

شناسایی امضای ایستا با استفاده از الگوریتم خوشه بندی تک کلاسی فازی

سید عبدالحمید اصفهانی^{*}^۱، محمد قاسمی گل^۲

(۱) دانشگاه آزاد اسلامی واحد قاینات، گروه کامپیوتر، قاینات، ایران

(۲) دانشجوی دکترای کامپیوتر دانشگاه فردوسی مشهد و عضو هیأت علمی دانشگاه بیرجند

چکیده:

امضاء یکی از اساسی‌ترین ارکان دنیای مجازی می‌باشد. از این رو ابداع روش‌های جهت تشخیص نمونه‌های جعلی امضاء همواره مورد توجه محققین بوده است. در میان روش‌های مختلف موجود، دسته‌بندهای تک‌کلاسی به دلیل دقت بالا به عنوان گزینه مناسبی در حل مسئله تشخیص امضاء مطرح می‌شوند. اما یکی از معضلات موجود در این روش‌ها، حضور نمونه‌های پرت در داده‌های آموزش است. در روش پیشنهادی FCSVDD نشان می‌دهیم با فازی نمودن قیود موجود در روش SVDD استاندارد می‌توان این مشکل مطرح شده را نیز برطرف نمود. برای بررسی این مسئله ابتدا ویژگی‌های مناسبی از نمونه‌های نرمال امضای استخراج شده و جهت تعلمی به دسته‌بندهای تک‌کلاسی (SVDD، FCSVDD) ارائه شده است. مزیت اصلی این روش‌ها عدم نیاز به نمونه‌های جعلی امضای در فرآیند آموزش است. هر دو الگوریتم تمام امضاهای جعلی را بدستی شناسایی می‌کنند. در الگوریتم SVDD امضاهای با دقت ۹۵ درصد دسته‌بندی شده است. الگوریتم FCSVDD در مقایسه با الگوریتم SVDD میانگین دقت الگوریتم (CA) ۲.۴ درصد را افزایش می‌دهد.

واژه‌های کلیدی:

دسته‌بندهای یک کلاسی، تشخیص امضاء، توصیف داده‌های بردار پشتیبان (SVDD)، توصیف داده‌های بردار پشتیبان فازی (FCSVDD)، استخراج ویژگی

۱- مقدمه

امضای روشی پذیرفته شده و رسمی برای بررسی صحت(تأیید) شخص است، به همین دلیل در دولت، معاملات حقوقی و تجاری استفاده می‌شوند و پذیرفته شده ترین روش تأیید هویت است. یکی از معایب جانبی واجتناب ناپذیر امضاهای این است که می‌توان آن را به منظور جعل اصل

^۱ On-line

^۲ Off-line

* عهده‌دار مکاتبات

دانشگاه آزاد اسلامی واحد قاینات، گروه کامپیوتر، قاینات، ایران

پست الکترونیکی: sfahani@iauq.ir

یک الگوریتم شناسایی باید بتواند نمونه های درست را تایید کرده و نمونه های اشتباه را رد کند. در مسئله شناسایی امضا جلوگیری از امضاهای جعلی اهمیت بیشتری دارد بدین منظور با تغییر پارامترهای هسته SVDD می‌توان تا حد زیادی امضاهای درست را شناسایی کرد و جلوی هرگونه جعل امضا را گرفت.

هر چند این روش نمونه های جعلی را بدرستی شناسایی می-کند ولی بدلیل اینکه در روش SVDD تنها از نمونه های نرمال جهت آموزش سیستم استفاده می‌شود، امکان حضور نمونه های پرت در داده های آموزش وجود دارد. با توجه به ساختار مجموعه داده های امضاء امکان حضور داده های پرت بیشتر است. حضور این چنین نمونه هایی در داده های آموزش، گاهًا منجر به تشکیل مرزهای نادرستی در اطراف نمونه های پرت می‌شود. در روش پیشنهادی FCSVDD نشان دادیم با فازی نمودن قیود موجود در روش SVDD استاندارد می‌توان این مشکل مطرح شده را نیز برطرف نمود

در بخش ۳ و ۴ پیش پردازش و استخراج ویژگی امضاء را مرور می کنیم در بخش ۵ الگوریتم SVDD و FSVDD را بررسی می کنیم و در بخش ۶ پیاده سازی الگوریتم بیان می شود و در بخش ۷ نتایج تجربی بررسی می شود و در آخر نتیجه گیری را بیان خواهیم کرد.

مروری بر کارهای انجام شده

در مورد شناسایی و بررسی هویت امضا کارهای زیادی انجام شده است که در این بخش به اختصار به چند مورد اشاره می کنیم.

خانم مینکاشی و کاوا از شبکه های عصبی با سرپرستی و بدون سرپرستی استفاده کرده اند. در روش با سرپرستی دقت الگوریتم ۹۶٪ است در صورتیکه در روش بدون سرپرستی ۵٪ است.^[3]

آقای مارتین و همکارانش یک روش با استفاده از الگوریتم

پویا بوسیله صفحات و قلم های الکترونیکی امضاء ها را بدست می آوریم ولی در روش ایستا با عکسبرداری از امضاء و یا اسکن کردن امضاء بدست می آید. امضاء پویا اطلاعات اضافه تری همچون شتاب قلم، نحوه حرکت قلم، فشار قلم و ... نسبت به امضاء ایستا دارد. در تشخیص امضاء پویا روش های مختلفی همچون شبکه های عصبی مدل مخفی مارکوف، فاصله اقلیدسی ... به کار می رود^[1] که از روش های فوق مدل مخفی مارکوف قدرت و توانایی بیشتری نسبت به بقیه روش ها دارد. عیب اصلی مدل امضاهای پویا محدودیت هایی است که در جمع آوری داده ها دارد به علاوه هزینه جمع آوری داده نسبت به روش ایستا بیشتر است.

در الگوریتم های تشخیص امضاء دو مسئله اساسی مورد بررسی قرار می گیرد دسته بندي^۱ و شناسایی^۲ [در دسته-بندي مالکیت امضاء مورد بررسی قرار می گیرد ولی در شناسایی علاوه بر مالکیت جعلی بودن امضاء را نیز مورد بررسی قرار می دهیم در دسته بندي یک امضا با توجه به ویژگی های آن به یک طبقه (شخص) نسبت داده می شود ولی در شناسایی امضا درستی و یا جعلی بودن امضا یک امضا بررسی می شود در واقع ما یک مجموعه امضاء را مورد بررسی قرار می دهیم علاوه بر مجموعه داده اصلی یک سری اضاء های تقلیلی برای هر نمونه امضاء را نیز مورد بررسی می کنیم. در این الگوریتم ها اغلب از یک دسته بندي تک کلاسی استفاده می شود.

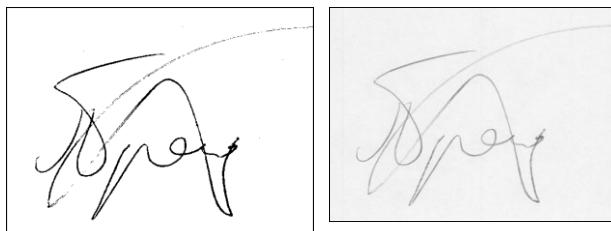
امضاهای جعلی به سه دسته تقسیم می شوند. امضا جعلی تصادفی، ساده و ماهر. امضا جعلی تصادفی هنگامی است که شخصی که جعل می کند نام و شکل امضا فرد را نمی داند. جعل ساده جعلی است که جاعل نام و شکل امضا را می بیند ولی هیچ سعی و تمرینی در جعل امضا نمی کند. جعل ماهرانه جعلی است که جاعل امضای شخص امضا کننده را تمرین می کند و امضای نزدیک به امضا واقعی او می کشد.

