



ارائه شده توسط :

سایت ترجمه فا

مرجع جدیدترین مقالات ترجمه شده

از نشریات معابر

مدل ترکیبی داده کاوی الگوریتم های انتخاب ویژگی و طبقه بندی کننده

های یادگیری گروهی برای امتیاز دهنده اعتباری

چکیده:

تکنیک های داده کاوی در حوزه بانکداری، از کاربردهای متنوعی جهت امتیاز دهنده اعتباری برخوردار اند. یکی از معروف ترین تکنیک های داده کاوی، روش طبقه بندی نام دارد. مطالعات پیشین نشان دادند استفاده از الگوریتم های انتخاب ویژگی ها و طبقه بندی کننده های گروهی سبب بهبود عملکرد بانک ها در مشکلات امتیاز دهنده اعتباری می گردد. در این زمینه، موضوع اساسی، شبیه سازی و استفاده ترکیبی از این دو الگوریتم فوق جهت تعیین پارامترها و دستیابی به مدلی با عملکرد بالا، است. این مقاله به نحوه استفاده از مدل ترکیبی داده کاوی الگوریتم های انتخاب ویژگی و طبقه بندی کننده های یادگیری گروهی در امتیاز دهنده اعتباری در ۳ مرحله می پردازد: ۱) جمع آوری و پردازش داده ها ۲) اجراء ۴ الگوریتم FS همچون آنالیز مولفه های اساسی PCA، الگوریتم ژنتیک GA، معیار ضریب بهره اطلاعات وتابع ارزیابی صفات مهم. در این مرحله، پارامترهای روش FS با کمک الگوریتم طبقه بندی کننده ماشین بردار پشتیبان، به دقت تعیین می شوند. پس از انتخاب مدل دقیق در هر ویژگی، باید از آن ها در الگوریتم های طبقه بندی کننده و بناء استفاده نمود. در مرحله فوق، بهترین الگوریتم FS همراه با پارامترهای تعیین شده اش جهت استفاده در مرحله مدلسازی، استفاده خواهد شد. ۳) اجراء الگوریتم های طبقه بندی بر روی مجموعه داده های آماده شده برای هر الگوریتم FS. نتایج مرحله ۲، نشان می دهد که الگوریتم PCA نسبت به FS از عملکرد مطلوب تری برخوردار است. نتایج طبقه بندی مرحله ۳ نیز نشان می دهد روش آدابوست در شبکه عصبی مصنوعی (ANN) از دقت طبقه بندی بسیار بالایی برخوردار است. در نهایت، مقاله حاضر به بررسی مدل ترکیبی به عنوان مدل عملیاتی و قدرتمندی جهت اجراء امتیاز دهنده اعتباری اشاره خواهد داشت.

کلمات تخصصی: امتیاز دهی اعتباری، طبقه بندی، انتخاب ویژگی، یادگیری گروهی، داده کاوی

1- مقدمه:

اخیراً موسسات مالی و بانک‌ها به بررسی ریسک اعتباری مشتریان خود پرداخته‌اند. آن‌ها جهت تفکیک خدمات اعتباری که به مشتریانشان اعطا می‌کنند نیاز به سیستم‌های امتیاز دهی اعتباری دارند. اخیراً، استفاده از روش‌های غیر پارامتری و داده کاوی به حوزه امتیاز دهی اعتباری مشتریان، راه یافته است. روش‌های آماری، غیر پارامتری و هوش مصنوعی AI همگی به توسعه امتیاز دهی اعتباری مشتریان می‌پردازند. علاوه بر این، روش‌های امتیاز دهی اعتباری گروهی در بسیاری از مطالعات استفاده گردیده‌اند. شایان ذکر است که تعداد قابل توجهی از محققین نشان دادند روش‌های طبقه بندی یادگیری گروهی در حوزه امتیاز دهی اعتباری در مقایسه با طبقه بندی کننده‌های مجزا از عملکرد بسیار بهتری برخوردار‌اند. بر این اساس، ۹ رویکرد اصلی مطالعه و بررسی معیار امتیاز دهی اعتباری ارائه می‌کنیم که عبارتند از:

1. مدل‌های امتیاز دهی اعتباری طبقه بندی کننده مستقل
2. مدل‌های امتیاز دهی اعتباری طبقه بندی کننده چندگانه
3. مدل‌های امتیاز دهی اعتباری مبتنی بر مدل‌های آماری
4. مدل‌های امتیاز دهی اعتباری مبتنی بر روش‌های AI
5. مدل‌های امتیاز دهی اعتباری خطی و غیر خطی
6. مدل‌های امتیاز دهی اعتباری پارامتری، شامل مدل احتمال خطی، مدل آنالیز تشخیصی، مدل‌های لوجیت و غیره
7. مدل‌های امتیاز دهی اعتباری غیر پارامتری (داده کاوی) شامل درخت تصمیم گیری، مدل نزدیک ترین همسایه، سیستم‌های خبره ANN، منطق فازی GA، knn
8. مدل‌های امتیاز دهی اعتباری یادگیری گروهی
9. مدل‌های امتیاز دهی اعتباری ترکیبی یا هیبریدی

محققان بسیاری به بررسی روش‌های ذکر شده پرداخته‌اند. هو و آنسل(2007) از الگوریتم‌هایی همچون رگرسیون لوجستیک ANN، LR و الگوریتم بهینه سازی حداقلی ترتیبی SMO در مطالعات خود، بهره برندند. مین و لی(2008) نیز به پیش‌بینی مدل امتیاز دهی اعتباری بر اساس روش تحلیل توسعه داده‌ها DEA پرداختند. در مطالعه دیگر، الگوریتم‌های رتبه‌دهی مبتنی بر تحلیل پیوند صفات همراه با SVM جهت امتیاز دهی اعتباری استفاده شد. ستینو و همکاران(2009) از GA جهت بهینه سازی الگوریتم KNN در زمینه امتیاز دهی اعتباری استفاده کردند. علاوه بر این، یاه و لین(2009) به مقایسه تکنیک‌های داده کاوی نظریه امتیاز دهی اعتباری استفاده کردند. SVM از روش‌جستجوی مستقیم برای KNN، IR، ANN و درخت تصمیم گیری پرداختند. ژو و همکاران(2009) از روش‌جستجوی مستقیم برای انتخاب پارامترها در الگوریتم SVM استفاده کردند. پینگ و یانگ ژن(2011) نیز از مجموعه پارامترهای مجاور و طبقه‌بندی کننده SVM جهت بررسی امتیاز دهی اعتباری، استفاده به عمل آوردند. در مطالعه دیگر، کائو و همکاران(2012) از مدل بیزین همراه با درخت رگرسیون طبقه‌بندی کننده استفاده کردند. وکوویچ و همکاران(2012) نیز از توابع اولویت همراه با مدل استدلال مبتنی بر حالت(CBR) در زمینه امتیاز دهی اعتباری، استفاده کردند. دانناس و گارسو(2015) از روش بهینه سازی ازدحام ذرات PSO جهت انتخاب بهترین طبقه‌بندی کننده خطی SVM در امتیاز دهی اعتباری، استفاده نمودند.

