

## مدل‌سازی و پیش‌بینی قیمت بنزین با استفاده از

### شبکه عصبی GMDH

دکتر حمید ابریشمی \*

دکتر علی معینی \*\*

دکتر محسن مهرآرا \*\*\*

مهدی احراری \*\*\*\*

فاطمه سلیمانی کیا \*\*\*\*\*

تاریخ پذیرش: ۱۳۸۷/۷/۲۹

تاریخ ارسال: ۱۳۸۶/۵/۲۷

#### چکیده

در این پژوهش از شبکه عصبی GMDH مبتنی بر الگوریتم ژنتیک به عنوان ابزاری با قابلیت بالا در مدل‌سازی سیستم‌های غیرخطی پویای پیچیده، برای پیش‌بینی قیمت بنزین با دو روش قیاسی و قواعد تحلیل تکنیکی، استفاده کرده‌ایم. متغیرهای ورودی در روش قیاسی شامل تمام عوامل مؤثر (درون و برون سیستمی) بر قیمت بنزین و در روش تحلیل تکنیکی شامل میانگین‌های متحرک کوتاه و بلندمدت است. نتایج نشان‌دهنده دقت بیش از ۹۶ درصد پیش‌بینی و پایداری روش قیاسی و بیش از ۹۹ درصد تحلیل تکنیکی است. اثر روز دوشنبه به عنوان یک معیار تحلیل تکنیکی در روش قیاسی، تأیید شده است. همچنین، در مقایسه معیارهای خطا، دقت پیش‌بینی‌های شبکه عصبی GMDH به طور معناداری از الگوی رگرسیونی بهتر است.<sup>۱</sup>

طبقه‌بندی: JEL: C5 , C53.

**واژگان کلیدی:** شبکه عصبی GMDH، قیمت بنزین، الگوریتم ژنتیک، قیمت نفت، پیش‌بینی، مدل‌سازی، میانگین متحرک، تحلیل تکنیکی، روش قیاسی.

Email: abrishami\_hamid@yahoo.com

\* استاد دانشکده اقتصاد دانشگاه تهران

\*\* دانشیار گرایش الگوریتم‌ها و محاسبات گروه علوم مهندسی پردیس دانشکده‌های فنی دانشگاه تهران

\*\*\* استادیار دانشکده اقتصاد دانشگاه تهران

\*\*\*\* پژوهشگر مؤسسه تحقیقات اقتصادی دانشگاه تهران

Email: abrishami\_hamid@yahoo.com

\*\*\*\*\* کارشناس ارشد اقتصاد انرژی دانشگاه تهران

۱. نویسندگان از مشورت‌های آقایان دکتر نریمان‌زاده استاد دانشکده مکانیک دانشگاه گیلان و مهندس جمالی دانشجوی دکتری دانشگاه گیلان بهره برده که کمال تشکر خود را از ایشان اعلام می‌دارند.



## مقدمه

یکی از نکات اساسی مغفول مانده در تحلیل‌های اقتصادسنجی، تشخیص ماهیت رفتاری و نوع سازه یک سری زمانی است. به طوری که در بیشتر موارد یک فرآیند غیرخطی پویا توسط یک مدل خطی تصادفی برآورد می‌شود. بنابراین، فرآیندهای غیرخطی و بدون نویز غالب، نمی‌تواند با این روش‌ها مدل‌شده و پیش‌بینی‌های به‌دست‌آمده نیز از اعتبار کافی برخوردار نخواهد بود. تلاش‌های بسیاری برای مدل‌کردن و تشخیص سازه فرآیندهای پیچیده با استفاده از داده‌های ورودی-خروجی انجام شده است. برای مدل‌کردن هر سیستم لازم است تا ارتباط بین داده‌های ورودی-خروجی به صورت دقیق و ساده فهمیده شود. استدلال فازی، شبکه‌های عصبی و الگوریتم ژنتیک، توانایی زیادی در حل سیستم‌های غیرخطی بسیار پیچیده و مسایل پیش‌بینی، به ویژه در بازارهای مالی دارند. از آنجایی که روند تغییرات قیمت در بازارهای بورس انرژی در تصمیم‌گیری‌های معاملاتی از اهمیت فوق‌العاده‌ای برخوردار است، تلاش‌های بسیاری برای به‌کارگیری روش‌های پیش‌بینی در تشخیص فرآیندها (مسیر تغییرات) انجام شده است. الگوریتم<sup>۱</sup> GMDH، اولین بار توسط ایواخنکو<sup>۲</sup> (۱۹۶۸) برای مدل‌کردن سیستم‌های پیچیده‌ای که شامل یک سری داده‌ها با چندین ورودی و یک خروجی بودند، مورد استفاده قرار گرفت. در واقع هدف اصلی، ساختن تابعی در یک شبکه براساس تابع انتقال درجه دوم است. در تلاش‌های اخیر توسط واسچکینا و یارین<sup>۳</sup> (۲۰۰۱) از الگوریتم ژنتیک برای یافتن مجموعه اتصالات بهینه برای شبکه استفاده می‌شود.

در این پژوهش، سری زمانی قیمت بنزین با استفاده از شبکه عصبی GMDH مبتنی بر الگوریتم ژنتیک، با دو روش قیاسی<sup>۴</sup> و قواعد تحلیل تکنیکی<sup>۵</sup> با دو سری ورودی جداگانه، شامل تمام عوامل مؤثر بر قیمت بنزین برای روش اول و میانگین‌های متحرک کوتاه‌مدت و بلندمدت برای روش دوم را مدل‌سازی و پیش‌بینی کرده‌ایم. در بخش نخست، پیشینه پژوهش انجام شده در این زمینه را مرور خواهیم کرد. در بخش دوم، مدل‌سازی با شبکه عصبی GMDH را شرح خواهیم داد. در بخش سوم، مروری بر عوامل مؤثر بر قیمت بنزین و بازارهای آن خواهیم داشت. در بخش چهارم نتیجه، تحلیل محاسبات و پیش‌بینی قیمت بنزین را ارائه کرده و بخش پنجم که دربرگیرنده نتیجه‌گیری است، پایان‌بخش این مقاله خواهد بود.

