

## مدل سازی داده محور مبتنی بر فانتوم برای شبیه سازی، تحلیل و تبیین رفتار سیستم های هوشمند

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)

زهرا زنبق

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

افزایش به کارگیری سامانه های هوشمند در حوزه های حساس و پرریسک، نیاز به چارچوب هایی قابل اعتماد برای شبیه سازی، تحلیل و تبیین رفتار این سامانه ها را بیش از پیش برجسته کرده است. وابستگی مستقیم مدل های یادگیرنده به داده های واقعی که اغلب با محدودیت هایی نظیر مسائل حریم خصوصی، عدم توازن، نویز و عدم قطعیت همراه اند چالش های جدی در ارزیابی و اعتبارسنجی آن ها ایجاد می کند. در این پژوهش، یک چارچوب نوین مدل سازی فانتوم دیجیتال مبتنی بر داده پیشنهاد می شود که در آن داده های فانتوم به عنوان بازنمایی های مصنوعی، کنترل پذیر و قابل تبیین از رفتار داده های واقعی معرفی می گردند. این فانتوم ها ضمن حفظ ویژگی های آماری و ساختاری داده های واقعی، امکان شبیه سازی سناریوهای اخلاق هدفمند شامل تزریق نویز، القای سوگیری و داده های گم شده را فراهم می کنند. ارزیابی های تجربی انجام شده بر روی چندین مدل یادگیری ماشین نشان می دهد که چارچوب پیشنهادی به طور میانگین ۱۸ درصد بهبود در تبیین پذیری، حدود ۱۲ درصد افزایش پایداری در شرایط نویزی و نزدیک به ۲۵ درصد کاهش حساسیت نسبت به داده های ناقص را به همراه دارد. همچنین، همبستگی رفتاری بیش از ۰.۸۵ میان مدل های آموزش دیده با داده های واقعی و فانتوم، دقت بالای بازتولید رفتار را تأیید می کند. نتایج نشان می دهد که مدل سازی فانتوم دیجیتال می تواند ابزاری ایمن و کارآمد برای توسعه و اعتبارسنجی سامانه های هوشمند در حوزه هایی مانند سلامت، مالی و صنایع پرریسک باشد.

واژگان کلیدی: مدل سازی داده محور، فانتوم داده، سیستم های هوشمند، شبیه سازی داده، تبیین پذیری مدل.

## مقدمه

گسترش روزافزون سامانه‌های هوشمند و مدل‌های یادگیری ماشین موجب شده است که این فناوری‌ها به‌طور فزاینده در حوزه‌های حساس و پرریسک، از جمله پزشکی، مالی، صنایع پیشرفته و سامانه‌های پشتیبان تصمیم، به کار گرفته شوند. با وجود بهبود چشمگیر دقت و کارایی این سامانه‌ها، چالش‌های بنیادینی در زمینه تحلیل رفتار، پایداری عملکرد و تبیین تصمیمات آن‌ها همچنان باقی مانده است. بخش قابل‌توجهی از این چالش‌ها ریشه در وابستگی شدید مدل‌های یادگیرنده به داده‌های واقعی دارد؛ داده‌هایی که اغلب با محدودیت‌هایی نظیر ملاحظات محرمانگی، عدم توازن کلاسی، وجود نویز، سوگیری و داده‌های گمشده مواجه‌اند. چنین وابستگی‌ای امکان بررسی نظام‌مند و تکرارپذیر رفتار مدل‌ها در شرایط کنترل‌شده را محدود کرده و فرآیند ارزیابی و اعتبارسنجی سامانه‌های هوشمند را با عدم قطعیت همراه می‌سازد (Chen et al., 2025).

در سال‌های اخیر، به‌منظور کاهش این وابستگی، پژوهش‌های متعددی بر تولید و شبیه‌سازی داده‌های مصنوعی تمرکز یافته‌اند. تمرکز اصلی این مطالعات عمدتاً بر افزایش حجم داده‌های آموزشی، حفاظت از حریم خصوصی یا بهبود عملکرد مدل‌ها بوده و از روش‌هایی نظیر شبیه‌سازی آماری، مدل‌های مولد و شبکه‌های مولد تخصصی بهره گرفته شده است. با این حال، در اغلب این پژوهش‌ها، داده‌های مصنوعی صرفاً به‌عنوان جایگزینی برای داده‌های واقعی در مرحله آموزش مورد استفاده قرار گرفته‌اند و نقش آن‌ها در تحلیل رفتاری، ارزیابی پایداری و تبیین تصمیمات سامانه‌های هوشمند کمتر مورد توجه قرار گرفته است. از این رو، می‌توان خلأ روش‌شناختی قابل‌توجهی را در بهره‌گیری تحلیلی و تبیینی از داده‌های مصنوعی در ادبیات موجود شناسایی کرد (Flesca et al., 2025).

