

Proces riešenia problému a multigraf

Juraj Kubiš

Riešením netriviálnych problémov získavame nové poznatky, resp. inovácie vyšších rádoov. Na meranie procesu riešenia použijeme konštrukciu pravdepodobnostného multigrafu podľa [1].

1. Pravdepodobnostný multigraf

Stochastické (pravdepodobnostné) multigrafy (orientované grafy s viacnásobnými hranami) sa používajú na modelovanie procesov s možnosťou opakovania niektorých skupín ich činností. V sieťovej analýze sa stochastické modelovanie opiera jednak o možnosti použiť zovšeobecnené uzly so stochastickou výstupnou časťou (stochastická topológia), jednak o možnosti použiť stochastické ohodnotenie činnosti časom, zdrojmi, nákladmi a pravdepodobnosťami jej výskytu. Na tieto skutočnosti nadväzuje použitie simulácií ako prostriedku modelovania možného priebehu projektu [1].

Podľa [2] má dobrý simulačný model navyše aj predikčnú silu, ktorá umožňuje pomocou rozhodnutia optimalizovať budúce stavy projektu, projektovaného systému vrátane jeho budúcich rizík.

Model, ktorý je východiskom riešenia, je znázornený na obr. 1 a je to hranovo orientovaný graf.

2. Riešenie problému

Riešením problému je už samotné učenie sa riešiteľského tímu a organizácie, v ktorej pôsobí. Všeobecne možno konštatovať, že schopnosť firmy učiť sa zo svojich skúseností je vlastnosť nutná na prežitie. V súvislosti s učením sa používa pojem učenie sa v slučke, v dvojitej slučke (v kyberneti-

ke by sme hovorili o vlastnej spätnej väzbe, resp. o dvojitej vlastnej spätnej väzbe). Traduje sa, že prvá definícia bola publikovaná v prameni [3], teda v roku 1978, avšak model prevzatý z prameňa [1] je o 4 roky starší. Objasníme tieto pojmy podľa literárnych zdrojov.

Pod jednoduchou slučkou rozumieme dôležitú formu učenia, ktoré mení stratégie konania (strategies of action) alebo predpoklady, na ktorých sú tieto stratégie založené. Mení ich takým spôsobom, že ponecháva hodnoty teórie konania (theory of action) nezmenené [4, s. 20]. Autori uvádzajú i nasledovné príklady:


- Pracovníci kontroly kvality zistia chybný výrobok, odovzdajú túto informáciu produktovým inžinierom, ktorí následne zmenou konštrukcie výrobku alebo výrobných metód môžu vznik tejto závary eliminovať.
- Marketingoví manažéri zistia, že mesačný predaj klesol pod očakávanie a začnú hľadať vysvetlenia tohto poklesu, ktoré by mohli použiť na vypracovanie nových

marketingových stratégií pre zvrátenie vývoja krivky obratu.

- Líniovní manažéri reagujú na zvýšenú fluktuáciu pracovníkov zisťovaním zdrojov ich nespokojnosti hľadajúc faktory, ktoré môžu ovplyvniť, ako napr. mzdové úrovne, nepeňažné odmeňovanie, dizajn pracovného miesta.

V takýchto prípadoch učenia jednoduchá slučka, sprostredkovaná organizačným hľadaním príčiny (organizational inquiry), spája zistenú chybu, teda výsledok aktivity, ktorý sa nezhoduje s očakávaniami, a preto prekvapuje – a organizačné stratégie konania a predpoklady, na ktorých tieto stoja. Uvedené stratégie alebo predpoklady sú modifikované, aby sa dosiahli výsledky organizácie v hraniciach daných existujúcimi organizačnými hodnotami a normami [4].

Pod dvojitou slučkou rozumieme učenie, ktoré vyplýva zo zmeny hodnôt používanej teórie (theory-in-use), ako aj jej stratégií a predpokladov. Dvojité slučka sa vzťahuje na dve slučky spätnej väzby, ktoré spájajú



počet uzlov $m = 7$
počet hrán $h = 12$

Číslo	Činnosť	Číslo	Činnosť	Znak	Druh uzla
0	štart	5	opakovanie riešenia	KD	konjunktívno-deterministický
1	formulácia	6	problém je neriešiteľný	IS	inkluzívno-stochastický
2	úprava pravidiel	7	verifikácia	KS	konjunktívno-stochastický
3	opakovanie formulácie	8	opakovanie verifikácie		
4	riešenie				

Obr.1 Stochastický multigraf procesu riešenia problému

pozorované výsledky aktivity so stratégiami a ich určujúcimi hodnotami. Stratégie a predpoklady sa môžu zmeniť súčasne alebo následkom zmeny v hodnotách. Dvojitá slučka učenia môže prebiehať na úrovni jednotlivca, keď hľadanie príčin vedie k zmene hodnôt v používaných teóriách, alebo na úrovni organizácie, keď jednotlivci hľadajú príčiny v zmene organizácie tak, že to povedie k zmene používaných teórií organizácie [4].

