



فصلنامه علمی پژوهشی دانش سرمایه‌گذاری  
سال چهارم / شماره چهاردهم / تابستان ۱۳۹۴

## پیش‌بینی قیمت هفتگی نفت خام از طریق مدل ترکیبی ماشین بردار پشتیبان و خودرگرسیو میانگین متحرک انباشته

شاپور محمدی

دانشیار، مدیریت مالی، دانشگاه تهران، دانشکده‌ی مدیریت  
shmohammadi@ut.ac.ir

رضا راعی

استاد، مدیریت مالی، دانشگاه تهران، دانشکده‌ی مدیریت  
Raei@ut.ac.ir

حسین کریمی

کارشناسی ارشد، مدیریت مالی، دانشگاه تهران، دانشکده‌ی مدیریت (مسئول مکاتبات)  
hkfinance85@yahoo.com

تاریخ دریافت: ۹۳/۱۰/۱۶ تاریخ پذیرش: ۹۴/۱/۲۹

### چکیده

همواره پیش‌بینی روند قیمت و نوسانات یکی از چالش‌های پیش‌روی معامله‌گران در بازارهای بورس نفت بوده و پیش‌بینی قیمت‌ها به عنوان یک امر ضروری و کاربردی مطرح می‌شود ولیکن باید پیش‌بینی را مورد توجه قرار داد که با دقت بیشتری صورت گیرد و نسبت به نتایج واقعی مشاهده شده خطای کمتری داشته باشد. به منظور پیش‌بینی قیمت هفتگی نفت خام برنت به عنوان یک نفت شاخص با توجه به دشوار بودن شناسایی دقیق الگوهای خطی و غیرخطی در سری‌های زمانی اقتصادی و مالی از ترکیب مدل‌های خودرگرسیو میانگین متحرک انباشته (ARIMA) با این پیش فرض که سری‌زمانی دارای الگوی خطی می‌باشد و ماشین بردار پشتیبان (SVM) که توانایی بالایی در مدل‌سازی الگوهای غیرخطی دارد به منظور افزایش دقت پیش‌بینی استفاده شده است. با توجه به آزمون مقایسه زوجی معیارهای ارزیابی عملکرد ریشه میانگین مجذور خطا (RMSE) و میانگین قدرمطلق درصد خطا (MAPE) که حاصل مقادیر پیش‌بینی شده و مقادیر واقعی هر یک از مدل‌ها هستند، نتایج بیانگر این موضوع بودند که در بیشتر موارد مدل ترکیبی خطای کمتری در پیش‌بینی قیمت نفت خام نسبت به کاربرد مجزای مدل‌های خودرگرسیو میانگین متحرک انباشته و ماشین بردار پشتیبان دارد.

واژه‌های کلیدی: خودرگرسیو میانگین متحرک انباشته (ARIMA)<sup>۱</sup>، ماشین بردار پشتیبان (SVM)<sup>۲</sup>، مدل ترکیبی<sup>۳</sup>، مانایی<sup>۴</sup>.

## ۱- مقدمه

پیش‌بینی روند قیمت و نوسانات یکی از چالش‌های معامله‌گران و سرمایه‌گذاران در بازارهای بورس نفت بوده و پیش‌بینی قیمت‌ها به عنوان یک امر ضروری و کاربردی مطرح می‌شود ولیکن باید پیش‌بینی را مورد توجه قرار داد که با دقت بیشتری صورت گیرد و نسبت به نتایج واقعی مشاهده شده خطای کمتری داشته باشد. در پیش‌بینی سری‌های زمانی از مشاهدات گذشته‌ی یک متغیر به منظور توسعه‌ی مدل پیش‌بینی در آینده استفاده می‌گردد. مدل‌های سری زمانی در طول چند دهه گذشته توسعه بسیاری یافته‌اند اما یکی از ساده‌ترین و پرکاربردترین آن‌ها مدل خودرگرسیو میانگین متحرک انباشته (ARIMA)<sup>۱</sup> می‌باشد که تحت عنوان روش باکس و جنکینز<sup>۲</sup> شناخته می‌شود. با وجود انعطاف‌پذیری بالای مدل مذکور در مدل‌سازی الگوهای خطی به دلیل دارا بودن اجزای خودرگرسیو و میانگین متحرک، این مدل نمی‌تواند الگوهای غیرخطی را به طور دقیق مدل‌سازی کند. شبکه‌های عصبی که به طور گسترده در پیش‌بینی سری‌های زمانی مورد استفاده قرار می‌گیرند در مدل‌سازی الگوهای غیرخطی بسیار انعطاف‌پذیر می‌باشند. الگوریتم ماشین بردار پشتیبان بر اساس اصول تئوری یادگیری آماری و حداقل‌سازی ریسک ساختاری پایه‌گذاری شده است. این الگوریتم در ابتدای سال‌های دهه ۱۹۹۰ توسط واپنیک<sup>۳</sup> و همکارانش برای حل مسایل طبقه‌بندی طراحی شد و پس از آن با پیشرفت‌هایی که توسط هابر<sup>۴</sup> و دیگران صورت گرفت از ماشین بردار پشتیبان در پیش‌بینی سری‌های زمانی به خصوص مدل‌سازی سری‌های زمانی غیرخطی مورد استفاده قرار گرفت. به دلیل اینکه شناسایی الگوی داده‌ها در واقعیت اغلب پیچیده می‌باشد، مطالعات زیادی به منظور ترکیب مدل‌های خطی و غیرخطی انجام پذیرفته است.

