

طبقه‌بند تک‌کلاسه گرانش‌گرای مبتنی بر ماشین بردار پشتیبان

سیدحسین غفاریان، هادی صدوقی یزدی و یونس الله‌یاری

رفتار غیر طبیعی به دلیل ماهیت آن، این ویژگی را ندارد. در نتیجه می‌توان برای رفتارهای معمول یک طبقه‌بند تک‌کلاسه ساخت و رفتارهای نرمال را بر اساس آن شناسایی کرد.

۱-۱ روند توسعه طبقه‌بندهای تک‌کلاسه مبتنی بر ماشین بردار پشتیبان

اولین طبقه‌بند تک‌کلاسه مبتنی بر بردار پشتیبان بنام SVC-7 در سال ۱۹۹۹ معرفی شد [۱]. مرز این طبقه‌بند ابرصفحه‌ای با حداکثر حاشیه است که نمونه‌های کلاس هدف را از مبدأ مختصات جدا می‌کند. در همین سال یک طبقه‌بند مبتنی بر مرز ارائه شد که در حالت خاص مشابه SVC-7 رفتار می‌کند. این طبقه‌بند توسعه گردداده مبتنی بر بردار پشتیبان (SVDD) نام دارد و توسط تکس پیشنهاد شد [۲].

علی‌رغم ویژگی‌های مناسب SVDD و کاربرد گسترده آن، مشکلاتی با خود به همراه دارد. این روش به دنبال پوشش دادن نمونه‌های یادگیری توسط ابرکرهای با کمترین شاعع ممکن در فضای ویژگی است که تنها با نمونه‌های یادگیری بیرونی توصیف می‌شود [۳]. چگالی نمونه‌های یادگیری تأثیری در فرایند تعیین مرزها ندارد و به همین دلیل چنان که خواهیم دید، گاهی اوقات مرز طبقه‌بند چندان مناسب نیست.

علاوه بر این اگر در رابطه با نمونه‌های پرت نیز اطلاعاتی در دست داشته باشیم، SVDD از آنها استفاده‌ای نمی‌کند. این نمونه‌ها را که گاهی نمونه‌های منفی نامیده می‌شوند، می‌توان در فرایند یادگیری دخالت داد [۴]. به این منظور سعی بر آن است که کره‌ای با مرکز a و حداقل شاعع R یافت شود به‌گونه‌ای که نمونه‌های مثبت را در داخل خود قرار داده و از پذیرش نمونه‌های منفی خودداری کند. این روش طبقه‌بند بردار پشتیبان با نمونه‌های منفی SVDD with Negative Samples نامیده می‌شود.

پس از معرفی طبقه‌بندهای SVDD و NSVDD روش‌های متنوعی برای بهبود عملکرد آن معرفی شدند. دسته‌ای از این روش‌ها با استفاده از پیش‌پردازش یا پس‌پردازش سعی در بهبود عملکرد در رابطه با نویز دارند. به عنوان مثال می‌توان به استفاده از فیلترینگ متعارف و ترکیب آن با روش SVDD اشاره نمود [۵]. در تحقیقی دیگر Guo و همکارانش با ارائه یک روش پس‌پردازشی سعی در افزایش قدرت SVDD داشتند [۶]. در الگوریتم پیشنهادی آنها از روش نزدیکترین همسایه برای اصلاح مرزهای بدست آمده توسط SVDD استفاده شده است.

یکی دیگر از مشکلات SVDD وابستگی آن به نمونه‌های نویزی و در نظر نگرفتن ناحیه‌های چگال است. برای حل این مشکل به هر نمونه یادگیری یک چگالی محلی نسبت داده می‌شود. سپس قیود مسئله بهینه‌سازی مرتبط با SVDD به‌گونه‌ای تغییر داده می‌شوند که مرکز ابرکره به سمت نمونه‌های چگال‌تر رانده شود. به این مدل ^۱ (DSVDD) برگره به سمت نمونه‌های چگال‌تر رانده شود. به این مدل ^۲

چکیده: در این مقاله یک طبقه‌بند تک‌کلاسه مبتنی بر مرز با الهام از طبقه‌بند تصیف‌گر داده مبتنی بر بردار پشتیبان ^۱ (SVDD) ارائه شده است. در طبقه‌بند SVDD حتی زمانی که نمونه‌های پرت به بیرون از مرز رانده می‌شوند، باز هم این نمونه‌ها بر مرز طبقه‌بند اثر می‌گذارند و این مسئله باعث افزایش خطای طبقه‌بند می‌شود. در طبقه‌بند پیشنهادی به گرانش نمونه‌های آموزش اهمیت داده می‌شود و همچنین همه نمونه‌ها در تعیین نمونه‌های آموزش اهمیت داده می‌شود. طبقه‌بند که در یکی دانش در مورد نمونه‌های پرت نیز در نظر گرفته می‌شود، پیشنهاد شده است. مسئله بهینه‌سازی مطرح در طبقه‌بند پیشنهادی علاوه بر این که تحدب را حفظ می‌کند، در حوزه کرنل نیز به سهولت کرنل قابل استفاده است. پس از معرفی طبقه‌بند پیشنهادی و حل مسئله بهینه‌سازی آن، چگونگی تغییرات مرز طبقه‌بند پیشنهادی در مقابل تغییرات پارامترهای مدل بررسی می‌شود. نتایج آزمایش‌ها در مقایسه با دو طبقه‌بند ^۲ SVDD و Density Induced SVDD نشان دهد که روش پیشنهادی در کاهش اثر نمونه‌های پرت موفق بوده است.

کلید واژه: طبقه‌بند تک‌کلاسه، نمونه‌های پرت، طبقه‌بند تک‌کلاسه گرانش‌گرای، طبقه‌بند مبتنی بر چگالی.

۱- مقدمه

توصیف داده‌ها در یک دامنه خاص یا همان طبقه‌بند تک‌کلاسه به عنوان یکی از مباحث مهم در یادگیری ماشین و داده‌کاوی مورد توجه پژوهش‌گران قرار گرفته است. هدف از مطرح شدن طبقه‌بند تک‌کلاسه، به دست آوردن مدلی برای توصیف داده‌های یک کلاس است به‌گونه‌ای که این مدل پذیرنده نمونه‌های مشابه آن کلاس بوده و از پذیرفتن نمونه‌های سایر کلاس‌ها خودداری کند. چالش مطرح در دسته‌بندی داده‌های دو کلاس است که نمونه‌های ناشناخته و فاقد هر گونه تشابه به داده‌های دو کلاس، در یکی از دو کلاس طبقه‌بندی می‌گردد. لذا عملکرد طبقه‌بند دو کلاس در مقابل این گونه نمونه‌ها مناسب نیست. برای مواجهه با این چالش، یکی از کاربردهای طبقه‌بند تک‌کلاسه تحت عنوان توصیف داده‌ها در یک دامنه مطرح می‌شود. در چنین حالاتی، منطقی است قبل از هر اقدامی برای طبقه‌بندی نمونه جدید در یکی از دو کلاس، تشابه یا عدم تشابه این نمونه را با مجموعه نمونه‌های یادگیری بررسی کرد.

به عنوان مثالی از کاربرد طبقه‌بند تک‌کلاسه می‌توان تشخیص رفتارهای غیر طبیعی در یک سیستم را نام برد. اگرچه شناخت رفتارهای طبیعی امکان‌پذیر است زیرا داده‌های زیادی در مورد آن وجود دارد، اما


این مقاله در تاریخ ۱ اردیبهشت ماه ۱۳۹۱ دریافت و در تاریخ ۲۲ مهر ماه ۱۳۹۱ بازنگری شد.

سیدحسین غفاریان، گروه مهندسی کامپیوتر، دانشگاه فردوسی مشهد، مشهد، (email: s.h.ghafarian@gmail.com).

هادی صدوقی یزدی، گروه کامپیوتر و قطب علمی رایانش نرم و پردازش هوشمند اطلاعات، دانشکده مهندسی، دانشگاه فردوسی مشهد، مشهد، (email: h-sadoghi@um.ac.ir).

یونس الله‌یاری، گروه مهندسی کامپیوتر، دانشگاه فردوسی مشهد، مشهد، (email: yns_ah@yahoo.com).

1. Support Vector Data Description



شکل ۲: چنانچه نمونه‌های نویزی با پرت با نمونه‌های یادگیری ترکیب شده باشد می‌توان در قبال صرف نظر کردن از نمونه‌های نویزی با پرت، به کرهای با شعاع کوچکتر رسید و توصیف مناسب‌تری را برای داده‌های کلاس هدف پیدا کرد.

علاوه بر نکات فوق، مسئله بهینه‌سازی در طبقه‌بند پیشنهادی به نحوی مطرح شده است که باعث تحبد آن و همچنین سهولت استفاده از آن در حوزه کرنل می‌شود.

در ادامه ابتدا به معرفی طبقه‌بند تک کلاسه SVDD می‌پردازیم و نقاط ضعف این طبقه‌بند را مطرح می‌کنیم. سپس در بخش بعد روش پیشنهادی در مواجهه با این نقاط ضعف را بررسی کرده و بر اساس آن طبقه‌بند جدید-طبقه‌بند تک کلاسه گرانش‌گرا (GSVDD) را معرفی می‌نماییم. پس از آن نتایج آزمایش‌ها بر روی این طبقه‌بند در مقایسه با طبقه‌بند SVDD تحلیل شده و در نهایت نتیجه‌گیری از طبقه‌بند مذکور ارائه می‌شود.

۲- طبقه‌بندی تک کلاسه مبتنی بر SVDD


۱-۲ معرفی SVDD

طبقه‌بند SVDD یک طبقه‌بند تک کلاسه مبتنی بر بردار پشتیبانی با یادگیری ناظارت‌نشده است [۷]. فرض در نظر گرفته شده برای مرز این طبقه‌بند، ابرکرهای با مرکز a و شعاع R است، به‌طوری که دارای کمترین شعاع ممکن بوده و نمونه‌های یادگیری کلاس هدف را پوشش دهد. به عنوان مثال در شکل ۱ ابرکره محیط‌شده بر داده‌ها، بیانگر مرز طبقه‌بند SVDD است.

