

A Framework for Integrating Transfer Learning and Crowd Intelligence to Overcome the Data-Poor Regime in Emerging Businesses

Maryam Nooraei
Abadeh *

Department of Computer Engineering, Arv.C.,
Islamic Azad University, Abadan, Iran

Shohreh Ajoudanian 

Department of Computer Engineering, Na.C.,
Islamic Azad University, Najafabad, Iran

Sondos Bahadori 

Department of Computer Engineering, IIC,
Islamic Azad University, Ilam, Iran

Abstract

Early-stage startups face the problem of cold start, as they have limited real-world data to train AI models. This lack of data, combined with the incompatibility of generic data with specific business needs, reduces the accuracy of predictions and recommendations. Rapid changes in data and concepts (such as data and concept drift), the risk of forgetting prior knowledge in transfer learning, and the heterogeneous quality of user feedback are the main challenges in this area. The proposed framework is an integrated and scalable architecture that combines transfer learning and crowd intelligence. The framework consists of four parts: collection and preprocessing of (limited), generic, and user feedback real-world data; transfer learning with a pretrained model and efficient optimization to prevent forgetting prior knowledge; model enhancement with filtered and weighted user feedback; and

* Corresponding Author: ma.nooraei@iau.ac.ir

How to Cite: Nooraei Abadeh, M., Ajoudanian, Sh., Bahadori, S. (2026). A Framework for Integrating Transfer Learning and Crowd Intelligence to Overcome the Data-Poor Regime in Emerging Businesses, *Journal of Business Intelligence Management Studies*, 15(55), 337-374. DOI: 10.22054/ims.2026.87652.2661

continuous prediction by monitoring data and concept changes with mathematical criteria. The training data is composed of a combination of real, generic, and user feedback data, and optimization is performed by minimizing error and controlling complexity. Evaluation on three real datasets. Other metrics such as prediction accuracy, positive sample detection, balance between the two, error reduction, and data stability were also improved in all three datasets, especially in investment data that is more scattered. This framework increases the efficiency of limited data and ensures the stability of the model.

Introduction

Emerging businesses often face the challenge of working under a low-data regime, where the scarcity of labeled or domain-specific datasets restricts the potential of traditional machine learning approaches. This issue becomes particularly critical when models are required to generalize well in dynamic environments such as startups, fintech solutions, and digital platforms, where continuous changes in consumer behavior and market trends are the norm. Addressing this challenge requires frameworks that can exploit prior knowledge while simultaneously adapting to the evolving data distribution. Recent advances in transfer learning have demonstrated strong capabilities in reusing pretrained models trained on large-scale source domains and fine-tuning them for target tasks with fewer data samples. However, transfer learning alone often struggles to maintain robustness in the long term, especially in contexts where the underlying data distribution shifts significantly. Complementary mechanisms are therefore necessary to ensure continuous adaptation without extensive data labeling costs.

Collective intelligence, on the other hand, leverages the wisdom of users, domain experts, and collaborative platforms to enrich datasets with high-quality feedback. By integrating user feedback with computational models, systems can achieve a deeper contextual understanding while remaining adaptive to new scenarios. This collective contribution acts as a reinforcement mechanism that strengthens model performance beyond the boundaries of static training data.

The motivation of this work is to integrate transfer learning and collective intelligence into a unified framework that systematically addresses the limitations of data scarcity while ensuring adaptability. The proposed approach is designed with modularity, scalability, and real-time responsiveness in mind, making it well-suited for emerging business ecosystems where agility and resilience are essential for success.

2- Methodology

The proposed framework is composed of four core modules, organized in a modular architecture with API-based interoperability. The process begins with the data acquisition stage, where two primary sources are combined: domain-specific real data D_r , typically scarce but highly relevant, and public or open datasets D_p , which provide broader contextual knowledge. After collection, both datasets are subjected to preprocessing procedures, including cleaning, normalization, feature extraction, and storage in a centralized feature store for consistent accessibility.

The second module is the transfer learning stage, where a pretrained base model, developed on a large-scale source domain, is selectively fine-tuned. Specifically, lower layers are kept frozen to preserve generalizable patterns, while upper layers are adapted using the combined dataset. Efficient optimization strategies such as LoRA and Adapters are employed to minimize computational costs and prevent catastrophic forgetting. This ensures that the model remains both lightweight and adaptive.

The third module integrates collective intelligence into the learning process. User feedback is continuously gathered from real-world interactions and subjected to quality filtering based on a threshold. Validated feedback is weighted according to user expertise and aggregated into a feedback dataset. This dataset is subsequently added to the training pool, enriching the model with experiential knowledge and domain-specific nuances that static datasets cannot capture.

The final module is real-time inference and continuous updating. The system provides predictions or recommendations in real-time while monitoring data drift and concept drift through KL-divergence measures. Once drift levels exceed predefined thresholds, the

retraining process is triggered automatically. Retraining stops only when both validation accuracy and drift measures meet the defined stopping criteria. Together, these mechanisms ensure that the framework operates adaptively in dynamic environments while maintaining high predictive performance.

3-Results

The experimental evaluation of the framework was conducted across multiple datasets representing different business contexts, including Yelp Reviews, Amazon Product data, and Startup Funding scenarios. Three configurations were compared: the baseline model without transfer learning, transfer learning alone, and the integrated transfer learning with collective intelligence (TL + CI). Metrics such as accuracy, precision, recall, F1-score, inverse loss, and inverse drift were used to assess performance comprehensively.

The baseline model exhibited moderate results, constrained by the limited availability of domain-specific data. These results underscored the inadequacy of relying solely on small datasets in emerging domains. With the introduction of transfer learning, performance improved significantly across all metrics. Accuracy values surpassed 0.80 in two out of three datasets, with consistent improvements across all metrics. Transfer learning effectively leveraged prior knowledge, allowing models to adapt more effectively to the new tasks despite limited data. However, some degree of drift sensitivity remained observable, particularly in the startup funding dataset where business contexts shift rapidly. The most significant improvement was observed when collective intelligence was integrated alongside transfer learning. Inverse drift values also confirmed stronger resilience against distributional changes, proving that continuous incorporation of user feedback provides the necessary adaptability for real-world business applications.

4- Conclusion

This study demonstrates the effectiveness of combining transfer learning with collective intelligence to overcome the low-data regime challenge prevalent in emerging business ecosystems. The integration of these two paradigms enhances not only the accuracy of predictions but also the robustness of models in dynamic environments where data distribution frequently shifts. From a methodological perspective, the

modular design of the framework ensures scalability, flexibility, and ease of integration with existing business platforms. By leveraging APIs and feature stores, the framework can be seamlessly deployed across diverse industries ranging from e-commerce and fintech to education and logistics.


The results highlight the complementary nature of transfer learning and collective intelligence. While transfer learning provides a foundation by reusing knowledge from source domains, collective intelligence enriches the system with real-time, domain-specific insights, ensuring continuous alignment with user needs and environmental changes. Together, they form a resilient and adaptive ecosystem for machine learning in business contexts.


Future work may explore extending this framework with reinforcement learning to optimize decision-making policies, as well as incorporating multimodal data sources such as images, audio, and sensor data to expand applicability. Additionally, exploring federated learning approaches could further enhance privacy-preserving data utilization while maintaining adaptability in distributed business environments.


Keywords: Transfer Learning, Collective Intelligence, Data Drift, Low-Data Regime, Emerging Businesses.



چارچوبی برای یکپارچه‌سازی یادگیری انتقالی و هوش جمعی در غلبه بر رژیم کم‌داده در کسب‌وکارهای نوظهور

مریم نورائی آباده *  استادیار، گروه مهندسی کامپیوتر، واحد بین‌المللی اروند، دانشگاه آزاد اسلامی، آبادان، ایران

شهره آجودانیان  استادیار، گروه مهندسی کامپیوتر، واحد نجف‌آباد، دانشگاه آزاد اسلامی، نجف‌آباد، ایران

سندس بهادری  استادیار، گروه مهندسی کامپیوتر، واحد ایلام، دانشگاه آزاد اسلامی، ایلام، ایران

چکیده

کسب‌وکارهای نوظهور در مراحل آغازین هوشمندسازی داده‌محور با چالش شروع سرد مواجه‌اند، زیرا به حجم محدودی از داده‌های واقعی دامنه‌ای برای آموزش و اعتبارسنجی مدل‌های هوش مصنوعی دسترسی دارند. این محدودیت داده، همراه با ناسازگاری داده‌های عمومی با نیازهای خاص هر کسب‌وکار، منجر به کاهش دقت پیش‌بینی‌ها و کیفیت توصیه‌ها می‌شود. علاوه بر این، پویایی محیط‌های تجاری و تغییرات سریع در توزیع داده و مفاهیم (نظیر انحراف داده و تغییر مفهوم)، خطر فراموشی دانش پیشین در یادگیری را تشدید می‌کند. چارچوب پیشنهادی این پژوهش، یک معماری یکپارچه و مقیاس‌پذیر برای ادغام یادگیری انتقالی و هوش جمعی ارائه می‌دهد. چارچوب پیشنهادی چهار لایه دارد: پیش‌پردازش داده‌ها، یادگیری انتقالی، تقویت با بازخورد کاربران و پیش‌بینی پیوسته با پایش انحراف. در این چارچوب، داده‌های آموزشی ترکیبی از داده‌های واقعی، عمومی و بازخورد کاربران هستند و بهینه‌سازی مدل باهدف کمینه‌سازی خطا و کنترل پیچیدگی انجام می‌گیرد. ارزیابی تجربی بر روی سه مجموعه داده واقعی نشان داد که این رویکرد بهبود مطلوبی در عملکرد ایجاد

چارچوبی برای یکپارچه‌سازی یادگیری انتقالی و هوش جمعی در ...؛ نورائی آبا‌ده و همکاران | ۳۴۳

می‌کند. علاوه بر معیار دقت، سایر شاخص‌ها همچون توانایی شناسایی نمونه‌های مثبت، تعادل میان دقت و بازخوانی، کاهش خطا و ثبات در برابر تغییرات داده نیز بهبود داشتند.

کلیدواژه‌ها: یادگیری انتقالی، هوش جمعی، انحراف داده، رژیم کم‌داده، کسب و کارهای نوظهور.

