

پیش بینی درماندگی مالی شرکت های پذیرفته شده در فرابورس و بورس اوراق بهادار تهران با استفاده از رگرسیون لجستیک لاسو

محمد نمازی^۱

شهلا ابراهیمی^۲

چکیده

توانایی پیش بینی درماندگی مالی شرکت برای تک تک واحدهای تجاری و همچنین، برای کل اقتصاد مهم است. از این رو، هدف این مقاله، کشف درماندگی مالی بالقوه و هشدار زود هنگام درماندگی مالی قریب الوقوع شرکت های پذیرفته شده در فرابورس و بورس اوراق بهادار است. بدین منظور، دامنه گسترده ای از ویژگی ها از جمله متغیرهای حسابداری تعهدی، حسابداری نقدی، بازار سهام، مکانیسم های حاکمیت شرکتی و شاخص های اقتصاد کلان برای پیش بینی درماندگی مالی شرکت های نمونه شناسایی شده اند. نمونه نهایی شامل ۴۲۱ شرکت و در نتیجه، ۳۶۷۰ شرکت-سال مشاهده است. سپس، داده آماده شده با استفاده از نسبت ۷۰ به ۳۰ به مجموعه داده آموزشی و آزمایشی تفکیک شد.

در این پژوهش، تکنیک های پیش پردازش داده یادگیری ماشین نظیر استانداردسازی نمره Z ، وان-هات انکدینگ، اعتبارسنجی متقابل K لایه طبقه ای، همراه با مهندسی ویژگی برای بهبود عملکرد طبقه بندی کننده بکار گرفته شدند. روش اعتبارسنجی متقابل K لایه طبقه ای با $(K=5)$ برای برآورد عملکرد پیش بینی مدل طی مرحله آموزش استفاده شد. طی مرحله آموزش، میزان سازی ابرپارامتر مدل با استفاده از جستجوی حرص انجام شد. افزون بر این، رویکرد فریادگیری حساس به هزینه همراه با معیار مختص مسائل نامتوازن یعنی نمره $F1$ برای غلبه بر مسأله نامتوازی افراطی کلاس ها استفاده شده است. بر اساس نتایج تجربی، مدل لجستیک لاسو به نمره $F1$ ، ضریب همبستگی متیوز، فراخوانی و دقتی به ترتیب برابر با 0.50 ، 0.73 و 0.38 بر روی مجموعه آموزشی دست یافت. سرانجام، مدل پیشنهادی بر روی مجموعه آزمایشی کنار گذاشته شده آزمون شد که به نمره $F1$ ، ضریب همبستگی متیوز، فراخوانی و دقتی به ترتیب برابر با 0.51 ، 0.51 ، 0.73 و 0.38 بر روی مجموعه آزمایشی منجر شد.

واژگان کلیدی: پیش بینی درماندگی مالی، رگرسیون لجستیک لاسو، یادگیری ماشین، داده کاوی، بورس اوراق بهادار تهران.

طبقه بندی موضوعی: M40, C19, E44, G34, G38, G33

۱. استاد حسابداری دانشگاه شیراز، ایران mnamazi@rose.shirazu.ac.ir

۲. کارشناس ارشد مدیریت مالی دانشگاه شهید بهشتی - نویسنده مسئول - shebrahimi_3622@yahoo.com

۱- مقدمه

درماندگی اقتصادی به معنای ناتوانی شرکت در کسب منابع کافی برای داوم عملیات معمولش است. عواملی نظیر هزینه‌های زیاد، کاهش تقاضای مشتریان و مدیریت مالی ضعیف می‌تواند موجب درماندگی اقتصادی شود. ورشکستگی یکی از پیامدهای احتمالی درماندگی اقتصادی شرکت است. سایر پیامدهای درماندگی اقتصادی عبارت‌اند از انحلال، تصفیه، ادغام، تجدید ساختار یا تداوم عملیات. بنا به گفته کورمایر و همکاران (۱۹۹۵: ۲۰۳) هر یک از این رویدادها بیانگر پایان شرکت است. پایان شرکت به عنوان عدم تداوم اقتصادی تعریف می‌شود. ارائه مدلی برای پیش‌بینی هر یک از این پیامدهای بسیار متفاوت، مسأله بسیار دشواری است؛ زیرا شناسایی و تعیین زمان هر یک از این رویدادها اغلب به راحتی قابل تعیین نیست (Lensberg, Eilifsen & McKee, 2006: 677-679).

در شرایط اقتصادی کنونی، سیستم‌های هشدار ورشکستگی زود هنگام به صورت ابزارهای با اهمیت کلیدی درآمده‌اند؛ زیرا توان بالقوه آن‌ها جهت اجتناب از زیان‌رسانی به سهامداران، بستانکاران، مدیران و سایر اشخاص ذینفع موجب تضمین ثبات اقتصادی می‌شود. از اواخر دهه ۱۹۶۰، روش‌های زیادی برای ارائه سیستم‌های پیش‌بینی ورشکستگی ارائه شده است. بیشتر این روش‌ها دارای این ویژگی مشترک هستند که به تکنیک‌های آماری یا هوشمند چندمتغیره‌ای تکیه می‌کنند که متغیرهای ورودی آن عمدتاً ویژگی‌های مالی شرکت‌ها است (Andrés, Landajo & Lorca, 2012: 67).

نسبت‌های مالی به طور گسترده‌ای در متون پیشین برای پیش‌بینی ورشکستگی مورد استفاده قرار گرفته‌اند (Xu, Fu & Pan, 2019: 1). دسترسی به نسبت‌های مالی به دلیل قابلیت دسترسی به آن‌ها در صورت‌های مالی شرکت‌ها، ساده است. استفاده از نسبت‌های مالی در تمایز بین شرکت‌های درمانده و سالم از اواسط دهه ۱۹۳۰ با پژوهش ویناکار و اسمیت^۳ (۱۹۳۵) در براه بکارگیری نسبت‌های مالی برای ارزیابی سلامت مالی شرکت‌ها شروع شد. اگرچه نسبت‌های مالی می‌توانند بیانگر سلامت مالی شرکت باشند، کیفیت این نسبت‌های در معرض تهدیدهای جدی در خصوص سودمندی آن‌ها است؛ زیرا این اطلاعات ممکن است دستکاری شوند (Waqas & Md-Rus, 2018: 3). نسبت‌های مالی، داده‌های تاریخی هستند که تفاوت مالی شرکت‌ها را به موقع منعکس نمی‌کنند. به ویژه، زمانی که محیط عملیات شرکت به سرعت تغییر می‌کند، نقش نسبت‌های مالی در پیش‌بینی درماندگی مالی احتمالاً کاهش خواهد یافت (Xu et al., 2019: 1).

³ Smith & Winakor

همچنین، جریان‌های نقدی نیز برای بقای شرکت مهم هستند. تئوری جریان نقدی بیانگر این است که شرکت در صورتی از نظر مالی توانمند خواهد بود که بتواند جریان نقدی کافی از محل عملیات خود ایجاد کند و هنگامی که نتواند جریان نقدی ورودی کافی از محل عملیات خود ایجاد کند، درمانده خواهد شد (Waqas & Md-Rus, 2018: 3). از دیدگاه شهودی، شرکت‌های دارای جریان‌های نقدی کمتر و پرنوسان تر و ذخایر دارایی‌های نقد کمتر جهت پوشش کمبودهای بالقوه باید از احتمال درماندگی بیشتری برخوردار باشند (Klobucnik et al., 2017: 9).

توانایی پیش‌بینی این مدل‌ها در چند دهه گذشته تنزل یافته است. از این رو، پژوهشگران استدلال می‌کنند که متغیرهای توضیحی بیشتری در مدل‌ها گنجانده شوند. کاهش توانایی پیش‌بینی این متغیرها را می‌توان به عواملی نظیر ادراک سرمایه‌گذاران و اعتباردهندگان از افزایش اختیار مدیران در محیط‌های حسابداری ارزش منصفانه نسبت داد (Cenciarelli et al, 2018: 2). برای غلبه بر بسیاری از محدودیت‌های مدل‌های مبتنی بر حسابداری و در نظر گرفتن ماهیت ناهمگن درماندگی مالی، متون اخیر دربرگیرنده اطلاعات خاصی از بازار سهام نیز است (Klobucnik, Miersch & Sievers, 2017: 7). منطق تئوریک معیارهای سنجش قیمت بازار، جذاب است. صورت‌های مالی دارای چندین محدودیت اساسی هستند. برای نمونه، این صورت‌ها گذشته‌نگر هستند و بر مبنای مفروضات مداوم فعالیت و محافظه‌کاری تهیه شده‌اند که سودمند بودن آن‌ها را محدود می‌کند. افزون بر این، داده‌های صورت‌های مالی دربرگیرنده اثرات نوسان نیستند. اثرات نوسان می‌تواند در مدل‌های پیش‌بینی ورشکستگی شرکت دارای ارزش پیش‌بینی باشد. مهم‌تر آنکه ارزش بازار سهام نشان‌دهنده مبلغی است که ارزش دارایی‌ها می‌تواند کاهش یابد و همچنان دارایی‌ها برای پوشش ارزش فعلی پرداخت‌های بدهی کافی باشد (Jones, 2017: 6).

افزون بر این، رسوایی‌های مالی اخیر انرون و وردکام شواهدی است دال بر اینکه ساختارهای حاکمیتی ضعیف، عامل کلیدی دستکاری داده‌های مالی و افزایش احتمال ورشکستگی است. بنابراین، حاکمیت شرکتی دارای توان بالقوه تأثیرگذاری بر عملکرد شرکت و سوق آن به درماندگی است (Shah, 2016: 25).

لازم به ذکر است که شرکت‌ها نمی‌توانند بر وضعیت کلی اقتصاد کشور و سیاست‌های اقتصاد کلان مقام‌های دولتی تأثیر بگذارند؛ اما این عوامل بر وضعیت مالی شرکت نظیر نقدینگی و توانایی پرداخت آن تأثیر می‌گذارند. در نتیجه، شاخص‌های مالی شرکت حاوی اطلاعات کافی درباره وضعیت اقتصادی پیش روی مدیریت شرکت و سرمایه‌گذاران نیستند. از این رو، بکارگیری

شاخص های اقتصاد کلان نیز توصیه می شود (Fontaine Rezende, Montezano, Nascimento)
 .(de Oliveira, & Lameira, 2017: 394

به دلیل عدم وجود تئوری ورشکستگی اقتصادی زیربنایی، جستجو برای مدل های پیش بینی ورشکستگی صحیح تر کماکان در زمینه پیش بینی ورشکستگی به عنوان یک آرمان مطرح است. در حقیقت، پیش بینی ورشکستگی را می توان در قالب مسأله طبقه بندی در نظر گرفت (Chen et al., 2011: 1348). طبقه بندی به معنای تفکیک مجموعه های متمایزی از موضوعات یا مشاهدات و تخصیص موضوعات یا مشاهدات به گروه های تعریف شده قبلی است (Jo & Han, 1996: 415). تمامی پژوهش های داخلی و بسیاری از پژوهش های خارجی پیش بینی ورشکستگی و درماندگی مالی (برای نمونه، آلتمن^۴، ۱۹۶۸؛ پندهارکار^۵، ۲۰۰۵؛ جاردین^۶، ۲۰۱۰) از روش نمونه گیری جفت تطبیقی استفاده کرده اند. عیب رویکرد تطبیق این است که بررسی اثرات بخش صنعت، اندازه شرکت یا سال ورشکستگی بر احتمال ورشکستگی امکان پذیر نیست (Lennox, 1999: 348; Chancharat, 2008: 116). دست کم، به نظر می رسد که گنجاندن این متغیرها به عنوان پیش بینی کننده، سودمندتر از بکارگیری آن ها برای اهداف تطبیق باشد (Ohlson, 1980: 112). افزون بر این، استفاده از نمونه های با اندازه کوچک می تواند به برآزش بیش از اندازه منجر شود (Lennox, 1999: 348; Chancharat, 2008: 116). تا کنون، هیچ کدام از پژوهش های داخلی و خارجی، فهرست جامعی از انواع متغیرهای پیش بینی کننده درمانده مالی شامل متغیرهای مبتنی بر حسابداری تعهدی، حسابداری نقدی، بازار، حاکمیت شرکتی و اقتصاد کلان را به صورت همزمان بکار نگرفته اند. همچنین، هیچ کدام از پژوهش های داخلی از نمونه آزمایشی کنار گذاشته شده استفاده نکرده اند. بنابراین، توازن بین واریانس و سوگیری^۷ مدل مورد ارزیابی قرار نگرفته است. همچنین، هیچ یک از پژوهش های داخلی و خارجی پیش بینی درماندگی مالی به تنظیم ابرپارامترهای^۸ مدل نپرداخته اند و معیارهای ارزیابی عملکرد محدودی را برای ارزیابی مدل پیشنهادی خود ارائه کرده اند. افزون بر این، مدل های پیشنهادی در پژوهش های داخلی و برخی پژوهش های خارجی، به دلیل بکارگیری نمونه های کوچک، عدم انتخاب تصادفی نمونه و انتخاب جانبدارانه شرکت های دارای عملکرد بسیار خوب یا بسیار ضعیف،

4 Altman

5 Pendharkar

6 Jardín

7 Bias

8 Hyperparameters

عدم کنارگذاری بخشی از داده به عنوان داده آزمایشی و انجام پیش‌پردازش و انتخاب ویژگی اولیه بر روی کل داده، در معرض برآزش بیشتر از اندازه مدل قرار دارند.

