



کاربردهای هوش مصنوعی در سیستم‌های انتقال و تصفیه آب: رویکردهای مبتنی بر یادگیری ماشین و مکانیک سیالات در هیدرولیک گذرا، بهینه‌سازی شبکه و کنترل هوشمند

علیرضا محمودی فرد^{۱*}، سید محمدرضا حسینی علی آباد^۲

^۱پسادکترای آینده پژوهی و مدرس دانشگاه ملی مهارت، دانشکده فنی انقلاب اسلامی، تهران، ایران، alireza10.m10@gmail.com

^۲پسادکتری مدیریت بازرگانی-مدیریت استراتژیک، دانشگاه بین‌المللی نورث‌وست ارمنستان، info@confnashr.ir

چکیده

هوش مصنوعی به‌ویژه یادگیری ماشین و یادگیری عمیق، انقلابی در شبیه‌سازی، پیش‌بینی و کنترل سیستم‌های انتقال و تصفیه آب ایجاد کرده است. این مقاله به بررسی جامع کاربردهای هوش مصنوعی در هفت حوزه‌ی اصلی شامل هیدرولیک گذرا و ضربه قوچ (با شبکه‌های عصبی مصنوعی و PINN، خطای پیش‌بینی فشار ۰٫۴۵ متر و سرعت ۵۰۰۰ برابری)، بهینه‌سازی شبکه‌های توزیع آب (با یادگیری تقویتی عمیق، کاهش نشت ۲۳٪ و انرژی ۱۸٪)، پیش‌بینی کیفیت آب (با LSTM، خطای کلر ۰٫۰۵ میلی گرم در لیتر)، کنترل شبکه‌های فاضلاب شهری (با CNN-LSTM و PPO، کاهش سرریز ۵۲٪ و انرژی هوادهی ۳۵٪)، مدل‌سازی فرآیندهای تصفیه (با ResNet، دقت دوز منعقدکننده ۹۷٪)، کاهش مرتبه در شبیه‌سازی CFD راکتورها (با POD-RNN، سرعت ۱۰۰۰ برابری و خطای ۳۰۲٪) و سیستم‌های نمک‌زدایی (پیش‌بینی زمان تمیزکاری با خطای ۴-۸ روز و کاهش هزینه‌ی نگهداری ۳۰٪) پرداخته است. نتایج فراتحلیل ۳۰ مقاله نشان می‌دهد که میانگین افزایش سرعت مدل‌های کاهش مرتبه نسبت به روش‌های کلاسیک (CFD، MOC) حدود ۴۵۰ برابر و میانگین خطای پیش‌بینی ۱۲-۵٪ است. چالش‌های اصلی شامل قابلیت تعمیم‌پذیری محدود، تفسیرپذیری پایین، نیاز به داده‌های حجیم و کمی‌سازی عدم قطعیت است. دوقلوی دیجیتال مبتنی بر IoT و یادگیری تقویتی با تأخیر کمتر از ۵ دقیقه قادر به پیش‌بینی و پیشگیری از سرریز فاضلاب است. نتایج این پژوهش می‌تواند مبنایی برای توسعه‌ی مدل‌های قابل اعتماد، تفسیرپذیر و دارای قابلیت تعمیم بالا در زیرساخت‌های آبی قرار گیرد.

کلمات کلیدی

هوش مصنوعی، سیستم‌های انتقال آب، تصفیه آب، هیدرولیک گذرا، یادگیری تقویتی، شبکه‌های عصبی مبتنی بر فیزیک، کاهش مرتبه، دوقلوی دیجیتال



مقدمه

دسترسی به آب سالم و پایدار یکی از چالش‌های اساسی قرن بیست و یکم است که با عواملی مانند رشد جمعیت، تغییرات اقلیمی، آلودگی منابع آبی و فرسودگی زیرساخت‌های انتقال و تصفیه، روزبه‌روز پیچیده‌تر می‌شود (UNESCO, ۲۰۲۱). سیستم‌های انتقال و تصفیه آب، به‌عنوان شریان‌های حیاتی جوامع مدرن، با مسائل متعددی از جمله نشت و هیدرولیک گذرا در خطوط انتقال، بهینه‌سازی فرآیندهای اختلاط و لخته‌سازی، کنترل جریان در شبکه‌های فاضلاب و کاهش مصرف انرژی در تصفیه‌خانه‌ها مواجه هستند (Tchobanoglous, ۲۰۲۱). در این میان، مکانیک سیالات به‌عنوان دانش حاکم بر رفتار آب در لوله‌ها، مخازن، کانال‌ها و راکتورهای تصفیه، نقشی محوری ایفا می‌کند (Ghidaoui, ۲۰۰۴). با این حال، ماهیت غیرخطی، آشسته و چندمقیاسی جریان‌های سیالاتی، همراه با عدم قطعیت‌های موجود در پارامترهای هیدرولیکی و کیفی، شبیه‌سازی و بهینه‌سازی این سیستم‌ها را با روش‌های سنتی به چالش بزرگی تبدیل کرده است (Pope, ۲۰۰۰). در این زمینه، هوش مصنوعی (Artificial Intelligence) و به‌ویژه شاخه‌های یادگیری ماشین (Machine Learning) و یادگیری عمیق (Deep Learning)، ابزارهای نوینی برای مدل‌سازی، پیش‌بینی، کنترل و بهینه‌سازی فرآیندهای هیدرولیکی و تصفیه آب فراهم آورده‌اند (Alvi, ۲۰۲۳). شبکه‌های عصبی مصنوعی (ANN) با قابلیت تقریب توابع غیرخطی عمومی، در شبیه‌سازی هیدرولیک گذرا (Transient Flow) و پدیده‌ی ضربه قوچ (Water Hammer) عملکرد چشمگیری داشته‌اند (Ye, ۲۰۲۲). به‌طور مثال، شبکه‌های عصبی چندلایه (MLP) قادر به پیش‌بینی فشار بیشینه در خطوط انتقال با خطای کمتر از ۱٪ و سرعت هزاران برابر سریع‌تر از روش‌های عددی کلاسیک مانند روش مشخصه (MOC) هستند (کرامت، ۲۰۲۵). در حوزه‌ی شبکه‌های فاضلاب شهری، سیستم‌های مبتنی بر یادگیری تقویتی (Reinforcement Learning) توانسته‌اند با یادگیری پویای استراتژی‌های کنترل بهینه، حجم سرریز فاضلاب را تا ۵۲٪ کاهش داده و مصرف انرژی را تا ۲۳۰ کیلووات ساعت بهبود بخشند (Zhang, ۲۰۲۵). همچنین، شبکه‌های عصبی مبتنی بر فیزیک (Physics-Informed Neural Networks – PINN) که معادلات دیفرانسیل حاکم (مانند معادلات سنت‌ونانت و معادله موج فشار) را مستقیماً در تابع هزینه قید می‌کنند، در بازسازی میدان فشار در خطوط لوله با داده‌های محدود و نویزدار، عملکردی فوق‌العاده داشته و عدم قطعیت ناشی از پارامترهای مجهول (مانند ضریب زبری و سرعت موج) را به‌طور مؤثر کاهش می‌دهند (Huang, ۲۰۲۴). در فرآیندهای تصفیه آب (مانند لخته‌سازی و انعقاد)، مدل‌های ترکیبی با استفاده از شبکه‌های عصبی کانولوشنی (CNN) و یادگیری تقویتی، توانسته‌اند دقت پیش‌بینی دوز ماده‌ی منعقدکننده را تا ۹۵-۹۷٪ افزایش دهند و زمان بهینه‌سازی را تا ۴۰٪ کاهش دهند (Mohamed, ۲۰۲۵). علاوه بر این، مدل‌های کاهش مرتبه (Reduced-Order Models) مبتنی بر شبکه‌های عصبی، با جایگزینی شبیه‌سازی‌های پرهزینه دینامیک سیالات محاسباتی (CFD) در راکتورهای تصفیه، هزینه‌های محاسباتی را به‌طور قابل توجهی کاهش داده‌اند (Wei, ۲۰۲۰). در زمینه‌ی هوشمندسازی تصفیه‌خانه‌ها، روش‌های یادگیری ماشین برای پیش‌بینی کیفیت پساب (مانند COD، نیتروژن آمونیاکی و فسفر)، بهینه‌سازی هوادهی (Aeration) و کاهش مصرف انرژی، به‌طور گسترده به‌کار گرفته شده‌اند (Wang, ۲۰۲۲). همچنین، فناوری دوقلوی دیجیتال (Digital Twin) با ادغام مدل‌های هوش مصنوعی و حسگرهای اینترنت اشیا (IoT)، امکان پایش لحظه‌ای، تشخیص ناهنجاری و کنترل خودکار شبکه‌های توزیع آب را فراهم کرده است (Liu, ۲۰۲۳). با وجود این پیشرفت‌ها، چالش‌های قابل توجهی از جمله نیاز به داده‌های آموزشی با کیفیت و پوشش کامل فضای حالت، قابلیت تعمیم‌پذیری مدل‌ها به شبکه‌هایی با توپولوژی متفاوت، تفسیرپذیری پایین شبکه‌های عصبی عمیق (مسئله‌ی جعبه‌سیاه) و کمی‌سازی عدم قطعیت پیش‌بینی‌ها (که در تصمیم‌گیری‌های ایمنی-حیاتی مانند کنترل فشار خطوط لوله ضروری است) همچنان پابرجاست (Raissi, ۲۰۱۹). به‌ویژه، در سیستم‌های با ابعاد بالا و دینامیک سریع (مانند شبکه‌های توزیع آب در مقیاس شهری)،

روش‌های سنتی بهینه‌سازی و کنترل با محدودیت‌های محاسباتی شدیدی مواجه هستند (Brunton, ۲۰۲۰). شکاف دانشی اصلی در فقدان یک چارچوب یکپارچه برای ارزیابی عملکرد، محدودیت‌ها و قابلیت اعتماد روش‌های هوش مصنوعی در کاربردهای مختلف سیستم‌های انتقال و تصفیه آب (از جمله هیدرولیک گذرا، کنترل فعال جریان، بهینه‌سازی فرایندهای تصفیه و مدیریت هوشمند شبکه) احساس می‌شود (National Academies, ۲۰۲۴). پژوهش حاضر با انگیزه‌ی پر کردن همین خلأها و ارائه‌ی یک تحلیل جامع از کاربردهای هوش مصنوعی در سیستم‌های انتقال و تصفیه آب با تأکید بر مباحث مکانیک سیالات، سعی دارد تا ضمن مرور انتقادی پیشینه، به بررسی روش‌های اصلی، چالش‌ها، فرصت‌ها و روندهای آینده بپردازد. نوآوری این کار در ارائه‌ی یک چارچوب طبقه‌بندی جدید برای کاربردهای هوش مصنوعی در مهندسی آب (بر اساس نوع مسئله، مقیاس و هدف) و همچنین پیشنهاد یک نقشه‌ی راه (Roadmap) برای توسعه‌ی مدل‌های قابل اعتماد، تفسیرپذیر و دارای قابلیت تعمیم بالا در زیرساخت‌های آبی است (Keramat, ۲۰۲۴). اهمیت این موضوع از آن جهت است که کاهش هزینه‌های عملیاتی و نگهداری، افزایش قابلیت اطمینان و تاب‌آوری سیستم‌های آبی و کاهش آلودگی زیست‌محیطی ناشی از سرریز فاضلاب‌ها، می‌تواند مستقیماً بر سلامت عمومی، امنیت آبی و توسعه‌ی پایدار تأثیر بگذارد (UN, ۲۰۲۳).

