

# Vybrané metody reprezentace znalostních bází s faktorem neurčitosti

Tomáš Faltejsek, Jakub Vančata, Jan Valeš

22. duba 2022

## Abstrakt

Konvenční modely strojového učení jsou často založeny na jedné z variant trénování na datech, kdy vytvoření modelu, který efektivně zachytí doménovou znalost představuje netriviální úlohu spojenou s reží velkého množství takových dat. V této práci je představen alternativní přístup k reprezentaci znalostí s faktorem neurčitosti založený na vstupu kvalifikovaného experta. Na triviálních modelech je prezentováno využití Bayesovských sítí s použitím orientovaných acyklických grafů a expertní systém NEST založený na principu IF-THEN pravidel a fuzzy logiky. Závěrem jsou demonstrovány možnosti dotazování a inference na vytvořených modelech.

## 1 Úvod

Práce se zabývá představením vybraných přístupů k reprezentaci znalostních bází s faktorem neurčitosti (*pravděpodobnostním faktorem*). Znalostní báze jsou založeny na vstupu kvalifikovaného experta v dané doméně. Oproti konvenčním modelům strojového učení tak nejsou založeny na trénování na rozsáhlých datech. V sekci 1.2 jsou představeny Bayesovské sítě jako model pro reprezentaci znalostní báze a přístup k jejich konstrukci. V sekci 1.3 je představen expertní software NEST pro konstrukci znalostní báze za použití IF-THEN pravidel a Fuzzy logiky. V práci dále prezentujeme ukázky vytvořených znalostních bází dle jednotlivých postupů, poukazujeme na jejich výhody a předkládáme náměty ke zlepšení zvolených postupů.

### 1.1 Znalost

V kontextu *znalosti* se nebavíme pouze o deskriptivních znalostech (*faktech*). Jedná se také o jakési neurčité (*subjektivně vnímané*) porozumění konkrétní doméně, procedurální znalost domény a dovednosti s tím spojené. Russell a Norvig (2009)

## 1.2 Bayesovská síť

Využití technik strojového učení se stalo široce rozšířeným nástrojem pro vyvozování znalostí a poskytnutí predikcí. Podstatná část modelů strojového učení ale funguje na jedné z variant trénování na datech.

Vytvoření modelu založeného na doménové znalosti experta tak bez rozsáhlého datasetu není zcela triviální úlohou. Existuje ale odvětví strojového učení založené na pravděpodobnostních modelech - tzv. Bayesovských sítích (*Bayesian networks* - zaměnitelné s *BayesNet*, *Bayesian belief networks*, *influence digrams* nebo *Causal probabilistic networks*). Bayesovské sítě mohou být použity k modelování doménových znalostí experta a rovněž k inferenci (odvození) znalostí ze závěru. Russell a Norvig (2009)

Bayesovské sítě vychází ze základů Teorie pravděpodobnosti, resp. Bayesovy věty, definované následovně:

$$P(Z | X) = \frac{P(X | Z)P(Z)}{P(X)}$$

kde:

- $P(Z | X)$ : "*Posterior*" (podmíněná pravděpodobnost jevu Z, za předpokladu že nastal jev X)
- $P(X | Z)$ : "*Podmíněná závislost*" (podmíněná pravděpodobnost jevu X, za předpokladu že nastal jev Z)
- $P(Z)$ : "*Prior*"
- $P(X)$ : "*Marginal*"

*Důkaz dostupný v Joyce 2021.*

Bayesovskou síť pak definujeme následovně:

Nechť  $X = (X_1, X_2, \dots, X_n)$  jsou náhodné proměnné.