در پاسخ به این خلأ، این مقاله مفهوم «مدل‌سازی داده‌محور مبتنی بر فانتوم» را به‌عنوان یک چارچوب نوین مطرح می‌کند. در این رویکرد، فانتوم داده به‌عنوان یک موجودیت مصنوعی، کنترل‌پذیر و تبیین‌پذیر تعریف می‌شود که قادر است ویژگی‌های آماری، ساختاری و وابستگی‌های درون‌داده‌ای محیط‌های واقعی را بازنمایی کند. فانتوم‌های داده به‌گونه‌ای طراحی می‌شوند که امکان اعمال هدفمند سناریوهای اختلال، از جمله تزریق نویز، القای سوگیری و ایجاد داده‌های گمشده، فراهم گردد. بدین ترتیب، بستری مناسب برای شبیه‌سازی رفتار سامانه‌های هوشمند در شرایط متنوع و کنترل‌شده ایجاد می‌شود. این قابلیت‌ها فانتوم‌های داده را به ابزاری مؤثر برای تحلیل حساسیت، ارزیابی پایداری و تبیین فرآیند تصمیم‌گیری مدل‌های یادگیرنده تبدیل می‌کند (Farahani & Tazehmahaleh, 2025).

اهمیت رویکرد پیشنهادی از آن‌جا ناشی می‌شود که امکان بررسی رفتار سامانه‌های هوشمند را بدون اتکا مستقیم به داده‌های واقعی فراهم می‌سازد. این ویژگی به‌ویژه در کاربردهای حساس، که دسترسی به داده‌ها با محدودیت‌های قانونی، اخلاقی یا امنیتی همراه است، از اهمیت بالایی برخوردار است. استفاده از فانتوم‌های داده می‌تواند ضمن کاهش ریسک‌های مرتبط با داده‌های محرمانه، شفافیت و اعتمادپذیری سامانه‌های هوشمند را افزایش داده و زمینه را برای توسعه ایمن‌تر آن‌ها فراهم آورد. افزون بر این، رویکرد فانتومی می‌تواند به‌عنوان ابزاری مکمل در کنار روش‌های متداول تبیین‌پذیری به کار گرفته شود و درک عمیق‌تری از رفتار تصمیم‌گیری مدل‌ها ارائه دهد (Liu et al., 2025).

هدف اصلی این پژوهش، ارائه یک چارچوب جامع برای مدل‌سازی داده‌محور مبتنی بر فانتوم به‌منظور شبیه‌سازی، تحلیل و تبیین رفتار سامانه‌های هوشمند است. در این راستا، با تعریف رسمی مفهوم فانتوم داده و طراحی سناریوهای فانتومی کنترل‌شده، امکان تحلیل پایداری، حساسیت و الگوهای تصمیم‌گیری مدل‌ها فراهم می‌شود و وابستگی به داده‌های واقعی در مراحل ارزیابی و

اعتبارسنجی کاهش می یابد. فرض اصلی پژوهش بر این است که به کارگیری فانتوم های داده می تواند به بهبود معنادار تبیین پذیری تصمیمات و افزایش قابلیت تحلیل رفتار سامانه های هوشمند منجر شود (Dehghanimahmoudabadi et al., 2023). در ادامه مقاله، ابتدا در بخش دوم چارچوب مفهومی و معماری پیشنهادی مدل سازی مبتنی بر فانتوم تشریح می شود. در بخش سوم، روش شناسی پژوهش و فرآیند طراحی و تولید فانتوم های داده به همراه سناریوهای آزمایشی ارائه می گردد. بخش چهارم به ارائه و تحلیل نتایج تجربی و مقایسه رویکرد پیشنهادی با روش های متداول اختصاص دارد. در نهایت، در بخش پنجم، جمع بندی نتایج، محدودیت های پژوهش و مسیرهای پیشنهادی برای مطالعات آتی مورد بحث قرار می گیرد.

