

فصلنامه‌ی مطالعات اقتصاد انرژی / سال نهم / شماره‌ی ۳۴ / پاییز ۱۳۹۱ / صفحات ۱۶۰-۱۳۷

مقایسه‌ی مدل‌های SVR و GARCH در پیش‌بینی بی‌ثباتی قیمت نفت

نفیسه زهره وند*

مدرس گروه ریاضی دانشگاه آزاد اسلامی واحد توپسرکان، n.zohrevand@gmail.com

مجید صادقی‌فر

استادیار گروه آمار، دانشگاه بوعلی سینا همدان sadeghifar@basu.ac.ir

حسن بشیری

مربی گروه مهندسی کامپیوتر و فناوری اطلاعات، دانشگاه صنعتی همدان bashiri@hut.ac.ir

یونس زهره‌وند

مربی گروه ریاضی، دانشگاه آزاد اسلامی واحد توپسرکان، zohrevand2002@yahoo.com

تاریخ دریافت: ۹۱/۳/۱۳ تاریخ پذیرش: ۹۱/۶/۲

چکیده

از آن‌جا که نفت خام یک عنصر استراتژیک در بسیاری از صنایع و بازارها می‌باشد، پیش‌بینی قیمت و شناسایی روند حرکت آن همواره مورد توجه محققان بوده است. امروزه استفاده از روش‌های غیرکلاسیک مانند تکنیک‌های هوش مصنوعی و یادگیری ماشین در مدل‌سازی و پیش‌بینی رفتار سیستم‌های پیچیده بسیار متداول شده است. در سال‌های اخیر یکی از روش‌های جدید یادگیری ماشین با نام ماشین بردار پشتیبان (SVM) کاربرد گسترده‌ای در مسائل رده‌بندی، رگرسیون و به ویژه پیش‌بینی سری‌های زمانی داشته است. این روش که براساس نظریه‌ی یادگیری آماری ساخته شده است، به دلیل دارا بودن ویژگی‌های برجسته‌ای مانند ساده بودن تعبیر هندسی آن، رسیدن به یک جواب عمومی و یکتا، توانایی مدل‌بندی توابع غیرخطی و هم‌چنین کمینه‌سازی خطای تعمیم به جای خطای یادگیری، توجه بسیاری از محققان را به خود جلب کرده است. در این مقاله عملکرد روش SVM در پیش‌بینی بی‌ثباتی قیمت نفت خام ایران مورد بررسی قرار گرفته و سپس عملکرد این روش با نتایج پیش‌بینی مدل‌های GARCH مقایسه شده است. در این تحقیق از داده‌های ماهانه‌ی قیمت نفت خام ایران در دوره‌ی زمانی آوریل ۱۹۸۱ تا دسامبر ۲۰۱۱ استفاده شده است. نتایج تحقیق نشان‌دهنده‌ی برتری روش SVM نسبت به مدل‌های GARCH، براساس معیارهای MSE، MAE، NMSE و TIC است.

طبقه‌بندی JEL: C22, C45, C53, F47

کلید واژه: پیش‌بینی بی‌ثباتی قیمت نفت، یادگیری ماشین، ماشین بردار پشتیبان، مدل‌های GARCH.

۱- مقدمه

با توجه به این که ایران یکی از بزرگ‌ترین صادرکننده‌های نفت در جهان می‌باشد، قیمت این ماده‌ی استراتژیک نقش به‌سزایی در اقتصاد این کشور ایفا می‌کند. پیش‌بینی مناسب قیمت نفت و نوسانات آن می‌تواند کمک زیادی به برنامه‌ریزی و سیاست‌گذاری‌های اقتصادی کشور داشته باشد. تاکنون مطالعات فراوانی در زمینه‌ی پیش‌بینی قیمت نفت در جهان انجام شده و روش‌های مختلفی مورد ارزیابی قرار گرفته‌اند. برای مثال می‌توان به مطالعات فرناندز^۱ (۲۰۰۶)، کولکارنی و حیدر^۲ (۲۰۰۹)، زمانی (۱۳۸۴) و بهرام‌مهر (۱۳۸۷) اشاره کرد.

یکی از ویژگی‌های سری‌های زمانی مالی^۳ هم‌چون؛ قیمت نفت، قیمت سهام، نرخ تورم و نرخ ارز، غیرخطی بودن آن‌هاست، لذا استفاده از مدل‌های خطی برای پیش‌بینی، نتایج مطلوبی به همراه نخواهد داشت. ویژگی مهم دیگر سری‌های زمانی مالی نامانایی^۴ آن‌هاست. به عبارت دیگر میانگین و واریانس آن‌ها ثابت نیست و در طول زمان تغییر می‌کند. بیش‌تر مدل‌های سری زمانی مانند مدل‌های اتورگرسیو^۵، میانگین متحرک^۶ و ARIMA^۷ بر اساس فرض ثابت بودن واریانس خطا استوار هستند، اما مطالعات نشان می‌دهند که سری‌های زمانی مالی معمولاً بی‌ثباتی^۸ یا تغییرپذیری متغیر با زمان دارند (انگل^۹ ۱۹۸۲ و ۲۰۰۱). بی‌ثباتی درجه‌ی نوسانات قیمت برای یک دارایی، نرخ یا شاخص معین است که معمولاً به صورت واریانس یا انحراف معیار بیان می‌شود. ایده‌ی اصلی مدل ARCH^{۱۰} برای اولین بار در سال ۱۹۸۲ توسط انگل ارائه و در سال ۱۹۸۶ توسط بولرسلو^{۱۱} به مدل کلی‌تر GARCH^{۱۲} یا ARCH تعمیم یافته، بسط داده شد.

1- Fernandez.

2- Kulkarni and Haidar.

3- Financial Time Series.

4- Non-Stationarity.

5- Autoregressive.

6- Moving Average.

7- Autoregressive Integrated Moving Average.

8- Volatility.

9- Engle.

10- Autoregressive Conditional Heteroskedasticity.

11- Bollerslev.

12- Generalized Autoregressive Conditional Heteroskedasticity.

این مدل‌ها که بر اساس فرض ناهمواریانسی شرطی مؤلفه‌ی خطا استوار هستند، به دلیل توانایی مدل‌بندی بی‌ثباتی در سری‌های زمانی مالی مورد توجه قرار گرفته‌اند. نقش مهم پیش‌بینی بی‌ثباتی در مدیریت ریسک^۱، سبب شده است که محققان تحقیقات بسیاری در زمینه‌ی مدل‌بندی و پیش‌بینی بی‌ثباتی در دهه‌های اخیر داشته باشند. برای مثال پانگ و همکاران^۲ (۲۰۰۷)، مدل‌های پیش‌بینی بی‌ثباتی در بازار بورس شنژن^۳ چین را مورد مطالعه قرار داده و با مقایسه‌ی مدل‌های AR(1)، AR(2) و و رگرسیون لجستیک مشاهده کرده‌اند که مدل AR(1) عملکرد بهتری نسبت به دو روش دیگر نشان می‌دهد. فلوروس^۴ (۲۰۰۸)، با استفاده از مدل‌های مختلف GARCH، به مدل‌بندی بی‌ثباتی بازارهای بورس خاورمیانه پرداخته است. او عملکرد مدل GARCH ساده، GARCH نمایی، GARCH آستانه‌های و GARCH مؤلفه‌ای را برای دو بازار بورس در خاورمیانه در یک دوره‌ی ده ساله را مورد بررسی قرار داده است. ابریشمی و همکاران (۱۳۸۶)، به ارزیابی عملکرد مدل‌های پیش‌بینی بی‌ثباتی قیمت نفت پرداخته و با استفاده از داده‌های قیمت روزانه‌ی نفت خام وست تگزاس اینترمدیت (WTI) در دوره‌ی زمانی ۱۹۹۰ تا ۲۰۰۵، خانواده‌ی مدل‌های GARCH را مورد بررسی قرار داده‌اند. نتایج به دست آمده حاکی از عملکرد بهتر مدل‌های GARCH و TGARCH نسبت به سایر مدل‌ها می‌باشد. آلبرگ و همکاران^۵ (۲۰۰۸)، یک مقایسه‌ی تجربی برای مدل‌های مختلف GARCH انجام داده‌اند. نتایج آن‌ها نشان می‌دهد که مدل‌های GARCH نامتقارن مانند GJR و EGARCH عملکرد بهتری در پیش‌بینی بی‌ثباتی بازار بورس دارند. آرجومان^۶ (۲۰۰۵)، عملکرد مدل GARCH را در پیش‌بینی بی‌ثباتی نرخ ارز برخی کشورهای در حال توسعه بررسی کرده و نشان داده است که مدل‌های GARCH غیرخطی بهتر از مدل‌های GARCH خطی در پیش‌بینی بی‌ثباتی نرخ ارز عمل می‌کنند.

