

ماشین های بردار پشتیبان

Support Vector Machine

پژوهشگر: مهدی غفاری

استاد: فاطمه شریفی زاده

واحد درسی: هوش مصنوعی

چکیده


در این تحقیق هدف ما معرفی روش ماشین های بردار پشتیبان بعنوان یکی از شاخه های مورد مطالعه در زمینه هوش مصنوعی است. سپس روش ماشین های بردار پشتیبان حداقل مربعات (*Least squares support vector machine LSSVM*) و ماشین های بردار پشتیبان دوقلو (*TSVM: TwinSupport Vector Machine*) که بعنوان 2 متذ تکامل یافته این روش را معرفی میکنیم. پس از معرفی سیر تکاملی روش ماشین های بردار پشتیبان گفته شده و بیان روابط ریاضی آنها به مقایسه عملکرد هر 3 روش برای طبقه بندی چند کلاسه می پردازیم. برای بررسی عملکرد آنها از دیتابیس های استاندارد UCI استفاده خواهیم کرد. برای پیاده سازی این 3 روش از نرم افزار متلب R2014b استفاده خواهیم کرد و نتایج را بصورت جدول هایی جهت مقایسه عملکرد هر یک از روش های بیان شده ارایه خواهیم داد.

معرفی

ماشین بردار پشتیبانی یکی از روش های یادگیری با نظارت است که از آن برای طبقه بندی خطی و غیرخطی و نیز رگرسیون چند بعدی استفاده می کنند. این روش از جمله روش های نسبتاً جدیدی است که در سال های اخیر کارایی خوبی نسبت به روش های قدیمی تر برای طبقه بندی از جمله شبکه های عصبی از خود نشان داده است. اساس کاری کلاس بندی کننده SVM کلاس بندی خطی داده ها است و در کلاس بندی خطی داده ها خطی را انتخاب کنیم که حاشیه اطمینان بیشتری داشته باشد. مساله پیدا کردن خط بهینه برای کلاس بندی داده ها به وسیله روش های QP که در حل مسائل محدودیت دار شناخته شده هستند صورت می گیرد. برای اینکه ماشین بتواند داده های با پیچیدگی بالا را نیز دسته بندی کند داده ها را به وسیله یک تبدیل کرنل به فضای با ابعاد خیلی بالاتر می برنند. برای اینکه بتوانیم مسئله ابعاد خیلی بالا را با استفاده از این روش ها حل کنیم از قضیه دوگان لاغرانژ برای تبدیل مسئله مینیمم سازی به فرم دوگان آن استفاده می کنیم. از توابع هسته مختلفی از جمله هسته های نمایی، چند جمله ای و سیگموید می توان استفاده نمود. الگوریتم SVM، جز الگوریتم های تشخیص الگو دسته بندی می شود. از الگوریتم SVM در هر جایی که نیاز به تشخیص الگو یا دسته بندی اشیا در کلاس های خاص باشد می توان استفاده کرد [1]. روش های ماشین های بردار پشتیبان حداقل مربعات و ماشین های بردار پشتیبان دوقلو نسخه های بهبود یافته از نظر سرعت و عملکرد این متذ هستند که در بخش های زیر آن ها را بصورت کامل بیان خواهیم کرد.

