

مدل پیشنهادی برای پیش‌بینی تولید ناخالص داخلی کاربرد مدل‌های ARIMA، شبکه‌های عصبی و تبدیل موجک

<sup>۱</sup> بیتا شایگانی<sup>۱</sup>

<sup>۲</sup> امیر بهداد سلامی<sup>۲</sup>

<sup>۳</sup> رامین خوچیانی<sup>۳</sup>

تاریخ پذیرش: ۹۲/۰۷/۰۰

تاریخ دریافت: ۹۳/۱/۱۵

### چکیده

تولید ناخالص داخلی یکی از عمدۀ ترین و کاربردی‌ترین شاخص‌های اقتصادی است؛ لذا پیش‌بینی آن، همواره توجه کلیه دست اندکاران اقتصادی و علوم مرتبط را به خود جلب کرده است. هرچند روش‌های تجزیه و تحلیل سری زمانی و روش‌های غیرخطی همانند مدل‌های شبکه عصبی مدت‌هاست که برای پیش‌بینی این گونه متغیرها به کار می‌روند، لیکن کاربرد ابزار توانمند موجک در پردازش داده‌ها و بررسی لایه‌های پنهان آن نشان می‌دهد که سری زمانی تولید ناخالص داخلی از جمله متغیرهایی است که پس از تجزیه در برخی سطوح، رفتاری خطی و در برخی سطوح رفتاری غیرخطی دارد؛ از این رو پیشنهاد شد که ابتدا سری زمانی مذکور به صورت داده‌های فصلی طی دوره ۱۳۸۷ تا ۱۳۸۹، با استفاده از تکنیک موجک به مولفه‌های مقیاسی متفاوتی تجزیه شده و سپس با کمک مدل ARIMA سری تقریب (روند) و سیکل‌های با رفتار خطی، و آنگاه با مدل شبکه عصبی سیکل‌های با رفتار غیرخطی پیش‌بینی شوند. این مقاله نشان می‌دهد که نتیجه اعمال این روش پیشنهادی در مقایسه با مدل شبکه عصبی خودتوضیح غیرخطی با لوب بسته و مدل ARIMA دقیق‌تر و کارآثر است.

**واژه‌های کلیدی:** پیش‌بینی تولید ناخالص داخلی، تبدیل موجک، شبکه عصبی.

۱- استادیار اقتصاد دانشگاه پیام نور pnu.shayegani@yahoo.com

۲- دکترای اقتصاد دانشگاه علامه طباطبائی، absalami@gmail.com

۳- دانشجوی دکترا اقتصاد دانشگاه پیام نور (مسئول مکاتبات) khochiany@gmail.com

**۱- مقدمه**

استفاده از مدل‌های تلفیقی خطی و غیرخطی می‌توان به پیش‌بینی‌های دقیق‌تر و با خطای کمتری رسید. این مطالعه به منظور معرفی الگوی مطلوب برای پیش‌بینی تولید ناخالص داخلی انجام شده است. داده‌های مورد استفاده به صورت فصلی و شامل دوره اولین فصل ۱۳۶۷ تا آخرین فصل ۱۳۸۹ می‌باشند. در این جا ابتدا به چند نمونه از مدل‌های پیش‌بینی خطی و غیرخطی که در اقتصاد کاربرد دارند؛ اشاره کرده و سپس با تلفیق آنها و ارائه مدل ترکیبی جدید، تولید ناخالص داخلی، پیش‌بینی می‌شود. در مرحله بعد کارایی هر کدام از مدل‌ها از طریق معیارهای متعارف ارزیابی بررسی می‌شوند. از جمله این مدل‌ها، مدل‌های شبکه عصبی مصنوعی، مدل ARIMA و مدل تلفیقی ARIMA موجک، شبکه عصبی است. در این مقاله پس از مروری بر مطالعات تجربی و پیشینه پژوهش در رابطه با پیش‌بینی تولید ناخالص داخلی، ضمن معرفی مدل‌های شبکه عصبی و تبدیل موجک، روش شناسی تحقیق بیان خواهد شد. در ادامه به آرایه یافته‌ها در رابطه با پیش‌بینی تولید ناخالص داخلی با استفاده از سه مدل مختلف یعنی خطی ARIMA، غیرخطی شبکه عصبی و مدل پیشنهادی که خود تلفیق مدل‌های ARIMA موجک، شبکه عصبی است، پرداخته می‌شود. آنگاه در بخش نهایی با مقایسه نتایج پیش‌بینی‌ها پیشنهاد ارائه می‌شوند.

**۲- مبانی نظری و مروری بر پیشینه پژوهش**  
در این بخش به مطالعات خارجی و داخلی که نتایج آن مستقیماً به تحقیق حاضر ارتباط دارد، پرداخته می‌شود. نکته قابل توجه آن است که

پیش‌بینی متغیرهای عملده اقتصادی در دوره‌های مختلف ماهانه، فصلی و سالانه، به منظور برنامه‌ریزی و سیاست‌گذاری‌های اقتصادی بسیار حائز اهمیت است. در میان این متغیرها، تولید ناخالص داخلی (GDP) از مهمترین شاخص‌های اقتصادی است که کسب آگاهی از روند تحولات فعلی و آتی آن می‌تواند به سیاست‌گذاران اقتصادی و تصمیم‌گیرندگان اقتصادی کمک کند تا راهکارهای مناسب برای جلوگیری از بحران‌ها و بهبود وضعیت اقتصادی را اتخاذ نمایند.

معمول‌ترین معیار برای ارزیابی کیفیت یک پیش‌بینی اقتصاد کلان، دقت آن در پیش‌بینی رشد GDP واقعی است. صرف نظر از اهمیت آگاهی از قبل نسبت به روند و آهنگ تغییرات این متغیر (سائبول هیمانس، ۱۳۹۰) گستردگی دامنه دربرگیرنده داده‌های مربوط به کالاهای و خدمات نهایی درون مرزهای جغرافیایی یک کشور از مهم‌ترین خصیصه‌های ممتاز این شاخص نسبت به سایر شاخص‌های اقتصادی است.

دیدگاه غالب، در زمینه پیش‌بینی متغیرهای اقتصادی، مدل‌های سری زمانی می‌باشد. روش‌های تجزیه و تحلیل سری زمانی به طور سنتی بر دو مفهوم مانابعی و خطی بودن بنیان نهاده شده‌اند. اما در مواردی که ویژگی‌های غیرخطی داده‌ها مشهود است، عملکرد مدل‌های سنتی در پیش‌بینی عمدتاً ضعیف می‌باشد. سری زمانی تولید ناخالص داخلی از جمله متغیرهایی است که علاوه بر رفتاری خطی در لایه‌های پنهان آن، رفتار غیرخطی داشته که با تجزیه موجک و جداسازی سطوح مختلف سیکلی و

آنجلینی و همکاران<sup>۲</sup> (۲۰۱۱) با ارزیابی مدل‌های پیش‌بینی سه ماهه تولید ناخالص داخلی در منطقه یورو، روش‌های سنتی معمول را با یک روش جدید مقایسه کردند. در این روش که آن را ارتباط با ضرایب<sup>۳</sup> عنوان کردند؛ تولید ناخالص داخلی سه ماهه با داده‌های ماهانه از طریق رگرسیون بر ضرایب استخراج شده از سری زمانی ماهانه با حجم نمونه بالا و با وقفه‌های انتشار متفاوت ارتباط داده می‌شود. این مدل چارچوبی برای به کارگیری اطلاعات ماهانه درپیش‌بینی داده‌های سه‌ماهه فراهم می‌کند. مدل مذکور همانند فیلتر کالمون<sup>۴</sup> در محاسبه ضرایب پیش‌بینی و محاسبه مشاهدات از دست رفته به علت وقفه‌های انتشار عمل می‌کند. در این تحقیق نشان داده شده که این روش با توجه به معیارهای ارزیابی مدل، بسیار مناسب‌تر از معادلات اقتصاد سنجی است.

