



مجله‌ی برنامه‌ریزی و توسعه گردشگری
سال چهارم، شماره‌ی ۱۳، تابستان ۱۳۹۴
صفحات ۷۱-۵۱

پیش‌بینی تقاضای گردشگری خارجی (یک مطالعه موردی برای ایران)

حمید ابریشمی^۱

احمد قلی برکیش^۲

تاریخ پذیرش: ۱۳۹۴/۰۶/۲۵

تاریخ دریافت: ۱۳۹۳/۰۸/۰۳

چکیده:

پیش‌بینی جریان آینده‌ی گردشگری ورودی برای تعیین مخارج سرمایه‌گذاری در صنعت گردشگری، هم برای بخش دولتی و هم برای بخش خصوصی، ضروری است. برای بخش دولتی و عمومی تخمین تقاضای گردشگری به‌منظور استفاده‌ی کارا از صنعت حمل‌ونقل و برنامه‌ریزی در نحوه‌ی تخصیص منابع حیاتی است. همچنین پیش‌بینی صحیح می‌تواند برای بخش خصوصی مانند شرکت‌های حمل‌ونقل هوایی در برنامه‌ریزی و طرح‌ریزی خطوط هوایی، تجهیزات، امکانات رفاهی و برنامه‌ریزی برای منابع انسانی مفید باشد. علی‌رغم اهمیت این موضوع در حوزه‌ی گردشگری، مطالعات انجام‌شده‌ی کشور ما در این حوزه بسیار محدود است. از سوی دیگر، از آنجایی‌که اثبات شده است مدل تک‌متغیره روش بسیار موفقیت‌آمیزی برای پیش‌بینی سری زمانی گردشگری است، در این مطالعه با استفاده از داده‌های ماهانه‌ی گمرک جمهوری اسلامی ایران در فاصله‌ی فروردین ۱۳۷۸ تا اسفند ۱۳۹۰، مدل‌های تک‌متغیره‌ی ARFIMA، روش هوشمند ANN و مدل ARFIMA-ANN را که آلاداگ^۳ و همکاران در سال ۲۰۱۲ پیشنهاد کرده‌اند، برای سری زمانی گردشگری کشور برآورد کردیم و نتایج حاصل از پیش‌بینی آن‌ها را با یکدیگر مقایسه نموده‌ایم. استفاده از معیارهای RMSE, MAPE, MAE برای ارزیابی صحت پیش‌بینی افق‌های زمانی متفاوت در میان مدل‌های مذکور نشان می‌دهد که مدل ARFIMA-ANN در افق‌های زمانی ۱۲، ۶، ۱۸ و ۲۴ ماه پیش رو توان بالاتری در پیش‌بینی نسبت به مدل‌های رقیب دارد و می‌تواند به‌عنوان مدلی مناسب برای برآورد و پیش‌بینی سری زمانی گردشگری کشور مورد استفاده قرار گیرد.

واژگان کلیدی: پیش‌بینی گردشگری، مدل ترکیبی، مدل ARFIMA، ARFIMA-ANN

^۱ استاد اقتصاد، دانشگاه تهران

^۲ نویسنده مسئول: دانشجوی دکتری اقتصاد دانشگاه فردوسی (gbarkish@gmail.com)

^۳ Aladagh

مقدمه

در دنیای امروز گردشگری خارجی برای کشورها به خاطر توانایی جذب درآمد و همچنین ایجاد فرصت مطلوب اشتغال در بخش‌های خدماتی و تولیدی مرتبط با آن بسیار بااهمیت است. از جمله‌ی این خدمات می‌توان به بخش‌های حمل‌ونقل مانند خطوط هوایی یا خدمات مهمانداری^۱ مانند محل اقامت اشاره نمود. از این‌رو، گردشگری می‌تواند به‌طور مستقیم یا غیرمستقیم نقش مهمی در تولید ناخالص داخلی یک کشور داشته باشد.

از سوی دیگر، گردشگری بین‌المللی در طول چند دهه‌ی گذشته، رشد پیوسته و عمیقی را تجربه نموده است. امروزه صنعت گردشگری یکی از بخش‌های اقتصاد است که بالاترین نرخ رشد را در میان تمام بخش‌های اقتصادی دیگر داراست، به‌گونه‌ای که حجم تجارت ایجاد شده از گردشگری برابر و یا حتی بیشتر از صادرات نفت، تولیدات مواد غذایی یا حتی صنعت اتومبیل است.^۲ گردشگری امروزه به بازیگر اصلی تجارت بین‌المللی تبدیل شده و هم‌زمان منبع درآمد عمده‌ای برای بسیاری از کشورهای در حال توسعه است. این گسترش عمومی گردشگری در میان نواحی توسعه‌یافته و صنعتی نیز منافع فراوانی در بخش‌های مرتبط از ساخت‌وساز گرفته تا کشاورزی و ارتباطات ایجاد نموده است. همچنین این رشد در سطح کلان با افزایش تنوع و رقابت میان کشورهای مقصد همراه بوده است.

مطابق با آمارهای سازمان جهانی گردشگری (UNWTO) سهم گردشگری از کل فعالیت اقتصادی (GDP) در سراسر دنیا در حدود ۰/۰۵ می‌باشد، البته سهم گردشگری از میزان اشتغال (مستقیم و غیرمستقیم) اندکی نسبتاً بالاتر است و در حدود ۶ تا ۷ درصد است. از سال ۱۹۵۰ تا ۲۰۱۰ گردشگری با یک نرخ سالانه‌ی (متوسط) ۶/۲ درصد رشد نموده و از مقدار ۲۵ میلیون در سال ۱۹۵۰ به ۹۴۰ میلیون در سال ۲۰۱۰ رسیده است. درآمد حاصله از گردشگری نیز حتی با یک نرخ رشد بالاتر به رقمی در حدود ۹۱۹ میلیارد دلار در سال ۲۰۱۰ رسیده است. در سال ۱۹۵۰، ۱۵ مقاصد اصلی گردشگری در حدود ۰/۸۸ مسافران بین‌المللی را جذب می‌کردند، این در حالی است که سهم این مقاصد در جذب گردشگر بین‌المللی در سال ۰/۱۹۷۰،۷۵ و در سال ۲۰۱۰، ۰/۵۵ بوده است که انعکاس‌دهنده‌ی این واقعیت است که مقصدهای جدیدی برای صنعت گردشگری ظهور نموده‌اند. مطابق با آمارهای سازمان جهانی گردشگری، بسیاری از این مقصدهای جدید گردشگری، کشورهای در حال توسعه هستند.^۳

این موضوع نمایانگر اهمیت و ضرورت مطالعات بیشتر برای جذب گردشگران بین‌المللی در کشورهای دارای توانش‌های گردشگری (مانند کشور ما) است.

^۱ Hospitality

^۲ <http://unwto.org/en/content/why-tourism>

از سوی دیگر، یکی از حوزه‌های مطالعات گردشگری که نیازمند توجه جدی و عمیق جهت استفاده و تعیین مخارج سرمایه‌گذاری برای بخش‌های خصوصی و دولتی است، بحث پیش‌بینی گردشگر ورودی یک کشور است؛ برای بخش دولتی و عمومی تخمین تقاضای گردشگری برای استفاده‌ی کارا از صنعت حمل‌ونقل و برنامه‌ریزی در نحوه‌ی تخصیص منابع حیاتی است. هم‌چنین پیش‌بینی صحیح می‌تواند برای بخش خصوصی مانند شرکت‌های حمل‌ونقل هوایی جهت برنامه‌ریزی و طرح‌ریزی هواپیماها، تجهیزات و امکانات رفاهی و برنامه‌ریزی جهت منابع انسانی مفید باشد. (چانگ^۱ و لیاو^۲، ۲۰۱۰: ۲۱۵)

اهمیت فزاینده‌ی پیش‌بینی گردشگری از جانب برخی از محققین مورد تأکید قرار گرفته است؛ به عنوان مثال، سانگ و ویت^۳ عنوان نموده‌اند که موفقیت تجاری، تصمیم‌های بازاریابی دولت و سیاست سرمایه‌گذاری همانند سیاست‌های اقتصاد کلان به‌وسیله‌ی صحت پیش‌بینی‌های گردشگری تحت تأثیر قرار خواهند گرفت. (سانگ و ویت، ۲۰۰۶: ۲۱۴) آرچر^۴ می‌افزاید چون محصول گردشگری از تعدادی خدمات تشکیل شده است که نمی‌توان آن‌ها را انباشته نمود، صحت پیش‌بینی‌های تقاضای گردشگری اهمیت فوق‌العاده‌ای برای تضمین دسترسی به این خدمات (در زمانی که مورد تقاضا قرار می‌گیرند) دارد. به علاوه طبیعت فصلی گردشگری منجر به ایجاد کمبود ظرفیت به دنبال مازاد ظرفیت خواهد شد. (آرچر، ۱۹۸۷: ۷۷)

