

## کاربرد ماشین بردار پشتیبان در پیش‌بینی درماندگی مالی شرکت‌ها با استفاده از نسبت‌های مالی

رضا راعی<sup>۱</sup>، سعید فلاح پور<sup>۲\*</sup>

۱. عضو هیات علمی دانشکده مدیریت دانشگاه تهران، ایران

۲. دانشجوی دوره دکتری مدیریت مالی دانشگاه تهران، ایران

(تاریخ دریافت: ۱۳۸۶/۱۲/۱، تاریخ تصویب: ۱۳۸۷/۵/۱۰)

استفاده از نسبت‌های مالی برای پیش‌بینی درماندگی مالی یا ورشکستگی شرکت‌ها، همیشه مورد توجه دانشگاهیان و بنگاه‌های اقتصادی، بویژه بانک‌ها و سایر نهادهای مالی بوده است. پیش‌بینی به موقع می‌تواند تصمیم‌گیران را در یافتن راه‌حل و پیشگیری از درماندگی مالی، یاری نماید. همچنین، این مدل‌ها کاربرد بسیار زیادی در رتبه‌بندی اعتباری و نحوه توزیع تسهیلات بانکی دارد. همواره سعی شده است تا دقت پیش‌بینی این مدل‌ها با استفاده از روش‌های پیشرفته‌تر بهبود یابد.

در این پژوهش که هدف اصلی آن بررسی کارایی استفاده از ماشین بردار پشتیبان (SVM) در پیش‌بینی درماندگی مالی شرکت‌ها بوده است، نتایج مدل SVM در مقایسه با مدل آماری رگرسیون لجستیک (LR) بررسی شده است. یافته‌های تحقیق حاکی از آن است که در پیش‌بینی درماندگی مالی شرکت‌ها، مدل SVM نسبت به مدل LR بطور معناداری، از دقت کلی بیشتری برخوردار است. بررسی‌های انجام شده نشان می‌دهد که مدل SVM نسبت به مدل LR، نه تنها از دقت کلی بهتری برخوردار است، بلکه توانایی بالاتری نیز در تعمیم‌پذیری دارد.

واژه‌های کلیدی:

## ۱. مقدمه

توسعه مدل‌های پیش‌بینی درماندگی مالی و ورشکستگی بعنوان یک موضوع مهم، همواره مورد توجه جامعه دانشگاهی و بنگاه‌های اقتصادی بوده است. پیش‌بینی درماندگی مالی می‌تواند اثر مهمی بر تصمیمات مربوط به اعطای تسهیلات و سودآوری نهادهای مالی داشته باشد.

پژوهش حاضر که به ارائه مدل جدیدی برای پیش‌بینی درماندگی مالی شرکت‌ها می‌پردازد، می‌تواند برای طراحی سیستم‌های امتیازدهی و رتبه‌بندی اعتباری در موسسات مالی استفاده گردد.

در فرهنگ لغات آکسفورد، واژه «Distress» به معنی درد، اندوه، فقدان منابع پولی و تنگدستی آورده شده است. در ادبیات مالی نیز تعاریف مختلفی از درماندگی مالی ارائه گردیده است. گردون در یکی از اولین مطالعات آکادمیک بر روی تئوری درماندگی مالی، آن را به عنوان کاهش قدرت سودآوری شرکت تعریف می‌کند که احتمال عدم توانایی بازپرداخت بهره و اصل بدهی را افزایش می‌دهد [۱۰].

ویتا کر درماندگی مالی را وضعیتی در نظر می‌گیرد که در آن جریان‌های نقدی شرکت از مجموع هزینه‌های بهره مربوط به بدهی بلند مدت کمتر است [۲۵].

از نقطه نظر اقتصادی، درماندگی مالی را می‌توان به زیان‌ده بودن شرکت تعبیر کرد که در این حالت شرکت دچار عدم موفقیت شده است. در واقع در این حالت نرخ بازدهی شرکت کمتر از نرخ هزینه سرمایه می‌باشد. حالت دیگری از درماندگی مالی زمانی رخ می‌دهد که شرکت موفق به رعایت کردن یک یا تعداد بیشتری از بندهای مربوط به قرارداد بدهی، مانند نگاهداشتن نسبت جاری یا نسبت ارزش ویژه به کل داراییها طبق قرارداد نمی‌شود. به این حالت نکول تکنیکی گفته می‌شود. حالات دیگری از درماندگی مالی عبارتند از زمانی که جریان‌های نقدی شرکت برای بازپرداخت اصل و فرع بدهی ناکافی باشد و همچنین زمانی که ارزش ویژه شرکت عددی منفی شود [۲۴].

در این پژوهش، ملاک درماندگی مالی شرکت‌ها، مشمول ماده ۱۴۱ بودن قانون تجارت می‌باشد. در قسمتی از این ماده آمده است: «اگر بر اثر زیانهای وارده حداقل نصف سرمایه شرکت از میان برود، هیأت مدیره مکلف است بلافاصله مجمع عمومی فوق العاده صاحبان سهام را دعوت نماید تا موضوع انحلال یا بقاء شرکت مورد شور و رأی واقع شود. هرگاه مجمع مزبور رأی به انحلال شرکت ندهد، باید در همان جلسه و با رعایت مقررات

ماده ۶ این قانون، سرمایه شرکت را به مبلغ سرمایه موجود کاهش دهد». باید توجه کرد که درماندگی مالی لزوماً به ورشکستگی منجر نمی شود بلکه اعلام ورشکستگی یکی از پیامدهای آن است که معمولاً آخرین راه حل است. شرکت ها برای مقابله با درماندگی مالی می توانند ساختار دهی مجدد انجام دهند.

