

فصل‌نامه‌ی مطالعات اقتصاد انرژی / سال هفتم / شماره‌ی ۲۴ / بهار ۱۳۸۹ / صفحات ۱۹۲ - ۱۷۱

پیش‌بینی قیمت گازوئیل خلیج فارس، مبتنی بر تحلیل تکنیکی و شبکه‌های عصبی

حمید ابریشمی

استاد دانشکده‌ی اقتصاد دانشگاه تهران abrishami@ut.ac.ir

حجت‌اله غنیمی فرد

استادیار دانشگاه صنعت نفت

مهدی احراری

پژوهشگر اقتصادی meahrari@yahoo.com

منیژه رضایی

کارشناس ارشد توسعه و برنامه‌ریزی اقتصادی دانشکده‌ی اقتصاد دانشگاه تهران

manizheh1983@yahoo.com

تاریخ دریافت: ۸۷/۱۰/۲۸ تاریخ پذیرش: ۸۸/۶/۲

چکیده

در این مقاله، از شبکه‌ی عصبی GMDH، برای پیش‌بینی قیمت گازوئیل مبتنی بر قواعد تحلیل تکنیکی، شامل میانگین‌های متحرک کوتاه مدت و بلندمدت، به عنوان ورودی شبکه، طی دوره‌های مختلف بازار، استفاده شده است. در این بررسی، هزینه‌های مبادله و عوامل برون‌زا لحاظ نشده است. در روش تحلیل تکنیکی، پیش‌بینی‌ها با تکیه بر رفتار گذشته‌ی قیمت در همان بازار (در این‌جا گازوئیل خلیج فارس) است. نتایج نشان می‌دهد که بهترین عملکرد پیش‌بینی در وضعیت باثبات بازار حاصل شده است. همچنین پیش‌بینی‌های شبکه‌ی عصبی نسبت به روش سری زمانی، از خطایکم‌تر و دقت بالاتری برخوردار است.

طبقه‌بندی JEL: Q47, C14, C15, C45, C53, C67, G17

کلیدواژه: شبکه‌ی عصبی GMDH، قیمت گازوئیل، پیش‌بینی، تحلیل تکنیکی

۱- مقدمه

بررسی روند مصرف گازوئیل در ایران حاکی از آن است که طی دوره‌ی ۸۶-۱۳۵۳، به جز مقطعی خاص که به دلیل جنگ یا تحولات اجتماعی میزان مصرف آن کاهش یافته، همواره با روندی رو به رشد مواجه بوده، به طوری که از ۱۷/۵ میلیون لیتر در روز، به ۸۷/۳ میلیون لیتر در روز افزایش داشته، که معادل رشد متوسط سالانه ۲/۴۵ درصد است. در یک نگاه کلی می‌توان گفت که شکاف بین تولید و مصرف طی سال‌های ۱۳۶۹-۱۳۷۶، ناشی از کاهش تولید نسبت به مصرف بوده است و برای جبران آن واردات گازوئیل داشته‌ایم. از سال ۸۳-۱۳۷۷، تولید به اندازه‌ای بوده که هم مصرف داخلی را تامین کرده و هم صادرات انجام شده است. متأسفانه از سال ۱۳۸۴، به دلیل افزایش مصرف، مجبور به واردات این محصول شده‌ایم.

با توجه به اهمیت پیش‌بینی در حوزه‌ی مسائل مالی و اقتصادی، محققان همواره در تلاشند که از روش‌های دقیق‌تری در این زمینه بهره‌گیرند تا به درک نسبی بهتری از وضعیت آینده‌ی بازار دست یافته و از ناطمینانی‌ها بکاهند. این مقاله سعی دارد تا با ارزیابی روشی دقیق‌تر نسبت به سایر روش‌های تجربه شده در حوزه‌ی پیش‌بینی بازار نفت و فرآورده‌های نفتی، به پیش‌بینی قیمت گازوئیل در خلیج فارس بپردازد، چرا که پیش‌بینی‌های صحیح قیمت این محصول در بازار خلیج فارس، به تصمیم‌گیری‌های مناسب در احداث واحدهای جدید تولید و یا میزان استفاده از ظرفیت تولید کنونی در کشورمان کمک می‌کند.

از دیرباز و به‌خصوص در چند دهه‌ی گذشته پیش‌بینی وقایع و درک آینده‌ی زمینه‌ی تحقیقات بسیاری بوده است. نتیجه‌ی این تلاش‌ها، روش‌های متنوعی است که بیش‌تر بر پایه‌ی مدل‌های آماری و اقتصادسنجی بنا شده‌اند. اما در مقابل این روش‌ها، روش دیگری است که از آن به عنوان شبکه‌های عصبی مصنوعی^۱ نام برده می‌شود. اگر چه روش‌های آماری و اقتصادسنجی، در زمینه‌ی پیش‌بینی سری‌های زمانی عملکرد نسبتاً خوبی داشته‌اند، اما در عین حال دارای محدودیت‌هایی نیز هستند. اول آن که ممکن است در این گونه روش‌ها فرم تبعی^۲ متغیرهای مستقل و وابسته در صورت

1- Artificial Neural Network.
2- Functional Form.