1- Risk Management.

2- Pang et al.

3- Shenzhen Stock Market.

4- Floros.

5- Alberg et al.

6- Arjuman.

در سال‌های اخیر الگوریتم‌های هوش مصنوعی و یادگیری ماشین^۱ کاربرد گسترده‌ای در مسائل مختلف پیدا کرده‌اند. ماشین بردار پشتیبان (SVM)^۲ یک الگوریتم جدید یادگیری ماشین است که توسط وپنیک^۳ در سال ۱۹۹۵ معرفی شده است. روش SVM در ابتدا برای حل مسائل رده‌بندی مورد استفاده قرار گرفته و سپس برای مسائل رگرسیون و برآورد تابع نیز توسعه داده شده است. شکلی از SVM که برای مسائل رگرسیونی مورد استفاده قرار می‌گیرد، SVR^۴ نامیده می‌شود. در حالی که روش‌های دیگر مانند مدل‌های رگرسیونی و شبکه‌های عصبی مصنوعی^۵ بر اساس اصل کمینه‌سازی مخاطره‌ی تجربی (ERM)^۶ استوار هستند، SVM با اجرای اصل کمینه‌سازی مخاطره ساختاری (SRM)^۷، سعی در کمینه‌سازی خطای تعمیم دارد. بر اساس اصل کمینه‌سازی مخاطره‌ی ساختاری، روش SVM توازی بین خطای یادگیری و خطای تعمیم ایجاد می‌کند (وپنیک ۱۹۹۵). انتخاب بهترین مدل در SVM معادل با حل یک مسئله‌ی برنامه‌ریزی درجه‌ی دو است که منجر به یک جواب عمومی و یکتا می‌شود. از سوی دیگر SVM با به کار بردن یک تابع هسته‌ی^۸ مناسب و نگاشت داده‌های اصلی به یک فضای با بعد بالاتر، قادر به برآورد توابع غیرخطی پیچیده نیز می‌باشد (باساک و همکاران^۹ ۲۰۰۷). به دلیل این ویژگی‌ها، الگوریتم SVM کاربرد گسترده‌ای در مسائل مختلف از رده‌بندی و رگرسیون گرفته تا دسته‌بندی متن، تشخیص چهره، تشخیص دست‌خط و سایر مسائل پیچیده‌ی مهندسی پیدا کرده است. تاکنون تحقیقات فراوانی در زمینه‌ی پیش‌بینی سری‌های زمانی و به ویژه سری‌های زمانی مالی بر اساس روش SVM انجام گرفته است. برای مثال هاو و یو^{۱۰} (۲۰۰۶)، از ماشین‌های بردار پشتیبان در پیش‌بینی قیمت سهام در بازار بورس شانگ‌های استفاده کرده‌اند. چن و همکاران^{۱۱} (۲۰۰۶)، ماشین بردار پشتیبان را با شبکه‌ی عصبی مصنوعی

1- Machine Learning.

2- Support Vector Machine.

3- Vapnik.

4- Support Vector Regression.

5- Artificial Neural Networks.

6- Empirical Risk Minimization.

7- Structural Risk Minimization.

8- Kernel Function.

9- Basak et al.

10- Hao and Yu.

11- Chen et al.

در پیش‌بینی شش بازار بورس مهم آسیا مقایسه کرده‌اند. نتایج آن‌ها نشان‌دهنده‌ی عملکرد بهتر روش SVM نسبت به شبکه‌ی عصبی پس انتشار در پیش‌بینی سری‌های زمانی مالی است. اینس و ترافالیس^۱ (۲۰۰۶)، از یک مدل آمیخته‌ی ARMA-SVM برای پیش‌بینی نرخ ارز استفاده کرده‌اند. لی و همکاران^۲ (۲۰۰۸)، ماشین‌های بردار پشتیبان را برای پیش‌بینی ظرفیت خنک‌سازی خنک‌کننده‌های ساختمان در گوانگ‌ژو چین به کار برده‌اند. مقایسه‌ی عملکرد روش SVM با شبکه‌ی عصبی نشان می‌دهد که روش SVM دقت بهتری نسبت به شبکه‌های عصبی دارد.

در این تحقیق از روش SVR برای پیش‌بینی بی‌ثباتی قیمت نفت خام ایران استفاده و سپس عملکرد آن با مدل متداول GARCH مقایسه شده است. در بخش‌های دوم و سوم، مبانی نظری مدل‌های SVR و GARCH معرفی می‌شود. بخش چهارم، به پیاده‌سازی و ارزیابی مدل‌های SVR و GARCH پرداخته است و بخش پنجم نیز به نتیجه‌گیری و ارائه‌ی پیشنهادات اختصاص دارد.

۲- ماشین‌های بردار پشتیبان برای مسائل رگرسیونی

فرض کنید $S = \{(X_1, y_1), (X_2, y_2), \dots, (X_n, y_n)\} \subset \mathcal{R}^d \times \mathcal{R}$ مجموعه‌ی داده‌های آموزشی باشد که \mathcal{R}^d نشان‌دهنده‌ی فضای ورودی (d بعدی) و n تعداد داده‌های آموزشی است. در SVR هدف یافتن تابع $f(X)$ است، به طوری که برای همه‌ی نمونه‌های آموزشی حداکثر به میزان ε از مقادیر هدف واقعی y_i ، انحراف داشته و در عین حال تا حد ممکن هموار^۳ باشد. به عبارت دیگر از خطاهایی که کم‌تر از ε هستند، چشم‌پوشی می‌شود اما خطاهای بزرگ‌تر از آن پذیرفتنی نیست. تابع رگرسیون خطی در فضای ورودی به صورت زیر است:

$$f(X) = \langle W, X \rangle + b \quad X, W \in \mathcal{R}^d, \quad b \in \mathcal{R} \quad (1)$$

که $\langle W, X \rangle$ نشان‌دهنده‌ی ضرب نقطه‌ای بین X و W می‌باشد. هموار بودن $f(X)$ به معنای این است که به دنبال مدلی با کم‌ترین پیچیدگی هستیم، که بنابر اصل کمینه‌سازی مخاطره ساختاری این کار را با مینیمم کردن $\|W\|^2$ انجام می‌دهیم

1- Ince and Trafalis.

2- Li et al.

3- Flat.