برای محاسبه مرکز و شعاع این ابرکره، مسئله بهینه‌سازی زیر مطرح می‌شود. در این مسئله متغیرهای a و R (مرکز و شعاع ابرکره) جواب‌های مسئله بهینه‌سازی زیر هستند. در این مسئله n بیانگر تعداد نمونه‌های یادگیری است

$$\begin{aligned} & \text{Minimize } R \\ & \text{subject to } \|x_i - a\|^2 \leq R^2, \quad i = 1, \dots, n \end{aligned} \quad (1)$$

مشکل این روش آن است که نمونه‌های پرت اگر اشتباهًا به عنوان نمونه‌های کلاس هدف برچسب‌گذاری شده باشند، به‌طور ناخواسته بر مرز طبقه‌بند اثر می‌گذارند. به منظور حل این مشکل، قیود نامساوی (۱) انعطاف‌پذیر می‌شود. این روش امکان می‌دهد که نمونه‌های نویزی یا پرت از داخل ابرکره بیرون رانده شوند. شکل ۲ بیانگر ایده پیشنهادی است. مدل ریاضی ایده پیشنهادی به صورت مسئله بهینه‌سازی (۲) است



شکل ۱: ابرکرهای با حداقل شعاع که پوشش‌دهنده نمونه‌های یادگیری است.

گفته می‌شود. روشنی که با رویکرد DSVDD نمونه‌های منفی را نیز در نظر می‌گیرد، DSVDD with Negative Samples یا NSVDD نامیده می‌شود.

از نقاط قوت SVDD و NSVDD سهولت حل مسئله بهینه‌سازی محدب درجه دوم آنها با استفاده از روش ضرایب لاغرانژ است. امتیاز دیگر این روش تعداد کم پارامترهای آزاد آن در مقایسه با مدل‌های توسعه‌یافته آن است.

۲-۱ روش پیشنهادی برای حل مشکلات طبقه‌بند تک کلاسه

چنان که مطرح شد، طبقه‌بند SVDD دو عیب اساسی دارد. نقطه ضعف اول آن تمایز قایل نشدن بین نمونه‌های چگال و غیر چگال است که می‌تواند باعث شود نمونه به اشتباه جزء نمونه‌های پرت تلقی شود. به این خطأ، خطای منفی-اشتباه^۱ گفته می‌شود. مشکل دوم این روش تأثیرپذیری مرز طبقه‌بند از نمونه‌های یادگیری پرت در تعیین سطح تصمیم است که می‌تواند به خطای منفی-اشتباه منجر شود.

اگرچه در روش‌های مبتنی بر چگالی DSVDD و NDSVDD هدف اصلی غلبه بر مشکل اول SVDD و NSVDD بود، اما این روش‌ها در مقایسه با روش‌های قبلی باعث افزایش تعداد پارامترهای پیداکردن بهینه می‌شوند. مشکل دیگر آنها در مقایسه با روش‌های SVDD و NSVDD چگونگی حل کردن مسائل بهینه‌سازی می‌باشد. تابع هدف این مسئله، یک مسئله کسری است و پیچیدگی زمانی آن در مقایسه با مسئله بهینه‌سازی درجه دوم مرتبط با SVDD بسیار بیشتر است.

برای حل این مشکلات در این مقاله طبقه‌بند تک کلاسه گرانش‌گرای مبتنی بر ماشین بردار پشتیبانی پیشنهاد شده است. در این طبقه‌بند ضمن تلاش برای کاهش شعاع ابرکره به کمینه کردن فاصله مرکز ابرکره از مرکز گرانش اهمیت داده می‌شود. علت این امر دو دلیل زیر است:

- اهمیت قایل شدن برای مرکز گرانش باعث نزدیک شدن مرکز ابرکره به نمونه‌های چگال و در نتیجه فاصله گرفتن مرز ابرکره از نمونه‌های چگال می‌شود.

- به علاوه باعث مشارکت تمام نمونه‌ها در تعیین مرکز ابرکره و به تبع آن کاهش اثر نمونه‌های نویزی یا پرت در محاسبه مرز طبقه‌بند می‌شود.

1. False Negative

$$\begin{aligned} \|x_i - a\|^r &< R^r \Leftrightarrow \alpha_i = 0, \xi_i = 0 \\ \|x_i - a\|^r &= R^r \Leftrightarrow 0 < \alpha_i < C, \xi_i = 0 \\ \|x_i - a\|^r &> R^r \Leftrightarrow \alpha_i = C, \xi_i > 0. \end{aligned} \quad (8)$$

به منظور محاسبه R^r کافی است فاصله یک نمونه دلخواه روی کره را از مرکز ابرکره مطابق (۹) محاسبه کرد

$$R^r = \|x - a\|^r = x \cdot x - 2 \sum_{i=1}^n \alpha_i (x \cdot x_i) + \sum_{i=1}^n \sum_{j=1}^n \alpha_i \alpha_j (x_i \cdot x_j) \quad (9)$$

همچنین برای بررسی تعلق نمونه تست z به کلاس هدف کافی است با استفاده از (۱۰) فاصله این نمونه را نسبت به مرکز به دست آورده و نتیجه را با R^r مقایسه کرد

$$D(z) = z \cdot z - 2 \sum_{i=1}^n \alpha_i (z \cdot x_i) + \sum_{i=1}^n \sum_{j=1}^n \alpha_i \alpha_j (x_i \cdot x_j) \quad (10)$$

$$f(z) = \begin{cases} 1 & D(z) \leq R^r \\ 0 & \text{otherwise} \end{cases} \quad (11)$$

با توجه به (۱۰) و (۱۱) روشن است که تنها نمونه‌هایی با ضریب لاگرانژ مخالف صفر در تعیین مرز طبقه‌بند دخالت دارند. بنابراین این روش در دسته ماشین‌های بردار پشتیبان قرار می‌گیرد.

چنانچه مطابق شکل ۳ توزیع داده‌های یادگیری کلاس هدف غیر کروی باشد، ابرکره به دست آمده توصیف‌کننده خوبی برای کلاس هدف نیست. برای غلبه بر این مشکل می‌توان از نگاشتهای غیر خطی استفاده کرد. با استفاده از این نگاشتهای نمونه‌ها به فضایی با ابعاد بالاتر نگاشت می‌شوند. پس از محاسبه مرز طبقه‌بند در فضای ویژگی، مرزهای انعطاف‌پذیر و مناسبی در فضای ورودی با استفاده از توابع کرنل به دست خواهد آمد.


رایج‌ترین توابع کرنل که به طور گسترده‌ای مورد استفاده قرار می‌گیرند، توابع RBF و Polynomial هستند. خابطه این توابع به صورت (۱۲) و (۱۳) است

$$K(x, y) = e^{-\frac{\|x-y\|^r}{\sigma^r}} \quad (12)$$

$$K(x, y) = (1 + x \cdot y)^p \quad (13)$$

پارامترهای مدل در محاسبه مرز طبقه‌بند تک کلاسه SVDD مؤثر هستند. چنانچه نمونه‌های یادگیری شکل ۱ با استفاده از کرنل RBF و پارامتر $\sigma = 1$ به فضای ویژگی نگاشت شوند و پارامتر C برابر ۱ در نظر گرفته شود، مرز طبقه‌بند مطابق شکل ۳ به دست می‌آید که در مقایسه با مرز شکل ۱ انعطاف‌پذیرتر است و نواحی نامطلوب و غیرچگال را به طور مناسبی از قلمروی کلاس هدف خارج کرده است.

همچنان که قبلاً اشاره شد، در طبقه‌بند SVDD برای خنثی کردن اثر نامطلوب نمونه‌های نویزی یا پرت، امکان پذیرش خطای یادگیری C پیش‌بینی شده است. وظیفه تنظیم خطای یادگیری بر عهده پارامتر C است. در صورتی که این پارامتر به گونه‌ای تنظیم شود که این نمونه‌ها از داخل ابرکره خارج شوند، طبقه‌بند سوم از (۸) و (۵) این نمونه‌ها بر مرکز ابرکره اثرگذار هستند و مرز طبقه‌بند را به سمت خودشان متambil می‌کنند. به عنوان مثال در شکل ۴ می‌توان دو نمونه را که در سمت چپ و فاصله دوری از بقیه قرار دارند، نویزی یا پرت تلقی کرد. برای غلبه بر تأثیر نامطلوب این نمونه‌ها اقدام به کاهش پارامتر C می‌شود. در اولین کاهش که در شکل ۴-الف مشاهده می‌شود، تنها یک نمونه یادگیری از قلمروی



شکل ۳: استفاده از نگاشتهای غیر خطی و توابع کرنل، به مرزهای مناسب‌تری منجر می‌شود.

$$\text{Minimize } R^r + C \sum_{i=1}^n \xi_i \quad (2)$$

$$\text{subject to } \|x_i - a\|^r \leq R^r + \xi_i, \xi_i \geq 0, i = 1, \dots, n$$

که عبارت $\sum_{i=1}^n \xi_i$ بیانگر میزان خطای یادگیری است و پارامتر C وظیفه برقراری تعادل بین شاعر ابرکره و خطای یادگیری را بر عهده دارد. برای حل این مسأله بهینه‌سازی باید تابع لاگرانژ آن مطابق (۳) تشکیل شود که در آن α_i و γ_i ضرایب لاگرانژ هستند

$$L = R^r + C \sum_{i=1}^n \xi_i + \sum_{i=1}^n \alpha_i (\|x_i - a\|^r - R^r - \xi_i) - \sum_{i=1}^n \gamma_i \xi_i \quad (3)$$

برای اعمال شرط لازم KKT، مطابق (۴) تا (۶) نسبت به متغیرهای a ، R و ξ_i عمل مشتق‌گیری انجام شده و برابر صفر قرار داده می‌شود

$$\frac{\partial L}{\partial R} = 2R(1 - \sum_{i=1}^n \alpha_i) = 0 \Rightarrow \sum_{i=1}^n \alpha_i = 1 \quad (4)$$

$$\frac{\partial L}{\partial a} = \sum_{i=1}^n \alpha_i (x_i - a) = 0 \Rightarrow a = \sum_{i=1}^n \alpha_i x_i \quad (5)$$

$$\frac{\partial L}{\partial \xi_i} = 0 \Rightarrow \alpha_i + \gamma_i = C \quad (6)$$

بعد از جایگزینی این فرمول‌ها در تابع لاگرانژ (۳) دو گان مسأله بهینه‌سازی (۷) به صورت (۷) ظاهر می‌شود

$$\begin{aligned} \text{Maximize } & \sum_{i=1}^n \alpha_i x_i \cdot x_i - \sum_{i=1}^n \sum_{j=1}^n \alpha_i \alpha_j x_i \cdot x_j \\ \text{subject to } & \begin{cases} 0 \leq \alpha_i \leq C, i = 1, \dots, n \\ \sum_{i=1}^n \alpha_i = 1 \end{cases} \end{aligned} \quad (7)$$

مسأله بهینه‌سازی درجه دوم محدب (۷)، دارای یک جواب بهینه سراسری است. با حل این مسأله بهینه‌سازی، ضرایب لاگرانژ بهینه به دست خواهد آمد. با بررسی شرایط مکمل زائد، رابطه بین ضریب لاگرانژ و وضعیت نمونه یادگیری نسبت به ابرکره طبق یکی از بندهای (۸) توصیف می‌شود. طبق این رابطه، نمونه‌هایی که داخل ابرکره قرار می‌گیرند دارای ضرایب لاگرانژ صفر و نمونه‌هایی روی ابرکره، ضریب لاگرانژ بین ۰ و C دارند. بعلاوه ضرایب لاگرانژ مربوط به نمونه‌هایی که در اثر پذیرش خطای یادگیری، بیرون از ابرکره واقع شده‌اند برابر است. C است.

