

## Prognózovanie obchodu a výroby v dynamicky sa meniacich podmienkach trhu

Peter Kačmár<sup>1</sup> a Dušan Malindžák<sup>2</sup>

### *Trade and production prognosis in condition of dynamic changes of market conditions*

*The trade dynamic changes of offers and demands strongly support ambitions of usage or development of prognosis methods, which are able to use solving of specified dynamic tasks. Solution of these tasks as a prediction of a future status is not only depended on the behaviour of the system in the past, but there are also composed some kinds of inputs information, which has a big value for prognosis making in the future.*

**Keywords:** prognosis, prediction, time series, method, dynamic changes, trade.

### Úvod

Aj napriek faktu, že strategické smerovanie podniku sa bez dlhodobej prognózy ťažko definuje, v súčasnosti vplyvom rýchlych zmien v trhovom prostredí je vysoká pravdepodobnosť výskytu pomerne veľkých nepresností pri vypracovávaní prognózy na dlhodobej úrovni. Príčiny je potrebné hľadať v hlavne súčasnej svetovej hospodárskej kríze, čo má za následok nasledovné zmeny:

- skokovité zmeny potrieb trhu,
- prevažne zánik a spomalený vznik nových firiem,
- zmena trendov predajnosti či spotrieb rôznych produktov,
- kolísanie cien produktov či služieb,
- rast nezamestnanosti a tým nižšia kúpna sila obyvateľstva,
- a pod.

Tento článok poukazuje na určité metódy prognózovania, ktoré je možné použiť pri vytváraní prognózy práve pri dnešných dynamických zmenách a poukazuje tiež na ich vhodnosť resp. aplikácie v praxi.

Súčasný stav metód prognózovania sa dá zdeliť do dvoch hlavných kategórií:

- Klasické metódy.
- Metódy umelej inteligencie (systémové metódy).

Toto základné delenie metód prognózovania môže byť interpretované každým autorom rôzne. Ako príklad môžem uviesť aj takéto delenie metód:

- Metódy trendové
- Metódy pre dynamicky meniace sa systémy (Malindžák).

Hlavným rozdielom medzi týmito dvoma kategóriami je ich prístup k riešeniu predikcie. Klasické metódy v sebe zahrňujú metódy kvantitatívne (objektívne) a kvalitatívne (subjektívne). Nová kategória metód (systémové) alebo metódy so systémovým prístupom, sú metódy, ktoré sú svojím charakterom veľmi zaujímavé z hľadiska spôsobu tvorby predikcie a sú výhodné pri použití práve v stochastických procesoch. Taktiež ich môžeme nazvať aj ako metódy umelej inteligencie, ktoré vo veľkej miere využívajú inteligentný výpočtový systém. Na jednej strane si zložité výpočty vyžadujú dostatočný výkon výpočtových prostriedkov, no na strane druhej, vďaka práve týmto komplexným výpočtovým riešeniam sa tieto metódy stávajú metódami, ktorých použitie pri riešení predikcie dynamických javov alebo javov v stave stochastičnosti prináša použiteľné a dôveryhodnejšie výsledky. V ďalšom sú uvedené metódy s ktorými sa dá najčastejšie stretnúť pri vypracovaní prognóz v praxi alebo sú zaujímavé vzhľadom k používaniu práve v dynamicky sa meniacich podmienkach.

<sup>1</sup> Ing. Peter, Kačmár, Technická univerzita v Košiciach, Fakulta BERG, Ústav logistiky priemyslu a dopravy, Park Komenského 14, 043 84 Košice, 055/602 2813, [peter.kacmary@tuke.sk](mailto:peter.kacmary@tuke.sk)

<sup>2</sup> Dr.h.c. prof. Ing., Dušan Malindžák, CSc., Technická univerzita v Košiciach, Fakulta BERG, Ústav logistiky priemyslu a dopravy, Park Komenského 14, 043 84 Košice, 055/602 3125, [dušan.malindzak@tuke.sk](mailto:dušan.malindzak@tuke.sk)  
(Recenzovaná a revidovaná verzia dodaná 28. 1. 10)