(اسمولا و اسچولکوف^۱، ۱۹۹۸). بنابراین مسئله‌ی اصلی را می‌توان به عنوان یک مسئله‌ی بهینه‌سازی درجه‌ی دو به صورت زیر نوشت:

$$\begin{aligned} \min \quad & \frac{1}{2} \|W\|^2 \\ \text{s.t.} \quad & y_i - \langle W, X_i \rangle - b \leq \varepsilon \\ & \langle W, X_i \rangle + b - y_i \leq \varepsilon \quad i = 1, 2, \dots, n \end{aligned}$$

فرضیه‌ی ضمنی در (۲) این است که این تابع f واقعاً وجود دارد که می‌تواند همه‌ی زوج‌های (X_i, y_i) را با دقت ε تقریب کند یا به عبارت دیگر مسئله‌ی بهینه‌سازی بالا قابل حل است. بعضی مواقع این حالت ممکن است اتفاق نیفتد، یعنی رابطه‌ی (۲) برای همه‌ی نمونه‌های آموزشی برقرار نباشد. برای برخورد با قیود غیرممکن مسئله‌ی بهینه‌سازی (۲)، متغیرهای کمکی ξ_i و ξ_i^* تعریف می‌شوند، به طوری که در قیود زیر صدق کنند:

$$\begin{aligned} \min \quad & \frac{1}{2} \|W\|^2 + C \sum_{i=1}^n (\xi_i + \xi_i^*) \quad (3) \\ \text{s.t.} \quad & y_i - \langle W, X_i \rangle - b \leq \varepsilon + \xi_i \\ & \langle W, X_i \rangle + b - y_i \leq \varepsilon + \xi_i^* \\ & \xi_i^{(*)} \geq 0, \quad i = 1, 2, \dots, n \end{aligned}$$

($\xi_i^{(*)}$ به متغیرهای کمکی ξ_i و ξ_i^* اشاره دارد و ثابت $C > 0$ ترازنی بین هموار بودن f و خطای تجربی برقرار می‌کند. برای مثال اگر $C = \infty$ باشد، آنگاه هدف، مینیمم کردن مخاطره‌ی تجربی بدون در نظر گرفتن پیچیدگی مدل است.)

این مسئله‌ی بهینه‌سازی متناظر با استفاده از تابع زیان ε -insensitive است که توسط وپنیک معرفی شده و به صورت زیر تعریف می‌شود:

$$L_\varepsilon(y - f(X)) = \max(|y - f(X)| - \varepsilon, 0) = \begin{cases} 0 & |y - f(X)| \leq \varepsilon \\ |y - f(X)| - \varepsilon & \text{o.w.} \end{cases}$$

در بیش‌تر موارد مسئله‌ی بهینه‌سازی (۳) می‌تواند در فرمول‌بندی دوگان آن بسیار ساده‌تر حل شود. از این رو از یک روش دوگان‌سازی استاندارد با استفاده از ضرایب لاگرانژ استفاده می‌شود:

$$L(W, b, \alpha, \beta) = \frac{1}{\gamma} \|W\|^2 + C \sum_{i=1}^n (\xi_i + \xi_i^*) - \sum_{i=1}^n \alpha_i (\varepsilon + \xi_i - y_i + \langle W, X_i \rangle + b) - \sum_{i=1}^n \alpha_i^* (\varepsilon + \xi_i^* + y_i - \langle W, X_i \rangle - b) - \sum_{i=1}^n (\beta_i \xi_i + \beta_i^* \xi_i^*) \quad (4)$$

α_i و α_i^* و β_i و β_i^* ضرایب لاگرانژ هستند که در شرایط زیر صدق می‌کنند:

$$\alpha_i, \alpha_i^*, \beta_i, \beta_i^* \geq 0 \quad i = 1, 2, \dots, n \quad (5)$$

می‌توان نشان داد که تابع لاگرانژ (L)، یک نقطه‌ی زینی نسبت به متغیرهای اصلی و دوگان دارد، بنابراین برای بهینه‌سازی، مشتقات جزئی L نسبت به متغیرهای اصلی باید صفر شوند.

$$\frac{\partial L}{\partial b} = \sum_{i=1}^n (\alpha_i^* - \alpha_i) = 0 \quad (6)$$

$$\frac{\partial L}{\partial W} = W - \sum_{i=1}^n (\alpha_i - \alpha_i^*) X_i = 0 \Rightarrow W = \sum_{i=1}^n (\alpha_i - \alpha_i^*) X_i \quad (7)$$

$$\frac{\partial L}{\partial \xi_i^{(*)}} = C - \alpha_i^{(*)} - \beta_i^{(*)} = 0 \Rightarrow \beta_i^{(*)} = C - \alpha_i^{(*)} \quad (8)$$

با قرار دادن (۶)، (۷) و (۸) در رابطه‌ی (۴)، مسئله‌ی بهینه‌سازی دوگان به صورت زیر تبدیل می‌شود:

$$\max_{\alpha} \left(\min_{W, b, \xi_i^{(*)}} L(W, b, \alpha, \beta) \right) = \max_{\alpha} - \frac{1}{\gamma} \sum_{i=1}^n (\alpha_i - \alpha_i^*) (\alpha_j - \alpha_j^*) \langle X_i, X_j \rangle - \varepsilon \sum_{i=1}^n (\alpha_i + \alpha_i^*) + \sum_{i=1}^n y_i (\alpha_i - \alpha_i^*) \quad (9)$$

$$\text{s.t.} \quad \sum_{i=1}^n (\alpha_i - \alpha_i^*) = 0, \quad \alpha_i, \alpha_i^* \in [0, C] \quad (10)$$

با محاسبه‌ی ضرایب لاگرانژ از رابطه‌ی (۹) و با استفاده از رابطه‌ی (۷) می‌توان $f(X)$ را به صورت زیر نوشت:

$$f(X) = \langle W, X \rangle + b = \sum_{i=1}^n (\alpha_i - \alpha_i^*) \langle X_i, X \rangle + b \quad (11)$$

محاسبه‌ی b

با استفاده از شرایط KKT^۱ در حل یک مسئله‌ی بهینه‌سازی دوگان به سادگی می‌توان b را محاسبه کرد. شرایط KKT بیان می‌کند که ضرب نقطه‌ای بین متغیرهای دوگان و قیود باید صفر باشد.

$$\alpha_i (\varepsilon + \xi_i - y_i + \langle W, X_i \rangle + b) = 0 \quad (12)$$

$$\alpha_i^* (\varepsilon + \xi_i^* + y_i - \langle W, X_i \rangle - b) = 0 \quad (13)$$

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

$$(C - \alpha_i^*) \xi_i^* = 0 \quad (15)$$

روابط بالا چند نتیجه‌ی مهم دارند. اول این که تنها نمونه‌های (X_i, y_i) متناظر با $\alpha_i^{(*)} = C$ خارج از حدود ε -insensitive قرار می‌گیرند. هم‌چنین همواره $\alpha_i \alpha_i^* = 0$ است، یعنی هرگز یک مجموعه از متغیرهای دوگان α_i و α_i^* وجود ندارد که هر دو به طور همزمان غیرصفر باشند. برای $\alpha_i^{(*)} \in (0, C)$ داریم $\xi_i^{(*)} = 0$ در نتیجه عامل دوم در (۱۲) و (۱۳) باید برابر صفر باشد. از این رو b می‌تواند به صورت زیر محاسبه شود:

$$b = y_i - \langle W, X_i \rangle - \varepsilon \quad \alpha_i \in (0, C)$$

$$b = y_i - \langle W, X_i \rangle + \varepsilon \quad \alpha_i^* \in (0, C)$$

از روابط (۱۲) و (۱۳) نتیجه می‌شود که تنها برای نمونه‌هایی با $|f(X_i) - y_i| \geq \varepsilon$ ، ضرایب لاگرانژ ممکن است غیرصفر باشند. زیرا برای نمونه‌هایی با $|f(X_i) - y_i| < \varepsilon$ ،

عامل دوم در (۱۲) و (۱۳) غیرصفر است، از این رو برای این که شرایط KKT برقرار باشد، باید α_i و α_i^* صفر باشند. نمونه‌هایی که ضرایب لاگرانژ غیر صفر دارند بردارهای پشتیبان^۱ نامیده می‌شوند. با توجه به روابط (۷) و (۱۱)، روشن است که برای محاسبه‌ی W و $f(X)$ به همه‌ی X_i ها نیازی نیست، بلکه تنها بردارهای پشتیبان در محاسبه‌ی W و $f(X)$ نقش دارند. این خاصیت در اصطلاح تنکی^۲ نامیده می‌شود، زیرا در حقیقت پیچیدگی مدل مستقل از بعد فضای ورودی است و تنها به تعداد بردارهای پشتیبان بستگی دارد.

