



Die HiPerWare-Plattform

KI & ML

BIM für den Immobilien-Lebenszyklus

Der Immobilienmarkt ist noch weit von der Perfektion seiner informationstechnologischen Grundlage entfernt, was es erschwert, ein Immobilienentwicklungsprojekt von der Idee bis zur Realisierung in einem einzigen digitalen Zyklus durchzuführen. Dennoch hält PropTech rasant Einzug in die Branche und schafft Raum für die Anwendung von KI- und ML-Technologien (Maschinelles Lernen).

Autoren: Leonid Lopatin, Pavel Filonov

Die Immobilienbranche ist trotz einer langen Entwicklungszeit nach wie vor handwerklich, vorindustriell, uneinheitlich und fragmentiert. Jeder an diesem Prozess Mitwirkende, sei es in der Planungs-, Bau- oder Betriebsphase, verfolgt eigene Ziele, hat spezifische Aufgaben, nutzt unterschiedliche Werkzeuge und Automatisierungsmethoden sowie separate Informationsquellen.

Das Aufkommen von Building Information Modeling (BIM) hat Visionären die Möglichkeit gegeben, ein Immobilienentwicklungsprojekt als einen durchgängigen informationstechnologischen Prozess darzustellen. Betrachten wir im Folgenden die einzelnen Phasen:

Planung: Die BIM-Methode hat eine revolutionäre Veränderung in der Herangehensweise an die Objektplanung bewirkt, indem sie die Möglichkeit bietet, das gesamte Objekt bis hin zur Fertigstellung in einem computergestützten, virtuellen Raum zu modellieren.

Bauen: Ausgehend von einem virtuellen Prototyp kann der Bau in der realen Welt als eine „Hard Copy“ des Objekts vorgestellt werden, vergleichbar mit einer 3D-Druckfunktion. Während der Ausschreibungs- und Bauausführungsphase wird das zuvor erstellte Modell

Bild: BPS

durch Informationen zu den tatsächlich im Projekt verwendeten Materialien, die Art der ausgeführten Arbeiten, den Lieferanten, Auftragnehmern, Preisen, Fristen usw. erweitert.

Das BIM Modell kann nach Bauabschluss in Analogie zum medizinischen Begriff als „Objektanatomie“ bezeichnet werden.

Betreiben: Vor der Inbetriebnahme stellt das BIM Modell eines Objekts eine „statische“ Aufnahme von dessen Anatomie dar. Der Beginn des Betriebs wird durch das Auftreten zahlreicher Prozesse geprägt, deren Dokumentation den Prozessen in lebendigen Organismen ähnlich sind. Das Informationsmodell beginnt nun, Echtzeit-Daten über die Prozesse in diesem „lebendigen Organismus“ zu empfangen. Diese Phase bezeichnen wir als „Connected BIM“.

Big Data – Vorteile von KI&ML

Wenn die umfangreichen Daten, die während der Planungs- und Bauphase gesammelt wurden, durch einen Datenstrom ergänzt werden, der während des Anlagenbetriebs gesammelt wird, eröffnet sich die Möglichkeit zur systematischen Analyse des digitalen Zwillings. Das Ziel besteht darin, die Planungs- und Bauentscheidungen zu überprüfen sowie die Betriebs- und Nutzungsprozesse einer Immobilienanlage zu optimieren.

Um die Vorgehensweise zu veranschaulichen, betrachten wir das System analog zu dem wie es in der Medizin funktioniert.

Jede medizinische Behandlung beginnt mit einem Gespräch mit dem Patienten. Beim Betreiben von Immobilien besteht die Herausforderung jedoch darin, dass im Gegensatz dazu ein Gebäude nicht mitteilen kann, ob etwas ‚wehtut‘, wann es sich ‚krank‘ fühlt oder wenn sein ‚Appetit‘ übermäßig zugenommen hat. Um bei der medizinischen Analogie zu bleiben – heutzutage messen BMS-Systeme lediglich grundlegende Parameter wie Puls, Blutdruck und Körpertemperatur. Diese sind von immenser Bedeutung und geben Aufschluss darüber, ob der „Patient“ lebt und stabil ist oder dringende Hilfe benötigt.

Jedoch reichen diese Parameter in der Medizin nicht aus, um einen nachhaltig gesunden Lebensstil zu führen oder plötzlich auftretende Krankheiten zu diagnostizieren und zu behandeln. Hier kommen fortschrittliche Technologien wie EKG, Ultraschall, Röntgen, CT, MRT, Blutuntersuchungen und weitere Methoden zur Anwendung.



In Situationen mit einer Vielzahl verbundener Zeitreihen haben sich Deep Learning-basierte Modelle bewährt.

