

## Machine-learning-driven agent-based modeling: Simulating the decision of health sector human resources to migrate

**Homa Khodadadi** 

Ph.D. student in Industrial Management, Concentration in Systems Management, Department of Management, Faculty of Economics and Administrative Sciences, Ferdowsi University of Mashhad, Mashhad, Iran

**Mostafa Kazemi** \*

Professor, Department of Management, Faculty of Economics and Administrative Sciences, Ferdowsi University of Mashhad, Mashhad, Iran

**Naser Motahari  
Farimani** 

Associate Professor, Department of Management, Faculty of Economics and Administrative Sciences, Ferdowsi University of Mashhad, Mashhad, Iran

**Seyyed Mohammad  
Tabatabaei** 

Associate Professor, Department of Medical Informatics, Faculty of Medicine, Mashhad University of Medical Sciences, Mashhad, Iran

### Abstract

Migration of human resources in the health sector not only reduces the quality of healthcare services but also imposes detrimental social and economic consequences on developing countries such as Iran. Therefore, accurately modeling the decision-making behavior of this workforce requires advanced analytical approaches to capture complexities and social interactions. This study aimed to design and validate a data driven agent-based model to simulate migration behavior among healthcare professionals in Iran. Secondary data were employed from the 2023 survey entitled “National Survey on Elite Migration and Factors Influencing the Outflow of Human

\* Corresponding Author: kazemi@um.ac.ir

**How to Cite:** Khodadadi, H., Kazemi, M., Motahari Frimani, N., Tabatabaei, S.M. (2026). Machine-learning-driven agent-based modeling: Simulating the decision of health sector human resources to migrate, *Journal of Business Intelligence Management Studies*, 15(55), 127-175. DOI: 10.22054/ims.2026.89993.2727

Capital in the Health Sector” conducted by the Iranian Migration Observatory using a standardized questionnaire. The research adopted a hybrid framework in which 384 balanced samples were used for training, and the Random Forest machine learning algorithm served as the behavioral meta model of agents to directly extract nonlinear decision-making rules from microdata. The model output, representing the migration probability of each agent, was then integrated into the agent-based simulation, where comparison with an optimal decision threshold determined the final migration or non-migration action. Results indicated that the data driven agent model significantly outperformed the theory driven agent model based on logistic regression in predicting migration intentions. Furthermore, analyses confirmed that key variables such as age, work experience, and social network effects played nonlinear and essential roles in shaping final decisions.

## 1. Introduction

Migration has always been a fundamental element in human history, representing an individual's decision to relocate from one place to another. While such relocation is a personal choice, it results from a unique combination of contextual conditions (Kniveton & Smith, 2011). Preserving human capital is among the most critical challenges for developing countries. Migration of the healthcare workforce is particularly significant due to its profound impacts on both the economy and public health. These migrations reduce the quality of medical services and impose financial and temporal burdens on patients. In Iran, the most evident negative consequences include declining access and quality of healthcare in rural and public sectors, as well as the loss of experienced faculty and workforce (Valizadeh et al., 2016; Asadi et al., 2018).

Given the importance and complexity of healthcare workforce migration, rigorous scientific investigation is essential. Many proposed solutions have been temporary and reactive in nature. Migration literature discusses policies for managing migration (Carling, 2011), and legal mechanisms exist to restrict it. However, evaluation reveals that such policies generally fail (De Luca et al., 2022). Thus, when migration cannot be controlled legally, advanced analytical models are required.

The foundations of agent-based modeling (ABM) are influenced by Herbert Simon and Thomas Schelling (Chen et al., 2016). ABM enables detailed analysis and simulation of diverse scenarios, representing cognition and interactions directly, and exploring nonlinear dynamics (Salgado & Gilbert, 2013; Badham et al., 2018). Unlike linear models, it accommodates heterogeneous expectations and bottom-up dynamics, uncovering rare but impactful scenarios (Tah, 2005; Lu, 2016; Khodabandelu & Park, 2021).

Traditional migration models face three limitations: inability to represent decision-making complexity, reliance on oversimplified assumptions, and lack of empirical calibration (Simon, 1956; Filatova et al., 2013). ABM, while powerful, struggles with defining migrant behavior precisely (Klabunde & Willekens). Data-driven approaches using machine learning overcome these limits, extracting behavioral rules directly from empirical data. For example, in Burkina Faso, algorithms predicted migration decisions based on individual and social

features, with improved accuracy when incorporating neighbor migration effects (Turgut & Bozdag, 2023). Such models can also simulate responses to political changes and be calibrated with survey data (De Luca et al., 2022).

In response to these challenges and Iran's healthcare workforce crisis, this study proposes a hybrid ABM–ML approach. Machine learning uncovers hidden patterns in real data, enhancing predictive accuracy and enabling interpretability of feature contributions (Lundberg & Lee, 2017; Grimm et al., 2020; Tolk et al., 2022).

Given the bottom-up nature of migration decisions, simulation capability, and flexibility, ABM is highly effective. Since no substantial study in Iran has applied this method to healthcare migration, the present research develops and validates a machine learning–based agent model to predict migration decisions under diverse stimuli. Findings are expected to assist policymakers, universities, and the healthcare workforce in understanding environmental influences on migration decisions. The central research question is: to what extent can such a model improve the prediction of total healthcare workforce migration?

## **2. Literature Review**

In this section, the history of human migration in the health sector and the modeling of the bottleneck factor are examined.

## **3. Methodology**

Summary of the Main Steps:


- 1) Feature Extraction: Variables influencing agent behavior are identified through a literature review and extracted from available data for subsequent machine learning training and agent-based modeling.
- 2) Initial Agent-Based Model Design: Agents, environment, behaviors, and interactions are defined, and a conceptual model is outlined using the overview protocol.
- 3) Machine Learning Model Development: Prepared training data are used to design and train a model (e.g., Random Forest) that predicts migration probability based on individual and contextual features such as age, education, and marital status. The model is optimized and evaluated to improve predictive accuracy.

- 4) Agent-Based Model Implementation: The machine learning output (migration probability) is integrated into the agent-based simulation. Each agent begins with an initial probability, which is compared against an optimal decision threshold to determine final migration outcomes.
- 5) Validation: The calibrated threshold enables the prediction of the number of migrants. Model outputs are compared with actual survey data to assess accuracy.

#### **4. Results**

Figure 1 shows that the most influential features are age, work experience, and working in metropolitan areas. These are followed by marital status, number of migrated friends, and education level (associate's or bachelor's). Other features, such as gender, graduation status, working in provincial centers, and advanced education, also contribute meaningfully but rank lower in importance. Table 4 compares the performance of data-driven and theory-driven behavioral models, showing higher AUC and accuracy for the Random Forest model despite longer training time.

**Figure 1. Feature importance chart in order of SHAP value**



**Table 4. Final validation and performance comparison of behavioral models**

Model	AUC-ROC	F1-Score	Accuracy	Training time (seconds)	Testing time (seconds)
Random Forest Model (Data-Driven Model)	0.8205	0.6364	0.7155	0.2000	0.0500
Logistic Regression (Theory-Driven Model)	0.7782	0.7258	0.7069	0.0300	0.0200

## 5. Discussion

The data-driven ABM outperformed the theory-driven model, confirming the nonlinear nature of migration decisions. SHAP analysis highlighted age, experience, and social networks as key drivers. Sensitivity to migration probability suggests strong push factors in the domestic environment. The model's static design limits its ability to capture temporal dynamics and feedback effects.

## 6. Conclusion

This study introduced a hybrid ABM–ML framework to simulate healthcare migration behavior in Iran. The model offers a powerful tool for policymakers, emphasizing the need to retain mid-career professionals. Future work should incorporate dynamic modeling and real-time migration data to enhance predictive accuracy.

**Keywords:** Agent-based modeling, Machine learning, Migration, Human resources, Health sector.



## مدل سازی عامل بنیان مبتنی بر یادگیری ماشین: شبیه سازی تصمیم مهاجرت نیروهای انسانی بخش سلامت

دانشجوی دکتری رشته مدیریت صنعتی گرایش مدیریت سیستم‌ها، گروه مدیریت، دانشکده علوم اداری و اقتصاد، دانشگاه فردوسی مشهد، مشهد، ایران

هما خدادادی

استاد، گروه مدیریت، دانشکده علوم اداری و اقتصاد، دانشگاه فردوسی مشهد، مشهد، ایران

مصطفی کاظمی \*

دانشیار، گروه مدیریت، دانشکده علوم اداری و اقتصاد، دانشگاه فردوسی مشهد، مشهد، ایران

ناصر مطهری فریمانی

دانشیار، گروه انفورماتیک پزشکی، دانشکده پزشکی، دانشگاه علوم پزشکی مشهد، مشهد، ایران

سید محمد طباطبائی

### چکیده

مهاجرت نیروی انسانی در بخش سلامت، علاوه بر کاهش کیفیت خدمات درمانی، تبعات مخربی در گستره اجتماعی و اقتصادی کشورهای در حال توسعه مانند ایران دارد؛ بنابراین مدل سازی دقیق رفتار تصمیم گیری این قشر نیازمند رویکردهای تحلیلی پیشرفته برای بازنمایی پیچیدگی‌ها و تعاملات اجتماعی است. این پژوهش با هدف طراحی و اعتبارسنجی یک مدل عامل بنیان داده محور انجام شد تا رفتار مهاجرت نیروی انسانی بخش سلامت ایران را شبیه سازی کند. در این پژوهش از داده‌های ثانویه استفاده شد که توسط رصدخانه مهاجرت ایران در سال ۱۴۰۲ با عنوان «پیمایش ملی مهاجرت نخبگان و عوامل مؤثر بر خروج سرمایه انسانی بخش سلامت» از طریق پرسشنامه استاندارد جمع آوری شده بود. روش پژوهش شامل یک چارچوب ترکیبی است که در آن از ۳۸۴ نمونه متوازن شده برای آموزش استفاده شد و الگوریتم یادگیری ماشین جنگل تصادفی به عنوان فرامدل رفتاری عامل ها عمل کرد تا قوانین تصمیم گیری غیرخطی را مستقیماً از داده‌های خرد استخراج نماید. سپس، خروجی این مدل، به عنوان احتمال مهاجرت هر عامل، به مدل عامل بنیان وارد شد با مقایسه آن با یک

مقاله حاضر برگرفته از رساله دکتری مدیریت صنعتی، گرایش مدیریت سیستم‌ها، دانشگاه فردوسی مشهد است.

\* نویسنده مسئول: kazemi@um.ac.ir

مدل‌سازی عامل‌بنیان مبتنی بر یادگیری ماشین: شبیه‌سازی تصمیم مهاجرت...؛ خدادادی و همکاران | ۱۳۵

آستانه تصمیم بهینه، اقدام نهایی مهاجرت یا عدم مهاجرت عامل شبیه‌سازی شود. نتایج نشان داد که مدل عامل‌بنیان داده‌محور در پیش‌بینی قصد مهاجرت، به‌طور معناداری از مدل عامل‌بنیان نظریه‌محور مبتنی بر رگرسیون لجستیک پیشی گرفت. همچنین تحلیل‌ها تأیید کردند که متغیرهای کلیدی سن، سابقه کار و اثرات شبکه اجتماعی، نقشی غیرخطی و اساسی در شکل‌دهی تصمیم نهایی داشتند.

**کلیدواژه‌ها:** مدل‌سازی عامل‌بنیان، یادگیری ماشین، مهاجرت، نیروی انسانی، بخش سلامت، تصمیم‌گیری.

## مقدمه

مهاجرت همواره عنصری اساسی در تاریخ بشر بوده و تصمیمی فردی است که یک شخص برای نقل مکان از مکانی به مکان دیگر اتخاذ می‌کند. درحالی که این نقل مکان یک انتخاب شخصی است اما نتیجه ترکیب منحصربه‌فردی از شرایط شکل گرفته است (نایوتن و اسمیت<sup>۱</sup>، ۲۰۱۱). از طرفی حفظ سرمایه‌های انسانی از مهم‌ترین مسائل کشورهای درحال توسعه است. در این میان مهاجرت نیروهای انسانی بخش سلامت به دلیل تأثیرات بزرگ آن در اقتصاد و سلامت همواره اهمیت فراوانی برای کشورهای مبدأ، به‌ویژه کشورهای درحال توسعه، دارد. به‌طوری که این مهاجرت‌ها علاوه بر افت کیفیت درمان منجر به تحمیل هزینه‌های مالی و زمانی به بیماران می‌شود. به‌طور خاص بارزترین پیامدهای منفی این امر در جمهوری اسلامی ایران، کاهش سریع دسترسی و کیفیت خدمات بهداشتی و درمانی در مناطق روستایی و بخش عمومی است. علاوه بر اختلال در خدمات، منجر به از دست رفتن استادان با تجربه و جمعیت فعال خواهد شد. (ولی‌زاده و همکاران، ۲۰۱۶؛ اسدی و همکاران<sup>۲</sup>، ۲۰۱۸). با توجه به اهمیت و پیچیدگی پدیده مهاجرت سرمایه انسانی این قشر، بررسی علمی و مستدل آن امری ضروری است. بسیاری از راه‌حل‌های ارائه‌شده برای مدیریت این چالش‌ها به‌صورت موقتی و در پاسخ به اتفاقات مقطعی بوده‌اند. از طرفی در ادبیات مهاجرت، در مورد انواع سیاست‌هایی که می‌توان برای مدیریت مهاجرت اعمال کرد مطالعاتی وجود دارد (کارلینگ<sup>۳</sup>، ۲۰۱۱). به همین ترتیب مکانیسم‌های قانونی برای کنترل مهاجرت برقرار هستند و هدف آن‌ها ایجاد ابزارهایی است که از طریق آن می‌توان مهاجرت را محدود کرد. گرچه سیاست‌ها می‌توانند رفتار یک نظام اجتماعی را تنظیم کنند تا در راستای آن‌ها در سیستم خود عمل کند، اما اگر بدون توجه به اهداف یک سیاست آن را از نظر عملکردی ارزیابی کنیم؛ خواهیم دید که سیاست‌های مهاجرت اصولاً نمی‌توانند مهاجرت را مدیریت کنند (د لوکا و همکاران<sup>۴</sup>، ۲۰۲۲)؛ بنابراین در صورتی که

- 
1. Kniveton & Smith
  2. Valizadeh et al., 2016; Asadi et al., 2018
  3. Carling
  4. De Luca et al.

