

Nowoczesne Systemy Zarządzania
Zeszyt 18 (2023), nr 1 (styczeń-marzec)
ISSN 1896-9380, s. 29-48
DOI: 10.37055/nasz/174986

Modern Management Systems
Volume 18 (2023), No. 1 (January-March)
ISSN 1896-9380, pp. 29-48
DOI: 10.37055/nasz/174986



Instytut Organizacji i Zarządzania
Wydział Bezpieczeństwa, Logistyki i Zarządzania
Wojskowa Akademia Techniczna
w Warszawie

Institute of Organization and Management
Faculty of Security, Logistics and Management
Military University of Technology
in Warsaw

Zarządzanie nieruchomościami z wykorzystaniem kognitywnej maszyny wnioskującej

Real estate management using a cognitive reasoning machine

Dariusz Nowak-Nova

Akademia WSB w Dąbrowie Górniczej
dnowaknova@gmail.com; ORCID: 0000-0002-7556-5677

Abstrakt. W artykule przedstawiono możliwość zastosowania Automatycznych Modeli Wyceny (AVMs), rozszerzonych o technologie algorytmów uczenia maszynowego i sztuczne sieci neuronowe, do przetwarzania kognitywnego w obszarze Facility Management. Opisano eksperymenty symulujące w procesach operacyjnego zarządzania nieruchomością, zachowania AVMs w kognitywnej maszynie wnioskującej. Badano poprawność działania algorytmów usług decyzyjnych wywoływanych przez zautomatyzowane silniki wnioskujące dla generalizacji informacji o nieruchomości oraz procesu planowania wykorzystującego algorytmy. Kluczowe wnioski z badania potwierdzają, że przyjęcie dla AVMs perspektywy kognitywnej i zastosowanie technologii algorytmów i sztucznych sieci neuronowych w operacyjnym zarządzaniu nieruchomością zwiększa produktywność procesów, tym samym przynosi korzyść zarządzającemu.

Słowa kluczowe: Automatyczne Modele Wyceny, zarządzanie nieruchomościami, uczenie maszynowe, sieci neuronowe, systemy kognitywne

Abstract. The article presents the possibility of using Automatic Valuation Models (AVMs), extended with technologies of Machine Learning algorithms and Neural Networks, for cognitive processing in the area of Facility Management. Experiments simulating, in the processes of operational management of real estate, of AVMs's behavior in a cognitive reasoning machine, have been described. The correctness of operation of decision service algorithms, triggered by automated inference engines, has been examined for generalization of information on the property and the planning process using the algorithms. The key findings of the study confirm that the adoption of a cognitive perspective for AVMs and the application of algorithm technology and artificial neural networks in the operational management of real estate, increases the productivity of the processes, and, thus brings benefits the managing entity.

Keywords: Automated Valuation Models, real estate, Machine Learning, Neural Networks, Cognitive Systems

Wstęp

Cyfryzacja staje się coraz bardziej powszechna w sektorze nieruchomości. Istnieją liczne, opisane przez wielu autorów, narzędzia informatyczne (ICT) wspierające operacyjne zarządzanie nieruchomościami (Cheng, Chen, Tan, Wang, 2016; Bucoń, Tomczak, 2018; Gavu, Tudzi, Ayitey, 2015). Istnieje niedostatek opracowań wiążących ICT z możliwościami obliczeń kognitywnych, opartych na metodach zalgorytmizowanego wnioskowania, ułatwiających zarządzanie nieruchomościami. Wydaje się, że poszerzenie możliwości ICT o zdolności poznawcze, przez zalgorytmizowane przetwarzanie informacji i automatyzację operującą w warstwie danych, komunikacji i aplikacji, może zwiększyć produktywność procesów zarządzania (Xu, Weisheng, Fan, Ke, 2019).

Normatywnie za procesy zarządzania nieruchomością odpowiada koncepcja *Facility Management* (FM) jako zorientowane na klienta całościowe świadczenie, którego przedmiotem są kompleksowe zasady podejmowania decyzji dla optymalnego planowania, użytkowania i przystosowania budynków, ich urządzeń i świadczeń; które wzmacniane są przez systemy ICT (Pruszkowski, 2012). Tradycyjne metody wyceny nieruchomości ewoluują w zaawansowane metody wykorzystujące ICT do automatyzacji procesów wyceny. Automatyczne Modele Wyceny (Automated Valuation Models, AVMs) są usługą umożliwiającą wycenę nieruchomości z użyciem modelowania matematycznego (Kara, Çağdaş, Işıkdağ, Bulent, 2018; Bilgilioglu, Hacı, 2021; Carranza, Piumetto, Lucca, Da Silva, 2022).

Przedmiotem eksperymentów była weryfikacja możliwości zastosowania AVMs w procesach FM. Weryfikowano, czy generalizacja i metody analiz porównawczych korzystające z sieci neuronowych i uczenia maszynowego, nadają się jako silniki wnioskujące w AVMs oraz czy zastosowanie AVMs do pomiaru wartości dla własności nieruchomości przynosi korzyść zarządzającemu taką nieruchomością.

Tło teoretyczne

Kognitywny system wnioskujący

Systemy informacyjne (SI) oparte na sztucznej inteligencji (Artificial Intelligence, AI) i wykorzystujące uczenie maszynowe (Machine Learning, ML) do rozumowania maszynowego (Machine Reasoning, MR) odgrywają coraz ważniejszą rolę w funkcjonowaniu organizacji.

Machine Learning to technologia, która opiera się na analizie danych pod kątem występowania wzorców. Algorytmy ML są w stanie przetwarzać szybko duże ilości danych i „odnajdywać” ukryte w nich wzorce potrzebne do przewidywania rezultatu. Algorytmy ML, jako oparte na metodach statystycznych i deterministyczne,

nie zapewniają jednak metody śledzenia przyczyn powstania rezultatu. W celu rozpoznania przyczyn stosuje się technologię MR.

Rozumowanie maszynowe to technologia rozszerzająca rezultaty uzyskiwane przez ML o syntezę opartą nie tylko na źródłach informacji, lecz także na kontekstach i wnioskach. Machine Reasoning bazuje na logicznie następujących po sobie faktach oraz na danych charakteryzujących się niejednoznacznością i niepewnością. Buduje i wiąże modele semantyczne, które najlepiej odwzorowują logiczne rozumowanie. Rozumowanie maszynowe generuje nie tylko odpowiedzi na problemy numeryczne, lecz także tworzy hipotezy i zalecenia, eliminując subiektywność oraz dokładność i gwarantując szybkość. Skoro przetwarzanie informacji, polegające na manipulowaniu reprezentacjami odnoszącymi się do świata zewnętrznego, odbywa się w sposób tak wysoce zorganizowany, to może być nazwane inteligentnym (Nowak-Nova, 2018). Tak odwzorowane technologicznie mechanizmy poznawcze mogą być używane do procesów decyzyjnych: (i) postrzegania informacji, (ii) zrozumienia wyników obserwacji z wykorzystaniem istniejącej wiedzy oraz (iii) podejmowania uzasadnionej zmiany w otoczeniu. Systemy realizujące takie procesy nazywa się systemami kognitywnymi (*Cognitive Systems*, CS), ponieważ realizowane przez nie obliczenia mogą symulować procesy myślowe człowieka w modelu komputerowym (Babu, Venkataram, 2009; Lemaignan, Warnier, Sisbot et al., 2017).

