

## الگوسازی و پیش‌بینی رشد اقتصادی ایران با رویکرد شبکه عصبی GMDH

حمید ابریشمی

استاد دانشکده اقتصاد دانشگاه تهران [abrihami@ut.ac.ir](mailto:abrihami@ut.ac.ir)

محسن مهرآرا

دانشیار دانشکده اقتصاد دانشگاه تهران [mmehrara@ut.ac.ir](mailto:mmehrara@ut.ac.ir)

مهدی احراری

پژوهشگر اقتصادی [meahrari@yahoo.com](mailto:meahrari@yahoo.com)

سوده میرقاسمی

کارشناس ارشد اقتصاد دانشکده اقتصاد دانشگاه تهران [Soudeh\\_mirghasemi@yahoo.com](mailto:Soudeh_mirghasemi@yahoo.com)

تاریخ دریافت: ۸۷/۱/۲۶ تاریخ پذیرش: ۸۸/۷/۷

### چکیده

در این مقاله از شبکه عصبی GMDH، به‌عنوان ابزاری با قابلیت بالا در مسیریابی و تشخیص روندهای غیرخطی پیچیده، به‌ویژه با تعداد مشاهدات محدود، برای الگوسازی و پیش‌بینی رشد تولید ناخالص داخلی به قیمت ثابت در ایران استفاده شده است. ابتدا الگویی بنیادی شامل ۷ متغیر همراه با وقفه اول رشد تولید ناخالص داخلی طراحی و سپس با استفاده از فرآیند قیاسی و نیز کنارگذاشتن هر متغیر از الگوی بنیادی، در مجموع ۱۸ مدل اجرا شد. نتایج نشان داد الگوهای حاصل از کنارگذاشتن رشد صادرات کل، رشد صادرات نفت و رشد حجم تجارت از الگوی بنیادی، به ترتیب بیش‌ترین سهم را در کاهش خطای پیش‌بینی دارا هستند. هم‌چنین اثر مضاعف رشد هزینه‌های دولت بر متغیر هدف، مؤید نتایج مطالعات اخیر در کشورهای در حال توسعه نفتی است. برتری شبکه عصبی GMDH در دقت پیش‌بینی رشد اقتصادی نسبت به روش ARIMA، بر اساس معیارهای خطا نیز مورد تأیید قرار گرفت.

طبقه‌بندی JEL : C22, C45, C53, O41

کلید واژه: شبکه عصبی GMDH، رشد تولید ناخالص داخلی، پیش‌بینی، فرآیند قیاسی.

## ۱- مقدمه

یکی از مهم‌ترین ابزارهای آماری در فرآیند برنامه‌ریزی و سیاست‌گذاری‌های اقتصادی، داده‌های حساب‌های ملی است. تهیه آمارهای حساب‌های ملی به‌صورت تفصیلی برای یک دوره یک‌ساله نیازمند زمان و هزینه بسیار است و طبیعی است که تأخیر در انتشار نتایج آن، عملاً استفاده به‌هنگام از این ابزارها را برای برنامه‌ریزان و سیاست‌گذاران اقتصادی غیرممکن می‌کند. از این رو در بیش‌تر کشورها متخصصان به پیش‌بینی متغیرهای عمده اقتصادی در کوتاه‌مدت (ماهانه، فصلی و سالانه) اقدام می‌کنند، که در این میان رشد تولید ناخالص داخلی از مهم‌ترین شاخص‌های اقتصادی مورد توجه آن‌هاست.

در این تحقیق ضمن مرور اجمالی بر شناخته‌شده‌ترین تئوری‌های اقتصادی، با استفاده از شبکه عصبی GMDH<sup>۱</sup>، که یکی از انواع جدید مدل‌های شبکه‌های عصبی است، رشد تولید ناخالص داخلی (به قیمت ثابت) ایران را الگوسازی و پیش‌بینی می‌کنیم. الگوریتم GMDH، قابلیت استفاده در موضوعات متنوعی چون کشف روابط، پیش‌بینی، مدل‌سازی سیستم‌ها، بهینه‌سازی و شناخت الگوهای غیرخطی را داراست. نکته حائز اهمیت در این الگوریتم استنتاجی، قابلیت شناسایی و غربال کردن متغیرهای کم‌اثر ورودی در دوره آموزش شبکه و حذف آن‌ها از روند شبیه‌سازی در دوره آزمون است. بدین ترتیب می‌توان با انجام یک فرآیند قیاسی<sup>۲</sup>، در چند مرحله تکرار، متغیرهای کم‌اثرتر را حذف کرد و در نهایت مدل بهینه برای پیش‌بینی رشد اقتصادی ایران را بر اساس معیارهای متداول خطا نظیر RMSE و MAPE و ... را به‌دست آورد. به علاوه، این الگوریتم قادر به شناسایی و رتبه‌بندی تأثیرگذارترین متغیرها نیز می‌باشد. لذا در این تحقیق، یک مدل بنیادی با ۸ متغیر، برای الگوسازی و پیش‌بینی در نظر گرفته شد و سپس با انجام شبیه‌سازی‌های متعدد، الگوی بهینه پیش‌بینی رشد اقتصادی ایران به‌دست آمد. هم‌چنین نتایج به‌دست آمده حاکی از برتری معنی‌دار الگوریتم GMDH در مقایسه با الگوی رگرسیونی ARIMA در کاهش خطای پیش‌بینی است.

در بخش ۲، مروری بر کارهای انجام گرفته در این زمینه خواهیم داشت. در بخش ۳، شبکه عصبی GMDH شرح داده می‌شود. در بخش ۴، نتایج حاصل از الگوسازی و

---

1 - Group Method of Data Handling.

2 - Deductive.

پیش‌بینی رشد تولید ناخالص داخلی ارائه شده است و بخش ۵ که در برگرفته نتیجه‌گیری است، پایان بخش مقاله خواهد بود.

## ۲- پیشینه تحقیقات

در مطالعات تجربی متغیرهای متنوعی برای توضیح رشد اقتصادی در نظر گرفته شده‌اند که بیش‌تر آن‌ها با میزان بازبودن اقتصاد، نقش دولت در اقتصاد و شرایط سیاسی و اجتماعی کشورها مرتبطند. هدف از این بخش، شناسایی عوامل مؤثر بر رشد، به ویژه در کشورهای مشابه با ایران است. بدین منظور ابتدا به بررسی مطالعات اخیر انجام گرفته بر روی چندین کشور در حال توسعه پردازیم و سپس مروری بر مطالعات اخیر درباره کشور ایران خواهیم داشت.

### ۲-۱- مطالعات تجربی بر رشد اقتصادی چند کشور در حال توسعه

کستانزو و همکاران<sup>۱</sup> (۲۰۰۴)، با استفاده از یک نگرش غیرخطی به پیش‌بینی رشد تولید ناخالص داخلی در ونزوئلا پرداخته و از یک مدل شبکه‌ی عصبی برای پیش‌بینی شاخص ماهیانه استفاده کرده‌اند. ساختار شبکه‌ی 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 را که نشان‌دهنده سطح فعالیت‌های اقتصادی هستند، انتخاب کرده است. از آن‌جایی که برخی از این شاخص‌ها تنها در طول مدت یک سال معنی‌دار هستند، لذا آن‌ها در تخمین شاخص ماهیانه در نظر گرفته نشده‌اند.

عوامل مؤثر بر رشد اقتصادی به عنوان ورودی‌های شبکه، در این تحقیق عبارت‌اند از: مصرف انرژی بر حسب گیگاوات ساعت، شاخص سهام کاراکاس، نرخ وام، نفت خام سفید، شاخص قیمتی مصرف‌کننده، شاخص S&P 500، T-bill<sup>۲</sup> اوراق قرضه کوتاه مدت ۹۰ روزه، قیمت طلا، قیمت مس، نرخ برابری دلار در برابر یورو، شاخص کالا و خدمات و شاخص داو جونز (DW).

در مطالعه‌ای که توسط سازمان ملل در سال ۲۰۰۵ میلادی انجام گرفته، وضعیت رشد اقتصادی کشورهای غرب آسیا و عوامل مؤثر بر آن، به ویژه دو عامل سرمایه‌گذاری

1 - Costanzo et al.

2 - Treasury Bill.

