

پیش‌بینی قیمت نفت با دو روش ARIMA و شبکه‌های عصبی مصنوعی

ایمان فرجامنیا*

محسن ناصری**

سید محمدمهری احمدی***

تاریخ پذیرش: ۱۳۸۶/۱/۲۸

تاریخ ارسال: ۱۳۸۵/۲/۲۳

چکیده

توانایی کم‌نظیر شبکه‌های عصبی مصنوعی به عنوان ابزاری قدرتمند برای تحلیل و برآورد در حوزه علوم تجربی و مهندسی موجب شد تا مورد توجه اقتصاددانان قرار گیرد. در این پژوهش، پس از مرور پژوهش‌های انجام‌شده در مورد تووانایی پیش‌بینی مدل‌های خود توضیح جمعی میانگین متحرک (ARIMA)^۱ و شبکه‌های عصبی مصنوعی (ANN)^۲ به مقایسه این دو روش برای پیش‌بینی قیمت روزانه نفت در دوره آوریل ۱۹۸۳ تا زوئن ۲۰۰۵ پرداخته‌ایم، افزون بر این، در این پژوهش پس از مدل‌سازی به وسیله شبکه‌های عصبی مصنوعی، به منظور تشخیص سهم مشارکت هر پارامتر ورودی در این مدل از تجزیه و تحلیل حساسیت استفاده کرده‌ایم، با توجه به حجم وسیع به کارگیری اطلاعات روزانه قیمت جهانی نفت (بیش از ۵۵۰۰ روز اطلاعات) نتایج به دست آمده نشان‌دهنده برتری غیرقابل مقایسه مدل شبکه‌های عصبی مصنوعی نسبت به مدل ARIMA در پیش‌بینی قیمت روزانه نفت است.

طبقه‌بندی JEL: Q۴ و E۴۷

واژگان کلیدی: سری‌های زمانی، شبکه‌های عصبی مصنوعی(ANN)، مدل ARIMA، آنالیز حساسیت.

E-mail: Emanfa75@yahoo.com

* کارشناسی ارشد اقتصاد و ارزی از دانشگاه تهران

** دانشجوی دکتری مهندسی عمران دانشگاه شیراز

*** دانشجوی کارشناسی ارشد اقتصاد نظری دانشگاه تهران

1. Autoregressive Integrated Moving Average

2. Artifical Neural Networks

مقدمه

موفقیت کمنظیر شبکه‌های عصبی مصنوعی به عنوان ابزاری قدرتمند برای تجزیه و تحلیل داده‌ها در علوم تجربی موجب شد تا مورد توجه اقتصاددانان نیز قرار گیرد. در آغاز، با توجه به نیاز این الگوها به داده‌های فراوان، پژوهش و مدل‌سازی در حوزه اقتصاد با استفاده از شبکه‌های عصبی در بازارهای مالی انجام و در سال‌های پایانی دهه ۱۹۸۰ میلادی مدل‌های مختلفی برای پیش‌بینی نرخ‌های ارز، قیمت سهام و شاخص‌های مختلف بورس ساخته شد. از جمله این کارها می‌توان به پژوهش وایت^۱ (۱۹۸۸)، که یک شبکه عصبی سه لایه را بر روی ۱۰۰۰ داده از قیمت سهام شرکت IBM به کار گرفت، اشاره کرد. هدف وایت به جای پیش‌بینی، آزمون فرضیه کلارآیی بازار بود. او نتوانست شواهدی را در مقابل نظریه‌ای که پیشنهاد می‌کند یک گام تصادفی^۲ بهترین مدل برای پیش‌بینی بازارهای مالی است، بیابد؛ اما شبکه استفاده شده وایت بسیار ساده بود. همین امر موجب شد نویسنده‌گان زیادی نتایج وی را به مجادله بگیرند و با استفاده از شبکه‌های پیچیده‌تر نشان دهند که در بسیاری از سری‌های زمانی مالی فرآیند غیرخطی معناداری وجود دارد. از جمله این کارها می‌توان به پژوهش‌های وانگ^۳ (۱۹۹۰)، تریپی و توریان^۴ (۱۹۹۰)، بوزا^۵ (۱۹۹۳)، تسبیوریس و زیدنیرگ^۶ (۱۹۹۵)، ریفنس و همکاران^۷ (۱۹۹۵) و همیسترا^۸ (۱۹۹۶) و نیز هافبک و هلمنسنین^۹ (۱۹۹۶) اشاره کرد.

هیل^{۱۰} و همکاران (۱۹۹۴) مجموعه‌ای از مقاله‌های تجربی و کاربردی را برای مقایسه نتایج پیش‌بینی شبکه‌های عصبی و مدل‌های آماری بررسی کردند. آنها همچنین با داده‌هایی با تکرار بیشتر (داده‌های ماهانه یا فصلی) نتایج بهتری را ارائه نمودند. این موضوع، پژوهشگران را به تفکر واداشت که داده‌هایی با تکرار بیشتر، فرآیندهای غیرخطی بیشتری دارند. در هر صورت، پژوهشگران به این نتیجه رسیدند که مقاله‌های نگارش شده در این زمینه، هنوز غیرقطعی است.

کهزادی و همکاران (۱۹۹۵) ضمن پیش‌بینی معاملات سلف ذرت، از مقایسه یک شبکه عصبی با یک مدل ARIMA با استفاده از معیارهای مختلف عملکرد پیش‌بینی، دریافتند که خطای پیش‌بینی مدل‌های شبکه عصبی بین ۱۸ تا ۴۰ درصد کمتر از مدل ARIMA است. کاکز^{۱۱} (۱۹۹۹) درستی

- 1.White
- 2.Rand m Walk
- 3.Wong
- 4.Trippi & Turban
- 5.Bosa
- 6.Tsibouris & Zeidenberg
- 7.Refenes
- 8.Hiemstra
- 9.Haefke & Helmenstein
- 10.Hill
- 11.Tkacz

مدل‌های خطی و شبکه‌های عصبی برای پیش‌بینی رشد GDP واقعی کانادا را با استفاده از سری شاخص‌های مالی مقایسه کرد. آنها ابراز داشتند که شبکه‌های عصبی می‌توانند فرآیندهای غیرخطی میان رشد تولید ناخالص داخلی واقعی و شاخص‌های مالی را به خوبی نشان دهند. مشیری و کامرون^۱ (۲۰۰۰) عملکرد شبکه‌های عصبی مصنوعی را با روش‌های دیگر اقتصادستنجی سنتی و سری‌های زمانی، برای پیش‌بینی نرخ تورم کانادا مقایسه کردند. در این مقاله آنها مدل‌های شبکه‌های عصبی را با مدل‌های ساختاری، ARIMA، BVAR و VAR برای افق‌های زمانی مختلف (یک، سه و دوازده ماه بعد) و میانگین مربع خطاهای (RMSE) و میانگین قدر مطلق خطاهای (MAE)، نشان دادند که شبکه‌های عصبی قادر است به خوبی تمام روش‌های اقتصادستنجی سنتی و سری‌های زمانی و در برخی از موارد بهتر از آنها نرخ تورم کانادا را پیش‌بینی کند. ورکویجن^۲ (۱۹۹۶) دقت مدل‌های مختلف برای پیش‌بینی نرخ مبادله دلار آمریکا به مارک آلمان در افق‌های زمانی ۱ تا ۳۶ ماه بعد را با یکدیگر مقایسه کرد. وی اذعان داشت که در پیش‌بینی، مدل‌های شبکه‌های عصبی از مدل‌های رگرسیون خطی و پیش‌بینی‌های گام تصادفی، به ویژه در افق‌های زمانی طولانی‌تر، دقیق‌تر بودند. هارنگ و وانگ^۳ (۲۰۰۱) یک مدل ساده شبکه‌های عصبی مصنوعی برای مدل‌سازی ARMA برای سری‌های زمانی استفاده کردند. وی و همکارش بیان می‌دارند هنگامی که از داده‌های پیچیده و غیرخطی استفاده می‌کنیم، مدل شبکه‌های عصبی مصنوعی قادر به مدل‌سازی مناسب‌تری برای داده‌ها بوده و این در حالی است که مدل‌های خطی ARMA چنین قابلیتی برای داده‌های غیرخطی ندارد. از موارد دیگر به کارگیری شبکه‌های عصبی مصنوعی می‌توان به کارهای داربلی و اسلاما^۴ (۲۰۰۰) هو^۵ و همکاران (۲۰۰۲) و همچنین، روش ابتکاری زنگ^۶ (۲۰۰۳) در ترکیب مدل‌های شبکه عصبی و ARIMA، قاسمی (۱۳۷۹)، مشیری (۱۳۸۰)، اصغری (۱۳۸۱)، مشیری و همکاران (۱۳۸۱)، آذر و همکاران (۱۳۸۲) و ناصری (۱۳۸۲) و نیز مشیری و فروتن (۱۳۸۳) اشاره کرد. مشیری و فروتن به بررسی روند آشوب در قیمت‌های آتی نفت پرداخته و از دو روش خطی و غیرخطی برای پیش‌بینی استفاده کرده‌اند. تفاوت‌های اصلی این پژوهش با بخش پیش‌بینی مقاله مشیری و فروتن (۱۳۸۳) در نوع روش پیش‌بینی و داده‌های آن است. در این پژوهش، برخلاف مقاله مشیری و فروتن که از روش پویا استفاده شده، از روش پیش‌بینی ایستا استفاده کردند ایم و داده‌های پژوهش نیز به مدت دو سال بیشتر (۱۹۸۳-۲۰۰۵) است. در این پژوهش، ابتدا مروری کوتاه بر تاریخچه شبکه‌های عصبی مصنوعی داشته،

