

ČESKÉ VYSOKÉ UČENÍ TECHNICKÉ V PRAZE

Fakulta jaderná a fyzikálně inženýrská

Katedra matematiky

DISERTAČNÍ PRÁCE

Zpracování signálů akustické emise
pomocí umělých neuronových sítí

Praha 2008

Milan Chlada

Název práce: **Zpracování signálů akustické emise pomocí umělých neuronových sítí**
Autor: Milan Chlada
Obor: Matematické inženýrství
Druh práce: Disertační práce
Vedoucí práce: Ing. Zdeněk Převorovský, CSc., Ústav termomechaniky AVČR, v.v.i.

Abstrakt

V práci jsou navrženy a diskutovány nové přístupy k analýze signálů akustické emise (AE), založené především na umělých neuronových sítích. Rozpracovány jsou zejména algoritmy pro identifikaci emisních zdrojů na základě nově zavedených parametrů signálů, jejichž začátky jsou detekovány původní, plně automatizovanou a robustní metodou. K optimalizaci počtu a typu parametrů je využívána faktorová analýza poskytující lineární hypotézu struktury dat. Pro lokalizaci emisních zdrojů bez znalosti časových diferencí byl navržen a úspěšně aplikován postup vycházející ze standardních parametrů AE, jako je např. RMS nebo amplituda. Úplné řešení inverzní úlohy o emisním zdroji je pro modelové i reálné podmínky zjednodušeno na inverzi signálových parametrů. Parametry emisních signálů z různých míst jsou přepočítávány na jednu referenční polohu v blízkosti vybraného snímače. Finálním a jedním z nejobtížnějších kroků analýzy záznamů AE je identifikace emisních zdrojů. Navržená klasifikační metodologie byla odzkoušena postupně v teoretických modelech rozpoznávání umělých zdrojových funkcí až po případ selekce dvou typů emisních zdrojů v reálné letecké konstrukci. Jádrem většiny navržených metod jsou umělé neuronové sítě a proto je podstatná část práce věnována zlepšování jejich vlastností, jako je rychlost učení a schopnost generalizace, a optimalizaci architektury na základě citlivostní analýzy.

Klíčová slova: akustická emise, lokalizace a klasifikace emisních zdrojů, umělé neuronové sítě.

Title: **Acoustic Emission Signal Processing by Means of Artificial Neural Networks**
Author: Milan Chlada

Abstract

In the thesis, the new approaches to acoustic emission (AE) signal analysis, mainly based on artificial neural networks are designed and discussed. Especially, the AE source identification procedures based on the new AE signal parameters are developed. The signal arrival times are more reliably determined using innovative fully automated and rugged expert method. The factor analysis, providing linear hypothesis of data structure is used for optimizing types and number of AE parameters. New AE source location method is proposed, exploiting only the standard AE signal features as e.g. RMS or amplitude, so that the computation of arrival time differences is not necessary. Inverse problem solution concerning both, model and real AE sources is simplified by the correction of the most important signal parameters with respect to the mutual source and sensor location. The final and one of the most difficult steps in AE analysis is the AE source identification. A new AE source classification and recognition methodology is designed and tested on model data with artificial source functions, and also on real AE data from the aircraft structure parts. The most of proposed methods are based on artificial neural networks. Substantial part of the thesis deals with improvement of their properties like the learning speed and generalization capability. The architecture of used artificial neural networks is optimized by sensitivity analysis.

Key words: acoustic emission, AE source location and classification, artificial neural networks.

Poděkování

Rád bych na tomto místě poděkoval všem, kteří byli inspirací k této práci. Svému školiteli Ing. Zdeňku Převorovskému, CSc za cenné podněty a ideje, jimiž dal směr mému výzkumu, spolu s vřelou ochotou a trpělivostí při konzultacích řešených problémů.

Kolegům a spolupracovníkům z Ústavu termomechaniky AVČR, v.v.i., kteří vytvořili příjemnou a přátelskou atmosféru na pracovišti.

Doc. RNDr. Ivetě Mrázové, CSc. (MFF UK) za významné rady a náměty při studiu umělých neuronových sítí.

V neposlední řadě pak děkuji své rodině, bez jejíž podpory a schovívavosti by tato práce nemohla být dokončena.

V Benešově 28.9.2008.

OBSAH

1. Úvod	9
2. Akustická emise	13
3. Expertní detekce začátku signálu AE	17
3.1 Vlastnosti algoritmu	17
3.2 Popis algoritmu	19
3.3 Další verze algoritmu	26
3.4 Testování algoritmu a nastavení parametrů	27
4. Parametrizace signálů AE	33
4.1 Cíle parametrizace	33
4.2 Definice parametrů	34
5. Faktorová analýza	37
5.1 Model faktorové analýzy	37
5.2 Modifikovaná metoda hlavních os (hlavních komponent)	39
5.3 Problém počtu faktorů	40
5.4 Rotace faktorů	41
5.5 Výpočet faktorových skóre	43
5.6 Rozlišení technik FA	43
5.7 Praktický příklad FA parametrů reálných signálů AE	43
6. Neuronové sítě	47
6.1 Jednoduchý perceptron a neuron	47
6.2 Vrstevnaté neuronové sítě	48
6.3 Aproximační vlastnosti vrstevnatých sítí	51
6.4 Učení vrstevnatých sítí	51
6.5 Maticová interpretace operací uvnitř sítě	54
6.6 Zrychlení adaptace vah	55
6.7 Volba tréninkových dat	56
6.8 Problém přeučení a zlepšení generalizace	57
6.9 Vážený gradient	59
6.10 Volba počátečních vah	59
6.11 Citlivostní analýza	62
7. Mapování obecných závislostí pomocí BP-sítí	65
7.1 Nový přístup k citlivostní analýze	65
7.2 Demonstrace metody na modelových datech	66

8. Lokalizace zdrojů AE pomocí ANN	71
8.1 Nová metoda lokalizace zdrojů AE	71
8.2 Popis experimentu	71
8.3 Numerické experimenty	73
8.4 Lokalizace na základě časových diferencí	74
8.5 Shrnutí výsledků	75
9. Korekce emisních parametrů na polohu zdroje AE	77
9.1 Problém inverzní úlohy o emisním zdroji	77
9.2 Numerický model šíření elastických vln	78
9.3 Model s experimentálně naměřenou Greenovou funkcí	84
9.4 Korekce emisních parametrů na reálné konstrukci	87
9.5 Možnosti korekce emisních parametrů na polohu zdroje AE.	88
10. Rozpoznávání zdrojů akustické emise	89
10.1 Problematika identifikace emisních zdrojů	89
10.2 Model s experimentálně naměřenou Greenovou funkcí	89
10.3 Rozpoznávání modelových pulzů v reálných konstrukcích	91
10.4 Identifikace emisních zdrojů v letecké součásti	99
Reference	103
Seznam publikací	105

1. ÚVOD

Náročné požadavky na spolehlivost a bezpečnost technických konstrukcí nelze splnit bez použití efektivních prostředků defektoskopické kontroly a průběžného monitorování jejich stavu. V disertační práci jsou rozebírány nové možnosti k tomuto účelu zvláště vhodné progresivní ultrazvukové NDT/NDE metody - akustické emise (AE). Tato metoda může oproti klasickým podstatně zefektivnit nedestruktivní kontrolu, neboť je schopna detekovat defekty v konstrukci "na dálku" a nevyžaduje tedy např. demontáž částí konstrukce. Její nevýhodou je zatím relativně složitější interpretace výsledků a proto je stále nutná jejich vhodná kombinace s tradičními metodami.

Aplikace AE v praxi vyžaduje nové přístupy k lokalizaci a klasifikaci emisních zdrojů, využívající prvky umělé inteligence, kterými mohou být umělé neuronové sítě (ANN-Artificial Neural Networks). Perspektivy využití těchto metod jsou dány zejména jejich vysokou citlivostí při detekci zárodečných defektů v materiálu. Nově navržené metodiky detekce počátku signálu AE spolu s lokalizací a klasifikací poruch pomocí ANN přinášejí velké množství dalších informací o stavu sledovaných konstrukcí. Praktické využití diskutovaných metod je ilustrováno na únavově namáhaných leteckých součástech.

K úspěšné aplikaci AE diagnostiky je zapotřebí řešit více okruhů problémů spojených s monitorováním AE. První se týká detekce počátků emisních událostí a parametrizace signálů AE. Do druhého lze zahrnout lokalizaci poruch spolu s korekcí parametrů AE na vzájemnou polohu mezi snímačem a emisním zdrojem. Finální etapou analýzy zaznamenaných dat je posléze klasifikace emisních zdrojů.

Po zachycení signálu AE je stěžejním úkolem dostatečně přesná lokalizace zdroje. Většinou se k tomuto používají časové diference příchodu signálu k jednotlivým snímačům. Při průchodu tělesem dochází ke značnému zkreslení signálu a nepřesná detekce začátku (prvního nasazení signálu), resp. určení časových diferencí, je tak zdrojem největších chyb. Přestože existuje mnoho přístupů k detekci prvního nasazení, v častých případech se tyto metody příliš neosvědčují. Pro zpracovávání rozsáhlých souborů signálů AE tak bylo nezbytné navrhnout zcela nový algoritmus (viz kap. 3). U jednodušších postupů, jako je např. prahová detekce, je při měnící se emisní aktivitě často nutné opakovaně nastavovat vstupní parametry (prahové úrovně) i vícekrát v rámci jednoho měření, např. i s ohledem na různé vlastnosti jednotlivých kanálů měřící aparatury.

Nový algoritmus detekce začátku signálu byl navržen pro potřeby rychlého a dostatečně spolehlivého zpracování záznamů, které mají složitý tvar, respektují různě vysoké hladiny šumu a mohou být i neúplné nebo částečně poškozené opožděným spouštěním nebo jinými chybami A/D převodníku, či mechanickým nebo elektrickým rušením apod. Tento algoritmus má jako jediný vstup navzorkovaný záznam emisního signálu a je založen na modelování expertní detekce prvního nasazení - podobně jako posuzuje začátek emisní události na obrazovce osciloskopu např. vyškolený "expert". Počátek signálu emisní události je určován na základě vývoje pomocného vektoru absolutních lokálních těžišť a energie signálu. Nová metoda se vyznačuje velkou robustností a není citlivá ani na chyby A/D převodu či elektrické poruchy. Parametry algoritmu jsou optimalizovány při předběžném zpracování náhodně vybraného souboru dat. Počátek emisní události lze takto určit s řádově vyšší přesností, než tomu bylo u doposud používaných postupů. V případech, kdy

je záznam signálu neúplný (chybí začátek) nebo při vyšších hladinách šumu, je čas prvního nasazení rekonstruován pomocí lineární extrapolace.

Dostatečně přesná znalost polohy zdroje akustické emise je základním požadavkem pro další charakterizaci mechanismu poruchy. Poloha zdroje se většinou určuje na základě časových diferencí příchodu emisního signálu k několika různým snímačům. Přesnost lokalizace je pak závislá na správném určení času příchodu, které je v případech vysoké hladiny šumu často problematické. Proto byla navržena nová lokalizační metoda na bázi umělých neuronových sítí, které místo časových diferencí zpracovávají odvozené parametry signálu, nezávislé na okamžiku registrace elastické vlny (kap. 8). Numerické simulace i experimenty na různých geometricky složitých dílech prokázaly, že navržená metoda je vhodná i pro velmi komplikované letecké konstrukce, složené z dílů s odlišnými rychlostmi šíření elastických vln. Dosažená přesnost lokalizace emisních zdrojů je přitom srovnatelná s klasickými metodami na bázi časových diferencí. Při vyšších hladinách rušivého šumu je nová metoda ještě mnohonásobně přesnější a dává uspokojivé výsledky i v případech, kdy časové difference nelze ani spolehlivě určit.

Správný výběr vhodných signálových parametrů AE z časové, frekvenční či časo-frekvenční oblasti je důležitý pro "inverzní analýzu" signálu AE, která umožňuje rozpoznání vlastního mechanismu emisního zdroje. Jednu z možností, jak zcela automaticky rozpoznávat a klasifikovat zdroje AE, nabízí opět využití ANN, jako prvku umělé inteligence. Závažným problémem je zde ale právě volba signálových parametrů (kap. 4), které slouží jako vstupy do klasifikační ANN. Podstatné parametry je třeba oddělit od nevýznamných a tak zjednodušit architekturu ANN klasifikátoru. Lineární závislosti mezi různými parametry vnášejí do analýzy zdrojů jistou redundanci, ale lze je snadno odhalit pomocí faktorové analýzy (viz kap. 5), která poskytuje předběžnou hypotézu ve formě korelačního schématu mezi parametry a latentními veličinami, zvanými faktory. Umožňuje tak následnou eliminaci triviálních lineárních závislostí mezi charakteristikami signálu a soustředit tak pozornost jen na parametry vzájemně lineárně nezávislé.

Další možností jak vyloučit pro klasifikaci nevýznamné parametry je nově navržený postup, který mapuje obecné závislosti a dokáže odhalit i komplikované nelineární vztahy mezi jednotlivými parametry (kap. 7). Doposud známé metody (např. nelineární regrese apod.) předpokládají apriorní znalost typu závislosti a odhadují pouze její parametry. Citlivostní analýzou speciálních sítí, naučených odhadovat jednotlivé parametry na základě zbývajících, lze mapovat i obecné vzájemné souvislosti v datech. Výsledky této metody jsou diskutovány na příkladech detekce funkčních závislostí na šumovém pozadí.

Redukcí množství parametrů je možné dospět k lepším, tzn. rychlejším a spolehlivějším expertním systémům na bázi ANN. Spolu s faktorovou analýzou byla k redukci využita také alternativní metoda volby parametrů metodou AFSSM (Alternative Feature Subset Selection Method - viz kap. 6.11), z níž vychází výše zmiňovaná analýza obecných závislostí a pomocí které lze eliminovat vstupní parametry, pro řešení konkrétního problému nevýznamné. To přineslo podstatné zrychlení algoritmu ANN a vedlo i k lepším a konzistentnějším výsledkům díky lepším generalizačním schopnostem sítě.

Při šíření elastických vln v materiálu dochází ke značnému zkreslení signálu AE. Lze proto očekávat odlišnou odezvu téhož emisního zdroje, naměřenou v různých místech tělesa. Vlivem disperze, útlumu a četných odrazů se tak mohou vypočtené parametry signálu značně lišit, přestože jde o signály z téhož zdroje. Pro spolehlivější diagnostické rozhodování je proto zapotřebí získat srovnatelnější informace. Jelikož úplné řešení inverzní úlohy o emisním zdroji je v reálných podmínkách prakticky nemožné, můžeme tento problém značně zjednodušit na inverzi signálových parametrů (kap. 9). Jedná se o přepočtení jednotlivých parametrů naměřených signálů z různých míst na jednu referenční polohu

zdroje, který je v blízkosti vybraného snímače. Dosavadní výsledky numerických experimentů s řešením inverzní úlohy tohoto typu pomocí neuronových sítí jsou nadějně pro použití této korekční metody v praxi.

Předchozí popisované metody představují přípravnou fázi zpracování signálů AE před klasifikací emisních zdrojů. Jejím úkolem je rozpoznávání nebezpečných defektů v reálných materiálech. Většina dosud realizovaných pokusů o rozpoznávání emisních zdrojů se týká velmi jednoduchých konfigurací. Navržené klasifikátory (kap. 10) proto směřují blíže k praxi. Jejich jádrem je vrstevnatá neuronová síť. Z důvodu obtížného získávání vhodných tréninkových dat ve skutečných materiálech byla tato síť v prvním přiblížení učena na přiřazování signálů ke třem typům poškození vzorků kompozitů s typickými vadami. Zde se aplikace neuronových sítí ukázala jako přínosná. Pro ověření vlastností tohoto systému byl postaven numerický model šíření ultrazvukových pulsů různého tvaru v ocelové desce s použitím experimentálně naměřené přenosové funkce. Neuronová síť zde s relativně velkou přesností aproximovala koeficienty kombinace pulsů, ze kterých byl následně numericky vygenerován výsledný signál, jehož parametry sloužily jako vstupní veličiny. Projevila se ale nežádoucí citlivost na změnu polohy buzení. Z toho vyplynul výše zmiňovaný požadavek na vhodnější parametrizaci signálu, potlačující závislost na vlastní lokalizaci zdroje a také nutnost přepočtu těchto parametrů do blízkého okolí snímače.

Dalším krokem blíže k praxi je rozpoznávání modelových zdrojů AE a jejich kombinací buzených na páce podvozku malého dopravního letadla. Neuronové sítě byly opět učeny odhadovat váhy kombinací jednotlivých modelových pulsů. Pro maximální výstupní napětí generátoru mimo tréninkovou množinu došlo k poklesu přesnosti sítí při vybavování, způsobeném zřejmě relativně vyšší složitostí problému. Dobrá konvergence sítí ale umožňuje rozšíření tréninkové množiny o zdroje vzniklé kombinacemi s větší variabilitou, což ovšem předpokládá budoucí plnou automatizaci experimentu. V souladu s dřívějšími numerickými modely byly ANN úspěšně aplikovány i jako primární klasifikátory zdrojů AE v praxi. Konkrétně za účelem separace signálů pocházejících od mechanického rušení a samotných mechanismů poškození uvnitř materiálu.

Jak je patrné z předešlého, neuronové sítě nacházejí široké uplatnění v oblasti zpracování signálů AE. Podstatná část práce (kap. 6) je proto věnována zlepšování jejich vlastností, zejména rychlosti učení a schopnosti generalizace. V programovém prostředí Matlab je k dispozici knihovna funkcí (toolbox) s implementovanými algoritmy jak pro inicializaci, tak pro učení i aplikaci nejrozšířenějších typů neuronových sítí. Při použití dané knihovny se v případě vrstevnatých bp-sítí zřetelně ukázaly určité nedostatky některých procedur. Jedná se především o nevhodné nastavování počátečních vah s tendencemi k následnému přeučení sítě a implementaci jednotlivých učících metod s omezenou možností jejich vzájemné kombinace.

Již samotnou volbou počátečních vah lze dosáhnout významně lepších výsledků. V posledních letech se pro inicializaci sítě objevily různé metody, odvozující míru rozptylu vah pomocí Cauchyho nerovnosti, či využívající pravděpodobnostní odhady na základě centrálního limitního teorému. Nově navržený postup (kap. 6.10) používá statistické odhady parametrů rozdělení konkrétního souboru tréninkových dat.

Některé metody, jako je citlivostní analýza apod., nejsou v daném Neural Networks Toolboxu dosud k dispozici. Z těchto důvodů byly všechny potřebné algoritmy naprogramovány odděleně a představují samostatný soubor m-funkcí s dílčími inovacemi oproti části knihovny "Neural Network Toolbox". Mezi nově vytvořené procedury patří např. již zmiňovaná volba počátečních vah, dále pak procedura učení s možností současné realizace resilientní varianty algoritmu back-propagation, momentového učení a regularizace spolu s vážením gradientu podle aktuálního vývoje chyby na tréninkových

datech (kap. 6.9). V neposlední řadě byla také naprogramována citlivostní analýza naučené sítě. Použitím těchto metod se podařilo výrazně potlačit nežádoucí efekty přeučení, sítě podstatně lépe generalizují a výsledky následné citlivostní analýzy lze tedy považovat za směrodatnější.

Práce je zaměřena především na praktické aplikace. V několika kapitolách se přiměřeně omezuje na stručný výklad teoretických poznatků, které jsou bezprostředně aplikovány nebo nově rozvíjeny. Nemá za cíl seznamovat čtenáře se základy faktorové analýzy a teorie umělých neuronových sítí, které jsou velmi přehledně zpracovány v odkazované literatuře.

Reálná data AE, na nichž bylo možné prakticky ověřit rozpracované metodiky lokalizace, korekce parametrů i rozpoznávání emisních zdrojů byla získána při experimentech v Ústavu termomechaniky a během únavových zkoušek cyklicky zatěžovaných leteckých součástí ve VZLÚ.

2. AKUSTICKÁ EMISE

Akustickou emisí (AE) rozumíme elastické vlny (v akustické či ultrazvukové oblasti frekvencí) vznikající následkem náhlého uvolnění energie v materiálu důsledkem lokální, dynamické a nevratné změny jeho struktury [1]. K těmto změnám vede deformace anebo porušení strukturní integrity pevné látky. Vznik akustické emise v materiálu je vázán na lokálně dynamické procesy, při nichž deformovaná oblast přechází do rovnovážného stavu. Tento přechod má impulzní charakter a lze jej popsat vyzařovacím diagramem pro různé typy napěťových vln. Pulsní uvolnění energie je charakterizováno jako emisní událost (EU), která se v detekovaném signálu konvenčně vymezuje pomocí okamžiku překročení určité prahové úrovně a tzv. mrtvé doby, po kterou tato prahová úroveň překročena není.

AE doprovází celou řadu jevů, jako jsou zemětřesení, laviny, sesuvy půdy, důlní otřesy a v neposlední řadě šíření trhlin v materiálech. Z uvedeného výčtu je zřejmé, že AE nachází celou řadu praktických aplikací, od geofyziky a geologie, přes defektoskopii a kontrolu kvality až k materiálovému výzkumu.

Vlny, jejichž zdrojem je rostoucí defekt v materiálu konstrukce, se po dosažení povrchu tělesa transformují na povrchové vlny, kde jsou piezoelektrickým snímačem převedeny na elektrický, tzv. emisní signál, který je možné detekovat jako signály AE na značnou vzdálenost od vysílacího zdroje. Při použití vícekanálové detekční aparatury lze takový zdroj s dostatečnou přesností také okamžitě lokalizovat. Na základě lokalizace aktivních zdrojů lze pak následnou defektoskopickou kontrolu aplikovat pouze v oblastech, kde se takové zdroje vyskytují, resp. zavčas informovat obsluhu sledovaného zařízení o přítomnosti nebezpečného defektu.

Parametry signálů AE obsahují informace o procesech doprovázejících změny mikrostruktury v pevných látkách a AE je tudíž nedestruktivní metodou umožňující v reálném čase studovat chování velkých objemů materiálu na mesoskopické úrovni. Ve srovnání s ostatními nedestruktivními diagnostickými technikami je tato metoda v mnoha směrech výhodnější. Především díky vysoké citlivosti lze detekovat vady v počátečním stádiu, které jsou klasickými způsoby (ultrazvuk, prozařování) ještě nepostizitelné, a jsou detekovány pouze aktivní vady, projevující se při zatížení.

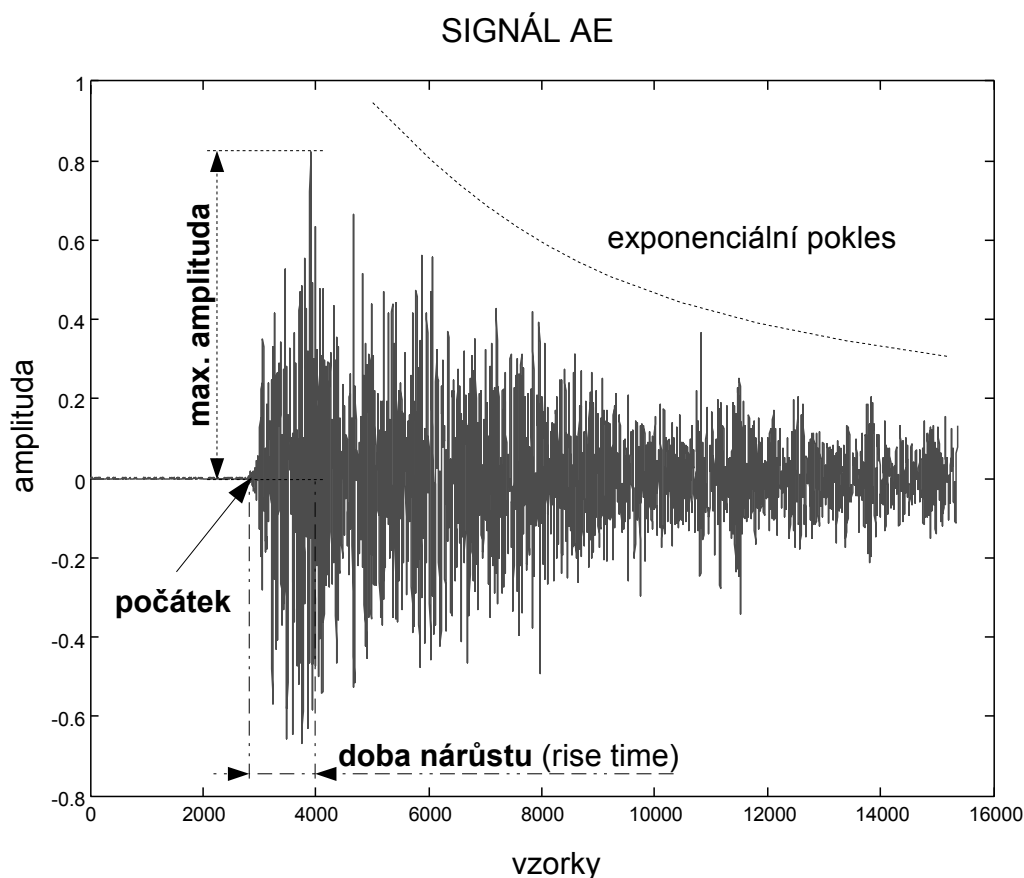
Většina NDT technik, používaných v současné době k monitorování vzniku a rozvoje poškození leteckých konstrukcí při statickém i dynamickém zatěžování, nesplňuje zcela požadavek na ekonomičnost defektoskopických kontrol, neboť spotřebuje většinu času na hledání defektů tam, kde se nevyskytují. Požadavek na vytvoření systému, který by detekoval přítomnost poškození a hodnotil jeho závažnost a přitom by spolehlivě ignoroval všechny nepoškozené části konstrukce, splňuje právě systém využívající metodu AE. Sledování signálů AE u staticky a cyklicky namáhaných konstrukčních součástí se jako nedestruktivní diagnostická metoda intenzívně používá již více než 20 let.

Zdrojem AE v namáhané součásti mohou být různé mechanismy, které se liší jak energií, tak časo-frekvenčními charakteristikami. U kovových součástí může být zdrojem AE kromě vzniku a růstu defektů typu trhlin také plastické deformace, únavové či korozní procesy spojené se změnou struktury materiálu (např. uvolnění pohybu dislokací, porušení lepených či nýtovaných spojů, poškozování na rozhraních zrn či vměstků, ale i např. tření vzájemně se pohybujících dílů apod). U kompozitových a sendvičových konstrukcí jsou nejčastějšími

zdroji AE delaminace vrstev, porušování vyztužujících elementů (přetrhávání vláken), vznik trhlin v kompozitové matici či na rozhraní matrice a vláken. Pro správnou lokalizaci a identifikaci zdrojů musí být především známy a odfiltrovány externí rušivé zdroje, jako je například tření mezi částmi sledované konstrukce při cyklickém namáhání a další možné zdroje vysokofrekvenčních vibrací.

Detekovaný emisní signál sice nese informace o emisním zdroji, ale jejich obsah je díky velice komplikovaným transformacím na přenosové cestě značně zkreslen [2]. Vlastní analýza emisních zdrojů je tedy silně ovlivněna složitým šířením elastických vln, při němž dochází k distorzi emisního signálu vlivem mnoha faktorů, jako jsou např.:

- Volné povrchy tělesa (*způsobují odrazy zvukových vln a dochází zde k přeměně objemových vln na povrchové a k interferenci*).
- Fázové rozhraní, hranice zrn, mikrotrhliny (*mají za následek další odrazy a difrakci vln*).
- Anizotropie (*deformuje původně sférický vlnový balík a nastává šíření různou rychlostí v různých směrech*).
- Nehomogenity (*narušují čelo vlny*).
- Nelineárně elastické chování materiálu (*způsobuje útlum a disperzi šířících se vln*).



Obr. 2.1: Typický záznam signálu AE - základní terminologie

Nejen útlum, disperze, konverze vlnových módů a odrazy na rozhraních, ale i samotná detekce AE, tj. konverze mechanického vlnění na elektrický signál, je příčinou nežádoucího zkreslení emisního signálu. Tato konverze se realizuje nejčastěji pomocí piezoelektrických snímačů, připevněných k povrchu materiálu. Elektrický signál (viz obr. 2.1) je dále zesílen a ovzorkován dostatečně rychlými A/D převodníky měřící aparatury. Mezi další komplikující aspekty praktického využití patří např. nezbytnost použít u každého monitorovacího uzlu specificky navržené uspořádání (experimentálně i teoreticky dobře podložené), potřebná znalost frekvenčních charakteristik snímačů AE a také odlišné algoritmy zpracování emisních signálů závislé na materiálu a geometrii sledovaného dílu.

Metoda AE se přesto jeví jako ideální prostředek okamžitého monitorování výskytu defektů, které by mohly vést k selhání konstrukce, neboť k detekci a lokalizaci těchto defektů na rozměrné konstrukci postačí relativně malý počet vhodně rozmístěných snímačů AE. Nasazení metody AE na spolehlivé monitorování vzniku a růstu defektů však není jednoduchá záležitost a pro její efektivní využití je nezbytný rozsáhlý výzkum. Je třeba si uvědomit, že k rozlišení užitečných a rušivých zdrojů AE a k defektoskopické interpretaci detekovaných signálů je zapotřebí jak dobrá znalost možných zdrojů elastických vln v dané součásti, tak způsob a charakteristiky šíření napěťových vln od zdroje ke snímačům.

3. EXPERTNÍ DETEKCE ZAČÁTKU SIGNÁLU AE

Po detekci signálu AE je dalším úkolem analýzy dostatečně přesné určení polohy emisního zdroje. K lokalizaci defektu se většinou používají časové diference příchodu signálu k jednotlivým snímačům. Při průchodu tělesem však dochází ke značnému zkreslení signálu a nepřesná detekce příchodu (prvního nasazení signálu), resp. určení časových diferencí, je tak zdrojem největších chyb lokalizace poruchy.

V současné době existuje mnoho přístupů k detekci příchodu signálu AE [3] jako např. metoda překmitu prahové úrovně, hranová detekce prvního nasazení, detekce časových diferencí pomocí vzájemné korelační funkce a metody vycházející z waveletové transformace. Novější algoritmy sledují lokální změny statistických parametrů signálu jakožto časové řady [4],[5], nebo vycházejí z Akaikeho informačního kritéria (AIC) [6]. Při vyšších nárocích na přesnost a robustnost se výsledky výše uvedených metod ukazují jako nedostačující. Z těchto důvodů byl navržen a odladěn nový algoritmus, modelující expertní detekci příchodu vlny na základě informace o tvaru signálu. Tato metoda, vycházející z časového vývoje lokálních těžišť a energie zaznamenaných signálů, se v mnoha aplikacích osvědčila jako dostatečně robustní, rychlá a snadno použitelná.

3.1 Vlastnosti algoritmu

Automatické zpracovávání rozsáhlých souborů signálů AE klade na aplikovaný algoritmus detekce prvního nasazení velmi silné požadavky. Vlastnosti analyzovaných záznamů jsou často proměnlivé a parametry detekčních algoritmů je nutné nastavovat i vícekrát v rámci zpracování dat z jednoho měření (např. s ohledem na různé vlastnosti jednotlivých kanálů měřící aparatury). Nový algoritmus detekce začátku signálu byl navržen pro potřeby rychlého a dostatečně robustního zpracování signálů, které mají složité tvary, zahrnují různě vysoké hladiny šumu a mohou být neúplné (chybějící začátek signálu viz obr. 3.1 typ 4), nebo částečně poškozené (chyby A/D převodníku, mechanické či elektrické rušení apod. - viz obr. 3.1 typ 2). Cílem tohoto algoritmu je modelování optické detekce prvního nasazení na základě vývoje lokálních těžišť a energie signálu.

Základní vlastnosti algoritmu lze shrnout do následujících bodů:

- ***princip***

Počátek signálu emisní události je určován na základě analýzy pomocného vektoru absolutních lokálních těžišť a energií (RMS).

- ***plná automatizace***

Algoritmus, jehož vstupem je pouze vhodně ovzorkovaný signál, provádí automatické nastavení parametru šířky měřícího okna a odhadne délku šumového počátku záznamu (pretrigger). Nově zavedené interní funkce spolehlivě oddělí šum v přibližně celé jeho délce a nikoliv jen počáteční pevně volenou část záznamu, která u jiných algoritmů slouží pro výpočet šumových parametrů.

- **robustnost vůči variabilitě signálů**

Nová metoda se vyznačuje velkou robustností vůči různým typům zpracovávaných signálů AE. Je odladěna na rozsáhlém souboru dat naměřených při reálných experimentech a uměle zašuměných záznamech. Není citlivá na chyby A/D převodníku, či elektrické poruchy.

- **relativně vysoká přesnost**

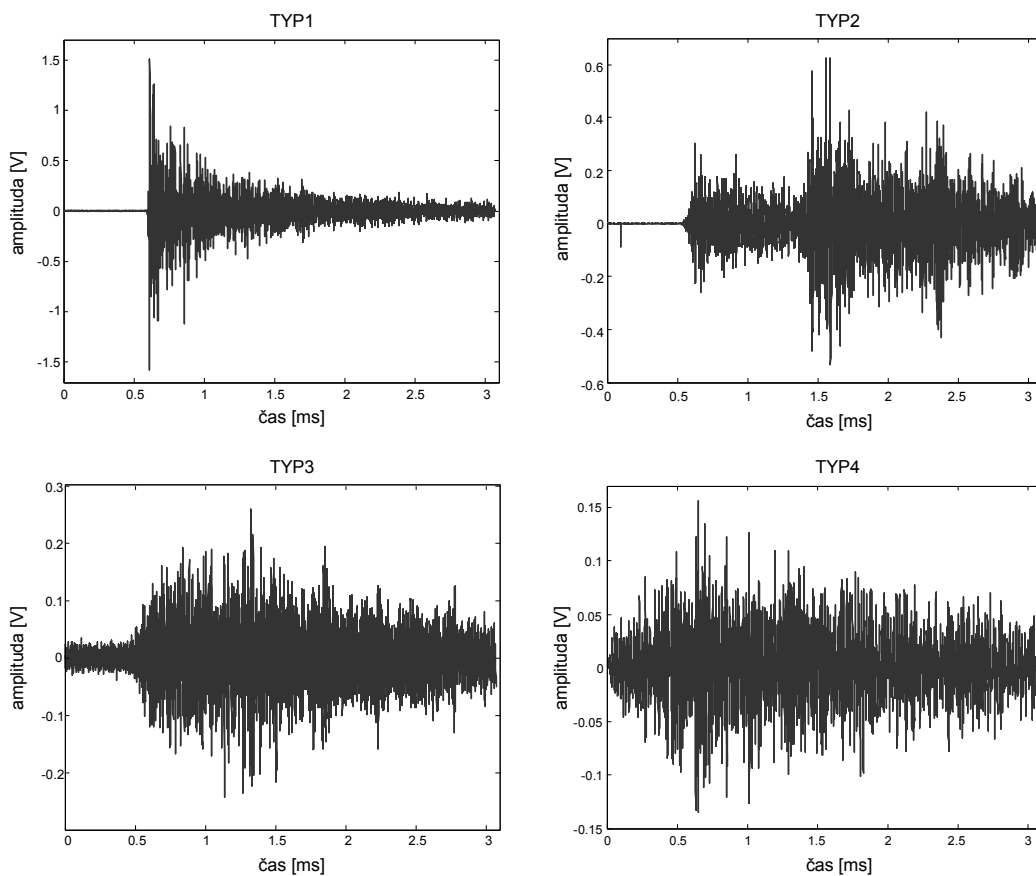
Parametry algoritmu jsou nastaveny experimentální optimalizací při zpracování náhodně vybraného souboru dat. Byla tak dosažena řádově vyšší přesnost, než u jiných doposud používaných metod.

- **možnost rekonstrukce chybějícího začátku signálu**

V případě neúplného záznamu signálu a vyšších hladin šumu je provedena lineární extrapolace, čímž lze částečně rekonstruovat polohu zašuměného, resp. chybějícího počátku.

- **dostatečná rychlost**

Optimalizovaná implementace algoritmu v prostředí Matlab umožňuje velmi rychlou analýzu v praxi běžně zpracovávaných záznamů signálů AE.




