فصلنامه اقتصاد کاربردی
سال دوم/ شماره ششم / پاییز ۱۳۹۰

پیش بینی قیمت سکه طلا در بورس کالای ایران
با رویکرد شبکه عصبی GMDH

عباس معمار نژاد [۱] ـ وحید فرمان آرا [۲]

تاریخ دریافت: ۹۰/۴/۱۸ تاریخ پذیرش: ۹۰/۸/۳

چکیده

اقتصاد هر کشور از بخش‌های مختلفی تشکیل شده که روابط بین این بخش‌ها، سمت و سوی اقتصاد آن کشور را مشخص می‌کند. در این بین بازار سرمایه در کنار بازار پول، به عنوان اجزائ تشکیل‌دهنده بازارهای مالی بوده و در واقع شریان‌های اصلی یک اقتصاد محسوب می‌گردند، که مسائلی نظیر رشد و توسعه اقتصادی منوط به عملکرد آنها در اقتصاد می‌باشد و چنانچه رابطه منطقی بین بازار مالی با سایر بخشهای اقتصادی وجود نداشته باشد، احتمال بروز اختلالات و نقصان‌هایی در سازوکار اقتصاد وجود دارد. بازار بورس به عنوان رکن اصلی بازار مالی نقش مهمی را در تسهیل سرمایه‌گذاری‌های شکل گرفته در بازار سرمایه ایفا می‌کند. هدف اصلی این مطالعه همان‌گونه که عنوان این تحقیق نیز مبین آن است، پیش‌بینی قیمت سکه طلا می‌باشد. لذا ضمن مرور اجمالی بر شناخته‌شده‌ترین تئوری‌های اقتصادی، به ارائه روش جدیدتری نسبت به سایر روش‌های متداول پیش بینی در گذشته پرداخته و با استفاده از مدل شبکه عصبی GMDH، اثر متغیرهای کلان اقتصادی (شامل نرخ ارز دلار، قیمت سکه، قیمت طلا به دلار، قیمت نفت به دلار، شاخص قیمت کل سهام، تاریخ روز تحویل سکه) بر قیمت آتی سکه را الگوسازی و پیش‌بینی می‌کنیم. الگوریتم GMDH قابلیت استفاده در موضوعات متنوعی چون کشف روابط، پیش‌بینی، مدل‌سازی سیستم‌ها، بهینه‌سازی وشناخت الگوهای غیرخطی را دارا می‌باشد. ویژگی خاص این الگوریتم استنتاجی، قابلیت شناسایی و غربال‌کردن متغیرهای کم‌اثر ورودی در دوره آموزش شبکه

[۱] عضو هیات علمی گروه اقتصاد دانشکده مدیریت و اقتصاد دانشگاه آزاد اسلامی واحد علوم تحقیقات تهران
economy@srbiau.ac.ir
[۲] دانشجوی دکتری اقتصاد دانشگاه آزاد اسلامی واحد علوم تحقیقات تهران
vahidfarmanara@yahoo.com (مسئول مکاتبات)

و حذف آنها از روند شبیه‌سازی در دوره آزمون می‌باشد. بدین ترتیب می‌توان با انجام یک فرآیند قیاسی، در چند مرحله تکرار، متغیرهای کم‌اثرتر را حذف نمود و نهایتاً مدل بهینه برای پیش‌بینی را بر اساس معیارهای متداول خطا نظیر RMSE و MAPE و... بدست آورد. بعلاوه، این الگوریتم قادر به شناسایی و رتبه‌بندی تأثیرگذارترین متغیرها نیز می‌باشد.

طبقه بندی JEL : E3,C6

کلید واژه: پیش‌بینی، قیمت سکه طلا، متغیرهای کلان، شبکه‌های عصبی مصنوعی، الگوریتم GMDH

۱- مقدمه:

امروزه شاهد گسترش روز افزون ابزارهای مالی در بازارهای مالی دنیا هستیم. اساس خلق ابزارهای مالی جدید به نیاز روز بازار به یک ساز و کار مشخص بر می‌گردد. از جمله‌ی مهم ترین این نیازها را می‌توان در حوزه ریسک مشاهده کرد.

در شرایط امروز کسب و کار، بازارها دچار نوسانات بسیار هستند و این نوسانات منشأ بسیاری از انواع ریسک‌ها می‌باشند. به همین منظور ابداع و بهره مندی از ابزارهای مختلف پوشش ریسک از اهمیت بسزایی برخوردار می‌باشد.ابزارهای مالی مختلف جهت پوشش این ریسک‌ها نتیجه احساس ضرورت به برخورداری از ابزارهای خاص جهت منظور مشخص محسوب می‌شود. از طرف دیگر بورس‌ها به عنوان نهادهای مالی در توسعه و گسترش استفاده از ابزارهای نوین مالی و بستر سازی به منظور حضور فعال سرمایه گزاران در این بازارها نقش بسیار مهمی را ایفا می‌نماید. یکی از ابزارهایی که به طور گسترده در بازارهای بورس و خارج از بورس مورد معامله قرار می‌گیرند، قراردادهای آتی[1] می‌باشد.

از جمله مواردی که در این ابزارها دارای اهمیت می‌باشد، چگونگی ارتباط بین بازار نقد دارایی پایه‌ای که این قراردادها از آن مشتق شده و بازار آتی می‌باشد. زیرا نوع ارتباط آنها در تصمیم گیری فعالان اقتصادی و مدل پیش بینی قیمت موثر خواهد بود. در این خصوص شیوه‌ها و تکنیک‌های مختلفی برای تعیین نوع ارتباط بین این دو بازار وجود دارد.

[1] futures

هدف از انجام این مقاله پیش بینی قیمت سکه طلا در بورس کالای ایران با استفاده از متغیرهای کلیدی تاثیرگذار در بازار طلا در داخل و خارج از کشور می‌باشد. با توجه به اینکه متغیرهای فراوان و عوامل متعددی می‌تواند بر روی قیمت سکه طلا تاثیر گذار باشد، توسعه یک الگوی جامع که در برگیرنده طیف گسترده این متغیرها باشد امری دشوار و حساس به نظر می‌رسد. طبیعی است برای نیل به این هدف و غلبه بر مشکلات آن، نیازمند طرح الگوریتمی جامع و استفاده از ابزاری قدرتمند برای پیاده‌سازی آن هستیم، که بتواند این پیچیدگی‌ها را در تحلیل لحاظ نموده و ابعاد گوناگون مسئله در آن امکان نمود داشته باشد.

بنابراین هدف علمی این مقاله، ارائه روشی مناسب برای الگوسازی و پیش‌بینی قیمت سکه طلا در بورس کالای ایران می‌باشد، که برای این منظور از مدل‌های شبکه عصبی مصنوعی از نوع الگوریتم GMDH استفاده می‌نماییم.

۲-مبانی نظری و پیشینه پژوهش

تحولات اخیر در حوزه فناوری منجر به تحولات در حوزه مدیریت سازمان گردیده و به تبع آن امور مالی شرکت‌ها را نیز به میزان زیادی تحت تاثیر قرار داده است. این امر باعث ظهور شاخه علمی جدیدی به نام مهندسی مالی[1] شده است.

