

7. Zpracování neurčitosti – klasické přístupy

Zpracování neurčitosti – klasické přístupy

7. listopadu 2023

Příčiny neurčitosti

Neurčitost je charakteristickým rysem složitých systémů. Vlastní povaha reality způsobuje, že poznatky, které z ní získáváme, jsou neurčité (vágní).

Příčiny neurčitosti:

- problémy s daty, např.:
 - chybějící nebo nedostupná data
 - nespolehlivá data (např. z důvodu chyb měření)
 - nepřesná nebo nekonzistentní reprezentace dat
- nejisté znalosti, např.:
 - znalost nemusí být platná ve všech případech
 - znalost může obsahovat nepřesné (vágní) pojmy

7. Zpracování neurčitosti – klasické přístupy

Druhy neurčitosti

Neurčitost v bázi znalostí – jsou v ní uloženy nejen exaktně dokázané znalosti, ale i nejrůznější heuristiky, které se expertovi či odborníkovi osvědčily při rozhodování v praxi. Pak se tam objevují pojmy jako „často“, „většinou“, „obvykle“, které je třeba kvantifikovat, např. ve škále od „určitě ano“ přes „nevím“ až k „určitě ne“. Takovou znalostí s neurčitostí může být např. „jestliže pacient má teplotu, obvykle je mu předepsán acylpyrin“; pacient totiž „často“ má teplotu v důsledku chřipky, ale „někdy“ může mít teplotu, protože je v poúrazovém šoku.

Neurčitost v datech – konkrétní data o daném případě bývají zatížena neurčitostí způsobenou nepřesně určenými hodnotami nebo subjektivním pohledem uživatele, např. odpovědi na míru jistoty v nějakém tvrzení. Může to být např. odpověď „snad ano“ na dotaz, zda pacient má teplotu.

Vyjádření neurčitosti

Neurčitost bývá ve znalostních systémech vyjadřována obvykle numerickými parametry, které se v různých systémech nazývají různě, např. *váhy, míry, stupně důvěry, faktory jistoty*.

Tyto numerické parametry se přiřazují jednotlivým tvrzením nebo pravidlům. Často nabývají hodnot z intervalu $\langle 0, 1 \rangle$, $\langle -1, 1 \rangle$, popř. také např. $\langle -5, 5 \rangle$ (FEL-Expert) apod.

Většinou se neurčitost vyjadřuje jediným číslem. Postupně se však začínají prosazovat přístupy, v nichž je neurčitost vyjadřována dvojicí čísel (tato dvojice může být např. interpretována jako interval hodnot).

Existují však také systémy, kde se pracuje s kvalitativně vyjádřenými neurčitostmi.

Přístupy ke zpracování neurčitosti

Přístupy založené na *ad hoc* modelech, použitých např. v:

- systému MYCIN (zde se pracuje s faktory jistoty),
- systému PROSPECTOR (pseudobayesovské přístupy).

Přístupy založené na teoretických principech, např. na:

- teorii pravděpodobnosti,
- teorii fuzzy množin,
- teorii fuzzy míry (sem patří např. Dempster-Shaferova teorie a teorie možnosti).

Problémy při zpracování neurčitosti

Omezme se nejprve na problematiku **pravidlových** systémů. Při zpracování neurčitosti se u nich střetáváme s následujícími problémy (problémy aproximativní inference):

- Jak kombinovat **neurčitá data** v předpokladu pravidla ?
- Jak kombinovat **neurčitost předpokladu pravidla** a **neurčitost pravidla jako celku** ?
- Jak stanovit **neurčitost závěru**, k němuž vede několik pravidel ?

7. Zpracování neurčitosti – klasické přístupy

Bayesovský přístup

Bayesovský přístup je nejstarší a nejlépe definovanou technikou pro zpracování neurčitosti.

Uvažujme znalost ve tvaru pravidla $E \rightarrow H$, které říká, že předpoklad (*evidence*) E podporuje závěr (*hypothesis*) H (je-li splněn předpoklad E , pak platí závěr H apod.).

Neurčitost závěru H v závislosti na předpokladu E může být kvantifikována pomocí podmíněné pravděpodobnosti $P(H | E)$:

$$P(H | E) = \frac{P(E | H)P(H)}{P(E)}$$

Bayesovy vzorce:

$$P(H | E) = \frac{P(E | H)P(H)}{P(E | H)P(H) + P(E | \neg H)P(\neg H)}$$

Pravděpodobnostní šance

Apriorní pravděpodobnostní šance:

$$O(H) = \frac{P(H)}{P(\neg H)} = \frac{P(H)}{1 - P(H)}$$

Aposteriorní pravděpodobnostní šance:

$$O(H | E) = \frac{P(H | E)}{P(\neg H | E)} = \frac{P(H | E)}{1 - P(H | E)}$$

Pravděpodobnost lze ze šance vypočítat podle vztahu

$$P = \frac{O}{O+1}$$

Míry postačitelnosti a nezbytnosti

Z Bayesových vzorců pro $P(H|E)$ a $P(\neg H|E)$ plyne, že

$$O(H|E) = L \cdot O(H), \text{ kde } L = \frac{P(E|H)}{P(E|\neg H)},$$

L se nazývá *mírou postačitelnosti* (velká hodnota $L \gg 1$ říká, že předpoklad E je postačitelny k dokázání hypotézy H).