## Klasické metódy - kvantitatívne (objektívne) metódy

### Nelineárna regresia

Vynechaním jednoduchých metód priemerov a metód zložitejších ako je exponenciálne vyrovnávanie, ktoré nie sú vhodné pre výpočet prognóz v dynamicky sa meniacich podmienkach, sa dostávame k metódam regresie. Z pomedzi metód regresie vynecháme taktiež lineárnu regresiu, ale nelineárna už začína byť zaujímavá pre tvorbu no nie však 100 %-ná pre tvorbu prognóz v dynamicky meniacich sa podmienkach.

Pokiaľ tvar regresnej funkcie nie je krivka, jedná sa o nelineárnu regresnú analýzu. Výber nelineárneho regresného modelu (NLRM) na základe vykresleného bodového diagramu nie je vždy jednoduchý. Ako pomôcku možno zostaviť niekoľko typických priebehov a pre ne potom prepočítať vhodné modely priamo pomocou MNŠ (lineárne v parametroch) alebo nepriamo (po ich úprave linearizáciou).

Aj metódy lineárnej aj nelineárnej regresie sú súčasťou takmer všetkých štatisticko-matematických programov a tabuľkových procesorov. Z toho dôvodu nie je uvedený podrobný popis výpočtu funkcií pre jednotlivé modely. Práve vďaka špecifickým programom si nelineárna regresia našla obľubu používania, pretože užívateľ na základe stručného zadefinovania typu a stupňa regresného modelu získa výsledok pomerne zložitých výpočtov o danom jave. Metóda začína byť **vhodná** pri meniacich sa dejoch, **nie je však vhodná** pri skokovitých zmenách dejoch na trhoch v súčasnej dobe.

V súčasnej ekonomickej praxi (a ešte stále aktuálnej dobe hospodárskej krízy) sa však stretávame s radom javov, ktoré sú v čase nestabilné a pre ktoré:

1. Extrapoláčne prognostické metódy neposkytujú systémové prognózy, kde sa každý jav posudzuje izolovane. Ekonomické veličiny sú však sprevádzané radom ďalších veličín – náhodných, a teda stochastických a extrapoláčne prognostické metódy ich teda nevedia nijako využiť.
2. Kvalita analýzy a prognózy je silne závislá od typu zvoleného modelu. Voľba typu modelu pri spracovávaní, analýze a prognóze sa spravidla robí empiricky.

Možnosti vhodnosti použitia ekonomických modelov nie je vhodné určovať len na základe formálnych štatistických kritérií. Okrem toho je nutné sformulovať aj určité ekonomické predpoklady o dynamike prognózovaných javov. Je teda potrebné súčasne s kvantitatívnou analýzou rešpektovať výsledky kvantitatívnej analýzy a často sa opierať aj o intuíciu [2].

### Metóda harmonických váh

Metóda harmonických váh [1] zo skupiny kvantitatívnych metód patrí k metódam **vhodným** pre prognózovanie dejov v dynamicky meniacich sa podmienkach. Práve prítomnosť tzv. harmonických váh je predpokladom, že podľa vývoja deja v „N“ tom období bude nasledovať vývoj v „N+1“ období. Táto metóda bola v praxi aplikovaná autorom metódy ale aj v [8], pri hľadaní smerovania predaja obalových materiálov v firme Chemosvit fólie, a.s., práve v dobe hospodárskej krízy. Metóda harmonických váh vychádza z nasledujúcich myšlienok:

- a) Čím je hodnota v časovej sérii bližšie k času prognózy, má väčšiu prioritu.
- b) Najväčšiu dominanciu má posledná hodnota v časovom rade  $Y_N$  [1].

Z hodnôt časovej sekvencie dát vypočítame pomerové indexy:

$$PI(I,t) = Y(I,t) / Y(I,t-1)$$

kde:  $t = 2, 3, \dots, n$ ;

I = číslo skupiny výrobkov (ak sa prognóza vytvára pre viac skupín výrobkov).

