

Paweł Stacewicz

Wydział Matematyki i Nauk Informatycznych
Politechnika Warszawska,

André Włodarczyk*

Université Paris-Sorbonne (CELTA)

O modelowaniu informatycznym ze szczególnym odniesieniem do badań nad sztuczną inteligencją

Niniejszy artykuł dotyczy modelowania różnych zjawisk przy użyciu pojęć i narzędzi informatycznych, związanych głównie z badaniami nad sztuczną inteligencją (SI). Po przedstawieniu idei sformalizowanego modelu informatycznego (MI) omawiamy ogólnie interaktywną procedurę modelowania (która składa się z czterech, powtarzanych cyklicznie, etapów: abstrakcji, formalizacji, symplifikacji i weryfikacji), a następnie charakteryzujemy ją w kontekście szczególnym, tj informatycznym.

Omawiając różne typy MI, odwołujemy się przede wszystkim do badań nad AI; np. rozróżniamy między modelami regułowymi (implementowanymi często w postaci systemów eksperckich), sieciowymi (realizowanymi często w postaci sztucznych sieci neuronowych) oraz ewolucyjnymi (nawiązującymi, na przykład, do teorii algorytmów genetycznych).

Co jest jednak najważniejsze, przedstawiamy pogląd, zgodnie z którym różne, przynależne do badań nad AI, techniki automatycznego uczenia się mogą, a w gruncie rzeczy powinny, być stosowane do automatyzacji poszczególnych etapów procedury modelowania.

This article treats about modeling different phenomena by means of concepts and tools elaborated in the computer science framework, mainly in that of Artificial Intelligence (AI). After having presented the notion of formalized computer science model (CSMd), we described general interactive modeling procedure (which consists of four stages: abstraction, formalization, simplification and verification). We next characterize this procedure in the context limited to computer science.

Discussing different types of CSMd we focus on the domain of AI, e.g. we distinguish between rule-based models (often implemented as expert systems), network-based models (often implemented as artificial neural networks) and evolutionary models (often based using genetic algorithms).

But, most importantly, we believe that machine learning tools (as part of the AI domain) could and, as the matter of fact, should be used in order to automate each of the stages of the proposed interactive modeling procedure.

Key words: modeling, computer science models, artificial intelligence, machine learning

1. Uwagi wstępne

1.1. Niniejszy artykuł traktuje o *modelowaniu*, które stanowi powszechnie używaną, być może nawet najpowszechniej używaną, metodę nauk empirycznych. Mówiąc na razie ogólnie i wstępnie, metoda ta polega na stopniowym konstru-

* <http://celta.paris-sorbonne.fr>

owaniu użytecznego poznawczo, choć wyidealizowanego i uproszczonego, *obrazu* badanego zjawiska. Ponieważ obraz ten przyjmuje często postać abstrakcyjnego *opisu formalnego* – np. układu równań, zbioru formuł logicznych czy zestawu algorytmów – to modelowanie odwołuje się w sposób istotny do nauk formalnych (takich jak matematyka, logika czy informatyka).

Jako typowe przykłady modeli budowanych w naukach empirycznych¹ można wymienić: a) w fizyce – modele *atomu*, np. model atomu Bohra; b) w neurobiologii – modele *neuronu*, np. liniowy model neuronu McCullocha i Pittsa [McCulloch, Pitts 1943]; c) w psychologii – zinformatywowane modele *pamięci semantycznej*, w tym sieciowy model Quilliana [Quillian 1968]. Osobna grupa modeli, szczególnie ważna z punktu widzenia niniejszej pracy, przynależy do kognitywistyki – są to cząstkowe modele *umysłu*, a wśród nich bogaty zbiór regułowych modeli wnioskowania, implementowanych np. w postaci systemów eksperckich (por. [Stacewicz 2010]).

Mając na uwadze powyższe przykłady, podkreślmy raz jeszcze właściwą wszelkim modelom funkcję *obrazowania*. Funkcja ta uwidacznia się najpełniej w relacji badacza do modelowanej rzeczywistości: będący obrazem model zawsze bowiem *pośredniczy* między podmiotem a poznawanym przezeń obiektem (zjawiskiem). Znaczy to, że model prowadzi badacza do nowej wiedzy o samym obiekcie, a mówiąc konkretniej, pozwala mu dostrzec i sformułować pewne problemy dotyczące obiektu, a następnie podjąć próbę ich rozwiązania. Tak pojęta funkcja pośredniczenia jest konieczna w dwóch sytuacjach. Po pierwsze wtedy, gdy badany obiekt jest poznawczo *niedostępny* (np. ze względów technicznych lub aksjologicznych), a po drugie wtedy, gdy badany obiekt jest zbyt *skomplikowany*, aby można go było badać bezpośrednio i całościowo (co dotyczy np. mózgu czy umysłu).

1.2. Pośród modeli obrazujących badane zjawiska w sposób formalny, czyli pośród modeli sformalizowanych, stosunkowa najmłodsza jest grupa *modeli informatycznych* (MI). Konstrukcje takie są opisane teoretycznie w języku informatyki (języku algorytmów i struktur danych), a dzięki temu są możliwe do zaimplementowania w postaci aplikacji i uruchomienia na komputerze. Co ważne także, konstrukcje takie nie biorą się znikąd. U ich podstaw leży pewien obraz wstępny, polegający na luźnym porównaniu badanego obiektu, np. umysłu, z określonym systemem informatycznym. Ów luźny obraz będziemy nazywać w niniejszym tekście informatyczną *metaforą*.

¹ W naukach formalnych, w szczególności w logice, mówi się ponadto o modelach w innym znaczeniu, a mianowicie o modelach *semantycznych* [Marciszewski 1998; *Mała encyklopedia logiki*; hasło: *model semantyczny*]. Są to takie interpretacje systemów aksjomatycznych, które czynią ich aksjomaty prawdziwymi (a zatem i wszystkie zdania-twierdzenia systemu, które dadzą się z aksjomatów wyprowadzić). Zauważmy wstępnie, że fragment teorii posiadającej model semantyczny, czyli teorii zinterpretowanej, może pełnić funkcję teoretycznego modelu danego obiektu (modelu w sensie podanym wyżej, czyli modelu jako obrazu).

Choć forma algorytmiczna i możliwość przekształcenia algorytmu w działający program komputerowy stanowią cechę swoistą MI, to nie należy zapominać o ich związkach z *matematyką*. Mamy na myśli fakt, że większość MI ma pewien nadrzędny i pierwotny względem informatyki opis matematyczny (np. algebraiczny) – opis będący podstawą dalszych konkretyzacji i rozszerzeń za pomocą pojęć informatycznych (np. konkretnych struktur danych). Innymi słowy: modele takie mają swoją warstwę *głębką* (matematyczną) i swoją warstwę *właściwą* (czysto informatyczną)².

W niniejszym tekście będą nas interesować takie modele informatyczne, które są stosowane *poza samą informatyką*, tj. służą innym celom niż formalny opis przetwarzania danych w systemach sztucznych (co nie zawsze musi mieć miejsce, bo na przykład o uniwersalnej maszynie Turinga wiemy, że stanowi najprostszy model komputera cyfrowego; tym samym zaś model ów obrazuje pewien system informatyczny, a nie układ innego rodzaju).

Na kolejnych stronach podejmiemy próbę *metodologicznej* charakterystyki modeli MI (stosowanych poza informatyką). Opiszemy zarówno procedurę ich powstawania, jak i jej (tymczasowe) wytwory. Analizę naszą poprzedzimy wprowadzeniem szeregu rozróżnień pojęciowych, które będą zakotwiczone we współczesnym języku informatyki.

1.3. Prowadząc wspomniane analizy metodologiczne, będziemy mieć na uwadze przede wszystkim przynależne do informatyki badania nad *sztuczną inteligencją*. Badania te rozpoczęto w latach 50 XX wieku, formułując od razu niezwykle ambitny program sztucznej realizacji intelektu. Choć program ten wciąż czeka na ostateczny sukces, to w kontekście modelowania, trzeba dostrzec ogromną liczbę już wypracowanych teorii, technik i schematów przetwarzania danych, które mimo wszystko przybliżają nas do lepszego zrozumienia istoty inteligencji. Są pośród nich różnego rodzaju logiki i właściwe im techniki automatyzacji wnioskowań, są też teorie uczenia się i właściwe im algorytmy nabywania wiedzy przez systemy sztuczne [Russel, Norvig 1994].

