

## NEURONOVÝ ROZHODOVACÍ MODEL O KAPITALIZACI PODNIKU

M. Pokorný, O. Trenz, V. Konečný

**Došlo: 15. prosince 2006**

### Abstract

POKORNÝ M., TRENTZ O., KONEČNÝ V.: *Neural decision model of business capitalization*. Acta univ. agric. et silvic. Mendel. Brun., 2007, LV, No. 3, pp. 97–104

The topic of this article is focused on problems related to enterprise financial supervising. In the concrete, the situation of enterprise investment policy evaluation is described here. In this case, as a convenient tool for decision support, the approach of artificial intelligence was selected, particularly the model of neuron network.

For the purpose of enterprise economic state evaluation, we use four input variables which describe the economic state. Three main variables are selected and the fourth one is the additional. The coding of main variables is chosen with the respect to the possible states of the enterprise. The multilayer neuron network was used for evaluation.

The neural network can solve problems, which are hardly solvable for a manager because there can exist a lot of factors affecting the final decision. We have to take into account the fact that sometimes the situation is too complex. In this case, when the system gives incorrect result, it is possible to extend the current learning set and add adequate patterns which will help the system to recognize states of the enterprise.

decision problem, artificial intelligence, neural networks

Ekonomické rozhodovací procesy podnikového managementu se často potýkají s vysokou složitostí rozhodovaného problému (Živělová, 1998; taktéž v Sůvová, 1999). Například *klasifikační* problém je charakteristický řadou vstupních proměnných, jejichž vyhodnocení dává určitý závěr. Vstupní proměnné odrážejí jisté výkonnostní charakteristiky podniku, závěr z rozhodnutí pak představuje klasifikaci do určité množiny možných výsledků. Řešení takového rozhodovacího problému je mnohdy velmi náročné, neboť i expert v dané oblasti není často schopen zvážit všechny možné vstupní varianty a u každé z nich jednoznačně rozhodnout o výsledku. Typické příklady lze najít například v oblasti finančního řízení podniku nebo v oblasti identifikace preferencí zákazníků.

Počítačová podpora klasifikačního problému technologiemi umělé inteligence obvykle vede k využití *expertních systémů* nebo *neuronových sítí*. V případě,

že je možné definovat pravidla rozhodování, bude efektivní použití expertního systému. V případě, že pro soubor vstupních vektorů jsou definovatelné výstupy, bude pravděpodobně efektivnější neuronová síť, což se týká i problému rozhodování o podkapitalizaci podniku. Cílem tohoto příspěvku bude návrh modelu pro rozhodování o celkové finanční situaci podniku.

### MATERIÁL A METODY

Pro zjednodušení problému budeme předpokládat, že rozhodování o podkapitalizaci podniku bude probíhat na základě hodnot čtyř vstupních proměnných, viz tab. I. Tři z nich budou považovány za *kmenové* ( $x_1$ ,  $x_2$  a  $x_3$ ) a jedna za *doplňkovou* ( $x_4$ ). V doplňkové proměnné je zahrnut vliv několika méně důležitých faktorů. Pro podrobnější zkoumání může být počet kmenových proměnných rozšířen.

Každá z uvedených proměnných může nabývat tří hodnot ve významu: *pozitivní extrém* (1), *nevyhraněná situace* (0) a *negativní extrém* (–1).

Výsledek klasifikace nechť představuje proměnná  $v$ , která nabývá stejných hodnot jako proměnné vstupní. To znamená, že rozhodnutí o stavu podniku může být: *podkapitalizován*, *překapitalizován* nebo v *nevyhraněné* situaci.

Hodnoty vstupních proměnných tvoří *vstupní vektor* a množina vstupních vektorů a jim odpovídající klasifikace – *báze vstupních vzorů*.

Za předpokladu, že je známá báze vstupních vzorů, pak jako nejvhodnější pro realizaci rozhodovacího modelu se jeví *vícevrstvá neuronová síť*, učená dle vzoru, tj. *s učitelem* (Konečný, Matiašová, Rábová; 2005).