حالت غیر خطی

در روش SVR در حالتی که نتوان یک تابع رگرسیون خطی در فضای ورودی به داده‌ها برازش داد، از یک نگاشت غیرخطی Φ برای تبدیل داده‌ها به یک فضای با بعد بالاتر استفاده شده و سپس در این فضای جدید الگوریتم SVR استاندارد اجرا می‌شود، بنابراین رگرسیون خطی در این فضای جدید متناظر با رگرسیون غیرخطی در فضای ورودی اصلی است. همان‌طور که در بخش قبل بیان شد در الگوریتم SVR خطی برای به دست آوردن تابع رگرسیون $f(X)$ ، به محاسبه‌ی ضرب نقطه‌ای $\langle X_i, X \rangle$ نیاز است. الگوریتم SVR غیرخطی نیز تنها به ضرب نقطه‌ای $\langle \Phi(X_i), \Phi(X) \rangle$ بستگی دارد. با جایگزینی توابع هسته به جای ضرب نقطه‌ای در فضای جدید، تابع رگرسیون خطی به صورت زیر نوشته می‌شود:

$$\begin{aligned} f(X) &= \langle W, \Phi(X) \rangle + b = \sum_{i=1}^n (\alpha_i - \alpha_i^*) \langle \Phi(X_i), \Phi(X) \rangle + b \\ &= \sum_{i=1}^n (\alpha_i - \alpha_i^*) K(X_i, X) + b \end{aligned}$$

توابع هسته قادر هستند با استفاده از داده‌های اصلی در فضای ورودی، بدون دانستن نگاشت Φ ، ضرب نقطه‌ای $\langle \Phi(X_i), \Phi(X_j) \rangle$ را انجام دهند. متداول‌ترین توابع هسته در جدول ۱ آورده شده است.

1- Support Vectors.
2- Sparseness.

جدول ۱- متداول‌ترین توابع هسته

نام	رابطه‌ی ریاضی	پارامتر
چند جمله‌ای همگن درجه‌ی m	$K(x, x') = \langle x, x' \rangle^m$	$m \in \mathbb{N}$
چند جمله‌ای ناهمگن درجه‌ی m	$K(x, x') = (\langle x, x' \rangle + c)^m$	$c \geq 0, m \in \mathbb{N}$
RBF گوسی	$K(x, x') = \exp(-\gamma \ x - x'\ ^2)$	$\gamma > 0$
RBF نمایی	$K(x, x') = \exp(-\gamma \ x - x'\)$	$\gamma > 0$
تانژانت هیپربولیک	$K(x, x') = \tanh(\rho \langle x, x' \rangle + \theta)$	ρ, θ

مأخذ: اسمولا و اسچولکویف (۱۹۹۸).

۳- مدل GARCH

تا قبل از سال ۱۹۸۰ بیش‌تر مدل‌های سری زمانی بر اساس فرض ثابت بودن واریانس ساخته شده‌اند، اما در عمل بسیاری از سری‌های زمانی دنیای واقعی، به ویژه سری‌های زمانی مالی، دارای تغییرپذیری و واریانس متغیر با زمان هستند. ایده‌ی اصلی مدل ARCH در سال ۱۹۸۲ توسط انگل داده شده است. او نشان داده است که در سری‌های زمانی مالی واریانس غیرشرطی خطا ثابت، اما واریانس شرطی وابسته به زمان است.

فرض کنید P_t قیمت در زمان t و $p_t = \ln P_t$ باشد. مطابق فرضیه‌ی بازارهای کارآمد، p_t معمولاً از الگوی قدم زدن تصادفی^۱ پیروی می‌کند که ناماناست.

$$p_t = \mu + p_{t-1} + \varepsilon_t$$

که μ تغییر مورد انتظار در قیمت و ε_t جملات اغتشاش، متغیرهای تصادفی مستقل و هم توزیع‌اند که معمولاً فرض می‌شود $\varepsilon_t \sim N(0, \sigma^2)$ iid است. بر اساس این مدل که یک مدل خطی است، بهترین پیش‌بینی قیمت در زمان t ، قیمت در دوره‌ی قبل (p_{t-1}) می‌باشد. بازدهی ساده (تغییر نسبی قیمت) به صورت زیر تعریف می‌شود:

$$R_t = \frac{P_t - P_{t-1}}{P_{t-1}}$$

1- Random Walk.

و بازدهی مرکب پیوسته نیز به صورت زیر است:

$$r_t = \ln(R_t + 1) = \ln \frac{P_t}{P_{t-1}} = p_t - p_{t-1} = \mu + \varepsilon_t$$

سری r_t را معمولاً به طور خلاصه، سری بازدهی^۱ یا نرخ بازدهی می‌نامند. در تجزیه و تحلیل به طور معمول سری‌های بازدهی (r_t)، نسبت به سری‌های زمانی مالی (P_t) ترجیح داده می‌شوند، زیرا آن‌ها مانا هستند و از یک الگوی تصادفی محض پیروی می‌کنند. سری بازدهی از نظر آماری دارای ویژگی‌های زیر است:

۱- کشیدگی مازاد: توزیع بازدهی دارایی‌های مالی نسبت به توزیع نرمال کشیده‌تر و دارای دنباله‌های چاق‌تر است، یعنی بازدهی‌های بزرگ (مثبت یا منفی) بیش از حد مورد انتظار اتفاق می‌افتد.

۲- چولگی منفی: بازدهی‌های بزرگ بیش‌تر منفی هستند.

۳- بی‌ثباتی خوشه‌ای: واریانس‌های بزرگ و کوچک به صورت خوشه‌ای ظاهر می‌شوند.

۴- اثر اهرمی^۲: کاهش قیمت‌ها نسبت به افزایش آن، بی‌ثباتی بیش‌تری به دنبال خواهد داشت.

بی‌ثباتی به عنوان نوسان یا تغییر بازدهی دارایی تعریف می‌شود و دامنه‌ی تغییرات بازدهی را نشان می‌دهد. یکی از خصوصیات قیمت‌ها در بازارهای مالی و بازارهای انرژی به ویژه بازار نفت خام، بی‌ثباتی یا ناهمسانی واریانس در طول زمان است. روش‌های گوناگونی برای اندازه‌گیری بی‌ثباتی وجود دارد که عبارتند از:

۱- بی‌ثباتی تاریخی^۳

۲- بی‌ثباتی تاریخی پارکینسون^۴

۳- بی‌ثباتی ضمنی (تلویحی)^۵

۴- شاخص بی‌ثباتی ضمنی^۶

۵- مدل‌های ARCH

1- Return Series.

2- Leverage Effect.

3- Historical Volatility.

4- Parkinson Historical Volatility.

5- Implied Volatility.

6- Implied Volatility Index.

در این تحقیق به منظور پیش‌بینی بی‌ثباتی قیمت نفت از مدل‌های ARCH استفاده شده است، زیرا مدل‌های اتورگرسیو می‌توانند روند واریانس شرطی را با توجه به اطلاعات گذشته‌ی خود توضیح دهند.

فرض کنید r_t نرخ بازدهی دارایی (نفت خام) در فاصله‌ی زمانی $t-1$ تا t و I_{t-1} مجموعه اطلاعات در دسترس تا زمان $t-1$ است. اگر $y_t = E(r_t | I_{t-1})$ میانگین شرطی و $\sigma_t^2 = \text{Var}(r_t | I_{t-1})$ واریانس شرطی r_t باشد، مدل پیشگوی زیر برای r_t وجود دارد:

$$r_t = E(r_t | I_{t-1}) + \varepsilon_t = y_t + \varepsilon_t$$

$\varepsilon_t = r_t - y_t$ ، بازده پیش‌بینی نشده است. هم‌چنین ε_t به عنوان معیار و اندازه‌ی اخبار^۱ در نظر گرفته می‌شود. در حالتی که $\varepsilon_t < 0$ است، یعنی کاهش پیش‌بینی نشده در بازده مشاهده می‌شود، ε_t را اخبار بد (شوک یا تکانه‌های منفی) و در حالتی که $\varepsilon_t > 0$ باشد، یعنی افزایش پیش‌بینی نشده در بازده مشاهده شود ε_t اخبار خوب (شوک یا تکانه‌های مثبت) تلقی می‌شود. $|\varepsilon_t|$ اندازه‌ی اخبار است که هر چه بزرگ‌تر باشد نشان‌دهنده‌ی با اهمیت بودن اخبار است. به منظور بررسی اثر ε_t بر نرخ بازدهی، الگوهای ARCH معرفی می‌شوند. در این مدل‌ها فرض می‌شود واریانس شرطی در طول زمان تغییر می‌کند و تابعی از جملات خطا (ε_t) می‌باشد. انگل فرض کرد که جمله‌ی خطای ε_t می‌تواند به صورت زیر تجزیه شود:

$$\varepsilon_t = z_t \sigma_t$$

که در آن $\{z_t\}$ دنباله‌ای از متغیرهای تصادفی مستقل و هم توزیع با میانگین صفر و واریانس یک است (و معمولاً فرض می‌شود دارای توزیع نرمال است) و

$$\sigma_t^2 = \text{Var}(r_t | I_{t-1}) = \text{Var}(\varepsilon_t | I_{t-1}) = \omega + \sum_{j=1}^q \beta_j \varepsilon_{t-j}^2 \quad (16)$$