در مطالعه کک و تراسویرتا<sup>۵</sup> (۲۰۱۱) عملکرد پیش‌بینی یک نوع از مدل‌های شبکه عصبی با نام "شبکه عصبی پیشخور با لایه پنهان واحد"، ارزیابی شده است. مهمترین هدف تحقیق مذکور بیان ابزار مفید برای پیش‌بینی متغیرهای مختلف اقتصادی و از جمله GDP است. نتیجه جالب توجه مطالعه آنها این است که مدل‌های غیرخطی همانند مدل شبکه عصبی برای داده‌هایی که با مکانیسم خطی ایجاد شده‌اند، چندان مناسب نمی‌باشد. بنابراین بهتر است، ابتدا رفتار داده‌ها از نظر خطی یا غیرخطی بررسی و سپس مدل مناسب آن انتخاب شود. گو و همکاران<sup>۶</sup> (۲۰۱۲) با استفاده از مدل‌های سری زمانی، اقدام به پیش‌بینی GDP چین طی سال‌های ۱۹۷۸ تا ۲۰۰۶ کردند. این پیش‌بینی با استفاده از مدل‌های سری زمانی خطی انجام

مطالعات انجام شده بیانگر برتری و مزیت یک مدل پیش‌بینی خطی یا غیرخطی نسبت به مدل‌های رقیب می‌باشد. لکن از آنجا که دیدگاه ناظر بر این مقاله آن است که سری زمانی تولید ناخالص داخلی مجموعه‌ای از فعالیت‌های اقتصادی در مقیاس‌های زمانی متفاوت است که در هر مقیاس زمانی می‌تواند رفتاری خطی یا غیرخطی داشته باشد؛ لذا مدل بهینه نیز می‌بایست تلفیقی از مدل‌های خطی (برای رفتارهای خطی سری زمانی) و مدل‌های غیرخطی (برای رفتارهای غیرخطی سری زمانی) باشد.

کستانزو و همکاران<sup>۷</sup> (۲۰۰۴) با استفاده از رویکرد غیرخطی به پیش‌بینی رشد تولید ناخالص داخلی در ونزوئلا پرداخته و از یک مدل شبکه عصبی برای پیش‌بینی شاخص ماهیانه استفاده کردند. ساختار شبکه عصبی به کار رفته در این تحقیق از نوع گروهی بوده که یک شبکه اصلی و هشت شبکه فرعی دارد. برای به دست آوردن این شاخص ماهیانه، بانک مرکزی ونزوئلا، تعدادی از شاخص‌های مرتبط که نشان دهنده سطح فعالیت‌های اقتصادی هستند؛ از جمله مصرف انرژی، شاخص سهام کاراکاس، نرخ وام، قیمت طلا، قیمت نفت خام سفید و ... را به عنوان ورودی شبکه عصبی، انتخاب کرده است. نتیجه تحقیق نشان می‌دهد که رشد تولید ناخالص داخلی یک الگوی سیکلی را دنبال می‌کند به طوری که اضافه کردن متغیرهای میانگین متحرک نقش تعیین‌کننده‌ای در کاهش بردار خطاهای خواهد داشت. همچنین مدل شبکه عصبی گروهی در پیش‌بینی تولید ناخالص داخلی نسبت به شبکه‌های عصبی فردی از کارایی بالاتری برخوردار است که در میزان بهره‌وری شبکه آموزش داده شده و معیارهای ارزیابی کارایی مدل مشهود است.

الگوهای رشد درونزا باشند. در این مقاله از دو الگو استفاده شده است؛ الگوی نخست الگویی است که به وسیله آن نقش عوامل اولیه‌ای چون سیاست‌های پولی، مالی و درآمدهای ارزی نفت بررسی می‌شود. حال آن که در الگوی دوم، نقش متغیرهای درونزا، نظیر سرمایه انسانی، تحقیق و توسعه و بهره‌وری مورد بررسی قرار می‌گیرد. نتایج به دست آمده از این تحقیق حاکی از آن است که مخارج دولت و درآمدهای ارزی نفت، به عنوان تنها عامل مؤثر و توضیح‌دهنده رشد اقتصادی ایران مطرح هستند و متغیرهای مؤثر بر سرمایه انسانی مورد بحث در الگوهای رشد درونزا چون آموزش، تحقیق و توسعه و بهره‌وری تأثیر چندانی بر رشد اقتصادی ایران ندارند.

در مطالعه ابریشمی و دیگران، (۱۳۸۸) از شبکه عصبی<sup>۱</sup> GMDH، به عنوان ابزاری با قابلیت بالا در مسیریابی و تشخیص روندهای غیرخطی پیچیده، به ویژه با تعداد مشاهدات محدود، برای الگوسازی و پیش‌بینی رشد تولید ناخالص داخلی به قیمت ثابت در ایران استفاده شده است. در ابتدا الگویی بنیادی شامل ۷ متغیر، همراه با وقفه اول رشد تولید ناخالص داخلی طراحی و سپس با استفاده از فرایند قیاسی و نیز کنار گذاشتن هر متغیر از الگوی بنیادی، در مجموع ۱۸ مدل اجرا شده است. نتایج نشان می‌دهد الگوهای حاصل از کنار گذاشتن رشد صادرات کل، رشد صادرات نفت و رشد حجم تجارت از الگوی بنیادی، به ترتیب بیشترین سهم را در کاهش خطای بنیادی دارا هستند. برتری شبکه عصبی GMDH در دقت پیش‌بینی رشد اقتصادی نسبت به روش ARIMA، بر اساس معیارهای خطای نیز مورد تأیید قرار گرفته است.

می‌شود. ابتدا داده‌ها از لحاظ مانایی بررسی و سپس با مدل‌های سری زمانی پیش‌بینی شده است. در مرحله بعد نیز از طریق علیت گرنجر رابطه مصرف انرژی و GDP بررسی شده است.

جانو و همکاران<sup>۲</sup> (۲۰۱۳) نیز با روش GLG<sup>۳</sup> که یک روش یادگیری موثر است و می‌تواند ساختارهای علی زمانی بین سری‌های زمانی بدون روند و قاعده را اخذ کرده و بر طبق آن نرخ رشد تولید ناخالص داخلی را با مجموعه داده‌های سسامدی مختلف پیش‌بینی کند. GDP چین را پیش‌بینی کرده‌اند. مزیت این روش در آن است که داده‌های مفقود با فرکانس پایین سری زمانی به طور مستقیم تخمین زده نمی‌شوند و محدود به فروض ایجاد داده‌های سری زمانی نمی‌گردند.

و در مطالعات داخلی نیز می‌توان به مطالعه قدیمی و مشیری (۱۳۸۱) اشاره کرد که، کارایی یک مدل شبکه عصبی با یک مدل خطی رگرسیون برای پیش‌بینی نرخ رشد اقتصادی در ایران مقایسه شده است. برای این منظور، ابتدا یک مدل رگرسیون رشد برای دوره ۱۳۷۳-۱۳۱۵ برآورد و سپس با همان مجموعه رگرسورها (متغیرهای ورودی) یک مدل شبکه عصبی طراحی و تخمین زده شده است. پس از آن، با استفاده از معیارهای مرسوم ارزیابی مدل‌های رقیب، کارایی دو مدل فوق در زمینه پیش‌بینی نرخ رشد اقتصادی در ایران در دوره ۱۳۸۰-۱۳۷۴ مقایسه شده است. نتایج نشان می‌دهد که مدل شبکه عصبی برای پیش‌بینی نرخ رشد اقتصادی در ایران از کارایی بالاتری برخوردار است.