-
- 1.Moshiri & Cameron
 - 2.Werkooijen
 - 3.Hwarng & Wong
 - 4.Darbellay & Slama
 - 5.Ho
 - 6.Zhang

سپس، به موضوع آنالیز حساسیت می‌پردازیم. در پایان، به مرور نتایج و مقایسه روش‌ها و ارائه پیشنهادهای لازم خواهیم پرداخت.

۱. شبکه عصبی مصنوعی

با شناخت توانایی سلول‌های عصبی در مغز انسان و مشابه‌سازی این روند در سیستم‌های کامپیوتربی، شبکه عصبی هوشمند مصنوعی برای نخستین بار در سال ۱۹۴۳ توسط مک کولا (عصب‌شناس) و پیت (ریاضیدان) به وجود آمد و از آنجایی که مفاهیم پایه‌ای مطرح شده در مباحث مربوط به آن از اساس ریاضی مستحکم و قابل اعتمادی برخوردار بود(Rumelhart et al., 1986)، بعدها به طور گسترده‌ای مورد اقبال عمومی پژوهشگران در مدلسازی تجربی فرآیندهای شدیداً غیرخطی قرار گرفت. امروزه شبکه‌های عصبی مصنوعی به عنوان یک روش درون‌باب و شبیه‌ساز پیشرفته که به خوبی توانایی شبیه‌سازی فرآیندهای پیچیده را دارد، کاربرد رو به رشدی دارد. در واقع، به کارگیری این روش افق جدیدی را در خانواده مهندسی و پس از آن در شاخه‌های دیگر علوم گشود. نکته جالب توجه و دارای اهمیت در مشابه‌سازی یادشده، شبیه‌سازی عملکرد پیچیده سلول‌های عصبی با تعداد زیادی واحد با عملکرد ساده و ارتباط‌های موازی بود. براساس تعریف، شبکه عصبی مصنوعی، یک سیستم پردازش اطلاعات است که از تعداد زیادی واحد غیرخطی به هم پیوسته پردازشگر اطلاعات (نورون‌ها یا گره‌ها) تشکیل شده است(Tokar and johson, 1999) و شبکه عصبی مصنوعی از دو جهت با مغز انسان مشابهت دارد(Haykin, 1999).

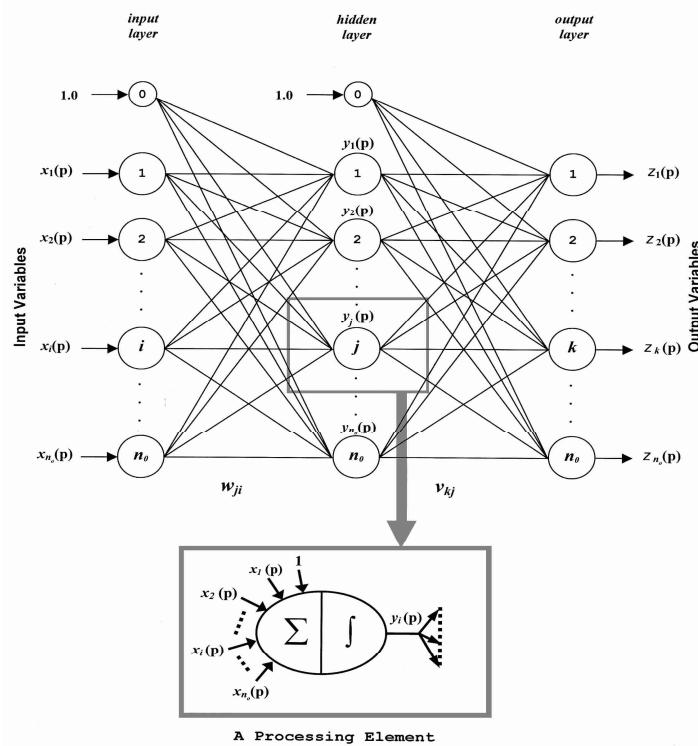
الف) کسب دانش توسط شبکه در فرآیندی به نام یادگیری یا آموزش انجام می‌شود.
ب) عوامل مرتبط‌کننده نورن‌ها که وزن‌های سینپتیک نامیده می‌شوند، دانش کسب شده توسط شبکه را ذخیره می‌نمایند.

شبکه‌های عصبی براساس جهت جریان یافتن و پردازش اطلاعات به دو دسته اصلی شبکه‌های پیش‌خور^۱ و شبکه‌های برگشتی^۲ تقسیم می‌شوند. در شبکه‌های برگشتی، تبادل اطلاعات میان گره‌ها دوطرفه است. این نوع شبکه به ویژه در مدلسازی فرآیندهای متغیر در زمان و مکان که نیازمند ابزاری پویا برای مدلسازی هستند، می‌تواند گزینه مناسبی باشد. البته لازم به توضیح است که به کارگیری شبکه‌های پیش‌خور حتی برای مدلسازی فرآیندهای پویا معمول‌تر است؛ چون شبکه‌های پیش‌خور از رواج بیشتری برخوردار بوده و در این پژوهش نیز از این گزینه برای مدلسازی استفاده شده است؛ در ادامه، این گزینه شبکه عصبی به طور گسترده‌تری بررسی خواهد شد.

در شبکه‌های عصبی پیش‌خور نورونها به طور معمول در گروههایی که لایه خوانده می‌شوند، دسته‌بندی می‌شوند. شکل (۱) یک شبکه عصبی پیش‌خور را نشان می‌دهد. همان‌طور که مشاهده می‌شود یک شبکه پیش‌خور را با یک لایه ورودی آغاز و به یک لایه خروجی ختم می‌شود. میان لایه ورودی و لایه خروجی می‌تواند چندین لایه پنهان وجود داشته باشد. لایه‌های ورودی و خروجی تنها لایه‌های شبکه عصبی هستند که با محیط در ارتباطند. لایه ورودی مقادیر ورودی مدل شبکه عصبی مصنوعی را از محیط دریافت می‌کند و لایه خروجی، پاسخ سیستم شبکه عصبی را به مقادیر ورودی، به محیط بر می‌گردند. دلیل نامگذاری لایه‌های پنهان، به دلیل عدم دسترسی مستقیم از محیط به این لایه‌ها و بر عکس می‌باشد. در یک شبکه پیش‌خور نورون‌های هر لایه، اطلاعات را تنها از نورون‌های لایه پیشین دریافت کرده، پس از پردازش، شکل پردازش شده آن را تنها به نورون‌های لایه بعد، تحويل می‌دهند. بر روی عوامل مرتبط‌کننده نورون‌های هر لایه به نورون‌های لایه بعد مقادیر وجود دارد که وزن‌های سینپتیک به اختصار وزن نامیده می‌شوند. به ماتریسی که مولفه‌های آن مقادیر وزن میان نورون‌های دولایه متوالی است، ماتریس وزن^۱ آن لایه می‌گویند. اگر تعداد نورون‌های لایه‌ای n و تعداد نورون‌های لایه پیشین آن m باشد، ماتریس وزن بین دو لایه $W_{n \times m}$ خواهد بود. بجز نورون‌های لایه ورودی که به طور مستقیم اطلاعات را از خارج سیستم (محیط) دریافت می‌کنند، هر نورون دیگر در شبکه عصبی پیش‌خور، خروجی هر نورون لایه پیشین را که توسط عملگری با وزن میان دو نورون ترکیب شده است، به عنوان ورودی خام^۲ خود دریافت می‌کند.

