

Rozpoznávání ultrazvukových signálů pomocí konvolučních neuronových sítí.


Martin Kovanda

Aplikované matematicko-stochastické metody


18. září 2020

- 1 Cíle bakalářské práce
- 2 Klasické architektury neuronových sítí
 - Problém posunu obrazu
- 3 Konvoluční neuronové sítě (CNN)
 - Základní schéma CNN
 - Časo-frekvenční interpretace
 - HFD spektrogram
- 4 Numerické experimenty
 - Přínos použití konvoluční části sítě
 - Přínos použití L2 regularizace
 - Přínos použití svazkové normalizace
 - Přínos zvýšení posunu časových oken
- 5 Závěry

Cíle bakalářské práce



AE kanál 2
(planetová ložiska)




- ověření možnosti rozpoznávání ultrazvukových signálů (pro detekci poruch, sledování stavu konstrukce,...)
- využití strojového učení (vrstevnaté sítě, CNN)

Klasické architektury neuronových sítí


Perceptron

(logické funkce, OR, AND,...)




Vrstevnaté sítě

(interpolace, složitější funkce,...)




Asociativní paměti

(ropoznání obrazu, odstranění šumu,...)




Kohonenova mapa

(klastrování,...)



Problém posunu obrazu

Vstupní obraz:




Vektorizace:




Analogický problém: časový posun vstupního signálu

Konvoluční neuronové sítě




Nutnost převést signál
do 2D podoby


Vstupní obrázek



$7 \times 7 \times 3$



Časo-frekvenční interpretace



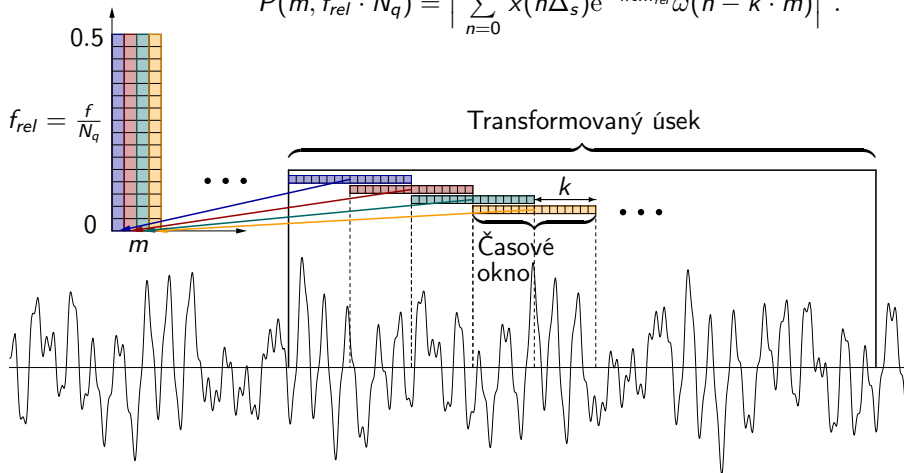
K aplikaci CNN na signál je nutné nejprve použít vhodnou časo-frekvenční transformaci, např.

- spektrogram,
- Spojitou waveletovou transformaci, nebo
- HFD spektrogram.

Schéma HFD spektrogramu


Definice High Frequency Density (HFD) spektrogramu:

$$P(m, f_{rel} \cdot N_q) = \left| \sum_{n=0}^{N-1} x(n\Delta_s) e^{-\pi i n f_{rel} \omega(n - k \cdot m)} \right|^2.$$




Příklad HFD spektrogramu

Vizualizace 4-kanálového signálu v barevném prostoru CMYK
pro $k = 1$:



a pro $k = 128$: (časová okna se již nepřekrývají)



Vizualizace architektury použitých sítí



Poolingová vrstva.



Konvoluční vrstva s L2 regularizací s parametrem p a počtem neuronů N .



Vrstva zploštění.



Vrstva vrstevnaté sítě s počtem neuronů N , na kterou je aplikována L2 regularizace s parametrem p .




Výstupní vrstva s počtem neuronů N .

\mathcal{N}

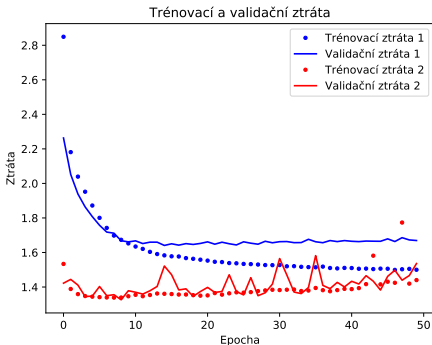



Použití svazkové normalizace.