Systemy wcześniejszych generacji były deterministyczne, systemy kognitywne są probabilistyczne. *Cognitive Systems* mają wystarczający potencjał do holistycznej interpretacji danych w dynamicznym środowisku biznesowym. Badania wykazujące luki w tradycyjnych systemach decyzyjnych wskazują, że systemy CS, dzięki dostępowi do nieograniczonej informacji, umożliwiają organizacjom zwiększanie wydajności (Kaur, Shivam, Sanjay, Mirko, 2019; Welck, Derdak, Veit, 2020).

Pomiar wartości dla nieruchomości

Zarządzanie nieruchomością analizować można w aspekcie finansowym (poziom dochodów z nieruchomości), technicznym (stan techniczny, infrastruktura i wyposażenie), prawnym (warunki najmu, stan prawny) czy użytkowym (bieżąca obsługa, świadczenie usług pomocniczych). Obszary te mogą być wspierane technologiami ICT opartymi na identyfikacji poszczególnych czynników dla konkretnej nieruchomości (Śliwiński, Śliwiński, 2006; Kozicki, Mitkow, Sowa, 2021). Wartość nieruchomości może być więc kształtowana przez działania w różnych obszarach zarządzania, tj. finansowym, technicznym, prawnym czy użytkowym. Dotyczy to także operacyjnego zarządzania związanego z bieżącą eksploatacją i utrzymaniem nieruchomości (vom Brocke, Recker, Mendling, 2010).

Koncepcja *Facility Management* (FM) opracowana przez konsorcjum stowarzyszeń zarządzających obiektami International Facility Management Association (IFMA),

postuluje dodawanie i utrzymywanie wartości nieruchomości w obszarach rzeczywistego jej stanu oraz ciągłego ulepszania wymagań operacyjnych (ISO 41011:2017, 2017). Procesy te kontrolowane są przez badanie stanu faktycznego dotyczącego: (i) gospodarności – rozumianej jako ocena procesów z punktu widzenia racjonalności i efektywności podejmowanych decyzji oraz (ii) celowości – rozumianej jako eliminacje działań niekorzystnych i zbędnych z punktu widzenia interesów organizacji (Thomas, 2014). Oznacza to konieczność opracowania mechanizmów pozwalających na stworzenie systemu długookresowego monitorowania kosztów nieruchomości. Jako koszty postrzegane są zarówno wartości finansowe dotyczące bieżącej obsługi nieruchomości, jak i koszty zadań remontowo-modernizacyjnych, w tym koszty planowanych prac wynikające ze zużycia się nieruchomości. Tak postrzegane FM staje się funkcją zarządzania, która koncentruje się na tym, jak rozwijać, utrzymywać i ulepszać zasoby fizyczne potrzebne do wspierania i dodawania wartości do procesów biznesowych organizacji (Xu, Weisheng, Fan, Ke, 2019; Śmietana, 2013; Pruszkowski, 2012).

Automatyczne Modele Wyceny

Automatyczne Modele Wyceny (Automated Valuation Models, AVMs) postrzegane są jako szybka i wygodna usługa wyceny nieruchomości, realizowana przez aplikacje komputerowe, wykorzystujące podejścia statystyczne do analizy związku między wartością nieruchomości a jej cechami użytkowymi (Mayer, Bourassa, Hoesli, Scognamiglio, 2019; Renigier-Biłozor, Chmielewska, Włacik et al., 2021; Lorenz, Willwersch, Cajias, Fuerst, 2022; Steurer, Hill, Pfeifer, 2021). Dostępne są dwie formalne definicje AVMs:

1. Definicja TEGoVA zawarta w Europejskich Standardach Wyceny EVIP 6 (TEGoVA 2017):
„Modele automatycznej wyceny (AVMs) można zdefiniować jako programy komputerowe oparte na statystykach, które wykorzystują informacje o nieruchomości (np. porównywalna sprzedaż i cechy nieruchomości itp.) do generowania wartości związanych z nieruchomościami lub sugerowanych wartości”.
2. Definicja International Association of Assessing Officers, IAAO, zawarta w specyfikacji standardu AVMs (I.A.A.O., 2018):
„Program komputerowy oparty na matematyce, który umożliwia oszacowanie wartości rynkowej na podstawie analizy lokalizacji, warunków rynkowych i charakterystyki nieruchomości na podstawie informacji, które zostały wcześniej zebrane oddzielnie”.

Można stwierdzić, że AVMs są programami komputerowymi służącymi do oszacowania wartości rynkowej nieruchomości na podstawie analizy jej lokalizacji, właściwości i warunków rynkowych. AVMs opiera się na trzech elementach składowych procesu wyceny: (i) bazie informacji zawierającej dane o cechach nieruchomości

i cenach transakcyjnych, (ii) analizie zgromadzonej informacji, (iii) wartości wyceny. Czynność wyceny realizowana jest przez informatycznego agenta programowego, działającego zgodnie z mechanizmami workflow, poszukującego opisu cech rynkowych nieruchomości wpływających na poziom ich cen oraz warunków zawarcia transakcji (O.M.G.WfMC Specification, 2000). Cechy te definiują przepisy prawa dotyczące zasad wyceny nieruchomości oraz standardy zawodowe jako reguły postępowania.

Nałożenie na AVMs perspektywy kognitywnej i zastosowanie technologii sztucznych sieci neuronowych (Neural Networks, NN) oraz algorytmów uczenia maszynowego (Machine Learning, ML) stworzyło warunki do zbadania możliwości samodzielnego podejmowania decyzji przez kognitywną maszynę wnioskującą. Przy czym samodzielność oznacza działanie: (i) bez oczekiwania na ludzkie instrukcje, (ii) uczenie się dzięki informacjom zwrotnym, a także (iii) mechanizmy do eksploracji danych.

Metoda badawcza

W eksperymentach symulowano możliwość zastosowania AVMs w obszarze operacyjnego gospodarowania nieruchomościami. Badano poprawność zachowania się kognitywnych algorytmów jako silników wnioskujących dla generalizacji informacji o nieruchomości. Przedmiotem badania były modele procesów stanowiących element FM oraz automaty decyzyjne sterowane przez algorytmy. Jako środowisko demonstratora wykorzystano oprogramowanie IBM Rational Software Architect (RSA) (IBM, 2023) w wersji 9.7. Do badania efektywności działania procesów wykorzystano oprogramowanie TIBCO Business Studio (TIBCO, 2023) w wersji 4.2.0.

W badaniu modelowane były: (i) procesy operacyjne obejmujące identyfikowanie potrzeb remontowych, wynikające z oceny stanu technicznego nieruchomości, oraz (ii) procesy planowania wydatków bazujące na kosztach bieżącej eksploatacji oraz przedmiarowaniu robót dla prac remontowych.

Jako dane wejściowe do eksperymentów przyjęto informacje dotyczące nieruchomości będących w zarządzie organizacji odpowiedzialnej za gospodarowanie i zarządzanie łącznie 446 budynkami mieszkalnymi, 180 mieszkalno-użytkowymi oraz 372 budynkami użytkowymi, w których znajduje się 14 009 lokali mieszkalnych i 1235 lokali użytkowych. Jako dane dotyczące przeprowadzonych prac remontowych w lokalach przyjęto liczbę 1201 wyremontowanych lokali mieszkalnych niezasiedlonych, 545 lokali mieszkalnych zasiedlonych oraz 174 wyremontowanych lokali użytkowych. Dla prowadzonych w latach 2019-2021 robót przyjęto liczbę 48 remontów ogólnobudowlanych, 20 robót instalacyjnych, 3 roboty wykończeniowe, 28 opracowań projektowych, 16 opinii i ekspertyz technicznych oraz 102 173 prac naprawczych i skutków awarii. Dane dostarczano w postaci plików

płaskich, wyekstrahowanych z systemów wykorzystywanych do bieżącego zarządzania nieruchomościami, semantycznych plików .pdf i .docx oraz arkuszy kalkulacyjnych .xlsx. Na potrzeby badań transformowano je do postaci tekstowej .txt.

