

## پیش بینی تقاضای گردشگری داخلی شهر تهران با استفاده از مدل‌های ترکیبی خلاقانه

ابتهال زندی<sup>۱</sup>

<sup>۱</sup> - دانشجوی دکتری مدیریت گردشگری دانشگاه علامه طباطبایی و عضو هیات علمی گروه مدیریت جهانگردی و هتلداری، دانشکده علوم انسانی دانشگاه آزاد اسلامی واحد تهران غرب [ebtehal.zandi@gmail.com](mailto:ebtehal.zandi@gmail.com)

### چکیده:

پیش بینی متغیرهای اقتصادی از اهمیت ویژه ای برای سیاستمداران و اقتصاددانان هر کشور به ویژه در حوزه گردشگری برخوردار است. در این مقاله، یک روش مؤثر مبتنی بر رویکرد شبکه عصبی مصنوعی برای پیش بینی سری زمانی تقاضای گردشگری داخلی شهر تهران ارائه شده است. سپس، این شبکه با استفاده از ۱۰ الگوریتم آموزشی موجود در تولباکس نرم افزار متلب آموزش داده شده و نتایج بدست آمده است. به منظور افزایش کارایی شبکه، از یک الگوریتم فراابتکاری به نام آموزش شبکه استفاده شده است. به منظور مقایسه دقت پیش بینی و بررسی کارایی رویکرد پیشنهادی، ابتدا معیار اندازه گیری عملکرد معرفی و سپس، از داده های واقعی مربوط به میزان تقاضای گردشگری داخلی شهر تهران برای پیش بینی استفاده شده است. نتایج حاصل از اجرای مدل به ازای الگوریتم‌های آموزشی ذکر شده نشان از برتری الگوریتم SVR نسبت به سایر الگوریتم‌های آموزشی دارد.

**واژگان کلیدی:** پیش بینی، سری های زمانی، شبکه عصبی مصنوعی، الگوریتم SVR، تقاضای گردشگری، گردشگری داخلی، شهر تهران.

### مقدمه:

اکثر تصمیمات مدیریت در تمام سطوح سازمان به طور مستقیم و یا غیر مستقیم به حالتی از پیش بینی آینده بستگی دارد و از طریق همین پیش بینی است که می توان یک موفقیت یا وضعیت در آینده را تجسم کرد و از این طریق ریسک را به حداقل ممکن رساند و یا هر گونه تعدیل و تطبیق در برنامه صورت داد (اینسکیپ، ۱۳۹۲: ۲۸).

صنعت گردشگری و سایر صنایعی که به دنبال موفقیت در کمک به ارتقاء سطح رفاه اقتصادی و اجتماعی شهروندی هستند. نیاز دارند که ریسک تصمیماتشان را کاهش دهند. البته، تمامی صنایع به این چنین کاهش ریسکی علاقه مندند. با این وجود، این نیاز ممکن است که به دلیل ماهیت و ویژگی‌های صنعت و فعالیت‌های گردشگری (غیر قابل ذخیره بودن، فناپذیر بودن و...)، برای صنعت گردشگری نسبت به صنایع عرضه کننده دیگر محصولات و خدمات، مبرم تر و حادثر باشد.

در واقع پیش بینی گردشگری، عبارت است از ایجاد رابطه بین تغییرات غیر قابل کنترل بازار و اقتصاد خارج از محیط گردشگری، با تغییرات قابل کنترل داخل محیط گردشگری. بنابراین، انجام عمل پیش بینی مستلزم مطالعه و تجزیه و تحلیل دقیق عوامل محیط خارج و داخل است. در بسیاری از موارد، مطالعه این عوامل با بررسی روند حرکت آنها در گذشته که از آمار و ارقام و

اطلاعات دوره‌های قبل قابل دسترسی است، امکان پذیر خواهد بود. اما باید توجه داشت که پیش بینی‌ها هرگز نمی‌توانند به طور صد درصد با آنچه که در عمل پیش خواهد آمد تطابق داشته باشند. همیشه فواصل و انحرافات بین مقادیر واقعی و پیش بینی موجود خواهد بود، ولی استفاده از روش‌های علمی و نوین در امر پیش بینی، باعث خواهد شد که نتایج حاصله به مراتب بیش از یک تخمین عینی به حقیقت نزدیک شوند.

از آنجایی که ماهیت روش‌های آماری به گونه‌ای است که در محیط‌های با تغییرات کم به خوبی قادر به پیش بینی هستند، اما در محیط‌های دارای اغتشاش نمی‌توانند تقریب خوبی از تغییرات محیطی را تخمین بزنند. از این رو، به روش‌هایی نیاز است که قابلیت حل چنین مشکلاتی را داشته باشد. شبکه عصبی مصنوعی به عنوان یکی از روش‌های محاسبات نرم از دقیقترین و محبوبترین روش‌های پیش بینی در مسائل مختلف به شمار می‌رود (شاردا<sup>۲</sup>، ۱۹۹۴). این روش دارای ویژگی‌های ارزشمند و قابل ملاحظه‌ای نسبت به سایر روشها است که برخی از آن‌ها عبارتند از (ژنگ و همکاران<sup>۳</sup>، ۱۹۹۸):

۱- شبکه‌های عصبی برخلاف روشهای سنتی و مرسوم، شبکه‌هایی خود تطبیقی و مبتنی بر داده‌ها هستند که در آن‌ها پی‌فرضهای کمی در مورد مدلهای به کار گرفته برای مسائل مختلف وجود دارد.

۲- شبکه‌های عصبی به آسانی قابل تعمیم هستند، به گونه‌ای که پس از یادگیری با استفاده از داده‌های نمونه، قادر هستند قسمت‌های مشاهده نشده از جمعیت را، حتی با احتمال وجود اغتشاش در داده‌های نمونه، به درستی استنتاج و استخراج کنند.

۳- شبکه‌های عصبی می‌توانند به عنوان تقریب زنده‌هایی عمومی و قوی برای توابع مختلف استفاده شوند. برخی از محققین مانند (فاناهاشی<sup>۴</sup>، ۱۹۸۹) (هورنیک و همکاران<sup>۵</sup>، ۱۹۸۹) نشان دادند که یک شبکه عصبی قادر است هر تابع پیوسته را با هر دقت، مورد انتظاری تقریب بزند و به طور کلی، شبکه‌های عصبی بسیار جامعتر و انعطاف پذیرتر از روشهای آماری سنتی برای تقریب توابع هستند.