I: Přehled vstupních a výstupních proměnných modelů

Proměnná	Název	Hodnoty		
		extrém +	nevyhraněné	extrém –
Vstupní proměnné				
$x_1$	Míra samofinancování	vysoká	střední	nízká
$x_2$	Dlouhodobé úvěry	nízké	střední	vysoké
$x_3$	Platební situace	příznivá	nevyhraněná	nepříznivá
$x_4$	Vedlejší faktory	příznivé	nevyhraněné	nepříznivé
Výstupní proměnné				
$v$	Výsledek	překapitalizování	nevyhraněná situace	podkapitalizování

Cílem je naučit neuronovou síť zařadit každý vstupní vektor do některé z množin reprezentovaných hodnotami výsledné proměnné  $v$ . Jedním ze základních předpokladů realizace takového rozhodovacího modelu je vytvoření báze vstupních vzorů.

Za předpokladu, že pro každou vstupní proměnnou se budou uvažovat tři hodnoty, bude učící soubor obsahovat  $3^4$  vzorů, kterým musí expert z oblasti finančního řízení přiřadit klasifikační hodnotu výstupní proměnné. Není vždy potřebné definovat kompletní množinu učícího souboru. Pro učení lze akceptovat pouze naprosto zřejmé situace a zbytek považovat (v daném případě) za *nevyhraněné* (nespecifikovatelné) vzory. Pokud se při testování nebo i využití modelu zjistí situace, kdy model rozhoduje nesprávně, lze využít jednu z výhod neuronových sítí – *doučení*.

Pro zjednodušení tvorby báze vstupních vzorů lze využít pomocnou funkci vyjadřující celkovou míru kapitalizace (MK) a na základě těchto hodnot definovat výstupní (klasifikační) hodnotu modelu. V daném případě byla použita funkce

$$MK = k_1 \cdot x_1 + k_2 \cdot x_2 + k_3 \cdot x_3 + k_4 \cdot x_4, \quad (1)$$

kde koeficienty  $k_1 = k_2 = k_3 = 1$ , vyjadřují stejnou váhu kmenových proměnných a  $k_4 = 0,33$  váhu doplňkové proměnné. Výstupy odvozené na základě této funkce může finanční expert podle vlastního uvážení korigovat.

Pokud by taková funkce dostatečně objektivně vyjadřovala míru kapitalizace, pro vlastní klasifikaci je pak nezbytné pouze definovat intervaly hodnot pro *podkapitalizování*, *překapitalizování* podniku nebo v *nevyhraněnou* situaci. Například

$$MK \in \langle MK_{\max}; MK_{\max}/2 \rangle - \text{překapitalizace} \quad (2)$$

$$MK \in \langle MK_{\max}/2; -MK_{\max}/2 \rangle - \text{nevyhraněná situace} \quad (3)$$

$$MK \in \langle -MK_{\max}/2; -MK_{\max} \rangle - \text{podkapitalizace}. \quad (4)$$

Pro uvažovaný příklad  $MK_{\max} \approx 3,33$ . Hodnota vah u jednotlivých kmenových proměnných nemusí být vždy shodná a je závislá na konkrétní praktické aplikaci.

Dílčí část báze vzoru (z celkového počtu 81), pro neuronový model podkapitalizace, je uvedena v tab. II.

