

# Identifikace jevů akustické emise pomocí Konvoluční Neuronové Sítě

Petr Kolář, Geofyzikální Ústav AV ČR

Matěj Petružálek, Geologický Ústav AV ČR

# Geofyzikální ústav AV ČR



*Praha - Spořilov*

*<http://www.ig.cas.cz>*



# Geofyzikální ústav AV ČR

**Struktura (odpovídá sledovaným geof. polím):**

- **Termika** (*tepelný tok, termální energie ...*)
- **Geoelektrika + Geomagnetika** (*variace, vodivost, paleomagnetismus ...*)
- **Gravimetrie** (*prospekce, kaverny, pyramidy, vojenství, družice...*)
- **Seismika (Západní Čechy)** (*rychlé mechanické změny*)
- **Tektonika a geodynamika** (*pomalé mechanické změny*)

*moto:*

„Co mám v kapse?“

*J.J.R. Tolkien: Hobit aneb cesta tam a zase zpátky.*

“What have I got in my pocket?”

*J.J.R. Tolkien: The Hobbit or there and back again*

# Zpracovávaná data



- **Akustická emise** (širší x užší vymezení)
- zatěžování horninových vzorků (*GU*) za účelem studia jejich mech. vlastností [0.1 – 1.0 MHz]
- ~ *Laboratorní zemětřesení*
- (oximoron ??)
- => lze aplikovat metodiku vyvinutou na zemětřesení (měřítková podobnost přes několik řádů !!!) (*GFU*)




# experiment

- schema

- provedení



data

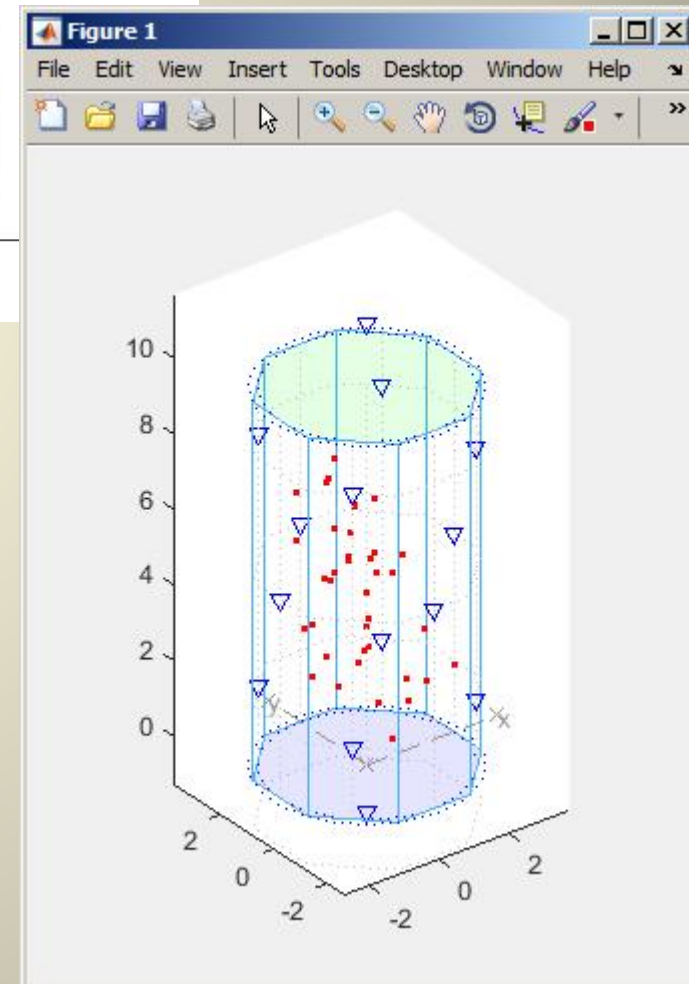


14-ti kanálový trigrovaný záznam  
Vzorkování 10 MHz  
délka 1024 vzorků (cca 0.1 ms)

**Relativně jednoduchá  
a homogenní data  
vhodná pro testy**

- Dobré pokrytí snímači
- Znalost řady parametrů
- Jeden typ jevů ...