-
1. Weight Matrix
 2. Raw Input

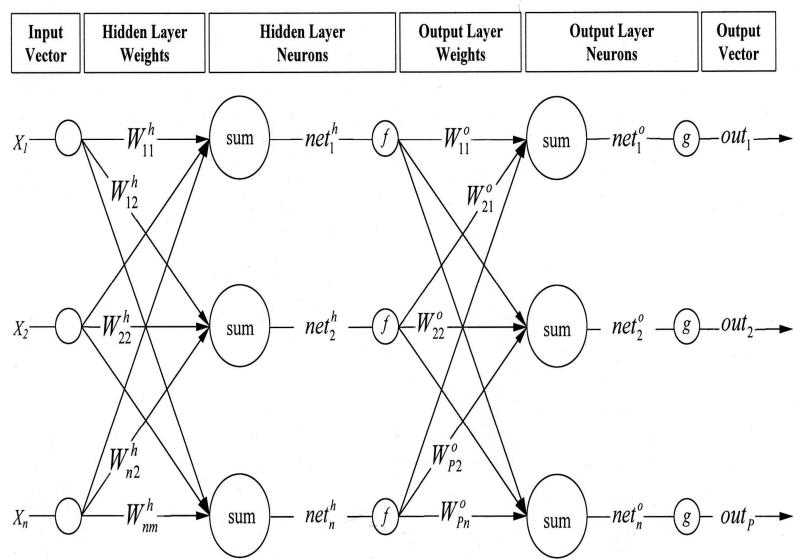
شکل ۱. نمونه شبکه عصبی پیش خور



عملیات منتهی به محاسبه مقدار خروجی نورون برای تمام نورون‌های موجود در شبکه (به استثنای نورون‌های لایه ورودی) انجام می‌شود. خروجی به دست آمده به ترتیب، پاسخ مدل شبکه عصبی به ورودی‌های داده شده به لایه ورودی خواهد بود. شکل (۲) یک نمونه شبکه عصبی سه لایه‌ای را نشان می‌دهد. لازم به ذکر است این شکل نمونه یک شبکه عصبی MLP^۱ است. مفاهیم ورودی خام و ورودی موثر را می‌توان به سادگی از شکل تفکیک شده نورون در تصویر شبکه درک کرد.

۱. در شبکه‌های عصبی چندلایه پروسپترون (Multi-layer perceptron) هر نورون حاصل ضرب خروجی نورون‌های لایه قبلی در وزن‌های میان آن نورون و نورون‌های لایه پیشین را به عنوان ورودی خام دریافت کرده، مجموع آنها را به عنوان ورودی موثر برای قرارگیری در تابع فعال‌سازی f و g در شکل ۲ محاسبه می‌کنند.

شکل ۲. نمونه یک شبکه عصبی MLP



پژوهشگران در مطالعات گوناگونی که انجام داده‌اند از توابع فعال‌ساز^۱ مختلفی استفاده کرده‌اند. با توجه به مفاهیم پایه‌ای، بیشتر توابع غیرخطی که به عنوان تابع فعال‌ساز در نظر گرفته می‌شوند، عملکرد مناسبی از شبکه عصبی در مقایسه با روش‌های آماری (مدل‌های براساس رگرسیونی) به دست می‌دهد؛ اما گرایش بیشتر پژوهشگران در استفاده از توابع فعال‌ساز کراندار بوده است. مشهورترین تابعی از این دست که به طور گسترده در پارادایم MLP استفاده شده است، تابع سیگموئید^۲ است.

۱. به نظر می‌رسد که تابع فعال‌ساز در شبکه‌های عصبی MLP می‌تواند عملکردی مشابه عملکرد تابع متابع تجدید شونده در اقتصاد منابع داشته باشد. زیرا در شبکه‌های عصبی، سه لایه ورودی، میانی و خروجی اطلاعات را داریم که شبکه خروجی خود را با اعمال تغییراتی در لایه میانی برای همانگی با ورودی در تعداد دفعات آموزش خود می‌دهد، که از این نظر شاهد یک سیر تجدیدشونده در بین لایه‌ها هستیم که خروجی‌ها با تغییرات در لایه میانی، خود را با لایه ورودی اطلاعات همانگ می‌کنند.
۲. تابع سیگموئید (Sigmoid) از بالا و پایین کراندار و اکیداً صعودی است و تابعی است که در همه جا پیوسته و مشتق‌پذیر است. دامنه این تابع، مجموعه اعداد حقیقی و برد آن، مجموعه اعداد حقیقی بین صفر و یک می‌باشد.

$$out = \frac{1}{1 + \exp(-net_j)}$$

۲. فرآیند آموزش در شبکه‌های پیش‌خور

برای اینکه شبکه عصبی مصنوعی از بردار داده‌های ورودی $X = [x_1, x_2, \dots, x_m]^T$ بردار خروجی $Y = [y_1, y_2, \dots, y_p]^T$ را به گونه‌ای تولید نماید که تا حد ممکن به بردار هدف $T = [t_1, t_2, \dots, t_p]^T$ نزدیک باشد، باید فرآیند آموزش یادگیری شبکه انجام شود. بدین منظور، نظری مدل‌های دیگر تجربی، لازم است که از پیش، مجموعه‌ای از بردارهای ورودی و خروجی متناظر (مجموعه کالیبراسیون مدل) تهیه شود. چنین مجموعه‌ای در ادبیات شبکه عصبی، مجموعه آموزشی و هر بردار ورودی و خروجی متناظر آن، الگوی آموزشی نامیده می‌شود.

براساس تعریف، فرآیند آموزش شبکه عصبی عبارت است از مجموعه عملیاتی که برای تعیین پارامترهای قابل تنظیم مدل شبکه عصبی انجام می‌شود تاتابع خطابی که نشان‌دهنده اختلاف میان خروجی شبکه (بردار OUT) و خروجی هدف (بردار T) است، کمینه شود. اگر تعداد کل الگوهای آموزشی Q باشد و لایه خروجی شبکه هم دارای P نورون باشد، تابع خطابی که به کارگیری آن در فرآیند آموزش رایج است به فرم زیر خواهد بود (Wasserman, 1993) (در روابط زیر، q شماره الگویی آموزشی است که طبیعتاً $Q = 1, 2, \dots, Q$ می‌باشد).

$$Er_q = \sum_{k=1}^P [t_{kq} - y_{kq}]^2 \quad (1)$$

$$Er = \frac{\sum_{q=1}^Q Er_q}{Q} \quad (2)$$

استفاده از رابطه (۱) به معنای اصلاح کردن پارامترهای شبکه به صورت الگو به الگو است.^۱ استفاده از رابطه (۲) که متوسط مجموع مربع خطاهای نورون‌های لایه خروجی در تمام الگوهاست، خطرا را به شکل کلی محاسبه کرده و از آن در اصلاح پارامترهای مدل استفاده می‌کند.^۲

اما موضوع مهم دیگری را که باید مد نظر داشت تجزیه و تحلیل حساسیت مدل‌سازی به وسیله شبکه عصبی مصنوعی است. در واقع، باید این مقوله را به عنوان یکی از مهم‌ترین ابزارهای کشف و درک عملکرد حقیقی مدل‌های ریاضی دانست. هدف اصلی تجزیه و تحلیل حساسیت را می‌توان در دو موضوع خلاصه کرد:

اول: بررسی و مشاهده نحوه تغییرات خروجی مدل در مقایسه با تغییرات پارامترهای ورودی،

دوم: بررسی کیفیت و تناسب داده‌های ورودی نسبت به نتایج خروجی.