یکی از راه هایی که می توان با استفاده از آن به بهره گیری مناسب از فرصت های سرمایه گذاری و تخصیص بهتر منابع کمک کرد، پیش بینی درماندگی مالی یا ورشکستگی است. به این ترتیب که اولاً، با ارائه هشدارهای لازم می توان شرکت ها را نسبت به وقوع درماندگی مالی هوشیار کرد تا آنها با توجه به این هشدارها دست به اقدام های مقتضی بزنند و دوم اینکه، سرمایه گذاران و اعتباردهندگان فرصت های مطلوب سرمایه گذاری را از فرصت های نامطلوب تشخیص دهند و منابعشان را در فرصت های مناسب سرمایه گذاری کنند. ارزش استفاده از نسبت های مالی در اجرای ورشکستگی شرکت ها مشخص شده است [۲].

بنابراین، پیش بینی درماندگی مالی و ورشکستگی شرکت ها همواره یکی از موضوعات مورد توجه سرمایه گذاران، اعتباردهندگان و دولت ها بوده است. تشخیص به موقع شرکت هایی که در شرف دچار شدن به درماندگی مالی هستند، بسیار مطلوب است [۱۲].

## ۲. پیشینه تحقیق

تا کنون از روش های مختلفی برای پیش بینی درماندگی مالی استفاده شده است. تحقیقات اولیه بر مدل های یک متغیره مانند یک نسبت مالی، تمرکز داشتند. یکی از قدیمی ترین نسبت های مالی که برای ارزیابی وضعیت اعتباری در سال ۱۸۷۰ مورد استفاده قرار گرفت، نسبت جاری بود.

در سال ۱۹۴۲ چارلز مروین، مطالعه ای انجام داد که در آن نسبت های مالی را برای شرکت های ورشکسته و غیر ورشکسته در یک دوره شش ساله بررسی کرد. او اظهار کرد که سه نسبت سرمایه در گردش تقسیم بر کل داراییها، ارزش ویژه تقسیم بر کل بدهی و نسبت جاری، پیش بینی کننده خوبی برای ورشکستگی می باشند. مروین به این نتیجه رسید که از بین این نسبت ها، نسبت سرمایه در گردش به کل داراییها، بهترین شاخص برای ورشکستگی شرکت است [۱۱].

در سال ۱۹۶۶، ویلیام بیور برای بررسی توان نسبت‌های مالی در پیش‌بینی درماندگی مالی، از تجزیه و تحلیل یک متغیری استفاده کرد. او در این تجزیه و تحلیل بیشتر از نسبت‌هایی استفاده کرد که مربوط به جریانات نقدی می‌شدند. در این پژوهش، بیور عدم توانایی شرکت به انجام تعهدات مالی اش را بعنوان درماندگی مالی تعریف کرد.

در این تحقیق، بیور ۳۰ نسبت مالی را که تصور می‌کرد بهترین شاخص برای سلامت مالی یک شرکت هستند انتخاب کرد. سپس این نسبت‌ها را به شش گروه تقسیم کرد. این شش گروه عبارت بودند از: نسبت‌های مربوط به جریان نقدی، نسبت‌های بدهی به کل دارایی‌ها، نسبت‌های دارایی‌های نقد شونده به کل دارایی‌ها، نسبت‌های دارایی‌های نقد شونده به بدهی‌های جاری، نسبت‌های فعالیت (گردش) و نسبت‌های سود خالص [۵].

در تحقیقات بعدی مدل‌های چند متغیره مورد توجه قرار گرفت. در واقع، محققان دریافته بودند که عوامل گوناگونی وجود دارند که بطور همزمان بر درماندگی مالی شرکت‌ها اثر دارند. ادوارد آلتمن، در سال ۱۹۶۸ برای اولین بار اثر ترکیبات مختلف نسبت‌های مالی را برای پیش‌بینی درماندگی مالی شرکت‌ها بررسی کرد. آلتمن در این مطالعه از MDA استفاده کرد. مدلی که او بدست آورد و به «Z-Score» معروف است، هنوز بعنوان شاخصی برای سلامت مالی شرکت‌ها مورد استفاده قرار می‌گیرد. تئوری اصلی آلتمن این بود که مدل پیش‌بینی ورشکستگی او که از ۵ نسبت مالی تشکیل می‌شود، می‌تواند برای تشخیص شرکت‌های ورشکسته از غیر ورشکسته مورد استفاده قرار گیرد. او پیشنهاد کرد که از مدلش در ارزیابی اعطای وام‌های تجاری، فرآیندهای کنترل داخلی و بررسی گزینه‌های سرمایه‌گذاری استفاده شود [۴].

در سال ۱۹۷۲، ادوارد دیکین، تحقیقات انجام شده توسط بیور و آلتمن را در مدل جدیدی ادغام کرد. دیکین اظهار کرد که روش بیور توان پیش‌بینی کنندگی بهتری دارد در حالیکه رویکرد آلتمن بینش بهتری بدست می‌دهد. دیکین نیز برای پیش‌بینی ورشکستگی از مدل MDA استفاده کرد ولی ۱۴ نسبتی را که در مطالعه بیور مورد استفاده قرار گرفته بودند بکار برد [۹].

السون در سال ۱۹۸۰ مدلی را با استفاده از تکنیک لجیت توسعه داد. وی در این پژوهش از ۱۰۵ شرکت ورشکسته و ۲۰۵ شرکت غیر ورشکسته بین سال‌های ۱۹۷۰ تا ۱۹۷۶ استفاده کرد. او نه نسبت مالی را بعنوان متغیر مستقل بکار برد. از این نه نسبت مالی، پنج تای آنها در مطالعات قبلی نیز استفاده شده بودند [۱۶].

مک کی و گرینس تین در سال ۲۰۰۰ مطالعات قبلی انجام شده در زمینه ورشکستگی را مورد انتقاد قرار دادند. آنها که از RPA برای پیش بینی ورشکستگی استفاده کردند، شش نسبت را بعنوان متغیرهای مستقل در نظر گرفتند [۱۴].