پژوهش های انجام شده در گذشته

این الگوریتم اولین بار در سال 1963 میلادی بوسیله Alexey Ya. Chervonenkis و Vladimir N. Vapnik () ابداع شد و در سال 1992 میلادی توسط Vladimir N. Vapnik Isabelle M. Guyon ، Bernhard E. Boser () با استفاده از ترفند کرنل (هسته) برای ساخت کلاس بندی کننده غیرخطی به کمک ابر صفحه ها، پیشنهاد شد. نسخه استاندارد که امروزه مورد استفاده قرار میگیرد در سال 1993 بوسیله Vladimir N. Vapnik و Corinna Cortes (Vladimir N. Vapnik پیشنهاد و در سال 1995 به چاپ رسید [2]. در سال 1999 میلادی روش ماشین های بردار پشتیبان حداقل مربعات توسط Suykens و همکاران (پیشنهاد در سال 1995 به چاپ رسید [3]. در سال 2007 روش ماشین های بردار پشتیبان دوقلو توسط Jayadeva و همکاران) معرفی و با عملکرد آن با روش های رایج کلاس بندی مقایسه و برتری های این روش نشان داده شد [4]. دو سال بعد از ارایه این روش نسخه ترکیبی 2 روش ماشین های بردار پشتیبان حداقل مربعات و دوقلو با عنوان ماشین های بردار پشتیبان دوقلوی حداقل مربعات بوسیله (M. Arun Kumar, M. Gopal) ارایه شد که نتایج بهتری نسبت به روش های گفته شده ارایه داد [5]. نسخه های مختلفی از روش ماشین های بردار پشتیبان دوقلو از سال 2007 تا 2016 براساس همین روش با اندکی تغییر معرفی و گاهی برای داده های خاصی نتایج بهتری را ارایه دادن که در شکل زیر تعدادی از آنها نشان داده شده است.



در ادامه هریک از متدها بصورت کامل توضیح داده خواهند شد.

کلاس بندی کننده‌ی (SVM)

منظور ما از کلاس بندی کننده در واقع یافتن خطی بصورت $w \cdot x + b = 0$ است که بتوانید بدرستی داده‌های 2 یا چند کلاس را از یکدیگر جدا کند. از آنجایی که لفظ خط بیشتر یادآور صفحه‌یا در بهترین حالت خم سه بعدی است برای داده‌هایی با ابعاد بالاتر باید از مفهوم کلی تری استفاده شود از لفظ ریاضی ابرصفحه به جای آن استفاده خواهیم کرد. در واقع به زبان ریاضی ابرصفحه زیرفضایی از فضای مورد مطالعه است که فقط به اندازه یک بعد با فضای مورد مطالعه تفاوت دارد، بنویان مثلاً یک صفحه 2 بعدی را بنویان فضا در نظر بگیریم ابرصفحه متناظر با آن یک خط معمولی و برای فضای 3 بعدی ابرصفحه ما یک صفحه 2 بعدی است و به همین ترتیب برای ابعاد بالاتر نیز این مفهوم تعمیم می‌ابد. شکل زیر را در نظر بگیرید.

ما مجموعه داده‌های آزمایش D شامل n عضو(نقطه) را در اختیار داریم که به صورت زیر تعریف می‌شود:

$$D = \left\{ (\mathbf{x}_i, y_i) | \hat{\mathbf{x}}_i \in \mathbb{R}^p, y_i \in \{-1, 1\} \right\}_{i=1}^n$$

جایی که مقدار y برابر 1 یا -1 و هر \mathbf{x}_i یک بردار حقیقی- p -بعدی است. هدف پیدا کردن ابرصفحه جداکننده با بیشترین فاصله از نقاط حاشیه‌ای است که نقاط با $y_i = 1$ را از نقاط با $y_i = -1$ جدا کند. هر ابرصفحه می‌تواند به صورت مجموعه ای از نقاط \mathbf{x} که شرط زیر را ارضاء می‌کند نوشت:

$\mathbf{w} \cdot \mathbf{x}_i - b = 0$ جایی که . علامت ضرب است \mathbf{w} . بردار نرمال است، که به ابرصفحه عمود است. می خواهیم \mathbf{w} و b را طوری انتخاب کنیم که بیشترین فاصله بین ابرصفحه‌های موازی که داده‌ها را از هم جدا می‌کنند، ایجاد شود. این ابرصفحه‌ها با استفاده از رابطه زیر توصیف می‌شوند.