Ak  $n = 4$  je počet časových intervalov, ktoré berieme do úvahy pri výpočte prognózy a počítame prognózu pre jeden výrobok, potom dostaneme tri pomerové indexy:

$$P(2), P(3), P(4) \text{ teda: } P(4) = \frac{Y_N}{Y_{N-1}}, P(3) = \frac{Y_{N-1}}{Y_{N-2}}, P(2) = \frac{Y_{N-2}}{Y_{N-3}}$$

Z týchto pomerových indexov vypočítame priemerný index skupiny výrobkov I, pomocou vzťahu pre harmonický vážený priemer.

$$PI(I) = \sqrt[n]{\left( \prod_{t=2}^n PI(I,t)^{W_t} \right)}$$

kde:  $W_t$  - sú tzv. harmonické váhy, ktoré vypočítame nasledovne:

$$W_t = \sum_{j=1}^{n-1} 1/(n-j)$$

Ak  $n = 4$ , potom:

$$W_2 = 1/(4-1) = 0,33,$$

$$W_3 = 1/(4-1) + 1/(4-2) = 0,83,$$

$$W_4 = 1/(4-1) + 1/(4-2) + 1/(4-3) = 1,83.$$

Z vyššie uvedeného vyplýva, že pre rôzne výrobky sú váhy rovnaké, pokiaľ  $n=4$ .

Priemerný index skupiny výrobkov I,  $PI(I)$  udáva extrapoláčnú smernicu, ako sa má  $Y_N$  ďalej vyvíjať.

Potom prognóza:

$$Y_{N+1}(I) = \bar{Y}_N(I) + (PI(I) - 1) \times Y_N(I)$$

kde:

$$(PI(I) - 1) \times Y_N(I)$$

predstavuje  $\Delta Y_N(I)$ , o ktorú sa má zmeniť posledná známa hodnota  $Y_N(I)$  a tak dostaneme hodnotu prognózy  $Y_{N+1}(I)$ .

Metóda je podobná ako metóda exponenciálneho vyrovnávania, avšak má dve výhody:

1. váhy zohľadňujú informačný prínos dát k prognóze;
2. váhy nie sú volené ľubovoľne.

Celá metóda je vypracovaná autorom publikácie a v nej je aj uvedená [1].

Metóda je **vhodná** pre systémy s **veľkou dynamikou zmien** najmä pre trendové modely.

### Klasické metódy - kvalitatívne (subjektívne) metódy

Podobne ako v prípade kantitatívnych hodnôt aj tu sa zameriavame na tie najdôležitejšie a najčastejšie metódy používané v praxi, ktoré sa svojim charakterom subjektívneho posudzovania stávajú použiteľnými v rôznych oblastiach a v rôznych obdobiach (rastu, ustáleného stavu a taktiež kríz, či neistôt). Sú taktiež vhodné pre doplnenie alebo spresnenie kvantitatívnych metód.

Tieto metódy sa v niektorých literatúrach uvádzajú aj ako „skupinové“ a často sa tiež využívajú na určovanie problémových častí (činností) systému na určovanie priorit [22].

#### **Panelová zhoda (brainstorming, skupinový posudok)**

Ide o najrozšírenejší metodologický postup. Nie je to v pravom slova zmysle metóda, ale ako skôr významný doplnok k ďalším metódam. Spočíva vo vytváraní expertných skupín (panelov), ktorých členovia v rámci výmeny názorov, brainstormingu, hľadajú odpovede na vytýčené otázky, či už v zadaní programu alebo v rôznych etapách prognózovania. V rámci skupín (panelov) vznikajú kontúry budúcich výstupov prognózovania. Ako bolo vyššie spomenuté, **je to veľmi vhodný doplnok** k vytváraniu prognózy **pre obdobia s dynamickými zmenami**.