عدم شناخت کافی به درستی تصریح نشود. دوم آن که داده‌های پرت^۱ ممکن است به تخمین اریب پارامترهای مدل بیانجامد. به علاوه، بیش تر مدل‌های سری زمانی، خطی بوده و بنابراین در توضیح رفتارهای غیرخطی ناتوان‌اند. از این رو می‌توان با استفاده از شبکه‌های عصبی برای مشکلات فائق آمد و محدودیت‌های مذکور را به حداقل رساند. روش برگزیده‌ی این مقاله برای پیش بینی قیمت گازوئیل، نوع خاصی از شبکه‌های عصبی، موسوم به دسته‌بندی گروهی داده‌های عددی GMDH^۲ است که بر اساس فرآیند خودسازماندهی و ارزیابی داده‌ها به صورت جداگانه با استفاده از معیار خارجی^۳ برای مدل‌سازی‌های پیچیده کاربرد دارد. متغیرهایی که روی فرآیند تأثیر می‌گذارند، می‌توانند به عنوان ورودی شبکه مورد استفاده قرار گیرند. سپس الگوریتم GMDH، با بررسی و کشف روابط بین آن‌ها و آزمون مدل‌های پیشنهادی به طور هوشمند، مدل بهینه‌ای را ارائه و متغیر خروجی را پیش بینی می‌کند. بنابر این، در این مقاله با استفاده از داده‌های عددی تجربی، مدل عددی مبتنی بر داده‌های تجربی، با استفاده از شبکه‌های عصبی از نوع GMDH، ارائه شده است.

در بخش ۲، پیشینه‌ی تحقیقات انجام گرفته در این زمینه را بررسی خواهیم کرد. روش شبکه‌ی عصبی GMDH در بخش ۳ شرح داده شده است. در بخش ۴، نتایج پیش‌بینی قیمت گازوئیل با روش GMDH و ARIMA با هم مقایسه می‌شود و بخش ۵، که در برگزیده‌ی نتیجه‌گیری است، پایان بخش مقاله خواهد بود.

۲- پیشینه‌ی تحقیقات

الگوریتم GMDH، اولین بار توسط ایواخنکو^۴ (۱۹۶۸)، برای مدل کردن سیستم‌های پیچیده‌ای که شامل یک سری داده‌ها با چندین ورودی و یک خروجی بودند، مورد استفاده قرار گرفت. در حقیقت هدف اصلی، ساختن تابعی در یک شبکه براساس تابع انتقال درجه‌ی دوم است.

تاکنون در مورد به کارگیری شبکه‌ی عصبی GMDH در اقتصاد مقالات بسیاری انتشار یافته است. از جمله زمینه‌های اولیه‌ی تحقیقاتی که مورد استفاده قرار گرفت،

1- Outliers.

2- Group Method of Data Handling.

3- External Criterion.

4- Ivakhnenko .

می‌توان به شناسایی و پیش‌بینی بازارهای مالی اشاره کرد. بر اساس نظر اسکات و هاچیسون^۱ (۱۹۹۹)، روش‌های معمول به دلیل عدم توانایی در طرح یک تکنیک معین جهت انتخاب متغیر ورودی، شکست خورده به حساب می‌آیند. این‌گونه سیستم‌ها به دلیل ماهیت غیرخطی خود، قادر به توضیح ارتباطات کوچک میان متغیرها و عکس‌العمل آن‌ها نسبت به هم نیستند. از این رو به نظر می‌رسد که GMDH در این زمینه بسیار کارساز عمل کرده باشد.

مولر و ایواخنکو^۲ (۱۹۹۶) در مقاله‌ای، آخرین دستاوردهای شبکه‌ی عصبی GMDH در پیش‌بینی و تحلیل بازار سهام را ارائه کردند. واتر و همکاران^۳ (۱۹۹۷)، قیمت سهام را با این نوع شبکه‌ی عصبی پیش‌بینی کردند، که از دقت بالایی برخوردار بود. لمکه^۴ 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 مرحله‌ی بعد با طراحی یک مکانیسم "کنترل فرآیندی"، پیش‌بینی‌ها را به سیگنال‌های خرید و فروش تبدیل کردند. پانديا و همکاران^۵ (۱۹۹۹)، به پیش‌بینی شاخص‌های بازار سهام با استفاده از این نوع شبکه‌ی عصبی پرداختند. هاولند و وس^۶ (۲۰۰۳) در مقاله‌ای، به پیش‌بینی میزان جریان گاز طبیعی از مخازن را پرداختند. مالیک و نصرالدین^۷ (۲۰۰۵) در مطالعه‌ی خود، روش شبکه‌ی عصبی آبخاری^۸ را معرفی کرده و از این روش جهت پیش‌بینی نوسانات قیمت نفت بر روی GDP استفاده و نتایج حاصل از آن را با مدل گام تصادفی، مدل اتورگرسیو و مدل خطی مقایسه کردند. نتیجه‌ی این‌که، آن‌ها استفاده از شبکه‌ی عصبی را به عنوان ابزاری قدرتمند در جهت پیش‌بینی معرفی می‌کنند. معینی و همکاران (۱۳۷۸)، از رویکرد هوشمند تلفیقی مشتمل بر شبکه عصبی GMDH و الگوریتم ژنتیک و بهینه‌سازی چند منظوره برای تحلیل قیمت پیش‌خرید و پیش‌فروش نفت خام به منظور محاسبه حداکثر عایدی حاصل از پیش‌بینی در روندهای مختلف بازار مبتنی بر قواعد تحلیل تکنیکی استفاده کردند. نتایج نشان داد روند

1- Scott & Hutchinson.
2- Muller & Ivakhnenko.
3- Water et al.
4- Lemke.
5- Pandya et al.
6- Howland & Voss.
7- Malik & Nasereddin.
8- Cascaded artificial neural net work.

صعودی دارای بیشترین عایدی و روند بی ثباتی توأم با تغییر، کمترین عایدی را دارد. سرینی واسان^۱ (۲۰۰۸)، تقاضای انرژی را با دو نوع شبکه‌ی عصبی پیش بینی 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 پیش بینی قیمت بنزین با دو روش قیاسی و قواعد تحلیل تکنیکی، 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 کوتاه‌مدت و بلندمدت بود. نتایج نشان از دقت بیش از ۹۶٪ پیش بینی و پایداری روش قیاسی و بیش از ۹۹٪ تحلیل تکنیکی داشت. هم‌چنین در مقایسه‌ی معیارهای خطا، دقت پیش‌بینی‌های شبکه‌ی عصبی GMDH، به‌طور معنی‌داری از الگوی رگرسیونی بهتر بود.