پدیده مهاجرت از طریق ابزارها، به‌ویژه ابزارهای حقوقی کنترل نشود، نیاز به رویکردهای جدید و مدل‌های تحلیلی پیشرفته برای درک بهتر و مدیریت این پدیده احساس می‌شود. امروزه موضوع مهاجرت دانشجویان و فارغ‌التحصیلان دانشگاهی، نیروی کار حرفه‌ای و متخصص بخش بهداشت، درمان و آموزش پزشکی همواره یکی از موضوعات داغ و پرحاشیه جامعه ایران است. گزارش‌های سالنامه مهاجرتی ایران ۱۴۰۱، برآورد میزان تمایل، تصمیم و اقدام به مهاجرت در سرمایه انسانی حوزه سلامت کشور در سال ۱۴۰۱ نشان می‌دهد که بیش از ۵۰٪ از افراد شرکت‌کننده در این پژوهش تمایل زیاد و بسیار زیاد به مهاجرت داشتند و میل به مهاجرت در بین دانشجویان و شاغلین حوزه سلامت وضعیت مشابهی داشت. بیش از یک‌سوم از افراد شرکت‌کننده حتی تمایل به کار در مشاغل غیرتخصصی و پایین‌تر در خارج از کشور را داشتند. تنها ۱۱٪ از افراد شرکت‌کننده تصمیم قطعی به ماندن در داخل کشور داشتند و مابقی تصمیم قطعی به مهاجرت داشته یا در خصوص مهاجرت دچار تردید و شک بودند (رصدخانه مهاجرت ایران، ۱۴۰۱). در همین راستا پژوهش حاضر از طریق پتانسیل مدل‌های مبتنی بر عامل در سیستم‌های انسانی، با در نظر گرفتن تصمیم مهاجرت به‌عنوان رفتاری که در پاسخ افراد به ترکیبات پیچیده از محرک‌های چند سطحی حاکم است، یک رویکرد جایگزین مناسب به‌جای رویکردهای تجربی ارائه شده برای مهاجرت نیروی انسانی در حوزه سلامت ارائه می‌دهد.

مبانی نظری مدل‌سازی عامل‌بنیان<sup>۱</sup> تحت تأثیر نظریات مهم هربرت سایمون و توماس شیلینگ<sup>۲</sup> است که هر دو نقشی برجسته در توسعه این حوزه ایفا کرده‌اند (چن و همکاران<sup>۳</sup>، ۲۰۱۶). عنوان یکی از رویکردهای نوین در علوم اجتماعی، امکان تحلیل دقیق‌تر و شبیه‌سازی سناریوهای مختلف را فراهم می‌کند. این مدل‌ها، با در نظر گرفتن تصمیم مهاجرت به‌عنوان رفتاری که در پاسخ به ترکیبات پیچیده از محرک‌های چند سطحی شکل می‌گیرد، می‌توانند ابزار مؤثری برای پیش‌بینی و مدیریت مهاجرت سرمایه انسانی باشند.

- 
1. Agent-Based Modeling (ABM)
  2. Herbert Simon & Thomas Schelling
  3. Chen et al

استفاده روزافزونی در کاربرد آن‌ها به عنوان یک رویکرد مدل‌سازی در علوم اجتماعی وجود دارد، زیرا محققان را قادر می‌سازد تا مدل‌های محاسباتی بسازند که در آن موجودیت‌های فردی، شناخت و تعاملات آن‌ها به طور مستقیم نمایش داده می‌شود (سالگادو و گیلبرت<sup>۱</sup>، ۲۰۱۳).

مدل‌سازی مبتنی بر عامل یک روش محاسباتی برای درک رفتار سیستم‌های پیچیده با شبیه‌سازی کنش‌های موجودات درون سیستم، از جمله نحوه تأثیرگذاری و تأثیرپذیری این اجزاء از محیط فیزیکی و اجتماعی خود است (بادهام و همکاران<sup>۲</sup>، ۲۰۱۸). این مدل می‌تواند انتظارات همگن یا ناهمگن را برآورده کند و برای پیش‌بینی نیازی به خطی بودن رابطه بین اطلاعات و متغیرها ندارد (سل<sup>۳</sup>، ۲۰۱۵). همچنین با رویکرد پایین به بالا، ویژگی‌ها و تعاملات عامل‌ها را در سطح خرد را تنظیم می‌کنند تا نتایج سیستم در سطح کلان را تولید کنند. مدل‌سازی در سطح خرد به مدل‌های عامل‌بنیان اجازه می‌دهد تا احتمال وقوع سناریوهای مختلف را بررسی کرده و سناریوهای نادری که ممکن است تأثیر شدیدی بر نتایج سیستم داشته باشند را کشف کند. همچنین توانایی آن‌ها برای به‌روزرسانی ویژگی‌های عامل‌ها، در مقایسه با سایر روش‌های شبیه‌سازی، می‌تواند به کاربران کمک کند تا مدل واقعی‌تری را دریافت کنند که به نوبه خود نتایج دقیق‌تری ارائه می‌دهد (تاه، ۲۰۰۵؛ لو<sup>۴</sup>، ۲۰۱۶؛ خدابنده‌لو و پارک<sup>۴</sup>، ۲۰۲۱).

مطالعه مهاجرت طی دهه‌های گذشته در قالب چارچوب‌های نظری و مدل‌های کمی متنوعی توسعه یافته است. مطالعات اولیه‌تر، عمدتاً بر رویکردهای کلان‌نگر و یکپارچه‌سازی داده‌های پراکنده متمرکز بودند. برای نمونه، رایمر و همکاران<sup>۵</sup> (۲۰۱۳) با معرفی یک مدل آماری بیزین یکپارچه، پاسخی علمی به چالش ناهماهنگی و کم‌شماری در داده‌های مهاجرتی اروپا ارائه کردند و بستری برای سیاست‌گذاری مبتنی بر شواهد فراهم آوردند.

- 
1. Salgado & Gilbert
  2. Badham et al
  3. Salle
  4. Tah, 2005; Lu, 2016; Khodabandelu & Park, 2021
  5. Raymer et al

هم‌زمان، با گسترش دسترسی به داده‌های خرد و پیشرفت علوم داده، رویکردهای یادگیری ماشین راه خود را به این حوزه باز کردند. مطالعه رابینسون و دیلکینا<sup>۱</sup> (۲۰۱۸) نمونه‌بارزی است که با به‌کارگیری این روش‌ها، امکان مدل‌سازی غیرخطی و هم‌زمان طیف وسیعی از متغیرهای اقتصادی، جمعیتی و محیطی برای پیش‌بینی جریان مهاجرت را فراهم ساخت.

در حوزه مهاجرت نیروی انسانی، تحولات روش‌شناختی به سمت طراحی مدل‌هایی برای درک تصمیم‌گیری فردی در چارچوب چرخه زندگی سوق یافته است. همان‌گونه که کنان و واکر<sup>۲</sup> (۲۰۱۳) در مرور نظری خود تأکید کرده‌اند، مدل‌سازی مهاجرت به‌عنوان یک سرمایه‌گذاری پویا مستلزم در نظرگیری توالی تصمیمات، نقش انتظارات، یادگیری و وضعیت ویژه محل زادگاه است. این چارچوب اقتصادی یکپارچه، توضیحی برای الگوهای پیچیده‌ای مانند مهاجرت بازگشتی و زنجیره‌ای ارائه می‌دهد و بر اهمیت کنترل مسئله انتخاب نمونه در مطالعات تجربی تأکید می‌کند. در مطالعات تجربی بعدی، پژوهش دگفاچو و همکاران<sup>۳</sup> (۲۰۲۵) با استفاده از مدل رگرسیون سوئیچینگ درون‌زای چندوجهی، نه تنها عوامل تعیین‌کننده مهاجرت را شناسایی کرد، بلکه با کنترل ناهمگونی رفتاری و انتخاب فردی، اثر خالص مهاجرت را با دقت بیشتری برآورد نمود. این تأکید بر سطح خرد و ناهمگونی در مطالعه هلمز و فراهر<sup>۴</sup> (۲۰۱۷) نیز در قالب یک مدل دو مرحله‌ای برای مهاجرت پزشکان دنبال شده است. در زمینه حفظ نیروی کار بخش سلامت، مطالعه دی‌کاپریو و همکاران<sup>۵</sup> (۲۰۲۵) گام دیگری به‌سوی عمل‌گرایی برداشته و با طراحی یک مدل تصمیم‌گیری چندمعیاره داده‌محور، ابزاری کمی برای اولویت‌بندی راهبردهای نگهداشت نیرو ارائه کرده است.

در پژوهش‌های داخل کشور نیز به مدل‌های مهاجرتی پرداخته شده است؛ از جمله مدل‌سازی با رویکرد بررسی روابط علی. در زمینه مهاجرت سرمایه انسانی فرتوک‌زاده و

- 
1. Robinson & Dilkina
  2. Kennan & Walker
  3. Degfachew et al
  4. Holmes & Fraher
  5. Di Caprio et al

اشراقی (۱۳۸۷) با بهره‌گیری از پویایی‌شناسی سیستم‌ها و مدل‌سازی پدیده مهاجرت نخبگان را مطالعه کردند. صفایی‌پور و محلی (۱۳۹۶) با یک رویکرد ترکیبی و با استفاده از مدل معادلات ساختاری و تحلیل سلسله‌مراتبی فازی عوامل تأثیرگذار بر مهاجرت از شهر اهواز پرداخته‌اند. این پژوهش نمونه‌ای از تلفیق روش‌های تصمیم‌گیری چندمعیاره فازی با مدل‌سازی علی برای شناسایی سهم و تأثیر عوامل کلان مؤثر بر مهاجرت در یک بافت جغرافیایی مشخص است.

با وجود پیشرفت‌های قابل توجه در مدل‌سازی کمی مهاجرت، ارزیابی‌های اخیر نشان می‌دهد که این حوزه به‌ویژه در مواجهه با پیچیدگی پدیده‌های با چالش‌های روش‌شناختی مواجه است. بایر و همکاران<sup>۱</sup> (۲۰۲۳) چند اولویت کلیدی برای نسل آینده این مدل‌ها برمی‌شمارد که از جمله می‌توان به گذار از روش‌های خطی به یادگیری ماشین غیرخطی، توجه به ناهمگونی‌های رفتاری و استفاده از داده‌های تفکیک‌شده برای کالیبراسیون اشاره کرد.

با توجه به پیشینه بررسی شده؛ در تحلیل پدیده مهاجرت مدل‌های سنتی همچنان با سه محدودیت مواجه‌اند. نخست، این مدل‌ها در بازنمایی پیچیدگی تصمیم‌گیری انسانی ناتوان‌اند؛ به‌ویژه مدل‌های کلان‌نگر مانند معادلات دیفرانسیل و رویکردهای آماری صرف، قادر به درک تعاملات فاکتورهای فردی (انگیزه‌ها، موانع، شبکه‌های اجتماعی) و ساختاری (اقتصادی، سیاسی) نیستند. دوم، اتکای این مدل‌ها به فرضیات ساده‌انگارانه نظیر عقلانیت کامل یا تابع مطلوبیت خطی و نادیده گرفتن واقعیت‌های پیچیده‌ای چون عقلانیت محدود و تأثیر شبکه‌های اجتماعی. سوم، چالش اعتبارسنجی در مدل‌های نظری محض، به دلیل فقدان مکانیزم‌های کالیبراسیون با داده‌های تجربی، موجب ضعف در پیش‌بینی رفتارهای نوظهور شده است. این محدودیت‌ها در مطالعات پیشین به‌روشنی مورد تأکید قرار گرفته‌اند (سایمون، ۱۹۵۶؛ نایون و همکاران، ۲۰۱۱؛ فیلاتوا و همکاران، ۲۰۱۳)<sup>۲</sup>؛ بنابراین، پژوهش حاضر با جایگزینی چارچوب‌های خطی سنتی با یک مدل غیرخطی داده‌بنیان، گامی در

1. Beyer

2. Simon, 1956; Kniveton et al., 2011; Filatova et al., 2013

جهت عملیاتی‌سازی اولویت‌های پژوهشی نوین برداشته و ابزار تحلیلی دقیق‌تری برای درک عوامل مؤثر بر مهاجرت نیروهای متخصص سلامت فراهم می‌کند.

با وجود اینکه مدل‌های عامل‌بنیان ابزار مؤثری برای مطالعه مهاجرت انسانی هستند، به‌ویژه در مواجهه با پیچیدگی‌های رفتاری، اما یکی از چالش‌های اصلی در طراحی این مدل‌ها، تعریف دقیق رفتار عامل‌های مهاجر است (کلابونده و ویلکنز<sup>۱</sup>، ۲۰۱۶). برای غلبه بر این محدودیت، رویکردهای داده‌محور و مبتنی بر یادگیری ماشین توسعه یافته‌اند که به‌جای تکیه بر فرض‌های نظری، قوانین رفتاری را مستقیماً از داده‌های تجربی استخراج می‌کنند. برای مثال، در مطالعه‌ای درباره مهاجرت در بورکینافاسو، الگوریتم‌های یادگیری ماشین برای پیش‌بینی تصمیم مهاجرت عاملان بر اساس ویژگی‌های فردی و اجتماعی به کار گرفته شد و با افزودن اثرات تعاملی مانند مهاجرت همسایگان، دقت مدل در سطح کلان افزایش یافت (تورگوت و بوزداگ<sup>۲</sup>، ۲۰۲۳). همچنین، این مدل‌ها امکان شبیه‌سازی واکنش عامل به تغییرات سیاسی را فراهم می‌کنند و با داده‌های نظرسنجی کالیبره می‌شوند (دلوکا<sup>۳</sup> و همکاران، ۲۰۲۲).

در پاسخ به این چالش‌ها و با توجه به بحران فراگیر نیروهای حرفه‌ای بهداشت و درمان که کشور به آن مبتلاست، پژوهش حاضر یک رویکرد داده‌محور را پیشنهاد می‌دهد که تلفیقی از مدل‌سازی عامل‌بنیان و یادگیری ماشین است. در این چارچوب، یادگیری ماشین با استخراج الگوهای پنهان از داده‌های واقعی، جایگزین فرضیات ذهنی در مدل‌سازی تصمیم‌گیری می‌شود؛ این رویکرد علاوه بر افزایش دقت پیش‌بینی، با بهره‌گیری از روش‌های تفسیرپذیری مدل‌های یادگیری ماشین، امکان تحلیل سهم نسبی هر ویژگی در خروجی مدل را فراهم می‌سازد (لوندبرگ و لی، ۲۰۱۷؛ گریم و همکاران، ۲۰۲۰، تاک و همکاران<sup>۴</sup>، ۲۰۲۲).

بنابراین به دلیل ماهیت پایین به بالای مسئله، قابلیت شبیه‌سازی تصمیم‌گیری و

---

1. Klabunde & Willekens

2. Turgut & Bozdag

3. De Luca

4. Lundberg & Lee, 201; Tolk et al., 2022; Grimm et al., 2020

انعطاف پذیری بالا؛ روش عامل بنیان بسیار اثربخش است و از آنجایی که تا به حال پژوهش قابل استنادی در ایران با این روش به این موضوع نپرداخته است؛ هدف این پژوهش ارائه مدلی در جهت پیش بینی تصمیم مهاجرت تحت تأثیر محرک‌ها است؛ بنابراین نتیجه حاصل می‌تواند علاوه بر مدیران حوزه سلامت و دانشگاه‌های علوم پزشکی، در شناخت کادر درمان از میزان تأثیر محیط بر تصمیم خود، مفید باشد. بر این اساس، سؤال اصلی پژوهش حاضر این است که توسعه و اعتبارسنجی یک مدل عامل بنیان مبتنی بر یادگیری ماشین تا چه میزان می‌تواند در پیش بینی تعداد کل مهاجران (نیروی انسانی بخش سلامت) مؤثر باشد؟

### پیشینه پژوهش

در این بخش پیشینه مهاجرت نیروی انسانی بخش سلامت و مدل سازی عامل بنیان بررسی می‌شوند.