Die herkömmlichen Gebäudemanagementsysteme (BMS) bieten lediglich eine beschränkte Anzahl von Variablen an. Diese umfassen grundlegende Komfortindikatoren für die Räumlichkeiten, die Funktionalität der grundlegenden technischen Systeme des Gebäudes sowie Benachrichtigungen über Unfälle und kritische Werte.

Die Anzahl der kontrollierten Variablen in einer modernen Anlage übersteigt selten Dutzende, Hunderte oder mehrere Hundert. Das Messintervall der Variablenwerte ist in der Regel recht lang, üblicherweise im Minuten-, Stunden- oder sogar Tagestakt. Solche Daten ermöglichen zwar bereits Schlussfolgerungen über den normalen Betrieb oder Fehlfunktionen bestimmter Systeme, aber sie reichen nicht aus, um ein umfassendes Bild der Systemfunktion oder Muster einzelner darin ablaufender Prozesse zu erstellen, die für eine detaillierte Analyse und Optimierung geeignet sind.

Die Dienstleister, die für die Verbesserung der Effizienz im Facility Management verantwortlich sind, bemängeln einen Mangel an Instrumenten, welche es ermöglichen, präzise zu verstehen, was vor Ort tatsächlich geschieht.

Für einen leistungsstarken Anlagenbetrieb sind umfangreiche Datenmengen erforderlich, die über viele Jahre gesammelt wurden und Millionen von Werten für Tausende von Variablen enthalten. Diese Daten müssen ordnungsgemäß nach Anlagenklasse, Position, Größe und Zweck strukturiert sein. Das größte Missverständnis besteht darin, dass die Daten zur Optimierung einfach dem BMS entnommen werden können, – denn genau diese notwendigen Daten stehen nicht zur Verfügung. Aussagen zu Datenquellen wie ‚wir haben eine offene API‘, ‚wir beziehen Daten vom BMS‘ oder ‚wir integrieren uns in die Plattformen der Gerätehersteller‘ sind nicht ausreichend vertrauenswürdig.

Die meisten Akteure im Bereich der ML&KI-Analytik vernachlässigen noch immer das bedeutende Thema der Verknüpfung von Daten mit der „Anatomie“ des Objekts und abstrahieren dieses mit allgemeinen Begriffen wie zum Beispiel „Daten aus dem HKLS-System“. Wenn man sich Anomalien mit der Frage nähert, „WO, WAS und WANN“ sie passiert sind und wie man darauf reagieren sollte, dann ist vor allem die Frage „WO“ entscheidend. Die genaue Lokalisierung ist der Schlüssel zur Analyse und zur effektiven Verwaltung von Anomalien, vergleichbar damit, wie Menschen präzise den Ort

eines Mückenstichs identifizieren und darauf unmissverständlich reagieren.

Die Optimierung von Prozessen basiert auf der Analyse von Prozessdaten. Die Prozessinformationen müssen eine für die Analyse und Optimierung geeignete Tiefe und Struktur aufweisen sowie zielgerichtet erhoben sein.

Dieses Verständnis führte zu einer Vorstellung davon, was als High Performance Operations (HiPerOps) für Immobilien betrachtet werden sollte. Mit der Entwicklung der HiPerWare-Plattform wurden all diese Herausforderungen gelöst und die Big-Data-Anforderungen erfüllt. Dadurch wurde es möglich, „Krankheiten“ und deren Behandlungen mit der HiPerWare Plattform zu systematisieren und eine Methodik für die Identifizierung von Symptomen, Diagnosen und Problemlösungen zu etablieren.

Für den nächsten Schritt, den Übergang vom Verständnis der Prozesse zum Training von KI&ML-Engines in High-Performance-Operationen, ist es notwendig zunächst die Anforderungen zu klären. KI&ML erfordert:

Big Data: Nur mit einer repräsentativen Stichprobe von korrekt erfassten Daten kann KI so trainiert werden, dass sie typische und nicht identifizierte Signaturen abnormalen Verhaltens erkennt.

Strukturierte Daten: Die Daten sollen strikt und einheitlich systematisiert, zeitlich synchronisiert und mit den „Organen“ der Anatomie des Objekts sowie ihrem Standort verbunden sein.

Das Ziel von Forschung und Optimierung ist durch eine mehrdimensionale Zeitreihe gekennzeichnet, in der viele Werte miteinander in Beziehung stehen. Um diese Art von Daten zu analysieren, lohnt es sich, Methoden zur Verarbeitung von Zeitreihen und deren Teilprobleme und Algorithmen zu betrachten.