۴- شبکه‌های عصبی غیرخطی هستند. روشهای سنتی پیش بینی، مانند روش ARIMA، بر این فرض استوارند که سریهای زمانی مبتنی بر فرآیندهای خطی هستند؛ درحالی که سیستمهای دنیای واقعی عمدتاً غیرخطی هستند.

از دیگر ویژگیهای شبکه‌های عصبی میتوان به قابل یادگیری بودن، قابلیت تعمیم، سرعت بالا به دلیل پردازشهای موازی، قابلیت سازگاری با تغییرات سیستم و ... اشاره نمود.

در یک شبکه عصبی، تعیین ساختار مناسب شبکه و انتخاب پارامترهای آن از اهمیت خاصی برخوردار است. همچنین، موفقیت شبکه‌های عصبی تا حد زیادی به دقت و کارایی الگوریتم‌های یادگیری آن بستگی دارد. برای یادگیری شبکه عصبی الگوریتم‌های مختلفی ارائه شده است که پرکاربردترین آن‌ها الگوریتم‌های مبتنی بر گرادیان به ویژه الگوریتم پس انتشار و الگوریتم

<sup>2</sup> Sharda

<sup>3</sup> Zhang et al

<sup>4</sup> Funahashi

<sup>5</sup> Hornik et al

لونبرگ مارکوارت (LM) هست. هرچند این الگوریتمها از توانمندی زیادی برخوردار است، اما وجود چندین ضعف عمده در آن ها، مشکلاتی را در برخی موارد برای کاربران ایجاد میکند.

الگوریتم های مبتنی بر گرادیان از تکنیکهای جستجوی محلی استفاده میکنند و از این رو، همواره در معرض گیر افتادن در نقاط بهینه محلی قرار دارند (پیغامی و خواندوسی، ۲۰۱۳). همچنین، الگوریتم LM از پیچیدگی محاسباتی بالایی برخوردار است و به حافظه زیادی برای محاسبات نیاز دارد. لذا به روشهایی نیاز است که مشکلات الگوریتم های مبتنی بر گرادیان را نداشته باشد. یکی از مناسبترین این روشها الگوریتم های تکاملی (EA) هستند. منظور از شبکه های عصبی تکاملی طراحی و آموزش شبکه های عصبی با استفاده از الگوریتمهای تکاملی هست. در سالهای اخیر، رویکردهای ترکیبی شبکه های عصبی و الگوریتمهای تکاملی توجه بسیاری به خود جلب کرده است. تاکنون، روشهای مختلفی برای ترکیب این دو تکنیک معرفی و مورد آزمایش قرار گرفته است که سه نوع اصلی آن عبارتند از (صدیقی و عادل، ۲۰۱۳):

**ترکیب حمایتی:** در این روش، شبکه های عصبی و الگوریتم های تکاملی به تناوب مورد استفاده قرار میگیرند، به گونه ای که یکی از آن ها به عنوان رویکرد اصلی و دیگری به عنوان رویکرد حمایتی مورد استفاده قرار میگیرد.

**ترکیب مشارکتی:** در این روش، هر دو رویکرد به طور همزمان و با هم به حل مسئله می پردازند.

**ترکیب آمیخته:** در این ترکیب، مکانیزم جستجوی الگوریتم تکاملی در الگویی از شبکه عصبی نمای داده میشود.

الگوریتم های تکاملی توانایی زیادی برای انجام جستجوی سراسری و پرهیز از قرار گرفتن در بهینه محلی دارند. البته برخی از الگوریتم های تکاملی، مانند الگوریتم ژنتیک، از سرعت همگرایی پایینی برخوردار هستند (پیغامی و خواندوسی، ۲۰۱۲). لذا، باید از الگوریتمهایی استفاده نمود که ضمن برطرف کردن مشکلات الگوریتمهای مبتنی بر گرادیان، از سرعت همگرایی مناسبی نیز برخوردار باشد. نمونه ای از این دسته الگوریتم ها، الگوریتم SVR است که علاوه بر حل مشکلات مربوط به الگوریتمهای مبتنی بر گرادیان، از توانمندی زیادی برای انجام جستجوی سراسری برخوردار است.

در سالهای اخیر با تغییر الگوی تعطیلات و شکل گیری تعطیلات کوتاه مدت، شهرها فرصتی برای توسعه گردشگری پیدا کردند. به همین دلیل مقصدهای شهری برای بدست آوردن و افزایش سهم خود در این بازار، با یکدیگر و همچنین با سایر انواع مقصدها مانند مقصدهای روستایی و تفرجگاهها رقابت میکنند (پیرس، ۲۰۰۱). با توجه به اینکه بسیاری از فعالیتهای گردشگری در بازار داخلی صورت میگیرد، عواملی مانند کوتاهی فاصله، آشنایی با زبان، اطمینان به امنیت ناشی از بومی بودن و صرفه جویی در هزینههای سفر، موجب گسترش گردشگری داخلی می شود (راسخی نژاد، ۱۳۸۸).

تحقیق حاضر سعی دارد که ابتدا، مدلهای شبکه عصبی و نحوه کاربرد آن ها در مسائل پیش بینی را معرفی کند و در ادامه، نقاط ضعف این مدلها را به ویژه در بخش آموزش شبکه بررسی و سپس از الگوریتم SVR برای بهبود فرآیند آموزش شبکه استفاده نماید و در انتها، مدل توسعه داده شده را در یکی از مباحث پیش بینی کاربردی در حوزه تقاضای صنعت گردشگری داخلی شهر تهران به کار گیرد و نتایج را مورد تحلیل و بررسی قرار دهد.

<sup>6</sup> -Pearce

### مبانی نظری و پیشینه پژوهش:

استفاده از شبکه های عصبی برای پیش بینی، با توجه به ماهیت غیرخطی بودن سیستمهای طبیعی، رشد فزایندهای را طی سالهای اخیر به خود گرفته است، به گونه ای که اکثر محققین دیگر تمایلی به استفاده از مدل‌های آماری سنتی برای پیش بینی از خود نشان نمی دهند. برخی از پژوهشگران به مقایسه مدل‌های ARIMA و شبکه های عصبی در پیش بینی سریهای زمانی در کاربردهای مختلف پرداخته اند به (حقیقت منفرد و همکاران، ۱۳۹۱)، (مکیان و موسوی، ۱۳۹۱)، (سالارپور و همکاران، ۱۳۹۱)، (لاشراس<sup>۷</sup>، ۲۰۱۵) (ولی پور و همکاران، ۲۰۱۳) مراجعه شود.

