

پیش بینی تورم ایران با استفاده از مدل های ساختاری، سری های زمانی و شبکه های عصبی^۳

دکتر سعید مشیری

عضو هیأت علمی دانشکده اقتصاد دانشگاه علامه طباطبایی

چکیده

امروزه، پیش بینی متغیرهای کلان اقتصادی از اهمیت ویژه ای برای سیاستگذاران و سایر واحدهای اقتصادی برخوردار است. در نتیجه، در دهه های اخیر، مدل های پیش بینی گوناگونی توسعه یافته و به رقابت با یکدیگر پرداخته اند. اخیراً به موازات مدل های متداول قبلی مانند مدل های ساختاری و سری های زمانی، مدل های دیگری تحت عنوان شبکه های عصبی مصنوعی در زمینه پیش بینی متغیرهای مالی و پولی به کار گرفته شده اند. این مدل ها که در حقیقت اقتباس از فرایند یادگیری مغز انسان هستند، با استفاده از سرعت محاسباتی کامپیوتر، روابط بین متغیرها را هر چند پیچیده باشند، یاد گرفته و از آن برای پیش بینی مقادیر آتی استفاده می نمایند. از ویژگی های مهم این مدل ها می توان به آزادی آنها از فرض آماری مربوط به متغیرها، استفاده از روش های محاسباتی موازی و غیرخطی بودن آنها اشاره نمود. در این مقاله، علاوه بر معرفی مدل های شبکه های عصبی و نحوه کاربرد آنها در اقتصاد، یک مدل شبکه عصبی برای پیش بینی تورم در ایران با استفاده از اطلاعات سال های (۱۳۷۷-۱۳۳۸) طراحی و اجرا شده است. نتایج به دست آمده حاکی از آن است که مدل های شبکه های عصبی در غالب موارد عملکرد بهتری در زمینه پیش بینی تورم دوره آتی ایران نسبت به رقبای خود دارند.

کلید واژه ها

پیش بینی / تورم / مدل های ساختاری / مدل های سری های زمانی / مدل های شبکه های عصبی مصنوعی

۳ این مقاله مستخرج از یک طرح تحقیقاتی که با حمایت معاونت پژوهشی دانشگاه علامه طباطبایی انجام شده است می باشد. قسمتی از بخش ۳ مقاله تحت عنوان "شبکه های عصبی و کاربردهای آن در اقتصاد و بازارگردانی" در مجزوم مجموعه سخنرانی های علمی گروه اقتصاد دانشکده اقتصاد دانشگاه علامه طباطبایی در بهمن ۷۸ چاپ شده است.

مقدمه

یکی از مهمترین کاربردهای مدل‌های اقتصادی، پیش‌بینی مقادیر آتی متغیرهای اقتصادی است. در حقیقت، مدل‌های اقتصادی را می‌توان با میزان صحت پیش‌بینی‌شان مورد آزمون قرار داد، بدین ترتیب که اگر یک مدل اقتصادی در تبیین روابط موجود بین متغیرها موفق باشد، باید قادر به پیش‌بینی صحیحی از آینده متغیرها نیز باشد. ارتباط پیش‌بینی متغیرهای اقتصادی با عملکرد سیاست‌های پولی و مالی کشورها اهمیت پیش‌بینی را افزون‌تر نیز کرده است. در حال حاضر، اکثر دولت‌ها و بانک‌های مرکزی، سیاست‌های مالی و پولی‌شان را نه صرفاً بر مبنای وضع موجود، بلکه بر مبنای پیش‌بینی‌های کوتاه و بلند مدت از متغیرهای کلیدی اقتصادی تدوین کرده و به مورد اجرا می‌گذارند. بدیهی است که میزان صحت پیش‌بینی این متغیرها، صرف نظر از درستی سیاست‌های مالی و پولی و تناسب آنها با شرایط موجود، از جمله رموز موفقیت این سیاست‌ها می‌تواند به شمار آید.

چنین اهمیتی باعث شده است تا تحقیقات در زمینه مدل‌ها و تکنیک‌های پیش‌بینی در چند دهه اخیر، با شتاب بیشتری مواجه شوند به طوری که امروزه در ادبیات اقتصاد سنجی و اقتصاد کاربردی، شاهد مدل‌ها و روش‌های بسیاری در این زمینه می‌باشیم. برخی از این دستاوردها، حاصل توسعه مدل‌ها و روش‌های موجود و برخی دیگر بر مبنای آرایه دیدگاه‌های جدید که هنوز نیز در حال گسترش هستند، بوده‌اند. دیدگاه سنتی و متداول در مدل‌سازی اقتصادی، مبتنی بر تبیین روابط بین متغیرهای اقتصادی بر مبنای رفتار عقلایی واحدهای اقتصادی اعم از تولیدکنندگان، مصرف‌کنندگان و سیاست‌گذاران اقتصادی بوده است. اقتصاددانان با برآورد این ارتباطات، با استفاده از روش‌های متنوع اقتصاد سنجی، سعی در تبیین وضع موجود، پیش‌بینی مقادیر آتی متغیرهای وابسته و همچنین آرایه سیاست‌ها و خط‌مشی‌های اقتصادی دارند. این مدل‌ها که نوعاً مدل‌های ساختاری نامیده می‌شوند، اگرچه قادر به تبیین نسبی وضع موجود بوده و از لحاظ تحلیلی به عنوان ابزار مناسبی برای سیاست‌گذاری اقتصادی مورد استفاده قرار گرفته‌اند ولی متأسفانه، در زمینه پیش‌بینی سابقه چندان موفق‌تری از خود به جای نگذاشته‌اند.

وجود این کاستی مهم و از طرفی، اهمیت روزافزون پیش‌بینی برای سیاستگذاران دولتی، بانکی و بخش خصوصی، به تدریج شرایط و دیدگاه جدیدی برای مدل‌سازی فراهم نمود. در این دیدگاه که نوعاً به سری‌های زمانی موسومند، وظیفه پیش‌بینی متغیرهای اقتصادی بیش از هر چیز به عهده خودشان گذاشته می‌شود. به عبارت دیگر، از آنجا که یک متغیر اقتصادی حاوی کلیه اطلاعات مربوط به آن است، یعنی تجلی کلیه کنش‌ها و ارتباطاتی است که منجر به شکل‌گیری آن می‌شود لذا قوی‌ترین منبع برای توضیح تغییرات خود آن متغیر محسوب می‌شود. طبق این دیدگاه اگر بتوان فرایندی که بر مبنای آن، مقادیر مربوط به یک متغیر تحقق می‌یابد^۱ را کشف کرد پیش‌بینی مقادیر آتی آن متغیر کار بسیار سختی نخواهد بود. ضعف عمده مدل‌های سری‌های زمانی عبارت از این است که به محقق اجازه تعیین سهم نسبی سایر عوامل در تغییرات متغیر مورد نظر را نمی‌دهند و لذا برای سیاستگذاری، قابلیت استفاده کمتری دارند. این ضعف تا حدودی با آرایه مدل‌های سری‌های زمانی چند متغیره مانند مدل اتورگرسیون برداری که توسط سیمز (۱۹۸۰)^۲ معرفی گردید، مرتفع شده، است.

اخیراً، دیدگاه دیگری نیز به موازات مدل‌های سری‌های زمانی در ادبیات اقتصاد کاربردی وارد شده است که طبق آن می‌توان با استفاده از هوش مصنوعی^۳ روابط بین متغیرها را هر چند پیچیده باشند، توسط کامپیوتر فراگرفت و از آن برای پیش‌بینی مقادیر آتی استفاده نمود. این دیدگاه که در حقیقت اقتباسی از فرایند یادگیری مغز انسان (هوش طبیعی) است، ابتدا در سایر رشته‌های علمی مانند فیزیک، کامپیوتر و مهندسی در زمینه‌های تشخیص الگو^۴ و طبقه‌بندی^۵ و کنترل^۶ مورد استفاده قرار گرفت که نتایج بسیار موفقی نیز به دنبال داشت. اقتصاددانان از اواسط دهه ۹۰ شروع به استفاده از این مدل‌ها که نوعاً به مدل‌های شبکه‌های عصبی^۷، یادگیری ماشین^۸ و یا

1- Data Generating process

2- Sims

3- Artificial Intelligence

4- Pattern recognition

5- Classification

6- Control

7- Neural Networks

8- Machine Learning

هوش مصنوعی موسومند، در زمینه پیش بینی طبقه بندی نمودند. طبق این دیدگاه، اگر بتوان روابط موجود بین متغیرهای اقتصادی را با استفاده از روش های جستجو در اطلاعات از طریق کامپیوتر فراگرفت، می توان از آنها برای پیش بینی مقادیر آتی نیز استفاده نمود. مزیت مهم این مدل ها نسبت به سایر مدل های ساختاری و سری های زمانی عبارت از این است که در طراحی این مدل ها، نیازی به اعمال فروض آماری خاص در مورد رفتار متغیرها مانند فروض مربوط به تابع توزیع احتمال آنها و یا اعمال فروض مربوط به نحوه ارتباط بین متغیرها نیست. مدلسازان شبکه های عصبی می توانند با استفاده از تکنولوژی پیشرفته کامپیوتر و به ویژه سرعت حیرت آور محاسباتی آن و بدون نیاز به فروض استاندارد مدل های متداول، ارتباط بین متغیرها را هر چند که پیچیده نیز باشند، فراگرفته و از آن برای پیش بینی بهره گیرند. استفاده از این مدل ها در اقتصاد، از پیش بینی و طبقه بندی در بازارهای مالی و پولی مانند پیش بینی تغییرات نرخ سهام یا نرخ برابری ارز شروع شد و از اواخر دهه ۱۹۹۰ به اقتصاد کلان نیز سرایت کرد^۱.

مدل های شبکه های عصبی به رغم کاربردهای بسیار مفید و مثبتی که در زمینه های گوناگون علمی داشته اند، از برخی لحاظ مورد نقد نیز قرار گرفته اند. در واقع، نقطه قوت مدل های شبکه های عصبی از لحاظ آزادی از قید و بندهای مفروضات مدل های آماری و سنجی، از نظر برخی آماردانان و اقتصاددانان همان نقطه ضعف آن نیز بشمار می رود. این محققین، بعضاً مدل های شبکه های عصبی را به جعبه ای سیاه که هیچ گونه اطلاعی از کم و کیف فعل و انفعالات درونی آن در دست نیست، تشبیه می کنند. از نظر این منتقدین، اگر نتوان از لحاظ آماری مدل و نتایج آن را ارزیابی کرد، به عنوان مثال سطح اعتماد مقادیر پیش بینی شده را مشخص نمود، نمی توان از آنها استفاده به عمل آورد. یا اینکه اگر قرار باشد اینگونه مدل ها بدون نیاز به تئوری های اقتصادی از هر گونه متغیر دلخواه برای توضیح تغییرات متغیرهای مورد نظر استفاده نمایند و برآزش خوبی نیز تحویل دهند، چگونه می توان به نتایج آنها اطمینان داشت؟

۱- برخی از کاربردهای اولیه این مدل ها را می توان در کتاب (Tripi, Truban (1993) و کاربردهای اولیه شبکه های عصبی در اقتصاد کلان را در (Swanson & White (1997)، (Maasomi, et al (1996) و (Moshiri & Cameron (2000) پیدا کرد.