## ۱. پیشینه پژوهش

1. Group Method of Data Handling

2. Ivakhnenko

3. Vasechkina and Yarin

4. Deductive Method

5. Technical Analysis

تاکنون در مورد به‌کارگیری شبکه عصبی GMDH در اقتصاد پژوهش‌های بسیاری انجام شده است. از جمله زمینه‌های اولیه پژوهشی که استفاده شده، می‌توان به شناسایی و پیش‌بینی بازارهای مالی اشاره کرد. بر اساس نظر اسکات و و هاتچینسون<sup>۱</sup> (۱۹۹۹) روش‌های معمول به‌دلیل عدم توانایی در طرح یک تکنیک معین برای انتخاب متغیر ورودی، شکست‌خورده به حساب می‌آیند. این‌گونه سیستم‌ها به دلیل ماهیت کاملاً غیرخطی خود قادر به توضیح ارتباطات کوچک میان متغیرها و واکنش آنها نسبت به هم نیستند. از این رو، به‌نظر می‌رسد که GMDH در این زمینه بسیار کارساز عمل کرده‌است. گولیوسوف<sup>۲</sup> و کوندراشوا<sup>۳</sup> (۱۹۸۷) در پژوهشی قابلیت GMDH را در استخراج اطلاعات کافی در مورد وابستگی متقابل شاخص‌های مالی کشورها با سیستم‌های اقتصادی حاکم بر آنها نشان داده‌اند. ایواخنکو<sup>۴</sup> و مولر (۱۹۹۶) در پژوهش خود، دستاوردهای شبکه عصبی GMDH در پیش‌بینی و تحلیل بازار سهام را ارائه کردند. واتر و دیگران<sup>۵</sup> (۱۹۹۷) قیمت سهام را پیش‌بینی کرده و لمکه<sup>۶</sup> و مولر (۱۹۹۷) از الگوریتم GMDH در دو مرحله استفاده کردند؛ به این ترتیب که در مرحله نخست به پیش‌بینی سبد سهام پرداخته و در مرحله بعد با طراحی یک ساز و کار "کنترل فرآیندی" توانستند پیش‌بینی‌ها را به سیگنال‌های خرید و فروش تبدیل نمایند. پانديا<sup>۷</sup> و کندو<sup>۸</sup> (۱۹۹۹) شاخص‌های بازار سهام را پیش‌بینی کردند. هاولند<sup>۹</sup> و وس<sup>۱۰</sup> (۲۰۰۳) در پژوهشی به پیش‌بینی میزان جریان گازطبیعی از مخازن پرداختند. هوانگ<sup>۱۱</sup> (۲۰۰۶) به همراه هسو<sup>۱۲</sup> و وانگ<sup>۱۳</sup> پژوهشی در زمینه یافتن شیوه جدید کشف ساختار الگو در سری‌های زمانی با استفاده از داده‌های مالی انجام داده‌اند. برای پیش‌بینی قیمت بنزین تا کنون از این روش استفاده نشده، اما به‌دلیل ماهیت مشابه روندهای موجود در بازارهای مالی، می‌توان از شبکه عصبی GMDH استفاده کرد.

در مورد به‌کارگیری قواعد تحلیل تکنیکی پژوهش‌های بسیاری انجام شده که می‌توان به بررسی قدرت پیش‌بینی قوانین تحلیل تکنیکی در مدل‌های خطی و غیرخطی که توسط نفتی<sup>۱۴</sup> (۱۹۹۱) صورت گرفته، اشاره کرد. بروک و همکاران<sup>۱۵</sup> (۱۹۹۲) علاوه بر حمایت از قواعد تحلیل‌های تکنیکی به عنوان متغیرهای ورودی، ضرورت به‌کارگیری مدل‌های غیرخطی را نیز پیشنهاد دادند. جن کی<sup>۱۶</sup> (۱۹۹۶) برای اولین بار از قواعد تحلیل تکنیکی به‌عنوان ورودی شبکه عصبی در بازارهای ارز خارجی استفاده کرد. در یک سری مقالات، جن کی (۱۹۹۹ a و ۱۹۹۸) و جن کی و استنجوس<sup>۱۷</sup> (۱۹۹۸) نشان دادند که قوانین تکنیکی ساده برای عایدی‌های جاری در یک مدل گام تصادفی برای هر دوی نرخ‌های

1.Scott and Hutchinson

3.Kondrasheva

5. Water et al

7.Pandya

9. Howlan

11. Huang

13.Wang

15.Brock et al

17.Stengos

2.Goleusov

4.A.G.Ivakhnenko

6.Lemke

8.Kondo

10.Voss

12Hsu

14 Nefti

16 Gencay

ارز خارجی و شاخص‌های سهام به اطلاعات مهم در پیش بینی منجر می‌شود. فرانسس و ون گرینسون<sup>۱</sup> (۱۹۹۷) جن کی (۱۹۹۸b) و فرناندز رودریگز و همکاران<sup>۲</sup> (۲۰۰۰) کانون توجه این شیوه را از دقت پیش‌بینی به منعکس کردن سودآوری در نتیجه خرید و فروش که اهداف تحلیل تکنیکی است، منتقل کردند. شامبورا و روزیتر<sup>۳</sup> (۲۰۰۷) به بررسی وجود عدم کارایی در بازارهای آتی نفت خام با استفاده از قواعد تحلیل تکنیکی به عنوان ورودی های شبکه عصبی، پرداختند.

## ۲. شبکه عصبی GMDH

شبکه عصبی GMDH دربرگیرنده مجموعه‌ای از نرون‌ها<sup>۴</sup> است که از پیوند جفت‌های مختلف از طریق یک چند جمله‌ای درجه دوم به وجود می‌آیند. شبکه با ترکیب چند جمله‌ای‌های درجه دوم حاصل از تمامی نرون‌ها، تابع تقریبی  $\hat{f}$  را با خروجی  $\hat{y}$ ، برای یک مجموعه از ورودی‌های  $X=(x_1, x_2, x_3, \dots, x_n)$ ، با کمترین خطا در مقایسه با خروجی واقعی  $y$ ، توصیف می‌کند. بنابراین، برای  $M$  داده آزمایشگاهی شامل  $n$  ورودی و یک خروجی، نتایج واقعی به شکل رابطه ۱ نمایش داده می‌شوند.

$$y_i = f(x_{i1}, x_{i2}, x_{i3}, \dots, x_{in}) \quad (i = 1, 2, \dots, M) \quad (1)$$

در اینجا به دنبال شبکه‌ای هستیم که بتواند مقدار خروجی  $\hat{y}$  را برای هر بردار ورودی  $X$ ، بر اساس رابطه ۲ پیش‌بینی کند.

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

به طوری که میانگین مربعات خطا بین مقادیر حقیقی و پیش‌بینی کمینه شود، به بیان دیگر:

$$MSE = \frac{\sum_{i=1}^M (\hat{y}_i - y_i)^2}{M} \rightarrow \min \quad (3)$$

شکل عمومی اتصال بین متغیرهای ورودی و خروجی را می‌توان با استفاده از تابع چند جمله‌ای به شکل رابطه ۴، بیان کرد.

$$y = a_0 + \sum_{i=1}^n a_i x_i + \sum_{i=1}^n \sum_{j=1}^n a_{ij} x_i x_j + \sum_{i=1}^n \sum_{j=1}^n \sum_{k=1}^n a_{ijk} x_i x_j x_k + \dots \quad (4)$$

1. Franses and van Griensven

2. Fernandez-Rodriquez et al

3. Shambora & Rossiter

4. Neuron

که چند جمله‌ای ایواخنکو نامیده می‌شود. در بسیاری از موارد کاربردی از شکل درجه دوم و دو متغیره این چند جمله‌ای به صورت رابطه ۵، استفاده می‌شود.

$$\hat{y} = G(x_i, x_j) = a_0 + a_1 x_i + a_2 x_j + a_3 x_i^2 + a_4 x_j^2 + a_5 x_i x_j \quad (5)$$

ضرایب مجهول  $a_i$  در رابطه ۵ با تکنیک‌های رگرسیونی چنان به دست می‌آیند که اختلاف بین خروجی واقعی  $y$  و مقادیر محاسبه شده  $\hat{y}$  برای هر جفت متغیر ورودی  $x_i$  و  $x_j$ ، کمینه شود. مجموعه‌ای از چند جمله‌ای‌ها با استفاده از رابطه ۵ ساخته می‌شوند که ضرایب مجهول تمام آنها، با استفاده از روش حداقل مربعات (LS) به دست می‌آیند. برای هر تابع  $G_i$  (هر نرون ساخته شده)، ضرایب معادلات هر نرون برای حداقل کردن خطای کل آن به منظور انطباق بهینه ورودی‌ها بر تمام جفت مجموعه‌های ورودی - خروجی، به دست می‌آیند.

$$E = \frac{\sum_{i=1}^M (y_i - G_i)^2}{M} \rightarrow \min \quad (6)$$

در روش‌های پایه‌ای الگوریتم GMDH، تمامی ترکیبات دوتایی (نرون‌ها) از  $n$  متغیر ورودی ساخته شده و ضرایب نامعلوم تمام نرون‌ها با استفاده از روش حداقل مربعات به دست می‌آیند. بنابراین نرون در لایه دوم ساخته می‌شوند که آن را می‌توان به شکل مجموعه  $\gamma$  نمایش داد.

