



# VYUŽITÍ NEURONOVÝCH SÍTÍ PŘI ZPRACOVÁNÍ SIGNÁLŮ AKUSTICKÉ EMISE

**Milan CHLADA**

chlada@it.cas.cz

*Oddělení nedestruktivního testování  
Ústav termomechaniky AVČR, v.v.i.  
Dolejškova 1402/5, 182 00 Praha 8*



# ÚVOD

## Požadavky praxe:

*Spolehlivost a bezpečnost materiálových konstrukcí.*

## Řešení:

*Aplikace vhodných nástrojů a metod.*

- nedestruktivní testování konstrukcí (NDT)
- kontinuální monitorování stavu

## Efektivní metody:


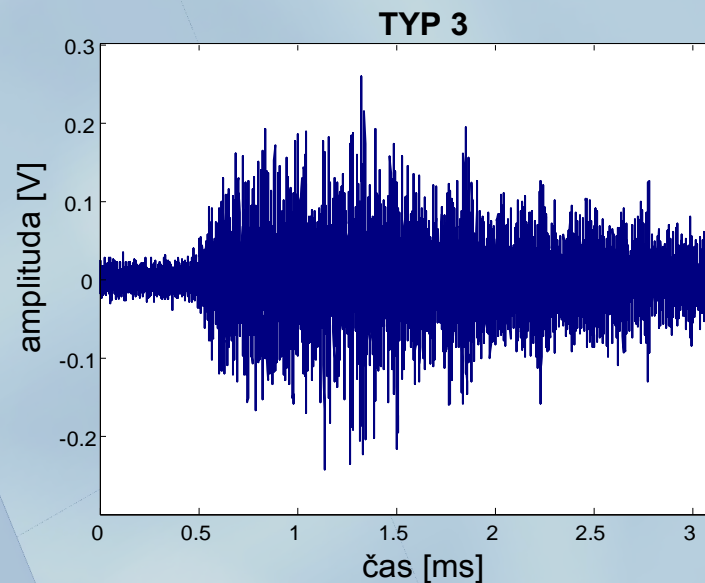

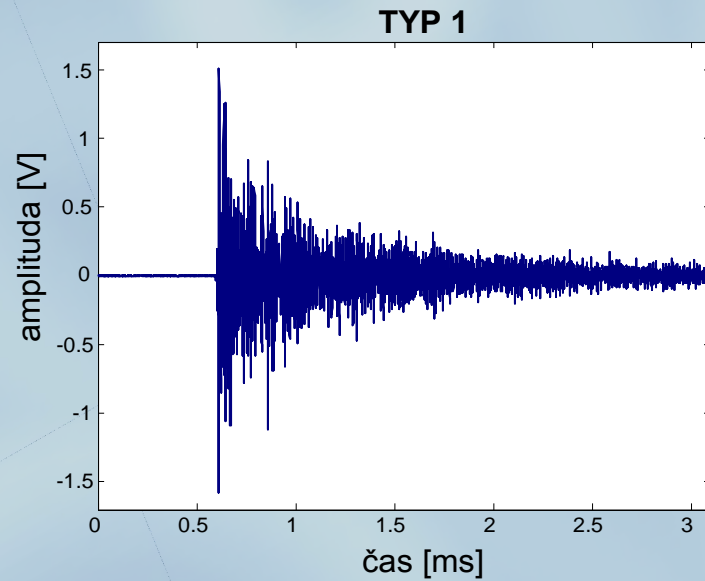
*Sledování akustické emise (AE).*

NDT metoda pro detekci a identifikaci rostoucích materiálových defektů.  
*(různé typy signálů detekovaných metodou AE přísluší k různým mechanismům poruch)*

## Vývoj a aplikace nových algoritmů zpracování signálů AE na bázi umělých neuronových sítí:

*Rozšíření možností a zvěrohodnění diagnostického rozhodování na základě lokalizace a klasifikace emisních zdrojů.*

# RŮZNÉ TYPY SIGNÁLŮ AE





# POČÍTANÉ SIGNÁLOVÉ PARAMETRY

- **Časová oblast:**

*(1) amplituda signálu, (2) amplituda vektoru  $\mathbf{g}$ , (3) doba nárůstu signálu, (4) doba nárůstu vektoru  $\mathbf{g}$ , (5) RMS signálu, (6) moment energie signálu, (7-10) 1.-4. centrální moment vektoru  $\mathbf{g}$  ve smyslu hustoty pravděpodobnosti.*

- **Parametry frekvenčního spektra:**

*(11-15) parametry výkonové spektrální hustoty  $\mathbf{f}(\omega)$ :*

$$P_X = 100 \cdot \frac{\int f(\omega) d\omega}{\int_G f(\omega) d\omega}, \quad X \in \{A, B, C, D, E\}$$

*kde  $\mathbf{G}$  je celkový frekvenční rozsah, pět zvolených pásem  $\mathbf{X}$  je vztaženo k Nyquistově frekvenci  $\omega_N$  následovně:*

*A:(0-0.05)\* $\omega_N$ ; B:(0.05-0.1)\* $\omega_N$ ; C:(0.1-0.15)\* $\omega_N$ ; D:(0.15-0.3)\* $\omega_N$ ; E:(0.3-0.5)\* $\omega_N$ .*

*(16-19) 1.-4. centrální moment  $\mathbf{f}(\omega)$  ve smyslu hustoty pravděpodobnosti*