به نظر می‌رسد، از هر دو بعد تقدیر و انتقاد از اینگونه مدل‌ها زیاده روی شده است. از طرفی، ادعای اینکه این مدل‌ها محققین را از تئوری‌های اقتصادی و همچنین تجزیه و تحلیل‌ها و استنباطات متداول آماری بی‌نیاز ساخته‌اند، ادعایی بی‌پایه و اثبات نشده است و از طرف دیگر، جعبه سیاه تلقی کردن این مدل‌ها و به عبارتی منفعل خواندن محققین در ارتباط با آنها را نیز نمی‌توان بسیار معتبر دانست. برخی تحقیقات مانند مشیری و کامرون (۲۰۰۰)^۱ نشان داده‌اند که هر چند می‌توان بدون استفاده جزء به جزء از تئوری‌های اقتصادی به برآزش خوبی از متغیرهای مورد نظر دست یافت اما نمی‌توان نتایج خوبی در پیش‌بینی به دست آورد. از نظر آماری نیز تحقیقات زیادی مانند کان و وایت (۱۹۹۴)^۲ در ارتباط با یافتن ویژگیهای آماری این مدل‌ها و انطباق آنها با مفاهیم رگرسیون صورت گرفته و نتایج قابل‌ارایه‌ای نیز داشته‌اند.

مقاله حاضر سعی دارد که اولاً، مدل‌های شبکه‌های عصبی و نحوه کاربرد آنها در اقتصاد را معرفی نماید و دوم، کاربرد این مدل‌ها را در ارتباط با پیش‌بینی تورم اقتصاد ایران در مقایسه با مدل‌های ساختاری و سری‌های زمانی، مورد مقایسه قرار دهد. فرضیه تحقیق عبارت از این است که مدل‌های شبکه‌های عصبی اگر به‌طور مناسبی از لحاظ ساختار درونی و هم‌چنین استفاده از تئوری‌های اقتصادی و آماری طراحی شوند، قادر خواهند بود در امر پیش‌بینی متغیرهای اقتصادی در بسیاری موارد بر سایر مدل‌های رقیب، برتری قابل‌ملاحظه‌ای داشته باشند.

در بخش اول، مدل‌های ساختاری و سری‌های زمانی برای پیش‌بینی تورم در اقتصاد ایران طراحی و برآورد می‌شوند. در بخش دوم، مدل‌های شبکه‌های عصبی معرفی می‌شوند و به دنبال آن، در بخش سوم، یک مدل شبکه عصبی برای پیش‌بینی تورم در اقتصاد ایران ارائه می‌گردد. مقایسه عملکرد مدل‌های پیش‌گفته و نتیجه‌گیری، در بخش آخر به دست داده می‌شود.

1- Moshiri & Cameron (2000)

2- Kuan & White (1994)

۱- مدل‌های ساختاری و سری‌های زمانی برای پیش‌بینی تورم در ایران

در این بخش، ابتدا یک مدل ساختاری با استفاده از منحنی فیلیپس تعمیم یافته معرفی می‌شود و سپس، طراحی یک مدل سری‌های زمانی برای پیش‌بینی تورم در اقتصاد ایران ارائه می‌گردد. برای برآورد و پیش‌بینی تورم در چارچوب مدل‌های فوق، نیاز به برآورد تولید بالقوه و هم‌چنین بررسی ویژگی‌های مانایی متغیرها و امکان هم‌انباشتگی بین آنها وجود دارد که جزئیات آنها در زیر توضیح داده خواهند شد. جزئیات مربوط به استراتژی پیش‌بینی نیز در بخش نتایج پیش‌بینی آمده است.

۱-۱- مدل ساختاری تورم

مدل‌های ساختاری گوناگونی در ادبیات اقتصادی مربوط به تورم وجود دارند که معروفترین و معتبرترین آنها را می‌توان بر پایه منحنی فیلیپس که در آن تورم با شکاف تولید یا نرخ بیکاری مربوط می‌شود، به دست آورد. با توجه به ادبیات موجود، می‌توان اظهار کرد که تاکنون مدل‌های تورم مبتنی بر منحنی فیلیپس، صحیح‌ترین پیش‌بینی‌ها را نسبت به سایر مدل‌های ساختاری دیگر ارائه داده‌اند.^۱ با توجه به اهمیت انتظارات تورمی در شکل‌گیری تورم، شکل تعمیم یافته‌تری از منحنی فیلیپس را نیز می‌توان معرفی نمود که علاوه بر متغیر شکاف تولید، انتظارات تورمی را هم در مدل دخالت می‌دهد. اگر معادله منحنی فیلیپس تعمیم یافته را به عنوان معادله عرضه کل در نظر گرفته و با معادله تقاضای کل که از حل معادلات IS-LM به دست می‌آید و در آن تقاضای کل تابعی از حجم پول و انتظارات تورمی می‌باشد، ترکیب نماییم آنگاه می‌توان فرم خلاصه شده تورم را استخراج نمود. در این صورت، تورم (π) تابعی از شکاف تولید (y)، عرضه پول واقعی (m) که بیانگر فشار تقاضاست و همچنین انتظارات تورمی (π^e) خواهد بود که به صورت زیر نمایش داده می‌شود.^۲

$$\pi_t = \theta_0 + \theta_1 y_{t-1} + \theta_2 m_t + \sum_{i=0}^n \rho_i \pi_{t-i-1} + \theta_3 \pi_t^m + \eta_t$$

1- Stock & Watson (1999)

۲- برای جزئیات بیشتر به Scarth (1998) و Moshiri, Cameron (2000) مراجعه نمایید.

در ارتباط با تصریح فوق، توضیح چند نکته ضروری است. اول، متغیر شکاف تولید که از تفاضل تولید واقعی و تولید بالقوه به دست می‌آید از طریق معادله عرضه کل و به صورت وقفه در معادله وارد شده است تا فرایند تعدیل ارتباط بین تورم و شکاف تولید را پوشش دهد. دوم، متغیر عرضه پول یا فشار تقاضا نیز به صورت اختلاف عرضه پول واقعی از عرضه پول متناسب با شرایط تعادلی اقتصاد در معادله وارد می‌شود. سوم، فرایند شکل‌گیری انتظارات یک فرایند تطبیقی^۱ فرض شده است که طبق آن، مردم در هر دوره انتظارات تورمی خود از دوره بعد را با توجه به خطاهای گذشته‌شان به تدریج تعدیل می‌کنند. بنابراین، بجای متغیر تورم انتظاری (π^e) از وقفه‌های تورم ($\sum p_i \pi_{t-i}$) استفاده شده است. چهارم، با توجه به اینکه اقتصاد متکی به نفت ایران، صرف‌نظر از عوامل داخلی عملاً تحت تأثیر تورم خارجی از طریق واردات است، متغیر تورم وارداتی (π^m) از دل متغیر اختلال (η_1) بیرون آمده و به‌طور صریح در مدل وارد شده است. پنجم، متغیر η_1 که به‌عنوان متغیر تصادفی با میانگین صفر و واریانس ثابت در معادله وارد شده است، معرف شوک‌های عرضه کل و تقاضای کل است.

۲-۱- مدل سری‌های زمانی

طبق دیدگاه مدل‌های سری‌های زمانی یک متغیره، تورم را می‌توان صرفاً تابعی از مقادیر گذشته خود در نظر گرفت. به عبارت دیگر، مقادیر سطح تورم در دوره‌های قبل حاوی کلیه اطلاعات لازم مربوط به عوامل تعیین‌کننده تورم بوده و لذا قادر خواهند بود تورم دوره جاری را به‌خوبی توضیح داده و مقادیر آتی آن را پیش‌بینی نمایند. بنابراین، مسأله مهم در این روش تنها تعیین تعداد وقفه‌های تورم و همچنین تشخیص ساختار متغیر تصادفی در مدل می‌باشد. برای این کار از روش استاندارد و متداول در این زمینه یعنی روش باکس - جنکینز استفاده خواهیم کرد. در این روش، تعداد وقفه‌ها و ساختار متغیر تصادفی بر اساس توابع خودهمبستگی^۲ و خودهمبستگی جزئی^۳ بین خطاهای

1- Adaptive Expectations

2- Autocorrelation Function (ACF)

3- Partial Autocorrelation Function (PACF)

مدل تعیین می‌گردند.

نکته قابل توجه در هر دو مدل ساختاری و سری زمانی عبارت از این است که آیا می‌توان از متغیرها به همان صورتی که هستند، استفاده کرد یا باید آنها را به صورت‌های انتقال یافته در مدل وارد نمود. علت طرح این سوال ناشی از نکته مهمی در ادبیات اقتصاد سنجی و سری‌های زمانی است مبنی بر آن که اگر سری‌های مورد استفاده در مدل غیرمانا^۱ و یا دارای روند زمانی^۲ باشند، نتایج به دست آمده از مدل و بویژه نتایج مربوط به استنباط آماری، معتبر نخواهند بود^۳. بنابراین، قبل از برآورد مدل‌های ارایه شده، باید ابتدا متغیرها را برای مانا بودن آزمون نمود و سپس با توجه به نتایج به دست آمده، فرم مناسب آنها را در مدل انتخاب کرد. آزمون استاندارد دیکی - فولر تعمیم یافته که نتایج آن در ضمیمه آمده است، نشان می‌دهد که متغیرهای تورم (π_t)، شکاف تولید (y_t)، و عرضه پول واقعی (m_t) غیر مانا هستند ولی متغیر اختلاف تورم خارجی با تورم داخلی (π_t^m) مانا می‌باشد. البته، نتایج این آزمون‌ها تا حد زیادی به حجم نمونه، وقفه‌های موجود در معادله آزمون و همچنین درصد اطمینان تعیین شده، بستگی دارند. به عنوان مثال، y_t در سطح ۱ درصد مانا ولی در سطح ۵ درصد غیر مانا است^۴.

