

ČESKÉ VYSOKÉ UČENÍ TECHNICKÉ V PRAZE – FAKULTA STAVEBNÍ

Program doktorského studia: STAVEBNÍ INŽENÝRSTVÍ

Obor doktorského studia: ZDRAVOTNÍ A EKOLOGICKÉ INŽENÝRSTVÍ

Ing. Marek Němec

PREDIKCE POTŘEBY VODY POMOCÍ NEURONOVÝCH SÍTÍ
PREDICTION OF WATER REQUIREMENTS USING NEURAL
NETWORK

Teze disertace k získání akademického titulu "doktor", ve zkratce "Ph.D."



Školitel: Doc. Ing. Iva Čiháková, CSc.

Praha, srpen 2005

Disertační práce byla vypracována v prezenční formě doktorského studia na katedře zdravotního a ekologického inženýrství Fakulty stavební ČVUT v Praze.

Uchazeč: Ing. Marek Němec
Fujitsu Siemens Computers
Evropská 176, Praha 6, 160 00

Školitel: Doc. Ing. Iva Čiháková, CSc.
katedra
Fakulta stavební ČVUT
Thákurova 7, 166 29 Praha 6 - Dejvice

Oponenti:

.....

.....

Teze byly rozeslány dne:

Obhajoba disertace se koná dne v hod. před komisí pro obhajobu disertační práce ve studijním oboru Vodní hospodářství a vodní stavby v zasedací místnosti č Fakulty stavební ČVUT v Praze.

S disertací je možno se seznámit na děkanátě Fakulty stavební ČVUT v Praze, na oddělení pro vědeckou a výzkumnou činnost, Thákurova 7, 166 29 Praha 6 – Dejvice.

.....
předseda komise pro obhajobu disertační práce
ve studijním oboru
Vodní hospodářství a vodní stavby
Fakulta stavební ČVUT, Thákurova 7, 166 29 Praha 6 – Dejvice

1.	SOUČASNÝ STAV PROBLEMATIKY	1
1.1.	Ústavy věnující se výzkumu neuronových sítí	1
2.	CÍLE DISERTAČNÍ PRÁCE	2
3.	KLASICKÉ METODY ZPRACOVÁNÍ – PROGNOTICKÉ METODY.....	3
4.	NEURONOVÉ SÍTĚ – PŘEDSTAVENÍ.....	3
4.1.	Výhoda neuronových sítí oproti klasickým metodám	4
4.2.	Algoritmus Back-Propagation.....	4
4.2.1	Architektura sítě	5
4.2.2	Výkonný prvek umělé neuronové sítě.....	5
4.2.3	Učení sítě Back-propagation	6
4.2.4	Matematický popis algoritmu back-propagation	9
5.	MODELOVACÍ PROSTŘEDKY	10
6.	CHARAKTERISTIKA ČASOVÝCH ŘAD	10
6.1.	Rozptyl	10
6.2.	Výběrový rozptyl (<i>Var</i>).....	10
6.3.	Směrodatná odchylka (<i>STD</i>).....	10
6.4.	Empirické momenty.....	11
6.5.	Šikmost.....	11
6.6.	Špičatost (ang. Kurtosis).....	11
6.7.	Autokorelace	11
6.8.	Histogram	12
6.9.	Hustota	12
6.10.	Ověření normality.....	12
7.	VÝSLEDKY	13
8.	ZÁVĚR.....	18
9.	LITERATURA	19
10.	PUBLIKACE	20
11.	SUMMARY	20

1. SOUČASNÝ STAV PROBLEMATIKY

Ve vodním hospodářství se doposud využívalo zejména klasických prognostických metod. Využití neuronových sítí se začíná uplatňovat zejména v posledním období ve spojení s nárůstem výpočetního výkonu PC.

1.1. Ústavy věnující se výzkumu neuronových sítí

Neuronovým sítím se na ČVUT nejvíce věnuje Doc. Ing. Miroslav Šnorek, CSc. z FEL ČVUT a neuronová skupina (Neural Computing Group) při katedře počítačů na FEL, kde jsem byl členem. Skupina se zabývá převážně výzkumem rozpoznávání znaků pomocí neuronových sítí například na automatizované třídění listovních zásilek nebo klasifikací respondentů s využitím neuronové sítě. Ve vodním hospodářství se neuronové sítě uplatňují zejména při predikci a optimalizaci složitějších soustav.

Na katedře hydrotechniky se problémem neuronových sítí zabývá Dr. Ing. Pavel Fošumpaur, který je využívá zejména pro předpovídání říčních průtoků a srážkoodtokových vztahů (ISBN 80-02-01274-7, ISSN 1211-0760). Na naší katedře zdravotního inženýrství se spotřebou vody zabývala již Doc. Ing. Iva Čiháková, CSc., ovšem za použití stochastických metod (Stochastický model potřeby vody se zaměřením na krátkodobou předpověď pro denní potřebu pitné vody, 1985. Případně ve své habilitační práci z roku 2004).

V rámci disertační práce byla navázána spolupráce například s děkanem Fakulty elektrotechniky a informatiky, VŠB – Technická univerzita Ostrava. Prof. Ing. Ivo Vondrákem, CSc., který mně v počátku ochotně poskytl několik cenných rad. Akademie věd ČR se v některých výzkumných úkolech také věnuje neuronovým sítím pod vedením Dr. Mirko Novaka z Ústavu informatiky.

Ze zahraničních ústavů zabývajících se predikcí spotřeby vody jsou to zejména STU Stavební fakulta, katedra zdravotního inženýrství v Bratislavě (např. Prof. Ing. Jozef Kriš, DrSc.) nebo Ing. Škarda B.C. ze švýcarských vodáren. Dále jsou to například tyto university: Technische Universität Berlin, Universität Hannover a jiné ústavy po celém světě zabývajících se výzkumem vody. Poměrně rozsáhlý výzkum v této oblasti prováděly vodárny v Barceloně (časopis Neural Network World), které si ovšem svoje výsledky pečlivě tají.

2. CÍLE DISERTAČNÍ PRÁCE

V disertační práci se budu zabývat výzkumem predikce potřeby vody pomocí neuronových sítí (dále NN sítě), a to jak z krátkodobého, tak z dlouhodobého hlediska na časových řadách s hodinovou potřebou vody. Takto malý krok byl zvolen záměrně, neboť tyto řady vykazují poměrně velký rozptyl a nahodilé výchyly, a proto je nelze s úspěchem modelovat pomocí klasických matematických metod.

V rámci disertační práce je třeba:

- i. Zjistit a ověřit, který typ neuronové sítě je vhodný pro predikci, zpracovat literaturu a vytvořit teoretický popis této sítě.
- ii. Vytvořit vhodný popis charakterizující časové řady.
- iii. Najít vhodný výpočetní prostředek pro pozdější analýzu, ten popsat a namodelovat výsledky.
- iv. V rámci modelování je nutné ověřit pokud možno co nejlepší postup, jak s časovými řadami nakládat.
- v. Dále se pokusím zjistit, zda se dají tyto parametry neuronové sítě aplikovat i na podobné časové řady potřeby vody, čímž by se značně urychlil vlastní učící proces.
- vi. Posoudit vhodnost neuronových sítí z hlediska krátkodobé predikce (čase $t+1$ vycházející ze známých hodnot) a dlouhodobé predikce (čase $t+x$, kdy se bude vycházet z již namodelovaných hodnot).
- vii. Závěrem každého výše uvedeného bodu dojde k porovnání namodelovaných výsledků se skutečnými hodnotami a zhodnocení dosažených výsledků.
- viii. Nakonec pro srovnání porovnáám predikci pomocí NN sítí s jinými typy předpovědních modelů. Například lineárními procesy, procesem klouzavých součtů MA, autoregresními procesy AR nebo smíšenými procesy ARMA či ARIMA. Tak, aby se mohly kvalitativně posoudit nejen výsledky nastavení jednotlivých NN sítí, ale aby existovalo i srovnání s jinými typy předpovědních modelů.
- ix. Závěrem dojde k celkovému zhodnocení použitelnosti neuronových sítí ve vodním hospodářství.

