

PARAMETRIZÁCIA HYDROLOGICKÉHO TRANSFORMAČNÉHO MODELU V PROSTREDÍ MATLAB

Peter Šúrek, Ján Szolgay, Milan Čistý

Katedra vodného hospodárstva krajiny, Stavebná fakulta STU v Bratislave

Abstrakt

Naším dlhodobým cieľom je overiť použiteľnosť novodobých metód pri práci s transformačnými hydrologickými modelmi. Hydrologické transformačné modely sú nástroje vodného hospodárstva, ktoré simulujú transformáciu povodňovej vlny v otvorených korytách, ktorý tu definujeme ako proces zmeny tvaru povodňovej vlny pri jej postupe určitým riečnym úsekom. To umožňuje predpovedanie vodného stavu v nižšie položenom profile, ak je známy priebeh povodňovej vlny na vstupe do simulovaného riečného úseku. V praxi sa transformačné modely využívajú na predpovedanie povodňových prietokov v určitom riečnom profile, čo umožňuje riadenie vodohospodárskych sústav v reálnom čase.

Matematické modely transformácie povodňovej vlny v koryte toku rozdeľujeme na hydraulické a hydrologické. Hydraulické modely detailne opisujú správanie sa transformácie prietokov v koryte toku pomocou parciálnych diferenciálnych rovníc. Vyžadujú veľké množstvo vstupných údajov (ako napr. opis geometrie koryta a drsnosti toku). Parametre týchto modelov majú fyzikálny význam. Môžu byť priamo merané alebo vypočítané, a teda zostavenie modelov nevyžaduje údaje o správaní sa simulovaného úseku v minulosti. Hydrologické modely sú v kontraste s hydraulickými založené na napodobňovaní správaní sa systému v minulosti. Parametre modelov nie sú väčšinou priamo merateľné, ale získavajú sa kalibráciou týchto modelov zo zodpovedajúcich si vstupných a výstupných hydrogramov. Jeden z najrozšírenejších hydrologických modelov u nás je multilineárny model kaskády lineárnych nádrží (KLN).

V tejto práci, ktorá nadväzuje na výsledky práce Šúrek (2009), je opísaný koncept, v ktorom je model KLN parametrizovaný umelou neurónovou sieťou (UNS). Výstupom použitej UNS sú optimálne hodnoty parametrov modelu KLN zohľadňujúc rôzne odtokové stavy. Bola použitá dopredná neurónová sieť, ktorá v procese učenia využíva metódu spätného šírenia chýb (feed-forward backpropagation). Na riešenie daného problému bolo použité programové prostredie MATLAB.


Navrhnutý hybridný koncept, v ktorom bol riečny transformačný model KLN parametrizovaný pomocou UNS, v porovnaní s KLN modelmi kalibrovanými pomocou genetického algoritmu dosahoval vyššiu presnosť simulácie, čo nás motivuje overiť navrhnutý koncept aj na iných riečnych úsekoch.

1 Úvod

V štúdiu sa zaoberáme simuláciou transformácie povodňových vln v otvorených korytách, ktoré tu chápeme ako proces zmeny tvaru povodňovej vlny pri jej postupe určitým riečnym úsekom. Tento proces je pomerne dobre opísateľný matematickými modelmi, ktoré umožňujú napr. predpovedať povodňové prietoky v určitom riečnom profile.


Postupová doba je dôležitým parametrom transformácie prietokovej vlny, ktorú tu definujeme ako čas, za ktorý postúpia charakteristické body povodňovej vlny (napr. vrcholy alebo ťažiská) riečnym úsekom. Morfológické a hydraulické charakteristiky simulovaného riečného úseku a tvar prítoku sú premietnuté do postupovej doby transformovanej povodňovej vlny. Tak ako sa morfológické a hydraulické charakteristiky menia s výškou hladiny a teda aj s prietokom v koryte, mení sa aj hodnota postupovej doby.

Prevrátenou hodnotou postupovej doby je celerita (rýchlosť postupu prietokovej vlny). Price (1973) upozornil na závislosť celerity od prietoku. Všeobecný tvar tejto závislosti popísal ako dve mocninové funkcie spojené prechodovou krivkou v tvare S (obr. 1).