متن اصلی

کاربردهای هوش مصنوعی در سیستم‌های انتقال و تصفیه آب (با تأکید بر مباحث مکانیک سیالاتی) را می‌توان به هفت حوزه‌ی اصلی تقسیم کرد: هیدرولیک گذرا و ضربه قوچ (Transient Flow & Water Hammer)، بهینه‌سازی شبکه‌های توزیع آب، پیش‌بینی کیفیت آب در خطوط انتقال، کنترل و مدیریت شبکه‌های فاضلاب شهری، مدل‌سازی فرآیندهای تصفیه آب (لخته‌سازی، رسوب‌گذاری، گندزدایی)، کاهش مرتبه در شبیه‌سازی‌های CFD راکتورهای تصفیه، و دوقلوی دیجیتال (Digital Twin) برای پایش و مدیریت کل سیستم (Alvi, ۲۰۲۳; Keramat, ۲۰۲۵). در حوزه‌ی هیدرولیک گذرا، روش‌های سنتی مانند روش مشخصه (MOC) و روش تفاضلات محدود (FDM) با چالش‌هایی از جمله دقت وابسته به گام زمانی، هزینه‌ی محاسباتی بالا در شبکه‌های بزرگ، و نیاز به تعیین دقیق پارامترهای مجهول مانند ضریب زبری مواجه هستند (Ghidaoui, ۲۰۰۴). شبکه‌های عصبی مصنوعی (ANN) به‌ویژه پرسپترون چندلایه (MLP) و شبکه‌های عصبی بازگشتی (RNN)، قادر به یادگیری نگاشت بین شرایط مرزی و متغیرهای هیدرولیکی هستند و می‌توانند فشار و دبی گذرا را با خطای کمتر از ۱٪ و سرعت هزاران برابر سریع‌تر از MOC پیش‌بینی کنند (Ye, ۲۰۲۲). در مطالعه‌ای که توسط کرامت و همکاران (۲۰۲۵) انجام شد، یک شبکه‌ی عصبی با ۳ لایه پنهان (هر لایه ۵۰ نورون) روی داده‌های حاصل از ۱۰۰۰ سناریوی شبیه‌سازی ضربه قوچ (با پارامترهای تصادفی شامل زبری، سرعت موج و زمان بستن شیر) آموزش دید و توانست فشار بیشینه را با میانگین خطای مطلق (MAE) ۰٫۴۵ متر و ضریب تعیین $R^2=۰٫۹۹۸$ پیش‌بینی کند (Keramat, ۲۰۲۵). شبکه‌های عصبی مبتنی بر فیزیک (PINN) نیز با قید کردن معادلات حاکم (معادله‌ی پیوستگی و معادله‌ی حرکت) در تابع هزینه، نیاز به داده‌های آموزشی را به‌شدت کاهش داده و قادر به حل مسائل معکوس (مانند تخمین سرعت موج و زبری از داده‌های فشار) با خطای کمتر از ۲٪ هستند (Huang, ۲۰۲۴). در بهینه‌سازی شبکه‌های توزیع آب، روش‌های کلاسیک مانند الگوریتم‌های ژنتیک و بهینه‌سازی ازدحام ذرات (PSO) به‌دلیل فضای جستجوی عظیم و هزینه‌ی بالای ارزیابی توابع هدف، با محدودیت مواجه هستند (Liu, ۲۰۲۳). رویکردهای مبتنی بر یادگیری تقویتی (Reinforcement Learning) با تعریف عامل هوشمند (Agent) و محیط (شبکه‌ی هیدرولیکی)، قادر به یادگیری استراتژی‌های کنترل بهینه‌ی شیرآلات و پمپ‌ها در زمان واقعی هستند (Zhang, ۲۰۲۵). به‌عنوان مثال، ژانگ و همکاران (۲۰۲۵) از یک عامل DQN (Deep Q-Network) با ۲ لایه پنهان (هر لایه ۱۲۸ نورون) برای کنترل هفت شیرآلات یک شبکه‌ی توزیع آب شهری با ۵۲ گره استفاده کردند و نشان دادند که حجم نشت را ۲۳٪ و مصرف انرژی پمپ‌ها را ۱۸٪ کاهش می‌دهد (Zhang, ۲۰۲۵). در پیش‌بینی کیفیت آب در خطوط انتقال، روش‌های مبتنی بر داده مانند شبکه‌های LSTM (Long Short-Term Memory) و GRU (Gated Recurrent Unit) قادر به پیش‌بینی

غلظت کلر باقیمانده، کدورت و pH در طول شبکه، با در نظر گرفتن دینامیک جریان و واکنش‌های شیمیایی هستند (Wang, ۲۰۲۲). مدل‌های LSTM با ۲ لایه پنهان (هر لایه ۶۴ نورون) و ۵۰ گام زمانی ورودی، می‌توانند غلظت کلر را در شبکه‌های توزیع با خطای ۰.۰۵ میلی‌گرم در لیتر و ضریب همبستگی $Pearson=0.92$ پیش‌بینی کنند (Wang, ۲۰۲۲). در کنترل و مدیریت شبکه‌های فاضلاب شهری، سیستم‌های مبتنی بر یادگیری تقویتی و مدل‌های پیش‌بینی بارش-رواناب، توانسته‌اند حجم سرریز فاضلاب (Sanitary Sewer Overflows) را تا ۵۲٪ کاهش دهند و در عین حال مصرف انرژی در تصفیه‌خانه را بهینه کنند (Liu, ۲۰۲۳). در مطالعه‌ی لیو و همکاران (۲۰۲۳)، یک مدل ترکیبی CNN-LSTM برای پیش‌بینی دبی ورودی به تصفیه‌خانه (با ۳۰ دقیقه افق زمانی) با میانگین خطای ۸.۲٪ توسعه یافت و سپس یک عامل یادگیری تقویتی (PPO - Proximal Policy Optimization) استراتژی‌های کنترل شیرآلات و پمپ‌ها را در ۲۰۰۰ دوره یادگیری بهینه کرد که منجر به کاهش ۳۵٪ در انرژی هوادهی شد (Liu, ۲۰۲۳). در فرایندهای تصفیه آب (لخته‌سازی و انعقاد)، مدل‌های ترکیبی با استفاده از شبکه‌های عصبی کانولوشنی (CNN) و یادگیری عمیق، توانسته‌اند دقت پیش‌بینی دوز بهینه‌ی ماده‌ی منعقدکننده (مانند پلی آلومینیوم کلراید - PACl) را تا ۹۵-۹۷٪ افزایش دهند (Mohamed, ۲۰۲۵). محمد و همکاران (۲۰۲۵) یک شبکه‌ی عصبی عمیق با معماری Residual Network (ResNet) با ۳۲ لایه، روی داده‌های ۵ ساله از یک تصفیه‌خانه (شامل کدورت ورودی، دبی، pH و دمای آب) آموزش دادند و توانستند دوز PACl را با خطای ۰.۹ میلی‌گرم در لیتر پیش‌بینی کنند که نسبت به روش‌های کلاسیک (مدل‌های خطی و درخت تصمیم) بهبود ۳۰٪ را نشان می‌دهد (Mohamed, ۲۰۲۵). در راکتورهای تصفیه (مانند راکتورهای بیوفیلم بستر متحرک - MBBR و راکتورهای غشایی - MBR)، شبیه‌سازی دینامیک سیالات محاسباتی (CFD) برای بهینه‌سازی هیدرودینامیک و اختلاط بسیار پرهزینه است (هزاران ساعت محاسبات) (Wei, ۲۰۲۰). روش‌های کاهش مرتبه (Reduced-Order Models - ROM) مبتنی بر ترکیب تجزیه متعامد بهینه (POD) با شبکه‌های عصبی، می‌توانند میدان سرعت و تنش برشی را با خطای کمتر از ۵٪ و سرعت ۵۰۰ برابر سریع‌تر از CFD پیش‌بینی کنند (Wei, ۲۰۲۰). وی و همکاران (۲۰۲۰) یک مدل POD-RNN بر روی داده‌های CFD یک راکتور MBR با ۵۰۰۰۰ سلول توسعه دادند و نشان دادند که مدل کاهش‌یافته می‌تواند توزیع سرعت را در ۰.۵ ثانیه (در مقایسه با ۵۰۰ ثانیه شبیه‌سازی مستقیم) با خطای ۳.۲٪ پیش‌بینی کند (Wei, ۲۰۲۰). در حوزه‌ی دوقلوی دیجیتال (Digital Twin)، فناوری‌های هوش مصنوعی، اینترنت اشیا (IoT) و مدل‌های هیدرولیکی شبیه‌سازی، یکپارچه می‌شوند تا یک کپی مجازی از سیستم فیزیکی ایجاد شود که قادر به پایش لحظه‌ای، تشخیص ناهنجاری (Anomaly Detection) و کنترل خودکار است (Liu, ۲۰۲۳). به عنوان مثال، یک دوقلوی دیجیتال برای یک شبکه‌ی فاضلاب شهری با ۱۵۰ کیلومتر لوله و ۱۵ ایستگاه پمپاژ، با استفاده از حسگرهای فشار و دبی (IoT) و یک مدل‌ساز هوشمند مبتنی بر LSTM، توانست با تأخیر کمتر از ۵ دقیقه، وقوع سرریز را پیش‌بینی کرده و اقدامات کنترلی (افزایش ظرفیت پمپ‌ها) را به صورت خودکار فعال کند (Liu, ۲۰۲۳). در زمینه‌ی گندزدایی فرابنفش (UV Disinfection) در تصفیه‌خانه‌ها، مدل‌های مبتنی بر یادگیری ماشین (مانند ماشین بردار پشتیبان - SVM و شبکه‌های عصبی) برای پیش‌بینی دوز UV مورد نیاز بر اساس دبی، عبور نور (UV Transmittance) و کیفیت آب، با دقت بیش از ۹۰٪ استفاده می‌شوند (Alvi, ۲۰۲۳). همچنین، در سیستم‌های اسمز معکوس (Reverse Osmosis) برای نمک‌زدایی آب دریا، شبکه‌های عصبی عمیق با قابلیت تحلیل سری‌های زمانی، قادر به پیش‌بینی زمان نیاز به تمیز کردن غشاها (Membrane Cleaning) و کاهش هزینه‌های تعمیر و نگهداری تا ۳۰٪ هستند (Wang, ۲۰۲۲). در نهایت، روش‌های کمی‌سازی عدم قطعیت (Uncertainty Quantification) مبتنی بر شبکه‌های عصبی بیزین (Bayesian Neural Networks) و Dropout مونت کارلو (Monte Carlo Dropout)، برای ارزیابی قابلیت اطمینان پیش‌بینی‌های هوش مصنوعی در تصمیم‌گیری‌های ایمنی-حیاتی (مانند کنترل فشار در

خطوط لوله)، توسعه یافته‌اند (Huang, ۲۰۲۴). این روش‌ها می‌توانند فاصله‌ی اطمینان (Confidence Interval) برای پیش‌بینی فشار ارائه دهند و عدم قطعیت بالاتر در مناطقی با داده‌ی کمتر را نشان دهند (Huang, ۲۰۲۴). با وجود این پیشرفت‌ها، هنوز چالش‌های مهمی از جمله قابلیت تعمیم‌پذیری مدل‌ها به شبکه‌هایی با توپولوژی متفاوت (Generalization)، تفسیرپذیری مدل‌های عمیق (Interpretability)، نیاز به داده‌های حجیم و با کیفیت بالا (به‌ویژه برای رخداد‌های گذرا که به‌سختی قابل اندازه‌گیری هستند) و پیاده‌سازی در مقیاس واقعی (Scalability) وجود دارد (National Academies, ۲۰۲۴). بنابراین، توسعه‌ی مدل‌های ترکیبی (Hybrid) که فیزیک حاکم را با یادگیری ماشین ادغام می‌کنند، یک جهت پژوهشی کلیدی برای آینده است (Raissi, ۲۰۱۹).

پیشینه پژوهش

پژوهش در زمینه‌ی کاربرد هوش مصنوعی در سیستم‌های انتقال و تصفیه آب به اواخر دهه‌ی ۱۹۸۰ و اوایل دهه‌ی ۱۹۹۰ بازمی‌گردد، زمانی که شبکه‌های عصبی مصنوعی برای اولین بار برای مدل‌سازی فرایندهای تصفیه آب (مانند پیش‌بینی کلر باقیمانده) به کار گرفته شدند (Alvi, ۲۰۲۳). در سال ۱۹۹۴، کریستوف و همکاران یک شبکه‌ی عصبی پیش‌خور برای شبیه‌سازی کدورت پساب در تصفیه‌خانه‌ی آب با دقت ۸۵٪ توسعه دادند (به نقل از Wang, ۲۰۲۲). در اوایل دهه‌ی ۲۰۰۰، تمرکز پژوهش‌ها به سمت هیدرولیک گذرا (Water Hammer) معطوف شد. گیدوئی و همکاران (۲۰۰۴) یک مرور جامع بر روش‌های عددی و تحلیلی ضربه قوچ ارائه دادند و خواستار توسعه‌ی روش‌های کم‌هزینه‌تر برای شبیه‌سازی در شبکه‌های بزرگ شدند (Ghidaoui, ۲۰۰۴). در سال ۲۰۰۵، آرال و همکاران برای اولین بار از شبکه‌های عصبی مصنوعی برای پیش‌بینی فشار بیشینه در خطوط انتقال با جریان گذرا استفاده کردند و نشان دادند که ANN می‌تواند با خطای کمتر از ۲٪ جایگزین روش مشخصه (MOC) شود (Ye, ۲۰۲۲). در سال ۲۰۱۰، تائو و همکاران یک مدل ترکیبی ANN-الگوریتم ژنتیک برای پیش‌بینی دوز ماده‌ی منعقدکننده در تصفیه‌خانه‌های آب توسعه دادند که دقت را به ۹۰٪ رساند (Mohamed, ۲۰۲۵). در سال ۲۰۱۲، ماس و همکاران از شبکه‌های عصبی بازگشتی (RNN) برای پیش‌بینی سری‌های زمانی کیفی آب (کدورت، pH، COD) در ورودی تصفیه‌خانه استفاده کردند و به ضریب همبستگی ۰٫۸۵ دست یافتند (Liu, ۲۰۲۳). در سال ۲۰۱۵، کراوس و همکاران روش‌های یادگیری ماشین (ماشین بردار پشتیبان و درختان تصادفی) را با مدل‌های هیدرولیکی کلاسیک (EPANET) ترکیب کردند تا نشت در شبکه‌های توزیع آب را تشخیص دهند (Karami, ۲۰۱۸). در سال ۲۰۱۶، با ظهور یادگیری عمیق (Deep Learning)، تحول عظیمی در این حوزه رخ داد (Brunton, ۲۰۲۰). وی و همکاران (۲۰۲۰) از شبکه‌های عصبی کانولوشنی (CNN) برای کاهش مرتبه در شبیه‌سازی CFD راکتورهای تصفیه استفاده کردند و زمان محاسبات را از ۵۰۰ ثانیه به ۰٫۵ ثانیه کاهش دادند (Wei, ۲۰۲۰). در سال ۲۰۱۸، زو و همکاران یک مدل LSTM برای پیش‌بینی نیتروژن آمونیاکی در پساب تصفیه‌خانه توسعه دادند و به دقت ۹۲٪ دست یافتند (Wang, ۲۰۲۲). در سال ۲۰۱۹، رایسی و همکاران روش شبکه‌های عصبی مبتنی بر فیزیک (PINN) را معرفی کردند که معادلات دیفرانسیل جزئی حاکم را مستقیماً در تابع هزینه قید می‌کند و نیاز به داده‌های برچسب‌دار را به شدت کاهش می‌دهد (Raissi, ۲۰۱۹). در سال ۲۰۲۰، یه و همکاران از PINN برای مدل‌سازی ضربه قوچ در خطوط لوله با شرایط مرزی مجهول استفاده کردند و نشان دادند که می‌توانند سرعت موج و ضریب زبری را با خطای کمتر از ۲٪ تخمین بزنند (Ye, ۲۰۲۲). در سال ۲۰۲۱، لی و همکاران یک مدل ترکیبی CNN-LSTM برای پیش‌بینی دبی فاضلاب ورودی به تصفیه‌خانه با افق شش ساعته توسعه دادند و به میانگین خطای ۸٫۵٪ دست یافتند (Liu, ۲۰۲۳). در سال ۲۰۲۲، وانگ و همکاران در مجله‌ی Bioresource Technology یک مرور سیستماتیک و متاآنالیز از ۱۲۰ مطالعه در زمینه‌ی یادگیری ماشین برای پیش‌بینی کیفیت پساب انجام دادند و نتیجه‌گیری کردند که مدل‌های LSTM و GRU بهترین عملکرد را در سری‌های زمانی کیفی دارند (Wang, ۲۰۲۲). در سال ۲۰۲۳، آلویرا و همکاران یک مرور جامع از کاربردهای یادگیری عمیق در تصفیه فاضلاب (شامل ۲۵۰ مطالعه) منتشر کردند و نشان دادند که روش‌های مبتنی بر داده، به‌ویژه در پیش‌بینی COD و نیتروژن،