1.On-Line Method

2.Bath Method

در مورد کیفیت و تناسب متغیرهای ورودی می‌توان این‌گونه پنداشت که تجزیه و تحلیل حساسیت مدل‌های ریاضی می‌تواند اهمیت این نوع متغیرها را در مدل بیان کند و در نهایت، آنچه که از این رهگذر نصیب کاربر می‌شود، نتایجی است که با اعمال آن بر پایداری و همگرایی مدل می‌افزاید (نظیر حذف پارامترهای ورودی غیرضروری). ضریب حساسیت نشان‌دهنده تأثیر یک ورودی بر روی خروجی مدل مورد نظر است؛ در واقع، این ضریب مربوط به حساسیت \bar{z} امین خروجی نسبت به \bar{z} امین ورودی در مدل یادشده است که آن را می‌توان به صورت یک مشتق جزئی از پارامتر وابسته یا خروجی نسبت به پارامتر مستقل یا ورودی توصیف کرد. گفتنی است چنانچه این مدل، n متغیر ورودی و m متغیر خروجی داشته باشد، به تعداد $m \cdot n$ ضریب حساسیت به دست می‌آید. واحد این ضریب برابر واحد خروجی بر روی ورودی است.

$$S_{ij} = \frac{\delta y_i}{\delta x_i} \cdot \frac{x_i}{y_i} \quad (3)$$

در مجموع، می‌توان گفت که سه روش برای محاسبه آنالیز حساسیت مطرح است: روش مستقیم، روش اختلال و روش الحقی. روش مستقیم که با مشتق‌گیری مستقیم از مدل به دست می‌آید، در مدل‌هایی که از لحاظ پیچیدگی در سطح بالایی نیستند، کاربرد دارد. اطلاعاتی که برای تعیین حساسیت مدل استفاده می‌شود از مجموعه اطلاعات پایه مدل بوده و در آن شرایط اولیه و مرزی لحاظ خواهد شد.

۳. مدل‌سازی و پیش‌بینی – با استفاده از شبکه‌های عصبی مصنوعی^۱

برای انجام پیش‌بینی و در واقع، گرفتن خروجی از شبکه، ابتدا باید قبل از نوشتن برنامه تعدادی وقفه برای داده‌ها لحاظ شود، که تعداد وقفه بهینه یا همان ورودی به وسیله آزمون و خطا و انجام مدل‌سازی‌های مختلف، مشخص می‌شود. برای مشخص شدن تعداد وقفه بهینه می‌توان به بحث آنالیز حساسیت مدل توجه کرد که بر این اساس، با ثابت در نظر گرفتن پارامترهای دیگر برنامه می‌توانیم تعداد وقفه‌های زاید و غیرموثر را از مدل حذف کنیم. گفتنی است منظور از وقفه زاید و غیرموثر، وقفه‌ای است که شبکه کمترین میزان یادگیری را از آن دارد. پس از این مرحله، تصادفی نمودن^۲ داده‌ها انجام می‌شود. نتیجه انجام این مرحله، داشتن مجموعه‌ای از ورودی و خروجی است که در آن،

۱. در این پژوهش، تنها بررسی و مطالعه شبکه عصبی مصنوعی چندلایه پروسپترون (Multi layer perceptron) با روش یادگیری پس انتشار خطا (Back propagation) برای پیش‌بینی قیمت روزانه نفت خام برای تحويل در ماه آینده از آوریل ۱۹۸۳ تا ژوئن ۲۰۰۵ مد نظر می‌باشد. لازم به یادآوری است برای تهیه این داده‌ها از سایت EIA استفاده شده و برای مدل‌سازی در شبکه‌های عصبی مصنوعی از نرم‌افزار NEUROSOLOATION 4.2 استفاده شده است.

2. Randomize

دسته‌های ورودی- خروجی دارای نظام خاص نیستند. پس از پایان تصادفی نمودن داده‌ها، میزان آمار و اطلاعاتی که باید آموزش ببیند در برنامه‌ای مشخص می‌شود. بر این اساس، بخشی از داده‌ها برای آموزش لحاظ می‌شود. از داده‌های دیگر، بخشی به عنوان داده واسنجی و بخشی دیگر به عنوان داده آزمون در نظر گرفته می‌شود.

دسته دوم داده‌ها که، با عنوان واسنجی مطرح شد، به منظور سنجش مجدد اطلاعات استفاده می‌شود. این مرحله به عنوان مرحله واسطه بین آموزش و آزمون نهایی است. این بخش از این رو به کار می‌رود تا از بروز پدیده بیش‌آموزشی^۱ در بخش آموزش جلوگیری شود.

از آنجا که در بخش آموزش، شبکه به دنبال کم کردن فاصله مقادیر محقق شده و برآورد شده است، به یک سری داده‌های تکراری عادت کرده و با مقدار جدیدی که مواجه می‌شود، دچار خطای بسیار شدید خواهد شد. بنابراین، داده واسنجی برای جلوگیری از وسوسات پیدا کردن شبکه به یکسری داده بعد از انجام هر یادگیری وارد می‌شود. پس از مشخص کردن داده‌های آموزش، واسنجی و آزمون باید تعداد لایه‌های مخفی را در برنامه لحاظ کنیم. تعداد لایه‌های مخفی در کل مدل‌های ساخته شده در این پژوهش یک در نظر گرفته شده و علت آن، گریز از اشکال بیش‌آموزشی خطا است.

از دیگر مواردی که باید در نوشتمن برنامه بدان توجه شود تابع تحریک، ضربی یادگیری و Momentum است. در مورد تابع تحریک، تابع سیگموید و ضربی یادگیری، یک در نظر گرفته شده است، که با استفاده از آزمون و خطا و تجربه به دست آمده است. Momentum نیز در واقع، تغییر جاری در وزن را به تغییر قبلی وزن و هم چنین، خطای جاری مرتبط می‌کند. پس از آنکه ساختار شبکه مشخص و مجموعه ورودی‌ها به شبکه ارائه شد، شبکه برای آموزش آماده می‌شود. شبکه با توجه به وزن‌ها که در مرحله اول به تصادف انتخاب می‌شوند، خروجی خود را ارائه می‌کند. سپس، با استفاده از تابع عملکرد مجموع مجذورات خط(MSE)، خروجی خود با مقادیر محقق شده را مقایسه کرده و با توجه به کمترین خطایی که از او انتظار می‌رود به تنظیم وزن‌ها پرداخته و این مراحل را آنقدر تکرار می‌کند تا به حداقل خطای مورد انتظار – با توجه به حداقل تکرار مجاز- دست یابد. حال که مراحل ساخت مدل ارائه شد به طرح ۱۲ مدلی که ساخته‌ایم، خواهیم پرداخت. در جدول (۱) مشخصات این مدل‌ها ارائه شده است. در ستون اول، منظور از تعداد ورودی همان وقنه‌های است. از آنجا که تابع تحریک تمامی این مدل‌ها سیگموید است از ذکر آن پرهیز می‌شود.

