

## طراحی و توسعه فانتوم دیجیتال داده‌محور برای ارزیابی و اعتبارسنجی الگوریتم‌های داده‌کاوی و یادگیری ماشین

محمدرضا دهقانی محمودآبادی

۱- استادیار، گروه مهندسی کامپیوتر، دانشکده فنی و مهندسی، دانشگاه آزاد اسلامی واحد بافق، بافق، ایران.  
[m.dehghanimahmoudabadi@iau.ir](mailto:m.dehghanimahmoudabadi@iau.ir)

بابک تشکری

۲- استادیار، گروه مهندسی کامپیوتر، دانشکده فنی و مهندسی، دانشگاه آزاد اسلامی واحد بافق، بافق، ایران.  
[babaktashakori@yahoo.com](mailto:babaktashakori@yahoo.com)

الهام دهقان طزرجانی

۳- دانشجوی کارشناسی ارشد تجارت الکترونیک، گروه مهندسی کامپیوتر، دانشکده فنی و مهندسی، دانشگاه آزاد اسلامی واحد بافق، بافق، ایران.  
[edt6058@gmail.com](mailto:edt6058@gmail.com)

### چکیده

این مطالعه چارچوبی نوآورانه برای ارزیابی و تحلیل رفتار و پایداری مدل‌های یادگیری ماشین ارائه می‌دهد. در این رویکرد، فانتوم دیجیتال با حفظ ویژگی‌های آماری و ساختاری داده‌های واقعی تولید می‌شوند، که امکان شبیه‌سازی سناریوهای متنوع، از جمله داده‌های دارای نویز، سوگیری و مقادیر گمشده، را فراهم می‌آورد. استفاده از این داده‌های مصنوعی امکان تحلیل مدل‌های مختلف یادگیری ماشین شامل شبکه‌های عصبی چندلایه، درخت‌های تصمیم و سیستم‌های دسته‌بند مبتنی بر قوانین را بدون وابستگی مستقیم به داده‌های واقعی فراهم می‌کند. تحلیل‌های تجربی نشان داد که به‌کارگیری فانتوم‌های دیجیتال باعث افزایش ۱۵ تا ۱۸ درصد قابلیت تبیین تصمیمات مدل‌ها و حفظ همبستگی رفتاری بالاتر از ۰.۸۵ با داده‌های واقعی شد. همچنین، پایداری مدل‌ها تحت شرایط اختلال در بازه ۸۲ تا ۹۵ درصد قرار گرفت. این نتایج حاکی از آن است که فانتوم‌های دیجیتال می‌توانند به‌عنوان ابزاری قابل اعتماد، منعطف و کم‌هزینه برای ارزیابی، تحلیل حساسیت و اعتبارسنجی الگوریتم‌های داده‌کاوی و یادگیری ماشین در محیط‌های کنترل‌شده مورد استفاده قرار گیرند. به‌طور کلی، چارچوب پیشنهادی می‌تواند جایگزینی مؤثر برای آزمایش‌های مبتنی بر داده‌های واقعی فراهم کرده و زمینه را برای توسعه روش‌های پایدار و قابل تبیین در کاربردهای عملی یادگیری ماشین هموار سازد.

واژگان کلیدی: فانتوم دیجیتال، یادگیری ماشینی، تحلیل و اعتبارسنجی، انعطاف‌پذیری، داده‌کاوی.

### مقدمه

با رشد سریع حجم داده‌ها در حوزه‌های علمی، صنعتی و اجتماعی، الگوریتم‌های داده‌کاوی و یادگیری ماشین به ابزارهای کلیدی برای تحلیل، پیش‌بینی و تصمیم‌گیری تبدیل شده‌اند. کیفیت و اعتبار داده‌های مورد استفاده نقش تعیین‌کننده‌ای در عملکرد و

قابلیت اعتماد مدل‌ها دارد. یکی از چالش‌های اصلی پژوهشگران و مهندسان داده، کمبود داده‌های واقعی با کیفیت بالا است؛ داده‌های واقعی اغلب ناقص، دارای نویز یا سوگیری بوده و دسترسی به آن‌ها هزینه‌بر یا محدود است. این محدودیت‌ها ارزیابی دقیق و کنترل‌شده الگوریتم‌ها را دشوار می‌سازد (Dehghanimahmoudabadi et al., ۲۰۲۳).