Obr.1. Všeobecný tvar závislosti celerity vlny (prevrátenej hodnoty postupovej doby) od prietoku opísaný v Price (1973).

Danáčová (2005) analýzou postupových dôb prietokových vln potvrdila tvar závislosti opísaný Pricom (1973) na rieke Morava (obr.2). Avšak pomerne veľký rozptyl bodov nás pri predpovedaní postupovej doby motivuje popri prietoku zohľadniť ďalšie faktory ako napr. vplyv bočných prítokov, sklon vodnej hladiny, alebo drsnosti koryta.




Obr.2. Závislosť postupovej doby od prietoku na rieke Morava u úseku Moravský Svätý Ján – Zahorská Ves (Danáčová, 2005).

Cieľom tejto štúdií je overiť možnosť parametrizácie multilineárneho hydrologického riešenia modelu kaskády lineárnych nádrží (KLN) aplikovaním neurónových sietí na odhad parametra k modelu KLN. Práca nadväzuje na výsledky práce Šúrek (2009).

2 Transformačný model KLN

V tejto štúdií bol použitý hydrologický transformačný multilineárny model kaskády lineárnych nádrží (KLN), ktorý reprezentuje schéma na obr.3. Model KLN predstavuje rozšírenie pôvodného modelu Kalinina a Miljukova (Kalinin-Miljukov, 1957) o bočné prítoky, do každej nádrže v kaskáde.



Obr.3. Schéma modelu KLN, kde $I(t)$ predstavuje vstupný prítok, $I_{s,i}(t)$ bočné prítoky, $Q(t)$ výstupný prítok z modelu a S_i je stavová veličina reprezentujúca objem vody v i -tej nádrži kaskády.

Každá nádrž okrem prvej má prítok z predchádzajúcej nádrže. Vstup do modelu predstavuje hydrogram v hornom profile modelovaného úseku a výstup z kaskády je zároveň výstupom z riečného úseku. Kaskáda môže byť obohatená o bočné prítoky, tak ako to naznačuje schéma na obr. 3.

Stavové rovnice modelu boli odvodené ešte v práci Szolgay (1981), kde sa vychádzalo z rovnice kontinuity a statickej relácie lineárnej nádrže. Odvodené stavové rovnice sú zapísané v tvare:

$$\bar{S}(a+1) = \bar{\Phi}(a+1, a) \bar{S}(a) + \bar{\Psi}(a+1, a) \bar{I}(a+1, a) \quad (1)$$

$$Q(a+1) = \bar{H}(a) \bar{S}(a+1) \quad (2)$$

kde $\bar{S}(a)$, $\bar{S}(a+1)$ je vektor objemov jednotlivých nádrží v časoch a , $a+1$.

$Q(a+1)$ je výstup zo systému, matica H je v danom prípade vektor $H = [0, 0, 0, \dots, 1/k]$.

Pre prvky prechodových matic Φ , Ψ , za predpokladu konštantných vstupov v intervale $\langle a, a+1 \rangle$, platí:

Pre $i \geq j$

$$\Phi(i, j) = \frac{T^{i-j} \cdot e^{-T/k}}{(i-j)! \cdot k^{(i-j)}} \quad (3)$$

$$\Psi(i, j) = k - \sum_{f=0}^{i-1} \frac{T^f \cdot e^{-T/k}}{f! k^{f-1}} \quad (4)$$

