

VYUŽITÍ NEURONOVÝCH SÍTÍ PRO ZPĚTNOU ANALÝZU PŘI NÁVRHU TUNELŮ

APPLICATION OF NEURAL NETWORKS FOR BACK ANALYSIS IN TUNNEL DESIGN

Jan Pruška¹

ABSTRAKT

Na rozdíl od většiny materiálů ve stavebním inženýrství zeminy a horniny vykazují nepředvídatelné a různorodé chování způsobené procesem utváření těchto přírodních materiálů. Z tohoto důvodu geotechničtí inženýři často zjednodušují řešené úlohy a používají pro návrh analytické a empirické metody. V případě podzemních staveb však musíme popsat chování masivu i postupy výstavby a pro návrh často použít numerické metody. Projektant musí zajistit, že chování numerického modelu je co nejbližší realitě. Jedním z nástrojů, který mu v této úloze pomáhá, je zpětná analýza. Zpětná analýza využívá různé postupy pro předpověď reálného chování systému hornina - podzemní stavba a jedním z nich jsou neuronové sítě. Článek podává stručný přehled o zpětné analýze v geotechnice. V první části popisuje metody používané pro zpětnou analýzu. Následně se stručně zabývá vlastními neuronovými sítěmi a tvorbou jejich struktury. Na závěr článku je uveden příklad použití neuronových sítí při analýze tunelu.

ABSTRACT

In contrast to most engineering materials in the civil engineering the soils and rocks exhibit varied and uncertain behaviour due to process associated with the formation of these natural materials. Therefore geotechnical engineers often simplified the solve problems and used an analytical or empirical methods for the design. In underground structures we have to describe the complexity of geotechnical behaviour and construction process so numerical methods are often used to design. The designers must ensure that the behaviour of numerical model is as close to reality as possible. He can use for this task back analysis. The back-analysis involves all the procedures to prediction the real behaviour of the ground and tunnel system and one of them are neural networks. This paper presents short review of back analysis in geotechnical engineering. In the first part it describes used methods for back analysis. Then overviews of the artificial neural network and their structure design. The example of the back analysis of ground behaviour around tunnel using neural network is shown at the end.

1 Úvod

Zpětné analýzy obecně využívají dvě odlišné metody - přímé a inverzní. Inverzní metody na základě výsledků observačních měření provádí modifikaci vstupních parametrů výpočtu tak, aby bylo dosaženo co největší shody mezi naměřenými hodnotami a hodnotami stanovenými výpočtem (využívají obecně dva optimalizační postupy - sblížovací a přímý).

¹doc. Dr. Ing. Jan Pruška, Katedra geotechniky, Stavební fakulta ČVUT v Praze, Thákurova 7, 166 29 Praha 6, tel.: 0420/22435, e-mail: Pruska@fsv.cvut.cz

Přímé metody zpětné analýzy jsou založeny na minimalizaci chyby funkce určující vlastnosti výsledků. Tyto metody většinou využívají iterační postupy aplikované na nelineární chybovou funkci neznámých parametrů a v současnosti jsou považovány za jednoduchý nástroj k provedení zpětné analýzy. Je možné konstatovat, že v oblasti řešení geotechnických úloh převládá dnes použití zpětné analýzy využívajících přímé metody.

Zpětná analýza může být vyřešena pomocí následujících postupů:

matematické algoritmy jsou nerozšířenější a poskytují velmi hodnověrné výsledky. Výhodou je skutečnost, že jsou vyvíjeny již dlouhou dobu a mohou být implementovány do kódu metody konečných prvků. Jejich nevýhodou je nutnost vysoce odborných znalostí z více vědních oborů (numerika, matematika apod.);

genetické algoritmy jsou metodou kombinatorické optimalizace založené na podobnosti s procesy v biologickém vývoji (Darwinově evoluční teorii);

umělé neuronové sítě využívají zkušební výpočty k dosažení očekávané úrovně kvality výsledků. Na základě dobrých zkušeností se v současnosti rychle rozmáhá použití této nekonvenční metody ve zpětných analýzách podzemních staveb.