ترتیب مرکز و شاعع ابرکره هستند. مقادیر مناسب این متغیرها جواب‌های مسئله بهینه‌سازی زیر هستند

$$\begin{aligned} & \text{Minimize } R^* + C \sum_{i=1}^n \xi_i \\ & \text{subject to } \rho_i \|x_i - a\|^* \leq R^* + \xi_i, \quad \xi_i \geq 0, \quad i = 1, \dots, n \end{aligned} \quad (15)$$

در این مسئله پارامتر C وظیفه تنظیم خطای یادگیری را بر عهده دارد و ρ_i بیانگر چگالی محلی تخصیص داده شده به هر نمونه یادگیری است. مطابق قیدهای این مسئله، بهینه‌سازی چنانچه برای نمونه یادگیری x_i رابطه $\rho_i (x_i - a)^T (x_i - a) \leq R^*$ برقرار باشد، فاصله نمونه x_i از مرکز ابرکره از کسر R^*/ρ_i کمتر خواهد بود. بنابراین هر چه قدر که مقدار ρ_i بزرگ‌تر باشد، تأکید بیشتری برای حضور این نمونه در نزدیکی مرکز ابرکره وجود دارد. در نتیجه نمونه‌های چگال نسبت به نمونه‌های غیر چگال فاصله کمتری از مرکز کره خواهند داشت.

۳-۲ طبقه‌بند ماشین بردار پشتیبان مبتنی بر چگالی با نمونه‌های منفی NDSVDD

در طبقه‌بند NDSVDD نمونه‌های منفی در فرایند یادگیری دخالت دارند [۹]. مطابق این مدل ضمن جستجوی ابرکرهای با حداقل شاعع که پوشش‌دهنده نمونه‌های یادگیری مثبت بوده و از پذیرش نمونه‌های یادگیری منفی خودداری کند، به چگالی محلی نمونه‌های یادگیری مثبت و منفی اهمیت داده شده است. در رابطه زیر، متغیرهای a و R به ترتیب مرکز و شاعع ابرکره مورد نظر هستند. مقادیر مناسب این متغیرها جواب‌های مسئله بهینه‌سازی زیر است


$$\begin{aligned} & \text{Minimize } R^* + C_1 \sum_{i=1}^n \xi_i^+ + C_2 \sum_{l=1}^m \xi_l^- \\ & \text{subject to} \begin{cases} \rho_i \|x_i - a\|^* \leq R^* + \xi_i^+, \\ \xi_i^+ \geq 0, \quad i = 1, \dots, n \\ \rho_l \|x_l - a\|^* \geq R^* - \xi_l^-, \\ \xi_l^- \geq 0, \quad l = 1, \dots, m \end{cases} \end{aligned} \quad (16)$$

در این مسئله پارامترهای C_1 و C_2 وظیفه تنظیم خطای یادگیری را بر عهده دارند و ضریب ρ_i متناظر با چگالی نمونه‌های یادگیری مثبت و ضریب ρ_l متناظر با چگالی نمونه‌های یادگیری منفی است.

مشکل این روش کسری‌بودنتابع هدف مسئله بهینه‌سازی دوگان آن است. حل کردن این مسئله بهینه‌سازی در مقایسه با مسئله بهینه‌سازی دوگان SVDD به زمان بیشتری نیاز دارد و یک نقطه ضعف این روش است. نقطه ضعف دیگر این روش فاصله‌گرفتن مرز ابرکره از ناحیه‌های غیر چگال است. اهمیت این ضعف از آنجا روش می‌شود که توجه کنیم که انتظار می‌رفت مرز طبقه‌بند فقط از ناحیه‌های چگال فاصله بگیرد.

در سال ۲۰۱۱ طبقه‌بندی به نام TC-SVDD با الهام از SVDD پیشنهاد شد. مطابق مدل پیشنهادشده فرض بر این است که داده‌های دو کلاس هدف در دسترس هستند ولی از نمونه‌های سایر کلاس‌ها اطلاع چندانی در دسترس نیست. با در نظر گرفتن این فرض و استفاده از طبقه‌بند NSVDD، طبقه‌بند دوکلاسه‌ای طراحی شد که ضمن جداسازی نمونه‌های دو کلاس از یکدیگر توان شناسایی نمونه‌های پرت را دارد.

در مقاله حاضر برای غلبه بر مشکل تأثیر نمونه‌های پرت بر مرز ابرکره، طبقه‌بند تک کلاسه‌گرانش‌گرای مبتنی بر SVDD معرفی می‌شود. در بخش بعد به بررسی روش پیشنهادی می‌پردازیم.



شکل ۴: (الف) $C = 0.25$ و (ب) $C = 0.21$. برای پیاده‌سازی SVDD از کرنل RBF استفاده شده است. برای غلبه بر نمونه‌های پرت پارامتر C تدبیجاً کاهش می‌باید. در شکل ۴-ب وجود خروج نمونه‌های یادگیری نویزی از داخل مرزها، همچنان مرزها به سمت این نمونه‌های یادگیری کشیدگی دارند.

کلاس خارج شده و مطابق شکل ۴-ب، بعد از دومین کاهش این نمونه‌ها از کره بیرون افتاده‌اند. لیکن هنوز مرز طبقه‌بند به سمت این نمونه‌ها تمایل و کشیدگی دارد که علت آن را می‌توان در (۵) ملاحظه کرد. در این فرمول روشن است که همه نمونه‌ها بر مرکز و مرز تأثیر می‌گذارند. این مرز با شکل توزیع نمونه‌های یادگیری همخوانی ندارد و ممکن است به خطای منفی-اشتباه منجر شود.

۲-۲ طبقه‌بند ماشین بردار پشتیبان مبتنی بر چگالی DSVDD

این طبقه‌بند در سال‌های ۲۰۰۵ تا ۲۰۰۷ پیشنهاد شد و ارتقا یافت [۳] و [۸]. در مدل پیشنهادشده با هدف دور کردن مرز طبقه‌بند از ناحیه‌های چگال، ابتدا به هر نمونه یادگیری یک چگالی محلی نسبت داده می‌شود. سپس قیود مسئله بهینه‌سازی مرتبط با SVDD به گونه‌ای تغییر داده می‌شوند تا مرز ابرکره به سمت نمونه‌های چگال‌تر رانده شود. فرمول پیشنهادشده جهت محاسبه چگالی محلی

$$\rho_i = \exp(\omega \times \frac{\text{MEAN}^K}{d(x_i, x_i^K)}), \quad i = 1, \dots, n, \quad \omega \leq 1 \quad (14)$$

که در آن n تعداد نمونه‌های یادگیری است، ω فاکتور وزن دهنده نام دارد و $d(x_i, x_i^K)$ برابر فاصله نمونه i از K امین نزدیک‌ترین نمونه بوده و MEAN^K برای میانگین $d(x_i, x_i^K)$ است. متغیرهای a و R به

$$\frac{\partial L}{\partial R} = \dots \Rightarrow \gamma R - \gamma R \sum_{i=1}^n \alpha_i = \dots \Rightarrow \sum_{i=1}^n \alpha_i = 1 \quad (21)$$

$$\frac{\partial L}{\partial \xi_i} = \dots \Rightarrow \alpha_i + \gamma_i = C \Rightarrow \alpha_i \leq C \quad (22)$$

$$\begin{aligned} \frac{\partial L}{\partial a} = \dots \Rightarrow & \frac{B}{n} \sum_{i=1}^n \sum_{j=1}^n (-x_i - a) - (x_j - a) \\ & + \sum_{i=1}^n \alpha_i (-2(x_i - a)) = \dots \Rightarrow a = \frac{\sum_{i=1}^n (\alpha_i + \frac{B}{n}) x_i}{1 + B} \end{aligned} \quad (23)$$

بعد از جایگذاری مقادیر به دست آمده بالا در (۲۰)، دو گان (۱۹) به صورت زیر به دست می‌آید

$$\begin{aligned} \text{Maximize}_{\bar{x}} \quad & \frac{1}{1+B} \left(-\frac{B}{n} \sum_{i=1}^n \sum_{j=1}^n \alpha_i x_i x_j - \frac{B}{n} \sum_{i=1}^n \sum_{j=1}^n x_i x_j \right. \\ & \left. - \sum_{i=1}^n \sum_{j=1}^n \alpha_i \alpha_j x_i x_j \right) + \sum_{i=1}^n \alpha_i x_i x_i + \frac{B}{n} \sum_{i=1}^n \sum_{j=1}^n x_i x_j \end{aligned} \quad (24)$$

$$\text{subject to} \begin{cases} \sum_{i=1}^n \alpha_i = 1 \\ \alpha_i \leq C, i = 1, \dots, n \end{cases}$$

پس از حل مسئله بهینه‌سازی بالا، اغلب ضرایب α_i برابر صفر خواهند شد و تنها تعداد محدودی از آنها مقدار غیر صفر اختیار می‌کنند. روابط بین ضرایب لاغرانژ و موقعیت نمونه‌های یادگیری نسبت به ابرکره، در یکی از شرط‌های زیر صدق می‌کنند

$$\begin{aligned} \|x_i - a\|^r < R^r & \Leftrightarrow \alpha_i = 0, \quad \xi_i = 0 \\ \|x_i - a\|^r = R^r & \Leftrightarrow 0 < \alpha_i < C, \quad \xi_i = 0 \\ \|x_i - a\|^r > R^r & \Leftrightarrow \alpha_i = C, \quad \xi_i > 0 \end{aligned} \quad (25)$$

با در اختیار داشتن ضرایب α_i ، فاصله هر نمونه z از مرکز کره، توسط

$$\begin{aligned} \|z - a\|^r &= z.z - \frac{2}{B+1} \left(\sum_{i=1}^n \alpha_i x_i.z + \frac{B}{n} \sum_{i=1}^n x_i.z \right) \\ &+ \frac{1}{(B+1)^r} \left[\sum_{i=1}^n \sum_{j=1}^n \alpha_i \alpha_j x_i x_j + \frac{B^r}{n^r} \sum_{i=1}^n \sum_{j=1}^n x_i x_j \right] \\ &+ \frac{B}{n} \sum_{i=1}^n \sum_{j=1}^n \alpha_i x_i x_j \end{aligned} \quad (26)$$

همچنان که مشاهده می‌شود برای محاسبه فاصله نمونه z تا مرکز ابرکره لازم است که عبارت $(B/n) \sum_{i=1}^n x_i.z$ محاسبه شود. بنابراین اگر B مخالف صفر باشد، تمام نمونه‌های یادگیری در محاسبات مربوط به طبقه‌بندی دخالت دارند و نمی‌توان این روش را در دسته ماشین‌های بردار پشتیبان طبقه‌بندی کرد.

