

The Improvement of Revenue Management in the Hoteling Industry using Neural Networks to Determine Stochastic Parameter in an Overbooking Model

Ahmad Tavakkoli^{1*}, Mohammad-Ali Faezirad²

1- Assistant Professor, Faculty of Economic and Administrative Sciences, Ferdowsi University of Mashhad, Mashhad, Iran
tavakoli-a@um.ac.ir

2- Ph.D. Student, Operational Research Management, Faculty of Economic and Administrative Sciences, Ferdowsi University of Mashhad, Iran
faezirad@mail.um.ac.ir

Abstract

The use of revenue management models has been increased in various industries. The cause of such increasing is as a result of performance and profitability of these models in businesses. Hoteling industry is considered as an important business in the field of revenue management that has a reservation process and stochastic variables due to it. Classic overbooking model is considered as a common model in revenue management that causes to make a trade-off between the number of present customers and no-show customers. This model makes a situation for studying the functions which describe costumers' presence distribution in probable form and then we can add some customers to system for increasing revenue due to no-shows. In this research, the binomial probability distribution using in overbooking model has been improved and estimated its probable parameter more accurately using artificial neural network as a tool in no-show estimation. This estimation is caused by fitting to effective indexes in show-up or no-show process using one-layer or multi-layer perceptron neural network. Therefore, a dynamic model for each sale and customers' reservation is represented that it can estimate the probability parameter of customers' show-up or no-show considering effective indexes.

Keywords: Artificial Neural Networks, Hoteling Industry, Overbooking Model, Revenue Management.

بهبود مدیریت درآمد در صنعت هتلداری با بهره‌گیری از شبکه عصبی مصنوعی در تعیین پارامتر احتمالی یک مدل رزرو مازاد

احمد توکلی^{1*}، محمدعلی فائزیراد²

1- استادیار گروه مدیریت، دانشکده علوم اداری و اقتصاد، دانشگاه فردوسی مشهد

tavakoli-a@um.ac.ir

2- دانشجوی دکتری مدیریت تحقیق در عملیات، دانشکده علوم اداری و اقتصاد، دانشگاه فردوسی مشهد

faezirad@mail.um.ac.ir

چکیده

بهره‌گیری از مدل‌های مدیریت درآمد در صنایع مختلف رو به افزایش است. این افزایش در بهبود عملکرد و سودآوری این مدل‌ها در کسب و کارها ریشه دارد. یکی از کسب و کارهای پراهمیت در این حوزه، صنعت هتلداری است که دارای فرایند رزرو و متغیرهای تصادفی ناشی از آن است. مدل کلاسیک رزرو مازاد، یک مدل مرسوم در مدیریت درآمد تلقی می‌شود که تلاش می‌کند بین تعداد مشتریان حاضر در سرویس مورد نظر و تعداد مشتریان غایب (No-Show) تعادل ایجاد کند. این مدل فرصتی ایجاد خواهد کرد تا بتوان با مطالعه توابعی که توزیع حضور مشتریان را به صورت احتمالی بیان می‌کنند، تعدادی مشتری مازاد را به سیستم اضافه کرد و عملاً از نبود مشتریان غایب نیز درآمد کسب کنند. در این پژوهش، با به کار بستن شبکه عصبی مصنوعی با عنوان ابزاری در تخمین تعداد مشتریان غایب، تابع احتمال دوجمله‌ای که در مدل رزرو مازاد به کار رفته، بهبود داده شده و پارامتر احتمالی آن به طور دقیق‌تری برآورد شده است. این امر ناشی از برازشی است که شبکه عصبی پرسپترون یک یا چندلایه در زمینه شاخص‌های مؤثر در حاضر شدن یا نشدن مشتریان ایجاد خواهد کرد. بنابراین، این توانایی ایجاد خواهد شد که مدلی پویا را برای هر بار فروش و رزرو مشتریان در بنگاه ایجاد کنیم که پارامتر احتمال حضور یا غیبت مشتریان را در نظر گرفتن شاخص‌های تأثیرگذار برآورده شود.

واژه‌های کلیدی: شبکه‌های عصبی مصنوعی، صنعت هتلداری، مدل رزرو مازاد، مدیریت درآمد

پنج ویژگی زیر محقق باشد دارد (گوادیکس⁵ و همکاران، 2010):

1. محدودیت ظرفیت. هدف مدیریت درآمد براساس محدودیت ظرفیت قابل ارائه تعیین می‌شود. واحدهای موجودی در دوره زمانی کوتاهی با ظرفیت محدودیتی به فروش می‌رود.

2. بخش بندی بازار. صنایع خدماتی از تقسیم بندی بازار به منظور انتخاب از میان مشتریان مختلف استفاده می‌کنند. این صنایع مجاز نیستند که از قیمت گذاری مطلق استفاده کنند؛ زیرا خدمات باید مشخصه‌های متمایزکننده‌ای داشته باشند تا بتوان با استفاده از واحدهای مشابهی از ظرفیت، خدمات بسیار مختلفی را عرضه کرد.

3. عدم قطعیت در تقاضای آینده. مدیریت درآمد باید توانایی پیش‌بینی تقاضای آینده را داشته باشد تا از این طریق بتوان در دوره‌هایی که حجم تقاضا بسیار است، قیمت را افزایش داد و در دوره‌هایی که تقاضا کمتر است، قیمت را کاهش داد.

4. واحدهای فاسدشدنی⁶ در موجودی. موجودی بین شرکت‌های خدماتی و شرکت‌های صنعتی تفاوت ایجاد می‌کند. واحدهایی از موجودی که پس از زمان خاصی در صنایع خدماتی فروش نرفته باقی بمانند، به هدر خواهند رفت؛ چراکه خدمات را نمی‌توان ذخیره یا انبار کرد. این ویژگی خاص باعث می‌شود که فروش خدمات پیش از این موعد انجام شود.

5. ساختار مناسب برای هزینه و قیمت گذاری. بسیاری از شرکت‌های خدماتی هزینه ثابتی در هزینه ظرفیت و تقاضایی که نتوان خیلی سریع با آن تطبیق پیدا کرد، دارند. به عبارت دیگر، افزودن یک مشتری

مدیریت درآمد عملاً تصمیم‌گیری درباره این است که چه محصولی را با چه قیمتی و به چه مشتریانی باید فروخت تا محدودیت‌های ظرفیت وجود داشته باشد (سیراگ¹ و همکاران، 2015). مفهوم مدیریت درآمد، نخستین بار در سال 1978 با مقررات زدایی از تثبیت نرخ بلیت هواپیماها در ایالات متحده شکل گرفت (هیلیر و لیبرمن²، 2015). این دانش، هنری برای پیش‌بینی و برآورد تقاضای مشتریان و دسترسی به محصول است؛ به گونه‌ای که بهینه کردن درآمد، هدف تلقی شود (کولن و هلسل³، 2006). مدل‌های مدیریت درآمد را می‌توان حوزه‌ای از مدل‌های کنترل موجودی نیز تلقی کرد؛ زیرا ذاتاً می‌توان آن را محصولات فاسدشدنی در نظر گرفت. بنابراین تحلیل آن راهی برای گسترش بیشتر و موفقیت زیاد ناحیه‌ای کاربردی از تحقیق در عملیات است که در نظریات کنترل موجودی نیز معمولاً مدیریت درآمد نامیده می‌شود (هیلیر و لیبرمن، 2015).

اگرچه مفهوم مدیریت درآمد نخست در صنعت هواپیمایی و خطوط مسافرتی مطرح شد، اما ایده آن به این صنعت محدود نشده و به سایر صنایعی که الگویی مشابه آن دارند، نیز گسترش یافت (مدرس و نجفی، 1388). از جمله صنایعی که مدیریت درآمد در آنها نیز توسعه یافته است، صنعت هتلداری، مؤسسات گردشگری، تئاترها و مراکز فرهنگی، مراکز ورزشی، مؤسسات کرایه‌دهنده خودرو، خطوط راه آهن و قطارهای مسافرتی را نام برد (هیلیر و لیبرمن، 2015). بر اساس پژوهش کیمز⁴ (2000) مدیریت درآمد قابلیت پیاده‌سازی در صنایع مختلف را در شرایطی که

1. Sieraga
2. Hillier and Lieberman
3. Cullen and Helsel
4. Kimes

5. Guadix
6. Perishable

پارامتر یا پارامترهای احتمالی تقاضای مشتریان محل بحث خواهد بود. در مدلی که براساس مطالعات تالوری و ون‌رایزین⁵ (2004) ارائه شده است، مدل برنامه‌ریزی رزرو مازاد براساس یک تابع احتمال دوجمله‌ای بررسی می‌شود (هیلیر و لیبرمن، 2015).