$$\{(y_i, x_{ip}, x_{iq}) | (i=1,2,\dots,M) \ \& \ p,q \in (1,2,\dots,M)\} \quad (7)$$

از شکل درجه دوم تابع بیان شده در رابطه ۵ برای هر  $M$  ردیف سه‌تایی استفاده می‌کنیم، این معادلات را می‌توان به شکل ماتریسی رابطه ۸ بیان کرد.

$$Aa = Y \quad (8)$$

که در آن،  $A$  بردار ضرایب مجهول معادله درجه دو نشان داده شده در رابطه ۵ است، یعنی:

$$a = \{a_0, a_1, \dots, a_5\} \quad (9)$$

و

$$Y = \{y_1, y_2, y_3, \dots, y_M\}^T \quad (10)$$

از مقادیر بردارهای ورودی و شکل تابع به راحتی قابل مشاهده است که:

$$A = \begin{bmatrix} 1 & x_{1p} & x_{1q} & x_{1p}^2 & x_{1q}^2 & x_{1p}x_{1q} \\ 1 & x_{2p} & x_{2q} & x_{2p}^2 & x_{2q}^2 & x_{2p}x_{2q} \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ 1 & x_{Mp} & x_{Mq} & x_{Mp}^2 & x_{Mq}^2 & x_{Mp}x_{Mq} \end{bmatrix} \quad (11)$$

روش حداقل مربعات از آنالیز multiple-regression، حل معادلات را به شکل رابطه ۱۲ به دست می‌دهد:

$$a = (A^T A)^{-1} A^T Y \quad (12)$$

این معادله بردار ضرایب رابطه ۵ را برای تمام M مجموعه سه‌تایی ایجاد می‌کند. ضرایب نرون‌ها در لایه‌های پنهان و خروجی در مرحله مدل‌سازی (آموزش) براساس تعریف اولیه برنامه از سطح معناداری و فاصله اطمینان مورد نظر پژوهشگر، تعیین و فرآیند بهینه‌یابی ضرایب و معادلات نرون‌ها و سازوکار غربال‌سازی داده‌ها، یعنی حذف متغیرهایی که همبستگی پایینی را در این مرحله نشان می‌دهند، توسط الگوریتم ژنتیک صورت می‌گیرد. بنابراین، محاسبات در حجم بالا در عمل قابل حل بوده و کمک می‌کند تا سیستم معادلات نرمال، در شرایط مناسب و قابل حل قرار گیرد.

یکی از مسائل مهمی که در شبکه‌های عصبی مصنوعی چند لایه (پرسپترون و جز اینها) مطرح است، طراحی ساختار شبکه است. در این طراحی باید تعداد لایه‌ها و نیز ساختار درونی از قبیل تعداد وزن‌ها و مقادیر اولیه آنها و همچنین، تابع تحریک هر نرون به صورت مناسب انتخاب شده تا یک نگاشت مناسب و ایده‌آل میان داده‌های ورودی و خروجی برقرار شود.

مسئله طراحی شبکه عصبی GMDH با مسائل عنوان شده در بالا متمایز است. در این نوع از طراحی، هدف جلوگیری از رشد واگرایی شبکه و نیز مرتبط کردن شکل و ساختار شبکه به یک یا چند پارامتر عددی بوده، به گونه‌ای که با تغییر این پارامتر ساختار شبکه‌ها نیز تغییر کند. روش‌های تکاملی مانند الگوریتم ژنتیک کاربرد وسیعی در مراحل مختلف طراحی شبکه‌های عصبی به دلیل قابلیت‌های منحصر به فرد خود در پیدا کردن مقادیر بهینه و امکان جستجو در فضاها غیرقابل پیش‌بینی، دارند<sup>۲</sup>. در این پژوهش، برای طراحی شکل شبکه عصبی و تعیین ضرایب آن، از الگوریتم ژنتیک استفاده کرده‌ایم.

### کاربرد الگوریتم ژنتیک در طراحی ساختار شبکه‌های عصبی نوع GMDH

برای عمومیت بخشیدن به شبکه‌های عصبی GMDH، لازم است که قید استفاده از لایه مجاور در ساختن لایه بعد را حذف کنیم. در این نوع شبکه‌های عصبی برای ساخت لایه جدید می‌توان از تمام لایه‌های قبلی (لایه ورودی را شامل می‌شود) استفاده کرد. ما این شبکه را GS<sup>1</sup> می‌نامیم.

### نمایش ژنوم شبکه‌های عصبی نوع GS-GMDH

ژنوم یا کروموزومی که برای نمایش ساختار شبکه عصبی در نظر گرفته‌ایم، شامل یک رشته سمبولیک ساده، حاصل از ترکیب حروف الفباست، که در آن، هر حرف نشان‌دهنده یکی از ورودی‌های شبکه عصبی است. در این نوع کدگذاری، هر ورودی با یک حرف جایگزین می‌شود و هر کروموزوم به صورت رشته‌ای ساخته شده از این حروف الفباست. برای یک شبکه با  $N$  ورودی  $X = (x_1, x_2, x_3, \dots, x_n)$ ، یک کروموزوم به صورت یک رشته و ترکیبی از  $\alpha_i \in \{a, b, c, d, \dots\}$  به شکل  $\alpha_1 \alpha_2 \dots \alpha_i \dots$  شکل می‌گیرد، که در آن  $a, b, c, \dots$  به ترتیب جایگزین ورودی‌های  $x_1, x_2, x_3, \dots$  می‌شوند. به طور مثال، برای یک شبکه با چهار ورودی، چهار حرف  $a, b, c, d$  می‌تواند برای ساختن ژنوم‌ها استفاده شود. بدیهی است که هر کروموزوم با طول  $2k$  که  $k \in \{1, 2, 3, \dots, (n_i + 1)\}$  (nl نشان‌دهنده تعداد لایه‌های مخفی است) می‌تواند نشان‌دهنده یک ساختار شبکه عصبی باشد. ابتدا فرض می‌کنیم که هر نرون از ترکیب دو نرون در لایه مجاور ساخته شده است (شبکه CS)، در این صورت، مشخص است که یک کروموزوم مانند  $abbcadbc$  نشان‌دهنده ساختار شبکه عصبی منحصر به فردی است که دارای چهار ورودی است. به طور کلی، رابطه  $2^{HL+1} = \text{Length of neuron}$  (HL نشان‌دهنده تعداد لایه‌های مخفی است)، ارتباط بین طول نرون و تعداد لایه‌های مخفی را در این کدگذاری نشان می‌دهد. بنابراین، این شبکه دارای دو لایه مخفی  $22+1=8$  است.