ایده اولیه به کارگیری شبکه های عصبی به عنوان ابزاری برای پیش بینی به سال ۱۹۶۴ برمیگردد؛ هو (۱۹۶۴) در پایان نامه اش از یک شبکه خطی تطبیقی ویدرو برای پیش بینی آب و هوا استفاده کرد. لازم به ذکر است که به علت فقدان الگوریتم‌های آموزشی برای شبکه های چند لایه در آن زمان، پژوه های مرتبط با مباحث پیش بینی به صورت کاملاً محدود انجام می شد، تا اینکه در سال ۷۷۹۵ الگوریتم پس انتشار (BP) توسط رومهارت<sup>۸</sup>، ۱۹۸۶ معرفی شد. وبراس<sup>۹</sup> (۱۹۷۴-۱۹۸۸) اولین بار الگوریتم پس انتشار را برای شبکه های عصبی به کار گرفت و نشان داد که شبکه هایی که با استفاده از الگوریتم پس انتشار آموزش دیده اند عملکرد بهتری نسبت به روشهای آماری سنتی مانند رگرسیون و ARIMA دارند. از اولین کاربردهای موفق شبکه های عصبی در مسائل پیش بینی میتوان به پژوه انجام شده توسط لپادس و فاربر (۱۹۸۸) اشاره کرد. آن ها با به کارگیری دو سری زمانی حاصل شده از نگاشت منطقی و معادله گلس مک کی، شبکه های عصبی پیشخور را طراحی کردند که با استفاده از آن قادر بودند سیستمهای غیرخطی پویا را با دقتی مناسب شبیه سازی و پیش بینی کنند. در زمینه استفاده از شبکه های عصبی در حوزه تقاضای گردشگری تحقیقات مختلفی انجام شده است. برای مثال، از مطالعات انجام گرفته با استفاده از روشهای هوش مصنوعی می‌توان به مطالعاتی چون لو و آیو (۱۹۹۹) مطالعه‌ای با عنوان «یک مدل شبکه عصبی جهت پیش بینی تقاضای ژاپنی‌ها برای مسافرت به هنگ کنگ»، چو (۲۰۰۳) مطالعه ای با عنوان «مقایسه سه رویکرد مختلف جهت پیش بینی ورودی‌های گردشگری» وانگ (۲۰۰۴) مطالعه ای با عنوان «پیش بینی تقاضای گردشگری با استفاده از سری‌های زمانی فازی و hybrid grey» پالمر و همکاران (۲۰۰۶) مطالعه ای با عنوان «طراحی یک شبکه عصبی مصنوعی برای پیش بینی سری‌های زمانی گردشگری» اشاره کرد. این تحقیقات هر کدام یا به نوعی از روش‌های شبکه‌های عصبی و یا منطق فازی بهره برده‌اند ولی تنها مطالعه یافت شده که از روش ترکیبی شبکه‌های عصبی فازی جهت پیش بینی تقاضای گردشگری استفاده کرده است پایان نامه دکتر پیریمان (۲۰۰۵) تحت عنوان پیش بینی عصبی-فازی ورودی‌های گردشگری می‌باشد که میزان تقاضا را با استفاده از روش‌های مختلف کلاسیک، اقتصاد سنجی و هوش مصنوعی برای مقصد گردشگری ژاپن پیش بینی کرده است.

در میان این مطالعات، مطالعاتی که توسط چن و ونگ (۲۰۰۷)، پای و همکاران (۲۰۰۶) و چن (۲۰۱۱) انجام گرفته است از روش رگرسیون بردار ساپورت (SVR) برای پیش بینی تقاضا گردشگری استفاده کرده‌اند. لازم به ذکر است که SVR در نتایج تجربی، عملکرد بهتری نسبت به مدل‌های پیش بینی سنتی همچون میانگین موثر انتگرالی اتورگرسیو داشته است.

<sup>7</sup> Lasheras

<sup>8</sup> Rumelhart et al

<sup>9</sup> Werbos

شن و سانگ (۲۰۱۱) شش روش ترکیبی را برای پیش بینی تقاضا گردشگری برون مرزی انگلستان در هفت کشور مقصد ارایه دادند. نتایج عددی ثابت می‌کند که روشهای ترکیبی عموماً عملکردهای بهتری داشته‌اند.

چن (۲۰۱۱) مدل‌های ریاضیاتی خطی و غیرخطی را برای پیش بینی گردشگری برون مرزی تایوان ترکیب کرد. نتایج تجربی نشان می‌دهد که مدل‌های ترکیبی SVR دارای قابلیت آشکارسازی تغییر هدایتی فوق العاده‌ای هستند. آکین (۲۰۱۵) در تحقیق خود با عنوان «ارایه یک رویکرد جدید در انتخاب مدل به منظور مدل سازی تقاضای گردشگری» از طریق ترکیب روش‌های شبکه عصبی و رگرسیون بردار ساپورت (SVR) و ARIMA داده‌های گردشگران ورودی ماهانه به ترکیه از کشورهای مختلف را بررسی کرده است که نتایج نشان داد دقت پیش بینی روش SVR از دو روش دیگر بیشتر است.

ونگ و لی (۲۰۱۵) در تحقیق خود با عنوان «بررسی پیش بینی جریان گردشگری بر اساس مدل PSO-SVR فصلی» به منظور از بین بردن تاثیر فصلی بودن جریان گردشگری با ترکیب دو روش SVR و PSO مدل PSO-SVR را پیشنهاد داده‌اند که درجه برازش مدل‌های پیش بینی‌های مختلف نشان می‌دهد که دقت پیش بینی مدل PSO-SVR فصلی به طور قابل توجهی بالاتر از مدل SVR، مدل فصلی و مدل PSO-SVR است.

شنگ لو و ژانگ<sup>۱۰</sup> (۲۰۰۹) در تحقیق خود با عنوان «پیش بینی تقاضای گردشگری از طریق الگوریتم SVR و ژنتیک» به منظور پیش بینی تقاضای گردشگری سه روش الگوریتم SVR، الگوریتم ژنتیک و ترکیب این دو یعنی G-SVR را بررسی کرده که نتایج نشان داد دقت پیش بینی روش G-SVR از دو روش دیگر بیشتر است.

