

## BUSINESS INTELLIGENCE A KONKURENCESCHOPNOST PODNIKU

V. Konečný, I. Rábová

**Došlo: 8. června 2005**

### Abstract

KONEČNÝ, V., RÁBOVÁ, I.: *Business Intelligence and competition ability of enterprise*. Acta univ. agric. et silvic. Mendel. Brun., 2005, LIII, No. 6, pp. 85–92

As far as the current state of the information and communication technologies usage is concerned, the information systems of the companies cover the major part of the transaction processes and the large amount of the processes at the level of the tactical decision-making.

Intensive implementation of the information technologies in many areas of the human activities cause gathering of the large amount of the data. The volume of the internal and external databases grows rapidly and the problem is to take advantage of the data they contain. But the problem is not only the growing volume of the databases but also the different and database structures. To get the new information from the large and incompatible database sources is possible but very inefficient. A manager often needs the information very fast to achieve competitive advantage and to solve problems at the level of strategic decision-making.

Another problem is the fact that the databases often contain information that is hidden there and there is no way known how to get this information out of the database. In this case, the user needs at least suitable tools in order to perform experiments and to explore and identify patterns and relationships in the data.

The transformation process of the data to information and to knowledge that is used in the process of decision-making is called Business Intelligence. Modern database tools offer wide support for building the data warehouse, OLAP analysis and data mining.

Our contribution focuses on the application of one of the data mining techniques such as neural networks and artificial intelligence. The application of those methods will be based on the assessment of the food quality and composing of the corresponding trend indicator.

Business Intelligence, business model, data warehouse, analytical tools, data mining, neural nets, expert systems

Jedním ze základních trendů tvorby a rozvoje informačních systémů je podpora strategického rozhodování. Nevyplyvá to jenom z jeho postavení v rámci rozhodovacích procesů podniku, ale také z možností, které nabízí bouřlivý rozvoj a využití informačních a komunikačních technologií. Jedná se především o tvorbu a využití rozsáhlých databází obsahujících informace jak z vlastních podniků, tak i širokého podnikatelského prostředí, umožňujících získávat po-

třebné informace pro kvalitní rozhodování a zvyšování konkurenceschopnosti podniku.

### MATERIÁL A METODY

#### **Podniková inteligence v managementu podniku**

Aparát technologií a softwarových nástrojů označovaný jako Business Intelligence se svým multidimenzionálním pojetím mění postupy a aktivity řídicích pracovníků a poskytuje nové prostředí pro jejich ana-

lytické a rozhodovací procedury. Poprvé byl termín Business intelligence (dále jen BI) použit Gartnerem a dále pak popularizován Howardem Dresnerem jako „*proces zkoumání doménově strukturovaných informací za účelem zjištění trendů nebo jiných společenských informací pro tvorbu závěrů*“. V literatuře lze nalézt mnoho dalších definicí, jako například:

1. BI – cesta k informacím a znalostem (HUIJŇÁK, 2005).
2. BI – cesta, jejíž cílem je zlepšení rozhodování využitím široké škály informačních systémů, aplikací a technologií sběru, uchování, analýzy a zpřístupnění dat (PYLE, 2003).
3. BI – proces zaměřený na zvýšení konkurenceschopnosti podniků inteligentním využitím přístupných dat v rozhodovacím procesu (CSIRO, 2005).

V podstatě se všechny shodují v tom, že se jedná o získávání informací využitelných pro podporu rozhodovacích procesů, avšak v původní definici Dresnera je správně kladen větší důraz na existenci zvláštní doménově strukturované (multidimenzionální) databáze.

Z hlediska základních funkcí informačního systému, ke kterým patří *sběr, uchování, zpracování a prezentace informací managementu* na všech úrovních řízení, nepředstavuje tedy BI nic nového, pokud by se nejednalo i o rozšíření a změnu způsobu získávání informací za účelem zvýšení kvality rozhodovacích procesů a zkvalitnění podpory strategického rozhodování. Podle (FRAWLEY, 1992) „Datový sklad nenahrazuje aplikace IS v úrovni transakčních procesů, je určen pro podporu strategického rozhodování“.

V souvislosti s rozvojem elektronického podnikání, nástupem systémů podporujících vztahy se zákazníky (Customer Relation Management – CRM) a dalšími novými druhy aplikací dochází k integraci technologií BI a CRM a ke vzniku zajímavé podmnnožiny podnikové inteligence, kterou je tzv. Customer Intelligence, (CI). CI představuje agregované znalosti o zákazníkovi a speciální analytické aplikace na bázi datových skladů a dolování dat.

