دوره ۱، شماره ۶، سال ۱۴۰۴

هوشمندسازی در حسابداری، اقتصاد و مدیریت مالی

تحلیل نقش الگوریتم‌های یادگیری ماشین در پیش‌بینی نرخ تورم و پیامدهای آن برای سیاست‌گذاری اقتصادی

۱. محسن رادمان طهرانی*: گروه حسابداری مدیریت، دانشگاه تهران، تهران، ایران (نویسنده مسئول). mohsen.radman.acc@gmail.com

۲. الناز صفرپور: گروه حسابداری مدیریت، دانشگاه تهران، تهران، ایران

چکیده

هدف پژوهش حاضر تحلیل نقش الگوریتم‌های یادگیری ماشین در ارتقای پیش‌بینی نرخ تورم و تبیین پیامدهای آن برای تصمیم‌گیری و سیاست‌گذاری اقتصادی است. این پژوهش با رویکرد کیفی و طرح تحلیل مضمون انجام شد. جامعه مشارکت‌کنندگان شامل خبرگان اقتصاد کلان، سیاست‌گذاری پولی، تحلیل داده‌های اقتصادی، اقتصادسنجی، بازارهای مالی و فناوری مالی در شهر تهران بود. نمونه‌گیری به‌صورت هدفمند و گلوله‌برفی انجام شد و فرایند گردآوری داده‌ها تا رسیدن به اشباع نظری ادامه یافت. در مجموع، ۱۹ نفر در مصاحبه‌های نیمه‌ساختاریافته شرکت کردند. ابزار گردآوری داده‌ها راهنمای مصاحبه نیمه‌ساختاریافته بود که بر محورهایی مانند قابلیت الگوریتم‌های یادگیری ماشین در پیش‌بینی تورم، محدودیت‌های مدل‌های اقتصادسنجی سنتی، کیفیت داده‌های اقتصادی، تفسیرپذیری مدل‌ها، الزامات نهادی، و پیامدهای سیاستی پیش‌بینی‌های الگوریتمی متمرکز بود. داده‌ها پس از پیاده‌سازی کامل مصاحبه‌ها، در نرم‌افزار NVivo کدگذاری شدند و با استفاده از تحلیل مضمون در سه سطح کدهای اولیه، مضامین فرعی و مقوله‌های اصلی تحلیل گردیدند. نتایج تحلیل داده‌ها به استخراج چهار مقوله اصلی منجر شد: «توانمندی الگوریتم‌های یادگیری ماشین در کشف روابط غیرخطی و الگوهای پنهان تورمی»، «وابستگی دقت پیش‌بینی به کیفیت، به‌هنگامی و یکپارچگی داده‌های اقتصادی»، «چالش تفسیرپذیری، اعتماد نهادی و پاسخگویی سیاستی»، و «کاربرد پیش‌بینی‌های الگوریتمی در بهبود زمان‌بندی، هدف‌گذاری و هماهنگی سیاست‌های اقتصادی». مشارکت‌کنندگان تأکید داشتند که الگوریتم‌هایی مانند جنگل تصادفی، گرادیان بوستینگ، شبکه‌های عصبی و روش‌های ترکیبی می‌توانند در محیط‌های داده‌غنی، تصویر دقیق‌تری از پویایی تورم ارائه دهند؛ بااین‌حال، استفاده سیاستی از این مدل‌ها بدون شفافیت روش‌شناختی، ارزیابی خطای پیش‌بینی و سازوکار توضیح‌پذیری می‌تواند به تصمیم‌گیری مکانیکی و کاهش اعتماد عمومی منجر شود. یافته‌ها نشان داد یادگیری ماشین می‌تواند مکملی قدرتمند برای مدل‌های اقتصادسنجی سنتی در پیش‌بینی تورم باشد، اما جایگزین قضاوت کارشناسی و تحلیل نهادی نیست. بهره‌گیری مؤثر از این الگوریتم‌ها در سیاست‌گذاری اقتصادی مستلزم زیرساخت داده‌ای معتبر، چارچوب حکمرانی الگوریتمی، تفسیرپذیری مدل‌ها، آموزش سیاست‌گذاران و ترکیب پیش‌بینی‌های کمی با فهم اقتصاد سیاسی تورم است.

کلیدواژه‌ها: یادگیری ماشین؛ پیش‌بینی تورم؛ سیاست‌گذاری اقتصادی؛ اقتصادسنجی؛ تحلیل مضمون؛ الگوریتم‌های پیش‌بین؛ حکمرانی داده.

شیوه استناددهی: رادمان طهرانی، محسن.، و صفرپور، الناز. (۱۴۰۴). تحلیل نقش الگوریتم‌های یادگیری ماشین در پیش‌بینی نرخ تورم و پیامدهای آن برای سیاست‌گذاری اقتصادی. *هوشمندسازی در حسابداری، اقتصاد و مدیریت مالی*، *۱*(۶)، ۵۲-۴۰.

© ۱۴۰۴ تمامی حقوق انتشار این مقاله متعلق به نویسنده است.

Volume 1, Issue 6, Year 2025

Smartification in Accounting, Economics, and Financial Management

Analyzing the Role of Machine Learning Algorithms in Inflation Forecasting and Its Implications for Economic Policymaking

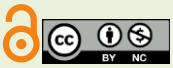
1. Mohsen Radman Tehrani*: Department of Management Accounting, University of Tehran, Tehran, Iran
(Corresponding Author). mohsen.radman.acc@gmail.com
2. Elnaz SafarPour: Department of Management Accounting, University of Tehran, Tehran, Iran

Abstract

This study aimed to analyze the role of machine learning algorithms in improving inflation forecasting and to explain their implications for economic policymaking. This qualitative study was conducted using a thematic analysis design. The participants consisted of experts in macroeconomics, monetary policymaking, economic data analysis, econometrics, financial markets, and financial technology in Tehran. Participants were selected through purposive and snowball sampling, and data collection continued until theoretical saturation was reached. In total, 19 experts participated in semi-structured interviews. The interview guide focused on the predictive capacity of machine learning algorithms, limitations of traditional econometric models, data quality and availability, model interpretability, institutional requirements, and policy consequences of algorithmic inflation forecasts. All interviews were transcribed verbatim and analyzed using NVivo software. Data analysis was performed through open coding, development of subthemes, and abstraction of main categories. The analysis resulted in four main categories: "the capacity of machine learning algorithms to detect nonlinear relationships and hidden inflationary patterns," "dependence of forecast accuracy on data quality, timeliness, and integration," "interpretability, institutional trust, and policy accountability challenges," and "the application of algorithmic forecasts in improving the timing, targeting, and coordination of economic policies." Participants emphasized that algorithms such as random forests, gradient boosting, neural networks, and hybrid models can provide a more accurate picture of inflation dynamics in data-rich environments. However, they also argued that policy reliance on these models without methodological transparency, forecast-error evaluation, and explainability mechanisms may lead to mechanical decision-making and weakened public trust. The findings indicate that machine learning can serve as a powerful complement to traditional econometric models in inflation forecasting, but it should not replace expert judgment and institutional analysis. Effective use of these algorithms in economic policymaking requires reliable data infrastructure, algorithmic governance, model interpretability, policymaker training, and integration of quantitative forecasts with political-economic understanding of inflation.