۳- مدل‌سازی با استفاده از شبکه‌های عصبی GMDH

برخلاف مدل‌سازی تحلیلی و تئوریک که تمامی اجزای سیستم معرفی شده و تنها لازم است که ارتباط اجزا برقرار و نیز تجزیه و تحلیلی از کل مجموعه ارائه شود، در مدل‌سازی عددی، اجزای سیستم مجهول بوده و تنها ورودی و خروجی آن در دسترس است. در مدل‌سازی عددی مبتنی بر شناسایی^۲ سیستم سعی داریم که با استفاده از اطلاعات ورودی و خروجی آن را شناسایی کنیم، که حاصل این شناسایی با ایجاد یک تابع تقریبی ریاضی میان ورودی و خروجی که همان مدل سیستم می‌باشد، توأم است. به طور کلی مسائل شناسایی سیستم بدین گونه مطرح می‌شود که فرض می‌کنیم رابطه‌ی خروجی (y) یک سیستم ناشناخته، با m ورودی به صورت $y = f(x_1, x_2, x_3, \dots, x_m)$ باشد. با داشتن N نمونه از این داده‌های ورودی و خروجی، سیستم همانند:

1- Srinivasan.
2- Identification.

<i>input</i>				<i>output</i>
x_{11}	x_{12}	x_{13}	x_{1m}	y_1
x_{21}	x_{22}	x_{23}	x_{2m}	y_2
.....			
x_{N1}	x_{N2}	x_{N3}	x_{Nm}	y_N

عمل شناسایی را می‌تواند انجام دهد، که نتیجه‌ی آن تقریب تابع \hat{f} است که به موجب آن می‌توان به ازای بردار ورودی $(x_1, x_2, x_3, \dots, x_m)$ مقدار خروجی \hat{y} را تقریب زد. شناسایی سیستم با به‌کار بردن روش‌ها و الگوریتم‌های متفاوت همراه با اجزای هوش محاسباتی امکان‌پذیر است، ولی آن‌چه به‌طور معمول به‌عنوان هدف مشترک روش‌های شناسایی سیستم مطرح است، کمینه کردن مجموع مربعات خطا به ازای N نمونه می‌باشد.

روش دسته‌بندی گروهی داده‌های عددی GMDH، یک فن آوری آموزش آماری شبکه‌ای است. این روش یک روش مدل‌سازی آماری کلاسیک نیست، بلکه فرآیندی منظم برای غلبه بر ضعف‌های آماری و شبکه‌های عصبی مصنوعی است. (اناستاساکیس^۱، ۲۰۰۱). مدل‌های خطی و غیرخطی احتمالی یا خوشه‌سازی شده، با کمینه شدن یک معیار خارجی به‌دست می‌آیند. الگوریتم‌های دسته‌بندی نسبتاً ساده‌اند و این الگوریتم‌ها اطلاعات خود را مستقیماً از داده‌های ورودی دریافت می‌کنند. متغیرهای مؤثر ورودی، تعداد لایه‌ها و نرون‌ها در لایه‌های پنهان و ساختار بهینه‌ی مدل به صورت خودکار تعیین می‌شوند. این کار بر اساس کمینه‌سازی معیار خارجی در حین کامل شدن ساختار انجام می‌شود. GMDH، یک روش استقرایی است که با شبکه‌ها و تکنیک‌های قیاسی که عموماً استفاده می‌شوند، تفاوت دارد. GMDH، برای مدل‌سازی سیستم‌های پیچیده و پیش‌بینی فرآیندهای چند متغیره، کاربردهای فراوانی دارد (ایواخنکو، ۱۹۹۵).

1- Anastasakis.

شبکه‌های عصبی GMDH حاوی مجموعه‌ای از نرون‌ها هستند که از پیوند جفت‌های مختلف از طریق یک چند جمله‌ای درجه‌ی دوم به وجود می‌آیند. شبکه با ترکیب چند جمله‌ای‌های درجه‌ی 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 داده‌ی آزمایشگاهی، شامل n ورودی و یک خروجی، نتایج واقعی به شکل رابطه‌ی (۱) نمایش داده می‌شوند:

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

ما به دنبال شبکه‌ای هستیم که بتواند مقدار خروجی \hat{y} را، برای هر بردار ورودی X ، مطابق رابطه‌ی (۲) پیش بینی 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 عبارت 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 رابطه‌ی (۴) بیان کرد،

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

که چند جمله‌ای ایواخنکو نامیده می‌شود. در بسیاری از موارد کاربردی از شکل درجه‌ی دوم و دو متغیره‌ی این چند جمله‌ای به صورت معادله‌ی (۵) استفاده می‌شود.

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

ضرائب مجهول a_i در معادله‌ی (۵) با تکنیک‌های رگرسیونی چنان به دست می‌آیند که اختلاف بین خروجی واقعی y و مقادیر محاسبه شده‌ی \hat{y} ، برای هر جفت متغیر ورودی x_i و x_j ، کمینه شود. مجموعه‌ای از چند جمله‌ای‌ها با استفاده از معادله‌ی (۵) ساخته می‌شوند که ضرائب مجهول همه‌ی آن‌ها، با استفاده از روش حداقل مربعات (LS) به دست می‌آید. برای هر تابع G_i (هر نرون ساخته شده)، ضرائب معادلات هر نرون برای حداقل کردن خطای کل آن، به منظور انطباق بهینه‌ی ورودی‌ها بر تمام جفت مجموعه‌های ورودی - خروجی، به دست می‌آیند (فارلو^۱، ۱۹۸۴):

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

در روش‌های پایه‌ای الگوریتم GMDH، تمامی ترکیبات دوتایی (نرون‌ها) از n متغیر ورودی ساخته شده و ضرایب مجهول تمامی نرون‌ها با استفاده از روش حداقل مربعات به دست می‌آیند. بنابراین $\binom{n}{2} = \frac{n(n-1)}{2}$ نرون در لایه‌ی دوم ساخته می‌شوند که آن را می‌توان به شکل مجموعه‌ی (۷) نمایش داد.