شاه و مرتزا در سال ۲۰۰۰ مدلی را با استفاده از ANN برای پیش بینی ورشکستگی ارائه دادند. در این مطالعه از اطلاعات ۶۰ شرکت ورشکسته و ۵۴ شرکت غیر ورشکسته بین سال های ۱۹۹۲ تا ۱۹۹۴ استفاده شد. دقت پیش بینی این مدل ۷۳٪ بدست آمد [۱۸].

مین و لی نیز در سال ۲۰۰۵ با استفاده از ماشین بردار پشتیبان اقدام به طراحی مدلی برای پیش بینی ورشکستگی شرکت ها نمودند. پژوهش آنها نشان داد که SVM نسبت به مدل های آماری سنتی، از عملکرد بهتری برخوردار است [۱۵].

شین، لی و کیم در سال ۲۰۰۵ با استفاده از ماشین بردار پشتیبان، مدلی را برای پیش بینی ورشکستگی مطرح کردند. آنها عملکرد مدلشان را با عملکرد شبکه های عصبی مصنوعی مقایسه نمودند. مطالعه آنها نشان داد که ماشین بردار پشتیبان هم از نظر تعمیم پذیری و هم از نظر دقت کلی مدل، عملکرد بهتری دارد. برای انجام این پژوهش، آنها از ۱۰ نسبت مالی بین سال های ۱۹۹۶ تا ۱۹۹۹ استفاده نمودند [۲۰].

روند مطالعات نشان می دهد که هر چند مدل های آماری توانستند پیش بینی های خوبی را در مورد درماندگی مالی یا ورشکستگی شرکت ها ارائه نمایند، در عین حال مفروضات محدود کننده برخی از این مدل ها، مانند خطی بودن، نرمال بودن و مستقل بودن متغیرهای پیش بین از هم، بر روی اثربخشی این روش موثر بود. بنابراین، به تدریج روش های دیگری به منظور مقابله با برخی یا تمامی این محدودیت ها و بهبود عملکرد پیش بینی ها معرفی گردید. به عنوان مثال، می توان به روش های شبکه های عصبی مصنوعی [۷، ۱۳ و ۶]، الگوریتم ژنتیک [۱۹ و ۲۲] و ماشین بردار پشتیبان [۱۵ و ۲۰] نیز اشاره نمود.

در این پژوهش، مدل SVM که در حل مسائل مربوط به طبقه بندی عملکرد بسیار خوبی از خود نشان داده است و در سال های اخیر در کشورهای توسعه یافته برای پیش بینی درماندگی مالی و ورشکستگی مورد توجه واقع شده است، به همراه یکی از پرکاربردترین مدل های آماری برای چنین مطالعه ای، یعنی LR، مورد بررسی قرار گرفته است.

### ۳. ماشین بردار پشتیبان

اولین الگوریتم برای طبقه‌بندی و دسته‌بندی الگوها در سال ۱۹۳۶ توسط فیشر ارائه شد و معیار آن برای بهینه کردن، کم کردن خطای طبقه‌بندی داده‌های آموزشی بوده است. بسیاری از الگوریتمها و روش‌هایی که تا کنون نیز برای طراحی طبقه‌بندی‌کننده‌ها ارائه شده است، از همین استراتژی پیروی می‌کنند. در این روش‌ها، طبقه‌بندی‌کننده‌ی طراحی شده دارای خاصیت تعمیم‌دهندگی کمی است. اگر طراحی طبقه‌بندی‌کننده‌ی الگو را بعنوان یک مساله بهینه‌سازی در نظر بگیریم، بسیاری از این روش‌ها با مشکل بهینه‌سازی محلی در تابع مواجهند و در دام بهینه‌سازی محلی گرفتار می‌آیند.

در سال ۱۹۶۵ محقق روسی به نام ولادیمیر وپنیک گامی بسیار مهم در طراحی طبقه‌بندی‌کننده‌ها برداشت. وی نظریه آماری یادگیری را به صورت مستحکم‌تری بنا نهاد و ماشین‌های بردار پشتیبان را بر این اساس ارائه داد. ماشین‌های بردار پشتیبان دارای خواص زیر هستند:

۱. طراحی طبقه‌بندی‌کننده با حداکثر تعمیم ۲- رسیدن به نقطه بهینه کلی تابع ۳- تعیین خودکار ساختار و توپولوژی بهینه برای طبقه‌بندی‌کننده ۴- مدل کردن توابع تمایز غیرخطی با استفاده از هسته‌های غیر خطی و مفهوم حاصل ضرب داخلی در فضاهای هیلبرت.

SVM الگوریتمی است که نوع خاصی از مدل‌های خطی را می‌یابد که حداکثر حاشیه ابر صفحه را حاصل می‌کنند. حداکثر کردن حاشیه ابر صفحه منجر به حداکثر شدن تفکیک بین طبقات می‌شود. به نزدیک‌ترین نقاط آموزشی به حداکثر حاشیه ابر صفحه، بردارهای پشتیبان اطلاق می‌گردد. تنها از این بردارها (نقاط) برای مشخص کردن مرز بین طبقات استفاده می‌شود [۲۰].

اگر داده‌ها به صورت خطی مجزا از هم باشند، SVM به ماشین‌های خطی برای تولید یک سطح بهینه که داده‌ها را بدون خطا و با حداکثر فاصله میان صفحه و نزدیکترین نقاط آموزشی (بردارهای پشتیبان) تفکیک می‌نماید، آموزش می‌دهد. اگر نقاط آموزشی را به صورت  $[x_i, y_i]$  و بردار ورودی  $x_i \in R^n$  و ارزش طبقه  $y_i \in \{-1, 1\}$ ,  $i = 1, \dots, l$  تعریف کنیم، آنگاه در حالتی که داده‌ها بصورت خطی قابل تفکیک هستند، قواعد تصمیم‌گیری که تعریف می‌شود و توسط یک صفحه بهینه که طبقات تصمیم‌گیری باینری را تفکیک می‌کند، به صورت معادله زیر است:

$$y = \text{sign} \left( \sum_{i=1}^N y_i \alpha_i (X \bullet X) + b \right) \quad (1)$$

که در آن  $Y$  خروجی معادله،  $y_i$  ارزش طبقه نمونه آموزشی  $X_i$  و  $\bullet$  نشان دهنده ضرب داخلی است. بردار  $x = (x_1, x_2, \dots, x_n)$  نشان دهنده یک داده ورودی و بردارهای  $X_i$ ،  $i=1, \dots, N$  بردارهای پشتیبان هستند. در معادله ۱، پارامترهای  $\alpha_i, b$  تعیین کننده ابر صفحه هستند.

