



## Demand Prediction in University Booking Systems to Reduce Food Waste Using Neural Networks Including Weighted Error Function

**Mohammadali Faezirad**

Ph.D. Candidate, Department of Management, Faculty of Economics and Administrative Science, Ferdowsi University of Mashhad, Mashhad, Iran. E-mail: faezirad@mail.um.ac.ir

**Alireza Pooya**

\*Corresponding Author, Prof., Department of Management, Faculty of Economics and Administrative Science, Ferdowsi University of Mashhad, Mashhad, Iran. E-mail: alirezapooya@um.ac.ir

**Zahra Naji-Azimi**

Prof., Department of Management, Faculty of Economics and Administrative Science, Ferdowsi University of Mashhad, Mashhad, Iran. E-mail: znajiazimi@um.ac.ir

**Maryam Amir Haeri**

Assistant Prof., Department of Learning, Data-Analytics and Technology, University of Twente, Enschede, Netherlands. E-mail: m.amirhaeri@utwente.nl

### Abstract

**Objective:** A significant challenge in the university meal booking is the high No-Show rate that leads to considerable food waste in consequence of facing low price of nutrition system and government subsidizing. This study aims to prevent food waste in university dining halls via predicting actual demand.

**Methods:** To model and solve the problem, an Artificial Neural Network has been used that was performed by weighting the error function with Generalized Pattern Search (GPS). Date, the day of the week, the price level of Food, total number of reservations, total number of reservations by undergraduate students, Masters' students, PhD students and dormitory students and the parallel food have been considered as inputs of the model. The output is the actual demands based on Show's number.


**Results:** The seven-year data of the meal booking system of a large university in Iran has been examined. This data demonstrated that the food waste rate is close to 10% of the total food reservations. An artificial neural network including weighted error function under GPS optimization was obtained to predict actual demand. Finally, the results of training indicated over 80% waste reduction in surplus daily food production.

**Conclusion:** The proposed model has the potential to provide an estimation of actual demand. Although adding indicators that influence demand estimation, the proposed model is able to change the actual demand prediction at various levels of risk expected by the university. To avoid food waste and prevent the loss of government subsidies, this precautionary approach can control overproduction.

**Keywords:** Meal booking, Food waste, Artificial neural networks, Weighted error function, Pattern search algorithm

**Citation:** Faezirad, Mohammadali; Pooya, Alireza; Naji-Azimi, Zahra and Amir Haeri, Maryam (2021). Demand Prediction in University Booking Systems to Reduce Food Waste Using Neural Networks Including Weighted Error Function. *Industrial Management Journal*, 13(2), 170-193. (in Persian)

Industrial Management Journal, 2021, Vol. 13, No.2, pp. 170-193

 <https://doi.org/10.22059/IMJ.2021.318760.1007821>

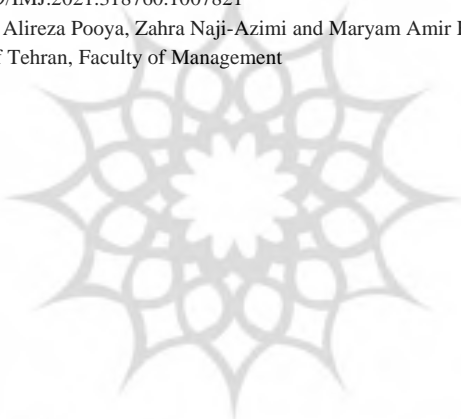
© Mohammadali Faezirad, Alireza Pooya, Zahra Naji-Azimi and Maryam Amir Haeri

Published by University of Tehran, Faculty of Management

Article Type: Research Paper

Received: February 20, 2021

Accepted: June 12, 2021



پژوهشگاه علوم انسانی و مطالعات فرهنگی  
رتال جامع علوم انسانی



## پیش‌بینی تقاضا در سیستم‌های رزرواسیون دانشگاهی با هدف کاهش ضایعات مواد غذایی به کمک شبکه‌های عصبی با تابع خطای موزون

محمدعلی فائزی راد

دانشجوی دکتری، گروه مدیریت، دانشکده علوم اداری و اقتصادی، دانشگاه فردوسی مشهد، مشهد، ایران. رایانامه: faezirad@mail.um.ac.ir

علیرضا پویا

\* نویسنده مسئول، استاد، گروه مدیریت، دانشکده علوم اداری و اقتصادی، دانشگاه فردوسی مشهد، مشهد، ایران. رایانامه: alirezapooya@um.ac.ir

زهرا ناجی عظیمی

استاد، گروه مدیریت، دانشکده علوم اداری و اقتصادی، دانشگاه فردوسی مشهد، مشهد، ایران. رایانامه: znajiazimi@um.ac.ir

مریم امیر حائری

استادیار، گروه یادگیری، تحلیل داده و فناوری، دانشگاه توئنته، انسخده، هلند. رایانامه: m.amirhaeri@utwente.nl

### چکیده

**هدف:** یکی از دغدغه‌های مهم در رزرواسیون غذای دانشگاهی، مراجعه نکردن بسیاری از دانشجویان است که با توجه به دریافت یارانه دولتی و قیمت ارزان غذا، انبوهی از مواد غذایی هدر رفته و به ضایعات تبدیل می‌شود. هدف اصلی این پژوهش، جلوگیری از تولید ضایعات مواد غذایی در دانشگاه‌ها، به کمک پیش‌بینی تقاضای واقعی است.

**روش:** برای مدل‌سازی و حل مسئله، از شبکه عصبی مصنوعی با تابع خطای موزونی که به کمک جست‌وجوی الگوی تعمیم‌یافته جهت‌دهی می‌شود، استفاده شد. شاخص‌های مجموع رزرو، روز هفته، سطح قیمت وعده، مجموع تعداد رزرو، تعداد رزرو به تفکیک مقطع تحصیلی، تعداد رزرو به تفکیک وضعیت اسکان و غذای مجاور به‌عنوان متغیرهای ورودی و تعداد تقاضای واقعی غذا نیز شاخص خروجی در نظر گرفته شد.

**یافته‌ها:** داده‌های هفت سال اخیر سامانه رزرواسیون سلف مرکزی یکی از دانشگاه‌های بزرگ کشور که سالانه به‌طور متوسط پتانسیل تولید ۵۶ هزار پرس غذای مازاد (بیش از ۲۳ هزار کیلوگرم مواد غذایی) را دارد، بررسی شد. با آموزش یک شبکه عصبی مصنوعی توأم با بهینه‌سازی GPS، الگوریتم ترکیبی با تابع خطای موزون متناسبی به‌دست آمد که قادر است تولید روزانه غذای مازاد را بیش از ۸۰ درصد کاهش دهد.

**نتیجه‌گیری:** با استفاده از مدل ارائه شده، می‌توان تقاضای واقعی را به‌طور دقیق‌تر تخمین زد. مدل پیشنهادی، ضمن معرفی شاخص‌های مؤثر بر تخمین تقاضا، قادر است که در سطوح ریسک مختلف مورد انتظار دانشگاه، تقاضاهای واقعی را برآورد کند. این رویکرد پیشگیرانه، وعده‌های غذایی کنترل شده را فقط به اندازه احتیاج تولید و توزیع خواهد کرد تا از ضایعات مواد غذایی یا اتلاف بودجه عمومی کشور جلوگیری شود.

**کلیدواژه‌ها:** رزرواسیون غذا، ضایعات مواد غذایی، شبکه عصبی مصنوعی، تابع خطای موزون، الگوریتم جست‌وجوی الگو

**استناد:** فائزی راد، محمدعلی؛ پویا، علیرضا؛ ناجی عظیمی، زهرا و امیرحائری، مریم (۱۴۰۰). پیش‌بینی تقاضا در سیستم‌های رزرواسیون دانشگاهی با هدف کاهش ضایعات مواد غذایی به کمک شبکه‌های عصبی با تابع خطای موزون. مدیریت صنعتی، ۱۳(۲)، ۱۷۰-۱۹۳.

## مقدمه

مدیریت رزرواسیون مفهوم جدیدی نیست؛ زیرا به طور گسترده‌ای در صنایع مختلفی نظیر صنایع حمل‌ونقل مثل خطوط هوایی، حمل‌ونقل ریلی یا مدیریت پارکینگ‌ها و نیز در صنایع دیگری چون صنعت هتل‌داری و مدیریت رستوران‌ها استفاده شده است (لیو، یانگ و ین<sup>۱</sup>، ۲۰۱۵). بررسی مفهوم رزرواسیون و کنترل و بهینه‌سازی آن در حوزه‌های مختلف، اغلب در قالب مدیریت درآمد مطرح می‌شود. در شاخه مدیریت درآمد مبتنی بر کمیّت با پایدارسازی قیمت، به مدیریت تعداد و شیوه رزرو پرداخته می‌شود تا پیرامون تخصیص منابع رزروی به مشتریان تصمیم‌گیری گردد (تالوری و ون‌رایزن<sup>۲</sup>، ۲۰۰۴).

مدیریت رزرو در حوزه خدمات تأمین و توزیع غذا نیز یکی از کاربردهای این دانش است که بیشتر در مدیریت رزرواسیون رستوران‌ها خلاصه می‌شود (گریگوراش<sup>۳</sup>، ۲۰۱۶). با این حال، یکی از حوزه‌های پرتراکنش در حوزه رزرو و توزیع غذا، سامانه‌های رزرواسیون دانشگاهی و سلف‌های غذای دانشگاهی است. سیستم‌های رزرواسیون وعده‌های غذا در دانشگاه‌های متعددی در دنیا وجود دارد که جریان رزرو، تأمین و توزیع غذا به دانشجویان را کنترل می‌کند (پینتر، تندلانا و کوآ<sup>۴</sup>، ۲۰۱۶). در ایران نیز با توجه به ماهیت یارانه‌ای توزیع غذای دانشجویی سیستم رزرواسیون در دانشگاه مختلف فعال است و یکی از تسهیلاتی که در دانشگاه‌های ایران به منظور رفاه دانشجویان در نظر گرفته شده است، ارائه وعده‌های غذایی ارزان قیمت به دانشجو است (قانون برنامه پنج‌ساله ششم توسعه، ۱۳۹۶).

مؤلفه‌های در تعامل با رزرو غذا در دانشگاه‌ها، مواردی چون قیمت پایین غذا (سیفی، ۱۳۹۹)، حجم تراکنش بالای رزرو و توزیع غذا و نیز ضایعات ناشی از پسماند غذا در سلف‌ها و نقاط توزیع (پینترو همکاران، ۲۰۱۶) است. با این حال، پژوهش‌های پیشین کمتر به طراحی رویکردهای کمی در این زمینه پرداخته‌اند. این در حالی است که ابعاد رزرواسیون غذا از جنبه‌های مالی و تولید ضایعات بسیار گسترده است. بر اساس برآورد مدیر صندوق رفاه دانشجویان، در سال تحصیلی ۹۸-۹۷، بالغ بر ۱۱۲ تا ۱۱۳ میلیون پرس غذا در وعده‌های ناهار و شام در دانشگاه‌های دولتی کشور توزیع شده که بیش از ۸۴۰ میلیارد تومان یارانه دولتی بابت آن پرداخت شده است (هزینه ناهار و شام دانشجویی، ۱۳۹۸). این در حالی است که در بند ت از ماده ۶۵ قانون برنامه ششم توسعه کشور که از سوی مجلس شورای اسلامی به دولت جمهوری اسلامی ایران ابلاغ شده است، بر پیش‌بینی و تأمین اعتبار مورد نیاز یارانه غذایی دانشجویی از محل درآمدهای عمومی تصریح شده است (قانون برنامه پنج‌ساله ششم توسعه، ۱۳۹۶). این تأکید قانونی و عملیاتی شدن مکرر آن در هر سال تحصیلی، بار مالی چشمگیری را به دولت و دانشگاه‌ها تحمیل کرده و می‌کند. در همین راستا، پژوهش پیش رو، به منظور کاهش بار مالی که از بودجه عمومی کشور تأمین می‌شود، اجرا شده است.