## ۲- مبانی نظری و مروری بر پیشینه پژوهش

در زمینه مدل‌سازی سری‌های زمانی، روش‌های متفاوتی مورد استفاده قرار می‌گیرد که می‌توان به مدل‌های سنتی میانگین متحرک و خودرگرسیو میانگین متحرک انباشته که الگوهای خطی را مدل‌سازی می‌کنند و به دلیل سادگی در فهم و کاربرد در دهه‌های اخیر بسیار مورد استفاده قرار گرفته است، اشاره کرد. به دلیل مشاهده الگوهای غیرخطی در دنیای واقعی یک سری از مدل‌های غیرخطی مانند ARCH<sup>۱</sup>، GARCH<sup>۲</sup> و TGARCH مطرح شدند ولی همگی این مدل‌های غیرخطی الگوهای بخصوصی را توضیح می‌دهند. کار الگوریتم ماشین بردار پشتیبان در واقع یافتن قوانین حاکم بر داده‌ها و نیز روابط نهفته میان آن‌ها می‌باشد. این مدل‌های یادگیری، همه بر پایه این فرض اولیه استوارند که تجربیات کسب شده و آموخته‌های ماشین یادگیری برای پیش‌بینی و تصمیم‌گیری در آینده مناسب می‌باشند. واضح است که این خود فرض ثابت بودن مدل احتمالی تولید کننده داده‌ها را می‌طلبد. در SVM<sup>۳</sup> ها نیز هدف الگوریتم یادگیری بدست آوردن توانایی تعیین نسبتاً دقیق کلاس داده‌های دیده نشده پس از پایان مرحله آموزش می‌باشد. (آبه، ۲۰۰۵). با وجود مزایای متعدد، شبکه‌های عصبی با محدودیت‌هایی همراه هستند که از جمله آنها می‌توان به ارائه نتایج پیچیده در مدل‌های خطی اشاره کرد و همچنین فرایند یادگیری نیازمند شمار بالای نمونه برای آموزش می‌باشد.

به دلیل اینکه تشخیص الگوی سری‌های زمانی مبنی بر خطی یا غیرخطی بودن روابط دشوار است و از طرفی به ندرت روابط کاملاً خطی و یا کاملاً غیرخطی مشاهده می‌شود (اغلب ترکیبی از دو الگو را دارا می‌باشند)، بنابراین ترکیبی از مدل‌های ARIMA و SVM می‌تواند به افزایش دقت پیش‌بینی کمک کند.

## ۲-۱- خودرگرسیو میانگین متحرک انباشته (ARIMA)

مدل‌های خودرگرسیو میانگین متحرک انباشته را معمولاً به صورت  $ARIMA(p, d, q)$  نمایش می‌دهند و در این مدل‌ها برای پیش‌بینی مقادیر آتی متغیر از ترکیب خطی مقادیر گذشته متغیر و اجزای اخلاص استفاده می‌شود. که در آن  $p$  مرتبه مورد نیاز برای خودرگرسیو،  $d$  میزان تفاضل مورد نیاز برای مانا کردن سری زمانی و  $q$  میزان مرتبه‌ی مورد نیاز برای میانگین متحرک است.

$$Y_t = \theta_0 + \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \dots + \phi_p Y_{t-p} + \theta_1 u_{t-1} + \theta_2 u_{t-2} - \dots + \theta_q \phi_{t-q} + U_t \quad (1)$$

$Y_t$  = مقدار واقعی متغیر

$U_t$  = خطای تصادفی در زمان  $t$

$\theta_j, \phi_i$  = ضرایب خودرگرسیو و میانگین متحرک

$p, q$  = مرتبه‌های خودرگرسیو و میانگین متحرک

به طور مثال مدل  $ARIMA(1, 0, 1)$  به صورت زیر نمایش داده می‌شود.

$$Y_t = \theta_0 + \phi_1 Y_{t-1} + \theta_1 u_{t-1} + U_t \quad (2)$$

شرط بهره‌گیری از مدل‌های خودرگرسیو میانگین متحرک انباشته، مانا بودن سری‌های زمانی می‌باشد. برای مانا کردن سری‌های زمانی مالی و اقتصادی اغلب از روش تفاضل استفاده می‌شود. جزء انباشتگی در مدل خودرگرسیو میانگین متحرک انباشته بیانگر میزان تفاضل مورد نیاز برای مانا کردن سری زمانی است. مدل خودرگرسیو میانگین متحرک انباشته بهینه، مدلی است که پسماندهای آن همبستگی خطی نداشته باشند، اما به دلیل اینکه تحلیل‌های پسماند قادر به شناسایی الگوهای غیرخطی نمی‌باشد، بنابراین وجود روابط غیرخطی در پسماندها می‌تواند محدودیتی برای مدل ARIMA به حساب آید.

**مرحله اول:** به منظور به کارگیری مدل خودرگرسیو میانگین متحرک انباشته جهت پیش‌بینی، سری زمانی را از طریق روش تفاضل مانا می‌کنیم.

**مرحله دوم:** تشخیص و شناسایی مدل به معنی تعیین مرتبه مدل می‌باشد. مهمترین ابزار برای تشخیص مرتبه مدل، استفاده از تابع خود همبستگی (ACF)<sup>۱۲</sup> و تابع خود همبستگی جزئی (PACF)<sup>۱۳</sup> است.

**مرحله سوم:** برآورد مدل عمدتاً وابسته به تشخیص مدل در مرحله دوم است. مدل را می‌توان با روش OLS یا روش‌های دیگر مانند حداکثر درست‌نمایی برآورد نمود.

**مرحله چهارم:** در این مرحله با توجه به توابع خودهمبستگی و خودهمبستگی جزئی و آماره‌ی باکس والزانگ، مستقل بودن سری پسماندها مورد آزمون قرار می‌گیرد. مدل خودرگرسیو میانگین متحرک انباشته بهینه، مدلی است که پسماند‌های آن فاقد همبستگی خطی باشند.

**مرحله پنجم:** در این مرحله با استفاده از مدل خود رگرسیو میانگین متحرک انباشته ایی که بین سری پسماندهای آن همبستگی وجود ندارد به پیش بینی ارزش متغیر در آینده می پردازیم.

## ۲-۲- ماشین بردار پشتیبان (SVM)

پایه‌های SVM در سال ۱۹۹۵ توسط ولادیمیر واپنیک<sup>۱۴</sup> گذارده شد. این ماشین‌های یادگیری به دلیل دارا بودن ویژگی‌های خاص و کارایی بالا در عمل به سرعت به شهرت بالایی دست یافتند و بسیاری از الگوریتم‌های یادگیری پیش از خود را کم اعتبار نمودند.

