

کاربرد تکنولوژی یادگیری ماشین در ارزیابی زیرساخت‌های آبی

UTILITY SIZE:

847 MILES



INCREASED ACCURACY:

21% MORE EFFECTIVE

AT IDENTIFYING PIPE BREAKS
OVER THE AGED BASED MODELPIPE REPLACEMENT
COST SAVINGS:

\$4M

\$1 MILLION COST
PER MILE x 4 MILESBREAK REDUCTION
SAVINGS:

\$120K

8 BREAKS AT \$15,000
AVERAGE COST PER BREAK

در تأسیسات شهری معمولاً برای تعیین این که کدام لوله آب در سیستم نیاز به جایگزینی دارد از معیار ذهنی استفاده می‌شود. تصمیم‌گیری برای جایگزینی لوله در مواقعی که فرصت آن فراهم می‌شود، مانند وقتی که قرار است در آینده نزدیک خیابان روسازی شود به دقت کم این روش می‌افزاید. این فرآیند باعث هزینه‌های ناکارآمد و آسیب‌پذیری شدید تأسیسات در مقابل ریسک‌های سازه‌ای و مالی خواهد شد.

قوانین ایالتی و فدرال در حال افزایش فشار برای ایجاد برنامه‌های مدیریت دارایی جامع و کارآمد تأسیسات هستند.

روش‌های مدیریت دارایی به همراه هوش مصنوعی به خصوص یادگیری ماشین، روش جدیدی برای ارزیابی شرایط لوله‌های آب مدفون ایجاد می‌کنند. به خصوص که هوش مصنوعی و یادگیری ماشین امکان تنظیم استراتژی‌های نگهداری، نوسازی و جایگزینی را به منظور تخصیص بهتر منابع محدود فراهم می‌کنند.

ارزیابی دیجیتالی وضعیت با استفاده از هوش مصنوعی و یادگیری ماشین

ابزارهای ارزیابی وضعیت مبتنی بر یادگیری ماشین تقریباً جدید هستند؛ اما در حال حاضر به صورت تجاری در دسترس قرار دارند. یادگیری ماشین که شاخه‌ای از هوش مصنوعی است، به کامپیوترها قابلیت یادگیری بدون برنامه‌ریزی را می‌دهد. این کار با استفاده از مدل‌های تکراری و خودکار برای یادگیری الگوهای داده‌های بزرگ، کشف بی‌قاعده‌گی‌ها و شناسایی یک ساختار که ممکن است جدید بوده و قبلاً شناخته‌نشده باشد، انجام می‌شود. با این قابلیت می‌توان با استفاده از داده‌های کمتر تحلیل‌های دقیق‌تری انجام داد و روش جدیدی برای نگهداری و در نتیجه برنامه‌ریزی مدیریت دارایی پایه‌گذاری کرد.

شرکت Fracta یک راه‌حل دیجیتالی ارزیابی شرایط مقرون‌به‌صرفه، دقیق و سریع ارائه می‌دهد که احتمال شکست (LOF) در لوله‌های اصلی توزیع آب را پیش‌بینی می‌کند.

Fracta کاملاً با نرم‌افزار پیش‌تاز بازار ArcGIS از شرکت Esri یکپارچه است. پلتفرم‌های یکپارچه Fracta و Esri یک چارچوب معماری برای استفاده راحت با دیگر برنامه‌های نرم‌افزاری مهم مورد استفاده در تأسیسات آب مانند Enterprise Asset Management، Computerized Maintenance Management Systems و Hydraulic Modeling فراهم می‌کنند.

بسیاری از تأسیسات، کمیسیون‌های تأسیسات عمومی و مهندسان مشاور هنوز به روش یادگیری ماشین و GIS در Fracta به چشم یک جعبه سیاه نگاه می‌کنند که برای هر فناوری جدیدی اتفاق می‌افتد. نگرانی اصلی هم به دقت آن مربوط است.

دقت متعادل برای پیش‌بینی‌های LOF

داده‌هایی که از مدل یادگیری ماشین بیرون می‌آیند به اندازه داده‌هایی که به مدل داده می‌شود دقیق هستند. Fracta از یک مدل یادگیری ماشین با متغیرهای ورودی (X) و متغیر خروجی (Y) استفاده می‌کند. این مدل از یک الگوریتم برای یادگیری تابع نگاشت از ورودی به خروجی، $Y=f(X)$ استفاده می‌کند. هدف از این کار تخمین تابع نگاشت به گونه‌ای است که برای داده‌های ورودی (X)، الگوریتم بتواند متغیرهای خروجی (Y) را پیش‌بینی کند.