Keywords: *Machine learning; Inflation forecasting; Economic policymaking; Econometrics; Thematic analysis; Predictive algorithms; Data governance.*

How to cite: Radman Tehrani, M. & SafarPour, E. (2025). Analyzing the Role of Machine Learning Algorithms in Inflation Forecasting and Its Implications for Economic Policymaking. *Smartification in Accounting, Economics, and Financial Management, 1*(6), 40-52.



© 2025 the authors.

مقدمه

تورم یکی از بنیادین‌ترین متغیرهای اقتصاد کلان و از حساس‌ترین شاخص‌های ارزیابی عملکرد سیاست‌گذاری اقتصادی است؛ زیرا تغییرات آن به‌طور مستقیم بر قدرت خرید خانوارها، هزینه تولید بنگاه‌ها، انتظارات فعالان اقتصادی، ارزش پول ملی، نرخ بهره، تصمیم‌های سرمایه‌گذاری و توزیع درآمد اثر می‌گذارد. در ادبیات اقتصاد کلان، پیش‌بینی تورم همواره جایگاهی محوری داشته است؛ چراکه سیاست‌گذار پولی و مالی برای تنظیم نرخ بهره، مدیریت نقدینگی، طراحی بسته‌های حمایتی، تدوین بودجه، کنترل انتظارات تورمی و حفظ ثبات اقتصاد کلان نیازمند برآوردی معتبر از مسیر آتی سطح قیمت‌هاست. اهمیت پیش‌بینی تورم از آنجا ناشی می‌شود که سیاست‌های اقتصادی با وقفه زمانی عمل می‌کنند و تصمیم امروز بانک مرکزی یا دولت، آثار خود را در ماه‌ها یا حتی سال‌های بعد نشان می‌دهد. ازاین‌رو، اگر سیاست‌گذار تصویر نادرستی از روند آینده تورم داشته باشد، احتمال اتخاذ سیاست‌های بیش‌ازحد انقباضی یا بیش‌ازحد انبساطی افزایش می‌یابد؛ وضعیتی که می‌تواند به رکود، بی‌ثباتی مالی، تشدید انتظارات تورمی یا کاهش اعتبار سیاست‌گذار منجر شود.

در چارچوب‌های سنتی، پیش‌بینی تورم عمدتاً بر مدل‌های اقتصادسنجی خطی، منحنی فیلیپس، مدل‌های خودرگرسیونی، مدل‌های برداری خودرگرسیون، مدل‌های تصحیح خطا، مدل‌های عامل پویا و روش‌های مبتنی بر انتظارات استوار بوده است. این مدل‌ها نقش مهمی در توسعه دانش پیش‌بینی اقتصادی داشته‌اند و همچنان در بسیاری از بانک‌های مرکزی و نهادهای سیاست‌گذار مورد استفاده قرار می‌گیرند. بااین‌حال، مطالعات کلاسیک نشان داده‌اند که پیش‌بینی تورم، به‌ویژه در افق‌های میان‌مدت و بلندمدت، کاری دشوار و همراه با خطای قابل توجه است. برای مثال، Stock و Watson نشان دادند که متغیرهایی مانند بیکاری، نرخ بهره، قیمت کالاها و شاخص‌های پولی در برخی دوره‌ها توان توضیحی دارند، اما عملکرد پیش‌بینی آن‌ها در طول زمان پایدار نیست (Stock & Watson, ۱۹۹۹). همچنین Atkeson و Ohanian با نقد کارایی برخی مدل‌های مبتنی بر منحنی فیلیپس نشان دادند که در برخی شرایط، پیش‌بینی‌های ساده و مبتنی بر تداوم تورم گذشته می‌توانند با مدل‌های پیچیده رقابت کنند (Atkeson & Ohanian, ۲۰۰۱). این یافته‌ها حاکی از آن است که تورم پدیده‌ای ایستا، خطی و تک‌علتی نیست، بلکه حاصل برهم‌کنش پیچیده متغیرهای پولی، مالی، ارزی، ساختاری، نهادی، انتظاری و جهانی است.

در دهه‌های اخیر، پیچیدگی فرایندهای تورمی به‌واسطه جهانی‌شدن زنجیره‌های تأمین، شوک‌های انرژی، تغییرات نرخ ارز، تحولات ژئوپلیتیک، سیاست‌های مالی انبساطی، بی‌ثباتی بازارهای دارایی، رشد داده‌های دیجیتال و سرعت انتقال انتظارات در شبکه‌های اجتماعی افزایش یافته است. در چنین محیطی، مدل‌های خطی سنتی ممکن است در شناسایی روابط غیرخطی، اثرات آستانه‌ای، تغییر رژیم‌ها، تعاملات پیچیده میان متغیرها و الگوهای پنهان داده‌ها محدودیت داشته باشند. به‌عنوان نمونه، اثر نرخ ارز بر تورم ممکن است در شرایط ثبات ارزی ضعیف باشد، اما در شرایط جهش ارزی، انتظارات تورمی و نااطمینانی سیاسی به‌صورت هم‌افزا عمل کرده و ضریب عبور نرخ ارز به قیمت‌ها را افزایش دهند. به همین ترتیب، رشد نقدینگی ممکن است در دوره‌هایی که سرعت گردش پول پایین است اثر محدودی بر تورم داشته باشد، اما در شرایط

بی‌اعتمادی به پول ملی، تبدیل نقدینگی به دارایی‌های جایگزین می‌تواند فشار تورمی را تشدید کند. این نوع روابط غیرخطی و وابسته به وضعیت، نیازمند ابزارهایی است که بتوانند فراتر از فروض ساده‌ساز خطی عمل کنند.

یادگیری ماشین به‌عنوان شاخه‌ای از هوش مصنوعی، مجموعه‌ای از روش‌های محاسباتی را در اختیار پژوهشگران و سیاست‌گذاران قرار می‌دهد که هدف اصلی آن‌ها استخراج الگو از داده و بهبود پیش‌بینی است. برخلاف بسیاری از مدل‌های اقتصادسنجی سنتی که بر تخمین پارامترهای قابل تفسیر و آزمون فرضیه‌های نظری تمرکز دارند، یادگیری ماشین عمدتاً بر کاهش خطای پیش‌بینی خارج از نمونه، شناسایی الگوهای پیچیده و یادگیری از داده‌های حجیم متکی است .(Mullainathan & Spiess, ۲۰۱۷) الگوریتم‌هایی مانند جنگل تصادفی، گرادیان بوستینگ، XGBoost، ماشین بردار پشتیبان، شبکه‌های عصبی مصنوعی، شبکه‌های عصبی بازگشتی، LSTM، مدل‌های ترکیبی و روش‌های منظم‌سازی‌شده می‌توانند در محیط‌های داده‌غنی، متغیرهای پرتعداد و روابط غیرخطی عملکرد مطلوبی داشته باشند Varian .نیز نشان داد که گسترش داده‌های بزرگ و روش‌های محاسباتی جدید، ابزارهای تازه‌ای برای اقتصادسنجی کاربردی فراهم کرده و امکان پیش‌بینی، طبقه‌بندی و کشف الگوهای رفتاری را افزایش داده است.(Varian, ۲۰۱۴)