### مهاجرت نیروی انسانی بخش سلامت

سرمایه انسانی یک منبع تجدیدپذیر است که می‌تواند انباشته شود. مطالعات نشان می‌دهد فرآیندهای مهاجرت کنونی سرمایه انسانی، به دلیل پویایی شدید، اثرات اجتماعی و اقتصادی قدرتمندی دارند. این فرآیندها تقریباً تمام حوزه‌های جامعه را تحت تأثیر قرار می‌دهند و بر کشورهای فرستنده و پذیرنده، به ویژه سرمایه انسانی آن‌ها تأثیر می‌گذارند (گربنیک و همکاران<sup>۱</sup>، ۲۰۲۱). مهاجرت نیروی انسانی بخش سلامت از موضوعات مهم و مورد توجه در حوزه مطالعات مهاجرت و بهداشت عمومی است. این پدیده تأثیرات گسترده‌ای بر سیستم‌های بهداشتی کشورهای مبدأ و مقصد دارد. در این بخش، به بررسی مطالعات انجام شده در زمینه مهاجرت نیروی انسانی بخش سلامت پرداخته می‌شود.

کانل<sup>۲</sup> (۲۰۱۴) بعد فرهنگی مهاجرت کارکنان سلامت را بررسی کرده است. فرهنگ متمرکز در خانواده‌ها و آرزوی بسیاری از افراد برای تبدیل شدن به کادر درمان در کنار این

1. Grebeniyk et al

2. Connell

تصور که همیشه شیوه‌های پزشکی برتر در خارج از کشور وجود دارد محرک این موج مهاجرت در کشورهای در حال توسعه است. ایتون<sup>۱</sup> و همکاران (۲۰۲۳) در پژوهشی رشد تعداد پرسنل بهداشتی بین‌المللی شاغل در بریتانیا را از سال ۲۰۱۸ بررسی کردند. آن‌ها به این نتیجه رسیدند که مهاجرت بین‌المللی کارکنان مراقبت‌های بهداشتی، وسیله‌ای برای حفظ کیفیت خدمات در بسیاری از کشورهای با درآمد بالا است، در حالی که پرسنل بهداشتی که در خارج از کشور آموزش دیده‌اند، از فقیرترین کشورهای جهان جذب می‌شوند. مهاجرت کارکنان بهداشتی منجر به ارائه خدمات بهداشتی ضعیف‌تر در کشورهای کم‌درآمد و متوسط است.

لیتائو<sup>۲</sup> و همکاران (۲۰۲۴) در یک مطالعه، مهاجرت کارکنان مراقبت‌های بهداشتی در مقیاس جهانی را به‌عنوان یک موضوع پیچیده و حیاتی عنوان کردند که عمیقاً بر پویایی سیستم‌های مراقبت‌های بهداشتی در سراسر جهان تأثیر می‌گذارد. نویسندگان به محرک‌های چندوجهی در پس مهاجرت بی‌سابقه متخصصان مراقبت‌های بهداشتی پرداختند و دلایل به هم پیوسته‌ای که این پدیده را به پیش می‌برند، معرفی کردند. این پژوهش ابعاد اقتصادی، اجتماعی و حرفه‌ای را در بر می‌گیرد و تأثیر متقابل و پیچیده فاکتورهای مؤثر بر تصمیم متخصصان مراقبت‌های بهداشتی برای مهاجرت را تأیید می‌کند. مهاجرت افراد شاغل در بخش سلامت (از جمله پرستاران) به‌عنوان بخشی از دارایی‌های فکری یک کشور از اهمیت سیاسی، اجتماعی و اقتصادی بالایی برخوردار است. کمبود پرستار به دلیل تأثیر آن بر کارایی و اثربخشی سیستم مراقبت‌های بهداشتی، یکی از نگرانی‌های عمده در بسیاری از کشورهای در حال توسعه است. در این میان وجود مشوق‌های مختلف برای تشویق پرستاران به مهاجرت به کشورهای دیگر از دیگر دلایلی است که وضعیت را در کشورهای مبدأ پیچیده‌تر کرده است. مشکلاتی مانند نارضایتی شغلی، ناآرامی‌های اجتماعی یا سیاسی و رفاه اجتماعی کمتر از جمله عواملی هستند که سرعت این مهاجرت را افزایش می‌دهند (ولیزاده و همکاران، ۲۰۱۶). اسدی و همکاران

---

1. Eaton

2. Leitão

(۲۰۱۸) مهاجرت متخصصان مراقبت‌های بهداشتی از کشورهای در حال توسعه را مطالعه و فاکتورهای مؤثر بر مهاجرت متخصصان را در پنج موضوع کلیدی شامل فاکتورهای ساختاری، شغلی، شخصی، اجتماعی-سیاسی و اقتصادی طبقه‌بندی نمودند. مهم‌ترین موارد مؤثر بر مهاجرت جمعیت مورد مطالعه ما مسائل ساختاری، مشکلات شغلی و نگرانی‌های شخصی بود.

مهاجرت در میان جامعه پزشکی می‌تواند پیامدهای مختلفی را برای ساختار خدمات پزشکی هر کشور داشته باشد که کشور ایران نیز به تازگی با مهاجرت نخبگان پزشکی روبه‌رو شده است. طاحراحمدی<sup>۱</sup> و همکاران (۲۰۲۳) نیز گرایش دانشجویان پزشکی ایرانی به مهاجرت و عوامل مرتبط با آن را در پژوهشی بررسی کردند. نتایج این پژوهش نشان داد در جامعه مورد مطالعه زنان، نخبگان و کسانی که دارای وضعیت اجتماعی-اقتصادی بالاتر، مواجهه قبلی با کشورهای خارجی، توانایی صحبت به زبان‌های خارجی و فعالیت‌های تحقیقاتی هستند، بیشتر احتمال دارد مهاجرت کنند.

در نشریات داخل کشور نیز مطالعاتی در این زمینه وجود دارد. علاءالدینی و همکاران (۱۳۸۴) در مطالعه‌ای میزان تمایل پزشکان ایرانی به مهاجرت ۵۳ درصد تخمین زدند. این تمایل در زنان و مردان تفاوت اندکی دارد و اما هر دو دلایل متعدد اجتماعی و اقتصادی را در برمی‌گیرند. ودادهیر و اشراقی (۱۳۹۸) در پژوهشی مسائل دافعه در کشور و جاذبه‌های زیاد در کشور مقصد برای پزشکان و پیراپزشکان را با تحلیل داده‌ها استخراج کردند. غفاریان و فردوسی (۱۴۰۱) در پژوهشی علاوه بر عوامل اقتصادی-شغلی و عوامل فرهنگی-اجتماعی، موانع ادامه تحصیل را نیز به عنوان عامل اصلی مهاجرت کادر درمان معرفی کردند. نتایج مطالعه حق‌دوست و همکاران (۱۴۰۱) نشان می‌دهد که حل مسئله مهاجرت کادر درمان نیازمند عزم جدی، همه‌جانبه و طولانی مدت به مسئله مدیریت نیروهای انسانی، انجام اصلاحات ساختاری و قانون‌گذاری، شایسته‌سالاری و افزایش امید در جامعه دانشگاهی است.

## مدل‌سازی عامل‌بنیان (ABM)

همان‌طور که پیش‌ازاین اشاره شد؛ توماس شیلینگ پایه‌گذار نخستین مدل شبیه‌سازی مبتنی بر عامل بود. در این مدل، عامل‌ها نشان‌دهنده افراد بودند و تعامل‌های بین آنان فرآیندهای اجتماعی را نشان می‌داد. شیلینگ یکی از مشکلات آن زمان در جامعه آمریکا، جدا کردن مناطق مسکونی سفیدپوستان از سیاه‌پوستان را با این مدل حل کرد. مدل شیلینگ از نخستین مدل‌هایی است که توانست الگوهای سطح سیستمی را بررسی کند و نشان دهد رفتارهای جزئی در سطح فردی، سبب می‌شود رفتارهای نوظهور بروز کند (صادقی مقدم و سلطانی نشان، ۱۴۰۲). هر مدل مبتنی بر عامل شامل چهار عنصر اصلی است؛ عامل‌ها، محیط استقرار عامل‌ها، قوانینی که چگونگی تعاملات عامل‌ها با یکدیگر و با محیط را تعریف می‌کنند و جهان شبیه‌سازی (حسین‌دوست و همکاران، ۱۴۰۱).

در مقایسه با سایر رویکردهای مدل‌سازی، شبیه‌سازی عامل‌بنیان روشی کامل‌تر است، با این حال تا اوایل دهه ۲۰۰۰ صرفاً یک مفهوم علمی بدون کاربرد واقعی در نظر گرفته می‌شد. کاربرد این روش مدل‌سازی بین سال‌های ۲۰۰۲ و ۲۰۰۳ توسط پژوهشگران آغاز شد و دلایل آن عبارت بودند از احساس نیاز به اشراف با عمق بیشتر در رفتار سیستم‌ها و توسعه و پیشرفت در تکنیک‌های مدل‌سازی برگرفته از علوم رایانه‌ای (فرح‌بخش، مدیری و همکاران، ۱۴۰۱). در نهایت مدل‌سازی مبتنی بر عامل به‌عنوان رویکردی مناسب برای شبیه‌سازی سیستم‌های پیچیده و ناهمگن معرفی شد (بندینی<sup>۱</sup> و همکاران، ۲۰۰۹). در این چارچوب، یادگیری عامل‌ها نقش مهمی در بازنمایی رفتارهای پویا ایفا می‌کند. پژوهش‌هایی مانند مطالعه ویتوسیاک<sup>۲</sup> (۲۰۱۲) به بررسی جنبه‌های نظری و عملی یادگیری در محیط‌های تصادفی پرداخته‌اند و کاربرد روش‌های رایانه‌ای را در تحلیل تصمیم‌گیری در حوزه حمل‌ونقل نشان داده‌اند و دره‌وگ<sup>۳</sup> (۲۰۱۶) نیز با بهره‌گیری از شبکه‌های مصنوعی چندلایه، روشی برای بهبود تخمین‌های تجربی در مدل‌های اقتصادی مبتنی بر

1. Bandini

2. Wojtusiak

3. Van der Hoog

عامل ارائه کرده است. در سال‌های اخیر، رویکردهای داده‌محور جایگزین روش‌های پیش‌پردازشی شده‌اند؛ به طوری که تقی‌خواه<sup>۱</sup> و همکاران (۲۰۲۲) از یادگیری رایانه‌ای برای ساخت مستقیم مدل‌های شبیه‌سازی استفاده کرده‌اند. چارچوب پیشنهادی آن‌ها با در نظر گرفتن روابط علی و بازخوردی در سیستم‌های غیرخطی، امکان توسعه مدل‌های رفتاری شفاف و قابل تفسیر را فراهم می‌سازد و مسیرهای جدیدی را برای تحلیل داده‌محور در شبیه‌سازی‌های اجتماعی می‌گشاید.

مدل‌سازی مبتنی بر عامل در سال‌های اخیر به‌عنوان رویکردی مؤثر برای تحلیل مهاجرت انسانی، به‌ویژه در مواجهه با پیچیدگی‌های رفتاری و فاکتورهای چندگانه، مورد توجه قرار گرفته است. سیلوریا<sup>۲</sup> و همکاران (۲۰۰۶) با ترکیب رویکرد آماری و مدل عامل‌بنیان، ویژگی‌های نوظهور مهاجرت روستا به شهر را در اقتصادهای در حال توسعه شبیه‌سازی کردند. نایوتن و همکاران (۲۰۱۱) نشان دادند که مدل‌های عامل‌بنیان با تلفیق نظریه رفتار برنامه‌ریزی‌شده، قابلیت بازنمایی تصمیم‌گیری مهاجرتی در پاسخ به تغییرات زیست‌محیطی و جمعیت‌شناختی را دارند. حسنی-محموئی و پریس<sup>۳</sup> (۲۰۱۲) نیز با توسعه یک مدل عامل‌بنیان، تأثیر تغییرات اقلیمی بر رفتارهای مهاجرتی را بررسی کرده و نقش این رویکرد را در تحلیل سناریوهای جمعیتی و سیاست‌گذاری مهاجرتی برجسته ساختند. در یک مرور نظری، کلابوند و ویلکنس<sup>۴</sup> (۲۰۱۶) کفایت نظریه‌های تصمیم‌گیری در مدل‌های مهاجرتی را ارزیابی کرده و بر ضرورت انتخاب نظریه‌های معتبر، داده‌های تجربی قابل مقایسه و توجه به تعاملات اجتماعی تأکید کردند. فو و هائو<sup>۵</sup> (۲۰۱۸) با تمرکز بر مهاجرت روستایی-شهری، نقش شبکه‌های اجتماعی را در تصمیم‌گیری مهاجرتی برجسته کرده و نشان دادند که لحاظ این عامل در مدل‌های عامل‌بنیان موجب افزایش دقت

- 
1. Taghikhah
  2. Silveira
  3. Hassani-Mahmooei & Parris
  4. Klabunde & Willekens
  5. Fu & Hao

پیش‌بینی می‌شود. مارینی<sup>۱</sup> و همکاران (۲۰۱۹) با استفاده از مدل عامل‌بنیان، پیامدهای مهاجرت بر زیرساخت‌های شهری را در شهر لوزان سوئیس بررسی کرده و تأثیر آن بر پویایی مسکن را تحلیل کردند. ریچی<sup>۲</sup> (۲۰۲۰) از مدل‌سازی مبتنی بر عامل برای بازنمایی مهاجرت پناهندگان سوری به ترکیه بهره گرفت و نقش عوامل محیطی و شبکه‌ای را در تصمیم‌گیری مهاجرتی برجسته ساخت. سرل و ون وورن<sup>۳</sup> (۲۰۲۱) چارچوبی برای طراحی مدل‌های مهاجرت اجباری ناشی از درگیری‌ها ارائه دادند که بر کمبود داده‌های قابل‌اعتماد تأکید دارد و نشان می‌دهد مدل‌های عامل‌بنیان می‌توانند در پیش‌بینی الگوهای حرکتی در مقیاس بزرگ و پشتیبانی از تصمیم‌گیری سازمان‌های بشردوستانه مؤثر باشند. ترین و مونرو<sup>۴</sup> (۲۰۲۳) با ادغام آزمایش انتخاب در مدل عامل‌بنیان، مهاجرت‌های ناشی از تغییرات آب‌وهوایی در دلتای رودخانه‌ای را پیش‌بینی کردند و نشان دادند که علاوه بر عوامل محیطی، شبکه‌های اجتماعی و تصمیمات همسایگان تأثیر قابل‌توجهی بر رفتار مهاجرتی دارند.

