

Sztuczna inteligencja : Rozumowanie w niepewnych sytuacjach

(IX / XVI)

ĆWICZENIA

1. Zidentyfikuj trzy dziedziny zastosowań, w których konieczne jest rozumowanie w warunkach niepewności. Wybierz jeden z tych obszarów i zaprojektuj sześć reguł wnioskowania odzwierciedlających rozumowanie w tej dziedzinie.

2. Biorąc pod uwagę następujące zasady w aplikacji systemu eksperckiego typu „back-chain”:

$$A \wedge \text{nie}(B) \Rightarrow C (.9)$$

$$C \vee D \Rightarrow E (0,75)$$

$$F \Rightarrow A (.6)$$

$$G \Rightarrow D (.8)$$

System może podsumować następujące fakty (z zwierzeniami):

$$F (0,9)$$

$$B (-.8)$$

$$G (.7)$$

Użyj algebry współczynników pewności Stanforda, aby określić E i jej pewność.

3. Rozważmy prostą regułę podobną do MYCIN: jeśli $A \wedge (B \vee C) \Rightarrow D (.9) \wedge E (.75)$. Omów kwestie, które pojawiają się przy uchwyceniu tych niepewności w kontekście bayesowskim. Jak można potraktować tę regułę w rozumowaniu Dempstera-Shafera?

4. Utwórz nowy przykład rozumowania diagnostycznego i użyj rozszerzenia Równania Dempstera – Shafera z sekcji 9.2.3 w celu uzyskania rozkładów przekonania, jak w tabeli 1 i 2.

5. Skorzystaj z aksjomatów schematu przedstawionych przez McCarthy'ego, aby utworzyć wyniki opisowe przedstawione w sekcji 9.1.3.

6. Utwórz kolejną sieć rozumowania podobną do tej z rysunku 4 i pokaż siatkę zależności dla jej obiektów, tak jak pokazano na rysunku 5.

7. Rozumowanie przy założeniu minimalnego modelu jest ważne w życiu codziennym człowieka. Opracuj jeszcze dwa przykłady, które zakładają minimalne modele.

8. Kontynuuj przykład odwróconego wahadła z sekcji 9.2.2 z dwoma kolejnymi iteracjami kontrolera, gdzie wyjście jednej iteracji dostarcza wartości wejściowe dla następnej iteracji.

9. Napisz program, który implementuje kontroler rozmyty z punktu 9.2.2.

10. Przejdź do literatury, na przykład Rossa, i opisz dwa inne obszary, w których kontrola rozmyta może być odpowiednia. Skonstruuj zestaw rozmytych reguł dla tych domen.

11. Tom zainwestował część swoich oszczędności w portfel pięciu akcji, $H = \{\text{Bank of China, Citibank, Intel, Nokia, Legend}\}$. Akcje te można podzielić na akcje banków (Bank of China i Citibank), akcje Hi-tech (Intel, Nokia i Legend) oraz akcje Chin (Bank of China i Legend). Zaproponowałeś zbudowanie systemu eksperckiego, który może udzielić mu porady, jak powinien zarządzać swoim portfelem akcji. W tym celu przeprowadziłeś wywiady z wieloma konsultantami finansowymi i opracowałeś zestaw reguł dla systemu ekspertowego. Te zasady mówią Tomowi, jak powinien podzielić swoje pieniądze między różne akcje w swoim portfelu. Zalecane proporcje są wprost proporcjonalne do prawdopodobieństwa wzrostu ceny akcji lub ich rodzaju:

R1: JEŚLI stopa procentowa wzrośnie, WTEDY kup akcje banków, akcje Hi-tech i Nokię w proporcjach odpowiednio 0,8, 0,15 i 0,05.

R2: JEŚLI stopa zatrudnienia wzrośnie, WTEDY kup akcje Bank of China, Intel i Hi-Tech w proporcjach odpowiednio 0,5, 0,2 i 0,3.

R3: JEŚLI stopa inflacji spada, WTEDY kup akcje Intela, Citibanku i Hi-Tech w proporcji odpowiednio 0,1, 0,4 i 0,5

David zauważył, że stopa procentowa właśnie wzrosła, korzystając z teorii dowodów Dempstera-Shafera, obliczyć przedziały wierzeń dla trzech typów akcji, tj. Akcji Banku, akcji Chin i akcji Hi-Tech oraz dla Nokii. Czy jest jakaś różnica w wierzeniach i przedziałach wierzeń między akcjami Nokii i Hi-Tech? Dlaczego lub dlaczego nie? (Ten problem został zaproponowany przez Jamesa Liu Nga Kwoka z Uniwersytetu Politechnicznego w Hongkongu, rozwiązanie w Przewodniku instruktora jest autorstwa studenta Qi Xianming).


12. Umieść kolejne łącze na rysunku 16, powiedzmy, że sezon łączący jest bezpośrednio połączony z gładkim chodnikiem, a następnie utwórz drzewo klikowe, które będzie reprezentowało tę sytuację. Porównaj kwestie złożoności z problemami z drzewa klikowego na rysunku 17.

13. Uzupełnij symboliczne oceny wymagane do zakończenia tabeli 4.

14. Utwórz algorytm propagacji przekonań bayesowskich i zastosuj go do domeny śliskiego chodnika w sekcji 9.3.2. Możesz użyć metody przekazywania komunikatów Pearl'a (1988) lub metody triangulacji klikowej zaproponowanej przez Lauritzena i Spiegelhaltera (1988).

15. Utwórz diagram przekonań bayesowskich dla innej aplikacji, na przykład diagnozy medycznej, odkrycia geologicznego lub analizy usterek samochodowych. Wskaż przykłady separacji d i utwórz drzewo klikowe dla tej sieci.

16. Utwórz kliknięcia i drzewo węzłów dla następującej sytuacji



Napad, wandalizm i trzęsienie ziemi mogą wywołać alarm w domu. Istnieje również miara potencjalnych złości w sąsiedztwie domu.

17. Weźmy pod uwagę sytuację rozumowania diagnostycznego przedstawioną w tabeli 1 i 2 modelu Dempstera-Shafera z sekcji 9.2.3 i przekształć ją w sieć przekonań bayesowskich. Porównaj i porównaj te dwa podejścia do diagnozy.

18. Zakładając, że chciałeś zaprojektować model Markowa drugiego rzędu, tj. W którym każdy obserwowalny stan byłby zależny od dwóch poprzednich obserwowalnych stanów. Jak byś to zrobił? Jak wyglądałaby macierz prawdopodobieństwa przejścia?

19. Biorąc pod uwagę możliwy do zaobserwowania model pogody Markowa z sekcji 9.3.4:

a. Określ prawdopodobieństwo, że (dokładnie) następane pięć dni będzie słońce.

b. Jakie jest prawdopodobieństwo dokładnie trzech dni słońca, potem jednego dnia opadów, a potem dokładnie jednego dnia słonecznego?

ROZUMOWANIE W NIEPEWNYCH SYTUACJACH

9.0 Wprowadzenie

W większości części I, II i III nasze procedury wnioskowania były zgodne z modelem rozumowania stosowanym w rachunku predykatów: z prawidłowych przesłanek, prawidłowe reguły wnioskowania dają nowe, gwarantowane prawidłowe wnioski. Jednak, jak widzieliśmy w częściach 5 i 7, istnieje wiele sytuacji, które nie pasują do tego podejścia; to znaczy, musimy wyciągać użyteczne wnioski ze źle sformułowanych i niepewnych dowodów, stosując błędne reguły wnioskowania. Wyciąganie pożytecznych wniosków z niepełnych i nieprecyzyjnych danych przy błędnym uzasadnieniu nie jest zadaniem niemożliwym; robimy to z powodzeniem w prawie każdym aspekcie naszego codziennego życia. Stawiamy prawidłowe diagnozy lekarskie i zalecamy leczenie niejednoznacznych objawów; analizujemy problemy z naszymi samochodami lub stereo; rozumiemy wypowiedzi językowe, które są często niejednoznaczne lub niepełne; rozpoznajemy przyjaciół po ich głosach lub gestach; i tak dalej. Aby zademonstrować problem rozumowania w niejednoznacznych sytuacjach, rozważ Regułę 2 z samochodowego systemu eksperckiego:

gdyby

silnik się nie obraca i

światła się nie włączają

następnie

problem to akumulator lub kable.

Na pozór ta reguła wygląda jak normalna relacja predykatów do stosowania we wnioskach dźwiękowych (modus ponens). Tak jednak nie jest; ma charakter heurystyczny. Możliwe, choć bardzo mało prawdopodobne, że akumulator i kable są w porządku, ale samochód ma po prostu zły rozrusznik i przepalone reflektory. Awaria silnika i zapalenie się lampek niekoniecznie oznaczają, że akumulator i kable są złe. Ciekawe, że prawdą jest odwrotność reguły:

gdyby

problem to akumulator lub kable

następnie

silnik się nie obraca i

światła się nie włączają.

Poza tym, co nadprzyrodzone, z rozładowaną baterią, ani światła, ani rozrusznik nie będą działać! Nasz system ekspercki oferuje przykład abdukcyjnego rozumowania. Formalnie uprowadzenie stwierdza, że z $P \rightarrow Q$ i Q można wywnioskować P . Porwanie jest błędną regułą wnioskowania, co oznacza, że wniosek niekoniecznie jest prawdziwy dla każdej interpretacji, w której przesłanki są prawdziwe (sekcja 2.3). Chociaż uprowadzenie jest niewłaściwe, często jest niezbędne do rozwiązania problemów. „Logicznie poprawna” wersja reguły baterii nie jest zbyt przydatna w diagnozowaniu awarii samochodu, ponieważ jej przesłanka, czyli zły akumulator, jest naszym celem, a wnioski z niej to obserwowalne objawy, z którymi musimy pracować. Reguła może być jednak stosowana w sposób abdukcyjny z zasady w wielu diagnostycznych systemach ekspertowych. Usterki lub choroby powodują (implikują) objawy, a nie odwrotnie; ale diagnoza musi działać od objawów aż po ich przyczyny. W systemach opartych na wiedzy często dodajemy do reguły czynnik pewności, aby zmierzyć zaufanie do jej konkluzji. Na przykład reguła $P \rightarrow Q$ (.9) wyraża przekonanie „Jeśli uważasz, że P jest prawdziwe, to wierzysz, że Q wydarzy się w 90% przypadków”. W ten sposób reguły heurystyczne mogą wyrażać wyraźną politykę dotyczącą przekonań.

Inną kwestią związaną z rozumowaniem systemu eksperckiego jest sposób wyciągania przydatnych wyników z danych z brakującymi, niepełnymi lub niepoprawnymi informacjami. Możemy użyć środków zapewniających pewność, aby odzwierciedlić naszą wiarę w jakość danych, na przykład stwierdzając, że światła mają pełną moc (.2), mogą wskazywać, że reflektory się włączają, ale są słabe i ledwo widoczne. Przekonania i niedoskonałe dane można propagować za pomocą reguł ograniczających wnioski. W tym rozdziale omówimy kilka sposobów radzenia sobie z wnioskowaniem abdukcyjnym i niepewnością, zwłaszcza, że jest to wymagane do rozwiązywania problemów wymagających dużej wiedzy. W sekcji 9.1 pokazujemy, jak można rozszerzyć formalizm oparty na logice, aby zająć się zadaniem abdukcyjnym, w tym wykorzystanie systemów niemonotonicznych wspieranych przez algorytmy utrzymywania prawdy. W 9.2 rozważymy kilka alternatyw dla logiki, w tym algebrę czynników pewności ze Stanforda, rozumowanie „rozmyte” oraz teorię dowodów Dempstera-Shafera. Te proste obliczenia są często wykorzystywane do rozwiązywania niektórych problemów związanych ze złożonością stosowania pełnego podejścia bayesowskiego do budowania systemów ekspertowych. W podrozdziale 9.3 wprowadzamy stochastyczne podejście do niepewnego rozumowania. Techniki te opierają się na twierdzeniu Bayesa dotyczącym rozumowania częstotliwości zdarzeń w oparciu o wcześniejsze informacje o tych zdarzeniach. Kończymy 9.3, wprowadzając modele graficzne, w tym sieci przekonań bayesowskich oraz obserwowalne i ukryte modele Markowa. W Części 13 przedstawiamy stochastyczne podejście do uczenia się.

9.1 Abdukcyjne wnioskowanie oparte na logice

Najpierw przedstawiamy podejście do uprowadzenia oparte na logice. Dzięki logice fragmenty wiedzy są wyraźnie używane w rozumowaniu i mogą być częścią wyjaśnień wynikających z wniosków. Ale tradycyjna logika ma również swoje ograniczenia, zwłaszcza w obszarach, w których brakuje informacji, są one zmieniane lub niepewne; w takich sytuacjach tradycyjne procedury wnioskowania mogą się nie nadawać. Przedstawiamy kilka rozszerzeń tradycyjnej logiki, które pozwalają jej wspierać wnioskowanie abdukcyjne. W 9.1.1 rozszerzamy logikę, aby opisała świat zmieniających się informacji i przekonań. Tradycyjna logika matematyczna jest monotoniczna: zaczyna się od zestawu aksjomatów uznawanych za prawdziwe i wyciąga wnioski z ich konsekwencji. Jeśli dodamy nowe informacje do tego systemu, może to spowodować zwiększenie zestawu prawdziwych stwierdzeń. Dodanie wiedzy nigdy

nie zmniejszy zestawu prawdziwych stwierdzeń. Ta monotoniczna właściwość prowadzi do problemów, gdy próbujemy modelować rozumowanie w oparciu o przekonania i założenia. Rozumując z pewnością, ludzie wyciągają wnioski na podstawie ich aktualnego zestawu przekonań; jednakże, w przeciwieństwie do aksjomatów matematycznych, przekonania te, wraz z ich konsekwencjami, mogą się zmieniać w czasie, gdy dostępnych będzie więcej informacji. Rozumowanie niemonotoniczne rozwiązuje problem zmiany przekonań. Niemonotoniczny system rozumowania radzi sobie z niepewnością, przyjmując najbardziej rozsądne założenia w świetle niepewnych informacji. Następnie kontynuuje rozumowanie tak, jakby te założenia były prawdziwe. W późniejszym czasie przekonanie może się zmienić, co wymaga ponownego przeanalizowania wszelkich wniosków wynikających z tego przekonania. Następnie można zastosować algorytmy utrzymywania prawdy, sekcja 9.1.2, w celu utrzymania spójności bazy wiedzy. Inne porywające rozszerzenia logiki obejmują „modele minimalne”, sekcja 9.1.3, oraz podejście „ustalonego pokrycia”, sekcja 9.1.4.

9.1.1 Logiki dla wnioskowania niemonotonicznego

Nonmonotoniczność jest ważną cechą rozwiązywania problemów człowieka i zdrowego rozsądku. W większości planów, na przykład podczas jazdy do pracy, przyjmujemy liczne założenia dotyczące dróg i ruchu. Jeśli stwierdzimy, że jedno z tych założeń jest naruszone, być może przez budowę lub wypadek na naszej zwykłej trasie, zmieniamy plany i znajdujemy alternatywną trasę. Konwencjonalne rozumowanie przy użyciu logiki predykatów opiera się na trzech ważnych założeniach. Po pierwsze, opisy predykatów muszą być wystarczające w odniesieniu do naszej domeny aplikacji. Oznacza to, że należy przedstawić wszystkie informacje niezbędne do rozwiązania problemu. Po drugie, baza informacji musi być spójna; to znaczy, fragmenty wiedzy nie mogą być ze sobą sprzeczne. Wreszcie, dzięki zastosowaniu reguł wnioskowania, znane informacje rodzą monotonicznie. Jeśli którekolwiek z tych trzech założeń nie zostanie spełnione, konwencjonalne podejście oparte na logice nie zadziała. Systemy niemonotoniczne rozwiązują każdy z tych trzech problemów. Po pierwsze, systemy rozumowania często borykają się z brakiem wiedzy na temat domeny. Jest tu ważna kwestia: przypuśćmy, że nie mamy wiedzy o predykatie p ; czy to oznacza brak wiedzy nie jesteśmy pewni, czy p jest prawdziwe, czy też jesteśmy pewni, że nie p jest prawdziwe? Na to pytanie można odpowiedzieć na wiele sposobów. Prolog wykorzystuje założenie o zamkniętym świecie, aby określić jako fałszywe wszystko, czego jego system rozumowania nie może okazać się prawdziwym. Jako ludzie często przyjmujemy alternatywne podejście, zakładając, że coś jest prawdą, chyba że można wyraźnie wykazać, że jest fałszywe.

Innym podejściem do problemu braku wiedzy jest formułowanie wyraźnych założeń dotyczących prawdy. W ludzkim rozumowaniu zakładamy niewinność ludzi niezwiązanych bezpośrednio z przestępstwem. Prawdopodobnie posunęlibyśmy się nawet dalej i założylibyśmy niewinność tych, którzy nie mogli skorzystać na zbrodni. Efektem tych założeń jest skuteczne uzupełnienie brakujących szczegółów wiedzy i rozszerzenie naszego rozumowania o nowe wnioski oparte na tych założeniach. Omówimy założenie zamkniętego świata i jego alternatywy w sekcji 9.1.3. Ludzie rozumują na podstawie tego, jak zwykle działa świat. Większość ptaków lata. Rodzice zwykle kochają i wspierają swoje dzieci. Wyciągamy wnioski na podstawie zgodności rozumowania z naszymi założeniami dotyczącymi świata. W tej sekcji omówimy dodawanie operatorów modalnych, takich jak jest spójne z i chyba, aby przeprowadzić wnioskowanie oparte na założeniach. Drugie założenie wymagane od tradycyjnych systemów opartych na logice jest takie, że wiedza wspierająca rozumowanie musi być spójna. Dla ludzkich rozumów byłoby to bardzo ograniczające założenie. Diagnozując problem, często mamy wiele możliwych wyjaśnień sytuacji, zakładając, że coś jest prawdą, dopóki alternatywne założenie nie okaże się bardziej owocne. Na przykład, analizując wypadek lotniczy, ekspert ds. katastrof rozważy kilka alternatywnych przyczyn, eliminując (wyjaśniając) tylko niektóre w miarę odkrywania

nowych informacji. My, ludzie, wykorzystujemy wiedzę o świecie, jak to zwykle bywa, próbując kierować rozumowaniem poprzez alternatywne scenariusze. Chcielibyśmy, aby systemy logiczne były w stanie przyjmować alternatywne hipotezy. Wreszcie, jeśli chcemy używać logiki, musimy zająć się problemem aktualizacji bazy wiedzy. Są tutaj dwie kwestie: po pierwsze, w jaki sposób możemy dodać wiedzę opartą wyłącznie na założeniach, a po drugie, co możemy zrobić, gdy jedno z naszych założeń okaże się później błędne. Aby rozwiązać pierwszą kwestię, możemy pozwolić na dodanie nowej wiedzy na podstawie założeń. Zakłada się, że ta nowa wiedza jest poprawna i może z kolei zostać wykorzystana do wnioskowania o większej ilości nowej wiedzy. Koszt tej praktyki polega na tym, że musimy śledzić wszystkie rozumowania i dowody oparte na założeniach: musimy być przygotowani do ponownego rozważenia wszelkiej wiedzy opartej na tych założeniach. Rozumowanie niemonotoniczne, ponieważ wnioski trzeba czasem ponownie przemyśleć, jest także nazywany wykonalnym; to znaczy nowe informacje mogą czasami unieważnić poprzednie wyniki. Reprezentacje i procedury wyszukiwania, które śledzą etapy rozumowania systemu logicznego, nazywane są systemami utrzymania prawdy lub TMS. W rozsądnym rozumowaniu TMS zachowuje spójność bazy wiedzy, śledząc wnioski, które mogą później wymagać zakwestionowania. W Sekcji 9.1.2 rozważymy kilka podejść do utrzymania prawdy. Najpierw rozważymy operatory, które mogą sprawić, że tradycyjne systemy rozumowania oparte na logice będą możliwe do pokonania. Wdrażając rozumowanie niemonotoniczne, możemy rozszerzyć naszą logikę o operator, chyba że. chyba że popiera wnioski oparte na przekonaniu, że jego argument jest nieprawdziwy. Założmy, że mamy następujący zestaw zdań logiki predykatów:

$p(X)$ chyba, że $q(X) \rightarrow r(X)$

$p(Z)$

$r(W) \rightarrow s(W)$

Pierwsza reguła oznacza, że możemy wywnioskować $r(X)$, jeśli $p(X)$ jest prawdziwe i nie wierzymy, że $q(X)$ jest prawdziwe. Kiedy te warunki są spełnione, wnioskujemy $r(X)$, a używając $r(X)$, możemy wnioskować o $s(X)$. Następnie, jeśli zmienimy nasze przekonanie lub stwierdzimy, że $q(X)$ jest prawdziwe, $r(X)$, a także $s(X)$ muszą zostać wycofane. Zauważ, że o ile nie dotyczy raczej kwestii wiary niż prawdy. W konsekwencji zmiana wartości argumentu z „nieznane lub uważane za fałszywe” na „uważane lub uznawane za prawdziwe” może spowodować, że wycofamy wszystkie wnioski, które zależą od tych przekonań. Rozszerzając naszą logikę o rozumowanie z przekonaniem, które można później wycofać, wprowadzamy do systemu niemonotoniczność. Opisany schemat rozumowania może być również użyty do zakodowania reguł domyślnych. Jeśli zamienimy $p(X)$, chyba że $q(X) \rightarrow r(X)$ z $p(X)$, chyba że $ab p(X) \rightarrow r(X)$, gdzie $ab p(X)$ reprezentuje nieprawidłowe $p(X)$, stwierdzamy, że jeśli nie mamy nienormalnego wystąpienia p , na przykład ptaka ze złamanym skrzydłem, możemy wyciągnąć wniosek, że jeśli X jest ptakiem, to X może latać. Drugi operator modalny do rozszerzania systemów logicznych jest sugerowany przez McDermotta i Doyle'a. Rozszerzają one logikę predykatów pierwszego rzędu o operator modalny M , który jest umieszczony przed odczytaniem predykatu zgodnie z. Na przykład:

$\forall X \text{ good_student}(X) \wedge M \text{ study_hard}(X) \rightarrow \text{absolvenci}(X)$

Ten punkt można przeczytać: Dla wszystkich X , gdzie X jest dobrym uczniem i jeśli fakt, że X uczy się ciężko, jest zgodny z wszystkim innym, co wiemy, to X ukończy szkołę. Oczywiście najtrudniejszą częścią jest tutaj dokładne zdefiniowanie, co jest zgodne ze wszystkim, co wiemy, co może w rzeczywistości oznaczać. Po pierwsze, zauważamy, że jest to zgodne ze wszystkim, co wiemy, może nie być rozstrzygalne. Powodem jest to, że operator modalny tworzy nadzbiór już nierozstrzygalnego systemu, a zatem będzie nierozstrzygalny. Istnieją dwa sposoby rozwiązania problemu nierozstrzygalności. Po pierwsze, możemy użyć negacji jako dowodu niepowodzenia w wykazaniu, z którym jest zgodny. W

naszym przykładzie spróbowalibyśmy udowodnić, że nie ($\text{study_hard}(X)$) i jeśli nie moglibyśmy udowodnić, że X nie prowadzi badań, to zakładamy, że X studiuje. Często używamy tego podejścia w aproksymacji logiki predykatów podobnej do Prologa. Niestety, negacja jako porażka może nadmiernie ograniczyć naszą domenę interpretacji. Drugie podejście do problemu jest zgodne z problemem polegającym na przeprowadzeniu opartego na heurystyce i ograniczonego (ograniczonego czasowo lub pamięcią) poszukiwania prawdy predykatu, w naszym przykładzie $\text{study_hard}(X)$, a następnie, jeśli nie ma przeciwnych dowodów, założymy, że to prawda, ze zrozumieniem, że być może będziemy musieli później wycofać wnioski absolwentów i wszystkie dalsze wnioski na ich podstawie. Możemy również wygenerować potencjalnie sprzeczne wyniki, używając jest zgodne z operatorem. Założymy, że ktoś, Piotr, jest dobrym uczniem, ale też bardzo lubi imprezy. Wtedy możemy mieć następujący zestaw predykatów opisujących sytuację:

$$\forall X \text{good_student}(X) \wedge M \text{study_hard}(X) \rightarrow \text{graduates}(X)$$

$$\forall Y \text{party_person}(Y) \wedge M \text{not}(\text{study_hard}(Y)) \rightarrow \text{not}(\text{graduates}(Y))$$

$$\text{good_student}(\text{peter})$$

$$\text{party_person}(\text{peter})$$

Dzięki temu zestawowi klauzul, w których nie mamy dalszych informacji na temat zwyczajów Piotra związanych ze studiowaniem, niezależnie od tego, czy uczy się ciężko, czy nie, możemy wywnioskować, że Piotr ukończy szkołę i nie będzie jej! Jedną z metod rozumowania, która chroni przed takimi sprzecznymi wynikami, jest śledzenie powiązań zmiennych używanych z operatorem modalnym, z którymi jest zgodny. Tak więc, gdy Piotr był związany albo z predykatem study_hard lub $\text{not}(\text{study_hard})$, system zapobiegał wiązaniu Piotra z innym orzeczeniem. Inne niemonotoniczne układy są jeszcze bardziej konserwatywne i uniemożliwiają wyciąganie jakichkolwiek wniosków z takich potencjalnie sprzecznych zestawów klauzul. Możemy stworzyć kolejną anomalię:

$$\forall Y \text{very_smart}(Y) \wedge M \text{not}(\text{study_hard}(Y)) \rightarrow \text{not}(\text{study_hard}(Y))$$

$$\forall X \text{not}(\text{very_smart}(X)) \wedge M \text{not}(\text{study_hard}(X)) \rightarrow \text{not}(\text{study_hard}(X))$$

Z tych klauzul możemy wywnioskować nową klauzulę:

$$\forall Z M \text{nie}(\text{study_hard}(Z)) \rightarrow \text{not}(\text{study_hard}(Z))$$

Dalszy rozwój semantyki jest zgodny z operatorem adresowania takiego anomalnego rozumowania. Kolejnym rozszerzeniem jest logika autoepistemiczna. Innym niemonotonicznym systemem logicznym jest logika domyślna, stworzona przez Reitera. Logika domyślna wykorzystuje nowy zestaw reguł wnioskowania w postaci:

$$A(Z) \wedge :B(Z) \rightarrow C(Z)$$

co brzmi: Jeśli $A(Z)$ jest możliwe do udowodnienia i jest zgodne z tym, co wiemy, zakładając $B(Z)$, możemy wywnioskować $C(Z)$. W tym momencie logika domyślna brzmi podobnie jak opisana właśnie niemonotoniczna logika McDermotta i Doyle'a. Istotną różnicą między nimi jest metoda rozumowania. W logice domyślnej te specjalne reguły wnioskowania są używane do wnioskowania o zestawach prawdopodobnych rozszerzeń oryginalnego zestawu aksjomatów / twierdzeń. Każde rozszerzenie jest tworzone przy użyciu jednej z domyślnych reguł wnioskowania logicznego na wiedzy reprezentowanej przez oryginalny zbiór aksjomatów / twierdzeń. W związku z tym naturalne byłoby posiadanie wielu wiarygodnych rozszerzeń oryginalnej bazy wiedzy. Można to zobaczyć w klauzulach dotyczących absolwentów:

$\forall X \text{ good_student}(X) \wedge : \text{study_hard}(X) \rightarrow \text{graduates}(X)$

$\forall Y \text{ party}(Y) \wedge : \text{not}(\text{study_hard}(Y)) \rightarrow \text{not}(\text{graduates}(Y))$

Każda klauzula może zostać użyta do stworzenia unikalnego, wiarygodnego rozszerzenia opartego na oryginalnym zestawie wiedzy. Logika domyślna pozwala następnie na przyjęcie dowolnego twierdzenia wywnioskowanego w prawdopodobnym rozszerzeniu jako aksjomat do dalszego rozumowania. Musi istnieć jakiś przewodnik podejmowania decyzji, aby ostatecznie określić, które rozszerzenie ma zostać użyte do dalszego rozwiązywania problemów. Logika domyślna nie mówi nic o tym, jak wybrać spośród możliwych prawdopodobnych rozszerzeń bazy wiedzy. Reiter, Criscuolo oraz Touretzky rozwijają te kwestie. Wreszcie, istnieje również niemonotoniczna sytuacja rozumowania stworzona przez wyszukiwanie dziedziczenia po reprezentacjach, w których obiekty mogą dziedziczyć od więcej niż jednego rodzica. Piotr, wspomniany wcześniej dobry student kochający imprezy, mógł odziedziczyć jeden zestaw cech z bycia dobrym uczniem, tj. Taki, który najprawdopodobniej ukończyłby. Piotr mógł również odziedziczyć inne, w tym przypadku częściowo sprzeczne, właściwości z bycia partyjnym, to znaczy, że nie ukończyłby studiów. Ważnym problemem, przed którym stają niemonotoniczne systemy rozumowania, jest zadanie skutecznej rewizji zestawu wniosków w świetle zmieniających się przekonań. Jeśli na przykład użyjemy predykatu r do wnioskowania s , to usunięcie r usuwa również wsparcie dla s , a także wszystkie inne wnioski, które wykorzystały s . O ile nie istnieje niezależny zestaw wniosków wspierających s , należy go wycofać. Wdrożenie tego procesu wycofania wymaga, w najgorszym przypadku, przeliczenia wszystkich wniosków za każdym razem, gdy zmienia się przekonanie. Przedstawione poniżej systemy utrzymania prawdy oferują mechanizmy utrzymania spójności plików bazy wiedzy.

9.1.2 Systemy utrzymania prawdy

Do ochrony logicznej spójności wniosków z systemu wnioskowania można zastosować system utrzymania prawdy (TMS). Jak wskazano w poprzedniej sekcji, konieczne jest przeliczenie poparcia dla pozycji w bazie wiedzy zawsze, gdy przekonania wyrażone przez zmienione klauzule bazy wiedzy. Systemy utrzymania prawdy rozwiązują tę kwestię, przechowując uzasadnienia dla każdego wniosku, a następnie ponownie rozważając poparcie dla wniosków w świetle nowych przekonań. Jednym ze sposobów spojrzenia na ten problem jest przejście algorytmu cofania. Wycofywanie się jest systematyczną metodą badania wszystkich alternatyw dla punktów decyzyjnych w rozwiązywaniu problemów w oparciu o wyszukiwanie. Ważną wadą algorytmu cofania jest jednak sposób, w jaki systematycznie (i na ślepo) wycofuje się ze ślepych zaułków przestrzeni i szuka alternatyw dla swoich ostatnich wyborów. Takie podejście jest czasami nazywane cofaniem chronologicznym. Zapewniamy, że chronologiczne cofanie będzie systematycznie sprawdzać wszystkie alternatywy w przestrzeni; jednak sposób, w jaki to przebiega, jest czasochłonny, nieefektywny i na bardzo dużej przestrzeni bezużyteczny. To, czego naprawdę chcemy w wyszukiwaniu opartym na logice, to możliwość cofnięcia się bezpośrednio do punktu w przestrzeni, w którym występuje problem, i dostosowania rozwiązania w ten stan. To podejście jest nazywane wycofywaniem ukierunkowanym na zależności. Rozważmy przykład z rozumowania niemonotonicznego. Musimy dowiedzieć się o p , czego nie możemy bezpośrednio wywnioskować. Istnieje jednak prawdopodobne założenie q , które, jeśli jest prawdziwe, potwierdzi p . Więc zakładamy q i wyprowadzamy p . Nasze rozumowanie jest kontynuowane i na podstawie p kończymy r i s . Kontynuujemy nasze rozumowanie i kończymy bez poparcia p , r lub s wyniki t i u . Wreszcie udowadniamy, że nasze wcześniejsze założenie q jest fałszywe. Co mamy robić? Chronologiczne cofanie się wróciłoby do naszych kroków rozumowania w odwrotnej kolejności w której zostały wykonane. Cofanie się w kierunku zależności od razu wróciłoby do źródła sprzecznych informacji, a mianowicie do pierwszego założenia q . Wtedy będzie się poruszał, chowając p , r i s . Możemy w tym momencie sprawdzić, czy r i s można wyprowadzić niezależnie od p i q . To, że zostały

pierwotnie wyprodukowane z błędnym założeniem, nie oznacza, że nie są obsługiwane w inny sposób. Wreszcie, ponieważ t i u zostały wyprowadzone bez p, r lub s, nie musielibyśmy ich ponownie rozważać. Aby zastosować w systemie wnioskowania wycofywanie się w kierunku zależności, musimy:


1. Powiązać z przedstawieniem każdego wniosku jego uzasadnienie. To uzasadnienie wskazuje na proces wyprowadzania tego wniosku. Uzasadnienie musi zawierać wszystkie fakty, zasady i założenia użyte do sformułowania wniosku.
2. Zapewnić mechanizm, który po przedstawieniu sprzeczności wraz z jej uzasadnieniem znajdzie w uzasadnieniu zbiór fałszywych założeń, które doprowadziły do sprzeczności.
3. Wycofać fałszywe założenia.
4. Stworzyć mechanizm, który podąża za wycofanymi założeniami i wycofuje wszelkie wnioski, które wykorzystują w swoich uzasadnieniach wycofane fałszywe założenie.

Oczywiście wszystkie wycofane wnioski niekoniecznie są fałszywe, więc należy je ponownie sprawdzić, aby sprawdzić, czy można je uzasadnić niezależnie od wycofanych klauzul. Następnie przedstawimy dwie metody budowania systemów wstecznego śledzenia ukierunkowanego na zależności. Jon Doyle stworzył jeden z najwcześniejszych systemów utrzymania prawdy, zwany systemem utrzymania prawdy opartym na uzasadnieniu lub JTMS. Doyle był pierwszym badaczem, który wyraźnie oddzielił system utrzymywania prawdy, sieć zdań i ich uzasadnień, od systemu rozumowania działającego w jakiejś dziedzinie. Rezultatem tego podziału jest to, że JTMS komunikuje się z osobą rozwiązującą problem, być może automatyczną weryfikacją twierdzeń, otrzymując informacje o nowych zdaniach i uzasadnieniach, a z kolei dostarczając rozwiązującemu problem informacje o tym, w które zdania należy wierzyć na podstawie aktualnie istniejących uzasadnień. Istnieją trzy główne operacje, które są wykonywane przez JTMS. Po pierwsze, JTMS bada sieć uzasadnień. Ta inspekcja może być wywołana przez zapytania od osoby rozwiązującej problem, takie jak: Czy mam wierzyć w propozycję p? Dlaczego mam wierzyć twierdzeniu p? Jakie założenia leżą u podstaw zdania p? Drugą operacją JTMS jest modyfikacja sieci zależności, w której modyfikacje są napędzane informacjami dostarczanymi przez rozwiązującego problem. Modyfikacje obejmują dodawanie nowych propozycji, dodawanie lub usuwanie przesłanek, dodawanie sprzeczności i uzasadnianie wiary w zdanie. Ostatnim działaniem JTMS jest aktualizacja sieci. Ta operacja jest wykonywana za każdym razem, gdy wprowadzana jest zmiana w sieci zależności. Operacja aktualizacji przelicza etykiety wszystkich propozycji w sposób zgodny z istniejącymi uzasadnieniami. Aby zademonstrować JTMS, tworzymy prostą sieć zależności. Rozważmy operator modalny M przedstawiony w sekcji 9.1.1, który znajduje się przed odczytaniem predykatu jako zgodny z. Na przykład:


$$\forall X \text{ good_student}(X) \wedge M \text{ study_hard}(X) \rightarrow \text{study_hard}(X)$$
$$\forall Y \text{ party_person}(Y) \rightarrow \text{not}(\text{study_hard}(Y))$$
$$\text{good_student}(\text{david})$$

Teraz tworzymy z tego zestawu twierdzeń sieć uzasadnienia.


W JTMS każdy predykat reprezentujący przekonanie jest powiązany z dwoma innymi zestawami przekonań. Pierwszy zbiór, oznaczony jako IN na rysunku 1, jest zbiorem zdań, w które należy wierzyć, aby zdanie się zachowało.



Drugie, oznaczone jako OUT, są propozycjami, w które nie należy wierzyć, aby były one aktualne. Rysunek 1 przedstawia uzasadnienie, które wspiera $study_hard(david)$ wyprowadzone z wcześniej wymienionych predykatów. Notacje z rysunku 1 wyjaśniono na rysunku 2.