برای تضمین مثبت بودن واریانس شرطی باید شرایط $\omega > 0$ و $\beta_j \geq 0$ ($j=1, 2, \dots, q$) برقرار باشد. معادله‌ی (۱۶) مدل ARCH(q) را تعریف می‌کند که در آن واریانس شرطی خطا تابعی از مقادیر گذشته‌ی مربع خطا می‌باشد. پارامترهای

ω و β_j معمولاً با استفاده از روش حداکثر درست‌نمایی^۱ برآورد می‌شوند. به دلیل پدیده‌ی تداوم بی‌ثباتی در بازارهای مالی، مراتب بالای مدل ARCH(q) مناسب‌تر است، اما برای صرفه‌جویی در تعداد پارامترها بهتر است بی‌ثباتی با یک مدل GARCH(p,q) مدل‌بندی شود، زیرا می‌توان نشان داد که یک مدل GARCH(1,1) هم‌ارز با مدل ARCH(∞) است. مدل GARCH(p,q) تعمیمی از مدل ARCH(q) است که با رابطه‌ی زیر تعریف می‌شود:

$$\sigma_t^2 = \omega + \sum_{i=1}^p \alpha_i \sigma_{t-i}^2 + \sum_{j=1}^q \beta_j \varepsilon_{t-j}^2$$

برای تضمین مثبت بودن واریانس شرطی باید شرایط $\omega > 0$ ، $\alpha_i \geq 0$ و $\beta_j \geq 0$ ($i = 1, 2, \dots, p$) ($j = 1, 2, \dots, q$) برقرار باشند.

یکی از اشکالات اساسی مدل‌های ARCH و GARCH این است که در این الگوها اخبار خوب و بد با اندازه‌ی برابر (با $|\varepsilon_t|$ برابر)، اثر یکسانی بر σ_t^2 دارند (این ویژگی اثر تقارن نامیده می‌شود)، اما ممکن است بازار به اخبار خوب و بد با قدرمطلق برابر واکنش متفاوتی نشان دهد، لذا آزمون عدم تقارن و لحاظ کردن آن در الگوهای ARCH بسیار با اهمیت می‌باشد. نلسون (۱۹۹۱)، الگوی GARCH نمایی (EGARCH) را برای کنترل اثرات عدم تقارن پیشنهاد کرده است. الگوی EGARCH(p,q) به صورت زیر تعریف می‌شود:

$$\ln \sigma_t^2 = \omega + \sum_{i=1}^p \alpha_i \ln \sigma_{t-i}^2 + \sum_{j=1}^q \beta_j \left[|Z_{t-j}| - \sqrt{\frac{2}{\pi}} \right] + \sum_{j=1}^q \gamma_j Z_{t-j}$$

ساده‌ترین حالت الگوی GARCH نمایی، EGARCH(1,1) است که به صورت زیر تعریف می‌شود:

$$\ln \sigma_t^2 = \omega + \alpha \ln \sigma_{t-1}^2 + \beta \left[|Z_{t-1}| - \sqrt{\frac{2}{\pi}} \right] + \gamma Z_{t-1}$$

الگوی GARCH نمایی چهار تفاوت اساسی با مدل‌های GARCH دارد:

۱- اثر اخبار در EGARCH نامتقارن است.

1- Maximum Likelihood.

2- Exponential Generalized Autoregressive Conditional Heteroskedasticity.

۲- اثر اخبار بزرگ ($|\varepsilon_t|$ بزرگ) در الگوی EGARCH نسبت به GARCH بیش‌تر است.

۳- تصریح لگاریتمی EGARCH متضمن مثبت بودن واریانس شرطی σ_t^2 است، یعنی در این مدل لزومی ندارد که برای مثبت شدن واریانس قیودی بر پارامترها تحمیل شود.

۴- اخبار بد منجر به نوسانات آتی بیش‌تری نسبت به اخبار خوب می‌شود. پدیده‌ی مذکور اثر اهرمی نامیده شده است.

الگوی GJR: گلاستن^۱، جاگانانان^۲ و رانکل^۳ (۱۹۹۳) الگوی عدم تقارن GJR(p,q) را به صورت زیر ارائه داده‌اند:

$$\sigma_t^2 = \omega + \sum_{i=1}^p \alpha_i \sigma_{t-i}^2 + \sum_{j=1}^q \left[\beta_j \varepsilon_{t-j}^2 + \gamma_j S_{t-j} \varepsilon_{t-j}^2 \right], \quad S_t = \begin{cases} 1 & \varepsilon_t < 0 \\ 0 & \varepsilon_t \geq 0 \end{cases}$$

حالت ساده‌ی GJR(۱,۱) به صورت زیر است:

$$\sigma_t^2 = \omega + \alpha \sigma_{t-1}^2 + \beta \varepsilon_{t-1}^2 + \gamma \varepsilon_{t-1}^2 S_{t-1}$$

در الگوی GJR اگر $\gamma < 0$ باشد، واریانس شرطی در حالت $\varepsilon_{t-1} < 0$ بیش‌تر از

$\varepsilon_{t-1} > 0$ (با قدر مطلق برابر) است. به عبارت دیگر اثر ε_{t-1}^2 بر واریانس شرطی σ_t^2 وقتی ε_{t-1} مثبت یا منفی باشد، متفاوت است.

۴- پیاده‌سازی و ارزیابی نتایج

در این بخش توانایی مدل SVR در پیش‌بینی بی‌ثباتی نشان داده شده و عملکرد آن با انواع مدل‌های GARCH مقایسه می‌شود. در این تحقیق داده‌های قیمت ماهانه‌ی نفت خام ایران از آوریل ۱۹۸۱ تا دسامبر ۲۰۱۱ مورد استفاده قرار گرفته است. این داده‌ها از سایت بانک مرکزی ایران^۴ استخراج شده‌اند. در این تحقیق از نرم افزار

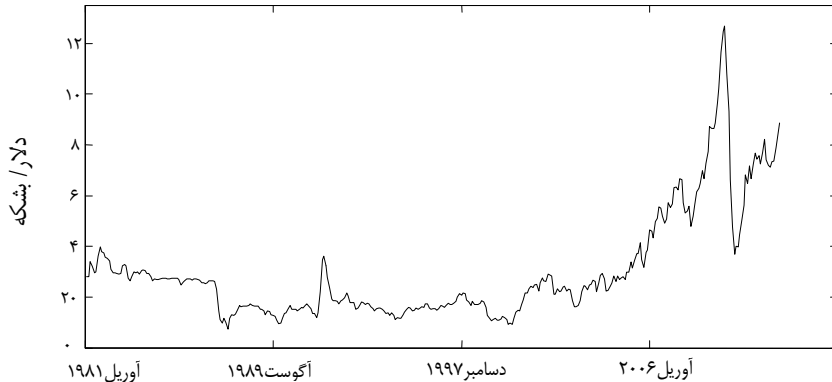
1- Glosten.

2- Jagannathan.

3- Runkle.