Te i nie tylko te osiągnięcia badaczy sztucznej inteligencji nadają się znakomicie, wręcz z definicji, na omawiane w niniejszej pracy *modele czynności umysłowych*. Przykładowo: różnego rodzaju algorytmy wnioskowań można traktować jako punkt wyjścia czy też jądro modeli rozumowań, natomiast przynależne do innego nurtu badań sztuczne sieci neuronowe wolno postrzegać jako dobry materiał na modele fragmentów mózgu.

Nie na tym jednak tylko polega znaczenie wzmiankowanych badań. Jak zobaczymy w punkcie 4, niektóre z technik „inteligentnego” przetwarzania danych daje

² Ponieważ obydwie w/w nauki, informatyka teoretyczna i matematyka, są dyscyplinami formalnymi, a zakresy ich kompetencji nierzadko przecinają się ze sobą (czemu towarzyszy również problem nieostrości tychże zakresów), to nie zawsze różnica między matematyczną a informatyczną warstwą modelu jest łatwo-rozpoznawalna.

się wykorzystać na wyższym niejako poziomie, tj. na poziomie samej procedury modelowania. Mamy na myśli projekt *automatyzacji*, a więc powierzenia maszynie, niektórych przynajmniej elementów tej procedury. Gdyby zamysł ów udało się wdrożyć na wszystkich etapach procesu modelowania, to tworzącemu model badaczowi pozostałaby rola podmiotu inicjującego cały proces, a następnie oceniającego wygenerowany automatycznie wynik.

2. Modele informatyczne jako modele sformalizowane

2.1. Z najbardziej ogólnego punktu widzenia modele (w sensie metodologicznym) dzielą się na *teoretyczne* i *realne*. Te pierwsze stanowią zbiór założeń upraszczających³ oraz wynikających z nich tez, te drugie zaś są fizycznymi realizacjami przyjętych założeń, czyli przedmiotami lub układami przedmiotów spełniającymi je [Marciszewski 1988; *Mała encyklopedia logiki*; hasło: *model*]. Wspomniane założenia i tezy konstytuują teoretyczny obraz badanego obiektu, a pochodzą z teorii, w ramach której (lub równoległe z którą) jest tworzony model. Z tego powodu model teoretyczny należy traktować jako pewien wąski fragment *teorii*, ukierunkowany na opis ograniczonej grupy zjawisk (danego typu) i rozwiązywanie dotyczących ich problemów.

Ze względu na przynależność do określonej teorii model teoretyczny pełni podobne *funkcje poznawcze* co sama teoria: umożliwia stawianie hipotez, może być testowany pod kątem adekwatności, pozwala rozwiązywać problemy, może dostarczyć niezbędnych wyjaśnień. Należy pamiętać jednak – co jest niezwykle ważne – że model i teoria są budowane równoległe; to znaczy teoria, o której mowa, nie jest czymś zamkniętym i ostatecznym; m.in. za sprawą weryfikacji modelu i jego przekształceń, teoria *zmienia się*.

Mówiąc o teorii uwikłanej w procedurę modelowania, tak naprawdę trzeba mieć na uwadze dwie teorie: a) po pierwsze, *meta-teorię*, czyli teorię formalną, która dostarcza (niezinterpretowanego jeszcze) języka modelu – np. w przypadku liniowego modelu neuronu jest to prosta algebra macierzowa (zob. dalszy przykład); b) po drugie jednak, *teorię właściwą*, czyli teorię badanej dziedziny, która jest formułowana i zarazem formalizowana w języku meta-teorii. Teoria właściwa stanowi zatem właściwą podstawę konstrukcji modelu, natomiast meta-teorię (a ściślej rzecz biorąc: jej fragment) można nazwać *formalną podstawą modelu*.

Tutaj należy dopowiedzieć, że pojęcie meta-teorii jest niezwykle pojemne i w przypadku większości modeli (tych zaawansowanych) bierze się pod uwagę nie pojedynczą teorię formalną (np. pewien wyróżniony dział matematyki), lecz więk-

³ Wybierając określone założenia, decyduje się o tym, które cechy badanego obiektu są poznawczo istotne, a ponadto „efektywne” ze względu na przyjęte cele badawcze.

szą ich liczbę. Mówiąc inaczej, zazwyczaj meta-teoria stanowi zbiór teorii formalnych. Na przykład – co wyjaśnimy dokładniej dalej – interesujące nas najbardziej modele informatyczne odwołują się i do pewnych formalizmów matematycznych (jak np. algebra), i do pewnych ogólnych metod czy technik komputerowych (jak np. algorytmy genetyczne).

2.2. Jakkolwiek nie wszystkie modele teoretyczne muszą być formalizowane – niektóre mogą mieć postać precyzyjnych opisów słownych – to za najbardziej zaawansowane uchodzą właśnie *modele sformalizowane*, czyli konstrukcje formalne zinterpretowane w określonej dziedzinie przedmiotowej (tej, której fragment podlega modelowaniu). Definiuje się je w języku matematyki lub dziedzin blisko z nią spokrewnionych, takich jak logika czy informatyka.

Stąd też, zależnie od dyscypliny, z której pochodzi szkielet formalny modelu, można mówić o modelach matematycznych, logicznych, informatycznych itp. (pamiętając jednak o tym, że każda z tych dziedzin ma swoje działy, co upoważnia do stosowania nazw węższych, jak np. modele algebraiczne).

Niezwykle użyteczna, a z uwagi na bujny rozwój technik komputerowych dominująca dziś, klasa modeli sformalizowanych to *modele informatyczne* (MI). Są to konstrukcje formalizowane w języku informatyki⁴, odwołujące się zwykle do pewnych konkretnych metod/technik przetwarzania danych, a realizowane praktycznie za pomocą programów komputerowych lub kontrolowanych programistycznie systemów. Konstrukcje takie służą najczęściej do opisu zjawisk zmieniających się w czasie i wykazujących przy tym dużą złożoność. Mogą to być, na przykład, zjawiska (czy też procesy) umysłowe.

W odniesieniu do modeli informatycznych przedstawione wyżej ogólne pojęcia modelu teoretycznego, modelu realnego oraz formalnej podstawy modelu konkretyzują się.

W ich przypadku:

(a) *formalną podstawą* modelu jest: (a1) w rozumieniu szerokim – pewna wyróżniona *teoria przetwarzania danych*, np. teoria przetwarzania danych przez (ogólnie pojęte) sztuczne sieci neuronowe; (a2) w rozumieniu wąskim – pewien *algorytm* (lub zbiór algorytmów), który precyzuje w abstrakcyjny sposób wybraną uprzednio metodę przetwarzania danych, opisywaną ogólnie przez teorię a1 (np. uczenie się sieci typu perceptron metodą wstecznej propagacji błędów);

⁴ Chodzi tu i o ogólny język informatyki (dotyczący pewnych typowych struktur danych i reguł ich przetwarzania), jak i język szczegółowy, związany z pewną wyróżnioną „mikro-teorią” przetwarzania danych (np. przetwarzania regulowego w ramach tak a tak wyspecyfikowanych systemów eksperckich).

(b) *modelem teoretycznym* jest *aplikacja*⁵ – czyli zakodowany (w konkretnym języku programowania) i stosowany w pewnej wskazanej dziedzinie (czyli zinterpretowany) algorytm;

(c) *modelem realnym* jest natomiast – (c1) *działająca* (uruchomiona) aplikacja, której kolejne kroki można śledzić (np. na ekranie komputera); albo (c2) kontrolowany przez aplikację i *działający system*, który w przeciwieństwie do samej aplikacji bezpośrednio oddziałuje z otoczeniem. W przypadku c1 mamy do czynienia z realnym modelem *wirtualnym*, a w przypadku c2 z realnym modelem *nie-wirtualnym*⁶.

Uprzedzając nieco rozdział 4, w którym podejmiemy się analizy procedury modelowania, należy stwierdzić, że w odniesieniu do modeli informatycznych modelowanie obejmuje różne czynności, spośród których centralna to *programowanie*, czyli tworzenie aplikacji. Oprócz programowania należy wymienić, poprzedzające je, a mające bardziej ogólny charakter, *projektowanie algorytmów* (lub wykorzystywanie istniejących algorytmów), oraz jeszcze bardziej pierwotne, a decydujące o kształcie algorytmu i odpowiadającej mu aplikacji, *formalizowanie* zjawisk i procesów w języku matematyki.