#### **Delfská metóda (Metóda Delphi)**

Táto metóda spočíva v zadávaní otázok expertom v dvoch etapách, s cieľom postupného dosiahnutia spoločného názoru a určitého konsenzu v pohľade na príslušnú problematiku. V každej nasledujúcej etape zadávania otázok sa tieto formulujú okolo odpovedí, pri ktorých bola dosiahnutá najväčšia zhoda expertov. Základnou koncepčnou myšlienkou metódy je, že konsenzus, ktorý sa dosiahol v rámci skupiny expertov, je spoľahlivejší ako názor jedného experta. Oproti brainstormingu je konsenzus tvorený tak, že jednotliví odborníci či experti medzi sebou nekomunikujú. Aj napriek tomu, že nevieme zaručiť anonymitu expertov a doba trvania môže byť veľká, keďže konsenzus je tvorený aj vo viacerých kolách, **je takisto táto metóda vhodná** pri tvorbe prognóz **v rôznych obdobiach**.

#### **Prieskum trhu**

Metóda prieskumu trhu sa používa na zber informácií o trhu v podobe očakávaní, požiadaviek, nedostatkov a pod. Prieskum trhu odráža momentálny stav trhov, a preto je výborná na získanie aktuálnych momentálnych informácií, no vo väčších časových horizontoch pri uvažovaní do budúcnosti už môže vznikaf skreslenie.

### Metódy umelej inteligencie (systémové metódy)

Systémové metódy sú opäť v podstate číselné metódy, len svojou komplexnosťou môžu pri analýze číselných radov odhaliť zákonitosti, ktoré nie sú odhaliteľné za pomoci klasických metód.


## Prognózovanie pomocou neurónových sietí

Pojem umelé neurónové siete je pomerne mladý, ide vlastne o pojem pochádzajúci zo sietí umelej inteligencie, či samotnej kybernetiky. Jednou z definícií tohto pojmu podľa [5] by mohlo byť: masívny paralelný výpočtový systém, ktorý má schopnosť uchovávaní informácií a umožňuje ich ďalšie spracovanie, pričom napodobňuje ľudský mozog v zbieraní poznatkov v procese učenia (*adaptabilita*) a uchovávaní týchto poznatkov s využitím medzineurónových spojení.

Podstatou problému je proces učenia, v ktorom sa parametre neurónových sietí menia podľa určitých pravidiel. Charakter týchto pravidiel (algoritmov) determinuje typ učenia sa neurónových sietí. Pod učením rozumieme adaptáciu neurónových sietí, ktorá po ukončení učenia bude nositeľkou znalostí so schopnosťou implementácie v konkrétnej rozhodovacej situácii [22].

Podľa smeru, ktorým sa šíria signály v neurónových sieťach ich môžeme rozdeliť do dvoch základných skupín. Dopredné (feed-forward) sú také, v ktorých sa signál šíri iba od vstupných neurónov (neuróny, ktorých vstupmi sú signály z prostredia) cez skryté neuróny (neuróny, ktoré sú vstupmi aj výstupmi spojené s inými neurónmi, tieto sa v niektorých typoch sietí nemusia vôbec nachádzať) k výstupným neurónom (neuróny, ktorých výstup vedie do prostredia) [5].

Základným prvkom neurónovej siete je neurón. Vo všeobecnosti má niekoľko vstupov od iných neurónov alebo z okolitého prostredia a jeden výstup. Operácia, ktorou neurón transformuje svoje vstupy na výstup je spravidla veľmi jednoduchá. Zložitá činnosť neurónových sietí spočíva v spojení mnohých takýchto jednoduchých elementov do jedného celku. Na ďalšom obr. 2 máme možnosť vidieť matematický model neurónu s jeho vstupmi, výstupmi a váhami vstupu. [5]

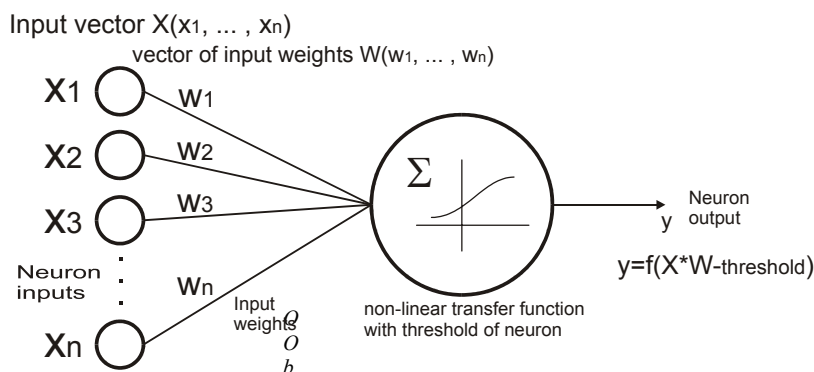


Obr. 1. Elementárny typ neurónovej siete.  
Fig. 1. Elementary type of neuron network.