Učenie dvojitou slučkou zahŕňa skúmanie kauzality s cieľom objasniť logiku skrývajúcu sa za problémom. Vyžaduje nové myslenie o probléme – zmenu základných intencií, v ktorých o probléme uvažujeme [5].

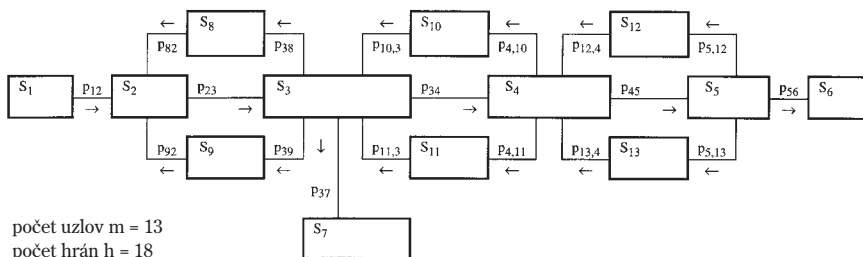
Autori vo všeobecnosti rozlišujú dve úrovne učenia – ako rozdiel medzi učením sa v kontexte predpokladov určujúcich problém a učením, ktoré transformuje tieto pôvodné podmienky v priebehu riešenia problému. Podmienky sa označujú ako inkrementálne a transformatívne [7], adaptívne a generatívne [8], učenie „ako“ a učenie „prečo“ [9] alebo učenie už spomínanou jednoduchou a dvojitou slučkou [10]. Hoci rozdiel medzi týmito dvomi druhmi učenia nie je vždy jasne vymedziteľný pri posudzovaní jednotlivých prípadov v praxi, koncepcne je dôležitý rozdiel medzi rozsahom, efektom a možnými prekážkami [5].

Aplikáciu tohto princípu zdôrazňuje i prameň [6, s. 27]: Podniky potrebujú kapacity na učenie sa v dvojitej slučke. Učenie sa v dvojitej slučke nastáva, keď manažéri skúmajú svoje predpoklady a sledujú, či teória, na ktorej boli postavené, zodpovedá súčasným faktom, pozorovaniam a skúsenostiam. Manažéri tiež potrebujú spätnú väzbu, aby zistili, či sa plní plánovaná stratégia – čo je proces učenia sa v jednoduchej slučke. Ale ešte dôležitejšia je spätná väzba, ktorá poskytuje informácie o tom, či plánovaná stratégia zostáva životaschopná a úspešná – to znamená proces učenia sa v dvojitej slučke.

3. Transformácia multigrafu

Prevodom grafu na uzlovo orientovaný odstránime násobné hrany, takže získame pravdepodobnostný digraf. Výsledok transformácie je uvedený na obr. 2. Jednotlivé uzly (stavy) digrafu (procesu) majú nasledovný význam:

- S₁ – štart procesu riešenia problému,
- S₂ – formulácia problému,
- S₃ – riešenie problému,
- S₄ – verifikácia riešenia problému,
- S₅ – vyhodnotenie verifikácie riešenia problému,
- S₆ – riešenie problému bolo získané,
- S₇ – riešenie problému sa nenašlo,
- S₈ – úprava pravidiel formulácie problému,
- S₉ – opakovanie formulácie problému,
- S₁₀ – úprava pravidiel riešenia problému,



počet uzlov m = 13
počet hrán h = 18

Obr.2 Stochastický digraf procesu riešenia problému

- S₁₁ – opakovanie riešenia problému,
- S₁₂ – úprava pravidiel verifikácie riešenia problému,
- S₁₃ – opakovanie verifikácie riešenia problému.

S ₄	P ₄₅	80
	P _{4,10}	90
	P _{4,11}	100
S ₅	P ₅₆	80
	P _{5,12}	90
	P _{5,13}	100

Transformácie typu hranovo-uzlovo orientovaný graf môžeme používať všeobecne v prípadoch, ak tým získame výhodnejšie prostredie na riešenie alebo ak modelovaný proces (projekt) je tým prehľadnejší a názornejší.

