

انتخاب متغیر در شبکه‌های عصبی پرسپترون چندلایه به منظور پیش‌بینی با استفاده از نگاشت‌های خودسازمان‌ده (SOM)

مهری خاشعی^{*}، مهدی بیجاری و فریماه مخاطب رفیعی

دانشکده مهندسی صنایع، دانشگاه صنعتی اصفهان

(دریافت مقاله: ۱۳۹۲/۰۹/۱۳ - دریافت نسخه نهایی: ۱۳۹۲/۱۲/۲۶)

چکیده - شبکه‌های عصبی پرسپترون چندلایه از مهم‌ترین و پرکاربردترین شبکه‌های عصبی در پیش‌بینی بازارهای مالی هستند. اما این گونه از شبکه‌ها، علی‌رغم تمام مزایای منحصر به فردشان، دارای محدودیت‌هایی نیز می‌باشند که از جمله مهم‌ترین آنها می‌توان به محدودیت تعداد متغیرهای ورودی به شبکه اشاره نمود. در شبکه‌های پرسپترون چندلایه برخلاف روش‌های سنتی پیش‌بینی، با افزایش تعداد ورودی‌ها ممکن است عملکرد شبکه کاهش یابد. در ادبیات موضوع، ترکیب مدل‌های مختلف و یا استفاده از مدل‌های ترکیبی یک راه معمول بهمنظور برطرف ساختن محدودیت‌های مدل‌های تکی و بیبود دقت پیش‌بینی‌ها است. در این مقاله با استفاده از نگاشت‌های خودسازمان‌ده که از دقیق‌ترین روش‌های حال حاضر در شناخت و تحلیل فضاهای چندبعدی غیرخطی هستند، یک روش ترکیبی از شبکه‌های پرسپترون چندلایه ارائه گردیده است. در روش پیشنهادی، ورودی‌های شبکه در ابتدا با استفاده از نگاشت‌های خودسازمان‌ده خوشه‌بندی شده و سپس متغیرهای موجود در هر خوشه با توجه به میزان تأثیرگذاری‌شان با یکدیگر ترکیب می‌گردند. نتایج حاصله از به کارگیری روش پیشنهادی در پیش‌بینی قیمت محصولات فولادی در بورس فلزات تهران بیانگر کارآمدی روش ترکیبی در تقابل با سایر روش‌ها است.

واژگان کلیدی: شبکه‌های عصبی پرسپترون چندلایه (MLP)، نگاشت‌های خودسازمان‌ده (SOM)، انتخاب متغیر، پیش‌بینی قیمت محصولات، بازارهای مالی.

Feature Selection in Multi-Layer Perceptrons (MLP) for Forecasting Using Self Organization Maps (SOM)

M. Khashei, M. Bijari and F. Mokhatab Rafiei

Industrial Engineering Department, Isfahan University of Technology

Abstract: Nowadays multilayer perceptrons (MLPs) are one of the most important and widely-used neural networks used as continuous measurable function with a desired accuracy. The second benefit is nonparametric data-driven nature of them which means multilayer perceptrons impose few prior assumptions on the underlying process. Being adaptive is the third advantage of

*: مسئول مکاتبات، پست الکترونیکی: Khashei@in.iut.ac.ir

MLPs. The adaptation of MLPs implies that in a nonstationary environment the accuracy and robustness of results are still countable. Utilizing fewer parameters is the fourth benefit of MLPs. Despite all these unique advantages of multilayer perceptrons, they suffer from some limitations such as negative relationship between number of inputs and the achieved performance, though using hybrid methods to overcome the limitations by means of a method alone and improving forecasting performance is achievable. Literature review suggests that by utilizing disparate and unrelated methods, we can obtain a new hybrid scheme capable of less variance or error. Hybridization of dissimilar methods can reduce the risk of using an inappropriate method. Usually, this is done based on this fact that the underlying process cannot easily be determined. The motivation behind using hybrid method is two folds: either single method cannot identify the true data generating process or cannot identify all the characteristics of the time series. In this paper, a new hybrid method of multilayer perceptrons is proposed which uses the self-organizational maps. The self-organizational maps are one of the most accurate tools in recognizing and analyzing the nonlinear multidimensional spaces. In the proposed method, inputs of the multilayer perceptron are firstly clustered by using a self-organizational map, and then variables in each cluster are combined together according to their effectiveness values. Empirical results of steel price forecasting in Tehran Metal Exchange indicate that the efficiency of the proposed method is comparable to other methods.

Keywords: Multi-Layer Perceptrons (MLPs), Self Organization Maps (SOMs), feature selection, price forecasting, financial markets.

۱- مقدمه

جامع برای پیش‌بینی نبوده و قابلیت به کارگیری در هر شرایط و هر نوع داده را ندارد. لذا با ترکیب مدل‌های مختلف می‌توان نقاط ضعف یک مدل را با استفاده از نقاط قوت مدل دیگر بهبود بخشد. یافته‌های تجربی و تئوریک نیز نشان می‌دهند که ترکیب مدل‌های متفاوت یک راه مؤثر و کارآ برای بهبود دقت پیش‌بینی‌ها است [۴].

در تحقیقات مربوط به پیش‌بینی با شبکه‌های عصبی مصنوعی نیز مدل‌های ترکیبی متعددی به منظور مرتفع ساختن محدودیت‌های موجود در این گونه از مدل‌ها و حصول نتایج دقیق‌تر ارائه شده است. خاشعی و بیخاری [۵] یک روش ترکیبی از شبکه‌های عصبی و روش میانگین متحرک خودرگرسیون ابیاشته (ARIMA) به منظور برطرف ساختن محدودیت خطی شبکه‌های عصبی در پیش‌بینی ارائه نموده‌اند. چن و وانگ [۶] یک روش ترکیبی از شبکه‌های عصبی بردارهای پشتیبان (SVM) با اریمای فصلی (SAIRMA) به منظور حل مشکل مدل‌سازی الگوهای فصلی در شبکه‌های عصبی ارائه داده‌اند. خاشعی و همکاران [۷] روشی ترکیبی با استفاده از مدل‌های رگرسیون فازی با شبکه‌های عصبی مصنوعی به منظور غلبه بر محدودیت تعداد داده‌های مورد نیاز شبکه‌های عصبی جهت پیش‌بینی در شرایط داده‌های قابل حصول کم پیشنهاد نموده‌اند. آرمانو و همکاران [۸] نیز یک

در سال‌های اخیر، شبکه‌های عصبی پرسپترون چندلایه به طور گسترده‌ای مورد مطالعه قرار گرفته و در پیش‌بینی بازارهای مالی به کارگرفته شده‌اند. مزیت اصلی شبکه‌های عصبی قابلیت مدل‌سازی غیرخطی انعطاف‌پذیرشان است. در شبکه‌های عصبی مصنوعی دیگر نیازی به تشخیص شکل خاص مدل نبوده و مدل تنها براساس اطلاعات موجود در داده‌ها شکل می‌گیرد. این رویکرد مبتنی بر داده برای بسیاری از مجموعه داده‌های تجربی به خصوص زمانی که هیچ اطلاعات تئوریکی برای پیشنهاد یک فرآیند تولید داده مناسب در دسترس نباشد، بسیار مناسب است [۱]. علی‌رغم تمام مزیت‌هایی که برای شبکه‌های پرسپترون چندلایه بیان شد، این گونه از شبکه‌ها معایبی نیز دارند که از جمله می‌توان به محدودیت تعداد متغیرهای ورودی به شبکه اشاره نمود.