در حوزه خاص پیش‌بینی تورم، پژوهش‌های اخیر شواهد قابل توجهی درباره ظرفیت یادگیری ماشین ارائه کرده‌اند Medeiros .و همکاران در مطالعه‌ای درباره پیش‌بینی تورم ایالات متحده در محیط داده‌غنی نشان دادند که روش‌های یادگیری ماشین، به‌ویژه جنگل تصادفی، می‌توانند در بسیاری از افق‌های پیش‌بینی عملکردی دقیق‌تر از الگوهای مرسوم داشته باشند، زیرا قادرند مجموعه وسیعی از متغیرها و روابط غیرخطی میان آن‌ها را پردازش کنند Araujo .(Medeiros et al., ۲۰۲۱) و Gaglianone نیز در پژوهشی درباره تورم برزیل، با مقایسه ۵۰ روش پیش‌بینی و استفاده از پایگاه داده‌ای شامل ۵۰۱ سری زمانی، نشان دادند که روش‌های یادگیری ماشین در موارد متعددی از مدل‌های اقتصادسنجی کلاسیک از نظر خطای میانگین مربعات بهتر عمل می‌کنند و می‌توانند به شناسایی متغیرهای کلیدی مؤثر بر تورم کمک کنند .(Araujo & Gaglianone, ۲۰۲۳)این یافته‌ها با نتایج Goulet Coulombe و همکاران نیز همسو است؛ آنان نشان دادند که مزیت اصلی یادگیری ماشین در پیش‌بینی کلان، توانایی آن در مدل‌سازی غیرخطی‌ها و تعاملات پیچیده در دوره‌های نااطمینانی، فشار مالی و تغییرات رژیمی است.(Goulet Coulombe et al., ۲۰۲۲)

با وجود این مزایا، استفاده از یادگیری ماشین در پیش‌بینی تورم بدون چالش نیست. نخست، بسیاری از الگوریتم‌های پیشرفته ماهیتی جعبه‌سیاه دارند و توضیح اینکه چرا مدل، نرخ تورم خاصی را پیش‌بینی کرده دشوار است. این مسئله در حوزه سیاست‌گذاری اقتصادی اهمیت مضاعف دارد؛ زیرا تصمیم‌های سیاستی باید برای نهادهای نظارتی، بازارها، رسانه‌ها و عموم مردم قابل توضیح باشند. اگر یک بانک مرکزی یا نهاد سیاست‌گذار صرفاً بر خروجی الگوریتمی اتکا کند، اما نتواند منطق پیش‌بینی را توضیح دهد، اعتبار سیاستی و پاسخگویی نهادی تضعیف می‌شود. در پاسخ به این چالش، ادبیات تفسیرپذیری مدل‌ها روش‌هایی مانند LIME و SHAP را برای توضیح سهم متغیرها در پیش‌بینی

پیشنهاد کرده است (Ribeiro et al., ۲۰۱۶; Lundberg & Lee, ۲۰۱۷). بااین‌حال، پرسش اصلی این است که آیا این ابزارها برای اقناع سیاست‌گذاران اقتصادی و ترجمه پیش‌بینی‌های الگوریتمی به زبان سیاستی کافی هستند یا خیر.

دوم، دقت الگوریتم‌های یادگیری ماشین به‌شدت وابسته به کیفیت داده است. در کشورهایی که داده‌های اقتصادی با تأخیر منتشر می‌شوند، بازنگری‌های مکرر دارند، از هماهنگی نهادی کافی برخوردار نیستند یا برخی بازارها غیررسمی و پنهان‌اند، حتی پیشرفته‌ترین الگوریتم‌ها نیز ممکن است خروجی‌های ناپایدار تولید کنند. در پیش‌بینی تورم، داده‌های مربوط به شاخص قیمت مصرف‌کننده، نرخ ارز رسمی و غیررسمی، قیمت دارایی‌ها، نقدینگی، پایه پولی، کسری بودجه، قیمت انرژی، دستمزدها، انتظارات تورمی، تجارت خارجی، شوک‌های عرضه، شاخص‌های نااطمینانی و داده‌های رفتاری می‌توانند اهمیت داشته باشند. اما چنانچه این داده‌ها ناقص، ناسازگار، غیرهم‌زمان یا سیاسی‌شده باشند، مدل یادگیری ماشین به جای کشف واقعیت اقتصادی، الگوهای مخدوش داده را بازتولید می‌کند. بنابراین، پیش‌بینی الگوریتمی تورم پیش از آنکه صرفاً مسئله‌ای فنی باشد، مسئله‌ای نهادی و حکمرانی داده است.

سوم، استفاده از یادگیری ماشین در سیاست‌گذاری اقتصادی با پرسش رابطه میان پیش‌بینی و تصمیم‌گیری مواجه است. در اقتصاد، پیش‌بینی دقیق لزوماً به معنای سیاست‌گذاری درست نیست؛ زیرا سیاست‌گذار باید علاوه بر مسیر محتمل تورم، پیامدهای رفاهی، توزیعی، سیاسی و نهادی سیاست‌ها را نیز در نظر گیرد. برای مثال، اگر مدل افزایش تورم را پیش‌بینی کند، پاسخ سیاستی می‌تواند افزایش نرخ بهره، کنترل نقدینگی، مدیریت نرخ ارز، اصلاح بودجه، سیاست‌های درآمدی یا ترکیبی از این موارد باشد. انتخاب میان این گزینه‌ها به ساختار اقتصاد، شدت رکود، وضعیت اشتغال، بدهی دولت، ثبات نظام بانکی و انتظارات اجتماعی بستگی دارد. ازاین‌رو، یادگیری ماشین می‌تواند کیفیت اطلاعات سیاست‌گذار را افزایش دهد، اما نمی‌تواند جایگزین قضاوت سیاستی، تحلیل علّی و فهم اقتصاد سیاسی شود. به بیان دیگر، الگوریتم می‌تواند هشدار دهد، اما تصمیم نهایی باید در چارچوب مسئولیت نهادی و عقلانیت سیاستی اتخاذ شود.

