

Fraud Detection in Banking Electronic Payment Using Data Mining

Marzie Hosseini

IT Expert at Tourism Bank

Ma.hosseini@tourismbank.ir

Abstract

Fraud continuing variation is one of the most important Fraud Detection challenge in Electronic Payment Systems. Electronic markets need high Performance Fraud Detection methods with top accuracy. In this project we have used logistic regression, BP neural network and GMDH neural network to make a useful method detecting Fraud in a bank financial transactions. We have implemented these methods on real dataset and have measured their results. The results are GMDH neural network ۹۱,۷۳%, logistic regression ۸۹,۲۶% and BP neural network ۹۰,۵۴%. Therefore our recommended method has the best accuracy.

Keywords: Fraud, Electronic Payment Systems, Financial transactions, Data Mining, GMDH Neural Network

Archive of SID

تشخیص تقلب در سیستم‌های پرداخت الکترونیکی بانکها با استفاده از داده کاوی

مرضیه حسینی

کارشناس فناوری اطلاعات بانک گردشگری

Ma.hosseini@tourismbank.ir

چکیده

یکی از چالش‌های تشخیص تقلب در حوزه سیستم‌های پرداخت الکترونیکی، تنوع و تغییر مداوم شیوه‌های تقلب است لذا نیاز به روش‌های تشخیص تقلب با کارایی و دقت بالا به روشنی قابل درک است. در این پژوهش روش داده کاوی رگرسیون لجستیک، شبکه عصبی BP و شبکه عصبی GMDH برای ساخت مدل‌هایی جهت شناسایی تقلب در تراکنش‌های مالی دستگاه خودپرداز یک بانک پیاده سازی شدند. در ادامه، این روش‌ها بر روی داده‌های واقعی آزمایش و کارایی هر روش سنجیده شد. روش شبکه عصبی GMDH با دقت ۹۱،۷۳ درصد در شناسایی تقلب یا غیرتقلب بودن تراکنش‌های مالی بهترین کارایی را در مقایسه با دو روش رگرسیون لجستیک با دقت کلی ۸۹،۲۶ و شبکه عصبی BP با دقت کلی ۹۰،۵۴ داشت. با توجه به نتایج بدست آمده روش پیشنهادی در تشخیص تقلب نسبت به دو روش دیگر با دقت بیشتری عمل کرده است.

واژه های کلیدی: تقلب، سیستم‌های پرداخت الکترونیکی، تراکنش‌های مالی، داده کاوی، شبکه عصبی GMDH

مقدمه

طی سال‌های اخیر تجارت الکترونیک رشد قابل توجهی داشته، بطوریکه امروزه به عنوان یکی از کانال‌های رایج برای کسب و کارها مطرح است. علت این امر را باید در گسترش روزافزون اینترنت و سهولت استفاده از این کانال در بسیاری از موارد جستجو کرد. اما همان‌طور که فرایند پرداخت جز لاینفک هر کسب و کاری است، پرداخت الکترونیکی نیز از اجزای لاینفک تجارت الکترونیکی است، همان‌گونه که بازار قابل توجهی برای فروشندگان است، منبع درآمد خوبی برای سوءاستفاده متقلبین نیز بوده است.

امروزه روش‌های متفاوتی برای کشف تقلب، بویژه در حوزه بانکداری الکترونیک صورت گرفته است که از رایج‌ترین آنها روش داده کاوی می‌باشد. اگرچه روشها و الگوریتم‌های روش داده کاوی طی سالیان اخیر گسترش و پیشرفت چشم‌گیری داشته‌اند، اما مساله دقت و سرعت در کشف تقلب هنوز به عنوان مساله ای چالش برانگیز مطرح است. با توجه به اهمیتی که در مورد تقلب کارت‌های اعتباری و تراکنش‌های الکترونیکی مطرح شد، در این پژوهش سعی داریم تا با پیاده‌سازی روش‌هایی از داده کاوی، شیوه ای موثر برای افزایش دقت تشخیص تقلب بیابیم. در این پژوهش به سه روش داده کاوی می‌پردازیم. روش‌های رگرسیون و شبکه عصبی پس انتشار خطا به عنوان روش‌های موجود و روش شبکه عصبی مبتنی بر الگوریتم ژنتیک^۱ به عنوان راه حلی جدید به تفسیر بیان خواهند شد. پژوهش جاری از داده‌های تراکنش‌های واقعی یک بانک بهره برده شده است، لذا نتایج حاصله نسبت به پژوهش‌های دیگر واقعی‌تر بوده و این از مزایای مهم پژوهش محسوب می‌شود. با توجه به معیارهای به دست آمده، تشخیص مدل شبکه عصبی مصنوعی GMDH از بیشترین معیار صحت برخوردار بوده و بنابراین می‌توان آن را به عنوان بهترین مدل جهت تشخیص تقلب تراکنش‌های مالی (در بین مدل‌های بکار برده شده در این پژوهش) معرفی نمود.

مفاهیم پایه

پرداخت الکترونیکی عبارت است از فراهم آوردن وسیله پرداخت برای محصولات و سرویس‌ها از طریق ارتباط عمومی به نحوی که کلیه اطلاعات مربوط به پرداخت به وسیله یک شبکه ارسال شده و نیاز به هیچ ارتباط خارجی (فکس-تلفن یا پست) نباشد [محمودی، فروزنده، ۲۰۰۹]. به عبارت دیگر پرداخت الکترونیکی شامل هرگونه پرداختی بین افراد، کسب و کارها و یا بانک است که از بستر ارتباطات از راه دور و یا شبکه‌های الکترونیکی با استفاده از فناوری‌های جدید صورت می‌پذیرد (Sumanjeet, 2009). انواع سیستم‌های پرداخت الکترونیکی عبارتند از پرداخت از طریق یک واسط (سرویس‌های تسویه حساب)، پرداخت براساس مبادله الکترونیکی وجوه (EFT) - مبادله پول نمادین، پرداخت براساس پول الکترونیکی، کارت اعتباری، چک الکترونیکی، پول دیجیتال.

از میان روش‌های ذکر شده کارت اعتباری مقبول‌ترین روش پرداخت خصوصا در کشورهای توسعه یافته و در حال توسعه است (محمودی، فروزنده، ۲۰۰۹) به گونه‌ای که بیشترین خسارت در اثر تقلب در کارت‌های اعتباری متوجه فروشندگان و

شرکت‌های صادرکننده کارت است. در حالیکه در انواع دیگر پرداخت‌های الکترونیکی بیشترین خطر متوجه خریدار است. به طور کلی اجزای تشکیل دهنده یک سیستم عملیاتی کارت اعتباری شامل صاحب کارت/مشتری، فروشنده/بازرگان، بانک پرداخت کننده، بانک صادر کننده، واسط امور بانکی می باشد. صادرکننده در این سیستم‌ها، همواره حساب خریدار را زیر نظر دارد و هنگام خرید، اعتبار وی را تأیید یا رد می‌کند. در واقع طرف حساب فروشنده، پایانه پرداخت و طرف حساب پایانه پرداخت، صادر کننده کارت است. ممکن است که بانک اعتباری کسی که در حسابش موجودی کافی ندارد را تأیید کند، در

¹ GMDH

این صورت آن بانک موظف به تسویه حساب در مهلت مقرر است و سپس صادرکننده با قوانین داخلی خود با مشتری طرف حساب خواهد بود. به طبع کارهایی که بر روی حسابها انجام می‌گیرد نیز تراکنش‌هایی مشخص، استاندارد و از پیش تعریف شده است که عبارتند از تایید هویت، ابطال، تسویه، استرداد، پرداخت، کسر از حساب، مطالبه مقدار.