Przesłanki uzasadnień są oznaczone jak na rysunku 2(a), a kombinacje zdań, które wspierają wniosek, są oznaczone jak na rysunku 2(b). Dzięki informacjom z sieci przedstawionym na rysunku 1 osoba rozwiązująca problem może wnioskować, że metoda $study_hard(david)$ jest obsługiwana, ponieważ założenie $good_student(david)$ jest uważane za prawdziwe i jest zgodne z faktem, że dobrzy uczniowie ciężko się uczą. W tym przykładzie nie ma również żadnych dowodów ani innych wskazówek, że David nie uczy się ciężko. Załóżmy, że dodamy założenie $party_person(david)$. To dodanie umożliwia wyprowadzenie $not(study_hard(david))$, a przekonanie $study_hard(david)$ nie jest już obsługiwane. Uzasadnienia takiej sytuacji przedstawiono na rysunku 3;




zwróć uwagę na zmianę etykiety IN i OUT. Jak pokazują rysunki 1 i 3, JTMS nie reprezentuje bezpośrednio relacji predykatów wyrażonych w pierwotnym zbiorze zdań. JTMS jest raczej prostą siecią, która bierze pod uwagę tylko relacje między zdaniami atomowymi i ich negacją i organizuje je w związki wspierające przekonania. Pełny zestaw łączników predykatów i schematów wnioskowania ($\forall X, \wedge, \vee, \rightarrow$ itp.) Jest używany w samym rozwiązaniu problemu. Systemy McAllestera oraz Martinsa i Shapiro połączyły TMS i narzędzie do rozwiązywania problemów w jedną reprezentację. JTMS zajmuje się tylko zależnościami między przekonaniami i nie zajmuje się treścią tych przekonań. Dlatego przekonania możemy zastąpić identyfikatorami, często w postaci n_1, n_2, \dots , które są skojarzone z obiektami w sieci zwanymi węzłami. Następnie algebra IN i OUT, którą widzieliśmy zaimplementowaną w przykładzie $study_hard$, umożliwia JTMS wnioskowanie o poparciu dla przekonań. Podsumowując,

JTMS działa z zestawami węzłów i uzasadnień. Węzły oznaczają przekonania, a uzasadnienia wspierają przekonania w węzłach. Z węzłami powiązane są etykiety IN i OUT, które wskazują stan przekonania skojarzonego węzła. Możemy wnioskować o wsparciu dla dowolnego węzła, odnosząc go do IN i OUT innych węzłów, które stanowią jego uzasadnienie (a). Podstawowymi operacjami algebry JTMS jest przeprowadzanie inspekcji, modyfikacji i aktualizacji operatorów wymienionych powyżej. Wreszcie, ponieważ sprawdzanie uzasadnienia jest wymuszane przez tworzenie kopii zapasowych na linkach samej sieci justowania, mamy przykład cofania opartego na zależnościach. Więcej informacji na temat tego podejścia do JTMS można znaleźć w Doyle lub Reinfranka . Drugim typem systemu utrzymania prawdy jest system utrzymania prawdy oparty na założeniach (ATMS). Termin oparty na założeniach został po raz pierwszy wprowadzony przez deKleera, chociaż podobne pomysły można znaleźć u Martinsa i Shapiro (1983). W tych systemach etykiety węzłów w sieci nie są już IN i OUT, ale raczej zestawami przesłanek (założeń) leżących u podstaw ich wyprowadzenia. deKleer dokonuje również rozróżnienia między węzłami przesłanek, które są uniwersalne, a węzłami, które mogą być założeniami poczynionymi przez osobę rozwiązującą problem, a które później mogą zostać wycofane. Przewaga ATMS nad JTMS wynika z dodatkowej elastyczności, jaką zapewnia ATMS w radzeniu sobie z wieloma możliwymi stanami przekonania. Oznaczając przekonania zbiorami przesłanek, w których się trzymają, nie ma już jednego stanu przekonania (w JTMS wszystkie węzły oznaczone jako IN), ale raczej szereg możliwych stanów, zbiorów wszystkich podzbiorów przesłanek wspierających. Stworzenie różnych zestawów przekonania lub możliwych światów pozwala na porównanie wyników różnych wyborów przesłanek, istnienie różnych rozwiązań problemu oraz wykrycie i wyłączenie ze sprzeczności. Wady ATMS obejmują brak możliwości reprezentowania zestawów założeń, które same w sobie są niemonotoniczne oraz kontrolę nad rozwiązaniem problemu. Komunikacja między ATMS a osobą rozwiązującą problemy jest podobna do komunikacji między JTMS a jego osobą rozwiązującą problemy z operatorami w celu kontroli, modyfikacji i aktualizacji. Jedyna różnica polega na tym, że w przypadku ATMS nie ma już jednego stanu wiary, ale raczej podzbiory potencjalnych przesłanek wspierających. Celem obliczeń w ATMS jest znalezienie minimalnych zestawów przesłanek wystarczających do obsługi każdego węzła. Obliczenia te są wykonywane przez propagowanie i łączenie etykiet, zaczynając od etykiet dla pomieszczeń. Następnie przedstawiamy szczegółowy przykład zaadaptowany z Martins. Założymy, że mamy sieć ATMS z rysunku 4.



W tej sieci n1, n2, n4 i n5 są przesłankami i przyjmuje się, że są prawdziwe. Sieć zależności odzwierciedla również relacje, które z przesłanek n1 i n2 obsługujemy n3, z n3 obsługujemy n7, z n4 obsługujemy n7, z n4 i n5 obsługujemy n6, a na koniec z n6 obsługujemy n7. Rysunek 5 przedstawia siatkę podzbioru / superzbioru dla zależności przesłanek znalezionych na rysunku 4.



Ta krata podzbiorów lokali oferuje przydatny sposób wizualizacji przestrzeni kombinacji pomieszczeń. Tak więc, jeśli okaże się, że jakaś przesłanka jest podejrzana, ATMS będzie w stanie określić, w jaki sposób ta przesłanka odnosi się do innych podzbiorów obsługi pomieszczeń. Na przykład węzeł n3 na rysunku 4 będzie obsługiwany przez wszystkie zestawy przesłanek, które znajdują się powyżej $\{n1, n2\}$ w kracie na rysunku 5. Rozumujący ATMS usuwa sprzeczności, usuwając z węzłów te zestawy przesłanek, które okazały się niespójne. Załóżmy na przykład, że zrewidujemy poparcie dla rozumowania przedstawionego na rysunku 4, aby uczynić n3 węzłem sprzeczności. Ponieważ etykietą dla n3 jest $\{n1, n2\}$, ten zbiór przesłanek jest określony jako niespójny. Kiedy ta niespójność zostanie wykryta, wszystkie zbiory przesłanek, które są w relacji nadzbiór do $\{n1, n2\}$ na rysunku 5, są oznaczane jako niespójne (zakreśliliśmy je) i usuwane z sieci zależności. W tej sytuacji jedna z możliwych etykiet obsługujących n7 również będzie musiała zostać usunięta. Pełny opis algorytmu usuwania sprzeczności można znaleźć w deKleer. Istnieje kilka innych ważnych przyczynków do rozumowania TMS. TMS oparty na logice jest oparty na pracy McAllestera. W LTMS relacje między zdaniem są reprezentowane przez klauzule, które można wykorzystać do wyprowadzenia wartości prawdziwości dowolnego z opisywanych przez nie zdań. Inne podejście, wielokrotne rozumowanie przekonań (MBR) jest podobne do rozumowania ATMS, z tym wyjątkiem, że rozwiązanie problemu i system utrzymania prawdy są połączone w jeden system. MBR jest oparty na języku logicznym zwanym SWM, który opisuje stany wiedzy. Każdy stan wiedzy składa się z pary deskryptorów, z których pierwszy odzwierciedla bazę wiedzy, a drugi zbiór zestawów znanych niespójnych przesłanek w bazie wiedzy. Algorytmy sprawdzania niespójności podczas rozumowania można znaleźć w Martins (1991). Dalszą dyskusję na temat systemów utrzymania prawdy można znaleźć w The Encyclopedia of Artificial Intelligence

9.1.3 Logika oparta na modelach minimalnych

W poprzednich sekcjach rozszerzyliśmy logikę o kilka różnych operatorów modalnych, które zostały specjalnie zaprojektowane, aby rozumieć świat taki, jaki jest zwykle, łągając wymóg, aby nasza wiedza o świecie była w jakiś sposób kompletna. Operatorzy ci zrodzili się z konieczności stworzenia bardziej elastycznego i zmiennego spojrzenia na świat. W tej sekcji przedstawiamy logikę zaprojektowaną specjalnie dla dwóch sytuacji: po pierwsze, aby uzasadnić, w którym zbiór twierdzeń określa tylko te rzeczy, które są prawdziwe, a po drugie, aby uzasadnić, w przypadku których ze względu na naturę zadania rozwiązywania problemów zbiory przypuszczeń są zwykle prawdziwe. W pierwszej sytuacji posługujemy się założeniem świata zamkniętego, w drugiej okręgach. Oba te podejścia do logiki są często nazywane rozumowaniem na podstawie modeli minimalnych. Widzieliśmy, że model jest interpretacją spełniającą S, zbiór wyrażeń predykatów, dla wszystkich

przypisać zmiennych. Istnieje wiele sposobów zdefiniowania, co oznacza model minimum. Definiujemy model minimum jako model tak, że nie ma mniejszych modeli, które mogą spełnić zestaw wyrażen S dla wszystkich przypisań zmiennych. Idea, która sprawia, że modele minimalne są ważne dla rozumowania, jest taka: istnieje (potencjalnie) nieskończona liczba predykatów, których można użyć do opisanie sytuacji na świecie. Rozważmy na przykład nieograniczone predykaty, które można wykorzystać do opisanie sytuacji problemu farmer-wilk-koza-kapusta: łódź nie tonie powoli, brzegi rzeki są na tyle blisko, że wiosłowanie będzie przepłynąć łodzią, wiatr i prąd nie są istotnymi czynnikami i tak dalej. Kiedy opisujemy problem, jesteśmy zwykle dość oszczędni w naszych opisach. Tworzymy tylko te predykaty, które są zarówno istotne, jak i potrzebne do rozwiązania problemu. Założenie o zamkniętym świecie opiera się na tym minimalnym modelu świata. Tworzone są dokładnie te predykaty, które są niezbędne do rozwiązania. Założenie o zamkniętym świecie wpływa na semantykę negacji w rozumowaniu. Na przykład, gdybyśmy chcieli ustalić, czy uczeń jest zarejestrowanym członkiem klasy, moglibyśmy przejść do bazy danych rejestracji, a jeśli uczeń nie jest wyraźnie wymieniony w tej bazie danych (model minimalny), nie byłby zarejestrowany. Podobnie, gdybyśmy chcieli wiedzieć, czy dwa miasta są bezpośrednio połączone samolotem, przeszlibyśmy do listy wszystkich połączeń lotniczych. Gdybyśmy nie wyszczególnili lotu bezpośredniego (model minimalny), to wywnioskowalibyśmy, że nie istnieje. Założenie o zamkniętym świecie to stwierdzenie, że jeśli nasz system obliczeniowy nie może stwierdzić, że $p(X)$ jest prawdziwe, to nie $(p(X))$ musi być prawdziwe. Jak zobaczymy, założenie o zamkniętym świecie wspiera wnioskowanie w Prologu. Zobaczymy trzy założenia (aksjomaty) implikowane w stosowaniu modeli minimalnych. Te aksjomaty są unikalną nazwą, tj. Wszystkie atomy o różnych nazwach są różne; zamknięty świat, tj. jedynymi przykładami relacji są te, które są implikowane przez obecne klauzule; i zamknięcie domeny. tj. atomy domeny są dokładnie tymi z modelu. Gdy te trzy elementy są spełnione, model minimalny staje się specyfikacją opartą w pełni na logice. Jeśli aksjomaty nie są spełnione, wymagana jest jakaś forma algorytmu utrzymania prawdy. Jeśli świat zamknięty wymaga, aby wszystkie predykaty składające się na model zostały określone, opis okrążenia wymaga podania tylko tych predykatów, które są istotne dla rozwiązania problemu. W opisie aksjomaty są dodawane do systemu, który wymusza minimalną interpretację predykatów bazy wiedzy. Te metapredykaty (predykaty dotyczące predykatów stwierdzenia problemu) opisują sposób, w jaki mają być interpretowane poszczególne predykaty. Oznacza to, że ograniczają lub zawężają możliwe interpretacje orzeczników. McCarthy przedstawił ideę okręgów w eksperymencie myślowym dotyczącym problemu misjonarzy i kanibali. Opis problemu prosi osobę rozwiązującą o wymyślenie serii ruchów, w których sześć postaci, pod pewnymi warunkami, może użyć łodzi do przepłynięcia rzeki. McCarthy przywołuje wiele absurdalnych sytuacji, które całkiem słusznie można zapytać o stwierdzenie problemu. Wiele z nich, takich jak wolno tonąca łódź lub czynnik wiatru, zostało przedstawionych wcześniej w tym rozdziale. Chociaż ludzie uważają takie sytuacje za absurdalne, rozumowanie, którego używamy, nie jest oczywiste. Aksjomaty opisujące problem, które McCarthy dodałby do specyfikacji problemu, precyzyjnie ograniczyłyby predykaty opisujące problem. Jako inny przykład okólnika rozważ wyrażenie predykatu ze specyfikacji rozumowania zorientowanego obiektowo, opartego na zdrowym rozsądku;

$$\forall X \text{ bird}(X) \wedge \text{not}(\text{abnormal}(X)) \rightarrow \text{flies}(X)$$

To wyrażenie może pojawić się w rozumowaniu, w którym jedną z właściwości ptaków są muchy. Ale co mogłoby ograniczyć definicję predykatu anormalnego? Że ptak nie jest pingwinem, że nie ma złamanego skrzydła, że nie jest martwy? Specyfikacja predykatu anormalnego jest potencjalnie nierozstrzygalna. Circumscription wykorzystuje schemat aksjomatów lub zestaw reguł meta w ramach rachunku predykatów pierwszego rzędu do generowania predykatów dla dziedziny problemowej. Reguły schematu powodują, że niektóre formuły mają najmniejsze możliwe rozszerzenia. Na przykład, jeśli B jest systemem przekonań obejmującym wiedzę o świecie K i wiedzę dziedzinową $A(p)$ o

predykacie p , to możemy uznać, że p jest zminimalizowane, ponieważ jak najmniej atomów a_i spełnia $p(a_i)$ zgodnie z wymogami z $A(p)$ i K . Wiedza o świecie K wraz z $A(p)$ i schematem opisowym są używane do wyciągania wniosków w standardowym rachunku predykatów pierwszego rzędu. Te wnioski są następnie dodawane do B , systemu przekonañ. Jako przykład załóźmy, że w świecie bloków, mamy wyrażenie:

$$\text{isblock}(a) \wedge \text{isblock}(b) \wedge \text{isblock}(c)$$

twierdząc, że a , b i c są blokami. Opisanie predykatu isblock daje:

$$\forall X (\text{isblock}(X) \leftarrow ((X = a) \vee (X = b) \vee (X = c)))$$

To wyrażenie stwierdza, że tylko bloki a , b i c , tj. Tylko te obiekty, których wymaga predykat isblock , są blokami w tej domenie. Podobnie predykat:

$$\text{isblock}(A) \vee \text{isblock}(B)$$

można ograniczyć do:

$$\forall X (\text{isblock}(X) \leftarrow ((X = a) \vee (X = b)))$$

Aby uzyskać szczegółowe informacje, w tym aksjomaty schematu użyte do wyprowadzenia tych wyników. Circumscription, gdy jest używany z operatorami takimi jak anormal , jest bardzo podobny do założenia zamkniętego świata, ponieważ wytwarza dokładnie te zmienne wiązania, które może obsługiwać anormalność . Jednak algebra opisowa pozwala nam rozszerzyć to rozumowanie na reprezentacje predykatów, ponieważ, jak właśnie zauważyliśmy, jeśli mamy predykat $p(X) \vee q(X)$, możemy opisać albo orzeczenie p lub q , albo jedno i drugie. Tak więc, w przeciwieństwie do założenia o zamkniętym świecie, opis obwodu pozwala nam opisać instancje możliwe w zbiorach opisy predykatów. Lifschitz wniósł ważny wkład, proponując punktowy opis, w którym model minimum może być przeprowadzony dla poszczególnych predykatów i ich możliwych instancji, a nie dla całej dziedziny. Innym ważnym wkładem jest Perlis (1988), gdzie rozumowanie może dotyczyć braku wiedzy określonego agenta.

9.1.4 Ustawianie ostony i odwodzenie oparte na logice

Jak zauważono na początku, w rozumowaniu abdukcyjnym mamy reguły postaci $p \rightarrow q$, wraz z rozsądną wiarą w q . Chcemy więc przedstawić argumenty za prawdziwością orzeczenia p . Rozumowanie abdukcyjne nie jest rozsądne, ale to, co często nazywa się rozumowaniem, stanowi najlepsze wyjaśnienie obecności danych q . W tej sekcji przyjrzymy się dokładniej generowaniu wyjaśnień w domenach wnioskowania abdukcyjnego. Oprócz przedstawionych już opisów rozumowania abdukcyjnego, naukowcy zajmujący się sztuczną inteligencją wykorzystali również zestaw pokrycia i analizy wspomagane logiką. Zestaw obejmuje podejście do uprowadzenia, próbuje wyjaśnić akt przyjęcia odwołalnej wiary w jakąś hipotezę wyjaśniającą na tej podstawie, że wyjaśnia ona niewytłumaczalny zestaw faktów. Oparte na logice podejście do wzięcia opisuje reguły wnioskowania dla wzięcia wraz z definicją ich legalnych formularzy do użytku. Podejście typu set cover definiuje abdukcyjne wyjaśnienie jako pokrycie predykatów opisujących obserwacje predykatami opisującymi hipotezy. Reggia i inni opisują pokrycie oparte na binarnej relacji przyczynowej R , gdzie R jest podzbiorem $\{\text{Hypotheses} \times \text{Observations}\}$. Zatem abdukcyjne wyjaśnienie zbioru obserwacji S_2 jest kolejnym zestawem hipotez S_1 wystarczającym do wywołania S_2 . Optymalnym wyjaśnieniem zgodnie z podejściem zestawu pokrycia jest minimalne pokrycie zestawu S_2 . Wadą tego podejścia jest to, że sprowadza ono wyjaśnienie do prostej listy hipotez przyczynowych (z S_1). W sytuacjach, w których istnieją wzajemnie powiązane lub oddziałujące przyczyny lub gdy wymagane jest zrozumienie struktury

lub sekwencjonowania interakcji przyczynowych, ustalony model pokrycia jest nieodpowiedni. Z drugiej strony, podejście do uprowadzenia oparte na logice opiera się na bardziej wyrafinowanej koncepcji wyjaśnienia. Levesque (1989) definiuje abdukcyjne wyjaśnienie jako minimalny zestaw hipotez H zgodny z podstawową wiedzą agenta K . Hipotezy H wraz z wiedzą podstawową K muszą pociągać za sobą O . Bardziej formalnie:

$\text{abduce}(K, O) = H$, wtedy i tylko wtedy, gdy

1. K nie pociąga za sobą O
2. $H \cup K$ pociąga za sobą O
3. $H \cup K$ jest zgodne, i
4. Żaden podzbiór H nie ma właściwości 1, 2 i 3.