$\frac{0.1}{\mathcal{N}}$




Použití dropoutu a svazkové normalizace.



Přínos použití konvoluční části sítě




Přínos použití L2 regularizace



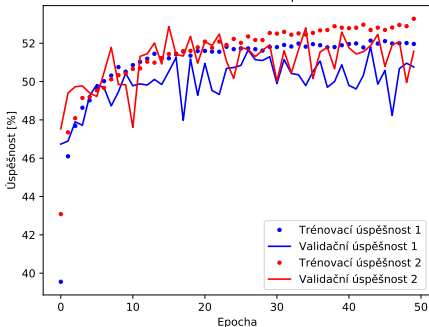
Přínos použití svazkové normalizace

1: $\begin{bmatrix} \text{H255} \\ [64, 64, 4] \end{bmatrix}$

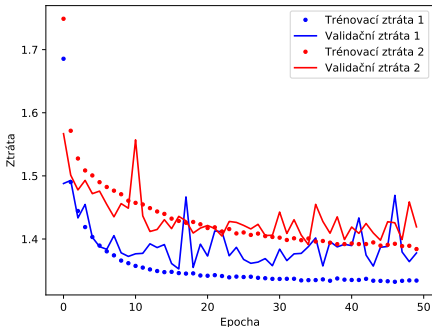
2: $\begin{bmatrix} \text{H255} \\ [64, 64, 4] \end{bmatrix}$



Trénovací a validační úspěšnost




Trénovací a validační ztráta



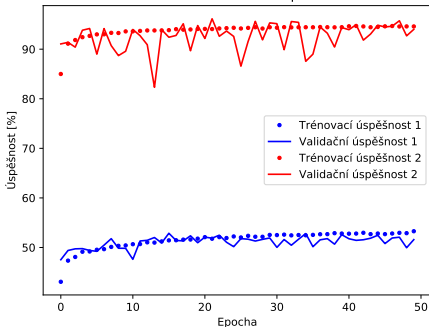
Přínos zvýšení posunu časových oken

1: $\begin{bmatrix} \text{H255} \\ [64, 64, 4] \end{bmatrix}$

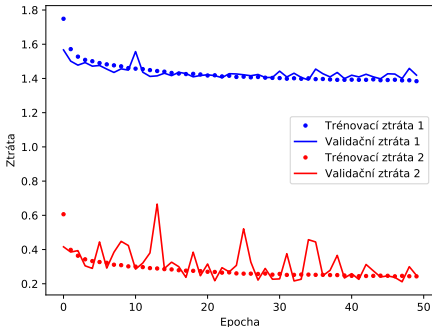
2: $\begin{bmatrix} \text{H16384} \\ [64, 64, 4] \end{bmatrix}$



Trénovací a validační úspěšnost

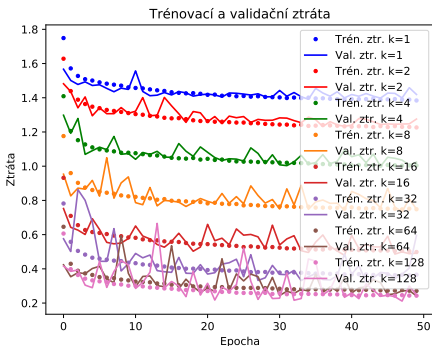
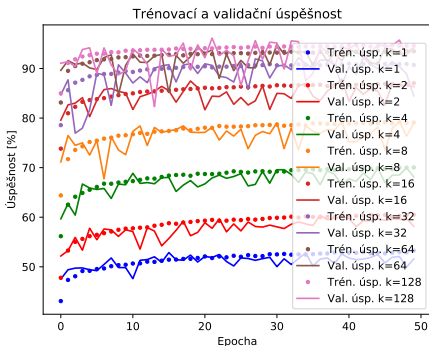



Trénovací a validační ztráta



- Vrstevnaté sítě jsou nevhodné pro analýzu delších časových úseků.
- CNN jsou méně náchylné na posun signálu o jednotlivé vzorky.
- Při CNN mohou klasifikaci zefektivnit optimalizované časo-frekvenční transformace.
- L2 regularizace se osvědčily u všech uvažovaných sítí.
- Dropout naopak může kvalitu sítě zhoršit.
- Významný nárůst úspěšnosti nastává s postupným zvyšováním posunu časového okna.

Otázka



Závěr: generalizace CNN se zlepšuje se zvětšováním transformovaného úseku