در ادامه این روند، تورگوت و بوزداگک (۲۰۲۳) یک چارچوب ترکیبی برای مدل‌سازی رفتار عامل‌ها در مدل‌های مبتنی بر عامل ارائه کردند که در آن، با تلفیق پشتیبانی نظری و الگوریتم‌های داده‌محور، تلاش می‌کند دقت مدل‌سازی رفتار عامل را افزایش دهد. مطالعه موردی آن‌ها نشان داد که استفاده از این رویکرد می‌تواند فرآیند ساخت مدل‌های عامل‌بنیان را تسهیل کرده و انطباق آن‌ها با واقعیت‌های پیچیده را بهبود بخشد. در جدیدترین مطالعه، گونگور<sup>۵</sup> و همکاران (۲۰۲۴) با شبیه‌سازی مسیرهای مهاجرت پناهندگان سوری، مدلی برای پشتیبانی از تصمیم‌گیری سازمان‌های امدادی توسعه دادند که قابلیت تعمیم به مناطق جغرافیایی مختلف را دارد.

ادغام یادگیری ماشین در مدل‌سازی مبتنی بر عامل، مسیرهای نوینی برای افزایش دقت، سازگاری و کاربردپذیری مدل‌ها در حوزه‌های پیچیده فراهم کرده است. مطالعات

1. Marini
2. Richey
3. Searle & van Vuuren
4. Trinh & Munro
5. Güngör

اخیر نشان داده‌اند که این هم‌افزایی می‌تواند به توسعه شبیه‌سازی‌های داده‌محور منجر شود که قادر به بازنمایی رفتارهای پیچیده در محیط‌های واقعی هستند. در این زمینه، الگوریتم‌های یادگیری تقویتی به‌عنوان روشی جایگزین برای استخراج رفتار عامل از طریق تعامل با محیط و یادگیری تدریجی مطرح شده‌اند. در مطالعه تورگوت و بوزداگک (۲۰۲۳)، اثر همتایان پس از محاسبه احتمال مهاجرت توسط مدل یادگیری ماشین، به‌صورت جداگانه و با فرمول نظری به‌قاعده تصمیم‌گیری عامل اضافه شده است؛ رویکردی که با چالش‌هایی در کالیبراسیون و تفسیرپذیری همراه بوده است. نوآوری پژوهش حاضر در ادغام مستقیم فاکتور شبکه (تعداد دوستان مهاجرت کرده) به‌عنوان یکی از ویژگی‌های ورودی مدل یادگیری ماشین است؛ رویکردی که امکان در نظر گرفتن هم‌زمان تعاملات فردی و محیطی را در تصمیم‌گیری عامل فراهم می‌سازد. همچنین، در حوزه مهاجرت نیروی کار دانشگاه‌های علوم پزشکی کشور، مطالعات پیشین عمدتاً بر پیامدهای اقتصادی مهاجرت پزشکان و پرستاران متمرکز بوده‌اند؛ درحالی‌که این پژوهش، دامنه وسیع‌تری از رشته‌های علوم پزشکی، پیراپزشکی و علوم پایه را در تحلیل خود لحاظ می‌کند.

## روش

مطالعه حاضر از نوع مقطعی و توصیفی است که با استفاده از روش‌های کیفی و کمی به بررسی توسعه مدل‌های عامل بنیان با الگوریتم‌های یادگیری ماشین در راستای تصمیم‌به‌مهاجرت نیروی انسانی حوزه سلامت می‌پردازد. با توجه به اینکه مدل‌سازی عامل بنیان رفتار کلان سیستم مورد بررسی از رفتار عامل‌ها در سطح خرد قابل تحلیل و ارزیابی است، این پژوهش رویکرد سیستمی را دنبال می‌کند.

داده‌های ثانویه به‌کاربرده شده در این پژوهش حاصل پیمایش ملی مهاجرت نخبگان و عوامل مؤثر بر خروج سرمایه انسانی بخش سلامت، سال ۱۴۰۲، هستند. ابزار گردآوری این داده‌ها پرسشنامه استاندارد است که توسط مرکز رصد مهاجرت نخبگان در دانشگاه صنعتی شریف طراحی شده، باین‌حال روایی و پایایی آن توسط تعدادی از استادان خبره و متخصص در حوزه سلامت مورد ارزیابی و تأیید قرار گرفته است. پاسخ‌دهندگان این

پرسشنامه ۵۴۲ نفر از دانشجویان و شاغلان مراکز تحت پوشش دانشگاه‌های علوم پزشکی با مقاطع تحصیلی کاردانی تا دکتری تخصصی، تخصص‌های بالینی و مقاطع بالاتر وزارت بهداشت درمان و آموزش پزشکی هستند.

در این پژوهش مدل‌سازی رفتاری از طریق یک فرایند چندمرحله‌ای و داده‌محور انجام می‌گیرد که هدف آن استخراج یک قانون تصمیم‌گیری غیرخطی و دقیق برای هر عامل است تا از فرضیات ساده‌انگارانه مدل‌های نظری پرهیز شود. خلاصه گام‌های اصلی این فرآیند عبارت‌اند از:

(۱) استخراج ویژگی‌ها: در ابتدا متغیرهایی که بر رفتار عامل‌ها تأثیر می‌گذارند؛ با جستجوی ادبیات شناسایی می‌شوند. در واقع متغیرهایی که در مراحل بعدی برای آموزش مدل یادگیری ماشین و پیاده‌سازی مدل عامل‌بنیان استفاده خواهند شد، از داده‌های موجود استخراج می‌شوند.

(۲) طراحی اولیه مدل عامل‌بنیان: پس از آماده‌سازی داده‌ها، شناسایی و تعریف عامل‌ها، محیط مدل، رفتارها و تعاملات بین آن‌ها انجام می‌شود. سپس مدل مفهومی اولیه با استفاده از پروتکل نمای کلی، مفاهیم طراحی و جزئیات ارائه می‌شود.

(۳) ساخت و آموزش مدل یادگیری ماشین: در این مرحله اقدامات لازم برای آماده‌سازی داده‌ها جهت توسعه یک مدل یادگیری ماشین انجام می‌شود. پس از آماده‌سازی داده‌های آموزشی، مدل طراحی و با داده‌های آموزشی یاد داده می‌شود. این مدل به گونه‌ای آموزش می‌بیند که بتواند احتمال مهاجرت هر عامل را بر اساس ویژگی‌های فردی و محیطی (مانند سن، تحصیلات، وضعیت تأهل و ...) پیش‌بینی کند. برای این کار، الگوریتم‌های مناسب انتخاب و مدل با داده‌های آموزشی بهینه‌سازی می‌شود. در این مرحله ارزیابی و تنظیم مدل یادگیری ماشین بر اساس داده‌های آموزشی برای بهبود دقت پیش‌بینی انجام می‌گیرد.

(۴) پیاده‌سازی مدل عامل‌بنیان: در این مرحله، خروجی مدل یادگیری ماشین (احتمال

مهاجرت هر عامل) به عنوان ورودی شبیه سازی عامل بنیان استفاده می شود. به عبارتی هر عامل برای شروع شبیه سازی یک احتمال اولیه برای مهاجرت دارد که در کنار سایر ویژگی ها با الگوریتم مناسب پردازش می شود. همچنین در این مرحله، آستانه تصمیم بهینه محاسبه می شود. احتمال مهاجرت هر عامل با این آستانه مقایسه می شود تا تصمیم نهایی تعیین گردد. به این ترتیب، تعداد کل عامل هایی که تصمیم به مهاجرت گرفته اند، مشخص خواهد شد.

(۵) اعتبارسنجی: تعیین مقدار آستانه تصمیم کالیبره منجر به پیش بینی تعداد مهاجران (از نمونه بررسی شده) می شود. خروجی نهایی مدل با داده های واقعی پرسشنامه ای مقایسه می شود تا میزان دقت پیش بینی ها ارزیابی شود.

#### یافته ها

همان طور که پیش از این اشاره شد؛ برای پیاده سازی روش پیشنهادی در بررسی تصمیم مهاجرت نیروی انسانی حوزه سلامت ایران، از داده های «پیمایش ملی مهاجرت نخبگان و عوامل مؤثر بر خروج سرمایه انسانی بخش سلامت» در قالب داده ثانویه استفاده شده است. این داده ها شامل ۵۴۲ نمونه هستند که در سال ۱۴۰۲ جمع آوری شده و شامل دانشجویان و دانش آموختگان رشته های موجود در وزارت بهداشت، درمان و آموزش پزشکی هستند. تعداد غالب این افراد را زنان (۵۵٪) از پاسخ دهندگان) و دانش آموختگان (۶۹٪) از پاسخ دهندگان) تشکیل می دهند.

در ادامه این بخش پس از ارائه مدل عامل بنیان به روش کلاسیک (نظریه محور و مبتنی بر ادبیات موضوع)، پیاده سازی مدل پیشنهادی پژوهش با تعداد ۳۸۴ نمونه متوازن از داده های معرفی شده؛ برای پیش بینی الگوهای مهاجرت نیروی انسانی حوزه سلامت با استفاده از یادگیری ماشین انجام می گیرد.

#### مدل عامل بنیان

در این بخش، به توصیف طراحی مدل عامل بنیان برای فرآیند تصمیم گیری مهاجرت

می‌پردازیم. برای اطمینان از وضوح و قابلیت بازتولید ساختار و فرآیندهای مدل، از پروتکل استاندارد ODD پیروی می‌کنیم. این پروتکل یک روش‌شناسی شناخته‌شده برای توصیف استاندارد مدل‌های عامل‌بنیان است (گرم و همکاران، ۲۰۰۶؛ ریلزبک و گرم، ۲۰۱۹). اجزای ABM اولیه مبتنی بر پروتکل ODD عبارت‌اند از:

(۱) هدف و الگو: هدف اصلی، شبیه‌سازی فرآیند تصمیم‌گیری مهاجرت نیروی انسانی بخش سلامت با تمرکز بر فاکتورهای فردی، حرفه‌ای، شبکه‌ای و محیطی است. مدل از ساختار دو مرحله‌ای تمایل و تصمیم الهام گرفته از نظریه رفتار برنامه‌ریزی‌شده و مدل‌های مرحله‌ای مهاجرت استفاده می‌کند (ون دالن هنکنز<sup>۲</sup>، ۲۰۰۸؛ کلابونده و ویلکنز، ۲۰۱۶).

جدول ۱. متغیرهای مدل عامل‌بنیان

ماهیت متغیر	متغیر	نام اختصاری	نوع موجودیت	توضیح
شخصی	سن	GND	عامل	سن تقویمی عامل
	جنسیت	AGE	عامل	جنسیت عامل
	وضعیت تأهل	MRTL	عامل	وضعیت تأهل عامل؛ مجرد یا متأهل.
	وضعیت فارغ‌التحصیلی	ACST	عامل	این ویژگی بیانگر در حال تحصیل یا دانش‌آموخته بودن عامل است.
	مقطع تحصیلی	LVL	عامل	آخرین مقطع تحصیلی عامی.
	سابقه فعالیت	EXP	عامل	سابقه فعالیت در ایران به‌عنوان کادر درمان.
مکانی	تصمیم مهاجرت	D	عامل	آیا فرد برای مهاجرت از ایران تصمیم خود را گرفته است؟ پاسخ‌ها دارای دو وضعیت است: خیر هنوز تصمیم قطعی نگرفته‌ام، بله تصمیم گرفته‌ام مهاجرت کنم.
	موقعیت مکانی	LOC	محیط	نشان‌دهنده سطح توسعه یافتگی جغرافیایی آخرین محل فعالیت یا تحصیل عامل.

1. Grimm et al., 2006; Railsback & Grimm, 2019

2. Van Dalen & Henkens

ماهیت متغیر	متغیر	نام اختصاری	نوع موجودیت	توضیح
شخصی	تعداد دوستان مهاجرت کرده از ابتدای تحصیل	FN	عامل	اندازه شبکه اجتماعی عامل و تأثیر آن بر تمایل به مهاجرت.

۲) موجودیت‌ها، متغیرهای حالت و مقیاس: مدل شامل دو نوع موجودیت اصلی است؛ عامل نیروی انسانی و محیط. هر عامل به عنوان عضوی از جامعه سلامت کشور و دارای ویژگی‌های فردی، محیطی و شبکه‌ای که متغیرهای حالت شخصی و محیطی ناهمگنی عامل‌ها را نشان می‌دهند. جدول ۱ جزئیات این متغیرها را ارائه می‌کند. مقیاس زمانی مدل سالانه ثبت می‌شود. مقیاس فضایی نیز به صورت طبقه‌بندی شده است و موقعیت مکانی عامل‌ها بر اساس چهار سطح مختلف، بر اساس توسعه یافتگی جغرافیایی، تعریف شده است. سطح تحلیل نیز فردی (در سطح عامل) و محیطی است.

۳) فرآیند تصمیم‌گیری: مدل عامل‌بنیان پیشنهادی از سه مرحله اصلی تشکیل شده است: مقداردهی اولیه، مدل یادگیری ماشین و شبیه‌سازی. در مرحله مقداردهی اولیه، عامل‌های نیروی انسانی تعریف می‌شوند. همان‌طور که در قسمت قبل اشاره شد؛ ویژگی‌های عامل‌ها مستقیماً از مجموعه داده‌های پیمایشی استخراج می‌شوند. در مرحله نهایی که در چارچوب کتابخانه MESA پیاده‌سازی شده است، تصمیم‌گیری نهایی هر عامل در یک گام زمانی واحد انجام می‌شود. با توجه به محدودیت داده‌های مقطعی، هیچ‌گونه به‌روزرسانی دینامیک یا تکرار زمانی در مدل لحاظ نشده است. هر عامل، مقدار احتمال مهاجرت خود را با آستانه تصمیم‌گیری کالیبره شده مقایسه کرده و تصمیم نهایی خود را اتخاذ می‌کند؛ به طوری که خروجی تصمیم نهایی نشان‌دهنده انتخاب مهاجرت یا عدم مهاجرت است. در پایان این گام زمانی، تعداد کل عامل‌هایی که تصمیم به مهاجرت گرفته‌اند محاسبه شده و به عنوان خروجی مدل برای ارزیابی عملکرد

آن ثبت می‌شود.