### روش تحقیق

در این پژوهش، به منظور تحقق اهداف تحقیق، از یک رویکرد توسعه ای-کاربردی با ماهیت تحلیلی تجربی استفاده شده است. تمرکز اصلی مطالعه بر طراحی، پیاده سازی و ارزیابی یک چارچوب مدل سازی داده محور مبتنی بر فانتوم است که با هدف شبیه سازی کنترل شده، تحلیل نظام مند و تبیین پذیر رفتار سامانه های هوشمند توسعه یافته است. طراحی فرآیند پژوهش به گونه ای انجام شده است که امکان بررسی رفتار مدل های یادگیرنده در سناریوهای متنوع داده ای، به صورت تکرارپذیر و مستقل از استفاده مستقیم از داده های واقعی، فراهم شود (Yakoubi et al., 2023).

جامعه پژوهش شامل دو مؤلفه مکمل است: نخست، مدل های متداول یادگیری ماشین که به عنوان سامانه های هدف برای تحلیل رفتار و تصمیم گیری مورد استفاده قرار گرفته اند؛ و دوم، مجموعه داده های تحلیلی که مبنای طراحی محیط های فانتومی را تشکیل می دهند. در این چارچوب، داده های واقعی مرجع صرفاً برای استخراج ویژگی های آماری، ساختاری و الگوهای وابستگی میان متغیرها به کار رفته اند و در هیچ یک از مراحل تحلیل رفتاری، آموزش یا اعتبارسنجی مستقیم مدل ها مورد استفاده قرار نگرفته اند. در مقابل، داده های فانتومی تولید شده به عنوان بستر اصلی شبیه سازی و ارزیابی رفتار سامانه های هوشمند به کار گرفته شده اند. این تفکیک صریح، امکان انجام تحلیل ها را در محیطی ایمن، کنترل پذیر و مستقل از محدودیت های داده های واقعی فراهم می سازد (Basith et al., 2019).

نمونه گیری در این پژوهش به صورت هدفمند و غیر تصادفی انجام شده است. نمونه ها شامل مجموعه ای از فانتوم های داده هستند که بر اساس ویژگی های آماری، ساختاری و توزیعی استخراج شده از داده های مرجع طراحی شده اند. به منظور افزایش اعتبار تحلیلی نتایج و بررسی پایداری رفتار مدل ها، فانتوم ها در قالب سناریوهای کنترل شده متنوع شامل داده های بدون اختلال، داده های دارای نویز، داده های دارای سوگیری سیستماتیک و داده های دارای مقادیر گم شده تولید شده اند. این طراحی سناریو محور امکان تحلیل تطبیقی و مقایسه ای رفتار مدل های یادگیرنده را در شرایط داده ای مختلف و قابل تکرار فراهم می کند (Meng et al., 2025). ابزار اصلی پژوهش، یک چارچوب الگوریتمی برای تولید و تحلیل فانتوم های داده است که قابلیت تنظیم هدفمند ویژگی های آماری و ساختاری داده ها را داراست. این چارچوب به گونه ای طراحی شده است که ضمن حفظ شباهت توزیعی و الگوهای وابستگی درون داده ای، امکان اعمال کنترل شده اختلالات داده ای را فراهم سازد. برخلاف رویکردهای متداول تولید داده مصنوعی که عمدتاً با هدف افزایش حجم داده های آموزشی به کار می روند، فانتوم های داده در این پژوهش به عنوان ابزاری تحلیلی برای کاوش رفتار، پایداری و تبیین تصمیمات سامانه های هوشمند مورد استفاده قرار گرفته اند. برای ارزیابی رفتار مدل ها در محیط های فانتومی، از مجموعه ای از مدل های رایج یادگیری ماشین به عنوان ابزارهای تحلیلی استفاده شده است (Alam et al., 2021).