Eksperyment 1: Pomiar wartości za pomocą generalizacji

W badaniu (RQ1) weryfikowano, czy generalizacja i metody analiz porównawczych, korzystające z sieci neuronowych i uczenia maszynowego, nadają się jako silniki wnioskujące w AVMs.

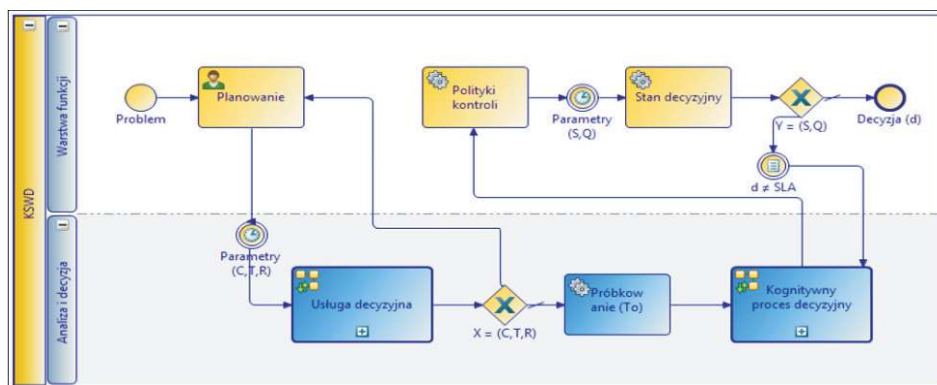
Struktura modelu maszyny wnioskującej zastosowanej w eksperymencie składała się z modułów odpowiedzialnych za wykonywane funkcje, tworzące razem cykl procesowy sprzężenia zwrotnego i ciągłego doskonalenia się modułów tworzących cykl. Zastosowano moduły: (i) <Planowanie> – odpowiadający za projektowanie celów i zawierający specyfikację kryteriów, wskaźników i zmiennych dla wydajności procesu; (ii) <Analiza i decyzja> – wykorzystujący zmienne i proponujący rozwiązania; (iii) <Polityki kontroli> – nadzorujący dotrzymanie przez proces rygorów normatywnych oraz wprowadzający korekty zachowania procesu; (iv) <Stan decyzyjny> – prezentujący najlepsze decyzje będące efektem procesu decyzyjnego.

Na potrzeby badania przyjęto następujące kroki:

<Planowanie> określa cele oraz kryteria wyników określających granice celu (SLA). Indeksy (Y) reprezentują wydajność będącą satysfakcją klienta (S) i jakość opracowanego planu (Q). Indeksy (Y) zależą od parametrów wydajności: $Y = (S, Q)$. Parametry (X) są reprezentowane przez zmienne stanu decyzyjnego i obejmują: koszt (C), terminowość (T) i kompletność (R). Parametry (X) prezentowane są za pomocą wzoru: $X = (C, T, R)$. Na etapie uruchamiania procesu ich wartości są określane na podstawie parametrów zawartych w bazach danych tworzących <Usługi decyzyjne>. Miarami są funkcje (f) używane do mapowania współczynników zmiennych stanu decyzyjnego (X) na wskaźniki wydajności (Y) zgodnie z równaniem $f: X \rightarrow Y$.

<Próbkowanie> (TO) związane jest ze zbieraniem jakościowych i ilościowych informacji o zmiennych (X). Wektor X zawiera C, T i R, które reprezentuje okres zbierania nowych informacji o X. W badaniu (TO) definiowane jest jako równe okresowi planowania, dlatego informacje o koszcie rzeczywistym (CA) i rzeczywistej kompletności wymagań (RA) są generowane na koniec procesu.

<Analiza i decyzja> dotyczy obliczeń oraz oceny wskaźników poprawności analizowanej informacji. Krok mapuje wskaźniki C, T i R na wskaźniki wydajności S i Q. Zadanie jest realizowane przez podproces <Kognitywny proces decyzyjny>, który oblicza indeksy dla S i Q na podstawie kosztów rzeczywistych (CA) i informacji o kompletności wymagań (RA), które są próbkowane w czasie (To). Etap <Planowanie> dostarcza informacje o Co i Ro (które reprezentują <Koszt planowania> i <Kompletność wymagań>). W badaniu przyjęto, że czas rzeczywisty (TA) jest równy czasowi próbkowania (TO), dlatego nie jest on uwzględniany jako zmienna do obliczeń.



Rys. 1. Model działania kognitywnej maszyny wnioskującej w notacji BPMN

Źródło: opracowanie własne na podstawie badań

<Polityki kontroli> regulują zachowanie procesu. Uwzględniają przepisy prawa, normy, standardy i regulacje wewnętrzne organizacji zaimplementowane w regułach workflow opartych na <ontologii> i sterujących przepływem procesu, zapewniając, że wytworzona przez <Kognitywny proces decyzyjny> wykorzystujący <Nadzorowane uczenie maszynowe> decyzja (d) będzie zgodna z założonym (SLA).

Model maszyny wnioskującej przedstawia rysunek 1.

Eksperyment 2: Pomiar wartości za pomocą AVMs

W badaniu (RQ2), uznając, że AVMs używane są do oszacowania wartości rynkowej nieruchomości na podstawie analizy jej lokalizacji, właściwości i warunków rynkowych, weryfikowano, czy zastosowanie AVMs do automatycznej oceny właściwości nieruchomości, przynosi korzyść zarządzającemu nieruchomością. W tym celu stworzony został proces AVMs, oparty na wywoływanych zautomatyzowanych usługach decyzyjnych, który do ustalenia wartości używa pomiaru za pomocą algorytmów technologii kognitywnych.

AVMs wykorzystują techniki oceny. W pierwszym kroku dane są gromadzone i analizowane w celu opracowania modelu oceny, który można zastosować do równoważnych nieruchomości na tym samym lub podobnym obszarze. Następnie dane podlegają stratyfikacji mającej na celu zorganizowanie ich w jednorodne grupy charakteryzowane podobnymi właściwościami – <Wektorami> warstw. W dalszych krokach warstwy te podlegają korektom, oceniającym populację właściwości, a następnie kalibracji określającej współczynnik związany z każdą zmienną. Kalibracja z zastosowaniem algorytmów sieci neuronowych pozwala na kalibrowanie modeli, na które składają się dane analizowane zarówno liniowo, jak i nieliniowo.

Po wprowadzeniu zmiennej z przypisanymi wagami komponent oprogramowania definiowany jako <Agent Algorytm> eksploruje i porządkuje dane, odnajdując ich najlepsze dopasowania. W procesie dopasowania wykorzystywane są mechanizmy zawarte w warstwie ukrytej, w której wagi są korygowane (kalibrowane) w sposób zmniejszający kwadrat błędu. Proces przebiega iteracyjnie, podobnie dla przebiegów regresji hybrydowej (nieliniowej). Sprawność procesu zależy od ilości iteracji, ponieważ sieć neuronowa uczy się na bieżąco w miarę przyjmowania nowych informacji oraz przetwarzania ich w celu rozpoznawania i dopasowywania niejasnych lub niekompletnych wzorców danych. Końcowe dane wyjściowe skutkują pojedynczym oszacowaniem wartości.