مدل رزرو مازاد با تابع احتمال دوجمله‌ای با استفاده مستقیم از خود تابع احتمال دوجمله‌ای یا تخمین آن با تابع توزیع نرمال حل‌شدنی است (آماروچکول و سایلیم⁶، 2011)؛ اما پیش‌تر از آن باید این بحث را انجام داد که پارامتر احتمال حضورنیافتن مشتری در موعد مقرر که پارامتر تابع دوجمله‌ای حساب می‌شود، چگونه تعیین می‌شود. در مدل کلاسیک، توزیع احتمالی و پارامتر آن از هر دوره به دوره دیگر تغییر نیافته و از دوره‌های زمانی مستقل است (لو⁷ و همکاران، 2009)؛ اما در واقعیت این وابستگی براساس شرایط محیطی و روندهای زمانی وجود خواهد داشت. بنابراین اینکه پارامتر توزیع احتمالی یکسان در نظر گرفته شده و در تخمین آن تلاشی نشود، ساده‌انگاری در مدل‌سازی مسئله خواهد بود. پژوهش حاضر با در نظر گرفتن این موضوع، می‌کوشد که با ادغام رویکرد داده‌کاوی با محوریت برازش، تعیین پارامتر توزیع احتمال دوجمله‌ای را با دقت و حساسیت بیشتری رقم بزند. در این راستا نیز، استفاده از شبکه عصبی مصنوعی یک ابزار کارآمد در حوزه برازش مدنظر بوده و جزئیات آن تشریح شده است. به عبارت دیگر، نوآوری پژوهش بر به کارگیری شبکه عصبی مصنوعی با هدف تخمین پارامتر توزیع احتمال مدل رزرو مازاد استوار است. اگر این پارامتر به‌درستی تخمین زده شود، اساس کارکرد مدیریت درآمد بر پایه

جدید به ظرفیت موجود هزینه بسیار کمی خواهد داشت.

با وجود گستره وسیعی از کاربرد مدل‌های مدیریت درآمد در صنایع گوناگون، پیاده‌سازی این مدل در مطالعات مربوط به صنایع هواپیمایی و هتلداری با توجه بیشتری همراه بوده است (سیراگ و همکاران، 2015). صنعت هتلداری از اواخر دهه 1980 مزایای مدیریت درآمد را درک کرده و در همین زمان تعدادی شرکت به وجود آمده که بر این صنعت تمرکز کردند (کتابی و همکاران، 1393). این موضوع نیز به دلیل اساس صنعت هتلداری است که با پنج ویژگی مدل‌های مدیریت درآمد یعنی محدودیت ظرفیت، بخش‌بندی بازار، عدم قطعیت در تقاضای آینده، واحدهای فاسدشدنی یا تمام‌شدنی موجودی و ساختار مناسب برای هزینه و قیمت‌گذاری انطباق دارد (گوادیکس و همکاران، 2010).

یکی از چالش‌های اصلی قیمت‌گذاری و ارائه مدل‌های مدیریت درآمد، عدم قطعیت در تقاضا و رفتار مشتریان است. با در نظر گرفتن مشتریان غایب¹ که در شرایط عدم قطعیت تقاضا به صورت بالقوه در سیستم انتظار می‌کشند، بهینه‌سازی با رویکرد پیشینه‌سازی درآمد بنگاه به یک مسئله مهم تبدیل می‌شود (جورجیادس و تانگ²، 2014). در چنین مسائلی رجوع به مدل‌های رزرو مازاد³ اولویت می‌یابد تا تأثیرات ناشی از حضورنیافتن مشتریان در سیستم را کاهش دهد (الشارو⁴ و همکاران، 2015).

پیش از پرداختن به بهینه‌سازی مسئله مدیریت درآمد با مشتریان غایب در مدل رزرو مازاد، برآورد

5. Talluri, and Van Ryzin
6. Amaruchkul and Sae-Lim
7. Luo

1. No-Show
2. Georgiadis and Tang
3. Overbooking
4. El-Sharo

مدل رزرو مازاد تأمین شده و منطق پیاده‌سازی آن مستحکم خواهد بود.

پس از روش شناسی و طرح ابزارهای مسئله، یک مثال عددی برای تفهیم بیشتر و پیاده‌سازی مدل ارائه شده، بیان می‌شود که مقایسه آن با رویکرد کلاسیک نیز بیان شده و مزایای مدل تشریح می‌شود.

مبانی نظری

مدل رزرو مازاد

رزرو مازاد رویکردی است که در آن تعداد بیش از حد اندازه‌ای مشتری نسبت به ظرفیت سیستم پذیرش شده تا با حضور نیافتن مشتریان غایب یا لغو حضور اختیاری آنها بتوان با هدف حداکثرسازی درآمد سیستم، از ظرفیت‌های خالی بهره گرفت (الشارو و همکاران، 2015). انتظار هر بنگاه، با رویکرد مدیریت درآمد، این است که تعداد عمده‌ای مشتری غایب وجود داشته باشد؛ این امر می‌تواند با رویکرد رزرو مازاد، با فروش رزروهای بیشتر از موجودی در دسترس، درآمد را افزایش دهد. با این حال، باید دقت کرد که رزرو بیش از حد نیز باعث کمبود می‌شود؛ زیرا هر بار که یک مشتری با رزرو قبلی، به موقع اما بعد از خالی شدن موجودی برسد، هزینه کمبود¹ رخ خواهد داد (هیلیر و لیبرمن، 2015).

مدل‌های رزرو مازاد در دو گروه مدل‌های ایستا و مدل‌های پویا دسته‌بندی می‌شوند. در مدل‌های ایستا، رزرو از جانب مشتریان ضروری تلقی شده و از لغو رزرو و درخواست موجودی از سوی مشتریان صرف نظر می‌شود؛ در حالی که در مدل‌های پویا، این آثار موقتی صریحاً در نظر گرفته می‌شوند (آماروچکول و سایلیم، 2011). در این پژوهش مدل ایستا که شباهت زیادی به سیستم‌های تجاری مدیریت درآمد دارد، به

کار برده می‌شود؛ اگرچه دلیل دیگر استفاده از آن سهولت در مدل‌سازی ابتدایی مسئله است.

در مدل رزرو مازاد ایستای کلاسیک، فرض می‌شود که تقاضای حضور یافتن² مشتریان در مدل از تابع توزیع احتمالی دو جمله‌ای³ پیروی می‌کند (تالوری و ون‌رایزین، 2004). فرم تابعی حضور یافتن بر سطح رزرو مازاد تأثیرگذار است (آماروچکول و سایلیم، 2011). از این رو، برآورد هرچه بهتر پارامترهای مدل احتمالی رزرو مازاد می‌تواند بر نتیجه نهایی تأثیر بگذارد و درآمد حاصل را افزون کند؛ چراکه سؤال اساسی در این مدل‌ها آن است که چقدر رزرو مازاد باید انجام پذیرد تا سود پیش‌بینی شده بنگاه به حداکثر برسد (هیلیر و لیبرمن، 2015).

مدل رزرو مازاد ایستا به طور کلاسیک دارای فرض‌های زیر است (هیلیر و لیبرمن، 2015):

- مشتریان به طور مستقل، رزرو خود را برای هر واحد موجودی انجام می‌دهند و برای رسیدن به واحدشان در زمان تعیین شده، از احتمال ثابت مشابهی برخوردارند.

- درآمد خالص ثابت و معینی برای هر رزرو انجام شده وجود دارد.

- هزینه کمبود ثابت و معینی در هر بار که یک مشتری در جایگاه رزرو شده‌اش حضور یابد اما موجودی تهی باشد، به وجود خواهد آمد.

براساس فرض‌های مدل رزرو مازاد فوق، پارامترهای مدل بر پایه توزیع دو جمله‌ای به شرح زیر تعیین می‌شوند:

p : احتمال حضور یافتن مشتری در جایگاه رزرو شده خویش

r : درآمد به دست آمده از هر رزرو

2. show-up (حضور یافتن در مقابل غایب شدن تلقی می‌شود).

