

پیش‌بینی سری زمانی با استفاده از مدل ترکیبی شبکه عصبی

مصنوعی و الگوریتم بهینه‌سازی گروهی ذرات

(مطالعه موردی بر روی میزان عرضه کل نفت ایران)

محمد امیرخان^۱، حسین دیده‌خانی^۲، امیرحسین زاهدی انارکی^۳

چکیده

پیش‌بینی متغیرهای کلان اقتصادی از اهمیت ویژه‌ای برای سیاست‌مداران و اقتصاددانان هر کشور برخوردار است. در این مقاله، یک روش مؤثر مبتنی بر رویکرد شبکه عصبی مصنوعی برای پیش‌بینی سری زمانی میزان عرضه کل نفت ایران ارائه شده است. سپس، این شبکه با استفاده از ۱۰ الگوریتم آموزشی موجود در تولباکس نرم‌افزار متلب آموزش داده شده و نتایج بدست آمده است. به منظور افزایش کارایی شبکه، از یک الگوریتم فراابتکاری به نام الگوریتم بهینه‌سازی گروهی ذرات برای آموزش شبکه استفاده شده است. به منظور مقایسه دقت پیش‌بینی و بررسی کارایی رویکرد پیشنهادی، ابتدا یک معیار اندازه‌گیری عملکرد معرفی و سپس، از داده‌های واقعی مربوط به میزان عرضه کل نفت ایران برای پیش‌بینی استفاده شده است. نتایج حاصل از اجرای مدل به ازای الگوریتم‌های آموزشی ذکر شده نشان از برتری الگوریتم بهینه‌سازی گروهی ذرات نسبت به سایر الگوریتم‌های آموزشی دارد.

واژگان کلیدی: پیش‌بینی، سری‌های زمانی، شبکه عصبی مصنوعی، بهینه‌سازی گروهی ذرات، نفت.

تاریخ دریافت مقاله: ۹۴/۸/۶، تاریخ پذیرش مقاله: ۹۴/۱۰/۲۰

۱ دانشجوی دکتری مهندسی صنایع، دانشکده صنایع دانشگاه آزاد اسلامی، واحد تهران جنوب (نویسنده مسئول) (st_m_amirkhan@azad.ac.ir)

۲ استادیار دانشکده مدیریت دانشگاه آزاد اسلامی، واحد علی‌آباد کتول.

۳ عضو هیات علمی دانشگاه جامع علمی کاربردی.

۱. مقدمه

ایران یکی از کشورهای بزرگ دارای ذخایر غنی نفتی در جهان است و درآمدهای حاصل از نفت و محصولات نفتی نقش بسزایی در سطح معیشتی مردم و همچنین تصمیم‌گیری‌های مسئولان کشور دارد. پیش‌بینی میزان کل عرضه نفت به دولت‌مردان قابلیت تخمین تغییرات ذخایر نفتی و تأثیر آن بر قیمت نفت در بازارهای جهانی را می‌دهد. اهمیت روزافزون پیش‌بینی متغیرهای کلان اقتصادی از یک سو و کمبود مدل‌های ساختاری مناسب برای پیش‌بینی از سوی دیگر باعث ایجاد مدل‌های سری‌های زمانی شده است. هدف اصلی مدل‌سازی سری‌های زمانی، دادن نظم خاص به مشاهدات وابسته به زمان است تا بر اساس آن بتوان آینده را پیش‌بینی کرد؛ به عبارت دیگر، مهم‌ترین هدف تجزیه و تحلیل سری‌های زمانی یافتن مدل تغییرات و پیش‌بینی آینده آن است (فرج زاده، ۱۳۸۶).

بسیاری از تلاش‌ها در سال‌های اخیر به یافتن روش‌ها و مدل‌هایی برای پیش‌بینی سری‌های زمانی اختصاص داده شده است. روش‌های آماری و روش‌های محاسبات نرم^۴ از شناخته شده‌ترین و پرکاربردترین تکنیک‌های موجود در این زمینه هستند. محاسبات نرم مجموعه‌ای چند رشته‌ای از فن‌آوری‌های محاسباتی هست که بخش هسته‌ای هوش محاسباتی را تشکیل می‌دهد. هموارسازی نمایی^۵ و مدل میانگین متحرک یکپارچه خود بازگشتی (ARIMA) باکس - جنکینز^۶ از معروف‌ترین روش‌های آماری در زمینه پیش‌بینی هستند. ماهیت روش‌های آماری به گونه‌ای است که در محیط‌های با تغییرات کم به خوبی قادر به پیش‌بینی هستند، اما در محیط‌های دارای اغتشاش نمی‌توانند تقریب خوبی از تغییرات محیطی را تخمین بزنند. از این رو، به روش‌هایی نیاز است که قابلیت حل چنین مشکلاتی را داشته باشد. شبکه عصبی مصنوعی^۷ به عنوان یکی از روش‌های محاسبات نرم از دقیق‌ترین و محبوب‌ترین روش‌های پیش‌بینی در مسائل مختلف به شمار می‌رود (Sharda، ۱۹۹۴). این روش دارای ویژگی‌های ارزشمند و قابل ملاحظه‌ای نسبت به سایر روش‌ها است که برخی از آن‌ها عبارتند از (Zhang et al.، ۱۹۹۸):

(۱) شبکه‌های عصبی برخلاف روش‌های سنتی و مرسوم، شبکه‌هایی خود تطبیقی^۸ و مبتنی بر داده‌ها هستند که در آن‌ها پیش‌فرض‌های کمی در مورد مدل‌های به کار گرفته برای مسائل مختلف وجود دارد.