۴) مفاهیم طراحی: مدل بر پایه تفکر سیستمی طراحی شده است که در آن الگوهای کلان از تعاملات خرد عامل‌ها ناشی می‌شوند (ویلنسکی و رند<sup>۱</sup>، ۲۰۱۵). عقلانیت محدود مبنای تصمیم‌گیری عامل‌هاست؛ آن‌ها بر اساس اطلاعات ناقص و درک خود از محیط، رفتارشان را با تغییر شرایط به‌روز می‌کنند (بونابو<sup>۲</sup>، ۲۰۰۵). تعاملات عامل‌ها در محیط‌های آموزشی و حرفه‌ای، نقش مهمی در تقویت تمایل و تشدید تصمیم‌های فردی ایفا می‌کند (هینش و بیجک<sup>۳</sup>، ۲۰۱۹). تصمیم عامل‌ها تحت تأثیر محیط بروز پیدا می‌کند.

۵) مقداردهی اولیه و داده‌های ورودی: مقادیر اولیه متغیرهای حالت مدل، از داده‌های پیمایشی استخراج شده‌اند.

### مدل یادگیری ماشین

مدل‌سازی رفتار مهاجرتی عامل‌های نیروی انسانی بخش سلامت، به یک سؤال اساسی پاسخ می‌دهد: چگونه یک عامل (نیروی انسانی بخش سلامت) تصمیم نهایی برای ترک یا ماندن در کشور برای ادامه فعالیت حرفه‌ای خود را اتخاذ می‌کند؟ پاسخ به این سؤال، الگوهای مهاجرت عامل‌ها در سطح خرد را تعیین می‌کند و تأثیر مستقیمی بر رفتار سطح کلان سیستم، یعنی جریان کلی مهاجرت، دارد. در واقع، رفتار سطح کلان به‌عنوان یک ویژگی نوظهور از تصمیمات فردی عامل‌ها و تعاملات آن‌ها منتج می‌شود (نایوتن و همکاران، ۲۰۱۱؛ تورگوت و بوزداگ، ۲۰۲۳). استفاده از تکنیک‌های یادگیری ماشین و رویکرد داده‌محور، امکان استخراج مستقیم قوانین رفتاری برای عامل‌ها را از داده‌های خرد فراهم می‌آورد (آل ابراهیم دهکوری، ۲۰۲۳؛ ان و همکاران<sup>۴</sup>، ۲۰۲۳).

---

1. Wilensky & Rand

2. Bonabeau

3. Hinsch & Bijak

4. Ale Ebrahim Dehkordi et al., 2023; An et al., 2023

مراحل ساخت مدل ML باهدف پیش‌بینی احتمال مهاجرت به شرح زیر است: آماده‌سازی داده‌ها: با توجه به نامتوازن بودن کلاس‌های متغیر هدف، از روش نمونه‌گیری تصادفی کمتر ۱ برای متوازن‌سازی مجموعه داده استفاده شد تا از سوگیری مدل به سمت کلاس اکثریت جلوگیری شود. این مجموعه داده متوازن شده سپس به نسبت ۷۰٪ برای آموزش و ۳۰٪ برای آزمون تقسیم شد تا تعمیم‌پذیری مدل‌ها به‌طور صحیح ارزیابی شود. متغیرهای کیفی (وضعیت فارغ‌التحصیلی، وضعیت تأهل، جنسیت، محل فعالیت) با استفاده از روش کدگذاری OneHot به‌صورت باینری کدگذاری شدند. متغیرهای کمی همچنین با استفاده از روش نرمال‌سازی ماکسیم-مینم در مقیاس [۰،۱] قرار گرفتند (جیمز و همکاران، ۲۰۱۳؛ علی و همکاران، ۲۰۱۹؛ پراتیوی و همکاران<sup>۲</sup>، ۲۰۲۰).

انتخاب، آموزش و ارزیابی مدل: دو مدل مبتنی بر درخت جنگل تصادفی و XGBoost به دلیل عملکرد پیش‌بینی قوی در مسائل طبقه‌بندی انتخاب شدند. هر مدل در قالب یک پایپلاین شامل پیش‌پردازش و طبقه‌بندی آموزش داده شد. برای ارزیابی عملکرد، از معیارهای AUC (به‌عنوان معیار اصلی دقت کلی)، F1-Score (معیار توازن بین خطای نوع اول و دوم و معیار کلیدی برای انتخاب مدل در داده‌های متوازن شده) و Accuracy (سنجش درصد کل پیش‌بینی‌های صحیح) استفاده شد. همان‌طور که در جدول ۲ مشاهده می‌شود؛ مدل جنگل تصادفی در داده‌های آزمون عملکرد بهتری نسبت به XGBoost داشته و در تمام معیارها امتیاز بالاتری کسب کرده است. نتایج نشان می‌دهد که مدل‌ها توانایی تعمیم‌پذیری مناسبی دارند و هیچ‌گونه نشانه‌ای از بیش‌برازش یا کم‌برازش مشاهده نشده (گورسوی و بادور، ۲۰۲۱؛ زورنیچ و مارکوویچ<sup>۳</sup>، ۲۰۲۲).

جدول ۲. ارزیابی دقت مدل‌های یادگیری ماشین بر روی مجموعه داده‌های آموزش و آزمون

- 
1. Random Under-Sampling
  2. James et al., 2013; Ali et al., 2019; Pratiwi et al., 2020
  3. Gürsoy & Badur, 2021; Zornić & Marković, 2022

Model	Train	Test
XGBoost	AUC= 0.9987 F1-Score= 0.978 Accuracy= 0.9789	AUC= 0.803 F1-Score = 0.734 Accuracy= 0.733
RandomForest	AUC= 0.9996 F1-Score = 0.986 Accuracy= 0.986	AUC= 0.8304 F1-Score = 0.7521 Accuracy= 0.75

### تحلیل اهمیت ویژگی‌ها و وابستگی جزئی

با توجه به نتایج مدل جنگل تصادفی در بخش قبل، از تحلیل<sup>۱</sup> SHAP برای تبیین سهم هر یک از ویژگی‌ها در پیش‌بینی تصمیم به مهاجرت استفاده شد. این رویکرد بر پایه نظریه بازی‌های شاپلی توسعه یافته و سهم هر ویژگی را در خروجی مدل به صورت عددی و جهت‌دار محاسبه می‌کند و از نظر تفسیرپذیری، یکی از معتبرترین ابزارهای موجود در حوزه یادگیری ماشین محسوب می‌شود (همیلتون و پاپادوپولوس، ۲۰۲۴؛ هان و همکاران<sup>۲</sup>، ۲۰۲۵).

نمودار<sup>۳</sup> شکل ۱، تأثیر هر ویژگی بر تصمیم برای تمام نمونه‌ها نمایش داده شده است. این نمودار علاوه بر اینکه اهمیت نسبی ویژگی‌ها را نشان می‌دهد، جهت تأثیر آن‌ها را نیز مشخص می‌سازد. طبق نتایج به دست آمده دو ویژگی سن و تجربه عامل که اهمیت بیشتری دارند عمدتاً SHAP مثبت دارند، به این معنا که سن بالا و به تبع آن تجربه بیشتر، احتمال مهاجرت را افزایش می‌دهد. این نتیجه بیانگر آن است که افراد با تجربه کاری بالاتر ممکن است منابع مالی یا مهارت‌های لازم برای دنبال کردن فرصت‌های بهتر در خارج از کشور را داشته باشند. علاوه بر این، شبکه اجتماعی، مقطع تحصیلی، وضعیت تأهل و محل فعالیت در کلان‌شهرها نیز اثر قابل توجهی نشان دادند. نکته مهم آن است که وضعیت تأهل، چه در حالت مجرد و چه متأهل، تقریباً به یک اندازه در تصمیم مهاجرت نقش دارد؛ با این حال، به دلیل آنکه در داده‌های پیمایش تعداد متأهل‌ها بیشتر بوده است، سهم آن‌ها در سطح کلان

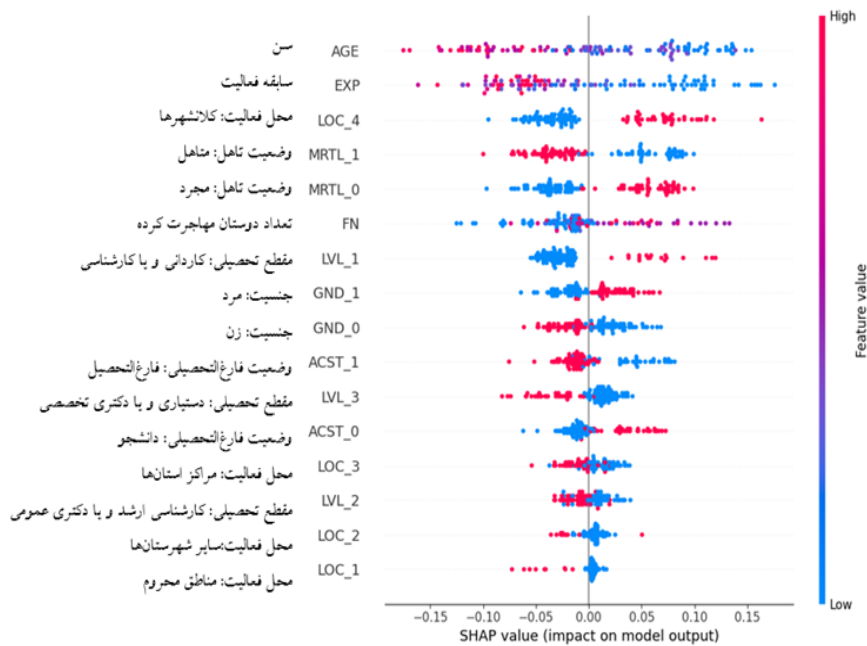
1. SHapley Additive exPlanations

2. Hamilton & Papadopoulos, 2024; Han et al., 2025

3. Beeswarm Plot with SHAP Values

پررنگ‌تر دیده می‌شود. این یافته با مطالعات پیشین همخوانی دارد که بر نقش ترکیبی فاکتورهای فردی و ساختاری در شکل‌گیری تصمیم مهاجرت تأکید کرده‌اند (جه<sup>۱</sup> و همکاران، ۲۰۱۸).

شکل ۱. نمودار اهمیت ویژگی‌ها به ترتیب مقدار SHAP



در رابطه با اهمیت محل فعالیت (متغیر محیطی)، نتایج نشان می‌دهد که اشتغال در کلان‌شهرها بیشترین تأثیر را در تصمیم به مهاجرت دارد. در مراتب بعد، مراکز استان‌ها و سایر شهرستان‌های استان‌ها به ترتیب محیط‌هایی هستند که تصمیم‌عامل را تقویت می‌کنند. در مقابل، فعالیت در مناطق محروم تقریباً نقشی در تعیین تصمیم‌عامل ندارد. این الگو نشان‌دهنده توزیع نابرابر فرصت‌ها و احتمالاً دسترسی به شبکه‌های مهاجرتی است که در مناطق شهری بزرگ‌تر متمرکز هستند، در حالی که فعالیت در مناطق محروم تأثیر ناچیزی بر تصمیم‌عامل دارد. این یافته با این ایده همخوانی دارد که پویایی‌های

شغلی و کسب‌وکارها الگوهای مهاجرت را شکل می‌دهند و بیش از آنکه توسط فاکتورهای دافعه در مناطق محروم هدایت شوند، توسط فرصت‌های کششی مقصد و شبکه‌های ارتباطی متمرکز در شهرهای بزرگ‌تر تقویت می‌شوند (داستمن و گلitz<sup>۱</sup>، ۲۰۱۱؛ چه و همکاران، ۲۰۱۸).

برخلاف انتظار اولیه، نتایج مدل نشان داد که افراد با تحصیلات پایین‌تر (مقطع کاردانی و کارشناسی) تمایل بیشتری به مهاجرت دارند. این یافته می‌تواند ناشی از محدودیت فرصت‌های شغلی داخلی برای این گروه، یا انعطاف‌پذیری بیشتر در پذیرش مشاغل عمومی در کشورهای مقصد باشد. در مقابل، افراد با تحصیلات بالاتر ممکن است به دلیل وابستگی‌های حرفه‌ای، تعهدات قانونی یا مسیرهای تخصصی، تمایل کمتری به مهاجرت نشان دهند. این نتیجه نشان می‌دهد که تصمیم مهاجرت الزاماً تابع سطح تحصیلات نیست و باید در تعامل با سایر ویژگی‌های فردی و ساختاری تحلیل شود (داستمن و گلitz، ۲۰۱۱؛ رحمتی، ۱۳۹۳).

در ویژگی‌های جمعیت‌شناختی، جنسی اثر کمتری نسبت به فاکتورهای اصلی دارد و نقش آن در مقایسه با سن، تجربه و محیط محدودتر است. وضعیت فارغ‌التحصیلی نیز اثر دارد اما نسبت به سایر ویژگی‌های کلیدی در مرتبه پایین‌تری قرار می‌گیرد. همان‌طور که در مطالعه احسانی چیمه<sup>۲</sup> و همکاران (۲۰۱۸) نسبت جنسیتی (مرد به زن) برای ماندن پزشکان ایرانی در مبدأ تفاوت معناداری نداشت.

برای بررسی دقیق‌تر نقش دو ویژگی کلیدی سن و تجربه کاری در پیش‌بینی تصمیم مهاجرت، از نمودارهای وابستگی جزئی استفاده شد (مولنار<sup>۳</sup>، ۲۰۲۳). این نمودارها روند میانگین احتمال پیش‌بینی‌شده مهاجرت را در برابر تغییرات هر ویژگی، با ثابت نگه‌داشتن سایر ویژگی‌ها، نمایش می‌دهند.

نمودار سمت چپ در شکل ۲ نشان می‌دهد که تأثیر سن بر احتمال مهاجرت کاملاً غیرخطی است و در سنین پایین (زیر ۳۰ سال)، منحنی نوسان دارد و مقدار پیش‌بینی‌شده

---


1. Dustmann & Glitz

2. Ehsani-Chimeh

3. Molnar

مهاجرت پایین است؛ این نشان می‌دهد که افراد جوان، به‌ویژه پس از فارغ‌التحصیلی و در آغاز مسیر شغلی، تمایل کمتری به مهاجرت دارند. از حدود ۳۰ سالگی به بعد، منحنی به‌طور پیوسته افزایش می‌یابد و در میان‌سالی به مقدار بالایی از احتمال مهاجرت می‌رسد. این روند با فرضیه‌ای همخوان است که افراد در میان‌سالی، پس از کسب تجربه و منابع مالی، آمادگی بیشتری برای مهاجرت دارند. همچنین در نمودار سمت راست مشاهده می‌شود که در سنین بالا که سابقه کاری بیشتر است، عامل‌ها پس از افت احتمال مهاجرت مجدداً با مقادیر بالاتر احتمال مهاجرت همراه‌اند. این نتیجه نشان می‌دهد که تأثیر مثبت سن بر تصمیم مهاجرت، زمانی تقویت می‌شود که با تجربه کاری بالا همراه باشد. به‌عبارتی تصمیم به مهاجرت تحت تأثیر ترکیبی از سن و تجربه کاری است. صرفاً سن بالا کافی نیست؛ بلکه ترکیب سن بالا با سابقه کاری قابل توجه دلیل اصلی افزایش احتمال مهاجرت است (نایوتن و همکاران، ۲۰۱۱؛ هان و همکاران، ۲۰۲۵). این تعامل غیرخطی و وابسته، اهمیت استفاده از مدل‌های یادگیری ماشین را در کشف الگوهای پیچیده رفتاری نشان می‌دهد که برخلاف رویکردهای آماری سنتی، به‌جای تمرکز بر روابط خطی، تعاملات پیچیده را در نظر می‌گیرند که برای مدل‌سازی رفتارهای ضروری است (چن و همکاران، ۲۰۰۸؛ ان و همکاران، ۲۰۲۳).