همچنین، از آنجا که غیر مانا بودن متغیرها ممکن است به علت انتقال یکباره میانگین و یا روند زمانی سری‌ها باشد، لذا برای اطمینان بیشتر باید تأثیر این انتقال را در نتیجه آزمون‌ها خنثی نمود. از آنجا که در سری‌های زمانی اقتصاد کلان ایران، امکان وجود تغییرات ساختاری در دوران انقلاب و جنگ وجود دارد، آزمون‌های تغییرات ساختاری چاو و کوزم (CUSUM) برای تعیین چنین تغییرات ساختاری در متغیرهای مدل یعنی تورم، شکاف تولید، عرضه پول و تورم وارداتی صورت گرفت. نتایج آزمون‌های فوق، هیچ یک، بر وجود چنین تغییرات ساختاری معنی‌داری دلالت نکردند. به رغم عدم تأیید تغییرات ساختاری در متغیرهای فوق، آزمون مانایی با حضور متغیرهای مجازی

1- Non-stationary

2- Time Trend

3- Granger & Newbold (1974)

۴- کلیه داده‌های مورد استفاده در این مقاله از دیسکت اطلاعات PDS موسسه پژوهش‌های سازمان مدیریت و برنامه‌ریزی کشور استخراج شده‌اند.

انفرادی و متقاطع و با استفاده از مقادیر بحرانی استخراج شده توسط پرون (۱۹۸۹) انجام شد که نتایج آن با نتایج به‌دست آمده در آزمون دیکی - فولر تعمیم یافته (ADF) سازگاری داشتند.

نتایج به‌دست آمده از آزمون ADF حکم می‌کنند که متغیرهای مدل ابتدا باید به سری‌های مانا تبدیل شده و سپس، در معادله رگرسیون بکار گرفته شوند. جداول ADF ضمیمه نشان می‌دهند که متغیرهای شکاف تولید و تورم با انجام یک وقفه و عرضه پول واقعی با دو وقفه به فرایند مانا تبدیل می‌شوند. بنابراین، در هر دو مدل‌های ساختاری و سری‌های زمانی، از متغیرها به صورت تبدیل یافته فوق استفاده خواهد شد. در ضمن، به علت ملاحظات می‌پیرامون میزان قطعیت و قدرت آزمونهای مانایی وجود دارند که به برخی از آنها در بالا اشاره شد و هم چنین از دست دادن میزان اطلاعات در صورت تبدیل متغیرها به صورت تفاضل، صرفاً جهت انجام مقایسه میزان صحت پیش‌بینی مدل‌ها، از متغیرها به صورت عادی نیز استفاده خواهد شد.

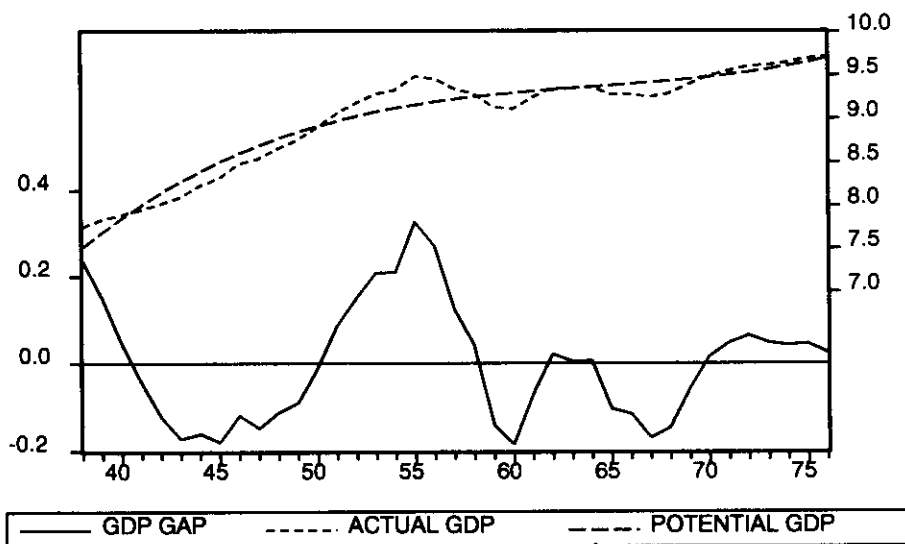
۱-۳- نتایج برآورد مدل‌ها

اولین مدل برآورد شده، فرم خلاصه شده تورم که در بخش (۱-۱) معرفی شده است، می‌باشد. برای برآورد این مدل، ابتدا باید متغیر شکاف تولید که برابر است با تفاضل میان تولید ناخالص داخلی واقعی و میزان بالقوه یا طبیعی آن، برآورد گردد. در ادبیات اقتصادی راههای گوناگونی مانند روند، فیلتر کردن، حالت فضا و بردار اتورگرسیون (VAR) برای برآورد تولید بالقوه وجود دارند^۱. در اینجا، با توجه به سیر زمانی متغیر تولید ناخالص واقعی به نظر می‌رسد که روش روند^۲، روش مناسب و در عین حال ساده‌ای باشد که می‌توان از آن استفاده کرد. برای این منظور، معادلات روند گوناگونی با درجات مختلف برآورد شدند که از بین آنها معادله روند چند جمله‌ای درجه ۳ با توجه به افت و خیزی که در روند تولید ناخالص داخلی در دوران قبل از انقلاب، پس از انقلاب و دوران تعدیل اقتصادی وجود دارند، نتایج قابل قبول تری به‌دست داد. نمودار (۱) روند

۱- برای آشنایی با این روش‌ها به (1997) C. Dupasquier, (1998) M. Kichian مراجعه شود.

تولید ناخالص داخلی واقعی و برآورد مقدار طبیعی آن و هم چنین شکاف تولید را نشان می‌دهد. طبق این برآورد، در دوران افزایش اولیه قیمت نفت یعنی سال‌های ابتدایی و میانی دهه ۵۰ شکاف تولید مثبت و در غالب سال‌های اواخر دهه‌های ۵۰، ۶۰ و ۷۰ شکاف تولید تقریباً صفر یا منفی وجود داشته است.

نمودار ۱- تولید واقعی، تولید بالقوه و شکاف تولید



نتایج برآورد معادله فرم خلاصه شده تورم برای دوره ۱۳۷۱-۱۳۳۸ به شرح زیر

هستند:

$$\hat{\pi}_t = -1/59 + 0/74 y_{t-1} + 0/15 m_t + 0/38 \pi_t^m - 0/34 \pi_{t-1}$$

s.e. (0/64) (1/7) (1/45) (0/14) (0/15)

در تفسیر نتایج فوق باید دقت نمود که متغیرهای معادله فوق همگی به صورت مانا تبدیل یافته‌اند یعنی تورم (π_t) و وقفه شکاف تولید (y_{t-1}) به صورت تفاضل مرتبه اول، عرضه پول (m_t) به صورت تفاضل مرتبه دوم و اختلاف تورم وارداتی و داخلی (π_t^m) به صورت تفاضل مرتبه اول (بدون هیچ تفاضل)، در معادله وارد شده‌اند. اعداد داخل پرانتز بیانگر

انحراف معیارهای (s.e.) ضرایب برآورده شده هستند. مقدار R^2 برابر با ۳۷ درصد و مقدار F برای معنادار بودن کل رگرسیون برابر با ۳/۷۹ است. تعداد وقفه تورم در معادله بر اساس معیار اطلاعات آکائیک (AIC) انتخاب شده است. معیار AIC تابعی از خطاهای رگرسیون می‌باشد که اثر افزودن متغیرهای جدید در قدرت توضیحی رگرسیون را تا حدی خنثی می‌کند. در اینجا معرفی بیش از یک وقفه برای تورم مقدار AIC را افزایش می‌داد و لذا تنها به یک وقفه کفایت شده است. با توجه به اینکه اطلاعات به صورت سالانه می‌باشد، به نظر طبیعی می‌رسد که بعد زمانی انتظارات تورمی مردم بر اساس تغییرات تورم یک دوره قبل و نه فراتر از آن باشد. علایم کلیه ضرایب با علایم مورد انتظار تطابق دارد. علامت منفی وقفه تورم به این معناست که به‌طور متوسط، افزایش شتاب در افزایش قیمت‌های هر دوره یعنی افزایش نرخ تورم با کاهش آن در دوره بعد مواجه بوده است. شدت عمل در سیاست‌های ضدتورمی دولت هر گاه که شرایط بسیار حاد تورمی به وجود آمده است همچنین نوسانات قیمت نفت که در انتظارات تورمی تاثیر می‌گذارد، شاید توجه‌گر این مسأله باشند.

همانگونه که قبلاً توضیح داده شد، به منظور مقایسه قدرت پیش‌بینی مدل‌های گوناگون، مدل ساختاری فوق یک بار دیگر با حضور متغیرها به صورت تبدیل نیافته برآورد شد که نتایج آن به صورت زیر می‌باشد:

$$\hat{\pi}_t = -2/10 + 1/23y_{t-1} + 0/35m_t + 0/5\pi_t^m + 0/15\pi_{t-1}$$

s.e. (0/51) (0/80) (0/08) (0/11) (0/14)

مقدار R^2 برابر با ۰/۸۵ و F برابر با ۳۹/۸۰ می‌باشد.

در هر دو فرم معادله برآورد شده فوق، متغیرهای مجازی برای انتقال تورم و یا تغییر شیب آن در مقاطع انقلاب و جنگ وارد شدند که در هیچ یک از موارد، ضرایب معنی داری نداشتند و تغییر چشمگیری نیز در نتایج مدل به وجود نیاوردند.

مدل برآورد شده بعدی، مدل سری‌های زمانی می‌باشد. برای تعیین تعداد و نوع وقفه‌هایی که قادر به تبیین تغییرات جاری تورم هستند، از روش باکس - جنکینز

استفاده شد. نمودارهای ACF و PACF و همچنین آزمون‌های مربوط به آنها، حاکی از آن هستند که مدل $AR(1)$ برای تورم ایران مناسب است. بر اساس نتایج آزمون‌های مانایی، ابتدا از متغیر تورم به صورت تفاضل مرتبه اول دربرآورد استفاده شد که نتایج آن به شرح زیر است:

$$\hat{\pi}_t = 0/09 - 0/38\pi_{t-1}$$

s.e. (0/14) (0/16)

مقدار R^2 برابر با 0/17 و F برابر با 5/86 است^۱. علامت وقفه تورم مانند علامت آن در مدل ساختاری منفی و مقدار ضریب آن نیز تقریباً با آن یکسان است. همانند مدل ساختاری، در اینجا نیز مدل $AR(1)$ با استفاده از مقادیر اصلی تورم برآورد شد که نتایج آن به شرح زیر است:

$$\hat{\pi}_t = -0/08 + 0/35\pi_{t-1} + 0/07\epsilon_t$$

s.e. (0/28) (0/16) (0/62)

در این مدل، ϵ_t به عنوان متغیر روند وارد معادله شده است که تا حدی جبران ضعف عدم استفاده از متغیرهای مانا را می‌نماید. مقدار R^2 برابر با 0/70 و F برابر با 31/33 است. در اینجا باید به این نکته اشاره نمود که مثبت و معنی دار بودن ضریب متغیر روند در معادله تورم، حاکی از آن است که تورم با گذشت زمان افزایش مدام داشته است. البته از آن جا که به نظر می‌رسد خود روند زمانی تورم نیز در دوران مختلف قبل و پس از انقلاب، جنگ و دوران تعدیل اقتصادی دستخوش تغییر بوده است، نمی‌توان با معرفی متغیر روند ساده مشکل غیرمانایی را حل نمود. به عبارت دیگر می‌توان گفت که در اینجا

۱- عدد ثابت در اینجا در حقیقت همان ضریب روند در معادله رگرسیونی که تورم به صورت غیرمانا حضور دارد، می‌باشد.