نظر به اهمیت این بحث و محدود بودن مطالعات مرتبط با پیش‌بینی گردشگری در کشور، در این پژوهش به پیش‌بینی تقاضای خارجی گردشگری در ایران بر مبنای مدل ARFIMA-ANN (که در سال ۲۰۱۲ به‌وسیله‌ی آلاداگ^۵ و همکاران پیشنهاد شده است) و مقایسه‌ی آن با مدل‌های خطی و غیرخطی سازنده‌ی آن پرداخته شده است. سایر بخش‌ها به این صورتند: در بخش بعد، ابتدا مروری بر تحقیقات انجام‌شده در حوزه‌ی پیش‌بینی گردشگری ارائه می‌گردد، پس از آن مبانی نظری مدل ARFIMA به‌عنوان یک مدل دارای حافظه بلندمدت، مدل ANN برای مدل‌سازی عوامل غیرخطی و مدل ARFIMA-ANN برای در نظر گرفتن هم‌زمان ویژگی‌های حافظه بلندمدت و مؤلفه‌های غیرخطی یک سری زمانی ذکر می‌شود، سپس به مدل‌سازی سری زمانی گردشگری کشور با استفاده از این مدل‌ها پرداخته‌ایم و در انتها نیز به نتایج به‌دست‌آمده از این مدل‌ها و مقایسه‌ی آن‌ها در مورد سری زمانی گردشگری کشور اشاره نموده‌ایم.

¹ Chang

² Liao

³ Song and Witt

⁴ Archer

⁵ Aladag

پیشینه‌ی تحقیق

دامنه‌ی پیش‌بینی تقاضای گردشگری حوزه‌ی گسترده‌ای از مدل‌های مختلف را شامل می‌شود. با وجود این، در یک نگاه اجمالی به تحقیقات صورت‌گرفته در دهه‌ی اخیر در زمینه‌ی مدل‌سازی تقاضای گردشگری (از طریق مطالعه‌ی مدل‌های سری زمانی) می‌توان کل این تحقیقات را در دو گروه کلی مدل‌های خطی و غیرخطی تقسیم‌بندی نمود. در میان مدل‌های خطی انتخاب شده به‌وسیله‌ی محققان در حوزه‌ی مطالعات پیش‌بینی گردشگری نیز می‌توان به سه گروه عمده‌ی مدل‌های پیش‌بینی ساده^۱، مدل‌های هموارسازی نمایی ساده (ES) و مدل اتورگرسیو هم‌انباشته‌ی میانگین متحرک (ARIMA) اشاره کرد، از مدل‌های پیش‌بینی ساده می‌توان مطالعه‌ی برگر^۲ و همکاران (۲۰۰۱) را نام برد. درباره‌ی مدل‌های هموارسازنمایی نیز می‌توان به مطالعه‌ی انجام‌شده به‌وسیله‌ی چوهادار^۳ (۲۰۱۴) که به پیش‌بینی گردشگر ورودی به شهر استانبول ترکیه پرداخته است، اشاره کرد. هم‌چنین از کارهای ARIMA نیز می‌توان به مدل‌سازی سری زمانی گردشگری کشور مالزی به‌وسیله‌ی لاگاناسان^۴ و همکاران (۲۰۱۰) و یا کار چو^۵ در سال ۲۰۰۹ که به بررسی توان مدل ARIMA در پیش‌بینی تقاضای گردشگری در چند کشور جنوب شرق آسیا می‌پردازد، اشاره نمود. نتایج مطالعات تجربی در میان مدل‌های ذکرشده نشان می‌دهد که مدل (ARIMA)، توانایی پیش‌بینی بهتری را در اکثر موارد نسبت به مدل‌های رقیب داشته است (کوان یو چن^۶، ۲۰۱۱:۳۶۸)، اما از آنجایی که این مدل‌ها ویژگی حافظه‌ی بلندمدت سری زمانی را در نظر نمی‌گیرند، مطلوب‌تر است از مدل‌های در نظرگیرنده‌ی حافظه‌ی بلندمدت استفاده شود. مشهورترین مدلی که به حافظه‌ی بلندمدت پرداخته است، مدل ARFIMA است که اولین بار به‌وسیله‌ی گرنجر و جویکس^۷ در سال ۱۹۸۰ معرفی شد. برخی از محققین برای برآورد تقاضای گردشگری از این مدل استفاده نموده‌اند. آن‌ها نشان داده‌اند که مدل‌سازی بر مبنای ARFIMA توان بالاتری در مقایسه با مدل‌های دیگر سری زمانی دارد، به‌عنوان نمونه، چو^۸ در سال ۲۰۰۸ از مدل اتورگرسیو میانگین متحرک انباشته‌ی کسری (ARFIMA) و مدل ARIMA برای پیش‌بینی جریان گردشگر ورودی به کشور سنگاپور استفاده نمود. نتایج پژوهش وی نشان داد که مدل ARFIMA توان بالاتری در پیش‌بینی سری زمانی گردشگر ورودی کشور سنگاپور نسبت به مدل رقیب دارد (چو، ۲۰۰۸:۷۹-۸۸) این نتیجه به‌وسیله‌ی مطالعات مشابه گیل-الانا^۹ (۲۰۰۵) برای پیش‌بینی سری زمانی گردشگری

^۱ Naïve method

^۲ Burger

^۳ Çuhadar

^۴ Loganathan

^۵ Chu

^۶ Kuan-YuChen

^۷ Granger and Joyeux

^۸ Chu

^۹ Gil-Alana

کشور آمریکا نیز تکرار شده است. وی نیز نشان داده است که مدل ARFIMA توان بالاتری در پیش‌بینی سری زمانی گردشگری کشور آمریکا نسبت به مدل ARIMA دارد. (گیل-آلانا، ۲۰۰۵: ۸۷۸-۸۶۷) شیتان^۱ (۲۰۰۸) نیز به بررسی و مقایسه‌ی مدل‌های خانواده‌ی ARIMA و ARFIMA در پیش‌بینی تقاضای گردشگری در کشور مالزی پرداخته است. نتایج یافته‌های وی نیز نشان می‌دهد که توانایی مدل ARFIMA در پیش‌بینی تابع تقاضای گردشگری کشور مالزی نسبت به مدل رقیب بالاتر است.

اما از آنجایی که در زندگی واقعی ارتباط بین متغیرها عموماً غیرخطی است، استفاده‌ی تنها از چنین مدل‌هایی به‌منظور تحلیل این مسائل از کارایی لازم برخوردار نخواهد بود، یکی از جایگزین‌های مهم برای این مدل‌ها شبکه‌های عصبی هستند. (اصلانارگان^۲ و همکاران، ۲۰۰۷: ۲۹) شبکه‌های عصبی چندلایه به خاطر دارا بودن طبیعت غیرخطی در ارتباط بین متغیرهای ورودی و خروجی نتایج کارآمدتری را در شناخت الگو و مسائل پیش‌بینی به دست می‌دهند؛ بنابراین، می‌توانند به عنوان یک رقیب جدی برای مدل‌های سنتی تحلیلی سری‌های زمانی در زمینه‌ی پیش‌بینی مطرح شوند (ژانگ^۳، ۲۰۰۳: ۱۶۰) به همین دلیل این مدل‌ها در طول دهه‌های گذشته در بسیاری از حوزه‌ها کاربرد یافته‌اند، اگرچه صرفاً در چند سال اخیر از آن‌ها برای پیش‌بینی گردشگر ورودی استفاده شده است (کلاوریا و تورا^۴، ۲۰۱۴: ۲۲۰) به عنوان عنوان مثال، کلاوریا و همکاران (۲۰۱۴) عملکرد چند مدل شبکه عصبی در پیش‌بینی گردشگر ورودی از کشورهای مختلف به ایالت کاتالونیای اسپانیا را مورد بررسی و آزمون قرار داده‌اند. هم‌چنین تیکسرا^۵ و فرناندز^۶ (۲۰۱۲) نیز دقت پیش‌بینی چند معماری شبکه عصبی را با چند چند مدل خطی مانند ARIMA در پیش‌بینی گردشگر ورودی با یکدیگر مقایسه نموده‌اند.