Obr. 3.1: Nejčastější typy záznamů signálů AE

3.2 Popis algoritmu

Výpočet délky měřicího okna

Vstupem algoritmu je navzorkovaný záznam signálu $s = \{s(i) | i=1, \dots, N\}$. Nejprve je určen parametr k , který vymezuje délku měřicího okna. Pro potlačení oscilací následně počítaného vektoru lokálních těžišť (3.5) by měla maximální šířka okna ($=2k+1$) přesahovat vlnovou délku odpovídající hlavní "nosné" frekvenci zaznamenaného signálu, tj. dvojnásobek maximální šířky vrcholů nad pevně stanovenou prahovou úrovní (viz obr. 3.2). Lze použít střední hodnotu signálu, ale lépe se osvědčila třetina maximální amplitudy záznamu. Míru přesahu délky okna přes nosnou frekvenci modeluje parametr c_k . Jeho velikost by ovšem neměla být příliš velká, jinak by metoda ztrácela přesnost.



Obr. 3.2: určení délky měřicího okna

Parametr k je počítán následovně:

$$k = c_k \cdot \max(\text{diff}(\text{find}(z))) \quad (3.1)$$

Pomocný vektor $z = \{z(i) | i=1, \dots, N\}$ tvoří logické hodnoty 0 a 1, určující je-li složka záznamu menší než třetina maximální amplitudy:

$$z(i) = \begin{cases} 1 & \text{pokud } s(i) < \text{amplituda}/3 \\ 0 & \text{jinak} \end{cases} \quad (3.2)$$

V souladu s prostředím Matlab vrací operace $\text{find}(z)$ vektor vzestupně uspořádaných indexů nenulových složek vektoru z , operace diference (diff) je definována jako vektor rozdílů dvou sousedních složek původního vektoru, viz (3.3), a $\max(v)$ je obecně maximální hodnota všech složek vektoru v .

$$\text{diff}(x) = \{x(j+1) - x(j) | j=1, \dots, N-1\} \quad (3.3)$$

Pomocný vektor lokálních těžišť

Následně je pro všechny vzorky signálu počítán pomocný vektor g , jehož i -tá složka obsahuje amplitudovou souřadnici těžiště $CG_Y(|s_i|)$ absolutní hodnoty části signálu v okolí příslušné složky i :

$$g(i) = CG_Y(|s_i|) , kde s_i = \{ s(j) \mid j = \max\{i-k, 1\}, \dots, \min\{i+k, N\} \} \quad (3.4)$$

Výpočet prvních a posledních k vzorků lokálních těžišť $g(i)$ se tedy provádí jen pro tu část signálu, která má smysl (existuje). Pro obecnou signálovou část s_i délky k_i platí:

$$g(i) = CG_Y(|s_i|) = \frac{\sum_{j=1}^{k_i} (k_i+1-j)|s_i(j)|}{\frac{1}{2}(k_i^2+k_i)} \quad (3.5)$$

Výpočet vektoru $g(i)$ podle vztahu (3.5) je v prostředí Matlab značně pomalý. Přepíšeme-li ale tento vztah pomocí konvoluce absolutní hodnoty signálu s a lineárně rostoucího vektoru f (viz 3.7), nabízí se velmi rychlá implementace:

$$g(i) = \frac{2w(i)}{(d(i))^2 + d(i)} \quad (3.6)$$

kde

$$w = |s| * f = conv(|s|, f) \quad (3.7)$$

$$f(i) = i \quad pro \quad i = 1, \dots, 2k+1 \quad (3.8)$$

$$d(i) = \begin{cases} i & pro \quad i \leq 2k \\ 2k+1 & pro \quad 2k < i \leq N+2k \end{cases} \quad (3.9)$$

Jako výsledek operace konvoluce dvou obecných vektorů u, v o délkách M a N je uvažován vektor $w = conv(u, v)$ délky $M+N-1$, který je definován následovně:

$$w(k) = \sum_j u(j)v(k+1-j) \quad (3.10)$$

Sumace probíhá přes všechny indexy j , které označují příslušné (existující) složky $u(j)$ a $v(k+1-j)$, konkrétně $j = \max(1, k+1-N), \dots, \min(k, M)$. Složky $k+1, \dots, k+N$ vektoru g počítaného podle (3.6) jsou tedy shodné s vektorem g podle vztahu (3.5).

Pro vyhlazení vektoru g je též výhodné vynásobit aktuální signálovou část s spektrálním okénkem (např. hanning). V případě rychlé implementace podle (3.6) postačí vynásobit pouze vektor f . V obou verzích ale dochází ke zmenšení hodnot vektoru těžišť. Jedním ze způsobů kompenzace tohoto efektu může být např. provedení přibližně páté odmocniny složek spektrálního okénka.

Automatické oddělení šumu a přibližné určení začátku


Klíčovým krokem automatického algoritmu je přibližné oddělení signálu od počáteční šumové části záznamu. Pokud nemá metoda používat žádný jiný vstupní parametr kromě signálu samotného, je třeba navrhnout funkce, které detekují výrazný nárůst okamžité

amplitudy těsně za skutečným příchodem signálu AE a poté oddělí zašuměný začátek záznamu. Využití znalosti polohy maximální amplitudy se ukázalo jako zavádějící. Vlivem disperze a různých odrazů vlny nemusí maximální amplituda souviset s místem nejstrmějšího nárůstu signálu. V jediném záznamu může být také zachyceno více překrývajících se signálů (viz obr. 3.1 typ 2) a maximální amplituda tak nemusí příslušet první události, jejíž detekci upřednostňujeme.

Za šum považujeme počáteční vzorky záznamu, které představují realizaci náhodného procesu s konstantní střední hodnotou a rozptylem. Na ojedinělé výchyly silně překračující rozptyl, jako např. elektrické rušení a chyby A/D převodníku (viz obr. 3.1 typ2), by algoritmus na rozdíl od prahové detekce neměl reagovat. V praxi se poměrně často setkáváme také s případy, kdy je počátek signálu zachycen jen velmi těsně prvními vzorky záznamu a nebo dokonce chybí. I takové situace by měl automatický algoritmus řešit a pomocí matematicky modelované expertní znalosti detekovat nepřítomnost šumové části, či neúplnost záznamu emisní události. Na základě těchto požadavků byly zavedeny následující funkce q_1 a q_2 :

$$q_1(i) = \begin{cases} 1 & \text{pro } i=1 \\ \frac{(i-1)(g(i)+g(1))}{\sum_{j=2}^i (g(j-1)+g(j))} & \text{pro } i=2, \dots, N \end{cases} \quad (3.11)$$


Funkce q_1 porovnává plochu pod spojnici prvního a i -tého vzorku vektoru lokálních těžišť se sumou ploch pod spojnicemi jednotlivých vzorků v analogickém rozmezí (viz obr. 3.3). Tento poměr detekuje první výrazný nárůst pomocného vektoru těžišť a tudíž i signálu samotného. Na ojedinělé výchyly záznamu naopak nereaguje, čímž je zajištěna relativní stabilita algoritmu. Místo výskytu prvního významného nárůstu signálu určuje index maximální složky (m_i) vektoru q_1 (3.12).



Obr. 3.3: výpočet vektoru q_1

Pro zavedení další funkce q_2 je potřeba určit prvním nárůstem vymezenou polohu maxima vektoru těžišť (m_2), která se obecně nemusí shodovat s polohou m_1 :

$$m_1 = \underset{i}{\operatorname{argmax}}\{q_1(i)\} , \quad m_2 = \underset{i < m_1}{\operatorname{argmax}}\{g(i)\} \quad (3.12)$$



Obr. 3.4: výpočet vektoru q_2

Funkce q_2 naopak porovnává sumu ploch pod spojnicemi jednotlivých vzorků vektoru lokálních těžišť mezi polohami i a m_2 s plochou pod spojnici krajních vzorků příslušného rozmezí (viz obr. 3.4). Tento poměr výrazně roste v okamžiku zvýšení amplitudy signálu nad šumové pozadí:

$$q_2(i) = \frac{\sum_{j=i+1}^{m_2} (g(j-1) + g(j))}{(m_2 - i)(g(m_2) + g(i))} \quad \text{pro } i=1, \dots, m_2-1 \quad (3.13)$$

Analogicky k výpočtu pomocného vektoru g je i vyčíslování poměrů q_1 a q_2 podle původních vzorců velmi zdlouhavé. Sumace ve jmenovateli (3.11) resp. čitateli (3.13) se provádí vždy pro všechny relevantní indexy, i když se další krok liší pouze přičtením jediného čísla. Dochází tak ke značné duplicitě numerických operací. Podstatně úspornější je algoritmizace pomocí předpočítaných kumulativních sum:

$$q_1(i) = \begin{cases} 1 & \text{pro } i=1 \\ \frac{(i-1)(g(i) + g(1))}{s_{c1}(i-1) + s_{c2}(i-1)} & \text{pro } i=2, \dots, N \end{cases} \quad (3.14)$$

kde

$$s_{c1}(i) = \sum_{j=1}^i g(j) , \quad s_{c2}(i) = \sum_{j=1}^i g(j+1) \quad \text{pro } i=1, \dots, N-1 \quad (3.15)$$

Obdobně lze vyjádřit i vzorec pro vektor q_2 :


$$q_2(i) = \frac{s_{c_3}(i) + s_{c_4}(i)}{(m_2 - i)(g(m_2) + g(i))} \quad \text{pro } i=1, \dots, m_2-1 \quad (3.16)$$

kde

$$s_{c_3}(i) = \sum_{j=i}^{m_2-1} g(j) \quad , \quad s_{c_4}(i) = \sum_{j=i}^{m_2-1} g(j+1) \quad \text{pro } i=1, \dots, m_2-1 \quad (3.17)$$

Pro odhad charakteristik šumu je třeba použít počáteční vzorky záznamu emisní události, které ovšem nezasahují do užitečného signálu. Tuto šumovou část lze vymezit okamžikem z_s , kde funkce q_2 překročí jistou mez (ozn. p_z). V případě vysokého odstupu signálu od šumu lze dokonce říci, že pokud tato funkce začíná hodnotou větší, než je tato mez, jedná se o záznam signálu s neúplným začátkem. Podle výsledků numerických experimentů při ladění algoritmu se optimální hodnota p_z pohybuje v rozmezí 0.2-0.3:

$$z_s = \min\{i \mid q_2(i) > p_z\} \quad (3.18)$$



Obr. 3.5: Identifikace šumové části záznamu

Charakteristiky vektoru lokálních těžišť g v přibližně vymezené šumové části záznamu lze uvažovat jako výchozí k dalším odhadům. Při určování prvního nasazení je směrodatný vývoj lokální energie signálu. Podobně i hodnoty lokálních absolutních těžišť jsou v případě šumu téměř konstantní a polohu vzorku signálu, kde tento pomocný vektor trvale přesáhne úroveň charakterizující šumové pozadí, lze považovat za přibližný počátek události. Jako úroveň tohoto prahu p_s je brána maximální hodnota vektoru lokálních těžišť až do vzorku z_s :

$$p_s = \max\{g(i) \mid i \leq z_s\} \quad (3.19)$$

Přibližný začátek z_p je posléze získán následujícím prahováním:

$$z_p = \max\{i \mid g(i) < p_s, i < m_2\} \quad (3.20)$$


Určení odhadu skutečného začátku signálu

Výše uvedeným přibližným začátkem z_p lze již relativně přesně vymežit část záznamu představujícího pouze šum. Charakteristiky takto určené šumové části jsou využívány ve finálních zpřesňovacích krocích metody. Jako hodnota pomocného prahu je uvažován součet průměru a směrodatné odchylky příslušné části vektoru těžišť:

$$p_1 = \text{mean}\{g(i) | 1 < i < z_p\} + \text{std}\{g(i) | 1 < i < z_p\} \quad (3.21)$$

Poslední vzorek vektoru $g(i)$, který je menší než hodnota p_1 , je považován za odhad prvního nasazení signálu (viz obr. 3.6):

$$z_1 = \max\{i | g(i) < p_1, i < m_2\} \quad (3.22)$$



Obr. 3.6: Prahování vektoru $g(i)$

Faktor délky měřícího okna


Důležitým faktorem ovlivňujícím přesnost detekční metody je bezesporu délka měřícího okna ve vztahu k úrovni šumu v záznamu signálu. V hypotetickém ideálním případě nepřítomnosti šumového pozadí ovlivňuje okamžitá amplituda signálu počítaný vektor lokálních těžišť o k vzorků dříve, než je poloha jeho aktuálně vyčíslované složky. Naopak, pokud je začátek signálu skrytý v šumu, změna vektoru těžišť se projeví pozvolněji. Pro kompenzaci tohoto efektu byl zaveden tzv. **faktor délky měřícího okna** f_k , který koriguje odhadnutou polohu počátku s ohledem na poměr mezi úrovní šumu a maximem vektoru lokálních těžišť. Konstantami c_1 a c_2 je laděna citlivost faktoru f_k na odstup signálu od šumu:

$$f_k = 1 - c_1 \cdot \left(\frac{p_s}{\max\{g(i)\}} \right)^{c_2} \quad (3.23)$$

Začátek signálu je výsledně korigován následovně:

$$z_2 = z_1 + k \cdot f_k \quad (3.24)$$

Obecnou závislost velikosti takto definovaného faktoru f_k na detekované úrovni šumového pozadí a nastavených parametrech ilustruje obr. 3.7. Již ze vzorce (3.23) je zřejmé, že v případech vysokého odstupu signál-šum, a tedy nízkého poměru $p_s / \max\{g(i)\}$, nabývá hodnot blízkých jedné. Podle vztahu (3.24) je tak odhad začátku korigován maximálně o k vzorků, čímž je kompenzován předčasný nárůst pomocného vektoru lokálních těžišť zmiňovaný výše. V opačném případě je počátek korigován záporným směrem. Parametr c_1 vymezuje maximální velikost korekce, přičemž exponent c_2 ovlivňuje tvar modelované závislosti (viz obr. 3.7).



Obr. 3.7: typické závislosti f_k na úrovni šumu

Korekce na průchod nulou

Ke zpřesnění metody po každém dílčím kroku lze použít "korekci na předchozí průchod nulou". Jedná se o nalezení posledního místa před polohou aktuálního odhadu počátku z_{akt} , kde signál prochází střední hodnotou. Vzorek napravo od tohoto místa je následně brán jako nový odhad počátku (ozn. z_n):


$$z_n = \max\{i \mid i \leq z_{akt} \wedge |d(i)| \neq 0\}, \text{ kde } d = \text{diff}(\text{sign}(s)) \quad (3.25)$$

Všechny zde uvedené verze odhadu začátku jsou tedy vždy korigovány na "průchod nulou".

Lineární extrapolace (chybějícího) začátku

Při vysokých hladinách šumu je odhad počátku komplikovanější. I pouhým pohledem na osciloskopický záznam není totiž jednoduché rozpoznat náběžnou hranu užitečného signálu. Na obr. 3.8 můžeme vidět detail počátku signálu s velkým odstupem od šumu, na jehož pozadí je světle šedou barvou zobrazen shodný signál, ke kterému byl ale přičten bílý šum

s relativně vysokou amplitudou. Je zřejmé, že původní počátek je tak zcela skryt v šumu a detekční metoda ztrácí přesnost (viz obr. 3.8 - začátek z_2). Nabízí se zde řešení, které pomáhá i v případech neúplného záznamu. Jelikož nárůst amplitudy emisního signálu má těsně za počátkem téměř lineární průběh, lze detekci prvního nasazení zpřesnit extrapolací pomocí přímky, která je naznačena na obr. 3.8. Jako výchozí jsou brány body o souřadnicích $[m_2, g(m_2)]$ a $[z_2, g(z_2)]$, jimiž proložíme přímku. Souřadnice z_3 , kde tato přímka protíná vodorovnou osu, dále zpřesňuje polohu odhadu počátku signálu.



Obr. 3.8: Lineární extrapolace začátku

Je evidentní (a žádoucí), že v případech s nízkou hladinou šumu tato extrapolace polohu počátku z_2 v podstatě zachovává. Pokud se z_2 nachází blízko začátku záznamu, výsledná hodnota z_3 může být i záporná. Takto dochází k určité automatické obnově nezaznamenaných počátků. Přínos této extrapolace je patrný z porovnání výsledků při nastavování parametrů algoritmu, viz kap. 3.4.

3.3 Další verze algoritmu

Spolu s lokálními absolutními těžišti zůstává v šumové části záznamu téměř konstantní i okamžitá energie signálu. Vzhledem k těmto vlastnostem může být jistou alternativou metody analogické hledání nárůstu vektoru lokálních hodnot RMS. Všechny kroky algoritmu mohou zůstat beze změn, pouze pomocný vektor $g(i)$ (původně viz 2.5) je třeba počítat jako RMS příslušné části signálu s_i :

$$g_{RMS}(i) = RMS(s_i) = \sqrt{\frac{1}{k_i} \sum_{j=1}^{k_i} (s_i(j))^2} \quad (3.26)$$

Obdobně jako pro lokální těžiště je výpočet vektoru $g_{RMS}(i)$ podle vzorce (3.26) v prostředí Matlabu značně pomalý. Implementaci uvedeného vztahu lze ale rovněž optimalizovat. V tomto případě pomocí konvoluce druhé mocniny signálu $s(i)$ po složkách (viz 3.29) a jednotkového vektoru f_{RMS} (3.28):

$$g(i) = \sqrt{\frac{w_{RMS}(i)}{d(i)}} \quad (3.27)$$

kde

$$w = s^2 * f_{RMS} = conv(s^2, f_{RMS}) \quad (3.28)$$

$$s^2(i) = (s(i))^2 \quad (3.29)$$

$$f_{RMS}(i) = 1 \quad pro \quad i = 1, \dots, 2k+1 \quad (3.30)$$

$$d(i) = \begin{cases} i & pro \quad i \leq 2k \\ 2k+1 & pro \quad 2k < i \leq N+2k \end{cases} \quad (3.31)$$

Vymezení "pretriggeru" pomocí funkcí q_1 a q_2 , postupné prahování a korekce odhadů začátku probíhá dále zcela obdobně. Výsledkem jsou nové počátky z_1^{RMS} , z_2^{RMS} a z_3^{RMS} , analogické k z_1 , z_2 a z_3 .

V rámci sledování vývoje šumu pomocnými vektory g a g_{RMS} lze zavést alternativní hodnoty prahů. Ukázalo se ale, že ne s tak přesnými výsledky pro daný testovací soubor signálů. Alternativním prahem p_2 k hodnotě p_1 může být maximum příslušného pomocného vektoru g resp. g_{RMS} do vzorku z_p :

$$p_2 = max\{g(i) \mid 1 < i < z_p\} \quad (3.32)$$

Dostáváme tak verze začátků z_4 (prahování vektoru g) a z_4^{RMS} (prahování vektoru g_{RMS}). Další modifikace prahů jako např. y souřadnice těžiště absolutní hodnoty nebo RMS celé šumové části se osvědčily méně.

3.4 Testování algoritmu a nastavení parametrů

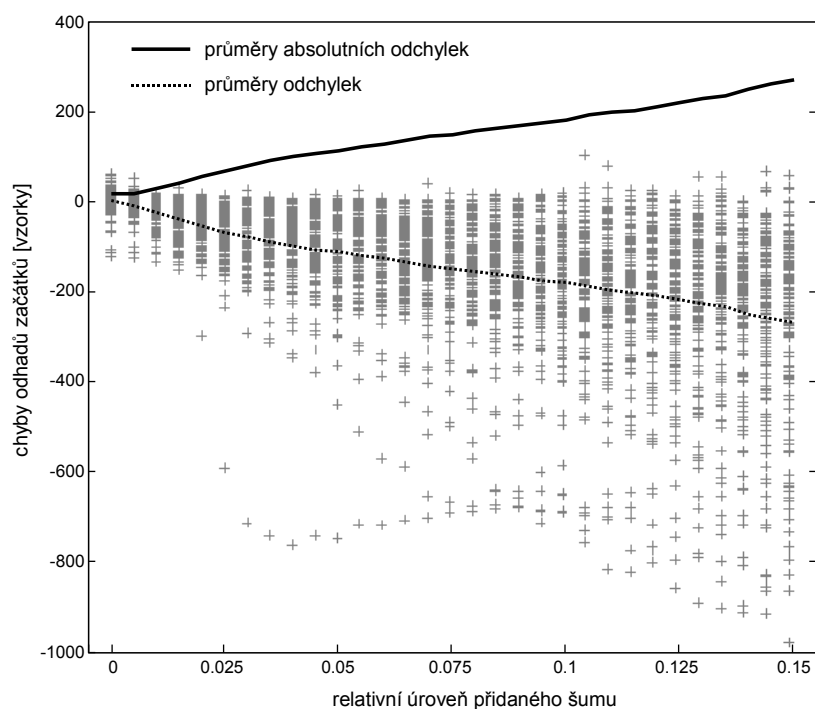
Optimalizace hodnot parametrů algoritmu (c_k , c_1 , c_2) byla provedena pomocí testovacího souboru 150 náhodně vybraných signálů naměřených při pen testech na složité části letecké konstrukce. Za přítomnosti vyšších hladin šumu je i pro lidské oko obtížné korektně určit skutečný začátek signálu. Proto byly kvůli posouzení úspěšnosti metody využity nejen původní záznamy s vysokým odstupem signálu od šumu, kde manuální odečet prvního nasazení není tolik nejednoznačný a lze ho považovat za správný, ale i tytéž signály s přidaným bílým šumem s rovnoměrným rozdělením v symetrickém intervalu kolem nuly. Výsledky testování algoritmu jsou proto hlavně v případě uměle zašuměných záznamů směrodatné, protože pro přirozeně zašuměné signály nelze s takovou přesností určit začátek ani manuálně.

U všech signálů byla nejprve z jejich záznamů ručně odečtena čísla vzorků pravděpodobného prvního nasazení. Následovalo srovnání těchto hodnot s výsledky automatického algoritmu s různě nastavenými parametry, přičemž v rámci testování hodnot jednoho optimalizovaného parametru zůstávaly ostatní konstantní. Jedná se tedy vždy o postupné experimentální přiblížení k optimu bez analytického výpočtu.


Jako vyhovující byla nejprve ověřena volba parametru c_k (viz 3.1) kolem hodnoty 2.5, při níž jsou pomocné vektory g a g_{RMS} relativně stabilní a přesnost metody zůstává zachována. Dalšími experimenty byla zkoumána vhodná citlivost faktoru f_k (tj. nastavení konstant c_1 a c_2) na různé úrovně odstupu signálu od šumu. Ke každému předem znormovanému signálu z testovacího souboru byl přičten bílý šum s rovnoměrným rozdělením v intervalu (-

1,1) s různým relativním zesílením v rozmezí 0-0.15 po krocích 0.005. Testování algoritmu prokázalo relativně vysokou citlivost odhadu počátku na změnu šumového pozadí. Nejen na změnu úrovně šumu, ale i na konkrétní realizaci náhodných veličin, které jej modelují. Metoda sama vykazuje určitý rozptyl výsledků i při konstantních šumových parametrech. Z těchto důvodů bylo pro získání stabilních výsledků nutné vygenerovat sto realizací šumu pro každou zvolenou úroveň a konkrétní testovací záznam, výsledky zprůměrovat a odečíst od manuálně určených odhadů počátků. Zároveň bylo nutné v jemných krocích měnit i nastavení parametrů c_1 a c_2 . Nejlepší výsledky byly dosaženy s hodnotami $c_1=3.9$ a $c_2=0.23$, jejichž vliv na průběh parametru f_k je ilustrován již na obr. 3.7.

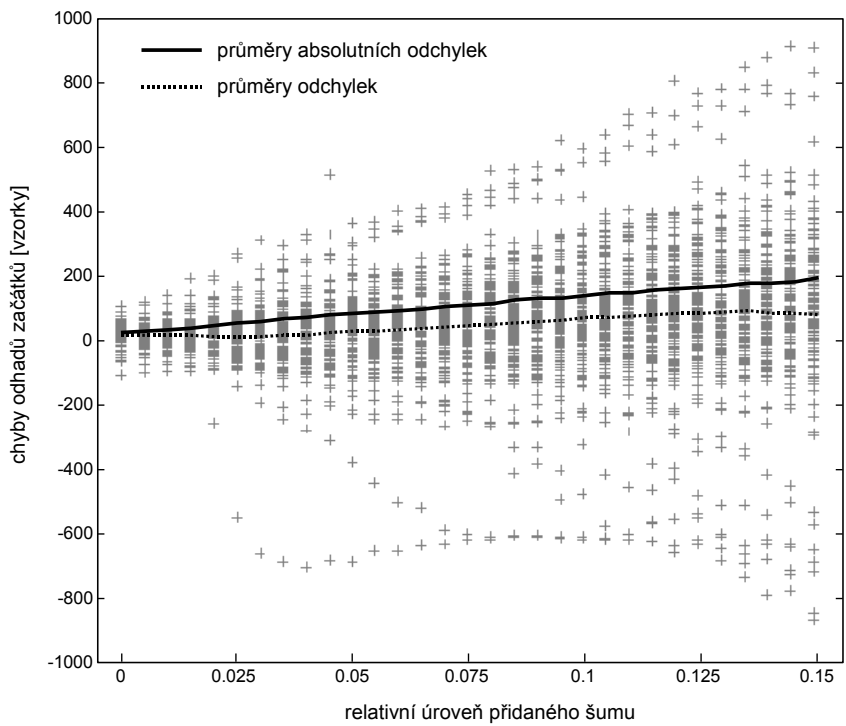
Následující obrázky dokumentují výše uvedeným způsobem získané výsledné hodnoty odchylek pro každý signál (jsou vyznačeny křížky v liniích nad příslušnou úrovní šumu na vodorovné ose). Dvěma křivkami je též znázorněn vývoj průměrů chyb a průměrů absolutních hodnot chyb přes všechny signály v závislosti na zesílení šumu.



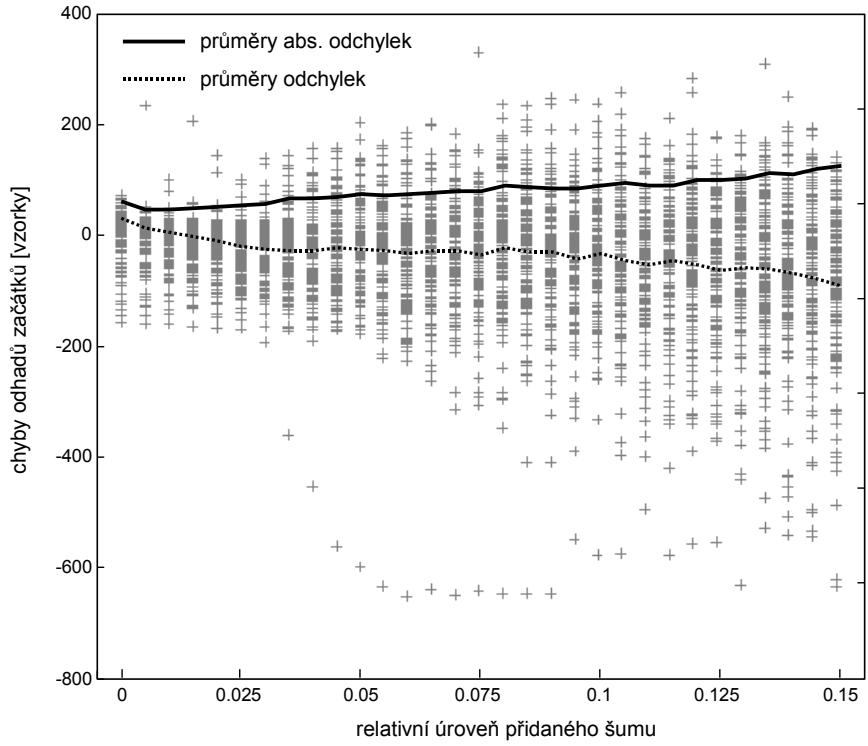
Obr. 3.9: Výsledky testu algoritmu (odhad verze z_1)




Obr. 3.10: Výsledky testu algoritmu (odhad verze z_2)




Obr. 3.11: Výsledky testu algoritmu (odhad verze z_3)



Obr. 3.12: Výsledky testu algoritmu (odhad verze z_1^{RMS})



Obr. 3.13: Výsledky testu algoritmu (odhad verze z_2^{RMS})



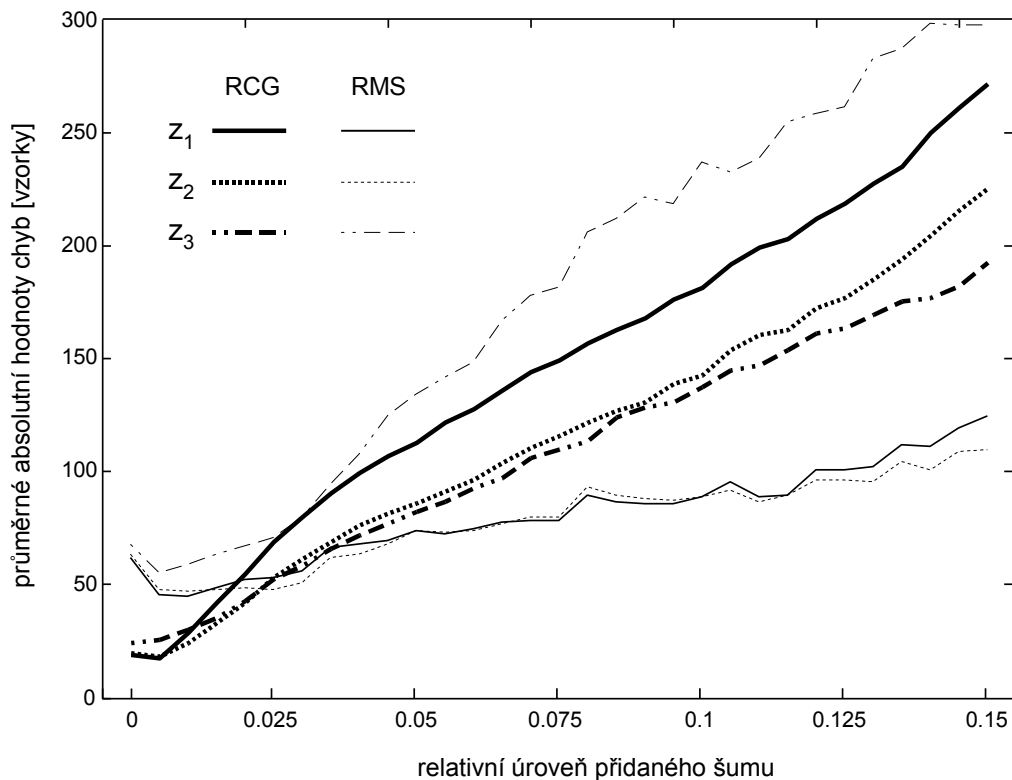
Obr. 3.14: Výsledky testu algoritmu (odhad verze z_3^{RMS})

Závěry

Z porovnání výsledků dvou metod detekce počátků a tří jejich modifikací plynou následující závěry. V první řadě nelze jednoznačně určit která konkrétní metoda a její modifikace je nejúspěšnější pro původní i zašuměné signály současně. Je zřejmé, že v případě vyšší hladiny šumu dává lepší výsledky metoda vycházející z vývoje lokálních RMS. Pro původní signály ale není tak přesná. Metoda detekce počátku pomocí sledování lokálních těžišť je naopak přesnější pro relativní úroveň šumu až do hodnoty 0.025 a pak se její přesnost ve srovnání s RMS metodou postupně zhoršuje (viz obr. 3.15).

Zajímavé je také srovnání tří modifikací obou základních metod. Z obr. 3.15 je evidentní také přínos korekce pomocí faktoru délky měřicího okna (f_k). Korigované verze začátků z_2 a z_2^{RMS} jsou v obou případech zpřesněním výchozích odhadů. Lineární extrapolace začátků je naopak vhodná pouze pro metodu lokálních těžišť a vyšší úroveň šumu, kdy dochází k výrazné redukci strannosti odhadů. Průměry chyb se sice s rostoucím zastoupením šumu lineárně zvětšují, ovšem podstatně méně než jejich rozptyl (viz obr. 3.11). V případě RMS metody není extrapolace přínosná a má smysl pouze pro automatickou obnovu nezaznamenaných počátků.

Jistým problémem je nastavení prahu p_z pro případ, kdy jsou v záznamu zachyceny dva signály těsně za sebou a mají řádově odlišné amplitudy, přičemž nižší předchází vyššímu (viz obr. 3.1 typ 2). Pokud je hodnota prahu příliš nízká, metoda sice detekuje příchod prvního signálu, ale v jiných případech častokrát nesprávně vymezení šumovou část, tj. určený vzorek z_s značně předchází skutečnému počátku. Proto byla zvolena kompromisní hodnota $p_z=0.25$ a v ojedinělých případech dvojitého záznamu tak dochází k vysokým chybám, které jsou v obrázku zobrazeny jako křížky mimo hlavní shluk výsledných dat.



Obr. 3.15: Souhrnné výsledky testu algoritmu

Souhrnné srovnání obou metod a všech jejich modifikací je ilustrováno na obr. 3.15 pomocí závislostí průměrů absolutních hodnot chyb v závislosti na úrovni šumového pozadí. Jsou zde patrné všechny výše zmiňované aspekty včetně lokálního zpřesnění odhadů pro velmi malá zesílení přidaného šumu. Zprůměrováním výsledků algoritmu v případě jednoho vybraného signálu, ke kterému přičteme nezávislé realizace šumu s relativním zesílením kolem 0.005, lze získat s velkou pravděpodobností lepší odhad počátku. Tento efekt se ale projeví pouze pro záznamy s nízkou úrovní přirozeného šumového pozadí.

Závěrem lze říci, že parametr RMS je oproti variantě lokálních těžišť citlivější na okamžitou amplitudu signálu a tato verze metody má tak menší robustnost vůči různým poruchám v záznamu. Osvědčuje se ale v případech s vyšší hladinou šumu. Do hladiny šumu 0.025, kdy poměr $p_s/\max\{g(i)\}$ nabývá hodnot kolem 0.031, je tedy výhodnější uvažovat výsledný odhad z_2 a v ostatních případech z_2^{RMS} .

Nejúspěšnější verze algoritmu je nejméně o řád lepší než metoda hranové detekce [3], která pro původní záznamy vykazuje průměrnou chybu určení začátku emisní události 195 a pro signály s hladinou šumu 0.1 dokonce 1347 vzorků. Vezmeme-li v úvahu vzorkovací periodu, která v případě testovacích dat byla 200ns, a přibližnou rychlost šíření podélné vlny v duralu ($v=6.18\text{mm/us}$), jedná se o zpřesnění lokalizace emisního zdroje v průměru z 241 resp. 1664 na 25 resp. 79 mm.

Popisovaný algoritmus expertní detekce počátku signálu AE má i přes relativně vysokou přesnost a robustnost další možnosti zlepšení. Zejména fáze počátečního vymezení šumové oblasti, do níž může být zahrnuto například určení příchodu různých typů vln, zůstává předmětem budoucího výzkumu.

4. PARAMETRIZACE SIGNÁLŮ AE

Číslicové zpracování emisního signálu neklade žádná omezení na typ a počet vyhodnocených parametrů. Prakticky všechny analyzátory AE jsou vybaveny vhodnými prostředky pro parametrizaci emisního signálu. U starších analyzátorů převládala analogová parametrizace pomocí pevně zapojených analogových a číslicových obvodů, u novějších jsou signálové parametry v reálném čase variabilně numericky vyhodnocovány z digitalizovaných dat pomocí rychlých signálových procesorů resp. programovatelných hradlových polí. Omezující podmínkou je přílišná složitost (výpočetní náročnost) vyhodnocovacího algoritmu a pochopitelně i požadavek, aby vyhodnocených parametrů bylo podstatně méně než digitalizovaných dat. Chceme-li pro identifikaci emisního zdroje využít pravděpodobnostní přístupy nebo určité algoritmy s prvky umělé inteligence (umělé neuronové sítě, pravděpodobnostní logické sítě, genetické algoritmy, buněčné automaty apod.), závisí úspěšnost rozpoznávání zdroje na volbě typu a počtu signálových parametrů.

Většina komerčních aparatur se omezuje na jednoduché vyhodnocení tradičních parametrů emisních událostí, jako jsou amplituda, efektivní či střední hodnota, energie, četnost překmitů, doba nárůstu do maxima, doba příchodu, trvání a lokalizace konvenčně definované emisní události atd. Díky relativní algoritmické složitosti jsou odlišné signálové parametry používány jen zřídka. Tak např. Yamaguchi [7] zahrnul do souboru signálových parametrů AE mimo jiné také statistické momenty a v "inteligentním" systému pro klasifikaci signálů ICEPAK kanadské společnosti Tektrend je možnost výběru ze 108 parametrů nejen v časové, ale i ve frekvenční a cepstrální reprezentaci.