1. Overlearning

$$2. MSE = \frac{\sum(Y_t - \hat{Y}_t)}{n}$$

جدول ۱. مشخصات مدل‌های ساخته شده شبکه عصبی

R^2	MSE	SSE	تعداد نمونه تجربه	تعداد گرهای عصبی	Momentum	ضریب یادگیری	تعداد نمونه آزمایش	تعداد نمونه آزمایش
۰/۹۷۶۳	۱/۴۸۳۴	۸۲۳۱/۵۳	۷۰۰۰	۱۶	۰/۷	۱	۸	اول
۰/۹۷۸۴	۱/۳۵۷۲	۷۵۳۴/۳۶	۱۰۰۰۰	۱۲	۰/۷	۱	۶	دوم
۰/۹۸۱۴	۱/۱۷۳۸	۶۵۱۷/۳۸	۲۰۰۰۰	۱۰	۰/۷	۱	۵	سوم
۰/۹۷۷۴	۱/۴۰۰۱	۷۷۵۲/۲۶	۱۰۰۰۰	۴۰	۰/۷	۱	۲۰	چهارم
۰/۹۸۲۷	۱/۰۶۵۷	۵۹۰۱/۰۵	۲۰۰۰۰	۴۰	۰/۷	۱	۲۰	پنجم
۰/۹۷۹۳	۱/۳۰۹۲	۷۲۶۸/۶۹	۱۰۰۰۰	۱۰	۰/۷	۱	۵	ششم
۰/۹۷۹۱۷	۱/۳۳۹۶	۷۳۸۲/۲۱	۱۰۰۰۰	۱۰	۰/۷	۰/۵	۵	هفتم
۰/۹۷۴۲	۱/۷۰۵۵	۹۴۴۱/۴۷	۲۰۰۰۰	۱۶	۰/۷	۱	۸	هشتم
۰/۹۷۴۴	۱/۴۸۹۲	۸۱۹۶/۴۸	۲۰۰۰۰	۴۰	۰/۷	۱	۲۰	نهم
۰/۹۷۳۸	۱/۶۶۷۸	۹۲۱۸/۱۲	۱۰۰۰۰	۴۰	۰/۷	۱	۲۰	دهم
۰/۹۷۰۶	۱/۹۹۲۳	۱۱۰۳۶/۹۳	۱۰۰۰۰	۱۴	۰/۷	۱	۷	یازدهم
۰/۹۷۴۲	۱/۶۸۱۹	۹۳۱۸/۲۴	۱۰۰۰۰	۱۴	۰/۸۵	۱	۷	دوازدهم

میزان مجموع مجذورات خطای میانگین مجذورات خطای در این جدول از طریق آخرین خروجی ساخته شده توسط شبکه – که همان خروجی بهینه نسبت به ورودی است- به دست می‌آید. با توجه به اطلاعات این جدول، از مقایسه مدل‌های ششم و هفتم در می‌یابیم که با کم کردن ضریب یادگیری همراه با ثابت نگه داشتن پارامترهای دیگر، میزان شخص میانگین مجذورات خطای افزایش می‌یابد. بنابراین، هر چه ضریب یادگیری مدل بالاتر و به عدد یک نزدیکتر باشد نتایج بهتری به دست می‌آید. از سوی دیگر، اگر به مدل‌های یازدهم و دوازدهم توجه کنیم به این موضوع می‌رسیم که با بالا بردن عدد Momentum در مدل با ثابت در نظر گرفتن پارامترهای دیگر به نتایج بهتری خواهیم رسید و میزان میانگین مجذورات خطای و ضریب تعیین (R^2) به ترتیب کوچکتر و بزرگتر خواهد شد. میزان ضرایب حساسیت خروجی‌های هر مدل نسبت به ورودی‌ها یا همان وقفه‌ها در جدول ۲ آمده است. با توجه به سه روش یادشده برای محاسبه ضریب حساسیت در قسمت‌های قبل باید گفت برای محاسبه ضریب حساسیت از روش مستقیم استفاده شده است. گفتنی است که ضریب حساسیت نشان‌دهنده میزان اثرپذیری یا یادگیری خروجی شبکه از ورودی‌هاست.

جدول ۲. میزان ضرایب حساسیت خروجی‌های هر مدل نسبت به ورودی‌ها

L10	L9	L8	L7	L6	L5	L4	L3	L2	L1	مدل
—	—	0.0563	0.0783	0.0557	0.0685	0.0933	0.0933	0.1097	0.0567	اول
—	—	—	—	0.076	0.101	0.106	0.082	0.135	0.1009	دوم
—	—	—	—	—	0.1009	0.081	0.104	0.141	0.177	سوم
0.023	0.062	0.031	0.0251	0.030	0.063	0.094	0.058	0.090	0.097	چهارم
0.018	0.025	0.022	0.037	0.032	0.052	0.063	0.098	0.145	0.163	پنجم
—	—	—	—	—	0.128	0.092	0.108	0.134	0.140	ششم
—	—	—	—	—	0.109	0.105	0.156	0.126	0.105	هفتم
—	—	—	—	—	0.090	0.084	0.122	0.142	0.205	هشتم
0.045	0.028	0.007	0.021	0.0009	0.092	0.092	0.095	0.123	0.209	نهم
0.034	0.017	0.043	0.047	0.069	0.061	0.057	0.102	0.109	0.139	دهم
—	—	—	0.073	0.023	0.056	0.085	0.099	0.101	0.205	یازدهم
—	—	—	0.039	0.016	0.069	0.081	0.130	0.094	0.215	دوازدهم

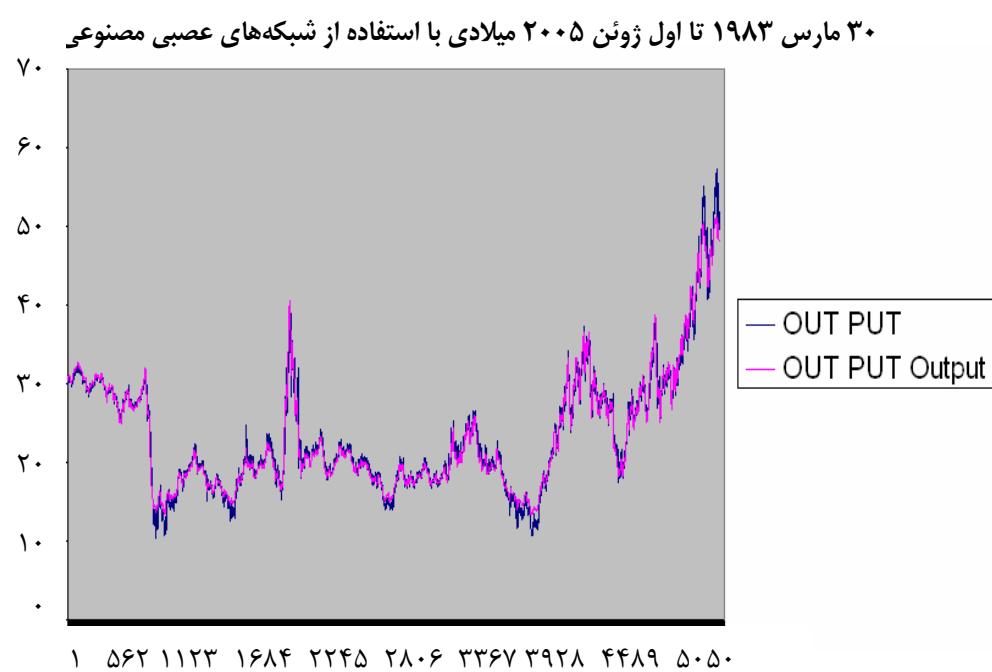
ادامه جدول ۲. میزان ضرایب حساسیت خروجی‌های هر مدل نسبت به ورودی‌ها

L20	L19	L18	L17	L16	L15	L14	L13	L12	L11	مدل
—	—	—	—	—	—	—	—	—	—	اول
—	—	—	—	—	—	—	—	—	—	دوم
—	—	—	—	—	—	—	—	—	—	سوم
0.021	0.014	0.003	0.024	0.001	0.017	0.013	0.003	0.031	0.0042	چهارم
0.02	0.005	0.028	0.010	0.011	0.007	0.012	0.015	0.027	0.01	پنجم
—	—	—	—	—	—	—	—	—	—	ششم
—	—	—	—	—	—	—	—	—	—	هفتم
—	—	—	—	—	—	—	—	—	—	هشتم
0.004	0.003	0.002	0.016	0.002	0.016	0.007	0.004	0.006	0.016	نهم
0.050	0.001	0.003	0.015	0.017	0.024	0.054	0.018	0.008	0.026	دهم
—	—	—	—	—	—	—	—	—	—	یازدهم
—	—	—	—	—	—	—	—	—	—	دوازدهم