Należy zauważyć, że ogólnie może istnieć wiele zestawów hipotez; to znaczy, może istnieć wiele potencjalnych abdukcyjnych zestawów wyjaśnień dla danego zbioru obserwacji O . Oparta na logice definicja abdukcyjnego wyjaśnienia sugeruje odpowiedni mechanizm odkrywania wyjaśnień w kontekście systemu opartego na wiedzy. Jeśli hipotezy wyjaśniające muszą pociągać za sobą obserwacje O , to sposób na skonstruowanie całości wyjaśnieniem jest wnioskowanie wstecz od O . Możemy zacząć od łącznych składników O i rozumować z powrotem od następników do ich poprzedników. To podejście z łańcuchem wstecznym wydaje się również naturalne, ponieważ warunki warunkowe, które ją wspierają, można łatwo uznać za prawa przyczynowe, co pozwala uchwycić kluczową rolę, jaką wiedza przyczynowa odgrywa w konstruowaniu wyjaśnień. Model jest również wygodny, ponieważ ładnie pasuje do czegoś, z czym już społeczność AI ma doświadczenie: backchaining i modele obliczeniowe do dedukcji. Istnieją również sprytnie sposoby na znalezienie pełnego zestawu uprowadzających wyjaśnień. Systemy podtrzymywania prawdy oparte na założeniach ATMS zawierają algorytm obliczania minimalnych zbiorów podpór, czyli zbioru (nieaksjomatów) zdań, które logicznie pociągają za sobą dane zdanie w teorii. Aby znaleźć wszystko, co możliwe dla abdukcyjnych wyjaśnień dla zbioru obserwacji, po prostu bierzemy iloczyn kartezjański przez zbiory podpór. Tak proste, precyzyjne i wygodne, jak oparte na logice ujęcie wzięcia, istnieją dwa powiązane wady: duża złożoność obliczeniowa i słabość semantyczna. Selman i Levesque stwierdzili, że złożoność zadań związanych z porwaniami jest podobna do złożoności obliczeniowych zestawów pomocniczych dla ATMS. Standardowy dowód na to, że problem ATMS jest NP-trudny, zależy od istnienia instancji problemowych z wykładniczą liczbą rozwiązań. Selman i Levesque unikają liczby potencjalnych problemów ze złożonością rozwiązań, pytając, czy znalezienie mniejszego zestawu rozwiązań jest również NP-trudne. Mając bazę wiedzy dotyczącą klauzuli Horna, Selman i Levesque tworzą algorytm, który znajduje jedno wyjaśnienie w kolejności $O(k * n)$, gdzie k wskazuje liczbę zmiennych zdaniowych, a n liczbę wystąpień literałów. Jednak gdy nakłada się ograniczenia na rodzaje poszukiwanych wyjaśnień, problem ponownie staje się NP-trudny, nawet w przypadku klauzul Horna. Jednym z interesujących wyników analizy Selmana i Levesque'a jest fakt, że dodanie pewnych rodzajów celów lub ograniczeń do zadania uprowadzenia w rzeczywistości znacznie utrudnia obliczenia. Z naiwnego punktu widzenia człowieka rozwiązującego problemy ta dodatkowa złożoność jest zaskakująca: człowiek zakłada, że dodanie dalszych ograniczeń w poszukiwaniu odpowiednich wyjaśnień ułatwia zadanie. Powodem, dla którego zadanie porwania jest trudniejsze w modelu opartym na logice, jest to, że wnosi tylko dodatkowe klauzule do problemu, a nie dodatkową strukturę przydatną do wyprowadzenia rozwiązania. Odnajdywanie wyjaśnień w modelu opartym na logice jest scharakteryzowane jako zadanie znalezienia zestawu hipotez o określonych właściwościach logicznych. Te właściwości, w tym zgodność z podstawową wiedzą i wynikanie z tego, co ma być wyjaśnione, mają na celu uchwycenie niezbędnych warunków wyjaśnień: minimalnych warunków, które musi spełnić

zestaw hipotez wyjaśniających, aby można je było uznać za wyjaśnienie uprowadzające. Zwolennicy tego podejścia uważają, że dodając dodatkowe ograniczenia, podejście można rozszerzyć, aby zapewnić scharakteryzowanie dobrych lub rozsądnych wyjaśnień. Jedną z prostych strategii tworzenia jakościowych wyjaśnień jest zdefiniowanie zestawu klauzul faktów, które są dające się porwać, to znaczy z których należy wybierać potencjalne hipotezy. Ten zestaw klauzul pozwala zawczasu ograniczyć wyszukiwanie do tych czynników, które mogą potencjalnie odgrywać rolę przyczynową w wybranej dziedzinie. Inną strategią jest dodanie kryteriów wyboru do oceny i wyboru między wyjaśnieniami. Zaproponowano różne kryteria selekcji, w tym minimalność zbioru, która preferuje jedną hipotezę nad inną, gdzie obie są spójne i pociągają za sobą to, co należy wyjaśnić, jeśli pierwsza jest zawarta w drugiej. Kryterium prostoty daje pierwszeństwo oszczędnym zestawom hipotez, zawierającym mniej niezawerifikowanych założeń. Zarówno minimalność, jak i prostota mogą być postrzegane jako zastosowania maszyny do golenia Ockhama. Niestety, minimalność zbioru ma ograniczoną moc jako narzędzie do przycinania wyszukiwania; eliminuje jedynie ostateczne wyjaśnienia, które są nadzbiorem istniejących wyjaśnień. Sama prostota jest również wątpliwa jako kryterium wyboru wyszukiwania. Nie jest trudno skonstruować przykłady, w których wyjaśnienie wymagające szerszego zestawu hipotez jest lepsze od prostszego, ale płytszego zestawu hipotez. Rzeczywiście, złożone mechanizmy przyczynowe będą zwykle wymagały większych zestawów hipotez; jednakże uprowadzenie takich mechanizmów przyczynowych może być dobrze uzasadnione, zwłaszcza gdy obecność pewnych kluczowych elementów tego mechanizmu została już zweryfikowana przez obserwację. Ciekawe są również dwa inne mechanizmy doboru wyjaśnień, ponieważ uwzględniają zarówno właściwości zestawu hipotez, jak i właściwości procedury dowodowej. Po pierwsze, uprowadzenie oparte na kosztach nakłada koszt na potencjalne hipotezy, a także na koszt reguł. Całkowity koszt wyjaśnienia oblicza się na podstawie całkowitego kosztu hipotez powiększonego o koszt reguł zastosowanych do zniesienia hipotez. Następnie porównuje się konkurencyjne zestawy hipotez pod względem kosztów. Jedną naturalną heurystyką, którą można dołączyć do tego schematu, jest heurystyka probabilistyczna. Wyższe koszty hipotez reprezentują mniej prawdopodobne zdarzenia; wyższe koszty reguł stanowią mniej prawdopodobne mechanizmy przyczynowe. Metryki oparte na kosztach można łączyć z algorytmami wyszukiwania o najniższych kosztach, takimi jak wyszukiwanie best-first, , znacznie zmniejszając złożoność obliczeniową zadania. Drugi mechanizm, selekcja oparta na koherencji, jest szczególnie interesująca, gdy to, co ma być wyjaśnione, nie jest prostym zdaniem, ale raczej zbiorem zdań. Ng i Mooney argumentowali, że miara spójności jest lepsza niż miara prostoty przy wyborze wyjaśnień w analizie tekstu w języku naturalnym. Definiują spójność jako właściwość wykresu dowodowego, w którym wyjaśnienia z większą liczbą powiązań między dowolną parą obserwacji i mniejszą liczbą rozłącznych podziałów są bardziej spójne. Kryterium spójności opiera się na heurystycznym założeniu, że to, o co nas proszono, to pojedyncze zdarzenie lub działanie o wielu aspektach. Uzasadnienie dla metryki koherencji w rozumieniu języka naturalnego opiera się na Griceańskich warunkach szczęścia, to znaczy na zobowiązaniu mówcy do bycia spójnym i trafnym. Nie jest trudno rozszerzyć ich argumentację na wiele innych sytuacji. Na przykład podczas diagnozy obserwacje, które obejmują początkowy zestaw rzeczy do wyjaśnienia, są łączone, ponieważ uważa się, że są one związane z tym samym podstawowym mechanizmem błędu lub niepowodzenia. W sekcji 9.1 rozważaliśmy rozszerzenia tradycyjnej logiki, które wspierały rozumowanie przy użyciu niepewnych lub brakujących danych. Następnie opiszemy nielogiczne alternatywy dla rozumowania w sytuacjach niepewności, w tym algebrę czynników pewności Stanforda, wnioskowanie ze zbiorami rozmytymi oraz teorię dowodów Dempstera-Shafera.

9.2 Abdukcja: alternatywa dla logiki

Podejścia oparte na logice opisane w sekcji 9.1 są uciążliwe i trudne do wykonania obliczeniowo w przypadku wielu zastosowań, zwłaszcza systemów eksperckich. Alternatywnie, kilka wczesnych

projektów systemów eksperckich, np. PROSPECTOR, próbowało zaadaptować techniki bayesowskie, do wnioskowania abdukcyjnego. Założenia dotyczące niezależności, ciągłe aktualizacje danych statystycznych oraz obliczenia wymagane do obsługi algorytmów wnioskowania stochastycznego ograniczają to podejście. Alternatywny mechanizm wnioskowania, zaprojektowany w celu złagodzenia tych ograniczeń, został użyty w Stanford do opracowania wczesnych systemów eksperckich, w tym MYCIN. Rozumując z wykorzystaniem wiedzy heurystycznej, ludzie eksperci są w stanie podać adekwatne i użyteczne szacunki ich zaufania do relacji reguł. Ludzie ważą wnioski takimi terminami, jak wysoce prawdopodobne, mało prawdopodobne, prawie na pewno lub możliwe. Te wagi oczywiście nie są oparte na dokładnej analizie prawdopodobieństw. Zamiast tego są one heurystykami wywodzącymi się z doświadczenia w rozumowaniu w dziedzinie problemowej. W sekcji 9.2 wprowadzimy trzy metodologie wnioskowania abdukcyjnego: teorię pewności Stanforda, rozumowanie rozmyte i teorię dowodów Dempstera-Shafera. W sekcji 9.3 przedstawiamy stochastyczne podejście do niepewności.

9.2.1 Algebra współczynnika pewności Stanforda

Teoria pewności Stanforda opiera się na szeregu obserwacji. Po pierwsze, w tradycyjnej teorii prawdopodobieństwa suma zaufania dla związku i ufności względem tego samego związku musi się sumować. Jednak często zdarza się, że ekspert-człowiek może mieć pewność 0,7 (z 1,0), że jakiś związek jest prawdziwy i nie ma w ogóle poczucia, że jest nieprawdziwy. Kolejnym założeniem leżącym u podstaw teorii pewności jest to, że wiedza zawarta w regułach jest znacznie ważniejsza niż algebra przy obliczaniu ufności. Miary zaufania odpowiadają nieformalnym ocenom, które ludzie eksperci dołączają do swoich wniosków, takich jak „to prawdopodobnie prawda”, „to prawie na pewno prawda” lub „jest wysoce nieprawdopodobne”. Teoria pewności ze Stanforda przyjmuje pewne proste założenia do tworzenia miar zaufania i ma kilka równie prostych reguł łączenia tych ufności, gdy program zmierza w kierunku zakończenia. Pierwszym założeniem jest rozdzielenie „zaufania dla” od „zaufania przeciwko” relacji:

Nazwij MB ($H|E$) miarą wiary w hipotezę H danym dowodem E.

Nazwij MD ($H|E$) miarą niedowierzania hipotezy H podanym dowodem E.

Teraz albo:

1 > MB ($H|E$) > 0, podczas gdy MD ($H|E$) = 0 lub

1 > MD ($H|E$) > 0, podczas gdy MB ($H|E$) = 0.

Te dwie miary ograniczają się wzajemnie, ponieważ dany dowód jest albo za, albo przeciw określonej hipotezie, co jest ważną różnicą między teorią pewności a teorią prawdopodobieństwa. Kiedy już zostanie ustalony związek między miarami wiary i niewiary, można je ponownie powiązać poprzez:

$$CF(H|E) = MB(H|E) - MD(H|E).$$

Gdy współczynnik pewności (CF) zbliża się do 1, dowody są silniejsze dla hipotezy; gdy CF zbliża się do -1, pewność wobec hipotezy staje się silniejsza; a CF około 0 wskazuje, że istnieje niewiele dowodów przemawiających za lub przeciw hipotezie lub że dowody przemawiające za i przeciw hipotezie są zrównoważone. Kiedy eksperci tworzą podstawę reguł, muszą uzgodnić CF, który będzie pasował do każdej reguły. Ten CF odzwierciedla ich zaufanie do wiarygodności reguły. Pewne miary można dostosować, aby dostroić działanie systemu, chociaż wykazano, że niewielkie zmiany miary ufności mają niewielki wpływ na cały działający system. Ta rola miar pewności utwierdza również w przekonaniu, że „wiedza daje siłę”, czyli rzetelność samej wiedzy najlepiej wspiera postawienie

prawidłowych diagnoz. Przesłanki każdej reguły składają się z i lub z szeregu faktów. Kiedy stosowana jest reguła produkcji, czynniki pewności związane z każdym warunkiem przesłanki są łączone w celu uzyskania miary pewności dla ogólnej przesłanki w następujący sposób. Dla P1 i P2 przesłanki reguły:

$$CF (P1 \text{ i } P2) = \text{MIN} (CF (P1), CF (P2)) \text{ i}$$

$$CF (P1 \text{ lub } P2) = \text{MAX} (CF (P1), CF (P2)).$$

Połączone CF przesłanek, przy użyciu powyższych reguł, jest następnie mnożone przez CF samej reguły, aby uzyskać CF dla wniosków reguły, biorąc pod uwagę te przesłanki. Na przykład rozważ regułę w bazie wiedzy:

$$(P1 \text{ i } P2) \text{ lub } P3 \rightarrow R1 (.7) \text{ i } R2 (.3)$$

gdzie P1, P2 i P3 to przesłanki, a R1 i R2 to wnioski z reguły, mające odpowiednio współczynniki CF 0,7 i 0,3. Liczby te są dodawane do reguły podczas jej projektowania i reprezentują pewność eksperta co do wniosku, jeśli wszystkie przesłanki są znane z całkowitą pewnością. Jeśli uruchomiony program wygenerował P1, P2 i P3 z wartościami CF równymi odpowiednio 0,6, 0,4 i 0,2, to R1 i R2 mogą zostać dodane do zebranych wyników specyficznych dla przypadku z wartościami CF odpowiednio 0,28 i 0,12. Oto obliczenia dla tego przykładu:

$CF (P1 (0,6) \text{ i } P2 (0,4)) = \text{MIN} (0,6; 0,4) = 0,4$. $CF ((0,4) \text{ lub } P3 (0,2)) = \text{MAX} (0,4,0,2) = 0,4$. Współczynnik CF dla R1 w regule wynosi 0,7, więc R1 jest dodawany do zbioru wiedzy specyficznej dla przypadku z powiązaniem współczynnikiem CF równym $(0,7) \times (0,4) = 0,28$. Współczynnik CF dla R2 w regule wynosi 0,3, więc R2 jest dodawany do zbioru wiedzy specyficznej dla przypadku z powiązaniem CF równym $(0,3) \times (0,4) = 0,12$. Potrzebny jest jeszcze jeden środek: jak połączyć wiele CF, gdy dwie lub więcej reguł popiera ten sam wynik R. Reguła ta odzwierciedla teorię pewności analogiczną do procedury mnożenia miar prawdopodobieństwa w celu połączenia niezależnych dowodów. Używając tej reguły wielokrotnie, można łączyć wyniki dowolnej liczby reguł używanych do określania wyniku R. Załóżmy, że CF (R1) jest obecnym współczynnikiem pewności związanym z wynikiem R, a poprzednio nieużywana reguła daje wynik R (ponownie) z CF (R2); wtedy nowy CF R jest obliczany ze wzoru: $CF (R1) + CF (R2) - (CF (R1) \times CF (R2))$, gdy CF (R1) i CF (R2) są dodatnie, $CF (R1) + CF (R2) + (CF (R1) \times CF (R2))$, gdy CF (R1) i CF (R2) są ujemne, oraz


$$CF (R1) + CF (R2) / 1 - \text{MIN} (|CF (R1)|, |CF (R2)|)$$

w przeciwnym razie, gdzie „X” jest wartością bezwzględną X. Oprócz tego, że są łatwe do obliczenia, równania te mają inne pożądane właściwości. Po pierwsze, współczynniki CF, które wynikają z zastosowania tej zasady, zawsze mieszczą się w przedziale od 1 do -1. Po drugie, wynikiem łączenia sprzecznych CF jest to, że znoszą się one nawzajem, tak jak jest to pożądane. Wreszcie, połączona miara CF jest funkcją monotonicznie rosnącą (malejącą) w sposób, jakiego można by oczekiwać w przypadku łączenia dowodów. Wreszcie, miary zaufania w tradycji czynników pewności ze Stanford są ludzkimi (subiektywnymi) oszacowaniami miar prawdopodobieństwa symptomów / przyczyn. Jak zauważono w tradycji bayesowskiej, jeśli A, B i C wszystkie wpływają na D, musimy wyodrębnić i odpowiednio połączyć wszystkie wcześniejsze i późniejsze prawdopodobieństwa, w tym $P (D)$, $P (D | A)$, $P (D | B)$, $P (D | C)$, $P (D | A, B)$ itd., Gdy chcemy uzasadnić kwestię D. Tradycja Stanford Certainty Factor pozwala inżynierowi wiedzy połączyć wszystkie te relacje w jeden czynnik zaufania, CF, dołączony do zasady; to znaczy, jeśli A, B i C, to D (CF). Niewątpliwie ta prosta algebra lepiej odzwierciedla sposób, w jaki eksperci-ludzie łączą i propagują wiele zestawów przekonań. Teoria pewności może być krytykowana jako nadmiernie ad hoc. Chociaż jest zdefiniowane w formalnej algebrze, znaczenie miar pewności nie jest tak rygorystycznie ugruntowane, jak formalna teoria prawdopodobieństwa. Jednak teoria


pewności nie próbuje stworzyć algebry dla „poprawnego” rozumowania. Raczej to „smarowanie” pozwala systemowi eksperckiemu łączyć zwierzenia, gdy porusza się w przestrzeni poszukiwań. Jego pomiary są ad hoc w tym samym sensie, w jakim zaufanie eksperta będącego człowiekiem do jego wyników jest przybliżone, heurystyczne i nieformalne. Kiedy MYCIN jest uruchomiony, CF są używane w wyszukiwaniu heurystycznym, aby nadać priorytet celom do osiągnięcia i punkt odcięcia, kiedy cel nie musi być dalej rozważany. Ale nawet jeśli CF jest używany do utrzymania działania programu i zbierania informacji, siła programu pozostaje zainwestowana w jakość reguł.

9.2.2 Rozumowanie z użyciem zbiorów rozmytych


Istnieją dwa założenia, które są niezbędne do zastosowania formalnej teorii mnogości. Pierwsza odnosi się do przynależności do zbioru: dla dowolnego elementu i zbioru należącego do jakiegoś wszechświata, element jest albo członkiem zbioru, albo jest członkiem dopełnienia tego zbioru. Drugie założenie, zwane prawem wyłącznego środka, głosi, że element nie może należeć zarówno do zbioru, jak i do jego uzupełnienia. Oba te założenia zostały naruszone w teorii zbiorów rozmytych Lotfi Zadeha. W rzeczywistości zbiory i prawa rozumowania tradycyjnej teorii mnogości są określane jako ostre, z rozmytego punktu widzenia zbiorów. Głównym argumentem Zadeha jest to, że chociaż teoria prawdopodobieństwa tak jest odpowiedni do mierzenia losowości informacji, jest odpowiedni do pomiaru znaczenia informacji. Rzeczywiście, wiele nieporozumień związanych ze stosowaniem angielskich słów i zwrotów jest związanych raczej z brakiem jasności (niejasności) niż z przypadkowością. Jest to kluczowy punkt do analizy struktur językowych i może być również ważny w tworzeniu miary zaufania do reguł produkcji. Zadeh proponuje teorię możliwości jako miarę niejasności, tak jak teoria prawdopodobieństwa mierzy losowość. Teoria Zadeha wyraża brak precyzji w sposób ilościowy, wprowadzając funkcję przynależności do zbioru, która może przyjmować wartości rzeczywiste od 0 do 1. Pojęcie zbioru rozmytego można opisać następująco: niech S będzie zbiorem i s członkiem tego zbioru. Rozmyty podzbiór F z S jest zdefiniowany przez funkcję przynależności $m_F(s)$, która mierzy „stopień” do którego s należy do F . Standardowy przykład zbioru rozmytego, jak pokazano na rysunku 6, polega na tym, że S jest zbiorem dodatnich liczb całkowitych, a F jest rozmytym podzbiorem S , zwanym małymi liczbami całkowitymi.



Teraz różne wartości całkowite mogą mieć „możliwość” rozkładu określającego ich „rozmyte członkostwo” w zbiorze małych liczb całkowitych: $m_F(1) = 1,0$, $m_F(2) = 1,0$, $m_F(3) = 0,9$, $m_F(4) = 0,8$, ..., $m_F(50) = 0,001$ itd. Dla stwierdzenia, że dodatnia liczba całkowita X jest małą liczbą całkowitą, m_F tworzy rozkład możliwości na wszystkie dodatnie liczby całkowite (S). Teoria zbiorów rozmytych nie zajmuje się sposobem tworzenia tych rozkładów możliwości, ale raczej regułami obliczania połączonych możliwości dla wyrażeń, które zawierają zmienne rozmyte. W związku z tym zawiera zasady łączenia miar możliwości dla wyrażeń zawierających zmienne rozmyte; w rzeczywistości prawa dla or , i , a nie tych wyrażeń są podobne do tych właśnie przedstawionych dla algebry współczynników pewności Stanforda; W przypadku rozmytej reprezentacji zbioru małych liczb całkowitych, każda liczba całkowita należy do tego zbioru z powiązaną miarą ufności. W tradycyjnej logice zbiorów „ostrych”, pewność elementu będącego w zbiorze musi wynosić 1 lub 0. Rysunek 7 przedstawia funkcję przynależności do zbioru dla pojęcia niskiego, średniego i wysokiego mężczyzny.