4. Simulácia procesu

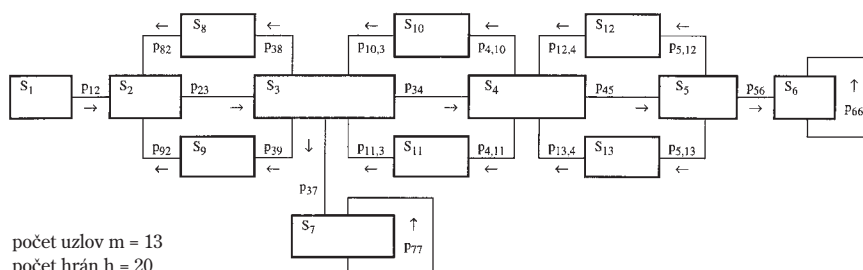
Postup je v tomto prípade jednoduchý. Zvolíme pravdepodobnosti stochastických výstupov a pomocou generátora náhodných čísel vypočítame postupnosti prechodov cez graf až po dosiahnutie konečného výsledku (riešenie problému alebo vyhlásenie o neriešiteľnosti problému – možno len subjektívny názor riešiteľského tímu).

Nech sú známe empirické výsledky z minulých riešení, ktoré umožnili definovať nasledovné pravdepodobnosti stochastických výstupov:

S ₃	P ₃₄	= 0,80
	P ₃₇	= 0,10
	P ₃₈	= 0,06
	P ₃₉	= 0,04
S ₄	P ₄₅	= 0,8
	P _{4,10}	= 0,1
	P _{4,11}	= 0,1
S ₅	P ₅₆	= 0,8
	P _{5,12}	= 0,1
	P _{5,13}	= 0,1

Zvolíme generovanie náhodných čísel z intervalu 1 až 100. Nastavíme hraničné hodnoty pre vetvenie pri výstupe z uzla:

S ₃	P ₃₄	80
	P ₃₇	90
	P ₃₈	96
	P ₃₉	100



počet uzlov m = 13
počet hrán h = 20

Obr.4 Absorpčný Markovov reťazec procesu riešenia problému

Použijeme postupnosť náhodných čísel:

- a) 87,
- b) 38, 77, 15,
- c) 2, 7, 84, 28.

Dostaneme nasledovné postupnosti prechodov grafom (obr. 3).

a	S ₁	→	S ₂	→	S ₃	→	S ₇										
b	S ₁	→	S ₂	→	S ₃	→	S ₄	→	S ₅	→	S ₆						
c	S ₁	→	S ₂	→	S ₃	→	S ₄	→	S ₅	→	S ₁₂	→	S ₄	→	S ₅	→	S ₆

Obr.3

Výsledok:

- a) priamou cestou sa ukončilo riešenie bez úspechu,
- b) priamou cestou sme získali výsledok riešenia problému,
- c) k výsledku riešenia sme sa dostali cez jeden opakovací cyklus.

Po týchto troch pokusoch by sme mohli predbežne prehlásiť, že v 1/3 prípadov je výsledok tímu negatívny a v 2/3 prípadoch je pozitívny. Opakovaním veľkého počtu (akého?) behov simulácie by sme sa dostali k istému odhadovanému intervalu spoľahlivosti o úspešnosti, resp. neúspešnosti riešiteľského tímu.

Referenčné hodnoty modelu môžeme získať rýchlejšie h-krát (v našom prípade 18-krát) a presne. Použijeme teóriu Markovových reťazcov, (porov. napr. prameň [11]). Získané referenčné hodnoty sa môžu používať aj ako limitné hodnoty na definovanie počtu opakovaní simulačných behov, pri ktorých sa skúmajú i ďalšie parametre modelu.

5. Markovov reťazec

Pre naše potreby využijeme kategóriu: konečný, homogénny, absorpčný Markovov

P	S ₁	S ₂	S ₃	S ₄	S ₅	S ₆	S ₇	S ₈	S ₉	S ₁₀	S ₁₁	S ₁₂	S ₁₃
S ₁	0	1	0	0	0	0	0	0	0	0	0	0	0
S ₂	0	0	1	0	0	0	0	0	0	0	0	0	0
S ₃	0	0	0	P ₃₄	0	0	P ₃₇	P ₃₈	P ₃₉	0	0	0	0
S ₄	0	0	0	0	P ₄₅	0	0	0	0	P _{4,10}	P _{4,11}	0	0
S ₅	0	0	0	0	0	P ₅₆	0	0	0	0	0	P _{5,12}	P _{5,13}
S ₆	0	0	0	0	0	1	0	0	0	0	0	0	0
S ₇	0	0	0	0	0	0	1	0	0	0	0	0	0
S ₈	0	1	0	0	0	0	0	0	0	0	0	0	0
S ₉	0	1	0	0	0	0	0	0	0	0	0	0	0
S ₁₀	0	0	1	0	0	0	0	0	0	0	0	0	0
S ₁₁	0	0	1	0	0	0	0	0	0	0	0	0	0
S ₁₂	0	0	0	1	0	0	0	0	0	0	0	0	0
S ₁₃	0	0	0	1	0	0	0	0	0	0	0	0	0

