

پیش‌بینی درآمدهای مالیاتی با استفاده از الگوریتم بهینه‌سازی ازدحام ذرات (PSO)

مرتضی اسدی^۱، سعیده حمیدی علمداری^۲، حمید خالوزاده^۳

تاریخ دریافت: ۹۵/۰۸/۰۶ تاریخ پذیرش: ۹۶/۰۹/۰۴

چکیده

پیش‌بینی درآمدهای مالیاتی قابل حصول در منابع مختلف مالیاتی، علاوه بر تخصیص بهینه منابع محدود سازمانی در جهت وصول مالیات، دولت را در انجام برنامه‌ریزی‌های دقیق مالی کمک می‌نماید. این مقاله با استفاده از الگوریتم تکاملی ازدحام ذرات و نسخه بهبودیافته آن به پیش‌بینی درآمدهای مالیاتی کشور به تفکیک منابع وصولی (مالیاتی‌های کل، کالا و خدمات، اشخاص حقوقی، درآمد و ثروت) برای سالهای ۹۵-۱۳۹۲ می‌پردازد. به این منظور از داده‌های درآمدهای مالیاتی سالهای ۸۶-۱۳۵۰ برای آموزش شبکه استفاده شده و سپس با استفاده از الگوریتم تکاملی ازدحام ذرات و ازدحام ذرات بهبود یافته پارامترهای این مدل بهینه شده است. از داده‌های سالهای ۹۱-۱۳۸۷ برای آزمون مدل استفاده شده که نتایج تاییدی بر عملکرد مدل مورد استفاده بوده و در نهایت پیش‌بینی برون‌نمونه‌ای درآمدهای مالیاتی به تفکیک منابع وصولی برای سالهای ۹۵-۱۳۹۲ با استفاده از نرم افزار MATLAB انجام شده است.

واژه‌های کلیدی: مالیات، پیش‌بینی، مدلسازی شبکه‌های عصبی، بهینه‌سازی، الگوریتم ازدحام ذرات (PSO).

طبقه‌بندی C22, H250:JEL.

Email: dr.asadi@khu.ac.ir

Email: hamidi_saeedeh@yahoo.com

Email: h_khaloozadeh@kntu.ac.ir

۱. عضو هیئت علمی دانشگاه خوارزمی، (نویسنده مسئول)

۲. کارشناس ارشد علوم اقتصادی دانشگاه خوارزمی،

۳. استاد دانشگاه خواجه نصیرالدین طوسی،

۱. مقدمه

اطلاع از میزان درآمدهای مالیاتی قابل حصول در منابع مختلف مالیاتی، علاوه بر تخصیص بهینه منابع محدود سازمانی در جهت وصول مالیات، دولت را در انجام برنامه‌ریزی‌های دقیق مالی کمک و میزان مشارکت مردم را در تأمین مالی هزینه‌های عمومی دولت به طور دقیق مشخص می‌نماید. پیش‌بینی مالیات برای اهدافی مانند ارزیابی عملکرد، برنامه‌ریزی وصول درآمدهای مالیاتی و تحلیل سیاستی بکار گرفته می‌شود.

روشهای بهینه‌سازی کلاسیک، که مبتنی بر قواعد و قوانین ریاضی هستند، در حل بسیاری از مسائل کاربردی و روزمره، کارایی لازم را ندارند. همچنین الزامات و شرایطی که این روش‌ها می‌طلبند، در اغلب موارد به قدری محدودکننده هستند، که عملاً این آن را غیرقابل استفاده و ناکارآمد می‌کنند. روش‌های بهینه‌سازی هوشمند یا روش‌های ابتکاری، با بهره‌گیری از مکانیزم‌های جستجوی مختلف، به دنبال پاسخ مسائل بهینه‌سازی می‌گردند. در الگوریتم‌های هوشمند قدیمی، جواب‌های اولیه به‌صورت تصادفی ایجاد می‌شوند و با توجه به مقدار تابع هدف و کیفیت جواب‌ها، رتبه‌بندی می‌شوند. سپس با اعمال مکانیزم‌هایی هم‌چون تقاطع^۱، جهش^۲، حرکت به سوی نخه و تکنیک‌های انتخاب، جواب‌های دیگری به‌وجود می‌آیند که از نظر کیفیت، به‌طور احتمالی، بهتر از جواب‌های اولیه هستند. اما در این شرایط احتمال رخ دادن همگرایی زودهنگام^۳ وجود دارد. اما در الگوریتم‌های تکاملی جواب‌هایی که در هر تکرار از این الگوریتم‌های بهینه‌سازی حاصل می‌شوند، نمونه‌هایی از توزیعی هستند که توزیع بهینه‌ی مورد نظر ما را تخمین می‌زنند. در طی عملیاتی که در هر مرحله از الگوریتم بهینه‌سازی انجام می‌شود، گروه دیگری از جواب‌ها به‌وجود می‌آیند که توزیع تخمینی متناظر با آن‌ها، به توزیع بهینه‌ی مورد نظر نزدیک‌تر است. این الگو، برخوردی غیرمستقیم با ایجاد مدل احتمالی بهینه است و در این الگوریتم‌ها هیچ‌گاه موضوع ایجاد تابع توزیع بهینه، مورد بحث واقع نشده است؛ از این‌رو امروزه کاربرد الگوریتم‌های بهینه‌سازی تکاملی برای آموزش شبکه‌های عصبی

-
1. Crossover
 2. Mutation
 3. Pre-Mature Convergence

بجای روش‌های آموزشی مرسوم، مورد توجه محققان قرار گرفته است. در این مقاله به منظور پیش‌بینی درآمدهای مالیاتی به تفکیک منابع وصولی برای سالهای ۹۵-۱۳۹۲ از الگوریتم بهینه‌سازی ذرات (PSO) برای آموزش شبکه‌های عصبی استفاده می‌شود.