2.3. Przytoczone wyżej rozróżnienia i wyjaśnienia zobrazujemy znanym przykładem *modelu neuronu*, który pierwotnie został zaproponowany przez McCullocha i Pittsa [McCulloch, Pitts 1943], a współcześnie jest na różne sposoby rozwijany w teorii sztucznych sieci neuronowych (zob. np. [Tadeusiewicz 1993]).

Teoretyczną podstawę modelu pierwotnego i jego rozmaitych rozszerzeń stanowią następujące trzy *założenia upraszczające*. Po pierwsze, model opisuje prawidłowości rządzące działaniem neuronu, a nie jego właściwości biologiczne – z tego powodu ma charakter funkcjonalny (a nie substancjalny). Po drugie, za trzy podstawowe funkcje neuronu uznaje się odbiór impulsów od innych neuronów, zamianę tych impulsów na sygnał wyjściowy i przekazanie tego sygnału innym neuronom – w ten sposób wprowadza się znaczące uproszczenia polegające na wyborze tylko niektórych spośród funkcji realizowanych przez rzeczywisty neuron. Po trzecie wreszcie, odbierane i przekazywane impulsy są kodowane liczbowo, a operacje

⁵ Nie używamy w tym miejscu pojęcia programu komputerowego (zastępując go pojęciem aplikacji), ponieważ w informatyce teoretycznej pojęcie programu zlewa się z pojęciem algorytmu; a zlewa się głównie dlatego, że większość algorytmów jest podawana w postaci programów napisanych w językach wysokiego poziomu (np. w PASCALU). Termin *aplikacja* jest o tyle lepszy, że zwraca uwagę na fakt zastosowania (aplikacji) algorytmu w konkretnej dziedzinie. Podkreślmy: nie tylko zakodowania go w konkretnym języku programowania, ale także stosowania go w konkretnej dziedzinie. Moglibyśmy powiedzieć więc, że aplikacje to programy/algorytmy zinterpretowane (zinterpretowane bo stosowane tak a tak).

⁶ Proponowane przez nas nazwy, model *wirtualny* i model *nie-wirtualny*, nie brzmią być może przekonująco, bo kojarzą się raczej z tematyką gier komputerowych, niż naukowym opisem modelowania. Wybraliśmy je, by podkreślić fakt, że istnieją dwa typy informatycznych modeli realnych: takie, które działają bez żadnej interakcji ze środowiskiem zewnętrznym (działają zatem tylko w wirtualnym środowisku komputerowym), i takie, które oddziałują na środowisko zewnętrzne (częściowo przynajmniej działają zatem w środowisku nie-wirtualnym).

na nich są zapisywane w języku matematyki – z tego powodu model ma charakter sformalizowany (zmatematyzowany).

Powyższe założenia ogólne dopuszczają bardzo wiele różnych konstrukcji teoretycznych, spośród których najprostszą (i historycznie pierwszą) jest tzw. *model liniowy*, sformalizowany w języku prostej algebry. Zgodnie z nim neuron składa się z: a) n wejść o określonych wagach (wejścia te odpowiadają rzeczywistym dendrytom), b) jednego wyjścia (odpowiednika rzeczywistego aksonu), i c) procesora przetwarzającego sygnały wejściowe. Co do działania tak modelowanego neuronu, to zakłada się, że polega ono na odbiorze n sygnałów wejściowych (od x_1 do x_n) o wartościach z przedziału $[0,1]$, przetworzeniu ich na sygnał wyjściowy y zgodnie z formułą (algebraiczną) $y = \sum w_i * x_i$ (w_i jest wagą i -tego wejścia) i przekazaniu sygnału y innym neuronom. Ze względu na zastosowany typ funkcji skalującej sygnały wejściowe x_i (sumy ważonej) model nazywa się *liniowym*; wybierając inne funkcje, na co pozwalają przyjęte założenia wstępne, uzyskuje się modele innego rodzaju. (Por. np. [Tadeusiewicz 1993] i [Żurada 1992]).

Przytoczony opis określa model teoretyczny sformalizowany w języku matematyki (prostej algebry) – jest to więc model *matematyczny*. Gdyby model ten został opracowany w postaci możliwej do uruchomienia aplikacji (symulującej działanie, a po rozszerzeniu modelu również uczenie się, rzeczywistego neuronu), powstałby teoretyczny model *informatyczny*. Gdyby aplikacja ta została uruchomiona na komputerze, lub zostałby utworzony odpowiadający jej układ elektroniczny, mielibyśmy do czynienia z informatycznym modelem realnym.

Charakteryzowane wyżej zagadnienia dotyczące modeli ujawniają się jednak najpełniej, gdy powyższy liniowy model neuronu czyni się podstawą szerszej konstrukcji, tj. *liniowej sieci neuropodobnej*, która stanowi model już nie pojedynczej komórki nerwowej, lecz pewnego ośrodka mózgowego. W przypadku tego nowego modelu istnieje faktyczna potrzeba odwołania się do teorii informatycznych (tj. teorii sztucznych sieci neuronowych), a także pewnych uniwersalnych algorytmów działania i uczenia się sieci określonego rodzaju. Teorie te należy traktować jako meta-teorie, wspomniane algorytmy – jako najmniej złożone elementy meta-teorii, utworzone na ich podstawie (a interpretowane jako narzędzia modelowania zjawisk neurobiologicznych) aplikacje – jako modele teoretyczne, działające aplikacje modelujące – jako wirtualne modele realne, a sterowane za pomocą tych aplikacji systemy fizyczne – jako nie-wirtualne modele realne.

3. Badania nad sztuczną inteligencją i ich konsekwencje dla modelowania

3.1. Zarówno przykład przytoczony w poprzednim punkcie, jak i liczne uwagi rozproszone w punktach pozostałych, prowadzą wprost do kluczowego dla dalszych rozważań hasła *sztucznej inteligencji*. Hasło to, wysunięte po raz pierwszy

w roku 1956, stanowi sugestywną ilustrację programu nowego, nie istniejącego wcześniej działu informatyki. Zgodnie ze znanym określeniem Marviniego Minsky'ego program ów można określić szerzej jako „*dążenie do konstrukcji takich systemów komputerowych, które byłyby w stanie podejmować zadania, które wymagają inteligencji wtedy, gdy są wykonywane przez ludzi*”.

Jakkolwiek badania, o których mowa, toczą się nieprzerwanie od ponad 50 lat, to łagodnie mówiąc, mają one charakter rozproszony i amorficzny. Przede wszystkim, toczą się one na bardzo różnych i niekiedy luźno powiązanych ze sobą poziomach. Po pierwsze, jest to poziom *ogólnych teorii* (jak np. teoria zbiorów rozmytych czy teoria zbiorów przybliżonych), po drugie, jest to poziom specyficznych *technik przetwarzania danych* (jak np. technika regułowa czy ewolucyjna), po trzecie, jest to najniżej usytuowany poziom konkretnych *algorytmów* (np. szachowych).

Rozproszeniu badań między różne poziomy towarzyszy problem wielości *obszarów szczegółowych*, które nie tworzą spójnej całości, lecz pewien luźny konglomerat prób teoretycznego opisu (czy też umaszynowania) takiej czy innej czynności poznawczej. Wymieńmy dla przykładu: automatyzację wnioskowań w logikach klasycznych i nieklasycznych (ang. *automated reasoning*), automatyczne uczenie się (ang. *machine learning*), eksplorację danych (ang. *data mining*), sztuczne sieci neuronowe (ang. *artificial neural networks*), logiki rozmyte (ang. *fuzzy logic*), zbiory przybliżone (ang. *rough sets*), algorytmy genetyczne (ang. *genetic algorithms*). Jak widać, są to obszary osadzone w zupełnie odmiennych dziedzinach podstawowych (np. z jednej strony logika, a z drugiej – neurobiologia), co z pewnością utrudnia opisanie zakresu badań nad sztuczną inteligencją jakąś jedną, syntetyczną formułą. (Por. [Russel, Norvig 1994]).

Nie próbując przedstawić takiej formuły, proponujemy spojrzeć na interesujący nas krąg zagadnień praktycznie (czyli w duchu inżynierskim) i wskazać trzy podstawowe funkcje systemów, które bylibyśmy skłonni uznawać za inteligentne.