4.1 Cíle parametrizace

Pro jednotlivé konkrétní aplikace lze z určitého pohledu optimalizovat množinu parametrů tak, aby jich bylo co nejméně (lze vypustit redundantní parametry, které obsahují víceméně stejnou informaci o signálu) a aby zvolená klasifikační kritéria umožňovala pokud možno jednoznačné rozhodování. Standardizované "klasické" emisní parametry ve většině případů nesplňují kritérium vzájemné nezávislosti (nejsou "ortogonální v prostoru parametrů"-korelace mezi nimi jsou významné), neboť většina z nich nějakým způsobem vypovídá pouze o energii signálu.

Pro popis jevu akustické emise a analýzu zaznamenaných signálů AE je tedy nutné zavést řadu vhodných zjednodušujících signálových charakteristik. Jak již bylo zmíněno, použití všech vzorků záznamu jako vstupu klasifikačního algoritmu je výpočetně téměř nerealizovatelné. Rovněž z hlediska aplikace neuronových sítí je značná variabilita jednotlivých vzorků signálů, byť nesoucích podobnou informaci o zdroji, velmi těžko naučitelná, protože se blíží nejednoznačné úloze. Pomocí signálových parametrů lze snížit objem a tok dat, která získáváme sledováním AE během experimentu, na teoreticky i prakticky únosnou mez.

Cílem každé parametrizace by mělo být získání maxima informace skryté v signálu za současné minimalizace redundance dat. Přestože se po zesílení a filtraci používá k charakterizaci signálu AE pulzního typu řada jednoduchých, dobře definovatelných a měřitelných parametrů, praxe ukazuje na mnohdy nedostatečné informace o emisním zdroji, či procesu, obsažené v těchto parametrech. Řada klasických charakteristik se

při šíření elastické vlny zásadně mění a tudíž nesou informace spíše o cestě od zdroje ke snímači než o samotném zdroji.

Předpokladem pro charakterizaci záznamu AE je vhodné vymezení pojmu emisní událost, která je nejčastěji definována na základě předem zvolené prahové úrovně okamžité výchylky a tzv. mrtvé doby. Emisní událost (EU) začíná prvním překmitem signálu přes prahovou úroveň a končí, pokud v časovém intervalu delším, než nastavená mrtvá doba, k žádnému překmitu nedojde. V běžných měřících aparaturách lze tyto hodnoty předem nastavit spolu s délkou záznamu, vyhrazenou pro jednu EU. V paměti aparatury je neustále cyklicky přepisována okamžitá kratší část (tzv. pretrigger) elektrického signálu z předzesilovačů, která se v případě překmitu přes prahovou úroveň předradí před samotný záznam EU a slouží k nalezení jejího skutečného začátku (viz kap. 3). Při výpočtu níže uvedených parametrů tedy signálem AE rozumíme vzorky od přesněji určeného začátku až do mrtvé doby, nebo samotného konce záznamu.

4.2 Definice parametrů

V rámci práce byly vybrány a použity některé klasické osvědčené charakteristiky z výše uvedených parametrizací a doplněny o nově zavedené, které lépe postihují problematické okolnosti spojené s distorzí elastické vlny během šíření v materiálu, či záznamem AE měřící aparaturou.

Výčet parametrů používaných v rámci numerických a praktických experimentů

(1) Amplituda signálu:

$$s_{max} = \max \{ |s(i)| \mid i = 1, \dots, N \} \quad (4.1)$$

(2) Amplituda vektoru g :

$$g_{max} = \max \{ |g(i)| \mid i = 1, \dots, N \} \quad (4.2)$$

Tato verze amplitudy má oproti klasické variantě menší citlivost na slabé zalimitování signálu. Jelikož vektor g je počítán integrací přes vymezený časový úsek, zalimitování (tj. přetečení rozsahu A/D převodníku) dostatečně malého počtu vzorků ovlivní hodnotu souřadnice lokálního těžiště, resp. RMS jen zanedbatelně. Na samotné amplitudě signálu mohou být tyto rozdíly mezi analogovou a digitální (přetečenou) hodnotou podstatně vyšší.

(3) Doba nárůstu do maxima signálu (Risetime):

$$RT = \operatorname{argmax} \{ |s(i)| \mid i = 1, \dots, N \} \quad (4.3)$$

(4) Doba nárůstu do maxima vektoru g :

$$RT_g = \operatorname{argmax} \{ |g(i)| \mid i = 1, \dots, N \} \quad (4.4)$$

Různé fázové interference a odrazy často způsobují velké změny pozice maximální amplitudy v signálu a v důsledku toho i skokovou změnu doby nárůstu. Výše uvedená modifikace parametru je opět díky integračnímu výpočtu pomocného vektoru g bližší době "energetického nárůstu" a rovněž stabilnější.

(5) Efektivní hodnota signálu (RMS):

$$RMS = \sqrt{\frac{1}{N} \sum_{i=1}^N s(i)^2} \quad (4.5)$$

(6) Moment energie:

$$T_E = \frac{1}{N} \sum_{i=1}^N i \cdot s(i)^2 \quad (4.6)$$

Standardizované centrální momenty signálu jakožto časové řady:

(7) průměrná hodnota (ASL):

$$\mu = \frac{1}{N} \sum_{i=1}^N s(i) \quad (4.7)$$

(8) směrodatná odchylka:

$$\sigma = \sqrt{\frac{1}{N-1} \sum_{i=1}^N (s(i) - \mu)^2} \quad (4.8)$$

(9) šikmost μ_3 , (10) špičatost μ_4 :

$$\mu_k = \frac{1}{\sigma^k \cdot N} \sum_{i=1}^N (s(i) - \mu)^k \quad (4.9)$$

Takto uvažované centrální momenty jsou pro praktické použití méně vhodné, i když podle faktorové analýzy (kap. 5) nesou významný podíl informace obsažené v zaznamenaných datech. Z důvodu nezávislosti výsledné hodnoty vzhledem k permutaci pořadí vzorků nemohou reflektovat tvar signálu a nejsou pro klasifikaci emisních zdrojů příliš významné.

Tvar signálu lépe postihují centrální momenty odvozené od pomocného vektoru g (def. viz 3.5), který představuje obálku signálu. Výpočet těchto nově zavedených parametrů vychází opět ze vzorců pro standardizované centrální momenty, avšak ve verzích pro danou hustotu pravděpodobnosti, nikoliv pro náhodnou veličinu, jako v případech (7-10). Průměr $\tilde{\mu}$ tedy charakterizuje těžiště plochy pod pomocným vektorem g . Momenty vyšších řádů pak zohledňují "symetrii" a "šířku" obálky signálu:

(11) těžiště vektoru g :

$$\tilde{\mu} = \frac{\sum_{i=1}^N i \cdot g(i)}{\sum_{i=1}^N g(i)} \quad (4.10)$$

(12) rozptyl:

$$\tilde{\sigma}^2 = \frac{\sum_{i=1}^N (i - \tilde{\mu})^2 \cdot g(i)}{\left(\sum_{i=1}^N g(i)\right) - 1} \quad (4.11)$$

(13) šikmost $\tilde{\mu}_3$, (14) špičatost $\tilde{\mu}_4$:

$$\tilde{\mu}_k = \frac{\sum_{i=1}^N (i - \tilde{\mu})^k \cdot g(i)}{\tilde{\sigma}^k \sum_{i=1}^N g(i)} \quad (4.12)$$

Stěžejní informace o zaznamenaném signálu AE nese jeho frekvenční spektrum. Následující souhrn (parametry 15-23) uvádí použité charakteristiky odhadu výkonové spektrální hustoty $f(i)$, určeného pomocí rychlé Fourierovy transformace (FFT).

(15-19) poměrné zastoupení frekvenčních pásem $A-E$ v celovém pásmu G :

$$P_X = 100 \cdot \frac{\sum_{\omega \in X} f(\omega)}{\sum_{\omega \in G} f(\omega)}, \quad X \in \{A, B, C, D, E\} \quad (4.13)$$

kde intervaly indexů frekvencí ω odpovídají frekvenčním pásmům X vztaženým k Nyquistově frekvenci ω_N . Jednotlivá pásma mohou být volena např. následovně:

$A:(0-0.03) \cdot \omega_N$; $B:(0.03-0.05) \cdot \omega_N$; $C:(0.05-0.1) \cdot \omega_N$; $D:(0.1-0.2) \cdot \omega_N$; $E:(0.2-0.5) \cdot \omega_N$;

$G:(0-0.5) \cdot \omega_N$.

Statistické tvarové parametry jsou počítány pro výkonovou spektrální hustotu obdobně jako v případě pomocného vektoru g . První moment (tj. střední hodnota), představující frekvenci odpovídající "těžišti spektra", je navíc normován na počet vzorků.

(20) relativní těžiště výkonové spektrální hustoty f :

$$\tilde{\mu}_f = \frac{\sum_{i=1}^N i \cdot f(i)}{N \sum_{i=1}^N f(i)} \quad (4.14)$$

(21) rozptyl f vyjádřený analogicky jako pro hustotu pravděpodobnosti:

$$\tilde{\sigma}_f^2 = \frac{\sum_{i=1}^N (i - \tilde{\mu}_f)^2 \cdot f(i)}{\left(\sum_{i=1}^N f(i)\right) - 1} \quad (4.15)$$

Vyšší momenty jsou počítány podobně jako ve vzorcích (4.11) a (4.12). Charakterizují "symetrii" resp. "šířku" výkonové spektrální hustoty f .

(22) šikmost $\tilde{\mu}_3(f)$, (23) špičatost $\tilde{\mu}_4(f)$:

$$\tilde{\mu}_k(f) = \frac{\sum_{i=1}^N (i - \tilde{\mu}_f)^k \cdot f(i)}{\tilde{\sigma}_f^k \sum_{i=1}^N f(i)} \quad (4.16)$$

5. FAKTOROVÁ ANALÝZA

5.1 Model faktorové analýzy

Faktorová analýza (FA) je metoda často používaná pro nalezení lineárních závislostí mezi parametry a výpočet nových, hypotetických proměnných (faktorů) vysvětlujících rozptyl původních parametrů [8],[9]. FA je založena na metodě hlavních os (PCA - principal component analysis), která ortogonalizuje složky vektorů do ní vstupujících a uspořádává je tak, aby první složka reprezentovala největší rozptyl. Složky přispívající celkovému rozptylu dat jen malou měrou naopak eliminuje. Ve smyslu rozdílu mezi původními a transformovanými daty je ztráta informace minimalizována.

Ve většině případů přináší metoda hlavních os a faktorová analýza velice podobné informace. Metoda hlavních os je nicméně preferována pro redukci dat, zatímco FA se lépe hodí pro zjišťování jejich struktury. FA je ve své podstatě lineární transformace (ortogonální rotace), následovaná změnou měřítka. Výsledkem jsou nové **hypotetické proměnné** a **faktorové schéma** nesoucí regresní koeficienty faktorů na původní proměnné. Interpretace faktorů bývá poněkud obtížná, protože řešením problému může být i jakákoliv jiná ortogonální rotace faktorového schématu. Cílem všech rotačních strategií (např. Varimax) je dosažení srozumitelného profilu faktorových zátěží, tzn. jednoduché struktury.

Faktorová analýza vychází z předpokladu, že více měřených proměnných spolu velmi úzce souvisí a jsou tedy mezi sebou v silné korelaci. Potom tyto proměnné vyjadřují do značné míry totéž a lze předpokládat, že se navzájem určují, anebo že se v nich projevuje jiná veličina, kterou nemůžeme přímo měřit. Pozorované korelace se považují za projev určité nepozorované nebo nepozorovatelné veličiny, tzv. faktoru, ze kterého můžeme korelace vypočítat. Chceme zjistit, zda z měřitelných proměnných je možné tento faktor izolovat, aby co nejjednodušeji a dostatečně přesně objasnil pozorované souvislosti. Faktor je hypotetický, je konstrukcí, odvozenou z dat. Je matematickou veličinou, vyhovující korelacím v tom smyslu, že se dají z faktoru odvodit. Faktorová analýza zjišťuje tyto hypotetické faktory a má pro takovouto tvorbu hypotéz vždy předběžný charakter.

FA poskytuje nejjednodušší lineární hypotézu struktury, která stojí za navzájem korelujícími veličinami. Hledá odpověď na otázku kolik a které hypotetické veličiny nebo faktory jsou nutné pro co nejpřesnější reprodukci a formálně matematické vysvětlení pozorovaných korelací mezi proměnnými. Velmi záleží na zvolené parametrizaci pozorování. Jednostranný výběr proměnných musí nevyhnutelně poskytnout nebo postavit do popředí jiné faktory než širší výzkum.

Sestavme z naměřených dat matici $Y=y(i,j)$, kde řádkový index $i=1,\dots,M$ představuje pozorované veličiny a sloupcový index $j=1,\dots,N$ měřené objekty. Z důvodu "sjednocení měřítek" je nutné před jakoukoliv analýzou dat provést standardizaci, tj. transformaci, která zajistí nulový průměr a jednotkovou směrodatnou odchylku dat:

$$z(i,j) = \frac{y(i,j) - \bar{y}(i)}{s(i)} \quad (5.1)$$

kde

$$\bar{y}(i) = \frac{1}{N} \sum_{j=1}^N y(i, j) \quad , \quad s(i) = \sqrt{\frac{1}{N-1} \sum_{j=1}^N (y(i, j) - \bar{y}(i))^2} \quad (5.2)$$

Vztah dvou veličin x, y v řadě N -různých pozorování popisuje korelační počet. Mírou těsnosti této vzájemné souvislosti je korelační koeficient (ozn. r_{xy}). Nezávisí na měřicí stupnici, je normovanou kovariancí a jeho hodnota se tudíž nezmění jakoukoliv lineární transformací dat. Obvyklý přístup ke korelačním koeficientům vychází z rozdělení rozptylu nějaké proměnné na část objasněnou regresí a zbývající nevysvětlenou část. Podíl objasněného rozptylu k celkovému rozptylu se nazývá mírou determinovanosti. Udává kolik procent celkového rozptylu se reprodukuje lineárním modelem. Vzorec pro výpočet korelačního koeficientu mezi standardizovanými proměnnými i a k má následující tvar:

$$r_{ik} = \frac{1}{N-1} \sum_{j=1}^N z(i, j) z(k, j) \quad (5.3)$$

Koeficient r_{ik} může nabývat hodnoty mezi -1 a $+1$. Jestliže je nulový, potom neexistuje lineární vztah mezi i a k (může existovat nelineární). Je-li roven -1 nebo $+1$, jejich vztah je přísně lineární. Pro **korelační matici** $R = r(i, j) = r_{ij}$ a matici standardizovaných dat $Z = z(i, j)$ potom platí:

$$\frac{1}{N-1} ZZ' = R \quad (5.4)$$

Cílem faktorové analýzy je vyjádřit hodnotu $z(i, j)$ jako lineární kombinaci r -hypotetických, nepozorovaných nebo nepozorovatelných proměnných, tzv. faktorů:

$$z(i, j) = a(i, 1) \cdot p(1, j) + a(i, 2) \cdot p(2, j) + \dots + a(i, r) \cdot p(r, j) \quad (5.5)$$

Tato rovnice formuluje základní model faktorové analýzy. $A = a(i, l)$ jsou pevné koeficienty, tzv. **faktorové zátěže** (saturace), které chceme určit, $p_l(j)$ **hypotetické veličiny** (faktory) s měrnými hodnotami $P = p(l, j)$, které nazýváme **faktorová skóre**, představující hodnoty nových (jednodušších) proměnných. V maticovém tvaru můžeme psát:

$$Z = AP \quad (5.6)$$

Matice A (tzv. **faktorová matice** o rozměrech $M \times r$) je složena z hledaných regresních koeficientů faktorů na proměnné a představuje tzv. **faktorové schéma**. Dosadíme-li (5.6) do (5.4), dostaneme vztah:

$$R = \frac{1}{N-1} AP(AP)' = \frac{1}{N-1} APP' A' = A \frac{1}{N-1} PP' A' \quad (5.7)$$

Analogicky ke vzorci (5.4) představuje výraz $\frac{1}{N-1} PP' = C$ korelační matici mezi faktory.

V případě požadavku ortogonálních faktorů je matice C jednotková, tj. faktory mezi sebou nekorelují a vztah (5.7) se zjednodušuje na tzv. **fundamentální větu faktorové analýzy**:

$$R = AA' \quad (5.8)$$

Obecně tedy korelační matice musí být reprodukovatelná faktorovým schématem (tj. faktorovou maticí A) a korelacemi mezi faktory. Za předpokladu lineárního modelu, standardizovaných dat a také standardizovaných nekorelovaných faktorů platí pro jednotkový rozptyl každé proměnné vztah (5.9), přičemž $a(i, j)^2$ je část celkového rozptylu

proměnné i vysvětlená závislostí na faktoru j .

$$a(i,1)^2 + a(i,2)^2 + \dots + a(i,r)^2 = 1 \quad (5.9)$$

5.2 Modifikovaná metoda hlavních os (hlavních komponent)

Problém faktorů spočívá v určení počtu a druhu souřadnicových os, které jsou potřebné ke znázornění korelací mezi proměnnými. Způsoby řešení tohoto problému vycházejí z různých omezení při hledání jednoznačného řešení systému rovnic $Z=AP$, avšak výsledky těchto metod jsou navzájem ekvivalentní.

Pro geometrické vysvětlení metody hlavních os si představme soubor třírozměrných dat, které po zobrazení v prostoru tvoří jakýsi shluk. Souřadnice těchto bodů lze bez porušení struktury shluku transformovat do význačného souřadnicového systému tzv. **hlavních os**. Nejdelším průměrem shluku je první hlavní osa λ_1 . Druhá hlavní osa λ_2 je nejdelším průměrem v rovině kolmé na první hlavní osu a prochází těžištěm dat. Třetí hlavní osa λ_3 je kolmicí k prvním dvěma hlavním osám, procházející těžištěm. V případě, kdy všechny body leží v blízkosti roviny určené prvními dvěma hlavními osami (mají malý rozptyl mimo tuto rovinu), ztratíme jen malou část informací, když namísto tří měřených proměnných zvolíme pro znázornění struktury dat jen dvě, a to souřadnice v systému prvních dvou hlavních os. Přechod od původního souřadnicového systému k systému $\lambda_1, \lambda_2, \lambda_3$ odpovídá extrakci faktorů metodou hlavních os. Bez ztráty informace se tento přechod může uskutečnit jen v případě určení všech hlavních komponent, jejichž počet odpovídá počtu proměnných. V praxi ale často pro reprodukci podstatné části rozptylu stačí méně hlavních os (viz popis výše).

Metodu hlavních os je možno rozvíjet z různých východiskových formulací. Nejrozšířenější postup vychází v jistém směru z maximalizace rozptylu za určitých vedlejších podmínek. Za předpokladu ortogonality faktorů se model faktorové analýzy redukuje na tvar (5.8). Tento systém rovnic bude mít jednoznačné řešení, pokud zavedeme podmínku aby součet čtverců saturací prvního faktoru dosahoval maxima v celkovém rozptylu, součet čtverců saturací druhého faktoru maxima ve zbytkovém rozptylu atd. Nejdříve tedy určíme první faktor tak, aby jeho příspěvek k celkové varianci byl maximální. Hledáme vektor $\{a(1,1), \dots, a(N,1)\}$, pro který platí:

$$\sum_{i=1}^N a(i,1)^2 = \max \quad (5.10)$$

za splnění $\binom{M}{2}$ nezávislých podmínek: $r(i,k) = a(i,1)a(k,1)$ pro $i, k = 1, \dots, M, i < k$

Maximalizace funkce za vedlejších podmínek pomocí metody Lagrangeových multiplikátorů vede na problém vlastních čísel a vektorů korelační matice R . Každé hlavní ose odpovídá jeden vlastní vektor a příslušné vlastní číslo. Hodnota vlastního čísla (vždy ≥ 0) závisí na velikosti rozptylu veličiny, jeho odmocnina odpovídá délce příslušné hlavní osy.

Pro extrakci prvního faktoru tedy použijeme největší vlastní číslo. Příslušný vlastní vektor $\{\alpha(1,1), \dots, \alpha(N,1)\}$ pak splňuje požadované podmínky a maximalizuje $\sum_{i=1}^N \alpha(i,1)^2$. Obdobně pro vlastní vektor $\{\alpha(1,2), \dots, \alpha(N,2)\}$ příslušející druhému největšímu vlastnímu číslu je $\sum_{i=1}^N \alpha(i,2)^2$ maximální s ohledem na zbytkový rozptyl atd.

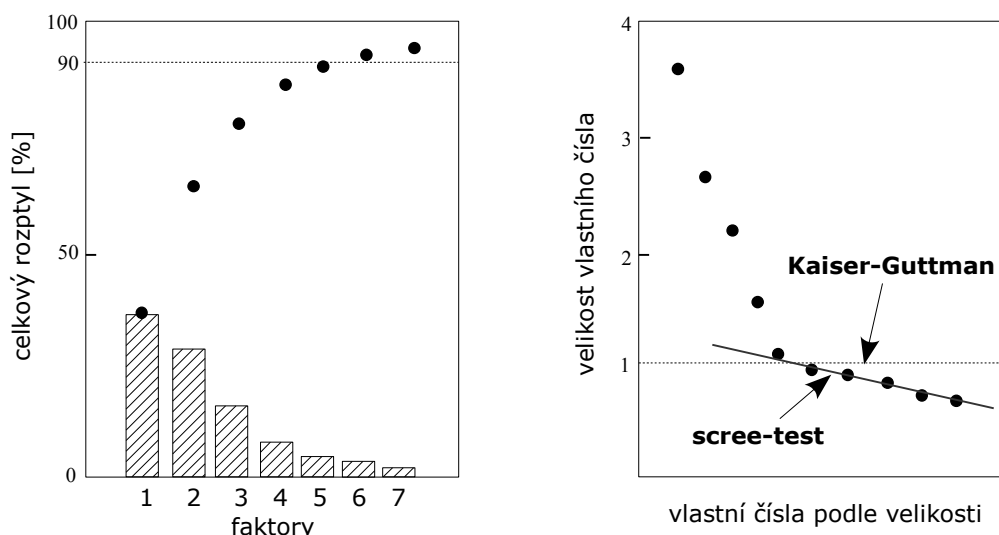
Faktory jsou přímo úměrné vlastním vektorům korelační matice R . Normováním dostaneme hledané prvky $a(i,j)$ faktorové matice A :

$$a(i,j) = \alpha(i,j) \sqrt{\frac{\lambda_j}{\alpha(1,j)^2 + \alpha(2,j)^2 + \dots + \alpha(N,j)^2}} \quad (5.11)$$

5.3 Problém počtu faktorů

Otázkou zůstává ukončení postupu extrakce faktorů. Na problém lze pohlížet z různých směrů. Můžeme například argumentovat všeobecnými vědeckými hledisky, požadovat vysvětlení určitého procenta celkového rozptylu nebo extrahovat faktory objasňující dostatečně významný podíl rozptylu proměnných apod. Uvedme přesto alespoň některá používaná kritéria:

- Pro svou jednoduchost je rozšířené "Kaiser-Guttman" kritérium podle nějž extrahujeme jen faktory s vlastními čísly >1 . Protože se jedná o absolutní kritérium a velikost vlastních čísel závisí na rozměru korelační matice, budeme při malém počtu proměnných extrahovat méně faktorů a naopak při relativně velké korelační matici faktorů více.
- Další jednoduchou a názornou metodou extrakce faktorů je znázornění jejich složek rozptylu. Celkový rozptyl n standardizovaných proměnných se vždy rovná n . Podíl rozptylu vysvětlený jedním faktorem se rovná součtu čtverců faktorových saturací příslušného sloupce faktorové matice A . Můžeme tedy libovolně volit požadované procentuelní objasnění celkového rozptylu proměnných (např. 90%) a zpětně určit postačující počet faktorů.



Obr. 5.1: Kritéria pro odhad počtu extrahovaných faktorů

- "Scree-test" metoda vychází z grafického zobrazení všech vlastních čísel korelační matice sestupně podle jejich velikosti. Příspěvek každého faktoru k celkovému rozptylu je roven odpovídajícímu vlastnímu číslu. Pokud korelační matici tvoří korelace nezávislých náhodných veličin, její vlastní čísla leží přibližně na klesající přímce.

V případě že nejde o náhodné korelace, dostáváme křivky podobného průběhu jako na obr. 5.1. Zde už body neleží na přímce. V průběhu takovýchto křivek nacházíme jasný zlom. Body v pravé části obrázku lze proložit přímkou. Počet větších vlastních čísel odklánějících se od této přímky udává počet faktorů, které máme extrahovat.

V praxi se pro určení počtu faktorů ukazuje jako výhodné kombinovat poslední dva přístupy. Jinými slovy, scree-test je dobrým kritériem pro první odhad počtu nových veličin, avšak křivky, proložené zobrazenými vlastními čísly, nemusejí mít typický průběh jako na obr. 5.1, což zmiňovanou metodu může zkomplikovat. Je ale dobré z ní vycházet a dále ověřit, jestli procentuální objasnění celkového rozptylu proměnných vyhovuje požadavkům, plynoucím z řešení konkrétní úlohy. Počet extrahovaných faktorů lze postupně zvyšovat a sledovat čerpání rozptylu spolu s profilem faktorového schématu. Ukazuje se, že pokud přidáný faktor $k+1$ není oproti předchozím k faktorům významně saturován, tj. maximální hodnota odpovídajících zátěží $a(i, k+1)$ je podstatně menší než v případě $a(i, k)$, nezlepší se výrazně ani čerpání rozptylu. Proces extrakce počtu nových proměnných nesoucích většinu informace lze tak ukončit.

5.4 Rotace faktorů

Výsledkem extrakce je schéma ortogonálních faktorů, tzv. faktorový prostor. Faktory představují souřadnicové osy a každou proměnnou lze vyjádřit jako vektor jehož souřadnice jsou příslušné faktorové zátěže. Toto schéma ovšem není jednoznačně interpretovatelné. Existuje totiž nekonečně mnoho poloh souřadnicových os ve faktorovém prostoru, které reprodukuje korelační matici stejně přesně (viz. 5.17). Cílem FA je odvodit z množství pozorovaných proměnných hypotetické veličiny, které mají své opodstatnění a které nejjednodušším možným způsobem dostatečně přesně objasňují pozorování.

Problém faktorů spočívá v nalezení nejmenšího možného počtu hypotetických veličin pro vysvětlení lineárních závislostí mezi původními proměnnými. V problému rotace jde o nalezení nejjednodušších možných vztahů proměnných a faktorů v již určeném společném faktorovém prostoru. Z geometrického hlediska se proto souřadnicová soustava lokalizuje tak, aby maximální počet proměnných ležel v co možná nejužší oblasti okolo souřadnicových os, tj. aby saturace $a(i, j)$ byly blízké ± 1 nebo 0. Tedy z hlediska algebraického jde o minimalizaci kritéria jednoduchosti struktury faktorové matice:

$$\sum_{k < l = 1}^r \sum_{i = 1}^N (a(i, k) a(i, l))^2 = \min \quad (5.12)$$

Pro ortogonální aproximaci jednoduché struktury se nejčastěji používá odvozené Kaiserovo **Varimax-kritérium**:

$$N \sum_{l = 1}^r \sum_{i = 1}^N (b(i, l) / h_i)^4 - \sum_{l = 1}^r \left(\sum_{i = 1}^N b(i, l)^2 / h_i^2 \right)^2 = \max \quad (5.13)$$

kde $A = a(i, l)$ je ortogonální východisková matice, $B = b(i, l)$ výsledek ortogonální rotace a h_i^2 tzv. **komunalita**:

$$h_i^2 = \sum_{l = 1}^r a(i, l)^2 = \sum_{l = 1}^r b(i, l)^2 \quad \text{pro } i = 1, 2, \dots, N \quad (5.14)$$

Maximalizace veličiny (5.13) zaručuje polohu souřadnicových os, která dostatečně přesně splňuje požadavky ortogonální jednoduché struktury, pokud je lze splnit ortogonální souřadnicovou soustavou. Tím lze dosáhnout maximální interpretovatelnosti bez upřednostňování jakékoliv předem přijaté hypotézy, přičemž vzájemné vztahy ve faktorovém prostoru zůstávají nezměněny (viz. 5.17).

Požadovaná "jednoduchá struktura" faktorové matice se hledá iterativně dílčími rotacemi souřadnic vždy v jedné rovině:

$$B = AT \quad (5.15)$$

Požadovanou rotaci o úhel α v rovině souřadnic k, l realizuje matice rotace $T=t(i, j)$:


$$t(i, j) = \delta_{ij} \text{ pro } i \neq k \neq j \wedge i \neq l \neq j, \quad t(k, k) = t(l, l) = \cos \alpha, \quad t(k, l) = -\sin \alpha, \quad t(l, k) = \sin \alpha \quad (5.16)$$

Protože T je ortogonální ($TT' = I$), reprodukce korelační matice R je možná i z rotované faktorové matice B :

$$BB' = AT(AT)' = AA' = R \quad (5.17)$$

Matice výsledné rotace T_v souřadnicového systému se získá vynásobením jednotlivých matic T_i dílčích rotací dvou os:

$$T_v = T_1 T_2 T_3 \dots \quad (5.18)$$



Obr. 5.2: Rotace v rovině dvou faktorů A_1, A_2

Před rotací je nutno každou proměnnou (tj. všechny řádky faktorové matice) normovat. V případě nízkých saturací (malé délky ve faktorovém prostoru) určité proměnné bychom jinak mohli dospět k jednoduché struktuře pouze zdánlivě. Po dokončení rotací je třeba původní délky obnovit.

5.5 Výpočet faktorových skóre

V případě smysluplně interpretovatelných výsledků FA (extrahovaných faktorů) má význam počítat také hodnoty (pozorování) nových veličin, tzv. faktorová skóre. Faktory jsou samy o sobě nepozorovatelné. Proto jsou jakákoliv empirická faktorová skóre pouze odhady společných faktorů, nikoliv skutečné faktory. Pro výpočet odhadů se používá řada různých přístupů. V rámci práce byla s nejlepšími výsledky aplikována metoda odhadu faktorových skóre vícenásobným regresním počtem [8]:

$$P = B' R^{-1} Z \quad (5.19)$$

Tento postup zaručuje výsledky velmi blízké případu extrakce plného počtu faktorů, kdy je možný přímý výpočet ze základního modelu faktorové analýzy (5.6), tj. inverze (v tomto případě čtvercové) rotované faktorové matice: $P=B^{-1}Z$.

5.6 Rozlišení technik FA

Obvyklá formulace FA vychází z matice naměřených dat, kterou lze uvažovat ve dvou směrech. Obyčejně se počítají korelace mezi sloupci (tj. proměnnými). Mluvíme o tzv. **R-technice**. Na druhou stranu můžeme také (vycházejíc ze stejné matice dat) vysvětlovat korelace mezi řádky, tedy zjišťovat vztahy mezi jednotlivými měřeními (osobami). V tomto případě jde o **Q-techniku**.

R-technika faktorové analýzy se používá pro izolaci skupin proměnných, které navzájem úzce souvisí a určují jeden faktor. V Q-technice se tento postup přenáší na vztahy mezi měřenými objekty. Dostáváme informaci o počtu faktorů, tzn. počtu význačných skupin objektů, které mají podobné naměřené vlastnosti. Tento počet lze využít ve shlukové analýze, která rozděluje objekty do zmiňovaných skupin.

5.7 Praktický příklad FA parametrů reálných signálů AE

Pro účely klasifikace AE zdrojů, pocházejících z různě namáhaných vzorků polymerních kompozitů byl získán a následně parametrizován rozsáhlý soubor emisních signálů [10]. Byly počítány následující parametry (definice viz kap. 4):

- amplituda (*v tab. 5.1 parametr č.1*)
- risetime (*č.2*)
- RMS (*č.3*)
- moment energie (*č.4*)
- ASL (*č.5*)
- směrodatná odchylka (*č.6*)
- šikmost (*č.7*)
- špičatost (*č.8*)

poměrné zastoupení frekvenčních pásem A-F:

- A ($[0, 0.12]f_N/2$) - (*č.9*)
- B ($[0.12, 0.24]f_N/2$) - (*č.10*)
- C ($[0.24, 0.36]f_N/2$) - (*č.11*)
- D ($[0.36, 0.48]f_N/2$) - (*č.12*)
- E ($[0.48, 0.6]f_N/2$) - (*č.13*)
- F ($[0.6, 1]f_N/2$) - (*č.14*)

v celkovém frekvenčním pásmu $G([0, 1/2]f_N)$, kde f_N je Nyquistova frekvence.

Za účelem redukce skrytých lineárních závislostí mezi čtrnácti počítanými parametry byla aplikována faktorová analýza, jejíž výsledky uvádí tab. 5.1. Na základě scree-testu bylo k extrakci vybráno 9 faktorů. Každý faktor je charakterizován jedním sloupcem, každá proměnná jedním řádkem rotované faktorové matice. Čím je absolutní hodnota dané faktorové saturace větší, tím těsnější je souvislost příslušného parametru a odpovídajícího faktoru. Závislosti v rotované faktorové matici jsou zvýrazněny stupni šedi. Z faktorových saturací bylo vypočítáno, že devět ortogonálních faktorů stačí na vysvětlení 98.38% celkového rozptylu všech proměnných.

Ze struktury rotované faktorové matice je zřejmé, že lze provést podstatnou redukci počtu měřených parametrů bez významné ztráty informace o charakteru signálu. Většinu faktorů můžeme objektivně interpretovat na základě známých fyzikálních souvislostí. Například lze očekávat, že s rostoucí energií signálu se bude zvětšovat i jeho amplituda, RMS a moment energie. Tyto tři parametry mají nejvyšší zátěže na jednom společném faktoru (vysoké zátěže parametrů 1, 3, 4 u druhého faktoru) a jsou tedy ovlivněny jednou veličinou, fyzikálně interpretovatelnou jako energetický faktor. Parametry amplituda, RMS a moment energie tedy spolu úzce souvisí a stačí uvažovat pouze jeden z nich, např. v praxi nejlépe osvědčená efektivní hodnota (RMS).

Obdobně můžeme postupovat i u prvního a třetího faktoru. Ty představují míru zastoupení nízkých resp. vysokých frekvencí (parametry 9 a 10 resp. 13 a 14). Frekvenční pásma A a B , resp. E a F lze spojit dohromady a redukovat parametry 9, 10 a 13, 14 na dva nové, počítané stejným způsobem, avšak pro pásma $A \cup B$, resp. $E \cup F$.

ROTOVANÁ FAKTOROVÁ MATICE (absolutní hodnoty)

1	0.04	0.91	0.16	0.10	0.01	0.07	0.06	0.01	0.23	
2	0.09	0.02	0.01	0.19	0.03	0.03	0.95	0.03	0.16	
3	0.10	0.96	0.15	0.00	0.03	0.00	0.02	0.05	0.07	
4	0.13	0.91	0.02	0.03	0.05	0.06	0.04	0.06	0.20	
5	0.30	0.05	0.04	0.41	0.06	0.49	0.17	0.07	0.66	
6	0.26	0.00	0.04	0.03	0.08	0.93	0.02	0.10	0.20	
7	0.29	0.06	0.03	0.27	0.03	0.17	0.16	0.04	0.86	
8	0.12	0.06	0.01	0.88	0.02	0.02	0.24	0.03	0.36	
9	0.90	0.15	0.09	0.08	0.15	0.17	0.06	0.21	0.18	
10	0.93	0.14	0.06	0.08	0.10	0.17	0.06	0.09	0.19	
11	0.25	0.10	0.12	0.03	0.25	0.11	0.03	0.90	0.05	
12	0.20	0.07	0.14	0.02	0.93	0.09	0.03	0.23	0.04	
13	0.04	0.09	0.97	0.00	0.05	0.00	0.00	0.06	0.02	
14	0.08	0.18	0.95	0.02	0.09	0.04	0.01	0.06	0.02	
		1	2	3	4	5	6	7	8	9

parametry

faktory

Tab. 5.1: Faktorové schéma

Faktory číslo 4-9 mají saturace podstatně odlišné od nuly většinou pouze u jednoho parametru. V tomto případě se jedná o tzv. **specifické faktory**, reprezentující jen jednu proměnnou. Původní parametrizaci lze tedy touto základní eliminací lineárních závislostí podstatně zredukovat na parametry 2, 3, 5, 6, 7, 8, 11, 12 a dva nové, spektrální.