علاوه بر کیفیت داده، قابلیت تبیین تصمیمات مدل‌ها نیز اهمیت ویژه‌ای دارد. بسیاری از الگوریتم‌های یادگیری ماشین، به‌ویژه مدل‌های پیچیده مانند شبکه‌های عصبی عمیق، به صورت «جعبه سیاه» عمل می‌کنند و مسیر تصمیم‌گیری آن‌ها برای پژوهشگران و کاربران نهایی غیرشفاف است. در پاسخ به این چالش‌ها، استفاده از داده‌های مصنوعی یا فانتوم‌های دیجیتال داده‌محور به عنوان محیط آزمایشی و شبیه‌سازی شده مطرح شده است. این داده‌ها می‌توانند ویژگی‌های آماری و ساختاری داده‌های واقعی را بازتولید کرده و امکان سناریوسازی کنترل‌شده را فراهم سازند (DehghaniMahmoudAbadi & Samavarchi, ۲۰۱۳).

پژوهش‌های پیشین نشان داده‌اند که تولید داده‌های مصنوعی می‌تواند در تحلیل حساسیت، اعتبارسنجی مدل‌ها و افزایش قابلیت تکرارپذیری نتایج مؤثر باشد. با این حال، بسیاری از روش‌های موجود محدودیت‌هایی در بازنمایی دقیق رفتار مدل‌ها و تحلیل مسیر تصمیم‌گیری دارند. برخی مطالعات به استفاده از داده‌های مصنوعی برای آموزش مدل‌ها و بهبود دقت آن‌ها پرداخته‌اند، اما اغلب به تحلیل تبیین‌پذیری و پایداری مدل‌ها توجه نکرده‌اند. بنابراین، یک چارچوب جامع که همزمان دقت، پایداری و قابلیت تبیین مدل‌ها را بررسی کند، هنوز ارائه نشده است (N nabavizadeh, ۲۰۲۳).

فانتوم‌های دیجیتال داده‌محور علاوه بر بازتولید داده‌ها، امکان ایجاد سناریوهای مختلف شامل داده‌های دارای نویز، سوگیری و مقادیر گم‌شده را فراهم می‌کنند. این ویژگی تحلیل مدل‌ها در شرایط غیرایده‌آل و شبیه‌سازی محیط‌های واقعی را ممکن می‌سازد. کاربرد این رویکرد در اعتبارسنجی الگوریتم‌های یادگیری ماشین و داده‌کاوی گسترده است و می‌تواند در صنایع حساس مانند پزشکی، انرژی، حمل‌ونقل و مدیریت ریسک به عنوان ابزاری برای ارزیابی و پیش‌بینی عملکرد سیستم‌ها مورد استفاده قرار گیرد. هدف اصلی این پژوهش، طراحی و توسعه چارچوب فانتوم دیجیتال داده‌محور است که رفتار مدل‌های یادگیری ماشین را با دقت بالا بازتولید کرده و قابلیت تبیین تصمیمات آن‌ها را ارتقا دهد. این چارچوب همچنین امکان تحلیل حساسیت و بررسی پایداری عملکرد مدل‌ها را فراهم می‌آورد (Rajathi & Rukmani, ۲۰۲۵).