از این رو، هدف این پژوهش، ارائه هشدار زودهنگام درماندگی مالی شرکت‌های پذیرفته شده در بورس اوراق بهادار تهران با استفاده از داده‌های مبتنی بر ترازنامه و صورت سود (زیان)، صورت گردش وجوه نقد، بازار سهام و نقدشوندگی، حاکمیت شرکتی و متغیرهای کلان اقتصادی به ذینفعان است تا آن‌ها بتوانند اقدامات مقتضی جهت پیشگیری از درماندگی مالی و همچنین، کاهش هزینه‌ها و زیان‌های ناشی از درماندگی مالی انجام دهند. پرسش‌های مهمی که در اینجا مطرح می‌شوند، این است که کدام یک از انواع متغیرهای حسابداری، جریان وجوه نقد، اطلاعات بازار و نقدشوندگی، حاکمیت شرکتی و اقتصاد کلان، بهترین متغیرهای پیش‌بینی کننده درماندگی مالی هستند؟ در حقیقت، باید تعیین نمود که اثربخش‌ترین مدل یادگیری ماشین جهت پیش‌بینی درماندگی مالی چیست؟ انگیزه اصلی این پژوهش، پاسخ به پرسش‌های بالا است.

۲- مروری بر پیشینه پژوهش

۲-۱- پیشینه پژوهش‌های داخلی

اعتمادی، انواری رستمی و فرج زاده دهکردی (۲۰۰۹) با بکارگیری برنامه‌نویسی ژنتیک و تحلیل تشخیصی چندمتغیره به ارائه مدلی برای پیش‌بینی ورشکستگی شرکت‌های پذیرفته شده در بورس اوراق بهادار تهران پرداختند. نمونه مورد بررسی آن‌ها شامل ۷۲ شرکت ورشکسته و ۷۲ شرکت غیرورشکسته طی دوره زمانی ۱۹۹۸-۲۰۰۸ بود. مدل برنامه‌نویسی ژنتیک آن‌ها به نرخ صحتی برابر با ۹۴٪ و ۹۰٪ به ترتیب در خصوص نمونه‌های آموزشی و آزمایشی دست یافت در حالی که نرخ صحت مدل تحلیل تشخیصی چندمتغیره در نمونه‌های آموزشی و آزمایشی به ترتیب برابر با ۷۷٪ و ۷۳٪ بود. آزمون مک‌نمار نیز نشان داد که عملکرد رویکرد برنامه‌نویسی ژنتیک در خصوص مسأله ورشکستگی شرکت، بهتر از عملکرد تحلیل تشخیصی چندمتغیره است.

مخاطب رفیعی، منظری و بوستانیان (۲۰۱۱) به پیش‌بینی ورشکستگی شرکت‌های پذیرفته شده در بورس اوراق بهادار تهران با استفاده از شبکه عصبی، الگوریتم ژنتیک و تحلیل تشخیصی چند متغیره پرداختند. نتایج حاصل از آزمون این مدل‌ها بر روی نمونه‌ای شامل ۵۸ شرکت ورشکسته و ۱۲۲ شرکت غیرورشکسته طی سال مالی منتهی به ۲۰۰۸ بیانگر این است که شبکه عصبی، الگوریتم ژنتیک و تحلیل تشخیصی چند متغیره به ترتیب دارای بیشترین صحت پیش‌بینی بودند.

آشوری و محمدی (2011) با استفاده از تکنیک‌های درخت طبقه‌بندی و رگرسیون و شبکه عصبی پرسپترون چند لایه به ارائه مدلی برای پیش‌بینی ورشکستگی شرکت‌های پذیرفته شده در بورس سهام تهران پرداختند. نمونه مورد بررسی آن‌ها شامل ۶۶ شرکت ورشکسته و ۶۶ شرکت غیرورشکسته طی دوره زمانی ۲۰۰۸-۱۹۹۸ بود. آن‌ها عملکرد شبکه عصبی پرسپترون چند لایه در صورت عدم بکارگیری درخت طبقه‌بندی و رگرسیون برای انتخاب متغیرهای ورودی را با عملکرد شبکه عصبی پرسپترون چند لایه در صورت بکارگیری درخت طبقه‌بندی و رگرسیون برای انتخاب متغیرهای ورودی مقایسه نمودند. آن‌ها دریافتند که بکارگیری درخت طبقه‌بندی و رگرسیون تنها موجب کاهش خطای نوع ۲ شده و تأثیر مثبتی بر خطای نوع ۱ و صحت پیش‌بینی مدل ندارند.

خواجهی و قدیریان آرانی (۱۳۹۶) به بررسی نقش توانایی مدیریت در بهبود عملکرد مدل‌های پیش‌بینی بحران مالی مبتنی بر نسبت‌های حسابداری پرداختند. نتایج حاصل از بکارگیری الگوریتم‌های طبقه‌بندی کننده بوستینگ، بگینگ و جنگل‌های چرخشی بر روی نمونه‌ای شامل ۲۰۱ سال-شرکت بحران‌زده و ۲۰۱ سال-شرکت سالم پذیرفته شده در بورس اوراق بهادار تهران در دوره زمانی ۱۳۹۴-۱۳۸۵ بیانگر این است که افزودن متغیر توانایی مدیریت به نسبت‌های حسابداری موجب بهبود معنادار عملکرد الگوریتم‌های بکار گرفته شده می‌شود. به ویژه، هر چقدر که فاصله دوره زمانی پیش‌بینی با وقوع بحران مالی بیشتر باشد، گنجاندن توانایی مدیریت در مدل‌های پیش‌بینی بحران مالی به میزان بیشتری عملکرد آن‌ها را بهبود می‌دهد.

۲-۲- پیشینه پژوهش‌های خارجی

أهلسن (۱۹۸۰) با استفاده از تحلیل لججیت به محاسبه احتمال ورشکستگی ۱۰۵ شرکت ورشکسته و ۲۰۵۸ شرکت غیرورشکسته طی دوره ۱۹۷۶-۱۹۷۰ پرداخت. نتایج حاصل از آزمون مدل وی بیانگر این بود که صحت عملکرد مدل پیشنهادی در یک سال قبل از ورشکستگی برابر با ۹۶/۱۲٪ است. افزون بر این، چهار عامل اندازه شرکت، ساختار مالی بر حسب اهرم، معیار عملکرد و نقدینگی جاری برای ارزیابی احتمال ورشکستگی معنادار هستند.

زمیجونسکی (Zmijewski, 1984) تأثیر جانبداری نمونه‌گیری جفت تطبیقی و جانبداری انتخاب نمونه‌های دارای داده‌های کامل بر مدل پیش‌بینی ورشکستگی را مورد بررسی قرار داد. نتایج حاصل از آزمون مدل پروبیت پیشنهادی وی بر روی نمونه‌های مختلف نشان‌دهنده این بود که پیش‌بینی مدل دارای نمونه جفت تطبیقی جانبدارانه است، این جانبداری با افزایش احتمال ورشکستگی نمونه به

احتمال ورشکستگی جامعه کاهش می‌یابد و جانبداری در صورت بکارگیری تکنیک‌های تخمین مناسب کاهش می‌یابد. همچنین، نتایج وی موید وجود جانبداری در مدل‌های پیش‌بینی ورشکستگی است که شرکت‌های دارای داده‌های ناقص را کنار می‌گذارند و صرفاً شرکت‌های دارای داده‌های کامل را بررسی می‌کنند. با این وجود، در هر دو مورد، نتایج بیانگر تغییر معنادار در نرخ طبقه‌بندی و پیش‌بینی کلی نبود و صرفاً نرخ پیش‌بینی و طبقه‌بندی هر یک از گروه‌های ورشکسته و غیرورشکسته به گونه معناداری تحت تأثیر قرار می‌گرفت.

تینکو و ویلسان (Tinoco & Wilson, 2013) به بررسی مطلوبیت ترکیب داده‌های حسابداری، داده‌های مبتنی بر بازار و داده‌های اقتصاد کلان برای پیش‌بینی درماندگی مالی شرکت‌های پذیرفته شده در بورس سهام بریتانیا پرداختند. نتایج مدل‌های برآوردی آن‌ها با استفاده از رگرسیون لجستیک بر روی نمونه‌ای شامل ۲۳۲۱۸ شرکت-سال طی دوره زمانی ۱۹۸۰-۲۰۱۱ بیانگر این است که گنجاندن متغیرهای بازار و اقتصاد کلان در مدل داده‌های حسابداری موجب بهبود عملکرد مدل می‌شود.

مای، تیان، لی و ما (Tian et al., 2019) توانایی مدل‌های یادگیری عمیق برای پیش‌بینی ورشکستگی با استفاده از داده‌های مبتنی بر حسابداری، داده‌های مبتنی بر بازار و داده‌های ساختار نیافته برگرفته از تجزیه و تحلیل و بحث مدیریت در فرم K-10 را مورد بررسی قرار دادند. مجموعه داده مورد بررسی آن‌ها شامل ۱۱۸۲۷ شرکت ایالات متحده آمریکا یا ۹۴۹۹۴ سال-شرکت طی دوره زمانی ۲۰۱۴-۱۹۹۴ است که از این بین ۴۷۷ شرکت-سال ورشکسته و مابقی شرکت-سال‌ها سالم است. یافته‌های آن‌ها بیانگر این است که هنگام بکارگیری داده‌های عددی به عنوان پیش‌بینی کننده، هیچ دلیل متقاعدکننده‌ای برای استفاده از یادگیری عمیق وجود ندارد و مدل‌های داده‌کاوی سنتی به ویژه، مدل‌های غیرخطی نظیر ماشین بردار پشتیبان و جنگل تصادفی از توانایی مشابهی برخوردارند. افزون بر این، در صورت بکارگیری داده‌های متنی به عنوان پیش‌بینی کننده، عملکرد مدل یادگیری عمیق با استفاده از لایه‌های تعبیه‌ای^۹ بهتر از رگرسیون لجستیک، ماشین بردار پشتیبان و جنگل تصادفی است. مهم‌تر اینکه آن‌ها دریافتند که هنگام پیش‌بینی ورشکستگی، داده‌های متنی می‌تواند مکمل داده‌های سنتی مبتنی بر حسابداری و داده‌های مبتنی بر بازار باشد و صحت پیش‌بینی مدل یادگیری عمیق در صورت بکارگیری ورودی‌های عددی همراه با ورودی‌های متنی بیشتر از سایر مدل‌ها است.

۳- پرسش‌های پژوهش

با توجه به پیشینه و مبانی نظری، این پژوهش به بررسی این می‌پردازد که:

- ۱- آیا متغیرهای حسابداری، جریان وجوه نقد، بازار و نقدشوندگی، حاکمیت شرکتی و اقتصاد کلان می‌توانند بین شرکت‌های درمانده مالی و شرکت‌های موفق مالی تمایز ایجاد کنند؟ به بیان دقیق‌تر، آیا این متغیرها، پیش‌بینی‌کننده درماندگی مالی هستند؟
- ۲- کدام یک از متغیرهای حسابداری، جریان وجوه نقد، بازار و نقدشوندگی، حاکمیت شرکتی و اقتصاد کلان، برای استفاده‌کنندگان در پیش‌بینی درماندگی مالی مفید هستند؟

۴- روش پژوهش

۴-۱- نوع مطالعه و روش بررسی پرسش‌ها

از آنجا که این پژوهش، مبتنی بر داده است و نتایج آن از طریق مشاهده قابل تأیید است، در قالب پژوهش تجربی قرار می‌گیرد (Kothari, 2004: 4). افزون بر این، با توجه به اینکه درصدد پاسخگویی به سؤال‌های دنیای واقعی است، کاربردی (Johnson & Christensen, 2014: 52-53) و به دلیل بکارگیری داده‌های کمی، در زمره پژوهش کمی محض جای می‌گیرد (Johnson & Christensen, 2014: 81). همچنین، این پژوهش، پژوهش غیرآزمایشی طولی (آینده‌نگر) پیش‌بینی‌کننده است. غیرآزمایشی از این جهت که هیچ‌گونه دست‌کاری یا تخصیص تصادفی وجود ندارد (Belli, 2009: 60). به دلیل جمع‌آوری داده‌های هر شرکت در چندین دوره زمانی، نیز پژوهش طولی از نوع پنل است (Johnson & Christensen, 2014: 546). پیش‌بینی‌کننده به این دلیل که درصدد پیش‌بینی متغیر هدف بر مبنای چندین متغیر پیش‌بینی‌کننده است (Johnson & Christensen, 2014: 548-549).

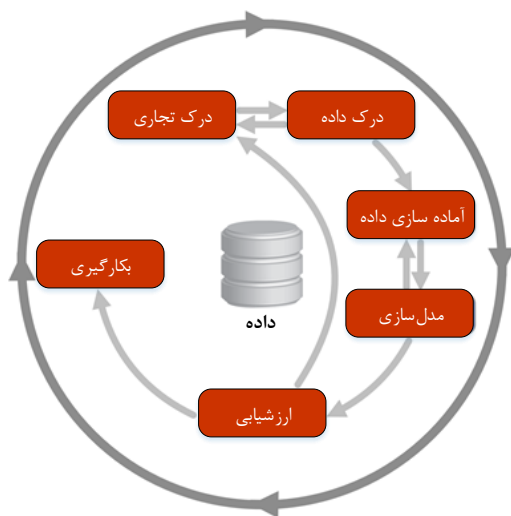
۴-۲- مدل پژوهش

در این پژوهش، یادگیری ماشین^{۱۰} جهت ارائه مدلی برای پیش‌بینی درماندگی مالی شرکت‌های پذیرفته شده در فرابورس و بورس اوراق بهادار تهران بکار گرفته می‌شود. برای ارائه یک مدل پیش‌بینی‌کننده معتبر، چندین گام می‌بایست اجرا شود. به منظور مدل‌سازی این گام‌ها، از مدل فرآیند استاندارد صنعت متقابل برای داده کاوی (CRISP - DM)^{۱۱} استفاده خواهد شد که در شکل ۱

¹⁰ Machine Learning

¹¹ Cross Industry Standard Process-Data Mining (CRISP-DM)

نمایش داده شده است. بر اساس نظرسنجی آنلاین صورت گرفته توسط جامعه داده کاوی بین‌المللی KDNuggets در سال ۲۰۱۴، $CRISP - DM$ با ۴۳٪ سهم مشهورترین روش شناسی برای پروژه‌های تحلیلی، داده کاوی و علم داده و متداول‌ترین فرآیند داده کاوی مورد ارجاع و مورد استفاده در عمل است (Niaksu, 2015: 52). این مدل، گام‌های متداول مورد استفاده در فرآیند داده کاوی را شرح می‌دهد و به سازمان‌دهی پروژه کمک می‌کند. مدل $(CRISP - DM)$ شامل شش مرحله است: درک تجاری^{۱۲}، درک داده^{۱۳}، آماده‌سازی داده^{۱۴}، مدل‌سازی^{۱۵}، ارزیابی^{۱۶} و بکارگیری^{۱۷} (Shearer, 2000: 14; Kwitek, 2016: 32).



