



OPTIMALIZACE ARCHITEKTURY NEURONOVÝCH SÍTÍ PRO ROZPOZNÁVÁNÍ ZDROJŮ AKUSTICKÉ EMISE

ARCHITECTURE OPTIMIZATION OF ACOUSTIC EMISSION SOURCE RECOGNITION NEURAL NETWORKS

Milan Chlada, Michal Blaháček, Zdeněk Převorovský
Ústav termomechaniky AV ČR

ABSTRAKT

V příspěvku je popsána a diskutována metoda rozpoznávání kombinace tří modelových emisních zdrojů buzených v reálné letecké konstrukci. Při optimalizaci zpětného odhadu jejich poměrného zastoupení ve zdrojové funkci naměřeného a zparametrizovaného signálu akustické emise byly učeny umělé neuronové sítě různých architektur. Následná citlivostní analýza těchto sítí umožnila cílenou redukci vstupů až na minimum parametrů potřebných pro spolehlivý odhad poměrného zastoupení modelových zdrojů v budícím ultrazvukovém pulzu.

ABSTRACT

In the paper, the acoustic emission model source recognition method is described and discussed. Weighted combinations of the three model pulses were excited in aircraft structure. For the original weights estimation, various artificial neural networks were tested. Within the architecture optimization, the sensitivity analysis of trained networks enabled targeted inputs reduction towards the minimal number of parameters needed for reliable model sources apportionment estimation.

1. ÚVOD

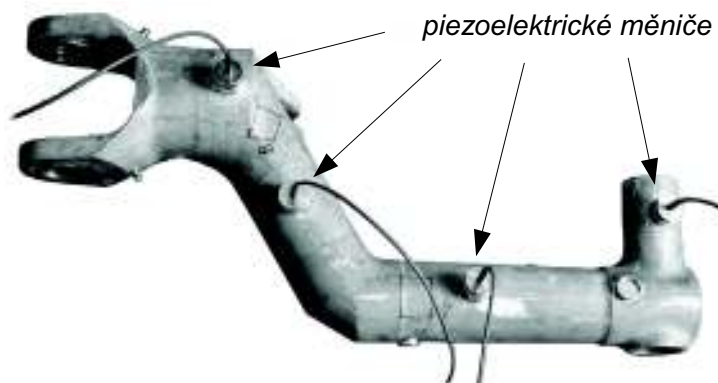
V praxi zaznamenávané signály akustické emise (AE) pocházejí často nejen od různých mechanismů poškození vzorku, ale mohou také vznikat v důsledku nežádoucího akustického rušení. Už jen spolehlivá primární selekce takových záznamů by umožnila věnovat veškerou pozornost emisním zdrojům, které jsou spojeny s destruktivními jevy v testované součásti. Emisní projevy způsobené např. pohybem namáhaného vzorku v upínacích čelistech zatěžovacího zařízení, elektrickým rušením, nebo chybami AD převodníku lze ignorovat a závěry z měření

emisní aktivity tak zvěrohodnit. Vlivem různé cesty od zdroje ke snímačům se zaznamenané události AE od sebe liší, i když pocházejí od identického zdroje. Často také dochází k okamžitému působení více mechanismů vzniku poruch, např. současný růst trhliny a tření jejích hran o sebe. Výše uvedené aspekty proces klasifikace zdrojů AE komplikují a do značné míry ho přesouvají do pravděpodobnostní roviny. Velkým problémem je také získání spolehlivě identifikovaných dat pro účely návrhu jakéhokoliv klasifikátoru. Z těchto důvodů byla navržena metoda rozpoznávání poměrného zastoupení modelových pulsů ve zdrojové funkci emisní události pouze z parametrů numericky generovaných signálů AE na základě umělých neuronových sítí (ANN) [1]. V současnosti je tento přístup testován již na reálné letecké konstrukci, viz níže.

2. POPIS EXPERIMENTU

2.1. Měřicí aparatura

Zkušebním vzorkem pro rozpoznávání modelových zdrojů AE a jejich kombinací byla páka podvozku malého dopravního letadla zhotovená z ušlechtilé ocele (obr.1). Zdroji i snímači AE byla čtveřice piezoelektrických měničů stejného typu. V každém okamžiku byl jeden měnič zapojen jako pulzér (zdroj AE) a ostatní tři jako snímače AE. K buzení pulzérů byl použit generátor libovolných průběhů (arbitrary generator), generující elektrické pulzy požadovaných tvarů a amplitud. Všechny zaznamenané signály AE byly parametrizovány. Jedna část z nich posloužila jako tréninková množina pro učení ANN a druhá vždy sloužila k ověření generalizačních schopností naučených sítí.



