

بررسی مقایسه‌ای توان پیش‌بینی شبکه‌های عصبی مصنوعی با روش توقف زود هنگام و فرایند سری زمانی خودبازگشت در برآورد نرخ تورم

پیام حنفی‌زاده

اسنادیار گروه مدیریت صنعتی، دانشگاه علامه طباطبائی، دانشکده مدیریت و حسابداری
hanafizadeh@gmail.com

حسین پورسلطانی

کارشناسی ارشد مدیریت فناوری اطلاعات، دانشگاه علامه طباطبائی، دانشکده مدیریت و حسابداری

پریسا ساکتی

کارشناسی ارشد مدیریت فناوری اطلاعات، دانشگاه علامه طباطبائی، دانشکده مدیریت و حسابداری

تاریخ دریافت: ۱۳۸۶/۲/۲۵ تاریخ پذیرش: ۱۳۸۶/۱۱/۱

چکیده

این مقاله به بررسی مقایسه‌ای توان شبکه‌های عصبی مصنوعی و سری‌های زمانی خودبازگشت در پیش‌بینی ایستای نرخ تورم ایران می‌پردازد. در یک بررسی، با استفاده از ۳۷ سال داده‌های تاریخی نرخ تورم ایران، مدل شبکه عصبی مصنوعی در پیش‌بینی آینده نزدیک در مقایسه با سری‌های زمانی خودبازگشت، به‌طور متوسط از عملکرد بهتری برخوردار است. در این بررسی، مزایای روش توقف زود هنگام در مرحله یادگیری شبکه عصبی برای پیش‌بینی سری‌های زمانی نشان داده شده است.

طبقه‌بندی JEL: C51, C52, C53, E37

کلید واژه: پیش‌بینی، تورم، انتخاب مدل، شبکه عصبی، سری‌های زمانی

۱- مقدمه

شبکه‌های عصبی مصنوعی کاربردهای روزافزونی در اقتصاد پیدا کرده‌اند. این کاربردها به‌خصوص در حوزه برآورد نرخ ارز^۱ و متغیرهای مالی^۲ مشهودند. در مقابل،

1- Exchange Rate.

2- Financial Statistics.

مطالعات اندکی در کاربرد این شبکه‌ها برای برآورد سری‌های زمانی اقتصاد کلان، انجام شده است. مطالعات محدودی هم که انجام شده‌اند، با کاستی‌هایی مواجه‌اند. یکی از این مطالعات متعلق به مشیری و کامرون (۲۰۰۰)^۱، است. در این مطالعه، یک مدل شبکه عصبی پیش‌خور با فرایند یادگیری پس‌انتشار خطا برای پیش‌بینی ایستای نرخ تورم مورد استفاده قرار گرفته است. اما همان‌گونه که ذکر شد، این روش نیز کاستی‌هایی دارد که مقاله حاضر تلاش می‌کند با معرفی روشی جدید، این کاستی‌ها را کاهش دهد. روایی پایین از جمله مشکلات عمده این روش‌ها است. افزایش زمان و حجم عملیات محاسباتی در مرحله یادگیری مدل‌های شبکه عصبی نیز از دیگر نقاط ضعف این روش به شمار می‌رود. در کاربردهای اخیر شبکه‌های عصبی در پیش‌بینی سری‌های زمانی، برای جلوگیری از افزایش حجم عملیات محاسباتی، روش پیش‌پردازش^۲ و برای افزایش روایی، مدل توقف زود هنگام^۳ پیشنهاد شده است. این مقاله نشان می‌دهد که این روش‌ها در مواجهه مؤثر با رفتارهای غیرخطی داده‌های نرخ تورم از اهمیت ویژه‌ای برخوردارند. باید این نکته را در نظر داشت که یافته‌های استوک و واتسون (۱۹۹۸)^۴ در پیش‌بینی سری‌های زمانی اقتصاد کلان، نشان می‌دهند که شبکه‌های عصبی در برآورد روابط خطی بسیار ضعیف عمل می‌کنند.