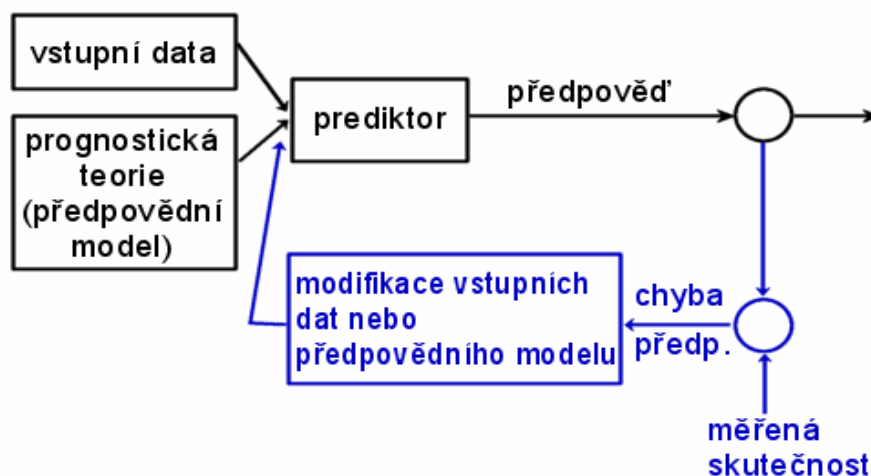
3. KLASICKÉ METODY ZPRACOVÁNÍ – PROGNOTICKÉ METODY

Při prognóze se vychází z minulého vývoje. Na prognózu ale působí tolik náhodných vlivů, že i nejlepší prognóza má jen jistou míru spolehlivosti a přesnosti. Prognózu můžeme rozdělit podle doby předpovědi na krátkodobé, střednědobé, dlouhodobé a perspektivní.

Přesnost každé prognózy závisí na třech faktorech:

- vstupních datech
- prognostické teorii – předpovědní model, popisující působení jednotlivých faktorů na předpověď
- prediktoru, tj. vlastní způsob určení předpovědi ze vstupních dat

Prognóza se v probíhajícím čase přizpůsobuje skutečnosti (velmi podobně jako u neuronových sítí).



(obr. 1. – prognóza)

Ve vodním hospodářství jsou nejčastěji používány tyto prognostické metody:

- Metoda interpolace a extrapolace,
- metoda založená na teorii pravděpodobnosti a matematické statistice,
- metoda analogie,
- metoda modelování a
- metody založené na expertizách.

4. NEURONOVÉ SÍTĚ – PŘEDSTAVENÍ

Prudký rozvoj výpočetní techniky až po současný stav umožnil snadnou aplikaci numerických metod pro matematické modelování. Tyto matematické modely jsou navrhovány nejenom pro vlastní návrh systému, ale v neposlední řadě i pro jeho posouzení a simulaci určitých zvláštních situací a podmínek.

S rozmachem výpočetní techniky je možnost modelovat i složitější matematické problémy. S tím ovšem roste složitost systému, dochází k zahrnování dalších veličin do výpočtu pro dosažení co možná největší shody mezi modelem a realitou. V důsledku toho objem zpracovávaných dat stoupá nad únosnou míru. Dalším problémem může být, **nedefinovatelnost různých matematických problémů klasickými numerickými metodami**, nehledě na jejich leckdy podivnou shodu s reálným stavem.

Metody umělé inteligence proto představují jedno z možných řešení. Mezi nejvíce se vyvíjející odvětví umělé inteligence patří expertní systémy, genetické algoritmy a neuronové sítě. Umělá inteligence má za cíl přesunout lidské schopnosti vnímání reálného světa z lidského vědomí na vnější medium a zpracování informací svěřit procesoru počítače. Většina metod umělé inteligence vychází z principů chování přírody a snaží se toto chování zalgoritmizovat. Krásně se to dá předvést na genetických algoritmech.

Genetické algoritmy jsou inspirovány přirozeným chováním přírody, v níž probíhá evoluční vývoj. Algoritmy jsou založeny na práci s velkým množstvím jedinců, tzv. populacích. Nové generace se neustále vytvářejí křížením a to nejzdravějších a nejsilnějších jedinců, čemuž říkáme výběrové hledisko. Podle tohoto hlediska dochází neustále k určitému zkvalitňování populace. Tento princip je vhodný pro řešení některých optimalizačních úloh v technické praxi.

Problematika umělých neuronových informačních systémů, které jsou schopny napodobovat funkce nervových soustav mozku živých organismů dokonalejším způsobem, než to v současné době může činit dosavadní, tzv. konvenční výpočetní technika, láká pozornost mnoha vědců i laiků již mnoho let. Historie neuroinformatiky je poměrně dlouhá a obor se neustále průběžně vyvíjí. Nebudeme-li za prazáčátek neuroinformatiky považovat rozvoj fyziologie a v níž se do historie oboru zapsal i náš J. E. Purkyně (1787–1869, univerzitní profesor medicíny; v roce 1839 vyslovil teorii o buněčné stavbě živých těl), lze říci, že počátek sahá do ranných let 20. století. V té době publikoval Američan W. S. McCulloch své první práce o modelech neuronů. V dalších letech ho pak následovali W. Pitts (jeho student), B. Widrow a další, kteří vytvořili první umělé sítě, které již byly schopny řešit praktické úlohy.

Umělé neuronové sítě představují velice zjednodušenou schematizaci biologického nervového systému. Mezi umělými neuronovými sítěmi a konvenčními počítači existuje **zásadní** rozdíl ve způsobu práce. Konvenční počítačové systémy pracují podle **předem daného postupu – matematického algoritmu**. Podle kterého se zpracovávají jednotlivé dílčí informace. Naproti tomu neuronové systémy uskutečňují velký počet dílčích operací současně a pracují **bez algoritmu**. Jejich činnost je založena na procesu učení, při kterém se neuronová síť postupně co nejlépe adaptuje k řešení dané úlohy.

4.1. Výhoda neuronových sítí oproti klasickým metodám

Oproti ostatním metodám jsou schopny realizovat složité nelineární funkce, dokonce libovolné. Při fázi učení se nemusíme zabývat problémem výběru správné funkce nebo výběrem expertů, protože sítě stačí pouze trénovací příklady. Toto je hlavní rozdíl mezi klasickým přístupem například přes nelineární modely a sítě back-propagation. Samozřejmě za tyto výhody musíme zaplatit. Neuronové sítě mohou uvíznout v lokálním extrému nebo konvergují při učení velmi pomalu. Nevíme tedy jak dlouho budeme muset síť učit, než se dostaneme pod maximální přípustnou chybu.


4.2. Algoritmus Back-Propagation

Tento typ algoritmu umělé neuronové sítě je nejvhodnější pro predikci, proto si ho popíšeme podrobněji.

Tato síť je vícevrstevná, kde učení probíhá zpětným šířením chyby.

4.2.1 ARCHITEKTURA SÍTĚ

Typické uspořádání sítě je vidět na obrázku níže (obr. 2.). Na obrázku je jasně vidět, že tato umělá neuronová síť se skládá z několika vrstev obsahující jednotlivé neurony. Vstupní vrstva (nejvíce vlevo) pouze rozvětjuje signál přicházející ze vstupu na všechny neurony 1. skryté vrstvy. Propojení mezi vstupní a 1. skrytou vrstvou je úplné, tedy je propojen každý neuron s každým.