1. Liu, Yang &amp; Yin

2. Talluri &amp; Van Ryzin

3. Gregorash

4. Painter, Thondhlana &amp; Kua

مدل پژوهش، علاوه بر اینکه در یک مسئله ملی و واقعی پیاده‌سازی شده است و این قابلیت را دارد که در سطح بین‌المللی توسعه یابد، می‌تواند از جنبه کاهش هزینه‌ها و افزایش رضایتمندی نیز خدمت‌شایان توجهی را در بودجه دولتی و شرایط صنفی دانشجویان ارائه دهد.

با درک ضرورت فوق، طراحی یک سازوکار برای کاهش ضایعات مواد غذایی ناشی از رزرو دانشجویان و حاضر نشدن آنها در موعد موردنظر در این پژوهش دنبال شده است. تصمیم‌سازی درباره دسترسی به ظرفیت رزرو از طریق پیش‌بینی دقیق تقاضا به وجود می‌آید که باید در آن به نوسانات تقاضای دوره رزرو توجه داشت (آزاده، مارکوتی و ساوارد<sup>۱</sup>، ۲۰۱۵). از همین جهت، می‌توان پیش‌بینی تقاضا را به عنوان مرکز بسیار مهمی تلقی کرد که ورودی‌هایی را برای کنترل ظرفیت ارائه می‌کند که برای سیستم حیاتی است (لمکی، ریدل و گابریس<sup>۲</sup>، ۲۰۱۳). زمانی که نیاز به پیش‌بینی تقاضا وجود داشته باشد، روش‌های مختلفی برای این منظور قابل ارائه هستند که به‌عنوان عنصر کلیدی موفقیت مدل‌ها تلقی می‌شوند (هیلیر و لیبرمن<sup>۳</sup>، ۲۰۱۵) از این روی، مدیریت تقاضا به‌عنوان ریشه مدیریت رزرو در نظر گرفته شده (ژائو، تریانتیس، تئودوریچ و آدارا<sup>۴</sup>، ۲۰۱۰) و مدل پیشنهادی مبتنی بر آن طراحی شده است.

سیستم‌های رزرواسیون در بسیاری از دانشگاه‌های دنیا وجود دارند (مریس، اسمیت، کتون و لوتزی<sup>۵</sup>، ۲۰۱۷؛ دانشگاه MIT، ۲۰۲۰) اما با بهره‌گیری از فناوری‌های اطلاعاتی جدید می‌توان اطلاعات مربوط به مشتریان را به راحتی جمع‌آوری کرده و یک سیستم رزرو هوشمند ایجاد کرد تا به‌طور کامل تقاضا را مدیریت کند (هاین و گریکو<sup>۶</sup>، ۲۰۰۳). در این پژوهش یک مدل یادگیری ماشین مبتنی بر شبکه‌های عصبی مصنوعی تدوین شده است تا بتواند نقش برآوردگر تقاضا را برای سیستم رزرواسیون بازی کند. با توجه به ماهیت حساس انتظارات دانشجویی در دانشگاه، نوع برآورد آن خالی از جهت‌گیری نیست. در این پیش‌بینی، بین کاهش حسن نیت دانشجویی ناشی از برآورد کم و افزایش ضایعات ناشی از برآورد زیاد یک تعادل برقرار شده و با استفاده از وزن‌دار کردن تابع خطای شبکه عصبی پیش‌بینی‌کننده به یک مدل پایدار برای برآورد نهایی تقاضای واقعی دست یافته شده است.

در ادامه این مقاله و در بخش پیشینه پژوهش، ادبیات مدیریت رزرو در حوزه‌های خدمات تأمین و توزیع غذا، کاهش ضایعات و مدل‌های پیش‌بینی آن مرور شده است. در بخش بعدی، روش پژوهش تشریح شده و مراحل پیاده‌سازی شبکه عصبی مبتنی بر تابع خطای موزون به همراه مدل ترکیبی با الگوریتم جست‌وجوی الگو تشریح شده است. بخش چهارم این مقاله، به مرور یافته‌ها اختصاص دارد که در آن، مطالعه موردی پژوهش معرفی شده و ساختار داده‌ها و شیوه به‌کارگیری آنها بررسی می‌شود. نتایج حاصل از پیاده‌سازی مدل پیشنهادی در ادامه این بخش ارائه شده است. در بخش آخر، کارکرد مدل معرفی شده جمع‌بندی شده و مزایای حاصل از به‌کارگیری آن بررسی شده است؛ همچنین دو پیشنهاد عملیاتی به‌منظور توسعه پژوهش مورد بررسی قرار گرفته است.

1. Azadeh, Marcotte & Savard
2. Lemke, Riedel & Gabrys
3. Hillier & Lieberman
4. Zhao, Triantis, Teodorović & Edara
5. Marais, Smit, Koen & Lötze
6. Hine & Grieco

## پیشینه پژوهش

### مدیریت رزرو در خدمات تأمین و توزیع غذا

ادبیات مدیریت رزرو تحت عنوان مدیریت رزرواسیون<sup>۱</sup> یا ثبت<sup>۲</sup> متمرکز نیست و بسته به حوزه علمی یا کاربرد آن به تحریر درآمده است. از این روی، ادبیات مدیریت رزرو یا مدیریت ثبت را باید در دانش مدیریت درآمد یا مطالعه سیستم‌های رزرو که متعلق به برخی از صنایع خدماتی هستند، یافت. مدیریت رزرو در بسیاری از صنایع رایج است و بنا بر ویژگی‌های هر صنعت سازگار شده است. صنعت هواپیمایی و مدیریت رزرو ایرلاین‌ها، یکی از قدیمی‌ترین حوزه‌هایی است که در آن از مدیریت رزرو استفاده شده است (هیلبر و لیبرمن، ۲۰۱۵). علاوه بر این صنعت، به‌کارگیری مدل‌های مدیریت رزرو - که در بسیاری از موارد بر مدل‌های مدیریت درآمد مبتنی است - در حوزه‌هایی چون صنعت هتل‌داری، مدیریت گردشگری، برنامه‌ریزی ترافیک، حمل‌ونقل مسافر و بار، صنایع تفریحی و نیز تولید صنعتی نیز گزارش شده است (لیو، یانگ و یین، ۲۰۱۵؛ تسای<sup>۳</sup>، ۲۰۱۴؛ مردانه و جوکار، ۱۳۸۵).

در مدیریت رزرواسیون، سیستم‌های رزرو نقش مهمی برای تضمین دسترسی کاربران به منبع را ایفا می‌کنند (لو، ۲۰۱۳). این سیستم‌ها مبتنی بر مدیریت درآمد در حیطه خدمات غذایی<sup>۴</sup> نیز گسترش یافته است (گریگوراش، ۲۰۱۶). سیستم رزرواسیون وعده غذایی یک ابزار ارزنده برای مانیتورینگ و کنترل وعده‌های غذایی مورد پردازش است. این سیستم کمک می‌کند که وعده‌های غذایی سفارش داده‌شده و وعده‌های غذایی تأمین‌شده یا تحویل‌شده با یکدیگر مقایسه شوند (مدیریت ضایعات مواد غذایی در NHS، ۲۰۰۵). یکی از کاربردهای سیستم‌های رزرواسیون وعده غذایی در حوزه رزرواسیون غذای دانشگاهی است. یک سیستم رزرواسیون وعده غذایی<sup>۵</sup> سامانه‌ای در حوزه عملیات خدمات غذایی دانشگاه است که به‌منظور ثبت و پردازش تعداد کل وعده‌های غذایی رزروشده یا غذاهای مشخص در روزهای معین به‌کار می‌رود (آلوو<sup>۶</sup>، ۲۰۱۵).

سیستم‌های رزرواسیون وعده‌های غذا در دانشگاه‌های متعددی در دنیا وجود دارد که در بسیاری از موارد با یارانه همراه است (آلوو، ۲۰۱۵؛ دانشگاه MIT، ۲۰۲۰). چنین سیستمی در دانشگاه‌های ایران نیز برقرار است و در قالب تسهیلاتی از بودجه عمومی، فرایند طبخ غذا را به پیمانکار سپرده و فرایند رزرو و توزیع را از این طریق پیاده‌سازی می‌کند. وعده‌های غذای دانشجویان مشمول یارانه دولتی بوده و با قیمت کم عرضه می‌شود. این رویه حتی در دانشگاه‌ها و مراکز آموزشی غیردولتی و غیرانتفاعی نیز با تعیین تعرفه غذا از سوی دولت در جریان است (سیفی، ۱۳۹۹).

با وجود سازوکارهای تأمین غذای دانشجویی در دانشگاه‌های مختلف جهان، پژوهش‌های اندکی با تمرکز بر پیش‌بینی تقاضا در فرایند تأمین و توزیع غذای دانشگاهی صورت گرفته است. این در حالی است که می‌توان ادعا کرد که ریشه مدیریت رزرو در مدیریت تقاضاست (ژائو، تریانتیس، تئودوریچ و ادارا، ۲۰۱۰)، زیرا رزروهای ثبت‌شده نمی‌توانند به تنهایی برآورد صحیحی از تعداد مشتریان را حاصل کنند (آزاده، مارکوتی و ساوارد، ۲۰۱۵).

1. Reservation
2. Booking
3. Tsai
4. Foodservices
5. Meal booking system
6. Alooh

جدول ۱، پژوهش‌های انجام‌گرفته در حوزه تخمین و برآورد تغذیه دانشجویی را نمایش می‌دهد. در این جدول بازه زمانی داده‌های مورد استفاده در هر پژوهش و عوامل در نظر گرفته شده در آن نشان داده می‌شوند. مؤلفه «تأثیر منو یا نوع غذا» می‌تواند شامل نام غذا، دسته‌بندی بر اساس رده قیمتی یا نوع ارزش تغذیه‌ای آن و سایر حالت‌های مربوطه باشد. «تأثیر زمان یا روز هفته»، به مدل‌سازی بر اساس تاریخ یا روز هفته و لحاظ کردن آن به‌عنوان یک متغیر مستقل دلالت می‌کند. منظور از تأثیر «فصل یا تعطیلات» نیز در نظر گرفتن تعطیلات مناسبتی یا فصول مختلف سال است. مؤلفه «تأثیر متقابل گزینه‌ها» بیان‌گر در نظر گرفتن غذا یا غذاهای موازی در کنار غذای مورد نظر به‌طور هم‌زمان و غیرمستقل است که تأثیر رقابتی بر یکدیگر را می‌رساند. «داده‌های رزرواسیون» نیز بر استفاده یا عدم‌استفاده از داده‌های رزرو دانشجویان یا مدل‌سازی بر آن پایه تأکید می‌کند.

جدول ۱. مروری بر مطالعات خدمات غذایی دانشگاهی با محوریت پیش‌بینی تقاضا

تأثیر متقابل گزینه‌ها	تأثیر فصل یا تعطیلات	تأثیر زمان یا روز هفته	تأثیر منو یا نوع غذا	دسته‌بندی کاربران	داده‌های رزرواسیون	روش حل	گستره زمانی	پژوهش
		✓	✓			میانگین متحرک و هموارسازی نمایی	۱۵ هفته	بلچر و یه، ۲۰۰۸
	✓		✓	✓		رگرسیون خطی	۳ سال	کیلیج، ۲۰۱۵
		✓	✓			شبکه عصبی	-	یرگوک، گوون و اجی، ۲۰۱۸
		✓				میانگین متحرک و هموارسازی نمایی	۷ سال	علی و همکاران، ۲۰۱۹
	✓	✓	✓			شبکه عصبی	۱۵ ماه	چتینکایا و اردال، ۲۰۱۹
		✓				آریم، شبکه عصبی و فیس‌بوک پرافت	۱۲ ماه	یورتسور و تکیم، ۲۰۲۰
✓		✓	✓	✓	✓	شبکه عصبی با تابع خطای موزون	۷ سال	پژوهش جاری

با بررسی پژوهش‌های مندرج در جدول ۱ درمی‌یابیم که اگرچه پژوهش‌های اندکی در زمینه پیش‌بینی تعداد غذای موردنیاز برای دانشجویان در سلف‌ها یا کافه‌های دانشگاهی صورت گرفته است، اما هیچ‌یک بر پایه داده‌های مربوط به رزرو و پیشینه آن بنا نشده‌اند. مطالعات قبلی، بر پایه اطلاعات تحویل غذا بنا شده‌اند و بنابراین فقط تعداد تقاضا در نقطه تحویل را مدنظر قرار داده‌اند فارغ از اینکه رزرواسیون وجود دارد یا خیر. این وجه از شکاف پژوهشی، غنای مدل پیشنهادی را در مطالعه جاری بیشتر نشان می‌دهد. از سوی دیگر، با وجود آنکه اغلب پژوهش‌های مورد اشاره، تأثیر منو یا انواع غذاهای پیشنهادی به دانشجو را به شیوه‌ای لحاظ کرده‌اند اما همچنان خلاً یک مدل که بتواند تأثیر منوها یا غذاهای پیشنهادی را به‌طور هم‌زمان در نظر بگیرد احساس می‌شود. این مورد نیز در پژوهش جاری با در نظر گرفتن دو خروجی هم‌زمان برای هر پیش‌بینی، پوشش داده شده است. تأثیر تعطیلات در مطالعه این مقاله در نظر گرفته نشده است زیرا سرویس‌دهی تغذیه مورد مطالعه در ایام تعطیلات، محدود یا تعطیل است.