علاوه بر بخش مقدمه، این مقاله در چهار بخش دیگر سازمان یافته است. در بخش دوم، پیش‌زمینه‌ای از کاربرد شبکه عصبی در پیش‌بینی سری‌های زمانی و روش‌شناسی ارزیابی شبکه عصبی ارائه شده است. بخش سوم به توصیف روش ساخت، آموزش و آزمایش مدل شبکه عصبی پیشنهادی می‌پردازد. کارایی عملکرد این مدل و نتایج حاصل از به‌کارگیری آن، در بخش چهارم مورد بررسی قرار گرفته است. جمع‌بندی و نتیجه‌گیری نیز در بخش پنجم ارائه شده است.

۲- پیش‌زمینه و روش‌شناسی

مهم‌ترین جذابیت شبکه‌های عصبی، انعطاف آن‌ها در تخمین دامنه وسیعی از روابط و توابع بین مقادیر داده‌ها و ستاده‌ها است. شبکه‌های عصبی‌ای که به قدر کافی پیچیده

1- Moshiri and Cameron (2000).

2- Preprocessing.

3- Early Stopping.

4- Stock and Watson (1998).

باشند، می‌توانند تخمینی با دقت مطلوب را از هر تابع دلخواه ارائه کنند. این ویژگی سبب می‌شود تا امکان جدیدی برای تخمین‌های بهتر روابط و توابع متداول غیرخطی در حوزه اقتصاد کلان به‌وجود آید.

در کاربرد شبکه عصبی در پیش‌بینی، می‌توان آن را به‌عنوان یک تابع غیرخطی پارامتری در نظر گرفت، که بر روی مجموعه‌ای از داده‌ها به‌کار می‌رود. این تابع غیرخطی را می‌توان به‌صورت ترکیبی از قطعاتی غیرخطی (تابع فعال‌سازی^۱)، به‌کار گرفت، که هر یک توجیه‌کننده بخشی از رفتار کلی داده‌های مورد استفاده در پیش‌بینی‌اند. یکی از این توابع غیرخطی که در پیش‌بینی سری‌های زمانی بسیار متداول است، تانژانت هیپربولیک است. این تابع به‌عنوان تابع فعال‌سازی در شبکه عصبی استفاده شده است.

تعداد نورون^۲ و لایه^۳ تشکیل دهنده شبکه عصبی، ساختار و چگونگی ارتباط توابع غیرخطی فعال‌سازی و داده‌ها را مشخص می‌کند. با افزایش تعداد توابع فعال‌سازی - که حاصل افزایش نورون‌ها و لایه‌های شبکه است - انعطاف شبکه عصبی در پیش‌بینی افزایش می‌یابد.

الگوریتم‌های یادگیری^۴ شبکه عصبی بسیار شبیه به روش‌های حداقل‌سازی متداول، مانند کم‌ترین مربعات غیرخطی^۵ اند. به‌طور خلاصه، الگوریتم‌های یادگیری پارامترهای شبکه را آن‌چنان برآورد می‌کنند که معیار خطای پیش‌بینی آن‌ها مکرراً کاهش یابد. گفتنی است که روش‌های متداول در شبکه عصبی تفاوت‌های مهمی با روش‌های اقتصادسنجی دارند.

به‌طور کلی مسأله روایی در مورد تمامی روش‌های برآوردیابی مطرح است. یک برآوردگر زمانی از روایی مطلوب برخوردار است، که علاوه بر خطای پایین برآوردهایش در پیش‌بینی داده‌های نمونه، از دقت کافی در انجام پیش‌بینی‌های خارج از نمونه نیز برخوردار باشد و به‌نحوی پیش‌بینی‌های آن تعمیم‌پذیر باشند.

شبکه‌های عصبی - که در این بررسی به‌عنوان یک روش برآوردیابی مورد استفاده قرار گرفته‌اند نیز از این قاعده کلی مستثنی نیستند. هنگامی که شبکه عصبی برای

1- Activation Function.
2- Neuron.
3- Layer.
4- Learning Algorithms.
5- Nonlinear Least Square.