4 Soft computing

5 Exponential smoothing

6 Box-Jenkins autoregressive integrated moving average (ARIMA) model

7 Artificial Neural Network (ANN)

8 Self- adaptive

- (۲) شبکه‌های عصبی به آسانی قابل تعمیم هستند، به گونه‌ای که پس از یادگیری با استفاده از داده‌های نمونه، قادر هستند قسمت‌های مشاهده نشده از جمعیت را، حتی با احتمال وجود اغتشاش در داده‌های نمونه، به درستی استنتاج و استخراج کنند.
- (۳) شبکه‌های عصبی می‌توانند به عنوان تقریب زنده‌هایی عمومی و قوی برای توابع مختلف استفاده شوند. برخی از محققین مانند (Hornik et al., ۱۹۸۹) نشان دادند که یک شبکه عصبی قادر است هر تابع پیوسته را با هر دقت مورد انتظاری تقریب بزند و به‌طور کلی، شبکه‌های عصبی بسیار جامع‌تر و انعطاف پذیرتر از روش‌های آماری سنتی برای تقریب توابع هستند.
- (۴) شبکه‌های عصبی غیرخطی هستند. روش‌های سنتی پیش‌بینی، مانند روش ARIMA، بر این فرض استوارند که سری‌های زمانی مبتنی بر فرآیندهای خطی هستند؛ در حالی که سیستم‌های دنیای واقعی عمدتاً غیرخطی هستند.
- از دیگر ویژگی‌های شبکه‌های عصبی می‌توان به قابل یادگیری بودن، قابلیت تعمیم، سرعت بالا به دلیل پردازش‌های موازی، قابلیت سازگاری با تغییرات سیستم و ... اشاره نمود.
- در یک شبکه عصبی، تعیین ساختار مناسب شبکه و انتخاب پارامترهای آن از اهمیت خاصی برخوردار است. هم‌چنین، موفقیت شبکه‌های عصبی تا حد زیادی به دقت و کارایی الگوریتم‌های یادگیری آن بستگی دارد. برای یادگیری شبکه عصبی الگوریتم‌های مختلفی ارائه شده است که پرکاربردترین آن‌ها الگوریتم‌های مبتنی بر گرادیان به ویژه الگوریتم پس انتشار و الگوریتم لونیگ-مارکوارت^۹ (LM) هستند. هرچند این الگوریتم‌ها از توانمندی زیادی برخوردار است، اما وجود چندین ضعف عمده در آن‌ها، مشکلاتی را در برخی موارد برای کاربران ایجاد می‌کند. الگوریتم‌های مبتنی بر گرادیان از تکنیک‌های جستجوی محلی استفاده می‌کنند و از این‌رو، همواره در معرض گیر افتادن در نقاط بهینه محلی^{۱۰} قرار دارند (Peyghami & Khanduzi, ۲۰۱۳). هم‌چنین، الگوریتم LM از پیچیدگی محاسباتی بالایی برخوردار است و به حافظه زیادی برای محاسبات نیاز دارد. لذا به روش‌هایی نیاز است که مشکلات الگوریتم‌های مبتنی بر گرادیان را نداشته باشد. یکی از مناسب‌ترین این روش‌ها الگوریتم‌های تکاملی^{۱۱} (EA) هستند. منظور از شبکه‌های عصبی تکاملی طراحی و آموزش شبکه‌های عصبی با استفاده از الگوریتم‌های تکاملی است. در سال‌های اخیر، رویکردهای ترکیبی شبکه‌های عصبی و الگوریتم‌های تکاملی توجه بسیاری به خود جلب کرده است. تاکنون، روش‌های مختلفی برای ترکیب این دو تکنیک معرفی

9 Levenberg-Marquardt

10 Local minima

11 Evolutionary algorithms

و مورد آزمایش قرار گرفته است که سه نوع اصلی آن عبارت‌اند از (Siddique & Adeli, ۲۰۱۳):

- ترکیب حمایتی^{۱۲}: در این روش، شبکه‌های عصبی و الگوریتم‌های تکاملی به تناوب مورد استفاده قرار می‌گیرند، به‌گونه‌ای که یکی از آن‌ها به عنوان رویکرد اصلی و دیگری به عنوان رویکرد حمایتی مورد استفاده قرار می‌گیرد.
- ترکیب مشارکتی^{۱۳}: در این روش، هر دو رویکرد به‌طور هم‌زمان و با هم به حل مسئله می‌پردازند.
- ترکیب آمیخته^{۱۴}: در این ترکیب، مکانیزم جستجوی الگوریتم تکاملی در الگویی از شبکه عصبی نمایش داده می‌شود.

الگوریتم‌های تکاملی توانایی زیادی برای انجام جستجوی سراسری و پرهیز از قرار گرفتن در بهینه محلی دارند. البته برخی از الگوریتم‌های تکاملی، مانند الگوریتم ژنتیک، از سرعت هم‌گرایی پایینی برخوردار هستند (Peyghami & Khanduzi, ۲۰۱۲). لذا، باید از الگوریتم‌هایی استفاده نمود که ضمن برطرف کردن مشکلات الگوریتم‌های مبتنی بر گرادیان، از سرعت هم‌گرایی مناسبی نیز برخوردار باشد. نمونه‌ای از این دسته الگوریتم‌ها، الگوریتم بهینه‌سازی گروهی ذرات^{۱۵} (PSO) است که علاوه بر حل مشکلات مربوط به الگوریتم‌های مبتنی بر گرادیان، از توانمندی زیادی برای انجام جستجوی سراسری برخوردار است.

تحقیق حاضر سعی دارد که ابتدا، مدل‌های شبکه عصبی و نحوه کاربرد آن‌ها در مسائل پیش-بینی را معرفی کند و در ادامه، نقاط ضعف این مدل‌ها را به ویژه در بخش آموزش شبکه بررسی و سپس از الگوریتم PSO برای بهبود فرآیند آموزش شبکه استفاده نماید و در انتها، مدل توسعه داده شده را در یکی از مباحث پیش‌بینی کاربردی در حوزه صنعت نفت به کار گیرد و نتایج را مورد تحلیل و بررسی قرار دهد.

ادامه این مقاله به صورت زیر سازمان‌دهی شده است. در بخش دوم، مبانی نظری و پیشینه تحقیق مورد بررسی قرار می‌گیرد. در فصل سوم، نحوه بکارگیری شبکه عصبی برای مسائل پیش‌بینی تشریح می‌شود. فرضیه‌ها و روش تحقیق در فصل چهارم و مدل ترکیبی شبکه عصبی و الگوریتم بهینه‌سازی گروهی ذرات در فصل پنجم معرفی می‌شود. در فصل ششم و هفتم نیز به ترتیب، نتایج شبیه‌سازی و بحث و نتیجه‌گیری ارائه می‌شود.

12 Supportive combination

13 Collaborative combination

14 Amalgamated combination

15 Particle Swarm Optimization

۲. مبانی نظری و پیشینه پژوهش

استفاده از شبکه‌های عصبی برای پیش‌بینی، با توجه به ماهیت غیرخطی بودن سیستم‌های طبیعی، رشد فزاینده‌ای را طی سال‌های اخیر به خود گرفته است، به‌گونه‌ای که اکثر محققین دیگر تمایلی به استفاده از مدل‌های آماری سنتی برای پیش‌بینی از خود نشان نمی‌دهند. برخی از پژوهشگران به مقایسه مدل‌های ARIMA و شبکه‌های عصبی در پیش‌بینی سری‌های زمانی در کاربردهای مختلف پرداخته‌اند (به حقیقت‌منفرد و همکاران، ۱۳۹۱)، (مکیان و موسوی، ۱۳۹۱)، (سالارپور و همکاران، ۱۳۹۱)، (Lasheras، ۲۰۱۵)، (Valipour et al.، ۲۰۱۳) مراجعه شود). Kohzadi et al. (۱۹۹۶) این دو مدل را برای پیش‌بینی هزینه کالاها به کار گرفتند. Adebity et al. (۲۰۱۴) مدل‌های ARIMA و شبکه‌های عصبی را برای داده‌های سهام منتشر شده از بورس اوراق بهادار نیویورک به کار گرفتند و نتایج را مورد مقایسه و بررسی قرار دادند. نتایج حاصل از بررسی آن‌ها نشان داد که شبکه‌های عصبی نسبت به مدل‌های ARIMA برتری دارند. Zhang et al. (۱۹۹۸) مطالعه جامعی بر روی کاربردهای شبکه عصبی در مباحث پیش‌بینی انجام دادند. آن‌ها همچنین در مقاله خود تشریح کاملی از نحوه به‌کارگیری شبکه‌های عصبی به عنوان ابزاری برای پیش‌بینی ارائه نمودند.