بر اساس اهداف پژوهش، فرضیه‌های اصلی به شرح زیر ارائه می‌شوند:

- فرضیه ۱: فانتوم‌های دیجیتال داده‌محور قادرند رفتار الگوریتم‌های یادگیری ماشین را با همبستگی بالاتر از ۰.۸۵ با داده‌های واقعی بازتولید کنند.
- فرضیه ۲: استفاده از داده‌های فانتومی موجب افزایش قابلیت تبیین تصمیمات مدل‌ها نسبت به استفاده صرف از داده‌های واقعی می‌شود.
- فرضیه ۳: چارچوب پیشنهادی توانایی حفظ پایداری عملکرد مدل‌ها در سناریوهای دارای نویز، سوگیری و مقادیر گم‌شده را دارد.

این پژوهش، با تمرکز بر شبکه‌های عصبی چندلایه، درخت تصمیم و سیستم‌های دسته‌بند مبتنی بر قوانین، قابلیت بازتولید رفتار و تحلیل تبیین تصمیمات مدل‌ها را ارزیابی می‌کند (Mohammed et al., ۲۰۲۵).

ادبیات تحقیق نشان می‌دهد که داده‌های مصنوعی و فانتوم‌های داده تا کنون در زمینه‌های آموزشی، شبیه‌سازی و بهبود کیفیت داده مورد استفاده قرار گرفته‌اند، اما استفاده همزمان از آن‌ها برای تحلیل تبیین‌پذیری و اعتبارسنجی مدل‌های پیچیده کمتر بررسی شده است. یافته‌های پیشین نشان می‌دهد که تولید داده‌های مصنوعی با ویژگی‌های آماری واقعی می‌تواند هزینه‌های جمع‌آوری داده، زمان اجرای آزمایش‌ها و وابستگی به داده‌های واقعی را کاهش دهد، اما نیازمند چارچوبی سیستماتیک و استاندارد برای اعتبارسنجی مدل‌ها است. اهمیت پژوهش حاضر در ارائه چارچوبی عملی و قابل تعمیم است که می‌تواند در محیط‌های مختلف

داده‌ای و مدل‌های متنوع یادگیری ماشین مورد استفاده قرار گیرد و تحلیل‌های حساسیت و پایداری مدل‌ها را به صورت دقیق امکان‌پذیر سازد (Xu et al., ۲۰۲۵).

ساختار مقاله به این صورت است که بخش دوم به مرور ادبیات و پیشینه تحقیق اختصاص دارد، بخش سوم روش تحقیق، جامعه و نمونه آماری، ابزارها و روش‌های تحلیل داده‌ها را شرح می‌دهد، بخش چهارم یافته‌ها را با جداول، نمودارها و تحلیل‌های تفصیلی ارائه می‌کند و در بخش پنجم نتایج با یافته‌های پیشین مقایسه شده و پیشنهادات کاربردی و پژوهشی ارائه می‌شوند. این ساختار امکان ارائه پژوهش به صورت روان، نظام‌مند و قابل استناد برای مجلات علمی داخلی و بین‌المللی را فراهم می‌کند.

### روش تحقیق

این پژوهش از نوع کاربردی و توسعه‌ای است و با هدف طراحی، پیاده‌سازی و ارزیابی چارچوب فانتوم دیجیتال داده‌محور انجام شده است. روش تحقیق به گونه‌ای انتخاب شد که بتواند همزمان دقت، پایداری و قابلیت تبیین مدل‌های یادگیری ماشین را بررسی کند و تعمیم یافته‌ها به محیط‌های داده‌ای واقعی را امکان‌پذیر سازد. تحقیق در دو مرحله اصلی انجام شد: توسعه چارچوب فانتوم دیجیتال و ارزیابی عملکرد مدل‌ها با داده‌های فانتومی و واقعی (Acevedo-Sánchez et al., ۲۰۲۵).