افزون بر موارد ذکر شده، تأثیر مؤلفه‌های شخصی یا دانشجویی در اغلب پژوهش‌های پیشین دیده نمی‌شود. برخلاف مؤلفه‌های سرویس‌دهنده (مثل نوع غذا یا روز هفته)، مؤلفه‌های مربوط به سرویس‌گیرنده نیز قابل بررسی است. این عناصر در گروه «دسته‌بندی کاربران» ذکر شده است که دانشجویان را بر اساس اطلاعات شخصی یا رفتاری آنها به گروه‌های مختلف دسته‌بندی می‌کند. چتینکایا و اردال<sup>۱</sup> (۲۰۱۹) مؤلفه‌های فردی را با اهمیت و تأثیرگذار می‌شمارند اما به‌کارگیری آنها را دشوار ارزیابی می‌کنند؛ کما اینکه در پژوهش خود نیز از آنها صرف نظر کرده‌اند. کیلیچ<sup>۲</sup> (۲۰۱۶) نیز فقط به دو شاخص مرخصی و بازه زمانی دریافت حقوق کاربران بسنده کرده و تعداد افراد را متناسب با حضور آنها در روز مشخص در نظر گرفته است. در پژوهش جاری، دو شاخص مقطع تحصیلی و اسکان در خوابگاه به عنوان شاخص‌های هویتی و فردی در نظر گرفته شده که در ابتدای بخش یافته‌ها معرفی می‌شوند.

### کاهش ضایعات غذایی مبتنی بر کنترل رزرواسیون

اگرچه بسیاری از دانشگاه‌های جهان خدمات غذایی خود به دانشجویان را بر مبنای رزرواسیون غذا ارائه می‌کنند، اما جایگاه مدل‌های بهینه‌سازی در این حوزه خاص به‌خوبی پوشش داده نشده است. این خلأ پژوهشی در حالی است که حجم ضایعات غذای ناشی از عدم حضور دانشجویان در موعد مقرر یا ناشی از رفتار دانشجویان، بسیار قابل توجه بوده به طوری که در پژوهش‌های متعدد به بررسی ضایعات غذایی ناشی از غذای دانشجویی پرداخته شده است (پینتر، تندلانا و کوآ، ۲۰۱۶). دلایلی همچون ارزان قیمت بودن غذای دانشجویی، حجم و تنوع بالا، مکان‌های توزیع متفاوت و وعده‌های مختلف موجب شده است که مطالعات گسترده‌ای بر روی کنترل سرویس غذای دانشجویی و کاهش ضایعات ناشی از آن در ادبیات این موضوع صورت پذیرد.

جدول ۲ به‌طور خلاصه پژوهش‌های پیشین مرتبط با موضوع ضایعات مواد غذایی دانشگاهی را با محورهای مورد مطالعه آنها نمایش می‌دهد. این پژوهش‌ها اغلب بر روش‌های اغلب بر بررسی و تخمین حجم ضایعات مواد غذایی در دانشگاه‌ها و روش‌های پیشگیری یا مدیریت آنها تمرکز کرده‌اند. رویکردهای مندرج در این جدول، هیچ‌یک پاسخ روشنی بر مدیریت و بهینه‌سازی مستقیم رزرواسیون و طبخ غذا نیست، این در حالی است که مدیریت رزرو، در کاهش ضایعات نقش پُررنگی دارد. پیاده‌سازی یک سیستم رزرواسیون که کاربران را از پیش مجبور به رزرو وعده‌های غذایی می‌کند، می‌تواند به برنامه‌ریزی و تولید در بخش طبخ کمک کند تا از تولید بیش از حد غذا جلوگیری شود (استین، میلفورس، روس و اریکسون، ۲۰۱۸). تعدادی از دانشجویان غذا رزرو می‌کنند اما هنگام تحویل آن، حاضر نمی‌شوند. بدین ترتیب تمام مواد غذایی تازه و غذاهای آماده تحویل به آنها تبدیل به ضایعات می‌شود (آلوو، ۲۰۱۵). این عدم حضور یا عدم دریافت غذای رزرو شده وعده‌های مختلف متفاوت است و حجم شایان توجهی از پسماند مواد غذایی را تولید می‌کند (پینتر، تندلانا و کوآ، ۲۰۱۶). اگرچه بر اساس اطلاعات جدول ۲، مطالعاتی با رویکرد انگیزه دانشجویان در تولید پسماند و ضایعات مواد غذایی صورت گرفته است اما طراحی یک سازوکار کمی مبتنی بر پیش‌بینی تقاضا و برآورد طبخ مورد نیاز یافت نشده است.



جدول ۲. رویکردهای رایج به مدیریت ضایعات غذایی ناشی از رفتار در دانشگاه‌ها

رویکرد	پژوهش	دانشگاه مورد مطالعه
بررسی حجم ضایعات مواد غذایی در وعده‌های ارائه شده به دانشجویان	گالاردو، ادوالکون، کارلوس و رناو (۲۰۱۶)	دانشگاه جامی - اسپانیا
	ازچیچک-دولیک‌اگلو و وار (۲۰۱۹)	دانشگاه چوکوروا - ترکیه
	عبدالعال، مک‌کی و مک‌کی (۲۰۱۹)	دانشگاهی در قطر
مطالعه روش‌های مدیریت پسماند در مواجهه با ضایعات مواد غذایی دانشگاهی	میو، هوروویتز، کیسی و جونز (۲۰۱۷)	دانشگاه کین - ایالات متحده
	گائو، تیان، وانگ، ونرستن و سان (۲۰۱۷)	دانشگاه شاندونگ - چین
	پنیسار (۲۰۲۰)	دانشگاه فلوریدای جنوبی - ایالات متحده
کشف دلایل و انگیزه‌های دانشجویان در تولید ضایعات غذای دانشگاهی	پینتر، تندلانا و کوآ (۲۰۱۶)	دانشگاه رودس - آفریقای جنوبی
	مک‌دونالد و همکاران (۲۰۱۷)	دانشگاه دالهاوزی - کانادا
	مریس، اسمیت، کئون و لوتزی (۲۰۱۷)	دانشگاه کیپ‌تاون - آفریقای جنوبی
سنجش تأثیر راهکارهای اجرایی برای جلوگیری از تولید ضایعات مواد غذایی توسط دانشجویان	وایتهر، شنکلین و برانون (۲۰۱۳)	دانشگاه‌هایی در ایالات متحده
	پینتو، دوستوس پینتو، ملو، کمپوس و کوردوویل (۲۰۱۸)	دانشگاه لیسبون - پرتغال
	لازل (۲۰۱۹)	دانشگاهی در انگلستان

با توجه به شکاف پژوهشی فوق و انگیزه کاهش هزینه و ریشه آن در ضایعات غذایی، مطالعه جاری با اتخاذ یک رویکرد نوآورانه، به بهینه‌سازی تعداد طبخ و تحویل وعده‌های غذایی مبتنی بر داده‌های رزرواسیون غذا می‌پردازد. در همین راستا و با توجه به اینکه تعیین مقدار دقیق ضایعات مواد غذایی نیازمند پیش‌بینی دقیق افراد سرویس‌گیرنده از سرویس غذایی است (پیرانی، عرفات و تامپسون<sup>۱</sup>، ۲۰۱۶)، طراحی یک مدل پیش‌بینی تقاضا مبتنی بر داده‌های رزرواسیون انجام گرفته است.

### شبکه‌های عصبی مصنوعی در پیش‌بینی تقاضا

پیش‌بینی تعداد کاربران در سیستم رزرو طی پژوهش‌های متعددی مورد بررسی قرار گرفته است (تسای، ۲۰۱۴). اغلب شیوه‌های پیش‌بینی پارامتری، شکلی کارکردی برای رابطه بین داده‌های مشاهده‌شده و عامل‌های مختلف فرض می‌کنند و سپس با استفاده از داده‌های قبلی پارامترهای این تابع را برآورد می‌کنند. در مقابل، شیوه‌های یادگیری ماشین، به‌ویژه شبکه‌های عصبی مصنوعی، پیش‌پیش‌تابعی را مفروض نمی‌دارند، بلکه از فعل‌وانفعالات در معماری شبکه برای تشخیص خودکار یک تابع زیرساختی استفاده می‌کنند که فرایند تقاضا را بهتر توضیح دهد. این رویکرد را پیش‌بینی ناپارامتری می‌نامند (تالوری و وان‌رایزن، ۱۳۹۴). در همین راستا، در مقالات و پژوهش‌های متعددی نشان داده شده است که مدل‌های کلاسیک پیش‌بینی نظیر سری‌های زمانی یا رگرسیون خطی نمی‌توانند رفتار مصرف‌کننده یا دسترسی به منابع را در یک زمان مشخص به‌خوبی پیش‌بینی کنند (آزاده، مارکوتی و ساوارد، ۲۰۱۴). دلایل رایج برای ضعف روش‌های کلاسیک در این موارد خلاصه می‌شود که ممکن است در این‌گونه از روش‌ها، فرم تابعی متغیرهای مستقل و وابسته در

صورت عدم شناخت به درستی تصریح نشود. از سوی دیگر، داده‌های پرت تخمین‌های نامناسبی از پارامترهای مدل را پدید می‌آورند. علاوه بر این محدودیت‌ها، بیشتر مدل‌های سری زمانی خطی هستند و در نتیجه رفتارهای غیرخطی را به خوبی توضیح نمی‌دهند (مروتی شریف‌آبادی و خوانچه‌مهر، ۱۳۹۳). این درحالی است که شبکه‌های عصبی یک ابزار مناسب برای تقریب غیرخطی و شرایط پیچیده محسوب می‌شوند (کاظمی و فاضلی راد، ۱۳۹۷)؛ لذا این شبکه‌ها به دلیل سازگاری با روندهای غیرخطی در داده‌های شهرت یافته‌اند (میریالا، سوبرامانین و میترا<sup>۱</sup>، ۲۰۱۸).

کاربرد شبکه‌های عصبی در پیش‌بینی تقاضا در صنایع و حوزه‌های مختلفی به چشم می‌خورد. پیش‌بینی تقاضای انرژی (مورالیتاران، سکنیول و ویشنوارتان<sup>۲</sup>، ۲۰۱۸)، پیش‌بینی تقاضا در صنعت گردشگری (لاو، لی، فونگ و هان<sup>۳</sup>، ۲۰۱۹)، پیش‌بینی تقاضای سفر (کی، ژنگ، یانگ و چن<sup>۴</sup>، ۲۰۱۷)، پیش‌بینی تقاضا در حمل‌ونقل ریلی (ژانگ، چی، چن، ما و هی<sup>۵</sup>، ۲۰۲۱)، پیش‌بینی ویزیت بیماران (یوسفی، یوسفی، فتحی و فولیگاتو<sup>۶</sup>، ۲۰۲۰)، پیش‌بینی تقاضای خودپرداز بانک‌ها (عربانی و کومله، ۲۰۱۹) و بسیاری از حوزه‌های دیگر از جمله کاربردهای شبکه‌های عصبی مصنوعی در پیش‌بینی تقاضا هستند.