داده‌های نمونه برآوردی نزدیک و قابل قبول ارائه کند، اما برای داده‌های خارج از نمونه برآوردی ضعیف انجام دهد، در حقیقت روایی خود را از دست داده و بیش‌برازش^۱ به مثابه یک عارضه انجام شده است. در چنین شرایطی، افزایش حجم نمونه نه تنها کمکی به حل مسأله نمی‌کند، بلکه بیش از پیش شبکه را محدود کرده و از تعمیم‌پذیری آن می‌کاهد. این طور به نظر می‌رسد که شبکه‌های عصبی به دلیل انعطاف‌پذیری بالا در تخمین توابع گوناگون، مستعد^۲ بیش‌برازش باشند.

برای پیش‌گیری از بیش‌برازش، باید الگوریتم یادگیری شبکه عصبی را مورد بازنگری قرار داد و آن را پیش از افتادن در نقطه کمینه موضعی^۳ متوقف کرد. یکی از روش‌های متداول برای مواجهه با این وضعیت، اعتبارسنجی مبنایی^۴ شبکه عصبی با استفاده از روش توقف زودهنگام است.

در روش توقف زودهنگام ابتدا داده‌ها به دو دسته داده‌های آموزش^۴ و داده‌های اعتبارسنجی^۵ تقسیم می‌شوند. سپس الگوریتم یادگیری با استفاده از داده‌های آموزش برای آموزش شبکه اجراء می‌شود. همانند دیگر روش‌های یادگیری الگوریتم یادگیری در جهت کاهش (عکس‌گردان) خطا عمل می‌کند. اما در روش توقف زودهنگام این روال مقید به این شرط است که میانگین مربعات خطای شبکه بر روی داده‌های اعتبارسنجی افزایش نیابد. از آن جا که این اتفاق معمولاً بسیار پیش‌تر از آن که حداقل میانگین مربعات خطای شبکه بر روی داده‌های آموزش به دست آید، رخ می‌دهد، این روش را توقف زود هنگام می‌نامند. نمودار (۱) نمایی ساده از این روش را نشان می‌دهد.

در این مقاله مزایای استفاده از مدل شبکه عصبی برای پیش‌بینی ایستای نرخ تورم بر اساس ارزیابی و مقایسه عمل کرد مدل مذکور با مدل‌های سری‌های زمانی خود بازگشت^۶ یک متغیره^۷ مورد بررسی قرار گرفته است. برای مقایسه این دو روش از معیار معیار کارایی نسبی برآوردگرها استفاده شده است. این معیار، حاصل از نسبت میانگین مربعات خطای شبکه عصبی به میانگین مربعات خطای مدل سری زمانی خود بازگشت

$$\text{بر روی داده‌های اعتبارسنجی است } (W = \frac{MSE_{NN}}{MSE_{AR}}).$$

-
- 1- Overfitting.
 - 2- Local Minima.
 - 3- Cross-Validation.
 - 4- Training Data.
 - 5- Validation Data.
 - 6- Autoregressive.
 - 7- Univariate.

۳- ریخت‌شناسی و آموزش شبکه عصبی

برای پیش‌بینی نرخ تورّم از شبکه بسیار ساده‌ای استفاده شده است.

$$\hat{\pi}_t = I_1 \cdot \tanh(I_1 \cdot x_{t-1} + b_1) + I_2 \cdot \tanh(I_2 \cdot x_{t-1} + b_2) + I_3 \cdot \tanh(I_3 \cdot x_{t-1} + b_3) + I_4 \cdot \tanh(I_4 \cdot x_{t-1} + b_4) + I_5 \cdot \tanh(I_5 \cdot x_{t-1} + b_5) + b_6$$