## II: Učící soubor (báze vzorů) základního modelu

N <sub>o</sub>	X <sub>1</sub>	X <sub>2</sub>	X <sub>3</sub>	X <sub>4</sub>	MK	V <sub>1</sub>	V <sub>2</sub>	
1	1	1	1	1	3,33	1	1	1,00
2	1	1	1	0	3	1	1	0,90
3	1	1	1	-1	2,67	1	1	0,80
4	1	1	0	1	2,33	1	1	0,70
5	1	1	0	0	2	1	1	0,60
6	1	1	0	-1	1,67	1	1	0,50
7	1	1	-1	1	1,33	1	0	0,40
8	1	1	-1	0	1	1	0	0,30
9	1	1	-1	-1	0,67	1	0	0,20
10	1	0	1	1	2,33	1	1	0,70
11	1	0	1	0	2	1	1	0,60
12	1	0	1	-1	1,67	1	1	0,50
13	1	0	0	1	1,33	1	0	0,40
14	1	0	0	0	1	1	0	0,30
15	1	0	0	-1	0,67	1	0	0,20
16	1	0	-1	1	0,33	1	0	0,10
17	1	0	-1	0	0	1	0	0,00
18	1	0	-1	-1	-0,33	0	1	-0,10
19	1	-1	1	1	1,33	1	0	0,40
41	0	0	0	0	0	1	0	0,00
42	0	0	0	-1	-0,33	0	1	-0,10
43	0	0	-1	1	-0,67	0	1	-0,20
44	0	0	-1	0	-1	0	1	-0,30
45	0	0	-1	-1	-1,33	0	1	-0,40
46	0	-1	1	1	0,33	1	0	0,10
47	0	-1	1	0	0	1	0	0,00
48	0	-1	1	-1	-0,33	0	1	-0,10
49	0	-1	0	1	-0,67	0	1	-0,20
50	0	-1	0	0	-1	0	1	-0,30
51	0	-1	0	-1	-1,33	0	1	-0,40
52	0	-1	-1	1	-1,67	0	0	-0,50
53	0	-1	-1	0	-2	0	0	-0,60
54	0	-1	-1	-1	-2,33	0	0	-0,70
55	-1	1	1	1	1,33	1	0	0,40
56	-1	1	1	0	1	1	0	0,30
57	-1	1	1	-1	0,67	1	0	0,20
58	-1	1	0	1	0,33	1	0	0,10
59	-1	1	0	0	0	1	0	0,00
60	-1	1	0	-1	-0,33	0	1	-0,10
76	-1	-1	0	1	-1,67	0	0	-0,50

№	$X_1$	$X_2$	$X_3$	$X_4$	MK	$V_1$	$V_2$	
77	-1	-1	0	0	-2	0	0	-0,60
78	-1	-1	0	-1	-2,33	0	0	-0,70
79	-1	-1	-1	1	-2,67	0	0	-0,80
80	-1	-1	-1	0	-3	0	0	-0,90
81	-1	-1	-1	-1	-3,33	0	0	-1,00

### VÝSLEDKY A DISKUSE

Blokové schéma modelu je uvedeno na obr. 1. Výstupní proměnná  $V$  je modelovaná dvojicí binárních výstupů  $v_1$  a  $v_2$ , které umožňují provádět klasi-

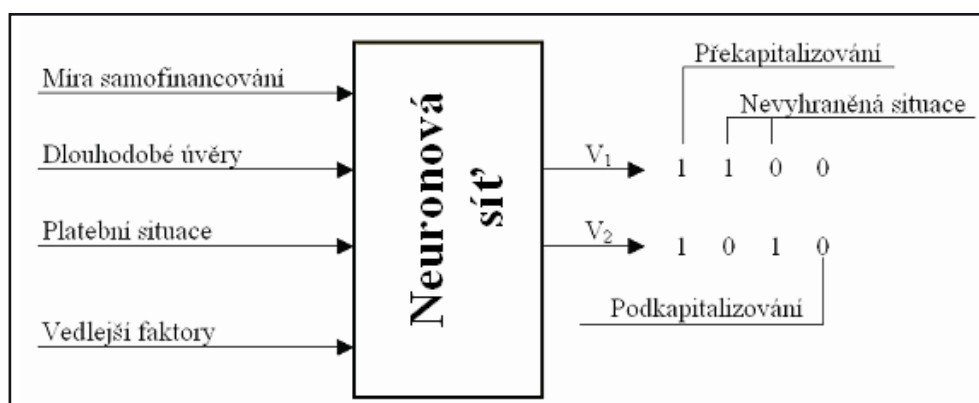
fikaci do čtyř podmnožin. Jedna přebytečná dvojice binárních hodnot umožnila upřesnit množinu reprezentující *nevyhraněnou situaci*. Navržený model pak bude provádět klasifikaci v souladu s tabulkou III.