^۱ Recognition

^۲ Verification

نمایش داده به فرم باینری

روش های زیادی برای دودویی کردن تصویر وجود دارد مانند روش اوتسو، نیبلک، آستانه تکراری و غیره. ساده ترین روش دودویی سازی، روش سراسری است که با استفاده از یک آستانه ثابت که به صورت دستی انتخاب می شود، عمل می کند. هر پیکسل با توجه به مقدار خود تبدیل به سیاه یا سفید می شود پیکسل های سیاه امضاء را تشکیل می دهد و پیکسل های سفید زمینه را تشکیل می دهند. در تصویر دودویی شده پیچیدگی محاسبات و استخراج ویژگی های تصویر و همچنین مقدار پیکسل کاهش می یابد.



شكل ۱: امضای اصلی و دودویی

حذف نویز

اغلب هنگامی که یک امضا دوتایی شده است، نویز حاصل از فرآیند به جا خواهد ماند. حذف این نویز به گسترش ویژگی های تصویر کمک می کند و منجر به ارائه دقیق امضا می شود. حذف نویز با استفاده از چندین روش صورت می گیرد در این مقاله از روش واسطه استفاده شده است.

نرمال کردن جهت چرخش

وقتی یک امضا دریافت شد، جهت آن ممکن است همگام با امضاهای مشابه نباشد. این چرخش نادرست توانایی تخریب کردن تمامی ویژگی ها را دارد و می تواند بر طبقه بنده تاثیرگذار باشد. نرمال کردن چرخش با استفاده از دو روش محور اینرسی حداقل و چرخش ناحیه انجام می شود.

SVM جهت شناسایی امضا ارائه داده است و این روش را با الگوریتم MLP مقایسه کرده است دقت الگوریتم SVM برای ورودی کل تصویر ۶۶.۵٪ و برای ورودی ویژگی های سراسری ۷۱.۲٪ است در صورتیکه الگوریتم MLP برای ورودی کل تصویر ۴۶.۸٪ و برای ورودی ویژگی های سراسری تصویر ۴۵.۲٪ است [4].

آقای سیگاری با همکارانش در مقاله خود از روش موجک Gabor برای شناسایی امضا استفاده کرده است و توانسته است با دقت ۱۰۰٪ شناسایی کند. [5]

محمدی در پایان نامه خود سیستمی ارایه کرده است که بر اساس آنالیز اجزای اصلی PCA عمل می کند. در این پایان نامه از PCA برای استخراج ویژگی و کاهش ابعاد داده های ورودی به شبکه عصبی استفاده شده است. دقت این سیستم ۹۱.۵٪ گزارش شده است. [6]

سید زاده در مقاله خود مسئله تأیید امضای ایستا بر پایه یک الگوریتم ردیابی مبتنی بر قوانین مکافهه ای مورد توجه قرار داده است. نتایج آزمایش ها با استفاده از امضاهای جعلی ماهرانه و در حالت درجه تفکیک میانی، با به کارگیری تمام ویژگی ها، نرخ خطای رد نادرست امضاهای اصلی را ۹.۵٪ نرخ خطای پذیرش نادرست امضاهای جعلی را ۱۱/۸٪ نشان می دهد [7].

پیش پردازش امضاء

هنگامی که یک امضا روی کاغذ نوشته می شود تبدیل به یک تصویر دیجیتالی می شود. اگر بلاfaciale بعد از گرفتن امضاء ویژگی های آن را استخراج کنیم ممکن است این کار باعث تحریف امضاء گردد یا به عبارتی ویژگی های تصویر سوء تعبیر شود که این مسئله می تواند بر قابلیت طبقه بنده تأثیر منفی زیادی بگذارد. بدین منظور ابتدا تصویر امضاء با استفاده از الگوریتم هایی نرمال شده و سپس ویژگی های آن استخراج می شود. پیش پردازش تصویر در چند مرحله انجام می شود که به اختصار مراحل آن را بیان می کنیم

بدست می آید

ستون و سطر ماکزیم : شماره ستون و سطربی که بیشترین پیکسل سیاه را دارند می توانند به عنوان دو ویژگی مهم امضاء استفاده شوند

مرکز عمودی و مرکز افقی امضاء : که با رابطه ۱ و ۲ محاسبه می شوند

$$\bar{x} = \frac{1}{n} \sum_{i=1}^n u_i \quad (1)$$

$$\bar{y} = \frac{1}{n} \sum_{i=1}^n v_i \quad (2)$$

در روابط بالا در متغیر n تعداد کل پیکسل های امضاء را در بر می گیرد و متغیرهای u و v مقدار مکانی x و y هر یک از پیکسل های امضاء می باشند.

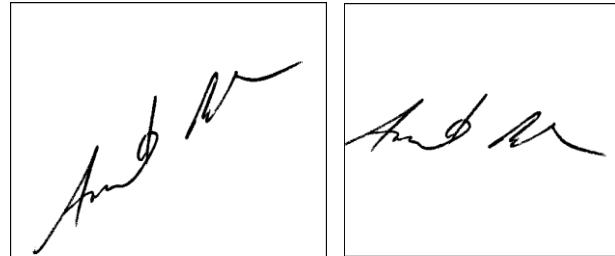
تعداد ماکزیم محلی سطربی و ستونی : اگر تعداد پیکسل های سیاه سطربها امضاء را در یک آرایه قرار دهیم تعداد ماکزیم های محلی این آرایه می تواند به عنوان یک ویژگی تصویر استفاده کرد همین کار را می توان برای ستون های تصویر امضاء بکار برد.

ویژگی های منطقه ای

با استخراج ویژگی های عمومی از یک امضاء قسمتی از اطلاعات فضایی مربوط به آن از بین می رود و اغلب ویژگی فرکانس آن حفظ می شود. این مسئله ممکن است باعث شود دو امضایی که دارای ظواهر متفاوتی هستند ویژگی های عمومی مشابه ای تولید کنند.

یک روش برای حل این مشکل استفاده از نمونه برداری منطقه ای می باشد که اطلاعات فضایی ویژگی های استخراج شده را با شکستن تصویر به مناطق ارائه می دهد.

یکی از رایج ترین و ساده ترین ویژگی های منطقه ای شبکه یکپارچه است یک شبکه یکپارچه مناطق مستطیل شکلی را برای نمونه برداری زمانی که تمام مناطق یک شکل و یک



الف- امضای چرخیده شده ب- امضای نیازمند به چرخش

شکل ۲ : تاثیر چرخش منطقه با استفاده از امضای پایه

استخراج ویژگی

هنگام طبقه بندي یک تصویر، یکی از نیازهای کلیدی استخراج ویژگی هایی است که معروف آن هستند. این اطلاعات به تصویر امضاء اجازه می دهد تا به اجزاء خود شکسته شود که این اجزاء برای توضیح ساختار آن مفیدتر هستند و هنگام مقایسه آن با امضاهای دیگر آن را متفاوت می سازند. هر چه ویژگی های استخراج شده بتوانند تمايز بیشتری ایجاد کنند قدرت و دقت طبقه بندي و شناسایی امضاء بیشتر می شود این بخش به ارائه ویژگی های متفاوت گوناگونی که قابل استخراج است و هر کدام ویژگی ساختاری متفاوتی از امسا را ارائه می دهد، می پردازد.