Obdobně platí $O(H|\neg E) = \hat{L} \cdot O(H)$, kde $\hat{L} = \frac{P(\neg E|H)}{P(\neg E|\neg H)}$

je *míra nezbytnosti* (malá hodnota $0 < \hat{L} \ll 1$) znamená, že předpoklad E je nezbytný pro dokázání H).

7. Zpracování neurčitosti – klasické přístupy

Váhy pravidel v prospectorovských systémech

Míry postačitelnosti a nezbytnosti zadává pro každé pravidlo expert jako svoje subjektivní váhy. Pravidlo $E \rightarrow H$ se vlastně chápe jako pravidlo

if E then H with váha L else H with váha L^{\wedge} ,

resp. jako dvojice pravidel

$$E \rightarrow H(L) \text{ a } \neg E \rightarrow H(L^{\wedge}).$$

Místo uvedených měr může expert zadat pravděpodobnosti $P(H|E)$ a $P(H|\neg E)$, z nichž se pak tyto míry vypočtou. Např.:

$$L = \frac{P(H|E)}{1 - P(H|E)} \cdot \frac{1 - P(H)}{P(H)}$$

7. Zpracování neurčitosti – klasické přístupy

Vliv neurčitosti tvrzení E

Předpokládejme, že k výroku E není přiřazena logická hodnota pravda nebo nepravda, ale je k dispozici pouze nějaké relevantní pozorování E' . Pak platí

$$\begin{aligned} P(H | E') &= P(H \wedge E | E') + P(H \wedge \neg E | E') = \\ &= P(H | E \wedge E')P(E | E') + P(H | \neg E \wedge E')P(\neg E | E') \end{aligned}$$

Můžeme udělat tento oprávněný předpoklad: Víme-li, že E je pravda nebo nepravda, pak pozorování E' nepřináší žádnou další informaci o H . Potom můžeme předchozí vztah přepsat do tvaru

$$\begin{aligned} P(H | E') &= P(H | E)P(E | E') + P(H | \neg E)P(\neg E | E') = \\ &= P(H | \neg E) + [P(H | E) - P(H | \neg E)]P(E | E') \end{aligned}$$

Aproximace výpočtu $P(H|E')$

Vztah $P(H | E') = P(H | \neg E) + [P(H | E) - P(H | \neg E)]P(E | E')$

představuje lineární závislost $P(H | E')$ na $P(E | E')$.

Protože však výzkumník nebo expert nezávisle zadává $P(H | E)$ a $P(H | \neg E)$ (přímo nebo prostřednictvím L a L^{\wedge}) a dále $P(H)$ a $P(E)$, je uvedená přímka přeúčena a může dojít k rozporu (zadávané údaje nemusejí být konzistentní).

Proto se výše uvedený teoretický vztah nahrazuje nějakou aproximací. Obvykle se fixují tyto tři body grafu:

$$[0, P(H | \neg E)], \quad [P(E), P(H)] \quad \text{a} \quad [1, P(H | E)].$$

Mezi těmito body se pak závislost interpoluje lineárními funkcemi.

Příklad aproximace $P(H | E')$

Uvažujme případ $P(H | \neg E) \leq P(H) \leq P(H | E)$. Pak můžeme $P(H | E')$ aproximovat vztahy

$$P(H | E') = P(H | \neg E) + \frac{P(H) - P(H | \neg E)}{P(E)} \cdot P(E | E')$$

pro $0 \leq P(E | E') \leq P(E)$ a

$$P(H | E') = P(H) + \frac{P(H | E) - P(H)}{1 - P(E)} \cdot (P(E | E') - P(E))$$

pro $P(E) \leq P(E | E') \leq 1$.

Kombinace více pravidel

Mějme pravidla $E_1 \rightarrow H, E_2 \rightarrow H, \dots, E_n \rightarrow H$. Pak se aposteriorní šance za předpokladu nezávislosti pravděpodobností E_i vypočte takto:

$$O(H \mid E_1 \wedge \dots \wedge E_n) = L_1 \cdot \dots \cdot L_n \cdot O(H)$$

Pokud místo přesných pravděpodobností E_i jsou k dispozici pouze pozorování E_i' , pak se aposteriorní šance vypočte podle vztahu

$$O(H \mid E_1' \wedge \dots \wedge E_n') = L_1' \cdot \dots \cdot L_n' \cdot O(H)$$

kde

$$L_i' = \frac{O(H \mid E_i')}{O(H)}$$

Kombinace předpokladů

Vztahy pro výpočet vah disjunkce, konjunkce a negace předpokladů přebírají prospectorovské systémy z fuzzy logiky:

Disjunkce předpokladů:

$$P(E_1 \vee E_2) = \max\{P(E_1), P(E_2)\}$$

Konjunkce předpokladů:

$$P(E_1 \wedge E_2) = \min\{P(E_1), P(E_2)\}$$

Negace předpokladu:

$$P(\neg E) = 1 - P(E)$$

Výhody a nevýhody bayesovských přístupů

Výhody:

- dobré teoretické základy
- dobře definovaná sémantika rozhodování

Nevýhody:

- potřeba velkého množství pravděpodobnostních dat
- nebezpečí neúplnosti a nekonzistence dat
- předpoklad nezávislosti pravděpodobností E_i bývá v praxi zřídka splněn
- možnost ztráty informace v důsledku popisu neurčitosti jedním číslem
- obtížnost vysvětlování

7. Zpracování neurčitosti – klasické přístupy

Přístup založený na faktorech jistoty

Faktory jistoty (*certainty factors*) byly poprvé použity v systému MYCIN. Cílem bylo eliminovat některé slabiny čistě pravděpodobnostního přístupu.

Znalosti jsou vyjádřeny opět ve tvaru pravidel $E \rightarrow H$, přičemž s každým pravidlem je spojen faktor jistoty CF . Tento faktor nabývá hodnot z intervalu $\langle -1, 1 \rangle$ a je určen mírami důvěry (MB) a nedůvěry (MD):

$$CF = \frac{MB - MD}{1 - \min\{MB, MD\}}$$

Faktor jistoty vyjadřuje stupeň důvěry v hypotézu H , jestliže předpoklad E je pravdivý (1 znamená absolutní důvěru, -1 absolutní nedůvěru).

Míra důvěry

Míra důvěry (*measure of belief*):

$$MB(H, E) = \begin{cases} 1 & \text{pro } P(H) = 1 \\ \frac{\max\{P(H | E), P(H)\} - P(H)}{1 - P(H)} & \text{jinak} \end{cases}$$

Míra důvěry nabývá hodnot z intervalu $\langle 0, 1 \rangle$. Vyjadřuje stupeň, ve kterém je důvěra v hypotézu H podporována pozorováním předpokladu E .

Míra nedůvěry

Míra nedůvěry (*measure of disbelief*):

$$MD(H, E) = \begin{cases} 1 & \text{pro } P(H) = 0 \\ \frac{P(H) - \min\{P(H | E), P(H)\}}{P(H)} & \text{jinak} \end{cases}$$

Míra nedůvěry nabývá hodnot z intervalu $\langle 0, 1 \rangle$. Vyjadřuje stupeň, ve kterém je nedůvěra v hypotézu H podporována pozorováním předpokladu E .

Vliv neurčitosti předpokladů

Předpoklad E v pravidlu $E \rightarrow H$ nemusí být znám s absolutní jistotou. Může být odvozen z jiného pravidla nebo zadán uživatelem s nějakým faktorem jistoty $CF(E)$. Pak se výsledný faktor jistoty vypočte takto:

$$CF_{new}(H, E) = CF_{old}(H, E) \cdot CF(E)$$

Jestliže přitom předpoklad E obsahuje konjunkci nebo disjunkci dílčích podmínek, pak se při výpočtu $CF(E)$ použijí následující vzorce:

$$CF(E_1 \wedge E_2) = \min\{CF(E_1), CF(E_2)\}$$

$$CF(E_1 \vee E_2) = \max\{CF(E_1), CF(E_2)\}$$

7. Zpracování neurčitosti – klasické přístupy

Kombinace více pravidel

Mějme pravidla $E_1 \rightarrow H, E_2 \rightarrow H, \dots, E_n \rightarrow H$. Označme $CF_n = CF(H, E_1, \dots, E_n)$. Výpočet CF_n se pak provede podle vzorce:

$$CF_n = \begin{cases} CF_{n-1} + CF(H, E_n) \cdot (1 - CF_{n-1}) & \text{pro } CF_{n-1} > 0 \text{ a } CF(H, E_n) > 0 \\ CF_{n-1} + CF(H, E_n) \cdot (1 + CF_{n-1}) & \text{pro } CF_{n-1} < 0 \text{ a } CF(H, E_n) < 0 \\ \frac{CF_{n-1} + CF(H, E_n)}{1 - \min\{|CF_{n-1}|, |CF(H, E_n)|\}} & \text{jinak} \end{cases}$$

Výhody a nevýhody faktorů jistoty

Výhody:

- jednoduchý a účinný výpočetní model
- shromáždění potřebných dat podstatně snazší než v jiných metodách
- snazší implementace vysvětlovacího modulu

Nevýhody:

- chybí pevné teoretické základy
- implicitní předpoklad nezávislosti pravděpodobností E_i