بجای یک روند قطعی^۱، یک روند تصادفی^۲ در سری زمانی تورم وجود دارد که ایجاب می‌نماید تا متغیر تورم به صورت تفاضل در معادله رگرسیون حضور یابد.

۴-۱- نتایج پیش‌بینی

پیش‌بینی تورم با استفاده از اطلاعات موجود در نمونه یعنی مطابق روش پیش‌بینی از درون نمونه^۳، صورت گرفته است. روش کار به شرح زیر است. ابتدا اطلاعات نمونه به دو گروه سال‌های ۱۳۷۱-۱۳۳۸ برای برآورد مدل‌ها و سال‌های ۱۳۷۶-۱۳۷۲ برای پیش‌بینی تورم در طی این سال‌ها، تقسیم شدند. پیش‌بینی برای یک دوره جلوتر^۴ به مدت ۵ سال صورت گرفت. از آنجا که متغیر وقفه تورم در مدل‌های تورم که در بخش قبلی معرفی شدند، وجود داشت پیش‌بینی از دو روش مختلف امکان‌پذیر بود: روش ایستا و روش پویا. در روش ایستا مقادیر وقفه تورم در طول دوره پیش‌بینی همان مقادیر واقعی آنها هستند. به عبارت دیگر، فرض می‌شود که پیش‌بینی‌کننده در هر دوره از مقدار واقعی تورم در دوره قبل در کل دوره پیش‌بینی اطلاع داشته و از آن استفاده نموده است. در روش پویا که با واقعیت نزدیک‌تر است، پیش‌بینی‌کننده از مقادیر پیش‌بینی خود برای هر دوره برای مقادیر وقفه تورم در کل دوره پیش‌بینی استفاده می‌کند. به عبارت دیگر، پیش‌بینی تورم هر دوره بر اساس پیش‌بینی تورم دوره قبل صورت می‌گیرد و در نتیجه اگر خطایی در پیش‌بینی دوره‌های قبل وجود داشته باشد، این خطاها به پیش‌بینی دوره‌های بعد نیز منتقل می‌گردند. بنابراین، به‌طور کلی انتظار می‌رود خطای پیش‌بینی در روش پویا بیشتر از آن در روش ایستا باشد. در مقاله حاضر، از هر دو روش پیش‌بینی استفاده شده است.

برای ملاک ارزیابی پیش‌بینی‌ها، معمولاً از خطاهای پیش‌بینی و یا توابعی از آنها

- 1- Deterministic Trend
- 2- Stochastic Trend
- 3- Out-of-Sample Forecasting
- 4- One - period ahead

استفاده می‌شود. در این مقاله از سه شاخص RMSE، MAE و آماره U برای این منظور استفاده شده است.

RMSE مجذور میانگین مربع خطاهای پیش بینی است که به صورت زیر محاسبه

می‌شود:

$$RMSE = \sqrt{\frac{1}{T} \sum_{t=1}^T e_{t+h,t}^2}$$

T تعداد کل مشاهدات، $e_{t+h,t}$ خطای پیش بینی برای h مرحله جلوتر در زمان t است.

$$MAE = \frac{1}{T} \sum_{t=1}^T |e_{t+h,t}| \quad \text{یعنی میانگین قدر مطلق خطاهاست}$$

آماره U که به U-Theil هم معروف است، برابر است با نسبت مجموع مربعات خطاهای یک دوره جلو مدل پیش بینی به مجموع مربعات خطاهای یک دوره جلو مدل ساده (Naive) یا بدون تغییر (No-change). مدل ساده فرض می‌کند که هیچ گونه تغییری در مرحله آتی متغیر ایجاد نخواهد شد، یعنی $y_{t+1,t} = y_t$. بنابراین مقدار کمتر از یک برای آماره U بیانگر عملکرد بهتر مدل پیش بینی نسبت به مدل ساده است و بر عکس. نتایج پیش بینی‌های مدل‌های ساختاری و سری‌های زمانی برای تورم ایران در جداول زیر خلاصه شده‌اند.

جدول ۱- نتایج پیش‌بینی‌های ایستای یک دوره به جلو با استفاده از مدل‌های ساختاری

و سری‌های زمانی (۱۳۷۶-۱۳۷۲)

مدل	RMSE	MAE	U-stat
سری‌های مانا			
ساختاری	۰/۵۵	۰/۴۸	۰/۰۸
سری‌های زمانی	۰/۴۴	۰/۴۰	۰/۰۷
سری‌های غیرمانا			
ساختاری	۰/۷۲	۰/۵۲	۰/۱۱
سری‌های زمانی	۰/۶۶	۰/۵۴	۰/۱۰

جدول ۲- نتایج پیش‌بینی‌های پویای یک دوره به جلو با استفاده از مدل‌های ساختاری

و سری‌های زمانی (۱۳۷۶-۱۳۷۲)

مدل	RMSE	MAE	U-stat
سری‌های مانا			
ساختاری	۰/۴۹	۰/۴۰	۰/۰۸
سری‌های زمانی	۰/۳۹	۰/۳۳	۰/۰۶
سری‌های غیرمانا			
ساختاری	۰/۷۶	۰/۵۴	۰/۱۱
سری‌های زمانی	۰/۸۲	۰/۶۸	۰/۱۱

از نتایج فوق می‌توان چنین نتیجه گرفت که در مجموع، مدل سری‌های زمانی $AR(1)$ نتایج بهتری نسبت به مدل ساختاری به‌دست داده است. همچنین، همانگونه که انتظار می‌رفت، شاخص‌های خطاهای اشتباه در روش پیش‌بینی پویا، در غالب موارد بیشتر از این شاخص‌ها در روش پیش‌بینی ایستا هستند. البته از آنجا که پیش‌بینی‌ها صرفاً به مدت ۵ سال صورت گرفته‌اند، تفاوت‌های شاخص‌های خطاها در دو روش ایستا و پویا چندان چشمگیر نیستند. نکته آخر اینکه شاخص U حاکی از آن است که هر دو مدل ساختاری و سری‌های زمانی، پیش‌بینی‌های صحیح‌تری نسبت به مدل ساده (بدون تغییر) ارائه نموده‌اند و کمتر بودن این شاخص‌ها برای مدل سری‌های زمانی نسبت به مدل ساختاری، مجدداً عملکرد بهتر این مدل را از نظر پیش‌بینی تورم نشان می‌دهد.

در بخش‌های بعد، ضمن معرفی مدل شبکه‌ای عصبی به طراحی یک مدل برای پیش‌بینی تورم پرداخته و نتایج پیش‌بینی‌ها با نتایج به‌دست آمده فوق مقایسه خواهد شد.

۲- مدل‌های شبکه‌های عصبی مصنوعی^۱

در این فصل، ابتدا مدل‌های ANN به‌طور مختصر معرفی خواهند شد. سپس، نحوه استفاده از مدل‌های ANN برای پیش‌بینی متغیرهای اقتصادی توضیح داده خواهد شد.

مدل‌های شبکه‌های عصبی مصنوعی (ANN) را به‌طور کلی می‌توان در قالب نظیر کننده‌های برداری^۲ جای داد: آنها مجموعه‌ای از داده‌ها^۳ را گرفته و پس از انجام عملیاتی که برنامه آنها در ساختار شان نهاده شده است ستاده‌هایی^۴ را تحویل می‌دهند.^۵

1- Artificial Neural Networks

2- Vector Mappers

3- Inputs

4- Outputs

5- Wasserman (1994)

مدل‌های ANN را همچنین می‌توان به مدل‌های داده - ستانده خاصی تعبیر نمود که دارای ویژگی‌هایی مانند انجام عملیات با حجم بسیار زیاد به صورت موازی و پردازش غیرخطی داده‌ها می‌باشند. این ویژگی‌ها که از شبکه‌های عصبی طبیعی موجود در مغز انسان گرفته شده‌اند، به همراه ویژگی پردازش اطلاعات در مراحل گوناگون به مدل‌های ANN اجازه داده‌اند تا در انجام کارهای خاصی مانند پیش‌بینی و تشخیص الگو بسیار موفق باشند.

کاربرد مدل‌های ANN در علم اقتصاد عمدتاً در زمینه پیش‌بینی و دسته‌بندی متغیرها در بازارهای مالی و پولی بوده است. برای مثال، از مدل‌های ANN برای پیش‌بینی قیمت‌های سهام و همچنین نرخ مبادله ارز یا درجه بندی اوراق قرضه استفاده شده است.^۱ شاید بتوان گفت که از مهمترین علل استفاده از این مدل‌ها در بازارهای پولی و مالی، عدم قدرت کافی مدل‌های موجود در تبیین و پیش‌بینی رفتار متغیرهای پولی و همچنین وجود آمار فراوان در این بازارها می‌باشد. مدل‌های ANN در اقتصاد کلان بسیار جدیدند. از آنجا که در اقتصاد کلان سوابق مدل‌های موجود در زمینه پیش‌بینی متغیرهای اقتصادی متأسفانه چندان درخشان نبوده‌اند، به نظر می‌رسد که می‌توان از مدل‌های ANN در این زمینه نیز استفاده نمود. از کارهای بسیار محدودی که تا کنون در این زمینه صورت گرفته‌اند، می‌توان از پیش‌بینی برخی متغیرهای اقتصاد کلان مانند شاخص قیمت‌های مصرف‌کننده، تولید ناخالص ملی، پول و دستمزدها در آمریکا توسط معصومی، ختن‌زاد، عبایی (۱۹۹۴)^۲، پیش‌بینی نه متغیر اقتصاد کلان در آمریکا توسط وایت و سوانسن (۱۹۹۷)^۳ و پیش‌بینی تورم در کانادا توسط مشیری و کامرون (۲۰۰۰)^۴ نام برد. در مقایسه‌ای که بین نتایج به دست آمده از مدل‌های ANN و سایر مدل‌های متداول که معمولاً برای پیش‌بینی استفاده می‌شوند مانند ARIMA یا

۱- به مجموعه مقالاتی که توسط R.Trippi و E.Truban در کتاب *Neural Networks in Finance and Investing* جمع آوری شده‌اند، مراجعه شود.