استفاده از مدل‌های ترکیبی یا ترکیب مدل‌های مختلف یک راه معمول در بهبود دقت پیش‌بینی‌ها و غلبه بر محدودیت‌های مدل‌های تکی است. ادبیات موضوع مربوط به مدل‌های ترکیبی بسیار گسترده بوده و مطالعات فراوانی از زمان اولین تحقیقات انجام شده در این زمینه توسط رید [۲] و بیتس و گرانجر [۳] تاکنون صورت گرفته است. ایده اساسی در ترکیب مدل‌ها بر این اصل استوار است که هیچ‌یک از روش‌های موجود، یک روش

جدول ۱ - لیست اقدامات انجام شده در ادبیات موضوع روش های ترکیبی با نگاشت های خودسازمان ده

نوع اسناد (گان)	سال انتشار	روش های استفاده شده	زمینه کاربرد	شماره مرجع
فام و همکاران	۲۰۱۴	روش های ارزیابی کانسی و نگاشت های خودسازمان ده	سرمایه گذاری در بازار سهام	[۱۶]
یو و لی	۲۰۱۳	روش های تحلیل سلسه مراتبی، تحلیل پوششی داده ها و نگاشت های خودسازمان ده	مدیریت و انتخاب تکنولوژی	[۱۷]
جیانگ و لی	۲۰۱۳	روش های بهینه سازی ازدحام ذرات و نگاشت های خودسازمان ده	سیستم های امنیتی	[۱۸]
تاسدیمیر و همکاران	۲۰۱۲	روش های تحلیل مبتنی بر هدف و نگاشت های خودسازمان ده	مدیریت منابع کشاورزی	[۱۹]
کارابولوت و ابریکی	۲۰۱۲	منطق فازی و نگاشت های خودسازمان ده	تشخیص الگو در زیست شناسی	[۲۰]
روستوم و ادلوي	۲۰۱۲	شبکه های عصبی چند لایه پیشخور و نگاشت های خودسازمان ده	مدیریت منابع آبی	[۲۱]
میشرا و بھارا	۲۰۱۲	روش های اصلاح شده خوش بندی k- میانه و نگاشت های خودسازمان ده	طبقه بندی داده های محک	[۲۲]
یاداف و سرینیواسان	۲۰۱۱	شبکه های عصبی مصنوعی و نگاشت های خودسازمان ده	پیش بینی کوتاه مدت الکترونیک	[۲۳]
ایسمایل و همکاران	۲۰۱۱	ماشین های بردار پشتیبان حداقل مربعات و نگاشت های خودسازمان ده	پیش بینی سری های زمانی	[۲۴]
لی و هانگ	۲۰۰۹	ماشین های بردار پشتیبان و نگاشت های خودسازمان ده	مدیریت ساخت و تولید	[۲۵]

عمومی (GRNNs)، مقاله وانگ و یان [۱۱] در ترکیب نگاشت های خودسازمان ده با شبکه های عصبی المان (ELMAN)، مقاله کارپین تریبو [۱۲] در ترکیب نگاشت های خودسازمان ده با شبکه های عصبی پرسپترون چند لایه (MLP) و غیره اشاره نمود [۱۳-۱۵]. لیست مختصری از این اقدامات در جدول (۱) خلاصه سازی شده اند.

در این مقاله، به منظور غلبه بر محدودیت تعداد متغیر های ورودی شبکه های عصبی و همچنین بهبود دقیق پیش بینی ها در محیط های مالی، از نگاشت های خودسازمان ده که از دقیق ترین روش های حال حاضر در شناخت و تحلیل فضاهای چنان بعدی غیر خطی هستند، به منظور پیشنهاد یک روش ترکیبی استفاده شده است. در روش پیشنهادی، ورودی های شبکه در ابتدا با


روش ترکیبی از شبکه های عصبی با الگوریتم ژنتیک (GA) به منظور بهبود مشکل طراحی شبکه های عصبی و کاهش خطای پیش بینی ها ارائه نموده اند.

نگاشت های خودسازمان ده (SOM) نیز از جمله روش هایی هستند که به منظور حل مشکلات موجود در شبکه های عصبی در پیش بینی به کار گرفته شده اند. هانگ و تسای [۹] یک روش ترکیبی از شبکه های عصبی بردار های پشتیبان با نگاشت های خودسازمان ده به منظور کاهش مشکل هزینه های یادگیری در شبکه های عصبی جهت پیش بینی های مالی ارائه نموده اند. از سایر روش های ترکیبی موجود در ادبیات موضوع پیش بینی های مالی، می توان به مقاله لی و همکاران [۱۰] در ترکیب نگاشت های خودسازمان ده با شبکه های عصبی رگرسیون

از شبکه‌ها تبدیل یک فضای ورودی با بعد دلخواه به یک فضای با بعد کمتر و غالباً یک نگاشت دو بعدی گستته می‌باشد. بهمین دلیل است که این گونه از شبکه‌ها را به عنوان یک ابزار کاهش‌دهنده بعد محاسبه می‌نمایند. هدف نهایی از استفاده از نگاشت‌های خودسازمانده نیز حصول همین مدل ساده از داده‌های اولیه به منظور کاهش محاسبات و پیچیدگی‌های موجود در زمینه تجزیه و تحلیل داده‌ها است. نگاشت‌های خودسازمانده کاربردهای فراوانی در زمینه‌های مختلف علوم داشته که مهم‌ترین آنها استخراج داده‌ها و تحلیل فضاهای پیچیده می‌باشد [۲۶]. از سایر کاربردهای این گونه از شبکه‌ها می‌توان به خوشبندی [۲۷]، تشخیص الگو [۲۸]، آنالیز تصاویر و اصوات [۲۹] و تشخیص خط [۳۰] اشاره نمود.

۱-۲- توپولوژی نگاشت‌های خودسازمانده
 نگاشت‌های خودسازمانده در حالت کلی دارای یک ساختار دو لایه با یک لایه ورودی و یک لایه خروجی هستند. نرون‌های لایه ورودی وظیفه انتقال داده‌ها به شبکه را بر عهده داشته و در حالت کلی تعداد آنها با بعد بردارها در فضای ورودی برابر است. لایه خروجی نیز شامل مجموعه‌ای از نرون‌ها است که معمولاً در یک صفحه مسطح کنار یکدیگر چیده شده‌اند. این نرون‌های لایه خروجی با توجه به روابط همسایگی مشخصی که فی‌مابين آنها تعریف شده و رفتار متقابل روی همدیگر، خروجی شبکه را ایجاد می‌کنند [۳۱]. تعداد نرون‌های موجود در لایه خروجی به مسئله مورد مطالعه وابسته بوده و توسط کاربر مشخص می‌گردد. ساختار یک نگاشت خودسازمانده (5×5) در شکل (۱) نمایش داده شده است.

نرون‌های ورودی به وسیله وزن‌های اتصالی به تمام نرون‌های لایه خروجی متصل می‌باشند. هر یک از واحدهای خروجی که بردارهای مرجع نیز نامیده می‌شوند، توسط مختصات آنها در صفحه خروجی وزن‌دهی می‌گردد؛




شکل ۱- ساختار یک نگاشت خودسازمانده (5×5)

استفاده از نگاشت‌های خودسازمانده خوشبندی می‌گردد. ایده این کار بر این اصل استوار است که در ادبیات موضوع پیش‌بینی با شبکه‌های عصبی مصنوعی، اکیداً توصیه شده است که متغیرهای ورودی به شبکه نباید با یکدیگر وابستگی خطی و غیرخطی داشته باشند. لذا با خوشبندی متغیرهای ورودی با استفاده از نگاشت‌های خودسازمانده می‌توان وابستگی فی‌ماین خوشبندی ورودی را به حداقل رسانید. در مرحله دوم از روش پیشنهادی نیز متغیرهای موجود در هر خوشبندی با توجه به میزان تأثیرگذاری شان با یکدیگر ترکیب می‌گردد تا مقدار مرتبط با هر خوشبندی تعیین گردد.

محتوای سایر قسمت‌های این مقاله بدین صورت است: در بخش‌های دوم و سوم، به ترتیب مفاهیم پایه‌ای شبکه‌های عصبی چندلایه پیشخور و نگاشت‌های خودسازمانده به اختصار شرح داده شده‌اند. در بخش چهارم روش ترکیبی پیشنهادی به منظور پیش‌بینی شرح داده شده است. در بخش پنجم قیمت محصولات فولادی شرکت سهامی ذوب آهن اصفهان در بورس فلزات تهران با استفاده از روش پیشنهادی، پیش‌بینی و نتایج حاصله با سایر روش‌ها مقایسه شده است، درنهایت نیز نتیجه‌گیری آورده شده است.