Zwróć uwagę, że każda osoba może należeć do więcej niż jednego zestawu, na przykład samiec 5 '9 "należy zarówno do zbioru średnich, jak i wysokich samców. Następnie pokażemy zasady łączenia i propagowania miar rozmytych przez przedstawianie części problemu, obecnie klasyczna w literaturze dotyczącej zbiorów rozmytych, reżim sterowania dla odwróconego wahadła. Rysunek 8 przedstawia wahadło, odwrócone, które chcemy zachować w równowadze i skierowane do góry.




Utrzymujemy wahadło w równowadze, przesuując podstawę układu, aby zrównoważyć siłę grawitacji działającą na wahadło. Istnieją zestawy równań różniczkowych, które mogą deterministycznie utrzymywać wahadło w równowadze. Zaletą rozmytego podejścia do sterowania tym układem wahadła jest to, że można ustalić algorytm do wydajnego sterowania systemem w czasie rzeczywistym. Następnie opiszemy ten reżim kontroli. Upraszczamy problem wahadła, przedstawiając go w dwóch wymiarach. Te dwa pomiary są używane jako wartości wejściowe do sterownika. Po pierwsze, kąt θ , odchylenie wahadła od pionu, a po drugie, prędkość $d\theta / dt$, z jaką porusza się wahadło. Obie te miary są dodatnie w kwadrancie po prawej stronie od pionu i ujemne po lewej stronie. Te dwie wartości są przekazywane do kontrolera rozmytego w każdej iteracji systemu. Sygnał wyjściowy kontrolera to ruch i kierunek podstawy systemu, instrukcje mające na celu utrzymanie równowagi wahadła. Aby wyjaśnić działanie kontrolera rozmytego, opisujemy proces rozwiązania zbioru rozmytego. Dane opisujące stan wahadła, θ i $d\theta / dt$, są interpretowane jako miary rozmyte i przedstawiane w zestawie reguł rozmytych. Ten krok jest często bardzo wydajny dzięki zastosowaniu struktury zwanej rozmytą macierzą asocjacyjną lub FAM, rysunek 9.12, gdzie relacje wejścia / wyjścia są kodowane bezpośrednio. Reguły nie są ze sobą powiązane, jak w przypadku tradycyjnego rozwiązywania problemów opartego na regułach. Zamiast tego wszystkie dopasowane reguły uruchamiają się, a ich wyniki są łączone. Wynik ten, zwykle reprezentowany przez obszar rozmytej przestrzeni parametrów wyjściowych, rysunek 9.10, jest następnie usuwany w celu zwrócenia odpowiedzi sterującej. Zauważ, że zarówno oryginalne wejście, jak i ostateczne wyjście kontrolera są wyraźnymi wartościami. Są to dokładne odczyty niektórych monitorów, wejść i precyzyjnych instrukcji dotyczących działań kontrolnych, wyjścia. Następnie opiszemy rozmyte regiony dla wartości wejściowych, θ i $d\theta / dt$. Przykład ten upraszcza sytuację np. W ilości rozmytych obszarów wartości wejściowych, ale pokazuje pełny cykl stosowania reguły i reakcję kontrolera. Wartość wejściowa θ jest podzielona na trzy obszary, Ujemny, Zero i Dodatni, gdzie θ mieści się w zakresie od -2 do +2 radianów, jak widać na rysunku.9a. Rysunek 9b


przedstawia trzy obszary, na które podzielona jest druga wartość wejściowa, $d\theta / dt$, ponownie ujemna, zero i dodatnia, w zakresie od -5 do +5 stopni na sekundę.



Rysunek 10 przedstawia podział przestrzeni wyjściowej, w którym używamy środkowych pięciu regionów, Negative Big, Negative, Zero, Positive i Positive Big. Miara między -24 a +24 reprezentuje ruch i kierunek każdej odpowiedzi.



Założmy, że rozpoczyna się symulacja i pierwsze wartości podane kontrolerowi to $\theta = 1$ i $d\theta / dt = -4$. Rysunek 11 odzwierciedla fuzyfikację tych miar wejściowych.



W każdej sytuacji wartość wejściowa wpływa na dwa obszary rozmytej przestrzeni wejściowej. Dla θ wartości wynoszą zero, przy 0,5 i dodatnie, przy 0,5 miarach możliwości. Dla $d\theta / dt$ są one Ujemne przy 0,8 i Zero przy 0,2 miarach możliwości. Rysunek12 przedstawia uproszczoną postać rozmytej macierzy asocjacyjnej dla tego problemu.

x_2	P	Z	N
P	PB	P	Z
Z	P	Z	N
N	Z	N	NB

Wartości wejściowe do tabeli dla θ lub x_1 znajdują się po lewej stronie, a dla $d\theta / dt$ lub x_2 znajdują się w górnej części macierzy. W takim razie tabela 3×3 w prawym dolnym rogu FAM podaje wartości wyjściowe. Na przykład, jeśli θ jest dodatnie, a $d\theta / dt$ jest ujemne, funkcja FAM zwraca wartość zerowego ruchu układu wahadła. Zwróć uwagę, że odpowiedź nadal musi zostać rozszyfrowana przy użyciu obszaru wyjściowego Zero z rysunku 10. W takim przypadku, ponieważ każda wartość wejściowa dotyczy dwóch obszarów przestrzeni wejściowej, należy zastosować cztery reguły. Jak wspomniano powyżej, reguły kombinacji dla układów rozmytych są podobne do reguł algebry współczynników pewności ze Stanford. W rzeczywistości Zadeh był pierwszym (historycznie), który zaproponował te reguły kombinacji dla algebry rozumowania rozmytego. Jeśli miary dwóch pomieszczeń są połączone operatorem AND, to minimum ich miar jest traktowane jako miara reguły. Jeśli dwa lokale są połączone, podejmowane są maksymalne środki. W naszym przykładzie wszystkie pary przesłanek są połączone operatorem AND, więc minimum ich miar jest traktowane jako miara wyniku reguły:

IF $x_1 = P$ AND $x_2 = Z$ THEN $u = P$

$\min(0.5, 0.2) = 0.2 P$

IF $x_1 = P$ AND $x_2 = N$ THEN $u = Z$

$\min(0.5, 0.8) = 0.5 Z$


IF $x_1 = Z$ AND $x_2 = Z$ THEN $u = Z$

$\min(0.5, 0.2) = 0.2 Z$


IF $x_1 = Z$ AND $x_2 = N$ THEN $u = N$

$\min(0.5, 0.8) = 0.5 N$.

Następnie łączone są wyniki wyjściowe. W tym przykładzie łączymy razem dwa obszary z rysunku 10, wskazane przez wyniki tego zestawu dwóch reguł strzelania. Istnieje wiele możliwych technik defuzyfikacji. Wybraliśmy jedną z najpopularniejszych, metodę centroidu. Aby użyć tej metody, środek ciężkości sumy pól wartości wyjściowych staje się wartością końcową, którą regulator przykładu do wahadła. Związek, jak również środek ciężkości związku, przedstawiono na rysunku 13.



a.



b.

Po zastosowaniu tego wyjścia lub wyniku do systemu, θ i $d\theta / dt$ są ponownie próbkowane i cykl kontrolny jest powtarzany. Istnieje wiele problemów, którymi nie zajęliśmy się przy opisywaniu systemów rozumowania rozmytego, w tym wzorce oscylacji w procesie konwergencji i optymalne częstotliwości próbkowania. Systemy rozmyte, szczególnie w dziedzinie sterowania, oferują inżynierom potężne i wydajne narzędzie do radzenia sobie z nieprecyzyjnymi pomiarami.

9.2.3 Teoria dowodów Dempstera-Shafera

Do tego momentu w naszej dyskusji na temat rozumowania w warunkach niepewności opisaaliśmy techniki, które uwzględniają indywidualne zdania i przypisują każdemu wpływ przyczynowy lub liczbową ocenę stopnia przekonania, jaki moglibyśmy mieć, mając dane zestawy dowodów. Jednym z ograniczeń probabilistycznych podejść do niepewności jest użycie jednej wielkości do pomiaru sytuacji, która może być bardzo złożona. Często niepewność wynika z kombinacji brakujących dowodów, nieodłącznych ograniczeń reguł heurystycznych oraz ograniczeń naszej własnej wiedzy. Alternatywne podejście, zwane teorią dowodów Dempstera-Shafera, rozważa zbiory zdań i przypisuje każdemu z nich przedział [przekonanie, prawdopodobieństwo], w którym musi znajdować się stopień przekonania dla każdego zdania. Ta miara wiary, oznaczona bel , waha się od zera, co wskazuje na brak dowodów na poparcie zbioru zdań, do jednego, co oznacza pewność. Wiarygodność zdania p , $pl(p)$, jest określona:

$$pl(p) = 1 - bel(\text{not}(p))$$

Zatem prawdopodobieństwo waha się również od zera do jednego i odzwierciedla, w jaki sposób dowód braku (p) odnosi się do możliwości wiary w p . Jeśli mamy pewne dowody na to, że nie (p), to $bel(\text{not}(p))$ będzie równe jeden, a $pl(p)$ będzie równe zero. Jedyną możliwą wartością $bel(p)$ jest również zero. Załóżmy, że mamy dwie konkurujące hipotezy h_1 i h_2 . Kiedy nie mamy informacji

popierając obie hipotezy, każda z nich ma zakres przekonania / prawdopodobieństwa $[0,1]$. W miarę gromadzenia dowodów spodziewamy się, że te przedziały się skracają, co stanowi wzrost wiarygodności hipotez. W domenie bayesowskiej prawdopodobnie zaczęlibyśmy (bez dowodów) równo rozdzielić wcześniejsze prawdopodobieństwa między dwie hipotezy, dając każdej, powiedzmy, $p(h_i) = 0,5$. Dempster – Shafer wyjaśnia, że nie mamy żadnych dowodów, kiedy zaczynamy; z drugiej strony podejście bayesowskie może skutkować taką samą miarą prawdopodobieństwa, niezależnie od tego, ile mamy danych. Zatem Dempster – Shafer może być bardzo przydatny, gdy jest ważne, aby podjąć decyzję na podstawie ilości zebranych dowodów. Podsumowując, Dempster i Shafer zajmują się problemem pomiaru pewności, dokonując fundamentalnego rozróżnienia między brakiem pewności a ignorancją. W teorii prawdopodobieństwa jesteśmy zmuszeni wyrazić zakres naszej wiedzy na temat hipotezy h za pomocą jednej liczby $p(h)$. Problem z tym podejściem, mówią Dempster i Shafer, polega na tym, że po prostu nie zawsze możemy znać wartości jego potwierdzających prawdopodobieństw, a zatem jakkolwiek konkretny wybór $p(h)$ może nie być uzasadniony. Funkcje przekonania Dempstera – Shafera spełniają aksjomaty słabsze niż te z teorii prawdopodobieństwa, to znaczy redukują się do teorii prawdopodobieństwa, gdy wszystkie prawdopodobieństwa są osiągalne. Funkcje wiary pozwalają nam wykorzystać naszą wiedzę do powiązania przypisania prawdopodobieństw zdarzeniom w przypadku braku dokładnych prawdopodobieństw. Teoria Dempstera – Shafera opiera się na dwóch ideach: po pierwsze, na idei uzyskiwania stopni przekonania dla jednego pytania z subiektywnych prawdopodobieństw dla pytań pokrewnych, a po drugie, na zastosowaniu reguły do łączenia tych stopni przekonania, gdy są one dowody. Ta reguła kombinacji została pierwotnie zaproponowana przez Dempstera. Następnie przedstawiamy nieformalny przykład rozumowania Dempstera-Shafera, następnie odrzucamy zasadę Dempstera i na koniec stosujemy tę regułę do bardziej realistycznej sytuacji. Załóżmy, że mam subiektywne prawdopodobieństwo wiarygodności mojej przyjaciółki Melissy. Prawdopodobieństwo, że jest wiarygodna wynosi 0,9, a niewiarygodna, 0,1. Przypuśćmy, że Melissa powie mi, że włamano się do mojego komputera. To stwierdzenie jest prawdziwe, jeśli Melissa jest wiarygodna, ale niekoniecznie jest fałszywe, jeśli jest niewiarygodna. Tak więc zeznanie Melissy w pewnym stopniu uzasadnia 0,9 przekonania, że włamano się do mojego komputera i 0,0 przekonania, że tak nie jest. Przekonanie o wartości 0,0 nie oznacza, że jestem pewien, że mój komputer nie został włamany, ponieważ prawdopodobieństwo wynosi 0,0. Oznacza to po prostu, że zeznania Melissy nie dają mi powodu, by sądzić, że mój komputer nie został włamany. Miarą prawdopodobieństwa, p_l , w tej sytuacji jest:

$p_l(\text{computer_broken_into}) = 1 - \text{bel}(\text{not}(\text{computer_broken_into})) = 1 - 0,0$ lub $1,0$, a moją miarą wiary dla zeznań Melissy jest $[0,9 \ 1,0]$. Zwróć uwagę, że nadal nie ma dowodów na to, że mój komputer nie został włamany. Następnie rozważymy regułę Dempstera dotyczącą łączenia dowodów. Przypuśćmy, że mój przyjaciel Bill również mi powie, że włamano się do mojego komputera. Załóżmy, że prawdopodobieństwo, że Bill jest wiarygodny, wynosi 0,8, a niewiarygodnego, wynosi 0,2. Muszę również przypuszczać, że zeznania Billa i Melissy na temat mojego komputera są od siebie niezależne; to znaczy mają oddzielne powody, by mi powiedzieć, że ich zdaniem włamano się do mojego komputera. Fakt, że Bill jest wiarygodny, musi być również niezależny od wiarygodności Melissy. Prawdopodobieństwo, że zarówno Bill, jak i Melissa są wiarygodni, jest iloczynem ich rzetelności, czyli 0,72; prawdopodobieństwo, że oba są niewiarygodne, wynosi 0,02. Prawdopodobieństwo, że przynajmniej jeden z nich jest wiarygodny, wynosi $1 - 0,02$ lub 0,98. Ponieważ obaj powiedzieli, że włamano się do mojego komputera i istnieje prawdopodobieństwo 0,98, że przynajmniej jeden z nich jest niezawodny, przypiszę zdarzeniu włamania do mojego komputera na $[0,98 \ 1,0]$ stopień wiary. Załóżmy, że Bill i Melissa nie zgadzają się co do tego, czy włamano się do mojego komputera: Melissa mówi, że tak, a Bill mówi, że tak nie jest. W tym przypadku nie mogą one jednocześnie być poprawne i nie mogą być jednocześnie wiarygodne. Albo są niewiarygodne, albo tylko jeden jest niezawodny.

Wcześniejsze prawdopodobieństwo, że tylko Melissa jest wiarygodna, wynosi $0,9 \times (1 - 0,8) = 0,18$, że tylko Bill jest wiarygodny, wynosi $0,8 \times (1 - 0,9) = 0,08$, a żadne z nich nie wynosi $0,2 \times 0,1 = 0,02$. Biorąc pod uwagę, że co najmniej jeden nie jest wiarygodny ($0,18 + 0,08 + 0,02$) = 0,28, możemy również obliczyć prawdopodobieństwo późniejsze, że tylko Melissa jest wiarygodna jako $0,18 / 0,28 = 0,643$, a mój komputer został włamany, lub prawdopodobieństwo późniejsze, że tylko Bill miał rację, $0,08 / 0,28 = 0,286$, a mój komputer nie został włamany. Właśnie użyliśmy reguły Dempstera, aby połączyć przekonania. Kiedy Melissa i Bill zgłosili włamanie do komputera, zsumowaliśmy trzy hipotetyczne sytuacje, które wsparły włamanie: Bill i Melissa są wiarygodni; Bill jest godny zaufania, a Melissa nie; i Melissa jest wiarygodna, a Bill nie. Przekonanie, 0,98, było sumą tych możliwych wspierających hipotetycznych scenariuszy. Przy drugim zastosowaniu reguły Dempstera świadkowie nie zgodzili się. Ponownie podsumowaliśmy wszystkie możliwe scenariusze. Jedyną niemożliwą sytuacją było to, że obaj byli wiarygodni; tak więc albo Melissa była wiarygodna, a Bill nie, Bill był godny zaufania, a Melissa nie, albo też żaden nie był wiarygodny. Suma tych trzech daje prawdopodobieństwo włamania 0,64. Przekonanie, że mój komputer nie został włamany (zdaniem Billa), wynosiło 0,286; ponieważ prawdopodobieństwo włamania wynosi 1 - bel (nie (włamanie)) lub 0,714, miarą przekonania jest $[0,286, 0,714]$. Aby zastosować regułę Dempstera, uzyskujemy stopnie wiary dla jednego pytania (Czy włamano się do mojego komputera?) z prawdopodobieństwa dla innego pytania (Czy świadkowie są wiarygodni?). Reguła zaczyna się od założenia, że pytania, dla których mamy prawdopodobieństwa, są niezależne, ale ta niezależność jest tylko a priori. Znika, gdy mamy konflikt między różnymi dowodami. Zastosowanie podejścia Dempstera – Shafera w określonej sytuacji wiąże się z rozwiązaniem dwóch powiązanych problemów. Po pierwsze, dzielimy niepewność sytuacji na niezależne dowody a priori. Po drugie, realizujemy regułę Dempstera. Te dwa zadania są ze sobą powiązane: Przypuśćmy znowu, że Bill i Melissa powiedzieli mi niezależnie, że wierzyli, że włamano się do mojego komputera. Przypuśćmy również, że zadzwoniłem do osoby zajmującej się naprawami, aby sprawdzić mój komputer i że zarówno Bill, jak i Melissa byli tego świadkami. Z powodu tego powszechnego zdarzenia nie mogę już porównywać stopni przekonania. Jeśli jednak wyraźnie rozważę możliwość pracy osoby naprawiającej na moim komputerze, to mam trzy niezależne dowody: wiarygodność Melissy, wiarygodność Billa oraz dowody na obecność osoby naprawiającej, które mogą następnie połączyć z regułą Dempstera. Założmy, że mamy wyczerpujący zestaw wzajemnie wykluczających się hipotez, które nazywamy Q. Naszym celem jest dołączenie pewnej miary przekonania, m, do różnych podzbiorów Z Q; m jest czasami nazywane funkcją gęstości prawdopodobieństwa dla podzbioru Q. Realistycznie rzecz biorąc, nie wszystkie dowody bezpośrednio potwierdzają poszczególne elementy Q. W rzeczywistości dowody najczęściej wspierają różne podzbiory Z z Q. Ponadto, ponieważ elementy Q są zakładając, że wzajemnie się wykluczają, dowody na korzyść niektórych mogą mieć wpływ na naszą wiarę w innych. W systemie czysto bayesowskim, w sekcji 9.3, zajmujemy się obydwoma tymi sytuacjami, wymieniając wszystkie kombinacje prawdopodobieństw warunkowych. W systemie Dempster – Shafer radzimy sobie z tymi interakcjami poprzez bezpośrednie manipulowanie zestawami hipotez. Wielkość $m_n(Z)$ mierzy ilość przekonania przypisanego do podzbioru Z hipotez, a reprezentuje liczbę źródeł dowodów. Reguła Dempstera mówi:

$$m_n(Z) = \frac{\sum_{X \cap Y = Z} m_{n-2}(X) m_{n-1}(Y)}{1 - \sum_{X \cap Y = \emptyset} m_{n-2}(X) m_{n-1}(Y)}$$

Na przykład wiara w hipotezę Z, przy $n = 3$ źródłach dowodu, $m_3(Z)$, jest sumą iloczynów sytuacji hipotetycznych $m_1(X)$ i $m_2(Y)$, których współwystępowanie wspiera Z, to znaczy $X \cap Y = Z$. Mianownik reguły Dempstera uznaje, jak widać w poniższym przykładzie, że X i Y mogą mieć puste przecięcie, a suma ufności musi być znormalizowana o jeden minus suma te wartości. Następnie stosujemy regułę

Dempstera do sytuacji diagnozy medycznej. Załóżmy, że Q reprezentuje domenę naszego zainteresowania, zawierającą cztery hipotezy: że pacjent ma przeziębienie (C), grypę (F), migrenowe bóle głowy (H) lub zapalenie opon mózgowych (M). Naszym zadaniem jest powiązanie miar przekonania z zestawami hipotez w Q . Jak już wspomniano, są to zestawy hipotez, ponieważ dowody nie muszą wspierać wyłącznie indywidualnych hipotez. Na przykład gorączka może wspomóc {C, F, M}. Ponieważ elementy Q są traktowane jako wzajemnie wykluczające się hipotezy, dowody na korzyść niektórych mogą wpływać na wiarę w innych. Jak już wspomniano, podejście Dempstera – Shafera odnosi się do interakcji poprzez bezpośrednie obsługiwane zestawów hipotez.