3. binomial distribution

1. shortage cost

S : هزینه کمبود هر واحد از تقاضای تأمین نشده

L : کل موجودی در دسترس

همچنین براین اساس، متغیر تصمیم n را در مدل، همان تعداد مشتریانی که می‌توان رزرو یک واحد از موجودی را به آن‌ها داد، تعریف می‌کنیم و بنابراین عبارت $n - L$ مقدار رزرو مازاد را نمایش می‌دهد. با توجه به مقدار n ، عدم قطعیت این است که چه تعداد از مشتریانی که رزرو انجام داده‌اند، برای دریافت آن به موقع در زمان معین اقدام می‌کنند؛ به عبارت دیگر تعداد مشتریان حضور یافته چقدر است. متغیر تصادفی میزان تقاضا $D(n)$ خواهد بود.

از آنجا که طبق فرض، $D(n)$ یک توزیع بینم (دوجمله‌ای) با پارامتر p دارد (تالوری و ون‌رایزین، 2004)، رابطه (1) مبین این توزیع است:

$$P\{D(n) = d\} = \binom{n}{d} p^d (1-p)^{n-d} \quad (1)$$

$$= \frac{n!}{d!(n-d)!} p^d (1-p)^{n-d}$$

که $D(n)$ ، میانگینی برابر با np و واریانسی برابر با $np(1-p)$ دارد.

یک متغیر تصادفی وابسته که در تحلیل این مدل پراهمیت خواهد بود، تقاضای تأمین نشده است که در رابطه (2) با فرض تعداد n رزرو نشان داده شده است.

$$U(n) = \begin{cases} 0 & , D(n) \leq L \\ D(n) - L & , D(n) > L \end{cases} \quad (2)$$

که امید ریاضی آن براساس رابطه (3) قابل محاسبه است.

$$E[U(n)] = \sum_{d=L+1}^n (d-L) P\{D(n) = d\} \quad (3)$$

با استفاده از تحلیل حاشیه‌ای¹ برای تعیین مقدار بهینه n که سود را حداکثر می‌کند، می‌توان اثر افزایش

مقدار n به اندازه 1 واحد را روی $E[U(n)]$ تحلیل کرد. با شروع n رزرو، اثر افزایش یک رزرو بیشتر برابر است با افزودن یک واحد به تقاضای تأمین نشده، در صورتی که دو اتفاق رخ دهد؛ یک اتفاق ضروری این است که n رزرو اصلی باعث تهی شدن کل موجودی شود؛ یعنی $D(n) \geq L$ برقرار باشد و اتفاق دیگر این است که مشتریانی که رزرو مازادی گرفته‌اند، در عمل در زمان معین برای دریافت واحد خود اقدام کنند؛ در غیر این صورت، هیچ اثری بر تقاضای تأمین نشده وارد نمی‌شود. در نتیجه رابطه (4) بیانگر یک واحد افزایش در متوسط تقاضای تأمین نشده است.

$$\Delta E[U(n)] = E[U(n+1)] - E[U(n)] = p P\{D(n) \geq L\} \quad (4)$$

براساس رابطه (4) مقدار $E[U(n)]$ به مقدار n بستگی دارد، زیرا احتمال تهی شدن موجودی یعنی عبارت $P\{D(n) \geq L\}$ به n (تعداد رزروها) وابسته است. تغییر در متوسط تقاضای تأمین نشده برای $n < L$ برابر با صفر است. از آنجایی که $\Delta E[U(n)]$ با افزایش n افزایش می‌یابد، پس احتمال تهی شدن موجودی به میزان افزایش تعداد رزروها، افزایش می‌یابد.

اگر متغیر تصادفی سود را با $P(n)$ نشان دهیم، مقدار آن از طریق رابطه (5) توجیه می‌شود که در آن تفاضل هزینه کمبود برای تقاضاهای مازاد بر ظرفیت از عایدی کل فروش محسوب شده است.

$$P(n) = r \cdot n - s \cdot U(n) \quad (5)$$

براساس رابطه (5)، متوسط سود با در نظر گرفتن امید ریاضی این رابطه محاسبه خواهد شد. رابطه (6) ارزش انتظاری $P(n)$ را نشان می‌دهد.

$$\begin{aligned} E[P(n)] &= r n - s E[U(n)] \\ &= \Delta E[P(n)] \\ &= E[P(n+1)] - E[P(n)] \\ &= r - s \Delta E[U(n)] \\ &= r - s p P\{D(n) \geq L\} \end{aligned} \quad (6)$$

آموزش خود کسب کند. باید گفت که برآزش داده‌ها صرفاً به معنی برآزش یک منحنی روی تمامی داده‌ها نیست؛ بلکه خروجی با اهمیت این رویکرد، تعیین مقدار بهینه پارامترهای منحنی براساس کمترین خطا و بیشترین انطباق خواهد بود (لی و ورما^۲، 2016).

یکی از کاربردهای مهم شبکه‌های عصبی مصنوعی، برآزش داده‌ها و تلاش برای یافتن بهترین برآزش با استفاده از تغییر در پارامترهای شبکه است (رحمانی و اسماعیلی، 1389). به طور کلی می‌توان گفت که شبکه‌های عصبی از لایه‌های نرونی تشکیل شده است؛ به طوری که این نرون‌ها از طریق ورودی‌های خود با جهان واقعی در ارتباط هستند و از طریق خروجی‌های خویش جهان واقعی را می‌سازند (تسای^۳، 2009). شکل (1) ساختار کلی یک شبکه عصبی مصنوعی با در نظر گرفتن لایه‌ها و نرون‌ها را نمایش می‌دهد (ادھیکاری^۴، 2015).

با توجه به اینکه $\Delta E[U(n)]$ با افزایش n افزایش می‌یابد؛ بنابراین عبارت $\Delta E[U(n)] > 0$ برای مقادیر کوچک n خواهد بود و با فرض اینکه $r < s p$ باشد، برای مقادیر به اندازه کافی بزرگ n به عبارت $\Delta E[U(n)] < 0$ تغییر می‌یابد. به این ترتیب n^* (که مقدار حداکثر کننده سود است) در دو رابطه (7) و (8) زیر به صورت همزمان صدق می‌کند.

$$\Delta E[P(n^* - 1)] > 0 \quad (7)$$

$$\Delta E[P(n^*)] \leq 0 \quad (8)$$

که روابط (9) و (10) نیز مبنای دو رابطه فوق براساس پارامترهای مسئله هستند.

$$r > s p P\{D(n^* - 1) \geq L\} \quad (9)$$

$$r \leq s p P\{D(n^*) \geq L\} \quad (10)$$

از آنجایی که $D(n)$ توزیع دو جمله‌ای دارد و مقداری گسسته است، مقدار n^* به طور مستقیم از صدق همزمان در دو رابطه (9) و (10) به دست خواهد آمد.


با توجه به اینکه در مدل کلاسیک فوق، پارامتر p به صورت ایستا در نظر گرفته شده، در تمامی دوره‌ها ثابت خواهد بود. این موضوع به معنای استقلال این پارامتر از دوره‌ها و شرایط زمانی و محیطی مسئله است (لو و همکاران، 2009). این مورد با توجه به عدم قطعیت گسترده در دنیای واقعی چندان باورپذیر نیست. از این رو، در این پژوهش مدلی برای پویاسازی تعیین پارامتر p در دوره‌های مختلف طراحی شده که در روش‌شناسی پژوهش به تفصیل بیان شده است.