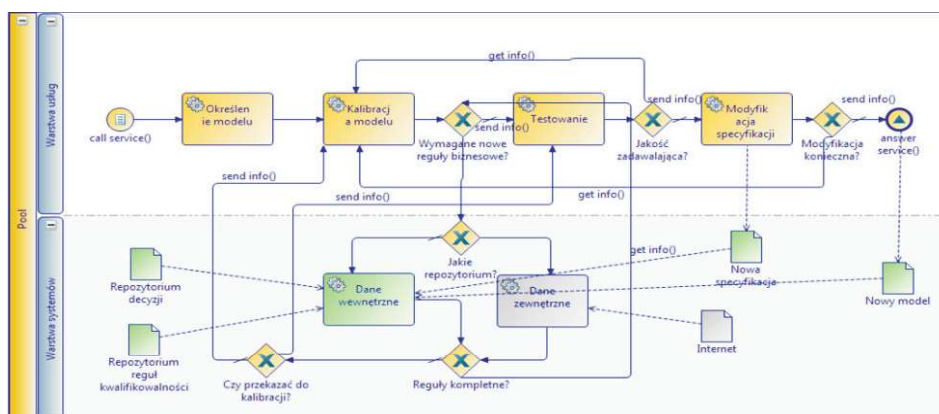
Pomiar wartości w <Usługach> udostępnianych w <Szybie usług> został zaprojektowany w taki sposób, by spełnić zestaw poniższych kryteriów:

<Agent workflow> identyfikuje rodzaj żądania i następuje <Określenie modelu> zgodnie z rodzajem <Usługi kognitywnej> tworzącej <Regułę biznesową>.

<Kalibracja modelu> wykorzystuje specyfikacje procesów biznesowych, transformując je na reguły eksploracji danych, zgodnie z kontrolowanym słownikiem <ontologii>. Wykonujący to zadanie <Agent algorytmiczny> może zgłosić wyjątek lub kilka typów wyjątków. Wyjątki są przechwytywane przez <Agent workflow> obsługującego wyjątki. Wyjątek obsługiwany jest przez wywołanie wartości <Wektor cech> decydującej, czy <Reguła biznesowa> wymaga informacji retrospektywnej, zawartej w <Danych wewnętrznych>, czy też żądania informacji lub danych w <Danych zewnętrznych>. Po skompletowaniu danych nowa wartość jest sprawdzana i albo wraca do <Kalibracji modelu>, albo jest przekazywana bezpośrednio do <Testowania>. Wyjątki są rejestrowane w repozytoriach w celach ich poprawnej obsługi w przyszłości.

<Testowanie> odpowiada za badanie trafności uogólnień w innych okolicznościach, weryfikując granice tych uogólnień. <Agent workflow>, działając w rygorach określonych ustalonymi miarami <Kryteriami jakości>, bada, czy wybór odpowiada poziomowi satysfakcji. Proces jest powtarzany iteracyjnie, aż testy zapewnienia jakości modelu zostaną spełnione.

<Modyfikacja specyfikacji> następuje wówczas, gdy <Kalibracja modelu> wymaga zastosowania nowych lub modyfikacji istniejących <Reguł biznesowych>. W takim przypadku <Agent workflow> obsługuje polecenie <send info()> do <Kalibracja modelu>, rozpoczynając ponowną ocenę. W wypadku powstania nowej <Reguły biznesowej> jej <Nowy model> trafia do repozytorium. Po poprawnym zakończeniu procesu sterowanie przesyła poza proces polecenie <answer service()> (zob. rys. 2).



Rys. 2. Schemat modelu pomiaru wartości w kognitywnych usługach udostępnianych przez szynę usług w notacji BPMN

Źródło: opracowanie własne na podstawie badań

Zadania klasyfikacji wywoływane były przez niezależnie wykonywane przepływy kompletnych zadań ML. Podzadania były zamknięte jako serie kroków utworzone z następujących elementów:

<Gromadzenie danych> – będące definicją problemu, która prowadzi do określenia zakresu danych biznesowych.

<Transformacja danych> – odpowiadająca za procesy czyszczenia danych i określenie inżynierii funkcji, czyli wartości, których model używa zarówno podczas uczenia, jak i produkcji.

<Dane wejściowe> – służące nauce przez model nauki nadzorowanej, tak by model był w stanie nauczyć się i przewidzieć wymaganą <klasę problemu> dla rozwiązania zadanego problemu biznesowego.

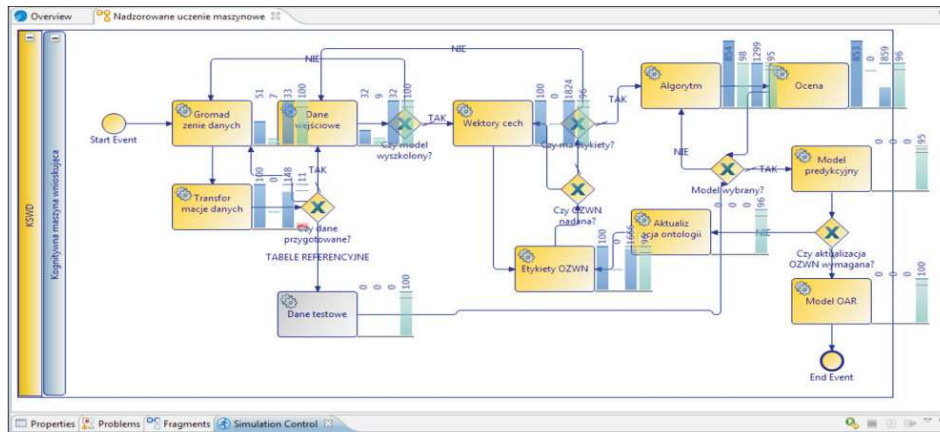
<Wektor cech> – zawierający informacje opisujące właściwości <Dane wejściowe>.

<Etykiety> – predefiniowane w <ontologii> kategoriami <klas ontologicznych> uwzględnianych przez model.

<Algorytm> – badany algorytm NN stosowany w badaniu.

<Model predykcyjny> – prezentujący wyniki oparte na zbiorze <Dane wejściowe> oraz przewidujący nowe <Etykiety>.

Strukturę modelu wraz z blokami funkcjonalnymi demonstruje rysunek 3.



Rys. 3. Interfejs TIBCO Business Studio prezentujący przebieg procesu wnioskowania opartego na nadzorowanym uczeniu maszynowym i automatycznych modelach wyceny

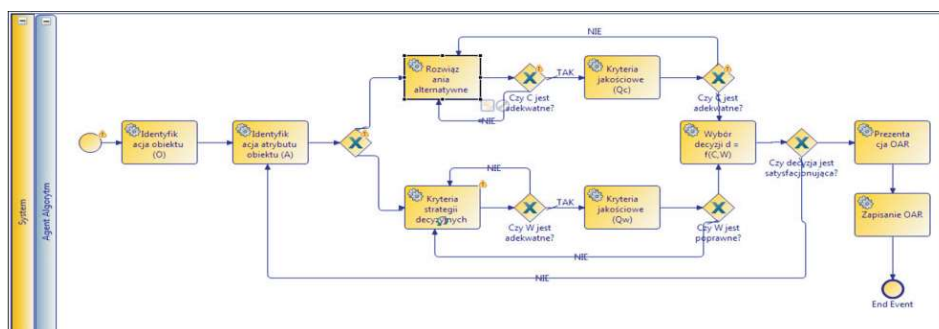
Źródło: opracowanie własne na podstawie badań

Rezultaty

RQ1: Czy generalizacja i metody analiz porównawczych, korzystających z sieci neuronowych i uczenia maszynowego, nadają się jako silniki wnioskujące w AVMs?