این یادگیری تحت نظارت است زیرا فرآیند یادگیری الگوریتم مشابه نظارت یک معلم بر فرآیند یادگیری است. با استفاده از یک مجموعه داده آموزشی با جواب‌های درست مشخص، الگوریتم چندین بار روی داده‌های آموزشی پیش‌بینی انجام می‌دهد و این پیش‌بینی‌ها توسط معلم اصلاح می‌شوند. وقتی الگوریتم به سطح قابل قبولی از عملکرد برسد الگوریتم متوقف می‌شود. معمولاً از ۸۰٪ از داده‌های تاریخچه برای آموزش و از ۲۰٪ باقیمانده هم برای اعتبارسنجی مدل یادگیری ماشین استفاده می‌شود.

ارزیابی سیستم توزیع آب با یک مدل یادگیری ماشین نیازمند درک شکست‌ها و عدم شکست‌ها است. True Positive Rate (TPR) نسبت مقادیر مثبت واقعی شناسایی شده را اندازه‌گیری می‌کند. در برنامه Fracta این به معنای شناسایی درست شکست‌های با احتمال بالا است. True Negative Rate (TNR) نسبت مقادیر منفی واقعی شناسایی شده را اندازه می‌گیرد. این روش بر شناسایی درست بخش‌هایی که LOF کمی دارند تکیه دارد. دقت، تعادل بین مقادیر LOF بالا و LOF پایین است. با توجه به این که آموزش و اعتبارسنجی مدل بر اساس ۸۰٪ از داده‌ها است، حداکثر دقت متعادلی که می‌توان به دست آورد ۸۰٪ است.

Figure 1 illustrates the concept of Balanced Accuracy for a medium water utility. The Machine Learning model accurately predicted 79.23% of actual main breaks captured. 79.23% out of 80% is a 99% accuracy.

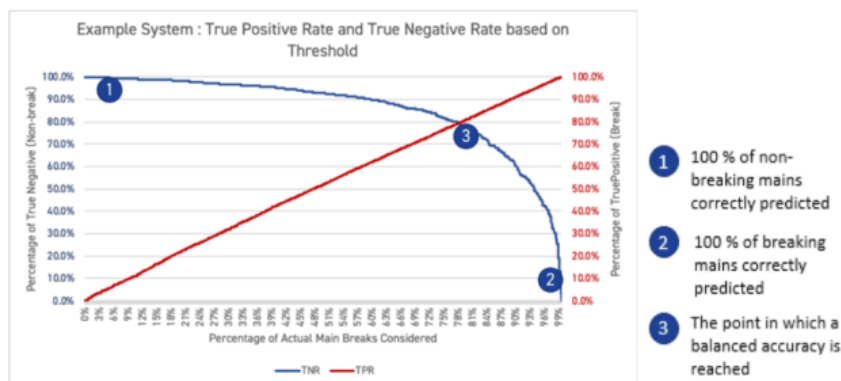


Figure 1: Case Study: Accuracy for a Large Utility (3,395 miles) Dataset 2013-2017

نسل بعدی ارزیابی‌های وضعیت: سریع، دقیق و مقرون به صرفه

در سیستم قدیمی ارزیابی وضعیت لوله‌های اصلی آب مدفون در دو دسته قرار می‌گیرد: مستقیم و غیرمستقیم. معمولاً ابتدا از یک روش مطالعه غیرمستقیم استفاده می‌شود. ارزیابی وضعیت و نظارت فیزیکی یا مستقیم برای لوله‌های آزمایش‌شده دقیق است اما سرعت آن کم، گران و نیازمند نیروی انسانی زیاد است. برای تعیین همبستگی و تأیید به اندازه‌گیری‌های فیزیکی زیادی نیاز است. برونیابی نتایج برای کل سیستم که ممکن است مبتنی بر فرضیات اختیاری باشد، سخت است (یعنی لوله‌های قدیمی‌تر نسبت به لوله‌های جدیدتر بیشتر نیاز به جایگزینی دارند).