۲. مبانی نظری

اصولاً پیش‌بینی عنصری کلیدی برای تصمیم‌گیری‌های مدیریتی است و به همین دلیل سیستم‌های مدیریتی برای طراحی و کنترل عملگرهای تشکیلاتی خود نیاز به پیش‌بینی دارند. به طور کلی می‌توان گفت که پیش‌بینی عبارت است از برآورد پیشامدهای آینده و هدف از پیش‌بینی، کاهش ریسک در تصمیم‌گیری است. پیش‌بینی اقتصادی فرآیند انجام پیش‌نگری از کل اقتصاد یا بخشی از آن است؛ این پیش‌بینی ممکن است با جزئیات کامل و یا خیلی کلی باشد. در هر حال اینگونه پیش‌بینی‌ها رفتار آتی و مورد انتظار کل یا بخشی از اقتصاد را توصیف کرده و کمکی برای انجام برنامه‌ریزی محسوب می‌شوند. به دلیل پیچیدگی‌هایی که در هر سیستم اقتصادی به دلیل ماهیت‌های تصادفی‌شان وجود دارد، انجام پیش‌بینی‌هایی با حداقل خطا از اهمیت زیادی برخوردار می‌باشد. به طور کلی در هر نظام اقتصادی وجود دو دلیل عمده، انجام پیش‌بینی‌ها را ضروری نموده است: اول آینده نامعلوم و عدم اطمینان نسبت به آن و دوم نگرانی از انحراف اثرات بسیاری از تصمیماتی که اکنون گرفته می‌شوند برای آینده؛ به همین دلیل انجام پیش‌بینی‌های دقیق از آینده می‌تواند کارایی فرایند تصمیم‌گیری را بهبود دهد. یکی از نگرانی‌های عمده تحلیل‌گران اقتصادی فهم و شناخت شرایطی است که اقتصاد در هر زمان با آن مواجه است و همچنین کنترل و نظارت بر آن به منظور پیش‌بینی تغییرات احتمالی این شرایط است. پیش‌بینی‌ها معمولاً دارای مقداری خطا هستند که میزان این خطا با داشتن اطلاعات بیشتر در مورد سیستم کاهش می‌یابد. چون پیش‌بینی همیشه با مقداری خطا همراه است، بنابراین فرآیند تصمیم‌گیری در بردارنده مقداری نااطمینانی ناشی از پیش‌بینی خواهد بود که استفاده از بازه در پیش‌بینی‌ها این مشکل را تا حدی حل می‌کند.

از نظر دیه بابل (۱۹۹۸)^۱ مدل‌های موفق برای انجام پیش‌بینی، مدل‌هایی هستند که به سرعت خودشان را با تغییرات در شرایط اقتصادی وفق می‌دهند و نه لزوماً "مدل‌هایی که بر پایه نظریات قوی اقتصادی بنا شده باشند. دومین مشخصه یک پیش‌بینی خوب که در حقیقت به عنوان یک استاندارد برای ارزیابی کیفیت پیش‌بینی قلمداد می‌شود، برخورداری از ثبات است. به عبارت دیگر، پیش‌بینی نایستی همگام با تکرار یا تغییر روش پیش‌بینی تغییر قابل توجه و معنی‌داری داشته باشد و گرنه این تغییر بایستی با توضیحات مفصلی همراه باشد. همچنین لزوم ثبات و پایداری در پیش‌بینی بدین معنی است که به طور کامل با اجماع نظرهای فعلی مغایرت نداشته باشد. روشهای متنوعی برای انجام پیش‌بینی در حوزه مسائل اقتصادی توسعه یافته که هر کدام بر پایه یک سری فروض آماری یا نظریات مشخص استوار است و در عین حال موافقان و مخالفان خاص خود را دارند. با این حال ذکر این نکته ضروری است که هیچ روش بهینه، مشخص و یا منحصر به فردی برای انجام پیش‌بینی وجود ندارد و دلیل آن نیز پیچیدگی ذاتی و در عین حال بیش از حد پدیده‌های دنیای پیرامونی ماست. به طور کلی روشهای پیش‌بینی را می‌توان به دو نوع کیفی و کمی طبقه‌بندی کرد؛ در روشهای کمی از داده‌های تاریخی و یک مدل پیش‌بینی استفاده می‌شود. مدل بیان و خلاصه‌ای از الگوهای رفتاری داده‌ها بوده و یک رابطه آماری بین مقادیر گذشته و حال یک متغیر بیان می‌کند؛ سپس از این مدل برای انجام پیش‌بینی الگوهای رفتاری داده‌ها در آینده استفاده می‌شود. به عبارت دیگر، مدل پیش‌بینی برای برون‌یابی رفتار گذشته و حال داده‌ها در آینده بکار می‌رود. به طور کلی انواع مختلف مدل‌های کمی پیش‌بینی وجود دارد اما سه مدل که به طور گسترده مورد استفاده قرار می‌گیرند عبارتند از: مدل‌های رگرسیونی، مدل‌های هموارسازی و روشهای سریهای زمانی.

در حوزه روشهای پیش‌بینی درآمدهای مالیاتی نیز، به طور کلی چهار روش وجود دارد که هر کدام معایب و مزایای خاص خود را دارند که شامل: ۱- پیش‌بینی درآمدهای مالیاتی به

1. Die Boble

روش کشش درآمدی مالیات، ۲-پیش‌بینی درآمدهای مالیاتی به روش نرخ موثر مالیاتی ۳-
پیش‌بینی درآمدهای مالیاتی به روش مدلسازی اقتصادکلان (اقتصادسنجی) ۴-پیش‌بینی
درآمدهای مالیاتی به روش مدلسازی سری‌های زمانی، می‌باشد.

سری‌های زمانی به مجموعه‌ای از مشاهدات مربوط به یک متغیر در خلال فواصل زمانی
معین و مساوی گفته می‌شود. روشهای سری زمانی اغلب برای پیش‌بینی‌های کوتاه‌مدت مورد
استفاده قرار می‌گیرند و در آن رفتار یک متغیر براساس مقادیر گذشته خود (و احتمالا مقادیر
گذشته سایر متغیرهایی که مایل هستیم آنها را پیش‌بینی کنیم) توضیح داده می‌شود. اهداف
آنالیز سری‌های زمانی توصیف کردن روند تولید داده و پیش‌بینی مقادیر آینده است. فرایندهای
سری زمانی را می‌توان به دو گروه روش‌های خطی و روش‌های غیرخطی تقسیم نمود. برخی از
مهمترین مدل‌های غیرخطی سری زمانی شامل مدل شبکه‌های عصبی مصنوعی، مدل درخت
تصمیم‌گیری، مدل خوشه بندی، روشهای شبیه سازی و ... می‌باشند.

روش نرخ مؤثر مالیاتی و کشش مالیاتی برای پیش‌بینی درآمدهای مالیاتی براساس
سیاستهای جاری کاربرد دارند و مدل‌های شبیه سازی خرد برای برآورد اثرات درآمدی تغییر
مالیات‌ها مورد استفاده قرار می‌گیرند. در برخی مواقع یافتن ارتباط بین نحوه‌ی شکل‌گیری
درآمدهای مالیاتی و متغیرهای کلان اقتصادی بسیار سخت می‌باشد؛ در چنین شرایطی روش
روند و الگوهای سری‌زمانی ممکن است تنها رویکرد عملی برای پیش‌بینی باشد. در برخی موارد
از طریق نمونه‌گیری از اظهارنامه‌های مالیاتی و طراحی مدل‌های شبیه‌سازی خرد اقدام به پیش‌بینی
در سطح خرد و سپس کلان می‌کنند همچنین این روش را می‌توان با دو روش آخر ترکیب
کرد. دو روش اخیر برای اقتصادهای پیشرفته و کشورهایی که از ثبات اقتصادی و بانک
اطلاعاتی غنی برخوردارند، بسیار مفید می‌باشند و می‌توانند به پیش‌بینی‌هایی مطمئن و دقیق‌تری
بیانجامند.