اگر داده‌ها به صورت خطی قابل تفکیک نباشند، معادله ۱ به معادله زیر تغییر می‌یابد:

$$Y = \text{sign} \left( \sum_{i=1}^N y_i \alpha_i K(X, X_i) + b \right) \quad (2)$$

تابع  $K(X, X_i)$ ، تابع کرنلی است که برای ایجاد ماشین‌هایی با انواع مختلفی از سطوح تصمیم‌گیری غیرخطی در فضای داده‌ها، ضرب‌های داخلی تولید می‌کند. به عنوان مثال، سه نوع تابع کرنل که در مدل SVM بکار می‌رود، عبارتند از:

- ماشین چند جمله‌ای با تابع کرنل

$$K(X, X_i) = (X \bullet X_i + 1)^d$$

که در آن  $d$ ، درجه کرنل چند جمله‌ای است.

- ماشین تابع پایه شعاعی با تابع کرنل

$$K(X, X_i) = \exp(-1/\delta^2 (X - X_i)^2)$$

که در آن  $\delta$  پهنای باند کرنل تابع پایه شعاعی است.


- ماشین NN دو لایه با تابع کرنل

$$K(X, X_i) = S[(X \bullet X_i)] = 1/[1 + \exp\{v(X \bullet X_i) - c\}]$$

که در آن  $c$  و  $v$  پارامترهای تابع زیگموییدی  $S[(X \bullet X_i)]$  هستند به نحوی که

نامعادله  $c \geq v$  برقرار باشد [۲۳].

فرآیند یادگیری برای ایجاد توابع تصمیم‌گیری دارای ساختاری دو لایه است. SVM از تئوری بهینه‌سازی برای طبقه‌بندی که براساس تئوری یادگیری آماری، خطای طبقه‌بندی را به حداقل می‌رساند، استفاده می‌کند. شکل ۱ فرآیند مدل SVM را نشان می‌دهد.



نمودار ۱. فرایند مدل SVM

SVM در شناسایی الگو، برآورد رگرسیون، پیش‌بینی‌های سری‌های زمانی مالی، بازاریابی، بازده‌های برآوردی تولید، طبقه‌بندی متن، تشخیص چهره با استفاده از تصویر، شناسایی دست‌خط و تشخیص‌های پزشکی در مقایسه با سایر تکنیک‌های یادگیری عملکرد بهتری دارد [۸].

در مجموع می‌توان گفت که SVM روشی است که در آن نقاط قوت روش‌های آماری سنتی که بیشتر تئوری محور می‌باشند و از نظر تجزیه و تحلیل ساده هستند، ترکیب می‌گردد. در سال‌های اخیر در حوزه‌های مختلف مدیریت مالی مانند رتبه‌بندی اعتباری و پیش‌بینی سری‌های زمانی از رویکرد SVM استفاده‌های زیادی شده است. در این تحقیق نیز از SVM برای پیش‌بینی در ماندگی مالی استفاده و قدرت پیش‌بینی آن با روش LR مقایسه می‌شود.

#### ۴. روش تحقیق

هدف اصلی این تحقیق، بررسی کاربرد و عملکرد ماشین بردار پشتیبان در پیش‌بینی در ماندگی مالی شرکت‌ها است. در واقع با استفاده از چندین متغیر پیش‌بین (مستقل) سعی می‌شود متغیر ملاک (وابسته) تعیین شود.

پس از مطالعه جامع ادبیات تحقیق و بررسی نسبت‌های مالی مهم مورد استفاده در پژوهش‌های قبلی، در نهایت ۵ نسبت مالی که بیش از همه در تحقیقات قبلی مورد استفاده



قرار گرفته بود، انتخاب گردیدند. در انتخاب این نسبت‌ها دو معیار مهم مورد نظر بوده است:

اول اینکه میانگین آنها در گروه شرکت‌های سالم و درمانده مالی از نظر آماری متفاوت باشد و دوم اینکه امکان دسترسی به اطلاعات وجود داشته باشد. به این منظور، ابتدا آماره‌های مربوط به هر یک از متغیرها در هر دو گروه محاسبه شدند و آزمون برابری میانگین‌ها نیز در مورد آنها صورت گرفت. در این مرحله بود که تصمیم نهایی نسبت به انتخاب پنج متغیر اصلی گرفته شد. از این مرحله به بعد، ادامه فعالیت‌ها با استفاده از این پنج نسبت شامل:

۱. سود قبل از هزینه مالی و مالیات به کل دارایی‌ها با نماد: EBIT- TA
  ۲. سود قبل از هزینه مالی و مالیات به خالص فروش با نماد: EBIT- NS
  ۳. کل حقوق صاحبان سهام به کل بدهی‌ها با نماد: TE- TD
  ۴. سرمایه در گردش به کل دارایی‌ها با نماد: WC- TA
  ۵. دارایی‌های جاری به بدهی‌های جاری با نماد: CA- CL
- صورت گرفت.

آزمون برابری میانگین‌ها نشان داد که بین میانگین تمامی متغیرهای دو گروه، در سطح ۵٪ تفاوت معنی‌داری وجود دارد. نگاره ۱ نتایج آزمون برابری میانگین‌ها را برای متغیرهای مورد استفاده نشان می‌دهد.