Cíle působnosti CI i BI lze odvodit z *podnikového modelu*, který definuje směry dosažení požadovaných příjmů a zisku. Tento model je abstrakcí toho, jak bude podnik sloužit svým zákazníkům a obsahuje jak strategii podniku, tak i její realizaci – a tedy je zaměřen na řešení následujících problémů:

- rozdělení (klasifikací) zákazníků na třídy podle určitých kritérií a zkoumání specifík jednotlivých tříd zákazníků,

- tvorbu nabídky produktů pro jednotlivé třídy zákazníků,
- hodnocení a možností rozšíření standardních i nestandardních služeb pro zákazníky,
- získávání a stabilizaci zákazníků,
- účinnost reklamní strategie,
- distribuci výrobků,
- strukturu zdrojů, zvyšování zisku (snižování nákladů),
- analýzu zásob, spotřeby materiálu, kvality subdodávek a efektivnost výroby.


Má-li BI přinést konkurenční výhodu, mělo by jeho řešení být na jedné straně unikátní, ale na druhé straně rychle realizovatelné a s adekvátními náklady. To lze docílit využitím typových prvků sběru dat, uchování, přístupu, analýzy a prezentace a tvorbou specifických uživatelských aplikací.

### Přístup BI

Typová řešení problematiky BI jsou v současné době prezentována v podobě *datových skladů (DS)*. Nutno ovšem poznamenat, že DS nelze chápat jako cíl podnikatelského snažení, ale jako cestu vedoucí k cíli (FRAWLEY, 1992). Smysl DS není jen v datech uskladených ve speciálních skladech (warehouses), ale i v procesu jejich extrakce pro potřeby rozhodování. Informační exploze v posledních desetiletích umožnila organizacím shromáždit obrovské objemy dat, ale jejich využití zřídka překračuje hranice operativního řízení.

Získání informace o vývoji prodeje určitého výrobku za posledních několik let může být složitý dotaz i pro současné databázové systémy, protože obvykle obsahují detailní údaje aktuálního období. Data dřívějších let jsou archivována mimo aktuální databázi. Ještě složitější situace nastane, pokud řešení nějaké úlohy vyžaduje data z externí databáze, protože obvykle mají nevhodnou strukturu. Má-li informační systém zvyšovat konkurenceschopnost podniku, musí být doba odezvy na formulovaný problém přijatelná – tj. prakticky okamžitá. Takový požadavek vyžaduje i pro současnou úroveň informačních technologií v podstatě předzpracovaná data, tj. do určité úrovně agregovaná a vhodným způsobem strukturovaná.

Architektura DS je uvedena na obr. 1. Pro splnění podnikatelských cílů a řešení souvisejících problémů je zapotřebí čerpat informace nejen z interních informačních zdrojů podniku (databáze IS podniku), ale také z externích informačních zdrojů (státních orgánů, finančních organizací, obchodních partnerů, konkurence atd.), jejichž struktura je velice různorodá.



1: Struktura datového skladu

V různorodosti datových zdrojů je skryt i první problém realizace databáze DS, a to *transformace* požadovaných dat z externích i interních zdrojů do vhodné unifikované podoby. Tento úkol plní nástroje označované jako ETL (Extraction, Transaction, Loading) nebo datové pumpy, jejichž hlavní funkce spočívají v selekci a extrakci dat z příslušného zdroje, vyčištění a transformace dat do požadované struktury a nakonec uložení do databáze datového skladu.

*Databáze datového skladu (DDS)* je konsolidovaný datový zdroj, vytvořený pro určitou organizaci a sdílený pouze v rámci této organizace. Jeho data dokumentují změny v časovém horizontu, a tak umožňují analýzu trendů a porovnání stavů vývoje organizace v různých obdobích. Databáze transakčních procesů a datového skladu jsou různé. Zatímco databáze transakčních procesů je normalizovaná, komplexní a optimální z hlediska editace a integrity, databáze datového skladu je určena pouze pro čtení, může obsahovat ne-normalizované struktury pro jednoduché pochopení jejich významu a dokumentaci vývoje a je optimalizovaná z hlediska řešení dotazů a tvorby reportů.

Z aktuální databáze informačního systému transakčních procesů se do datového skladu čerpají pouze ta data, která mají význam pro úlohy strategického řízení. Data potřebná pro čistě operativní aktivity v rámci informačního systému nejsou do DDS transformována.