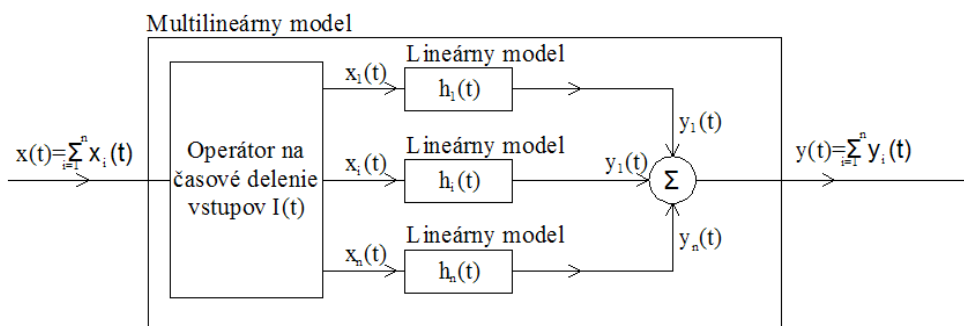
Inak

$$\Phi(i, j) = 0 \quad (5)$$

$$\Psi(i, j) = 0 \quad (6)$$

Parametrami modelu sú počet nádrží v kaskáde n a parameter k , ktoré boli v minulosti počas modelovania považované za konštantné. Kalinin a Miljukov (1957) naznačili, že súčin n a k je úmerný hodnote postupovej doby. Použitelnosť takto zostrojeného modelu pre rieky s premenlivou postupovou dobou je však obmedzená.

Premenlivosť postupovej doby je možné zohľadniť použitím princípov multilinearity, ktorý navrhol Kundzewicz (1985) (obr. 4). Ide o kombináciu dvoch koncepcií, operátora na rozdelenie vstupného signálu do modelu na čiastkové signály a množinu lineárnych transformačných submodelov, ktoré sa podieľajú na transformácii vstupu na výstup zo systému.




Obr.4. Základná schéma multilinearity, ktorý navrhol Kundzewicz (1985).

Nelineárny proces sa potom simuluje množinou lineárnych submodelov. V modeli KLN sa jednotlivé lineárne submodely líšia hodnotou parametra k . Túto hodnotu je možné viazať na ovplyvňujúce faktory tak, aby najlepšie vystihovali stav opisovaného javu. Takýto koncept bol použitý aj v Szolgay (2003) a Danáčová (2008), kde multilineárny koncept modelu KLN bol identifikovaný závislosťou $k=f(Q_{in})$. Išlo o sériu lineárnych modelov, v ktorých sa parameter k menil v závislosti na prítoku. V kontraste s predchádzajúcimi prácami je v tejto štúdii multilineárny koncept modelu KLN parametrizovaný umelou neurónovou sieťou, ktorej výstup bol hodnota parametra k .

3 Metóda

V predchádzajúcich prácach Szolgay (2003), Danáčová (2005) a Šúrek (2008) sa parameter k modelu KLN menil v závislosti na vstupnom prítoku do simulovaného úseku. Vplyv bočného prítoku a vegetácie bol zanedbaný. Preto si táto štúdia dáva za cieľ zlepšiť parametrizáciu modelu, zabudovaním umelej neurónovej siete (UNS) do transformačného modelu. UNS v modeli nahradila doposiaľ používanú regresnú závislosť $k=f(Q)$.

V práci je použitá viacvrstvová dopredná neurónová sieť (Feed Forward Neural Network, FFNN), ktorá je zložená z troch typov vrstiev, do ktorých sú neuróny zoskupované: vstupná, skrytá a výstupná vrstva.



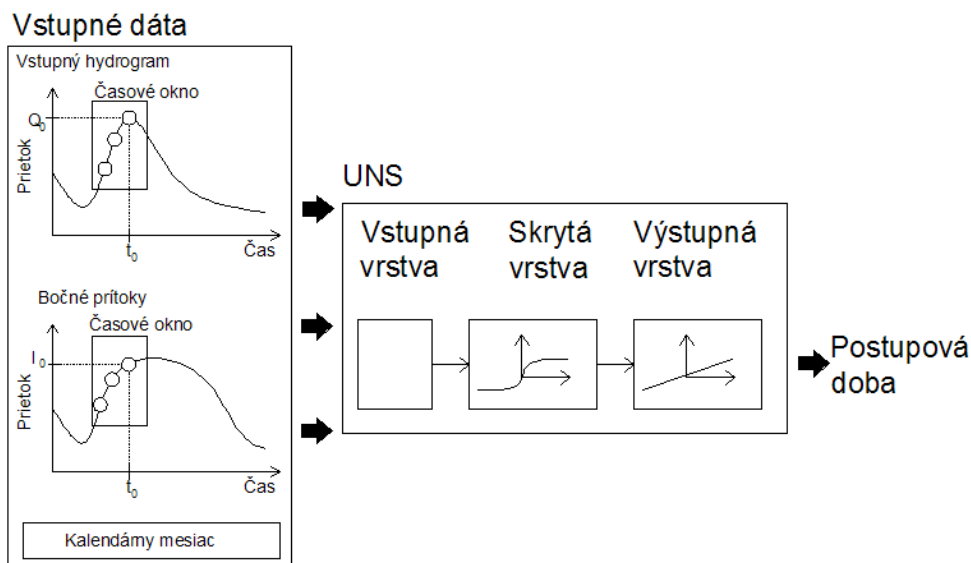
Obr.5. Viacvrstvová dopredaná neurónová sieť zložená zo vstupnej, skrytej a výstupnej vrstvy.