اگر داده های آموزشی جدایی پذیر خطی باشند، می توانیم دو صفحه در حاشیه نقاط به طوری که هیچ نقطه مشترکی نداشته باشند، در نظر بگیریم و سپس سعی کنیم، فاصله آنها را، ماسکسیمم کنیم. با استفاده از هندسه، فاصله این دو صفحه $\frac{2}{\|\mathbf{w}\|}$ است. بنابر این ما باید $\|\mathbf{w}\|$ را مینیمم کنیم. برای اینکه از ورود نقاط به حاشیه جلو گیری کنیم، شرایط زیر را اضافه می کنیم: برای هر i و به ازای هر \mathbf{x}_i متعلق به کلاس اول داشته باشیم $\mathbf{w} \cdot \mathbf{x}_i - b \geq 1$ یا به ازای هر \mathbf{x}_i متعلق به کلاس دوم داشته باشیم $\mathbf{w} \cdot \mathbf{x}_i - b \leq -1$

می توان آن را به صورت زیر نیز نوشت:


$$y_i(\mathbf{w} \cdot \mathbf{x}_i - b) \geq 1, \quad 1 \leq i \leq n. \quad (1)$$

با کنار هم قرار دادن این دو یک مسئله بهینه سازی به دست می آید:

Minimize (\mathbf{w}, b) $\|\mathbf{w}\|$

subject to

$$(i = 1, \dots, n) y_i(\mathbf{w} \cdot \mathbf{x}_i - b) \geq 1.$$



مسئله بهینه سازی، مسئله سختی برای حل کردن است، زیرا به $\|\mathbf{w}\|$ وابسته است، بدون تغییر در مسئله $\|\mathbf{w}\|$ را با $\frac{1}{2} \|\mathbf{w}\|^2$ جانشین کنیم (عبارت $\frac{1}{2} \|\mathbf{w}\|^2$ برای آسودگی در محاسبات ریاضی آورده شده). و آن را به برنامه ریزی غیرخطی (QP) تبدیل کنیم، یعنی:

$$\text{Minimize } (\mathbf{w}, b) \quad \frac{1}{2} \|\mathbf{w}\|^2$$

subject to

$$(i = 1, \dots, n) y_i (\mathbf{w} \cdot \mathbf{x}_i - b) \geq 1.$$

می توان این عبارت را با استفاده از ضرایب نامنفی لاغرانژ به صورت زیر نوشت که در آن α_i ضرایب لاغرانژ هستند.

$$\min_{\mathbf{w}, b} \max_{\alpha} \left\{ \frac{1}{2} \|\mathbf{w}\|^2 - \sum_{i=1}^n \alpha_i [y_i (\mathbf{w} \cdot \mathbf{x}_i - b) - 1] \right\}$$

حالا می توان این مسئله را به کمک برنامه ریزی غیرخطی استاندارد حل کرد. جواب این مساله بهینه سازی می تواند به صورت ترکیب خطی از بردارهای پشتیبان بیان شود:

$$\mathbf{w} = \sum_{i=1}^n \alpha_i y_i \mathbf{x}_i$$

در این مساله تعداد محدودی از α_i ها بزرگتر از صفر خواهد بود. متناظر، دقیقاً همان بردار پشتیبان خواهد بود. با توجه به این واقعیت می توان نتیجه گرفت که بردارهای پشتیبان شرط زیر را نیز ارضاء می کنند:

$$y_i (\mathbf{w} \cdot \mathbf{x}_i - b) = 1$$

که اجازه می دهد مقدار b به صورت زیر تعریف شود که در آن N_{SV} تعداد بردارهای پشتیبان است.

$$b = \frac{1}{N_{SV}} \sum_{i=1}^{N_{SV}} (\mathbf{w} \cdot \mathbf{x}_i - y_i)$$

فرم دوگان مساله

استفاده از این واقعیت که $\mathbf{w} = \sum_{i=1}^n \alpha_i y_i \mathbf{x}_i$ و $\|\mathbf{w}\|^2 = \mathbf{w} \cdot \mathbf{w}$ به مسئله بهینه SVM می توان نشان داد که دوگان سازی زیر ساده می شود:

Maximize (α_i)

$$\tilde{L}(\alpha) = \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i,j} \alpha_i \alpha_j y_i y_j \mathbf{x}_i^T \mathbf{x}_j = \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i,j} \alpha_i \alpha_j y_i y_j k(\mathbf{x}_i, \mathbf{x}_j)$$

$$(i = 1, \dots, n) \alpha_i \geq 0,$$

$$\sum_{i=1}^n \alpha_i y_i = 0.$$

چیزی که بیان کردیم ساده ترین حالت ممکن برای بردارهای پشتیبان است و عملاً بیشتر مناسب کلاس بندی هایی است که از یکدیگر براحتی بوسیله یک ابرصفحه از هم جدا می شوند. حال فرض کنیم که داده های ما جدایی پذیر نباشند و عبارت ساده تر یک ابرصفحه که قادر باشد همه داده های 2 کلاس را از یکدیگر جدا کند وجود نداشته باشد، در این حالت از متغیر کمکی ξ_i و ترفندهای تابع هسته یا همان کرنل استفاده میکنیم و داریم:

$$\begin{cases} y_i [\mathbf{w}^T \phi(\mathbf{x}_i) + b] \geq 1 - \xi_i, & i = 1, \dots, N, \\ \xi_i \geq 0, & i = 1, \dots, N. \end{cases}$$

براساس قاعده کاهش ریسک ساختاری، حاشیه های ریسک بوسیله مساله مینیم سازی زیر کاهش میابد:

$$\min J_1(w, \xi) = \frac{1}{2} w^T w + c \sum_{i=1}^N \xi_i,$$

$$\text{Subject to} \begin{cases} y_i [w^T \phi(x_i) + b] \geq 1 - \xi_i, & i = 1, \dots, N, \\ \xi_i \geq 0, & i = 1, \dots, N, \end{cases}$$

تابع لگرانژ را بصورت زیر تشکیل میدهیم:

$$L_1(w, b, \xi, \alpha, \beta) = \frac{1}{2} w^T w + c \sum_{i=1}^N \xi_i + \sum_{i=1}^N \alpha_i \{y_i [w^T \phi(x_i) + b] - 1 + \xi_i\} + \sum_{i=1}^N \beta_i \xi_i,$$

که در آن $\alpha_i \geq 0, \beta_i \geq 0 (i = 1, \dots, N)$ ضریب لگرانژ هستند. نقطه بهینه این مساله متناظر با نقطه گره زینی تابع لگرانژ ما خواهد شد، آنگاه داریم

$$\begin{cases} \frac{\partial L_1}{\partial w} = 0 \rightarrow w = \sum_{i=1}^N \alpha_i y_i \phi(x_i), \\ \frac{\partial L_1}{\partial b} = 0 \rightarrow \sum_{i=1}^N \alpha_i y_i = 0, \\ \frac{\partial L_1}{\partial \xi_i} = 0 \rightarrow 0 \leq \alpha_i \leq c, i = 1, \dots, N. \end{cases}$$

و با جایگذاری w بدست آمده در تابع لگرانژ مساله بهینه سازی ما به یک مساله بهینه سازی غیرخطی بصورت زیر تبدیل می شود:

$$\max Q_1(\alpha) = -\frac{1}{2} \sum_{i,j=1}^N \alpha_i \alpha_j y_i y_j K(x_i, x_j) + \sum_{i=1}^N \alpha_i,$$

با حل این مساله بهینه سازی با توجه به محدودیت های مربوط به ضرایب لگرانژ، ابرصفحه ای در فضای ویژگی با ابعاد بالاتر بدست خواهد آمد در حالی که کلاس بندی کننده ما در همان فضای اولیه است. در عبارت بالا $K(x_i, x_j) = \langle \phi(x_i), \phi(x_j) \rangle$ یک تابع کرنل است که در ادامه نسخه هایی از آنها را که در این ماشین های بردار پشتیبان مورد استفاده قرار میگردند را معرفی خواهیم کرد.