همانطور که گفتیم، مدل‌های امتیاز دهی اعتباری گروهی در مطالعات فراوانی استفاده شده‌اند. تساوی و وو(2008) از شبکه عصبی پرسپترون چندلایه MLP در زمینه امتیاز دهی اعتباری و نانی و لومینی(2009) از روش‌هایی نظریه جنگل تصادفی، فضای تصادفی و تغییر کلاس در امتیاز دهی اعتباری، توالا(2010) از روش‌هایی همچون ANN، درخت تصمیم گیری، KNN و تحلیل تشخیص لجستیک، سیه و هانگ(2010) از طبقه‌بندی کننده‌های گروهی Bagging و شبکه بیزین، پالئولوگو و همکاران(2010) از طبقه‌بندی کننده‌های subbagging همچون SVM، KNN، ANN، SVM نظریه Bagging را ارائه کردند. وانگ و ما(2012) نیز از روش یادگیری ترکیبی با استفاده از SVM به عنوان یادگیرنده اصلی در ارزیابی ریسک اعتباراتِ شرکت‌ها، استفاده کردند.

مطالعات مختلفی به بررسی استفاده از روش FS در مدل های امتیاز دهی اعتباری پرداخته اند. وانگ و هانگ(2009) از روش های پویا جهت جمع آوری داده هایی در زمینه امتیاز دهی اعتباری استفاده کردند.تسای(2009) به مقایسه 5 روش FS در پیش بینی ورشکستگی شرکت ها (نظیر آزمون تی،ماتریس MLP،همبستگی،رگرسیون گام به گام،PCA و تحلیل عامل) و بررسی عملکرد آن ها با کمک شبکه های عصبی LDA،پرداختند. چن و لی(2010)،استراتژی های ترکیبی با روش های FS همچون آنالیز تشخیص خطی SVM نظریه مجموعه مبنا،درخت تصمیم گیری و مدل طبقه بندی در زمینه امتیاز دهی اعتباری را مطرح کردند. چن(2012)،بر اساس نظریه مجموعه مبنا، به ترکیب FS با توزیع احتمال تجمعی در حوزه امتیاز دهی اعتباری پرداخت.هاجک و میشالاک(2013)،روشی را جهت ترکیب روش های فردی و گروهی FS همراه با مدل های یادگیری ماشینی نظیر MLP,RBS,SVM,LDA و طبقه بندی کننده نزدیک ترین میانه در پیش بینی امتیاز دهی اعتباری شرکت ها ارائه نمودند. اورسکی (2014) نیز به ترکیب GA با ANN را جهت تشخیص و شناسایی بهترین ویژگی ها و افزایش دقت طبقه بندی در ارزیابی ریسک اعتبارات،پرداخت. لیانگ و همکاران(2015) از 3 فیلتر با عنوان LDA،آزمون تی و رگرسیون خطی همراه با روش های FS مبتنی بر SVM در ترکیب با 6 مدل پیش بینی کننده متفاوت با عنوان RBF,SVM,KNN,CART خطی، و بیز جهت گردآوری داده های مربوط به ورشکستگی و امتیاز دهی اعتباری شرکت ها،استفاده کردند.

مطالعات فوق همگی در سه دیدگاه اصلی انجام شده اند:1) ارزیابی کلی امتیاز دهی اعتباری 2) ارزیابی امتیاز دهی اعتباری گروهی و 3) ارزیابی امتیاز دهی اعتباری مبتنی بر FS.این مقاله سعی کرده از این سه دیدگاه فاصله بگیرد.البته باید توجه داشت که مطالعات پیشین تنها یکم یا دو دیدگاه از سه دیدگاه فوق را در اختیار داشته اند.علاوه بر این،هدف اصلی مقاله حاضر،استفاده از الگوریتم FS و طبقه بندی کننده های مبنا و گروهی و توجه به عواملی نظیر دقت طبقه بندی،منحنی ویژگی های عملیاتی AUC و تعیین پارامترهای در مدل های امتیاز دهی اعتباری، می باشد . همچنین بسیاری از مطالعات،تأثیر روش های مختلف FS و پارامترهای تعیین شده طبقه بندی کننده ها بر مشکلات امتیاز دهی اعتباری را نادیده گرفته اند. بنابراین به منظور ایجاد مدل ترکیبی جدید FS و مدل گروهی امتیاز دهی اعتباری،نه رویکرد مطرح شده اند. مدل پیشنهادی ما،ترکیبی از تکنیک

های FS همراه با طبقه بندی کننده های مبنا(مستقل) و گروهی در روش های پارامتری و غیر پارامتری امتیاز دهی اعتباری، می باشد . در تعیین پارامترها از 4 الگوریتم FS و دو الگوریتم طبقه بندی کننده، استفاده به عمل آمده است . عملکرد هر الگوریتم FS، بر اساس شاخص دقیق طبقه بندی SVM سنجیده شده است. روش یادگیری موثری بوده که در مسائل طبقه بندی، استفاده می شود. SVM یکی از تکنیک های رایج استفاده شده در ادبیات محسوب می شود. بنابراین می توان از آن جهت ارزیابی عملکرد الگوریتم های fs استفاده نمود. همچنین، مطابق با دقیق طبقه بندی و شاخص AUC، الگوریتم های طبقه بندی با یکدیگر مقایسه شده اند. در این مقاله، مجموعه داده هایی از بانک توسعه صادرات ایران به دست آمده اند. در مدل ترکیبی، از 4 الگوریتم FS استفاده شده که عبارتند از: 1) GA(2) PCA(3) معیار ضریب بهره اطلاعات و 4) الگوریتم Relief. علاوه بر این، دو الگوریتم طبقه بندی رایج در مطالعات پیشین با عنوان 1) طبقه بندی کننده های مستقل نظری bagging، 2) الگوریتم های گروهی نظری CART و ANN و 3) SVM. آدبوست، درخت تصادفی و staking، نیز مورد استفاده قرار گرفته اند. نتایج نشان می دهند مدل ترکیبی امتیاز دهی اعتباری در مقایسه با سایر الگوریتم های دیگر، از عملکرد مطلوب تری برخوردار است .

ویژگی های مهم این مقاله که از مدل پیشنهادی به دست آمده عبارتند از:

1. انجام مطالعه جامع و کامل با مقایسه طبقه بندی کننده ها و روش های FS متناسب با مسائل امتیاز دهی اعتباری
2. استفاده ترکیبی و همزمان از 3 روش امتیاز دهی اعتباری گروهی، کلی و FS
3. استفاده از الگوریتم های FS و مقایسه عملکرد آن ها با هدف تشخیص کارآیی آگوریتم SVM و سنجش دقیق AUC
4. تعیین پارامترهای الگوریتم های طبقه بندی و FS جهت بهبود عملکرد امتیاز دهی اعتباری
5. استفاده همزمان و مقایسه الگوریتم های یادگیری مستقل و گروهی در مدل امتیاز دهی اعتباری
6. استفاده و مقایسه 9 روش مدلبنده امتیاز دهی اعتباری بر اساس چهار چوب ترکیبی

7. اگرچه امتیاز دهی اعتباری بر روی مشتریان واقعی بررسی شده اما مدل امتیاز دهی اعتباری ما بر اساس مشتریان حقیقی، ساخته شده است.