مقدمه

در عصر حاضر که نوآوری و تحول دیجیتال به عنوان محرک‌های اصلی اقتصاد جهانی شناخته می‌شوند، کسب و کارهای نوظهور (استارت‌آپ‌ها) نقشی محوری در ایجاد ارزش، اشتغال‌زایی و پیشبرد فناوری ایفا می‌کنند. این کسب و کارها، با ایده‌های خلاقانه و مدل‌های کسب و کار نوآورانه، پتانسیل بالایی برای تغییر ساختار بازارها و پاسخ به نیازهای جدید مشتریان دارند. با این حال، موفقیت استارت‌آپ‌ها به عوامل متعددی وابسته است که یکی از مهم‌ترین آن‌ها توانایی آن‌ها در بهره‌گیری از داده‌ها برای تصمیم‌گیری‌های هوشمند و پیش‌بینی‌های دقیق است. در مراحل اولیه فعالیت، استارت‌آپ‌ها اغلب با چالش «آغاز سرد»^۱ مواجه‌اند که به دلیل کمبود داده‌های واقعی و خاص برای آموزش مدل‌های هوش مصنوعی ایجاد می‌شود (Yu, Zhang et al. 2022, Jeon, Liu et al. 2024). این کمبود داده، توانایی استارت‌آپ‌ها در تحلیل رفتار مشتریان، بهینه‌سازی فرآیندها، پیش‌بینی روندهای بازار، یا ارائه توصیه‌های شخصی‌سازی شده را به شدت محدود می‌کند. بر اساس گزارش‌های جهانی، مانند گزارش‌های CB Insights و Startup Genome، بسیاری از استارت‌آپ‌ها در سه تا پنج سال اول فعالیت خود با شکست مواجه می‌شوند و کمبود داده‌های کافی برای تحلیل و تصمیم‌گیری یکی از عوامل کلیدی این ناکامی‌هاست (Fayaz-Bakhsh, Ataee et al. 2025).

مشکل آغاز سرد در رژیم کم‌داده^۲ چالش‌برانگیز است، زیرا مدل‌های سنتی یادگیری ماشین به حجم زیادی از داده‌های با کیفیت و متنوع نیاز دارند تا بتوانند الگوهای پیچیده و کاربردی را استخراج کنند (Lao, Yang et al. 2022). در فقدان چنین داده‌هایی، استارت‌آپ‌ها یا باید به داده‌های عمومی و متن‌باز (مانند پایگاه‌های داده موجود در دامنه‌های مشابه) تکیه کنند یا منتظر بمانند تا با گذشت زمان داده‌های کافی تولید شود که هر دو گزینه مشکلات خاص خود را دارند. داده‌های عمومی، هرچند در دسترس و گسترده‌اند،

-
1. Cold Start Problem
 2. Low-Data Regime

اغلب با نیازهای خاص یک کسب و کار نوظهور همخوانی ندارند، زیرا توزیع داده‌ها یا ویژگی‌های آن‌ها ممکن است با دامنه هدف متفاوت باشد. این ناسازگاری می‌تواند به کاهش دقت مدل‌ها و ناکارآمدی در پیش‌بینی‌ها منجر شود (Li, Mohd Noah et al.). از سوی دیگر، انتظار برای جمع‌آوری داده‌های کافی زمان‌بر است و در محیط‌های رقابتی که سرعت عمل حیاتی است، می‌تواند فرصت‌های رشد را از بین ببرد.

علاوه بر کمبود داده، استارت‌آپ‌ها در محیط‌هایی پویا و پرشتاب فعالیت می‌کنند که با تغییرات مداوم در رفتار مشتریان، ترجیحات بازار و الگوهای داده همراه است. این تغییرات که به‌عنوان انحراف داده^۱ و انحراف مفهوم^۲ شناخته می‌شوند، می‌توانند عملکرد مدل‌های هوش مصنوعی را در طول زمان تضعیف کنند. برای مثال، تغییر در ترجیحات مشتریان یک کسب و کار خرده‌فروشی آنلاین یا نوسانات در روندهای سرمایه‌گذاری در استارت‌آپ‌ها می‌تواند توزیع داده‌های ورودی را تغییر دهد، به گونه‌ای که مدل‌های آموزش‌دیده در گذشته دیگر کارایی لازم را نداشته باشند. این پویایی‌ها نیازمند رویکردهایی هستند که نه تنها کمبود داده را جبران کنند، بلکه بتوانند مدل‌ها را به‌صورت مستمر با تغییرات محیطی هماهنگ سازند.

یادگیری انتقالی^۳ به‌عنوان یک راهکار کلیدی برای غلبه بر مشکل کمبود داده مطرح شده است (Nerurkar 2025). این روش امکان استفاده از دانش پیش‌آموزش‌دیده از یک دامنه مبدأ (مانند داده‌های عمومی یا گسترده‌تر) را برای بهبود عملکرد در دامنه هدف (مانند یک استارت‌آپ خاص) فراهم می‌کند (Frikha 2022). در یادگیری انتقالی، یک مدل پایه^۴ که روی مجموعه داده‌های بزرگ و عمومی آموزش‌دیده، برای دامنه جدید تنظیم می‌شود (Fayaz-Bakhsh, Ataei et al. 2025). این تنظیم معمولاً با ثابت نگه‌داشتن لایه‌های پایین‌تر مدل که الگوهای عمومی و پایه را استخراج می‌کنند و به‌روزرسانی لایه‌های بالاتر که به ویژگی‌های خاص‌تر دامنه حساس هستند، انجام می‌شود. تکنیک‌های

1. Data Drift
2. Concept Drift
3. Transfer Learning
4. Mbase

بهینه‌سازی مانند LoRA^۱ این فرآیند را کارآمدتر کرده و از پدیده "فراموشی فاجعه‌بار"^۲ جلوگیری می‌کنند که در آن دانش عمومی مدل در اثر بازآموزی روی داده‌های خاص از بین می‌رود. با این حال، یادگیری انتقالی به تنهایی نمی‌تواند تمام چالش‌ها را برطرف کند، زیرا داده‌های عمومی ممکن است به‌طور کامل با نیازهای خاص کسب و کار هم‌راستا نباشند و نتوانند ویژگی‌های منحصر به فرد دامنه هدف را به‌خوبی پوشش دهند.

برای جبران این کاستی، مفهوم هوش جمعی^۳ با افزودن بازخوردهای کاربران، مدل را با تجربیات واقعی و به‌روز هماهنگ می‌کند، دقت آن را افزایش می‌دهد و مقاومت آن را در برابر تغییرات محیطی بهبود می‌بخشد (Huang and Chin 2018). با این حال، استفاده از بازخورد کاربران چالش‌هایی مانند کیفیت ناهمگون، تنوع زیاد در نظرات و نیاز به فیلتر و تجمیع مؤثر را به همراه دارد. بدون روش‌های مناسب برای ارزیابی و وزن‌دهی به بازخورد، مدل ممکن است تحت تأثیر داده‌های غیرمرتبط یا نادرست قرار گیرد (Gunasekaran, Mostafa et al. 2015). علاوه بر این، دستیابی به تعادل بین دقت مدل و پایداری آن در برابر تغییرات زمانی و محیطی، به‌ویژه در رژیم کم‌داده، نیازمند رویکردهایی است که بتوانند به‌صورت خودکار تغییرات را تشخیص داده و مدل را به‌روز کنند. معیارهایی مانند فاصله کولبک-لایبلر^۴ برای پایش انحراف داده و مفهوم و معیارهای توقف بازآموزی مبتنی بر دقت و ثبات، در این زمینه نقش کلیدی ایفا می‌کنند.

چارچوب پیشنهادی در این پژوهش، باهدف پاسخ به این چالش‌ها، یک معماری ماژولار، مقیاس‌پذیر و API-محور ارائه می‌دهد که یادگیری انتقالی و هوش جمعی را به‌صورت یکپارچه ترکیب می‌کند. چارچوب پیشنهادی نه تنها به استارت‌آپ‌ها امکان می‌دهد تا با منابع محدود به رشد سریع دست یابند، بلکه می‌تواند به‌عنوان پایه‌ای برای توسعه سیستم‌های هوش مصنوعی پایدار و انعطاف‌پذیر در اکوسیستم نوآوری عمل کند. با توجه به اهمیت روزافزون داده‌محوری در موفقیت کسب و کارها، این پژوهش می‌تواند راهگشای

-
1. Low-Rank Adaptation
 2. Catastrophic Forgetting
 3. Collective Intelligence
 4. KL-Divergence

تحقیقات آینده در زمینه هوش مصنوعی برای استارت‌آپ‌ها باشد و به توسعه ابزارهای کاربردی برای حمایت از اقتصاد نوآوری کمک کند.

پیشینه پژوهش

در سال‌های اخیر، پژوهش‌های متعددی به بررسی چالش «آغاز سرد»^۱ در کسب و کارهای نوظهور و رژیم کم‌داده، با تمرکز بر استفاده از یادگیری ماشین و هوش مصنوعی برای بهبود عملکرد در شرایط کمبود داده پرداخته‌اند (Lam, Vu et al. 2008). این بخش به مرور مهم‌ترین کارهای مرتبط در سه حوزه کلیدی می‌پردازد: یادگیری انتقالی، هوش جمعی و روش‌های پایش تغییرات داده و مفهوم. این مرور باهدف شناسایی شکاف‌های موجود در ادبیات پژوهش و برجسته‌سازی نوآوری‌های چارچوب پیشنهادی انجام شده است. در سه بخش پیشینه این پژوهش بررسی می‌شود.

۱-۲ یادگیری انتقالی برای غلبه بر کمبود داده

در مطالعه (Pan and Yang 2009) یک بررسی جامع به تشریح چارچوب‌ها و تکنیک‌های یادگیری انتقالی پرداخته و نقش کلیدی آن در بهبود عملکرد مدل‌های یادگیری ماشین در شرایط داده محدود را نشان داده است. این مقاله اساس نظری محکمی برای کاربرد یادگیری انتقالی در صنایع با داده کم فراهم می‌کند. در پژوهش (Ali, Zhou et al. 2025) مطالعه‌های کاربردی، چارچوبی مبتنی بر یادگیری انتقالی و یادگیری فدرال برای حفظ حریم خصوصی داده و توسعه مدل‌های کسب و کار در بازارهای نوظهور ارائه داده‌اند که نشان‌دهنده کارایی این روش در محیط‌های کم‌داده است. در مطالعه (Wang, Juni Asrini et al. 2022) به بررسی مدل‌سازی فرآیند انتقال مهارت‌های انسانی به هوش مصنوعی پرداختند و نشان دادند که این فرایند می‌تواند به بهبود عملکرد مدل‌های یادگیری انتقالی در شرایط ناقص بودن داده‌ها کمک کند، امری مهم در کسب و کارهای نوظهور با داده محدود.