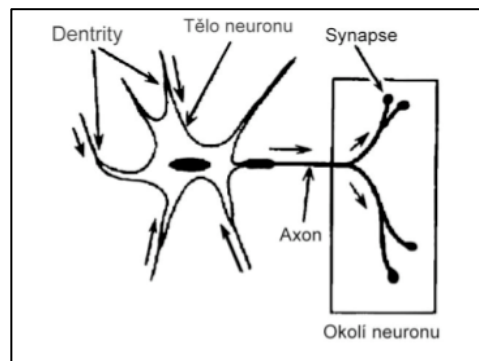
Začátky používání zpětné analýzy v geotechnice spadají do sedmdesátých let minulého století. Jednu z prvních ucelených prací věnovaných obecně použití zpětné analýzy včetně řešených příkladů publikovala Annamaria Cividini (1981). Gioda a Sakurai (1987) publikovali přehled metod zpětné analýzy a jejich principy včetně odkazů na řešené problémy při návrhu a výstavbě tunelů. Sakurai a kol. (1985) popsali koncepci kritického přetvoření s využitím Mohr - Coulombova konstitučního vztahu pro prognózu porušení zeminy. Přínosem pro používání pravděpodobnostních výpočtů podzemních staveb bylo odvození zpětné analýzy využívající minimalizační proceduru spolu s výpočtem pravděpodobnosti spočtených parametrů a její implementace do metody konečných prvků - Ledesma a kol (1996) a Gens a kol. (1996)). Deng a Lee (2001) použili v geotechnice jako jedni z prvních zpětnou analýzu využívající neuronové sítě při řešení stability skalního svahu. Použití neuronových sítí ve zpětných analýzách úloh podzemního stavitelství se rozvíjí od začátku tohoto století Pichler a kol. (2003). Jejich metoda zpětné analýzy je též zabudována do metody konečných prvků. V nedávné době aplikoval Lee se svými spolupracovníky neuronové sítě při zpětné analýze tunelů s nízkým nadložím v málo únosných zeminách (Lee a kol. (2006). V poslední době se aplikaci neuronových sítí v řešení geotechnických úloh věnují Park (2011), Ochmaňski (2012) či Li a kol. (2015). V České republice se problémům zpětné analýzy věnují např. Zapletal (2011,2015), Pruška (2014).

2 Umělé neuronové sítě

Neuronové sítě (ANN - Artificial Neural Network, resp. NN - neural network) je programovací prostředek napodobující chování lidského mozku při řešení vztahů mezi vícerozměrnou vstupní proměnnou a jedno či více rozměrnou výstupní proměnnou. Historie NN spadá do 40. let minulého století, kdy byly s rozvojem neurologického bádání položeny její základní principy. V roce 1958 byl Rosenblattem definován matematický model neuronu nazvaný perceptron jako základ vícevrstevných neuronových sítí (Rojas 1996). V posledních letech jsou NN velmi populární a výkonnou metodou nejen v expertních systémech znalostního typu, ale jsou využívány i samostatně při řešení problémů, které jsou pomocí klasických algoritmických postupů obtížně řešitelné.

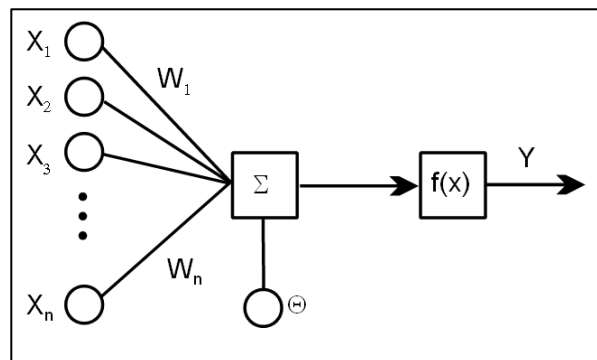
Inspirací pro NN je struktura mozkové tkáně vyšších živočichů, kde jsou znalosti ukládány prostřednictvím vazeb mezi jednotlivými neurony (mozková kůra obsahuje 13 – 15 miliard neuronů). Na obr. 1 je znázorněno propojení biologických neuronů. Tělo neuronu (buňky) je na základě vstupních signálů (vzruchu, informace) vstupujících tzv. dentrity vybuzeno (vytvoří vnitřní potenciál). Signál vzniklý vybuzením těla neuronu je přenesen pomocí

axonového vlákna k výstupům neuronu - synapsím. Synapse přijatý signál z axonového vlákna zesilují či zeslabují a předávají jej takto upravený dalším neuronům (každý neuron může být propojen až s 5000 dalšími neurony).




Obr. 1 Biologický neuron (QC.Expert 2015)
Fig. 1 Biological neuron (QC.Expert 2015)

Základní jednotkou NN (stavební i funkční) je matematický model neuronu (obr. 2), který všechny vstupní proměnné x_i násobí váhovým koeficientem w_i . Součet $\sum w_i x_i$ je dále v neuronu transformován aktivační funkcí f (též přenosová funkce neuronu) a stává se tak výstupem neuronu $y = f(\sum w_i x_i)$. Aktivační funkce vyjadřuje intenzitu odezvy na daný vstup a vedle nejčastěji používané funkce sigmoid $z = 1/(1+e^{-z})$ znázorněné na obr. 3 se používají např. lineární funkce, skokové funkce, hyperbolická tangenta apod. Sigmoid je však nejrozšířenější, protože se podobá biologické sensorické odezvové funkci.