۲- نگاشت‌های خودسازمانده (SOM)

نگاشت‌های خودسازمانده کلاس خاصی از شبکه‌های عصبی مصنوعی هستند که غالباً به منظور تحلیل فضاهای پیچیده داده‌ها مورد استفاده قرار می‌گیرند. اساس عملکرد این گونه



شکل ۲ - انتخاب نرون برنده از میان الگوهای مرجع

$X = (x_1, x_2, \dots, x_d)$ به شبکه اعمال می‌گردد.

۲- تعیین نرون برنده، در این مرحله براساس معیار تشابه شبکه، نرون برنده مشخص می‌گردد. معیارهای تشابه مختلفی را می‌توان در نگاشتهای خودسازمانده به کار گرفت، اما معمول ترین معیاری که در این گونه از شبکه‌ها به کار گرفته می‌شود، فاصله اقلیدسی است. رابطه معیار تشابه اقلیدسی مطابق رابطه زیر می‌باشد:

$$\|X - W\| = \left(\sum_{i=1}^d (X_i - w_i)^2 \right)^{1/2} \quad (1)$$

حال به صورت همزمان ورودی $X = (x_1, x_2, \dots, x_d)$ با تمام عناصر موجود در شبکه مقایسه می‌گردد. نرون برنده، نرونی با فاصله کمینه در میان تمامی الگوهای مرجع از داده ورودی است:

$$\|X - m_c\| = \min \{\|X - m_r\|\} \quad (2)$$

به قسمی که m_c نرون برنده و m_r بردارهای مرجع می‌باشند. نمونه‌ای از انتخاب نرون برنده از میان الگوهای مرجع در شکل (۲) آورده شده است.

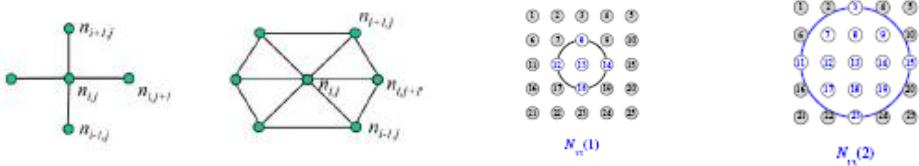
۳- تعیین نرون‌های همسایه، بعد از مشخص شدن نرون برنده مجموعه‌ای از نرون‌های همسایه نرون برنده که می‌بایست مقادیرشان تغییر نمایند، مشخص می‌شوند. برخی از همسایگی‌های مختلف در شکل (۳) آورده شده است. تغییر مقادیر مربوط به نرون‌های همسایه در حالت کلی به دو صورت انجام می‌پذیرد [۳۲]. در حالت اول یک شاعع همسایگی معین در اطراف سلول برنده انتخاب می‌گردد. در این روش تمام نرون‌هایی از شبکه که در فاصله معین از نرون برنده می‌باشند با یک ضریب ثابت به سمت ورودی حرکت می‌کنند. در

سپس با ارائه الگوهای آموزشی به شبکه، وزن نرون‌ها که مبین مختصات آنها در صفحه خروجی می‌باشد، طبق الگوریتم آموزشی که در قسمت‌های بعدی توضیح داده خواهد شد، تغییر خواهد کرد. اساس تغییر در اوزان جستجوی نرونی با بیشترین شباهت به الگوی ورودی (نرون برنده) و حرکت نرون مذکور و جمعی از همسایگانش به سوی الگوی ورودی است. نتیجه نهایی تغییر اوزان فشرده‌سازی اطلاعات و تعیین فضای مورد نظر می‌باشد.

۲-۲- الگوریتم یادگیری نگاشتهای خودسازمانده

الگوریتم آموزش نگاشتهای خودسازمانده از نوع بدون ناظر است. اساساً الگوریتم یادگیری بدون ناظر را می‌توان به وسیله معادلات مرتبه اول مشخص نمود. این معادلات توصیف می‌کنند که چگونه وزن‌های شبکه نسبت به زمان یا تکرار حالت گستته سازگار می‌شوند. به منظور سازگاری اوزان اغلب از یک مقیاس شباهت یا اشتراک الگو برای هدایت فرآیند یادگیری که عموماً مارا به سوی برخی از شکل‌های همبستگی، خوش‌سازی و یا رفتارهای رقابتی شبکه سوق می‌دهد، استفاده می‌گردد. الگوریتم یادگیری نگاشتهای خودسازمانده در حالت کلی مبتنی بر انتخاب نرون برنده و حرکت نرون مذکور و برخی از همسایگانش، به سوی داده ورودی موردنظر است. الگوریتم یادگیری نگاشتهای خودسازمانده را را می‌توان در مراحل زیر خلاصه نمود:

- ۱- مرحله آغازین، در این مرحله وزن هر نرون به صورت یک عدد تصادفی قرار داده می‌شود، سپس یک الگوی ورودی



شکل ۳- انواعی از همسایگی‌ها در نگاشت‌های خودسازمان‌ده

۳-۲- بکارگیری نگاشت‌های خودسازمان‌ده به منظور نمایش و تحلیل فضاهای چندبعدی

پس از آموزش یک شبکه خودسازمان‌ده، به تعداد نرون‌های انتخابی برای شبکه، بردارهای وزنی n بعدی به دست خواهد آمد که هر یک نمایانگر بخشی از فضای مورد تحلیل است. در صورت انتخاب تعداد مناسب نرون، ابعاد شبکه و در نهایت آموزش مناسب شبکه، نمایش بردارهای وزنی متناظر با نرون‌های هر نقشه می‌تواند به خوبی نمایانگر فضای مورد تحلیل باشد. بدین متناظر با مقدار هر مشخصه در بردار وزنی یک بردار RGB و در نتیجه یک رنگ در نظر گرفته می‌شود [۳۴]. به گونه‌ای که کلیه مقادیر با استفاده از طیف رنگی، از آبی تیره برای کمترین مقدار تا قرمز تیره برای بیشترین مقدار، قابل نمایش باشد. توضیحًا RGB از فرمتهای استاندارد تعريف رنگ‌های است که هر رنگی را با توجه به میزان شدت رنگ‌های اصلی و از ترکیب آنها قابل حصول می‌سازد.

بدین ترتیب به ازاء هر مشخصه، رنگ هر نرون تعیین شده و نقشه متناظر با آن مشخصه به دست آید. با به دست آمدن نقشه‌های مشخصات، بررسی ارتباط متقابل میان مشخصه‌ها و تست همبستگی بین آنها امکان پذیر می‌گردد. به عنوان مثال هم رنگ بودن قسمت‌های متناظر دو نقشه، نشان‌دهنده وجود رابطه و همبستگی مشخصه‌های متناظر با هر مشخصه است. میزان رابطه موجود و شدت همبستگی میان دو متغیر در قسمت‌های مختلف فضا نیز از شدت تفاوت یا تشابه رنگ میان نقشه‌های متناظر با هر یک از متغیرها قابل بررسی است. البته ممکن است شدت و یا حتی نوع رابطه موجود بین دو مشخصه

روش دوم تمامی نرون‌های موجود در شبکه با ضریب نابرابر به سمت ورودی حرکت می‌کنند. این ضریب نابرابر به صورتی است که در نرون برنده حداقل مقدار را داشته و با دورشدن از نرون برنده مقدارش کاهش پیدا می‌کند.