در این شبکه، $\hat{\pi}_t$ پیش‌بینی نرخ تورّم فصل آتی و x_{t-1} برداری متشکل از نرخ‌های تورّم پنج فصل پیشین است، که به صورت $x_{t-1} = [\pi_{t-1}, \pi_{t-2}, \pi_{t-3}, \pi_{t-4}, \pi_{t-5}]$ تعریف می‌شود. مقادیر I_i, I_i, b_i نیز پارامترهای شبکه‌اند. در ادبیات شبکه‌های عصبی، به پارامترهای I_i بردار وزن‌های ورودی و به پارامترهای b_i وزن‌های لایه‌ها می‌گویند. پارامترهای b_i نیز آریبی نرون‌ها را مشخص می‌کنند. لازم به ذکر است که در این شبکه پیش‌بینی نرخ تورّم در هر دوره به پنج دوره پیش از خود وابسته است. این شبکه بر اساس یک فرایند تک‌متغیره طراحی شده و به‌طور معادل با فرآیند خودبازگشت تک‌متغیره مورد استفاده قرار می‌گیرد.

شبکه با جستجو از میان بدیل‌های مختلف انتخاب شده است. در بدیل‌های دیگری که مورد آزمایش قرار گرفته‌اند، از توابع فعال‌سازی غیرخطی دیگری به جای تانژانت هیپربولیک استفاده شده و وقفه‌های اول تا هشتم فرایند خودبازگشت نیز مورد آزمایش قرار گرفته‌اند. این تغییرات تأثیر اندکی بر نتایج داشته‌اند و به‌منظور حفظ اختصار شرح این بررسی‌ها گزارش نشده‌اند.

برای انتخاب الگوریتم یادگیری مناسب تلاش زیادی شده است. از میان الگوریتم‌های یادگیری مختلف، الگوریتم لونیبرگ-مارکواریت^۱ انتخاب شده است. این الگوریتم علاوه بر این که کمینه خطای شبکه را به‌دست می‌دهد، نرخ هم‌گرایی پایینی نیز دارد، که سبب می‌شود شبکه بسیار سریع‌تر از زمانی که از الگوریتم‌های متعارف استفاده می‌شود، هم‌گرا شود.

داده‌های آموزش و اعتبارسنجی بر اساس یک روش ابتکاری از میان داده‌های نمونه انتخاب شده‌اند. در این روش زوج داده‌های آموزش (ورودی-خروجی‌های شبکه) بر اساس موقعیت‌شان در مجموعه داده‌ها در هر یک از این دو دسته قرار گرفته‌اند. به این صورت که زوج داده اول (یعنی $[x_5, \pi_6]$)، به مجموعه آموزش و زوج داده دوم (یعنی $[x_6, \pi_7]$) به مجموعه اعتبارسنجی تخصیص داده شده و به همین ترتیب تا به انتها.

1- Levenberg-Marquardt.

از آن جا که کمینه موضعی و نواحی اطراف آن در شبکه‌های عصبی یک مسأله جدی تلقی می‌شود، مطابق روش متداول، شبکه مذکور را با تعداد قابل توجهی از مقادیر تصادفی انتخابی برای پارامترها آموزش می‌دهیم و از میان پارامترهای حاصل، آن مقداری را که بر اساس شاخص انتخاب (در این جا از حداقل میانگین مربعات خطا استفاده شده است) بهترین است، برمی‌گزینیم. اما/شباع^۱ کردن فضای پارامترها با تعداد زیادی از مقادیر اولیه تصادفی نیز نامطلوب است. بنابراین، با استفاده از روش آزمون و خطا، مقادیر کمینه شده پارامترهایی که در جهت عکس توقف زودهنگام قرار دارند را پیدا می‌کنیم.

برای این منظور، با استفاده از ۱۰۰ مجموعه تصادفی مختلف از پارامترها، شبکه را بر روی داده‌های آموزش و اعتبارسنجی آزموده و مجموعه‌ای که کم‌ترین میانگین مربعات خطا را داشته باشد، به عنوان مقادیر اولیه^۲ پارامترهای شبکه عصبی انتخاب می‌کنیم.