**Bayesovská síť** je orientovaný acyklický graf (*directed acyclic graph*) – tedy topologicky uspořádaný graf – který specifikuje sjednocenou pravděpodobnostní distribuci skrze  $X$  jako součin lokálně podmíněných distribucí pro každou z uspořádaných dvojic:

$$P = (X_1 = x_1, X_2 = x_2, \dots, X_n = x_n) = \prod_{i=1}^n p(x_i | x_{parent(i)})$$

Iliopoulou et al. 2020 Flugge, Zimmer a Petersohn 2019

### 1.2.1 Reprezentace znalostí

K reprezentaci znalostní báze můžeme využít Bayesovskou síť - systém sekvencí procesů, jejichž výstup je vstupem pro další (následující) proces. Více takto zřetězených sekvencí pak zkombinujeme do grafové reprezentace znalostní báze ve formě orientovaného acyklického grafu. Každý z vrcholů grafu koresponduje s proměnnou a každá hrana grafu reprezentuje podmíněnou závislost mezi uspořádanými dvojicemi vrcholů. Geron (2017)

### 1.2.2 Práce s neurčitostí - Pravděpodobnostní grafické modely

Pravděpodobnostní grafické modely (*probabilistic graphical models* dále jen *PGM*) jsou ideální modelování a reprezentaci znalostní báze. Výhody reprezentace znalostní báze formou PGM:

- Komplexní báze je sestavena kombinací elementárních komponent (modularita)
- Teorie grafů nabízí intuitivní reprezentaci kauzálních vztahů
- Pravděpodobnostní teorie (Bayes theorem [Soni 2018](#)) nabízí způsob jak propojit proměnné s ohledem na neurčitost


Pro reprezentaci Bayesovské sítě pomocí PGM je nutné definovat dvě komponenty:

1. Orientovaný acyklický graf
2. Conditional probabilistic table (CPT)

Tímto způsobem je možné sestavit **reprezentaci doménové znalosti experta**, a to včetně možnosti **reprezentace neurčitosti**. [Iliopoulou et al. 2020](#)

#### Orientovaný acyklický graf

Z matematických vlastností orientovaného acyklického grafu (dále jen *DAG*) – *dosažitelnosti*, *tranzitivního uzávěru* a *tranzitivní redukce* lze obecně vyvodit tři základní a unikátní 3-vrcholové vzory vrcholů jejichž kombinací lze následně DAG konstruovat.



Obrázek 1: Tři základní 3-vrcholové vzory vrcholů DAG

Pro úplnost ještě zrekapitulujeme základní pravidla DAG které vyplývají z výše zmíněného:

- Hrany reprezentují podmíněné závislosti vrcholů
- Hrany jsou orientované
- DAG **nemůže** být cyklický – narušili bychom předpoklad **topologického** uspořádání Flugge, Zimmer a Petersohn 2019

### Tabulka podmíněných závislostí


Tabulka podmíněných závislostí (*Conditional probabilistic table* zaměnitelně *Conditional probability distribution*, dále jen *CPT*) reprezentují sílu závislosti dvou vrcholů a vychází z Bayesovy věty. Jinými slovy čím vyšší hodnota vztahu dvou proměnných, tím vyšší pravděpodobnost nastane jev A v závislosti na jevu B. V první řadě, v expertním systému nejsou CPT výsledkem učení se z dat - jelikož žádná data nemáme k dispozici. Místo toho jsou váhy určeny na základě doménových znalostí experta.

Při sestavování znalostní báze je kritická správná interpretace informací obdržených od experta. Je velmi důležité, aby obě strany (příjemce a odesílatel) vnímali prezentované informace ve stejném kontextu.

Jednoduchý příkladem je následující scénář. Expert (odesílatel) příjemci předává doménovou znalost o zítřejším počasí ve dvou různých zemích:

- Zítřka bude v Anglii *pravděpodobně* celý den pršet
- Zítřka bude v Egyptě *pravděpodobně* celý den pršet

Příjemce by si mohl slovo *pravděpodobně* v obou příkladech vyčíslit zcela odlišně. Proto je při přejímání doménových znalostí od experta velmi důležité vyvarovat se nedorozuměním spojených s kontextem. Při konstrukci CPT lze využít některé z numericky definovaných pravděpodobností často misinterpretovaných frází.