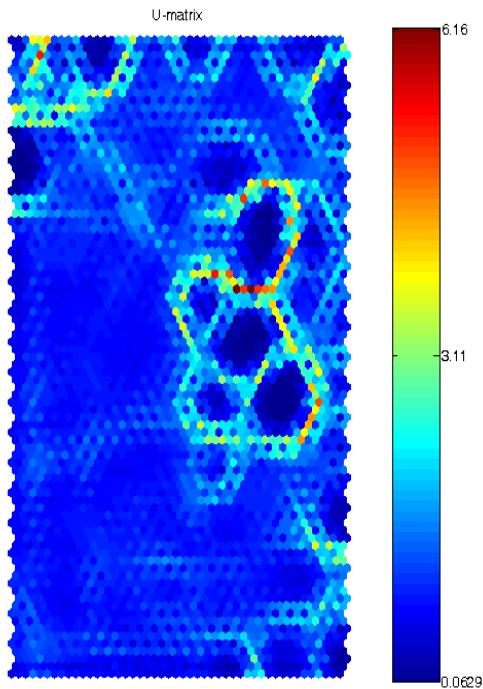
۴- اصلاح اوزان، در انتها اوزان مربوط به نرون برنده و همسایگانش باید براساس ورودی شبکه اصلاح گردند. این تغییرات براساس رابطه زیر صورت می‌گیرد:

$$m_r(t+1) = m_r(t) + \alpha(t) \cdot h_{cr}(t) \quad (3)$$


به قسمی که $x(t)$ بردار ورودی در زمان t $m_r(t)$ مرجع x در زمان t $\alpha(t)$ نرخ یادگیری در زمان t و $h_{cr}(t)$ تابع همسایگی است که براساس تابع کرنل مطابق زیر تعریف می‌گردد:

$$h_{cr}(t) = \exp\left(-\frac{\|k_c - k_r\|^2}{2\sigma(t)^2}\right) \quad (4)$$

به قسمی که $k_c, k_r \in \mathbb{R}^d$ به ترتیب بیانگر نرون برنده و الگوهای مرجع همسایه آن بوده و $\sigma(t)$ شعاع تابع کرنل در زمان t می‌باشد. نتیجه موارد فوق اصلاح اوزان و حرکت نرون‌های مذکور به سوی نمونه آموزشی است. $\alpha(t)$ پارامتری است که به منظور کنترل همگرایی الگوریتم به کار گرفته می‌شود و وابسته به تکرار است. به منظور پایداری شبکه می‌بایست $1 < \alpha(t) < 0$ بوده و لزوماً بر حسب t به صورت کاهشی یکنواخت باشد. آموزش بدون نظارت در حالت کلی به صورت اجتناب‌ناپذیری از حالت نظارتی پیچیده‌تر بوده و به همین دلیل نیز به زمان بیشتری جهت یادگیری الگوهای آموزشی نیاز دارد [۳۳].



شکل ۵- نمونه‌ای از یک ماتریس دسته‌بندی



شکل ۴- نمونه‌ای از نقشه‌های SOM در تحلیل الگوهای پیچیده

در نقاط مختلف فضا متفاوت و متأثر از مقدار سایر مشخصه‌ها نیز باشد که همگی با استفاده از نقشه‌های SOM به خوبی قابل نمایش و مشاهده هستند. در شکل (۴) می‌توانید نمونه‌ای از نقشه‌های SOM و کاربردهای شبکه‌های خودسازمانده در تحلیل الگوهای پیچیده و نمایش همزمان اثرات متقابل متغیرهای مختلف بر یکدیگر را مشاهده نمایید.

همان‌گونه که از شکل (۴) مشخص است فضای مورد تحلیل دارای پنج بعد می‌باشد. از مقایسه نقشه‌های مذکور با یکدیگر اطلاعات زیادی از جمله موارد زیر قابل استنتاج است:

- متغیرهای دوم و پنجم و همچنین متغیرهای اول و چهارم در تمامی دامنه تغییرات خود دارای رابطه و همبستگی معکوس می‌باشند. گرچه شدت همبستگی متغیرهای دوم و پنجم و در تمامی نقاط فضا تقریباً ثابت است، اما این نکته در مورد متغیرهای اول و چهارم صادق نیست.

- متغیرهای سوم و پنجم نیز دارای همبستگی معکوس هستند اما شدت همبستگی آنها در تمامی نقاط فضا ثابت نمی‌باشد. همچنین شدت این همبستگی از شدت همبستگی بین متغیرهای دوم و پنجم کمتر است.

- متغیرهای دوم و سوم دارای همبستگی مستقیم‌اند ولی شدت همبستگی آنها وابسته به مقادیر سایر متغیرهای است.

- همبستگی متغیرهای اول، چهارم و پنجم کاملاً غیرخطی بوده و شدت آن در نقاط مختلف فضا متفاوت است.

۳- روش شبکه‌های عصبی مصنوعی (ANNs)

شبکه‌های عصبی مصنوعی از جمله روش‌هایی هستند که قادر به تخمین موارد غیرخطی متعدد در داده‌ها بوده و یک

یک مدل بیش از حد برآش شده، برای داده‌هایی که در ساخت مدل (داده‌های آموزشی) استفاده شده‌اند برآش خوبی نشان می‌دهد اما توانایی تعمیم آن، برای داده‌های خارج از نمونه بسیار ضعیف است [۳۴]. انتخاب تعداد نرون‌های لایه مخفی وابسته به داده‌ها بوده و هیچ قانون سیستماتیکی به منظور تعیین این پارامتر در طراحی شبکه‌های عصبی وجود ندارد. علاوه بر این، مرحله مهم دیگر مدل‌سازی شبکه‌های عصبی، انتخاب تعداد وقههای موجود در مشاهدات به عنوان بردار ورودی شبکه است که شاید مهم‌ترین پارامتر در طراحی مدل‌های شبکه‌های عصبی مصنوعی باشد، زیرا این پارامتر در تعیین ساختار خودهمبسته غیرخطی سری‌های زمانی نقش اساسی دارد. هیچ تئوری خاصی جهت انتخاب P وجود ندارد، از این‌رو تجربه و آزمایشات، مشخص کننده مقدار مناسب P و Q خواهد بود. هنگامی که یک ساختار شبکه‌ای P و Q مشخص شد شبکه آماده آموزش فرآیند تخمین پارامترها است. همانند مدل‌سازی خودرگرسیون میانگین متحرک انباسته، پارامترها به گونه‌ای تخمین‌زده می‌شوند که معیار دقت شبکه مانند میانگین مربعات خطأ حداقل گردد. این فرآیند توسط الگوریتم‌های بهینه‌سازی غیرخطی همچون پس انتشار خطأ انجام می‌شود.

۴- روش ترکیبی پیشنهادی

شبکه‌های عصبی پرسپترون چندلایه برخلاف روش‌های سنتی پیش‌بینی همچون رگرسیون، دارای محدودیت تعداد متغیرهای ورودی هستند. در روش‌هایی همچون رگرسیون عملکرد مدل با تعداد متغیرهای ورودی توضیح دهنده رابطه مستقیم غیراکید دارد، به عبارت دیگر با افزایش تعداد متغیرهای توضیح دهنده، عملکرد مدل کاهش پیدا نخواهد کرد. اما در شبکه‌های عصبی چندلایه پیشخور همچون پرسپترون‌های چندلایه این مسئله برقرار نمی‌باشد. لذا مسئله تعیین تعداد متغیرهای ورودی به شبکه به مسئله‌ای مهم و تأثیرگذار در طراحی شبکه‌های عصبی تبدیل شده است. هر چند قانون تعریف شده‌ای برای تعداد ورودی‌های شبکه، در مسائل مختلف تعیین نشده است، اما در

چارچوب محاسبه‌ای انعطاف‌پذیر برای دامنه وسیعی از مسائل غیرخطی می‌باشند. یکی از مزیت‌های بارز این‌گونه مدل‌ها نسبت به مدل‌های دیگر غیرخطی، این است که شبکه‌های عصبی مصنوعی یک تقریب‌زننده جهانی هستند که می‌توانند هر نوع تابعی را با دقت دلخواه تقریب بزنند. این نوع از شبکه‌ها نیاز به هیچ‌گونه پیش‌فرضی در مورد شکل مدل در فرآیند مدل‌سازی نداشته و به‌طورکلی یک مدل مبتنی بر داده می‌باشند [۳۵]. این‌گونه مدل‌ها از سه لایه پردازش ساده اطلاعات متصل به هم تشکیل شده‌اند. رابطه بین خروجی (y_t) و ورودی‌ها (x_1, x_2, \dots, x_p) به صورت زیر است:

$$y_t = b_0 + \sum_{j=1}^Q w_j \cdot g(b_{0j} + \sum_{i=1}^P w_{i,j} \cdot x_i) + \epsilon_t \quad (5)$$