با توجه به اهمیت موضوع، پژوهش حاضر می‌کوشد نقش الگوریتم‌های یادگیری ماشین در پیش‌بینی نرخ تورم و پیامدهای آن برای سیاست‌گذاری اقتصادی را از منظر خبرگان بررسی کند. تمایز این مطالعه با بسیاری از پژوهش‌های کمی آن است که به جای مقایسه صرف خطای پیش‌بینی مدل‌ها، بر تجربه، تفسیر و نگرش متخصصانی تمرکز می‌کند که در مرز میان اقتصاد کلان، تحلیل داده و سیاست‌گذاری فعالیت دارند. چنین رویکردی امکان می‌دهد ابعاد فنی، نهادی، تفسیری و سیاستی استفاده از الگوریتم‌ها به‌صورت هم‌زمان بررسی شود. بر این اساس، پرسش اصلی پژوهش عبارت است از: الگوریتم‌های یادگیری ماشین چه نقشی در پیش‌بینی نرخ تورم دارند و استفاده از آن‌ها چه پیامدهایی برای سیاست‌گذاری اقتصادی ایجاد می‌کند؟

۱ مواد و روش‌ها

پژوهش حاضر از نظر رویکرد، کیفی و از نظر راهبرد تحلیل، مبتنی بر تحلیل مضمون بود. انتخاب رویکرد کیفی به این دلیل صورت گرفت که هدف پژوهش، سنجش عملکرد عددی الگوریتم‌ها یا برآورد دقت پیش‌بینی آن‌ها نبود، بلکه فهم عمیق ادراک خبرگان از ظرفیت‌ها، محدودیت‌ها

و پیامدهای سیاستی یادگیری ماشین در پیش‌بینی تورم مدنظر قرار داشت. تحلیل مضمون به‌دلیل انعطاف‌پذیری نظری و توانایی آن در شناسایی الگوهای معنایی در داده‌های مصاحبه‌ای انتخاب شد (Braun & Clarke, ۲۰۰۶). محیط پژوهش شهر تهران بود؛ زیرا بخش مهمی از نهادهای سیاست‌گذاری، مراکز پژوهشی اقتصادی، شرکت‌های تحلیل داده، مؤسسات مالی و متخصصان اقتصاد کلان و فناوری مالی در تهران متمرکز هستند.

مشارکت‌کنندگان پژوهش شامل ۱۹ نفر از خبرگان حوزه اقتصاد کلان، اقتصادسنجی، سیاست‌گذاری پولی، تحلیل داده‌های مالی، فناوری مالی و بازار سرمایه در تهران بودند. معیارهای ورود به پژوهش عبارت بودند از: داشتن حداقل پنج سال سابقه حرفه‌ای یا پژوهشی مرتبط با تحلیل اقتصاد کلان، پیش‌بینی تورم، مدل‌سازی داده‌های اقتصادی یا سیاست‌گذاری اقتصادی؛ آشنایی نظری یا کاربردی با روش‌های داده‌کاوی و یادگیری ماشین؛ و تمایل به شرکت در مصاحبه. نمونه‌گیری به‌صورت هدفمند آغاز شد و سپس برای دسترسی به خبرگان تخصصی‌تر، از روش گلوله‌برفی استفاده گردید. فرایند نمونه‌گیری تا رسیدن به اشباع نظری ادامه یافت؛ به‌گونه‌ای که در مصاحبه هفدهم مضمون جدید معناداری ظاهر نشد و دو مصاحبه بعدی برای اطمینان از کفایت داده‌ها انجام گرفت. اتکا به اشباع نظری با منطق پژوهش‌های کیفی همخوان است؛ زیرا در چنین مطالعاتی، کفایت نمونه نه بر اساس حجم آماری، بلکه بر مبنای تکرار الگوها و عدم ظهور داده‌های جدید تعیین می‌شود (Guest et al., ۲۰۰۶).

داده‌ها تنها از طریق مصاحبه‌های نیمه‌ساختاریافته گردآوری شد. راهنمای مصاحبه بر اساس ادبیات پژوهش و هدف مطالعه طراحی گردید و شامل محورهایی مانند تجربه مشارکت‌کنندگان از پیش‌بینی تورم، محدودیت‌های مدل‌های سنتی، مزایای احتمالی الگوریتم‌های یادگیری ماشین، نقش داده‌های کلان و جایگزین، چالش‌های تفسیرپذیری، اعتماد به خروجی مدل‌ها، الزامات نهادی، و پیامدهای سیاستی استفاده از پیش‌بینی‌های الگوریتمی بود. نمونه پرسش‌ها عبارت بودند از: «به نظر شما الگوریتم‌های یادگیری ماشین در چه بخش‌هایی می‌توانند پیش‌بینی تورم را بهبود دهند؟»، «مهم‌ترین مانع استفاده سیاستی از این مدل‌ها چیست؟»، «آیا مدل‌های جعبه‌سیاه می‌توانند مبنای تصمیم‌گیری اقتصادی قرار گیرند؟»، و «چگونه می‌توان خروجی الگوریتمی را به زبان قابل استفاده برای سیاست‌گذار تبدیل کرد؟». مصاحبه‌ها به‌صورت حضوری یا آنلاین انجام شدند و مدت هر مصاحبه بین ۴۵ تا ۷۵ دقیقه بود. پیش از شروع مصاحبه، هدف پژوهش برای مشارکت‌کنندگان توضیح داده شد و رضایت آگاهانه آنان اخذ گردید.

تحلیل داده‌ها هم‌زمان با گردآوری داده‌ها انجام شد. ابتدا فایل صوتی مصاحبه‌ها به‌صورت کامل پیاده‌سازی شد. سپس متن مصاحبه‌ها چندین بار خوانده شد تا آشنایی عمیق با داده‌ها حاصل گردد. در مرحله بعد، کدگذاری اولیه در نرم‌افزار NVivo انجام شد. کدهای اولیه شامل مفاهیمی مانند «کشف روابط غیرخطی»، «داده‌های ناقص»، «تأخیر انتشار آمار»، «اعتماد سیاست‌گذار»، «جعبه‌سیاه بودن مدل»، «پیش‌بینی سناریویی»، «خطای مدل»، «انتظارات تورمی»، «هماهنگی سیاست پولی و مالی» و «لزوم تیم میان‌رشته‌ای» بودند. پس از آن، کدهای مشابه در قالب مضامین فرعی تجمیع شدند و در نهایت، چهار مقوله اصلی استخراج گردید. برای افزایش اعتبارپذیری یافته‌ها، از بازبینی

مشارکت‌کنندگان، مرور همتای پژوهشی، ثبت مسیر تحلیل و مقایسه مداوم کدها استفاده شد. همچنین برای رعایت قابلیت اعتماد، فرایند تصمیم‌گیری تحلیلی و تغییرات کدها در قالب یادداشت‌های پژوهشی ثبت شد. معیارهای اعتبار، انتقال‌پذیری، وابستگی و تأییدپذیری بر اساس منطق Lincoln و Guba در کل فرایند پژوهش مورد توجه قرار گرفت.(Lincoln & Guba, ۱۹۸۵)

یافته‌ها

از مجموع ۱۹ مشارکت‌کننده، ۱۱ نفر مرد و ۸ نفر زن بودند. از نظر گروه سنی، ۴ نفر در دامنه ۳۰ تا ۳۹ سال، ۹ نفر در دامنه ۴۰ تا ۴۹ سال و ۶ نفر ۵۰ سال و بالاتر قرار داشتند. از نظر سطح تحصیلات، ۵ نفر دارای مدرک کارشناسی ارشد و ۱۴ نفر دارای مدرک دکتری در رشته‌های اقتصاد، مدیریت مالی، آمار، مهندسی مالی، علم داده و سیاست‌گذاری عمومی بودند. از نظر حوزه تخصصی، ۶ نفر اقتصاددان و پژوهشگر اقتصاد کلان، ۴ نفر متخصص اقتصادسنجی و مدل‌سازی پیش‌بینی، ۳ نفر تحلیلگر داده و یادگیری ماشین، ۳ نفر کارشناس بازارهای مالی و ۳ نفر فعال در حوزه سیاست‌گذاری پولی یا مالی بودند. از نظر سابقه کاری، ۵ نفر بین ۵ تا ۱۰ سال، ۸ نفر بین ۱۱ تا ۲۰ سال و ۶ نفر بیش از ۲۰ سال سابقه حرفه‌ای داشتند. همچنین ۷ نفر تجربه همکاری با نهادهای پژوهشی یا سیاست‌گذاری، ۶ نفر تجربه فعالیت در مؤسسات مالی و سرمایه‌گذاری، و ۶ نفر تجربه دانشگاهی یا مشاوره تخصصی در حوزه داده‌های اقتصادی داشتند.