III: Význam výstupu základního modelu

V		Význam
$v_1$	$v_2$	
1	1	překapitalizace (PŘEK)
1	0	nevyhraněná situace – blíže k překapitalizace (NPŘEK)
0	1	nevyhraněná situace – blíže k podkapitalizace (NPODK)
0	0	podkapitalizace (PODK)

Neuronová síť s ohledem na počet vstupních proměnných obsahuje čtyři vstupní neurony, dva výstupní a čtyři neurony ve skryté vrstvě. Počet neuronů skryté

vrstvy  $N_s$  byl stanoven přibližně podle pravidla  $N_s = \max(N_{vst}, N_{vys})$ , kde  $N_{vst}$  je počet neuronů vstupní vrstvy a  $N_{vys}$  – počet neuronů výstupní vrstvy.



1: Blokové schéma modelu

Učení neuronové sítě bylo provedeno na EMNS (experimentálním modelu neuronové sítě), kde je implementována metoda BPE (Back Propagation Errors) (Konečný, 2002). Počet epoch (1 epocha = 1

korekce parametru sítě za všechny vzory) fáze učení je závislý na požadované hodnotě chybové funkce

$$Ch = \frac{1}{2} \sum_i \sum_j [Y_j^0(V_i) - Y_j(V_i)]^2, \quad (5)$$

kde  $V_i$  je  $i$ -tý vzor učebního souboru (báze vstupních vzorů). V procesu učení je prováděna korekce parametru (vah a prahových hodnot) neuronové sítě tak, aby se zmenšovala hodnota chybové funkce směrem ke globálnímu minimu. Pro naučení sítě s hodnotou  $Ch \leq 0,001$  bylo potřebných 819 epoch učení. Maximální absolutní odchylka výstupní hodnoty od požadované je menší než 0,01. Pro ověření tohoto přístupu je však nutné provést validační test, který je součástí dalšího řešení.

Jako excitační funkce neuronu (vzhledem k metodě učení sítě) je v modelu nutno použít funkci derivovatelnou na celém definičním oboru. Tuto podmínku splňuje jednoduchá, sigmoidální a často používaná funkce

$$Y(z) = \frac{1}{1 + e^{-z}}, \text{ kde} \quad (6)$$

$$z = \sum_k (w_k \cdot Y_k + \Theta). \quad (7)$$

$Y_k$  jsou výstupy neuronu z předchozí úrovně připojené k excitačnímu vstupu s váhami  $w_k$ .

Vzhledem k tomu, že v třívrstvé architektuře první vrstva neuronu provádí transformaci 1:1, tj. výstupy neuronu jsou rovny vstupním hodnotám, v procesu učení se provádí nastavení pouze parametru druhé a třetí vrstvy. Učením neuronové sítě byly pro zkoumaný model získány následující parametry neuronové sítě

$$W_2 = \begin{bmatrix} -6,201 & -5,158 & -4,944 & 8,141 \\ -6,201 & -5,158 & -4,944 & 8,141 \\ -6,201 & -5,158 & -4,944 & 8,141 \\ -2,916 & -0,384 & -0,015 & 3,980 \end{bmatrix}, \Theta = \begin{bmatrix} -1,352 \\ -7,612 \\ 6,848 \\ 1,874 \end{bmatrix} \quad (8)$$

$$W_3 = \begin{bmatrix} -6,615 & 7,706 \\ -2,116 & -13,617 \\ -0,438 & -13,157 \\ 9,071 & -7,161 \end{bmatrix}, \Theta_3 = \begin{bmatrix} -0,620 \\ 12,828 \end{bmatrix}, \quad (9)$$

kde  $W_i$  je matice vah a  $\Theta_i$  – matice prahových hodnot úrovně  $i$ .