به‌طوری که w_j , $w_{i,j}$ پارامترهای مدل بوده که غالباً وزن‌های اتصالی نامیده می‌شوند، P تعداد گره‌های ورودی و Q تعداد گره‌های مخفی هستند.تابع سیگموئیدی اغلب به عنوانتابع فعال‌سازی لایه مخفی مورد استفاده قرار می‌گیرد:

$$g(x) = \frac{1}{1 + \exp(-x)} \quad (6)$$

از این‌رو مدل شبکه‌های عصبی مصنوعی رابطه (۶) در حقیقت به عنوان یک نگاشت غیرخطی از مشاهدات گذشته به مقدار آینده خواهد بود، یعنی:

$$y_t = f(x_1, x_2, \dots, x_p, w) + \epsilon_t \quad (7)$$

به‌طوری که W بردار همه پارامترها و f تابعی است که توسط ساختار شبکه عصبی و وزن‌های اتصالی تعیین می‌گردد، از این‌رو شبکه‌های عصبی معادل مدل خودرگرسیون غیرخطی هستند. مدل ساده بیان شده توسط رابطه (۷) دارای قدرت تقریب بسیار زیادی می‌باشد، چرا که قادر است هر تابع دلخواه را به شرط آنکه تعداد گره‌های مخفی (Q) به اندازه کافی بزرگ باشد را تقریب بزند. در عمل ساختار شبکه عصبی ساده که تعداد نرون کمتری در لایه مخفی دارد غالباً در پیش‌بینی‌های خارج از نمونه بهتر عمل می‌کند و این به دلیل دوری جستن از مسئله برآش بیش از حد است که عمدتاً در فرآیند مدل‌سازی شبکه‌های عصبی رخ می‌دهد.

در مرحله بعدی از روش پیشنهادی، باید متغیرهای موجود در هر خوشه با یکدیگر ترکیب شوند، زیرا براساس مفاهیم پایه‌ای در روش‌های خوش‌بندی، متغیرهای موجود در هر خوشه ممکن است حاوی اطلاعات تکراری باشند. این در حالی است که براساس اصول طراحی شبکه‌های عصبی، این گونه از اطلاعات تکراری نه تنها عملکرد شبکه را افزایش نخواهد داد، بلکه حتی ممکن است باعث کاهش عملکرد آن نیز گردد [۴]. لذا در مرحله سوم و قبل از طراحی شبکه نهایی، متغیرهای موجود در هر خوشه باید با یکدیگر ترکیب شوند. در حالت کلی، هدف از ترکیب متغیرها تجمعی، ادغام و فشرده‌سازی اطلاعات موجود در متغیرها است [۲۷].

در ادبیات موضوع، روش‌های مختلفی به منظور ترکیب داده‌ها با یکدیگر پیشنهاد شده است [۲۸] که از جمله مهم‌ترین آنها می‌توان به روش‌های پایه‌ترکیب همچون میانگین، میانگین وزن‌دار، میانه، مدل، مجموع، ماکریم، مینیمم، نزدیک‌ترین همسایه و یا روش‌های پیشرفته‌تر همچون دمپستر شیفر [۲۹]، فازی [۳۰]، بیزین [۳۱] و غیره [۳۲] اشاره نمود. در این مقاله نیز متغیرهای موجود در هر خوشه با استفاده از روش میانگین وزن‌دار (یا و بدون در نظر گرفتن رتبه هر متغیر) با یکدیگر ترکیب شده‌اند. بدین منظور ابتدا تمام متغیرها براساس میزان تأثیرگذاری شان بر متغیر وابسته رتبه‌بندی می‌شوند؛ سپس وزن هر متغیر برابر با میزان توضیح دهنده‌گی آن متغیر بر متغیر وابسته در نظر گرفته می‌شود. حال با توجه به مطالب فوق متغیرهای هر خوشه را می‌توان به دو صورت با یکدیگر ترکیب نمود:

- ۱- با درنظر گرفتن رتبه
- ۲- بدون درنظر گرفتن رتبه

$$V_{\text{Group}}(i) = \sum_{j=1}^m (m - R_j + 1) \cdot W_j \cdot V_{X_{(j)}}(i) \quad \text{for } i = 1, 2, \dots, n$$

۲- بدون درنظر گرفتن رتبه

$$V_{\text{Group}}(i) = \sum_{j=1}^m W_j \cdot V_{X_{(j)}}(i) \quad \text{for } i = 1, 2, \dots, n$$

به قسمی که

$V_{\text{Group}}(i)$: مقدار نام گروه

حالت کلی تعداد ورودی‌های شبکه به ساختار شبکه، الگوریتم آموزش، پیچیدگی مسئله مورد نظر و اختلالات موجود در داده‌ها وابسته می‌باشد [۷].

در ادبیات موضوع، راه حل معمول برای مسئله فوق‌الذکر، انتخاب تأثیرگذارترین متغیرهای ورودی بر مقدار تابع هدف و حذف سایر متغیرها است [۴]. حال در نظر نگرفتن این متغیرها در ساختار نهایی شبکه و عدم توانایی تحلیل نوع و میزان تأثیرگذاری آنها بر متغیر وابسته، مشکلی است که از محبویت شبکه‌های پرسپترون چندلایه در پیش‌بینی کاسته است. در روش ترکیبی پیشنهادی به جای حذف متغیرهایی با تأثیرگذاری کمتر، این گونه از متغیرها با سایر متغیرهای تأثیرگذار هم‌دسته خود ترکیب می‌گردد. با ترکیب ورودی‌ها با یکدیگر، دیگر نه تنها مشکل تعداد ورودی‌ها را نخواهیم داشت، بلکه توانایی تحلیل نوع و میزان تأثیرگذاری هر یک از متغیرها را نیز به‌دست خواهیم آورد.

روش ترکیبی پیشنهادی در حالت کلی شامل چهار مرحله اساسی زیر می‌باشد:

- ۱- تشخیص متغیرهای تأثیرگذار
 - ۲- خوش‌بندی متغیرهای تأثیرگذار
 - ۳- ترکیب متغیرهای تأثیرگذار در هر دسته
 - ۴- طراحی شبکه عصبی نهایی و پیش‌بینی متغیر وابسته
- در روش پیشنهادی به منظور تشخیص متغیرهای تأثیرگذار از میان مجموعه متغیرهای موجود و همچنین خوش‌بندی آنها از نگاشتهای خودسازمانده استفاده شده است. نگاشتهای خودسازمانده کلاس خاصی از شبکه‌های عصبی مصنوعی هستند که غالباً به منظور تحلیل فضاهای پیچیده داده‌ها مورد استفاده قرار می‌گیرند [۲۶]. اساس عملکرد این گونه از شبکه‌ها تبدیل یک فضای ورودی با بعد دلخواه به یک فضا با بعد کمتر و غالباً یک نگاشت دو بعدی گستته است. هدف نهایی در استفاده از نگاشتهای خودسازمانده نیز حصول همین مدل ساده از داده‌های اولیه به منظور کاهش محاسبات و پیچیدگی‌های موجود در زمینه تجزیه و تحلیل داده‌ها می‌باشد.

روش پیشنهادی، تقسیم‌بندی داده‌ها، به داده‌های تست و آموزش در جدول (۲) آورده شده است.