Obr.1: Konfigurace měničů AE

Na snímku v obr.1 jsou patrné 4 snímače/budiče signálu AE o průměru 20 mm, integrované s magnetickými podložkami, tvarovanými podle poloměru různých částí trubkovitého tělesa tak, aby byl zaručen celoplošný kontakt epoxidovým tmelem přilepeného měniče s povrchem zkoušeného dílu. Měřicí aparatura AE byla typu PAC μ Disp, schopná při vzorkovací frekvenci 10 MHz zaznamenat 16-bitová data. Délka záznamu byla 15360 vzorků. Aby bylo možné piezoelektrické měniče v průběhu experimentu snadno přepojovat do režimu snímač resp. budič signálu,

byly měniče zapojeny nejdříve do multiplexeru, který umožňoval snadný výběr vysílacího kanálu, a z něj byl teprve signál AE snímačů veden do předzesilovačů PAC (zisk 40 dB) a dále na vstup měřicí aparatury.

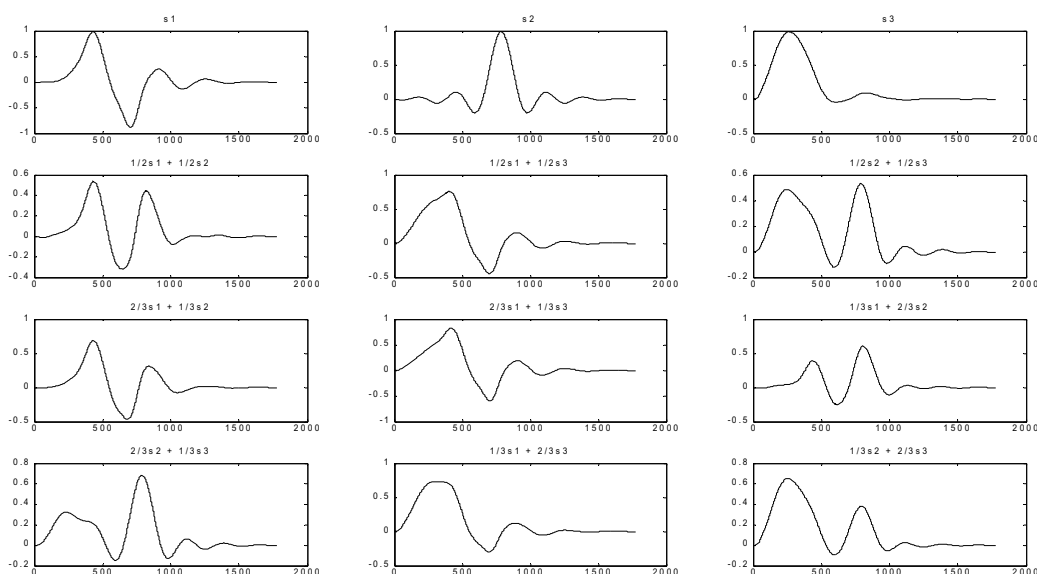
2.2. Generování pulzů

Zdrojové pulzy byly buzeny generátorem libovolných průběhů NI-5421 se 16-bitovým D/A převodníkem a vzorkováním 100MHz. Tři typické zdrojové funkce emisních událostí byly modelovány pulsy s_1 - s_3 , jejichž tvar je znázorněn na obr.2 spolu s jejich lineárními kombinacemi o následujících vahách:

$kombinace = [1\ 0\ 0 ; 0\ 1\ 0 ; 0\ 0\ 1 ; 1/2\ 1/2\ 0 ; 1/2\ 0\ 1/2 ; 0\ 1/2\ 1/2 ;$

$2/3\ 1/3\ 0 ; 2/3\ 0\ 1/3 ; 1/3\ 2/3\ 0 ; 0\ 2/3\ 1/3 ; 1/3\ 0\ 2/3 ; 0\ 1/3\ 2/3]$

Tímto způsobem bylo tedy v každé konfiguraci nakombinováno 12 výsledných zdrojových funkcí, které byly před použitím normalizovány tak, aby se jejich energie nelišily. Volba počtu vzorků ($N=1779$) zaručuje, že spektrum budících signálů vykazuje maximum v oblasti největší citlivosti použitých AE měničů, t.j. 80–300kHz. Kromě tvaru budících pulzů byly během měření měněny také jejich amplitudy pomocí regulace zesilovače generátoru NI-5421. Maximální výstupní napětí generátoru tak postupně dosahovalo hodnot 0.6, 2.4, 3, 3.6 a 6 V.