در بسیاری از حوزه‌ها، محدودیت داده‌های آموزشی چالشی اساسی در توسعه مدل‌های دقیق یادگیری ماشین است. پژوهش‌های متعددی از جمله Woolley و همکاران (Woolley, Chabris et al. 2010) با معرفی RegionTrans نشان داده‌اند که استفاده از تطبیق دامنه مبتنی بر منطقه می‌تواند انتقال دانش بین شهرها را ممکن ساخته و دقت پیش‌بینی جریان جمعیت را تا ۱۰٫۷٪ نسبت به روش‌های پیشرفته بهبود دهد. در پژوهش (Da and Huang 2020) با استفاده از یادگیری انتقالی فدرال توانستند تطبیق دامنه را در حالی انجام دهند که حریم خصوصی داده‌ها حفظ شود، هرچند نیاز به حداقل تغییرات در مدل و محدودیت‌های قانونی از چالش‌های آن است. این مطالعات نشان می‌دهند که یادگیری انتقالی ابزار قدرتمندی برای غلبه بر کمبود داده و بهبود عملکرد مدل‌ها در شرایط داده محدود است.

۲-۲ هوش جمعی و اشتراک دانش سازمانی

هوش جمعی با ترکیب دانش و مهارت‌های متنوع کاربران یا عامل‌ها، ظرفیت یادگیری مدل‌ها را افزایش می‌دهد (Kazai, Kamps et al. 2013). مطالعه (Kamar, Hacker et al. 2012) نیز توانسته است از منابع چندگانه و روش وزن‌دهی مبتنی بر همبستگی دسته‌ای برای مقابله با چالش‌های تأمین جمعی در شرایط مجموعه باز بهره‌برداری کنند. مطالعاتی همچون (Hedderich, Lange et al. 2020) با معرفی CrowdTransfer نیز نشان داده‌اند که همکاری عامل‌ها و ترکیب چهار حالت انتقال (مشتق‌گیری، اشتراک، تکامل، ادغام) می‌تواند انعطاف‌پذیری سیستم‌ها را در بهره‌برداری از منابع انسانی و سیستمی افزایش دهد. این شواهد حاکی از آن است که هوش جمعی نه تنها دقت مدل‌ها را ارتقا می‌دهد بلکه تاب‌آوری و سازگاری آن‌ها را در سناریوهای پیچیده افزایش می‌دهد.

Woolley و همکاران (Woolley, Chabris et al. 2010) در تحقیق خود به تحلیل نقش هوش جمعی در بهبود تصمیم‌گیری‌های گروهی پرداخته‌اند و نشان داده‌اند که این رویکرد موجب هم‌افزایی دانش فردی و ارتقای بهره‌وری سازمان‌ها می‌شود. پژوهش (Da and Huang 2020) به تبیین نظریه «حکمت جمعی» پرداخت و کاربردهای آن را در

زمینه‌های مختلف اقتصادی و مدیریتی مورد بررسی قرار داد؛ این نظریه زمینه مفهومی قوی برای استفاده از هوش جمعی در کسب و کارهای نوظهور فراهم می‌کند.

۲-۳ کاربردهای عملی و مطالعه موردی

ترکیب یادگیری انتقالی و هوش جمعی در عمل توانسته است به پیشرفت‌های ملموسی در حوزه‌های مختلف منجر شود. Irshad و همکاران (Irshad, Xin et al. 2018) با به کارگیری یادگیری فعال و یادگیری انتقالی در شناسایی علائم پارکینگ، مدلی سریع و کم‌هزینه برای شهرهای هوشمند ارائه دادند (Wang, Juni Asrini et al. 2022). نیز با ترکیب تطبیق دامنه، انتخاب منبع مبتنی بر یادگیری تقویتی و یادگیری فدرال، سامانه‌ای برای پیش‌بینی اشغال پارکینگ طراحی کردند که حدود ۲۱٪ بهبود عملکرد داشت. Xie و همکاران (Xie, Lu et al. 2016) با رویکرد یادگیری چندوظیفه‌ای و انتقال متقابل دامنه‌ای موفق شدند مشکلات داده‌های پراکنده و ناقص را در پلتفرم‌های آنلاین کاهش دهند. این موارد نشان می‌دهد که کاربرد این فناوری‌ها در شرایط واقعی می‌تواند نه تنها بهره‌وری را افزایش دهد بلکه زمان و هزینه توسعه مدل‌ها را نیز کاهش دهد.

در یک مطالعه موردی، Chen و همکاران (Adewale 2024) از یادگیری انتقالی برای دسته‌بندی و تحلیل رفتار مشتری در یک بازار نوظهور با داده محدود استفاده کرده‌اند و نتایج نشان از افزایش دقت مدل‌ها و بهبود فرآیندهای بازاریابی داشته است. کاربرد یادگیری انتقالی در اتوماسیون فرآیندهای کسب و کار نوظهور، از جمله بازاریابی دیجیتال و خدمات مشتری، توسط (Paschek, Luminosu et al. 2017) مورد بررسی قرار گرفته و اثربخشی در کاهش هزینه‌ها و افزایش بهره‌وری نشان داده شده است. پژوهش‌هایی در زمینه پزشکی و امنیت سایبری مانند مطالعه (Alzubaidi, Fadhel et al. 2020) نشان داده‌اند که ترکیب یادگیری انتقالی و هوش جمعی می‌تواند به‌طور مؤثری با کمبود داده‌های آموزشی مقابله کند و تشخیص دقیق‌تری ارائه دهد.

مقاله‌ی Kairouz و همکاران (Kairouz, McMahan et al. 2021) به بررسی چالش‌های فنی، مدیریتی و حریم خصوصی موجود در استفاده از یادگیری انتقالی در

محیط‌های داده کم پرداخته و راهکارهایی برای بهبود امنیت و اعتمادسازمانی ارائه کرده است.

۲-۴ مقایسه تحلیلی با پژوهش‌های جدید و شکاف تحقیقاتی

جدول ۱ مقایسه کیفی چارچوب پیشنهادی پژوهش با دو مقاله‌ای که در بخش تحلیل به صورت کمی باهم مقایسه می‌شوند را نشان می‌دهد. مقاله اول یادگیری انتقالی صفر-شات برای آغاز سرد در جستجو و توصیه گر (Pham, Dai et al. 2023) و مقاله دوم، یادگیری انتقالی عمیق با جاسازی چندوجهی برای حل آغاز سرد و کمبود داده (Jafri, Ghazali et al. 2022) انتخاب شده است. مقایسه بر اساس معیارهای کلیدی مانند تمرکز پژوهش، روش شناسی، داده‌های استفاده‌شده، نتایج و تمایزها انجام شده است. مقاله (Pham, Dai et al. 2023)، بر یادگیری صفر-شات تمرکز دارد که برای سیستم‌های مقیاس بزرگ مناسب است اما فقدان بازخورد کاربران و پایش انحراف داده، کاربرد آن را در استارت‌آپ‌های کوچک محدود می‌کند. همچنین مقاله (Jafri, Ghazali et al. 2022) با جاسازی چندوجهی و فیلترینگ مشارکتی (مشابه هوش جمعی) به داده‌های چندمنبعی توجه دارد (اما پیچیدگی محاسباتی بالا و عدم پایش پویا، آن را برای استارت‌آپ‌های کم‌منبع کمتر عملی می‌کند).

چارچوب پیشنهادی در این پژوهش با ترکیب یکپارچه یادگیری انتقالی و هوش جمعی، به همراه پایش مستمر تغییرات داده و مفهوم، به این شکاف‌ها پاسخ می‌دهد. این چارچوب از داده‌های محدود واقعی (D_r)، داده‌های عمومی (D_p) و بازخوردهای فیلترشده کاربران (D_i) به صورت هم‌زمان استفاده می‌کند. با بهره‌گیری از تکنیک‌های بهینه‌سازی مانند LoRA، پیچیدگی محاسباتی کاهش یافته و از فراموشی دانش پیشین جلوگیری می‌شود. همچنین، پایش خودکار انحراف داده با استفاده از فاصله کولبک-لایبلر و بازآموزی مبتنی بر معیارهای دقت و ثبات، پایداری مدل را در محیط‌های پویا تضمین می‌کند. ارزیابی روی داده‌های واقعی (نظرات مشتریان، فروش محصولات و سرمایه‌گذاری استارت‌آپ‌ها) نشان‌دهنده کارایی این چارچوب در رژیم کم‌داده و محیط‌های پویا است.

جدول ۱. مقایسه چارچوب پیشنهادی پژوهش با دو مقاله مرتبط

چارچوب پیشنهادی	Zero-Shot Transfer Learning (Google Research)(Pham, Dai et al. 2023)	Deep Transfer Learning with Multimodal Embedding (PMC) (Jafri, Ghazali et al. 2022)	معیار
غلبه بر آغاز سرد در کسب و کارهای نوظهور با ترکیب یادگیری انتقالی و هوش جمعی در رژیم کم‌داده	حل آغاز سرد کوثری-آیتم در سیستم‌های جستجو و توصیه‌گر با یادگیری انتقالی صفر-شات	حل آغاز سرد و کمبود داده در سیستم‌های توصیه‌گر با یادگیری انتقالی و جاسازی چندوجهی	تمرکز پژوهش
(۱) یادگیری انتقالی با مدل پیش‌آموزش دیده و بهینه‌سازی LoRA (۲) تقویت با هوش جمعی (فیلتر و وزن‌دهی - بازخورد) (۳) پایش انحراف داده و مفهوم با KL-Divergence و بازآموزی خودکار	(۱) یادگیری نمایندگی آیتم‌ها با وظیفه کمکی (پیش‌بینی گراف همبستگی آیتم-آیتم) (۲) انتقال صفر-شات به پیش‌بینی کوثری-آیتم بدون داده‌های جفتی	(۱) فاز آفلاین: استخراج ویژگی با VGG-16 و جاسازی چندوجهی (کاربر، لاگ، شبکه‌های اجتماعی) با SVD (۲) فاز آنلاین: فیلترینگ مشارکتی کاربرمحور برای توصیه‌های top-N	روش‌شناسی کلیدی
(۱) ترکیب یکپارچه یادگیری انتقالی و هوش جمعی (۲) پایش مستمر انحراف داده و مفهوم (۳) مقیاس‌پذیری با LoRA (۴) استفاده از بازخورد کاربران برای تطبیق پویا	(۱) یادگیری صفر-شات بدون نیاز به داده‌های جفتی (۲) تعمیم‌پذیری بالا به جفت‌های نادر (۳) مناسب برای سیستم‌های جستجو مقیاس‌بزرگ	(۱) استفاده از جاسازی چندوجهی برای غنی‌سازی داده‌ها (۲) فیلترینگ مشارکتی برای توصیه‌های شخصی (۳) عملکرد خوب در سطوح مختلف کمبود داده	مزایا
(۱) وابستگی به کیفیت بازخورد کاربران (۲) نیاز به تنظیم دقیق آستانه‌های بازآموزی (drift, tacc)	(۱) عدم استفاده از بازخورد کاربران (۲) وابستگی به داده‌های عمومی با کیفیت بالا (۳) فقدان پایش انحراف داده	(۱) پیچیدگی محاسباتی بالا (VGG-16 و SVD) (۲) عدم پایش مستمر انحراف داده (۳) تمرکز محدود به توصیه‌گرها	محدودیت‌ها
مناسب برای استارت‌آپ‌های متنوع (تحلیل احساسات، فروش، سرمایه‌گذاری) در رژیم کم‌داده	سیستم‌های جستجو و توصیه‌گر مقیاس‌بزرگ (مانند Google)	سیستم‌های توصیه‌گر تجارت الکترونیکی با داده‌های چندوجهی	کاربردها