Primární zpracování  
(lokace)  
 $v = \text{cca } 5 \text{ km/s}$







TCC 16

© Humusoft



cnn **AlexNet**



Indian elephant



African elephant

# Zpracování seismogramu s CNN

## 3 (triviální) otázky

1. Co vložit ?

2. Architektura CNN ?

3. Jaký výstup (co hledat) ?



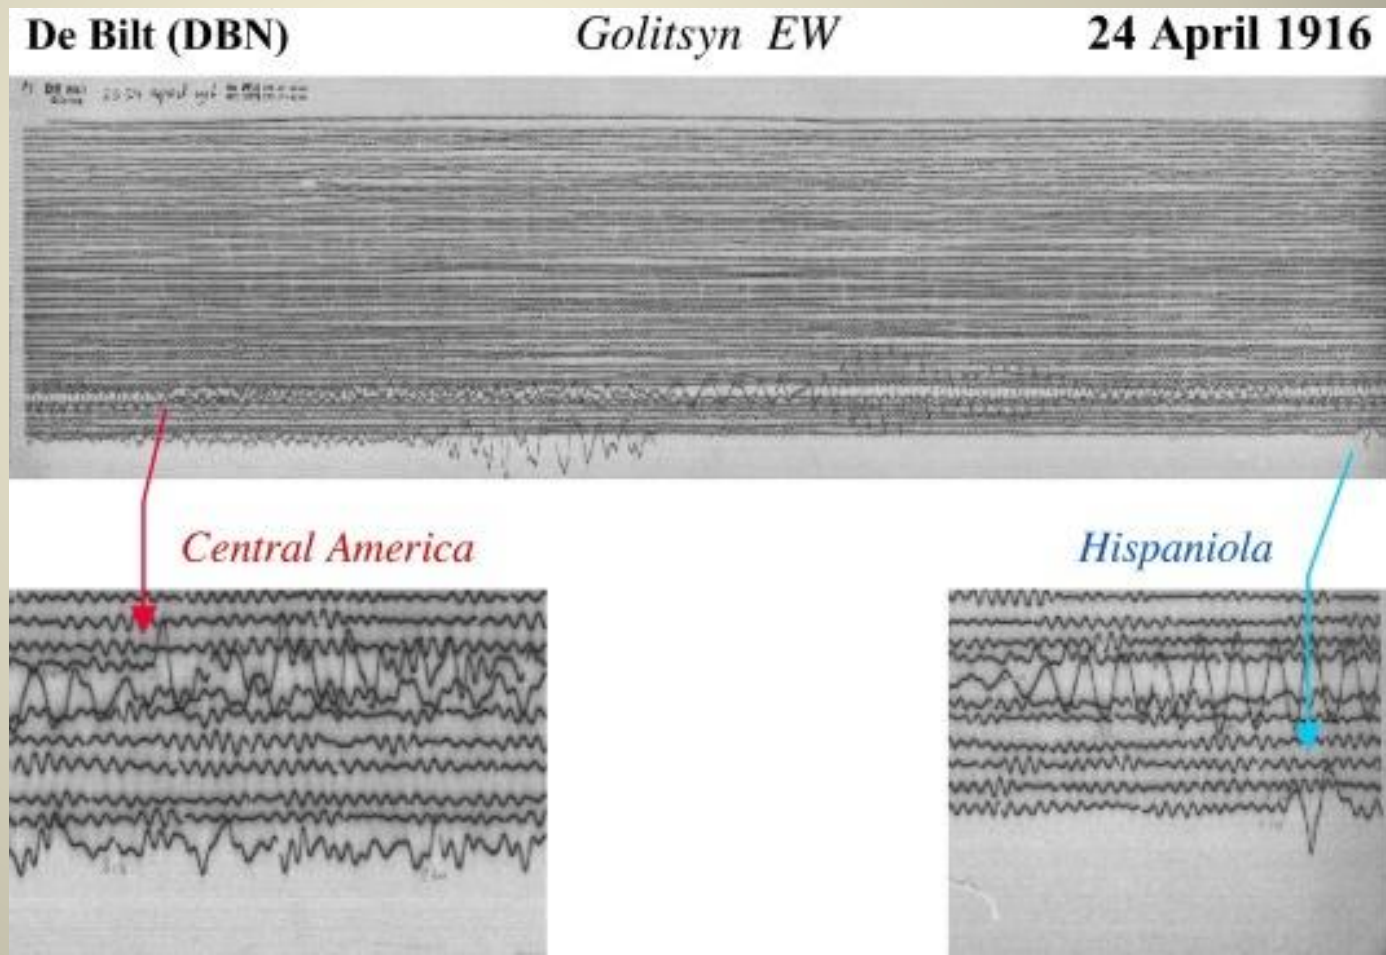
# 1. Co vložit ?