برای محاسبه R^r کافی است یکی از نمونه‌های را که مطابق بند دوم (۲۲) بر روی ابرکره واقع شده، انتخاب و در (۲۳) جایگزین کرد. برای بررسی تعلق یک نمونه تست به کلاس هدف کافی است که فاصله اش تا مرکز محاسبه شده و با R^r مقایسه گردد. چنانچه فاصله نمونه از مرکز کمتر از R^r باشد، نمونه تست به عنوان نمونه‌ای از آن کلاس پذیرفته می‌شود. همچنین با در نظر گرفتن مسئله بهینه‌سازی (۲۴) و مشاهده عبارت‌های ضرب نقطه‌ای بین نمونه‌های یادگیری، می‌توان نتیجه گرفت که GSVDD مانند SVDD قابلیت استفاده از توابع کرنل را دارد.

۳- روش پیشنهادی: طبقه‌بند تک کلاسه گرانش‌گرای مبتنی بر ماشین بردار پشتیبان

در این بخش دو مدل توسعه‌یافته از SVDD مطرح می‌شود تا نقاط ضعف آن را مرتفع نماید. ابتدا به معرفی روش GSVDD پرداخته و سپس به معرفی روش NGSVDD می‌پردازیم.

۱-۳ طبقه‌بند تک کلاسه مبتنی بر گرانش

در مدل پیشنهادی ضمن تلاش برای کاهش شاعع ابرکره، کمبینه کردن فاصله مرکز ابرکره از مرکز گرانش اهمیت دارد. اهمیت قایل شدن برای مرکز گرانش باعث می‌شود مرکز ابرکره به نمونه‌های چگال نزدیک شده و در نتیجه مرز ابرکره از مرکز گرانش ایجاد شود. علاوه بر این باعث مشارکت تمام نمونه‌ها در تعیین مرکز ابرکره و به تبع آن کاهش اثر نمونه‌های نویزی یا پرت در محاسبه مرز طبقه‌بند می‌شود.

مطابق ایده پیشنهادشده متغیرهای a و R به ترتیب مرکز و شاعع ابرکره هستند و از طریق حل مسئله بهینه‌سازی (۱۷) به دست می‌آیند

$$\begin{aligned} \text{Minimize}_{R^r} \quad & R^r + B \|\bar{x} - a\|^r \\ \text{subject to} \quad & \begin{cases} (x_i - a)^T (x_i - a) \leq R^r \\ \xi_i \geq 0, i = 1, \dots, n \end{cases} \end{aligned} \quad (17)$$

در این مسئله \bar{x} مرکز گرانش نمونه‌های یادگیری است و B پارامتری است که درجه اهمیت مرکز گرانش نمونه‌های یادگیری را تعیین می‌کند. هر چه قدر این پارامتر بزرگ‌تر باشد، مرکز گرانش نقش بیشتری در تعیین مرکز ابرکره خواهد داشت. اگر مقدار پارامتر B برابر صفر باشد، طبقه‌بند پیشنهادشده به SVDD تبدیل می‌شود. بنابراین با معرفی روشی جدید که از لحاظ تعداد پارامترها نسبت به SVDD یک درجه آزادی بیشتر دارد، می‌توان به پیدا کردن جواب‌هایی بهتر امیدوار شد.

فاصله مرکز ابرکره از مرکز گرانش را می‌توان به صورت (۱۸) بازنویسی کرد

$$\begin{aligned} \|\bar{x} - a\|^r &= \left\| \sum_{i=1}^n \frac{x_i}{n} - a \right\|^r = \frac{1}{n^r} \left\| \sum_{i=1}^n x_i - \sum_{i=1}^n a \right\|^r \\ &= \frac{1}{n^r} \sum_{i=1}^n \sum_{j=1}^n (x_i - a) \cdot (x_j - a) \end{aligned} \quad (18)$$

چنانچه کاهش اندازه ابرکره در قبال خطای یادگیری پذیرفتنی باشد، می‌توان با در نظر گرفتن (۱۸) و (۱۷)، مسئله بهینه‌سازی زیر را برای مدل کردن طبقه‌بند ارائه داد

$$\begin{aligned} \text{Minimize}_{R^r} \quad & R^r + \frac{B}{n^r} \sum_{i=1}^n \sum_{j=1}^n (x_i - a) \cdot (x_j - a) + C \sum_{i=1}^n \xi_i \\ \text{subject to} \quad & \begin{cases} \|x_i - a\|^r \leq R^r + \xi_i \\ \xi_i \geq 0, i = 1, \dots, n \end{cases} \end{aligned} \quad (19)$$

یکی از متغیرهای کمبود هستند و پارامتر C وظیفه تنظیم خطای یادگیری را بر عهده دارد. برای حل (۱۹) تابع لاغرانژ به صورت زیر تشکیل می‌شود

$$\begin{aligned} L &= R^r + \frac{B}{n^r} \sum_{i=1}^n \sum_{j=1}^n (x_i - a) \cdot (x_j - a) + C \sum_{i=1}^n \xi_i \\ &+ \sum_{i=1}^n \alpha_i (\|x_i - a\|^r - R^r - \xi_i) - \sum_{i=1}^n \gamma_i \xi_i \end{aligned} \quad (20)$$

برای احراز شرط لازم KKT مطابق (۲۱) تا (۲۳)، از تابع لاغرانژ (۲۰) نسبت به متغیرهای (۱۹) مشتق گرفته شده و برابر صفر قرار داده می‌شود

$$\frac{\partial L}{\partial \xi_i^-} = 0 \Rightarrow \beta_i + \eta_i = C_i \quad (۳۲)$$

بعد از جایگذاری روابط به دست آمده بالا درتابع لاغرانژ (۲۵)، دو گان مسئله بهینه‌سازی (۲۴) به صورت زیر ظاهر می‌شود

$$\begin{aligned} \text{Maximize} & -\frac{1}{1+B} \left\{ \gamma \frac{B}{n} \sum_{i=1}^n \sum_{j=1}^m \alpha_i x_i x_j \right. \\ & - 2 \frac{B}{n} \sum_{i=1}^n \sum_{l=1}^m \beta_l x_i x_l - 2 \sum_{i=1}^n \sum_{l=1}^m \alpha_i \beta_l x_i x_l \\ & + \frac{B}{n} \sum_{i=1}^n \sum_{j=1}^m x_i x_j + \sum_{i=1}^n \sum_{j=1}^m \alpha_i \alpha_j x_i x_j \\ & \left. + \sum_{l=1}^m \sum_{p=1}^n \beta_l \beta_p x_l x_p \right\} \\ & + \sum_{i=1}^n \alpha_i x_i x_i - \sum_{l=1}^m \beta_l x_l x_l \\ & + \frac{B}{n} \sum_{i=1}^n \sum_{j=1}^m x_i x_j \\ & \left. \sum_{i=1}^n \alpha_i - \sum_{l=1}^m \beta_l = 1 \right. \\ \text{subject to} & \left. \begin{array}{l} \cdot \leq \alpha_i \leq C_i, i = 1, \dots, n \\ \cdot \leq \beta_l \leq C_l, l = 1, \dots, m \end{array} \right. \end{aligned} \quad (۳۳)$$

برای سادگی و سهولت کارکردن با فرمول مسئله، می‌توان آن را به صورت زیر بازنویسی کرد

$$\begin{aligned} \text{Maximize} & -\frac{1}{1+B} \left\{ +\frac{B}{n} \sum_{i=1}^{n+m} \sum_{j=1}^n \alpha_i x_i x_j \right. \\ & + \sum_{i=1}^{n+m} \sum_{j=1}^n \alpha_i \alpha_j x_i x_j + \frac{B}{n} \sum_{i=1}^n \sum_{j=1}^m x_i x_j \\ & \left. + \sum_{i=1}^{n+m} \alpha_i x_i x_i + \frac{B}{n} \sum_{i=1}^n \sum_{j=1}^m x_i x_j \right\} \\ \text{subject to} & \left. \begin{array}{l} \sum_{i=1}^{n+m} \alpha_i = 1 \\ \cdot \leq \alpha_i \leq C_i, i = 1, \dots, n \\ \cdot \leq -\alpha_i \leq C_i, i = n+1, \dots, m \end{array} \right. \end{aligned} \quad (۳۴)$$

در این مسئله نمونه‌های با اندیس بین ۱ تا n ، نمونه‌های مثبت و نمونه‌های با اندیس بین $n+1$ تا $n+m$ ، نمونه‌های منفی هستند.

در شکل ۶ توانایی NGSVDD در مقایسه با SVDD و NSVDD به تصویر کشیده شده است. در این شکل نمونه‌های مثبت و منفی به ترتیب با علامت‌های دایره و + مشخص شده‌اند و فرض شده که چهار عدد نمونه دایره که در سمت چپ قرار دارند، نمونه‌های پرت هستند که اشتباهاً به عنوان نمونه مثبت برچسب‌گذاری شده‌اند. در شکل ۵-الف مرز طبقه‌بند SVDD برای توصیف کلاس هدف رسم شده است. مطابق این شکل به دلیل حضور نمونه‌های پرت در بین نمونه‌های مثبت، مرز به دست آمده چندان مناسب نیست. برای غلبه بر این مشکل از طبقه‌بند NSVDD استفاده شده و مرز آن در شکل ۵-ب به تصویر کشیده شده است. در این شکل مرز محاسبه شده نسبت به مرز SVDD مناسب‌تر است ولی هنوز تحت تأثیر نمونه‌های پرت قرار دارد. در نهایت از روش NGSVDD برای محاسبه مرز شکل ۵-ج استفاده شده است. همان‌طور

و به واسطه این خصوصیت می‌توان مرز انعطاف‌پذیر و مناسبی را برای کلاس هدف محاسبه کرد. برای تحقق این هدف کافی است در مسئله بهینه‌سازی (۲۴) به جای هر عبارت $x \cdot y$ تابع $K(x, y)$ جایگزین گردد.