بدیهی است که هر نرون به طول  $2^n$  متعلق به لایه  $n$  ام است. برای شبکه یادشده تمام نرون‌ها با طول دو (2) متعلق به لایه اول  $(ab | bc | ad | bc)$ ، و تمام نرون‌ها با طول چهار (22)، متعلق به لایه دو  $(abbc | acbc)$  و ... بوده، بنابراین، از این خاصیت استفاده می‌کنیم تا ژنومی را برای شبکه عصبی نوع GS تشکیل دهیم. در شبکه عصبی نوع GS نرون‌ها با طول‌های مختلف با یکدیگر ترکیب می‌شوند، در واقع، نرون با طول کوچکتر باید از چند لایه مخفی جهش کرده و با نرون با طول بزرگتر ترکیب شود. برای حل این مشکل نام نرون‌هایی را که از لایه‌ها جهش می‌کنند، تکرار می‌کنیم. در شکل ۳ مشاهده می‌شود که نرون  $ad$  در لایه مخفی اول با جهش از لایه مخفی دوم با نرون  $abbc$  (با طول بزرگتر) ترکیب شده و نرون  $abbcadad$  را تشکیل داده است، در واقع، نرون مجازی با نام  $adad$  در لایه مشابه نرون  $abbc$  ساخته شده و با آن ترکیب می‌شود. تعداد تکرار نرون با طول کوچکتر برابر  $2^n$  است،



که در آن،  $n$  نشان‌دهنده تعداد لایه‌هایی است که نرون از آنها جهش کرده‌است. کروموزوم‌هایی نظیر  $acacdad$  در این شیوه کدگذاری غیرقابل قبولند، زیرا به راحتی می‌توان آن‌را به صورت  $acad$  نمایش داد. بنابراین، شبکه  $CS$  زیرمجموعه‌ای از شبکه  $GS$  است.

### ۳. عوامل مؤثر بر قیمت بنزین

به طور کلی در هر کشور، عوامل اصلی در تعیین قیمت بنزین عبارتند از: ۱. قیمت نفت خام، ۲. هزینه پالایش، ۳. میزان مالیات (و یا یارانه) و ۴. هزینه توزیع و بازاریابی. در هر کشور چنانچه تولید بنزین در پالایشگاه‌ها براساس میزان مصرف نباشد، کمبود بنزین از طریق واردات جبران می‌شود. توجه به این نکته ضروری است که در کشورهای مختلف، سهم هر یک از عوامل یاد شده متفاوت بوده و براساس سیاست دولت تعیین می‌شود.

در نمودار ۱، ده کشور جهان را که دارای بالاترین قیمت بنزین در سال ۲۰۰۶ - بر حسب سنت در هر لیتر - بوده‌اند، نشان داده‌ایم.

نمودار-۱. کشورهای دارای بالاترین قیمت بنزین در سال ۲۰۰۶ (بر حسب سنت در هر لیتر)




مأخذ: World Development Indicators(2006)

در تمامی این کشورها، که بیشتر آنها اروپایی هستند، علت گران بودن قیمت بنزین، اعمال مالیات‌های سنگین بر مصرف بنزین است، به طوری که منطقه اروپا که تا سال ۱۹۹۳ پس از کشورهای آمریکای شمالی (ایالات متحده و کانادا) دومین مصرف‌کننده بنزین در جهان بوده، اکنون به جایگاه سوم

نزول کرده و منطقه آسیا دومین مصرف‌کننده بنزین در جهان به شمار می‌رود. در نمودار ۲، ده کشور جهان را که در سال ۲۰۰۶ به ترتیب دارای کمترین قیمت بنزین بوده‌اند، نشان داده‌ایم.

نمودار ۲- کشورهای دارای پایین‌ترین قیمت بنزین در سال ۲۰۰۶ (برحسب سنت در هر لیتر)



مأخذ: World Development Indicators(2006)


نکته قابل توجه آن است که تمام این کشورها جزء کشورهای نفتی هستند. یکی از مهم‌ترین دلایل ارزان بودن قیمت بنزین در این کشورها آن است که بخش اصلی درآمدهای دولت نه از طریق اخذ مالیات، بلکه از طریق فروش نفت خام به دست می‌آید، بنابر این، با وجود درآمدهای ارزی بالا، نه تنها از مصرف‌کنندگان مالیات‌های سنگین برای مصرف بنزین دریافت نشده، بلکه با اعطای یارانه‌های فراوان، بنزین را پایین‌تر از قیمت تمام‌شده برای دولت، در اختیار مصرف‌کنندگان قرار می‌دهند.

در سال‌های ۱۹۹۸-۲۰۰۶ قیمت بنزین در کشورهای منطقه خاورمیانه با افزایش دائمی روبرو بوده، به طوری که از ۳۵ سنت در هر لیتر به رقم ۵۲ سنت در هر لیتر رسیده است. در سال ۲۰۰۶ گران‌ترین و ارزان‌ترین قیمت‌های بنزین در این منطقه به ترتیب متعلق به کشورهای فلسطین اشغالی (۲۹ سنت) و ایران (۹ سنت) بوده است. بجز فلسطین اشغالی، اردن و لبنان تمام کشورهای این منطقه (که جزء کشورهای نفتی هستند) به شهروندان خود یارانه سوخت پرداخت می‌نمایند. از آنجا که قیمت‌های جهانی بنزین می‌تواند در تعیین قیمت‌های داخلی کشورها- به ویژه کشورهای واردکننده اصلی- مؤثر باشد، در قسمت بعد، قیمت بنزین در بازارهای مهم جهان را مورد بررسی قرار می‌دهیم.

### قیمت بنزین در بازارهای جهانی

سه عامل مهم که می‌تواند در تعیین قیمت بنزین در بازارهای جهانی مؤثر باشند، عبارتند از: ۱. قیمت نفت خام، ۲. هزینه‌های پالایش و ۳. هزینه حمل از پالایشگاه تا بازارهای عمده فروش. قیمت‌های اعلام‌شده در بورس بنزین به صورت فوب<sup>۱</sup> بوده، به طوری که قیمت اعلام‌شده شامل تمام هزینه‌ها از تولید تا رساندن بنزین بر روی کشتی است. نمودار ۳، روند تغییرات قیمت بنزین در پنج بازار اصلی جهان از ژانویه ۱۹۹۷ تا ژانویه ۲۰۰۷ را نشان می‌دهد. این ۵ بازار عبارت از سه بازار بورس آمریکایی نیویورک، خلیج مکزیک و لوس آنجلس به همراه بازار بورس اروپایی روتردام و بازار بورس آسیایی سنگاپور است.

نمودار ۳- روند تغییرات قیمت بنزین در بازارهای جهانی (۱۹۹۷-۲۰۰۷)




در سال‌های ۱۹۹۷-۲۰۰۷ متوسط قیمت بنزین در بازارهای جهانی ۹۴/۱ سنت در هر گالن بوده است. بالاترین قیمت بنزین نیز در آگوست ۲۰۰۵ در بازار نیویورک با قیمت ۳۲۶/۴۵ سنت در هر گالن و کمترین قیمت بنزین نیز در فوریه ۱۹۹۹ با رقم ۲۷ سنت در هر گالن به بازار خلیج مکزیک اتفاق افتاده است. همچنین، در این دوره، متوسط قیمت بنزین در بازار آسیایی سنگاپور ۸۸/۴ سنت در هر گالن بوده و در می ۲۰۰۶ قیمت در این بازار به حداکثر میزان خود، ۲۱۷/۵ سنت در هر گالن و در دسامبر ۱۹۹۸ به کمترین مقدار خود یعنی ۲۹/۵۲ سنت در هر گالن رسیده است. در نمودار ۳، به وضوح می‌توان مشاهده کرد که روند تغییرات در این بازارها همسو بوده و شوک و تغییر در یک بازار بر

1. FOB: Free On Board

دیگر بازارها نیز اثر خواهد گذاشت. همچنین، برای نشان دادن وابستگی قیمت بنزین به قیمت نفت خام، روند قیمت نفت خام و بنزین را در دوره مورد نظر در نمودار ۴ نشان داده‌ایم.