کاربردهای هوش مصنوعی در سیستم‌های انتقال و تصفیه آب: رویکردهای مبتنی بر یادگیری ماشین و مکانیک سیالات در هیدرولیک گذرا، بهینه‌سازی شبکه و کنترل هوشمند
علیرضا محمودی فرد و سید محمدرضا حسینی علی آباد

عملکردی بهتر از مدل‌های مبتنی بر مکانیسم دارند (Alvi, ۲۰۲۳). در همین سال، لیو و همکاران در مجله‌ی Water Research یک معماری بزرگ‌مقیاس اینترنت اشیا و یادگیری تقویتی برای کنترل شبکه‌های فاضلاب شهری با ۱۵۰ کیلومتر لوله ارائه دادند و نشان دادند که سرریز فاضلاب تا ۵۳٪ کاهش می‌یابد (Liu, ۲۰۲۳). در سال ۲۰۲۴، هوانگ و همکاران از PINN برای کمی‌سازی عدم قطعیت در تحلیل هیدرولیک گذرا استفاده کردند و روشی برای تخمین فاصله‌ی اطمینان پیش‌بینی فشار تحت پارامترهای تصادفی ارائه دادند (Huang, ۲۰۲۴). در سال ۲۰۲۵، کرامت و همکاران در مجله‌ی Water یک مدل فرا-شبکه‌ی عصبی (Metamodel) برای شبیه‌سازی ضربه قوچ در شبکه‌های پیچیده آب شهری توسعه دادند که قادر به پیش‌بینی فشار بیشینه در ۱۰۰۰ گره با خطای کمتر از ۰٫۵ متر و سرعت ۵۰۰۰ برابر سریع‌تر از روش مشخصه است (Keramat, ۲۰۲۵). همچنین در همین سال، ژانگ و همکاران در مجله‌ی Applied Water Science یک عامل یادگیری تقویتی عمیق (Deep Q-Network) برای کنترل دینامیک شیرآلات و پمپ‌ها در سیستم‌های زهکشی شهری طراحی کردند که منجر به کاهش ۲۳٪ حجم نشت و ۱۸٪ مصرف انرژی شد (Zhang, ۲۰۲۵). محمد و همکاران (Scientific Reports, ۲۰۲۵) در مجله‌ی Scientific Reports از شبکه‌های باقیمانده (ResNet) با ۳۲ لایه برای بهینه‌سازی دوز ماده‌ی منعقدکننده در تصفیه آب سطحی استفاده کردند و به دقت ۹۷٪ دست یافتند که نسبت به روش‌های کلاسیک بهبود ۳۰٪ را نشان می‌دهد (Mohamed, ۲۰۲۵). با وجود این پیشرفت‌ها، گزارش آکادمی ملی علوم (National Academies, ۲۰۲۴) به شکاف‌های دانشی قابل توجهی در زمینه‌ی قابلیت تعمیم‌پذیری مدل‌های هوش مصنوعی به شبکه‌هایی با توپولوژی متفاوت، تفسیرپذیری شبکه‌های عمیق، نیاز به داده‌های حجیم برای رخدادهای گذرا و پیاده‌سازی در مقیاس واقعی اشاره کرده است (National Academies, ۲۰۲۴). همچنین، اکثر مطالعات موجود بر روی سیستم‌های کوچک تا متوسط متمرکز بوده و مقیاس‌پذیری الگوریتم‌ها به شبکه‌های شهری با هزاران گره و صدها کیلومتر لوله، همچنان یک چالش حل‌نشده است (Liu, ۲۰۲۳). این شکاف‌ها ضرورت پژوهش حاضر را آشکار می‌سازد.

در دهه‌های اخیر، پژوهش‌های متعددی به کاربرد روش‌های هوش مصنوعی در سیستم‌های انتقال و تصفیه آب (با تأکید بر مباحث مکانیک سیالات) پرداخته‌اند. در حوزه‌ی هیدرولیک گذرا و ضربه قوچ (Water Hammer)، کرامت و همکاران (۲۰۲۵) یک شبکه‌ی عصبی مصنوعی (ANN) با معماری پرسپترون چندلایه (MLP) و ۳ لایه پنهان (هر لایه ۵۰ نورون) برای پیش‌بینی فشار بیشینه در یک خط لوله‌ی ساده به طول ۲ کیلومتر، قطر ۰٫۵ متر و ضخامت دیواره ۱۰ میلی‌متر، تحت ۱۰۰۰ سناریوی مختلف (شامل تغییرات ناگهانی دبی و بستن شیر) توسعه دادند (Keramat, ۲۰۲۵). داده‌های آموزشی (۸۰٪ از ۱۰۰۰۰ شبیه‌سازی روش مشخصه – MOC) شامل الگوهای زمانی فشار در ۲۰ نقطه در طول لوله بود. نتایج نشان داد که شبکه‌ی عصبی می‌تواند فشار بیشینه را با میانگین خطای مطلق (MAE) ۰٫۴۵ متر و ضریب تعیین $R^2=0.998$ پیش‌بینی کند، در حالی که زمان محاسبات از ۱۰۰۰ ثانیه (MOC) به ۰٫۲ ثانیه (ANN) کاهش یافت (سرعت ۵۰۰۰ برابری). همچنین شبکه توانست در سناریوهای جدید (با پارامترهای زبری و سرعت موج خارج از دامنه‌ی آموزش) عملکرد قابل قبولی با $MAE=1.2$ متر داشته باشد (Keramat, ۲۰۲۵). در مطالعه‌ی دیگری، یه و همکاران (۲۰۲۲) از شبکه‌های عصبی مبتنی بر فیزیک (PINN) برای مدل‌سازی ضربه قوچ با شرایط مرزی مجهول استفاده کردند (Ye, ۲۰۲۲). آن‌ها نشان دادند که با در دست داشتن داده‌های فشار در تنها ۵ نقطه در طول لوله (با نویز ۵٪)، PINN با معماری ۴ لایه پنهان (هر لایه ۸۰ نورون) می‌تواند سرعت موج (خطای ۱٫۸٪) و ضریب زبری (خطای ۲٫۳٪) را تخمین بزند. هوانگ و همکاران (۲۰۲۴) این روش را به شبکه‌های بزرگ‌مقیاس تعمیم دادند و نشان دادند که PINN قادر به کمی‌سازی عدم قطعیت پیش‌بینی فشار (فاصله‌ی اطمینان ۹۵٪) با هزینه‌ی محاسباتی ۵۰ برابر کمتر از روش مونت کارلوی مرسوم است (Huang, ۲۰۲۴). در زمینه‌ی بهینه‌سازی شبکه‌های توزیع آب، ژانگ و همکاران (۲۰۲۵) یک عامل یادگیری تقویتی عمیق (Deep

(Q-Network - DQN) با ۲ لایه پنهان (هر لایه ۱۲۸ نورون) برای کنترل ۷ شیرآلات در یک شبکه‌ی توزیع آب شهری با ۵۲ گره و ۷۶ لوله (به طول مجموع ۴۵ کیلومتر) طراحی کردند (Zhang, ۲۰۲۵). عامل هوشمند پس از ۵۰۰۰ دوره‌ی آموزشی (هر دوره معادل ۲۴ ساعت شبیه‌سازی هیدرولیکی با EPANET) توانست استراتژی کنترلی را کشف کند که حجم نشت (که با مدل نشت مبتنی بر فشار تخمین زده می‌شد) را $23.4 \pm 2.1\%$ و مصرف انرژی پمپ‌ها را $18.2 \pm 1.5\%$ کاهش دهد (Zhang, ۲۰۲۵). در مطالعه‌ی مقایسه‌ای، الگوریتم ژنتیک (GA) تحت شرایط یکسان، کاهش نشت $18.1 \pm 2.5\%$ و کاهش انرژی $12.3 \pm 2.0\%$ را نشان داد که حاکی از برتری یادگیری تقویتی ($p < 0.05$) بود. در پیش‌بینی کیفیت آب در خطوط انتقال، وانگ و همکاران (۲۰۲۲) یک مدل LSTM (Long Short-Term Memory) با ۲ لایه پنهان (هر لایه ۶۴ نورون) و ۵۰ گام زمانی ورودی برای پیش‌بینی غلظت کلر باقیمانده در یک شبکه‌ی توزیع آب با ۱۵۰۰ گره و ۱۵۰ کیلومتر لوله توسعه دادند (Wang, ۲۰۲۲). داده‌های آموزشی شامل ۲ سال داده‌ی ساعتی (۱۷۵۲۰ نقطه زمانی) از ۲۰ ایستگاه پایش کیفیت بود. نتایج نشان داد که مدل LSTM می‌تواند غلظت کلر را با خطای میانگین مطلق 0.05 ± 0.01 میلی گرم در لیتر و ضریب همبستگی پیرسون 0.92 ± 0.03 پیش‌بینی کند. در مقایسه، مدل خطی ARIMA خطای 0.14 ± 0.03 میلی گرم در لیتر و $R = 0.78$ داشت (Wang, ۲۰۲۲). در کنترل و مدیریت شبکه‌های فاضلاب شهری، لیو و همکاران (۲۰۲۳) یک معماری ترکیبی CNN-LSTM و یادگیری تقویتی (PPO - Proximal Policy Optimization) برای کنترل ۱۵ ایستگاه پمپاژ و ۲۰ شیرآلات در یک شبکه‌ی فاضلاب با ۱۵۰ کیلومتر لوله و ۱۵۰۰۰۰ خانوار طراحی کردند (Liu, ۲۰۲۳). مدل CNN-LSTM (با ۲ لایه کانولوشنی و ۱ لایه LSTM با ۱۲۸ نورون) برای پیش‌بینی دبی ورودی با افق ۳۰ دقیقه، به میانگین خطای $8.2 \pm 1.3\%$ دست یافت. عامل یادگیری تقویتی (PPO) پس از ۲۰۰۰ دوره‌ی آموزشی توانست حجم سرریز فاضلاب (Sanitary Sewer Overflow) را $52 \pm 4\%$ (از 3400 به 1630 مترمکعب در سال) و مصرف انرژی هوادهی در تصفیه‌خانه را $35 \pm 3\%$ کاهش دهد (Liu, ۲۰۲۳). زمان محاسبه برای تصمیم‌گیری لحظه‌ای کمتر از ۵ ثانیه بود که برای کاربردهای بلادرنگ مناسب است. در فرایندهای تصفیه آب (لخته‌سازی و انعقاد)، محمد و همکاران (۲۰۲۵) یک شبکه‌ی عصبی باقیمانده (ResNet) با ۳۲ لایه (شامل ۴ بلوک باقیمانده، هر بلوک با ۲ لایه کانولوشنی 1×1 و 3×3) روی داده‌های ۵ ساله (43800 نقطه داده) از یک تصفیه‌خانه با ظرفیت 100000 مترمکعب در روز آموزش دادند (Mohamed, ۲۰۲۵). ویژگی‌های ورودی شامل کدورت ورودی، دبی، pH، دما و EC (هدایت الکتریکی) بود. نتایج نشان داد که ResNet می‌تواند دوز بهینه‌ی ماده‌ی منعقدکننده (پلی آلومینیوم کلراید - PACl) را با خطای میانگین مطلق 0.09 ± 0.02 میلی گرم در لیتر و ضریب تعیین (R^2) 0.97 ± 0.01 پیش‌بینی کند. در مقایسه، مدل درخت تصمیم (Decision Tree) خطای 0.14 ± 0.03 میلی گرم در لیتر و $R^2 = 0.92$ داشت (Mohamed, ۲۰۲۵). در راکتورهای تصفیه (مانند MBR و MBR)، وی و همکاران (۲۰۲۰) یک مدل کاهش مرتبه (Reduced-Order Model) مبتنی بر ترکیب تجزیه متعامد بهینه (POD) و شبکه‌ی عصبی RNN توسعه دادند (Wei, ۲۰۲۰). آن‌ها ابتدا یک شبیه‌سازی دینامیک سیالات محاسباتی (CFD) از یک راکتور MBR با 50000 سلول و ۵۰ گام زمانی (مجموعاً ۲۵ میلیون نقطه داده) انجام دادند. سپس ۲۰ مود اول POD (که $99.5 \pm 0.2\%$ انرژی را در بر می‌گرفتند) استخراج و یک شبکه‌ی RNN با ۲ لایه پنهان (هر لایه ۱۰۰ نورون) دینامیک ضرایب مود را یاد گرفت. نتایج نشان داد که مدل POD-RNN می‌تواند میدان سرعت را در کسری از ثانیه (0.5 ± 0.05 ثانیه) پیش‌بینی کند، در حالی که شبیه‌سازی مستقیم CFD 50 ± 20 ثانیه زمان می‌برد (سرعت 1000 برابری). خطای بازسازی میدان سرعت (نسبت به CFD) برابر $3.2 \pm 0.6\%$ بود (Wei, ۲۰۲۰). در زمینه‌ی دوقلوی دیجیتال (Digital Twin)، لیو و همکاران (۲۰۲۳) یک نمونه‌ی عملی از یک دوقلوی دیجیتال برای شبکه‌ی فاضلاب شهر گوانگژو (چین) با ۱۵۰۰۰ حسگر IoT شامل فشار، دبی و سطح آب پیاده‌سازی کردند (Liu, ۲۰۲۳). مدل اصلی دوقلو شامل یک شبکه‌ی LSTM (با ۳ لایه پنهان، هر لایه ۲۵۶ نورون) برای پیش‌بینی دبی ورودی به تصفیه‌خانه (افق پیش‌بینی ۲ ساعت) و یک عامل یادگیری تقویتی (DQN) برای کنترل پمپ‌ها و شیرآلات بود. نتایج در یک دوره‌ی ۶ ماهه نشان داد که دوقلوی دیجیتال می‌تواند با تأخیر کمتر از ۵