از جمله معماری‌های پر استفاده شبکه عصبی مصنوعی که در حوزه‌های مختلف به کارگیری شبکه‌های عصبی بسیار رایج است، ساختار پیش‌خور<sup>۷</sup> است (چائو، گو و لی<sup>۸</sup>، ۲۰۲۰). این ساختار در حوزه پیش‌بینی و برآورد تقاضا در سامانه‌های پرتراکنش نیز رایج بوده و با تعداد لایه کم نیز به پاسخ‌های مناسب منجر شده است (امین‌ناصری و فرنام، ۱۳۹۱). به‌ویژه اینکه با در نظر گرفتن ریسک بیش‌برازش در یادگیری، معماری کم‌عمق شبکه‌های عصبی با یک لایه برای دیتاست‌های کوچک با تعداد داده کم مناسب‌تر از ساختارهای پیچیده‌تر شبکه عصبی به‌ویژه شبکه‌های عمیق است (پاسوپا و سونهم<sup>۹</sup>، ۲۰۱۶). مبنای یادگیری این شبکه‌ها، کاهش خطا مبتنی بر تابع خطا شبکه است (لولی و همکاران<sup>۱۰</sup>، ۲۰۱۷). با همه داده‌ها در پردازش طی تابع خطا به‌طور یکسان رفتار می‌شود درحالی‌که ماهیت داده‌ها یا جهت‌گیری آنها می‌تواند بر این تابع و ساختار آن تأثیر بگذارد (جونگ و کوان<sup>۱۱</sup>، ۲۰۱۳). در این پژوهش طی پیاده‌سازی مدل برآورد تقاضا، تلاش شده است که یادگیری شبکه به سمت انتظارات دانشجویی جهت‌دهی شود. از این روی، با استفاده از تغییر در تابع خطای شبکه و بهبود ساختار آن با الگوریتم جست‌وجوی الگو، این پژوهش به یک مدل کاربردی جدید در حوزه پیش‌بینی تقاضا با شبکه عصبی مصنوعی دست یافته است که می‌تواند مطابق سیاست‌های موردنظر، در یادگیری شبکه و تخمین تقاضا جهت‌دهی ایجاد کند. این جهت‌دهی به‌ویژه در شرایطی که مازاد یا کمبود مقدار پیش‌بینی نسبت به مقدار واقعی اهمیت پیدا می‌کند، مؤثر خواهد بود. کنترل این موضوع بر اساس اوزان تعریف‌شده و برپایه بهینه‌سازی با الگوریتم GPS این

1. Miriyala, Subramanian & Mitra
2. Muralitharan, Sakthivel & Vishnuvarthan
3. Law, Li, Fong & Han
4. Ke, Zheng, Yang & Chen
5. Zhang, Che, Chen, Ma & He
6. Fogliatto
7. Feedforward
8. Qiao, Guo & Li
9. Pasupa & Sunhem
10. Lolli et al.
11. Jung & Kwon

توانایی را حاصل کرد که با نگره‌داشتن خطای کل نزدیک به مقدار اولیه، تمایل تصمیم‌گیرندگان نیز لحاظ شده و یادگیری جهت‌دار شبکه عصبی این امر را اجرایی سازد.

## روش‌شناسی پژوهش

با توجه به ماهیت مسئله که از جنس برازش تلقی می‌شود، ساختارهای مختلفی برای به‌کارگیری شبکه‌های عصبی مصنوعی در قالب حل‌کننده مسائل تخمین تابع وجود دارد. در این پژوهش ساختار شبکه عصبی MLP<sup>۱</sup> مورد استفاده قرار گرفته است که با ساختارهای GRNN<sup>۲</sup> و RBF<sup>۳</sup> که همگی از جمله ساختارهای مناسب برای حل مسائل تخمین تابع هستند (یانگ، تینگ، من و گوان<sup>۴</sup>، ۲۰۱۳) نیز مقایسه شده تا بهترین ساختار ممکن در این پژوهش استخراج شود. به منظور تعیین ترکیب مناسبی از پارامترهای MLP مبتنی بر معماری پیش‌خور، پارامترها و عواملی نظیر تعداد لایه‌ها و گره‌ها، تغییر الگوریتم آموزش و توابع انتقال مختلف به عنوان مجموعه‌ای از ساختارهای ممکن برای حل مسئله در نظر گرفته می‌شوند. بهترین ساختار، بر اساس کمترین مقادیر شاخص خطا سنجیده می‌شود. در این پژوهش از دو شاخص انحراف جذر میانگین مربعات (RMSE) و میانگین نسبت خطای مطلق (AAEP) برای سنجش خطا استفاده شده است (میریالا، سوبرامانین و میترا، ۲۰۱۸؛ کاظمی، شکوری، منهج، مهرگان و نشاط، ۲۰۱۰) تا به طور همزمان خطای هم‌ارز داده‌ها و همچنین خطای نرمال شده برحسب نسبت مقدار واقعی سنجیده شوند:

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (\hat{x}_i - x_i)^2} \quad \text{رابطه (۱)}$$

$$AAEP = \frac{1}{N} \sum_{i=1}^N \left| \frac{\hat{x}_i - x_i}{x_i} \right| \quad \text{رابطه (۲)}$$

که در روابط فوق،  $x_i$  و  $\hat{x}_i$  به ترتیب نمایش‌دهنده مقدار واقعی و مقدار پیش‌بینی شده هستند.  $N$  تعداد کل نمونه‌ها را نشان می‌دهد و  $i$  نیز بیانگر نمونه  $i$  ام است.

با فرض داشتن  $T$  نمونه آموزشی در قالب  $\{(x_t, d_t), t = 1, \dots, T\}$  با  $x_t = (x_{t1}, x_{t2}, \dots, x_{tn}) \in R^n$  و  $d_t = (d_{t1}, d_{t2}, \dots, d_{tm}) \in \mathbb{R}^m$  که به ترتیب بردارهای ورودی و هدف شبکه را در یک یادگیری بانظارت نمایش می‌دهند، می‌توان به آموزش یک شبکه عصبی مصنوعی پرداخت. در این شبکه، بردار  $w_i = (w_{i1}, w_{i2}, \dots, w_{in})^T$  بردار وزن ورودی است که گره‌های ورودی را به گره پنهان  $i$  ام متصل می‌کند.  $\beta_i = (\beta_{i1}, \beta_{i2}, \dots, \beta_{im})^T$  نیز بردار وزن خروجی است که گره‌های پنهان را به گره‌های خروجی متصل می‌کند و  $b_i$  بایاس متناظر گره پنهان  $i$  ام است.

1. Multilayer Perceptron
2. Generalized Regression Neural Network
3. Radial Basis Function Neural Network
4. Yang, Ting, Man & Guan

به طور کلی و مجزا از معماری شبکه عصبی، دستیابی به حداقل خطا در تخمین نمونه‌ها معادل یافتن  $w_i$ ،  $\beta_i$  و  $b_i$  است که رابطه ۳ را کمینه سازد (لولی و همکاران، ۲۰۱۷؛ چائو، گو و لی، ۲۰۲۰):

$$\|Y_N(x_t) - d_t\|, t = 1, \dots, T \quad \text{رابطه ۳}$$

رابطه ۳ که به تابع هزینه یا تابع خطا مشهور است، توسط الگوریتم‌های آموزشی شبکه عصبی پردازش شده و با حداقل سازی آن، مقادیر وزن و بایاس مناسب یافت می‌شود. به طور معمول، تابع هزینه در قالب حداقل مربعات خطا مطابق رابطه ۴ سنجیده شده و مورد حداقل سازی قرار می‌گیرد (ژانگ، ۲۰۰۱):

$$MSE = \frac{1}{T} \sum_{t=1}^T [y_t - d_t]^2 \quad \text{رابطه ۴}$$

با توجه به ماهیت حساس خدمت‌رسانی به دانشجویان در امور دانشجویی دانشگاه‌ها، نیاز است که تابع هزینه متداول دستخوش تغییر گردد. ذات مسئله ایجاب می‌کند که خطاهایی که در اثر کوچک‌تر شدن مقدار پیش‌بینی از مقدار واقعی پیش می‌آید، بیشتر دیده شود زیرا کمبود در تأمین غذای دانشجویی به مراتب آثار مخرب‌تری بر عملکرد معاونت مربوطه و هویت اجرایی دانشگاه خواهد داشت نسبت به زمانی که غذا زیادتر طبخ شود و عملاً خطا ناشی از بزرگتر شدن مقدار پیش‌بینی از مقدار واقعی باشد. بنابراین تابع خطا در رابطه ۴ را می‌توان به یک تابع دو ضابطه‌ای به فرم زیر تغییر داد:

$$e_{tj} = \begin{cases} \alpha_1 [y_{tj} - d_{tj}]^2 & y_{tj} > d_{tj} \\ \alpha_2 [y_{tj} - d_{tj}]^2 & y_{tj} \leq d_{tj} \end{cases}, 0 \leq j \leq m \quad \text{رابطه ۵}$$

$$e_j = \frac{1}{T_w} \sum_{t=1}^T (e_{tj}) \quad \text{رابطه ۶}$$

در رابطه ۵،  $\alpha_1$  و  $\alpha_2$  به ترتیب وزن خطا در شرایط بزرگ‌بودن یا کوچک‌تر بودن مقدار پیش‌بینی نسبت به مقدار واقعی هستند.  $T_w$  دربردارنده  $\alpha_1$  و  $\alpha_2$  است که موجب می‌شود که خطای کل ( $e_j$ )، یک میانگین وزنی از خطاهای نمونه‌ها ( $e_{tj}$ ) باشد. با توجه به ماهیت سرویس‌دهی دانشجویی که پیش‌تر ذکر شد،  $\alpha_1 < \alpha_2$  شرطی است که با توجه به معیار حساسیت دانشگاه در رابطه ۵ لحاظ می‌گردد. بنابراین بردار خطای وزن‌دار به صورت رابطه ۷ بررسی خواهد شد:

$$e_t = (e_1, e_2, \dots, e_m)^T \quad \text{رابطه ۷}$$

با در نظر گرفتن رابطه‌های ۵ تا ۷، هدف حداقل سازی خطا در شبکه عصبی به حداقل سازی این تابع هزینه موزون تبدیل می‌شود. با توجه به دشوارتر شدن استفاده از روش‌های مبتنی بر گرادیان در بهینه‌سازی ساختار شبکه مبتنی بر تابع هزینه جدید، در این پژوهش بهره‌گیری از رویکردهای بهینه‌سازی تکاملی و بدون اطلاعات مشتق در دستور کار قرار

گرفته است. به همین منظور، به جهت بهینه‌سازی تابع هزینه موزون و یافتن وزن‌ها و بایاس‌های ساختار شبکه عصبی از روش جست‌وجوی الگوی تعمیم‌یافته (GPS)<sup>۱</sup> استفاده شده است. پس از ارائه یک پاسخ اولیه (بردار وزن‌ها و بایاس‌های شبکه) توسط شبکه عصبی مصنوعی تحت الگوریتم‌های متداول آموزش آن به الگوریتم جست‌وجوی الگو، بهبود تابع هدف طی تکرارهای روش GPS ادامه می‌یابد.