۵- نتایج حاصله

در ابتدا به منظور مشخص نمودن مجموعه متغیرهای اولیه، از روش دلفی (Delphi) استفاده شد. پس از مشخص نمودن مجموعه متغیرهای اولیه، براساس الگوریتم پیشنهادی و با استفاده از نگاشتهای خودسازمانده، متغیرهای مؤثر بر متغیر وابسته تشخیص داده شده‌اند [۳۶]. در مرحله بعدی با درنظر گرفتن نوع و میزان همبستگی هر یک از متغیرها بر قیمت محصولات به عنوان متغیر وابسته، متغیرهای مؤثر خوش‌بندی شده‌اند. فرآیند تشخیص و خوش‌بندی متغیرها براساس بررسی و مقایسه نقشه‌های مربوط به هر یک از متغیرهای مستقل اولیه با متغیر وابسته می‌باشد. نقشه‌های مربوط به متغیر وابسته و متغیرهای مستقل در شکل (۶) آورده شده است.

در این شکل هر یک از نقشه‌ها با طیف رنگی آبی تیره برای کمترین مقدار تا قرمز تیره برای بیشترین مقدار بیان کننده فضای مورد تحلیل بوده و هر سلول بیانگر جزئی از فضای مورد نظر است، بعد این فضا نیز برابر با تعداد متغیرهای ورودی است. حال با مقایسه نقاط متناظر هر یک از متغیرها می‌توان به روابط موجود پی‌برد، به عنوان مثال هم‌رنگ بودن قسمت‌های بالایی نقشه‌های مربوط به متغیر وابسته و قیمت جهانی فولاد بیانگر رابطه موجود بین دو متغیر است، ضمناً شدت تشابه یا تفاوت رنگ، بیان کننده میزان این رابطه می‌باشد. در مرحله سوم، متغیرهای هر خوش‌بندی با یکدیگر ترکیب می‌شوند. نتایج اجرای مراحل فوق الذکر بیانگر وجود ده خوش‌بندی متغیرهای هر خوش‌بندی بر قیمت محصولات بوده که در جدول (۳) آورده شده‌اند.

سپس با استفاده از روش‌های رگرسیون خطی و پرسپترون‌های چندلایه وزن‌های متغیرهای موجود در هر خوش‌بندی و همچنین رتبه‌های هر یک از خوش‌بندی‌ها محاسبه شده‌اند. نتایج حاصله در جدول (۴) آورده شده است. در انتها نیز با توجه به

جدول ۲- تقسیم‌بندی داده‌ها به داده‌های تست و آموزش

محصولات	تعداد داده‌ها	نمونه	مجموعه آموزش	سایز	سایز	سری زمانی
	۱۲۰	۱۰۰	۲۰			

$$X_{(j)}^i : \text{مقدار زام متغیر } i$$

R_j : رتبه متغیر زام در گروه

W_j : وزن متغیر مستقل زام

m : تعداد متغیرهای مستقل

n : تعداد داده‌ها است.


لذا در انتهای متغیرهای موجود در هر خوش‌بندی براساس وزن و اهمیت نسبی آنها طبق روابط فوق با یکدیگر ترکیب می‌شوند و مقادیر حاصله به عنوان نماینده هر خوش‌بندی و ورودی شبکه در نظر گرفته می‌شود. لازم به ذکر است که وزن هر یک از متغیرها در هر خوش‌بندی، بسته به نوع متغیر (گسسته و یا پیوسته) از طریق رگرسیون خطی و یا شبکه‌های پرسپترون‌های چندلایه به دست آورده می‌شود.

۵- پیش‌بینی قیمت محصولات شرکت ذوب‌آهن اصفهان

در این قسمت، مراحل روش پیشنهادی به منظور پیش‌بینی قیمت محصولات فولادی شرکت سهامی ذوب‌آهن اصفهان در بورس فلزات تهران، به صورت مبسوط‌تری توضیح داده شده است.

۱-۵- مجموعه داده‌ها

مجموعه داده‌های استفاده شده در این مقاله، داده‌های مربوط به قیمت محصولات فولادی شرکت سهامی ذوب‌آهن اصفهان و سایر متغیرهای مؤثر از ابتدای تأسیس بورس فلزات تهران May/1996 تا Aug/2005 بوده و جمعاً شامل ۱۲۰ داده است [۳۴]. با توجه به تعداد داده‌ها (سایز نمونه) و مراحل اجرای



شکل ۶- نقشه‌های مربوط به متغیرهای مؤثر اولیه

به قسمی که

Var 1: متغیر وابسته (قیمت)

Var 3: میزان تقاضا

Var 5: قیمت پایه پیشنهادی

Var 7: تأثیر مرتبه سوم قیمت

Var 9: تأثیر مرتبه پنجم قیمت

Var 11: فاصله عقد قرارداد تا تحويل

Var 13: نرخ ارز

Var 2: میزان عرضه کالا
Var 4: حجم معامله قبلی
Var 6: تأثیر مرتبه دوم قیمت
Var 8: تأثیر مرتبه چهارم قیمت
Var 10: تفاوت عرضه و تقاضا
Var 12: قیمت جهانی فولاد خام
Var 14: نوع محصول

۳-۵- مقایسه عملکرد روش پیشنهادی با سایر روش‌ها
مسئله نهایی اطمینان از قدرت عملکرد روش پیشنهادی در پیش‌بینی قیمت محصولات است، زیرا مدل مذکور به شرط آنکه عملکرد بهتری نسبت به سایر روش‌ها داشته باشد، ارزشمند خواهد بود. لذا در این قسمت عملکرد روش

اصول طراحی شبکه‌های عصبی [۳۷-۳۸] و خوش‌های به دست آمده، شبکه نهایی طراحی و قیمت محصولات پیش‌بینی شده‌اند. نتایج حاصله از عملکرد روش پیشنهادی و همچنین میزان بهبودی که در مقایسه با سایر روش‌ها به دست آورده است، در جدول (۵) خلاصه‌سازی شده‌اند.

جدول ۳- اطلاعات مربوط به خوشه‌های متغیرهای مؤثر اولیه

ردیف	نام گروه	متغیرهای مؤثر موجود در گروه
-۱	تولیدکننده‌ها	تولیدکننده اول تا تولیدکننده پنجم)
-۲	نوع محصول	نوع محصول (محصول نوع اول تا محصول نوع چهارم)
-۳	زمان قرارداد	سال قرارداد و فصل قرارداد
-۴	قیمت گذشته	تأخیرات مرتبه دوم تا پنجم قیمت
-۵	قیمت پایه	قیمت پایه
-۶	قیمت جهانی فولاد خام	قیمت جهانی فولاد خام
-۷	نرخ ارز	نرخ ارز
-۸	میزان عرضه و میزان تقاضا	میزان عرضه و میزان تقاضا
-۹	تفاوت میان میزان عرضه و تقاضا	تفاوت میان میزان عرضه و تقاضا
-۱۰	حجم معامله قبلی	حجم معامله قبلی

جدول ۴- وزن‌های بدست آمده برای متغیرهای موجود در هر خوش

نام خوش	متغیرهای موجود در هر خوش	وزن متغیر	رتبه متغیر	روش محاسبه اوزان
۱- تولیدکننده‌ها	تولیدکننده اول	%۱	۴	رگرسیون خطی
	تولیدکننده دوم	%۶۳	۱	رگرسیون خطی
	تولیدکننده سوم	%۳۲	۲	رگرسیون خطی
	تولیدکننده چهارم	%۱	۵	رگرسیون خطی
	تولیدکننده پنجم	%۳	۳	رگرسیون خطی
۲- نوع محصول	محصول نوع اول	%۱	۴	رگرسیون خطی
	محصول نوع دوم	%۱۲	۳	رگرسیون خطی
	محصول نوع سوم	%۱۷	۲	رگرسیون خطی
	محصول نوع چهارم	%۷۱	۱	رگرسیون خطی
۳- زمان قرارداد	سال قرارداد	%۸۶	۱	رگرسیون خطی
	فصل قرارداد	%۱۴	۲	رگرسیون خطی
	بهار	%۴۸	۱	رگرسیون خطی
	تابستان	%۴	۳	رگرسیون خطی
	فصل قرارداد	%۴۷	۲	رگرسیون خطی
۴- قیمت‌های گذشته	زمستان	%۱	۴	رگرسیون خطی
	تأخیر دوم قیمت	%۳۲	۱	شبکه‌های عصبی
	تأخیر سوم قیمت	%۲۶	۲	شبکه‌های عصبی
	تأخیر چهارم قیمت	%۲۵	۳	شبکه‌های عصبی
	تأخیر پنجم قیمت	%۱۷	۴	شبکه‌های عصبی