پیشینه پژوهش

روش‌های بکار رفته در سامانه‌های کشف تقلب برای بازنمایی دانش، تحلیل اطلاعات و مدل کردن رفتار عادی، شامل روش‌هایی مانند سیستم‌های مبتنی بر قانون^۱، روش آماری، تحلیل‌های گذار حالت^۲ و روش‌های داده‌کاوی مانند شبکه عصبی، درخت تصمیم‌گیری، الگوریتم ژنتیک، شبکه بیزین و ماشین بردار پشتیبان، خوشه‌بندی داده‌ها یا ترکیبی از روش‌های فوق است. داده‌کاوی نام خود را از شباهت بین جستجو برای یافتن اطلاعات با ارزش تجاری در یک پایگاه اطلاعات بزرگ (مثل یافتن محصولات مرتبط در یک پایگاه اطلاعات بزرگ) و کاویدن کوه برای یافتن رگه‌های اصلی سنگ معدن گرفته است (Standards, 2010) هر دو فرایند شامل حرکت و یا جستجوی هوشمندانه در یک حجم بسیار بزرگ به منظور یافتن ارزش می‌باشد. امروزه داده‌کاوی با حمایت سه تکنولوژی که به مرحله بلوغ رسیده‌اند کاملاً آماده استفاده می‌باشد. این سه تکنولوژی عبارتند از جمع‌آوری و ذخیره‌سازی داده‌ها، کامپیوترهای با قدرت پردازش چندگانه، الگوریتم‌های پیشرفته داده‌کاوی. برای فهم بهتر اینکه داده‌کاوی چه کاری انجام می‌دهد، بهتر است ابتدا مفاهیم، کاربردها، عملیات و روش‌های داده‌کاوی به تفکیک بیان شوند (Yamanishi, 2011). این اطلاعات عبارتند از:

- عملیات، شامل دسته‌بندی، پیش‌بینی، خوشه‌بندی، تخمین، تعیین ارتباط بین متغیرها.
- کاربردها، شامل دسته‌بندی مشتریان، نگهداری مشتریان، شناسایی تقلب، تحلیل سایت‌های اینترنتی، تحلیل داده‌ها در بازاریابی، تحلیل و پیش‌بینی روندهای بازار بورس.
- تکنیک‌ها، شامل شبکه‌های عصبی، درخت تصمیم‌گیری، الگوریتم‌های نزدیکترین همسایه، تحلیل خوشه، استنتاج قانون، الگوریتم ژنتیک.

روش پیشنهادی

یکی از روش‌هایی که به عنوان یک روش امیدوارکننده در مسأله تشخیص تقلب معرفی گردیده است، روش شبکه عصبی مصنوعی می‌باشد که در برخی از موارد توانایی بالقوه‌ی خوبی جهت تشخیص تقلب‌های مالی از خود نشان داده‌اند. اما نکته اساسی این است که در مدل‌های شبکه عصبی مصنوعی، پیش‌داوری محقق در مورد ساختار مدل با توجه به فروض اولیه، به شبکه تحمیل می‌شود. حال آنکه در این بین مدل‌های شبکه عصبی مبتنی بر الگوریتم GMDH، نوعی شبکه‌ی خودسامانده و یک‌سویه بوده و دیگر نیازی به تحمیل شرایط اولیه توسط محقق ندارد، که استفاده از این نوع شبکه عصبی به دلیل بیان شده از جمله نوآوری‌های این پژوهش به‌شمار می‌آید.

^۱ Rule-Based Expert System

^۲ State transition analysis

شبکه عصبی مصنوعی

شبکه عصبی روشی است که با استفاده از مجموعه‌ای از گره‌های بهم‌مرتبط، از کارکرد مغز انسان تقلید می‌کند. این روش مبتنی است بر مدل‌های رایانه‌ای از نورون‌های زیستی. یک شبکه عصبی چندلایه دربرگیرنده تعداد زیادی واحد (نورون) بهم‌مرتبط در الگویی از ارتباطات است (Phua et al., ۲۰۰۵). این روش به شکل گسترده‌ای در رده بندی و خوشه‌بندی استفاده شده است و پس از رگرسیون پرکاربردترین روش داده‌کاوی مورد استفاده در کشف تقلب‌های مالی است (Yue et al., ۲۰۰۷). نخست، شبکه با استفاده از مجموعه‌ای از داده‌های زوجی برای ترسیم ورودیها و خروجیها آموزش داده می‌شود. سپس وزن ارتباطات بین نورون‌ها تثبیت می‌شود و شبکه برای تعیین رده بندی‌های مجموعه‌ای جدید از داده‌ها مورد استفاده قرار می‌گیرد (Phua et al., ۲۰۰۵). مزایای این روش از این قرارند؛ نخست اینکه این روش انطباق‌پذیر است. دوم اینکه این روش مدل‌های دارای پایایی ۲۶ ایجاد می‌کند و سوم اینکه اگر وزنهای آموزشی تغییر کنند، فرایند رده بندی را نیز می‌توان اصلاح کرد. آنان با استفاده از داده‌های مالی و غیرمالی، یک مدل بحران مالی تدوین کردند. نتایج مطالعه آنان نشان می‌دهد که شبکه‌های عصبی مصنوعی بهتر از روشهای سنتی آماری، بحران مالی را پیش‌بینی می‌کنند.

الگوریتم ژنتیک

الگوریتم ژنتیک یکی از الگوریتم‌های جست‌وجو بوده که بر اساس ژنتیک ارگانیسم‌های زنده پایه‌گذاری شده است. این الگوریتم اصل "انتخاب یا بقای اصلح"^۴ داروین^۵ را با یک سری اطلاعات تصادفی ساخت، ادغام نموده و یک الگوریتم جست‌وجو با خصوصیت روش‌های تکاملی طبیعی ایجاد می‌نماید (Shu-Heng, 2002). در واقع اساس کار این گونه الگوریتم‌ها، حل نمودن مسائل دنیای واقعی از طریق شبیه سازی فرآیندهای ژنتیک طبیعی می‌باشد. همچنین، با توجه به آنکه بسیاری از مسائل دنیای صنعتی بویژه سیستم‌های تولیدی بسیار پیچیده بوده و با روش‌های بهینه سازی سنتی و متداول قابل حل نمی‌باشند، نقش روش‌های بهینه‌سازی احتمالی نظیر الگوریتم ژنتیک در این زمینه بسیار حساس و مؤثر خواهد بود.

مدل‌های شبکه عصبی مبتنی بر الگوریتم GMDH

اساساً روش‌های تکاملی^۶ مانند الگوریتم ژنتیک، کاربرد وسیعی در مراحل مختلف طراحی شبکه‌های عصبی دارند (مهرآرا، بهزادمهر، اهراری، محقق، ۲۰۱۱) چنانکه دارای قابلیت‌های منحصربه فردی در یافتن مقادیر بهینه و امکان جست‌وجو در فضاها غیر قابل پیش‌بینی هستند (جعالی، نریمان زاده، آتش کاری، ۲۰۰۶). از این‌رو در این پژوهش جهت طراحی شکل شبکه عصبی و تعیین ضرایب آن، از الگوریتم ژنتیک استفاده شده است. زیرا شبکه عصبی GMDH مبتنی بر الگوریتم ژنتیک، ابزاری با قابلیت بالا در مدل‌سازی سیستم‌های غیرخطی پویای پیچیده به شمار می‌رود.