مهندسی مالی به عنوان ابزارهای مالی برای بازسازی شرایط فعلی به شرایطی با توفیقات بیشتر تعریف شده است. ابزارهایی که از طریق مهندسی مالی طراحی می‌گردند باعث کاهش ریسک گردیده‌اند. یکی از حوزه هایی که در آن مهندسی مالی فعالیت میکند، نوآوری در اوراق بهادار است. نوآوری در اوراق بهادار سبب ایجاد شدن ابزارهای مالی جدیدی مانند قراردادهای آتی[2] و قراردادهای اختیار[3] و می‌باشد. از آنجایی که این اوراق ارزش خود را از دارایی پایه می‌گیرند، به عنوان ابزارهای مشتقه[4] معروف گردیده اند. قرارداد آتی به نوعی قرارداد اشاره دارد که در آن طرفین معامله انتقال دارایی پایه در تاریخ معین و با قیمت معین را منعقد می‌کنند. دارایی پایه می‌توانند شامل داراییهای مالی

1 Financial Enginnering
2 Future contracts
3 Option contracts
4 Derivative Instrument

(مانند سهام، شاخص سهام) و دارایی‌های فیزیکی (مانند سکه طلا، آهن،مس و محصولالت کشاورزی) باشد.در حال حاضر در بورس کالای ایران قراردادهای آتی بر روی داراییهای فیزیکی انجام می‌شود.قراردادهای آتی سکه طلا از سال ۱۳۸۷ در بورس کالای لیران مورد معامله قرار گرفته است. این قرارداد برای تحویل ۱۰ سکه تمام بهار آزادی تدوین شده است و در حال حاضر با سررسیدهای ماه دی و اسفند و (اردیبهشت و تیر ۹۱) در بازار کالا عرضه می‌گردد، که به عنوان یکی از متغیرهای الگو آن را مد نظر گرفته ایم.

یکی از مسائل بسیار قابل توجه در عرصه بازارهای مالی، رابطه تنگاتنگ قیمت کالاها و ارزش ارزهای کشورهای مختلف جهان با یکدیگر است. به طوری که در هیچ بازاری نمی‌توان منفرد عمل کرد و به اخبار و اطلاعات مربوط به آن کالا یا ارز بسنده کرد و باید اطلاعات جامعی اگر نگوییم از تمام کالاها لااقل از تعداد قابل توجهی از آنها را گردآوری و تحلیل کرد تا به نتیجه‌ای مطلوب رسید.

در مورد رابطه دلار و نفت و مسائلی که در ادامه مطرح می‌شود باید این نکته را در نظر گرفت که رابطه بین ارزها و کالاهای حساس مثل نفت و طلا صرفاً یکی از چندین پارامتر تأثیرگذار است وحتی در شرایط خاص این ملاحظات از طرف بازیگران بازار نادیده گرفته شود. تشخیص اینکه در چه شرایطی این روابط محکم و استوار است و در چه شرایطی سست و ناپایدار، به عهده تحلیلگران بازارهای مالی و این مهم خود امری دشوار است.

بازار نفت یکی از اصلی ترین بازارهای جهانی است که معمولاً در رابطه با دیگر بازارها، پیشرو است. به عبارت دیگر تغییرات نفت موجب تحول در دیگر بازارها از جمله ارز می‌شود و عکس این موضوع معمولاً صادق نیست. این مسئله اهمیت بررسی تحولات نفت را دوچندان می‌کند.

عوامل تأثیرگذار بر قیمت نفت خارج از بازارهای مالی هستند و بیشتر به مسائل سیاسی جاری در کشورهای تولید کننده و به تقاضا از طرف مصرف کنندگان بزرگ مثل چین و هند و ایالات متحده مربوط می‌شود.

اما تغییرات قیمت نفت تأثیر شدیدی بر بازارهای مالی دارد. براثر گران شدن نفت سهام بسیاری از شرکتها و ارزهای رایج ضربه می‌بینند که از آن میان می‌توان به سهام شرکتهای اتومبیل سازی اشاره کرد که قیمت نفت از فاکتورهای تأثیرگذار بر آنها است. نفت در بازار ارز نیز تأثیر خود را می‌گذارد و با گران شدن نفت ارز رایج کشورهایی که مصرف کنندگان بزرگ نفت هستند با کاهش ارز روبه رو می‌شود که از بین آنها می‌توان به دلار و ین اشاره کرد.

از دیگر کالاهای حیاتی و بسیار مهم در عرصه مبادلات جهانی که نفت تأثیر زیادی بر آن دارد می‌توان به طلا اشاره کرد. بالا رفتن قیمت نفت موجب افزایش تورم جهانی می‌شود و در این شرایط سرمایه گذاران علاقه مند هستند تا سرمایه خود را به چیزی تبدیل کنند تا بیشترین مقاومت را در برابر افزایش تورم داشته باشد، طلا یکی از بهترین انتخاب‌های آنان است و به همین دلیل تقاضا برای طلا بالا رفته و موجب گرانی آن می‌شود.

از طرف دیگر طلا و نفت عوامل تأثیرگذار مشترک یکسانی دارند که موجب می‌شود قیمت این دو کالای حیاتی هم جهت باشد. به عنوان مثال تنش‌های منطقه‌ای علی الخصوص در خاورمیانه هم باعث بالا رفتن قیمت نفت و هم طلا می‌شود. تأثیرگذاری قیمت نفت بر طلا موجب می‌شود تا نفت به صورت غیر مستقیم بر بسیاری دیگر از کالاها، سهام شرکتها و ارزهای رایج کشورهای مختلف نیز تأثیر بگذارد. تغییرات قیمت طلا نیز تأثیر زیادی بر بازارهای مالی جهان دارد. در بازار ارز عمده ارزهایی که رابطه تنگاتنگی با طلا دارند عبارت اند از دلار، فرانک سوئیس و دلار استرالیا. برخلاف نفت که در تمامی روابط خود با دیگر بازارها نقش پیشرو (Leader) را داشت طلا در رابطه خود با بازار ارز گاه نقش پیشرو و گاه نقش پیرو را بازی می‌کند. به عنوان مثال در رابطه طلا با دلار، دلار نقش پیشرو را بازی می‌کند و تغییرات طلا متأثر از تغییرات دلار است. عکس آن نیز در مواردی دیده شده است. یعنی طلا دلار را مطیع خود کرده و تغییرات دلار از پی تغییر قیمت طلا آمده اما به طور کلی آنچه معمول است اینست که دلار جهت طلا را مشخص می‌کند. علت این مسئله اینست که طلا در بازارهای جهانی به دلار ارزش گذاری می‌شود و با بالا رفتن ارزش دلار قیمت طلا برای کسانی که

با دیگر ارزها قصد خرید دارند گران می‌شود و در نتیجه از تقاضای آن کاسته شده که کاهش قیمت را به دنبال دارد. عکس این موضوع نیز صادق است یعنی کاهش ارزش دلار موجب کاهش قیمت طلا برای خریدارانی است با ارزی غیر از دلار که قصد خرید دارند، در نتیجه تقاضا بالا رفته موجب افزایش قیمت می‌شود. بنابراین یکی از اولین قوانین بازار طلا اینست که قیمت این فلز با ارزش دلار رابطه معکوس دارد و در جهت خلاف آن حرکت می‌کند. البته بسیاری اوقات دیده شده که این قانون نقض می‌شود و طلا و دلار هم جهت با یکدیگر حرکت می‌کنند که نمونه مشهور آن هم رفتار بازار در سال ۲۰۰۵ بود که طلا و دلار هر دو افزایش داشتند.