هسته های متداول به صورت زیر هستند:

خطی:

$$k(x, x_i) = x_i^T x,$$

چندجمله ای (همگن) درجه d :

$$k(x_i, x_j) = (x_i \cdot x_j)^d$$

چندجمله ای (ناهمگن) درجه d :

$$k(x_i, x_j) = (x_i \cdot x_j + 1)^d$$

گوسیین :

$$k(x_i, x_j) = \exp(-\gamma \|x_i - x_j\|^2), \gamma > 0., \gamma = 1/2\sigma^2$$


یا بصورت زیر

$$k(x, x_i) = \exp\left(-\|x - x_i\|^2 / \sigma^2\right),$$

تانژانت هذلولی:

$$k(x_i, x_j) = \tanh(kx_i \cdot x_j + c)$$

شکل زیر بصورت ساده نحوه تاثیر تابع هسته بر روی فضای ویژگی ها و نتیجه مرتب با آن را بخوبی نشان می دهد.



کلاس بندی کننده ی (LSSVM)

نسخه حداقل مربعات ماشین های بردار پشتیبان بوسیله بازنویسی مساله مینیم سازی بصورت زیر حاصل می شود:

$$\min J_2(w, b, e) = \frac{\mu}{2} w^T w + \frac{\zeta}{2} \sum_{i=1}^N e_{c,i}^2,$$

subject to:

$$y_i [w^T \phi(x_i) + b] = 1 - e_{c,i}, \quad i = 1, \dots, N.$$

کلاس بندی کننده‌ی حداقل مربعات بالا بطور ضمنی برای درونیابی رگرسیون با مقادیر هدف $y_i = \pm 1$ فرمول بندی شده است و با استفاده از ترفند کرنل برای داده‌های با فضای ورودی پیچیده نیز قابل استفاده است با بکار بردن $y_i = 1$ داریم:

$$\sum_{i=1}^N e_{c,i}^2 = \sum_{i=1}^N (y_i e_{c,i})^2 = \sum_{i=1}^N e_i^2 = \sum_{i=1}^N (y_i - (w^T \phi(x_i) + b))^2,$$

که

$$e_i = y_i - (w^T \phi(x_i) + b).$$

است. بنابراین فرمول بندی کلاس بندی کننده‌ی حداقل مربعات با رابطه زیر معادل است.

$$J_2(w, b, e) = \mu E_w + \zeta E_D$$

که در آن

$$E_w = \frac{1}{2} w^T w$$

و

$$E_D = \frac{1}{2} \sum_{i=1}^N e_i^2 = \frac{1}{2} \sum_{i=1}^N (y_i - (w^T \phi(x_i) + b))^2.$$

است.

جواب مساله بالا بعد از تبدیل تابع لاگرانژ زیر و حل آن بدست خواهد

$$\begin{cases} L_2(w, b, e, \alpha) = J_2(w, e) - \sum_{i=1}^N \alpha_i \left\{ [w^T \phi(x_i) + b] + e_i - y_i \right\}, \\ \quad = \frac{1}{2} w^T w + \frac{\gamma}{2} \sum_{i=1}^N e_i^2 - \sum_{i=1}^N \alpha_i \left\{ [w^T \phi(x_i) + b] + e_i - y_i \right\}, \end{cases}$$

که ضرایب لاگرانژ و شرایط بهینه برای آن بصورت زیر هستند

$$\begin{cases} \frac{\partial L_2}{\partial w} = 0 \rightarrow w = \sum_{i=1}^N \alpha_i \phi(x_i), \\ \frac{\partial L_2}{\partial b} = 0 \rightarrow \sum_{i=1}^N \alpha_i = 0, \\ \frac{\partial L_2}{\partial e_i} = 0 \rightarrow \alpha_i = \gamma e_i, i = 1, \dots, N, \\ \frac{\partial L_2}{\partial \alpha_i} = 0 \rightarrow y_i = w^T \phi(x_i) + b + e_i, i = 1, \dots, N. \end{cases}$$