Ako je z obrázka zrejmé, práca daného neurónu je charakterizovaná matematickou funkciou, a to:

$$y = f\left(\sum_{i=1}^n (x_i \cdot w_i) - \theta\right)$$

kde:  $y$  – výstup neurónu,  
 $w_i$  – váhy neurónu,  
 $x_i$  – vstupy neurónu,  
 $\theta$  – prah neurónu,  
 $f$  – neurónová aktivačná funkcia.



Obr. 2. Matematický model neurónu [6].  
Fig. 2. Mathematical model of a neuron [6].

Využitie neurónových sietí (neural networks) má síce stále najväčšie uplatnenie vo fyzike a v technických odvetviach, no ich výhody a princíp fungovania začína prenikať do ekonomiky a manažérstva. V ekonomike sa neurónové siete zvyknú využívať na modelovanie vývoja trhu, v ekonomickom prognózovaní, v rozhodovacích procesoch a pod.

Výhodou neurónových sietí je, že nie je potrebné mať na mysli nejaký špeciálny model, keď sa spúšťa analýza. Neurónové siete môžu tiež nájsť interakčné efekty (napríklad efekty z kombinácie veku a pohlavia), ktoré musia byť explicitne vyjadrené v regresii. Nevýhodou je ťažšia interpretácia výsledného modelu, preto ich použitie je užitočnejšie na predpovedanie cieľovej premennej, keď sú údaje nelineárne, ale nie sú veľmi užitočné alebo keď je potrebné tieto vzťahy medzi údajmi vysvetliť [5].

### Pohľad na spôsoby použitia neurónových sietí v praxi

Využívanie prognózovania pomocou neurónových sietí sa vo svete pomerne rýchlo rozšírilo a mnohí vedci začali publikovať svoje výsledky na odborných konferenciách. Vedci z Georgia Institute of Technology v Atlante, USA [16], rozoberajú prognózu poruchovosti priemyselných chladiarenských



podpory rozhodovania zvaný Vista, nasadený v riadiacom centre v Houstone. Systém spracúva údaje telemetrie a poskytuje odhady pravdepodobnosti vzniku rôznych porúch pohonu raketoplánov, spolu s odporúčaním najvhodnejších akcií a inteligentným zobrazovaním informácií. Rozšírené je tiež využitie v rôznych systémoch ohodnotenia a analýzy rizík, ako napr. Agena. Použitie bayesovských sietí bolo úspešne testované aj na predpovedanie futbalových výsledkov [7].

