

## پیش‌بینی تقاضای حمل‌ونقل هوایی مسافر در پروازهای فرودگاه بین‌المللی کرمان

### مقاله علمی - پژوهشی

پویان ایار\*، استادیار، دانشکده مهندسی عمران، گروه راه و ترابری، دانشگاه علم و صنعت ایران، تهران، ایران  
محمدعلی زاینده‌رودی، دانشجوی دکتری، دانشکده مهندسی عمران، گروه راه و ترابری، دانشگاه علم و صنعت ایران، تهران، ایران  
\*پست الکترونیکی نویسنده مسئول: [ayar@iust.ac.ir](mailto:ayar@iust.ac.ir)

دریافت: ۱۴۰۱/۰۴/۲۹ - پذیرش: ۱۴۰۱/۱۰/۲۵

صفحه ۱۴۶-۱۳۹

#### چکیده

در این مقاله تقاضای جابجایی مسافر از طریق هواپیما در ایران مورد تجزیه و تحلیل قرار می‌گیرد. با استفاده از مدلی برای تقاضای مسافر، اثرگذاری متغیرهای جغرافیایی، اقتصادی-اجتماعی و رقابتی بر میزان تقاضا بررسی شده‌است. برای این منظور اطلاعات نشست و برخاست‌های فرودگاه کرمان طی سال‌های ۱۳۹۰ تا ۱۳۹۹ مورد بررسی قرار گرفت. برای پیش‌بینی تقاضا ابتدا از یک مدل اقتصادسنجی بهره گرفته شده‌است. در این مدل معنی‌داری تمام متغیرهای مورد استفاده در این مقاله بررسی می‌شود. سپس با حذف متغیرهایی که دارای معنی‌داری ناچیزی هستند، یک مجموعه اطلاعات جدید ایجاد می‌شود. در ادامه این اطلاعات توسط الگوریتم خوشه‌بندی *K-Means* پردازش شده و سپس به عنوان داده‌های آموزشی برای یادگیری شبکه عصبی استفاده می‌شوند. شبکه عصبی مورد استفاده، شبکه یادگیری عمیق *LSTM* است که به منظور پیش‌بینی تقاضای مسافران برای سال‌های آینده استفاده شده‌است. در نهایت با داشتن متغیرهای اقتصادی و اجتماعی شامل تولید ناخالص داخلی، درآمد، جمعیت، تورم، نرخ ارز، قیمت بنزین و قیمت نفت برای سال‌های آینده درصد تغییرات تعداد مسافران را برای هر سال نسبت به سال قبل پیش‌بینی شده‌است. نتایج خروجی شبکه عصبی تغییرات تقاضای سفرهای هوایی را بر اساس متغیرهای تولید ناخالص ملی، متوسط درآمد مردم کرمان، نرخ تورم قیمت بنزین و قیمت نفت برای هر زمان به دست می‌آورد که در میان این متغیرها تولید ناخالص ملی بیشترین تأثیر را بر تقاضای سفرهای هوایی دارد. دقت به دست آمده در این روش ۸۳٪ است که دقت بالایی برای تقاضای سفرهای هوایی نسبت به روش‌های رگرسیونی می‌باشد.

واژه‌های کلیدی: اقتصادسنجی، الگوریتم خوشه‌بندی، پیش‌بینی تقاضای مسافران هوایی، رگرسیون چندگانه، شبکه عصبی

#### ۱- مقدمه

کردن مسیرهای جدید، بهبود خدمات به مسافران و تغییر قیمت بلیط مورد نیاز است. در این میان، توجه بیشتر به پیش‌بینی تقاضای کوتاه‌مدت نقش مهمی در برنامه‌ریزی فرودگاه، برنامه‌ریزی عملیات و نگهداری کوتاه‌مدت ایفا می‌کند. با این حال، پیش‌بینی تقاضای مسافر به دلیل ویژگی‌های چندوجهی فرآیند، مانند غیر ثابت بودن، نوسانات زیاد و بی‌نظمی بودن، بسیار چالش برانگیز است (Jalili and Manteghi, 1397).

تجزیه و تحلیل بازار سفرهای هوایی بخشی جدایی ناپذیر از

حمل‌ونقل هوایی یک سیستم پیچیده است که شامل هواپیماها، فرودگاه‌ها، مسیرهای دسترسی زمینی، مسیرهای پرواز و همچنین سیستم‌های مدیریت ترافیک هوایی است. مهم‌ترین نقش هوانوردی در صنعت حمل‌ونقل و توسعه اجتماعی-اقتصادی است. در صنعت هواپیمایی، پیش‌بینی تقاضای مسافر در شرکت‌های هواپیمایی از اهمیت حیاتی برخوردار است. پیش‌بینی تقاضای بلندمدت برای توسعه برنامه‌های عملیاتی، مانند افزایش تعداد پروازها بین مسیرها، ارتقاء فرودگاه‌ها، باز