بعد از حذف w و e یک سیستم خطی بجای یک سیستم برنامه‌ریزی غیرخطی درجه دوم بصورت زیر حاصل می‌شود:

$$\begin{bmatrix} 0 & 1_N^T \\ 1_N & \Omega + \gamma^{-1} I_N \end{bmatrix} \begin{bmatrix} b \\ \alpha \end{bmatrix} = \begin{bmatrix} 0 \\ Y \end{bmatrix},$$

$\Omega \in \mathbf{R}^{N \times N}$ و $I_N \times I_N$ یک ماتریس همانی در اینجا I_N است. $Y = [y_1, \dots, y_N]^T$, $1_N = [1, \dots, 1]^T$, $\alpha = [\alpha_1, \dots, \alpha_N]^T$ کرنل تعريف شده توسط $\Omega_{ij} = \phi(x_i)^T \phi(x_j) = k(x_i, x_j)$ است.

کلاس بندی کنندی (TwinSVM or TSVM)

نسخه ماشین های بردار پشتیان دوقلو راهکار متفاوتی را برای کلاس بندی مورد استفاده قرار میدهد. در این متدهای بجای بدست آوردن یک ابر صفحه جدا کننده برای کلاس بندی ما 2 ابر صفحه غیر موازی را به نحوی انتخاب میکنیم که هر کدام کمترین فاصله ممکن را از داده های یک کلاس و بیشترین فاصله ممکن را از کلاس دیگر داشته باشد. بصورت بسیار ساده برای داده های با 2 کلاس هدف ما یافتن ابرصفحه های بصورت شکل زیر است. کلاس بندی بوسیله آن هم بسیار ساده است و عملاً هر داده آزمایشی که داخل هریک از ابرصفحه مقدار آن محاسبه می شود و کلاس مربوط به داده آزمایشی متناظر با ابرصفحه با کمترین مقدار است



فرم اولیه مساله بهینه سازی برای روش ماشین های بردار پشتیبان دوقلو بصورت زیر است:

$$\begin{aligned} \min(w_1, b_1, \xi) \quad & \frac{1}{2} \|X_1 w_1 + e_1 b_1\|^2 + c_1 e_2^T \xi \\ \text{s.t.} \quad & -(X_2 w_1 + e_2 b_1) + \xi \geq e_2, \quad \xi \geq 0 \end{aligned}$$

$$\begin{aligned} \min(w_2, b_2, \eta) \quad & \frac{1}{2} \|X_2 w_2 + e_2 b_2\|^2 + c_2 e_1^T \eta \\ \text{s.t.} \quad & (X_1 w_2 + e_1 b_2) + \eta \geq e_1, \quad \eta \geq 0 \end{aligned}$$

که در آن ξ و η متغیرهای کمکی و c_1, c_2 پارامترهای جریمه هستند. e_1 و e_2 نشانده 2 بردار با بعد مناسب که دارای مقادیر 1 هستند. فرم لاغرانژ معادله اول بصورت زیر است:

$$L(w_1, b_1, \xi, \alpha, \beta) = \frac{1}{2} \|X_1 w_1 + e_1 b_1\|^2 + c_1 e_2^T \xi + \alpha^T ((X_2 w_1 + e_2 b_1) - \xi + e_2) - \beta^T \xi$$

که در آن α و β ضرایب لاغرانژ هستند و شرایط KKT (Karush–Kuhn–Tucker) برای تابع لاغرانژ بصورت زیر هستند:

$$\frac{\partial L}{\partial w_1} = X_1^T (X_1 w_1 + e_1 b_1) + X_2^T \alpha = 0$$

$$\frac{\partial L}{\partial b_1} = e_1^T (X_1 w_1 + e_1 b_1) + e_2^T \alpha = 0$$

$$\frac{\partial L}{\partial \xi} = c_1 e_2^T - \beta^T - \alpha^T = 0$$

$$-(X_2 w_1 + e_2 b_1) + \xi \geq e_2, \xi \geq 0$$

$$\alpha^T ((X_2 w_1 + e_2 b_1) - \xi + e_2) = 0, \beta^T \xi = 0$$

$$\alpha \geq 0, \beta \geq 0$$

که منجر به رابطه زیر می شود

$$\begin{bmatrix} X_1^T \\ e_1^T \end{bmatrix} \begin{bmatrix} X_1 & e_1 \end{bmatrix} \begin{bmatrix} w_1 \\ b_1 \end{bmatrix} + \begin{bmatrix} X_2^T \\ e_2^T \end{bmatrix} \alpha = 0$$