Dla funkcji gęstości prawdopodobieństwa m i wszystkich podzbiorów Z zbioru Q wielkość $m(q_i)$ reprezentuje przekonanie, które jest obecnie przypisane do każdego q_i z Q z sumą wszystkich $m(q_i)$ równą jeden. Jeśli Q zawiera n elementów, to istnieją 2^n podzbiory Q . Chociaż adresowanie 2^n wartości może wydawać się zniechęcające, zwykle okazuje się, że wiele podzbiorów nigdy nie wystąpi. W związku z tym istnieje pewne uproszczenie procesu rozwiązywania, ponieważ wartości te można zignorować, ponieważ nie mają one użyteczności w dziedzinie problemu. Wreszcie wiarygodność Q to $pl(Q) = 1 - \sum m(q_i)$, gdzie q_i to zbiory hipotez, które mają pewne przekonanie wspierające. Jeśli nie mamy informacji o jakichkolwiek hipotezach, jak to często bywa, kiedy rozpoczynamy diagnozę, to $pl(Q) = 1,0$. Załóżmy, że pierwszym dowodem jest to, że nasz pacjent ma gorączkę i to potwierdza {C, F, M} na poziomie 0,6. Nazywamy to pierwsze przekonanie m_1 . Jeśli jest to nasza jedyna hipoteza, to $m_1\{C, F, M\} = 0,6$, gdzie $m_1(Q) = 0,4$, aby uwzględnić pozostałą dystrybucję przekonania. Należy zauważyć, że $m_1(Q) = 0,4$ reprezentuje pozostałą część naszego rozkładu przekonania, to znaczy wszystkie inne możliwe przekonania w Q , a nie naszą wiarę w dopełnienie {C, F, M}. Załóżmy, że mamy teraz jakieś nowe dane do naszej diagnozy, powiedzmy, że pacjent ma silne nudności, co sugeruje {C, F, H} z poziomem wsparcia 0,7. Dla tego przekonania nazwijmy go m_2 , mamy $m_2\{C, F, H\} = 0,7$ i $m_2(Q) = 0,3$. Używamy reguły Dempstera, aby połączyć te dwa przekonania, m_1 i m_2 . Niech X będzie zbiorem podzbiorów Q , którym m_1 przypisuje wartość różną od zera, a Y będzie zbiorem podzbiorów Q , którym m_2 przypisuje wartość niezerową. Następnie tworzymy przekonanie złożone, m_3 zdefiniowane w podzbiórach Z z Q przy użyciu reguły Dempstera. Stosując regułę Dempstera do diagnoz, najpierw zwróć uwagę, że nie ma zbiorów $X \cap Y$, które byłyby puste, więc mianownikiem jest 1. Rozkład przekonania dla m_3 przedstawiono w tabeli 1.

m_1	m_2	m_3
$m_1\{C,F,M\} = 0.6$	$m_2\{C,F,H\} = 0.7$	$m_3\{C,F\} = 0.42$
$m_1(Q) = 0.4$	$m_2\{C,F,H\} = 0.7$	$m_3\{C,F,H\} = 0.28$
$m_1\{C,F,M\} = 0.6$	$m_2(Q) = 0.3$	$m_3\{C,F,M\} = 0.18$
$m_1(Q) = 0.4$	$m_2(Q) = 0.3$	$m_3(Q) = 0.12$

Używając reguły Dempstera, cztery zbiory Z , wszystkie możliwe sposoby przecięcia X i Y , tworzą skrajną prawą kolumnę tabeli 1. Ich poziom przekonania jest obliczany przez pomnożenie przekonania dla odpowiednich elementów X i Y odpowiednio pod m_1 i m_2 . Należy również zauważyć, że w tym przykładzie każdy zestaw w Z jest unikalny, co często nie ma miejsca. Rozszerzamy nasz przykład po raz ostatni, aby pokazać, w jaki sposób puste zestawy przekonania są uwzględniane w analizie. Załóżmy, że mamy nowy fakt, wyniki hodowli laboratoryjnej, które są związane z zapaleniem opon mózgowych. Mamy teraz $m_4\{M\} = 0,8$ i $m_4(Q) = 0,2$. Możemy użyć wzoru Dempstera, aby połączyć m_3 , wyniki naszej poprzedniej analizy, z m_4 , aby otrzymać m_5 , jak widać w tabeli 2.

m_3	m_4	m_5 (without denominator)
$m_3\{C,F\} = 0.42$	$m_4\{M\} = 0.8$	$m_5\{\} = 0.336$
$m_3\{Q\} = 0.12$	$m_4\{M\} = 0.8$	$m_5\{M\} = 0.096$
$m_3\{C,F\} = 0.42$	$m_4\{Q\} = 0.2$	$m_5\{C,F\} = 0.084$
$m_3\{Q\} = 0.12$	$m_4\{Q\} = 0.2$	$m_5\{Q\} = 0.024$
$m_3\{C,F,H\} = 0.28$	$m_4\{M\} = 0.8$	$m_5\{\} = 0.224$
$m_3\{C,F,M\} = 0.18$	$m_4\{M\} = 0.8$	$m_5\{M\} = 0.144$
$m_3\{C,F,H\} = 0.28$	$m_4\{Q\} = 0.2$	$m_5\{C,F,H\} = 0.056$
$m_3\{C,F,M\} = 0.18$	$m_4\{Q\} = 0.2$	$m_5\{C,F,M\} = 0.036$

Po pierwsze, zauważ, że $m_5\{M\}$ jest tworzone przez przecięcia dwóch różnych par zbiorów, więc suma $m_5\{M\} = 0,240$. Mamy również przypadek, w którym kilka przecięć zbiorów daje pusty zbiór $\{\}$. Zatem mianownik równania Dempstera to $1 - (0,336 + 0,224) = 1 - 0,56 = 0,44$. Ostateczna połączona funkcja przekonań dla m_5 to:

$m_5\{M\} = 0.545$	$m_5\{C,F\} = 0.191$	$m_5\{\} = 0.56$
$m_5\{C,F,H\} = 0.127$	$m_5\{C,F,M\} = 0.082$	$m_5\{Q\} = 0.055$

Trzy uwagi końcowe. Po pierwsze, duże przekonanie przypisane do pustego zbioru, jak w tym końcowym $m_5\{\} = 0,56$, wskazuje, że istnieją sprzeczne dowody w zestawie przekonań m_i . W rzeczywistości zaprojektowaliśmy nasz przykład tak, aby pokazać kilka cech rozumowania Dempstera-Shafera, a w konsekwencji poświęcić rzetelność medyczną. Po drugie, gdy istnieją duże zestawy hipotez, a także złożone zbiory dowodów, obliczenia dla zestawów przekonań mogą stać się kłopotliwe, mimo że, jak wskazano wcześniej, ilość obliczeń jest nadal znacznie mniejsza niż w przypadku rozumowania bayesowskiego. Wreszcie podejście Dempstera – Shafera jest bardzo przydatnym narzędziem, gdy silniejsze założenia bayesowskie mogą nie być uzasadnione. Dempster – Shafer jest przykładem algebry wspierającej użycie prawdopodobieństwa subiektywnego w rozumowaniu. Czasami wydaje się, że te subiektywne prawdopodobieństwa lepiej odzwierciedlają rozumowanie eksperta.


9.3 Stochastyczne podejście do niepewności

Korzystając z teorii prawdopodobieństwa, możemy określić, często z argumentu a priori, szanse zaistnienia zdarzeń. Możemy również opisać, jak kombinacje zdarzeń mogą na siebie wpływać. Chociaż ostatecznie poprawki teorii prawdopodobieństwa czekały na matematyków początku XX wieku, w tym Fishera, Neymana i Pearsona, próba stworzenia algebry kombinatorycznej sięga średniowiecza do Greków, w tym Llulla, Porfiry'ego i Platona. Wgląd wspierający teorię prawdopodobieństwa jest taki, że jeśli potrafimy zrozumieć częstotliwość, z jaką zdarzenia miały miejsce w przeszłości, możemy wykorzystać te informacje (jako błąd indukcyjny) do interpretacji i wnioskowania na temat obecnych danych. W Części 5 zauważyliśmy, że istnieje wiele sytuacji, w których analiza probabilistyczna jest odpowiednia. Na przykład, gdy świat jest naprawdę losowy, jak podczas gry z dobrze wymieszanymi kartami lub kręcenia uczciwym kołem ruletki. Co więcej, kiedy wiele wydarzeń na świecie może nie być naprawdę przypadkowych, ale niemożliwe jest poznanie i zmierzenie wszystkich ich przyczyn i interakcji na tyle dobrze, aby przewidzieć zdarzenia; korelacje statystyczne są użytecznym wsparciem w interpretacji świata. Kolejną rolą statystyki jest podstawa automatycznej indukcji i uczenia maszynowego (na przykład algorytm ID3 z sekcji 10.3). Wreszcie w ostatnich pracach podjęto próbę bezpośredniego połączenia pojęć prawdopodobieństwa i przyczynowości. Podstawowym

mechanizmem wnioskowania w domenach stochastycznych jest pewna forma reguły Bayesa. Jak jednak zauważyliśmy, pełne wykorzystanie wnioskowania bayesowskiego w domenach złożonych szybko staje się trudne do opanowania. Probabilistyczne modele graficzne są specjalnie zaprojektowane w celu rozwiązania tej złożoności. Probabilistyczne modele graficzne to „... małżeństwo między teorią prawdopodobieństwa i teorią grafów”. Probabilistyczne modele graficzne stają się również coraz ważniejsze w uczeniu maszynowym (Część 13), ponieważ mogą rozwiązywać problemy niepewności i złożoności, które są obecne i mogą być fundamentalnie ograniczające dla współczesnej sztucznej inteligencji. Jordan zwraca uwagę, że problem modułowości jest kamieniem węgielnym modułów graficznych: proste części modelu są łączone ze sobą za pomocą teorii prawdopodobieństwa, która wspiera spójność systemu jako całości i jednocześnie integruje model graficzny z danymi wniosek (Jordan 1999). Jednocześnie teoria grafów oferuje modele graficzne zarówno jako intuicyjny sposób przedstawiania wysoce oddziałujących zestawów komponentów, jak i strukturę danych, która wspiera wydajne algorytmy wnioskowania. Rozważymy dwa typy probabilistycznych modeli graficznych: ukierunkowane, bayesowskie sieci przekonań i różne formy modeli Markowa oraz nieukierunkowane drzewa klikowe i pola losowe Markowa. Pola Markowa i inne niekierowane modele graficzne są w stanie przedstawić wiele cyklicznych zależności, których nie można przedstawić za pomocą skierowanych grafów. Z drugiej strony sieci przekonań bayesowskich są ukierunkowanymi modelami graficznymi, które są w stanie uchwycić niejawnie wywnioskowane związki i zależności dokładniej i wydajniej niż w przypadku niekierowanych modeli graficznych. W następnych sekcjach przedstawiamy sieci przekonań bayesowskich i kilka technik wnioskowania zaprojektowanych specjalnie w celu rozwiązania złożoności obliczeniowej grafów nieukierunkowanych i / lub pełnego rozumowania bayesowskiego. Później, w sekcji 9.3.5, wprowadzimy procesy Markowa i wspomnimy o kilku ważnych odmianach reprezentacyjnych. Jedną z nich jest dynamiczna sieć bayesowska, a drugą dyskretny proces Markowa. Jednym z głównych ograniczeń BBN i tradycyjnych HMM jest ich wrodzona propozycja. Aby rozwiązać ten problem, podjęto kilka prób połączenia logiki przyimkowej, pełnego rachunku predykatów opartego na zmiennych; z probabilistycznymi modelami graficznymi. Podsumujemy kilka z tych wysiłków w sekcji 9.3.7, a systemy probabilistyczne pierwszego rzędu ponownie omówimy w Części 13.

9.3.1 Ukierunkowany model graficzny: Bayesowska sieć przekonań

Chociaż Bayesowska teoria prawdopodobieństwa, oferuje matematyczną podstawę do wnioskowania w niepewnych warunkach, złożoność napotkana przy stosowaniu jej do realistycznych dziedzin problemowych może być wygórowana. Na szczęście często możemy zmniejszyć tę złożoność, koncentrując się na mniejszym zestawie bardziej istotnych wydarzeń i dowodów. Jedno podejście, bayesowskie sieci przekonań lub BBN (Pearl 1988), oferuje model obliczeniowy do rozumowania w celu najlepszego wyjaśnienia zbioru danych w kontekście oczekiwanych związków przyczynowych w dziedzinie problemowej. Sieci przekonań bayesowskich mogą radykalnie zmniejszyć liczbę parametrów pełnego modelu bayesowskiego i pokazać, w jaki sposób dane domeny (lub nawet brak danych) mogą podzielić i skupić się na rozumowaniu. Ponadto modułowość domeny problemowej często pozwala projektantowi programu przyjmować wiele założeń dotyczących niezależności, które są niedozwolone w pełnym leczeniu bayesowskim. W większości przypadków rozumowania nie jest konieczne tworzenie dużej wspólnej tabeli prawdopodobieństwa, w której wymienione są prawdopodobieństwa dla wszystkich możliwych kombinacji zdarzeń i dowodów. Raczej ludzcy eksperci są w stanie wybrać lokalne zjawiska, o których wiedzą, że będą oddziaływać i uzyskać wskaźniki prawdopodobieństwa lub wpływu, które odzwierciedlają tylko te grupy zdarzeń. Eksperci zakładają, że wszystkie inne zdarzenia są warunkowo niezależne lub ich korelacje są tak małe, że można je zignorować. BBN precyzują te intuicje. Jako przykład bayesowska sieć przekonań, rozważ ponownie problem ruchu, przedstawiony na rysunku 14.



Przypomnijmy, że budowa drogi to C, wypadek, A, obecność pomarańczowych beczek, B, zły ruch uliczny, T, a migające światła to L. Aby obliczyć łączne prawdopodobieństwo wszystkich parametrów z przykładu, przyjmując pełne podejście bayesowskie, wymagana wiedza lub pomiary dla wszystkich parametrów znajdujących się w poszczególnych stanach. Zatem wspólne prawdopodobieństwo, przy użyciu topologicznie posortowanej kolejności dla zmiennych, wynosi:

$$p(C, A, B, T, L) = p(C) p(A | C) p(B | C, A) p(T | C, A, B) p(L | C, A, B, T)$$

Liczba parametrów w tym wspólnym prawdopodobieństwie wynosi 2^5 lub 32. Ta tabela jest wykładnicza pod względem liczby parametrów. W przypadku problemu o dowolnej złożoności, powiedzmy z trzydziestoma lub więcej parametrami, wspólna tabela dystrybucji miałaby ponad miliard elementów! Należy jednak pamiętać, że jeśli możemy podtrzymać założenie, że parametry tego problemu zależą tylko od prawdopodobieństw ich rodziców, to znaczy możemy przyjąć, że węzły są niezależne od wszystkich nie-potomków, biorąc pod uwagę wiedzę ich rodziców, obliczenie $p(C, A, B, T, L)$ staje się:

$$p(C, A, B, T, L) = p(C) * p(A) * p(B | C) * p(T | C, A) * p(L | A)$$

Aby lepiej zobaczyć wprowadzone przez nas uproszczenia, rozważ $p(B | C, A)$ z poprzedniego równania. W naszym najnowszym równaniu zredukowaliśmy to do $p(B | C)$. Opiera się to na założeniu, że budowa drogi nie jest skutkiem przyczynowym zaistnienia wypadku. Podobnie, obecność pomarańczowych beczek nie jest przyczyną złego ruchu, ale budowa i wypadek dają w rezultacie $p(T | C, A)$, a nie $p(T | C, A, B)$. Wreszcie, zależność probabilistyczna $p(L | C, A, B, T)$ zostaje zredukowana do $p(L | A)$. Rozkład prawdopodobieństwa dla $p(C, A, B, T, L)$ ma teraz tylko 20 (zamiast 32) parametrów. Jeśli przejdziemy do bardziej realistycznego problemu, na przykład z 30 zmiennymi i jeśli każdy stan ma co najwyżej dwoje rodziców, w rozkładzie będzie najwyżej 240 elementów. Jeśli każdy stan ma trzech rodziców, maksymalna liczba elementów w rozkładzie wynosi 490: znacznie mniej niż miliard wymagany dla pełnego podejścia bayesowskiego! Musimy uzasadnić tę zależność węzła w sieci przekonań wyłącznie od jego rodziców. Powiązania między węzłami sieci przekonań reprezentują warunkowe prawdopodobieństwa wpływu przyczynowego. W rozumowaniu eksperckim za pomocą wnioskowania przyczynowego ukryte jest założenie, że wpływy te są ukierunkowane, to znaczy, że obecność jakiegoś zdarzenia powoduje w jakiś sposób inne zdarzenia w sieci. Co więcej, rozumowanie wpływu przyczynowego nie jest koliste, ponieważ jakiś skutek nie może zawrócić, by sam spowodować. Z tych powodów sieci przekonań bayesowskich będą miały naturalną reprezentację jako skierowany graf acykliczny lub DAG, w którym spójne wzorce rozumowania są odzwierciedlane jako ścieżki przez związki przyczynowo-skutkowe. Bayesowskie sieci przekonań są jednym z przykładów tego, co często nazywa się modelami graficznymi.