Podobné funkce jako plní ETL nástroje při ukládání dat do databáze datového skladu plní i ETL nástroje, které připravují data pro jednotlivé aplikace a ukládají je do *datových tržišť* (*Data Mart*). Obsahují tedy jistou podmnožinu údajů DDS vytvořenou například pro aplikace určité skupiny uživatelů, a tedy i rychlejší plnění jejich požadavků.

Uživatelské aplikace (resp. nástroje) datového skladu jsou rozhodující pro úspěšnost datového skladu a lze je rozdělit do tří základních skupin: *dotazovací* (*query*), *analytické* (*OLAP – On Line Analytical Processing*) a aplikace pro tzv. *dolování dat* (*data mining*).

Dotazovací nástroje umožňují jednoduchý přístup k existujícím datům (v úrovni DDS nebo Data Mart) a tvorbu dokumentů vysoké úrovně. Například zobrazení hodnot hlavních ekonomických ukazatelů za

zvolené období běžného roku a pro možné porovnání ještě dvou předchozích let.

*Analytické nástroje* typu OLAP umožňují rychle poskytnout odpověď na komplexní databázové dotazy. Využívají zvláštní nebo relační multidimenzionální databázi. Jednotlivé dimenze (např. výrobky, regiony, zákazníci, čas, atd.) umožňují zkoumat data z různých pohledů. Podle koncepce využívané databáze se dělí na MOLAP (multidimenzionální OLAP) a jako hlavní představitel bývají často označovány jako OLAP, ROLAP (relační OLAP) a HOLAP (hybridní OLAP). Každý typ má své výhody i nevýhody, MOLAP jsou vhodné pro menší objemy dat a při realizaci dotazů jsou rychlejší.

Multidimenzionální databáze ROLAP lze formálně definovat jako projekci

$$M: (X, Y, Z, \dots) \rightarrow M,$$

kde  $X, Y, Z, \dots$  jsou dimenze a zároveň primární klíče entity  $M$ . Zbývající hodnoty atributů tvoří doplňující informaci pro plnění požadované úlohy.

Dolování dat představuje nástroje určené pro vysoce sofistikované analýzy dat, zejména v datových skladech, schopné odhalovat skryté, na první pohled nezřetelné závislosti mezi daty. Dolování dat je podle (FRAWLEY, 1992) definováno jako „netriviální získávání implicitních, dříve neznámých, ale potenciálně užitečných informací z dat“, resp. hledání informací v databázích (KDD – Knowledge-Discovery in Databases), či objevování smysluplných vzorků a pravidel chování z velkého množství dat. V data miningu rozlišujeme postupy a techniky. Zatímco postupy specifikují CO se bude řešit (patří sem například klasifikace, estimace, predikce, clustering, nebo deskripce), techniky popisují JAK se daná úloha bude řešit. Jednou ze základních technik jsou vedle analýzy nákupního košíku, dedukce, detekce shluků, analýzy závislostí a dalších také neuronové sítě.

Využitím technologie neuronových sítí a umělé inteligence, které tvoří druhou vývojovou linii data miningu, se zabývá tento příspěvek.

### Technologie umělé inteligence

K základním technologiím umělé inteligence (UI), které lze využít pro podporu rozhodovacích procesů na různých úrovních (operativní, taktické i strategické), patří technologie zaměřené na tvorbu: *expertních systémů, fuzzy expertních systémů, neuronových sítí, hybridních systémů (neuro-expertní, fuzzy neuro-expertní) a systémů využívajících genetický algoritmus.*

*Expertní systémy (ES) jsou založené na pravidlech* a využívají se pro takové rozhodovací procesy, pro které lze definovat pravidla rozhodování. Jako příklad může posloužit poradenský expertní systém, který formou dialogu se zákazníkem mu napomůže zvolit nejvhodnější typ výrobku z nabízeného sortimentu. Takové systémy je vhodné umístit do elektronického obchodu nebo na podnikové prezentační WWW stránky. Expertní systémy lze také využít pro tvorbu nabídky vybraným třídám zákazníků, plánování a řízení distribuce výrobků a další.

V rozhodovacích procesech, ve kterých se pravidla snadněji definují pomocí vágních pojmů, lze uvažovat o využití fuzzy expertních systémů (FES), například fuzzy systém rozhodování o umožnění nákupu na úvěr.