ایده اولیه به‌کارگیری شبکه‌های عصبی به عنوان ابزاری برای پیش‌بینی به سال ۱۳۶۴ برمی‌گردد؛ Hu (۱۹۶۴) در پایان‌نامه‌اش از یک شبکه خطی تطبیقی ویدرو^{۱۶} برای پیش‌بینی آب و هوا استفاده کرد. لازم به ذکر است که به علت فقدان الگوریتم‌های آموزشی برای شبکه‌های چند لایه در آن زمان، پژوهش‌های مرتبط با مباحث پیش‌بینی به صورت کاملاً محدود انجام می‌شد، تا اینکه در سال ۱۹۸۶ الگوریتم پس انتشار^{۱۷} (BP) توسط (Rumelhart et al.، ۱۹۸۶) معرفی شد. Werbos (۱۹۷۴-۱۹۸۸) اولین بار الگوریتم پس انتشار را برای شبکه‌های عصبی به کار گرفت و نشان داد که شبکه‌هایی که با استفاده از الگوریتم پس انتشار آموزش دیده‌اند عملکرد بهتری نسبت به روش‌های آماری سنتی مانند رگرسیون و ARIMA دارند. از اولین کاربردهای موفق شبکه‌های عصبی در مسائل پیش‌بینی می‌توان به پژوهش انجام‌شده توسط (Lapedes & Farber، ۱۹۸۸) اشاره کرد. آن‌ها با به‌کارگیری دو سری زمانی حاصل‌شده از نگاشت منطقی و معادله گلس-مک کی^{۱۸}، شبکه‌های عصبی پیش‌خور^{۱۹} را طراحی کردند که با استفاده از آن قادر بودند سیستم‌های غیرخطی پویا را با دقتی مناسب شبیه‌سازی و پیش‌بینی کنند.

در زمینه استفاده از شبکه‌های عصبی در حوزه مسائل نفتی تحقیقات مختلفی انجام شده است. شکیبایی و همکاران (۱۳۸۸) به پیش‌بینی میزان عرضه نفت خام در یازده کشور تولیدکننده با

16 Widrow's adaptive linear network

17 Backpropagation algorithm

18 Glass-Mackey

19 Feed-forward

استفاده از مدل‌های رگرسیون خطی و شبکه عصبی پرداختند که نتایج بررسی آن‌ها حاکی از برتری شبکه عصبی بر مدل رگرسیون خطی دارد. مکیان و موسوی (۱۳۹۱) پژوهشی بر روی پیش‌بینی قیمت سهام شرکت فرآورده‌های نفتی پارس با استفاده از شبکه عصبی و روش رگرسیونی انجام داده‌اند. ابونوری و خدادادی (۱۳۹۱) از دو الگوی شبکه عصبی مبتنی بر الگوریتم ژنتیک و ARIMA جهت پیش‌بینی قیمت نفت خام سنگین ایران استفاده کردند. یوسفی و همکاران (۱۳۹۲) به مدل‌سازی و پیش‌بینی تقاضای نفت خام در ایران با استفاده از شبکه عصبی پرداختند و به منظور ارزیابی دقت پیش‌بینی، این مدل را با مدل ARMAX مقایسه کردند. آن‌ها همچنین در مقاله خود، متغیرهای تعیین‌کننده تقاضای نفت خام در کشورهای منتخب عضو اوپک را مورد مقایسه قرار دادند. Chiroma et al. (۲۰۱۵) رویکردی مبتنی بر شبکه عصبی و الگوریتم ژنتیک برای پیش‌بینی قیمت نفت خام تگزاس غرب ارائه کردند. نتایج تحقیق آن‌ها نشان داد که مدل ترکیبی ارائه‌شده بهتر از الگوریتم‌های پایه شبکه عصبی عمل می‌کند.

۳. به‌کارگیری شبکه عصبی مصنوعی برای پیش‌بینی سری‌های زمانی

امروزه، شبکه‌های عصبی مصنوعی در مسائل مختلفی از دنیای واقعی به کار گرفته می‌شوند. از شناخته‌شده‌ترین کاربردهای شبکه‌های عصبی می‌توان به تقریب توابع، دسته‌بندی و خوشه‌بندی اطلاعات، ذخیره و بازیابی داده‌ها، بهینه‌سازی مسائل مقید، تعقیب مسیر و ... اشاره کرد. یکی از مهم‌ترین کاربردهای شبکه عصبی مصنوعی این است که از آن می‌توان به عنوان یک ابزار قوی برای پیش‌بینی سری‌های زمانی استفاده کرد.

رویکردهای مختلفی برای بکارگیری شبکه‌های عصبی برای مسائل پیش‌بینی وجود دارد که شبکه‌های عصبی پیش‌خور چند لایه^{۲۰} (MLFF-NN) دو نوع پرکاربرد آن‌ها هستند. (برای نمونه به (Sharda, ۱۹۹۴) مراجعه شود و در زمینه شبکه‌های بازگشتی^{۲۱} برای نمونه به (Kuan & Liu, ۱۹۹۵)، (Connor et al., ۱۹۹۴) مراجعه شود). به‌طور کلی، مدل پیش‌بینی برای مسائل سری زمانی به فرم عمومی زیر است:


$$X_t = f(X_{t-1}, X_{t-2}, \dots, X_{t-k}) \quad (1)$$

که در آن X_{t-1} ، X_{t-2} ، ... و X_{t-k} متغیرهای وابسته و X_t متغیر مستقل می‌باشند. شبکه‌های عصبی می‌توانند آموزش دیده شوند تا یک یا چند متغیر مستقل را پیش‌بینی نمایند که البته دقت پیش‌بینی وابستگی زیادی به آموزش مناسب شبکه دارد. MLFF-NN نوعی شبکه است

20 Multi-layer feed-forward neural networks

21 Recurrent networks

که از یک لایه ورودی به منظور دریافت اطلاعات، یک یا چند لایه پنهان و یک لایه خروجی به منظور ارائه جواب نهایی تشکیل شده است و دارای توانمندی‌های زیادی برای مسائل پیش‌بینی است. نمونه‌ای از یک شبکه MLFF-NN با ارتباط کامل بین گره‌ها در شکل (۱) نمایش داده شده است. قبل از به‌کارگیری شبکه عصبی برای پیش‌بینی، ابتدا باید داده‌های ورودی مسئله دسته‌بندی شود. در مقاله حاضر از رویکرد معرفی شده توسط (Khalili-Damghani & Sadi-Nezhad، ۲۰۱۱) برای دسته‌بندی ورودی‌ها استفاده می‌شود.