و مخارج دولتی بررسی شده اند. در این مطالعه از یک مدل سری زمانی PVAR<sup>۱</sup> برای پیش‌بینی و تعیین مشارکت چهار عامل سرمایه‌گذاری، هزینه‌های دولتی، درآمد نفتی و صادرات بر GDP در کشورهای آسیای غربی استفاده شده است و هزینه دولتی بهینه برای رسیدن به نرخ رشد بهینه نیز پیش‌بینی شده است. متغیرهای وابسته عبارت از تغییرات GDP حقیقی ( $\Delta y_{i,t}$ )، تغییرات درآمد نفتی ( $\Delta OR_{i,t}$ )، تغییرات نسبت هزینه‌های دولت به GDP حقیقی ( $\Delta(G_{i,t}/Y_{i,t})$ ) و تغییرات نسبت سرمایه‌گذاری به GDP حقیقی ( $\Delta(I_{i,t}/Y_{i,t})$ ) هستند. نتایج نشان داد که درآمد نفتی و نسبت هزینه‌های دولتی به GDP اثر قابل توجهی بر رشد اقتصادی حقیقی دارند، اما در مقابل، نسبت صادرات با وقفه به GDP و همچنین نسبت سرمایه‌گذاری به GDP چندان بر نرخ رشد فعلی مؤثر نیستند.

## ۲-۲ - مطالعات تجربی در زمینه عوامل مؤثر بر رشد اقتصادی ایران

مروری بر مطالعات رشد اقتصادی ایران، حاکی از طیف گسترده‌ای از مطالعات انجام‌شده در دوره‌های زمانی مختلف و با روش‌های متفاوت است. در این بخش به بررسی اجمالی چند نمونه از مطالعات اخیر انجام‌گرفته در این زمینه می‌پردازیم. در مطالعه قدیمی و مشیری (۱۳۸۱)، 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 ۱۳۱۵-۱۳۷۳ 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 ۱۳۷۴-۱۳۸۰ مقایسه شده است. نتایج نشان داد 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 بیش‌تر متغیرهای تأثیرگذار بر رشد حضور داشته باشند و ثانیاً، این مطالعات به نوعی دربرگیرنده الگوهای رشد درون‌زا باشند. این مطالعات در دو گروه عمده جای گرفته‌اند. نخست، مطالعاتی که در آنها از داده‌ها و اطلاعات چند کشور

1 - Panel Vector Auto Regression.

استفاده شده است و دوم مطالعاتی که به‌منظور بررسی شرایط رشد اقتصادی یک کشور خاص انجام گرفته‌اند. نتایج مطالعات آن‌ها نشان می‌دهد که رشد اقتصادی متأثر از عوامل متعددی است که نظریات رشد تنها بخشی از آن‌ها را بیان کرده‌اند. لذا بعضی از متغیرهای کلان اقتصادی به‌طور تجربی به مدل‌های ساده‌ی اضافه شده و سبب توضیح بهتر رشد اقتصادی شده‌اند. سپس با بررسی پویایی تولید ناخالص داخلی ایران و بهره‌گیری از روش هم‌گرایی خودبازگشتی با وقفه‌های توزیعی به بررسی عوامل تعیین‌کننده رشد در اقتصاد ایران پرداخته شده است. در راستای شناسایی عوامل رشد در ساختار گذشته اقتصاد ایران، در این مقاله از دو الگو استفاده شده است. الگوی نخست الگویی است که به‌وسیله آن نقش عوامل اولیه‌ای چون سیاست‌های پولی، مالی و درآمدهای ارزی نفت بررسی می‌شود. حال آن‌که در الگوی دوم، نقش متغیرهای درون‌زا نظیر سرمایه‌انسانی، تحقیق و توسعه و بهره‌وری مورد بررسی قرار می‌گیرد. نتایج به‌دست آمده از این تحقیق حاکی از آن است که مخارج دولت و درآمدهای ارزی نفت، به‌عنوان تنها عامل مؤثر و توضیح‌دهنده رشد اقتصادی ایران مطرحند و متغیرهای مؤثر بر سرمایه‌انسانی مورد بحث در الگوهای رشد درون‌زا چون آموزش، تحقیق و توسعه و بهره‌وری تأثیر چندانی بر رشد اقتصادی ایران ندارند. لذا در این مقاله نتیجه گرفته می‌شود که تداوم چنین ساختاری امکان تحقق رشد اقتصادی پایدار و بالا را فراهم نکرده و ادوار تجاری اقتصاد ایران را تحت تأثیر شوک‌های داخلی سیاست‌های مالی دولت و شوک‌های خارجی ارز حاصل از صادرات نفت شکل می‌دهد. بنابراین، عوامل تعیین‌کننده رشد در اقتصاد ایران به علت ماهیت درون‌زا بودن و به دلیل ایجاد نوسانات کوتاه‌مدت در تولید، موجب عدم رشد بالای بلندمدت می‌شوند.

جهانگرد (۱۳۸۳)، برای الگوسازی رشد از روش VAR و VECM استفاده کرده است. علت استفاده از این روش‌ها فائق‌آمدن بر مشکلاتی هم‌چون مشکلات آماری، هم‌زمانی ناپیوستایی و هم‌چنین پیش‌بینی برای آینده است. در برآورد الگو علاوه بر متغیرهای نیروی کار شاغل و موجودی واقعی سرمایه، از مخارج واقعی دولت و دو متغیر مجازی دوران جنگ DW و دوران انقلاب DR نیز استفاده شده است. نتایج تخمین رابطه بلندمدت نشان می‌دهد که ضریب متغیر سرمایه، ۲۳٪ و ضریب عامل نیروی کار ۲۴٪ است. این موضوع با توجه به این‌که دامنه برآورد بیش‌تر مطالعات ارائه‌شده در ایران در مورد عامل نیروی کار بین ۴۷٪ تا ۸۲٪ و در خصوص عامل سرمایه بین ۲۰٪ تا ۵۲٪ برآورد شده، نشان‌دهنده عدم تغییر ساختاری و معنی‌داری عوامل در اقتصاد ایران

است. تأثیر مخارج مصرفی دولت نیز در این الگو، مثبت و معادل ۰.۳۱٪ است. بر اساس نتایج، پیش‌بینی الگو، متوسط رشد سالانه در طول برنامه چهارم توسعه را معادل ۰.۶۳٪ تخمین می‌زند. هم‌چنین، نتایج نشان می‌دهد که روند رشد اقتصادی در سال‌های اخیر هم‌چنان ادامه می‌یابد، ولی در سال‌های ۱۳۸۴ و ۱۳۸۸ این رشد کمی افت خواهد داشت. با توجه به این که در برنامه چهارم توسعه، پیش‌بینی رشد ۰.۸٪ به‌عنوان هدف برنامه مدنظر گرفته است، الگوی مذکور نشان می‌دهد در صورت عدم اصلاح ساختار اقتصادی و روابط و اصلاح ساختار عوامل موجود، این رشد محقق نخواهد شد که به‌دنبال آن سایر اهداف کمی و کیفی برنامه همانند ایجاد حدود ۹۰۰ هزار فرصت شغلی سالانه و دیگر اهداف نیز تحقق نمی‌یابد. بنابراین براساس نتیجه‌گیری این تحقیق، برای دستیابی به اهداف برنامه، به اصطلاحات متنوع اقتصادی در رویکردها و ساختارهای اقتصادی کشور نیاز است.

به تازگی کاربرد روش‌های غیرخطی در برآورد و پیش‌بینی مدل‌های اقتصادی، فزونی یافته است. مشیری و قدیمی (۲۰۰۴)، بر اساس این نظر، در مقاله خود به پیش‌بینی رشد اقتصادی در ایران با استفاده از تلفیق شبکه‌های عصبی مصنوعی با الگوریتم ژنتیک پرداخته و نتایج آن را با روش شبکه‌های عصبی مصنوعی مبتنی بر الگوریتم‌های یادگیری پیش‌خور و گرادیان نزولی و... و هم‌چنین مدل‌های اقتصادسنجی سری زمانی، شامل VAR, ARMA بر اساس معیارهای خطا مقایسه کرده‌اند. نتایج نشان داد که به‌کارگیری الگوریتم ژنتیک در فرآیند یادگیری شبکه عصبی مصنوعی، از عملکرد خطای پیش‌بینی بهتری نسبت به سایر روش‌های مورد بررسی در تحقیق برخوردار بوده است.