UNS bola natrénovaná tak, aby odhadovala pre rôzne prítokové stavy optimálnu hodnotu parametra k . UNS zohľadňovala vplyv sezóny v roku, vplyv bočných prítokov do simulovaného prítoku ako aj vplyv tvaru povodňovej vlny. Ako vstupy do UNS boli zvolené:

- údaje o prítoku na vstupnom profile do modelovaného úseku s niekoľko hodinovou históriou, aby mala UNS informáciu o tvare transformovanej vlny.
- údaje o prítoku na prítoku Zaya s niekoľko hodinovou históriou

- poradové číslo kalendárneho mesiaca, čo umožnilo zahrnúť vplyv vegetácie

Štruktúra vstupov je znázornená na obr. 6



Obr.6. Štruktúra vstupov do zostavenej UNS siete.

V práci bola použitá dopredná neurónová sieť, ktorá v procese učenia využíva metódu spätného šírenia chýb (feed-forward backpropagation). Sieť bola zostavená z jednej skrytej vrstvy s aktivačnou funkciou hyperbolický tangenciálny sigmoid. Optimálny počet neurónov v skrytej vrstve bol určený metódou pokus-omyl. Sieť dosahovala najvyššiu výkonnosť s ôsmimi neurónmi v skrytej vrstve. Na učenie bola zvolená metóda Levenberg-Marquardt, s optimalizačným kritériom MSE (Mean Squared Error).

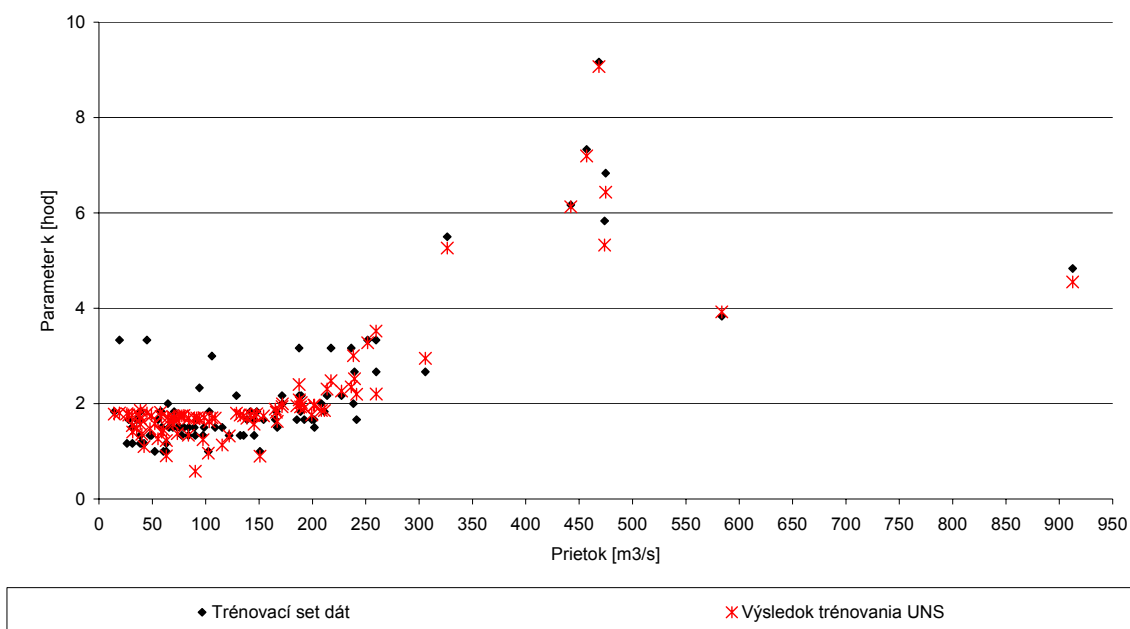
Hodinové údaje z riečného úseku medzi vodomernými stanicami Moravský Svätý Ján – Záhorská Ves na toku Morava z obdobia 1992-2002 boli použité na overenie funkčnosti navrhnutého konceptu. Rovnaké údaje boli použité v práci Danáčová (2005). To umožnilo porovnanie výkonnosti týchto dvoch koncepcií. Ako porovnávacie kritérium presnosti simulácie bol použitý Nash-Sutcliffov koeficient (Nash, 1970).