Otóż systemy takie powinny: po pierwsze, swobodnie komunikować się z ludźmi (również w językach etnicznych), po wtóre, podejmować trafne decyzje (w tym logicznie uzasadnione), po trzecie wreszcie, winny doskonalić swój sposób działania w interakcji ze środowiskiem (tj. poszerzać zakres swoich zdolności). Stosownie do trzech wymienionych funkcji możemy wyodrębnić trzy *podstawowe obszary badawcze*, do których powinny odnosić się wszelkie badania szczegółowe. Są to:

- (1) *komunikacja komputer-człowiek* (ang. *man-machine communication*),
- (2) *podejmowanie decyzji* (ang. *decision making*),
- (3) *automatyzacja uczenia się* (ang. *machine learning*).

Propozycja nasza – polegająca w istocie na uznaniu pewnych już wyróżnionych obszarów badawczych za obszary nadrzędne – ma tę zaletę, że pokazuje jasno, dlaczego tak różne i pozornie niespójne ze sobą poszukiwania mogą współist-

nieć w jednym informatycznym dziale. I tak: badania *logiczne* mieszczą się w nim, bo poprawne logiczne wnioskowania służą dobrze podejmowaniu decyzji (obszar 2); badania nad sieciami *neuropodobnymi* mieszczą się także, bo właściwa sieciom zdolność do samoorganizacji może leżeć u podstaw uczenia się maszyn (obszar 3); teoria zbiorów *rozmytych* powinna być obecna, bo za pomocą zbiorów rozmytych definiuje się znaczenia słów w językach naturalnych, niezbędne do komunikacji maszyn z ludźmi (obszar 1)...

3.3. Kończące poprzedni akapit trzy kropki sugerują, że wyliczankę badań niezbędnych do wyposażenia maszyn w sztuczną inteligencję można by ciągnąć jeszcze długo, wymieniając badania o różnym rodowodzie i różnym charakterze. Czy nie udałoby się jednak poczynić kolejnego rozróżnienia, które wniosłoby do już wstępnie uporządkowanej mozaiki zagadnień innego rodzaju porządek? Naszym zdaniem jest to możliwe, a możliwość, o której mowa, dotyczy *roli logiki* (a patrząc z drugiej strony: roli empirii).

Otóż proponujemy wyróżnić w badaniach nad sztuczną inteligencją dwa wyraźnie zarysowane i wyraźnie odrębne nurty rozwojowe. Nazwiemy je *logicyzmem* i *naturalizmem*. (Por. też [Stacewicz 2010, s. 44-48]).

Poszukiwania osadzone w nurcie pierwszym, traktowane często jako trzon badań, polegają na próbach algorytmicznego opisu różnych *technik logicznych* – takich technik, które umożliwiają poprawne, w tym niezawodne, wnioskowania. Najbardziej chyba typowym rozwiązaniem logicystycznym są *systemy eksperckie*. Układy takie służą do podejmowania decyzji w pewnych wąskich i ściśle określonych dziedzinach (np. w pewnych działach medycyny) poprzez konsekwentne stosowanie reguły typu „*jeśli przesłanki, to konkluzja*”. Są to zatem typowe algorytmiczne systemy wnioskujące, przy czym współcześnie wzbogaca się je dodatkowo o mechanizmy uczenia się, czyli poszerzania lub modyfikacji bieżącego zbioru reguł [Ignizio 1991]. Do innych rozwiązań logicystycznych zaliczyć trzeba: systemy pozyskujące wiedzę drogą indukcji (oparte na jakiejś logicznej teorii indukcji), programy do gier (takich jak warcaby czy szachy) oraz programy do rozpoznawania zdań języka naturalnego w oparciu o różnego rodzaju „regułowe gramatyki” (np. gramatyki Chomsky’ego).

Podkreślić trzeba, że siłą napędową tego rodzaju badań jest wiara w to, że wszelkie akty myślowe da się zrozumieć i opisać w kategoriach *logiki formalnej* (niekoniecznie klasycznej). Ideał badacza-logicysty stanowi natomiast jakaś hipotetyczna hiper-maszyna logiczna, której zasady działania opierałyby się bez reszty na pewnym, niezwykle rozbudowanym, rachunku logicznym.

Badania osadzone w nurcie drugim – opatrzonym tutaj etykietą *naturalizmu* – wyrastają z zupełnie innego światopoglądu czy też nastawienia badawczego. Ich metodologicznym podłożem jest neutralne względem logicyzmu przeświadczenie, że właściwe ludziom czynności umysłowe można poznać tak jak zjawiska przyrodnicze, to znaczy empirycznie. Jedną z metod miałyby polegać na badaniu *mó-*

zgu, inna – na analizie danych *doświadczalnych*, dostarczanych przez psychologów i socjologów. Silną przesłanką dla tego rodzaju metod miałby być fakt, że ludzkie zdolności umysłowe stanowią część przyrody – rozwinęły się w toku naturalnej ewolucji, ich biologicznym podłożem jest aktywność neuronów wewnątrz mózgu, są one zależne od międzyludzkiej interakcji itp.

Jeśli chodzi o inspirowane nastawieniem naturalistycznym konkretne rozwiązania, to trzeba wymienić przede wszystkim: *sztuczne sieci neuronowe* – przetwarzające dane na podobieństwo ludzkiego mózgu, oraz *algorytmy genetyczne* – służące do rozwiązywania problemów metodą symulowanej ewolucji. Ujmując rzecz obrazowo, można stwierdzić, że ideałem inżynierskim badacza-naturalisty jest jakaś gigantyczna, uformowana w drodze sztucznej ewolucji, zdolna do samoorganizacji, przypominająca ludzki mózg sieć neuropodobna.

3.4. Wiedząc o tym, że badania nad sztuczną inteligencją mają dwojaki rodzaj profil, logicystyczny i naturalistyczny, wiedząc nadto, że toczą się one w obrębie trzech obszarów podstawowych, możemy omówić szerszy obszar interesujący nas najbardziej, czyli *automatyzację uczenia się*.

Pojęciami podstawowymi są tu: *sztuczny system uczący się* (SSU) oraz *algorytm uczenia się* (AU). Pojęcie pierwsze oznacza układ informatyczny zdolny doskonalić swoje działanie w interakcji z otoczeniem, pojęcie drugie – kluczowy element SSU, odpowiedzialny za skuteczne zmiany w jego schemacie działania. Algorytm AU można określić zatem jako algorytm drugiego rzędu, który opisuje, jak pewne parametry algorytmu właściwego, kierującego działaniem systemu, mają zmieniać się w odpowiedzi na takie a nie inne dane płynące ze środowiska⁷ ([Cichosz 2000], [Stacewicz 2010]).

Informatycy proponują różne typy algorytmów AU – zależne *de facto* od wyboru nadrzędnej względem nich techniki przetwarzania danych. Oto dwa wyraziste przykłady. W układach logicystycznych (takich jak systemy eksperckie), kierowanych za pomocą symbolicznych reguł postaci „Jeśli A to B” występuje niekiedy potrzeba wygenerowania lub zmiany parametrów A i/lub B (zwłaszcza wtedy, gdy twórca systemu nie zna dokładnego kształtu reguły i system musi ją określić sam, na bazie doświadczeń). W takich sytuacjach można sięgnąć po znane z logiki reguły indukcji (por. np. [Pawlak 1991]), zaszyć je w algorytmie uczenia się i na ich podstawie uogólnić wiedzę zawartą w przykładach. Podobnego rodzaju procedura, tj. uogólnianie wiedzy cząstkowej, zachodzi wewnątrz sieci neuropodobnych. Tutaj jednak, w odróżnieniu od wskazanych wyżej reguł logicznej indukcji, generowanie nowej wiedzy polega na masowym dostrajaniu wag połączeń międzyneuronalnych – połączeń, których całościowy rozkład definiuje wiedzę sieci. Owo dostrajanie zaś

⁷ Przyczyny zainteresowania algorytmami uczenia się są bardzo różnorodne. Zmienność środowiska, złożoność środowiska, chęć naśladowania procesów faktycznie występujących u człowieka (do nich należy uczenie się) i przekonania się mówiąc swobodnie, co z tego wyjdzie (wyjdzie dla skuteczności systemu).

(tj. zmniejszanie i zwiększanie poszczególnych wag) zachodzi na podstawie reguł mających swoje źródło w obserwacjach układu nerwowego zwierząt i ludzi.