در خصوص پیش بینی درآمدهای مالیاتی مطالعات زیادی انجام شده که از جمله می توان به مطالعات انجام شده توسط شهشهانی و داوولینگ (۱۳۵۶)، شهشهانی (۱۳۵۷)، محمدی (۱۳۶۳)، حمید رضا ارباب (۱۳۶۶)، فهیم یحیایی (۱۳۷۰)، قطمیری (۱۳۷۰)، محمود محضر نیا (۱۳۷۳) (سیستم معادلات همزمان)، حمید صفای نیکو (۱۳۷۵)، عیسی زاده روشن (۱۳۷۶)، مرتضی سامتی (۱۳۷۸) (سیستم معادلات همزمان)، رسول بخشی دستجردی (۱۳۷۸)، صفری بکناش (۱۳۸۰)، محمد حسین احسانفر (۱۳۸۰)، ملایی پور و فتحانی (۱۳۸۱)، محمد رضا منجذب و پارسا سلیمانی (۱۳۸۴)، الیزابت شیرازی (۱۳۸۵)، مطالعه قطمیری و اسلاملوئیان (۱۳۸۵) و روح الله مهربان (۱۳۸۶) از روشهای خطی برای پیش بینی درآمدهای مالیاتی (ظرفیت بالفعل یا ظرفیت عملکرد) استفاده شده است. لزگی و همکاران (۱۳۸۷) از روشهای سری زمانی برای پیش بینی درآمدهای مالیاتی طی سالهای ۸۳-۱۳۷۴ استفاده نموده است. امین رشتی و رضایی (۱۳۸۸) نیز از روشهای سری زمانی ARIMA برای پیش بینی درآمدهای مالیاتی استفاده نموده است. حمیدی (۱۳۸۴) از روشهای سری زمانی ARIMA، روش اقتصادسنجی کلاسیک و روشهای غیرخطی شبکه های عصبی برای پیش بینی درآمدهای مالیات بر مشاغل استفاده نموده است. رضایی و همکاران (۱۳۸۶) از شبکه های عصبی پیشخور برای پیش بینی درآمدهای مالیاتی استفاده نموده است. حمیدی و خالوزاده (۱۳۸۸) پیش بینی درآمدهای مالیاتی را به تفکیک منابع وصولی با استفاده از شبکه های عصبی با ساختار سری- موازی برای سالهای ۸۸-۱۳۸۷ انجام داده اند. در مطالعه عرب مازار و همکاران (۱۳۸۷) ظرفیت بالفعل مالیاتی با استفاده از شبکه های عصبی با ساختار موازی و مدلهای سری زمانی ARIMA برآورد و در نهایت عملکرد دو روش با یکدیگر مقایسه شده است نتایج این تحقیق حاکی از عملکرد بهتر روش شبکه عصبی می باشد. عبدی و حمیدی (۱۳۹۰) از روش شبکه های عصبی با ساختار پیشنهادی چندورودی- چندخروجی و روشهای سری زمانی ARIMA و مدل VAR برای پیش بینی درآمدهای مالیاتی به تفکیک منابع وصولی استفاده نمودند. ضمناً در این مطالعه تاثیر نوسانات نرخ ارز بر روی هر یک از منابع

مالیاتی بررسی و در نهایت با در نظر گرفتن نوسانات نرخ ارز پیش‌بینی درآمدهای مالیاتی انجام شده است.

در این مقاله ما پس از بیان مبانی نظری، از روشهای غیرخطی شبکه‌های عصبی با آموزش الگوریتم بهینه‌سازی ازدحام ذرات برای پیش‌بینی درآمدهای مالیاتی استفاده می‌کنیم که این الگوریتم از نظر مدل‌سازی از قویترین ساختار برای پیش‌بینی برخوردار می‌باشد.

• ساختار شبکه‌های عصبی

از سال ۱۹۴۰ تحقیقات و علاقمندی در زمینه شبکه‌های عصبی آغاز شد و اهداف این تحقیقات دستیابی به راز پردازش سریع مغز انسان، چگونگی پردازش اطلاعات در آن، چگونگی کار حافظه، مسئله یادگیری، یادآوری و می‌باشد. مدل‌های شبکه عصبی با استفاده از توابع و پردازشگرهای ریاضی به شبیه‌سازی عملکرد مغز انسان می‌پردازند و قادرند روابط ناشناخته به شدت غیرخطی را مدل‌سازی کنند. یکی از ساختارهای شبکه‌ی عصبی، ساختار پرسپترون چندلایه است. مفهوم پرسپترون در سال ۱۹۴۳ توسط پیتس و مک کولچ^۱ به عنوان یک نرون مصنوعی ارائه شد. یک پرسپترون چند لایه نشان‌دهنده یک ارتباط غیرخطی بین بردارهای ورودی و خروجی می‌باشد. این کار از طریق اتصال نرون‌های هر گره در لایه‌های قبلی و بعدی انجام می‌گیرد. الگوریتم‌های مختلفی جهت آموزش شبکه‌های عصبی بکار می‌روند. از مهم‌ترین الگوریتم‌های آموزشی می‌توان از الگوریتم پس‌انتشار خطا^۲ نام برد. در این الگوریتم، مقدار خروجی محاسبه شده در هر مرحله، با مقدار واقعی مقایسه شده و با توجه به خطای بدست آمده، وزن‌ها و بایاس‌های شبکه به گونه‌ای اصلاح می‌گردند که اندازه خطای بدست آمده کمتر از مرحله قبل گردد. اساس این کمینه‌سازی، حرکت بر روی بردار گرادیان تابع مربعات خطای

1. McCulloch & Pitts
2. Back Propagation Error

شبکه می‌باشد؛ که این بردار نیز به وسیله مشتق‌گیری زنجیره‌ای از تابع خطا نسبت به تک‌تک پارامترهای شبکه بدست می‌آید.