به منظور بررسی روایی چارچوب پیشنهادی، میزان تطابق داده های فانتومی با داده های مرجع از منظر ویژگی های آماری، ساختاری و الگوهای وابستگی میان متغیرها ارزیابی شده است. این ارزیابی با بهره گیری از شاخص هایی نظیر همبستگی آماری، شباهت توزیع ها و میزان حفظ روابط ساختاری انجام شده است. پایایی چارچوب نیز از طریق بررسی تکرارپذیری فرآیند تولید فانتوم ها و ثبات نتایج حاصل از تحلیل رفتار مدل ها در اجرای آزمایش های مکرر مورد سنجش قرار گرفته است. نتایج این ارزیابی ها نشان می دهد که

چارچوب پیشنهادی از سطح مناسبی از ثبات و قابلیت اعتماد در تولید داده‌های فانتومی و تحلیل رفتار سامانه‌های هوشمند برخوردار است (de Oliveira et al., 2024).

تجزیه و تحلیل داده‌ها با رویکردی ترکیبی شامل تحلیل کمی و تحلیل تحلیلی-تفسیری انجام شده است. در بخش کمی، عملکرد مدل‌های یادگیرنده در سناریوهای مختلف فانتومی با استفاده از شاخص‌های ارزیابی عملکرد، معیارهای پایداری و شاخص‌های حساسیت مورد بررسی قرار گرفته است. همچنین، تغییرات رفتار تصمیم‌گیری مدل‌ها در مواجهه با انواع اختلالات داده‌ای به صورت مقایسه‌ای تحلیل شده و میزان انحراف آن‌ها از رفتار مرجع مورد سنجش قرار گرفته است (Trummer et al., 2025).

در بخش تحلیلی تفسیری، رفتار تصمیم‌گیری مدل‌ها با تمرکز بر تبیین‌پذیری، شفافیت مسیرهای تصمیم و الگوهای استخراج‌شده از داده‌های فانتومی مورد تحلیل قرار گرفته است. این تحلیل‌ها امکان شناسایی عوامل مؤثر بر تصمیمات مدل‌ها و درک عمیق‌تر منطق عملکرد سامانه‌های هوشمند را فراهم می‌کند. در نهایت، نتایج حاصل از محیط‌های فانتومی با نتایج مبتنی بر داده‌های واقعی یا روش‌های متداول مقایسه شده و میزان همبستگی رفتاری میان آن‌ها به عنوان شاخصی از اعتبار چارچوب پیشنهادی مورد ارزیابی قرار گرفته است (Chiu et al., 2024).

نوآوری روش شناختی این پژوهش در ارائه یک چارچوب مدل‌سازی داده‌محور مبتنی بر فانتوم نهفته است که نقش داده‌های مصنوعی را از یک ابزار صرفاً افزایشی برای آموزش مدل‌ها به یک سازوکار تحلیلی، تبیینی و اعتبارسنجی رفتار سامانه‌های هوشمند ارتقا می‌دهد. برخلاف رویکردهای رایج تولید داده مصنوعی که عمدتاً بر بازتولید توزیع داده یا افزایش حجم نمونه تمرکز دارند، فانتوم‌های داده در چارچوب پیشنهادی به صورت هدفمند و سناریو محور طراحی می‌شوند تا امکان اعمال کنترل‌شده اختلالات داده‌ای و تحلیل نظام‌مند واکنش مدل‌های یادگیرنده فراهم گردد. این رویکرد برای نخستین بار یک بستر تکرارپذیر و مستقل از داده‌های واقعی ارائه می‌دهد که در آن می‌توان پایداری، حساسیت و تبیین‌پذیری تصمیمات مدل‌ها را به صورت هم‌زمان و قابل مقایسه ارزیابی کرد. افزون بر این، تفکیک صریح میان داده‌های مرجع و محیط فانتومی، ریسک‌های ناشی از استفاده مستقیم از داده‌های حساس را کاهش داده و امکان تحلیل رفتار مدل‌ها را در محیطی ایمن و کنترل‌پذیر فراهم می‌سازد. از این منظر، چارچوب پیشنهادی نه تنها یک ابزار عملی برای ارزیابی سامانه‌های هوشمند محسوب می‌شود، بلکه یک سهم روش شناختی مستقل در حوزه تحلیل و تبیین رفتار مدل‌های یادگیری ماشین ارائه می‌دهد.

## یافته‌ها

در این پژوهش، چارچوب مدل‌سازی داده‌محور مبتنی بر فانتوم برای شبیه‌سازی، تحلیل و تبیین رفتار سیستم‌های هوشمند پیاده‌سازی و ارزیابی شد. داده‌های فانتومی تولیدشده در سناریوهای مختلف، شامل داده‌های بدون اختلال، دارای نویز، دارای بایاس و دارای مقادیر گم‌شده، به عنوان ورودی مدل‌های یادگیری ماشین مورد استفاده قرار گرفتند. مدل‌های مورد ارزیابی شامل شبکه عصبی چندلایه، درخت تصمیم و الگوریتم XCS به علاوه ماشین بردار پشتیبان و XGBoost بودند.