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

از شکل درجه‌ی دوم تابع بیان شده در معادله‌ی (۵)، برای هر M ردیف سه تایی استفاده می‌کنیم، این معادلات را می‌توان به شکل ماتریسی (۸) بیان کرد:

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

که در آن A ، بردار ضرایب مجهول معادله‌ی درجه‌ی دو نشان داده شده در معادله‌ی (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:

1- Farlow.

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

روش حداقل مربعات از آنالیز رگرسیون چندگانه^۱، حل معادلات را به شکل معادله‌ی (۱۲) به دست می‌دهد:

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

این معادله، بردار ضرایب معادله‌ی (۵) را برای تمام M مجموعه‌ی سه تایی ایجاد می‌کند.

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

مسئله طراحی شبکه‌های 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 است، به گونه‌ای که با تغییر این پارامتر، ساختار شبکه‌ها نیز تغییر کند. روش‌های تکاملی^۲ 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 فضاها‌ی غیر قابل پیش بینی، دارند (نریمان زاده و همکاران ۲۰۰۲ و ۲۰۰۳). در تحقیق حاضر، برای طراحی شکل شبکه‌ی عصبی و تعیین ضرایب آن، از الگوریتم ژنتیک استفاده شده است.

1- multiple-regression.
2- Evolutionary.

۴- پیش‌بینی قیمت گازوئیل مبتنی بر تحلیل تکنیکی و شبکه‌ی عصبی GMDH

مهم‌ترین بازارهای سازمان یافته‌ی بورس در جهان برای گازوئیل، بازار بورس نفت نیویورک (نایمکس^۱) و بازار بورس لندن (ICE^۲) هستند. بازار بورس نایمکس در سال ۱۸۷۲ تاسیس شده و نخست محل مبادله‌ی کالاهای کشاورزی و فلزات قیمتی بوده است، اولین قرارداد مربوط به فرآورده‌های نفتی، در سال ۱۹۸۷ و در قالب قراردادهای آتی (پیش خرید و پیش فروش) برای تحویل گازوئیل در بندر نیویورک بسته شد. پس از آن قرارداد دیگری در سال ۱۹۸۱ با همان ویژگی برای بنزین بسته شد. در پی موفق عمل کردن این قراردادها، معامله‌گران نفتی به آن توجه بیش‌تری کردند و در پی آن نخستین قرارداد آتی نفت خام وست تگزاس اینترمدیت^۳ قابل تحویل در ایالت اوکلاهاما، در مارس ۱۹۸۳ منعقد شد. این بازار با معرفی قراردادهای اختیاری در نوامبر ۱۹۸۶، مورد توجه خاص قرار گرفت، به گونه‌ای که پس از یک ماه (یعنی در دسامبر همان سال)، حجم قراردادهای اختیاری نفت خام به ۵۴۹۰۹ قرارداد، با حجم نفتی ۵۵ میلیون بشکه رسید. در سال ۱۹۹۰ نیز قراردادهای آتی مربوط به گاز طبیعی در این بورس، معرفی و مورد معامله قرار گرفت. در دهه‌ی ۱۹۹۰، این بازار به گونه‌ای به سیستم‌های رایانه‌ای مجهز شد که معامله در ساعات تعطیلی بورس نیز امکان پذیر شد. سیستم الکترونیکی "اکسز"، مبادلات مزبور به قراردادهای آتی را پوشش می‌دهد. در بازار بورس نایمکس گازوئیل حرارتی^۴ معامله می‌شود و معامله از ۹ صبح الی ۲:۳۰ بعدازظهر انجام می‌پذیرد.

بازار بورس لندن برای نخستین بار در آوریل ۱۹۸۱ بر روی قراردادهای آتی انرژی گشایش یافت. اولین قرارداد آن مربوط به گازوئیل برای تحویل در بندر روتردام بود. در روز اول گشایش، تعداد قراردادهای مربوط به گازوئیل به ۸۰۷ قرارداد رسید. این بازار به دلیل عقب ماندن از تکنولوژی روز، در مقایسه با نایمکس، در سال‌های اخیر دچار ضعف شده است به گونه‌ای که چند گزینه و پیشنهاد برای خرید سهام توسط برخی شرکت‌های دست اندر کار مسائل انرژی و هم‌چنین بازار بورس نایمکس جهت ادغام آن ارائه شده است. در جون ۲۰۰۱، بازار بورس لندن که دومین بازار بزرگ انرژی در جهان است، از IPE به ICE تغییر نام یافت.^۵

1- New York Mercantile Exchange(NYMEX).

2- International Commercial Exchange.

3- West Texas Intermediate.

4- Heating oil.

5- PVM Consulting Company.

بر اساس بررسی های انجام گرفته، قیمت های گازوئیل بازار خلیج فارس به عنوان یکی از معیارهای اصلی در تعیین قیمت پایه ای معاملات در بازار هندوستان است و از آنجا که بیشترین واردات گازوئیل ایران از هندوستان انجام می گیرد، بنابراین در این مقاله به پیش بینی قیمت های گازوئیل خلیج فارس به عنوان متغیر خروجی خواهیم پرداخت.

آمار مربوط به قیمت های گازوئیل بازار بورس خلیج فارس، سنگاپور و نیویورک که در این تحقیق استفاده شده اند، از طریق نشریه بین المللی^۱ Plats، که مرکز انتشار آن نیویورک است و سایت اینترنتی سازمان اطلاعات انرژی امریکا (EIA)^۲، به دست آمده است. قیمت های گازوئیل در نظر گرفته شده برای انجام این تحقیق، به صورت روزانه و در بازه زمانی ۲ ژانویه ۲۰۰۴، الی ۱۹ نوامبر ۲۰۰۹ هستند.