نمودار-۴. مقایسه روند قیمت‌های نفت و بنزین در بازارهای جهانی



نکته قابل توجهی که در نمودار (۴) مشهود است، فاصله میان قیمت‌های بنزین و نفت در بازارهای جهانی است. در بازارهای جهانی هرگاه قیمت‌های نفت با افزایش روبه رو شده‌است، روند افزایش قیمت‌های بنزین رشد بیشتری داشته است. اگر فضای میانی به‌وجود آمده بین قیمت‌های نفت و بنزین را بررسی نماییم، پس از هر دوره رونق و رکود، فضای به‌وجود آمده، افزایش می‌یابد. به‌بیان دیگر، واکنش قیمت‌های جهانی بنزین به شوک‌های نفتی به‌گونه‌ای است که شوک‌های رونق نفتی به رشد سریع قیمت بنزین منجر شده، در حالی که با آغاز دوران رکود نفتی، قیمت بنزین با سرعت بسیار کمتری کاهش‌یافته و تعدیل می‌شود و به همین دلیل شکاف میان قیمت‌های نفت و بنزین در طول زمان در هر دوره بیشتر می‌شود.

در پایان این بخش، مرور مختصری بر روند تولید، مصرف و واردات بنزین در ایران در سال‌های ۱۳۸۳-۱۳۶۷ خواهیم داشت. نمودار ۵ روندهای یاد شده را نشان می‌دهد.

نمودار-۵. روند مصرف، تولید و واردات بنزین در ایران (۱۳۶۷-۱۳۸۳)



مأخذ: شرکت ملی پخش فرآورده‌های نفتی.

همان‌طور که مشاهده می‌شود، میزان مصرف بنزین در کشور بیش از تولید آن بوده و این شکاف به دلیل رشد چشمگیر مصرف در برابر تولید، بزرگتر شده که برای جبران اختلاف به وجود آمده، میزان واردات افزایش یافته است.

بر اساس پیش‌بینی‌های شرکت ملی پخش فرآورده‌های نفتی (بر اساس جدول ۱)، چنانچه این روند ادامه یابد، تا سال ۱۴۰۰ میزان مصرف با لحاظ سناریوهای مختلف به گونه‌ای افزایش می‌یابد که تأمین ارز مورد نیاز برای واردات بنزین، مشکلی اساسی برای دولت خواهد بود.

جدول ۱- سناریوهای مختلف در مورد رشد مصرف بنزین در ایران

میزان مصرف در سال ۱۴۰۰	سناریوهای مختلف در مورد رشد مصرف (از ابتدای سال ۱۳۸۲)
۸۷ میزان مصرف در سال ۱۴۰۰	برابر رشد مصرف جهانی (۲/۵ درصد)
۱۳۰ میزان مصرف در سال ۱۴۰۰	برابر ۵ درصد
۲۰۷ میزان مصرف در سال ۱۴۰۰	برابر متوسط رشد سال‌های ۱۳۸۱-۱۳۷۷ برابر ۷/۶ درصد
۳۰۹ میزان مصرف در سال ۱۴۰۰	برابر ۱۰ درصد

مأخذ: شرکت ملی پخش فرآورده‌های نفتی

#### ۴. مدل‌سازی و پیش‌بینی قیمت بنزین با شبکه عصبی GMDH

بر اساس بررسی‌های انجام شده، قیمت‌های بنزین بازار بورس سنگاپور به عنوان یکی از معیارهای اصلی در تعیین قیمت پایه‌ای معاملات خاورمیانه، مورد استفاده قرار می‌گیرد. بنابراین، در این پژوهش به مدل‌سازی و پیش‌بینی سری زمانی قیمت‌های بنزین سنگاپور به عنوان متغیر خروجی، خواهیم پرداخت. آمار مربوط به پنج بورس بین‌المللی بنزین - سنگاپور، نیویورک، لوس آنجلس، روتردام و خلیج مکزیک - و دو بورس بین‌المللی نفت خام - برنت و وست تگزاس اینترمدیت - که در این پژوهش استفاده کرده‌ایم، از طریق سایت اینترنتی سازمان اطلاعات انرژی آمریکا<sup>۱</sup> جمع‌آوری شده‌است. منبع مورد استفاده این سایت در جمع‌آوری اطلاعات یاد شده، خبرگزاری رویترز است. همچنین، آمار مربوط به قیمت دو بورس مهم نفت برنت، تگزاس در این سایت آورده شده است. این آمار از سال ۱۹۹۸ تا اوایل ۲۰۰۷ به صورت روزانه موجود بوده و منبع جمع‌آوری این اطلاعات مجله وال استریت است. در این پژوهش از دو روش برای مدل‌سازی و پیش‌بینی قیمت بنزین به شرح زیر استفاده کرده‌ایم.

روش اول عبارت از یک فرآیند "کل به جزء" یا همان روش قیاسی (ایواخنکو ۱۹۷۱ و ۱۹۸۶ و ۱۹۹۵) در مدل‌سازی و پیش‌بینی قیمت روزانه بنزین سنگاپور به عنوان خروجی، مبتنی بر تمام عوامل مؤثر درون سیستمی شامل قیمت‌ها و میانگین‌های با وقفه بنزین سنگاپور و روزهای هفته و برون سیستمی شامل

1. Energy Information Administration , [www.eia.doe.gov](http://www.eia.doe.gov)

قیمت‌ها و میانگین‌های با وقفه بنزین روتردام، نیویورک، لوس آنجلس و خلیج آمریکا و قیمت نفت خام برنت و وست تگزاس، که در مجموع ۲۶ متغیر ورودی به شرح ذیل است:

۱. روزهای هفته از دوشنبه تا جمعه به طوری که روز جاری عدد ۱ و روزهای دیگر عدد صفر است (۵ ورودی).

۲. قیمت‌های با وقفه ۱ و ۲ و ۷ روزه بنزین سنگاپور، روتردام، نیویورک، لوس آنجلس و خلیج‌مکزیک (۱۵ ورودی).

۳. قیمت‌های با وقفه ۱ و ۲ و ۷ روزه نفت خام برنت و وست تگزاس (۶ ورودی).  
تمامی این قیمت‌ها به صورت روزانه و مربوط به سال ۲۰۰۶ است.

نرم‌افزار محاسباتی تحت نرم افزار MATLAB با عنوان GEvoM<sup>۲</sup> مبتنی بر بهینه‌سازی دو منظوره<sup>۳</sup> بر مبنای الگوریتم ژنتیک<sup>۴</sup> با هدف کمینه‌کردن خطای الگوسازی و پیش‌بینی، طراحی شده که به طور همزمان<sup>۵</sup> دقت پیش‌بینی و پایداری فرآیند را افزایش می‌دهد. ورودی‌ها در دو دسته داده‌های آموزش<sup>۶</sup> (شامل حداقل ۷۰ درصد داده‌ها) و آزمون<sup>۷</sup> (شامل حداکثر ۳۰ درصد داده‌ها) تقسیم شده‌اند که نتایج این سیستم ورودی- خروجی شبکه عصبی GMDH به ازای لایه‌های پنهان<sup>۸</sup> مختلف به شرح جدول ۲ است.<sup>۹</sup>

با توجه به نتایج به دست آمده، در انتخاب ترکیب بهینه، با پارادوکس انتخاب میان لایه‌های بالاتر که ضامن خطای پیش‌بینی و مدل‌سازی کمتر در مقابل افزایش پیچیدگی‌ها و احتمال بیش‌برازش<sup>۱۰</sup> است، رو به رو هستیم. با کاهش مرحله‌ای لایه‌ها، متغیرهای ورودی اثرگذار بر متغیر خروجی استخراج خواهند شد.