برآزش با شبکه عصبی مصنوعی

برآزش داده‌ها^۱ یکی از رویکردهای بنیادین در داده‌کاوی است. این رویکرد می‌کوشد که بهترین و نزدیک‌ترین انطباق را در قبال تمامی داده‌های تحت

2. Li and Verma
3. Tsai
4. Adhikari

1. data fitting



شکل (1). نمای کلی از ساختار شبکه عصبی مصنوعی

پیشینه پژوهش

با ایجاد مفهوم مدیریت درآمد طی دهه 1970 در صنایع هواپیمایی و خطوط مسافرتی هوایی (هیلیر و لیبرمن، 2015)، طی دهه 1980 این دانش به صنعت هتلداری گسترش یافته و با توجه به دارا بودن ویژگی‌های مدل‌های مدیریت درآمد، در این صنعت فعال شد (کتابی و همکاران، 1393). اولین مقاله در زمینه مدیریت درآمد را راستین با محوریت خطوط هوایی منتشر ساخت (راستین²، 1971) و چندسال بعد خود وی این موضوع را به هتل و صنایع اقامتی تعمیم داد (راستین، 1974). ویژگی مهمی که موجب گسترش این مدل‌ها به صنعت هتلداری شده است، محدودیت ظرفیت پذیرش هتل به دلیل محدودیت تعداد اتاق‌های آن است. اتاق‌ها نقش موجودی‌های زوال‌پذیر را بازی

برای تعیین معماری شبکه عصبی و آموزش آن نیاز به تعیین نوع شبکه، تعیین اجزا و تعیین توابع مدنظر است. یک شبکه یک (چند) لایه پرسپترون از سه نوع لایه ساخته شده است که به ترتیب واقع شدن عبارت‌اند از لایه ورودی، لایه (های) پنهان و لایه‌های خروجی. لایه ورودی نقش درگیر کردن اطلاعات ورودی با شبکه را دارد، لایه پنهان پردازش‌کننده اطلاعات به صورت غیرخطی است و لایه خروجی نتایج نهایی را تولید می‌کند. ویژگی مهم شبکه‌های عصبی پرسپترون آن است که نیاز خاصی به اطلاعات پیشین و ویژگی‌ها و روابط بین متغیرها و شاخص‌های ورودی و خروجی ندارد و کشف این روابط براساس فعالیت و آموزش خود شبکه انجام می‌شود (کیم¹ و همکاران، 1999).

صنعت هتلداری ترکیه و در گروه هتل‌های پنج‌ستاره انجام شد.

در پژوهش لای و انگ³ (2005) یک مدل برنامه‌ریزی خطی با در برگیری یک دوره زمانی و یک دوره رزرو ارائه شده که در آن تنها یک دوره رزرواسیون وجود دارد. پژوهش فوق، به دلیل احتمالی بودن ساختار تقاضای مفروضش فرایند بهینه‌سازی از طریق بهینه‌سازی استوار و ایجاد سناریوهای مختلف را دنبال کرد؛ این در حالی است که لیو و همکاران (2008) مدل برنامه‌ریزی خطی را برای یک دوره خاص و دوره‌های رزرواسیون متفاوت ارائه کرده‌اند. در این مقاله نیز تقاضا حالت احتمالی داشته و از بهینه‌سازی استوار برای ارائه پاسخ برای آن بهره گرفته شده است. در همین راستا، پژوهش‌های دیگری نظیر پژوهش کتابی و همکاران (1393) انجام شده است که در آن مدل ارائه‌شده اولاً با در نظر گرفتن لغو درخواست و حضور نیافتن مشتری در نظر گرفته شده و ثانیاً تقاضای آن به صورت قطعی و غیرقطعی بررسی شده است.

کوید و ایشی⁴ (2005) در پژوهش خود، مدیریت درآمد در هتل با دو کلاس قیمتی را بررسی کرده‌اند. در این پژوهش، رزرو مازاد و لغو رزرو از سوی مشتری مفروض است. هاروود⁵ (2006) سیاست‌های مختلف مدیریت درآمد را با استفاده از شبیه‌سازی مونت کارلو با یکدیگر مقایسه کرده و عملاً از دانش شبیه‌سازی و فرایندهای احتمالی در تعیین سناریوی مطلوب مدیریت درآمد در یک مجموعه بهره برده است. وی قیاسی را بین دو سیاست اولین ورود - اولین سرویس و همچنین خدمت‌دهی براساس قیمت پایه ارائه کرده است.

می‌کنند که اگر طی تاریخ خاصی اشغال نشوند، درآمد مربوط به آن تاریخ حاصل نشده و انبار کردن یا نگهداشت موجودی ممکن نیست. ویژگی دیگر، انعطاف‌پذیری عرضه خدمات هتل در قالب اتاق‌های متنوع به مشتریان مختلف است؛ بدین معنا که می‌توان بازار هدف را براساس تنوع خدمات بخش‌بندی کرد. این موضوع همچنین در قالب ویژگی دیگری چون احتمالی بودن تقاضای آینده در گروه‌های مختلف مشتریان اهمیت دارد. علاوه بر آن، این عدم قطعیت در شاخصه‌های مختلفی نظیر حضور یا غیبت مشتریان، تعداد مشتریان هر بخش، تمایل مشتریان به استفاده از خدمات مختلف و ... جریان می‌یابد (گوادیکس و همکاران، 2010)؛ از این رو، صنعت هتلداری حوزه‌ای است که شاخصه‌های اصلی پیاده‌سازی مدل‌های مدیریت درآمد در آن وجود دارد، کانون توجه بوده است (مدرس و نجفی، 1388).

مطالعات روی روند مدیریت درآمد در صنعت هتلداری طی 15 سال اخیر نمایان‌گر توسعه پرشتاب این حوزه است. ویرتز¹ و همکاران (2003) اثرات به کارگیری مدیریت درآمد را بر رضایت مشتری بررسی کرده‌اند. آنها با بررسی اختلال‌ها و تضادهای بروزیافته مشتریان که آینده صنعت و بنگاه‌های هتلداری را تهدید می‌کنند، استراتژی‌های مختلف سازمانی و بازاریابی را با هدف مدیریت این اختلالات تأثیرگذار بر رضایت مشتری بررسی کرده‌اند. از سوی دیگر، در همین حوزه بررسی اثرات، ایمکسز² و همکاران در سال 2005 اثرات مدیریت درآمد را بر عملکرد مالی و عملیاتی کاویدند و نشان دادند که استفاده از مدل‌های مدیریت درآمد به مقدار چشمگیری در عملکردهای مالی و عملیاتی به بهبود می‌انجامد. مطالعه مذکور در

3. Lai and Ng

4. Koide and Ishii

5. Harewood

1. Wirtz

2. Emeksiz

تصمیم مارکوف در نظر گرفته شده و سه مدل حل با برنامه‌ریزی پویا برای آن به دست داده شده است. سیراگ و همکاران نشان می‌دهند که در شرایط همراه با قطعیت این مدل به دقت براساس روش‌های ساده قابلیت حل داشته اما در غیر این صورت، روش‌های ابتکاری ارائه می‌شود؛ چراکه مدل به شدت ابعاد پیچیده‌ای می‌یابد. در این شرایط روش‌های عددی تقریباً هم‌پای روش‌های دقیق می‌توانند به حل مسئله یاری برسانند.

به کارگیری شبکه‌های عصبی مصنوعی در مسائل مدیریت درآمد و رزرو مازاد، به اواخر دهه ۱۹۸۰ و اوایل دهه ۱۹۹۰ بازمی‌گردد. فریزلمن و گریچمن^۵ نخستین تلاش‌ها را برای بهره‌مندی از این ترکیب (۱۹۹۳) انجام داده‌اند. آنها طی پژوهشی، مدل رزرو مازاد را برای خطوط هوایی با کمک شبکه عصبی ایجاد کردند. در این پژوهش، از شبکه عصبی برای پیش‌بینی تعداد مسافران غایب (خروجی شبکه) با استفاده از تعداد صندلی‌های رزرو شده در دوره‌های پیشین (ورودی شبکه) استفاده شده است. شبکه عصبی آموزش دیده مذکور با استفاده از تعداد صندلی‌های رزرو شده در پروازهای آتی تعداد مسافران غایب را تخمین می‌زند؛ اگرچه این مطالعه از پژوهش‌های آغازین و شروع خوبی بوده است، اما در نظر نگرفتن سایر عوامل نظیر شاخص‌های اثرگذاری بر غیبت مشتریان، یک نقص تلقی می‌شود. در پژوهش دیگری براساس داده‌های واقعی خطوط هوایی، سان^۶ و همکاران (۱۹۹۳) نشان داده‌اند که شبکه‌های عصبی نه تنها جایگزین مناسبی برای روش‌های پیش‌بینی سنتی است؛ بلکه بهبود چشمگیری را در دقت حاصل می‌کنند. همچنین، انعطاف‌پذیری و سهولت استفاده از