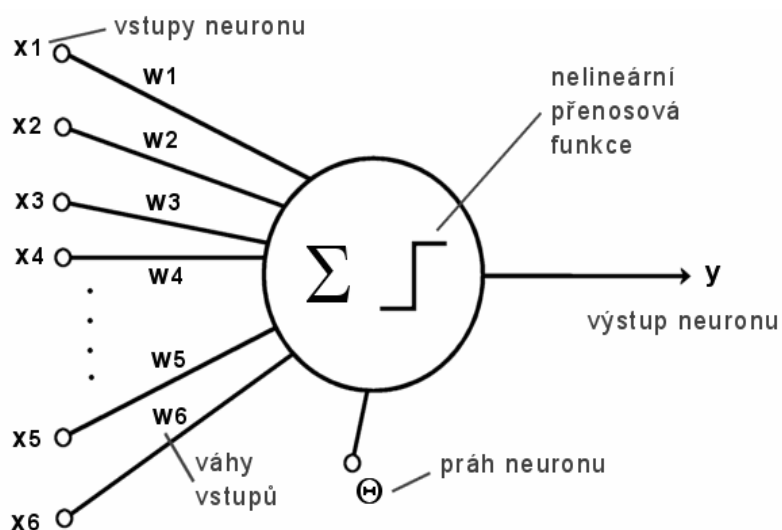
(obr. 2. – schéma NN sítě a jednotlivých vazeb)

4.2.2 VÝKONNÝ PRVEK UMĚLÉ NEURONOVÉ SÍTĚ

Výkonným prvkem umělé neuronové sítě, jak už jsem uvedl v předchozí kapitole, je neuron. Tento neuron zpracovává vstupní údaje podle vztahu:

$$y = S\left(\sum_{i=1}^N w_i \cdot x_i + \Theta\right)$$

[rov. 1.], kde



- y je výstup (aktivita neuronu),
- x_i je i -tý vstup neuronu, vstupů je celkem N ,
- w_i představuje hodnotu i -té synaptické váhy
- S je lineární přenosová funkce neuronu a
- Θ představuje prahovou hodnotu

(obr. 3. – výkonný prvek umělé neuronové sítě)

4.2.3 UČENÍ SÍTĚ BACK-PROPAGATION

Postup učení této sítě je podobný učení žáka ve škole. Žák se danou látku učí tak dlouho, dokud ji neumí a dokáže ji interpretovat s jistou přesností. Podobně to funguje i v tomto algoritmu.

Žákem je sama neuronová síť, probírané látce odpovídá trénovací množina. Zkoušením zjišťujeme, zda síť na dané vzory odpovídá správnými výstupy. Pokud ne, měníme váhové koeficienty tak dlouho, dokud nezačne reagovat správně. Algoritmus učení lze programovací „řečí“ popsat následovně:

```
náhodná_inicializace_vah
repeat
  repeat
    vyber_vzor_z_trénovací_množiny
    přilož_vybraný_vzor_na_vstupy_sítě
    vypočti_výstupy_sítě
    porovnej_výstupy_s_požadovanými_hodnotami
    modifikuj_váhy
  until vybrány_všechny_vzory_trénovací_množiny
until globální_chyba < kritérium
```

Výběr vzorů z trénovací množiny nemusí být jen sekvenční, někdy může být využito například náhodného výběru. Volba strategie není pevně dána a spíše závisí na „umění učit“ neuronové sítě a na vhodně zvolených parametrech této sítě. V průběhu učení můžeme určité vzory předkládat častěji k učení, jiné zase méně často atp.

Globální chybou je v algoritmu míněna například střední kvadratická chyba (MSE – *Mean Squared Error*).

$$MSE = \frac{\sum_{t=1}^n (y_t - \hat{y}_t)^2}{n}, \text{ kde} \quad [\text{rov. 2.}]$$


n je počet neuronů výstupní vrstvy.

Trénování sítě ukončuje splnění předem dané podmínky. Touto podmínkou může být dosažení předepsaného počtu trénovacích etap (kroků) nebo pokles globální chyby pod předem stanovenou mez. První podmínka správné natrénování sítě zaručuje stěží! Touto podmínkou můžeme pouze omezit trénovací čas na únosnou míru. Druhá podmínka nám může kvalitu učení ovlivnit již smysluplně. Máme-li však na globální chybu přemrštěné požadavky, přesáhne trénovací čas únosnou míru. Nejlepším ukazatelem je sledovat časový průběh globální chyby sítě po jednotlivých etapách (krocích).

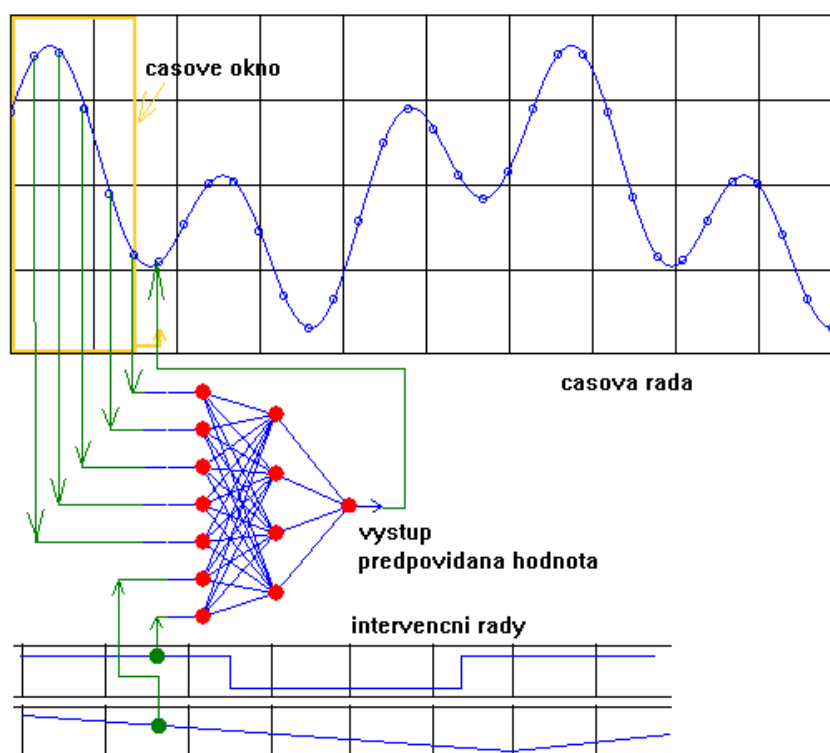
Vysvětlení vlastního učení a pojmů trénovací a testovací množina na příkladu:

Máme údaje o časově závislé proměnné x_t ($t=1, 2, \dots$) a chceme předpovědět hodnotu proměnné v čase $t+h$.

Predikce časové řady pomocí neuronové sítě spočívá v naučení sítě na průběh veličiny v nějakém omezeném čase a následném použití do budoucnosti. Sítí předkládáme na vstup data z minulosti a jako výstup očekáváme data z budoucnosti (obr. 4.). Jedná se tedy o učení s učitelem. Pro přesnější predikci je vhodné dodat další informace, například ve formě intervenčních proměnných (obr. 5.). Neplatí však, že více údajů zaručuje lepší predikci, někdy je tomu právě naopak. Vždy je potřeba vybrat relevantní údaje, pokud jsou k dispozici.



(obr. 4. – učení časové řady bez intervenčních proměnných)

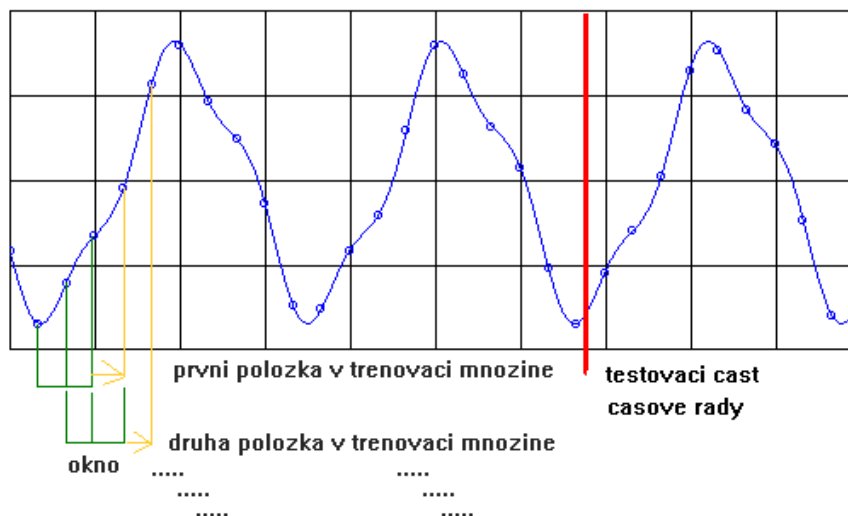


(obr. 5. – učení časové řady s intervenčními proměnnými)