شکل ۲. نمودار وابستگی جزئی سن و تجربه به احتمال تصمیم مهاجرت



## پیاده‌سازی و ارزیابی ABM

در این مرحله، مدل عامل‌بنیان مهاجرت نیروی انسانی بخش سلامت، با استفاده از زبان برنامه‌نویسی پایتون و چارچوب MESA پیاده‌سازی شد (کازیل ۱ و همکاران، ۲۰۲۰). در این مدل، الگوریتم جنگل تصادفی آموزش دیده به‌عنوان فرا-مدل رفتاری عمل می‌کند که مسئولیت تعیین تصمیم هر عامل در هر گام تصمیم را بر عهده دارد. هر عامل داده‌های مربوط به ویژگی‌های خرد خود را به‌عنوان ورودی به مدل جنگل تصادفی می‌دهند و خروجی مدل، احتمال پیوسته قصد مهاجرت را تعیین می‌کند. به‌عبارتی خروجی نهایی مدل یادگیری ماشین، مجموع وزنی امتیازات درخت‌های تصمیم<sup>۲</sup> است که با استفاده از تابع سیگموئید<sup>۳</sup> (لجستیک) به‌احتمال بین [۰، ۱] تبدیل می‌شود (لامپرتی و همکاران، ۲۰۱۸؛ ژانگ و ژائو<sup>۴</sup>، ۲۰۲۶). این فرمول مطابق روابط ۱، رفتار هر عامل را در محیط شبیه‌سازی تعیین می‌کند:

$$S_{score,i} = \sum_{k=1}^K f_k(x_i) \quad \text{for all } i = 1, 2, \dots, N$$

$$\&$$

$$p_{intend,i} = \frac{1}{1 + e^{-S_{score,i}}} \quad (1)$$

در این فرمول؛ K تعداد درختان در مدل جنگل تصادفی و  $f_k(X_i)$  امتیاز پیش‌بینی شده توسط درخت k برای عامل i (از تعداد کل N) با مجموعه ویژگی  $X_i$  است.  $P_{intend,i}$  احتمال نهایی قصد به مهاجرت عامل i را نشان می‌دهد. سپس، این احتمال پیوسته به یک تصمیم گسسته تبدیل می‌شود. این انتقال با مقایسه  $P_{intend,i}$  با آستانه تصمیم کالیبره شده (T) مطابق رابطه ۲ صورت می‌گیرد:

$$Decision_i = \begin{cases} 1 & \text{if } p_{intend,i} \geq T \\ & \text{if } p_{intend,i} < T \end{cases} \quad (2)$$

- 
1. Kazi
  2. Score,i
  3. Sigmoid
  4. Lamperti et al., 2018; Zhang & Zhao, 2026

چنانچه مقدار احتمال نهایی از آستانه بهینه بیشتر شود؛ عامل اقدام به مهاجرت می کند (لامپرتی و همکاران، ۲۰۱۸، تورگوت و بوزداگ، ۲۰۲۳، گوتیرز- لویز<sup>۱</sup> و همکاران، ۲۰۲۳). در بخش کالیبراسیون مقدار بهینه T تعیین شده است.

در ادامه این بخش بررسی سهم متغیرهای کلیدی در عملکرد نهایی مدل رفتاری الگوریتم یادگیری ماشین و توجیه استفاده از مجموعه کامل ویژگی‌ها به عنوان قانون تصمیم‌گیری عامل در محیط شبیه‌سازی انجام گرفته است. نتایج این مقایسه در جدول ۳ ارائه می‌شود.

جدول ۳. مقایسه عملکرد مدل‌های XGBoost بر اساس ترکیب ویژگی‌ها

نام مدل	ویژگی‌های ورودی	AUC	F1-Score	Accuracy
مدل ۱	تمام ویژگی‌ها به جز FN	0.7986	0.6667	0.6724
مدل ۲	AGE, EXP, MRTL, LOC	0.7875	0.6942	0.6810
مدل ۳	تمام ویژگی‌ها (مدل کامل)	0.8227	0.7368	0.7414

نتایج حاصل از جدول ۳، برتری مدل ۳ را در پیش‌بینی رفتار مهاجرتی عامل‌ها تأیید می‌کند. مهم‌ترین نکته در تحلیل حساسیت، تفاوت عملکرد بین مدل ۱ و مدل ۳ است. مدل ۱ صرفاً متغیر اثر شبکه (تعداد دوستان مهاجرت کرده) را که یک عامل تعاملی و اجتماعی است، حذف می‌کند. این حذف منجر به کاهش شدید AUC و F1-Score از شده است. این کاهش عملکرد، سهم حیاتی متغیر تعاملی FN را در تعیین تصمیم به مهاجرت عامل‌ها به صورت عددی تأیید می‌کند. این نتیجه با ماهیت عامل بنیان بودن مدل سازگار است و نشان می‌دهد که نادیده گرفتن تعاملات اجتماعی، همان‌طور که در مدل‌های تئوری صرف رایج است، منجر به خطای قابل توجهی در پیش‌بینی جریان مهاجرت در سطح کلان خواهد شد.

مدل ۲ تنها از ویژگی‌های اصلی که بالاترین اهمیت را در تحلیل SHAP داشتند استفاده می‌کند. با این حال، این مدل ضعیف‌ترین عملکرد را به ثبت رسانده است. این


موضوع نشان می‌دهد که هرچند برخی ویژگی‌ها به‌طور میانگین نقش بالاتری دارند، اما حذف سایر ویژگی‌ها منجر به نادیده گرفتن بخش مهمی از رفتار عامل‌ها می‌شود. در نهایت، نتایج تحلیل حساسیت به‌وضوح انتخاب مدل ۳ را به‌عنوان مدل رفتاری نهایی در پیاده‌سازی مدل عامل‌بنیان توجیه می‌کند، زیرا این مدل بهترین توانایی را در جذب و انعکاس پیچیدگی‌ها و اثرات متقابل عوامل فردی و تعاملی در تصمیم‌گیری مهاجرت عامل‌ها فراهم می‌آورد.

### کالیبراسیون آستانه تصمیم عامل

همان‌طور که در بخش قبل مطرح شد؛ خروجی مدل جنگل تصادفی یک احتمال پیوسته برای قصد مهاجرت عامل است. برای اینکه عامل بتواند در هر گام تصمیم یک تصمیم دودویی (مهاجرت یا عدم مهاجرت) اتخاذ کند، این احتمال باید با یک آستانه تصمیم مقایسه شود. این آستانه، حساسیت مدل رفتاری عامل را تعیین می‌کند. هدف از کالیبراسیون، یافتن آستانه بهینه است که عملکرد مدل را در تبدیل احتمال به تصمیم نهایی، به بالاترین سطح برساند. از آنجا که داده‌های آموزشی ما برای کلاس هدف (مهاجرت) متوازن شده‌اند، از معیار F1-Score برای تعیین آستانه بهینه استفاده شد، زیرا این معیار یک توازن محتاطانه بین دقت و فراخوانی ایجاد می‌کند.

با جستجو در محدوده آستانه‌های ممکن، F1-Score ماکزیمم شده و آستانه بهینه با مقدار ۰,۴۳۶۲ شناسایی شد. این آستانه حداکثر F1-Score برابر با ۰,۹۹۷۴ را به دست آورد. اعمال این آستانه بر روی داده‌های متوازن‌شده، تعداد عامل‌های با قصد مهاجرت را ۱۹۳ نفر، از کل نمونه، پیش‌بینی کرد که بسیار نزدیک به مقدار واقعی ۱۹۲ نفر در داده‌های متوازن‌شده است. در ادامه شکل ۳ و شکل ۴ تأثیر این آستانه را بر عملکرد و نرخ پیش‌بینی قصد مهاجرت نشان می‌دهند.


شکل ۳. بهینه‌سازی آستانه تصمیم بر اساس معیار F1 در مدل پیش‌بینی مهاجرت



نمودار شکل ۳ نشان می‌دهد که با تغییر  $T$  از ۰ به ۱، عملکرد مدل با معیار F1-Score چگونه تغییر می‌کند. این نمودار اثبات می‌کند که ۰,۴۳۶۲ بهترین نقطه برای تبدیل خروجی احتمالی مدل به یک تصمیم قطعی است، زیرا در این نقطه معیار مذکور به بالاترین مقدار خود می‌رسد و کمترین خطا را در طبقه‌بندی هر دو کلاس داریم.

نمودار شکل ۴ نشان‌دهنده حساسیت مدل در سطح کلان به تغییرات آستانه است و تأیید می‌کند که با افزایش  $T$ ، تعداد عامل‌هایی که تصمیم به مهاجرت می‌گیرند، کاهش می‌یابد. خط چین سبزرنگ نشان‌دهنده تعداد واقعی مهاجران در داده‌های متوازن شده است. خط چین قرمز نیز آستانه بهینه را نشان می‌دهد و تأیید می‌کند تعداد پیش‌بینی شده (تقریباً ۱۹۳ نفر) به خط واقعی بسیار نزدیک است. در نتیجه آستانه بهینه انتخاب شده برای دقت در سطح خرد (معیار F1-Score)، منجر به دقت بالا در پیش‌بینی نرخ کلان (تعداد کل مهاجران) نیز می‌شود که یک اعتبارسنجی قوی برای مدل رفتاری عامل بنیان داده‌محور است.

شکل ۴. تحلیل حساسیت نرخ پیش‌بینی مهاجرت نسبت به آستانه تصمیم



### اعتبارسنجی نهایی ABM

در این مرحله، عملکرد مدل رفتاری مبتنی بر یادگیری ماشین با یک مدل نظریه محور استاندارد مقایسه شده تا توانایی آن در بازتولید رفتار عامل‌ها به صورت کمی اعتبارسنجی شود. مدل الگوریتم جنگل تصادفی به عنوان نماینده رویکرد داده‌محور انتخاب شد که قادر است روابط غیرخطی و تعاملات پیچیده میان ویژگی‌ها را بدون فرض‌های قبلی استخراج کند. در مقابل، رگرسیون لجستیک به عنوان مدل تنوری محور در نظر گرفته شد که بر پایه فرض رابطه خطی میان متغیرها عمل می‌کند و از نظر تفسیرپذیری، ساختار ساده‌تری دارد. در مطالعات مدل‌سازی عامل‌بنیان، به منظور دستیابی به دقت بالا در پیش‌بینی، الگوریتم‌های مبتنی بر یادگیری ماشین اغلب در برابر مدل‌های نظریه‌محور سنتی ارزیابی می‌شوند (تورگوت و بوزداگ، ۲۰۲۳). این مقایسه به درک بهتر توانایی هر رویکرد در مدل‌سازی تصمیم‌گیری‌های پیچیده عامل‌ها کمک می‌کند (ال‌ابراهیم دهکردی و همکاران، ۲۰۲۳).

هر دو مدل بر روی داده متوازن آموزش داده شدند و پس از اعمال پیش‌پردازش یکسان، خروجی آن‌ها بر روی مجموعه آزمون ارزیابی شد. برای تبدیل خروجی پیوسته مدل‌ها به تصمیم گسسته، آستانه تصمیم بهینه اعمال شد. جدول ۴ نتایج این اعتبارسنجی را

نشان می‌دهد. مدل جنگل تصادفی در تمامی معیارهای عملکردی، از جمله قدرت تفکیک (معیار AUC)، تعادل بین دقت و پوشش (معیار F1) و دقت کلی (معیار Accuracy)، عملکرد بهتری نسبت به مدل خطی رگرسیون لجستیک داشت. این برتری نشان می‌دهد که رویکرد داده‌محور می‌تواند رفتار عامل‌ها را با دقت بالاتری مدل‌سازی کند، بدون آنکه به فرض‌های محدودکننده نظری وابسته باشد.

اگرچه مدل داده‌محور زمان آموزش بیشتری نسبت به مدل تئوری‌محور دارد، اما عملکرد آن در پیش‌بینی دقیق رفتار عامل‌ها، قدرت تفکیک بالا و انطباق نرخ کلان، آن را به گزینه‌ای برتر برای مدل‌سازی رفتاری تبدیل کرده است. در اینجا، کیفیت پیش‌بینی بر سرعت اجرا اولویت دارد.

جدول ۴. اعتبارسنجی نهایی و مقایسه عملکرد مدل‌های رفتاری

مدل	AUC-ROC	F1-Score	Accuracy	زمان آموزش (ثانیه)	زمان آزمون (ثانیه)
جنگل تصادفی (مدل داده‌محور)	0.8205	0.6364	0.7155	0.2000	0.0500
رگرسیون لجستیک (مدل نظریه‌محور)	0.7782	0.7258	0.7069	0.0300	0.0200

علاوه بر ارزیابی عملکرد در سطح عامل‌ها، اعتبارسنجی آماری در سطح کلان نیز انجام شد تا میزان انطباق مدل با نرخ واقعی مهاجرت بررسی شود. با اعمال آستانه بهینه ۰٫۴۵۳۴ بر روی کل مجموعه داده، مدل داده‌محور تعداد ۱۹۳ عامل (از ۳۸۴ نمونه) با قصد مهاجرت را پیش‌بینی کرد. این مقدار بسیار نزدیک به تعداد واقعی ۱۹۲ عامل در مجموعه داده متوازن شده است. این انطباق بالا، اعتبار آماری مدل رفتاری عامل‌بیان داده‌محور را در شبیه‌سازی جریان‌های کلان مهاجرت تأیید می‌کند و نشان می‌دهد که مدل نه تنها در سطح خرد، بلکه در سطح کلان نیز قابل اعتماد است.

## بحث و نتیجه‌گیری

این مطالعه باهدف توسعه یک چارچوب مدل‌سازی عامل‌بنیان مبتنی بر داده برای شبیه‌سازی رفتار مهاجرتی نیروی انسانی بخش سلامت ایران انجام شد. نوآوری اصلی این رویکرد، ادغام مستقیم و غیرخطی قوانین رفتاری استخراج‌شده از مدل یادگیری ماشین جنگل تصادفی در هسته تصمیم‌گیری عامل‌ها در ABM بود. این امر به مدل اجازه داد تا به‌جای اتکا به فرضیات تئوری خطی، الگوهای پیچیده و تعاملی مهاجرت را مستقیماً از داده‌های خرد شناسایی کند.