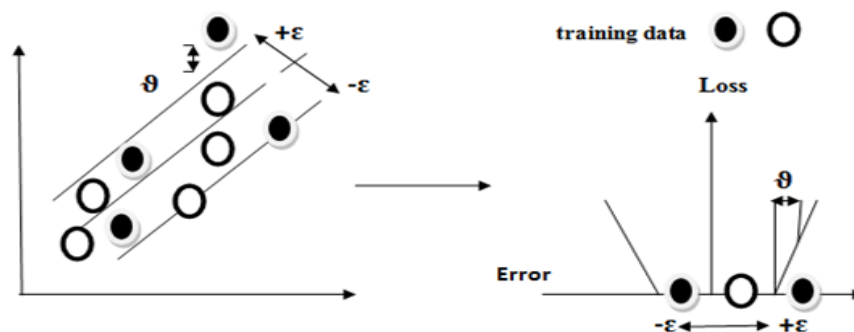
فرمول بندی SVM مینیمم کردن ریسک ساختاری (SRM)<sup>۱۵</sup> را به کار می‌گیرد که برتری آن نسبت به مینیمم کردن ریسک تجربی (ERM)<sup>۱۶</sup> که در شبکه‌های عصبی رواج دارد ثابت شده است. (گان<sup>۱۷</sup>، ۱۹۹۸). این در واقع تفاوتی است که به SVM توانایی تعمیم بالاتری می‌دهد و هدف یادگیری آماری نیز جز این نیست. از آنچه گفته شد می‌توان نتیجه گرفت که SVMها قادرند خطای طبقه بندی را هم در آموزش و هم در رویارویی با داده‌های نادیده مینیمم کنند. این در حالی است که در شبکه‌های عصبی سه لایه مرزهای تصمیم مستقیماً تعیین نمی‌شوند و کارایی شبکه در فاز تست وابسته به تعداد داده‌های آموزش، روش آموزش و وزن‌های اولیه دارد. این موضوع در صورتی که تعداد داده‌ها کم باشد به شدت قابلیت تعمیم را تنزل می‌دهد. (آبه<sup>۱۸</sup>، ۲۰۰۵) واضح است که SVMها از این حیث نیز از سایر طبقه‌بندها برترند و حتی با وجود یک مشاهده برای هر کلاس نیز به خوبی کار می‌کنند.

در یادگیری و به طور دقیق‌تر در یادگیری از روی نمونه‌ها، یک مجموعه از مشاهدات در اختیار یادگیرنده قرار می‌گیرد و سیستم یادگیرنده با یک الگوریتم مناسب از روی این داده‌ها یک مدل می‌سازد. این مدل پس از تکمیل قادر خواهد بود که نماینده تمام داده‌ها باشد. در واقع ثمره فرآیند یادگیری را در این مدل می‌توان خلاصه کرد و دیگر به وجود داده‌ها نیازی نخواهد بود. چنین مدلی شامل یک یا چند تابع تصمیم خواهد بود. توابع تصمیم را می‌توان به الگوهای آموخته شده از مشاهدات موجود توسط ماشین یادگیری تعبیر نمود. بنابراین در فاز تست، توابع تصمیم که نقش آموخته‌ها و تجربیات یادگیرنده را بازی می‌کنند تعیین کننده پاسخ خروجی ماشین یادگیری به ازای داده‌های تست می‌باشند.

طبقه‌بندهای مبتنی بر شبکه‌های عصبی چندلایه نسبت به حضور داده‌های خارجی آسیب پذیرند زیرا از حاصل جمع مربعات خطاها استفاده می‌کنند. بنابراین، برای جلوگیری از تأثیر داده‌های خارجی بایستی پیش از آموزش حذف گردند. و یا مکانیزمی برای کم اثر کردن داده‌های خارجی باید در آموزش اتخاذ شود. در SVMها، پارامتر حاشیه C خطای طبقه بندی را کنترل می‌کند. اگر مقدار آن را بزرگ انتخاب کنیم، خطای طبقه بندی به کمینگی می‌گراید و اگر مقدار کوچکی برای آن برگزینیم، در واقع پذیرفته‌ایم که داده‌هایی که از مراکز تجمع دور هستند اشتباه طبقه بندی شوند. پس با انتخاب درست C، داده‌های خارجی کم اثر خواهند بود.


در آموزش یک طبقه‌بند مبتنی بر شبکه‌های عصبی چندلایه، حاصل جمع مربعات خطاهای موجود میان ورودی‌ها و خروجی‌های مطلوب کمینه می‌شود. بنابراین، مرزهای کلاس و در نتیجه قابلیت تعمیم به مقدار قابل

ملاحظه‌ای تقلیل می‌یابد. اما از آنجا که در SVM بنای آموزش بر بیشینه کردن حاشیه است، قابلیت تعمیم حتی در شرایط خاص مذکور هم آنچنان دست‌خوش تغییر نمی‌شود (آبه، ۲۰۰۱).  
 ماشین بردار پشتیبان، تابع رگرسیون را با به کارگیری یک تابع خطی تخمین می‌زند و عملیات رگرسیون را با تابعی که انحراف از مقدار واقعی در آن به میزان کمتر از  $\epsilon$  مجاز است انجام می‌دهد (تابع ضرر)  $\epsilon$ ، ماشین بردار پشتیبان با کمینه کردن ریسک ساختاری جواب بهینه را ارائه می‌دهد. در رگرسیون نیز SVM ها پس از نگاشت داده‌ها به فضای ویژگی، مسائل پیچیده را به صورت رگرسیون خطی حل می‌نمایند.



شکل ۱- تابع ضرر و پنینک

مساله رگرسیون خطی در SVM به آسانی قابل گسترش به رگرسیون غیر خطی است. بدین منظور از توابع کرنل استفاده می‌شود و تاکنون کرنل های گوناگونی از جمله کرنل های چند جمله‌ای و پایه شعاعی (RBF) معرفی شده اند.



شکل ۲- فرایند ماشین بردار پشتیبان

## ۲-۳- مدل ترکیبی (hybrid model)

در مدل ترکیبی سعی بر این داریم که روابط غیرخطی در پسماندها را با استفاده از SVM مدل‌سازی کرده و پیش‌بینی پسماندهای حاصل از ماشین بردار پشتیبان را به پیش‌بینی خودرگرسیون میانگین متحرک انباشته اضافه کنیم. با این ترکیب الگوهای خطی بوسیله‌ی ARIMA و الگوهای غیرخطی بوسیله‌ی SVM مدل‌سازی خواهند شد. از مدل ترکیبی به منظور بالابردن دقت پیش‌بینی قیمت هفتگی نفت خام برنت که به عنوان نفت شاخص معرفی می‌شود و مبنای قیمت‌گذاری دو سوم معاملات در بازارهای بورس نفت و فرآورده‌های نفتی است استفاده خواهیم کرد و فرضیه‌های پژوهش را مورد آزمون قرار می‌دهیم.