شکل ۱: مراحل مدل $CRISP - DM$

برگرفته از: شرر، ۲۰۰۰: ۱۴؛ نیاکسو، ۲۰۱۵: ۵۳

۴-۲-۱- متغیرهای پژوهش

در این پژوهش، از دو دسته متغیر استفاده می‌شود:

۱- **متغیر مستقل:** اطلاعات قابل اندازه‌گیری مورد استفاده برای پیش‌بینی متغیر هدف است که پیش‌بینی کننده، ویژگی، خصوصیت، متغیر ورودی، متغیر توضیحی یا از دید پایگاه داده، فیلد نیز نامیده می‌شود

¹² Business Understanding

¹³ Data Understanding

¹⁴ Data Preparation

¹⁵ Modeling

¹⁶ Evaluation

¹⁷ Deployment

(University of Notre Dame, n.d.) متون پیش‌بینی در ماندگی بدون تئوری مشخصی تکامل یافته است که تعیین کند کدام نسبت‌های مالی یا چند نسبت یا چه رویکرد وزن‌دهی به بهترین نحو امکان ارزیابی احتمال در ماندگی را فراهم می‌کند (Beaver, Correia & McNichols, 2010: 113). از این رو، رویکرد معمول برای پیش‌بینی ورشکستگی این است که برای شناسایی مجموعه بزرگی از متغیرهای مستقل مالی یا غیرمالی بالقوه به مرور متون پرداخت و سپس، از طریق ترکیب تحلیل‌های ریاضیاتی و قضاوتی به مجموعه کوچک‌تری از متغیرهای مستقل دست یافت که ورشکستگی را پیش‌بینی می‌کنند. برخی از این مدل‌ها از صحت پیش‌بینی حدود ۹۰ درصد برخوردارند. اما، مسأله مطرح این است که مدل‌های ارائه شده معمولاً از متغیرهای مختلف و شکل‌های مختلفی برای تعیین روابط بین این متغیرها استفاده می‌کنند (McKee & Lensberg, 2002: 436-437). بنابراین، پس از ۳۰ سال پژوهش درباره این موضوع، هیچ مدل پذیرفته شده کلی برای پیش‌بینی ورشکستگی وجود ندارد که اساس آن مبتنی بر تعیین روابط علی عوامل اقتصادی زیربنایی باشد (McKee & Lensberg, 2002: 436-437; Lin, Wang, Wu & Chuang, 2009: 1593). در این پژوهش، سه معیار جهت انتخاب نسبت‌های مالی برای پیش‌بینی بحران مالی استفاده شده است:

۱- نسبت‌های مالی باید به صورت متداول در متون پیش‌بینی بحران مالی مورد استفاده قرار گرفته باشند: بیش از ۸۵۲ متغیر یا نسبت مختلف از ۱۲۸ مقاله معتبر (برای نمونه، تینکو و ویلسان (۲۰۱۳)، ژو و همکاران (۲۰۱۲)، چن (۲۰۱۱)، اسکلنگر و کراس (۱۹۹۴) و اهللسان (۱۹۸۰)) استخراج گردید. انتخاب تمامی این متغیرها برای ایجاد مدل غیرممکن است. از این رو، نسبت‌ها یا عواملی که بیشتر از سه دفعه در ۱۲۸ مقاله مورد استفاده قرار گرفته‌اند، انتخاب خواهند شد.

۲- اطلاعات مورد نیاز برای محاسبه این نسبت‌های مالی باید در دسترس باشد: کشورهای مختلف ممکن است سیاست‌های حسابداری مختلفی داشته باشند و شرکت‌های مختلف متعلق به صنایع مختلف ممکن است انواع مختلفی از صورت‌های مالی داشته باشند. از این رو، معمولاً تمامی ۸۵۲ متغیر برای همه شرکت‌ها در همه پایگاه داده‌ها در دسترس نیست (Zhou, Lai & Yen, 2012: 2486).

۳- تصمیم پژوهشگر بر مبنای تجربه قبلی خویش در پژوهش‌های پیشین یا بر مبنای آزمایش‌های

مقدماتی

با در نظر گرفتن این سه معیار، ۱۲۴ متغیر پیش‌بین به شرح مندرج در جدول ۱ انتخاب شده است.

جدول (۱): متغیرهای پیش‌بین (ورودی‌ها یا ویژگی‌ها)	
متغیر	طبقه
$1- \text{نسبت جاری} = \frac{\text{دارایی‌های جاری}}{\text{بدهی‌های جاری}}, 2- \text{بازده دارایی‌ها} = \frac{\text{سود خالص}}{\text{کل دارایی‌ها}}, 3- \text{نسبت بدهی} = \frac{\text{کل بدهی‌ها}}{\text{کل دارایی‌ها}}, 4- \text{گردش کل دارایی‌ها} = \frac{\text{فروش}}{\text{کل دارایی‌ها}}, 5- \text{بازده عملیاتی دارایی‌ها} = \frac{\text{سود عملیاتی}}{\text{کل دارایی‌ها}}, 6- \text{سرمایه در گردش به کل دارایی‌ها} = \frac{\text{سرمایه در گردش}}{\text{کل دارایی‌ها}}, 7- \text{نسبت سریع} = \frac{\text{دارایی‌های سریع}}{\text{بدهی‌های جاری}}, 8- \text{حاشیه سود خالص} = \frac{\text{سود خالص}}{\text{فروش}}, 9- \text{بازده حقوق صاحبان سهام} = \frac{\text{سود خالص}}{\text{حقوق صاحبان سهام}}, 10- \text{سود انباشته به کل دارایی‌ها} = \frac{\text{سود انباشته}}{\text{کل دارایی‌ها}}, 11- \text{دارایی‌های جاری به کل دارایی‌ها} = \frac{\text{دارایی‌های جاری}}{\text{کل دارایی‌ها}}, 12- \text{نسبت پوشش بهره} = \frac{\text{سود عملیاتی}}{\text{هزینه بهره}}, 13- \text{حقوق صاحبان سهام به کل دارایی‌ها} = \frac{\text{حقوق صاحبان سهام}}{\text{کل دارایی‌ها}}, 14- \text{کل بدهی‌ها به حقوق صاحبان سهام} = \frac{\text{کل بدهی‌ها}}{\text{حقوق صاحبان سهام}}, 15- \text{گردش حساب‌های دریافتی} = \frac{\text{فروش}}{\text{حساب‌های دریافتی}}, 16- \text{حاشیه عملیاتی} = \frac{\text{سود عملیاتی}}{\text{فروش}}, 17- \text{گردش موجودی کالا} = \frac{\text{بهای تمام شده کالای فروش رفته}}{\text{موجودی کالا}}, 18- \text{وجه نقد به کل دارایی‌ها} = \frac{\text{وجه نقد}}{\text{کل دارایی‌ها}}, 19- \text{هزینه بهره به فروش} = \frac{\text{هزینه بهره}}{\text{فروش}}, 20- \text{وجه نقد به بدهی‌های جاری} = \frac{\text{وجه نقد}}{\text{بدهی‌های جاری}}, 21- \text{گردش دارایی‌های جاری} = \frac{\text{فروش}}{\text{دارایی‌های جاری}}, 22- \text{گردش دارایی‌های ثابت} = \frac{\text{فروش}}{\text{دارایی‌های ثابت}}, 23- \text{حاشیه سود ناخالص} = \frac{\text{سود ناخالص}}{\text{فروش}}, 24- \text{بدهی‌های جاری به کل دارایی‌ها} = \frac{\text{بدهی‌های جاری}}{\text{کل دارایی‌ها}}, 25- \text{سود هر سهم} = \frac{\text{سود خالص}}{\text{تعداد سهام عادی}}, 26- \text{اندازه شرکت (لگاریتم کل دارایی‌ها)}, 27- \text{گردش سرمایه در گردش} = \frac{\text{فروش}}{\text{سرمایه در گردش}}, 28- \text{رشد کل دارایی‌ها}, 29- \text{بدهی بلندمدت به کل دارایی‌ها} = \frac{\text{بدهی بلندمدت}}{\text{کل دارایی‌ها}}, 30- \text{دارایی‌های سریع به کل دارایی‌ها} = \frac{\text{دارایی‌های سریع}}{\text{کل دارایی‌ها}}, 31- \text{گردش حساب‌های پرداختی} = \frac{\text{بهای تمام شده کالای فروش رفته}}{\text{حساب‌های پرداختی تجاری}}, 32- \text{دارایی‌های سریع به فروش} = \frac{\text{دارایی‌های سریع}}{\text{فروش}}, 33- \text{بدهی‌های جاری به کل بدهی‌ها} = \frac{\text{بدهی‌های جاری}}{\text{کل بدهی‌ها}}, 34- \text{فروش به موجودی کالا} = \frac{\text{فروش}}{\text{موجودی کالا}}, 35- \text{دوره حساب‌های دریافتی} = \frac{\text{حساب‌های دریافتی} \times 360}{\text{فروش}}, 36- \text{سود خالص به دارایی‌های جاری} = \frac{\text{سود خالص}}{\text{دارایی‌های جاری}}, 37- \text{بدهی‌های بلندمدت به حقوق صاحبان سهام} = \frac{\text{بدهی‌های بلندمدت}}{\text{حقوق صاحبان سهام}}, 38- \text{وجه نقد به فروش} = \frac{\text{وجه نقد}}{\text{فروش}}, 39- \text{رشد فروش}, 40- \text{دارایی‌های جاری} = \frac{\text{دارایی‌های جاری}}{\text{کل دارایی‌ها}}$	نسبت‌های مالی مبتنی بر ترازنامه و صورت سود (زیان)

جدول (۱): متغیرهای پیش‌بین (ورودی‌ها یا ویژگی‌ها)	
متغیر	طبقه
<p>ثابت به کل دارایی‌ها = $\frac{\text{دارایی‌های ثابت}}{\text{کل دارایی‌ها}}$، ۴۱- گردش حقوق صاحبان سهام = $\frac{\text{فروش}}{\text{حقوق صاحبان سهام}}$، ۴۲- رشد سود خالص (در صورت وجود سود خالص در سال گذشته: $\frac{\text{سود (زیان) خالص سال جاری} - \text{سود خالص سال گذشته}}{\text{سود خالص سال گذشته}}$، در صورت وجود زیان خالص در سال گذشته: $\frac{\text{سود (زیان) خالص سال جاری} + \text{زیان خالص سال گذشته} }{ \text{زیان خالص سال گذشته} }$)، ۴۳- حقوق صاحبان سهام به دارایی‌های ثابت = $\frac{\text{حقوق صاحبان سهام}}{\text{دارایی‌های ثابت}}$، ۴۴- بازده دارایی‌های ثابت = $\frac{\text{سود خالص}}{\text{دارایی‌های ثابت}}$، ۴۵- سرمایه در گردش به حقوق صاحبان سهام = $\frac{\text{سرمایه در گردش}}{\text{حقوق صاحبان سهام}}$، ۴۶- سود خالص به کل بدهی‌ها = $\frac{\text{سود خالص}}{\text{کل بدهی‌ها}}$، ۴۷- بدهی‌ها به خالص دارایی‌های مشهود = $\frac{\text{بدهی‌ها}}{\text{کل دارایی‌ها} - \text{دارایی‌های نامشهود} - \text{کل بدهی‌ها}}$، ۴۸- خالص دارایی‌ها به ازای هر سهم = $\frac{\text{خالص دارایی‌ها}}{\text{تعداد سهام}}$، ۴۹- بدهی‌های جاری به حقوق صاحبان سهام = $\frac{\text{بدهی‌های جاری}}{\text{حقوق صاحبان سهام}}$، ۵۰- بهای تمام شده کالای فروش رفته به فروش = $\frac{\text{بهای تمام شده کالای فروش رفته}}{\text{فروش}}$، ۵۱- اندازه شرکت (لگاریتم فروش)، ۵۲- حاشیه سود عملیاتی قبل از استهلاک = $\frac{\text{سود عملیاتی قبل از استهلاک}}{\text{فروش}}$، ۵۳- بازده ناخالص کل دارایی‌ها = $\frac{\text{سود ناخالص}}{\text{کل دارایی‌ها}}$، ۵۴- فروش به ازای کارکنان = $\frac{\text{فروش}}{\text{کل تعداد کارکنان}}$، ۵۵- تغییر در سود خالص = $\frac{NI_t - NI_{t-1}}{(NI_t + NI_{t-1})}$، ۵۶- موجودی کالا به کل دارایی‌ها = $\frac{\text{موجودی کالا}}{\text{کل دارایی‌ها}}$، ۵۷- رشد دارایی‌های ثابت، ۵۸- تعدیلات سنواتی به کل دارایی‌ها = $\frac{\text{تعدیلات سنواتی}}{\text{کل دارایی‌ها}}$، ۵۹- تعدیلات سنواتی به فروش = $\frac{\text{تعدیلات سنواتی}}{\text{فروش}}$، ۶۰- هزینه مالیات به سود قبل از مالیات = $\frac{\text{هزینه مالیات}}{\text{سود قبل از مالیات}}$</p>	
<p>۶۱- بازده نقدی دارایی‌ها = $\frac{\text{جریان نقدی عملیاتی}}{\text{کل دارایی‌ها}}$، ۶۲- جریان نقدی عملیاتی به کل بدهی‌ها = $\frac{\text{جریان نقدی عملیاتی}}{\text{کل بدهی‌ها}}$، ۶۳- جریان نقدی عملیاتی به بدهی‌های جاری = $\frac{\text{جریان نقدی عملیاتی}}{\text{بدهی‌های جاری}}$، ۶۴- جریان نقدی عملیاتی به فروش = $\frac{\text{جریان نقدی عملیاتی}}{\text{فروش}}$، ۶۵- جریان نقدی عملیاتی هر سهم = $\frac{\text{جریان نقدی عملیاتی}}{\text{تعداد سهام عادی}}$، ۶۶- بازده نقدی حقوق صاحبان سهام = $\frac{\text{جریان نقدی عملیاتی}}{\text{حقوق صاحبان سهام}}$، ۶۷- پوشش نقدی بهره = $\frac{\text{جریان نقدی عملیاتی}}{\text{بهره پرداخت شده}}$، ۶۸- پوشش سرمایه‌گذاری مجدد = $\frac{\text{جریان نقدی عملیاتی}}{\text{وجه نقد پرداختی بابت بازپرداخت بدهی‌های بلندمدت}}$، ۶۹- پوشش پرداخت بدهی = $\frac{\text{جریان نقدی عملیاتی}}{\text{وجه نقد پرداختی بابت بازپرداخت بدهی‌های بلندمدت}}$</p>	نسبت‌های جریان نقدی