Obr. 2 Matematický model neuronu
Fig. 2 Mathematical model of neuron



Obr. 3 Aktivační funkce neuronu- sigmoid
Fig. 3 Activation function of neuron- sigmoid

V jednovrstvé síti představují váhové funkce w_i intenzitu vazby mezi vstupní proměnnou a neuronem. V případě vícevrstevných sítí (obr. 4) představují váhové funkce w_i intenzitu vazby mezi vstupní proměnnou a neuronem ve vrstvách. Výstupní proměnné se pak predikují jako vážené lineární kombinace výstupů z poslední vrstvy vnitřních neuronů (tzv. skryté vrstvy). V tomto případě může každý neuron současně přijímat libovolný konečný počet různých vstupních signálů a dalším neuronům předávat libovolný konečný počet shodných informací o stavu svého výstupu (NN je tedy ve své podstatě neparаметrická nelineární regrese). Neuronové sítě se také dělí na nerekurzivní (dopředné) a rekurzivní. V dopředných sítích je jednoznačně definován tok informací a tak stejná vstupní data (stimul) dávají vždy stejnou odezvu sítě. U rekurzivních sítí není odezva dána pouze aktuálními vstupními daty (stimulem), ale do sítě se implementuje také časový vliv na vstupní data, který se zavádí pomocí rekurzivních neuronů.



Obr. 4 Schéma vícevrstvé neuronové sítě
Fig. 4 Diagram of multiplayer neural network

Umělé neuronové sítě pracují ve dvou fázích: optimalizující (adaptivní, učící se) a prediktivní (aktivní, vybavovací). Optimalizační fáze slouží pro učení se sítě řešit daný problém. NN se učí většinou iteračním procesem změnou váhových funkcí (synaptických vah) či přizpůsobením aktivační (přenosové) funkce nebo změnou topologie sítě. NN se optimalizuje pomocí metody nejmenších čtverců, tj. tak, aby součet čtverců rozdílů predikované a naměřené hodnoty výstupní proměnné byl minimální. Rozlišujeme dva typy učení NN:

- tzv. s učitelem, kdy se v síti nastavují váhy podle toho, jak blízko je výstup danému vzoru,
- tzv. bez učitele (samoorganizací) – NN síť hledá ve vstupních datech určité vzory, jež mají společné vlastnosti a závislosti bez přítomnosti nějaké další vnější informace (využívá se shluková analýza).

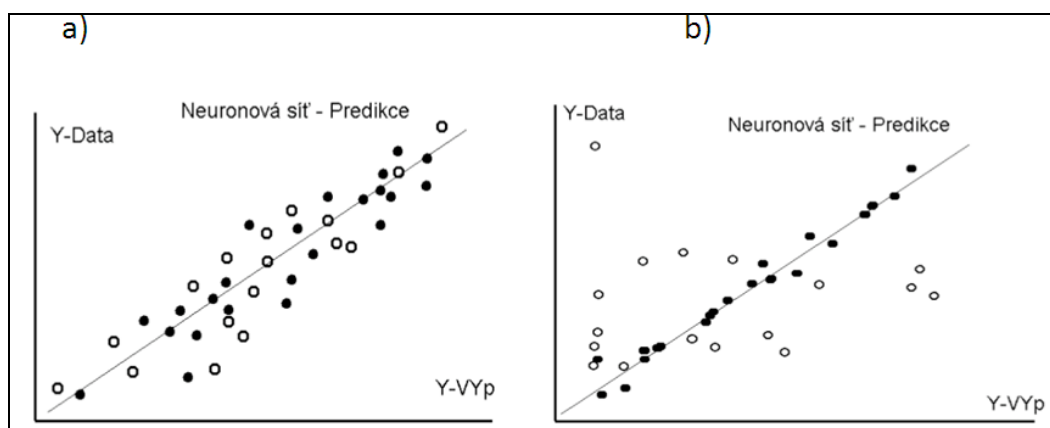
V aktivní fázi pracuje NN podle optimalizovaného algoritmu z adaptivní fáze s nově vloženými vstupními daty. Po načtení dat vznikne ve vstupní vrstvě NN nerovnovážný stav. Vlivem ostatních neuronů se začnou v neuronech zapamatované hodnoty měnit až do dosažení stabilního stavu (rovnovážného) a na výstupech NN pak bude odezva na vložená vstupní data.

Typický postup použití neuronové sítě je následující:

1. Zvolíme skupinu nezávisle proměnných (prediktorů), které mají vliv na závisle proměnné a také zvolíme skupinu závisle proměnných (může být i jen jedna hodnota), na kterou mají mít vliv prediktory.
2. Zvolíme strukturu neuronové sítě – počet vrstev a počty neuronů v jednotlivých vrstvách. Neexistuje jednoznačné pravidlo pro vytvoření nejlepší struktury sítě, je však vhodné používat počet neuronů přibližně odpovídající počtu proměnných. Sítě

s jednou skrytou vrstvou neuronů se používají u lineárních a slabě lineárních vztahů a jsou obecně dostatečné pro většinu řešených problémů. Dvouvrstvé sítě modelují silně nelineární vztahy a jejich použití nemusí být efektivnější (navíc velmi složité sítě mohou být přeuročené, nejednoznačné a nestabilní a těžko optimalizovatelné). Masters (1994) uvádí, že při použití NN pro podzemní stavby je použití dvouvrstevných sítí nutné jen v případě diskontinuitního horninového masivu. Počet vstupních dat by měl být nejméně desetkrát větší, než počet neuronů v síti. Obvykle stačí i pro rozsáhlé problémy síť s 2 - 20 neurony a 1 - 3 vrstvami (QC.Expert 2015).


