

فصلنامه‌ی مطالعات اقتصاد انرژی / سال پنجم / شماره‌ی ۱۹ / زمستان ۱۳۸۷ / صفحات ۲۲ - ۱

محاسبه‌ی هوشمند حداکثر درآمد در بازار پیش خرید و پیش فروش نفت خام

علی معینی

دانشیار گرایش الگوریتم‌ها و محاسبات دانشکده‌ی فنی دانشگاه تهران moeini@ut.ac.ir

محسن مهرآرا

دانشیار دانشکده‌ی اقتصاد دانشگاه تهران mmehrara@ut.ac.ir

مهدی احراری

پژوهشگر اقتصادی دانشکده‌ی اقتصاد دانشگاه تهران ahrari@ut.ac.ir


تاریخ دریافت: ۸۸/۴/۲۰ تاریخ پذیرش: ۸۸/۶/۲۱

چکیده

در این مقاله، از رویکرد هوشمند تلفیقی، مشتمل بر نوعی از شبکه‌ی عصبی موسوم به GMDH و الگوریتم ژنتیک و بهینه‌سازی چند منظوره، برای تحلیل قیمت پیش خرید و پیش فروش نفت خام به منظور محاسبه‌ی حداکثر درآمد حاصل از پیش‌بینی در روندهای مختلف بازار مبتنی بر قواعد تحلیل تکنیکی استفاده شده است. نتایج نشان می‌دهد که در بازه‌ی زمانی ۵ تا ۱۰ روزه برای دوره‌های مختلف، بازار عایدی مطلق به ۹۷٪ می‌رسد. هم‌چنین روند صعودی دارای بیش‌ترین عایدی و روند بی‌ثباتی توأم با تغییر، کم‌ترین عایدی را دارد.

طبقه بندی JEL: Q47, C14, C15, C45, C53, C67, G17

کلید واژه: شبکه‌ی عصبی GMDH، الگوریتم ژنتیک، نفت خام، بازار پیش خرید و پیش فروش، تحلیل تکنیکی، عایدی، بهینه‌سازی چند منظوره.



۱- مقدمه

هدف اصلی بورس بازان و معامله گران در بازار پیش خرید و پیش فروش نفت خام، دستیابی به حداکثر عایدی حاصل از پیش‌بینی روند تغییرات قیمت‌ها به عنوان سیگنال خرید و فروش است. بدین منظور دو مسئله‌ی مهم پیش روی معامله‌گران یا بورس بازان قرار می‌گیرد. اول این که هر اندازه دقت پیش‌بینی روند و مسیر قیمت‌های پیش خرید و پیش فروش بیشتر باشد، تصمیم‌گیری‌های معاملاتی صحیح‌تر و به تبع آن، عایدی حاصل از آن بیشتر خواهد بود. مسئله‌ی دوم پایداری مدل‌های پیش‌بینی و مسیر یابی روند قیمت‌هاست. به عبارت دیگر مدل‌های انتخابی باید از درجه‌ی اطمینان و توان بالایی در ارائه پیش‌بینی‌های دقیق طی دوره‌های مختلف بازار برخوردار باشند. روش تحلیل تکنیکی^۱ یک گام فراتر از روش‌های سنتی مذکور بوده و معیار معامله در بازار را تفاوت میانگین‌های متحرک کوتاه‌مدت و بلندمدت در نظر می‌گیرد. روش تحلیل تکنیکی بر پایه‌ی سه اصل اساسی استوار است، که این اصول در تمام بازارها صادق‌اند.

- همه‌ی ویژگی‌های هر دارایی در قیمت آن منعکس است.
- قیمت‌ها به صورت روندهایی حرکت می‌کنند که در مقابل تغییرات مقاوم‌اند.
- روندهای بازار تکراری‌اند.

یکی از متداول‌ترین قواعد تحلیل تکنیکی روش میانگین متحرک^۲ است که سری داده‌ها را هموار می‌کند و زمینه را برای پی‌گیری روندها فراهم می‌کند. میانگین‌های متنوعی از سوی پژوهشگران ارائه شده‌اند، که ساده‌ترین آن‌ها میانگین متحرک ساده است که در آن میانگین n داده به‌طور عادی و بدون هیچ‌گونه اعمال وزنی محاسبه می‌شود. میانگین‌ها در تجزیه و تحلیل فنی بازار نقشی اساسی و عمده دارند و براساس تئوری داو^۳، اولین اصل در بازار، مطالعه‌ی میانگین‌هاست. در حقیقت میانگین متحرک، یک ابزار یکنواخت‌کننده است، که با استفاده از میانگین قیمت‌ها ارقام بالا و پائین کنار هم گذاشته می‌شوند تا روند اساسی بازار به سادگی قابل تشخیص شود. یک میانگین متحرک کوتاه‌مدت مانند میانگین متحرک پنج روزه، عملکرد قیمت‌ها را با نزدیک‌تری

1 - Technical Analysis.

2 - Moving Average.

3 - Dow.

بیش‌تری نسبت به یک میانگین پنجاه روزه مورد مطالعه قرار می‌دهد و اصولاً میانگین کوتاه‌مدت نسبت به حرکت‌های روز به روز قیمت حساس‌تر است (میرزایی ۱۳۸۶).
مطالعات متنوعی در زمینه‌ی برتری شبکه‌های عصبی نسبت به روش‌های سنتی پیش‌بینی و مدل‌های تصمیم‌گیری در بازارهای مالی و پیش خرید و پیش فروش نفت انجام گرفته است. در این مقاله قصد داریم با استفاده از شبکه‌ی عصبی GMDH^۱ مبتنی بر قواعد تحلیل تکنیکی به عنوان ورودی شبکه، حداکثر عایدی حاصل از پیش‌بینی قیمت پیش خرید و پیش فروش نفت و بازه‌ی زمانی ایجاد کننده‌ی آن را طی دوره‌های مختلف بازار محاسبه کنیم.

در بخش ۲، مروری بر کارهای انجام گرفته در این زمینه خواهیم داشت. در بخش ۳، شبکه‌ی عصبی GMDH شرح داده شده است. بخش ۴، نتایج حاصل از محاسبه‌ی عایدی معاملات بر روی قیمت پیش خرید و پیش فروش نفت ارائه شده و بخش ۵ که در برگزیده‌ی نتیجه‌گیری است، پایان بخش مقاله خواهد بود.