با مروری بر روند قیمت ها در دو بازار بورس گازوئیل خلیج فارس و سنگاپور، مشاهده می شود که در دوره ای مورد نظر، قیمت ها همواره روندی افزایشی داشته اند. البته در ابتدای دوره با کمی نوسان همراه بود و سپس قیمت ها به کندی رو به افزایش گذاشته و از ماه جون تا اوت، حالتی آرام را داشته و سپس تا آخر این دوره قیمت ها به سرعت افزایش یافته و بازاری پر رونق داشته ایم.

یکی از متداول ترین قواعد تحلیل تکنیکی روش میانگین متحرک^۳ است که سری داده ها را هموار و زمینه را برای پیگیری روند داده ها فراهم می کند. میانگین های متعددی از سوی پژوهشگران ارائه شده است که ساده ترین آن ها میانگین متحرک ساده است که در آن میانگین n داده به طور عادی و بدون هیچ گونه اعمال وزنی محاسبه می شود. میانگین ها در تجزیه ای تحلیل فنی بازار نقشی اساسی و عمده دارند و براساس تئوری داو^۴، اولین اصل در بازار، مطالعه ای میانگین هاست. امروزه میانگین های متحرک یکی از کاربردی ترین شاخص های کامپیوتری بوده و به دلیل روش ساختاری و هم چنین حساسیت آن نسبت به تعیین کمی تصاویر و به کارگیری در آزمون ها، مبنای بیش تر سیستم های پیگیری روند مکانیکی است. به عنوان مثال برای محاسبه ای یک میانگین متحرک ۱۰ روزه، بایستی قیمت های ده روز اخیر را با یکدیگر جمع و حاصل جمع مزبور را بر عدد ۱۰ تقسیم کرد. واژه متحرک به این دلیل استفاده می شود که فقط

1- Macro Hill Plats.

2- www.eia.org.

3- Moving Average.

4- DOW.

قیمت‌های آخرین ده روز گذشته در محاسبه‌ی آن مورد استفاده قرار می‌گیرند. بنابراین برای این که مجموعه‌ی اطلاعات به صورت میانگین متحرک محاسبه شود، باید هم‌پای هر روز تجاری حرکت کرد. به عبارت دیگر در هر روز میانگین قیمت‌های ده روز گذشته را مطالعه می‌کنیم. در حقیقت میانگین متحرک یک ابزار یکنواخت کننده است که با استفاده از میانگین قیمت‌ها، ارقام بالا و پائین کنار هم گذاشته می‌شوند تا روند اساسی بازار به سادگی قابل تشخیص شود. به منظور توضیح چگونگی استفاده از میانگین‌های متحرک ساده، بحث خود را با یک میانگین ده روزه ساده شروع می‌کنیم. متوسط قیمت‌های روزانه‌ی آخرین ده روز را محاسبه و سپس به کمک نمودار میله‌ای آن را با قیمت‌های بسته شده‌ی بازار مقایسه می‌کنیم. اگر قیمت‌های بسته شده‌ی بازار بالاتر از میانگین متحرک ساده مزبور قرار گیرد، علامت خرید و اگر پائین‌تر از میانگین متحرک ساده قرار گیرد، علامت فروش است. برای محاسبه‌ی میانگین‌های متحرک، از میانگین حسابی، مطابق رابطه‌ی زیر استفاده می‌کنیم:

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

که در آن P_t ، قیمت در لحظه‌ی t ، P_{t-i} قیمت در i روز قبل از آن است، n تعداد روزها و 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 ورودی‌های مؤثر در آرایه‌ی سیگنال معاملاتی، تفاوت میانگین‌های متحرک کوتاه مدت و بلندمدت هستند (جن کی^۱، ۱۹۹۸ و شامبورا و روزیتر^۲، ۲۰۰۷).

ورودی‌های مدل بر اساس قواعد تحلیل تکنیکی که مبتنی بر معیار میانگین متحرک کوتاه مدت و بلندمدت قیمت گازوئیل خلیج فارس است، به شرح ذیل تعریف می‌شوند:

- ۱- میانگین‌های متحرک ۵ و ۵۰ روزه .
- ۲- میانگین‌های متحرک ۵ و ۵۰ روزه با یک وقفه
- ۳- میانگین‌های متحرک ۵ و ۵۰ روزه با دو وقفه

1- Gencay.

2- Shambora & Rossiter.


۴- تفاوت میانگین متحرک ۵ با یک وقفه و ۵۰ روزه با یک وقفه

۵- تفاوت میانگین متحرک ۵ با دو وقفه و ۵۰ روزه با دو وقفه

بر اساس متغیرهای فوق، قیمت گازوئیل را برای چهار روند موجود در بازار شامل: روند صعودی، نزولی، نوسانی^۱ و هموار^۲ مدل سازی و در هر حالت متغیر مؤثر را شناسایی و در نهایت پیش بینی می کنیم.

● روند صعودی

ورودی مؤثر بر لگاریتم نرخ بازگشت قیمت روزانه‌ی بازار گازوئیل خلیج فارس، به‌عنوان خروجی مدل با دو لایه‌ی پنهان، شامل میانگین متحرک قیمت ۵ روز قبل با یک وقفه، تفاوت میانگین متحرک قیمت ۵ روز قبل و میانگین متحرک قیمت ۵۰ روز قبل، تفاوت میانگین متحرک قیمت ۵ روز قبل با یک وقفه و میانگین متحرک ۵۰ روز قبل با یک وقفه، تفاوت میانگین متحرک قیمت ۵ روز قبل با دو وقفه و میانگین متحرک قیمت ۵۰ روز قبل با دو وقفه است. نمودار(۱)، مقادیر پیش‌بینی و واقعی قیمت گازوئیل خلیج فارس در روش تحلیل تکنیکی، برای روند صعودی را نشان داده است.