لایه و رگرسیون بردار پشتیبان، به طور متناوب در مراحل دوم و سوم استفاده می‌شوند. در (Srisaeng, Baxter, and Wild. 2015) پیش‌بینی تقاضای مسافری حاصل از کیلومتر مسافری با استفاده از روش‌های مدل‌سازی سنتی اقتصادسنجی و شبکه عصبی مصنوعی متمرکز است. برای توسعه مدل، تولید ناخالص داخلی واقعی استرالیا، تولید ناخالص داخلی واقعی سرانه، کرایه هواپیما، جمعیت و بیکاری استرالیا، گردشگری و ۴ متغیر ساختگی، با استفاده از داده‌های فصلی به دست آمده بین سال‌های ۲۰۰۲ و ۲۰۱۲، به عنوان پارامترهای مدل انتخاب شده‌اند. شبکه عصبی از معماری پرسپترون چند لایه (MLP) استفاده می‌کند که یک شبکه پیش‌خور چند لایه است و توابع سیگموئید و خطی به عنوان توابع فعال‌سازی با الگوریتم انتشار استفاده می‌شوند. در (Suh and Ryerson.2019) از داده‌های در دسترس عموم برای توسعه و آزمایش روش‌هایی استفاده می‌شود که برنامه‌ریزان فرودگاه را قادر می‌سازد که احتمال کاهش شدید در حجم مسافران را پیش‌بینی کنند و همچنین دقت پیش‌بینی را با ترکیب سیستماتیک خطاهای پیش‌بینی قبلی همتایان فرودگاه بهبود بخشند و بنابراین پیش‌بینی‌های خوش‌بینانه را «پایه‌دار» کنند. با گنجاندن خطاهای پیش‌بینی گذشته از فرودگاه‌های مشابه در مدل‌های پیش‌بینی فرودگاه، روشی را ایجاد می‌کنند که مبتنی بر شیوه‌های پیش‌بینی تقاضا است و می‌تواند دقت مدل‌های پیش‌بینی تقاضای هوانوردی را به طور قابل‌توجهی بهبود بخشد. در (Saâdaoui, Saadaoui, and Rabbouch. 2020) روش مبتنی بر تجزیه سری‌های زمانی و شبکه‌های عصبی مصنوعی (ANN) در چارچوب مدیریت ترافیک هوایی بررسی و بازنگری می‌شود. در این رابطه، یک رویکرد ترکیبی که شبکه‌های عصبی پیش‌خور را با برازش منحنی رگرسیون مبتنی بر حداقل مربعات غیرخطی برای پیش‌بینی چند مرحله‌ای ترکیب می‌کند، توسعه یافته‌است. در (Samli, Firat, and Yiltas-Kaplan.2021) روشی برای تعیین ظرفیت بهینه صندلی‌های هواپیما که بتواند بالاترین ضریب بار را برای عملیات پرواز بین هر دو کشور تامین کند، معرفی شده‌است. روش‌های یادگیری ماشین شبکه عصبی مصنوعی (ANN)، رگرسیون خطی تقویت گرادیان و جنگل تصادفی به کار گرفته شده‌اند و نرم‌افزاری برای حل مساله توسعه داده شده‌است. مجموعه داده‌های ایجاد شده از پایگاه داده بانک

طرح شرکتی یک شرکت هواپیمایی است که استفاده از ظرفیت، نیازهای نیروی انسانی و پیش‌بینی‌های مالی برای پروژه‌های سرمایه‌ای عملیاتی و غیره را بازتاب می‌دهد. علاوه بر این، با ارزیابی عینی سمت تقاضا در تجارت حمل‌ونقل هوایی، به کاهش ریسک شرکت هواپیمایی کمک می‌کند. در عوض، باید به صورت پویا برای کمک به یک شرکت هواپیمایی برای ارزیابی استراتژی‌ها استفاده شود. روش‌های مختلفی از مدل‌سازی اقتصادسنجی گرفته تا تکنیک‌های سری زمانی برای نمایش بازار سفرهای هوایی در دسترس هستند. رویکردهای سری زمانی رایج‌ترین روش‌ها برای پیش‌بینی تقاضا هستند. این روش‌ها به دلیل ناتوانی در شناسایی علل رشد بازار و پیوند دادن رشد آتی با تحولات مورد انتظار عوامل مسبب، نامناسب هستند (Kafaei and Kabirirad.1390). از طرفی یادگیری ماشینی یکی از رایج‌ترین روش‌های تشخیص الگو در داده‌های پیچیده است. در سال‌های اخیر، هزینه محاسباتی کاهش یافته در حالی که ظرفیت حافظه افزایش یافته است که منجر به بهره‌مندی برنامه‌های کاربردی در دنیای واقعی از این تکنیک‌ها شده‌است. هدف این مقاله توسعه روش اقتصادسنجی و یادگیری ماشین است که رشد آینده تقاضای سفرهای هوایی در شهر کرمان را با تحولات مورد انتظار عوامل مسبب مرتبط می‌سازد.