مقوله اول: توانمندی الگوریتم‌های یادگیری ماشین در کشف روابط غیرخطی و الگوهای پنهان تورمی .نخستین مقوله نشان داد که از دید مشارکت‌کنندگان، مهم‌ترین مزیت یادگیری ماشین در پیش‌بینی تورم، توانایی آن در شناسایی روابط غیرخطی، تعاملات چندمتغیره و الگوهایی است که در مدل‌های خطی سنتی به‌سادگی دیده نمی‌شوند. خبرگان تأکید داشتند که تورم در اقتصادهای ناپایدار، صرفاً تابع رشد نقدینگی یا شکاف تولید نیست، بلکه از برهم‌کنش نرخ ارز، انتظارات، کسری بودجه، شوک‌های عرضه، قیمت دارایی‌ها و رفتارهای سفته‌بازانه شکل می‌گیرد. یکی از مشارکت‌کنندگان گفت: «در مدل خطی شما مجبورید از قبل فرض کنید رابطه نرخ ارز و تورم چگونه است؛ اما الگوریتم یادگیری ماشین می‌تواند نشان دهد این رابطه در سطح‌های مختلف نرخ ارز یا در دوره‌های بحران کاملاً تغییر می‌کند.» مشارکت‌کننده دیگری بیان کرد: «وقتی تورم وارد فاز انتظاری می‌شود، متغیرهای رفتاری و حتی اخبار بازار مهم می‌شوند؛ مدل‌های سنتی معمولاً این پیچیدگی را دیر تشخیص می‌دهند.» در این مقوله، کدهایی مانند «تشخیص آستانه‌های تورمی»، «یادگیری از دوره‌های بحران»، «مدل‌سازی تعامل نرخ ارز و نقدینگی»، «کشف شاخص‌های پیشرو»، و «بهبود پیش‌بینی در شرایط نااطمینانی» برجسته بودند. از نظر مشارکت‌کنندگان، الگوریتم‌هایی مانند جنگل تصادفی و گرادیان بوستینگ به‌دلیل توانایی در رتبه‌بندی اهمیت متغیرها و شناسایی روابط غیرخطی، برای پیش‌بینی تورم کاربرد ویژه‌ای دارند. بااین‌حال، آنان تأکید کردند که مزیت یادگیری ماشین زمانی آشکار می‌شود که مدل با داده‌های کافی، افق پیش‌بینی مشخص و ارزیابی خارج از نمونه همراه باشد.

مقوله دوم: وابستگی دقت پیش‌بینی به کیفیت، به‌هنگامی و یکپارچگی داده‌های اقتصادی .دومین مقوله نشان داد که مشارکت‌کنندگان، مسئله داده را مهم‌تر از انتخاب الگوریتم می‌دانستند. از دید آنان، پیش‌بینی تورم در محیطی که داده‌های اقتصادی با تأخیر

منتشر می‌شوند، برخی شاخص‌ها دچار بازنگری می‌شوند، داده‌های غیررسمی در دسترس نیستند و هماهنگی میان پایگاه‌های داده وجود ندارد، با محدودیت جدی مواجه است. یکی از مشارکت‌کنندگان اظهار کرد: «الگوریتم قوی روی داده ضعیف معجزه نمی‌کند؛ اگر داده تورم، نقدینگی، نرخ ارز و کسری بودجه دقیق و به‌موقع نباشد، مدل فقط خطای سیستم آماری را بازتولید می‌کند.» مشارکت‌کننده دیگری گفت: «برای پیش‌بینی تورم باید داده رسمی، داده بازار و داده رفتاری کنار هم قرار گیرد. اگر فقط شاخص‌های ماهانه رسمی را وارد مدل کنیم، بخش زیادی از تغییرات انتظاری را از دست می‌دهیم.» کدهای اصلی این مقوله شامل «تأخیر آماری»، «ناهمگونی منابع داده»، «نبود داده‌های فرکانس بالا»، «بازنگری شاخص‌ها»، «داده‌های غیررسمی بازار ارز»، «نیاز به انبار داده اقتصادی» و «استانداردسازی سری‌های زمانی» بود. مشارکت‌کنندگان تأکید کردند که برای استفاده مؤثر از یادگیری ماشین، نهادهای سیاست‌گذار باید زیرساخت داده‌ای یکپارچه ایجاد کنند و داده‌های پولی، مالی، ارزی، تجاری، بودجه‌ای و انتظاری را در قالبی قابل تحلیل در دسترس تیم‌های تخصصی قرار دهند.

مقوله سوم: چالش تفسیرپذیری، اعتماد نهادی و پاسخگویی سیاستی .سومین مقوله به مسئله اعتماد و توضیح‌پذیری اختصاص داشت. بسیاری از مشارکت‌کنندگان معتقد بودند که حتی اگر یک الگوریتم دقت پیش‌بینی بالایی داشته باشد، استفاده از آن در سیاست‌گذاری اقتصادی مستلزم امکان توضیح خروجی مدل است. در سیاست‌گذاری تورمی، تصمیم‌هایی مانند افزایش نرخ بهره، کنترل اعتبارات، اصلاح بودجه یا مدیریت نرخ ارز آثار اجتماعی و توزیعی گسترده‌ای دارند؛ بنابراین سیاست‌گذار نمی‌تواند صرفاً بگوید «مدل چنین پیش‌بینی کرده است». یکی از مشارکت‌کنندگان گفت: «بانک مرکزی باید بتواند توضیح دهد چرا پیش‌بینی تورم بالا رفته است؛ آیا به‌خاطر نرخ ارز است، کسری بودجه است، انتظارات است یا شوک عرضه. خروجی عددی بدون توضیح، برای سیاست‌گذاری کافی نیست.» مشارکت‌کننده دیگری بیان کرد: «اگر مدل جعبه‌سیاه باشد، در جلسات سیاستی مقاومت ایجاد می‌کند؛ اقتصاددان می‌خواهد منطق ببیند، نه فقط عدد.» در این مقوله، مفاهیمی مانند «جعبه‌سیاه بودن»، «پاسخگویی سیاست‌گذار»، «توضیح سهم متغیرها»، «اعتماد کارشناسان»، «اعتبار نهادی»، «قابل دفاع بودن تصمیم» و «ترکیب مدل و قضاوت انسانی» شناسایی شد. مشارکت‌کنندگان پیشنهاد کردند که استفاده از ابزارهای تفسیرپذیری مانند تحلیل اهمیت متغیرها، سناریونویسی، آزمون حساسیت، SHAPو مقایسه با مدل‌های مرجع می‌تواند پذیرش نهادی مدل‌ها را افزایش دهد.