2- Maasoumi, Khotanzad, Abaye

3- White, Swanson

4- Moshiri, Cameron

VAR انجام شده است، ملاحظه می‌شود که در برخی موارد مدل‌های ANN نتایج مطلوب‌تری ارائه داده‌اند.

مدل‌های شبکه‌های عصبی مصنوعی به‌رغم تنوع‌شان از ساختار کلی مشابهی برخوردارند. یک شبکه عصبی مصنوعی معمولاً از سه لایه (بردار)^۱ به ترتیب زیر تشکیل می‌شود:

۱- لایه ورودی^۲

۲- لایه میانی^۳

۳- لایه خروجی^۴

لایه ورودی شامل واحدهایی به تعداد متغیرهای توضیحی مدل می‌باشد. بنابراین، اگر تعداد متغیرهای توضیحی مدل پنج باشد، باید پنج واحد در لایه ورودی به کار گرفته شوند.

لایه‌های میانی و خروجی شامل واحدهای پردازش اطلاعات هستند. در این واحدها، عملیاتی جبری بر روی اطلاعات ورودی صورت گرفته و نتیجه آنها به صورت یک ورودی جدید به واحدهای دیگر در لایه‌های بعدی ارسال می‌گردد. واحدهای لایه خروجی به مثابه همان متغیرهای وابسته در مدل رگرسیون هستند که مقادیر برآورد شده، متغیر وابسته را تحویل می‌دهند. در مدل‌های تک معادله‌ای فقط یک واحد پردازش اطلاعات لایه خروجی وجود خواهد داشت ولی در مدل‌های سیستم معادلات همزمان، تعداد واحدهای لایه خروجی برابر با تعداد متغیرهای وابسته یا تعداد معادلات سیستم خواهد بود.

واحدهای لایه‌های میانی از اهمیت بسیاری در مدل‌های شبکه‌های عصبی

۱- اصطلاحات بکار گرفته شده در ادبیات مدل‌های شبکه‌های عصبی غالباً عبارات پزشکی هستند. در اینجا به منظور روان‌تر شدن مطلب برای مخاطبین اقتصاددان، عبارات مترادف در ادبیات اقتصاد سنجی و آماری را نیز به همراه عبارات اصلی بکار خواهیم برد.

2- Input Layer


3- Hidden Layer

4- Output Layer

مصنوعی برخوردارند زیرا نقش مؤثری در فرایند یادگیری (برآورد) صحیح مدل ایفا می‌نمایند. تعداد لایه‌های میانی و تعداد واحدهای پردازش اطلاعات در این لایه‌ها هنوز از قانونمندی واحدی تبعیت نمی‌کنند ولی بنا به یک قضیه اثبات شده^۱ در صورتی که تعداد مکفی از این لایه‌ها و واحدها در یک مدل شبکه‌های عصبی وجود داشته باشند، مدل قادر خواهد بود هر گونه ارتباط بین داده‌ها و ستاده‌ها را با دقت مورد نظر یاد بگیرد، به عبارت دیگر برآورد صحیحی از رابطه بین داده‌ها و ستاده‌ها ارایه نماید.

نمودار (۲) شمای کلی یک مدل شبکه‌های عصبی مصنوعی را نشان می‌دهد.

نمودار ۲ - شمای کلی یک مدل شبکه‌های عصبی



جریان پردازش اطلاعات در هر واحد لایه‌های میانی و خروجی، به صورت زیر است. هر واحد پردازش اطلاعات دو عمل را انجام می‌دهد. ابتدا مجموع حاصل ضرب اطلاعات ورودی و وزنه‌های ارتباطی (پارامترهایی که مقادیر اولیه آنها معمولاً به صورت تصادفی تعیین می‌شوند) را محاسبه می‌کند. به عبارت دیگر، اگر متغیرهای ورودی را با X_i و پارامترهای ارتباطی را با γ_i نشان دهیم، واحد پردازش اطلاعات h ابتدا عبارت


$$Net_h = \sum_{i=1} \gamma_i x_i$$

را به دست می‌آورد.

وظیفه دوم واحد پردازش اطلاعات، انتقال مقدار Net_h از طریق یک تابع تبدیل به واحد پردازش لایه جلوتر است. به عبارت دیگر، اگر تابع تبدیل را با $f(\cdot)$ نشان دهیم، واحد پردازش اطلاعات مقدار $F_h = f(Net_h)$ را محاسبه می‌کند. تعداد نسبتاً وسیعی از توابع تبدیل خطی و غیرخطی مانند توابع همانی، Sigmoid، Tangent Hyperbolic و

Threshold در این مرحله می‌توانند مورد استفاده قرار گیرند. نمودار ۳ نحوه عملیات یک واحد پردازش اطلاعات را نشان می‌دهد.

نمودار ۳ - شمای کلی جریان پردازش اطلاعات در یک واحد پردازش اطلاعات



INPUT WEIGHTS PROCESSING UNIT OUTPUT

انواع گوناگونی از مدل‌های ANN وجود دارند. مدل‌های ANN در یک طبقه بندی به مدل‌های ایستا و پویا^۱ تقسیم می‌شوند. در مدل‌های ایستا^۲، مسیر پردازش اطلاعات از داده‌ها به ستاده‌هاست بدون اینکه بازگشتی در سیستم ارتباطی واحدها وجود داشته باشد، در حالی که در مدل‌های پویا^۳، مسیرهای بازگشتی از بردار ستاده‌ها یا بردار واحدهای میانی به بردار داده‌ها نیز وجود دارند. این مسیرهای بازگشتی را می‌توان به متغیرهای تأخیری در مدل رگرسیون تشبیه نمود زیرا در این صورت ستاده‌ها نه تنها تابع داده‌ها بلکه تابع خود ستاده‌ها که در مرحله قبل ایجاد شده‌اند نیز می‌باشند. مدل‌های ANN را از لحاظی دیگر نیز می‌توان تقسیم نمود. اگر بردار داده‌ها با بردار ستاده‌ها مختلف باشند، مدل دگرهمراهی^۴ و چنانچه بردار داده‌ها با بردار ستاده‌ها

1- Static & Dynamic

2- Feed Forward

3- Recurrent

4- Hetero-association

یکسان باشند، مدل خودهمراهی^۱ نامیده می‌شود. و بالاخره مدل‌های ANN را از لحاظ نوع یادگیری می‌توان به دو نوع یادگیری هدایت شده^۲ و یادگیری بدون هدایت^۳ تقسیم نمود. در حالت یادگیری هدایت شده، بردارهای داده‌ها و ستاده‌ها در مدل معرفی شده و هدف، به‌دست آوردن ستاده‌های حتی الامکان نزدیک به ستاده‌های مطلوب است. در حالی که در مدل‌های بدون هدایت، تنها بردار داده‌ها به مدل معرفی می‌شوند و مراحل یادگیری بدون بردار از قبل معرفی شده ستاده‌ها، صورت می‌گیرد. مدل‌هایی که در اقتصاد و در زمینه پیش‌بینی کاربرد بیشتری دارند، مدل‌های ANN با ویژگی‌های ایستا و پویا، دگرهمراهی و یادگیری هدایت شده می‌باشند. از این میان، مدل‌های پس‌انتشار خطا^۴ که جزء مدل‌های ایستا، دگرهمراهی و هدایت شده هستند، تاکنون بیشترین کاربرد را در اقتصاد داشته‌اند. جزئیات این مدل در بخش بعدی آرایه خواهد شد.^۵

۱-۲- مدل پس‌انتشار خطا (BPN)

مدل‌های شبکه‌های عصبی پس‌انتشار خطا که از نوع ایستا، دگرهمراهی و با یادگیری هدایت شده هستند، از معروف‌ترین مدل‌های شبکه‌های عصبی به‌شمار می‌روند. مدل‌های پس‌انتشار خطا معمولاً (ولی نه الزاماً) از سه لایه (بردار) داده‌ها، میانی (پنهانی) و ستاده‌ها تشکیل شده‌اند و در بسیاری از زمینه‌ها مورد استفاده قرار گرفته‌اند. نحوه عملکرد مدل‌های پس‌انتشار خطا به صورت خلاصه به شرح زیر است.

پس از اینکه بردارهای داده‌ها و ستاده‌ها به مدل معرفی شدند، ضرایب ارتباطی بین واحدهای لایه‌های ورودی، میانی و خروجی به طور تصادفی تعیین می‌شوند. سپس،

1- Auto-association

2- Supervised learning


3- Unsupervised learning

4- Error Back-propagation

۵- برای اطلاع بیشتر از جزئیات سایر مدل‌ها به کتابهای Wasserman(1994)، Haykin(1994) و Masters(1994) مراجعه شود.

مدل با پردازش داده‌های هر واحد و ارسال آنها به واحدهای جلوتر، مقادیر بردار ستاده‌ها را محاسبه می‌کند. در این مرحله، مقادیر محاسبه شده ستاده‌ها با مقادیر واقعی آنها مقایسه و مقدار خطا محاسبه می‌شود. اگر میزان خطا یا هر تابع دیگری از خطا با مقدار مطلوب آن که از قبل در نظر گرفته شده است متفاوت بود، به عقب برگشته و با تغییر ضرایب ارتباطی و با تکرار مراحل قبلی مجدداً ستاده‌های جدیدی محاسبه می‌شود. البته ضرایب ارتباطی طبق مکانیزم‌هایی که به مکانیزم‌های یادگیری^۱ موسومند، در جهتی تغییر می‌کنند که خطا یعنی همان تفاوت بین ستاده محاسبه شده و ستاده واقعی کمتر و کمتر شود. این جریان یادگیری آن قدر ادامه می‌یابد تا خطا به میزان مورد نظر برسد. نمودار (۴) یک نمای کلی از جریان عملکرد یک شبکه پس انتشار خطا با r واحد در لایه ورودی، دو واحد در لایه میانی و یک واحد در لایه خروجی را نشان می‌دهد.

نمودار ۴ - یک مدل شبکه عصبی مصنوعی پس انتشار خطا با تعداد r واحد در لایه ورودی، دو واحد در لایه میانی، و یک واحد ستانده در لایه خروجی^۲



Input Layer

Weights

Hidden Layer

Weights

Output Layer

Target Output t

1- Learning Mechanism

۲- η و β ها وزنه‌های ارتباطی بین واحدهای لایه‌های میانی و خروجی هستند.