^۴ Survival of the Fittest

^۵ Darwin

^۶ Evolutionary

شبکه عصبی GMDH در برگیرنده مجموعه‌ای از نرون‌ها بوده که از پیوند جفت‌های مختلف از طریق یک چندجمله‌ای درجه دوم به وجود می‌آید. فرض کنید مجموعه‌ای از m متغیر شامل x_1, x_2, \dots, x_m و یک متغیر y وجود دارد، داده‌های مربوط به هر کدام از x_i ها و متغیر هدف y متغیر خروجی نیز برای یک دوره زمانی وجود دارد به عبارتی هر یک از متغیرها به صورت یک بردار که شامل اعداد سری زمانی مربوط به آن متغیر است، می‌باشد (زمانی، ۲۰۱۰). اطلاعات اولیه‌ای که جهت ساخت الگوریتم GMDH باید جمع‌آوری گردد. مجموعه‌ای از n مشاهده است که در ماتریس زیر نشان داده شده است (زمانی، ۲۰۱۰).

$$\begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_n \end{bmatrix} = \begin{bmatrix} x_{11} & x_{12} & \dots & x_{1m} \\ x_{21} & x_{22} & \dots & x_{2m} \\ \vdots & \vdots & \text{مجموعه آموزش} & \vdots \\ x_{n1} & x_{n2} & \dots & x_{nm} \\ \vdots & \vdots & \text{مجموعه آزمون} & \vdots \\ x_{n1} & x_{n2} & \dots & x_{nm} \end{bmatrix}$$

برای شروع به کار الگوریتم با دو مسئله مواجه هستیم تشخیص رابطه‌ای که متغیر خروجی را بر اساس متغیرهای ورودی x_i ها تولید می‌کند. پیش بینی y به ازای مقادیر معلوم x_i ها به عبارتی نیاز به تشخیص مدل و رابطه بین متغیرها می‌باشد (مدل سازی) که سپس بتوان از روی آن مدل مقادیر آتی متغیر هدف پیش بینی کرد [Ivakhnenko, 1995].

مبنای الگوریتم GMDH عبارت از فرآیندی جهت ساخت یک چند جمله‌ای با مراتب بالا است که به سری تابع ولترا^۶ معروف است و به شکل زیر ارائه می‌گردد: (این چند جمله -

ای را ایواخنکو نیز می‌نامند).

$$\hat{y} = a_0 + \sum_{i=1}^m a_i x_i + \sum_{i=1}^m \sum_{j=1}^m a_{ij} x_i x_j + \sum_{i=1}^m \sum_{j=1}^m \sum_{k=1}^m a_{ijk} x_i x_j x_k + \dots \quad (1)$$

برای این منظور در الگوریتم GMDH ابتدا به تجزیه سری توابع ولترا به چند جمله‌ای‌های دو متغیره درجه دوم می‌پردازیم.

$$G(x_i, x_j) = a_0 + a_1 x_i + a_2 x_j + a_3 x_i^2 + a_4 x_j^2 + a_5 x_i x_j \quad (2)$$

در این تجزیه، سری ولترا به مجموعه‌ای از معادلات بازگشتی زنجیره‌ای تبدیل می‌گردد به گونه‌ای که مجدداً با جایگذاری جبری هر یک از روابط بازگشتی در این رابطه سری ولترا برقرار می‌گردد.

$$y_i = f(x_{i1}, x_{i2}, x_{i3}, \dots, x_{im}) \quad i = 1, 2, 3, \dots, m \quad (3)$$

^۶ Volterra Functional Series

تقریب زده می شود: f توسط تابع y_i

$$\hat{y}_i = f(x_{i1}, x_{i2}, x_{i3}, \dots, x_{im}) \quad i = 1, 2, 3, \dots, m \quad (4)$$

و در صورتی که تابع f به صورت زیر بیان شود:

$$\hat{y} = a_0 + \sum_{i=1}^m a_i x_i + \sum_{i=1}^m \sum_{j=1}^m a_{ij} x_i x_j + \sum_{i=1}^m \sum_{j=1}^m \sum_{k=1}^m a_{ijk} x_i x_j x_k + \dots \quad (5)$$

در این صورت رابطه F را می توان به فرم زیر تجزیه نمود:

$$\begin{aligned} \hat{y}_k &= G(u_i, u_j) & i, j &= 1, 2 (i \neq j) & k &= 1 \\ \hat{u}_k &= G(s_i, s_j) & i, j &= 1, 2, k, F_1 (i \neq j) & F_1 &\leq C_{F_2}^2 & k &= 2 \\ \hat{s}_k &= G(p_i, p_j) & i, j &= 1, 2, k, F_2 (i \neq j) & F_2 &\leq C_{F_3}^2 & k &= 3 \\ &\vdots & & & & & & \\ \hat{z}_k &= G(w_i, w_j) & i, j &= 1, 2, k, F_l (i \neq j) & F_l &\leq C_m^2 & k &= F_{l+1} \\ \hat{w}_k &= G(x_i, x_j) & i, j &= 1, 2, k, F_m (i \neq j) & & & k &= F_m \end{aligned} \quad (6)$$

همان گونه که در معادلات بالا مشاهده می شود ترتیب روابط فوق از بالا به پایین نمایی از پروسه تجزیه رابطه (۷) به چند جمله‌ای‌های درجه دوم بوده و از طرفی نیز ترتیب این روابط از پایین به بالا بیانگر تکمیل رابطه (۷) توسط معادلات بازگشتی می باشد در واقع هدف این الگوریتم یافتن ضرایب مجهول α در سری توابع ولترا می باشد. لازم به ذکر است که تمامی مدل-های جزئی به وجود آمده از یک ساختار متشابه همانند رابطه زیر برخوردار هستند:

$$\hat{f}(x_i, x_j) = v_0 + v_1 x_i + v_2 x_j + v_3 x_i^2 + v_4 x_j^2 + v_5 x_i x_j \quad (7)$$

با توجه به اینکه هدفی را که ما در این الگوریتم دنبال می کنیم چیزی جز مدل سازی سیستم اولیه نیست لذا با ترکیب مدل سیستم‌های جزئی و تکرار این عمل می توان به مدل اصلی سیستم دست یافت.

$$\hat{y} = v_0 + \sum_{i=1}^m v_i x_i + \sum_{i=1}^m \sum_{j=1}^m v_{ij} x_i x_j + \sum_{i=1}^m \sum_{j=1}^m \sum_{k=1}^m v_{ijk} x_i x_j x_k + \dots \quad (8)$$

بعد از تجزیه سیستم اصلی به تعداد C_m^2 سیستم جزئی، مدلی با دو متغیر ورودی برای هر یک از آن ها محاسبه می شود.

سپس مدل های جزئی ایجاد شده را دو به دو با هم ترکیب کرده که حاصل این ترکیب، تعداد $\frac{C_m^2(C_m^2-1)}{2}$ سیستم و یا

مدل جزئی جدید با حداقل سه و چهار متغیر ورودی می باشد، البته تعداد متغیرهای وابسته به مدل و یا به عبارتی تعداد ورودی های سیستم مهم نبوده و تنها دقت تخمین واقعی سیستم اصلی توسط مدل های ایجاد شده اهمیت دارد لذا با در نظر گرفتن این قاعده برای کاهش محاسبات مضاعف و زائد و افزایش راندمان و دقت مدل سازی تعدادی از مدل های جزئی تشکیل شده را که از دقت و تخمین بالایی نسبت به مدل های دیگر برخوردار هستند انتخاب نموده و مابقی را حذف می کنیم (ابریشمی، مهرآرا، اهراری، محقق، ۲۰۱۰).