جدول ۵ - معیارهای عملکرد هر یک از روش‌ها و میزان بهبود روش پیشنهادی نسبت به سایر روش‌ها

داده‌های تست				معیار
میزان بهبود		میزان عملکرد		
MSE	MAE	MSE	MAE	روش
۶۱/۶۵	۳۹/۹۵	۵۳۴۹۷	۱۷۴/۷	رگرسیون چندگانه
۳۶/۸۵	۱۷/۰۸	۳۲۴۸۶	۱۲۶/۵	پرسپترون‌های چندلایه سنتی
----	----	۲۰۵۱۶	۱۰۴/۹	روش ترکیبی پیشنهادی

رقابتی در تقابل با دیگر رقبا می‌باشد. در این مقاله یک روش ترکیبی از پرسپترون‌های چندلایه با استفاده از نگاشت‌های خودسازمانده ارائه گردیده است. هدف روش پیشنهادی بهره‌مندی از مزایای منحصر به فرد نگاشت‌های خودسازمانده در تحلیل غیرخطی فضاهای چندبعدی به منظور خوش‌بندی و ترکیب متغیرهای ورودی به پرسپترون‌های چندلایه برای مرتفع ساختن محدودیت تعداد ورودی‌ها، در این‌گونه از شبکه‌ها می‌باشد. نتایج حاصل از به کارگیری روش پیشنهادی در پیش‌بینی قیمت محصولات شرکت سهامی ذوب آهن اصفهان در بورس فلزات تهران بیانگر آن است که روش پیشنهادی نه تنها قادر به حصول نتایج دقیق‌تر نسبت به پرسپترون‌های چند لایه سنتی است، بلکه امکان تحلیل تعداد بیشتری از متغیرهای مؤثر بر قیمت محصولات را برای تصمیم‌گیران مالی فراهم می‌سازد.

قدرتانی

در اینجا جا دارد از همکاری‌ها و حمایت‌های کارشناس محترم بخش تحقیق و توسعه شرکت سهامی ذوب آهن اصفهان، جناب آقای مهندس مجید رفیعی به جهت ارائه اطلاعات و آمار مورد نیاز تشکر و قدردانی نماییم. همچنین نویسنده‌گان بر خود لازم می‌دانند تا از نظرات اصلاحی داوران محترم که کمال شایانی درجهت بهبود کیفیت مقاله حاضر بوده است، کمال تشکر و قدردانی را داشته باشند.

پیشنهادی با دو مدل پرسپترون‌های چندلایه سنتی و مدل رگرسیون چندگانه مقایسه شده است. نتایج حاصله بیانگر برتری اکید روشن پیشنهادی بر پرسپترون‌های چندلایه معمولی و همچنین رگرسیون چندگانه در هر دو معیار میانگین قدرمطلق خطای مربع (MSE) و میانگین مربع خطای (MAE) است. مطابق با نتایج گزارش شده در جدول (۵)، روش پیشنهادی قادر بوده تا قیمت محصولات را در داده‌های تست با میانگین قدرمطلق خطای ۱۰۴/۹ ریال پیش‌بینی نماید. این در حالی است که این معیار برای مدل‌های رگرسیون چندگانه و پرسپترون‌های چندلایه به ترتیب برابر با ۱۷۴/۷ و ۱۲۶/۵ می‌باشد. بر این اساس می‌توان مشاهده نمود که روش پیشنهادی توانسته عملکرد این دو روش را به ترتیب به میان ۳۹/۹۵٪ و ۱۷/۰۸٪ بهبود بخشد. روش پیشنهادی همچنین قادر بوده تا میانگین مربعات خطای پیش‌بینی را به عدد ۲۰۵۱۶ برساند که این خود به ترتیب بیانگر ۶۱/۶۵٪ و ۳۶/۸۵٪ بهبود نسبت به مدل‌های رگرسیون چندگانه و پرسپترون‌های چندلایه است. بر این اساس، چنین به نظر می‌رسد که روش پیشنهادی می‌تواند راهکار و جایگزینی مناسب برای روش‌های سنتی پیش‌بینی باشد.

۶- نتیجه‌گیری

قیمت محصولات و روند تغییرات مربوط به آن از مهم‌ترین عوامل در تصمیم‌گیری و تدوین استراتژی‌های مالی است و پیش‌بینی آنها از جمله مهم‌ترین راهکارها، جهت ایجاد مزیت

مراجع

۱. خاشعی، م، و بیجاری، م، "بهبود عملکرد پیش‌بینی‌های مالی با ترکیب مدل‌های خطی و غیر خطی خودرگرسیون میانگین متحرک انباسته و شبکه‌های عصبی مصنوعی"، فصلنامه علمی و پژوهشی پژوهش‌های اقتصادی، دانشگاه تربیت مدرس، سال هشتم، شماره ۲، ص ۱۰۰-۸۳، تابستان ۱۳۸۷.

2. Reid, M. J., "Combining Three Estimates of Gross Domestic Product", *Economica*, Vol. 35, pp. 431– 444, 1968.
3. Bates, J. M. C., and Granger, W. J., "The Combination of Forecasts", *Operation Research Quarterly*, Vol. 20, pp. 451– 468, 1969.
4. Zhang, G., Patuwo, B. E., and Hu, M. Y., "Forecasting with Artificial Neural Networks: The State of the Art", *International Journal of Forecasting*, Vol. 14, pp. 35– 62, 1998.
5. Khashei, M., and Bijari, M., "An Artificial Neural Network (p,d,q) Model for Time Series Forecasting", *Expert Systems with Applications*, Vol. 37, pp. 479– 489, 2010.
6. Chen, K., and Wang, C., "A Hybrid SARIMA and Support Vector Machines in Forecasting the Production Values of the Machinery Industry in Taiwan", *Expert Systems with Applications*, Vol. 32, pp. 254– 264, 2007.
7. Khashei, M., Hejazi, S. R., and Bijari, M., "A New Hybrid Artificial Neural Networks and Fuzzy Regression Model for Time Series Forecasting", *Fuzzy Sets and Systems*, Vol. 159, pp. 769– 786, 2008.
8. Armano, G., Marchesi, M., and Murru, A., "A Hybrid Genetic-Neural Architecture for Stock Indexes Forecasting", *Information Sciences*, Vol. 170, pp. 3– 33, 2005.
9. Huang, C., and Tsai, C., "A Hybrid SOFM-SVR with a Filter-Based Feature Selection for Stock Market Forecasting", *Expert Systems with Applications*, Vol. 34, pp. 254– 267, 2008.
10. Li, C. F., Zhang, J. B., Wang, Z. Y., and Wang, S. T., "A Fully Automated Pattern Classification Method of Combining Self-Organizing Map with Generalization Regression Neural Network", *13th International Conference on Neural Information Processing*, pp. 132– 139, 2006.
11. Wang, J., and Yan, D., "A High Precision Prediction Method by Using Combination of ELMAN and SOM Neural Networks", *The First International Symposium on Neural Networks*, pp. 943– 949, 2004.
12. Carpinteiro, O., Reis, A., and Silva, A., "A Hierarchical Neural Model in Short-Term Load Forecasting", *Applied Soft Computing*, Vol. 4, pp. 405– 412, 2004.
13. Chang, P., and Liao, T. W., "Combining SOM and Fuzzy Rule Base for Flow Time Prediction in Semiconductor Manufacturing Factory", *Applied Soft Computing*, Vol. 6(2), pp. 198– 206, 2006.
14. Beccali, M., Cellura, M., Lo Brano, V., and Marvuglia, A., "Forecasting Daily Urban Electric Load Profiles Using Artificial Neural Networks", *Energy Conversion and Management*, Vol. 45, pp. 2879– 2900, 2004.
15. Ghate, V. N., and Dudul, S. V., "Optimal MLP Neural Network Classifier for Fault Detection of Three Phase Induction Motor", *Expert Systems with Applications*, Vol. 37, pp. 3468– 3481, 2010.
16. Pham, E., Cooper, T., Cao, K., and Kamei, H., "Hybrid Kansei-SOM Model Using Risk Management and Company Assessment for Stock Trading" *Information Sciences*, Vol. 256, pp. 8– 24, 2014.
17. Yu, P., and Lee, J., "A Hybrid Approach Using Two-Level SOM and Combined AHP Rating and AHP/DEA-AR Method for Selecting Optimal Promising Emerging Technology", *Expert Systems with Applications*, Vol. 40, pp. 300– 314, 2013.
18. Jing, Y., and Li, L. F., "SOM and PSO Based Alerts Clustering in Intrusion Detection System", *Applied Mechanics and Materials*, Vol. 401, pp. 1453– 1457, 2013.
19. Tasdemir, K., Milenov, P., and Tapsall, B., "A Hybrid Method Combining SOM-Based Clustering and Object-Based Analysis for Identifying Land in Good Agricultural Condition", *Computers and Electronics in Agriculture*, Vol. 83, pp. 92– 101, 2012.
20. Karabulut, T., and Ibricci, M., "A Fuzzy Self-Organizing Map Algorithm for Biological Pattern Recognition", *Expert Systems*, Vol. 29, pp. 25– 38, 2012.
21. Rustum, R., and Adeloye, A., "Improved Modelling of Wastewater Treatment Primary Clarifier Using Hybrid ANNs", *International Journal of Computer Science and Artificial Intelligence*, Vol. 2, pp. 14– 22, 2012.
22. Mishra, M., and Behera, H. S., "Kohonen Self Organizing Map with Modified K-means clustering for High Dimensional Data Set", *International Journal of Applied Information Systems (IJAIS)*, Vol. 2, pp. 34– 39, 2012.
23. Yadav, V., and Srinivasan, D., "A SOM-Based Hybrid Linear-Neural Model for Short-Term Load Forecasting", *Neurocomputing*, Vol. 74, pp. 2874– 2885, 2011.
24. Ismail, S., Shabri, A., and Samsudin, R., "A Hybrid Model of Self-Organizing Maps (SOM) and Least