لین[1] (۲۰۱۰) به بررسی پیش بینی قیمت طلا با استفاده از مدلهای آریما و قارچ(GARCH) پرداخت. مطالعه آن‌ها دوره تحقیق ۱۹۷۱ تا ۲۰۱۰ را با استفاده از داده‌های ماهانه برای پیش بینی قیمت طلا را مورد بررسی قرار داد.وی از روش تحقیق باکس–جنکینز برای ساختن مدل‌های آریما استفاده کرد. در این تحقیق ابتدا از داده‌های دوره ۱۹۷۱ تا ۲۰۰۸ برای تخمین مدل آریما استفاده کردند. نتیجه تحقیق نشان داد که میانگین موزون با P و q یک (یعنی (۱و۱) MA) مدل مناسبی برای قیمت طلا است. سپس، از این مدل برای پیش بینی دوره ۲۰۰۹ تا ۲۰۱۰ استفاده شد. همچنین نتایج نشان داد که مدل قارچ با P و q یک (یعنی (۱و۱) GARCH) نیز مدل مناسبی برای پیش بینی قیمت طلا است.

فرناندز[2] (۲۰۰۵) به بررسی پیش بینی قیمت کالای نفت خام و قیمت گاز پرداخته است. وی در این تحقیق خود از مدل شبکه هوش مصنوعی، مدل برداری و ARIMA برای پیش بینی استفاده نمود. نتایج تحقیق وی نشان داد که برای دوره‌های پیش بینی کوتاه مدت (یعنی ۲ تا ٤ روز) مدل ARIM بهنر است.

مطالعات اخیر پیشنهاد می‌کنند که استراتژیهای انتقالی بر مبنای پیش بینی‌های جهت از نوسانهای سطح قیمت مؤثرتر هستند. و می‌توانند فواید بیشتری نسبت به استراتژیهای یک پیش بینی سطح قیمت خاص ارائه دهند. با در نظر گرفتن این، تمرکزها بر پیش بینی

[1] Lin (2010)
[2] Fernandes(2005)

تغییرات قیمت طلا است به جای اینکه بر سطح خود قیمت باشد. لذا، به منظور ارزیابی مدل‌های شبکه‌ای عصبی و ظرفیت پیش بینی، ما بارها محاسبه می‌کنیم تا مدل صحیح را پیش بینی کنیم. با دنبال کردن این طرز فکر، لیونگ و همکاران (۲۰۰۰) ظرفیت پیش بینی مدل‌های دسته بندی[1] را با مدل‌ها سطح برآورد[2] مقایسه کردند و نتیجه گرفتند که قبلی[3] کارائی بهتری نسبت به دومی دارد. اوکونر و همکاران (۱۹۹۷) از فایده پیش بینی جهت در تغییرات قیمتی نسبت به سطوح قیمت حمایت کردند. به علاوه، هودگسون، نیکولز(۱۹۹۱) ارزیابی اقتصادی از پیش بینی جهت تغییرات در قیمت‌ها و نه در سطوح را پیشنهاد کردند. هلسترون و هلترون (۱۹۹۸) تعداد زیادی از ویژگی‌های خاص سری‌های زمانی و روندهای قیمت را بر شمردند. اگر چه زمانیکه با هم مقایسه می‌شوند منحصر بفرد نبودند و با هم پیش بینی غیر معمولی برای موارد خاص با ایجاد یک سیستم پیش بینی می‌باشند.

این روند ظاهرا بیشتر شبیه به روند پردازش گام تصادفی است که الگوهایی را برای تغییر زمان به زمان ارائه می‌دهد. به علاوه، این روند از نظر زمانی ظاهرا متغیر می‌باشد و سطوح صدا (NOISE) و ناپایداری را بعنوان جهش‌های بازار سهام در خارج از دوره‌های مربوطه نشان می‌دهد.

تحت این الگو یک شیوه جدید مدل دهنده مورد نیازی باشد، شیوه‌ای که بتوان برای پیش بینی به کار برده شود، حداقل در یک دوره کوتاه مدت و جائیکه مدل‌های غیر خطی نظیر شبکه‌های عصبی بتوانند پیش بینی‌های موفقیت آمیزی به بار آورند. هربیرچ و همکاران (۲۰۰۰) نشان دادند که مهم ترین ویژگی‌های شبکه‌های عصبی ظرفیت آنها برای یادگیری توابع غیر خطی بر مبنای تعداد محدودی از مشاهدات می‌باشد. این بدین معنی است که شبکه تنظیماتی از داده‌های آموزشی به همراه دارد، که بعدا به نمونه‌های جدید منتقل می‌شوند. به محض اینکه شبکه ها، آموزش دوباره به لایه‌های میانی را آغاز کردند، آنها یاد می‌گیرند که ویژگیهای مختلف مجموعه آموزشی را تشخیص دهند. استفاده از شبکه‌های عصبی در پیش بینی قیمت طلا کار جدیدی نمی‌باشد. مک کان و کالمن

[1] Linear discriminant analysis , logit model , probit model and probabilistic neural network
[2] Adaptive exponential smoothing , vector autoregression with Kalman filter . multivariate transfer function and multilayered feed or ward neural network.
[3] Which were proposed to predict the sign of the direction of the return of the stock exchange indices S&P500 , FTSE100 and Nikkei 225.

(۱۹۹٤) تلاشی به منظور استفاده از شبکه‌های عصبی برای تشخیص نقاط تورم در بازار طلا بر مبنای داده‌های تاریخی ده شاخص انجام دادند که پیش بینی هایی با معنا و مفید برای دوره مطالعه شده به همراه داشتند. اخیرا، مک میلان(۲۰۰۰)، برآورد متناوب و برگشتی را به کاربرد دو مدرکی از تابع غیرخطی STAR در DJIA یافت. به علاوه، پارامترهایی از بهره وابستگی موقتی را نشان می‌دهند. این نتایج می‌گویند که غیر خطی یک ویژگی داده هایی است که باید مدل بندی شوند و در پیش بینی به کاربرده شوند، اگر چه تغییرات در ارزش‌های پارامتری ممکن است نیاز به مشارکت و همکاری داشته باشند. چن ولونگ (۲۰۰۰) یک ارزیابی از معماری‌های شبکه عصبی بروی پیش بینی روابط ارز خارجی، در مقایسه با کارایی مدل‌ها بر مبنای معماری شبکه عصبی و شبکه چند لایه تغذیه‌ای (MLFN) و شبکه عصبی رگوسیون عمومی (GRNN) انجام دادند. ارزیابی اولیه آنها قدرت مدل‌های شبکه‌ای را در پیش بینی رابطه تغییر با توجه به تنوع آزمایشات آماری نشان دادند. نتایج این آزمایشات می‌گویند که انتخاب طراحی معماری مناسب ممکن است مستقیما به موفقیت در پیش بینی شبکه عصبی کمک کند.

لیاو همکاران (۲۰۰٦) یک مدل اقدام جمعی آمیخته برای تلفیق شبکه عصبی و ساده کردن مراحل آزمایشی ارائه دادند. مدل مطرح شده ویژگی‌های خطی یک مدل ساده تصاعدی و الگوهای غیر خطی شبکه عصبی را برای ایجا مدل تلفیقی با تکنیک برنامه نویسی خطی را ارائه می‌دهد.

توزیع بررسی‌ها در تحقیق مربوط به شبکه‌های متناوب و برگشتی وجود دارد و بعنوان یک اصلاح شبکه‌های عصبی سنتی شبیه به موارد به کار رفته توسط مک کان و کالمین(۱۹۹٤) و پیش بینی این استراتژیهای برگشتی و متناوب جدید برای پیش بینی تغییرات قیمت طلا می‌باشد. نتایج (AIC) با مدل ARIMA سنتی مقایسه می‌شوند و با استفاده از ملاک اطلاعات آکائیک انتخاب می‌شوند.