در دومین مرحله ترکیب مدل های جزئی انتخاب شده و یا به عبارتی سیستم های ایده آل شکل گرفته در مرحله قبلی مجدداً دو به دو همانند مرحله قبلی ترکیب شده و سیستم های جزئی جدیدی با حداقل پنج و حداکثر شش متغیر ورودی

تشکیل می شود به همین طریق در مراحل بعدی نیز با انتخاب و حذف تعدادی از مدل های جزئی ایجاد شده عمل ترکیب آنها را ادامه می دهیم تا در نهایت به مدلی نسبتا ایده آل دست یابیم.

هدفی که همواره در پروسه ترکیب مدل های به وجود آمده مورد نظر است دست یافتن به مدلی می باشد که تقریبا تمامی متغیرهای سیستم در آن نمایان و نقش داشته باشند و هدف دیگری که در انجام ترکیب های مکرر مورد نظر است رسیدن به مدلی می باشد که میزان خطای خروجی آن نسبت به سایر مدل های محاسبه شده در مراحل قبل کمتر باشد (شارژی، اهراری، فخرایی، ۲۰۰۹).

روش پیشنهادی، شامل استفاده از شبکه عصبی مبتنی بر الگوریتم ژنتیک (GMDH) است. این شبکه ها مبتنی بر شبیه سازی های کامپیوتری از نرون های عصبی هستند و با استفاده از یک پایه ریاضیاتی اعمال خود را انجام می دهند. ایده اصلی این روش عبارتست از طراحی یک مدل بهینه ی پیچیده، که فقط مدل را بر پایه داده ها و اطلاعات طراحی کند و هیچ گونه پیش زمینه نظری از نحوه عملکرد داده ها از سوی محقق انجام نگیرد و این کار تنها بر اساس کشف ارتباط ساده و پیچیده میان داده های ورودی و خروجی سیستم انجام گیرد، بنابراین یک مدل خودتنظیم کننده خواهد ساخت که قابلیت حل مسائلی نظیر تشخیص، پیش بینی و سایر مسائل سیستمی به کار برده شده را دارد. در ادامه، ضمن پیاده سازی روش مذکور، نخست روش های گوناگون بر روی داده ها بکار گرفته خواهد شد و با استفاده از معیارهای ارزیابی، دقت و کارایی هر روش محاسبه و سپس با مقایسه کارکرد روش ها با یکدیگر، توانمندی های هر روش ارزیابی خواهد شد.

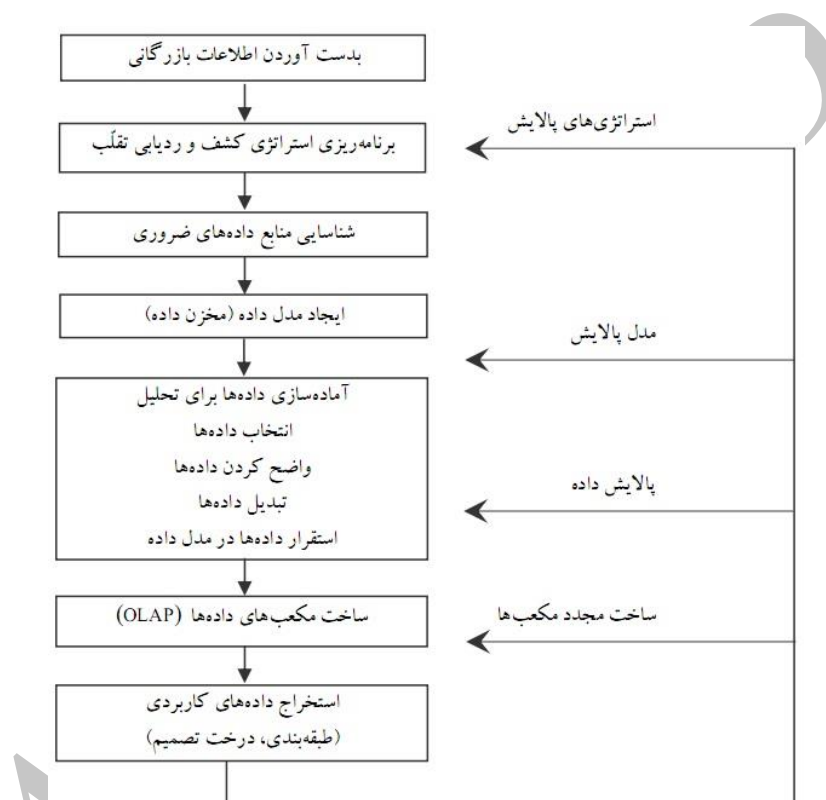
تحلیل و ارزیابی نتایج

در این پژوهش شبکه عصبی مبتنی بر الگوریتم ژنتیک (GMDH) پیشنهاد شد. مزیت روش پیشنهادی نسبت به شبکه های عصبی مصنوعی، کشف ارتباط ساده و پیچیده میان داده های ورودی و خروجی سیستم و به تبع آن سازمان دهی خودکار ساختار شبکه می باشد. در ادامه به جزئیات استفاده از این نوع از شبکه های عصبی به همراه ارزیابی و تحلیل نتایج پرداخته خواهد شد.

یک ساختار هوشمند تشخیص فعالیت ها و تراکنش های مشکوک به تقلب به طور عام از چند لایه متشکل شده است که در سطوح مختلف تحلیل می شوند که اصلی ترین سطح، سطح تراکنش های بانکی می باشد. تحلیل تراکنش یکی از مهمترین و اصلی ترین کارهای یک سیستم مبارزه با تقلب می باشد. تراکنش ها و حساب ها را نمی توان به طور مجزا مورد بررسی قرار داد. بلکه مجموعه تراکنش و حساب بانکی به همراه هم باید یک دید کلی از رفتار مشتریان ارائه کنند. تحلیل ها بر پایه دو ویژگی مهم می باشند؛ فرکانس تراکنش ها و مقدار هر تراکنش. زیرسیستم پیشنهادی از ترکیب این دو ویژگی به صورت یک مجموعه قوانین برای تشخیص موارد مشکوک استفاده می کند.