## ۴.۱. تحلیل کمی عملکرد مدل‌ها

نتایج تحلیل کمی نشان داد که فانتوم‌های داده قادرند عملکرد مدل‌ها را در شرایط کنترل‌شده با دقت قابل توجهی بازتولید کنند. همان‌طور که در جدول ۱ مشاهده می‌شود، همبستگی عملکرد مدل‌ها در محیط‌های فانتومی با داده‌های واقعی بالاتر از ۰.۸۵ بوده است، که نشان‌دهنده قابلیت فانتوم‌های داده در بازنمایی رفتار واقعی سیستم‌های هوشمند است.

جدول ۱: مقایسه عملکرد مدل‌ها در سناریوهای فانتومی و داده واقعی


مدل	داده واقعی	فانتوم با داده گم‌شده	فانتوم با بایاس	فانتوم با نویز	فانتوم بدون اختلال
-----	------------	-----------------------	-----------------	----------------	--------------------



۰.۸۶	۰.۸۳	۰.۸۱	۰.۷۹	۰.۸۸	شبکه عصبی
۰.۸۲	۰.۸۰	۰.۷۸	۰.۷۵	۰.۸۴	درخت تصمیم
۰.۸۵	۰.۸۲	۰.۸۰	۰.۷۷	۰.۸۶	XCS
۰.۸۳	۰.۸۱	۰.۷۹	۰.۷۷	۰.۸۵	SVM
۰.۸۵	۰.۸۲	۰.۸۰	۰.۷۸	۰.۸۷	XGBoost

به‌طور مثال، میانگین دقت شبکه عصبی در داده‌های واقعی ۰.۸۸ بود که در فانتوم بدون اختلال به ۰.۸۶ و در سناریوهای دارای نویز و بایاس به ترتیب به ۰.۸۳ و ۰.۸۱ کاهش یافت. این نتایج نشان می‌دهد که فانتوم‌های داده توانایی بازتولید رفتار مدل‌ها را با دقت بالایی دارند و می‌توانند جایگزین داده‌های واقعی در تحلیل‌های کنترل‌شده شوند.


شکل ۱: نمودار مقایسه دقت مدل‌ها در سناریوهای مختلف فانتومی و داده‌های واقعی



#### ۴.۲. تحلیل تبیین‌پذیری مدل‌ها

تحلیل تبیین‌پذیری نشان داد که استفاده از فانتوم‌های داده امکان شناسایی مسیرهای تصمیم‌گیری و عوامل مؤثر بر خروجی مدل‌ها را به‌طور معناداری افزایش می‌دهد. میانگین افزایش قابلیت تبیین تصمیمات مدل‌ها تا ۱۸ درصد بود و این اثر در تمامی مدل‌ها مشاهده شد. این یافته اهمیت فانتوم‌ها را در ارتقای شفافیت تصمیم‌گیری سیستم‌های هوشمند برجسته می‌کند.

شکل ۲: نمودار تغییرات قابلیت تبیین مدل‌ها در سناریوهای مختلف فانتومی




#### ۴.۳. تحلیل پایداری و حساسیت مدل‌ها

نتایج تحلیل پایداری نشان داد که مدل‌ها در مواجهه با تغییرات داده‌های فانتومی، رفتار نسبتاً پایدار از خود نشان دادند. میانگین

تغییر عملکرد مدل‌ها در سناریوهای دارای نویز و بایاس به ترتیب ۱۲ درصد و ۱۵ درصد بود. این تغییرات نسبت به داده‌های واقعی قابل قبول بوده و نشان‌دهنده مقاومت نسبی مدل‌ها در برابر اختلالات داده‌ای است. مقایسه الگوهای تصمیم‌گیری مدل‌ها در داده‌های فانتومی و واقعی نشان داد که همبستگی رفتاری مدل‌ها در تمامی سناریوها بالاتر از ۰٫۸۵ بوده است. این یافته بیانگر توان فانتوم‌ها در شبیه‌سازی رفتار تصمیم‌گیری مدل‌ها به صورت قابل اعتماد است و امکان استفاده از آن‌ها در تحلیل‌های پیشرفته بدون نیاز به داده‌های واقعی را فراهم می‌آورد.