Další možností redukce dimenze dat podle faktorové analýzy je výpočet zcela nových parametrů, tzv. faktorových skóre podle (5.19). Z hlediska míry zachování informace o vzájemných vztazích je tento přístup korektnější, nicméně i triviální výběr původních parametrů reprezentujících extrahované faktory se v praxi dobře osvědčil.

6. NEURONOVÉ SÍTĚ

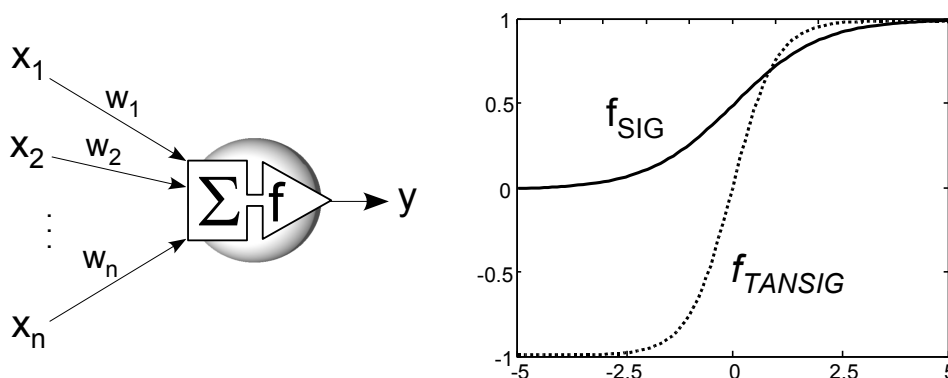
6.1 Jednoduchý perceptron a neuron

Koncept umělých neuronových sítí vychází z pokusů o matematické modelování funkcí lidského mozku [11]. V roce 1943 představili McCulloch a Pitts jednoduchý perceptron, který slouží jako zjednodušený model neuronu, základní jednotky struktury lidského neurálního systému. V průběhu dalších let byl tento model zobecněn, ale podstata jeho funkce zůstala nezměněna, tj. každý perceptron má určitý počet vstupů, které jsou transformovány na jediný výstup.

Jednoduchým perceptronem rozumíme výpočetní jednotku s vahami $w_1, \dots, w_N \in \mathbb{R}$ a prahem $\delta \in \mathbb{R}$, která spočte svoji excitaci (potenciál) pomocí vážené sumy vstupů a určí výstup 0, resp. 1 pokud je potenciál menší, resp. větší než práh. Výstup je tedy počítán tzv. skokovou přenosovou funkcí. Tato jednotka je schopna klasifikovat lineárně separabilní množiny bodů, tj. množiny oddělitelné nadrovinou, přičemž optimalizace nastavení vah a prahu je prováděna tzv. perceptronovým algoritmem [11]. Příkladem aplikace může být výpočet základních logických funkcí.

Zobecněný neuron je analogie perceptronu, avšak se spojitou přenosovou funkcí f . Je definován jako výpočetní jednotka s obdobnými vahami $w=(w_1, \dots, w_N) \in \mathbb{R}^N$ a prahem b , počítající funkci $f[w, b](x)$ pro libovolný vstup $x=(x_1, \dots, x_N) \in \mathbb{R}^N$. Základní schéma neuronu uvádí obr. 6.1. Výstup y je určen přenosovou funkcí f působící na potenciál neuronu ξ :

$$y = f(\xi) = f\left(\sum_{i=1}^N w_i x_i + b\right) \quad (6.1)$$



Obr. 6.1: Schéma neuronu a přenosové funkce

Volbou přenosové funkce, vah a prahu je určena reakce neuronu na předložený vstup. Spojitá přenosová funkce je nejčastěji sigmoida s volitelnou strmostí. Obor hodnot je

interval $(0,1)$ v případě klasické sigmoidální funkce f_{SIG} , nebo $(-1,1)$ pro tangens-sigmoidu f_{TANSIG} :

$$f_{SIG}(\xi) = \frac{1}{1 + e^{-\lambda\xi}}, \quad f_{TANSIG}(\xi) = \frac{1 - e^{-\lambda\xi}}{1 + e^{-\lambda\xi}} \quad (6.2)$$

6.2 Vrstevnaté neuronové sítě

Tvar závislostí, které je schopen modelovat jeden neuron, je logicky omezen dimenzí a typem použité přenosové funkce. Pro postizení složitějších případů je nutné propojit více výpočetních jednotek, tj. výstupy neuronů připojit na vstupy jiných a vytvořit tak neuronovou síť.

Definice:

Neuronová síť je uspořádaná šestice $K = (\Theta, \Lambda, I, O, w, t)$, kde

Θ	...	konečná neprázdná množina neuronů
$\Lambda \subseteq \Theta \times \Theta$...	neprázdná množina orientovaných spojů mezi neurony
$I \subseteq \Theta$...	neprázdná množina vstupních neuronů
$O \subseteq \Theta$...	neprázdná množina výstupních neuronů
$w: \Lambda \rightarrow \mathbb{R}$...	váhová funkce (každému spoji přiřadí váhu)
$t: \Theta \rightarrow \mathbb{R}$...	prahová funkce (každému neuronu přiřadí práh)

Definice.:

Grafem sítě K rozumíme graf spojů mezi neurony, tj. uspořádanou dvojici (Θ, Λ) .

Činnost (funkci) sítě lze rozdělit do dvou fází, učení a vybavování. V první dochází k adaptaci vah a prahů na základě postupného předkládání tzv. tréninkové množiny bodů za účelem minimalizace rozdílu mezi skutečným a požadovaným výstupem. Následnou druhou fází je výpočet odezvy na předložené neznámé vzory, tzv. vybavování.

Obecná umělá neuronová síť (ANN) se skládá z velkého množství vzájemně propojených jednotek zvaných neurony. V závislosti na definici neuronů (obecně nemusí provádět pouze operace jako uvedené výše) a způsobu jejich propojení lze rozlišovat mezi různými typy (architekturami) sítí jako např. vrstevnaté (Feed-Forward) ANN, Hopfieldovy ANN, Kohonenovy mapy. Následující kapitoly se týkají výhradně vrstevnatých sítí (též zvané vícevrstvé perceptrony nebo backpropagation sítě), které byly aplikovány při zpracovávání signálů AE.


Schopnost "učit se" z daných příkladů je nejvýznačnější vlastnost ANN. Popularita vrstevnatých ANN je dána existencí efektivního učícího algoritmu zvaného back-propagation (BP). Výčet aplikací ANN za posledních dvacet let zahrnuje řadu oblastí jako jsou průmysl, doprava, finance, obchod, telekomunikace, identifikace, klasifikace apod. až po medicínu, rétoriku a zábavní průmysl. Umělé neuronové sítě mohou být aplikovány při obecném rozpoznávání, v nelineárních řídicích systémech, při analýze dat, optimalizaci, plánování apod. V současnosti jsou návrhy aplikací ANN podstatně zjednodušeny díky možnostem využití efektivních softwarových vývojových nástrojů jako např. Neural Network Toolbox v programovém prostředí MATLAB.

Definice.:

Vrstevnatá síť mající $N-1$ (skrytých) vrstev je neuronová síť s orientovaným acyklickým grafem spojů. Množina neuronů je tvořena posloupností $N-1$ vzájemně disjunktních podmnožin, zvaných vrstvy. Graf spojů obsahuje pouze hrany z i -té do $(i+1)$ -ní vrstvy.

- První vrstva (M_0 neuronů) je vrstvou vstupní. Tyto neurony nemají v grafu žádné předchůdce, neprovádějí žádné výpočty a pouze předávají vstupní informaci dalším vrstvám.
- Poslední N -tá je vrstva výstupní, jejíž M_N neuronů nemá v grafu žádné následníky, mají většinou lineární přenosové funkce a jejich výstupní hodnoty jsou i výstupy sítě.
- Všech ostatních $N-1$ vrstev obsahuje neurony se sigmoidálními přenosovými funkcemi a jsou nazývány skryté vrstvy.

Vstupy sítě jsou tedy přiřazeny neuronům ve vstupní vrstvě. Informace je dál šířena sítí v dopředném směru, přičemž vážené sumy výstupů neuronů minulé vrstvy jsou po zpracování přenosovými funkcemi předány neuronům ve vrstvě následující. Výstupem sítě finálně rozumíme hodnoty na výstupech neuronů poslední vrstvy.



Obr. 6.2: Schéma N -vrstvé neuronové sítě

Definice.:

Pro vrstevnatou síť K s M_0 vstupními a M_N výstupními neurony se zavádějí následující pojmy:

- **Vstupní vzor** p je vstupní vektor $x_p = (x_p(1), \dots, x_p(M_0)) \in \mathbb{R}^{M_0}$ zpracovávaný sítí K .
- **Požadovaný výstup** p sítě K je vektor $d_p = (d_p(1), \dots, d_p(M_N)) \in \mathbb{R}^{M_N}$ tvořený požadovanými výstupními hodnotami neuronů ležících ve výstupní vrstvě.

- **Skutečný výstup** p sítě K je vektor $y_p = (y_p(1), \dots, y_p(M_N)) \in \mathbb{R}^{M_N}$ tvořený skutečnými výstupními hodnotami neuronů ležících ve výstupní vrstvě.
- **Tréninková množina** T je množina P uspořádaných dvojic [vstupní vzor, požadovaný výstup] $T = \{[x_1, d_1], \dots, [x_P, d_P]\}$.

Matematicky vzato jsou vrstevnaté ANN zobrazení $K: \mathbb{R}^{M_0} \rightarrow \mathbb{R}^{M_N}$, určené architekturou sítě, přenosovými funkcemi a hodnotami jejich vah a prahů. Pokud jsou nastaveny tak, aby po předložení vektoru $x_i = (x_i(1), \dots, x_i(M_0))$ odpověděla síť vzorem $d_i = (d_i(1), \dots, d_i(M_N))$ s co možná nejmenší odchylkou, pro vstupy podobné x_i odpoví za určitých předpokladů výstupem blízkým d_i .

Pro potřeby popisu detailů algoritmů v následujících kapitolách zavedme následující značení:

M_k	... počet neuronů v k -té vrstvě
$W = \{W^{(1)}, \dots, W^{(N)}\}$... ozn. všechny váhy sítě
$W^{(k)} = \{w_{ij}^{(k)}\}$... matice vah k -té vrstvy
$w_{ij}^{(k)}$... váha i -tého neuronu k -té vrstvy, příslušná jeho j -tému vstupu
$b_i^{(k)}$... práh i -tého neuronu v k -té vrstvě
f_k	... přenosová funkce neuronů v k -té vrstvě
$y^{(k)}(i) = f_k(\xi_i^{(k)})$... výstup i -tého neuronu v k -té vrstvě
$\xi_i^{(k)}$... potenciál i -tého neuronu v k -té vrstvě:

$$\xi_i^{(k)} = \sum_{j=1}^{M_{k-1}} w_{ij}^{(k)} y^{(k-1)}(j) + b_i^{(k)} \quad (6.3)$$

$y_p^{(N)}(i)$... skutečný i -tý výstup sítě, odpovídající učicímu vzoru p
$y^{(N)}(i)$... obecný i -tý výstup sítě
$d_p(i)$... požadovaný i -tý výstup sítě, odpovídající učicímu vzoru p
$x_p(i) = y_p^{(0)}(i)$... předložený i -tý vstup sítě, odpovídající učicímu vzoru p
$x(i) = y^{(0)}(i)$... obecný i -tý vstup sítě
P	... počet trénovacích vzorů
p	... konkrétní trénovací vzor
E	... celková kvadratická chyba
E_p	... kvadratická chyba učicího vzoru p

$$E = \frac{1}{2} \sum_{p=1}^P \sum_{i=1}^{M_N} (y_p^{(N)}(i) - d_p(i))^2 = \sum_{p=1}^P E_p \quad (6.4)$$

MSE ... průměrná kvadratická chyba

$$MSE = \frac{1}{P \cdot M_N} \sum_{p=1}^P \sum_{i=1}^{M_N} (y_p^{(N)}(i) - d_p(i))^2 \quad (6.5)$$

6.3 Aproximační vlastnosti vrstevnatých sítí

Lze dokázat, že sítě se dvěma skrytými vrstvami mají univerzální aproximační schopnosti, tj. dokáží s požadovanou přesností aproximovat libovolnou spojitou funkci. Důkaz vychází z Kolmogorovy věty, podle níž lze libovolnou spojitou funkci N proměnných vyjádřit jen pomocí součtu a složení spojitých funkcí jedné proměnné. Tyto funkce ale nejsou hladké, mají dokonce fraktální grafy, konstruují se v závislosti na aproximované funkci a nejsou reprezentovatelné v parametrickém tvaru. Nehodí se tedy jako přenosové funkce neuronů. V roce 1993 ale V. Kůrková ukázala, že Kolmogorovu větu lze použít i pro běžné perceptronové sítě, pokud není nutné přesné vyjádření funkce a postačí libovolně přesná aproximace. Teoreticky vzato, každou funkční závislost lze tedy napsat ve tvaru vrstevnaté neuronové sítě, přičemž přesnost aproximace je omezena počtem použitých neuronů, který v praxi udává výpočetní kapacita a velikost paměti počítače.

Ačkoliv existují odhady dávající do vztahu požadovanou chybu generalizace, počet neuronů a vah sítě spolu s počtem trénovacích vzorů a jsou zavedeny pojmy popisující složitost učeného problému a generalizační schopnosti sítí (jako např. Vapnik-Chervonenkisova dimenze, viz [11]), experimentální nalezení optimální architektury sítě vhodné pro konkrétní úlohu se v praxi ukazuje jako adekvátní postup. Podrobnějším rozbořením problému dobré generalizace se věnuje kap. 6.8.

Klíčovým problémem samozřejmě zůstává nalezení odpovídajících vah a prahů. Náhodně volené malé inicializační hodnoty (možná optimalizace, viz kap. 6.10) jsou během procesu učení laděny za účelem dosažení odpovídající konfigurace stávající architektury a dosažení vlastností sítě vhodných pro specifický rámec konkrétní úlohy. Potřebné vlastnosti modelovaného zobrazení, jako je např. odchylka mezi skutečnou a požadovanou odezvou sítě, jsou formulovány a měřeny vhodnou účelovou funkcí. Standardní mírou přesnosti aproximace je chybová funkce E (6.4), tj. suma kvadrátů rozdílů hodnot všech M skutečných a požadovaných výstupů sítě pro P dat z uvažované, např. tréninkové nebo testovací množiny T . Pro ovlivnění dalších vlastností, jako např. hladkost aproximace nebo samotného průběhu učení, se zavádějí dodatečné modifikace kvadratické chyby, viz např. (6.17), (6.19) nebo nově navržená (6.20).

6.4 Učení vrstevnatých sítí

Cílem procesu učení je nastavení vah a prahů sítě tak, aby byla chybová funkce minimalizována až na předepsanou hodnotu pro konkrétní tréninkovou množinu T . Chyba sítě přímo závisí na často komplikované nelineární složené funkci, kterou síť aktuálními hodnotami svých parametrů realizuje. Jedná se tedy o netriviální optimalizační problém.

Díky diferencovatelnosti neuronové sítě jakožto složené funkce lze použít gradientní metodu největšího spádu. Její podstatou je sestavení tečného vektoru ke grafu chybové funkce v bodě, jehož souřadnice jsou aktuální váhy. Jejich adaptace pak probíhá v záporném směru gradientu (tečného vektoru, ukazujícího největší spád) dostatečně malým posunem do bodu, kde je chybová funkce menší. Celý postup se opakuje, čímž je limitně dosaženo lokálního minima. V každém kroku t se váhy $W(t)$ adaptují na $W(t+1)$ následovně:

$$w_{ij}^{(k)}(t+1) = w_{ij}^{(k)}(t) - \alpha \frac{\partial E(W(t))}{\partial w_{ij}^{(k)}} \quad (6.6)$$

Parametr α se nazývá parametr učení. Je jím laděna velikost adaptačního kroku a tedy rychlost učení. Pro vyšší hodnoty probíhá minimalizace chybové funkce rychleji, ale hrozí přeskočení lokálního minima a následná oscilace učící chyby. V případě malých hodnot

může ale v lokálním minimu učení ustrnout a znemožnit tak nalezení lepšího suboptima.

Ikdyž existuje mnoho variant této gradientní metody (viz např. [11]), východiskem pro všechny je optimalizovaná algoritmizace výpočtu parciálních derivací výstupů sítě podle jednotlivých vah a prahů. Velmi rychlé vyčíslování hodnot gradientu lze znázornit schématem "zpětného šíření", které dalo název celému algoritmu "back-propagation". Samotné schéma ale neplyne přímo z prvotního výpočtu podle věty o derivaci složené funkce. Teprve po vhodném přeuspořádání výsledných vzorců je patrný velký rozsah stejných operací, které je nutno provádět při postupném derivování podle různých vah sítě. Díky specifickému schématu vrstevnaté sítě tak vyplyne algoritmus (details viz níže), který je v literatuře často uváděn bez odvození a čtenáři tak uniká jeho vyjímečná efektivita oproti derivování "přímo podle věty".

Pro zjednodušení matematického zápisu může být každý práh ekvivalentně reprezentován fiktivním neuronem s konstantním jednotkovým výstupem, od něhož vede synapse, jejíž váha je rovna hodnotě nahrazovaného prahu. Dále tedy není nutné prahy bez újmy na obecnosti uvažovat. Označme pouze fiktivní vstup indexem nula a rozšířme matici vah o nultý sloupec $w_{i0}^{(k)} = b_i^{(k)}$. Sumace ve vzorcích pro výpočty potenciálů neuronů budou tedy probíhat od nuly s jednotkovou hodnotou fiktivního vstupu $y_p^{(k)}(0)=1$ pro každý vzor p .

Díky linearitě operace derivace lze dále obecné vyčíslování gradientu celkové kvadratické chyby omezit na případ vybraného učicího vzoru p a derivovat pouze jeden sčítanec E_p . Adaptaci vah je možné provádět cyklicky pro jednotlivé učicí vzory samostatně (tzv. učení "online"), ale jako stabilnější se ukazuje korekce na základě hodnot vzniklých součtem dílčích gradientů kvadratických chyb E_p všech tréninkových dat zvláště (tzv. učení "offline"), tj. gradientem celkové chyby E . Pro zjednodušení značení tedy uvažujme jediný učicí vzor a chybu $E=E_p$, čímž odpadá potřeba psaní indexu vzoru p .

Z důvodů, které vyplynou až na závěr, začneme výpočet gradientu nejprve derivacemi podle vah neuronů výstupní (N -té) vrstvy a dílčí výsledek označme $\delta_i^{(N)}$:

$$\frac{\partial E}{\partial w_{ij}^{(N)}} = \frac{\partial E}{\partial y^{(N)}(i)} \frac{\partial y^{(N)}(i)}{\partial \xi_i^{(N)}} \frac{\partial \xi_i^{(N)}}{\partial w_{ij}^{(N)}} = y^{(N-1)}(j) f'_N(\xi_i^{(N)}) (y^{(N)}(i) - d(i)) = y^{(N-1)}(j) \delta_i^{(N)} \quad (6.7)$$

Pokračujme další vrstvou ve směru ke vstupům, tj. derivacemi podle vah vrstvy $N-1$:

$$\begin{aligned} \frac{\partial E}{\partial w_{jk}^{(N-1)}} &= \sum_{i=1}^{M_N} \frac{\partial E}{\partial y^{(N)}(i)} \frac{\partial y^{(N)}(i)}{\partial \xi_i^{(N)}} \frac{\partial \xi_i^{(N)}}{\partial w_{jk}^{(N-1)}} = \sum_{i=1}^{M_N} (y^{(N)}(i) - d(i)) f'_N(\xi_i^{(N)}) w_{ij}^{(N)} \frac{\partial y^{(N-1)}(j)}{\partial w_{jk}^{(N-1)}} = \\ &= \sum_{i=1}^{M_N} (y^{(N)}(i) - d(i)) f'_N(\xi_i^{(N)}) w_{ij}^{(N)} f'_{N-1}(\xi_j^{(N-1)}) y^{(N-2)}(k) \end{aligned} \quad (6.8)$$

Přeskupením činitelů a substitucemi dostáváme:

$$\frac{\partial E}{\partial w_{jk}^{(N-1)}} = y^{(N-2)}(k) f'_{N-1}(\xi_j^{(N-1)}) \sum_{i=1}^{M_N} (w_{ij}^{(N)} \delta_i^{(N)}) = y^{(N-2)}(k) \delta_j^{(N-1)} \quad (6.9)$$

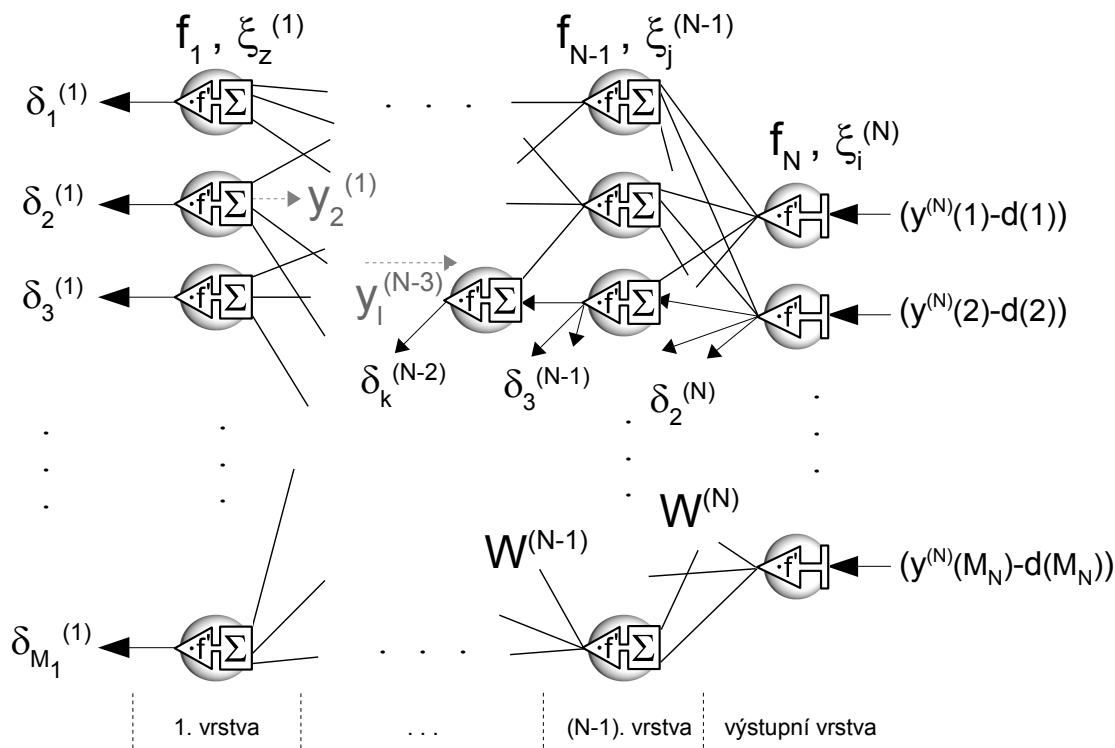
Následuje vrstva N-2:

$$\begin{aligned} \frac{\partial E}{\partial w_{kl}^{(N-2)}} &= \sum_{i=1}^{M_N} \frac{\partial E}{\partial y^{(N)}(i)} \frac{\partial y^{(N)}(i)}{\partial \xi_i^{(N)}} \frac{\partial \xi_i^{(N)}}{\partial w_{kl}^{(N-2)}} = \sum_{i=1}^{M_N} \left(\frac{\partial E}{\partial y^{(N)}(i)} \frac{\partial y^{(N)}(i)}{\partial \xi_i^{(N)}} \sum_{j=1}^{M_{N-1}} w_{ij}^{(N)} \frac{\partial y^{(N-1)}(j)}{\partial w_{kl}^{(N-2)}} \right) = \\ &= \sum_{i=1}^{M_N} \left((y^{(N)}(i) - d(i)) f'_N(\xi_i^{(N)}) \sum_{j=1}^{M_{N-1}} (w_{ij}^{(N)} f'_{N-1}(\xi_j^{(N-1)}) w_{jk}^{(N-1)} f'_{N-2}(\xi_k^{(N-2)}) y^{(N-3)}(l) \right) \end{aligned} \quad (6.10)$$

Dalšími úpravami dospějeme k:

$$\begin{aligned} \frac{\partial E}{\partial w_{kl}^{(N-2)}} &= y^{(N-3)}(l) f'_{N-2}(\xi_k^{(N-2)}) \sum_{j=1}^{M_{N-1}} \left(w_{jk}^{(N-1)} f'_{N-1}(\xi_j^{(N-1)}) \sum_{i=1}^{M_N} (w_{ij}^{(N)} f'_N(\xi_i^{(N)})) (y^{(N)}(i) - d(i)) \right) = \\ &= y^{(N-3)}(l) f'_{N-2}(\xi_k^{(N-2)}) \sum_{j=1}^{M_{N-1}} (w_{jk}^{(N-1)} \delta_j^{(N-1)}) = y^{(N-3)}(l) \delta_k^{(N-2)} \end{aligned} \quad (6.11)$$

Derivace pro další vrstvy směrem ke vstupní se počítají stejným způsobem, přičemž v každé úrovni přibývá jedna vnořená suma do výrazu obdobného (6.10), u něhož rovněž není vhodné zůstat. Záměnou pořadí sumace a uspořádáním členů do přehlednějšího tvaru odpovídajícímu (6.11) totiž vyplyne zmiňované algoritmicke velmi rychlé zpracování gradientní metody zvané back-propagation. Ze vzorců (6.7), (6.9), (6.11) a z analogie pro další vrstvy je zřejmé, že při výpočtu parciálních derivací kvadratické chyby podle vah neuronů vnitřní vrstvy k se používají dílčí výsledky $\delta_i^{(k+1)}$ počítané pro vrstvu $k+1$. Jednotlivé složky gradientu chybové funkce (derivace podle příslušných vah neuronů) je proto výhodné vyčíslovat v pořadí od výstupní ke vstupní vrstvě sítě a používat již spočtené $\delta_i^{(j)}$.



Obr. 6.3: Schéma "zpětného šíření"

Algoritmus lze schematicky zobrazit podobně jako učenou neuronovou síť, avšak s numerickými operacemi probíhajícími v opačném směru a s jinými výpočetními jednotkami (viz obr. 6.3). Na výstup se předkládají rozdíly skutečných a požadovaných výstupů sítě. Tyto odchylky jsou zpracovávány speciálními neurony a distribuovány po synapsích ve směru ke vstupům. Odtud název back-propagation (zpětné šíření chyby). Finální hodnota derivace chybové funkce podle konkrétní váhy $w_{ij}^{(k)}$ se počítá vynásobením šířené "chyby" $\delta_i^{(k)}$ hodnotou $y_j^{(k-1)}$ odpovídající výstupu neuronu, ze kterého vede (v dopředném směru) příslušná synapse, nebo příslušným vstupem sítě v případě váhy první skryté vrstvy.

Speciální neurony v průběhu algoritmu back-propagation provádějí váženou sumaci dílčích výsledků $\delta_i^{(k)}$ a násobení derivací přenosové funkce. Před samotným zpětným šířením je proto potřeba pro všechna tréninková data předpočítat výstupy neuronů celé sítě spolu s derivacemi přenosových funkcí v hodnotách potenciálů pro aktuální adaptační krok t postupné minimalizace učící chyby.

Výpočet parciálních derivací funkce E pomocí algoritmu zpětného šíření lze pak v každém adaptačním kroku shrnout do následujících bodů:

1. Obecný vzorec pro výpočet příslušných derivací má tvar:

$$\frac{\partial E}{\partial w_{ij}^{(k)}} = y^{(k-1)}(j) \delta_i^{(k)} \quad (6.12)$$

2. Algoritmus začíná výpočtem dílčích výsledků $\delta_i^{(k)}$ pro výstupní vrstvu, tj. pro $k=N$:

$$\delta_i^{(N)} = f'_N(\xi_i^{(N)}) (y^{(N)}(i) - d(i)) \quad (6.13)$$

3. Vyčíslení derivací podle vah výstupní vrstvy dosazením $\delta_i^{(N)}$ do vzorce (6.12) (pro $k=N$)

4. Výpočet dílčích výsledků $\delta_i^{(k)}$ rekurzivně pro skrytou vrstvu $k=N-1, N-2, \dots, 1$ a dosazení do (6.12):

$$\delta_i^{(k)} = f'_k(\xi_i^{(k)}) \sum_{j=1}^{M_{k+1}} w_{ji}^{(k+1)} \delta_j^{(k+1)} \quad (6.14)$$

6.5 Maticová interpretace operací uvnitř sítě

Ze vzorce (6.3) definujícího neuron jako výpočetní jednotku je evidentní, že operace probíhající uvnitř sítě lze po jednotlivých vrstvách zapsat formou maticového násobení. Výpočet vektoru potenciálů zvolené vrstvy k je tak možné implementovat jako násobení sloupcového vektoru výstupů neuronů předchozí vrstvy ($k-1$) zleva maticí $W^{(k)}$. Na výsledný vektor se následně po složkách aplikuje přenosová funkce, čímž dostáváme výstupní hodnoty neuronů vrstvy k . Tato interpretace je výhodná nejen v prostředí Matlab, kde výpočet výstupů sítě může být realizován jednoduchým kódem i pro více vstupních dat (uspořádaných do jedné matice) najednou.

Schéma zpětného šíření lze zapsat analogicky, matice vah jednotlivých vrstev sítě je ale třeba transponovat a působení přenosovou funkcí nahradit násobením po složkách předpočítanými derivacemi sigmoidy v potenciálech neuronů (viz vzorec 6.14).

6.6 Zrychlení adaptace vah

Jak je patrné z předešlého, algoritmus zpětného šíření (back-propagation) je velmi rychlou implementací výpočtu gradientu chybové funkce E . Následná adaptace vah podle vzorce (6.6) je ale v praxi velmi pomalá. Příčinou je nutnost kompromisní volby parametru učení α . Vyšší hodnoty sice zaručují procházení chybové nadplochy většími kroky, což příznivě ovlivní rychlost procesu, ale způsobují možné "přeskočení" lokálních minim. Naopak malé hodnoty adaptaci, i přes pravděpodobné nalezení vyhovujících vah, časově neúnosně prodlužují.

Řešením je zavedení adaptivního parametru učení, který je korigován v závislosti na vývoji chybové funkce. Pokud dojde k poklesu učící chyby, jeho hodnota se obecně zvýší a naopak. Pokud nastane změna znaménka některé složky gradientu, vrací se algoritmus o krok zpět (např. metoda Super SAB) a opakovanou změnu vah provede o menší vzdálenost (tj. sníží parametr učení), čímž se často i vícekrát zasebou snaží nepřeskočit pravděpodobné lokální minimum. Adaptivní parametr učení se zavádí globálně (stejný pro všechny váhy sítě) a lokálně, kdy každá váha sítě má svůj speciální, což se v praxi ukazuje jako výhodnější. Podrobný přehled jednotlivých metod je uveden v [11]. Kromě již zmiňovaného Super SAB algoritmu mezi ně patří např. Silva-Almeida a Delta-bar-delta algoritmus. Tyto metody jsou zásadně rychlejší než klasický back-propagation s pevným parametrem učení a umožňují významnou úsporu strojového času.

V praxi se velmi dobře osvědčila rovněž varianta Silva-Almeida algoritmu zvaná **resilient back-propagation**. Váhy sítě adaptuje pouze pomocí proměnlivých parametrů učení a znamének parciálních derivací chybové funkce podle příslušných vah, čímž zrychluje proces učení především v plochých oblastech účelové funkce a v blízkosti lokálních minim. Z důvodu zamezení nadměrného zvýšení, či snížení rychlosti adaptace se zavádí konstanty α_{min} a α_{max} omezující rozsah hodnot parametrů učení. V kroku t jsou parametry učení $\alpha_{ij}^{(k)}$ příslušné váze $w_{ij}^{(k)}$ korigovány následovně:

$$\alpha_{ij}^{(k)}(t+1) = \begin{cases} \min\{u \cdot \alpha_{ij}^{(k)}(t), \alpha_{max}\} & \text{pokud } \frac{\partial E(W(t))}{\partial w_{ij}^{(k)}} \cdot \frac{\partial E(W(t-1))}{\partial w_{ij}^{(k)}} > 0 \\ \max\{d \cdot \alpha_{ij}^{(k)}(t), \alpha_{min}\} & \text{pokud } \frac{\partial E(W(t))}{\partial w_{ij}^{(k)}} \cdot \frac{\partial E(W(t-1))}{\partial w_{ij}^{(k)}} < 0 \\ \alpha_{ij}^{(k)}(t) & \text{jinak} \end{cases} \quad (6.15)$$

Pokud tedy po poslední adaptaci nedošlo ke změně znaménka příslušné souřadnice gradientu, odpovídající parametr učení je násoben konstantou $u > 1$, tj. zvětšen maximálně na hodnotu α_{max} . Pokud změna znaménka nastala, je násoben konstantou $d < 1$, tj. zmenšen na hodnotu ne menší než α_{min} . V případě nulového součinu parciálních derivací v (6.15) zůstává parametr učení nezměněn, přičemž příslušné váhy jsou spolu s případem neměnného znaménka adaptovány podle vzorce:

$$w_{ij}^{(k)}(t+1) = w_{ij}^{(k)}(t) - \alpha_{ij}^{(k)}(t) \cdot \text{sgn}\left(\frac{\partial E(W(t))}{\partial w_{ij}^{(k)}}\right) \quad \text{pokud } \frac{\partial E(W(t))}{\partial w_{ij}^{(k)}} \cdot \frac{\partial E(W(t-1))}{\partial w_{ij}^{(k)}} \geq 0 \quad (6.16)$$

Pokud ke změně znaménka došlo (což znamená, že mohlo být přeskočeno lokální minimum, nejedná-li se o lokální extrém typu "sedlo"), příslušná váha není adaptována.

Hledání lokálních minim je tedy řízeno na základě předchozího vývoje gradientu chybové funkce, přičemž není potřeba se striktně řídit směrem největšího spádu a postačí váhy adaptovat souhlasně se znaménkem souřadnic gradientu. Délka adaptačního kroku je určena pouze proměnlivými parametry učení, které reflektují dosavadní vývoj procesu minimalizace učící chyby.

Do první skupiny rychlých algoritmů je možné zahrnout i tzv. zpětné šíření s momentem, které potlačením oscilací učící chyby zrychluje nalezení lokálního minima ležícího v "úzkém údolí" chybové nadplochy. Při adaptaci vah bere v úvahu kromě aktuální hodnoty gradientu chybové funkce také předchozí změny vah. Do vzorce pro výpočet nových hodnot vah přibývá oproti klasické BP-verzi (6.6) **momentový člen**:

$$w_{ij}^{(k)}(t+1) = w_{ij}^{(k)}(t) - \alpha \frac{\partial E(W(t))}{\partial w_{ij}^{(k)}} + \alpha_m (w_{ij}^{(k)}(t) - w_{ij}^{(k)}(t-1)) \quad (6.17)$$

Je tak dosaženo vyšší setrvačnosti hodnot vah a tím i zmiňované menší oscilace chybové funkce. Parametr α_m ladí míru vlivu přidaného členu a nazývá se **moment učení**.

Metody druhého řádu a relaxační metody [11] již nevycházejí z klasického algoritmu back-propagation. Využívají standardní techniky numerické optimalizace nebo perturbace vah. Newtonovské a pseudonewtonovské metody vycházejí z aproximace chybové funkce pomocí Taylorovy řady a narážejí na problém inverze hessianové matice parciálních derivací druhého řádu, který řeší dalšími aproximacemi. Levenberg-Marquardtův algoritmus pak kombinuje gradientní a Newtonovské metody. Tyto přístupy ale v rámci práce nebyly aplikovány.

