



INŽENÝRSKÁ MECHANIKA 2005

NÁRODNÍ KONFERENCE

s mezinárodní účastí

Svratka, Česká republika, 9. - 12. května 2005

""""INVERSE FEM ANALYSIS I: STOCHASTIC TRAINING ""OF NEURAL NETWORK

D. Novák^{*}, D. Lehký^{*}

Summary: *The paper suggests a new approach of inverse analysis to obtain parameters of FEM computational model in order to obtain best agreement with experimental data. The proposed inverse analysis approach is based on coupling of FEM computational model and the stochastic training of artificial neural network. Identification parameters play the role of basic random variables with a scatter reflecting the physical range of possible values. Novelty of the approach is the utilization of efficient small-sample simulation method Latin Hypercube Sampling (LHS) used for stochastic training of neural network. Once the network is trained it represents an approximation consequently utilized in an opposite way: For given experimental data to provide the best possible set of model parameters. The approach is general and can be applied easily to any inverse problem of engineering mechanics.*

1. Úvod

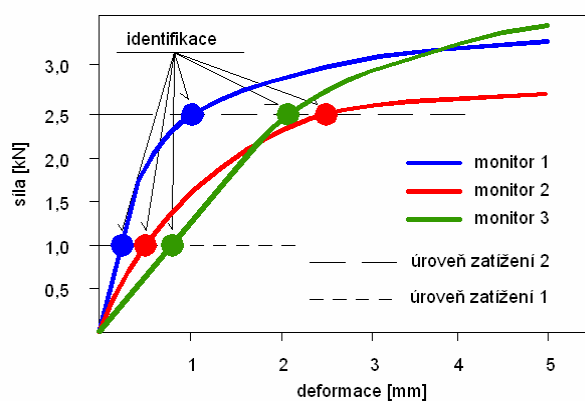
Inverzní problémy se v inženýrských vědách objevují v různých formách. Definice úlohy a způsoby řešení jsou v mnoha případech víceméně identické, jsou však prezentovány pod různými termíny (např. inverse analysis, identification, model updating, inverse FEM). Cílem inverzní analýzy je na základě změřených dat identifikovat parametry výpočtového modelu. Měřená data a parametry, které identifikujeme, mohou být obecně různého druhu, podle typu řešeného problému. Omezíme-li se na úlohy inženýrské mechaniky, řešené metodou konečných prvků, jedná se např. o třídy úloh uvedené v následujících odstavcích. Pro přehlednou orientaci budeme dále používat označení pro identifikované parametry IP a pro měřená data MD.

Identifikace druhu a velikosti zatížení působící na konstrukci na základě měřené odezvy (např. deformace či napětí ve vybraných bodech konstrukce) představuje klasicky definovaný problém. Maincon (2004) uvádí přehled postupů a navrhuje postup inverzní metody konečných prvků (iFEM) formulovaný a úspěšně aplikovaný na třídu lineárních problémů. Výhodou navrženého postupu je přímý výpočet zatížení na základě rozšířené soustavy lineárních rovnic, postup však není možné aplikovat na nelineární problémy. Klasifikace problému: IP = zatížení, MD = odezva ve vybraných bodech.

^{*} Prof. Ing. Drahomír Novák, DrSc., Ing. David Lehký: Ústav stavební mechaniky, Fakulta stavební, VUT v Brně; Veveří 95; 602 00 Brno; tel.: +420 541 147 360; fax: +420 541 140 994; e-mail: novak.d@fce.vutbr.cz

Včasná detekce úrovně a/nebo lokalizace poškození konstrukce pomocí nedestruktivních experimentálních metod nabývá v současné době na významu vzhledem ke zvyšujícím se nákladům na údržbu. Známostou a rozšířenou metodou je dynamický experiment, měřením kmitání konstrukce získáme frekvence a vlastní tvary – reálné dynamické chování lze pak srovnávat s dynamickým FEM modelem. „Naladit“ FEM model heuristicky změnou materiálových parametrů modelu je stále obtížnou úlohou. Přístupy nazývané „model updating“, jsou vyvíjeny především pro aplikace na mosty, např. Deix & Geier (2004), Link (1999). Klasifikace problému: IP = parametry materiálu, MD = frekvence a vlastní tvary pomocí dynamického experimentu.

Identifikace parametrů materiálových modelů na základě testování laboratorních vzorků pro modelování konstrukcí z kvazikřehkých materiálů (např. betonových konstrukcí) je jednou ze základních úloh, na kterou je dlouhodobě zaměřen výzkum v oboru lomové mechaniky. V této oblasti existuje řada prací, které spadají v zásadě do dvou kategorií inverzní analýzy: (1) použití experimentálně získané celé křivky zatížení-přetvoření, (2)



Obr. 1 Zatěžovací diagramy pro různé monitorovací body

užití experimentálních dat, které představují pouze maximální únosnosti (tedy vrchol křivky zatížení-přetvoření), ale identifikace je prováděna na různé velikosti vzorku, nebo různé typy vzorků a to tak aby byl podchycen vliv velikosti – „size effect“ (Planas et al., 1999). V případě identifikace materiálových parametrů s využitím nedestruktivních zkoušek, tj. použití monitorovacích systémů na skutečných konstrukcích jsou data získána pouze v určitých úrovních zatížení, není k dispozici celý diagram zatížení-přetvoření. Pracuje se s celou sadou monitorovacích bodů, ilustrace je na obr. 1.

