

## **Wstęp**

Rozumowanie i podejmowanie decyzji to podstawowe elementy podejścia opartego na sztucznej inteligencji opartego na reprezentacji wiedzy i wnioskowaniu (KR&R). KR&R zajmuje się projektowaniem, analizą i wdrażaniem algorytmów wnioskowania i struktur danych. Praca w KR&R ma głębokie korzenie w rzeczywistości: problemy z rozumowaniem pojawiają się naturalnie w wielu aplikacjach wchodzących w interakcję ze światem – zdroworozsądkowe odpowiadanie na zapytania, rozwiązywanie problemów diagnostycznych, planowanie, wnioskowanie na temat wiedzy naukowej, przetwarzanie języka naturalnego i kontrola wieloagentowa, aby wymienić kilka. Oprócz oczywistego znaczenia praktycznego, algorytmy rozumowania i reprezentacje wiedzy stanowią podstawę teoretycznych badań nad sztuczną inteligencją na poziomie ludzkim. Rozumowanie to poddziedzina KR&R poświęcona odpowiadaniu na pytania na podstawie różnych danych bez interwencji i pomocy człowieka. Zazwyczaj dane podawane są w jakimś formalnym systemie, którego semantyka jest jasna. We wczesnych dziesięcioleciach badań ukierunkowanych na zautomatyzowane rozumowanie i odpowiadanie na pytania (począwszy od lat pięćdziesiątych XX wieku) dane były w większości pokrewne wiedzy lub naszym intuicjom na ich temat. Niedawno (od lat 80. XX wieku) ludzie zakładali, że dane potrzebne do rozumowania są mieszkanką prostych danych i bardziej złożonych danych. Te pierwsze wymagają niskiego stopnia złożoności obliczeniowej do przetwarzania i są przedmiotem badań w dużych bazach danych (np. relacyjnych bazach danych, takich jak te rejestrujące transakcje sprzedaży w firmach, oprogramowanie księgowo dla osób fizycznych i ewidencja towarów w sklepach). Te ostatnie są podane bardziej wyrazistym językiem, zajmują mniej miejsca do przedstawienia i odpowiadają zarówno uogólnieniom, jak i bardziej szczegółowym informacjom. Podejmowanie decyzji to forma rozumowania skupiająca się na odpowiadaniu na pytania dotyczące preferencji między działaniami, na przykład w kontekście autonomicznego agenta próbującego wykonać zadanie dla człowieka. Często podejmowanie decyzji odbywa się w dziedzinie dynamicznej, która zmienia się wraz z realizacją działań i upływem czasu. W takich obszarach wcześniejsze działania wpływają na późniejsze decyzje, a zadaniem rozumowania jest znalezienie sekwencji działań lub uniwersalnego planu (polityki) reakcji na sytuacje lub bodźce zmysłowe. Podejmowane tam decyzje dotyczą osiągnięcia celów lub optymalizacji niektórych kryteriów, takich jak długość planu, koszt działań czy przyszła oczekiwana skumulowana nagroda. Badania nad dwoma tematami: rozumowaniem i podejmowaniem decyzji są często prowadzone oddzielnie, przy użyciu różnych metod i różnych teoretycznych interpretacji tych dwóch tematów, a niniejszy rozdział przeglądowy podzielono w podobny sposób. W rozdziale tym wyróżniono także badania prowadzone w oparciu o reprezentację, ze szczególnym uwzględnieniem reprezentacji logicznych i prawdopodobieństw. Jednakże badania nad tymi dwoma tematami również w znacznym stopniu uzupełniają się i przekazują główne wyniki, techniki i pomysły, a niniejszy przegląd przyjmuje szerszą perspektywę, zgodnie z którą te dwa problemy są zasadniczo takie same. Celem tego rozdziału jest zarówno przegląd bieżących badań, jak i omówienie bieżących i pojawiających się pytań w tej dziedzinie. Obie perspektywy przedstawiono łącznie, starając się położyć na nich równy nacisk. Oczywiście obie perspektywy są poważnie ograniczone. Istnieje ponad 100 000 artykułów i książek na temat rozumowania i podejmowania decyzji, z czego ponad 3000 artykułów publikowanych jest co roku, i nieuchronnie nie można tu omówić wielu szczegółów technicznych ani dużych wysiłków badawczych. Więcej informacji na ten temat można znaleźć w części „Dalsza lektura” oraz w cytowanych w tekście pracach.

## **Reprezentacja wiedzy i rozumowanie**

Od początków dziedziny sztucznej inteligencji jednym z dominujących poglądów na temat ścieżki rozwiązania problemu sztucznej inteligencji było poszukiwanie jednoznacznej reprezentacji wiedzy o danym systemie i rozumowania na jego temat. Lata 60. XX wieku przyniosły wiele sukcesów w zakresie

tego podejścia, znanego później jako KR&R. Większa część wysiłków była poświęcona logice pierwszego rzędu (FOL) jako ogólnemu językowi reprezentacji wiedzy oraz dowodom twierdzeń FOL jako generatorom inteligentnego zachowania. W latach 70. emocje opadły po odkryciu kilku przeszkód. Przeszkody te obejmowały złożoność rozumowania za pomocą FOL, kruchość systemów ekspertowych, trudność w reprezentowaniu codziennej wiedzy zdroworozsądkowej oraz problemy, jakie ma FOL w przedstawianiu wyciągania pochopnych wniosków lub rozumowania z domyślnymi wartościami. Lata 80. jeszcze bardziej uwydatniły lukę między KR&R a badaniami nad uczeniem maszynowym, teorią sterowania i teorią decyzji. Późniejsze badania w KR&R miały na celu rozwiązanie tych problemów dwiema ścieżkami: zrozumienie, w jaki sposób pokonać trudności obliczeniowe za pomocą FOL oraz zrozumienie, jak budować przydatne reprezentacje zjawisk w świecie rzeczywistym. FOL jest obliczeniowo równoważny maszynie Turinga i dlatego jest w stanie reprezentować wszystko, co potrafią obliczyć obecne komputery. Ta wyrazistość reprezentacji jest również powodem, dla którego obliczenia za jej pomocą są trudne, ponieważ FOL musi zająć dużo czasu, aby obliczyć wiele zapytań i może nigdy nie zakończyć obliczeń dla innych. Badania nad językami reprezentacji, które umożliwiają łatwe odpowiadanie na zapytania, dały wyniki w postaci języków specjalistycznych o dużej liczbie zastosowań. W tej sekcji opisano pracę wzdłuż tych ścieżek badawczych, koncentrując się na logicznym rozumowaniu, probabilistycznym i zdroworozsądkowym rozumowaniu.