در مقاله درگاهی و قدیری (۱۳۸۲)، مطالعاتی مرکز توجه قرار می‌گیرند که اولاً در آن مطالعات، پیش‌تر متغیرهای تأثیرگذار بر رشد حضور داشته باشند و ثانیاً، این مطالعات به نوعی دربرگیرنده

های عصبی مختلف مانند: شبکه های پیشخور، شبکه‌های برگشتی، شبکه خودسازمان ده کوهون و....، شبکه عصبی برگشتی ۱۲ مورد استفاده قرار گرفته است. زیرا شبکه‌های برگشتی برخلاف شبکه‌های پیش خور حداقل یک سیگنال برگشتی از یک نرون به همان نرون یا نرون‌های همان لایه یا نرون‌های لایه قبل وجود دارد. ضمن آنکه اگر نرونی دارای فیدبک باشد یعنی خروجی نرون در حال حاضر نه تنها به ورودی در آن لحظه بلکه به مقدار خروجی خود نرون در لحظه گذشته نیز بستگی دارد. با قرار دادن مقادیر گذشته به عنوان داده‌های ورودی شبکه امکان تشخیص الگوهای رفتاری پنهان سری زمانی ایجاد شده و با حرکت در امتداد مقیاس زمانی داده‌های پیش‌بینی شده را می‌توان تولید کرد. به این ترتیب شبکه‌های برگشتی بهتر می‌توانند رفتار مربوط به ویژگی‌های زمانی و پویایی سیستم‌ها را نشان دهند. (فتی پور جلیلیان و نجبا، ۱۳۸۸: ۱۶)

در این نوع شبکه‌ها بعد از مرحله یادگیری شبکه نیز پارامترها تغییر کرده و تصحیح می‌شوند. (به طور مثال در پیش‌بینی‌ها بعد از گذر زمان مقایسه انجام شده و پارامترهای آزاد شبکه تنظیم می‌شوند). در این شبکه همه نرون‌ها شبیه به یکدیگر عمل کرده و هیچ کدام از نرون‌ها به عنوان ورودی یا خروجی از هم متمایز نمی‌شوند.

به عنوان مثال برای پیش‌بینی تولید ناخالص داخلی پنج گام به جلو به صورت ریاضی می‌توان نوشت:

(۱)

$$X(t+n) = f[X(t), X(t-1), X(t-2), \dots, X(t-i)] \\ \text{for } n=1, \dots, 5$$

شبکه عصبی خود برگشتی را در شکل ذیل می‌توان نشان داد:

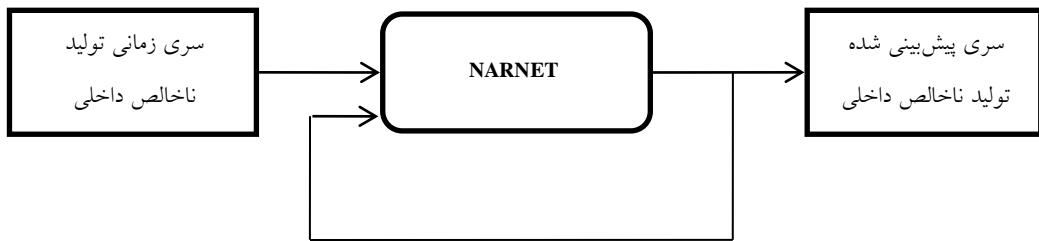
معرفی شبکه‌های عصبی، تبدیل موجک، مدل خطی ARIMA، مدل شبکه عصبی و مدل پیشنهادی

### شبکه‌های عصبی<sup>۱۰</sup>

شبکه‌های عصبی یکی از پویاترین حوزه‌های تحقیق در دوران معاصر است که افراد متعددی از رشته‌های گوناگون علمی را به خود جلب کرده است. زیست‌شناسان، شبکه‌های عصبی بیولوژیکی<sup>۱۱</sup> را طی سالیان متعددی مطالعه کرده‌اند، که مغز انسان، نمونه‌ای از این شبکه‌های است. (البرزی، ۱۳۸۰)

برای مدل‌سازی یک شبکه عصبی مصنوعی، می‌توان از یک مدل ریاضی که خصوصیات یک سیستم بیولوژیکی را توصیف می‌کند، استفاده کرد. مدل سازی شبکه‌های عصبی به شکل مدل‌های سازمان یافته لایه‌ای، و با توجه به پردازش موازی یک تصویر در مغز انسان، انجام می‌گیرد. به عبارت دیگر مدل‌های ANN را همچنین می‌توان به مدل‌های داده‌ستانده خاصی تعبیر نمود که دارای ویژگی‌های مانند انجام عملیات با حجم بسیار زیاد به صورت موازی و پردازش غیرخطی داده‌ها می‌باشند. این ویژگی‌ها، 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 این مدل‌ها در علم اقتصاد عمده‌تا در زمینه پیش‌بینی و دسته‌بندی متغیرها در بازارهای مالی و پولی و بیشتر به واسطه عدم قدرت کافی مدل‌های موجود در تبیین و پیش‌بینی رفتار متغیرهای اقتصادی بوده است. برای مثال در پیش‌بینی قیمت سهام، نرخ مبادله ارز یا درجه‌بندی اوراق قرضه از این مدل‌ها استفاده شده است. در این مقاله از بین انواع شبکه



نمودار ۱. ساختار شبکه عصبی برگشتی (منبع: نرم افزار Matlab)

فواصل کوتاه‌تر برای دیدن اطلاعات با بسامد بالا استفاده شود.

در این مدل سیگنال اصلی در طول زمان، توسط توابع موجک تغییر مقیاس یافته (که در طول زمان جابجا می‌شوند) ضرب شده و سپس انتگرال‌گیری می‌شود.

(۲)

$$C(S, T) = \int_{-\infty}^{+\infty} f(t) \cdot \psi_{S,T}(t) dt$$

در رابطه بالا  $\psi_{S,T}(t)$  موجک مادر تغییر مقیاس یافته به اندازه  $S$  و انتقال یافته در زمان، به اندازه  $T$  می‌باشد. نتیجه تبدیل موجک پیوسته، ضرایب موجک  $C$  می‌باشند که توابعی از مقیاس و ضریب جابجایی می‌باشند. با ضرب کردن هر کدام از این ضرایب در موجک‌های مادر تغییر مقیاس یافته و جابجا شده در زمان، می‌توان موجک‌های تشکیل‌دهنده سیگنال اصلی را بدست آورد. پایه موجک از یک موجک پدر که بیانگر روند اصلی داده‌هاست و یک موجک مادر که در جهت توضیح تمام انحرافات از روند اصلی داده‌ها استفاده می‌شود، تشکیل می‌شود. عبارت مادر به این دلیل به کار رفته که توابع متفاوت به وجود آمده بر اساس پارامترهای انتقال و مقیاس، همگی از تابع پایه (یا مینا) یعنی انتقال و مقیاس، همگی از تابع پایه (یا مینا) یعنی

### تجزیه موجک<sup>۱۳</sup>

تجزیه موجک برای روشن ساختن ساختارهای پیچیده‌ای که در وضعیت تلاطم ظاهر می‌شوند، مانند جریان‌های جوی و نیز به عنوان ابزاری عددی که می‌تواند تا حد زیادی از پیچیدگی محاسبات بزرگ مقیاس بکاهد؛ استفاده می‌شود.