- Square Support Vector Machine (LSSVM) for Time-Series Forecasting”, *Expert Systems with Applications*, Vol. 38, pp. 10574– 10578, 2011.
25. Li, T., and Huang, C., “Defect Spatial Pattern Recognition Using a Hybrid SOM-SVM Approach in Semiconductor Manufacturing”, *Expert Systems with Applications*, Vol. 36, pp. 374– 385, 2009.
26. Brian S. P., “Using Self-Organizing Maps to Visualize High-Dimensional Data”, *Computers & Geosciences*, Vol. 31, pp. 531– 544, 2005.
27. Dubois, D., and Prade, H. “On the Use of Aggregation Operations in Information Fusion Processes”, *Fuzzy Sets and Systems*, Vol. 142, pp. 143– 161, 2004.
28. Calvo, T., Mayor, G., and Mesiar, R. (Eds.), “Aggregation Operators: New Trends and Applications”, *Studies in Fuzziness and Soft Computing*, Vol. 97, Physica-Verlag, Heidelberg, 2002.
29. Casanovas, M., and Merigo, J., “Fuzzy Aggregation Operators in Decision Making with Dempster–Shafer Belief Structure”, *Expert Systems with Applications*, Vol. 39, pp. 7138– 7149, 2012.
30. Bedregal, B., Reiser, R., Bustince, H., Lopez-Molina, C., and Torra, V., “Aggregation Functions for Typical Hesitant Fuzzy Elements and the Action of Automorphisms”, *Information Sciences*, Vol. 255, pp. 82– 99, 2014.
31. Wang, P., Xu, L., Zhou, S., Fan, Z., Li, Y., and Feng, S., “A Novel Bayesian Learning Method for Information Aggregation in Modular Neural Networks”, *Expert Systems with Applications*, Vol. 37, pp. 1071– 1074, 2010.
32. Theodosiou, M., “Disaggregation & Aggregation of Time Series Components: A Hybrid Forecasting Approach Using Generalized Regression Neural Networks and the Theta Method” *Neurocomputing*, Vol. 74, pp. 896– 905, 2011.
33. Huidong, J., Wing-Ho, S., Kwong-Sak, L., and Man-Leung, W., “Expanding Self-Organizing Map for Data Visualization and Cluster Analysis”, *Information Sciences*, Vol. 163, pp. 157– 173, 2004.
34. Ana, M., Fonseca, Jose L., Biscaya, A., and Ana M., “Geographical Classification of Crude Oils by Kohonen self-organizing Maps”, *Analytica Chimica Acta*, Vol. 556, pp. 374– 382, 2006.
35. Zampighi, L.M., Kavanau, C.L., and Zampighia, G.A., “The Kohonen Self-Organizing Map: a Tool for the Clustering and Alignment of Single Particles Imaged Using Random Conical Tilt”, *Journal of Structural Biology*, Vol. 146, pp. 368– 380, 2004.
36. Mohamad Khaled, A., “Real-time use of Kohonen’s Self-Organizing Maps for Threat Stabilization”, *Information Fusion*, Vol. 6, pp. 153– 163, 2005.
37. Pei-Chann, C., and Chien-Yuan, L., “A Hybrid System Combining Self-Organizing Maps with Case-Based Reasoning in Wholesaler’s New-Release Book Forecasting”, *Expert Systems with Applications*, Vol. 29, pp. 183– 192, 2005.
38. Demuth, H., and Beale, B., “Neural Network Toolbox User Guide the Math Works Inc”, Natick, 2004.
39. Marzia, Z., Pietro, S., and Krishna, C., “Drift Counteraction with Multiple Self-Organizing Maps for an Electronic Nose”, *Sensors and Actuators*, Vol. 98, 2004, pp. 305– 317.
٤٠. خاشعی، م.، ”پیش‌بینی و تحلیل قیمت محصولات عرضه شده شرکت ذوب آهن اصفهان در بورس فلزات تهران با به کارگیری شبکه‌های عصبی مصنوعی”， پایان‌نامه کارشناسی ارشد، دانشکده صنایع و سیستم‌ها، دانشگاه صنعتی اصفهان، ۱۳۸۴.
٤١. Khashei, M., Bijari, M., and Raissi, GH. A., “Improvement of Auto-Regressive Integrated Moving Average Models Using Fuzzy Logic and Artificial Neural Networks (ANNs)”, *Neurocomputing*, Vol. 72, pp. 956– 967, 2009.
٤٢. خاشعی، م. و بیجاری، م.، ”به کارگیری شبکه‌های عصبی خودسازمانده به منظور تعیین فاکتورهای اساسی تأثیرگذار در متامدل‌بندی بازارهای سازمان یافته مالی”， سمپوزیوم فولاد، ۱۶، بندرعباس، منطقه ویژه صنایع معدنی و فلزی خلیج فارس، ص ۹۲۱-۹۳۰، اسفند ۱۳۸۶.
٤٣. خاشعی، م. و بیجاری، م.، ”به کارگیری شبکه‌های عصبی مصنوعی به منظور پیش‌بینی و تحلیل قیمت محصولات عرضه شده شرکت ذوب آهن اصفهان در بورس فلزات تهران قسمت اول”， ماهنامه فولاد، شماره ۱۳۳، ص ۲۸-۳۱، فروردین ۱۳۸۵.
٤٤. خاشعی، م. و بیجاری، م.، ”به کارگیری شبکه‌های عصبی مصنوعی به منظور پیش‌بینی و تحلیل قیمت محصولات عرضه شده شرکت ذوب آهن اصفهان در بورس فلزات تهران قسمت دوم”， ماهنامه فولاد، شماره ۱۳۴، ص ۲۸-۳۱، اردیبهشت ۱۳۸۵.