Obr.2: Kombinace zdrojových pulzů

2.3. Parametrizace signálů

Po záznamu jedním budičem generovaných signálů pomocí odpovídajících měničů v režimu snímač byly pro všechny příslušné kanály počítány následující klasické parametry v časové a frekvenční oblasti:

- *časová oblast:*
(1) Amplituda, (2) Doba nárůstu do maxima (Rise time), (3) Efektivní hodnota (RMS), (4) Moment energie, (5) ASL, (6-8) Centrální momenty vyšších řádů, konkrétně deviace, asymetrie a exces
- *spektrální parametry:*
(9-13) parametry výkonové spektrální hustoty $f(\omega)$:

$$P_X = 100 \cdot \frac{\int_X f(\omega) d\omega}{\int_G f(\omega) d\omega}, \quad X \in \{A, B, C, D, E\}; \quad RCG = \frac{\int_0^{\omega_N} \omega \cdot f(\omega) d\omega}{\omega_N \cdot \int_0^{\omega_N} f(\omega) d\omega}$$

kde frekvenční pásma X , vztažená k Nyquistově frekvenci ω_N , byla volena následovně:

A: $(0-0.03) \cdot \omega_N$; B: $(0.03-0.05) \cdot \omega_N$; C: $(0.05-0.1) \cdot \omega_N$; D: $(0.1-0.2) \cdot \omega_N$; E: $(0.2-0.5) \cdot \omega_N$.
Parametr (14), tedy RCG, je frekvence odpovídající těžišti výkonové spektrální hustoty.

3. NEURONOVÉ SÍTĚ

3.1. Učení

Pro řešení klasifikačního problému se již dříve osvědčily umělé neuronové sítě se dvěma skrytými vrstvami neuronů se sigmoidálními přenosovými funkcemi. Inicializační váhy a prahy neuronů byly nastaveny statistickou optimalizací startovních potenciálů neuronů a během učení dále iteračně adaptovány pomocí rychlé resilientní varianty učicího algoritmu zpětného šíření s momentem a generalizaci zlepšující regularizací.

Počet neuronů ve vstupní vrstvě je dán počtem vstupních parametrů, což bylo v našem případě 42 (použita data ze tří snímačů), nebo 14 (použita data pouze z jednoho snímače). Počet neuronů ve výstupní vrstvě je určen počtem požadovaných výstupů. Jelikož měly neuronové sítě odhadovat původní koeficienty kombinace tří modelových pulsů, ve výstupních vrstvách byly neurony tři. Počet skrytých vrstev spolu s počtem neuronů v nich je nutné volit podle složitosti řešené úlohy. Protože dosud neexistuje analytický odhad minimální architektury, která by zaručila konvergenci sítě pro konkrétní učicí data, je vhodné volit nejprve poněkud přemrštěné počty neuronů a v případě úspěšné minimalizace tréninkové chyby architekturu postupně zmenšovat. V opačném případě, kdyby počty neuronů zůstávaly příliš vysoké, hrozí "přeučení" a tudíž špatná generalizace sítě. Jak vyplynulo z mnoha experimentů při učení různých verzí sítí (viz kap.3.3), ani jinak velmi účinná regularizace nezabrání riziku špatné generalizace tak, jako v rámci zaručení konvergence co největší minimalizace architektury.

Pro zaručení správné vybavovací funkce sítě je třeba dostatečně jemně "ovzorkovat" oblast možných vstupů a výstupů tréninkovými daty, mezi kterými nemá učená závislost nepředpokladatelný vývoj. V rámci výše popisovaného experimentu bylo kvůli zajištění dostatečně úspěšné generalizace nutné volit tréninková a testovací data jako parametry signálů z jednoho, či více snímačů, buzených vždy jedním

vybraným vysílačem (t.j. snímačem v režimu budič). Do něj přicházelo všech dvanáct nakombinovaných pulsů, zesílených na různé amplitudy:

tréninková data: 0.6V ; 3V ; 6V

testovací data: 2.4V ; 3.6V

Pokud byla učicí data více zúžena, přesnost sítí při vybavování značně klesala, což poukazuje zřejmě na relativně vyšší složitost problému. Jinak řečeno, testovací data nelze jednoduše "interpolovat" na základě sousedních tréninkových. Dobrá konvergence sítí ale umožňuje rozšíření tréninkové množiny o tato data, tudíž postihnout problém mnohem detailněji a rozšířit použitelnost klasifikátoru i na rozpoznávání zdrojů vzniklých kombinacemi mimo tréninkovou množinu. To ovšem předpokládá plnou automatizaci experimentu, která v době jeho provádění nebyla ještě k dispozici.