یک تبدیل موجک دارای ویژگی‌های زیر است:

(صادقی و ذوالفقاری، ۱۳۹۰)

(۱) تبدیل یک سیگنال به مجموعه‌ای از

موجک‌ها

(۲) ایجاد و ارایه یک مسیر برای آنالیز نمودن شکل موج‌های مختلف در دو حوزه زمان و بسامد

(۳) امکان ذخیره نمودن سیگنال‌ها با بازدهی بهتر نسبت به تبدیل فوریه

(۴) توانایی تقریب سیگنال‌ها با کیفیتی بسیار بهتر

همان طور که نگریستن به یک شیء از فاصله خیلی دور فقط اطلاعات کلی از شیء بdst می‌دهد و با هر چه نزدیک‌تر شدن به آن، امکان مشاهده جزئیات، فراهم می‌گردد؛ تحلیل موجک نیز این امکان را به وجود می‌آورد، تا از فواصل زمانی طولانی‌مدت برای دیدن اطلاعات با بسامد پایین و از

دارد، در حالی که با تبدیل موجک می‌توان در دو مقیاس زمان و بسامد سری زمانی را تجزیه کرد و لذا این مشکل مرتفع می‌شود علاوه بر این با تبدیل موجک می‌توان به پیش‌بینی و بررسی تغییرات ساختاری، نویززدایی، تجزیه مقیاسی- زمانی داده‌های مالی و اقتصادی و بررسی روابط علت و معلولی میان متغیرهای اقتصادی پرداخت. در این مقاله از توانایی موجک‌ها در زمینه تجزیه داده‌ها و سپس پیش‌بینی رفتار سری زمانی تولید ناخالص داخلی استفاده می‌شود.

تجزیه سیگنال و داده‌های بسامد بالا و بسامد پایین در آنالیز موجک از تقریب سیگنال و جزئیات آن استفاده می‌شود. تقریب سیگنال معمولاً از مقیاس‌های بزرگ و یا مولفه‌های با بسامد پایین تشکیل می‌شود. ولی جزئیات سیگنال یا همان سطوح تجزیه شده، از مقیاس‌های کوچک و یا مولفه‌های با بسامد بالا تشکیل شده است. مطابق با شکل (۲) می‌توان مولفه‌های بسامد پایین را دوباره از دو فیلتر پایین‌گذر و بالا گذر عبور داده و ضرایب دیگری از تبدیل موجک گستته در سطوح مختلف بسامدی را بدست آورد.

موجک مادر) ناشی می‌شوند.(پولیکار، ۱۹۹۶) این موجک‌های مبنا یکتا نیستند و بسته به کاربرد، انواع گوناگونی را می‌توان انتخاب نمود و این متنوع بودن موجک‌های مادر باعث تفاوت اصلی و برتری ویژه تبدیل موجک بر سایر تبدیل‌ها شده است. از مهمترین موجک‌های مادر می‌توان به موجک‌های هار<sup>۱۴</sup>، دابوچی<sup>۱۵</sup>، سیملت<sup>۱۶</sup>، کویفلت<sup>۱۷</sup>، میر<sup>۱۸</sup>، گوسین<sup>۱۹</sup>، مورلت<sup>۲۰</sup> و شانون<sup>۲۱</sup> اشاره کرد. هر کدام از این موجک‌ها در استفاده خاصی بهترین نتیجه را به همراه دارند. بنابراین با توجه به کاربرد مورد نیاز، بایستی توجه نمود که از کدام موجک بایستی استفاده نمود.(صادقی و ذوالقدری، ۱۳۹۰)

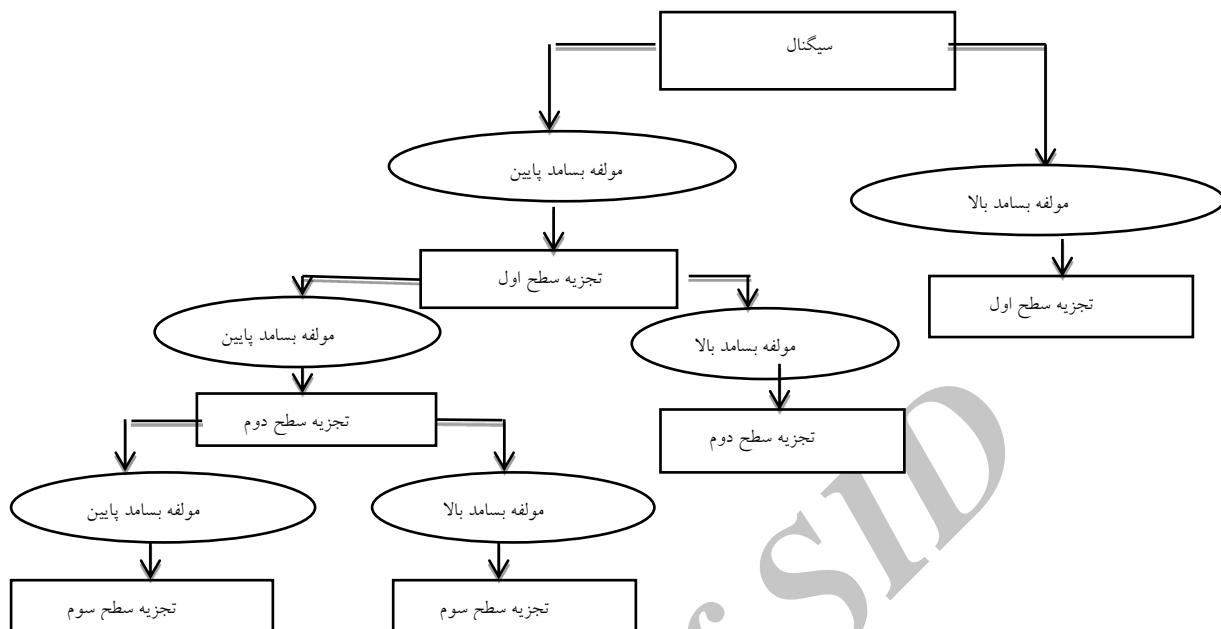
کلیه توابع پنجره  $(t)_{s,\tau}^*$  که از تابع مادر ساخته می‌شوند، موجک‌های دختر ۲۲ نامیده شده و از رابطه ذیل بدست می‌آیند.

(۳)

$$\Psi_{s,\tau}(t) = \Psi\left(\frac{t-\tau}{s}\right)$$

در مقیاس‌های بالا، موجک بر جزئیات و پدیده‌های کوتاه مدت تمرکز دارد اما در مقیاس‌های پایین، موجک قادر به تشریح پدیده‌های بلند مدت است.(مشیری و دیگران، ۱۳۸۹)

اگرچه تحلیل موجک ریشه در تحلیل فوریه دارد اما برتری‌های مهمی با تحلیل فوریه<sup>۲۳</sup> دارد. از جمله آن که تحت تبدیل فوریه اطلاعات زمانی سری زمانی کاملاً از بین می‌رود و در نتیجه نمی‌توان اطلاعاتی در مورد هنگام وقوع یک سیکل مشخص و هنگام ناپدید شدن آن دریافت نمود. این امر در مورد سری‌های زمانی نامانا می‌تواند مشکلاتی را ایجاد کند؛ زیرا در سری‌های زمانی نامانا نیاز به بررسی همزمان مقیاس‌های زمان و بسامد وجود



نمودار ۲. تجزیه سه سطحی یک سیگنال با استفاده از فیلترهای پایین گذر و بالا گذر

منبع: (عباسی نژاد و محمدی، ۱۳۸۶)

### پیش‌بینی تولید ناخالص داخلی با مدل ARIMA

در مدل‌های سری زمانی از نوع باکس-جنکینز که از نظر تکنیکی به روش‌شناسی ARIMA شهرت یافته است، متغیر مورد بررسی با استفاده از مقادیر گذشته و جملات خطای استوکاستیک توضیح داده می‌شود.