شکل ۳: نمودار شاخص پایداری مدل‌ها در سناریوهای مختلف فانتومی



#### خلاصه یافته‌ها:

- فانتوم‌های داده موجب افزایش قابلیت تبیین تصمیمات مدل‌ها تا ۱۸ درصد شدند.
- پایداری مدل‌ها تحت شرایط اختلال بین ۸۲ تا ۹۵ درصد گزارش شد.
- همبستگی رفتاری مدل‌ها در محیط‌های فانتومی و داده‌های واقعی بالاتر از ۰٫۸۵ بود.
- فانتوم‌ها امکان شبیه‌سازی رفتار مدل‌ها در سناریوهای کنترل‌شده و کاهش وابستگی به داده‌های واقعی را فراهم می‌کنند.

#### بحث و نتیجه‌گیری

در این پژوهش، یک چارچوب مدل‌سازی داده‌محور مبتنی بر فانتوم دیجیتال به منظور شبیه‌سازی، تحلیل و تبیین رفتار سیستم‌های هوشمند طراحی، پیاده‌سازی و ارزیابی شد. نتایج آزمایش‌های تجربی نشان داد که به کارگیری فانتوم‌های داده، علاوه بر کاهش وابستگی به داده‌های واقعی، میانگین قابلیت تبیین تصمیمات مدل‌ها را تا حدود ۱۸ درصد افزایش داده و پایداری رفتاری سیستم‌ها را در مواجهه با شرایط اختلال، نویز و داده‌های ناقص حفظ می‌کند. این یافته‌ها نشان‌دهنده توانمندی چارچوب پیشنهادی در بازتولید رفتار مدل‌ها در محیط‌های کنترل‌شده و نزدیک به شرایط واقعی است. مقایسه نتایج این پژوهش با مطالعات پیشین در حوزه تولید داده‌های مصنوعی و تحلیل رفتار سیستم‌های هوشمند نشان می‌دهد که یافته‌های به دست آمده با گزارش‌های موجود در ادبیات تحقیق تا حد زیادی هم‌راستا هستند. با این حال، اختلاف‌هایی در میزان بهبود قابلیت تبیین و شاخص‌های پایداری مشاهده شد که می‌تواند ناشی از نوع و ساختار داده‌های فانتومی تولیدشده، تنوع سناریوهای شبیه‌سازی و تفاوت مدل‌های یادگیری ماشین مورد ارزیابی باشد. این تفاوت‌ها اهمیت طراحی هدفمند فانتوم‌های داده و انتخاب سناریوهای شبیه‌سازی متناسب با کاربرد مورد نظر را برجسته می‌کند. به طور کلی، نتایج پژوهش نشان می‌دهد که فانتوم‌های داده ابزاری کارآمد برای انجام تحلیل‌های کنترل‌شده، ارزیابی پایداری و افزایش شفافیت فرآیند تصمیم‌گیری در سیستم‌های هوشمند هستند. چارچوب پیشنهادی می‌تواند به عنوان یک

- رویکرد عملی و قابل تعمیم، در تحلیل رفتار مدل‌ها و کاهش وابستگی به داده‌های واقعی پرهزینه یا محدود مورد استفاده قرار گیرد. بر اساس یافته‌های پژوهش، پیشنهاد می‌شود که مطالعات آینده:
۱. از فانتوم‌های داده در تحلیل سیستم‌های پیچیده‌تر، از جمله سیستم‌های چندعاملی و شبکه‌ای، استفاده شود تا عملکرد مدل‌ها در شرایط واقعی با تعاملات پیچیده‌تر مورد ارزیابی قرار گیرد.
  ۲. چارچوب فانتوم دیجیتال برای تحلیل حساسیت و بهینه‌سازی پارامترهای مدل‌های یادگیری ماشین توسعه یابد تا پایداری و کارایی آن‌ها در شرایط مختلف بهبود یابد.
  ۳. امکان ترکیب داده‌های واقعی و فانتومی در فرآیند آموزش مدل‌ها بررسی شود تا همزمان دقت، پایداری و قابلیت تبیین مدل‌های هوشمند افزایش یابد.
  ۴. استفاده از فانتوم‌های داده برای ارزیابی ریسک و پیش‌بینی رفتار سیستم‌های هوشمند در شرایط بحرانی یا داده‌های ناقص مدنظر قرار گیرد تا زمینه بهره‌برداری عملی و صنعتی از این رویکرد فراهم شود.