Po naučení neuronové sítě realizovat zadanou funkci se využívá pouze výpočetního režimu sítě. Tj. zadají se hodnoty vstupního vektoru a provede se výpočet podle vztahu

$$Z_i = W_i^T \cdot Y_{i-1} + \theta_i, Y_i = F(Z_i), \quad (10)$$

pro  $i = 2$  a  $3$  (případně až  $n$ , pro  $n$  vrstvou neuronovou síť) a kde  $Z_i$  – je vektor hodnot excitačních vstupů neuronu, jehož prvky jsou dány vztahem (7),  $Y_i$  – vektor výstupu, jehož prvky jsou dány vztahem

(6). Při  $i = 2$ ,  $Y_{i-1} = Y_1 = X_1$ , protože první vrstva neuronu pouze převádí vstupní hodnoty na výstupy beze změny.

Proces učení neuronové sítě lze zefektivnit a tedy naučení lze provést v menším počtu iteračních cyklů, pokud budeme v průběhu učení adekvátně měnit učící koeficient, více v (Konečný, 2005).

Výpočetní fázi neuronové sítě podle vztahu (10) lze jednoduše realizovat např. pomocí tabulkového procesoru (jako EXCEL) nebo jiných výpočetních nástrojů.

#### IV: Test základního modelu výstupu

Vstupy				Výstupy		Komentář
$x_1$	$x_2$	$x_3$	$x_4$	$v_1$	$v_2$	
0,7	0,7	0,3	0,5	1,00	0,97	překapitalizace
0,3	0,8	0,7	0,6	1,00	0,98	překapitalizace
1,0	-0,7	0,3	-0,8	1,00	0,00	nevyhr. situace blíže k překapit.
-0,3	1,0	0,8	0,7	1,00	0,72	překapitalizace
0,7	-0,7	-1,0	-0,6	0,00	1,00	nevyhr. situace blíže k podkapit.
-0,9	-0,4	-0,8	-1,0	0,00	0,00	podkapitalizace

Zvolený interval vstupních hodnot  $\langle -1; 1 \rangle$  všech proměnných modelu umožňuje zadávat i takové situace, které nejsou obsaženy v bázi vstupních vzorů a jejich klasifikace do specifikovaných množin by byla náročná. V tabulce tab. IV je uvedeno několik vzorových příkladů s výslednou klasifikací navrženým modelem. Jak je patrné z tab. III, některé výstupy  $v_1$  a  $v_2$  mají hodnoty, které nesplňují přesně požadavek pro výstupní hodnoty, které by měly být pouze 0 nebo 1. Je to proto, že použitá funkce neuronu je spojitá a oborem její funkčních hodnot je interval  $(0, 1)$ .

Nicméně situaci lze jednoduše řešit tím, že za každý výstupní neuron se přidá ještě jeden, který bude realizovat funkci

$$Y(z) = \begin{cases} 1, & \text{pro } z \geq 0,5 \\ 0, & \text{pro } z < 0,5. \end{cases} \quad (11)$$

To znamená, že každá výstupní hodnota  $v_i \geq 0,5$  se považuje za hodnotu 1 a každá výstupní hodnota  $v_i < 0,5$  se považuje za hodnotu 0.

#### V: Neúplná báze vzorů

Nº	$x_1$	$x_2$	$x_3$	$x_4$	$v$
1.	1	1	1	1	1
2.	1	1	1	0	1
3.	1	1	1	-1	1
4.	1	1	0	1	1
5.	1	1	0	0	1
6.	1	1	0	-1	1
7.	1	0	1	1	1
8.	1	0	1	0	1
9.	1	0	1	-1	1
10.	0	1	1	1	1
11.	0	1	1	0	1
12.	0	1	1	-1	1
13.	0	-1	-1	1	0

Nº	$x_1$	$x_2$	$x_3$	$x_4$	$v$
14.	0	-1	-1	0	0
15.	0	-1	-1	-1	0
16.	-1	0	-1	1	0
17.	-1	0	-1	0	0
18.	-1	0	-1	-1	0
19.	-1	-1	0	1	0
20.	-1	-1	0	0	0
21.	-1	-1	0	-1	0
22.	-1	-1	-1	1	0
23.	-1	-1	-1	0	0
24.	-1	-1	-1	-1	0
25.	0	0	0	0	0,5

#### Neúplná báze vzorů

Pro zjednodušený model bude jako báze vstupních vzorů akceptována pouze podmnožina vzorů uvedených v tab. III. Jsou to takové vzory, pro které může expert s velkou jistotou definovat výstupy modelu (viz tab. V). Poslední vzor reprezentuje naprosto jasně nevyhraněnou situaci s nulovými hodnotami vstupních proměnných.