جامعه آماری پژوهش شامل الگوریتم‌های یادگیری ماشین و داده‌کاوی پرکاربرد در زمینه‌های پیش‌بینی، دسته‌بندی و تحلیل داده‌های پیچیده است. این الگوریتم‌ها شامل شبکه عصبی چندلایه، درخت تصمیم، الگوریتم XCS و سایر مدل‌های مبتنی بر قوانین می‌باشند. جامعه داده‌ها نیز شامل مجموعه داده‌های استاندارد و واقعی در حوزه‌های پزشکی، صنعتی و مالی است که ویژگی‌های متنوعی از جمله نویز، بایاس و مقادیر گم‌شده دارند. برای نمونه‌گیری داده‌ها از روش غیرتصادفی هدفمند استفاده شد تا مجموعه داده‌ها نماینده ویژگی‌ها و پیچیدگی‌های واقعی باشند. داده‌های فانتومی با استفاده از الگوریتم‌های مدل‌سازی داده‌محور تولید شدند تا ویژگی‌های آماری و ساختاری داده‌های واقعی را بازتولید کنند. این فانتوم‌ها سناریوهای مختلف داده‌ای، شامل داده‌های بدون اختلال، دارای نویز، دارای بایاس و ناقص را شبیه‌سازی می‌کنند تا ارزیابی مدل‌ها در شرایط متنوع ممکن شود (Nofal et al., ۲۰۲۵).

ابزارهای پژوهش شامل چارچوب نرم‌افزاری تولید فانتوم داده، محیط اجرای الگوریتم‌های یادگیری ماشین و ابزارهای آماری و تحلیل داده‌ها بودند. برای اطمینان از روایی ابزارها، ویژگی‌های داده‌های فانتومی با داده‌های واقعی مقایسه شد و همبستگی آماری و تطابق ساختاری تأیید گردید. شاخص‌های مورد استفاده شامل میانگین، واریانس، همبستگی، شاخص‌های پایداری و قابلیت تبیین مدل‌ها بود. بررسی پایداری و قابلیت تکرارپذیری ابزارها با اجرای چندباره آزمایش‌ها و مقایسه نتایج با داده‌های واقعی انجام شد تا اطمینان حاصل گردد که ابزارها قابل اعتماد و پایا هستند (Wiese et al., ۲۰۲۵).

تجزیه و تحلیل داده‌ها شامل تحلیل کمی و کیفی عملکرد مدل‌ها بود. تحلیل کمی با شاخص‌هایی مانند دقت، صحت، حساسیت، F1-score، همبستگی رفتار مدل‌ها و شاخص پایداری انجام شد. در تحلیل کیفی، مسیر تصمیم‌گیری مدل‌ها و قابلیت تبیین آن‌ها با داده‌های فانتومی و واقعی مقایسه گردید. همچنین، جداول و نمودارهای تحلیلی برای ارائه نتایج به صورت تصویری و قابل تفسیر استفاده شدند تا امکان تحلیل روندها، مقایسه سناریوها و بررسی جزئیات تصمیم‌گیری مدل‌ها فراهم شود (Ma et al., ۲۰۲۵).

ترکیب این روش‌ها امکان ارزیابی جامع چارچوب فانتوم دیجیتال از منظر دقت، قابلیت تبیین و پایداری را فراهم کرده و قابلیت تعمیم یافته‌ها به محیط‌های داده‌ای واقعی و پیچیده را تضمین نمود. این رویکرد علاوه بر توسعه علمی، قابلیت کاربردی در تحلیل و اعتبارسنجی الگوریتم‌های داده‌کاوی و یادگیری ماشین در محیط‌های کنترل‌شده و صنعتی را فراهم می‌آورد (Li et al., ۲۰۲۵).

### یافته‌ها

این بخش نتایج پژوهش در زمینه طراحی و توسعه فانتوم دیجیتال داده‌محور برای ارزیابی و اعتبارسنجی الگوریتم‌های یادگیری ماشین را ارائه می‌دهد. تحلیل‌ها شامل پنج مدل پرکاربرد: شبکه عصبی چندلایه، درخت تصمیم، XCS، ماشین بردار پشتیبان و

جنگل تصادفی است. داده‌ها در چهار سناریو بررسی شدند: داده بدون اختلال، داده دارای نویز، داده دارای بایاس و داده دارای مقادیر گمشده.