۲- پیشینه‌ی تحقیقات

اولین بار تحقیقی توسط نفچی^۲ (۱۹۹۱) در زمینه‌ی قدرت پیش‌بینی قواعد تحلیل تکنیکی در مدل‌های خطی و غیرخطی انجام گرفت. او از روش تلفیقی شبکه‌های عصبی با قواعد تحلیل تکنیکی برای پیش‌بینی قیمت ماهانه‌ی نفت خام استفاده کرد، که نتایج بهتری را نسبت به روش‌های سنتی در برداشت. بروک و همکاران^۳ (۱۹۹۲)، علاوه بر حمایت از قواعد تحلیل‌های تکنیکی به عنوان متغیرهای ورودی، ضرورت به کارگیری مدل‌های غیرخطی را نیز پیشنهاد دادند. آن‌ها روش میانگین متحرک را بر روی یک قرن اطلاعات روزانه‌ی شاخص صنعتی داوجونز در بورس نیویورک مورد بررسی قرار داده و پی‌بردند که این قواعد منجر به کسب درآمد می‌شود. هم‌چنین سیگنال‌هایی که به وسیله‌ی این قواعد ایجاد شده‌اند، قادرند عایدی‌های غیرمعمول را در مقایسه با سایر استراتژی‌های متداول در بازار شناسایی کنند. آن‌ها میانگین متحرک‌هایی با طول ۵، ۱۰ و ۲۰ روزه را برای دوره‌ی کوتاه مدت و ۵۰، ۱۰۰ و ۲۰۰ روزه را برای دوره‌ی بلندمدت مورد بررسی قرار دادند و نتایج سودآوری را حتی با وجود در نظر

1 - Group Method of Data Handling.

2 - Neftci.

3 - Brock et al.



گرفتن هزینه‌های مبادله^۱ به دست آورند. جن کی^۲ (۱۹۹۶)، برای اولین بار از قواعد تحلیل تکنیکی به عنوان ورودی شبکه‌ی عصبی در بازارهای ارز خارجی استفاده کرد. در یک سری مقالات، جن کی (۱۹۹۹ و ۱۹۹۸a) و جن کی و استنجوس^۳ (۱۹۹۸)، نشان دادند که قواعد تکنیکی ساده برای عایدی‌های جاری نسبت به یک مدل گام تصادفی برای نرخ‌های ارز خارجی و شاخص‌های سهام، منجر به بهبود عملکرد پیش‌بینی می‌شود. فرانسس و فن گرینسون^۴ (۱۹۹۷)، جن کی (۱۹۹۸b) و فرناندز رودریگز و همکاران^۵ (۲۰۰۰)، کانون توجه خود را از دقت پیش‌بینی، به سمت سودآوری حاصل از خرید و فروش که اهداف تحلیل تکنیکی است، سوق دادند. شامبورا و روزیتر^۶ (۲۰۰۷)، برتری شبکه‌های عصبی مصنوعی (ANN)^۷ در پیش‌بینی و کسب بالاترین عایدی جمعی نسبت به روش‌های سنتی در بازار پیش‌خرید و پیش‌فروش نفت خام را با استفاده از میانگین متحرک‌های با وقفه‌ی ۵ و ۵۰ روزه به عنوان ورودی شبکه، مورد تایید قرار دادند. کابودان و همکاران^۸ (۲۰۰۱)، در یک دوره‌ی کوتاه‌مدت ماهانه، به پیش‌بینی قیمت نفت با دو روش برنامه نویسی ژنتیک و استفاده از ANN پرداختند و با استفاده از گام تصادفی تخمین‌هایی انجام و نشان دادند که برنامه نویسی ژنتیک دارای نتایج بهتری نسبت به روش ANN است. وانگ و همکاران^۹ (۲۰۰۵)، روش جدید TEI@I را مطرح کردند. آن‌ها از روش‌های تلفیقی هوشمند برای پیش‌بینی قیمت نفت استفاده و اثر حوادث مختلف را روی قیمت نفت بررسی کردند و بدین ترتیب یک روش غیرخطی را جهت بهبود روند پیش‌بینی قیمت نفت پیشنهاد دادند.

وانگ و همکاران (۲۰۰۴)، از سیستم تلفیقی شبکه‌ی عصبی و پایگاه قواعد به منظور پیش‌بینی قیمت نفت استفاده کردند و نشان دادند که این سیستم روشی مؤثر و منعطف برای پیش‌بینی است. یو و همکاران^{۱۰} (۲۰۰۷)، از یک شبکه‌ی عصبی با چند مرحله یادگیری جهت پیش‌بینی قیمت نفت WTI استفاده کردند، که نتایج پیش‌بینی با

-
- 1 - Transaction cost.
 - 2 - Gencay.
 - 3 - Stengos.
 - 4 - Franses and Van Griensven
 - 5 - Fernandez-Rodriquez et al.
 - 6 - Shambora and Rossiter.
 - 7 - Artificial Neural Networks.
 - 8 - Kaboudan et al .
 - 9 - Wang et al.
 - 10 - Yu et al.

این روش بسیار رضایت بخش بود. مشیری و فروتن (۲۰۰۶)، قیمت‌های روزانه‌ی پیش خرید و پیش فروش‌های نفت خام را از ۱۹۸۳ تا ۲۰۰۳، با استفاده از روش‌های GARCH, ARIMA پیش‌بینی کردند و در نهایت از مدل منعطف و غیرخطی ANN برای پیش‌بینی استفاده کردند و نشان دادند که قیمت پیش خرید و پیش فروش نفت خام یک جریان پویای غیرخطی دارد، که استفاده از ANN نتایج پیش‌بینی را بهبود داده است. ناصری و احمدی (۲۰۰۶)، از یک مدل هوشمند تلفیقی شبکه‌ی عصبی و الگوریتم ژنتیک برای پیش‌بینی ماهانه‌ی قیمت نفت استفاده کردند.

در زمینه‌ی به کارگیری شبکه‌ی عصبی GMDH برای پیش‌بینی و تحلیل بازارهای مالی، می‌توان به مطالعات مولر و ایواخنکو^۱ (۱۹۹۶) اشاره کرد، که در آن مزایای این نوع شبکه‌ی عصبی در پیش‌بینی و تحلیل بازار سهام مورد تأکید قرار گرفته است. واتر و دیگران^۲ (۱۹۹۷) قیمت سهام را با روش مذکور پیش‌بینی کردند و نتایج بسیار مطلوبی به دست آوردند. لمکه^۳ و مولر (۱۹۹۷)، از الگوریتم GMDH در دو مرحله استفاده کردند. به این ترتیب که در مرحله‌ی نخست به پیش‌بینی سبد سهام پرداخته و در مرحله بعد با طراحی یک مکانیسم "کنترل فرآیندی"، توانستند پیش‌بینی‌ها را به سیگنال‌های خرید و فروش تبدیل کنند. پانديا و کندو^۴ (۱۹۹۹)، به پیش‌بینی شاخص‌های بازار سهام با استفاده از این نوع شبکه‌ی عصبی پرداختند. مهرآرا و دیگران (۲۰۰۸)، عایدی حاصل از پیش‌بینی در بازارهای پیش خرید و پیش فروش نفت را با شبکه‌ی عصبی GMDH بررسی کردند. نتایج نشان داد که عایدی‌های تجمعی، سالانه، عایدی‌ها در یک دوره‌ی بازار و نسبت‌های شارپ، همگی برای شبکه‌ی عصبی با تفاوتی قابل ملاحظه در سطح بالاتری قرار دارند. هم‌چنین عایدی‌های معنی دار مدل GMDH، فرضیه‌ی کارایی بازار پیش خرید و پیش فروش نفت را مورد تردید جدی قرار داد. سرینی واسان^۵ (۲۰۰۸)، تقاضای انرژی را با دو نوع شبکه‌ی عصبی پیش‌بینی کرده که نتایج نشان از برتری شبکه‌ی عصبی GMDH نسبت به شبکه‌های عصبی بازگشتی دارد. ابریشمی و همکاران (۲۰۰۸)، در تحقیقی، از شبکه‌ی عصبی GMDH مبتنی بر الگوریتم ژنتیک برای پیش‌بینی قیمت بنزین با دو روش قیاسی و قواعد تحلیل تکنیکی،


1 - Muller and Ivakhnenko .