شکل (۱): نمونه‌ای از یک شبکه پیش‌خور دو لایه با ارتباط کامل بین گره‌ها

لازم به ذکر است که ساختار شبکه عصبی از قبل تعریف می‌شود و در طی اجرای برنامه تغییر نمی‌کند و همواره ثابت است، در حالی که، وزن‌های شبکه باید به صورت یک مسئله جستجوی بهینه سراسری فرموله شوند. ساختن یک شبکه عصبی پیش‌بینی کننده نیازمند اتخاذ تصمیمات مهمی است که هر یک از آن‌ها در این‌جا تشریح می‌شود:

- **تعداد گره‌های ورودی:** برای مسائل پیش‌بینی سری‌های زمانی، معمولاً تعداد گره‌های ورودی برابر تعداد متغیرهای وابسته استفاده شده در فرم عمومی مدل پیش‌بینی (مدل (۱)) در نظر گرفته می‌شود (Zhang et al., ۱۹۹۸).
- **تعداد گره‌های خروجی:** در شبکه‌های پیش‌بینی کننده، تعداد گره‌های خروجی معمولاً برابر با افق زمانی پیش‌بینی مسئله مورد بررسی در نظر گرفته می‌شود. همچنین دو نوع پیش‌بینی به صورت یک گام به جلو و چند گام به جلو وجود دارد که هر دو به صورت تکراری یا مستقیم قابل پیاده‌سازی هستند (Zhang et al., ۱۹۹۸)، (Zhang, ۱۹۹۴).

- تعداد لایه‌های پنهان و گره‌های آن: اکثر محققین مانند (Peyghami & Khanduzi, ۲۰۱۱ - ۲۰۱۲)، (Hornik et al., ۱۹۸۹) فقط یک لایه پنهان را برای شبکه‌های پیش‌بینی کننده در نظر می‌گیرند. آن‌ها معتقدند که شبکه‌های دارای یک لایه پنهان قادرند که هر تابع غیرخطی پیچیده را با هر دقت مورد نظری تخمین بزنند. برخی از محققین از دو لایه پنهان برای شبکه‌های پیش‌بینی کننده استفاده می‌کنند (Chester, ۱۳۹۰)، (Zhang, ۱۹۹۴)، (Sharda, ۱۹۹۴). لازم به ذکر است که اکثر محققین گذشته، از رویکردهای تجربی و سعی و خطا برای تعیین تعداد لایه‌های پنهان شبکه استفاده کرده‌اند. برای تعیین تعداد گره‌های لایه پنهان نیز رویکرد مشخصی وجود ندارد و عمده روش‌ها مبتنی بر سعی و خطا هست. Che (۲۰۱۰) پیشنهاد کرد که تعداد بهینه گره‌های لایه پنهان، عددی بین نصف مجموع گره‌های لایه‌های ورودی و پنهان و دو برابر گره‌های لایه ورودی انتخاب شود. Zhang et al. (۱۹۹۸) عقیده داشتند که اگر تعداد گره‌های لایه پنهان برابر تعداد گره‌های لایه ورودی در نظر گرفته شود نتایج بهتری از شبکه حاصل می‌گردد؛ Lippmann (۱۹۸۷) پیشنهاد کرد که تعداد اتم‌های لایه پنهان برابر $2n + 1$ "در نظر گرفته شود که n تعداد اتم‌های لایه ورودی هست.
- ارتباط بین گره‌ها: به‌طور کلی، ارتباط بین گره‌های لایه‌های مختلف مشخص‌کننده رفتار شبکه هست. در مسائل پیش‌بینی سری زمانی معمولاً شبکه به صورت ارتباط کامل در نظر گرفته می‌شود (Peyghami & Khanduzi, ۲۰۱۱ - ۲۰۱۲ - ۲۰۱۳).
- تابع انتقال: این تابع که تابع فعال‌سازی نیز نامیده می‌شود، مشخص‌کننده رابطه بین ورودی‌ها و خروجی‌های گره هست. توابع انتقال زیادی وجود دارد که در عمل، فقط تعدادی از آن‌ها شامل توابع سیگموئید^{۲۲}، تانژانت هیپربولیک، سینوس یا کسینوس و توابع خطی مورد استفاده قرار می‌گیرد.
- تعداد نمونه برای آموزش^{۲۳} و آزمایش^{۲۴}: در هر شبکه عصبی، مجموعه داده‌ها باید به دسته مجموعه آموزش و مجموعه آزمایش تقسیم شوند. مجموعه آموزش برای توسعه مدل شبکه و مجموعه آموزش برای ارزیابی توانایی مدل به منظور پیش‌بینی کردن استفاده می‌شود. در برخی موارد، مجموعه سومی به نام مجموعه اعتبار^{۲۵} برای تصدیق مدل در نظر گرفته می‌شود که معمولاً این مجموعه با مجموعه آزمایش یکی

22 Sigmoid

23 Training

24 Test

25 Validation

- در نظر گرفته می شود. لازم به ذکر است که میزان تقسیم داده های اولیه به دو (سه) مجموعه فوق یکی از پارامترهای اصلی شبکه های عصبی هست.
- **الگوریتم های آموزشی:** پرکاربردترین الگوریتم برای آموزش شبکه های عصبی الگوریتم پس انتشار هست. البته در سال های اخیر، از الگوریتم های تکاملی و نیز الگوریتم های ترکیبی برای آموزش شبکه استفاده شده است.
 - **نرمال سازی داده ها:** برخی توابع انتقال، تنها بازه های خاصی را برای داده های ورودی قبول می کنند. از این رو، باید از رویکردهایی برای تبدیل داده های ورودی به بازه های مورد نظر استفاده نمود که بتوان شرایط اولیه به کارگیری آن تابع را فراهم کرد. نرمال سازی خطی و نرمال سازی آماری از مهم ترین روش های این دسته هستند.
 - **سنجه های عملکرد^{۲۶}:** به طور کلی سنجه های عملکرد دقت، مبتنی بر خطای پیش بینی به دست آمده از اختلاف بین مقادیر واقعی و مقادیر پیش بینی شده هست. مهم ترین سنجه های عملکرد در شبکه های عصبی عبارت اند از: مجموع مربعات خطا^{۲۷}، میانگین مربعات خطا^{۲۸}، جذر میانگین مربعات خطا^{۲۹}، میانگین انحرافات مطلق^{۳۰} و میانگین درصد خطای مطلق^{۳۱}.

۴. فرضیه ها و روش تحقیق

در این تحقیق فرضیه اصلی عبارت است از: برای مسئله تحقیق حاضر، خطای پیش بینی حاصل از مدل شبکه عصبی آموزش دیده توسط الگوریتم PSO کوچک تر از یا مساوی خطای پیش بینی حاصل از مدل شبکه عصبی آموزش دیده توسط ۱۰ الگوریتم جدول (۱) (موجود در تابلو کس نرم افزار متلب) است.