3.2. Citlivostní analýza

Citlivostní analýza je nástroj pro identifikaci vstupů vrstevnatých ANN, které ovlivňují hodnoty výstupů sítě největší měrou. V praxi se nejlépe osvědčila alternativní metoda volby parametrů AFSSM (Alternative Feature Subset Selection Method) [2]. Podstatou AFSSM je výpočet tzv. citlivostních koeficientů $s_{j,i}$ na základě parciálních derivací jednotlivých výstupů sítě podle všech vstupů pro vybranou množinu bodů, kterou mohou být tréninková, testovací, či jiná data:

$$s_{j,i} = \frac{1}{P} \sum_{p=1}^P \left| \frac{\partial y_{p,j}}{\partial x_{p,i}} \right| \quad \begin{array}{l} \text{kde } y_j - \text{výstupy sítě, } x_i - \text{vstupy sítě,} \\ p - \text{index příslušného bodu uvažované množiny.} \end{array}$$

Z obecných vlastností parciálních derivací a neuronových sítí je zřejmé, že pro danou aproximovanou souvislost je podstatná část vstupní informace skrytá v parametrech s nejvyššími hodnotami $s_{j,i}$. Vstupní parametry, které nejvýznamněji ovlivňují výstupy sítě, mají odpovídající parciální derivace podstatně vyšší, než parametry představující spíše informační šum. Díky použití metody AFSSM lze nalézt takové parametry AE signálu (viz následující kapitola), které jsou v tomto modelovém případě nejvýznamnější pro rozpoznávání různých emisních zdrojů.

3.3. Optimalizace architektury ANN

Ve výchozí fázi optimalizace architektury ANN byly využívány parametry signálů ze všech snímačů. Počty neuronů v jednotlivých vrstvách dosahovaly čísel až 42 - 50 - 30 - 3, což zaručilo rychlou konvergenci učicí chyby (aktuální průměr sumy kvadrátů chyb sítě na jejích výstupních neuronech pro učicí data) až na relativně nízkou hodnotu 0.017, ale i přes probíhající regularizaci se pro více případů startovacích vah podařilo dosáhnout testovací chyby (t.j. průměru sumy kvadrátů odchylek skutečných výstupů sítě od správných výstupních hodnot testovacích dat) minimálně 0.047. Citlivostní schéma (t.j. tabulka citlivostních koeficientů) neukazovalo na přeučení sítě, jeho koeficienty byly poměrně malé. Pro velké architektury bylo značně proměnlivé a tudíž hůře fyzikálně interpretovatelné. Klasifikace překvapivě závisela spíše na energetických parametrech a době nárůstu. V případě dat z buzení pulsů vysílačem č.4 se postupnou redukcí počtů neuronů

ve skrytých vrstvách až na architekturu 42 - 5 - 4- 3 a zesílenou regularizací dále podařilo zlepšit generalizační (testovací) chybu na hodnotu 0.00195, při učicí chybě 0.00019. Citlivostní koeficienty se stabilizovaly a pro všechny snímače naznačovaly evidentní závislost odhadů vah kombinací zdrojů spíše na vyšších spektrálních parametrech. Citlivostní schéma bylo pro skupinu parametrů příslušející konkrétnímu senzoru velmi podobné případu ostatních snímačů, což opodstatnilo hypotézu, podle které jako vstupy sítě postačuje uvažovat parametry signálů pouze z jediného vybraného snímače, v některých případech volby budičů ne nezbytně nejbližšího k vysílači. V dalším kroku minimalizace architektury byly tedy učeny sítě již jen s 12-ti vstupy.

Postupnou optimalizací počtů neuronů až na verzi 12 - 17 - 5 - 3 byl zachován dobrý učicí potenciál sítě a stabilní citlivostní schéma (viz tab.1 - v podstatě shodná s případem 42 - 5 - 4- 3 zúženým pro jeden snímač). Generalizační chyba, při učicí o hodnotě 0.00081, byla 0.0035.

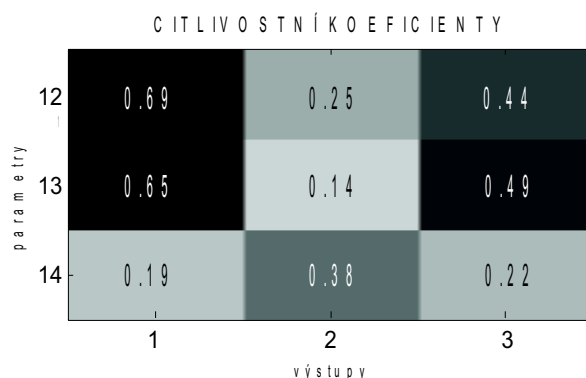
CITLIVOSTNÍ KOEFICIENTY

1	0.04	0.03	0.07
2	0.12	0.11	0.14
3	0.04	0.02	0.05
4	0.28	0.11	0.14
5	0.04	0.03	0.04
6	0.08	0.06	0.13
7	0.17	0.03	0.05
8	0.07	0.02	0.03
9	0.05	0.07	0.09
10	0.05	0.04	0.04
11	0.13	0.23	0.09
12	0.70	0.21	0.50
13	0.66	0.17	0.49
14	0.12	0.19	0.07
	1	2	3