# 1. VSTUP (neúspěšné) pokusy

Seismogram: časová řada, nestacionární jev

(jako např. tlumený oscilátor)

=> **PROBLEMATICKÉ**



staro(nová) inspirace:  
seismogram jako

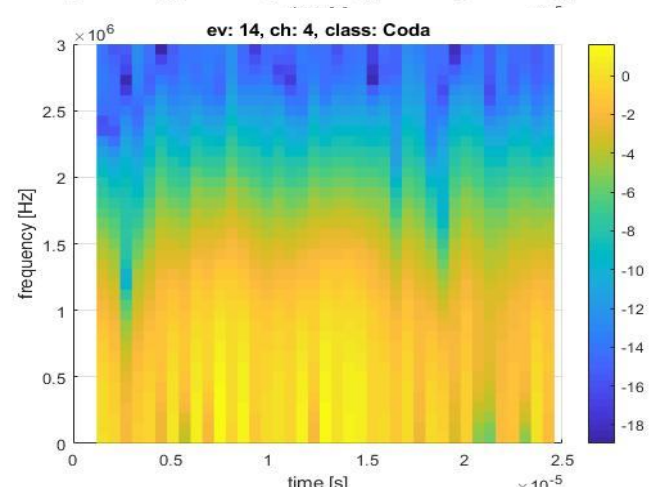

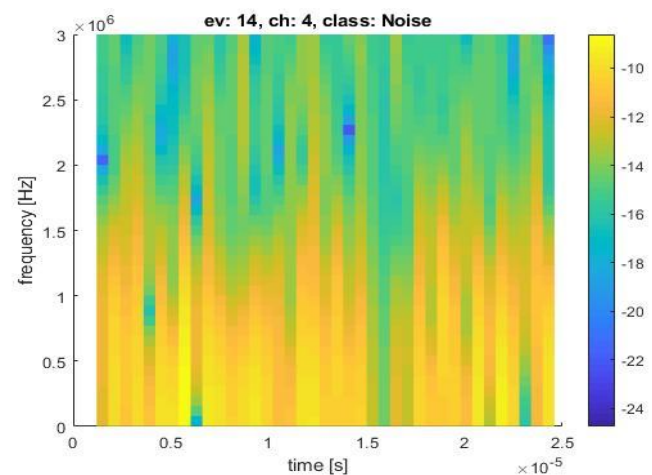

**OBRAZ !!!**

# 1. Co vložit ?

3 zákl. typy signálu

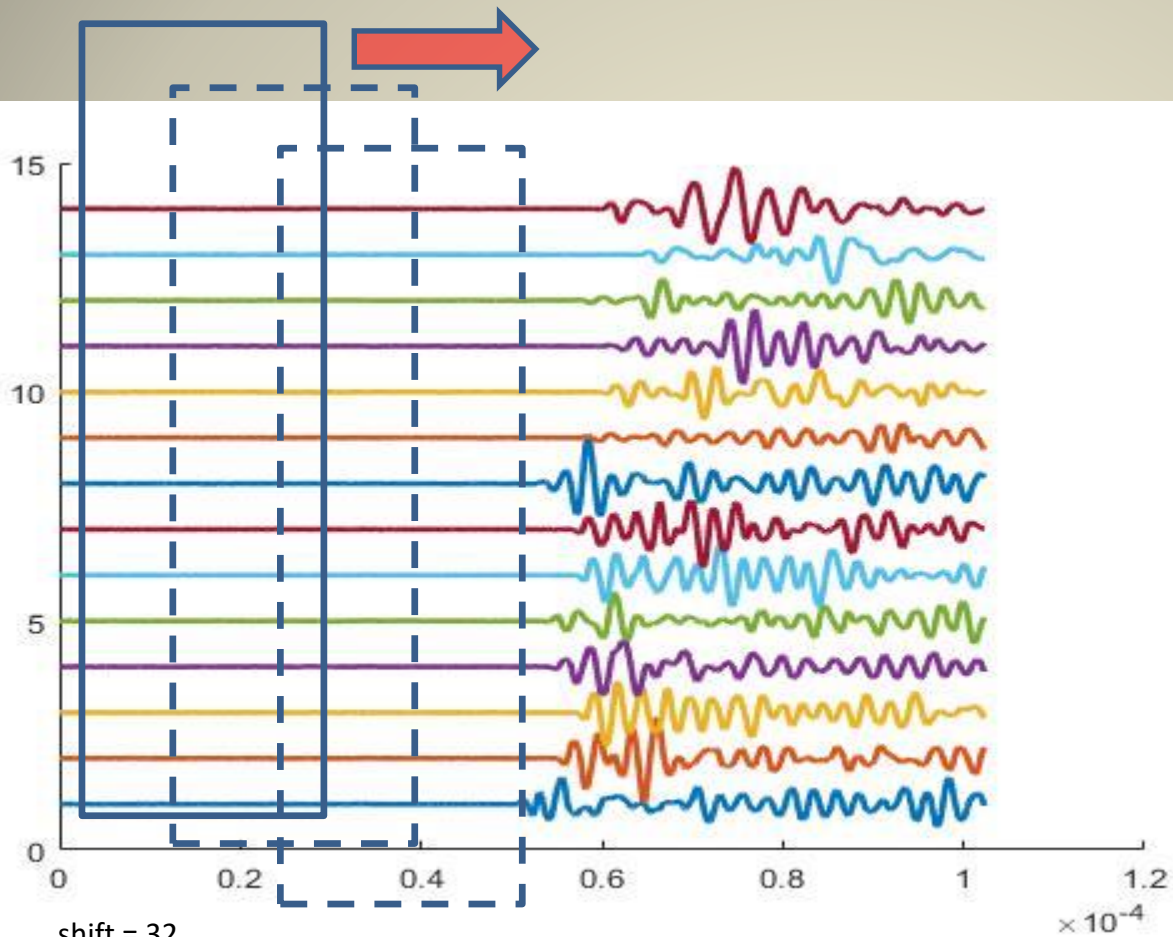
```
[p,f,t]=pspectrum(imagA(j,:),fs,'spectrogram');
```

ev.: 14






## AE seismogramy – rozřídění a kategorizace



### Kategorie:

- Noise
- partEvent
- Event
- partCoda
- Coda

shift = 32



dWin = 256



tj. 26 sub-jevů

dSeism = 1024




**1. Co vložit ?**

(neúspěšné) pokusy 1D






# (neúspěšné) pokusy 3D



1. Co vložit ?

až v MTL ver. 2018b

```
imageInputLayer([n m {1;3}=> k ])
```





## 2. Architektura CNN ?

Convolution package	Layer No.	Name, function	Description, parameters
(input)	1	'Image Input'	(40 x 40 x 14) images with 'zerocenter' normalization
1 <sup>st</sup>	a	'Convolution 1'	14 (7 x 7) convolutions with stride [1 1] and padding 'same'
	3	'Batch Normalization 1'	Batch normalization
	4	'ReLU 1'	ReLU
	5	'Max Pooling 1'	(2 x 2) max pooling with stride [2 2] and padding [0 0 0 0]
2 <sup>nd</sup>	6	'Convolution 2'	28 (5 x 5) convolutions with stride [1 1] and padding 'same'
	7	'Batch Normalization 2'	Batch normalization
	8	'ReLU 2'	ReLU
	9	'Max Pooling 2'	(2 x 2) max pooling with stride [2 2] and padding [0 0 0 0]
3 <sup>rd</sup>	10	'Convolution 3'	56 (3 x 3) convolutions with stride [1 1] and padding 'same'
	11	'Batch Normalization 3'	Batch normalization
	12	'ReLU 3'	ReLU
(output and classification)	13	'Dropout'	50% dropout
	14	'Fully Connected'	5 fully connected layer
	15	'Softmax'	Softmax
	16	'Classificaation output'	Crossentropyex

### 3. Jaký výstup (co hledat) ?

3 kategorie (*noise, event, coda*)