## ۲-۳-۱ فرآیند مدل ترکیبی

سری زمانی  $Y_t$  را می‌توان به دو بخش خطی و غیر خطی تقسیم کرد.

$$Y_t = L_t + N_t \quad (3)$$

در این مدل  $L_t$  به عنوان بخش خطی و  $N_t$  به عنوان بخش غیرخطی مدل ترکیبی معرفی می‌شود. در معادله زیر  $\hat{L}_t$  بیانگر پیش‌بینی بخش خطی مدل از طریق مدل خودرگرسیون میانگین متحرک انباشته در زمان  $t$  و  $e_t$  نشان دهنده پسماند در زمان  $t$  است که از طریق مدل خودرگرسیون میانگین متحرک انباشته محاسبه شده است.

$$e_t = Y_t - \hat{L}_t \quad (4)$$

پسماندها از طریق ماشین بردار پشتیبان مدل‌سازی شده و به صورت زیر نمایش داده می‌شوند.

$$e_t = f(e_{t-1}, e_{t-2}, \dots, e_{t-n}) + \varepsilon_t \quad (5)$$

در معادله بالا  $f$  بیانگر تابع غیرخطی که از طریق ماشین بردار پشتیبان برازش می‌شود و  $\varepsilon_t$  به عنوان جزء اختلال معرفی می‌شود. در معادله زیر  $\hat{N}_t$  بیانگر پیش‌بینی پسماندها یا همان جزء غیرخطی است که از طریق ماشین بردار پشتیبان مدل‌سازی می‌شود و به بخش خطی مدل اضافه می‌گردد.

$$\hat{e}_t = \hat{N}_t \quad (6)$$

$$\hat{Y}_t = \hat{L}_t + \hat{N}_t \quad (7)$$

$\hat{Y}_t$ : پیش‌بینی مدل ترکیبی

$\hat{L}_t$ : پیش‌بینی مدل خودرگرسیون میانگین متحرک انباشته

$\hat{N}_t$ : پیش‌بینی پسماندها با ماشین بردار پشتیبان

## ۲-۴- پیشینه پژوهش

در تحقیقات داخلی و خارجی مطالعات زیادی انجام شده است که برتری مدل شبکه‌های عصبی مصنوعی را بر روش‌های سنتی در پیش‌بینی سری‌های زمانی نشان داده‌اند. اما در زمینه روش‌های ترکیبی ماشین بردار پشتیبان و روش‌های سنتی در تحقیقات داخلی مطالعات کمی صورت گرفته است، از این رو نمونه‌هایی از

تحقیقات انجام شده به وسیله روش‌های سنتی و مدل شبکه‌های عصبی مصنوعی که برای پیش‌بینی مورد استفاده قرار گرفته است را ذکر خواهیم کرد.

هونگ ژان و همکاران (۲۰۱۲)<sup>۲۰</sup> برای پیش‌بینی بارگذاری کوتاه‌مدت الکتروسیته با ترکیب مدل‌های خودرگرسیو میانگین متحرک انباشته و ماشین بردار پشتیبان به پیش‌بینی مدیریت کارای سیستم نیرو پرداختند و بیان نمودند که پیش‌بینی سری‌های زمانی از طریق مدل ترکیبی خودرگرسیو میانگین متحرک انباشته و ماشین بردار پشتیبان در مقایسه با کاربرد مجزای مدل‌های ARIMA و SVM از دقت بیشتری برخوردار است و معیارهای ارزیابی RMSE و MAPE کمتری را نشان می‌دهد. گاوریشچاکا و بانرجی (۲۰۰۶)<sup>۲۱</sup> با توجه به داده‌های مربوط به ۷۵۰ روز شاخص S&P500 بین سال‌های ۱۹۹۹ تا ۲۰۰۳، ۵۰۰ داده را به عنوان مجموعه آموزش و ۲۵۰ داده بعدی را برای مجموعه آزمون مورد استفاده قرار دادند. همچنین آنها از چند تابع کرنل در تحقیق خود استفاده کردند و به این نتیجه دست یافتند که کرنل RBF<sup>۲۲</sup> جهت پیش‌بینی بهتر عمل می‌کند و پژوهش آنها نشان داد که SVM بر مدل‌های EGARCH و GARCH برتری دارد. پینگ و چین (۲۰۰۵)<sup>۲۳</sup> با استفاده از مجموعه داده‌های مربوط به قیمت واقعی سهام ده شرکت با توجه به پیش‌بینی یک گام به جلو بیان نمودند که مدل ترکیبی سری‌های زمانی قیمت سهام در مقایسه با مدل‌های خودرگرسیو میانگین متحرک انباشته و ماشین بردار پشتیبان، معیارهای ارزیابی MAPE و RMSE کمتری را نشان می‌دهد و دقت پیش‌بینی مدل ترکیبی نسبت به پیش‌بینی مجزا به وسیله هر یک از مدل‌های ماشین بردار پشتیبان و خودرگرسیو میانگین متحرک انباشته بیشتر است.

یو، وانگ ولای (۲۰۰۵)<sup>۲۴</sup> با توجه به مقادیر شاخص S&P و چند نماگر تحلیل تکنیکال به عنوان ورودی و انتخاب متغیرها به وسیله الگوریتم ژنتیک و طراحی مدل ماشین بردار پشتیبان با توجه به تابع RBF جهت پیش‌بینی روند بازار، در نهایت مدل ترکیبی خود را با شبکه عصبی پس‌انتشار خطا، ARIMA و SVM مقایسه نمودند. پژوهش آنها نشان داد که روش ترکیبی ماشین بردار پشتیبان با الگوریتم ژنتیک بر دیگر روش‌ها برتری دارد، در ضمن سریع‌تر از سایر روش‌ها عمل می‌کند. گوک (۲۰۰۲)<sup>۲۵</sup> در مطالعه مقایسه‌ای از شبکه‌ی عصبی و مدل باکس و جنکینز در پیش‌بینی سری‌های زمانی به منظور برازش مدل شبکه‌ی عصبی پیش‌خور چندلایه و مدل خودرگرسیو میانگین متحرک انباشته و مقایسه‌ی عملکرد این مدل‌ها در پیش‌بینی تعداد دفعات خرابی در سیستم کمپرسور، از سری زمانی ۹۰ خرابی در یک کارخانه نیروژی در طی سال‌های ۱۹۶۸ تا ۱۹۸۹ استفاده کردند. نتایج تحقیق آنها نشان داد که عملکرد مدل‌های شبکه‌ی عصبی بازگشتی و خودرگرسیو میانگین متحرک انباشته، از نظر دو مقیاس ارزیابی میانگین مجذور خطا (MSE) و میانگین قدر مطلق خطا (MAE) هم در کوتاه‌مدت و هم در بلندمدت نسبت به شبکه‌ی عصبی پیش‌خور چندلایه دارای خطای کمتری می‌باشند.