مقوله چهارم: کاربرد پیش‌بینی‌های الگوریتمی در بهبود زمان‌بندی، هدف‌گذاری و هماهنگی سیاست‌های اقتصادی .چهارمین مقوله نشان داد که از دید مشارکت‌کنندگان، یادگیری ماشین زمانی ارزش سیاستی دارد که پیش‌بینی را به تصمیم عملی تبدیل کند. آنان تأکید داشتند که پیش‌بینی دقیق‌تر تورم می‌تواند به سیاست‌گذار کمک کند تا زمان مناسب مداخله را بهتر تشخیص دهد، میان ابزارهای پولی و مالی هماهنگی ایجاد کند، گروه‌های آسیب‌پذیر را شناسایی کند و پیامدهای سناریوهای مختلف را ارزیابی نماید. یکی از مشارکت‌کنندگان گفت: «ارزش مدل این نیست که فقط بگوید تورم سه ماه بعد چند درصد است؛ ارزش آن این است که نشان دهد اگر نرخ ارز کنترل نشود یا کسری بودجه افزایش یابد، مسیر تورم چگونه تغییر می‌کند.» مشارکت‌کننده دیگری اظهار کرد: «یادگیری ماشین می‌تواند نقش سیستم هشدار

سریع داشته باشد؛ یعنی قبل از اینکه تورم در شاخص رسمی ظاهر شود، از روی داده‌های بازار و رفتار مصرف‌کننده سیگنال بدهد.» کدهای این مقوله شامل «سیستم هشدار زودهنگام»، «پیش‌بینی سناریویی»، «هدف‌گذاری سیاستی»، «هماهنگی سیاست پولی و مالی»، «پشتیبانی تصمیم»، «پایش انتظارات» و «کاهش تأخیر واکنش سیاست‌گذار» بود. بر اساس این یافته، الگوریتم‌های یادگیری ماشین نه به‌عنوان جایگزین سیاست‌گذار، بلکه به‌عنوان ابزار تصمیم‌یار می‌توانند کیفیت و سرعت واکنش سیاستی را افزایش دهند.

بحث

یافته نخست پژوهش نشان داد که خبرگان، اصلی‌ترین ظرفیت یادگیری ماشین در پیش‌بینی تورم را توانایی آن در کشف روابط غیرخطی و الگوهای پنهان می‌دانند. این نتیجه با ادبیات پیش‌بینی کلان همسو است؛ زیرا بسیاری از مطالعات نشان داده‌اند که مزیت روش‌های یادگیری ماشین زمانی برجسته می‌شود که روابط میان متغیرها پیچیده، ناپایدار و وابسته به وضعیت باشد Medeiros .و همکاران نشان دادند که در محیط داده‌غنی، الگوریتم‌های یادگیری ماشین، به‌ویژه جنگل تصادفی، می‌توانند عملکرد بهتری نسبت به معیارهای سنتی داشته باشند و بخشی از این برتری ناشی از توان مدل در شناسایی روابط غیرخطی میان متغیرهای کلان و تورم است .(Medeiros et al., ۲۰۲۱) همچنین Araujoو Gaglianone در مطالعه تورم برزیل نشان دادند که روش‌های درختی و ترکیبی در بسیاری از افق‌های پیش‌بینی عملکرد مناسبی دارند و می‌توانند متغیرهای کلیدی مؤثر بر تورم را شناسایی کنند .(Araujo & Gaglianone, ۲۰۲۳) این یافته با تحلیل Goulet Coulombeو همکاران نیز همخوان است که بر نقش غیرخطی‌ها، اعتبارسنجی متقاطع و منظم‌سازی در بهبود پیش‌بینی‌های کلان تأکید کردند .(Goulet Coulombe et al., ۲۰۲۲) از منظر سیاستی، این نتیجه اهمیت ویژه‌ای دارد؛ زیرا تورم در اقتصادهای در معرض شوک، رفتاری خطی و قابل تقلیل به یک معادله ساده ندارد. اثر نرخ ارز، قیمت انرژی، کسری بودجه، رشد نقدینگی و انتظارات تورمی در دوره‌های مختلف می‌تواند تغییر کند. بنابراین، یادگیری ماشین می‌تواند به سیاست‌گذار کمک کند تا الگوهای پنهان و تغییرات رژیمی را زودتر تشخیص دهد. بااین‌حال، باید توجه داشت که قدرت پیش‌بینی بالاتر به معنای فهم علّی کامل نیست. همان‌گونه که Mullainathan و Spiess تأکید می‌کنند، یادگیری ماشین عمدتاً برای مسئله پیش‌بینی طراحی شده است و نباید بدون احتیاط به‌عنوان ابزار استنتاج علّی به کار رود .(Mullainathan & Spiess, ۲۰۱۷)بنابراین، یافته حاضر نشان می‌دهد که یادگیری ماشین باید مکمل اقتصادسنجی ساختاری و تحلیل نظری باشد، نه جایگزین آن.

یافته دوم پژوهش نشان داد که کیفیت، به‌هنگامی و یکپارچگی داده‌ها شرط بنیادین موفقیت الگوریتم‌های یادگیری ماشین در پیش‌بینی تورم است. این یافته با ادبیات داده‌محور اقتصاد کاملاً همسو است Varian .تأکید می‌کند که ارزش روش‌های نوین اقتصادسنجی و یادگیری ماشین زمانی محقق می‌شود که داده‌های کافی، مناسب و قابل پردازش در دسترس باشد .(Varian, ۲۰۱۴) در زمینه تورم، کیفیت داده اهمیت مضاعف دارد؛ زیرا تورم حاصل تعامل بازار کالا، بازار پول، بازار ارز، بازار کار، سیاست مالی و انتظارات است. اگر داده‌ها ناقص، با تأخیر، غیرهمگن یا دچار بازنگری‌های مکرر باشند، الگوریتم‌ها به جای یادگیری واقعیت اقتصادی، از نویزها و خطاهای نهادی یاد می‌گیرند. این مسئله در

اقتصادهایی که بخشی از مبادلات در بازارهای غیررسمی انجام می‌شود یا شاخص‌های انتظارات تورمی به‌صورت منظم اندازه‌گیری نمی‌شوند، جدی‌تر است. یافته حاضر همچنین با توصیه‌های ادبیات پیش‌بینی سازگار است که بر ارزیابی خارج از نمونه، مقایسه با مدل‌های معیار، کنترل بیش‌برازش و اعتبارسنجی متقاطع تأکید دارند (Hyndman & Athanasopoulos, ۲۰۲۱; Makridakis et al., ۲۰۱۸). بنابراین، برای استفاده سیاستی از یادگیری ماشین، صرف خرید نرم‌افزار یا به‌کارگیری الگوریتم کافی نیست؛ بلکه باید معماری داده‌ای اقتصاد کلان اصلاح شود. این معماری شامل استانداردسازی داده‌ها، ایجاد پایگاه داده یکپارچه، دسترسی به داده‌های فرکانس بالا، ثبت داده‌های بازارهای رسمی و غیررسمی، مستندسازی بازنگری‌های آماری و ایجاد پروتکل‌های کیفیت داده است. از این منظر، یادگیری ماشین بیش از آنکه فقط ابزار فنی باشد، محرکی برای اصلاح حکمرانی داده در نهادهای اقتصادی است.