Z řady prací spadající do těchto kategorií citujme např. Fairbairn et al. (1999), Iacono et al. (2003), Novák et al. (2003), Novák & Lehký (2004, 2005), Kučerová et al. (2004), Červenka et al. (2005). Klasifikace problému: IP = parametry materiálového modelu, MD = křivka zatížení-přetvoření, nebo její část (resp. bod).

Výše uvedené oblasti provádějí inverzní analýzu zpravidla na úrovni deterministické, tj. jak IP tak MD jsou deterministické veličiny. V identifikaci lze však jít dále: Místo deterministických MD pracovat např. s naměřenými histogramy a identifikovat IP jako náhodné veličiny. Jedná se o vyšší úroveň identifikace, kterou lze nazvat statistickou nebo pravděpodobnostní inverzní analýzou. V této oblasti, pokud je autorům známo, ještě mnoho práce vykonáno nebylo, výjimkou je aplikace na betonové konstrukce, kde jsou identifikovány první dva statistické momenty parametrů materiálového modelu (Strauss et al., 2004, navazující článek autorů na této konferenci, Lehký & Novák, 2005). Klasifikace problému: IP = statistické parametry materiálového modelu (např. střední hodnota, směrodatná odchylka), MD = statistické charakteristiky odezvy získané z měření.

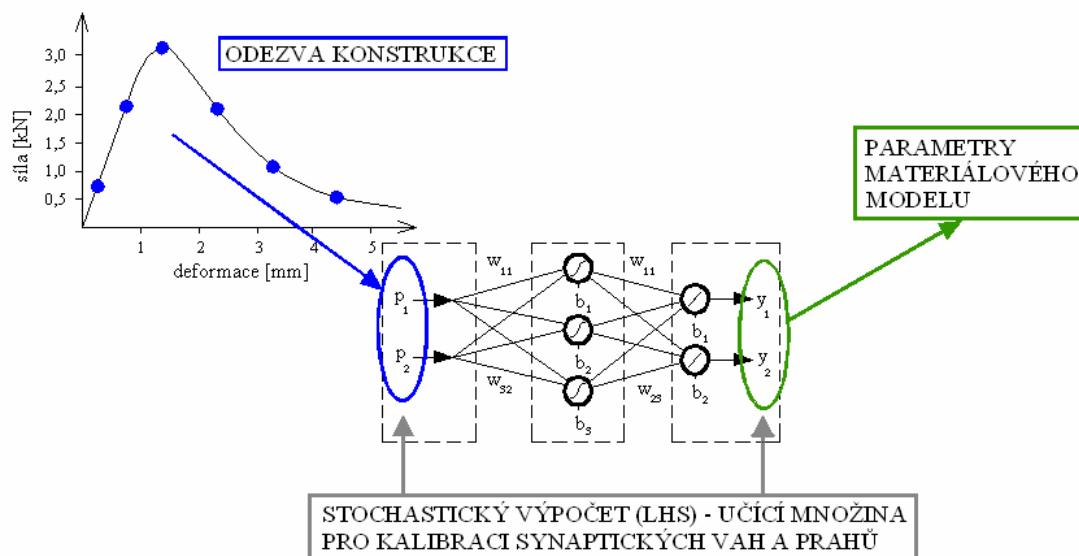
Cílem tohoto článku je popsat nově navrženou metodiku inverzní FEM analýzy založenou na kombinaci stratifikované simulace typu Monte Carlo a učení neuronových sítí. Důraz je přitom kladen na: (1) obecnost přístupu a snadnou aplikovatelnost na jakýkoliv problém

inverzní analýzy; (2) účinnost učení neuronových sítí pomocí velmi malého počtu realizací, kde se používá stochastická metoda Latin Hypercube Sampling s možností uvažování statistických závislostí. Hledané parametry při tomto postupu vystupují ve formě náhodných veličin a simulace typu Monte Carlo nám umožní za použití malého počtu simulací pokrytí celého oboru hodnot IP v reálně daných mezích. Tyto simulace poslouží pro učení vhodné neuronové sítě. Pro stanovení parametrů je nakonec využita naučená neuronová síť. Článek popisuje metodiku z obecného pohledu na problematiku identifikace, klasifikuje možnosti použití navržené inverzní analýzy tak, aby ji bylo možno použít prakticky pro jakýkoliv problém představovaný FEM modelem, jenž je použit pro modelování. Jsou rovněž stručně popsány k tomuto účelu vyvinuté softwarové prostředky. Příspěvek je doplněn vybranými numerickými příklady. dokumentující účinnost navrženého postupu.