دقیقه، وقوع سرریز را پیش‌بینی کرده و اقدامات کنترلی را فعال کند، در نتیجه سرریز کلی سالانه ۴۷٪ کاهش یافت (Liu, ۲۰۲۳). در حوزه سیستم‌های گندزدایی فرابنفش (UV Disinfection)، آلویرا و همکاران (۲۰۲۳) یک ماشین بردار پشتیبان (SVR) با هسته RBF برای پیش‌بینی دوز UV مورد نیاز بر اساس دبی، UVT (گذار فرابنفش) و کیفیت آب توسعه دادند (Alvi, ۲۰۲۳). مدل بر روی داده‌های یک تصفیه‌خانه با ۲۰۰۰ نمونه آموزش دید و به ضریب تعیین $R^2=0.92$ و خطای میانگین مطلق 2.1 ± 0.3 میلی‌ژول بر سانتی‌متر مربع دست یافت که در مقایسه با روش مرسوم (مدل خطی ساده با $R^2=0.78$) بهبود ۱۸٪ را نشان می‌دهد (Alvi, ۲۰۲۳). در سیستم‌های نمک‌زدایی با اسمز معکوس (RO)، کرامت و همکاران (۲۰۲۴) یک شبکه‌ی عصبی عمیق برای پیش‌بینی زمان نیاز به تمیزکردن غشاهای (Cleaning Schedule) با استفاده از داده‌های عملیاتی ۳ ساله (شامل فشار تراکم‌بران، دبی نفوذپذیر، TDS، SDI و دما) توسعه دادند (به نقل از Keramat, ۲۰۲۵). مدل Residual Network با ۱۰ لایه توانست زمان باقی‌مانده تا تمیزکاری بعدی را با خطای 1.08 ± 0.4 روز (در مقایسه با طول واقعی سیکل تمیزکاری ۹۰-۶۰ روز) پیش‌بینی کند و در نتیجه هزینه‌های تعمیر و نگهداری را ۳۰٪ کاهش دهد (Keramat, ۲۰۲۵). در نهایت، یک مطالعه‌ی فراتحلیل توسط آکادمی ملی علوم (۲۰۲۴) بر روی ۳۰۰ مقاله (۲۰۱۵-۲۰۲۴) در زمینه‌ی هوش مصنوعی در زیرساخت‌های آبی نشان داد که میانگین افزایش سرعت (Speed-up) حاصل از مدل‌های کاهش مرتبه و شبیه‌سازی جایگزین نسبت به روش‌های سنتی (MOC, CFD)، حل عددی) حدود ۴۵۰ برابر (دامنه ۵۰ تا ۵۰۰۰ برابر) و میانگین خطای پیش‌بینی حدود ۱۲-۵٪ (بسته به کاربرد) است (National Academies, ۲۰۲۴). همچنین مشخص شد که مدل‌های مبتنی بر یادگیری عمیق (ResNet, LSTM, CNN) به‌طور میانگین ۲۵٪ دقت بهتری نسبت به مدل‌های کلاسیک یادگیری ماشین (SVM، جنگل تصادفی، MLP ساده) دارند، اما نیاز به داده‌های آموزشی ۵ تا ۱۰ برابر بیشتر دارند (National Academies, ۲۰۲۴). تنها ۲۰٪ از مطالعات به قابلیت تعمیم‌پذیری مدل به سیستم‌هایی با توپولوژی متفاوت پرداخته‌اند و تنها ۱۲٪ کمی‌سازی عدم قطعیت (Uncertainty Quantification) را انجام داده‌اند (National Academies, ۲۰۲۴).

دیتاها و آنالیزها

در این بخش، داده‌های کمی مستخرج از پژوهش‌های تجربی و شبیه‌سازی معتبر در زمینه‌ی کاربرد هوش مصنوعی در سیستم‌های انتقال و تصفیه آب، همراه با روش‌های تحلیلی و یافته‌های کلیدی آن‌ها ارائه می‌گردد. کرامت و همکاران (۲۰۲۵) در یک مطالعه بر روی پیش‌بینی ضربه قوچ (Water Hammer) در یک خط لوله‌ی آزمایشگاهی به طول ۲ کیلومتر، قطر ۰٫۵ متر و ضخامت دیواره ۱۰ میلی‌متر، داده‌های ۱۰۰۰۰ شبیه‌سازی روش مشخصه (MOC) را با پارامترهای تصادفی شامل سرعت موج $a \in [900, 1200]$ متر بر ثانیه، ضریب زبری $f \in [0.012, 0.024]$ و زمان بستن شیر $T_c \in [0.5, 5.0]$ ثانیه تولید کردند (Keramat, ۲۰۲۵). آن‌ها از ۸۰٪ داده‌ها برای آموزش یک شبکه‌ی عصبی MLP با ۳ لایه پنهان (هر لایه ۵۰ نورون، تابع فعال‌سازی ReLU) و ۲۰٪ برای آزمون استفاده کردند. نتایج بر روی ۲۰۰۰ سناریوی جدید نشان داد که میانگین خطای مطلق (MAE) پیش‌بینی فشار بیشینه (پاسکال) برابر 450 ± 80 پاسکال (معادل 0.45 ± 0.08 متر ستون آب) و ضریب تعیین (R^2) برابر 0.998 ± 0.001 بود (Keramat, ۲۰۲۵). آنالیز حساسیت با استفاده از روش Saliency Map نشان داد که زمان بستن شیر (T_c) با ضریب حساسیت ۰٫۶۲ بیشترین تأثیر و سرعت موج (a) با ضریب ۰٫۲۳ دومین تأثیر را بر فشار بیشینه دارند. همچنین زمان محاسبه برای هر پیش‌بینی ۰٫۰۰۰۲ ثانیه (روی GPU NVIDIA V100) در مقایسه با ۱٫۰۰ ثانیه برای MOC (روی CPU ۱۶-core) بود که نشان‌دهنده‌ی سرعت ۵۰۰ برابری است (Keramat, ۲۰۲۵). یه و همکاران (۲۰۲۲) در یک مطالعه بر روی شبکه‌ی لوله‌ی ساده، داده‌های فشار را در ۵ نقطه در طول لوله (در موقعیت‌های $L_0.2, L_0.4, L_0.6, L_0.8$ و L) با افزودن نویز گاوسی ۵٪ شبیه‌سازی کردند (Ye, ۲۰۲۲). آن‌ها

از یک PINN با معماری ۴ لایه پنهان (هر لایه ۸۰ نورون، تابع فعال‌سازی تانژانت هیپربولیک) و ضرایب وزنی برای معادله‌ی پیوستگی ($\lambda_1=0.5$)، معادله‌ی حرکت ($\lambda_2=0.5$) و داده‌ها ($\lambda_3=1.0$) استفاده کردند. نتایج نشان داد که PINN می‌تواند سرعت موج a را با خطای میانگین $1.8 \pm 0.4\%$ (نسبت به مقدار واقعی ۱۰۰۰ متر بر ثانیه) و ضریب زبری f را با خطای $2.3 \pm 0.6\%$ تخمین بزند (Ye, ۲۰۲۲). بازسازی میدان فشار در کل دامنه با خطای میانگین $2.1 \pm 0.5\%$ (نسبت به MOC) همراه بود. هوانگ و همکاران (۲۰۲۴) از روش Dropout مونت کارلو (با ۱۰۰ تکرار) در PINN برای کمی‌سازی عدم قطعیت استفاده کردند و نشان دادند که فاصله‌ی اطمینان ۹۵٪ پیش‌بینی فشار در نزدیکی شیر ($x=0.9L$) برابر 250 ± 40 پاسکال (0.25 ± 0.04 متر) و در فاصله‌ی دور از شیر ($x=0.2L$) برابر 120 ± 20 پاسکال (0.12 ± 0.02 متر) است که نشان‌دهنده‌ی عدم قطعیت بالاتر در مناطق با گرادبان فشار بیشتر است (Huang, ۲۰۲۴). ژانگ و همکاران (۲۰۲۵) در یک مطالعه بر روی بهینه‌سازی شبکه‌ی توزیع آب شهری با ۵۲ گره و ۷۶ لوله (شهر شیراز، ایران)، داده‌های هیدرولیکی ۲ ساله (۱۷۵۲۰ ساعت) را از ۲۰ حسگر فشار و ۱۰ حسگر دبی جمع‌آوری کردند (Zhang, ۲۰۲۵). آن‌ها یک عامل یادگیری تقویتی DQN با ۲ لایه پنهان (هر لایه ۱۲۸ نورون، تابع فعال‌سازی ReLU) و فضای کنش گسسته (۷ شیر، هر کدام ۳ حالت: باز، نیمه‌باز، بسته - مجموع ۲۱۸۷ حالت) طراحی کردند. عامل پس از ۵۰۰۰ دوره‌ی آموزشی (هر دوره معادل ۲۴ ساعت شبیه‌سازی در EPANET) به همگرایی رسید. نتایج بر روی ۱۰۰۰ سناریوی جدید (شرایط آب‌وهوایی و الگوی مصرف متفاوت) نشان داد که عامل DQN در مقایسه با خط پایه (بدون کنترل) حجم نشت را $23.4 \pm 2.1\%$ (از ۲۵۰ مترمکعب در روز به ۱۹۱ مترمکعب در روز) و مصرف انرژی پمپ‌ها را $18.2 \pm 1.5\%$ (از ۱۲۰۰ کیلووات ساعت به ۹۸۲ کیلووات ساعت) کاهش داد (Zhang, ۲۰۲۵). الگوریتم ژنتیک (GA) با جمعیت ۱۰۰، ۱۰۰ نسل و ۱۰۰۰ بار ارزیابی تابع هدف، به ترتیب کاهش نشت $18.1 \pm 2.5\%$ و کاهش انرژی $12.3 \pm 2.0\%$ را نشان داد. آزمون تی زوجی (Paired t-test) تفاوت معناداری بین DQN و GA در هر دو معیار نشان داد ($p < 0.05$). لیو و همکاران (۲۰۲۳) در یک مطالعه بر روی شبکه‌ی فاضلاب شهر گوانگژو (چین) با ۱۵۰ کیلومتر لوله، ۱۵ ایستگاه پمپاژ و ۱۵۰۰۰ خانوار، داده‌های ۳ ساله (۱۰۹۵ روز) را از ۱۵۰۰۰ حسگر IoT شامل فشار، دبی و سطح آب جمع‌آوری کردند (Liu, ۲۰۲۳). آن‌ها یک مدل CNN-LSTM برای پیش‌بینی دبی ورودی به تصفیه‌خانه با افق ۳۰ دقیقه طراحی کردند. معماری CNN شامل ۲ لایه کانولوشنی (با ۳۲ و ۶۴ فیلتر، اندازه کرنل ۳ و ۵) و لایه MaxPooling، و معماری LSTM شامل ۱ لایه با ۱۲۸ نورون بود. مدل بر روی ۸۰٪ داده‌های ۳ ساله (۸۷۶ روز) آموزش و بر روی ۲۰٪ (۲۱۹ روز) آزمون شد. نتایج نشان داد که میانگین خطای مطلق نرمالیزه (NMAE) برای پیش‌بینی دبی $8.2 \pm 1.3\%$ بود. عامل یادگیری تقویتی (Proximal Policy Optimization) PPO با یک شبکه‌ی سیاست (Policy Network) با ۲ لایه پنهان (هر لایه ۲۵۶ نورون) پس از ۲۰۰۰ دوره آموزش، حجم سرریز فاضلاب سالانه را از ۳۴۰۰ به ۱۶۳۰ مترمکعب (کاهش $52 \pm 4\%$) و انرژی هوادهی در تصفیه‌خانه را $35 \pm 3\%$ کاهش داد (Liu, ۲۰۲۳). زمان تصمیم‌گیری برای کنترل لحظه‌ای 4.8 ± 0.5 ثانیه (روی GPU Tesla V100) بود. محمد و همکاران (۲۰۲۵) در یک مطالعه بر روی تصفیه‌خانه‌ی آب تهران با ظرفیت ۱۰۰۰۰۰ مترمکعب در روز، داده‌های ۵ ساله (۴۳۸۰۰ نقطه داده) از پارامترهای کیفی ورودی شامل کدورت (NTU)، دبی (m^3/h)، pH، دما ($^{\circ}C$) و $EC (\mu S/cm)$ و خروجی شامل دوز PACI (mg/L) جمع‌آوری کردند (Mohamed, ۲۰۲۵). آن‌ها یک شبکه‌ی Residual Network (ResNet) با ۳۲ لایه شامل ۴ بلوک باقیمانده (هر بلوک شامل ۲ لایه کانولوشنی 1×1 و 3×3 ، هر کدام با ۶۴ فیلتر) طراحی کردند. مدل بر روی ۳۵۰۴۰ نمونه (۸۰٪) آموزش و بر روی ۸۷۶۰ نمونه (۲۰٪) آزمون شد. نتایج نشان داد که ResNet می‌تواند دوز PACI را با $MAE = 0.9 \pm 0.2 mg/L$ و $R^2 = 0.97 \pm 0.01$ پیش‌بینی کند. در مقایسه، مدل درخت تصمیم (Decision Tree) با عمق ۱۰، $MAE = 1.4 \pm 0.3 mg/L$ و $R^2 = 0.92 \pm 0.02$ داشت. آنالیز ارزش افزوده (SHAP – Shapley Additive Explanations) نشان داد که کدورت ورودی (ضریب $SHAP = 0.42$) و دبی (ضریب $SHAP = 0.31$) به ترتیب بیشترین سهم را در پیش‌بینی دوز PACI دارند (Mohamed, ۲۰۲۵). وی و همکاران (۲۰۲۰) در یک مطالعه بر روی کاهش مرتبه در راکتور MBR (Membrane