2 - Water et al.

3 - Lemke.

4 - Pandya and Kondo.


5 - Srinivasan.



استفاده کردند. متغیرهای ورودی در روش قیاسی، شامل همه‌ی عوامل مؤثر (درون و برون سیستمی) بر قیمت بنزین و در روش تحلیل تکنیکی، شامل میانگین‌های متحرک کوتاه و بلندمدت بود. نتایج نشان از دقت بیش از ۹۶٪ پیش‌بینی روش قیاسی و بیش از ۹۹٪ تحلیل تکنیکی داشت. همچنین در مقایسه‌ی معیارهای خطا، دقت پیش‌بینی‌های شبکه‌ی عصبی GMDH، به طور معنی داری از الگوی رگرسیونی بهتر بود.

۳- شبکه‌های عصبی از نوع GMDH و بهینه‌سازی چند منظوره‌ی پارتو^۱


زمانی که رگرسیون‌های استاندارد با فرم حاصل ضرب، به جهت پیچیدگی محاسبات و مشکل وابستگی خطی به بن بست رسیده بودند، ایواخنکو (۱۹۶۸)، تکنیکی برای ساخت یک چند جمله‌ای بسیط با مراتب بالا، به نام الگوریتم GMDH یا روش سازماندهی کردن داده، معرفی کرد. شبکه‌ی عصبی GMDH مبتنی بر الگوریتم ایواخنکو (۱۹۷۱ و ۱۹۹۵)، شبکه‌ای خود سازمانده و یک سویه است که از چندین لایه و هر لایه نیز از چندین نرون تشکیل شده است. تمامی نرون‌ها از ساختار مشابهی برخوردارند به طوری که دارای دو ورودی و یک خروجی است و هر نرون با ۵ وزن و یک بایاس، عمل پردازش را میان داده‌های ورودی و خروجی براساس شکل زیر و رابطه‌ی (۱) برقرار می‌کند:



$$y_{ik}^* = N(x_{i\alpha}, x_{i\beta}) = b^k + w_1^k x_{i\alpha} + w_2^k x_{i\beta} + w_3^k x_{i\alpha}^2 + w_4^k x_{i\beta}^2 + w_5^k x_{i\alpha} x_{i\beta} \quad (1)$$

$$i = 1, 2, 3, \dots, N$$

که در آن N ، داده‌های ورودی و خروجی بوده و $(K = 1, 2, 3, \dots, C_m^2)$ و $\alpha, \beta \in \{1, 2, 3, \dots, m\}$ می‌باشد، که در آن‌ها m تعداد نرون‌های لایه‌ی قبلی است.



وزن‌ها بر اساس روش‌های کم‌ترین مربعات خطا محاسبه شده و سپس به‌عنوان مقادیر مشخص و ثابت در داخل هر نرون جای‌گذاری می‌شوند. ویژگی بارز این نوع شبکه آن است که نرون‌های مرحله‌ی قبلی و یا لایه‌ی قبلی، عامل و مولد تولید نرون‌های جدید به تعداد $C_m^2 = \frac{m(m-1)}{2}$ هستند و از میان نرون‌های تولید شده، لزوماً تعدادی از آن‌ها حذف شده‌اند تا بدین وسیله از واگرایی شبکه جلوگیری به‌عمل آید. (فارلو^۱ ۱۹۸۴)

نرون‌هایی که برای ادامه و گسترش شبکه باقی می‌مانند، امکان دارد برای ایجاد فرم هم‌گرایی شبکه و عدم ارتباط آن‌ها با نرون لایه‌ی آخر حذف شوند که اصطلاحاً به آن‌ها نرون غیرفعال می‌گویند. معیار گزینش و حذف مجموعه‌ای از نرون‌ها در یک لایه، نسبت مجموع مربعات خطا (r_j^2) بین مقادیر خروجی واقعی (y_i) و خروجی نرون زام (y_{ij}^*) به‌صورت رابطه‌ی (۲) است.

$$r_j^2 = \frac{\sum_{i=1}^N (y_i - y_{ij}^*)^2}{\sum_{i=1}^N y_i^2} \quad j \in \{1, 2, 3, \dots, C_m^2\} \quad (2)$$

که در آن m تعداد نرون‌های گزینش شده در لایه‌ی قبلی است. نگاهی که بین متغیرهای ورودی و خروجی توسط این نوع از شبکه‌های عصبی برقرار می‌شود، به شکل تابع غیرخطی ولتر^۲ به صورت رابطه‌ی زیر است:


$$\hat{y} = a_0 + \sum_{i=1}^m a_i x_i + \sum_{i=1}^m \sum_{j=1}^m a_{ij} x_i x_j + \sum_{i=1}^m \sum_{j=1}^m \sum_{k=1}^m a_{ijk} x_i x_j x_k + \dots \quad (3)$$

ساختاری که برای نرون‌ها در نظر گرفته شده، به‌صورت فرم خلاصه شده‌ی دو متغیره‌ی درجه‌ی دوم زیر است:

$$y_i = f(x_{ip}, x_{iq}) = a_0 + a_1 x_{ip} + a_2 x_{iq} + a_3 x_{ip} x_{iq} + a_4 x_{ip}^2 + a_5 x_{iq}^2 \quad (4)$$

1 - Farlow.

2 - Volterra.