Segmentierung von Zeitreihen

Steuersysteme können in verschiedenen Betriebsmodi arbeiten, die mit der Periodizität (Tag/Nacht, Winter/Sommer) und Änderungen in ihrer Konfiguration (technischer Modus, Starten, Anhalten, Umschalten) zusammenhängen. Ein wichtiger Schritt bei der Verarbeitung solcher Daten ist die Segmentierung der Zeitreihen in verschiedene Zustände. Dies ermöglicht die Anwendung unterschiedlicher



Leonid Lopatin ist Geschäftsführer der BPS Group, führender Experte für Building Information Modeling (BIM) und Mitbegründer von HiPer it! Er bringt umfassende Erfahrung als Luft- und Raumfahrtingenieur sowie IT-Spezialist mit. Mit mehr als 30 Jahren Führungserfahrung im IT- und Immobilienbereich (insbesondere in der Immobilienentwicklung und -verwaltung) hat er durch seine visionäre Führungsumgebung eine Atmosphäre geschaffen, die innovative Ideen fördert und maßgeblich zur Entwicklung von Produkten und Lösungen bei BPS International beiträgt. bpsinternational.de

Modelle innerhalb der einzelnen Segmente, je nach Typ (monoton, stationär, periodisch, transient, diskret usw.).

Es gibt mehrere Datensätze zur Bewertung der Qualität der Segmentierungsaufgabe, die jedoch nicht direkt mit der BIM-Landschaft in Verbindung stehen.

Klassifizierung von Zeitreihen

Jedes extrahierte Segment wird entsprechend der Art der Zeitreihe oder dem Namen des Modus, in dem das Gerät gerade funktioniert, klassifiziert. Klassische ML-Algorithmen und Deep-Learning-Methoden können bei einer solchen Aufgabe gute Ergebnisse erzielen, vorausgesetzt, es wird viel Aufwand in die Datenerfassung, -bereinigung und -aufteilung investiert. Auf der Grundlage der vorhergesagten Klassen können Systeme entwickelt werden, welche die für den Betrieb der Anlage verantwortlichen Personen warnen, wenn das System beispielsweise in einen anderen Modus umgeschaltet hat, der als potenzieller Notfall oder ineffizient eingestuft wird.

Jeder ML-Algorithmus macht Fehler, deren Anteil in der Trainings- und Validierungsphase vorläufig geschätzt wird. Bei der Integration in ein Alarmsystem ist es besonders wichtig, die Rate der falsch-positiven Meldungen zu kontrollieren. Aus der Praxis des Betriebs solcher Lösungen ist bekannt, dass das Vertrauen der für die Ergebnisverarbeitung zuständigen Personen in das System erheblich sinkt und es nicht mehr als effektives Instrument betrachtet wird, wenn die Anzahl der falsch-positiven Meldungen sehr hoch ist, sei es durch ihre Häufigkeit (mehrmals am Tag) oder ihren Anteil (mehr als 90 Prozent).

Erkennung von Anomalien

Wenn es nicht möglich ist, Zeitreihen zu kennzeichnen oder wenn neue Zustände auftreten, können Ansätze zur Erkennung von Anomalien in Betracht gezogen werden. Im Gegensatz zur Klassifizierung werden bei der Anomalieerkennung keine Kennzeichnungen benötigt, um das Modell zu trainieren, sondern lediglich, um seine Metriken zu schätzen. Dies gilt bereits im Testbetrieb. Insbesondere in Situationen mit einer Vielzahl verbundener Zeitreihen haben sich Deep Learning-basierte Modelle bewährt. Dies ist besonders nützlich im Zusammenhang mit Steuersystemen, bei denen sich verschiedene Parameter und Zustände gegenseitig beeinflussen können. Solche Modelle können

Autorenbilder: BPS

automatisch Anomalien erkennen, nicht nur in den Werten der Zeitreihen, sondern auch in ihrer Dynamik und den Wechselwirkungen zwischen ihnen.

Die HiPerWare-Plattform identifizierte beispielsweise die Ursache für einen übermäßigen Energieverbrauch der Kühlanlagen zur Aufrechterhaltung einer Temperatur von -18°C in einem Kühlhaus. Das herkömmliche SCADA-System konnte die Ursache zuvor nicht feststellen. Die instrumentelle Analyse, die Messung des Betriebsverhaltens der Kühlanlage-Energieverbrauch (1 Messung pro Sekunde), Temperatur und Druck – ergab, dass die Kühlanlage Nummer 3 in einem falschen Modus betrieben wurde und sich mehrmals pro Minute ein- und ausschaltete. Dies führte zu einem erhöhten Verschleiß und Energieverbrauch.