در نهایت بطور خلاصه، یکی از معماری‌های متفاوت شبکه‌های عصبی به کار رفته از این بررسی، این است که شبکه‌های متناوب به خوبی شبکه هایی با یک عملکرد برگشتی از ظرفیت پیش بینی می‌باشند. در مورد تغییرات قیمت طلا، ارزیابی مجدد میانگین‌های شبکه بر مبنای یک اصل دوره به دوره ضروری است یعنی آموزش اولیه باید شاخص

اطلاعاتی درباره تمامی تنظیمات ممکنی باشند که شبکه در آینده خواهد داشت. بر طبق مراحل آزمایشی DA، شبکه متناوب برای یک نمونه با ۲۹ مشاهده، ظرفیت پیش بینی بالایی را در شرایط آماری برآورد کرد و به بهترین کارایی پیش بینی رسید. لذا، پیش بینی شبکه‌های پویا متناوب است و آنها را بعنوان یک جایگزین برای بررسی تکنیکی و تکنیک‌های قراردادی پیش بینی سری‌های زمانی نظیر مدل‌های AR/MA قرار می‌دهد.

لذا استفاده از مدل‌های عصبی متناوب می‌تواند ظرفیت پیش بینی نوسانات در قیمت طلا را بهبود بخشد که سبب افزایش برگشتی و کاهش ریسک نقل و انتقال این فلز می‌شود. با فرض این نتایج ما می‌توانیم نتیجه بگیریم که این تکنیک می‌تواند در هر طرح اقتصادی استفاده شود و استفاده آنرا در پیش بینی حمایت طلا معتبر می‌سازد.

فرهاد رمضان (۱۳۷۹) به بررسی رفتار قیمت در بازار سلف طلای تهران می‌پردازد. در این مقاله نتایج و آزمون‌های انجام شده در بازار سلف طلای تهران نشان می‌دهد که رفتار قیمتی در بازار نیمه متشکل سلف رقابتی طلای تهران رفتار قیمتی شبیه به آنچه که در بازارهای متشکل سلف پیش بینی شده دارد.

محمد قوام زاده (۱۳۷٦) به پیش بینی در بازارهای سازمان یافته معاملات پرداخته است. وی در این تحقیق به پیش بینی شاخص بورس اوراق بهادار تهران، قیمت سهم در بورس، قیمت جهانی نفت و قیمت جهانی طلا پرداخته است. در این تحقیق از مدل شبکه عصبی‌ای که تعداد لایه‌ها و نرون‌های مشخص و از قبل تعیین شده‌ای دارد، برای پیش بینی متغیرهای ذکر شده استفاده شده است.

محمد باقر عبدالعلی زاده (۱۳۸٤)، به بررسی امکان سنجی بکارگیری قرارداد آتی روی اوراق مالی در بازار بورس اوراق بهادار ایران پرداخته است. این تحقیق با مفروض دانستن امکان بکار گیری قرارداد آتی در بازار سرمایه ایران از لحاظ شرعی با توجه به تحقیقات قبلی، به امکان سنجی بکارگیری این ابزار مالی جدید با توجه به ساختار بورس اوراق بهادار تهران و استقبال سرمایه گذاران پرداخته است.

سعید علی احمدی و مجید احمدلو (۱۳۹۰) به بررسی پیش بینی قیمت قراردادهای آتی سکه طلا در بورس کالای ایران پرداخته است. در این تحقیق از روش باکس- جنکینز برای بررسی توانایی پیش بینی قیمت آتی قراردادهای سکه استفاده شده. نتایج تحقیق نشان

داد که برای دوره مورد بررسی، مدل آریما (ARIMA) با دو وقفه خودرگرسیونی و ۲ وقفه میانگین متحرک برای پیش بینی قیمت قرارداد آتی سکه طلا مدل مناسبی است و توانایی پیش بینی قیمت قرارداد آتی سکه را دارد.

۳-معرفی مدل و برآورد الگو

مبنای ریاضی الگوریتم GMDH

فرض کنید مجموعه‌ای از m متغییر شامل $x_1,x_2,\ldots,x_m$ و یک متغیر y وجود دارد. داده‌های مربوط به هر کدام از x_iها 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.[1] اطلاعات اولیه‌ای که جهت ساخت الگوریتم GMDH باید جمع‌آوری گردد، مجموعه‌ای از n مشاهده است که در ماتریس زیر نشان داده شده است:

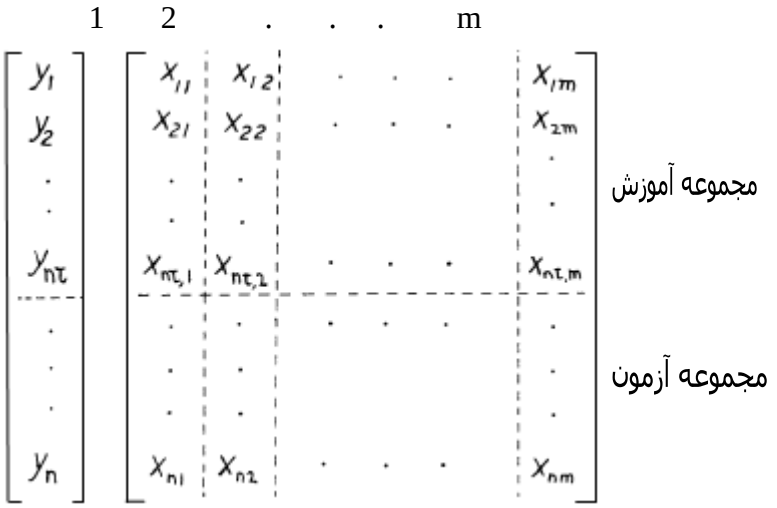

متغیرهای ورودی به الگوریتم GMDH [2]

[1] Madala, H.R., & Ivakhnenko, A.G.; "Inductive learning algorithms for complex system modeling".

[2] Farlow, S. J.; "The GMDH Algorithm of Ivakhnenko"; The American Statistician, vol.35, No.4, 1984, pp.210-215.

برای شروع به کار الگوریتم با دو مسئله مواجه هستیم: ۱) تشخیص رابطه‌ای که متغییر خروجی را براساس متغییرهای ورودی(x_i ها) تولید کند. ۲) پیش بینی y به ازای مقادیر معلوم x_i ها. به عبارتی نیاز به تشخیص مدل و رابطه بین متغییرها می‌باشد(مدل سازی) که سپس بتوان از روی آن مدل، مقادیر آتی متغییر هدف را پیش بینی کرد(پیش بینی).