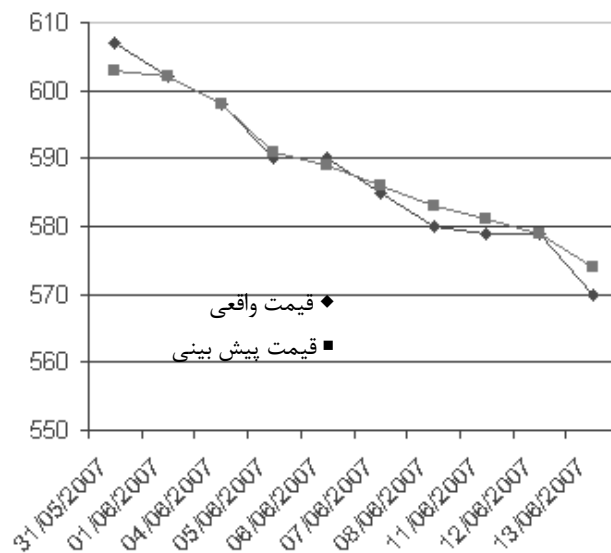


نمودار(۱)- مقایسه‌ی قیمت‌های واقعی و پیش‌بینی شده‌ی گازوئیل در بازار خلیج فارس در روش تحلیل تکنیکی برای روند صعودی قیمت‌ها

1- Fluctuate.
2- Smooth .

• روند نزولی

ورودی مؤثر بر لگاریتم نرخ بازگشت قیمت روزانه بازار گازوئیل خلیج فارس، به‌عنوان خروجی مدل با دو لایه‌ی پنهان شامل: میانگین متحرک ۵ روز قبل، میانگین ۵ روز قبل با یک و دو وقفه و تفاوت میانگین متحرک ۵ و ۵۰ روز با دو وقفه است. در نمودار (۲)، مقادیر پیش‌بینی و واقعی قیمت گازوئیل خلیج فارس در روش تحلیل تکنیکی، برای روند نزولی قیمت‌ها، نشان داده شده است.




نمودار ۲- مقایسه‌ی قیمت‌های واقعی و پیش‌بینی شده‌ی گازوئیل در بازار خلیج فارس در روش تحلیل تکنیکی، برای روند نزولی قیمت‌ها

• روند نوسانی

ورودی مؤثر بر لگاریتم نرخ بازگشت قیمت روزانه بازار گازوئیل خلیج فارس، به عنوان خروجی مدل با دو لایه‌ی پنهان شامل: میانگین متحرک ۵ روز قبل با یک و دو وقفه، میانگین متحرک ۵۰ روز قبل، تفاوت میانگین متحرک ۵ و ۵۰ روز قبل، تفاوت میانگین متحرک ۵ روز قبل با یک وقفه و ۵۰ روز قبل با یک وقفه است. نمودار

۱۸۵ پیش بینی قیمت گازوئیل خلیج فارس، مبتنی بر تحلیل تکنیکی و شبکه عصبی

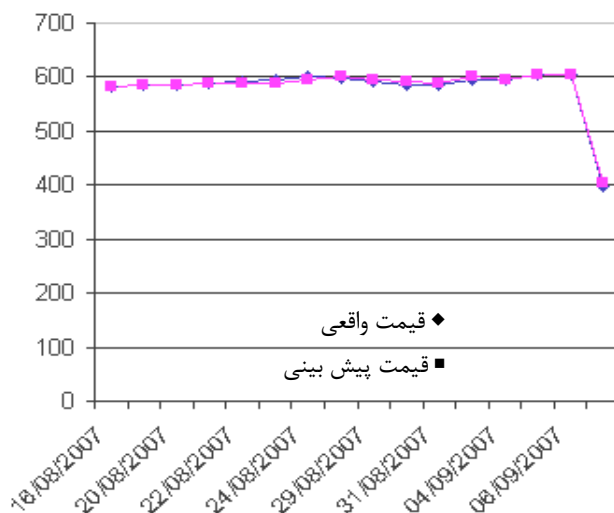
(۳)، مقادیر پیش‌بینی و واقعی قیمت گازوئیل خلیج فارس برای روند نوسانی را نشان می‌دهد.



نمودار ۳- مقایسه‌ی قیمت‌های واقعی و پیش‌بینی شده‌ی گازوئیل در بازار خلیج فارس در روش تحلیل تکنیکی، برای روند نوسانی قیمت‌ها

• روند هموار

ورودی مؤثر بر لگاریتم نرخ بازگشت قیمت روزانه‌ی بازار گازوئیل خلیج فارس، به‌عنوان خروجی مدل با دولایه‌ی پنهان شامل: میانگین متحرک ۵ روز قبل، میانگین متحرک ۵ روز قبل با یک وقفه، میانگین متحرک ۵۰ روز قبل، میانگین متحرک ۵۰ روز قبل با دو وقفه، تفاوت میانگین متحرک ۵ و ۵۰ روز قبل، تفاوت میانگین متحرک ۵ روز قبل با یک وقفه و میانگین متحرک ۵۰ روز قبل با یک وقفه است. در نمودار (۴)، مقادیر پیش‌بینی و واقعی قیمت گازوئیل خلیج فارس در روش تحلیل تکنیکی در حالت هموار قیمت‌ها، نشان داده شده است.



نمودار ۴- مقایسه‌ی قیمت‌های واقعی و پیش‌بینی شده‌ی گازوئیل در بازار خلیج فارس در روش تحلیل تکنیکی برای روند هموار قیمت‌ها

در جدول (۱)، روندهای چهارگانه‌ی مذکور بر اساس معیار خطا رتبه‌بندی شده‌اند.