سایر قسمت های دیگر این مقاله عبارتند از:بخش 2: شرح مختصری از روش ها بخش 3: ارائه طرح آزمایش نظری
شرح مجموعه داده ها و پردازش آن ها، ارزیابی عملکرد و توسعه مدل امتیاز دهی اعتباری بخش 4: بیان نتایج و
بخش 5: نتیجه گیری و ارائه پیشنهادات

2- پیش زمینه

2.1 امتیاز دهی اعتباری

توماس، امتیاز دهی اعتباری را به عنوان فرآیند شناسایی مشتریان بانک ها جهت اعطای تسهیلات و اعتبارات به آن ها بر اساس برخی معیارهای از پیش تعیین شده، تعریف نمود. در واقع، مطابق با گفته اونگ و همکاران، مدل های امتیاز دهی اعتباری از مزیت های متعددی برخوردار اند از جمله: 1) کاهش هزینه های تحلیل اعتبارات 2) تخصیص اعتبارات بر اساس تصمیم گیری های سریع و به موقع³ سوددهی بالا در زمان بازپرداخت تسهیلات و 4) کاهش خطرات احتمالی. در سال 1936 میلادی، فیشر با کمک مدل امتیاز دهی اعتباری، مفهوم آنالیز تشخیص آماری را بیان نمود. پس از وی، دیوید دوراند در سال 1941، از روش های متعددی جهت انجام امتیاز های بد از خوب استفاده کرد. سپس در سال 1960، موسسات و بانک ها از کارت های اعتباری جهت انجام امتیاز دهی اعتباری استفاده کردند. در سال 1980، کارشناسان بانکداری، استفاده از روش امتیاز دهی اعتباری را نقطه عطفی جهت استفاده از سایر روش های دیگر، عنوان کردند. بنابراین امتیاز دهی اعتباری از سوی این افراد جهت بررسی تصمیم گیری نهایی در بانک ها استفاده شد. محققان در ارزیابی امتیاز دهی اعتباری مشتریان از 3C, 4C, 5C (همچون سرمایه، شخصیت، توانایی و وضعیت مشتری) بهره برند. یو و همکاران (2009) در مطالعات خود به بررسی روش های بهینه سازی و آماری امتیاز دهی اعتباری نظری LDA، تحلیل لجستیک، تحلیل پریویک، برنامه ریزی خطی، برنامه ریزی ترکیبی، KNN و درخت طبقه بندی، پرداختند. اخیرا برخی مطالعات به بررسی تکنیک های ANN, EC, GA, SVM در حوزه امتیاز دهی اعتباری، توجه

داشته اند. علاوه بر این، مدل های امتیاز دهنده اعتباری مستقل و ترکیبی نیز از سوی برخی محققان استفاده شده است.

2.2 الگوریتم های انتخاب ویژگی:

الگوریتم های انتخاب ویژگی ها که به روش های پیش پردازشی مدل نیز معروف اند، جهت افزایش عملکرد طبقه بندی، استفاده می شوند. مزیت های این روش ها عبارتند از: ۱- کاهش نویز در مجموعه داده ها ۲- کاهش هزینه های محاسباتی جهت آنایی با مدل ها ۳- کمک به درک بهتری از مدل های نهایی در الگوریتم های طبقه بندی ۴- استفاده آسان و ۵- به روز رسانی مدل. در روش FS، سه شاخص عمده وجود دارد: ۱) شاخص ارزشیابی ۲) جستجوی رفتار و ۳) قانون توقف. نوع نوع معيار ارزشیابی نیز در این مدل وجود دارد که عبارتند از: ۱) اطلاعات ۲) واپسیگی ۳) فاصله ۴) ثبات و ۵) دقت طبقه بندی. همچنین ۳ نوع روش تحقیق نیز در FS موجود بوده که عبارت است از: ۱- جستجوی تصادفی ۲- اکتشافی و ۳- جستجوی کامل. همچنین قوانین توقف که از طرف وانگ ولی ارائه شده دارای ویژگی های ذیل می باند: ۱) تعیین ماکزیمم تعداد تکرار ۲- عدم تغییر عملکرد بدون اضافه کردن یا حذف یک ویژگی ۳- تعیین مجموعه ویژگی های ایده آل.

در این مقاله، ۳ نوع الگوریتم FS استفاده شده اند: ۱- GA- ۲- معيار ضریب بهره اطلاعات و ۳- روش relief در ادامه، شرحی از الگوریتم های موجود ذکر خواهند شد:

۱. انتخاب ویژگی الگوریتم ژنتیک: در این روش، ابتدا کروموزومی به عنوان مجموعه ای از ویژگی مشتریان بانک، انتخاب می شود. ژن نیز به عنوان یکی از ویژگی های مشتریان انتخاب شده است. جهت شناسایی بهترین مجموعه ایده آلی از متغیرها، از استراتژی گلدبرگ استفاده گردیده است. در ادامه به منظور ارزیابی متغیرهای ورودی، از تابع ارزیاب با اعتبار n استفاده شد. علاوه بر این، زیرمجموعه ای از ویژگی ها نیز مطابق با معيار دقت طبقه بندی الگوریتم SVM انتخاب گردید. در نهایت، ماکزیمم تعداد نسل ها، جمعیت اولیه، تعداد جهش ها، احتمال مقطوعی، اعتبار سنجی مقطوعی و تعداد بذرهای تصادفی به ترتیب ۲۰، ۰۱، ۹/۰ و ۱ به دست آمدند.

2. انتخاب ویژگی روش Relief: این روش با کمک نرم افزار Rapid Miner می تواند مقدار هر ویژگی و نیز مقدار نزدیک ترین همسایه به آن را ارزیابی نماید.

3. انتخاب معیار ضریب بهره اطلاعات: این روش مبتنی بر مفهوم آنتروپی اطلاعات است. در این روش، از ابزار یادگیری ماشینی WEKA جهت تعیین معیار ضریب بهره اطلاعات مناسب با هر گروه، استفاده شده و مقدار معیار ضریب بهره اطلاعات معادل با H منهای H می باشد.

4. انتخاب ویژگی تحلیل مولفه اساسی: PCA، روشی انتقالی جهت کاهش تعداد ویژگی‌ها با استخراج ویژگی‌های جدید بوده و در آن، ویژگی‌های مربوطه به عنوان مولفه‌های اساسی انتخاب شده‌اند. مطابق با یافته‌ای سوستریسیک و همکاران (2009)، مولفه‌های اساسی متعدد جود دارد که به عنوان متغیرهای اصلی مدل انتخاب شده‌اند.

2.3 الگوریتم‌های طبقه‌بندی مبنا (مستقل):

1- درخت تصمیم گیری: این الگوریتم را می‌توان یکی از مشهورترین الگوریتم‌های استفاده شده در زمینه امتیاز دهی اعتباری نامید درخت تصمیم گیری، مدلی با ساختار درختی بوده که از نقاط، شاخه‌ها و برگ‌های فراوانی تشکیل شده است. هر نقطه به یک متغیر یا صفت تعلق دارد به بیان بهتر، شاخه‌ها، داده‌ها را به مجموعه داده‌های کوچک‌تری تقسیم نموده و برگ‌ها نیز از مقدار مشخصی بهره مند‌اند. در این مقاله از طبقه‌بندی کنندۀ درخت تصمیم گیری CART که از دو شاخه برای هر نقطه تصمیم گیری تشکیل شده، استفاده شده است. به منظور تقسیم داده‌های آموزشی، تمام تعاملات را به زیرمجموعه‌ای از تعاملات با مقادیر مشابهی برای متغیرهای هدف، طبقه‌بندی می‌کند. CART، یک جستجوی جامع نیز بر روی تمام صفات انجام داده و از تمام مقادیر به دست آمده جهت دستیابی به بهترین شاخص تقسیم بندی شده، استفاده می‌کند.