روش‌شناسی باکس-جنکینز، شامل چهار مرحله تشخیص، تخمین، کنترل تشخیصی و پیش‌بینی است. (گجراتی ۱۳۷۸<sup>۲۴</sup>) اگر متغیر مورد نظر مانا نباشد، ابتدا باید آن را تبدیل به یک سری زمانی مانا نمود و سپس آن را مدل‌سازی نمود. آزمون مانایی برای جلوگیری از رگرسیون‌های کاذب صورت می‌گیرد. برای مانا نمودن متغیرها به ناچار بایستی از تفاضل متغیرها استفاده نمود. به طور خلاصه در این روش بعد از اطمینان از مانا بودن متغیر مورد نظر و یا به عبارت دیگر بعد از تعیین درجه مانایی متغیر

### پیش‌بینی تولید ناخالص داخلی

در این بخش به پیش‌بینی تولید ناخالص داخلی با مدل‌های مختلف پرداخته می‌شود. برای مقایسه عملکرد مدل‌ها از معیارهای ریشه میانگین مربعات خطای پیش‌بینی (RMSE) و میانگین قدر مطلق خطاهای (MAE) به صورت زیر استفاده شد.

$$\text{RMSE} = \sqrt{\frac{1}{T-(T_1-1)} \sum_{t=T_1}^T (y_{t+s} - f_{t,s})^2} \quad (4)$$

$$\text{MAE} = \frac{1}{T-(T_1-1)} \sum_{t=T_1}^T |y_{t+s} - f_{t,s}| \quad (5)$$

که در آن  $T$ : اندازه کل نمونه (داده‌های داخل نمونه و خارج نمونه)؛  $T_1$ : اولین مشاهده خارج از نمونه؛  $f_{t,s}$ : پیش‌بینی  $s$  گام جلوتر متغیر در زمان  $t$ ؛  $y_t$ : مقدار واقعی متغیر در زمان  $t$  می‌باشد.

وجود نداشته باشد. نتایج این پیش‌بینی در جدول نشان داده شده است.

### پیش‌بینی تولید ناخالص داخلی با مدل شبکه عصبی

در مطالعه حاضر برای پیش‌بینی سری زمانی تولید ناخالص داخلی از نوعی شبکه عصبی یعنی شبکه عصبی خود توضیح غیرخطی (NARNET)<sup>۳۰</sup> استفاده می‌شود. NARNET یک شبکه برگشتی یا پسخور است، که توضیح کامل آن در بخش معرفی مدل شبکه عصبی داده شد. علت انتخاب این نوع مدل شبکه عصبی استفاده صرف آن از مقادیر گذشته متغیر برای پیش‌بینی است که خود، امر پیش‌بینی را آسان‌تر می‌سازد.

شبکه با استفاده از الگوریتم معمولی لونبرگ مارکواردت<sup>۳۱</sup> آموزش داده می‌شود. همچنین برای لایه‌های پنهان تابع فعالسازی سیگموئید<sup>۳۲</sup> و برای نرون‌های لایه خروجی نیز از تابع فعالسازی خطی<sup>۳۳</sup> استفاده شده است. تعداد لایه پنهانی<sup>۸</sup> و تعداد وقنه تا خیری<sup>۳</sup> انتخاب شد. نسبت‌های آموزش، آزمایش و ارزیابی به ترتیب، ۱۵، ۱۵<sup>۷۰</sup> و می‌باشد. شبکه پس از آموزش با لوب بسته<sup>۳۴</sup> و برای پیش‌بینی پنج گام به جلو از فصل چهارم ۱۳۸۸ تا فصل چهارم ۱۳۸۹ استفاده شد.

موردنرسی با توجه به توابع خودهمبستگی<sup>۲۵</sup> و خودهمبستگی جزئی<sup>۲۶</sup> و توجه به اصل صرفه‌جویی که از معیارهای شوارتزیزین<sup>۲۷</sup>، آکائیک<sup>۲۸</sup> و حنان کوئین<sup>۲۹</sup> استفاده می‌شود. مرتبه مدل را شناسایی نموده و به تخمین آن پرداخته می‌شود. بعد از تخمین مدل و تثیت آن به عنوان مدل نهایی اقدام به پیش‌بینی مدل می‌گردد.

آزمون ریشه واحد برای تولید ناخالص داخلی فصلی نشان می‌دهد که این داده در سطح، نامانا می‌باشد.(نتایج آزمون در قسمت ضمیمه آمده است). پس از مانا کردن آن با یک بار تفاضل‌گیری برای انتخاب مدل بهینه برای پیش‌بینی، از معیار آکایک استفاده شده است.

### ۳- نتایج پژوهش

برای پیش‌بینی ابتدا از داده‌های فصل اول ۱۳۶۷ تا فصل سوم ۱۳۸۸ استفاده کرده و سپس به پیش‌بینی خارج از نمونه تا پنج گام به جلو یعنی فاصله از فصل چهارم ۱۳۸۸ تا ۱۳۸۹ می‌پردازیم. دلیل استفاده از پیش‌بینی نوع گام به گام، آن است که گرچه یک مدل امکان دارد در چند گام اول، نسبت به مدل دیگری از قدرت پیش‌بینی بالایی برخوردار باشد اما در مجموع پنج گام ممکن است این برتری

جدول ۱. نتایج پیش‌بینی پنج گام به جلو با مدل ARIMA

RMSE	MAE	مقدار پیش‌بینی (میلیارد ریال)	مقدار واقعی (میلیارد ریال)	MA	درجه AR	ARIMA مدل پیش‌بینی (گام یا فصل)
936	936	122425.0	121489.0	۵	۵	یک گام به جلو
918	917.9	123332.2	124232.0	۵	۵	دو گام به جلو
1667.8	1472.1	150477.4	153058.0	۵	۵	سه گام به جلو
1687.2	1540.1	137355.0	135611.0	۵	۵	چهار گام به جلو
1655.8	1536.8	127749.0	129273.0	۵	۵	پنج گام به جلو

منبع: محاسبات تحقیق



نمودار ۳. بهره وری شبکه آموزش داده شده (منبع: محاسبات تحقیق)

جدول ۲. نتایج پیش‌بینی پنج گام به جلو با مدل شبکه عصبی

مدل شبکه عصبی	مقدار واقعی (میلیارد ریال)	مقدار پیش‌بینی (میلیارد ریال)	تعداد تاخیری	تعداد لایه پنهانی	MAE	RMSE
یک گام به جلو	121489.0	121277.4	۳	۸	211.6	211.6
دو گام به جلو	124232.0	125969.4	۳	۸	974.5	1237.6
سه گام به جلو	153058.0	145522.4	۳	۸	3161.5	4466.4
چهار گام به جلو	135611.0	135792.4	۳	۸	2416.5	3869.1
پنج گام به جلو	129273.0	127023.5	۳	۸	2383.1	3603.9

منبع: محاسبات تحقیق

تجزیه می‌شود که سطح تقریب آن به صورت یک خط تقریباً راست دریایید: (در این مقاله، سری زمانی تولید ناچالص داخلی تا سه سطح تجزیه گردیده است). پس از آن سری هموار شده با استفاده از یک مدل ARIMA پیش‌بینی می‌شود. در اینجا سری زمانی به یک سطح تقریب یا روند و سه سطح جزئیات یا سه سیکل با بسامدهای مختلف تجزیه شده است. تقارن هر کدام از سیکل‌ها می‌تواند نشان دهنده رفتار خطی و عدم تقارن آنها بیانگر رفتاری غیرخطی باشد. بنابراین سیکل متقارن با مدل خطی ARIMA و سیکل نامتقارن نیز با مدل غیرخطی شبکه عصبی پیش‌بینی می‌شود. پیش‌بینی نهایی،

همانطور که در شکل (۳) مشاهده می‌شود، میزان بهره‌وری شبکه آموزش اجرا شده تقریباً ۰/۹۹ می‌باشد که نشان دهنده کارایی بالای سیستم برای پیش‌بینی داده‌های مذکور می‌باشد. مقادیر پیش‌بینی شده، در جدول ذیل مشاهده می‌شود.