ژانگ^۱ (2007) در پژوهشی رویکردهای مختلف قیمت‌گذاری براساس جو بازار و هزینه‌ها در هتل را بررسی کرده است و نون و ماتیلا^۲ (2009) اثر قیمت‌های ترکیبی و غیر ترکیبی را بر مطلوبیت مشتریان در سیستم مدیریت درآمد سنجدیده‌اند. گوادیکس و همکاران (2010) در پژوهشی به ارائه یک سیستم پشتیبان تصمیم با هدف تنظیم شاخص‌های بیشینه‌کننده درآمد در صنعت هتلداری پرداخته‌اند. در مقاله مذکور ضمن ارائه مدل برنامه‌ریزی ریاضی با هدف تأمین هدف مدیریت درآمد، از مجموعه‌ای از روش‌های پیش‌بینی تقاضای مشتریان برای پایش‌کننده ورودی سیستم استفاده شده است. از سوی دیگر در سال 2012، لینگار و سوری^۳ در پژوهشی، سودآوری مشتری را به عنوان رویکردی پیش‌تاز در بهینه‌سازی درآمد هتل‌ها تجزیه و تحلیل کرده‌اند. آنها در این پژوهش، یک رویکرد گذشته‌نگر براساس حسابداری مدیریت و یک رویکرد آینده‌نگر بر مبنای ارزش طول عمر مشتری را برای برآورد سودآوری مشتریان در محیط کسب و کار هتلداری ارائه داده‌اند. بلس‌ترو و سرانو^۴ (2012) در مطالعه تجربی خود درباره ارزیابی وضعیت مدیریت درآمد در هتل‌های اسپانیا، با استفاده از روش دلفی به یک مدل کاربردی دست یافته‌اند.


سیراگ و همکاران (2015) در پژوهشی مدیریت درآمد را براساس رفتار انتخاب‌گر مشتریان با فرض لغو رزروها و مجازبودن رزرو مازاد مطالعه کردند. در این پژوهش، براساس مدل تالوری و ون رایزین (2004) و با فرض تأثیرپذیری رزروهای مازاد از رزروهای لغوشده یک مدل ارائه شده است. این مدل یک فرایند

1. Zhang
2. Noone and Mattila
3. Iyengar and Suri
4. Ballestero and Serrano

روش‌شناسی پژوهش

براساس مبانی نظری پژوهش، مدل کلاسیک و ایستا در حوزه رزرو مازاد بر پایه فرض استقلال پارامتر احتمالی توزیع دوجمله‌ای بنا شده است. از این منظر، با حذف این فرض و ارائه مدلی سازمان‌یافته برای تعیین پارامتر توزیع احتمال براساس داده‌های گذشته و منطق حاکم بر آنها می‌توان مدل کلاسیک را به واقعیت موجود در داده‌ها نزدیک کرد. برازش داده‌های دنیای واقعی موجب می‌شود که بتوان احتمال حضور یا غیبت مشتریان را با اتقان بیشتری برآورد و تعیین کرد. شکل (2) تصویری از مراحل پژوهش حاضر و منطق جاری در آن را نشان می‌دهد.

آنها مزیت دیگری است که در این پژوهش نشان داده شده است. مشابه این موضوع را وِدرفوردر و کیمز (۲۰۰۳) نیز در ارزیابی پیش‌بینی با شبکه‌های عصبی در مقایسه با روش‌های سنتی نظیر میانگین متحرک و غیره در مدیریت درآمد صنعت هتلداری بررسی کرده و شبکه عصبی را نسبت به روش‌های کلاسیک پیشین برتر دانسته‌اند. تسای و همکاران (۲۰۰۹) در مطالعه خود دو شبکه عصبی جدید را برای پیش‌بینی تقاضای کوتاه‌مدت خطوط ریلی در مدل مدیریت درآمد توسعه دادند. ایده این پژوهش براساس پایش اطلاعات و ارائه اطلاعات به شبکه عصبی در مکان مناسب بوده است؛ به جای آنکه تمام اطلاعات یکدفعه به شبکه ارائه شود.



شکل (2). مدل کلی پژوهش برای تخمین پارامتر احتمالی در مدل رزرو مازاد

مشتریان است، پس باید شاخص‌هایی در نظر گرفته شوند که بر حضور یا غیبت مشتریان مؤثر باشند. پس از تعیین این شاخص‌ها، داده‌های مربوط به دوره‌های گذشته جمع‌آوری شده و با قراردادن این شاخص‌ها به

گام نخست از مراحل تحقیق، به بررسی و تعیین شاخص‌های تأثیرگذار بر حضور مشتریان اختصاص دارد. از آنجا که هدف نهایی این مدل، دستیابی به پارامتر احتمالی مدل یعنی احتمال حضور یا غیبت

کمبودی برابر با 1,500,000 تومان در نظر گرفته شده است. با توجه به ازدحام این ایام خاص، رزروهایی که پس از یک ماه مانده به نوروز لغو شوند، مبلغ استردادی ندارد و کل مبلغ رزرو را متضرر خواهند شد.

براساس مفروضات این مثال، تأخیرهای ناشی از حمل و نقل و همچنین بازه زمانی مسافرت بر احتمال حضور مشتریان با رزرو قبلی تأثیر می‌گذارد. از این رو، با استفاده از سه شاخص حجم ترافیک جاده‌ای، حجم بارندگی و کیفیت هوا با هدف مطالعه تأثیرپذیری حمل و نقل زمینی و هوایی از آن و همچنین بازه زمانی مسافرت براساس چهار بازه چهار روزه تعطیلات نوروز (از 27 یا 28 اسفند تا 13 فروردین) تخمین مستدل تری ارائه می‌شود.

در این مثال اطلاعات مربوط به 10 سال طی چهار بازه زمانی نوروز (یعنی 40 دوره) با احتساب شاخص‌های حمل و نقل فوق‌الذکر در نظر گرفته شده است. همچنین نسبت مشتریانی که در هر دوره حاضر شده‌اند به کل مشتریان آن دوره، میزان حاضر شدن p ، شاخص خروجی مدل برازش را تشکیل می‌دهد.

با توجه به فرض‌های مثال فوق و داده‌های تصادفی تعریف شده برای آن، فرایند آموزش شبکه عصبی پس‌خور با جایگشت‌های مختلف براساس الگوریتم آموزش، تعداد لایه و نرون‌ها انجام شده است. اجرای این شبکه در نرم‌افزار MATLAB 2015a انجام شده و جدول (1) مقدار خطای RMSE را براساس هر ترکیب از پارامترهای مختلف شبکه نشان می‌دهد. لازم به ذکر است که در تمام این اجراها، تابع محرک لایه پنهان و لایه خروجی به ترتیب توابع تانژانت هیپربولیک و تابع خطی بوده و تغییری در آنها ایجاد نشده است.

عنوان شاخص‌های ورودی مدل برازش و همچنین تعریف شاخص خروجی مدل برازش به عنوان میزان احتمال حضور یا غیبت متناظر هر دوره، مدل‌سازی و جمع‌داده‌ها انجام می‌شود. پس از ایجاد ساختار مدل قابل برازش و پیش‌پردازش داده‌ها می‌توان شبکه عصبی مصنوعی را با پارامترها و تنظیمات متناسب اجرا کرد تا فرایند آموزش آن تکمیل شود؛ سپس با استفاده از شاخص‌های خطا بهترین ساختار شبکه که کمترین خطا و بهترین برازش روی داده‌های موجود ایجاد می‌کند، انتخاب شود و برای برآورد احتمال حضور یا غیبت مشتریان در تخمین‌های بعدی استفاده شود.

برای تفهیم هرچه بیشتر این مدل و اعتبارسنجی و آزمون آن، از یک مثال عددی استفاده شده است. این مثال عددی ابعاد مدل را به نمایش درآورده و مطلوبیت حاصل از آن را تبیین می‌کند.

مثال عددی

پژوهش‌های مختلف هر یک نرخ‌های متوسط گوناگونی را برای حضور نیافتن مشتریان در صنایع خدماتی ذکر کرده‌اند. در صنعت هتلداری احتمال غیبت مشتری از 5 تا 25 درصد (جورجیادس و تانگ، 2014) ذکر شده که بازه گسترده‌ای را نمایش می‌دهد.