جدول ۲- نتایج مدل‌سازی و پیش‌بینی قیمت بنزین سنگاپور با روش قیاسی (مرحله اول)

مرحله	RMSE	تعداد لایه‌های پنهان	تعداد ورودی‌ها	تعداد ورودی‌های حذف شده در هر مرحله	تعداد ورودی‌های مؤثر در هر مرحله
۱	۱/۳۳	۶	۲۶	۰	۲۶
۲	۱/۵۷	۵	۲۶	۳	۲۳
۳	۱/۶۱	۴	۲۶	۵	۲۱
۴	۱/۹۰	۳	۲۶	۱۳	۱۳
۵	۲/۱۳	۲	۲۶	۱۸	۸

۱. رجوع کنید به پایگاه اطلاعاتی دانشگاه گیلان، دانشکده فنی، پژوهش.

2. Multi-Objective Optimization Program

۵. امانی فرد و همکاران ۲۰۰۷

۳. آتشکاری و همکاران ۲۰۰۷.

5. Train

7. Hidden Layers

6. Test

9. Over-fitting

۸. سلیمانی کیا ۱۳۸۶.

یکی از مهم‌ترین ویژگی‌های الگوریتم GMDH توانایی شناسایی و حذف متغیرهای زاید است.<sup>۱</sup> در نخستین گام برای غربال‌سازی مدل با ۲۶ متغیر ورودی، به ترتیب ۳ متغیر کیفی روزهای سه شنبه، چهارشنبه و پنجشنبه به همراه ۶ متغیر کمی شامل قیمت با وقفه ۲ و ۷ روز قبل نفت وست تگزاس، قیمت ۱ و ۷ روز قبل بنزین خلیج مکزیک و قیمت ۲ روز قبل بنزین نیویورک و لوس آنجلس که در فرآیند کاهش لایه‌های پنهان در مقایسه با متغیرهای دیگر ورودی، کمترین اثر را داشته‌اند، حذف شدند.

گام دوم غربال‌سازی، در مراحل ۶ و ۷ با استفاده از ۱۷ متغیر ورودی، مدل‌هایی با ۴ و ۳ لایه پنهان را برآورد کرده که قیمت ۲ و ۷ روز قبل بنزین روتردام را حذف کرده‌ایم و تعداد متغیرهای ورودی را به عدد ۱۵ رسانده‌ایم.

در گام سوم با استفاده از ۱۵ متغیر ورودی، مدل‌هایی با ۴، ۳ و ۲ لایه پنهان را برآورد کرده که قیمت ۱ روز قبل بنزین روتردام، متغیر کیفی روز جمعه، قیمت ۱ روز قبل نفت برنت و قیمت ۷ روز قبل بنزین نیویورک از میان متغیرهای ورودی را حذف کرده‌ایم.

مدل نهایی با ۱۱ متغیر ورودی و دو لایه پنهان را برآورد کرده که از ترکیبات ۷ متغیر ورودی برای توضیح‌دهندگی متغیر خروجی استفاده کرده‌ایم. متغیر کیفی اثر روز دوشنبه<sup>۲</sup> به همراه متغیرهای کمی قیمت ۱، ۲ و ۷ روز قبل بنزین سنگاپور، قیمت ۱ روز قبل بنزین لوس آنجلس و نیویورک و قیمت دو روز قبل نفت برنت، متغیرهای مؤثر در مدل نهایی است. نمودار ۶، مقادیر پیش‌بینی و واقعی قیمت بنزین سنگاپور در روش قیاسی را نشان می‌دهد.

جدول ۳- نتایج مدل‌سازی و پیش‌بینی قیمت بنزین سنگاپور با روش قیاسی (مرحله نهایی)

مرحله	RMSE	تعداد لایه‌های پنهان	تعداد ورودی‌ها	تعداد ورودی‌های حذف‌شده در هر مرحله	تعداد ورودی‌های مؤثر در هر مرحله
۶	۱/۶۵	۴	۱۷	۲	۱۵
۷	۱/۸۸	۳	۱۷	۷	۱۰
۸	۱/۶۳	۴	۱۵	۰	۱۵
۹	۱/۸۷	۳	۱۵	۴	۱۱
۱۰	۲/۱۵	۲	۱۵	۸	۷
۱۱	۲/۱۵	۲	۱۴	۷	۷
۱۲	۲/۱۵	۲	۱۱	۴	۷

۱. فارلو (Farlow)، ۱۹۸۴، اناستاساکیس (Anastasakis) ۲۰۰۱ و فانگ چن (Fang Chen) ۲۰۰۶

۲. گاهی در بازارهای مالی وضعیتی وجود دارد که از آن به عنوان Monday Effect یاد می‌شود. این وضعیت به شرایطی گفته می‌شود که اگر بازار بورس در یک هفته با روند افزایشی و رونق رو به رو باشد، در اولین روز کاری هفته جدید (دوشنبه)، قیمت اعلامی (Announce) با رقمی بالاتر از قیمت بسته‌شده (Close) آخرین روز کاری در هفته گذشته (جمعه) آغاز خواهد شد و برعکس. به بیان دیگر، گویی روند افزایش و یا کاهش قیمت‌ها در ایام تعطیل بورس نیز ادامه داشته است.

در روش دوم، ورودی‌های مدل بر اساس قواعد تحلیل تکنیکی که مبتنی بر معیار میانگین‌های متحرک کوتاه‌مدت و بلندمدت قیمت بنزین سنگاپور است، به شرح ذیل تعریف می‌کنیم:


۱. میانگین‌های متحرک کوتاه‌مدت ۵ و ۱۰ و ۲۰ روزه،
۲. میانگین‌های متحرک بلندمدت ۵۰ و ۱۰۰ و ۲۰۰ روزه،
۳. تفاوت میانگین ۵ و ۵۰ روزه،
۴. تفاوت میانگین ۱۰ و ۱۰۰ روزه،
۵. تفاوت میانگین ۲۰ و ۲۰۰ روزه.

نمودار-۶. مقایسه مقادیر واقعی و پیش‌بینی قیمت بنزین سنگاپور در مدل نهایی روش قیاسی



ورودی‌های مؤثر بر لگاریتم نرخ بازگشت قیمت روزانه بنزین سنگاپور به عنوان خروجی مدل با ۲ لایه پنهان شامل: میانگین متحرک ۱۰، ۲۰، ۵۰، ۱۰۰ و ۲۰۰ روزه و تفاوت میانگین ۱۰ و ۱۰۰ روزه است. ریشه میانگین مجذور خطای<sup>۱</sup> مدل‌سازی و پیش‌بینی کمتر از یک درصد است. جدول ۴ و نمودار ۷، مقادیر پیش‌بینی و واقعی قیمت بنزین سنگاپور در روش تحلیل تکنیکی را نشان می‌دهد.