6.7 Volba tréninkových dat

Vhodně naučené BP-sítě by měly přiměřeně zareagovat i na předložená neznámá data. Typicky by měl nový vstup vést k výstupu podobnému pro učící vzory, které mají vstupní hodnoty nejbližší nově předloženému. Tato generalizační vlastnost umožňuje učit síť na reprezentativní množině vstupů a požadovaných výstupů a získávat dobré výsledky i bez učení na všechny možné vstupně-výstupní hodnoty, kterých může být nekonečně mnoho. Proto je volba vhodných tréninkových dat klíčovým faktorem pro finální chování multidimenzionální funkce, kterou představuje naučená neuronová síť. Množina učících vzorů by tedy měla vhodně a dostatečně pokrývat oblast možných vstupů.

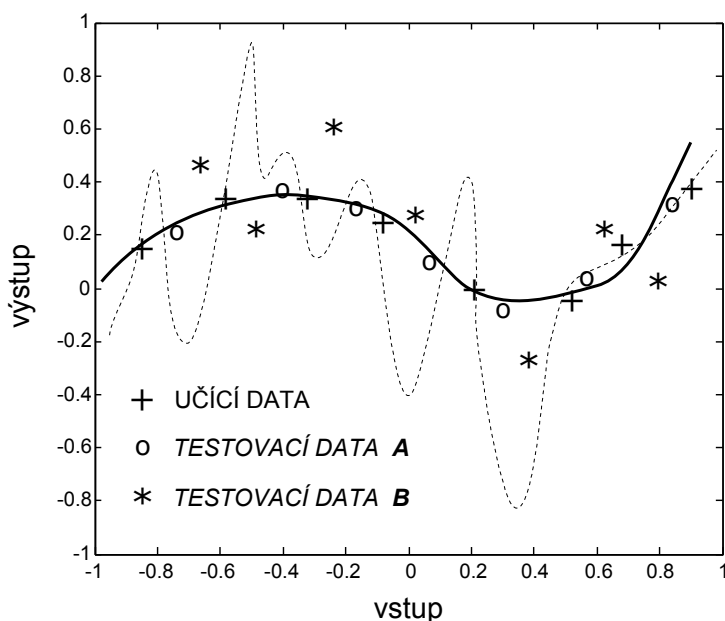
Jedním ze základních předpokladů relevantních vlastností naučené sítě je jednotné měřítko vstupních a výstupních veličin. V opačném případě by síť nereagovala např. na změnu vstupů, které mají podstatně menší rozptyl než jiné. Podobně by relativně malá chyba mohla v nevhodně zvoleném měřítku absolutně znamenat chybu zásadní a nebo naopak. Před samotným učením je tedy nutné nejprve provést standardizaci, tj. sjednotit měřítko všech vstupních a výstupních veličin. Jedná se o lineární transformaci dat (vstupů i výstupů) zaručující jejich nulovou střední hodnotu a jednotkovou směrodatnou odchylku.

Dalším vhodným předzpracováním dat je analýza hlavních os a následná eliminace korelovaných parametrů např. pomocí faktorové analýzy (viz kap. 5). Tímto způsobem lze provést žádanou redukci dimenze vstupního prostoru spolu s potlačením informačního šumu mezi proměnnými. U neuronových sítí učených na optimalizovaných datech lze pak očekávat rychlejší učení a lepší generalizační vlastnosti.

6.8 Problém přeučení a zlepšení generalizace

Zřejmě největším problémem, týkajícím se praktické aplikace neuronových sítí, je tzv. přeučení (overfitting). Vzniká již v samotném procesu učení a má za následek nevhodné vlastnosti při generalizaci [12]. Přeučenou síť lze charakterizovat (*def.*) jako takovou, která sice vykazuje velmi malé výstupní odchylky v případě tréninkových dat, ale pro neznámé vstupy naopak selhává. Říkáme, že síť špatně generalizuje.

Typický případ špatné generalizace (ozn. **přeučení 1.typ**) uvádí obr. 6.4. Síť s jedním vstupem a výstupem je učena aproximovat závislost mezi tréninkovými daty, označenými křížky. "Dobře aproximující" verze sítě je ilustrována spojitou čarou. Velmi těsně prochází kolem testovacích dat (skupina A), zobrazených kroužky. Tečkovaně je naopak zobrazena možná verze velmi přeučené sítě, která by v praxi nebyla použitelná.



Obr. 6.4: Ilustrace typů přeučení

Mnohdy opomíjený typ přeučení (ozn. **2.typ**), vyhovující výše uvedené definici, lze ilustrovat příkladem poměrně hladce aproximující sítě a specifickou testovací množinou. Použijme ještě jednou tutéž síť, jejíž funkční závislost je na obr. 6.4 zobrazena spojitou čarou. Jak již bylo řečeno, jedná se o "dobře aproximující" verzi sítě, učícími daty prokládá velmi hladkou závislost, což je velmi žádáno, ale generalizace opět selhává. Složitost konkrétní praktické úlohy totiž může způsobit, že jsou k dispozici pouze data, která nedostatečně pokrývají parametrický prostor daného problému. Pak je možné, že zvolené testovací body (skupina B - viz obr. 6.4) neleží blízko spojnic mezi nejbližšími učícími a síť udává příliš odlišné hodnoty, přestože by byla v případě jiných testovacích dat velmi dobře naučená a úspěšně zobecňující.

Je evidentní, že pojem přeučení nezávisí pouze na aproximačních vlastnostech naučené sítě, ale je dán velkou měrou volbou tréninkových a testovacích dat. V praxi bývá poměrně složité oba typy přeučení odlišit. Zvláště v případech vysoké dimenze parametrického prostoru je analýza sousedících bodů a průběhu naučené závislosti velmi náročná a komplikovaná. Znalost typu přeučení je ovšem pro řešení problému klíčová. Vývoj metodologie posouzení vhodnosti dané množiny dat pro aplikaci umělých neuronových sítí je více než žádoucí a představuje jeden ze směrů budoucího výzkumu. Jistým vodítkem pro

odhad typu přeučení je v současnosti analýza citlivosti naučených sítí (viz kap. 6.11). Vysoké hodnoty parciálních derivací jejich výstupů podle vstupů ukazují spíše na první typ. Hladká funkční závislost se naopak vyznačuje hodnotami středními a malými.

Základní možností jak zamezit přeučení 1. typu je sledování vývoje chyby sítě na tzv. validační množině dat, která se liší od tréninkové. Validační chyba během počáteční fáze učení obvykle klesá, podobně jako učící. Nicméně, pokud nastává typické přeučení, chyba na validační množině začne naopak stoupat. Pokud se validační chyba zvyšuje po více než předem daný počet učících cyklů, proces učení se předčasně zastaví a jako výsledné jsou brány v úvahu váhy sítě při minimální chybě na validační množině. Tento postup ale neřeší samotný problém přeučení, pouze ho detekuje. Lepším postupem je pochopitelně zahrnout validační data do učících a zajistit dobrou generalizaci jiným, účinnějším způsobem, např. optimalizovaným učením. V případě přeučení 2. typu by validační množina problém nevyřešila, dokonce by proces učení mohla znemožňovat.

Jednou z příčin klasického přeučení 1. typu je nárůst velikostí vah v průběhu učení. Na každou jejich adaptaci podle (6.6). lze pohlížet jako na přičtení náhodných hodnot, které způsobují nárůst celkového rozptylu všech vah sítě. S ním se zvyšuje citlivost jednotlivých neuronů na změnu vstupů a v důsledku tedy i složitost vícerozměrné funkce, která je sítí modelována.

Efektivní metodou pro potlačení nežádoucí citlivosti neuronů je učení se současnou regularizací. Ikdyž existuje více jejích modifikací, řada numerických experimentů prokázala dobré vlastnosti sítí naučených pomocí základní varianty algoritmu, kdy je spolu s minimalizací chybové funkce požadována i triviální minimalizace sumy kvadrátů všech vah. Účelová funkce je tedy za tímto účelem modifikována sumou přes všechny váhy sítě:

$$msw = \frac{1}{N_W} \sum_{j=1}^{N_W} w_j^2, \text{ kde } N_W \text{ je celkový počet vah sítě} \quad (6.18)$$

Do chybové funkce se suma začleňuje následujícím způsobem:

$$E_{REG} = \nu E + (1 - \nu) msw \quad (6.19)$$

Zavedením chybové funkce E_{REG} je podstatně omezen nárůst vah při učení a tím i neadekvátní reakce sítě na změnu vstupů. Naučená funkční závislost má tedy hladší průběh a klesá tendence sítě k přeučení. Schéma algoritmu zpětného šíření se touto modifikací nemění. Díky linearitě operátoru gradientu se k vypočteným parciálním derivacím přičte jen násobek příslušné váhy. Jediným problémem výše uvedené varianty regularizace je optimální volba parametru ν . Pokud by měl regularizační člen msw příliš velkou váhu, učící chyba by nebyla minimalizována. V opačném případě by se efekt potlačení růstu vah neprojevil a učení by probíhalo podobně jako bez regularizace.

Velký potenciál k přeučení je rovněž dán příliš velkou architekturou sítě. Vyšší počet neuronů umožňuje síti aproximovat složitější závislosti a může vést i k nežádoucí citlivosti. Obecně ale nemají malé sítě takovou tendenci k přeučení jako velké, použité pro stejná data. V praxi se optimální architektura pro konkrétní problém předem těžko odhaduje, ale je třeba hledat co možná nejmenší počet neuronů ve skrytých vrstvách, které umožní dostatečně rychlou konvergenci učící chyby na požadovanou úroveň.

6.9 Vážený gradient

Při výpočtu směru adaptace vah metodou **offline**, kdy výsledný gradient ∇E je součtem jednotlivých dílčích ∇E_p , není brána v úvahu absolutní velikost chyby sítě na konkrétním učícím vzoru. Přesnost aproximace tak nemusí být v tréninkové množině rozdělena rovnoměrně a odchylka skutečného od požadovaného výstupu malého počtu vzorů může značně přesahovat průměr kvadratických odchylek MSE pro všechna učící data. Tento jev může souviset i s počínajícím přeučením 1.typu a znamená lokální zhoršení přesnosti aproximace.

Již při samotném učení je proto výhodné korigovat adaptaci vah směrem vedoucím k výraznější minimalizaci chyby pro učící vzory s větší odchylkou skutečného od požadovaného výstupu. Jinak řečeno, výsledný gradient sčítat s proměnlivými vahami reflektujícími chybu na příslušném vzoru. Hodnoty těchto vah představují jednotlivé poměrné velikosti sumy kvadrátů odchylek E_p všech výstupů na učícím vzoru p vzhledem k celkové chybě E . Gradient ∇E_p příslušný k vzoru p s velkou odchylkou od požadovaného výstupu tak přispívá do celkového ∇E větší měrou, než gradienty odpovídající lépe naučeným datům z tréninkové množiny. Míru "vážení" gradientu lze modelovat parametrem v_w z intervalu $(0,1)$. Vzorec pro výpočet souřadnic výsledného váženého gradientu G_w lze zapsat následovně:

$$G_w = (1 - v_w) \nabla E + v_w \sum_{p=1}^P \frac{E_p}{E} \cdot \nabla E_p \quad (6.20)$$

Více jsou tak minimalizovány větší chyby, čímž je síť jistým způsobem nucena k hladší aproximaci a může být potlačeno i počínající přeučení.

6.10 Volba počátečních vah

Vhodnou volbou počátečních vah lze do značné míry ovlivnit průběh učení neuronové sítě spolu s její citlivostí na změnu vstupních dat. Dobře známou heuristikou pro vrstevnaté sítě je inicializace učení s váhami rovnoměrně volenými v intervalu $\langle -\theta, \theta \rangle$ [11]. Pokud se výchozí potenciály neuronů pohybují v mezích největšího spádu sigmoidy, tj. v symetrickém intervalu kolem nuly, její derivace je blízká maximu (tj. hodnotě 0.25 pro přenosovou funkci f_{SIG}). Gradient chybové funkce nabývá vysokých hodnot, čímž dochází k výraznějším změnám vah na začátku učení, přičemž neurony zůstávají dostatečně citlivé. Meze uvedeného intervalu $\langle -\theta, \theta \rangle$ by proto měly být voleny tak, aby se hodnoty potenciálů neuronů nepohybovaly v málo strmých, nebo až plochých oblastech konkrétního typu sigmoidální funkce.

Považujeme-li potenciál neuronu za náhodnou veličinu, vyplývá z předchozího požadavek jeho nulové střední hodnoty. Oblast největšího spádu sigmoidy pokrývají obdobně hodnoty s jednotkovou směrodatnou odchylkou (v případě přenosové funkce f_{SIG}). Volbou vah by proto měl být zajištěn rozsah potenciálů těchto parametrů. Příliš velké váhy vedou k saturaci neuronů, kdy neurony nelze dále učit (váhy se stále zvětšují) a síť se dostává do plochých oblastí chybové funkce. Váhy ale současně nemohou být příliš malé, čímž by absolutní velikost složek gradientu v průběhu algoritmu zpětného šíření podstatně klesala vlivem násobení malými čísly a učení by bylo rovněž paralyzováno.

Různé empirické pokusy ukázaly, že neexistuje jedno θ , optimální pro všechny případy architektury, ale velmi široký interval hodnot s téměř stejnou efektivností konvergence. Jelikož mají různé volby počátečních vah především v prvních učících cyklech za důsledek

velmi podobný průběh minimalizace účelové funkce, je obtížné jednotlivé přístupy srovnávat ohledně rychlosti učení. Pokud ale budeme sledovat např. kvalitu generalizace, souvislost přeučení s příliš velkými vahami se projeví zcela zřetelně.

Pojem "přílišné velikosti" vah je ale relativní. Na vstupy neuronů můžeme pohlížet jako na nezávislé náhodné veličiny (v případě první vrstvy po standardizaci dat s nulovou střední hodnotou a jednotkovým rozptylem), které jsou násobeny vahami a sčítány. Výsledný rozptyl potenciálů tak pro pevnou směrodatnou odchylku vah záleží velkou měrou na počtu sčítanců, tj. vstupů neuronu. Interval velikostí vah $\langle -\theta, \theta \rangle$, zaručující vhodný rozptyl potenciálů, je tedy nutné odvozovat od konkrétního počtu vstupů jednotlivých neuronů. Váhy v rozmezí např. $\langle -0.3, 0.3 \rangle$ mohou proto být pro malou síť optimální, ale pro velký počet neuronů způsobují nepřiměřený rozptyl jejich potenciálů.

Přístupme nyní k samotnému odvození mezí intervalu možných hodnot vah, které zajistí požadované rozmezí potenciálů neuronů. Váhy $w_{ij}^{(k)}$ volíme pro každou vrstvu k zvlášť jako vzájemně nezávislé, stejně rozdělené náhodné veličiny s rovnoměrným rozdělením na intervalu $\langle -\theta_k, \theta_k \rangle$, nezávislé na vzorech. Konkrétní hodnota váhy je tedy realizace náhodné veličiny, která má nulovou střední hodnotu, tj. $E(w_{ji}^{(k)})=0$ pro pevné j . Z nezávislosti $w_{ij}^{(k)}$ a výstupů (resp. vstupů) neuronů $y^{(k-1)}(i)$, vypočítaných z obecného vstupu sítě $y^{(0)}(i)$ potom dále plyne:

$$E(\xi_j^{(k)}) = E\left(\sum_{i=0}^{M_k} w_{ji}^{(k)} y^{(k-1)}(i)\right) = \sum_{i=0}^{M_k} E(w_{ji}^{(k)}) \cdot E(y^{(k-1)}(i)) = 0 \quad (6.21)$$

Předpokládaným rozdělením vah je tedy zaručena i požadovaná nulová střední hodnota potenciálu bez ohledu na očekávané hodnoty vstupů.

Odvoďme obecné vyjádření rozptylu σ_j^2 potenciálů $\xi_j^{(k)}$ pomocí (6.21):

$$\sigma_j^2 = E(\xi_j^{(k)})^2 - E^2(\xi_j^{(k)}) = E\left(\sum_{i=0}^{M_k} w_{ji}^{(k)} y^{(k-1)}(i)\right)^2 = E\left(\sum_{i=0}^{M_k} \sum_{l=0}^{M_k} w_{ji}^{(k)} w_{jl}^{(k)} y^{(k-1)}(i) y^{(k-1)}(l)\right) \quad (6.22)$$

Z již zmiňované nezávislosti vah a vstupů dále plyne:

$$\sigma_j^2 = \sum_{i=0}^{M_k} E(w_{ji}^{(k)})^2 \cdot E(y^{(k-1)}(i))^2 \quad (6.23)$$

Podle předpokladu je váha $w_{ij}^{(k)}$ náhodná veličina s rovnoměrným rozdělením na intervalu $\langle -\theta_k, \theta_k \rangle$ s hustotou pravděpodobnosti $h = 1/2\theta_k$. Proto platí:

$$E(w_{ji}^{(k)})^2 = \int_{-\theta_k}^{\theta_k} (w_{ji}^{(k)})^2 \cdot \frac{1}{2\theta_k} dw_{ji}^{(k)} = \left[\frac{(w_{ji}^{(k)})^3}{6\theta_k} \right]_{-\theta_k}^{\theta_k} = \frac{\theta_k^2}{3} \quad (6.24)$$

Vztah (6.23) lze tedy upravit:

$$\sigma_j^2 = \frac{\theta_k^2}{3} \sum_{i=0}^{M_k} E(y^{(k-1)}(i))^2 \quad (6.25)$$

Pro parametr θ_k pak dostáváme:

$$\theta_k = \sqrt{\frac{3\sigma_j^2}{\sum_{i=0}^{M_k} E(y^{(k-1)}(i))^2}} \quad (6.26)$$

Protože směrodatnou odchylku σ_j požadujeme jednotkovou a nultý vstup neuronu je fiktivní, rovněž jednotkový, pro obecnou vrstvu k platí:

$$\theta_k = \sqrt{\frac{3}{1 + \sum_{i=1}^{M_k} E(y^{(k-1)}(i))^2}} \quad (6.27)$$

V případě první skryté vrstvy ($k=1$), kde $y^{(0)}(i)$ jsou standardizovaná učící data (s nulovou střední hodnotou a jednotkovou směrodatnou odchylkou), se vzorec zjednodušuje:

$$\theta_1 = \sqrt{\frac{3}{M_1 + 1}} \quad (6.28)$$

Pro další skryté vrstvy se problém komplikuje. Ve výrazu (6.27) není obecně známá střední hodnota druhé mocniny vstupů neuronů. Víme pouze, že potenciály předchozí vrstvy jsou stejně rozdělené náhodné veličiny s nulovou střední hodnotou a jednotkovým rozptylem (tak byla provedena volba vah neuronů předchozí vrstvy). Tyto charakteristiky náhodných veličin ale po působení nelineární funkce (sigmoidou) nelze obecně vyjádřit bez znalosti jejich hustot pravděpodobností.

Pro dostatečný počet neuronů by bylo možné aplikovat Centrální limitní teorém [11] a zmiňované hustoty pravděpodobností aproximovat normálním rozdělením. Znalost konkrétních učících dat umožňuje cílenější řešení. Je jím statistický odhad střední hodnoty. V dalších vrstvách ($k=2, 3, \dots, M_k$) se tedy pro všechny tréninkové vzory určují výstupy neuronů vrstvy předchozí (za použití již vygenerovaných vah) a aritmetický průměr jejich kvadrátů:

$$\theta_k \approx \sqrt{\frac{3}{1 + \frac{1}{P} \sum_{i=1}^{M_k} \sum_{p=1}^P (y_p^{(k-1)}(i))^2}} \quad (6.29)$$

Zajistíme-li touto volbou vah nulovou střední hodnotu a jednotkový rozptyl potenciálů neuronů, nezačíná učení v ploché oblasti chybové funkce. Pro konkrétní tréninkové vzory tak učení startuje v bodě vahového prostoru, ve kterém má chybová funkce dostatečný spád. Při gradientním algoritmu tak zřejmě odpadá počáteční fáze „hledání údolí“.

Metoda nastavuje počáteční váhy cíleně pro konkrétní učící data postupnou optimalizací potenciálů neuronů jednotlivých vrstev. Nepoužívá odhady hustoty pravděpodobnosti na základě centrálního limitního teorému, které zejména pro menší architektury sítí nejsou přesné. Dále nevyužívá jakékoliv nerovnosti pro omezení velikosti potenciálu. Jedinou aproximací po analytickém odvození je finální odhad střední hodnoty aritmetickým průměrem.

Jelikož se potenciály neuronů první adaptací vah gradientní metodou nepředvídatelně mění (v různých výchozích bodech vahového prostoru mohou být diametrálně odlišné gradienty), je jakékoliv srovnání metod pro inicializaci parametrů sítí z hlediska vývoje učící chyby irelevantní. S ohledem na požadované charakteristiky startovních potenciálů neuronů se metoda jeví jako optimální, protože parametry pravděpodobnostního rozdělení vah nastavuje cíleně, na základě konkrétních učících dat.

Nový algoritmus generující inicializační váhy byl implementován v prostředí Matlab a porovnán s procedurami knihovny Neural Network Toolbox, které nastavují váhy nevhodně a v mnohých případech tak způsobují silné přeučení. Ukazuje se, že nový přístup

riziko přeučení významně snižuje a spolu s regularizací (viz kap. 6.8) a optimalizací architektury představuje úspěšnou metodologii pro nalezení konfigurace sítě s uspokojivými generalizačními vlastnostmi.

6.11 Citlivostní analýza

Volba vhodných vstupních parametrů je stěžejní otázkou nejen pro klasifikační systémy. Problém výběru spočívá v identifikaci významných charakteristik a zanedbání ostatních, které v původní objemné sadě parametrů nesou převážně redundantní informaci. Některé z charakteristik mohou být pro řešení konkrétní úlohy zcela nevýznamné a nebo vzájemně korelované. Navíc mezi nimi mohou existovat složitější závislosti, které jsou klasickými metodami, jako např. korelační analýza, nepostižitelné. Velmi užitečné možnosti redukce redundantních parametrů poskytují naopak metody citlivostní analýzy neuronových sítí.

Často používaným přístupem při volbě parametrů pro systémy s jedním výstupem je založen na výpočtu marginální míry významu pro každý parametr zvlášť. V praxi ale často nejsou vstupní charakteristiky vzájemně nezávislé a výstup systému může záviset spíše na vztazích mezi vstupy, než na vstupních hodnotách samotných. Pokud je počet vstupních parametrů malý, mohou být pro nalezení jejich optimální podmnožiny otestovány všechny možné kombinace a podobné téměř vyčerpávající (quasi-exhaustive) metody. Počet možných kombinací ale s přibývajícimi vstupy rychle roste. Proto Fidalgo navrhl alternativní přístup pro volbu podmnožiny charakteristik (Alternative Feature Subset Selection Method, ozn. AFSSM), který na rozdíl od jiných metod nevychází z lineárních korelací mezi vstupy a výstupy neuronové sítě [13]. Podstatou AFSSM je výpočet tzv. citlivostních koeficientů. Pomocí zavedeného značení lze kroky metody popsat následovně:

- Učení neuronové sítě se všemi parametry (vstupy), které jsou k dispozici.
- Výpočet citlivostních koeficientů s_{ij} , definovaných průměry absolutních hodnot parciálních derivací pro zvolenou datovou množinu:

$$s_{ij} = \frac{1}{P} \sum_{p=1}^P \left| \frac{\partial y_p^{(N)}(j)}{\partial x_p(i)} \right| \quad (6.30)$$

- Eliminace parametrů, jejichž citlivostní koeficienty mají nízké hodnoty.

Z obecných vlastností parciálních derivací a neuronových sítí je zřejmé, že pro danou aproximovanou závislost je podstatná část vstupní informace skrytá v parametrech s nejvyššími hodnotami $s_{i,j}$. Jednotlivé vstupy, které významně ovlivňují výstupy sítě, mají podstatně vyšší příslušné parciální derivace, než parametry, představující převážně informační šum. V praxi se ukazuje, že po eliminaci těchto, z hlediska naučené aproximace nevýznamných, parametrů, mají redukované sítě ve smyslu učící chyby lepší vlastnosti.

Rozdíly mezi hodnotami citlivostních koeficientů význačných a ostatních parametrů se s přibývajícím šumem zmenšují. Jestliže jsou nedůležité vstupy eliminovány a pro opakované učení použity zbývající parametry, chyba sítě lépe konverguje, což potvrzuje přínos eliminace vstupů, které se vyznačují malými hodnotami citlivostních koeficientů a představují šum, nebo nevýznamnou informaci [13].

Citlivostní analýza naučených BP-sítí umožňuje podstatnou redukci jejich architektury. Tato metoda optimalizace vstupů vykazuje lepší výsledky než mnoho klasických přístupů k výběru parametrů. Navíc není nutné zpracovávat hodnoty všech původních proměnných a transformovat je, jako např. u metody hlavních os. Po tréninku dosahuje síť

s redukovanou topologií častokrát lepších výsledků než verze s původními vstupními proměnnými.

Další výhodou AFSSM je možnost porovnání různých verzí sítí úspěšně naučených pro řešení konkrétní úlohy. Kromě informace o význačných vstupních parametrech lze na jejím základě zvažovat i možné přeučení a aplikovat síť, jejíž citlivost nejlépe vyhovuje daným požadavkům. Schopnost generalizovat také často souvisí s citlivostí, kterou lze různými modifikacemi učícího algoritmu ovlivňovat.

Výpočet citlivostních koeficientů

Ideu zpětného šíření lze použít i pro výpočet citlivostních koeficientů, které jsou sumou absolutních hodnot parciálních derivací všech výstupů sítě podle jednotlivých vstupů. Jde o derivování složené funkce obdobné struktury jako v případě chybové funkce (6.4). Teorie i praxe ukazují, že pro aproximaci dané funkce postačí neuronová síť se dvěma skrytými vrstvami o dostatečném počtu neuronů se sigmoidálními přenosovými funkcemi. Vyjádření obecného tvaru sčítanců citlivostního koeficientu můžeme tedy omezit na případ $N=3$:

$$\begin{aligned} \frac{\partial y^{(3)}(i)}{\partial x(l)} &= f_3'(\xi_i^{(3)}) \sum_{j=1}^{M_2} w_{ij}^{(3)} \frac{\partial y^{(2)}(j)}{\partial x(l)} = f_3'(\xi_i^{(3)}) \sum_{j=1}^{M_2} \left(w_{ij}^{(3)} f_2'(\xi_j^{(2)}) \sum_{k=1}^{M_1} w_{jk}^{(2)} \frac{\partial y^{(1)}(k)}{\partial x(l)} \right) = \\ &= f_3'(\xi_i^{(3)}) \sum_{j=1}^{M_2} \left(w_{ij}^{(3)} f_2'(\xi_j^{(2)}) \sum_{k=1}^{M_1} \left(w_{jk}^{(2)} f_1'(\xi_k^{(1)}) w_{kl}^{(1)} \right) \right) \end{aligned} \quad (6.31)$$

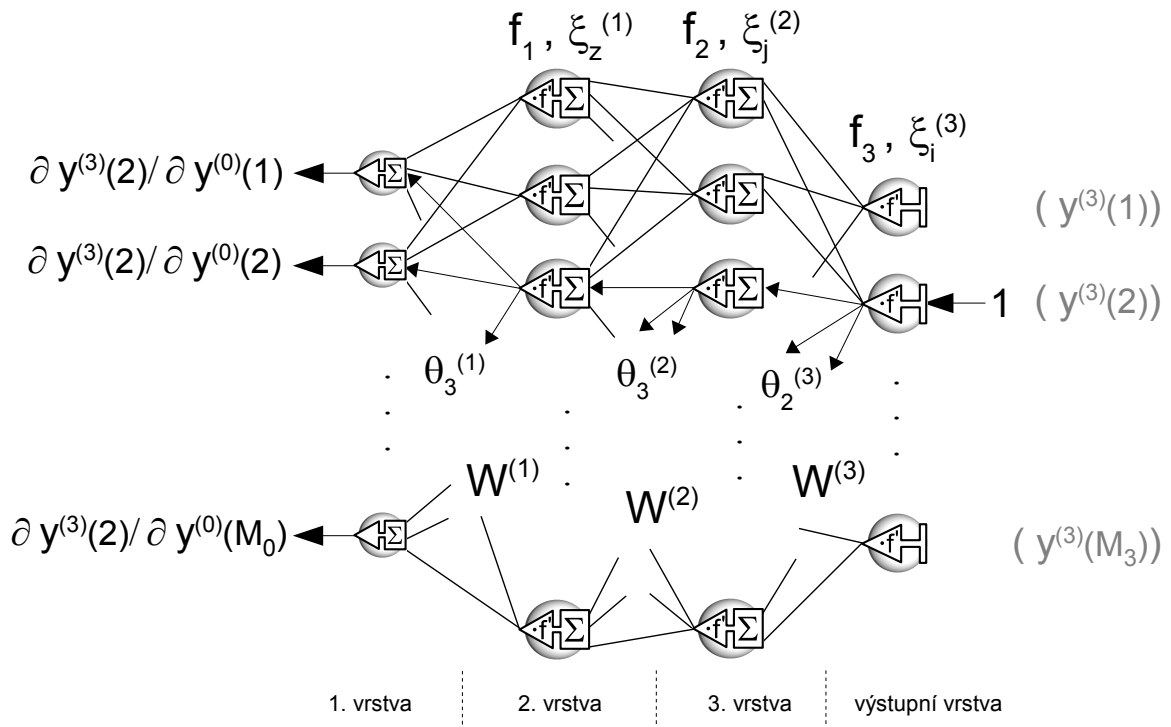
Záměnou sumačního pořadí a přeuspořádáním činitelů dostáváme:

$$\frac{\partial y^{(3)}(i)}{\partial x(l)} = \sum_{k=1}^{M_1} \left(w_{kl}^{(1)} f_1'(\xi_k^{(1)}) \sum_{j=1}^{M_2} \left(w_{jk}^{(2)} w_{ij}^{(3)} f_2'(\xi_j^{(2)}) f_3'(\xi_i^{(3)}) \right) \right) \quad (6.32)$$

Z tohoto tvaru je již patrné, že výpočet parciálních derivací zvoleného výstupu podle jakéhokoliv vstupu má velkou část operací shodných. Konkrétně sumace podle indexu j nezávisí na volbě vstupu, tj. indexu l , a výpočet se liší až ve finální fázi. Proto je výhodné derivace vyčíslovat podle korigovaného schéma zpětného šíření, které lze pomocí dílčích výsledků $\theta_i^{(N)}$ zapsat následovně:

$$\frac{\partial y^{(3)}(i)}{\partial x(l)} = \sum_{k=1}^{M_1} \left(w_{kl}^{(1)} f_1'(\xi_k^{(1)}) \sum_{j=1}^{M_2} \left(w_{jk}^{(2)} f_2'(\xi_j^{(2)}) w_{ij}^{(3)} \theta_i^{(3)} \right) \right) = \sum_{k=1}^{M_1} \left(w_{kl}^{(1)} f_1'(\xi_k^{(1)}) \sum_{j=1}^{M_2} w_{jk}^{(2)} \theta_j^{(2)} \right) = \sum_{k=1}^{M_1} w_{kl}^{(1)} \theta_k^{(1)} \quad (6.33)$$

Pro ilustraci uveďme ještě obrázek obdobný jako obr. 6.3, avšak pro výpočet parciálních derivací výstupů podle jednotlivých vstupů sítě se dvěma skrytými vrstvami. Zpětné šíření oproti učící fázi začíná dílčími výsledky s jednotkovými hodnotami a končí až na vstupech sítě. Tímto postupem lze popisovaný algoritmus oproti aplikaci vzorce (6.31) zásadním způsobem urychlit. Po provedení naznačeného výpočtu pro všechny výstupy sítě a zvolená testovací data můžeme přistoupit k finální sumaci podle vzorce (6.30) a dostáváme výslednou matici citlivostních koeficientů, tzv. **citlivostní schéma**.



Obr. 6.5: Schéma "zpětného šíření" pro citlivostní analýzu

7. MAPOVÁNÍ OBECNÝCH ZÁVISLOSTÍ POMOCÍ BP-SÍTÍ

7.1 Nový přístup k citlivostní analýze

Numerické experimenty ukázaly, že citlivostní analýzu pomocí AFSSM lze použít též při mapování i obecných, nejen lineárních závislostí mezi parametry. Standardní aplikace AFSSM totiž neřeší případ, kdy spolu více měřených proměnných souvisí a mají zároveň všechny vysoký citlivostní koeficient. Teoreticky je možná další redukce, kterou ale na základě těchto, byť vysokých, avšak přibližně stejných hodnot citlivostních koeficientů, nelze odůvodnit.

Podobně jako má při významné závislosti vstup-výstup příslušný citlivostní koeficient (6.30) vyšší hodnotu než v případě šumu, lze očekávat vysoké derivace funkčních vztahů mezi závislými parametry. Je evidentní, že čím je funkce zobrazující hodnoty parametru x_1 na hodnoty x_2 strmější, tím je větší i suma absolutních hodnot jejích derivací ve vybraných testovacích bodech. Nutnou podmínkou takové analýzy je ale existence a diferencovatelnost analytického popisu vztahů mezi příslušnými parametry, který ovšem není apriori k dispozici. Řešením může být jeho aproximace pomocí neuronové sítě. Na citlivostní schéma lze pak pohlížet jako na míry vzájemných závislostí mezi uvažovanými parametry.

Pro účely mapování obecných závislostí byla navržena metoda využívající citlivostní analýzu N speciálních BP-sítí s $(N-1)$ vstupy a jedním výstupem, kde N je počet měřených parametrů. Síť je třeba učit pomocí speciálně sestrojených tréninkových množin. Předpokládejme, že máme k dispozici P nezávislých měření N parametrů. Učící množinu i -té sítě tvoří P uspořádaných dvojic požadovaných výstupů (naměřené hodnoty parametru x_i) a vstupních vzorů (naměřené hodnoty zbývajících parametrů):

$$T_i = \{[(x_p(1), \dots, x_p(i-1), x_p(i+1), \dots, x_p(N)), x_p(i)] \mid p=1, \dots, P\} \quad (7.1)$$

Sítě jsou takto volenými tréninkovými množinami učeny přiřazovat hodnotám $(N-1)$ vybraných parametrů zbývajících jeden na svém výstupu a aproximovat tak neznámé závislosti mezi nimi. Citlivostní koeficienty těchto sítí pak slouží k odhadu míry závislosti výstupního parametru x_i na parametrech zbývajících.

Při tomto způsobu učení mohou být získané výsledky teoreticky neopodstatněné, jelikož obecně nelze zaručit konvergenci gradientní učící metody. Problémy mohou též nastat v případě vzájemně nezávislých parametrů. Zde je obtížné rozhodnout, zda se jedná o nezávislé proměnné, nebo o nevhodně navrženou neuronovou síť, která nemá dostatečnou kapacitu na aproximaci dané závislosti.

Z výše uvedených důvodů byly sítě pro ověření nového přístupu učeny nejprve na všech N parametrech, přičemž tréninkové množiny měly tvar:

$$T_i = \{[(x_p(1), \dots, x_p(N)), x_p(i)] \mid p=1, \dots, P\} \quad (7.2)$$

Problém konvergence gradientní metody zde sice odpadá a "skryté" identity mezi parametry x_i na vstupu a x_i na výstupu jsou citlivostními koeficienty zřetelně detekovatelné,

avšak ostatní hledané závislosti se na pozadí snadno naučitelné identity prokazují velmi obtížně. Lze říci, že mezi zbylými citlivostními koeficienty není zásadní rozdíl a další existující vztahy tak nelze odlišit od šumu. Je proto nutné se dále zabývat původní verzí metody, která do vstupních proměnných nezahrnuje parametr výstupní (tréninková množina viz 7.1).

Neméně podstatný problém pak představuje přeučení sítí, kdy malá změna vstupu způsobuje neadekvátně velkou reakci výstupu. Derivace a tudíž i citlivostní koeficienty pak nabývají vysokých hodnot, které ale nereflektují skutečnou učenou závislost. Proto se jeví účelné potlačovat přeučení již během učení sítě, tj. vhodně volit architekturu, inicializační váhy a aplikovat regularizaci. Numerické experimenty na druhou stranu naznačují, že k prokázání tréninkovými daty dobře ovzorkované funkční závislosti postačí citlivostní schéma sítě i s velmi malou архитектурou, přičemž učící chybu MSE není třeba minimalizovat na hodnoty menší než řádově setiny. Vzájemně funkčně závislé proměnné jsou pak v rámci jedné speciální sítě charakterizovány řádově vyššími citlivostními koeficienty oproti nevýznamným "šumovým" vztahům.