Trénovací množinu vytvoříme přímo z časové řady jednoduše tak, že jako vstupy vezmeme určitý počet naměřených hodnot a jako požadovaný výstup vezmeme hodnotu (případně hodnoty) v určité vzdálenosti od vstupních hodnot. Vstupní část časové řady se nazývá okno, výstupní část je predikovaná hodnota. Posunem tohoto okna po časové řadě vytváříme položky trénovací množiny (obr. 6.). Je vhodné ponechat část naměřené

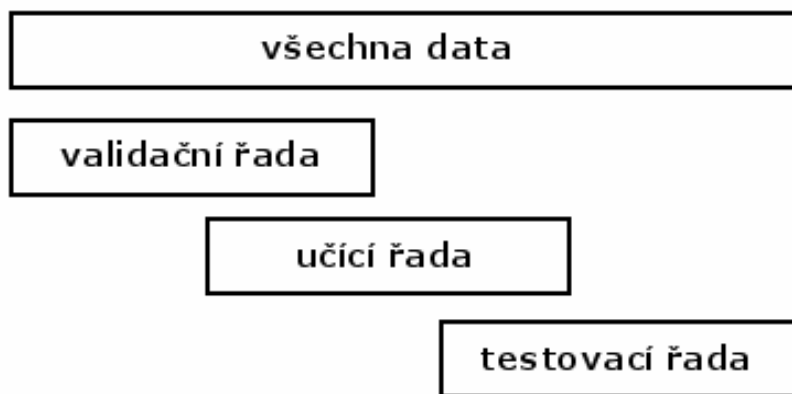
řady pro testování, tzn. nepředkládat tuto část časové řady při učení, ale použít jí pro testování naučenosti sítě.

Takto získanou trénovací množinu je ještě třeba upravit dle konkrétní použité sítě, například přepočítat získané hodnoty do určitého intervalu.



(obr. 6. – vytváření trénovací množiny)

Data, která máme k dispozici, se často rozdělují na učící řadu, validační řadu a testovací řadu. Tyto tři řady se mohou vzájemně částečně překrývat (obr. 7.) a nemusí být souvislé. Učící řada je posloupnost, kterou předkládáme síti, a dle které síť upravujeme. Odchylku v odpovědích na validační řadu používáme jako kritérium pro ukončení učení sítě. Testovací řadu pak použijeme na test naučenosti sítě pro hodnoty v budoucnosti, které síť během učení "neviděla". Učící řada tedy slouží na hledání modelu, validační řada na ověřování modelu a testovací řada na test použitelnosti modelu.



(obr. 7. – příklad rozvržení validační, učící a testovací řady)

Důležité je též předzpracování dat. Je například vhodné z časové řady odstranit trend, náhodné chyby měření a jiné složky (např. sezónní), pokud jsme ovšem tyto složky schopni identifikovat.

Zvláště pro neuronové sítě (které mají výstupy v určitém intervalu) platí, že nelze úspěšně předpovídat hodnoty mimo předem daný interval.

4.2.4 MATEMATICKÝ POPIS ALGORITMU BACK-PROPAGATION

- Krok 1. Inicializace

Všechny váhy v síti se nastaví v náhodně malém rozsahu, například $\langle -0,3;0,3 \rangle$.

- Krok 2. Předložení vzoru

Vybereme vzor z trénovací množiny a přiložíme na vstupy sítě. Dále po vrstvách směrem od vstupu k výstupům sítě počítáme výstupy jednotlivých neuronů podle vztahů:

$$y = S\left(\sum_{i=1}^n w_i x_i + \Theta\right) \text{ a } S(\varphi) = \frac{1}{1 + e^{-\varphi}}. \quad [\text{rov. 3. a 4.}]$$

- Krok 3. Srovnání

V kroku srovnání nejprve vypočítáme energii podle vztahu $E = \frac{1}{2} \sum_{i=1}^n (y_i - d_i)^2$, která bude využita jako přírůstek k celkové energii počítané přes všechny testovací vzory. Dále spočítáme chybu pro výstupní vrstvu:

$$\delta_i^o = (d_i - y_i^o) \gamma \cdot y_i^o (1 - y_i^o). \quad [\text{rov. 5.}]$$

- Krok 4. Zpětné šíření chyby a modifikace vah

Pro všechny neurony ve vrstvě vypočteme:

$$\Delta w_{ij}^l(t) = \eta \delta_i^l(t) y_j^{l-1}(t) + \alpha \Delta w_{ij}^l(t-1), \quad [\text{rov. 6.}]$$

$$\Delta \Theta_i^l(t) = \eta \delta_i^l(t) + \alpha \Delta \Theta_i^l(t-1). \quad [\text{rov. 7.}]$$

Podle vztahu $\delta_i^{h-1} = y_i^{h-1} (1 - y_i^{h-1}) \sum_{k=1}^n w_{ki}^h \delta_k^h$ zpětně šíříme chybu do vrstvy, která je blíže vstupům. Na závěr kroku 4 modifikujeme váhy:

$$w_{ij}^l(t+1) = w_{ij}^l(t) + \Delta w_{ij}^l(t), \quad [\text{rov. 8.}]$$

$$\Theta_i^l(t+1) = \Theta_i^l(t) + \Delta \Theta_i^l(t)$$

Krok 4 opakujeme pro všechny vrstvy sítě tak, že začínáme vrstvou výstupní ($l=0$), pak následují skryté vrstvy ($l=h$). V případě, že zpracováváme skrytou vrstvu, která je nejbližší vstupní vrstvě, nahradíme y_j^{l-1} v rovnici pro výpočet Δw za odpovídající vstupní hodnotu, tedy za x_j .

- Krok 5. Ukončení výběru vzorů z trénovací množiny

Jestliže byly síti předloženy všechny vzory z trénovací množiny, pokračujeme krokem 6, jinak se vracíme na krok 2.

Pozn.: Při sekvenčním výběru je realizace tohoto testu jednoduchá. Vybíráme-li však vzory náhodně, musíme v průběhu učení zaznamenávat, které vzory byly použity, a které nikoliv.

- Krok 6. Ukončení učení

Jestliže byla chyba neuronové sítě za poslední epochu menší, než námi stanovené kritérium nebo byl vyčerpán maximální počet epoch, pak učení ukončíme. Jinak se pokračuje krokem 2.

5. MODELOVACÍ PROSTŘEDKY

Pro výpočty této disertační práce byl použit program MATLAB s rozšířením o Neural Network Toolbox, který umožňuje práci s neuronovými sítěmi. Důvodů k tomuto kroku bylo několik. Jde o komerční produkt, takže jeho vývoj není ovlivněn momentální situací členů volně dostupných projektů. Jde o jeden z nejvíce podporovaných produktů na trhu a posledním, ovšem ne co do důležitosti, argumentem pro jeho použití je skutečnost, že ČVUT je držitelem multilicenční smlouvy na tento produkt.

Podrobný popis tohoto i dalších softwarových prostředků pro práci s neuronovými sítěmi lze najít ve vlastní disertační práci.

6. CHARAKTERISTIKA ČASOVÝCH ŘAD

K popisu jednotlivých časových řad potřeby vody získaných od Pražských vodovodů a kanalizací a.s. použijeme některé z metod popisné statistiky. Ta zkoumá vlastnosti, které se projevují na určitém rozsáhlém souboru případů a snaží se je pomocí popisných metod charakterizovat. K popisu jednotlivých řad potřeby vody jsem použil metody vyjmenované níže.

6.1. Rozptyl

Popisuje velikost kolísání náhodné veličiny kolem střední hodnoty v určitém souboru, vypočtený z hodnot pro všechny jednotky tohoto souboru. Vypočte se jako průměr druhých mocnin všech rozdílů výsledků jednotlivců od průměru.

$$\sigma^2 = \frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n}, \quad [\text{rov. 9.}]$$

kde x_i jsou výsledky jednotlivců, \bar{x} je průměr a n je počet testovaných.

6.2. Výběrový rozptyl (Var)

Popisuje velikost kolísání náhodné veličiny kolem střední hodnoty na základě zadaných výběrových hodnot.

$$s^2 = \frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n - 1} \quad [\text{rov. 10.}]$$

6.3. Směrodatná odchylka (STD)

Vypočte se jako druhá odmocnina rozptylu $s = \sqrt{s^2}$. [rov. 11.]