طیسی (۱۳۹۱) با توجه به برآوردهای صورت گرفته برای ارزش در معرض ریسک با استفاده از مدل‌های سنتی پیش‌بینی نوسانات چون GARCH و EGARCH و انجام پس‌آزمون لویز و پس‌آزمون مبتنی بر ریزش مورد انتظار که رویکردهایی مقایسه‌ای برای سنجش اعتبار ارزش در معرض ریسک هستند با عملکرد مدل ترکیبی مورد مقایسه قرار گرفتند و نتایج حاصل از این پژوهش نشان داد که مدل ترکیبی نسبت به سایر مدل‌های مورد

استفاده در این تحقیق، به طور معناداری از عملکرد بهتری برخوردار است. راعی و فلاح‌پور (۱۳۸۷) اذعان داشتند که بر اساس نتیجه بررسی‌ها، مدل SVM می‌تواند جانشین بسیار قدرتمندی برای مدل آماری رگرسیون لجستیک باشد. در واقع یافته‌های این تحقیق نشان داد که دقت کلی مدل ماشین بردار پشتیبان از دقت کلی مدل رگرسیون لجستیک به طور معناداری بیشتر است. به ویژه آنکه قدرت تعمیم‌پذیری مدل ماشین بردار پشتیبان بیشتر از مدل رگرسیون لجستیک می‌باشد. زراءنژاد و حمید (۱۳۸۸) جهت پیش‌بینی نرخ تورم در اقتصاد ایران با استفاده از شبکه‌های عصبی پویا (دیدگاه سری زمانی) از طریق شبکه‌های عصبی مصنوعی در هر مرحله برای انتخاب بهترین شبکه، خطاها و میزان پراکندگی جواب‌ها محاسبه گردید تا مدل بهینه برای پیش‌بینی نرخ تورم انتخاب گردد. از آنجا که در دیدگاه سری زمانی وظیفه پیش‌بینی متغیرهای اقتصادی به عهده خود سری زمانی گذاشته می‌شود، به محقق اجازه تعیین سهم سایر عوامل موثر در تغییرات متغیر مورد نظر داده نمی‌شود و مدل طراحی شده بر اساس این دیدگاه تنها به فراگیری و مطالعه گذشته متغیر خواهد پرداخت. لذا اگر خطایی در داده‌های گذشته باشد یا رخ دهد، مدل براساس ورودی، مقادیر آتی را پیش‌بینی خواهد کرد و خطاهای مقادیر گذشته را به مقادیر آینده منتقل می‌کند. نوری، خاکپور، دهقانی و فرخ‌نیا (۱۳۸۹) برای پیش‌بینی ماهانه جریان آب با استفاده از ماشین بردار پشتیبان بر مبنای آنالیز مولفه اصلی<sup>۲۶</sup> (PCA) با هدف بررسی تاثیر انتخاب متغیرهای ورودی بر اساس آنالیز مولفه اصلی بر عملکرد مدل ماشین بردار پشتیبان انجام شد. به این منظور ابتدا با استفاده از ۱۸ متغیر به عنوان ورودی به مدل SVM، دبی جریان ماهانه آب پیش‌بینی گردید و سپس با استفاده از آنالیز مولفه اصلی تعداد متغیرهای ورودی به مدل ماشین بردار پشتیبان از ۱۸ متغیر به ۵ مولفه کاهش یافت. در نهایت با استفاده از آماره توسعه یافته توسط نویسنده‌گان مقاله، عملکرد مدل‌های ارائه شده (SVM و PCA-SVM) مورد ارزیابی قرار گرفتند و یافته‌های تحقیق نشان داد که پیش‌پردازش متغیرهای ورودی به مدل SVM با استفاده از PCA، بهبود عملکرد SVM را به همراه داشته است.

منجمی، ابرزی و شوازی (۱۳۸۸) به طراحی و ارائه یک مدل پیش‌بینی قیمت سهام با استفاده از شبکه عصبی مصنوعی فازی و الگوریتم‌های ژنتیک جهت کاهش خطای پیش‌بینی قیمت سهام با استفاده از آن نسبت به استفاده از تکنیک شبکه عصبی مصنوعی به صورت منفرد پرداختند و پس از طراحی و پیاده‌سازی مدل‌ها با استفاده از چهار معیار سنجش خطا ( $R^2$ , MAPE, NMSE, MSE) دو مدل مورد مقایسه قرار گرفت. مقایسه‌ی نتایج حاصل از مدل شبکه عصبی با نتایج حاصل از مدل شبکه‌ی عصبی فازی و الگوریتم ژنتیک نشان داد که از نقطه نظر معیارهای ارزیابی عملکرد، پیش‌بینی قیمت سهام روز بعد توسط مدل ترکیبی شبکه عصبی فازی و الگوریتم ژنتیک دقیق‌تر از شبکه عصبی است، به عبارتی دیگر پیش‌بینی قیمت سهام با استفاده از شبکه عصبی فازی و الگوریتم‌های ژنتیک، خطای برآورد قیمت سهام را نسبت به تکنیک شبکه عصبی مصنوعی کاهش می‌دهد. رضانی (۱۳۸۳) در پژوهش خود به این نتیجه دست یافت که در پیش‌بینی میزان تقاضای ماهیانه مصرف برق با توجه به داده‌های مربوط به سال‌های ۱۳۷۰ تا سال ۱۳۸۱ و با توجه به پیش‌بینی‌های صورت گرفته توسط مدل‌های بهینه، شبکه عصبی میزان MSE و MAPE کمتری را در پیش‌بینی انجام گرفته نسبت به مدل خودرگرسیون میانگین متحرک انباشته داشته است و با توجه به معیارهای ارزیابی فوق مشخص است که شبکه



های عصبی مصنوعی عملکرد بهتری از مدل‌های خودرگرسیو میانگین انباشته در خصوص پیش‌بینی مقادیر سری‌زمانی داشته‌اند.