Kognitywny proces decyzyjny, napędzający <Usługę Zasób lokalowy>, <Usługę Ewidencja>, <Usługę Najem>, <Usługę Eksploatacja> stanowiących razem <Usługę decyzyjną>, odbywał się w środowisku <Szyny usług> i realizowany był przez <Agenta Algorytm> działającego według schematu OAR.

Przyjęty na potrzeby badania schemat, prezentowany w postaci OAR = (O, A, R), zapewniał jednolity model podejmowania decyzji, który gwarantował powtarzalność zastosowań w każdej stosowanej <Usłudze decyzyjnej>. Precyzja tak uzyskiwanego wyniku zależała od wielkości analizowanych zbiorów obiektów i ich atrybutów oraz decyzji wcześniej podjętych. Zgodnie z modelem decyzyjnym opisywanym notacją DMN (O.M.G.DMN Guide, 2019) decyzje wcześniejsze wzbogacały <Repozytorium decyzji>, dostarczając <Wiedzę biznesową> będącą podstawą uruchamiania kryteriów jakościowych, rozszerzając tym samym analizowane zbiory.

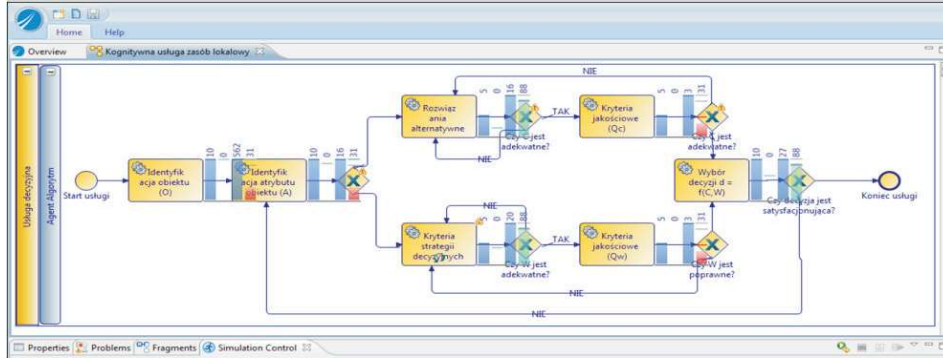


Rys. 4. Model kognitywnego algorytmicznego procesu decyzyjnego (dla pojedynczej decyzji) realizowanego przez <Agent Programowy> wykorzystujący logikę decyzyjną (Description Logic, DL) przedstawiony w notacji BPMN

Źródło: opracowanie własne na podstawie badań

<Usługa Zasób lokalowy>, <Usługa Ewidencja>, <Usługa Najem>, <Usługa Eksploatacja> uruchamiane były kolejno, tak by zawęzić obszar odnajdywanych zależności pomiędzy klasyfikacją O, ich atrybutami A oraz asocjacjami R. Za kategoryzację, klasteryzację i tworzenie asocjacji odpowiadała ontologia, dostarczająca rozpoznawalnych i zrozumiałych <pojęć> podlegających semantycznym analizom podczas wyszukiwania kryteriów przydatnych strategii decyzyjnych (C) oraz rozwiązań alternatywnych (W).

Ilościowe określanie C i W nadzorowane było przez ocenę jakościową (Qc i Qw). Wybór preferowanej decyzji następował na podstawie najbardziej dopasowanego spełnienia warunków trafności $d = f(C, W)$. Jako odchylenie standardowe dla poszczególnych usług przyjęto skalę zawężającą: od 0,4 w wypadku pierwszej <Usługi Zasób lokalowy> do 0,1 w przypadku ostatniej <Usługi Eksploatacja>. Pomimo że usługi realizowane były przez <Agenty> oprogramowania, to dla porównania efektywności pracy czas realizacji poszczególnych zadań podawany był w minutach, podobnie jak w przypadku personelu. W badaniu chodziło o zweryfikowanie efektywności wykonywanych zadań, a nie o sam czas ich realizacji. Założono zróżnicowany czas pracy każdej usługi, brak zadań wstępnych oraz oczekiwaną maksymalną efektywność wykorzystywania czasu pracy na poziomie 85%. Występowanie nowych zadań generowane było rozkładem jednolitym, podczas którego zadania mają równe prawdopodobieństwo rozpoczęcia się w zadanym przedziale określonym przez minimum i maksimum oraz zgodnie z terminem realizacji zadania. Zwizualizowane efekty działania poszczególnych usług pokazują kolejne rysunki i tabele.

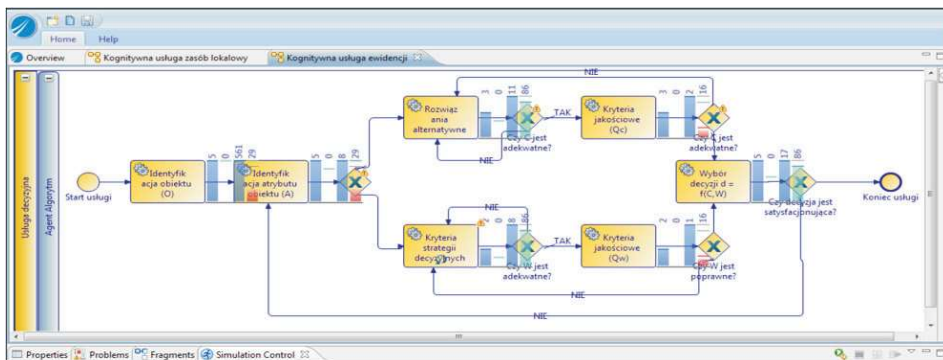


Rys. 5. Interfejs TIBCO Business Studio prezentujący wartości działań dla <Usługi Zasób lokalowy>
Źródło: opracowanie własne na podstawie badań

Tabela 1. Parametry efektywności kognitywnego procesu decyzyjnego dla <Usługi Zasób lokalowy>

Nazwa kroku	Liczba przypadków	Sprawy niezrealizowane	Suma korekt	Efektywność czasu pracy
Identyfikacja obiektu (O)	10	0	562	31
Identyfikacja atrybutu obiektu (A)	10	0	16	31
Rozwiązanie alternatywne (C)	5	0	16	88
Kryteria jakościowe (Qc)	5	0	3	31
Strategie decyzyjne (W)	5	0	20	88
Kryteria jakościowe (Qw)	5	0	3	31
Wybór decyzji (d)	10	0	27	88

Źródło: opracowanie własne na podstawie badań

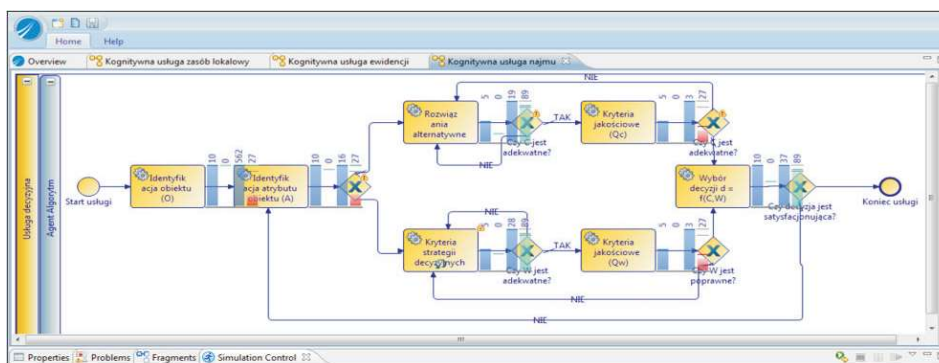


Rys. 6. Interfejs TIBCO Business Studio prezentujący wartości działań dla <Usługi Ewidencja>
Źródło: opracowanie własne na podstawie badań