از سوی دیگر، تأکید هرکدام از این مدل‌ها بر ویژگی‌های متفاوت سبب شده است که برخی از محققان برای پیش‌بینی سری‌های زمانی از ترکیب دو یا چند مدل سری شده در کنار هم که معروف به مدل‌های هیبریدی یا ترکیبی هستند استفاده نمایند. به اعتقاد ژانگ ترکیب مدل‌های متفاوت سبب در نظر گرفتن ابعاد مختلف الگوهای موردبررسی می‌شود (ژانگ، ۲۰۰۳: ۱۶۵) اگرچه استفاده از مدل‌های هیبریدی یا ترکیبی جدید نیست و به کار اولیه بیتس^۷ و گرنجر^۸ (۱۹۶۹) برمی‌گردد، اما این ایده که ترکیب دو نوع مدل نتیجه‌ای بهتر از هر مدل به‌تنهایی ارائه می‌دهد به‌وسیله‌ی لورنس^۹ و همکاران (۱۹۸۶) و ماکریداکیس^{۱۰} (۱۹۸۹)

¹ Shitan

² Aslanargun

³ Zhang

⁴ Claveria and Torra

⁵ Teixeira

⁶ Fernandes

⁷ Bates

⁸ Granger

⁹ Lawrence

¹⁰ Makridakis

نیز نشان داده شده است، به نحوی که امروزه مدل‌های ترکیبی در زمینه‌های اقتصادی، بیمه، پیش‌بینی فروش و قیمت به کار می‌روند (کوان یو چن^۱، ۲۰۱۱:۳۶۹) البته در دهه اخیر استفاده استفاده از این شیوه شتاب بیشتری داشته است، به عنوان نمونه تی شنگ^۲ و همکاران در سال ۲۰۰۲ یک مدل پیش‌بینی متشکل از مدل‌های SARIMA و BPNN را ارائه دادند. آن‌ها نشان دادند که مدل هیبریدی حاصل توانایی بالاتری در برآورد پیش‌بینی‌ها نسبت به هر کدام از مدل‌ها به تنهایی داشته است. (تی شنگ و همکاران، ۲۰۰۲:۷۱) همچنین در سال ۲۰۰۳، ژانگ^۳، یک الگوی هیبریدی که ترکیبی از یک شبکه‌ی عصبی و ARIMA بود را برای پیش‌بینی چند سری زمانی به کار برد. (ژانگ، ۲۰۰۳:۱۷۵-۱۵۹)

در چند سال اخیر نیز برخی از محققین در حوزه‌ی پیش‌بینی گردشگری از مدل‌های ترکیبی استفاده نموده‌اند که از آن جمله می‌توان به مطالعه‌ی اصلائارگان و همکاران در پیش‌بینی تعداد گردشگر ورودی به ترکیه اشاره نمود. هم‌چنین آلاداگ و همکاران در سال ۲۰۱۲ یک مدل هیبریدی متشکل از مدل ARFIMA و شبکه عصبی مبتنی بر مدل ژانگ (۲۰۰۳) پیشنهاد داده‌اند. نتیجه استفاده از این مدل برای پیش‌بینی سری زمانی گردشگری ترکیه به وسیله‌ی آن‌ها نشان می‌دهد که این مدل توانایی بهتری در پیش‌بینی سری زمانی پیش رو نسبت به هر دو مدل شبکه عصبی و ARFIMA دارد. از دیگر مطالعاتی که از روش‌های ترکیبی در حوزه‌ی گردشگری استفاده نموده‌اند نیز می‌توان به مطالعه‌ی هوانگ و دی^۴ (۲۰۱۳) و کوان یو چن (۲۰۱۱) اشاره کرد.

در زمینه‌ی مطالعات داخلی برای برآورد تقاضای خارجی گردشگری، عموماً از روش‌های کمی چندمتغیره استفاده شده است. به عنوان نمونه، کاوه‌ئیان (۱۳۸۱) با استفاده از روش حداقل مربعات معمولی و متغیرهایی همانند نرخ ارز نسبت قیمت داخل به خارج و متغیر موهومی برای دوره‌ی جنگ تابع تقاضای گردشگری را برآورد نموده است. هم‌چنین، موسایی (۱۳۸۳) از روش حداقل مربعات معمولی تابع تقاضای گردشگری ایران را تصریح نموده است. متغیرهای وی شاخص قیمت داخل به شاخص قیمت جهانی، تولید ناخالص جهانی، درآمد حاصل گردشگری دوره‌ی قبل و متغیر مجازی برای دوره‌های سیاسی و جنگ بوده است. از دیگر مطالعات می‌توان به مطالعه‌ی مراسلی (۱۳۷۴) و نوری (۱۳۷۵) اشاره کرد؛ اما از آن جایی که در چند سال اخیر برخی از محققین نشان داده‌اند که در ارتباط با سری زمانی گردشگری مدل‌های مبتنی بر سری زمانی خالص نسبت به مدل‌های دارای متغیر توضیحی عملکرد بهتری در پیش‌بینی دارند (آئاناسوپولوس و همکاران، ۲۰۱۱:۸۲۲) و هم‌چنین از سوی دیگر اثبات شده

¹ Kuan-YuChen

² Tseng

³ Zhang

⁴ Hwang and Day

است که مدل‌سازی سری زمانی تک‌متغیره روش بسیار موفقیت‌آمیزی برای پیش‌بینی سری زمانی گردشگری می‌باشد (سایمن^۱ و سایمن، ۲۰۱۰: ۲۸۱)، بنابراین، در این مطالعه از روش‌های تک‌متغیره‌ی ARFIMA و روش هوشمند ANN و مدل ترکیبی ARFIMA-ANN برای پیش‌بینی سری زمانی گردشگری کشور در افق‌های زمانی متفاوت استفاده شده است.

روش‌شناسی تحقیق

مدل ARFIMA

این مدل که مدل خود رگرسیون میانگین متحرک انباشته جزئی^۲ نام دارد مهم‌ترین و قابل انعطاف‌پذیرترین گروه از مدل‌های دارای حافظه بلندمدت است و قادر است سری‌های دارای حافظه بلندمدت را مدل‌سازی نماید. در این مدل d ناظر بر ویژگی‌های حافظه بلندمدت سری زمانی است. وجود حافظه بلندمدت در یک سری مبین این نکته است که سری زمانی قادر است آثار یک تکانه را تا زمان‌های طولانی در خود ذخیره نماید. مشخصه عمده سری‌های دارای حافظه بلندمدت تابع خودهمبستگی آن‌هاست که با یک نرخ هیپربولیک کاهش می‌یابد، این نرخ کاهش خیلی پایین‌تر از سری‌های دارای حافظه کوتاه‌مدت می‌باشد (ژیو^۳ و جین^۴ ۲۰۰۷: ۱۳۸) یک مدل ARFIMA(p,d,q) به شکل زیر تعریف می‌گردد:

$$\phi(L)(1-L)^d(y_t - \mu) = \theta(L)\varepsilon_t, \quad \varepsilon_t \sim \text{nid}(0, \sigma_\varepsilon^2)$$

که در آن تمام ریشه‌های $\theta(L)$ و $\phi(L)$ در خارج دایره‌ی واحد قرار دارند و d پارامتر تفاضل‌گیری کسری است. واضح است که این مدل تعمیم مدل ARIMA در حالت غیر صحیح بودن d است. تعبیر یک مدل ARIMA هم انباشته از مرتبه d این است که باید از $d, (y_t - \mu)$ بار تفاضل‌گیری گردد و سپس یک مدل ARMA در حول آن ساخته شود. مدل ARFIMA نیز به همان صورت تعبیر می‌گردد (لیدهولد^۵، ۲۰۰۰: ۱۵) عموماً گفته می‌شود $I(d)$ ، $(y_t - \mu)$ است، اگر به‌وسیله یک مدل ARFIMA(p,d,q) تولید شده باشد. ویژگی‌های سری زمانی به‌وسیله پارامتر d در مدل تبیین می‌گردد، به‌گونه‌ای که برای $d < 0.5$ سری زمانی مانا خواهد بود و در صورتی که $0 < d < 0.5$ باشد آنگاه سری زمانی دارای حافظه بلند خواهد بود. در این پژوهش برای تخمین مراتب پویایی‌های کوتاه‌مدت و هم‌چنین d سری زمانی گردشگری کشور از نرم‌افزار OXMetrics استفاده شده است.