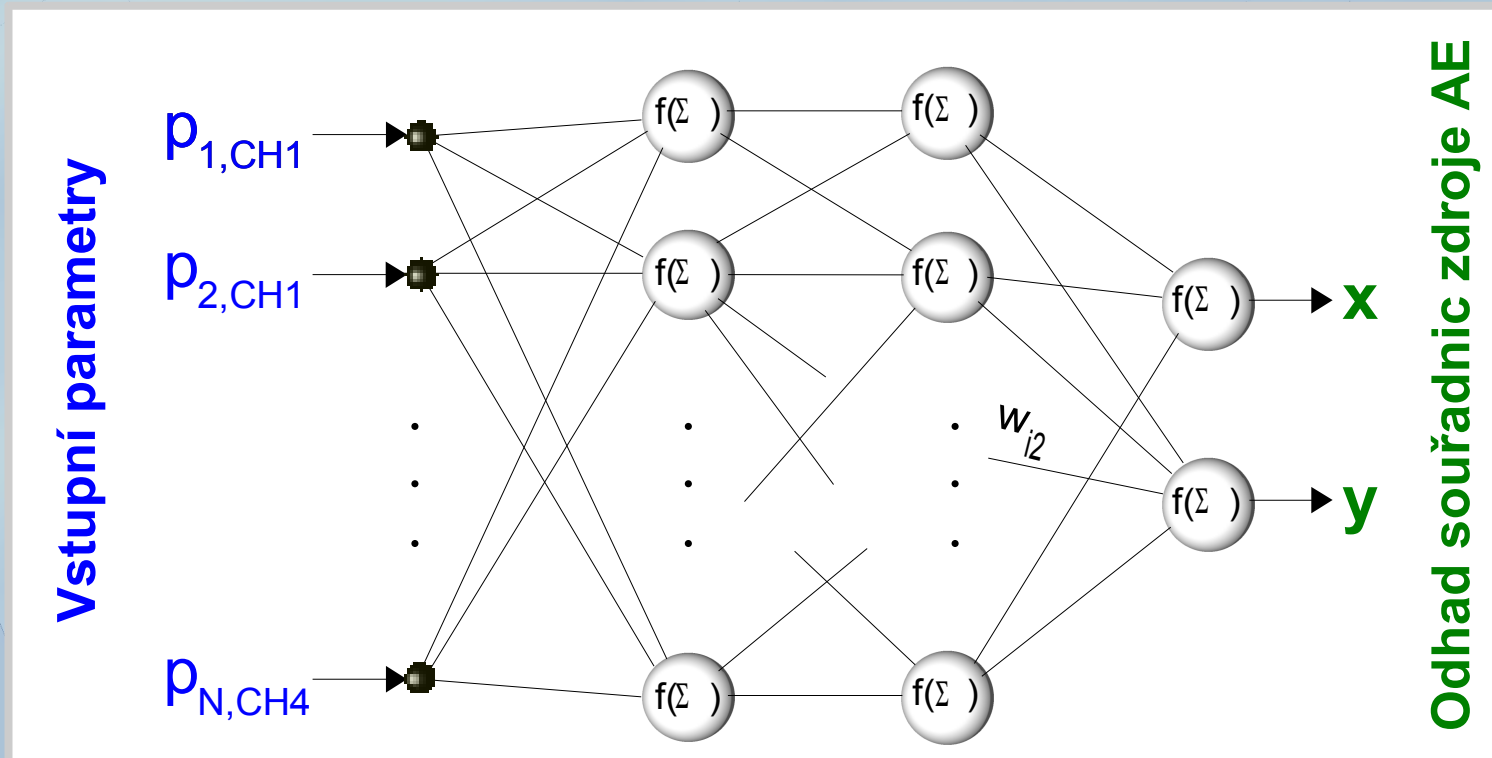
# CÍLE

## ***Návrh a aplikace nových přístupů k analýze signálů AE založených především na vrstevnatých ANN.***

- Optimalizace volby signálových parametrů
  - *definice nových emisních parametrů*
  - *faktorová analýza (lin. hypotéza a výpočet faktorových skóre)*
  - *mapování obecných závislostí pomocí speciálních BP-sítí*
  - *citlivostní analýza*
- Lokalizace zdrojů AE pomocí ANN
- Korekce emisních parametrů na polohu zdroje AE
- Rozpoznávání zdrojů AE (*modelových a reálných*)
- Zlepšování vlastností BP-sítí

# LOKALIZACE ZDROJŮ AE POMOCÍ ANN


- Aplikace neuronových sítí (ANN) - *osvědčená alternativa pro klasický triangulační algoritmus lokalizace zdrojů signálů AE.*
- Obtížné určování začátku signálu - *možné chybné výsledky obzvláště za přítomnosti vysokých hladin šumu.*
- Nová metoda lokalizace zdrojů AE - *jádrem ANN, na vstupech běžné signálové parametry (RMS, doba nárůstu, max. amplituda apod.)*





# LOKALIZACE ZDROJŮ AE POMOCÍ ANN

- Pen-testy na části nosníku letounu L-39





# LOKALIZACE ZDROJŮ AE POMOCÍ ANN

- Porovnání výsledků (podíly RMS versus časové difference)

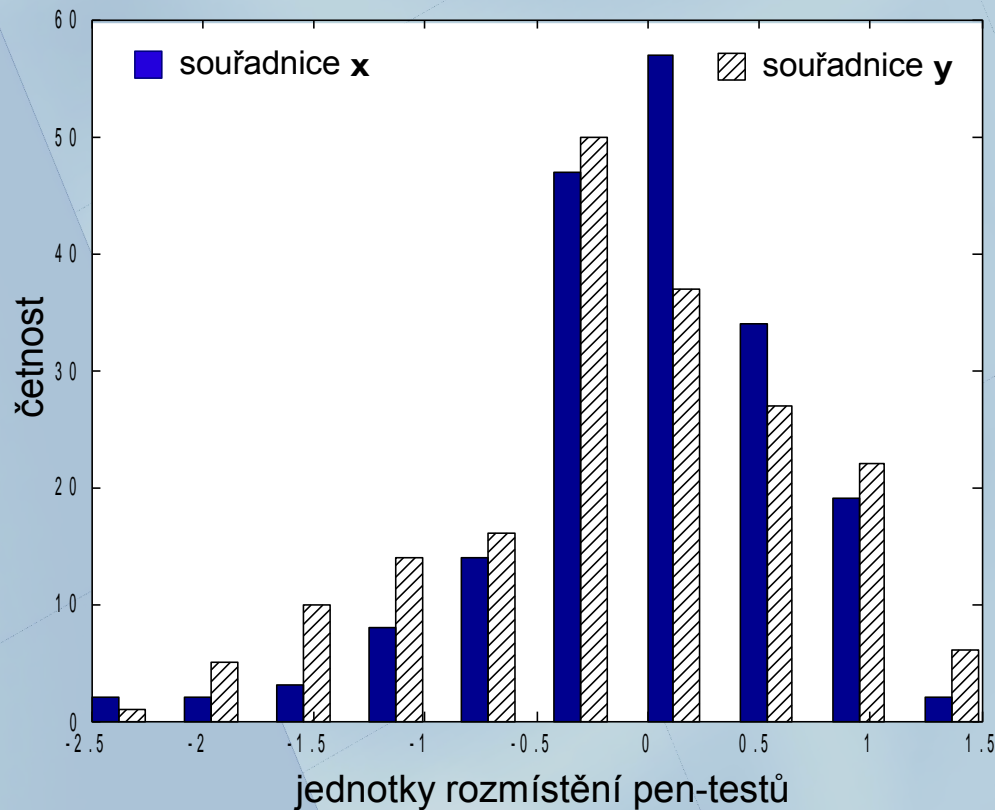
vstupy sítě:

$$\text{RMS}_{\text{CHi}} / \text{RMS}_{\text{CHj}}$$

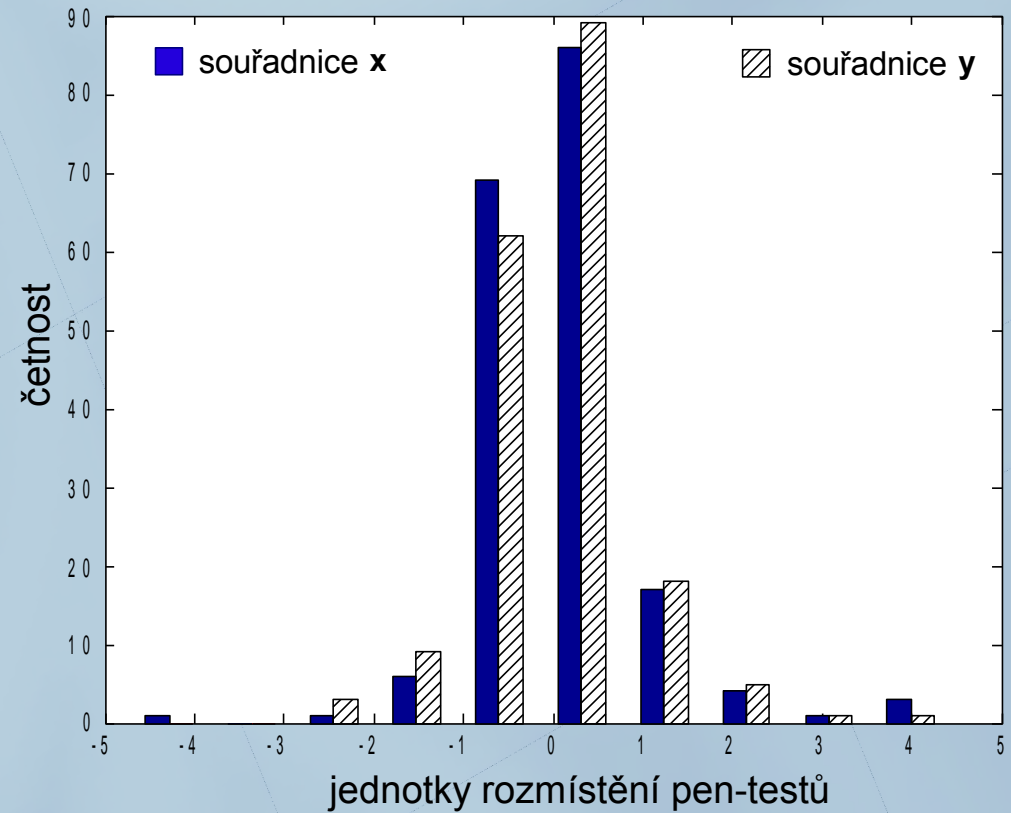
VS.

$$t_1 - t_2 ; t_1 - t_3 ; t_1 - t_4 ; t_2 - t_3$$

HISTOGRAM ČETNOSTÍ ODCHYLEK




HISTOGRAM ČETNOSTÍ ODCHYLEK



# LOKALIZACE ZDROJŮ AE POMOCÍ ČASOVÝCH PROFILŮ

- 2D schéma rozmístění senzorů na tenké desce



značení:


- $t_s$  - čas inicializace zdroje AE
- $t_i$  - čas příchodu signálu
- $T_i$  - čas šíření signálu od zdroje ke snímači  $S_i$
- $T$  - normalizační perioda
- $d_i$  - vzdálenost mezi zdrojem AE a snímačem
- $d$  - vzdálenost mezi dvěma vhodně zvolenými body
- $v$  - rychlost šíření elastické vlny

# LOKALIZACE ZDROJŮ AE POMOCÍ ČASOVÝCH PROFILŮ


- Časový profil je vektor s následovně definovanými složkami  $p_i$ :

$$p_i = \frac{\bar{T}_i}{\max_j \{|\bar{T}_j|\}} \quad , \quad \text{kde} \quad \bar{T}_i = T_i - \frac{1}{N} \sum_{j=1}^N T_j$$

ČASY PŘÍCHODŮ



ČASOVÝ PROFIL





# LOKALIZACE ZDROJŮ AE POMOCÍ ČASOVÝCH PROFILŮ

- Výpočet pomocí časů příchodů ( $t_s$  - čas inicializace zdroje AE):


$$\bar{T}_i = t_i - t_s - \frac{1}{N} \sum_{j=1}^N (t_j - t_s) = t_i - \frac{1}{N} \sum_{j=1}^N t_j \stackrel{\text{ozn.}}{=} \bar{t}_i \Rightarrow p_i = \frac{\bar{t}_i}{\max_j \{|\bar{t}_j|\}}$$

- **Nezávislost** časových profilů na **změně měřítka a materiálu**:

$$p_i = \frac{\frac{1}{v} \cdot \bar{d}_i}{\frac{1}{v} \cdot \max_j \{|\bar{d}_j|\}} = \frac{\bar{d}_i}{\max_j \{|\bar{d}_j|\}} = \frac{s \cdot \bar{d}_i}{\max_j \{|s \cdot \bar{d}_j|\}}, \text{ kde } \bar{d}_i = d_i - \frac{1}{N} \sum_{j=1}^N d_j$$

# LOKALIZACE ZDROJŮ AE POMOCÍ ČASOVÝCH PROFILŮ


- Zpětná projekce učících bodů do tréninkové oblasti:





# LOKALIZACE ZDROJŮ AE POMOCÍ ČASOVÝCH PROFILŮ


- Výsledky lokalizace reálných signálů:






# LOKALIZACE ZDROJŮ AE POMOCÍ ČASOVÝCH PROFILŮ

- Zpětná projekce učících bodů do redukované tréninkové oblasti:



# LOKALIZACE ZDROJŮ AE POMOCÍ ČASOVÝCH PROFILŮ

- Výsledky lokalizace reálných signálů - redukováná tréninková oblast:




# KOREKCE EMISNÍCH PARAMETRŮ NA POLOHU ZDROJE AE

- Cíl korekce:**

*přepočítání parametrů signálů z různých míst na jednu referenční polohu zdroje, která je v blízkosti vybraného snímače.*

s1,s2,s3,s4 - snímače



MOTIVACE:

*Velké zkreslení emisního signálu při šíření vln od zdroje ke snímačům - pro diagnostické rozhodování je zapotřebí získat srovnatelné informace.*

*Úplné řešení inverzní úlohy o emisním zdroji je v reálných podmínkách nemožné - omezení na inverzi signálových parametrů.*

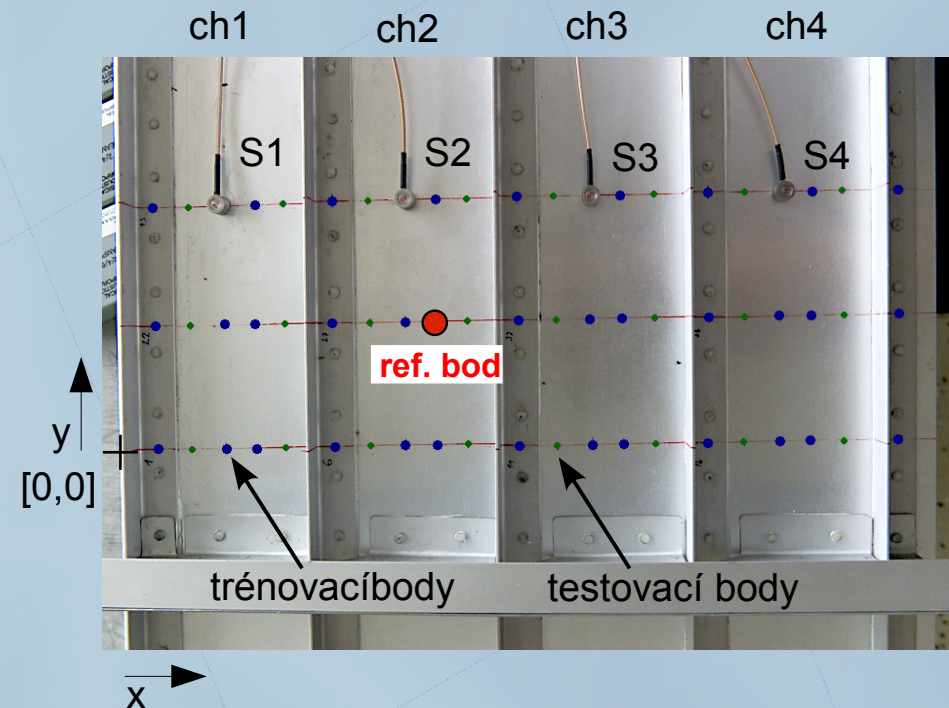
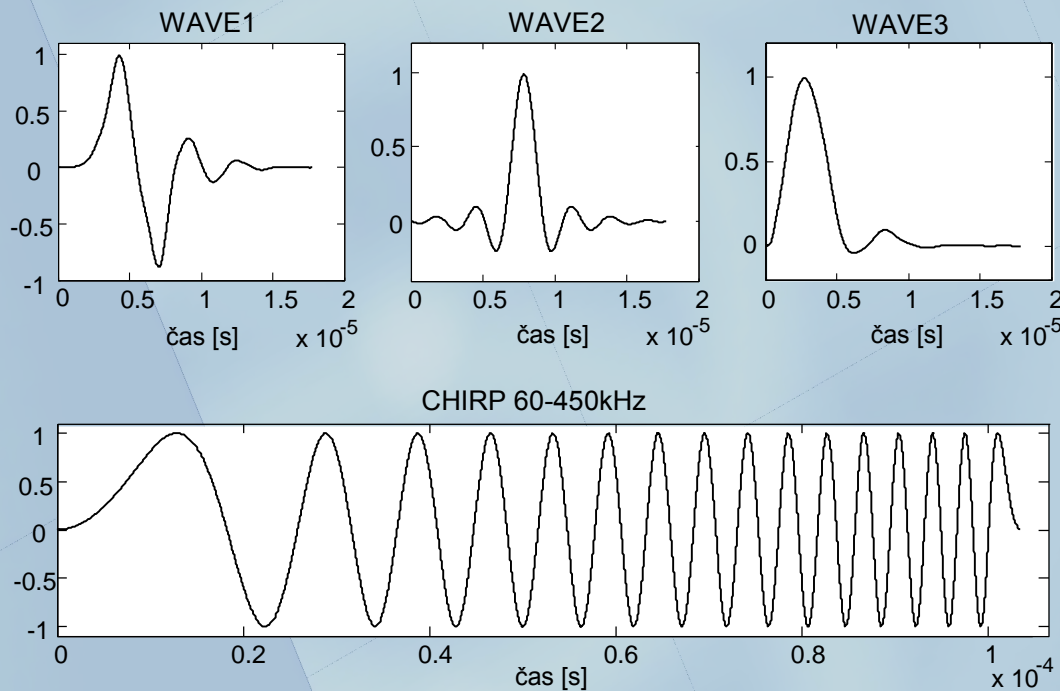


# KOREKCE EMISNÍCH PARAMETRŮ NA POLOHU ZDROJE AE

- Reálný experiment:**

*buzení let. konstrukce pomocí zdrojů s různými časovými průběhy a amplitudami*

*analytické řešení korekce není známo => aplikace umělých neuronových sítí  
(metodika předběžně ověřena numerickým modelem).*