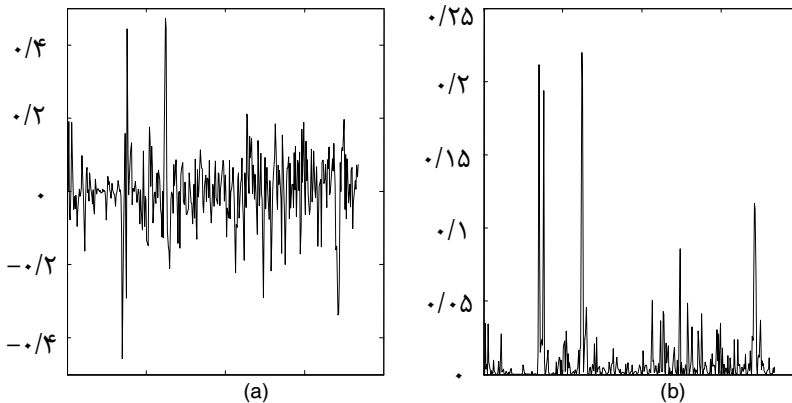
4- www.cbi.ir

LIBSVM^۱ برای اجرای الگوریتم SVR استفاده و نمودار سری زمانی داده‌های اصلی در شکل ۱ نشان داده شده است.



شکل ۱- نمودار سری زمانی قیمت ماهانه نفت خام ایران در دوره‌ی زمانی ۲۰۱۱-۱۹۸۱.

همان‌طور که گفته شد بی‌ثباتی به عنوان نوسان یا تغییر بازدهی دارایی تعریف می‌شود، بنابراین معمولاً $(I_t - \bar{I})^2$ یا I_t^2 (زیرا \bar{I} معمولاً نزدیک به صفر است) به عنوان اندازه‌ی بی‌ثباتی در زمان t در نظر گرفته می‌شود (ابریشمی ۱۳۸۶، گاوریچ-چاکا و بنرجی^۲ ۲۰۰۶).



شکل ۲- (a) نمودار سری بازدهی، (b) نمودار مقادیر بی‌ثباتی

۱- که از وب سایت www.csie.ntu.edu.tw/~cjlin/libsvm/ قابل دستیابی است.

2- Gavrishchaka and Banerjee.

برای پیاده‌سازی مدل SVR، بعد از تبدیل سری زمانی مالی (قیمت نفت) به سری بازدهی، مقادیر بی‌ثباتی $(v_t = (r_t - \bar{r})^2)$ محاسبه و به عنوان داده‌های ورودی الگوریتم SVR در نظر گرفته می‌شود. در ابتدا این داده‌ها به دو بخش تقسیم می‌شوند. تعداد ۳۳۳ داده از آوریل ۱۹۸۱ تا دسامبر ۲۰۰۸ به عنوان مجموعه داده‌ی آموزشی^۱ و ۳۶ داده از ژانویه ۲۰۰۹ تا دسامبر ۲۰۱۱ به عنوان مجموعه داده‌ی آزمون^۲ مورد استفاده قرار می‌گیرد. همان‌طور که در بخش‌های قبل اشاره شد، متغیرهای ورودی الگوریتم SVR، d بعدی هستند، بنابراین برای استفاده از روش SVR در پیش‌بینی سری‌های زمانی و تبدیل داده‌ها به فرمت ورودی SVR، فرض می‌شود مقدار متغیر در زمان t تابعی از d مقدار گذشته باشد. این هم‌ارز با در نظر گرفتن یک پنجره‌ی متحرک^۳ با اندازه‌ی d است. مشخص کردن اندازه‌ی پنجره بستگی به داده‌های موجود دارد. با توجه به این که در این مطالعه از داده‌های ماهانه استفاده شده است، از یک پنجره‌ی متحرک با اندازه‌ی ۲ استفاده می‌شود، بنابراین داده‌های ورودی برای پیش‌بینی بی‌ثباتی با استفاده از الگوریتم SVR به صورت زیر خواهند بود:

$$\begin{aligned} X_1 &= (v_1, v_2) & y_1 &= v_3 \\ X_2 &= (v_2, v_3) & y_2 &= v_4 \\ X_3 &= (v_3, v_4) & y_3 &= v_5 \\ &\dots & & \end{aligned}$$

- که در آن $v_t = (r_t - \bar{r})^2$ اندازه‌ی بی‌ثباتی در زمان t است.
- به طور کلی مراحل ساخت مدل در الگوریتم SVR به صورت زیر است:
- ۱- انتخاب داده‌ها و تبدیل آن‌ها به فرمت ورودی الگوریتم SVR،
 - ۲- استفاده از یک تابع هسته‌ی مناسب،
 - ۳- انتخاب پارامترهای تابع هسته، ϵ و C ،
 - ۴- یادگیری مدل با استفاده از پارامترهای انتخاب شده،
 - ۵- آزمون مدل.

1- Training Set.
2- Test Set.
3- Rolling Window.

در این تحقیق از تابع هسته‌ی RBF گوسی^۱ استفاده می‌شود که به صورت زیر می‌باشد:

$$K(X_i, X_j) = \exp\left(-\gamma \|X_i - X_j\|^2\right)$$

دقت مدل SVR تا حدود زیادی بستگی به انتخاب درست پارامترهای ε ، C و γ دارد. مقادیر کوچک ε منجر به افزایش تعداد بردارهای پشتیبان و مقادیر بزرگ آن منجر به کاهش تعداد بردارهای پشتیبان می‌شود. از سوی دیگر هر چه مقدار پارامتر C بزرگ‌تر باشد اهمیت خطای یادگیری نسبت به پیچیدگی مدل افزایش می‌یابد، بنابراین هر یک از پارامترها به نوعی در پیچیدگی مدل و دقت پیش‌بینی تأثیرگذارند. در این مطالعه از روشی برای انتخاب پارامترها استفاده می‌کنیم که در کائو و تی^۲ (۲۰۰۱) و (۲۰۰۳) و هم‌چنین لی و همکاران (۲۰۰۹) مورد استفاده قرار گرفته است. این روش به این صورت است که با ثابت در نظر گرفتن دو پارامتر، مقادیر پارامتر دیگر را تغییر می‌دهیم و بر اساس کم‌ترین MSE^۳ (میانگین مربع خطا)، بهترین مقدار پارامتر انتخاب می‌شود.

جدول ۲- پارامترهای انتخاب شده‌ی مدل SVR.

پارامتر	γ	C	ε
MSE	۱۲	۱	۰/۰۱

مأخذ: نتایج تحقیق

قبل از پیاده‌سازی الگوهای GARCH، برای بررسی مناسب بودن این مدل‌ها از آزمون انگل استفاده می‌شود. تحت این فرض صفر که اثرات GARCH، یا ناهمواریانسی شرطی وجود ندارد. آماره‌ی این آزمون به طور مجانبی دارای توزیع کای دو است (انگل ۱۹۸۲). خروجی اول این آزمون تابع تصمیم H است که تنها دو مقدار صفر و یک را می‌گیرد. مقدار $H = 0$ به معنای این است که ناهمواریانسی شرطی وجود ندارد و فرض صفر پذیرفته می‌شود و $H = 1$ نشان‌دهنده‌ی رد فرض صفر است. سایر خروجی‌ها

1- Gaussian Radial Basis Function.

2- Cao and Tay.

3- Mean Square Error.

شامل p -value، آماره‌ی آزمون و مقدار بحرانی توزیع کای دو است. این آزمون در سطح معنی‌داری ۵ درصد ($\alpha = 0.05$) و برای وقفه‌های ۱۰، ۱۵ و ۲۰ اجرا شده است.