+ 2 přechodové kategorie

=====

5 kategorií



### 3. Jaký výstup (co hledat) ?

38 záznamů ~ 3.400 sub-obrazů

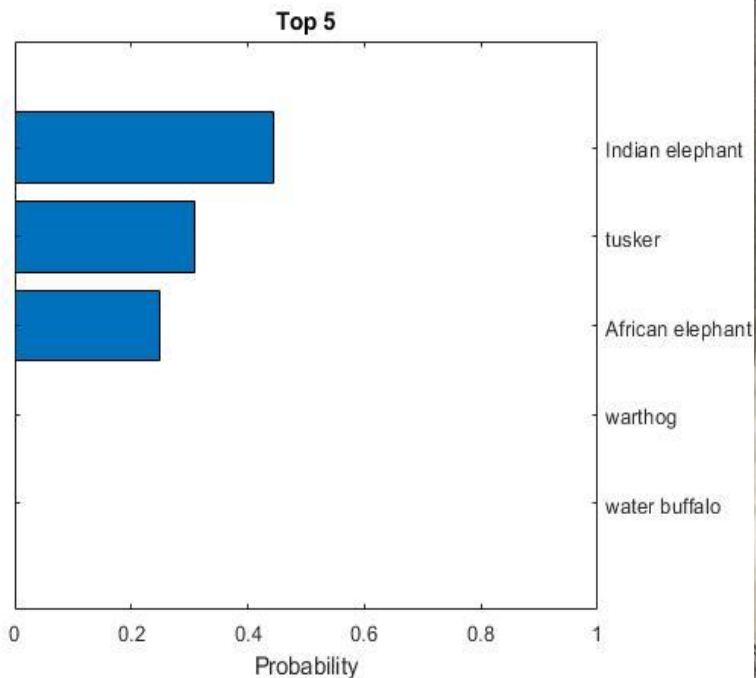
train	valid	test
60 %	10 %	30%
23	4	11

**Confusion Matrix**

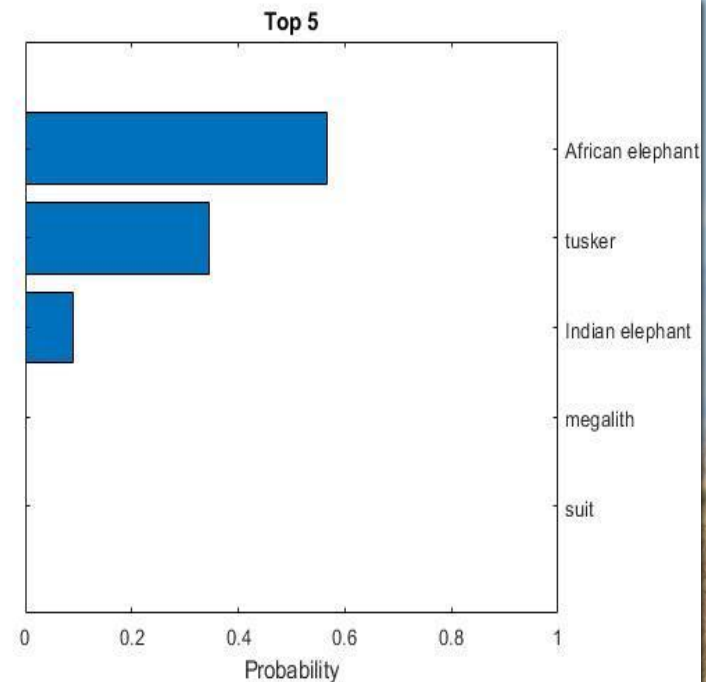
Output Class	Coda	Event	Noise	PartCoda	PartEvent	
Coda	146 13.7%	0 0.0%	0 0.0%	11 1.0%	0 0.0%	93.0% 7.0%
Event	0 0.0%	155 14.5%	0 0.0%	18 1.7%	4 0.4%	87.6% 12.4%
Noise	0 0.0%	0 0.0%	343 32.1%	0 0.0%	9 0.8%	97.4% 2.6%
PartCoda	16 1.5%	4 0.4%	0 0.0%	164 15.4%	0 0.0%	89.1% 10.9%
PartEvent	0 0.0%	15 1.4%	2 0.2%	0 0.0%	180 16.9%	91.4% 8.6%
	90.1% 9.9%	89.1% 10.9%	99.4% 0.6%	85.0% 15.0%	93.3% 6.7%	92.6% 7.4%
	Coda	Event	Noise	PartCoda	PartEvent	