#### به کارگیری شبکه عصبی مصنوعی برای پیش بینی سری‌های زمانی:

امروزه، شبکه‌های عصبی مصنوعی در مسائل مختلفی از دنیای واقعی به کار گرفته می‌شوند. از شناخته شده ترین کاربردهای شبکه‌های عصبی می‌توان به تقریب توابع، دسته بندی و خوشه بندی اطلاعات، ذخیره و بازبینی داده‌ها، بهینه سازی مسائل مقید، تعقیب مسیر و . . . اشاره کرد. یکی از مهم ترین کاربردهای شبکه عصبی مصنوعی این است که از آن می‌توان به عنوان یک ابزار قوی برای پیش بینی سریهای زمانی استفاده کرد.


رویکردهای مختلفی برای بکارگیری شبکه‌های عصبی برای مسائل پیش بینی وجود دارد و سری زمانی به فرم عمومی زیر است:

$$X_t = f(X_{t-1}, X_{t-2}, \dots, X_{t-k}) \quad (1)$$

که در آن  $X_{t-1}$ ،  $X_{t-2}$ ، . . . و  $X_{t-k}$  متغیرهای وابسته و  $X_t$  متغیر مستقل است. شبکه‌های عصبی میتوانند آموزش دیده شوند تا یک یا چند متغیر مستقل را پیش بینی نمایند که البته دقت پیش بینی وابستگی زیادی به آموزش مناسب شبکه دارد. MLFF-NN نوعی شبکه است که از یک لایه ورودی به منظور دریافت اطلاعات، یک یا چند لایه پنهان و یک لایه خروجی به منظور ارائه جواب نهایی تشکیل شده است و دارای توانمندی‌های زیادی برای مسائل پیش بینی است. نمونه‌ای از یک شبکه-MLFF-NN با ارتباط کامل بین گره‌ها در شکل (۱) نمایش داده شده است. قبل از به کارگیری شبکه عصبی برای پیش بینی، ابتدا باید

<sup>10</sup> - Sheng Lu & Zhang

داده های ورودی مسئله دسته بندی شود. در مقاله حاضر از رویکرد معرفی شده توسط (خلیلی دامغانی و سعدی نژاد، ۲۰۱۱) برای دسته بندی ورودیها استفاده میشود.



شکل (۱): نمونه‌ای از یک شبکه پیشخور دو لایه با ارتباط کامل بین گره‌ها

لازم به ذکر است که ساختار شبکه عصبی از قبل تعریف میشود و در طی اجرای برنامه تغییر نمی کند و همواره ثابت است، درحالی که، وزن های شبکه باید به صورت یک مسئله جستجوی بهینه سراسری فرموله شوند. ساختن یک شبکه عصبی پیش بینی کننده نیازمند اتخاذ تصمیمات مهمی است که هر یک از آن ها در اینجا تشریح می شود:

- **تعداد گره های ورودی:** برای مسائل پیش بینی سریهای زمانی، معمولاً تعداد گره های ورودی برابر تعداد متغیرهای وابسته استفاده شده در فرم عمومی مدل پیش بینی (مدل (۱)) در نظر گرفته میشود (ژنگ و همکاران، ۱۹۹۸).

- **تعداد گره های خروجی:** در شبکه های پیش بینی کننده، تعداد گره های خروجی معمولاً برابر با افق زمانی پیش بینی مسئله مورد بررسی در نظر گرفته میشود. همچنین دو نوع پیش بینی به صورت یک گام به جلو و چند گام به جلو وجود دارد که هر دو به صورت تکراری یا مستقیم قابل پیاده سازی هستند (ژنگ و همکاران، ۱۹۹۸) و (ژنگ، ۱۹۹۴).

- **تعداد لایه های پنهان و گره های آن:** اکثر محققین مانند (هورنیک و همکاران، ۱۹۸۹، پیغامی و خوانزاده، ۲۰۱۳-۲۰۱۱) فقط یک لایه پنهان را برای شبکه های پیش بینی کننده در نظر میگیرند. آن ها معتقدند که شبکه های دارای یک لایه پنهان قادرند که هر تابع غیرخطی پیچیده را با هر دقت مورد نظری تخمین بزنند. برخی از محققین از دو لایه پنهان برای شبکه های پیش بینی کننده استفاده میکنند (ژنگ، ۱۹۹۴) (شاردا، ۱۹۹۴). لازم به ذکر است که اکثر محققین گذشته، از رویکردهای تجربی و سعی و خطا برای تعیین تعداد لایه های پنهان شبکه استفاده کرده اند. برای تعیین تعداد گره های لایه پنهان نیز رویکرد مشخصی وجود ندارد و عمده روشها مبتنی بر سعی و خطا هست (چه، ۲۰۱۰) پیشنهاد کرد که تعداد بهینه گره های لایه پنهان، عددی بین نصف مجموع گره های لایه های ورودی و پنهان و دو برابر گره های لایه ورودی انتخاب شود.

ژنگ و همکاران، ۱۹۹۸ عقیده داشتند که اگر تعداد گره های لایه پنهان برابر تعداد گره های لایه ورودی در نظر گرفته شود نتایج بهتری از شبکه حاصل میگردد: لیپمن (۱۹۸۷) پیشنهاد کرد که تعداد اتم های لایه پنهان برابر  $2n+1$  در نظر گرفته شود. که  $n$  تعداد اتمهای لایه ورودی هست.

- ارتباط بین گره ها**: به طور کلی، ارتباط بین گره های لایه های مختلف مشخص کننده رفتار شبکه هست. در مسائل پیش بینی سری زمانی معمولاً شبکه به صورت ارتباط کامل در نظر گرفته می شود (پیغامی و خوانزاده، ۲۰۱۱، ۲۰۱۲، ۲۰۱۳).
- تابع انتقال**: این تابع که تابع فعالسازی نیز نامیده میشود، مشخص کننده رابطه بین ورودی ها و خروجی های گره هست. توابع انتقال زیادی وجود دارد که در عمل، فقط تعدادی از آن ها شامل توابع سیگموئید، تانژانت هیپربولیک، سینوس یا کسینوس و توابع خطی مورد استفاده قرار می گیرد.
- تعداد نمونه برای آموزش و آزمایش**: در هر شبکه عصبی، مجموعه داده ها باید به دسته مجموعه آموزش و مجموعه آزمایش تقسیم شوند. مجموعه آموزش برای توسعه مدل شبکه و مجموعه آموزش برای ارزیابی توانایی مدل به منظور پیش بینی کردن استفاده میشود. در برخی موارد، مجموعه سومی به نام مجموعه اعتبار برای تصدیق مدل در نظر گرفته می شود که معمولاً این مجموعه با مجموعه آزمای یکی در نظر گرفته می شود. لازم به ذکر است که میزان تقسیم داده های اولیه به دو (سه) مجموعه فوق یکی از پارامترهای اصلی شبکه های عصبی هست.
- الگوریتم های آموزشی**: پرکاربردترین الگوریتم برای آموزش شبکه های عصبی الگوریتم پس انتشار هست. البته در سالهای اخیر، از الگوریتم های تکاملی و نیز الگوریتم های ترکیبی برای آموزش شبکه استفاده شده است.
- نرمالسازی داده ها**: برخی توابع انتقال، تنها بازه های خاصی را برای داده های ورودی قبول می کنند. از اینرو، باید از رویکردهایی برای تبدیل داده های ورودی به بازه های موردنظر استفاده نمود که بتوان شرایط اولیه به کارگیری آن تابع را فراهم کرد. نرمال سازی خطی و نرمالسازی آماری از مهم ترین روشهای این دسته هستند.
- سنجه های عملکرد**: به طور کلی سنجه های عملکرد دقت، مبتنی بر خطای پیش بینی به دست آمده از اختلاف بین مقادیر واقعی و مقادیر پیش بینی شده هست. مهم ترین سنجه های عملکرد در شبکه های عصبی عبارت اند از: مجموع مربعات خطا، میانگین مربعات خطا، جذر میانگین مربعات خطا، میانگین انحرافات مطلق و میانگین درصد خطای مطلق.