۲-۳ طبقه‌بند تک کلاسیه مبتنی بر گرانش با نمونه‌های منفی

چنانچه تعدادی از نمونه‌های یادگیری پرت در دسترس باشند، می‌توان GSVDD را به گونه‌ای توسعه داد که نمونه‌های پرت در فرایند یادگیری دخالت داشته باشند. مدل پیشنهادی به صورت مسئله بهینه‌سازی زیر ارائه می‌شود

$$\begin{aligned} \text{Minimize} & R^\gamma + C_i \sum_{i=1}^n \xi_i^+ + C_l \sum_{l=1}^m \xi_l^- \\ & + \frac{B}{n^\gamma} \sum_{i=1}^n \sum_{j=1}^m (x_i - a) \cdot (x_j - a) \\ \text{subject to} & \begin{cases} \|x_i - a\|^\gamma \leq R^\gamma + \xi_i^+ \\ , \xi_i^+ \geq 0, i = 1, \dots, n \end{cases} \\ & \begin{cases} \|x_l - a\|^\gamma \geq R^\gamma - \xi_l^- \\ , \xi_l^- \geq 0, l = 1, \dots, m \end{cases} \end{aligned} \quad (۳۷)$$

مطابق این مسئله بهینه‌سازی، ضمن جستجوی ابرکرهای با حداقل شعاع که پوشش‌دهنده نمونه‌های یادگیری مثبت باشد و از پذیرش نمونه‌های یادگیری منفی خوداری کند، به مرکز گرانش نمونه‌های یادگیری مثبت نیز اهمیت داده می‌شود. در روش پیشنهادشده با استفاده از متغیرهای کمبود ξ_i^+ و ξ_l^- اجازه وقوع خطای یادگیری محدود شده است تا امکان غلبه بر نمونه‌های نویزی و پرت وجود داشته باشد. در این مسئله پارامترهای C_i و C_l وظیفه تنظیم خطای یادگیری را بر عهده دارند. برای حل این مسئله کافی است که تابع لاغرانژ مسئله (۲۴) به صورت (۲۸) تشکیل شود

$$\begin{aligned} L = & R^\gamma + C_i \sum_{i=1}^n \xi_i^+ + C_l \sum_{l=1}^m \xi_l^- \\ & + \sum_{i=1}^n \alpha_i (\|x_i - a\|^\gamma - R^\gamma - \xi_i^+) - \sum_{i=1}^n \gamma_i \xi_i^+ \\ & + \sum_{l=1}^m \beta_l (-\|x_l - a\|^\gamma + R^\gamma - \xi_l^-) - \sum_{l=1}^m \eta_l \xi_l^- \\ & + \frac{B}{n^\gamma} \sum_{i=1}^n \sum_{j=1}^m (x_i - a) \cdot (x_j - a) \end{aligned} \quad (۲۸)$$


برای تحقق شرط لازم KKT، مطابق (۲۹) تا (۳۲) از تابع لاغرانژ فوق نسبت به متغیرهای (۲۷) مشتق گیری شده و برابر صفر قرار داده می‌شود

$$\frac{\partial L}{\partial R} = 2R (1 - \sum_{i=1}^n \alpha_i + \sum_{l=1}^m \beta_l) = 0 \Rightarrow \sum_{i=1}^n \alpha_i - \sum_{l=1}^m \beta_l = 1 \quad (۲۹)$$


$$\begin{aligned} \frac{\partial L}{\partial a} = & 2 \sum_{i=1}^n \alpha_i (x_i - a) - 2 \sum_{l=1}^m \beta_l (x_l - a) \\ & + \frac{B}{n^\gamma} \sum_{i=1}^n \sum_{j=1}^m (-(x_i - a) - (x_j - a)) = 0 \end{aligned} \quad (۳۰)$$

$$\Rightarrow a = \frac{\sum_{i=1}^n \alpha_i x_i - \sum_{l=1}^m \beta_l x_l + \frac{B}{n} \sum_{i=1}^n x_i}{1+B}$$

$$\frac{\partial L}{\partial \xi_i^+} = 0 \Rightarrow \alpha_i + \gamma_i = C_i \quad (۳۱)$$






(الف)



(ب)

شکل ۴: (الف) مرز طبقه‌بند به‌طور مستقیم در فضای ورودی محاسبه شده است و (ب) مرز طبقه‌بند با استفاده از کرنل RBF و پارامتر $\sigma = 10$ محاسبه شده است.



شکل ۵: (الف) $C_r = 0.2$ ، $\sigma = 3$. NSVDD (ب) $C_r = 0.21$ ، $\sigma = 3$. SVDD و $B = 4$ و $C_r = 0.21$ ، $\sigma = 3$. NGSVDD (ج) $C_r = 0.21$ و $\sigma = 3$.

که مشاهده می‌شود، مرز محاسبه شده در مقایسه با مرزهای حاصل از SVDD و NSVDD مناسب‌تر و بهتر است.

۳-۳ تأثیر تغییرات پارامترها بر رفتار طبقه‌بند NGSVDD

به منظور بررسی تأثیر تغییرات پارامترها بر رفتار کرنل ابتدا به سراغ رابطه پارامتر σ کرنل RBF و طبقه‌بند NGSVDD رفته و رفتار طبقه‌بند با تغییر این پارامترها بررسی می‌شود.

۳-۳-۱ رابطه پارامتر σ کرنل RBF و طبقه‌بند NGSVDD

بسط تیلور کرنل RBF را به‌صورت رابطه زیر داریم

به وجود می‌آورد.
حال چنانچه پارامتر σ به سمت صفر میل داده شود، رابطه زیر درباره کرنل RBF برقرار است

$$\lim_{\sigma \rightarrow 0} K(x_i, x_j) = \exp\left(-\frac{\|x_i - x_j\|^2}{\sigma^2}\right) = 0, \forall i \neq j \quad (41)$$

بنابراین در صورت استفاده از کرنل RBF با مقدار کوچک σ و چایگرینی آن با عبارت‌های ضرب نقطه‌ای، مسئله بهینه‌سازی (۳۴) به مسئله زیر تبدیل می‌شود

$$\begin{aligned} \text{Maximize}_{\alpha} & -\frac{1}{1+B} (+2\frac{B}{n} \sum_{i=1}^n \alpha_i + \sum_{i=1}^{n+m} \alpha_i) \\ \text{subject to} & \begin{cases} \sum_{i=1}^{n+m} \alpha_i = 1 \\ 0 \leq \alpha_i \leq C, i = 1, \dots, n \\ 0 \leq -\alpha_i \leq C, i = n+1, \dots, m \end{cases} \end{aligned} \quad (42)$$

این یک مسئله بهینه‌سازی محاسب است و جواب بهینه منحصر به فرد دارد. از طرفی ساختار این مسئله به‌گونه‌ای است که به‌طور جداگانه نسبت به ضرایب لاگرانژ نمونه‌های مثبت و منفی متفاوت است. لذا ضرایب لاگرانژ نمونه‌های مثبت با هم برابر هستند و با نماد α نشان داده می‌شوند. با استدلالی مشابه ضرایب لاگرانژ نمونه‌های منفی با نماد β نمایش داده می‌شوند و لذا مسئله بهینه‌سازی (۴۲) به مسئله بهینه‌سازی زیر تبدیل می‌شود

$$\begin{aligned} \text{Maximize}_{\alpha, \beta} & -\frac{1}{1+B} (+2B\alpha + n\alpha^2 + m\beta^2) \\ \text{subject to} & \begin{cases} n\alpha + m\beta = 1 \\ 0 \leq \alpha \leq C \\ 0 \leq \beta \leq C \end{cases} \end{aligned} \quad (43)$$

جواب بهینه (۴۳) در صورت وجود به صورت $\alpha_i = 1/n, i = 1, \dots, n$ و $\alpha_i = 0, i = n+1, \dots, m$ خواهد بود. بنابراین هنگامی که پارامتر σ به سمت صفر میل می‌کند، نمونه‌های مثبت به صورت مساوی در تعیین مرکز ابرکره دخالت دارند و نمونه‌های منفی بی‌اثر هستند. با توجه به این که در این حالت ضرایب لاگرانژ نمونه‌های مثبت مقداری غیر صفر است، مرز طبقه‌بند از روی تمام نمونه‌های یادگیری عبور می‌کند و به نوعی وضعیت پیچیدگی مرز را به وجود می‌آورد.

همچنین ثابت می‌شود که برای مقدار میانی σ عملکرد GSVDD مشابه تخيين‌گر پارزن می‌شود. برای اثبات این ادعا کافی است که فاصله نمونه دلخواه z از مرکز ابرکره مطابق فرمول زیر محاسبه شود

$$\begin{aligned} \|z - a\|^2 &= \left\| z - \frac{\sum_{i=1}^n \alpha_i x_i + \frac{B}{n} \sum_{i=1}^n x_i}{1+B} \right\|^2 = z.z \\ &- 2 \times \frac{\sum_{i=1}^n \alpha_i z.x_i + \frac{B}{n} \sum_{i=1}^n z.x_i}{1+B} + \left\| \frac{\sum_{i=1}^n \alpha_i x_i + \frac{B}{n} \sum_{i=1}^n x_i}{1+B} \right\|^2 \end{aligned} \quad (44)$$

در صورت استفاده از کرنل RBF و ثابت در نظر گرفتن جملات مستقل از σ خواهیم داشت

تابع (۳۶) باید نسبت به ضرایب لاگرانژ ماکریم شود، پس می‌توان تمام یا بعضی از عبارات مستقل از این ضرایب را حذف کرد. بعد از حذف $2(B^r/n^r) \sum_{i=1}^n \sum_{j=1}^n x_i.x_j / \sigma^r$ عبارات مستقل از ضرایب لاگرانژ به جزء (۳۷) به دست می‌آید

$$\begin{aligned} L = & -\frac{1}{1+B} \left\{ 4 \frac{B}{n} \sum_{i=1}^{n+m} \sum_{j=1}^n \alpha_i \frac{x_i.x_j}{\sigma^r} \right. \\ & + 2 \frac{B^r}{n^r} \sum_{i=1}^n \sum_{j=1}^n \frac{x_i.x_j}{\sigma^r} + 2 \sum_{i=1}^{n+m} \sum_{j=1}^m \alpha_i \alpha_j \frac{x_i.x_j}{\sigma^r} \} \\ & + \frac{1}{1+B} \left\{ +2 \frac{B}{n} \sum_{i=1}^{n+m} \sum_{j=1}^n \alpha_i \left(\frac{\|x_i\|^2}{\sigma^r} + \frac{\|x_j\|^2}{\sigma^r} \right) \right. \\ & \left. + \sum_{i=1}^{n+m} \sum_{j=1}^m \alpha_i \alpha_j \left(\frac{\|x_i\|^2}{\sigma^r} + \frac{\|x_j\|^2}{\sigma^r} \right) \right\} + \dots \end{aligned} \quad (37)$$