مبنای الگوریتم GMDH عبارت از فرآیندی جهت ساخت یک چند جمله‌ای با مراتب بالا است که به سری تابع ولترا[1] معروف است و به شکل زیر ارائه می‌گردد:(این چند جمله‌ای را ایواخننکو نیز می‌نامند.)

$$\hat{y} = \alpha_0 + \sum_{i=1}^{m} a_i\ x_i + \sum_{i=1}^{m}\sum_{j=1}^{m} a_{ij}\ x_i x_j + \sum_{i=1}^{m}\sum_{j=1}^{m}\sum_{k=1}^{m} a_{ijk}\ x_i x_j x_k + \ldots \qquad (۱-۳)$$

برای این منظور در الگوریتم GMDH ابتدا به تجزیه سری توابع ولترا به چندجمله‌ای‌های دومتغیره درجه دوم می‌پردازیم.

$$G(x_i, x_j) = a_0 + a_1 x_i + a_2 x_j + a_3 x_i^{\,2} + a_4 x_j^{\,2} + a_5 x_i x_j \qquad (۲-۳)$$

در این تجزیه، سری ولترا به مجموعه‌ای از معادلات بازگشتی زنجیره‌ای تبدیل می‌گردد، به‌گونه‌ای که مجدداً با جایگذاری جبری هریک از روابط بازگشتی در این رابطه (سری ولترا)، برقرار می‌گردد. رابطه

$$y_i = f(x_{i1}, x_{i2}, x_{i3}, \ldots, x_{im}); \quad i = 1, 2, 3, \ldots, n \qquad (۳-۳)$$

توسط تابع $\hat{f}$ تقریب زده می‌شود:

$$\hat{y}_i = \hat{f}(x_{i1}, x_{i2}, x_{i3}, \ldots, x_{im}); \quad i = 1, 2, 3, \ldots, n \qquad (۴-۳)$$

و در صورتی که تابع $\hat{f}$ به‌صورت زیر بیان شود:

$$\hat{y} = \alpha_0 + \sum_{i=1}^{m} a_i\ x_i + \sum_{i=1}^{m}\sum_{j=1}^{m} a_{ij}\ x_i x_j + \sum_{i=1}^{m}\sum_{j=1}^{m}\sum_{k=1}^{m} a_{ijk}\ x_i x_j x_k + \ldots \qquad (۵-۳)$$

در این صورت رابطه $\hat{f}$ را می‌توان به‌فرم زیر تجزیه نمود:

[1] Volterra Functional Series

$$
\begin{array}{llll}
\hat{y}_k = G(u_i, u_j) & i,j = 1,2 (i \neq j) & & k = 1 \\
u_k = G(s_i, s_j) & i,j = 1,2,K,F_1 (i \neq j) & F_1 \leq C_{F_2}^2 & k = 2 \\
s_k = G(p_i, p_j) & i,j = 1,2,K,F_2 (i \neq j) & F_2 \leq C_{F_3}^2 & k = 3 \\
\vdots & & & \\
z_k = G(w_i, w_j) & i,j = 1,2,K,F_l (i \neq j) & F_l \leq C_m^2 & k = F_{l-1} \\
w_k = G(x_i, x_j) & i,j = 1,2,K,m (i \neq j) & & k = F_l
\end{array}
\qquad (۶-۳)
$$

همان‌گونه که در معادلات بالا مشاهده می‌شود، ترتیب روابط فوق از بالا به پایین، نمایی از پروسه تجزیه رابط(٤-۳) به چندجمله‌ای‌های درجه دوم بوده و از طرفی نیز ترتیب این روابط از پایین به بالا بیانگر تکمیل رابطه(٤-۳) توسط معادلات بازگشتی می‌باشد. در واقع هدف این الگوریتم یافتن ضرایب مجهول a در سری توابع ولترا می‌باشد.

۳-۱ روش تخمین شبکه GMDH

مرحله اول: ساخت متغیرهای جدید

اولین مرحله شامل ساخت متغیرهای جدید $(Z_1, Z_2, ..., Z_{\binom{m}{2}})$ است که بسیار ساده می‌باشد. تمام متغیرهای مستقل x را به صورت زوجهای مرتب در یک مرحله زمانی انتخاب می‌کنیم و برای هر ترکیب $\binom{m}{2}$ حداقل مربعات چندجمله‌ای زیر را برآورد می‌نماییم که بهترین برآوردهای y در مجموعه آموزش دهنده را در بر دارد.

$$y = A + Bu + Cv + Du^2 + Ev^2 + Fuv \qquad (۱-۱-۳)$$

به این مفهوم که ما آن $\binom{m}{2} = \frac{m(m-1)}{2}$ صفحات چندجمله‌ای را که در شکل زیر نشان داده شده است می‌یابیم.

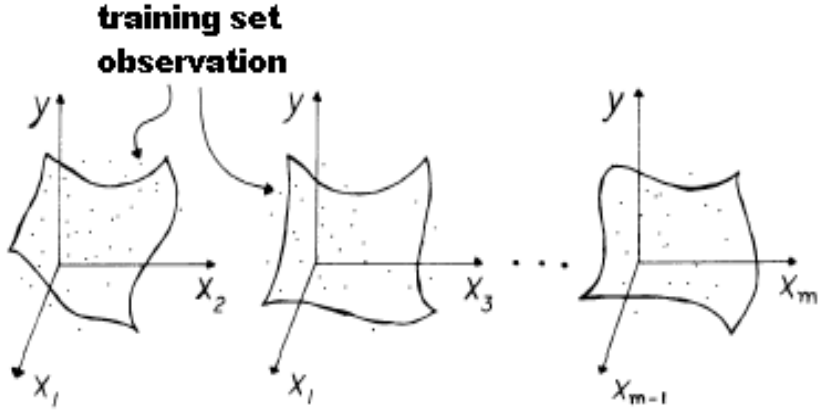

شکل: ساخت متغیرهای جدید

حال برای هر $\binom{m}{2}$ صفحه در شکل بالا، مقدار عددی چندجمله‌ای را برای n داده به دست می‌آوریم. برای مثال، برای اولین صفحه‌ای که در بالا عنوان شده است، مقدار عددی

$$z = A + Bx_1 + Cx_2 + Dx_1^2 + Ex_2^2 + Fx_1x_2 \qquad (۲-۱-۳)$$

را به ازای زوجهای مرتب حاصل از دو ستون اول x، یعنی(x_{11},x_{12})، (x_{21},x_{22})،...، (x_{n1},x_{n2}) به دست آورده و این n مقدار را در اولین ستون بردار Z (متغیر جدید) ذخیره می‌نماییم.

$\binom{m}{2}-1=\frac{m(m-1)}{2}-1$ ستون باقیمانده نیز به شکل مشابه تولید می‌شوند. بنابراین ستون Z را به عنوان $\binom{m}{2}$ مشاهده از متغیرهای جدید $(Z_1, Z_2,..., Z_{\binom{m}{2}})$ در نظر می‌گیریم که هر یک از این متغیرهای جدید حاصل یک چندجمله‌ای از متغیرهای اصلی $x_1, x_2, \ldots, x_m$ می‌باشد. به عبارت دیگر، ما متغیرهای جدیدی ساخته ایم که جایگزین

متغیرهای اصلی اولیه شده اند. هدف آن است که آن Z_iها که بهترین برآوردکننده بردار y هستند را نگهداشته و مابقی را حذف کنیم.