# KOREKCE EMISNÍCH PARAMETRŮ NA POLOHU ZDROJE AE


- Potvrzení výsledků numerického modelu:
  - pro dostatečně přesnou korekci jednoho konkrétního parametru je nutné uvažovat i charakteristiky jiné
  - citlivostní analýza ukazuje, že znalost souřadnic zdrojů AE není potřeba uvažovat jako vstupy sítí
  - korekce parametrů se složitou přenosovou funkcí vyžaduje jemnější pokrytí trénovacích bodů

ZMĚNY PARAMETRŮ V ZÁVISLOSTI NA VZDÁLENOSTI OD ZDROJE  
(snímač 4, buzení vlnou WAVE1, amplituda 12V)

RMS<sup>2</sup> [dB]



$P_{(0.04-0.05)Nq}$





# ROZPOZNÁVÁNÍ ZDROJŮ AE

- **Primární selekce dat**

- *identifikace emisních zdrojů, které jsou spojeny s destruktivními jevy v testované součásti*
- *eliminace emisních projevů způsobených např. pohybem namáhaného vzorku v upínacích čelistech zatěžovacího zařízení, elektrickým rušením, nebo chybami AD převodníku*

→ věrohodnější závěry z měření emisní aktivity

- **Klasifikace mechanismů poruch**

**problémy:**

- *zkreslení na cestě ke snímači (odlišnost signálů i když pocházejí od stejného zdroje)*
- *okamžitým působení více mechanismů vzniku poruch (např. současný růst trhliny a tření jejích hran o sebe)*
- *získání spolehlivě identifikovaných dat pro účely návrhu klasifikátoru*


**řešení:**

- *navržena metoda rozpoznávání poměrného zastoupení modelových pulsů ve zdrojové funkci emisní události pouze z parametrů numericky generovaných signálů AE na základě umělých neuronových sítí (ANN)*



# ROZPOZNÁVÁNÍ MODELOVÝCH ZDROJŮ AE

- Tři typické zdrojové funkce emisních událostí byly modelovány pulsy **S1-S3** spolu s jejich lineárními kombinacemi



*váhy kombinací:*

[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]

# ROZPOZNÁVÁNÍ MODELOVÝCH ZDROJŮ AE

- **Zkušební vzorek** (*páka podvozku malého dopravního letounu*)



- **Měřicí aparatura**

*zdroje / snímače AE:* čtveřice piezoelektrických měničů zapojených přes multiplexer  
*buzení pulzéro:* generátor libovolných průběhů (arbitrary generator NI-5421)  
*záznam AE:* PAC  $\mu$ Disp (fr.vz. 10MHz, 16bitů, 15360 vzorků)



# ROZPOZNÁVÁNÍ MODELOVÝCH ZDROJŮ AE

## • Výběr tréninkových a testovacích dat


- **parametry signálů** z jednoho, či více snímačů, buzených vždy jedním vybraným vysílačem, do kterého přicházelo všech 12 nakombinovaných pulsů, zesílených na různé amplitudy:

**tréninková data:** 0.6V ; 3V ; 6V

**testovací data:** 2.4V ; 3.6V

**zúžení učicích dat** -> přesnost sítí při vybavování značně klesá  
(testovací data nelze jednoduše "interpolovat" na základě sousedních tréninkových)

**dobrá konvergence sítí** -> možné rozšíření tréninkové množiny  
(předpoklad plné automatizace experimentu)



Počty neuronů:

3 - 17 - 5 - 3

(vstupy - parametry signálů  
z jednoho snímače)

Učicí / testovací chyba (MSE):


0.0031 / 0.0033



# ROZPOZNÁVÁNÍ REÁLNÝCH ZDROJŮ AE

- Úkol klasifikátoru zdrojů AE:

*Rozpoznání signálů typů "A" a "B", pocházejících z příslušných dvou oblastí, kde jsou předpokládány různé zdrojové mechanismy.*



# ANALÝZA PARAMETRIZACE SIGNÁLŮ AE

## • Faktorová analýza

Metoda pro nalezení lineárních závislostí mezi parametry a výpočet nových, hypotetických proměnných (faktorů) vysvětlujících celkový rozptyl původních parametrů.

**FA** vychází z metody hlavních os (*PCA*), která provádí následující:

- transformuje proměnné do nového prostoru, jehož souřadnicový systém je ortogonální a nekorelovaný
- uspořádává souřadnicové osy tak, aby první z nich měla největší podíl na rozptylu dat
- eliminuje osy, které do celkového rozptylu přispívají jen zanedbatelnou měrou

**FA** představuje lineární transformaci dat (*ortogonální rotaci následovanou změnou měřítka*):

$$Z = A \cdot P$$

**Z** - původní data, **P** - nové hypotetické proměnné (faktory)

**A** - faktorové schéma (regresní koeficienty faktorů na původní proměnné)


**Výpočet faktorových skóre** (*hodnoty nových nekorelovaných signálových charakteristik*):

$$P = A' \cdot R^{-1} \cdot Z'$$

**R** - korelační matice standardizovaných dat **Z**

# FAKTOROVÁ ANALÝZA ZVOLENÝCH PARAMETRŮ

ROTOVANÉ FAKTOROVÉ SCHÉMA (absolutní hodnoty)