جدول ۱- رتبه‌بندی روندهای بازار براساس معیار خطا

*RMSE	نوع روند	رتبه
۲/۵	هموار	۱
۲/۸	صعودی	۲
۳/۱	نزولی	۳
۳/۹	نوسانی	۴

* ریشه‌ی میانگین مربع خطا Root Mean Square Error

ملاحظه می‌شود که بهترین عملکرد پیش‌بینی، مربوط به روند هموار بازار است و در وضعیت نوسانی که بی‌ثباتی بر بازار حاکم است، پیش‌بینی‌ها از دقت کم‌تری (نسبت به وضعیت باثبات بازار) برخوردار است. به عبارت بهتر، هرچه قدر حالت سیستم پایدارتر باشد، پیش‌بینی‌ها دقت بیشتری خواهند داشت.

مزیت‌های الگوریتم GMDH و مقایسه‌ی نتایج حاصل از روش ARIMA

از جمله برتری شبکه‌ی عصبی GMDH در مقایسه با روش‌های رگرسیونی، توانایی این الگوریتم در مدل‌سازی غیرخطی است، که به واسطه‌ی آن پیچیدگی‌های مدل در توضیح دهندگی روابط غیرخطی متغیرهای توضیحی و متغیر خروجی افزایش می‌یابد. از دیگر مزیت‌های الگوریتم GMDH، فرآیند هوشمند غربال‌سازی ورودی‌های شبکه است، به طوری که ورودی‌هایی را که نسبت به سایر متغیرها اثرگذاری کم‌تری بر متغیر خروجی دارند، شناسایی و از مدل خارج می‌کند.

به طور کلی محدودیت‌های استفاده از روش‌های رگرسیونی که در الگوریتم شبکه‌ی عصبی وجود ندارد را می‌توان به صورت زیر خلاصه کرد:

الف) هم‌خطی از جمله مشکلاتی است که معمولاً در رگرسیون‌های معمولی بروز می‌کند. هم‌خطی هم می‌تواند میان متغیرهای مختلف توضیحی وجود داشته باشد، چنان‌چه یک متغیر از فرآیند AR تبعیت کند، لحاظ هم‌زمان وقفه‌های آن متغیر در مدل، می‌تواند با ایجاد هم‌خطی، بر معنی‌داری پارامترهای تخمینی اثر گذارد.


ب) در روش‌های رگرسیونی، استفاده از وقفه‌های متغیر وابسته به دلیل وجود رابطه‌ی میان جزء اخلاص و متغیر توضیحی، فرض استقلال متغیر توضیحی از جزء اخلاص را نقض و برآوردها را دچار تورش می‌کند.

ج) در مدل‌سازی رگرسیونی، محقق نمی‌تواند به دلخواه خود متغیرهای توضیحی را افزایش دهد، چرا که اضافه کردن یک متغیر توضیحی اولاً نیازمند تصریح تئوری بر لحاظ آن متغیر بوده و ثانياً درجه‌ی آزادی را کاهش می‌دهد و به خصوص در شرایطی که محقق با کمبود مشاهدات نیز روبه‌رو باشد، دقت مدل و قابلیت تعمیم دهی آن را به شدت تحت تأثیر قرار می‌دهد.

این روش معایبی هم دارد که به طور اجمالی می‌توان به موارد زیر اشاره کرد:

الف) از آنجایی که الگوریتم GMDH یک فرآیند اکتشافی بوده و مبتنی بر یک تئوری اثباتی نیست، بنابراین نمی‌توان قابلیت اطمینان تخمین‌های ضرایب چندجمله‌ای ایواخنکو را ثابت کرد، همان‌گونه که قادر نیستیم اثبات کنیم که بر اساس چه معیاری مشاهدات مجموعه‌های کنترل و آموزش را انتخاب می‌کنیم. حال آن‌که با روش‌های رگرسیونی می‌توان تحلیل‌های نظری و سیاستی را انجام داد.

ب) گرچه الگوریتم GMDH روابط خوبی را بین متغیرهای ورودی و خروجی می‌سازد، اما لزوماً یک مدل ساختاری درست را به ما نخواهد داد. برای پیش‌بینی قیمت با روش ARIMA، از لگاریتم قیمت گازوئیل و تفاضل مرتبه‌ی اول آن استفاده شده است که به این ترتیب متغیر مانا شده است. پیش‌بینی‌ها به جهت امکان مقایسه با روش GMDH تکنیکی برای یک سوم انتهایی داده‌ها انجام گرفته است. نمودار (۵) مقایسه نتایج پیش‌بینی و مقادیر واقعی قیمت گازوئیل با روش ARIMA را نشان می‌دهد.



نمودار ۵- مقایسه‌ی روند واقعی و پیش‌بینی شده در مدل‌سازی به روش ARIMA

در جدول (۲) نتایج حاصل از پیش‌بینی با روش ARIMA و GMDH را با هم مقایسه می‌کنیم.

جدول ۲- مقایسه نتایج پیش‌بینی GMDH و ARIMA

روش پیش‌بینی	RMSE	درصد خطای پیش‌بینی
GMDH	۳/۱	٪۰/۴
ARIMA	۱۵/۷	٪۲

همان طور که مشاهده می شود، بر اساس معیارهای خطا، پیش بینی با روش شبکه عصبی GMDH، به طور قابل توجهی برتر از مدل ARIMA است. مقدار عددی آماره ی آزمون مربوط به نسبت RMSE، در الگوهای رگرسیونی و شبکه ی عصبی برابر $F(10,10) = 5/064$ است، که بزرگ تر از مقدار بحرانی جدول $F(10,10) = 2/98$ می باشد. لذا تفاوت معنی داری بین این دو الگو وجود دارد و بنابراین شبکه ی عصبی GMDH از عملکرد به مراتب بهتری جهت پیش بینی رشد اقتصادی نسبت به الگوی های سری زمانی برخوردار است.