Target Class

# cnn AlexNet



Indian elephant



African elephant



# Vylepšení - kombinace pravděpodobností z jednotlivých kategorií

identification probability (*IP*)


$$IP1 = 0.5 * pN + (1 - pPe) + pE + 0.5 * pPc + (1 - pC), \quad (1)$$

$$IP2 = (1 - pN) + 0.5 * pPe + pE + 0.5 * pPc + (1 - pC), \quad (2)$$

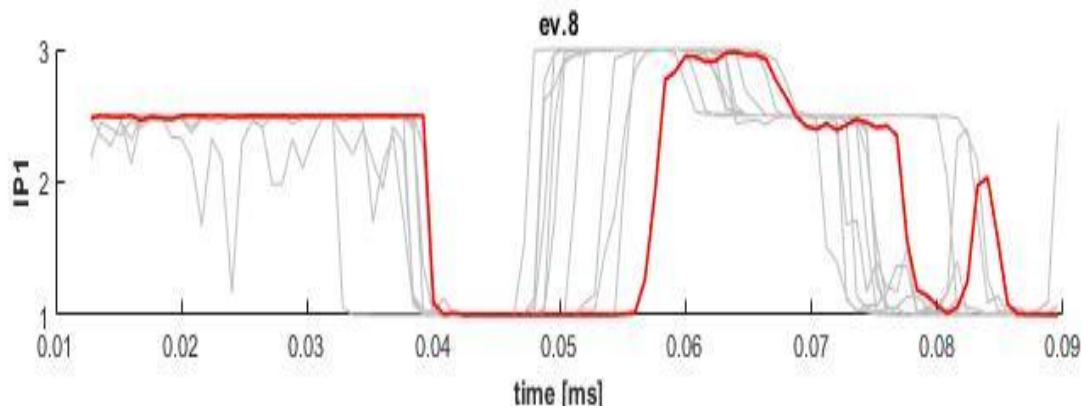
$$IP3 = (-pN) + (pPe - 0.5) + pE + (pPc - 0.5) + (-pC), \quad (3)$$

where  $pN$ ,  $pPe$ ,  $pE$ ,  $pPc$ , and  $pC$  indicate the probability of classes: *noise*, *part-event*, *event*, *part-coda*, and *coda*