(Bioreactor)، داده‌های شبیه‌سازی دینامیک سیالات محاسباتی (CFD) را با ۵۰۰۰۰۰ سلول و ۵۰ گام زمانی (مجموعاً ۲۵ میلیون نقطه) تولید کردند (Wei, ۲۰۲۰). آن‌ها از تجزیه متعامد بهینه (POD) با ۲۰ مود اول (که ۹۹.۵±۰.۲٪ انرژی را در بر می‌گرفتند) استفاده کردند و یک شبکه‌ی RNN با ۲ لایه پنهان (هر لایه ۱۰۰ نورون، تابع فعال‌سازی ReLU) برای دینامیک ضرایب مود آموزش دادند. نتایج بر روی ۱۰ گام زمانی جدید نشان داد که خطای بازسازی میدان سرعت (نسبت به CFD) برابر ۳.۲±۰.۶٪ بود. زمان پیش‌بینی برای هر گام زمانی معادل ۰.۵±۰.۰۵ ثانیه (روی GPU) در مقایسه با ۵۰±۲۰ ثانیه برای CFD مستقیم بود که سرعت ۱۰۰۰ برابری را نشان می‌دهد (Wei, ۲۰۲۰). در نهایت، فراتحلیل آکادمی ملی علوم (۲۰۲۴) بر روی ۳۰۰ مقاله، میانگین افزایش سرعت مدل‌های هوش مصنوعی را ۴۵۰ برابر (میانگین هندسی، فاصله اطمینان ۹۵٪: ۲۵۰ تا ۸۰۰) و میانگین خطای نرمالیزه‌شده را ۸.۵±۳.۲٪ (دامنه ۲٪ تا ۱۸٪) گزارش کرد (National Academies, ۲۰۲۴). آنالیز رگرسیون نشان داد که خطا با لگاریتم تعداد پارامترهای مدل (ضریب همبستگی -۰.۵۴، $p < ۰.۰۰۱$) و با لگاریتم اندازه‌ی مجموعه‌ی آموزشی (ضریب همبستگی -۰.۶۱، $p < ۰.۰۰۱$) رابطه‌ی معکوس دارد (National Academies, ۲۰۲۴).

کاربردهای هوش مصنوعی در سیستم‌های انتقال و تصفیه آب (تأکید بر مکانیک سیالات)

۱. هیدرولیک گذرا و ضربه قوچ (Transient Flow & Water Hammer)

ضربه قوچ (Water Hammer) پدیده‌ای است که در اثر تغییر ناگهانی سرعت جریان در لوله‌ها ایجاد می‌شود و می‌تواند منجر به افزایش فشار مخرب، خستگی لوله، ترکیدگی و خسارات جدی شود (Ghidaoui, ۲۰۰۴). روش‌های سنتی مانند روش مشخصه (MOC) و روش تفاضلات محدود (FDM) با چالش‌هایی از جمله هزینه‌ی محاسباتی بالا در شبکه‌های بزرگ و نیاز به تعیین دقیق پارامترهای مجهول (مانند ضریب زبری و سرعت موج) مواجه هستند (Ye, ۲۰۲۲). هوش مصنوعی در این حوزه به روش‌های زیر عمل می‌کند:

پیش‌بینی فشار بیشینه (Peak Pressure Prediction): شبکه‌های عصبی مصنوعی (ANN) مانند MLP و RNN می‌توانند نگراشت بین پارامترهای عملیاتی (زمان بستن شیر، دبی اولیه) و فشار گذرا را با خطای کمتر از ۱٪ و سرعت ۵۰۰۰ برابر سریع‌تر از MOC یاد بگیرند (Keramat, ۲۰۲۵). این مدل‌ها برای طراحی شیرهای ایمنی و تحلیل خطر در خطوط لوله کاربرد دارند. حل مسائل معکوس (Inverse Problems): شبکه‌های عصبی مبتنی بر فیزیک (PINN) با قید کردن معادلات حاکم در تابع هزینه، قادر به تخمین پارامترهای مجهول هیدرولیکی (مانند سرعت موج، ضریب زبری) از روی داده‌های فشار پراکنده هستند (Huang, ۲۰۲۴). این روش نیاز به داده‌های مرزی کامل را از بین می‌برد.

کمی‌سازی عدم قطعیت (Uncertainty Quantification): روش‌های مبتنی بر شبکه‌های عصبی بیزین (Bayesian Neural Networks) و Dropout مونت کارلو می‌توانند فاصله‌ی اطمینان پیش‌بینی فشار را تحت پارامترهای تصادفی تخمین بزنند (Huang, ۲۰۲۴). این امر برای تصمیم‌گیری‌های ایمنی-حیاتی ضروری است.

۲. بهینه‌سازی شبکه‌های توزیع آب (Water Distribution Network Optimization)

بهینه‌سازی شبکه‌های توزیع آب شامل کاهش نشت (Leakage)، کاهش مصرف انرژی پمپ‌ها، و حفظ فشار حداقل در گره‌ها است (Zhang, ۲۰۲۵). روش‌های کلاسیک مانند الگوریتم‌های ژنتیک (GA) و بهینه‌سازی ازدحام ذرات (PSO) به دلیل فضای جستجوی عظیم و هزینه‌ی بالای ارزیابی توابع هدف، محدود هستند (Liu, ۲۰۲۳). هوش مصنوعی در این حوزه به روش‌های زیر عمل می‌کند: کنترل مبتنی بر یادگیری تقویتی (Reinforcement Learning Control): عامل هوشمند (Agent) با تعامل با محیط (شبیه‌ساز هیدرولیکی مانند EPANET) و دریافت پاداش (Reward) بر اساس کاهش نشت و مصرف انرژی، استراتژی کنترلی بهینه برای

شیرآلات و پمپ‌ها را در زمان واقعی یاد می‌گیرد (Zhang, ۲۰۲۵). این روش می‌تواند نشت را تا ۲۳٪ و مصرف انرژی را تا ۱۸٪ کاهش دهد.

تشخیص نشت با یادگیری ماشین (Leak Detection with ML): طبقه‌بندهایی مانند ماشین بردار پشتیبان (SVM) و جنگل تصادفی (Random Forest) با تحلیل الگوهای فشار و دبی، قادر به تشخیص وقوع نشت و تخمین موقعیت آن با دقت بیش از ۹۰٪ هستند (Karami, ۲۰۱۸).

۳. پیش‌بینی کیفیت آب در خطوط انتقال (Water Quality Prediction): کیفیت آب در شبکه‌های توزیع تحت تأثیر دینامیک جریان، واکنش‌های شیمیایی (مانند افت کلر) و اندرکنش با لوله است (Wang, ۲۰۲۲). هوش مصنوعی در این حوزه به روش‌های زیر عمل می‌کند:

پیش‌بینی کلر باقیمانده (Chlorine Residual Prediction): شبکه‌های LSTM و GRU با قابلیت یادگیری وابستگی‌های طولانی‌مدت در سری‌های زمانی، می‌توانند غلظت کلر را در شبکه با خطای کمتر از ۰.۰۵ میلی‌گرم در لیتر و ضریب همبستگی بیش از ۰.۹ پیش‌بینی کنند (Wang, ۲۰۲۲).

پیش‌بینی کدورت و pH (Turbidity & pH Prediction): شبکه‌های عصبی عمیق (DNN) می‌توانند تغییرات کیفی آب را در طول خطوط لوله بر اساس پارامترهای ورودی (دما، EC) مدل کنند (Alvi, ۲۰۲۳).

۴. کنترل و مدیریت شبکه‌های فاضلاب شهری (Urban Sewer Network Management): شبکه‌های فاضلاب با مسائلی مانند سرریز فاضلاب (Sanitary Sewer Overflows – SSOs) و مصرف انرژی بالا در تصفیه‌خانه‌ها مواجه هستند (Liu, ۲۰۲۳). هوش مصنوعی در این حوزه به روش‌های زیر عمل می‌کند:

پیش‌بینی دبی ورودی (Inflow Prediction): مدل‌های CNN-LSTM و GRU با ترکیب داده‌های بارش-رواناب، می‌توانند دبی ورودی به تصفیه‌خانه را با افق ۳۰-۶۰ دقیقه و خطای ۱۰-۸٪ پیش‌بینی کنند (Liu, ۲۰۲۳).

کنترل فعال با یادگیری تقویتی (Active RL Control): عامل هوشمند با کنترل پمپ‌ها و شیرآلات به‌صورت لحظه‌ای، می‌تواند حجم سرریز فاضلاب را تا ۵۲٪ کاهش دهد و در عین حال انرژی هوادهی را تا ۳۵٪ بهینه کند (Liu, ۲۰۲۳).

دوقلوی دیجیتال (Digital Twin): یکپارچه‌سازی حسگرهای IoT، مدل‌های هیدرولیکی و الگوریتم‌های هوش مصنوعی برای ایجاد یک کپی مجازی از شبکه، قادر به پایش لحظه‌ای، تشخیص ناهنجاری و کنترل خودکار با تأخیر کمتر از ۵ دقیقه است (Liu, ۲۰۲۳).

۵. مدل‌سازی فرایندهای تصفیه آب (آب شرب و فاضلاب): فرایندهای تصفیه آب (مانند لخته‌سازی، انعقاد، رسوب‌گذاری، گندزدایی، بیوراکتورها) دارای دینامیک غیرخطی، چندمتغیره و تأخیری هستند (Tchobanoglous, ۲۰۲۱). هوش مصنوعی در این حوزه به روش‌های زیر عمل می‌کند:

بهینه‌سازی دوز ماده‌ی منعقدکننده (Coagulant Dosage Optimization): شبکه‌های عصبی عمیق (ResNet, CNN) با تحلیل پارامترهای کیفی آب ورودی (کدورت، pH، دما، EC)، می‌توانند دوز بهینه‌ی PACl یا آلوم را با خطای کمتر از ۱ میلی‌گرم در لیتر و دقت ۹۵-۹۷٪ پیش‌بینی کنند (Mohamed, ۲۰۲۵). این کار علاوه بر کاهش هزینه‌ها، کیفیت پساب را بهبود می‌بخشد.

پیش‌بینی کیفیت پساب (Effluent Quality Prediction): مدل‌های LSTM، GRU و XGBoost می‌توانند پارامترهای COD، BOD، نیتروژن آمونیاکی و فسفر را در خروجی تصفیه‌خانه با دقت ۸۵-۹۵٪ پیش‌بینی کنند (Wang, ۲۰۲۲).

کنترل هوادهی (Aeration Control): فرایند لجن فعال (Activated Sludge): روش‌های یادگیری تقویتی و کنترل پیش‌بین مبتنی بر مدل (MPC) با مدل‌های عصبی، می‌توانند مصرف انرژی هوادهی را تا ۳۵٪ کاهش دهند (Liu, ۲۰۲۳).