2. Metodika inverzní FEM analýzy

Navržená inverzní analýza představuje kombinaci statistické simulace a neuronových sítí. Celý postup je možno popsat v následujících bodech:

- 1) Nejdříve je nutné vytvořit výpočtový FEM model daného problému. Tento model je předběžně „naladě“ pomocí parametrů modelu (IP), které budou předmětem identifikace, tak, aby odezva FEM modelu byla alespoň částečně v určitém souladu s experimentálními daty (MD). Tento předběžný krok je založen na přibližné znalosti některých parametrů nebo jejich inženýrském odhadu, „ladění“ je prováděno heuristicky v několika málo iteracích tak abychom nebyli příliš vzdáleni od MD.
- 2) IP modelu dále uvažujeme jako náhodné veličiny popsané matematickým modelem rozdělení pravděpodobnosti, rovnoměrné rozdělení představuje přirozenou volbu, neboť dolní a horní mez tohoto rozdělení může představovat hranice reálného výskytu daného parametru. Nicméně jiná rozdělení pravděpodobnosti je možno rovněž použít, např. normální, chceme-li potlačit extrémy parametrů a naopak zdůraznit oblast výskytu s největší pravděpodobností. IP modelu nasimulujeme pomocí vhodné simulace typu Monte Carlo (LHS). Výsledkem jsou náhodné realizace IP (vektor \mathbf{y}). Je možné uvažovat i statistickou závislost mezi IP (je-li alespoň přibližně známa, může inverzní analýze při následném stochastickém trénování pomoci).
- 3) S náhodnými realizacemi IP \mathbf{y} pak provedeme opakované řešení FEM výpočtového modelu a získáme statistický soubor virtuální odezvy \mathbf{p} .
- 4) Náhodné realizace \mathbf{y} a získaná náhodná odezva z FEM modelu \mathbf{p} slouží jako stochastický vstup pro učení vhodné neuronové sítě. Tento klíčový prvek celého postupu je ilustrativně znázorněn na obr. 2 (pro odezvu FEM modelu ve formě nelineární závislosti zatížení-přetvoření včetně pokritického chování).
- 5) Jakmile je neuronová síť naučena, pak lze na jejím základě zodpovědět otázku opačnou: Určit nejlépe soubor IP tak aby FEM model poskytl co nejlepší shodu s MD. To se provede simulací neuronové sítě s MD jako jejím vstupem. Výsledkem je soubor parametrů \mathbf{y}_{opt} .
- 6) Závěrečná verifikace výsledků postupu představuje FEM výpočet s parametry \mathbf{y}_{opt} . Srovnání s MD poskytne představu o tom, jak byla inverzní analýza úspěšná.



Obr.2 Schéma stochastického učení neuronové sítě

V této souvislosti je nutné uvést problematické aspekty inverzní analýzy jako takové a navrženého postupu, které mohou způsobit selhání výše navržené inverzní analýzy:

- Problém může být špatně podmíněn („ill-posed“), např. když budeme identifikovat velké množství parametrů na základě velmi malého počtu měření, postup nutně selhává. Rovněž malá chyba na úrovni experimentu MD může vést k velkým chybám na úrovni IP. Tento problém je všeobecně znám a zabývá se jím podrobněji např. Planas et al. (1999), Maree & Maincon (2004), Bernardo & Maincon (2004).
- Pokud bude navržena neuronová síť nevhodně co do struktury (počty neuronů, vrstev, typy přenosových funkcí) ve vztahu ke složitosti řešeného problému, pak nemusí být výsledky dobré.
- Pokud navrhne statistickou simulaci tak, že FEM výsledky s jednotlivými realizacemi IP jsou prakticky mimo obor experimentu MD, postup selhává. Význam iniciačních výpočtů s FEM modelem a správná rozvaha rozptylu IP pro statistickou simulaci je zřejmá. Zdálo by se, že větší rozptyl pro IP při statistické simulaci je výhodný neboť pokrytí MD je zajištěno s větší pravděpodobností, avšak pak učení neuronové sítě může být obtížné (horší konvergence, výsledky zatížené větší chybou). Znalost daného problému a kvalifikovaný inženýrský odhad jsou nezastupitelné, celou metodiku rozhodně nelze používat jako „black-box“ metodu.


3. Stochastické učení neuronových sítí pomocí stratifikované simulace

3.1 Latin Hypercube Sampling

Základem celého postupu je nutnost vygenerování učící množiny (určitý počet náhodných simulací), což může např. při nelineární FEM analýze znamenat značně časově náročný úkol. Pokud se navíc identifikují statistické charakteristiky, vstupuje do hry druhá úroveň stochastické analýzy – získání náhodné odezvy. To představuje další simulace navíc. Snažíme

se proto eliminovat množství simulací využitím efektivní simulační metody LHS. Ta nám umožní, na rozdíl od klasické metody Monte Carlo, zvolit minimální počet simulací závislý na učení sítě nikoliv na použité simulační metodě.