### **Logika i kombinatoryka**

Logika matematyczna (odtąd logika) służy jako formalna podstawa dla wielu zastosowań w świecie rzeczywistym: komputerów i teorii obliczeniowej, naszego systemu prawnego i argumentacji, a także teoretycznych osiągnięć i dowodów w nauce i inżynierii. Nowoczesna logika zrodziła się z wysiłków (Fregego, Russella, Hilberta i wielu innych) na rzecz przedstawiania codziennych argumentów i rozumowań w sposób kompletny i niezaprzeczalny. Wysiłki KR&R (podążając za McCarthym 1958) skupiały się na rozszerzeniu tej wizji na możliwy do zrealizowania automatyczny system rozumowania komputerowego. W tej wizji osoba rozumująca reprezentuje swoją wiedzę o świecie w logice i uzasadnia tę wiedzę za pomocą algorytmów rozumowania ogólnego przeznaczenia. Szczegóły tego programu okazały się wyzwaniem pod kilkoma względami. Po pierwsze, niektóre rodzaje wiedzy (np. wiedza przestrzenna, czasowa i niepewna) okazują się trudne do przedstawienia w języku zdaniowym (McCarthy i Hayes 1969; Cohn 1997). Po drugie, nie jest łatwo skompilować wiedzę potrzebną do dużych zastosowań, ani też nie jest łatwo nauczyć się wiedzy w wyrazistym, logicznym języku (Lavrač i Džeroski 1994). Wreszcie, rozumowanie w językach ekspresyjnych, które wydają się potrzebne, nie jest obliczeniowo wykonalne ani łatwe, nawet jeśli można pokonać dwie pierwsze trudności (Tseitin 1970). Trzy krytyczne debaty toczące się na ten temat są następujące: Pierwsza to twierdzenie, że logika nie może reprezentować wielu rzeczy, takich jak analogia, przestrzeń, kształt, niepewność, a zatem nie powinna być brana pod uwagę jako odgrywająca aktywną rolę w budowaniu pełnowymiarowego społeczeństwa ludzkiego. poziom systemu AI. Kontrargument sugeruje, że logika może służyć jako jedno z kilku narzędzi. Obecnie jego połączeniu siły reprezentacji, elastyczności i przejrzystości nie dorównuje żadna inna metoda ani system. Druga krytyczna debata dotyczy twierdzenia, że logika jest zbyt powolna, aby można było wnioskować i dlatego nigdy nie odegra roli we wdrożonym systemie. Twierdzenie wzajemne jest takie, że istnieją sposoby przybliżenia wnioskowania za pomocą logiki, tak aby mieściło się ono w granicach czasowych i nastąpił postęp w przyspieszaniu wnioskowania logicznego. Wreszcie niektórzy twierdzą, że bardzo trudno jest stworzyć systemy aksjomatów logicznych dla dużych zastosowań w świecie rzeczywistym. Ci, którzy uważają inaczej, rozwijają strumień aktywnych badań nad technikami uczenia się aksjomatów logicznych z tekstu w języku naturalnym i autorów w Internecie (WWW) (Mancilla-Caceres i Amir 2011). Istnieje wiele różnych typów logiki; rozważymy niektóre z najważniejszych, w tym logikę zdań, logikę pierwszego rzędu, logikę modalną i logikę niemonotoniczną. Logika zdań jest bardzo prostym i powszechnym językiem

reprezentacji formalnej. Reprezentowanie w nim wiedzy jest już zakończone symbole zdań (szczególny przypadek zmiennych boolowskich)<sup>1</sup> i spójniki zdaniowe, takie jak  $\wedge$  (i),  $\vee$  (lub) i  $\neg$  (nie). Na przykład wzór  $\phi = \neg \text{deszcz} \vee \text{chmury}$  stwierdza, że jeśli jest deszcz, to muszą być chmury. Istnieją cztery typowe zadania rozumowania w przypadku znajomości logiki zdań: (1) Spełnialność: Czy istnieje model dla  $\phi$ ? (model formuły to takie przypisanie wszystkich zmiennych, że formuła ma wartość PRAWDA); (2) Założenie: Czy  $Q$  logicznie wynika z  $\phi$ ? (zapisane  $\phi \vDash Q$  dla danego wzoru  $Q$ ); (3) Liczenie modeli: ile modeli ma  $\phi$ ? oraz (4) Kwantyfikowane formuły logiczne (QBF): zapytania, które przeplatają warunki konsekwencji w przypadku niektórych zmiennych i spełnialność w przypadku innych zmiennych. Centralną koncepcją logiki klasycznej w ogóle jest koncepcja implikacji lub wnioskowanie. Relacja syntaktyczna  $\vdash$  oznacza możliwość mechanicznego wyprowadzenia zapytania ze zbioru aksjomatów  $\phi$  poprzez zastosowanie szeregu kombinacji składniowych i manipulacji formułami odpowiadającymi zadanemu zbiorowi reguł. Natomiast relacja semantyczna  $\vDash$  (implikacja logiczna) dostarcza nam definicji znaczenia implikacji. Biorąc pod uwagę semantyczną relację między strukturami formalnymi (modelami) a zdaniami logicznymi, definicje implikacji zazwyczaj mówią, że zbiór zdań logicznych pociąga za sobą kolejne zdanie, jeśli wszystkie modele spełniające każde zdanie pierwszego spełniają również to drugie. Na przykład, jeśli wszystkie modele „deszczu” spełniają warunki „deszczu  $\vee$  chmury”, wówczas mówimy, że „deszcz” logicznie pociąga za sobą „deszcz  $\vee$  chmury”. Logiki zazwyczaj mają definicje obu relacji i twierdzenia o „kompletności” ustanawiające równoważność między tymi dwoma relacjami. Łącznie umożliwiają one obliczenie, czy  $\phi$  wynika ze zbioru przesłanek  $T$ . QBF to formuły zdaniowe z kwantyfikatorami. Reprezentują stwierdzenia takie jak „istnieje plan (sekwencja działań), który doprowadzi do celu niezależnie od stanu początkowego”, co można zapisać jako QBF  $\exists \text{plan} \forall s_0 \text{ cel}(\text{do}(\text{plan}, s_0))$ , gdzie  $\text{plan}$  i  $s_0$  są reprezentowane jako zbiory zdań logiki zdań,  $\text{do}$  to kodowanie zdań (z większą liczbą zmiennych zdaniowych) wykonania sekwencji planu działań zaczynając od  $s_0$ , a  $\text{cel}$  to formuła zdaniowa na zmiennych końcowych  $\text{do}(\text{plan}, s_0)$ . Spełnianie ograniczeń to uogólnienie logiki zdań na zmienne, które nie są wartościami boolowskimi i mogą przyjmować wartości z dziedziny skończonej. Obecne badania nad logiką zdań i spełnianiem ograniczeń skupiają się na znalezieniu skutecznych rozwiązań tych zadań, przy czym heurystyki i teoretyczne rozumienie są rozwijane dla różnych rozkładów problemów (Selman, Mitchell i Levesque 1997). Logika pierwszego rzędu (FOL) rozszerza logikę zdań i składa się z języka, teorii dowodu i semantyki. Przykład powinien wyjaśnić różnicę:

$$\psi = \exists \text{time clouds}(\text{time}, \text{above}(\text{Chicago})) \wedge \text{rain}(\text{time}, \text{Chicago})$$

to formuła w FOL, która mówi, że są okresy ( $\exists$ czas), w których nad Chicago są chmury, ale nie pada deszcz. Tutaj są chmury i deszcz predykaty, czyli symbole oznaczające relacje, czas jest zmienną

nad bytami (możliwe czasy), Chicago jest stałym symbolem mającym odnosić się do miasta Chicago w USA, a powyżej ( $x$ ) jest symbolem funkcji ma odnosić się do obszaru powyżej  $x$ . Formalnie język FOL ma zestaw symboli stałych obiektowych, zestaw symboli predykatów relacji, zestaw symboli funkcji i zestaw spójników (OR ( $\vee$ ), AND ( $\wedge$ ), NOT ( $\neg$ )), kwantyfikatorów (ISTNIEJE ( $\exists$ ), DLA WSZYSTKICH ( $\forall$ )), a nawiasy oznaczają operatorów budynków. Razem wybrany zestaw symboli predykatów, stałych i funkcji nazywany jest sygnaturą języka. Na przykład powyższy wzór  $\psi$  ma podpis  $\langle \text{Chicago}; \text{chmury}, \text{deszcz}; \rangle$ . FOL ma bogatszą interpretację niż logika zdań. Interpretacją jest para  $M = \langle U, I \rangle$ , która określa wszechświat elementów  $U$  i funkcję interpretacji  $I$  dla podpisu. Na przykład jedna interpretacja to  $U = \{15:00, 24 \text{ kwietnia } 2012, 16:00, 24 \text{ kwietnia } 2012, \text{Tel Awiw}\}$  i  $I(\text{chmury}) = \langle 15:00, \text{Tel-Awiw}, 16:00, \text{Tel Awiw} \rangle$ ,  $I(\text{deszcz}) = 16:00, \text{Tel-Awiw}$  i  $I(\text{Chicago}) = \text{Tel-Awiw}$ . W tej interpretacji w Tel-Awii w Izraelu są chmury o 15:00 i 16:00, ale deszcz pada tylko o 16:00. Symbol Chicago w naszym podpisie jest interpretowany jako prawdziwy Tel-Awiw w Izraelu.  $M = \langle U, I \rangle$  nazywa się modelem  $\psi$  powyżej. Zaangażowanie jest oznaczane przez  $M \vDash \psi$ , ponieważ interpretacja  $\psi$  w  $M$  ma wartość