**Výsledky:**

*Počet extrahovaných faktorů:*

**6**

*Procento vysvětleného rozptylu dat:*

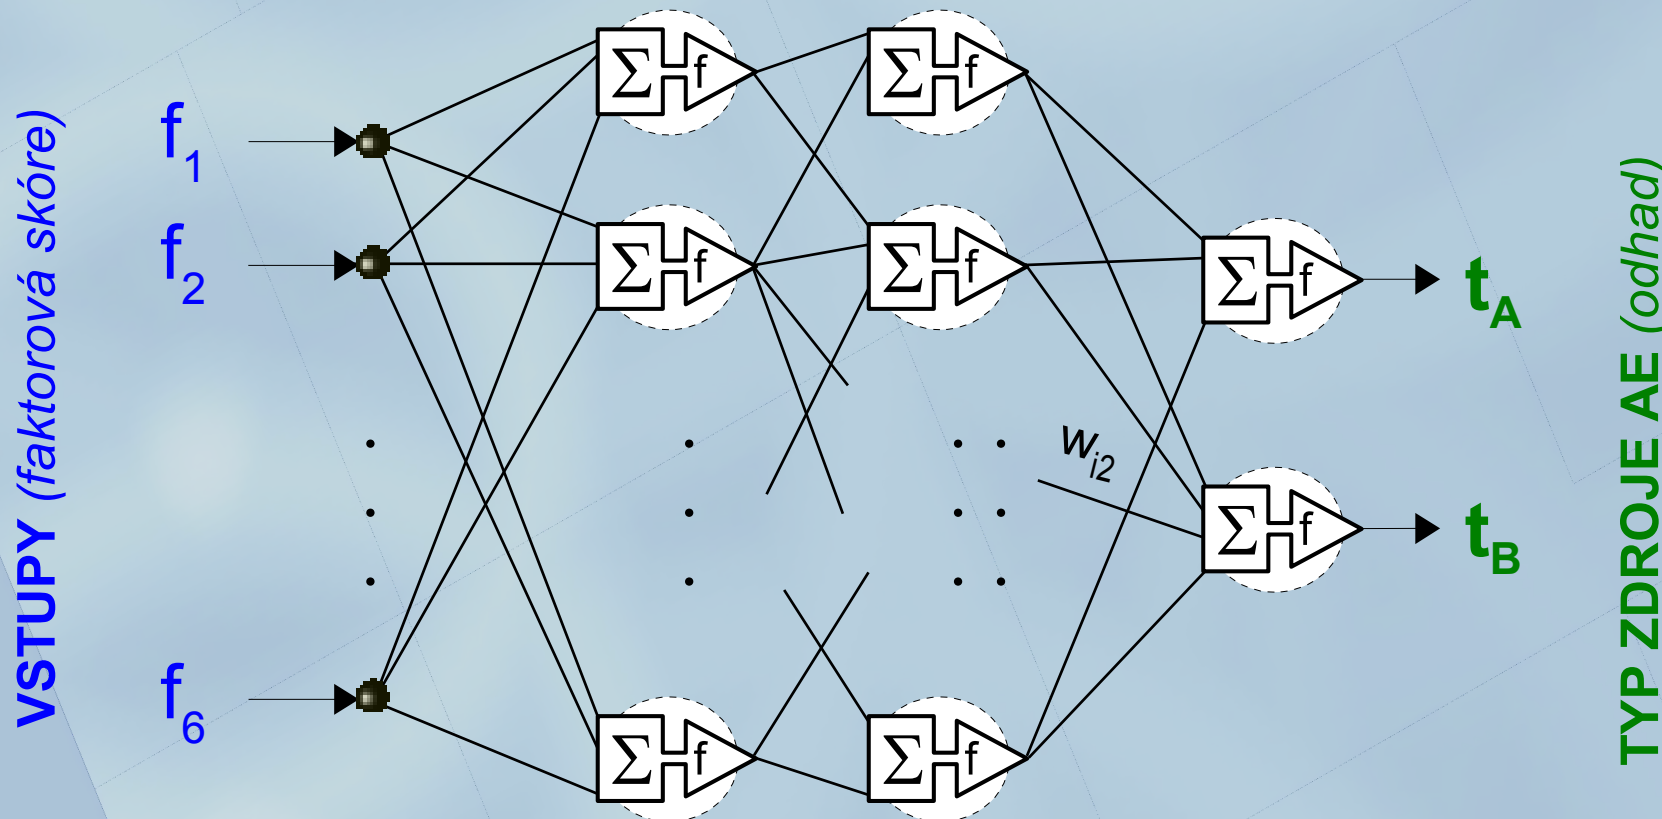
**96%**



# KLASIFIKÁTOR ZDROJŮ AE

- **Učení neuronové sítě**

- *architektura sítě (počty neuronů v každé vrstvě): 6-9-7-2*
- inicializační váhy nastaveny *statistickou optimalizací* startovních potenciálů neuronů
- váhy a prahy postupně korigovány *resilientní verzí algoritmu back-propagation s momentem* and *regularizací* (450 zpracovaných signálů použito pro učení)



# ANALÝZA PARAMETRIZACE SIGNÁLŮ AE

- Citlivostní analýza neuronových sítí (AFSSM)

**ALGORITMUS:**

1. Učení sítě pomocí všech vstupních parametrů
2. Výpočet citlivostních koeficientů:

$$s_{j,i} = \frac{1}{P} \sum_{p=1}^P \left| \frac{\partial y_{p,j}}{\partial x_{p,i}} \right|$$

$y_j$  - výstupy sítě,

$x_i$  - vstupy sítě,

$p$  - index předložených vzorů.

3. Eliminace vstupů s malými hodnotami koeficientů  $s_{j,i}$ .

*Vysoké hodnoty citlivostních koeficientů indikují "významný" vstupní parametr naučené BP-sítě.*



# KLASIFIKÁTOR ZDROJŮ AE - VÝSLEDKY

- Chyby sítě po přibl. 100 učicích cyklech:

$$MSE_{\text{TRAIN}} = 0.000187 \quad ; \quad MSE_{\text{TEST}} = 0.0034$$

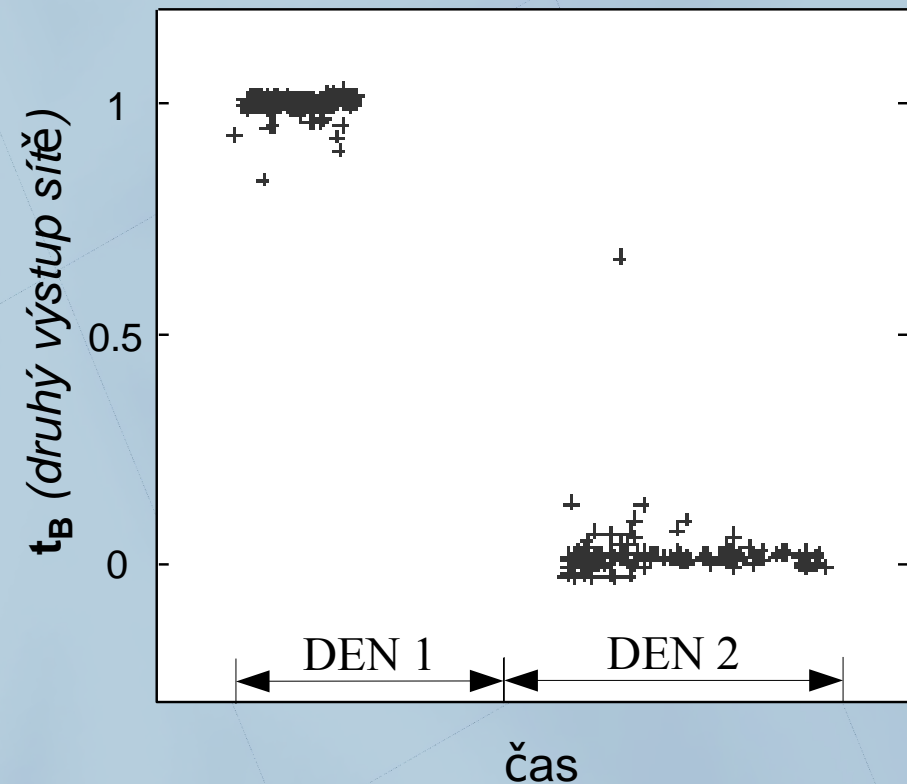
- Citlivostní analýza:

druhý faktor je nejvýznamnější vstup (saturován parametry nižších spektr. pásem)

CITLIVOSTNÍ KOEFICIENTY

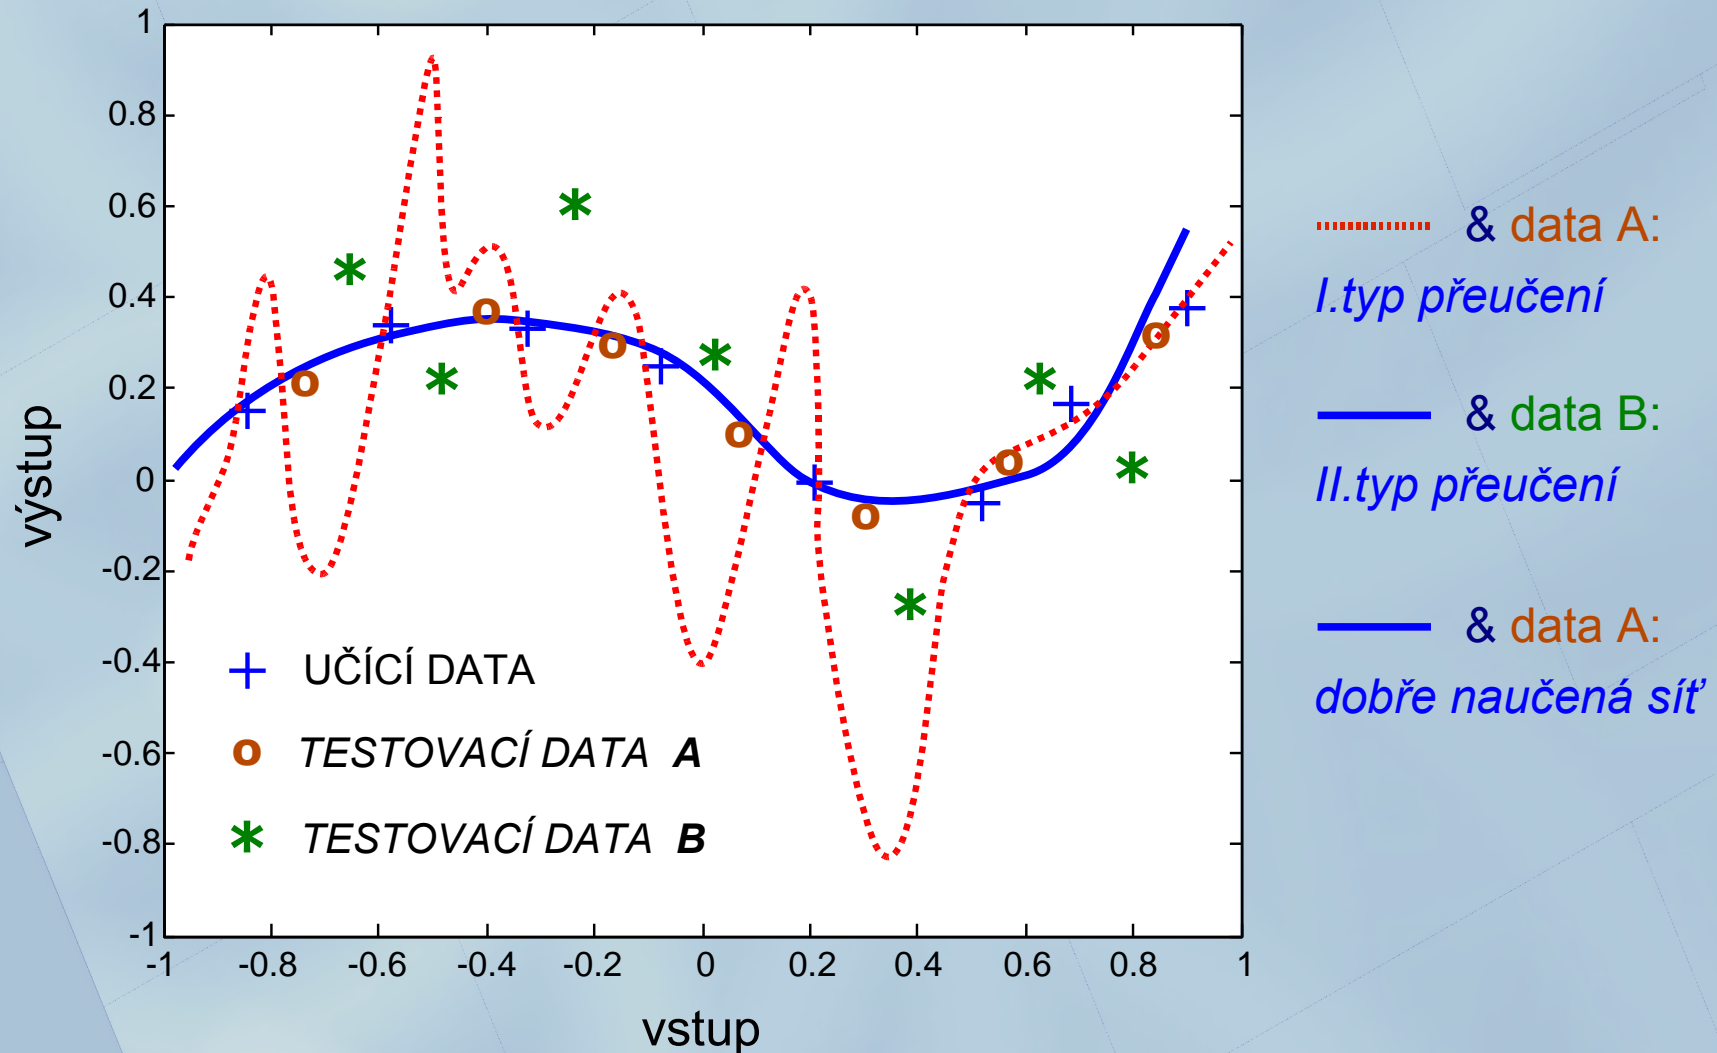
vstupy (faktory)	výstupy	
	1	2
1	0.02	0.01
2	<b>0.22</b>	<b>0.22</b>
3	0.14	0.11
4	0.01	0.01
5	0.03	0.02
6	0.00	0.01