نمودار-۷. مقایسه مقادیر واقعی و پیش‌بینی قیمت بنزین سنگاپور در روش تحلیل تکنیکی



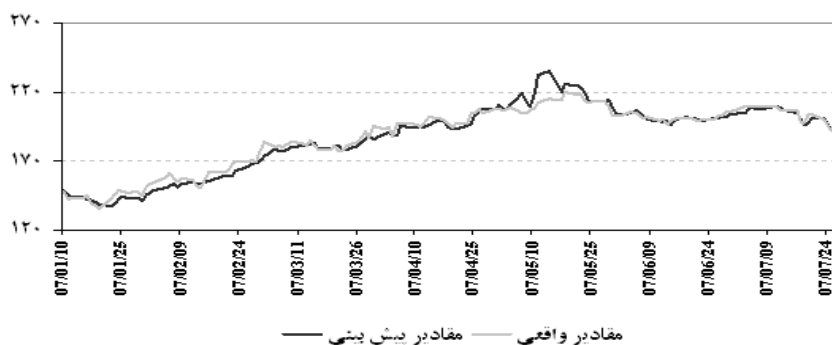
جدول-۴. نتایج مدل‌سازی و پیش‌بینی قیمت بنزین سنگاپور با روش تحلیل تکنیکی



مرحله	RMSE	تعداد لایه‌های پنهان	تعداد ورودی‌ها	تعداد ورودی‌های حذف‌شده در هر مرحله	تعداد ورودی‌های مؤثر در هر مرحله
۱	۰/۰۰۹۱	۲	۹	۲	۷

در پایان، نتایج پیش‌بینی‌های پویا<sup>۱</sup> (چند گام به جلو) برای قیمت آبی بنزین سنگاپور، یعنی بازه زمانی که در مدل‌سازی استفاده نشده (خارج از نمونه) را بررسی می‌کنیم. بازه زمانی انتخاب‌شده برای بررسی میزان دقت پیش‌بینی‌های مدل، عبارت از ۱۰ ژانویه تا ۳۰ جولای ۲۰۰۷ (در حدود ۵ ماه بعد) است. نمودار ۸، مقادیر واقعی و پیش‌بینی شده در روش قیاسی، در دور یادشده را نشان می‌دهد.

نمودار ۸- پیش‌بینی قیمت بنزین سنگاپور در روش قیاسی برای دوره زمانی آبی



در جدول ۵، خطای پیش‌بینی برای دوره‌های مختلف ۱ تا ۵ ماه بعد بررسی شده است.

جدول ۵- بررسی دقت پیش‌بینی مدل برآوردشده در روش قیاسی برای ماه‌های آبی

بازه زمانی	RMSE تجمعی	میانگین قیمت بازه	خطای پیش‌بینی (درصد)	دقت پیش‌بینی (درصد)
یک ماه بعد	۴/۵	۱۵۰/۷	۲/۹۸	۹۷/۰۲
دو ماه بعد	۴/۴۱	۱۶۵/۷	۲/۶۶	۹۷/۳۴
سه ماه بعد	۵/۵۸	۱۷۸/۱	۳/۱۳	۹۶/۸۷
چهار ماه بعد	۵/۱۶	۱۸۵/۱	۲/۷۹	۹۷/۲۱
پنج ماه بعد	۴/۸۴	۱۸۸/۱	۲/۵۷	۹۷/۴۳


۲. دو روش برای پیش‌بینی وجود دارد: پیش‌بینی پویا و پیش‌بینی ایستا. در پیش‌بینی پویا (چند گام به جلو) از مقادیر برآوردشده و در پیش‌بینی ایستا (یک گام به جلو) از مقادیر واقعی متغیر استفاده می‌شود. در نتیجه، پیش‌بینی ایستا دقیق‌تر از پیش‌بینی پویا خواهد بود.

و میزان درصد خطای پیش‌بینی بر اساس رابطه زیر محاسبه می‌شود:

$$\frac{\sqrt{MSE}}{\text{Mean Price}} * 100 = \frac{RMSE}{\text{Mean Price}} * 100$$

با توجه به آنکه دقت پیش‌بینی‌های مدل، بیش از ۹۶/۸۷ درصد است، می‌توان گفت که این مدل قادر به توضیح تغییرات سیستماتیک در بازار بنزین سنگاپور بوده و هر چه دوره زمانی پیش‌بینی بیشتر شود، دقت پیش‌بینی‌ها افزایش و  $RMSE$  کاهش می‌یابد. از آن جهت که در ماه سوم یک شوک غیرسیستماتیک<sup>۱</sup> به مدل وارد شده،  $RMSE$  تجمعی تا سه ماه بعد افزایش یافته و به ۵/۵۸ رسیده است. ولی پس از آن، شوک به‌وجود آمده، تعدیل شده و دقت پیش‌بینی‌ها افزایش یافته و در نهایت، درصد خطای پیش‌بینی برای ۵ ماه آتی به ۲/۵۷ درصد رسیده است. مدل مورد نظر برای پیش‌بینی ایستا (یک گام به جلو) قیمت در ۳ ماه قبل از بازه زمانی (داخل نمونه) نیز بررسی شده و نتایج نشان می‌دهد که دقت پیش‌بینی بیش از ۹۶/۳ درصد است. مقایسه بین مقادیر پیش‌بینی و واقعی را در نمودار ۹ نشان داده‌ایم.

نمودار ۹- مقایسه مقادیر پیش‌بینی و واقعی برای سه ماه قبل از بازه مورد استفاده در مدل‌سازی



### برآورد رگرسیونی قیمت بنزین

نتایج برآورد مدل به روش رگرسیون معمولی، برای داده‌های لگاریتمی، در دوره زمانی ۲۷ جولای ۲۰۰۶ تا ۱۰ ژانویه ۲۰۰۷ را در جدول ۶ نشان داده‌ایم.

$$R^2 = 0.95$$

جدول ۶- نتایج برازش مدل به روش رگرسیون معمولی


۱. این شوک درون سیستمی و ناشی از تغییر قیمت بنزین بوده اما از آنجایی که مدل شامل تمام متغیرهای درون و بیرون سیستمی است، بنابراین، این شوک رهگیری نشده است. در حالی که با روش تحلیل تکنیکی، این گونه تغییرات به خوبی رهگیری می‌شود.

متغیر	ضریب	RMSE	t	احتمال قبول فرضیه $H_0$
GN(-1)	0.256075	0.056397	4.540596	0.0000
GS(-1)	0.574566	0.089640	6.409676	0.0000
GS(-2)*MON	0.388122	0.133082	2.916406	0.0043
OB(-2)*MON	-0.903000	0.370243	-2.438937	0.0163
GS(-2)	0.054810	0.086533	0.633398	0.5278
MON	-3.635570	7.592625	-0.478829	0.6330
OB(-2)	0.070190	0.147229	0.476737	0.6345
GN(-1)*MON	-0.021858	0.134663	-0.162314	0.8714
GL(-1)	-0.004601	0.050572	-0.090971	0.9277

همچنین، پیش‌بینی مدل برآوردشده به روش رگرسیون معمولی در بازه مورد استفاده در برآورد و همچنین، قیمت‌های آتی بنزین برای ۵ ماه بعد را در نمودار ۱۰ نشان داده‌ایم.

از آنجا که ریشه میانگین مجذورات خطا در این مدل برای بازه مورد استفاده در برآورد ۱۲/۹۲ به‌دست آمده و همچنین، میانگین مقادیر واقعی قیمت بنزین در این دوره ۱۶۳/۳ سنت در هر گالن بوده است، درصد خطای پیش‌بینی مدل رگرسیون معمولی ۷/۹۱ درصد است. همچنین، ریشه میانگین مجذورات خطای پیش‌بینی برای بازه زمانی ۵ ماه بعد، ۹/۹۶ و میانگین مقادیر واقعی قیمت ۱۸۷ سنت بر هر گالن بوده که در نتیجه، درصد خطای پیش‌بینی در این مدل را به ۵/۳۲ درصد رسانده است.

نمودار ۱۰- مقایسه مقادیر واقعی و پیش‌بینی به‌دست آمده از رگرسیون معمولی



با توجه به نتایج به‌دست‌آمده از رگرسیون معمولی می‌توان گفت اگر برآورد‌های رگرسیونی قادر به تصریح متغیرهای اثرگذار بر قیمت بنزین سنگاپور و همچنین، روابط غیرخطی حاکم میان این متغیرها می‌بود، همچنان دقت این روش‌ها در پیش‌بینی قیمت بنزین در مقایسه با شبکه عصبی  $GMDH$ ،

۵۰ درصد ( $۵/۳۲=$  روش رگرسیون معمولی،  $۲/۵۷=$  روش *GMDH*) کمتر است. مقدار عددی آماره آزمون مربوط به نسبت  $MSPE^1$  الگوی رگرسیونی به شبکه عصبی *GMDH*، برابر  $F(10,10)=۳۴,۴^2$  است که به طور معناداری بزرگتر از مقدار بحرانی جدول  $F_{0,05}(10,10)=۲/۹۸$  است.