V tomto případě nebylo účelné využít dva výstupy modelu, protože by měly stejné hodnoty. To ovšem znamená, že interpretace výstupu bude záležet na velikosti jeho hodnoty. Hodnoty výstupu blízké k 1 ( $0,7 \leq v < 1$ ) znamenají *překapitalizaci*, blízké k 0 ( $0 < v \leq 0,3$ ) – *podkapitalizaci* a zbývající hodnoty z intervalu  $(0; 1)$  označují *nevyhraněnou situaci*.

Je zřejmé, že při neúplně definované výstupní funkci modelu nelze očekávat korektní výsledek pro každou zadanou situaci vstupních proměnných. Pokud se vstupy nebudou příliš odlišovat od vzoru, bude model fungovat uspokojivě. Jako příklad jsou v tab. V uve-

deny výsledky se stejným testovacím souborem, jako výchozí model naučený podle vzoru tab. IV, ale pro různé aktivační funkce neuronu sítě. Proces učení u modelu se sigmoidální aktivační funkcí byl ukončen při hodnotě chybové funkce  $Ch = 0,01$ . U modelu s lineární aktivační funkcí byl proces učení ukončen po 500 epochách učení ( $|Ch| < 0,001$ ).

Srovnatelnější výsledky s výchozím modelem poskytuje model s lineární aktivační funkcí neuronu ( $Y(x) = 0,1 * X$ ). Použití lineární aktivační funkce umožňuje nalezení lineární závislosti mezi vstupy a výstupem modelu (skryté vrstvy lze vynechat), tj. získat koeficienty funkce (1) – míry kapitalizace na základě báze vzorových situací.

K výsledku posledních dvou experimentů nutno ještě dodat, že zatím co ve výchozím modelu byla u čtvrté proměnné uvažována menší váha než u zbývajících proměnných, v experimentech s minimalizovanou bází vzoru mají všechny proměnné stejnou váhu.

## VI: Testy modelu s minimalizovanou bází vzoru

Vstupy				funkce neuronu (6)		funkce neuronu lineární	
$x_1$	$x_2$	$x_3$	$x_4$	$v$	Komentář	$v$	Komentář
0,7	0,7	0,3	0,5	0,96	Překapitalizace	0,91	Překapitalizace
0,3	0,8	0,7	0,6	0,97	Překapitalizace	0,93	Překapitalizace
1,0	-0,7	0,3	-0,8	0,86	Překapitalizace	0,67	Nevyhraněná situace, blíže k překapitalizaci
-0,3	1,0	0,8	0,7	0,96	Překapitalizace	0,86	Překapitalizace
0,7	-0,7	-1,0	-0,6	0,08	Podkapitalizace	0,32	Nevyhraněná situace, blíže k podkapitalizaci
-0,9	-0,4	-0,8	-1,0	0,03	Podkapitalizace	0,07	Podkapitalizace
-0,4	0,0	0,0	1,0	0,24	Podkapitalizace	0,34	Nevyhraněná situace, blíže k podkapitalizaci

## ZÁVĚR

Pro dosažení co nejlepší funkce rozhodovacího modelu je žádoucí definovat co nejvíce vzorových situací. V mnoha případech je možnost tvorby báze vzorových situací značně omezena. Také v řešeném problému podkapitalizace podniku existují situace, kdy expert může zcela jednoznačně rozhodnout, v jaké situaci se podnik nachází, ale v mnoha dalších situacích je to obtížné.