منظور از خطای پیش بینی در عبارت فوق، خطای تعریف شده به صورت زیر است:

$$error = \frac{RMSE(Data_Test)}{2} * 100$$

به طوری که $Data_Test$ نشان دهنده داده های مربوط به بخش آزمایش هست. برای آزمون فرضیه اصلی، ده فرضیه آماری تدوین می گردد که در ذیل، یکی از آنها نوشته شده است:

26 Performance measures
 27 Sum of squared error (SSE)
 28 Mean squared error (MSE)
 29 Root mean squared error (RMSE)
 30 Mean absolute deviation (MAD)
 31 Mean absolute percentage error (MAPE)

H_0 : برای مسئله تحقیق حاضر، خطای پیش‌بینی حاصل از مدل شبکه عصبی آموزش‌دیده توسط الگوریتم PSO کوچک‌تر از یا مساوی خطای پیش‌بینی حاصل از مدل شبکه عصبی آموزش‌دیده توسط الگوریتم LM (trainlm) است.

H_1 : برای مسئله تحقیق حاضر، خطای پیش‌بینی حاصل از مدل شبکه عصبی آموزش‌دیده توسط الگوریتم PSO بزرگ‌تر از خطای پیش‌بینی حاصل از مدل شبکه عصبی آموزش‌دیده توسط الگوریتم LM (trainlm) است.

لازم به ذکر است که نه فرضیه آماری دیگر، مانند فرضیه فوق است و فقط به جای الگوریتم LM (trainlm) از الگوریتم‌های دیگر جدول (۱) استفاده می‌شود.

جدول (۱): الگوریتم‌های استفاده‌شده برای آموزش شبکه عصبی پیش‌بینی‌کننده (موجود در تویلباکس متلب)

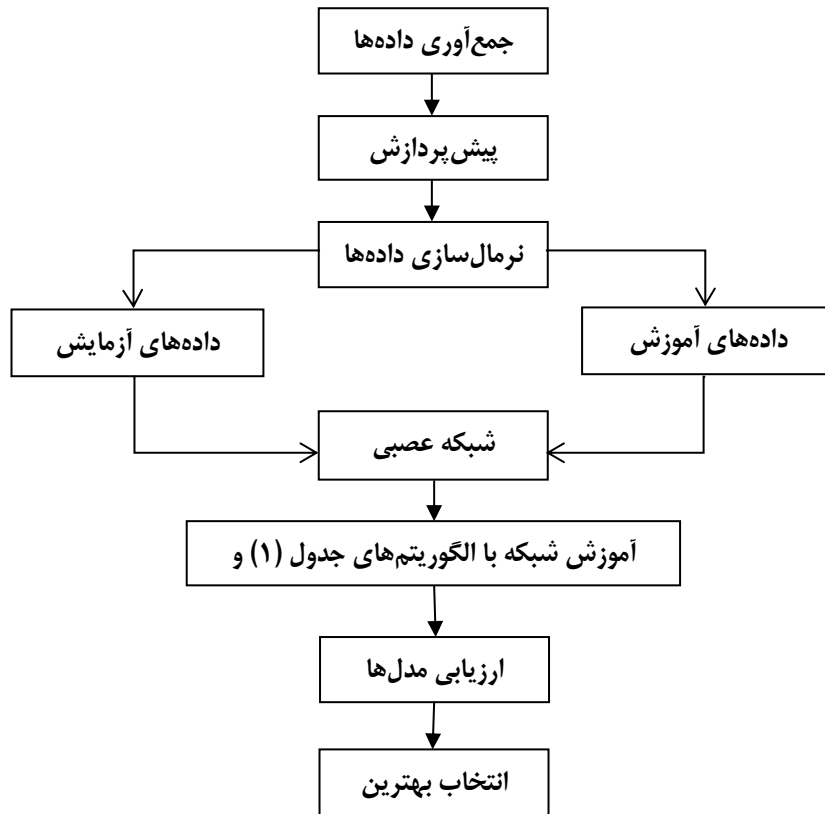
نام اختصاری الگوریتم	نام کامل الگوریتم
trainlm	Levenberg-Marquardt backpropagation
traingd	Gradient descent backpropagation
traingdx	Gradient descent with momentum and adaptive learning rate backpropagation
traingda	Gradient descent with adaptive learning rate backpropagation
traingdm	Gradient descent with momentum backpropagation
trainb	Batch training with weight and bias learning rules
trainbfg	BFGS quasi-Newton backpropagation
trainbr	Bayesian regulation backpropagation
trainoss	One-step secant backpropagation
trainrp	Resilient backpropagation

پژوهش حاضر از نوع مقایسه‌ای هست که با استفاده از داده‌های پس‌رویدادی جمع‌آوری شده به روش کتابخانه‌ای، فرضیات آزمون شده است. تحقیق حاضر از نظر مکانی محدود به بخش نفتی ایران و از نظر زمانی در برگیرنده دوره زمانی ژانویه سال ۱۹۹۴ الی آوریل ۲۰۱۵ هست و داده‌ها از نوع ماهیانه هستند. در دسترس بودن، جدید بودن و به‌اندازه کافی زیاد بودن داده‌ها برای به‌کارگیری شبکه عصبی از دلایل انتخاب این بازه زمانی می‌باشد. هم‌چنین قلمرو موضوعی آن،

پیش بینی سری زمانی میزان عرضه کل نفت ایران در بازه زمانی ذکر شده است. داده های تحقیق در سایت اینترنتی زیر قابل دستیابی هستند:

<http://www.eia.gov/cfapps/ipdbproject/iedindex3.cfm?tid=50&pid=53&aid=1&cid=&syid=1994&eyid=2015&freq=M&unit=TBPD>

رویه انجام پژوهش حاضر در شکل (۲) نمایش داده شده است.



شکل (۲): رویه انجام پژوهش حاضر

۵. مدل ترکیبی شبکه عصبی و الگوریتم بهینه سازی گروهی ذرات

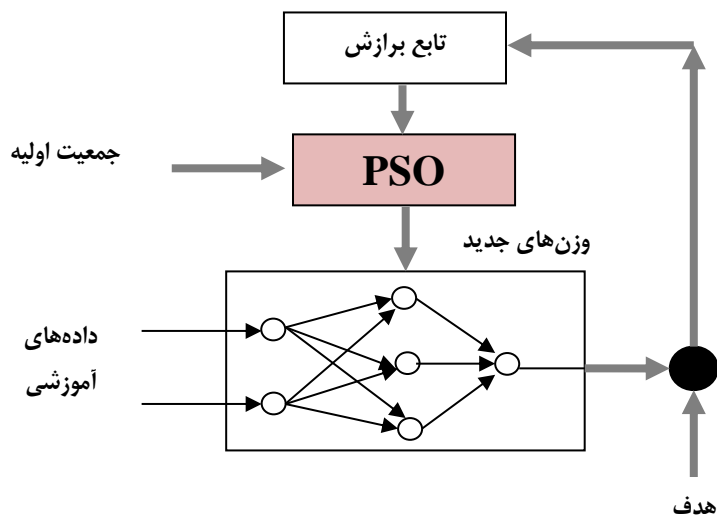
۵-۱- آموزش شبکه عصبی

هر شبکه عصبی باید آموزش دیده شود تا مقادیر مناسب وزن های شبکه تعیین گردد. دانش فراگرفته شده، به صورت وزن کمان و اریبی گره ها در شبکه ذخیره می شود (Zhang et al., ۱۹۹۸). فرآیند آموزش شبکه مانند یک مدل برنامه ریزی غیرخطی است که تابع هدف آن از سنجه های عملکرد تشریح شده در بخش قبل (مانند MSE و SSE) انتخاب می شود و هدف آن