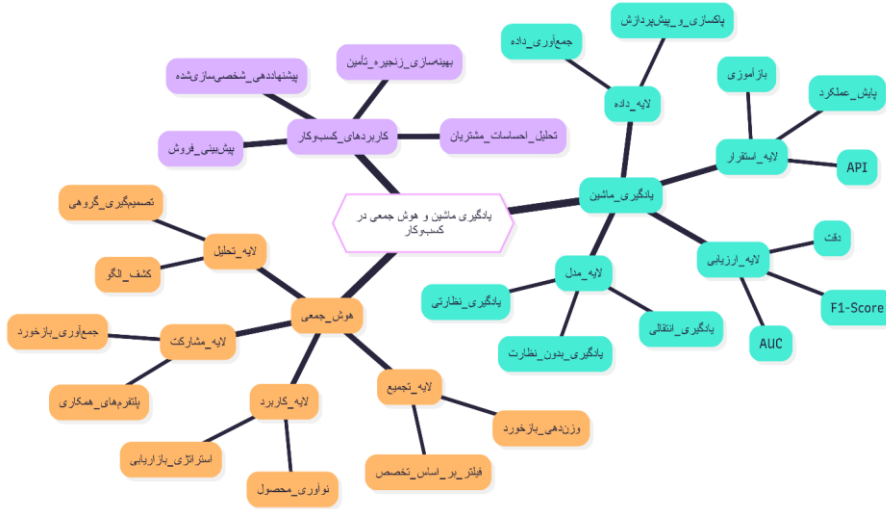
روش شناسی

محور نخست روش این پژوهش به یادگیری ماشین اختصاص دارد که فرآیند آن از لایه داده آغاز می‌شود؛ جایی که داده‌ها از منابع مختلف جمع‌آوری شده و با انجام عملیات پاک‌سازی و پیش‌پردازش، برای مرحله مدل‌سازی آماده می‌شوند. در لایه مدل، بسته به ماهیت مسئله از الگوریتم‌های یادگیری نظارتی، بدون نظارت و یادگیری انتقالی استفاده می‌شود تا هم از دانش پیشین بهره‌برداری شود و هم نیاز به داده‌های وسیع کاهش یابد. لایه ارزیابی با استفاده از شاخص‌هایی همچون دقت، امتیاز F1 و AUC کیفیت مدل را می‌سنجد و در نهایت لایه استقرار، مدل را از طریق API در محیط واقعی پیاده‌سازی کرده، عملکرد آن را پایش می‌کند و در صورت افت کیفیت یا تغییر داده، فرآیند بازآموزی را فعال می‌سازد.

محور دوم این نقشه به هوش جمعی می‌پردازد که از لایه مشارکت آغاز می‌شود؛ در این لایه بازخورد کاربران از طریق پلتفرم‌های همکاری جمع‌آوری می‌شود. سپس در لایه جمع‌بندی، بازخوردها بر اساس میزان تخصص و اعتبار کاربران وزن‌دهی شده و فیلترهای کیفی برای حذف نویز و داده‌های کم‌اعتبار اعمال می‌شود. لایه تحلیل با کشف الگوهای پنهان در بازخوردها، زمینه تصمیم‌گیری گروهی را فراهم می‌سازد و در لایه کاربرد، نتایج این تحلیل‌ها برای نوآوری محصول و بهبود استراتژی‌های بازاریابی به کار گرفته می‌شود. در آخر، بخش کاربردهای کسب و کار به‌عنوان خروجی تلفیق یادگیری ماشین و هوش جمعی مطرح می‌شود. این بخش شامل پیش‌بینی فروش با استفاده از الگوهای تاریخی، تحلیل احساسات مشتریان از داده‌های متنی و شبکه‌های اجتماعی، بهینه‌سازی زنجیره تأمین از طریق داده‌های لحظه‌ای و ارائه پیشنهادهای شخصی‌سازی شده برای ارتقای نرخ تبدیل و رضایت مشتریان است. چنین ساختاری، نقشه‌ای جامع از مسیر داده تا خلق ارزش را ترسیم می‌کند که به تصمیم‌گیرندگان کمک می‌کند روابط بین اجزای فنی و تجاری را به شکلی سریع و شهودی درک کنند. نقشه ذهنی این پژوهش در شکل ۱ دیده می‌شود.

1. Accuracy

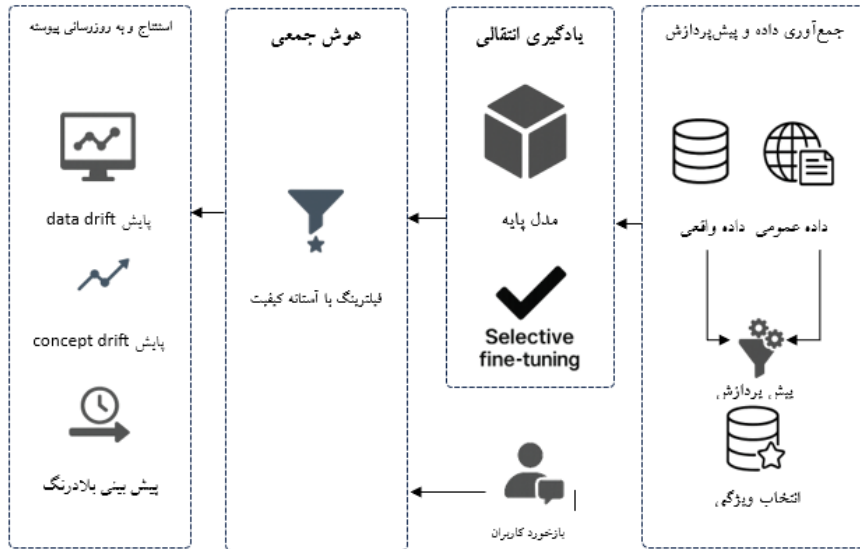
شکل ۱. نقشه ذهنی مفهومی-فنی برای همگرایی یادگیری ماشین و هوش جمعی



۳-۱ معماری چارچوب پیشنهادی

چارچوب پیشنهادی ما شامل چهار بخش اصلی است که در یک معماری ماژولار و با قابلیت توسعه و اتصال از طریق API پیاده‌سازی شده‌اند. فرآیند از مرحله دریافت داده آغاز می‌شود؛ جایی که مجموعه‌ای از داده‌های واقعی و محدود از دامنه کسب‌وکار نوظهور که آن را D_T می‌نامیم، به همراه داده‌های عمومی یا متن‌باز مرتبط با همان دامنه (D_P) جمع‌آوری می‌گردد. این داده‌ها پس از جمع‌آوری، تحت یک فرآیند پیش‌پردازش شامل پاک‌سازی، نرمال‌سازی، استخراج ویژگی و ذخیره‌سازی در یک مخزن ویژگی^۱ قرار می‌گیرند.

شکل ۲. فلوجارت مدل پیشنهادی



در گام دوم، ماژول یادگیری انتقالی وارد عمل می‌شود. در این مرحله، یک مدل پایه M_{base} که پیش‌تر بر روی یک دامنه مبدأ D_{source} آموزش دیده، بارگذاری می‌گردد. این مدل به صورت انتخابی بازآموزی می‌شود؛ به این معنا که تنها لایه‌های بالایی آن به‌روزرسانی می‌شوند و لایه‌های پایین‌تر که الگوهای پایه را استخراج می‌کنند، ثابت باقی می‌مانند. برای این بازآموزی از داده‌های ترکیبی $D_T \cup D_P$ استفاده می‌شود تا وزن‌های مدل (θ) بهینه شوند.

در مرحله سوم، تقویت عملکرد مدل با استفاده از هوش جمعی انجام می‌شود. بازخوردهای کاربران که با نماد $F = \{f_i\}$ نشان داده می‌شوند، به‌طور مستمر از تعاملات واقعی گردآوری شده و سپس با یک الگوریتم فیلتر مبتنی بر آستانه کیفیت tf پالایش می‌شوند. بازخوردهای معتبر به صورت وزن‌دار با توجه به سابقه و تخصص هر کاربر تجمیع شده و در قالب یک مجموعه داده جدید (D_f) به فرآیند آموزش افزوده می‌گردند. این امر باعث می‌شود که مدل نه تنها از داده‌های اولیه، بلکه از تجربه‌های واقعی کاربران نیز یاد بگیرد و به‌مرور زمان سازگاری بیشتری با نیازهای دامنه پیدا کند.

مرحله چهارم شامل استنتاج و به‌روزرسانی پیوسته است. در این بخش، مدل خروجی‌های پیش‌بینی یا توصیه را در زمان واقعی ارائه می‌کند و به‌صورت هم‌زمان، شاخص‌های تغییر توزیع داده^۱ و تغییر مفهوم^۲ پایش می‌شوند. میزان Drift با استفاده از فاصله کولبک-لایبلر^۳ بین توزیع داده‌های آموزش و داده‌های جاری اندازه‌گیری شده و در صورت عبور از آستانه تعریف شده، فرآیند بازآموزی خودکار فعال می‌گردد. معیار توقف بازآموزی بر اساس ترکیبی از دقت اعتبارسنجی (Acc_{val}) و سطح Drift تعیین می‌شود، به طوری که بازآموزی تنها زمانی متوقف می‌شود که مدل به دقت مطلوب رسیده و تغییرات داده به سطح قابل قبول کاهش یافته باشد. مجموعه داده آموزشی نهایی ما به صورت

$$D_{train} = D_r \cup D_p \cup D_f \quad (1)$$

تعریف می‌شود که در آن D_f حاصل از بازخورد معتبر کاربران است. بهینه‌سازی مدل در چارچوب یادگیری انتقالی از طریق حل مسئله

$$\theta^* = \arg \min_{\theta} \frac{1}{N} \sum_{i=1}^N L(y_i, M_{\theta}(x_i)) + \lambda R(\theta) \quad (2)$$

انجام می‌گیرد که در آن L تابع زیان و R جمله منظم‌ساز برای کنترل پیچیدگی مدل است. تجمیع بازخوردهای کاربران نیز بر اساس رابطه

$$f_{agg} = \frac{\sum_{i=1}^m w_i f_i}{\sum_{i=1}^m w_i} \quad (3)$$

صورت می‌پذیرد که در آن w_i وزن تخصص‌کاربر i و f_i بازخورد وی است. شاخص انحراف داده نیز با فرمول

$$Drift = KL(P_{train}(X) \parallel P_{current}(X)) \quad (4)$$

-
1. Data Drift
 2. Concept Drift
 3. KL-Divergence

اندازه گیری می شود.