PRAWDA. FOL ma bardzo bogatą siłę wyrazu, zwłaszcza gdy jest wyposażony w odpowiednie słownictwo i aksjomaty (np. zbiór aksjomatów w języku FOL, który może reprezentować całą współczesną matematykę). W rzeczywistości jest tak wyrazisty, że może reprezentować każde zadanie obliczeniowe, które można rozwiązać w powszechnym modelu nowoczesnych komputerów, maszynie Turinga. Maszyna Turinga modeluje obliczenia we wszystkich zbudowanych do dziś komputerach (jeśli to możliwe, przyszłe komputery kwantowe będą wykraczać poza tę moc obliczeniową). Dlatego każdy problem obliczeniowy i algorytm można zapisać w FOL w taki sposób, że implikacja w FOL jest równoważna rozwiązaniu problemu przez komputer. Jest to istotne, ponieważ zniechęca do poszukiwania bardziej ekspresyjnych języków, ponieważ z pewnością będą one poza naszymi możliwościami obliczeniowymi. Ekspresyjność FOL pomaga badaczom przekładać wyniki dotyczące FOL na wyniki dotyczące bardziej specjalistycznych problemów. Na przykład wyniki dotyczące automatycznego wnioskowania za pomocą FOL (Amir i McIlraith 2005) doprowadziły do nowych metod automatycznego planowania robotów (patrz sekcja 9.3.1.). Niektórzy twierdzą, że FOL nie ma praktycznego zastosowania w rzeczywistych zastosowaniach, ponieważ jego wyrazistość powoduje trudne obliczenia. Inni twierdzą, że ekspresja FOL jest wymagana do reprezentacji wiedzy ogólnej. Twierdzenia, że FOL nie jest wystarczająco wyrazisty, aby przedstawić kwantyfikację relacji lub prawdopodobieństw i modalności, spotykają się z kontrargumentami, które stosują teorię mnogości w FOL do reprezentowania takich brakujących konstrukcji. Logiki modalne to logiki z operatorami modalnymi, to znaczy operatorami, które przyjmują formuły jako argumenty. Na przykład

*believes(John, at(Sarah, Home))*

ma operator modalny, który przyjmuje symbol stały John i formułę FOL *at(Sarah, Home)* jako argumenty. W tym przykładzie operator modalny uważa, że pomija wartość logiczną *at(Sarah, Home)*. Może być tak, że Sary nie ma w domu, ale John nadal w to wierzy. Wiele operatorów modalnych stosowanych w AI oznacza wiedzę i przekonania, odpowiednio K i B (Fagin i in. 1995). Unikalną zdolnością takich języków jest możliwość omawiania przekonań na temat przekonań na temat przekonań i tak dalej. Można na przykład wyrazić (i uzasadnić) przekonanie Sary, że Jan zna szyfr do sejfku:

$B_{Sarah}(\exists \text{comb } K_{John}(\text{unlocks}(\text{comb}, \text{Safe})))$

Podobnie, mając grupę agentów, można reprezentować i uzasadniać przekonania grupy (np. wszyscy wiedzą, że Jan zna kombinację do sejfku) oraz wiedzę powszechną (tj. wszyscy wiedzą, że wszyscy wiedzą...). Wreszcie innym ważnym zastosowaniem logiki modalnej jest zdolność do reprezentowania wymagań i wiedzy w czasie, na przykład zgodnie z ostatecznym stanem  $\phi$ . Jest to szczególnie przydatne w weryfikacji formalnej i innych podejściach do zapewniania poprawności obwodów cyfrowych, protokołów i oprogramowania (Manna i Pnueli 1995). Wszystkie omówione powyżej logiki są monotoniczne, co oznacza, że dodawanie wiedzy nigdy nie powoduje wycofania wniosków. Formalnie dla wzorów A, B, C, jeśli  $A \models C$ , to także  $A \wedge B \models C$ , niezależnie od tego, czym jest B. Ta monotoniczność nie sprawdza się w rzeczywistych sytuacjach, w których wyciąga się wnioski bez uprzedzenia, dlatego w ciągu ostatnich trzydziestu do czterdziestu lat pojawiła się dziedzina skupiająca się na tworzeniu systemów zapewniających odpowiednie ramy do rozumowania w niemonotonicznych formach na temat sytuacji w świecie rzeczywistym. Przykładem takiej logiki niemonotonicznej jest opis , będący metodą wnioskowania niemonotonicznego, która przyjmuje założenia o minimalności niektórych predykatów, jeśli założenia te są spójne z resztą wiedzy. Na przykład,


$\varphi = Ab(John) \rightarrow rich(John)$

mówi, że Jan nie jest bogaty, jeśli nie jest nienormalny. Minimalizowanie predykatu  $Ab$  w  $\phi$  tak, aby odnosił się on tylko do tych rzeczy, o których obecnie wiadomo, że są nienormalne, oznacza, że Jan nie jest bogaty. Jeśli teraz dowiemy się, że John zainwestował w Google przed jego wejściem na giełdę, wówczas  $Ab$  rozszerzy się o Johna i wycofamy się z ostatniego wniosku. Sposób rozumowania niemonotonicznego rozszerzył się od czasu jego debiutu i obecnie istnieje kilka podręczników, które dają rzetelny obraz tego rozumowania oraz jego zastosowań. W badaniu różnych reguł wnioskowania i aksjomatów, które spełnia relacja wnioskowania, uważa się relację wnioskowania jako relację między zbiorem zdań a zdaniem w języku formalnym - zazwyczaj albo zdaniowym, albo pierwszego rzędu. Kraus, Lehmann i Magidor (1990) oraz dalsze prace badają warunki, jakie powinna spełniać ta relacja implikacji, wraz z pewnymi implikacjami praktycznymi. Większość prac na ten temat dotyczyła konkretnych scenariuszy, w szczególności rewizji przekonań. Obecnie główne zastosowania systemów rozumowania niemonotonicznego obejmują formalizowanie różnych aspektów rozumowania zdroworozsądkowego i szybkie wdrażanie metod rozumowania w ograniczonych zestawach problemów rozumowania niemonotonicznego. Tematy zastosowań wykorzystujących te techniki obejmują robotykę kognitywną, planowanie, uczenie się i reprezentację preferencji oraz szybkie rozwiązania w zakresie ekspresyjnych rozszerzeń logiki zdań.

### **Przedstawienia probabilistyczne i rozumowanie**

Wiedza o zjawiskach stochastycznych i niepewność co do nich, iedzę i przekonania można uchwycić za pomocą narzędzi z teorii prawdopodobieństwa i statystyki. Narzędzia te ułatwiają dyskusję i automatyczne wnioskowanie na temat prawdopodobieństwa zdarzeń, przekonań, które możemy posiadać, zmian w tych przekonaniach podczas dokonywania obserwacji oraz stopnia naszej pewności co do tych przekonań. Badania nad tym paradygmatem stały się w ostatnich latach popularne. Badania skupiają się na reprezentacji różnych rodzajów niepewności i niepewnej wiedzy, rozumowaniu na podstawie tego rodzaju wiedzy i uczeniu się ich. Jest również ściśle powiązany ze statystycznymi podejściami do uczenia maszynowego i teorii sterowania, ułatwiając w ten sposób rozwój stosowanych systemów o znaczeniu praktycznym, takich jak aplikacje do diagnostyki medycznej, sterowanie robotyczne, widzenie maszynowe i przetwarzanie języka naturalnego. W tej części omówiono główne podejścia i problemy dotyczące tej poddziedziny badawczej. Zajmuje się głównie modelami graficznymi rozkładów prawdopodobieństwa i opisuje pewne założenia leżące u podstaw ich stosowania. Te modele graficzne są konstrukcjami matematycznymi opisującymi fragmenty rzeczywistości, z pewnymi założeniami strukturalnymi i parametrami numerycznymi. W tej części omówiono także podejścia do wnioskowania z wykorzystaniem tych modeli oraz uczenia się ich parametrów i struktur na podstawie danych. Teoria prawdopodobieństwa opiera się na pojęciu eksperymentu losowego, czyli eksperymentu, którego wynik można przewidzieć z ograniczoną pewnością. Zazwyczaj zakładamy, że eksperyment można powtórzyć w identycznych okolicznościach z identycznymi właściwościami statystycznymi wyniku. Założenia te pozwalają na dyskusję, opis i wnioskowanie na temat wiedzy niepewnej (np. uważam, że akcje Facebooka jutro wzrosną z pewnością 0,5) i wiedzy statystycznej (np. 50% dni, w których akcje Facebooka rosną na wartości). Właściwości losowego eksperymentu rejestruje się za pomocą zmiennych losowych i rozkładu prawdopodobieństwa. Każda zmienna losowa  $X$  jest abstrakcją odnoszącą się do (a priori nieznanego) wyniku (wartości)  $x$  losowego eksperymentu. Na przykład zmienna losowa  $Up_{Facebook}$  może przyjmować wartości PRAWDA lub FAŁSZ. Rozkład prawdopodobieństwa  $P$  odwzorowuje wartości, jakie może przyjąć zmienna losowa, na segment liczb rzeczywistych  $[0, 1]$ . W powyższym przykładzie  $P(Up_{Facebook} = TRUE) = 0,5$  obejmuje zarówno pojęcie wiedzy niepewnej, jak i wiedzy statystycznej, tylko przy różnych założeniach podstawowych dotyczących znaczenia losowego eksperymentu. Wiele przypadków interesujących społeczność AI dotyczy domen, które są zbyt duże, aby można było je bezpośrednio określić i uzasadnić. Na przykład, gdy nasza przestrzeń próbna  $\Omega$  w powyższym przykładzie ma  $n$  akcji,  $\Omega$  ma  $2^n$  wartości. Prosta