Przytoczone przykłady nie wyczerpują, rzecz jasna, ogromnego bogactwa współczesnych badań nad algorytmizacją uczenia się. Celem niniejszego opracowania nie jest jednak dokładny opis tychże badań i katalogowanie ich wyników. Najważniejszy dla nas pozostaje fakt, że algorytmy uczenia się (będące pewnym formalnym elementem SSU) można wykorzystać na poziomie modelowania, a konkretniej do zautomatyzowania wskazanych dalej etapów modelowania.

3.5. Naturalnym rozwinięciem programu sztucznej inteligencji w dziedzinie modelowania są *informatyczne modele czynności umysłowych* (IMCU) – to znaczy, modele takich czynności jak rozpoznawanie obiektów, rozumienie języka, wnioskowanie czy uczenie się (a mówiąc ogólniej, modele wszelkich czynności prowadzących do inteligentnego zachowania). Przytoczony w punkcie 2.3 przykład sztucznej sieci neuronowej można potraktować – przy pewnej interpretacji oczywiście – jako dobry przykład układu informatycznego modelującego czynność percepcji.

W pracy [Stacewicz 2010] dokonano (nie wyczerpującej) klasyfikacji IMCU ze względu na typy informatycznych systemów modelujących – takich systemów, które tworzy się w ramach badań nad sztuczną inteligencją.

W pracy tej rozróżniono:

- (a) modele *regułowe* – odwołujące się do teorii przetwarzania danych symbolicznych za pomocą przejrzystych reguł typu „*jeśli przesłanka, to konkluzja*”, a implementowane w postaci systemów eksperckich [Ignizio 1991];
- (b) modele *koneksyjne* (sieciowe) – odwołujące się do teorii przetwarzania danych subsymbolicznych w sposób rozproszony i równoległy, a realizowane praktycznie za pomocą sztucznych sieci neuronowych [Żurada 1992]; oraz
- (c) modele *ewolucyjne* (selekcyjne) – odwołujące się do teorii symulowanej, elektronicznej ewolucji, obejmującej m.in. teorię algorytmów genetycznych⁸ [Michalewicz 1992].

Przykładowo: próbując wymodelować właściwą ludziom strategię *uczenia się metodą prób i błędów*, można odwołać się do teorii algorytmów genetycznych, opisać przebieg próbowania i błędzenia za pomocą tak a tak skonfigurowanego algorytmu i obserwować, czy działający model wykazuje podobną skuteczność co uczący się człowiek. Testowany model należałby, zgodnie z powyższym zestawieniem, do kategorii ewolucyjnych.

Już powyższy przykład obrazuje dobrze ogólną koncepcję modelu IMCU – modelu powstającego wskutek pewnej interpretacji definiujących model konstrukcji informatycznych. Mówiąc bardziej szczegółowo, koncepcja ta przedstawia

⁸ Wybór ten jest w dużej mierze arbitralny. Zdaniem autorów jednak oddaje dość dobrze współczesne tendencje badawcze informatyków, a ponadto obrazuje pewną ważną dystynkcję między *logicystycznym* (odwołującym się do logiki) i *naturalistycznym* (odwołującym się do empirii) nurtem badań nad sztuczną inteligencją.

się następująco: a) *podstawę formalną modelu* stanowią odpowiednie algorytmy i struktury danych, osadzone w szerszym kontekście określonej techniki przetwarzania danych (w powyższym przykładzie była to technika ewolucyjna); b) wszystkie formalne pojęcia informatyczne są *interpretowane* jako pojęcia dotyczące czynności umysłowych (w powyższym przykładzie chodziło o uczenie się); c) przyjęta interpretacja ma na celu *wyjaśnienie* czyli lepsze zrozumienie tychże czynności, a w praktyce także prognozowanie ich przebiegu oraz wyników.

3.6. Na koniec niniejszego rozdziału podkreślić trzeba, że z genetycznego czy też generatywnego punktu widzenia wszelkie modele IMCU wywodzą się ze współczesnej postaci metafory umysłu jako mechanizmu⁹. Zgodnie z jej nowym, „komputerowym”, brzmieniem „*umysł przypomina mechanizm do przetwarzania danych, a więc system informatyczny*”; przy czym przez system informatyczny rozumie się całość złożoną ze sprzętu i oprogramowania, nie przesądzając wstępnie, o jakiego rodzaju sprzęt (komputer) chodzi, oraz jakiego typu programy są na nim realizowalne.

Dlaczego metaforę taką warto podjąć i rozwijać? Niezależnie od realnych sukcesów na polu komputerowej realizacji różnych czynności poznawczych, zdają się przesądzać o tym dwie okoliczności natury ogólnej. Otóż, po pierwsze, umysł przypomina w pewnym sensie system informatyczny, bo istotą czynności umysłowych (w odróżnieniu od cielesnych) jest przetwarzanie *informacji* (a nie materii czy energii). W języku potocznym informacje te zwie się po prostu myślami. A po drugie: podobnie jak systemy informatyczne służą, między innymi, do *sterowania* układami fizycznymi, tak umysł ma za zadanie, między innymi, kierować czynnościami cielesnymi (kierować na podstawie uzyskiwanych z zewnątrz i odpowiednio przetwarzanych informacji).

Tematykę metafory, jak również rekonstrukcję procesu przechodzenia *od metafory do modelu*, przedstawiliśmy w pracy [Stacewicz, Włodarczyk 2010]. W tym miejscu pragniemy jedynie uwypuklić fakt, że modele mogą wywodzić się z metafor, a zatem analizując procedurę modelowania, należy uwzględnić zarówno samą metaforę, jak i operacje jej wykorzystywania i ewentualnego przekształcania.

4. Interaktywna procedura modelowania

Po przedstawieniu typowego wytworu czynności modelowania informatycznego, jakim są modele IMCU (zob. 3.5), możemy przejść do metodologicznej analizy samej czynności. Uczynimy to najpierw w kontekście ogólnym, a następnie – informatycznym.

⁹ Metafora ta stanowi podstawę psychologii poznawczej, a także badań kognitywistycznych. Pośród innych wpływowych metafor, które leżą u podstaw innych nauk o umyśle, szczególnie ważne są: a) metafora umysłu jako *czarnej skrzynki* (która zapoczątkowała behawioryzm), oraz b) metafora umysłu-*mózgu* (którą przyjmuje się w ramach różnych neuro-nauk).

Na początek jednak ważna uwaga wstępna, kierująca uwagę czytelnika na wątek anonsowany już w punkcie 1.3. Otóż każda czynność modelowania – informatycznego, matematycznego, fizycznego itd. – ma swojego wykonawcę, czyli *badacza*. To badacz przecież wybiera obiekt modelowany, to badacz przekształca model, próbując uzyskać coraz pełniejszą wiedzę o interesującym go obiekcie, to badacz wreszcie decyduje, kiedy tworzony model staje się adekwatny. Innymi słowy: to badacz kieruje *interakcją* między modelem a rzeczywistością, a zupełnie naturalny kontekst metodologicznej analizy całego procesu to układ trójczłonowy [*badacz, model, rzeczywistość*].

Czy mimo to – pamiętając o tym, że istnieją w informatyce pewne formalne i zautomatyzowane techniki nabywania wiedzy (co wyjaśnia pkt 3.4) – nie możemy myśleć o modelach powstających autonomicznie, bez kontroli badacza? A mówiąc inaczej: czy niektórych przynajmniej elementów procedury modelowania nie da się *zautomatyzować*? Oto pytania, które będą towarzyszyć dalszej analizie.

4.1. Mając na uwadze ważkie zagadnienie automatyzacji, zabierzmy się do rzeczy powoli i stopniowo. Nie pomijajmy na razie roli badacza, podzielmy złożoną czynność modelowania na odrębne etapy i zobaczymy, w jaki sposób konstytuują one coś, co można nazwać *interaktywną pętlą modelowania*. Na pętlę tę składają się cztery procedury.