همانطور که نتایج آزمون برابری میانگین‌ها در نگاره ۱ نشان می‌دهد، می‌توان گفت میانگین تمامی متغیرها با ۹۹ درصد اطمینان، در دو گروه متفاوت هستند.

نگاره ۱. نتایج آزمون برابری میانگین‌ها در مورد متغیرهای استفاده شده

نام متغیر	میانگین در شرکت‌های سالم	میانگین در شرکت‌های درمانده مالی	آماره t	P-Value
CA_CL	۱/۶۳۸۵	۰/۹۷۱۲	۲/۷۵۱	۰/۰۰۹
EBIT_NS	۰/۲۷۰۶	-۰/۰۹۲۷	۹/۰۲۵	۰/۰۰۰
EBIT_TA	۰/۲۶۲۴	-۰/۰۵۶۴	۱۱/۱۶	۰/۰۰۰
TE_TD	۰/۷۰۷۱	۰/۰۴۳۶	۶/۹۳۲	۰/۰۰۰
WC_TA	۰/۲۰۲۱	-۰/۱۲۹۱	۴/۶۴	۰/۰۰۰

جامعه مورد مطالعه در این پژوهش عبارت است از شرکت‌های تولیدی پذیرفته شده در بورس اوراق بهادار تهران. نمونه مورد استفاده متشکل از ۸۰ شرکت تولیدی می‌باشد. با توجه به تعداد شرکت‌های بزرگ که مشمول ماده ۱۴۱ قانون تجارت بودند و اینکه، قریب به اتفاق این شرکت‌ها در بین سال‌های ۱۳۷۵ تا ۱۳۸۰ مشمول ماده مذکور شده بودند، لیستی از کل شرکت‌های این گروه (درمانده مالی) در این دوره پنج ساله تهیه شد. از بین شرکت‌های این گروه (در مجموع حدود ۵۰ شرکت)، تنها ۴۰ شرکت بودند که دسترسی به اطلاعات مورد نیاز آنها بطور کامل وجود داشت. بنابراین، تمامی این ۴۰ شرکت به عنوان شرکت‌های درمانده مالی انتخاب شدند.

سپس، ۴۰ شرکت تولیدی سالم با استفاده از نمونه‌گیری تصادفی انتخاب گردیدند. با توجه به اینکه برای آزمون تعمیم‌پذیری مدل، عملکرد مدل برای یک سال قبل ( $t-1$ ) و دو سال قبل ( $t-2$ ) از درماندگی مالی نیز بررسی شده است، بنابراین در مورد هر شرکت از اطلاعات سه سال مالی آنها استفاده گردیده است. پس در مجموع از اطلاعات مالی ۸۰ شرکت تولیدی استفاده شده است که این ۸۰ شرکت بطور برابر به دو گروه درمانده مالی و سالم تقسیم شده‌اند.

در ارتباط با فرضیه تحقیق باید گفت که با توجه به نتایج پژوهش‌های انجام شده، فرضیه اصلی این پژوهش به این صورت است:

«دقت کلی مدل SVM در پیش‌بینی درماندگی مالی از دقت کلی مدل LR بیشتر است.» این فرضیه پژوهشی، در قالب سه فرضیه آماری برای سال‌های  $t$ ،  $t-1$  و  $t-2$  مورد آزمون قرار گرفته‌اند.

به منظور کاهش اثر تغییر پذیری نمونه‌ها، نمونه اصلی به دو بخش تقسیم شده است. بدین ترتیب که با استفاده از یک بخش، مدلسازی انجام می‌شود و روی بخش دیگر آزمایش می‌شود. همچنین برای غنی‌تر شدن مدل‌ها، ۴ دسته نمونه فرعی ایجاد شده است. در هر نمونه فرعی، ۶۰ نمونه برای آموزش مدل و ۲۰ نمونه برای آزمایش قدرت مدل استفاده گردیده است. به عبارت دیگر، در هر نمونه فرعی جای ۲۰ نمونه از مجموعه آموزشی با ۲۰ نمونه مجموعه آزمایشی تعویض می‌شود. بنابراین، با توجه به اینکه برای هر ترکیب یک مدل ارائه می‌شود، در مجموع برای هر یک از دو رویکرد SVM و LR، ۴ مدل مختلف ارائه گردیده است.

به منظور تلخیص داده‌ها، ابتدا نسبت‌های مورد نظر با استفاده از داده‌های جمع‌آوری شده برای تمامی شرکت‌ها و هر یک از سال‌های  $t$ ،  $(t-1)$  و  $(t-2)$  محاسبه شدند. کلیه فعالیت‌های مربوط به عملیات تلخیص با استفاده از نرم‌افزار اکسل به همراه کدنویسی توسط VBA انجام پذیرفته است.

پس از آنکه داده‌ها به این ترتیب تلخیص شدند، ابتدا مدل آماری، یعنی LR مورد توجه قرار گرفت. مدل‌های مربوط با استفاده از رگرسیون لجستیک موجود در نرم‌افزار SPSS بدست آمد که بصورت زیر است:

$$Z = -1.9313 + 0.0545X_1 + 0.0386X_2 - 0.0025X_3 + 0.0339X_4 + 0.0420X_5 \quad (1): \text{برای نمونه فرعی (۱)}$$

$$Z = -2.5120 + 0.0528X_1 + 0.1120X_2 - 0.0005X_3 - 0.0194X_4 + 0.0286X_5 \quad (2): \text{برای نمونه فرعی (۲)}$$

$$Z = -1.8180 + 0.0720X_1 + 0.2983X_2 - 0.0158X_3 - 0.0878X_4 + 0.0485X_5 \quad (3): \text{برای نمونه فرعی (۳)}$$

$$Z = -2.3256 + 0.0168X_1 + 0.0400X_2 - 0.0002X_3 + 0.0224X_4 + 0.0618X_5 \quad (4): \text{برای نمونه فرعی (۴)}$$