پس از انجام ساده‌سازی‌های متوالی و حذف مجدد عبارات مستقل از ضرایب لاگرانژ، طبق (۳۸) تا (۴۰) خواهیم داشت

$$\begin{aligned} L = & -\frac{1}{1+B} \left\{ 4 \frac{B}{n} \sum_{i=1}^{n+m} \sum_{j=1}^n \alpha_i \frac{x_i.x_j}{\sigma^r} \right. \\ & + 2 \frac{B^r}{n^r} \sum_{i=1}^n \sum_{j=1}^n \frac{x_i.x_j}{\sigma^r} + 2 \sum_{i=1}^{n+m} \sum_{j=1}^m \alpha_i \alpha_j \frac{x_i.x_j}{\sigma^r} \} \\ & + 2 \frac{B}{B+1} \sum_{i=1}^{n+m} \alpha_i \frac{\|x_i\|^2}{\sigma^r} + 2 \frac{1}{B+1} \sum_{i=1}^{n+m} \alpha_i \frac{\|x_i\|^2}{\sigma^r} + \dots \end{aligned} \quad (38)$$

$$\begin{aligned} L = & -\frac{1}{1+B} \left\{ 4 \frac{B}{n} \sum_{i=1}^{n+m} \sum_{j=1}^n \alpha_i \frac{x_i.x_j}{\sigma^r} \right. \\ & + 2 \frac{B^r}{n^r} \sum_{i=1}^n \sum_{j=1}^n \frac{x_i.x_j}{\sigma^r} + 2 \sum_{i=1}^{n+m} \sum_{j=1}^m \alpha_i \alpha_j \frac{x_i.x_j}{\sigma^r} \} \\ & + 2 \sum_{i=1}^{n+m} \alpha_i \frac{\|x_i\|^2}{\sigma^r} + \dots \end{aligned} \quad (39)$$

پس از ضرب عبارت بالا در $\sigma^r / 2$ عبارت زیر حاصل می‌شود

$$\begin{aligned} L = & -\frac{1}{1+B} \left\{ 2 \frac{B}{n} \sum_{i=1}^{n+m} \sum_{j=1}^n \alpha_i x_i.x_j \right. \\ & + \frac{B^r}{n^r} \sum_{i=1}^n \sum_{j=1}^n x_i.x_j + \sum_{i=1}^{n+m} \sum_{j=1}^m \alpha_i \alpha_j x_i.x_j \} \\ & + \sum_{i=1}^{n+m} \alpha_i x_i.x_i + \dots \end{aligned} \quad (40)$$

چنانچه مقدار پارامتر σ به اندازه کافی بزرگ باشد، در (۴۰) جملات مرتبه بالا به سمت صفر میل می‌کنند و می‌توان از آنها صرف نظر کرد. در این صورت (۴۰) (پس از الحق عبارت مستقل از ضریب لاگرانژ $(B/n^r)(\sum_{i=1}^n \sum_{j=1}^n x_i.x_j)$) هم‌ارز تابع هدف (۳۶) می‌شود. به عبارت دیگر در صورت استفاده از کرنل RBF با مقدار بزرگ σ ، مسئله بهینه‌سازی در فضای ویژگی به مسئله بهینه‌سازی در فضای ورودی تبدیل شده و مرز محاسبه شده یک ابرکره خواهد بود.

به عنوان مثال در شکل ۶-الف مرز طبقه‌بند در فضای ورودی محاسبه و ترسیم شده و مرز شکل ۶-ب با استفاده از کرنل RBF به‌ازای مقادیر بزرگ σ به تصویر کشیده شده است. همچنان که مشاهده می‌شود برای مقادیر بزرگ σ مرز محاسبه شده مانند مرزی است که در فضای ورودی محاسبه گردیده است. بنابراین می‌توان این گونه نتیجه گرفت که مرز این طبقه‌بند به‌ازای مقادیر بزرگ σ بسیار ساده بوده و پدیده سادگی مرز را

$$\|z - a\|^r = \text{constant} \\ -\frac{2}{1+B} \times \left(\sum_{i=1}^n \alpha_i e^{-\frac{\|z-x_i\|^r}{\sigma^r}} + \frac{B}{n} \sum_{i=1}^n ??? \frac{\|z-x_i\|^r}{\sigma^r} \right) \quad (45)$$

چنانچه مقدار محاسبه شده توسط (۴۵) کمتر از شعاع R^r باشد، نمونه z در داخل ابرکره قرار دارد و بنابراین می‌توان مسأله تعلق یک نمونه به کلاس هدف را به صورت خابطه تصمیم (۴۶) در نظر گرفت

$$\text{if } \sum_{i=1}^n (\alpha_i + \frac{B}{n}) e^{-\frac{\|z-x_i\|^r}{\sigma^r}} > (\text{constant} - R^r) \times \frac{B+1}{2} \quad (46)$$

then z belongs to target class


در این ضابطه عبارت $\sum_{i=1}^n (\alpha_i + B/n) \exp(-\|z-x_i\|^r / \sigma^r)$ تابع تخمین‌گر پارزن را در ذهن تداعی می‌کند. لکن همان طور که در قسمت‌های بعدی توضیح داده خواهد شد، پارامتر B می‌تواند مقادیر منفی بزرگ‌تر از -1 را اختیار کند. لذا ضابطه تصمیم (۴۶) حالتی فراگیرتر نسبت به پارزن دارد و ضرایب متضاد نمونه‌های داخلی می‌توانند مقادیر منفی هم اختیار کنند در حالی که در مورد پارزن این ویژگی مصدق ندارد. در این قسمت تغییرات مرز طبقه‌بند GSVDD در مقابل تغییرات پارامتر σ به تصویر کشیده می‌شود. در مجموعه شکل‌های ۷ مقدار پارامتر σ تدریجی افزایش می‌یابد. برای مقادیر بسیار کوچک σ پدیده پیچیدگی مرز رخ داده است و با افزایش σ به تدریج پیچیدگی مرز کمتر می‌شود. برای مقادیر میانی این پارامتر می‌توان تعمیم مناسبی را برای طبقه‌بند متصور شد و به ازای مقادیر بزرگ‌تر σ شکل مرزها به سمت سادگی میل می‌کند.

۲-۳-۳- بروزی رابطه پارامتر B و تأثیر تغییرات آن بر مرز NGSVDD طبقه‌بند


پارامتر B بیانگر وزن و اهمیت مرکز گرانش نمونه‌های یادگیری است. از مسأله بهینه‌سازی (۳۶) دیده می‌شود که این مسأله بهارای مقادیر B بزرگ‌تر از -1 ، به یک مسأله بهینه‌سازی محدب تبدیل می‌شود. چنانچه پارامتر $B = 0$ باشد، مدل پیشنهادی NGSVDD به مدل NSVDD تبدیل می‌شود. اگر $B > 0$ باشد، به این معنی است که کاهش فاصله بین مرکز کره و مرکز گرانش دارای اهمیت است و اگر $B < 0$ برقرار باشد به این معنی است که دورشدن از مرکز گرانش ترجیح داده می‌شود. به عبارتی دیگر چنانچه پارامتر B مقادیر منفی اختیار شود، امکان گریز از مرکز گرانش فراهم شده است. پارامتر B همانند پارامتر σ کرنل RBF وظیفه برقراری تعمیم را بر عهده دارد. به عبارتی دیگر با پیداکردن مقدار مناسب پارامتر B می‌توان عملکرد NGSVDD را بر روی داده‌های دیده‌نشده بهبود داد. چنانچه پارامتر B به اندازه کافی بزرگ باشد، مسأله بهینه‌سازی (۳۶) به مسأله بهینه‌سازی خطی زیر تبدیل می‌شود

$$\begin{aligned} \text{Maximize} & -\frac{2}{n} \sum_{i=1}^{n+m} \sum_{j=1}^n \alpha_i x_i \cdot x_j + \sum_{i=1}^{n+m} \alpha_i x_i \cdot x_i \\ & \sum_{i=1}^{n+m} \alpha_i = 1 \\ \text{subject to} & \begin{cases} 0 \leq \alpha_i \leq C_1, & i = 1, \dots, n \\ 0 \leq -\alpha_i \leq C_2, & i = n+1, \dots, m \end{cases} \end{aligned} \quad (47)$$


تحت این شرایط مطابق (۴۸) مرکز ابرکره بر مرکز گرانش منطبق می‌شود و ضرایب لاگرانژ، نقشی در تعیین مرکز ابرکره نخواهند داشت




(الف)



(ب)



(ج)



(د)

شکل ۷: تغییرات مرز طبقه‌بند GSVDD در مقابل تغییرات پارامتر σ . (الف) $\sigma = 0.2$ ، (ب) $\sigma = 0.5$ ، (ج) $\sigma = 0.9$ و (د) $\sigma = 2.2$.

$$\lim_{B \rightarrow \infty} a = \lim_{B \rightarrow \infty} \frac{\sum_{i=1}^n \alpha_i x_i - \sum_{l=1}^m \beta_l x_l + \frac{B}{n} \sum_{i=1}^n x_i}{1+B} \quad (48)$$

$$= \frac{1}{n} \sum_{i=1}^n x_i = \bar{x}$$

همچنین اگر از کرنل RBF برای نگاشت غیر خطی نمونه‌ها استفاده شود، مسأله بهینه‌سازی (۳۴) را می‌توان به صورت مسأله بهینه‌سازی زیر بازنویسی کرد. این یک مسأله بهینه‌سازی محدب است که دارای جواب بهینه سراسری است

$$\text{Maximize}_{\alpha} -\frac{1}{1+B} \left\| \sum_{i=1}^{n+m} \alpha_i \phi(x_i) + \frac{B}{n} \sum_{i=1}^n \phi(x_i) \right\|^2$$


$$\text{subject to} \begin{cases} \sum_{i=1}^{n+m} \alpha_i = 1 \\ 0 \leq \alpha_i \leq C, i = 1, \dots, n \\ 0 \leq -\alpha_i \leq C, i = n+1, \dots, n+m \end{cases} \quad (49)$$

تحت این شرایط اگر $B \rightarrow -1^+$ ، مقدار بهینه تابع هدف مسأله (۴۹) به سمت صفر می‌کند و جواب‌های بهینه آن در رابطه‌های $\alpha_i = 1/n, i = 1, \dots, n$ و $\alpha_i = 0, i = n+1, \dots, n+m$ صدق خواهد کرد. با در نظر گرفتن موارد بالا، چنانچه پارامتر C مقداری بزرگ‌تر از $1/n$ داشته باشد، ضریب لاگرانژ تمام نمونه‌های یادگیری مثبت در شرط $\alpha_i < C$ صدق می‌کند. لذا با در نظر گرفتن بند دوم (۲۵) مرز ابرکره به سمت تمام نمونه‌های یادگیری مثبت می‌کند. بنابراین بهازی مقادیر مناسب σ می‌توان منحنی (هایی) برای درون‌یابی نمونه‌های یادگیری در فضای ورودی محاسبه کرد. علت تأکید بر واژه "مقادیر مناسب σ " در جمله قبل این است که اگر مقدار σ بسیار کوچک در نظر گرفته شود، وضعیت پیچیدگی مرز رخ خواهد داد و منحنی درون‌یاب در فضای ورودی، شکل به شدت گسته‌ای خواهد داشت.