^۱ Saayman and Saayman

^۲ Autoregressive fractionally integrated moving average

^۳ Xiu

^۴ Jin

^۵ Lildholdt

مدل شبکه عصبی مصنوعی^۱

مدل‌های شبکه عصبی، چهارچوب‌های محاسباتی قابل‌انعطافی برای مدل‌سازی طیف گسترده‌ای از مسائل غیرخطی هستند. یک مزیت مهم مدل‌های ANN بر دیگر کلاس‌های مدل‌های غیرخطی این است که ANNها تخمین زن‌های جهانی هستند که می‌توانند گروه بزرگی از توابع با درجات بالایی از دقت را تخمین بزنند. این قدرت آن‌ها ناشی از پردازش موازی اطلاعات و داده‌ها می‌باشد. هیچ نیازی به فرض قبلی و اولیه در مورد شکل مدل در فرایند ساخت مدل نیست. در عوض مدل شبکه اکثراً به‌وسیله ویژگی‌های داده‌ها تعیین می‌گردد (ژانگ:۲۰۰۳:۱۶۳)

در حوزه‌ی پیش‌بینی گردشگری بعضی محققان نشان داده‌اند که مدل‌های ANN عملکرد بهتری نسبت به روش‌های آماری داشته‌اند (اصلانارگان و همکاران، ۲۰۰۷:۳۰). ما نیز همگام با محققان دیگر در حوزه‌ی گردشگری در این پژوهش از شبکه پرسپترون^۲ چندلایه با الگوریتم آموزش پس انتشار خطا^۳ استفاده خواهیم نمود.

نحوه‌ی استفاده از شبکه عصبی ANN برای مدل‌سازی سری‌های زمانی^۴:

عمدتاً از شبکه‌های عصبی از نوع پیش‌خور^۵ برای مدل‌سازی سری زمانی و پیش‌بینی استفاده می‌شود (ژانگ و همکاران، ۱۹۹۸:۳۷) هم‌چنین در انتخاب ساختار شبکه عصبی به‌منظور مدل‌سازی سری‌های زمانی معمولاً از یک‌لایه پنهان استفاده می‌شود (ژانگ:۲۰۰۳:۱۶۳)؛ بنابراین، ساختار کلی این شبکه‌ها به‌صورت $N:P:1$ خواهد بود که شامل N مشاهده اخیر به‌عنوان ورودی، P تعداد گره‌ها در لایه پنهان و یک گره خروجی که شامل $N+1$ امین مشاهده است، می‌باشد.

در شکل (۱) معماری یک شبکه پیش‌خور چندلایه که در این مطالعه مورد استفاده قرار گرفته است نمایش داده شده است.

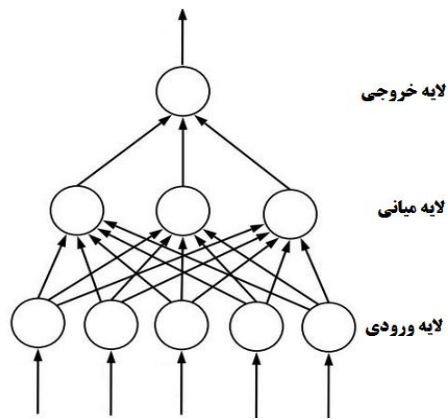
^۱ Artificial Neural Networks(ANN)

^۲ Multi-Layer Perceptron(MLP)

^۳ Back Propagation (BP)

^۴ مدل‌سازی سری زمانی با شبکه عصبی و روش ترکیبی که از مطالعات ژانگ (۱۹۹۸، ۲۰۰۱ و ۲۰۰۳) در اینجا ارائه شده است در عمده مطالعات مهم پیش‌بینی در دهه اخیر مورد استفاده قرار گرفته است.

^۵ Feed Forward Neural Network (FFNN)



شکل (۱): نمای کلی شبکه عصبی پیشخور مورد استفاده در این مطالعه؛ در این مقاله مطابق روش استفاده شده به وسیله‌ی ژانگ (۱۹۹۸، ۲۰۰۳) و آلوداگ (۲۰۱۲) یک گره در لایه خروجی به کار رفته است. همچنین برای لایه ورودی نیز از دوازده گره استفاده شده است.

در حالت کلی مدل‌سازی ریاضی شبکه عصبی از یک سری زمانی را می‌توان به شکل زیر نوشت:

$$y_t = \alpha_o + \sum_{j=1}^q \alpha_j g \left(\beta_{oj} + \sum_{i=1}^p \beta_{ij} y_{t-i} \right) + \varepsilon_t$$

که در آن α_j ($j = 1, 2, \dots, q$) و β_{ij} ($i = 1, 2, 3, \dots, p$ & $j = 1, 2, \dots, q$) پارامترهای مدل هستند و وزن‌های ارتباطی نامیده می‌شوند. همچنین p تعداد گره‌های ورودی و q تعداد گره‌ها در لایه میانی می‌باشند. تابعی که اغلب به‌عنوان تابع انتقال در لایه میانی انتخاب می‌گردد تابع انتقال لگستیک است که به‌صورت زیر می‌باشد:

$$g(x) = \frac{1}{1 + \exp(-x)}$$

بدین ترتیب همان‌طور که از معادله بالا مشخص است مدل کردن ANN سری زمانی یک تابع غیرخطی است که مقادیر گذشته مشاهدات را بر روی مقدار آتی نگاشت می‌کند و می‌توان آن را به‌صورت زیر نوشت:

$$y_t = f(y_{t-1}, y_{t-2}, y_{t-3}, \dots, y_{t-n}, \omega) + \varepsilon_t$$

که در آن y_{t-1} مقادیر ورودی شبکه است، y_t مقدار هدف، w وزن‌های شبکه و ε بردار بایاس در زمان t می‌باشد. مقدار y_t پیش‌بینی‌شده نیز به صورت زیر محاسبه می‌گردد.

$$\hat{y}_t = f(y_{t-1}, y_{t-2}, y_{t-3}, \dots, y_{t-n}, \omega)$$

اگر سری زمانی شامل N مشاهده $(y_1, y_2, y_3, \dots, y_N)$ باشد، تعداد نمونه‌های آموزش $N-n$ خواهد بود. به این شکل که در ابتدا بردار $(y_1, y_2, y_3, \dots, y_n)$ به عنوان نخستین بردار ورودی و y_{n+1} نیز به عنوان خروجی هدف متناظر با آن به شبکه جهت آموزش داده می‌شود. سپس در گام دوم بردار $(y_2, y_3, y_4, \dots, y_{n+1})$ به عنوان بردار ورودی بعدی و y_{n+2} نیز به عنوان خروجی هدف به شبکه فوق داده می‌شود و با تکرار همین روال در آخرین گام نیز به ترتیب $(y_{N-n}, y_{N-n+1}, y_{N-n+2}, \dots, y_{N-1})$ به عنوان آخرین ورودی‌ها و خروجی‌ها به شبکه داده خواهد شد. در خلال روند آموزش پارامترها وزن‌ها و بایاس‌های شبکه در جهت حداقل کردن مقدار مجموع مربعات خطا^۱ به مقادیر بهینه‌ی خود نزدیک می‌گردند. در مجموع، همان‌طور که قبلاً ذکر گردید در عمل یک شبکه ساده که تعداد کمی گره در لایه پنهان دارد اغلب می‌تواند به خوبی داده‌های خارج نمونه را پیش‌بینی نماید؛ اما انتخاب q وابسته به داده‌ها بوده و هیچ قانون نظام‌مندی در تصمیم برای انتخاب این پارامتر وجود ندارد. علاوه بر این، یکی دیگر از وظایف مهم در مدل‌سازی ANN برای سری‌های زمانی انتخاب تعداد وقفه‌های مشاهدات (p) یا بعد بردار ورودی است، شاید این یکی از مهم‌ترین پارامترهایی است که باید در مدل‌سازی ANN تشخیص داده شود و نقش عمده‌ای در تعیین ساختار خودهمبستگی (غیرخطی) سری‌های زمانی بازی می‌کند. اگرچه هیچ تئوری که بتواند در انتخاب مقدار p کمک کند وجود ندارد، با این وجود، تجربه و آزمایش اغلب می‌تواند شخص را به سمت انتخاب p و q مناسب هدایت نماید.

روش ترکیبی ARFIMA-ANN

یک سری زمانی را می‌توان به صورت ترکیب خطی از یک ساختار خودهمبستگی خطی و یک مؤلفه غیرخطی به صورت زیر در نظر گرفت (ژانگ، ۲۰۰۳: ۱۶۵):

$$y_t = L_t + N_t$$

که L_t نشان‌دهنده‌ی جزء خطی و N_t نشان‌دهنده‌ی مؤلفه غیرخطی سری است. این دو مؤلفه از روی داده‌های سری زمانی تحت بررسی برآورد می‌گردند. بدین منظور، ابتدا از یک مدل

^۱ Sum Squared Error(SSE)

ARFIMA جهت مدل‌سازی مؤلفه خطی استفاده می‌گردد، سپس باقی‌مانده‌های جزء خطی که تنها شامل ارتباط غیرخطی است به دست می‌آید. در معادله زیر e_t نشان‌دهنده‌ی جزء پسماند یا باقی‌مانده در لحظه t است.

$$e_t = y_t - \hat{L}_t$$

\hat{L}_t نیز مقدار پیش‌بینی زمان t ، مدل خطی است.