برای مقایسه نیز سری‌های زمانی خودبازگشت با وقفه‌های بین یک تا هشت را با استفاده از رابطه زیر محاسبه می‌کنیم:

$$\hat{\pi}_t = a. + \sum_{i=1}^k a_i \pi_{t-i}$$

در این رابطه، $\hat{\pi}_t$ برآورد خودبازگشت تورم فصل است و k نیز تعداد وقفه‌هایی است که این برآورد به آن وابسته است. به جای استفاده از روش‌های پیچیده‌تر انتخاب مدل مناسب سری زمانی (مثل روش باکس-جنکینز^۳)، صرفاً بر اساس تفسیر توابع خودهمبستگی^۴ و خودهمبستگی جزئی^۵ سری زمانی، نتایج مدل‌های مختلف برای تمامی وقفه‌های محتمل در فرایند خودبازگشت مورد بررسی قرار گرفته‌اند.

مجموعه داده‌های مورد استفاده در این تحقیق، نرخ‌های تورم فصلی بین سال‌های ۱۳۴۸ و ۱۳۸۴ هجری خورشیدی‌اند که از سال‌نامه‌های بانک مرکزی جمهوری اسلامی ایران استخراج شده‌اند. این داده‌ها به دو قسمت تقسیم شده‌اند. بخش نخست از ۱۳۴۸ تا ۱۳۷۵ برای آموزش و اعتبارسنجی شبکه و بخش دوم از ۱۳۷۶ تا ۱۳۸۴ برای

1- Saturation.

2- Initial Values.

3- Box-Jenkins.

4- Auto Correlation Function (ACF).

5- Partial Auto Correlation Function (PACF).

آزمایش و مقایسه مدل شبکه عصبی با مدل‌های سری زمانی خودبازگشت مورد استفاده قرار گرفته است.

نمودار (۲)، گام‌های مختلف مطالعه را به اختصار نمایش می‌دهد. هم‌چنین برای پیاده‌سازی شبکه عصبی، از محیط برنامه‌نویسی مت‌لب^۱ استفاده شده است. نتایج به‌دست آمده از این محیط، با استفاده از محیط برنامه‌نویسی اس-پلاس^۲ با سری‌های زمانی فوق‌الذکر مقایسه شده است.

۴- نتایج

جدول (۱)، نسبت میانگین مربعات خطای مدل شبکه عصبی به مدل خود بازگشت را نمایش می‌دهد. در افق‌های زمانی کوتاه‌مدت (یک و دو فصل آتی)، مدل شبکه عصبی از میانگین مربعات خطای کم‌تری نسبت به مدل‌های سری زمانی خودبازگشت برخوردار است. در افق‌های زمانی بیشتر (سه و چهار فصل آتی)، میانگین مربعات خطای دو روش برابر بوده و با افزایش زمان، میانگین مربعات خطای مدل شبکه عصبی از مدل‌های سری زمانی خودبازگشت بیشتر می‌شود. البته باید در نظر داشت که به‌دلیل استفاده از داده‌های آموزش و اعتبارسنجی به‌عنوان داده‌های آزمون، شبکه به‌دلیل تمهیداتی که برای بیش‌برازش در نظر گرفته شده، میانگین مربعات خطای بسیار کم‌تری را نسبت به داده‌های خارج از نمونه داراست. بنابراین، انتظار می‌رود با استفاده از مجموعه جدیدی از داده‌های آزمون، میانگین مربعات خطا افزایش یابد، اما نسبت‌های مذکور تغییراتی اندک را شاهد باشند.