¹ V odborné literatuře se objevují dvě definice pro výpočet směrodatné odchylky:

$\sigma = \left(\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2 \right)^{1/2}$ nebo $s = \left(\frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2 \right)^{1/2}$, vychází se tedy buď z rozptylu, nebo výběrového rozptylu. Častější variantou je varianta vycházející z výběrového rozptylu (vzorec 10), kterou budu také používat.

Pokud od průměru odečteme, resp. k němu přičteme dvojnásobek směrodatné odchylky ($\bar{x} \pm 2.s$), dostaneme hranice, mezi nimiž se nacházejí téměř všechny výsledky (mimo ně je pouze přibližně 5 %).

6.4. Empirické momenty

Kromě variability lze číselně vyjádřit i další charakteristiky postihující tvar rozdělení dat. Dříve než si dvě takové charakteristiky uvedeme, seznámíme se s tzv. empirickými momenty. Tzv. k-tý obecný moment M'_k je definován jako průměr k-tých mocnin.

$$M'_k = \frac{1}{n} \sum_{i=1}^n x_i^k \quad [\text{rov. 12.}]$$

Dále se užívají centrální momenty M_k , které vycházejí ze součtu mocnin odchylek od průměru:

$$M_k = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^k \quad [\text{rov. 13.}]$$

Z momentů jsou odvozeny další charakteristiky, šikmost (angl. skewness) a špičatost (angl. kurtosis).

6.5. Šikmost

$$g_1 = \frac{M_3}{(M_2)^{3/2}} \quad [\text{rov. 14.}]$$

Nulová šikmost znamená, že rozdělení dat je symetrické okolo průměru, kladná šikmost znamená, že rozdělení četností je zešikmeno vlevo, záporná šikmost znamená zešikmení vpravo.

6.6. Špičatost (ang. Kurtosis)

$$g_2 = \frac{M_4}{(M_2)^2} - 3 \quad [\text{rov. 15.}]$$

Důvod proč na pravé straně odečítáme hodnotu 3 je, že špičatost vztahujeme k nejčastěji vyskytujícímu se rozdělení, k tzv. normálnímu rozdělení, u kterého je poměr $\frac{M_4}{(M_2)^2}$ roven 3. Špičatost je tedy vztažena ke špičatosti normálního rozdělení, kladná špičatost znamená špičatější rozdělení než normální, záporná špičatost znamená, že rozdělení pozorovaných hodnot je "placatější" než normální.

6.7. Autokorelace

Nezávislost prvků se nejčastěji testuje autokorelačními koeficienty. Nejvíce se používá autokorelační koeficient 1. řádu r_1 , který lze chápat jako „korelaci“ 1. hodnoty se 2., 2. se 3., 3. se 4. atd. Autokorelační koeficient k-tého řádu r_k je definován jako:

$$r_k = \frac{\sum_{i=1}^{n-k} (x_i - \bar{x})(x_{i+k} - \bar{x})}{\sum_{i=1}^n (x_i - \bar{x})^2}$$

[rov. 16.]

Díky autokorelační funkci lze odhalit periodicitu signálu. Autokorelační funkce u periodického signálu o periodě N bude mít maxima pro $k = N$.

6.8. Histogram

Histogram reprezentuje četnost zastoupení na určitém intervalu.

6.9. Hustota

Hustota pravděpodobnosti nám umožňuje pro každý, uměle zvolený interval říci, s jakou pravděpodobností se bude náhodně pozorovaný stav veličiny v tomto intervalu nalézat. Tuto pravděpodobnost spočteme jako plochu nad zvoleným intervalem, která je shora omezena křivkou grafu.


Přičemž směrodatná odchylka náhodné veličiny, určuje tvar hustoty normálního rozdělení. Čím je směrodatná odchylka větší, tím je hustota plošší, čím je menší, tím je křivka strmější.

6.10. Ověření normality


Metody klasické statistické analýzy dat jsou založeny na předpokladu normality. Chceme-li je použít, musíme se přesvědčit, zda pozorování x_1, x_2, \dots, x_n představují realizaci náhodného výběru pocházejícího z normálního rozdělení. To je možné učinit buď pomocí vhodného grafu dat, nebo aplikací testu normality.

Běžně dostupný statistický software zpravidla nabízí dvě možnosti grafického posouzení normality. První z nich je histogram. Pro normalitu dat svědčí histogram odpovídající svým tvarem Gaussově křivce hustoty normálního rozdělení. Měl by tedy být jednovrcholový a přibližně symetrický.

Druhým grafem pro posouzení normality dat je normální diagram (normal probability plot). Je to graf obsahující body o souřadnicích $\Phi^{-1}(i/(n+1)), x_{(i)}$. Data pocházející z normálního rozdělení mají na normálním diagramu body soustředěné kolem přímky.



(obr. 8. – histogram a normální diagram svědčící pro normalitu dat)

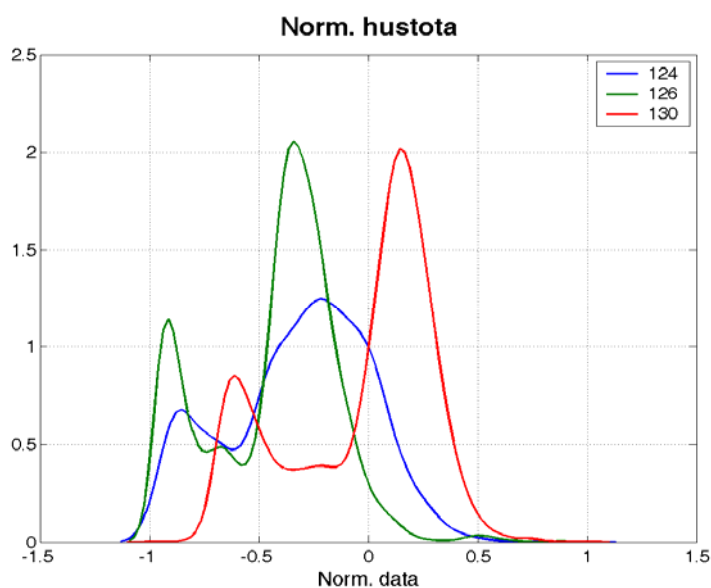


(obr. 9. – histogram a normální diagram svědčící proti normalitě dat)

Histogram nebo normální diagram nemusí poskytnout jasnou odpověď na otázku normality dat. V takovém případě můžeme použít některý z testů normality, zmiňme např. test Kolmogorovův-Smirnovův, či testy založené na šikmosti (skewness) a špičatosti (kurtosis).

7. VÝSLEDKY

- i. Podrobně jsem teoreticky popsal problematiku neuronových sítí s detailním popisem algoritmu back-propagation, který byl zvolen jako nejvhodnější pro predikci potřeby vody.
- ii. V kapitolách zabývajících se jednotlivými výsledky jsem vybral popisné statistické metody, které mohou snadno charakterizovat jednotlivé časové řady potřeby vody (v tezi kapitola 6.). Pomocí těchto popisných statistických analýz jsem dospěl k závěru, že u hodinových potřeb vody nelze počítat s normálním rozdělením. Ukazuje to jak šikmost, histogram, tak jednotlivé normální diagramy, kde body nejsou soustředěny kolem přímky. Zejména v počáteční a konečné fázi. Pro práci s těmito daty tedy nelze použít metody klasické statistické analýzy.