3. Dalším krokem je optimalizaci parametrů sítě (tzv. “učení” NN). Během tohoto procesu je spuštěn algoritmus, který se snaží najít takové nastavení váhových koeficientů w_i , aby NN předpovídala hodnoty v co nejlepším souladu se zadanými závisle proměnnými. Na vliv volby vstupních vah nepanuje jednotný názor. Někteří autoři tvrdí, že volba výchozích hodnot váhových koeficientů má vliv na konvergenci NN, jiní že tomu tak není. Pokud optimalizace začíná s náhodnými hodnotami váhových koeficientů w_i , je každé jednotlivé řešení nalezené optimalizací zcela odlišné od ostatních. Soulad se zadanými závislými proměnnými se určuje metodou nejmenších čtverců (součtem čtverců). I zcela rozdílné nastavení vah v síti může poskytnout prakticky identickou predikci modelu se shodným součtem čtverců pro zadaná data. Obecně nemůže být zaručeno, že nalezené řešení je nejlepší možné. Proto se někdy může vyplatit spustit optimalizaci vícekrát a použít model s lepším reziduálním součtem čtverců. Rozdíl v optimalizaci NN se pak ovšem může někdy projevit v kvalitě predikce pro neznámá data.
4. Úspěšnost neuronové sítě můžeme posoudit validací (cross validation). Pro validaci se většinou používá 70 % vstupních dat (tato hodnota není však závazná) a ze zbylých 30% dat se pak po optimalizaci (nebo i během ní) počítá predikce, která se srovná se skutečnou hodnotou odezvy. Pokud se tato predikce shoduje se skutečnou odezvou, svědčí to o schopnosti sítě predikovat správně odezvu i pro neznámá data (která předtím “neviděla”). Kvalitu predikce lze posoudit pomocí grafu průběhu optimalizace nebo grafu predikce (obr. 5).
5. Posledním krokem je použití natrénované sítě k predikci neznámých hodnot, kdy zvolíme nezávisle proměnné stejné jako v bodu 1.



Obr. 5 Graf průběhu predikce neuronové sítě (QC.Expert 2015)
a) dobrá predikční schopnost b) špatná predikční schopnost
Fig. 5 Graph of the neural network prediction (QC.Expert 2015)
a) good prediction property b) bad prediction property

3 Příklad použití NN pro zpětnou analýzu tunelu

Pro objasnění zpětné analýzy pomocí NN je popsán postup pro numerický model „fiktivního“ silničního tunelu raženého Novou rakouskou tunelovací metodou. Tunel je 25 metrů pod povrchem terénu. Pokryvné útvary jsou tvořeny deluviálními sedimenty (písek jílovitý F3 a písek hlinitý S4), pod nimi se nachází zvětralé až navětralé jílovité vápnité břidlice (horniny R5 až R4) a hlouběji je zdravá ordovická břidlice (horniny R3 - R2) - obr. 6. Intervaly geotechnických parametrů byly určeny na základě geotechnického průzkumu a konkrétní hodnoty pro jednotlivé vrstvy byly odhadnuty na základě charakteristiky vrstvy - tabulka 1. Čelba je členěna horizontálně na kalotu, opěří a dno. Jako výztuž se uvažuje stříkaný beton tloušťky 300 mm se svorníky typu SN délky 4 m s únosností 150 kN v kalotě i jádru. Během výstavby byl prováděn rozsáhlý monitoring, z kterého do zpětné analýzy jsou uvažovány hodnoty poklesové kotliny a konvergenčních měření.




Obr. 6 Příčný geologický řez
Fig. 6 Geological cross section

Tabulka 1 Intervaly geotechnických parametrů
Table 1 Intervals of geotechnical parameters

Veličina	Objemová tíha γ [kN/m ³]	Deformační modul E_{def} [MPa]	Poissonovo číslo ν [-]	Soudržnost c [kN/m ²]	Vnitřní úhel tření ϕ [°]
F3	18,0 - 21,0	10 - 12	0,35 - 0,38	16 - 25	24 - 29
S4	18,0 - 19,0	12 - 15	0,29 - 0,30	5 - 10	28 - 30
R5 - R6	22,0 - 23,5	15 - 30	0,38 - 0,40	25 - 35	25 - 30
R4 - R3	22,0 - 25,0	50 - 100	0,30 - 0,33	30 - 35	28 - 30
R3 - R2	25,0 - 26,0	100 - 400	0,15 - 0,20	40 - 150	30 - 40