---

1. Mean Square Prediction Error

2.  $F= MSPE(R)/MSPE(GMDH)$

##### ۵. نتیجه‌گیری

در این پژوهش، مدل‌سازی و پیش‌بینی قیمت بنزین را با استفاده از شبکه عصبی GMDH مبتنی بر الگوریتم ژنتیک برای داده‌های روزانه بازار بورس بنزین سنگاپور (۲۰۰۶-۲۰۰۷) با دو روش قیاسی و تحلیل تکنیکی انجام داده‌ایم. نتایج حاصل از روش اول که تمام قیمت‌ها و میانگین‌های با وقفه بنزین و نفت بازارهای اصلی دنیا را به عنوان ورودی (۲۶ ورودی) در نظر گرفته بود، حاکی از تأثیر خالص ۷ متغیر بر قیمت بنزین سنگاپور، به عنوان خروجی سیستم است که دارای پیش‌بینی و پایداری با دقت بیش از ۹۶ درصد است. نتایج روش دوم که ورودی‌های مدل براساس قواعد تحلیل تکنیکی شامل میانگین‌های متحرک کوتاه‌مدت و بلندمدت و تفاوت آنهاست (۹ ورودی)، نشان از تأثیر ۷ ورودی بر متغیر هدف و نیز دقت بیش از ۹۹ درصد پیش‌بینی و پایداری روند حرکت قیمت روزانه بنزین سنگاپور دارد. همچنین، اثر روز دوشنبه به عنوان معیار تحلیل تکنیکی در روش قیاسی را مورد تأیید قرار دادیم. در مجموع می‌توان گفت شبکه عصبی GMDH از قابلیت بالایی در مدل‌سازی فرآیندهای پیچیده و پیش‌بینی مسیرهای غیرخطی پویا برخوردار است. بدین ترتیب از این رویکرد می‌توان برای پیش‌بینی قیمت‌های جهانی و همچنین، مدیریت مصرف انرژی در داخل کشور سود جست.

## منابع

سلیمانی کیا، فاطمه. مدل‌سازی و پیش‌بینی قیمت بنزین با استفاده از شبکه عصبی GMDH. پایان‌نامه کارشناسی ارشد اقتصاد انرژی. دانشکده اقتصاد دانشگاه تهران. بهار ۱۳۸۰.

- Amanifard, N, N. Nariman-Zadeh, M. Borji, A. Khalkhali and A. Habibdoust. (2007). Modelling and Pareto Optimization of Heat Transfer and Flow Coefficients in Microchannels using GMDH Type neural Networks and Genetic Algorithms. *Energy Conversion and Management*.
- Anastasakis, L, N. Mort. (2000). 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.
- Atashkari, K, N. Nariman-Zadeh, M. Gölcü, A. Khalkhali and A. Jamali. (2007). 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. pp. 1029-1041*.
- Brock, W.A. Lakonishok, J., LeBaron, B. (1992). Simple Technical Trading Rules and the Stochastic Properties of Stock Returns. *Journal of Finance* 47, 1734-1764
- Fang Chen, Jiuping Xu. Factor analysis for well-off construction Based on GMDH. *World Journal of Modeling and Simulation*, Vol. 2, No. 4, pp 213-221.
- Farlow, S.J. (1984). Self-organizing methods in modeling. GMDH Type Algorithms. New York and Basel, Marcel Dekker, Inc.
- Fernandez-Rodriguez, Fernando, Gonzalez-Martel, Christian, Sosvilla-Rivero, Simon. (2000). On the Profitability of Technical Trading Rules Based on Artificial Neural Networks: evidence from the Madrid stock market. *Economics Letters* 69 (1), pp. 89-94
- Franses, Philip Hans, van Griensven, Kasper. (1997). Forecasting Exchange Rates using Neural Networks for Technical Trading Rules. *Studies in Nonlinear Dynamics and Econometrics* 2 (4), pp 108-114.
- Gencay, Ramazan. (1996). Non-linear Prediction of security Returns with Moving Average Rules. *Journal of Forecasting* 15 (3), pp.165-174.
- Gencay, Ramazan. (1998a). The Predictability of Security Returns with Simple Technical Trading Rules. *Journal of Empirical Finance* 5 (4), pp 347-359.
- Gencay, Ramazan. (1998b). Optimization of Technical Trading Strategies and the Profitability in Security Markets. *Economics Letters* 59 (2), pp 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), pp. 94-107.
- Gencay, Ramazan, Stengos, Thanasis. (1998). Moving Average Rules, Volume and the Predictability of Security Returns with Feed Forward Networks. *Journal of Forecasting* 17 (5-6), pp.401-414.
- Goleusov, I.V and S.A. Kondrasheva. (1987). 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, pp.3943.

- Ivakhnenko, A.G. (1971). Polynomial Theory of Complex System. IEEE Trans. Syst. Man & Cybern, SMC-1, pp. 364-378.
- Ivakhnenko, A.G.(1968). The group Method of data Handling; a rival of the Method of Stochastic Approximation. Soviet Automatic Control, 13(3),pp 43-55.
- Ivakhnenko. A.G and G.A. Ivakhnenko. (1995). The Review of Problems Solvable by Algorithms of the Group Method of Data Handling (GMDH). Pattern Recognition and Image Analysis, vol.5, no4 , pp 527-535.
- James C. Howland, Mark S. Voss ( 2003). Natural Gas Prediction Using The Group Method of Data Handling. ASC.
- Lemke. F and J.A. Muller. (1997). 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.
- Muller. J.A and G.A. Ivakhnenko. (199۶). Recent Developments of Self-organizing Modeling in Prediction and Analysis of Stock Market.available in URL address: <http://www.inf.kiev.ua/GMDHhome/articles/>.
- Nariman-zadeh, N.; Darvizeh, A.; Darvizeh, M.; Gharababaei, H. (2002). Modelling of Explosive Cutting Process of Plates Using GMDH-type Neural Network and Singular Value Decomposition. *Journal of Materials Processing Technology*, vol. 128, no. 1-3, pp 8۶7 , Elsevier Science.
- Neftci ,S.N. (1991). Naive Trading Rules in Financial Markets and Wiener-Kolmogorov prediction Theory: a study of technical analysis. *Journal of Business* 64 ,pp.549-571.
- Pandya. A.S, T. Kondp T.U. Shah and V.R. Gandhi. (1999). Prediction of Stock Market Characteristics Uses Neural Networks. in Proceedings of the SPIE. The International Society for Optical Engineering, vol.3722, pp 189-197.
- Scott. D.E. and C.E. Hutchinson. (1999). The GMDH Algorithm – a Technique for Economic Modeling. *Modeling and Simulation*, vol.7, pp 729-733.
- Shambora William E. Rossiter R. (2007). Are There Exploitable Inefficiencies in the Futures Market for Oil? *Journal of Energy Economics*, Volume: 29 pp: 18 27.
- Vasechkina, E.F. and Yarin, V.D. (2001). Evolving Polynomial Neural Network by Means of Genetic Algorithms: some Application Examples. *Complexity International*, Vol. 9.
- Water. P.R, S. Wibier, E.J.H. Kerckhoffs and H. Koppelaar. (199۷). GMDH-Based Stock Price Prediction. *Neural Network World*, vol.7, no4-5 , pp.552-563.