### فرضیه ها و روش تحقیق:

در این تحقیق فرضیه اصلی عبارت است از: برای مسئله تحقیق حاضر، خطای پیش بینی حاصل کوچک تر از یا مساوی خطای پیش بینی SVR از مدل شبکه عصبی آموزش دیده توسط الگوریتم حاصل از مدل شبکه عصبی آموزش دیده توسط ۱۰ الگوریتم جدول (۱) (موجود در تولباکس نرم افزار متلب) است. منظور از خطای پیش بینی در عبارت فوق، خطای تعریف شده به صورت زیر است:

$$error = \frac{RMSE(Data\_Test)}{2} * 100$$

به طوری که  $Data\_Test$  نشان دهنده داده های مربوط به بخش آزمایش هست. برای آزمون فرضیه اصلی، ده فرضیه آماری تدوین می گردد که در ذیل، یکی از آن ها نوشته شده است:



H0: برای مسئله تحقیق حاضر، خطای پیش بینی حاصل از مدل شبکه عصبی آموزش دیده توسط الگوریتم SVR کوچک تر از یا مساوی خطای پیش بینی حاصل از مدل شبکه عصبی آموزش دیده توسط الگوریتم LM (trainlm) است.

H1: برای مسئله تحقیق حاضر، خطای پیش بینی حاصل از مدل شبکه عصبی آموزش دیده توسط الگوریتم SVR بزرگ تر از خطای پیش بینی حاصل از مدل شبکه عصبی آموزش دیده توسط الگوریتم LM (trainlm) است.

لازم به ذکر است که نه فرضیه آماری دیگر، مانند فرضیه فوق است و فقط به جای الگوریتم LM (trainlm) از الگوریتم‌های دیگر جدول (۱) استفاده میشود.

جدول (۱): الگوریتم‌های استفاده شده برای آموزش شبکه عصبی پیش‌بینی کننده  
(موجود در توبلاکس متلب)

نام اختصاری الگوریتم	نام کامل الگوریتم
trainlm	Levenberg-Marquardt backpropagation
traingd	Gradient descent backpropagation
traingdx	Gradient descent with momentum and adaptive learning rate backpropagation
traingda	Gradient descent with adaptive learning rate backpropagation
traingdm	Gradient descent with momentum backpropagation
trainb	Batch training with weight and bias learning rules
trainbfg	BFGS quasi-Newton backpropagation
trainbr	Bayesian regulation backpropagation
trainoss	One-step secant backpropagation
trainrp	Resilient backpropagation

پژوهش حاضر از نوع مقایسه ای هست که با استفاده از داده های پس رویدادی جمع آوری شده به روش کتابخانه ای، فرضیات آزمون شده است. تحقیق حاضر از نظر مکانی محدود به داده‌های گردشگری داخلی شهر تهران در طول سال‌های گذشته (سال ۱۳۸۰ تا ۱۳۹۴) تشکیل می‌دهد. همچنین قلمرو موضوعی آن، پیش بینی سری زمانی میزان تقاضای گردشگری داخلی شهر تهران در بازه زمانی ذکر شده است.

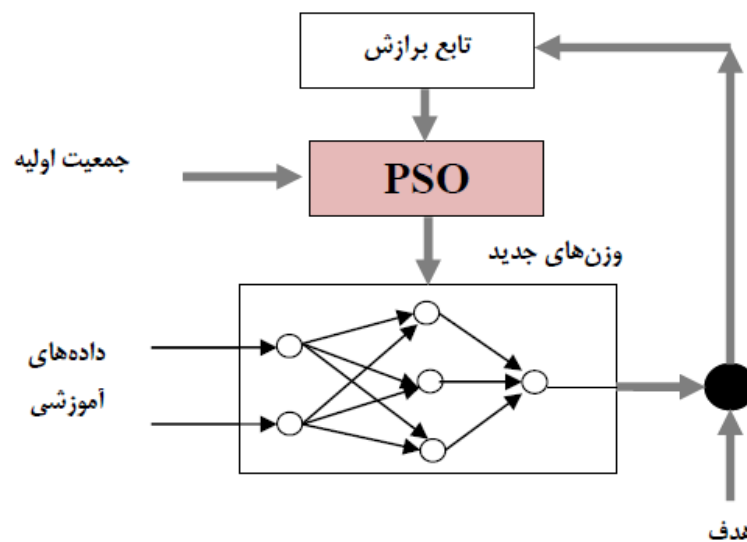
### مدل ترکیبی شبکه عصبی و الگوریتم SVR:

#### - آموزش شبکه عصبی:

هر شبکه عصبی باید آموزش دیده شود تا مقادیر مناسب وزنه‌های شبکه تعیین گردد. دانش فراگرفته شده، به صورت وزن کمان و اربیبی گره‌ها در شبکه ذخیره میشود (ژنگ و همکاران، ۱۹۹۸). فرآیند آموزش شبکه مانند یک مدل برنامه ریزی غیرخطی است که تابع هدف آن از سنج‌های عملکرد تشریح شده در بخ قبل (مانند MSE و SSE) انتخاب میشود و هدف آن یافتن وزن



کمان های شبکه است، به گونه ای که سنجه های عملکرد کمینه گردد. در شبکه های عصبی از آن جهت به یادگیری نیاز است که ارتباط بین ورودی ها و خروجی های شبکه به طور دقیق و کامل مشخص نیست (فروغی و همکاران، ۱۳۹۲). روش های مختلفی برای آموزش شبکه های عصبی وجود دارد که پرکاربردترین آنها تکنیک های مبتنی بر گرادیان است. همانطور که در بخش مقدمه تشریح شد، این روش ها دارای معایب مختلفی هستند. از این رو، محققین برای برطرف کردن این معایب از روشهای دیگری برای آموزش شبکه استفاده می کنند که از مهم ترین آن ها میتوان به الگوریتم های فرا ابتکاری اشاره کرد. در تحقیق حاضر، از الگوریتم SVR برای آموزش شبکه استفاده شده است. رویه به کارگیری این الگوریتم در آموزش شبکه در شکل (۲) به تصویر کشیده شده است.