جدول ۳- آزمون وجود اثرات GARCH

وقفه	H	p-value	آماره‌ی آزمون	مقدار بحرانی
۱۰	۱	۰/۰۰۰۰	۹۰/۹۲۵۹	۱۸/۳۰۷۰
۱۵	۱	۰/۰۰۰۰	۹۳/۶۴۶۲	۲۴/۹۹۵۸
۲۰	۱	۰/۰۰۰۰	۹۳/۱۶۲۸	۳۱/۴۱۰۴

مأخذ: نتایج تحقیق

نتایج آزمون نشان‌دهنده‌ی وجود اثرات GARCH و مناسب بودن این مدل برای داده‌های موجود است و فرض صفر به طور قوی رد می‌شود، زیرا مقدار آماره‌ی آزمون به طور معناداری بزرگ‌تر از مقدار بحرانی توزیع کای دو است. در این مقاله از مدل‌های مختلف GARCH برای پیش‌بینی بی‌ثباتی استفاده می‌شود، با این فرض که $\{\varepsilon_t\}$ دنباله‌ای از متغیرهای تصادفی مستقل با توزیع نرمال و میانگین شرطی سری بازدهی، مقدار ثابت μ است. برای ساخت مدل GARCH، داده‌ها به دو بخش تقسیم می‌شوند. تعداد ۳۳۳ داده از آوریل ۱۹۸۱ تا دسامبر ۲۰۰۸ برای برآورد پارامترها و ساخت مدل و ۳۶ داده از ژانویه ۲۰۰۹ تا دسامبر ۲۰۱۱ برای پیش‌بینی و آزمون استفاده می‌شود. برای پیاده‌سازی مدل GARCH از نرم افزار Matlab7.6 استفاده شده است. در جدول ۴، آماره‌های توصیفی مربوط به سری بازدهی آورده شده است. نتایج، نشان‌دهنده‌ی چولگی منفی و کشیدگی مازاد سری بازدهی است. $Q(10)$ و $Q^2(10)$ آماره‌های آزمون Ljung-Box برای آزمون همبستگی پیاپی به ترتیب در بازدهی و مربع آن برای وقفه‌ی ۱۰ می‌باشد که به صورت $\chi^2(10)$ توزیع می‌شوند. همچنین $A(10)$ آماره‌ی آزمون انگل برای بررسی اثرات GARCH در وقفه‌ی ۱۰ بوده که دارای توزیع $\chi^2(10)$ می‌باشد. داخل پرنانتر مقادیر p-value برای هر آزمون در سطح معناداری ۵ درصد آورده شده است که نشان می‌دهد آماره‌های هر سه آزمون به طور معناداری بزرگ هستند.

جدول ۴- آماره‌های مربوط به سری بازدهی.

\bar{r}	$Var(r_t)$	$Skewness(r_t)$	$Kurtosis(r_t)$	$Q(10)$	$Q^2(10)$	$A(10)$
۰/۰۰۳۱	۰/۰۰۹۵	-۰/۰۰۷۷	۷/۹۹۴۹	۶۸/۵۹۹۴ (۰/۰۰۰۰)	۱۰۲/۱۵۵۵ (۰/۰۰۰۰)	۹۰/۹۲۵۹ (۰/۰۰۰۰)

مأخذ: نتایج تحقیق

در این تحقیق از سه مدل GARCH، GJR و EGARCH برای پیش‌بینی بی‌ثباتی نفت خام ایران استفاده شده است. در الگوی GARCH مقادیر مختلفی برای پارامترها در نظر گرفته شده و نتایج تحقیق نشان داده است که با تغییر پارامترها تفاوت چشم‌گیری در دقت مدل حاصل نمی‌شود.

جدول ۵- برآورد پارامترهای مدل‌های GARCH

مدل	پارامتر	μ	ω	α_1	α_2	β_1	β_2	γ
GARCH(1,1)	مقدار	۰,۰۰۳۱۲۸	۰,۰۰۱۷۴۴	۰,۴۵۱۵۵	-	۰,۴۰۱۰۴	-	-
	خطای استاندارد	۰,۰۰۴۷۶	۰,۰۰۰۴۶	۰,۰۷۸۲۱	-	۰,۰۵۴۶۴	-	-
	آماره‌ی T	۰,۶۵۷۰	۳,۷۲۱	۵,۷۷۳۱	-	۷,۳۳۸۶	-	-
GARCH(2,1)	مقدار	۰,۰۰۳۵۳	۰,۰۰۱۹	۰,۰۵۴۹۴	۰,۲۹۹۱۸	۰,۴۹۰۳۴	-	-
	خطای استاندارد	۰,۰۰۴۴۷	۰,۰۰۰۵۸	۰,۰۷۰۲	۰,۰۸۵۹۱	۰,۰۶۰۹۱	-	-
	آماره‌ی T	۰,۷۸۸۴	۳,۲۲۹۹	۰,۷۸۲۷	۳,۴۸۲۵	۸,۰۴۹۴	-	-
GARCH(1,2)	مقدار	۰,۰۰۳۱۲	۰,۰۰۱۷۴	۰,۴۵۱۵۵	-	۰,۴۰۱۰۳	۰	-
	خطای استاندارد	۰,۰۰۴۷۶	۰,۰۰۰۹۲	۰,۲۳۱۶۴	-	۰,۰۶۰۶۸	۰,۱۸۴۴۲	-
	آماره‌ی T	۰,۶۵۶۳	۱,۸۷۶۵	۱,۹۴۹۳	-	۶,۶۰۸۲	۰,۰۰۰۰	-
	مقدار	۰,۰۰۳۳۹	۰,۰۰۲	۰	۰,۳۱۳۱۴	۰,۴۸۷۶۱	۰,۰۳۸۷۴	-

مدل	پارامتر	μ	ω	α_1	α_2	β_1	β_2	γ
GARCH(۲,۲)	خطای استاندارد	۰,۰۰۴۴۸	۰,۰۰۰۹۶	۰,۲۷۶۳	۰,۰۹۸۸۴	۰,۰۶۳۳۶	۰,۱۸۴۴۲	-
	آماره‌ی T	۰,۷۵۷۰	۲,۰۸۵۹	۰,۰۰۰۰	۳,۱۶۸۰	۷,۶۹۵۰	۰,۲۱۰۱	-
GJR(۱,۱)	مقدار	۰,۰۰۱۶۴	۰,۰۰۰۷۹	۰,۶۲۲۸۸	-	۰,۲۴۲۹۶	-	۰,۲۶۸۳۲
	خطای استاندارد	۰,۰۰۳۷۱	۰,۰۰۰۳۸	۰,۰۹۲۴۵	-	۰,۱۲۸۵۳	-	۰,۱۸۷۱۸
	آماره‌ی T	۰,۴۴۲۴	۲,۰۷۵۳	۶,۷۳۷۱	-	۱,۸۹۰۳	-	۱,۴۳۳۵
EGARCH(۱,۱)	مقدار	۰,۰۰۱۱۹	-۰,۴۸۱۳	۰,۹۰۱۲۵	-	۰,۵۶۷۱۸	-	-۰,۱۰۰۲
	خطای استاندارد	۰,۰۰۳۵۹	۰,۲۲۱۶۹	۰,۰۴۲۴۸	-	۰,۱۱۶۷۴	-	۰,۰۷۶۰۳
	آماره‌ی T	۰,۳۳۳۵	-۲,۱۷۱۲	۲۱,۲۱۶	-	۴,۸۵۸۷	-	-۱,۳۱۸

مأخذ: نتایج تحقیق

نتایج پیش‌بینی با معیارهای میانگین مربع خطا (MSE)، میانگین قدرمطلق خطا (MAE)^۱، میانگین مربع خطای نرمال شده (NMSE)^۲ و ضریب نابرابری تایل (TIC)^۳ ارزیابی می‌شود.

$$MSE = \frac{1}{k} \sum_{t=1}^k (v_t - \hat{v}_t)^2$$

$$MAE = \frac{1}{k} \sum_{t=1}^k |v_t - \hat{v}_t|$$

-
- 1- Mean Absolute Error.
2- Normalized Mean Square Error.
3- Theil Inequality Coefficient.

$$NMSE = \frac{1}{k\sigma^2} \sum_{t=1}^k (v_t - \hat{v}_t)^2, \quad \sigma^2 = \frac{1}{k-1} \sum_{t=1}^k (v_t - \bar{v})^2, \quad \bar{v} = \frac{1}{k} \sum_{t=1}^k v_t$$

$$TIC = \frac{\sum_{t=1}^k (v_t - \hat{v}_t)^2 / k}{\sqrt{\sum_{t=1}^k \hat{v}_t^2 / k} + \sqrt{\sum_{t=1}^k v_t^2 / k}}$$

که k تعداد داده‌های آزمون، v_t اندازه‌ی بی‌ثباتی در زمان t و \hat{v}_t پیش‌بینی بی‌ثباتی در زمان t می‌باشد. دو معیار اول به مقیاس اندازه‌گیری داده‌ها حساس‌اند، در حالی که دو معیار NMSE و TIC به مقیاس اندازه‌گیری وابسته نیستند. ضریب نابرابری تایل، معیار MSE را به گونه‌ای تعدیل می‌کند که همواره بین صفر و یک باشد. مقدار صفر برای هر یک از آماره‌ها نشان‌دهنده‌ی برازش کامل است.