Tabela 2. Parametry efektywności kognitywnego procesu decyzyjnego dla <Usługi Ewidencja>

Nazwa kroku	Liczba przypadków	Sprawy niezrealizowane	Suma korekt	Efektywność czasu pracy
Identyfikacja obiektu (O)	5	0	561	29
Identyfikacja atrybutu obiektu (A)	5	0	8	29
Rozwiązanie alternatywne (C)	3	0	11	86
Kryteria jakościowe (Qc)	3	0	2	16
Strategie decyzyjne (W)	2	0	8	86
Kryteria jakościowe (Qw)	2	0	1	16
Wybór decyzji (d)	5	0	17	86

Źródło: opracowanie własne na podstawie badań



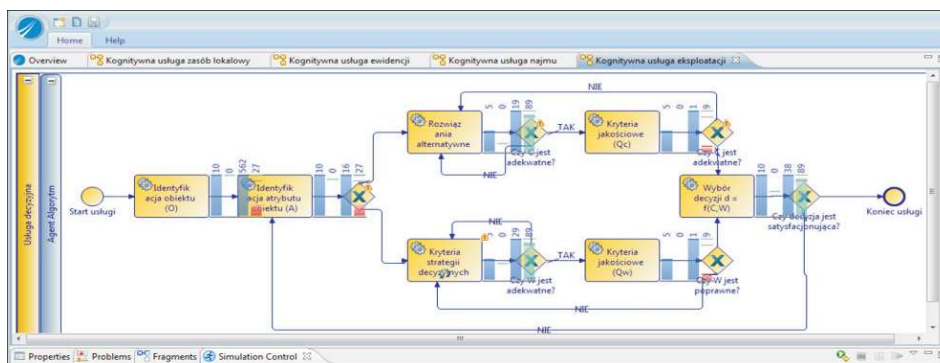
Rys. 7. Interfejs TIBCO Business Studio prezentujący wartości działań dla <Usługi Najem>

Źródło: opracowanie własne na podstawie badań

Tabela 3. Parametry efektywności kognitywnego procesu decyzyjnego dla <Usługi Najem>

Nazwa kroku	Liczba przypadków	Sprawy niezrealizowane	Suma korekt	Efektywność czasu pracy
Identyfikacja obiektu (O)	10	0	562	27
Identyfikacja atrybutu obiektu (A)	10	0	16	27
Rozwiązanie alternatywne (C)	5	0	19	89
Kryteria jakościowe (Qc)	5	0	3	27
Strategie decyzyjne (W)	5	0	28	89
Kryteria jakościowe (Qw)	5	0	3	27
Wybór decyzji (d)	10	0	37	89

Źródło: opracowanie własne na podstawie badań



Rys. 8. Interfejs TIBCO Business Studio prezentujący wartości działań dla <Usługi Eksploatacja>

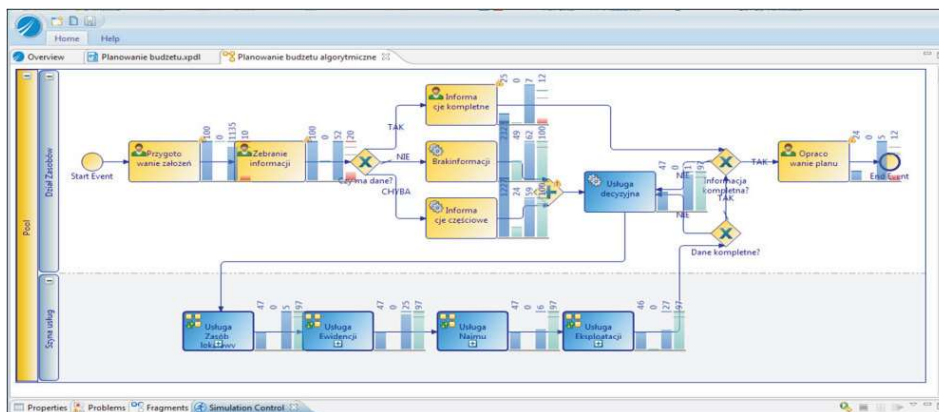
Źródło: opracowanie własne na podstawie badań

Tabela 4. Parametry efektywności kognitywnego procesu decyzyjnego dla <Usługi Eksploatacja>

Nazwa kroku	Liczba przypadków	Sprawy niezrealizowane	Suma korekt	Efektywność czasu pracy
Identyfikacja obiektu (O)	10	0	562	27
Identyfikacja atrybutu obiektu (A)	10	0	16	27
Rozwiązanie alternatywne (C)	5	0	19	89
Kryteria jakościowe (Qc)	5	0	1	9
Strategie decyzyjne (W)	5	0	29	89
Kryteria jakościowe (Qw)	5	0	1	9
Wybór decyzji (d)	10	0	38	89

Źródło: opracowanie własne na podstawie badań

Wyniki symulacji dla całego <Procesu planowania wykorzystującego algorytm i zautomatyzowane usługi decyzyjne> prezentuje rysunek 9. Ilustruje on wartości dla poszczególnych czynności w kontekście ról zaangażowanych w realizację analizowanego procesu. Kalkulacja parametrów kosztów działań odnosi się do tworzenia całościowych, szacowanych wartości opartych na transakcjach realizowanych przez system podczas symulacji procesu. Pojedyncza transakcja przypisywana jest do jednostkowego działania uczestnika procesu, a następnie program oblicza koszt działania (czas trwania działania pomnożony przez koszt jednostkowy uczestnika). Prezentowane na diagramie słupki oznaczają: (i) liczbę obserwowanych przypadków, (ii) rozmiar kolejki spraw zrealizowanych, (iii) sumę opóźnień w realizacji czynności wynikający z opóźnień w działaniach wcześniejszych, (iv) efektywnie wykorzystany czas pracy.



Rys. 9. Interfejs TIBCO Business Studio prezentujący wartości poszczególnych działań w procesie wykorzystującym algorytmy i zautomatyzowane usługi decyzyjne

Źródło: opracowanie własne na podstawie badań

Końcowe wyniki symulacji prezentuje tabela 5 zawierająca wartości zaangażowania poszczególnych ról w realizację procesu.

Tabela 5. Wartości wyliczone dla poszczególnych ról w procesie planowania wykorzystującym algorytmy i zautomatyzowane usługi decyzyjne

Jednostka	Rola	Nazwa kroku	Średni czas bezczynności	Średni czas zaangażowania	% wykorzystania
Dział zasobów	Menedżer zasobów	Przygotowanie założeń	15	100	87,06
	Koordinator zasobów	Zebranie informacji	115	356	98,28
	Personel zasobów	Komplet informacji	15	105	12,34
	Analityk zasobów	Opracowanie planu	14	482	97,29
Szyrna usług	Agent Algorytm	Usługa decyzyjna	58	1506	98,52
	Agent Workflow	Usługa decyzyjna	67	1477	93,85
	Agent System	Usługa decyzyjna	15	1081	90,14

Źródło: opracowanie własne na podstawie badań

RQ2: Czy zastosowanie AVMs do automatycznej oceny właściwości nieruchomości przynosi korzyść zarządzającemu taką nieruchomością?