که در آن:

$$X_1: (WC\_TA) = \text{سرمایه در گردش به کل دارایی‌ها}$$

$$X_2: (EBIT\_TA) = \text{سود قبل از هزینه مالی و مالیات به کل دارایی‌ها}$$

$$X_3: (CA\_CL) = \text{نسبت جاری}$$

$$X_4: (EBIT\_NS) = \text{سود قبل از هزینه مالی و مالیات به خالص فروش}$$

$$X_5: (TE\_TD) = \text{کل حقوق صاحبان سهام به کل بدهی‌ها}$$

Z: شاخص کل

در ارتباط با مدل SVM، پارامترهای مختلفی وجود دارند که تغییر در آنها در عملکرد مدل بسیار اثرگذار است. یکی از مهمترین این پارامترها، تعیین نوع تابع کرنل است. در این پژوهش پس از بررسی عملکرد مدل با استفاده از توابع گوناگون و متداول کرنل، تابعی که دارای بهترین عملکرد بود، به عنوان مدل مقایسه‌ای برای مدل LR انتخاب شد. با توجه به نتایج بدست آمده، نهایتاً تابع کرنل RBF (که در مورد آن در بخش قبلی توضیح داده شد)، برای مدلسازی استفاده گردید. تمامی فعالیت‌های مربوط به مدل SVM با استفاده از نرم افزار MATLAB انجام شده است.

## ۵. یافته‌های تحقیق

در این قسمت یافته‌های تحقیق و تجزیه و تحلیل آنها ارائه می‌شود. نگاره ۲، نتایج پیش‌بینی مدل SVM را به همراه مدل LR برای سال  $t$  نشان می‌دهد.

نگاره ۲. نتایج آزمون دقت مدل‌ها برای سال t

نام گروه	SVM				LR			
	نمونه فرعی (۴)	نمونه فرعی (۳)	نمونه فرعی (۲)	نمونه فرعی (۱)	نمونه فرعی (۴)	نمونه فرعی (۳)	نمونه فرعی (۲)	نمونه فرعی (۱)
درمانده مالی	۳۹	۴۰	۳۹	۳۷	۳۷	۳۶	۳۷	۳۷
	%۹۷/۵	%۱۰۰	%۹۷/۵	%۹۲/۵	%۹۲/۵	%۹۰	%۹۲/۵	%۹۲/۵
فاقد درماندگی مالی	۳۶	۴۰	۳۸	۴۰	۳۶	۳۷	۳۷	۳۶
	%۹۰	%۱۰۰	%۹۵	%۱۰۰	%۹۰	%۹۲/۵	%۹۲/۵	%۹۰
دقت کلی	۷۵	۸۰	۷۷	۷۷	۷۳	۷۳	۷۴	۷۳
	%۹۳/۷۵	%۱۰۰	%۹۶/۲۵	%۹۶/۲۵	%۹۱/۲۵	%۹۱/۲۵	%۹۲/۵	%۹۱/۲۵

در هر ستون، عدد اول نشان‌دهنده تعداد پیش‌بینی صحیح و عدد پایینی آن، درصد پیش‌بینی صحیح را نشان می‌دهد. مجدداً یادآوری می‌گردد که تعداد نمونه‌ها در هر گروه ۴۰ شرکت است. قسمت «دقت کلی»، حاصل جمع پیش‌بینی‌های صحیح در هر دو گروه است. همانطور که نگاره ۲ نشان می‌دهد، دقت کلی پیش‌بینی مدل SVM در سال t برای نمونه‌های فرعی ۱ تا ۴، به ترتیب ۵/، ۳/۷۵، ۸/۷۵ و ۲/۵ بیشتر است. این امر قدرت بالای مدل SVM را در سال t نشان می‌دهد. برای بررسی فرضیه پژوهشی، مبنی بر عملکرد بهتر مدل SVM در سال t، از آزمون مقایسه زوجی استفاده شده است. با استفاده از این آزمون، عملکرد بهتر مدل SVM از نظر آماری بررسی می‌شود. نگاره ۳ نتایج آزمون مقایسه زوجی را برای سال t نشان می‌دهد.

نگاره ۳. نتایج آزمون مقایسه زوجی برای سال t

SVM	LR	میانگین دقت کلی
۰/۹۶۵۶۲۵	۰/۹۱۵۶۲۵	
	۳/۷۰۳	آماره t
	۰/۰۳۴	p-value

همانطور که نگاره ۳ نشان می‌دهد، می‌توان گفت که دقت کلی پیش‌بینی مدل SVM، با سطح اطمینان ۹۵٪، از دقت کلی پیش‌بینی مدل LR بیشتر است. بنابراین، فرضیه پژوهشی برای سال t تایید می‌گردد.

نگاره ۴، نتایج پیش‌بینی مدل SVM را به همراه مدل LR برای یک سال قبل (t-1) از درماندگی مالی نشان می‌دهد.

نگاره ۴. نتایج آزمون دقت مدل‌ها برای یک سال قبل از درماندگی مالی (t-1)

نام گروه	SVM				LR			
	نمونه فرعی (۴)	نمونه فرعی (۳)	نمونه فرعی (۲)	نمونه فرعی (۱)	نمونه فرعی (۴)	نمونه فرعی (۳)	نمونه فرعی (۲)	نمونه فرعی (۱)
درمانده مالی	۳۶	۳۴	۳۸	۳۷	۲۸	۳۰	۳۲	۲۸
	%۹۰	%۸۵	%۹۵	%۹۲/۵	%۷۰	%۷۵	%۸۰	%۷۰
فاقد درماندگی مالی	۳۲	۳۶	۳۰	۳۰	۳۵	۳۸	۳۴	۳۷
	%۸۰	%۹۰	%۷۵	%۷۵	%۸۷/۵	%۹۵	%۸۵	%۹۲/۵
دقت کلی	۶۸	۷۰	۶۸	۶۷	۶۳	۶۸	۶۶	۶۵
	%۸۵	%۸۷/۵	%۸۵	%۸۳/۷۵	%۷۸/۷۵	%۸۵	%۸۲/۵	%۸۱/۲۵