2- شبکه عصبی مصنوعی: این الگوریتم طبقه‌بندی بر اساس روش‌های غیر پارامتری ارائه شده و به وفور در مسائل امتیاز دهی اعتباری، مورد استفاده قرار می‌گیرد. ANN می‌تواند در مسائل غیر خطی نیز بکار برد شود. در مطالعه حاضر، از ANN دارای 3 لایه استفاده شده که لایه درونی شامل نورون‌های مربوط به متغیرهای ورودی و لایه خارجی دارای یک نورون می‌باشد. ارتباط بین نورون‌های موجود در هر لایه به وزن آن‌ها بستگی

دارد . هر نورون در لایه های مخفی و خروجی با کمک تابع فعالسازی، تحریک می شود. در طی مرحله آموزش شبکه، وزن لایه ها کاهش یافته اگرچه دقیق طبقه بندی افزایش می یابد. رویکرد آموزشی، نوعی فرآیند تکراری بوده که بر اساس یادگیری گرادیان نزولی و با کمک شاخص ضریب یادگیری، محاسبه می شود.

3- ماشین بردار پشتیبان SVM ابتدا توسط واپنیک، توسعه یافت می توان آن را نوعی الگوریتم یادگیری ناظارتی و غیر پارامتری در نظر گرفت . اخیرا، SVM در مطالعات مختلفی در حوزه امتیاز دهی اعتباری استفاده شده است . مطابق با مطالعات پینگ و یانچنگ (2011)، رویکرد اصلی SVM، مینیمم سازی ریسک ساختاری با کمک معادله $w \cdot x + b = 0$ است . در این مطالعه، کرنل های خطی، چند جمله ای و RBF جهت بهینه سازی ابرصفحات استفاده شده اند.

4- روش بیز: این الگوریتم مبتنی بر روش های پارامتری و یادگیری احتمالات است . مطابق با گفته توala (2010)، این طبقه بندی کننده از قوانین بیز جهت محاسبه احتمال دارا بودن تمام صفات A_j توسط C_i و پیش بینی بیشترین احتمال یک کلاس، استفاده می کند. احتمال مقدار کلاس C_i در n مشاهدات با کمک معادله ذیل به دست می آید:

$$p(C_i|X) = \prod_{j=1}^n p(A_j|C_i) \cdot p(C_i) \quad (1)$$

2.4: الگوریتم های طبقه بندی گروهی:

الگوریتم های طبقه بندی گروهی در حوزه امتیاز دهی اعتباری از کاربردهای گسترده ای برخوردار اند. یادگیری گروهی بر اساس روش های یادگیری ماشینی بنا شده و اکثر الگوریتم های یادگیری جهت حل مسائل امتیاز دهی اعتباری بکار برده می شوند. این الگوریتم ها متصاد الگوریتم های مستقل هستند. به تازگی، الگوریتم های گروهی در مطالعات امتیاز دهی اعتباری، به وفور استفاده می شوند. در بخش 1، برخی مدل های امتیاز دهی اعتباری گروهی مطرح شد . در ادامه، 4 مدل اصلی یادگیری گروهی بیان خواهند شد:

1. Bagging: این الگوریتم از سوی بریمن توسعه یافته و مبتنی بر مفاهیم مختلفی است. که در

آن، مجموعه داده های آموزشی متتنوع به طور تصادفی جهت آموزش به فرد یادگیرنده استفاده می شود.

2. آدبوست: این الگوریتم توسط فرنند و شافیر توسعه یافته و به رویکرد بوستینگ تعلق دارد. این الگوریتم به سنجش تمام تعاملات و تکرارهای آن ها می پردازد.

3. Stacking: این الگوریتم با ترکیب در الگوریتم های یادگیری مختلف جهت دستیابی به دقت پیش بینی بالا، استفاده شده و مطابق با مطالعات وانگ و همکاران (Stacking 2011)، یا کمک یادگیرنده‌گان در سطح متابه، پیش بینی فعالیت یادگیرنده‌گان متعدد می پردازد.

4. جنگل تصادفی: این روش، مجموعه ای از درخت های تصمیم گیری منسجم بوده که مطابق با آزمون های سنجش داده های آموزشی، مورد استفاده قرار می گیرد.

3- طرح آزمایش:

3.1 تشریح مجموعه داده ها و پیش پردازش آن ها:

مجموعه داده های استفاده شده جهت ارزیابی عملکرد مدل پیشنهادی به مشتریان حقیقی بانک توسعه صادرات ایران طی دو سال، وابسته اند. در ادامه، متغیرهای بکار برده شده در این مدل ارائه خواهند شد. نوع متغیرها یا پیوسته (C) بوده یا ناپیوسته (D)، بنابراین داریم:

برگشت فروش (C)، مجموع نمرات کیفیت (C)، چرخه مطالبات (C)، عملیات سیکل (C)، موجودی دوره (C)، ریسک بازارهای هدف (D)، تجارب بانک (D)، سابقه ورشکستگی (D)، آمار مدیران ارشد (D)، شخصیت حقوقی (D)، عوامل فصلی (D)، فعالیت در بازار داخلی (D)، قلمرو بازار خارجی (C)، سرمایه در گردش (C)، جریان دارایی های جاری (C)، دارایی های غیر جاری (C)، نرخ بهره با سرمایه ثابت (C)، نرخ بهره سرمایه گذاری (C)، نسبت بدھی ها به دارایی های غیر جاری (C)، میزان پوشش هزینه های مالی (C)، نسبت جریان (C)، نسبت دارایی های خالص به دارایی های غیر جاری (C)، نسبت آنی (C)، نسبت بدھی (C) و نسبت دارایی (متغیر هدف) (C)

در این مجموعه داده ها، متغیر هدف، یک مساله دو کلاسی بوده که بدین صورت تعریف شده است: مشتریان بد و خوب، کسانی اند که بازپرداخت های آن ها قبل و بعد از دو ماه صورت گرفته باشد. این مجموعه داده ها متشکل از 1100 مشتری حقوقی با تعداد 59 ویژگی، است.

جهت استفاده از این مجموعه، ابتدا باید عمل پردازش داده ها صورت گیرد. در این مقاله، جهت آماده سازی داده ها، روش های پیش پردازش مختلفی به صورت زیر استفاده شده است: 1) حذف برخی ویژگی ها و آمار ثبت شده نامعتبر 2) ترکیب داده ها 3) انتقال و تبدیل داده ها 4) حذف برخی از ویژگی های اضافی 5) نرمال سازی 6) تعیین همبستگی بین دو متغیر با کمک آزمون پیرسون 7) تجسم داده ها 8) ایجاد ویژگی جدید و 9) تعیین طرح اصلی.