(obr. 10. – zobrazení rozložení hustoty jednotlivých řad – všimněte si dvou vrcholů)

- iii. Vytvořil jsem seznam dostupných simulátorů neuronových sítí spolu se stručným popisem jejich vlastností (v tezi kapitola 5.). Z čehož jsem detailně popsal vlastnosti programu Matlab, který byl vybrán k modelování NN sítí.
- iv. Z důvodů možnosti porovnání jednotlivých časových řad, a také pro ověření toho, zda se NN síť lépe učí na reálných datech či na normalizovaných byl odvozen v další části algoritmus převádějící veškeré vstupní hodnoty do intervalu <-1;1>.


$$x_n = 2 \cdot \frac{x - \min x}{\max x - \min x} - 1 \quad [\text{rov. 17.}]$$

Jsou-li data převedena pomocí tohoto algoritmu zůstanou zachovány jejich vlastnosti, ale maximální hodnota dané řady bude nabývat hodnoty +1 a naopak minimem řady bude hodnota -1. Pokud jsou takto upraveny všechny řady potřeby vody, lze je daleko lépe porovnávat a vyslovovat případné hypotézy, než v případě práce s reálnými daty. Navíc se při učení NN sítě potvrdilo, že normalizovaná data jsou daleko vhodnější pro učení NN sítí, než když použijeme reálné hodnoty. U reálných hodnot stupeň naučenosti NN sítě klesá postupně s rostoucí velikostí trénovací skupiny dat. Tento průběh není lineární a vyskytují se u něj dosti značné výchyly. Naopak kvalita naučenosti na normalizovaných datech si zachovává lineární charakter.



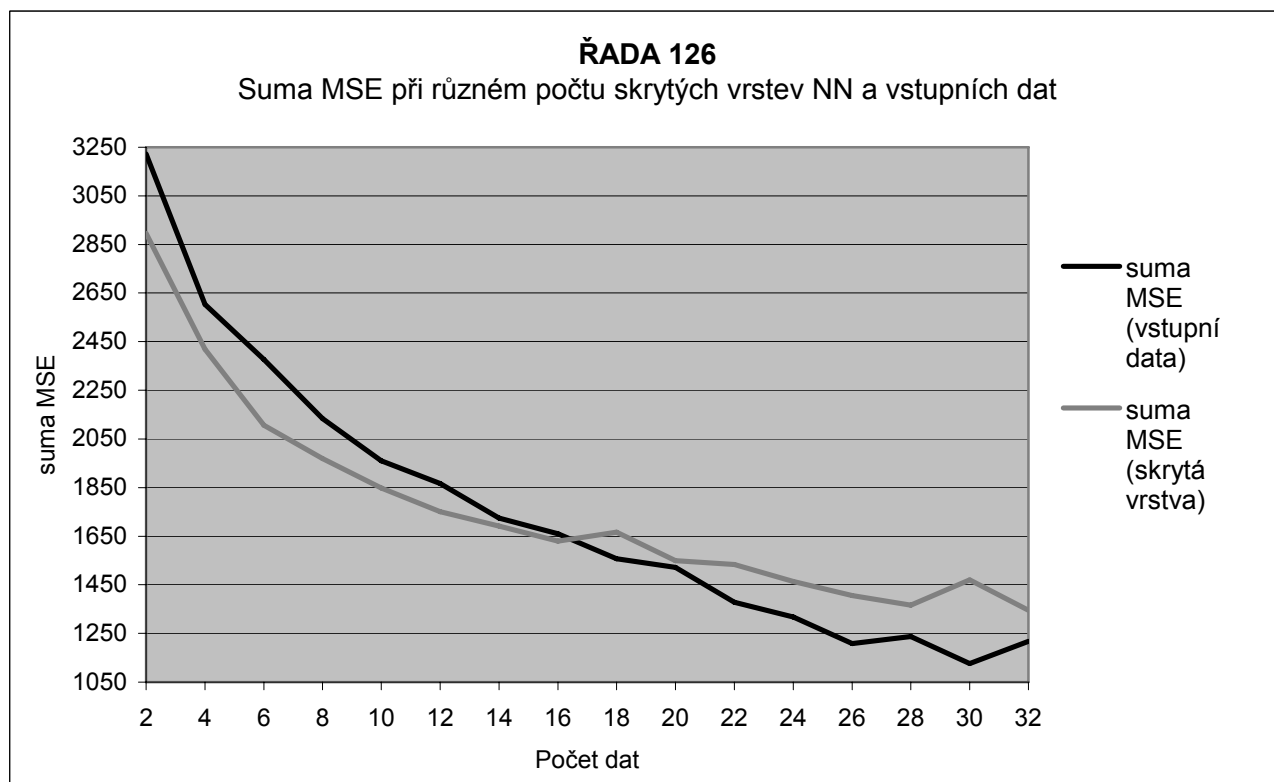
(obr. 11. – porovnání naučenosti NN sítě na reálných a normalizovaných datech)

Dalším výsledkem, ke kterému jsem při své disertační práci dospěl je fakt, že využití uvedených intervenčních proměnných není pro učení NN sítě v tomto případě výhodné. Z výpočtů jasně vyplývá, že pokud do výpočtu vstupuje méně hodnot, tak jsou výsledky s použitím intervenčních proměnných kvalitnější. Ovšem okolo 12 vstupů dosáhne učení NN sítě s pomocí intervenčních proměnných svého vrcholu a od té doby víceméně stagnuje. Naproti tomu učení NN sítě, které jsou poskytovány vstupy tvořené pouze daty časové řady, se neustále zkvalitňuje.



(obr. 12. – vliv standardních vstupů a vstupů s intervenčními proměnnými na kvalitu učení NN sítě)


Při posuzování skutečnosti jaký vliv má na kvalitu učení počet současně vstupujících hodnot do výpočtu a počet neuronů skryté vrstvy NN sítě jsem zjistil, že učení stoupá zpočátku strmě a s postupem času se zpomaluje. Z výsledků také vyplynulo, že větší vliv na kvalitu učení má množství dat vstupujících do výpočtu, než-li počet neuronů skryté vrstvy.



(obr. 13. – porovnání vlivu množství vstupních dat a počtu neuronů skryté vrstvy na kvalitu učení NN sítě)

Dalším krokem při posuzování vlivu počtu vstupních parametrů bylo posouzení toho, jaký vliv na kvalitu učení má velikost trénovací množiny. V tomto případě se splnil logický předpoklad. Se zvětšujícím se množstvím dat trénovací skupiny bude současně s tím klesat i chyba na celé časové řadě. Pro predikci časové řady potřeby vody je tedy vhodné použít co nejdelší časovou řadu předchozích hodnot. Protože na co delší časový úsek bude NN síť naučena, tím lépe dokáže predikovat na nenaučených datech. Tento poznatek vyplývá ze skutečnosti, že s velikostí trénovací množiny klesá zároveň i chyba (MSE) na nenaučených datech. Zároveň se ukazuje, že kvalitnějších výsledků lze dosáhnout na časových řadách s menším rozptylem.