W badaniu proces specyfikacji modelu identyfikował cechy właściwości (zmienne), które miały wpływ na strukturę modelu. Następnie wybierał odpowiedni (najkorzystniejszy) model <Procesu biznesowego>, a potem, w efekcie działania, rozwijał go na podstawie odnalezionych danych. Kalibracja modelu polegała na wyprowadzaniu aktualnych współczynników dla wcześniej określonych zmiennych. Nowe zmienne powstawały w wyniku transformacji. Podstawowe kroki przebiegały według schematu zaproponowanego jako standard wykorzystywania AVMs: (i) ustalenie zakresu, (ii) identyfikacja danych, (iii) eksploracyjna analiza danych, (iv) stratyfikacja, (v) określenia reprezentatywności danych, (vi) specyfikacja modelu, (vii) kalibracja modelu, (viii) zapewnienie jakości, (ix) zastosowanie modelu i przegląd wartości. Kroki (ii-ix) realizowane były przez działające sekwencyjnie w <Szybie usług> poszczególne usługi kognitywne. Model udostępniał interfejs, na którym dla <Dział zasobów> prezentowane były wszystkie wymagane i niezbędne do gospodarowania nieruchomością informacje dotyczące nieruchomości. Dostęp do zakresu danych był indywidualizowany zgodnie z rolami i przypisanymi do nich poziomami uprawnień dla <Personelu zasobów>.

<Personel zasobów> wskazuje interesujący go zakres danych, w tym warunki ograniczające i hipotetyczne, wywołując proces sekwencyjnie uruchamianych kognitywnych usług decyzyjnych działających niejawnie w <Szybie usług>.

Pierwszą usługą jest <Usługa Zasób lokalowy> wysyłająca żądanie <get info()> do <Usługi Ewidencja>. Żądanie nadzorowane jest semantycznie przez odpowiednie <klasy ontologiczne>. Żądanie realizowane jest sekwencyjnie, aż do uzyskania wyczerpującego zakres żądania efektu końcowego.

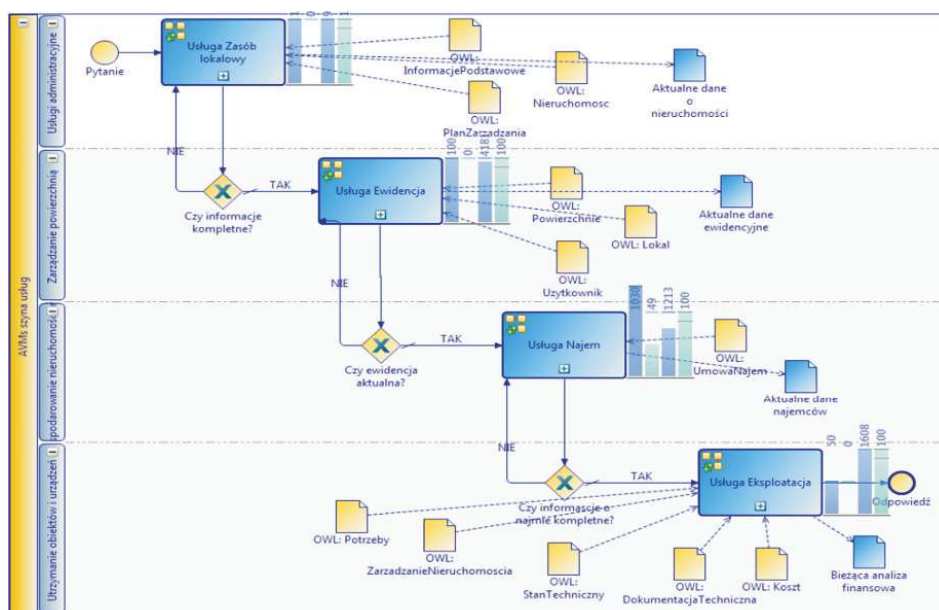
W kolejnym kroku uruchamiana jest <Usługa Ewidencja> odpowiedzialna za dostarczenie informacji związanych z danymi ewidencyjnymi nieruchomości. W wypadku braków danych uruchamiany jest podproces <Kognitywnej maszyny wnioskującej> odpowiedzialnej za dostarczenie decyzji (d) zgodnie z założonym (SLA). Żądanie realizowane jest sekwencyjnie, aż do uzyskania wyczerpującego zakres żądania efektu końcowego.

Następna w kolejności uruchamiana jest <Usługa Najem> odpowiedzialna za aktualne dane dotyczące umów najmu, ich okresów, warunków, metod i sposobów naliczania kosztów użytkowania nieruchomości. Także w tym wypadku, przed dostarczeniem wyniku żądania, dane są aktualizowane i ponownie opracowywane przez <Kognitywną maszynę wnioskującą> zgodnie z regułami <ontologii>.

Jako ostatnia uruchamiana jest <Usługa Eksploatacja> dostarczająca cały zestaw danych dotyczących zagadnień eksploatacyjnych dla nieruchomości. W wypadku braku danych lub danych nieaktualnych uruchamiany jest podproces <Zebranie danych technicznych> nadzorowany przez <Kognitywną maszynę wnioskującą>.

Działanie usługi realizowane jest sekwencyjnie, aż do uzyskania wyczerpującego zakresu żądania efektu końcowego.

Schemat przebiegu procesu przedstawiony został na rysunku 10. Prezentowane na diagramie słupki oznaczają: (i) liczbę obserwowanych przypadków, (ii) rozmiar kolejki w realizacji czynności, (iii) liczbę spraw zrealizowanych, (iv) wykorzystany efektywnie czas pracy.



Rys. 10. Proces sekwencyjnie uruchamianych kognitywnych usług w szynie usług w notacji BPMN
Źródło: opracowanie własne na podstawie badań

W badaniu analizowano, czy zastosowanie AVMs do automatycznej wyceny wartości nieruchomości przynosi korzyść zarządzającemu nieruchomością. Przeprowadzona symulacja wykazała, że uruchamiane niezależnie dla każdej z usług kognitywnych <Modele pomiaru wartości> działają poprawnie i dokonują obliczeń, nie zaburzając całego sekwencyjnego procesu realizowanego przez <Szynę usług>. W wypadku każdej kognitywnej usługi sprawność jej efektywności wynosiła 100%. Najwięcej ponownych przebiegów, poszukujących właściwych asocjacji dostarczanych w sekwencjach danych dotyczyło <Usługi Najem>. Powodowane jest to liczbą obiektów do zweryfikowania oraz dużą, naturalną dynamiką związaną z kształtowaniem się umów najmu. Co istotne, nie zaburzyło to <Usługi Eksploatacja>, która odpowiada za dostarczenie najbardziej odpowiedniej decyzji prezentującej poszukiwaną wartość. Przebieg procesu realizowany był całkowicie przez oprogramowanie. Uczestniczyły w nim <Agent Algorytm>, <Agent Workflow>, <Agent Oprogramowanie> i <Agent System>.

Dyskusja

Wnioski z badania RQ1

Przeprowadzona symulacja wykazała, że w wypadku kroków realizowanych przez <Agenta Algorytm> stan wyjściowy <Brak informacji> oraz <Informacje częściowe> nie ma żadnego znaczenia dla płynności i czasu przebiegu procesu kompletowania informacji. Wszystkie zadania wymagające skorzystania z <Szyny usług> i <Usługi decyzyjnej> zostały wykonane poprawnie, a ich poziom efektywności wyniósł 98%. Aktorem wstrzymującym <Opracowanie planu> jest <Personel zasobów>. Mimo posiadania na wyjściu <Informacji kompletnej> jest aktorem, którego efektywność w procesie została wyliczona na 12%. Efektywność tę obniża także fakt, że zadania <Personelu zasobów> przejmowane są przez <Usługę decyzyjną>. Wyliczona niska efektywność personelu przeczy powszechnej tezie, że dla skuteczności procesu konieczne jest posiadanie kompletu informacji na wejściu. W wypadku zastosowania algorytmów i zautomatyzowanych usług decyzyjnych stan wejściowy nie ma znaczenia lub ma znaczenie minimalne dla efektu całego procesu.