در این مثال، فرض می‌شود که قیمت یک نوع اتاق در هتل برای هر شب اقامت در ایام نوروز 300,000 تومان است. ظرفیت هتل برای این اتاق، 100 واحد است که در صورت تأمین نشدن هر تقاضای اضافی در شرایط رزرو مازاد، براساس هزینه مهیا کردن جای دیگری برای اقامت، ایجاد تضمین برای اقامت آینده و هزینه نامشهود و زیاد از بین رفتن بخشی از مشتریانی که روی گردان شده‌اند (هیلیر و لیبرمن، 2015)، هزینه

جدول (1). نتایج عملکرد شبکه عصبی مصنوعی با ساختارهای مختلف در برازش مثال

| شاخص RMSE | معماری نرون ها | تعداد لایه | الگوریتم آموزش |
|-----------|----------------|------------|---|
| 1/9014 | [5] | 1 | Levenberg-Marquardt backpropagation |
| 1/9331 | [5] | 1 | Bayesian regulation backpropagation |
| 2/6732 | [5] | 1 | Scaled conjugate gradient backpropagation |
| 1/2999 | [10] | 1 | Levenberg-Marquardt backpropagation |
| 1/7617 | [10] | 1 | Bayesian regulation backpropagation |
| 1/3920 | [10] | 1 | Scaled conjugate gradient backpropagation |
| 1/5533 | [15] | 1 | Levenberg-Marquardt backpropagation |
| 1/6612 | [15] | 1 | Bayesian regulation backpropagation |
| 1/9268 | [15] | 1 | Scaled conjugate gradient backpropagation |
| 2/1886 | [5 10] | 2 | Levenberg-Marquardt backpropagation |
| 1/2223 | [5 10] | 2 | Bayesian regulation backpropagation |
| 1/8444 | [5 10] | 2 | Scaled conjugate gradient backpropagation |
| 0/7391 | [10 10] | 2 | Levenberg-Marquardt backpropagation |
| 1/2473 | [10 10] | 2 | Bayesian regulation backpropagation |
| 1/2668 | [10 10] | 2 | Levenberg-Marquardt backpropagation |
| 1/6661 | [10 15] | 2 | Bayesian regulation backpropagation |
| 1/3962 | [10 15] | 2 | Scaled conjugate gradient backpropagation |
| 1/6488 | [10 15] | 2 | Levenberg-Marquardt backpropagation |

لونیبرگ مارکوات با تابع محرک تانژانت هیپربولیک در لایه پنهان گزارش شده است. نمای شماتیک این ساختار در شکل (3) نمایان است.


با توجه به خروجی های بالا از اجرای شبکه های عصبی، بهترین مقدار RMSE مربوط به ساختار شبکه پرسپترون پس خور چندلایه (با 10 نرون در هریک از دو لایه پنهان) با الگوریتم آموزش تابع پسانتشار



شکل (3). نمای شماتیک ساختار برگزیده

لگاریتمی برای هر سه دسته داده آموزش، اعتبارسنجی و آزمون براساس شاخص MSE ترسیم شده است.


روند تغییرات خطا در آموزش شبکه عصبی با ساختار برگزیده، در شکل 4 نشان داده شده است. همان‌طور که در این شکل مشخص است، روند تغییرات



شکل (4). عملکرد شبکه بر اساس شاخص MSE طی دوره آموزش


آن به طور مکرر آزمون‌های اعتبارسنجی مردود شده است. این آزمون‌ها روی داده‌های اعتبارسنجی و با معیار کمتر شدن شاخص MSE انجام شده است.

توقف آموزش شبکه، به دلیل رسیدن آزمون‌های اعتبارسنجی به سقف معین آن 4 بار است که این موضوع در شکل 5 بیشتر روشن است. آموزش شبکه در تکرار هفتم متوقف شده؛ زیرا در شش تکرار بعد از



شکل (5). اعتبارسنجی و تأییدهای آن

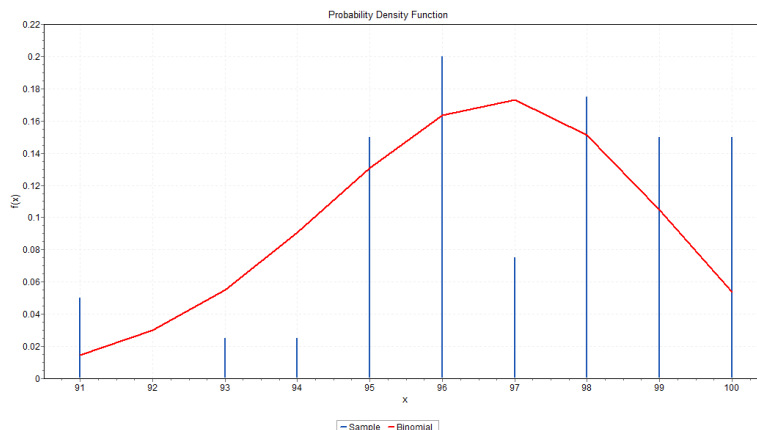
برازش حاصل از اجرای شبکه عصبی مصنوعی در نمودار شکل 6 به نمایش در آمده است. در این شکل، میزان همبستگی مقدار برآورد شده و مقدار واقعی آن برای تمام نمونه‌ها ارائه شده که شاخص R نمایان‌گر آن است.



شکل (6). رگرسیون حاصل از همبستگی مقادیر برازش شده و مقادیر واقعی

مشتری حاصل می‌شود که این مقادیر در جدول 2 ارائه شده است. از سوی دیگر با رویکرد کلاسیک تعیین پارامتر توزیع دوجمله‌ای، با استفاده از نرم‌افزار EasyFit 5.5 برازشی روی پیشامدهای حضور مشتریان در چهل دوره مورد نظر انجام شده است. شکل 7 خروجی این برازش را نشان می‌دهد و براساس گزارش این نرم‌افزار مقدار پارامتر p در این توزیع برابر با $0/9448$ تخمین زده شده است.

با استفاده از منطق برازش ایجادشده با شبکه عصبی مصنوعی بالا، می‌توان مقادیر مربوط به دوره بعدی را به عنوان ورودی به آن داده و تخمین احتمال حضور مشتریان را از آن دریافت کرد. به همین منظور سه پیشامد تصادفی برای ارزیابی مدل در نظر گرفته می‌شود. این سه پیشامد هر یک دارای مقادیر تصادفی در شاخص‌های مدنظر هستند که با ارائه این مقادیر به عنوان ورودی مدل حاصل از برازش، احتمال حضور



شکل (7). برازش حاصل از توزیع دو جمله‌ای روی داده‌های مربوط به حضور مشتریان هتل

جدول 2 مقادیر مربوط به برآورد شبکه عصبی برای سه پیشامد تصادفی بعدی را در مقایسه با میزان حضور ثابت برای مشتریان نشان می‌دهد.

جدول (2). مقادیر پارامتر p حاصل از شبکه عصبی و رویکرد کلاسیک

| p | | |
|------------------------|---------------------------|----------|
| تعیین با رویکرد کلاسیک | تخمین با شبکه عصبی مصنوعی | |
| 0/9448 | 0/9589 | پیشامد 1 |
| 0/9448 | 0/9673 | پیشامد 2 |
| 0/9448 | 0/9854 | پیشامد 3 |

برای سه پیشامد جدول 2 بررسی کرد. جدول 3 و 4 مقادیر مربوط به محاسبات n^* را براساس هر یک از سه پیشامد مذکور به ترتیب برای تخمین با شبکه عصبی و تعیین با رویکرد کلاسیک نشان می‌دهد.