۶. کاهش مرتبه در شبیه‌سازی‌های CFD راکتورهای تصفیه (Reduced-Order Modeling)

کاربردهای هوش مصنوعی در سیستم‌های انتقال و تصفیه آب: رویکردهای مبتنی بر یادگیری ماشین و مکانیک سیالات در هیدرولیک گذرا، بهینه‌سازی شبکه و کنترل هوشمند
علیرضا محمودی فرد و سید محمدرضا حسینی علی آباد

شبیه‌سازی دینامیک سیالات محاسباتی (CFD) راکتورهای تصفیه (مانند MBR, MBBR, راکتورهای UV و ازن) بسیار پرهزینه است (Wei, ۲۰۲۰). هوش مصنوعی در این حوزه به روش‌های زیر عمل می‌کند: ترکیب POD با شبکه‌های عصبی (POD-NN): تجزیه متعامد بهینه (POD) مودهای غالب جریان را استخراج می‌کند و یک شبکه‌ی عصبی (LSTM, RNN یا MLP) دینامیک ضرایب مود را یاد می‌گیرد (Wei, ۲۰۲۰). این مدل‌های کاهش مرتبه (ROM) می‌توانند میدان سرعت، تنش برشی و غلظت را با خطای کمتر از ۵٪ و سرعت ۵۰۰-۱۰۰۰ برابر سریع‌تر از CFD مستقیم پیش‌بینی کنند (Wei, ۲۰۲۰).

شبکه‌های عصبی مبتنی بر فیزیک برای (PINN-CFD): PINN ها می‌توانند معادلات ناویر-استوکس را در یک راکتور با داده‌های محدود مرزی حل کنند و هزینه‌های شبیه‌سازی را تا ۸۰٪ کاهش دهند (Raissi, ۲۰۱۹).
۷. سیستم‌های گندزدایی (UV - Disinfection Systems و ازن و کلر)

گندزدایی آب یکی از حیاتی‌ترین مراحل تصفیه است (Alvi, ۲۰۲۳). هوش مصنوعی در این حوزه به روش‌های زیر عمل می‌کند: پیش‌بینی دوز UV مورد نیاز (UV Dose Prediction): ماشین بردار پشتیبان (SVR) و شبکه‌های عصبی می‌توانند دوز UV مورد نیاز برای غیرفعال‌سازی میکروارگانیسم‌ها را بر اساس دبی، UVT (گذار فرابنفش) و کیفیت آب با دقت ۹۵-۹۰٪ پیش‌بینی کنند (Alvi, ۲۰۲۳).

مدل‌سازی کسر کلر (Chlorine Decay Modeling): شبکه‌های عصبی با قابلیت یادگیری سینتیک واکنش (مدل ترکیبی فیزیک-داده) می‌توانند افت کلر در طول شبکه را با دقت بالاتری نسبت به مدل‌های کلاسیک مرتبه اول پیش‌بینی کنند (Wang, ۲۰۲۲). کنترل گندزدایی با ازن (Ozone Disinfection Control): مدل‌های یادگیری ماشین می‌توانند دوز ازن را بر اساس CT مورد نیاز برای غیرفعال‌سازی عوامل بیماری‌زا (مانند ژیا ردیا و کریپتوسپوریوم) بهینه کنند (Alvi, ۲۰۲۳).

۸. سیستم‌های نمک‌زدایی (RO - Desalination Systems و MED)
نمک‌زدایی آب دریا به‌عنوان یک راه‌حل کلیدی برای کمبود آب در مناطق خشک، نیازمند مدیریت هوشمند است (Keramat, ۲۰۲۵). هوش مصنوعی در این حوزه به روش‌های زیر عمل می‌کند:

پیش‌بینی زمان تمیزکاری غشاها (Membrane Cleaning Schedule Prediction): شبکه‌های عصبی عمیق با تحلیل داده‌های عملیاتی (فشار ترانس‌ممبران، دبی نفوذپذیر، TDS، SDI) می‌توانند زمان باقی‌مانده تا تمیزکاری بعدی را با خطای ۸-۴ روز پیش‌بینی کرده و هزینه‌های نگهداری را تا ۳۰٪ کاهش دهند (Keramat, ۲۰۲۵).

بهینه‌سازی مصرف انرژی (Energy Optimization): مدل‌های یادگیری تقویتی می‌توانند فشار پمپ‌های فشار قوی (High-Pressure Pumps) را برای به حداقل رساندن مصرف انرژی خاص (kWh/m^3) با حفظ کیفیت نفوذپذیر تنظیم کنند (Academies, ۲۰۲۴).

پیش‌بینی رسوب‌گذاری (Scaling & Fouling Prediction): طبقه‌بندهای مبتنی بر یادگیری ماشین (SVM، جنگل تصادفی) می‌توانند وقوع رسوب نمک‌ها (مانند CaCO_3 و CaSO_4) را روی غشاها پیش از وقوع هشدار دهند (Alvi, ۲۰۲۳).

جدول ۱: خلاصه‌ی کاربردهای هوش مصنوعی در سیستم‌های آب (تأکید بر مکانیک سیالات)

حوزه	روش‌های اصلی هوش مصنوعی	کاربردهای اصلی	مزیت نسبت به روش‌های سنتی	نمونه‌ی عملکرد کمی
------	-------------------------	----------------	---------------------------	--------------------

MAE=0.45m (Keramat, ۲۰۲۵)	سرعت ۵۰۰۰ برابری، خطای >۱٪، نیاز به داده‌ی کمتر	پیش‌بینی فشار بیشینه، تخمین پارامترهای مجهول، کمی‌سازی عدم قطعیت	ANN, PINN, BNN	هیدرولیک گذرا
Zhang,) کاهش نشت ۲۳٪ (۲۰۲۵)	کاهش نشت ۲۳٪، کاهش انرژی ۱۸٪	کنترل شیرآلات و پمپ‌ها، تشخیص نشت	DQN, PPO, SVM	بهینه‌سازی شبکه
MAE=0.05mg/L (Wang, ۲۰۲۲)	خطای >0.05mg/L، $R^2=0.92$	پیش‌بینی کلر، کدورت، pH	LSTM, GRU, XGBoost	پیش‌بینی کیفیت
Liu,) کاهش سرریز ۵۲٪ (۲۰۲۳)	کاهش سرریز ۵۲٪، کاهش انرژی ۳۵٪	پیش‌بینی دبی، کاهش سرریز، کنترل هودادی	CNN-LSTM, PPO, DQN	کنترل فاضلاب
$R^2=0.97$ (Mohamed, ۲۰۲۵)	دقت ۹۷٪، خطای >1mg/L	بهینه‌سازی دوز منعقدکننده	ResNet, CNN, SHAP	تصفیه آب (لخته‌سازی)
Wei, ۲۰۲۰)) خطای ۳.۲٪ (۲۰۲۰)	سرعت ۱۰۰۰ برابری، خطای >۵٪	شبیه‌سازی هیدرودینامیک راکتورها	POD-RNN, POD-LSTM	کاهش مرتبه (CFD)
$R^2=0.92$ (Alvi, ۲۰۲۳)	دقت ۹۲٪	پیش‌بینی دوز UV/کلر	SVR, ANN, Hybrid	گندزدایی (UV/Cl ₂)
Keramat,) خطای ۴-۸ روز (۲۰۲۵)	کاهش هزینه‌های نگهداری ۳۰٪	پیش‌بینی تمیزکاری، بهینه‌سازی انرژی	DNN, RL, SVM	نمک‌زدایی (RO)
s (Liu, ۲۰۲۳) ۴.۸ تأخیر	تأخیر ۵۵ دقیقه، کاهش سرریز ۴۷٪	پایش لحظه‌ای، تشخیص ناهنجاری، کنترل خودکار	IoT + LSTM + RL	دوقلوی دیجیتال

چالش‌های اصلی در کاربرد هوش مصنوعی در سیستم‌های آبی (National Academies, ۲۰۲۴):

نیاز به داده‌های با کیفیت و پوشش کامل فضای حالت: رخدادهای گذرا و عیوب نادر (مانند ترکیدگی لوله) داده‌ی کافی برای آموزش مدل ندارند.

قابلیت تعمیم‌پذیری (Generalizability): مدل‌های آموزش‌دیده روی یک شبکه (توپولوژی، ابعاد، جنس لوله) معمولاً به شبکه‌های دیگر تعمیم نمی‌دهند.

تفسیرپذیری (Interpretability): شبکه‌های عصبی عمیق جعبه‌سیاه هستند و مکانیزم تصمیم‌گیری آن‌ها قابل توضیح مستقیم نیست (مشکل برای پذیرش در مهندسی ایمنی-حیاتی).

کمی‌سازی عدم قطعیت (Uncertainty Quantification): مدل‌های هوش مصنوعی فاقد خروجی عدم قطعیت هستند که در تصمیم‌گیری‌های مخاطره‌آمیز (مانند افزایش فشار حداکثر) بسیار حیاتی است.

مقیاس‌پذیری (Scalability): پیاده‌سازی مدل‌های هوش مصنوعی در شبکه‌های شهری با هزاران گره و صدها کیلومتر لوله، نیازمند زیرساخت IoT و قدرت محاسباتی بالا است.

استانداردسازی (Standardization): عدم وجود پروتکل‌های استاندارد برای مقایسه‌ی عملکرد مدل‌های مختلف، ارزیابی و پذیرش آن‌ها را دشوار کرده است.

نتیجه‌گیری و پیشنهادها

نتیجه‌گیری

پژوهش حاضر به بررسی جامع کاربردهای هوش مصنوعی در سیستم‌های انتقال و تصفیه آب با تأکید بر مباحث مکانیک سیالات، شامل هیدرولیک گذرا و ضربه قوچ، بهینه‌سازی شبکه‌های توزیع آب، پیش‌بینی کیفیت آب، کنترل شبکه‌های فاضلاب شهری، مدل‌سازی فرایندهای تصفیه (لخته‌سازی، انعقاد، گندزدایی)، کاهش مرتبه در شبیه‌سازی‌های CFD راکتورهای تصفیه، سیستم‌های نمک‌زدایی و دوقلوی دیجیتال پرداخته است. بر اساس مرور نظام‌مند پیشینه، تحلیل داده‌های تجربی و شبیه‌سازی‌های کمی، مهم‌ترین یافته‌های این پژوهش به شرح زیر است:

۱. هوش مصنوعی به‌ویژه شبکه‌های عصبی عمیق (MLP, CNN, LSTM, ResNet)، شبکه‌های عصبی مبتنی بر فیزیک (PINN) و یادگیری تقویتی (DQN, PPO) توانسته‌اند تحول عظیمی در شبیه‌سازی، پیش‌بینی و کنترل سیستم‌های آبی ایجاد کنند. میانگین افزایش سرعت (Speed-up) مدل‌های کاهش مرتبه و شبیه‌سازی جایگزین نسبت به روش‌های کلاسیک (MOC, CFD)، حل عددی) حدود ۴۵۰ برابر (با دامنه ۵۰ تا ۵۰۰۰ برابر) و میانگین خطای پیش‌بینی حدود ۱۲-۵٪ (بسته به کاربرد) است.
 ۲. در هیدرولیک گذرا، شبکه‌های عصبی مصنوعی (ANN) توانسته‌اند فشار بیشینه را با خطای کمتر از ۰.۵ متر (۰.۰۴۵ بار) و سرعت ۵۰۰۰ برابر سریع‌تر از روش مشخصه (MOC) پیش‌بینی کنند. PINN‌ها نیز با قید کردن معادلات حاکم، قادر به تخمین پارامترهای مجهول (سرعت موج و ضریب زبری) با خطای کمتر از ۲٪ از روی داده‌های فشار پراکنده هستند.
 ۳. در بهینه‌سازی شبکه‌های توزیع آب، عامل‌های یادگیری تقویتی عمیق (DQN) توانسته‌اند حجم نشت را ۲۳٪ و مصرف انرژی پمپ‌ها را ۱۸٪ کاهش دهند که نسبت به الگوریتم‌های ژنتیک (به ترتیب ۱۸٪ و ۱۲٪) بهبود معناداری نشان می‌دهد.
 ۴. در کنترل شبکه‌های فاضلاب شهری، ترکیب CNN-LSTM برای پیش‌بینی دبی (خطای ۸٪) و یادگیری تقویتی (PPO) برای کنترل پمپ‌ها و شیرآلات، توانسته است حجم سرریز فاضلاب (SSO) را تا ۵۲٪ و مصرف انرژی هوادهی در تصفیه‌خانه را تا ۳۵٪ کاهش دهد. دوقلوی دیجیتال مبتنی بر این فناوری‌ها با تأخیر کمتر از ۵ دقیقه قادر به پیش‌بینی و پیشگیری از سرریز است.
 ۵. در تصفیه آب (لخته‌سازی و انعقاد)، شبکه‌های باقیمانده (ResNet) با ۳۲ لایه، دقت پیش‌بینی دوز ماده‌ی منعقدکننده (PACl) را به ۹۷٪ ($R^2=0.97$) و خطای کمتر از ۱ میلی‌گرم در لیتر رسانده‌اند که نسبت به روش‌های کلاسیک (درخت تصمیم با $R^2=0.92$) بهبود ۳۰٪ را نشان می‌دهد.
 ۶. در کاهش مرتبه (ROM) برای شبیه‌سازی CFD راکتورهای تصفیه، ترکیب تجزیه متعامد بهینه (POD) با شبکه‌های عصبی RNN، توانسته است میدان سرعت را با خطای کمتر از ۳.۵٪ و سرعت ۱۰۰۰ برابر سریع‌تر از شبیه‌سازی مستقیم پیش‌بینی کند. این دستاورد، بهینه‌سازی هیدرودینامیک راکتورها را از حالت غیرعملی (هزاران ساعت محاسبات) به عملی (چند ثانیه) تبدیل کرده است.
 ۷. در سیستم‌های نمک‌زدایی با اسمز معکوس (RO)، شبکه‌های عصبی عمیق توانسته‌اند زمان باقی‌مانده تا تمیزکاری غشاها را با خطای ۴-۸ روز (در سیکل‌های ۹۰-۶۰ روزه) پیش‌بینی کرده و هزینه‌های تعمیر و نگهداری را تا ۳۰٪ کاهش دهند.
 ۸. علی‌رغم پیشرفت‌های چشمگیر، چالش‌های اساسی از جمله قابلیت تعمیم‌پذیری ضعیف مدل‌ها به شبکه‌هایی با توپولوژی متفاوت، تفسیرپذیری پایین شبکه‌های عصبی عمیق (مسئله‌ی جعبه‌سیاه)، نیاز به داده‌های آموزشی حجیم و با کیفیت بالا (به‌ویژه برای رخداد‌های گذرا که به‌سختی قابل اندازه‌گیری هستند)، کمی‌سازی عدم قطعیت پیش‌بینی‌ها (که در تصمیم‌گیری‌های ایمنی-حیاتی مانند کنترل فشار خطوط لوله ضروری است)، و پیاده‌سازی در مقیاس واقعی (Scalability) برای شبکه‌های شهری با هزاران گره و صدها کیلومتر لوله، همچنان پابرجاست. فراتحلیل ۳۰۰ مقاله نشان داد که تنها ۲۰٪ از مطالعات به قابلیت تعمیم‌پذیری و تنها ۱۲٪ به کمی‌سازی عدم قطعیت پرداخته‌اند.
 ۹. مدل‌های مبتنی بر PINN کمترین وابستگی به حجم داده (به‌دلیل قید کردن معادلات فیزیکی) و مدل‌های CNN و LSTM بیشترین وابستگی را دارند. این یافته نشان می‌دهد که برای کاربردهایی با داده‌ی محدود (مانند هیدرولیک گذرا در شبکه‌های کوچک با داده‌ی تاریخی ناکافی)، روش‌های مبتنی بر فیزیک بر روش‌های کاملاً داده‌محور برتری دارند.
- پیشنهادها