تابع f دارای شش ضریب مجهول است، که به ازای تمام زوج‌های دو متغیر وابسته به سیستم $\{(x_{ip}, x_{iq}), i=1,2,\dots,N\}$ ، خروجی مطلوب $\{(y_i), i=1,2,\dots,N\}$ را برآورد می‌کند. حال عبارت زیر را بر اساس قاعده‌ی کم‌ترین مربعات خطا حداقل می‌کنیم:

$$\text{Min} \sum_{k=1}^N [(f(x_{ki}, x_{kj}) - y_i)^2] \quad (5)$$

براین اساس، دستگاه معادله‌ای را که دارای شش مجهول و N معادله است، را حل می‌کنیم.

$$\begin{cases} a_0 + a_1 x_{1p} + a_2 x_{1q} + a_3 x_{1p} x_{1q} + a_4 x_{1p}^2 + a_5 x_{1q}^2 = y_1 \\ a_0 + a_1 x_{2p} + a_2 x_{2q} + a_3 x_{2p} x_{2q} + a_4 x_{2p}^2 + a_5 x_{2q}^2 = y_2 \\ \dots \\ a_0 + a_1 x_{Np} + a_2 x_{Nq} + a_3 x_{Np} x_{Nq} + a_4 x_{Np}^2 + a_5 x_{Nq}^2 = y_N \end{cases}$$

دستگاه معادله‌ی فوق را می‌توان به فرم ماتریسی زیر نمایش داد:

$$Aa = Y \quad (6)$$

که در آن

$$a = \{a_0, a_1, a_2, a_3, a_4, a_5\}^T \quad (7)$$

$$Y = \{y_1, y_2, y_3, \dots, y_N\} \quad (8)$$

$$A = \begin{bmatrix} 1 & x_{1p} & x_{1q} & x_{1p}x_{1q} & x_{1p}^2 & x_{1q}^2 \\ 1 & x_{2p} & x_{2q} & x_{2p}x_{2q} & x_{2p}^2 & x_{2q}^2 \\ \vdots & \vdots & \vdots & \ddots & \vdots & \vdots \\ 1 & x_{Np} & x_{Nq} & x_{Np}x_{Nq} & x_{Np}^2 & x_{Nq}^2 \end{bmatrix} \quad (9)$$

برای حل معادله لازم است که شبه معکوس ماتریس غیرمربع A محاسبه شود (آناستاساکیس^۱ ۲۰۰۱).

یکی از مسائل مهمی که در شبکه‌های عصبی مصنوعی مطرح می‌باشد، طراحی ساختار شبکه است. در این طراحی بایستی تعداد لایه‌ها و نیز ساختار نرونی از قبیل تعداد وزن‌ها و مقادیر اولیه‌ی آن‌ها و همچنین تابع تحریک هر نرون به صورت مناسب انتخاب شوند، تا یک نگاشت مناسب و ایده آل میان داده‌های ورودی و خروجی برقرار شود.

در طراحی شبکه‌های عصبی GMDH، هدف، جلوگیری از رشد واگرایی شبکه و نیز مرتبط کردن شکل و ساختار شبکه به یک یا چند پارامتر عددی است، به گونه‌ای که با تغییر این پارامترها، ساختار شبکه‌ها نیز تغییر کند. روش‌های تکاملی^۲ مانند الگوریتم ژنتیک، کاربرد وسیعی در مراحل مختلف طراحی شبکه‌های عصبی دارند (واسیچکینا و یارین^۳ ۲۰۰۱)، چنان‌که دارای قابلیت‌های منحصر به فردی در پیدا کردن مقادیر بهینه و امکان جستجو در فضاها غیرقابل پیش‌بینی هستند. در تحقیق حاضر، برای طراحی شکل شبکه‌ی عصبی و تعیین ضرایب آن، از الگوریتم ژنتیک استفاده شده است (جمالی و همکاران ۲۰۰۶).

نرم‌افزار محاسباتی مبتنی بر روش تلفیقی الگوریتم ژنتیک و شبکه‌ی عصبی GMDH (نریمان زاده و همکاران ۲۰۰۲ و ۲۰۰۳) با هدف بهینه‌سازی دو منظوره^۴ (آتشکاری و همکاران، ۲۰۰۷)، کمینه خطای مدل سازی و پیش‌بینی، با استفاده از Matlab طراحی شده، که مجموعه‌ای از نقاط بهینه (امانی فرد و همکاران، ۲۰۰۷) خطای پیش‌بینی و الگوسازی فرآیند را گزارش می‌دهد.

بهینه‌سازی چند منظوره یا بهینه‌سازی برداری عبارت است از یافتن برداری از متغیرهای تصمیم‌گیری که شرایط و محدودیت‌های مورد نظر را ارضاء کنند و مقادیر بهینه‌ای را برای همه‌ی توابع هدف فراهم کنند. به بیان ریاضی می‌خواهیم بردار

$$X^* = [x_1^*, \dots, x_n^*]^t \text{ را بیابیم، به گونه‌ای که تابع زیر بهینه شود:}$$


$$F(x) = [f_1(x), f_2(x), \dots, f_k(x)]^t$$

1 - Anastasakis.

2 - Evolutionary.

3 - Vasechkina and Yarin.

4 - Multi-Objective Optimization Program.



که در آن $X^* \in R^n$ ، بردار تصمیم‌گیری یا متغیرهای طراحی هستند و $F(*) \in R^k$ بردار توابع هدف است.

۴- نتایج و تحلیل محاسبات

قیمت‌گذاری در بازارهای پیش خرید و پیش فروش بر اساس قیمت "نفت‌های شاخص"^۱ مانند برنت، وست تگزاس و دبی انجام می‌گیرد، که در این جا از قیمت‌های پیش خرید و پیش فروش نفت خام وست تگزاس طی سال‌های ۲۰۰۶ - ۲۰۰۸ (روزانه) استفاده شده است. نرم افزار محاسباتی مبتنی بر روش تلفیقی الگوریتم ژنتیک و شبکه‌ی عصبی GMDH (نریمان زاده و همکاران با هدف بهینه‌سازی دو منظوره^۲ (آتشکاری و همکاران ۲۰۰۷) کمینه خطای مدل سازی و پیش‌بینی طراحی شده است، که مجموعه‌ای از نقاط بهینه^۳ (امانی فرد و همکاران ۲۰۰۷) خطای پیش‌بینی و الگوسازی فرآیند را گزارش می‌دهد.

در این مقاله‌ی عایدی‌های تجمعی برای بازه‌های زمانی ۵ تا ۲۰ روزه و روندهای عمومی بازار را به‌وسیله‌ی شبکه‌ی عصبی GMDH با دو لایه‌ی پنهان، محاسبه و با مقادیر مطلق^۴ (بدون خطا) عایدی هر دوره مقایسه می‌کنیم. برای محاسبه‌ی عایدی باید مقادیر پیش‌بینی قیمت نفت خام را برای قرار دادهای پیش خرید و پیش فروش برآورد کنیم. بدین منظور میانگین‌های متحرک ۵، ۱۰ و ۲۰ روزه را برای دوره‌ی کوتاه‌مدت و میانگین‌های ۵۰، ۱۰۰ و ۲۰۰ روزه را برای دوره‌ی بلندمدت و تفاضل آن‌ها (M۵۰-M۵) (M۱۰-M۱۰۰) و (M۲۰-M۲۰۰) را به عنوان ورودی شبکه‌ی عصبی تعریف می‌کنیم. برای محاسبه‌ی میانگین‌های متحرک، از میانگین حسابی مطابق رابطه‌ی زیر استفاده کرده‌ایم:

$$M_t^n = \left(\frac{1}{n}\right) \sum_{i=0}^{n-1} p_{t-i}$$

1 -Marker or Benchmark.

2 - Multi-Objective Optimization Program.