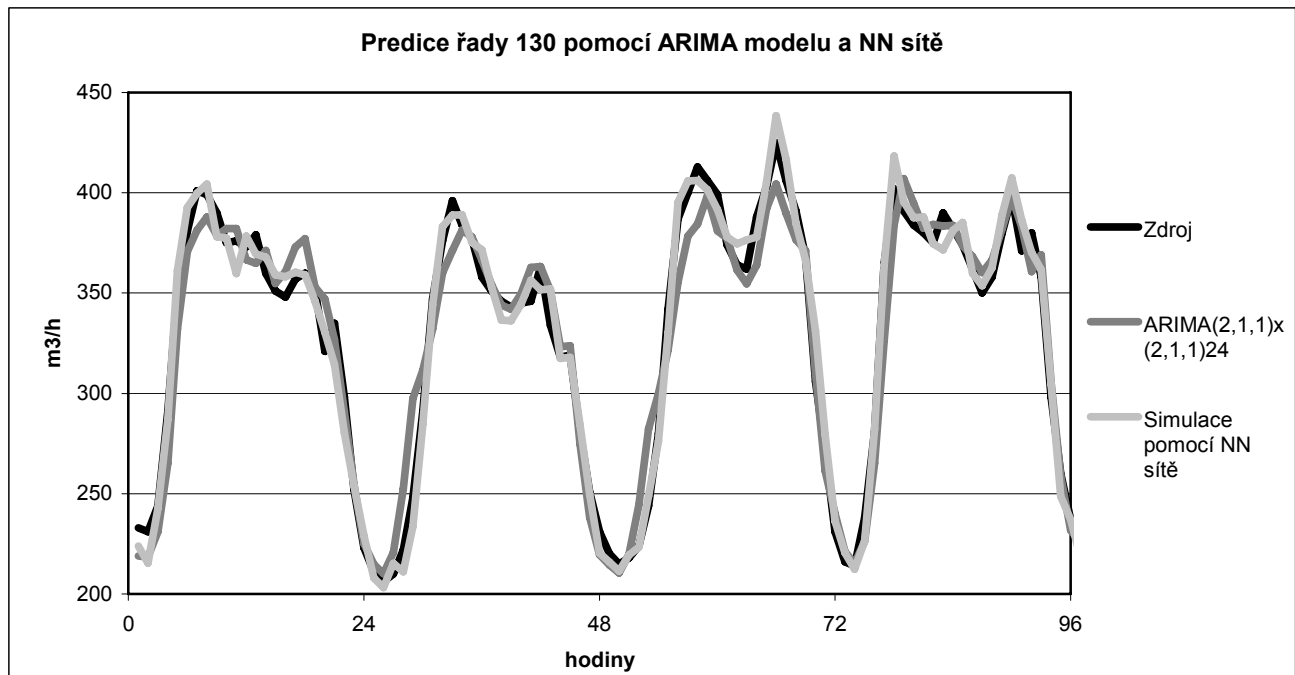
- v. Při dalším ověřování jsem se zabýval možností transformace již naučené NN sítě na zcela jinou síť. Chtěl jsem ověřit, zda lze již naučenou NN síť použít k výpočtům na zcela jiné časové řadě, než na které se učila a s jakou kvalitou výsledků lze počítat. Spolu s tím jsem hledal matematický vztah, který by dokázal předem odhadnout, jak bude tato transformace kvalitní. Odhad kvality transformace se prováděl na normalizovaných datech. Následně byl vždy proveden podíl mezi naučenou řadou a řadou, kterou pomocí naučené řady chceme predikovat. Na těchto podílech (vyjma hodnot min a max) byl spočten výběrový rozptyl. Předpoklad je takový, že čím bude hodnota výběrového rozptylu menší, tím si jsou řady více podobné a lze na ně použít transformaci. Jako důkaz pro potvrzení tohoto předpokladu posloužila celková suma MSE na všech provedených výpočtech (viz tabulka 13 až 15 vlastní disertační práce). Domněnka se potvrdila a u řad navržených pro transformaci dle zvolené metody byla celková suma MSE po 256 výpočtech nejmenší. Dalším důležitým krokem bylo zjistit, zda u predikce časové řady pomocí již jiné naučené řady máme používat nejlépe naučenou NN síť. Tedy ty s nejmenšími MSE, nebo zda se k tomuto účelu hodí spíše méně naučené sítě, které jsou obecnější. Z výsledků provedených analýz vyplynulo, že naučenou neuronovou síť lze úspěšně transformovat na jinou časovou řadu s kvalitními výsledky. Musí být ovšem dodrženy určité podmínky. Poměrná výběrová variabilita mezi sítěmi musí být co nejnižší a pro transformaci je důležité, narozdíl od vlastního učení, použít zcela jinou strukturu NN sítě. Nejvíce se pro transformaci osvědčily 2 neurony ve skryté vrstvě a 26 hodnot vstupujících do výpočtu. Tím byla prokázána možná jedna z nejdůležitějších vlastností neuronových sítí, a to že podle určitých pravidel popsanych výše lze předpovědět časovou řadu potřeby řady pomocí jiné než vlastní naučené NN sítě. Tato vlastnost by se mohla uplatnit zejména při zjišťování dalších hodnot ve vodovodní síti jako je doba zdržení či hodnoty zbytkového chlóru a všech podobných veličin, které se jen těžko zjišťují přímou matematickou cestou.
- vi. Dalším krokem bylo ověřit, s jakou přesností mohou NN sítě predikovat potřebu vody z krátkodobého hlediska. Tedy s jakým úspěchem jsou NN sítě schopny předpovědět na základě daných skutečností hodnotu v čase $t+1$. Z výsledků vyplývá, že NN sítě jsou z krátkodobého hlediska téměř 100% přesné. MSE se pohybuje v rozmezí 30 až 100 a při volbě časově ještě náročnější struktury NN sítě bychom mohli dosáhnout ještě lepších hodnot. Zde ovšem vyvstává otázka, zda je to z hlediska potřebného výpočetního výkonu a času vhodné řešení. Nejlepších výsledků bylo dosaženo, pokud do výpočtu vstupovalo 26 vstupů a ve skryté vrstvě bylo 32 neuronů. To při jednom výstupu představuje 864 vah. Z tohoto důvodu je dobré, aby trénovací skupina obsahovala minimálně 1 000 prvků, jinak by docházelo ke ztrátě robustnosti a obecnosti NN sítě! Stejně pravidlo platí i při změně struktury sítě, nikdy by neměla NN síť mít více vah, než-li je počet hodnot k učení NN sítě.



(obr. 14. – naučenost NN sítě při 26 vstupech a 32 neuronech skryté vrstvy na řadě 124, zobrazení na výřezu 1009:1345)

Jak už jsem uvedl, v případě krátkodobé predikce se předpovídá pouze pro jeden časový krok do budoucna. Neuronové síti je předložena známá hodnota časové řady (t) a na základě této (a znalosti z časového okna) se předpovídá budoucí hodnota časové řady ($t+1$). Pro predikci následující hodnoty časové řady ($t+2$) se ale použije hodnota známá, tedy hodnota ze skutečné časové řady ($t+1$). Naproti tomu dlouhodobá predikce vychází ze známých hodnot pouze na počátku a pro predikci hodnoty časové řady ($t+1$) se využívá předchozí predikovaná hodnota časové řady (t). V tomto případě jsem zkusil predikovat 336 hodin dopředu, což odpovídá 14 dnům, a výsledek jsem posléze porovnal se skutečným stavem. Jednoznačně se potvrdilo, že v případě dlouhodobé predikce poskytuje nejlepší výsledky kombinace 23 vstupních hodnot a 23 neuronů skryté vrstvy. Dalším zajímavým zjištěním je skutečnost, že daleko lepších výsledků lze dosáhnout, pokud výsledky jednotlivých simulací zprůměrujeme a tuto průměrnou hodnotu ve výsledku prezentujeme jako dlouhodobou predikci. Také v tomto ohledu se podařilo dokázat vhodnost použití NN sítí i na dlouhodobou predikci potřeby vody, v tomto případě můžeme počítat s celkovým MSE okolo 500.

- vii. Výše jsou uvedené veškeré zjištěné poznatky získané z práce s neuronovými sítěmi. Podrobnosti lze najít v jednotlivých kapitolách disertační práce, kde se vždy každá kapitola věnuje uvedeným problémům podrobně. V případě potřeby lze dokonce dohledat veškeré výsledky v detailní podobě na přiloženém CD-ROMu k disertační práci.
- viii. V porovnání s klasickými metodami analýzy časových řad jasně vyplývá, že v případě krátkodobé predikce produkují NN síťi několikanásobně kvalitnější výstupy než-li v případě modelů ARIMA.



(obr. 15. – porovnání kvality výstupu ARIMA modelu a NN sítě, výřez 27:123)

Ačkoliv to z obrázku není na první pohled vidět, ARIMA model dosáhl nejlepší hodnoty MSE 269, kdežto NN síť pouhých 84!

Také u dlouhodobé předpovědi potřeby vody jsou výstupy NN sítí (až na výjimku u řady 124) mnohonásobně kvalitnější.

Kupodivu jsou některé výsledky NN sítí, které jsem získal transformací naučené NN sítě na jinou řadu, stále kvalitnější než-li předpověď pomocí modelů ARIMA. Jednoznačně se tak potvrdilo, že **NN síť patří mezi nejperspektivnější metody pro předpověď potřeby vody.**

8. ZÁVĚR

- ix. V rámci disertační práce jsem provedl více jak 2 500 dílčích simulací predikce potřeby vody pomocí NN sítí, které jsem všechny zaznamenal a posléze analyzoval. Pokud by jedna simulace trvala v průměru 20 minut (viz poznámka pod čarou číslo 5 disertační práce), pak by jen vlastní simulace bez přípravy materiálů a vyhodnocení zabraly přibližně 50 000 minut.