Hlavní nevýhoda expertních systémů je stejná jako

u všech softwarových produktů – každý požadavek na změnu funkce vyžaduje změnu programu, tj. nelze je doučit, resp. přeučit. Tuto nevýhodu ale nemají systémy založené na bázi neuronových sítí.

*Neuronové sítě (NS)* lze využít pro rozhodování v situacích, kdy pravidla nelze definovat vůbec nebo velmi obtížně, ale jsou k dispozici pozorové situace (obecně vektor vstupů a vektor požadovaných výstupů), které mohou posloužit jako učící soubor. V daném případě se jedná o využití vícevrstvých neuronových sítí a jejich učení s „učitelem“. V řadě případů mohou nahradit použití ES nebo FES.

Pro řadu klasifikačních úloh a pro případy, kdy nelze stanovit požadované výstupy neuronové sítě, lze využít *samoučící se neuronové sítě (SNS).*

*Genetický algoritmus (GA)* je využíván v systémech, které při hledání řešení problému napodobují princip rozmnožování živých organismů – selekce, křížení a mutace. Pro jeho použití je nutná výchozí populace (množina vyhovujících řešení) a kritérium hodnocení jedinců, aby po získání nové populace bylo možné vybrat množinu nejlepších jedinců.

V návaznosti na podnikový model a vlastnosti technologií umělé inteligence lze reálně uvažovat o jejich využití v rozhodovacích procesech dle tab. I.

I: *Problémové oblasti a technologie UI*

| Problémová oblast                  | Technologie UI   |
|------------------------------------|------------------|
| Klasifikace zákazníků              | ES, FES, NS, SNS |
| Tvorbou nabídky produktů           | ES, GA           |
| Plánování a distribuce výrobků     | ES, GA           |
| Hodnocení kvality výrobků a služeb | ES, FES, NS, SNS |
| Analýza trendů vývoje              | NS, SNS          |

V následující části příspěvku představujeme aplikaci jedné z technologií podnikové inteligence (neuronové sítě) při řešení dvou problémových oblastí, a to hodnocení kvality výrobku a analýza trendu vybraného ukazatele. Výsledky lze rozšířit na kterýkoli produkt zákaznického řetězce.

### ŘEŠENÍ A VÝSLEDKY

#### Hodnocení kvality a trendu vývoje

##### *Hodnocení kvality potravin*

**Kvalita výrobků a služeb** patří v současné době k jednomu z nejsledovanějších atributů konkurenceschopnosti podniků. Proto neustálá péče o kvalitu je prvořadým úkolem managementu na všech úrovních řízení, zvláště pokud jde o komodity potravinářské. Jakmile však neexistují zcela objektivní metody

a metriky, může být hodnocení kvality velmi obtížný úkol a navíc se značně subjektivním výsledkem.

Například po uvaření piva je potřebné degustací zjistit, zda je pivo kvalitní a vhodné ke konzumaci spotřebitelem. Degustace piva začíná nalitím piva do sklenice a posuzuje se: *pěna (výška, hustota, barva), čírost (resp. jiskra) a barva piva, vůně a chuti piva (čistota, charakter vůně a chuti, hořkost piva).* Kvalitní pivo má dobrou pěnivost, hustou a dlouhotrvající pěnu, je čiré, má zlatožlutou barvou, voní a chutná. Dále se vyznačuje dobrým a příjemným řízem a harmonickou hořkostí.

Vyhodnocení všech atributů ovlivňujících kvalitu piva a jeho objektivní zařazení např. do jedné ze čtyř klasifikačních tříd může být velmi obtížné, a to i při volbě velmi jednoduché metriky pro každý atribut.

Například 0 – znamená nevyhovující a 1 – vyhovující. I když budou hodnoty atributů hodnoceného vzorku stanoveny správně, značně subjektivní může být následné zařazení do jedné z požadovaných kvalitativních skupin – např.: 1–4.

Z obecného hlediska se jedná o realizaci rozhodovacího modelu se vstupními hodnotami atributů hodnoceného vzorku piva a výstupem udávajícím příslušnou kvalitativní třídu (skupinu).