با قرار دادن $u_1 = \begin{bmatrix} w_1 \\ b_1 \end{bmatrix}$, $B = [X_2, e_2]$ و $A = [X_1, e_1]$:

$$A^T A u_1 + B^T \alpha = 0$$

$$u_1 = -(A^T A)^{-1} B^T \alpha$$

برای اینکه مقدار $A^T A$ وارون پذیر باشد و از سینگولار شدن آن جلوگیری شود آن را بصورت $(A^T A + \delta I)$ در نظر میگیریم که I یک ماتریس همانی هم انداز ماتریس $A^T A$ است. که خواهیم داشت:

$$u_1 = -(A^T A + \delta I)^{-1} B^T \alpha$$

با روندی کاملا مشابه برای ابرصفحه دوم به عبارت زیر خواهیم رسید

$$u_2 = (B^T B + \delta I)^{-1} A^T \gamma$$

که در نهایت کلاس بندی کننده‌ی ما برای 2 کلاس بصورت (i کلاس) است. نکته‌ای که در هر سه روش معرفی شده و همه روش کلاس بندی کننده براساس ماشین‌های بردار بعنوان وجه مشترک می‌توان به آن اشاره کرد، 2 کلاسه بودن داده‌های مورد استفاده است. برای اینکه بتوان از این متدی‌های برای کلاس بندی‌های چندکلاسه استفاده کرد از دو رویکرد زیر استفاده می‌شود.

- 1- یک کلاس در مقابل بقیه کلاس ها : (One vs All)
 - 2- یک کلاس در مقابل یک کلاس دیگر یا کلاس بندی دودویی: (One vs One)

روش پیشنهادی

با استفاده از سه روش معرفی شده یک سیستم هوشمند را آموزش میدهیم و سپس سه روش را برای مقایسه میزان دقت کلاس بندی روی دیتابیس های استاندارد UCI مورد بررسی قرار خواهیم داد.

آزمایش و بررسی

برای بررسی عملکرد هر سه روش ماشین های بردار پشتیبان از 3 دیتابیس استاندار که اصل دیتابیس ها و توضیحات مربوط به آنها بصورت کامل در فایل ضمیمه گنجانده شده است. در این بررسی از 85 درصد داده ها برای تعلیم سیستم و از 15 درصد داده ها برای آزمایش سیستم استفاده شده است. برای بدست آوردن دقیق نسبی هر یک از روش ها هر کدام از روش ها 10 بار تکرار شده و در هر تکرار تعداد داده های تعلیم و آزمایش بصورت تصادفی و براساس توضیح نرمال انتخاب شده اند. و در نهایت میانگین درصد درستی و زمان اجرا برای هر روش محاسبه شده است. نتایج حاصل بروی سیستم عامل ویندوز ماکروسافت 8.1 و با مشخصات سخت افزاری سی پی یو corei5 2.2GHz , Ram 4Gb R2014b با استفاده از نسخه SVM از تولباکس متلب استفاده شده است و کد های مربوط به 2 روش دیگر براساس مقالات مربوط به آنها طراحی شده است. نتایج حاصل در جدول های زیر آمده است.