ویژگی هایی که از یک امضاء می توان استخراج کرد به دو گروه کلی تقسیم می شوندو ویژگی های عمومی و ویژگی های منطقه ای [8]

ویژگی های عمومی

این ویژگی ها شامل موارد کلی از تصویر امضاء می شود موارد زیر ویژگی های عمومی هستند که از یک نمونه امضاء استخراج می شود [8,9]:

چگالی امضاء : چگالی امضاء از تقسیم تعداد پیکسل های سیاه بر تعداد کل پیکسل های تصویر بدست می آید
پهنه ای امضاء : از تقسیم طول امضاء بر عرض آن ژهناهی امضاء

طرف دیگر فاصله‌های بزرگ‌تر هم باید جریمه شوند. بنابراین در اینجا یک متغیر لغزش معرفی می‌شود و مسأله کوچک سازی تبدیل می‌شود به:

$$\|x\| = \sqrt{x^2 + \sum_{i=1}^n x_i^2}, \quad (5)$$

با این قید که تقریباً تمام داده‌ها درون کره هستند.

$$\|\sum_{i=1}^n x_i - x\|^2 \leq \sum_{i=1}^n x_i^2 + \sum_{i=1}^n x_i, \quad \forall x. \quad (6)$$

همان متغیر لغزش است که اجازه می‌دهد برخی نمونه‌ها خارج از کره قرار بگیرند. پارامتر C نیز نسبت میان حجم کره و میزان خطای را کنترل می‌کند. در اینجا قید شماره (6) می‌تواند در معادله (5) با استفاده از ضرایب لاغرانژ بکار گرفته شود. در این صورت تابع زیر با ضرایب لاغرانژ $\alpha_i \geq 0$ داشت:

$$\begin{aligned} \sum_{i=1}^n \alpha_i (\sum_{j=1}^n x_i \cdot x_j - \sum_{j=1}^n x_j^2) &= \sum_{i=1}^n \alpha_i x_i^2 + \sum_{i=1}^n \alpha_i \sum_{j=1}^n x_i \cdot x_j \\ &- \sum_{i=1}^n \alpha_i \{x_i^2 + \sum_{j=1}^n x_j - (\sum_{j=1}^n x_j^2 - 2 \sum_{j=1}^n x_j + \sum_{j=1}^n x_j^2)\} \end{aligned} \quad (7)$$

با قرار دادن مشتقات جزیی تابع L برابر صفر، قیدهای زیر بدست می‌آید.

(8)

(9)

(10)

با جایگزینی معادلات بالا در تابع L ، معادله زیر نتیجه می‌شود.

(11)

(11)

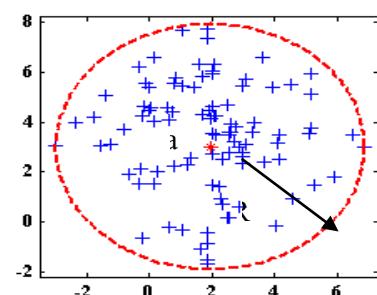
اندازه باشند، ایجاد می‌کند.

برای بدست آوردن ویژگی‌های شبکه‌ای امضاء ابتدا امضاء را به (6) قسمت مستطیلی تقسیم می‌کنیم سپس بر اساس مجموع سطوح خاکستری پیکسل‌های هر قسمت ویژگی آن بخش استخراج می‌شود

الگوریتم طبقه‌بندی تک کلاسی

SVDD

سال ۲۰۰۴ توسط آقایان Tax و Duin روش جدیدی برای توصیف داده‌ها، با الهام از ماشین‌های بردار پشتیبان ارائه شد [10] [11] [12]. به همین جهت نام این روش را Support Vector Data Description (SVDD) نهادند. در این روش محدوده‌ای به شکل کروی در اطراف مجموعه هدف بدست می‌آید. همان‌طور که در شکل ۳ نشان داده شده است، این کره بهوسیله مرکز a و شعاع R مشخص می‌شود.



محدود شده‌اند. a و مرکز R شکل ۳: داده‌های هدف توسط یک کره با شعاع

در این الگوریتم سعی بر آن است که حجم این کره مینیمم شود. بنابراین تابع خطایی که توسط آن‌ها معرفی شد به شکل زیر است که بایستی با توجه به قید مطرح شده کوچک سازی شود.

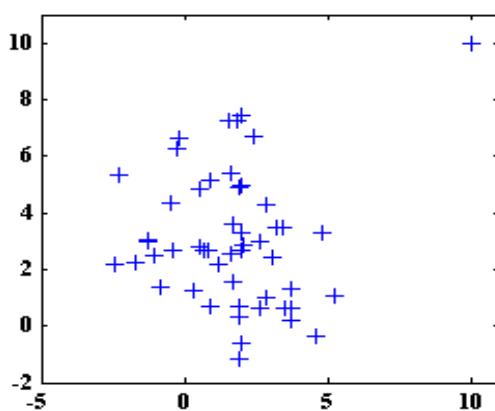
$$\|x - a\|^2, \quad (3)$$

$$x \cdot x - \|x\|^2 \leq R^2, \quad \forall x \quad (4)$$

با احتمال وجود داده‌های پرت در مجموعه آموزش، فاصله داده x_i تا مرکز a حتماً باید کوچک‌تر از R^2 باشد. اما از

در این بخش دیدگاه جدیدی را در زمینه توصیف داده‌های یک کلاس مطرح می‌کنیم. همان‌طور که اشاره شد دسته‌بندهای یک کلاسی برای توصیف داده‌های یک کلاس تنها به نمونه‌های همان کلاس جهت استفاده در مرحله آموزش نیازمند هستند. حال چنانچه در فرایند آموزش تعدادی نمونه پرت در میان نمونه‌های هدف حضور داشته باشد موجب بروز مشکلاتی در مشخص نمودن مرزهای کلاس هدف و سطوح تصمیم‌گیری بدست آمده خواهد شد.

روش SVDD از مکانیزم شناخته شده‌ای جهت کاهش تاثیر حضور نمونه‌های پرت در نمونه‌های آموزش استفاده می‌کند. همان‌طور که در روابط ۵ و ۶ بخش قبل برای روش SVDD نشان داده شد، در این روش با استفاده از متغیر لغزش و ضریب پنالتی سعی شده تاثیر نمونه‌های پرت حداقل شود. در این بخش ابتدا ناکارامدی این ضرایب را در حوزه کرنل نشان خواهیم داد. سپس روش پیشنهادی برای حل این مشکل را به دقت بررسی می‌کنیم. شکل ۴ یک مجموعه داده‌ای دو بعدی را که شامل یک نمونه پرت در مجموعه هدف است نشان می‌دهد. چنانچه در این مجموعه داده‌ای بخواهیم توصیف دقیقی برای نمونه‌های کلاس هدف داشته باشیم با استنی تاثیر نمونه پرت را در فرایند آموزش حذف کنیم.



شکل ۴ مجموعه داده‌ای دو بعدی شامل یک نمونه پرت در میان نمونه‌های هدف.

در اینجا با استفاده از روش SVDD می‌خواهیم مرزهای کلاس هدف را در مجموعه داده‌ای مذکور تعیین کنیم. طبق این روش ابتدا محدوده‌ای کروی شکل به دور نمونه‌های

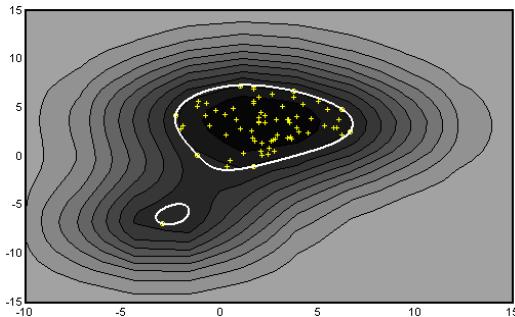
)
(۱۲) کمینه کردن این تابع خطاباً قید مطرح شده یک مسئله آشنا است که به برنامه‌ریزی غیر خطی معروف است. چنانچه \Box نمونه‌ای از داده‌های روی مرز باشد، شعاع کره را می‌توان به شکل زیر محاسبه نمود.

)
(۱۳) در همه فرمول‌های ارائه شده \Box ‌ها به صورت ضرب داخلی هستند. و مشابه [11] این ضرب داخلی می‌تواند به وسیله یک تابع کرنل جایگزین شود تا روش‌های قابل انعطاف پیشتری بدست آید. در این میان با توجه به آزمایشات صورت گرفته کرنل گوسی نتایج بهتری را به همراه خواهد داشت. با استفاده از تکنیکی که به حقه کرنل^۱ معروف است، می‌توان به راحتی و بدون تحمیل محاسبات اضافه نتایج دقیق‌تری را برای روش SVDD در حوزه کرنل بدست آورد. البته تعیین مقدار مناسب برای پارامتر S یکی از موارد تاثیرگذار در نتایج نهایی است.