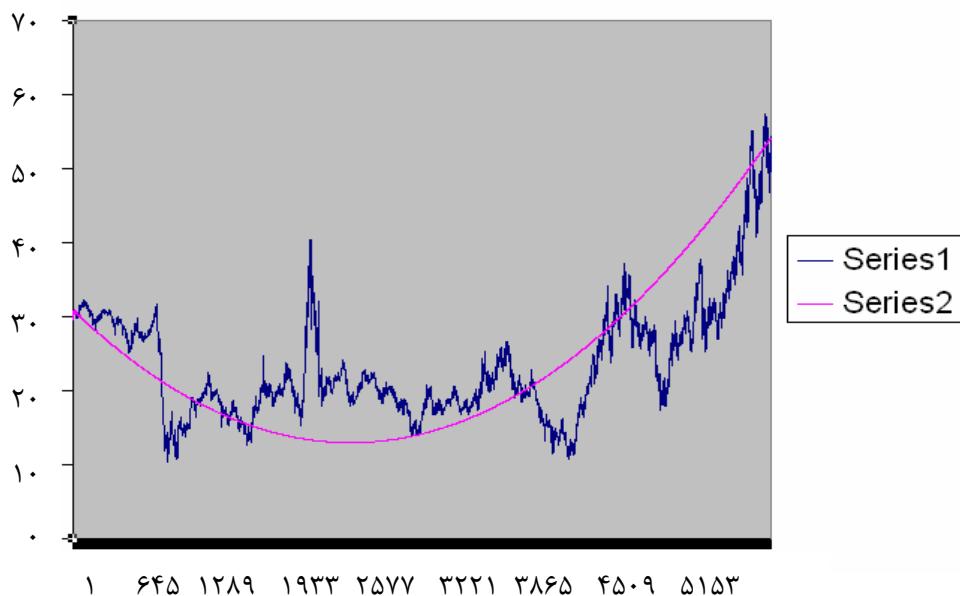
علاوه بر پارامترهای میانگین مجددات خطای ضریب تعیین می‌توان بیان کرد زمانی عملکرد شبکه‌ای بهینه خواهد بود که بیشترین اثرپذیری را از ورودی اول داشته باشد، زیرا ورودی اول تنها با یک روز وقفه اعمال شده است. شبکه‌ای که بیشترین یادگیری را از ورودی‌های دوم و سوم و جز اینها نسبت به ورودی اول دارد به نوعی در عملکرد خود با اختلال مواجه شده است؛ زیرا از وقفه‌های دورتر به خاطرپذیری یا با یادگیری بیشتری داشته است.

لازم به ذکر است که برخلاف شاخص‌های میانگین مجدورات خطأ و ضریب تعیین که مطلق هستند، شاخص ضریب حساسیت یک معیار نسبی است. اگر به جدول (۲) دقت نماییم، خواهیم دید که مدل‌های هشتم، نهم، یازدهم و دوازدهم نسبت به مدل پنجم از ضریب حساسیت بالاتر اما از میانگین مجدورات خطأ بالاتر و ضریب تعیین پایین‌تری برخوردارند. نتایج بهترین مدل‌سازی انجام شده در شکل (۳) آورده شده است، که در آن می‌توان هماهنگی بسیار بالای نتایج مشاهده شده و محاسبه شده را مشاهده کرد.

شکل ۳. نمودار مقادیر مشاهده شده و محاسبه شده قیمت جهانی نفت، تحویل در ماه آتی در خلال



شكل ۴. نمودار مقادیر مشاهده شده و محاسبه شده قیمت جهانی نفت، تحویل در ماه آتی در خلال ARIMA ۳۰ مارس ۱۹۸۳ تا اول ژوئن ۲۰۰۵ میلادی با استفاده از بهترین مدل



۴. مدل‌سازی و پیش‌بینی با استفاده از ARIMA

برای پیش‌بینی مقادیر قیمت روزانه نفت تحویل در ماه آینده از آوریل ۱۹۸۳ تا ژوئن ۲۰۰۵ با استفاده از روش باکس جنکینز باید مدل ویژه‌ای را از میان مدل‌های اتورگرسیو(AR)- مدل‌های میانگین متحرک (MA) و در نهایت، مدل‌های تلفیق شده اتورگرسیو- میانگین متحرک (ARIMA) انتخاب کرد و بدین منظور، ابتدا باید نسبت به مانابودن سری مربوطه اطمینان به دست آورد.

برای مشخص کردن مانابودن سری مربوطه از آزمون دیکی و فولر استفاده می‌کنیم. نتایج به دست آمده از این آزمون در جدول ۳ آمده است.

جدول ۳. نتایج بدست آمده از آزمون مانایی داده‌های سری زمانی

ADF Test Statistic	-1.209.662	1% Critical Value	-3.4347	
		5% Critical Value	-2.8626	
		10% Critical Value	-2.5674	
Variable	Coefficient	Std.Error	t-Statistic	Prob
OILPRICE(-1)	-0.001202	0.000994	-1.209662	0.2265
D(OILPRICE(-1))	-0.005821	0.013468	-0.432199	0.6656
D(OILPRICE(-2))	-0.035387	0.013457	-2.629552	0.0086
D(OILPRICE(-3))	-0.036836	0.013457	-2.737260	0.0062
D(OILPRICE(-4))	0.025304	0.013466	1.879197	0.0603
C	0.032892	0.024678	1.332855	0.1826
R - squared	0.003681	Mean dependent var	0.004362	
Adjuster R-squared	0.002782	S.D dependent var	0.583976	
S.E of regression	0.583163	Akaike info criterion	1.760379	
Sum squared resid	1886.076	Schwarz criterion	1.767535	
Log likelihood	-4880.812	F - statisic	4.097670	
Durbin - Watson stat	1.994127	Prob (F - statistic)	0.001026	

همان‌طور که از جدول آزمون دیکی-فولر پیداست این داده‌ها در سطوح ۱٪، ۵٪ و ۱۰٪ ناماننا هستند. برای مانانمودن داده‌های یادشده، ابتدا تفاضل مرتبه اول را اعمال می‌نماییم. برای آگاهی از مانشدن داده‌ها آزمون دیکی-فولر را انجام می‌دهیم. نتایج مربوط به این آزمون در جدول (۴) آمده است.

جدول ۴. نتایج مربوط به آزمون مانایی داده‌های سری زمانی پس از تفاضل مرتبه اول

ADF Test Statistic	-3.526.525	1% Critical Value	-3.4347	
		5% Critical Value	-2.8626	
		10% Critical Value	-2.5674	
<hr/>				
Variable	Coefficient	Std.Error	t-Statistic	Prob
DOP(-1)	-1.101037	0.031222	-35.26525	0.0000
D(DOP(-1))	0. 095277	0.027795	3.427798	0.0006
D(DOP(-2))	0. 057428	0.023694	2.423670	0.0154
D(DOP(-3))	0. 018171	0.019081	0.952325	0. 3410
D(DOP(-4))	0. 042393	0.013450	3.151887	0.0016
C	0. 004766	0.007823	0. 609228	0.5424
<hr/>				
R - squared	0. 504649	Mean dependent var	0.000495	
Adjuster R-squared	0. 504203	S.D dependent var	0. 827645	
S.E of regression	0. 582768	Akaike info criterion	1.759026	
Sum squared resid	1883.187	Schwarz criterion	1.766184	
Log likelihood	-4876.178	F - statisic	1129. 818	
Durbin - Watson stat	1. 999066	Prob (F - statistic)	0.000000	

همان‌طور که از جدول آزمون اخیر دیکی-فولر بر می‌آید، این داده‌ها در سطوح ۰/۱ و ۰/۵٪ مانا هستند. پس از مانashدن داده‌ها، نوبت به تعداد وقفه بهینه برای MA و AR می‌رسد. تعداد وقفه‌ای را که برای هر کدام از مدل‌های اتورگرسیو و میانگین متحرک در نظر گرفته‌ایم، ده وقفه است. حال می‌خواهیم ببینیم که چه ترکیبی از این وقفه‌ها برای پیش‌بینی قیمت روزانه نفت خام بهینه است. معادلات به دست آمده، از ترکیبات مختلف وقفه‌های MA و AR ساخته می‌شود. ترکیبی که کمترین آکاییک را نسبت به ترکیبات وقفه‌های دیگر دارد، انتخاب می‌کنیم. ترکیب (۱۰ و ۹) ARMA کمترین آکاییک را در بین ۱۲۱ معادله حاصل از ترکیبات مختلف MA و AR دارد، بنابراین، مدل بهینه به صورت (۱۰ و ۹) ARIMA خواهد بود. عدد یک هم در این ترکیب نشان دهنده مرتبه تفاضل داده‌هاست. نتایج به دست آمده از اجرای این مدل در جدول (۵) آمده است.