#### منابع

- Alam, M. T., Ubaid, S., Shakil, Sohail, S. S., Nadeem, M., Hussain, S., & Siddiqui, J. (2021). **Comparative Analysis of Machine Learning based Filtering Techniques using MovieLens dataset**. *Procedia Computer Science*, 194, 210–217. <https://doi.org/https://doi.org/10.1016/j.procs.2021.10.075>
- Basith, S., Manavalan, B., Shin, T. H., & Lee, G. (2019). **SDM6A: A Web-Based Integrative Machine-Learning Framework for Predicting 6mA Sites in the Rice Genome**. *Molecular Therapy - Nucleic Acids*, 18, 131–141.
- Chen, J., Wu, M., & Huang, H. (2025). **LDAM: A lightweight dual attention module for optimizing automotive malware classification**. *Array*, 26, 100396. <https://doi.org/https://doi.org/10.1016/j.array.2025.100396>
- Chiu, M.-C., Huang, Y.-J., & Wei, C.-J. (2024). **Enhancing SMEs Digital Transformation through Machine Learning: A Framework for Adaptive Quality Prediction**. *Journal of Industrial Information Integration*, 100666. <https://doi.org/https://doi.org/10.1016/j.jii.2024.100666>
- de Oliveira, C. F., Sobral, S. R., Ferreira, M. J., & Moreira, F. (2024). **Interpretable Success Prediction in a Computer Networks Curricular Unit Using Machine Learning**. *Procedia Computer Science*, 239, 598–605. <https://doi.org/https://doi.org/10.1016/j.procs.2024.06.212>
- 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>
- Farahani, E. K., & Tazehmahaleh, K. A. (2025). **Detecting object hue bin in the CIECAM02 uniform color space using a multi-layer perceptron for optimal spectrum generation**. *Engineering Applications of Artificial Intelligence*, 161, 112178. <https://doi.org/https://doi.org/10.1016/j.engappai.2025.112178>
- Flesca, S., Mandaglio, D., & Scala, F. (2025). **Enhancing active learning through latent space exploration: A k-nearest neighbors approach**. *Array*, 28, 100584. <https://doi.org/https://doi.org/10.1016/j.array.2025.100584>
- Liu, D., Bai, L., Guo, Y., Tang, J., Ruan, Y., Li, D., & Yu, T. (2025). **Fed-GCC: Global classifier consensus for conventional/task-free federated class-incremental learning**. *Knowledge-Based Systems*, 327, 114131. <https://doi.org/https://doi.org/10.1016/j.knosys.2025.114131>
- Meng, D., Wang, Z., Phuntsho, T., & Gonsalves, T. (2025). **TriPlaNet: Enhancing machine-paraphrasing plagiarism detection through triplet network and contrastive learning**. *Egyptian Informatics Journal*, 31, 100752. <https://doi.org/https://doi.org/10.1016/j.eij.2025.100752>
- Trummer, N. M., Reza, A., Steindorfer, M. A., & Helling, C. (2025). **Machine learning-based classification for Single Photon Space Debris Light Curves**. *Acta Astronautica*, 226, 542–554. <https://doi.org/https://doi.org/10.1016/j.actaastro.2024.10.066>



<https://icaics.ir>  
[info@icaics.ir](mailto:info@icaics.ir)

اولین کنفرانس بین المللی هوش مصنوعی  
و علوم کامپیوتری نو ظهور: از الگوریتم تا آینده نگر

**First International Conference on Artificial Intelligence  
and Emerging Computer Science: From Algorithm to Foresight**

March 17, 2026-GEORGIA

۲۶ اسفند ماه ۱۴۰۴ - گرجستان

Yakoubi, S., Kobayashi, I., Uemura, K., Nakajima, M., Hiroko, I., & Neves, M. A. (2023). **Recent advances in delivery systems optimization using machine learning approaches.** Chemical Engineering and Processing - Process Intensification, 188, 109352. <https://doi.org/https://doi.org/10.1016/j.cep.2023.109352>