(FCSVDD) با قیدهای فازی

یکی از مشکلات عمدۀ روش SVDD عدم تلاش برای توصیف دقیق‌تر داده‌ها در فضای ورودی است. طراحان این روش با تبدیل فضا و استفاده از حوزه کرنل سعی کردند این مشکل را برطرف نمایند. اما این راه کار خود مشکل دیگری را ایجاد می‌کند. در هنگام استفاده از کرنل، تعیین پارامترهای انتخابی کاربر معصل جدیدی است که چاره‌ای جز روش‌های سعی و خطأ ندارد. در راستای حل مشکلات بیان شده با استفاده منطق فازی راه کار جدیدی ارائه کردۀ ایم که در این قسمت به بیان آن می‌پردازیم.

Kernel trick^۱



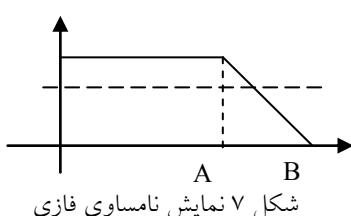
شکل ۶ توصیف داده‌ها به روش SVDD با بکارگیری کرنل گوسی.
بنابراین ضرایب لغزش و ضریب پنالتی نمی‌توانند در حوزه کرنل مؤثر باشند. زیرا توسط آن‌ها هیچ اهمیتی برای نمونه‌ها لحاظ نمی‌شود. در این‌جا برای حل این مشکل بر روی قیدهای مسئله بیشتر متمرکز می‌شویم. هدف ما بدست آوردن روشی است که توسط آن بتوان به صورت صریح اهمیت هر نمونه در تعیین مرزهای تصمیم‌گیری را مشخص نمود. به طورکلی در روش SVDD با قیدهای زیر مواجه هستیم.

$$\|x_i - a\|^2 \leq R^2 + \xi_i, \quad \forall i. \quad (14)$$

حال چنانچه این قیدها را به صورت فازی در نظر بگیریم انعطاف بیشتری در آن‌ها ایجاد خواهد شد. یعنی بجای استفاده از این قیود آن‌ها را به صورت زیر در نظر بگیریم

$$\|x_i - a\|^2 \lesssim R^2 + \xi_i, \quad \forall i. \quad (15)$$

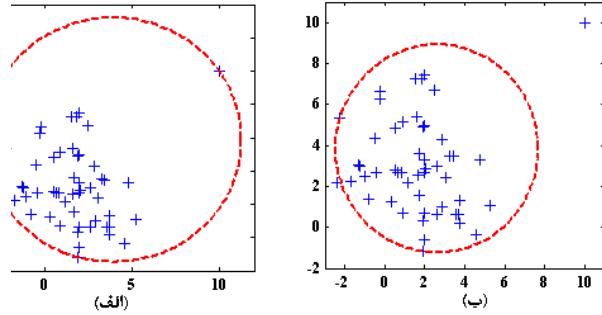
با این کار اجازه تخطی به برخی از قیود داده می‌شود. در حالت کلی هر نامساوی فازی را می‌توان براحتی به صورت یک نامساوی معمولی تبدیل نمود. فرض کنید A نسبت به B کمتر مساوی فازی باشد ($B \lessdot A$). این نامساوی فازی را می‌توان به صورت زیر نمایش داد.



شکل ۷ نمایش نامساوی فازی

بر اساس این تعریف تابع عضویت زیر را خواهیم داشت:

آموزش ایجاد می‌کنیم. با توجه به روابط ۵ و ۶ این محدوده باید به شکلی باشد که از یک سو به اندازه کافی کوچک باشد و از سوی دیگر تقریباً تمام نمونه‌های آموزش در درون آن قرار گیرند. به عبارت دیگر در این‌جا با استفاده از ضرایب لغزشی که برای هر نمونه تعیین می‌شود، به برخی نمونه‌ها اجازه عبور از این محدوده کروی شکل داده می‌شود. همچنین برای جلوگیری از کوچک شدن بیش از اندازه محدوده کروی، ضریبی تحت عنوان ضریب پنالتی توسط کاربر تعیین می‌گردد. شکل ۵ تفاوت بین استفاده و عدم استفاده از این ضرایب را در توصیف مجموعه داده‌ای مذکور در فضای ورودی نشان می‌دهد.



شکل ۵ طریقه رفتار روش SVDD برای توصیف داده‌ها در فضای ورودی. (الف) بدون استفاده از ضرایب لغزش و ضریب پنالتی. (ب) با استفاده از ضرایب لغزش و ضریب پنالتی.

اما این ضرایب در هنگام توصیف داده‌ها در حوزه کرنل تاثیر چندانی ندارند. چنانچه بیان شد در روش SVDD یافتن نتایج دقیق‌تر مستلزم بکارگیری کرنل گوسی است. شکل ۶ رفتار روش SVDD را نسبت به مجموعه داده‌ای مذکور در حوزه کرنل نشان می‌دهد. همان‌طور که ملاحظه می‌کنید نمونه پرت در تعیین مرزهای جداکننده تاثیرگذار بوده و سطح تصمیم‌گیری را به سمت خودش متمایل می‌کند. مقدار پارامتر کرنل (S) تیز تاثیری بر روی مشکل موجود ندارد.

در اینجا با دو مفهوم جدید یعنی x_i و a مواجه می‌شویم. با دقت در نامساوی (۲۱) ملاحظه می‌کنید که نقش x_i که توسط سیستم تعیین می‌شود کاملاً با مقدار ثابتی که به سمت راست نامساوی اضافه شده متفاوت است. مفهوم نامساوی (۲۱) این است که فاصله هر نمونه تا مرکز کمتر مساوی شعاع کره بعلاوه یک مقدار ثابت است. هر چه این مقدار ثابت بزرگ‌تر باشد موجب می‌شود قید (۲۱) با شعاع به مراتب کوچک‌تری ارضا شود و شعاع محدوده کروی کوچک‌تر شود. از این‌رو باقیتی برای نمونه‌هایی که اهمیت بیشتری نسبت به بقیه دارند، $(1 - \alpha)d_i$ مقدار بزرگ‌تری باشد.

اما از آنجایی که میزان α برای همه نمونه‌ها ثابت فرض می‌شود می‌توان برای هر نمونه x_i مناسبی در نظر گرفت. به عبارت دیگر باقیتی برای نمونه‌هایی که در هسته یک دسته قرار دارند، d_i بزرگ‌تری در نظر بگیریم که این امر موجب می‌شود این نمونه‌ها در تعیین شعاع محدوده کروی مؤثرتر از سایر نمونه‌ها باشند. برای نمونه‌های پرت نیز مقدار d_i را کوچک در نظر می‌گیریم.

شاید در نگاه اول تصور کنید مقادیر کوچک d_i برای نمونه‌های پرت باعث بزرگ‌تر شدن شعاع می‌شود. اما این تصور درست نیست چراکه در تعیین شعاع مناسب همه قیود به طور هم‌زمان تاثیر دارند. حال که تعداد زیادی از قیود رأی به کوچک‌تر شدن شعاع داده‌اند، نمونه‌های پرت نمی‌توانند اندازه شعاع را افزایش دهند بلکه با افزایش یافتن مقدار ξ_i برای این نمونه‌ها می‌توانند به روند کوچک ماندن شعاع کمک کنند.

برای این‌که این موضوع بیشتر روشن شود در اینجا یک مجموعه داده‌ای مصنوعی دوبعدی ایجاد می‌کنیم. در این مجموعه داده‌ای دو نمونه پرت نیز وارد شده‌اند که ویژگی‌های کاملاً متفاوتی نسبت به سایر نمونه‌ها دارند.