### پیش‌بینی تولید ناچالص داخلی با مدل موجک- شبکه عصبی ARIMA

این نوع پیش‌بینی، در واقع تلفیقی از تبدیل موجک، شبکه عصبی و مدل ARIMA است. بدین صورت که ابتدا سری زمانی تولید ناچالص داخلی فصلی، با استفاده از موجک سیملت ۴، تا سطحی

طبیعی است که سری توابع جزئیات مانا بوده و نیاز به تناقض‌گیری ندارد. در شکل ۵ سری هموار شده و توابع جزئیات نشان داده شده است.

### جدول ۳. بررسی رفتار سیکلی سری زمانی تولید ناخالص داخلی

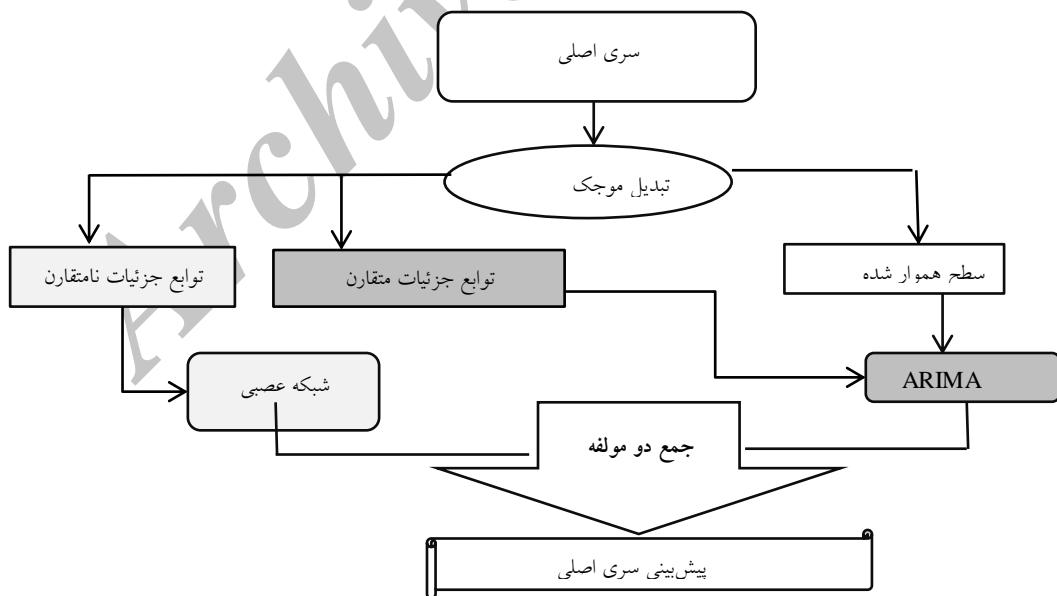
تقارن در عمق تغییرات	تقارن در سرعت تغییرات	سیکل‌های تجزیه شده با موجک بر اساس شدت بسامد
تقارن تایید می‌شود.	تقارن تایید می‌شود.	(بسامد بالا) D1
تقارن تایید نمی‌شود.	تقارن تایید می‌شود.	(بسامد متوسط) D2
تقارن تایید نمی‌شود.	تقارن تایید نمی‌شود.	(بسامد پایین) D3

منبع: محاسبات تحقیق

مجموع پیش‌بینی‌های سطوح تجزیه شده و سطح تقریب است.

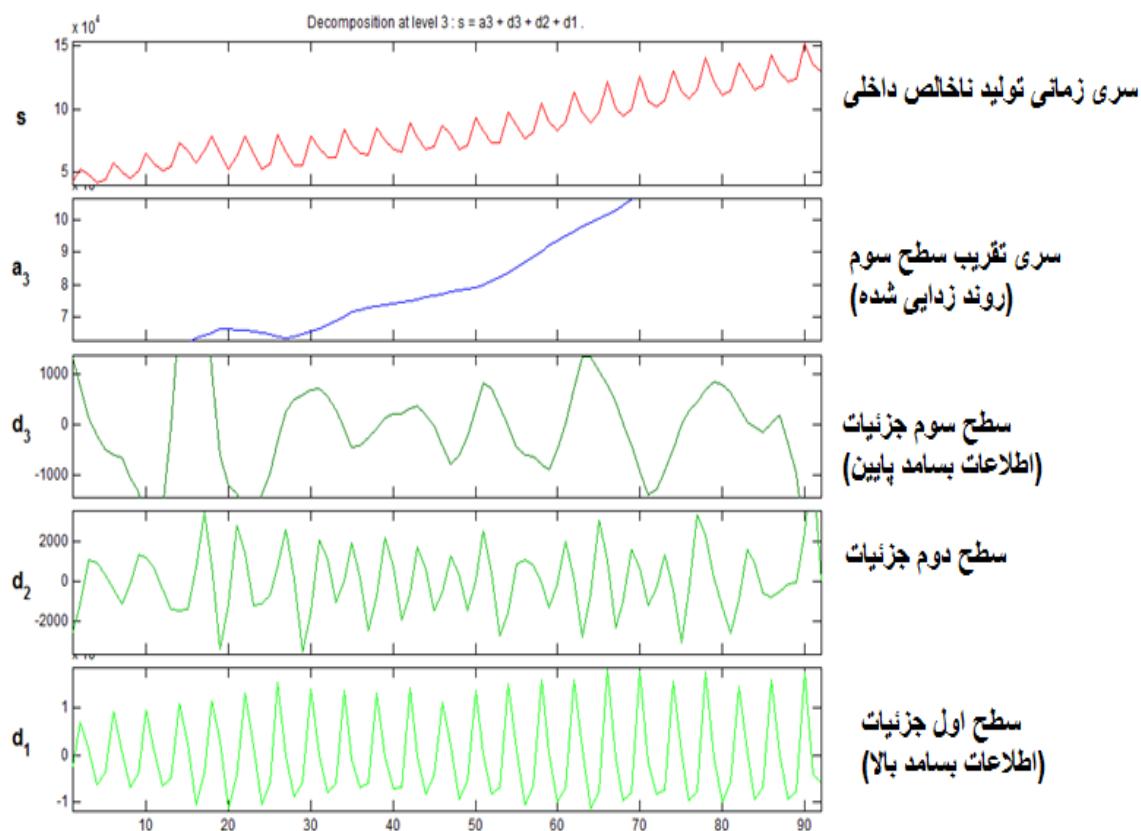
موضوع تقارن سیکل‌ها خود مبحث مهم و گسترده‌ای است که نگارنده مقاله، در تحقیقی جداگانه به این موضوع پرداخته که تنها به ذکر نتایج آن تحقیق بسنده می‌شود.

بنابراین سری هموار شده (رونده) و سطح اول و دوم سیکل تجزیه شده به دلیل رفتار متقارن، با مدل ARIMA پیش‌بینی می‌شود. مزیت انجام این کار، این است که مدل‌های ARIMA در پیش‌بینی سری‌های خطی، قدرت بالایی دارند و در نتیجه سطح تقریب و سیکل‌های متقارن اول و دوم را با دقت بالایی پیش‌بینی می‌کنند. سطح سوم سیکل تجزیه شده نیز به دلیل رفتار نامتقارن با مدل شبکه عصبی پیش‌بینی می‌شود.



### نمودار ۴. مراحل پیش‌بینی با مدل تلفیقی موجک - ARIMA - شبکه عصبی

منبع: محاسبات تحقیق



نمودار ۵ . سرو زمانی تولید ناخالص داخلی و تجزیه سطح آن با موجک سمیلت ۴ .