یافتن وزن کمان‌های شبکه است، به‌گونه‌ای که سنج‌های عملکرد کمینه گردد. در شبکه‌های عصبی از آن جهت به یادگیری نیاز است که ارتباط بین ورودی‌ها و خروجی‌های شبکه به‌طور دقیق و کامل مشخص نیست (فروغی و همکاران، ۱۳۹۲).

روش‌های مختلفی برای آموزش شبکه‌های عصبی وجود دارد که پرکاربردترین آن‌ها تکنیک‌های مبتنی بر گرادیان است. همان‌طور که در بخش مقدمه تشریح شد، این روش‌ها دارای معایب مختلفی هستند. از این‌رو، محققین برای برطرف کردن این معایب از روش‌های دیگری برای آموزش شبکه استفاده می‌کنند که از مهم‌ترین آن‌ها می‌توان به الگوریتم‌های فرا ابتکاری اشاره کرد.

در تحقیق حاضر، از الگوریتم PSO برای آموزش شبکه استفاده شده است. رویه به‌کارگیری این الگوریتم در آموزش شبکه در شکل (۲) به تصویر کشیده شده است.



شکل (۲): فرآیند آموزش شبکه عصبی با استفاده از الگوریتم PSO

۲-۵- الگوریتم PSO

الگوریتم PSO یک تکنیک محاسباتی تکاملی است که توسط (Eberhart & Kennedy, ۱۹۹۵a-۱۹۹۵b) معرفی شده است. این الگوریتم بر اساس رفتار اجتماعی دسته پرندگان و ماهی‌ها طراحی شده است. برخلاف برخی الگوریتم‌های بهینه‌سازی تکاملی، مانند الگوریتم ژنتیک و برنامه‌ریزی تکاملی^{۳۳} (EP) که مبتنی بر رقابت و بقای اعضای قوی‌تر هستند، الگوریتم

PSO بر اساس اشتراک‌گذاری اطلاعات بین اعضای جمعیت رفتار می‌کند (Ismail et al., ۲۰۱۳). این الگوریتم در بسیاری از زمینه‌ها مانند شبکه‌های عصبی و کنترل سیستم‌های فازی عملکرد مناسبی از خود نشان می‌دهد. این الگوریتم با یک جمعیت اولیه شروع به کار می‌کند و در تکرارهای متوالی به سمت جواب بهینه حرکت می‌کند. در هر تکرار دو مقدار $X^{i-Pbest}$ و X^{Gbest} به دست می‌آید که این دو به ترتیب، نمایانگر بهترین مکان حاصل شده برای هر ذره در طول حرکت خود و بهترین مکان در جمعیت فعلی هست. اساس کار PSO بر این اصل استوار است که در هر لحظه هر ذره مکان خود را در فضای جستجو با بهترین مکانی که تاکنون خود در آن قرار گرفته و بهترین مکانی که در همسایگی‌اش وجود دارد تنظیم می‌کند (Eberhart & Kennedy, ۱۹۹۵a-۱۹۹۵b). با توجه به مقادیر فوق، سرعت حرکت و مکان بعدی ذره از دو رابطه زیر به دست می‌آید:

$$V_{j+1}^i = W_j V_j^i + c_1 r_1 (X_j^{i-Pbest} - X_j^i) + c_2 r_2 (X_j^{Gbest} - X_j^i) \quad (1)$$

$$X_{j+1}^i = X_j^i + V_{j+1}^i \quad (2)$$

در روابط فوق، c_1 و c_2 ضرایب یادگیری (پارامترهای شناختی و اجتماعی) انتخاب شده از بازه $[2,0]$ هستند و مقادیر آن‌ها قبل از حل مسئله مشخص می‌شود و r_1 و r_2 اعدادی تصادفی بین صفر و یک می‌باشند. همچنین V_j^i و X_j^i به ترتیب، نشان‌دهنده سرعت و موقعیت ذره i ام در تکرار j ام می‌باشند. برای توضیح بیشتر الگوریتم PSO به مقالات مرتبط مانند (Eberhart & Kennedy, ۱۹۹۵a-۱۹۹۵b)، (ElKady & Abdelsalam, ۲۰۱۶) رجوع شود.

۶. نتایج شبیه‌سازی

برای ساختن شبکه عصبی، از یک شبکه عصبی پیش‌خور دو لایه با ارتباط کامل بین گره‌ها استفاده شده است. سایر اطلاعات شبکه در جدول (۲) نشان داده شده است.


جدول (۲): ویژگی‌های ساختار شبکه

گره‌های لایه ورودی	گره‌های لایه مخفی	گره‌های لایه خروجی	توابع انتقال: لایه مخفی و لایه خروجی	اندازه داده‌ها: آموزش، آزمایش	بازه نرمال سازی داده‌ها
۴	۹	۱	Tansig & purelin	۸۰٪، ۲۰٪	[-1,1]


برای اجرای شبکه عصبی به ازای الگوریتم‌های جدول (۱) و الگوریتم PSO از نرم‌افزار MATLAB r2013a استفاده شده است. خطای پیش‌بینی حاصل از اجرای شبکه عصبی به ازای الگوریتم‌های آموزشی جدول (۱) و همچنین الگوریتم PSO در جدول (۳) نشان داده شده است. البته، لازم به ذکر است که به منظور کاهش انحرافات تصادفی، برنامه به ازای هر الگوریتم ۳۰ مرتبه تکرار شده و میانگین جواب‌های حاصل در جدول (۳) لحاظ شده است. شکل‌های (۳) و (۴) نیز به ترتیب، خروجی شبکه را به ازای داده‌های بخش آموزش و آزمایش نشان می‌دهد.

جدول (۳): خطای پیش‌بینی به ازای الگوریتم‌های آموزشی جدول (۱) و همچنین الگوریتم PSO

شماره	الگوریتم	میزان خطا
۱	trainlm	۱۱/۷۴۸۸
۲	traingd	۸/۶۱۹۵
۳	traingdx	۶/۰۶۸۷
۴	traingda	۶/۶۶۳۷
۵	traingdm	۸/۴۳۳۵
۶	trainb	۱۵/۲۱۳۴
۷	trainbfg	۱۵/۹۸۷۷
۸	trainbr	۹/۱۲۱۹
۹	trainoss	۹/۱۵۳۵
۱۰	trainrp	۷/۴۲۶۱
۱۱	PSO	۵/۳۵۷۲



شکل (۳): خروجی شبکه به ازای داده‌های بخش آموزش



شکل (۴): خروجی شبکه به ازای داده‌های بخش آزمایش

با توجه به مقادیر میزان خطا در جدول (۲)، مشاهده می‌شود که شبکه آموزش دیده با استفاده از الگوریتم PSO دارای خطای کمتری نسبت به ۱۰ الگوریتم دیگر هست و این، حاکی از آن است که هر ۱۰ فرضیه تحقیق پذیرفته می‌شود.