در شکل ۹ مجموعه داده‌ای ایجاد شده را ملاحظه می‌کنید.

$$\mu = \begin{cases} 1, & \text{if } A \leq B \\ \frac{-A + B + d}{d}, & \text{if } B < A < B + d \\ 0, & \text{if } A \geq B + d \end{cases} \quad (16)$$

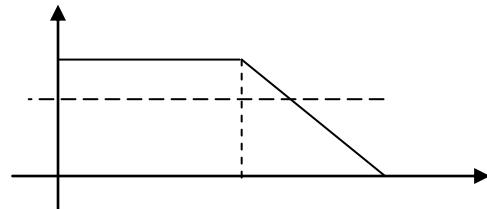
حال با در نظر گرفتن α برش^۱ در این تابع عضویت داریم:

$$\mu \geq \alpha \Rightarrow \frac{-A + B + d}{d} \geq \alpha \quad (17)$$

از این‌رو بین A و B همواره رابطه زیر برقرار خواهد بود.

$$A \leq B + d(1 - \alpha) \quad (18)$$

بنابراین به راحتی توانستیم یک نامساوی فازی را به صورت یک نامساوی معمولی تبدیل نماییم. بر این اساس رابطه (۱۸) را نیز می‌توانیم به صورت یک نامساوی معمولی تبدیل کرد. نمایش این نامساوی فازی به شکل زیر است.



شکل ۸: نمایش نامساوی فازی رابطه (۲-۵).

تابع عضویت مربوط به این نامساوی فازی به صورت زیر تعریف می‌شود.

(۱۹)

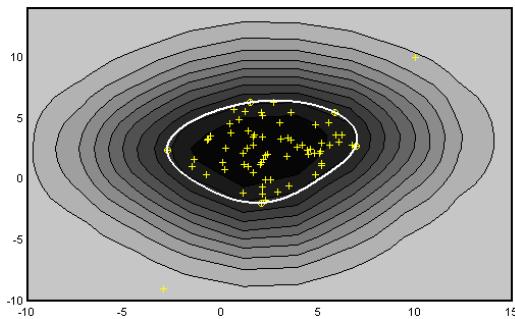
$$\mu(a, R, \xi_i) = \begin{cases} 1, & -\|x_i - a\|^2 + \\ & \frac{R^2 + \xi_i}{d} \geq \alpha \\ 0, & \text{otherwise} \end{cases}$$

در این‌جا نیز با استفاده از α برش داریم:

$$\mu(a, R, \xi_i) \geq \alpha \Rightarrow \frac{-\|x_i - a\|^2 + (R^2 + \xi_i) + d_i}{d_i} \geq \alpha \quad (20)$$

بنابراین نامساوی فازی (۲۳) را می‌توان به صورت نامساوی معمولی زیر تبدیل نمود.

$$\|x_i - a\|^2 \leq (R^2 + \xi_i) + d_i(1 - \alpha) \quad (21)$$

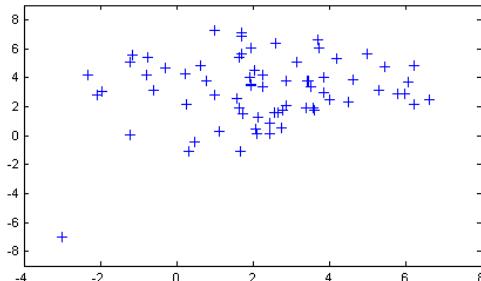


شکل ۱۱ سطوح تصمیم بدست آمده توسط روش FCSVDD جهت توصیف مجموعه دادهای ایجاد شده.

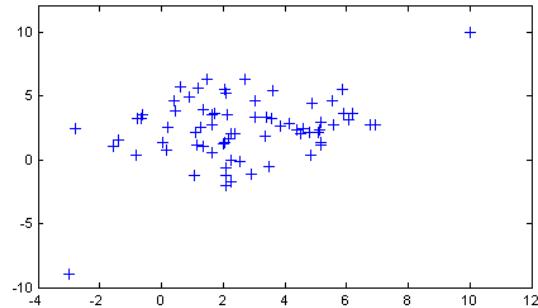
بنابراین مقدار d_i به اهمیت نمونه‌ها اشاره دارد و می‌توان آن را به وزن نمونه‌ها نیز تعبیر کرد. هر چه وزن نمونه بیشتر باشد نشان دهنده این است که اهمیت نمونه در توصیف مجموعه دادهای و تعیین سطوح تصمیم‌گیری بیشتر است. با دقت در رابطه (۲۱) ملاحظه می‌کنید که d_i برای هر نمونه در مقدار ثابت $(I - \alpha)$ ضرب می‌شود. دامنه تغییرات α بین صفر و یک است. افزایش مقدار α باعث کاهش تاثیر d_i و کاهش مقدار α موجب افزایش توجه به اهمیت نمونه‌ها خواهد شد. از این‌رو پارامتر α را به عنوان معیاری برای عدم قطعیت^۱ در نظر می‌گیریم. بنابراین با کمک این پارامتر می‌توان میزان اطمینان نسبت به وزن تعیین شده برای هر نمونه را مشخص کرد.

برای آشنایی بیشتر با عملکرد پارامتر α در اینجا یک مجموعه داده‌ای دیگر را تنها با یک نمونه پرت ایجاد می‌کنیم.

شکل ۱۲ موجود در این مجموعه داده‌ای را نشان می‌دهد.

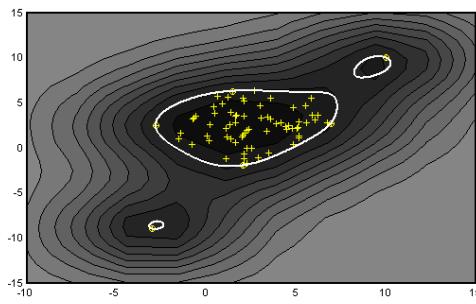


شکل ۱۲ یک مجموعه داده شامل یک نمونه پرت.



شکل ۹ مجموعه دادهای مصنوعی شامل دو نمونه پرت.

چنانچه با استفاده از روش SVDD استاندارد توصیفی از این مجموعه دادهای ایجاد کنیم، سطوح تصمیم مناسبی بدست نخواهد آمد. به عبارت دیگر این روش قادر به تحمل حضور نمونه‌های پرت در فرایند آموزش نیست.



شکل ۱۰ سطوح تصمیم بدست آمده توسط روش SVDD جهت توصیف مجموعه دادهای ایجاد شده.

همان‌طور که در شکل ۱۰ ملاحظه می‌کنید روش SVDD به اشتباه فضایی را در اطراف این نمونه‌های پرت به عنوان کلاس هدف در نظر می‌گیرد. حال با استفاده از روش FCSVDD توصیفی از مجموعه دادهای مذکور ارائه می‌دهیم. برای این منظور ابتدا با استی مقادیر d_i یا به عبارتی اهمیت نمونه‌ها را مشخص کنیم. چنانچه برای نمونه‌های پرت مقدار d_i را نصف مقدار d_i مربوط به سایر نمونه‌ها در نظر بگیریم و میزان پارامتر α را نیز برابر 0.5° فرض کنیم آنگاه شکل ۱۱ حاصل خواهد شد.

¹ uncertainty

برای بررسی تاثیر پارامتر α ، روش پیشنهادی را با استفاده از α های مختلف بر روی مجموعه دادهای مذکور تکرار می-کنیم. نتایج این آزمایشات در نمایش داده شده است. در تمامی این تکرارها مقادیر d_i یکسان و برای نمونه‌های پرت نصف سایر نمونه‌ها در نظر گرفته شده است.