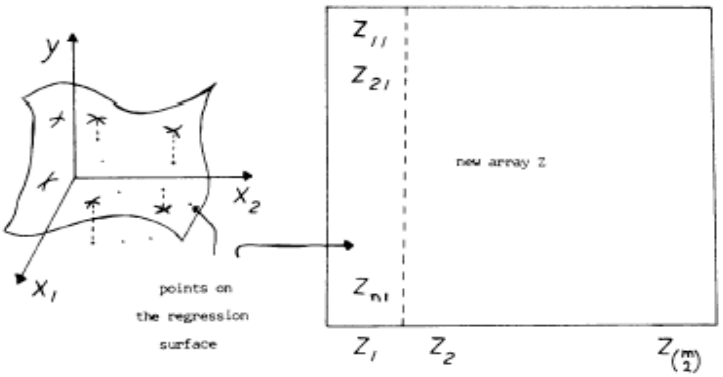

شکل: ساخت بردار جدید **Z**

مرحله دوم: غربال کردن Z هایی که مهم نیستند

در این مرحله ستونهای x را با ستونهای Z که بهترین پیش بینی از بردار y مشاهده شده را ارایه می‌دهند، جایگزین می‌نماییم. به عبارت بهتر در این مرحله برای هر ستون j ام بردار Z، حداقل مربع خطای d_j را به صورت زیر محاسبه می‌کنیم.

$$d_j^{\,2} = \sum_{i=nT+1}^{n} (y_i - Z_{ij})^2 \qquad j = 1,2,\ldots,\binom{m}{2} \qquad (۳-۱-۳)$$

ستونهای Z را بر اساس افزایش حداقل مربع خطاهای d_j مرتب می‌کنیم و سپس ستونهایی را که برای آنها $d_j < M$ (M مقداری از پیش تعیین شده است) می‌باشد را جانشین ستونهای X می‌نماییم. این ستونهای Z متغیرهای جدید X می‌باشند. توجه به این نکته ضروری است که تعداد این ستونهای جانشین جدید- که آن را m_1 می‌نامیم، ممکن است بزرگتر و یا کوچکتر از تعداد متغیرهای قبلی که در اصل m تا بوده، باشد. همچنین توجه کنید که حداقل مربعات خطای d_j روی مشاهدات کنترل کننده جمع می‌شوند.

مرحله سوم: آزمون همگرایی

از مرحله قبل کوچکترین d_jها را انتخاب کرده و DMIN می‌نامیم که نمودار آن در شکل زیر مشاهده می‌گردد. در هر مرحله اگر مقدار DMIN کمتر از DMIN مرحله قبل باشد آنگاه به مراحل ۱ و۲ برگشته و آن را تکرار می‌کنیم. ولی اگر مقدار DMIN بزرگتر از DMIN قبلی آن باشد، فرآیند را متوقف نموده و نتایج به دست آمده برای مینیمم مقدار DMIN را مورد استفاده قرار می‌دهیم.

میانگین مربع خطا به عنوان تنها معیار مورد استفاده در رگرسیون استاندارد می‌باشد. بنابراین امکان اینکه از طریق آن ثابت کنیم مدل بسیار ساده و یا خیلی پیچیده است، وجود ندارد. در حالیکه با اعمال آزمون چندجمله‌ای ایواخننکو می‌توانیم به یک چندجمله‌ای "بهینهٔ پیچیدهٔ" واحد برسیم.

اگرچه الگوریتم GMDH به ما اجازه نمی‌دهد ثابت کنیم نمودار DMIN تنها یک مقدار می‌نیمم مطلق دارد، اما تمام نتایج تجربی نشانگر درست بودن این مسئله است. طبیعت کلی نمودار DMIN به گونه‌ای است که ابتدا به سمت یک نقطه می‌نیمم، نزولی و پس از آن صعودی می‌شود.

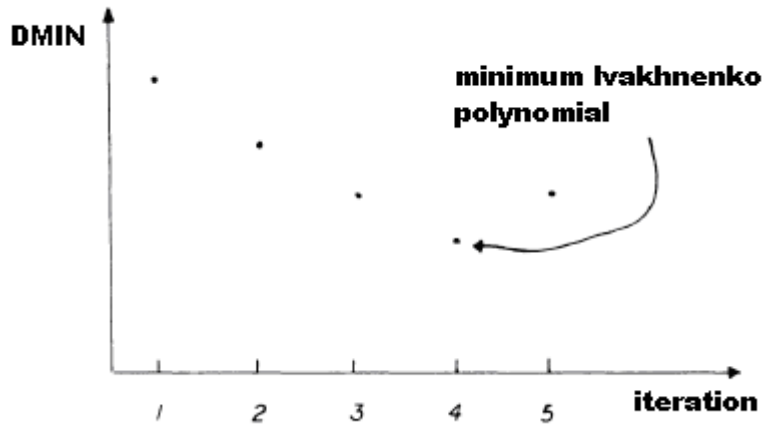

شکل: همگرایی

برای مثال در شکل بالا، پس از ۵ مرتبه تکرار، فرآیند را متوقف می‌نماییم. این پایان الگوریتم ایواخننکو است و در مجموع مراحل عملیات الگوریتم GMDH را می‌توان در شکل زیر نشان داد:

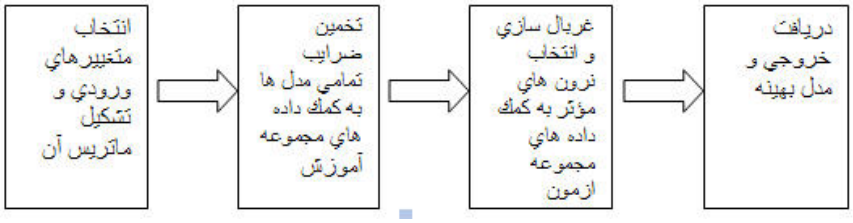

شکل: مراحل عملیات الگوریتم[1] GMDH

۱-۱. نتایج حاصل از الگو و تحلیل محاسبات

مدل مذکور را با استفاده از داده‌های روزانه از سال ۱۳۸٦الی ۱۳۸۹ برآورد می‌نمائیم. همانطور که توضیح داده شد، در این روش با استفاده از قابلیت غربال‌سازی الگوریتم GMDH طی چند مرحله به غربال‌کردن متغیرهای کم‌اثرتر پرداخته و نهایتاً مدل پیش‌بینی نهایی را از این طریق استخراج کرده و با مدل بدست آمده اقدام به پیش‌بینی قیمت سکه طلا می‌نماییم.

متغیرهای الگو

با توجه به مبانی نظری و پیشینه پژوهش و متغیرهای کلیدی اقتصاد کلان ذکر شده در این مقاله، در این تحقیق برای برآورد الگو از متغیرهای ارائه شده در زیر استفاده گردیده است.

متغیرهای کلیدی اقتصاد کلان بکار رفته در پیش‌بینی قیمت سکه طلا در بورس کالای ایران عبارتند از: قیمت طلا به دلار، شاخص قیمت کل بورس، نرخ ارز دلار به ریال، قیمت نفت به دلار، تاریخ روز تحویل، قیمت آتی سکه.

FUTURE/RIAL= F (TEPIX, USD/RIAL,GOLD/USD, SEKE/RIAL, DAY TO DELIVER, WIT/USD)

[1] Madala, H.R., & Ivakhnenko, A.G.; "Inductive learning algorithms for complex system modeling"

تخمین مدل

باید به این نکته توجه کرد که در برآورد مدلها به روش شبکه عصبی در بیشتر آن‌ها تعداد لایه‌ها و نرون‌های شبکه از قبل مشخص می‌شود ولی در صورتیکه روش‌ای که در این مقاله از آن استفاده شده و در خروجی جدول زیر هم آمده، روش GMDH است که یک روش الگوریتم ژنتیک است(یک روش پویا) بدین معنی می‌باشد که قابلیت شناسایی و غربال کردن متغیرهای کم اثر ورودی در دوره آموزش شبکه و حذف آن‌ها از روند شبیه سازی در دوره آزمون می‌باشد.بدین ترتیب می‌توان با انجام یک فرآیند قیاسی، در چند مرحله تکرار، متغیرهای کم اثرتر را حذف نمود و نهایتا مدل بهینه برای پیش بینی را براساس معیار خطا مانند RMSEو درصد خطای پیش بینی بدست آورد.