reprezentacja rozkładu tych wartości ma formę tabeli, której każdy wiersz jest możliwą kombinacją wartości dla stanu każdej akcji (np. UpFacebook = True, UpGoogle = False itp.). Zatem tabela ta miałaby  $2^n$  wierszy i dlatego byłaby zbyt duża, aby pomieścić w pamięci komputera skromne  $n = 50$ . Z tego powodu od lat 90. badania skupiały się na podejściach do kodowania rozkładów prawdopodobieństwa w tak dużych dziedzinach, łącznie z metodami wnioskowania z tymi kodowaniami. Graficzne modele probabilistyczne (inaczej modele graficzne) to jedno z najpopularniejszych podejść do przedstawiania rozkładów prawdopodobieństwa w takich dziedzinach świata rzeczywistego. Powszechną wersją tego podejścia są sieci Bayesa, które kodują rozkłady prawdopodobieństwa za pomocą grafów skierowanych, jak na rysunku



Graf skierowany to zbiór węzłów (okręgów na tym diagramie) i łączących je strzałek. Każdy węzeł odpowiada zmiennej losowej i zawiera tablicę prawdopodobieństwa warunkowego (CPT) prawdopodobieństwa tej zmiennej losowej, przy danych wartościach jej rodziców (węzły skierowane strzałkami w stronę tej zmiennej). Reprezentacja sieci Bayesa rozkładu prawdopodobieństwa  $P(X_1, \dots, X_n)$  przedstawia go jako iloczyn prawdopodobieństw warunkowych. Zawiera skierowany graf bez skierowanych cykli, a prawdopodobieństwa warunkowe w iloczynie to  $P(X_i | \text{pai})$ , gdzie  $\text{pai}$  są rodzicami  $X_i$ . Wynikowa reprezentacja jest znacznie bardziej zwarta niż prosta, ponieważ liczba rodziców zmiennej jest zwykle mniejsza (np. dwóch lub trzech) niż całkowita liczba zmiennych  $n$ , co daje małe wartości  $y$  z warunkowym prawdopodobieństwem. Czasami sieci Bayesa są postrzegane jako kodujące związek przyczynowy między cechami domeny, na przykład gdy akcje Facebooka wpływają na stan innych spółek. Przyczynowość ma niewiele wspólnego z matematyczną reprezentacją sieci bayesowskich, ale intuicja przyczynowości wielokrotnie sprawdza się w odniesieniu do kierunków pokazanych w sieci bayesowskiej i jest przydatną heurystyką w budowaniu tych reprezentacji sieci. Istnieje kilka rodzajów zadań związanych z wnioskowaniem na podstawie informacji probabilistycznych. Typowe zadania to ocena prawdopodobieństwa krańcowego lub warunkowego, znalezienie najbardziej prawdopodobnego przypisania do zmiennych na podstawie obserwacji i wygenerowanie próbek z rozkładu. Dla wspólnego rozkładu  $P(X, Y)$  krańcowy  $P(X)$  definiuje się jako  $P(X) = \sum_Y P(X, Y)$ , gdzie  $X$  i  $Y$  są zbiorami zmiennych, a symbol sumowania z indeksem dolnym  $Y$  oznacza sumowanie po wszystkie wartości, jakie może przyjąć  $Y$ . Prawdopodobieństwo krańcowe jest zatem prawdopodobieństwem pierwotnym zastosowanym tylko w odniesieniu do podzbioru zmiennych. Na przykład  $P(\text{wysoki, gruby})$  to łączne prawdopodobieństwo, że ktoś jest zarówno wysoki, jak i gruby, podczas gdy  $P(\text{wysoki})$  to granica pierwszego, gdy interesuje nas tylko wysoki. Zazwyczaj interesuje nas znalezienie krańcowego prawdopodobieństwa, że  $X$  przyjmuje określoną wartość  $x$ . Wiąże się to z sumowaniem wszystkich wartości, jakie może przyjąć  $Y$ . Na przykład, jeśli chcemy znaleźć prawdopodobieństwo, że akcje Facebooka pójdą w górę, UpFacebook, i mamy łączny rozkład zmiennych losowych dla wszystkich akcji, musimy marginalizować (sumować) wszystkie zmienne, które

nie są UpFacebook . Konceptyjnie obliczanie marginesów jest proste z definicji. W praktyce marginalizacja nie jest prosta w przypadku dużych modeli, ponieważ sumowanie może zająć czas wykładniczy pod względem liczby sumowanych zmiennych. Z tego powodu wiele badań inwestuje się w efektywne obliczanie marginesów. Badania te mogą również służyć do łatwego obliczania innych zadań związanych z rozumowaniem, takich jak znajdowanie najbardziej prawdopodobnych diagnoz medycznych i lokalizowanie robotów. W przypadku sieci Bayesa jeden prosty sposób obliczania marginesów polega na ostrożnym sumowaniu zmiennych wzdłuż struktury wykresu. Najpierw podsumowuje zmienne, które mają bardzo niewielu rodziców lub dzieci, najlepiej nie mają rodziców lub dzieci. To podsumowanie tworzy nowy graf sieci bayesowskiej bez tego węzła, prawdopodobnie tworząc nowe połączenia między rodzicami i dziećmi usuniętego węzła. W ten sposób eliminujemy węzły z wykresu, aż pozostanie nam tylko interesująca nas zmienna losowa na wykresie. Podczas tego iteracyjnego procesu aktualizujemy reprezentację wykresu i CPT w sposób, który nie wymaga więcej niż lokalnych obliczeń na przetwarzanie liścia (liść jest węzłem bez dzieci). Jeśli struktura wykresu sieci Bayesa jest wystarczająco prosta, obliczenia te wymagają czasu liniowo proporcjonalnego do liczby wierzchołków wykresu (liczby zmiennych w rozkładzie), a także liniowo proporcjonalnego do wielkości CPT. Większość praktycznych zastosowań wymaga również modeli probabilistycznych skomplikowane dla precyzyjnych metod. W takich przypadkach ludzie zwracają się do atrakcyjnych przybliżonych metod rozumowania. Metody takie zapewniają wyniki związane z prawidłowym rozumowaniem, ale z ograniczonymi gwarancjami. Rodzaj przybliżenia stosowanego w rozumowaniu zależy od zadania i rodziny metod, które stosujemy. Wczesne badania miały na celu znalezienie metod, które zwracałyby wyniki wnioskowania niedokładne co najwyżej o stały czynnik. Niestety wyniki pokazały, że takie przybliżenie nie jest teoretycznie możliwe, jeśli fundamentalna kwestia w informatyce nie zostanie pozytywnie rozwiązana. Pytanie brzmi, czy znalezienie satysfakcjonującego przypisania w logice zdań można przeprowadzić w czasie wielomianowym w rozmiarze problemu wejściowego . To pytanie pozostaje otwarte od ponad czterdziestu lat i wielu uważa, że odpowiedź jest negatywna. Ponieważ w związku z tym uważa się, że nawet przybliżenie wnioskowania probabilistycznego jest trudne, przypięcztowało to pogoń za wykonalnymi sposobami przybliżenia rozumowania z gwarancją precyzji. Obecne przybliżone techniki wnioskowania probabilistycznego dzielą się na dwa główne paradygmaty. Pierwsze przybliżenie wariacyjne ma na celu przybliżenie modelu probabilistycznego za pomocą modelu łatwiejszego do obliczeń. Najpopularniejsza technika wykorzystuje formę przekazywania komunikatów, czyli przetwarzanie dowodów i obserwacji na wykresie oraz wysyłanie komunikatów pomiędzy węzłami na wykresie. Takie komunikaty pomagają aktualizować lokalne szacunki krańców w każdym wierzchołku, a konsekwencje są wykorzystywane do dostarczania przybliżonych rozwiązań dla tych krańców. Komunikaty mogą przechodzić na wykresie bez określonej kolejności, chociaż czasami niektóre porządki gwarantują szybszą zbieżność. Drugi paradygmat wnioskowania przybliżonego, techniki Monte Carlo, koncentruje się na zapewnieniu zestawu odpowiedzi na zapytanie, które można wykorzystać do przybliżenia pierwotnego zapytania. Wiąże się to z pobieraniem próbek. Próbuje wygenerować próbki z zadanego rozkładu prawdopodobieństwa i wykorzystać je do odpowiedzi na nasze pytania. Na przykład w przypadku naszej historii na Facebooku próbkowanie wygenerowałoby m przykładów (m zależy od czasu, jaki mamy na obliczenia), z których każdy przypisuje wartości wszystkim zmiennym w modelu – to znaczy każdy przykład określa, czy każda z n akcji w naszej historii idzie w górę. Liczymy, ile z tych m próbek pozytywnie odpowiedziało na nasze zapytanie i na tej podstawie zwracamy przybliżoną odpowiedź.