Error! Reference source not همان‌طور که در شکل

۱۴^{found.} نیز مشاهده می‌کنید افزایش مقدار α منجر به بروز نتایجی شبیه روش SVDD می‌شود. از سوی دیگر با توجه به رابطه (۲۷) واضح است در صورتی که d_i را برابر همه نمونه‌ها مقدار ثابتی در نظر بگیریم و یا میزان α برابر یک باشد، نتایج بدست آمده از دو روش کاملاً یکسان خواهد بود.

اما یکی از مسائل مهمی که در اینجا باید به آن توجه کرد، تعیین مقادیر مناسب برای d_i ها است. به عبارت دیگر در هنگامی که اهمیت نمونه‌های آموزش برای کاربر مشخص نیست باستی مکانیزمی جهت تعیین خودکار مقادیر d_i اتخاذ نمود. یکی از ساده‌ترین روش‌هایی که می‌توان برای این منظور در روش SVDD بکار گرفت، استفاده از معکوس فاصله هر نمونه تا مرکز کلاس است. بر این اساس هرچه فاصله نمونه از مرکز کلاس بیشتر باشد d_i مربوط به آن کوچک‌تر خواهد شد و بالعکس.

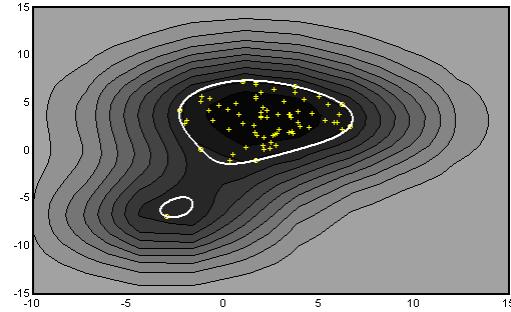
پیاده سازی

مجموعه داده ها

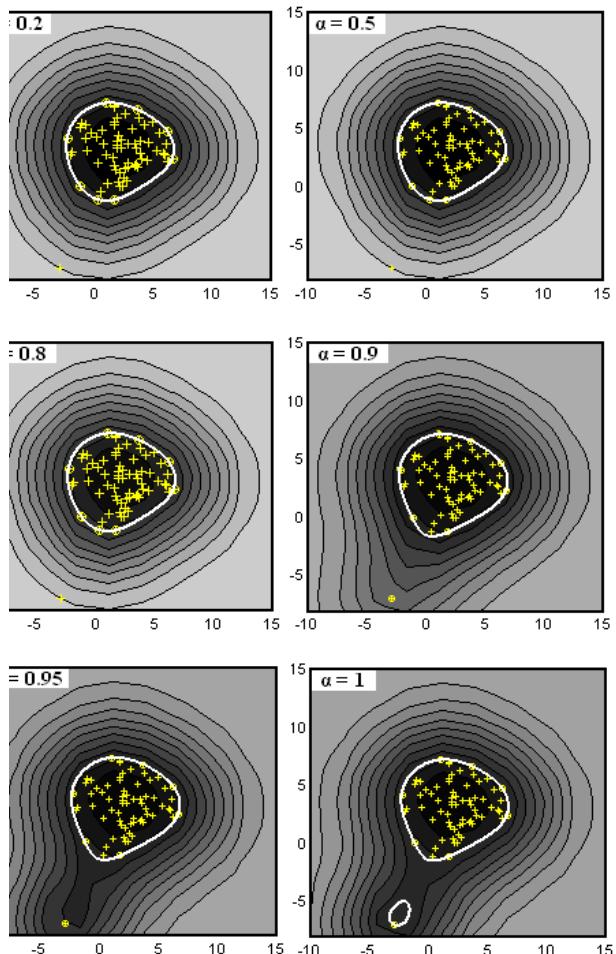
این مجموعه داده از امضا شامل ۲۰ کلاس (فرد) مختلف است. در هر کلاس ۲۰ امضا اصلی و ۱۰ امضا جعلی وجود دارد. ۲۰ امضا جعلی برای هر کلاس به دو دسته تایی تقسیم می‌شود.^[5,15]

از ۱۰ امضا جعلی، ۴ امضا جعلی ابتدا جعل ساده و ۶ امضا دیگر به شکل ماهراهه جعل گشته است.

در هنگام استفاده از روش SVDD همانند مثال پیشین سطوح تصمیم مناسبی بدست نخواهد آمد. نتایج حاصل از اجرای این روش در نمایش داده شده است. وجود این نمونه پرت در داده‌های آموزش موجب بروز اختلال در تشکیل مرزهای کلاس هدف شده است.



شکل ۱۳ اجرای روش SVDD بر روی یک مجموعه داده با یک نمونه پرت.



شکل ۱۴ اجرای روش FCSVDD بر روی یک مجموعه داده شامل یک نمونه پرت با مقادیر مختلف برای پارامتر α .

معیارهای ارزیابی

شده به کار می‌رود.

$$CA = \frac{TP - FP}{TP + FP + FN + TN} * 100 \quad (24)$$

معیار ارزیابی^۵ CA نیز بیانگر دقیقت الگوریتم پیاده‌سازی شده در دسته‌بندی داده‌ها است.

$$CA = \frac{TP + TN}{TP + TN + FN + FP} * 100 \quad (25)$$

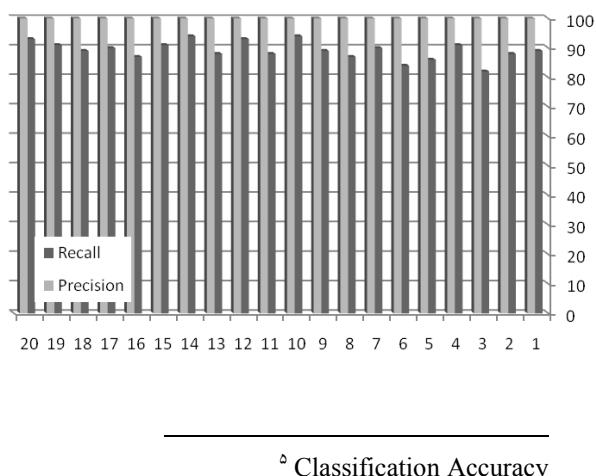
نتایج تجربی

SVDD

در هر آزمایش به صورت تصادفی ۱۰ نمونه از امضاهای اصلی هر کلاس برای آموزش و ۱۰ نمونه دیگر از امضاهای اصلی و ۱۰ نمونه امضای جعلی برای تست به دسته بند یک کلاسی SVDD ارائه شده است. در جدول زیر نتایج را برای ۱۰۰ مرتبه تکرار الگوریتم مشاهده می‌کنید.

جدول ۱ : نتایج الگوریتم SVDD برای ۱۰۰ مرتبه تکرار

T N	T P	F P	F N	P re	Re call	F- mea	C A
1 0	.8 .95	0 .08	1 .00	1 .6	89 94	9 4.6	



- True positive^۱
- False positive^۲
- True negative^۳
- False negative^۴

در هنگام دسته‌بندی یک داده تست توسط یک دسته‌بند تک-

کلاسی یکی از چهار وضعیت زیر رخ می‌دهد:

۱. داده نرمال توسط دسته‌بند به درستی شناسایی شود.^۱
۲. داده نرمال به اشتباه به عنوان یک نمونه پرت تشخیص داده شود.^۲
۳. نمونه پرت به درستی شناسایی شود.^۳
۴. نمونه پرت به اشتباه به عنوان یک داده نرمال پذیرفته شود.^۴

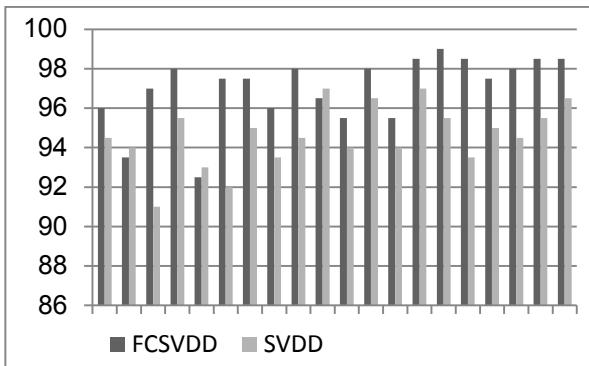
همان‌طور که ملاحظه می‌کنید موارد ۲ و ۴ معرف خطاهای صورت گرفته در دسته‌بندی داده‌ها هستند. این دو خطاهای معیارهایی هستند که برای ارزیابی روش‌های مختلف موجود برای توصیف یک دامنه خاص (دسته‌بندی‌های تک‌کلاسی) مورد استفاده قرار می‌گیرند.