۷. بحث و نتیجه‌گیری

نفت به عنوان کالایی استراتژیک در کشور ایران همواره نقش کلیدی در تصمیم‌گیری‌های کلان اقتصادی دارد. در این مطالعه به پیش‌بینی سری زمانی میزان عرضه کل نفت ایران با استفاده از رویکرد شبکه عصبی مصنوعی پرداخته شده است. برای انجام پیش‌بینی، مدل‌های مختلفی در چند دهه اخیر معرفی شده است. مدل‌های آماری سنتی مانند ARIMA از توانایی بالایی برای پیش‌بینی در محیط‌های دارای اغتشاش برخوردار نیستند. شبکه‌های عصبی ابزار توانمندی برای پیش‌بینی هستند که برخلاف روش‌های آماری سنتی، قادرند سیستم‌های دارای ساختار غیرخطی را نیز تقریب بزنند و در آن‌ها پیش‌فرض‌های کمی در مورد مدل‌های به کار گرفته برای مسائل مختلف وجود دارد. این شبکه‌ها قادر هستند هر تابع پیوسته را با هر دقت مورد انتظاری تقریب بزنند و به‌طور کلی، بسیار جامع‌تر و انعطاف‌پذیرتر از روش‌های آماری سنتی برای تقریب توابع هستند.

علی‌رغم همه توانمندی‌های شبکه‌های عصبی، وجود مشکلاتی در بخش آموزش این شبکه‌ها پژوهش‌گران را همواره بر آن داشته است که از رویکردهای جانشین مناسبی برای آموزش شبکه استفاده کنند. الگوریتم‌های آموزشی پایه شبکه عصبی عمدتاً مبتنی بر روش‌گرادیان هستند که از تکنیک‌های جستجوی محلی استفاده می‌کنند و از این‌رو، همواره در معرض گیر افتادن در نقاط

بهینه محلی قرار دارند. همچنین برخی از انواع این الگوریتم‌ها مانند الگوریتم LM به حافظه زیادی برای محاسبات نیاز دارند. برای رفع این مشکلات، در تحقیق حاضر از یک الگوریتم فرا ابتکاری به نام PSO برای آموزش شبکه استفاده شده است که نتایج به‌کارگیری این الگوریتم در پیش‌بینی میزان کل عرضه نفت ایران، حاکی از برتری آن نسبت به الگوریتم‌های مبتنی بر گرادیان دارد.

یکی از مهم‌ترین محدودیت‌هایی که همواره در به‌کارگیری شبکه‌های عصبی به عنوان ابزار پیش‌بینی وجود دارد تعیین ساختار مناسب شبکه است که معمولاً با روش سعی و خطا با آن برخورد می‌شود. استفاده از روش‌های تکاملی برای تعیین ساختار مناسب شبکه، موضوعی است که کمتر مورد توجه پژوهش‌گران قرار گرفته است که برای تحقیقات آتی، انجام آن پیشنهاد می‌گردد. همچنین با توجه به اهمیت پژوهش در زمینه نفت و مشتقات آن، به‌کارگیری مدل تحقیق حاضر در موضوعاتی هم‌چون پیش‌بینی میزان تولید و مصرف نفت خام، گاز طبیعی، گاز مایع، محصولات پتروشیمی و ... پیشنهاد می‌گردد.

۸. منابع

- ابونوری، عباسعلی، خدادادی، ناهید. (۱۳۹۱). مقایسه عملکرد مدل‌های رگرسیونی ARIMA و شبکه عصبی با الگوریتم ژنتیک (GMDH) در پیش‌بینی قیمت نفت خام ایران. *مجله مهندسی مالی و مدیریت اوراق بهادار*، ۱۱، ۴۳-۶۲.
- حقیقت‌منفرد، جلال، احمدعلی‌نژاد، محمود، متقالچی، سارا. (۱۳۹۱). مقایسه مدل‌های شبکه عصبی با مدل سری زمانی باکس-جنکینز در پیش‌بینی شاخص کل قیمت سهام بورس اوراق بهادار تهران. *مجله مهندسی مالی و مدیریت اوراق بهادار*، ۱۱، ۱-۱۶.
- سالاریپور، ماشا...، نجاری، جعفر، سیدآقا حسینی، سیدمحسن، صبحی، محمود. (۱۳۹۱). پیش‌بینی صادرات غیرنفتی ایران تحت تاثیر تغییرات نرخ ارز با استفاده از مدل شبکه‌ی پرسپترون چند لایه (MLP). *دو فصلنامه اقتصاد پولی، مالی (دانش و توسعه سابق)*، ۱۹(۴)، ۱۰۱-۱۲۱.
- شکیبایی، علیرضا، نظام‌آبادی پور، حسین، حسینی، سیدجعفر. (۱۳۸۸). پیش‌بینی عرضه نفت خام در یازده کشور تولیدکننده با استفاده از شبکه‌های عصبی و رگرسیون خطی (۲۰۰۶-۱۹۸۰). *مجله دانش و توسعه*، ۲۷، ۹۸-۱۱۹.
- فرج‌زاده، منوچهر. (۱۳۸۶). *تکنیک‌های اقلیم‌شناسی*. تهران: انتشارات سمت.
- فروغی، داریوش، فروغ‌نژاد، حیدر و میرزایی، منوچهر. (۱۳۹۲). پیش‌بینی سود هر سهم: ترکیب شبکه‌های عصبی مصنوعی و الگوریتم بهینه‌سازی حرکت تجمعی ذرات. *فصلنامه علمی پژوهشی دانش سرمایه‌گذاری*، ۶، ۸۲-۶۳.
- مکیان، سید نظام‌الدین، موسوی، فاطمه السادات. (۱۳۹۱). پیش‌بینی قیمت سهام شرکت فرآورده‌های نفتی پارس با استفاده از شبکه عصبی و روش رگرسیونی، مطالعه موردی: قیمت سهام شرکت فرآورده‌های نفتی پارس. *فصلنامه مدل‌سازی اقتصادی*، ۱۸، ۱۰۵-۱۲۱.
- یوسفی، محمدقلی، محمدی، تیمور، معرف‌زاده، نوید. (۱۳۹۲). پیش‌بینی تقاضای نفت خام در ایران با استفاده از شبکه‌های عصبی مصنوعی (ANN) و مدل ARMAX. *فصلنامه اقتصاد انرژی ایران*، ۷، ۱۴۷-۱۷۰.
- Adebiyi, A. A. Adewumi, A. O. & Ayo, C. K. (2014). Comparison of ARIMA and artificial neural networks models for stock price prediction. *Journal of Applied Mathematics*, 1-7.
- Che, Z. (2010). PSO-based back-propagation artificial neural network for product and mold cost estimation of plastic injection molding. *Computers & Industrial Engineering*, 58(4), 625-637.
- Chester, D. L. (1990). *Why two hidden layers are better than one*. In *Proceedings of the international joint conference on neural networks*. Washington, DC: IEEE.
- Chiroma, H., Abdulkareem, S., & Herawan, T. (2015). Evolutionary Neural Network model for West Texas Intermediate crude oil price prediction. *Applied Energy*, 142, 266-273.
- Connor, J. T., Martin, R. D., & Atlas, L. E. (1994). Recurrent neural networks and robust time series prediction. *IEEE Transactions on Neural Networks*, 5(2), 240-254.