### تحلیل دقت مدل‌ها

جدول ۱ دقت مدل‌ها را در سناریوهای مختلف نشان می‌دهد. نتایج حاکی از آن است که شبکه عصبی چندلایه در داده واقعی دقت ۸۸ درصد داشت و با فانتوم بدون اختلال به ۸۶ درصد کاهش یافت. در سناریوهای دارای نویز، بایاس و داده گمشده، دقت به ترتیب ۸۳ درصد، ۸۱ درصد و ۷۹ درصد بود. درخت تصمیم در داده واقعی دقت ۸۴ درصد داشت و در سناریوهای اختلالی بین ۷۵ درصد تا ۸۲ درصد متغیر بود. XCS دقتی بین ۸۶ درصد و ۷۷ درصد در سناریوهای مختلف داشت و همبستگی رفتار آن با داده واقعی بیش از ۰.۸۵ باقی ماند. ماشین بردار پشتیبان با داده واقعی دقت ۸۵ درصد داشت و در داده فانتومی بدون اختلال به ۸۳ درصد رسید. جنگل تصادفی نیز در داده واقعی دقت ۸۷ درصد داشت و در سناریوهای اختلالی بین ۷۹ درصد تا ۸۵ درصد متغیر بود.

جدول ۱. دقت مدل‌ها در سناریوهای داده‌ای مختلف

مدل	داده واقعی	فانتوم با داده گمشده	فانتوم با بایاس	فانتوم با نویز	فانتوم بدون اختلال
شبکه عصبی چندلایه	۰.۸۸	۰.۷۹	۰.۸۱	۰.۸۳	۰.۸۶
درخت تصمیم	۰.۸۴	۰.۷۵	۰.۷۸	۰.۸۰	۰.۸۲
XCS	۰.۸۶	۰.۷۷	۰.۸۰	۰.۸۲	۰.۸۵
ماشین بردار پشتیبان	۰.۸۵	۰.۷۷	۰.۷۹	۰.۸۱	۰.۸۳
جنگل تصادفی	۰.۸۷	۰.۷۹	۰.۸۰	۰.۸۲	۰.۸۵

نمودارهای میله‌ای این جدول نشان می‌دهند که مدل‌ها حتی در سناریوهای اختلالی عملکرد نسبتاً پایداری دارند. نمودارهای خطی همبستگی رفتار مدل‌ها تأیید می‌کند که فانتوم‌ها بیش از ۸۵ درصد رفتار مدل‌ها را بازتولید کرده‌اند.

استفاده از فانتوم دیجیتال موجب افزایش شفافیت تصمیم‌گیری مدل‌ها تا ۱۵ تا ۲۰ درصد شد. تحلیل جریان تصمیم در شبکه عصبی چندلایه و جنگل تصادفی نشان داد که مسیر تصمیم‌گیری تحت داده فانتومی قابل ردیابی و منطقی است. تحلیل حساسیت ویژگی‌ها نیز امکان بررسی اثرگذاری ورودی‌ها بر خروجی مدل‌ها را حتی در سناریوهای اختلالی فراهم کرد. مقایسه مدل‌ها نشان داد که XCS و جنگل تصادفی بیشترین پایداری و قابلیت تبیین را در سناریوهای دارای نویز و بایاس دارند. نتایج آماری و تطبیقی بین داده واقعی و فانتومی، اعتبار چارچوب پیشنهادی را تأیید کرده و نشان داد که استفاده از فانتوم دیجیتال می‌تواند هزینه جمع‌آوری داده و زمان اجرای آزمایش‌ها را به‌طور چشمگیری کاهش دهد.

نتایج نشان می‌دهد که در داده واقعی، شبکه عصبی چندلایه با دقت ۰.۸۸ و جنگل تصادفی با دقت ۰.۸۷ بهترین عملکرد را در میان مدل‌های مورد بررسی دارند. درخت تصمیم با دقت ۰.۸۴ پایین‌ترین عملکرد را در داده واقعی نشان داد، در حالی که XCS و ماشین بردار پشتیبان به ترتیب دقت ۰.۸۶ و ۰.۸۵ داشتند. این یافته‌ها حاکی از توانایی مدل‌های پیچیده مانند شبکه عصبی چندلایه و جنگل تصادفی در یادگیری روابط پیچیده داده‌ها و قابلیت تعمیم مناسب آنهاست.