شکل (۲): فرآیند آموزش شبکه عصبی با استفاده از الگوریتم PSO

#### - الگوریتم SVR (رگرسیون بردار پشتیبان):


این روش مستقیماً از نظریه یادگیری آماری وپنیک به نام ماشین های بردار پشتیبان (SVM) استخراج شده است. ماشین های بردار پشتیبان برای مسائل طبقه بندی به کار می روند (وپنیک، ۱۹۹۵) بعدها الگوریتم آنها برای کار با مسائل رگرسیون با تخمین داده ها توسعه یافت. این الگوریتم جدید رگرسیون بردار پشتیبان (SVR) نامیده شد (سمولا، ۱۹۹۸). شرح مختصر روش در ادامه آمده است:

فرض کنیم مجموعه ای از داده ها به شکل  $(x_i, y_i)_{1 \leq i \leq l}$  داریم که  $x \in R^n$  و  $y \in R$ . یعنی هر داده دارای  $n$  بُعد است (یک بردار  $n$  بُعدی است) و متناظر با هریک از این داده ها یک مقدار اسکالر  $y$  نیز در اختیار داریم. ساده ترین تابع تخمین گر را به صورت  $f(x) = w^T x + b$  می نویسیم به طوری که رابطه بین داده های برداری  $x$  و مقادیر خروجی  $y$  را به بهترین شکل ممکن و با کمترین خطای ممکن تخمین بزند، به عبارت دیگر هدف پایین آوردن رابطه (۱) است.

$$R_{emp} = \frac{1}{N} \sum_{k=1}^N |y_k - w^T I_k - b|_c \quad \text{رابطه (۱) تابع ریسک}$$

عبارت داخل سیگما در عبارت فوق تابع هزینه وپنیک نام دارد و تابعی به شکل رابطه (۲) و نمودار شماره ۱ است.

$$|y - f(x)|_{\varepsilon} = \begin{cases} 0 & \text{if } |y - f(x)| \leq \varepsilon \\ |y - f(x)| - \varepsilon & \text{otherwise} \end{cases} \quad \text{رابطه (۲) تابع هزینه وپنیک.}$$



نمودار (۱): تابع هزینه وپنیک.

هدف ما پیدا کردن بردار  $w$  و مقدار اسکالر  $b$  به گونه‌ای است که شرایط رابطه (۳) را برآورده کنند.


$$\min_{w, b, \xi, \xi^*} J_P(w, \xi, \xi^*) = \frac{1}{2} w^T w + c \sum_{k=1}^N (\xi_k + \xi_k^*) \quad \text{رابطه (۳)}$$

$$y_k - w^T x_k - b \leq \varepsilon + \xi_k, \quad k = 1, \dots, N$$

$$w^T x_k + b - y_k \leq \varepsilon + \xi_k^*, \quad k = 1, \dots, N$$

$$\xi_k, \xi_k^* \geq 0, \quad k = 1, \dots, N$$

برای درک بهتر این مسئله بهینه‌سازی، کافی است به نمودار (۲) توجه شود:



نمودار (۲) رگرسیون بردار پشتیبان

مطابق این شکل در حالی که مقدار  $\varepsilon$  را باید ثابت در نظر بگیریم، مقدار حاشیه را باید تا جایی که امکان دارد افزایش دهیم و در عین حال برش عرضی لوله مشخص شده در تصویر به گونه‌ای باشد که مقدار عرض برش آن در راستای محور  $y$ ها (محور عمودی) از  $2\varepsilon$  تجاوز نکند. به بیان ساده، به دنبال لوله‌ای هستیم که حتی‌الامکان تمام داده‌ها را پوشش دهد ولی برش عرضی آن در راستای محور  $y$ ها از مقدار  $2\varepsilon$  تخطی نکند. در این مسئله بهینه‌سازی پارامتر  $C$  بیان‌گر هزینه تخطی یا خارج کردن نمونه‌ها از

داخل لوله است و مقدار نويز در داده‌ها را نشان می‌دهد. این مسئله با استفاده از روش ضرایب لاگرانژ قابل حل است که پس از انجام محاسبات لازم و ساده‌سازی روابط، دوگان مسئله فوق به صورت زیر به دست می‌آید:

$$\max_{a_k^*} J_D(a_k^*) = -\frac{1}{2} \sum_{k,i=1}^N (a_k - a_k^*)(a_i - a_i^*) x_k^T x_i - \varepsilon \sum_{k=1}^N (a_k + a_k^*) + \sum_{k=1}^N y_k (a_k - a_k^*) \quad \dots, N$$

رابطه (۴)

به طوری که:

$$\sum_{k=1}^N (a_k - a_k^*) = 0 \quad a_k a_k^* \in [0, c].$$

رابطه (۵)

و در نهایت تابع تخمین‌گر به صورت رابطه (۶) معرفی می‌شود:

$$f(x) = \sum_{k=1}^N (a_k + a_k^*) x_k^T x + b$$

رابطه (۶)

که در آن که  $a_i$  و  $a_i^*$  چند جمله‌های لاگرانژ و جواب‌های مسئله بهینه‌سازی هستند حال اگر داده‌ها به صورت غیرخطی باشند می‌تواند از توابع کرنل برای به‌دست آوردن تابع تخمین‌گر استفاده کرد یعنی:

$$f(x) = \sum_{k=1}^N (a_k - a_k^*) K(x, x_k) + b$$

رابطه (۷)

که در آن  $k(x_i, x_j)$  یک تابع کرنل است و فضای ویژگی‌های بهترین راه‌حل مسئله بهینه‌سازی را تعریف می‌کند.