روش جست‌وجوی الگوی تعمیم‌یافته، طبقه‌ای از روش‌های جست‌وجوی مستقیم است که بدون نیاز به مشتق و برپایه جست‌وجوی مستقیم به فعالیت می‌پردازند. با یک حدس اولیه از پاسخ که در قالب بردار  $x'$  است  $\left( x' = \left( w_{i_1}, w_{i_2}, \dots, w_{i_n}, \beta_{i_1}, \beta_{i_2}, \dots, \beta_{i_m}, b_1, b_2, \dots, b_N, b_1^{\text{out}}, \dots, b_m^{\text{out}} \right)^T \right)$  و یک مقدار اولیه برای پارامتر کنترلی طول گام ( $\Delta, \Delta > 0$ )، دنباله‌ای از تکرارها  $\{x^k\}$  تولید می‌شود که در آن تابع هدف، افزایشی نخواهد بود:  $f(x^{k+1}) \leq f(x^k)$ . تمامی نقاطی که مقدار تابع هدف در آنها ارزیابی می‌شود در یک شبکه<sup>۲</sup> به نام  $M_k$  قرار می‌گیرند و الگوریتم مرحله نمونه‌برداری<sup>۳</sup> را طی می‌کند. در این مرحله تابع هدف  $f$  را با استفاده از تعداد محدودی نقطه آزمایشی در شبکه  $M_k$  ارزیابی می‌کنند تا یک نقطه بهبودیافته پیدا شود. این نقطه، پاسخی است که در آن مقدار تابع هدف از  $f(x^k)$  کمتر شود. سپس  $M_k$  به وسیله  $x^k$  مرکزیت یافته و با مجموعه متناهی  $D$  از جهت‌ها که  $\mathbb{R}^n$  را به‌طور مثبت پدید می‌آورد، تعریف شده و مقدار تابع هدف در الگوی زیر ارزیابی می‌شود (ایهم، مارسدن و پیتچ<sup>۴</sup>، ۲۰۰۸؛ بوگانی، گاسپرو و پاپینی<sup>۵</sup>، ۲۰۰۹):

$$P_k = \{x^k + \Delta_k d : d \in D_k\} \quad \text{رابطه ۸}$$

در رابطه ۸،  $D_k \subseteq D$  یک مجموعه مناسب از جهت‌های نمونه‌برداری است. اگر  $I$  ماتریس همانی و  $i$  بردار یک‌ها باشند، معمولاً  $D$  به صورت  $D = [I, -I]$  یا  $D = [I, -i]$  انتخاب می‌شود که به ترتیب متناظر  $2n$  و  $n+1$  بردار است (آدت و دنیس<sup>۶</sup>، ۲۰۰۰؛ کوشندرfer و ویلر<sup>۷</sup>، ۲۰۱۹). در صورتی که یک پاسخ بهبودیافته پیدا شود ( $\xi$ )، تکرار جدید  $\xi = x^{k+1}$  پذیرفته شده و اندازه گام با استفاده از رابطه ۹ به  $\Delta_{k+1}$  ( $\Delta_{k+1} \geq \Delta_k$ ) به‌روز می‌شود؛ در غیر این صورت،  $x^{k+1} = x^k$  در نظر گرفته شده و اندازه گام کاهش می‌یابد:

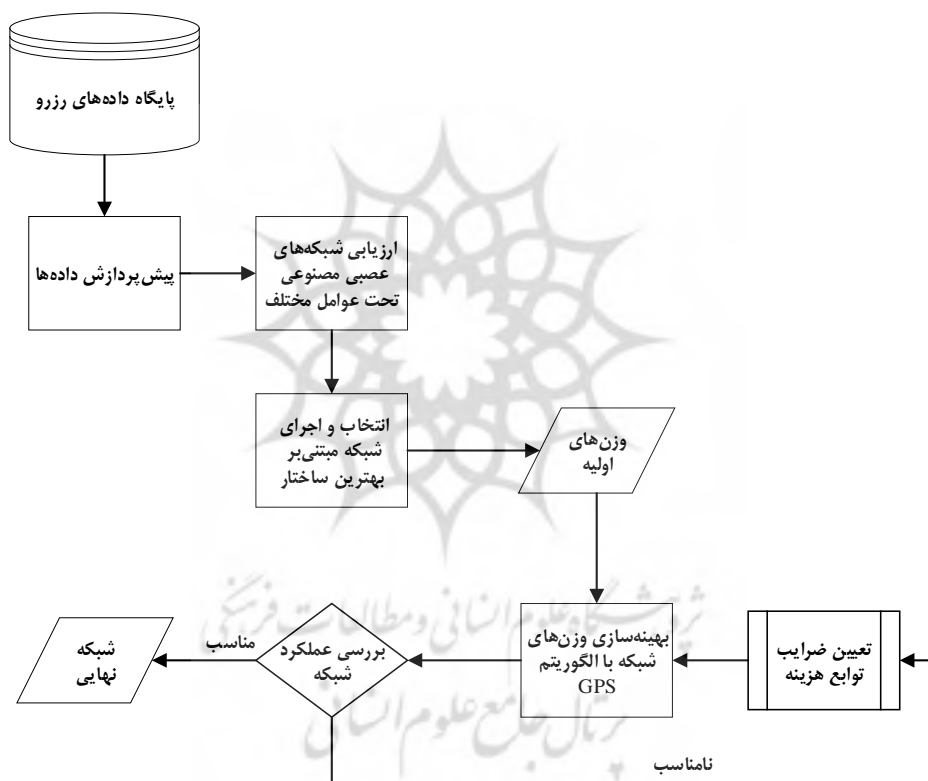
$$\Delta_{k+1} = \lambda_k \Delta_k \quad \text{رابطه ۹}$$

مقدار  $\lambda_k$  بر اساس  $\lambda_k \geq 1$  یا  $0 < \lambda_k < 1$  تعیین می‌شود که به ترتیب به شرایطی وابسته است که اندازه گام افزایشی یا کاهش‌ی باشد.

بر اساس شکل ۱ که روش اجرایی پژوهش را نمایش می‌دهد، شبکه عصبی مصنوعی پس از پیش‌پردازش داده‌ها با

1. Generalized Pattern Search (GPS)
2. Mesh
3. Poll step
4. Ihme, Marsden & Pitsch
5. Bogani, Gasparo & Papini
6. Audet & Dennis
7. Kochenderfer & Wheeler

فرض  $\alpha_1 = \alpha_p = 1$  آموزش می‌بیند. این آموزش با جایگشتی از انواع معماری‌ها و الگوریتم‌های آموزش پس‌انتشار انجام شده تا در نهایت بهترین ساختار برگزیده شود. در ادامه، با استفاده از شبکه عصبی منتخب، یک جواب اولیه مطلوب برای شروع بهینه‌سازی تابع هزینه جدید با الگوریتم GPS تولید شود. این بردار به‌عنوان یک پاسخ اولیه، الگوریتم GPS را به میزان قابل توجهی جلو می‌اندازد و باعث می‌شود که نقطه شروع الگوریتم از پاسخ موجه و مناسبی آغاز گردد. این جواب اولیه که شامل بردار وزن‌های لایه پنهان، وزن‌های لایه خروجی و بایاس‌های گره‌های دو لایه است، به الگوریتم GPS وارد شده و این الگوریتم با فرض  $\alpha_1 < \alpha_p$  اجرا می‌شود. مقادیر  $\alpha_1$  و  $\alpha_p$  ضرایب تابع هزینه را تشکیل داده و بر اساس آن خروجی GPS تولید می‌شود. تحلیل حساسیت و عملکرد بر اساس طیف‌های مختلف  $\alpha_1$  و  $\alpha_p$  در بخش بعدی این مقاله ارائه شده است.



شکل ۱. روش حل مبتنی بر مدل پژوهش

## یافته‌های پژوهش

داده‌های این پژوهش از پایگاه داده سیستم تغذیه یکی از دانشگاه‌های بزرگ شهر تهران استخراج شده است. بر اساس این داده‌ها که به بازه سال ۱۳۹۱ تا ۱۳۹۷ تعلق دارند، سالانه به طور متوسط بیش از ۴۸۰ هزار پرس غذا در وعده ناهار سلف مرکزی این دانشگاه رزرو می‌شود که ۵۶۱۲۳ پرس از آنها در وضعیت غذای مازاد قرار می‌گیرد و در صورت پخت توسط پیمانکار، دانشجویان برای دریافت آن حضور پیدا نمی‌کنند. با احتساب استاندارد وزن ۴۲۰ گرم برای هر پرس غذای دانشجویی، سالانه به طور متوسط پتانسیل تولید ۲۳۵۷۲ کیلوگرم غذای مازاد وجود دارد که می‌تواند به منجر به

ضایعات گسترده مواد غذایی شود. از سوی دیگر حتی به‌کارگیری روش‌هایی نظیر فروش غذای مازاد به صورت روزانه نیز اگرچه از پسماند غذایی جلوگیری می‌کند اما در نهایت منجر به هدررفت یارانه غذایی دانشجویی خواهد شد. بر اساس این داده‌ها، سهم مقاطع تحصیلی کارشناسی، کارشناسی ارشد و دکتری از کل رزرو سالیانه، به‌طور میانگین ۵۵، ۳۴ و ۱۱ درصد است. همچنین دانشجویان خوابگاهی به‌طور میانگین، ۷۶ درصد از رزرو غذا در هر سال را به خود اختصاص داده‌اند.

داده‌های مورد استفاده در این پژوهش، مربوط به روزهای خدمت‌دهی وعده نهار با دو غذا در سلف مرکزی این دانشگاه است که در مجموع شامل ۵۷۷ رکورد می‌شود. شاخص‌های مستخرج عبارت‌اند از: تاریخ، روز هفته، سطح قیمتی وعده، مجموع تعداد رزرو، تعداد رزرو به تفکیک مقطع تحصیلی، تعداد رزرو به تفکیک وضعیت اسکان، غذای مجاور. متغیر پاسخ یا پیش‌بینی‌شونده این پژوهش تعداد رزروهای حضور یافته است. منظور از این متغیر تعداد کاربرانی است که در سیستم رزرو کرده‌اند و برای دریافت خدمت حضور می‌یابند. با توجه به ماهیت دو غذایی سیستم رزرو، هر دانشجو می‌تواند در یکی از غذاهای پیشنهادی اقدام به رزرو کند. از این روی، به غیر از شاخص تاریخ و روز هفته، مابقی شاخص‌ها برای هر یک از غذاها به‌طور جداگانه دارای مقدار هستند.

در گام نخست پیاده‌سازی، نمونه‌های مربوط به سیستم رزرواسیون دانشگاهی برای وعده نهار، تحت شاخص‌های، تعداد رزرو کل (یک شاخص با مقدار عدد صحیح) روز هفته (در قالب پنج شاخص صفر - یک)، نوع غذا (در قالب سه شاخص صفر - یک)، تعداد رزرو به تفکیک مقطع تحصیلی (در قالب سه شاخص با مقدار عدد صحیح برای سه مقطع) و تعداد رزرو به تفکیک وضعیت اسکان (در قالب صفر - یک برای دو حالت خوابگاهی یا غیرخوابگاهی بودن) ساختاردهی شدند. شاخص‌های صفر - یک بر اساس کدگذاری one-hot در کنار سایر متغیرها در نظر گرفته شده است (یانگ و وانگ<sup>۱</sup>، ۲۰۱۹). با توجه به اینکه در هر رکورد (روز) دو غذا وجود دارد، شاخص‌های رزرو کل، نوع غذا، تعداد رزرو به تفکیک مقطع تحصیلی و تعداد رزرو به تفکیک وضعیت اسکان برای هر غذا مجزا بوده و لذا دو بار مقداردهی می‌شوند. از این روی، مقادیر هر رکورد ورودی، طی ۲۳ ویژگی بیان می‌شود. به این ترتیب، ساختار داده‌های ورودی/خروجی، در قالب ۲۳ شاخص ورودی و ۲ شاخص خروجی است که شاخص‌های خروجی تعداد تقاضاهای واقعی (حضور یافته) برای غذای نوع یک و دو را نشان می‌دهند.

به دنبال پیش‌پردازش داده‌ها شامل حذف نویزها و داده‌های پرت، در مجموع ۵۷۷ نمونه‌ها برای یادگیری شبکه عصبی وجود دارد. پس از نرمالایز کردن، بر اساس یک نسبت مورد قبول (باقری، نظری و سنجایان<sup>۲</sup>، ۲۰۱۹)، به‌طور مستقیم ۷۰ درصد از نمونه‌ها برای آموزش شبکه عصبی مورد استفاده قرار گرفت. نمونه‌های مورد استفاده در فرایند اعتبارسنجی و آزمون شبکه نیز هر یک ۱۵ درصد از رکوردها را به خود اختصاص دادند.

پیاده‌سازی بخش اول مدل مبتنی بر آموزش شبکه عصبی مورد نظر بر پایه ترکیبی از پارامترهای مختلف است. در این گام، گستره‌ای از شبکه‌های MLP با جایگشت ساختارهای زیر در نظر گرفته می‌شود.