# výsledky

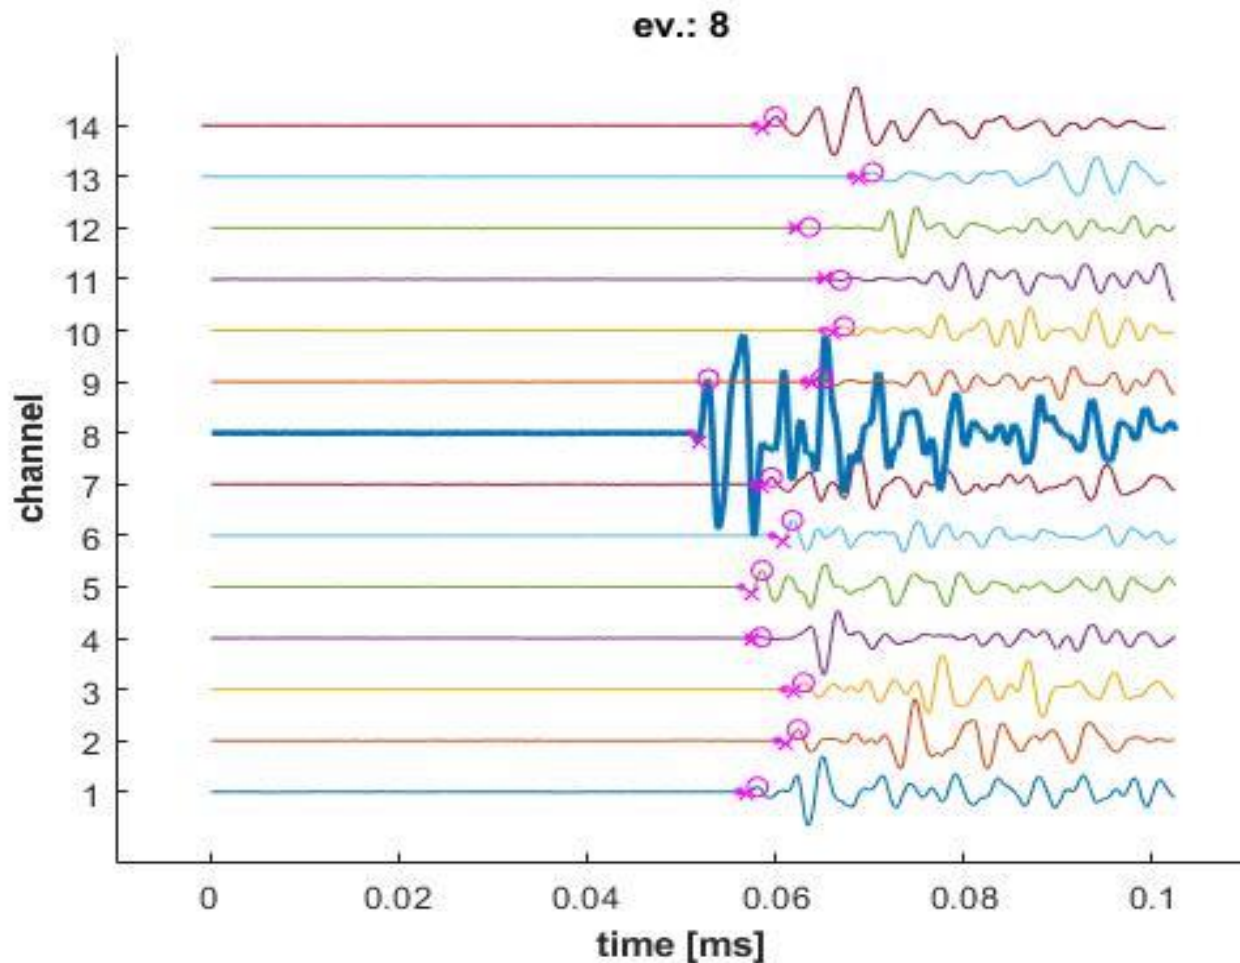







zvláštní  
případ I.


*dvojitý  
jev*



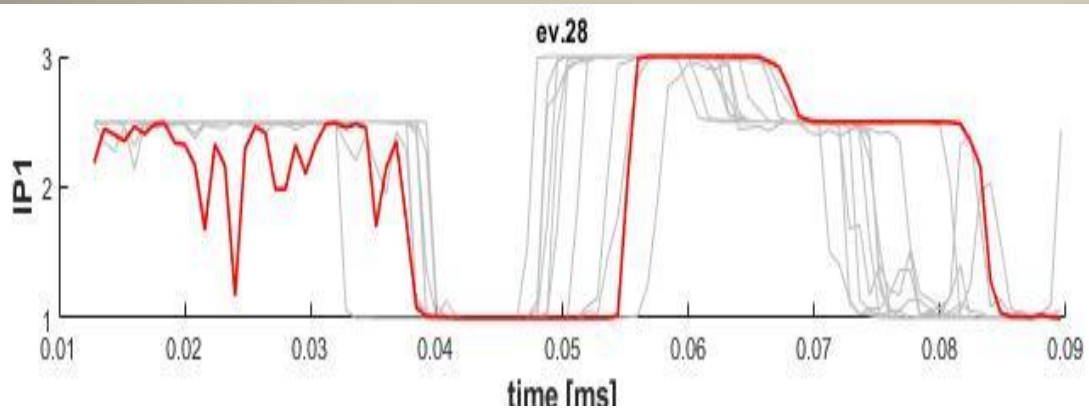


zvláštní  
případ II.

*dřívější  
začátek*









zvláštní  
případ III.

*slabý jev/  
rušení*



# Větší datový soubor

*identifikace 200 z 660 jevů*



# Shrnutí:

úspěšná identifikace testovacích jevů

3 části:

- vstup  $L \times K \times N_{dim}$  (počet kanálů)
- zpracování standardní
- výstup kombinace pravděpodobnosti

Plány:

- slabé AE jevy s nekompletním seismogramem
- reálná data

Poděkování:

za TCC ??,

které je nejen 'příjemné' && 'inspirativní' (alespoň jeden případ 😊)