DATA name : ionosphere

	LSSVM		TwinSVM		SVM		N	Test	N	Train
R	Accu	Time	Accu	Time	Accu	Time				
R	94.3396	0.1092	58.4906	14.4815	88.6792	0.19236	53		298	
	90.566	0.1248	75.4717	13.2128	90.566	0.17204	53		298	
	92.4528	0.078	73.5849	13.2509	88.6792	0.1405	53		298	
	92.4528	0.1092	73.5849	13.9477	88.6792	0.18752	53		298	
	92.4528	0.1248	60.3774	14.7561	90.566	0.13141	53		298	
	90.566	0.0624	64.1509	14.3847	90.566	0.19277	53		298	
	94.3396	0.078	62.2642	14.3193	88.6792	0.19481	53		298	
	92.4528	0.078	66.0377	15.136	90.566	0.15726	53		298	
	83.0189	0.0624	69.8113	14.6669	88.6792	0.18111	53		298	
	90.566	0.1248	54.7171	14.4465	88.6792	0.19624	53		298	

	LSSVM		TwinSVM		SVM		N Test	N Train
R	Accu	Time	Accu	Time	Accu	Time		
1	82.9268	0.0312	48.7805	7.8407	78.0488	0.088038	41	229
2	85.3659	0.093601	53.6585	7.852	75.6098	0.11399	41	229
3	87.8049	0.093601	51.2195	7.461	85.3659	0.094701	41	229
4	85.3659	0.093601	48.7805	8.085	65.8537	0.10339	41	229
5	82.9268	0.0312	53.6585	10.3664	75.6098	0.098591	41	229
6	82.9268	0.0624	56.0976	8.504	82.9268	0.096557	41	229
7	78.0488	0.0624	51.2195	8.433	65.8537	0.096994	41	229
8	87.8049	0.078	48.7805	8.9963	75.6098	0.098683	41	229
9	90.2439	0.0468	48.7805	8.3985	70.7317	0.092684	41	229
10	85.3659	0.0624	53.6585	8.2852	78.0488	0.097592	41	229
<hr/>								
ave: 84.878 0.06552 51.4634 8.4222 75.3659 0.098122 41 229								
<hr/>								

	LSSVM		TwinSVM		SVM		N Test	N Train
R	Accu	Time	Accu	Time	Accu	Time		
1	67.3077	0.1248	42.3077	14.0934	59.6154	0.16126	52	293
2	69.2308	0.078001	53.8462	12.9608	65.3846	0.11091	52	293
3	80.7692	0.078001	53.8462	14.1087	78.8462	0.12942	52	293
4	76.9231	0.1248	59.6154	13.2661	69.2308	0.1096	52	293
5	59.6154	0.1248	46.1538	13.7842	69.2308	0.11844	52	293
6	71.1538	0.078	53.8462	13.8513	65.3846	0.16601	52	293
7	65.3846	0.1248	57.6923	13.2794	61.5385	0.17353	52	293
8	69.2308	0.1092	42.3077	13.9663	69.2308	0.14427	52	293
9	73.0769	0.0156	26.9231	13.1219	69.2308	0.17655	52	293
10	75	0.078	51.9231	13.1397	73.0769	0.1705	52	293
<hr/>								
ave: 70.7692 0.093601 48.8462 13.5572 68.0769 0.14605 52 293								
<hr/>								

نتیجه گیری

باتوجه به به نتایج حاصل از بررسی روش ماشین های بردار پشتیبان حداقل مربعات دارای عملکرد بهتر هم از نظر دقیقیت کلاس بندی و هر از نظر زمان اجرا نسبت به 2 روش دیگر است.

منابع

- [1] https://en.wikipedia.org/wiki/Support_vector_machine
- [2] C. Corinna and V. Vapnik, “Support-vector networks”, Machine learning, vol. 20, no. 3, (1995), pp. 273-297.
- [3] Suykens J.A.K., Van Gestel T., De Brabanter J., De Moor B., Vandewalle J., Least Squares Support Vector Machines, World Scientific, to appear. 1999
- [4] Jayadeva, Khemchandani, R., & Chandra, S. (2007). Twin support vector machines for pattern classification. IEEE Transactions on Pattern Analysis and Machine Intelligence, 29(5), 905–910.
- [5] K. M. Arun and M. Gopal, “Least squares twin support vector machines for pattern classification”, Expert Systems with Applications, vol. 36, (2009), pp. 7535–7543.