بعد از انجام پیش پردازش، تعداد 30 ویژگی انتخاب شدند. علاوه بر این، تعداد رکوردهای ثبت شده بعد از آماده سازی داده ها نیز به 777 مورد کاهش یافته است.

3.2 ارزیابی عملکرد:

جهت ارزیابی آزمایشات، برخی شاخص ها از جمله دقت طبقه بندی و AUC مورد استفاده قرار گرفتند. شرح هر یک از این شاخص ها باید بر حسب ماتریس درهم ریختگی و مطابق با شکل 1، انجام شود. موارد اختصار در این ماتریس عبارتند از: $TP =$ مثبت حقیقی، $TN =$ منفی حقیقی، $FP =$ مثبت غیر حقیقی و $FN =$ منفی کاذب و غیر حقیقی. در شکل 1، تعریف هر یک از این اختصارات نیز ذکر شده است. دقت طبقه بندی را می توان با کمک معادله ذیل محاسبه نمود.

$$\text{Accuracy} = \frac{TP + TN}{TP + FP + FN + TN} \quad (2)$$

دومین شاخص ارزیابی، AUC است براون و مانوس (2012) بیان کردند که منحنی ویژگی های عملیاتی گیرنده ROC یک نمودار دو بعدی بوده و می تواند تعاملات بین مثبت حقیقی و مثبت کاذب را نشان دهد. به منظور مقایسه طبقه بندی کننده های مختلف با یکدیگر، می توان از AUC استفاده نمود.

| | | Actual classification | |
|--------------------------|---------------------------------|---------------------------------|--------------------------------|
| | | Positive (Good customers) | Negative (Bad customers) |
| Predicted classification | Positive (Good customers) | True Positive (TP) | False Positive (FP) |
| | Negative (Bad customers) | False Negative (FN) | True Negative (TN) |

شکل 1: ماتریس درهم ریختگی

3.3 مدل پیشنهادی:

در این بخش، از مدل داده کاوی ترکیبی در امتیاز دهی اعتباری استفاده شده است. شکل 2، نمودار مدل پیشنهادی را نشان می دهد. این مدل از سه مرحله تشکیل شده است: 1) جمع آوری داده ها و پیش پردازش آن 2) انتخاب ویژگی ها و 3) مدلسازی یا همان طبقه بندی. در مرحله نخست، بعد از جمع آوری داده ها، از روش های پیش پردازش نیز استفاده شده است. در مرحله دوم، جهت دستیابی به بیشترین عملکرد الگوریتم های طبقه بندی در مرحله بعد، از 4 الگوریتم FS استفاده شده است. این 4 الگوریتم عبارتند از: 1) GA (روش Relief) 3) معیار ضریب بهره اطلاعات و 4) PCA. در این مرحله، پارامترهای تمام تکنیک های FS، تعیین شده است. پارامترهای بهینه نیز توسط شاخص دقت طبقه بندی SVM برای هر الگوریتم فوق تعیین شده است. بر این اساس، 70 و 30 درصد از داده ها به ترتیب به عنوان داده های آموزشی و آزمایشی انتخاب شدند. شاخص دقت نیز جهت مقایسه الگوریتم های FS استفاده شدند. در مرحله 3، از 4 طبقه بندی کننده مستقل استفاده شده که عبارتند از: CART, ANN, SVM, -CART و بیز و تعدادی طبقه بندی گروهی نظیر بیز-آدبوست، آدبوست- ANN، bagging - ANN، bagging -CART، bagging بیز- ANN. مجموعه داده های آموزشی (90 درصد) و آزمایشی (10 درصد) نیز جهت ساخت مدل های امتیاز دهی اعتباری گروهی و مستقل استفاده شده و جهت ارزیابی الگوریتم های طبقه بندی فوق، از دو شاخص 1) دقت طبقه بندی و 2) AUC استفاده به عمل آمد. با کمک این شاخص ها، الگوریتم های طبقه بندی در امتیاز دهی اعتباری مشتریان بانک استفاده شد. در مدل های ضعیف، تعیین پارامترها در مرحله مدلسازی باید به دقت انجام شود.

همانطور که در بخش مقدمه بیان شد، مطالعات متعددی به استفاده از استراتژی های ترکیبی و گروهی در مسائل امتیاز دهی اعتباری پرداخته اند. آن ها از طبقه بندی کنند های مختلفی جهت حل مشکلات امتیاز دهی اعتباری بهره می برند. از الگوریتم های FS جهت دستیابی به عملکرد بالای مدل های طبقه بندی امتیاز دهی اعتباری استفاده شده با این حال، این مطالعات نیاز به رویکردی جامع برای شبیه سازی الگوریتم های FS در چهار چوب داده کاوی ترکیبی، دارند. در این رابطه، واضح است که یکی از ویژگی های بارز این چهار چوب، تعیین پارامترهای FS و مدل سازی مدل پیشنهادی می باشد. علاوه بر این، به خاطر استفاده از مجموعه داده های مختلف در مسائل امتیاز دهی اعتباری، تنها برخی از الگوریتم های FS با مجموعه داده های موجود، همخوانی دارند. علاوه بر این، می توان از الگوریتم های طبقه بندی متعددی جهت بررسی مسائل امتیاز دهی اعتباری، به شکل صحیح استفاده نمود. مدل پیشنهادی ما، می تواند مشکلات فوق را با درنظر گرفتن نقاط قوت مطالعات پیشین، به حداقل برساند.

4- نتایج و بحث و گفتگو:

در این بخش، مجموعه داده های بانک توسعه صادرات ایران، جهت ارزیابی مدل استفاده شده است. از نرم افزار داده کاوی Rapid Miner نیز جهت بررسی مدل استفاده شده است. در این نرم افزار، مقادیر مربوط به هر پارامتر در الگوریتم های FS به صورت پیش فرض انتخاب شده است.

در مدل پیشنهادی، بعد از گردآوری داده ها و پیش پردازش آن ها در مرحله نخست، از الگوریتم های FS جهت تعیین پارامترها و دقت طبقه بندی استفاده شده در ادامه، نتایج این مرحله شرح داده خواهد شد.

4.1 الگوریتم ژنتیکی و تعیین پارامترها:

در الگوریتم ژنتیک FS، پارامتر "اندازه جمعیت" تغییر یافته است. ماکریم تعداد مقادیر نسل ها، جهش ها و تبادلات به ترتیب 30، 01 و 5٪ می باشند. از خروجی FS نیز در مدل طبقه بندی SVM استفاده می شود. در جدول 1 نتایج فوق ارائه شده اند.

با توجه به این جدول، ویژگی های انتخاب شده از پارامتر اندازه جمعیت در طبقه بندی SVM، مورد استفاده قرار گرفته براین اساس، مقدار پارامتر فوق دارای دقت عملکرد مطلوبی بوده است. در جدول 1، دقت طبقه بندی و مقادیر AUC در مدل 1 به ترتیب 88.41 و 90.45 درصد بوده اند از این رو، بهتر است از ویژگی های انتخابی فوق در طبقه بندی مستقل و گروهی استفاده نمود. ویژگی های انتخابی به دست آمده توسط GA عبارتند از: نسبت دارایی های خالص به بدھی های غیر جاری، نرخ بهره سرمایه گذاری، تخفیف سهام، ریسک بازارهای هدف، عوامل فصلی، تاریخچه شرکت/ورشکستگی، آمار ثبت شده مدیران ارشد و نمره کیفی کل.