3 - Pareto.

۴ - عایدی مطلق، عبارت از میزان عایدی بدون خطاست که به صورت رابطه‌ی $R = \sum |r_t|$ تعریف می‌شود. به عبارت دیگر اگر عایدی‌های واقعی روزانه را فقط با علامت مثبت جمع کنیم، عایدی مطلق که فاقد هر گونه خطایی است، به‌دست می‌آید. برای مثال عایدی مطلق سال ۲۰۰۶ برابر ۱۴۲ درصد محاسبه شده است.

که در آن p_t ، قیمت در لحظه t ، p_{t-i} قیمت در i روز قبل از آن، n تعداد روزها، M میانگین حسابی متحرک در لحظه‌ی t در n روز است. لازم به ذکر است که میانگین‌های هندسی و وزنی نیز برای این کار می‌توانند مورد استفاده قرار بگیرند. نتایج حاصل از مطالعات متعدد، بیانگر آن است که تفاوت میانگین‌های متحرک کوتاه مدت و بلندمدت، ورودی‌های مؤثر در ارائه‌ی علائم معامله‌ای است (جن کی ۱۹۹۹). حال با اجرا کردن مدل توسط الگوریتم GMDH، مقادیر پیش‌بینی را برآورد می‌کنیم. از مقادیر پیش‌بینی برای استخراج علامت^۱ استفاده می‌کنیم، که این کار به وسیله‌ی الگوی زیر انجام می‌گیرد:

$$\hat{S}_t = \text{Log}(\hat{P}_t) - \text{Log}(\hat{P}_{t-1})$$

که در آن \hat{P}_t ، \hat{P}_{t-1} به ترتیب عبارت از پیش‌بینی قیمت امروز و روز قبل است. حال از مقادیر حاصل از رابطه‌ی فوق، بردار علائم \hat{S}_t را به صورت زیر تولید می‌کنیم:

$$\hat{S}_t = \begin{cases} 1 & S > 0 \\ 0 & S = 0 \\ -1 & S < 0 \end{cases}$$

زمانی که $\hat{S}_t = 1$ باشد، وضعیت خرید^۲ و وقتی $\hat{S}_t = -1$ است، وضعیت فروش^۳ خواهد بود.

برای به دست آوردن عایدی ناخالص (بدون علامت)، باید از عایدی‌های واقعی که به صورت رابطه‌ی زیر تعریف می‌شوند، استفاده کنیم:

$$r_t = \text{Log}(P_t) - \text{Log}(P_{t-1})$$


که در آن P_t ، P_{t-1} به ترتیب مقادیر حقیقی قیمت امروز و روز قبل اند. حال عایدی‌های ناخالص روزانه را در بردار علائم \hat{S}_t ضرب کرده و با هم جمع می‌نمائیم. حاصل، عبارت از عایدی تجمعی برای دوره‌های مختلف بازار است که به صورت رابطه‌ی زیر نشان داده شده است:

$$\hat{R} = \sum_{t=0}^T \hat{S}_t r_t$$

1 - Signal Extracting.

2- Long Position.

3- Short Position.



که در آن \hat{R} ، عایدی تجمعی هر دوره است که شامل مقادیر عایدی ناخالص (بدون علامت) و سیگنال قیمتی است. به عبارت بهتر، عایدی تجمعی بخشی از عایدی مطلق است که خطای پیش‌بینی در آن لحاظ شده است.

در ابتدا عایدی تجمعی حاصل از علائم پیش‌بینی و درصد عایدی مطلق آن‌ها را بر روی بازه‌های زمانی ۵ تا ۲۰۰ روزه، که شاخص دوره‌های بلندمدت و کوتاه‌مدت قواعد تحلیل تکنیکی هستند و نیز روندهای عمومی بازار را بررسی کرده و سپس در بخش بعدی عایدی‌های مبتنی بر ریسک برای هریک از آن‌ها را محاسبه و مقایسه می‌کنیم.

درصد عایدی مطلق برای بازه‌های زمانی ۵ تا ۲۰۰ روزه

درصد عایدی‌های مطلق و ریشه‌ی متوسط مربع خطای پیش‌بینی (RMSE¹) برای بازه‌های زمانی ۵ تا ۲۰۰ روزه به شرح جدول و نمودار (۱) ارائه می‌شوند:

جدول ۱- درصد عایدی مطلق برای بازه‌های زمانی ۵ تا ۲۰۰ روزه


بازه‌ی زمانی (روز) / معیار	۲۰۰	۱۰۰	۵۰	۲۰	۱۰	۵
درصد عایدی مطلق	۳۴.۲	۴۱.۶	۶۲.۳	۸۱.۸	۹۴.۷	۹۹.۲
RMSE	۲.۰۶	۱.۹۳	۱.۲	۰.۴۲	۰.۰۴۵	۰.۰۱۲

مشاهده می‌شود که خطای پیش‌بینی با روند پرشتابی نسبت به کاهش بازه‌ی زمانی، افول می‌کند. به عبارت بهتر، روند تغییرات خطا با کاهش بازه‌ی زمانی میرا شده و به سمت صفر میل می‌کند.

نتایج نشان می‌دهد که با کاهش بازه‌ی زمانی، دقت پیش‌بینی‌ها بهبود یافته و به تبع آن صحت تشخیص مسیر تغییرات قیمت به میزان زیادی افزایش می‌یابد. در این حالت تعداد سیگنال‌های معامله‌ای صحیح حاصل از پیش‌بینی، افزایش یافته و بنابراین عایدی تجمعی به سمت حداکثر مقدار خود (۱۰۰٪) میل می‌کند. به طور کلی با کاهش بازه‌ی زمانی، درصد عایدی مطلق حاصل از پیش‌بینی با شبکه‌ی عصبی GMDH، به صورت نمایی رشد می‌کند. دو دلیل اصلی را می‌توان برای نتایج مذکور

1 - Root Mean Square Error.

یادآور شد، اولاً ماهیت کوتاه‌مدت قواعد تصمیم‌گیری در تحلیل‌های تکنیکی و ثانیاً وجود روندهای آشوب‌ناک در سری زمانی قیمت پیش خرید و پیش فروش، پیش‌بینی در بلندمدت را ناممکن کرده^۱ به طوری که فقط در کوتاه‌مدت می‌توان به پیش‌بینی‌های با دقت بالا، اطمینان کرد.




نمودار ۱- درصد عایدی مطلق برای بازه‌های زمانی ۵ تا ۲۰۰ روزه

عوامل مؤثر بر تشخیص صحیح روند تغییرات قیمت در تحلیل تکنیکی، عبارت از تفاضل میانگین‌های متحرک کوتاه و بلندمدت به عنوان سیگنال‌های معامله‌ای هستند. هرچه قدر تعداد تفاضل‌های متناظر در مدل اجرا شده بیشتر باشد، صحت علائم پیش‌بینی بیشتر، شناسایی مسیر تغییرات دقیق‌تر و به تبع آن درصد عایدی مطلق افزایش می‌یابد. جدول (۲)، درصد میانگین متحرک‌های تفاضلی را از کل عوامل حاصل از اجرای مدل توسط شبکه‌ی عصبی GMDH با دو لایه‌ی پنهان^۲ برای هریک از بازه‌های زمانی نشان می‌دهد. تعداد متغیرهای تفاضلی مورد استفاده در مدل‌سازی و پیش‌بینی قیمت پیش خرید و پیش فروش نفت، شامل ۸ ورودی است.