K modelování tunelu (vybraného řezu) bylo použito metody konečných prvků (program PLAXIS). Rozložení vrstev v řezu bylo namodelováno v souladu s geotechnickým průzkumem, prostor uvnitř tunelu a výztuž jsou rozděleny horizontálním členěním výrubu na kalotu, opěří a dno viz. obr. 7. Výztuž je modelována pomocí nosíkových prvků o následujících parametrech: $A = 0,30 \text{ m}^2$, $I = 2,250 \text{ E}^{-3} \text{ m}^4$, $EA = 8,700 \text{ E}^6 \text{ kN}$, $EI = 6,525 \text{ E}^4 \text{ kNm}^2$, $w = 7,50 \text{ kN/m}$. Kotvení horniny je zavedeno do modelu pomocí zlepšení parametrů horniny nad a vedle tunelu. Prostorové chování horninového masivu bylo zavedeno pomocí β metody. Postup výstavby tunelu byl modelován pomocí následujících fází výpočtu:

1. výpočet primární napjatosti, 2. výrub kaloty (redukce zatížení variována), 3. vybudování ostění kaloty (zatížení variováno), 4. přikotvení stropu kaloty a boků kaloty, 6. pobrání opěří (zatížení variováno), 7. vybudování ostění opěří.



Obr. 7 Členění výrubu v numerickém modelu
Fig. 7 Face dividing in numerical model

3.1 Vytvoření NN

Před vlastním vytvořením NN je nutné na základě rozsahu vstupních parametrů provést parametrickou studii chování numerického modelu daného řezu databází dat. Pro náš případ uvažujeme jako proměnné do parametrického výpočtu následující veličiny: deformační modul E_{def} , hodnoty parametru β popisujícího prostorové chování masivu, redukované hodnoty smykových parametrů α_c a α_ϕ a součinitel bočního tlaku K_o . Pro zjednodušení byly tyto veličiny variovány jen pro vrstvu, ve které se nachází vlastní tunel (zdravé ordovické břidlice), uvažované hodnoty jsou uvedeny v tabulce 2. Uvažované parametry mají 4, 3, 3 a 4 rozdílné hodnoty, takže počet všech možných kombinací je 144 (tj. $4 \cdot 3 \cdot 3 \cdot 4$). Vzhledem k časové náročnosti je možné použít pro parametrickou studii metodu LHS (Latinských hyperkrychlí), která významně sníží nutný počet výpočtů – např. Pruška, Vrbata (2014). Prvním krokem při vytváření struktury NN je určení vstupních a výstupních dat. Jako vstupní parametry uvažujeme data z monitoringu: naměřené hodnoty poklesové kotliny a konvergenční měření. Výstupními parametry budou deformační modul E_{def} , součinitel bočního tlaku K_o a parametr α , který udává procento změny hodnoty soudržnosti a úhlu vnitřního tření vzhledem k jejich původním hodnotám. Pro větší přesnost predikce a též z důvodu dosažení lepší konvergence během vytváření modelu a zmenšení počtu iterací při minimalizačním procesu byla predikce hodnot provedena ve dvou krocích – v modelu 1 pro kalotu a v modelu 2 pro celý profil. Popis vstupních a výstupních hodnot pro modely neuronové sítě jsou uvedeny v tabulce 3.

Tabulka 2 Hodnoty pro parametrickou studii
Table 2 Parameter values for parametric study

Veličina	Uvažované hodnoty
deformační modul E_{def} [MPa]	150, 200, 250, 300, 350
parametr β [-]	30%, 40%, 50%
součinitel bočního tlaku K_o [-]	0,2; 0,3; 0,5
redukce smykových parametrů [-]	80 %, 70 %, 60 %, 40 %

Tabulka 3 Popis vstupních a výstupních hodnot pro model NN
 Table 3 Description of input and output parameters in NN model

Parametr NN	Značení	Model 1	Model 2
Svislý pokles terénu ve vzdálenosti x od svislé osy tunelu [mm]	SPx	Vstup	Vstup
Konvergenční měření v kalotě, j - poloha měřicího bodu [mm], svislé (+ dolů), vodorovné (+ doprava) posuny	SUj, SVj	Vstup	Vstup
Konvergenční měření v kalotě a opěří, j - poloha měřicího bodu [mm], svislé (+ dolů), vodorovné (+ doprava) posuny	SUj, SVj	-	Vstup
Deformační modul [MPa]	E_{def}	Výstup	Vstup
Součinitel bočního tlaku [-]	K_o	Výstup	Vstup
Parametr β [-]	β	Výstup	Vstup
Soudržnost (upravená) [kPa]	αc	-	Výstup
Úhel vnitřního tření (upravený)	$\alpha \varphi$	-	Výstup

Pro vytvoření sítě, která dává spolehlivě predikce je dobré vytvořit jak učící data, tak tzv. trénovací data (učící podmnožinu). Z dostupných dat (N dat – pro model 1 tabulka 4.) se vytvoří trénovací data (%N dat), jež se použijí pro nalezení modelu, a zbytek dat se použije na validaci sítě. Obě sady dat (trénovací a učící se) by měly být statisticky shodné. Vzhledem k množství dat, dostupných z parametrické studie numerických výpočtů uvažujeme učící se data 70 % a statistickou shodnost neposuzujeme. Pokud se pro optimalizaci se použijí všechna data (neuvažujeme trénovací data) je zajištěna pouze křížná validace. Následuje provedení transformace nezávisle proměnných z důvodu zajištění plné pozornosti všem datům při optimalizaci NN (většina programů nabízí i volbu automatické transformace). Existuje několik typů transformace, z nichž nejpoužívanější jsou následující dvě (pro náš případ byla vybrána první):