تقوی و محمدی (۱۳۸۵)، تأثیر سرمایه انسانی بر رشد اقتصادی در ایران را مورد بررسی قرار داده‌اند. در این مطالعه با استفاده از آمارهای مربوط به دوره ۸۱-۱۳۳۸، به بررسی تأثیر رشد شاخص‌های معرف سرمایه انسانی بر رشد اقتصادی در ایران پرداخته و این نتیجه حاصل شده که رشد سطح سواد در بزرگسالان و نیز رشد متوسط سال‌های تحصیل نیروی کار، تأثیر مثبت و معناداری روی رشد تولید ناخالص داخلی داشته است. حسینی و مولایی (۱۳۸۵)، تأثیر سرمایه‌گذاری مستقیم خارجی بر رشد اقتصادی در ایران را مورد بررسی قرار داده‌اند. هدف از این مطالعه بررسی اثر سرمایه‌گذاری مستقیم خارجی (FDI) روی رشد اقتصادی است. در این راستا، با استفاده از داده‌های سری زمانی برای سال‌های ۸۱-۱۳۵۷، سه الگوی اقتصادسنجی برآورد شده است. با توجه به

متغیرهای سرمایه‌گذاری مستقیم خارجی، سرمایه‌گذاری داخلی، سرمایه‌انسانی و درصد باز بودن اقتصاد، یک الگوی اقتصادسنجی پایه، تدوین و در الگوی دوم به ترتیب اثر توأم سرمایه‌گذاری مستقیم خارجی با سرمایه‌گذاری داخلی، سرمایه‌انسانی و تجارت خارجی و در الگوی سوم اثر تورم، مالیات و مخارج دولت، به‌عنوان شاخص‌هایی از ساختار اقتصادی بررسی شده است. نتایج این الگوها بیان‌گر تأثیر مثبت سرمایه‌گذاری مستقیم خارجی بر روی رشد اقتصادی است و نشان می‌دهد که سرمایه‌انسانی اثر آن را نیز تقویت می‌کند. از سوی دیگر، افزایش نرخ تورم، مالیات و مخارج دولتی بر رشد اقتصادی در ایران آثاری منفی دارند.

جعفری صمیمی و همکاران (۲۰۰۷) در تحقیق خود، مقایسه‌ای بین سه روش سری‌های زمانی، هموارسازی نمایی<sup>۱</sup> و شبکه‌های عصبی برای پیش‌بینی رشد اقتصادی در ایران انجام داده‌اند. در این تحقیق از داده‌های فصلی سال‌های ۱۹۹۸-۲۰۰۳، برای الگوسازی و سال‌های ۲۰۰۴-۲۰۰۵، برای پیش‌بینی درون نمونه‌ای با سه روش مذکور استفاده کرده‌اند. نتایج پیش‌بینی‌های هر روش با مقادیر واقعی، بر اساس معیار خطای اندازه‌گیری، محاسبه و در نهایت با هم مقایسه شده‌اند. نتیجه آن که شبکه عصبی به نسبت دو روش دیگر از عملکرد بهتری در پیش‌بینی برخوردار بوده است.

### ۳- شبکه‌های عصبی از نوع GMDH

شبکه GMDH، شبکه‌ای خود سازمانده و یک سوپه است که از چندین لایه و هر لایه نیز از چندین نرون تشکیل یافته است (ابواخنکو<sup>۲</sup> ۱۹۶۸ و ۱۹۹۵). تمامی نرون‌ها از ساختار مشابهی برخوردارند، به طوری که دارای دو ورودی و یک خروجی هستند و هر نرون با ۵ وزن و یک بایاس، عمل پردازش را میان داده‌های ورودی و خروجی را بر اساس شکل زیر و رابطه (۱) برقرار می‌کند:



1 - Exponential Smoothing.

2 - Ivakhnenko.

$$y_{ik}^* = N(x_{i\alpha}, x_{i\beta}) = b^k + w_1^k x_{i\alpha} + w_2^k x_{i\beta} + w_3^k x_{i\alpha}^2 + w_4^k x_{i\beta}^2 + w_5^k x_{i\alpha} x_{i\beta} \quad (1)$$

$$i = 1, 2, 3, \dots, N$$

که در آن  $N$  داده‌های ورودی و خروجی و  $(K = 1, 2, 3, \dots, C_m^2)$  و  $\alpha, \beta \in \{1, 2, 3, \dots, m\}$  است، که در آن‌ها  $m$  تعداد نرون‌های لایه قبلی است.

وزن‌ها بر اساس روش‌های کم‌ترین مربعات خطا محاسبه شده و سپس به‌عنوان مقادیر مشخص و ثابت در داخل هر نرون جای‌گذاری می‌شوند. ویژگی بارز این شبکه آن است که نرون‌های مرحله قبلی و یا لایه قبلی، عامل و مولد تولید نرون‌های جدید به

تعداد  $C_m^2 = \frac{m(m-1)}{2}$  هستند و از میان نرون‌های تولید شده، لزوماً تعدادی از آن‌ها

حذف شده‌اند تا بدین وسیله از واگرایی شبکه جلوگیری شود.

نرون‌هایی که برای ادامه و گسترش شبکه باقی می‌مانند، امکان دارد برای ایجاد فرم هم‌گرایی شبکه و عدم ارتباط آن‌ها با نرون لایه آخر حذف شوند که در اصطلاح به آن‌ها نرون غیرفعال می‌گویند. معیار گزینش و حذف مجموعه‌ای از نرون‌ها در یک لایه، نسبت مجموع مربعات خطا  $(r_j^2)$  بین مقادیر خروجی واقعی  $(y_i)$  و خروجی نرون  $(y_{ij}^*)$  به‌صورت رابطه (۲) است.

$$r_j^2 = \frac{\sum_{i=1}^N (y_i - y_{ij}^*)^2}{\sum_{i=1}^N y_i^2} \quad j \in \{1, 2, 3, \dots, C_m^2\}$$

که در آن  $m$ ، تعداد نرون‌های گزینش شده در لایه قبلی است.

ارتباطی که بین متغیرهای ورودی و خروجی توسط این نوع از شبکه‌های عصبی برقرار می‌شود به شکل تابع غیرخطی ولتر<sup>۱</sup> به صورت رابطه زیر است:

$$\hat{y} = a_0 + \sum_{i=1}^m a_i x_i + \sum_{i=1}^m \sum_{j=1}^m a_{ij} x_i x_j + \sum_{i=1}^m \sum_{j=1}^m \sum_{k=1}^m a_{ijk} x_i x_j x_k + \dots \quad (3)$$



ساختاری که برای نرون‌ها در نظر گرفته شده، به صورت فرم خلاصه شده دو متغیره درجه دوم نشان داده می‌شود:

$$y_i = f(x_{ip}, x_{iq}) = a_0 + a_1 x_{ip} + a_2 x_{iq} + a_3 x_{ip} x_{iq} + a_4 x_{ip}^2 + a_5 x_{iq}^2 \quad (4)$$

تابع  $f$  دارای شش ضریب مجهول است، که به ازای تمام زوج‌های دو متغیر وابسته به سیستم  $\{(x_{ip}, x_{iq}), i = 1, 2, \dots, N\}$ ، خروجی مطلوب  $\{(y_i), i = 1, 2, \dots, N\}$  را برآورد می‌کند. حال عبارت زیر را براساس قاعده کم‌ترین مربعات خطا حداقل می‌کنیم:

$$\text{Min} \sum_{k=1}^N [(f(x_{ki}, x_{kj}) - y_i)^2] \quad (5)$$

براین اساس، دستگاه معادله‌ای را که دارای شش مجهول و  $N$  معادله است را حل می‌کنیم.

$$\begin{cases} a_0 + a_1 x_{1p} + a_2 x_{1q} + a_3 x_{1p} x_{1q} + a_4 x_{1p}^2 + a_5 x_{1q}^2 = y_1 \\ a_0 + a_1 x_{2p} + a_2 x_{2q} + a_3 x_{2p} x_{2q} + a_4 x_{2p}^2 + a_5 x_{2q}^2 = y_2 \\ \dots \\ a_0 + a_1 x_{Np} + a_2 x_{Nq} + a_3 x_{Np} x_{Nq} + a_4 x_{Np}^2 + a_5 x_{Nq}^2 = y_N \end{cases}$$