## II: Atributy učicího souboru

| Pěna  |         |       | Čírost | Barva | Vůně    |           | Chuť | Výstupy        |                |
|-------|---------|-------|--------|-------|---------|-----------|------|----------------|----------------|
| Výška | Hustota | Barva |        |       | Čistota | Charakter |      | 2 <sup>1</sup> | 2 <sup>0</sup> |
| 0     | 0       | 0     | 0      | 0     | 0       | 0         | 0    | 0              | 0              |
| 1     | 1       | 1     | 1      | 1     | 1       | 1         | 1    | 1              | 1              |
| 0     | 0       | 1     | 1      | 0     | 0       | 1         | 0    | 0              | 0              |
| 0     | 0       | 1     | 1      | 0     | 0       | 1         | 1    | 0              | 1              |
| 0     | 1       | 1     | 1      | 1     | 0       | 1         | 1    | 0              | 1              |
| 0     | 1       | 1     | 1      | 1     | 0       | 1         | 0    | 0              | 1              |
| 1     | 0       | 1     | 1      | 1     | 1       | 1         | 1    | 1              | 0              |
| 1     | 1       | 0     | 1      | 1     | 1       | 1         | 1    | 1              | 1              |

Velmi jednoduchá realizace takového systému se nabízí v podobě *třívrstvé neuronové sítě* s osmi vstupy a se dvěma výstupy pro binární kódování příslušné třídy (00, 01, 10, 11) – viz tab. II. Nejvyšší hodnocení má třída 3 = [11]<sub>2</sub> a nejnižší třída 0 = [00]<sub>2</sub>. V rámci provedeného experimentu byla zvolena třívrstvá neuronová síť (8 neuronů na vstupu, 4 neurony ve skryté vrstvě a 2 neurony na výstupu) s učením podle zadaných vzorů v tab. II. (autoři nejsou experti pro degustaci, pouze konzumenti), metodou zpětného šíření chyb.

Neurony vstupní vrstvy realizují funkci  $y = x$  (tj. výstupní hodnota je rovna vstupní hodnotě) a zbývající neurony funkci  $1/[1+\exp(-x)]$ . Výstupní hodnoty  $< 0,5$  jsou považovány za logickou hodnotu 0 a výstupní hodnoty  $\geq 0,5$  za logickou hodnotu 1. Tento

drobný nedostatek modelu lze odstranit jednoduchým rozšířením neuronové sítě.

Výsledek testu naučené třívrstvé neuronové sítě je uveden v tab. III. Ke každému vektoru vstupů a požadovaných výstupů (hodnoty jsou ve stejném pořadí jako v tab. II.) jsou uvedeny vypočítané (skutečné) výstupy neuronové sítě.

Poslední řádek obsahuje vstupní hodnoty, které nebyly součástí učicího souboru a jsou výsledkem degustace jednoho vzorku piva. Požadované výstupy u tohoto vzorku model neakceptuje. Pro zadané vstupy jsou na výstupech neuronové sítě hodnoty [0,9654, 0,2180]. Podle předchozího předpokladu budeme pro účely klasifikace hodnoty menší než 0,5 považovat za 0 a hodnoty větší nebo rovné 0,5 za 1 a tedy zkoumaný vzorek byl zařazen do třídy [10]<sub>2</sub> = 2.

## III: Výstup experimentálního modelu N-vrstvé neuronové sítě

| VSTUPY                                                            | POŽADOVANÉ VÝSTUPY | VYPOČÍTANÉ VÝSTUPY |
|-------------------------------------------------------------------|--------------------|--------------------|
| [ 0.0000, 0.0000, 0.0000, 0.0000, 0.0000, 0.0000, 0.0000, 0.0000] | [ 0.0000, 0.0000]  | [ 0.0290, 0.0228]  |
| [ 1.0000, 1.0000, 1.0000, 1.0000, 1.0000, 1.0000, 1.0000, 1.0000] | [ 1.0000, 1.0000]  | [ 0.9722, 0.9721]  |
| [ 0.0000, 0.0000, 1.0000, 1.0000, 0.0000, 0.0000, 1.0000, 0.0000] | [ 0.0000, 0.0000]  | [ 0.0098, 0.0328]  |
| [ 0.0000, 0.0000, 1.0000, 1.0000, 0.0000, 0.0000, 1.0000, 1.0000] | [ 0.0000, 1.0000]  | [ 0.0195, 0.9630]  |
| [ 0.0000, 1.0000, 1.0000, 1.0000, 1.0000, 0.0000, 1.0000, 1.0000] | [ 0.0000, 1.0000]  | [ 0.0264, 0.9964]  |
| [ 0.0000, 1.0000, 1.0000, 1.0000, 1.0000, 0.0000, 1.0000, 0.0000] | [ 0.0000, 1.0000]  | [ 0.0068, 0.9725]  |
| [ 1.0000, 0.0000, 1.0000, 1.0000, 1.0000, 1.0000, 1.0000, 1.0000] | [ 1.0000, 0.0000]  | [ 0.9813, 0.0314]  |
| [ 1.0000, 1.0000, 0.0000, 1.0000, 1.0000, 1.0000, 1.0000, 1.0000] | [ 1.0000, 1.0000]  | [ 0.9780, 0.9788]  |
| [ 0.7000, 0.2000, 1.0000, 1.0000, 0.8000, 1.0000, 0.9000, 1.0000] | [ 0.0000, 0.0000]  | [ 0.9654, 0.2180]  |