یافته سوم پژوهش نشان داد که تفسیرپذیری، اعتماد نهادی و پاسخگویی سیاستی از چالش‌های محوری استفاده از الگوریتم‌های یادگیری ماشین در پیش‌بینی تورم است. این یافته با ادبیات هوش مصنوعی توضیح‌پذیر و کاربرد یادگیری ماشین در اقتصاد همسو است Breiman . با معرفی جنگل تصادفی، ظرفیت بالای روش‌های تجمیعی در پیش‌بینی را نشان داد، اما رشد این نوع مدل‌ها همواره با مسئله کاهش شفافیت تفسیری همراه بوده است (Breiman, ۲۰۰۱). در حوزه‌های سیاستی، این چالش جدی‌تر است؛ زیرا خروجی مدل تنها یک پیش‌بینی عددی نیست، بلکه می‌تواند مبنای تصمیم‌هایی قرار گیرد که بر رفاه عمومی، نرخ بهره، هزینه تأمین مالی، اشتغال و توزیع درآمد اثر می‌گذارند . Ribeiroو همکاران با معرفی LIME نشان دادند که اعتماد به مدل‌های پیچیده نیازمند توضیح محلی پیش‌بینی‌هاست (Ribeiro et al., Lundberg .(۲۰۱۶و Lee نیز با ارائه SHAP چارچوبی برای تبیین سهم متغیرها در پیش‌بینی مدل‌های پیچیده فراهم کردند (Lundberg & Lee, ۲۰۱۷). یافته حاضر نشان می‌دهد که در سیاست‌گذاری اقتصادی، تفسیرپذیری صرفاً یک مسئله فنی نیست، بلکه بخشی از پاسخگویی دموکراتیک و اعتبار نهادی است. سیاست‌گذار باید بتواند توضیح دهد چرا مدل افزایش تورم را پیش‌بینی کرده، کدام متغیرها بیشترین نقش را داشته‌اند، خطای مدل چقدر است، و خروجی مدل نسبت به تغییر فروض چه حساسیتی دارد. بنابراین، استفاده از یادگیری ماشین در سیاست‌گذاری باید با داشبوردهای توضیح‌پذیر، سناریوهای قابل فهم، تحلیل حساسیت، مقایسه با مدل‌های اقتصادسنجی و مستندسازی تصمیم‌ها همراه باشد. در غیر این صورت، خطر تصمیم‌گیری مکانیکی، وابستگی بیش‌ازحد به الگوریتم و کاهش اعتماد عمومی وجود دارد.

یافته چهارم پژوهش نشان داد که الگوریتم‌های یادگیری ماشین می‌توانند در بهبود زمان‌بندی، هدف‌گذاری و هماهنگی سیاست‌های اقتصادی نقش تصمیم‌یار داشته باشند. این یافته با منطق سیاست‌گذاری پولی سازگار است؛ زیرا پیش‌بینی تورم یکی از ورودی‌های اصلی تصمیم‌گیری درباره نرخ بهره، مدیریت نقدینگی، کنترل انتظارات و هماهنگی سیاست‌های پولی و مالی است. مطالعات مربوط به منحنی فیلیپس و پیش‌بینی تورم نشان داده‌اند که مدل‌های سنتی در برخی دوره‌ها اطلاعات مفیدی فراهم می‌کنند، اما عملکرد آن‌ها در برابر شوک‌های ساختاری و تغییر رژیم‌ها محدود است (Stock & Watson, ۲۰۰۸). در چنین شرایطی، الگوریتم‌های یادگیری ماشین می‌توانند با استفاده از داده‌های فرکانس بالا، شاخص‌های بازار، داده‌های مالی و متغیرهای رفتاری، نقش سیستم هشدار زودهنگام را ایفا کنند. این امر برای سیاست‌گذاری اقتصادی

اهمیت عملی دارد؛ زیرا واکنش دیرهنگام به تورم می‌تواند هزینه کنترل آن را افزایش دهد. بااین‌حال، یافته‌ها نشان دادند که خروجی الگوریتم باید در قالب سناریوهای سیاستی ترجمه شود. پیش‌بینی اینکه تورم افزایش می‌یابد، به‌تنهایی کافی نیست؛ سیاست‌گذار باید بداند این افزایش ناشی از کدام کانال است و کدام ابزار سیاستی می‌تواند با کمترین هزینه اجتماعی آن را مهار کند. از این منظر، یادگیری ماشین می‌تواند پشتیبان تصمیم باشد، اما نباید به تصمیم‌گیرنده تبدیل شود. ترکیب پیش‌بینی الگوریتمی با دانش اقتصاد کلان، تحلیل نهادی، شناخت ساختار بودجه، وضعیت نظام بانکی و پویایی انتظارات، شرط استفاده مؤثر از این فناوری در سیاست‌گذاری است.

محدودیت‌ها :پژوهش حاضر با وجود ارائه تصویری عمیق از دیدگاه خبرگان، با چند محدودیت مواجه بود. نخست، داده‌ها صرفاً از طریق مصاحبه‌های نیمه‌ساختاریافته گردآوری شد و از روش‌هایی مانند مشاهده، تحلیل اسناد یا گروه کانونی استفاده نشد؛ بنابراین یافته‌ها بازتاب تجربه و تفسیر مشارکت‌کنندگان است و نه سنجش مستقیم عملکرد الگوریتم‌ها. دوم، مشارکت‌کنندگان همگی در تهران مستقر بودند و ممکن است دیدگاه خبرگان سایر شهرها یا نهادهای منطقه‌ای در یافته‌ها منعکس نشده باشد. سوم، به‌دلیل ماهیت تخصصی موضوع، تعداد مشارکت‌کنندگان محدود به ۱۹ نفر بود؛ هرچند اشباع نظری حاصل شد، اما تعمیم آماری یافته‌ها مدنظر نیست. چهارم، برخی مشارکت‌کنندگان به‌دلیل حساسیت موضوع سیاست‌گذاری تورمی و داده‌های اقتصادی، ممکن است با احتیاط درباره مسائل نهادی یا محدودیت‌های داده‌ای اظهار نظر کرده باشند.

پیشنهادها برای پژوهش‌های آینده :پیشنهاد می‌شود پژوهش‌های آینده با رویکرد ترکیبی انجام شوند و یافته‌های کیفی حاضر را با مقایسه تجربی عملکرد الگوریتم‌هایی مانند جنگل تصادفی، XGBoost، LSTM، شبکه‌های عصبی و مدل‌های اقتصادسنجی سنتی در پیش‌بینی تورم ایران تکمیل کنند. همچنین انجام مطالعات طولی برای بررسی پایداری عملکرد مدل‌ها در دوره‌های آرام، بحرانی، جهش ارزی و شوک‌های سیاستی ضروری است. پژوهش‌های آینده می‌توانند نقش داده‌های جایگزین، مانند داده‌های جست‌وجوی اینترنتی، قیمت‌های آنلاین، اخبار اقتصادی، داده‌های شبکه‌های اجتماعی و شاخص‌های انتظارات تورمی را در بهبود پیش‌بینی بررسی کنند. افزون بر این، مطالعه تطبیقی میان کشورهایی با تورم مزمن و کشورهایی با تورم پایین می‌تواند نشان دهد که مزیت یادگیری ماشین در چه محیط‌های نهادی و داده‌ای بیشتر است.