Obr.5

p(0) = (1, 0, ..., 0)			
krok	p ₆	p ₇	ostatné
(0)	0	0	1
(3)	0	0,1	0,9
(5)	0,512	0,1	0,388
(6)	0,512	0,126	0,362
(9)	0,72704	0,13532	0,13764
(12)	0,809165	0,138818	0,052017
(15)	0,840217	0,140139	0,019644
(18)	0,851944	0,140637	0,007419
(21)	0,856373	0,140825	0,002802
(25)	0,858046	0,140896	0,001058
(30)	0,858916	0,140933	0,000151
(35)	0,85904	0,140937	0,000023
(40)	0,859053	0,140939	0,000008
(41)	0,859057	0,140939	0,000004

Tab.1 Vývoj absolútnych pravdepodobností vybraných stavov Markovovho reťazca

reťazec. Grafický záznam je na obr. 4. Prakticky pribudli dve slučky. Vlastná spätná väzba znamená, že ak sa proces dostane do stavu (uzla), ktorý má vlastnú spätnú väzbu a nie je z neho výstup, tak končí, zostáva v tomto stave (uzle).

Matica prechodov **P** má tvar podľa obr. 5.

V tab. 1 uvádzame postupnosť konvergenzie Markovovho reťazca k limitnému roz-

deleniu absolútnych pravdepodobností pre zhodné pravdepodobnosti prechodu ako v predošlom príklade. Vychádzame z predpokladu, že vektor východiskových pravdepodobností má tvar

$$p(0) = [p_1(0) = 1, p_2(0) = 0, \dots, p_{13}(0) = 0]$$

teda proces začína v stave S₁. Vieme, že absorpčné stavy sú len dva (S₆, S₇), preto si budeme všimaf len ich hodnoty pravdepodobností (absolútne, teda nepodmienené).

Môžeme vyhlásiť záver, že pri daných pravdepodobnostiach prechodov v grafe je 14 % prípadov riešenia problémov skúmaného tímu výsledok negatívny a v 86 % prípadoch je pozitívny.

Záver

I zložité môže byť jednoduché, ak použijeme správnu metódu.

Literatúra

- [1] TRÁVNIK, I., VLACH, J.: Sieťová analýza. 1. vyd. Bratislava: ALFA 1974, 308 s.
- [2] WEINBERGER, J., PIVOŇKA, P.: Řízení projektů a řízení rizik. II. část: Význam simulace a optimalizace při řízení projek-

toých rizik. IT System, 2002, č. 7 – 8, s. 38 – 39.

[3] ARGYRIS, C., SCHÖN, D. A.: Organizational Learning. Reading, Mass.: Addison-Wesley 1978.

[4] ARGYRIS, C. A SCHÖN, D. A.: Organizational Learning II. Addison-Wesley 1996.

[5] ŠÁRNIK, M.: Organizačný rozvoj: prístup organizačného učenia. Diplomová práca. Fakulta manažmentu Univerzity Komenského. Bratislava 2001.

[6] KAPLAN, R. S., NORTON, D. P.: BALANCED SCORECARD - strategický systém měření výkonnosti podniku. 1. Vyd. Praha: MANAGEMENT PRESS, 2000, 267 s.

[7] DIBELLA, A. J., NEWIS, E. C.: How Organizations Learn. Jossey-Bass 1998.

[8] SENGE, P.: The Fifth Discipline. Doubleday 1990.

[9] MOINGEON, B., EDMONDSON, A.: When to Learn How and When to learn Why in Organizational Learning and Competitive Advantage. SAGE Publications 1996, pp. 15 – 35.

[10] ARGYRIS, C.: Organizational Learning. Addison-Wesley 1978.

[11] HUŤKA, V.: Teória pravdepodobnosti II. 1. vyd. Bratislava: Fakulta hospodárskej informatiky EU, 1996, 159 s.

Ing. Juraj Kubiš, CSc.
Slovakodota, a. s.
Bratislava