الگوریتم یادگیری شبکه عصبی نقش مؤثری در میزان موفقیت مدل ایفا می‌کند. جدول (۲)، نسبت میانگین مربعات خطای شبکه عصبی‌ای را که با استفاده از الگوریتم کم‌ترین مربعات غیرخطی محاسبه شده است، به میانگین مربعات خطای شبکه‌ای که با استفاده از الگوریتم پیشین محاسبه شده است، نمایش می‌دهد. همان‌طور که در این جدول مشهود است، میانگین مربعات خطای الگوریتم یادگیری جدید در افق‌های زمانی کوتاه‌مدت (یک تا سه فصل آتی) بیش از روش پیشین است، اما در افق‌های زمانی طولانی‌تر، میانگین مربعات خطای این روش نسبت به روش پیشین کاهش می‌یابد.

1- MATLAB.

2- S-PLUS.

جدول (۲)، نشان می‌دهد که یکی از دلایل مهم نتایج مثبتی که در این تحقیق به دست آمده‌اند، استفاده از روش توقف زود هنگام در الگوریتم یادگیری شبکه عصبی است. این مسأله کاهش مقدار میانگین مربعات خطای الگوریتم یادگیری‌ای که از این روش استفاده کرده، نسبت به الگوریتم یادگیری‌ای که از چنین ویژگی‌ای بی‌بهره است، در جدول (۲) نمایان شده است. روش توقف زود هنگام برای شبکه‌های عصبی پیچیده‌تر، مهم‌تر است، زیرا این شبکه‌ها بیشتر مبتلا به بیش‌برازش‌اند.

جدول (۲)، مؤید این نکته نیز هست که روش توقف زود هنگام خالی از ایراد نیست، نکته‌ای که در متون شبکه عصبی نیز به آن اشاره شده است. میانگین مربعات خطایی که با استفاده از این روش و برای چهار فصل آتی محاسبه می‌شود، بیشتر از زمانی است که از این روش استفاده نمی‌کنیم. باید توجه داشت که به کارگیری روش توقف زود هنگام، تنها روش مواجهه با مسأله بیش‌برازش نیست و می‌توان روش‌های دیگری را نیز جستجو کرد. با توجه به این نتایج، برای پیش‌بینی در فواصل نزدیک زمانی، استفاده از روش توقف زود هنگام در الگوریتم یادگیری شبکه عصبی مطلوب است، حال آن که این مزیت برای فواصل زمانی طولانی‌تر از میان خواهد رفت.

۵- جمع‌بندی

کاربردهای موجود شبکه‌های عصبی در حوزه اقتصاد کلان مؤید این مطلب است که این شبکه‌ها در برآورد مدل‌های خطی بسیار ضعیف عمل می‌کنند. این تحقیق به نتایج مثبتی در برآورد نرخ تورم با استفاده از شبکه‌های عصبی دست یافته است. شبکه عصبی طراحی شده می‌تواند در فواصل زمانی کوتاه‌مدت، یعنی یک یا دو فصل آتی، برآورد بهتری از نرخ تورم را نسبت به فرآیندهای سری زمانی خودبازگشت ارائه کند. نتایج به دست آمده نشان می‌دهد که به کارگیری روش توقف زود هنگام نقش مؤثری در کسب این موفقیت داشته است.

۶- فهرست منابع

- 1- Barnett, William A., Alfredo Medio, and Apostolos Serletis, (2003) "Nonlinear and Complex Dynamics in Economics", Working Paper.
- 2- Chen, Xiaohong, J. Racine, and N. Swanson, (2001), "Semiparametric ARX Neural Network Models with an Application to Forecasting Inflation," *IEEE Transactions on Neural Networks*, Vol 12, 674-683.


- 3- Gonzalez, Steven, (2000) "Neural Networks for Macroeconomic Forecasting: A Complementary Approach to Linear Regression Models," Finance Canada Working Paper.
- 4- Hornik, K., M. Stinchcombe, and H. White, (1989), "Multilayer Feedforward Networks are Universal Approximators," *Neural Networks*, Vol 2, 359–366.
- 5- Lebaron, B. and A.S. Weigend, (1998), "A Bootstrap Evaluation of the Effect of Data Splitting on Financial Time Series," *IEEE Transactions on Neural Networks*, Vol 9 (1), 213–220.
- 6- Moshiri, Saeed and Norman Cameron, (2000), "Econometrics Versus ANN Models in Forecasting Inflation," *Journal of Forecasting*, Vol 19, February,
- 7- Stock, James H. and Mark W. Watson, (1998) "A Comparison of Linear and Nonlinear Univariate Models for Forecasting Macroeconomic Time Series," June. NBER Working Paper 6607.