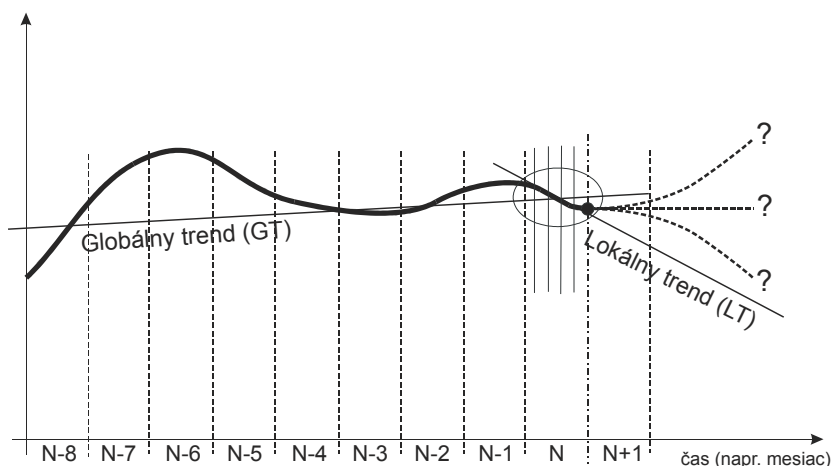
Bayesovské siete majú teda podobné vlastnosti ako neurónové siete, čo sa týka ich použitia v praxi a teda sú schopné vyhodnocovať obrovské množstvo údajov na vstupe za účelom stanovenia príslušného rozhodnutia resp. predikcie. Použitie bayesovských sietí v prostrediach neurčitosti je rozoberané autormi J. W. Sheppardom a M. A. Kaufmanom [18] zo spoločnosti ARINC (uvedený ako svetový líder v dopravnom, komunikačnom a systémovom inžinieringu), kde vytvorili pravdepodobnostno-výpočtový model pre prognózovanie v stave neurčitosti. Aj v tomto prípade vedci z Shanghai Jiaotong University [19] M. Dong a Z. Yang preverovali použitie bayesovských sietí pri konštruovaní prognózy spotreby vrtákov na určitom vrtacom stroji, kde príčina ničenia týchto vrtákov vstupuje veľká množstva vstupov do systému. Na samotný výpočet prognózy použili programový prostriedok Matlab na základe Bayesian Network Toolkit. Výsledkom bola síce funkčná, no na druhej strane len jednoúčelová prognóza, ktorá potrebuje ešte ďalší hlbší vývoj, aby mohla byť použitá na iné aplikácie. Aj keď ide o pomerne nový prístup pri tvorbe prognóz, použitie bayesovských sietí je **vhodné** na realizáciu prognóz pre dynamicky sa meniace deje a sú stále predmetom ďalšieho výskumu.

### Vývoj novej metódy - metóda „Hlava hada“

Táto metóda podobne ako ostatné kvantitatívne metódy vychádza z analýzy časových radov (TSA – time series analysis), ale dôležité je práve sústredenie sa na posledné obdobie  $N$  (obr. 3), ktorého hodnoty sú známe, sú najdôveryhodnejšie. Pri určovaní budúceho vývoja časového radu v čase „ $N+1$ “ vychádzame z predpokladu, že trend budúceho vývoja môže byť dvojaký, a to:

- podľa lokálneho trendu (vývoj podľa trendu v úseku „ $N$ “);
- podľa globálneho trendu (vývoj podľa celkového trendu celého časového radu).

Medzi GT a LT môžu nastať tri situácie:  $GT > / = / < LT$ .



Obr. 3. Príklad časového radu predaja či spotreby tovaru.

Pic. 3. Example of time series for sale or consumption of goods.

- Ak  $GT = LT$ , vývoj bude naďalej pokračovať podľa GT.
- Ak  $GT >$  alebo  $< LT$ , ďalší vývoj bude závisieť od GT alebo LT. Pokiaľ zmeny, resp. nerovnosť medzi GT a LT je nevýrazná, nie je veľká, tak vývoj a trend bude podľa GT. Pokiaľ sú zmeny výrazné, tak trend sa bude uberať podľa LT. Hranica určenia, kedy sa bude vývoj uberať podľa ktorého trendu je úzko špecifická pre oblasť použitia, či konkrétny výrobok, a je predmetom ďalšieho výskumu a vývoja tejto metódy.