Při numerických experimentech se rovněž ukázalo, že nedostatečná konvergence učící chyby nemusí představovat problém. Pokud se po určitém počtu adaptačních cyklů nepodaří snížit chybu na zmiňované malé hodnoty, je možné učení zastavit a provést citlivostní analýzu. Jejím výsledkem pak bývají citlivostní koeficienty s přibližně stejnými, relativně nízkými hodnotami, což koresponduje s hypotézou nezávislých dat, z níž zpětně plyne i špatná konvergence gradientního algoritmu.


Jinak řečeno, pokud se nedaří učící chybu minimalizovat, je velmi pravděpodobné, že jsou dané parametry nezávislé, nebo mezi nimi existuje příliš složitá funkční závislost, která je ale z hlediska analýzy dat nezajímavá. Např. každou funkci, omezenou na intervalu $\langle -1, 1 \rangle$, která je dána konečným počtem bodů, lze aproximovat funkcí tvaru $\sin(\alpha x)$, tj. sinusoidou vhodné frekvence. Pokud bychom zvolili dostatečně velký počet neuronů, je možné najít takové váhy a prahy, aby síť s určitou přesností aproximovala i realizaci šumu. Proto se při mapování obecných závislostí neuronovými sítěmi osvědčilo zůstat u malých architektur a hranici mezi významným funkčním vztahem a "šumem" charakterizovat schopností, či neschopností sítě tuto souvislost se zvolenou přesností aproximovat.

7.2 Demonstrace metody na modelových datech

Následující numerický experiment demonstruje popisované mapování obecných závislostí mezi parametry pomocí citlivostní analýzy speciálních neuronových sítí na příkladech modelových dat. Nový přístup byl testován na detekci dvou typů funkčních závislostí skrytých mezi šesti proměnnými. Bylo vygenerováno 10 000 šestiřozměrných testovacích dat. Parametry x_1, x_3, x_4, x_5 byly voleny náhodně s rovnoměrným rozdělením v intervalu $(-1, 1)$. Hodnoty druhého parametru pak byly vypočítány na základě čtvrtého parametru, podle vzorce $x_2 = (x_4)^3$. Druhá skrytá závislost je modelována složitějším funkčním vztahem $x_6 = (x_1)^2 + \sin(5(x_3)^2)$, který je již vícerozměrný a není prostý, čímž se stává lineárními metodami (jako např. faktorová analýza) nedetekovatelným. Tato závislost je zobrazena v 3D řezu $x_1 - x_3 - x_6$ na obrázku 7.1.

Před samotnou aplikací nové metody byla rovněž provedena faktorová analýza souboru dat se všemi šesti parametry. Pět faktorů stačilo na vysvětlení 98.6% celkového rozptylu proměnných. Největší část jejich variability lze vysvětlit prvním faktorem, ovlivňujícím parametry x_2 a x_4 (viz vysoké zátěže v prvním sloupci faktorového schématu na obr. 7.2). Tím je jasně prokázána souvislost těchto parametrů, která je díky po částech lineárně

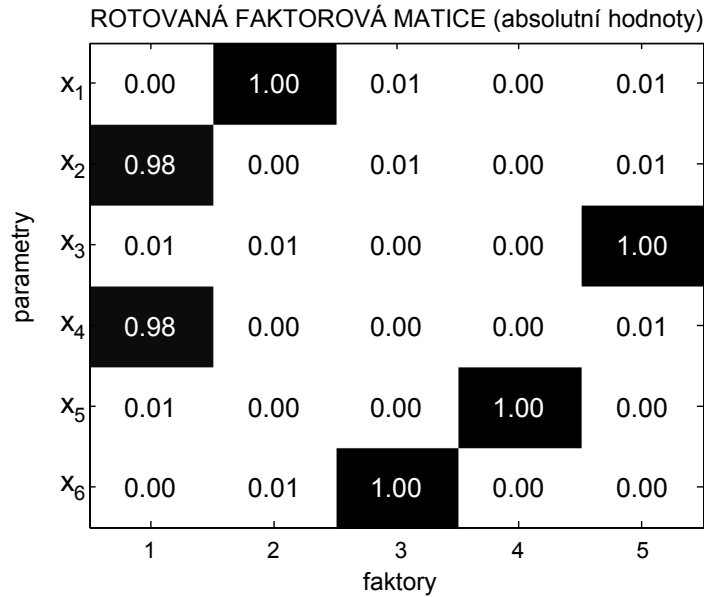
aproximovatelnému tvaru funkce $x_2 = (x_4)^3$ postižitelná i korelační analýzou. Zbylé faktory jsou čerpány vždy jedním parametrem, což koresponduje s nekorelovaností proměnných x_1, x_3, x_5 a x_6 . V souladu s předpokladem tedy druhá skrytá závislost nebyla faktorovou analýzou detekována.



Obr. 7.1: Zobrazení modelové závislosti v 3D řezu x_1 - x_3 - x_6

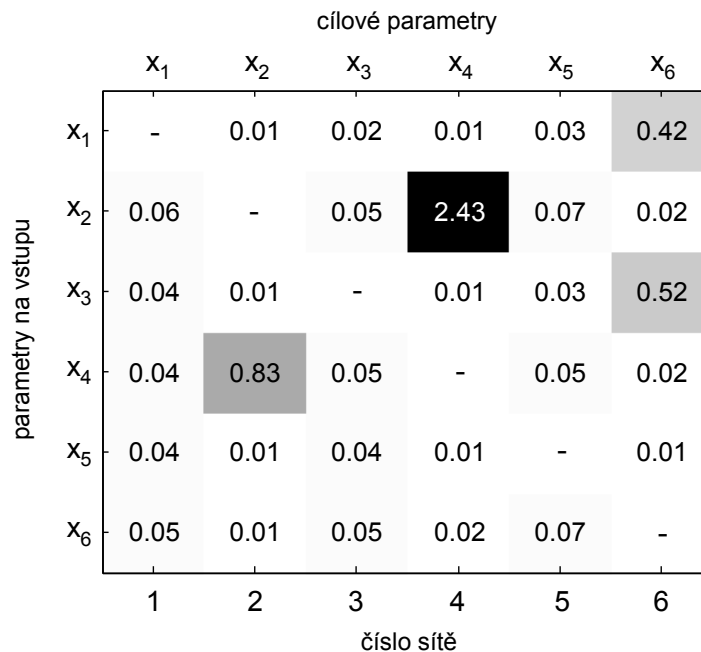
Pro ověření schopnosti nového přístupu detekovat i obecné (nelineární) vztahy bylo učeno šest různých neuronových sítí s architekturou 5-9-7-1, tj. s pěti vstupy, devíti, resp. sedmi neurony s tangens-sigmoidálními přenosovými funkcemi v první, resp. druhé skryté vrstvě a jedním výstupním neuronem s lineární přenosovou funkcí. Příslušné tréninkové množiny T_i byly sestaveny podle vztahu (7.1) pro $P=10\ 000$. Pro maximální potlačení přeučení probíhala adaptace statisticky optimalizovaných inicializačních vah (viz kap. 6.10) podle resilientní verze algoritmu zpětného šíření s regularizací (6.19) a momentem. Délka procesu učení byla omezena na max. 300 cyklů. V případě sítí číslo 2 a 4 byla učicí chyba (MSE) úspěšně minimalizována na hodnoty menší než 0.01. Architektura 5-9-7-1 umožnila pro šestou síť redukovat chybu pouze na hodnoty kolem 0.05. Průběh procesu učení ostatních sítí nebyl podle předpokladů úspěšný ($MSE \approx 0.3$ po 300 cyklech). Počty neuronů 5-9-7-1 byly záměrně voleny tak, aby neumožnily postihnout "šumový vztah" mezi nezávislými parametry.

Z principu gradientní minimalizace učicí chyby je zřejmé, že změna počátečních podmínek procesu (inicializačních vah) může mít za následek odlišné vlastnosti finálně naučené sítě. I když míra proměnlivosti výstupů jednotlivých verzí sítí klesá s dobrými generalizačními vlastnostmi, je vhodné výsledky průměrovat. Zvláště pak pro dosažení relevantních závěrů citlivostní analýzy. Sumární schéma na obr. 7.3 je proto sestaveno z průměrných výsledků citlivostních analýz vždy sedmi verzí příslušných šesti sítí.



Obr. 7.2: Faktorové schéma

V průběhu numerických experimentů byl ohledně průměrování pozorován ještě jeden zajímavý jev. Výsledky citlivostních analýz vykazovaly významnější změny spíše v závislosti na realizaci náhodných dat (tréninkové množiny), než na změnu počátečních vah. Teprve podstatným rozšířením učicích dat (vygenerovaných v prostředí Matlab až na počet 10 000) bylo dosaženo dobré "stability" výsledných citlivostních schémat. Při použití podstatně menších souborů dat (např. 1 000 tréninkových vzorů) byly mezi šumem detekovány i velmi slabé, ve skutečnosti neexistující vztahy, které nezávisely na verzi sítě, ale na vygenerovaných datech.



Obr. 7.3: Souhrnné citlivostní schéma

Ze schématu na obr. 7.3 lze vydedukovat následující závěry. Nejsilnějším detekovaným vztahem (citlivostní koeficient s hodnotou 2.43) je závislost parametru x_4 na změně x_2 , přičemž jejich inverzní vztah je druhým nejvýznamnějším (citl. koef. 0.83). Je tak potvrzena i hypotéza o souvislosti těchto parametrů podle faktorové analýzy. Oproti ní se ale podařilo evidentně prokázat i podstatně složitější nelineární závislost šesté proměnné na x_1 a x_3 (viz velké citlivosti v posledním sloupci schématu). Obě modelové závislosti se tedy na citlivostních koeficientech projeví zcela zřetelně a metoda úspěšně detekuje i korelačně nepostihnutelné vztahy, kdy klasický, lineární přístup selhává.

Citlivostní analýza BP-sítí tedy umožňuje nejen podstatné zjednodušení jejich architektury. Jak plyne z výsledků modelových experimentů, "citlivostní přístup" je použitelný i k redukci redundantní informace v dané parametrizaci ještě před konstrukcí složitějšího klasifikačního systému, a lze jím na rozdíl od lineárních metod postihnout i obecné funkční závislosti. Budoucí vývoj metody je zaměřen na interpretaci jejích výsledků v případě reálných experimentálních dat (parametrizované signály AE), což vyžaduje další výzkum obecných vlastností naučených BP-sítí.

8. LOKALIZACE ZDROJŮ AE POMOCÍ ANN

8.1 Nová metoda lokalizace zdrojů AE

Dostatečně přesná znalost polohy zdroje AE je základním požadavkem pro další charakterizaci mechanismu poruchy. Pro získání komplexní informace o povaze defektu materiálu jsou souřadnice zdrojů AE nejčastěji určovány pomocí triangulačního algoritmu založeného na časových diferencích příchodů emisního signálu, zaznamenaného několika různými snímači [3]. V praxi se ale zejména při testování složitých konstrukcí setkáváme s mnoha situacemi, kdy klasický triangulační algoritmus selhává. V těchto případech jsou alternativou triangulačního algoritmu metody založené na umělých neuronových sítích. Na rozdíl od klasických přístupů mají metody využívající ANN dvě podstatné výhody. Jsou použitelné pro lokalizaci zdroje AE v silně disperzních konstrukcích a rychlost šíření elastické vlny není jejich vstupním parametrem [3],[14],[15].

Obdobně jako v případě obecného triangulačního algoritmu jsou časové difference vstupními parametry i pro základní metody založené na ANN. Algoritmy využívající časové difference ale mohou kvůli obtížnému určování začátku signálu vést k chybným výsledkům, obzvláště za přítomnosti vysokých hladin šumu. Z těchto důvodů byla navržena nová metoda lokalizace zdrojů AE. Jejím jádrem je umělá neuronová síť, do níž vstupují běžně používané parametry signálů AE jako např. RMS, doba nárůstu, maximální amplituda apod., které představují redundantní vstupní data pro lokalizační algoritmus. Pro určení polohy emisního zdroje tak není zapotřebí znát přesné časové difference, čímž odpadá jeden z problémů zpracování záznamů signálů AE.

8.2 Popis experimentu

Nový přístup k lokalizaci zdrojů AE je demonstrován na části nosníku křídla cvičného letounu. Elastické vlny byly během experimentu buzeny pen-testy, detekovány malými piezoelektrickými snímači a zaznamenány čtyřkanálovým AE systémem PAC μ DiSP. Pro účely zpracování neuronovými sítěmi (učení a aproximace přesných souřadnic pen-testů) byly provedeny dvě sady měření. První, zahrnující trénovací body, pro zajištění správného učení neuronové sítě. Druhou pak představují testovací body, na kterých byly ověřovány generalizační vlastnosti sítě (viz obr. 8.1).

Parametrizace signálů

Po záznamu signálů všemi čtyřmi snímači ($S1-S4$) byly pro všechny kanály počítány následující klasické parametry v časové a frekvenční oblasti, definované v kap. 4:

Časová oblast:

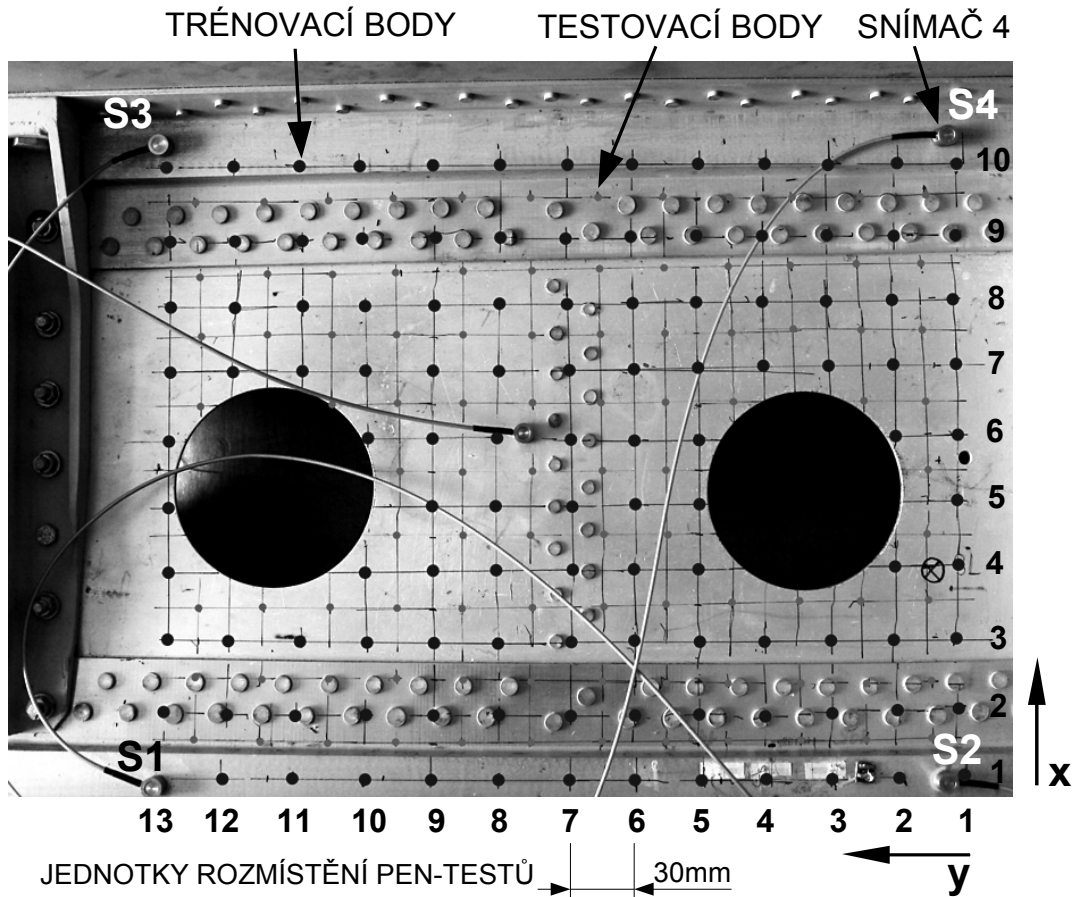
Amplituda (4.1), doba nárůstu do maxima (risetime, viz 4.3), efektivní hodnota (RMS, viz 4.5), moment energie (4.6), průměrná hodnota (ASL, viz 4.7), směrodatná odchylka (4.8), šikmost a špičatost (4.9).

spektrální parametry:

Poměrné zastoupení P_X (4.13) frekvenčních pásem $A-E$ v celkovém pásmu F :

$A:(0-0.03)*\omega_N$; $B:(0.03-0.05)*\omega_N$; $C:(0.05-0.1)*\omega_N$; $D:(0.1-0.2)*\omega_N$; $E:(0.2-0.5)*\omega_N$;

$F:(0-0.5)*\omega_N$, kde ω_N je Nyquistova frekvence.



Obr. 8.1: Část nosníku křídla L-39 - umístění pen-testů

Učení neuronových sítí

Ve všech numerických experimentech popsaných níže byly aplikovány BP-sítě se dvěma skrytými vrstvami. Parametry počítané pro všechny čtyři kanály určovaly počet neuronů ve vstupní vrstvě. První a druhou skrytou vrstvou tvořilo 39 resp. 19 neuronů se sigmoidální přenosovou funkcí. Výstupní vrstvu představovaly dva neurony s lineární přenosovou funkcí, které počítaly odhad skutečných souřadnic pen-testů.

Během učení byly váhy a prahy neuronů iteračně adaptovány pomocí rychlé resilientní varianty učícího algoritmu zpětného šíření s momentem a generalizací zlepšující regularizací. Inicializační váhy a prahy byly nastaveny statistickou optimalizací startovních potenciálů neuronů (viz kap. 6). Pro ověření vlastností naučených neuronových sítí byla použita alternativní metoda volby parametrů AFSSM (Alternative Feature Subset Selection Method) [13].

8.3 Numerické experimenty

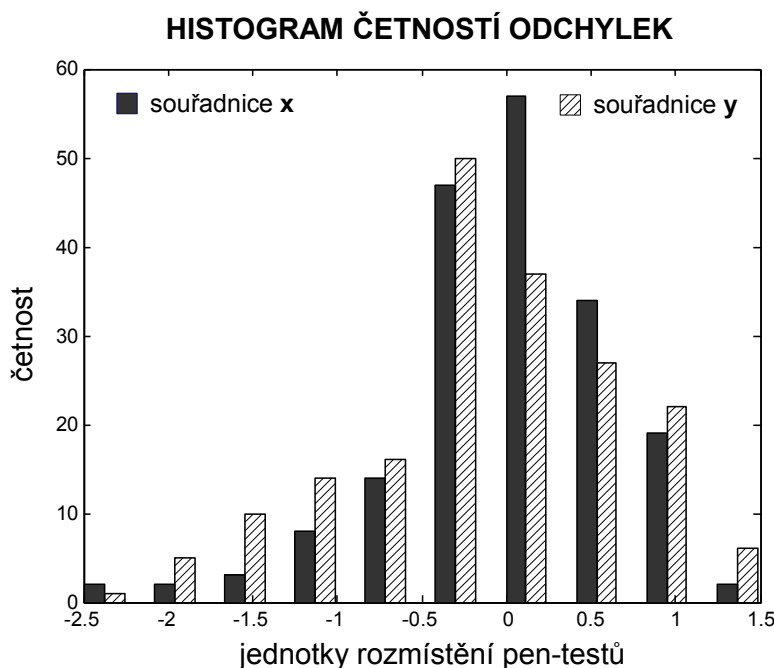
Během testování generalizačních vlastností naučených neuronových sítí byla provedena řada numerických experimentů s různými kombinacemi signálových parametrů na vstupech. Ze všech výše uvedených signálových charakteristik určila citlivostní analýza jako nejvýznamější parametr RMS . Následnou redukcí vstupů na čtyři (tj. RMS od každého kanálu), se podařilo podstatně zlepšit generalizační vlastnosti sítě. Pro lokalizační úlohu zřejmě představují ostatní parametry převážně informační šum.

Modifikace vstupních parametrů

Za účelem obecnějšího vystižení informace o poloze zdroje skryté v energetických parametrech byly dále zavedeny následující nové modifikace efektivní hodnoty:

$RMS_{CH1} - RMS_{CH2}$; $RMS_{CH1} - RMS_{CH3}$; $RMS_{CH1} - RMS_{CH4}$; $RMS_{CH2} - RMS_{CH3}$;
 RMS_{CH1} / RMS_{CH2} ; RMS_{CH1} / RMS_{CH3} ; RMS_{CH1} / RMS_{CH4} ; RMS_{CH2} / RMS_{CH3} ,
kde RMS_{CHi} je parametr RMS příslušného signálu, zaznamenaného snímačem i .

Ačkoliv chyba sítě neklesala tak rychle jako v předchozích neredukovaných případech, po 500 učicích cyklech se průměr kvadrátů výstupních odchylek MSE_{TRAIN} pro standardizovaná tréninková data přiblížil hodnotě 0.04 a generalizační schopnosti sítě se dále zlepšily (průměr kvadrátů odchylek pro standardizovaná testovací $MSE_{TEST}=0.045$). Naučená síť tedy neinklinuje k přeučení a pomalá konvergence učící chyby ilustruje spíše složitost dat, než nežádoucí vlastnosti sítě jako takové.



Obr. 8.2: Odchylky odhadů lokalizací na základě poměrů RMS

Podle výsledků citlivostní analýzy řeší nově přidané charakteristiky lokalizační úlohu přesněji než parametr RMS samotný, přičemž sada s poměry RMS_{CHi} / RMS_{CHj} je nejvýznamnější. Obrázek 8.2 uvádí histogram četností odchylek odhadů a skutečných souřadnic inicializačních míst již v nestandardizovaných jednotkách rozmístění pen-testů (krok 30mm) pro testovací data.

8.4 Lokalizace na základě časových diferencí

Pro porovnání nového lokalizačního přístupu s metodami uvedenými v [3], [14], [15], [16] byly v rámci numerických experimentů učeny také neuronové sítě s časovými diferencemi ($t_i - t_j$) na vstupech:


$t_1 - t_2$; $t_1 - t_3$; $t_1 - t_4$; $t_2 - t_3$, kde t_i jsou časy příchodů signálů naměřených kanálem i .

V prvním případě byly časy příchodů určeny původním automatickým algoritmem (viz kap. 3) detekujícím první nasazení signálu (příchody podélných vln). Při učení neuronové sítě byla pozorována pomalá konvergence chyby spolu s horšími generalizačními vlastnostmi (viz obr. 8.3):

$MSE_{TRAIN}=0.033$ (po 500 učicích cyklech); $MSE_{TEST}=0.076$.

V druhém případě byly jako časy příchodů použity trigrovací časy určené AE systémem PAC μ DiSP. Relativně pomalá konvergence byla opět pozorována, přičemž generalizační vlastnosti sítě se zlepšily. Zřejmě kvůli faktu, že k rozpoznání příchodu smykového nebo disperzního vlnového módu byly použity pouze nejvyšší výchylky signálu:

$MSE_{TRAIN}=0.0117$ (po 500 učicích cyklech); $MSE_{TEST}=0.021$.



Obr. 8.3: Odchylky odhadů lokalizací na základě časových diferencí

8.5 Shrnutí výsledků

Nová metoda pro lokalizaci zdrojů signálů AE pomocí umělých neuronových sítí obchází problém detekce prvního nasazení signálu a odhaduje souřadnice zdroje na základě signálových parametrů. Její výhody byly prokázány na numerických experimentech s daty, naměřenými na složité části letecké konstrukce. Citlivostní analýza naučených neuronových sítí extrahovala parametr *RMS* jako nejvhodnější signálovou charakteristiku pro lokalizaci emisního zdroje, což odpovídá základní vlastností šíření disperzních elastických vln. Zavedení modifikací parametru *RMS* dále zlepšilo generalizační schopnosti naučených sítí a výsledky lokalizace jsou srovnatelné s klasickými algoritmy založenými na časových diferencích příchodů signálů. Přednosti nové metody se uplatňují zvláště v případech geometricky složitých částí konstrukcí (za přítomnosti vlnových odrazů a disperzních efektů), vysoké hladiny šumového pozadí atd.

9. KOREKCE EMISNÍCH PARAMETRŮ NA POLOHU ZDROJE AE

9.1 Problém inverzní úlohy o emisním zdroji

Při šíření elastických vln, emitovaných zdrojem akustické emise v materiálu, dochází na cestě od zdroje ke snímačům k velkému zkreslení emisního signálu, které do značné míry znesnadňuje správnou klasifikaci a posouzení nebezpečnosti různých zdrojů. Četné odrazy, útlum a zejména pak geometrická i materiálová disperse [17] má za následek odlišnou odezvu jednoho emisního zdroje u snímačů, rozmístěných na různých místech tělesa. Vyhodnocené parametry detekovaných signálů AE se tak mohou značně lišit, přestože jde o signály téhož původu. Pro spolehlivější diagnostické rozhodování a hodnocení emisní aktivity je proto zapotřebí získat srovnatelné informace, nezávislé na vzdálenosti snímače od zdroje.

Dokonalá identifikace emisního zdroje na základě znalosti jeho seismických momentů vyžaduje záznam a analýzu kompletního emisního signálu z více snímačů a řešení velmi komplikované inverzní elastodynamické úlohy v dispersním prostředí. Úplné řešení inverzní úlohy o emisním zdroji (výpočet seismických momentů) není v reálných podmínkách prakticky možné a ve většině diagnostických aplikací nebývá ani nutné. V reálných situacích postačí mnohem jednodušší rozpoznávání a klasifikace emisních zdrojů na základě vhodně zvolených signálových parametrů, o jejichž vyhodnocení se již hardwarově či softwarově postará analyzátor AE.

Problémem však zůstává vzájemné porovnání těchto parametrů z různě vzdálených zdrojů. Software soudobých analyzátorů AE dnes sice umožňuje korigovat některé parametry, jako např. amplitudu či RMS na vzdálenost spolehlivě lokalizovaného zdroje, tedy na útlum vln v konstrukci (jde většinou o exponenciální závislost), ale další, např. frekvenční parametry, korigovány nebývají (v některých geometricky jednodušších případech lze k jejich sofistikované korekci využít znalost dispersních křivek [18]). Závislost většiny emisních parametrů na vzdálenosti od zdroje bývá i v relativně jednoduchých případech izotropního tělesa relativně komplikovaná (není ryze monotónní) a v anizotropních tělesech je navíc i směrově proměnlivá.


Pro praktické potřeby ale můžeme tento problém značně zredukovat na inverzi signálových parametrů. Jedná se o přepočítání jednotlivých parametrů naměřených signálů z různých míst na jednu referenční polohu zdroje, který je v blízkosti vybraného snímače. Jednoduchá, okamžitá korekce emisních parametrů v reálném čase s ohledem na vzájemnou polohu snímače a zdroje, založená na automatickém přepočtu těchto parametrů pomocí umělých neuronových sítí, byla v hrubých rysech nastíněna v [19].

Rozpracování této metodiky řešení redukovaného inverzního problému vyústilo v návrh nového algoritmu zjednodušené korekce nejdůležitějších signálových parametrů pomocí naučených neuronových sítí. Navržené postupy jsou v následujících odstavcích ilustrovány

na příkladech numerických simulací šíření elastických vln v izotropní rovinné desce a praktických experimentů s umělými emisními zdroji, působícími na komplikovaných součástech letecké konstrukce.

9.2 Numerický model šíření elastických vln

Cílem numerických simulací šíření elastických vln v ocelové desce bylo získání přenosových funkcí mezi místy emisního zdroje a snímače. Pro učení i testování umělé neuronové sítě je zapotřebí nalézt tyto tzv. Greenovy funkce k dostatečně velkému počtu dvojic bodů [zdroj, snímač] jako odezvy bodového pulsního zdroje, naměřené v místě snímače. Uvažujeme-li homogenní izotropní prostředí, závisí výpočet pouze na vzdálenosti senzoru od zdroje signálu. Při zanedbání odrazů od bočních stěn je tedy možné se omezit na 2D řez tělesem. K tomuto omezení nás nutí extrémní výpočetní náročnost 3D modelu. Navržený 2D model (viz obr. 9.1) přesto dovolí zachytit důležitý efekt, který se při šíření vlny v tenké desce uplatňuje, a sice mnohačetné odrazy mezi dvěma blízkými stěnami, vedoucí k vlnové dispersi.



Obr. 9.1: Schéma korekce (3D model)

Simulace byly provedeny pomocí programu LISA 2D. LISA (Local Interaction Simulation Approach) je program pro výpočet numerického řešení elastodynamické vlnové rovnice, založený na metodě konečných diferencí, modifikované na oblasti s četnými materiálovými rozhraními. V simulacích byly uvažovány následující materiálové a numerické parametry:

Materiál: ocel (hustota 7850 kg/m^3 , $v_L=5890 \text{ m/s}$, $v_T=3240 \text{ m/s}$)
Numerické parametry: síť 10001×101 bodů ($500 \text{ mm} \times 5 \text{ mm}$), časový krok $dt=5.95e-9 \text{ s}$, volné okrajové podmínky (na všech okrajích)

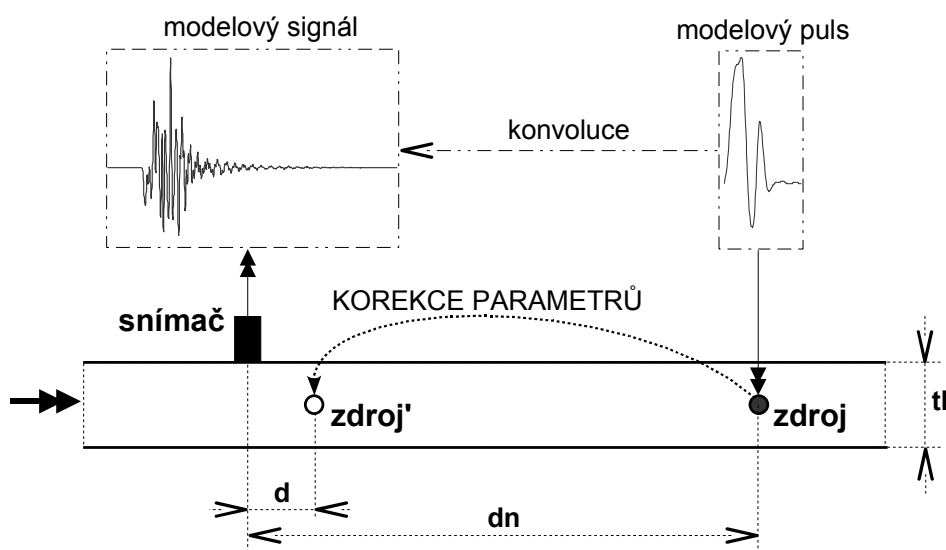
Časový průběh vstupního pulsu odpovídá Rickerově funkci (druhá derivace Gaussovy funkce). Prostorové rozložení pulsu bylo radiálně symetrické. Epicentrum zdrojového pulsu bylo umístěno uprostřed desky (viz obr. 9.2).

Matematický model umožňuje výpočet odezvy modelových pulsů v rozmezí vzdáleností $10\text{-}200 \text{ mm}$ od snímače (s krokem 1 mm). Proto jsou jednotlivé senzory s_1 , s_2 , s_3 , s_4 pro

potřeby numerického experimentu umístěny do vrcholů čtverce o hraně 176.7 mm. Oblast pro korekci byla vymezena body A, B, C, D o souřadnicích $[40,40], [135,40], [135,135], [40,135]$, přičemž počátkem souřadnicové soustavy je snímač s_1 . Referenční poloha zdroje byla zvolena do vzdálenosti $d=30\text{ mm}$ od snímače s_1 . Referenční poloha je poloha virtuálního snímače k němuž jsou korigovány parametry. 2D schéma korekce znázorňuje na obr. 9.2 řez materiálem ve směru referenční snímač - místo původního zdroje, který je na obr. 9.1 vyznačen dvojitými šipkami.

Různé zdroje signálů AE byly simulovány lineární kombinací tří modelových zdrojových funkcí W_1, W_2, W_3 s koeficienty a, b, c . Výsledný signál $z(t)$, v místě snímače ve vzdálenosti d_n od místa zdroje byl počítán konvolucí kombinovaného zdroje W_{abc} s příslušnou Greenovou funkcí G_{d_n} :

$$z(t) = (G_{d_n} * W_{abc})(t); W_{abc} = a \cdot W_1 + b \cdot W_2 + c \cdot W_3; a, b, c \in (0,1)$$




Obr. 9.2: Schéma korekce (2D model)

Vybuzení emisního zdroje, šíření vlny tělesem a záznam signálu AE jsou modelovány následujícím způsobem: V místě o souřadnicích $[x,y]$ působí kombinovaný modelový zdroj W_{abc} . Přenos mezi zdrojem a snímačem s_1 je vyjádřen konvolucí zdrojové funkce s Greenovou funkcí G_{d_n} pro konkrétní vzdálenost $d_n = \text{round}(\sqrt{x^2 + y^2})$.

Obdobný postup, tj. výpočet vzdálenosti a konvoluce s příslušnou nejbližší Greenovou funkcí, je aplikován na všechny čtyři od zdroje různě vzdálené snímače a výsledkem jsou čtyři záznamy signálů AE, které pocházejí od jednoho a téhož emisního zdroje. Analogickým postupem získáme signál, který by vybudil identický zdroj W_{abc} ve vzdálenosti d od zvoleného referenčního snímače, v tomto případě senzoru s_1 . Zde provedeme obdobný výpočet s Greenovou funkcí pro vzdálenost $d=30\text{ mm}$.

Na obr. 9.3 jsou zobrazeny časové průběhy modelových zdrojových funkcí W_1, W_2, W_3 , výsledná časová funkce zdroje W_{abc} pro kombinaci $(a,b,c)=(0,5; 0,4; 0,7)$, Greenova funkce pro konkrétní tloušťku materiálu $tl=10\text{ mm}$ a vzdálenost $d_n=75\text{ mm}$, a výsledný signál $z(t)$ pro tento případ.



Obr. 9.3: Modelové zdrojové funkce, Greenova funkce, výsledný signál.

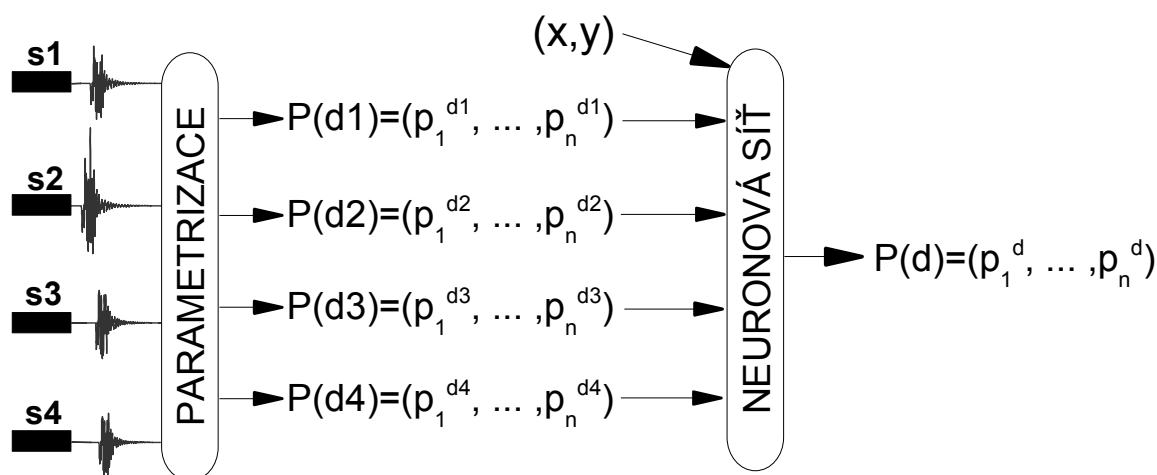
Učení neuronové sítě

Neuronová síť má za úkol provést pro konkrétní emisní zdroj ve vymezené oblasti přepočít parametrů signálu AE z více snímačů na parametry signálu zvoleného referenčního snímače, který je nejbližší ke zdroji. Schéma tohoto korekčního algoritmu je znázorněno na obr. 9.4. Vstupy neuronové sítě jsou vybrané parametry signálu ze všech čtyř snímačů spolu se souřadnicemi polohy lokalizovaného zdroje. Výstupem sítě je odhad parametrů signálu (případně i jiných parametrů než vstupních), který by naměřil referenční snímač $s1$ od téhož zdroje, ale ve vzdálenosti $d=30mm$, tj. v referenční poloze.