Wnioski z badania RQ2

Przeprowadzona symulacja wykazała, że uruchamiane niezależnie od siebie kognitywne usługi decyzyjne oparte na metodach zalgorytmizowanego wnioskowania działają poprawnie i dokonują obliczeń, nie zaburzając sekwencyjnego procesu złożonego z wszystkich połączonych z sobą usług. Ich sprawność wynosiła 100%. Dla usługi dotyczącej najmu zarejestrowano najwięcej ponownych przebiegów. Spowodowane to było dużą liczbą obiektów do zweryfikowania oraz dużą, naturalną dynamiką związaną z kształtowaniem się umów najmu. Nie wpłynęło to negatywnie na wyliczenia dla usług dotyczących eksploatacji.

Badanie potwierdziło, że AVMs mogą zostać wykorzystane do automatycznej oceny właściwości charakteryzujących nieruchomości, przynosząc tym samym korzyść (w postaci kosztu oraz czasu poświęconego na realizację zadań) zarządzającemu nieruchomością.

BIBLIOGRAFIA

- [1] BABU, S., VENKATARAM, P., 2009. A Dynamic Authentication Scheme for Mobile Transactions, *International Journal of Network Security*, nr 8(1), s. 59-74.
- [2] BILGILIOĞLU, S.S., HACI, M.Y., 2021. Comparison of Different Machine Learning Models for Mass Appraisal of Real Estate, *Survey Review*, November, s. 1-12.
- [3] BUCOŃ, R., TOMCZAK, M., 2018. Decision-Making Model Supporting the Process of Planning Expenditures for Residential Building Renovation, *Technological and Economic Development of Economy*, nr 24 (3), s. 1200-1214.
- [4] CARRANZA, J.P., PIUMETTO, M.A., LUCCA, C.M., DA SILVA, E., 2022. Mass Appraisal as Affordable Public Policy: Open Data and Machine Learning for Mapping Urban Land Values, *Land Use Policy*, nr 119 (August).
- [5] CHENG, J.C.P., CHEN, W., TAN, Y., WANG, M., 2016. A BIM-Based Decision Support System Framework for Predictive Maintenance Management of Building Facilities, 16th International Conference on Computing in Civil and Building Engineering, Osaka.
- [6] GAVU, K.E., TUDZI, E.P., AYITEY, J.Z., 2015. *Corporate Real Estate Management: A Survey of Literature*, Conference: 4th International Conference on Infrastructure Development in Africa (ICIDA), Kumasi, Ghana.
- [7] I.A.A.O., 2018. *Standard on Automated Valuation Models (AVMs) – 2018*, Kansas City, MO: International Association of Assessing Officers.
- [8] IBM, 2023, <https://www.ibm.com/developerworks/downloads/r/architect/index.html> (dostęp: 9.02.2033).
- [9] ISO 41011:2017, 2017. ISO 41011:2017 – Facility Management – Vocabulary.
- [10] KARA, A., ÇAĞDAŞ, V., IŞIKDAĞ, U., BULENT, O.T., 2018. Towards Harmonizing Property Measurement Standards, *Journal of Spatial Information Science*, nr 17, s. 87-119.
- [11] KAUR, S., SHIVAM, G., SANJAY, K.S., MIRKO, P., 2019. Organizational Ambidexterity through Global Strategic Partnerships: A Cognitive Computing Perspective, *Technological Forecasting and Social Change*, nr 145, s. 43-54.
- [12] KOZICKI, B., MITKOW, Sz., SOWA, B., 2021. Prognozowanie w obszarze zakupu nieruchomości w Polsce na 2021 rok w aspekcie bezpieczeństwa ekonomicznego, *Nowoczesne Systemy Zarządzania*, nr 16 (2), s. 23-37.
- [13] LEMAIGNAN, S., WARNIER, M., SISBOT, E.A., CLODIC, A., ALAMI, R., 2017. Artificial Cognition for Social Human-Robot Interaction: An Implementation, *Artificial Intelligence*, vol. 247, June, s. 45-69.
- [14] LORENZ, F., WILLWERSCH, J., CAJIAS, M., FUERST, F., 2022. Interpretable Machine Learning for Real Estate Market Analysis, *Real Estate Economics*, s. 1-31.
- [15] MAYER, M., BOURASSA, S., HOESLI, M., SCOGNAMIGLIO, D., 2019. Estimation and Updating Methods for Hedonic Valuation, *Journal of Real Estate Research*, nr 33 (3), s. 87-349.
- [16] NOWAK-NOVA, D., 2018. Potencjał kognitywnej robotyzacji zaawansowanych procesów biznesowych. Mit czy rzeczywistość?, *Przedsiębiorczość i Zarządzanie*, nr 19 (5, cz. 2), s. 76-163.
- [17] O.M.G.DMN Guide, 2019. *Decision Model and Notation: Version 1.2. OMG Document*.
- [18] O.M.G.WfMC Specification, 2000. *Workflow Management Facility Specification, V1.2. OMG Document*.
- [19] PRUSZKOWSKI, L., 2012. Facility Management jako innowacyjna koncepcja zarządzania procesami pomocniczymi, *Innowacje w Zarządzaniu i Inżynierii Produkcji*, nr 16, s. 25-214.

-
- [20] RENIGIER-BIŁOZOR, M., CHMIELEWSKA, A., WALACIK, M., JANOWSKI, A., LEPKOVA, N., 2021. Genetic Algorithm Application for Real Estate Market Analysis in the Uncertainty Conditions, *Journal of Housing and the Built Environment*, nr 36 (4), s. 70-1629.
- [21] STEURER, M., HILL, R.J., PFEIFER, N., 2021. Metrics for Evaluating the Performance of Machine Learning Based Automated Valuation Models, *Journal of Property Research*, nr 38 (2), s. 99-129.
- [22] ŚLIWIŃSKI, A., ŚLIWIŃSKI, B., 2006. *Facility Management*, Warszawa: C.H. Beck.
- [23] ŚMIETANA, K., 2013. Benchmarking w Zarządzaniu Wartością Nieruchomości Przedsiębiorstw, *Finanse, Rynki Finansowe, Ubezpieczenia*, nr 64 (1), s. 61-451.
- [24] TEGoVA, 2017. *EVS 6 Automated Valuation Models (AVMs)*.
- [25] THOMAS, W., 2014. Operations Research Vis-a-vis Management at Arthur D. Little and the Massachusetts Institute of Technology in the 1950s, *Business History Review*, nr 86, s. 99-122.
- [26] TIBCO, 2023, <https://www.tibco.com/resources/datasheet/tibco-business-studio> (dostęp: 9.02.2033).
- [27] VOM BROCKE, J., RECKER, J., MENDLING, J., 2010. Value-Oriented Process Modeling: Integrating Financial Perspectives into Business Process Re-Design, *Business Process Management Journal*, nr 16 (2).
- [28] WELCK, M., DERDAK, I.J., VEIT, D., 2020. Understanding Individuals Perceptions Re-garding Cognitive Computing Systems, *International Conference on Information Systems (ICIS)*, s. 1-9.
- [29] XU, J., WEISHENG, L., FAN, X., KE, CH., 2019. Cognitive Facility Management: Definition, System Architecture, and Example Scenario, *Automation in Construction*, nr 107(2), s. 1-25.