4.2 تعیین پارامترها و روش Relief

در روش Relief، تعدادی از ویژگی های انتخابی و نزدیک ترین همسایه ها تغییر یافته اند. از این ویژگی ها می توان جهت طبقه بندی SVM استفاده نمود. نتایج طبقه بندی در جدول 2 ذکر شده است.

شکل 2: نمودار کلی مدل پیشنهادی

جدول 1: تعیین پارامترها در الگوریتم FS مبتنی بر روش GA

| Model | Population size | Accuracy (%) | AUC (%) |
|-------|-----------------|--------------|---------|
| 1 | 5 | 88.41 | 90.45 |
| 2 | 10 | 87.70 | 90.17 |
| 3 | 15 | 88.41 | 90.13 |

جدول 2: تعیین پارامترها در FS مبتنی بر روش Relief

| مدل | تعداد ویژگی های انتخابی | تعداد همسایه | تعداد نزدیک ترین همسایه | دققت (%) | AUC (%) |
|-----|-------------------------|--------------|-------------------------|----------|---------|
| 1 | 10 | 5 | 21.46 | 50.00 | |
| 2 | 10 | 10 | 78.54 | 50.00 | |
| 3 | 10 | 15 | 78.54 | 50.00 | |
| 4 | 10 | 20 | 78.54 | 50.00 | |
| 5 | 10 | 25 | 78.54 | 50.00 | |
| 6 | 15 | 5 | 78.54 | 50.00 | |
| 7 | 15 | 10 | 78.54 | 50.00 | |
| 8 | 15 | 15 | 78.54 | 50.00 | |
| 9 | 15 | 20 | 78.54 | 52.00 | |
| 10 | 15 | 25 | 78.54 | 52.00 | |
| 11 | 20 | 5 | 78.54 | 50.00 | |
| 12 | 20 | 10 | 78.54 | 50.00 | |
| 13 | 20 | 15 | 78.54 | 50.00 | |
| 14 | 20 | 20 | 78.54 | 50.00 | |
| 15 | 20 | 25 | 78.54 | 50.00 | |

جدول 3: تعیین تعیین پارامترها در FS مبتنی بر روش معیار ضریب بهره اطلاعات:

| مدل | تعداد ویژگی های انتخابی | دققت (%) | AUC (%) |
|-----|-------------------------|----------|---------|
| 1 | 10 | 90.99 | 86.27 |
| 2 | 13 | 77.25 | 55.81 |
| 3 | 16 | 76.39 | 50.00 |
| 4 | 19 | 78.97 | 58.71 |
| 5 | 22 | 80.69 | 52.22 |
| 6 | 25 | 78.11 | 50.00 |

با توجه به جدول 2، مدل های 9 و 10 از عملکرد بالاتری در طبقه بندی SVM، برخوردار اند. مقادیر دقته و شاخص AUC نیز به ترتیب 78.54 و 52 درصد بوده اند. بنابراین، ویژگی مدل های 9 و 10 در ساخت مدل های طبقه بندی کننده می توانند مورد استفاده قرار گیرند. جدول 2 نشان می دهد که مقدار AUC در هر مدل (به استثناء 9 و 10) مساوی با یکدیگر بوده است. بعد از اجراء روش Relief، ویژگی های مهم انتخابی بدین صورت به دست آمده اند: شخصیت حقوقی، نمره کیفیت کل، عقاید کارشناسان اعتباری، نسبت دارایی ها، نسبت بدھی ها، نسبت دارایی های خالص به بدھی ها، نسبت دارایی خالص به دارایی غیرجاری، ضریب بهره سرمایه گذاری، سرمایه عملیاتی / سرمایه در گردش، عوامل فصلی، ریسک بازارهای هدف و تجربه کارکنان بانک.

جدول 4: تعیین پارامترها در FS مبتنی بر روش PCA

| Model | Number of factor | Accuracy (%) | AUC (%) |
|--------------|-------------------------|---------------------|----------------|
| 1 | 10 | 87.12 | 83.73 |
| 2 | 20 | 87.12 | 84.26 |
| 3 | 30 | 87.12 | 84.14 |
| 4 | 40 | 87.12 | 84.17 |
| 5 | 50 | 87.12 | 84.10 |


4.3 روش معیار ضریب بهره اطلاعات و تعیین پارامترها:

در روش معیار ضریب بهره اطلاعات FS، تنها تعدادی از ویژگی ها تغییر می کنند. از این ویژگی ها نیز در طبقه بندی SVM استفاده می شود. نتایج در جدول 3 موجوداند.

مطابق با این جدول، مدل 1 از عملکرد بالایی در طبقه بندی SVM برخوردار است. مقادیر مربوط به دقت و شاخص AUC به ترتیب 90.99 و 86.27 درصد بوده است. در ادامه، ویژگی های مدل 1 نیز جهت ساخت مدل طبقه بندی استفاده می شوند. با استفاده از روش معیار ضریب بهره اطلاعات، ویژگی های ذیل به دست آمده اند: نسبت بدھی ها، نمره کیفیت کل، شخصیت حقوقی، عقاید کارشناسان اعتباری، نسبت دارایی ها، نسبت دارایی های خالص به بدھی ها، نسبت بدھی های خالص به دارایی غیرجاری، ضریب بهره سرمایه گذاری و سرمایه عملیاتی/ سرمایه در گرددش.

4.4 تحلیل مولفه اساسی و تعیین پارامترها:

در روش کاهش ویژگی های PCA، تعداد عوامل تغییر یافته اند. ویژگی های انتخابی به دست آمده نیز در طبقه بندی SVM استفاده می شوند. جدول 4، نتایج مربوطه را نشان می دهد.




شکل 3: نتایج الگوریتم FS

مطابق با جدول 4، مدل 2 دارای عملکرد بالایی در طبقه بندی SVM است . مقادیر مربوط به دقت و شاخص AUC به ترتیب 87.12 و 84.26 درصد بوده بنابراین ویژگی های انتخابی مدل 2 در مدل طبقه بندی مورد استفاده قرار می گیرند. جدول 4 نشان می دهد که مقدار دقت در هر مدل با دیگری یکی بوده زیرا تغییر پارامتر "تعداد عوامل" باعث تغییری در مقدار دقت مدل ها نمی کند. انتخاب ویژگی PCA تنها با کمک 19 متغیر پیوسته در هنگام محاسبات و بعد از اجراء الگوریتم، امکان پذیر خواهد بود در نتیجه تعداد 13 متغیر جدید به دست خواهند آمد. این متغیرهای جدید با 19 متغیر دیگر ترکیب شده اند و میانگین اهمیت نسبی متغیرهای فوق باید به دقت محاسبه شده هرچند که وزن آن ها بیشتر از 15٪ بوده است. این متغیرهای عبارتند از: چرخه مطالبات، دارایی های جاری، نسبت بدھی به دارایی های غیر جاری، نمره کل کیفیت، نسبت بهره به سرمایه ثابت، بازده فروش، سرمایه در گردش یا سرمایه عملیاتی، نسبت بدھی های جاری به دارایی خالص و سود سهام تقسیم شده.

