



MATEMATICKÝ MODEL BIOLOGICKÝCH NEURONOVÝCH SÍTÍ V TECHNICKÉ PRAXI

Milan CHLADA

chlada@it.cas.cz

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





MATEMATICKÝ MODEL BIOLOGICKÝCH NEURONOVÝCH SÍTÍ V TECHNICKÉ PRAXI

- Matematické modelování
- Umělé neuronové sítě (ANN)
- Příklady využití ANN v praxi




MATEMATICKÉ MODELOVÁNÍ



MATEMATICKÉ MODELOVÁNÍ

popis reálného světa řečí čísel

zavedení čísel



sčítání a násobení




$$5 + 5 = 10$$





$$5 + 5 + 5 = 3 \times 5 = 15$$

rovnoměrný pohyb




kmitavý pohyb





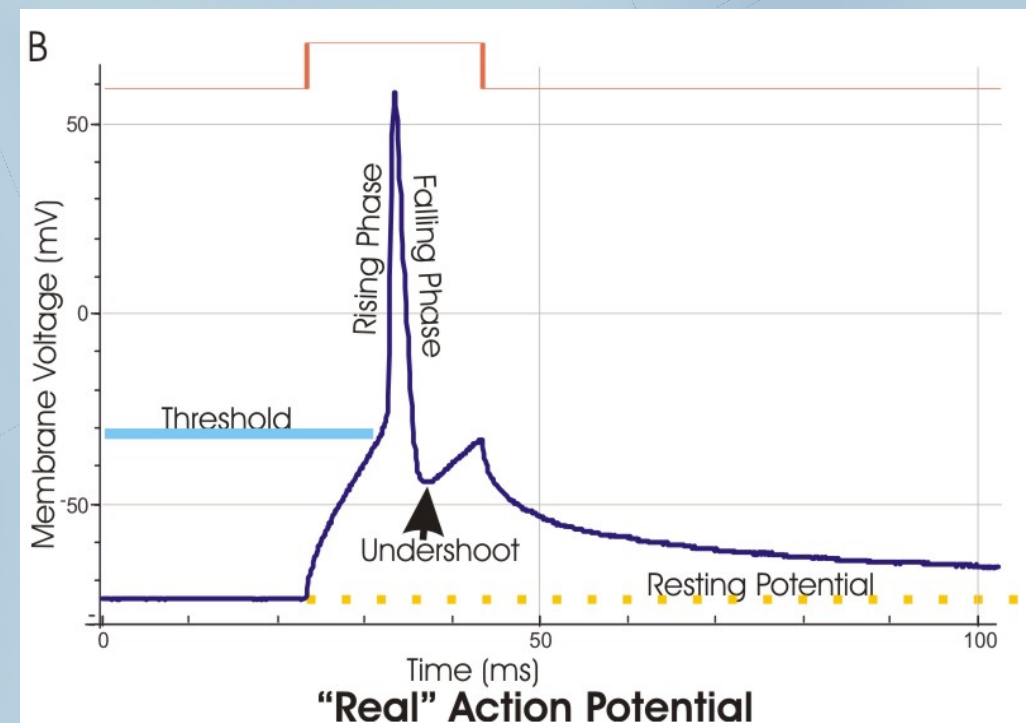

BIOLOGICKÁ NERVOVÁ SOUSTAVA *(NEURONOVÁ SÍŤ)*