## ۲- پیشینه تحقیق

توسعه سیستم‌های پیش‌بینی دقیق می‌تواند در برنامه‌های کاربردی دنیای واقعی چالش برانگیز باشد. مدل‌سازی سری‌های زمانی در دنیای واقعی کار بسیار دشواری است، زیرا آنها معمولاً از الگوهای خطی و غیرخطی تشکیل شده‌اند که به شکلی با هم ترکیب می‌شوند. چندین سیستم ترکیبی که تکنیک‌های خطی و غیرخطی را ادغام می‌کنند، از نظر دقت در مقایسه با مدل‌های منفرد، نتایج مطلوب‌تری را به دست آورده‌اند. در (Domingos, de Oliveira, and de Mattos Neto. 2019) یک سیستم ترکیبی پیشنهاد می‌شود که به دنبال یک تابع مناسب برای ترکیب پیش‌بینی‌های مدل‌های خطی و غیرخطی می‌گردد. بنابراین، سیستم پیشنهادی مدل‌سازی خطی سری‌های زمانی و مدل‌سازی غیرخطی سری خطا را انجام می‌دهد. در هر دو نسخه، مدل در مرحله اول استفاده می‌شود و دو مدل هوشمند غیرخطی - پرسپترون چند

مدل‌های پیش‌بینی ترکیبی ARIMA-SVM اخیراً ایجاد شده‌اند که از قدرت منحصربه‌فرد مدل‌های ARIMA و SVM به ترتیب در مدل‌سازی خطی و غیرخطی بهره می‌برند. در (Ming et al. 2014) به طور یکسان به این مدل‌های ترکیبی ARIMA-SVM پرداخته شده‌است و به گسترش آن‌ها در مورد پیش‌بینی چند مرحله‌ای برای ترافیک مسافران هوایی با دو استراتژی پیش‌بینی چند مرحله‌ای متداول، یعنی استراتژی تکراری و استراتژی مستقیم، ادامه می‌دهد. علاوه بر این، اثربخشی رویکردهای پیش‌پردازش داده‌ها، مانند فصل‌زدایی و گرایش‌زدایی، همراه با این دو استراتژی بررسی و اثبات می‌شود. در (Naghawi, Alobeidyeen, and Abdel-Jaber.2019) توسعه یک مدل اقتصادسنجی تقاضای سفر هوایی مسافر انجام شده‌است. دو مرحله در فرآیند توسعه مدل وجود دارد. در مرحله اول، عوامل تعیین کننده تقاضا که همبستگی بالایی با تقاضای سفر هوایی مسافر دارند با استفاده از تکنیک رگرسیون گام به گام شناسایی شده و سپس در مرحله دوم، از تحلیل رگرسیون خطی چندگانه برای توسعه مدل اقتصادسنجی استفاده شده‌است. در (Kumar and Bhandari.2021) از یک مدل اقتصادسنجی برای پیش‌بینی تقاضای مسافران هوایی استفاده شده‌است. این مدل با جمع‌آوری داده‌های مقطعی با استفاده از تحلیل رگرسیون خطی چندگانه کالیبره شد. این مدل با دو روش مختلف اعتبار سنجی شده‌است که شامل تکنیک اعتبارسنجی متقابل و روش پیش‌بینی معکوس برای دانستن اعتبار آماری و منطقی مدل برای استفاده در پیش‌بینی تقاضای سفر است. در جدول (۱) برخی از مدل‌های بکار رفته توسط محققین در حوزه پیش‌بینی تقاضای سفرهای هوایی مورد اشاره قرار گرفته‌است.

### ۳- روش پیشنهادی

در این بخش، روش‌ها و مدل‌های مورد نیاز برای توسعه و ارزیابی پیاده‌سازی‌های پیشنهادی شرح داده می‌شود. در ابتدا، روش اقتصادسنجی به منظور یافتن متغیرهای مؤثر در پیش‌بینی تقاضا استفاده می‌شود. این روش برای انتخاب متغیرهایی است که بیشترین تأثیر را بر پیش‌بینی تقاضا دارند و موجب کاهش داده‌های اضافی و غیرضروری می‌شود و پیش‌بینی را ساده‌تر می‌کند. در ادامه الگوریتم خوشه‌بندی و سپس شبکه‌های عصبی عمیق مورد تجزیه و تحلیل قرار خواهند گرفت. از آنجایی که

جهانی، که شامل هزاران ویژگی برای همه کشورها است، استفاده شده‌است. در (Kim et al. 2020) یک مدل رگرسیون چندگانه با متغیرهای توضیحی متعدد با بررسی داده‌های طبقه‌بندی شده اجتماعی-اقتصادی خانوار که بر تقاضای هوایی تأثیر می‌گذارد، ایجاد شده‌است. مدل تقاضای سفر هوایی برای سال‌های ۲۰۰۹-۲۰۱۵ بر اساس میانگین سالانه تعداد بازدید از جزیره ججو توسط خانوارهایی در گروه‌های درآمدی خاص کالیبره شده‌است. متغیر توضیحی با استفاده از یک متغیر ساختگی برای هر گروه درآمد خانوار و نسبت بلیط هواپیما به تولید ناخالص داخلی سرانه تنظیم شد. در مدل به دست آمده درآمد بالاتر خانوار به معنای بازدیدهای مکرر از جزیره ججو بود. در (Kanavos et al. 2021) سعی شده با استفاده از سری‌های زمانی و تکنیک‌های یادگیری عمیق تقاضای هوانوردی پیش‌بینی شود. مدل‌های تخمین و پیش‌بینی تقاضای سفر هوایی با استفاده از روش‌های میانگین متحرک یکپارچه خودکار، رویکردهای فصلی و شبکه‌های عصبی یادگیری عمیق توسعه داده شده‌است. علاوه بر این، این تحقیق با هدف ارائه راهنما برای انتخاب رویکرد مدل‌سازی بهینه، مقایسه کیفی تکنیک‌های مذکور را انجام داده‌است. در (Jin et al. 2020) یک رویکرد ترکیبی VMD-ARMA/KELM-KELM برای پیش‌بینی کوتاه‌مدت پیشنهاد می‌شود، که شامل تجزیه حالت متغیر، مدل میانگین متحرک اتورگرسیون و یادگیری ماشین شدید هسته است. اول، VMD برای تجزیه داده‌های اصلی به چندین عملکرد حالت تقسیم شده تا پیچیدگی آنها کاهش یابد. سپس، آزمون ریشه واحد برای طبقه‌بندی تمام حالت‌ها به سری‌های پایدار و ناپایدار استفاده می‌شود. در همین حال، مدل‌های ARMA و KELM به ترتیب برای پیش‌بینی اجزای ثابت و غیر ساکن استفاده می‌شوند. در نهایت، نتیجه نهایی توسط مدل KELM دیگری که نتایج پیش‌بینی همه اجزا را در خود جای داده‌است، ادغام می‌شود. یک روش تحلیل پیش‌بینی ترکیبی مبتنی بر ARIMA-REGRESSION در (Li 2019) با مفهوم عملگر IOWHA و تحلیل پیش‌بینی بر روی مشتقات مختلف به عنوان پایه پیشنهاد شده‌است. این مقاله ابتدا مدل پیش‌بینی یک آیتم را ساخته و سپس از مدل تحلیل رگرسیون چندگانه و مدل سری زمانی ARIMA برای پیش‌بینی حجم سالانه مسافران هواپیمایی کشوری در چین استفاده کرده‌است.