Mimo to při použití NN sítí nehrozí jako u klasických statistických metod problémy s délkou časové řady. U velice dlouhých řad existuje nebezpečí, že se v průběhu času podstatně mění charakteristika modelu, takže vybudování tohoto modelu klasickými metodami se stává s rostoucí délkou řady stále obtížnější. S tímto problémem se u NN sítí neseťkáme při vhodně nastavené struktuře NN sítě, je naopak vhodné NN síť učit pokud možno na co nejdelší řadě.

Neuronové sítě se ukázaly jako velmi perspektivní nástroj pro předpověď potřeby vody. Proto by bylo vhodné s výzkumem jejich možného uplatnění v rámci vodního hospodářství dále pokračovat. Velmi perspektivní je vidím například v oblasti potlačení šumu. Fakt, že neuronová síť dokáže rekonstruovat poškozené vzory, není nic jiného než potlačování šumu. Pro potlačování šumu se používají různé filtry, které mohou být úspěšně nahrazeny neuronovou sítí. Pokud je neuronová síť dobře

naučena, pak je signál ze zašuměného vzoru úspěšně vyfiltrován a šum silně potlačen.

Určitě je možné dále posoudit její vhodnost i pro další ukazatele pitné vody jako kvalita, doba zdržení či možnost optimalizace řízení procesu výroby a distribuci. Dále lze zkoumat využití genetických algoritmů pro urychlení procesu učení či jejich použitelnost na optimalizaci trubních sítí. V budoucnu s rozvojem počítačové techniky by mohla NN síť například sloužit jako základ pro expertní řídicí systémy.

Z jednodušších problémů, kromě predikce potřeby vody, které jsou NN sítě schopné řešit, může jít například o modelování zbytkového chlóru ve vodovodním řadu, případně doby zdržení.

Pokud bychom chtěli využít NN sítě nejenom k modelování, ale též jako součást řídicích systémů, pak si dokážu představit jejich uplatnění jako systému pro sledování neobvyklých stavů. Zde by byly NN sítě použity jako základ řídicího systému, který by hlásil neobvyklé stavy. Za neobvyklý stav by se považoval například takový, který by se ve dvou po sobě jdoucích hodnotách odlišoval od předpovědí získaných pomocí NN sítí. Dalším možným řídicím systémem by mohlo být sledování doby zdržení v reakci na aktuální objem vodojemu, kde by NN sítě mohly posloužit jako automatický systém pro jeho co nejefektivnější provoz. Určitě jsem nenastínil všechny možné situace, které jsou NN sítě schopné řešit. Mnoho dalších napadne jistě každého z vás.

9. LITERATURA

1. Bagchi Tapan P.: „Multiobjective Scheduling by Genetic Algorithms“, Kluwe, 1999
2. Bertsekas D.P. & Tsitsiklis J.N.: „Parallel and distributed computation: Numerical Methods“, Englewood Cliffs, NJ, Prentice Hall, 1987
3. Dorfman R., Samuelson P.A., Solow R.M.: „Linear Programming and economics analysis“, MacGraw-Hill, New York, 1958
4. Hakl F.: „Úvod do teorie neuronových sítí“, ČVUT, Praha 1998
5. Holas Z.: „Stochastická optimalizace řídicích procesů pomocí neuronových sítí“, Praha: b.t. 1980
6. Jiřina M.: „Neuronové sítě“, Univerzita Karlova, Praha 1995
7. Kohoutek J., Odstrčil M.: „Algoritmy hodnocení a optimalizace“, Edič. Stř. VUT, Brno 1989
8. Michálek J., Valtyni J.: „Modelování a optimalizace“, NTL, Praha 1984
9. Míka S.: „Matematická optimalizace“, Západočeská univerzita, Plzeň 1997
10. Novák Ivo: „Umělá inteligence a neuronové sítě“, VŠB – Ostrava, 1998
11. Patera Adolf, Voruba Ladislav: „Hospodaření s vodou“, Ediční středisko ČVUT, Praha 1991
12. Plexindr V., Kondelík P.: „Optimalizace a identifikace matematického modelu“, NTL, Praha 1986

13. Sutton Richard & Barto Andrew: „Toward a modern theory of adaptive networks: Expectation and prediction“, Psychological Review, vol. 88, p 135-170, 1981
14. Šíma J., Neruda R.: „Teoretické základy neuronových sítí“, Univerzita Karlova, Praha 1996
15. Škrášek J., Tichý Z.: „Základy aplikované matematiky 3“, NTL, Praha 1990
16. Turzík D.: „Matematika 3, Základy optimalizace“, VŠCHT, 1994
17. Vašíček J.: „Optimalizace rozvoje distribučních rozvodných soustav“, Praha: b.t. 1986
18. Virius M.: „Aplikace matematické statistiky – metoda Monte Carlo“, ČVUT, Praha 1989
19. Zelinka Ivan: „Umělá inteligence. Část 1, Neuronové sítě a genetické algoritmy“, VUTIUM, 1998
20. T. Cipra: „Analýza časových řad s aplikacemi v ekonomii“, SNTL/ALFA, 1986
21. Návod k programu Matlab
22. Návod k programu Statgraphics

10. PUBLIKACE

- Němec M.: Tvorba městského informačního systému, Autodesk News 13/1998
- Šrytr, Němec M.: Hodnocení rizik ochrany zdrojů minerálních vod, Workshop 2000
- Slavíček M., Němec M., Macek M.: Využití technologií GIS pro zlepšení správy a provozu inženýrských sítí, konference GIS ve státní správě – Seč 2000
- Němec M.: Predikce spotřeby vody pomocí neuronových sítí a testování využitelnosti genetických algoritmů pro optimalizaci vodovodních řadů, Workshop 2002
- Více než 1 000 odborných publikací s počítačovou tematikou zveřejněných na serveru Živě.cz, časopisech Computer a Connect!

11. SUMMARY

In my dissertation thesis, I have researched prediction of water requirements using neural network – both in the short-term and long-term perspective – on time series with hourly demand for water. Such a small spacing was chosen deliberately, as these lines show relatively large variance and random deviations, and thus cannot be successfully modelled using traditional mathematical methods. The individual time series of the demand for water were provided to me by the Pražské vodovody a kanalizace company which I would like to thank.

For computing of this dissertation thesis, I used the MATLAB program with the Neural Network Toolbox extension that enables for handling neural networks, were used. This choice was based on several reasons. Above all, as a commercial product, the development of MATLAB is not affected by the current situation of members of the

projects that are available freely. Moreover, it is one of the most supported projects on the market. Last, but not least, reason for selecting it is the fact that the Czech Technical University in Prague holds a multi-license agreement for MATLAB.

On the time series from Pražské vodovody a kanalizace company, it was necessary to find out and verify which of the types of neural networks is suitable for predicting, prepare the literature search and create theoretical description of this network. I had to find a suitable means of computing for the subsequent analysis, describe it and model the results. During modelling, the best practises of handling time series were verified. The option of applying these parameters of neural network also on similar time series of water demand, which would significantly accelerate the learning process, was validated. In conclusion, the results modelled were compared with the real values and the results were evaluated.

For the final comparison, the time series of the demand for water was predicted using the standard types of forecasting models, such as linear processes, Ma process of MA moving average, AR autoregressive processes or mixed processes of ARMA or ARIMA. The goal was not only to judge the quality of the results of settings in the individual NN networks, but moreover to establish a comparison with other types of forecasting models.

In all the points described, I have achieved unambiguous conclusions and I have proven that the neural networks count among the most prospective methods for predicting demand for water. In all aspects, the neural networks have proven to be a very prospective tool for water demand forecasting. Therefore, it would be advisable to continue the research of their possible applications in water economy. For example, I can see a large space for neural networks in the field of noise elimination. The ability of the neural network to reconstruct cracked patterns is exactly the basis of noise elimination. To eliminate noise, various filters are used, and those can be successfully substituted by a neural network. If the network is well taught, the signal of the noised pattern is successfully filtered and the noise is strongly suppressed.

It would be certainly useful to evaluate the suitability of neural networks for other indicators of drinkable water, such as quality, retaining time or options for optimising the management of manufacturing and distribution process. Further, the using of genetic algorithms for accelerating the learning process or for optimising the pipe networks can be argued. In the future, with more developed computing technology available, the NN network could be used as a basis for expert managing systems.