شبکه‌های عصبی قابلیت بسیار مناسبی در حل مسائل پیش‌بینی دارند. اگرچه استفاده از الگوریتم پس انتشارخطا در سالهای اخیر برای آموزش شبکه‌های عصبی رواج بسیاری پیدا کرده است، اما استفاده از این روش در برخی موارد منجر به بروز مشکلاتی از جمله همگرایی زودرس در مینیمم‌های محلی می‌باشد. امروزه کاربرد الگوریتم‌های بهینه‌سازی تکاملی برای آموزش شبکه‌های عصبی بجای روش‌های آموزشی مرسوم، مورد توجه محققان قرار گرفته است. یکی از الگوریتم‌های بهینه‌سازی تکاملی، الگوریتم بهینه‌سازی ازدحام ذرات (PSO) است که می‌تواند به عنوان جایگزینی برای آموزش شبکه عصبی مورد استفاده قرار گیرد. الگوریتم‌های تکاملی خاصیتی سیستماتیک دارند که در آنها عامل‌ها به طور محلی با هم همکاری می‌نمایند و رفتار جمعی تمام عامل‌ها باعث یک همگرایی در نقطه‌ای نزدیک به جواب بهینه سراسری می‌شود؛ نقطه قوت این الگوریتم عدم نیاز به یک کنترل سراسری می‌باشد. هر ذره (عامل) در این الگوریتم‌ها خود مختاری نسبی دارد که می‌تواند در سراسر فضای جواب‌ها حرکت کند و می‌بایست با سایر ذرات (عامل‌ها) همکاری داشته باشد. استفاده از ایده جدید هوش جمعی در ترکیب با شبکه‌های عصبی مصنوعی می‌تواند راهکاری برای غلبه بر چالش موجود درخصوص آموزش شبکه‌های عصبی باشد.

• الگوریتم بهینه‌سازی ازدحام ذرات

الگوریتم بهینه‌سازی انبوه ذرات یکی از مهمترین الگوریتم‌هایی است که در حوزه‌ی هوش جمعی جای می‌گیرد. جیمز کندی^۱، روانشناس اجتماعی و راسل سی ابرهات^۲، مهندس برق، صاحبان اصلی ایده‌ی الگوریتم بهینه‌سازی انبوه ذرات می‌باشند. آن‌ها در ابتدا قصد داشتند که با بهره‌گیری از مدل‌ها و روابط موجود اجتماعی، نوعی از هوش محاسباتی را به‌وجود آورند که

-
1. James Kennedy
 2. Russell C. Eberhart


به توانایی‌های فردی و ویژه‌ای نیاز نداشته باشد. این الگوریتم که از روی رفتار اجتماعی دسته‌های پرندگان طراحی شده است در ابتدا به منظور کشف الگوهای حاکم بر پرواز همزمان پرندگان و تغییر ناگهانی مسیر آنها و تغییر شکل بهینه‌ی دسته به کار گرفته شده است. برای برخی از حیوانات از جمله دسته‌های ماهی و پرندگان که به صورت گروهی زندگی می‌کنند، رفتارهای پیچیده‌ای به هنگام حرکت قابل مشاهده است. این در حالی است که هر کدام از اعضای جمع به اطلاعات محدودی دسترسی دارند و فقط از موقعیت عده‌ای اندک از همسایگان خود خبر دارند. در چنین مجموعه‌ای هر کدام از حیوانات فقط از چند قانون ساده تبعیت می‌کنند و رفتارهای پیچیده‌ای که در کل جمع قابل مشاهده هستند، چیزی جز ترکیب این قوانین ساده نیست. در PSO، ذرات^۱ در فضای جستجو جاری می‌شوند. تغییر مکان ذرات در فضای جستجو تحت تأثیر تجربه و دانش خودشان و همسایگانشان است. بنابراین موقعیت دیگر توده^۲ ذرات روی چگونگی جستجوی یک ذره اثر می‌گذارد. نتیجه‌ی مدل‌سازی این رفتار اجتماعی فرایند جستجویی است که ذرات به سمت نواحی موفق میل می‌کنند. ذرات از یکدیگر می‌آموزند و بر مبنای دانش بدست آمده به سمت بهترین همسایگان خود می‌روند اساس کار PSO بر این اصل استوار است که در هر لحظه هر ذره مکان خود را در فضای جستجو با توجه به بهترین مکانی که تاکنون در آن قرار گرفته است و بهترین مکانی که در کل همسایگی‌اش وجود دارد، تنظیم می‌کند.

حرکت این ذرات به سمت هدف توسط دو پارامتر سرعت و موقعیت اداره می‌شود. در ابتدا سرعت هر ذره با اضافه‌شدن مقدار اختلاف بین موقعیت فعلی ذرات و بهترین موقعیت قبلی خود و همچنین با اضافه کردن تفاوت بین موقعیت ذرات و بهترین موقعیت جهانی، به‌روز می‌شود و سپس در مرحله بعد، موقعیت ذرات با اضافه شدن این سرعت جدید به موقعیت فعلی به‌روز

1. Particle

2. Swarm

می‌شود. این مراحل چندین بار تکرار می‌شود تا آن‌که جواب موردنظر به دست آید. در شکل زیر نمایشی از جست‌وجوی ذرات نشان داده شده است.



شکل ۱. جابه‌جایی ذرات

۳. یافته‌های تحقیق

جابه‌جایی ذرات در فضای n بعدی حرکت کرده و مسیر حرکت خود را در فضای جستجو بر اساس تجارب گذشته خود و دیگر ذرات تغییر می‌دهند. در دسته‌ای متشکل از n ذره، موقعیت ذره نام تحت تأثیر یک بردار مکانی n بعدی مطابق رابطه ۱ قرار دارد:

$$X_i = (x_{i1}, x_{i2}, \dots, x_{in})^T \in S \quad (1)$$

که در آن S بیانگر فضای جستجو است. علاوه بر این، ذره نام دارای یک بردار سرعت به صورت رابطه ۲ است:

$$V_i = (v_{i1}, v_{i2}, \dots, v_{in})^T \in S \quad (2)$$

بهترین موقعیت بدست آمده برای ذره α با استفاده از رابطه (۳) نمایش داده می‌شود:

$$P_i = (p_{i1}, p_{i2}, \dots, p_{in})^T \quad (3)$$

در نهایت موقعیت جدید اعضای جمعیت با استفاده از روابط (۴) و (۵) بدست می‌آیند:

$$V_i(t+1) = V_i(t) + cr_1(P_i(t) - X_i(t)) + cr_2(P_g(t) - X_i(t)) \quad (4)$$

$$X_i(t+1) = X_i(t) + V_i(t+1) \quad (5)$$

در روابط فوق، g شاخص بکار رفته برای ذره‌ای است که بهترین موقعیت را دارد، t بیانگر

تعداد تکرار، c ثابت شتاب و r عددی تصادفی در بازه $[0, 1]$ می‌باشد.