آموزشی که شامل متغیرهای ورودی مؤثر مسأله هستند، یادگیری می‌شود. روش مورد استفاده در این مقاله به دلیل انتخاب متغیرهای مناسب از میان متغیرهای موجود و عملیات پردازش روی داده‌ها قبل از استفاده در شبکه عصبی یک روش جدید و کارآمد است و نتایج پیش بینی حاصل از این روش با دقت بسیار بالایی قابل قبول است.

داده‌های مورد بررسی در شکل اولیه خود مناسب استفاده در شبکه عصبی نیستند. باید یک پیش‌پردازش روی داده‌ها انجام شود. به همین منظور از الگوریتم خوشه‌بندی استفاده می‌شود و داده‌ها به تعدادی خوشه تقسیم می‌شوند. این پردازش سبب بالا رفتن دقت خروجی و کارایی بهتر مدل می‌گردد. استفاده از شبکه عصبی نیز به منظور پیش‌بینی تقاضای سفر با استفاده از داده‌های پردازش شده است. شبکه عصبی توسط داده‌های

جدول ۱. برخی از مدل‌های بکار رفته در پیش‌بینی تقاضای سفر هوایی

نام نویسنده	سال	روش پیش‌بینی تقاضا
دومینگوس و همکاران	۲۰۱۹	استفاده از مدل ARIMA و دو مدل هوشمند غیرخطی - پرسپترون چند لایه (MLP) و رگرسیون بردار پشتیبان (SVR)
سریسانگ و همکاران	۲۰۱۵	روش‌های مدل‌سازی سنتی اقتصادسنجی و شبکه عصبی مصنوعی (ANN) بر اساس تولید ناخالص داخلی واقعی سرانه، کرایه هواپیما، جمعیت و بیکاری، گردشگری و $\Delta$ متغیر ساختگی، با استفاده از داده‌های فصلی
سوه و ریرسون	۲۰۱۹	گنجاندن خطاهای پیش‌بینی گذشته از فرودگاه‌های مشابه در مدل‌های پیش‌بینی فرودگاه
سادوی و همکاران	۲۰۲۰	تجزیه سری‌های زمانی و شبکه‌های عصبی مصنوعی (ANN)
رملی و همکاران	۲۰۲۱	روش‌های یادگیری ماشین شبکه عصبی مصنوعی (ANN)، رگرسیون خطی (LR)، تقویت گرادیان (GB) و جنگل تصادفی (RF)
کاناووس و همکاران	۲۰۲۱	استفاده از روش‌های میانگین متحرک یکپارچه خودکار (ARIMA)، رویکردهای فصلی (SARIMA) و شبکه‌های عصبی یادگیری عمیق (DLNN)
جین و همکاران	۲۰۱۹	تجزیه حالت متغیر (VMD)، مدل میانگین متحرک اتورگرسیو (ARMA) و یادگیری ماشین شدید هسته (KELM)
لی	۲۰۱۹	تحلیل رگرسیون چندگانه و مدل سری زمانی ARIMA
مینگ و همکاران	۲۰۱۴	پیش‌بینی ترکیبی ARIMA-SVM
نقوی و همکاران	۲۰۱۹	استفاده از تکنیک رگرسیون گام به گام و سپس تحلیل رگرسیون خطی چندگانه برای توسعه مدل اقتصادسنجی
کومار و همکاران	۲۰۲۱	مدل اقتصادسنجی با جمع‌آوری داده‌های مقطعی با استفاده از تحلیل رگرسیون خطی چندگانه

گذشته با کیفیت پایین یا دانش نادرست از عوامل ایجاد کننده رشد تراکم ایجاد شود، بی‌فایده است. داده‌های مورد استفاده در مدل از انواع مختلفی از منابع اجتماعی-اقتصادی سرچشمه می‌گیرند. داده‌های اقتصادی و جمعیتی شامل داده‌های مربوط به تولید ناخالص داخلی، درآمد، جمعیت، تورم، نرخ ارز، قیمت بنزین و قیمت نفت است. در این مدل از رگرسیون خطی استفاده شده است.