با بهره‌گیری توأمان از رابطه‌های (9) و (10) و با تأکید بر اینکه مقدار تصادفی تقاضا $D(n)$ یک توزیع دو جمله‌ای با پارامتر p دارد (تالوری و ون‌رایزین، 2004)، می‌توان سیاست بهینه را براساس هر رویکرد

جدول (3). محاسبه n^* بر اساس رویکرد شبکه عصبی

| $1 - P\{D(n^*) < L\} = P\{D(n^*) \geq L\}$ | $P\{D(n^*) < L\}$ | n | |
|--|-------------------|------------|-------------------------|
| 0/0144 | 0/9856 | 101 | پیشامد 1 |
| 0/0743 | 0/9257 | 102 | |
| 0/1998 | 0/8002 | 103 | $p = 0/9589$ |
| 0/3769 | 0/6231 | 104 | $\frac{r}{sp} = 0/2086$ |
| 0/5662 | 0/4338 | 105 | |
| 0/0348 | 0/9652 | 101 | پیشامد 2 |

| | | | |
|--------|--------|------------|-------------------------|
| 0/1498 | 0/8502 | 102 | |
| 0/3415 | 0/6585 | 103 | $p = 0/9673$ |
| 0/5567 | 0/4433 | 104 | $\frac{r}{sp} = 0/2068$ |
| 0/7397 | 0/2603 | 105 | |
| 0/2264 | 0/7736 | 101 | پیشامد 3 |
| 0/5602 | 0/4398 | 102 | |
| 0/8088 | 0/1912 | 103 | $p = 0/9854$ |
| 0/9334 | 0/0666 | 104 | $\frac{r}{sp} = 0/2030$ |
| 0/9807 | 0/0193 | 105 | |

جدول (4). محاسبه n^* براساس رویکرد تعیین کلاسیک

| $1 - P\{D(n^*) < L\}$ | $P\{D(n^*) < L\}$ | n | |
|-----------------------|-------------------|------------|--|
| 0/0032 | 0/9968 | 101 | پیشامدهای 1 و 2 و 3 $p = 0/9448$ $\frac{r}{sp} = 0/2117$ |
| 0/0212 | 0/9788 | 102 | |
| 0/0720 | 0/9280 | 103 | |
| 0/1681 | 0/8319 | 103 | |
| 0/3060 | 0/6940 | 105 | |
| 0/4659 | 0/5341 | 106 | |

یک میزان حضور ثابت برای مشتریان استفاده می کند که در مثال بالا، 5 رزرو مازاد را علاوه بر 100 رزرو معمول نتیجه می دهد.

نتیجه گیری

بهره گیری از رویکرد رزرو مازاد در صنعت هتلداری در بهینه سازی سودآوری تأثیر بسزایی دارد (مدرس و نجفی، 1388). این مهم زمانی محقق خواهد شد که فرایند مدل سازی و بهینه سازی مدل مدیریت درآمد براساس رزرو مازاد به درستی انجام شود.

در این پژوهش، مدل رزرو مازاد با در نظر گرفتن مشتریان غایب بررسی شد و پارامتر احتمالی آن به صورت مستقل از روندها و رخدادهای تأثیرگذار بر آن در نظر گرفته نشد. امری که در بسیاری از پژوهش های

جدول 3 و 4 مقادیر مربوط به محاسبات n^* را براساس هریک از سه پیشامد مذکور به ترتیب برای تخمین با شبکه عصبی و تعیین با رویکرد کلاسیک نشان می دهد. همان طور که از جداول مذکور مشخص است، n^* براساس مقداری تعیین می شود که در آن $P\{D(n^*) \geq L\}$ برای اولین بار از p متناظر آن پیشامد بیشتر شود. برای مثال، در پیشامد 1 در جدول 3 اولین مقداری که براساس آن $P\{D(n^*) \geq L\}$ از 0/9589 $p = 0/3769$ بوده که مربوط به 104 $n =$ است؛ بنابراین تعداد رزروشدنی برای 100 اتاق هتل براساس این پیشامد و رویکرد برازش شبکه عصبی 104 واحد تلقی می شود که 4 واحد آن رزرو مازاد خواهد بود. براساس نتایج جدول 4، روشن است که محاسبه تعداد رزرو مازاد براساس رویکرد کلاسیک به پیشامدهای مختلف بستگی ندارد؛ چرا که فقط از

دیگر انجام می‌پذیرد (لو و همکاران، 2009) و میزان حضور یا غیبت مشتریان در موعد مقرر رزروشان را صرفاً براساس برآزش یک تابع توزیع احتمالی دو جمله‌ای بر پیشینه حضور آنها تعیین می‌کند. این رویکرد کلاسیک اگرچه می‌تواند پاسخ مطلوبی را ایجاد کند، اما با توجه به وجود احتمال کمبود در ظرفیت (به دلیل محدودیت ذاتی در مدل رزرو مازاد) مخاطراتی از جنس تحمیل هزینه‌های کمبود و نارضایتی مشتریان را به دنبال خواهد داشت. از این رو، بهره‌گیری از روشی که بتوان با دقت بیشتر و صحت بیشتری پارامترهای مدنظر را برآورد کرد، نیاز ضروری مدل‌های مدیریت درآمد است. به همین دلیل، در این پژوهش از شبکه‌های عصبی به‌عنوان تخمین‌زن مناسبی برای پارامتر احتمالی به کار برده می‌شود تا تأثیرات

محیطی و غیره را نیز روی این شاخص لحاظ کند. این موضوع در مثال عددی ذکر شده در بخش پیش به چشم می‌خورد. در صورتی که هریک از پیشامدهای 1، 2 و 3 در آن مثال رخ دهند و مقادیر مربوط به تخمین شبکه عصبی به عنوان برآوردهای صحیحی از نرخ حضور مشتریان تلقی شود، اگر از همان رویکرد کلاسیک بهره بگیریم، هزینه‌های احتمالی به سیستم وارد خواهد شد؛ چراکه در همه حالت‌ها، میزان حضور پیش‌بینی شده با شبکه عصبی از میزان حضور تعیین شده با روش کلاسیک بیشتر است و این موضوع در عمل به ایجاد هزینه کمبود (S) به ازای هر مشتری حاضر شده در شرایط پر بودن تمامی اتاق‌ها، منجر خواهد شد. این هزینه‌ها در جدول 5 گزارش شده است.

جدول (5). هزینه‌های احتمالی حاصل از رویکرد کلاسیک

| هزینه احتمالی ناشی از کمبود | تفاوت تعداد رزروهای مازاد | p | | |
|-----------------------------|---------------------------|--------------------|-----------------|----------|
| | | پیش‌بینی شبکه عصبی | پیش‌بینی کلاسیک | |
| 1,500,000 تومان | 1 | 0/9589 | 0/9448 | پیشامد 1 |
| 3,000,000 تومان | 2 | 0/9673 | 0/9448 | پیشامد 2 |
| 4,500,000 تومان | 4 | 0/9854 | 0/9448 | پیشامد 3 |

از آنجا هزینه کمبود در بسیاری از مدل‌ها بسیار بیشتر از هزینه درآمدی در نظر گرفته می‌شود و میزان جریمه زیادی دارد (هیلیر و لیبرمن، 2015)، برآورد نرخ صحیح حضور مشتریان اهمیت بسیار زیادی در مدیریت این هزینه پیدا می‌کند. به همین دلیل، در پژوهش حاضر با به کارگیری رویکرد برآزش در بستر شبکه عصبی مصنوعی مدلی توسعه یافت تا پس از شاخص‌سنجی و مطالعه معیارهای تأثیرگذار بر حضور نیافتن مشتریان بتواند پارامتر احتمالی حضور یا غیبت در توزیع دو جمله‌ای را برآورد سازد.

پیشنهادها

با هدف توسعه این پژوهش می‌توان دو رویکرد پیشنهاد داد. در پژوهش جاری صرفاً از رویکرد برآزش در تعیین پارامتر احتمالی مدل رزرو مازاد استفاده شده است؛ در حالی که می‌توان آن را با رویکردهای دیگر نیز مقایسه کرد تا بهترین تخمین حاصل شود. از جمله رویکرد خوشه‌بندی و طبقه‌بندی داده‌ها که قابلیت ویژه‌ای در گروه‌بندی نرخ‌های حضور انواع مشتریان در کلاس‌های مختلف بروز می‌دهد. با تعیین طبقه‌های

متفاوتی از مشتریان با تعیین میزان حضور نیافتن هر گروه می‌توان مدل رزرو مازاد را در چندین سطح به‌طور جداگانه بررسی کرد تا همه طبقات تجاری با یک میزان تحت تأثیر قرار نگیرند. همچنین می‌توان از تحلیل سری‌های زمانی برای پیش‌بینی روند آتی بهره گرفت تا با یک رویکرد غیرخطی بتوان با نگاهی گذشته‌نگر به داده‌های پیشین، روند آنها را برآورد کرد و داده‌های بعدی را تخمین زد. اگر بتوان مجموعه‌ای غنی از داده‌های پیشین فراهم کرد، استفاده از سایر روش‌های تحلیل سری‌های زمانی به پارامتریابی این پژوهش کمک شایانی می‌کند.