استفاده از فانتوم دیجیتال بدون اختلال موجب کاهش اندک دقت مدل‌ها شد، به گونه‌ای که شبکه عصبی چندلایه از ۰.۸۸ به ۰.۸۶ و جنگل تصادفی از ۰.۸۷ به ۰.۸۵ رسید. سایر مدل‌ها نیز کاهش مشابهی داشتند، که نشان می‌دهد فانتوم‌های بدون اختلال قادرند رفتار مدل‌ها را با دقت بالایی بازتولید کنند و صحت آماری و ساختاری داده‌ها حفظ شود.

در سناریوهای اختلالی، کاهش دقت مدل‌ها مشاهده شد. داده‌های دارای نویز موجب افت دقت حدود ۰.۰۳ تا ۰.۰۵ در مدل‌ها شد اما XCS و جنگل تصادفی کمترین کاهش دقت را تجربه کردند و پایداری نسبی خود را حفظ کردند. در سناریوهای دارای بایاس، کاهش دقت کمی بیشتر بود و مدل‌هایی مانند شبکه عصبی چندلایه و درخت تصمیم نسبت به اختلال حساسیت بیشتری نشان دادند، در حالی که XCS و جنگل تصادفی همچنان عملکرد پایداری داشتند. بیشترین افت دقت مربوط به داده‌های دارای مقادیر



گمشده بود؛ درخت تصمیم دقت خود را به ۰.۷۵ کاهش داد، در حالی که شبکه عصبی چندلایه و جنگل تصادفی به ترتیب دقت ۰.۷۹ را حفظ کردند و توانایی تطبیق با داده‌های ناقص را نشان دادند.

تحلیل قابلیت تبیین مدل‌ها نشان داد که استفاده از فانتوم دیجیتال موجب افزایش شفافیت تصمیم‌گیری تا ۱۵ تا ۲۰ درصد شد. نمودارهای خطی همبستگی رفتار مدل‌ها تأیید کردند که فانتوم‌ها بیش از ۸۵ درصد رفتار مدل‌ها را بازتولید می‌کنند. تحلیل جریان تصمیم<sup>۱</sup> در شبکه عصبی چندلایه و جنگل تصادفی نشان داد که مسیر تصمیم‌گیری تحت داده فانتومی قابل ردیابی و منطقی است. علاوه بر این، تحلیل حساسیت ویژگی‌ها<sup>۲</sup> امکان بررسی اثرگذاری ورودی‌ها بر خروجی مدل‌ها را حتی در سناریوهای اختلالی فراهم کرد.

در مجموع، مقایسه مدل‌ها نشان می‌دهد که XCS و جنگل تصادفی بیشترین پایداری و قابلیت تبیین را در سناریوهای دارای نویز و بایاس دارند و عملکرد آن‌ها با داده واقعی هماهنگی بالایی دارد. استفاده از فانتوم دیجیتال علاوه بر حفظ رفتار مدل‌ها، موجب کاهش چشمگیر هزینه جمع‌آوری داده و زمان اجرای آزمایش‌ها شد. بنابراین، چارچوب فانتوم دیجیتال داده‌محور ابزاری قدرتمند برای اعتبارسنجی، تحلیل حساسیت و بررسی پایداری مدل‌های یادگیری ماشین است و می‌تواند در محیط‌های داده‌ای واقعی و صنعتی به کار گرفته شود.