اغلب روش ها و نرم افزارهای شناسایی تقلب موجود براساس فرکانس و میزان یک نوع تراکنش مشخص و براساس میانگین و انحراف معیار آن عمل می کنند. در واقع چنین سیستم هایی به نوعی، فقط مقایسه یک طرفه را در نظر می گیرند؛ یعنی رفتار یک مشتری خاص در برابر همین مشتری در گذشته. از نظر منطقی این رویکرد برای ردیابی تراکنش های یک مشتری کافی است اما این کار به تنهایی کافی نمی باشد، چراکه فاکتورهای بسیاری وجود دارند که میزان فرکانس تراکنش ها را در بانکداری تحت تاثیر قرار می دهند، مثل محیط سیاسی، اقلیم و نوع بازار سرمایه، ارزش سرمایه و غیره. یکی از راه حل های موجود برای تعیین پارامترهای تاثیرگذار و همچنین میزان تاثیر هر پارامتر در جهت افزایش دقت و کارایی یک سیستم ضد تقلب استفاده از روش های داده کاوی است. در واقع سیستم پیشنهادی به عنوان یک سامانه مبارزه با تقلب مبتنی بر روش های داده کاوی در زمینه تحلیل تراکنش های بانک و بهبود دقت و سرعت کشف موارد مشکوک به تقلب، عملکرد بسیار خوبی را خواهد داشت. در

این سیستم از شبکه عصبی GMDH جهت شناسایی موارد رفتاری و تراکنش های غیرمعمول و مشکوک و اعلان هشدار به سیستم بانکی استفاده می شود. از ویژگی های بارز این سیستم، استفاده از عملیات اکتشاف متوالی جهت تعیین الگوهای توالی داده ها و تراکنش ها و همچنین استفاده از تحلیل داده ها جهت شناسایی تراکنش ها و شبکه جرایم مالی و استخراج داده های محرمانه در اسناد بانک است. اجزای سیستم پیشنهادی به منظور پیاده سازی این وظیفه در شکل ۱ نشان داده شده است.



شکل ۱- اجزای سیستم پیشنهادی جهت پیاده سازی وظیفه کشف تقلب

برای ساختن یک مدل ریاضی، نیاز به داده هایی از هر دو دسته تراکنش های تقلب و غیر تقلب داریم. در این بخش با استفاده از اطلاعات تراکنش های دستگاه POS مربوط به یک بانک که در طی آذرماه سال ۱۳۹۱ تا پایان اردیبهشت ماه ۱۳۹۲ ثبت شده اند و همچنین با به کارگیری روش های ذکر شده در بخش قبل، مدل هایی جهت شناسایی تقلب در تراکنش های مالی ارائه شده است. این داده ها شامل حدود یکصد و نه هزار تراکنش است که پس از انتخاب حدود ده هزار داده از این میان، تعداد ۶۸ تراکنش توسط کارشناسان به عنوان تقلب تشخیص داده شده است.

در هر یک از مدل هایی که در این بخش برای شناسایی تقلب استفاده خواهند شد، تقلب یا غیرتقلب بودن یک تراکنش، به عنوان متغیر وابسته در نظر گرفته می شود. مقدار ۱ برای متغیر وابسته به معنای تقلب بودن تراکنش و مقدار ۰ به معنای غیرتقلب بودن آن تراکنش است. در این مطالعه، از ۳۷ متغیر مستقل ثبت شده، ۹ تای آن برای فرآیند شناسایی تقلب انتخاب

شده است. برای انتخاب متغیرهای مستقل از کارشناسان بانکی در حوزه شناسایی تقلب بهره گرفته شد. در جدول ۱ متغیرهای مستقل مورد استفاده جهت فرآیند شناسایی تقلب آورده شده است.

جدول ۱- متغیرهای انتخاب شده در فرآیند تشخیص تقلب

متغیر مستقل	توصیف متغیر
CARD_NUMBER	شماره کارت مبدأ
PROCESSING_CODE	کد پردازش
TRANSACTION_AMOUNT	مقدار تراکنش
CARD_ACCEPTOR_ACTIVITY	شناسه پذیرنده کارت
TRX_TIME	زمان تراکنش
TRX_DATE	تاریخ تراکنش
CARD_MAGSAD	شماره کارت مقصد
PAZIRANDEH	کد پذیرنده
POS_DATA	اطلاعات پیگیری درگاه

روش رگرسیون لجستیک

زمانی که متغیر وابسته، متغیری کیفی با دو سطح باشد، مدل‌های رگرسیون معمولی قابل استفاده نیستند. در این گونه موارد معمولاً از رگرسیون لجستیک استفاده می‌شود. مدل رگرسیون لجستیک به این صورت تعریف می‌شود:

$$\text{logit}\left(\frac{p}{1-p}\right) = \beta_0 + \beta_1 X_1 + \dots + \beta_d X_d \quad (9)$$

در این مدل X_1, \dots, X_d متغیرهای مستقل و p احتمال مشاهده مقدار ۱ برای متغیر وابسته به شرط مشاهده مقادیر X_1, \dots, X_d است. ضرایب رگرسیونی در این حالت با فرض دوجمله‌ای بودن توزیع متغیر وابسته از روش برآورد حداکثر درست نمایی[^] (MLE) محاسبه می‌شوند. با توجه به اینکه در این تحقیق متغیر وابسته (وضعیت تقلب بودن تراکنش) یک متغیر

[^] Maximum Likelihood Estimation

دوسطحی است، از رگرسیون لجستیک برای تشخیص تقلب یا غیرتقلب بودن تراکنش‌های مالی استفاده شده است. برای این منظور و شبیه‌سازی مدل رگرسیون لجستیک از نرم افزار MATLAB بهره گرفته شد.

پس از انجام شبیه‌سازی و ارائه خروجی، برای به دست آوردن دقت مدل، رابطه ۱۰ محاسبه می‌گردد. در این رابطه منظور از $|a|$ همان قدرمطلق a است و F_i برابر با خروجی واقعی و F'_i برابر با خروجی محاسبه شده توسط مدل است.

$$Accuracy = (\sum_{j=1}^m (1 - (|F_i - F'_{i,j}| / |F_i|))) / m \quad (10)$$

به طوری که m تعداد داده‌های آزمون باشد. مقدار صحت الگوریتم بین ۰ تا ۱ تغییر می‌کند و هرچه بیشتر باشد بیانگر دقت بهتر در انجام عملیات است. با به کارگیری این مدل بر روی داده‌های اولیه، دقت مدل سنجیده شده است. همان‌طور که در جدول ۲ مشاهده می‌شود، دقت مدل در شناسایی تراکنش‌های تقلب، ۸۶،۵۷ درصد و در شناسایی تراکنش‌های غیرتقلب ۸۹،۳۵ بوده است. ضمن اینکه دقت مدل در شناسایی صحیح تقلب یا غیرتقلب هر تراکنش برابر ۸۹،۲۶ درصد است.

جدول ۲- نتایج برآورد دقت تشخیص تقلب مدل رگرسیون لجستیک

		برآورده شده		درصد صحیح
		تقلب	غیر تقلب	
مشاهده شده	تقلب	۵۸	۹	۸۶،۵۷
	غیر تقلب	۲۱۷	۱۸۲۰	۸۹،۳۵
کل				۸۹،۲۶

روش شبکه عصبی پس انتشار خطا

شبکه‌های عصبی مصنوعی و شبکه‌های عصبی پرسپترون چندلایه^۹ (MLP) با الگوریتم آموزشی پس انتشار خطا^{۱۰} (BP) برای حل هر مسئله‌ای، سه مرحله را طی می‌کنند که این مراحل به ترتیب عبارتند از آموزش، تعمیم و اعتبارسنجی (امینیان، محقق، عامری، ۱۹۹۵). الگوریتم یادگیری BP، بر اساس الگوریتم تقریبی بیشترین تنزل^{۱۱} (S.D) است. تنظیم پارامترهای شبکه، مطابق با سیگنال‌های خطا که بر اساس ارائه هر الگو به شبکه محاسبه می‌شود، صورت می‌گیرد.