در شکل ۸ تغییرات مرز طبقه‌بند GSVDD در مقابل تغییرات پارامتر B ترسیم شده است. قبلاً نیز عنوان شد که حوزه تغییرات پارامتر B بازه $(-1, +\infty)$ است. در این شکل مقدار پارامتر B از مقادیر نزدیک به -1 شروع شده و تدریجاً به سمت مقادیر بزرگ گرایش پیدا می‌کند. همچنان که مشهود است، بهازی مقادیر منفی مرز محاسبه شده به گونه‌ای است که وضعیت پیچیدگی مرز را در ذهن تداعی می‌کند. به علاوه مشاهده می‌شود که برای مقادیر منفی و به اندازه کافی کوچک B مرز محاسبه شده از روی نمونه‌های یادگیری عبور می‌کند و به نوعی عمل درون‌یابی را انجام می‌دهد.

هرچه پارامتر B بیشتر شود، به این معنی است که گرایش به مرکز گرانش نمونه‌های یادگیری بیشتر است. مطابق این شکل‌ها، افزایش پارامتر B و اهمیت قایل شدن برای مرکز گرانش نمونه‌های یادگیری باعث شده که مرز محاسبه شده در شکل ۸-د از نمونه‌های یادگیری سمت راست داده‌ها فاصله بگیرد، در حالی که این اتفاق برای مرز طبقه‌بند رخ نداده است (به شکل‌های ۲ و ۳ مراجعه شود). فاصله گرفتن SVDD مرز از این نمونه‌ها می‌تواند باعث کاهش خطای منفی-اشتباه و برقراری تعمیم‌پذیری مناسب گردد.


با توجه به این که روش پیشنهادی مبتنی بر گرانش است، این مسئله به ذهن می‌رسد که تأثیر افزایش تعداد نمونه‌ها بر عملکرد و رفتار طبقه‌بند چگونه خواهد بود. از آنجا که در واقع در این روش صرفاً مرکز گرانش




(الف)



(ب)



(ج)



(د)

شکل ۸: تغییرات مرز طبقه‌بند GSVDD در مقابل تغییرات پارامتر B . (الف) $B = -0.9999$ ، (ب) $B = -0.9$ ، (ج) $B = 3$ و (د) $B = 13$.

می‌شود، اثر داده‌های پرت در GSVDD کاهش یافته است. افزار داده‌ها به زوج مجموعه‌های یادگیری/ ارزیابی با استفاده از روش ۱۰-Fold-Cross Validation واقعی انجام شد. برای مقایسه نتایج از روش‌های تخمین بازه‌ای ۱۰-Fold-Cross Validated paired t Test مقاومت استفاده شده است.

همچنین برای مقایسه طبقه‌بندی‌های مختلف باید آنها را در بهترین پیکربندی ممکن، مورد آزمایش قرار داد. روش‌های مختلف برای محاسبه بهترین پیکربندی (پارامترهای بهینه) پیشنهاد شده است که عبارت هستند از:

- بهترین حدس Best guess

- یک فاکتور در هر بار One factor at a time


- جستجوی کامل (Grid search)

روش استفاده شده در این مقاله روش Best guess است و برای پیاده‌سازی آن از روش بهینه‌سازی PSO استفاده شده است.


در این قسمت عملکرد روش‌های GSVDD، DSVDD و SVDD مقایسه می‌شود. جدول ۱ بیانگر نتایج حاصل از اعمال روش‌های فوق بر روی مجموعه داده‌های انتخاب شده در حضور داده‌های نرمال است. در این جدول ستون اول بیانگر مجموعه داده و کلاس هدف انتخاب شده می‌باشد. ستون دوم بیانگر دقت روش SVDD است. ستون سوم بیانگر دقت GSVDD بوده و ستون چهارم بیانگر مقدار بهینه پارامتر B DSVDD است. در ستون پنجم دقت طبقه‌بند GSVDD درج شده و در ستون ششم درجه اطمینان حاصل از تخمین بازه‌ای DSVDD برای مقایسه روش‌های GSVDD و One tailed t test می‌باشد. در ستون ششم بیانگر آزمایش‌های انجام شده بر ثبت رسیده است. در این جدول هر ردیف بیانگر آزمایش‌های انجام شده بر روی مجموعه داده و کلاس هدف انتخاب شده می‌باشد. خانه‌های هاشور افقی، خاکستری کمرنگ و خانه‌های هاشور عمودی به ترتیب نشانه اولین، دومین و سومین روش از لحاظ کارایی هستند. اختلاف هاشورگذاری مشاهده شده در هر سطر ناشی از مقایسه نتایج از دیدگاه برآورد نقطه‌ای است. چنانچه دو روش، کارایی مشابهی بر روی یک کلاس از یک مجموعه داده داشته باشند با یک هاشور مشابه نمایش داده می‌شوند.

مطابق این جدول چنانچه یکی از روش‌های GSVDD و DSVDD نسبت به دیگری از دیدگاه برآورد نقطه‌ای برتری داشته باشد، عدد درج شده در ستون ششم بیانگر احتمال یا درجه اعتماد برتری می‌باشد. مثلاً در ستون ششم ردیف آخر جدول فوق عدد 0.8294 درج شده است. این عدد بیانگر این موضوع است که روش GSVDD (روشی که در برآورد نقطه‌ای به عنوان روش بهتر شناخته شده است) با احتمال 82.94% نسبت به روش DSVDD برتری دارد.


به طور مشابه در جدول ۲ نتایج حاصل از روش‌های SVDD و GSVDD و DSVDD در حضور داده‌های آمیخته با نمونه‌های پرت به نمایش درآمده است. این داده‌های پرت از بین نمونه‌های مربوط به سایر کلاس‌های همان مجموعه داده به صورت تصادفی انتخاب شده‌اند. روش دیگری به نام تحلیل مقاومت برای تحلیل و مقایسه الگوریتم‌ها وجود دارد. در این روش، تحلیل مقاومت بر اساس میانگین دقت طبقه‌بند تقسیم بر بزرگ‌ترین میانگین طبقه‌بندی‌های مورد مقایسه صورت می‌گیرد [۱۰]. در عبارت زیر هرچه مقدار حاصل بیشتر باشد، کارایی روش در مقایسه با بهترین روش بر روی پایگاه داده بهتر است. مجموع این مقادیر بر روی همه پایگاه‌های داده معیار خوبی برای روش مورد نظر است



(الف)



(ب)




(ج)

شکل ۹: (الف) SVDD ، $\sigma = 1$ ، $B = 1$ ، (ب) SVDD ، $\sigma = 1$ ، $B = 2$ ، (ج) SVDD ، $\sigma = 2$ ، $B = 1$

اهمیت دارد، بنابراین افزایش تعداد نمونه‌ها تأثیر مستقیمی بر مرز ندارد زیرا در روابط بهینه‌سازی مربوط به GSVDD اگرچه تعداد نمونه‌ها وجود دارد اما این مقدار صرفاً برای محاسبه مرکز گرانش استفاده شده است. این مسئله در (۱۷) کاملاً روشن است و تا هنگامی که مرکز گرانش با افزایش تعداد نمونه‌ها جایجا نشود، مرز تغییری نخواهد کرد.

۴- نتایج آزمایش‌ها

قبل از انجام آزمایش روی مجموعه داده‌های واقعی، آزمایش‌ها را بر روی داده‌های سنتز شده با استفاده از کرنل RBF انجام می‌دهیم. در شکل ۹ مرزهای تعیین شده توسط GSVDD و SVDD با پارامترهای $B = 1$ و $B = 2$ نمایش داده شده‌اند. همچنان که در شکل دیده



شکل ۱۰: تحلیل مقاومت انجامشده متناظر با سطرهای جدول ۱.


جدول ۱: مقایسه روش‌های SVDD، GSVDD و DSVDD.

Dataset/target	SVDD Accuracy	GSVDD Accuracy	B	DSVDD Accuracy	Confidence degree of one tailed t-test
iris1	0.9863	0.9863	-	0.9931	0.83
iris2	0.9319	0.9319	-	0.9387	0.6972
iris3	0.9251	0.9455	-0.9	0.9251	0.906
wine1	0.9714	0.9885	10	0.9885	
wine2	0.8285	0.8514	20	0.8514	
wine3	0.9657	0.9657	230.8	0.9657	
glass1	0.7844	0.7892	2,1,0.75	0.7844	0.7913
glass2	0.6971	0.7307	6,0.56	0.6971	0.9585
glass3	0.9278	0.9278	-	0.9278	
glass7	0.9471	0.9663	7,0.73	0.9663	
ecoli1	0.942	0.9573	10,30.811	0.9603	0.829
ecoli2	0.8689	0.875	8,659	0.8689	0.69885
ecoli5	0.9237	0.9288	28,62519	0.9237	0.71675
ecoli6	0.9564	0.97561	21,128	0.97561	
ecoli8	0.942	0.9573	5,8699	0.9512	0.9167
breast tissue1	0.91	0.91	-	0.92	0.69215
breast tissue2	0.87	0.9	30	0.87	0.85
breast tissue3	0.83	0.83	16,4849	0.83	
breast tissue4	0.91	0.92	15,40.11	0.91	0.729
breast tissue5	0.95	0.95	-	0.97	0.83615
breast tissue6	0.94	0.96	-0.6567	0.95	0.8294
balance scale1	0.92283	0.961415	-0.9	0.92283	0.9999
balance scale2	0.89389	0.911576	8,722584	0.906752	0.78205
balance scale3	0.89228	0.903537	-0.9	0.892283	0.78772
breast cancer wisconsin2	0.95301	0.9647	25,0.5	0.9574	0.76375
breast cancer wisconsin4	0.9368	0.9543	24,14	0.9427	0.89805
Ionosphere1	0.9111	0.9111	-	0.9111	
Ionosphere2	0.659	0.6676	37,72353	0.6647	0.8294

جدول‌های ۱ و ۲ بر بزرگ‌ترین نتیجه هر سطر تقسیم می‌شود. جواب به دست آمده برای هر طبقه‌بند بیانگر میزان مقاومت آن روش برای مجموعه داده مربوطه است. جمع جواب‌های متناظر هر ستون بیانگر مقاومت هر یک از طبقه‌بندی‌های SVDD، GSVDD و DSVDD است. شکل‌های ۱۰ و ۱۱ بیانگر تحلیل مقاومت روش‌های مختلف بر روی

$$b_m = \frac{p_m}{\max_k p_k} \quad (50)$$

این روش بر خلاف آزمون t که برای مقایسه دو الگوریتم به کار می‌رود، توان مقایسه چند الگوریتم را دارد. همان طور که در فرمول بالا دیده می‌شود، در این روش نتایج درج شده در ستون‌های دوم، سوم و ششم www.SID.ir



شکل ۱۱: تحلیل مقاومت انجام شده متناظر با سطرهای جدول ۲.