جدول ۱ - نسبت میانگین مربعات خطای مدل شبکه عصبی (بدون توقف زودهنگام) به مدل خودبازگشت

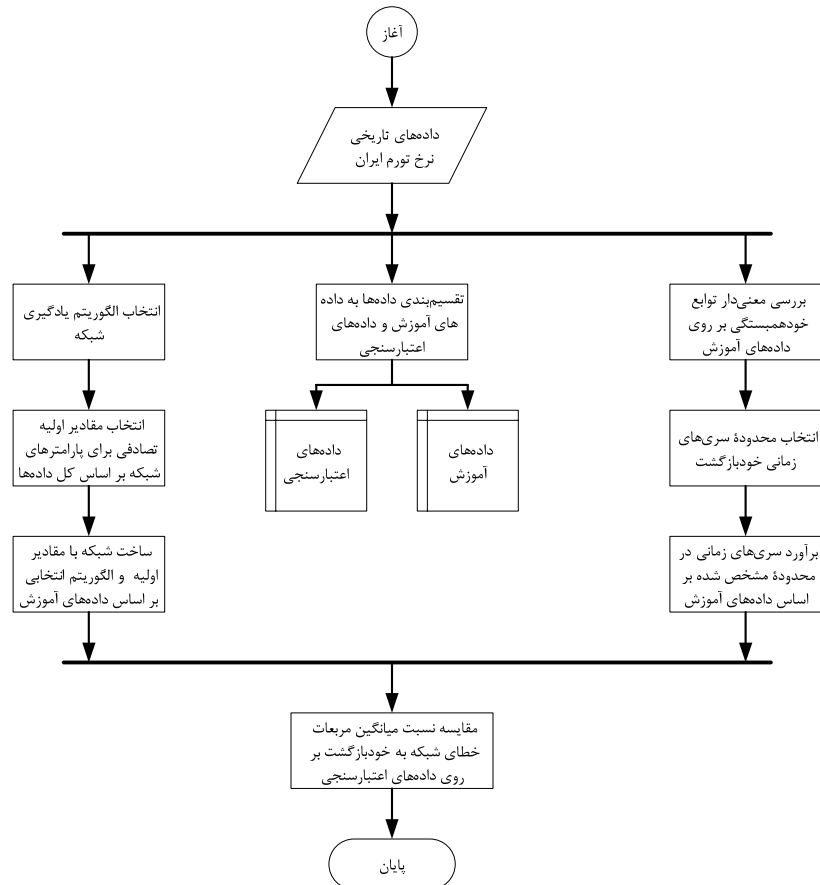
	افق زمانی پیش‌بینی (فصل)			
	1	2	3	4
AR(1)	0.72	0.77	0.77	0.85
AR(2)	0.73	0.81	0.81	0.86
AR(3)	0.73	0.81	0.85	0.90
AR(4)	0.72	0.83	0.85	0.90
AR(5)	0.72	0.82	0.87	0.90
AR(6)	0.72	0.82	0.86	0.92
AR(7)	0.74	0.84	0.87	0.94
AR(8)	0.76	0.84	0.88	0.93

جدول ۲ - نسبت میانگین مربعات خطای شبکه عصبی با توقف زودهنگام به شبکه عصبی بدون توقف زودهنگام

	افق زمانی پیش‌بینی (فصل)			
	1	2	3	4
MSE Ratio	0.94	0.92	0.92	0.99



نمودار ۱ - روش توقف زودهنگام در یادگیری شبکه عصبی



نمودار ۲ - مراحل مختلف مطالعه