در نهایت الگوریتم بیشترین تنزل با معادله ۱۱ توصیف می‌شود:

^۹ MultiLayer Perceptron

^{۱۰} Back-Propagation Algorithm

^{۱۱} Steepest Descent

$$S^L j(k) = \frac{\delta F(K)}{\delta n_j^L(K)} = \left[\sum_{m=1}^{S^{L+1}} S_m^{L+1}(k) W_{mj}^{L+1}(k) \right] f^L(N_j^L(k)) \quad (11)$$

به طوری که $S^L j(k)$ ، حساسیت رفتار شبکه در لایه L ام است.

در قدم اول برای آموزش شبکه، مجموعه دادگان آماده شده در بخش قبل را که در قالب فایل اکسل تنظیم شده بود، به عنوان مجموعه آموزشی یا به عبارت دیگر بردارهای ورودی انتخاب کرده و ۹ ستون مربوط به متغیرهای انتخاب شده برای تراکنش‌های مالی را از نرم افزار اکسل به شبکه عصبی اعمال می‌کنیم (در نرم افزار MATLAB). به طور مشابه در مورد مقادیر هدف (تقلب یا غیرتقلب بودن تراکنش‌ها) نیز که به صورت کد ۰ و ۱ در نظر گرفته شده‌اند، کدهای مربوط به همان تراکنش‌ها در قسمت قبل را به عنوان خروجی مطلوب به شبکه وارد می‌کنیم. قدم بعدی، ایجاد ساختار اولیه شبکه و پس از آن آموزش شبکه می‌باشد. با استفاده از بردارهای ورودی و هدف و نیز با تعیین تعداد نرون‌های لایه میانی می‌توان یک شبکه با دولایه به صورت پیش‌فرض ایجاد کرد. سپس شبکه مورد نظر در مرحله آموزش، روابط بین داده‌های ورودی و هدف را با استفاده از الگوریتم‌های آموزشی (BP) یاد می‌گیرد. بدین منظور و در خلال فرایند آموزش، بردارهای ورودی و هدف به طور تصادفی به سه دسته تقسیم می‌شوند. دسته اول که شامل ۶۰ درصد از بردارهای ورودی است، به عنوان مجموعه آموزشی وارد مرحله آموزش می‌شود. دسته دوم که شامل ۲۰ درصد دیگر از بردارها می‌باشد، به منظور اعتبارسنجی انتخاب می‌شوند تا توسط آنها قدرت تعمیم شبکه سنجیده شود. این داده‌ها برخلاف داده‌های آموزشی که در تعیین وزن‌های شبکه مورد استفاده قرار می‌گیرند، در تعیین وزن‌ها نقش مستقیم ندارند. در حقیقت پس از ارائه داده‌های آموزشی به شبکه، داده‌های مربوط به اعتبارسنجی با استفاده از وزن‌های حاصله، وارد شبکه شده و مقادیر خروجی شبکه، مانند قبل در قالب کدهای ۰ و ۱ برای نشان دادن مقادیر غیرتقلب و تقلب محاسبه می‌شوند. مرحله آموزش تا زمانی ادامه می‌یابد که سبب کاهش خطا در بردارهای مربوط به اعتبارسنجی شود. اما در حالتی که خطای مربوطه بیش از حد زیاد شود، شبکه به جایی می‌رسد که قدرت تعمیم خود را از دست می‌دهد. در این حالت شبکه، قابلیت دریافت ارتباط صحیح بین بردارهای ورودی و خروجی را از دست می‌دهد. اما هر زمان که این مشکل رخ دهد، شبکه با تقسیم‌بندی ذکر شده که به صورت خودکار انجام می‌گیرد، آموزش را متوقف می‌کند تا از مشکل فوق‌الذکر جلوگیری شود. ۲۰ درصد بردارهای باقیمانده نیز که تاکنون در شبکه مورد استفاده قرار نگرفته‌اند، برای سنجش نهایی قابلیت تعمیم شبکه استفاده می‌شوند.

پس از اعمال بردارهای ورودی و خروجی مطلوب به شبکه و انجام فرایند آموزش، نوبت به ارزیابی میزان دقت پاسخ‌های شبکه و یا به عبارت دیگر خروجی‌های شبکه می‌رسد. پس از محاسبه دقت الگوریتم نتایج موجود در جدول ۳ حاصل شد.

جدول ۳- نتایج برآورد دقت تشخیص تقلب مدل شبکه عصبی BP

		برآورده شده		درصد صحیح
		تقلب	غیر تقلب	
داده‌های تقلب	تقلب	۶۹	۱۱	۸۶،۲۵
	غیر تقلب	۱۸۸	۱۸۳۶	۹۰،۷۱
کل				۹۰،۵۴

همان طور که در جدول ۳ مشاهده می شود، دقت مدل در شناسایی تراکنش های تقلب، ۸۶،۲۵ درصد و در شناسایی تراکنش های غیر تقلب ۹۰،۷۱ بوده است. ضمن اینکه دقت مدل در شناسایی صحیح تقلب یا غیر تقلب هر تراکنش برابر ۹۰،۵۴ درصد است.

روش شبکه عصبی مبتنی بر الگوریتم GMDH

موضوع طراحی شبکه عصبی GMDH با مسائل عنوان شده در بخش قبل متمایز است. در این نوع از طراحی، هدف، جلوگیری از رشد واگرایی شبکه و نیز مرتبط کردن شکل و ساختار شبکه به یک یا چند پارامتر عددی است، به گونه ای که با تغییر این پارامترها، ساختار شبکه ها نیز تغییر کند. روش های تکاملی مانند الگوریتم ژنتیک، کاربرد وسیعی در مراحل مختلف طراحی شبکه های عصبی به دلیل قابلیت های منحصر به فرد خود در پیدا کردن مقادیر بهینه و امکان جستجو در فضاهای غیر قابل پیش بینی، دارند (نریمان زاره، ۸۰-۸۷). در تحقیق حاضر، برای طراحی شکل شبکه عصبی و تعیین ضرایب آن، از الگوریتم ژنتیک استفاده شده است. به منظور تدوین الگو و تشخیص تقلب تراکنش های مالی در این مدل، از نرم افزار GEvoM^{۱۱} استفاده می شود (برای توسعه این نرم افزار Net Framework. بکار رفته است). آدرس وب گاه برنامه نصب کننده نرم افزار از آدرس زیر، قابل دانلود است:

<http://research.guilan.ac.ir/gevom/docs/GEvoM%20-%20Demo.exe>

نرم افزار محاسباتی مبتنی بر بهینه سازی چند منظوره (آتش کاری، نریمان زاده، ۲۰۰۷)، با هدف کمینه کردن خطای الگوسازی و تشخیص، طراحی شده که با استفاده از نمودار پرتو (امانی فرد، نریمان زاده، برجی، خلخالی، حبیب دوست، ۲۰۰۸) دقت تشخیص و پایداری فرآیند را افزایش می دهد. منظور از خطای الگوسازی، خطایی است که به واسطه اختلاف مقادیر برآورد شده با مقادیر واقعی در دوره آموزش شبکه حاصل شده است و منظور از خطای تشخیص، میزان خطایی است که به واسطه اختلاف مقادیر برآورد شده و مقادیر واقعی در مشاهدات دوره پیش بینی محاسبه شده است.