دستگاه معادله فوق را می‌توان به فرم ماتریسی زیر نمایش داد:

$$Aa = Y \quad (6)$$

که در آن:

$$a = \{a_0, a_1, a_2, a_3, a_4, a_5\}^T \quad (7)$$

$$y = \{y_1, y_2, y_3, \dots, y_N\} \quad (8)$$

$$A = \begin{bmatrix} 1 & x_{1p} & x_{1q} & x_{1p}x_{1q} & x_{1p}^2 & x_{1q}^2 \\ 1 & x_{2p} & x_{2q} & x_{2p}x_{2q} & x_{2p}^2 & x_{2q}^2 \\ \vdots & \vdots & \vdots & \ddots & \vdots & \vdots \\ 1 & x_{Np} & x_{Nq} & x_{Np}x_{Nq} & x_{Np}^2 & x_{Nq}^2 \end{bmatrix} \quad (9)$$

برای حل معادله لازم است که شبه معکوس ماتریس غیرمربع  $A$  محاسبه شود. روش‌های تکاملی<sup>۱</sup> مانند الگوریتم ژنتیک، کاربرد وسیعی در مراحل مختلف طراحی شبکه‌های عصبی (به دلیل قابلیت‌های منحصر به فرد خود در پیدا کردن مقادیر بهینه و امکان جستجو در فضاها غیرقابل پیش‌بینی)، دارند (نریمان زاده و همکاران ۲۰۰۲). در تحقیق حاضر، برای طراحی شکل شبکه عصبی و تعیین ضرایب آن، از الگوریتم ژنتیک استفاده شده است.

در سال‌های اخیر روش شناسی شبکه عصبی به‌عنوان رقیبی برای متدولوژی‌های سنتی آماری ظهور کرده است. ایده اصلی این روش عبارتست از طراحی یک مدل بهینه پیچیده که فقط مدل را بر پایه داده‌ها و اطلاعات طراحی کرده و هیچ‌گونه پیش‌زمینه نظری از نحوه عملکرد داده‌ها از سوی محقق انجام نگیرد و این کار تنها براساس کشف ارتباط ساده و پیچیده میان داده‌های ورودی و خروجی سیستم انجام پذیرد، بنابراین یک مدل خود تنظیم کننده خواهد ساخت که قابلیت حل مسائل پیش‌بینی، تشخیص، ترکیبات کنترلی و سایر مسائل سیستمی به کار برده شده را دارد. گزیده‌ای از مزایای شبکه‌های عصبی نسبت به روش‌های سنتی به شرح ذیل است:

۱- این رویکرد مدل‌سازی همراه با توانایی یادگیری از طریق تجربه، ابزاری مفید برای دستیابی به بسیاری از مسائل عملی است، چرا که بسیاری از اوقات داشتن داده‌ها بسیار راحت‌تر از داشتن حدسیات تئوریک خوب در زمینه قوانین مسلط بر مجموعه و یا سیستمی است که داده‌ها از آن استخراج می‌شوند.

۲- شبکه‌های عصبی قابلیت تعمیم دهی بسیار بالایی دارند. بعد از آن که توسط قسمتی از داده‌ها (یک نمونه) آموزش داده شوند، این شبکه‌ها بیش‌تر اوقات می‌توانند قسمت دیده نشده جامعه را حتی زمانی که نمونه دارای اطلاعات نویزی باشد، به خوبی حدس بزنند.

۳- شبکه‌های عصبی در مقایسه با روش‌های آماری سنتی، اشکال تابعی جامع‌تر و انعطاف پذیری بیش‌تری دارند. به علت پیچیدگی‌های سیستم‌های حقیقی، روش‌های آماری سنتی محدودیت‌های زیادی در تخمین این روابط دارند. در این میان شبکه‌های عصبی می‌توانند گزینه‌ای مناسب برای تخمین این روابط باشند.

1- Evolutionary.

۴- شبکه‌های عصبی، بر خلاف روش‌های اقتصادسنجی سری زمانی، دارای الگوهای غیرخطی‌اند. این در حالی است که بیش‌تر سری‌های زمانی حقیقی، غیرخطی هستند. ۵- قدرت رهگیری و مسیر یابی بالا و خطای کمینه پیش‌بینی متغیر هدف، یکی از ویژگی‌های برجسته شبکه‌های عصبی در مقایسه با سایر روش‌های سری زمانی است. اما در پایان باید به تفاوت عمده شبکه‌های عصبی و روش‌های متداول آماری در روش تحقیق آن‌ها اشاره کنیم. الگوهای اقتصادسنجی، فرضیات و سؤالات مبتنی بر مبانی نظری تحقیق را آزمون می‌کنند. به عبارت دیگر نظریه مورد آزمون به‌عنوان مدل اصلی، فرض شده و تنها به برآورد ضرایب و آزمون روابط نظری بر اساس تکنیک‌های آماری اقدام می‌شود. در روش شبکه‌ عصبی مدل‌سازی بر اساس نظریات و نظرات، طراحی و سپس بر اساس خروجی‌های شبکه، مدل نهایی استخراج می‌شود. نظریات اقتصادی و نظرات و دانش خبره، در قالب ورودی‌های شبکه وارد جریان مدل‌سازی غیرخطی پویا شده و نتایج به صورت مرحله‌ای (معادلات لایه‌های پنهان) و خروجی برآزش شده نهایی، تحت یک معادله غیرخطی، که با واقعیت رفتاری و ساختاری مقادیر خروجی، انطباق بیش‌تری دارد، مدل می‌شود.

#### ۴- نتایج و تحلیل محاسبات

با توجه به مباحث عنوان‌شده در بخش ۲، برای برآورد الگو از متغیرهای ارائه شده در جدول (۱) استفاده شده است. متغیرهای مذکور را به‌عنوان عوامل تعیین‌کننده رشد اقتصادی در قالب الگوهای مختلف مورد استفاده قرار داده و عملکرد پیش‌بینی آن‌ها را با یکدیگر مقایسه می‌کنیم.

پژوهشگاه علوم انسانی و مطالعات فرهنگی  
پرتال جامع علوم انسانی

جدول ۱- متغیرهای مؤثر بر رشد تولید ناخالص داخلی در یک الگوی بنیادی

ردیف	عنوان	علامت اختصاری
۱	نرخ رشد موجودی سرمایه به قیمت ثابت*	<i>CSf</i>
۲	وقفه اول نرخ رشد محصول ناخالص داخلی به قیمت ثابت*	<i>RGDP (-1)</i>
۳	نرخ رشد صادرات کل به قیمت ثابت*	<i>RX</i>
۴	نرخ رشد واردات کل به قیمت ثابت*	<i>RM</i>
۵	نرخ رشد درآمد نفت و گاز در بودجه عمومی	<i>Rloil</i>
۶	نرخ رشد هزینه‌های دولت***	<i>RTGE</i>
۷	رشد صادرات نفت	<i>RXoil</i>
۸	نرخ رشد حجم تجارت***	<i>RXM</i>

\* توضیح: سال پایه ۱۳۷۶ است.

\*\* توضیح: هزینه‌های دولت برابر هزینه‌های جاری و عمرانی است.

\*\*\* توضیح: حجم تجارت برابر با نسبت تجارت (واردات + صادرات) به GDP است.

برای سنجش میزان تأثیرگذاری متغیرهای مورد نظر در الگوهای مختلف، نرم‌افزار محاسباتی تحت نرم افزار MATLAB<sup>۱</sup>، با هدف کمینه‌کردن خطای مدل‌سازی و پیش‌بینی، طراحی شده است (آتشکاری و همکاران، ۲۰۰۷ و امانی فرد و همکاران، ۲۰۰۷). داده‌های مورد نیاز برای تخمین الگو، به صورت سالانه از داده‌های مرکز آمار ایران برای سال‌های ۸۵-۱۳۳۸ استخراج شده‌اند. در این تحقیق از دو روش برای مدل‌سازی و پیش‌بینی رشد اقتصادی در ایران با رویکرد شبکه عصبی GMDH به شرح زیر استفاده می‌کنیم:

#### ۴-۱- پیاده‌سازی فرآیند قیاسی در الگوی بنیادی

در این روش با توجه به قابلیت الگوریتم GMDH در غربال‌سازی و تشخیص روندهای غیرخطی، از یک فرآیند قیاسی (ایواخنکو، ۲۰۰۰) (a)، (b) و ابریشمی و همکاران، ۱۳۸۷)، بر اساس یک الگوی بنیادی متشکل از ۸ متغیر ورودی به شرح جدول (۱) استفاده می‌کنیم. نتایج حاصل از برازش متغیرهای الگوی بنیادی بر روی متغیر هدف توسط شبکه عصبی GMDH به شرح جدول (۲) است:

۱- رجوع کنید به سایت دانشگاه گیلان، دانشکده فنی، پژوهش، GEvoM.