### ۳-۲- خوشه‌بندی

خوشه‌بندی یکی از رایج‌ترین روش‌های تجزیه و تحلیل داده‌ها است که برای به دست آوردن اطلاعاتی در مورد ساختار داده‌ها استفاده می‌شود و می‌تواند زیر گروه‌ها را در داده‌ها شناسایی کند. به صورتی که داده‌هایی در یک زیر گروه (خوشه) قرار می‌گیرند، بسیار مشابه هستند. از طرفی داده‌هایی

### ۳-۱- روش اقتصادسنجی

اقتصادسنجی شاخه‌ای از علم اقتصاد و نتیجه طبیعی پیشرفت و تکامل علم است که هر روز بیش از پیش بر دامنه یافته‌های آن افزوده می‌شود و یکی از ابزارهایی است که اقتصاددانان برای پیش‌بینی تغییرات آتی اقتصاد از آن استفاده می‌کنند. در حال حاضر از اقتصادسنجی به عنوان یک ابزار اساسی در پژوهش‌های کاربردی در زمینه‌های مختلف اقتصادی و غیراقتصادی استفاده می‌گردد و هر روز بر دامنه کاربرد آن افزوده می‌شود، بطوریکه می‌توان از آن به عنوان اصلی‌ترین روش‌های پژوهش در مطالعات اقتصادی نام برد. مدل اقتصادسنجی ابزار ارزشمندی برای افزایش درک نحوه عملکرد یک سیستم اقتصادی و آزمایش و ارزیابی سیاست‌های جایگزین است. با این حال، چنین مدلی اگر بر اساس داده‌های

غیرخطی پیچیده دلخواه بین عوامل وابسته و مستقل را نشان دهند. دلیل اصلی پذیرش آنها این است که شبکه‌های عصبی تولید اساسی داده‌ها را بدون هیچ گونه فرضی در مورد شکل مدل تخمین می‌زنند. یکی دیگر از ویژگی‌های اصلی شبکه‌های عصبی این واقعیت است که آنها می‌توانند یک کلاس عظیم از عملکردها را به روشی دقیق تقریب بزنند. شبکه‌های عصبی رفتار مغز انسان را منعکس می‌کنند و به برنامه‌های رایانه‌ای اجازه می‌دهند الگوها را تشخیص داده و مشکلات رایج در زمینه‌های هوش مصنوعی، یادگیری ماشینی و یادگیری عمیق را حل کنند. شبکه‌های عصبی، که به عنوان شبکه‌های عصبی مصنوعی یا شبکه‌های عصبی شبیه‌سازی شده نیز شناخته می‌شوند، زیر مجموعه‌ای از یادگیری ماشینی هستند و در قلب الگوریتم‌های یادگیری عمیق قرار دارند. نام و ساختار آنها از مغز انسان الهام گرفته شده‌است و از راهی که نورون‌های بیولوژیکی به یکدیگر نشان می‌دهند تقلید می‌کند. شبکه‌های عصبی برای یادگیری و بهبود دقت خود در طول زمان به داده‌های آموزشی متکی هستند. با این حال، هنگامی که این الگوریتم‌های یادگیری تنظیم شدند، ابزارهای قدرتمندی در علوم رایانه و هوش مصنوعی هستند و این امکان را می‌دهند که داده‌ها با سرعت بالا طبقه‌بندی و خوشه‌بندی شوند. انجام برخی وظایف مانند تشخیص گفتار یا تشخیص تصویر در مقایسه با شناسایی دستی توسط متخصصان انسانی ممکن است چند دقیقه طول بکشد. الگوریتم جستجوی گوگل یکی از شناخته شده‌ترین شبکه‌های عصبی است. شبکه‌های عصبی مصنوعی از یک یا چند لایه تشکیل شده‌اند که شامل یک لایه ورودی، یک یا چند لایه مخفی و یک لایه خروجی است. هر گره یا نورون مصنوعی به دیگری متصل می‌شود و وزن و حد آستانه مربوطه را دارد. اگر خروجی هر گره جداگانه بیشتر از مقدار آستانه مشخص شده باشد، آن گره فعال می‌شود و داده‌ها را به لایه بعدی شبکه ارسال می‌کند. در غیر این صورت، هیچ داده‌ای به لایه بعدی شبکه منتقل نمی‌شود (Fausett, 1969). اطلاعات شبکه‌های عصبی سنتی دارای ماندگاری نیستند و به نظر می‌رسد این یک کاستی اساسی است. شبکه‌های عصبی بازگشتی به دنبال برطرف کردن این کاستی هستند (Qiao et al. 2020). شبکه‌های حافظه‌دار کوتاه مدت بلند مدت که "LSTM" نام دارند، یک نوع خاص از شبکه‌های عصبی بازگشتی هستند که می‌توانند وابستگی‌های طولانی مدت را یاد بگیرند. LSTM‌ها