الگوریتم PSO ناحیه جواب بهینه را به سرعت پیدا می‌کند؛ اما با رسیدن به این ناحیه،

سرعت همگرایی آن به شدت کاهش می‌یابد. برای رفع این مشکل، روابط ۴ و ۵ بصورت روابط

۶ و ۷ تصحیح می‌گردند:

$$V_i(t+1) = wV_i(t) + c_1r_1(P_i(t) - X_i(t)) + c_2r_2(P_g(t) - X_i(t)) \quad (6)$$

$$X_i(t+1) = X_i(t) + V_i(t+1) \quad (7)$$

در روابط فوق، w ضریب اینرسی، c_1 و c_2 ضرایب یادگیری هستند. r_1 و r_2 باعث

می‌شوند که نوعی گوناگونی در جواب‌ها به وجود آید و به این نحو جست‌وجوی کاملی روی

فضا انجام پذیرد. c_1 ضریب یادگیری مربوط به تجارب شخصی هر ذره است و در مقابل c_2

ضریب یادگیری مربوط به تجارب کل جمع می‌باشد.

۴. الگوریتم PSO بهبود یافته

استفاده از PSO در برخی از مسائل نشان می‌دهد که این الگوریتم دچار همگرایی زودرس می‌شود و سبب می‌شود در حل مسائل چندقله‌ای به‌خصوص مسائلی با فضای حالت بزرگ ناتوان باشد. به منظور رفع این مشکل الگوریتم را با تغییراتی بهبود می‌دهیم. W ضریب اینرسی ذره نام دارد که نقش بسیار مهمی در عملکرد اجرای الگوریتم دارد. این ضریب یک نوع تعادل بین جست‌وجوی محلی و سراسری ایجاد می‌نماید. وزن اینرسی بزرگ، محرکی برای اکتشاف در سراسر ناحیه (حرکت به سمت مناطقی از فضای جست‌جو که پیشتر تجربه نشده‌اند) می‌باشد، درحالی‌که وزن اینرسی کمتر، محرکی برای اکتشاف در نواحی محلی است و در واقع وزن کمتر موجب می‌گردد که جست‌جو در مناطقی که در گذشته تجربه شده‌اند، با دقت بیشتری ادامه یابد. انتخاب مقدار مناسب برای W متضمن برقراری تعادل مطلوب بین اکتشاف محلی و سراسری بوده و در نتیجه باعث افزایش کارایی الگوریتم می‌گردد. نتایج تجربی نشان می‌دهند که انتخاب مقادیر بزرگ برای W در آغاز جست‌جو، موجب می‌گردد که اولویت اکتشاف سراسری نسبت به اکتشاف محلی بالاتر رود و با کاهش تدریجی W ، جست‌جو در فضاهای محلی اهمیت بیشتری پیدا کند. بر این اساس، مقدار W در طول فرآیند جست‌جو کاهش یافته و تدریجاً به صفر میل می‌کند.

راه بهتر که به نتایج بهتری منجر شده است مدلاسیون ضریب اینرسی W بر طبق فاصله بین ذرات یک نسل و بهترین موقعیتی که به‌وسیله کل جمع تجربه شده است، می‌باشد. مقدار W برای هر ذره به‌صورت زیر است:

$$w = w_0 \left(1 - \frac{\text{dist}_i}{\max\_dist}\right)$$

$$\text{dist}_i = \sqrt{\sum_{d=1}^D (\text{gbest}_d - x_{i,d})^2}$$

$$\max\_dist = \underset{i}{\operatorname{argmax}}(\text{dist}_i)$$
(۸)

در رابطه بالا w_0 یک عدد تصادفی بین بازه $[0.5, 1]$ و dist_i فاصله اقلیدسی بین ذره i ام و بهترین موقعیتی که به‌وسیله کل جمع تجربه شده است، می‌باشد. D بعد فضای مسئله و $\max\_dist$ بیشترین فاصله یک ذره از بهترین موقعیت کل جمع، در هر نسل می‌باشد. این مدل‌اسیون ضریب اینرسی باعث می‌شود ذراتی که دور از بهترین موقعیت سراسری نقل مکان کرده‌اند، به سمت بهترین موقعیت کل جمع جذب شوند و به نقطه بهینه همگرا شوند. برای رسیدن به این نقطه بهینه صحیح و جلوگیری از همگرایی زودرس، باید از داشتن تحرک ذرات در مرحله‌های بعدی مطمئن شویم. برای رسیدن به این هدف، معادله به‌روزرسانی موقعیت‌ها به صورت زیر اصلاح می‌گردد:

$$x_{i,d}[t] = (1 - p) \cdot x_{i,d}[t-1] + v_{i,d}[t]$$
(۹)

در رابطه بالا p یک عدد تصادفی با توزیع یکنواخت در بازه $[-0.25, 0.25]$ است. در نتیجه با اضافه شدن این قسمت، ذرات دارای تحرک بیشتر، حتی زمانی که سرعت آن‌ها بسیار کم است، می‌شوند.

• آموزش شبکه عصبی با استفاده از الگوریتم PSO

در این قسمت درآمدهای مالیاتی به تفکیک منابع وصولی برای سالهای ۹۵-۱۳۹۲ با استفاده از روش شبکه‌های عصبی غیرخطی با استفاده از الگوریتم بهینه‌سازی ازدحام ذرات (PSO) پیش‌بینی شده است. همان‌طور که می‌دانیم الگوریتم PSO یک روش بهینه‌سازی مبتنی بر جمعیت

است که در آن ذرات به جست‌وجوی نقطه بهینه در فضای تصادفی می‌پردازند و حرکت این ذرات به سمت هدف توسط دو پارامتر سرعت و موقعیت اداره می‌شود. در ابتدا سرعت هر ذره با اضافه شدن مقدار اختلاف بین موقعیت فعلی ذرات و بهترین موقعیت قبلی خود و همچنین با اضافه کردن تفاوت بین موقعیت ذرات و بهترین موقعیت جهانی، به‌روز می‌شود و سپس در مرحله بعد، موقعیت ذرات با اضافه شدن این سرعت جدید به موقعیت فعلی به‌روز می‌شود. متغیرهای بهینه‌سازی در آموزش یک شبکه عصبی شامل وزن‌ها و بایاس‌های مربوط به شبکه می‌باشد. اگر لایه n ام از یک شبکه فرضی متشکل از R ورودی و M نرون باشد، آنگاه ماتریس وزن‌ها (W^n) و بایاسهای (B^n) این لایه را می‌توان با رابطه ۸ نشان داد:

$$W^n = \begin{bmatrix} (w_1^n)^T \\ (w_2^n)^T \\ \vdots \\ (w_M^n)^T \end{bmatrix}, \quad B^n = \begin{bmatrix} b_1^n \\ b_2^n \\ \vdots \\ b_M^n \end{bmatrix} \quad (10)$$