جدول ۲- نتایج حاصل از خروجی شبکه‌ی عصبی GMDH برای الگوی بنیادی با ۸ متغیر ورودی

متغیرهای حذف‌شده	CSf, RGDP(-1)
متغیرهای با اثر مضاعف	RM, RTGE
<sup>۱</sup> RMSE	۰/۰۱۰۶
<sup>۲</sup> MAPE	۰/۰۲۷
درصد خطای پیش‌بینی	۱۰/۲
درصد دقت پیش‌بینی	۸۹/۸
ضریب نابرابری تایل	۰/۴۱

یکی از مهم‌ترین ویژگی‌های الگوریتم *GMDH*، توانایی شناسایی و حذف متغیرهای زاید است (فارلو<sup>۳</sup>، ۱۹۸۴، آناستاساکیس<sup>۴</sup>، ۲۰۰۱ و چن<sup>۵</sup>، ۲۰۰۶). بدین ترتیب متغیرهایی که در جریان مدل‌سازی اثر کم‌تری (یا بدون تأثیر) بر متغیر هدف داشته‌اند، از الگو حذف می‌شوند. نرخ رشد موجودی سرمایه به قیمت ثابت (*CSf*) و وقفه<sup>۱</sup> اول رشد تولید ناخالص داخلی به قیمت ثابت در فرآیند مدل‌سازی از الگو حذف شده و در مقابل واردات و هزینه‌های دولت، دارای اثر مضاعف<sup>۲</sup> بوده‌اند. ردیف‌های سوم تا هفتم جدول فوق، معیارهای اندازه‌گیری خطای پیش‌بینی در مرحله<sup>۶</sup> آزمون<sup>۷</sup> شبکه‌ی عصبی را مشخص کرده‌اند. مقادیر معیارهای خطا، نشان‌دهنده<sup>۸</sup> دقت بالا و صحت پیش‌بینی‌اند. همچنین، مقدار آماره<sup>۹</sup> تایل (کم‌تر از ۰/۵۵)، نشان‌دهنده<sup>۱۰</sup> صحت بالای مدل‌سازی توسط شبکه‌ی عصبی *GMDH* است. از آن جایی که تعداد زیادی از مشاهدات برای آموزش شبکه استفاده شده‌اند (۷۶-۱۳۳۸)، بنابراین بازه<sup>۱۱</sup> پیش‌بینی‌های درون نمونه‌ای (مرحله<sup>۱۲</sup> آزمون)، حد فاصل سال‌های ۸۶-۱۳۷۷ است. پیش‌بینی سال ۱۳۸۷ نیز به‌عنوان پیش‌بینی یک گام به جلوی خارج از نمونه برآورد شده است. نمودار(۱)، مقادیر واقعی و پیش‌بینی الگوی بنیادی را نشان می‌دهد.

1 -Root Mean Square Error.

2 -Mean Absolute Percentage Error.


3 -Farlow.

4 -Anastasakis.

5 - Chen.

۶- متغیرهای با اثر مضاعف، برای ورودی‌ها در ادبیات شبکه‌ی عصبی *GMDH* معنای متفاوتی با تحلیل‌های رگرسیونی دارند و به متغیرهایی که تعداد تکرار بیش‌تری نسبت به سایر متغیرها در خروجی برنامه<sup>۱۳</sup> شبکه داشته، یا بتوانند از یک لایه<sup>۱۴</sup> پنهان به لایه<sup>۱۵</sup> بالاتر پرش کنند، اطلاق می‌شوند.

7 - Test.



نمودار ۱- مقادیر واقعی و پیش‌بینی شده رشد تولید ناخالص داخلی برای الگوی بنیادی

در هر مرحله فرآیند قیاسی، از متغیرهای مؤثر شناخته‌شده در مرحله قبل به‌عنوان ورودی‌های شبکه عصبی استفاده می‌کنیم. بدین ترتیب، با کنار گذاشتن متغیر حذف‌شده از الگوی بنیادی، الگوی نهایی قیاسی شامل ۶ متغیر بوده، که به همراه نتایج حاصل از خروجی برنامه به شرح جدول (۳) است.

جدول ۳- نتایج حاصل از خروجی شبکه عصبی *GMDH* برای الگوی بنیادی - مرحله نهایی قیاسی

RTGE, RXoil, RXM, RX, RM, RIoil,	متغیرهای الگو
RX, RXM	متغیرهای حذف‌شده
RTGE, RM, RIoil,	متغیرهای با اثر مضاعف
۰/۰۰۳۵	RMSE
۰/۰۲۷	MAPE
۵/۴۷	درصد خطای پیش‌بینی
۹۴/۵۳	درصد دقت پیش‌بینی
۰/۲۲	ضریب نابرابری تایل

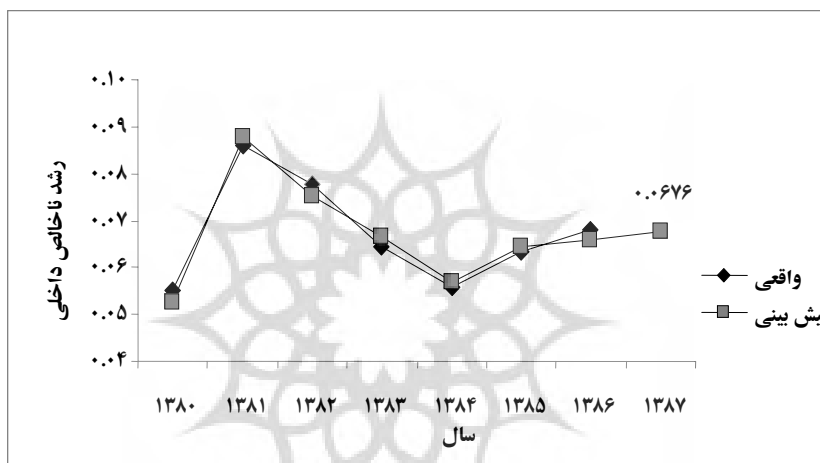
بدین ترتیب الگوی نهایی حاصل از فرآیند قیاسی شامل چهار متغیر به شرح رابطه

(۱) است:

$$RGDP = f(RTGE, RXoil, RM, RIoil) \quad (1)$$

ملاحظه می‌شود در الگوی بنیادی- نهایی متغیرهای مؤثر نهایی شامل نرخ رشد هزینه‌های دولت (RTGE)، رشد صادرات نفت (RXoil)، نرخ رشد واردات کل به قیمت ثابت (RM) و نرخ رشد درآمد نفت و گاز در بودجه (RIOil) است، که متغیرهای نرخ رشد هزینه‌های دولت، نرخ رشد واردات کل به قیمت ثابت و نرخ رشد درآمد نفت و گاز در بودجه از تأثیر بیش‌تری بر نرخ رشد تولید ناخالص داخلی، در این الگو برخوردار بوده‌اند.

نمودار (۲)، مقادیر واقعی و پیش‌بینی شده رشد تولید ناخالص داخلی را برای الگوی بنیادی- نهایی نشان می‌دهد.



نمودار ۲- مقادیر واقعی و پیش‌بینی شده رشد تولید ناخالص داخلی برای الگوی بنیادی- نهایی

جدول (۴)، الگوی بنیادی را با الگوی فرآیند قیاسی، بر اساس معیارهای خطا با یکدیگر مقایسه کرده است.