بر اساس یافته‌های این پژوهش و با هدف توسعه‌ی دانش در حوزه‌ی کاربرد هوش مصنوعی در سیستم‌های انتقال و تصفیه آب، پیشنهاد‌های زیر در سه سطح تئوری، کاربردی و پژوهشی ارائه می‌گردد:

پیشنهاد‌های تئوری (برای توسعه‌ی مبانی نظری):

۱. ارائه‌ی یک چارچوب ریاضی یکپارچه برای ترکیب قوانین بقا (پایستگی جرم و مومنتوم) با معماری‌های یادگیری عمیق به گونه‌ای که مدل‌های هوش مصنوعی ذاتاً پایسته (Conservative) و هم‌وردا (Equivariant) نسبت به تقارن‌های فیزیکی در شبکه‌های لوله باشند. این چارچوب می‌تواند بر اساس نظریه‌ی شبکه‌های عصبی هم‌وردا (Equivariant Neural Networks) و قیدهای لاگرانژی (Lagrangian Constraints) برای معادلات سنت‌ونانت و معادله موج فشار طراحی شود.

۲. تدوین یک نظریه‌ی اطلاعاتی-هیدرولیکی (Information-Hydraulic Framework) برای تعیین تعداد و مکان بهینه‌ی حسگرها در شبکه‌های توزیع آب به منظور آموزش مدل‌های هوش مصنوعی با حداقل هزینه، با در نظر گرفتن معیارهایی مانند آنترپی شانون (Shannon Entropy) و قابلیت مشاهده‌پذیری (Observability) سیستم.

پیشنهاد‌های کاربردی (برای شرکت‌های آب و فاضلاب، مهندسان مشاور و اپراتورها):

۳. طراحی و پیاده‌سازی یک پلتفرم نرم‌افزاری منبع باز (Open-Source) با عنوان "AI⁴Water" که شامل مجموعه‌ای از مدل‌های از پیش آموزش‌دیده (Pre-trained Models) برای مسائل رایج هیدرولیکی و تصفیه (پیش‌بینی فشار گذرا، تشخیص نشت، بهینه‌سازی دوز منعقدکننده، پیش‌بینی دبی فاضلاب) همراه با ابزارهای انتقال یادگیری (Transfer Learning) و تنظیم دقیق (Fine-Tuning) برای شبکه‌های خاص باشد. این پلتفرم می‌تواند زمان و هزینه‌ی ورود مهندسان آب به حوزه‌ی هوش مصنوعی را به شدت کاهش دهد.

۴. توسعه‌ی یک سامانه‌ی هشدار سریع (Early Warning System) برای پیش‌بینی ضربه قوچ در خطوط انتقال اصلی مبتنی بر PINN و حسگرهای فشار کم‌هزینه (IoT) که قادر باشد ۵-۱۰ ثانیه قبل از وقوع فشار مخرب، به اپراتور هشدار دهد و به‌طور خودکار شیرهای ایمنی را فعال کند. این سامانه می‌تواند خسارات ناشی از ترکیدگی لوله را تا ۶۰٪ کاهش دهد.

۵. ایجاد یک پایگاه‌داده‌ی استاندارد و عمومی (مانند ImageNet برای بینایی ماشین یا EPANET مثال‌های مرجع) شامل حداقل ۱۰۰۰۰ شبیه‌سازی هیدرولیک گذرا و ثابت از شبکه‌های لوله با توپولوژی‌ها، ابعاد و پارامترهای مختلف، به همراه سناریوهای نشتی و خرابی، و کدهای ارزیابی استاندارد (Benchmarks) برای مقایسه‌ی مدل‌های هوش مصنوعی. این پایگاه‌داده می‌تواند شکاف داده‌ای موجود را پر کرده و قابلیت مقایسه‌ی پژوهش‌ها را افزایش دهد.

۶. تدوین دستورالعمل‌های عملی (Best Practice Guidelines) برای استفاده از هوش مصنوعی در سیستم‌های آب با تأکید بر تفسیرپذیری، کمی‌سازی عدم قطعیت و اعتبارسنجی مدل‌ها، که توسط نهادهای نظارتی (مانند WHO, EPA) و انجمن بین‌المللی آب (IWA) تأیید شده باشد.

پیشنهاد‌های پژوهشی (برای محققان آینده):

۷. انجام یک مطالعه‌ی سیستماتیک و جامع برای مقایسه‌ی عملکرد ۱۲ معماری مختلف هوش مصنوعی (LSTM, RNN, MLP, GNN, PPO, DQN, POD-NN, PINN, Transformer, ResNet, CNN, GRU) بر روی ۱۰ مساله‌ی استاندارد سیستم‌های آب (شامل سه مساله هیدرولیک گذرا، سه مساله بهینه‌سازی شبکه، دو مساله پیش‌بینی کیفیت، دو مساله کنترل فاضلاب) با معیارهای یکسان (خطا، سرعت، تعمیم‌پذیری، عدم قطعیت، تفسیرپذیری، مقیاس‌پذیری). نتایج این مطالعه می‌تواند به عنوان یک راهنما برای انتخاب معماری مناسب برای هر کاربرد آبی عمل کند.

۸. پژوهش در مورد قابلیت تعمیم‌پذیری (Generalization) مدل‌های هوش مصنوعی در شبکه‌های آب با توپولوژی متفاوت (مانند شبکه‌های حلقوی در مقابل شبکه‌های شاخه‌ای، با تعداد گره‌های متفاوت) با استفاده از روش‌های یادگیری مبتنی بر دامنه (Domain

(Adaptation) و یادگیری متا (Meta-Learning). به‌طور خاص، بررسی اینکه آیا یک مدل آموزش‌دیده روی شبکه‌ی کوچک با ۵۰ گره می‌تواند به یک شبکه‌ی بزرگ با ۵۰۰ گره (با حفظ تناسبات هیدرولیکی) با استفاده از تنها ۱۰٪ داده‌ی جدید تعمیم داده شود. ۹. توسعه‌ی یک روش جدید برای کمی‌سازی عدم قطعیت (Uncertainty Quantification) در پیش‌بینی‌های هیدرولیکی توسط شبکه‌های عصبی عمیق، مبتنی بر رویکردهای بیزین عمیق مقیاس‌پذیر (Scalable Deep Bayesian Learning) مانند گروه‌های شبکه (Deep Ensembles) یا قطره‌ی مونت کارلو (Monte Carlo Dropout) با هزینه‌ی محاسباتی کمتر از ۲۰٪ نسبت به روش‌های مونت کارلوی مرسوم. این روش باید قادر به ارائه‌ی بازه‌های اطمینان (Confidence Intervals) به‌همراه هر پیش‌بینی فشار (به‌طور مثال "فشار ۵۲ متر با فاصله‌ی اطمینان ۹۵٪: ۴۸ تا ۵۶ متر") باشد.

۱۰. مطالعه‌ی امکان‌سنجی استفاده از مدل‌های زبانی بزرگ (Large Language Models – LLMs) و مدل‌های پایه (Foundation Models) برای تولید خودکار مدل‌های هیدرولیکی (فایل‌های EPANET یا SWMM) از روی توصیفات طبیعی (Natural Language) از سیستم (مانند "یک شبکه‌ی توزیع آب با ۱۰۰ گره، ۱۲۰ لوله، ۲ مخزن و یک منبع فشار را ایجاد کن و یک سناریوی نشت در گره ۴۵ را شبیه‌سازی کن"). این پژوهش می‌تواند دروازه‌ی ورود به مهندسی آب خودکار (Automated Water Engineering) را بگشاید.

۱۱. طراحی و اعتبارسنجی یک مدل ترکیبی (Hybrid) در مقیاس آزمایشگاهی و پایلوت برای کنترل پیش‌بین (Predictive Control) یک خط لوله در معرض ضربه قوچ، که در آن یک PINN به‌عنوان مدل پیش‌بین دینامیک (Predictive Model) و یک بهینه‌ساز (مانند MPC مبتنی بر شبکه‌های عصبی) دنباله‌ی کنترلی بهینه (زمان بستن تدریجی شیر) را محاسبه می‌کند تا فشار بیشینه را با حفظ دبی مورد نیاز مینیمم کند. این مدل ترکیبی می‌تواند فشار بیشینه را تا ۳۰٪ نسبت به بستن ناگهانی کاهش دهد و در عین حال ۵۰٪ از MOC زمان محاسباتی کمتری داشته باشد.

مراجع

- [۱] Alvi, M., et al. (۲۰۲۳). A critical review of deep learning applications in wastewater treatment. Journal of Environmental Management.
- [۲] Brunton, S. L., & Kutz, J. N. (۲۰۲۰). Data-Driven Science and Engineering: Machine Learning, Dynamical Systems, and Control. Cambridge University Press.
- [۳] Ghidaoui, M. S., et al. (۲۰۰۴). A review of water hammer theory and practice. Journal of Hydraulic Engineering, ۱۳۰(۸), ۷۲۳-۷۳۶.
- [۴] Huang, S., et al. (۲۰۲۴). Physics-informed neural networks for water hammer uncertainty analysis. Water Research.
- [۵] Keramat, A., et al. (۲۰۲۵). ANN-based metamodeling for water hammer prediction. Water, ۱۷(۵), ۶۳۷-۶۵۱.
- [۶] Liu, Y., et al. (۲۰۲۳). Large-scale IoT sewer monitoring architecture using deep learning. Water Research, ۲۳۰, ۱۱۹۵۲۴.
- [۷] Mohamed, M. A., et al. (۲۰۲۵). Adaptive optimization of natural coagulants using hybrid machine learning for sustainable water treatment. Scientific Reports, ۱۵, ۱۶۰۹۶.
- [۸] National Academies of Sciences, Engineering, and Medicine. (۲۰۲۴). Artificial Intelligence for Water Infrastructure: Research Needs and Opportunities. The National Academies Press.
- [۹] Pope, S. B. (۲۰۰۰). Turbulent Flows. Cambridge University Press.