### ۳- بیان مسئله و فرضیه‌های پژوهش

مسئله اصلی پژوهش و مبنای فرضیه‌های پژوهش این موضوع است که آیا مدل ترکیبی خطای کمتری در پیش‌بینی قیمت هفتگی نفت خام نسبت به کاربرد مدل‌های خودرگرسیو میانگین متحرک انباشته و ماشین بردار پشتیبان به طور مجزا دارد؟

**فرضیه اول:** بین دو جامعه ریشه میانگین مجذور خطا مدل ترکیبی و مدل ARIMA اختلاف معناداری وجود دارد.

**فرضیه دوم:** بین دو جامعه ریشه میانگین مجذور خطا مدل ترکیبی و مدل SVM اختلاف معناداری وجود دارد. **فرضیه سوم:** بین دو جامعه میانگین قدرمطلق درصد خطا مدل ترکیبی و مدل ARIMA اختلاف معناداری وجود دارد.

**فرضیه چهارم:** بین دو جامعه میانگین قدرمطلق درصد خطا مدل ترکیبی و مدل SVM اختلاف معناداری وجود دارد.

### ۴- روش‌شناسی پژوهش

این پژوهش از لحاظ روش، توصیفی و از لحاظ هدف، کاربردی محسوب می‌شود چرا که می‌تواند در فرآیند تصمیم‌گیری مورد استفاده قرار گیرد و هدف تحقیق کاربردی، توسعه دانش کاربردی در یک زمینه خاص می‌باشد. مبانی نظری پژوهش از طریق مطالعات کتابخانه‌ای یعنی مطالعه مقالات و کتب منتشر شده به دست آمده و بر پایه آن فرضیه‌های پژوهش تدوین گردیده است. جهت برازش هر یک از مدل‌های خودرگرسیو میانگین متحرک انباشته، ماشین بردار پشتیبان و مدل ترکیبی و مقایسه عملکرد مدل‌ها با یکدیگر از قیمت هفتگی نفت خام برنت از ابتدای سال ۲۰۰۶ تا سپتامبر ۲۰۱۲ برای پیش‌بینی متغیر مورد نظر تحقیق که قیمت هفتگی نفت خام برنت می‌باشد، استفاده شده است. با توجه به اینکه در انجام این تحقیق هدف را بر مبنای مقایسه عملکرد مدل ترکیبی نسبت به هر یک از مدل‌های خودرگرسیو میانگین متحرک انباشته و ماشین بردار پشتیبان برای پیش‌بینی قیمت پایانی برای یک مرتبه پیش‌رو (one step ahead) قرار دادیم، بنابراین در مرحله اول با توجه به مطالب مطرح شده در بخش مبانی نظری از (328) مشاهده به منظور برازش هر یک از مدل‌ها و پیش‌بینی مشاهده (۱۳۲۹م) برای قیمت پایانی استفاده شده و در مرحله بعد مشاهده واقعی (۱۳۲۹م) که مربوط به اولین هفته‌ای است که پیش‌بینی در مورد آن صورت گرفته است را به منظور برازش مجدد مدل به سری زمانی اضافه کرده و قیمت پایانی مرتبه (هفته) بعد را که مشاهده (۱۳۳۰م) می‌باشد را پیش‌بینی می‌کنیم و مراحل فوق را برای بیست مرتبه (هفته) تا پیش‌بینی مشاهده پایانی تکرار می‌کنیم. با توجه به پیش‌بینی‌های

انجام شده برای بیست هفته پیش‌رو معیارهای ارزیابی عملکرد ریشه میانگین مجذور خطا (RMSE) و میانگین قدر مطلق درصد خطا (MAPE) که نحوه محاسبه آن در زیر آمده است برای هر هفته و برای هر سه مدل محاسبه می‌شود. در مرحله پایانی با توجه به معیارهای ارزیابی عملکرد و با استفاده از آزمون مقایسه زوجی فرضیه‌های تحقیق را مورد آزمون قرار خواهیم داد.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (Y_{(i)} - F_{(i)})^2} \quad (18)$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{Y_{(i)} - F_{(i)}}{Y_{(i)}} \right| \times 100 \quad (19)$$

$Y_{(i)}$ : مقدار واقعی متغیر

$F_{(i)}$ : مقدار پیش‌بینی متغیر

n: تعداد اجزاء خارج نمونه‌ای

##### ۵- نتایج پژوهش

در این بخش با توجه به مدل‌های کاربردی مطرح شده در مبانی نظری، معیارهای ارزیابی عملکرد به همراه نتایج آزمون مقایسه زوجی برای بررسی فرضیه‌های پژوهش مورد بررسی قرار گرفته است.

جدول ۱- ریشه‌ی میانگین مربع خطا

مرتبۀ (هفته پیش‌رو)	RMSE (ریشه میانگین مربع خطا)		
	ARIMA	SVM	Hybrid
۱	0.2601	0.5052	0.0656
۲	0.9000	0.9685	0.2259
۳	0.6118	0.5911	0.4156
۴	0.0586	0.3524	0.0449
۵	2.9778	2.8570	2.4986
۶	1.6346	1.4235	0.9985
۷	2.1659	3.2673	2.0678
۸	1.4192	1.8413	1.3162
۹	0.1966	0.5291	0.1693
۱۰	1.5749	1.8110	1.5250

مرتبۀ (هفته پیش رو)	RMSE (ریشه میانگین مربع خطا)		
	ARIMA	SVM	Hybrid
۱۱	0.1152	1.8759	0.0820
۱۲	0.8354	2.3406	0.2879
۱۳	0.1874	1.2011	0.6840
۱۴	2.5938	1.0010	0.8041
۱۵	1.7121	1.5631	1.2764
۱۶	0.8455	0.8291	0.8506
۱۷	1.6332	0.1436	1.2835
۱۸	2.3142	1.6021	2.3262
۱۹	0.8389	0.8458	0.7467
۲۰	0.1057	0.3062	0.1083
میانگین	1.1490	1.2928	0.8889

**فرضیه اول:**

$H_0$ : بین دو جامعه ریشه میانگین مجذور خطا مدل ترکیبی و مدل ARIMA اختلاف معناداری وجود ندارد.  
 $H_1$ : بین دو جامعه ریشه میانگین مجذور خطا مدل ترکیبی و مدل ARIMA اختلاف معناداری وجود دارد.