منبع: محاسبات تحقیق

آزمون ریشه واحد برای سرو تقریب(سطح هموارشده) نشان می‌دهد که این سرو در سطح و تفاضل اول نامانا می‌باشد. ولی در تفاضل مرتبه دوم مانا خواهد بود.

برای انجام پیش‌بینی ابتدا از داده‌های فصل اول ۱۳۶۷ تا فصل سوم ۱۳۸۸ در مدل استفاده کرده و سپس به پیش‌بینی خارج از نمونه تا پنج گام به جلو از فصل چهارم ۱۳۸۸ تا فصل چهارم ۱۳۸۹ می‌پردازیم. مدل بهینه برای پیش‌بینی سطوح مختلف در جدول ذیل آورده شده است.

موجک سمیلت دارای ویژگی‌ها و مزایایی می‌باشد که انتخاب آن را توجیه‌پذیر می‌سازد. این موجک و انتخاب آن یک انتخاب حد وسط است. چرا که به طور منطقی، موجکی باریک و نسبتاً هموار و تقریباً متقارن است و دارای درجه متوسطی از انعطاف پذیری می‌باشد. (رمزی و لمپارت<sup>۳۰</sup>، ۱۹۹۸) علاوه بر آن، در مدل رمزی و لمپارت نیز که رابطه درآمد و مصرف براساس تجزیه موجک بررسی شده نیز به همین دلایل اشاره و از آن به عنوان یک موجک با ویژگی‌های کیفی خوب یاد شده است.

سری زمانی تولید ناخالص داخلی است. شبکه با استفاده از الگوریتم معمولی لونبرگ مارکواردت آموزش داده می‌شود. همچنین برای لایه‌های پنهان تابع فعالسازی سیگموئید و برای نزون‌های لایه خروجی نیز از تابع فعالسازی خطی استفاده شده است. تعداد لایه پنهانی ۲۰ و تعداد وقهه تاخیری ۶ انتخاب شد. نسبت‌های آموزش، آزمایش و ارزیابی به ترتیب، ۱۵، ۷۰ و ۱۵ می‌باشد. شبکه پس از آموزش با لوب بسته و برای پیش‌بینی پنج گام به جلو از فصل چهارم ۱۳۸۸ تا فصل چهارم ۱۳۸۹ استفاده شد.

میزان بهره‌وری شبکه آموزش اجرا شده تقریباً ۰/۹۹ می‌باشد که نشان دهنده کارایی بالای سیستم برای پیش‌بینی داده‌های مذکور می‌باشد. پس از پیش‌بینی مجموع توابع جزئیات با شبکه عصبی، و سری تقریب با مدل خطی ARIMA، مقادیر پیش‌بینی شده را در جدول ذیل مشاهده می‌کنیم.

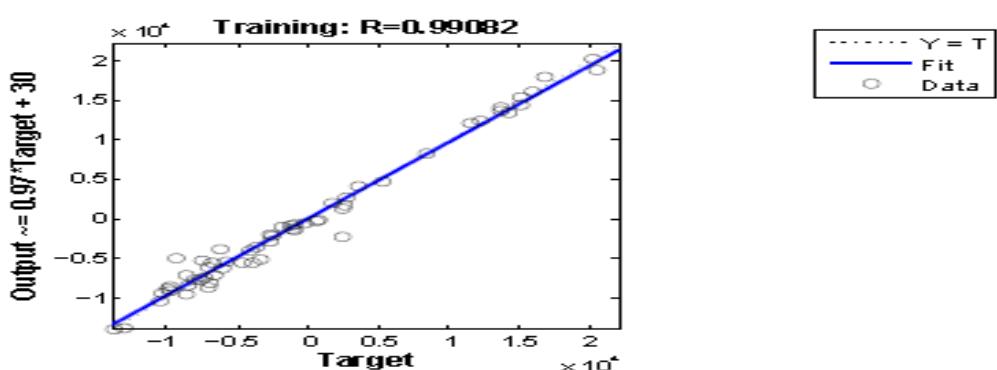
#### جدول ۴. مدل‌های بهینه برای پیش‌بینی سطوح مختلف

##### تجزیه شده

سطح تجزیه شده	الگوی رفتاری	نوع مدل پیش‌بینی	ویژگی‌های مدل
سطح تقریب (رونده‌سری)	خطی	ARIMA	ARIMA(5,2,3)
سطح اول (چرخه‌های با بسامد بالا)	تقارن چرخه‌ای	ARIMA	ARIMA(3,0,3)
سطح دوم	تقارن چرخه‌ای در سرعت تغییرات	ARIMA	ARIMA(4,0,3)
سطح سوم (چرخه‌های با بسامد پایین)	عدم تقارن چرخه‌ای	شبکه عصبی (NARNET)	تعداد وقهه تاخیری: ۶ تعداد لایه پنهان: ۱۵

منبع: محاسبات تحقیق

مدل شبکه عصبی برای پیش‌بینی سطح سوم توابع جزئیات، همان مدل گفته شده برای پیش‌بینی



نمودار ۶. بهره‌وری شبکه آموزش داده شده مجموع توابع جزئیات

منبع: محاسبات تحقیق

جدول ۵. پیش‌بینی سطح تقریب و مجموع توابع جزئیات تولید ناخالص داخلی

RMSE	MAE	مقدار واقعی (میلیارد ریال)	مقدار پیش‌بینی نهایی	پیش‌بینی سطح سوم با مدل شبکه عصبي	پیش‌بینی سطح با مدل ARIMA	پیش‌بینی سطح دوم با مدل ARIMA	پیش‌بینی سطح اول با مدل ARIMA	پیش‌بینی سطح تقریب با مدل ARIMA	مدل تلفيقی پیش‌بینی
870.9	870.9	121489	122360	361.1278	593.4718	-9665.42	131070.8	یک گام به جلو	
981.3	975.7	124232	125312.5	-1013.03	442.8285	-7332.18	133214.9	دو گام به جلو	
1601.4	1451	153058	150656.4	-1704.09	536.3839	17183.85	134640.3	سه گام به جلو	
1619.7	1506.6	135611	137284.5	-4021.93	5253.157	-1189.01	137242.3	چهار گام به جلو	
1454.9	1265.1	129273	128973.6	-5574.07	-126.268	-3383.83	138057.8	پنج گام به جلو	

منبع: محاسبات تحقیق

دسترسی پیدا کرده و در نتیجه الگوی رفتاری سری زمانی را مشخص نمود. همانطور که از نتایج تحقیق پیداست در پیش‌بینی یک گام، مدل شبکه عصبی بهینه بوده است (دارای کمترین RMSE و MAE می‌باشد). در پیش‌بینی دو گام مدل ARIMA و از پیش‌بینی سه گام تا پنج گام به جلو مدل تلفیقی پیشنهادی عملکرد بهتری داشته است. به نظر می‌رسد که استفاده از روش‌هایی که شبکه عصبی را با تبدیل موجک ترکیب می‌سازد، روشی مناسب برای پیش‌بینی تولید ناخالص داخلی است. به نظر می‌رسد علت احتمالی بهینه نبودن مدل پیشنهادی در گام‌های اول و دوم نسبت به مدل‌های رقیب، نوع موجک به کار رفته در تبدیل، نوع فیلترها و یا مناسب نبودن نوع آموزش سری‌های مولفه باشد. چرا که این پارامترها می‌توانند تاثیرات بسزایی روی عملکرد مدل داشته باشند. در کل به نظر می‌رسد پس از مدل پیشنهادی، به دلیل تقارن کلی سری زمانی تولید ناخالص داخلی، مدل‌های خطی می‌توانند عملکرد بهتری نسبت به شبکه‌های عصبی داشته باشند. در پایان پیشنهاد می‌شود محققین بعدی با استفاده از این مدل، ولی با موجک‌های دیگر و یا

با جمع جبری سری پیش‌بینی شده تقریب و سری‌های پیش‌بینی شده توابع جزئیات، تولید ناخالص داخلی پیش‌بینی شده با مدل تلفیقی بدست می‌آید. مقدار پیش‌بینی نهایی در جدول ۵ آورده شده و با شاخص RMSE و MAE ارزیابی شده‌اند.