پیشنهادها برای عمل :نهادهای سیاست‌گذار اقتصادی باید استفاده از یادگیری ماشین را در قالب یک چارچوب تصمیم‌یار و نه جایگزین قضاوت کارشناسی دنبال کنند. ایجاد پایگاه داده یکپارچه اقتصاد کلان، ارتقای کیفیت و به‌هنگامی آمارها، تشکیل تیم‌های میان‌رشته‌ای متشکل از اقتصاددانان، متخصصان علم داده و سیاست‌گذاران، و طراحی داشبوردهای قابل تفسیر برای پیش‌بینی تورم ضروری است. همچنین توصیه می‌شود هر پیش‌بینی الگوریتمی همراه با دامنه عدم قطعیت، تحلیل حساسیت، مقایسه با مدل‌های مرجع و توضیح سهم متغیرهای کلیدی ارائه شود. در سطح نهادی، لازم است پروتکل‌هایی برای حکمرانی الگوریتمی، مستندسازی مدل‌ها، بازبینی دوره‌ای عملکرد، کنترل خطای پیش‌بینی و پاسخگویی در برابر تصمیم‌های مبتنی بر مدل تدوین شود.

نتیجه‌گیری

پژوهش حاضر با هدف تحلیل نقش الگوریتم‌های یادگیری ماشین در پیش‌بینی نرخ تورم و پیامدهای آن برای سیاست‌گذاری اقتصادی انجام شد. یافته‌ها نشان داد که یادگیری ماشین می‌تواند با کشف روابط غیرخطی، پردازش داده‌های حجیم، شناسایی الگوهای پنهان و ارائه هشدارهای زودهنگام، کیفیت پیش‌بینی تورم را ارتقا دهد. بااین‌حال، مزیت این الگوریتم‌ها وابسته به کیفیت داده، طراحی درست مدل، ارزیابی خارج از نمونه، تفسیرپذیری و پذیرش نهادی است. از دید خبرگان، یادگیری ماشین نمی‌تواند جایگزین تحلیل اقتصاد کلان، قضاوت سیاست‌گذار و فهم نهادی از تورم شود، اما می‌تواند به‌عنوان ابزاری قدرتمند برای پشتیبانی از تصمیم‌گیری، سناریونویسی و هماهنگی سیاست‌های اقتصادی عمل کند. بنابراین، بهره‌گیری موفق از این فناوری نیازمند نگاه صرفاً فنی نیست، بلکه مستلزم اصلاح حکمرانی داده، توسعه ظرفیت تحلیلی نهادهای سیاست‌گذار، ایجاد سازوکارهای توضیح‌پذیری و تدوین چارچوب پاسخگویی الگوریتمی است. در نهایت، سیاست‌گذاری اقتصادی هوشمند زمانی محقق می‌شود که پیش‌بینی الگوریتمی، تحلیل انسانی و مسئولیت نهادی در کنار یکدیگر قرار گیرند.

تشکر و قدردانی

از تمامی کسانی که در انجام این پژوهش ما را همراهی کردند تشکر و قدردانی به عمل می‌آید.

موازین اخلاقی

در این پژوهش اصول اخلاقی مرتبط با نشر و انجام پژوهش رعایت گردیده است.

مشارکت نویسندگان

تمامی نویسندگان نقش یکسانی ایفا کردند.

تعارض منافع

بر اساس اظهار نویسندگان، در این مقاله هیچ‌گونه تضاد منافعی وجود ندارد.

فهرست منابع

Araujo, G. S., & Gaglianone, W. P. (2023). Machine learning methods for inflation forecasting in Brazil: New contenders versus classical models. *Latin American Journal of Central Banking, 4*(2), 100087. doi:10.1016/j.latcb.2023.100087

Atkeson, A., & Ohanian, L. E. (2001). Are Phillips curves useful for forecasting inflation? *Federal Reserve Bank of Minneapolis Quarterly Review, 25*(1), 2–11.

Braun, V., & Clarke, V. (2006). Using thematic analysis in psychology. *Qualitative Research in Psychology, 3*(2), 77–101. doi:10.1191/1478088706qp063oa

Breiman, L. (2001). Random forests. *Machine Learning, 45*(1), 5–32. doi:10.1023/A:1010933404324

Creswell, J. W., & Poth, C. N. (2018). *Qualitative inquiry and research design: Choosing among five approaches* (4th ed.). SAGE Publications.

Goulet Coulombe, P., Leroux, M., Stevanovic, D., & Surprenant, S. (2022). How is machine learning useful for macroeconomic forecasting? *Journal of Applied Econometrics, 37*(5), 920–964. doi:10.1002/jae.2910

Guest, G., Bunce, A., & Johnson, L. (2006). How many interviews are enough? An experiment with data saturation and variability. *Field Methods, 18*(1), 59–82. doi:10.1177/1525822X05279903

Hyndman, R. J., & Athanasopoulos, G. (2021). *Forecasting: Principles and practice* (3rd ed.). OTexts.

Lincoln, Y. S., & Guba, E. G. (1985). *Naturalistic inquiry*. SAGE Publications.

Lundberg, S. M., & Lee, S.-I. (2017). A unified approach to interpreting model predictions. *Advances in Neural Information Processing Systems, 30*, 4765–4774.

Makridakis, S., Spiliotis, E., & Assimakopoulos, V. (2018). Statistical and machine learning forecasting methods: Concerns and ways forward. *PLOS ONE, 13*(3), e0194889. doi:10.1371/journal.pone.0194889

Medeiros, M. C., Vasconcelos, G. F. R., Veiga, Á., & Zilberman, E. (2021). Forecasting inflation in a data-rich environment: The benefits of machine learning methods. *Journal of Business & Economic Statistics, 39*(1), 98–119. doi:10.1080/07350015.2019.1637745

Mullainathan, S., & Spiess, J. (2017). Machine learning: An applied econometric approach. *Journal of Economic Perspectives, 31*(2), 87–106. doi:10.1257/jep.31.2.87

Ribeiro, M. T., Singh, S., & Guestrin, C. (2016). "Why should I trust you?" Explaining the predictions of any classifier. *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, 1135–1144. doi:10.1145/2939672.2939778

Stock, J. H., & Watson, M. W. (1999). Forecasting inflation. *Journal of Monetary Economics, 44*(2), 293–335. doi:10.1016/S0304-3932(99)00027-6

Stock, J. H., & Watson, M. W. (2008). Phillips curve inflation forecasts. In *Understanding inflation and the implications for monetary policy: A Phillips curve retrospective* (pp. 99–202). Federal Reserve Bank of Boston.

Varian, H. R. (2014). Big data: New tricks for econometrics. *Journal of Economic Perspectives, 28*(2), 3–28. doi:10.1257/jep.28.2.3