I když model využívá pouze dvě hodnoty vstupních atributů jak pro učení, tak i pro klasifikaci, lze využít celý interval hodnot  $\langle 0, 1 \rangle$ .

Atributy modelu kvality lze rozšířit o další faktory ovlivňující kvalitu piva a vytvořit tak komplexnější model.

#### **Trend vývoje zvoleného ukazatele**

Zkoumání trendu vývoje zvoleného ukazatele na základě historických dat náleží do skupiny prospěšných praktických problémů. I v tomto případě lze technologii neuronových sítí představit jako nástroj získávání informací (znalostí) o budoucím chování procesů.

Pro prezentaci prognózy vývoje jsou použita data přírůstku zisku (v desetinách %) obchodní organizace za čtvrtletí. Zdrojová data jsou uvedena v tab. IV ve sloupcích označených jako Z.

Pro řešení prognózy vývoje byla zvolena třívrstvá neuronová síť, jejíž neurony realizují funkci

$$y = \frac{2}{1 + \exp(-X)} - 1. \quad (1)$$


Neuronová síť byla naučena predikci výstupních hodnot  $y(t_{21}) \div y(t_{120})$  na základě 20 předchozích hodnot, to znamená, že realizuje funkci  $y(t_i) = F[y, y(t_{i-2}), y(t_{i-3}), \dots, y(t_{i-20})]$ . Její struktura očividně musí obsahovat 20 vstupních neuronů, jeden výstupní. Pro skrytou vrstvu bylo zvoleno 10 neuronů. Učení neuronové sítě bylo ukončeno po dosažení chyby

$$\frac{1}{2} \sum_{i=1}^{120} [y(t_i) - y^o(t_i)]^2 \leq 0,01, \quad (2)$$

kde  $y^o(t_i)$  je požadovaná a  $y(t_i)$  je skutečná výstupní hodnota neuronové sítě. Výstupy naučené neuronové sítě jsou uvedeny v tab. IV, ve sloupcích označených NS.

IV: Zdrojová data a výstupy naučené neuronové sítě (přírůstek zisku v %/10)