در این روش با توجه به قابلیت الگوریتم GMDH در غربال‌سازی و تشخیص روندهای غیرخطی، از یک شبکه عصبی GMDH بر اساس یک الگوی متشکل از ۷ متغیر به عنوان ورودی به شرح (بالا) استفاده می‌کنیم. نتایج حاصل از برازش متغیرهای الگو بر روی متغیر هدف توسط شبکه عصبی GMDH به شرح جدول زیر می‌باشد، که برای داده‌های روزانه بطور جداگانه تخمین‌زده شده است.

جدول: نتایج حاصل از خروجی شبکه عصبی GMDH برای داده‌های روزانه

متغیرهای حذف‌شده	ندارد
متغیرهای مؤثر	USD/RIAL و DAY TO DELIVER و TEPIX WIT/USD و FUTURE/RIAL و GOLD/USD و SEKE/RIAL
متغیرهای با اثر مضاعف	USD/RIAL و DAY TO DELIVER
MSE[1]	0.0002
RMSE[2]	0.01414
MAPE[3]	0.012905
درصد خطای پیش‌بینی	0.019
درصد دقت پیش‌بینی	99.98096

[1] Mean Square Error
[2] Root Mean Square Error
[3] Mean Absolute Percentage Error

همان‌طور که قبلا نیز توضیح داده شد، یکی از مهم‌ترین ویژگی‌های الگوریتم GMDH توانایی شناسایی و حذف متغیرهای زاید است. بدین ترتیب متغیرهایی که در جریان مدل‌سازی اثر کمتری داشته و یا بدون تأثیر بر متغیر هدف هستند، از الگو حذف می‌شوند. این متغیرها در ردیف اول جدول فوق مشخص گردیده‌اند. همان‌طور که ملاحظه می‌گردد، هیچ متغیری در فرآیند مدل‌سازی از الگو حذف نگردیده است.

در مقابل متغیرهای نرخ ارز دلار به ریال و تاریخ روز تحویل دارای اثر مضاعف[۱] بوده‌اند. بعلاوه، ردیف‌های چهارم تا هشتم جدول فوق، معیارهای اندازه‌گیری خطای پیش‌بینی در مرحله آزمون[۲] شبکه عصبی را تعیین می‌کنند. مقادیر معیارهای خطا، نشان‌دهنده دقت بالا و صحت پیش‌بینی توسط شبکه عصبی GMDH می‌باشند. نمودار زیر مقادیر واقعی و پیش‌بینی شده قیمت سکه طلا در بورس کالای تهران توسط شبکه عصبی GMDH را نشان می‌دهد.

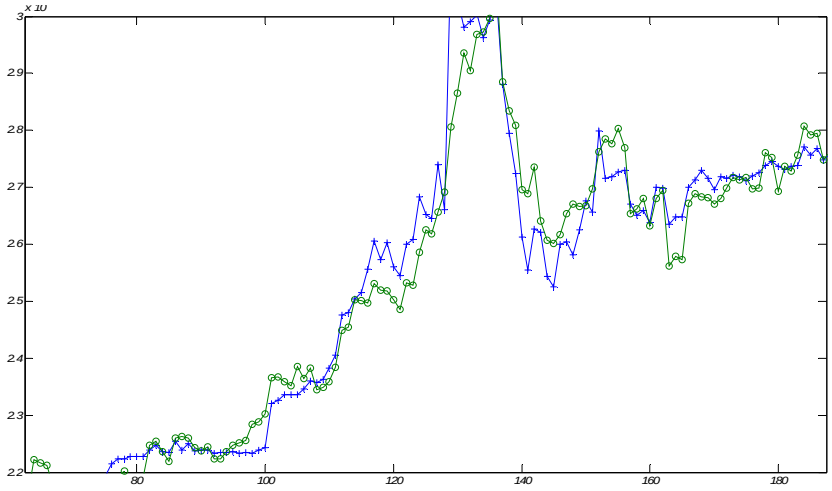

نمودار۳-۱: مقادیر واقعی و پیش بینی شده قیمت سکه طلا در بورس کالای ایران برای داده‌های روزانه

[۱] متغیرهای با اثر مضاعف برای ورودی ها در ادبیات شبکه عصبی GMDH ، معنای متفاوتی با تحلیل های رگرسیونی دارد و به متغیری که تعداد تکرار بیشتری نسبت به سایر متغیرها در خروجی برنامه شبکه داشته، یا بتواند از یک لایه پنهان پرش کند، اطلاق می شود.

[2] Testing

همانطور که در شکل دیده می‌شود خط آبی رنگ مقادیر اصلی می‌باشند و خط سبز رنگی که دوایر را به هم متصل می‌کند مقادیر پیش بینی را نشان می‌دهد، به عبارت دیگر علامت " O" مقادیر پیش بینی وعلامت + مقادیر اصلی را نشان می‌دهد.

٤- نتیجه گیری

نتایج حاصل از خروجی نشان می‌دهد که هیچ متغیری در ورودی به سیستم شبکه عصبی GMDH کم‌اثر نبوده و لذا در فرآیند

شبیه‌سازی مدل GMDH هیچ متغیری حذف نگردیده است. بدین ترتیب معیارهای سنجش ارائه‌شده در جدول فوق بدست آمده‌اند. در مقابل، متغیرهای نرخ ارزدلار به ریال وتاریخ روز تحویل، دارای اثر مضاعف در برازش مدل بوده‌اند.

نتایج بدست‌آمده حاکی از دقت بسیار بالا و قابلیت فوق‌العاده الگوریتم GMDH در پیش‌بینی قیمت سکه طلا می‌باشد، بطوریکه خطای حاصل از پیش‌بینی قیمت سکه طلا برای داده‌های روزانه، **۰،۰۱۹** می‌باشد.

همان‌طور که ملاحظه می‌شود خطا و درصد دقت پیش‌بینی حاصله در مقایسه با روش‌های متعارف اقتصادسنجی بسیار مقبول بوده و لذا نشان‌دهنده قدرت بسیار بالای مدل شبکه عصبی GMDH در پیش‌بینی می‌باشد.

در مجموع علت این امر را می‌توان در روش بکار رفته و نحوه شبیه‌سازی انجام‌شده توسط الگوریتم GMDH جستجو کرد. از آنجائیکه عوامل مؤثر بر پیش‌بینی قیمت سکه طلا دارای ابعاد و پیچیدگی‌های زیادی می‌باشد، و همه متغیرهای یاد شده سهمی را در کاهش خطای پیش بینی ایفا می‌کنند، استفاده از الگوریتم GMDH سبب شده است که بتوان تمامی عوامل مؤثر را در کنار یکدیگر و ارتباطات آنها را به صورت غیرخطی و حتی با مراتب بالا در فرآیند پیش‌بینی قیمت سکه طلا در بورس کالای ایران دخیل نمود.