Są to:

- (1) *abstrakcja* – procedura, w toku której należy wyodrębnić te *cechy* modelowanego zjawiska, które będą uwzględnione w modelu, resztę zaś pominąć;
- (2) *formalizacja*¹⁰ – procedura, w toku której należy odwołać się do *meta-teorii*, to znaczy wybrać i zastosować narzędzia formalne (teorie matematyczne, teorie informatyczne, algorytmy, struktury danych itp), pozwalające opisać ściśle (zazwyczaj symbolicznie) modelowane zjawisko;
- (3) *symplifikacja* – procedura, w toku której formalną strukturę modelu *upraszcza się* (na drodze przekształceń formalnych), tak aby zachować pierwotny stopień spójności (niesprzeczności) modelu, a także jego pierwotną moc wyjaśniającą i prognostyczną;
- (4) *weryfikacja* – procedura, w toku której sprawdza się takie własności modelu, jak zgodność z opisywanym fragmentem rzeczywistości (adekwatność), jego niesprzeczność lub pożądaný stopień niesprzeczności (spójność), a także efektywność prognostyczną i prostotę (z punktu widzenia określonego inter-

¹⁰ Etapy abstrakcji i formalizacji są ze sobą ściśle powiązane, być może nawet, stanowią jedną całość. Wynik zabiegu abstrakcji, tj. wybór istotnych cech modelowanego zjawiska, zależy w dużej mierze od używanego narzędzia formalnego (określony formalizm eliminuje np. pewne typy abstrahowanych cech). Z drugiej strony założony wstępnie wynik abstrakcji, tj. abstrahowane cechy, motywuje badacza do wyboru takiego a nie innego narzędzia formalnego.

pretatora)¹¹; dodajmy, że model należy sprawdzać zarówno w oderwaniu od innych konstrukcji, np. wyprowadzając z niego pewne wnioski, a następnie sprawdzając ich zgodność z rzeczywistością, jak również w odniesieniu do konstrukcji alternatywnych, np. porównując ze sobą moc prognostyczną lub prostotę różnych modeli.

Należy podkreślić, że wskutek definicyjnej „przybliżoności” modelu – a także za sprawą aktywności konstruującego model badacza – na etapie (4) procedura modelowania, czy też dochodzenia do modelu maksymalnie adekwatnego, nie kończy się, lecz *zapętla*. Następuje przejście do etapu (1), w którym uwypukla się – zależnie od wyników weryfikacji – inne cechy modelowanego zjawiska niż w cyklu poprzednim. W ten sposób dokonuje się *innego rodzaju abstrakcji*, która stanowi podstawę etapów kolejnych; dodajmy tu, że zależnie od intensywności zmian w ramach nowej procedury abstrakcji, twórca modelu może wybrać nowe narzędzia formalne (meta-teoretyczne) lub pozostać przy dotychczasowych.

Cztery w/w etapy złożonej czynności modelowania, polegające *de facto* na wykonywaniu pewnych zabiegów poznawczych, należy rozpatrywać w odniesieniu do *czterech elementów*, których zabiegi te dotyczą.

Są to:

- (a) badana *dziedzina* D – będąca fragmentem rzeczywistości empirycznej;
- (b) dana *meta-teoria* MT – będąca uporządkowanym hierarchicznie konglomeratem *stricte* formalnych teorii, mikro-teorii i schematów (w odniesieniu do modeli informatycznych powiedzielibyśmy, że najwyższe miejsce w hierarchii zajmują teorie matematyczne, a najniższe algorytmy i używane w nich struktury danych);
- (c) konstruowana *teoria badanej dziedziny* TD – pod względem formalnym identyczna z pewnym fragmentem meta-teorii (a mówiąc inaczej: teoria, której język formalny określa meta-teoria);
- (d) konstruowany *model* M – będący testowanym aktualnie fragmentem teorii TD (fragmentem, który w razie pozytywnej weryfikacji uwiarygodnia teorię TD).

Ze względu na cztery w/w elementy – D, MT, TD i M – można podać następującą charakterystykę czterech etapów modelowania: *abstrakcja* dotyczy wstępnego wyboru i opisu tych „fragmentów” rzeczywistości, a w niej dziedziny D, które badacz chce uwzględnić w modelu; zachodzi więc między D i TD; *formalizacja* oznacza zastosowanie meta-teorii MT do precyzyjnego opisu dziedziny D w postaci modelu M (w ujęciu wąskim) lub teorii TD (w ujęciu szerokim); zachodzi więc między D, MT i M/TD; operację tę można nazwać interpretacją pewnego fragmen-

¹¹ Właściwie należałoby tu mówić – za Popperem – o próbach falsyfikacji, tj. weryfikacji ukierunkowanej na odrzucenie modelu. Por. [Popper 2002 (1934)].

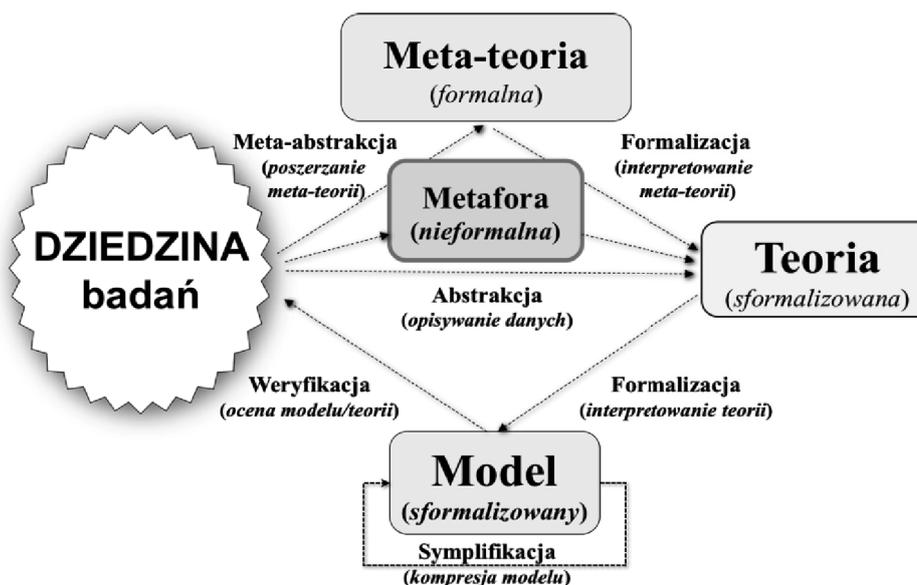
tu meta-teorii w dziedzinie D; *symplifikacja* odbywa się w ramach wyznaczonych przez MT (np. jeśli MT jest teorią dedukcyjną obowiązują w niej określone reguły wyvodu), a dotyczy przekształceń modelu M; *weryfikacja* polega na konfrontacji modelu (również wyprowadzonych z niego przewidywań) z odpowiednim fragmentem rzeczywistości, czyli dziedziną D; zachodzi więc między M i D (pośrednio jest to weryfikacja teorii TD).

Nie należy zapominać, że w przypadku niektórych modeli – np. cząstkowych modeli umysłu IMCU (zob. 3.5 i 3.6), realizowanych za pomocą aplikacji (komputerowych) i/lub systemów informatycznych – wstępny kształt modelu określa *metafora* (np. metafora umysłu jako systemu informatycznego).

W interaktywnej pętli modelowania metaforę trzeba więc uwzględnić. Można zauważyć nawet coś więcej: w praktyce modelowania niejednokrotnie zachodzi potrzeba – wobec serii negatywnych weryfikacji modeli opartych na danej metaforze – zmiany metafory na inną (np. zmiany metafory umysłu jako „czarnej skrzynki” na metaforę informatyczną). Z tego względu obecność metafory w schemacie interaktywnej pętli modelowania jest jak najbardziej uprawniona.

Nie należy zapominać nadto, że wykorzystywana meta-teoria (której wybór zależy często od treści bieżącej metafory) nie jest czymś zamkniętym i ściśle określonym. W trakcie modelowania, głównie zaś w wyniku negatywnej weryfikacji kolejnych modeli, zachodzi potrzeba wyabstrahowania z rzeczywistości (ewentualnie skonstruowania *a priori*) nowych elementów meta-teorii. Operację tę można nazwać *meta-abstrakcją*.

Poczynione wyżej spostrzeżenia uwidacznia poniższy schemat.



4.2. Mając na uwadze powyższe określenia, objaśnienia i rozrysowany schemat, można wyjaśnić bliżej, co rozumiemy przez *pętlę modelowania*.

Składają się na nią trzy cykle:

(1) *mały cykl symplifikacji* – ta pętla, polegająca na czysto formalnej/syntaktycznej eliminacji „nadmiarowych” elementów modelu, może być realizowana automatycznie, tj. bez udziału badacza; do jej komputerowej realizacji nadają się dobrze algorytmy automatycznego uczenia się (o czym dalej).