از سوی دیگر، به دلیل مهیانبودن زیرساخت‌های داده‌محور مدیریت درآمد در صنعت هتلداری کشور، پایگاه‌های داده‌ی غنی و تأثیرگذاری برای اجرای مدل در فضای واقعی وجود ندارد؛ حتی در مطالعات داخلی نظیر پژوهش کتابی و همکاران (۱۳۹۳) یا مطالعه‌ی مدرس و نجفی (۱۳۸۸) از مثال عددی استفاده شده است و نبود مطالعات موردی در این حوزه حس می‌شود. این در حالی است که در بخش حمل و نقل داخلی مطالعات موردی نظیر پژوهش پورسیدآقایی و همکاران (۱۳۸۸) در حمل و نقل ریلی یا پژوهش اعتباری و آقایی (۱۳۹۱) در خطوط هوایی به چشم می‌خورد؛ اما در صنعت هتلداری و بخش‌های مبتنی بر آن همچنان نبود مطالعاتی حقیقی حس می‌شود. از این رو، می‌توان با پایش و ثبت داده‌های مربوط به یک مجموعه خاص این مهم را برآورد کرد تا در فضای واقعی به بهینه‌سازی فوق دست پیدا کنیم. برای اجرایی کردن این پیشنهاد ضروری است که پس از تعیین شاخص‌های مربوط به تحلیل حضور مشتریان، به جمع‌آوری داده‌های مربوطه در یک بازه زمانی خاص در یک یا چند مجموعه اقامتی اقدام شود تا بتوان در فاز بعدی، این داده‌ها را تحلیل کرد.

منابع

- 1- اعتباری، فرهاد و آقایی، عبدالله (۱۳۹۱). «قیمت‌گذاری پویای پروازهای موازی با در نظر گرفتن رفتار انتخابی مشتری». پژوهشنامه حمل و نقل، ۹ (۲)، ۱۱۷-۱۳۵.
- 2- پورسیدآقایی، محسن؛ خدمتلو، سعید و آزرمی، سیاوش (1388). «طراحی مدل مدیریت درآمد در شرکت‌های حمل و نقل عمومی: مورد کاوی قطار غزال تهران مشهد». نشریه مهندسی صنایع، ۴۳ (۱)، ۱-۱۱.
- 3- رحمانی، علی و اسماعیلی، غریبه (1389). «کارایی شبکه‌های عصبی، رگرسیون لجستیک و تحلیل تمایزی در پیش‌بینی نکل». اقتصاد مقداری، 7 (4)، 151-172.
- 4- کتابی، سعیده؛ قندهاری، مهسا و احمدی، مسعود (1393). «بهینه‌سازی درآمد هتل در حالت وجود تقاضای قطعی و غیرقطعی با در نظر گرفتن لغو درخواست و عدم حضور میهمان». مدیریت تولید و عملیات، 9 (2)، 129 - 144.
- 5- مدرس، محمد و نجفی، مهدی (1388). «برنامه‌ریزی تصادفی بهینه‌سازی پایدار درآمد هتل». نشریه بین‌المللی مهندسی صنایع و مدیریت تولید، 4 (20): 11-21.
- 6- Adhikari, R. (2015). A neural network based linear ensemble framework for time series forecasting. *Neurocomputing*, 157: 231-242.
- 7- Amaruchkul, K. & Sae-Lim, P. (2011). Airline overbooking models with misspecification. *Journal of Air Transport Management* 17, 143-147
- 8- Ballesterro, P.T. & Serrano, L.G. (2012). Yield Revenue Management in the Hotel Sector: An Empirical Analysis of Its Application and Results in Madrid, Spain (Chapter). *Quantitative Methods in Tourism Economics*: 213-231.

- 3-14.
- 20- Koide, T. and Ishii, H. (2005). The hotel yield management with two types of room prices, overbooking and cancellations. *International Journal of Production Economics*, 93-94: 417-428.
 - 21- Lai, K.K. & Ng, W.L. (2005). A stochastic approach to hotel revenue optimization. *Computers and Operations Research*, 32(1): 1059-1072.
 - 22- Li, M.M. & Verma, B. (2016). Nonlinear curve fitting to stopping power data using RBF neural networks. *Expert Systems With Applications* 45, 161-171.
 - 23- Luo, S., Çakanyıldırım, M. & Kasilingam, R.G. (2009). Two-dimensional cargo overbooking models. *European Journal of Operational Research* 197(3), 862-883.
 - 24- Noone, B.M. & Mattila, A. (2009). Hotel revenue management and the Internet: The effect of price presentation strategies on customers willingness to book. *International Journal of Hospitality Management*, 28(2): 272-279.
 - 25- Rothstein, M. (1971). An Airline Overbooking Model. *Transportation Science*, 9(2), 180-192.
 - 26- Rothstein, M. (1974). Hotel Overbooking as a Markovian Sequential Decision Process. *Decision Science*, 5, 389-404.
 - 27- Sieraga, D.D., Koole, G.M., van der Meia, R.D., van der Rest, J.I. & Zwart, B. (2015). Revenue management under customer choice behaviour with cancellations and overbooking. *European Journal of Operational Research*, 246(1): 170-185.
 - 28- Sun X. S., Brauner E. and Hormby S. (1998) A Large-Scale Neural Network for Airline Forecasting in Revenue Management. In: Yu G. (eds) *Operations Research in the Airline Industry*. International Series in Operations Research & Management Science, 9. Boston: Springer.
 - 29- Talluri, G. & Van Ryzin, K. (2004). *Theory and Practice of Yield Management*. Boston: Kluwer Academic Publishers (now Springer).
 - 30- Tsai, L. (2009). Customer churn prediction by hybrid neural networks. *Expert Systems with Applications*, 36: 12547-12553.
 - 31- Tsai, T-H., Lee, C-K. and Wei, C-H. (2009). Neural network based temporal
 - 9- Cullen, K & Helsel, C. (2006), *Defining Revenue Management Top Line to Bottom Line*, HSMAL.
 - 10- El-Sharo, M., Zheng, B., Yoon, S.W. & Khasawneh, M.T (2015). An overbooking scheduling model for outpatient appointments in a multi-provider clinic. *Operations Research for Health Care*, 6, 1-10.
 - 11- Emeksiz, M., Gursoy, D. & Icoz, O. (2005). A yield management model for five-starhotels: Computerized and n-computerized implementation. *International Journal of Hospitality Management*, 25(4): 536-551.
 - 12- Freisleben, B. and Gleichmann, G. (1993). Controlling airline seat allocations with neural networks. *Proceedings of the Twenty-sixth Hawaii International Conference on System Sciences*.
 - 13- Georgiadis, G. & Tang, C.S. (2014). Optimal reservation policies and market segmentation. *Int. J. Production Economics* 154, 81-99
 - 14- Guadix, J., Cortés, P., Onieva, L. & Muñozuri, J. (2010). Technology revenue management system for customer groups in hotels. *Journal of Business Research*, 63(5), 519-527.
 - 15- Harewood, S.I. (2006). Managing a hotel's perishable inventory using bid prices. *International Journal of Operations & Production Management*, 26(10): 1108-1122.
 - 16- Hillier, F. S. & Lieberman, G. J. (2015). *Introduction to Operations Research (Tenth Edition)*. New York: McGraw-Hill Education.
 - 17- Iyengar, A. & Suri, K. (2012). Customer profitability analysis an avant-garde approach to revenue optimisation in hotels. *International Journal of Revenue Management*, 6(1/2): 127-143.
 - 18- Kim, H.S., Eykholt, R., Salas, J.D. (1999). Nonlinear dynamics, delay times and embedding windows. *Physica D: Nonlinear Phenomena*, 127(1-2): 48-60.
 - 19- Kimes S. A strategic approach to yield management. In: Ingold A, McMahan-Beattie U, Yeoman I, editors. *Yield Management: Strategies for the service industries*. London: Continuum; 2000. p.

- 33- Wirtz. J., Kime, S., Theng, J.H.P. & Patterson, P. (2003). Revenue Management: Resolving potential customer conflicts. *Journal of Revenue and Pricing Management*, 2(3): 216–226.
- 34- Zhang, Y. (2007). The Theoretical Research Summary of Hotel Room Pricing Method. *Tourism Tribune*, 3(1): 40-58.
- feature models for short-term railway passenger demand forecasting. *Expert Systems with Applications*, 36(2), 3728-3736.
- 32- Weatherford, L. R. and Kimes, S. E. (2003) A comparison of forecasting methods for hotel revenue management. *International Journal of Forecasting*, 19(3), 401–415.