Obrázek 2: Distribuce pravděpodobnosti slov Iliopoulou et al. 2020

Použití CPTs tedy získáváme možnost, jak v modelované bázi reprezentovat neurčitost, tím, že definujeme hodnotu hran uspořádaných dvojic vrcholů.

### 1.2.3 Odvozování

Odvozování (*inferenci*) v Bayesovské síti lze provést několika způsoby. Mezi populární formalizované postupy patří:

- Variable Elimination Soni 2018
- Forward Inference Soni 2018
- Backward Inference Soni 2018

### 1.3 IF-THEN pravidla a Fuzzy logika (NEST)

„NEST (*Nový Expertní SysTém*) je inteligentní počítačový program, využívající znalosti a inferenční procedury k řešení problémů, které jsou natolik obtížné, že vyžadují významnou lidskou expertízu.“ Berka 2004b

#### 1.3.1 Reprezentace znalostí

Systém NEST reprezentuje znalosti pomocí pravidel ve tvaru:

IF předpoklad THEN závěr AND akce

kde předpoklad reprezentujeme disjunktivní formou literálů a závěr seznamem literálů.

Atributy a výroky lze dle jejich hodnot dělit následovně:

##### Atributy (popisují prostředí)

- binární
- jednoduché nominální
- množinové nominální
- numerické Berka 2004a

##### Výroky

- binární = boolean (true, false)
- jednoduché nominální = množina přípustných hodnot atributu
- množinové nominální = množina přípustných hodnot atributu
- numerické = fuzzy intervaly (*horní a dolí crisp a fuzzy mez*) Berka 2004a

#### 1.3.2 Práce s neurčitostí - Fuzzy logika

použity kombinační funkce pro práci na intervalu  $[-1, 1]$ :

- **NEG** pro výpočet váhy negace výroku,
- **CONJ** pro výpočet váhy konjunkce výroků,
- **DISJ** pro výpočet váhy disjunkce výroků,
- **CTR** pro výpočet příspěvku pravidla k váze závěru,
- **GLOB** pro skládání příspěvků více pravidel.

*Kombinační funkce převzaty z Berka 2004b.*


#### 1.3.3 Odvozování

Odvozování (*inferenci*) v síti pravidel můžeme provést na základě logických pravidel (využitím *modus ponens*) - tzv. nekompozicionální odvozování. Nebo zpětným a přímým řetězením v rámci kompozicionálních a apriorních pravidel. Při inferenci rovněž probíhá kontrola neporušení integritních omezení.

## 2 Metody

### 2.1 Bayesovská síť

Pro účely demonstrace reprezentace znalostní báze byl sestaven triviální model, na kterém lze dotazovat inference. Pro jednoduchost se skládá pouze ze tří čtyř vrcholů (*with\_partner*, *feel\_good*, *cinema*, *horror*) a má za účel doporučit za jakých okolností se podívat na film hororového žánru. Iliopoulou et al. 2020



Obrázek 3: Vizualizace triviální Bayesovské formou DAG (autor)

- *with\_partner*: indikuje, zda film budeme sledovat s partnerem, či samostatně
- *feel\_good*: závisí na atributu *with\_partner* a indikuje, zda jsme v dobré náladě
- *cinema*: závisí na atributu *with\_partner* a indikuje, zda film budeme sledovat v kině, či doma
- *horror*: závisí na attributech *feel\_good* a *cinema* a indikuje, zda film bude hororového, či jiného žánru

#### 2.1.1 Konzultace znalostní báze

Na modelu byly provedeny následující inference:

- *Make inference on watching horror movie, given i am without partner*
- `q1 = bn.inference.fit(model, variables=['horror'], evidence={'with_partner':0})  
print(q1.df)`

horror	P
0	0.809
1	0.191

Tabulka 1: Výsledek prvního dotazu na znalostní bázi reprezentovanou BN



- # Make inference on watching horror movie, given i am with partner and we feel good  
`q2 = bn.inference.fit(model, variables=['horror'], evidence={'feel_good':1, 'with_partner': 1}) print(q2.df)`

horror	P
0	0.175
1	0.825

Tabulka 2: Výsledek druhého dotazu na znalostní bázi reprezentovanou BN

- *Make inference on watching horror movie, given i go to cinema (no further specification)*  
`q3 = bn.inference.fit(model, variables=['horror'], evidence={'cinema':1}) print(q3.df)`

horror	P
0	0.398649
1	0.601351

Tabulka 3: Výsledek třetího dotazu na znalostní bázi reprezentovanou BN

- *Make inference on likelihood that i will go to cinema when i watch horror*  
`q4 = bn.inference.fit(model, variables=['cinema'], evidence={'horror':1}) print(q4.df)`

cinema	P
0	0.129159
1	0.870841

Tabulka 4: Výsledek čtvrtého dotazu na znalostní bázi reprezentovanou BN

- *Make inference on likelihood that i will be with partner when i watch horror*  
`q5 = bn.inference.fit(model, variables=['with_partner'], evidence={'horror':1}) print(q5.df)`

with_partner	P
0	0.0747554
1	0.925245

Tabulka 5: Výsledek pátého dotazu na znalostní bázi reprezentovanou BN

*Kompletní zdrojový kód modelu pro replikaci je dostupný v příloze.*

## 2.2 NEST

Pro účely demonstrace byla sestavena jednoduchá znalostní báze v expertním systému NEST, sloužící k doporučení žánru filmu.

### 2.2.1 Cíle

**Dokumentární film**

**SciFi**

**Horror**

### 2.2.2 Výroky

**Délka filmu** Délka filmu se udává v minutách, pro naše potřeby předpokládáme, že nejdelší jsou filmy ze žánru sci-fi. Nejkratší naopak dokumenty, které se často soustředí na jednu konkrétní oblast. Horror je mezi těmito dvěma žánry se střední délkou

- >90 minut - SciFi
- 60-90 - Horror
- <60 - Dokument

**Film je založený na pravdě** U sci-fi už z názvu vyplývá, že jde o výmysl, tudíž nemůže být založený na pravdě, může se však inspirovat některými reálnými motivy. Horror může i nemusí být založený na pravdě, často přebírají reálnou událost, která je však kreativně upravena pro větší zaujetí diváků. Dokument musí být založený čistě na pravdě, jelikož se snaží pravdivě vysvětlit a předat nějakou událost nebo věc.

- Dokument bude 100%
- SciFi 10%
- Horror 50%

**V jakém roce se film odehrává** Sci-fi se nejpravděpodobněji odehrává v budoucnosti, jelikož to dává studiu největší kreativní volnost, může však být o cestování časem a odehrávat se tak částečně i v minulosti. Horror se může odehrávat v jakémkoliv období, předpokládáme však, že je ze současnosti. Dokument nejčastěji pojednává o věcech, které se již staly a je tak v minulosti.

**Budget filmu** U sci-fi se předpokládá, že bude mít nejširší divácké spektrum, proto si mohou dovolit mít nejvyšší rozpočet. Horror bude mít průměrný rozpočet, nebude mít nejspíše tolik diváků jako sci-fi, ale zároveň více než dokumenty, které mají rozpočet nejmenší.

**Kolik je v hlavních rolích známých herců** Známí herci jsou důležitou složkou úspěšných filmů, pravděpodobně nejvíce jich bude ve sci-fi filmech, které mají vysoký rozpočet a mohou si je dovolit zaplatit. Dokumentem může provázet i jedna osoba jako vypravěč, není však kritická, proto nemusí být známá. U hororu lze očekávat něco mezi, v závislosti na rozpočtu může mít několik známých herců nebo i žádného.

- Hodně - 3, 4 a více herců
- Středně - 2 a 3 herci
- Málo - 0 a 1 herců

**Jak je velké studio?** Velké studia jsou potřeba pro velké filmy s velkým rozpočtem, v našem případě tedy sci-fi. Hororové filmy nemají takový dosah a rozsah, budou se jimi zabývat spíše malé a střední studia.