### Metóda bilančnej rovnice

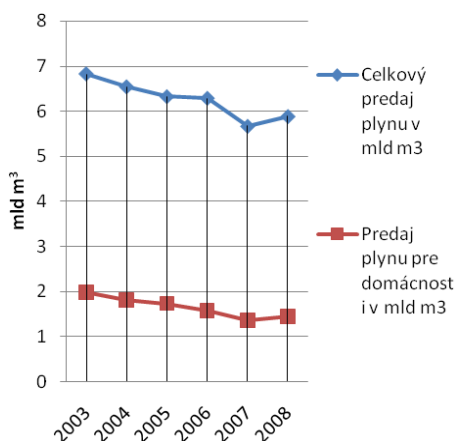
Iniciatíva pre vývoj tejto metódy vychádza z riešenia úlohy pre tvorbu prognózy spotreby energetickej komodity, a to konkrétne hnedého uhlia na Slovensku. Keďže Slovensko disponuje vlastnými zdrojmi hnedého uhlia, je pre potreby domácností aj priemyselných organizácií dôležitou zložkou energetických zdrojov Slovenska. Druhým veľkým konkurentom z hľadiska energetických zdrojov je zemný plyn a stále sa rozširujúca plynofikácia Slovenska. Ak zoberieme do úvahy všetky zložky energetických zdrojov, dostávame energetickú bilančnú rovnicu:



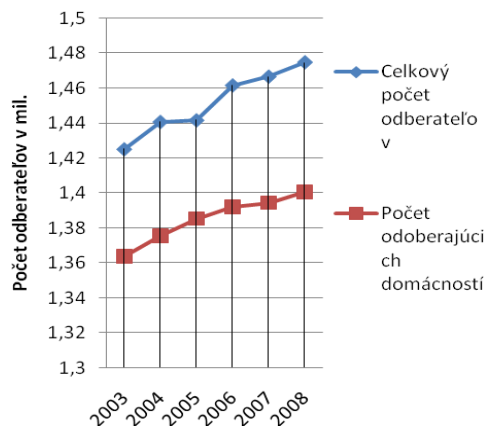
$$E_P + E_U + E_D + E_E + E_I = E_{CELK}$$

kde:  $E_P$  – energia z plynu,  
 $E_U$  – energia z uhlia,  
 $E_D$  – energia z dreva,  
 $E_E$  – elektrická energia,  
 $E_I$  – energia z iných palív,  
 $E_{CELK}$  – celkový energetický dopyt.

Najväčšie energetické zložky tvorí plyn a uhlie. Preto môžeme zanedbať ostatné zložky, pretože nemajú veľký vplyv na vývoj plynofikácie, resp. používanie hnedého uhlia. Takže sa bilančná energetická rovnica zjednoduší:  $E_P + E_U = E_{CELK}$ .




Obr. 4. Grafický prehľad vývoja predaja plynu.  
 Pic. 4. Chart for development of natural gas sale.  
 Source: SPP a.s.



Obr. 5. Grafický prehľad rozvoja plynofikácie.  
 Pic. 5. Chart for development of natural gas distribution.  
 Source: SPP a.s.

Na obrázkoch (obr. 4, 5) je vidieť, že aj napriek rastúcej plynofikácii pokles spotreby, s výnimkou roku 2008. Pod pokles spotreby zemného plynu sa v hlavnej miere podpisala cena, ktorá v znázornených rokoch výrazne stúpala. Obr. č. 6 znázorňuje kolísavý predaj hnedého uhlia na Slovensku v rokoch 2005-2009. V týchto rokoch je nevýrazný pokles predaja HU s výnimkou roku 2008, kedy bol dokonca nárast jeho predaja.



Obr. 6. Grafický prehľad vývoja predaja hnedého uhlia (HU).  
 Fig. 6. Chart for development of brown coal sale.  
 Zdroj: HBP, a.s.

Ak porovnáme grafické prehľady zistíme, že pri poklese predaja zemného plynu sa daný priestor ponúka hnedému uhlíu (prevažne pre domácnosti a malé podniky, ktoré HU používajú na vykurovanie). Ďalší zaujímavý vzťah je vidieť hlavne pri roku 2007, keď výraznejšie poklesla spotreba zemného plynu súčasne výraznejšie poklesla spotreba hnedého uhlia. Rok 2007 bol označený ako nadpriemerne teplý, s veľmi slabou zimou a tým pádom to výrazne ovplyvnilo spotrebu energetických komodít. Hľadanie užšej závislosti vzťahu plyn - hnedé uhlie je predmetom ďalšieho výskumu.