بررسی اجزا پسماند در تشخیص کارایی یک مدل خطی بسیار مهم است. یک مدل خطی اگر بعد از مدل‌سازی هنوز ساختار همبستگی خطی درون اجزاء پسماندش باشد کارا نخواهد بود، باین‌وجود، تحلیل پسماند قادر به تشخیص الگو غیرخطی در داده‌ها نیست، بنابراین حتی اگر یک مدل خطی در مرحله کنترل تشخیصی مورد تأیید قرار گیرد، مدل مذکور ممکن است هنوز به خاطر عدم مدل‌سازی مناسب روابط غیرخطی، دقیق نباشد (ژانگ، ۲۰۰۳: ۱۶۵). وجود هر الگوی غیرخطی مهم در پسماندها محدودیت مدل‌سازی خطی را نشان می‌دهد. به‌وسیله مدل‌سازی باقی‌مانده‌ها با استفاده از ANN می‌توان روابط غیرخطی سری زمانی را کشف نمود. با فرض n گروه ورودی مدل ANN برای باقیمانده‌ها را می‌توان به‌صورت زیر نوشت:

$$e_t = f(e_{t-1}, e_{t-2}, e_{t-3}, \dots, e_{t-n}) + \varepsilon_t$$

که f یک تابع غیرخطی تعیین‌شده به‌وسیله شبکه عصبی و ε_t جزء خطای تصادفی است. البته باید به این نکته توجه نمود که اگر مدل f یک مدل مناسب نباشد جزء خطا لزوماً تصادفی نخواهد بود؛ بنابراین، تشخیص مدل صحیح حیاتی است. معادله بالا مدل‌سازی غیرخطی پسماندها است که نشانگر \hat{N}_t غیرخطی در معادله اول است؛ بنابراین، مدل هیبریدی ابتدایی را می‌توان به شکل نهایی زیر نوشت:

$$\hat{y}_t = \hat{L}_t + \hat{N}_t$$

به‌طور خلاصه، در یک جمع‌بندی می‌توان گفت که یک متدولوژی هیبریدی شامل دو مرحله است. در مرحله نخست از یک مدل خطی (مانند ARFIMA در این مطالعه) جهت برآورد و تحلیل بخش خطی مسئله استفاده می‌گردد. در مرحله دوم از یک مدل شبکه عصبی برای مدل‌سازی باقی‌مانده‌های حاصل از مرحله اول و استخراج روابط غیرخطی از آن‌ها استفاده می‌گردد. شبکه عصبی سری با ARFIMA پس از آموزش قادر به برآورد و پیش‌بینی خطای ARFIMA خواهد بود.

مواد و روش تحقیق

داده‌های مورد استفاده در این مطالعه شامل داده‌های سری زمانی گردشگری به کشور در فاصله فروردین ۱۳۷۸ تا اسفند ۱۳۹۰ است که به‌طور مستقیم از دفتر فن‌آوری و اطلاعات گمرک جمهوری اسلامی ایران اخذ شده است. با توجه به عدم دسترسی به داده‌های سال‌های بعد و قبل از این بازه‌ی زمانی کل داده‌های قابل استفاده شامل ۱۵۶ داده است که به‌منظور تخمین و ارزیابی مدل آن‌ها را به دو قسمت تقسیم می‌نماییم و از قسمت اول آن شامل داده‌های ماهانه‌ی فروردین ۱۳۷۸ تا اسفند ۱۳۸۸ به‌منظور تصریح و انتخاب مدل و از قسمت دوم آن شامل ۲۴ ماه انتهایی نیز برای ارزیابی پیش‌بینی مدل استفاده نموده‌ایم. هم‌چنین به‌منظور ارزیابی توان پیش‌بینی مدل‌ها از معیارهای میانگین قدر مطلق درصد خطا^۱ (MAPE)، میانگین قدر مطلق خطا^۲ (MAE) و جذر میانگین مربعات خطا^۳ (RMSE) استفاده می‌شود که مقادیر پایین‌تر آن‌ها نشان از دقت بالاتر پیش‌بینی است. تعریف این شاخص‌ها در زیر آمده است:

$$MAE = \frac{1}{N} \sum_{n=1}^N |x_n - \hat{x}_n|$$

$$MAPE = \frac{1}{N} \sum_{n=1}^N |(x_n - \hat{x}_n) / x_n| (100\%)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{n=1}^N (x_n - \hat{x}_n)^2}$$

از سوی دیگر، در ارزیابی توان هر مدل به‌تنهایی می‌توان از معیار لوییس^۴ استفاده نمود. بر مبنای معیار لوییس تنها در صورتی که MAPE کمتر از ده درصد باشد توانایی مدل در پیش‌بینی عالی خواهد بود. معیار ارزیابی لوییس (۱۹۸۲) در جدول (۱) آمده است. لازم به ذکر است که در این مطالعه برای استفاده از مدل ARFIMA از لگاریتم داده‌ها استفاده شده است.

^۱ Mean absolute percentage error

^۲ Mean absolute error


^۳ Root of mean square error

^۴ Lewis

جدول (۱): مقادیر MAPE برای ارزیابی مدل

MAPE(%)	ارزیابی
$MAPE \leq 10$	پیش‌بینی صحت بالا
$10 < MAPE \leq 20$	پیش‌بینی خوب
$20 < MAPE \leq 50$	پیش‌بینی معقول
$MAPE > 50$	پیش‌بینی ناصحیح

منبع: (لوییس، ۱۹۸۲)



شکل (۲) نمودار سری زمانی گردشگری کشور در فاصله زمانی فروردین ۱۳۷۸ تا اسفند ۱۳۹۰

منبع: گمرک جمهوری اسلامی ایران

برازش مدل‌ها و انتخاب مدل‌های مناسب

استفاده از شبکه‌های عصبی برای مدل‌سازی سری زمانی گردشگر ورودی به کشور:

در این مطالعه همگام با دیگر محققین از شبکه عصبی پیشخور با یک لایه پنهان استفاده می‌نماییم. یکی از مهم‌ترین کارها در انتخاب ساختار اولیه یک شبکه عصبی انتخاب تعداد گره‌های لایه ورودی است؛ زیرا تعداد گره‌های لایه ورودی متناظر با تعداد مشاهدات با وقفه مورد استفاده برای کشف الگوهای نهفته و ساختارهای خودهمبستگی در سری‌های زمانی است، به همین دلیل نقش مهمی در طبقه‌بندی و برازش مدل دارد (ژانگ و همکاران ۲۰۰۱:۳۸۴) به نظر می‌آید که با توجه به فصلی بودن داده‌های مورد مطالعه در این مقاله، وجود تعداد گره‌های ورودی با تناوب فصلی مثلاً ۶، ۳، ۹ و ۱۲ بهترین عملکرد را داشته باشد، هم‌چنین همان‌طور که قبلاً نیز ذکر گردید در انتخاب ساختار اصلی شبکه نیز از ساختار متعارف و استاندارد با یک لایه پنهان استفاده می‌نماییم که به ترتیب دارای تابع تبدیل سیگموئید و خطی در لایه پنهان و آخر است. با انجام آزمایش‌های متعدد تعداد دوازده گره برای لایه ورودی انتخاب می‌نماییم. با انتخاب ساختار اولیه باید تعداد گره‌ها در لایه میانی را انتخاب نمود. بدین منظور و برای

انتخاب مناسب‌تر تعداد گره‌های لایه میانی ابتدا شبکه موردنظر را با تعداد کمتر تکرار (۵۰ تکرار) و با استفاده از الگوریتم سریع LM (لونبرگ-مارکوات) مورد آزمایش و شبیه‌سازی سریع قرار دادیم. با توجه به نتایج حاصل مشخص شد که شبکه عصبی با تعداد گره‌های کمتر از ۱۰ عدد عملکرد بهتری را در مدل‌سازی سری زمانی گردشگری کشور خواهد داشت. سپس در مرحله دوم با تکرار بسیار زیاد (۲۰۰ تکرار)، تعداد دقیق گره در لایه میانی را به دست آوردیم. آزمایش‌های متفاوت نشان داد که استفاده از چهار گره در لایه میانی بهترین عملکرد را دارد؛ بنابراین، در نهایت شبکه عصبی با معماری ۱۲:۴:۱ برای مدل‌سازی سری زمانی گردشگری کشور انتخاب شد. در تمام مراحل برای انتخاب شبکه بهینه و مقایسه بین شبکه‌ها از معیار میانگین مجذور خطا^۱ استفاده نمودیم. همچنین برای توقف فرآیند و جلوگیری از ازر نمودن شبکه نیز از روش توقف زودهنگام^۲ استفاده گردید. تمام این مراحل در نرم‌افزار متلب برنامه‌نویسی و اجرا شد^۳.