جدول (۱): متغیرهای پیش‌بین (ورودی‌ها یا ویژگی‌ها)	
متغیر	طبقه
<p>۷۰- پوشش پرداخت سود سهام = $\frac{\text{جریان نقدی عملیاتی}}{\text{سود سهام پرداخت شده}}$، ۷۱- پوشش خروجی سرمایه‌گذاری و تأمین مالی = $\frac{\text{جریان نقدی عملیاتی}}{\text{وجه نقد خروجی بابت فعالیت‌های سرمایه‌گذاری و تأمین مالی}}$، ۷۲- مالیات نقدی پرداختی به سود قبل از مالیات = $\frac{\text{مالیات پرداخت شده}}{\text{سود قبل از مالیات}}$، ۷۳- سود تقسیمی هر سهم = $\frac{\text{سود خالص تقسیم شده}}{\text{تعداد سهام عادی}}$</p>	
<p>۷۴- ارزش بازار سهام به ارزش دفتری بدهی‌ها = $\frac{\text{ارزش بازار سهام}}{\text{ارزش دفتری بدهی‌ها}}$، ۷۵- ارزش بازار سهام به ارزش دفتری سهام = $\frac{\text{ارزش بازار سهام}}{\text{ارزش دفتری سهام}}$، ۷۶- اندازه شرکت (لگاریتم ارزش بازار شرکت). ۷۷- بازدهی سهام، ۷۸- رتبه نقدشوندگی، ۷۹- قیمت سهام، ۸۰- ریسک سیستماتیک ($\beta_i = \frac{\text{Cov}(R_i, R_M)}{\text{Var}(R_M)}$)، ۸۱- تعداد معامله‌های سهام، ۸۲- حجم معامله‌های سهام، ۸۳- ارزش معامله‌های سهام، ۸۴- تعداد روزهای معامله سهام، ۸۵- آمیوست $Amivest_i = \frac{1}{N_i} \sum_{t=1}^{N_i} \frac{Vol_{i,t}}{ R_{i,t} }$ که در این رابطه، N_i: تعداد روزهای بازده غیرصفر سهام $Vol_{i,t}$: حجم معامله سهام i بر حسب ریال در روز t و $R_{i,t}$: قدرمطلق بازده سهام i در روز t، ۸۶- آمیهود ($Amihud_i = \frac{1}{N_i} \sum_{t=1}^{N_i} \frac{ R_{i,t} }{Vol_{i,t}}$ که در این رابطه، N_i: تعداد روزهای با حجم معامله غیرصفر سهام i، $Vol_{i,t}$: حجم معامله سهام i بر حسب ریال در روز t و $R_{i,t}$: قدرمطلق بازده سهام i در روز t، ۸۷- سهام شناور آزاد (حاصل ضرب ضریب شناوری در مجموع سهام سهامداران غیرمدیریتی).</p>	متغیرهای بازار سهام و نقدشوندگی
<p>۸۸- تمرکز مالکیت $HHI = \sum_{i=1}^{N_j} (SHARE_{i,j})^2$ که در این رابطه، $SHARE_{i,j}$: درصد سهام تحت تملک سهامدار i در شرکت j، ۸۹- سهامداران عمده (مجموع درصد سهام تحت تملک سهامداران دارای مالکیت بیشتر از ۵٪)، ۹۰- نخستین سهامدار بزرگ (درصد سهام تحت تملک نخستین سهامدار بزرگ دارای مالکیت بیشتر از ۵٪)، ۹۱- دومین سهامدار بزرگ (درصد سهام تحت تملک دومین سهامدار بزرگ دارای مالکیت بیشتر از ۵٪)، ۹۲- مالکیت مدیریتی (مجموع درصد سهام تحت تملک اعضای هیأت مدیره و مدیر عامل دارای مالکیت بیشتر از ۵٪)، ۹۳- مالکیت خانوادگی (مجموع درصد سهام تحت تملک اعضای خانواده‌های دارای مالکیت بیشتر از ۵٪)، ۹۴- مالکیت نهادی (مجموع درصد سهام تحت تملک سهامداران نهادی (بانک‌ها، شرکت‌های بیمه، صندوق‌های بازنشستگی، شرکت‌های سرمایه‌گذاری و سایر مؤسسه‌هایی که به خرید و فروش حجم بالایی از اوراق بهادار می‌پردازند) دارای مالکیت بیشتر از ۵٪)، ۹۵- اندازه مؤسسه حسابرسی (بزرگ (سازمان حسابرسی) و کوچک (سایر مؤسسه‌های حسابرسی))، ۹۶- نوع گزارش حسابرسی (مقبول، مشروط، عدم اظهارنظر، مردود)، ۹۷- تغییر حسابرس ((عدم) تغییر حسابرس شرکت نسبت به سال گذشته)، ۹۸- اندازه هیأت مدیره (تعداد اعضای هیأت مدیره)، ۹۹- دوگانگی مدیر</p>	متغیرهای حاکمیت شرکتی

جدول (۱): متغیرهای پیش‌بین (ورودی‌ها یا ویژگی‌ها)	
طبقه	متغیر
	عامل (بکارگیری همزمان یک مدیر به عنوان مدیر عامل و رئیس هیأت مدیره)، ۱۰۱- استقلال هیأت مدیره (مؤلف نبودن رئیس هیأت مدیره)، ۱۰۱- استقلال هیأت مدیره = $\frac{\text{تعداد اعضای غیرمؤلف هیأت مدیره}}{\text{تعداد کل اعضای هیأت مدیره}}$ ، ۱۰۰- استقلال رئیس هیأت مدیره
متغیرهای اقتصاد کلان	۱۰۲- رشد تولید ناخالص داخلی به قیمت پایه، ۱۰۳- رشد تولید ناخالص ملی به قیمت پایه-ثابت، ۱۰۴- رشد صادرات کالاها و خدمات-ثابت، ۱۰۵- رشد واردات کالاها و خدمات-ثابت، ۱۰۶- شاخص کل قیمت بورس، ۱۰۷- رشد نقدینگی (پول + شبه پول)، ۱۰۸- نرخ بیکاری، ۱۰۹- نرخ بازار دلار، ۱۱۰- رشد سرمایه‌گذاری خارجی، ۱۱۱- نرخ تورم، ۱۱۲- رشد مخارج دولت (کل پرداخت‌ها)، ۱۱۳- چرخه تجاری (رونق)، ۱۱۴- رتبه صندوق بین‌المللی پول، ۱۱۵- شاخص کل تولید کارگاه‌های بزرگ صنعتی، ۱۱۶- شاخص بهای کالاها و خدمات مصرفی، ۱۱۷- شاخص بهای تولیدکننده، ۱۱۸- نرخ اوراق مشارکت، ۱۱۹- نرخ وام - صنعت و معدن، ۱۲۰- نرخ بهره واقعی.
سایر متغیرها	۱۲۱- صنعت (طبقه‌بندی شرکت‌ها در ۳۷ صنعت بر اساس آیسیک ^{۱۸})، ۱۲۲- سود انباشته به سرمایه، ۱۲۳- عمر شرکت بر حسب مدت پذیرش در بورس، ۱۲۴- عمر شرکت بر حسب زمان تأسیس.

۲- **متغیر وابسته:** متغیر مورد پیش‌بینی در یادگیری نظارت شده است که متغیر پاسخ، متغیر خروجی، متغیر هدف، متغیر پیامد یا برجسب نیز نامیده می‌شود (University of Notre Dame, n.d.). در مطالعات تجربی مندرج در متون، ورشکستگی و درماندگی مالی به جای یکدیگر به کار گرفته شده‌اند. استفاده از درماندگی مالی موجب انعطاف‌پذیری در مرحله پژوهش می‌شود. درماندگی مالی در مقایسه با ورشکستگی تعریف متداول‌تری است و برای افزایش اندازه نمونه به پژوهش محدودیت‌هایی در پژوهش و کاهش اندازه نمونه می‌شود. استفاده از درماندگی مالی نه تنها در عمل بلکه در تئوری نیز دارای برتری است؛ زیرا همه شرکت‌های درمانده مالی ورشکسته نمی‌شوند. ورشکستگی آخرین گزینه برای شرکت‌هایی است که نمی‌توانند مشکلات مالی خودشان را حل کنند. به گونه خلاصه، استفاده از ورشکستگی تنها موجب محدود شدن به یک جنبه از درماندگی مالی می‌شود (Aktan, 2011: 23). از این رو، در این پژوهش، برای تشریح وضعیت شرکت‌های روبه رو با دشواری مالی از عبارت درماندگی مالی استفاده می‌شود. افزون بر این، برای تشخیص شرکت‌های درمانده مالی نیز درماندگی مالی بر اساس ماده ۱۴۱ قانون تجارت ایران تعریف می‌شود (کاتبی، ۱۳۸۰: ۹۵):

¹⁸ International Standard Industrial Classification (ISIC)

اگر بر اثر زیان‌های وارده حداقل نصف سرمایه شرکت از میان برود، هیأت مدیره مکلف است بلافاصله مجمع عمومی فوق‌العاده صاحبان سهام را دعوت نماید تا موضوع انحلال یا بقاء شرکت مورد شور و رأی واقع شود.

۴-۳- جامعه آماری، روش نمونه‌گیری و حجم نمونه

جامعه آماری این پژوهش، شامل تمامی شرکت‌های پذیرفته شده در فرابورس و بورس اوراق بهادار تهران است. برای اجتناب از انتقادهای وارد بر جانبداری نمونه جفت تطبیقی، در این پژوهش از نمونه‌ای استفاده خواهد شد که نشان‌دهنده نرخ درماندگی واقعی است. داده‌های ۴۲۱ شرکت پذیرفته شده در فرابورس و بورس اوراق بهادار تهران طی دوره ۱۶ ساله از سال ۱۳۹۵-۱۳۸۰ در تمامی صنایع به جز صنعت مالی گنجانده خواهد شد. این روش نمونه‌گیری، امکان ارزیابی تأثیر اندازه شرکت و صنعت بر احتمال درماندگی مالی را فراهم می‌کند. بر این اساس شرکت‌های خدمات مالی نظیر بانک‌ها، بیمه‌ها، کارگزاری‌ها، لیزینگ‌ها و غیره در تجزیه و تحلیل گنجانده نشده‌اند (Ohlson, 1980: 114; Lee, Booth & Alam, 2005: 5; Pendharkar, 2005: 2569; Chancharat, 2008: 824; Li & Miu, 2010: 116)؛ زیرا شرکت‌های عضو این صنایع از دیدگاه ساختاری متفاوت هستند، محیط ورشکستگی متفاوتی دارند و در برخی موارد، بدست آوردن داده‌های مربوطه آن‌ها دشوار است (Ohlson, 1980: 114). افزون بر این، مؤسسه‌های مالی نظیر بانک‌های تجاری یا بانک‌های سرمایه‌گذاری به این دلیل در این مجموعه داده گنجانده نشده‌اند که در اقتصاد ایران، سرنوشت چنین واسطه‌گری‌های مالی به نظر می‌رسد که بیشتر تحت تأثیر سیاست‌های دولت و نه وضعیت مالی خودشان باشد (Lee, Booth & Alam, 2005: 5). فهرست اسامی صنایع مورد بررسی در این پژوهش، در جدول ۲ نمایش داده شده است. انتظار بر این است که بکارگیری کل صنایع شرکت‌های پذیرفته شده به ارائه مدل پیش‌بینی درماندگی مالی اثربخشی در بورس اوراق بهادار تهران منجر شود؛ زیرا این نمونه می‌بایست معرف کل اقتصاد ایران باشد.