$$R^2 = 1 - \frac{\sum_{t=1}^N (Q_{o(t)} - Q_{m(t)})^2}{\sum_{t=1}^N (Q_{o(t)} - \overline{Q_o})^2} \quad (7)$$

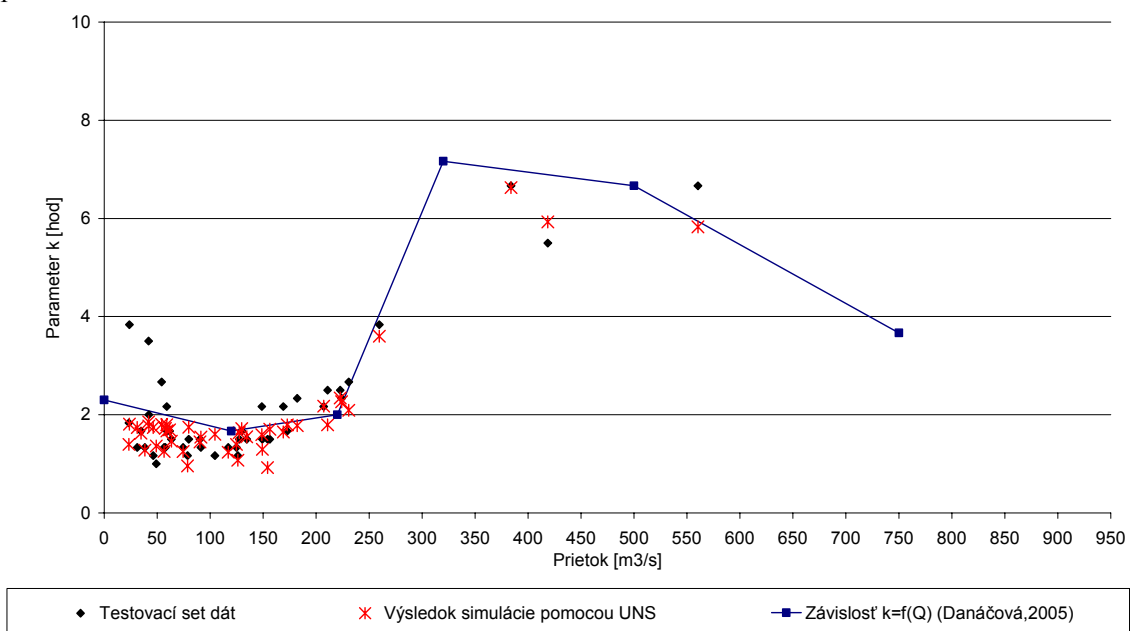
Kde: $\overline{Q_o}$ je aritmetický priemer meraných prietokov; $Q_{o(t)}$ je meraný prietok a $Q_{m(t)}$ je simulovaný prietok.

4 Prezentácia a analýza výsledkov

V prvej fáze bola zostrojená UNS, ktorej výstupom sú optimálnej hodnoty parametra k . Výsledky učenia a verifikácie zostavenej siete znázorňujú obr.7 a obr.8.




Obr.7. Výsledky učenia neurónovej siete, ktorá bola učená tak, aby jej výsledkom boli hodnoty parametra k .