در حالت کلی، معادله ستاده یک مدل شبکه‌های عصبی مصنوعی را که شامل τ داده، q واحد میانی و یک ستاده می‌باشد، می‌توان به صورت زیر نوشت:

$$F(x, w) = F(\beta + \sum_{j=1}^q G(x\gamma_j)\beta_j),$$

در اینجا $F(x, w)$ ستاده نهایی محاسبه شده توسط مدل و $G(x\gamma_j)$ ستاده واحد میانی z است. برای F و G معمولاً از توابع غیرخطی، به عنوان مثال تابع سیگموئید (Sigmoid) استفاده می‌شود که داده‌ها را به اعدادی بین صفر و یک تبدیل می‌نماید. $x = [1, x_1, \dots, x_p]$ بردار داده‌هاست و عدد ۱ برای واحد ثابت یا تورش^۱ در نظر گرفته شده است. $w = (\gamma_1, \gamma_2, \dots, \gamma_q, \beta_j)$ ماتریس حاوی ضرایب ارتباطی است. هر یک از γ_j ها نمایانگر یک بردار $1 \times p$ حاوی وزن‌ها یا ضرایب ارتباطی بین متغیرهای بردار داده‌ها و یکی از واحدهای میانی است. β_j نیز برداری است که شامل وزن‌های ارتباطی هر واحد میانی و بردار ستاده است.

۲-۲- قاعده یادگیری

قواعد یادگیری متفاوتی در مدل‌های شبکه‌های عصبی مصنوعی مورد استفاده قرار می‌گیرند. قاعده یادگیری در شبکه پس انتشار خطا، وزن‌های ارتباطی بین واحدهای مدل را در جهتی تغییر می‌دهد که خطای حاصل از مدل به حداقل برسد. قاعده یادگیری‌ای که معمولاً در مدل‌های پس انتشار خطا استفاده می‌شود، قاعده یادگیری دلتای تعمیم یافته^۲ نام دارد که مطابق آن وزن‌های ارتباطی بین واحدها در قالب معادله تفاضلی زیر تغییر داده می‌شوند:

$$w(t+1) = w(t) + \eta \nabla$$


1- Bias

2- Generalized Delta Rule

در اینجا $w(t)$ وزن ارتباطی در زمان t و η نرخ یادگیری (معمولاً بین صفر و ۱) و ∇ بردار حاوی شیبهای مربوط به وزنهای ارتباطی است^۱. بردار ∇ مجموعه‌ای از مشتق‌های خطای محاسبه شده توسط شبکه نسبت به همه وزن‌ها می‌باشد. مدل پس انتشار خطا، بردار شیب‌ها را به صورت برداری با استفاده از قاعده زنجیری در مشتق‌های جزئی محاسبه می‌نماید.

برای رسیدن به حداقل خطا ضروری است که تغییر وزن‌ها در هر مرحله، در جهت کاهش خطای محاسبه شده صورت گیرد، به عبارت دیگر فرایند یادگیری به سمت همگرایی پیش برود. نمودار (۵) یک نمونه از کاهش خطا بر اثر تغییر وزن‌های ارتباطی در یک شبکه پس انتشار خطا را نشان می‌دهد.

نمودار ۵ - فرایند یادگیری در یک مدل پس انتشار خطا^۲



1- Gradient Vector

معمولاً در گلوله‌ای که در بالای نمودار مشاهده می‌شود از کوتاهترین مسیر به سمت حداقل خود حرکت می‌کند.

گاهی اوقات ممکن است که مدل پس انتشار خطا به جای همگرایی تدریجی به سمت جواب (حداقل خطا)، واگرایی ایجاد کرده و لذا دسترسی به جواب میسر نباشد. این مشکل را می‌توان با اضافه نمودن "شتاب"^۱ به قاعده یادگیری مرتفع نمود. "شتاب" تغییر جاری در وزن را به تغییر قبلی وزن و همچنین خطای جاری مرتبط می‌کند. این ارتباط باعث می‌شود تا تغییرات وزن‌ها در یک جهت ادامه یابند. قاعده یادگیری با شتاب را می‌توان به صورت زیر نوشت:

$$w(t+1) = w(t) + [\Delta w(t) + \alpha \Delta w(t-1)],$$

$\Delta w(t)$ از معادله قبلی برابر است با $\eta \nabla_{j_i}$.

همانگونه که قبلاً اشاره شد، مدل‌های شبکه‌های پس انتشار خطا قادرند هرگونه توابع پیوسته‌ای را با دقت مطلوب یادگیرند (برآورد نمایند) به شرط اینکه به تعداد کافی واحدهای میانی در آنها معرفی شده باشند^۲.

۳- یک مدل پس انتشار خطا برای پیش‌بینی تورم در لیرلن

۳-۱- مراحل طراحی مدل

در این بخش، یک مدل شبکه عصبی مصنوعی از نوع پس انتشار خطا که برای پیش‌بینی تورم در ایران طراحی شده است، ارائه می‌شود. مراحل طراحی این مدل به شرح زیر است:

۱- مرحله اول عبارت است از تعیین تعداد واحدهای لایه ورودی و یا به عبارتی دیگر، متغیرهای توضیحی مدل. در ادبیات اخیر، کاربردهای اقتصادی شبکه‌های عصبی، به‌درستی این موضوع اشاره شده است که در صورت انتخاب واحدهای لایه ورودی بر اساس یک تئوری اقتصادی و یا خصوصیات آماری سری‌های مورد استفاده، نتایج به

1- Momentum

2- Rumelhart, Hinton, Williams (1986), White (1990)

مراتب بهتری عاید خواهد گشت^۱. از این رو، واحدهای لایه ورودی در مدل مورد نظر ما نیز بر پایه تئوری اقتصادی تورم و همچنین ویژگی‌های آماری سری زمانی تورم که در بخش قبل مورد بحث قرار گرفتند، انتخاب شدند. بدین ترتیب، دو مدل مختلف شبکه‌های عصبی، یکی بر اساس مدل ساختاری تورم و دیگری بر اساس AR، طراحی و برآورد شدند. به عبارت دیگر، متغیرهای ورودی مدل اول عبارتند از وقفه شکاف تولید، عرضه پول واقعی، تورم خارجی و وقفه تورم و مدل دوم عبارت است از وقفه تورم. در هر دو مدل، یک واحد تورش با مقدار ۱ به عنوان عدد ثابت معادله در نظر گرفته شده است. مانند روشی که در بخش قبل اعمال شد، در اینجا متغیرها به هر دو صورت مانا و نامانا مورد استفاده قرار گرفتند.

۲- مرحله دوم، تعیین حجم نمونه برای بخش یادگیری (برآورد) و هم چنین بخش آزمون (پیش بینی) است. بدین منظور، حجم نمونه به دو قسمت تقسیم شد: دوره ۱۳۷۱-۱۳۳۸ یعنی یک دوره سی و چهار ساله برای یادگیری و دوره ۱۳۷۶-۱۳۷۲ یعنی یک دوره پنج ساله برای آزمون یا پیش بینی.

۳- مرحله سوم، تعیین تعداد واحدهای لایه خروجی و لایه میانی است. تعداد واحدهای لایه خروجی در این مسأله یک می‌باشد که بیانگر میزان تورم و یا تغییرات آن بر حسب مدل مورد استفاده است. تعداد واحدهای لایه میانی از طریق روش آزمون و خطا مشخص شد. بدین طریق که مدل با یک واحد در لایه میانی برآورد شد و معیار ارزیابی پیش بینی (به عنوان مثال RMSE) محاسبه شد. سپس به تعداد واحدهای لایه میانی، یک واحد دیگر اضافه شد و معیار ارزیابی پیش بینی به دست آمده با قبل مقایسه گردید. این روند ادامه یافت تا اینکه تعداد واحدهای لایه میانی متناظر با بهترین معیار ارزیابی پیش بینی به دست آمده انتخاب شد. در مدل حاضر، یک واحد لایه میانی بهترین جواب را داد و لذا در کلیه موارد بدین ترتیب عمل شد.

در مورد تعیین تعداد واحدهای پردازش اطلاعات، لایه میانی به رغم آن که فرمول‌هایی جهت این امر در ادبیات مدل‌های شبکه‌های عصبی مصنوعی ارائه شده‌اند، ولی هنوز

هم روش آزمون و خطا روش مؤثرتری به نظر می‌رسد. به هر حال، تعداد بسیار کم یا بسیار زیاد واحدهای میانی ممکن است منجر به نتیجه نامطلوب به‌ویژه در بخش پیش‌بینی گردد. تعداد بسیار کم واحدهای میانی هر چند که سرعت یادگیری را بالا می‌برد ولی ممکن است باعث شود تا فرایند یادگیری به‌صورت ناقص انجام شده و لذا مدل عاجز از پیش‌بینی درست بماند. از طرف دیگر، تعداد بسیار زیاد واحدهای میانی هر چند که ممکن است نتیجه مطلوبی در فرایند یادگیری (برآورد) مدل داشته باشد، اما احتمالاً آثار خوبی در مرحله پیش‌بینی نخواهد داشت. این مسأله شبیه به افزودن بی‌رویه متغیرهای توضیحی در یک مدل رگرسیون است که ممکن است درصد توضیح دهنده متغیرها را افزایش دهد اما نتایج مطلوبی در امر پیش‌بینی بدنبال نخواهد داشت. در ادبیات مدل‌های شبکه‌های عصبی مصنوعی این مشکل "حفظ کردن" ^۱ مدل نامیده می‌شود. مدلی که ارتباطات را صرفاً حفظ کرده باشد، قادر نخواهد بود در شرایط جدیدی که قبلاً نمونه آنها عیناً دیده نشده باشند، عکس‌العمل خوبی نشان دهد.

۴- مرحله چهارم، تعیین یک سری پارامترها و عناصری درون مدل مانند ضریب یادگیری، تعداد دفعات تکرار مدل، مقدار خطای پیش‌بینی مطلوب و همچنین نوع توابع تبدیل در لایه‌های میانی و خروجی است. در مدل حاضر، ضریب یادگیری 0.1 ، تعداد دفعات تکرار 4000 ، و خطای پیش‌بینی مطلوب $10^{-2} \times 0.5$ تعیین شدند. همچنین تابع ^۲ برای واحدهای لایه میانی و تابع خطی همانی برای لایه خروجی در نظر گرفته شد.