بطوریکه در این راستا، بر اساس مدل مذکور که حاصل فرآیند قیاسی الگوی GMDH می‌باشد، متغیرهای مختلف در رقابت با یکدیگر برای پیش‌بینی قیمت سکه طلا ارزیابی گردیده و ضمن دادن فرصت‌های برابر به همه آنها در فرآیند پیش‌بینی، در یک پروسه تکاملی اصلاحی همانند آنچه در فرآیندهای طبیعی اصلاح ژنتیک دیده می‌شود، به حذف

عوامل کم‌اثرتر و بهبود عوامل تاثیرگذار و نهایتاً شناسایی عوامل مؤثرتر که اصطلاحاً دارای اثر مضاعف بر متغیر هدف هستند، می‌پردازیم. بنابراین می‌توان علل و عوامل مؤثر در پیش‌بینی قیمت سکه طلا در بورس کالای ایران را به طور ویژه‌ای در تقابل و رقابت با یکدیگر در یک سیستم غیرخطی که دارای ابعاد گوناگون و گسترده‌ای است، تبیین نمود.

لذا از پیشنهاداتی که می‌توان در این مقاله ارائه نمود، علاوه بر گسترش استفاده از روش‌های پیش‌بینی غیرخطی نظیر مدل‌های شبکه عصبی مصنوعی و استفاده از مزیت‌های آنها در مقایسه با روش‌های متعارف اقتصاد سنجی سری‌های زمانی نظیر مدل‌های ARIMA و غیره، استفاده از این الگوها به عنوان مبنای تحلیل‌های قیاسی است که می-تواند به عنوان موضوعات جدید در مطالعات بعدی تعقیب گردد

منابع و مآخذ فارسی

۱) فرهاد رمضان، "بررسی رفتار قیمت در بازار سلف طلای تهران"، پایان نامه کارشناسی ارشد موسسه عالی پژوهش در برنامه ریزی و توسعه در مهندسی سیستمهای اقتصادی و اجتماعی، به راهنمایی دکتر سید احمد رضا جلالی نائینی، بهمن ۱۳۷۹.

۲) محمد قوام زاده، "پیش بینی در بازارهای سازمان یافته معاملات"، پایان نامه کارشناسی ارشد دانشگاه تهران گروه مهندسی برق و کامپیوتر، به راهنمایی دکتر کارولوکس، پاییز ۱۳۷۶

۳) کدخدایی، حسین؛ " مبانی مقررات بازار سرمایه"؛ بیمه مرکزی یاران، (۱۳۷۸).

۴) جکسون، تی. و بیل آر. (۱۳۸۰). آشنایی با شبکه‌های عصبی مصنوعی، ترجمه محمود البرزی، تهران موسسه انتشارات علمی

۱) سرفراز، لیلا (۱۳۷۴). "بررسی ارتباط طلا، دلار و حق برداشت مخصوص در منظری تاریخی" مجله دانشکده علوم اداری و اقتصادی دانشگاه فردوس مشهد، شماره۳.

۲) محمدی، تیمور و تقوی، مهدی و برزنده، محمد؛ "بررسی متغیرهای اقتصادی اثرگذار بر شاخص قیمت سهام بورس اوراق بهادار تهران"؛ مجله برنامه و بوجه، شماره ٤٠ و ٤١، (۱۳۷۸).

۳) بت شکن، محمد هاشم. شناخت قراردادهای آتی و اختیارات معاملات و ارائه الگویی جهت راه اندازی بازار آن‌ها در ایران، رساله کارشناسی ارشد دانشگاه تهران.۱۳۷۷

۴) آرام محمد، امکان سنجی راه اندازی بورس آتی نفت در جمهوری اسلامی ایران، با دو رویکرد فقهی و مالی و اقتصادی. رساله کارشناسی ارشد دانشگاه امام صادق(ع). ۱۳۸۲

۵) فرآیند اجرایی معاملات بورس کالا (معاملات آتی)، شرکت بورس کالای ایران، آبان ۸۶ امید نامه پذیرش و درج قراردادهای آتی سکه بهار آزادی در شرکت بورس کالای ایران، آبان ۸۷.

منابع و مآخذ انگلیسی

6) Anastasakis, L., & Mort, N.; “The Development of Self-organization Techniques in Modeling: A Review of the Group Methods of Data Handling (GMDH)”; Department of Automatic Control & Systems Engineering The University of Sheffield, Mappin St, Sheffield, No. 813, 2001.
7) Farlow, S. J.; “The GMDH Algorithm of Ivakhnenko”; The American Statistician, vol.35, No.4, 1984, pp.210-215.
8) O'connor, M., & Madden, M.G.;"A Neural Network Approach to Predicting Stock Exchange Movements Using External Factors"; National University of Ireland, Galway, University Road, Galway, Ireland, 2006, pp.371-378.
9) Pesaran, M.H., & Shin, Y.; "An Autoregressive Distributed Lag Modeling Approach to Cointegration Analysis"; in (Ed) S. Strom, Econometrics and Economic Theory in the 20th Century: the Ragnar Frisch Centennial Symposium, Chapter 11, Cambridge University Press, Cambridge.1999
10) Phylaktis, k., & Ravazzolo, F.; "Stock Prices and Exchange Rate Dynamic"; Journal of International Money and Finance, 24, 2005, PP.1031 -1053.
11) Water, P.R., Wibier, S., Kerckhoffs, E.J.H., & Koppelaar, H.; "GMDH-based stock price prediction", Neural Network World, vol.7, No.4-5,1997, pp.552-563,
12) Ivakhnenko.A.G, Ivakhnenko.A.N, Kostenko.Yu.V,. Muller.J.A, Sarychev.A.P and Yurachkovskiy.Yu.P, “Nonparametric forecasting GMDH models, Part 3.Models in the pattern- and clusteranalysis language, for forecasting processes in economic macro-systems”, Soviet Journal of Automation and Information Sciences c/c of Avtomatika, vol.22, no.3, pp.1-14, 1989
13) O'connor, M. & G.Madden, M., (2006), "A Neural Network Approach to Predicting Stock Exchange Movements Using External Factors," National University of Ireland, Galway, University Road, Galway, Ireland, pp371-378
14) Goleusov, I.V., & Kondrasheva, S.A.; “Comparative analysis of the interdependence structure of the macro-economic indices of COMECON

member-countries by the group method of data handling"; Soviet Journal of Automation and information Sciences c/c of Avtomatika, vol.20, No.3, 1987,pp.39-43.
15) application to Bell 20 stock market Index", European Journal of Economic and social system, 14, No 1, PP. 81-91.
16) Models in the pattern- and clusteranalysis language, for forecasting processes in economic macro-systems", Soviet Journal of Automation and Information Sciences c/c of Avtomatika, vol.22, no.3, pp.1-14,
17) Pinches, G. E. (1970). "The Random Walk. Hypothesis and Technical Analysis", Financial Analysis Journal. (March- April 1970). PP. 104-110
18) R. A. Schwartz and D. K. Whitcomb (June 1977). "Evidence on the Presence and Causes of Serial Correlation in Market Model Residuals", Journal of Financial and Quantitative Analysis, PP. 291-313
19) RESCHER, N. (1998) Predicting the future: An introduction to the theory of forcasting. State University of New York Press
20) Robert J. & Van Eyden (1996). "The Application of Neural Networks in the Forecasting of Share Prices", Finance and Technology Publishing. PP. 47-72.
21) Serletin. A. and Shintani, M. (2003). "No evidence of chaos but some evidence of dependence in US stock market", Chaos, solitonis and fractals 17. PP. 449-459
22) Sounders, E. M. (1994). "Testing the efficient market Hypothesis without Assumptions", Journal of portfolio management, No 20 (4). PP. 28-30.
23) STATSOFT (2002) Time Series Prediction in ST Neural Network.