۵- نتیجه گیری

در این مقاله، مدل سازی و پیش بینی قیمت گازوئیل با استفاده از شبکه ی عصبی GMDH، مبتنی بر الگوریتم ژنتیک برای داده های روزانه بازار گازوئیل خلیج فارس با روش تحلیل تکنیکی انجام گرفت. نتایج پیش بینی قیمت گازوئیل خلیج فارس برای ۴ روند موجود در بازار نشان داد که بهترین عملکرد پیش بینی به ترتیب مربوط به روند هموار، صعودی، نزولی و نوسانی است. به عبارت دیگر، در وضعیت باثبات بازار پیش بینی های دقیق تری نسبت به روندهای بی ثبات و ناپایدار خواهیم داشت. با مقایسه ی معیارهای خطای به دست آمده از شبکه ی عصبی با مدل سری زمانی ARIMA، مشاهده می شود که کارایی الگوریتم GMDH در پیش بینی قیمت گازوئیل، به مراتب بهتر از مدل ARIMA است.

فهرست منابع

ابریشمی، معینی، مهرآرا، احراری و سلیمانی کیا، مدل سازی و پیش بینی قیمت بنزین با استفاده از شبکه ی عصبی GMDH، مبتنی بر الگوریتم ژنتیک، فصل نامه ی پژوهش های اقتصادی ایران، دانشکده ی اقتصاد دانشگاه علامه طباطبائی، شماره ی ۳۶، پائیز ۱۳۸۷.

معینی، علی، مهرآرا، محسن، احراری، مهدی، محاسبه هوشمند حداکثر عایدی در بازار پیش خرید و پیش فروش نفت خام، فصل نامه ی مطالعات اقتصاد انرژی، موسسه مطالعات بین المللی انرژی، شماره ی ۱۹، زمستان ۱۳۸۷.

Anastasakis L., "The Development of Self-Organization Techniques in Modelling: A Review of the Group Method of Data Handling (GMDH)", Research Report No.813, 2001

Farlow, Stanley J., 1984, "Self-Organizing Methods in Modeling: GMDH Type Algorithms", Marcel Dekker, Inc., New York, NY..Vol. 5.

Gencay, Ramazan, (1998), Moving Average Rules, Volume and the Predictability of Security Returns with Feedforward Networks. Journal of Forecasting 17 (56), 401-414.

Howland, J.C. and M.S. Voss, 2003, "Natural Gas Prediction Using the Group Method of Data Handling", ASC.

Ivakhnenko, A. G., 1968, "The Group Method of Data Handling: A Rival of the Method of Stochastic Approximation", Soviet Automatic Control: Vol.13.

Ivakhnenko, A. G., 1995, "Self-Organization of Neuro Net with Active Neurons for Effects of Nuclear Tests Explosions Forecasting", Systems Analysis Modeling Simulation: Vol. 20.

Ivakhnenko, A. G., G. A. Ivakhnenko, 2000, "Problems of Further Development of the Group Method of Data Handling Algorithms", Pattern Recognition and Image Analysis: Vol.10.

Lemke F, 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.

Malik, F., Nasereddin, M., Forecasting Output Using Oil Prices: A Cascaded Artificial Neural Network Approach, Journal of Economics and Business 58 (2006) 168–180.

Muller, J.A., and F. Lemke, 2003, "Self organizing Data Mining Extracting Knowledge from Data", Canada: Trafford Publishing.

Narimanzadeh, N., 2003, "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: Vol.217.

Narimanzadeh, N., A. Darvizeh, and H. Gharababaei, 2002, "Modeling of Explosive Cutting Process of Plates Using GMDH-type Neural Network and Singular Value Decomposition", Journal of Materials Processing Technology: Vol. 128.

Pandya, A. S., T. Kondo, T. U. Shah, and V. R. Gandhi, 1999, "Prediction of Stock Market Characteristics Using Neural Networks", The International Society for Optical Engineering: Vol.3722.

Scott, D.E. and Hutchinson, C.E. "The GMDH Algorithm – A technique for Economic Modeling", Modeling and Simulation, vol.7, pp.729-733, 1999.

Shambora William E. Rossiter R, (2007), "Are there Exploitable Inefficiencies in the Futures Market for Oil?", Journal of Energy Economics, Volume: 29 Page: 18-27.

Srinivasan, Dipti, Energy Demand Prediction Using GMDH Networks, Neurocomputing, 72 (2008) 625–629.

Water, Wibier, Kerckhoffs and Koppelaar, "GMDH-Based Stock Price Prediction", Neural Network World, vol.7, no.4-5, pp.552-563, 1997.

پیوست

نتایج خروجی مدل ARIMA برای پیش بینی قیمت گازوئیل.

Dependent Variable: D(Y)				
Method: Least Squares				
Date: 10/06/08 Time: 23:38				
Sample (adjusted): 2004 2041				
Included observations: 38 after adjustments				
Convergence achieved after 57 iterations				
Backcast: OFF (Roots of MA process too large)				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	2.730261	0.940312	2.903568	0.0065
AR(1)	0.088576	0.075711	1.169916	0.2504
AR(2)	0.089148	0.228334	0.390428	0.6987
MA(1)	0.662749	0.213323	3.106779	0.0039
MA(2)	-0.987610	0.325603	-3.033173	0.0047
R-squared	0.546472	Mean dependent var		2.342105
Adjusted R-squared	0.491498	S.D. dependent var		8.315652
S.E. of regression	5.929833	Akaike info criterion		6.519948
Sum squared resid	1160.376	Schwarz criterion		6.735420
Log likelihood	-118.8790	F-statistic		9.940703
Durbin-Watson stat	1.803923	Prob(F-statistic)		0.000022
Inverted AR Roots	.35	-.26		
Inverted MA Roots	.72	-1.38		
Estimated MA process is noninvertible				