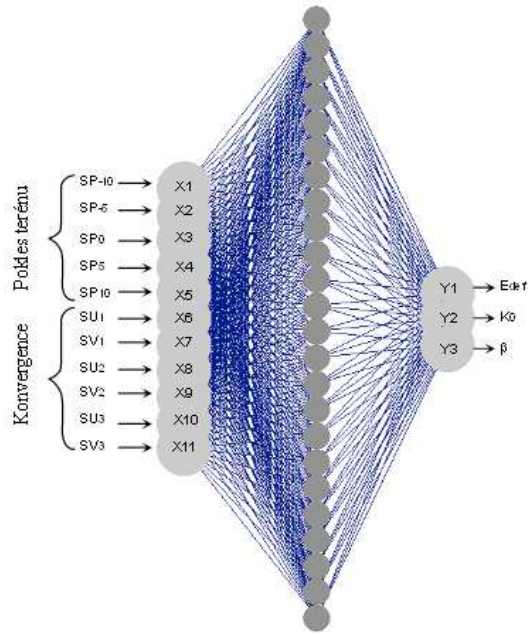
$$(x - \min) / (\max - \min) \quad (1)$$

kde: x - transformovaná nezávislá proměnná,
 min - minimální hodnota nezávislé proměnné,
 max - maximální hodnota nezávislé proměnné.

$$1 / (1 + \exp(-ax)) \quad (2)$$

kde: x - transformovaná nezávislá proměnná,
 a - parametr transformace závislý na aktivační funkci neuronu.

Dále se určí počet skrytých vrstev sítě (v našem případě je zvolena jedna), počet neuronů ve skrytých vrstvách, který by měl být nejméně dvakrát větší, než počet neuronů v síti (někteří autoři tvrdí že až desetkrát), počet iteračních optimalizačních kroků, který omezuje délku výpočtu, parametry ovlivňující samotný optimalizační algoritmus: rychlost učení a moment, kdy doporučené hodnoty jsou od 0,1 do 0,9. Dále je možné zvolit aktivační funkci neuronu a její parametry, kdy v našem případě je zvolen sigmoid se strmostí rovnou 1 (tento parametr udává citlivost, s jakou budou neurony reagovat na změnu nezávisle proměnných). Zvolené hodnoty parametrů NN jsou uvedeny v tab. 5. Na obr 8 je grafické vyjádření architektury sítě.



Obr. 8 Grafické zobrazení struktury NN
Fig. 8 Graphical view of NN structure

Tabulka 4 Data pro NN – model 1
Table 4 Data for NN – model 1

Číslo	SP-10	SP-5	SP0	SP5	SP10	SU1	SV1	SU2	SV2	SU3	SV3	E _{def} [MPa]	K0 [-]	β [%]
1	21	45	64	45	23	82	0	119	30	119	30	160	0,2	30
2	19	39	59	40	20	73	0	103	24	103	24	200	0,3	30
3	8	22	31	22	9	53	0	78	18	78	18	300	0,2	30
4	22	46	66	47	24	98	0	130	40	130	40	160	0,3	30
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
26	7	17	29	18	7	50	0	78	18	78	18	350	0,2	40
27	16	34	56	34	16	64	0	103	24	103	24	250	0,3	40
28	14	33	52	33	13	61	0	92	22	92	22	250	0,2	30
29	23	48	68	47	24	90	0	120	33	120	33	160	0,3	40
30	9	21	32	22	9	56	0	80	20	80	20	300	0,3	40

Tabulka 5 Parametry a architektura NN
Table 5 NN architecture and parameters

NN analýza	Model 1	Model 2
Počet uzlů vstupní vrstvy	11	16
Počet uzlů ve skryté vrstvě	24	30
Počet uzlů ve výstupní vrstvě	3	2
Počet iteračních kroků	3000	3000