1. Yang & Wang

2. Bagheri, Nazari & Sanjayan

جدول ۳. عوامل مختلف در ارزیابی ساختار شبکه عصبی

عامل	تعداد لایه پنهان	تعداد گره در هر لایه	تابع انتقال	الگوریتم آموزش
حالت‌ها	۱ و ۲	۵، ۱۰، ۱۵، ۲۰، ۲۵	تابع Tanh تابع ReLU	لورنبرگ - مارکوات (LM) گرادیان مزدوج (SCG) منظم‌سازی بیزی (BR)

به دنبال آموزش انواع شبکه‌ها مبتنی بر ساختارهای حاصل از جدول ۳، مناسب‌ترین معماری شبکه بر اساس توابع خطای رابطه ۱ و ۲ به یک شبکه عصبی یک لایه با ۵ نرون در لایه پنهان و تابع انتقال تانژانت هیپربولیک (Tanh) طی الگوریتم آموزش پس‌انتشار منظم‌سازی بیزی (BR) انجامید. مقادیر RMSE و AAEP برای داده‌های آزمون خروجی اول و دوم به ترتیب ۲۷/۷۲ و ۳۳/۸۳ است. همچنین مقدار شاخص AAEP نیز به ترتیب برابر با ۰/۰۱۹۸ و ۰/۰۲۳۰ حاصل شده است. بر این اساس، فرایند یادگیری شبکه منتخب، طی ۱۶۸ تکرار با رسیدن به آستانه پارامتر مارکوات ( $10^{-1}$ ) متوقف شده و بر پایه کمترین مقدار RMSE در تکرار ۶۶ به یک شبکه عصبی آموزش‌دیده دست یافته شده است.


شبکه به‌دست آمده تحت آموزش BR، با دو شبکه GRNN و RBF نیز مقایسه شد. شاخص AAEP برای شبکه GRNN بر روی داده‌های آزمون در خروجی اول و دوم به ترتیب ۰/۰۶۴۷ و ۰/۰۵۹۷ شده است. همین مقادیر برای RBF برابر با ۱/۸۵ و ۰/۷۱ حاصل شده که هر دو بر کیفیت بالاتر شبکه منتخب مبتنی بر یادگیری BR با پنج لایه صحنه می‌گذارند.

بردار وزنی که در این گام ایجاد شده است، به‌عنوان یکی از ورودی‌های الگوریتم جست‌وجوی الگوی تعمیم‌یافته (GPS) مورد استفاده قرار می‌گیرد. ساختار شبکه عصبی مورد استفاده در این الگوریتم مشابه ساختار گام قبلی است و تنها تفاوت آن تابع هزینه شبکه (تابع خطا) است که مطابق رابطه ۵ وزن‌دار شده است. با توجه به ماهیت حساس بهینه‌سازی در این مرحله و نیز جهت‌دهی‌ای که به درک شبکه عصبی از تابع هدف داده می‌شود، در تعیین وزن‌های تابع هزینه باید حساسیت قابل توجهی را لحاظ کرد. از همین روی، گستره‌ای از وزن‌ها برای این مرحله در نظر گرفته شده و منطبق با آنها، الگوریتم GPS تلاش کرده است که با در نظر گرفتن پاسخ اولیه حاصل از گام پیش، نقطه نزدیک به بهینه را بیابد. در اینجا، تنظیمات پایه الگوریتم GPS، بر اساس تولید  $2n$  نقطه محتمل در شبکه طی هر تکرار (یعنی جهت‌های موردنظر به صورت  $D = [I, -I]$  هستند) و نیز سقف ۲۰۰ تکرار طی کل فرایند اجرا پیاده‌سازی شده است. مقدار اولیه طول گام برابر با ۱ در نظر گرفته شده و در صورت افزایش طول گام از  $\lambda_k = 2$  و در صورت کاهش طول گام از  $\frac{1}{p}$  استفاده شده است. همچنین، ۱۵ درصد از نمونه‌ها که مجموعه داده‌های اعتبارسنجی را تشکیل می‌دهند، در هر تکرار GPS وظیفه بررسی عملکرد یادگیری را دارند و در صورت افزایش خطا روی نمونه‌های اعتبارسنجی طی ۱۰ تکرار، الگوریتم GPS متوقف می‌شود.

در تمامی آزمایش‌ها، وزن‌های تابع هزینه بر اساس رابطه ۵ به صورت زوج  $(\alpha_1 = 1, \alpha_p = \omega)$  در نظر گرفته




شده است که  $\omega$  اعداد صحیح در بازه  $[1, 20]$  بوده و لذا حالت مورد بررسی از زوج  $(\alpha_1 = 1, \alpha_2 = 1)$  تا  $(\alpha_1 = 20, \alpha_2 = 1)$  ادامه می‌یابد. حالت نخست نیز همان شبکه عصبی حاصل از یادگیری BR است. شکل ۲ نمایش دهنده عملکرد شبکه‌های عصبی حاصل از GPS بر روی داده‌های آزمون است. محور عمودی، مقدار شاخص خطای AAEP را نشان می‌دهد که به ازای مقادیر مختلف  $\omega$  طی ۲۰۰ تکرار الگوریتم GPS ارائه شده است.



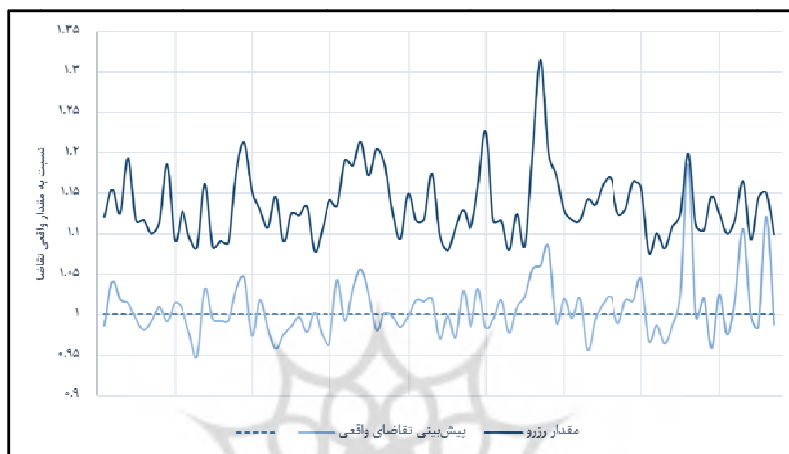
شکل ۲. عملکرد شبکه عصبی MLP پس از آموزش با الگوریتم GPS روی داده‌های آزمون

با توجه به خروجی GPS، رفتار همگرایی خطا برای هر دو نوع غذا در مقدار  $\omega = 2$  ظاهر شده است. اگرچه مقدار حداقل خطا برای غذای نوع یک در وزن برابر با ۱ رخ داده است، اما اگر هر دو روند را همزمان مورد توجه قرار دهیم، در  $\omega = 2$  کمترین مقدار متوسط خطا در داده‌های آزمون مشاهده می‌شود. بنابراین می‌توانیم نسبت ۲ به ۱ را برای وزن  $\alpha_1$  به  $\alpha_2$  در نظر بگیریم. عملکرد الگوریتم بهینه‌سازی GPS در این حالت در شکل ۳ ارائه شده است. همان‌طور که مشخص است روند مجموعه داده‌های آزمون و مجموعه داده‌های آموزش شبیه به یکدیگر و تقریباً در طول مسیر یادگیری به صورت نزولی است. همان‌طور که در شکل مشخص شده است، شرط توقف مبتنی بر داده‌های اعتبارسنجی طی ۱۰ تکرار نامطلوب پیاپی، در تکرار ۲۷ رخ داده که وقوع بیش‌برازش را کم‌رنگ کرده است.

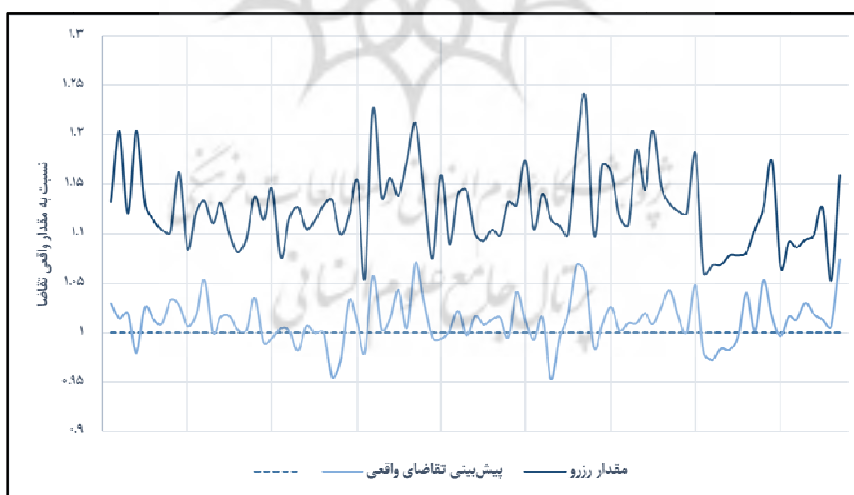


شکل ۳. روند بهبود تابع هزینه موزون طی تکرارهای متوالی الگوریتم GPS

شکل ۴ خروجی حاصل از شبکه عصبی مبتنی بر الگوریتم GPS را با توجه به تابع هزینه موزون نسبت به مقدار واقعی تقاضا نمایش می‌دهد. محور افقی شامل داده‌های آزمون است که مبنای تست شبکه بوده و محور عمودی نسبت مقدار موردنظر (رزرو شده یا پیش‌بینی شده) به مقدار واقعی را نشان می‌دهد. اگر این مقدار بالاتر از خط ۱ باشد، یعنی حساسیت تصمیم‌گیری ارضا شده و مقدار پیش‌بینی بیشتر از مقدار واقعی است اما اگر این مقدار کمتر از ۱ قرار گیرد یعنی مقدار پیش‌بینی شده کمتر از واقعی برآورد شده است. شکل ۵ نیز همین مورد را برای غذای نوع دو نمایش می‌دهد.



شکل ۴. پیش‌بینی تقاضای واقعی در مقایسه با مقدار رزرو برای غذای نوع یک



شکل ۵. پیش‌بینی تقاضای واقعی در مقایسه با مقدار رزرو برای غذای نوع دو


بر اساس آنچه از شکل‌های ۴ و ۵ مشخص است، پیش‌بینی تقاضا مبتنی بر تابع خطای موزون، علاوه بر اینکه از تأثیر مقدار رزرو مازاد اجتناب کرده است، تلاش کرده تا با بالاتر از خط ۱ قرار گیرد تا جهت‌گیری پیش‌بینی به سمت انتظارات دانشگاه را نیز برآورده سازد. این مورد، در شکل ۵ بیشتر مشهود است. در صورتی که وزن افزایش یابد، متوسط

نسبت پیش‌بینی تقاضا به مقدار واقعی آن بیشتر خواهد شد. این مورد در جدول ۴ به تفکیک وزن‌ها مبتنی بر داده‌های آزمون ارائه شده و شکل ۶ نیز روند کلی این افزایش را نمایش می‌دهد.