جدول (۲): صنایع مورد بررسی

ردیف	صنعت	ردیف	صنعت
۱	ابزار پزشکی، اپتیک و اندازه گیری	۲۰	سایر محصولات کانی غیر فلزی
۲	استخراج زغال سنگ	۲۱	سیمان، آهک و گچ
۳	استخراج سایر معادن	۲۲	عرضه برق، گاز، بخار و آب گرم
۴	استخراج کانه های فلزی	۲۳	فرآورده های نفتی، کک و سوخت هسته ای
۵	استخراج نفت گاز و خدمات جنبی به جز اکتشاف	۲۴	فلزات اساسی
۶	انبوه سازی، املاک و مستغلات	۲۵	قند و شکر
۷	انتشار، چاپ و تکثیر	۲۶	کاشی و سرامیک
۸	پیمانکاری صنعتی	۲۷	لاستیک و پلاستیک
۹	تجارت عمده فروشی به جز وسایل نقلیه موتور	۲۸	ماشین آلات و تجهیزات
۱۰	تجارت عمده و خرده فروشی وسایل نقلیه موتور	۲۹	ماشین آلات و دستگاه های برقی
۱۱	حمل و نقل، انبارداری و ارتباطات	۳۰	محصولات چوبی
۱۲	خدمات فنی و مهندسی	۳۱	محصولات شیمیایی
۱۳	خرده فروشی، به استثنای وسایل نقلیه موتوری	۳۲	محصولات غذایی و آشامیدنی به جز قند و شکر
۱۴	خودرو و ساخت قطعات	۳۳	محصولات کاغذی
۱۵	رایانه و فعالیت های وابسته به آن	۳۴	مخابرات
۱۶	زراعت و خدمات وابسته	۳۵	منسوجات
۱۷	ساخت دستگاه ها و وسایل ارتباطی	۳۶	مواد و محصولات دارویی
۱۸	ساخت محصولات فلزی	۳۷	هتل و رستوران
۱۹	سایر تجهیزات حمل و نقل		

۴-۴- ابزار گردآوری داده ها

در این پژوهش، برای نگارش و جمع آوری اطلاعات مورد نیاز بخش مبانی نظری و پیشینه پژوهش از مجله ها و کتاب های تخصصی لاتین، و برای گردآوری سایر داده های کمی و اطلاعات مورد نیاز از سایت کدال، سایت بورس اوراق بهادار تهران، بانک های اطلاعاتی سازمان بورس اوراق بهادار تهران، سایت بانک مرکزی جمهوری اسلامی ایران، سایت صندوق بین المللی پول، گزارش کلان اقتصادی

پژوهشکده پولی و بانکی بانک مرکزی جمهوری اسلامی ایران، نرم افزار ره آورد نوین، نرم افزار تدبیر پرداز، و نرم افزار تی اس ای کلاینت^{۱۹} استفاده خواهد شد. بنابراین، اطلاعات مورد نیاز بخش مبنای نظری و پیشینه پژوهش، داده ثانویه از نوع مستندات رسمی و داده‌های مورد نیاز بخش مدل‌سازی، داده ثانویه از نوع داده‌های پژوهشی آرشویی است (Johnson & Christensen, 2014).

۴-۵- روش تجزیه و تحلیل داده‌ها

۴-۵-۱- پیش پردازش (تکمیل مقادیر گم‌شده و استخراج ویژگی‌های اولیه)

پیش پردازش داده‌ها یک گام مهم برای داده کاوی با کیفیت خوب در فرآیندهای داده کاوی یا کشف دانش در پایگاه داده است (Tsai & Cheng, 2012: 333). تکنیک‌های پیش پردازش مورد استفاده در این پژوهش عبارت‌اند از:

پاک‌سازی داده: پاک‌سازی داده به معنای تکمیل مقادیر نامشخص، هموارسازی داده‌های نویزی، شناسایی داده‌های پرت و رفع داده‌های ناسازگار است (Li & Sun, 2011: 464). در این فرآیند، نخست رکوردهای تکراری حذف گردیدند اما به علت حجم اندک داده‌های در دسترس و زیاد بودن رکوردهای حاوی مقادیر گم‌شده، رکوردهای حاوی مقادیر گم‌شده حذف نشدند و بر حسب مورد به صورت دستی از طریق گزارش‌های مالی مندرج در سایت کدال و سایت بورس اوراق بهادار تهران، میانگین مقدار آن متغیر در سال قبل و بعد همان شرکت، یا مقدار آن متغیر در سال بعد همان شرکت تکمیل شده‌اند.

ت ترکیب داده: در این فرآیند، چندین منبع داده شامل ترازنامه، صورت سود و زیان، صورت جریان وجوه نقد، حاکمیت شرکتی، داده‌های بازار سهام و نقدشوندگی بر اساس دو شناسه نام (نماد) شرکت و سال و متغیرهای کلان اقتصادی بر اساس شناسه سال ادغام شده‌اند.

استخراج ویژگی‌های اولیه: استخراج ویژگی‌های مورد نیاز جهت پیش‌بینی درماندگی مالی بر اساس مرور ۱۲۸ مقاله پیش‌بینی درماندگی مالی، انتخاب نسبت‌ها یا ویژگی‌های مورد استفاده در بیشتر از ۳ مقاله از ۱۲۸ مقاله، امکان‌پذیری محاسبه آن‌ها و یا سودمندی آن‌ها بر اساس دانش و تجربه پژوهشگر انجام شده است. ویژگی‌های استخراجی اولیه در جدول ۱، ارائه شده‌اند. با توجه به اینکه از یک سو، برای محاسبه برخی نسبت‌های مالی به اطلاعات سال گذشته نیاز است و از سوی دیگر، برای پیش‌بینی

¹⁹ TSEClient

درماندگی مالی نیز از ویژگی‌های یک سال قبل استفاده می‌شود، نمونه انتخابی شامل ۳۶۷۰ سال-شرکت و ۱۲۳ ویژگی است.

وان هات انکدینگ: با توجه به اینکه ویژگی صنعت، یک متغیر طبقه‌ای اسمی هست، بر روی این ویژگی، وان هات انکدینگ اجرا شده است. پس از اجرای وان هات انکدینگ، به مجموعه داده، ۳۷ ستون جدید با مقادیر صرفاً ۰-۱ افزوده شده است. اما از آنجا که ویژگی نوع اظهار نظر حسابرس، متغیر طبقه‌ای ترتیبی است، با استفاده از اعداد ۱ تا ۴ به مقادیر عددی تبدیل شده است.

ساخت ویژگی: گاهی اوقات جهت دستیابی به عملکرد بهتر به ویژگی‌های اضافی نیاز است؛ زیرا ویژگی‌های اولیه مندرج در داده خام به منظور توصیف خصوصیات نمونه‌ها ممکن است اضافی باشند یا معنادار نباشند (Fan, 2016: 10-11). در نتیجه، ویژگی جدیدی تحت عنوان نسبت سود (زیان) انباشته به سرمایه سال قبل برای پیش‌بینی درماندگی مالی در سال بعد ساخته شده است.

۴-۵-۲- تفکیک نمونه

سپس، داده آماده شده به مجموعه داده آموزشی و آزمایشی تفکیک می‌شود. در این پژوهش، از تفکیک ۷۰ به ۳۰ استفاده می‌شود. بدین معنا که ۷۰٪ داده به صورت تصادفی انتخاب می‌شود تا برای آموزش مدل استفاده شود در حالی که ۳۰٪ داده به عنوان مجموعه آزمایشی کنار گذاشته شده در نظر گرفته می‌شود تا در ارزیابی نهایی مورد استفاده قرار گیرد. مقدار بنیادی مولد تصادفی برای این تفکیک ثابت نگه داشته می‌شود تا مدل قابلیت ایجاد دوباره را داشته باشد (Oleksy, 2017: 51). به دلیل زیادی تعداد متغیرهای پیش‌بینی کننده، صرفاً آمار توصیفی برخی از متغیرهای پیش‌بینی کننده مجموعه داده آموزشی در جدول ۳ نمایش داده شده است.

۴-۵-۳- اعتبارسنجی متقابل

در این پژوهش، برای ارزیابی ترکیبات مختلف آبرپارامترهای الگوریتم یادگیری از اعتبارسنجی متقابل k لایه طبقه‌ای (با $k = 5$) استفاده شده است. اعتبارسنجی متقابل طبقه‌ای به ویژه، در خصوص مسائل کلاس نامتوازن می‌تواند برآورد بهتری از واریانس و سوگیری ارائه کند. در اعتبارسنجی متقابل k لایه طبقه‌ای، نسبت کلاس‌ها در هر لایه ثابت نگه داشته می‌شود تا اطمینان حاصل شود که هر لایه معرف نسبت کلاس‌ها در مجموعه داده آموزشی است.

۴-۵-۴- پیش پردازش (مقیاس دهی ویژگی و انتخاب ویژگی)

مقیاس دهی ویژگی‌ها: در این پژوهش، برای مقیاس دهی ویژگی‌ها از استانداردسازی استفاده شده است.

رویه استانداردسازی را می‌توان با معادله زیر بیان کرد:

$$x_{std}^{(i)} = \frac{x^{(i)} - \mu_x}{\sigma_x} \quad (1)$$

که در این رابطه: μ_x میانگین نمونه یک ستون ویژگی خاص و σ_x انحراف معیار مربوط به آن

است (Raschka, 2015: 111).

جدول (۳): آمار توصیفی مجموعه داده آموزشی

پیش‌بینی کننده	هدف	تعداد	میانگین	انحراف معیار	چولگی	کشیدگی	پیش‌بینی کننده	هدف	تعداد	میانگین	انحراف معیار	چولگی	کشیدگی
۳۹x	۰	۲۴۷۴	۶۱/۱۴	۲۲۴۷/۷۲	۴۱/۱۳	۱۷۷۷/۵۴	۵۸x	۰	۲۴۷۴	۰/۰۱	۰/۳۹	۰/۶۶	۱/۰۳
	۱	۹۵	۹۵	۰/۰۱	۰/۳۹	۰/۶۶		۱/۰۳					
۴۰x	۰	۲۴۷۴	۰/۲۶	۰/۱۸	۰/۹	۰/۳۶	۶۰x	۰	۲۴۷۴	۰/۲۲	۰/۱۷	۱/۲۲	۱/۱۸
	۱	۹۵	۹۵	۰/۲۲	۰/۱۷	۱/۲۲		۱/۱۸					
۴۲x	۰	۲۴۷۴	۰/۹۷	۱۲/۹۸	۲۶/۵۲	۸۷۶/۸۲	۶۳x	۰	۲۴۷۴	۰/۹۷	۲۶/۰۸	۶/۳۵	۴۵/۹۸
	۱	۹۵	۹۵	۴/۸۷	۲۶/۰۸	۶/۳۵		۴۵/۹۸					
۴۵x	۰	۲۴۷۴	۰/۱۷	۰/۷۳	۳/۴۵	۲۹/۴۵	۷۹x	۰	۲۴۷۴	۰/۱۷	۰/۷۳	۳/۴۵	۲۹/۴۵
	۱	۹۵	۹۵	۰/۱۷	۰/۷۳	۳/۴۵		۲۹/۴۵					
۴۶x	۰	۲۴۷۴	۰/۳۱	۰/۴۶	۵/۹۱	۶۴/۴۷	۸۲x	۰	۲۴۷۴	۰/۳۱	۰/۴۶	۵/۹۱	۶۴/۴۷
	۱	۹۵	۹۵	۰/۳۱	۰/۴۶	۵/۹۱		۶۴/۴۷					
۴۷x	۰	۲۴۷۴	۱۱۵۲/۳۸	۴۰۸۲۳/۷۴	۳۶/۶۳	۱۳۷۱/۷۳	۸۸x	۰	۲۴۷۴	۰/۳۴	۰/۲۲	۰/۷۸	۰/۱
	۱	۹۵	۱۵۹۰۲/۰۷	۱۵۴۹۲۲	۹/۵۹	۹۰/۰۱		۹/۵۹					
۴۸x	۰	۲۴۷۴	۲۴۸۴/۴۳	۱۷۶۴/۶۴	۳/۲	۱۵/۵۸	۹۲x	۰	۲۴۷۴	۱/۳۳	۸/۰۷	۸/۰۷	۷۲/۲۶
	۱	۹۵	۱۳۶۹/۶۲	۱۰۲۷/۱۶	۲/۸۴	۹/۴۶		۲/۸۴					
۵۰x	۰	۲۴۷۴	۰/۷۲	۰/۱۷	۰/۷۱	۱/۷۷	۹۳x	۰	۲۴۷۴	۰/۲۴	۰/۴۳	۱/۲	۰/۵۶
	۱	۹۵	۹۵	۰/۷۲	۰/۱۷	۰/۷۱		۱/۷۷					
۵۱x	۰	۲۴۷۴	۱۲/۹۶	۱/۷۳	۰/۰۸	۵/۷۴	۹۵x	۰	۲۴۷۴	۰/۲۴	۰/۴۳	۱/۲	۰/۵۶
	۱	۹۵	۱۲/۰۷	۲/۰۵	۱/۷۳	۱۱/۵۱		۱/۷۳					

انتخاب ویژگی: انتخاب زیرمجموعه ویژگی به معنای یافتن زیرمجموعه ویژگی I به گونه‌ای است که ریسک مورد انتظار طبقه کننده در صورت آموزش با I حداقل شود (Pajkossy, 2013: 6). در این پژوهش، انتخاب ویژگی به روش ترکیبی با استفاده از عبارت پراکندگی λ_1 انجام شده است. تکنیک انتخاب ویژگی حاصل از بکارگیری λ_1 را لاسو می‌نامند. لاسو روش قدرتمندی است که دو کار اصلی را انجام می‌دهد: تنظیم و انتخاب ویژگی. روش لاسو، محدودیتی بر مجموع قدرمطلق پارامترهای مدل وضع می‌کند مبنی بر اینکه این مجموع باید کمتر از یک مقدار ثابت (حد بالا) باشد. بدین منظور، این روش فرآیند انقباض (تنظیم) را به کار می‌گیرد که به موجب آن، ضرایب متغیرهای رگرسیون را با انقباض برخی از آن‌ها به صفر، جریمه می‌کند. طی فرآیند انتخاب ویژگی، متغیرهایی که بعد از فرآیند انقباض همچنان دارای ضریب غیر صفر هستند، به عنوان بخشی از مدل انتخاب می‌شوند. هدف این فرآیند، حداقل کردن خطای پیش‌بینی است (Fonti, 2017: 5). مقدار بهینه λ تعداد ویژگی‌های انتخاب شده را کنترل می‌کند و می‌تواند با استفاده از اعتبارسنجی متقابل تعیین شود (Pajkossy, 2013: 6).