جدول ۵- مقایسه‌ی مدل‌های SVR و GARCH براساس معیارهای MAE، MSE، NMSE و TIC.

	GARCH(1,1)	GARCH(1,2)	GARCH(2,1)	GARCH(2,2)	GJR (1,1)	EGARCH(1,1)	SVR
MSE	۰/۰۰۰۷۴۰۳۴	۰/۰۰۰۷۴۰۳۴	۰/۰۰۰۷۴۵۴۶	۰/۰۰۰۷۴۵۱۵	۰/۰۰۰۹۴۰۷۱	۰/۰۰۰۷۴۷۸۳	۰/۰۰۰۶۴۴۳
MAE	۰/۰۱۴۴	۰/۰۱۴۴	۰/۰۱۴۵	۰/۰۱۴۶	۰/۰۲۱۸	۰/۰۱۴۲	۰/۰۱۳۲
NMSE	۰/۹۷۷۵	۰/۹۷۷۳	۰/۹۸۴۰	۰/۹۸۵۲	۱/۲۲۲۱	۰/۹۷۴۵	۰/۸۳۲۳
TIC	۰/۰۱۷۹	۰/۰۱۷۹	۰/۰۱۸	۰/۰۱۷۹۶	۰/۰۱۸۲	۰/۰۲۰۵	۰/۰۱۵۲

منبع: نتایج تحقیق

همان‌طور که مشاهده می‌شود نتایج GARCH(1,1) و GARCH(1,2) بسیار نزدیک به هم می‌باشد و این دو مدل براساس دو معیار MSE و TIC دقت بیش‌تری نسبت به سایر مدل‌های GARCH دارند و الگوی EGARCH براساس دو معیار MAE و NMSE عملکرد بهتری نسبت به سایر مدل‌های GARCH نشان می‌دهد. در حالی‌که مدل SVR در مقایسه با همه‌ی الگوها خطای پیش‌بینی کم‌تری دارد.

۵- نتیجه‌گیری

در این تحقیق یکی از الگوریتم‌های جدید یادگیری ماشین با نام SVR در پیش‌بینی بی‌ثباتی قیمت نفت خام ایران استفاده و نتایج پیش‌بینی با مدل‌های مختلف GARCH مقایسه شده است. نتایج تحقیق نشان می‌دهد که مدل SVR عملکرد بسیار بهتری نسبت به مدل‌های GARCH دارد. از آن‌جا که دقت مدل SVR تا حدود زیادی بستگی به انتخاب درست پارامترهای ε ، C و پارامترهای تابع هسته دارد، یافتن یک روش دقیق برای انتخاب بهینه‌ی پارامترها و همچنین انتخاب تابع هسته می‌تواند سبب افزایش دقت روش SVR شود. همچنین با در نظر گرفتن متغیرهای اقتصادی تأثیرگذار بر قیمت نفت خام می‌توان پیش‌بینی‌های دقیق‌تری با استفاده از روش SVR به دست آورد.

فهرست منابع

- ابریشمی، حمید و همکاران (۱۳۸۶)، ارزیابی عملکرد مدل‌های پیش‌بینی بی‌ثباتی قیمت نفت، مجله‌ی تحقیقات اقتصادی، شماره‌ی ۷۸، صص ۲۱-۱.
- بهرادمهر، نفیسه (۱۳۸۷)، پیش‌بینی قیمت نفت خام با استفاده از هموارسازی موجک و شبکه‌ی عصبی مصنوعی، فصل‌نامه‌ی مطالعات اقتصاد انرژی، سال پنجم، شماره‌ی ۱۸، صص ۹۸-۸۱.
- زمانی، مهرزاد (۱۳۸۴)، مدل‌سازی و پیش‌بینی قیمت نفت خام WTI، فصل‌نامه‌ی مطالعات اقتصاد انرژی، سال دوم، شماره‌ی ۴، صص ۲۸-۲۲.
- Alberg, D. et al. (2008), Estimating Stock Market Atility Using Asymmetric GARCH Models, *Alieid Financial Economics*, 18, 1201-1208.
- Arjuman Ara, L. (2005), Performance of GARCH Models in Forecasting the Atility of Exchange Rate for Developing Countries, *China-USA Business Review*, 4, No. 10, 13-20.
- Basak, D. et al. (2007), Suort Vector Regression, *Neural Information Processing- Letters and Reviews*, 11, No. 10, 203-223.
- Bollerslev, T. (1986), Generalized Autoregressive Conditional Heteroskedasticity, *Journal of Econometrics*, 31, 307-327.

- Cao, L. J. and Tay, F. E. H. (2001), Financial Forecasting Using Suort Vector Machines, *Neural Comput & Alict*, 10, 184-192.
- Cao, L. J. and Tay, F. E. H. (2003), Suort Vector Machine with Adaptive Parameters in Financial Time Series Forecasting, *IEEE Transactions on Neural Networks*, 14, No. 6, 1506-1518.
- Chen, W-H. et al. (2006), Comparison of Suort Vector Machines and Back Propagation Neural Networks in Forecasting the Six Major Asian Stock Markets, *International Journal of Electronic Finance*,. 1, No. 1, 49, 49-67.
- Engle, R. (1982), Autoregressive Conditional Heteroskedasticity with Estimates of the Variance of United Kingdom Inflation, *Economical*, 50, Issue 4, 987-1008.
- Engle, R. (2001), the Use of ARCH/GARCH Models in Allied Econometrics, *Journal of Economic Perspective*, 15, 4, 157-168.
- Floros, C. (2008), Modeling Atility Using GARCH Models, *Middle Eastern Finance and Economics*, Issue 2, 31-71.
- Gavrishchaka, V. and Banerjee, S. (2006), Suort Vector Machine as an Efficient Framework for Stock Market Atility Forecasting, *CMS*, 3, 147-160.
- Hao, W. and Yu, S. (2006), Suort Vector Regression for Financial Time Series Forecasting, *International Federation for Information Processing (IFIP)*, 207, 825-830.
- Ince, H. and Trafalis, T. B. (2006), A Hybrid Model for Exchange Rate Prediction, *Decision Suort Systems*, 42, 1054-1062.
- Kulkarni, S. and Haidar, I. (2009), Forecasting Model for Crude Oil Price Using Artificial Neural Networks and Commodity Futures Prices, *International Journal of Computer Science and Information Security*,. 2, No. 1.
- Li, Q. et al. (2009), Aling Suort Vector Machine to Predict Hourly Cooling Load in the Building, *Alied Energy*, 86, 2249-2256.
- Pang, S. et al. (2007), A Comparison of Forecasting Models of the Atility in Shenzhen Stock Market, *Acta Mathematica Scientia*, 27, Ser. B, 125-136.
- Smola, A. and Scholkopf, B. (1998), A Tutorial on Suort Vector Regression, *Technical Report NeuroCOLT NC-TR-98-030*.
- Tang, L.-B. et al. (2009), Forecasting Atility Based on Wavelet Suort Vector Machine, *Expert Systems with Alications*, 36, 2901-2909.

Tay, F. E. H. and Cao, L. (2001), Alication of Suort Vector Machines in Financial Time Series Forecasting, The International Journal of Management Science, Omega, 29, 309-317.

Vapnik, V. N. (1995), the Nature of Statistical Learning Theory, New York: Springer-Verlag.