W przypadku przykładu ruchu mamy jeszcze silniejszą sytuację, bez cykli nieukierunkowanych. To pozwala nam w bardzo prosty sposób obliczyć rozkład prawdopodobieństwa w każdym węźle. Rozkład węzłów bez rodziców jest bezpośrednio sprawdzany. Wartości węzłów potomnych są obliczane przy użyciu tylko rozkładów prawdopodobieństwa rodziców każdego dziecka, wykonując odpowiednie obliczenia na tabeli prawdopodobieństwa warunkowego dziecka i rozkładach rodziców. Jest to

możliwe, ponieważ nie musimy martwić się o korelacje między rodzicami innych węzłów niebędących potomkami. Powoduje to naturalną separację abdukcyjną, w której wypadek nie ma żadnego związku z obecnością pomarańczowych beczek, jak widać na rysunku 14. Podsumowujemy naszą dyskusję na temat BBN za pomocą następującej definicji.


DEFINICJA

Bayesowka sieć przekonań

Model graficzny nazywa się siecią przekonań bayesowskich (BBN), jeśli jego wykres, opatrzony adnotacjami prawdopodobieństw warunkowych, jest ukierunkowany i acykliczny. Ponadto BBN zakładają, że węzły są niezależne od wszystkich ich nie-potomków, biorąc pod uwagę wiedzę o ich rodzicach. Dynamiczna (lub czasowa) sieć bayesowska (DBN) to sekwencja identycznych sieci bayesowskich, których węzły są połączone w (ukierunkowanym) wymiarze czasu. Ogólny DBM rozważymy szerzej w sekcji 9.3.4 oraz w Części 13. W następnej sekcji rozważymy założenie ukryte w większości ludzkiego rozumowania ekspertów: że obecność lub brak danych w domenie (niejawnie przyczynowej) może podzielić i ukierunkować poszukiwanie wyjaśnień w tej dziedzinie. Fakt ten ma również poważne konsekwencje dla złożoności eksploracji przestrzeni poszukiwań.

9.3.2 Ukierunkowane modele graficzne: separacja d

Ważną zaletą reprezentowania domen aplikacji jako modeli graficznych jest to, że obecność lub brak informacji może prowadzić do podziału modelu na partycje, a co za tym idzie do kontrolowania złożoności wyszukiwania. Następnie przedstawiamy kilka przykładów tego, a następnie podajemy definicję separacji d, która wspiera te intuicje. Rozważmy diagnozę problemów z olejem w silniku samochodowym: załóżmy, że zużyte pierścienie tłokowe powodują nadmierne zużycie oleju, co z kolei powoduje niski odczyt poziomu oleju w samochodzie. Sytuację tę ilustruje rysunek 15a, gdzie A to zużyte pierścienie tłokowe, V to nadmierne zużycie oleju, a B to niski poziom oleju. Jeśli nie wiemy nic o nadmiernym zużyciu oleju, to mamy związek przyczynowy między użytymi pierścieniami tłokowymi a niskim poziomem oleju. Jeśli jednak jakiś test da wiedzę o stanie nadmiernego zużycia oleju, to zużyte pierścienie tłokowe i niski poziom oleju są od siebie niezależne. W drugim przykładzie: załóżmy, że zużyte pierścienie tłokowe mogą powodować zarówno niebieski wydech, jak i niski poziom oleju. Sytuację tę przedstawiono na rysunku 15b, gdzie V to zużyte pierścienie tłokowe, A to niebieski wydech, a B to niski poziom oleju.




Jeśli wiemy, że zużyte pierścienie tłokowe są prawdziwe lub fałszywe, to nie wiemy, czy niebieski wydech i niski poziom oleju są skorelowane; jeśli nie mamy informacji o zużytych pierścieniach tłokowych, wówczas niebieski wydech i niski poziom oleju są skorelowane. Wreszcie, jeśli niski poziom

oleju może być spowodowany albo nadmiernym zużyciem oleju, albo wyciekami oleju, to mając wiedzę o tym, czy jest niski poziom oleju, są skorelowane jego dwie możliwe przyczyny. Jeśli stan niskiego poziomu oleju nie jest znany, to dwie możliwe przyczyny są niezależne. Ponadto, jeśli prawdziwy jest niski poziom oleju, ustalenie wycieku oleju jako prawdziwego wyjaśni nadmierne zużycie oleju. W obu przypadkach informacja o niskim poziomie oleju jest kluczowym elementem w procesie wnioskowania. Widzimy tę sytuację na rysunku 15c, gdzie A to nadmierne zużycie oleju, B to wyciek oleju, a V to niski poziom oleju. Doprecyzowujemy te intuicje, definiując rozdzielenie d węzłów w sieci przekonań lub innym modelu graficznym:

DEFINICJA

d-SEPARACJA

Dwa węzły A i B w skierowanym acyklicznym grafie są rozdzielone d, jeśli każda ścieżka między nimi jest zablokowana. Ścieżka to dowolna ciągła seria połączeń na grafie (węzły łączące w dowolnym kierunku, np. Istnieje ścieżka od A do B na rysunku 15b). Ścieżka jest blokowana, jeśli na ścieżce znajduje się węzeł pośredni V z jedną z właściwości: połączenie jest szeregowo lub rozbieżne, a stan V jest znany, lub połączenie jest zbieżne i ani V, ani żadne z dzieci V nie mają dowodów. Podajemy dalsze przykłady relacji szeregowych, rozbieżnych i zbieżnych węzłów, a także jak separacja d wpływa na ścieżki argumentacji w przykładzie na rysunku 16.



Zanim opuścimy wykresy z rysunku 15, pokażemy, w jaki sposób założenia sieci przekonań bayesowskich mogą uprościć obliczanie prawdopodobieństw warunkowych. Korzystając z prawa Bayesa, każdy wspólny rozkład prawdopodobieństwa można rozłożyć na iloczyn prawdopodobieństw warunkowych. Tak więc na rysunku 15a. wspólne prawdopodobieństwo trzech zmiennych A, V, B wynosi:

$$p(A, V, B) = p(A) p(V | A) p(B | A, V).$$

Korzystamy z założenia sieci przekonań bayesowskich, że prawdopodobieństwo warunkowe zmiennej danej wiedzy wszystkich jej poprzedników jest równe prawdopodobieństwu warunkowemu danej wiedzy tylko jej rodziców. W rezultacie w powyższym równaniu $p(B | A, V)$ staje się $p(B | V)$, ponieważ V jest bezpośrednim rodzicem B, a A nie. Łączne rozkłady prawdopodobieństwa dla trzech sieci na rysunku 15 są następujące:

$$a) p(A, V, B) = p(A) p(V | A) p(B | V),$$

$$b) p(V, A, B) = p(V) p(A | V) p(B | V) i$$

$$c) p(A, B, V) = p(A) p(B) p(V | A, B).$$

Jak pokazał przykład ruchu, w przypadku większych sieci przekonań bayesowskich można wyeliminować znacznie więcej zmiennych z prawdopodobieństw warunkowych. To właśnie to uproszczenie sprawia, że sieci przekonań bayesowskich i inne modele graficzne są znacznie łatwiejsze do opracowania statystycznego niż pełna analiza bayesowska. Następnie przedstawiamy bardziej złożony model graficzny, zawierający cykl nieukierunkowany, i proponujemy skuteczny algorytm wnioskowania, propagację drzewa klikowego.

9.3.3 Ukierunkowane modele graficzne: algorytm wnioskowania

Następny przykład, zaadaptowany z Pearl (1988), pokazuje bardziej złożoną sieć bayesowską. Pora roku na rysunku 16 determinuje prawdopodobieństwo wystąpienia opadów deszczu oraz wody z instalacji tryskaczowej. Mokry chodnik będzie skorelowany z deszczem lub wodą z tryskacza. Wreszcie, chodnik będzie śliski w zależności od tego, czy jest to mokry chodnik, czy nie. Na rysunku przedstawiliśmy relację prawdopodobieństwa, jaką każdy z tych parametrów ma ze swoimi rodzicami. Należy również zauważyć, że w porównaniu z przykładem ruchu, przykład śliskiego chodnika ma cykl, jeśli wykres nie jest ukierunkowany. Zadajemy teraz pytanie, jak można opisać prawdopodobieństwo wystąpienia mokrego chodnika, $p(WS)$? Nie da się tego zrobić jak poprzednio, gdzie $p(W) = p(W | S) p(S)$ lub $p(R) = p(R | S) p(S)$. Dwie przyczyny WS nie są od siebie niezależne; na przykład, jeśli $S = \text{lato}$, to $p(W)$ i $p(R)$ mogą wzrosnąć. Tak więc pełne korelacje dwóch zmiennych, wraz z ich dalszą korelacją z S , należy obliczyć. W tej sytuacji możemy to zrobić, ale, jak zobaczymy, obliczenie to jest wykładnicze pod względem liczby możliwych przyczyn WS. Obliczenie przedstawiono w tabeli 4.

R	W	$p(WS)$
t	t	x
t	f	
f	t	
f	f	

} S=hot
} S=cold


Teraz obliczamy jeden wpis w tej tabeli, x , gdzie R i W są prawdą; aby życie było prostsze, zakładamy, że sezon S jest albo hot, albo cold.

$$x = p(R = t, W = t) \text{ for the two (hot, cold) conditions of } S, \text{ season}$$

$$= p(S = \text{hot}) p(R = t | S = \text{hot}) p(W = t | S = \text{hot}) +$$

$$p(S = \text{cold}) p(R = t | S = \text{cold}) p(W = t | S = \text{cold})$$

W podobny sposób można uzupełnić pozostałą część tabeli 4. Stanowi to wspólne prawdopodobieństwo wystąpienia opadów deszczu i wody z tryskacza. Ten większy „element makro” reprezentuje $p(WS) = p(WS | R, W) p(R, W)$. Uciekliśmy tutaj z dość rozsądną kalkulacją; problem polega na tym, jak wspomniano powyżej, że to wyliczenie jest wykładnicze pod względem liczby rodziców państwa. Nazywamy ten element makra połączoną zmienną lub kliką do obliczania $p(WS)$. Używamy tej koncepcji klik w celu zastąpienia propagacji ograniczeń DAG z rysunku 16 acyklicznym drzewem klik, jak widać na rysunku 17.



Prostokątne prostokąty na rysunku 17a odzwierciedlają zmienne, które dzielą grupy powyżej i poniżej. Tabela, która przekazuje odpowiednie parametry do następnej kliki, jest wykładnicza pod względem liczby tych parametrów. Należy również zauważyć, że zmienna łącząca wraz ze wszystkimi jej rodzicami musi być obecna w kliki. Dlatego przy tworzeniu sieci przekonań lub innego modelu graficznego (procesu inżynierii wiedzy) powinniśmy uważać, ile zmiennych jest rodzicami dowolnego stanu. Kliki będą się również nakładać, jak widać na rysunku 17b, aby przekazywać informacje przez pełne drzewo klik, zwane drzewem skrzyżowań. Następnie przedstawiamy algorytm opracowany przez Laurintzena i Spiegelhaltera (1988), który tworzy drzewo połączeń z dowolnej sieci przekonań bayesowskich.

1. Dla wszystkich węzłów w sieci przekonań ustaw wszystkie skierowane linki jako nieukierunkowane.
2. Dla dowolnego węzła narysuj połączenia między wszystkimi jego rodzicami (przerywana linia między R i W na rysunku 17b).
3. Na otrzymanym wykresie poszukaj dowolnego cyklu o długości większej niż trzy i dodaj kolejne łącza, które skracają ten cykl do trzech. Ten proces nazywa się triangulacją i na przykładzie z rysunku 17b nie jest konieczny.
4. Utworzyć drzewo węzłowe z wynikową strukturą triangulacyjną. Odbywa się to poprzez znalezienie maksymalnych klik (klik, które są kompletnymi podgrafami, a nie podgrafami większej kliki) Zmienne w tych klikach są umieszczane w węzłach, a wynikowe drzewo węzłów jest tworzone przez połączenie dowolnych dwóch węzłów, które mają co najmniej jedną zmienną, jak na rysunku 17a.

Proces triangulacji opisany w kroku 3 powyżej jest krytyczny, ponieważ chcemy, aby wynikowe drzewo węzłów miało minimalny koszt obliczeniowy podczas propagowania informacji. Niestety, decyzja o stworzeniu optymalnych drzew węzłów kosztów jest NP trudna. Często na szczęście do uzyskania użytecznych wyników może wystarczyć prosty zachłanny algorytm. Zwróć uwagę, że rozmiary tabel wymagane do przekazania informacji w drzewie połączeń na rysunku 9.17 to $2 * 2 * 2$, $2 * 2 * 2$ i $2 * 2$. Na koniec bierzemy przykładową sieć z rysunku 16 i wracamy do kwestii separacji d. Pamiętaj, że celem rozdzielenia d jest to, że przy niektórych informacjach części sieci przekonań można zignorować podczas obliczania rozkładów prawdopodobieństwa.


1. SL jest oddzielone d od R, S i W, biorąc pod uwagę, że WS jest znane.
2. D-separacja jest symetryczna, to znaczy S jest również d-oddzielona od (i nie jest to możliwe wyjaśnienie SL), biorąc pod uwagę wiedzę o WS.
3. R i W są zależne z powodu S, ale wiedząc, że S, R i W są rozdzielone d.
4. Jeśli znamy WS, to R i W nie są rozdzielone d; jeśli nie znamy S, to R i W są.

5. Mając łańcuch $R \rightarrow WS \rightarrow SL$, jeśli znamy WS , to R i SL są rozdzielone d .

Musimy być ostrożni, gdy znamy informacje o potomkach danego państwa. Na przykład, jeśli znamy SL , to R i W NIE są rozdzielone d , ponieważ SL jest skorelowane z WS , a wiedząc, że WS , R i W nie są rozdzielone d . Ostatni komentarz: Bayesowskie sieci przekonań wydają się odzwierciedlać sposób, w jaki ludzie rozumują w złożonych domenach, w których niektóre czynniki są znane i powiązane a priori z innymi. W miarę jak rozumowanie postępuje poprzez stopniowe tworzenie instancji informacji, wyszukiwanie jest jeszcze bardziej ograniczone i w rezultacie bardziej wydajne. Ta efektywność wyszukiwania silnie kontrastuje z podejściem wspieranym przez zastosowanie pełnego wspólnego rozkładu, gdzie więcej informacji wymaga wykładniczo większej potrzeby relacji statystycznych i wynikającego z tego szerszego wyszukiwania. Dostępnych jest wiele algorytmów służących do budowania sieci przekonań i propagowania argumentów w miarę pozyskiwania nowych dowodów. Szczególnie polecamy podejście z przekazywaniem wiadomości Pearl'a oraz metodę triangulacji drzew kliki zaproponowaną przez Lauritzena i Spiegelhaltera. Druzel i Henrion również zaproponowali algorytmy propagacji wpływu w sieci. Dechter (1996) przedstawia algorytm eliminacji wiadra jako ujednolicającą strukturę wnioskowania probabilistycznego. W następnej sekcji wprowadzimy dynamiczne sieci bayesowskie.

9.3.4 Ukierunkowane modele graficzne: dynamiczne sieci bayesowskie

Następnie rozważymy uogólnienie sieci przekonań bayesowskich, dynamicznej (lub czasowej) sieci bayesowskiej lub DBN. Ideą wspierającą DBN jest przedstawienie stanu domeny lub czasu obserwacji za pomocą zestawu zmiennych losowych, a nie tylko pojedynczej zmiennej losowej. Dzięki temu rozszerzeniu sieci przekonań bayesowskich mogą być używane do reprezentowania warunkowej niezależności między zmiennymi z różnych perspektyw, na przykład w różnych okresach. Większość wydarzeń, z którymi stykamy się my, ludzie, i na które oczekuje się od nas inteligentnej reakcji, ma charakter czasowy: pojawiają się one w różnych okresach czasu. Dwa przykłady można zobaczyć na rysunkach 18 i 19.




Na rysunku 18 wzięliśmy nasz model ruchu z rysunku 14 i zmapowaliśmy go w różnych okresach czasu. Może to uchwycić zmieniający się punkt widzenia kierowcy w czasie, powiedzmy co minutę, zostanie uchwycony przez zmieniające się parametry sieci bayesowskiej. Za pierwszym razem kierowca jest świadomy zwolnienia, za drugim zauważa obecność pomarańczowych beczek, w trzecim jest ich jeszcze więcej itd. Oczekuje się, że DBN uchwyci rosnącą świadomość budowy dróg, wraz z (znacznie) mniejszą pewnością wypadku. Rysunek 9.19 przedstawia przykładowe dane sygnałów pochodzących

ze złożonego środowiska. (W rzeczywistości są to wielokrotne sygnały cieplne, wibracje i inne sygnały pochodzące z układu wirnika helikoptera). To, co DBN musi mierzyć w tej sytuacji, to jak te sygnały zmieniają się w czasie i informują kontrolera o aktualnym stanie pracy systemu. Rozważymy ten przykład dokładniej. Sieci DBN są najczęściej wykorzystywane do śledzenia dwóch typów systemów zmiennych w czasie. Po pierwsze, sekwencje zależne od czasu, takie jak opisane na rysunkach 18 i 19, a po drugie zjawiska naturalnie występujące w czasie, takie jak próbkowanie fonemów lub słów w aplikacji do analizy języka naturalnego. Należy zauważyć, że możliwe jest przedstawienie korelacji między zmiennymi losowymi w tym samym przedziale czasu (korelacje chwilowe) zarówno z skierowanymi, jak i nieskierowanymi krawędziami modeli graficznych. Jednak korelacje między elementami wykresów odzwierciedlających dane szeregów czasowych muszą być uchwycone za pomocą ukierunkowanych modeli graficznych. Podsumowując: Jeśli każda krawędź łącząca serię modeli graficznych reprezentujących dane związane z czasem ma odzwierciedlać wymiar czasu, model nazywa się dynamiczną siecią Bayesa. DBN może również przechwytywać nieczasowe dane sekwencyjne, takie jak język, gdzie nowe informacje odzwierciedlają zmianę stanu przetwarzania.

9.3.5 Modele Markowa: dyskretny proces Markowa

Przedstawiliśmy maszyny skończone jako reprezentacje graficzne, w których stany są zmieniane w zależności od zawartości strumienia wejściowego. Stany i ich przejścia odzwierciedlają właściwości języka formalnego. Następnie przedstawiliśmy akceptor stanów skończonych (maszynę Moore'a), maszynę stanową, która potrafiła „rozpoznawać” łańcuchy o różnych właściwościach. Przedstawiliśmy probabilistyczną maszynę skończoną, maszynę stanu, w której następną funkcją stanu była reprezentowana przez rozkład prawdopodobieństwa stanu bieżącego. Dyskretny proces Markowa jest specjalizacją tego podejścia, w którym system ignoruje wartości wejściowe. Rysunek 20 to maszyna stanu Markowa, czasami nazywana łańcuchem Markowa, z czterema różnymi stanami.