K vytvoření učící množiny pro neuronovou síť je navržena stochastická analýza konstrukce, která k náhodně generovaným parametrům modelu přiřadí odpovídající výstup, např. zatěžovací křivku, apod. Jako velmi účinné se jeví použití simulační metody Latin Hypercube Sampling (LHS), která nám zajistí pokrytí celého oboru hodnot daných veličin při malém počtu simulací – opakovaném řešení nelineárního výpočtu. Princip metody LHS je následující. Definiční obor distribuční funkce $F_i(x)$ každé náhodné veličiny X_i se rozdělí na N_{sim} intervalů (= počet simulací) o stejné pravděpodobnosti $1/N_{sim}$. Při každé simulaci se



náhodně na základě náhodných permutací celých čísel $1, 2, \dots, N_{sim}$ zvolí jeden interval. Z takto zvoleného intervalu se vybere reprezentant, např. střed intervalu. S ním se provede inverzní transformace distribuční funkce a výsledkem bude náhodná realizace dané veličiny.

Je dokázáno, že jedna z nejúčinnějších LHS strategií, která je schopna nasimulovat střední hodnoty naprosto přesně a v případě rozptylu poskytuje velmi dobré výsledky, je postup navržený autory Keramat & Kielbasa (1997) a Huntington & Lyrantzis (1998). Náhodná střední hodnota každého intervalu je vybrána jako (obr. 3):

Obr.3 Ilustrace simulace LHS

$$x_{i,k} = \frac{\int_{y_{i,k-1}}^{y_{i,k}} x \cdot f_i(x) dx}{\int_{y_{i,k-1}}^{y_{i,k}} f_i(x) dx} = N_{sim} \cdot \int_{y_{i,k-1}}^{y_{i,k}} x \cdot f_i(x) dx, \quad (1)$$

kde f_i je hustota rozdělení pravděpodobnosti veličiny X_i , a integrační meze jsou:

$$y_{i,k} = F_i^{-1}\left(\frac{k}{N_{sim}}\right). \quad (2)$$

3.2 Statistická závislost parametrů

Pomocí metody LHS jsou vygenerovány realizace, které velmi dobře pokrývají mnohorozměrný prostor náhodných veličin – parametrů, které budeme dále identifikovat. V případě, že je známa statistická závislost mezi jednotlivými parametry, je vhodné ji uvažovat již při přípravě náhodných realizací pomocí metody LHS. Toho lze docílit různými metodami, např. Huntington & Lyrantzis (1998), Iman & Conover (1982), nicméně tyto postupy mají různá omezení.


Velmi robustní technika zavedení statistické závislosti založená na stochastické optimalizační metodě simulované žihání byla navržena Vořechovským & Novákem (2003). Zavedení statistické závislosti je chápáno jako optimalizační problém. Rozdíl mezi požadovanou korelační maticí \mathbf{K} a generovanou \mathbf{S} musí být co nejmenší. Vhodným měřítkem je např. norma korelačních koeficientů:

$$E_{overall} = \sqrt{\sum_{i=1}^{N_V-1} \sum_{j=i+1}^{N_V} (S_{i,j} - K_{i,j})^2} . \quad (3)$$

Tato norma je pak minimalizována změnou realizací v generovaných simulacích LHS pomocí metody simulovaného žihání.

3.3 Neuronová síť

Obecně existuje velmi mnoho druhů neuronových sítí, přičemž každá se hodí na různé typy úloh. Při aplikaci na identifikaci parametrů je použita dopředná síť označovaná jako vícevrstvý perceptron (ML-perceptron z anglického Multi-layer-perceptron). Základním stavebním kamenem této sítě je McCulloch-Pittsův perceptron. Neuronovou síť typu vícevrstvý perceptron tvoří obecně sada neuronů uspořádaných v několika vrstvách. Všechny neurony v jedné vrstvě jsou vzájemně pospojovány se všemi neurony vrstvy následující, neurony jedné vrstvy vzájemně spojeny nejsou. Každý spoj mezi neurony dvou sousedních vrstev je definován váhovým koeficientem (synaptickou váhou) $w_{i,j}$, který simuluje různou vodivost spojových cest. K množině impulsů, které jsou přivedeny k neuronu od všech neuronů z předcházející vrstvy, je přičtena prahová hodnota b_j neuronu a aplikována přenosová funkce f . Dle typu této funkce se neurony dělí na prahové, lineární a nelineární. Hodnoty synaptických vah a prahů jsou spolu s typem přenosové funkce určující pro chování neuronu i celé sítě. Výstup z jednoho neuronu se dá stanovit z následujícího vztahu:



Obr.4 Schéma základního neuronu

$$y = f(x) = f\left(\sum_k (w_k p_k) + b\right), \quad (4)$$

kde k je číslo vstupujícího neuronu ($1, \dots, K$), w_k je synaptická váha spojové cesty z k -tého neuronu předcházející vrstvy, p_k je impuls z k -tého neuronu předcházející vrstvy, b je práh neuronu a f je přenosová funkce neuronu. Při výpočtu výstupního vektoru celé sítě postupujeme vrstvu po vrstvě od vstupní vrstvy k výstupní.