BIOLOGICKÝ NEURON

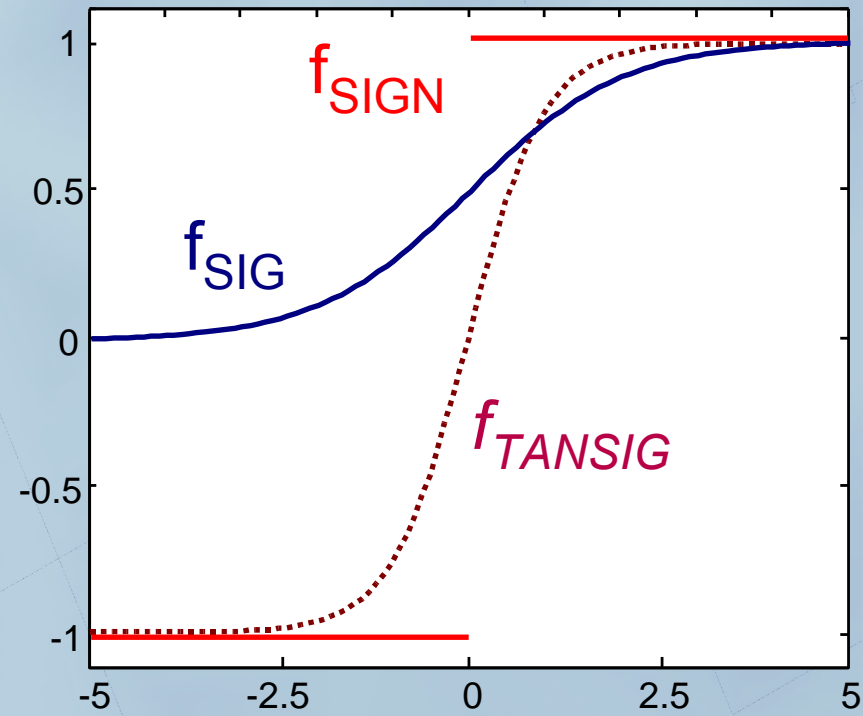
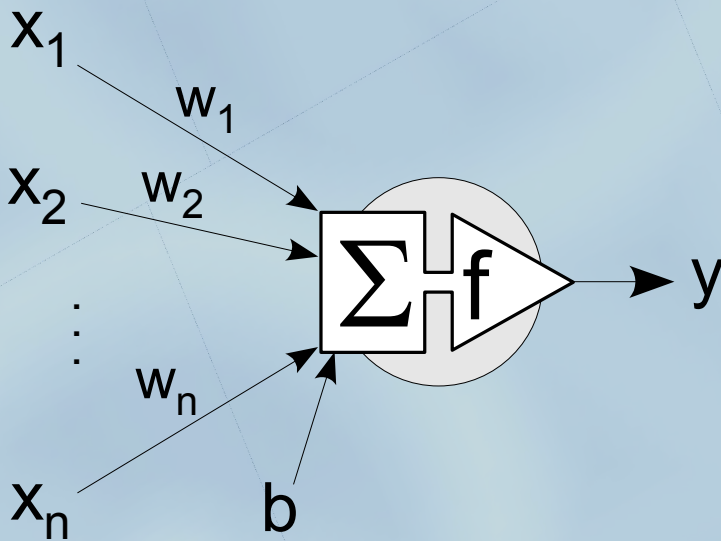


AKTIVITA BIOLOGICKÉHO NEURONU

reakce na přichodzí elektrický vzruch




MATEMATICKÝ MODEL NEURONU



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

MATEMATICKÝ MODEL NEURONU


demonstrace funkce jednoduchého perceptronu



$$y = \text{sign}(x_1 - 2x_2 + 50)$$


dělicí přímka:

$$x_1 - 2x_2 + 50 = 0$$



MATEMATICKÝ MODEL NEURONU


demonstrace funkce jednoduchého neuronu



$$y = \text{sign}(x_1 - 2x_2 + 50)$$

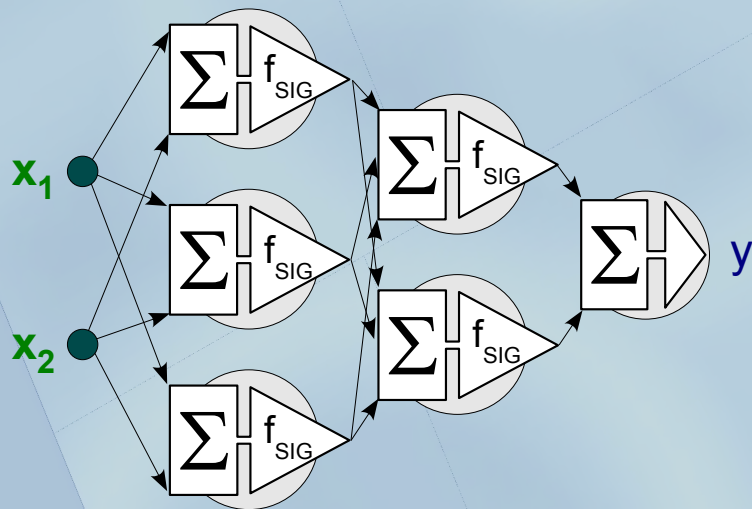
dělicí přímka:

$$x_1 - 2x_2 + 50 = 0$$



JEDNODUCHÁ NEURONOVÁ SÍŤ

architektura 2-3-2-1:




váhy:

$$W1 = \begin{bmatrix} 1 & 10 \\ 1 & -2 \\ -2 & 1 \end{bmatrix};$$

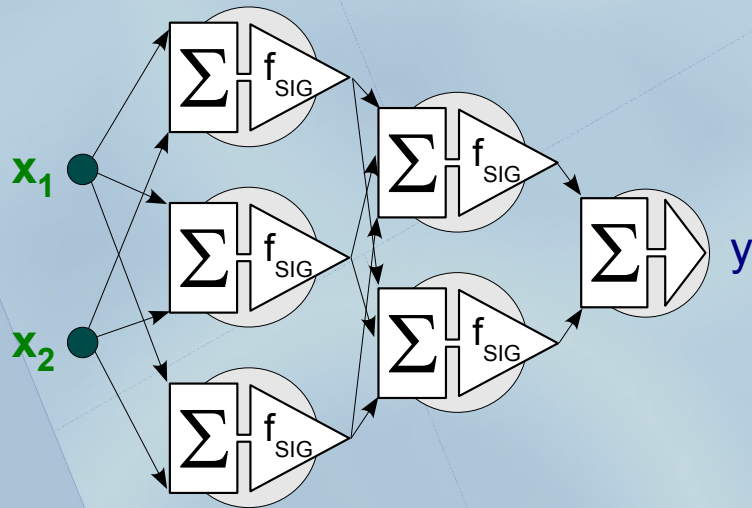
$$W2 = \begin{bmatrix} 0.2 & 0.5 & -0.5 \\ 0.1 & -0.7 & -0.1 \end{bmatrix};$$

$$W3 = [0.3 \ 0.7];$$



JEDNODUCHÁ NEURONOVÁ SÍŤ

architektura 2-3-2-1:




váhy:

$$W1 = \begin{bmatrix} 2 & 1 \\ 0.1 & -1 \\ -0.2 & 1.1 \end{bmatrix};$$

$$W2 = \begin{bmatrix} 0.7 & 0.25 & -0.5 \\ 0.1 & 0.9 & -0.1 \end{bmatrix};$$


$$W3 = [0.3 \ 0.1];$$



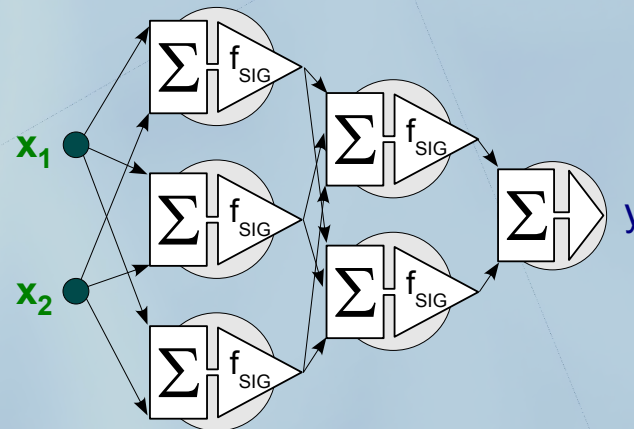
UČENÍ

nastavování vah a prahů

Jednoduchý perceptron: *perceptronové učení*



Vrstevnatá síť: *backpropagation (zpětné šíření)*



TECHNICKÁ PRAXE

Požadavky:

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


TYP 1




TYP 2



TYP 3



TYP 4



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 ω_N následovně:

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

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

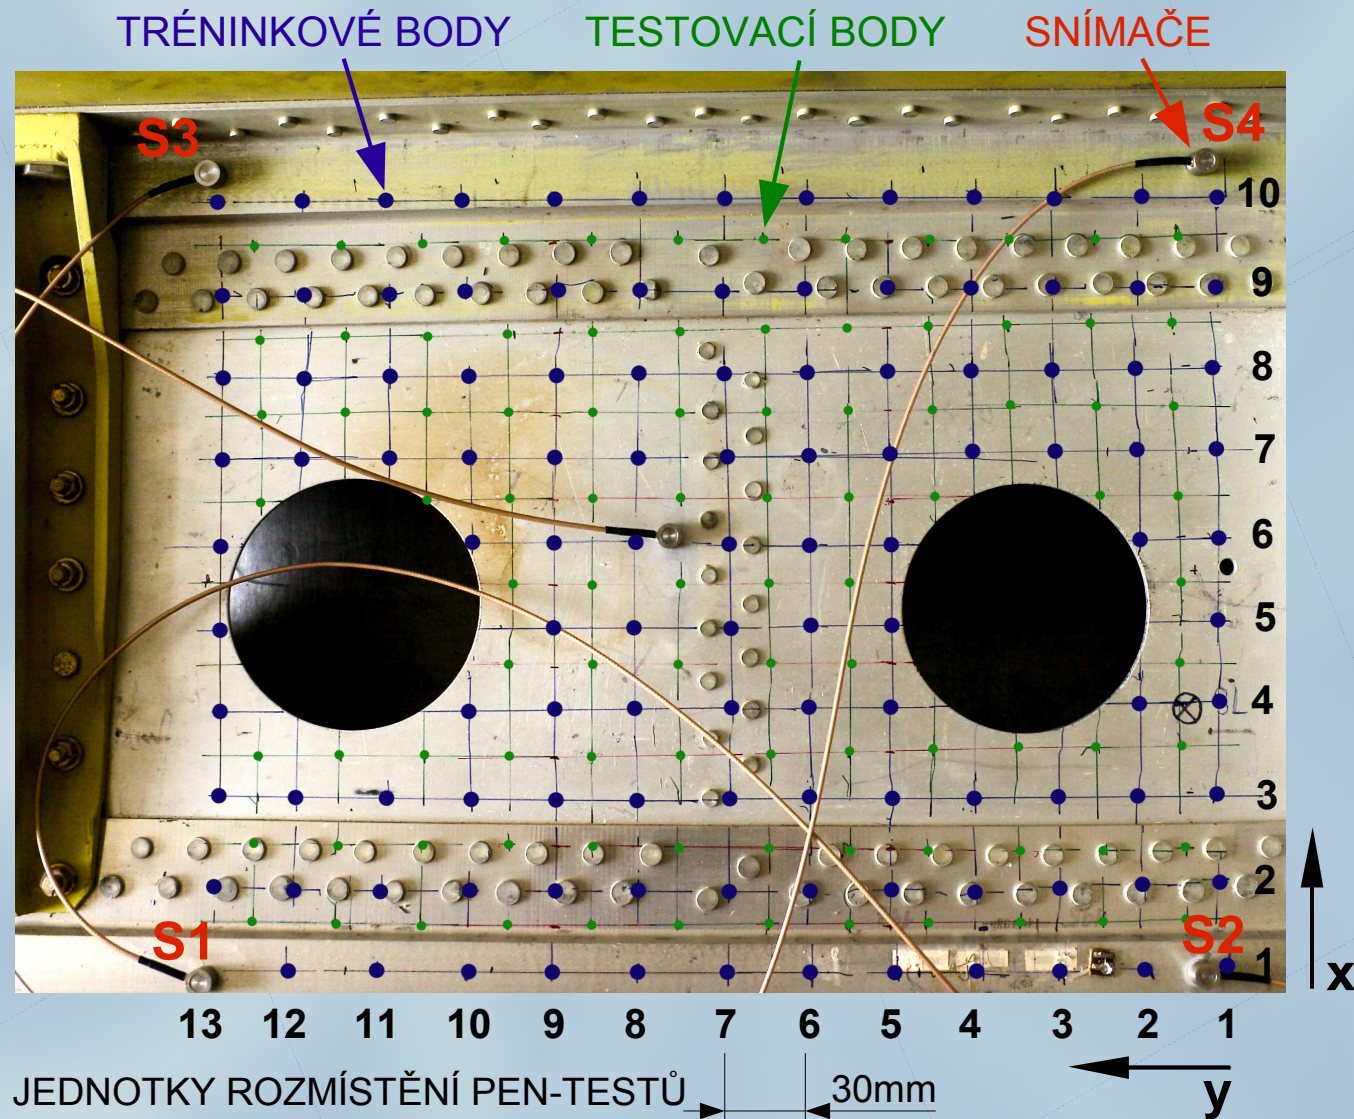
LOKALIZACE ZDROJŮ AE POMOCÍ ANN

- 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.)*



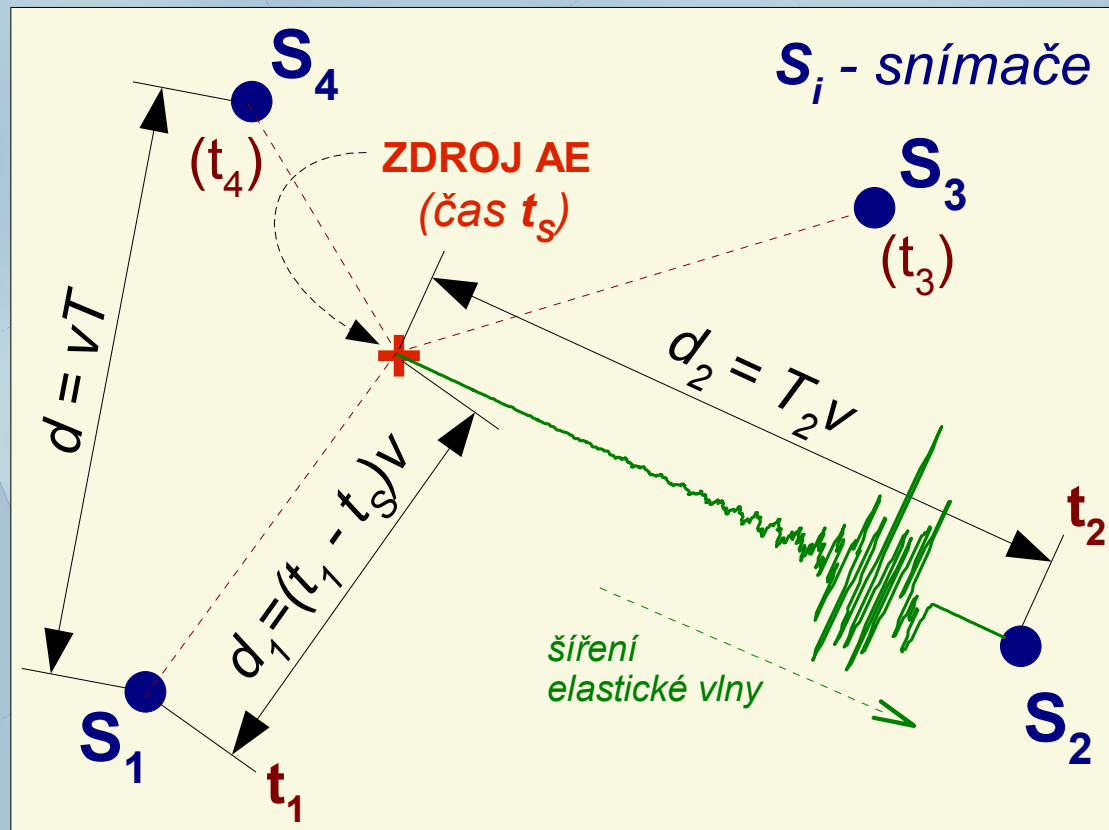
LOKALIZACE ZDROJŮ AE POMOCÍ ANN

- Pen-testy na části nosníku letounu L-39



LOKALIZACE ZDROJŮ AE POMOCÍ 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

ANN LOKALIZACE - ZATĚŽOVACÍ SÍLA <20 20<70 >70



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:

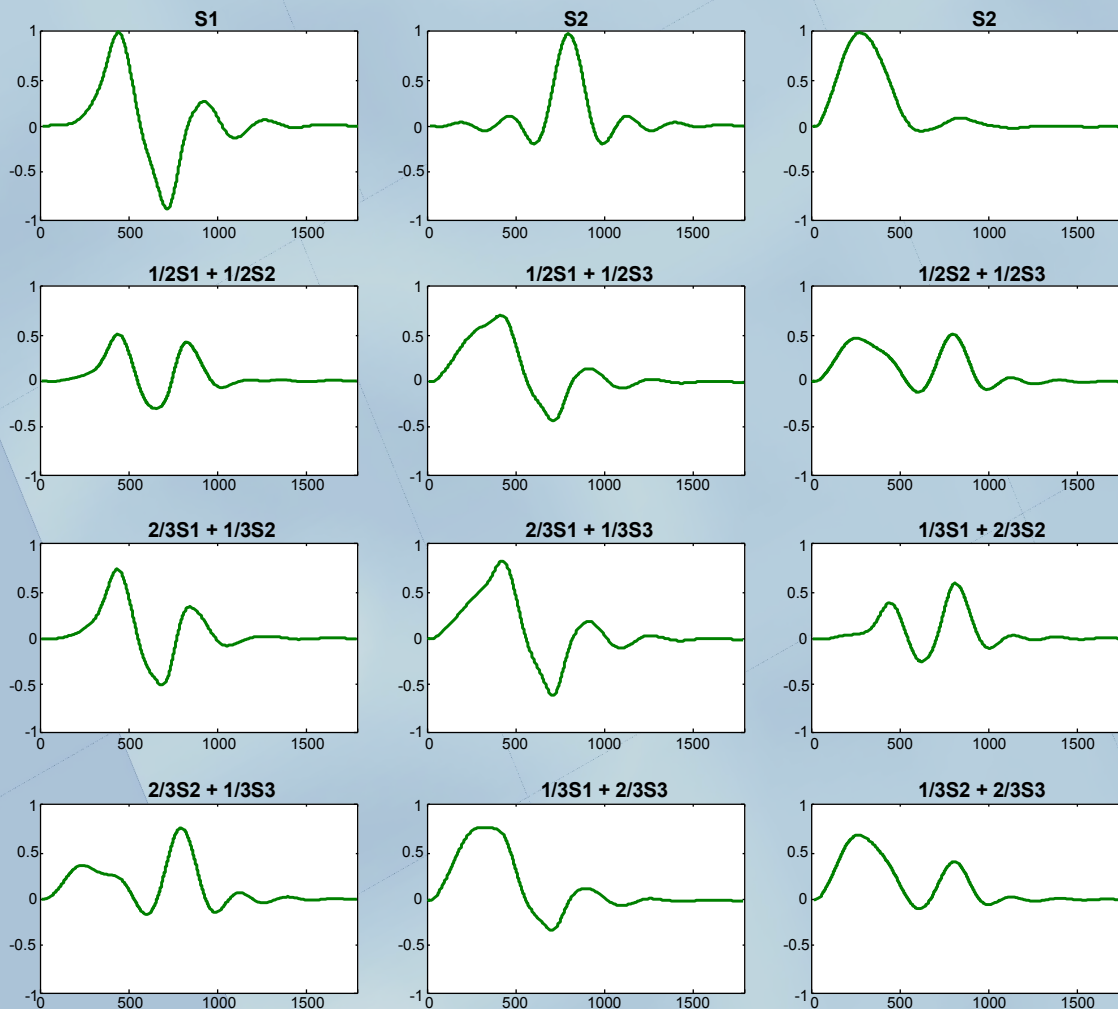
- *zkreslení na cestě ke snímači (odlišnost signálů i když pocházejí od stejného zdroje)*
- *okamžitým působení více mechanismů vzniku poruch (např. současný růst trhliny a tření jejích hran o sebe)*
- *získání spolehlivě identifikovaných dat pro účely návrhu klasifikátoru*

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 pulzérů: generátor libovolných průběhů (arbitrary generator NI-5421)
záznam AE: PAC μ 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.



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)





SHRNUTÍ

- Matematické modelování
- Umělé neuronové sítě (ANN)
- Příklady využití ANN v praxi

Děkuji za pozornost...