Uczenie maszynowe to poddziedzina sztucznej inteligencji, która zajmuje się skomputeryzowanym automatycznym uczeniem się na podstawie danych wzorców. Celem uczenia maszynowego jest wykorzystanie niektórych danych szkoleniowych do wykrycia wzorców, a następnie wykorzystanie tych wyuczonych wzorców do automatycznego odpowiadania na pytania oraz autonomicznego

podejmowania i wykonywania decyzji. Przykładami uczenia maszynowego są modele wyuczone przez komputery w celu przewidywania preferencji użytkowników dotyczących książek, programów telewizyjnych i decyzji zakupowych w sklepach spożywczych. Tam danymi szkoleniowymi są książki, które ludzie wybrali w przeszłości oraz charakterystyka tych książek i ludzie, którzy je wybrali. Modele wyciągnięte z tych danych szkoleniowych są następnie wykorzystywane do przewidywania, jakie inne książki te osoby prawdopodobnie kupią. Modele probabilistyczne są zbliżone do statystycznego uczenia maszynowego i służą jako medium pomiędzy uczeniem maszynowym a automatycznym rozumowaniem. Uczenie maszynowe modeli probabilistycznych dzieli się na dwa główne zadania: uczenie się CPT, gdy podany jest wykres, oraz uczenie samego wykresu. Biorąc pod uwagę przykłady szkoleniowe, uczenie maszynowe CPT jest stosunkowo łatwe i sprowadza się do zliczenia, ile razy zmienna losowa otrzymała określoną wartość, spośród czasów, gdy rodzice otrzymali odpowiednie wartości. Metodę tę nazywamy estymacją parametrów metodą największej wiarygodności. Nauka struktury wykresu modelu jest trudniejsza i polega na ulepszaniu modelu krok po kroku. Typowe metody wykorzystują algorytm zwany maksymalizacją oczekiwań (EM), który mierzy prawdopodobieństwo, że hipotetyczny model wyjaśnia dane (tj. że model ten jest w rzeczywistości poprawny i że wygenerował dane uczące). EM proponuje alternatywne zmiany w modelu i wybiera tę, która najlepiej poprawia wyjaśnienie danych uczących. Obecne badania nad probabilistyczną reprezentacją, uczeniem się i rozumowaniem skupiają się na zagadnieniach obejmujących dużą liczbę zmiennych (tutaj „duża” jest większa niż, powiedzmy, 100 zmiennych). Łączne rozkłady ponad 100 zmiennych mogą być bardzo różne, gdy w rzeczywistości (z ludzkiego punktu widzenia) wydają się prawie identyczne (np. rozkład cech ulic jednego kwartału może bardzo różnić się od rozkładu ulic innego, ale mogą wyglądać to samo dla niewprawnego oka). Ludzie przyjmują założenia, takie jak niezależność zmiennych losowych, które nie sprawdzają się w rzeczywistości, co prowadzi do błędnego postrzegania podobieństwa sytuacji.

### **Zautomatyzowane podejmowanie decyzji**

Podejmowanie decyzji polega na podejmowaniu decyzji, która następnie jest wykonywana w świecie przez autonomicznego agenta lub przez osobę korzystającą z rady decydenta. Na przykład agenci grający w gry, roboty autonomiczne, agenci WWW i agenci konwersacji podejmują decyzje dotyczące tego, co robić. Często decyzje te uwzględniają dynamikę świata, na przykład wtedy, gdy komputerowy szachista wybiera akcję w oparciu o przyszłe możliwe działania swojego przeciwnika. Czasem decyzje podejmowane są bez jasnej ścieżki na przyszłość, np. gdy decydujemy się na wynajęcie mieszkania w określonej cenie i lokalizacji. Podejmowanie decyzji jako obszar badań obejmuje dziedziny ekonomii, psychologii, informatyki i praktycznie wszystkich dyscyplin inżynierskich. W szczególności w informatyce i sztucznej inteligencji badania nad podejmowaniem decyzji skupiają się na zautomatyzowanych sposobach i właściwościach obliczeniowych podejmowania decyzji. Jest oczywiste, że badania nad podejmowaniem decyzji przez ludzi wpływają na sposób, w jaki podejmowanie decyzji jest zautomatyzowane, ale ten aspekt wykracza poza zakres sztucznej inteligencji i tego badania. Automatyczne podejmowanie decyzji można podzielić na kilka osi, które można sformułować w formie pytań: (1) Czy jest to dziedzina o charakterze dynamicznym, w której wymagana jest sekwencja decyzji, czy też o charakterze bardziej statycznym, w którym podejmowana jest pojedyncza decyzja lub zestaw równoczesnych decyzji? Jeśli to pierwsze, czy staramy się optymalizować decyzje dla ograniczonego (małego) zestawu kroków czasowych, czy też podejmujemy (prawie) optymalne decyzje, które uwzględniają (w zasadzie) nieskończoną przyszłą sekwencję wydarzeń? (2) Czy dziedzina ma charakter deterministyczny, niedeterministyczny czy stochastyczny? Na przykład, czy nasze działania wpływają na świat w sposób deterministyczny (zawsze taki sam, jeśli są wykonywane w tych samych warunkach) czy stochastyczny (np. w połowie przypadków nasze działania kończą się niepowodzeniem)? (3) Czy próbujemy zoptymalizować narzędzie, czy tylko




staramy się osiągnąć cel? (4) Czy domena jest przez cały czas w pełni obserwowana (np. cały czas widzimy cały stan szachownicy) czy obserwowana częściowo (np. nie widzimy, czy w pomieszczeniu pali się światło, chyba że w nim jesteśmy) pokój)? W pozostałej części tej sekcji omówiono podejścia do autonomicznego podejmowania decyzji opracowane w ciągu ostatnich pięćdziesięciu lat. Techniki te zostały opracowane z myślą o praktyczności, są więc efektem uproszczeń założeń i decyzji projektowych, których poprawność jest wątpliwa. Założenia te obejmują: wybrane reprezentacje działań deterministycznych (działania mają warunki wstępne i skutki określone wzorami logicznymi); istnienie działań prawdziwie deterministycznych w praktyce; poprawna i pełna znajomość modelu świata przez działającego agenta; oraz istnienie wyraźnej nagrody lub funkcji użyteczności, która charakteryzuje nasze wybory. Mimo to siłą napędową tych problematycznych sformułowań i technik jest często zestaw docelowych zastosowań, zatem skuteczność tych założeń jest testowana i potwierdzana w udanych zastosowaniach. Pierwsze trzy osie powyżej zostały omówione w tej sekcji, ale czwarta została pozostawiona do głębszego rozważenia w sekcji kolejnej. Dyskusja dzieli się na podejmowanie decyzji w dziedzinach logicznych, typowo deterministycznych i podejmowanie decyzji w dziedzinach o charakterze stochastycznym. Te pierwsze są prostsze, więc można do nich skutecznie podejść pomimo czasami złożonych struktur kombinatorycznych i zazwyczaj można je rozwiązać dla większych dziedzin. Te ostatnie są bardziej złożone w procesie decyzyjnym, więc wymagają wielu założeń, ale są też bardziej skuteczne i lepiej modelują problemy, jeśli mają zastosowanie w praktyce.