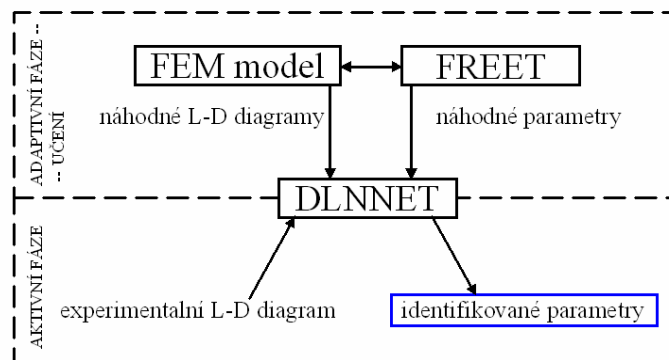
Umělá neuronová síť pracuje v zásadě ve dvou fázích – aktivní a adaptivní. V aktivní fázi vstupuje do sítě signál, který prochází celou sítí od neuronu k neuronu skrze spojové cesty a ve výstupní vrstvě obdržíme požadovaný výstupní signál. Aby bylo možné tuto fázi provést, je nutné mít správně nastaveny váhy jednotlivých spojových cest a prahové hodnoty neuronů. K tomu se využívá druhá fáze při níž se hodnoty vah a prahů učí (nebo také trénují). Síť se učí na základě tzv. učící množiny, tj. množiny uspořádaných dvojic $[\mathbf{p}_i, \mathbf{y}_i]$, kde \mathbf{y}_i je výstupní vektor, kterým očekáváme, že síť odpoví na vstup \mathbf{p}_i . Učení pak spočívá v minimalizaci kritéria:

$$E = \frac{1}{2} \sum_{i=1}^{N_{sim}} \sum_{j=1}^K (y_{ik}^v - y_{ik}^*), \quad (5)$$

kde N_{sim} značí počet uspořádaných dvojic (sad) „vstup-výstup“ v učící množině, y_{ik}^* je požadovaná výstupní hodnota k -tého výstupního neuronu při i -tém vstupu (\mathbf{p}_i) a y_{ik}^v je skutečná výstupní hodnota (při tomtéž vstupu). K minimalizaci kritéria E se používá některé optimalizační metody - gradientní, stochastické nebo metody založené na umělé inteligenci.

4. Softwarové prostředky


Výše uvedená teorie je realizována v software, jenž je možno snadno aplikovat prakticky na jakýkoliv problém inverzní analýzy. Tento otevřený programový systém vznikl integrací software pro statistickou, citlivostní a pravděpodobnostní analýzu FReET (Novák et al., 2005) a software pro práci s neuronovými sítěmi DLNNET (Lehký, 2005). Integrace problému, který je předmětem inverzní analýzy (např. FEM výpočet) je zřejmá ze schématu na obr. 5. Implementace problému do systému může být realizována na dvou úrovních: Pro jednoduché funkce lze využít „equation editor“, který je součástí uživatelského prostředí programu FReET. Pro složitější modely (existující jako počítačové programy v některém programovacím jazyce (C++, Fortran, aj.) je nutno vytvořit dle určitých pravidel funkci *.DLL, se kterou pak software inverzní analýzy pracuje.



Obr.5 Schéma komunikace softwarových nástrojů

5. Numerické příklady

5.1 Učení sítě: klasická metoda Monte Carlo vs. Latin Hypercube Sampling

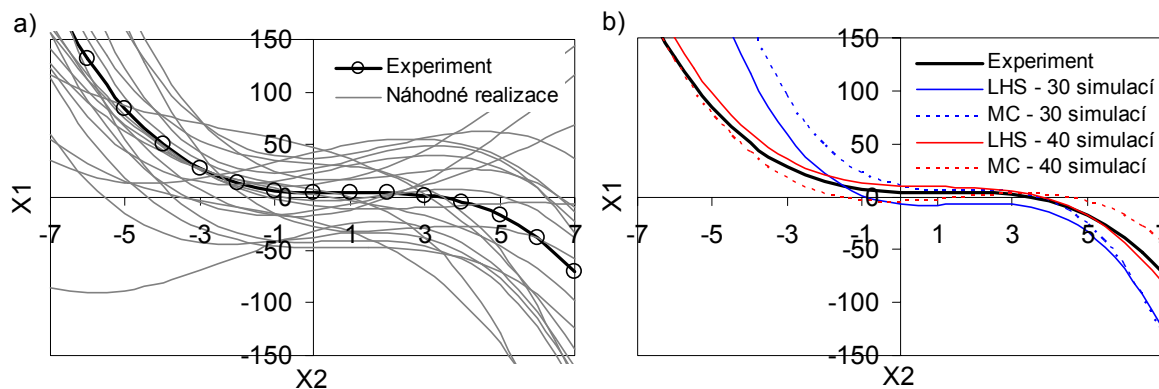


Cílem tohoto příkladu je ukázat účinnost učení neuronové sítě při použití stratifikované simulace LHS ve srovnání s klasickou simulací Monte Carlo. Pro tyto účely byl zvolen případ funkce poruchy rámové konstrukce na obr. 6. Příklad je podrobně analyzován z pohledu spolehlivostní analýzy, mechanismy porušení rámu je možno aproximovat interpolačními polynomy (Grigoriu, 1982/83). Výsledný tvar funkce poruchy rozdělující prostor na oblast poruchy (funkce je záporná) a oblast bezpečnou (funkce je kladná) je:

Obr.6 Schéma rámové konstrukce

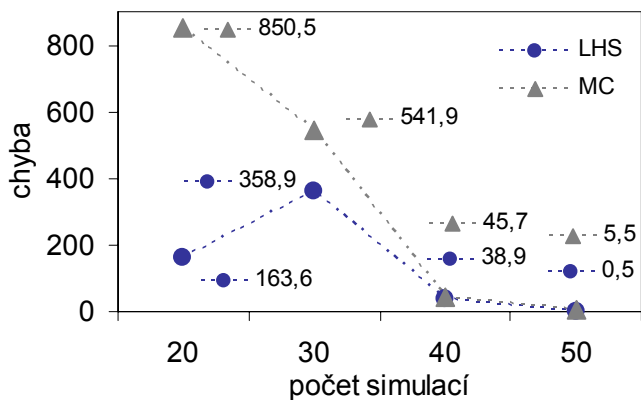
$$g(\mathbf{X}) = aX_2^3 + bX_2^2 + cX_2 - X_1 + d \quad (6)$$

kde koeficienty jsou $a = -0,36355$, $b = 1,18046$, $c = -1.0892988$, $d = 4.2042064$ a parametry X_1, X_2 představují účinky zatížení H a V normalizované mezním plastickým momentem průřezu $X_1 = Ha/m_p$, $X_2 = Va/m_p$. Pro účely srovnání účinnosti zvolme následující (hypotetický) případ: Řekněme, že máme k dispozici experimentální data parametrů X_1, X_2 odpovídající poruše ($g(\mathbf{X}) = 0$). Tyto body leží přesně na hranici (6) a jsou označeny na obr.7a jako experiment (celkem 15 bodů). Cílem je nyní identifikovat všechny 4 parametry polynomu (6), které budeme pokládat za neznámé IP, v případě velmi úspěšné identifikace se musí tyto hodnoty rovnat (limitně blížit) koeficientům uvedeným výše.



Obr.7 a) 20 náhodných realizací LHS, b) $g(x)$ po identifikaci pro různé počty simulací

Zaměříme se na velmi malé počty simulací pro trénování neuronové sítě – 20, 30, 40, 50 a dvě varianty simulace, LHS a Monte Carlo. Podmínky pro učení sítě byly nastaveny shodně – stejné rozptyly parametrů (rovnoměrné rozdělení) při randomizaci, stejná struktura neuronové sítě (počty vrstev, neuronů apod.) a stejná inicializace parametrů při zahájení učení sítě. Množina křivek pro učení sítě je znázorněna pro 20 simulací LHS na obr.7a. Na obr.7b jsou znázorněny funkce $g(x)$ spočtené s identifikovanými parametry koeficientů. Je zřejmé, že se zvyšujícím se počtem simulací se křivky více přimykají tvaru přesnému (pro 50 simulací již prakticky splývají). Abychom kvantifikovali účinnost obou přístupů, nebudeme porovnávat




Obr.8 Srovnání chyb identifikace pro metody LHS a Monte Carlo a různé počty simulací

dosažené hodnoty koeficientů (koeficienty totiž ovlivňují tvar funkce různým způsobem – citlivost je velká vzhledem k silné nelinearitě funkce), ale výstižnost získané funkce poruchy. Zavedeme proto jako objektivní kritérium chyby součet kvadratických odchylek funkce poruchy přesné (původní) a identifikované. Výsledek je zobrazen na obr. 8, je zřejmé, že se projevila větší účinnost metody LHS pro všechny počty simulací. Výrazné je to u velmi malého počtu (20), u 50 simulací je již chyba velmi malá pro obě metody.

Identifikované parametry – koeficienty jsou již velmi blízké přesným hodnotám), nicméně stále výhoda LHS dominuje (chyba 0,5, u Monte Carla je 5,5). Zdůrazněme, že tento výsledek byl získán pro stejnou inicializaci sítě při učení, jiná inicializace může samozřejmě vést k rozdílným výsledkům, avšak vyšší účinnost LHS pro malé počty simulací pro učení neuronové sítě oproti klasické metodě Monte Carlo byla u tohoto příkladu vždy zaznamenána.

5.2 Identifikace materiálových parametrů konstitutivního vztahu pro porušování betonu

Jako ilustrativní příklad identifikace materiálových parametrů byla zvolena stěna testovaná Maierem a Thürlimanem (1985), podrobný popis problému včetně identifikace je publikován Červenkou et al. (2005). Jedná se o pravoúhle vyztužený stěnový panel se ztužujícími žebry, rozměry jsou patrné z obr.6. Jako první bylo aplikováno svislé zatížení $F_v = 1689 \text{ kN}$ simulující stálé zatížení na stěnu. Poté byla postupně aplikována vodorovná síla až do smykového porušení stěny. Během zatěžování se tvořily výrazné diagonální trhliny a při maximálním zatížení docházelo ke ztrátě únosnosti rozdrčením betonu.