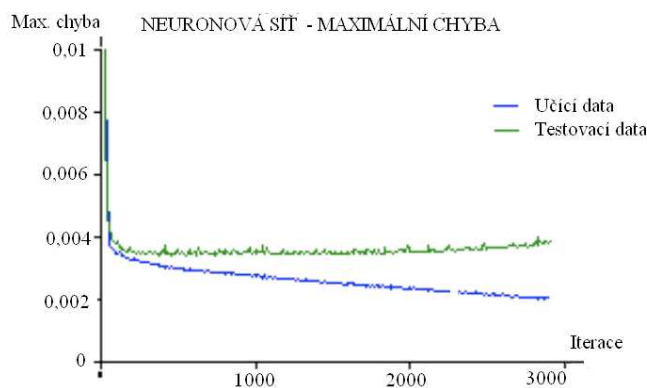
3.2 Optimalizace sítě neuronů

Dalším krokem je optimalizace parametrů sítě (tzv. “učení” NN), kdy zde byla použita metoda optimalizace "s učitelem" nazývaná BPNN (back propagation neural networks). Jedná se o algoritmus zpětného šíření přepočtu chyby výstupní vrstvy do vrstev předchozích. Pro optimalizaci byly zvoleny náhodné hodnoty váhových koeficientů w_i určené funkcí náhodného čísla (RND) v rozsahu $-0,1$ a $1,0$. Soulad se zadanými závislými proměnnými se určuje metodou nejmenších čtverců (součtem čtverců), kdy se počítají střední a maximální chyba pro učící a testovací data. Výsledky optimalizace sítě jsou uvedeny v tab. 6. Možnosti posouzení kvality predikčních schopností neuronové sítě se liší i dle používaného softwaru. Při použití komerčního softwaru QC.Expert máme následující možnosti:

- Graf Y-Predikce. Graf shody naměřených (zadaných) hodnot závisle proměnné a vypočítaných hodnot predikce.
- Grafické znázornění vah, kdy tloušťka synapsí v grafickém znázornění NN ukazuje absolutní velikost odpovídající váhy a tím také množství informace, která teče mezi dvěma neurony. Podle tloušťky synapse se tak dá usuzovat na významnost nezávisle proměnné (vychází z ní tlusté synapse) a také na kvalitu predikce jednotlivých závisle proměnných (vchází do ní tlusté synapse).
- Relativní vliv prediktorů na predikci vyjádřený jako součet absolutních vah jednotlivých predikovaných proměnných.
- Graf učícího procesu, pokles součtu čtverců rozdílů predikce a skutečných hodnot závisle proměnné v závislosti na počtu iterací - pro náš příklad je tento graf na obr. 9.

Tabulka 6 Výsledky optimalizace NN
Table 6 Results of optimization NN

Veličina	Model
Predikovaná veličina	E_{def}
Aktivační funkce	Sigmoid
Struktura	11- 24 -3
Rychlost učení	0,3
Moment	0,9
Ukončení při chybě	0,05
Maximální chyba pro učící data	0,0026
Maximální chyba pro testovací data	0,0042



Obr. 9 Graf učícího procesu (QC.Expert 2015)
Fig. 9 Graph of learning procedure (QC.Expert 2015)

3.3 Výsledné hodnoty NN

Výsledky parametrické studie dávají značný rozsah sledovaných hodnot, nicméně jsou základem pro vytvoření NN. Ověření správného fungování numerického modelu lze provést porovnáním velikostí sledovaných veličin (deformací) s hodnotami naměřenými při realizaci podzemního díla. Zde nám významně pomůže při zpětné analýze vytvořená NN, neboť umožňuje predikci vstupních parametrů numerického modelu na základě zadání naměřených deformací. Z vytvořené NN (tj. modelu 1 a modelu 2) jsou pro naměřené poklesy terénu a konvergence predikovány tyto veličiny: $E_{\text{def}} = 300 \text{ MPa}$, $K_o = 0,15$, $\beta = 30 \%$, $c = 55 \text{ kPa}$, a $\varphi = 32^\circ$. Tyto parametry byly vloženy do numerického modelu a přesné výsledky s porovnáním s naměřenými hodnotami jsou v tabulce 7. Rozdíly u poklesové kotliny jsou způsobeny zjednodušenou zpětnou analýzou, kdy byly upravovány parametry jen u vrstvy zdravých ordovických břidlic a ne dalších vrstev hornin směrem k povrchu terénu.

Tabulka 7 Porovnání naměřených a predikovaných hodnot [mm]
Table 7 Comparison of measured and predicted values [mm]

Veličina	SP ₋₁₀	SP ₋₅	SP ₀	SP ₅	SP ₁₀	SU ₁	SV ₁	SU ₂	SV ₂	SU ₃	SV ₃
Měřená hodnota	6	9	20	8	7	69	0	90	29	91	29
Predikovaná hodnota	8	16	32	16	8	67	0	92	22	92	22

4 Závěr

V geotechnické inženýrské praxi se značná část návrhů tunelů provádí pomocí numerických analýz založených na metodě konečných prvků. Je obecně známé, že parametry zemin a hornin získané jako výsledek geotechnického průzkumu jsou náchylné k jistým chybám, které mohou ovlivnit vypočtené hodnoty. Pro zajištění skutečnosti, že chování numerického modelu je co nejvíce shodné se skutečností je možné použít zpětnou analýzu. V současnosti v ČR převládá použití zpětné analýzy využívající sbližovací inverzní postupy. Tento postup je relativně jednoduchý (a proto inženýrskou praxí upřednostňován), nicméně nemusí nutně vést k žádoucím výsledkům. Z mnoha dalších postupů zpětných analýz převládá ve vyspělých tunelářských zemích postup využívající umělé neuronové sítě, který má následující přednosti:

- dává dobré výsledky, je používán ve většině vědních oborů (například geovědní obory: program DIPMETER ADVISOR pro hodnocení geofyzikálních měření ve vrtech),
- metoda je jednoduše aplikovatelná na většinu geotechnických problémů bez nutnosti hluboké znalosti matematiky a programování,
- metoda díky váhovému ohodnocení v neuronové síti může zohlednit přesnost měřených dat.
- komerční produkty obsahují nástroje, které uživatele provedou všemi kroky potřebnými pro vytváření neuronových sítí (např. automatický vyhledávač sítě).