جدول ۲: مقایسه روش‌های SVDD، GSVDD و DSVDD در حضور داده‌های پرت.

Dataset/target	SVDD	GSVDD	B	DSVDD	Confidence degree of one tailed t-test
iris1	0.9115	0.9727	0.9945	0.9591	0.78465
iris2	0.9037	0.9115	0.916167	0.9183	0.71355
iris3	0.8707	0.8707	-	0.8707	
wine1	0.91428	0.9714	0.9163	0.96	0.9167
wine2	0.7314	0.8285	0.7586	0.7771	0.97955
wine3	0.88	0.9542	0.94921	0.9257	0.99245
glass1	0.7451	0.774	0.7102	0.7451	0.75065
glass2	0.7019	0.7307	0.7004	0.7019	0.94855
glass3	0.923	0.9278	0.9035	0.923	0.8294
glass7	0.9326	0.9663	0.8864	0.9663	
ecoli1	0.9268	0.9542	1.001	0.9573	0.70865
ecoli2	0.8567	0.878	0.9163	0.8567	0.9554
ecoli5	0.877	0.9177	0.869	0.9055	0.86105
ecoli6	0.9573	0.9725	0.94587	0.9695	0.70215
ecoli8	0.9268	0.9481	0.9458	0.9329	0.8973
breast tissue1	0.89	0.89	-	0.89	
breast tissue2	0.86	0.87	0.8012	0.86	0.75065
breast tissue3	0.83	0.83	0.7748	0.83	
breast tissue4	0.9	0.93	0.7789	0.91	0.8549
breast tissue5	0.87	0.92	0.84272	0.91	0.8294
breast tissue6	0.88	0.89	0.91777	0.88	0.8294
balance scale1	0.890675	0.893891	1.0	0.890675	0.91605
balance scale2	0.874598	0.901929	0.8506694	0.9084	0.777
balance scale3	0.858521	0.885852	0.790849	0.882637	0.84075
breast cancer wisconsin2	0.9192	0.9412	0.81472	0.933921	0.8942
breast cancer wisconsin4	0.8458	0.8737	0.9416194	0.8458	0.9274
Ionosphere1	0.8366	0.851	0.7822	0.8395	0.8189
Ionosphere2	0.5873	0.5902	0.5	0.5873	0.6525

مطابق نتایج جدول‌های ۱ و ۲ و شکل‌های ۱۰ تا ۱۳ می‌توان این گونه نتیجه گرفت که:

- GSVDD در اغلب موارد نسبت به DSVDD برتری دارد.
- GSVDD و DSVDD در بدترین شرایط مساوی و هم‌ارز SVDD هستند.

- GSVDD با مشارکت‌دادن تمام نمونه‌های یادگیری تعمیمی

مجموعه داده‌های مختلف هستند. همچنان که در این نمودارها مشخص است، روش GSVDD در اغلب موارد نسبت به روش‌های دیگر برتری دارد. شکل‌های ۱۲ و ۱۳ بیانگر تحلیل مقاومت روش‌های مختلف بر روی تمام مجموعه داده‌ها هستند. مطابق نتیجه به دست آمده از این نمودارها روش GSVDD از لحاظ کارایی در مقام اول قرار دارد و روش‌های SVDD و DSVDD در رتبه‌های بعدی قرار دارند.

داده‌های انتخابی دارد. با بررسی و مقایسه این طبقه‌بند با طبقه‌بندهای SVDD و DSVDD نشان داده شد که طبقه‌بند پیشنهادی همیشه از یعنی دو طبقه‌بند دقت بهتری دارد و به علاوه این طبقه‌بند با مشارکت دادن همه نمونه‌ها تعمیم‌پذیری بالاتری دارد. همچنین ثابت شد GSVDD در مقایسه با SVDD حالت فراگیرتری داشته و توانایی آن در شناسایی نمونه‌های پرت در مقایسه با SVDD بیشتر است.


مراجع

- [1] B. Scholkopf, R. C. Williamson, A. J Smola, J. Shawe-Taylor, "SV estimation of a distribution's support," in *Proc. Neural Information Processing Systems*, 1999.
 - [2] D. M. J. Tax and R. P. W. Duin, "Support vector domain description," *Pattern Recognition Letters*, vol. 20, no. 11-13, pp. 1191-1199, Dec. 1999.
 - [3] K. Y. Lee, *et al.*, "Improving support vector data description using local density degree," *Pattern Recognition*, vol. 38, no. 10, pp. 1768-1771, Oct. 2005.
 - [4] D. M. J. Tax and R. P. W. Duin, "Support vector data description," *Machine Learning*, vol. 54, no. 1, pp. 45-66, 2004.
 - [5] H. W. Cho, "Data description and noise filtering based detection with its application and performance comparison," *Expert Systems with Applications*, vol. 36, no. 1, pp. 434-441, Jan. 2009.
 - [6] S. M. Guo *et al.*, "A boundary method for outlier detection based on support vector domain description," *Pattern Recognition*, vol. 42, no. 1, pp. 77-83, Jan. 2009.
 - [7] J. A. Zachman, "A framework for information systems architecture," *IBM Systems J.*, vol. 26, no. 3, pp. 276-292, 1987.
 - [8] K. Y. Lee *et al.*, "Density - induced support vector data description," *IEEE Trans. on Neural Networks*, vol. 18, no. 1, pp. 284-289, Jun. 2007.
 - [9] K. Y. Lee *et al.*, "PLPD: reliable protein localization prediction from imbalanced and overlapped dataset," *Nucleic Acids Research*, vol. 34, no. 17, pp. 4655-4666, 2006.
 - [10] X. Geng *et al.*, "Supervised nonlinear dimensionality reduction for visualization and classification," *IEEE Trans. Sys. Man Cybernet.*, vol. 35, no. 6, pp. 1098-1107, 2005.


هادی صدو^۱ و یزدی لیسانس الکترونیک خود را از دانشگاه فردوسی در سال ۱۳۷۳ و کارشناسی ارشد الکترونیک را در ۱۳۷۵ در دانشگاه تربیت مدرس اخذ کرد. دکتری مهندسی برق را در زمینه پردازش تصاویر ویدیویی در دانشگاه تربیت مدرس در سال ۱۳۸۴ به اتمام رساند. هم اکنون دانشیار گروه کامپیوتر دانشگاه فردوسی مشهد است. علاقه‌مندی او در زمینه‌های شناسایی الگو و پردازش سیگنال می‌باشد.

سیدحسین غفاریان کارشناسی کامپیوتر سخت افزار از دانشگاه صنعتی اصفهان در سال ۱۳۷۵ و در سال ۱۳۷۸ کارشناسی ارشد مهندسی نرم افزار از دانشگاه فردوسی دریافت نمود. وی هم‌اکنون عضو هیأت علمی دانشگاه فناوری‌های نوین قوچان و همچنین دانشجوی دکتری مهندسی کامپیوتر است. در دوره دکتری وی زیر نظر اقای دکتر هادی صدوqi بیزدی در زمینه‌های شناسایی الگو و یادگیری ماشین مشغول به تحقیق، مراشد.

یونس الله یاری در سال ۱۳۷۵ از دانشگاه فردوسی مشهد در رشته مهندسی نرم - افزار فارغ التحصیل شد. در سال ۱۳۸۷ در مقطع کارشناسی ارشد کامپیوتر گرایش هوش مصنوعی در دانشگاه فردوسی مشهد پذیرفته شده و در سال ۱۳۹۰ فارغ التحصیل گردید. تازمینه کار ایشان در حوزه شناسایی الگو و طبقه‌بندی مبتنی بر جاذبه و نیز طبقه‌بندی



شكل ١٢: تحليل مقاومت نهايي نتايج جدول ١.



شكل ١٣: تحليل مقاومت نهاية، نتائج جدول ٢.

بہتری دارد۔

- GSVDD در مقابل نویز یا داده‌های پرت مقاومتر است. هنگام استفاده از GSVDD، پارامتر بهینه B گاهی اوقات مقدار منفی اختیار کرده است (به اعدادی که با رنگ خاکستری در سیون چهارم جدول ۱ علامت‌گذاری شده‌اند، توجه شود). در این گونه موارد می‌توان این گونه استدلال کرد که دور کردن مرکز ابرکره از مرکز گرانش می‌تواند به بهبود عملکرد و افزایش کارایی منجر گردد. به عبارت دیگر می‌توان نتیجه گرفت که اهمیت دادن به مرکز گرانش باعث همپوشانی طبقه‌بندی داده‌های پرت خواهد شد و دور شدن مرکز ابرکره از مرکز گرانش ترجیح داده می‌شود. این ویژگی منحصر به روش GSVDD است و در مدل‌های مرتبط با روش‌های SVDD و DSVDD اثری از این خصوصیت دیده نمی‌شود.

۵- نتیجہ گیری

در این مقاله به منظور رفع نقاط ضعف طبقه‌بند SVDD، طبقه‌بندی به نام GSVDD مطرح شد. اولین نقطه ضعف SVDD، تفاوت قایل نشدن بین نمونه‌های چگال و غیر چگال است و نقطه ضعف دیگری ش تأثیرپذیری مرزهای طبقه‌بند از نمونه‌های نویزی یا پرت می‌باشد. این مشکلات باعث می‌شود که تعیین‌پذیری طبقه‌بند SVDD کاهش پیدا کند. به منظور مرتضی نمودن این مشکلات و ارتقای عملکرد این طبقه‌بند، طبقه‌بند دیگری به نام GSVDD پیشنهاد شد. در طراحی طبقه‌بند GSVDD تلاش شد ضمن ارتبردن ویژگی‌های مشتب طبقه‌بندی های DSVDD و SVDD، بر نقاط ضعف آنها غلبه شود. در روش پیشنهادی علاوه بر حداقل کردن شعاع ابرکره، کاهش فاصله بین مرکز گرانش و مرکز ابرکره نیز مد نظر قرار داده شد. آزمایش‌ها نشان دادند که این روش در مقایسه با روش‌های دیگر کارایی بیشتری دارد، اغلب مجموعه