Obr.6 Geometrie stěny namáhané smykem a trhliny při numerickém modelování

Numerická analýza byla provedena softwarem ATENA. Pro modelování betonu byl použit konstitutivní model SBETA, pro ocel bilineární pracovní diagram. Identifikovat tedy bylo nutné parametry obou materiálů, celkem jich bylo 10, tab.1. Tyto parametry byly vhodně „randomizovány“ (uvažováno rovnoměrné rozdělení pravděpodobnosti) provedením 20 simulací metodou LHS a získány náhodné realizace l-d diagramů. Po provedení citlivostní analýzy jednotlivých parametrů materiálového modelu bylo zjištěno, že 6 parametrů ($E_c, f_t, f_c, \epsilon_c, x_l$ a f_{x1}) je dominantních (velká citlivost), zbylé pak nedominantní. Proto byly realizovány 2 varianty: Identifikace byla provedena pro všech 10 parametrů; identifikace byla provedena pouze pro 6 dominantních parametrů, zbylé čtyři byly uvažovány střední hodnotou.

Použitá neuronová síť sestává ze 2 skrytých vrstev, z toho první čítá 12 nelineárních neuronů, druhá 10 nelineárních neuronů a výstupní vrstvy s 10 či 6 lineárními neurony (10 či 6 hledaných parametrů). Počet vstupních parametrů sítě je 24 (odpovídá 24 bodům na l-d diagramu). Po naučení sítě a její simulaci s experimentálním zatěžovacím diagramem byly získány identifikované materiálové parametry uvedené v tab.1. Závěrečný numerický výpočet nosníku v softwaru ATENA s již identifikovanými parametry poskytl pro obě alternativy velmi dobrou shodu s experimentálním l-d diagramem, viz obr.7.

Tab.1 Hodnoty identifikovaných parametrů získaných simulací neuronové sítě

Parametr	10 parametrů	6 parametrů
BETON (SBETA model):		
Modul pružnosti E_c [GPa]	33,3	29,9
Pevnost v tahu f_t [MPa]	2,47	2,47
Pevnost v tlaku f_c [MPa]	35,30	34,51
Lomová energie G_F [N/m]	77,85	75,00
Poměr. přetv. v tlaku ε_c [-]	0,00257	0,00251
Max. tlak def. w_d [m]	0,0031	0,0030
VÝZTUŽ (bilineární diag. oceli):		
x_1 [m]	0,00274	0,00272
f_{x1} [kN]	577,7	566,9
x_2 [m]	0,0147	0,0150
f_{x2} [kN]	768,8	764,0



Obr.7 Experimentální a numerická odezva stěny pro jednotlivé varianty identifikace

6. Závěr

Příspěvek popisuje metodiku stanovení parametrů FEM modelu pomocí inverzní analýzy. Parametry výpočtového modelu (např. nepřesně stanovené parametry materiálových modelů) je nutno v případě známé (naměřené) odezvy upřesnit, tak aby numerická FEM simulace odpovídala experimentu. Parametry výpočtového modelu jsou uvažovány jako náhodné veličiny reprezentující možný výskyt parametrů pro identifikaci. S těmito veličinami se provede simulace typu Monte Carlo (LHS) – odezva konstrukce se opakovaně numericky řeší s výpočtovým FEM modelem. Získaný soubor náhodné odezvy konstrukce je poté užít pro učení vhodné neuronové sítě. Naučená síť je pak schopna identifikovat soubor nejvhodnějších parametrů, při jejichž použití je shoda mezi numerickým výpočtem a experimentem co možná nejlepší. Pro učení neuronové sítě se používá stratifikovaná simulace LHS, což redukuje počet nutných analýz problému inverzní analýza na minimum (desítky až stovky), vyšší

účinnost byla ukázána na příkladu 1. Metodiku a vyvinuté softwarové prostředky je možno použít bez větších potíží prakticky pro jakýkoliv problém inverzní analýzy.

7. Poděkování

Práce vznikla díky podpoře v rámci projektu GAČR 103/04/2092.