Genau wie Menschen müssen auch Gebäudeanlagen regelmäßig überprüft werden, um potenzielle Probleme zu erkennen und den Betrieb zu optimieren. In diesem Fall ermöglichte die Big-Data-Analyse in der HiPerWare-Plattform die Identifizierung von Problemen im Betriebsmuster der Kühlanlage, die im bestehenden SCADA-System nicht sichtbar waren. Dadurch konnten 12 Prozent des Energieverbrauchs eingespart, die Lebensdauer der Geräte verlängert und das Risiko von Unfällen und Überlastungen des Stromnetzes aufgrund hoher Einschaltströme verringert werden.

Ein entscheidender Aspekt bei der Anwendung von Methoden zur Erkennung von Anomalien in Steuersystemen ist die kontinuierliche Kontrolle der Algorithmus-Metriken. Neben der Kontrolle des Anteils der falsch-positiven Meldungen sollte auch die Zeit bis zur Erkennung einer Anomalie reduziert werden. Es ist von großer Bedeutung, eine verdächtige Situation so früh wie möglich zu melden, um den Zeithorizont für Untersuchungen und Entscheidungen zu verlängern. Auf diese Weise können Geräteausfälle im Frühstadium verhindert oder erhebliche Energieeffizienzverluste über einen langen Zeitraum hinweg vermieden werden. Daher müssen die Modellparameter und Empfindlichkeitsstufen sorgfältig angepasst werden, um Fehlalarme zu minimieren und ein stabiles sowie genaues System zur Erkennung von Anomalien zu gewährleisten.

Mehrere Studien zur Anwendung von Anomalieerkennung im Gebäudemanagement betonen die praktische Möglichkeit, Modelle auf Rohdaten zu trainieren, ohne vorher eine Kennzeichnung der Daten vornehmen zu müssen.

Optimierungspotenzial des Immobilienmarktes

Der Immobiliensektor bietet enorme Möglichkeiten zur Optimierung der Betriebskosten und zur Senkung des Energieverbrauchs, die heute nur unzureichend genutzt werden. Dies resultiert aus der Verwendung von veralteten Gebäudemanagementsystemen und Betriebskonzepten, die auf Denkweisen und Technologien aus dem letzten Jahrhundert basieren.

Gebäude in der EU verbrauchen 40 Prozent der Energie und verursachen jährlich 36 Prozent aller Treibhausgasemissionen. Bis heute stellen Gebäude den größte Energieverbraucher in der EU dar. Im Vergleich dazu trägt der Luftverkehr in der EU zu lediglich 3,8 Prozent der CO₂-Emissionen bei. Es ist offensichtlich, dass die Optimierung des Energieverbrauchs im Immobiliensektor von größter Bedeutung ist, um die Ziele des europäischen Green Deal, die ESG- und internationalen Ziele, einschließlich der Ziele für nachhaltige Entwicklung, zu erreichen.

Auf EU-Ebene und in den einzelnen Ländern wird eine Vielzahl von Maßnahmen ergriffen, um die Energie- und Ressourceneffizienz neuer Gebäude und Infrastrukturen zu optimieren und bestehende Einrichtungen zu renovieren. Im Jahr 2050 werden mehr als 85 Prozent der bestehenden Gebäude in Betrieb sein.

Die Internationale Energieagentur (IEA) betont, dass die Digitalisierung, einschließlich KI-Technologien, transformative Technologien umfasst, die die Energieeffizienz, auch in Gebäuden, radikal verbessern können.

Fazit

Steve Jobs sagte einmal: „Ein Computer war schon immer ein Fahrrad des Geistes“. Seitdem haben Computer in viele Bereiche unseres Lebens Einzug gehalten, und der menschliche Fortschritt ist nicht nur mit Erfindungen und Entdeckungen verbunden, sondern auch mit der besonderen Gabe, vertraute Dinge mit anderen Augen zu sehen. So eine neue Sicht der Gebäudesysteme bietet uns die KI-basierte Modelanalyse. Nutzen Sie die Technologien und Werkzeuge, die sich in Deutschland in realen Projekten bewährt haben.

Think different: Gemeinsam gestalten wir die Zukunft des digitalen Life-cycles von Immobilien. Hiper it! Technologien sind bereits Realität. ■



Pavel Filonov ist Experte für maschinelles Lernen und künstliche Intelligenz mit Spezialisierung auf Probleme der Zeitreihenverarbeitung und Anomalieerkennung. Teilnahme an Projekten zur Anomalieerkennung in Industrieanlagen. Autor mehrerer Publikationen zum maschinellen Lernen in Industrieanlagen einschließlich der Thesen zu NeurIPS und ICML Konferenzen. Derzeit entwickelt er das Geschäftsfeld Künstliche Intelligenz bei Hiper It! bpsinternational.de