این روش پیشنهادی، با ادغام یادگیری انتقالی، داده های ترکیبی و هوش جمعی، رویکردی انعطاف پذیر و مقیاس پذیر برای غلبه بر چالش رژیم کم داده در کسب و کارهای نوظهور فراهم می آورد، به گونه ای که هم بهره وری داده های محدود افزایش یافته و هم پایداری عملکرد مدل در گذر زمان حفظ می شود.

تحلیل و یافته ها

در این بخش، نتایج حاصل از ارزیابی چارچوب پیشنهادی تحلیل و تفسیر می شود تا میزان اثربخشی آن در غلبه بر چالش رژیم کم داده در کسب و کارهای نوظهور به طور دقیق بررسی گردد. تمرکز اصلی این تحلیل بر مقایسه عملکرد مدل پایه، مدل مبتنی بر یادگیری انتقالی و مدل تقویت شده با هوش جمعی در سناریوهای واقعی است.

۴-۱ دیتاست

در مطالعه حاضر، برای آموزش و ارزیابی چارچوب یادگیری انتقالی و هوش جمعی، از سه مجموعه داده واقعی و کاربردی استفاده شده است. این دیتاست ها شامل داده های متنوعی از حوزه های مختلف کسب و کارهای نوظهور می باشند. استفاده هم زمان از داده های محدود و داده های عمومی، به همراه بازخوردهای واقعی کاربران، امکان ارزیابی دقیق و جامع چارچوب پیشنهادی را فراهم می کند.

جدول ۲. مشخصات دیتاست های استفاده شده

نام دیتاست	حجم داده (نمونه ها)	دامنه کاربرد	توضیحات کوتاه
Yelp Reviews	~200,000	تحلیل احساس مشتریان در کسب و کارهای محلی	نظرات کاربران درباره کسب و کارهای کوچک و متوسط با ویژگی های متن کوتاه و متنوع
Amazon Product Data	~100,000	داده های فروش و نقد محصولات	شامل اطلاعات محصولات، نقدها و داده های فروش با تمرکز بر کسب و کارهای نوظهور در بازارهای مختلف

نام دیتاست	حجم داده (نمونه‌ها)	دامنه کاربرد	توضیحات کوتاه
Startup Funding Data	~50,000	داده‌های سرمایه‌گذاری استارت‌آپ‌ها	اطلاعات مربوط به دوره‌های سرمایه‌گذاری، ارزش شرکت‌ها و وضعیت رشد استارت‌آپ‌ها

دیتاست Yelp شامل میلیون‌ها نظر و امتیاز کاربران به کسب‌وکارهای محلی است، از رستوران‌ها گرفته تا فروشگاه‌های کوچک. حجم داده قابل انتخاب و کاهش است تا برای مدل‌های کم‌داده مناسب شود. داده‌ها شامل متن، امتیاز عددی، تاریخچه تعاملات و ویژگی‌های متنی هستند. این دیتاست به دلیل تنوع دامنه و کمبود داده‌های خاص برای برخی کسب‌وکارهای نوظهور، محیط مناسبی برای آزمایش یادگیری انتقالی فراهم می‌کند.

دیتاست Amazon_Product شامل داده‌های محصول شامل مشخصات فنی، نقدها و فروش محصولات مختلف است که برای کسب‌وکارهای نوظهور در بازارهای رقابتی اهمیت زیادی دارد. این مجموعه داده ترکیبی از داده‌های عمومی و نقدهای کاربران است که می‌تواند به‌عنوان داده عمومی در چارچوب یادگیری انتقالی مورد استفاده قرار گیرد. این دیتاست امکان تحلیل روند رشد فروش و بازخورد مشتریان را در شرایط کم‌داده فراهم می‌کند.

دیتاست Startup_Funding مجموعه‌ای از اطلاعات سرمایه‌گذاری و رشد استارت‌آپ‌ها است که شامل مراحل مختلف تأمین مالی، مقادیر سرمایه جذب‌شده و وضعیت مالی استارت‌آپ‌ها است. این داده‌ها برای مطالعه و تحلیل الگوهای رشد و موفقیت کسب‌وکارهای نوظهور بسیار کاربردی هستند. به دلیل محدود بودن داده‌ها برای بسیاری از استارت‌آپ‌ها، این دیتاست مثال خوبی برای بررسی رژیم کم‌داده و کاربرد یادگیری انتقالی در حوزه کسب‌وکارهای نوظهور به شمار می‌رود.

۲-۴ معیارها

دقت اعتبارسنجی یکی از معیارهای پایه و متداول در ارزیابی مدل‌های یادگیری ماشین

است که نسبت نمونه‌های درست پیش‌بینی شده را به کل نمونه‌ها نشان می‌دهد. برای مدل‌های طبقه‌بندی، این معیار به سادگی صحت کلی عملکرد مدل را نشان می‌دهد. تابع زیان (L) در فرایند آموزش نقش کلیدی دارد و با اندازه‌گیری اختلاف بین پیش‌بینی مدل و داده‌های واقعی، مسیر بهینه‌سازی مدل را تعیین می‌کند. همچنین، جمله منظم‌ساز که معمولاً به صورت L1 یا L2 تعریف می‌شود، برای جلوگیری از بیش‌برازش و حفظ تعادل بین پیچیدگی مدل و دقت آن به کار گرفته می‌شود. جدول ۳ معیارهای ارزیابی این مطالعه را نشان می‌دهد.

جدول ۳. معیارهای ارزیابی

معیار	نماد	فرمول / توضیح	کاربرد
دقت اعتبارسنجی	Acc_{val}	$\frac{TP + TN}{TP + TN + FP + FN}$	نسبت پیش‌بینی‌های صحیح به کل نمونه‌ها
جمله منظم‌ساز	$R(\theta)$	L2 Regularization	جلوگیری از بیش‌برازش و کنترل پیچیدگی مدل
شاخص انحراف داده	Drift	$KL(P_{train} \parallel P_{current})$	اندازه‌گیری تغییر توزیع داده‌ها
آستانه دقت	τ_{acc}	Acc_{val}	معیار توقف آموزش
آستانه انحراف	τ_{drift}	Drift	معیار توقف آموزش
دقت (Precision)	P	$\frac{TP}{TP + FP}$	نسبت پیش‌بینی‌های مثبت درست به کل مثبت‌ها
یادآوری (Recall)	R	$\frac{TP}{TP + FN}$	نسبت نمونه‌های مثبت شناسایی شده به کل نمونه‌های مثبت
معیار F1	$F1$	$2 \times \frac{P \times R}{P + R}$	میانگین هارمونیک دقت و یادآوری

علاوه بر دقت کلی، معیارهای دقیق‌تر و حساس‌تری مثل دقت^۱ و یادآوری^۲ نیز در این مطالعه مورد توجه هستند. دقت نشان‌دهنده درصد نمونه‌های مثبت درست شناسایی شده از میان تمام پیش‌بینی‌های مثبت است، درحالی‌که یادآوری بیانگر توانایی مدل در شناسایی تمام نمونه‌های مثبت واقعی می‌باشد. معیار F1 به‌عنوان میانگین هارمونیک دقت و

1. Precision
2. Recall

یادآوری، تعادلی میان این دو معیار برقرار می‌کند و برای داده‌های نامتوازن یا کم‌داده اهمیت زیادی دارد.

در کنار معیارهای فوق، شاخص انحراف داده^۱ که با استفاده از فاصله کولبک-لایبیلر اندازه‌گیری می‌شود، برای پایش تغییرات توزیع داده‌های ورودی به کار می‌رود. این شاخص نقش مهمی در تشخیص تغییرات ناخواسته داده‌ها و فعال‌سازی فرایند بازآموزی خودکار دارد. دو آستانه کلیدی T_{drift} و T_{acc} به‌عنوان معیارهای توقف آموزش تعیین شده‌اند تا مدل تنها زمانی آموزش را متوقف کند که به دقت موردنظر رسیده و تغییر توزیع داده نیز در حد قابل قبول باقی مانده باشد. این رویکرد تضمین‌کننده پایداری و کیفیت مداوم مدل در شرایط متغیر است.

۴-۳ تنظیمات ماژول هوش جمعی

در این پیاده‌سازی، ابتدا گروهی از ۲۵۰ مشارکت‌کننده با امتیاز تخصصی بالاتر از ۰/۷ انتخاب شدند تا کیفیت داده‌های جمع‌آوری شده تضمین شود. داده‌ها به نسبت ۸۰ درصد برای آموزش و ۲۰ درصد برای اعتبارسنجی تقسیم شد و در هر چرخه، وظایف برچسب‌گذاری به گروه ارسال و پس از دریافت پاسخ‌ها، با استفاده از روش رأی‌گیری وزن‌دار ترکیب شدند تا نظرات دقیق‌تر وزن بیشتری داشته باشند. این فرآیند در چهار چرخه تکرار شد تا پایداری و پوشش داده افزایش یابد.

در مرحله ادغام با یادگیری انتقالی، از روش ادغام در سطح ویژگی^۲ استفاده شد که در آن ویژگی‌های استخراج‌شده از داده‌های هوش جمعی با ویژگی‌های مدل مبنا ترکیب شده و سپس فرآیند آموزش مدل ادامه یافت. این روش باعث شد تا دانش جمع‌آوری شده از کاربران به شکل مستقیم در بازنمایی ویژگی‌ها وارد شود و دقت پیش‌بینی‌ها در سناریوهای داده کم افزایش یابد. تنظیمات این ماژول در جدول ۴ نمایش داده شده است.

1. Drift

2. Feature-level Fusion


جدول ۴. مشخصات شرکت کنندگان

پارامتر	مقدار	توضیح
معیار تخصص	Expertise Score ≥ 0.7	محاسبه بر پایه تاریخچه برچسب گذاری
تقسیم داده	۸۰٪ آموزش و ۲۰٪ اعتبارسنجی	برای بهینه سازی مدل
روش ترکیب	رأی گیری وزن دار	وزن دهی بر اساس اطمینان پاسخ ها

۴-۴ یافته ها

نتایج نشان می دهد که در هر سه دیتاست، گذر از مدل پایه به مدل یادگیری انتقالی منجر به افزایش قابل توجه دقت شده است، اما بیشترین جهش زمانی رخ داده که ماژول هوش جمعی به مدل اضافه شده است. برای مثال، در Yelp_Reviews دقت از محدوده ۷۲٪ در حالت پایه به حدود ۸۱٪ با TL و سپس به بیش از ۸۸٪ با TL+CI رسیده است. این روند در Amazon_Product نیز تکرار شده، اگرچه دامنه تغییرات کمتر بوده است. در Startup_Funding که داده ها پراکندگی بیشتری دارند، نقش TL+CI حتی پررنگ تر بوده و افزایش دقت بیش از ۱۲ درصد نسبت به مدل پایه مشاهده شده است.