جدول شماره ۵. نتایج بدست آمده از اجرای مدل ARIMA (۹,۱,۱۰)

Variable	Coefficient	Std.Error	t - Statistic	Prob
C	-0.015535	0.014708	-1.056240	0,2909
@TREND	7.18E-60	4.59E-60	1.564074	0.1179
AR(1)	0.228783	0.037029	6.178514	0.0000
AR(2)	0.140986	0.042076	3.350715	0.0008
AR(3)	0.066114	0.033308	1.984910	0.0472
AR(4)	0.001197	0.031857	0.037575	0.7900
AR(5)	0.185983	0.29953	6.209260	0.0000
AR(6)	-0.119189	0.036058	-3.305503	0.0010
AR(7)	0.582760	0.029125	20.00862	0.0000
AR(8)	-0.388993	0.035806	-10.86383	0.0000
AR(9)	0.490218	0.037750	-12.98585	0.0000
MA(1)	-0.237832	0.035414	-6.715777	0.0000
MA(2)	-0.170160	0.041514	-4.098894	0.0000
MA(3)	-0.092568	0.035657	-2.596100	0.0095
MA(4)	0.027450	0.033820	0.811643	0.4170
MA(5)	-0.224535	0.031484	-7.131652	0.0000
MA(6)	0.106333	0.3038501	2.761806	0.0058
MA(7)	-0.569593	0.032525	-17.51226	0.0000
MA(8)	0.370181	0.033543	11.03597	0.0000
MA(9)	0.509495	0.037634	1353804	0.0000
MA(10)	0.032673	0.015323	2.132245	0.0330
R-squared	0.018936	Mean dependent var	0.004348	
Adjuster R-squared	0.015386	S.D dependent var	0.584178	
S.E of regression	0.579666	Akaike info criterion	1.751050	
Sum squared resid	1856.807	Schwarz criterion	1.776116	
Log likelihood	-4835.536	F - statistic	5.333143	
Durbin - Watson stat	1.997432	prob (F - statistic)	0.000000	

همان‌طور که در جدول (۵) مشخص شده، شاخص دوربین – واتسون نیز در وضعیت مناسبی است.

میزان مجموع مجذورات خطای میانگین مجذورات خطای این مدل پس از تبدیل آن به سطح ۲۸۳۳۸۱/۲۹ و ۵۰/۹۹۵ است، که در جدول (۶) آمده است.

جدول شماره ۶.

R2	MSE	SSE	مدل
0.018	50.995	283381.29	ARIMA (9,1,10)

مدل دیگری که در نظر گرفته‌ایم، برای هر کدام از مدل‌های اتورگرسیو و میانگین متحرک ۵۰ وقفه داده شده است. حال باید ببینیم که چه ترکیبی از این وقفه‌ها برای پیش‌بینی، بهینه است. معادلات به دست آمده از ترکیبات وقفه‌های مختلف از AR و MR ساخته می‌شود. برای یافتن معادله مطلوب که تعداد وقفه بهینه از هر دو را دارد، از معیار آکاکیویک استفاده می‌کنیم. آن ترکیب از وقفه‌ها را که کمترین آکاکیویک نسبت به ترکیبات دیگر از وقفه‌ها دارد، انتخاب می‌کنیم. ترکیب (۱۶ و ۷) AR و MA کمترین آکاکیویک را در بیش از ۱۰۰۰ معادله به دست آمده از ترکیبات مختلف AR و MA دارد. بنابراین معادله بهینه، (۱۶ و ۷) ARIMA است. نتایج به دست آمده از اجرای این مدل در جدول ۷ آمده است.

جدول شماره ۷. نتایج بدست آمده از اجرای مدل (۷,۱,۱۶)

Variable	Coefficient	Std.Error	t - Statistic	Prob
C	-0.016223	0.014285	-1.135655	0.2562
@TREND	7.35E-60	4.45E-60	1.650619	0.0989
AR(1)	-0.110902	0.118146	-0.93868	0.3479
AR(2)	-0.342424	0.102499	-3.0340736	0.0008
AR(3)	-0.103789	0.110341	-0.94062	0.3469
AR(4)	-0.36511	0.093835	-3.890968	0.0001
AR(5)	-0.145031	0.113987	-1.272348	0.2033
AR(6)	-0.323605	0.098237	-3.294114	0.0010
AR(7)	0.652532	0.105102	6.208545	0.0000
MA(1)	0.099994	0.118346	0.844932	0.3982
MA(2)	0.301975	0.101797	2.966436	0.0030
MA(3)	0.055853	0.104998	0.531943	0.5948
MA(4)	0.376104	0.085448	4.401560	0.0000
MA(5)	0.088864	0.108760	0.817059	0.4139
MA(6)	0.274012	0.089784	3.051896	0.0023

ادامه جدول شماره ۷. نتایج بدست آمده از اجرای مدل (۷,۱,۱۶) ARIMA

Variable	Coefficient	Std.Error	t - Statistic	Prob
MA(7)	-0.705492	0.092636	-7.615778	0.0000
MA(8)	-0.074674	0.023938	-3.119440	0.0018
MA(9)	-0.011281	0.026858	-0.420028	0.6745
MA(10)	0.033367	0.01873	1.781532	0.0749
MA(11)	-0.005775	0.017128	-0.337169	0.7360
MA(12)	0.000632	0.016762	0.03768	0.9699
MA(13)	0.021145	0.016832	1.256292	0.2091
MA(14)	0.038884	0.015540	2.502177	0.0124
MA(15)	0.05795	0.015112	3.834679	0.0001
MA(16)	0.044211	0.016192	2.7320342	0.0063
R-squared	0.021909	Mean dependent var		0.00429
Adjuster R-squared	0.017660	S.D dependent var		0.58408
S.E of regression	0.578901	Akaike info criterion		1.74913
Sum squared resid	1851.240	Schwarz criterion		1.77896
Log likelihood	-4827.949	F - statistic		5.15577
Durbin - Watson stat	1.996269	prob (F - statistic)		0.000000

جدول شماره ۸.

R2	MSE	SSE	مدل
0.021	49/307	274003. 506	ARIMA(7,1,16)

همانطور که در جدول ۷ مشخص است، شاخص دوربین-واتسون نیز در وضعیت مناسبی است. نتایج نهایی به دست آمده از این مدل پس از تبدیل داده‌های برآورده شده به سطح و مدل قبلی در جدول (۸) آمده است.

بنابراین، با مقایسه نتایج نهایی بین مدل اول یعنی (۱۰ و ۱ و ۹) ARIMA با مدل دوم یعنی (۱۶ و ۷۱) ARIMA مشاهده می‌کنیم که مدل دوم بدلیل داشتن مجموع مجذورات خطأ و به دنبال آن، میانگین مجذورات خطأ پایین‌تر، از مدل اول مناسب‌تر است.

۵. نتیجه‌گیری و پیشنهادات

همانطور که بیان شد، این پژوهش برای مقایسه عملکرد مدل خود توضیح جمعی میانگین متحرک (ARIMA) و شبکه‌های عصبی برای پیش‌بینی قیمت روزانه نفت خام برای تحويل در ماه آینده، انجام شده است.