| Z      | Z      | NS     | Z      | NS     | Z      | NS     | Z      | NS     | Z       | NS      | Z       | NS      |
|--------|--------|--------|--------|--------|--------|--------|--------|--------|---------|---------|---------|---------|
| 1-20   | 21-40  | 21-40  | 41-60  | 41-60  | 61-80  | 61-80  | 81-100 | 81-100 | 101-120 | 101-120 | 121-140 | 121-140 |
| 0,451  | 0,110  | 0,116  | -0,346 | -0,350 | -0,050 | -0,038 | -0,06  | -0,041 | -0,416  | -0,409  | -0,304  | -0,306  |
| -0,219 | 0,547  | 0,553  | -0,539 | -0,528 | -0,238 | -0,222 | -0,353 | -0,371 | 0,550   | 0,550   | -0,410  | -0,396  |
| 0,337  | -0,323 | -0,314 | -0,084 | -0,094 | 0,481  | 0,511  | -0,522 | -0,514 | 0,430   | 0,419   | 0,423   | 0,431   |
| 0,047  | -0,323 | -0,329 | 0,235  | 0,241  | 0,463  | 0,469  | -0,042 | -0,053 | 0,332   | 0,322   | 0,289   | 0,288   |
| 0,133  | 0,095  | 0,089  | -0,188 | -0,185 | -0,049 | -0,049 | -0,070 | -0,068 | -0,338  | -0,323  | -0,240  | -0,226  |
| -0,119 | -0,326 | -0,328 | 0,061  | 0,070  | 0,338  | 0,335  | 0,130  | 0,127  | 0,382   | 0,371   | -0,315  | -0,299  |
| -0,055 | -0,205 | -0,225 | -0,179 | -0,162 | 0,117  | 0,115  | 0,202  | 0,194  | -0,303  | -0,298  | -0,384  | -0,400  |
| -0,114 | 0,107  | 0,110  | -0,489 | -0,490 | -0,191 | -0,184 | 0,284  | 0,266  | 0,392   | 0,406   | 0,364   | 0,364   |
| -0,254 | -0,287 | -0,274 | 0,391  | 0,389  | 0,120  | 0,099  | 0,369  | 0,397  | 0,541   | 0,537   | 0,219   | 0,201   |
| 0,416  | 0,036  | 0,038  | 0,322  | 0,322  | 0,415  | 0,426  | -0,150 | -0,186 | -0,180  | -0,174  | 0,192   | 0,191   |
| -0,184 | -0,367 | -0,363 | 0,456  | 0,445  | 0,537  | 0,485  | -0,391 | -0,403 | 0,073   | 0,062   | 0,345   | 0,353   |
| 0,214  | -0,510 | -0,489 | 0,337  | 0,336  | 0,159  | 0,179  | -0,480 | -0,433 | 0,484   | 0,475   | 0,261   | 0,264   |
| 0,614  | 0,157  | 0,162  | -0,028 | -0,030 | 0,191  | 0,183  | -0,122 | -0,148 | 0,444   | 0,432   | -0,375  | -0,364  |
| -0,028 | 0,018  | 0,022  | -0,214 | -0,220 | 0,228  | 0,216  | 0,363  | 0,374  | 0,319   | 0,315   | -0,491  | -0,461  |
| 0,465  | -0,316 | -0,301 | 0,075  | 0,084  | 0,098  | 0,120  | 0,261  | 0,265  | 0,104   | 0,106   | -0,483  | -0,501  |
| -0,120 | -0,093 | -0,104 | -0,01  | -0,009 | 0,423  | 0,401  | 0,226  | 0,220  | 0,553   | 0,550   | -0,373  | -0,365  |
| 0,604  | 0,373  | 0,386  | -0,304 | -0,305 | 0,435  | 0,433  | -0,264 | -0,276 | -0,159  | -0,145  | 0,017   | 0,013   |
| 0,230  | -0,215 | -0,216 | 0,299  | 0,311  | 0,402  | 0,390  | 0,410  | 0,383  | -0,373  | -0,37   | -0,347  | -0,355  |
| 0,103  | -0,531 | -0,575 | 0,387  | 0,381  | 0,254  | 0,262  | 0,057  | 0,053  | -0,049  | -0,052  | -0,363  | -0,372  |
| -0,036 | 0,263  | 0,238  | -0,030 | -0,032 | -0,058 | -0,082 | 0,456  | 0,446  | -0,372  | -0,382  | 0,068   | 0,064   |



2: Časová řada originálních dat, interpretace neuronovou sítí a průběh predikce

Pro větší názornost jsou vstupní data i výstupy neuronové sítě znázorněny grafy na obr. 2. Z obrázku je patrné, že odchylky zdrojových hodnot od hodnot ge-

nerovaných neuronovou sítí jsou velmi malé. V závěrečné části grafu je znázorněna predikce (hodnoty viz tab. V) vývoje na dalších 20 dnů.

V: Prognózované hodnoty budoucího vývoje zisku

|                 |        |        |        |        |        |        |        |        |       |        |
|-----------------|--------|--------|--------|--------|--------|--------|--------|--------|-------|--------|
| <b>Dny</b>      | 1.     | 2.     | 3.     | 4.     | 5.     | 6.     | 7.     | 8.     | 9.    | 10.    |
| <b>Prognóza</b> | 0,461  | 0,17   | 0,439  | -0,316 | 0,346  | -0,147 | 0,106  | -0,335 | 0,755 | -0,482 |
| <b>Dny</b>      | 11.    | 12.    | 13.    | 14.    | 15.    | 16.    | 17.    | 18.    | 19.   | 20.    |
| <b>Prognóza</b> | -0,078 | -0,802 | -0,130 | 0,130  | -0,308 | -0,634 | -0,528 | 0,287  | 0,299 | 0,154  |

Experimentální model umožňuje predikci několika výstupních veličin systému, závislých na hodnotách vstupních veličin systému (obr. 2).