### **Decyzje w przestrzeniach logicznych, kombinatorycznych**

Logiczne problemy decyzyjne to takie, które mają charakter niestochastyczny. W tej sekcji rozważono dwa główne ustawienia takich problemów decyzyjnych: planowanie (jeden aktor lub współpraca) i kontradyktoryjne (głównie gry dla dwóch graczy). W obu przypadkach dyskusja zakłada, że mamy pełną informację o początkowych i pośrednich stanach świata, że działania mają jedynie deterministyczne, znane skutki oraz że istnieje określony warunek celu (np. konkretnego pokoju). Obydwa typy problemów mają aktualne zastosowania w świecie rzeczywistym, np. w misjach kosmicznych NASA, sterowaniu robotami, logistyce, oprogramowaniu gier i świata wirtualnego, złożonych zachowaniach w Internecie, weryfikacji oprogramowania oraz bezpieczeństwie komputerów i sieci. Ogólnie rzecz biorąc, problem planowania składa się z sytuacji początkowej, warunku docelowego i zestawu dozwolonych działań lub przejść między stanami. Wynikiem procesu planowania jest sekwencja lub zbiór działań, których prawidłowe wykonanie prowadzi wykonawcę od stanu początkowego do stanu spełniającego warunek celu. Rozważmy scenariusz, w którym trzy bloki oznaczone A, B, C leżą na stole, a chwytak robota musi je podnieść w odpowiedniej kolejności i odłożyć tak, aby A znajdowało się na B, a B na C. Prosta reprezentacja w tym scenariuszu nazywa się STRIPS i składa się z listy warunków wstępnych Pre, listy usuwania Del i listy dodawania Add dla każdej akcji robota. Reprezentuje stan ze zbiorem faktów, które są prawdziwe, oraz możliwymi działaniami z takimi listami Pre, Add, Del. PASKI mogą reprezentować scenariusz świata bloków z akcjami  $pickUp(x, y)$  i  $putDown(x, y)$ , gdzie  $x, y$  to bloki A, B, C lub Tabela. Na przykład  $pickUp(x, y)$  może mieć  $Pre = on(x, y) \wedge handEmpty$ ,  $Add = inHand(x)$  i  $Del = on(x, y), handEmpty$ . Zamiarem tych operatorów i list jest scharakteryzowanie przesłanek i skutków tych działań. Efekt zmienia stan obecny poprzez jego dodanie i usunięcie. Gdy stan świata to  $\{on(A, Table), on(B, Table), on(C, Table), handEmpty\}$ , robot podnosi A ze stołu, a następnie A nie ma już na stole, ręka robota nie jest już pusta i robot trzyma teraz blok A. Dlatego algorytm planowania aktualizuje stan za pomocą tej akcji, stosując polecenie usuwania  $on(A, Tabela)$ , usuwania  $handEmpty$  i dodawania  $inHand(A)$  do opisu stanu. Stany i akcje określają wspólnie przestrzeń poszukiwań, w której należy znaleźć plan. Plan w tej przestrzeni to ciąg działań prowadzący od stanu początkowego (w pełni określonego) do stanu spełniającego warunek celu. Planista (proces podejmujący decyzję) otrzymuje taką reprezentację problemu planistycznego i ma za zadanie znaleźć plan. W tym celu wykorzystuje różne metody wyszukiwania, które mogą różnić się w zależności od domeny i mogą

obejmować heurystyki ogólnego przeznaczenia, strategie przewidywania przyszłości i wiedzę domenową. Planowanie jest trudne obliczeniowo nawet w przypadku prostych języków specyfikacji problemów, takich jak ten powyżej. Poszukiwanie planu nie może w praktyce reprezentować ani przemierzać całego grafu przestrzeni stanów, ponieważ jest on wykładniczo duży pod względem liczby cech stanu definiujących dziedzinę (np. Odpowiadających liczbie bloków w naszym przykładzie powyżej). Dlatego techniki wyszukiwania muszą tworzyć częściowe ścieżki w nadziei na osiągnięcie celu. Poszukiwania takich planów cofają się, gdy planista uzna, że nie ma sensu dalej rozszerzać planu i że należy zmienić wcześniejsze etapy planu, aby umożliwić osiągnięcie celu. Badania nad planowaniem skupiają się na opracowaniu nowych metod wyszukiwania, nowych reprezentacji działań i stanów, które ułatwiają planowanie, a także bardziej wyrazistych języków i metod specyfikacji problemów planowania. Na przykład wiele algorytmów planowania wykorzystuje założenia niezależności lub luźne interakcje pomiędzy komponentami w domenie planowania, aby efektywniej znajdować plany. Planisci hierarchiczni dzielą cel na cele cząstkowe (operatorzy wysokiego szczebla), stosując rozkład domeny na luźno powiązane ze sobą części. Planowanie odbywa się tam na każdym poziomie oddzielnie, a później plany cząstkowe są łączone w całość w celu zbudowania prawidłowego planu. Podejmowanie decyzji, gdy istnieją siły, które próbują negatywnie wpłynąć na nasz wynik, jest tematem teorii gier. Tutaj zadaniem decydenta jest maksymalizacja zysku lub szans na sukces przy jednoczesnej minimalizacji kontrydiktoryjnego efektu decyzji innych. Sytuacja ta jest typowa dla gier planszowych dla dwóch graczy (np. szachy, go itp.) i ma również znaczenie dla minimalizacji usterek w projektach (np. oprogramowania i sprzętu) oraz dla bezpieczeństwa (np. komputerów i sieci). Minimax to prosty model podejmowania takich decyzji w sytuacjach gry dwuosobowej. Osoba podejmująca decyzję wykorzystuje informacje heurystyczne o wartości stanów (w odniesieniu do ich przyszłych wyników), aby oszacować wartość decyzji w obecnym stanie. Na przykład w szachach przesuwamy figurę, drugi gracz przesuwa swoją figurę i dochodzimy do nowego stanu gry, który wymaga podjęcia innej decyzji. Każda nasza decyzja prowadzi do jednego z kilku stanów, podobnie jak decyzja przeciwnika. Możemy nakreślić wszystkie możliwe przyszłe stany kolejnych kroków, patrząc na te stany, do których można dotrzeć z naszego obecnego stanu poprzez serię możliwych wyborów dokonanych przez nas i naszego przeciwnika. Wygodnie jest umieścić te osiągalne stany w drzewie, przy czym obecny stan jest korzeniem tego drzewa (najwyższy węzeł w drzewie), a liście drzewa są najniższymi węzłami w drzewie. (Mówiąc bardziej ogólnie, gałęzie drzewa mogą się łączyć, ale ignorujemy to, aby uprościć dyskusję.) W minimaksie obliczamy wartości wyższych węzłów zgodnie z tym drzewem w sposób min-max. Poziom drzewa to min (minimalizacja), jeśli przeciwnik podejmuje decyzję w tych stanach, ponieważ jego celem jest doprowadzenie do stanów, które minimalizują nasz wynik. Poziom drzewa jest maksymalny (maksymalny), jeśli to my podejmujemy decyzję w tych stanach, ponieważ naszym celem jest doprowadzenie do stanów, które maksymalizują nasz wynik. Pokazano to na rysunku