- Malé - Dokument
- Horror Střední - Dokument
- Horror Velké - SciFi

**Hodnocení filmu** Parametr z hodnotících serverů pro filmy. Pro naše účely předpokládáme, že vysokorozpočtové filmy mají vyšší hodnocení, z toho lze usoudit, že sci-fi bude hodnoceno nejlépe, dokument má poměrně nízký dosah a nebude mít tolik hodnocení a horor bude mít průměrné hodnoty.

- Hodně - 70-100%
- Středně - 50-60%
- Málo - 0-49%

**Naplněnost sálu** Nejvíce naplněný bude sál vysílající sci-fi, jelikož má nejvyšší potencionální dosah. Naproti tomu u dokumentu lze očekávat málo naplněný sál a horor bude mít variabilní hodnotu naplněnosti v závislosti na konkrétním titulu, pro naše potřeby předpokládáme okolo poloviny kapacity.

- SciFi - hodně
- Horror - středně
- Dokument - málo

**Kolik dílů je v sérii** Fanoušek filmové série půjde na další díl i přes nízké hodnocení, lze očekávat že sci-fi tituly budou mít vzhledem k většímu rozpočtu a divácké základně více dílů na pokračování. Dokument pojednává většinou o jedné konkrétní věci, kterou lze předat v jednom filmu, výjimky jsou poté například dvoudílné dokumenty. Horor často bývá samostatně, může však mít i několik dílů, očekávat lze ale méně než u sci-fi.

Otázka je z důvodu, jestli potřebuje Labužník vidět nějaké filmy předtím. SciFi mává spoustu dílů (StarWars), dokument bývá jeden, max dva filmy, horor může mít 3 díly

- Hodně - 4 a více filmů
- Středně - 2 nebo 3 filmy
- Málo - 1 film

**Používá film speciální efekty** Již z podstaty žánru můžeme přepokládat, že sci-fi bude mít nejvíce speciálních efektů, jak z příběhové stránky, tak díky vyššímu rozpočtu. Horor může použít několik speciálních efektů pro některé scény, zdaleka však ne tolik jako sci-fi. Dokument z nich bude mít nejméně efektů, často pouze pro vizualizace.

- Hodně - SciFi
- Středně - Dokument, Horror
- Málo - Dokument, Horror

### 2.2.3 Pravidla

1. *Pokud je dílů v sérii hodně a používá hodně speciálních efektů, je to jistě sci-fi*
2. *Pokud se film odehrává v minulosti a má nízký budget, asi to není sci-fi*
3. *Pokud není film založený na pravdě a má hodně dílů v sérii, jistě to není dokument*
4. *Pokud na filmu pracuje velké studio a sál je naplněný, je nejspíše to sci-fi*
5. *Pokud film používá málo speciálních efektů a má nízký budget, není to jistě sci-fi*
6. *Pokud je rozpočet filmu střední a má nízké hodnocení, jde nejspíše o horor*
7. *Pokud je ve filmu hodně známých herců a má vysoké hodnocení, jde nejspíše o sci-fi*
8. *Pokud je délka filmu pod 60 minut, má málo známých herců a nepoužívá speciální efekty, jde nejspíše o dokument*
9. *Pokud je nízké hodnocení filmu a je z poloviny založený na pravdě, jde asi o horor*
10. *Pokud je plně naplněný filmový sál a film se odehrává v budoucnosti, jde jistě o sci-fi*
11. *Pokud je ve filmu málo známých herců a filmový sál je málo naplněný, jde nejspíše o dokument*
12. *Pokud je rozpočet filmu vysoký a je delší než 60 minut, jde asi o sci-fi*
13. *Pokud se film odehrává v minulosti (nebo pojednává o historii) a pracovalo na něm malé studio, jde nejspíše o dokument*
14. *Pokud je film velmi málo založený na pravdě a odehrává se v budoucnosti, jde jistě o sci-fi*