همانطور که نگاره ۴ نشان می‌دهد، دقت کلی پیش‌بینی مدل SVM در سال t-1 برای نمونه‌های فرعی ۱ تا ۳، ۲/۵٪ و برای نمونه فرعی ۴، ۶/۲۵٪ بیشتر است. این عملکرد بهتر، قدرت بالای تعمیم‌پذیری مدل SVM را نشان می‌دهد. برای بررسی فرضیه پژوهشی، مبنی بر عملکرد بهتر مدل SVM در سال t-1، نیز از آزمون مقایسه زوجی استفاده شده است. نگاره ۵ نتایج آزمون مقایسه زوجی را برای سال t-1 نشان می‌دهد.

نگاره ۵. نتایج آزمون مقایسه زوجی برای سال t-1

SVM	LR	میانگین دقت کلی
۰/۸۵۳۱۲۵	%۸۱۸۷۵۰	
۳/۶۶۷		t آماره
۰/۰۳۵		p-value

همانطور که نگاره ۵ نشان می‌دهد، می‌توان گفت که دقت کلی پیش‌بینی مدل SVM، با سطح اطمینان ۹۵٪، از دقت کلی پیش‌بینی مدل LR بیشتر است. بنابراین، فرضیه پژوهشی

برای سال t-1 نیز تایید می‌گردد. نگاره ۵، همچنین نشان می‌دهد که مدل SVM، تا ۱ سال قبل از درماندگی مالی، بطور متوسط بالغ بر ۸۵ درصد موارد را صحیح پیش‌بینی می‌نماید. نگاره ۶، نتایج پیش‌بینی مدل SVM را به همراه مدل LR برای دو سال قبل (t-2) از درماندگی مالی نشان می‌دهد.

نگاره ۶. نتایج آزمون دقت مدل‌ها برای دو سال قبل از درماندگی مالی (t-2)

نام گروه	SVM				LR			
	نمونه فرعی (۴)	نمونه فرعی (۳)	نمونه فرعی (۲)	نمونه فرعی (۱)	نمونه فرعی (۴)	نمونه فرعی (۳)	نمونه فرعی (۲)	نمونه فرعی (۱)
درمانده مالی	۳۹	۳۲	۳۹	۳۹	۱۵	۱۷	۲۳	۱۸
	%۹۷/۵	%۸۰	%۹۷/۵	%۹۷/۵	%۳۷/۵	%۴۲/۵	%۵۷/۵	%۴۵
فاقد درماندگی مالی	۲۱	۳۱	۲۱	۲۱	۳۷	۳۷	۳۵	۳۷
	%۵۲/۵	%۷۷/۵	%۵۲/۵	%۵۲/۵	%۹۲/۵	%۹۲/۵	%۸۷/۵	%۹۲/۵
دقت کلی	۶۰	۶۳	۶۰	۶۰	۵۲	۵۴	۵۸	۵۵
	%۷۵	%۷۸/۷۵	%۷۵	%۷۵	%۶۵	%۶۷/۵	%۷۲/۵	%۶۸/۷۵

همانطور که نگاره ۶ نشان می‌دهد، دقت کلی پیش‌بینی مدل SVM در سال t-2 برای نمونه‌های فرعی ۱ تا ۴، به ترتیب %۶/۲۵، %۲/۵، %۱۱ و %۱۰ بیشتر است. همانگونه که مشخص است، با دور شدن از سال t، اختلاف عملکرد دو مدل بیشتر شده است که این امر، قدرت بسیار بیشتر مدل SVM را در تعمیم‌پذیری نشان می‌دهد. نگاره ۷، نتایج بررسی فرضیه پژوهشی، مبنی بر عملکرد بهتر مدل SVM را برای سال t-2 نشان می‌دهد.

نگاره ۷. نتایج آزمون مقایسه زوجی برای سال t-2

SVM	LR	میانگین دقت کلی
۰/۷۵۹۳۷۵	۰/۶۸۴۳۷۵	
۳/۷۹۵		آماره t
۰/۰۳۲		p-value

همانگونه که نگاره ۷ نشان می دهد، برای سال  $t-2$  نیز می توان گفت که دقت کلی پیش بینی مدل SVM، با سطح اطمینان ۹۵٪، از دقت کلی پیش بینی مدل LR بیشتر است. بنابراین، فرضیه پژوهشی برای سال  $t-2$  نیز تایید می گردد. نگاره ۷، همچنین نشان می دهد که مدل SVM، تا ۲ سال قبل از درماندگی مالی، بطور متوسط حدود ۷۶ درصد موارد را صحیح پیش بینی می نماید.

## ۶. نتیجه گیری

پیش بینی درماندگی مالی و ورشکستگی شرکت ها یکی از پژوهش های با اهمیت در حوزه مالی است. معمولاً بانکها و موسسات رتبه بندی اعتباری از این مدل ها برای اتخاذ تصمیمات اعتباری و اختصاص رتبه استفاده می نمایند. با پیش بینی درماندگی مالی و پس از آن ریشه یابی مسأله و حل آن، می توان به نتایج بسیار رضایت بخشی دست یافت.

در این پژوهش، پیش بینی درماندگی مالی شرکت ها با استفاده از مدل های LR و SVM انجام گرفت. نتایج این بررسی نشان داد که مدل SVM می تواند جانشین بسیار قدرتمندی برای مدل آماری و پرکاربرد LR باشد. در واقع، یافته های تحقیق نشان داد که دقت کلی مدل SVM در هر سه سال، از دقت کلی مدل LR، بطور معناداری بیشتر است. بویژه آنکه نتایج نشان داد که قدرت تعمیم پذیری مدل SVM بسیار بالاتر از مدل LR است. به عبارت دیگر، در سال های قبل از درماندگی مالی، می توان از مدل SVM با اطمینان بیشتری برای پیش بینی یا رتبه بندی اعتباری استفاده نمود.