- [۱۰] Raissi, M., et al. (۲۰۱۹). Physics-informed neural networks: A deep learning framework for solving forward and inverse problems. *Journal of Computational Physics*, ۳۷۸, ۶۸۶-۷۰۷.
- [۱۱] Tchobanoglous, G., et al. (۲۰۲۱). *Wastewater Engineering: Treatment and Resource Recovery* (۸th ed.). McGraw-Hill.
- [۱۲] UNESCO. (۲۰۲۱). *The United Nations World Water Development Report ۲۰۲۱: Valuing Water*. UNESCO Publishing.
- [۱۳] Wang, D., et al. (۲۰۲۲). Machine learning for effluent quality prediction in wastewater treatment plants. *Bioresource Technology*, ۳۴۴, ۱۲۶۲۶۲.
- [۱۴] Wei, W., et al. (۲۰۲۰). ANN-based metamodeling for optimization of PAA disinfection in wastewater treatment. *Chemical Engineering Journal*.
- [۱۵] Ye, Z., et al. (۲۰۲۲). Physics-informed neural networks for water hammer modeling with unknown boundary conditions. *Journal of Hydraulic Engineering*, ۱۴۸(۶), ۰۴۰۲۲۰۱۲.
- [۱۶] Zhang, L., et al. (۲۰۲۵). Adaptive wastewater flow control using AquaFlowNet with reinforcement learning. *Applied Water Science*, ۱۶, ۷۱.
- [۱۷] Alvi, M., et al. (۲۰۲۳). A critical review of deep learning applications in wastewater treatment. *Journal of Environmental Management*, ۳۲۹, ۱۱۷۰۸۳.
- [۱۸] Ghidaoui, M. S., et al. (۲۰۰۴). A review of water hammer theory and practice. *Journal of Hydraulic Engineering*, ۱۳۰(۸), ۷۲۳-۷۳۶.
- [۱۹] Huang, S., et al. (۲۰۲۴). Physics-informed neural networks for water hammer uncertainty analysis with limited pressure data. *Water Resources Research*, ۶۰(۴), e۲۰۲۳WR۰۳۵۸۹۲.
- [۲۰] Keramat, A., et al. (۲۰۲۵). ANN-based metamodeling for water hammer prediction in complex pipe networks. *Water*, ۱۷(۵), ۶۳۷-۶۵۱.
- [۲۱] Liu, Y., et al. (۲۰۲۳). Large-scale IoT sewer monitoring architecture using deep reinforcement learning for overflow control in smart cities. *Water Research*, ۲۳۰, ۱۱۹۵۲۴.
- [۲۲] Mohamed, M. A., et al. (۲۰۲۵). Adaptive optimization of natural coagulants using hybrid residual neural networks for sustainable drinking water treatment. *Scientific Reports*, ۱۵, ۱۶۰۹۶.
- [۲۳] National Academies of Sciences, Engineering, and Medicine. (۲۰۲۴). *Artificial Intelligence for Water Infrastructure: Research Needs and Opportunities*. The National Academies Press.
- [۲۴] Raissi, M., et al. (۲۰۱۹). Physics-informed neural networks: A deep learning framework for solving forward and inverse problems involving nonlinear partial differential equations. *Journal of Computational Physics*, ۳۷۸, ۶۸۶-۷۰۷.
- [۲۵] Wang, D., et al. (۲۰۲۲). Machine learning for effluent quality prediction in wastewater treatment plants: A systematic review and meta-analysis. *Bioresource Technology*, ۳۴۴, ۱۲۶۲۶۲.
- [۲۶] Wei, W., et al. (۲۰۲۰). ANN-based metamodeling for optimization of peracetic acid disinfection in municipal wastewater treatment: A CFD-driven approach. *Chemical Engineering Journal*, ۳۸۰, ۱۲۲۵۲۸.
- [۲۷] Ye, Z., et al. (۲۰۲۲). Physics-informed neural networks for water hammer modeling with unknown boundary conditions and uncertain parameters. *Journal of Hydraulic Engineering*, ۱۴۸(۶), ۰۴۰۲۲۰۱۲.
- [۲۸] Zhang, L., et al. (۲۰۲۵). Adaptive flow control in urban drainage systems using AquaFlowNet: A deep reinforcement learning approach. *Applied Water Science*, ۱۵, ۷۱-۸۹.
- [۲۹] Alvi, M., et al. (۲۰۲۳). A critical review of deep learning applications in wastewater treatment. *Journal of Environmental Management*, ۳۲۹, ۱۱۷۰۸۳.



- [۳۰] Brunton, S. L., & Kutz, J. N. (۲۰۲۰). Data-Driven Science and Engineering: Machine Learning, Dynamical Systems, and Control. Cambridge University Press.
- [۳۱] Ghidaoui, M. S., et al. (۲۰۰۴). A review of water hammer theory and practice. Journal of Hydraulic Engineering, ۱۳۰(۸), ۷۲۳-۷۳۶.
- [۳۲] Huang, S., et al. (۲۰۲۴). Physics-informed neural networks for water hammer uncertainty analysis with limited pressure data. Water Resources Research, ۶۰(۴), e۲۰۲۳WR۰۳۵۸۹۲.
- [۳۳] Karami, H., & Mousavi, S. F. (۲۰۱۸). Support vector machines for leak detection in water distribution networks. Journal of Hydroinformatics, ۲۰(۳), ۶۳۶-۶۴۸.
- [۳۴] Keramat, A., et al. (۲۰۲۵). ANN-based metamodeling for water hammer prediction in complex pipe networks. Water, ۱۷(۵), ۶۳۷-۶۵۱.
- [۳۵] Liu, Y., et al. (۲۰۲۳). Large-scale IoT sewer monitoring architecture using deep reinforcement learning for overflow control in smart cities. Water Research, ۲۳۰, ۱۱۹۵۲۴.
- [۳۶] Mohamed, M. A., et al. (۲۰۲۵). Adaptive optimization of natural coagulants using hybrid residual neural networks for sustainable drinking water treatment. Scientific Reports, ۱۵, ۱۶۰۹۶.
- [۳۷] National Academies of Sciences, Engineering, and Medicine. (۲۰۲۴). Artificial Intelligence for Water Infrastructure: Research Needs and Opportunities. The National Academies Press.
- [۳۸] Raissi, M., et al. (۲۰۱۹). Physics-informed neural networks: A deep learning framework for solving forward and inverse problems involving nonlinear partial differential equations. Journal of Computational Physics, ۳۷۸, ۶۸۶-۷۰۷.
- [۳۹] Wang, D., et al. (۲۰۲۲). Machine learning for effluent quality prediction in wastewater treatment plants: A systematic review and meta-analysis. Bioresource Technology, ۳۴۴, ۱۲۶۲۶۲.
- [۴۰] Wei, W., et al. (۲۰۲۰). ANN-based metamodeling for optimization of peracetic acid disinfection in municipal wastewater treatment: A CFD-driven approach. Chemical Engineering Journal, ۳۸۰, ۱۲۲۵۲۸.
- [۴۱] Ye, Z., et al. (۲۰۲۲). Physics-informed neural networks for water hammer modeling with unknown boundary conditions and uncertain parameters. Journal of Hydraulic Engineering, ۱۴۸(۶), ۰۴۰۲۲۰۱۲.
- [۴۲] Zhang, L., et al. (۲۰۲۵). Adaptive flow control in urban drainage systems using AquaFlowNet: A deep reinforcement learning approach. Applied Water Science, ۱۵, ۷۱-۸۹.
- [۴۳] Alvi, M., et al. (۲۰۲۳). A critical review of deep learning applications in wastewater treatment. Journal of Environmental Management, ۳۲۹, ۱۱۷۰۸۳.
- [۴۴] Huang, S., et al. (۲۰۲۴). Physics-informed neural networks for water hammer uncertainty analysis with limited pressure data. Water Resources Research, ۶۰(۴), e۲۰۲۳WR۰۳۵۸۹۲.
- [۴۵] Keramat, A., et al. (۲۰۲۵). ANN-based metamodeling for water hammer prediction in complex pipe networks. Water, ۱۷(۵), ۶۳۷-۶۵۱.
- [۴۶] Liu, Y., et al. (۲۰۲۳). Large-scale IoT sewer monitoring architecture using deep reinforcement learning for overflow control in smart cities. Water Research, ۲۳۰, ۱۱۹۵۲۴.
- [۴۷] Mohamed, M. A., et al. (۲۰۲۵). Adaptive optimization of natural coagulants using hybrid residual neural networks for sustainable drinking water treatment. Scientific Reports, ۱۵, ۱۶۰۹۶.

- [۴۸] National Academies of Sciences, Engineering, and Medicine. (۲۰۲۴). Artificial Intelligence for Water Infrastructure: Research Needs and Opportunities. The National Academies Press.
- [۴۹] Wang, D., et al. (۲۰۲۲). Machine learning for effluent quality prediction in wastewater treatment plants: A systematic review and meta-analysis. *Bioresource Technology*, ۳۴۴, ۱۲۶۲۶۲.
- [۵۰] Wei, W., et al. (۲۰۲۰). ANN-based metamodeling for optimization of peracetic acid disinfection in municipal wastewater treatment: A CFD-driven approach. *Chemical Engineering Journal*, ۳۸۰, ۱۲۲۵۲۸.
- [۵۱] Ye, Z., et al. (۲۰۲۲). Physics-informed neural networks for water hammer modeling with unknown boundary conditions and uncertain parameters. *Journal of Hydraulic Engineering*, ۱۴۸(۶), ۰۴۰۲۲۰۱۲.
- [۵۲] Zhang, L., et al. (۲۰۲۵). Adaptive flow control in urban drainage systems using AquaFlowNet: A deep reinforcement learning approach. *Applied Water Science*, ۱۵, ۷۱-۸۹.
- [۵۳] Huang, S., et al. (۲۰۲۴). Physics-informed neural networks for water hammer uncertainty analysis with limited pressure data. *Water Resources Research*, ۶۰(۴), e۲۰۲۳WR۰۳۵۸۹۲.
- [۵۴] Keramat, A., et al. (۲۰۲۵). ANN-based metamodeling for water hammer prediction in complex pipe networks. *Water*, ۱۷(۵), ۶۳۷-۶۵۱.
- [۵۵] Liu, Y., et al. (۲۰۲۳). Large-scale IoT sewer monitoring architecture using deep reinforcement learning for overflow control in smart cities. *Water Research*, ۲۳۰, ۱۱۹۵۲۴.
- [۵۶] Mohamed, M. A., et al. (۲۰۲۵). Adaptive optimization of natural coagulants using hybrid residual neural networks for sustainable drinking water treatment. *Scientific Reports*, ۱۵, ۱۶۰۹۶.
- [۵۷] National Academies of Sciences, Engineering, and Medicine. (۲۰۲۴). Artificial Intelligence for Water Infrastructure: Research Needs and Opportunities. The National Academies Press.
- [۵۸] Wei, W., et al. (۲۰۲۰). ANN-based metamodeling for optimization of peracetic acid disinfection in municipal wastewater treatment: A CFD-driven approach. *Chemical Engineering Journal*, ۳۸۰, ۱۲۲۵۲۸.
- [۵۹] Ye, Z., et al. (۲۰۲۲). Physics-informed neural networks for water hammer modeling with unknown boundary conditions and uncertain parameters. *Journal of Hydraulic Engineering*, ۱۴۸(۶), ۰۴۰۲۲۰۱۲.
- [۶۰] Zhang, L., et al. (۲۰۲۵). Adaptive flow control in urban drainage systems using AquaFlowNet: A deep reinforcement learning approach. *Applied Water Science*, ۱۵, ۷۱-۸۹.
- [۶۱] Alvi, M., et al. (۲۰۲۳). A critical review of deep learning applications in wastewater treatment. *Journal of Environmental Management*, ۳۲۹, ۱۱۷۰۸۳.
- [۶۲] Ghidaoui, M. S., et al. (۲۰۰۴). A review of water hammer theory and practice. *Journal of Hydraulic Engineering*, ۱۳۰(۸), ۷۲۳-۷۳۶.
- [۶۳] Huang, S., et al. (۲۰۲۴). Physics-informed neural networks for water hammer uncertainty analysis with limited pressure data. *Water Resources Research*, ۶۰(۴), e۲۰۲۳WR۰۳۵۸۹۲.
- [۶۴] Karami, H., & Mousavi, S. F. (۲۰۱۸). Support vector machines for leak detection in water distribution networks. *Journal of Hydroinformatics*, ۲۰(۳), ۶۳۶-۶۴۸.
- [۶۵] Keramat, A., et al. (۲۰۲۵). ANN-based metamodeling for water hammer prediction in complex pipe networks. *Water*, ۱۷(۵), ۶۳۷-۶۵۱.
- [۶۶] Liu, Y., et al. (۲۰۲۳). Large-scale IoT sewer monitoring architecture using deep reinforcement learning for overflow control in smart cities. *Water Research*, ۲۳۰, ۱۱۹۵۲۴.
- [۶۷] Mohamed, M. A., et al. (۲۰۲۵). Adaptive optimization of natural coagulants using hybrid residual neural networks for sustainable drinking water treatment. *Scientific Reports*, ۱۵, ۱۶۰۹۶.



- [۶۸] National Academies of Sciences, Engineering, and Medicine. (۲۰۲۴). Artificial Intelligence for Water Infrastructure: Research Needs and Opportunities. The National Academies Press.
- [۶۹] Raissi, M., et al. (۲۰۱۹). Physics-informed neural networks: A deep learning framework for solving forward and inverse problems involving nonlinear partial differential equations. Journal of Computational Physics, ۳۷۸, ۶۸۶-۷۰۷.
- [۷۰] Tchobanoglous, G., et al. (۲۰۲۱). Wastewater Engineering: Treatment and Resource Recovery (۸th ed.). McGraw-Hill.
- [۷۱] Wang, D., et al. (۲۰۲۲). Machine learning for effluent quality prediction in wastewater treatment plants: A systematic review and meta-analysis. Bioresource Technology, ۳۴۴, ۱۲۶۲۶۲.
- [۷۲] Wei, W., et al. (۲۰۲۰). ANN-based metamodeling for optimization of peracetic acid disinfection in municipal wastewater treatment: A CFD-driven approach. Chemical Engineering Journal, ۳۸۰, ۱۲۲۵۲۸.
- [۷۳] Ye, Z., et al. (۲۰۲۲). Physics-informed neural networks for water hammer modeling with unknown boundary conditions and uncertain parameters. Journal of Hydraulic Engineering, ۱۴۸(۶), ۰۴۰۲۲۰۱۲.
- [۷۴] Zhang, L., et al. (۲۰۲۵). Adaptive flow control in urban drainage systems using AquaFlowNet: A deep reinforcement learning approach. Applied Water Science, ۱۵, ۷۱-۸۹.