Obr.8. Výsledky validácie siete a porovnanie schopnosti siete vystihnúť postupovú dobu so reťazovou závislosťou, ktorá bola odhadnutá v práci Danáčová (2005).

Sieť lepšie odhaduje hodnoty postupovej doby v porovnaní s regresnou závislosťou (Danáčová, 2005), kde je postupová doba viazaná iba na hodnoty prietokov. Pri predpovedaní postupovej doby s použitím UNS bola dosiahnutá hodnota kritéria strednej kvadratickej chyby MSE (Mean Squared Error) 10,02 m³/s, zatiaľ čo pri použití reťazovej závislosti bola hodnota MSE 13,13 m³/s.

Po procese učenia UNS, mohla byť následne sieť napojená na multilinéarny model. Obrázky č.9 a č.10 znázorňujú výstupy simulácie KLN modelu, ktorý je parametrizovaný UNS sieťou.



Obr.9. Priebeh verifikácie prietokovej vlny z obdobia od 8.11.1996-9.12.1996, pri použití model KLN so vstavanou UNS. Nash-Sutcliffov koeficient dosiahol hodnotu 0,978.



Obr.10. Priebeh verifikácie prietokovej vlny z obdobia od 09.02.1997-18.03.1997, pri použití model KLN so vstavanou UNS. Nash-Sutcliffov koeficient dosiahol hodnotu 0,976.

V tabuľke 1 sú pre porovnanie uvedené získané hodnoty Nash-Sutcliffovho koeficientu z predchádzajúcich prác. Danáčová (2005) viazala hodnotu parametra k na prietok v vstupnom profile. V práci Šúrek (2009), na ktorú nadväzuje súčasná štúdia, bol transformačný model parametrizovaný pomocou UNS, avšak práce sa líšia samotnými vstupmi do UNS. Vstupy do UNS použitej v tejto

štúdií boli podrobne rozpísané v predchádzajúcej kapitole. UNS zo štúdie Šúrek (2009) bola zostrojená pre nasledovné vstupy: prietok v profile do modelovaného úseku a rýchlosť nárastu prietoku transformovanej vlny.

Tab.1. Porovnanie dosiahnutých hodnôt Nash-Sutcliffových koeficientov s predchádzajúcimi prácami.

Obdobie	Kulminácia [m ³ /s]	Predchádzajúce práce		Súčasná práca
		Danáčová (2005)	Šúrek (2009)	
06.06.1992 - 19.06.1992	120,9	0,942	0,947	0,921
13.01.1993 - 14.02.1993	154,7	0,921	0,926	0,935
08.11.1996 - 09.12.1996	207,4	0,976	0,971	0,978
20.12.1995 - 06.01.1996	212,7	0,995	0,933	0,948
29.08.1995 - 13.09.1995	222,8	0,982	0,944	0,982
07.12.1993 - 01.03.1994	251,2	0,987	0,976	0,986
17.11.1991 - 19.11.1991	259,5	0,989	0,969	0,959
24.05.1994 - 06.06.1994	272,6	0,963	0,962	0,944
04.09.1996 - 09.11.1996	305,8	0,983	0,981	0,960
15.10.1998 - 05.12.1998	438,4	0,983	0,98	0,969
09.02.1997 - 18.03.1997	457	0,985	0,978	0,976
11.03.1993 - 06.05.1993	470,6	0,958	0,949	0,946
20.01.1992 - 27.04.1992	583,5	0,984	0,988	0,989
15.03.1996 - 12.06.1996	622,4	0,974	0,984	0,975
Priemer:		0,973	0,963	0,962

Pri simulovaní transformácie povodňovej vlny dosahoval navrhnutý koncept pomerne vysokú presnosť. Avšak v porovnaní s prácou Danáčová (2005) dosiahol horšie hodnoty Nash-Sutcliffových koeficientov.

5 Záver

V práci sa overovala použiteľnosť neurónových sietí na parametrizáciu riečného transformačného modelu KLN. Analýza výsledkov potvrdila, že UNS sú mimoriadne vhodné na predpovedanie samotnej postupovej doby prietokovej vlny (obr.8).