این نرم افزار مبتنی بر شبکه های عصبی مبتنی بر الگوریتم GMDH بوده و امکان ایجاد شبکه های عصبی چند جمله ای را فراهم می کند. این نرم افزار امکان مدل سازی داده های آزمایشی و شبیه سازی را داراست. در این سیستم از ژنتیک و تکنیک SVD برای بهینه سازی پیکربندی شبکه و ضرایب چند جمله ای حاصله استفاده می شود. این نرم افزار از چهار متد مختلف ^{۱۲}JSP، ^{۱۳}PSD، ^{۱۴}ED و روش تکاملی برای طراحی شبکه های عصبی مبتنی بر GMDH استفاده می کند. روش تکاملی از الگوریتم ژنتیک برای پیکربندی بهینه اتصالات ساختاری شبکه عصبی GMDH استفاده می کند. در کلیه روش های فوق از ^{۱۵}SVD و یا ^{۱۶}SNE برای به دست آوردن ضرایب چند جمله ای استفاده می شود.

^{۱۱} GMDH-type Neural Network Design by Evolutionary Method for Modeling

^{۱۲} Increasing Selection Pressure Method

^{۱۳} Pre-specified-Design Method

^{۱۴} Error-Driven Method

^{۱۵} Singular Value Decomposition

^{۱۶} Solving Normal Equations

برای کار با این ابزار می‌بایست داده‌های ورودی در قالب یک فایل CSV^{18} - که اعداد در هر سطر با یک فضای خالی از هم جدا شده باشند - به نرم‌افزار داده شود. لازم به ذکر است که اگر داده‌ها با کاما ویا سایر کاراکترها از هم جدا شده باشند نرم‌افزار آن‌ها را بارگذاری نخواهد کرد. امکان بازبینی و ویرایش داده‌ها با استفاده از DataView نیز وجود دارد. داده‌ها باید دارای تعداد ستون‌های مساوی در هر یک از سطرها باشند و اولین ستون به صورت یک عدد ترتیبی است که از ۱ شروع شده و در سطرها بعدی یکی افزایش می‌یابد تا نشان دهنده شماره سطر باشد. بنابراین اگر داده‌های ورودی دارای n ستون باشند، ستون اول بیانگر شماره سطر خواهد بود، ستون ۲ تا $n-1$ بعنوان متغیرهای ورودی بوده و دارای نام‌های مشخص هستند و در هر سطر مقدار مشخصی را می‌پذیرند. ستون آخر داده‌ها، حاوی مقدار خروجی است بنابراین قالب داده‌ها مطابق شکل ۲ خواهد بود.

شماره سطر	داده‌های ورودی			مقدار خروجی
ستون ۱	ستون ۲		ستون $n-1$	ستون n

شکل ۲- قالب داده‌های ورودی

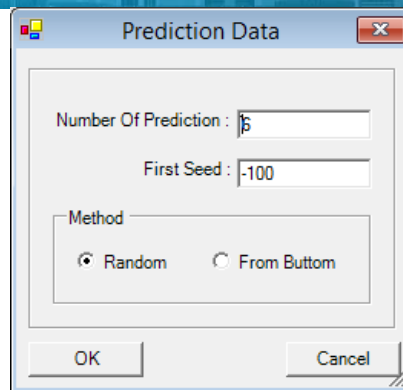
شکل ۳، نحوه ویرایش داده‌ها با قالب فوق بعد از ورود به سیستم را نشان می‌دهد.

Num	a1	b1	c1	F
1	18.8	0.036	30	1.75
2	18.8	0.036	12	1.12
3	18.3	0.08	64	1.56
4	15.5	0.036	12	1.35
5	15.5	0.036	6	0.96
6	16.3	0.08	72	1.953
8	8.88	0.036	2	0.81
10	7.77	0.08	8	0.92
11	16.1	0.036	24	1.49
12	16.1	0.036	12	1
13	18.3	0.08	36	1.25
15	15.8	0.064	72	1.57
16	15.8	0.064	60	1.45
17	15	0.048	48	1.71
18	15	0.048	12	0.78
19	13	0.036	36	1.63

شکل ۳- صفحه ویرایشگر داده‌های ورودی

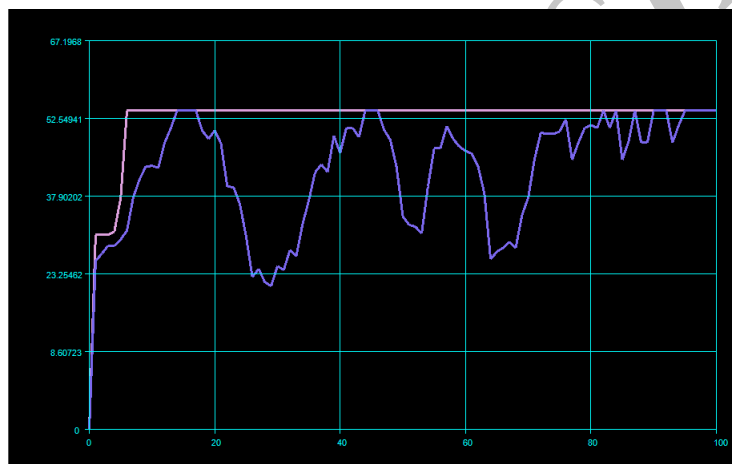
تنظیمات مربوط به پیش‌بینی براساس داده‌های ورودی، مطابق شکل ۴، وارد می‌شود.

¹⁸ Comma Separated Values




شکل ۴- نحوه مقداردهی پارامترهای پیش بینی

پس از مقداردهی پارامترهای مربوط به پیش بینی، نحوه پیشرفت اجرای سیستم توسط شکل ۵ نمایش داده می شود.



شکل ۵- نحوه پیشرفت اجرای سیستم

نمودار شکل ۶، امکان مقایسه دقیق بین داده های ورودی و مقادیر محاسبه شده توسط الگوریتم GMDH را نشان می دهد. محور افقی در این نمودار نمایش دهنده شماره سطر داده ورودی و محور عمودی نمایش دهنده مقدار خروجی شبکه عصبی GMDH است. همان طور که در این شکل مشخص است مقادیر واقعی با مقادیر محاسبه شده توسط سیستم، نظیر به نظیر در مجاور هم هستند و با دارا بودن دو رنگ متفاوت، امکان مقایسه دقیق و به دست آوردن دقت جواب حاصله توسط شبکه عصبی GMDH مقدور است.



شکل ۶- مقایسه مقادیر مطلوب داده‌های ورودی و مقادیر به دست آمده از مدل GMDH

پس از محاسبه دقت الگوریتم (با توجه به رابطه ۱۰) نتایج موجود در جدول ۴ حاصل شد.

جدول ۴- نتایج برآورد دقت تشخیص تقلب مدل شبکه عصبی GMDH

		برآورده شده		درصد صحیح
		تقلب	غیر تقلب	
مشاهده شده	تقلب	۶۷	۹	۸۸,۱۶
	غیر تقلب	۱۶۵	۱۸۶۳	۹۱,۸۶
کل				۹۱,۷۳

همان‌طور که در جدول ۴ مشاهده می‌شود، دقت مدل در شناسایی تراکنش‌های تقلب، ۸۸,۱۶ درصد و در شناسایی تراکنش‌های غیرتقلب ۹۱,۸۶ بوده است. ضمن اینکه دقت مدل در شناسایی صحیح تقلب یا غیرتقلب هر تراکنش برابر ۹۱,۷۳ درصد است.

با توجه به معیارهای به‌دست آمده، دقت تشخیص مدل شبکه عصبی مصنوعی مبتنی بر الگوریتم ژنتیک (GMDH) از بیشترین معیار صحت برخوردار بوده و بنابراین می‌توان آن را به عنوان بهترین مدل جهت تشخیص تقلب تراکنش‌های مالی (در بین مدل‌های بکار برده شده در این پژوهش) معرفی نمود.