Obzvláště složitá situace nastane při větším počtu vstupních proměnných. Pro zjednodušení je v příspěvku použita pomocná funkce, nicméně lze tvořit model i na omezené množině vzorů. Je nutno ale počítat s tím, že některá nabídnutá řešení nemusí být korektní a pro další využití je nutno model doučit.

Co se týče konfigurace sítě (řešeného problému), strukturu [4, 4, 2] u výchozího modelu lze zjednodušit na [4, 3, 2], ale nelze dosáhnout stejně nízkou hodnotu chybové funkce. Nicméně použitelnost modelu by neměla být dotčena. U dalšího modelu v pořadí nelze druhou vrstvu změnit – naruší se kvalita modelu. Jak již bylo uvedeno v modelu s lineární aktivační funkcí, lze stejných výsledku dosáhnout v konfiguraci [4, 1].

Uvedený přístup k řešení problému rozhodování lze použít i v celé řadě dalších případů. Nutno si ale uvědomit, že naučená vícevrstvá neuronová síť reprezentuje interpolační funkci definovanou bází vzoru, tj. vstupu a požadovaných výstupů konstruovaného modelu. Po odzkoušení modelu a získání parametru neuronové sítě lze model, podle vztahu (10), provozovat v prostředí tabulkového kalkulátoru.

## SOUHRN

Téma článku je zaměřeno do problematiky rozhodování v oblasti finančního řízení podniku. Konkrétně je zde rozebrán případ vyhodnocování investiční politiky podniku. Jedná se o kritickou oblast pro management ovlivňující další kroky při využití interních i externích zdrojů podniku. Jako vhodný nástroj pro podporu rozhodování byl v tomto případě zvolen přístup z oblasti umělé inteligence a to konkrétně vhodně koncipovaný model neuronové sítě.

Ve vytvořeném modelu neuronové sítě, rozhodujícím o finanční situaci podniku, bylo použito čtyř vstupních proměnných (tři hlavních a jedné doplňující) popisující konkrétní stav podniku. Kódování hlavních proměnných je zvoleno adekvátně k vyhodnocovaným stavům. Pro vyhodnocení se použila vícevrstvá neuronová síť.

Výhodou naučené neuronové sítě je, že může klasifikovat i případy pro manažera obtížně řešitelné a to obzvláště případy o větším počtu faktů ovlivňující výsledné rozhodnutí. Ne vždy je však situace jednoduše vyhodnotitelná, limitujícím faktorem je vhodně sestavený učební soubor. V případě nesprávných rozhodnutí lze provést vhodné rozšíření učícího souboru o adekvátní vzory a neuronovou síť doučit.

rozhodovací problém, umělá inteligence, neuronové sítě

## LITERATURA

KONEČNÝ, V., PEZLAR, Z.: *Základy umělé inteligence* [on-line]. Brno: 2002. Dostupné na: <[http://](http://old.mendelu.cz/~konecny/zaklady_ui.zip)

[old.mendelu.cz/~konecny/zaklady ui.zip](http://old.mendelu.cz/~konecny/zaklady_ui.zip)> [cit. 2006–12–12]. Dokument ve formátu PostScript v archivu ZIP.



- KONEČNÝ, V., MATIÁŠOVÁ, A., RÁBOVÁ, I.: *Učení n-vrstvé neuronové sítě*. Acta Universitatis Agriculturae et Silviculturae Mendelianae Brunensis. 2005. sv. LIII, č. 6, s. 75–84. ISSN 1211-8516.
- SŮVOVÁ H. a kol.: *Finanční analýza v řízení podniku, v bance a na počítači*. Praha: Bankovní institut, a. s., 1999. 1. vyd. ISBN 80-7265-027-0.
- ŽIVĚLOVÁ, I.: *Finanční řízení podniku I*. Brno: MZLU v Brně, 1998. 1. vyd. ISBN 80-7157-339-6.

## Adresa

Ing. Martin Pokorný, Ing. Oldřich Trenz, Doc. Ing. Vladimír Konečný, CSc., Ústav informatiky, Mendelova zemědělská a lesnická univerzita v Brně, Zemědělská 1, 613 00 Brno, Česká republika