KLASIFIKACE SIGNÁLŮ



# PROBLÉM PŘEUČENÍ

**Přeučenou** síť lze charakterizovat (*def.*) jako takovou, která sice vykazuje velmi malé výstupní odchylky v případě tréninkových dat, ale pro neznámé vstupy naopak selhává.





# PROBLÉM PŘEUCENÍ

- Příčiny (I.typ):

*Nárůst velikostí vah v průběhu učení. Na každou jejich adaptaci podle 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.*

- Řešení:

- > **REGULARIZACE**

*Postačuje i triviální minimalizace sumy kvadrátů všech vah. Účelová funkce je tedy za tímto účelem modifikována sumou přes všechny váhy sítě:*

$$msw = \frac{1}{N_w} \sum_{j=1}^{N_w} w_j^2, \text{ kde } N_w \text{ je celkový počet vah sítě}$$

*Do chybové funkce se suma začleňuje následujícím způsobem:*

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

- > **MINIMALIZACE ARCHITEKTURY**

- > **VÁŽENÝ GRADIENT**

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

- > **OPTIMALIZACE STARTOVNÍCH VAH**

# OPTIMALIZACE VOLBY STARTOVNÍCH VAH

- Zajištění vysokých hodnot gradientu chybové funkce:  
Výchozí potenciály neuronů v mezích největšího spádu sigmoidy lze zajistit volbou vah, pro každou vrstvu  $k$  zvlášť jako vzájemně nezávislé, stejně rozdělené náhodné veličiny s rovnoměrným rozdělením na intervalu  $\langle -\theta_k, \theta_k \rangle$  :

$$\theta_k = \sqrt{\frac{3}{1 + \sum_{i=1}^{M_{k-1}} E(y^{(k-1)}(i))^2}} \quad , \text{ tj. pro první skrytou vrstvu } \theta_1 = \sqrt{\frac{3}{M_0 + 1}}$$

Pro další vrstvy výhodný statistický odhad na základě konkrétních učicích dat:

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



# MAPOVÁNÍ OBECNÝCH ZÁVISLOSTÍ POMOCÍ ANN

- **Metoda využívající citlivostní analýzu  $N$  speciálních BP-sítí:**  
*( $N-1$ ) vstupů, 1 výstup, speciální tréninkové množiny:*

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

- **Učení a výpočet citlivostních koeficientů  $s_{i,j}$ :**


$$s_{j,i} = \frac{1}{P} \sum_{p=1}^P \left| \frac{\partial x_p(j)}{\partial x_p(i)} \right|$$

- **Analýza citlivostních koeficientů:**  
*Vysoké hodnoty indikují "významnou závislost" mezi příslušnými parametry.*

# MAPOVÁNÍ OBECNÝCH ZÁVISLOSTÍ POMOCÍ ANN

- Demonstrace metody na modelových datech  
*vygenerováno 10 000 šestirozměrných testovacích dat:*

$$x_1, x_3, x_4, x_5 \sim U(-1,1), \quad x_2 = (x_4)^3, \quad x_6 = (x_1)^2 + \sin(5(x_3)^2)$$



Zobrazení  
modelové  
závislosti  
v 3D řezu  
 $x_1 - x_3 - x_6$



# MAPOVÁNÍ OBECNÝCH ZÁVISLOSTÍ POMOCÍ ANN

- Porovnání faktorové analýzy a ANN-metody

$$x_1, x_3, x_4, x_5 \sim U(-1,1), \quad x_2 = (x_4)^3, \quad x_6 = (x_1)^2 + \sin(5(x_3)^2)$$

ROTOVANÁ FAKTOROVÁ MATICE (absolutní hodnoty)

parametry	1	2	3	4	5
$x_1$	0.00	1.00	0.01	0.00	0.01
$x_2$	0.98	0.00	0.01	0.00	0.01
$x_3$	0.01	0.01	0.00	0.00	1.00
$x_4$	0.98	0.00	0.00	0.00	0.01
$x_5$	0.01	0.00	0.00	1.00	0.00
$x_6$	0.00	0.01	1.00	0.00	0.00

faktory

	$x_1$	$x_2$	$x_3$	$x_4$	$x_5$	$x_6$
$x_1$	-	0.01	0.02	0.01	0.03	0.42
$x_2$	0.06	-	0.05	2.43	0.07	0.02
$x_3$	0.04	0.01	-	0.01	0.03	0.52
$x_4$	0.04	0.83	0.05	-	0.05	0.02
$x_5$	0.04	0.01	0.04	0.01	-	0.01
$x_6$	0.05	0.01	0.05	0.02	0.07	-

parametry na vstupu

číslo sítě

# SHRNUTÍ

## *Nové přístupy k analýze signálů AE založené především na vrstevnatých ANN:*

- Lokalizace zdrojů AE pomocí ANN
- Korekce emisních parametrů na polohu zdroje AE
- Rozpoznávání zdrojů AE
- Problém přeučení
- Optimalizace volby startovních vah
- Mapování obecných závislostí pomocí speciálních BP-sítí