**فرضیه دوم:**

$H_0$ : بین دو جامعه ریشه میانگین مجذور خطا مدل ترکیبی و مدل SVM اختلاف معناداری وجود ندارد.  
 $H_1$ : بین دو جامعه ریشه میانگین مجذور خطا مدل ترکیبی و مدل SVM اختلاف معناداری وجود دارد.

**جدول ۲ - آزمون مقایسه زوجی ریشه میانگین مجذور خطا**

Mean	RMSE			
	- ARIMA Hybrid		Hybrid - SVM	
	Hybrid	ARIMA	Hybrid	SVM
	۰/۸۸۸۸	۱/۱۴۹۰	۰/۸۸۸۸	۱/۲۹۲۷
Observations	۲۰		۲۰	
Df	۱۹		۱۹	
t Stat	-۲,۵۶		-۲,۵۴	
P(T<=t) one-tail	۰,۰۰۹۴		۰,۰۰۹۷	
t Critical one-tail	۱,۷۲		۱,۷۲	
P(T<=t) two-tail	۰,۰۱۸۸		۰,۰۱۹۵	
t Critical two-tail	۲,۰۹۳		۲,۰۹۳	

با توجه به جدول فوق بین میانگین دو جامعه‌ی RMSE از مدل ترکیبی در مقایسه با مدل خودرگرسیون میانگین متحرک انباشته (ARIMA) و مدل ماشین بردار پشتیبان اختلاف معناداری وجود دارد و میانگین RMSE مدل ترکیبی در نمونه‌های مورد بررسی از دو مدل دیگر کمتر است. بنابراین، از نظر معیار ارزیابی RMSE، عملکرد مدل ترکیبی به طور معناداری در پیش‌بینی قیمت پایانی نفت خام از دو مدل خودرگرسیون میانگین متحرک انباشته و ماشین بردار پشتیبان بهتر عمل می‌کند.

جدول ۳- میانگین قدرمطلق درصد خطا

مرتبۀ (هفته پیش رو)	میانگین قدرمطلق درصد خطا (MAPE)		
	ARIMA	SVM	Hybrid
۱	0.002536	0.004926	0.000639
۲	0.008725	0.009389	0.00219
۳	0.005895	0.005696	0.004004
۴	0.000566	0.003405	0.000434
۵	0.031982	0.030685	0.026835
۶	0.017987	0.015663	0.010987
۷	0.024879	0.03753	0.023752
۸	0.016809	0.021809	0.01559
۹	0.00236	0.006355	0.002034
۱۰	0.019417	0.022328	0.018802
۱۱	0.001317	0.003816	0.00135
۱۲	0.001343	0.021869	0.000956
۱۳	0.009399	0.026334	0.003239
۱۴	0.002104	0.01348	0.007676
۱۵	0.027468	0.010601	0.008515
۱۶	0.017794	0.016245	0.013265
۱۷	0.008837	0.008665	0.00889
۱۸	0.017069	0.001501	0.013414
۱۹	0.023721	0.016422	0.023844
۲۰	0.009176	0.009252	0.008168
میانگین	0.012469	0.014299	0.009729

## فرضیه سوم

H<sub>0</sub>: بین دو جامعه میانگین قدرمطلق درصد خطا مدل ترکیبی و مدل ARIMA اختلاف معناداری وجود ندارد.  
H<sub>1</sub>: بین دو جامعه خطای میانگین قدرمطلق درصد خطا مدل ترکیبی و مدل ARIMA اختلاف معناداری وجود دارد.

## فرضیه چهارم

H<sub>0</sub>: بین دو جامعه میانگین قدرمطلق درصد خطا مدل ترکیبی و مدل SVM اختلاف معناداری وجود ندارد.  
H<sub>1</sub>: بین دو جامعه میانگین قدرمطلق درصد خطا مدل ترکیبی و مدل SVM اختلاف معناداری وجود دارد.  
با توجه به جدول فوق بین میانگین دو جامعه MAPE از مدل ترکیبی و مدل خودرگرسیون میانگین متحرک انباشته و دو جامعه میانگین قدرمطلق درصد خطا از مدل ترکیبی و مدل ماشین بردار پشتیبان اختلاف معناداری وجود دارد و میانگین MAPE برای مدل ترکیبی در نمونه‌ی مورد بررسی از دو مدل دیگر کمتر است. بنابراین، از نظر معیار ارزیابی میانگین قدر مطلق درصد خطا، مدل ترکیبی به طور معناداری در پیش‌بینی قیمت پایانی از دو مدل خودرگرسیون میانگین متحرک انباشته و ماشین بردار پشتیبان بهتر عمل می‌کند.

جدول ۴- آزمون مقایسه زوجی میانگین قدرمطلق درصد خطا

mean	MAPE			
	Hybrid – ARIMA		Hybrid – SVM	
	Hybrid	ARIMA	Hybrid	SVM
	۰/۰۰۹۷	۰/۰۱۲۴۷	۰/۰۰۹۷	۰/۰۱۴۳۰
Observations	۲۰		۲۰	
Df	۱۹		۱۹	
t Stat	-۲,۵۹۰		-۲,۵۴۱	
P(T<=t) one-tail	۰,۰۰۸۹		۰,۰۰۹۹	
t Critical one-tail	۱,۷۲		۱,۷۲	
P(T<=t) two-tail	۰,۰۱۷۹		۰,۰۱۹۹	
t Critical two-tail	۲,۰۹۳		۲,۰۹۳	

## ۶- نتیجه‌گیری و بحث

با توجه به محاسبه معیارهای ارزیابی عملکرد ریشه میانگین مجذور خطا و میانگین قدرمطلق درصد خطا برای پیش‌بینی قیمت‌ها برای هر یک از سه مدل و انجام آزمون فرضیه‌ها، نتایج بیانگر این بودند که مدل ترکیبی در پیش‌بینی قیمت در مقایسه با مدل‌های خودرگرسیون میانگین متحرک انباشته و مدل ماشین بردار پشتیبان دارای خطای کمتری می‌باشد و فرضیه‌های تحقیق مبنی بر کمتر بودن خطای پیش‌بینی مدل ترکیبی

نسبت به مدل ARIMA و SVM رد نشدند. در مقایسه با نتیجه گیری‌های حاصل شده از این پژوهش با پژوهش‌های داخلی و خارجی انجام شده در زمینه کاربرد مدل‌های ترکیبی برای پیش‌بینی، دقت مدل‌های ترکیبی نسبت به کاربرد مجزای مدل‌های مورد استفاده برای پیش‌بینی مورد تایید قرار گرفت. در تحقیق حاضر به مدل سازی الگوهای غیرخطی پسماندها از طریق ماشین بردار پشتیبان و اضافه کردن آنها به بخش پیش‌بینی خطی خودرگرسیو میانگین متحرک انباشته پرداختیم ولی برای بررسی کارایی و مقایسه نتایج می‌توان این پسماندها را به مدل شبکه‌های عصبی از جمله شبکه عصبی پیش‌خورداد تا دقت آن را نسبت به ماشین بردار پشتیبان مورد سنجش قرار داد و دقت پیش‌بینی ترکیب شبکه عصبی و ARIMA را نسبت به کاربرد مجزای هر یک از مدل‌ها مورد بررسی قرار داد.