Ta ogólna klasa systemu może być opisana w dowolnym okresie jako będąca w jednym ze zbioru S odrębnych stanów, $s_1, s_2, s_3, \dots, s_n$. System podlega zmianom stanu, z możliwością pozostawania w tym samym stanie w regularnych, dyskretnych odstępach czasu. Opisujemy uporządkowany zbiór czasów T , które są powiązane z dyskretnymi przedziałami jako $t_1, t_2, t_3, \dots, t_t$. System zmienia stan zgodnie z rozkładem prawdopodobieństw związanych z każdym stanem. Oznaczmy aktualny stan maszyny w czasie t jako σ_t . Pełny opis probabilistyczny tego systemu wymaga w ogólnym przypadku określenia stanu obecnego σ_t w odniesieniu do wszystkich jego stanów poprzedzających. Zatem prawdopodobieństwo, że system znajdzie się w jakimkolwiek określonym stanie σ_t , wynosi: $p(\sigma_t) = p(\sigma_t | \sigma_{t-1}, \sigma_{t-2}, \sigma_{t-3}, \dots)$ gdzie σ_{t-i} są poprzednimi stanami σ_t . W łańcuchu Markowa pierwszego rzędu prawdopodobieństwo obecnego stanu jest funkcją tylko jego bezpośredniego stanu poprzednika:

$$p(\sigma_t) = p(\sigma_t | \sigma_{t-1})$$

gdzie σ_{t-1} poprzedza σ_t . (Ogólnie rzecz biorąc, stan w łańcuchu Markowa rzędu n jest zależny od poprzedzających go n stanów). Zakładamy również, że prawa strona tego równania jest niezmienna w czasie, tj. Stawiamy hipotezę, że we wszystkich okresach czasu układu przejścia między określonymi stanami zachowują te same relacje probabilistyczne. Na podstawie tych założeń możemy teraz stworzyć zbiór prawdopodobieństw przejścia stanów a_{ij} między dowolnymi dwoma stanami s_i i s_j :

$$a_{ij} = p(\sigma_t = s_i \mid \sigma_{t-1} = s_j), \quad 1 \leq i, j \leq N$$

Przypomnij sobie, że mogą równać się j , w którym to przypadku system pozostaje w tym samym stanie. Na rozkładach prawdopodobieństwa pozostają tradycyjne ograniczenia; dla każdego stanu s_i :

$$a_{ij} \geq 0 \text{ oraz}$$

System, który właśnie opisaliśmy, nazywany jest obserwowalnym modelem Markowa pierwszego rzędu, ponieważ wyjściem systemu jest zbiór stanów w każdym dyskretnym przedziale czasu, a każdy stan systemu odpowiada zdarzeniu fizycznemu (obserwowalnemu). Sprawiamy, że obserwowalny model Markowa jest bardziej formalny z definicją, a następnie podajemy przykład.

DEFINICJA

(OBSERWOWALNY) MODEL MARKOWA

Model graficzny nazywamy (obserwowalnym) modelem Markowa, jeśli jego wykres jest ukierunkowany, a prawdopodobieństwo dotarcia do dowolnego stanu s_t ze zbioru stanów S w dyskretnym czasie t jest funkcją rozkładów prawdopodobieństwa jego bycia w poprzednich stanach S w poprzednich czasach. Każdy stan $s_t \in S$ odpowiada fizycznie obserwowalnej sytuacji.

Obserwowalny model Markowa jest pierwszego rzędu, jeśli prawdopodobieństwo, że znajdzie się on w stanie obecnym s_t w dowolnym momencie t jest jedynie funkcją tego, że był w stanie poprzednim s_{t-1} w chwili $t-1$, gdzie s_t i s_{t-1} należą do zbioru obserwowalnych stanów S . Zauważ, że każdy rozkład prawdopodobieństwa ma właściwość bycia modelem Markowa. Siła tego podejścia wynika z założeń pierwszego rzędu. Jako przykład obserwowalnego modelu Markowa pierwszego rzędu, rozważmy pogodę w południe, powiedzmy, dla określonej lokalizacji. Zakładamy, że ta lokalizacja ma cztery różne stany dyskretne dla zmiennej pogody: s_1 = słońce, s_2 = pochmurno, s_3 = mgła, s_4 = opady. Przedziały czasowe dla modelu Markowa będą w południe każdego kolejnego dnia. Zakładamy również, że rany między stanami pogody pozostają stałe w czasie (nie jest to prawda dla większości lokalizacji!), A obserwowalna pogoda może pozostawać w tym samym stanie przez wiele dni. Ta sytuacja jest przedstawiona na rysunku 20 i jest obsługiwana przez macierz przejść stanów a_{ij} :

$$a_{ij} = \begin{array}{c|cccc} & s_1 & s_2 & s_3 & s_4 \\ \hline s_1 & 0.4 & 0.3 & 0.2 & 0.1 \\ s_2 & 0.2 & 0.3 & 0.2 & 0.3 \\ s_3 & 0.1 & 0.3 & 0.3 & 0.3 \\ s_4 & 0.2 & 0.3 & 0.3 & 0.2 \end{array}$$

W tej macierzy przejść a_{ij} , pierwszy rząd przedstawia przejścia od s_1 do każdego ze stanów, w tym przebywanie w tym samym stanie; drugi rząd to przejścia z s_2 i tak dalej. Właściwości wymagane, aby przejścia były rozkładami prawdopodobieństwa z każdego stanu są spełnione (ich suma wynosi 1,0). Teraz zadajemy pytania dotyczące naszego modelu. Załóżmy, że dzisiaj, s_1 , jest słonecznie; jakie jest

prawdopodobieństwo, że następnym pięć dni pozostanie słonecznych? Albo jakie jest prawdopodobieństwo następnym pięciu dni są słoneczne, słoneczne, pochmurne, pochmurne, opady? Aby rozwiązać ten drugi problem, określamy prawdopodobieństwo i określamy, że pierwszy dzień, s_1 , to dzisiejsze obserwowane słońce: $O = s_1, s_1, s_1, s_2, s_2, s_4$

Prawdopodobieństwo tych obserwowanych stanów, biorąc pod uwagę model Markowa pierwszego rzędu, M , wynosi:

$$\begin{aligned} p(O | M) &= p(s_1, s_1, s_1, s_2, s_2, s_4 | M) \\ &= p(s_1) \times p(s_1 | s_1) \times p(s_1 | s_1) \times p(s_2 | s_1) \times p(s_2 | s_2) \times p(s_4 | s_2) \\ &= 1 \times a_{11} \times a_{11} \times a_{12} \times a_{22} \times a_{24} \\ &= 1 \times (.4) \times (.4) \times (.3) \times (.3) \times (.3) \\ &= .00432 \end{aligned}$$

Wynika to z założenia Markowa pierwszego rzędu, gdzie pogoda każdego dnia jest funkcją (tylko) pogody z poprzedniego dnia. Obserwujemy też, że dziś jest słońce. Możemy rozszerzyć ten przykład, aby określić, biorąc pod uwagę, że znamy dzisiejszą pogodę, prawdopodobieństwo, że pogoda będzie taka sama przez dokładnie następnym t dni, tj. że pogoda pozostaje taka sama do dnia $t + 1$, w którym to czasie jest inna. Dla dowolnego stanu pogody s_i i modelu Markowa M mamy obserwację O :

$O = \{s_i, s_i, s_i, \dots, s_i, s_j\}$, gdzie jest dokładnie $(t + 1)$ s_i i gdzie $s_i \neq s_j$, to:

$$p(O | M) = 1 \times a_{ii}^t \times (1 - a_{ii})$$

gdzie a_{ii} to prawdopodobieństwo przejścia stanu s_i do siebie. Wartość ta nazywana jest dyskretną funkcją gęstości prawdopodobieństwa dla czasu trwania t okresów w stanie s_i modelu M . Ta funkcja gęstości czasu trwania wskazuje na czas trwania stanu w modelu Markowa. Na podstawie tej wartości możemy obliczyć, w ramach modelu M , oczekiwaną liczbę obserwacji lub czas trwania d_i w dowolnym stanie s_i , zakładając, że pierwsza obserwacja jest w tym stanie:

$$\begin{aligned} d_i &= \sum_{d=1}^n d(a_{ii})^{(d-1)}(1 - a_{ii}) \quad \text{where } n \text{ approaches } \infty, \text{ or:} \\ &= \frac{1}{1 - a_{ii}} \end{aligned}$$

Na przykład oczekiwana liczba kolejnych dni opadów, w tym modelu, wynosi $1 / (1 - 0,3)$ lub 1,43. Podobnie liczba kolejnych słonecznych dni, których można by się spodziewać w przypadku tego modelu, wynosi 1,67. Następnie podsumujemy różne formy modeli Markowa

9.3.6 Modele Markowa: wariacje

W modelach Markowa, które widzieliśmy do tej pory, każdy stan odpowiada dyskretnemu fizycznemu - i możliwemu do zaobserwowania - zdarzeniu, takim jak wartość pogody o określonej porze dnia. Ta klasa modelu jest naprawdę dość ograniczona i teraz uogólniamy ją na szerszą klasę modeli. Opisujemy pokrótce kilka z tych podejść. Rozdział 13.1 oferuje bardziej wszechstronną prezentację ukrytych modeli Markowa wraz z kilkoma ważnymi odmianami.

Ukryte modele Markowa

W przedstawionych już modelach Markowa każdy stan odpowiada dyskretnemu fizycznemu i obserwowalnemu wydarzeniu. W ukrytym modelu Markowa lub HMM zakłada się, że obserwowane wartości są funkcjami probabilistycznymi bieżącego stanu ukrytego. Na przykład, obserwowany dźwięk mowy ludzkiej jest odbiciem telefonu, który ma zamiar odtworzyć rozmówca. Wypowiadany dźwięk jest tylko probabilistycznie powiązany z rzeczywistym stanem lub intencjami mówiącego. Zatem HMM jest podwójnie osadzonym procesem stochastycznym, w którym obserwowalny proces stochastyczny (hałas mówiącego) jest wspomagany przez nieobserwowalny proces stochastyczny (stan lub intencje mówiącego). HMM jest szczególnym przypadkiem DBN

Modele semi-Markowa

Model semi-Markov to dwuskładnikowy łańcuch Markowa. Pierwsza składowa odpowiada za wybór kolejnego przejścia stanu, a druga za czas przejścia. Kiedy model semi-Markowa wchodzi w stan s_i pozostaje w tym stanie dla czasu t_i , który jest pobierany z rozkładu prawdopodobieństwa trwania stanu. Po upływie czasu t_i proces przechodzi do następnego stanu s_{i+1} zgodnie z rozkładem prawdopodobieństwa przejścia między stanami i ponownie wybiera się czas przejścia t_{i+1} . Model semi-Markowa obsługuje dowolne rozkłady prawdopodobieństwa czasu trwania stanu w porównaniu ze stałymi przejściami czasowymi określonymi przez tradycyjne modele Markowa.

Procesy decyzyjne Markowa

Dwa inne warianty modeli Markowa, szeroko stosowane w uczeniu się ze wzmocnieniem, to proces decyzyjny Markowa (MDP) i częściowo obserwowalny proces decyzyjny Markowa, r POMDP. MDP jest zdefiniowany w dwóch przestrzeniach: przestrzeni stanów dla rozpatrywanego problemu oraz przestrzeni możliwych działań. Przejście do nowego stanu w przestrzeni stanów jest zależne od stanu obecnego i aktualnego działania i jest kierowane przez warunkowy rozkład prawdopodobieństwa. W każdym stanie obliczana jest nagroda na podstawie obecnego stanu i działania. Zwykle zadaniem uczenia się przez wzmocnianie jest maksymalizacja skumulowanej funkcji nagrody w obecnych warunkach. Podczas gdy MDP działa ze stanem obserwowanym (deterministycznym) przed użyciem macierzy przejścia opartej na prawdopodobieństwie do wybrania następnego stanu, POMDP ma tylko probabilistyczną wiedzę o swoim obecnym stanie (a także o macierzy probabilistycznej do określenia następnego stanu). W ten sposób POMDP może okazać się trudny obliczeniowo w złożonych środowiskach.

9.3.7 Alternatywy pierwszego rzędu dla BBN w modelowaniu probabilistycznym

Do tego punktu w sekcji 9.3 przedstawiliśmy reprezentacje oparte na rachunku zdań dla wnioskowania z niepewnością. Naturalne jest pytanie, w jakim sensie modele oparte na logice predykatów probabilistycznych mogą być użyte do wnioskowania. Siłą pełnej reprezentacji logiki predykatów jest semantyka deklaratywna wraz z ramami reprezentacji opartymi na zmiennych. Ograniczenia reprezentacji tradycyjnych podejść opartych na logice zdań obejmują ograniczoną zdolność radzenia sobie z szumem i niepewnością, a także statyczny obraz reprezentacji. Zatem modele Bayesian i Markovian przedstawione w sekcji 9.3 są ograniczone do reprezentacji na poziomie propozycji, gdzie przedstawienie ogólnych (opartych na zmiennych) relacji z rozkładem, na przykład, $\forall X \text{ male}(X) \rightarrow \text{smart}(X)$ (0,49 0,51). Wiele złożonych dziedzin problemowych wymaga tego poziomu ekspresji. W przypadku złożonych dziedzin, szczególnie w obszarach diagnozy i rokowania, ważne jest również, aby móc reprezentować powtarzalne, rekurencyjne i (potencjalnie) nieskończone struktury. Dlatego jeśli chcemy reprezentować systemy, które zmieniają stan w czasie, musimy mieć tę reprezentacyjną moc. Wymaga to rekurencyjnego lub powtarzanego do czasu wykonania reżimu kontroli typu. Jeśli chcemy dynamicznie przebudować tradycyjny BBN, jesteśmy zmuszeni do rekonstrukcji całej sieci w okresach czasu, ponieważ tym strukturom brakuje deklaratywnej i zorientowanej na czas semantyki. Niedawna

działalność badawcza doprowadziła do powstania wielu ważnych rozszerzeń modeli graficznych, w tym szeregu systemów pierwszego rzędu (opartych na zmiennych i rekurencyjnych). Istnieje również szereg hierarchicznych i rozkładalnych modeli bayesowskich. Wymieniamy kilka z tych nowych formalizmów modelowania, które wspierają taką reprezentację.

Budowa sieci bayesowskiej na podstawie baz wiedzy

Haddawy, Ngo i współpracownicy łączą razem system logiczny pierwszego rzędu z sieciami przekonań bayesowskimi. W rezultacie tworzą logikę probabilistyczną pierwszego rzędu używaną jako język reprezentacji do określania pewnej klasy sieci w postaci bazy wiedzy. Semantyka formalna bazy wiedzy (bayesowskiej) jest egzekwowana za pomocą ściśle określonego języka reprezentacji określającego zdania bazy. Haddawy i Ngo dostarczyły sprawdzony, poprawny algorytm generowania sieci bayesowskiej, implementujący kombinację semantyki formalnej dla bazowego języka logicznego, a także semantyki niezależności dla bazy wiedzy. Jedną z cech algorytmu generującego jest to, że unika on tworzenia nieistotnych węzłów dla sieci przy użyciu dowodów określonych przez użytkownika. Haddawy i Ngo argumentują, że rozumowanie staje się bardzo nieefektywne, gdy wiedza podstawa staje się bardzo duża. Jako środek zaradczy proponują wykorzystanie informacji kontekstowych do indeksowania probabilistycznych zdań bazy wiedzy. Kiedy algorytm generowania modelu konstruuje sieć, pomija zdania z bazy wiedzy, których kontekst nie jest istotny do bieżącego zadania. Wynikowy model jest znacznie mniejszy, niż gdyby do budowy modelu wykorzystano całą bazę wiedzy. Podejście Haddawy, Ngo i współpracowników jest jedną z pierwszych prób badawczych w dziedzinie stochastycznego modelowania logicznego, które jawnie wykorzystuje kontekstowe informacje o domenie jako sposób na skoncentrowanie bazy wiedzy na odpowiednich informacjach i zmniejszenie rozmiaru modelu. konieczne do rozwiązania określonego zadania rozumowania.

Programy logiki bayesowskiej, BLP.

Programy logiki bayesowskiej oferują ramy reprezentacyjne, w tym programowanie logiczne i modele graficzne. Dokładniej rzecz biorąc, BLP łączą sieci przekonań bayesowskich z logiką klauzuli Horn. Na podstawie określonego zapytania system generuje sieć bayesowską w celu udzielenia odpowiedzi na zapytanie przy użyciu zestawu reguł pierwszego rzędu z parametrami niepewności. Wynikowa reprezentacja jest łatwa do zinterpretowania, a jej projektanci przypisują jej teoretyczną semantykę modelu podobną do tej przedstawionej w Cześci 2.

Probabilistyczne modele relacyjne, PRM

Friedman, Getoor i ich współpracownicy opracowali inne podejście do systemów probabilistycznych pierwszego rzędu. Zamiast tworzyć deklaratywny język podobny do logiki, PRM określają model prawdopodobieństwa dla klas obiektów. Osoby o ograniczonej możliwości poruszania się definiują ograniczenia prawdopodobieństwa na poziomie klasy, dzięki czemu ograniczenia te mogą być używane z dowolnym obiektem z tej klasy. W przypadku PRM możliwe jest również określenie probabilistycznych zależności między atrybutami powiązanych klas. Szereg rozszerzeń PRM pozwala na podklasy wspierające probabilistykę zależności na odpowiednich poziomach szczegółowości. Hierarchie klas pozwalają na modelowanie zarówno na poziomie jednostek (tradycyjna sieć przekonań bayesowskich), jak i klas. Dalszym rozszerzeniem PRM jest traktowanie struktur relacyjnych samych modeli jako niepewnych, a nie ustalonych. Z tej perspektywy istnieje ścisły związek między PRM a relacyjnymi bazami danych, ponieważ mogą one mieć podobną strukturę.

Sieci logiczne Markowa, sieci MLN.

Richardson i Domingos proponują inny system oparty na logice probabilistycznej, zwany sieciami logicznymi Markowa (MLN). Większość poprzednich opartych na logice podejść do modelowania stochastycznego wykorzystuje ograniczone podzbiory logiki ogólnej, przy czym klauzule Horn są najbardziej typową reprezentacją. Aby usunąć ograniczenia logiki, Richardson i Domingos używają ogólnej logiki pierwszego rzędu, której zdania są konwertowane na spójną formę normalną (CNF). Wykorzystują również pola losowe Markowa jako probabilistyczny odpowiednik logiki, co jest kolejną istotną różnicą w stosunku do wcześniej opisanych systemów (sieci przekonań bayesowskich są zdecydowanie najczęściej używaną reprezentacją). W konsekwencji mapowanie zdań logicznych w CNF na pola losowe Markowa jest proste. MLN to pierwsze ramy teoretyczne z pełnym mapowaniem od rachunku predykatów pierwszego rzędu z symbolami funkcji do rozkładów prawdopodobieństwa.

Loopy Logic

Logika pętli jest deklaratywnym językiem probabilistycznym pierwszego rzędu i kompletnym według Turinga. Swoją nazwę zawdzięcza wykorzystaniu zapętłonego algorytmu propagacji przekonań Pearl do wnioskowania. Jego oparte na logice deklaratywne reprezentacje są najpierw tłumaczone na pola losowe Markowa. Uczenie się parametrów z algorytmem maksymalizacji oczekiwań (EM) dobrze współgra z zapętloną propagacją przekonań. Zapętłony system logiczny, wraz z wykorzystaniem pola losowego Markowa i uczenia parametrów w oparciu o EM. Istnieje wiele dalszych rozszerzeń tradycyjnych BBN, które sprawiają, że są one pierwszym zamówieniem i Turingiem. Dalsze przykłady modelowania stochastycznego pierwszego rzędu obejmują język IBAL Pfeffera oraz Stochastic Lambda Calculus of Pless i Luger. Zorientowane obiektowo reprezentacje stochastyczne obejmują (Koller i Pfeffer 1997, 1998; Pfeffer i wsp. 1999; Xiang i wsp. 2000; Pless i wsp. 2000). Metody stochastyczne są ważne w całej dziedzinie sztucznej inteligencji; patrz, na przykład, czynniki probabilistyczne.