شکل ۳. مقایسه معیار دقت بر روی دیتاست های مختلف



در شاخص Precision، اضافه کردن هوش جمعی به یادگیری انتقالی باعث کاهش خطای

مثبت کاذب^۱ شده است. برای مثال در Amazon_Product، مقدار Precision از حدود ۷۴٪ در TL به بیش از ۷۹٪ در TL+CI رسیده که بیانگر بهبود هدف‌گیری دقیق پیش‌بینی‌هاست. در Yelp_Reviews، افزایش Precision کمتر از معیار Accuracy بوده و این می‌تواند به دلیل ماهیت متنی و تنوع بالای بازخورد کاربران باشد. Startup_Funding بیشترین بهبود Precision را داشته که نشان می‌دهد مدل توانسته با یادگیری از بازخورد متخصصان، موارد سرمایه‌گذاری موفق را با خطای کمتر شناسایی کند.

شکل ۴. مقایسه معیار precision بر روی دیتاست‌های مختلف

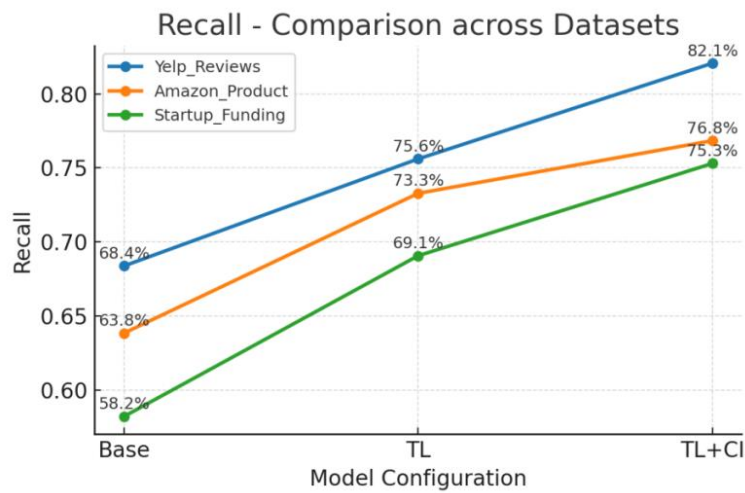


حساسیت مدل در هر سه دیتاست با اضافه شدن TL افزایش یافته اما بیشترین جهش مربوط به TL+CI است. Recall در Yelp_Reviews از ۶۸٪ در Base به ۷۵٪ در TL و ۸۲٪ در TL+CI بهبود یافته است که نشان می‌دهد مدل توانسته تعداد بیشتری از نمونه‌های مثبت واقعی را شناسایی کند. شاخص F1 که تعادلی بین Precision و Recall است، نشان می‌دهد که TL+CI در هر سه دیتاست بهترین توازن را ایجاد کرده است. برای Yelp_Reviews، F1 از ۶۷٪ در Base به ۷۵٪ در TL و ۸۱٪ در TL+CI رسیده که

1. False Positive

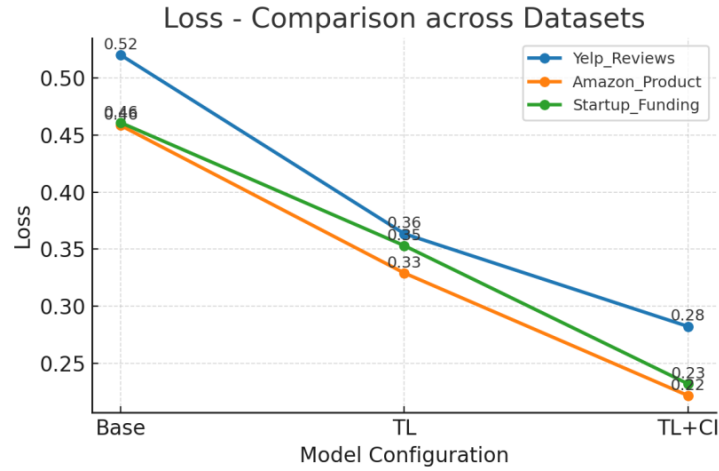
افزایش هم‌زمان هر دو مؤلفه Precision و Recall را تأیید می‌کند. برای Startup_Funding، F1 از ۵۹٫۳٪ در Base به ۶۸٪ در TL و ۷۳٫۴٪ در TL+CI رسیده که افزایش هم‌زمان هر دو مؤلفه Precision و Recall را نشان می‌دهد. همچنین برای Amazon_Product، F1 از ۶۴٫۳٪ در Base به ۷۴٫۸٪ در TL و ۷۸٫۵٪ در TL+CI رسیده است.

شکل ۴. مقایسه معیار Recall بر روی دیتاست‌های مختلف



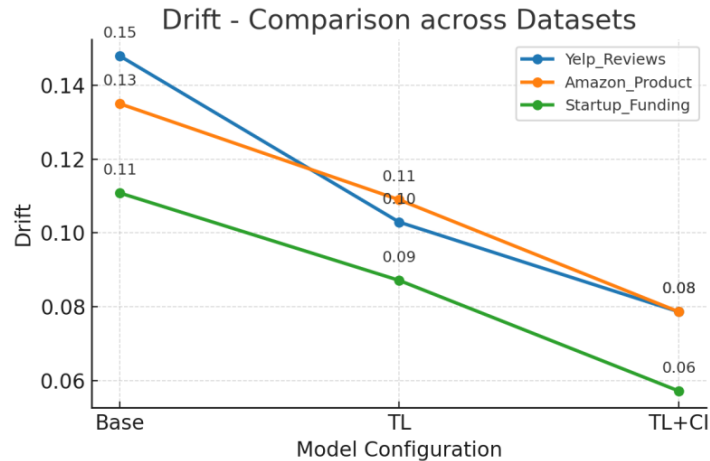
مقدار Loss مطابق شکل ۵، در هر سه دیتاست با انتقال از Base به TL و سپس TL+CI کاهش یافته است که ناشی از تطبیق بهتر مدل با داده‌های متنی و بازخورد کاربران است.

شکل ۵. مقایسه معیار Loss بر روی دیتاست‌های مختلف



شاخص Drift که تفاوت بین توزیع داده‌های آموزش و داده‌های جاری را می‌سنجد، نشان می‌دهد که TL+CI توانسته بیشترین ثبات را ایجاد کند (شکل ۶). در Yelp_Reviews معیار Drift از حدود ۰,۱۵ در Base به کمتر از ۰,۰۸ در TL+CI کاهش یافته است. در Amazon_Product که تغییرات توزیع داده کمتر بوده، کاهش Drift نیز محدودتر است. Startup_Funding بیشترین کاهش Drift را تجربه کرده که به دلیل نقش کلیدی بازخورد مستمر در به‌روز کردن مدل با تغییرات سریع بازار سرمایه‌گذاری نوظهور است.

شکل ۶. مقایسه معیار **Drift** بر روی دیتاست‌های مختلف



۴-۵ مقایسه با روش‌های پایه

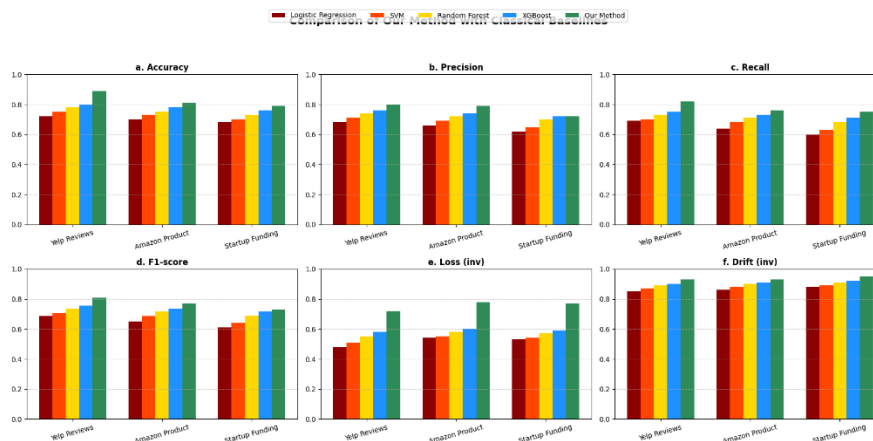
در این تحلیل مطابق شکل ۷، عملکرد سه روش مختلف شامل مدل پایه بدون یادگیری انتقالی، یادگیری انتقالی^۱ و یادگیری انتقالی همراه با هوش جمعی^۲ بر روی سه مجموعه در شش معیار Accuracy، Precision، Recall، F1-score، Loss و Drift بررسی شده است. مقایسه نتایج نشان می‌دهد که استفاده از یادگیری انتقالی، نسبت به مدل پایه، بهبود مطلوبی در تمام معیارها ایجاد می‌کند و افزودن هوش جمعی این بهبود را بیش‌ازپیش تقویت می‌کند، به‌ویژه در معیارهای مرتبط با پایداری مدل در برابر تغییرات داده. در معیار دقت^۳، مدل پایه پایین‌ترین مقادیر را ثبت کرده است، اما با به‌کارگیری یادگیری انتقالی، دقت در هر سه دیتاست افزایش یافته و در ترکیب یادگیری انتقالی و هوش جمعی به بیشترین مقدار خود رسیده است. این روند نشان می‌دهد که هر دو تکنیک به کاهش خطاهای پیش‌بینی کمک کرده‌اند، ولی اثر هوش جمعی در تثبیت عملکرد و جلوگیری از افت دقت در دامنه‌های مختلف مشهودتر است.

1. Transfer Learning
2. TL + Collective Intelligence
3. Accuracy

در معیارهای Precision و Recall، روند مشابهی مشاهده می‌شود. مدل پایه دچار محدودیت در تشخیص صحیح نمونه‌های مثبت بوده، اما یادگیری انتقالی با استفاده از دانش پیشین، این ضعف را کاهش داده است. افزوده شدن هوش جمعی باعث شده تا مدل در شناسایی مثبت‌ها دقیق‌تر عمل کند. این امر ناشی از غنی‌تر شدن داده آموزشی به واسطه بازخورد کاربران و تجمیع تجربه‌های عملی است.