تخمین مدل ARFIMA با استفاده از نرم‌افزار OxMetrics

در این مطالعه برای برازش مدل ARFIMA بر روی سری زمانی گردشگری از نرم‌افزار OxMetrics/pcgive استفاده می‌نماییم. بدین منظور، ابتدا با حذف ویژگی‌های فصلی سری زمانی گردشگری با استفاده از عملگر تفاضل‌گیری مرتبه ۱۲ پویایی‌های کوتاه‌مدت سری به دست آمده را به وسیله این نرم‌افزار تعیین می‌نماییم.

از آن جایی که در این نرم‌افزار تمام پارامترها به صورت همزمان به دست می‌آیند، روش انجام مدل‌سازی به شکل آزمایش و خطا تعیین می‌گردد؛ به این صورت که با تعیین اولیه مراتب مختلف AR و MA ضرایب و پارامترهای مدل تخمین زده می‌شوند. این کار معمولاً با دادن مراتب مختلف AR و MA که عموماً بین ۰ تا ۵ در نظر گرفته می‌شود انجام می‌گیرد، البته چون نرم‌افزار OxMetrics از روش‌های عددی بهینه‌سازی برای محاسبات استفاده می‌نماید باید همگرا نشدن جواب را نیز در مورد بعضی از مدل‌ها در نظر گرفت (دورینک^۴ و اومس^۵، ۱۹۹۹). همچنین بی‌معنی بودن بعضی از ضرایب یک مدل نیز باعث حذف آن مدل در انتخاب نهایی می‌گردد، در نهایت، نیز با توجه به ساختار نمودار خودهمبستگی و خودهمبستگی جزئی و برخی معیارهای دیگر همانند کمترین مقدار آکائیک مدل مناسب از میان مدل‌های رقیب انتخاب می‌شود. در این مطالعه نیز با استفاده از رویکرد فوق مدل مناسب از بین

^۱ Mean of Squared Error(MSE)

^۲ Early stopping

^۳ تمامی این برنامه‌ها به وسیله‌ی نگارنده‌ی مقاله در محیط برنامه‌نویسی متلب تهیه شده است که در صورت درخواست می‌تواند در اختیار محققین گرامی قرار گیرد.

^۴ Doornik

^۵ Ooms

مدل‌های رقیب انتخاب شد که نتایج آن در جدول (۲) نمایش داده شده است. البته لازم به ذکر است که به دلیل شکستگی ظاهری در نمودار سری زمانی موجود برای تخمین ضرایب و پارامترهای مدل از داده‌های دوره‌ی ۱۳۸۴/۱ تا ۱۳۸۸/۱۲ استفاده نموده‌ایم.

جدول (۲): نتایج برآورد مدل ARFIMA

Variable	coefficient	t-statistic	AIC
d	۳۹۷/۰	۴۳/۴	۲۷۵/-۰
۱AR()	۹۸/۰	۹۰/۷	
۲AR()	۷۴/۰	۸۳/۴	
۳AR()	۸۶/۰-	۶۴/۸-	
۱MA()	۸۷/۰-	۷۱/۴-	
۲MA()	۸۸/۰-	۱۴/۹-	
۳MA()	۸۵/۰	۸۱/۴	

منبع: محاسبات تحقیق حاضر

تخمین مدل ARFIMA-ANN

برای ساخت و انتخاب مدل ترکیبی ARFIMA-ANN با توجه به انتخاب مدل ARFIMA مناسب در بخش قبل و به دست آمدن باقیمانده‌ها یا پسماندها باید مدل مناسب شبکه عصبی برای مدل نمودن باقیمانده‌ها را انتخاب نمود.


همان‌طور که قبلاً نیز ذکر شد در این مطالعه همگام با مطالعات محققان دیگر در این حوزه، برای بخش غیرخطی مدل ترکیبی نیز از شبکه عصبی پیشخور با ساختار استاندارد یک‌لایه پنهان استفاده می‌نماییم. هم‌چنین به ترتیب توابع انتقال سیگنویید و خطی را به‌عنوان توابع انتقال گره‌های لایه پنهان و لایه خروجی انتخاب می‌کنیم. به‌منظور جلوگیری از بیش‌برازش یا ازیر نمودن شبکه نیز در اینجا همانند مدل شبکه عصبی بخش قبل از الگوریتم توقف زودهنگام استفاده می‌گردد، بدین منظور همانند بخش قبل به‌صورت تصادفی بیست درصد داده‌ها را برای مجموعه اعتبار بیست درصد دیگر برای مجموعه آزمایش و مابقی برای آموزش انتخاب می‌گردند. هم‌چنین الگوریتم پس انتشار مقاوم نیز به‌عنوان الگوریتم آموزش اصلی انتخاب می‌گردد. حال برای انتخاب تعداد گره‌های ورودی و تعداد گره‌ها در لایه پنهان با روش سعی و خطا مدل مناسب را که دارای کمترین مقدار مربعات خطا بر روی تمام داده‌ها باشد انتخاب می‌شود. لازم به ذکر است با توجه به تصادفی بودن مقادیر اولیه وزن‌ها و بایاس‌ها هر معماری شبکه را برای ۲۰۰ تکرار آزمون می‌نماییم. پس از آزمایش‌های مختلف شبکه عصبی با

معماری (۶:۳:۱) را که دارای کمترین مقدار مجموع مربعات خطا است انتخاب نموده و از آن به‌عنوان قسمت غیرخطی مدل ترکیبی استفاده می‌نماییم.

بحث و نتایج

در این بخش با استفاده از سه مدل انتخاب‌شده ANN، ARFIMA و ARFIMA-ANN به پیش‌بینی سری زمانی گردشگر ورودی به کشور در دو سال ۱۳۸۹ و ۱۳۹۰ و همچنین مقایسه‌ی نتایج آن‌ها برای پیش‌بینی سری زمانی فوق در افق‌های زمانی مختلف بر مبنای معیار MAPE می‌پردازیم.

شکل (۳) نتایج پیش‌بینی دو مدل ARFIMA و ARFIMA-ANN به همراه سری زمانی گردشگری اصلی کشور را در بازه‌ی اسفندماه ۱۳۸۸ تا اسفندماه ۱۳۹۰ نشان می‌دهد. همچنین در جدول (۳) نتایج استفاده از سه مدل فوق برای پیش‌بینی سری زمانی گردشگری کشور در افق‌های زمانی مختلف بر مبنای معیار MAPE ارائه شده است.



شکل (۳): نمودار اصلی سری زمانی گردشگری و نمودار پیش‌بینی شده آن با استفاده از مدل ARFIMA-ANN (■) و مدل ARFIMA-ANN (*) برای فاصله زمانی اسفند ۱۳۸۸ تا اسفند ۱۳۹۰

جدول (۳): مقایسه‌ی بین مدل‌های مختلف در افق زمانی متفاوت بر مبنای معیار MAPE*

MODEL	۶ ماه	۱۲ ماه	۱۸ ماه	۲۴ ماه
ARFIMA(p,d,q)	۱۵/۲۴	۱۵/۶۹	۱۴/۸۰	۱۳/۷۱
NN	۱۶/۵۱	۱۳/۲۴	۱۴/۳۴	۱۴/۶۲
ARFIMA-NN	۱۰/۷۴	۰۹/۸۲	۱۰/۱۷	۰۹/۹۳

منبع: محاسبات تحقیق حاضر؛ *اعداد برحسب (درصد)

همان‌طوری که از نتایج جدول (۳) مشخص است، در افق زمانی شش‌ماهه و بعد از آن شاخص MAPE برای ARFIMA-ANN به ترتیب ۱۰/۹۳، ۱۰/۱۷، ۱۰/۱۷ و ۹/۹۳ است که پایین‌ترین مقدار در افق‌های زمانی متناظر در بین هر سه مدل است و به معنای بالاتر بودن

توان پیش‌بینی این مدل نسبت به مدل‌های رقیب، در افق‌های زمانی متفاوت است. با این وجود، شاخص لوییس برای این مدل در همه‌ی افق‌های زمانی در مرز صحت بالا قرار می‌گیرد که می‌توان یکی از دلایل عمده آن را نوین‌دار بودن و تغییرات فراوان سری زمانی گردشگری کشور در طول زمان دانست.