۴-۵-۵- آموزش الگوریتم یادگیری

الگوریتم یادگیری: رگرسیون لجستیک بسیار کارا است، نیازمند منابع محاسباتی خیلی زیادی نیست، از قابلیت تفسیر بالایی برخوردار است، تنظیم آن ساده است و احتمال پیش‌بینی‌ها را نیز ارائه می‌کند. افزون بر این، الگوریتم‌های ساده نظیر مدل رگرسیون لجستیک برای مجموعه داده‌های کوچک دارای همبستگی زیاد بین متغیر پاسخ و ویژگی‌ها مناسب است. از این رو، در این پژوهش از رگرسیون لجستیک به عنوان الگوریتم یادگیری استفاده شده است. رگرسیون لجستیک، نوعی تجزیه و تحلیل رگرسیونی است که در آن متغیر پاسخ، باینری است بدین معنا که صرفاً مقادیر ۰ یا ۱ را می‌تواند بگیرد. متغیرهای توضیحی می‌توانند گسسته یا پیوسته باشند. اجزای اصلی این مدل عبارت‌اند از (Fonti, 2017: 18):

۱- جزء تصادفی: توزیع احتمال f متغیر پاسخ، دوجمله‌ای است:

$$Y_i \sim \text{Binomial}(n_i, \pi_i) \quad (۲)$$

که در این رابطه، n_i مخرج دوجمله‌ای و π_i احتمال است.

۲- جزء سیستماتیک: ترکیب خطی از متغیرهای توضیحی است:

$$\eta_i = x_i^T \beta \quad (۳)$$

۳- تابع رابط: تابع رابط در واقع تابع لوجیت است:

$$\eta_i = \text{logit}(\pi) = \log\left(\frac{\pi}{1-\pi}\right) = \sum_{j=0}^p \beta_j x^{(j)} \quad (۴)$$

بکارگیری تعداد زیادی متغیر برای مدل‌سازی به صورت غیرضروری تفسیر تجزیه و تحلیل را پیچیده می‌کند، ممکن است به برازش بیشتر از اندازه منجر شود و همچنین، اصل امساک را نقض کند. افزون بر این، به احتمال زیاد ساختار همبستگی بین مجموعه متغیرهای بزرگ وجود دارد که به بی‌ثباتی فضای پاسخ و نتایج نامنسجم منجر می‌شود. برای نمونه، در رگرسیون چندگانه، همخطی چندگانه بین مجموعه متغیرها می‌تواند به رگرسیونی منجر شود که حتی هنگامی که هیچ کدام از متغیرها معنادار نیستند کل رگرسیون معنادار است. یک شیوه غلبه بر این مشکلات، بکارگیری روش لاسو است (Grosswindhager, 2009: 12).

رگرسیون لجستیک لاسو: روش لاسو، حد بالای ثابتی را بر مجموع قدر مطلق پارامترهای مدل وضع می‌کند. در خصوص مدل‌های خطی تعمیم یافته، این محدودیت را می‌توان از طریق جریمه کردن منفی لگاریتم احتمال با نرم L_1 بیان کرد. در مدل رگرسیون لجستیک، منفی لگاریتم احتمال برابر است با (Fonti, 2017: 18-19):

$$-\sum_{i=1}^n \log(P_{\beta}(Y_i|X_i)) = \sum_{i=1}^n \left\{ -Y_i \left(\sum_{j=0}^p \beta_j x^{(j)} \right) + \log \left(1 + \exp \left(\sum_{j=0}^p \beta_j x^{(j)} \right) \right) \right\} \quad (۵)$$

که می‌توان آن را بر حسب تابع زیان ρ نوشت:

$$\rho_{(\beta)}(x, y) = -y \left(\sum_{j=0}^p \beta_j x^{(j)} \right) + \log \left(1 + \exp \left(\sum_{j=0}^p \beta_j x^{(j)} \right) \right) \quad (۶)$$

برآوردکننده لاسو برای مدل رگرسیون لجستیک بدین گونه تعریف می‌شود:

$$\hat{\beta}(\lambda) = \underset{\beta}{\operatorname{argmin}} \left(n^{-1} \sum_{i=1}^n \rho(\beta)(X_i, Y_i) \right) + \lambda \|\beta\|_1 \quad (۷)$$

رگرسیون لجستیک لاسو می‌تواند برای ترکیب انتخاب ویژگی و آموزش طبقه‌بندی کننده بکار گرفته شود. مزیت این کار این است که مجموعه ویژگی‌ها برای مدل خاصی بهینه می‌شوند و در نتیجه، عملکرد مدل بهبود می‌یابد. افزون بر این، ترکیب انتخاب ویژگی و برآورد ضرایب موجب کاهش بار محاسباتی می‌شود؛ زیرا نیازی به هیچ گونه الگوریتم انتخاب ویژگی صریحی نیست. به

دلیل سادگی مدل، ضرایب مدل به سادگی تفسیرپذیر هستند و دانش بیشتری را ارائه می کنند (Manninen, 2014: 9).

یادگیری نامتوازن: در حوزه مسائل طبقه بندی، اغلب سناریوی داده های نامتوازن مطرح می شود. ویژگی اصلی این نوع مسأله طبقه بندی این است که تعداد نمونه های یک نوع کلاس به میزان قابل توجهی بیشتر از تعداد نمونه های کلاس دیگر است (López, 2013: 114). هنگامی که یک طبقه بندی کننده استاندارد بر روی یک داده نامتوازن بکار گرفته می شود، مدلی که کورکورانه تمامی نمونه ها را به عنوان کلاس اکثریت طبقه بندی می کند، کماکان می تواند به نرخ طبقه بندی نادرست اندکی دست یابد. بنابراین، نه تنها به چارچوب مناسب تری برای مسائل داده نامتوازن نیاز است بلکه به سیستمی نیاز است که مدل های دارای نرخ طبقه بندی نادرست متوازن تر در بین کلاس ها را انتخاب کند. مسأله نخست، معمولاً با اصلاح های مبتنی بر داده یا الگوریتم روش های کلاسیک قابل حل و فصل است. مسأله بعدی به این موضوع می پردازد که چه معیاری برای ارزیابی مسائل کلاس نامتوازن مناسب تر است (Ren, 2014: 20)؟

در این پژوهش، با توجه به اینکه مجموعه داده در ماندگی مالی، نامتوازن است، برای پاسخ به مسأله نخست از روش یادگیری حساس به هزینه استفاده شده است. این روش مستلزم اختصاص هزینه های مختلف به نمونه های دارای طبقه بندی نادرست، از طریق ماتریس هزینه است. برای نمونه، فرض کنید $C(i, j)$ هزینه طبقه بندی نمونه کلاس i ام به عنوان کلاس j ام است. آنگاه، معمولاً، $C(i, i) = 0$ و $C(i, j) \geq C(j, i)$ در نظر گرفته خواهد شد چنانچه فراوانی کلاس i ام کمتر باشد. هدف از این کار، حداقل نمودن هزینه کل بعد از اجرای ماتریس هزینه هست (Ren, 2014: 24).

افزون بر این، برای پاسخ به مسأله بعدی نیز نمره F_1 به عنوان معیار ارزیابی عملکرد انتخاب می شود؛ زیرا نمره F_1 هنگام بررسی مسأله کلاس نامتوازن مناسب تر از AUC است. افزون بر این، AUC معیاری مبتنی بر منحنی جهت نمایش عملکرد میانگین یا کلی یک طبقه بندی کننده است در حالی که نمره F_1 معیاری نقطه ای است که در برخی موارد در عمل معنادارتر است (Fan, 2016: 19).

۴-۵-۶- بهینه سازی آبرپارامتر

آبرپارامترها، پارامترهای مختص مدل هستند که برای بهینه سازی مدل مورد استفاده قرار می گیرند. معمولاً، به منظور بهینه سازی عملکرد مدل و کاهش واریانس و سوگیری مدل باید آبرپارامترها را تنظیم کرد (Bonnes, 2017: 27). تنظیم آبرپارامترهای مدل با استفاده از کاوش کامل زیرمجموعه هایی از

فضای ترکیبات احتمالی آبرپارامتر انجام می‌شود. هدف، یافتن مقادیری برای آبرپارامترها است که به عملکرد طبقه‌بندی بهینه منجر شود. این نوع جستجو را جستجوی شبکه‌ای نیز می‌نامند؛ زیرا آرایه‌های پارامترها یک شبکه چندبعدی را تشکیل می‌دهند (Oleksy, 2017: 51).

بکارگیری اعتبارسنجی متقابل k لایه همراه با جستجوی شبکه‌ای، رویکرد مفیدی برای میزان‌سازی دقیق عملکرد مدل یادگیری ماشین از طریق تغییر مقادیر آبرپارامترهای آن هست (Raschka, 2015: 187). اما بهینه‌سازی آبرپارامترها با استفاده از جستجوی شبکه‌ای به روش اعتبارسنجی متقابل، فرآیندی مستلزم صرف منابع و زمان زیاد است. از این رو، در این پژوهش، فضای جستجوی آبرپارامترها و همچنین، تعداد تکرارهای اعتبارسنجی متقابل محدود شده است (Oleksy, 2017: 52).

مجموعه آبرپارامترهای ارائه شده به الگوریتم رگرسیون لجستیک در جدول ۴ نمایش داده شده است.

جدول (۴): فضای جستجوی آبرپارامترها	
مقادیر	آبرپارامترها
[0/001, 0/01, 0/004, 0/002, 0/005, 0/0007, 0/0006, 0/0005, 0/006, 0/03, 0/025]	C
[{0:1, 1:11}, {0:1, 1:12}, {0:1, 1:8}, {0:1, 1:9}, {0:1, 1:10}, {0:1, 1:7/5}, {0:1, 1:8/5}, {0:1, 1:13}]	$class_weight$

۴-۵-۷- پس پردازش (معیارهای سنجش عملکرد و انتخاب مدل)

پس از آموزش رگرسیون لجستیک لاسو با مقادیر مختلف آبرپارامترها و ارزیابی عملکرد آن، آبرپارامترهای مندرج در جدول ۵، به عنوان آبرپارامترهای بهینه مدل انتخاب شده‌اند که به مدل دارای بهترین عملکرد از نظر توان پیش‌بینی منجر می‌شوند.

جدول (۵): آبرپارامترهای بهینه	
مقادیر	آبرپارامترها
$L1$	$penalty$
$saga$	$solver$
0/02	C
{0:1, 1:8}	$class_weight$

۴-۵-۸- مدل طبقه‌بندی نهایی

پس از اجرای رگرسیون لجستیک لاسو با آبرپارامترهای بهینه بر روی داده‌های آموزشی، ضرایب ویژگی‌های نامربوط و اضافی در مدل، صفر و نسبت شانس آن‌ها برابر با ۱ می‌شود. این بدان معناست که این ویژگی‌ها تأثیری بر شانس وقوع درماندگی مالی ندارند. ضرایب سایر ویژگی‌های مربوط و مهم به شرح مندرج در جدول ۶ است.