همچنین، نتایج حاصل از این پژوهش نشان داد که نسبت های مالی می توانند پیش بینی کننده خوبی برای درماندگی مالی شرکت ها باشند. به علاوه، با توجه به توان بالای مدل های ارائه شده، بانکها و موسسات رتبه بندی اعتباری می توانند مدل ها و نسبت های مالی استفاده شده در این پژوهش را در فرایند رتبه بندی اعتباری شرکت ها بکار بگیرند.

در مجموع باید گفت که با استفاده از نتایج این پژوهش بعنوان اولین گام، می توان از مبتلا شدن شرکت ها به درماندگی مالی و ورشکستگی و همچنین پیامدهای آن بطور مطلوبی جلوگیری کرد. البته در صورتیکه پس از پیش بینی به ریشه یابی مسأله و ردیابی علل پرداخته شود. همچنین، بانکها و سایر موسسات مالی می توانند برای اتخاذ تصمیمات

اعتباری دقیق‌تر و علمی‌تر از این مدل‌ها استفاده نمایند، بویژه بانک‌هایی که قصد دارند رویکرد رتبه‌بندی داخلی از دستورالعمل‌های ۲ را پیاده‌سازی نمایند.

## منابع

۱. آذر، عادل و مومنی، منصور (۱۳۷۷). *آمار و کاربرد آن در مدیریت (تحلیل آماری)*. تهران: سمت.
۲. مهران، ساسان؛ بهرامفر، نقی و غیور، فرزاد. بررسی رابطه بین نسبت‌های نقدینگی سنتی و نسبت‌های حاصل از صورت جریان وجوه نقد جهت ارزیابی تداوم فعالیت شرکت‌ها. *فصلنامه بررسی‌های حسابداری و حسابرسی*. سال دوازدهم - شماره ۴۰ - تابستان ۱۳۸۴ - صص ۱۷-۳.
۳. سرمد، زهره؛ بازرگان، عباس و حجازی، الهه (۱۳۸۰). *روش‌های تحقیق در علوم رفتاری*. تهران: آگه.
4. Altman, E. I. (1968). Financial ratios, discriminant analysis and the Prediction of corporate bankruptcy. *The Journal of Finance*, 23 (4), 589-609
5. Beaver, W. H. (1966). Financial ratios as predictors of failure. *Journal of Accounting Research*, 4, Empirical Research in Accounting: Selected Studies, (Supplement), 71-111.
6. Boritz, J., & Kennedy, D. (1995). Effectiveness of neural networks types for prediction of business failure. *Expert Systems with Applications*, 9, 503-512.
7. Charalambous, C., Charitous, A., & Kaourou, F. (2000). Comparative analysis of artificial neural network models: application in bankruptcy prediction. *Annals of Operations Research*, 99, 403-425.
8. Cristianini Nello & Shawe John (2000). *An Introduction to Support Vector Machines and Other Kernel-based Learning Methods*. Cambridge University Press.
9. Deakin, E. B. (1972, Spring). A discriminant analysis of predictors of Business failure. *Journal of Accounting Research*, 10 (1), 167-179.



10. Gordon, M.J. (1971). Towards a theory of Financial distress. *The Journal of Finance*, 26, 347-356.
11. Horrigan, J. o. (1968, Autumn). A short history of Financial ratio analysis. *The Accounting Review*, 284-294.
12. Jones, F. L. (1987). Current techniques in Bankruptcy Prediction. *Journal of Accounting Literature*, 6, 131-164.
13. Lee, K. C., Han, I. G., & Kwon, Y. (1996). Hybrid neural network models for bankruptcy predictions. *Decision Support Systems*, 18, 63-72.
14. Mckee, T. E., & Greenstein, M. (2000). Predicting bankruptcy using recursive partitioning and a realistically proportioned data set. *Journal of forecasting*, 19 (3), 219-230.
15. Min H. Jae, & Lee C. Young (2005). Bankruptcy prediction using support vector machine with optimal choice of kernel function parameters. *Expert Systems with Applications*, 28, 603-614.
16. Ohlson, J. (1980). Financial ratios and the probabilistic prediction of bankruptcy. *Journal of Accounting Research*, 18(1), 109-131.
17. Salchengerger, L. M., Cinar, E. M., & Lash, N. A. (1992). Neural networks: A new tool for Predicting thrift failures. *Decision Sciences*, 23, 899- 916.
18. Shah, J. R., & Murtaza, M. B. (2000). A neural network based clustering procedure for bankruptcy Prediction. *American Business Review*, 18 (2), 80-86.
19. Shin, K., & Lee, Y. (2002). A genetic algorithm application in bankruptcy prediction modeling. *Expert Systems with Applications*, 23(3), 321-328.
20. Shin S. Kyung, Lee S. Taik, & Kim J. Hyun (2005). An application of support vector machines in bankruptcy prediction model. *Expert Systems with Applications*, 28, 127-135.
21. Tabachnich, Barbera & Fidell, Linda (2001). Using multivariate Statistics (4<sup>th</sup> ed.). Boston: Allyn & Bacon.
22. Varetto, F. (1998). Genetic algorithms applications in the analysis of insolvency risk. *Journal of Banking and Finance*, 22, 1421-1439.
23. Wang Lipo (2005). Support Vector Machines: Theory and Applications. Springer
24. Weston J. Fred., Copeland, Thomas E. (1992). *Managerial Finance*. Dryden Press; 9th edition

25. Whitaker, Richard (1999). The Early Stage of Financial Distress. *Journal of Economics and Finance*, 23 (2), 123-133.

Archive of SID