Popularita metodologie neuronových sítí rychle stoupá v nejrůznějších oblastech lidského zkoumání od základního výzkumu po vytěžování dat (data mining), v oblastech predikcí v komerční sféře, řízení rizik, marketingu a další. ANN se úspěšně použila na řadě projektů podzemních staveb ve světě, jmenujme například čtvrtou linku metra v Budapešti, stanici metra Taborstrasse ve Vídni, železniční tunel v Gong – Ju v provincii Chunch cheong nam, metro ve městě Dalian či hydroelektrárnu v Jinpingu. Dá se tedy snad objektivně konstatovat,

že použití ANN vede určitě i ke snížení rizik spojených s návrhem a výstavbou podzemních děl.

5 Seznam použité literatury

- Cividini, A., Jurina, G., Gioda, G., 1981. Some aspects of characterization problems in geomechanics. *International Journal of Rock Mechanics and Mining Sciences* 18, 487-503.
- Deng, J. H., Lee, C. F., 2001. Displacement back analysis for a steep slope at the Three Gorges Project site. *International Journal of Rock Mechanics and Mining Sciences* 38, 259-268.
- Gens, A., Ledesma, A., Alonso, E. E., 1996. Estimation of parameters in geotechnical back analysis - II. Application to a tunnel excavation problem. *Computers and Geotechnics* 18 (1), 29-46.
- Ledesma, A., Gens, A., Alonso, E. E., 1996. Estimation of Parameters in Geotechnical Backanalysis - I. Maximum Likelihood Approach. *Computers and Geotechnics* 18 (1), 1-27.
- Lee, J., Akutagawa, S., Yokota, Y., Kitagawa, T., Isogai, A., Matsunaga, T., 2006. Estimation of model parameters and ground movement in shallow NATM tunnel by means of neural network. *Tunnelling and Underground Space Technology* 21, 242.
- Li, C.H., Feng, J.W., Zhao, K., 2015. Back analysis of rock parameters based on neural network and FLAC. *Transit Development in Rock Mechanics – Cai Yang & Wang. Eds., Taylor and Francis*
- Masters, T., 1994. *Practical neural networks recipes in C*, Boston MA, Academic Press
- Ochmański, M., Bzówka, J., 2012. Back Analysis of SCL tunnels based on Artificial Neural Network. *Architectur Civil Engineering Environment*, No. 3/2012, Silesian University, Poland
- Park H.I., 2011. Study for Application of Artificial Neural Networks in Geotechnical Problems. *Samsung C&T,I*, Korea of Republic
- Pichler, B., Lackner, R., Mang, H. A., 2003. Back analysis of model parameters in geotechnical engineering by means of soft computing. *International Journal for numerical Methods in Engineering* 57, 1943-1978.
- Pruška, J., 2014. Zpětná analýza při návrhu tunelů. In *Sborník 42. Konference Zakládání staveb Brno 2014. ČGtS ČSSI Praha*, s. 143 – 148
- Pruška, J., Vrbata, J., 2014. Application of LHS method in tunnel analyses. In: *14th GeoConference on Science and technologies in geology, exploration and mining Conference proceedings. Sofia: International Multidisciplinary Scientific GeoConference SGEM, 2014, vol. 2, p. 93-100.*
- QC.Expert 2015, TriloByte Statistical Software, www.trilobyte.cz
- Rojas, R., 1996. *Neural networks : A Systematic Introduction*. Springer-Verlag Berlin Heidelberg, 1996. 502 s. ISBN 3-540-60505-3.
- Sakurai, S., Shimizu, N., Matsumuro, K., 1985. Evaluation of plastic zone around underground openings by means of displacement measurements. *Proceedings, 5th International Conference on Numerical Methods in Geomechanics, Nagoya, Japan*, 1-5 April, 1985, pp. 111-118.
- Zapletal, A., 2011. Kritické zhodnocení možností zpětné analýzy. *Tunel 2/2011*, pp. 52 – 60
- Zapletal, A., Louženský, T., 2015. Zpětná analýza mělce založených tunelových konstrukcí, <http://www.ita-aites.cz/cz/aktuality/novinky> (červen 2015)

Poděkování

Príspevek vznikl v rámci řešení úkolu programu Centra kompetence Technologické agentury České republiky (TAČR), číslo projektu TE01020168.