که در خوشه‌های مختلف قرار دارند بسیار متفاوت هستند. الگوریتم K-Means یکی از روش‌های خوشه‌بندی است که جزء الگوریتم‌های یادگیری بدون نظارت است یعنی مجموعه داده‌های بدون دسته‌بندی را در خوشه‌های مختلف گروه‌بندی می‌کند. K، تعداد این گروه‌بندی‌ها (خوشه‌ها) است. خوشه‌هایی که باید در این فرآیند ایجاد شوند، از پیش تعیین می‌شوند، به عنوان مثال در  $K=2$  دو خوشه و  $K=3$  سه خوشه وجود دارد. در این الگوریتم می‌توان داده‌ها را در گروه‌های مختلف دسته‌بندی کرد. این الگوریتم روش مناسبی برای مشخص نمودن گروه‌های مختلف داده‌ها در یک مجموعه داده بدون نظارت است. این الگوریتم مبتنی بر نقاط مرکز داده‌ها است، به این صورت که هر خوشه با یک مرکز مشخص می‌شود. هدف اصلی این الگوریتم به حداقل رساندن فاصله بین داده‌ها و نقاط مرکز خوشه‌های مربوط به آنها است. این الگوریتم مجموعه داده‌های فاقد دسته‌بندی را گرفته و آنها را به تعداد K خوشه تقسیم می‌کند و این عمل را تا جایی که بهینه‌ترین خوشه‌ها را پیدا نکند، تکرار می‌کند. تعداد K را در این الگوریتم از قبل باید تعیین کرد. بنابراین دو وظیفه عمده الگوریتم خوشه‌بندی K-means این است که با استفاده از یک فرآیند تکرارشونده، بهترین نقاط مرکز K را برای خوشه‌ها تعیین می‌کند و همچنین هرکدام از نقاط داده‌ها را به نزدیک‌ترین مرکز K اختصاص می‌دهد که مجموعه نقاطی از داده که نزدیک به مرکز K هستند در کنار یکدیگر یک خوشه ایجاد می‌کنند. بنابراین، هرکدام از خوشه‌ها دارای نقاط اشتراک با برخی از داده‌ها است و دارای فاصله مناسبی از خوشه‌های دیگر است (Likas, Vlassis, and J. Verbeek 2003). در این مقاله برای آماده‌سازی داده‌ها قبل از ورود به شبکه عصبی از خوشه‌بندی K-Means استفاده شده‌است. داده‌ها ابتدا توسط خوشه‌بندی K-Means به تعداد 60 خوشه تقسیم شده و یک مجموعه داده جدید بر اساس این خوشه‌بندی‌ها ایجاد می‌شود. این داده‌ها به عنوان ورودی به شبکه عصبی LSTM داده می‌شوند.

### ۳-۳- شبکه‌های عصبی

بررسی استراتژی‌های پیشرفته برای تعدادی از مسائل طبقه‌بندی به منظور افزایش دقت و عملکرد، یکی از اهداف حیاتی محققان است. شبکه‌های عصبی می‌توانند هر ارتباط

رگرسیون خطی از پارامترهای تولید ناخالص داخلی، متوسط درآمد مردم کرمان، جمعیت کرمان، نرخ تورم، نرخ ارز، قیمت بنزین و قیمت نفت به عنوان متغیرهای مستقل استفاده شده است. ابتدا همبستگی این متغیرها بررسی شد که به این منظور داده‌های مربوط به تمام متغیرها در نرم افزار SPSS وارد شده و همبستگی هرکدام از آنها با یکدیگر توسط این نرم افزار به دست آمد. با توجه به این نتایج هیچ کدام از متغیرها با یکدیگر همبستگی ندارند.

داده‌های این متغیرها مربوط به ۱۰ سال اخیر است. متغیر وابسته در این مدل درصد تغییرات تعداد مسافری در ۱۰ سال اخیر است. بعد از حل رگرسیون خطی به کمک نرم افزار SPSS مدلی برای تخمین درصد تغییرات تقاضا به دست آمد. همچنین معنی داری هر کدام از متغیرهای مستقل بررسی شده که متغیرهای جمعیت و نرخ ارز به معنی داری کمتر از ۰/۹ رسیدند بنابراین با حذف این متغیر مدل نهایی برای تخمین تقاضای مسافری در معادله (۱) نشان داده می شود.

$$\text{Passengers} = -1.5T + 0.15B - 1.37 \times 10^7 D - 2.82 \times 10^6 O + 3.12 \times 10^5 G - 40.454 \quad (1)$$

خوشه‌بندی K-Means پردازش شده و به تعداد ۶۰ خوشه تقسیم شدند. استفاده از داده‌های خوشه‌بندی تأثیر به سزایی در عملکرد و یادگیری بهتر شبکه عصبی دارد. سپس یک شبکه عصبی LSTM با تعداد ۱۰۰ لایه پنهان و تعداد ۲۰ دسته خروجی به ازای هر درصد از تغییرات توسط داده‌های موجود در جدول (۲) آموزش داده شد. در تصویر (۱) نتایج حاصل از مقایسه خروجی‌های پیش‌بینی شده و خروجی‌های واقعی برحسب درصد تغییرات تقاضای مسافری نمایش داده شده است.

صراحتاً برای برطرف کردن مشکلات وابستگی طولانی مدت طراحی شده‌اند. این شبکه‌ها به طور پیش فرض اطلاعات را برای مدت زمان طولانی به خاطر می‌سپارند. در شبکه عصبی LSTM مقدار به روز شدن یا حذف اطلاعات گذشته تعیین می‌شود. همچنین با ورود اطلاعات جدید به شبکه، این اطلاعات فیلتر شده و فقط بخش‌هایی از اطلاعات را که نیاز است در تعیین خروجی مشارکت داده شوند، باقی می‌مانند. در این مقاله از شبکه عصبی LSTM برای پیش‌بینی تقاضای مسافران هوایی برای سال‌های آینده استفاده شده است.