بر اساس این چهار وضعیت، معیارهای مختلفی جهت ارزیابی روش‌های دسته‌بندی ارائه شده است. به عنوان مثال دو معیار Precision و Recall که به صورت زیر تعریف می‌شوند اعدادی در بازه ۰ تا ۱۰۰ تولید می‌کنند. Precision درصد قابلیت اعتماد به خروجی را نشان می‌دهد. در حالی که Recall نشان‌دهنده درصد موفقیت الگوریتم در تشخیص نمونه‌های مربوط به هر دسته است. امکان بهبود هم‌زمان این دو معیار کار مشکلی است و همواره نیازمند برقراری تعادلی بین این دو مقدار هستیم.

$$Precision = \frac{TP}{TP + FP} * 100 \quad (22)$$

$$Recall = \frac{TP}{TP + FN} * 100 \quad (23)$$

معیار F-measure برای محاسبه مصالحه میان دو معیار ذکر



شکل (۱۶) مقایسه میزان CA در دو روش FCSVDD و SVDD

در هنگام تشخیص امضا

محمدی سیستم شناسایی امضا با استفاده از PCA و MLP ارایه کرده است که دقت آن ۹۱.۵٪ است در حالی که الگوریتم پیشنهادی بر روی پایگاه داده یکسان توانست به دقت ۹۷٪ دست پیدا کند.

در سیستمی که آقای سید زاده ارایه داده است با به کارگیری تمام ویژگی‌ها، نرخ خطای رد نادرست امضاهای اصلی را ۹.۵٪ و نرخ خطای پذیرش نادرست امضاهای جعلی را ۱۱/۸٪ نشان می‌دهد. در حالیکه در روش پیشنهادی نرخ خطای رد نادرست امضاهای اصلی را ۴٪ و نرخ خطای پذیرش نادرست امضاهای جعلی صفر است.

نتیجه‌گیری

یک امضا از چند کاراکتر بعلاوه تعدادی خط هندسی تشکیل شده است. دو روش برای اکتساب امضا وجود دارد روش پویا^۱ و روش ایستا^۲. در روش پویا بوسیله صفحات و قلم‌های الکترونیکی امضاهای را بدست می‌آوریم ولی در روش ایستا با عکسبرداری از امضاء و یا اسکن کردن امضاء بدست می‌آید. در این مقاله امضاهای را به صورت ایستا جمع آوری شده است در الگوریتم های تشخیص امضاء دو مسئله اساسی مورد بررسی قرار می‌گیرد دسته‌بندی و شناسایی در دسته‌بندی مالکیت امضاء مورد بررسی قرار می‌گیرد ولی در شناسایی

شكل (۱۵) مقدار Precision و Recall

همانطور که در جدول ۱ مشاهده می‌شود مقدار Precision در تمامی طبقات ۱۰۰ درصد است این نشان می‌دهد که الگوریتم پیشنهادی ما تمامی نمونه‌های جعلی را به درستی رد می‌کند. میانگین مقدار Recall ۸۹.۶ درصد و میانگین دقت الگوریتم (CA) ۹۴.۶ درصد است.

FCSVDD

در جدول زیر نتایج مربوط به اجرای الگوریتم پیشنهادی (FCSVDD) را مشاهده می‌کنید. در این آزمایش به صورت تصادفی ۱۰ نمونه از امضاهای اصلی هر کلاس برای آموزش و ۱۰ نمونه دیگر از امضاهای اصلی و ۱۰ نمونه امضای جعلی را برای تست استفاده کرده ایم. در این جدول نتایج حاصل از ۱۰۰ مرتبه تکرار الگوریتم آورده شده است. در اینجا مقدار وزن هر نمونه برابر فاصله آن نمونه از مرکز دسته منظور شده است.

جدول ۲: نتایج الگوریتم FCSVDD برای ۱۰۰ مرتبه تکرار

T N	T P	F P	F N	P re	Re call	F- mea	C A
1	9	.	.	1			9
0	.4	0	6	00	94	96.6	7

همانطور که در جدول ۶-۵ مشاهده می‌شود مقدار Precision در تمامی طبقات ۱۰۰ درصد است این نشان می‌دهد که الگوریتم FCSVDD همانند الگوریتم SVDD تمامی نمونه های جعلی را به درستی شناسایی می‌کند. اما این روش توانسته است نسبت به الگوریتم SVDD میانگین مقدار Recall ۴.۴ درصد افزایش داده و میانگین دقت الگوریتم (CA) ۲.۴ درصد را افزایش داده است.

در نمودار زیر دقت دو روش پیشنهادی با هم مقایسه شده است.

^۱ On-line

^۲ Off-line

الگوریتم تمامی نمونه‌های جعلی را به درستی رد می‌کند. این مسئله یکی از نقاط قوت مهم روش های پیشنهادی است که می‌تواند به درستی جلوی تمام امضاهای جعلی را بگیرد. در روش SVDD میانگین مقدار Recall ۸۹.۶ درصد و میانگین دقت الگوریتم (CA) ۹۴.۶ درصد است. با توجه به ساختار مجموعه داده های امضاء وجود داده‌های پرت در این مجموعه دسته بندی الگوریتم FSVDD نتایج بهتری ارائه می‌دهد. در این روش میانگین مقدار Recall ۹۴ درصد و میانگین دقت الگوریتم (CA) ۹۷ درصد است که نسبت به الگوریتم SVDD میانگین مقدار Recall ۴.۴ درصد افزایش داده و میانگین دقت الگوریتم (CA) ۲.۴ درصد را افزایش داده است.

پیشنهادات پژوهشی

در ادامه برخی از کارهایی را که در آینده می‌تواند به عنوان زمینه‌های تحقیقاتی مرتبط با این طرح پژوهشی مورد استفاده قرار بگیرد بررسی می‌کنیم.

✓ یافتن کاربردهای دیگری از دسته‌بندهای یک کلاسی در حل مسائل مشابه

با توجه به کاربردهای فراوان روش‌های دسته‌بندی یک کلاسی می‌توان مسائل مختلفی را که در این حوزه قابل حل هستند بررسی نمود. به عبارت دیگر چنانچه در حل مسئله دسته‌بندی به دقت بالا نیاز است و یا تعداد نمونه‌های یک کلاس خیلی بیشتر از سایر کلاس‌ها است، دسته‌بندهای یک کلاسی می‌توانند ابزارهای بسیار مفیدی باشند.

✓ ارائه روشی جهت تعیین پارامتر مناسب برای کرنل در SVDD

یکی از مشکلات عمده روش SVDD تعیین پارامترهای کرنل است. هرچند در روش پیشنهادی با استفاده از نرمال‌سازی نمونه‌ها مقدار زیادی از این مشکل مرتفع می‌شود، ولی با این وجود همچنان تعیین میزان دقیق پارامتر کرنل که منجر به پیدایش جواب بهینه شود کاری دشوار است و روش‌های سعی و خطأ در مورد آن اجرا می‌شود.

علاوه بر مالکیت جعلی بودن امضاء را نیز مورد بررسی قرار می‌دهیم در دسته‌بندی یک امضا با توجه به ویژگی‌های آن به یک طبقه (شخص) نسبت داده می‌شود ولی در شناسایی امضاهای جعلی بودن امضاهای بررسی می‌شود الگوریتم پیشنهادی یک طبقه‌بندی کننده تک کلاسی است که برای شناسایی امضاهای کار می‌رود.