بعد از اجراء FS و تعیین پارامترها، جهت یافتن بهترین ویژگی ها، باید تمام الگوریتم های گروهی و مستقل در هر یک از مدل های FS (جداول 1-4) اجرا شوند. شکل 3، بهترین نتایج طبقه بندی برای هر الگوریتم FS را نشان می دهد به عنوان مثال، با استفاده از ویژگی های انتخابی GA در تمام الگوریتم ها، می توان گفت الگوریتم ANN-bagging از بهترین عملکرد با مقادیر دقت و AUC به ترتیب 87.4 و 90.1 درصد برخوردار است .

مطابق با شکل ۳، در تمام الگوریتم های ANN-bagging مدل طبقه بندی FS از عملکرد طبقه بندی بسیار مطلوبی بهره مند بوده علاوه بر این، مدل فوق که از الگوریتم PCA به دست آمده نسبت به سایر الگوریتم های دیگر، نتایج بسیار خوبی را به دنبال داشته است. مقادیر مربوط به دقت و AUC در بهترین الگوریتم به ترتیب ۸۸.۴ و ۹۰.۳ درصد بوده اند.

شکل ۴، میانگین مقادیر دقت و AUC در این ۴ الگوریتم های FS و در تمام الگوریتم های طبقه بندی، را نشان می دهد واضح است که PCA از عملکرد بهتری نسبت به سایر الگوریتم ها بر اساس دو شاخص دقت و مقدار AUC به ترتیب ۸۷.۸ و ۸۶.۲ درصد برخوردار بوده بنابراین با توجه به اشکال ۳ و ۴، ما از این الگوریتم جهت ساخت مدل های طبقه بندی گروهی و مستقل استفاده خواهیم کرد.



شکل ۴: نتایج الگوریتم های FS با توجه به میانگین دقت و AUC در تمام الگوریتم های طبقه بندی

| Accuracy (%) | AUC (%) |
|--------------|---------|
| 82.05 | 79.81 |

جدول ۵: بهترین مدل بیز

| Confidence for pruning | Minimal size for split | Accuracy (%) | AUC (%) |
|------------------------|------------------------|--------------|---------|
| 0.125 | 16 | 85.90 | 89.31 |

جدول ۶: بهترین مدل CART

| Learning rate | Epochs | Accuracy (%) | AUC (%) |
|---------------|--------|--------------|---------|
| 0.6 | 400 | 87.18 | 84.54 |

جدول 7: بهترین مدل ANN

| Kernel type | Coefficient | Accuracy (%) | AUC (%) |
|-------------|-------------|--------------|---------|
| RBF | 0 | 85.90 | 81.85 |

جدول 8: بهترین مدل SVM

بعد از انتخاب بهترین الگوریتم FS و تعیین پارامترهای آن، حال باید از آن در ساخت الگوریتم های طبقه بندی استفاده نمود. در ادامه، نتایج طبقه بندی همراه با پارامترهای تعیین شده برای هر الگوریتم ذکر خواهد شد. در برنامه Rapid Miner، تمام مقادیر پارامترها (به جزء پارامترهای تعیین شده) در هر دو طبقه بندی کننده مستقل و گروهی به صورت پیش فرض در نظر گرفته شده اند. در درخت تصمیم گیری CART، دو پارامتر "کمترین اندازه شکاف و آماده برای هرس" دارای مقدار 0-5٪ و 40-4٪ بوده اند. علاوه بر این، در مدل ANN، پارامترهای "تعداد دورها و میزان یادگیری" به ترتیب 4/6٪ و 400-600 تعیین شده اند. تعداد لایه های مخفی و سرعت حرکت شتاب نیز 1 و 2٪ انتخاب شده اند. شایان ذکر است که نوع لایه های ورودی و خروجی به ترتیب خطی و حلقی بوده اند. در SVM، پارامتر "نوع کرنل" به صورت زیر بیان شده است: 1- خطی 2- چند جمله ای و 3- RBF. همچنین پارامتر ضریب ثابت نیز بین 100-100 و سایر پارامترها به صورت پیش فرض انتخاب شده اند. در مدل آدابوست، پارامتر تکرار دارای مقادیر 8، 5 و 10 بوده در مدل bagging، پارامتر نسبت نمونه ها نیز بین 7٪ تا 1٪ انتخاب شده در درخت تصادفی، ارامتر تعداد درخت ها بین 8-10 بوده و کمترین اندازه شکاف در دو مرحله بین 4-15 در نظر گرفته شده است. پارامتر آماده برای هرس در مرحله بین 2٪ تا 5٪ انتخاب شده، دو پارامتر مینیمم بهره و ماکزیمم مق نیز 1٪ و 20٪ انتخاب شده اند. در مدل stacking، بهترین یادگیرنده ها عبارتند از: ANN، SVM-ANN و CART-ANN. بعد از تعیین پارامترها در جداول 5-12 نشان داده شده اند.

| Row | Model | Iterations | Accuracy (%) | AUC (%) |
|-----|----------------------|------------|--------------|---------|
| 1 | ANN-AdaBoost | 8 | 91.03 | 91.20 |
| 2 | CART-AdaBoost | 8 | 83.33 | 84.72 |
| 3 | Naïve Bayes-AdaBoost | 8 | 82.05 | 83.84 |
| 4 | SVM-AdaBoost | 8 | 85.90 | 75.28 |

جدول 9: بهترین مدل آدابوست

| Row | Model | Sample ratio | Accuracy (%) | AUC (%) |
|-----|---------------------|--------------|--------------|---------|
| 1 | ANN-bagging | 1 | 88.46 | 90.28 |
| 2 | CART-bagging | 1 | 84.62 | 89.31 |
| 3 | Naïve Bayes-bagging | 0.7 | 83.33 | 83.70 |
| 4 | SVM-bagging | 0.8 | 85.90 | 81.39 |

جدول 10: بهترین مدل bagging

در ادامه، شکل ۵ به مقایسه الگوریتم های مستقل و گروهی با توجه به دو شاخص دقت AUC خواهد پرداخت. الگوریتم آدابوست در زمینه امتیاز دهی اعتباری بهترین الگوریتم طبقه بندی، شناخته شده است و مقادیر مربوط به دقت و شاخص AUC در آن به ترتیب 91.2 و 91 درصد بوده اند. الگوریتم ANN-bagging نیز جایگاه بعدی را به خود اختصاص داده است. الگوریتم های بیز و SVM-آدابوست به خاطر مقادیر پایین دو شاخص دقت و شاخص AUC، جزء بدترین الگوریتم ها شناخته شده اند.

دو شکل 6 و 7 به مقایسه نتایج دقت طبقه بندی و شاخص AUC در الگوریتم های طبقه بندی اشاره دارند. به منظور مقایسه الگوریتم های طبقه بندی، دو شاخص میانگین دقت و میانگین AUC با یکدیگر مقایسه شده که نتایج آن در شکل 8 قابل مشاهده است.