(2) *właściwy cykl modelowania* – na tę pętlę składają się cyklicznie powtarzane zabiegi abstrakcji, formalizacji, symplifikacji i weryfikacji (z wykorzystywaniem meta-teorii, a niekiedy też z początkowym odwołaniem się do metafory); cały proces pozostaje pod kontrolą badacza (decydującego np. o przebiegu abstrakcji i formalizacji); można jednak zastanawiać się nad jego umaszynowaniem, pozostawiając badaczowi rolę instancji oceniającej tymczasowe modele.

(3) *szeroki cykl modelowania* – w którym dopuszcza się konstrukcję nowych elementów meta-teorii oraz posilkowanie się nowymi metaforami (nowymi w stosunku do tej, która zapoczątkowała całą procedurę)¹².

4.3. Chcąc rozpatrzyć opisaną wyżej procedurę w kontekście informatycznym, musimy przypomnieć (za punktem 2.2), że w kontekście tym modelowanie rozumie się jako *programowanie* – ugruntowane matematycznie i odwołujące się do różnych technik informatycznych, a mające na celu zaprojektowanie aplikacji modelującej i/lub sterowanego tą aplikacją systemu.

Przyjąwszy tak szeroką koncepcję programowania, możemy scharakteryzować ogólnie kolejne etapy modelowania, zwracając za każdym razem uwagę na możliwość *automatyzacji* danego etapu. Jest to zagadnienie niezmiernie interesujące ze względu na fakt, że automatyzacja różnych procesów stanowi najważniejszy – a w wielu przypadkach już zrealizowany – cel badań informatycznych¹³.

¹² Na rysunku powyżej mały cykl modelowania jest oznaczony „zapętloną” strzałką wokół elementu *model*; właściwy cykl modelowania wyznaczają trzy strzałki tworzące trójkąt o wierzchołkach *model*, *dziedzina*, *teoria*; duży cykl modelowania natomiast obejmuje wszystkie strzałki.

¹³ W tym miejscu nie sposób pominąć ważnego rozróżnienia między a) informatyką jako narzędziem wspomagającym wszelkie modelowanie, oraz b) informatyką jako dziedziną macierzystą modelu (informatycznego). A ujmując rzecz proceduralnie, rozróżnić trzeba między: a1) procedurą konstruowania *dowolnego modelu* z aktywnym wykorzystywaniem przez badacza różnych narzędzi informatycznych (m.in. algorytmów pozyskiwania i redukcji wiedzy); oraz b1) procedurą konstruowania *modelu informatycznego*, tj. modelu (teoretycznego) w postaci aplikacji, którego podstawą jest jakiś algorytm, a ujmując rzecz szerzej, jakaś mini-teoria przetwarzania danych. Sugerowane rozróżnienie nie ma charakteru alternatywy: sytuacja b/b1 może być bowiem traktowana jako szczególny przypadek sytuacji a/a1.

W dalszych uwagach będziemy koncentrować się na sytuacji b/b1, pamiętając jednak o tym, że współczesna informatyka – jako najsprawniejsze narzędzie automatyzacji procesów poznawczych – jest wykorzystywana w każdej niemal procedurze modelowania.

Zacznijmy od dwóch splecionych ze sobą etapów *abstrakcji* i *formalizacji*. Chodzi w nich o opis modelowanego zjawiska w precyzyjnych kategoriach *struktur danych* (czy szerzej: metod reprezentacji wiedzy) dostosowanych zwykle do wybranej wcześniej techniki przetwarzania danych. Na przykład, reprezentacja wiedzy w postaci formuł logiki predykatów 1-go rzędu jest nierozzerwalnie spleciona z regułowymi technikami przetwarzania danych, reprezentacja w postaci sieci neuropodobnych – z technikami konekcyjnymi, zaś reprezentacja za pomocą struktur genetycznych – z technikami ewolucyjnymi (por. [Stacewicz 2010]).

Kiedy badacz dokona już wyborów meta-teoretycznych, czyli zdecyduje się na konkretny *kształt formalny* modelu, może przystąpić do *interpretacji* formalizmów w interesującej go dziedzinie. Na przykład: może związać struktury danych z konkretnymi, coś-oznaczającymi danymi. Niekoniecznie przy tym musi budować całą teorię tej dziedziny, może przystąpić od razu do budowy pewnego jej fragmentu, czyli konkretnego modelu-aplikacji, który będzie stosowany w wyróżnionej dziedzinie. I tu dwie uwagi odnośnie automatyzacji: (1) automatyzacja etapu abstrakcji byłaby możliwa pod warunkiem istnienia jakiegoś uniwersalnego schematu wyboru coraz bardziej obiecujących (ze względu na adekwatność modelu) cech modelowanego zjawiska, oraz (2) o ile modelowanie uznać za domenę ludzkiego umysłu, to automatyzacja etapu formalizacji byłaby możliwa pod warunkiem istnienia uniwersalnego formalizmu (np. rachunku logicznego) lub przynajmniej skończonego zbioru takich formalizmów, które opisywałyby czynności umysłowe.

W etapie kolejnym, tj. etapie *symplicyfikacji*, badacz musi zastosować jakieś informatyczne narzędzie upraszczania wstępnego modelu-aplikacji. Wydaje się, że największe zastosowanie mogą tu znaleźć metody automatycznego uczenia się (*machine learning*) – dotyczące redukcji wiedzy. Jedną z takich metod to opisana w pracy [Pawlak 1991] metoda redukcji tabel decyzyjnych. Spośród innych warto wymienić: metody oparte na samoorganizujących się sztucznych sieciach neuronowych i algorytmach genetycznych. Automatyzacja w tym zakresie jest jak najbardziej możliwa ze względu na algorytmiczny charakter wspomnianych metod.

W etapie kolejnym badacz musi dokonać *weryfikacji* modelu-aplikacji – to znaczy sprawdzić, czy uproszczona aplikacja działa, czy realizuje modelowany proces (w sensie tych samych wyników), czy wykazuje istotne podobieństwa funkcjonalno-strukturalne do znanych skądinąd własności modelowanego zjawiska, czy nie istnieją aplikacje prostsze, sprawniejsze i lepiej odzwierciedlające modelowane zjawisko...

Przeprowadziwszy odpowiednią liczbę drobiazgowych testów, badacz może uznać aplikację za wystarczająco dobry model tymczasowy lub odrzucić model, by w przyszłości odwołać się do innej postaci metafory informatycznej i/lub innych narzędzie formalnych informatyki.

4.4. Jako przykład obrazujący powyższe uwagi rozważymy zagadnienie szczególnie ważne z punktu widzenia współczesnych zastosowań informatyki, a mianowicie proces posługiwania się *pojęciami* w celu rozpoznawania obiektów określonego typu. Nie wdając się szczegółowo w kwestie logiczne i psychologiczne, wyjaśnijmy krótko, że przez pojęcia w logice rozumie się znaczenia nazw ogólnych (takich jak owoc, samochód, mebel itp), o których sądzi się dodatkowo, że mają w umysłach ludzkich pewne reprezentacje, będące uogólnionymi wzorcami obiektów pewnego typu (tak właśnie sądzą psychologowie). Na przykład, jeśli osoba X zna (czy też: ma) pojęcie, dajmy na to, kredensu, to w jej pamięci tkwi jakiś ogólny obraz różnych możliwych kredensów, na podstawie którego potrafi poprawnie wyróżniać kredensy spośród innych mebli (por. [Maruszewski 1996]).

Mając na uwadze powyższe objaśnienie, przejdźmy do zapowiadanego przykładu ogólnego. Niech przedmiotem modelowania będzie pojęcie, rozpatrywane pod kątem możliwości rozpoznawania obiektów (tj. desygnatów pojęcia) na podstawie ich wyróżnionych cech. Zobaczmy, jak wyglądają poszczególne etapy procedury modelowania.

W etapie pierwszym, czyli etapie abstrakcji, twórca modelu musi wybrać *cechy istotne* rozpoznawanych obiektów i do nich zawęzić dalsze kroki. Załóżmy, że chodzi o obiekty podpadające pod pojęcie *owoc*, zdefiniowane za pomocą czterech tylko cech, np. (*barwa, kształt, smak, termin dojrzewania*). Z każdą z cech wiąże się ściśle określony zbiór wartości; np. dla *barwy* są to wartości: *czerwona, zielona, żółta, pomarańczowa, fioletowa*.