با توجه به پیش‌بینی‌های انجام شده، مشخص است که شبکه‌های عصبی مصنوعی عملکرد به مراتب بهتری نسبت به مدل‌های خود توضیح جمعی میانگین متحرک در خصوص پیش‌بینی قیمت‌های روزانه نفت خام دارند. در نتیجه، می‌توان از مدل شبکه‌های عصبی مصنوعی به عنوان ابزاری دقیق‌تر برای پیش‌بینی متغیرهای اقتصادی، در کنار روش‌های دیگر بهره جست. با توجه به نتایج به دست آمده در این پژوهش و پژوهش‌های مشابه دیگر، که در مقدمه بیان شد، در مجموع می‌توان چنین بیان کرد، تا جایی که به پیش‌بینی متغیرهای اقتصادی مربوط می‌شود، شبکه‌های عصبی مصنوعی قادرند دقیق‌تر از مدل‌های رایج دیگر به پیش‌بینی بپردازند. مدل شبکه‌های عصبی مصنوعی را می‌توان مانند بیشتر مدل‌های سری زمانی در گروه مدل‌های غیرتئوریک جای داد. از این مدل‌ها به عنوان یک مدل غیرخطی نیز یاد می‌شود. بنابراین، در مطالعات آینده عملکرد این مدل را می‌توان با مدل‌های دیگری نظیر خود توضیح‌برداری (VAR)^۱، واریانس شرطی خود رگرسیون تعمیم یافته (GARCH)^۲، خود رگرسیون‌برداری بیزین (BVAR)^۳ که اینها نیز در بیشتر مدل‌های غیرتئوریک جای می‌گیرند- در خصوص انجام پیش‌بینی مقایسه کرد.

شایان ذکر است، کاربردهای مدل شبکه‌های عصبی مصنوعی در اقتصاد به پیش‌بینی محدود نمی‌شود، از این مدل‌ها می‌توان برای آزمون روابط غیرخطی بین متغیرهای اقتصادی نیز استفاده کرد. به رغم آنکه بیشتر پژوهش‌های اقتصادی که از مدل شبکه‌های عصبی مصنوعی استفاده کرده‌اند، به مدل پس انتشار خطأ محدود بوده‌اند، مدل‌های متنوعی از لحاظ ساختار، نوع روابط بین واحدهای ورودی، میانی و خروجی و هم چنین مکانیزم یادگیری در شبکه‌های عصبی برگشتی (RNN)^۴ اشاره کرد. افزون بر این، از مدل تابع اساسی شعاعی (RBF)^۵ که جزء شبکه‌های پیش‌خور است، می‌توان یاد کرد. این مدل‌ها در زمینه‌های پیش‌بینی و گروه‌بندی متغیرهای اقتصادی می‌توانند عملکرد بسیار خوبی داشته باشند. به ویژه مدل شبکه‌های عصبی برگشتی که ساختار آنها اجازه عملکرد متغیرها با وقفه زمانی را می‌دهد، برای کاربرد در زمینه مدل‌های پویای اقتصادی که در آنها تعديل متغیرها با وقفه زمانی انجام

- 1.Vector Auto regressive
- 2.General Auto Correlation heteros chedasticidity
- 3.Bayesian vector Autoregressive
- 4.Recurrent Neural NetWorks
- 5.Genetic Algorithm

می‌شود، بسیار مناسب هستند. همچنین، می‌توان از مدل‌های شبکه عصبی مصنوعی که فرآیند یادگیری‌شان متکی بر روش‌های ژنتیک یا منطق فازی^۱ است، استفاده کرد.

1. Fuzzy Logic

منابع

- آذر، عادل؛ رجبزاده، علی. (پاییز و زمستان ۱۳۸۲). ارزیابی پیش‌بینی ترکیبی: با رویکردهای شبکه‌های عصبی - کلاسیک در حوزه اقتصاد. مجله اقتصاد دانشکده اقتصاد دانشگاه تهران / شماره ۶۲
- اصغری اسکویی، محمدرضا. (پاییز ۱۳۸۱). کاربرد شبکه‌های عصبی در پیش‌بینی سری‌های زمانی. فصلنامه پژوهش‌های اقتصادی ایران، شماره ۱۲.
- البرزی، محمود. (۱۳۸۰) آشنایی با شبکه‌های عصبی. موسسه انتشارات علمی دانشگاه صنعتی شریف. چاپ اول.
- توكلی، اکبر(۱۳۷۸). اقتصادستنجه کاربردی. انتشارات مانی.
- رمضانی، رضا. (۱۳۸۳). مقایسه عملکرد پیش‌بینی در مدل‌های شبکه عصبی مصنوعی و ARIMA (مورد مطالعه تقاضای ماهیانه برق در ایران). پایان‌نامه کارشناسی ارشد دانشکده اقتصاد دانشگاه تهران.
- قاسمی، عبدالرسول؛ اسدپور، حسن و شاهصادقی، مختار. (بهار ۱۳۷۹). کاربرد شبکه‌های عصبی در پیش‌بینی سری‌های زمانی و مقایسه با مدل ARIMA پژوهشنامه بازرگانی، فصلنامه شماره ۱۴.
- مجموعه مقالات اولین همایش. (۱۳۸۱) معرفی و کاربرد مدل‌های ناخطي پویا و محاسباتی در اقتصاد. دانشکده اقتصاد دانشگاه علامه طباطبائی.
- مشیری، سعید. (بهار و تابستان ۱۳۸۰). پیش‌بینی تورم ایران با استفاده از مدل‌های ساختاری سری زمانی و شبکه‌های عصبی. مجله تحقیقات اقتصادی، شماره ۵۸.
- مشیری، سعید؛ قدیمی، محمدرضا. (پاییز ۱۳۸۰). مدل‌سازی و پیش‌بینی رشد اقتصادی در ایران با استفاده از شبکه‌های عصبی مصنوعی(ANN). فصلنامه پژوهش‌های اقتصادی ایران، شماره ۱۲.
- منهاج، محمدباقر. (پاییز ۱۳۸۱). مبانی شبکه‌های عصبی هوش مصنوعی. مرکز نشر دانشگاه امیرکبیر.
- ناصری، محسن (۱۳۸۲). پیش‌بینی زمانی- مکانی بارندگی با استفاده از شبکه‌های عصبی و الگوریتم ژنتیک. پایان‌نامه کارشناسی ارشد دانشگاه صنعتی اصفهان.
- Darbellay Georges A, Marek Slama. (2000)"Forecasting the Short term Demand for Electricity Do Neural Network Stand a Better Chance?". International Journal of Forecasting. Noll, PP 71-83.
- Greene W.H. (2000). "Econometric Analysis, Forth Edition, Prentice Hall."
- Ho S L, Xie M, Goh T N.(2002). "A Comparative study of Neural Network and Box-Jenkins ARIMA Modeling in Time Series Prediction". Computing and Industrial Engineewing. 42.
- Hwarng H Brian, Ang H T. (2001). "A Simple Neural Network for ARMA(p,q) Time Series". Omega, 29. 319-333.
- Kaashoek John F, Dijk Herman K van(2001). "Neural Networks as Econometric Tool". Econometric Institute Report(2001). EI, Vol.5.

- Moshiri, Saeed, N. Kohzadi, and N. Camerin. (2002), Testing for Stochastic Non Linearity in Rational Expectations Permanent In come. *Hypothesis Iranian Economic Review*, Vol, 6.
- Moshiri, Saeed and N. Cameron. (2000). Econometrics Versus Neural Networks Models in Forecasting Inflation. *Journal of Forecasting*, 16, Feb.
- Moshiri, Saeed, Cameron Norman and Scuse David.(1999). "Static Dynamic and Hybrid Neural Networks in Forecasting Inflation". *Computational Economics* 14, PP. 219-235.
- Sportt J.C(2003). Choas and Time Series Analysis Oxford University Peress.
- Zhang G Peter(2003). Time Series Forecasting Using Hybrid ARIMA and Neural Network Model". *Neurocomputing* 50. PP, 159-175.