روش مدیریت مبتنی بر عملکرد زیرساخت‌های مدفون شامل فهرست تفصیلی بخش‌های خط لوله و کنترل مطابقت عملکرد هر کدام از لوله‌ها با سطح سرویس مورد انتظار است. با توجه به عدم دسترسی آسان به زیرساخت‌های مدفون، مدیریت عملکرد این تأسیسات در صنعت آب انجام نشده است.

یک روش قدرتمندتر مقایسه عوامل مختلف در مقیاس بزرگ برای ارزیابی پیش‌بینی محور دقیق‌تر و اصلاح‌شده‌تر از اندرکنش بین متغیرها است. یادگیری ماشین فناوری است که تأثیر قابل توجهی بر مدیریت زیرساخت‌های مدفون آب دارد. یادگیری ماشین از داده‌های پیچیده بزرگی استفاده می‌کند که حاوی متغیرهای فراتر از قابلیت پردازش انسان با ابزارهای کنونی است. روش داده محور، محدودیت‌های انسانی از جمله پیش‌داوری را از بین برده و نتایج دقیق‌تری ارائه می‌کند که به شرکت‌های خدماتی در گرفتن تصمیمات بهتر برای جایگزینی کمک می‌کنند.

با توجه به حجم بالای داده‌های جغرافیایی و تاریخچه‌ای مورد نیاز برای انجام الگوریتم‌های یادگیری ماشین، ارزیابی شرایط لوله آب یک روش ایده آل است. داده‌های لوله و داده‌های زیست‌محیطی اطراف آن از جمله سال نصب، جنس لوله، سابقه شکست، سطح فشار، موقعیت جغرافیایی، تراز، قطر لوله، مجاورت با سایر سیستم‌های زیرساختی و ترکیب خاک را می‌توان در ارزیابی در کنار صدها متغیر دیگر مختص به یک موقعیت خاص استفاده کرد. تحلیل پیوسته این داده‌ها می‌تواند روند عملکرد لوله‌ها را نمایان کرده، دید خوبی در مورد سلامت لوله ارائه کند و یک ارزیابی داده محور در اختیار ما قرار دهد.

داده‌های لوله‌های جدید قدرت پیش‌بینی یک الگوریتم یادگیری ماشین را افزایش می‌دهند. یادگیری ماشین می‌تواند با داده‌های محدود درباره شکست یا تأسیسات و از طریق پر کردن خلاءها برای تأسیسات سودمند باشد. یادگیری ماشین می‌تواند از جریان‌های داده بسیاری برای انجام پیش‌بینی‌های خاص استفاده کرده و الگوهایی را یاد بگیرد که ما را از شرایطی که با داده‌های معمولی نمی‌توان به آن‌ها پی برد، آگاه کند و به این صورت یک انقلاب دیجیتالی جدید در مسیر روش‌های مدیریت دارایی‌ها شکل می‌گیرد. هر چه یک مدل داده‌های بیشتری داشته باشد، مدل قدرتمندتر است. با توجه به این که در تأسیسات جمع‌آوری داده‌هایی مانند شکست و نصب لوله‌ها به صورت پیوسته انجام می‌شود، می‌توان این داده‌ها را به صورت پیوسته به یک مدل یادگیری ماشین داد.

در فوریه ۲۰۱۹، Fracta موج بعدی قابلیت‌های خود را به کار گرفت. آن‌ها پیش‌بینی‌های LOF سریع، دقیق و اقتصادی خود را با نتایج شکست (COF) همراه کردند تا بتوانند آسیب‌پذیری کسب‌وکار در مقابل ریسک (BRE) و هزینه جایگزینی برای هر یک از لوله‌های سیستم توزیع محاسبه کنند.

BRE را می‌توان برحسب رده‌بندی ریسک و هزینه‌های مستقیم و غیرمستقیم محاسبه کرد. این روش یک ارزیابی هدف ارائه کرده و نتایج را به لحاظ مالی به مهندسان آب، برنامه ریزان و متخصصان مالی می‌دهد که می‌توانند از آن برای گرفتن تصمیمات دقیق، سریع و مقرون‌به‌صرفه در راستای کاهش ریسک در مورد لوله‌های آب مدفون استفاده کنند.

مترجم: علی اکبر خلیلی

منبع:

https://cseengineermag.com/predicting-output-variables/?_ke=eyJrbF9lbWFpbCl6ICJtb2p0YWJhODA4QHlhaG9vLmNvbSl6ICJrbF9jb21wYW55X2lkIjogIktlWEc2TjI9