15. *Pokud na filmu pracuje středně velké studio a má nízké hodnocení, jde nejspíše o horor*

#### 2.2.4 Integritní omezení

- Dokument není v budoucnosti
- Dokument musí být založený na pravdě
- Sci-fi nemůže být založeno na pravdě

### 3 Výsledky

V softwaru NEST byla sestavena ukázka expertního systému určeného k odvození filmového žánru za pomoci tvrdých dat o filmu - konkrétně ohledně zákaznických preferencí. Jedná se o zjednodušený pohled na realitu, kdy je vybíráno pouze ze tří žánrů, které se mezi sebou pouze nepatrně prolínají. Model nepřipouští žádné externí faktory (profil zákazníka a kontextové proměnné). Pomocí softwaru bnlearn byla sestavena zjednodušená Bayesovská síť pro inferenci podmínek, za jakých se uživatel půjde podívat pravděpodobně na hororový film. Inferenci by zde šlo využít i v opačném pohledu – a to k vytvoření segmentů, které definují typ zákazníků kteří např. rádi sledují hororové filmy v kině. Takové segmenty pak lze využít např. k lepšímu zacílení reklamy.

### 4 Diskuze

Jako efektivnější volba pro konstrukci znalostní báze by se jevila více granulární distribuce atributů. Pokud bychom atributy rozdělili do třech množin následovně:

- $U$  - množina proměnných uživatelského charakteru (věk, pohlaví, ...)
- $S$  - množina proměnných o kontextu (kdo - pár, skupina kamarádů, samotný; lokace - domov, kino, ... ; nálada - šťastný, smutný, nostalgický, ...)
- $C$  - množina proměnných o filmu (režisér, stopáž, herci, ...)

Konzultace znalostní báze by tak postupně mohla zpřesňovat konzultaci, na základě širšího spektra poskytnutých informací. Dle naší hypotézy by toto přineslo přesnější doporučení.

### 5 Závěr

Práce zdařile ukazuje možnost odvození žánru filmu od obecných atributů filmů a filmových preferencí zákazníka. Tento model je pouze ukázkou, jak by podobný systém mohl fungovat, proto práce vysvětluje, jaké jsou další způsoby tvorby expertních systémů a jak by se takový systém dal rozšířit pro to, aby reálně mohl být užitečný z business hlediska pro pobočky kina, nebo streamovací služby.

## 6 Reference

### Odkazy

- Berka, Petr (2004a). “Expertni systemy”. In: *sorry.vse.cz/berka*.
- (2004b). “Novy Expertni SysTem”. In: *sorry.vse.cz/berka*.
- Flugge, Sebastian, Sandra Zimmer a Uwe Petersohn (zář. 2019). “Knowledge representation and diagnostic inference using Bayesian networks in the medical discourse”. In: arXiv: 1909.08549 [cs.AI].
- Geron, Aurelien (2017). *Hands-on machine learning with Scikit-Learn and TensorFlow : concepts, tools, and techniques to build intelligent systems*. Sebastopol, CA: O’Reilly Media. ISBN: 978-1491962299.
- Iliopoulou, Konstantina et al. (2020). “Improving Movie Recommendation Systems Filtering by Exploiting User-Based Reviews and Movie Synopses”. In: *Artificial Intelligence Applications and Innovations. AIAI 2020 IFIP WG 12.5 International Workshops*. Springer International Publishing, s. 187–199. DOI: 10.1007/978-3-030-49190-1\_17.
- Joyce, James (2021). “Bayes Theorem”. In: *The Stanford Encyclopedia of Philosophy*. Ed. Edward N. Zalta. Fall 2021. Metaphysics Research Lab, Stanford University.
- Russell, Stuart J. a Peter Norvig (2009). *Artificial Intelligence: a modern approach*. 3. vyd. Pearson.
- Soni, Devin (2018). “Introduction to Bayesian Networks”. In: *towardsdatascience.com*.

### Přilohy

AND\_OR\_GRAPH.png  
dag.py