نتایج نشان داد که مدل انتخابی، با کسب برتری قاطعی نسبت به مدل نظریه‌محور رگرسیون لجستیک در پیش‌بینی قصد مهاجرت عامل‌ها دارد. این برتری، توجه می‌کند که رابطه بین ویژگی‌های فردی و تصمیم مهاجرت، ماهیتی غیرخطی داشته و نیازمند ابزارهای داده‌محور است. از طرفی تحلیل SHAP، عوامل کلیدی مؤثر بر تصمیم‌گیری را مشخص کرد که سن و سابقه کار بالاترین سهم را در افزایش احتمال مهاجرت دارند. تحلیل وابستگی جزئی نشان داد که این تأثیر غیرخطی بوده و اوج تمایل به مهاجرت در میان‌سالی، پس از کسب تجربه و مهارت‌های لازم برای جذب در بازارهای بین‌المللی رخ می‌دهد.

وجود متغیر تعداد دوستان مهاجرت‌کرده در مدل ۳، عملکرد مدل را به‌طور قابل توجهی نسبت به مدل ۱ بهبود بخشید. این یافته، نقش حیاتی شبکه‌های اجتماعی در کاهش عدم قطعیت و تسهیل فرآیند مهاجرت نیروی متخصص را تأیید می‌کند.

کالیبراسیون مدل، آستانه بهینه تصمیم را برابر با ۰,۴۳۶۲ تعیین کرد که اندکی پایین‌تر از آستانه پیش‌فرض ۰,۵ است. این امر نشان می‌دهد که نیروی انسانی بخش سلامت، نسبت به احتمال مهاجرت، حساسیت بالایی دارد و حتی با کمی بیشتر شدن احتمال، تصمیم به مهاجرت عملی می‌شود. این حساسیت بالا، بیانگر وجود فاکتورهای قوی دافعه در محیط مبدأ است که باعث می‌شود عامل‌ها با اطمینان کمی نیز به سمت خروج سوق پیدا کنند.

نتایج این پژوهش می‌تواند به‌عنوان یک ابزار شبیه‌سازی قدرتمند برای سیاست‌گذاران عمل کند. با توجه به اهمیت بالای سن، تجربه و عامل شبکه، سیاست‌های حفظ نیروی





انسانی باید بر تعدیل محیط کاری متخصصان میان سال متمرکز شود تا این گروه حیاتی از خروج بازداشته شوند.

این مطالعه با وجود ارائه چارچوب نوین مدل سازی، از چند محدودیت روش شناختی برخوردار است که در تفسیر و تعمیم پذیری نتایج باید مدنظر قرار گیرند. نخست، نمونه پژوهش مشتمل بر داده های پیمایش ملی مهاجرت نخبگان بخش سلامت است که اگرچه از تنوع مناسبی در متغیرهای کلیدی جمعیت شناختی و حرفه ای برخوردار است، اما عمدتاً جامعه دانشگاهی و مراکز دولتی حاضر در کشور را پوشش می دهد و ممکن است به طور کامل نماینده نیروهای شاغل در بخش خصوصی یا افرادی که پیش تر مهاجرت کرده اند نباشد. باین حال، استفاده از این نمونه به دلیل دسترسی به مهم ترین منبع داده های خرد ملی در حوزه مهاجرت نیروی سلامت و تنوع درونی آن برای آموزش و آزمون مدل یادگیری ماشین، توجیه پذیر است. محدودیت مهم دیگر، مقطعی بودن داده ها و به تبع آن ایستایی مدل پیشنهادی است. افزودن این بعد زمانی، نه تنها قابلیت تحلیل مسیرهای مهاجرت را فراهم می آورد، بلکه زمینه ارزیابی سناریوهای مختلف سیاستی در پاسخ به تحولات آتی را نیز ایجاد خواهد نمود؛ بنابراین، پژوهش حاضر به مثابه گام نخست در ارائه یک زیرساخت روش شناختی یکپارچه عمل می کند که قابلیت تکمیل و گسترش به سوی مدل های پویا و پیش بین را دارد.

## تعارض منافع

نویسندگان این پژوهش تعارض منافی ندارند.

### ORCID

Homa Khodadadi		<a href="https://orcid.org/0009-0000-3760-5976">https://orcid.org/0009-0000-3760-5976</a>
Mostafa Kazemi		<a href="https://orcid.org/0000-0002-5084-5752">https://orcid.org/0000-0002-5084-5752</a>
Naser Motahari Farimani		<a href="https://orcid.org/0000-0001-6828-6736">https://orcid.org/0000-0001-6828-6736</a>
Seyyed Mohammad Tabatabaei		<a href="http://orcid.org/0000-0002-3153-8968">http://orcid.org/0000-0002-3153-8968</a>

## منابع

۱. حسین دوست، سمانه، زمانی، بهمن و فاطمی، افسانه. (۱۴۰۱). ارزیابی ابزارهای مدل‌سازی و شبیه‌سازی مبتنی بر عامل بر اساس استاندارد ایزو ۲۵۰۱۰. پژوهش‌های نوین در تصمیم‌گیری، (۱۷)، ۶۱-۸۶. <https://sid.ir/paper/1045807/fa>
۲. حق‌دوست، ع.، نوری حکمت، س.، طلایی، ب.، ملک‌پور افشار، ر.، صلواتی، ب.، بهزادی، ف.، بذرافشان، ع. (۱۴۰۱). بررسی عوامل مؤثر بر مهاجرت نیروی انسانی در حوزه سلامت در سال ۱۴۰۱. نشریه فرهنگ و ارتقای سلامت فرهنگستان علوم پزشکی، (۲)۶، ۲۰۵-۲۱۲. <http://dx.doi.org/10.22034/6.2.2>
۳. رحمتی، ح. (۱۳۹۳). نقش مهاجرت سرمایه‌های فکری بر جریان دانش، پایان‌نامه کارشناسی ارشد، دانشگاه الزهرا (س).
۴. رصدخانه مهاجرت ایران. (۱۴۰۱). مهاجرت نیروی انسانی حوزه سلامت در جهان و ایران. در سالنامه مهاجرتی ایران ۱۴۰۱ (صص. ۳۶۶-۳۹۷). تهران: رصدخانه مهاجرت ایران. <https://imobs.ir/outlook/detail/22>
۵. صفای پور، م. و محلی، ی. (۱۳۹۶). بررسی عوامل تأثیرگذار بر مهاجرت از شهر با استفاده از مدل معادلات ساختاری و تکنیک تحلیل سلسله مراتبی فازی (مطالعه موردی: شهر اهواز). مطالعات محیطی هفت حصار، (۲۲) ۶، ۸۱-۹۶. <http://hafthesar.iauh.ac.ir/article-1-500-fa.html>
۶. علماء‌الدینی، فرشید، فاطمی، رزیتا، رنجبران جهرمی، هومن، اصغری رودسری، الهام، اسکندری، شروین، توکلی، حمیدرضا، رضوی، اوستا، فیض زاده، علی، حسین پور، احمدرضا، میرزاصادقی، علیرضا و اردلان، علی. (۱۳۸۴). میزان تمایل به مهاجرت و علل آن در پزشکان ایرانی. تحقیقات نظام سلامت حکیم (حکیم)، (۳)۸، ۹-۱۵. <https://sid.ir/paper/29245/fa>
۷. غفاریان، ع.، فردوسی، م. (۱۴۰۱). مهاجرت کادر درمان؛ زنگ خطر به صدا درآمده است؟ مجله علمی دانشگاه علوم پزشکی بیرجند، (۴)۲۹، ۳۹۷-۴۰۱. <http://dx.doi.org/10.34785/bums024.2022.030>

۸. فرتوک زاده، حمیدرضا و اشراقی، حسن. (۱۳۸۷). مدل‌سازی دینامیکی پدیده مهاجرت نخبگان و نقش نظام آموزش عالی در آن. *پژوهش و برنامه‌ریزی در آموزش عالی*، ۱۴(۴) (۵۰)، ۱۳۹-۱۴۰.

<https://sid.ir/paper/68087/fa>

۹. فرح‌بخش، م.، مدیری، م.، خاتمی فیروزآبادی، س.م.ع.م.، پورابراهیمی، ع. (۱۴۰۱). شبیه‌سازی چرخه عمر صنعت برق با استفاده از شبیه‌سازی عامل‌بنیان. *چشم‌انداز مدیریت صنعتی*، ۱۲(۴)، ۳۵-۹.

<https://doi.org/10.52547/jimp.12.4.9>

۱۰. ودادهیر، ابوعلی و اشراقی، سمیه. (۱۳۹۸). گرایش به مهاجرت به خارج در جامعه پزشکی ایران: مطالعه‌ای کیفی. *پژوهش و برنامه‌ریزی در آموزش عالی*، ۲۵(۲)، ۲۳-۴۲.

<https://sid.ir/paper/68063/fa>

## References

1. Ale Ebrahim Dehkordi, M., Lechner, J. M., Ghorbani, A., Nikolic, I., Chappin, É., & Herder, P. M. (2023). Using machine learning for agent specifications in agent-based models and simulations: A critical review and guidelines. *Journal of Artificial Societies and Social Simulation*, 26(1). <https://doi.org/10.18564/jasss.5016>
2. Ali, H., Salleh, M., Talpur, K., Ullah, A., Ahmad, A., & Naseem, R. (2019). A review on data preprocessing methods for class imbalance problem. 390-397. <https://doi.org/10.14419/ijet.v8i3.29508>
3. An, L., Grimm, V., Bai, Y., Sullivan, A., Turner, B. L. II, Malleson, N., Heppenstall, A., Vincenot, C., Robinson, D., Ye, X., Liu, J., Lindkvist, E., & Tang, W. (2023). Modeling agent decision and behavior in the light of data science and artificial intelligence. *Environmental Modelling & Software*, 166, 105713. <https://doi.org/10.1016/j.envsoft.2023.105713>
4. Asadi, H., Ahmadi, B., Nejat, S., Akbari Sari, A., Garavand, A., Almasian Kia, A., & Hasoumi, M. (2018). Factors influencing the migration of Iranian healthcare professionals: A qualitative study. *PLoS ONE*, 13(6), e0199613. <https://doi.org/10.1371/journal.pone.0199613>
5. Badham, J., Chattoe-Brown, E., Gilbert, N., Chalabi, Z., Kee, F., & Ruth F. Hunter. (2018). Developing agent-based models of complex health behaviour. *Health & Place*, 54, 170-177. <https://doi.org/10.1016/j.healthplace.2018.08.022>
6. Bandini, S., Manzoni, S., & Vizzari, G. (2009). Agent based modeling and simulation: An informatics perspective. *Journal of Artificial Societies and Social Simulation*, 12(4), 1-4. <https://ideas.repec.org/a/jas/jasssj/2009-69-1.html>

7. Beyer, R. M., Schewe, J., & Abel, G. J. (2023). Modeling climate migration: dead ends and new avenues. *Frontiers in Climate*, 5(1212649). <https://doi.org/10.3389/fclim.2023.1212649>
8. Bonabeau, B. (2002). Agent-based modeling: Methods and techniques for simulating human systems. *PNAS*, 99(suppl 3), 7280–7287. <http://dx.doi.org/10.1073/pnas.082080899>
9. Carling, Jørgen (2011) The European Paradox of Unwanted Migration, in A Threat Against Europe? Security, Migration and Integration. Brussels: Brussels University Press (VUB) (33–46). <https://www.prio.org/publications/31>
10. Chen, T., & Guestrin, C. (2016). XGBoost: A scalable tree boosting system. *CoRR*, abs/1603.02754. <https://doi.org/10.1145/2939672.2939785>
11. Chen, Z., Jiang, S., Lu, M., & Sato, H. (2008). How do heterogeneous social interactions affect the peer effect in rural-urban migration?: Empirical evidence from China. *SSRN Electronic Journal*. <https://doi.org/10.2139/ssrn.1360689>
12. Connell, J. (2014). The two cultures of health worker migration: A Pacific perspective. *Social Science & Medicine*, 116, 73–81. <https://doi.org/10.1016/j.socscimed.2014.06.043>
13. De Luca, G., Lampoltshammer, T. J., Parven, S., & Scholz, J. (2022). A literature review on the usage of agent-based modelling to study policies for managing international migration. *Social Sciences*, 11(8), 356. <http://dx.doi.org/10.3390/socsci11080356>
14. Degfachew, T. N., Dilnesaw, M. M., & Massa, M. M. (2025). Impact of international labor migration on crop production in eastern Amhara, Ethiopia. A multinomial endogenous switching regression model analysis. *Ecological Frontiers*, 45(3), 768–779. <https://doi.org/10.1016/j.ecofro.2025.02.004>
15. Di Caprio, D., Sironi, S., Lan, F.-Y., & Rostamkhani, R. (2025). A data-driven multicriteria decision model for healthcare workforce retention strategies. *Healthcare Analytics* (New York, N.Y.), 8(100403), 100403. <https://doi.org/10.1016/j.health.2025.100403>
16. Dustmann, C., & Glitz, A. (2011). Migration and education. In E. A. Hanushek, S. Machin, & L. Woessmann (Eds.), *Handbook of the Economics of Education* (Vol. 4, pp. 327–434). Elsevier. <https://doi.org/10.1016/B978-0-444-53444-6.00004-3>
17. Eaton, J., Baingana, F., Abdulaziz, M., Obindo, T., Skuse, D., & Jenkins, R. (2023). The negative impact of global health worker migration, and how it can be addressed. *Public Health*, 225, 254–257. <https://doi.org/10.1016/j.puhe.2023.09.014>