výstupy


Tab.1: Citlivostní schéma verze 12-17-5-3

Z tab.1 je patrné, že odhad původní kombinace modelových zdrojů nejvíce ovlivňují parametry č. 12 a 13, méně pak 4, 11 a 14. Ostatní nesou spíše informační šum. Proto lze v redukci architektury úspěšně pokračovat. Z fyzikálních důvodů byly pro další testování vybrány pouze parametry 12, 13 a 14. Celkový počet neuronů sítě ovšem nemůže klesnout pod hranici teoreticky zaručující konvergenci učicí chyby, což je patrné z postupného nárůstu minima neuronů ve skrytých vrstvách oproti úspěšné architektuře 42 - 5 - 4- 3, redukováme-li architekturu v rámci zachování generalizace až na 3 - 17 - 5- 3.



Tab.2: Citlivostní schéma verze 3-17-5-3

Citlivostní schéma (tab.2) potvrzuje oprávněnost vynechání parametrů kromě výše uvedených, přičemž významné závislosti výstupů sítě na příslušných vstupech 12 a 13 zůstávají zachovány. Parametry procentuálního zastoupení frekvencí nejvyšších pásem D a E v signálu AE nesou převážnou část informace o poměrném zastoupení pulsů ve zdrojové funkci. Finálním výsledkem postupně prováděné redukce počtu neuronů může být tedy verze pouze se třemi vstupy. V souladu s teoretickými předpoklady se generalizační chyba po eliminaci šumové informace v podstatě nezměnila, dokonce byly učením nalezeny úspěšnější konfigurace vah a prahů sítě. Učící, resp. testovací chyby nejlepší verze dosáhly hodnot 0.0031, resp. 0.0033.



Obr.3: Histogram absolutních odchylek výstupů sítě verze 3-17-5-3

Odchytky výstupů naučené ANN od skutečných hodnot kombinace zdrojové funkce jsou vyneseny do histogramu na obr.3. Je zřejmé, že absolutní chyba v určení vah,

odpovídajících třem základním typům budících pulsů, je na každém výstupním neuronu ve dvou případech z celkového počtu 24 větší než 0.1 (tedy v 8% případů). Většinou je ale podstatně menší, což k určení převažujícího typu emisního zdroje plně postačuje.

4. ZÁVĚRY

Poznatky získané při optimalizaci architektury ANN pro rozpoznávání modelových zdrojů AE buzených v části letecké konstrukce lze shrnout do následujících bodů:

- V souladu s dřívějšími numerickými modely lze ANN i v praxi úspěšně použít jako klasifikátory zdrojů AE.
- Důležitým předpokladem pro přesnější generalizaci je dostatečné množství tréninkových dat.
- V popisovaném případě postačí jako vstupy charakteristiky signálů pouze z jednoho snímače.
- Ze 14 signálových parametrů určila citlivostní analýza jako nejvýznamnější poměrné zastoupení vyšších frekvenčních pásem ve spektrech signálů AE.
- Regularizace nezaručuje dobré generalizační vlastnosti sítí s extrémně velkou architekturou. Redukce počtů neuronů ve skrytých vrstvách se ukázala jako nezbytná.
- Výsledky citlivostní analýzy ANN s nižšími generalizačními chybami jsou lépe fyzikálně interpretovatelné a směrodatnější.

Poděkování

Práce byla podporována z prostředků grantového projektu GAČR č.101/07/1518 a z projektu MPO ČR č. FT-TA/026-T9.

Literatura

- [1] Chlada M., Převorovský Z., Mrázová I.: *Selection of signal parameters for analysis of AE Sources*. (31st Internat. Conf. on NDT "DEFEKTOSKOPIE 2001", Prague, 20-22 Novemeber 2001, Proc. ed. by P.Mazal, CNDT 2001, pp.317-327).
- [2] Fidalgo J. N.: *Feature Subset Selection Based on ANN Sensitivity Analysis – a Practical Study*, in: N. Mastorakis, ed.: *Advances in Neural Networks and Applications*, WSES Press, pp. 206-211, 2001