Na tym rysunku liczby na dole drzewa oznaczają wartości, które gracze oszacowaliby jako znajdujące się w tym stanie (na przykład za pomocą funkcji heurystycznej), a każdy gracz wybiera działania, które minimalizują lub maksymalizują wartości otrzymane z dołu. Metody, które można udowodnić, usuwają gałęzie z drzewa minimax, jeśli nie ma szans, że przyczynią się do rozwiązania (tj. do preferencji wyższych gałęzi). Nowsze badania próbują oszacować wartość stanu poprzez próbkowanie poddrzew tego drzewa min-max. Wyzwaniem dla kontryktoryjnego podejmowania decyzji jest zrównoważenie uczenia się i decyzji. Kiedy przeciwnik próbuje udaremnić nasze próby, uczenie się danej dziedziny podczas podejmowania decyzji (np. poprzez uczenie się przez wzmacnianie) jest trudne, ponieważ eksploracja w celu uczenia się może doprowadzić nas do bardzo złego wyniku. Musimy zrównoważyć prawdopodobieństwo zdobycia cennych informacji podczas eksploracji z ryzykiem, że zostaniemy odrzuceni przez naszych przeciwników. Jednakże unikanie poszukiwań z pewnością przyniesie nieoptymalne wyniki, które mogą być bardzo odległe od pożądanych lub akceptowalnych

### **Domeny stochastyczne**

Dynamika wielu domen świata rzeczywistego ewoluuje stochastycznie, to znaczy z pewnymi nietrywialnymi właściwościami statystycznymi. Możemy na przykład rozważyć zakup samochodu, który ma nieznaną nam właściwość, a które wpływają na jego wartość. Zależności te wpływają na naszą decyzję i musimy ocenić naszą użyteczność, biorąc pod uwagę całe ryzyko i niepewność. Dziedziny stochastyczne są w praktyce trudniejsze do podejmowania decyzji, ale także bardziej tolerują przybliżenia niż domeny deterministyczne. Uprozczone założenia przyjęte w praktyce sprawiają, że automatyczne podejmowanie decyzji staje się praktyczne. Istnieje kilka sformułowań problemów, które obejmują różne aspekty i przypadki podejmowania decyzji w dziedzinach stochastycznych. Najbardziej znane to sieci decyzyjne i procesy decyzyjne Markowa (MDP). Sieci decyzyjne są podobne do sieci bayesowskich tylko z trzema typami węzłów: (1) zmiennymi losowymi (jak w sieciach bayesowskich), (2) węzłami decyzyjnymi i (3) węzłami użyteczności publicznej. Węzły decyzyjne wymagają przypisania decyzji co do ich wartości i nie mają rządzącego nimi rozkładu prawdopodobieństwa (jednak wartości dla innych węzłów mogą zależeć stochastycznie od wartości przypisanej do węzłów decyzyjnych). Węzły użyteczności oznaczają te wielkości, które chcemy maksymalizować (w oczekiwaniu). MDP to najpopularniejszy formalizm służący do modelowania zadań decyzyjnych w dynamicznych środowiskach stochastycznych. Ich celem jest modelowanie sytuacji, w

których działania mają skutki stochastyczne, a celem nie jest konkretny cel, ale raczej maksymalizacja użyteczności w czasie. Rozwiązania MDP to zasady wybierające działanie dla każdego stanu w taki sposób, aby zminimalizować całkowity koszt oczekiwanych działań i zmaksymalizować całkowitą sumę lub pozytywne nagrody.

## **Zagadnienia przekrojowe**

### **Zdrowe rozumowanie**

Terminy „zdroworozsądkowe rozumowanie” i „zdroworozsądkowa wiedza” odnoszą się do szerokiego zestawu zdolności, które ludzie wnoszą do podejmowania decyzji i myślenia. Jednym z przykładów jest zdolność rozumowania na temat bardzo dużej liczby przedmiotów, właściwości, ludzi i relacji w naszym codziennym życiu. Możemy stwierdzić, że kubek jest w stanie utrzymać swoją zawartość, ale tylko wtedy, gdy jest skierowany do góry lub gdy zawartość jest dobrze połączona z kubkiem. Możemy wykorzystać ten fakt przy podejmowaniu decyzji o sposobie transportu kubka z miejsca na miejsce. Badania nad zdrowym rozsądkiem starają się wyposażyć aplikacje i komputery w zdolność uogólniania, uczenia się i wykorzystywania bardzo szerokiego zestawu wiedzy o życiu codziennym. Obecnie praktyczne zastosowania omijają wiele kwestii związanych ze zdroworozsądkowym rozumowaniem. Robią to poprzez staranne opracowywanie potrzebnych informacji i modeli, ograniczanie zestawu tematów i zmiennych podczas uczenia się oraz opracowywanie tylko tych zastosowań, które nie wymagają tak zdrowego rozsądku. Badania nad zdrowym rozsądkiem dzielą się na trzy główne nurty: teoria logiczna, duże bazy wiedzy zdroworozsądkowej i techniki zdrowego rozsądku ad hoc. Formalizacja logiczna i teoria rozumowania zdroworozsądkowego próbuje wykorzystywać i modyfikować logikę do reprezentowania i rozumowania na podstawie wiedzy zdroworozsądkowej w sposób zgodny z naszą intuicją dotyczącą takiego rozumowania. Na przykład większość ludzkiego rozumowania na temat świata wykorzystuje pojęcie wartości domyślnych – założeń, które są przydatne, ale mogą nie być prawdziwe. Mówimy, że ptaki latają (niektóre z nich nie); zakładamy, że nasz komputer działa poprawnie (może tak nie być); i stosujemy się do zaleceń lekarzy (mogą być błędne). Logika nie pozwala łatwo uchwycić takich niepewności i niedociągnięć. Rozumowanie niemonotoniczne próbuje i jest pomocne w uogólnianiu ich w formę użytecznego rozumowania zdroworozsądkowego. Taka logika wychwytyje jedną właściwość potrzebną do zdroworozsądkowego rozumowania, a mianowicie zdolność do reprezentowania wartości domyślnych i uzasadniania ich. Wciąż jednak wiele pozostaje otwartych: w jaki sposób możemy zdobyć wiedzę, jak skalować techniki reprezentacji i rozumowania do dużego zestawu wiedzy, która wydaje się potrzebna, i jak wykorzystać tę wiedzę w zastosowaniach, które jej potrzebują? Wysiłki mające na celu budowanie dużych baz wiedzy i wykorzystywanie informacji na nowe sposoby mają na celu przezwycięzenie ograniczeń zdroworozsądkowego rozumowania opartego na logice. Na przykład Cyc, najbardziej znana obecnie duża, zdroworozsądkowa baza wiedzy, jest wynikiem ponad dwudziestu pięciu lat rozwoju i utrzymywania przez ekspertów. Zawiera ponad 1 000 000 faktów i logicznych zdań na temat ponad 100 000 obiektów, relacji, typów i funkcji. Jego semantyka nie jest tak prosta i przejrzysta, jak sugeruje się w literaturze dotyczącej formuł logicznych, ale w rezultacie wydaje się bardziej użyteczna (początkowe zastosowania istnieją w przetwarzaniu języka naturalnego i podejmowaniu decyzji). Inne wysiłki próbują automatycznie tworzyć wiedzę na podstawie autorów i mas informacji dostępnych w Internecie. Celem jest łatwiejsze tworzenie systemów szerokiej wiedzy, ale z możliwie luźniejszą semantyką. Podejścia te pozwalają uniknąć rozważania pytań o znaczenie posiadanej wiedzy i wydają się obiecujące w zastosowaniach wymagających szerokiej wiedzy (np. autonomiczne roboty rzeczywiste i wirtualne).