18. Ehsani-Chimeh, E., Majdzadeh, R., Delavari, S., Najafi Gharebelagh, M., Rezaei, S., & Homaie Rad, E. (2018). Physicians' retention rate and its effective factors in the Islamic Republic of Iran. *East Mediterr Health J.*, 24(9), 830–837. <https://doi.org/10.26719/2018.24.9.830>
19. Filatova, T., Verburg, P. H., Parker, D. C., & Stannard, C. A. (2013). Spatial agent-based models for socio-ecological systems: Challenges in design and validation. *Environmental Modelling & Software*, 45, 1–7. <https://doi.org/10.1016/j.envsoft.2013.03.017>
20. Fu, Z., & Hao, L. (2018). Agent-based modeling of China's rural–urban migration and social network structure. *Physica A*, 490, 1061–1075. <https://doi.org/10.1016/j.physa.2017.08.145>
21. Ge, J., Polhill, J. G., Craig, T., & Liu, N. (2018). From oil wealth to green growth - An empirical agent-based model of recession, migration and sustainable urban transition. *Environmental Modelling & Software*, 107, 119–140. <https://doi.org/10.1016/j.envsoft.2018.05.017>
22. Grebeniyk, A., Aleshkovski, I., & Maksimova, A. (2021). The impact of labor migration on human capital development. *Migraciones Internacionales*, 12, 0. <https://doi.org/10.33679/rmi.v1i1.2190>
23. Grimm, V., Berger, U., Bastiansen, F., Eliassen, S., Ginot, V., Giske, J., & DeAngelis, D. L. (2006). A standard protocol for describing individual-based and agent-based models. *Ecological Modelling*, 198(1–2), 115–126. <https://doi.org/10.1016/j.ecolmodel.2006.04.023>
24. Grimm, V., et al. (2020). The ODD protocol for describing agent-based and other simulation models: A second update to improve clarity, replication, and structural realism. *Journal of Artificial Societies and Social Simulation*, 23(2), 7. <https://doi.org/10.18564/jasss.4259>
25. Gürsoy, F., & Badur, B. (2021). An agent-based modelling approach to brain drain. *IEEE Transactions on Computational Social Systems*. <https://doi.org/10.1109/TCSS.2021.3066074>
26. Gutiérrez-López, A., González-Serrano, F.-J., & Figueiras-Vidal, A. R. (2023). Optimum Bayesian thresholds for rebalanced classification problems using class-switching ensembles. *Pattern Recognition*, 135, 109158. <https://doi.org/10.1016/j.patcog.2022.109158>
27. Hamilton, R. I., & Papadopoulos, P. N. (2023). Using SHAP values and machine learning to understand trends in the transient stability limit. *IEEE Transactions on Power Systems*, 39(1), 1384–1397. <https://doi.org/10.1109/tpwrs.2023.3248941>
28. Han, J., Guzman, J. A., & Chu, M. L. (2025). Prediction of gully erosion susceptibility through the lens of the SHapley Additive exPlanations (SHAP) method using a stacking ensemble model. *Journal of Environmental Management*, 383, 125478. <https://doi.org/10.1016/j.jenvman.2025.125478>

29. Hassani-Mahmooei, B., & Parris, B. W. (2012). Climate change and internal migration patterns in Bangladesh: An agent-based model. *Environment and Development Economics*, 17(6), 763–780. <https://doi.org/10.1017/S1355770X12000290>
30. Hinsch, M., & Bijak, J. (2019). *Rumours lead to self-organized migration routes*.
31. Holmes, G. M., & Fraher, E. P. (2017). Developing physician migration estimates for workforce models. *Health Services Research*, 52, 529–545. <https://doi.org/10.1111/1475-6773.12656>
32. James, G., Witten, D., Hastie, T., & Tibshirani, R. (2013). *An Introduction to Statistical Learning* (8th ed., Vol. 103). Springer New York. <https://doi.org/10.1007/978-1-4614-7138-7>
33. Kazil, J., Masad, D., & Crooks, A. (2020). Utilizing python for agent-based modeling: The Mesa framework. In *Lecture Notes in Computer Science. Social, Cultural, and Behavioral Modeling* (pp. 308–317). [https://doi.org/10.1007/978-3-030-61255-9\\_30](https://doi.org/10.1007/978-3-030-61255-9_30)
34. Kennan, J., & Walker, J. R. (2013). *Modeling individual migration decisions*. In A. F. Constant & K. F. Zimmermann (Eds.), *International handbook on the economics of migration* (pp. 39–54). Edward Elgar Publishing.
35. Khodabandelu, A., & Park, J. (2021). Agent-based modeling and simulation in construction. *Automation in Construction*, 131, 103882. <https://doi.org/10.1016/j.autcon.2021.103882>
36. Klabunde, A., & Willekens, F. (2016). Decision-making in agent-based models of migration: State of the art and challenges. *European Journal of Population*, 32(1), 73–97. <https://doi.org/10.1007/s10680-015-9362-0>
37. Kniveton, D., Smith, Ch., & Wood, Sh. (2011). Agent-based model simulations of future changes in migration flows for Burkina Faso. *Global Environmental Change*, 21(Supplement 1), S34–S40. <https://doi.org/10.1016/j.gloenvcha.2011.09.006>
38. Lamperti, F., Roventini, A., & Sani, A. (2018). Agent-based model calibration using machine learning surrogates. *Journal of Economic Dynamics & Control*, 90, 366–389. <https://doi.org/10.1016/j.jedc.2018.03.011>
39. Leitão, C. A., Salvador, G. L. de O., Idowu, B. M., & Dako, F. (2024). Drivers of global health care worker migration. *Journal of the American College of Radiology*, 21(8), 1188–1193. <https://doi.org/10.1016/j.jacr.2024.03.005>
40. Lundberg, S. M., Erion, G., Chen, H., DeGrave, A., Prutkin, J. M., Nair, B., & Lee, S.-I. (2020). From local explanations to global understanding

- with explainable AI for trees. *Nature Machine Intelligence*, 2(1), 56–67. <https://doi.org/10.1038/s42256-019-0138-9>
41. Marini, M., Chokani, N., & Abhari, R. S. (2019). Immigration and future housing needs in Switzerland: Agent-based modelling of agglomeration Lausanne. *Computers, Environment and Urban Systems*, 78, 101400. <https://doi.org/10.1016/j.compenvurbsys.2019.101400>
42. Molnar, C., Freiesleben, T., König, G., Herbringer, J., Reisinger, T., Casalicchio, G., Wright, M. N., & Bischl, B. (2023). Relating the partial dependence plot and permutation feature importance to the data generating process. In L. Longo (Ed.), *xAI 2023, CCIS 1901* (pp. 456–479). Springer, Cham [https://doi.org/10.1007/978-3-031-44064-9\\_24](https://doi.org/10.1007/978-3-031-44064-9_24)
43. Pratiwi, H., Windarto, A. P., Susliansyah, S., Aria, R. R., Susilowati, S., Rahayu, L. K., Fitriani, Y., Merdekawati, A., & Rahadjeng, I. R. (2020). Sigmoid Activation Function in Selecting the Best Model of Artificial Neural Networks. *Journal of Physics: Conference Series*, 1471(1), 012010. <https://doi.org/10.1088/1742-6596/1471/1/012010>
44. Railsback, S. F., & Grimm, V. (2019). *Agent-based and individual-based modeling* (2nd edn). Princeton, NJ: Princeton University Press. ISBN: 9780691190822
45. Raymer, J., Wiśniowski, A., Forster, J. J., Smith, P. W. F., & Bijak, J. (2013). Integrated modeling of European migration. *Journal of the American Statistical Association*, 108(503), 801–819. <https://doi.org/10.1080/01621459.2013.789435>
46. Richey, M. K. (2020). *Scalable Agent-Based Modeling of Forced Migration* (Doctoral dissertation, George Mason University).
47. Robinson, C., & Dilkina, B. (2018, June 20). A machine learning approach to modeling human migration. Proceedings of the 1st ACM SIGCAS Conference on Computing and Sustainable Societies, 1–8. Presented at the COMPASS '18: *ACM SIGCAS Conference on Computing and Sustainable Societies, Menlo Park and San Jose CA USA*. <https://doi.org/10.1145/3209811.3209868>
48. Salgado, M., & Gilbert, N. (2013). *Agent based modelling. In Handbook of quantitative methods for educational research* (pp. 247-265). Rotterdam: SensePublishers.
49. Salle, I. L. (2015). Modeling expectations in agent-based models — An application to central bank's communication and monetary policy. *Economic Modelling*, 46, 130–141. <http://dx.doi.org/10.1016/j.econmod.2014.12.040>
50. Searle, C., & van Vuuren, J. H. (2021). Modelling forced migration: A framework for conflict-induced forced migration modelling according to an agent-based approach. *Computers, Environment and Urban*

- Systems*, 85, 101568.  
<https://doi.org/10.1016/j.compenvurbsys.2020.101568>
51. Silveira, J. J., Espíndola, A. L., & Penna, T. J. P. (2006). Agent-based model to rural–urban migration analysis. *Physica A*, 364, 445–456. doi:10.1016/j.physa.2005.08.055
52. Simon, H. A. (1956). Rational Choice and the Structure of the Environment. *Psychological Review*, 63, 129-138. <https://doi.org/10.1037/h0042769>
53. Taghikhah, F., Voinov, A., Filatova, T., & Polhill, J. G. (2022). Machine-assisted agent-based modeling: Opening the black box. *Journal of Computational Science*, 64, 101854. <https://doi.org/10.1016/j.jocs.2022.101854>
54. Tah, J. H. M. (2005). Towards an agent-based construction supply network modelling and simulation platform. *Automation in Construction*, 14(3), 353–359. <https://doi.org/10.1016/j.autcon.2004.08.003>
55. Taherahmadi, M., Khabaz Mafinejad, M., Sayarifard, A., Akbari Sari, A., & Farahani, P. (2023). Iranian medical students' tendency to migrate and its associated factors. *BMC Medical Education*, 23(1), 232. <https://doi.org/10.1186/s12909-023-04147-x>
56. Tolk, A., Diallo, S. Y., Turnitsa, C. D., & Yilmaz, L. (2022). Integrating machine learning with agent-based modeling: A methodological framework. *Simulation Modelling Practice and Theory*, 123, 102707. <https://doi.org/10.1016/j.simpat.2022.102707>
57. Trinh, T. T., & Munro, A. (2023). Integrating a choice experiment into an agent-based model to simulate climate-change induced migration: The case of the Mekong River Delta, Vietnam. *Journal of Choice Modelling*, 48, 100428. <https://doi.org/10.1016/j.jocm.2023.100428>
58. Turgut, Y., & Bozdog, C. E. (2023). A framework proposal for machine learning-driven agent-based models through a case study analysis. *Simulation Modelling Practice and Theory*, 123, 102707. <https://doi.org/10.1016/j.simpat.2022.102707>
59. Valizadeh, S., Hasankhani, H., & Shojaeimotlagh, V. (2016). Nurses' Immigration: Causes and Problems. *IJMRHS*, 5, 486–491.
60. Van Dalen, H. P., & Henkens, K. (2013). Explaining emigration intentions and behaviour in the Netherlands, 2005-10. *Population Studies*, 67(2), 225–241. <http://dx.doi.org/10.1080/00324728.2012.725135>
61. Van der Hoog, S. (2016). Deep learning in agent-based models: A prospectus. *SSRN Electronic Journal*. <https://doi.org/10.2139/ssrn.2711216>
62. Wilensky, U., & Rand, W. (2015). *An introduction to agent-based modeling: Modeling natural, social, and engineered complex systems with NetLogo*. MIT Press. <https://mitpress.mit.edu/9780262731898/>

63. Wojtusiak, J., Warden, T., & Herzog, O. (2012). Machine learning in agent-based stochastic simulation: Inferential theory and evaluation in transportation logistics. *Computers & Mathematics with Applications*, 64(12), 3658–3665. <https://doi.org/10.1016/j.camwa.2012.01.079>
64. Zhang, J., & Zhao, Z. (2026). Corporate ESG rating prediction based on XGBoost-SHAP interpretable machine learning model. *Expert Systems With Applications*, 295, 128809. <https://doi.org/10.1016/j.eswa.2025.128809>
65. Zornić, N., & Marković, A. (2022). A methodological framework for the integration of machine learning algorithms into agent-based simulation models. *Journal of Universal Computer Science: J. UCS*, 28(5), 540–562. <https://doi.org/10.3897/jucs.73924>

### References [In Persian]

1. Ala Aldini, F., Fatemi, R., Ranjbaran Jahromi, H., Feyzzadeh, A., Ardalani, A., Hosseinpoor, A. R., Asghari Roudsari, E., Eskandari, Sh., Tavakoli, H. R., Mirzasadeghi, A. R., & Razavi, A. (2005). The inclination to immigration and the related factors among Iranian physicians. *Hakim Research Journal*, 8(3), 9–15. <https://sid.ir/paper/29245/en>
2. Farahbakhsh, M., Modiri, M., Khatami Firozabadi, S. M. A., & Puorebrahimi, A. (2022). Power industry's life cycle simulation using agent based modeling. *Journal of Industrial Management Perspective*, 12(4), 9–35. <https://doi.org/10.52547/jimp.12.4.9>
3. Fartoukzadeh, H.R., & Eshraghi, H. (2009). A Dynamic Modeling of Elites' Immigration and the Role of Higher Education System. *Journal of Research and Planning in Higher Education*, 14(4 (50)), 139-168. SID. <https://sid.ir/paper/68087/en>
4. Ghaffarian, A., & Ferdosi, M. (2022). Migration of medical staff; Has the alarm sounded? *Journals of Birjand University of Medical Sciences*, 29(4), 397–401. <http://dx.doi.org/10.34785/bums024.2022.030>
5. Haghdoost, A. A., Noorihekmat, S., Talaei, B., Malekpour Afshar, R., Salavati, B., Behzadi, F., et al. (2022). An investigation of factors associated with emigration of the health workforce in Iran in 2022. *Iranian Journal of Culture and Health Promotion*, 6(2), 205–213. <http://dx.doi.org/10.22034/6.2.2>
6. HoseinDoost, S., Zamani, B., & Fatemi, A. (2022). Evaluation of agent-based modeling and simulation tools based on ISO 25010. *Modern Research in Decision Making*, 7(1), 61–86. <https://dor.isc.ac/dor/20.1001.1.24766291.1401.7.1.3.8>
7. Iran Migration Observatory. (2022). Human resources migration in the health sector in Iran and the world. In *Iran Migration Outlook 2022* (pp. ...)

- 366–397). Tehran: Iran Migration Observatory. <https://imobs.ir/outlook/detail/22>
8. Rahmati, H. (2015). *Role Of Intellectual Capitals Migration On The Knowledge Flow*. M.SC.Thesis. Alzahra University.
9. Safaie Pour, M., & Mahali, Y. (2017). Investigating Factors Affecting City Migration Using the Amos Structural Equation Modeling and Fuzzy Hierarchy Process Analysis (Case Study: Ahwaz City). *Haft Hesar J Environ Stud* 2018; 6 (22):81-96 <http://hafthesar.iauh.ac.ir/article-1-500-fa.html>
10. Vedadhir, A., & Eshraghi, S. (2019). Attitude toward migrate abroad in Iranian medical community: A qualitative study. *Journal of Research and Planning in Higher Education*, 25(2), 23–42. <https://sid.ir/paper/68063/en>

**استناد به این مقاله:** خدادادی، هما، کاظمی، مصطفی، مطهری فریمانی، ناصر، طباطبائی، سید محمد. (۱۴۰۵). مدل‌سازی عامل‌بنیان مبتنی بر یادگیری ماشین: شبیه‌سازی تصمیم مهاجرت نیروهای انسانی بخش سلامت، مطالعات مدیریت کسب و کار هوشمند، ۱۵(۵۵)، ۱۲۷-۱۷۵. DOI: 10.22054/ims.2026.89993.2727



Journal of Business Intelligence Management Studies is licensed under a Creative Commons Attribution-NonCommercial 4.0 International License..