روش SVR برای مساله پیش‌بینی تقاضا گردشگری مناسب بوده و اینکه روش‌های ترکیبی می‌توانند عملکرد بهتری را ارائه دهند. در سال‌های اخیر بطور گسترده‌ای مورد استفاده قرار گرفته و مدل موثری در پیش‌بینی تقاضا گردشگری است. در SVR از یک اصل حداقل سازی خطر ساختاری استفاده می‌کنند که این اصل تلاش دارد تا محدوده‌های بالاتر خطای تعمیم را بجای کاهش خطای آموزش به حداقل برساند.

### نتایج شبیه‌سازی:

برای ساختن شبکه عصبی، از یک شبکه عصبی پی‌خور دو لایه با ارتباط کامل بین گره‌ها استفاده شده است. سایر اطلاعات شبکه در جدول (۲) نشان داده شده است.

جدول (۲): ویژگی‌های ساختار شبکه


بازه نرمال	اندازه داده‌ها:	توابع انتقال:	گره‌های لایه ورودی	گره‌های لایه مخفی	گره‌های لایه خروجی
سازای داده‌ها	آموزش، آزمایش	لایه مخفی و لایه خروجی	۴	۹	۱
[-1,1]	%۲۰، %۸۰	Tansig & purelin			

برای اجرای شبکه عصبی به ازای الگوریتم‌های جدول (۱) و الگوریتم SVR از نرم افزار MATLAB r2013a استفاده شده است. خطای پیش‌بینی حاصل از اجرای شبکه عصبی به ازای الگوریتم‌های آموزشی جدول (۱) و همچنین الگوریتم SVR در جدول (۲) نشان داده شده است. البته، لازم به ذکر است که به منظور کاهش انحرافات تصادفی، برنامه به ازای هر الگوریتم ۳۰ مرتبه


تکرار شده و میانگین جواب های حاصل در جدول (۳) لحاظ شده است. شکل های ۳ و ۴ نیز به ترتیب، خروجی شبکه را به ازای داده های بخش آموزش و آزمایش نشان می دهد.

جدول (۳): خطای پیش بینی به ازای الگوریتم های آموزشی جدول (۱) و هم چنین الگوریتم PSO

شماره	الگوریتم	میزان خطا
۱	trainlm	۱۱/۷۴۸۸
۲	traingd	۸/۶۱۹۵
۳	traingdx	۶/۰۶۸۷
۴	traingda	۶/۶۶۳۷
۵	traingdm	۸/۴۳۳۵
۶	trainb	۱۵/۲۱۳۴
۷	trainbfg	۱۵/۹۸۷۷
۸	trainbr	۹/۱۲۱۹
۹	trainoss	۹/۱۵۳۵
۱۰	trainrp	۷/۴۲۶۱
۱۱	PSO	۵/۳۵۷۲



شکل (۳): خروجی شبکه به ازای داده های بخش آموزش



شکل (۴): خروجی شبکه به ازای داده‌های بخش آزمایش

با توجه به مقادیر میزان خطا در جدول (۲)، مشاهده می‌شود که شبکه آموزش دیده با استفاده از الگوریتم SVR دارای خطای کمتری نسبت به ۱۰ الگوریتم دیگر هست و این، حاکی از آن است که هر ۱۰ فرضیه تحقیق پذیرفته می‌شود.

#### نتیجه گیری:

برای انجام پیش بینی، مدل‌های مختلفی در چند دهه اخیر معرفی شده است. مدل‌های آماری سنتی مانند ARIMA از توانایی بالایی برای پیش بینی در محیط‌های دارای اغتشاش برخوردار نیستند. شبکه‌های عصبی ابزار توانمندی برای پیش بینی هستند که برخلاف روشه‌ای آماری سنتی، قادرند سیستم‌های دارای ساختار غیرخطی را نیز تقریب بزنند و در آن‌ها پیش فرضهای کمی در مورد مدل‌های به کار گرفته برای مسائل مختلف وجود دارد. این شبکه‌ها قادر هستند هر تابع پیوسته را با هر دقت مورد انتظاری تقریب بزنند و به طور کلی، بسیار جامع‌تر و انعطاف پذیرتر از روشهای آماری سنتی برای تقریب توابع هستند. علی‌رغم همه توانمندی‌های شبکه‌های عصبی، وجود مشکلاتی در بخش آموزش این شبکه‌ها پژوهش‌گران را همواره بر آن داشته است که از رویکردهای جانشین مناسبی برای آموزش شبکه استفاده کنند. الگوریتم‌های آموزشی پایه شبکه عصبی عمدتاً مبتنی بر روش گرادیان هستند که از تکنیک‌های جستجوی محلی استفاده می‌کنند و از این رو، همواره در معرض گیر افتادن در نقاط بهینه محلی قرار دارند. همچنین برخی از انواع این الگوریتم‌ها مانند الگوریتم LM به حافظه زیادی برای محاسبات نیاز دارند. برای رفع این مشکلات، در تحقیق حاضر از یک الگوریتم فرا ابتکاری به نام SVR برای آموزش شبکه استفاده شده است که نتایج به کارگیری این الگوریتم در پیش بینی تقاضای گردشگری داخلی شهر تهران، حاکی از برتری آن نسبت به الگوریتم‌های مبتنی بر گرادیان دارد.