۵- مرحله پنجم، مشخص کردن قاعده یادگیری است. در مدل شبکه پس انتشار خطا، معمولاً از قانون کاهش شیب ^۳ که در بخش قبل معرفی شد، استفاده می‌شود. در اینجا از روش (LM) ^۴ استفاده شده است. بکارگیری این روش یادگیری، موجب می‌شود که نتایج مدل به مراتب سریعتر از هنگامی که روش یادگیری کاهش شیب بکار گرفته

1- Memorization

2- Tanh

3- Gradient Descent

4- Levenberg-Margardt

می‌شود، تولید شوند. روش LM در حقیقت یک تقریبی از قاعده بهینه‌یابی گاس - نیوتن^۱ است که روش یادگیری کاهش شیب را نیز دربرمی‌گیرد. قاعده یادگیری LM به شرح زیر است:

$$\Delta w = (H'H + \nu I)^{-1} H'E$$

w بردار وزن‌های ارتباطی، H ماتریس ژاکوبین مشتق‌های هر خطا نسبت به هر وزن، ν یک عدد ثابت، I یک ماتریس واحد و E بردار خطاهاست. مکانیزم عمل این قانون یادگیری چنین است که اگر ν عدد بسیار بزرگی باشد، قانون فوق مشابه قانون کاهش شیب است، اما اگر ν عدد بسیار کوچکی باشد قانون فوق معادل قانون گاس - نیوتن خواهد بود. در قانون LM، مقدار ν متناسب با یادگیری مدل تغییر می‌کند، از آنجاییکه حول و حوش حداقل خطا روش گاس - نیوتن بسیار سریع‌تر و صحیح‌تر عمل می‌نماید، هنگامی که خطا کاهش می‌یابد مدل قانون یادگیری را از کاهش شیب به گاس - نیوتن تبدیل می‌کند. شایان ذکر است که اجرای این قانون یادگیری احتیاج به حافظه نسبتاً زیادی در کامپیوتر دارد.

۳-۲- نتایج پیش‌بینی

مدل شبکه عصبی که در بخش قبل معرفی شد، با کمک نرم‌افزار MATLAB 5.3 و جعبه ابزار شبکه‌های عصبی آن برآورد شده است. لازم به تذکر است که با این نرم‌افزار صرفاً می‌توان پیش‌بینی‌های ایستا را به‌دست آورد ولی برای به‌دست آوردن پیش‌بینی‌های پویا احتیاج به برنامه‌های مجزا و تکمیلی است که باید نوشته شده و همراه برنامه‌های اصلی به اجرا درآیند. خوشبختانه نرم‌افزار MATLAB و جعبه‌افزار آن اجازه اعمال چنین تغییری را به استفاده‌کننده می‌دهد.

جداول زیر، نتایج پیش‌بینی‌های به‌دست آمده توسط مدل شبکه پس انتشار خطا را

نشان می‌دهند. این پیش‌بینی‌ها یک دوره به جلو و برای مدت ۵ سال می‌باشند. به منظور مقایسه کردن نتایج با نتایج به‌دست آمده در بخش‌های قبلی (مدل‌های ساختاری و سری‌های زمانی) پیش‌بینی‌ها با هر دو روش ایستا و پویا صورت گرفتند. مدل‌های پیش‌بینی از لحاظ نوع متغیرهای ورودی به چهار نوع به شرح زیر تقسیم شدند:

۱- مدل پس انتشار خطا (BPN) با متغیرهای ساختاری و مانا.

۲- مدل پس انتشار خطا (BPN) با متغیرهای ساختاری و نامانا.

۳- مدل پس انتشار خطا (BPN) با متغیرهای AR و مانا.

۴- مدل پس انتشار خطا (BPN) با متغیرهای AR و نامانا.

ملاک‌های ارزیابی پیش‌بینی‌های به‌دست آمده نیز مانند بخش قبلی، مجذور میانگین مربع خطاها (RMSE)، میانگین قدر مطلق خطاها (MAE) و شاخص U که میزان صحت پیش‌بینی‌های مدل را نسبت به پیش‌بینی‌های مدل ساده (بدون تغییر) نشان می‌دهد، هستند.

جدول ۳ - نتایج پیش‌بینی لیستای تورم لیرلن برای دوره ۷۶-۱۳۷۱ با استفاده از

مدل BPN

U	MAE	RMSE	مدل
			سری‌های مانا
۰/۰۷۳	۰/۳۸	۰/۵۰	BPN-ساختاری
۰/۰۷۵	۰/۳۷	۰/۴۵	BPN-سری زمانی
			سری‌های غیرمانا
۰/۰۵۵	۰/۴۱	۰/۵۲	BPN-ساختاری
۰/۰۷۱	۰/۵۵	۰/۳۰	BPN-سری زمانی

جدول ۴ - نتایج پیش‌بینی‌های پویای تورم ایران برای دوره ۷۶-۱۳۷۱ با استفاده از

مدل BPN و متغیرهای مانا

U	MAE	RMSE	مدل
			سری‌های مانا
۰/۰۸۵	۰/۳۸	۰/۵۰	BPN-ساختاری
۰/۰۸۵	۰/۳۷	۰/۲۱	BPN-سری زمانی
			سری‌های غیرمانا
۰/۰۵۳	۰/۴۱	۰/۵۲	BPN-ساختاری
۰/۰۵۶	۰/۴۴	۰/۵۵	BPN-سری زمانی

۴- مقایسه نتایج پیش‌بینی‌ها توسط مدل‌های ساختاری، سری‌های زمانی و شبکه‌های

عصبی مصنوعی

برای ارزیابی میزان صحت پیش‌بینی تورم توسط مدل‌های گوناگونی که در این مقاله بکار گرفته شدند، MAE، RMSE و آماره U آنها با یکدیگر مقایسه شدند. به منظور تسهیل در امر مقایسه، شاخص جدیدی که از تقسیم شاخص‌های صحت پیش‌بینی مدل‌های ساختاری و سری‌های زمانی به شاخص‌های صحت پیش‌بینی مدل شبکه‌های عصبی مصنوعی به دست می‌آید، معرفی شده است. اگر شاخص مزبور کوچک‌تر از یک باشد بدین معنی خواهد بود که مدل‌های اقتصادسنجی فوق پیش‌بینی صحیح‌تری نسبت به مدل‌های شبکه‌های عصبی ارائه داده‌اند و برعکس، اگر شاخص فوق بزرگتر از یک باشد به معنی عملکرد بهتر مدل‌های شبکه‌های عصبی در زمینه پیش‌بینی تورم اقتصاد ایران نسبت به سایر مدل‌های متداول در اقتصادسنجی خواهد بود. شاخص برابر با یک نیز بالطبع به معنی برابری میزان صحت پیش‌بینی مدل‌های رقیب می‌باشد.

جدول ۵ - مقایسه نتایج پیش‌بینی تورم توسط مدل‌های ساختاری، سری‌های زمانی و

شبکه‌های عصبی مصنوعی

MAER	RMSER	شاخص‌های مقایسه
		مدل‌های مورد مقایسه
۱/۲۶	۱/۱	I - مانا - ایستا
		BPN-ساختاری
۱/۰۸	۰/۹۸	BPN-سری زمانی
۱/۲۷	۱/۳۸	II - نامانا - ایستا
		BPN-ساختاری
۰/۹۸	۲/۲	BPN-سری زمانی
۱/۰۵	۰/۹۸	III - مانا - پویا
		BPN-ساختاری
۰/۸۹	۱/۸۶	BPN-سری زمانی
۱/۳۲	۱/۴۶	IV - نامانا - پویا
		BPN-ساختاری
۱/۵۴	۱/۴۲	BPN-سری زمانی

۱. RMSER = نسبت مجذور میانگین مربعات خطاهای به‌دست آمده از دو مدل

MAER = نسبت میانگین قدر مطلق خطاهای به‌دست آمده از دو مدل

همانگونه که شاخص‌های جدول (۵) نشان می‌دهند، مدل‌های شبکه‌های عصبی در اغلب موارد، نسبت به مدل‌های ساختاری و سری‌های زمانی پیش‌بینی صحیح‌تری ارائه داده‌اند. به‌طور مشخص، هنگامی که شاخص RMSE در نظر گرفته شود، در سه مورد از چهار مورد، مدل‌های شبکه‌های عصبی برتری قابل توجهی نسبت به هر دو مدل ساختاری و سری‌های زمانی داشته و در یک مورد نیز تقریباً با آنها برابری داشته است. اگر شاخص MAE برای مقایسه در نظر گرفته شود، مدل شبکه‌های عصبی در کلیه موارد بر مدل ساختاری و در دو مورد بر مدل سری‌های زمانی برتری داشته است. در دو مورد

دیگر نیز نتایج مدل‌های شبکه عصبی و سری‌های زمانی تقریباً برابر بوده‌اند. در نهایت اگر شاخص نسبت آماره L برای مقایسه در نظر گرفته شود، مدل شبکه‌های عصبی در سه مورد بر مدل ساختاری و در دو مورد بر مدل سری‌های زمانی برتری داشته است. در سایر موارد نیز عملکرد مدل‌ها چندان تفاوتی با یکدیگر نداشته‌اند.

برای مقایسه عملکرد پیش‌بینی مدل‌ها، روش‌های آماری دیگری نیز در ادبیات پیش‌بینی مطرح شده‌اند. در این روش‌ها، اختلاف‌های شاخص‌های به‌دست آمده با تکیه بر خصوصیات آماری خطاهای پیش‌بینی مورد آزمون قرار می‌گیرند تا مشخص شود که آیا اختلاف‌های موجود از لحاظ آماری معنی دار هستند یا خیر؟ در این مقاله، روش مبتنی بر میانگین تفاضل زیان^۱ استفاده شده است. در این روش ابتدا متغیر تفاضل زیان نمونه به‌صورت زیر محاسبه می‌شود:^۲

$$d_t = L(e_{t+h}^a, t) - L(e_{t+h}^b, t)$$

$L(e_{t+h}, t)$ بیانگر تابع زیان که بر اساس مقدار خطای پیش‌بینی (e) تعریف شده است، می‌باشد. h افق پیش‌بینی و a و b روش‌های پیش‌بینی را نشان می‌دهند. در مرحله بعد، رگرسیون متشکل از متغیر d_t به عنوان متغیر وابسته و C به عنوان عدد ثابت (عرض از مبدأ) اجرا می‌شود. در این رگرسیون، می‌توان رفتار متغیر تصادفی اختلال را با روش AR یا MA نیز مدل‌سازی نمود. اگر عدد ثابت از لحاظ آماری معنی دار بود، به معنی معنی‌دار بودن اختلاف بین دو تابع زیان به‌دست آمده از دو مدل a و b است. در غیر این صورت، نمی‌توان اختلاف ظاهری بین دو تابع را معنی‌دار تلقی نمود. به عبارت دیگر، نمی‌توان یک مدل را بر مدل دیگر برتر دانست. جدول (۶) خلاصه نتایج حاصله از آزمون d_t را نشان می‌دهد.

