasting, Electricity market, Technical analysis, Support Vector Machine.