8. Literatura

- Bernardo, C. & Maincon, P. (2004) Inverse FEM IV: Influence of modeling error. In: *Progress in Structural Engineering, Mechanics and Computation*, Zingoni (ed.), Taylor & Francis Group, London, pp.1031-1035.
- Červenka, V., Novák, D., Lehký, D. & Pukl, R. (2005) Identification of shear wall failure mode. *11th International Conference on Fracture, ICF XI*, Torino, Italy.
- Deix, S. & Geier, R. (2004) Updating FE-models using experimental modal analysis for damage detection and system identification in civil structures. *Third European Conference on Structural Control*, 3ECSC, Vienna University of Technology, Vienna, Austria.
- Fairban, E. M. R., Paz, C. N. M., Ebecken, N. F. F. & Ulm, F. J. (1999) Use of neural networks for fitting of FE probabilistic scaling model parameters. *International Journal of Fracture*, 95, pp.315-324.
- Grigoriu, M. (1982/83) Methods for approximate reliability analysis. *Structural Safety*, 1, pp.155-165.
- Huntington, D.E. & Lyrintzis, C.S. (1998) Improvements to and limitations of Latin hypercube sampling. *Probabilistic Engineering Mechanics*, Vol. 13, No. 4, pp.245-253.
- Iacono, C., Sluys, L. J. & van Mier, J. G. M. (2003) Development of an inverse procedure for parameters estimates of numerical models. In: *Proceedings of the Euro-C conference*, St. Johann im Pongau, Austria, pp.259-268.
- Iman, R.C. & Conover, W.J. (1982) A distribution free approach to inducing rank correlation among input variables. *Communications in Statistics* Vol. B11, pp.311-334.
- Keramat, M. & Kielbasa, R. (1997) Efficient average quality index of estimation of integrated circuits by modified Latin Hypercube Sampling Monte Carlo (MLHSMC). *Proc. of IEEE Symp. on Circuits and Systems*, Hong Kong.
- Kučerová, A., Lepš, M. & Zeman, J. (2004) Soft computing methods for estimation of microplane model parameters. In: *Computational Mechanics Conference, WCCM VI* in conjunction with APCOM'04, Sept. 5-10, Beijing, China, Tsinghua University Press & Springer-Verlag.
- Lehký, D. & Novák, D. (2004) Identification of material model parameters using stochastic training of neural network, *5th International PhD Symposium in Civil Engineering*, Delft, Netherlands, pp.535-542.
- Lehký, D. (2005) *DLNNET – program documentation*. Theory and User's Guides, Brno, (v přípravě).

- Lehký, D. & Novák, D. (2005) Inverse FEM analysis II: Random parameters identification of reinforced concrete frame. *Inženýrská mechanika 2005*, Svratka, Česká republika.
- Link, M. (1999) Updating of analytical models – basic procedures and extensions. *Modal Analysis and Testing*, (J.M.M. Silva and N.M.M. Maia, eds), NATO Science Series, Kluwer Academic Publ.
- Maier, J. & Thürliman, B. (1985) *Bruchversuche an Stahlbetonscheiben*. Institut für Baustatik und Konstruktion ETH Zürich, Bericht Nr.8003-1.
- Maincon, P. (2004) Inverse FEM I: Load and response estimates from measurements. In: *Progress in Structural Engineering, Mechanics and Computation*, Zingoni (ed.), Taylor & Francis Group, London, 2004, pp.967-971.
- Maincon, P. (2004) Inverse FEM II: Dynamic and non-linear problems. In: *Progress in Structural Engineering, Mechanics and Computation*, Zingoni (ed.), Taylor & Francis Group, London, pp.991-995.
- Maree, A. J. & Maincon, P. (2004) Inverse FEM III: Influence of measurement data availability. In: *Progress in Structural Engineering, Mechanics and Computation*, Zingoni (ed.), Taylor & Francis Group, London, 2004, pp.1025-1029.
- Novák, D. et al. (2005) *FReET – program documentation*. User's and Theory Guides. Brno/Červenka Consulting, Prague.
- Novák, D., Lehký, D. & Keršner, Z. (2003) Lomově-mechanické parametry vysokohodnotného betonu: experiment, modelování a identifikace, 2. mez. symposium FC & HPC – Fibre Concrete & High Performance Concrete, Malenovice, pp.67-74.
- Novák, D. & Lehký, D. (2005) Neural network based identification of material model parameters to capture experimental load-deflection curve. *Acta Polytechnica*, Praha, Česká republika (v tisku).
- Novák, D., Rusina, R. & Vořechovský, M. (2003) Small-sample statistical analysis – software FREET. In *9th International Conference on Applications of Statistics and Probability in Civil Engineering (ICASP9)*, San Francisco, USA, Rotterdam Millpress. pp.91-96 .
- Planas, J., Guinea, G. V. & Elices, M. (1999) Size effect and inverse analysis in concrete fracture. *Int. Journal of Fracture*, Vol. 95, Kluwer Academic Publisher, pp.367-378.
- Pukl, R., Červenka, V., Strauss, A., Bergmeister, K. & Novák, D. (2003) An advanced engineering software for probabilistic-based assessment of concrete structures using nonlinear fracture mechanics. *9th Int. Conf. on Applications of Statistics and Probability in Civil Engineering (ICASP9)*, San Francisco, California, USA, pp.1165-1171.
- Strauss, A., Bergmeister, K., Novák, D. & Lehký, D. (2004) Stochastische Parameteridentifikation bei Konstruktionsbeton für die Betonerhaltung. *Beton und Stahlbetonbau*, Vol. 99, No. 12, Vienna, Austria, pp.967-974.
- Strauss A., Lehký, D., Novák, D., Bergmeister, K. & Santa, U. (2004) Probabilistic response identification and monitoring of concrete structures, *Third European Conference on Structural Control*, 3ECSC, Vienna University of Technology, Vienna, Austria.
- Vořechovský, M. & Novák, D. (2003) Statistical correlation in stratified sampling. In *9th Int. Conf. on Applications of Statistics and Probability in Civil Engineering – ICASP 9*, San Francisco, USA, Rotterdam Millpress, pp.119-124.