1- Mean Loss Differential

2- Diebold (1998), ch.12

جدول ۶- نتایج آزمون معنی دلر بودن اختلاف شاخص‌های درستی پیش‌بینی

مدل‌های مورد مقایسه	c ^۱	آماره t	P-value
I - مانا - ایستا			
BPN-ساختاری	۰/۱۳۷	۱/۰۰	۰/۳۷
BPN-سری زمانی	-۰/۸۵	-۵/۴۸	-۰/۰۰۵
II - نامانا - ایستا			
BPN-ساختاری	۰/۹۴	-۱۲/۴	۰/۰۰
BPN-سری زمانی	۰/۱۰	۱/۴۳	۰/۲۲
III - مانا - پویا			
BPN-ساختاری	۰/۲۲۱	۱/۲۰	۰/۳۰
BPN-سری زمانی	-۰/۸۷	-۵/۱۵	۰/۰۰۷
IV - نامانا - پویا			
BPN-ساختاری	-۱/۱۳	-۱۰/۲۴	۰/۰۰۰
BPN-سری زمانی	۰/۱۷	۱/۳۴	۰/۲۵

۱ - عدد ثابت (عرض از مبدأ) رگرسیون = C

همانگونه که ارقام مربوط به آماره t در جدول نشان می‌دهند، در چهار مورد از هشت مورد، اختلافات مربوط به شاخص‌های صحت پیش‌بینی‌ها توسط مدل‌های ساختاری یا سری‌های زمانی با شاخص‌های شبکه‌های عصبی معنی دار هستند.

۴-۱- برخی ملاحظات پیرامون مدل‌های شبکه‌های عصبی

با توجه به نتایج به دست آمده در این مطالعه و سایر مطالعات مشابه، در مجموع می‌توان اظهار نظر کرد که تا جایی که مربوط به پیش‌بینی متغیرهای اقتصادی می‌شود

مدل‌های شبکه‌های عصبی قادرند به خوبی مدل‌های رایج در اقتصاد سنجی اعم از ساختاری و سری‌های زمانی و در برخی موارد نیز حتی بهتر از آنها پیش‌بینی نمایند. بنابراین، می‌توان به دستگاه‌های مسؤول پیش‌بینی متغیرهای اقتصادی پیشنهاد نمود تا از این مدل‌ها حداقل در کنار سایر مدل‌های متداول سنتی نیز بهره‌جویند.^۱ در آخر، در ارتباط با کاربرد مدل‌های شبکه‌های عصبی در اقتصاد باید نکات زیر را یادآوری نمود:

- ۱- کاربرد مدل‌های شبکه‌های عصبی در اقتصاد محدود به پیش‌بینی نمی‌شود. از این مدل‌ها می‌توان برای آزمون روابط غیرخطی بین متغیرهای اقتصادی و همچنین گروه‌بندی آنها نیز استفاده نمود.^۲ در زمینه‌های فوق نیز مدل‌های شبکه‌های عصبی نشان داده‌اند که برتری نسبی نسبت به سایر مدل‌های متداول و رقیب دارند.
 - ۲- به‌رغم آن‌که اکثر تحقیقات اقتصادی که از مدل‌های شبکه‌های عصبی استفاده کرده‌اند، محدود به مدل پس‌انتشار خطا بوده‌اند، ولی مدل‌های متنوعی از لحاظ ساختار، نوع روابط بین واحدهای ورودی، میانی و خروجی و همچنین مکانیزم یادگیری در ادبیات شبکه‌های عصبی وجود دارند که می‌توانند مورد استفاده قرار گیرند. به‌عنوان نمونه، می‌توان به مدل‌های RBFN^۳ و RNN^۴ اشاره نمود که در زمینه‌های پیش‌بینی و گروه‌بندی متغیرهای اقتصادی، عملکرد بسیار خوبی می‌توانند داشته باشند. به‌ویژه، مدل‌های RNN که ساختار آنها اجازه عملکرد متغیرها با تأخیر زمانی را می‌دهد برای کاربرد در زمینه مدل‌های پویای اقتصادی که در آنها تعدیل متغیرها با وقفه زمانی صورت می‌گیرد، بسیار مناسب هستند.^۵
- همچنین می‌توان از مدل‌های شبکه‌های عصبی که فرایند یادگیریشان متکی بر

۱- هم‌اکنون بسیاری مؤسسات پیش‌بینی‌کننده اقتصادی اعم از بخش دولتی و خصوصی جهان، مدل‌های شبکه‌های عصبی مصنوعی را جایگزین مدل‌های پیش‌بینی قبلی خود نموده‌اند.

2- Ahmadi (1994), Moshiri, Kohzadi & Cameron (2000), Kuwan white (1994)

3- Radial Basis Function Networks

4- Recurrent Networks

5- Moshiri, Cameron & Scuse (2000)

روش‌های ژنتیک^۱ و یا منطق فازی^۲ باشد، استفاده نمود. این روش‌ها نشان داده‌اند که در پیش‌بینی متغیرهای بازارهای پولی و مالی بسیار موفق بوده‌اند.

۳- مدل‌های شبکه‌های عصبی را می‌توان مانند غالب مدل‌های سری‌های زمانی در گروه مدل‌های غیر تئوریک جای داد. البته همان گونه که در مدل‌های سری‌های زمانی چند متغیره مانند اتورگرسیون برداری VAR، انتخاب متغیرهای توضیحی می‌توانند مبنای تئوریک داشته باشند، در مدل‌های شبکه‌های عصبی نیز همین روش قابل اعمال است. در حقیقت، برخی محققین نشان داده‌اند که هر چه انتخاب متغیرهای ورودی بر پایه نظریه‌های تئوریک صورت گرفته باشد، نتیجه پیش‌بینی دقیق‌تر خواهد بود. بنابراین، نمی‌توان ادعا نمود که مدل‌های شبکه‌های عصبی با هر گونه ورودی‌های دلخواه قادر به پیش‌بینی صحیحی بوده و لذا ما را از تئوری‌های اقتصادی بی‌نیاز می‌کنند.

محدودیتی که مدل‌های شبکه‌های عصبی در این زمینه دارند عبارت از این است که تعیین سهم مشخص هر یک از متغیرها در تغییرات متغیر توضیحی به علت روابط پیچیده غیر خطی مدل‌چندان ساده نیست و لذا انجام تجزیه و تحلیل حساسیت^۳ به راحتی مدل‌های متداول اقتصادسنجی میسر نیست. البته، در این زمینه تحقیقاتی صورت گرفته و ادبیات آن نیز به سرعت در حال پیشرفت است. روشی که در حال حاضر برای تجزیه و تحلیل حساسیت استفاده می‌شود عبارت از این است که می‌توان با اضافه یا کم نمودن متغیرهای ورودی، عملکرد مدل را مقایسه نمود و بدین ترتیب، در مورد حضور یا عدم حضور متغیر به خصوصی تصمیم گرفت. این امر با توجه به زمان لازم برای یادگیری و پیش‌بینی توسط مدل‌های شبکه‌های عصبی ممکن است طولانی و خسته کننده به نظر برسد، ولی با پیشرفت سریع تکنولوژی محاسباتی که زمان انجام محاسبات را به شدت کاهش داده است، مشکل چندان در این زمینه وجود ندارد.

-
- 1- Genetic Algorithm
 - 2- Fuzzy Logic
 - 3- Sensitivity Analysis

۴- نکته آخر اینکه مدل‌های شبکه‌های عصبی بر خلاف مدل‌های سنتی رایج در اقتصادسنجی، آزاد از قید و بندهای مفروضات آماری هستند. این ویژگی هم می‌تواند به عنوان نقطه قوت و هم به عنوان نقطه ضعف این گونه مدل‌ها مطرح شود. در حالی که آزاد گذاشتن دست محقق در تنظیم روابط بین متغیرها، انعطاف‌پذیری مدل و سهولت انجام کار را می‌توان دلایلی بر نقطه قوت آن دانست ولی عدم قابلیت انجام آزمون‌های آماری می‌تواند دلیلی بر نقطه ضعف این مدل‌ها نیز به شمار رود. البته در این زمینه نیز تحقیقات بسیاری در حال انجام است و محققان به دنبال ایجاد ارتباط منطقی بین مدل‌های شبکه‌های عصبی و مدل‌های آماری هستند تا بتوان مفاهیم استنباط آماری را نیز در اینگونه مدل‌ها بکار بست^۱.

منابع

- 1- Ahmadi H., **Testability of the Arbitrage Pricing Theory by Neural Networks**, in Trippi, Truban(ed), **Neural Networks in Finance and Investing**, 1993.
- 2- Diebold, F. X. **Elements of Forecasting**, International Thomson Publishing, 1998.
- 3- Dupasquier Ch., A. Guay & P. St. Amant, **A Comparison of Alternative Methodologies For Estimating Potential Output & The Output Gap**, Bank of Canada, 1997.
- 4- Faraway, J. & C. Chatfield, **Timeseries Forecasting with Neural Networks: A Case Study**, Research Report 95-66, Statistics Group, University of Bath, 1995.
- 5- Granger, C.W.J. and P. Newbold, **Spurious Regression in Econometrics**, *Journal of Econometrics*, 1974, 111-120.
- 6- Haykin, Simon, **Neural Networks** Macmillan College Publishing Company, 1994.
- 7 - Kuan, C., and H. White. **Artificial Neural Networks: An Econometrics Perspective**, *Econometric Review*, 13(1), 1994.
- 8- Maasumi E., A. Khotanzad, and A. Abaye; **Artificial Neural Networks For Some Macroeconomic Series: A First Report**, *Econometric Reviews*, 13(1), 1994.
- 9- Maral Kichian, **Measuring Potential Output within A State - Space Framework**, Bank of Canada, 1998.
- 10- Masters, T., **Signal and Image Processing With Neural Network**, 1994.
- 11- Moshiri, Saeed, N. Cameron, **Neural Network Versus Econometric Models**

- in Forecasting Inflation**, Journal of Forecasting, 19, 2000, 201-217.
- 12- Moshiri S., N. Cameron, D. Scuse, **Static, Dynamic, and Hybrid Neural Networks in Forecasting Inflation**, Computational Economics, 14, 1999, 219-235.
- 13- Moshiri, S., N. Kohzadi, N. Cameron, **Testing For Stochastic Non-linearity in Rational Expectations Permanent Income Hypothesis**, Working paper, 2000.
- 14- Perron, P., **The Great Crash, The Oil Price Shock, And The Unit Root Hypothesis**, Econometrica, 57, 1989, 1361-1401.
- 15- Rumelhart, D.E., G. E. Hinton, and R. J. Williams, **Learning Internal Representations By Error Propagation**, Parallel Distributed Processing, 1, 1986, 318-62.
- 16- Stock S. H., M. W. Watson, **Forecasting Inflation**, Journal of Monetary Economics, 44, 1999, 293-335.
- 17- Swanson N., H. White, **A Model Selection Approach To Real - Time Macroeconomic Forecasting Using Linear Models And Artificial Neural Networks**, The Review of Economics and Statistics, 1997.
- 18- Trippi R., E. Truban, eds. **Neural Networks in Finance And Investing**, Probus Publishing Co., 1993.
- 19- Wasserman P. D.; **Advanced Methods in Neural Computing**, Van Nostrand Reinhold, 1994.
- 20- White H., **Connectionist Nonparametric Regression: Multivector Feedforward Networks Can Learn Arbitrary Mappings**; Neural Networks. 3. 1990. 525-549.