#### ۴- بحث

همانطور که در توضیحات روش پیشنهادی عنوان شد، برای پیش‌بینی تقاضای مسافران هوایی شهر کرمان از روش شبکه عصبی LSTM با کمک روش اقتصادسنجی استفاده شده است. در این روش ابتدا داده‌های سری زمانی مربوط به متغیرهای تحت بررسی در پیش‌بینی تقاضا بررسی شده و متغیرهایی که معنی داری قابل قبولی دارند انتخاب می‌شوند. برای حل

که در آن T برابر با نرخ تورم، B برابر با قیمت بنزین، D برابر با متوسط درآمد مردم، O برابر با قیمت نفت و G برابر با مقدار تولید ناخالص داخلی است. خروجی این مدل میزان تقاضای مسافران هوایی شهر کرمان برحسب درصد تغییرات نسبت به ماه‌های گذشته است. همچنین مشخص شد که متغیر تولید ناخالص داخلی بیشترین تأثیر را در تقاضای سفرهای هوایی دارد. پس از تعیین متغیرهای مؤثر در تخمین تقاضای مسافران هوایی، داده‌های سری زمانی مربوط به این متغیرها به عنوان داده‌های ورودی به شبکه عصبی اعمال می‌شوند. این داده‌ها برای استفاده در شبکه عصبی توسط الگوریتم

جدول ۲. متغیرهای ورودی مورد استفاده در شبکه عصبی


شماره	متغیر ورودی
۱	تولید ناخالص ملی
۲	متوسط درآمد مردم
۳	نرخ تورم
۴	قیمت بنزین
۵	قیمت نفت



تصویر ۱. خروجی پیش‌بینی شده توسط شبکه عصبی و خروجی واقعی تقاضای مسافران هوایی شهر کرمان

به شمار می‌رود. در تصویر (۲) دقت این شبکه عصبی در طول یادگیری توسط داده‌های آموزشی نمایش داده شده‌است.

با استفاده از شبکه عصبی LSTM، نتایج مطلوبی برای تخمین تقاضای مسافران هوایی به دست آمد. میزان دقت به دست آمده در این مدل ۸۳ درصد است که دقت خوبی



تصویر ۲. دقت شبکه عصبی در طول یادگیری توسط داده‌های آموزشی

## ۵- نتیجه‌گیری

به عدم معناداری متغیرهای جمعیت شهر کرمان و نرخ ارز، از این متغیرها در شبکه عصبی استفاده نشده‌است. متغیرهای مورد استفاده برای شبکه عصبی شامل متغیرهای تولید ناخالص ملی، متوسط درآمد مردم کرمان، نرخ تورم قیمت بنزین و قیمت نفت است. داده‌های مربوط به ۱۰ سال گذشته به ازای ماه‌های مختلف، به عنوان داده‌های آموزشی شبکه عصبی در نظر گرفته شدند. این داده‌ها ابتدا توسط الگوریتم خوشه‌بندی

در این مقاله تقاضای مسافران هوایی در کرمان بر اساس متغیرهای جغرافیایی، اقتصادی - اجتماعی و رقابتی، توسط شبکه عصبی LSTM که یکی از روش‌های یادگیری ماشین است، با کمک روش اقتصادسنجی مورد تحلیل قرار گرفت. متغیرهای مورد استفاده در روش اقتصادسنجی شامل تولید ناخالص داخلی، متوسط درآمد مردم کرمان، جمعیت کرمان، نرخ تورم، نرخ ارز، قیمت بنزین و قیمت نفت بود که با توجه

for a New Domestic Airport with Limited Data”, *Transportation Research Record* (2214), pp. 59–68.

-Li, Cheng, (2019), “Combined Forecasting of Civil Aviation Passenger Volume Based on Arima-Regression”, *International Journal of Systems Assurance Engineering and Management* 10(5), pp. 945–52.

<https://doi.org/10.1007/s13198-019-00825-6>.

-Likas, Aristidis, Nikos Vlassis, and Jakob J. Verbeek, (2003), “The Global K-Means Clustering Algorithm.” *Pattern Recognition* 36(2), pp.451–61.

-Ming, Wei, Yukun Bao, Zhongyi Hu, and Tao Xiong., (2014), “Multistep-Ahead Air Passengers Traffic Prediction with Hybrid ARIMA-SVMs Models”, *The Scientific World Journal*.

-Naghawi, Hana, Ala’ Alobeidyeen, and Mu’Tasim Abdel-Jaber, (2019), “Econometric Modeling for International Passenger Air Travel Demand in Jordan”, *Jordan Journal of Civil Engineering* 13(3), pp.377–85.

-Qiao, Meiyang, Shuhao Yan, Xiaxia Tang, and Chengkuan Xu., (2020), “Deep Convolutional and LSTM Recurrent Neural Networks for Rolling Bearing Fault Diagnosis under Strong Noises and Variable Loads”, *IEEE Access* 8, pp. 66257–69.

-Saâdaoui, Foued, Hayet Saadaoui, and Hana Rabbouch, (2020), “Hybrid Feedforward ANN with NLS-Based Regression Curve Fitting for US Air Traffic Forecasting”, *Neural Computing and Applications* 32(14), pp. 10073–85.