جدول ۴. مقدار شاخص AAEP و متوسط نسبت پیش‌بینی به تقاضای واقعی در هریک از اوزان تابع خطا

متوسط نسبت پیش‌بینی تقاضا به تقاضای واقعی غذای دو	متوسط نسبت پیش‌بینی تقاضا به تقاضای واقعی غذای یک	AAEP غذای دو	AAEP غذای یک	$\alpha_p$
۱/۰۰۶۹	۱/۰۰۳۳	۰/۰۲۱	۰/۰۲۴	۱
۱/۰۱۲۵	۱/۰۰۷۵	۰/۰۲۰	۰/۰۲۵	۲
۱/۰۱۱۰	۱/۰۰۰۸	۰/۰۲۱	۰/۰۲۵	۳
۱/۰۱۲۶	۱/۰۱۱۸	۰/۰۲۲	۰/۰۲۸	۴
۱/۰۰۹۴	۱/۰۰۷۴	۰/۰۲۳	۰/۰۲۷	۵
۱/۰۱۰۴	۱/۰۱۸۵	۰/۰۲۳	۰/۰۳۲	۶
۱/۰۱۲۳	۱/۰۱۶۵	۰/۰۲۳	۰/۰۳۳	۷
۱/۰۱۱۳	۱/۰۱۲۲	۰/۰۲۷	۰/۰۲۷	۸
۱/۰۱۵۷	۱/۰۱۶۱	۰/۰۲۴	۰/۰۲۷	۹
۱/۰۱۰۲	۱/۰۱۳۰	۰/۰۲۵	۰/۰۲۶	۱۰
۱/۰۱۵۰	۱/۰۱۸۹	۰/۰۲۹	۰/۰۲۹	۱۱
۱/۰۱۶۸	۱/۰۱۵۳	۰/۰۳۱	۰/۰۳۱	۱۲
۱/۰۱۵۲	۱/۰۱۰۲	۰/۰۲۵	۰/۰۲۷	۱۳
۱/۰۱۴۲	۱/۰۲۴۲	۰/۰۲۹	۰/۰۳۴	۱۴
۱/۰۱۶۶	۱/۰۰۸۱	۰/۰۲۸	۰/۰۲۹	۱۵
۱/۰۲۶۱	۱/۰۲۰۵	۰/۰۳۱	۰/۰۳۳	۱۶
۱/۰۱۷۹	۱/۰۱۰۱	۰/۰۲۶	۰/۰۲۷	۱۷
۱/۰۱۰۶	۱/۰۰۸۴	۰/۰۲۷	۰/۰۲۷	۱۸
۱/۰۱۴۶	۱/۰۱۸۵	۰/۰۲۶	۰/۰۳۱	۱۹
۱/۰۱۳۰	۱/۰۲۱۰	۰/۰۲۸	۰/۰۳۳	۲۰

بنابراین، با افزایش مقدار وزن  $\alpha_p$  در تابع خطای موزون، انتظار یک روند افزایشی برای نسبت مقدار پیش‌بینی تقاضا نسبت به مقدار تقاضای واقعی وجود دارد که طبیعی است؛ زیرا فلسفه به‌کارگیری چنین تابع خطایی نیز جهت‌گیری شبکه به سمت کاهش احتمال کمبود غذا بود. بنابراین با رعایت تصمیم‌گیری و نظر خبرگان مورد مطالعه می‌توان به سطح افزایش موردنظر دست یافت. سقف وزن جایی است که به نسبت رزرو می‌رسد و عملاً بالاتر از آن بی‌معنا خواهد بود.



ب) غذای نوع دو



الف) غذای نوع یک

شکل ۶. متوسط نسبت پیش‌بینی تقاضا به تقاضای واقعی بر روی داده‌های آزمون

## بحث

شکل ۴ و ۵ که نتیجه پیش‌بینی مبتنی بر مدل ارائه شده را در مقایسه با مقدار رزرو شده به ترتیب برای غذای نوع یک و نوع دو نشان می‌دهند، شکاف بین مقدار واقعی تقاضا و مقدار رزرو انجام شده را نمایش می‌دهند. در این دو شکل، مقادیر نسبت به مقدار واقعی تقاضا تعدیل شده و از این روی، نسبت آنها به مقدار واقعی تقاضا نیز قابل مشاهده است. بر اساس داده‌های آزمون این مطالعه، غذای نوع یک و دو به ترتیب به طور متوسط دارای ۱۳۰ و ۱۵۷ پرس مازاد هستند که این رزرو مازاد، بین ۱۱ تا ۱۲ درصد رزرواسیون را تشکیل داده است. بنابراین در صورت طبخ غذا بر پایه این آمار رزرو، روزانه به طور متوسط ۲۸۷ پرس (تقریباً ۱۲۰ کیلوگرم) مازاد طبخ وجود خواهد داشت که یا به پسماند مواد غذایی تبدیل می‌شود و یا در قالب‌های دیگری توزیع می‌شود که بازهم با یارانه دولتی سازگار نیست. این در شرایطی است که مدل پیشنهادی پژوهش برای غذای نوع یک و دو تقریباً به طور میانگین ۲۲ و ۲۵ پرس غذا از مقدار واقعی انحراف دارد. حتی اگر این میانگین انحراف مثبت باشد، باز هم روزانه به طور متوسط کمتر از ۵۰ پرس غذا نسبت به تقاضای واقعی انحراف خواهیم داشت که اختلاف قابل توجهی با شرایط کنونی دارد. این شکاف بین تعداد تقاضای رزرو شده و تعداد تقاضای واقعی، منشأ اسراف منابع عمومی یارانه تخصیص داده شده و نیز تولید ضایعات یا پسماند مواد غذایی حاصل از آن است. این کاهش به میزان قابل توجهی از دورریز غذای طبخ شده به دلیل وجود تقاضای حضور نیافته جلوگیری می‌کند و طبخ به میزان واقعی خود نزدیک می‌گردد. از سوی دیگر، از جنبه تخصیص هزینه‌های دولتی - بر اساس آنچه در مقدمه این پژوهش ذکر شده است - هزینه یارانه‌ی توزیعی از سوی دولت و دانشگاه به همین میزان کاهش یافته و منابع عمومی که به این امر اختصاص داده شده دچار هدررفت نمی‌شود.

## نتیجه‌گیری و پیشنهادها

در این پژوهش تلاش شد تا برای اولین بار، یک روش تخمین تقاضای واقعی در سیستم‌های رزرو و توزیع دانشگاهی پیشنهاد شود. بر اساس پیشینه این پژوهش، برخی اجزای مدل پیشنهادی همچون استفاده مستقیم از داده‌های رزرواسیون برای پیش‌بینی تقاضای واقعی در موعد توزیع خدمت غذای دانشگاهی برای نخستین بار در نظر گرفته شده است. همچنین انگیزه این پژوهش که کاهش ضایعات مواد غذایی و به‌دنبال آن، کاهش بار مالی برای دولت در زمینه تأمین سوبسید غذای دانشجویی است، یک محور جدید برای نگاه به مسائل کنترل ضایعات مواد غذایی ناشی از رفتار دانشجویان در سلف‌های دانشگاهی است که کمتر مورد توجه پژوهش‌های پیشین واقع شده بود.

برای طراحی سازوکار پیشنهادی، از شبکه عصبی مصنوعی به‌عنوان برآوردگر تقاضای واقعی استفاده شد. طی این کار، تابع خطای شبکه از حالت عادی به یک تابع خطای موزون تغییر پیدا کرد تا نسبت به خطاهای حاصل از کمتر شدن تقاضای پیش‌بینی‌شده از تقاضای واقعی، واکنش شدیدتری نشان دهد. این جهت‌گیری در یادگیری به دلیل حساسیت اکوسیستم دانشجویی و مدیریت امور دانشجویی در حوزه تغذیه است تا دانشجویانی که غذای رزرو کرده داشته‌اند کمتر دچار چالش فقدان غذا شوند.

اگرچه پژوهش‌هایی مانند پینتر، تندلانا و کوآ (۲۰۱۶) تلاش کرده‌اند که دلایل عدم حضور دانشجویان پس از رزرواسیون غذا را بیابند، اما طراحی یک سازوکار مبتنی بر یادگیری ماشین که بتواند تخمین صحیحی از تقاضای واقعی مبتنی بر داده‌های رزرواسیون داشته باشد، در پیشینه پژوهش یافت نمی‌شود. با اجرای مدل پیشنهادی شامل شبکه عصبی اولیه، طراحی تابع خطا و اجرای الگوریتم GPS برای آموزش شبکه نهایی، سازوکار حاضر قابلیت کاهش شکاف بین میزان واقعی تقاضا و تقاضای رزروشده که به واقعی‌سازی میزان تولید غذا (طبخ غذا) می‌انجامد را یافت. این دستاورد، موجب کاهش حجم ضایعات ناشی از طبخ بیش از اندازه و همچنین هدررفت یارانه دولتی می‌شود. با پیاده‌سازی مدل پیشنهادی این پژوهش، یک رویکرد پیش‌گیرانه اتخاذ می‌شود که در پژوهش‌های پیشین کمتر یافت شده است. درحالی که بسیاری از دانشگاه‌های جهان از سیستم‌های رزرواسیون بهره می‌برند، اما فقدان پژوهشی که چنین سازوکاری را برای پیش‌بینی تعداد واقعی تقاضا مبتنی بر رزرواسیون و مبتنی بر سرویس دهی پیشنهاد دهد، وجود داشت. مطابق پژوهش جاری، با استفاده از داده‌های این سیستم و دخیل کردن شاخص‌های تأثیرگذار به این رویکرد پیش‌گیرانه رسید. در مقایسه با مطالعاتی مبتنی بر بررسی رویکردهای تولید و کنترل ضایعات مواد غذایی در دانشگاه‌ها بوده‌اند (جدول ۲)، اتخاذ رویکرد این پژوهش پیش‌گیرانه و فعال به نظر می‌رسد چراکه پژوهش حاضر توانسته است با یک رویکرد کنترلی، حجم تولید بیش‌ازحد را کاهش دهد و به تقاضای واقعی نزدیک کند.

به‌عنوان مسیر پیشنهادی برای ادامه این پژوهش، می‌توان رخداد تولید کمتر از حد را مدیریت نمود. همان‌طور که در شکل ۱۱ و ۱۲ مشخص است، کاهش فاصله بین تقاضای رزروشده و تقاضای واقعی گاهی به تولید کمتر از حد نیز می‌انجامد. اگرچه طی به‌کارگیری تابع خطای وزن‌دار در شبکه عصبی تلاش شده است که این رخداد خطای بیشتری تولید کند اما در خروجی نهایی اجتناب‌ناپذیر است. از این روی، پیشنهاد می‌شود با در نظر گرفتن یک تابع هزینه برای این شرایط یا تعریف حد آستانه برای کاهش بیش از تقاضای واقعی، این موضوع مورد توجه واقع شود. علاوه‌براین، می‌توان

به جای شبکه عصبی مصنوعی، الگوریتم‌های دیگری را به عنوان الگوریتم برآزش انتخاب کرده و تابع خطای موزون مناسب آن را سنجید. پیشنهاد اخیر می‌تواند نوسان و واریانس خطا بین خروجی شبکه عصبی و دیگر روش‌ها را تحلیل کند تا در مواجهه با عدم قطعیت ذاتی این مسئله، حجم انحراف‌ها کمتر شود.

از سوی دیگر، طراحی یک سازوکار منسجم برای تصمیم‌سازی پیرامون سطح وزن‌دهی موردنظر می‌تواند تکمیل‌کننده مدل ترکیبی پیشنهادی باشد. تصمیم‌گیری در این پژوهش بر اساس کمترین میزان خطا واقع شده است، درحالی که ممکن است روند خطا صعودی باشد. از این روی، می‌توان معیار جانبی دیگری برای ایجاد تبادل بین خطا و افزایش سطح پیش‌بینی نسبت به مقدار واقعی تعریف کرد؛ در غیر این صورت، همواره مدل بدون وزن برگزیده می‌شود زیرا محدودیتی در تابع هدف ندارد.

## منابع

- امین ناصری، محمدرضا؛ بهنام، فرنام (۱۳۹۱). پیش‌بینی تقاضای سفر ریلی در مسیر تهران-مشهد. *پژوهشنامه حمل و نقل*، ۱۹(۱)، ۱۵-۲۸.
- سیفی، زهرا (۱۳۹۹). نرخ مصوب قیمت غذای دانشجویی به دانشگاه‌ها ابلاغ شد. *خبرگزاری مهر*. ۲۶ شهریور. دسترسی در آدرس: <https://www.mehrnews.com/news/5024681>
- قانون برنامه پنج‌ساله ششم توسعه اقتصادی، اجتماعی و فرهنگی جمهوری اسلامی ایران (۱۳۹۶). دسترسی در آدرس: <https://rc.majlis.ir/fa/law/show/1014547>
- کاظمی، مصطفی؛ فاضلی راد، محمدعلی (۱۳۹۷). پیش‌بینی کارایی به کمک تأثیرپذیری غیرخطی از تأخیرهای زمانی در تحلیل پوششی داده‌ها با شبکه‌های عصبی مصنوعی. *مدیریت صنعتی*، ۱۰(۱)، ۱۷-۳۴.
- مردانه، الهام؛ اکبری جوکار، محمدرضا (۱۳۸۵). توسعه و به‌کارگیری تکنیک مدیریت درآمد در سیستم‌های تولید انبارشی. *مهندسی صنایع و مدیریت*، ۳۲(۳۴)، ۸۷-۹۶.
- هزینه نهار و شام دانشجویی هزار میلیارد تومان! (۱۳۹۸، ۱ مرداد). *روزنامه شهروند*، ص ۱۲.