که در آن، $w_m^n = [w_{m,1}^n \ w_{m,2}^n \ \dots \ w_{m,R}^n]^T$ بردار وزنهایی است که نرون m ام از لایه M را به ورودی‌های همان لایه مربوط می‌کند. بردار پارامترهای این لایه را نیز می‌توان با رابطه ۹ نشان داد:

$$X^n = \begin{bmatrix} w_1^n \\ \vdots \\ \frac{w_M^n}{b_1^n} \\ \vdots \\ b_M^n \end{bmatrix} \quad (11)$$


به همین ترتیب برای هر لایه، ماتریس‌های وزن و بایاس و نیز بردار پارامترهای مربوطه تعریف می‌گردند. برای یک شبکه عصبی با L لایه، بردار متغیرهای X از رابطه ۱۰ بدست می‌آید:

$$X = \begin{bmatrix} X^1 \\ X^2 \\ \vdots \\ X^L \end{bmatrix} \quad (۱۲)$$

در واقع این بردار همان بردار موقعیت ذکر شده در رابطه ۱ است که مقدار بهینه آرگومانهای آن با استفاده از الگوریتم PSO محاسبه خواهد شد.

ابتدا N بردار موقعیت $(X_i, i=1,2,...,N)$ که N برابر با تعداد اعضای دسته (تعداد متغیرهای مسأله بهینه‌سازی) می‌باشد، بصورت تصادفی تولید می‌گردد. جمعیت دسته نیز معمولاً ۴ تا ۵ برابر تعداد متغیرهای بهینه‌سازی انتخاب می‌گردد. شبکه عصبی به ازای پارامترهایی برابر با متغیرهای این بردارها اجرا شده و خطای بدست آمده از هر اجرا به عنوان میزان برازندگی بردار متغیرها در نظر گرفته می‌شود. در این مرحله بردارهای P_i, P_g با توجه به برازندگی‌های بدست آمده محاسبه گردیده و N بردار موقعیت جدید با استفاده از روابط ۶ و ۷ تولید می‌گردد. این روند ادامه می‌یابد تا زمانی که همگرایی نهایی حاصل گردد. منظور از همگرایی نهایی رسیدن به بردار موقعیت بهینه به نحوی است که خطای آموزش به ازای آن کمینه گردد. در اجرای الگوریتم PSO، در این مقاله ضرایب c_1, c_2 به ترتیب برابر با ۱ و ۳ در نظر گرفته شده و وزن اینرسی w در ابتدا برابر با ۰/۴ در نظر گرفته شده که در طول تکرارها تدریجاً به سمت صفر میل می‌کند. از داده‌های درآمدهای مالیاتی سالهای ۸۶-۱۳۵۰ برای آموزش شبکه استفاده شده و الگوریتم برای تعداد دفعات قابل تنظیمی مثلاً ۱۲ بار در ۴ مرحله تکرار شده است. میانگین مقادیر بدست آمده از این تکرارها برای سالهای ۹۱-۱۳۸۷ به عنوان پاسخ در نظر گرفته شده و با داده‌های واقعی مقایسه شده است؛ سپس به منظور بررسی عملکرد و انتخاب شبکه مناسب از

دو معیار میانگین مجذور مربع خطا^۱ (RMSE) و میانگین قدر مطلق خطا^۲ (MAE) استفاده کرده که پس از تأیید نتایج این مرحله از شبکه نهایی برای پیش بینی برون نمونه ای درآمدهای مالیاتی به تفکیک منابع وصولی برای سالهای ۹۵-۱۳۹۲ استفاده شده است؛ همچنین جهت افزایش دقت پاسخها، داده های سالانه با استفاده از روش درونیابی غیرخطی به داده های ماهانه تبدیل شده است. نمودار ۱ نمونه ای از تکثیر داده های مالیات بر درآمد را برای سالهای ۹۱-۱۳۵۰ نشان می دهد.



نمودار ۱. تخمین داده های ماهانه با استفاده از داده های سالانه مالیات بر درآمد

جدول زیر مقدار دو معیار مجذور میانگین مربع خطا و میانگین قدر مطلق انحراف برای منابع مختلف مالیاتی را نشان می دهد.

-
1. Root Mean Squared Error
 2. Mean Absolute Error

پیش‌بینی درآمدهای مالیاتی با استفاده از الگوریتم بهینه‌سازی ازدحام ذرات (PSO) □ ۱۶۱


جدول ۱. مقدار معیارهای RMSE , MAE

برای مدل شبکه عصبی مصنوعی با آموزش PSO بهبودیافته


منابع	RMSE	MAD
مالیات کل	۰/۰۰۵۲۹۸	۰/۰۰۲۱۶
مالیات بر اشخاص حقوقی	۰/۰۲۱۴۶۶۹	۰/۰۰۸۷۶۳۸
مالیات بر درآمد	۰/۰۳۳۷۲۸	۰/۰۱۳۷۶۹
مالیات بر ثروت	۰/۰۲۹۹۴۲۷	۰/۰۸۱۷۹
مالیات بر کالا و خدمات	۰/۰۱۰۶۶۶	۰/۰۰۴۳۵۴۵

منبع: محاسبات تحقیق


پس از انتخاب مدل‌های بهینه، پیش‌بینی برون‌نمونه‌ای برای درآمدهای مالیاتی به تفکیک منابع وصولی طی سالهای ۹۵-۱۳۹۲ با استفاده از الگوریتم PSO بهبودیافته انجام می‌شود. در این بخش فقط به ذکر نتایج پیش‌بینی برون‌نمونه‌ای برای مالیات بر درآمد در قالب نمودار اکتفا شده است؛ نمودار ۲ پیش‌بینی مالیات بر درآمد را با استفاده از الگوریتم PSO و PSO بهبودیافته نشان می‌دهد. همانطور که در نمودار نیز مشاهده می‌شود مدل PSO بهبودیافته در دوره آزمون از نتایج بهتری برخوردار می‌باشد.