Vhodný výběr tréninkových dat ovlivňuje zásadním způsobem generalizační schopnosti neuronové sítě. Při řešení problému korekce signálových parametrů je také zapotřebí dostatečně postihnout možnou variabilitu uvažovaných emisních zdrojů v jednom místě, jinak by celá úloha ztrácela smysl. Proto byly časové funkce zdroje modelovány různými lineárními kombinacemi tří spektrálně odlišných pulsů. Tím je zajištěna dostatečná variabilita jak energie, tak spektrálních charakteristik zdrojové funkce. Uvažovanou oblast, v níž mají být korigovány signálové parametry, je třeba dostatečně jemně pokrýt tréninkovými daty, neboť u tenké desky lze očekávat složité vlnové interference a tedy i výrazné změny přenosové funkce s malou změnou vzdálenosti snímače od zdroje. Z těchto důvodů byly pro tréninkové účely brány v úvahu polohy zdroje (body) o souřadnicích z množiny S_{TR} a v nich hodnoty koeficientů kombinace modelových pulsů z množiny K_{TR} :

$$S_{TR} = \{[x, y] | x, y \in \{40; 45; 50; \dots; 135\}\} \quad K_{TR} = \{(a, b, c) | a, b, c \in \{0.1; 0.5; 0.9\}\}$$

Korekční oblast je tedy rovnoměrně pokryta sítí bodů s roztečí $5mm$. Pro každý bod a pro každý snímač byly vypočteny příslušné odezvy na všechny kombinace pulsů. Vybrané parametry takto vygenerovaných signálů představují spolu s odpovídajícími souřadnicemi $[x, y]$ vstupní tréninková data. Parametry signálu (nemusí být totožné s parametry na vstupu sítě) od příslušného hypotetického zdroje v referenční vzdálenosti od snímače $s1$ pak slouží jako výstupní tréninková data. Tímto způsobem bylo pro učení sítě vygenerováno 10 800 tréninkových vzorů.



Obr. 9.4: Korekční schéma (odhad parametrů)

Korekce byla prováděna na následujících parametrech signálu $z(t)$, definovaných v kap. 4:

Amplituda (4.1), efektivní hodnota (RMS, viz 4.5), poměrné zastoupení P_x frekvenčních pásem $A ([0, 0.03]f_N)$, $B ([0.03, 0.05]f_N)$, $C ([0.05, 0.1]f_N)$, $D ([0.1, 0.2]f_N)$ a $E ([0.2, 0.5]f_N)$ v celkovém frekvenčním pásmu $F ([0, f_N])$ (kde f_N je Nyquistova frekvence) a relativní poloha těžiště spektrální hustoty $f(\omega)$, tj. relativní frekvence odpovídající "těžišti spektra", viz (4.14).

Různé verze umělých neuronových sítí pak byly učeny resilientní variantou metody "back-propagation" s regularizací a momentem, na průměr kvadratické chyby (MSE) menší než 0.001. V závislosti na složitosti tréninkových dat se počty neuronů v první skryté vrstvě, resp. druhé skryté vrstvě, pohybovaly okolo 140, resp. 60.

Pro hodnocení generalizačních schopností naučených sítí a jejich citlivostní analýzu byla vygenerována testovací data obdobným způsobem jako data tréninková, avšak na základě jiných množin souřadnic zdrojových bodů S_{TEST} a hodnot koeficientů kombinací modelových pulsů K_{TEST} :

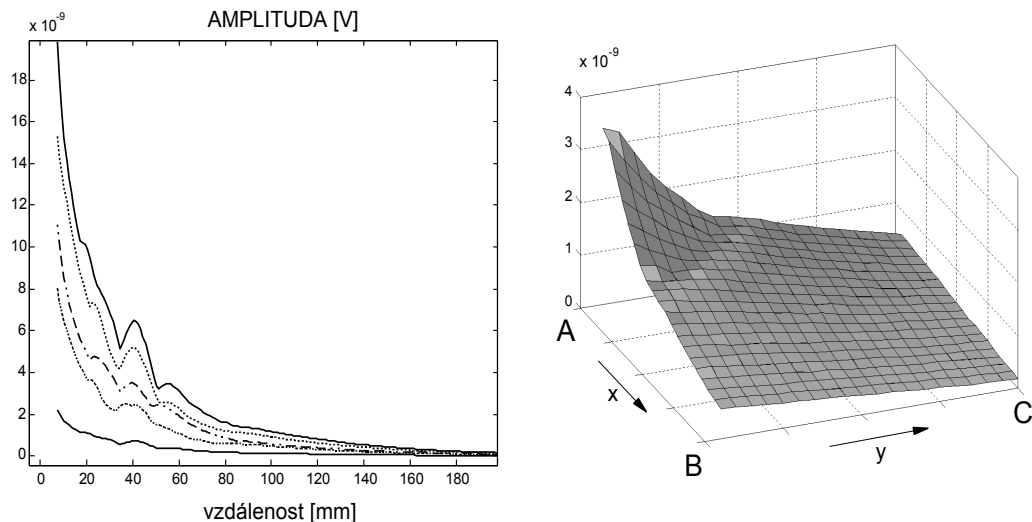
$$S_{TEST} = \{[x, y] \mid x, y \in \{42.5; 47.5; 52.5; \dots; 132.5\}\} \quad K_{TEST} = \{(a, b, c) \mid a, b, c \in \{0.3; 0.7\}\}$$

Diskuse

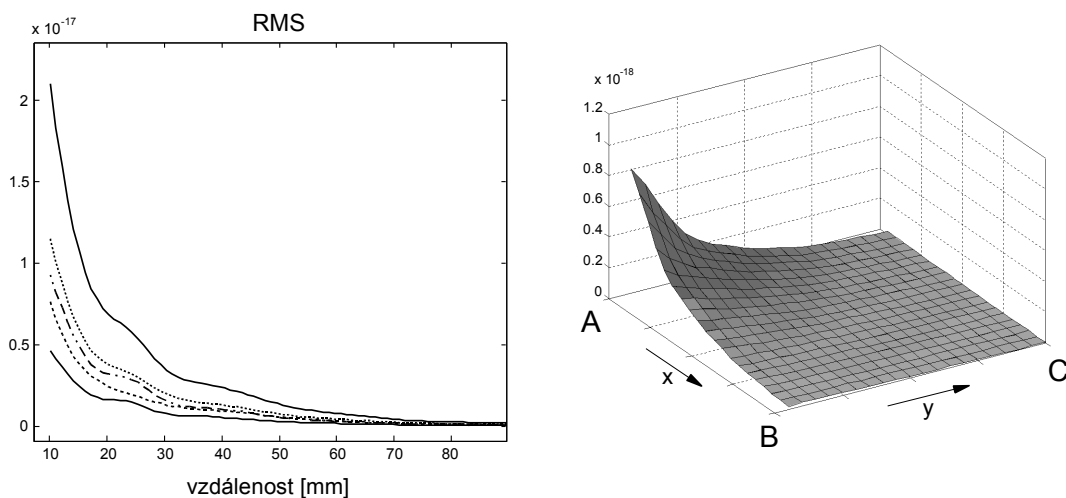
Natrénovaná neuronová síť využívá k požadované korekci parametrů jistou redundantní informaci o konkrétním emisním zdroji, která je obsažena v parametrech signálů z více snímačů. Úkolem sítě je okamžitě přepočítávat hodnoty emisních parametrů "naměřené" vzdálenými snímači na parametry signálu z referenčního snímače, který se nachází v blízkém okolí působícího zdroje. Pokud bychom uvažovali pouze jediný zdroj se stejnými charakteristikami, žádná korekce by nebyla potřeba.

Vezmeme-li však v úvahu proměnlivost alespoň jednoho parametru zdroje (jako např. energie), problém hodnocení parametrů se zkomplikuje. Z pohledu neuronových sítí dostáváme učící data, která mají blízko k nejednoznačnosti, tj. pro dva blízké vstupy požadujeme příliš vzdálené výstupy. Síť hůře konverguje a je proto třeba změnit její architekturu (zvyšovat počet neuronů). Ještě více problém komplikuje přítomnost různých typů emisních zdrojů (např. ze spektrálního hlediska). Tato situace může být ilustrována na příkladech signálů ze zdrojů s různým relativním zastoupením jednotlivých spektrálních

pásem. V levé části obr. 9.5-9.9 jsou vyneseny křivky popisující změny zvolených parametrů se vzdáleností od zdroje ($dn = 10-200\text{mm}$) pro vybrané kombinace zdrojových funkcí (různé styly čar). V pravé části je pak zobrazen průběh téhož parametru, naměřeného snímačem $s1$ v korekční oblasti, vymezené body A, B, C, D pro jednu typickou zdrojovou funkci.





Obr. 9.5: Závislost **amplitudy** na vzdálenosti od zdroje.





Obr. 9.6: Závislost **RMS** na vzdálenosti od zdroje.



Jako účinné řešení problému nejednoznačnosti se ukázalo použití více charakteristik pro korekci jednoho parametru, tj. přechod do vstupního prostoru vyšší dimenze, kde jsou výše zmiňované vstupy dostatečně vzdálené. Tak např. pro přesnější korekci parametru RMS se ukázalo vhodné využít i spektrální parametry. U více verzí naučených bp-sítí bylo zjištěno, že při nízké vlastní chybě sítě pro standardizovaná tréninková data ($MSE < 0.001$) je i generalizační chyba na testovací množině relativně malá ($MSE = 0.01$).



Obr. 9.7: Závislost parametru P_A na vzdálenosti od zdroje.



Obr. 9.8: Závislost parametru P_B na vzdálenosti od zdroje.



Obr. 9.9: Změny relativního těžiště spektrální hustoty.

Další poznatky přináší citlivostní analýza naučených sítí. V první řadě se ukázalo, že oproti očekávání nemají vstupní parametry lokalizace zdroje pro korekci ostatních parametrů zásadní význam. V praxi to znamená, že přesná lokalizace emisního zdroje není pro účely klasifikace signálů potřeba a stačí nám pouze informace o dalších parametrech z více snímačů. V modelovém případě rozmístění senzorů podle obr. 9.1 lze při hodnocení zdroje dále vynechat i parametry z jednoho až dvou snímačů umístěných diagonálně proti sobě, aniž by se výrazně zhoršil průběh učení a generalizační schopnosti naučené sítě.

Často nastává i situace, kdy pro korekci jednoho parametru má větší význam odlišný parametr. Například poměrné zastoupení frekvencí prvního pásma může neuronová síť aproximovat spíše na základě parametru relativní polohy těžiště spektrální hustoty. Samotné citlivostní schéma transformace parametrů závisí spíše na konkrétním modelu (např. různé tloušťky materiálu), než na dané verzi sítě.

Závěry

Výsledky numerických experimentů naznačily, že pro korekci parametrů signálu AE s ohledem na vzdálenost snímače AE od emisního zdroje lze vhodně využít rychlý algoritmus, založený na aplikaci vrstevnatých umělých neuronových sítí. Jejich citlivostní analýza ukázala, že vstupní parametry lokalizace zdroje nehrají při korekcích zásadní roli a lze je i při učení sítě vynechat. Dále lze zanedbat parametry signálu AE až ze dvou protilehlých snímačů, aniž by se zhoršily učící a generalizační vlastnosti sítě. Korekce parametrů při malé předpokládané variabilitě zdrojů signálů není příliš komplikovaná (lze použít velmi jednoduchou neuronovou síť a uvažovat na vstupu jediný signálový parametr od minimálně dvou snímačů).

K dostatečně spolehlivé korekci jednotlivých signálových parametrů od výrazněji odlišných emisních zdrojů je vždy na vstupech zapotřebí uvažovat i další parametry. Platí to zejména pro amplitudu a RMS, kde nepomáhá ani znalost kartézských, či polárních souřadnic zdroje. V tomto případě je pro lepší konvergenci neuronové sítě výhodné zahrnout do vstupních dat také spektrální parametry. Pro navrženou korekci daného emisního parametru mohou hrát významnou roli zcela odlišné parametry signálu, přičemž samotné citlivostní schéma transformace emisních parametrů závisí spíše na konkrétním tělese, rozmístění snímačů a tréninkové množině než na použité verzi neuronové sítě.

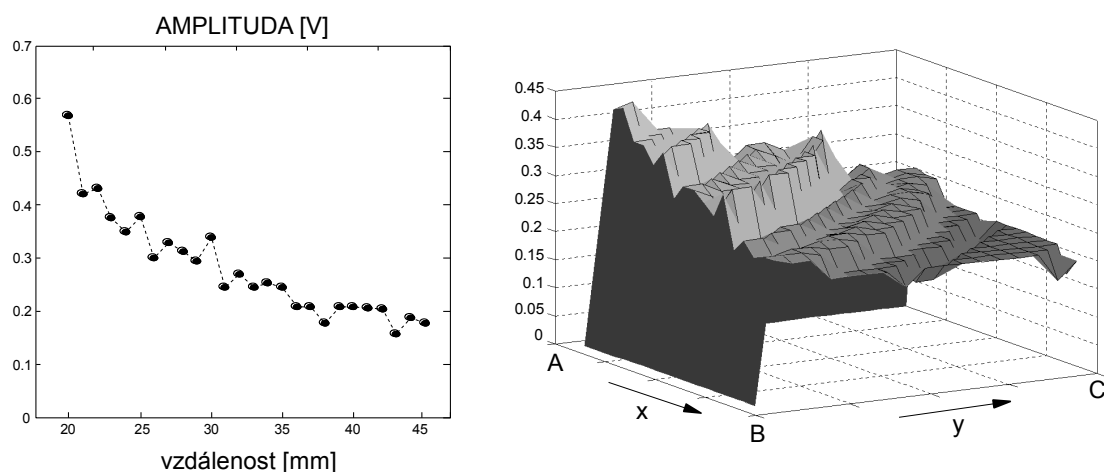
Důležitým poznatkem, plynoucím ze simulačních experimentů je, že na výstupech neuronové sítě můžeme získat i jiné korigované emisní parametry než byly vstupní. Výsledky numerických experimentů naznačují široké možnosti praktického využití navržené metody korekce parametrů emisních zdrojů i na komplikovaných konstrukcích. V praxi bude ale ve většině případů nezbytné získat vhodná tréninková data experimentálně. Algoritmus umělých neuronových sítí je velmi rychlý a umožní vyhodnocování korigovaných emisních parametrů v reálném čase.

9.3 Model s experimentálně naměřenou Greenovou funkcí

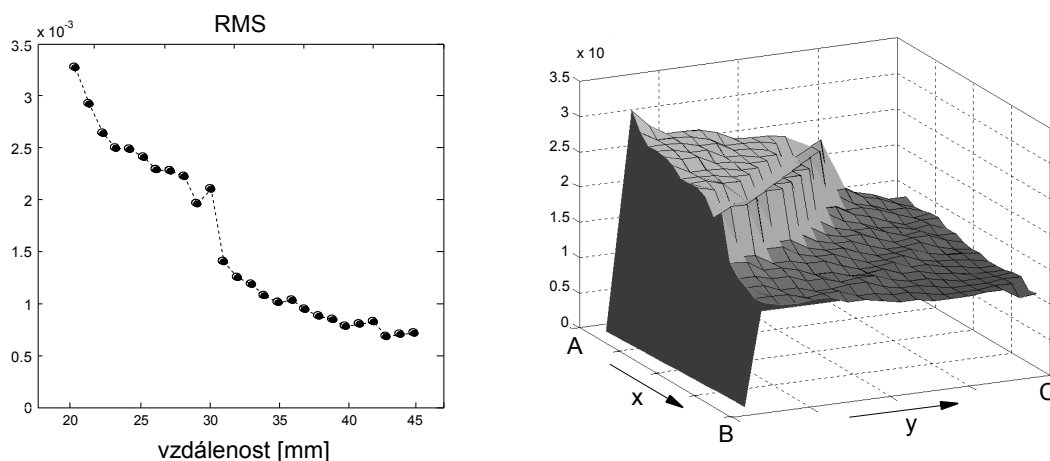
Pro porovnání čistě teoretických výsledků s reálnějším numerickým modelem byly Greenovy funkce naměřeny experimentálně při buzení tenké skleněné desky (tl. 8mm) pulsním laserem. Jednotlivými přenosovými funkcemi (pulsní odezvy) jsou signály AE zachycené ve vzdálenostech 20-45mm s krokem 1mm. Jako referenční byla zvolena vzdálenost 20mm. Obecné korekční schéma a výpočty se v ostatním shodovaly s výše popisovaným numerickým modelem, tj. byly použity stejné modelové zdrojové funkce a jejich učící a testovací kombinace (množiny K_{TR} a K_{TEST}) spolu s totožnými algoritmy.

Z obr. 9.10 a 9.11 je patrné, že vývoj hodnot parametrů vzhledem k vzdálenosti od zdroje má oproti numerickému modelu podstatně složitější průběh. Na vývoji energetických parametrů (amplituda a RMS), jejichž hodnoty v modelovém případě klesaly se vzdáleností téměř exponenciálně, jsou patrné náhlé změny. Důležitou roli zde hrají zřejmě interference vln o vlnových délkách srovnatelných s tloušťkou desky.

Pro ověření aspektů korekce parametrů, které předdeslal numerický model, byly i v tomto praxi bližším případě naučeny různé architektury a verze sítí. Především byla testována nutnost znalosti lokalizace zdrojů a závislost výsledků konverze na počtu použitých snímačů. Adaptace vah neuronových sítí resilientní variantou algoritmu back-propagation probíhala vždy v max. 500 učicích cyklech, po níž následovala citlivostní analýza.



Obr. 9.10: Závislost amplitudy na vzdálenosti od zdroje.



Obr. 9.11: Závislost RMS na vzdálenosti od zdroje.

Tab. 9.1 uvádí souhrn výsledků devíti verzí sítí, typických pro příslušnou konfiguraci, a testovaný výběr vstupních parametrů. Hodnoty amplitudy a RMS byly přepočítávány vždy pouze z hodnot příslušného jednoho parametru signálu z vybraných snímačů $s1-s4$ a případně souřadnic lokalizace zdroje. Použité vstupní parametry jsou označeny v posledních šesti sloupcích tabulky 9.1 spolu s citlivostními koeficienty odpovídající verze naučené sítě. Stupně šedi jsou uvažovány relativně vzhledem k hodnotám koeficientů

příslušné jedné sítě (pro zvýraznění významných vstupů), nikoliv globálně. Dále jsou v přehledu počty neuronů v jednotlivých vrstvách (3.-5.sloupec) včetně učící (MSE) a generalizační chyby (MSE_{GEN}) na množinách K_{TR} resp. K_{TEST} .

verze sítě	korigovaný parametr	počty neuronů ve vrstvách / / učící a gen. chyba			použité souřadnice lokalizace a snímače / / citlivostní koeficienty					
		vstupní	1.skrytá	2.skrytá	x	y	s ₁	s ₂	s ₃	s ₄
1.	AMPLITUDA	6	199	99	•	•	•	•	•	•
		MSE=0.0218 ; MSE _{GEN} =0.0795			0.23	0.25	0.40	0.39	0.55	0.39
2.	RMS	6	59	39	•	•	•	•	•	•
		MSE=0.0030 ; MSE _{GEN} =0.0015			0.04	0.05	0.33	0.31	0.29	0.29
3.	RMS	4	99	69			•	•	•	•
		MSE=0.0018 ; MSE _{GEN} =0.0038					0.21	0.41	0.23	0.41
4.	RMS	4	99	69			•	•	•	•
		MSE=0.0019 ; MSE _{GEN} =0.0035					0.38	0.24	0.39	0.25
5.	RMS	3	99	69				•	•	•
		MSE=0.0030 ; MSE _{GEN} =0.0026						0.60	0.07	0.61
6.	RMS	2	39	19				•		•
		MSE=0.0053 ; MSE _{GEN} =0.0026						0.63		0.64
7.	RMS	5	39	19	•	•		•	•	•
		MSE=0.0034 ; MSE _{GEN} =0.0017			0.04	0.07		0.49	0.21	0.57
8.	RMS	4	39	19	•	•			•	•
		MSE=0.0058 ; MSE _{GEN} =0.0033			0.06	0.27			0.54	0.65
9.	RMS	3	39	19	•	•				•
		MSE=0.0080 ; MSE _{GEN} =0.0044			0.31	0.28				1.25

Tab. 9.1: Souhrnné výsledky různých verzí neuronových sítí na korekci vybraných parametrů v případě tenké desky.

Závěry

Podobně jako u čistě numerického modelu ukazují citlivostní koeficienty na fakt, že parametry lokalizace nehrají zásadní roli a lze je při učení sítě vynechat. Dále lze vynechat parametry z maximálně dvou snímačů, umístěných diagonálně proti sobě, aniž by se konvergence učící chyby a generalizace zhoršily. Z citlivostních koeficientů verze 3 a 4, které se liší pouze inicializačními vahami, je "symetrie" významnosti protilehlých snímačů patrná.

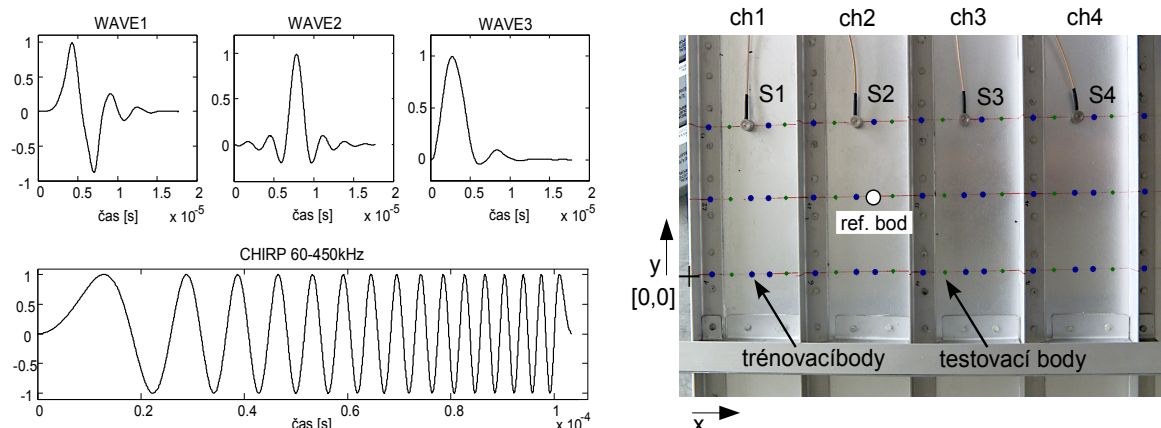
Poslední tři verze sítí jsou uvedeny pro demonstraci významu znalosti lokalizace, která získává na důležitosti až při využití parametrů pouze z jediného snímače (viz tab. 9.1, verze 9). Dalším porovnáním výsledků je patrné, že sítě s menším počtem neuronů vykazují překvapivě lepší generalizační chybu MSE_{GEN} než učící MSE . Jako vysvětlení se nabízí díky menší architektuře hladší aproximace korekčního vztahu ve spojení s testovacími daty, která mohou svou příhodnou variabilitou lépe vyhovovat chybové funkci.

9.4 Korekce emisních parametrů na reálné konstrukci

Jak je patrné z předešlého, zjednodušená korekce nejdůležitějších signálových parametrů využívající umělé neuronové sítě byla úspěšně testována na numericky simulovaných datech [20]. Nicméně, detailní numerické modelování šíření elastických vln ve složitých konstrukcích je extrémně náročné a doposud mimo možnosti současné výpočetní techniky. Z tohoto důvodu byly korekční neuronové sítě aplikovány při experimentech na částech reálných leteckých konstrukcí.

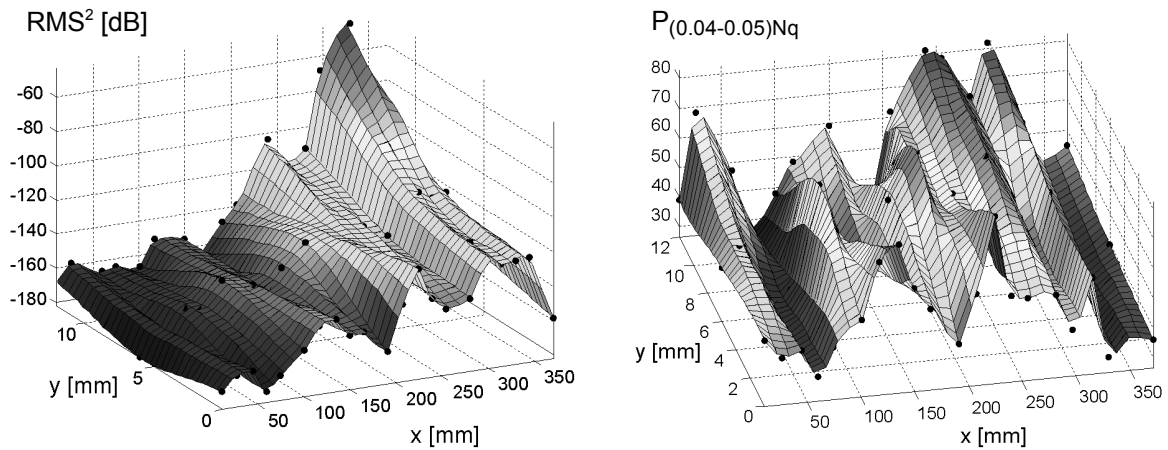
Pro účely zpracování neuronovými sítěmi byly při ultrazvukovém buzení pomocí zdrojů s různými časovými průběhy (*WAVE1-3* a *CHIRP* viz obr. 9.12) a amplitudami (1.5, 3, a 6V) naměřeny signály, jejichž parametrizací byla získána tréninková a testovací data (rozmístění budících bodů viz pravá část obr. 9.12). Počítané parametry byly shodné s charakteristikami použitými při lokalizaci zdrojů AE v kap. 8. Všechny korekce byly vztaženy k jednomu zvolenému referenčnímu bodu (viz obr. 9.12).

Pro přepočty parametrů byly opět aplikovány BP-sítě se dvěma skrytými vrstvami (79 a 39 neuronů se sigmoidálními přenosovými funkcemi). Během 500 učicích cyklů se pro amplitudové parametry dařilo snížit chybu sítí až na hodnotu $MSE=0.01$. V souladu s výsledky předchozího numerického modelu [20] se ale ukazuje, že pro dostatečně přesnou korekci jednoho konkrétního parametru je nutné uvažovat i charakteristiky jiné. Citlivostní analýza obdobně potvrdila, že znalost souřadnic zdrojů není potřeba uvažovat jako vstupy sítí.



Obr. 9.12: Zdroje *WAVE1-3*, *CHIRP* a rozmístění budících bodů

Z obrázku 9.13 je patrné, že učení neuronových sítí na korekci parametrů se složitou přenosovou funkcí vyžaduje podstatně rozsáhlejší měření s jemnějším pokrytím trénovacích bodů na uvažované oblasti. Jejich stávající hustota neumožňuje z naměřených dat vyčlenit testovací množinu, která by neidentifikovala přeučení druhého typu (def. viz kap. 6.8). Na jednoduchých leteckých konstrukcích mohou numerické simulace naopak redukovat počet měření s různými tvary budících vln a jejich amplitudami.



Obr. 9.13: Změny vybraných parametrů naměřených snímačem 4 (buzení vlnou WAVE1 o amplitudě 12V)

9.5 Možnosti korekce emisních parametrů na polohu zdroje AE

Pro jednoduchou a okamžitou korekci emisních parametrů s ohledem na vzájemnou polohu snímače a zdroje AE, která je důležitá pro porovnání aktivity různých zdrojů, byla navržena metoda, založená na automatickém přepočtu těchto parametrů pomocí ANN. Natrénovaná neuronová síť využívá ke korekci redundantní informace o konkrétním emisním zdroji, které jsou obsaženy v parametrech signálů z více snímačů. Úkolem sítě je okamžitě přepočítávat hodnoty emisních parametrů ze snímačů vzdálených od zdroje AE na parametry signálu z referenčního snímače, který se nachází v blízkém okolí zdroje.

Citlivostní analýza ukázala, že vstupní parametry lokalizace (souřadnice polohy zdroje) nehrají při korekcích zásadní roli a lze je i při učení sítě vynechat. K dostatečně spolehlivé korekci jednoho signálového parametru od výrazněji odlišných emisních zdrojů je na vstupech zapotřebí vždy uvažovat také ostatní parametry. Pro lepší konvergenci učení neuronové sítě je výhodné zahrnout do vstupních dat např. také parametry spektrální. Citlivostní schéma transformace emisních parametrů závisí na konkrétním tělese, rozmístění snímačů a tréninkové množině spíše než na použité verzi neuronové sítě.

Důležitým poznatkem, plynoucím ze simulačních experimentů je, že na výstupech neuronové sítě lze získat i jiné korigované emisní parametry než které byly uvažovány na vstupech. Výsledky numerických experimentů naznačily široké možnosti praktického využití navržené metody korekce parametrů emisních zdrojů, v případě komplikovaných leteckých konstrukcí však za předpokladu dostatečného množství tréninkových dat, tj. rozsáhlejšího měření s jemnějším pokrytím trénovacích bodů na uvažované oblasti.

10. ROZPOZNÁVÁNÍ ZDROJŮ AE

10.1 Problematika identifikace emisních zdrojů


Identifikace emisních zdrojů je jedním z nejobtížnějších problémů analýzy záznamů AE. Při jejich rozpoznávání vycházíme z detekovaných signálů AE pocházejících často nejen od různých mechanismů poškozování materiálu, ale také vznikajících v důsledku nežádoucího akustického rušení. Důležité jsou přitom nejen globální parametry emitujícího zdroje, jako je jeho lokalizace, četnost emisních událostí a emisních překmitů, ale i další, tvarové parametry signálu, které umožňují rozpoznat či alespoň odhadnout o jaký typ emisní aktivity jde (určení původu signálu představuje řešení komplikované inverzní úlohy). Už jen spolehlivá primární selekce takových záznamů by umožnila věnovat veškerou pozornost rizikovým 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.

Nedostatečná znalost vlivu disperzních efektů v materiálech je jedním z nejvíce omezujících faktorů klasifikace zdrojů AE. 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 (kap. 10.2) [21]. Tento přístup byl dále testován na letecké konstrukci (kap. 10.3) [22] a finálně při identifikaci reálných zdrojů AE (viz kap. 10.4) [23].


10.2 Model s experimentálně naměřenou Greenovou funkcí

Přenos mezi zdrojem AE a snímačem je obecně modelován Greenovou funkcí. Jelikož ale její přesné vyjádření není dosud prakticky možné, byla experimentálně naměřena při buzení ocelové desky pulsním laserem. Vstupní signály použité pro učení a testování neuronové sítě byly generovány konvolucí modelových zdrojů s touto pulsní odezvou. Různé zdroje AE pak byly simulovány lineární kombinací tří modelových zdrojových funkcí (modifikované wavelety, viz obr. 10.1). Cílem klasifikátoru je zpětný odhad váhových koeficientů této lineární kombinace.

Koeficienty kombinace waveletů a , b , c splňují podmínky $a, b, c \in \langle 0, 1 \rangle$, $a, b, c = 1$. Klasifikované signály $z_p(t)$ byly počítány konvolucí kombinovaného zdroje S_p s Greenovou funkcí G (graf viz obr. 10.2), představující zmiňovaný přenos mezi zdrojem AE a snímačem.



Obr. 10.1: Modelové zdrojové funkce $W1$, $W2$, $W3$ a jejich kombinace.



$$z_p(t) = \text{conv}(S_p, G), \quad S_p = a_p * W1 + b_p * W2 + c_p * W3, \quad a_p=0.3, b_p=0.2, c_p=0.5$$

Obr. 10.2: Graf typické Greenovy funkce a vygenerovaného signálu

Celkem bylo pro testování sítě vygenerováno 2000 signálů, z nichž 500 bylo použito jako tréninková množina. Vstupy neuronové sítě se dvěma skrytými vrstvami a architekturou 14-27-19-3 pak představují časové a frekvenční parametry signálů $z_p(t)$:

1. Amplituda (4.1), 2. Risetime (4.3), 3. Efektivní hodnota (RMS, viz 4.5), 4. Moment energie (4.6), 5. Průměrná hodnota (ASL, viz 4.7), 6. Směrodatná odchylka (4.8), 7. Šikmost a 8. Špičatost (4.9), 9.-14. Poměrné zastoupení P_X frekvenčních pásem **A** ($[0, 0.12]f_N$), **B** ($[0.12, 0.24]f_N$), **C** ($[0.24, 0.36]f_N$), **D** ($[0.36, 0.48]f_N$), **E** ($[0.48, 0.6]f_N$) a **F** ($[0.6, 1]f_N$) v celkovém frekvenčním pásmu **G** ($[0, f_N]$) (kde f_N je Nyquistova frekvence).

CITLIVOSTNÍ KOEFICIENTY

1	0.173	0.266	0.149
2	0.093	0.068	0.047
3	0.320	0.193	0.184
4	0.301	0.178	0.196
5	0.564	0.250	0.206
6	0.196	0.322	0.158
7	0.099	0.063	0.043
8	0.065	0.015	0.030
9	0.022	0.014	0.016
10	0.053	0.020	0.012
11	0.035	0.012	0.032
12	0.039	0.050	0.022
13	0.081	0.134	0.082
14	0.260	0.172	0.109
	1	2	3

výstupy

Tab. 10.1: Citlivostní schéma naučené sítě

Učení na chybu $MSE=0.001$ (průměr kvadrátů odchylek) proběhlo v přibližně 180 iteracích. Pro všechna vygenerovaná data pak byly určeny průměrné absolutní hodnoty (MAE) odchylek na výstupech, které uvádí tabulka 10.2. Z citlivostních koeficientů sítě v tabulce 10.1. je zřejmé, že nejvýznamnější parametry pro rozpoznávání modelových zdrojů odpovídají vstupům 1, 3, 4, 5, 6, 13 a 14 (tj. "energetické" parametry, ASL a poměrné zastoupení vysokých frekvencí). V tomto případě se pro redukci vstupů neosvědčila faktorová analýza. Mezi proměnnými jednoznačně detekovala pouze závislost parametru 3 a 4, což vedlo spolu s citlivostní analýzou ke konečné redukci na parametry 1, 3, 5, 6, 13 a 14. Nová naučená síť s architekturou 6-13-7-3 a obdobnými parametry učení dosahovala na stejné datové množině dokonce lepších výsledků (viz tabulka 10.2). Tyto výsledky korespondují s teoreticky očekávanou vlastností lepší generalizace.

MAE	VÝSTUPY		
	1	2	3
před redukcí	0.0254	0.0239	0.0240
po redukcí	0.0247	0.0204	0.0188


Tab. 10.2.: Průměry kvadrátů odchylek na výstupech sítě.

10.3 Rozpoznávání modelových pulzů v reálných konstrukcích

Aplikovatelnost umělých neuronových sítí pro rozpoznávání zdrojů AE byla na základě dobrých výsledků odhadů kombinací modelových pulzů postupně ověřována na experimentálních konfiguracích, které jsou blíže praxi. Nahrazení numerických simulací reálným experimentem na části letecké konstrukce představuje důležitý vývojový krok směrem k praktickým aplikacím této slibné metody.

Popis experimentu

Zkušební vzorkem pro rozpoznávání modelových zdrojů AE a jejich kombinací byla páka podvozku malého dopravního letadla zhotovená z ušlechtilé ocele (obr. 10.3). Zdroji i snímači AE byla čtveřice piezoelektrických měničů stejného typu s integrovanými, trubkovitě tvarovanými magnetickými podložkami. V každém okamžiku byl jeden měnič zapojen jako pulzér (zdroj AE) a ostatní tři jako snímače AE. K buzení pulzéro bylo použito generátor libovolných průběhů (arbitrary generator), generující elektrické pulzy požadovaných tvarů a amplitud.