جدول ۴- مقایسه فرآیند قیاسی الگوی بنیادی بر مبنای معیارهای خطا

مرحله	RMSE	MAPE	درصد خطای پیش‌بینی	TIC
الگوی بنیادی	0/0106	0/0993	10/2	0/48
نهایی	0/0035	0/0494	5/4	0/21

مشاهده می‌شود که معیارهای خطا در فرآیند قیاسی کاهش یافته‌اند، به طوری که خطای مرحله نهایی نسبت به الگوی بنیادی، 94/7٪ کاهش داشته است. مقدار عددی

آماره آزمون مربوط به نسبت RMSE، در الگوهای مرحله اول و نهایی برابر  $F(10,10) = 3/03$  است که بزرگتر از مقدار بحرانی جدول  $F_{0.5}(10,10) = 2/98$  می باشد. لذا تفاوت معنی داری بین الگوی بنیادی و مرحله نهایی وجود داشته و بنابراین الگوی نهایی از نقطه نظر آماری نیز نسبت به الگوی بنیادی بهتر است.

#### ۴-۲- اثر کنارگذاشتن هر متغیر از مدل بنیادی و بررسی الگوهای حاصل

در این قسمت تأثیر کنارگذاشتن هر متغیر از الگوی بنیادی را با استفاده از معیارهای خطا، ارزیابی و رتبه بندی می کنیم. جدول (۵)، نتایج حاصل از الگوهای ۸ گانه که با کنارگذاشتن هر متغیر از الگوی بنیادی به دست آمده را بر اساس معیار ریشه میانگین مربع خطای پیش بینی (RMSE) رتبه بندی کرده است.

جدول ۵- رتبه بندی الگوهای ۸ گانه حاصل از کنارگذاشتن هر متغیر از الگوی بنیادی بر اساس معیار خطا

رتبه	متغیر حذف شده	RSME	MAPE	TIC	درصد خطای پیش بینی	آماره F
۱	نرخ رشد صادرات کل به قیمت ثابت	۰/۰۰۲۴	۰/۰۳	۰/۱۴	۳/۵	۴/۴۲
۲	رشد صادرات نفت	۰/۰۰۲۶	۰/۰۳۲	۰/۱۵	۳/۹	۴/۰۸
۳	نرخ رشد حجم تجارت	۰/۰۰۳	۰/۰۴	۰/۱۸	۴/۵	۳/۵۳
۴	نرخ رشد درآمد نفت و گاز در بودجه عمومی	۰/۰۰۴۶	۰/۰۶۱	۰/۲۷	۶/۹	۲/۳۰
۵	نرخ رشد واردات کل به قیمت ثابت	۰/۰۰۵۵	۰/۰۶۵	۰/۳۲	۷/۴	۱/۹۳
۶	نرخ رشد موجودی سرمایه به قیمت ثابت	۰/۰۰۶۱	۰/۰۸۶	۰/۳۶	۷/۹	۱/۷۴
۷	وقفه اول GDP به قیمت ثابت	۰/۰۰۶۶	۰/۰۸۷	۰/۳۹	۸/۳	۱/۶۱
۸	نرخ رشد هزینه های دولت	۰/۰۰۷۵	۰/۰۸۵	۰/۴۱	۸/۸	۱/۴۱
۹	الگوی بنیادی	۰/۰۱۰۶	۰/۰۹۹	۰/۴۸	۱۰/۲	۱

همان طور که از جدول فوق مشاهده می شود، حذف متغیرهای رشد صادرات (RX)، رشد صادرات نفت (RXoil) و نرخ رشد حجم تجارت (RXM) نسبت به سایر متغیرها



سبب کاهش معنی‌داری در خطای پیش‌بینی الگوی بنیادی شده‌اند. این مطلب با توجه به آماره F آن‌ها کاملاً مشهود است، چراکه مقدار عددی آماره آزمون مربوط به نسبت RMSE الگوهای مربوط به کنار گذاشتن هر یک از این سه متغیر از الگوی بنیادی، به‌طور معنی‌داری از مقدار بحرانی جدول  $F_{0.05}(10,10) = 2/98$  بزرگ‌تر است. به علاوه، با توجه به ردیف هشتم جدول فوق، درمی‌یابیم که با حذف متغیر نرخ رشد هزینه‌های دولت از الگوی بنیادی، خطای پیش‌بینی افزایش می‌یابد، که نشان‌دهنده شدت اثرگذاری این پارامتر بر روی نرخ رشد اقتصادی است. بنابراین می‌توان ارزش اثر گذاری هر متغیر بر روی رشد تولید ناخالص داخلی را بر اساس جدول (۶) رتبه بندی کرد.

جدول ۶- رتبه بندی متغیرهای مؤثر بر رشد تولید ناخالص داخلی

ردیف	عنوان	علامت اختصاری
۱	نرخ رشد هزینه‌های دولت	RTGE
۲	وقفه اول نرخ رشد محصول ناخالص داخلی به قیمت ثابت	RGDP (-1)
۳	نرخ رشد موجودی سرمایه به قیمت ثابت	CSf
۴	نرخ رشد واردات کل به قیمت ثابت	RM
۵	نرخ رشد درآمد نفت و گاز در بودجه عمومی	RIoil
۶	نرخ رشد حجم تجارت	RXM
۷	رشد صادرات نفت	RXoil
۸	نرخ رشد صادرات کل به قیمت ثابت	RX

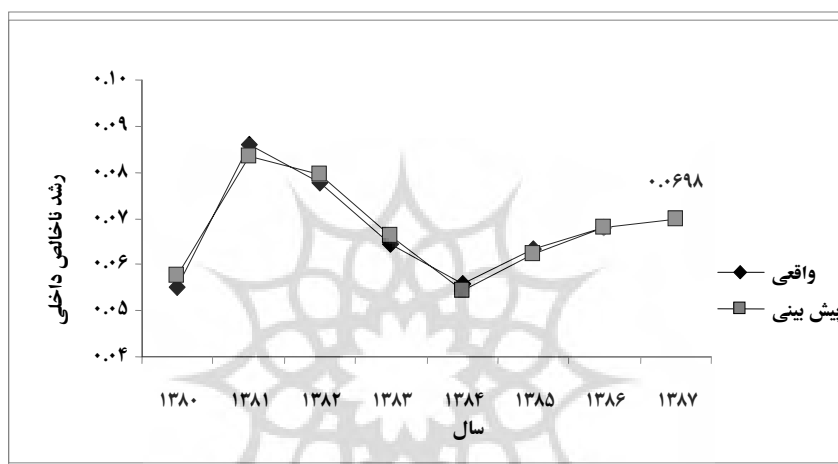
#### ۴-۳- استخراج مدل بهینه حاصل از شبیه‌سازی‌های شبکه عصبی GMDH

در این قسمت، برای هر یک از الگوهای جدول (۵)، فرآیند قیاسی را پیاده سازی می‌کنیم. رتبه‌بندی تمامی شبیه‌سازی‌های انجام‌شده (شامل ۱۸ الگو) توسط شبکه عصبی GMDH براساس معیار خطای RMSE در جدول (۷) مشخص آمده است.