W etapie drugim, czyli etapie formalizacji, należy określić *schemat reprezentacji* pojęcia – schemat osadzony w jakiejś stosunkowo bogatej teorii formalnej, która umożliwia operowanie na schematach mu podobnych. Załóżmy, że twórca modelu wybiera wspomnianą już dwukrotnie teorię zbiorów przybliżonych Z. Pawłaka i wywodzącą się z niej logiczną metodę reprezentacji pojęć jako *reguł decyzyjnych* (zob. [Pawlak 1991], a także [Bolc, Cytowski, Stacewicz 1996]). Przy takim wyborze pojęciu odpowiada alternatywa implikacji logiki decyzyjnej, w poprzednikach których stoją koniunkcje wartości wybranych uprzednio cech, a w następnikach liczby 0 i 1 (0 – informuje o tym, że dana reguła jest negatywnym opisem pojęcia, a 1 – że pozytywnym). Na przykład, jedna z reguł składających się na definicję śliwki (jako jednego z owoców) mogłaby wyglądać następująco „Jeśli (*barwa, fioletowa*) i (*kształt, owalny*) i (*smak, słodko-kwaśny*) i (*termin dojrzewania, sierpień*), to (*śliwka, 1*)”.

W etapie kolejnym, czyli etapie symplifikacji, należy wybrać metodę (najlepiej zautomatyzowaną), która pozwoli maksymalnie *uprościć model*, a więc w naszym wypadku, ograniczyć liczbę reguł i ich elementów, które w sumie składają się na reprezentację pojęcia. Załóżmy, że w tym celu zostaje wybrany wywodzący się z teorii zbiorów przybliżonych *algorytm redukcji wiedzy*. Algorytm ten prowadzi do zminimalizowanego zbioru reguł, który zapewnia tę samą zdolność rozpo-

znawania desygnatów pojęcia co zbiór pierwotny; innymi słowy, jeśli zbiór reguł decyzyjnych rozumieć jako model pojęcia, to algorytm ten doprowadza do modelu uproszczonego. Po dokonaniu tak pojętej symplifikacji twórca modelu musi ocenić model uproszczony, np. pod kątem stopnia dokonanej redukcji (przechodzi zatem do etapu weryfikacji)¹⁴. Jeśli stopień redukcji jest, jego zdaniem, niewystarczający, może powrócić do etapu abstrakcji i wybrać inny zbiór cech oraz ich wartości. W ten sposób cykl modelowania może rozpocząć się od początku.

5. Uwagi końcowe

Zaproponowaną wyżej rekonstrukcję modelowania w kontekście informatycznym należy uznać za jeden z możliwych *modeli* tego, co faktycznie czynią teoretycy i praktycy budując informatyczne modele zjawisk. Opis nasz ma charakter przybliżony (jak każdy model) i odzwierciedla ogólne ramy procesu, który w rzeczywistości jest dużo bardziej skomplikowany, a z pewnością też może być ujmowany (tj. modelowany) na różne sposoby. Już to, co zaprezentowaliśmy, upoważnia jednak do wysnucia pewnych wniosków odnośnie związków między teorią modelowania i badaniami nad sztuczną inteligencją (SI).

Otóż po pierwsze, badania nad SI prowadzą w naturalny sposób do *modeli informatycznych* – modeli tych czynności, które są wyrazem ludzkiej inteligencji. Można stwierdzić śmiało, że służące realizacji różnych zadań poznawczych programy komputerowe, a przynajmniej niektóre z nich, są gotowymi modelami odpowiednich czynności. Wspominaliśmy w tekście o takich czynnościach, jak wnioskowanie, uczenie się i percepcja. Poczynić tu trzeba jednak ważne zastrzeżenie: otóż w kontekście modelowania liczy się nie tylko tożsamość rezultatów (czynności właściwej i jej symulacji), ale także podobieństwo (obydwu czynności) co do przebiegu i ich wewnętrznej struktury.

Po drugie jednak, co wydaje się dużo ważniejsze, badania nad SI mogą dostarczyć skutecznych środków *automatyzacji* procesu modelowania – i to modelowania wszelkiego rodzaju zjawisk, a nie tylko umysłowych. Elementem kluczowym są tu *algorytmy uczenia się*, będące – jak widzieliśmy – przedmiotem odrębnego działu informatyki. Algorytmy takie – jakkolwiek dziś są stosowane w zakresie dużo węższym – mogłyby sprawić, że model sam, bez ingerencji badacza, zmieniałby swój kształt i stawałby się coraz bardziej adekwatny. Kreśląc tak śmiałą wizję, zauważamy, że ma ona pewne oparcie w logice procesu modelowania. Wszak zaprezentowany schemat [(*abstrakcja*->*formalizacja*->*symplifikacja*->*weryfikacja*)...] jest w istocie ogólnym schematem uczenia się: tymczasowe modele zmieniają się zależnie od wyników weryfikacji, a wprowadzane zmiany mają doprowadzić do konstrukcji

¹⁴ Zauważmy, że procedura symplifikacji opartej na proponowanym algorytmie redukcji nie zmienia najbardziej istotnej własności modelu, jaką jest zdolność do rozpoznawania desygnatów pojęcia. Pierwotna zdolność zostaje zachowana. Dlatego też, weryfikując model, jego twórca nie może brać pod uwagę tejsze zdolności, lecz co najwyżej prostotę modelu.

najbardziej adekwatnej. Pozostają, rzecz jasna, zasygnalizowane w tekście pytania o to, w jakim stopniu poszczególne etapy całej procedury dają się zautomatyzować.

BIBLIOGRAFIA

- Bolc L., Cytowski J., Stacewicz P.: *O logice i wnioskowaniu przybliżonym*, Prace IPI PAN nr 822, Warszawa 1996.
- Cichosz P.: *Systemy uczące się*, Warszawa 2000, Wydawnictwa Naukowo-Techniczne.
- Ignizio J. P.: *An Introduction to Expert Systems*, New York 1991, McGraw-Hill.
- Maruszewski T.: *Psychologia poznawcza*, Warszawa 1996, Biblioteka Myśli Semiotycznej.
- Marciszewski W. [red.], *Mała encyklopedia logiki*, Wrocław 1988, Zakład Narodowy im. Ossolińskich.
- Marciszewski W., Stacewicz P.: *Umysł – Komputer – Świat. O zagadce umysłu z informatycznego punktu widzenia*, Warszawa 2011, Akademicka Oficyna Wydawnicza EXIT.
- Michalewicz Z.: *Genetic Algorithms + Data Structures = Evolution Programs*, Springer Verlag, 1992.
- Mitchell T.M.: *Machine Learning*, Singapore 1997, McGraw-Hill.
- McCulloch W., Pitts W.: *A Logical Calculus of the Ideas Immanent In Nervous Activity*, „Bulletin of Mathematical Biophysics” (5), 1943, s. 115-133.
- Old L.J., Priss U.: *Metaphor and Information Flow*, w: Proceedings of the 12th Midwest Artificial Intelligence and Cognitive Science Conference, 2001, s. 99-104.
- Quillian M.R.: *Semantic Memory*, Minsky M. [red.], *Semantic Information Processing*, Cambridge 1968, MIT Press, s. 227-270.
- Pawlak Z.: *Rough Sets. Theoretical Aspects of Reasoning about Data*, Dordrecht 1991, Kluwer Academic Publishers.
- Popper K. R.: *Logika odkrycia naukowego*, Warszawa 2002, Fundacja Aletheia, Oryg.: *Logik der Forschung*; Wiedeń 1934.
- Russel S., Norvig P.: *Artificial Intelligence: A Modern Approach*, Prentice-Hall, Englewood Cliffs 1994.
- Stacewicz P.: *Umysł a modele maszyn uczących się. Współczesne badania informatyczne w oczach filozofa*, Warszawa 2010, Akademicka Oficyna Wydawnicza EXIT.
- Stacewicz P., Włodarczyk A.: *Modeling in the Context of Computer Science – a Methodological Approach*, *Studies in Logic*, „Grammar and Rhetoric” 20, (33) 2010; s. 155-180.
- Tadeusiewicz R.: *Sieci neuronowe*, Warszawa 1993, Akademicka Oficyna Wydawnicza RM.
- Włodarczyk A.: *Interactive Discovery of Ontological Knowledge for Modeling Language Resources*, International Scientific Conference COGNITIVE and CONTRASTIVE STUDIES – MONDILEX Project Open Workshop „Representing Semantics in Digital Lexicography”, 2009 June 29th – July 1st, Pałac Staszica PAN, Warszawa 2009.
- Żurada J.M.: *Introduction to Artificial Neural Systems*, St. Paul 1992, West Publishing Company.