ملاحظه می‌شود که با افزایش بازه‌ی زمانی، تعداد متغیرهای تفاضلی در مدل اجرا شده افزایش می‌یابد که خطای سیستماتیک در پیش‌بینی بر اساس قواعد تحلیل

۱ - پیش‌بینی‌ها دارای خطای سیستماتیک شده و مسیرهای واگرا را طی می‌نمایند.

۲ - تعداد متغیرهای مؤثر از خروجی مدل شبکه عصبی GMDH عبارت از $2k+1$ است که در آن k تعداد لایه‌های پنهان است. بنابراین برای ۲ لایه پنهان تعداد ورودی‌های مؤثر برابر ۸ متغیر خواهد بود.



تکنیکی را کاهش می دهند. بنابراین سیگنال‌های معامله‌ای حاصل از پیش‌بینی از دقت بالایی برخوردار بوده و در نتیجه درصد عایدی مطلق بالا می‌رود.

جدول ۲- درصد میانگین متحرک‌های تفاضلی برای بازه‌های زمانی ۵ تا ۲۰۰ روزه

معیار	بازه‌ی زمانی (روز)	۲۰۰	۱۰۰	۵۰	۲۰	۱۰	۵
تعداد متغیرهای تفاضلی از کل متغیرهای مدل		۲	۳	۴	۵	۶	۷
درصد متغیرهای تفاضلی از کل متغیرهای مدل		۲۵	۳۲.۵	۵۰	۶۲.۵	۷۵	۸۷.۵

درصد عایدی مطلق برای روندهای بازار

علاوه بر بررسی دوره‌های زمانی فوق، چهار روند عمومی در بازار را نیز به شرح ذیل بررسی می‌کنیم:

۱- روند بی‌ثباتی توأم با تغییر^۱: تغییرات قیمت دارای نوسان در مرزهای آشوبی است، به طوری که محدوده‌ی مقداری تغییرات بیش از ۲/۵ واحد قیمت است. این نوع روندها در وضعیت بی‌ثباتی بازار حادث می‌شود.

۲- روند صعودی^۲: تغییرات قیمت دارای یک روند افزایشی و بدون نوسان شدید خواهد بود. در حقیقت این نوع روندها بخشی از وضعیت رونق بازار^۳ می‌باشد.


۳- روند نزولی^۴: تغییرات قیمت دارای یک روند کاهشی و بدون نوسان شدید خواهد بود. در حقیقت این نوع روندها بخشی از وضعیت رکود بازار^۵ هستند.

۴- روند هموار^۶: تغییرات قیمت دارای نوسانات در یک محدوده مقداری کم‌تر از ۲/۵ واحد قیمت است. این نوع روندها در وضعیت آرامش بازار به‌وقوع می‌پیوندند.


در این قسمت نتایج حاصل از پیش‌بینی روندهای ذکر شده با شبکه‌ی عصبی GMDH را بررسی و درصد عایدی‌های مطلق هر یک از آن‌ها را با یکدیگر مقایسه می‌نمائیم.

- 1- Fluctuate Trend.
- 2- Increasing Trend.
- 3- Bull Market .
- 4- Decreasing Trend.
- 5- Bear Market.
- 6- Smooth Trend .



بر اساس نمودارهای (۲) و (۳) و (۴) و (۵) بیش‌ترین انطباق را روند صعودی و کم‌ترین انطباق را روند بی‌ثباتی توأم با تغییر دارد. البته همه‌ی روندها از خطای کم‌تر از ۲ درصد برخوردارند را نشان می‌دهند. قدرت و پایداری بالای پیش‌بینی‌های شبکه‌ی عصبی GMDH را نشان می‌دهند.




نمودار ۲- مقادیر واقعی و پیش‌بینی قیمت پیش خرید و پیش فروش نفت برای روند بی‌ثباتی توأم با تغییر



نمودار ۳- مقادیر واقعی و پیش‌بینی قیمت پیش خرید و پیش فروش نفت برای روند صعودی



نمودار ۴- مقادیر واقعی و پیش‌بینی قیمت پیش خرید و پیش فروش نفت برای روند نزولی



نمودار ۵- مقادیر واقعی و پیش‌بینی قیمت پیش خرید و پیش فروش نفت برای روند هموار

درصد عایدی مطلق و خطای پیش‌بینی برای روندهای فوق در جدول (۳) نشان داده شده است:

جدول ۳- درصد عایدی مطلق برای روندهای بازار

معیار	روند	صعودی	هموار	نزولی	بی ثباتی توأم با تغییر
درصد عایدی مطلق		۹۸/۳	۹۲/۱	۹۰/۲	۶۶/۳
RMSE		۰/۰۱۱	۰/۰۱۵	۰/۰۱۴	۰/۰۴۲

نتایج نشان می‌دهد که بیش‌ترین عایدی در روند صعودی و کم‌ترین منفعت حاصل از روند بی‌ثباتی توأم با تغییر حاصل می‌شود. هم‌چنین ملاحظه می‌شود که به جز روند بی‌ثباتی توأم با تغییر، سایر روندها بیش از ۹۰٪ عایدی به همراه دارند. بازه‌های زمانی روندهای مذکور بین ۷ تا ۱۰ روز بوده، که ناشی از طبیعت ذاتی آن‌هاست. به غیر از روند بی‌ثباتی توأم با تغییر، سایر روندها دارای خطای کم‌تر از ۰.۰۲ هستند.


اگر بازه‌ی زمانی روند بی‌ثباتی توأم با تغییر از ۱۰ روز مورد بررسی به ۵ تا ۷ روز کاهش دهیم، نتایج تغییر محسوسی خواهند داشت، به طوری که درصد عایدی مطلق تا ۹۴٪ افزایش پیدا می‌کند، که بر اساس تحلیل قسمت اول قابل پیش‌بینی است. بنابراین روندهای بی‌ثبات و دارای نوسان زیاد را تنها می‌توان در بازه‌های زمانی بسیار کوتاه، با خطای کم، پیش‌بینی کرد.

برای بررسی درصد عوامل مؤثر بر تعیین سیگنال‌های معامله‌ای، جدول زیر درصد میانگین متحرک‌های تفاضلی را از کل عوامل حاصل از اجرای مدل توسط شبکه‌ی عصبی GMDH با دولایه‌ی پنهان برای هریک از روندهای بازار نشان می‌دهد. تعداد متغیرهای تفاضلی مورد استفاده در مدل سازی و پیش‌بینی قیمت پیش خرید و پیش فروش نفت، شامل ۸ ورودی است.