این الگوریتم با انجام یک سری تغییرات بر الگوریتم SVDD بدست می‌آید. در این الگوریتم از تابع کرنل گوسی استفاده شده است که با توجه به آزمایشات نتایج بهتری را به همراه دارد. همچنین با استفاده از این تکنیک که به حقه کرنل^۱ معروف است، به راحتی و بدون تحمیل محاسبات اضافه نتایج دقیق‌تری را برای روش SVDD در حوزه کرنل بدست می‌آید. البته تعیین مقدار مناسب برای پارامتر S یکی از موارد تاثیرگذار در نتایج نهایی است.

یکی از معضلات موجود در روش SVDD و سایر روش‌هایی که تنها از نمونه‌های نرمال جهت آموزش سیستم استفاده می‌کنند، حضور نمونه‌های پرت در داده‌های آموزش است. که این مسئله در مجموعه داده های مربوط به تشخیص امضاء بسیار اتفاق می‌افتد. حضور این چنین نمونه‌هایی در داده‌های آموزش، گاهاً منجر به تشکیل مزدھای نادرستی در اطراف نمونه‌های پرت می‌شود. در روش پیشنهادی FCSVDD نشان دادیم با فازی نمودن قیود موجود در روش SVDD استاندارد می‌توان این مشکل مطرح شده را نیز برطرف نمود. در هنگام فازی کردن قیود مفاهیم جدیدی به سیستم اضافه می‌شوند که با استفاده از آن‌ها می‌توان اهمیت نمونه‌ها را در تعیین سطوح تصمیم‌گیری مشخص نمود. در هر آزمایش به صورت تصادفی ۱۰ نمونه از امضاهای اصلی هر کلاس برای آموزش و ۱۰ نمونه دیگر از امضاهای اصلی و ۱۰ نمونه امضاهای جعلی برای تست به دسته بند یک کلاسی SVDD و FSVDD ارائه شده است. در هر دو روش مقدار Precision بدست آمده در تمامی طبقات ۱۰۰ درصد است این نشان می‌دهد که هر دو

¹ Kernel trick

مراجع

- [1] J.Fierrez, J.OrtegaGarcia,D.Ramos,G.Rodriguez "HMM-based on-linesignature verification:Feature extraction and signature modeling" Pattern Recognition LettersVolume 28, Issue 16, 1 December 2007, Pages 2325–2334
- [2] Milena R. P. Souza, George , " Off-line signature verification: an approach based on combining distances and one-class classifier"22nd International Conference on Tools with Artificial Intelligence 2010
- [3] Meenakshi.Sh, Kavita.K"Offline Signature Verification Using Supervised and Unsupervised Neural Networks"International Journal of Computer Science and Mobile Computing, Vol.3 Issue.7, July- 2014, pg. 425-436
- [4] E. Frias-Martinez, A. Sanchez, J. Velez. "Support Vector Machines versus Multi-Layer Perceptrons for Efficient Off-Line Signature Recognition". Elsevier Editorial System for Engineering Applications of Artificial Intelligence. 2006.
- [5] محمدحسین سیگاری، محمدرضا پورشهابی، حمیدرضا پوررضا، «شناسایی امضای دستنویس ایستا با استفاده از موجک گابور»، شانزدهمین کنفرانس مهندسی برق ایران، صفحه ۳۹۴-۴۰۰، تهران، ایران، اردیبهشت ۱۳۸۷
- [6] سیده زهرا محمدی ، " بازشناسی امضای ایستا فارسی "پایان نامه کارشناسی مهندسی برق ، گرایش کنترل دانشگاه فردوسی مشهد ، بهار ۱۳۸۵
- [7] سید آرش استادزاده، سید شروین استادزاده " طراحی یک سیستم چند سطحی تأیید امضای دستنویس ایستا بر پایه تطبیق کشسان با درجه تفکیک پذیری چند گانه" مجله فنی مهندسی دانشگاه آزاد اسلامی واحد مشهد تابستان ۱۳۸۵
- /8/ J.P. Swanepoel, J. Coetzer "Off-line Signature Verification Using Flexible Grid Features and Classifier Fusion" 12th International Conference on Frontiers in Handwriting Recognition2010
- [9] Zhang, B.. "Off-Line Signature Recognition and Verification by Kernel Principal"Component Self-Regression. Proceedings of the 5th International Conferenceon Machine Learning and Applications, pages 28–33. (2006)
- [10] D.M.J. Tax, R.P.W. Duin, "Support vector domain description", Pattern Recognition Letters 20, pp. 1191-1199, 1999.
- [11] D.M.J. Tax, R.P.W. Duin, "Data Description in Subspaces", International Conference on Pattern Recognition, Vol. 2, pp. 672–675, 2000.

حساسیت این پارامتر به حدی است که حتی با تغییر تعداد نمونه‌های آموزش، بایستی مجدداً مقدار مناسبی برای آن تعیین نمود. تا کنون تعدادی روش بر پایه الگوریتم‌های ژنتیک در این زمینه ارائه شده که اصولاً کارایی بالایی نداشته‌اند.

✓ تعیین مکانیزم‌های دقیقی برای تعیین پارامترهای روش FCSVDD

دیدگاه جدیدی که در این روش پیشنهادی مطرح شد، اهمیت دادن به نمونه‌ها است. در هنگامی که ساختار نمونه‌ها مشخص باشد می‌توان به راحتی راه حلی برای این موضوع پیدا نمود و حتی توسط یک شخص خبره وزن نمونه‌ها را تعیین کرد. اما در شرایطی که هیچ دیدی نسبت به نمونه‌های آموزش وجود نداشته باشد، کار کمی دشوار می‌شود. به نظر می‌رسد یافتن یک روش کلی برای تعیین اهمیت هر نمونه - که برای همه مجموعه‌های داده‌ای مناسب باشد - مورد نیاز است.

✓ ارائه دسته‌بندهای چندکلاسی با استفاده از روش‌های پیشنهادی

در تمامی مسائل مطرح شده در این طرح تنها از یک دسته‌بند یک‌کلاسی جهت تشخیص دو دسته از داده‌ها استفاده شده است. در این حالت یکی از کلاس‌ها را تحت عنوان کلاس هدف در نظر گرفته‌ایم در حالی که سایر کلاس‌ها به صورت کلاس غیر هدف فرض شده‌اند.

حال چنانچه بخواهیم تعدادی کلاس از داده‌ها را به صورت همزمان تشخیص دهیم بایستی مکانیزم جدیدی اتخاذ نمود. در حالتی که n کلاس جداگانه از نمونه‌ها وجود دارد، در ساده‌ترین حالت می‌توان برای هر دسته یک دسته‌بند یک‌کلاسی استفاده نمود. به عبارت دیگر هر دسته را به صورت جداگانه توصیف نمود.

سپاسگزاری

در پایان لازم میدانم از آقای سیگاری که مجموعه داده خود را در اختیار ما گذاشتند تشکر و قدردانی نمایم.

[12] D.M.J. Tax, "One-class classification: concept learning in the absence of counter-examples", Netherlands, Technische Universiteit Delft, Vol. 65, 2001.

[13] D.M.J. Tax, R.P.W. Duin, "Support Vector Data Description", Machine Learning 54, Kluwer Academic Publishers, pp. 45-66, 2004.

[14] V. Vapnik, "Statistical Learning Theory", Wiley, 1998

[۱۵] محمد رضا پور شهابی، محمد حسین سیگاری، حمید رضا پور رضا، «تایید امضای دستنویس بروندختی با استفاده از موجک Gabor»، چهاردهمین کنفرانس ملی انجمن کامپیوتر ایران، تهران، ایران، اسفند ۱۳۸۷.