جدول 11: بهترین مدل جنگل تصادفی

| Confidence for pruning | Minimal size for split | Number of trees | Accuracy (%) | AUC (%) |
|------------------------|------------------------|-----------------|--------------|---------|
| 0.2 | 4 | 10 | 87.18 | 89.12 |

جدول 12: بهترین مدل stacking


| Accuracy (%) | AUC (%) |
|--------------|---------|
| 85.90 | 82.41 |

بنابراین می توان چنین نتیجه گرفت که:

1. در الگوریتم های FS، الگوریتم PCA بهترین عملکرد را نسبت به سایر الگوریتم ها داشته بنابراین

ویژگی های انتخابی از این الگوریتم توانسته دقت طبقه بندی و شاخص AUC را بهبود بخشد (دو

شکل 4 و 3)



شکل 5: نتایج الگوریتم های طبقه بندی بر حسب دقت و شاخص AUC

2. مطابق با شکل 8، الگوریتم های یادگیری گروهی از عملکرد مطلوب ترین نسبت به الگوریتم های

مستقل بهره مند اند. علاوه بر این، در شکل 6 و 7، دقت و شاخص AUC در سطح مطلوبی قرار دارد

اما باید توجه داشت که الگوریتم مستقل قادر است به خوبی با الگوریتم گروهی ترکیب شود به عنوان

(اشکال 6-8) مثال، SVM قادر به ترکیب با الگوریتم گروهی نخواهد بود.

3. مطابق با شکل 7 و ANN.8 نسبت به سایر روش های یادگیری دیگر همانند بیز و SVM (به استثناء

CART) از نتایج مطلوب تری برخوردار بوده است. مطابق با شکل ANN.6 از دقت طبقه بندی بهتری


نسبت به سایرین بهره مند است . همچنین ANN-آدابوست نیز نسبت به سایر الگوریتم مستقل و

گروهی دیگر، بهترین عملکرد را به خود اختصاص داده است(اשکال 6-8). به عبارت بهتر، بهترین طبقه


بندی کننده مستقل در الگوریتم های یادگیری ANN است.

4. مطابق با شکل 8، الگوریتم های بیز، بیز-آدابوست و بیز-bagging، از بدترین عملکرد برخوردار بوده

همچنین الگوریتم بیز در استراتژی یادگیری مستقل، هیچ گونه نقش قابل توجهی را ایفا نمی کند.



شکل 6: نتایج الگوریتم های طبقه بندی بر حسب دقت



شکل 7: نتایج الگوریتم های طبقه بندی بر حسب شاخص AUC

5- نتیجه گیری و پیشنهادات:

در این مقاله، مدل امتیاز دهنده اعتباری ترکیبی جدیدی از الگوریتم های FS و طبقه بندی کننده های یادگیری گروهی و مستقل در بانک توسعه صادرات ایران مورد استفاده قرار گرفتند. در مدل پیشنهادی، در وهله اول، تعداد 4 الگوریتم FS جهت دستیابی به مجموعه داده مناسب با دقت طبقه بندی مطلوب، انتخاب شدند. الگوریتم FS که بهترین دقت طبقه بندی را برای SVM به ارمغان می آورد نیز در این مدل انتخاب گردید. علاوه بر این، از مرحله تعیین پارامترها جهت دستیابی به بهترین نتایج در الگوریتم FS استفاده شد. در این بین، روش هایی همچون GA, PCA, FS و معیار بهره اطلاعات به عنوان بهترین گزینه ها انتخاب شدند. پس از انتخاب بهترین الگوریتم FS از الگوریتم های طبقه بندی در مدل استفاده شده و در مدل های ضعیف تر نیز، از روش FS جهت مدلسازی استفاده به عمل آمد. اشکال 6-8 نشان می دهند که الگوریتم ANN-آدابوست بهترین عملکرد را در حوزه امتیاز دهنده اعتباری از آن خود کرده اند همچنین الگوریتم های SVM-آدابوست، بیز و بیز-آدابوست بدترین عملکرد را بر حسب شاخص های ارزیابی، در اختیار داشته اند.

مدل ترکیبی ما جهت نشان دادن شاخص های مالی به مشتریان شایسته، از روش امتیاز دهنده اعتباری استفاده می کند. علاوه بر این، جهت برطرف نمودن مشکلات موجود، رویکردی جامع همراه با تعداد زیادی از الگوریتم های FS و طبقه بندی و نیز چهارچوب داده کاوی ترکیبی جهت افزایش سطح اطمینان مدل های امتیاز دهنده اعتباری، ارائه شده اند.

بر این اساس، می توان چنین نتیجه گرفت که الگوریتم های طبقه بندی گروهی نسبت به الگوریتم های مستقل در بررسی امتیاز دهنده اعتباری داده کاوی از عملکرد مطلوبتری برخوردار اند. همچنین مطالعات آتی باید به بررسی روش های ترکیبی در زمینه امتیاز دهنده اعتباری نیز توجه داشته باشند. این مقاله از یک مدل ترکیبی جهت شبیه سازی الگوریتم های FS استفاده نموده و دو الگوریتم گروهی و مستقل را با یکدیگر مقایسه نموده است. نتایج نشان دادند مدل های ترکیبی نسبت به مستقل، عملکرد قابل توجهی دارند بنابراین جهت دستیابی به عملکرد بالا، باید تعیین پارامترها برای FS و الگوریتم های طبقه بندی به دقت انجام شود. در واقع، نتایج بیان

کرده اند روش های غیر پارامتری امتیاز دهی اعتباری نسبت به روش های پارامتری،نمایش بهتری از خود نشان داده اند.

در مطالعات آینده،سایر الگوریتم های FS نظیر الگوریتم تبرید شبیه سازی شده SA،PSO،LDA،F،نمره کلی مورچه ها و تئوری مجموعه های راف نیز باید بررسی شوند. همچنین،سایر الگوریتم های طبقه بندی از جمله LR-CHAID-KNN،نیز باید بررسی شده و نتایج هر یک با دیگری مقایسه شوند. شایان ذکر است که مرحله تعیین پارامترها در این مقاله جهت دستیابی به نتایج بهتر می تواند توسعه یابد.بنابراین الگوریتم های یادگیری گروهی باید با سایر الگوریتم های دیگر در آینده مقایسه شوند.پیشنهاد می کنیم در میان انواع مختلف مدل های ترکیبی امتیاز دهی اعتباری،از دو نوع مدل استفاده کنید که عبارتند از: 1) تکنیک های طبقه بندی هر کلاستر با کمک الگوریتم های اجرا شده در مجموعه داده های موجود و 2) رویکردهای ترکیبی 2 مرحله ای همراه با دو الگوریتم طبقه بندی.



این مقاله، از سری مقالات ترجمه شده رایگان سایت ترجمه فا میباشد که با فرمت PDF در اختیار شما عزیزان قرار گرفته است. در صورت تمایل میتوانید با کلیک بر روی دکمه های زیر از سایر مقالات نیز استفاده نمایید:

✓ لیست مقالات ترجمه شده

✓ لیست مقالات ترجمه شده رایگان

✓ لیست جدیدترین مقالات انگلیسی ISI

سایت ترجمه فا؛ مرجع جدیدترین مقالات ترجمه شده از نشریات معترض خارجی