جدول ۴- درصد میانگین متحرک‌های تفاضلی برای روندهای عمومی بازار

معیار	روند بازار	صعودی	نزولی	هموار	بی‌ثباتی توأم با تغییر
تعداد متغیرهای تفاضلی از کل متغیرهای مدل		۷	۶	۶	۵
درصد متغیرهای تفاضلی از کل متغیرهای مدل		۸۷/۵	۷۵	۷۵	۶۲/۵

ملاحظه می‌شود که بیش‌ترین تعداد و درصد متغیرهای تفاضلی در مدل اجرا شده مربوط به روند صعودی و کم‌ترین آن‌ها نیز مربوط به روند بی‌ثباتی توأم با تغییر است. در نتیجه خطای سیستماتیک در پیش‌بینی بر اساس قواعد تحلیل تکنیکی در روند نزولی، کم‌تر و سیگنال‌های معامله‌ای حاصل از پیش‌بینی دارای دقت بالاتری نسبت به سایر روندها بوده و در نتیجه درصد عایدی مطلق آن نیز بالاتر می‌باشد.



مقایسه‌ی عایدی‌ها مبتنی بر ریسک

از آن جایی که مقایسه‌ی عایدی‌های مدل‌های مختلف، فقط بر مبنای سودآوری ناقص است، بنابراین مقایسه‌ی این عایدی‌ها نسبت به ریسکی که دارند، مهم است. بدین منظور از معیار ضریب تغییرات^۱ که عبارت از نسبت انحراف معیار به متوسط عایدی روزانه است، برای محاسبه‌ی ریسک عایدی‌ها استفاده می‌کنیم. جدول زیر ضریب تغییرات عایدی‌های روزانه برای بازه‌های زمانی ۵ تا ۲۰۰ روزه (همگی به درصد) را نشان می‌دهد. هر اندازه ضریب تغییرات یا CV کم‌تر باشد، ریسک پایین‌تر خواهد بود.

جدول ۳- عایدی مبتنی بر ریسک برای بازه‌های زمانی ۵ تا ۲۰۰ روزه

بازه‌ی زمانی (روز)	۵	۱۰	۲۰	۵۰	۱۰۰	۲۰۰
متوسط عایدی روزانه	۰/۸۹	۰/۷۸	۰/۵۷	۰/۴۸	۰/۳۵	۰/۲۸
انحراف معیار	۰/۰۰۵۸	۰/۰۰۶۴	۰/۰۰۷۲	۰/۰۰۰۸	۰/۰۱۲	۰/۰۲۱
ضریب تغییرات (درصد)	۰/۶۵	۰/۸۲	۱/۲۶	۱/۶۷	۳/۴۳	۱۰/۳۲

ملاحظه می‌شود که با افزایش بازه‌ی زمانی، ضریب تغییرات به سرعت افزایش می‌یابد که ناشی از اثر هم‌زمان کاهش متوسط عایدی روزانه و افزایش انحراف معیار با رشد بازه‌ی زمانی است. بنابراین هم‌چنان که پیش‌بینی در بازه‌ی‌های زمانی کوتاه‌مدت بر اساس قواعد تحلیل تکنیکی توسط شبکه‌ی عصبی GMDH عواید بیش‌تری را به دنبال دارد، از ریسک کم‌تری نیز برخوردار است. جدول زیر ضریب تغییرات عایدی‌های روزانه برای روندهای چهارگانه‌ی بازار (همگی به درصد) را نشان می‌دهد.

جدول ۴- عایدی مبتنی بر ریسک برای روندهای بازار

روند	صعودی	نزولی	هموار	بی ثباتی توأم با تغییر
متوسط عایدی روزانه	۰/۹۳	۰/۸۵	۰/۸۷	۰/۶۹
انحراف معیار	۰/۰۰۲۸	۰/۰۰۳۱	۰/۰۰۶۸	۰/۰۱۲
ضریب تغییرات (درصد)	۰/۳	۰/۳۶	۰/۷۸	۱/۷۴

1- Coefficient of Variation.

بر اساس نتایج به دست آمده، تنها روند بی‌ثباتی توأم با تغییر دارای ضریب تغییرات بیش از ۱ درصد است که ناشی از انحراف معیار بالا و عایدی متوسط کم‌تر نسبت به سایر روندهاست. فاصله‌ی اندک ضریب تغییرات روند صعودی و نزولی ناشی از وجود انحراف معیار و عایدی‌های تقریباً یکسان آن‌هاست، ولی به طور کلی روند صعودی (مانند سایر معیارهای دیگر) نتایج بهتری را به همراه دارد.


۵- نتیجه گیری

در این مقاله با استفاده از شبکه‌ی عصبی GMDH، درصد عایدی مطلق (بدون خطا) بر روی بازه‌های زمانی ۵ تا ۲۰۰ روزه و روندهای عمومی بازار مبتنی بر قواعد تحلیل تکنیکی، شامل میانگین‌های متحرک کوتاه مدت و بلندمدت به عنوان ورودی شبکه‌ی عصبی، محاسبه شده‌اند.

بر اساس نتایج به دست آمده، درصد عایدی مطلق با کاهش بازه‌ی زمانی افزایش قابل ملاحظه‌ای داشته است و خطا نیز به شدت میرا می‌شود. هم‌چنین تعداد عوامل مؤثر در تعیین علائم معامله‌ای شامل تفاضل میانگین متحرک‌های کوتاه و بلندمدت نیز با کاهش بازه‌ی زمانی، در مدل استخراجی افزایش می‌یابد. با محاسبه‌ی ضریب تغییرات عایدی‌ها به عنوان معیار برآورد ریسک نسبی معاملات، مشخص شد که با کاهش بازه‌ی زمانی، ریسک معاملاتی به شدت کاهش می‌یابد. در بررسی روندهای عمومی بازار ملاحظه شد که روند صعودی دارای بیش‌ترین درصد عایدی مطلق و کم‌ترین ریسک بوده و درمقابل روند بی‌ثباتی توأم با تغییر از کم‌ترین درصد عایدی مطلق و بیش‌ترین ریسک معاملاتی برخوردار است. در این جا از سایر هزینه‌های مترتب بر بازار، از جمله هزینه‌های مبادله صرف نظر کرده‌ایم. هم‌چنین مدل مورد بررسی مختص معامله‌گران و بورس بازان درون بازار و فاقد عوامل برون زاست.

فهرست منابع

ابریشمی، معینی، مهرآرا، احراری و سلیمانی کیا، مدل سازی و پیش‌بینی قیمت بنزین با استفاده از شبکه‌ی عصبی GMDH مبتنی بر الگوریتم ژنتیک، فصل‌نامه‌ی پژوهش‌های اقتصادی ایران، دانشکده‌ی اقتصاد دانشگاه علامه طباطبایی، شماره‌ی ۳۶، پائیز ۱۳۸۷.