## References

- Abdelaal, A. H., McKay, G., & Mackey, H. R. (2019). Food waste from a university campus in the Middle East: Drivers, composition, and resource recovery potential. *Waste Management*, 98, 14-20.
- Ali, A. Y., Hassen, J. M., & Wendem, G. G. (2019). Forecasting as a framework for reducing food waste in Ethiopian university canteens. *Journal of Applied Research on Industrial Engineering*, 6(4), 374-380.
- Alooh, A. O. (2015). *Quantifying food plate waste: case study of a university dining facility*. Doctoral dissertation, Stellenbosch: Stellenbosch University.
- Amin-Nasari, M. & Behnam, F. (2012) Forecastin the Travel Demand for Tehran-Mashhad Rail Route. *Journal of Transportation Research*, 9(1), 15-28. (in Persian)

- Arabani, S. P., & Komleh, H. E. (2019). The improvement of forecasting ATMS cash demand of Iran banking network using convolutional neural network. *Arabian Journal for Science and Engineering*, 44(4), 3733-3743.
- Audet, C., & Dennis, Jr., J. E. (2000). Pattern search algorithms for mixed variable programming. *SIAM Journal on Optimization*, 11(3), 573-594.
- Azadeh, S. S., Marcotte, P., & Savard, G. (2014). A taxonomy of demand uncensoring methods in revenue management. *Journal of Revenue and Pricing Management*, 13(6), 440-456.
- Azadeh, S. S., Marcotte, P., & Savard, G. (2015). A non-parametric approach to demand forecasting in revenue management. *Computers & Operations Research*, 63, 23-31.
- Bagheri, A., Nazari, A., & Sanjayan, J. (2019). The use of machine learning in boron-based geopolymers: Function approximation of compressive strength by ANN and GP. *Measurement*, 141, 241-249.
- Blecher, L., & Yeh, R. J. (2008). Forecasting meal participation in university residential dining facilities. *Journal of Foodservice Business Research*, 11(4), 352-362.
- Bogani, C., Gasparo, M. G. & Papini, A. (2009). Generalized Pattern Search methods for a class of nonsmooth optimization problems with structure. *Journal of Computational and Applied Mathematics*, 229(1), 283-293.
- Çetinkaya, Z., & Erdal, E. (2019, September). Daily Food Demand Forecast with Artificial Neural Networks: Kirikkale University Case. In *2019 4th International Conference on Computer Science and Engineering (UBMK)* (pp. 1-6). IEEE.
- Gallardo, A., Edo-Alcón, N., Carlos, M., & Renau, M. (2016). The determination of waste generation and composition as an essential tool to improve the waste management plan of a university. *Waste management*, 53, 3-11.
- Gao, A., Tian, Z., Wang, Z., Wennersten, R., & Sun, Q. (2017). Comparison between the technologies for food waste treatment. *Energy Procedia*, 105, 3915-3921.
- Gregorash, B. J. (2016). Restaurant revenue management: apply reservation management. *Information Technology & Tourism*, 16(4), 331-346.
- Hillier, F. S. & Lieberman, G. J. (2015). *Introduction to Operations Research*. 10<sup>th</sup> Edition. New York: McGraw-Hill Education.
- Hine, J., & Grieco, M. (2003). Scatters and clusters in time and space: implications for delivering integrated and inclusive transport. *Transport Policy*, 10(4), 299-306.
- Ihme, M., Marsden, A. L. & Pitsch, H. (2008). Generation of Optimal Artificial Neural Networks Using a Pattern Search Algorithm: Application to Approximation of Chemical Systems. *Neural Computation*, 20, 573-601.
- Jung, S., & Kwon, S. D. (2013). Weighted error functions in artificial neural networks for improved wind energy potential estimation. *Applied energy*, 111, 778-790.
- Kazemi, A., Shakouri, H. G., Menhaj, M. B., Mehregan, M. R., & Neshat, N. (2010). A hierarchical artificial neural network for transport energy demand forecast: Iran case study. *Neural Network World*, 20(6), 761-772.

- Kazemi, M. & Faezirad, M. (2018). Efficiency Estimation using Nonlinear Influences of Time Lags in DEA Using Artificial Neural Networks. *Industrial Management Journal*, 10(1), 17-34.
- Ke, J., Zheng, H., Yang, H., & Chen, X. (2017). Short-term forecasting of passenger demand under on-demand ride services: A spatio-temporal deep learning approach. *Transportation Research Part C: Emerging Technologies*, 85, 591-608.
- Kılıç, G. (2015). *Yapay Sinir Ağları ile Yemekhane Günlük Talep Tahmini*. Master's thesis, Pamukkale Üniversitesi Fen Bilimleri Enstitüsü.
- Kochenderfer, M. J., & Wheeler, T. A. (2019). *Algorithms for optimization*. Cambridge, MA: The MIT Press.
- Law, R., Li, G., Fong, D. K. C., & Han, X. (2019). Tourism demand forecasting: A deep learning approach. *Annals of Tourism Research*, 75, 410-423.
- Lazell, J. (2016). Consumer food waste behaviour in universities: Sharing as a means of prevention. *Journal of Consumer Behaviour*, 15(5), 430-439.
- Lemke, C., Riedel, S., & Gabrys, B. (2013). Evolving forecast combination structures for airline revenue management. *Journal of Revenue and Pricing Management*, 12(3), 221-234.
- Liu, W., Yang, H., & Yin, Y. (2015). Efficiency of a highway use reservation system for morning commute. *Transportation Research Part C: Emerging Technologies*, 56, 293-308.
- Lolli, F., Gamberini, R., Regattieri, A., Balugani, E., Gatos, T., & Gucci, S. (2017). Single-hidden layer neural networks for forecasting intermittent demand. *International Journal Of Production Economics*, 183, 116-128.
- Lowe, D. (2013). Integrating Reservations and Queuing in Remote Laboratory Scheduling. *IEEE Transactions on Learning Technologies*, 6(1), 73-84.
- MacDonald, L., Rotteveel, L., Selim-Omar, J., Brown, N., Qin, S., & Allen, S. (2017). *Food wasting attitudes and behaviours among residence meal hall users at Dalhousie University*, Halifax, Nova Scotia.
- Managing food waste in the NHS. (2005). *Nutrition & Food Science*, 35(5). <https://doi.org/10.1108/nfs.2005.01735eab.010>.
- Marais, M. L., Smit, Y., Koen, N., & Lötze, E. (2017). Are the attitudes and practices of foodservice managers, catering personnel and students contributing to excessive food wastage at Stellenbosch University? *South African Journal of Clinical Nutrition*, 30(3).
- Mardane, A., Akbari Jokar, M. (2006). Revenue Management in Make to Stock Manufacturing Systems. *Sharif Journal of Industrial Engineering & Management*, 22(34), 87-96. (in Persian)
- Miriyala, S. S., Subramanian, V., & Mitra, K. (2018). TRANSFORM-ANN for online optimization of complex industrial processes: Casting process as case study. *European Journal of Operational Research*, 264(1), 294-309.
- MIT University. (2020, July 07). *Further decisions about the fall semester*. Retrieved from <https://president.mit.edu/speeches-writing/further-decisions-about-fall-semester>.



- Mu, D., Horowitz, N., Casey, M., & Jones, K. (2017). Environmental and economic analysis of an in-vessel food waste composting system at Kean University in the US. *Waste management*, 59, 476-486.
- Muralitharan, K., Sakthivel, R., & Vishnuvarthan, R. (2018). Neural network based optimization approach for energy demand prediction in smart grid. *Neurocomputing*, 273, 199-208.
- Ozcicek-Dolekoglu, C., & Var, I. (2019). Analysis of food waste in university dining halls: A case study from turkey. *Fresenius Environ. Bull*, 28, 156-166.
- Painter, K., Thondhlana, G., & Kua, H. W. (2016). Food waste generation and potential interventions at Rhodes University, South Africa. *Waste Management*, 56, 491-497.
- Panesar, K. (2020). *Implementation of Full-Scale Anaerobic Digestion of Food Waste at the University of South Florida* (Doctoral dissertation, University of South Florida).
- Pasupa, K., & Sunhem, W. (2016, October). A comparison between shallow and deep architecture classifiers on small dataset. In *2016 8th International Conference on Information Technology and Electrical Engineering (ICITEE)* (pp. 1-6). IEEE.
- Pinto, R. S., dos Santos Pinto, R. M., Melo, F. F. S., Campos, S. S., & Cordovil, C. M. D. S. (2018). A simple awareness campaign to promote food waste reduction in a University canteen. *Waste management*, 76, 28-38.
- Pirani, S. I., Arafat, H., & Thompson, G. (2016). *FRESH: A Food-service Sustainability Rating for Hospitality Sector Events*. Available in: <https://ecommons.cornell.edu/handle/1813/71008>
- Qiao, J., Guo, X., & Li, W. (2020). An online self-organizing modular neural network for nonlinear system modeling. *Applied Soft Computing*, 97, 106777.
- Seyfi, Z. (2020). The approved rate of student food prices was announced to the universities. *Mehr News Agency*. September 16. Available from: <https://www.mehrnews.com/news/5024681>. (in Persian)
- Steen, H., Malefors, C., Röös, E., & Eriksson, M. (2018). Identification and modelling of risk factors for food waste generation in school and pre-school catering units. *Waste Management*, 77, 172-184.
- Talluri, K. T., & Van Ryzin, G. (2004). *The Theory and Practice of Revenue Management*. New York: Kluwer Academic Publishers.
- The cost of student lunch and dinner is one thousand billion tomans! (2019, July 23). *Shahrvand Newspaper*, p.12. (in Persian)
- The Law on the Sixth Five-Year Economic, Cultural and Social Development Plan for 2017-2021. (2017) (in Persian)
- Tsai, T. (2014). A self-learning advanced booking model for railway arrival forecasting. *Transportation Research Part C: Emerging Technologies*, 39, 80-93.
- Whitehair, K. J., Shanklin, C. W., & Brannon, L. A. (2013). Written messages improve edible food waste behaviors in a university dining facility. *Journal of the Academy of Nutrition and Dietetics*, 113(1), 63-69.

- Yang, H., & Wang, F. (2019). Wireless network intrusion detection based on improved convolutional neural network. *Ieee Access*, 7, 64366-64374.
- Yang, S., Ting, T. O., Man, K. L., & Guan, S. U. (2013). Investigation of neural networks for function approximation. *Procedia Computer Science*, 17, 586-594.
- Yergök, D., Güven, C., & Acı, M. (2018). Artificial Neural Network Model Design for Daily Demand Prediction in Mass Meal Production. ICATCES'18, [http://apbs.mersin.edu.tr/files/maci/Scientific\\_Meetings\\_001.pdf](http://apbs.mersin.edu.tr/files/maci/Scientific_Meetings_001.pdf).
- Yousefi, M., Yousefi, M., Fathi, M. and Fogliatto, F.S. (2020). Patient visit forecasting in an emergency department using a deep neural network approach. *Kybernetes*, 49(9), 2335-2348.
- Yurtsever, M., & Tecim, V. (2020). Forecasting Meal Requirements Using Time Series Methods in Organization. In *Economic and Financial Challenges for Balkan and Eastern European Countries* (pp. 243-254). Springer, Cham.
- Zhang, G. P. (2001). An investigation of neural networks for linear time-series forecasting. *Computers & Operations Research*, 28(12), 1183-1202.
- Zhang, J., Che, H., Chen, F., Ma, W., & He, Z. (2021). Short-term origin-destination demand prediction in urban rail transit systems: A channel-wise attentive split-convolutional neural network method. *Transportation Research Part C: Emerging Technologies*, 124, 102928.
- Zhao, Y., Triantis, K., Teodorović, D., & Edara, P. (2010). A travel demand management strategy: The downtown space reservation system. *European Journal of Operational Research*, 205(3), 584-594.