هم‌چنین در مورد مدل ANN نیز به‌استثنای افق ۶ ماهه مقدار MAPE برای سایر افق‌ها روند افزایشی دارد، در حالی که روند افزایش مقدار MAPE برای مدل ARFIMA و ARFIMA-ANN منتخب ملایم‌تر و گاهی دارای نوسان خفیف است، بنابراین، قابلیت اعتماد پیش‌بینی این مدل‌ها با افزوده شدن افق زمانی نسبت به مدل ANN بالاتر است.

در جدول‌های (۴) و (۵) نیز به ترتیب نتایج ارزیابی پیش‌بینی هر سه مدل فوق برای سال‌های ۱۳۸۹ و ۱۳۹۰ بر مبنای معیارهای MAPE, MAE, RMSE ارائه شده است. نتایج این جداول نیز نشان‌دهنده‌ی توان بالاتر پیش‌بینی مدل ARFIMA-ANN برای سال‌های مجزای پیش روی مذکور نسبت به مدل‌های رقیب می‌باشد. با این حال، مطابق معیار لوییس در ارزیابی سالانه‌ی مجزا نیز توان پیش‌بینی مدل ARFIMA-NN در مرز صحت بالا قرار می‌گیرد.

جدول (۴): معیارهای عملکردی مدل‌های مورد مطالعه برای داده‌های سال ۱۳۸۹

MODEL	RMSE	MAE	MAPE*	معیار لوییس
ARFIMA(p,d,q)	۳۵۲۵۹	۳۲۴۸۳	۱۵/۶۹	خوب
NN	۳۰۳۵۹	۲۷۶۶۲	۱۳/۲۴	خوب
ARFIMA-NN	۲۳۳۴۶	۲۰۲۲۳	۰۹/۸۲	صحت بالا

منبع: محاسبات تحقیق حاضر؛ *اعداد بر حسب (درصد)

جدول (۵): معیارهای عملکردی مدل‌های مورد مطالعه برای داده‌های سال ۱۳۹۰

MODEL	RMSE	MAE	MAPE*	معیار لوییس
ARFIMA(p,d,q)	۳۲۵۷۷	۲۷۸۴۴	۱۱/۷۲	خوب
NN	۴۹۵۷۲	۳۹۲۹۵	۱۶/۰۱	خوب
ARFIMA-NN	۲۵۶۲۵	۲۱۹۸۵	۰۹/۸۷	صحت بالا

منبع: محاسبات تحقیق حاضر؛ *اعداد بر حسب (درصد)

نکته دیگر در ارتباط با این جداول عملکرد نسبتاً بهتر مدل‌سازی بر مبنای ARFIMA (در افق زمانی بالاتر) نسبت به مدل شبکه عصبی است که می‌تواند دلیل بر در نظر گرفتن حافظه سری زمانی مورد آزمایش باشد، اگرچه پیش‌بینی هر دوی این مدل‌ها بر مبنای شاخص لوییس یک پیش‌بینی با صحت بالا نیست. هم‌چنین استفاده از مدل‌سازی ترکیبی بر مبنای مدل ARFIMA و شبکه عصبی توانسته است توان پیش‌بینی مدل را نسبت به مدل ARFIMA

بهبود ببخشد، به عبارت دیگر از آنجایی که مدل‌های غیرخطی عوامل بیشتری را در الگوسازی لحاظ می‌نمایند استفاده از آن‌ها در مدل ترکیبی سبب افزایش توان و دقت بیشتر مدل می‌شود.

این نتایج همگام با نتایج به دست آمده از مطالعات انجام شده به وسیله سایر محققان مانند ژانگ (۲۰۰۳، ۱۹۹۸) و آلاداگ و همکاران (۲۰۱۲) است که از طریق بررسی مقایسه‌ای در سری‌های زمانی مورد مطالعه‌ی خود نشان داده‌اند که مدل‌های ترکیبی توان بالاتری برای پیش‌بینی نسبت به هر کدام از مدل‌ها به تنهایی دارند.

نتیجه‌گیری

یکی از حوزه‌هایی که نیازمند برنامه‌ریزی مداوم و طراحی و ساخت طرح‌های زیربنایی و زیرساخت‌ها بر مبنای پیش‌بینی روند آتی است حوزه‌ی گردشگری است، به عبارت دیگر، هر کشوری برای انتخاب استراتژی مناسب و بلندمدت و برنامه‌ریزی مناسب در زمینه‌ی صنعت گردشگری نیازمند آگاهی دقیق از میزان گردشگر ورودی آینده‌اش است. از همین رو است که مدل‌سازی اقتصادی در جهت تخمین تعداد گردشگر آتی از اهمیت بسزایی برای هر کشور برخوردار است. همان‌گونه که سانگ و لی^۱ نیز اشاره نموده‌اند، مدل‌سازی اقتصادی در جهت تخمین تعداد گردشگر آتی به عنوان یک از مهم‌ترین حوزه‌های تحقیقات گردشگری از اهمیت بسزایی برخوردار است، به گونه‌ای که توجه بسیاری از محققین دانشگاهی و دست‌اندرکاران این حوزه را به خود جلب نموده است (سانگ و لی، ۲۰۰۸ : ۲۰۳) اگرچه اهمیت پیش‌بینی گردشگری در مطالعات مختلف مورد تأکید قرار گرفته است، ولی مطالعات محدودی پیرامون این موضوع در کشور ما انجام شده است، از این رو، در این پژوهش به پیش‌بینی تقاضای خارجی گردشگری در ایران بر مبنای مدل ARFIMA-ANN (که در سال ۲۰۱۲ به وسیله‌ی آلاداگ و همکاران پیشنهاد شده است) و مقایسه‌ی آن با مدل‌های خطی و غیرخطی سازنده‌ی آن پرداخته شده است. بخش خطی مدل آن‌ها را مدل ARFIMA تشکیل می‌دهد، اگرچه این مدل در چند سال اخیر برای پیش‌بینی و مدل‌سازی سری‌های زمانی حافظه بلندمدت مورد استفاده قرار گرفته است، اما به اعتقاد آلاداگ و همکاران مدل‌های مذکور همیشه برای تحلیل سری‌های زمانی حافظه‌ی بلندمدت که به‌طور همزمان هم شامل ساختار خطی و هم غیرخطی هستند مناسب نیستند، بلکه رویکرد مؤثر و کارا در چنین وضعیتی باید استفاده از ترکیب مدل‌های خطی و غیرخطی جهت بهبود عملکرد مدل‌های پیش‌بینی باشد (آلاداگ و همکاران، ۲۰۱۲: ۱۶) آن‌ها بر مبنای این رویکرد با استفاده از روش ارائه شده به وسیله‌ی ژانگ (۲۰۰۳) یک مدل ترکیبی متشکل از مدل ARFIMA برای ملحوظ نمودن بخش خطی و یک

^۱ Song and Li

مدل شبکه عصبی برای در نظر گرفتن ساختار غیرخطی سری زمانی در مدل پیشنهاد داده‌اند. نتایج تحقیق و آزمایش این نوع مدل‌سازی برای سری زمانی گردشگری کشور ترکیه نشان می‌دهد که مدل ترکیبی حاصل عملکرد بهتری نسبت به هرکدام از مدل‌ها به تنهایی داشته است که این را می‌توان جدا از ویژگی مدل ترکیبی تا حدودی به ویژگی‌های سری زمانی مورد مطالعه نیز نسبت داد.

مبتنی بر این روش در این مقاله به مطالعه و بررسی توانایی پیش‌بینی مدل ترکیبی ARFIMA-NN و مقایسه‌ی نتایج آن با مدل‌های ARFIMA و ANN در افق‌های زمانی متفاوت پرداخته‌ایم. بدین منظور نخست با استفاده از داده‌های ماهانه‌ی گمرک جمهوری اسلامی ایران در فاصله زمانی فروردین ۱۳۷۸ تا اسفند ۱۳۸۸ مدل شبکه عصبی پیش‌خور مناسب بر مبنای کمترین معیار میانگین مجذور خطا انتخاب شد. سپس با استفاده از داده‌های سری زمانی در بازه مذکور مدل ARFIMA مناسب بر داده‌ها برازش شد، با تکمیل فرآیند انتخاب مدل ARFIMA و محاسبه سری زمانی پسماند یا باقیمانده در گام بعدی مدل شبکه عصبی مناسب برای مدل‌سازی سری زمانی پسماند و تکمیل مدل هیبریدی ARFIMA-NN نیز انتخاب شد.