به طور کلی، چارچوب فانتوم دیجیتال داده‌محور ابزاری قدرتمند برای اعتبارسنجی، تحلیل حساسیت و بررسی پایداری مدل‌های یادگیری ماشین است و قابلیت کاربرد در محیط‌های داده‌ای واقعی و صنعتی را داراست. نمودارها و جداول ارائه شده به وضوح امکان مقایسه مدل‌ها، سناریوها و تأثیر انواع اختلال‌ها را فراهم می‌کنند و نشان می‌دهند که فانتوم‌ها می‌توانند رفتار مدل‌ها را به صورت قابل اعتماد بازتولید کنند.

### بحث و نتیجه‌گیری

در این پژوهش، چارچوب فانتوم دیجیتال داده‌محور برای ارزیابی و اعتبارسنجی الگوریتم‌های داده‌کاوی و یادگیری ماشین طراحی و توسعه یافت. نتایج نشان داد که استفاده از داده‌های فانتومی، علاوه بر کاهش هزینه و زمان جمع‌آوری داده، قادر است رفتار مدل‌ها را با همبستگی بالای ۸۵ درصد با داده واقعی بازتولید کند. پنج مدل مورد بررسی شامل شبکه عصبی چندلایه، درخت تصمیم، XCS، ماشین بردار پشتیبان و جنگل تصادفی بودند. تحلیل‌های دقت، پایداری و قابلیت تبیین نشان داد که فانتوم دیجیتال توانسته است در شرایط اختلالی (نویز، بایاس و داده گمشده) عملکرد مدل‌ها را حفظ کند و مسیر تصمیم‌گیری و حساسیت ویژگی‌ها را به شکل قابل ردیابی و شفاف ارائه دهد. این یافته‌ها با پژوهش‌های پیشین در زمینه داده مصنوعی و اعتبارسنجی مدل‌های یادگیری ماشین هم‌راستا است و نشان می‌دهد که فانتوم دیجیتال ابزاری مؤثر برای تحلیل و شبیه‌سازی رفتار مدل‌ها است، اگرچه میزان افزایش قابلیت تبیین و پایداری در مدل‌های مختلف متفاوت است و نوآوری پژوهش در ترکیب داده فانتومی با مدل‌های متعدد برجسته می‌شود. با توجه به یافته‌های این پژوهش، پیشنهادات کاربردی و پژوهشی برای مطالعات آینده به شرح زیر ارائه می‌شود:

۱. گسترش چارچوب به مدل‌های پیچیده‌تر: توسعه فانتوم دیجیتال برای مدل‌های یادگیری عمیق و شبکه‌های عصبی بزرگ مقیاس به منظور بررسی رفتار مدل‌ها در محیط‌های صنعتی و داده‌های واقعی پیچیده.
۲. استفاده عملی در صنایع: به کارگیری فانتوم دیجیتال برای تحلیل حساسیت و شفافیت تصمیم‌گیری مدل‌ها در پروژه‌های عملی و صنعتی جهت کاهش ریسک خطای تصمیم.

<sup>1</sup> Decision Flow

<sup>2</sup> Sensitivity Analysis

۳. افزایش تنوع سناریوهای احتمالی: اضافه کردن سناریوهای داده احتمالی متنوع‌تر، شامل داده‌های زمان‌مند و چندمنبع، برای ارتقای قابلیت بازتولید رفتار مدل‌ها در شرایط واقعی.
۴. اتصال به محیط‌های تولید: ارزیابی امکان اتصال فانتوم دیجیتال به پایگاه‌های داده و محیط‌های تولید برای اعتبارسنجی و پایش مدل‌ها در زمان واقعی.
- این نتایج نشان می‌دهد که چارچوب فانتوم دیجیتال داده‌محور، علاوه بر کاربرد پژوهشی، قابلیت عملی بالایی برای اعتبارسنجی، تحلیل حساسیت و بررسی پایداری مدل‌های یادگیری ماشین در محیط‌های واقعی و صنعتی دارد.