جدول (۶): ضرایب رگرسیون لجستیک لاسو					
نسبت شانس	ضرایب	ویژگی	نسبت شانس	ضرایب	ویژگی
۰/۹۶۱۳۹۷	-۰/۰۳۹۳۷	x _{۸۸}	۰/۰۵۷۵۵۸	-۲/۸۵۴۹۶	Intercept
۰/۹۵۶۲۳۲	-۰/۰۴۴۷۵	x _{۹۲}	۰/۹۷۳۰۶۲	-۰/۰۲۷۳۱	x _{۳۹}
۱/۰۶۳۱۹۱	۰/۰۶۱۲۷۵	x _{۹۳}	۱/۲۷۴۷۸۴	۰/۲۴۲۷۷۷	x _{۴۰}
۰/۸۹۵۶۴۴	-۰/۱۱۰۲۱	x _{۹۵}	۰/۵۸۵۶۳۲	-۰/۵۳۵۰۶	x _{۴۲}
۰/۹۱۳۶۸۳	-۰/۰۹۰۲۷	x _{۹۷}	۱/۰۸۰۳۷۱	۰/۰۷۷۳۰۵	x _{۴۵}
۰/۹۵۷۱۴۹	-۰/۰۴۳۸	x _{۹۸}	۰/۷۰۸۴۱۱	-۰/۳۴۴۷۳	x _{۴۶}
۰/۹۹۹۹۹۸	-۱/۵۴E-۰۶	x _{۱۰۲}	۰/۴۵۴۹۳۱	-۰/۷۸۷۶۱	x _{۴۷}
۱/۰۲۴۸۵۵	۰/۰۲۴۵۵۱	x _{۱۰۸}	۱/۰۰۰۵۷۱	۰/۰۰۰۵۷	x _{۴۸}
۰/۹۸۴۹۹۷	-۰/۰۱۵۱۲	x _{۱۰۹}	۰/۷۸۴۴۷۷	-۰/۲۴۲۷۴	x _{۵۰}
۰/۹۱۹۲۵۱	-۰/۰۸۴۲	x _{۱۱۳}	۱/۱۸۵۱۷۸	۰/۱۶۹۸۹۳	x _{۵۱}
۰/۹۶۸۳۱۱	-۰/۰۳۲۲	x _{۱۲۲}	۰/۹۵۳۸۸۹	-۰/۰۴۷۲۱	x _{۵۸}
۱/۰۲۷۵۹۷	۰/۰۲۷۲۲۳	x _{۱۲۱_۵}	۰/۹۵۱۹۵	-۰/۰۴۹۲۴	x _{۶۰}
۱/۳۵۴۸۴۶	۰/۳۰۳۶۸	x _{۱۲۱_۸}	۰/۹۷۷۴۸۹	-۰/۰۲۲۷۷	x _{۶۳}
۱/۲۳۹۲۰۹	۰/۲۱۴۴۷۴	x _{۱۲۱_۱۰}	۰/۹۹۶۸۲۳	-۰/۰۰۳۱۸	x _{۷۹}
۱/۰۶۹۱۷	۰/۰۶۶۸۸۲	x _{۱۲۱_۱۵}	۱/۰۱۷۳۲۲	۰/۰۱۷۱۷۴	x _{۸۲}
۱/۰۲۳۳۱	۰/۰۲۳۰۴۳	x _{۱۲۱_۲۰}	۱/۰۰۶۸۷۲	۰/۰۰۶۸۴۸	x _{۸۴}
۰/۸۹۲۹۵۶	-۰/۱۱۳۲۲	x _{۱۲۱_۲۱}	۱/۰۲۷۸۰۶	۰/۰۲۷۴۲۶	x _{۸۶}
۰/۹۹۸۲۸۴	-۰/۰۰۱۷۲	x _{۱۲۱_۲۷}	۱/۰۵۰۴۱۶	۰/۰۴۹۱۸۷	x _{۸۷}

بر اساس نتایج مندرج در جدول ۶، یک سال قبل از درماندگی مالی، ویژگی‌های رشد فروش، رشد سود خالص، سود خالص به کل بدهی‌ها، بدهی‌ها به خالص دارایی‌های مشهود، بهای تمام شده

کالای فروش رفته به فروش، تعدیلات سنواتی به کل دارایی‌ها، هزینه مالیات به سود قبل از مالیات، جریان نقدی عملیاتی به بدهی‌های جاری، قیمت پایانی سهام، تمرکز مالکیت، مالکیت مدیریتی، اندازه موسسه حسابرسی، تغییر حسابرس، اندازه هیات مدیره، رشد تولید ناخالص داخلی به قیمت پایه، نرخ بازار دلار، چرخه تجاری (روتن)، سود انباشته به سرمایه، صنایع سایر محصولات کانی غیرفلزی، لاستیک و پلاستیک دارای تأثیر منفی بر وقوع درماندگی مالی هستند. در واقع، همان گونه که از نسبت شانس آن‌ها پیداست، با افزایش این ویژگی‌ها یا با فعالیت در این صنایع، شانس وقوع درماندگی مالی (به اندازه ۱ منهای نسبت شانس) کاهش می‌یابد. همچنین، ویژگی‌های دارایی‌های ثابت به کل دارایی‌ها، سرمایه در گردش به حقوق صاحبان سهام، خالص دارایی‌ها به ازای هر سهم، لگاریتم فروش، حجم معاملات، تعداد روز معاملاتی، آمیهود، سهام شناور آزاد، مالکیت خانوادگی، نرخ بیکاری، صنایع استخراج نفت گاز و خدمات جنبی به جز اکتشاف، پیمانکاری صنعتی، تجارت عمده و خرده فروشی وسائط نقلیه موتور و رایانه و فعالیت‌های وابسته به آن دارای تأثیر مثبت بر وقوع درماندگی مالی هستند. در حقیقت، همان گونه که از نسبت شانس آن‌ها پیداست، با افزایش این ویژگی‌ها یا با فعالیت در این صنایع، شانس وقوع درماندگی مالی (به اندازه ۱ منهای نسبت شانس) افزایش می‌یابد.

سپس، مدل انتخابی، بر روی کل ۷۰٪ داده آموزشی تفکیک شده، آموزش داده می‌شود. آموزش مدل با استفاده از کل مجموعه داده آموزشی، به ماتریس درهم ریختگی مندرج در جدول ۷، منجر می‌شود.

جدول (۷): ماتریس درهم ریختگی مجموعه داده آموزشی			
واقعی		وضعیت	
تعداد شرکت درمانده	تعداد شرکت سالم	تعداد شرکت سالم	پیش‌بینی شده
۲۶	۲۳۶۰	تعداد شرکت درمانده	
۶۹	۱۱۴	جمع	
۹۵	۲۴۷۴		

معیارهای ارزیابی عملکرد طبقه‌بندی کننده انتخابی بر روی کل مجموعه داده آموزشی در جدول ۸ نشان داده شده است.

جدول (۸): معیارهای ارزیابی مجموعه داده آموزشی			
مقدار	معیار	مقدار	معیار
٪۵۰	ضریب همبستگی متیوز	٪۹۵	صحت
٪۸۳	میانگین هندسی	٪۳۸	دقت
٪۵۱	شاخص صحت متوازن	٪۷۳	فراخوانی
٪۲۷	خطای نوع ۱	٪۵۰	معیار F
٪۰۵	خطای نوع ۲	٪۹۵	ناحیه زیر منحنی مشخصه عملیاتی دریافت کننده
		٪۴۷	کاپا کوهن

۴-۵-۹- ارزیابی مدل نهایی

ارزیابی مدل نهایی به معنای برآورد عملکرد مدل انتخابی بر روی داده جدید است. از این رو، عملکرد مدل انتخابی در قسمت قبل، بر روی ۳۰٪ داده آزمایشی کنار گذاشته شده، مورد آزمون قرار می‌گیرد. پس از ارائه مجموعه داده آزمایشی به مدل انتخابی، ماتریس درهم ریختگی مندرج در جدول ۹ بدست می‌آید.

جدول (۹): ماتریس درهم ریختگی مجموعه داده آزمایشی			
واقعی		وضعیت	
تعداد شرکت درمانده	تعداد شرکت سالم	تعداد شرکت سالم	پیش‌بینی شده
۱۱	۱۰۱۶	تعداد شرکت درمانده	
۲۹	۴۵		
۴۰	۱۰۶۱		

معیارهای ارزیابی حاصل از ماتریس درهم ریختگی مجموعه داده آزمایشی به شرح مندرج در جدول ۱۰ است.

جدول (۱۰): معیارهای ارزیابی مجموعه داده آزمایشی			
مقدار	معیار	مقدار	معیار
۵۱٪	ضریب همبستگی متیوز	۹۵٪	صحت
۸۳٪	میانگین هندسی	۳۹٪	دقت
۵۱٪	شاخص صحت متوازن	۷۳٪	فراخوانی
۲۸٪	خطای نوع ۱	۵۱٪	معیار F
۰۴٪	خطای نوع ۲	۹۶٪	ناحیه زیر منحنی مشخصه عملیاتی دریافت کننده
		۴۸٪	کاپا کوهن

۵- نتیجه‌گیری و ارایه پیشنهادها

پیش‌بینی درماندگی مالی کماکان مسأله بسیار بااهمیتی و مورد توجه گروه‌های درون سازمانی و برون سازمانی نظیر مدیران شرکت، سرمایه‌گذاران، بستانکاران، حساب‌برسان، قانون‌گذاران دولت و سایر ذینفعان است (Aktan, 2011: 62). از این رو، هدف پژوهش حاضر، ارائه مدلی برای پیش‌بینی درماندگی مالی شرکت‌های پذیرفته شده در فرابورس و بورس اوراق بهادار تهران است. بر اساس نتایج این پژوهش، اطلاعات صورت‌های مالی، بازار سهام، حاکمیت شرکتی و متغیرهای اقتصاد کلان می‌تواند به عنوان ابزاری برای علامت‌دهی درماندگی مالی مورد استفاده قرار گیرد. افزون بر این، پژوهش بیور و همکاران (۲۰۰۵) نیز بیانگر این است که محتوای اطلاعاتی داده‌های صورت‌های مالی برای هشدار درماندگی مالی در طی زمان کاسته نشده است. از این رو، یافته‌های این پژوهش با یافته‌های آن‌ها سازگار است اگر چه این پژوهش‌ها در محیط متفاوت و با استفاده از تکنیک‌های تحلیلی متفاوتی در دوره‌های زمانی مختلفی انجام شده‌اند. همچنین، نتایج تجربی بیانگر این است که مدل لجستیک لاسو به نمره $F1$ ، ضریب همبستگی متیوز، فراخوانی و دقتی به ترتیب برابر با ۵۰٪، ۵۰٪، ۷۳٪ و ۳۸٪ بر روی مجموعه آموزشی منجر می‌شود. افزون بر این، آزمون مدل پیشنهادی بر روی مجموعه آزمایشی کنار گذاشته شده حاکی از این است که نمره $F1$ ، ضریب همبستگی متیوز، فراخوانی و دقتی به ترتیب برابر با ۵۱٪، ۵۱٪، ۷۳٪ و ۳۸٪ بر روی مجموعه آزمایشی بدست می‌آید. در انجام این پژوهش محدودیت‌هایی به شرح زیر وجود داشت: مدل ارائه شده صرفاً داده‌های کمی را بکار خواهد گرفت. نمونه شرکت‌های مورد بررسی در این پژوهش، محدود به شرکت‌های سهامی عام پذیرفته شده در فرابورس و بورس اوراق بهادار تهران است. این سوگیری مهم است؛ زیرا

شرکت‌های کوچک بیشتر در معرض درماندگی مالی هستند. از این رو، این محدودیت ممکن است تعمیم نتایج تجربی را محدود نماید. حجم اندک داده در دسترس، محدودیت‌هایی را در خصوص بکارگیری الگوریتم‌های پیچیده ایجاد می‌کند. از یک سو، پذیرش تعریف قانونی از درماندگی مالی طبق ماده ۱۴۱ قانون تجارت، و از سوی دیگر، احتمال دست‌کاری حساب‌ها، ابهاماتی را در خصوص تمایز دقیق شرکت‌های درمانده از غیردرمانده مطرح می‌کند. به بیان دقیق‌تر، نه تنها خود شرکت‌ها تمایل دارند که به منظور عدم شمول ماده ۱۴۱ قانون تجارت، صورت‌های مالی خود را دست‌کاری نمایند بلکه قانون‌گذار نیز انتقال مازاد تجدید ارزیابی شرکت‌ها به حساب افزایش سرمایه را برای شرکت‌های مشمول ماده ۱۴۱ قانون تجارت که به وسیله این تجدید ارزیابی از ماده ۱۴۱ قانون تجارت خارج شوند، را مجاز می‌داند هر چند که از لحاظ محتوایی و بنیادی، تغییر اساسی در ساختار مالی شرکت‌ها ایجاد نمی‌شود و صرفاً نوعی حساب آرایبی است. در واقع، پتانسیل و نقدینگی جدیدی وارد شرکت نمی‌شود بلکه صرفاً ارزش دارایی‌های فعلی شرکت‌ها به روزرسانی می‌شود و تنها ترازنامه شرکت‌ها تغییر می‌کند. بدیهی است که عدم تفکیک دقیق شرکت‌های درمانده از غیردرمانده تأثیر منفی بر عملکرد مدل می‌گذارد. افزون بر این، ماهیت نویزی داده‌های حسابداری و مالی، دست‌کاری حساب‌ها، تجدید ارائه مکرر صورت‌های مالی و در نتیجه تعدیلات سنواتی زیاد، عدم رعایت یکنواختی و ثبات رویه در تهیه گزارش‌های مالی و همچنین، دانش و دقت ناکافی دست‌اندرکاران تهیه و ارائه صورت‌های مالی در طبقه‌بندی صحیح حساب‌ها در سرفصل‌های مربوطه موجب کاهش محتوای اطلاعاتی داده‌های پیش‌بینی‌کننده و در نتیجه، تخریب عملکرد مدل می‌شود.

از این رو، پیشنهاد می‌شود که با افزودن داده‌های سال‌های آتی شرکت‌های فعلی و همچنین، شرکت‌های جدیدی که سهام آن‌ها در آینده در بورس اوراق بهادار تهران معامله خواهد شد، حجم داده‌های مورد استفاده را افزایش دهند تا بتوانند با بکارگیری الگوریتم‌های غیرخطی نظیر مدل‌های یادگیری عمیق، عملکرد مدل را بهبود دهند. همچنین، یافته‌های این پژوهش دارای مفاهیم ضمنی برای تحلیل‌گران و مدیران بخش دولتی و خصوصی است. با بکارگیری مدل پیش‌بینی درماندگی شرکت‌ها، قانون‌گذاران می‌توانند به راحتی ثبات اقتصادی را نظارت و تضمین کنند، سرمایه‌گذاران می‌توانند تصمیم‌های بهتری در خصوص زمان خرید سهام جدید یا حتی فروش سهام بگیرند، بستانکاران نیز از ارزش اعتباری شرکت‌ها آگاهی می‌یابند و می‌توانند بهتر در خصوص اعطای اعتبار، شرایط و مدت آن قضاوت نمایند، مدیریت شرکت می‌تواند از دست دادن مدیران و کارگران

کلیدی، عرضه‌کنندگان عمده، مشتریان بزرگ و همچنین، از بین رفتن اعتماد بستانکاران، سهامداران و سرمایه‌گذاران پیشگیری نماید.