- Eberhart, R. C., & Kennedy, J. (1995a). *A new optimizer using particle swarm theory*. Paper presented at the Proceedings of the sixth international symposium on micro machine and human science.
- Eberhart, R. C., & Kennedy, J. (1995b). *Particle swarm optimization*. Paper presented at the Proceedings, Perth, Australia of IEEE International Conference on Neural Network.
- ElKady, S. K., & Abdelsalam, H. M. (2016). A Modified Particle Swarm Optimization Algorithm for Solving Capacitated Maximal Covering Location Problem in Healthcare Systems. *Applications of Intelligent Optimization in Biology and Medicine*, 96, 117-133.
- Funahashi, K.I. (1989). On the approximate realization of continuous mappings by neural networks. *Neural networks*, 2(3), 183-192.
- Hornik, K., Stinchcombe, M., & White, H. (1989). Multilayer feedforward networks are universal approximators. *Neural networks*, 2(5), 359-366.
- Hu, M.J.C. (1964). *Application of the adaline system to weather forecasting*. (Master Thesis). Technical Report 6775-1. Stanford Electronic Laboratories. Stanford. CA. June.
- Ismail, A., Jeng, D.-S., & Zhang, L. (2013). An optimised product-unit neural network with a novel PSO-BP hybrid training algorithm: Applications to load-deformation analysis of axially loaded piles. *Engineering applications of artificial intelligence*, 26(10), 2305-2314.
- Khalili-Damghani, K., & Sadi-Nezhad, S. (2011). Application of multi-layer recurrent neural network in chaotic time series prediction: a real case study of crude oil distillation capacity. *International Journal of Artificial Intelligence and Soft Computing*, 2(4), 367-380.
- Kohzadi, N., Boyd, M. S., Kermanshahi, B., & Kaastra, I. (1996). A comparison of artificial neural network and time series models for forecasting commodity prices. *Neurocomputing*, 10(2), 169-181.
- Kuan, C. M., & Liu, T. (1995). Forecasting exchange rates using feedforward and recurrent neural networks. *Journal of Applied Econometrics*, 10(4), 347-364.
- Lapedes, A., & Farber, R. (1988). How neural nets work. In: Anderson, D.Z. (Ed.). *Neural Information Processing Systems*. American Institute of Physics. New York, 442-456.
- Lasheras, F. S., de Cos Juez, F. J., Sánchez, A. S., Krzemień, A., & Fernández, P. R. (2015). Forecasting the COMEX copper spot price by means of neural networks and ARIMA models. *Resources Policy*, 45, 37-43.
- Lippmann, R. P. (1987). An introduction to computing with neural nets. *ASSP Magazine, IEEE*, 4(2), 4-22.
- Peyghami, M. R., & Khanduzi, R. (2011). A hybrid model based on neural network and hybrid genetic algorithm for automotive price forecasting. *International Journal of Applied Mathematics and Computation*, 3(3), 158-168.
- Peyghami, M. R., & Khanduzi, R. (2012). Predictability and forecasting automotive price based on a hybrid train algorithm of MLP neural network. *Neural Computing and Applications*, 21(1), 125-132.
- Peyghami, M. R., & Khanduzi, R. (2013). NOVEL MLP NEURAL NETWORK WITH HYBRID TABU SEARCH ALGORITHM. *Neural Network World*, 3(13), 255-270.

- Rumelhart, D. E., Hinton, G. E., & Williams, R. J. (1986). Learning representations by back-propagating errors. *Nature*, 323, 533-538.
- Sharda, R. (1994). Neural networks for the MS/OR analyst: An application bibliography. *Interfaces*, 24(2), 116-130.
- Siddique, N., & Adeli, H. (2013). *Computational intelligence: synergies of fuzzy logic, neural networks and evolutionary computing*: John Wiley & Sons.
- Valipour, M., Banihabib, M. E., & Behbahani, S. M. R. (2013). Comparison of the ARMA, ARIMA, and the autoregressive artificial neural network models in forecasting the monthly inflow of Dez dam reservoir. *Journal of Hydrology*, 476, 433-441.
- Werbos, P. J. (1974). *Beyond regression: New tools for prediction and analysis in the behavioral sciences*. (Ph.D Thesis). Harvard University, USA.
- Werbos, P. J. (1988). Generalization of backpropagation with application to a recurrent gas market model. *Neural networks*, 1(4), 339-356.
- Zhang, G., Patuwo, B. E., & Hu, M. Y. (1998). Forecasting with artificial neural networks: The state of the art. *International journal of forecasting*, 14(1), 35-62.
- Zhang, X. (1994). Time series analysis and prediction by neural networks. *Optimization Methods and Software*, 4(2), 151-170.

Time series prediction using a hybrid model based on artificial neural network and particle swarm optimization: a case study of total oil supply in Iran

Mohammad Amir Khan¹, Hosein Dideh-khani², Amir Hosein Zahedi Anaraki³

Abstract

The prediction of macro-economic variables is of particular importance to politicians and economists of countries. In this paper, an efficient method based on an artificial neural network approach presented to predict time series of total supply of Iranian oil. Thereafter, this network was trained using 10 training algorithms available in MATLAB toolbox and results were obtained. In order to enhance the efficiency of the network, a meta-heuristic algorithm called particle swarm optimization (PSO) was applied to train the network. In order to evaluate the accuracy of prediction and investigate the efficiency of the proposed model, a performance measure was first introduced and then, the actual data related to the total Iranian oil supply was used for prediction. The results obtained from the running the model for the mentioned training algorithms demonstrated the superiority of PSO algorithm to other training algorithms.

Key words: prediction, time series, artificial neural network, particle swarm optimization, oil.

¹ PhD student of Industrial Engineering, Department of Industrial Engineering, Islamic Azad University, South-Tehran Branch (Corresponding Author) (st_m_amirkhan@azad.ac.ir).

² PhD of Industrial Engineering, Assistant Professor, Department of Management, Islamic Azad University, Aliabad Katoul Branch.

³ University of Applied Science and Technology.