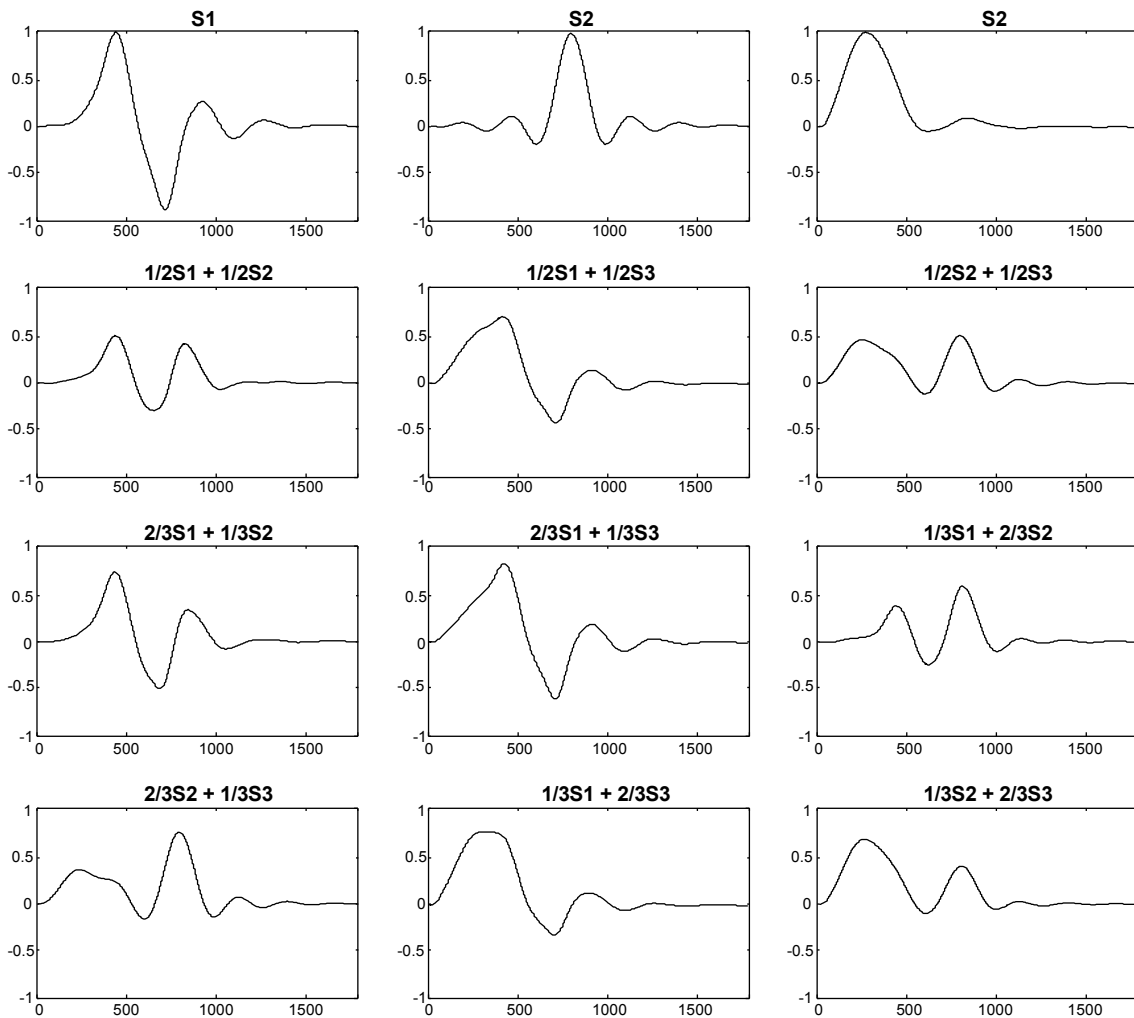


Obr. 10.3: Konfigurace měničů AE

Signály byly buzeny různými kombinacemi tří základních zdrojových typů (viz obr.10.4). Každá složená zdrojová kombinace byla vysílána s pěti různými amplitudami, zaznamenána jako signál AE a zparametrizována. Několik set takto simulovaných emisních zdrojů AE z různých míst pak sloužilo k učení a testování ANN. Jejich architektury byly pomocí citlivostní analýzy postupně optimalizovány tak, aby hodnoty na výstupních neuronech poskytl co nejlepší odhady kvantitativního zastoupení testovaného typu emisního zdroje.

Měřicí aparatura

Na snímku v obr. 10.3 jsou patrné 4 snímače/budiče signálu AE o průměru 20mm, 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 15 360 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 40dB) a dále na vstup měřicí aparatury.



Obr. 10.4: Kombinace zdrojových pulsů

Generování pulsů

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 $S1-S3$, jejichž tvar je znázorněn na obr. 10.4 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, tj. 80-300kHz. Kromě tvaru budících pulsů 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.

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:

1. Amplituda (4.1), 2. Risetime (4.3), 3. Efektivní hodnota (RMS, viz 4.5), 4. Moment energie (4.6), 5. Průměrná hodnota (ASL, viz 4.7), 6. Směrodatná odchylka (4.8), 7. Šikmost a 8. Špičatost (viz 4.9), 9.-13. Poměrné zastoupení P_X frekvenčních pásem $A ([0,0.03]f_N)$, $B ([0.03,0.05]f_N)$, $C ([0.05,0.1]f_N)$, $D ([0.1,0.2]f_N)$ a $E ([0.2,0.5]f_N)$ v celkovém frekvenčním pásmu $F ([0,f_N])$ (kde f_N je Nyquistova frekvence) a 14. Relativní poloha těžiště spektrální hustoty $f(w)$, tj. relativní frekvence odpovídající "těžišti spektra", viz (4.14).

Učení neuronových sítí

Pro řešení klasifikačního problému se již dříve osvědčily umělé neuronové sítě se dvěma skrytými vrstvami neuronů s tangens-sigmoidálními přenosovými funkcemi. Inicializační váhy a prahy neuronů byly nastaveny statistickou optimalizací startovních potenciálů neuronů (viz kap. 6.10) a během učení dále iteračně adaptovány pomocí rychlé resilientní varianty učicího algoritmu zpětného šíření s momentem a 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 neuronů ve skrytých vrstvách je nutné volit podle složitosti řešené úlohy, nejprve poněkud přemrštěné. V případě úspěšné minimalizace tréninkové chyby je žádoucí architekturu postupně zmenšovat. V opačném případě, kdyby počty neuronů zůstávaly příliš vysoké, hrozí "přeučení" a tudíž špatná generalizace sítě (viz kap. 6.8). Jak vyplynulo z mnoha experimentů při učení různých verzí sítí, 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 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 (tj. 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.

Optimalizace architektury ANN

Díky použití metody citlivostní analýzy ANN (AFSSM viz kap. 6.11) lze nalézt takové parametry AE signálu (viz následující), které jsou v tomto případě nejvýznamnější pro rozpoznávání různých modelových emisních zdrojů. 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 učící chyby až na relativně nízkou hodnotu 0.017, ale i přes probíhající regularizaci se pro více případů startovních vah podařilo dosáhnout testovací chyby (tj. průměru sumy kvadrátů odchylek skutečných výstupů sítě od správných výstupních hodnot testovacích dat) minimálně 0.047. Citlivostní schéma 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 do maxima (risetime).

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 učící 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 14-ti vstupy.

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. 10.3: Citlivostní schéma verze 14-17-5-3

Postupnou optimalizací počtů neuronů až na verzi $14-17-5-3$ byl zachován dobrý učící potenciál sítě a stabilní citlivostní schéma (viz tab. 10.3 - v podstatě shodná s případem $42-5-4-3$ zúženým pro jeden snímač). Generalizační chyba, při učící o hodnotě 0.00081, byla 0.0035. Z tab. 10.3 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. Nabízí se tedy redukce vstupů pouze na těchto pět parametrů. Po naučení neméně úspěšné sítě byla opět provedena její citlivostní analýza. Výrazný význam poměrného zastoupení vysokých frekvencí (parametry 12 a 13) zůstal zachován, přičemž charakteristiky jiné, než spektrální, nejsou klíčové (viz tab. 10.4).

CITLIVOSTNÍ KOEFICIENTY


vstupní parametry	4	0.10	0.09	0.04
	11	0.15	0.12	0.07
	12	0.72	0.22	0.44
	13	0.63	0.18	0.40
	14	0.13	0.36	0.22
		1	2	3
		výstupy		

Tab. 10.4: Citlivostní schéma verze 5-17-5-3

V redukci architektury lze tedy pokračovat. Na základě uvedených závěrů citlivostní analýzy, které jsou i fyzikálně opodstatněné, byly pro další testování vybrány pouze parametry 12, 13 a 14. Celkový počet neuronů sítě ovšem nemůže klesnout pod hranici teoreticky zaručující konvergenci učící chyby, což je patrné z postupného nárůstu minima neuronů ve skrytých vrstvách oproti úspěšné architektuře 4-5-4-3, redukuje-li architekturu v rámci zachování dobré generalizace až na 3-17-5-3.

Minimalizace učící chyby verze sítě se třemi vstupy probíhala poměrně rychle, max. kolem 500 adaptačních cyklů. Typický průběh je zobrazen na obr. 10.5. Všimněme si rovněž dočasné ustrnutí v lokálním minimu kolem 40. cyklu, kde došlo opakovaně ke zhoršení aktuální *MSE* s následným úspěšným pokračováním minimalizace až na hodnotu 0.00421 díky automatickému přenastavení parametrů učení. Průměr kvadrátů všech vah sítě (*MSW*) dosáhl hodnoty 0.182, což je z hlediska vhodné citlivosti neuronů vzhledem k jejich počtu uspokojivé.

Citlivostní schéma (tab. 10.5) potvrzuje oprávněnost vynechání parametrů kromě tří spektrálních, 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 zřejmě 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. 10.5: Průběh minimalizace učící chyby sítě verze 3-17-5-3

CITLIVOSTNÍ KOEFICIENTY

vstupní parametry	12	0.69	0.25	0.44
	13	0.65	0.14	0.49
	14	0.19	0.38	0.22
		1	2	3
		výstupy		

Tab. 10.5: Citlivostní schéma verze 3-17-5-3

Odchytky výstupů naučené ANN od skutečných hodnot kombinace zdrojové funkce jsou vyneseny do histogramu na obr. 10.6. 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.



Obr. 10.6: Histogram odchylek výstupů sítě verze 3-17-5-3

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.

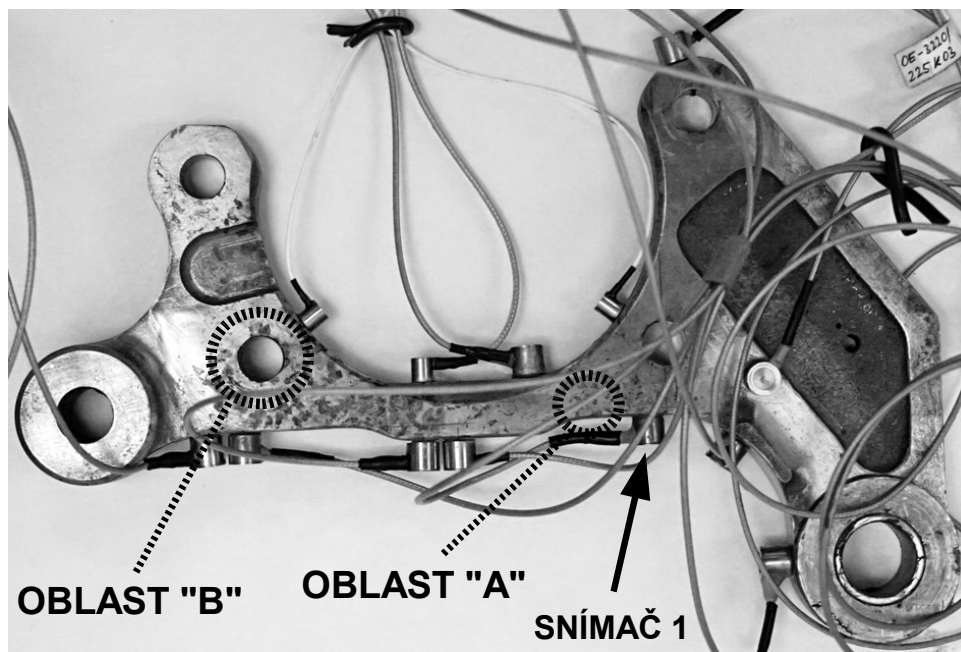
10.4 Identifikace emisních zdrojů v letecké součásti

Ačkoliv přesné určení původu signálu AE vyžaduje úplné řešení inverzní úlohy (které je v praxi nerealizovatelné), pro odhad typu emisní aktivity postačí zjednodušený algoritmus, jehož vstupy jsou pouze vybrané parametry zaznamenaného signálu. Klasifikátor takového typu byl navržen a úspěšně aplikován pro případ modelových zdrojů (viz předchozí kapitoly). Spolehlivá primární selekce záznamů emisních projevů způsobených např. pohybem namáhaného vzorku v upínacích čelistech zatěžovacího zařízení od rizikových emisních zdrojů je úkolem níže popisovaného systému na bázi ANN. Jeho návrh (především fáze učení neuronové sítě) byl možný díky souboru spolehlivě identifikovatelných dat, zaznamenaných při únavové zkoušce malé části letecké konstrukce, na níž byly pokročilými metodami lokalizace zdrojů AE prokázány dvě dominantní oblasti emisní aktivity.

Popis experimentu

Testovaným vzorkem byla součást předního podvozku letounu, zvaná "steering actuator bracket" (SAB), která je spolu se snímači AE ilustrována na obr. 10.6. SAB byl cyklicky tlakově namáhán jednoosovým zatěžovacím strojem Instron-Schenck 100kN maximální silou 43kN, v kritických bodech způsobující maximální tlak okolo 870MPa. Akustická emise byla během cyklování monitorována AE systémem DAKEL XEDO. Všechny zaznamenané signály AE byly po určitém počtu zatěžovacích cyklů využity k detailní expertní analýze lokalizace emisních událostí za účelem detekce iniciace trhliny.

Nejvíce emisních událostí vznikalo blízko místa očekávaného formování trhliny (viz obr. 10.6, oblast "A"). Další koncentrace AE byla pozorována kolem otvoru v levé části bracketu (viz obr. 10.6, oblast "B"). Úkolem klasifikátoru zdrojů AE je rozpoznání signálů typů "A" a "B", pocházejících z příslušných dvou oblastí, kde jsou předpokládány různé zdrojové mechanismy.



Obr. 10.6: Namáhaný vzorek (steering actuator bracket)

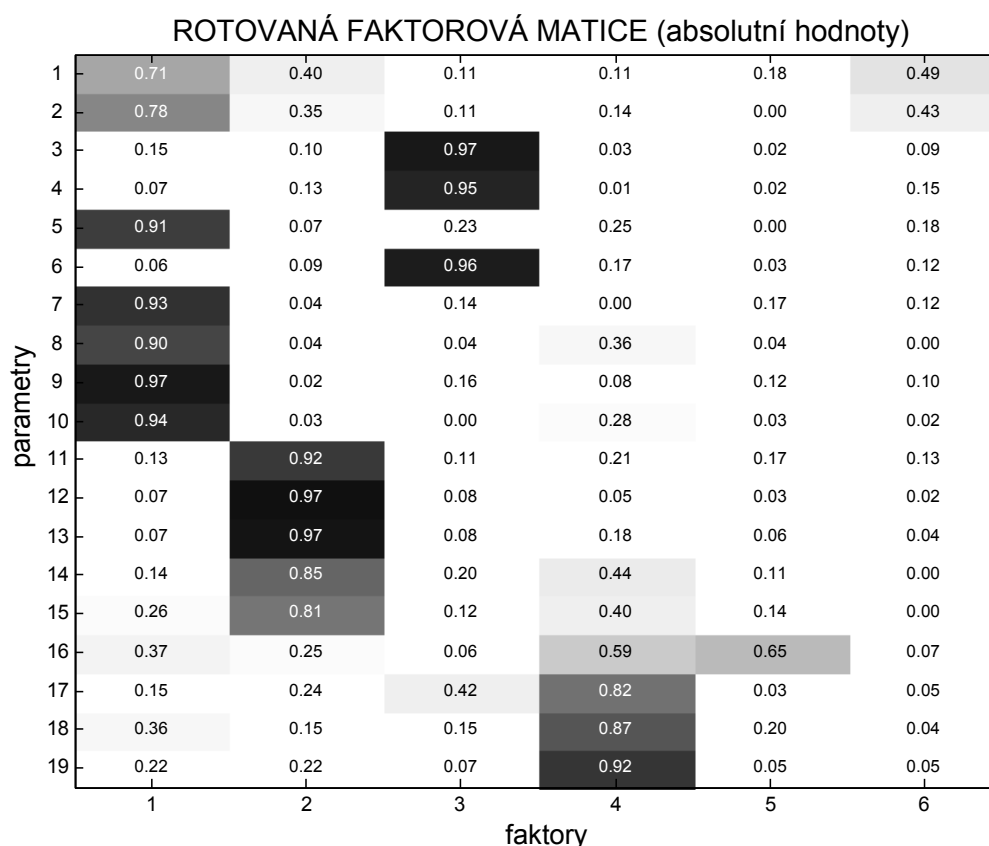
Parametrizace signálů AE

Jako charakteristiky signálů AE bylo použito následujících 19 parametrů v časové a frekvenční oblasti:

1. Amplituda signálu (4.1), 2. Amplituda vektoru g (4.2), 3. Rise time signálu (4.3), 4. Rise time vektoru g (4.4), 5. Efektivní hodnota (RMS, viz 4.5), 6. Moment energie (4.6), 7-10. Centrální momenty vektoru g ve smyslu hustoty pravděpodobnosti (4.10-4.12) 11.-15. Poměrné zastoupení P_X frekvenčních pásem A ($[0,0.05]f_N$), B ($[0.05,0.1]f_N$), C ($[0.1,0.15]f_N$), D ($[0.15,0.3]f_N$) a E ($[0.3,0.5]f_N$) v celkovém frekvenčním pásmu F ($[0,0.5]f_N$) (kde f_N je Nyquistova frekvence), 16. Relativní poloha těžiště spektrální hustoty $f(\omega)$ (relativní frekvence odpovídající "těžišti spektra", viz (4.14)) a 17.-19. Rozptyl a vyšší centrální momenty spektrální hustoty f podle vzorců 4.15 a 4.16.

Faktorová analýza a výpočet faktorových skóre

Oproti předchozím případům redukce dimenze klasifikačního problému na základě faktorové analýzy, kdy výběr charakteristik signálů AE vyplýval z rotované faktorové matice (vysoké hodnoty faktorových zátěží), byla aplikována metoda přepočtu parametrů na faktorová skóre, tj. hodnoty nových, nekorelovaných proměnných. Metoda hlavních os ukázala, že na vysvětlení 96% celkového rozptylu dat postačí pouhých 6 faktorů.



Tab. 10.6: Faktorové schéma

Rotované faktorové schéma uvádí tabulka 10.6. Je evidentní, že první faktor je saturován vlastnostmi jako jsou amplituda, RMS a centrální momenty vektoru g . Další dobře interpretovatelné faktory jsou jasně určeny poměrným zastoupením nižších spektrálních pásem (2. faktor) a tvarem výkonové spektrální hustoty (4. faktor). Faktorová analýza dále


prokázala, že nově zavedené charakteristiky tvaru spektrální hustoty (parametry 16-19) představují novou, lineárně nezávislou informaci. Samotné hodnoty faktorových skóre P (nových nekorelovaných veličin) byly počítány podle vzorce (5.19).

Učení neuronové sítě

Dobré výsledky při rozpoznávání modelových zdrojů umožnily rozšířit možnou aplikaci umělých neuronových sítí i na případ primární selekce reálných zdrojů AE. Jádrem klasifikátoru byla tedy opět BP-síť se šesti vstupy, což odpovídá počtu extrahovaných faktorů, přičemž byly uvažovány signály pouze z jednoho snímače. Optimální architektura se na základě výsledků různých verzí sítí pohybuje kolem 9 a 7 neuronů s tangens-sigmoidálními přenosovými funkcemi v první, resp. druhé skryté vrstvě. Výstupní vrstvu tvořily dva neurony s lineární přenosovou funkcí, počítající odhad klasifikačních vah.

Učení neuronových sítí probíhalo opět podle resilientní verze algoritmu zpětného šíření s momentem a regularizací, inicializovaného ze statisticky optimalizovaných vah (viz kap. 6.10). Pro předložená faktorová skóre, odpovídající zdroji AE z oblasti A a B , by měly být výstupy neuronové sítě blízké vektoru $[1,0]$, resp. $[0,1]$. Jako tréniková množina byla použita polovina z 900 zpracovaných signálů (faktorová skóre), ostatní pro účely testování.

Po přibližně 300 učicích cyklech dosahoval průměr kvadrátů odchylek (MSE) na tréninkových standardizovaných faktorových skóre hodnot pod 0.0004, přičemž generalizační chyba na testovacích byla kolem 0.002. Tabulka v levé části obrázku 10.7 uvádí citlivostní schéma typické verze popisované sítě. Každý ze dvou sloupců obsahuje šest hodnot pro příslušný vstup sítě, jimiž jsou faktorová skóre. Je zřejmé, že nejvýznamnější vstup odpovídá druhému faktoru saturovanému původními parametry zastoupení nižších spektrálních pásem.



Obr. 10.7: Výsledky klasifikace

Tento výsledek se odráží od faktu, že dva typy signálů AE jsou téměř lineárně separovatelné na základě některých spektrálních parametrů. Teoreticky by tedy měl k rozlišení obou typů zdrojů AE postačit jediný perceptron. Nicméně, tato apriorní informace sloužila pouze k ověření použité metodologie a při samotném návrhu klasifikátoru nebyla využita. Poměrně významným vstupem je i třetí faktor, který je čerpán rozptylem dob nárůstu do maxima signálu a pomocného vektoru g a také momentem energie.

Pravá část obr. 10.7 ilustruje výsledky rozpoznávání pro veškerá data. Téměř všechny signály byly úspěšně přiřazeny ke správné oblasti lokalizace. V ideálním případě přiřazuje demonstrováný druhý výstup neuronové sítě o hodnotách 1 nebo 0 původ emisních zdrojů do oblasti *B*, resp. *A*. Pro reálná data je původ určen bližší hodnotou ke skutečnému výstupu sítě.

Závěry

V praxi byla na příkladu emisních dat ze zátěžové zkoušky části letecké konstrukce úspěšně odzkoušena metodologie optimalizace parametrizace signálů AE sloužících jako vstupy jednoduchého klasifikátoru emisních zdrojů na bázi umělých neuronových sítí. Cílem klasifikační metody je spolehlivá eliminace nežádoucích signálů AE. Sadu běžných emisních parametrů rozšířenou o nově zavedené charakteristiky se podařilo interpretovat a podstatně redukovat pomocí faktorové analýzy, při níž bylo extrahováno šest faktorů vysvětlujících 96% celkového rozptylu proměnných. Pouze šest nových nekorelovaných signálových charakteristik (faktorová skóre) na vstupech ANN postačilo k úspěšnému naučení sítí pro identifikaci zdrojů AE dvou různých typů.

Podle výsledků citlivostní analýzy naučených sítí je nejvýznamnějším vstupem klasifikátoru druhý extrahovaný faktor, který je saturován původními parametry poměrného zastoupení nižších spektrálních pásem. Tento závěr dobře koresponduje s apriorní informací o struktuře dat a může být snadno interpretován v rámci teorie šíření elastických vln. Výsledky navržené metody jsou slibné pro její budoucí využití na složitější emisní data.

REFERENCE

- [1] Miller, Ronnie K., McIntire P.: *Nondestructive testing handbook; v.5.* (American Society for Nondestructive Testing, INC., USA, ISBN 0-931403-02-2, 1987)
- [2] Rose, Joseph L.: *Ultrasonic Waves in Solid Media.* (Cambridge University Press, ISBN 0 521 64043 1, 1999)
- [3] Blaháček M.: *Lokalizace zdrojů akustické emise pomocí umělých neuronových sítí.* (Disertační práce, ČVUT FJFI, 1999)
- [4] Petřík M., Kůs V.: *Localization of Acoustic Emission Sources by Means of Statistical Methods.* (2nd Internat. Workshop "NDT in Progress 2003", Prague, 6-8 Oct. 2003, Proc. ed. by P. Mazal, CNDT 2003, pp. 320).
- [5] Lokajíček T., Klíma K.: *High-order Statistics Approach: Automatic Determination of Sign and Arrival Time of Acoustic Emission Signals.* (28th European Conference on Acoustic Emission Testing "EWGAE - Kraków 2008", Kraków, September 17-19, 2008, Proc. ed. by K. Ono, ISBN 978-83-7242-478-5, pp. 82-87)
- [6] Sedlák P., Hirose Y., Enoki M., Šikula J.: *Arrival Time Detection in Thin Multilayer Plates on the Basis of Akaike Information Criterion.* (28th European Conference on Acoustic Emission Testing "EWGAE - Kraków 2008", Kraków, September 17-19, 2008, Proc. ed. by K. Ono, ISBN 978-83-7242-478-5, pp. 166-171)
- [7] Yamaguchi K., Oyaizu H.: *Advanced AE Instrumentation System for Versatile and Precise Use by Waveform Microdata Processing.* (Proc. of the 3rd Congress on AE from Composite materials "AECM 3", Paris, July 17-21, 1989)
- [8] Ůberla K.: *Faktorová analýza.* (ALFA, Bratislava, 1976)
- [9] Řičan P., Hampejsová O.: *Prolegomena k faktorové analýze.* (Státní pedagogické nakladatelství, Praha, 1972)
- [10] Chlada M.: *Rozpoznávání zdrojů akustické emise pomocí neuro-fuzzy systému.* (Diplomová práce, ČVUT FJFI, 1999)
- [11] Rojas R.: *Neural networks: a systematic introduction.* (Springer-Verlag Berlin Heidelberg, ISBN 3-540-60505-3, 1996)
- [12] Bishop Ch. M.: *Neural Networks for Pattern Recognition.* (Oxford University Press, ISBN 0-19-853864-2, 1995)
- [13] 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)
- [14] Převorovský Z., Blaháček M.: *Acoustic Emission Source Location by Artificial Neural Networks.* (Tagungsband der IV. Kolloquium Technische Diagnostik, Dresden 1996, p.212)

- [15] Převorovský Z., Landa M., Blaháček M., Varchon D., Rousseau J., Ferry L., Perreux D.: *Ultrasonic Scanning and AE of Composite Tubes Subjected to Multiaxial Loading*. (Ultrasonics 36 (1-5), 531-537, 1998)
- [16] Grabec I., Sachse W.: *Solving AE problems by a neural network*. (Journal of Acoustic Emission 6(1), 19-28, 1987)
- [17] Převorovský Z.: *Notes on wave and waveguide concepts in AE*. (25th European Conference on Acoustic Emission Testing "EWGAE 2002", Prague, September 11-13, 2002, Proc. Vol.II, pp. 83-90)
- [18] Vallen H., Vallen J.: *Free of cost software tools generate dispersion curves, perform wavelet transform and help to correlate both kinds of information*. (25th EWGAE, Prague, 11-13 September 2002, pp. II/255-II/262)
- [19] Blaháček M., Převorovský Z., Landa M.: *Processing of AE signals in dispersive media*. (26th EWGAE, Berlin, 14-17 September 2004)
- [20] Chlada M., Převorovský Z., Vodička J.: *Correction of AE signal parameters by neural networks*. (34th Internat. Conf. on NDT "DEFEKTOSKOPIE 2004", Prague, 3-5 November 2004, Proc. ed. by P.Mazal, CNDT 2004, ISBN 80-214-2749-3, pp.339-346)
- [21] 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 November 2001, Proc. ed. by P.Mazal, CNDT 2001, pp.317-327)
- [22] Chlada M., Blaháček M., Převorovský Z.: *Architecture Optimization of Acoustic Emission Source Recognition Neural Networks*. (37th Internat. Conf. on NDT "DEFEKTOSKOPIE 2007", Prague, 7-9 November 2007, Proc. pp.297-304)
- [23] Chlada M., Převorovský Z.: *AE Source Recognition by Neural Networks with Optimized Signal Parameters*. (28th European Conference on Acoustic Emission Testing "EWGAE - Kraków 2008", Kraków, September 17-19, 2008, Proc. ed. by K. Ono, ISBN 978-83-7242-478-5, pp. 250-255)

SEZNAM PUBLIKACÍ

Články v mezinárodních recenzovaných časopisech:

Landa M., Chlada M., Převorovský Z., Novák V., Šittner P.: *Nondestructive evaluation of phase transformations in Cu based shape memory alloys by ultrasonic techniques.* (Journal of Acoustic Emission, 17 (3-4), S57-S64, 1999)

Blaháček M., Převorovský Z., Krofta J., Chlada M.: *Neural network localization of noisy AE events in dispersive media.* (Journal of Acoustic Emission, 18 (1), 279-285, 2000).

Chlada M., Převorovský Z.: *Threshold Counting in Wavelet Domain.* (Journal of Acoustic Emission, 20 (1), ISSN 0730-0050, 134 - 144, 2002)

Článek v časopise:

Převorovský Z., Krofta J., Blaháček M., Chlada M.: *Efektivní metody ultrazvukové diagnostiky porušování leteckých konstrukcí.* (NDT WELDING BULLETIN, 17 (4), ISSN 1213-3825, 15-20, 2008)

Kapitola v knize:

Převorovský Z., Chlada M., Vodička J.: *Inverse Problem Solution in Acoustic Emission Source Analysis - Classical and Artificial Neural Network Approach.* (in: P.P. Delsanto, ed.: "Universality of Nonclassical Nonlinearity with applications NDE and Ultrasonics", SPRINGER - Science+Business Media, Inc., New York, USA, 2007, ISBN-10: 0387-33860-8, chapter 32)

Příspěvky ve sbornících mezinárodních konferencí:

Převorovský Z., Chlada M., Landa M., Blaháček M.: *Simulation and identification of AE sources in anisotropic structures.* (Internat. Conf. "Acoustic Emission '99", Brno, CZ, June 15-17, 1999, Proc. ed. by P.Mazal, Brno University of Technology, 1999, ISBN 80-216-1303-4, pp. 223-224)

Landa M., Chlada M., Převorovský Z., Novák V., Šittner P.: *Nondestructive evaluation of phase transformations in Cu based shape memory alloys by ultrasonic techniques.* (Internat. Conf. "Acoustic Emission'99", Brno, June 15-17, 1999, Proc. ed. by P.Mazal, ISBN 80-216-1303-4, pp.123-130)

Blaháček M., Převorovský Z., Krofta J., Chlada M.: *Neural network localization of noisy AE events in dispersive media.* (24th European Conference on Acoustic Emission Testing "EWGAE 2000", Senlis, France, 24-26 May, 2000, pp. 363-368)

Krofta J., Chlada M., Převorovský Z.: *Probabilistic and Neural Network Classification of Simulated AE.* (EUROMECH 419 Colloquium on Elastic Waves in NDT, Prague, 3-5 Oct. 2000, Book of Abstracts, ISBN 80-85918-57-9, p. 47).

Převorovský Z., Fischer J., Krofta J., Chlada M., Blaháček M.: *Fuzzy-Probabilistic Evaluation of AE During Steel Plate Punching*. (in: E.Govekar, ed.: Proc. of the COST P4 Conf. on Characterization of Manufacturing Processes "Synergetics and Data Processing Methods", Ljubljana, Slovenia, 25-26 May 2000, pp. 279-285)

Chlada M., Mrázová I., Převorovský Z.: *Acoustic emission and feature selection based on sensitivity analysis*. (4th Internat. Conf. on Prediction and Nonlinear Dynamics! NOSTRADAMUS, Zlín, CZ, Tomas Bata University of Zlin, September 25-26, 2001, Book of Abstracts p.11, Proc. CD ROM, ISBN 80-7318-030-8, pp. 527-534)

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 November 2001, Proc. ed. by P.Mazal, CNDT 2001, pp.317-327)

Chlada M., Převorovský Z.: *Threshold counting in wavelet domain*. (25th European Conference on AE Testing "EWGAE 2002", Proc. ISBN 80-214-2174-6, pp. I/107-116)

Převorovský Z., Chlada M., Krofta J., Varchon D., Vescovo P.: *Nonlinear ultrasonic characterization of human skin under tension*. (Ultrasonics International 2003, 30 June - 3 July, Granada, Spain, UI '03 Abstract Book, Paper No. UI 424, P191)

Chlada M., Převorovský Z., Vodička J.: *Correction of AE signal parameters by neural networks*. (34th Internat. Conf. on NDT "DEFEKTOSKOPIE 2004", Prague, 3-5 November 2004, Proc. ed. by P.Mazal, CNDT 2004, ISBN 80-214-2749-3, pp.339-346)

Chlada M., Blaháček M., Převorovský Z.: *Neural Network AE Source Location Based on Extracted Signal Features*. (3rd Internat. Conf. "NDT in Progress", Prague, 10-12 October 2005, Proc. ed. by P.Mazal, CNDT DGZfP 2005, ISBN 80-214-2996-8, pp.55-62)

Převorovský Z., Chlada M., Blaháček M., Pour T.: *Ultrasonic Signal Transfer in Thin Extended Aircraft Parts - Experiments and Modeling*. (3rd Internat. Conf. "NDT in Progress", Prague, 10-12 October 2005, Proc. ed. by P.Mazal, CNDT DGZfP 2005, ISBN 80-214-2996-8, pp.332-339)

Blaháček M., Převorovský Z., Chlada M.: *Elastic Wave Propagation in Complex Aircraft Structure*. (3rd Internat. Conf. "NDT in Progress", Prague, 10-12 October 2005, Proc. ed. by P.Mazal, CNDT DGZfP 2005, ISBN 80-214-2996-8, pp.47-54)

Chlada M., Blaháček M., Převorovský Z.: *AE Source Location and Emission Parameters Correction Using Neural Networks*. (35th Internat. Conf. on NDT "DEFEKTOSKOPIE 2005", Znojmo, 8-10 November 2005, Proc. ed. by P.Mazal, CNDT 2005, ISBN 80-214-3053-2, pp.81-88)

Blaháček M., Chlada M., Převorovský Z.: *AE Source Location in Complex Aircraft Structures*. (35th Internat. Conf. on NDT "DEFEKTOSKOPIE 2005", Znojmo, 8-10 November 2005, Proc. ed. by P.Mazal, CNDT 2005, ISBN 80-214-3053-2, pp.17-24)

Blaháček M., Chlada M., Převorovský Z.: *Acoustic Emission Source Location Based on Signal Features*. (27th European Conference on Acoustic Emission Testing, Cardiff, 20-22 September 2006, Proc. ed. by R. Pullin, K. M. Holford, S. L. Evans, J. M. Dulieu-Barton, Trans Tech Publications LTD, Switzerland 2006, ISBN 0-87849-420-0, pp.77-82)

Chlada M.: *Expert AE signal arrival detection*. (36th Internat. Conf. on NDT "DEFEKTOSKOPIE 2006", Tábor, 7-9 November 2007, Proc. pp.91-100)

Chlada M.: *Expert AE Signal Arrival Detection*. (IVth workshop NDT in progress, Prague,

2007, pp. 81-88)

Chlada M., Blaháček M., Převorovský Z.: *Architecture Optimization of Acoustic Emission Source Recognition Neural Networks*. (37th Internat. Conf. on NDT "DEFEKTOSKOPIE 2007", Prague, 7-9 November 2007, Proc. pp.297-304)

Chlada M., Převorovský Z.: *AE Source Recognition by Neural Networks with Optimized Signal Parameters*. (28th European Conference on Acoustic Emission Testing "EWGAE - Kraków 2008", Kraków, September 17-19, 2008, Proc. ed. by K. Ono, ISBN 978-83-7242-478-5, pp. 250-255)

Výzkumné zprávy:

Landa M., Chlada M., Novák V., Urbánek P., Převorovský Z.: *Akustoultrazvukové hodnocení strukturních změn během mechanického zatěžování materiálů s trvalou pamětí na bázi Cu, Al, Ni*. (Výzk zpráva č.Z-1264/99, ÚT AV ČR, Praha, 1999)

Chlada M., Mrázová I., Převorovský Z.: *Acoustic emission and feature selection based on sensitivity analysis*. (Technical Report No. 2001/4, MFF UK, Praha, 2001)

Blaháček M., Převorovský Z., Chlada M.: *Parametrizace signálů a rozpoznávání zdrojů akustické emise*. (Výzk zpráva č.Z-1386/06, ÚT AV ČR, Praha, 2006, 31 s.)

Chlada M., Převorovský Z.: *Citlivostní analýza umělých neuronových sítí a korekce emisních parametrů na polohu zdroje AE*. (Výzk zpráva č.Z-1396/06, ÚT AV ČR, Praha, 2006, 35 s.)