#### ۴- نتیجه‌گیری و بحث

طبق جدول ذیل، مدل تلفیقی در پیش‌بینی‌های سه گام، چهار گام و پنج گام به جلو از مدل خطی و شبکه عصبی خودتوضیح غیرخطی کارایی بهتری داشته است. علت این امر آن است که سری تولید ناخالص داخلی در واقع حاصل فعالیت‌های اقتصادی در دوره‌های زمانی- مقیاسی متفاوتی است؛ چرا که حرکت ادوار تجاری، چیزی جز مجموع این مولفه‌های مجزا که در افق‌های زمانی متفاوت نمایان می‌شوند؛ نیست. هر کدام از این مولفه‌های مجزا که هم بسامد و هم مقیاس زمانی متفاوتی با هم دارند دارای رفتارهای متفاوت هستند که با یک مدل خطی یا غیر خطی خاصی نمی‌توان به خوبی الگوی رفتاری آنها را پیش‌بینی کرد. اما با ابزار موجک می‌توان به اطلاعات و لایه‌های پنهان سری زمانی

- \* صادقی، ح و ذوالفاری، م. (۱۳۹۰). مبانی مدل‌های پیش‌بینی در علوم اقتصادی، چاپ اول، انتشارات نور علم، تهران، ۲۴۸ ص.
- \* عباسی نژاد، ح و محمدی، ا. (۱۳۸۶). پیش‌بینی نرخ ارز با استفاده از شبکه‌های عصبی و تبدیل موجک. نامه اقتصادی ۶۰، ش. ۱، (۱۳۸۶)، ۱۹-۶۲.
- \* قدیمی، م. و مشیری، س.، (۱۳۸۱)، مدل سازی و پیش‌بینی رشد اقتصادی در ایران با استفاده از شبکه‌های عصبی مصنوعی (ANN)، پژوهش‌های اقتصادی ایران، شماره ۱۲ گجراتی، د. (۱۳۸۶)، مبانی اقتصادسنجی، ترجمه: حمید ابریشمی، تهران: انتشارات دانشگاه تهران.
- \* مشیری، س. پاکیزه، ک. دیبریان، م و جعفری، ا. (۱۳۸۹)، بررسی رابطه میان بازدهی سهام و تورم با استفاده از تجزیه و تحلیل موجک در بورس اوراق بهادار تهران، فصلنامه پژوهش‌های اقتصادی ایران، ش. ۴۲، ۷۴-۵۵.
- \* منهاج، م (۱۳۷۹). مبانی شبکه‌های عصبی مصنوعی. انتشارات دانشگاه صنعتی امیر کبیر، ص. ۷۱۵.
- \* نوروشیس، م (۱۳۸۸)، شبکه‌های عصبی در SPSS، ترجمه: امیر رضا فتی پورجلیلیان، مازیار نجبا، تهران: انتشارات کیان رایانه سبز.
- \* هیمانس، س.، (۱۳۹۰) پیش‌بینی و مدل‌های اقتصاد سنجی، مترجمان: صادق الحسینی، م. رنجبر م.، دنیای اقتصاد.
- \* Angelini, E., Camba-Mendez, G., Giannone, D., Reichlin, L., Rünstler, G., (2011), "Short-term forecasts of euro area GDP growth.", The Econometrics Journal. Vol 14 Issue 1.
- \* Costanzo S., Trigo L., Jimenez L. and Gonzalez J., (2007) "A Neural Network Model of the Venezuelan Economy" Audio, Transactions of the IRE Professional Group on.

با شبکه‌های مختلف عصبی به پیش‌بینی تولید ناخالص داخلی پرداخته و آن را با دیگر مدل‌های پیش‌بینی مقایسه کنند تا بتوان به یک مدل بهینه در این زمینه رسید.

#### جدول ۶. مقایسه مدل‌هادر گام‌های مختلف پیش‌بینی بر اساس شاخصهای RMSE و MAE

مدل پیش‌بینی	مدل سوم	مدل دوم	مدل اول	مدل
یک گام به جلو	مدل شبکه عصبی	مدل پیشنهادی	شبکه عصبی	ARIMA مدل
دو گام به جلو	مدل ARIMA	مدل پیشنهادی	مدل شبکه عصبی	مدل شبکه عصبی
سه گام به جلو	مدل پیشنهادی	مدل شبکه عصبی	مدل ARIMA	مدل شبکه عصبی
چهار گام به جلو	مدل پیشنهادی	مدل شبکه عصبی	مدل ARIMA	مدل شبکه عصبی
پنج گام به جلو	مدل شبکه عصبی	مدل ARIMA	مدل پیشنهادی	مدل شبکه عصبی

منبع: محاسبات تحقیق

#### فهرست منابع

- \* ابریشمی، ح.، مهرآرا، م.، احراری، م.، میرقاسمی، س.، (۱۳۸۸)، الگوسازی و پیش‌بینی رشد اقتصادی ایران با رویکرد شبکه عصبی GMDH، تحقیقات اقتصادی پاییز ۱۳۸۸؛ (۴۴) ۸۸.
- \* البرزی، (۱۳۸۰) آشنایی با شبکه‌های عصبی مصنوعی. انتشارات دانشگاه صنعتی شریف.
- \* درگاهی ح، و قدیری، ا. (۱۳۸۲)، تجزیه و تحلیل عوامل رشد اقتصادی ایران، فصل نامه پژوهش‌های بازارگانی، شماره ۲۶.

یادداشت‌ها

1. Costanzo et al.
2. Angelini et al.
3. Bridging With Factors
4. Kalman filter
5. Kock & Terasvirta.
6. Gu et al.
7. Gao et al.
8. Generalized lasso granger method
9. Group Method of Data Handling.
10. Neural Networks
11. Biological Neural Networks
12. Recurrent
13. Wavelet Analysis
14. Haar
15. Daubechie
16. Symlet
17. Coiflet
18. Meyer
19. Gaussian
20. Morlet
21. Shannon
22. Daughter Wavelet
23. Fourier Analysis.<sup>23</sup>
24. Gujarati
25. Auto Correlation Function
26. Partial Auto Correlation Function
27. Schwarz Basian Criteria.
28. Akaike Info Criteria
29. Hannan Quinn Criteria
30. Nonlinear Autoregressive Neural Network
31. Levenberg-Marquardt
32. sigmoid activation function
33. Linear activation function
34. Closed Loop
35. Ramsey And Lampart
- \* Gao, Zh., Yang, J. Tan, Sh., (2013), Forecasting Chinese GDP with Mixed Frequency Data Set: A Generalized Lasso Granger Method., Advances in Swarm Intelligence Lecture Notes in Computer Science Volume 7929, 2013, pp 163-172 .
- \* Gu, P., Wang, X., Chen, Y., (2012), Research on GDP forecast and its relationship with energy consumption., Advances in Applied Economics and Finance, Vol 4. No.1
- \* Kock, A. B., Teräsvirta, T.,(2011), Forecasting Macroeconomic Variables using Neural Network Models and Three Automated Model Selection Techniques., CReATES Research Paper 2011-27
- \* Ramsey, J. B., and Lampart. C. The Decomposition of Economic Relationships by Time Scale Using Wavelets: Money and Income , Macroeconomic Dynamics. 1998, 2. 49-71