#### منابع

- Acevedo-Sánchez, G., Alarcón-Paredes, A., & Yáñez-Márquez, C. (2025). **Effect of agriculture-related dataset complexity on classical machine learning and deep learning classifiers performance.** *Computers and Electronics in Agriculture*, 239, 110941. <https://doi.org/https://doi.org/10.1016/j.compag.2025.110941>
- Dehghanimahmoudabadi, M., Mirzaie, K., & Peyravi, F. (2023). **Improving Credit Assignment in a learning classier system with Markov reinforcement learning for protein secondary structure prediction.** *Journal of Applied and Basic Machine Intelligence Research*, 1(2), 92–104. <https://www.magiran.com/paper/2661108>
- DehghaniMahmoudAbadi, M., & Samavarchi, H. (2013). **Designing the Matrix of Analysis to Solve the Problems Regarding the Web Site Searching.** *International Journal of Soft Computing And Software Engineering (JSCSE)*, 34(2251–7545), DOI-10.
- Li, X., Shu, Q., Kong, C., Wang, J., Li, G., Fang, X., Lou, X., & Yu, G. (2025). **An Intelligent System for Classifying Patient Complaints Using Machine Learning and Natural Language Processing: Development and Validation Study.** *Journal of Medical Internet Research*, 27. <https://doi.org/https://doi.org/10.2196/55721>
- Ma, M., Ng, D. T. K., Liu, Z., & Wong, G. K. W. (2025). **Fostering responsible AI literacy: A systematic review of K-12 AI ethics education.** *Computers and Education: Artificial Intelligence*, 8, 100422. <https://doi.org/https://doi.org/10.1016/j.caeai.2025.100422>
- Mohammed, A. A., Ambak, K., Yahia, H. A. M., Abdulhadi, I. M., Mohammed, H. A., Mashhadany, Y. Al, & Jashami, H. (2025). **Management and prediction of traffic crashes on residential streets in Iraq using the expert system (MPTCRSI-ES).** *Case Studies on Transport Policy*, 21, 101530. <https://doi.org/https://doi.org/10.1016/j.cstp.2025.101530>
- N nabavizadeh, M. R. deghanimahmoudabadi. (2023). **Improving the learning classifier system with the basic memetic algorithm to solve the problem based on the law. The Journal of Engineering Management and Soft Computing.**
- Nofal, A. Bin, Ali, H., Hadi, M., Ahmad, A., Qayyum, A., Johri, A., Al-Fuqaha, A., & Qadir, J. (2025). **AI-enhanced interview simulation in the metaverse: Transforming professional skills training through VR and generative conversational AI.** *Computers and Education: Artificial Intelligence*, 8, 100347. <https://doi.org/https://doi.org/10.1016/j.caeai.2024.100347>
- Rajathi, C., & Rukmani, P. (2025). **Hybrid Learning Model for intrusion detection system: A combination of parametric and non-parametric classifiers.** *Alexandria Engineering Journal*, 112, 384–396. <https://doi.org/https://doi.org/10.1016/j.aej.2024.10.101>
- Wiese, L. J., Patil, I., Schiff, D. S., & Magana, A. J. (2025). **AI ethics education: A systematic literature review.** *Computers and Education: Artificial Intelligence*, 8, 100405. <https://doi.org/https://doi.org/10.1016/j.caeai.2025.100405>
- Xu, Z., Shi, X., Shu, W., Xin, Y., Zan, X., Si, Z., & Cheng, J. (2025). **Machine learning classifiers to detect data pattern change of continuous emission monitoring system: A typical chemical industrial park as an example.** *Environment International*, 201, 109594. <https://doi.org/https://doi.org/10.1016/j.envint.2025.109594>

- Camisón, César. And Villar-López, Ana. (2011). **Non-technical innovation: Organizational memory and learning capabilities as antecedent factors with effects on sustained competitive advantage**. Industrial Marketing Management. 40 (2011). 1294–1304.
- Hazen, Benjamin and Terry Anthony. (2012). **Toward creating competitive advantage with logistics information technology**. International Journal of Physical Distribution & Logistics Management. Vol. 42. No. 1. 8-35.