نتایج روی معیار F1-score نشان می‌دهد که مدل‌های TL + CI توانسته‌اند توازن بهتری بین دقت و بازخوانی برقرار کنند. بررسی معیار Drift معکوس شده که بیانگر پایداری مدل در برابر تغییرات توزیع داده‌هاست، نشان می‌دهد که مدل‌های مجهز به هوش جمعی در مقایسه با دو روش دیگر، بیشترین مقاومت را در برابر Data Drift و Concept Drift داشته‌اند. به‌ویژه، کاهش Drift در Yelp_Reviews و Startup_Funding اهمیت استفاده از بازخوردهای واقعی کاربران برای به‌روزرسانی پیوسته مدل را برجسته می‌کند. این نتایج تأیید می‌کند که ترکیب یادگیری انتقالی و هوش جمعی نه تنها دقت را بالا می‌برد، بلکه پایداری عملکرد مدل را در بلندمدت تضمین می‌کند.

شکل ۷. مقایسه با روش‌های پایه



۴-۶ آزمون همگرایی

برای ارائه تحلیل عددی دقیق‌تر از KL-Divergence در چارچوب مقاله، نیاز به تخمین و

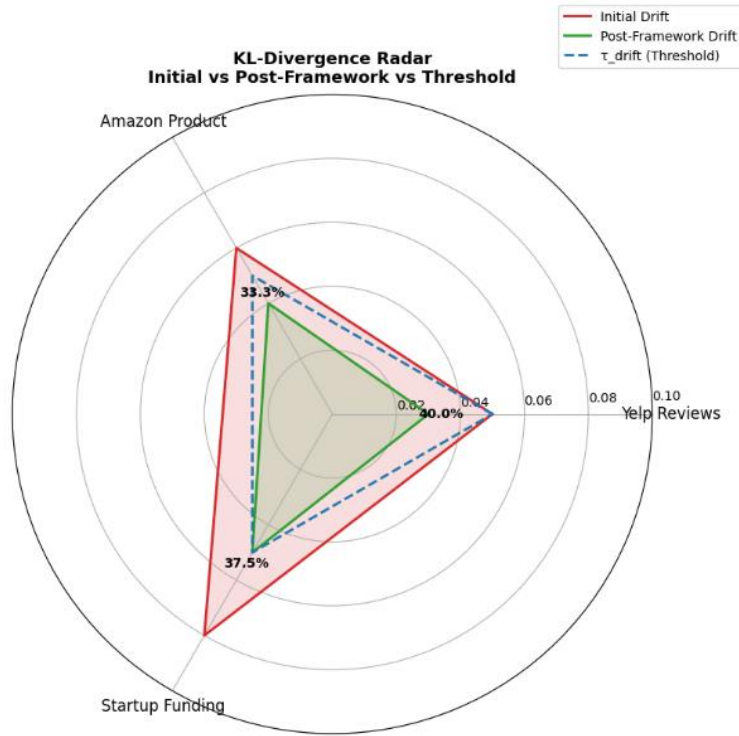
فرض مقادیر عددی برای سه مجموعه داده مورد استفاده داریم. هدف، نمایش تغییرات Drift قبل و بعد از اعمال چارچوب پیشنهادی و مقایسه آن با آستانه‌های تعریف شده (τ_{drift}) است. این تحلیل عددی به عنوان یک مکمل برای بخش تحلیل KL در مقاله عمل می‌کند.

در نمودار ۸، هر محور نماینده‌ی یکی از سه دیتاست Amazon، Yelp، Startup است و سه منحنی رسم شده شامل Drift اولیه مدل‌های پایه، Drift پس از چارچوب پیشنهادی و آستانه $\tau_{drift}=0.05$ همان‌طور که دیده می‌شود، برای Amazon و Yelp منحنی پس از چارچوب به‌طور محسوسی درون ناحیه آستانه قرار گرفته و کاهش drift نسبت به حالت اولیه نشان می‌دهد؛ این یعنی توزیع داده‌های جاری با توزیع آموزش هم‌سوتر شده و مدل در برابر تغییرات داده پایدارتر عمل می‌کند.

در دیتاست Startup Funding نیز drift کاهش یافته است، هرچند مقدار نهایی دقیقاً روی آستانه ۰,۰۵ قرار گرفته است. همین نزدیکی به مرز آستانه توجیه‌گر فعال‌سازی بازآموزی خودکار در معماری پیشنهادی است که بیانگر سازوکاری است که با شناسایی نزدیک شدن به حد مجاز، حلقه بازآموزی را برای تثبیت بیشتر مدل آغاز می‌کند. این رفتار در محیط‌های ناپایدار مالی و سرمایه‌گذاری که با شوک‌ها و تغییر رژیم‌های آماری همراه‌اند، ضروری است.

همگرایی هم‌زمان کاهش KL با بهبود معیارهای پیش‌بینی مانند افزایش FI و کاهش Loss در نتایج نشان می‌دهد که پایش KL نه تنها هشداردهنده تغییر توزیع است، بلکه اثر مداخله‌ها و هوش جمعی را نیز کمی‌سازی می‌کند. در عمل، توصیه می‌شود τ_{drift} برای هر دامنه پویا تنظیم شود؛ مثلاً برای Startup مقدار ۰,۰۴ حساسیت به تغییرات را بالا می‌برد.

شکل ۸. آزمون همگرایی



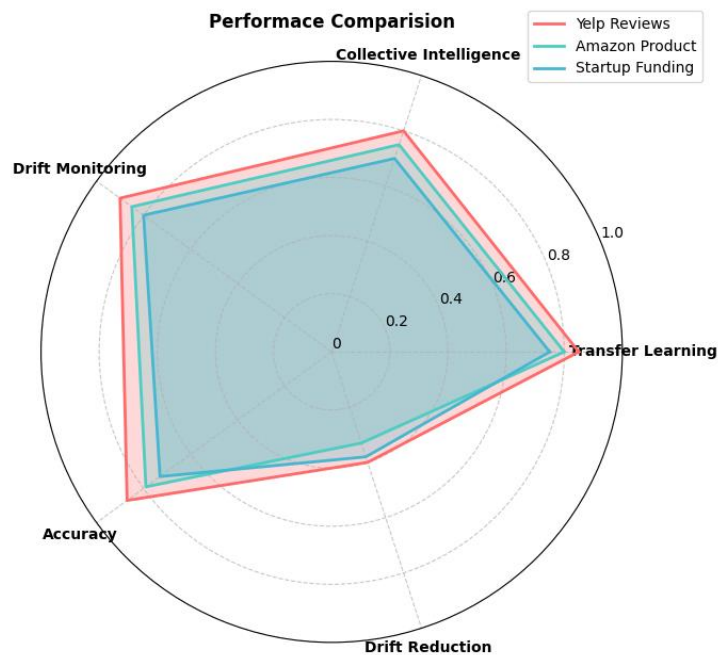
آزمایش نهایی ارائه شده در این مقاله بر پایه یک چارچوب یکپارچه برای غلبه بر چالش آغاز سرد در رژیم کم داده در کسب و کارهای نوظهور استوار است. هدف اصلی این آزمایش، ارزیابی عملکرد مدل‌های هوش مصنوعی در شرایط کمبود داده واقعی با استفاده از ترکیب یادگیری انتقالی، هوش جمعی و پایش انحراف داده است. این آزمایش روی سه مجموعه داده واقعی انجام می‌شود.

روش‌شناسی آزمایش شامل چهار مرحله اصلی است که به صورت ماژولار پیاده‌سازی شده‌اند. در مرحله اول، داده‌های واقعی (D_T)، عمومی (D_P) و بازخورد کاربران (D_F) جمع‌آوری و پیش‌پردازش می‌شوند. سپس، یادگیری انتقالی با مدل پیش‌آموزش دیده برای جلوگیری از فراموشی فاجعه‌بار اعمال می‌شود که وزن‌های مدل (θ) را با استفاده از داده‌های ترکیبی بهینه می‌کند. در مرحله سوم، هوش جمعی با فیلتر بازخوردهای کاربران

بر اساس آستانه کیفیت (τ_f) و وزندهی بر اساس تخصص، مدل را تقویت می‌کند. در نهایت، استنتاج پیوسته با پایش انحراف داده و مفهوم از طریق KL-Divergence انجام می‌شود که اگر Drift از آستانه (τ_{drift}) عبور کند، بازآموزی خودکار فعال می‌گردد. این فرآیند با معیارهای مانند دقت اعتبارسنجی (Acc_{val}) و منظم‌سازی ($R(\theta)$) برای کنترل بیش‌برازش، ارزیابی می‌شود.

نتایج آزمایش مطابق شکل ۹ نشان‌دهنده بهبود قابل توجه عملکرد مدل است، به طوری که دقت در Yelp_Reviews از ۷۷٪ به ۸۷٪ در Amazon_Product از حدود ۷۰٪ به ۷۹٪ و در Startup Funding از حدود ۶۸٪ به ۷۳٪ افزایش یافته است. کاهش Drift و بهبود معیارهای Precision، Recall و F1 تأیید می‌کند که چارچوب نه تنها کمبود داده را جبران می‌کند، بلکه پایداری مدل را در برابر تغییرات زمانی تضمین می‌نماید.

شکل ۹. نمایش راداری مقایسه معیارهای مختلف



بحث و نتیجه‌گیری

پژوهش حاضر چارچوبی نوآورانه و مقیاس‌پذیر برای غلبه بر چالش آغاز سرد در کسب و کارهای نوظهور در رژیم کم‌داده ارائه داد. این چارچوب با ترکیب یکپارچه یادگیری انتقالی و هوش جمعی، به همراه پایش مستمر تغییرات داده و مفهوم، راهکاری جامع برای بهبود عملکرد مدل‌های هوش مصنوعی در شرایط کم‌داده فراهم کرد. مراحل اصلی این چارچوب شامل جمع‌آوری و پیش‌پردازش داده‌های واقعی، عمومی و بازخورد کاربران، بازآموزی مدل پیش‌آموزش‌دیده با تکنیک‌های بهینه‌سازی مانند LoRA، تقویت مدل با بازخوردهای فیلترشده و وزن‌دار کاربران و استنتاج پیوسته با پایش انحراف داده و مفهوم از طریق فاصله کولبک-لایبلر بود. معیارهای Precision، Recall، F1 و میزان کاهش Loss و Drift نیز نتایج مطلوبی ارائه دادند، به‌ویژه در دیتاست Startup_Funding که پراکندگی داده بالایی دارد. این نتایج نشان‌دهنده توانایی چارچوب در بهره‌وری از داده‌های محدود و حفظ پایداری مدل در محیط‌های پویا است.

در مقایسه با روش‌های موجود، چارچوب پیشنهادی به دلیل ترکیب هوش جمعی، پایش پویا انحراف داده و مقیاس‌پذیری بالا با LoRA، برتری دارد. این چارچوب نه تنها برای استارت‌آپ‌ها با منابع محدود مناسب است، بلکه در دامنه‌های متنوع (تحلیل احساسات، فروش، سرمایه‌گذاری) عملکرد قوی‌تری ارائه می‌دهد. نمودار رادار ارائه‌شده در بخش تحلیل، برتری بصری روش پیشنهادی را در معیارهای مختلف نشان داد.