در این پژوهش روش داده‌کاوی رگرسیون لجستیک، شبکه عصبی BP و شبکه عصبی GMDH برای ساخت مدل‌هایی جهت شناسایی تقلب در تراکنش‌های مالی معرفی شدند. در ادامه، این روش‌ها بر روی داده‌های واقعی آزمایش و کارایی هر روش سنجیده شد. روش شبکه عصبی GMDH با دقت ۹۱,۷۳ درصد در شناسایی تقلب یا غیرتقلب بودن تراکنش‌های مالی بهترین کارایی را در مقایسه با دو روش رگرسیون لجستیک با دقت کلی ۸۹,۲۶ و شبکه عصبی BP با دقت کلی ۹۰,۵۴

داشت. البته باید به این نکته توجه داشت که در هر سه مدل معرفی شده برای تشخیص تقلب تراکنش‌های مالی، تعداد ۹ متغیر که از دید کارشناسان حوزه بانکی انتخاب گردید، استفاده شد. لذا همان‌طور که پیش از این نیز گفته شد، در این تحقیق متغیرهای دیگری نیز وجود دارند که به شرط ثبت اطلاعات آن‌ها در تراکنش‌های پیشین، می‌توانند با ورود به مدل به تشخیص بهتر تقلب در تراکنش‌های مالی کمک کنند.

نتیجه گیری

از جمله الگوریتم‌های داده کاوی مورد استفاده برای کشف تقلب می‌توان به شبکه‌های عصبی، خوشه بندی، درخت‌های تصمیم‌گیری، گراف تحلیل روابط، تحلیل آماری، تجمیع موارد مشکوک و موتور استنتاج اشاره نمود. همان‌طور که گفته شد، یکی از روش‌هایی امیدوارکننده در مسأله تشخیص تقلب، روش شبکه عصبی مصنوعی است که در برخی از موارد توانایی بالقوه‌ی خوبی جهت تشخیص تقلب‌های مالی از خود نشان داده‌اند. اما نکته اساسی این است که، در مدل‌های شبکه عصبی مصنوعی، پیش‌داوری محقق در مورد ساختار مدل با توجه به فروض اولیه، به شبکه تحمیل می‌شود. حال آنکه در این بین مدل‌های شبکه عصبی مبتنی بر الگوریتم GMDH، نوعی شبکه‌ی خودسامانده و یک‌سویه بوده و دیگر نیازی به تحمیل شرایط اولیه توسط محقق ندارد، که استفاده از این نوع شبکه عصبی به دلیل بیان شده به عنوان روش پیشنهادی در این پژوهش مطرح گردید. نتایج حاصل از این پژوهش نشان داد که مدل شبکه‌ی عصبی مصنوعی مبتنی بر الگوریتم GMDH، عملکرد قابل توجهی در شناسایی تقلب داشته و قادر به ارائه تشخیص‌های دقیق‌تری نسبت به مدل‌های پایه خود (مدل‌های به‌کار گرفته شده در این پژوهش) می‌باشد.

مراجع

- Mahmoudi, M. T., Forouzideh, N., Lucas, C., and Taghiyareh, F. (۲۰۰۹). "Artificial Neural Network Weight Optimization based on Imperialist Competitive Algorithm," Seventh International Conference on Computer Science and Information Technologies, Yerevan, Armenia, ۲۸ September-۲ October.
- Sumanjeet, S. (۲۰۰۹). "Emergence of Payment Systems in the age of Electronic Commerce: the state of art," Global Journal of International Business Research, Vol. ۲, No. ۲, PP. ۱۷-۲۶.
- Morgan, J. P. (March ۲۰۱۱). "Payment Fraud and Control Survey,".
- Stands, K. (۲۰۱۰). On Knowledge Discovery-Data Mining Community Accessed from www.Kdnuggets.com.
- Yamanishi, et al, K. (۲۰۱۱). "Online Unsupervised Outlier Detection Using Finite Mixtures with Discounting.
- Shu-Heng, C. (۲۰۰۶). "Genetic Algorithm and Genetic Programming in Computational Finance", Springer Kluwer Academic Publications, New York; USA: ۹۰-۱۰۲.
- Mehrara, M., Behzadmehr, N., Ahrari, M., Mohaghegh, M., (۲۰۱۱). Prediction of Volatility of Crude Oil Prices Using GMDH Neural Network, Quarterly Energy Economics Review, Vol. ۱(۲۵), pp. ۸۹-۱۱۲.
- Jamali, A., Nariman-zadeh, N., Atashkari, K., (۲۰۰۶). "Inverse Modeling of Multi-Objective Thermodynamically Optimized and GAI" ۱۴th Annual (International) Mechanical Engineering Conference, Isfahan University of Technology, Isfahan, Iran.
- Zamani, N., (۲۰۱۰), "Analysis and Forecast Crude Oil Sales Revenues Using Neural Networks and Their Comparison", MSc Thesis, University of Tehran.
- Ivakhnenko, G.A (۱۹۹۵), "The Review of Problems Solvable by Algorithms of the Method of Data Handling (GMDH)", Pattern Recognition and Image Analysis, Vol. ۵, No. ۴, PP ۵۲۷-۵۳۵.
- Abrishami, H., Mehrara, M., Ahrari, M., Mirghasemi, S., (۲۰۱۰). "Modeling and Forecasting Economic Growth of Iran GMDH Neural Network Approach", Journal of Economic Research, Vol. ۱(۸۸), PP. ۱-۲۴.
- Sharzehi, G., Ahrari, M., Fakhraie, H., (۲۰۰۹). "Projection of Water Demand In Tehran Using Structural Patterns", Time Series and the GMDH-type Neural Network, Journal of Economic Research, Vol. ۱(۸۴), pp. ۱۵۱-۱۷۵.
- White A.C., Molnar D., Aminian K., Mohaghegh S., Ameri S. & Esposito P., (۱۹۹۵). "The application of ANN for zone identification in a complex reservoir", SPE Paper ۳۰۹۷۷, SPE Eastern Regional Conference & Exhibition, Morgantown, West Virginia, USA.
- Demuth H., Beal M. & Hagan M., (۱۹۹۲-۲۰۰۹). "Neural network toolbox ۶" (Users Guide), The MathWorksTM.
- Nariman-zadeh, N.; Darvizeh, A.; Darvizeh, M.; Gharababaei, H., (۲۰۰۲), "Modelling of Explosive Cutting Process of Plates Using GMDH-type Neural Network and Singular Value Decomposition". Journal of Materials Processing Technology, ۱۲۸ (۱-۳): ۸۰-۸۷.
- Atashkari, K. Nariman-Zadeh, N. Gölcü, M. Khalkhali, A., Jamali, A. (۲۰۰۷) "Modelling and Multi-objective Optimization of a Variable Valve-timing Spark-ignition Engine Using Polynomial Neural Networks and Evolutionary Algorithms", Energy Conversion and Management, ۴۸ (۳): ۱۰۲۹-۱۰۴۱.

Amanifard, N., Nariman-Zadeh, N., Borji, M., Khalkhali, A., Habibdoust, A. (۲۰۰۸). "Modelling and Pareto Optimization of Heat Transfer and Flow Coefficients in Microchannels Using GMDH type Neural Networks and Genetic Algorithms", Energy Conversion and Management, ۴۹(۲): ۳۱۱ – ۳۲۵.

Archive of SID