Navrhnutý koncept parametrizácie riečného transformačného modelu KLN pomocou UNS nedosahoval presnosť simulácie modelu z predchádzajúcej práce Danáčová (2005). Autori článku predpokladajú, že celkový potenciál parametrizácie KLN pomocou UNS ešte nebol dostatočne využitý.

Spracovanie štúdie bolo podporené Agentúrou na podporu vedy a techniky prostredníctvom finančnej podpory č. APVV-0443-07.

6 Referencie

- Danáčová, M. (2005): Hodnotenie zmien transformácie vln na dolnej Morave. Diplomová práca, Slovenská technická univerzita v Bratislave.
- Danáčová, M., Spál, P., Szolgay, J. (2008): Analýza citlivosti multilineárneho transformačného modelu KLN na voľbu počtu nádrží a súčiniteľa lineárnej nadržky. *Acta Hydrologica Slovaca*. Ročník 9, č.1, 2008, 24-38.
- Dawson, C. W. , Harpham, C. , Wilby, R. L. , Chen, Y. (2002): Evaluation of artificial neural network techniques for flow forecasting in the River Yangtze, China. *Hydrology and Earth System Sciences*, 6, 619-626.
- Drábek, O., Seidl, P., Taufer, I. (2006): Umelé neuronové siete – základy teórie a aplikácie. *CHEMagazín*, číslo 1, ročník XVI.
- Goswami, M., O'Connor, K. M. (2006): Real-time flow forecasting in the absence of quantitative precipitation forecasts: A multi-model approach. *Journal of Hydrology*, Volume 334, Issue 1-2, p. 125-140.
- Kalinin, G. P, Miljukov, P. L. (1957): O raschote neustanovivshegosya dvizhenia vodi v otkritich ruslakh (in Russian), *Meteorologia i gidrologia*, 10, p. 10-18. Cited in: Pekarova, P., Szolgay, J. (2005). Multilineárny model transformácie prietokov v korytách tokov. In: *Scenáre zmien vybraných zložiek hydrosféry a biosféry v povodí Hrona a Váhu v dôsledku klimatickej zmeny*. Bratislava. p. 203 – 252.
- Kundzewicz, Z. W., Dooge, J. C. I. (1985): Unified structural approach to linear flood routing. *Advances in Water Resources*, 8(3), p. 37–42. Cited in: Pekarova, P., Szolgay, J. (2005). Multilineárny model transformácie prietokov v korytách tokov. In: *Scenáre zmien vybraných zložiek hydrosféry a biosféry v povodí Hrona a Váhu v dôsledku klimatickej zmeny*. Bratislava. p. 203 – 252.
- McCulloch, W. S. , Pitts, W. H. (1943): A logical calculus of the ideas immanent in nervous activity. *Bulletin of Mathematical Biophysics*, 5:115-133.
- Nash, J. E., Sutcliffe, J. V. (1970): River flow forecasting through conceptual models part I — A discussion of principles, *Journal of Hydrology*, 10 (3), p. 282-290.
- Price, R. K. (1973): Flood routing methods for British rivers, *Proceedings of the Institution of Civil Engineers*, 55, p. 913–930.
- Shrestha, R.R., Theobald, S. ,Nestmann F. (2005): Simulation of flood flow in a river system using artificial neural networks, *Hydrol. Earth Syst. Sci.*, 9, 313-321.
- Spál, P., Szolgay, J., Danáčová, M. (2008): Voľba účelovej funkcie pri optimalizácii parametrov multilineárneho transformačného modelu KLN. *Acta Hydrologica Slovaca*. Ročník 9, č. 2, 2008, 243-251.
- Szolgay, J. (1981): *Adaptívne modely v hydrologických predpovediach*. PhD Thesis, Bratislava, UHH SAV, p. 130.
- Szolgay, J. (2003): Multilinear discrete cascade model for river flow routing and real time forecasting in river reaches with variable wave speed. In: *Assessment of the impacts of land-use and climate changes*. Proceedings of the ESF LESC Exploratory Workshop held at Bologna, October 24–25.
- Šúrek, P. (2009): Parametrizácia hydrologického transformačného modelu neuronovou sieťou. *Acta Hydrologica Slovaca*. Ročník 10, č. 1, 2009.