جدول ۷- معیارهای ارزیابی خطایابی کلیه شبیه‌سازی‌های انجام‌گرفته

ردیف	الگو	RMSE	MAPE	درصد خطای پیش‌بینی	TIC
۱	الگوی بدون رشد صادرات کل RX	۰/۰۰۲۴	۰/۰۳۱	۳/۵۳	۰/۱۴
۲	الگوی بدون رشد صادرات نفت RXoil	۰/۰۰۲۶	۰/۰۳۲	۳/۸۷	۰/۱۵
۳	الگوی بدون رشد حجم تجارت RXM	۰/۰۰۳۰	۰/۰۴۳	۴/۴۶	۰/۱۸
۴	الگوی قیاسی- نهایی بنیادی	۰/۰۰۳۵	۰/۰۵۲	۵/۴۲	۰/۲۱
۵	الگوی بدون نرخ رشد درآمد نفت و گاز در بودجه Rloil	۰/۰۰۴۶	۰/۰۶۱	۶/۷۸	۰/۲۷
۶	الگوی قیاسی- نهایی بدون رشد حجم تجارت RXM	۰/۰۰۴۷	۰/۰۶۲	۷/۱۵	۰/۲۸
۷	الگوی بدون نرخ رشد واردات کل به قیمت ثابت RM	۰/۰۰۵۵	۰/۰۶۵	۷/۴۳	۰/۳۲
۸	الگوی قیاسی- نهایی بدون رشد صادرات کل RX	۰/۰۰۵۸	۰/۰۶۸	۷/۶۵	۰/۳۳
۹	الگوی بدون نرخ رشد موجودی سرمایه به قیمت ثابت Csف	۰/۰۰۶۱	۰/۰۸۶	۷/۹۳	۰/۳۶
۱۰	الگوی بدون وقفه اول GDP به قیمت ثابت	۰/۰۰۶۶	۰/۰۸۷	۸/۲۸	۰/۳۹
۱۱	الگوی قیاسی- نهایی بدون رشد صادرات نفت RXoil	۰/۰۰۶۸	۰/۰۸۷	۸/۴۷	۰/۴۱
۱۲	الگوی قیاسی- نهایی بدون رشد درآمد نفت و گاز در بودجه Rloil	۰/۰۰۷	۰/۰۸۴	۸/۶۵	۰/۴۲
۱۳	الگوی بدون رشد هزینه‌های دولت RTGE	۰/۰۰۷۵	۰/۰۸۵	۸/۷۷	۰/۴۱
۱۴	الگوی قیاسی- نهایی بدون وقفه اول GDP به قیمت ثابت	۰/۰۰۷۹	۰/۰۸۶	۹/۱۵	۰/۴۳
۱۵	الگوی قیاسی- نهایی بدون رشد موجودی سرمایه به قیمت ثابت	۰/۰۰۸	۰/۰۸۷	۹/۳۷	۰/۴۴
۱۶	الگوی قیاسی- نهایی بدون رشد واردات کل RM	۰/۰۰۸۴	۰/۰۸۹	۹/۵۶	۰/۴۶
۱۷	الگوی قیاسی- نهایی بدون رشد هزینه‌های دولت RTGE	۰/۰۰۸۹	۰/۰۹۱	۹/۸۷	۰/۴۶
۱۸	الگوی بنیادی	۰/۰۱۰۶	۰/۰۹۹	۱۰/۲	۰/۴۸

با توجه به جدول فوق، ملاحظه می‌شود که الگوی بنیادی با کنار گذاشتن رشد صادرات کل (RX) نسبت به تمامی الگوهای شبیه‌سازی شده دیگر عملکرد بهتری در مدل‌سازی و پیش‌بینی رشد تولید ناخالص داخلی داشته و دارای خطای کم‌تری است. لذا می‌توان این الگو را به‌عنوان الگوی بهینه برگزید و از این الگوی ۷ متغیره برای پیش‌بینی رشد اقتصادی ایران بهره گرفت. نمودار (۳)، مقادیر واقعی و پیش‌بینی‌شده رشد تولید ناخالص داخلی را برای این الگوی بهینه نشان می‌دهد.



نمودار ۳- مقادیر واقعی و پیش‌بینی‌شده رشد تولید ناخالص داخلی برای الگوی بهینه

#### ۴-۴- تخمین مدل ARIMA و مقایسه آن با مدل بهینه شبکه عصبی GMDH

به منظور ارزیابی و مقایسه نتیجه به دست آمده از شبکه عصبی GMDH، اقدام به اجرای یک مدل  $ARIMA(1,1,0)$  کردیم. این مدل توسط نرم‌افزار Eviews، به اجرا گذاشته می‌شود و نتایج حاصل از آن به‌طور خلاصه در جدول (۸) با الگوی بهینه شبکه عصبی GMDH مقایسه شده است.

جدول ۸ - مقایسه شبکه عصبی GMDH با الگوی ARIMA بر اساس معیار خطا

TIC	درصد خطای پیش‌بینی	MAPE	RMSE	الگو
۰/۱۴	۳/۵۳	۰/۰۳۱	۰/۰۰۲۴	الگوی بنیادی با کنار گذاشتن رشد صادرات
۰/۱۰	۱۲/۶۸	۲/۰۲۱	۰/۰۱۴۱	الگوی ARIMA

همان‌طور که مشاهده می‌شود، بر اساس همه معیارهای خطای مدل بهینه شبکه عصبی GMDH به‌طور قابل توجهی برتر از مدل ARIMA عمل نموده است. البته مقادیر خطا در تمام شبیه‌سازی‌های شبکه عصبی از الگوی رگرسیونی بهتر می‌باشد. مقدار عددی آماره آزمون مربوط به نسبت RMSE در الگوهای رگرسیونی و شبکه عصبی برابر  $F(10,10) = 5/875$  است که بزرگ‌تر از مقدار بحرانی جدول  $F_{0.05}(10,10) = 2/98$  می‌باشد. لذا تفاوت معنی‌داری بین این دو الگو وجود داشته و بنابراین شبکه عصبی GMDH از عملکرد به مراتب بهتری جهت پیش‌بینی رشد اقتصادی نسبت به الگوهای رگرسیونی برخوردار است. با استفاده از آزمون‌های معنی‌داری F و گرنجر-نیوبولد<sup>۱</sup> نیز تفاوت معنی‌داری بین دو الگو وجود داشته که نتایج در جدول (۹) آمده است.<sup>۲</sup>

جدول ۹- نتایج آزمون ارزیابی مقایسه‌ای پیش‌بینی شبکه عصبی GMDH با ARIMA

Forecast Evaluation			
Test	Statistics	P-Value	Results
1) The F Test	19.271475	1.027E-07	RMSE1<RMSE2
2) The Granger-Newbold Test	-8.3095729	8.004E-07	RMSE1<RMSE2
3) The Diebold-Mariano Test			
3-1) $g(h)=h^2$	-0.8190720	0.5473489	RMSE1=RMSE2
3-2) $g(h)=h^4$	-0.3410157	0.7377130	RMSE1=RMSE2

مطابق آزمون‌های (۱) و (۲) تفاوت خطای شبکه عصبی GMDH نسبت به ARIMA معنی‌دار است.

۱ - این آزمون با فرض وجود شرط اول و دوم و برای حل مشکل سوم پیشنهاد شده است. فرض کنید داریم:

$$x_t = e_{it} + e_{2t}, z_t = e_{it} - e_{2t}$$

اگر خطاهای مدل اول و دوم یکی باشد، ضریب همبستگی بین  $x_t$  و  $z_t$  برابر صفر خواهد بود. لذا تحت فرضیه صفر-برابری خطاهای پیش‌بینی- مقدار زیر دارای توزیع  $t$  با درجه آزادی  $H-1$  خواهد بود:

$$GN = \frac{r_{xz}}{\sqrt{\frac{(1 - r_{xz}^2)}{H - 1}}}$$

اگر ضریب همبستگی مثبت باشد، مدل اول خطای بیش‌تر و در غیر این صورت مدل دوم خطای بیش‌تری خواهد داشت.

۲ - آزمون فوق مبتنی بر برنامه طراحی شده آقای مهدی نوری (دانشجوی دکتری اقتصاد، دانشگاه تهران) است.

## ۵ - نتیجه‌گیری

از مجموع شبیه‌سازی‌های انجام‌شده و مطالب ارائه شده در این فصل، نتایج زیر ارائه می‌شود:

- ۱- از کل شبیه‌سازی‌های انجام‌گرفته در الگوی بنیادی، تنها فرآیند قیاسی منجر به کاهش معیارهای خطا شده و در بقیه موارد، پیاده‌سازی فرآیندهای قیاسی افزایش معیارهای خطا و کاهش دقت پیش‌بینی شده را سبب شده است.
- ۲- بهترین الگو از میان ۱۸ الگوی شبیه‌سازی‌شده، بر اساس معیار خطای کمینه و بهبود در عملکرد پیش‌بینی، الگوی حاصل از کنار گذاشتن متغیر رشد صادرات کل از الگوی بنیادی است. رتبه‌های دوم و سوم نیز به الگوهای حاصل از کنار گذاشتن متغیر رشد صادرات نفت و رشد حجم تجارت از الگوی بنیادی تعلق می‌گیرد. (جدول ۷)
- ۳- با مقایسه معیارهای خطا در الگوی بهینه به‌دست آمده از شبکه عصبی GMDH با مدل سری زمانی ARIMA، مشاهده می‌شود که کارایی الگوریتم GMDH در پیش‌بینی رشد اقتصادی به مراتب بهتر از مدل ARIMA است. نکته حائز اهمیت این است که حتی آخرین مدل در جدول رتبه‌بندی الگوهای شبکه عصبی (جدول ۷) نسبت به مدل ARIMA،  $1/3$  برابر دقیق‌تر است و عملکرد بهتر شبکه عصبی GMDH در پیش‌بینی نسبت به روش‌های رگرسیونی تأیید می‌کند.
- ۴- هر یک از عوامل مؤثر بر رشد تولید ناخالص داخلی، سهمی در کاهش خطای پیش‌بینی دارد. در این میان (مطابق جدول ۶) متغیرهای رشد صادرات کل به قیمت ثابت، رشد صادرات نفت و رشد حجم تجارت به ترتیب کم‌ترین سهم و متغیرهای رشد هزینه‌های دولت، وقفه اول رشد تولید ناخالص داخلی و رشد موجودی سرمایه به قیمت ثابت، بیش‌ترین سهم را در کاهش خطای پیش‌بینی داشته‌اند. بنابراین با کنار گذاشتن هر یک از عوامل بخش اول، توانایی الگو برای پیش‌بینی‌های یک گام به جلو برای رشد اقتصادی افزایش می‌یابد. هم‌چنین براساس مدل نهایی حاصل از فرآیند قیاسی الگوی بنیادی، متغیرهای رشد هزینه‌های دولت، درآمد نفت و گاز در بودجه عمومی و واردات کل، دارای اثر مضاعف بر متغیر هدف بوده‌اند. بنابراین نمی‌توان علل و عوامل مؤثر بر رشد تولید ناخالص داخلی را به طور مشخص تبیین کرد.
- ۵- هرچند متغیرهای الگو با الهام از نظریه‌های اقتصادی و شرایط اقتصادی کشور (به ویژه رشد هزینه‌های دولت) انتخاب شده‌اند، با این حال ساز و کار و چگونگی تأثیر آن‌ها بر متغیر هدف (رشد تولید ناخالص داخلی)، از نظر ساختاری را مشخص نمی‌کنند.

در حقیقت تحلیل‌های انجام گرفته درباره سهم مربوط به اطلاعات گذشته متغیرهای ورودی در کاهش (معنی‌دار) خطای پیش‌بینی یک مفهوم علیت را تداعی می‌کند. به این ترتیب که ورودی‌های مؤثر را می‌توان به‌عنوان علت تغییرات رشد تولید ناخالص داخلی تفسیر کرد.

۶- با توجه به قابلیت و توانایی شبکه عصبی GMDH در تحلیل و پیش‌بینی سیستم‌های پیچیده (تعدد متغیرهای ورودی) و با مشاهدات محدود، می‌توان از الگوهای بنیادی به‌عنوان مبنای تحلیل‌های قیاسی استفاده کرد. اما نکته مهم در زمینه آن است که اضافه کردن متغیرها به مدل الزاماً به کاهش خطای پیش‌بینی منجر نمی‌شود. به عبارت دیگر، الگوهای بزرگ‌تر لزوماً، نتایج بهتری به لحاظ عملکرد پیش‌بینی ایجاد نمی‌کنند. به طوری که الگوی بنیادی در جدول (۷) رتبه آخر را از نظر خطا و عملکرد پیش‌بینی، به خود اختصاص داده است.

### فهرست منابع

- ۱- ابریشمی، معینی، مهرآرا، احراری و سلیمانی کیا، (۱۳۸۷) "مدل‌سازی و پیش‌بینی قیمت بنزین با استفاده از شبکه عصبی GMDH"، فصل‌نامه پژوهش‌های اقتصادی ایران، دانشکده اقتصاد علامه طباطبایی، شماره ۳۶.
- ۲- تقوی، مهدی و محمدی، حسین، ۱۳۸۵ "تأثیر سرمایه‌انسانی بر رشد اقتصادی در ایران"، پژوهش‌نامه اقتصادی.
- ۳- جهانگرد، اسفندیار، (۱۳۸۳) "پیش‌بینی رشد اقتصادی ایران و مقایسه آن با اهداف برنامه چهارم توسعه"، مجله برنامه و بودجه، شماره ۸۹.
- ۴- حسینی، صفدر و مولایی، مرتضی، (۱۳۸۵) "تأثیر سرمایه‌گذاری مستقیم خارجی بر رشد اقتصادی در ایران"، پژوهش‌نامه اقتصادی، شماره ۲۱، تابستان.
- ۵- درگاهی حسن و قدیری امرا...، (۱۳۸۲) "تجزیه و تحلیل عوامل رشد اقتصادی ایران"، فصل‌نامه پژوهش‌های بازرگانی، شماره ۲۶.
- ۶- قدیمی، محمدرضا و مشیری، سعید، (۱۳۸۱) "مدل‌سازی و پیش‌بینی رشد اقتصادی در ایران با استفاده از شبکه‌های عصبی مصنوعی (ANN)"، پژوهش‌های اقتصادی ایران، شماره ۱۲.

- 7- Amanifard N., Nariman-Zadeh N., Borji M., Khalkhali A. and Habibdoust A., (February 2008), Modelling and Pareto optimization of heat transfer and flow coefficients in microchannels using GMDH type neural networks and genetic algorithms, Energy Conversion and Management, Volume 49, Issue 2, Pages 311-325.
- 8- Anastasakis L., Mort N., (2001) The Development of Self-Organization Techniques in Modelling: A Review of The Group Method of Data Handling (GMDH), Department of Automatic Control & Systems Engineering The University of Sheffield, Mappin St, Sheffield, No. 813.
- 9- Atashkari K., Nariman-Zadeh N., Gölcü M., Khalkhali A. and Jamali A., (2007), Modelling and multi-objective optimization of a variable valve-timing spark-ignition engine using polynomial neural networks and evolutionary algorithms, Energy Conversion and Management, Volume 48, Issue 3, p.p. 1029-1041.
- 10- Chen F., and Xu J. (2006), Factor analysis for well-off construction based on GMDH, World Journal of Modelling and Simulation, Vol. 2, No. 4, pp. 213-221.
- 11- Costanzo S., Trigo L., Jimenez L. and Gonzalez J., (2007) A Neural Network Model of the Venezuelan Economy.
- 12- Enders W., (2004), Applied Econometric Time Series, 2nd ed., John Wiley & Sons Inc., 79-86.
- 13- Farlow S. J., (1984) Self-organizing methods in modeling, GMDH type algorithms, New York and Basel, Marcel Dekker, Inc.
- 14- Ivakhnenko A. G., and Ivakhnenko G. A., (1995), The review of problems solvable by algorithms of the group method of data handling (GMDH), Pattern Recognition and Image Analysis, vol.5, no.4, pp.527-535.
- 15- Ivakhnenko A. G., Ivakhnenko G. A., (2000(a)), Problems of Further Development of the Group Method of Data Handling Algorithms, Part I, Pattern Recognition and Image Analysis, Vol. 10, No. 2, pp. 187-194.
- 16- Ivakhnenko G., 2000(b), Problems of further development of the group method of data handling algorithms. Pattern Recognition and Image Analysis, 187-194.
- 17- Ivakhnenko, A. G., (1968) The group method of data handling; a rival of the method of stochastic approximation, Soviet Automatic Control, 13(3), 43-55.
- 18- Jafari-Samimi, A., Shirazi, B., Fazlollahtabar, H., (2007), A Comparison Between Time Series, Exponential Smoothing and Neural

- Network Methods to Forecast GDP of Iran, Iranian Economic Review, vol 12, No 19, pp 19-35.
- 19- Moshiri, S. and Ghadimi, R., (2004), forecasting Growth Using ANN model whit Genetic Algorithm, Iranian Economic Review, vol 9, No 11, pp 67-83.
- 20- Nariman-zadeh, N.; Darvizeh, A.; Darvizeh, M.; Gharababaei, H (2002) "Modelling of explosive cutting process of plates using GMDH-type neural network and singular value decomposition". Journal of Materials Processing Technology, vol. 128, no. 1-3, pp. 80-87, Elsevier Science.
- 21- United Nation, (2005) Global Forecasts and Prediction for Western ESCWA Region: The Roles of Investment and Public Expenditure in Economic Growth, ISSUE NO. 2.