این چارچوب با ارائه یک معماری ماژولار و API-محور، امکان پیاده‌سازی عملی در اکوسیستم‌های استارت‌آپی را فراهم می‌کند و می‌تواند به شتاب‌دهی رشد کسب و کارهای نوظهور کمک کند. پایداری مدل در برابر تغییرات داده و مفهوم، همراه با بهره‌گیری از بازخورد کاربران، این چارچوب را به یک راهکار انعطاف‌پذیر و آینده‌نگر برای چالش‌های رژیم کم‌داده تبدیل کرده است.

برای توسعه و بهبود چارچوب پیشنهادی در تحقیقات آینده، چندین جهت گیری کلیدی پیشنهاد می شود. ابتدا، بهبود کیفیت بازخورد کاربران از طریق الگوریتم های پیشرفته تر فیلتراسیون، مانند مدل های یادگیری عمیق برای شناسایی بازخوردهای غیرمعتبر یا روش های مبتنی بر تحلیل احساسات برای وزن دهی دقیق تر به بازخوردهای تخصصی، می تواند عملکرد مدل را ارتقا دهد. همچنین، استفاده از یادگیری تقویتی برای بهبود مستمر فرآیند وزن دهی کاربران، وابستگی به کیفیت اولیه بازخورد را کاهش خواهد داد. علاوه بر این، گسترش دامنه های کاربرد چارچوب به حوزه هایی مانند سلامت، آموزش، یا لجستیک، نیازمند آزمایش روی داده های متنوع تر و تنظیم مدل برای ویژگی های خاص هر دامنه است. این امر تعمیم پذیری چارچوب را تقویت کرده و کاربرد آن را برای استارت آپ های مختلف گسترش می دهد. در نهایت، بهینه سازی محاسباتی بیشتر با تکنیک هایی مانند فشرده سازی مدل می تواند امکان اجرای چارچوب روی سخت افزارهای کم قدرت را فراهم کند که برای استارت آپ های با منابع محدود حیاتی است.

جهت گیری های بعدی شامل پایش پیشرفته تر انحراف داده و مفهوم با استفاده از معیارهای ترکیبی (مانند ترکیب KL-Divergence با آنتروپی) (برای تشخیص دقیق تر تغییرات در محیط های پویا و ادغام روش های یادگیری آنلاین برای بازآموزی سریع تر مدل است. همچنین، افزودن داده های چندوجهی (مانند تصاویر یا صوت) با استفاده از مدل های چندوجهی، می تواند چارچوب را برای استارت آپ های فعال در تجارت الکترونیک یا رسانه های اجتماعی غنی تر کند. ارزیابی در مقیاس بزرگ تر با همکاری استارت آپ های واقعی و توسعه یک پلتفرم کاربرپسند یا API متن باز، پیاده سازی عملی را برای کسب و کارهای بدون تخصص فنی آسان تر خواهد کرد. در آخر، مقایسه با روش های پیشرفته تر مانند یادگیری خودنظارتی یا مدل های صفر-شات می تواند برتری چارچوب را در برابر رویکردهای نوین تر اثبات کند و توسعه ابزارهای عملیاتی مانند رابط های گرافیکی برای مدیریت داده ها و پایش عملکرد، پذیرش چارچوب را در

چارچوبی برای یکپارچه‌سازی یادگیری انتقالی و هوش جمعی در ...؛ نورائی آباده و همکاران | ۳۷۱

اکوسیستم نوآوری تسریع خواهد بخشید.

تعارض منافع

تعارض منافع وجود ندارد.

ORCID

Maryam Nooraei Abadeh
Shohreh Ajoudanian
Sondos Bahadori



<https://orcid.org/0000-0002-6221-7008>



<https://orcid.org/0000-0001-8798-787X>



<https://orcid.org/0009-0004-5365-6182>

References

1. Adewale, T. (2024). "Transfer Learning Applications in Cross-Market Investment Strategies".
2. Ali, W., X. Zhou and J. Shao (2025). "Privacy-preserved and responsible recommenders: From conventional defense to federated learning and blockchain." *ACM Computing Surveys* 57(5): 1-35. <https://doi.org/10.1145/3708982>.
3. Alzubaidi, L., M. A. Fadhel, O. Al-Shamma, J. Zhang, J. Santamaría, Y. Duan and S. R. Oleiwi (2020). "Towards a better understanding of transfer learning for medical imaging: a case study." *Applied Sciences* 10(13): 4523. <https://doi.org/10.3390/app10134523>.
4. Da, Z. and X. Huang (2020). "Harnessing the wisdom of crowds." *Management Science* 66(5): 1847-1867. <https://doi.org/10.1287/mnsc.2019.3294>.
5. Fayaz-Bakhsh, M., D. Ataei and M. Fazli (2025). "Cold Start Active Preference Learning in Socio-Economic Domains." arXiv preprint arXiv: <https://doi.org/10.48550/arXiv.2508.05090>.
6. Frikha, A. (2022) .*Deep knowledge transfer for generalization across tasks and domains under data scarcity, lmu.* <https://doi.org/10.5282/edoc.30833>.
7. Gunasekaran, S. S., S. A. Mostafa and M. S. Ahmad (2015). *Knowledge transfer model in collective intelligence theory.* *Advances in Intelligent Informatics, Springer:* 481-491.
8. Hedderich, M. A., L. Lange, H. Adel, J. Strötgen and D. Klakow (2020). "A survey on recent approaches for natural language processing in low-resource scenarios." <https://doi.org/10.48550/arXiv.2010.12309>.
9. Huang, Y.-C. and Y.-C. Chin (2018). "Transforming collective knowledge into team intelligence: the role of collective teaching." *Journal of Knowledge Management* 22(6): 1243-1263. <https://doi.org/10.1108/JKM-03-2018-0186>.
10. Irshad, M. S., Q. Xin and H. Arshad (2018). "Competitiveness of Pakistani rice in international market and export potential with global world: A panel gravity approach." *Cogent Economics & Finance* 6(1): 1486690. <https://doi.org/10.1080/23322039.2018.1486690>.
11. Jafri, S. I. H., R. Ghazali, I. Javid, Z. Mahmood and A. A. A. Hassan (2022). "Deep transfer learning with multimodal embedding to tackle cold-start and sparsity issues in recommendation system." *Plos one* 17(8): e0273486. <https://doi.org/10.1371/journal.pone.0273486>.

12. Jeon, H. J., S. Liu, Y. Li, J. Lyu, H. Song, J. Liu, P. Wu and Z. Zhu (2024). "Epinet for Content Cold Start." arXiv preprint arXiv:2412.04484. <https://doi.org/10.48550/arXiv.2412.04484>.
13. Kairouz, P., H. B. McMahan, B. Avent, A. Bellet, M. Bennis, A. N. Bhagoji, K. Bonawitz, Z. Charles, G. Cormode and R. Cummings (2021). "Advances and open problems in federated learning." Foundations and trends® in machine learning 14(1–2): 1-210. <https://doi.org/10.1561/22000000083>.
14. Kamar, E., S. Hacker and E. Horvitz (2012). *Combining human and machine intelligence in large-scale crowdsourcing*. Aamas. <https://doi.org/10.5555/2343576.2343643>.
15. Kazai, G., J. Kamps and N. Milic-Frayling (2013). "An analysis of human factors and label accuracy in crowdsourcing relevance judgments." Information retrieval 16(2): 138-178. <https://doi.org/10.1007/s10791-012-9205-0>.
16. Lam, X. N., T. Vu, T. D. Le and A. D. Duong (2008). *Addressing cold-start problem in recommendation systems*. Proceedings of the 2nd international conference on Ubiquitous information management and communication. <https://doi.org/10.1145/1352793.1352837>.
17. Lao, D., X. Yang, Q. Wu and J. Yan (2022). *Variational inference for training graph neural networks in low-data regime through joint structure-label estimation*. Proceedings of the 28th ACM SIGKDD conference on knowledge discovery and data mining. <https://doi.org/10.1145/3534678.3539283>.
18. Li, S., S. A. Mohd Noah and Y. Xu "Drn-Cskt: Solving Cold-Start in Knowledge Tracing with Disentangled Attention and Retentive Networks".
19. Nerurkar, I. M. K. C. B. (2025). "The Role of Transfer Learning in Low-Data Regimes: Applications and Challenges".
20. Pan, S. J. and Q. Yang (2009). "A survey on transfer learning." IEEE Transactions on knowledge and data engineering 22(10): 1345-1359. <https://doi.org/10.1109/TKDE.2009.191>.
21. Paschek, D., C. T. Luminosu and A. Draghici (2017). *Automated business process management—in times of digital transformation using machine learning or artificial intelligence*. MATEC web of conferences, EDP Sciences. <https://doi.org/10.1051/mateconf/201712104007>.
22. Pham, H., Z. Dai, G. Ghiasi, K. Kawaguchi, H. Liu, A. W. Yu, J. Yu, Y.-T. Chen, M.-T. Luong and Y. Wu (2023). "Combined scaling for zero-shot transfer learning." Neurocomputing 555: 126658. <https://doi.org/10.1016/j.neucom.2023.126658>.

23. Wang, K.-J., L. Juni Asrini, L. Sanjaya and H.-P. Nguyen (2022). "Model for deep learning-based skill transfer in an assembly process." *Advanced Engineering Informatics* **52**: 101643. <https://doi.org/10.1016/j.aei.2022.101643>.
24. Woolley, A., C. Chabris, A. Pentland, N. Hashmi and T. Malone (2010). "Evidence of a Collective Intelligence Factor in the Performance of Human Groups." *Science (New York, N.Y.)* **330**: 686-688. <https://doi.org/10.1126/science.1193147>.
25. Xie, J., Y. Lu, S.-C. Zhu and Y. Wu (2016). *A theory of generative convnet*. International conference on machine learning, PMLR. <https://doi.org/10.48550/arXiv.1602.03264>.
26. Yu, Y., R. Zhang, R. Xu, J. Zhang, J. Shen and C. Zhang (2022). "Cold-start data selection for few-shot language model fine-tuning: A prompt-based uncertainty propagation approach." *arXiv preprint arXiv:2209.06995*. <https://doi.org/10.48550/arXiv.2209.06995>.

استناد به این مقاله: نورائی آبا، مریم، آجودانیان، شهره، بهادری، سندس. (۱۴۰۵). چارچوبی برای یکپارچه‌سازی یادگیری انتقالی و هوش جمعی در غلبه بر رژیم کم داده در کسب و کارهای نوظهور، *مطالعات مدیریت کسب و کار هوشمند*، ۱۵(۵۵)، ۳۳۷-۳۷۴. DOI: 10.22054/ims.2026.87652.2661



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