نمودار ۲. پیش‌بینی مالیات بر درآمد برای سالهای ۹۵-۱۳۹۲ با استفاده از الگوریتم PSO



نمودار ۳. پیش بینی مالیات بر درآمد برای سالهای ۹۵-۱۳۹۲ با استفاده از الگوریتم PSO



نمودار ۴. پیش بینی مالیات بر درآمد برای سالهای ۹۵-۱۳۹۲ با استفاده از الگوریتم PSO بهبود یافته

نتایج پیش‌بینی درآمدهای مالیاتی به تفکیک منابع وصولی برای سالهای ۹۵-۱۳۹۲ با استفاده از نسخه بهبودیافته الگوریتم تکاملی ازدحام ذرات به همراه ارقام بودجه در جدول ۲ آمده است. همانطور که در جدول نیز مشاهده می‌شود نتایج حاصل از پیش‌بینی درآمدهای

پیش‌بینی درآمدهای مالیاتی با استفاده از الگوریتم بهینه‌سازی ازدحام ذرات (PSO) □ ۱۶۳

مالیاتی برای سال ۱۳۹۲ تحقیقی بین (۹۲٪-۹۱٪) را نشان می‌دهد این در حالی است که سازمان امور مالیاتی با ۴۱۳۸۵۱٫۸ میلیارد ریال وصولی در سال گذشته توانسته ۹۱ درصد از تکالیف خود را محقق نماید که این رقم در بازه پیش‌بینی شده قرار دارد که این تاییدی بر عملکرد مناسب مدل‌های مورد استفاده می‌باشد؛ میزان وصولی در خصوص سایر منابع وصولی به استثناء مالیات بر اشخاص حقوقی همگی در بازه پیش‌بینی شده قرار دارد لذا با اطمینان بیشتری می‌توان نتایج مدل‌ها را برای سالهای ۹۵-۱۳۹۲ پذیرفت.

جدول ۲. پیش‌بینی درآمدهای مالیاتی به تفکیک منابع وصولی برای سالهای (۹۵-۱۳۹۱)
(میلیارد ریال)

منابع	مالیات کل	اشخاص حقوقی	مالیات بر درآمد	مالیات بر ثروت	کالا و خدمات
پیش‌بینی ۱۳۹۲	(۴۱۹۰۸۶٫۵-۴۱۳۶۳۳٫۶)	(۱۹۴۵۹۲٫۸-) (۱۸۳۲۹۳٫۵)	(۷۹۰۹۹-۷۵۳۹۱)	(۲۰۳۳۳٫۶-۲۱۲۶۸٫۴)	(۱۲۶۸۹۲٫۶-) (۱۳۸۵۷۹٫۱)
قانون بودجه ۱۳۹۲	۴۵۸۵۰۴	۲۳۱۵۷۲	۸۲۳۹۵	۲۰۹۰۰	۱۲۳۶۳۷
عملکرد	۴۱۳۸۵۱٫۸	۱۷۹۹۶۹	۷۶۰۶۷٫۸	۲۱۸۴۵٫۶	۱۳۵۹۶۹٫۱
پیش‌بینی ۱۳۹۳	(۴۷۹۰۴۵-۴۵۱۰۶۵)	(۲۱۶۹۷۵-) (۱۹۹۴۳۱)	(۹۶۳۶۳-۹۰۱۶۵)	(۲۴۰۴۹-۲۲۷۵۹)	(۱۵۴۲۵۸-) (۱۳۶۰۲۵)
قانون بودجه ۱۳۹۳	۵۹۸۶۳۱٫۶۷	۲۳۹۲۴۵٫۲۵۸	۱۰۲۴۰۷٫۴۵۵	۲۷۱۴۶٫۶۸۵	۲۲۹۸۳۲٫۲۷۴
پیش‌بینی ۱۳۹۴	(۴۹۲۹۵۱-۴۶۳۱۱۹)	(۲۷۰۲۷۲-) (۲۵۵۹۲۸)	(۱۰۹۲۱۶-۱۰۰۰۶۵)	(۲۶۳۱۱-۲۴۴۵۱)	(۱۷۲۴۱۹-) (۱۵۵۹۲۸)
پیش‌بینی ۱۳۹۵	(۵۵۷۰۴۱-۵۲۴۸۱۳)	(۳۰۳۵۷۹-) (۲۸۴۲۲)	(۱۰۹۲۳۹-۱۲۱۷۴۵)	(۲۹۷۹۶-۲۶۹۱۳)	(۲۱۲۶۴۷-) (۱۹۱۴۸۳)

۵. نتیجه‌گیری

در این مقاله درآمدهای مالیاتی کشور به تفکیک منابع وصولی که شامل مالیاتهای کل، کالا و خدمات، اشخاص حقوقی، درآمد و ثروت می‌باشد، برای سالهای ۹۵-۱۳۹۲ با استفاده از الگوریتم تکاملی ازدحام ذرات و نسخه بهبود یافته آن پیش‌بینی شده است. از داده‌های درآمدهای مالیاتی سالهای ۸۶-۱۳۵۰ برای آموزش شبکه استفاده شده و الگوریتم برای تعداد

دفعات قابل تنظیمی مثلاً ۱۲ بار در ۴ مرحله تکرار شده است. میانگین مقادیر بدست آمده از این تکرارها برای سالهای ۹۱-۱۳۸۷ به عنوان پاسخ در نظر گرفته شده و با داده‌های واقعی مقایسه شده است؛ سپس به منظور بررسی عملکرد و انتخاب شبکه مناسب از دو معیار میانگین مجذور مربع خطا (RMSE) و میانگین قدر مطلق خطا (MAE) استفاده کرده که پس از تأیید نتایج این مرحله از شبکه نهایی برای پیش‌بینی برون‌نمونه‌ای درآمدهای مالیاتی به تفکیک منابع وصولی برای سالهای ۹۵-۱۳۹۲ استفاده شده است؛ نتایج بدست آمده بیانگر کارایی بهتر روش‌های PSO بهبود یافته نسبت به روش PSO برای پیش‌بینی درآمدهای مالیاتی در دوره آزمون می‌باشد لذا از این روش برای پیش‌بینی برون‌نمونه‌ای درآمدهای مالیاتی استفاده شده است. مقایسه عملکرد سال ۱۳۹۲ با نتایج پیش‌بینی تاییدی بر عملکرد مناسب مدل مورد استفاده می‌باشد لذا نتایج پیش‌بینی مدل را با اطمینان بیشتری می‌توان پذیرفت.