### Literatúra – References

- [1] Malindžák D.: Výrobná logistika I. *ŠTROFFEK, Košice, 1997.*
- [2] Seger J., Hindls, R.: Statistické metódy v tržním hospodárství, Viktoria Publishing, Praha, 1995.
- [3] Cipra, T.: Analýza časových rad s aplikaciami v ekonomii, *SNTL, Praha, 1986.*
- [4] Floreková L., Benková M.: Základy štatistického spracovania dát, *FPP-F BERG, TU Košice, 1998.*
- [5] Kelišek, A.: Analýza časových radov pomocou neurónových sietí, 21. 4. 2009, <http://aldebaran.feld.cvut.cz/~xmyslik/www/neural.html>.
- [6] Darula M., Bayesovské siete, <http://www2.fiit.stuba.sk/~kapustik/ZS/Clanky0607/darula/index.html>, 21. 4. 2009.
- [7] Šveda, M., Diplomová Práca, 2009.
- [8] [http://july.fixedreference.org/en/20040724/wikipedia/Bayesian\\_network](http://july.fixedreference.org/en/20040724/wikipedia/Bayesian_network), 25. 5. 2009
- [9] [http://controls.engin.umich.edu/wiki/index.php/Bayesian\\_network\\_theory](http://controls.engin.umich.edu/wiki/index.php/Bayesian_network_theory), 25. 5. 2009
- [10] [http://sk.wikipedia.org/wiki/V%C3%A1%C5%BEen%C3%BD\\_priemer\\_n%C3%A1kladov\\_na\\_kapit%C3%A1](http://sk.wikipedia.org/wiki/V%C3%A1%C5%BEen%C3%BD_priemer_n%C3%A1kladov_na_kapit%C3%A1) 18. 6. 2009
- [11] J. J. LaViola Jr.: Double Exponential Smoothing: An Alternative to Kalman Filter-Based Predictive Tracking, International Immersive Projection Technologies Workshop, [http://www.cs.brown.edu/~jil/pubs/kfvsexp\\_final\\_laviola.pdf](http://www.cs.brown.edu/~jil/pubs/kfvsexp_final_laviola.pdf).
- [12] <http://uk.answers.yahoo.com/question/index?qid=20070411153100AAb6OXW>, 24. 6. 2009
- [13] Motulski, H.: The difference between linear and nonlinear regression, 24. 6. 2009, [http://www.curvefit.com/linear\\_vs\\_nonlinear.htm](http://www.curvefit.com/linear_vs_nonlinear.htm).
- [14] Luo, J., Qiao L.: Model-based Prognostic Techniques, AUTOTESTCON 2003, IEEE Systems Readiness Technology Conference Proceedings, 25. 5. 2009, <http://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=4273732&isnumber=4273706&type=ref>.
- [15] Wang, P., Vachtsevanos, G.: Fault Prognosis Using Dynamic Wavelet Neural Networks, AAI Technical Report SS-99-04. *Compilation copyright © 1999, AAI (www.aaai.org)*.
- [16] Kemler, M., Fridrich, V.: Porovnanie neurónových sietí a regresných modelov na predpoveď koncentrácií prízemného ozónu, [www.cbks.cz/sbornikRackova03/sections/3/Kremler-Valach.pdf](http://www.cbks.cz/sbornikRackova03/sections/3/Kremler-Valach.pdf)
- [17] Sheppard J., W., Kaufman M., A.: Bayesian diagnosis and prognosis using instrument uncertainty, AUTOTESTCON 2005, IEEE Systems Readiness Technology Conference Proceedings, 18. 5. 2009, <http://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=1609172&isnumber=33790>.
- [18] Dong, M., Yang, Z.: Dynamic Bayesian Network Based Prognosis in Machining Processes, *Journal of Shanghai Jiaotong University (Science)*, 24. 6. 2009, <http://www.springerlink.com/content/a3071j18150tmh81/fulltext.pdf>.
- [19] [www.spp.sk](http://www.spp.sk)
- [20] [www.hbp.sk](http://www.hbp.sk)
- [21] Balog, M., Tomašová, D., Uličná, N.: Strategická logistika, *ES/AMS F BERG, 2005, ISBN 80-8073-409-7*