-Samli, Ruya, Murat Firat, and Derya Yiltas-Kaplan, (2021), “Forecasting Air Travel Demand for Selected Destinations Using Machine Learning Methods”, *Journal of Universal Computer Science* 27(6), pp. 564–81.

-Srisaeng, Panarat, Glenn S. Baxter, and Graham Wild, (2015), “Forecasting Demand for Low Cost Carriers in Australia Using an Artificial Neural Network Approach”, *Aviation* 19(2), pp. 90–103.

-Suh, Daniel Y., and Megan S. Ryerson, (2019), “Forecast to Grow: Aviation Demand Forecasting in an Era of Demand Uncertainty and Optimism Bias”, *Transportation Research Part E: Logistics and Transportation Review* 128 (December 2018), pp. 400–416.

<https://doi.org/10.1016/j.tre.2019.06.016>.

K-Means به تعداد ۶۰ خوشه تقسیم شده و سپس از آنها در شبکه عصبی استفاده شد. نتایج حاصل از پیش‌بینی‌های شبکه عصبی به دقت ۸۳ درصد دست یافت که برای پیش‌بینی تقاضای مسافران دقت مناسبی است. همچنین یافته‌ها حاکی از آن است که متغیر تولید ناخالص داخلی بیشترین تأثیر را بر تقاضای سفرهای هوایی دارد. همچنین برای سال ۱۴۰۰ این مدل ارزیابی شده و نتایج بسیار نزدیک به واقعیت است.

## ۶-مراجع

-جلیلی، م. و منطقی، م.، (۱۳۹۷)، “تحلیل پیش‌بینی تقاضای مسافر و بار در صنعت هوایی ایران”، فصلنامه مطالعات پژوهشی، سال دهم، شماره اول، ص. ۷۵-۱۰۱.

-کفایی، س.م.ع. و کبیری‌راد، س.، (۱۳۹۰)، “برآورد تابع تقاضای حمل‌ونقل هوایی مسافر در پروازهای داخلی یکس تهران”، پژوهشنامه حمل و نقل، سال هشتم، شماره دوم، ص. ۱۸۲-۱۶۹.

-Domingos, Domingos S., João F.L. de Oliveira, and Paulo S.G. de Mattos Neto., (2019), “An Intelligent Hybridization of ARIMA with Machine Learning Models for Time Series Forecasting”. *Knowledge-Based Systems* 175, pp. 72–86.

<https://doi.org/10.1016/j.knosys.2019.03.011>.

-Fausett, Laurene, (1969), “Fundamentals Of Neural Networks”, *IEEE Transactions on Computers* C–18(6), pp.572.

-Jin, Feng, Yongwu Li, Shaolong Sun, and Hongtao Li., (2020), “Forecasting Air Passenger Demand with a New Hybrid Ensemble Approach”, *Journal of Air Transport Management* 83 (October 2019): 101744. <https://doi.org/10.1016/j.jairtraman.2019.101744>.

-Kanavos, Andreas, Fotios Kounelis, Lazaros Iliadis, and Christos Makris, (2021), “Deep Learning Models for Forecasting Aviation Demand Time Series”, *Neural Computing and Applications* 33(23), pp. 16329–43.

<https://doi.org/10.1007/s00521-021-06232-y>.

-Kim, Jungin et al., (2020), “Model Calibration and Forecasts of Air Travel Demand with Categorized Household Socioeconomic Attributes”, *Transportation Research Record* 2674(6), pp. 363–71.

-Kumar, Amir, and Abhisek Bhandari, (2021), “Modeling and Forecasting Passenger Demand



# Air Passenger Demand Forecast in Kerman International Airport

*Pooyan Ayar, Assistant Professor, School of Civil Engineering, Iran University of Science and Technology, Tehran, Iran.*

*Mohammadali Zayandehroodi, Ph.D., Student, School of Civil Engineering, Iran University of Science and Technology, Tehran, Iran.*

*E-mail: ayar@iust.ac.ir*

Received: September 2022- Accepted: February 2023

## **ABSTRACT**

In this article, the demand for air travel is analyzed. By using a model, the impact of geographical, socioeconomic, and competitive aspects has been investigated while studying passenger travel demand. To this end, departure data on at Kerman airport have been gathered during the period of 2011 to 2020. First, the demand is forecasted by using an economic model. In this model the importance of significant differences of all variables is examined. Therefore, an entirely new set of data is produced and the minor variables have been removed. The K-Means clustering algorithm is then used to analyze this data, after which it is used as training data for neural network learning. The neural network used for this analysis is an LSTM Deep Learning Network, which has been used to forecast passenger demand for future coming years. Finally, with economic and social variables including GDP, income, population, inflation, exchange rate, gasoline prices and oil prices for the coming years, the percentage change in the number of passengers for each year compared to the previous year has been predicted. Based on the outputs of the neural network, changes in air travel demand are determined based on the variables of gross national product, mean income, gasoline price, and oil price inflation for each specific time. Among all these variables, the most important variable is GDP, which has a significant influence on air travel demand. The accuracy obtained in this method is 83%, which is a very good accuracy level for air travel demand compared to other regression methods.

**Keywords:** Econometrics, Clustering Algorithm, Air Travel Prediction, Multiple Regression, Neural Network