### فهرست منابع

- \* راعی، رضا و فلاح‌پور، سعید (۱۳۸۷). کاربرد ماشین بردار پشتیبان در پیش‌بینی درماندگی مالی شرکت‌ها با استفاده از نسبت‌های مالی. بررسی‌های حسابداری و حسابرسی، ۴، ۳۴-۱۷.
- \* رضانی، رضا (۱۳۸۳). مقایسه عملکرد پیش‌بینی در مدل‌های شبکه عصبی مصنوعی و ARIMA (مورد مطالعه: تقاضای ماهیانه برق در ایران)، پایان‌نامه کارشناسی ارشد، دانشکده مدیریت دانشگاه تهران.
- \* زراءنژاد، منصور و حمید، شهرام (۱۳۸۸). پیش‌بینی نرخ تورم در اقتصاد ایران با استفاده از شبکه‌های عصبی پویا (دیدگاه سری زمانی)، فصلنامه اقتصاد مقداری، ۶۷، ۱-۹۸.
- \* سوری، علی (۱۳۹۱). اقتصاد سنجی همراه با کاربرد Eviews 7، تهران: انتشارات چاپ‌الغدیر.
- \* صادقی، مهدی و شوال‌پور، سعید (۱۳۸۶). اقتصادسنجی سری‌های زمانی با رویکرد کاربرد، تهران: انتشارات دانشگاه امام صادق (ع).
- \* صادقی، آ (۱۳۸۹). پیش‌بینی شاخص قیمت سهام در بورس اوراق بهادار تهران با رویکرد ماشین بردار پشتیبان. پایان‌نامه کارشناسی ارشد، دانشکده مدیریت دانشگاه تهران.
- \* طبسی، م (۱۳۹۱). برآورد ارزش در معرض ریسک با استفاده از مدل ترکیبی ماشین بردار پشتیبان و گارچ. پایان‌نامه کارشناسی ارشد، دانشکده مدیریت دانشگاه تهران.
- \* منجمی، سید امیرحسین، ابرزی، مهدی و شوازی، علیرضا (۱۳۸۸). پیش‌بینی قیمت سهام در بورس اوراق بهادار با استفاده از شبکه عصبی فازی و الگوریتم‌های ژنتیک و مقایسه‌ی آن با شبکه‌ی عصبی مصنوعی. فصل‌نامه اقتصاد مقداری، ۲۲، ۲۶-۱.
- \* نوری، روح‌اله، خاکپو، امیر، دهقانی، مجید و فرخ‌نیا، اشکان (۱۳۹۰). پیش‌بینی ماهانه جریان آب با استفاده از ماشین بردار پشتیبان بر مبنای آنالیز مولفه اصلی. فصلنامه علمی و پژوهشی آب و فاضلاب، ۷۷، ۱۱۸-۱۲۳.

- \* Abe, S. (2005) support vector machines for pattern classification, springer, london.
- \* Brooks, C (2008). Introductory Econometrics for Finance, UK Cambridge university press.
- \* Enders, W (1995). Applied Econometric Time Series.

- \* Gavrishchka, v & Banerjee, s (2006). Support vector machines an efficient for stock market volatility forecasting, springer, 3, 147-160
- \* Gunn, S (1998). Support Vector Machines for Classification and Regression, university of south Ampton. 147-165.
- \* Gok, T (2002). comparative study of neural networks and Box-Jenkins ARIMA modeling in time series prediction, Computer & Industrial Engineering jurnal, 371-375.
- \* Hongzhan, N, Guohui, L, Xiaoman & Yong, W (2012). Hybrid of ARIMA and SVMs for Short-Term Load Forecasting, 16, 1455-1460.
- \* Huang, Z, Chen, h, jung, c, hwa, w & soushan, w (2004). credit rating analysis with support vector machines and neural network a market comparative study, Decision support system, 37, 543-558.
- \* Lipo, W (2005). Support Vector Machines: Theory and Applications, Springer. 2, 38-96.
- \* McKenzie, E (1988) A note on using the integrated form of ARIMA forecasts, International Journal of Forecasting, 4, 117-134.
- \* PackD, J (1990). In defense of ARIMA modeling, International Journal of Forecasting, 6, 20-36.
- \* Ping, P & Chin, L (2005). a hybrid ARIMA and support vector machines model in stock price forecasting, omega, 33, 497-505.
- \* Sanchez, D (2003). Advanced Support Vector Machines and Kernel methods, Nero computing, 48, 5-20.
- \* Tsay, R (2002). Analysis of Financial Time Series, John Wiley & sons. 2, 70-89.
- \* Vapnik, V (1995). The nature of statistical learning theory, Springer. 2, 12-68

## یادداشت‌ها

---

- 1 - Autoregressive Integrated Moving Average
- 2 - Support Vector Machine
- 3 - hybrid model
- 4 - stationary
- 5 - Autoregressive Integrated Moving Average
- 6 - Box-Jenkins
- 7 - vapnik
- 8 - Huber
- 9 - Autoregressive conditional heteroskedasticity
- 10 - Generalized autoregressive conditional heteroskedasticity
- 11 - Threshold generalized autoregressive conditional heteroskedasticity
- 12 - Auto Correlation Function
- 13 - Partial Auto Correlation Function
- 14 - Vapnik
- 15 - Structural Risk Minimization
- 16 - Empirical Risk Minimization
- 17 - Gunn
- 18 - Abe
- 19 - Loss function
- 20 - Hongzhan
- 21 - Gavrishchka & Banerjee
- 22 - Radial Basis Function
- 23 - Ping & Chin
- 24 - Yu, Vannng & Lay
- 25 - Gok
- 26 - Principal component analysis