### **Łączenie logiki i prawdopodobieństwa**

Wiele aplikacji zawiera zarówno elementy stochastyczne, jak i niestochastyczne. Na przykład sterowanie robotem może obejmować specyfikacje wysokiego poziomu w logice i probabilistyczny model wykrywania niższego poziomu. Ponadto przetwarzanie języka naturalnego ma na celu zastosowanie wiedzy wysokiego poziomu w logice z probabilistycznymi modelami tekstu i sygnałów mówionych niższego poziomu. Wreszcie, wiele baz danych opiera się na logice (np. wpis  $\langle \text{Eyal, Shavit} \rangle$  w bazie danych ojciecOf wskazuje na logiczną instrukcję ojciecOf(Eyal, Shavit)), podczas gdy relacje między tymi bazami danych a najnowszymi rozszerzeniami baz danych są probabilistyczne (np. wpis  $\langle \text{John, Mary} \rangle$  jest niepewnym wpisem w bazie danych love z prawdopodobieństwem 0,7 albo dlatego, że John nie jest pewien, albo dlatego, że posiadacze bazy danych nie są pewni). Od 1990 r. społeczność AI i społeczność baz danych włożyła wiele pracy w połączenie ekspresji logicznej i probabilistycznej. W pracy tej zaprezentowano języki umożliwiające wyrażenie rozkładów prawdopodobieństwa wraz z wyraźnymi odniesieniami do obiektów, funkcji i relacji, jak w logice pierwszego rzędu (np. Pfeiffer i in. 1999). Języki te stanowią przydatne struktury dla wielu zastosowań uczenia maszynowego, a ostatnie prace pokazują również, że są one przydatne pod względem wydajności obliczeniowej wnioskowania (Poole 2003; de Salvo Braz, Amir i Roth 2006). Trwają badania nad połączeniem logiki i prawdopodobieństwa. Aktualne wyzwania obejmują (1) zastosowanie struktury relacyjnej do przyspieszania wnioskowania i traktowania modeli probabilistycznych na wielu obiektach, (2) łączenie baz wiedzy, które są już podane w formie probabilistycznej lub logicznej oraz (3) rozszerzenie języków reprezentacji o funkcje i równość obiektów w zdrowy i prosty sposób.

### **Częściowa obserwowalność**

Agenci działający w wielu domenach świata rzeczywistego nie znają dokładnego stanu świata w żadnym momencie. Domeny te są częściowo obserwowalne, ponieważ agenci nie mogą obserwować wszystkich cech świata, które mogą być dla nich istotne. Na przykład agent przeglądający WWW może nacisnąć przycisk na stronie, ale może nie zobaczyć natychmiastowego efektu swojego działania (ale mógłby to zobaczyć, gdyby przeglądał inną stronę). Problemy związane z częściową obserwowalnością są szczególnie trudne i zazwyczaj ograniczają się do bardzo małych dziedzin (np. 100 stanów lub 8 cech dziedzinowych). Dzieje się tak, ponieważ każdy wybór działania zależy od stanu wiedzy podmiotu i odebranych przez niego spostrzeżeń, co prowadzi do superwykładniczego obliczenia liczby kroków i cech w domenie. Działanie w obszarach częściowo obserwowalnych, częściowo znanych jest szczególnie trudne, a mimo to najbliższe realnemu życiu. Główne podejścia obejmują co najmniej wyczerpującą eksplorację danej dziedziny (np. uczenie się przez wzmacnianie, dzięki któremu uczymy się zachowań w danej domenie na podstawie nagród otrzymywanych w czasie i różnych stanach lub doradzanie w sprawie obiecujących trajektorii). Podejścia gwarantujące zbieżność rozwiązania robią to tylko w granicach nieskończonej liczby kroków. Co najważniejsze, jeśli zmieni się cel systemu, proces należy rozpocząć od nowa, a wiedza zgromadzona w poprzednich uruchomieniach jest w niewielkim stopniu wykorzystywana. Najnowsze podejścia identyfikują ważne, wykonalne przypadki o szczególnym znaczeniu – na przykład dziedziny, w których wiadomo, że działania są deterministyczne i nie powodują skutków warunkowych (np. działania STRIPS (sekcja 9.3.1)). Algorytmy takie przeplatają planowanie i wykonanie oraz zapewniają pewne gwarancje osiągnięcia celu w liczbie kroków bliskich optymalnej.

### **Aplikacje to nie programowanie**

Dominujący pogląd w badaniach naukowych sugeruje, że zastosowania w świecie rzeczywistym są prostą implementacją teorii i badań podstawowych. W szczególności sztuczna inteligencja i podejmowanie decyzji zaprzeczają temu pogładowi. Przetwarzanie języka naturalnego, widzenie maszynowe i wykrywanie oszustw to tylko niektóre z zastosowań, które w abstrakcji można postrzegać

jako zastosowania badań podstawowych. Mimo to tematy te wymagały i otrzymały (i nadal otrzymują) wnikliwą, specjalistyczną uwagę, zanim mogły zostać wprowadzone w praktyce. Mówiąc bardziej ogólnie, teoretycznie należy być w stanie reprezentować wszystko, co jest potrzebne do inteligentnego zachowania w FOL. Dzieje się tak, ponieważ FOL ma równoważną moc reprezentacyjną maszynom Turinga<sup>2</sup> (dominujący abstrakcyjny model obliczeniowy). Chociaż sztuczna inteligencja na poziomie ludzkim w FOL jest teoretycznie możliwa (ponieważ jeśli dowolny komputer może to zrobić, to FOL może), w praktyce niewiele można zyskać, unikając problemu, jak faktycznie przedstawić wiedzę lub rozum w FOL lub innym języku. Jeśli chcemy osiągnąć praktyczne, inteligentne zastosowania na poziomie człowieka, nie da się uniknąć problemów związanych z faktycznym budowaniem potrzebnej wiedzy i jej wykorzystaniem w praktyce. Diabeł tkwi w szczegółach i bez zwracania uwagi na te szczegóły badania nie przyniosą większego postępu, co widać w licznych gałęziach sztucznej inteligencji, które rozwinęły się z biegiem czasu (weryfikacja formalna i bazy danych to dwie dziedziny, które wyrosły z sztucznej inteligencji).

### **Wnioski**

Od połowy lat 90. XX w. w dziedzinie KR&R nastąpiło zasadnicze przesunięcie punktu ciężkości z narzędzi matematyczno-logicznych na narzędzia teorii prawdopodobieństwa oraz z teorii na zastosowania. Zmiana ta była ostra i doprowadziła do podziału badań na prace oparte na logice i prawdopodobieństwie. Logika jest wygodniejsza do reprezentowania wiedzy zdaniowej (zwłaszcza wiedzy relacyjnej, obiektowej) i dobrze nadaje się do problemów i struktur kombinatorycznych (nie wypukłych), takich jak poszukiwanie w labiryncie czy rozwiązywanie zagadek, natomiast podejścia oparte na prawdopodobieństwie (w szczególności , graficzne modele probabilistyczne) lepiej reprezentują wiedzę niepewną, lepiej nadają się do uczenia się w obecności szumu i mają wiele zastosowań w świecie rzeczywistym (zgodnie z praktyczną zasadą 80–20 – wykonaj 20% pracy na rzecz łatwiejszych 80% zadań Praca). Rozumowanie i podejmowanie decyzji za pomocą każdej z reprezentacji jest łatwiejsze lub trudniejsze w różnych sytuacjach, a zazwyczaj ich mocne strony wydają się uzupełniać (np. rozwiązywanie problemów ze spełnialnością logiczną jest często szybkie, podczas gdy rozumowanie probabilistyczne jest łatwe do przybliżenia). Wielu badaczy zgadza się, że oba narzędzia (logika i prawdopodobieństwo) są niezbędne do skalowania systemów do zastosowań w świecie rzeczywistym, ale sposób połączenia ich mocnych stron pozostaje niejasny. Co więcej, badania nad uczeniem maszynowym i rozumowaniem osiągnęły punkt, w którym mają one wiele praktycznych zastosowań. Obecne badania to coś więcej zorientowane na aplikacje, a tendencja ta polega na odnotowaniu lepszego skupienia i sukcesów w świecie rzeczywistym. Pojawienie się WWW i odnoszących sukcesy wyszukiwarek zapewniło inny rodzaj władzy decyzyjnej, w której władza kolektywu pomaga ominąć trudne problemy teoretyczne. Zmiany te kształtują odmienne środowisko badawcze i kierunki rozumowania i podejmowania decyzji. Te nowe kierunki będą oddziaływać na rozwój teorii gier, neurobiologii i innych dziedzin nauki, które nie zostały tu poruszone.