منابع و مأخذ

- Hamidi ,S. (2006), Modeling and Forecasting Business Tax in Iran, Application of Neutral Nets, Graduate Dissertation, Ferdousi University , Mashhad , Iran
- Hamidi ,S , Khaloozade, H. (2010), Non Linear Modeling for forecasting Personal Tax , An application of Neutral Nets, Economic Research Centre, Ministry of Economics ,Iran
- Hamidi ,S , Khaloozade, H. Asadollahzade ,R. (2009), Forecasting Tax Revenues in fifth development plan, Tax Research center , Tehran, Iran
- Khaloozade, H. Khaki, A (2004). A survey of Stock Market Forecasting Methods, A non Linear Neural Nets , Journal of Economic Research, No.63 , pp43-85.
- Khaloozade, H., Hamidi ,S , Zaer, A. (2009), Non linear Modeling and Forecasting of Various Tax Revenues, The Second Tax Conference , Iran Tax Administration.
- Hamidi ,S , Zaer, A. Gholami,E. (2009), Methods of Tax Forecasting , Tax Research Centre , Iran Tax Administration.
- Arabmazar , A. Hamidi ,S , Zaer, A. Gholami,E. (2009), An Estimation of Tax Capacity, Tax Research Centre , Iran Tax Administration.
- Falahi, M.A. ,Khaloozade, H., Hamidi ,S ,(2007),Non Linear Modeling and Forecasting of Iran Business Tax , Journal of Economic Research, No.63 , PP. 143-167
- Ghetmiri , M.A., Islamlooian ,K. ,(2007) Iran Tax Capacity Estimation , Case of Selected Developing Countries, Research Project sponsored by Iran Tax Administration.
- Aminrashti,N. Rezaiee,G. (2010) Forecasting of Direct Tax Revenue In fifth Development Plan , Tax Journal , No.6 , PP. 67-82
- Monjazebe, M.R., Soleimani, P.(2006) Economic Research Letter , No.16 , pp.139-162
- Farzbod, J. Mollaiipour ,M. , Salimifar,M. (2002), Tax Potentiality of Khorasan , , Province, Case of Spare Parts, Economic Magazine , No.4-5, pp.7-11.
- Samati,M., Teyebi,S.K., Heidari,S. (2009), Impact of Government Revenue on Inflation and Real Growth of Iran Economy , Tax Journal , Iran Tax Administration , No.2 , pp.17-32
- Sarlak, A. ,(2007) Estimation of Tax Capacity in Markazi Province of Iran, Economic Magazine No. 61, pp15-40.

- Lezgi, F., Amini A. , Shomali ,L , Najafi A. (2009),, Forecast of Tax Revenue in Ghazvin Province , Journal of Research and Economic Policy, No.47 pp.121-153
- Abraham, B. and Ledolter, J. [1983]. Statistical Methods for Forecasting. Wiley, Hoboken, NJ.
- Durbin, J. and Watson, G. S. [1950]. Testing for serial correlation in least squares regression I. Biometrika, 37, 409--438.
- Chen, An-S. and Mark T. Leung (2004), "Regression Neural Network for error Correction in Foreign Exchange Forecasting and Trading", Elsevier, pp.1049-1068.
- Diebold, F.X. (1998),. "The Past, Present and Future of Macroeconomic Forecasting". Journal of Economic Perspectives, 12, 175-192
- Fllareiov, G.F and E.O. Averehenkov; "Using Neural Nets for Time Series Forecasting "; IEEE , pp. 249-253, 1999.
- Fllareiov, G.F. and E.O. Averehenkov (1999), "Using Neutral Nets for Time Series Forecasting", IEEE, pp. 249-253.
- Garliauskas, A.; "Neural Network Chaos and Computational Algorithms of Forecast in Finance "; IEEE, pp. 638-643, 1999.
- H. Choi, S. Ohmori, K. Yoshimoto and H. Ohtake, "Improvement of Particle Swarm Optimization" the 8th IEEE International Conference on Supply Chain Management and Information Systems, pp. 6-9 2010.
- J. Kennedy and R. Mendes, "population Structure and Particle Swarm Performance" in Proceeding of IEEE International Conference on Evolutionary Computation, pp. 1671-1676, 2002.
- J. Kennedy and R. C. Eberhart, "Particle Swarm Optimization" presented at the in Proceeding of the 4th IEEE International Conference on Neural Networks, 1995.
- K. Suresh, S. Ghosh, D. Kundu and A. Sen, "Inertia-Adaptive Particle Swarm Optimizer for Improved Global Search" 8th International Conference on Intelligent Systems Design and applications, vol. 2, pp. 26-28, Nov, 2008.
- M. Clerc and J. Kennedy, "The Particle Swarm: Explosion, Stability and Convergence in multi-dimensional complex space" IEEE Transactions on Evolutionary Computation, vol. 20, pp. 58-73, 2002.

- M. Qais, Z. Abdulvahid, "A New Method for Improving Particle Swarm Optimization Algorithm (TriPSO)" 5th International Conference on Modeling, Simulation and Applied Optimization, pp. 1-6, Apr, 2013.
- N. Nedjah and L. M. Mourelle, Swarm Intelligent Systems: Springer- Verilog Berlin Heidelberg, 2006.
- S. He, J. Wen, Y. Prempain and S. Mann, "An Improved Particle Swarm Optimization for Optimal Power Flow" in Proceeding of IEEE International Conference Power System Technology, vol. 2, pp. 1633-1637 2004.
- X. Hu, R. Eberhart, 'Solving Constrained Nonlinear Optimizatin Problem with Particle Swarm Optimization" Proc. The 6th World Multiconference on Systemics, Cybernetics and Informatics, pp. 203-206, 2002.
- Y. Shi and R. C. Eberhart, "A Modified Particle Swarm Optimizer" in Proceeding of IEEE International Conference on Evolutionary Computation, pp. 69-73, 1998.

Tax Revenues Forecasting By Applying PSO Optimization Algorithm

Morteza Asadi¹, Saeedeh Hamidi Alamdari²,
Hamid Khaloozadeh³*

Received: 2016/10/27

Accepted: 2017/11/25

Abstract

Forecasting tax revenues is vitally important issue for optimal allocation of taxable resources, planning and budgeting in national and regional levels and knowing the potential national participation in public expenditures. The classical optimization based on mathematical methods may not be reliable in real world and mostly inefficient and inapplicable in complicated world due to their restricted assumptions. The smart optimization may help us to find the solution. This essay based on modified PSO methodology. The initial trial based on the data during 1971- 2007 in case of various direct and indirect taxes , and using updated data during 2008- 2012 for final forecasting , to estimate tax revenues for upcoming next three years (2013 up to 2016) by MATLAB software.

Keywords: Tax, Forecast, Neural Net Modeling, Optimization, PSO and Modified PSO.

JEL Classification: H250.

1 . Faculty Member of Kharazmi University (Corresponding Author), Email: dr.asadi@khu.ac.ir

2 . Master of Economics, Kharazmi University, Email: hamidi_saeedeh@yahoo.com

3. Professor of Khaje Nasirooldin Tousi, Email: h_khaloozadeh@kntu.ac.ir