با انتخاب سه مدل ARFIMA، ANN و ARFIMA-NN در ادامه به پیش‌بینی سری زمانی گردشگری در افق‌های زمانی متفاوت ۶، ۱۲، ۱۸ و ۲۴ و همچنین دو سال مجزای پیش‌رو پرداختیم. نتایج استفاده از معیارهای RMSE, MAPE, MAE برای مقایسه‌ی توان مدل‌های ذکر شده مدل‌ها در پیش‌بینی افق پیش‌رو نشان می‌دهد که مدل ترکیبی ARFIMA-NN توان بالاتری در پیش‌بینی با افق‌های زمانی متفاوت نسبت به سایر روش‌های رقیب دارد. همچنین توانایی این مدل در پیش‌بینی سری زمانی در افق‌های زمانی دو سال مجزای پیش‌رو نیز نسبت به هر دو مدل دیگر به‌تنهایی بیشتر است. این نتایج همگام با نتایج مطالعه‌ی آلاداگ و همکاران در سال ۲۰۱۲ است. با این وجود، برخلاف نتیجه به دست آمده به‌وسیله‌ی آن‌ها مقایسه‌ی دقت نتایج پیش‌بینی با استفاده از معیار لوییس برای سری زمانی گردشگری کشور ما نشان می‌دهد که دقت پیش‌بینی این مدل در افق‌های زمانی مورد آزمون در مرز صحت بالا قرار می‌گیرد که آن را می‌توان تا حدود بسیار زیادی به نوبه دار بودن سری زمانی گردشگری کشور و تأثیرپذیری زیاد آن از شرایط محیطی آن‌گونه که از نمودار آن مشهود است نسبت داد. با این حال و در یک جمع‌بندی بر اساس نتایج به دست آمده در این مطالعه، استفاده از مدل ترکیبی ARFIMA-ANN برای پیش‌بینی سری زمانی گردشگری کشور توانسته است به شکل مشهودی عملکرد پیش‌بینی را نسبت به هرکدام از مدل‌های ARFIMA و ANN بهبود ببخشد، بنابراین می‌توان از این مدل به‌عنوان یک روش جایگزین و مناسب‌تر نسبت به مدل‌های ARFIMA و ANN برای پیش‌بینی گردشگری پیش‌روی کشور استفاده نمود.

منابع

۱. کاوه‌ئیان، نسترن (۱۳۸۱). برآورد تابع تقاضای جهانگردی بین‌المللی ایران طی سال‌های ۱۳۷۵-۱۳۵۰. دانشگاه شهید بهشتی، دانشکده‌ی علوم اقتصادی و سیاسی، تهران.
۲. مراسلی، عزیز (۱۳۷۴). تخمین توابع عرضه و تقاضای خارجی گردشگری در ایران، پایان‌نامه‌ی کارشناسی ارشد، دانشکده‌ی علوم انسانی دانشکده‌ی تربیت مدرس تهران، تهران.
۳. موسایی، میثم (۱۳۸۳). تخمین تابع تقاضای گردشگری به ایران، فصلنامه‌ی پژوهشنامه‌ی بازرگانی، شماره ۳۲: ۲۴۴-۲۲۵.
۴. نوری، مهناز (۱۳۷۵). برآورد تابع تقاضای گردشگری در ایران ۱۳۷۲-۱۳۴۸، پایان‌نامه‌ی کارشناسی ارشد، دانشکده‌ی علوم اقتصادی و اجتماعی، دانشگاه تهران، تهران.
5. Aladag, C.H., Egrioglu, E. and Kadilar, C. (2012). Improvement in forecasting accuracy using the hybrid model of ARFIMA and feed forward neural network, **American Journal of Intelligent Systems**, 2(2):12-17.
6. Archer, B.H. (1987). Demand forecasting and estimation, In Ritchie, J.R.B. and Goeldner, C.R. (Eds) **Travel, tourism and hospitality research**, New York: Wiley.
7. Aslanargun, A., Mammadov, M., Yazici, B. and Yolacan, S. (2007). Comparison of ARIMA, neural networks and hybrid models in time series: Tourist arrival forecasting, **Journal of Statistical Computation and Simulation**, 77: 29-53.
8. Athanasopoulos, G., Hyndman, R.J., Song, H. and Wu, D.C. (2011). The tourism forecasting competition, **International Journal of Forecasting**, 27: 822-844.
9. Burger, C.J.S.C., Dohnal, M., Kathrada, M. and Law, R. (2001). A practitioners guide to time-series methods for tourism demand forecasting—A case study of Durban, South Africa, **Tourism Management**, 22: 403-409.
10. Claveria, O., Monte, E. and Torra, S. (2014). Tourism demand forecasting with neural network models: Different ways of treating information, **International Journal of Tourism Research**, 1-20, DOI: 10.1002/jtr.2016.
11. Claveria, O. and Torra, S. (2014). Forecasting tourism demand to Catalonia: Neural networks vs. time series models, **Economic Modelling**, 36: 220-228.
12. Chang, Y.W. and Liao, M.Y. (2010). A seasonal ARIMA model of tourism forecasting: The case of Taiwan, **Asia Pacific journal of Tourism research**, 15(2): 215-221.
13. Chu, F.L. (2008). A fractionally integrated autoregressive moving average approach to forecasting tourism demand, **Tourism Management**, 29: 79-88.
14. Chu, F.L. (2009). Forecasting tourism demand with ARMA-based methods, **Tourism Management**, 30:741-751.
15. Cuhadar, M. (2014). Modelling and forecasting inbound tourism demand to Istanbul—A comparative analysis, **European Journal of Business and Social Sciences**, 2:12.
16. Doornik, A. and Ooms, M. (1999). **A package for estimating, forecasting and simulating ARIFMA models: Help of ARIFMA package 1.0 for Ox**, from fmwww.bc.edu/ec-p/software/ox/Ox.arfima.v2.1.pdf.
17. Gil-Alana, L.A. (2005). Modeling international monthly arrivals using seasonal univariate long-memory processes, **Tourism Management**, 26: 867-878.
18. Granger C.W.J and Joyeux, R. (1980). An introduction to long-memory time series models and fractional differencing- J, **Time Series Anal**, 1(1):15-29.

19. Hwang, K.P. and Day, Y.J. (2013). Tourism revenue forecasting: A hybrid model approach, **Actual Problems of Economics**, 141(3): 478-484.
20. Kuan-Yu, C. (2011). Combining linear and nonlinear model in forecasting tourism demand, **Expert Systems with Applications**, 38: 10368–10376.
21. Lewis, C.D. (1982). **International and business forecasting methods**, London: Butterworths.
22. Lildhold, P. (2000). **Long memory an ARFIMA modeling**, University of Aarhus.
23. Loganathan, N. and Ibrahim, Y. (2010). Forecasting international tourism demand in Malaysia using Box Jenkins sarima application, **South Asian Journal of Tourism and Heritage**, 3(2): 50-59.
24. Saayman, A. and Saayman, M. (2010). Forecasting tourist arrivals in South Africa, **Acta Commercii**, 10: 281-293.
25. Shitan, M. (2008). Time series modelling of tourist arrivals to Malaysia, **InterStat, (October)**: 1-12.
26. Song, H. and Li, G. (2008). Tourism demand modelling and forecasting—A review of recent research, **Tourism Management**, 29 (2): 203-220.
27. Song, H. and Witt, S.F. (2006). Forecasting international tourist flows to Macau, **Tourism Management**, 27: 214-224.
28. Teixeira, J. P. and Fernandes, P.O. (2012). Tourism time series forecast-different ANN architectures with time index input, **Procedia Technology**, 5: 445-454.
29. Tseng, F.M., Yu, H.C. and Tzeng, G.H. (2002). Combining neural network with seasonal time series ARIMA model, **Technological Forecasting and Social Change**, 69(1):71–87.
30. UNWTO. (2012). ‘Why tourism?’ [Online article]. Available from: <http://www2.unwto.org/en/content/why-tourism>, [Accessed 15 September 2012].
31. Xiu, J. and Jin, Y. (2007). Empirical study of ARFIMA model based on fractional differencing, **Physica A**, 377:138 –154.
32. Zhang, G.P. (2003). Time series forecasting using a hybrid ARIMA and neural network model, **Neurocomputing**, 50: 159-175.
33. Zhang, G.P., Patuwo, E.B. and Hu, M.Y. (1998). Forecasting with artificial neural networks: the state of the art, **International Journal of Forecasting**, 14: 35–62.
34. Zhang, G.P., Patuwo, E.B. and Hu M.Y. (2001). A simulation study of artificial neural networks for nonlinear time-series forecasting, **Computer & Operation Research**, 28: 381–396.