منابع و مآخذ

۱. خواجهی، شکرالله و محمدحسین قدیریان آرانی (۱۳۹۶). نقش توانایی مدیریت در پیش‌بینی بحران مالی، پژوهش‌های حسابداری مالی، سال نهم، شماره ۴، پیاپی (۳۴)، ۸۳-۱۰۱.
۲. کاتبی، حسینقلی (۱۳۸۰). حقوق تجارت. چاپ هفتم، تهران: انتشارات گنج دانش.
3. Aktan, S. (2011). Early warning system for bankruptcy: Bankruptcy prediction (Doctoral dissertation, Karlsruhe Institute of Technology, KIT). Retrieved from <https://d-nb.info/1019790032/34>.
4. Altman, E. I. (1968). "Financial ratios, discriminant analysis and the prediction of corporate bankruptcy", *The Journal of Finance*, 23(4), 589-609.
5. Andrés, J., Landajo, M., & Lorca, P. (2012). "Bankruptcy prediction models based on multinorm analysis: An alternative to accounting ratios", *Knowledge-Based Systems*, 30, 67-77.
6. Ashoori, S., & Mohammadi, S. (2011). "Compare failure prediction models based on feature selection technique: Empirical case from Iran", *Procedia Computer Science*, 3, 568-573.
7. Beaver, W. H., Correia, M., & McNichols M. F. (2010). "Financial statement analysis and the prediction of financial distress", *Foundations and Trends in Accounting*, 5(2), 99-173.
8. Belli, G. (2009). Nonexperimental quantitative research. In S. D. Lapan & M. T. Quartaroli (Eds.), *Research essentials: An introduction to designs and practices*. (pp. 59-77). Jossey-Bass Publications.
9. Bonnes, K. (2017). Predicting mortgage demand using machine learning techniques (Master Thesis, University of Twente). Retrieved from https://essay.utwente.nl/73640/7/Bonnes_MA_EEMCS.pdf.
10. Cenciarelli, V. G., Greco, G., & Allegrini, M. (2018). "External audit and bankruptcy prediction", *Journal of Management and Governance*, 22(4), 863-890.
11. Chancharat, N. (2008). An empirical analysis of financially distressed Australian companies: The application of survival analysis (Doctoral dissertation, University of Wollongong). Retrieved from <https://ro.uow.edu.au/theses/401/>.
12. Chen, M. Y. (2011). "Bankruptcy prediction in firms with statistical and intelligent techniques and a comparison of evolutionary computation approaches", *Computers and Mathematics with Applications*, 62(12), 4514-4524.
13. Chen, H. L., Yang, B., Wang, G., Liu, J., Xu, X., Wang, S. J., & Liu, D. Y. (2011). "A novel bankruptcy prediction model based on an adaptive Fuzzy K-nearest neighbor method." *Knowledge-Based Systems*, 24, pp. 1348-1359.
14. Etemadi, H., Anvary Rostamy, A. A., & Farajzadeh Dehkordi, H. (2009). "A genetic programming model for bankruptcy prediction: Empirical evidence from Iran", *Expert Systems with Applications*, 36(2), 3199-3207.

15. Fan, X. (2016). An adaptive and diversity-based ensemble method for binary classification (Master Thesis, Carleton University). Retrieved from https://curve.carleton.ca/system/files/etd/e2e72ad2-2da5-47b8-ab6a28810d5eb197/etd_pdf/81f038dc409086dafcc1cced7b46be03/fan-anadaptiveanddiversitybasedensemblemethod.pdf.
16. Fontaine Rezende, F., Montezano, R., Nascimento de Oliveira, F., & Lameira, V. (2017). "Predicting financial distress in publicly-traded companies", *Revista Contabilidade & Finanças*, 28(75), 390-406.
17. Fonti, V. (2017). Feature selection using LASSO (Research paper in Business Analytics, Vrije Universiteit). Retrieved from https://beta.vu.nl/nl/Images/werkstuk-fonti_tcm235-836234.pdf.
18. Grosswindhager, S. (2009). Using penalized logistic regression models for predicting the effects of advertising material (Master Thesis, Vienna University of Technology). Retrieved from https://publik.tuwien.ac.at/files/PubDat_179921.pdf
19. Jardin, P. (2010). "Predicting bankruptcy using neural networks and other classification methods: The influence of variable selection techniques on model accuracy", *Neurocomputing*, 73(10-12), 2047–2060.
20. Jo, H., & Han, I. (1996). "Integration of case-based forecasting, neural network, and discriminant analysis for bankruptcy prediction", *Expert Systems with Applications*, 11(4), 415–422.
21. Johnson, R. B., & Christensen, L. (2014). *Educational research: quantitative, qualitative, and mixed approaches* (5th ed.). London: SAGE Publications, Inc.
22. Jones, S. (2017). "Corporate bankruptcy prediction: a high dimensional analysis", *Review of Accounting Studies*, 22(3), 1366-1422.
23. Klobucnik, J., Miersch, D., & Sievers, S. (2017). "Predicting early warning signals of financial distress: Theory and empirical evidence", Retrieved from https://papers.ssrn.com/sol3/papers.cfm?abstract_id=2237757.
24. Kothari, C. R. (2004). *Research methodology, methods and techniques*. New Delhi: New Age International (P) Ltd. Publishers.
25. Kwitek, M. (2016). A feasibility study of AZURE machine learning for sheet metal fabrication (Master Thesis, University of Vaasa). Retrieved from <https://www.tritonia.fi/fi/e-opinnaytteet/tiivistelma/7268/A+Feasibility+Study+of+Azure+Machine+Learning+for+Sheet+Metal+Fabrication>
26. Lee, K., Booth, D., & Alam, P. (2005). "A comparison of supervised and unsupervised neural networks in predicting bankruptcy of Korean firms", *Expert Systems with Applications*, 29(1), 1–16.
27. Lensberg, T., Eilifsen, A., & McKee, T. E. (2006). "Bankruptcy theory development and classification via genetic programming", *European Journal of Operational Research*, 169(2), 677–697.
28. Li, H., & Sun, J. (2011). "On performance of Case-Based reasoning in Chinese business failure prediction from sensitivity, specificity, positive and negative values", *Applied Soft Computing*, 11(1), 460–467.

29. Li, M. Y. L., & Miu, P. (2010). "A hybrid bankruptcy prediction model with dynamic loadings on accounting-ratio-based and market-based information: A binary quantile regression approach", *Journal of Empirical Finance*, 17(4), 818–833.
30. Lin, R. H., Wang, Y. T., Wu, C. H., & Chuang, C. L. (2009). "Developing a business failure prediction model via RST, GRA and CBR", *Expert Systems with Applications*, 36(2), 1593–1600.
31. López, V., Fernández, A., García, S., Palade, V. & Herrera, F. (2013). An insight into classification with imbalanced data: Empirical results and current trends on using data intrinsic characteristics. *Information Sciences*, 250, 113-141.
32. Mai, F., Tian, S., Lee, C., & Ma, L. (2019). "Deep learning models for bankruptcy prediction using textual disclosures", *European Journal of Operational Research*, 274(2), 743-758.
33. Manninen, T. (2014). Predictive modeling using sparse logistic regression with applications (Doctoral Dissertation, Tampere University of Technology). Retrieved from <https://tutcris.tut.fi/portal/files/1788046/manninen.pdf>.
34. McKee, T. E., & Lensberg, T. (2002). "Genetic programming and rough sets: A hybrid approach to bankruptcy classification", *European Journal of Operational Research*, 138(2), 436–451.
35. Mokhatab Rafiei, F., Manzari, S. M., & Bostanian S. (2011). "Financial health prediction models using artificial neural networks, genetic algorithm and multivariate discriminant analysis: Iranian Evidence", *Expert Systems with Applications*, 38(8), 10210–10217.
36. Niakšu, O. (2015). Development and application of data mining methods in medical diagnostics and healthcare management (Doctoral Dissertation, Vilnius University). Retrieved from https://old.mii.lt/files/mii_dis_2015_niaksu.pdf.
37. Ohlson, J. A. (1980). "Financial ratios and the probabilistic prediction of bankruptcy", *Journal of Accounting Research*, 18(1), 109 –131.
38. Oleksy, T. A. (2017). Machine learning methods for mood disorder decision support (Master Thesis, University of Bergen). Retrieved from <http://bora.uib.no/bitstream/handle/1956/16259/actigraphdataformoods.pdf?sequence=4&isAllowed=y>.
39. Pajkossy, K. (2013). Studying feature selection methods applied to classification tasks in natural language processing (Master Thesis, Eotvos Lorand University of Sciences). Retrieved from https://web.cs.elte.hu/blobs/diplomamunkak/msc_alkmat/2013/pajkossy_katalin.pdf
40. Pendharkar, P. C. (2005). "A threshold-varying artificial neural network approach for classification and its application to bankruptcy prediction problem", *Computers & Operations Research*, 32(10), 2561–2582.
41. Raschka, S. (2015). Python machine learning. Birmingham: Packt Publishing Ltd..
42. Ren, J. (2014). Robust feature selection with penalized regression in imbalanced high dimensional data (Doctoral Dissertation, University of Southern

- California). Retrieved from <http://digitallibrary.usc.edu/cdm/ref/collection/p15799coll3/id/443080>.
43. Shah, S. B. H. (2016). "The impact of corporate governance on financial distress; Evidence from Pakistan", (Master Thesis, Capital University of Science and Technology). Retrieved from <https://thesis.cust.edu.pk/UploadedFiles/Syed%20Basharat%20Hussain%20Shah%20-MMS151042.pdf>
44. Shearer, C. (2000). "The CRISP-DM model: The new blueprint for data mining", *Journal of Data Warehousing*, 5(4), 13-22.
45. Smith, R. F., & Winakor, A. H. (1935). *Changes in the financial structure of unsuccessful industrial corporations*. Urbana: University of Illinois.
46. Suntraruk, Phassawan (2009). *Predicting Financial Distress: Evidence from Thailand*. <http://www.efmaefm.org/OEFMAMEETINGS/EFMA%20ANNUAL%20MEETINGS/2009-milan/phd/phassawan.pdf>
47. Tinoco, M. H., & Wilson, N. (2013). "Financial distress and bankruptcy prediction among listed companies using accounting, market and macroeconomic variables", *International Review of Financial Analysis*, 30, 394-419.
48. Tsai, C. F., & Cheng, K. C. (2012). "Simple instance selection for bankruptcy prediction", *Knowledge-Based Systems*, 27, 333-342.
49. University of Notre Dame (n.d.). Retrieved January 18, 2019, from <https://www3.nd.edu/~busiforc/handouts/DataMining/dataminingdefinitions.html>
50. Waqas, H., & Md-Rus, R. (2018). "Predicting financial distress: Importance of accounting and firm-specific market variables for Pakistan's listed firms", *Cogent Economics & Finance*, 6, 1-16.
51. Wu, Y., Gaunt, C., & Gray, S. (2010). "A comparison of alternative bankruptcy prediction models", *Journal of Contemporary Accounting & Economics*, 6(1), 34-45.
52. Xu, W., Fu, H., & Pan, Y. (2019). "A novel soft ensemble model for financial distress prediction with different sample sizes", *Mathematical Problems in Engineering*, 2019, 1-12.
53. Zhou, L., Lai, K. K., & Yen, J. (2012). "Empirical models based on features ranking techniques for corporate financial distress prediction", *Computers and Mathematics with Applications*, 64(8), 2484-2496.
54. Zmijewski, M. E. (1984). "Methodological issues related to the estimation of financial distress prediction models", *Journal of Accounting Research*, 22, 59-82.

Financial Distress Prediction of the Listed Companies on Tehran Stock Exchange (TSE) and Iran Fara Bourse (IFB) Using Lasso Logistic Regression

Mohammad Namazi^{۲۰}

Shahla Ebrahimi^{۲۱}

Abstract:

The ability to predict corporate financial distress is important to business individuals as well as to the economy in general. Therefore, the purpose of this article is the detection of potential financial distress and early warnings of impending financial distress among the listed companies on Tehran Stock Exchange (TSE) and Iran Fara Bourse (IFB). To do so, a wide range of features including accrual accounting variables, cash-based accounting variables, market-based variables, corporate governance mechanisms, and macroeconomic indicators have been identified to prospectively predict the financial distress in the companies.

The final sample includes 421 firms leading to 3,670 firm-year observations. The prepared data, was then split into a train and test data set using a 70/30 ratio.

In this research, various data pre-processing machine learning techniques i.e., Z-score standardization, one-hot encoding, stratified K-fold validation combined with feature engineering are applied to improve classifier performance. Stratified K-fold cross validation method, (with $k = 5$) was used for estimation of model prediction performance during training phase. During the training phase, hyperparameter tuning of a model was carried out using a grid-search. Furthermore, a cost-sensitive meta-learning approach in conjunction with the proposed imbalance-oriented metric i.e., F1 score were used to overcome the extreme class imbalance issue.

Based on the experimental results, the tuned LASSO logistic model achieved a f1-score, MCC, recall and precision of respectively, 50%, 50%, 73% and 38% on the training set. Finally, the proposed model was tested on the hold-out test set which resulted in a f1-score, MCC, recall and precision of 51%, 51%, 73% and 39%, respectively.

Keywords: Financial Distress Prediction, Lasso Logistic Regression, Machine Learning, Data Mining, Tehran Stock Exchange.

JEL Classification: G33, G38, G34, E44, C19, M40

^{۲۰}. Professor of Accounting Shiraz University, Iran. mnamazi@rose.shirazu.ac.ir

^{۲۱}. PhD Student of Accounting Shiraz University, Iran. (Corresponding Author). shebrahimi_3622@yahoo.com