میرزایی، مجید، مقایسه‌ی عایدی قراردادهای آبی و آبی نفت خام با استفاده از شبکه‌ی عصبی GMDH. پایان نامه‌ی کارشناسی ارشد، دانشکده‌ی اقتصاد دانشگاه تهران، ۱۳۸۳.

Amanifard, N. Nariman-Zadeh, M. Borji, A. Khalkhali and A. Habibdoust, "Modelling and Pareto optimization of heat transfer and flow coefficients in microchannels using GMDH type neural networks and genetic algorithms", *Energy Conversion and Management*, Volume 49, Issue 2, February 2008, Pages 311-325.

Anastasakis, L., Mort, N., The Development of Self-Organization Techniques in Modeling: A Review of The Group Method of Data Handling (GMDH), Department of Automatic Control & Systems Engineering The University of Sheffield, Mappin St, Sheffield, No. 813, 2001.

Atashkari, N. Nariman-Zadeh, M. Gölcü, A. Khalkhali and A. Jamali, "Modelling and multi-objective optimization of a variable valve-timing spark-ignition engine using polynomial neural networks and evolutionary algorithms", *Energy Conversion and Management*, Volume 48, Issue 3, March 2007, Pages 1029-1041.

Brock, W.A. Lakonishok, J., LeBaron, B, Simple technical trading rules and the stochastic properties of stock returns, *Journal of Finance* 47 ,1731–1764, 1992.

Farlow, S.J., Self-organizing methods in modeling, GMDH type algorithms, New York and Basel, Marcel Dekker, Inc., 1984.

Fernandez-Rodriquez, Fernando, Gonzalez-Martel, Christian, Sosvilla-Rivero, Simon, On the profitability of technical trading rules based on artificial neural networks: evidence from the Madrid stock market, *Economics Letters* 69 (1), 89–94, 2000.

Franses , Philip Hans, van Griensven, Kasper, Forecasting exchange rates using neural networks for technical trading rules", *Studies in Nonlinear Dynamics and Econometrics* 2 (4), 108–114, 1997.

Gencay, Ramazan, 1996. Non-linear prediction of security returns with moving average rules. *Journal of Forecasting* 15(3), 165– 174

Gencay, Ramazan, 1998a. The predictability of security returns with simple technical trading rules. *Journal of Empirical Finance* 5 (4), 347–359.

Gencay, Ramazan, 1998b. Optimization of technical trading strategies and the profitability in security markets. *Economics Letters* 59 (2), 249– 254.

Gencay, Ramazan, 1999. Linear, non-linear and essential foreign exchange rate prediction with simple technical trading rules. *Journal of International Economics* 47 (1), 91–107.

Gencay, Ramazan, Stengos, Thanasis, 1998. Moving average rules, volume and the predictability of security returns with feedforward networks. *Journal of Forecasting*, 17 (56), 401–414.

Ivakhnenko A.G and Ivakhnenko, G.A., The review of problems solvable by algorithms of the group method of data handling (GMDH), *Pattern Recognition and Image Analysis*, vol.5, no.4, pp.527-535, 1995.

Ivakhnenko, A.G. The group method of data handling; a rival of the method of stochastic approximation. *Soviet Automatic Control*, 13(3), 43-55, 1968.

Ivakhnenko, A.G., Polynomial Theory of Complex System, *IEEE Trans. Syst. Man & Cybern*, SMC-1, 364-378, 1971.

Jamali, A., Nariman-zadeh, N., Atashkari, K., Inverse Modelling of Multi-objective Thermodynamically Optimized Turbojet Engines using GMDH and GA, 14th Annual (International) Mechanical Engineering Conference – May 2006, Isfahan University of Technology, Isfahan, Iran.

Kaboudan, Penn State, Fagelsville, Evolutionary Computation, roceedings of the 2001 Congress on, Volume 1, 2001, pages 283-287.

Lemke, F. and J.A. Muller, Self-organizing modeling in financial risk control, Proceedings of the 15th IMACS World Congress on Scientific Computation, Modeling and Applied Mathematics, vol.6 (Application on Modeling and Simulation), pp.733-738, 1997.


Mehrara M, Moeini A, Ahrari M, Erfanifard A. Investigating the efficiency in oil futures market based on GMDH approach. *Journal of Expert Systems with Applications* 2008; Elsevier Science.

Moshiri S, Foroutan F, Forecasting nonlinear Crude Oil Prices, the energy journal, Volume 27, No.4, 2006, pages 81-95.

Muller, J.A. and G.A. Ivakhnenko, Recent developments of self-organizing modeling in prediction and analysis of stock market, available in URL address: <http://www.inf.kiev.ua/GMDHhome/articles/>, 1996.

Nariman-Zadeh, N., A Darvizeh, G R Ahmad-Zadeh., Hybrid genetic design of GMDH-type neural networks using singular value decomposition for modeling and prediction of the explosive cutting process, *Journal of Engineering manufacture Proceedings of the I MECH E Part B*, Volume: 217 Page: 779 -- 790, 2003.

Nariman-zadeh, N.; Darvizeh, A.; Darvizeh, M.; Gharababaei, H, Modeling of explosive cutting process of plates using GMDH-type neural network and singular value decomposition, *Journal of Materials Processing Technology*, 2002, vol. 128, no. 1-3, pp. 80-87, Elsevier Science.



Nasari M, Ahmadi E, A Hybrid Artificial Intelligence Approach to Monthly Forecasting of Crude Oil Price Time series , Engineering Application 's of Neural Network, Volume 284, 2006.

Neftci, S.N., 1991.Naïve trading rules in financial markets and Wiener-Kolmogorov prediction theory: a study of technical analysis. Journal of Business 64, 549–571.

Pandya, A.S., Kondo, T., Shah, T.U. and Gandhi, V.R., Prediction of stock market characteristics uses neural networks, in Proceedings of the SPIE. The International Society for Optical Engineering, vol.3722, pp.189-197, 1999.

Shambora, William E., Rossiter R, Are there exploitable inefficiencies in the futures market for oil?, Journal of Energy Economics, Volume: 29 Page: 18-27 , 2007.

Srinivasan, Dipti, Energy demand prediction using GMDH networks, Neurocomputing 72 (2008) 625–629.

Vasechkina, E.F. and Yarin, V.D., “Evolving polynomial neural network by means of genetic algorithms: some application examples”. Complexity International, Vol. 9, 2001.

Wang S, Yu L, Lai K.K,Crude Oil Price Forecasting with TEI@I Methodology, Journal of Systems Science and Complexity, Volume 18, No. 2, 2005.

Wang S, Yu L, Lai K.K, A Novel Hybrid AI System Framework for Crude Oil Price Forecasting, Springer –Verlag Heidelberg, 2004, pages 233-242.

Water, P.R., S. Wibier, E.J.H. Kerckhoffs and H. Koppelaar, GMDH-based stock price prediction, Neural Network World, vol.7, no.4-5, pp.552-563, 1997.