To znamená, že proces učení vícevrstvé neuronové sítě musí obsahovat učící klauzule ve smyslu výrazu

$$\bar{Y}(t_i) = F[\bar{Y}(t_{i-1}), \dots, \bar{Y}(t_{i-s}), \bar{X}(t_i), \bar{X}(t_{i-1}), \dots, \bar{X}(t_{i-s})], (3)$$

kde  $\bar{Y}(t_i)$  je vektor výstupních,  $\bar{X}(t_i)$  vstupních hodnot v čase  $t_i$  a  $s$  počet hodnot časových řad (resp. stavů systému) akceptovaných pro predikci výstupu.

## SOUHRN

Klíčovým faktorem výkonnosti managementu posledních několika let je rozhodování v prostředí rizika a nejistoty. Objevuje se mnoho kvalitativně nových informací i nástrojů k jejich využití v rozhodovacím procesu. Klasická statistická analýza dat je tak zařazována do širšího kontextu v příspěvku zmíněných datových skladů a metod dolování dat. Jedním z moderních nástrojů analýzy dat v manažerské praxi je umělá inteligence.

Z možností využití technologií umělé inteligence pro realizaci uživatelských aplikací v rámci podnikové inteligence jsou v příspěvku uvedeny dva příklady, pro jejichž řešení byl využit experimentální model  $n$ -vrstvé neuronové sítě s učením podle vzorů metodou zpětného šíření chyb. Takový model rozšířený o vazbu na datový sklad představuje jednoduchý nástroj získávání znalostí o stavu a chování podnikových i mimopodnikových procesů, a potažmo i konkurenční výhody.

Nejen vícevrstvé neuronové sítě, ale i další technologie umělé inteligence nacházejí stále větší uplatnění v aplikacích pro podporu rozhodovacích procesů na úrovních řízení.

Schopnost rozeznat spolehlivost disponibilních informací, správně je interpretovat a seřadit tak, aby vzniklo přesné, kvalitní a kvalifikované rozhodnutí, je v odpovědnosti manažerských týmů. Použití nejnovějších přístupů a spojení teoretických základů s nekonečným potenciálem informačních technologií přináší do manažerské práce nové impulsy. Vztah mezi praktickými potřebami manažerského týmu, pružným rozvojem nových sofistikovaných metodik a jejich podporou v informačních technologiích je výzvou pro manažery stejně jako pro informatiky.

podniková inteligence, podnikový model, datový sklad, analytické nástroje, dolování dat, neuronové sítě, expertní systémy

Příspěvek vznikl v rámci výzkumného záměru VZ 6215648904.

#### LITERATURA

- Wikipedia. Business Intelligence. [online]. [cit. 23. 5. 2005]. URL: <<http://encyclopedia.thefreedictionary.com/Business+intelligence>>
- HUJŇÁK, P. Makroinformatika a podnikové informační systémy [online]. [cit. 23. 5. 2005]. URL: <<http://petr.hujnak.cz/aktivita/si/clanky/1997/makrociz.html>>
- SEARCH CRM. Business Intelligence. [online]. [cit. 23. 5. 2005]. URL: <[http://searchcrm.techtarget.com/sDefinition/0,,sid11\\_gci213571,00.html](http://searchcrm.techtarget.com/sDefinition/0,,sid11_gci213571,00.html)>
- EGIDERIA. Competitive Intelligence. [online]. [cit. 23. 5. 2005]. URL: <<http://www.egideria.com/>>
- CSIRO. Business Intelligence [online]. [cit. 23. 5. 2005]. URL: <<http://www.cmis.csiro.au/bi/what-is-BI.htm>>
- PYLE, D.: Business Modeling and Data Mining. Morgan Kaufman Publishers, San Francisco 2003. ISBN 1-55860-653-X
- BARQUIN, R. C., EDELSTEIN, H.: Planning and Designing the Data Warehouse. Prentice Hall, New Jersey 1997.
- FRAWLEY, W., PIATENSKY-SHAPIO, G., MATHIEUS, C.: Knowledge Discovery in Databases: An Overview. AI Magazine, Fall 1992, pgs 213–228

#### Adresa

Doc. Ing. Vladimír Konečný, CSc., Ing. Ivana Rábová, Ph.D., Ústav informatiky, Mendelova zemědělská a lesnická univerzita v Brně, Zemědělská 1, 613 00 Brno, Česká republika, [konecny@mendelu.cz](mailto:konecny@mendelu.cz), [rabova@mendelu.cz](mailto:rabova@mendelu.cz)