## منابع:

- اینسکیپ، ادوارد (۱۳۹۲). برنامه ریزی گردشگری رویکردی یکپارچه و پایدار به برنامه ریزی و توسعه گردشگری، ترجمه محمود حسن پور و سعید داغستانی، تهران: مهکامه
- حقیقت منفرد، جلال، احمدعلی نژاد، محمود، متقالجی، سارا. (۱۳۹۱) مقایسه مدل‌های شبکه عصبی با مدل سری زمانی باکس جنکینز در پیش بینی شاخص کل قیمت سهام بورس اوراق بهادار تهران. مجله مهندسی مالی و مدیریت اوراق بهادار، ۱۱-۱۶ صص ۱-۱۶.
- راسخی نژاد، آرزو (۱۳۸۸)، تخمین تابع تقاضای گردشگری داخلی در ایران، پایان‌نامه تحصیلی کارشناسی‌ارشد، دانشگاه تربیت مدرس، دانشکده علوم انسانی، تهران.
- سالارپور، ماشا. . . ، نجاری، جعفر، سیدآقاحسینی، سیدمحسن، صبحی، محمود. (۱۳۹۱) پیش بینی صادرات غیر نفتی ایران تحت تاثیر تغییرات نرخ ارز با استفاده از مدل شبکه پرسپترون چندلایه. دوفصلنامه اقتصادپولی، مالی (دانش و توسعه سابق)، (۴) ۱۹-صص ۱۰۱-۱۲۱.
- فروغی، داریوش، فروغزاد، حیدرومیرزایی، منوچهر. (۱۳۹۲) پیش بینی سود هر سهم: ترکیب شبکه های عصبی مصنوعی و الگوریتم بهینه سازی حرکت جمعیتی ذرات. فصلنامه علمی و پژوهشی سرمایه گذاری، ۶، صص ۸۳-۶۳.
- مکیان، سیدنظام الدین، موسوی، فاطمه السادات. (۱۳۹۱)، پیش بینی قیمت سهام شرکت فرآورده های نفتی پارس با استفاده از شبکه عصبی و روش رگرسیون، مطالعه موردی: قیمت سهام شرکت فرآورده های نفتی پارس. فصلنامه مدل سازی اقتصادی، ۱۸، صص ۱۲۱-۱۰۵.
- Akin, M(2015), A Novel Approach to Model Selection in Tourism Demand Modeling, Tourism Management journal, Vol 48. Elsevier.
- Che, Z. (2010). PSO-based back-propagation artificial neural network for product and mold cost estimation of plastic injection molding. *Computers & Industrial Engineering*, 58(4), 625-637.
- Chen, K. -Y. , & Wang, C. -H. (2007). Support vector regression with genetic algorithms in forecasting tourism demand. *Tourism Management*, 28, 215-216.
- Chen, K. -Y. (2011). Combining linear and nonlinear model in forecasting tourism demand. *Expert Systems with Applications*, 38, 10368-10376.
- Funahashi, K. I. (1989). On the approximate realization of continuous mappings by neural networks. *Neural networks*, 2(3), 183-192.
- Hornik, K. , Stinchcombe, M. , & White, H. (1989). Multilayer feedforward networks are universal approximators. *Neural networks*, 2(5), 359-366.
- Hu, M. J. C. (1964). *Application of the adaline system to weather forecasting*. (Master Thesis). Technical Report 6775-1. Stanford Electronic Laboratories. Stanford. CA. June.
- Khalili-Damghani, K. , & Sadi-Nezhad, S. (2011). Application of multi-layer recurrent neural network in chaotic time series prediction: a real case study of crude oil distillation capacity. *International Journal of Artificial Intelligence and Soft Computing*, 2(4), 367-380.
- Lapedes, A. , & Farber, R. (1988). How neural nets work. In: Anderson, D. Z. (Ed. ). *Neural Information Processing Systems*. American Institute of Physics. New York, 442-456.
- Lasheras, F. S. , de Cos Juez, F. J. , Sánchez, A. S. , Krzemień, A. , & Fernández, P. R. (2015). Forecasting the COMEX copper spot price by means of neural networks and ARIMA models. *Resources Policy*, 45, 37-43.
- Law, R and Au, N. (1999). A Neural network model to forecast Japanese demand for travel to Hong Kong. *Tourism Management*. No. 20, pp. 89-97.
- Lippmann, R. P. (1987). An introduction to computing with neural nets. *ASSP Magazine, IEEE*, 4(2), 4-22.

- 
- Pai, P. F. , Hong, W. C. , Chang, P. T. , & Chen, C. T. (2006). The application of support vector machines to forecast tourist arrivals in Barbados: an empirical study. *International Journal of Management*, 23, 375-385.
  - Palmer, Alfonso; Jose, Montano Juan and Sese, Albert. (2006). Designing an artificial neural network for forecasting tourism time series. *Tourism Management*. Vol. 27, 781-790.
  - Pearce, D. G. , (2001). Towards a Regional Analysis of Tourism in Southeast Asia. In: Teo, P. , Chang, T. C. , Ho, K. C. (Eds. ) *Interconnected Worlds: Tourism in Southeast Asia*. Oxford, Pergamon.
  - Peyghami, M. R. , & Khanduzi, R. (2011). A hybrid model based on neural network and hybrid genetic algorithm for automotive price forecasting. *International Journal of Applied Mathematics and Computation*, 3(3), 158-168.
  - Peyghami, M. R. , & Khanduzi, R. (2012). Predictability and forecasting automotive price based on a hybrid train algorithm of MLP neural network. *Neural Computing and Applications*, 21(1), 125-132.
  - Peyghami, M. R. , & Khanduzi, R. (2013). NOVEL MLP NEURAL NETWORK WITH HYBRID TABU SEARCH ALGORITHM. *Neural Network World*, 3(13), 255-270.
  - Rumelhart, D. E. , Hinton, G. E. , & Williams, R. J. (1986). Learning representations by back-propagating errors. *Nature*, 323, 533-538.
  - Sharda, R. (1994). Neural networks for the MS/OR analyst: An application bibliography. *Interfaces*, 24(2), 116-130.
  - Shen, S. , Li, G. , & Song, H. (2011). Combination forecasts of international tourism demand. *Annals of Tourism Research*, 38, 72-89.
  - Sheng Lu, Zh& Zhang, X(2009), Tourism Demand Forecasting by Support Vector Regressin and Genetic Algorithm. *Computer Science and Information journal*. ieeexplore. ieee. org
  - Siddique, N. , & Adeli, H. (2013). *Computational intelligence: synergies of fuzzy logic, neural networks and evolutionary computing*: John Wiley & Sons.
  - Valipour, M. , Banihabib, M. E. , & Behbahani, S. M. R. (2013). Comparison of the ARMA, ARIMA, and the autoregressive artificial neural network models in forecasting the monthly inflow of Dez dam reservoir. *Journal of Hydrology*, 476, 433-441.
  - Weng, G,& Li, L(2015), Study of Tourism Forecasting Based on a Seasonally Adjusted Particle Swarm Optimaization-Support Vector Regression Model. *Journal of Information & Copmputational Science*. 12:7. Pp2747-2757.
  - Werbos, P. J. (1974). *Beyond regression: New tools for prediction and analysis in the behavioral sciences*. (Ph. D Thesis). Harvard University, USA.
  - Werbos, P. J. (1988). Generalization of backpropagation with application to a recurrent gas market model. *Neural networks*, 1(4), 339-356.
  - Zhang, G. , Patuwo, B. E. , & Hu, M. Y. (1998). Forecasting with artificial neural networks: The state of the art. *International journal of forecasting*, 14(1), 35-62.
  - Zhang, X. (1994). Time series analysis and prediction by neural networks. *Optimization Methods and Software*, 4(2), 151-170.