

Beszámoló

Zeffer Tamás

2025 január 23

Anyagtudományok és Technológiák Doktori Iskola (VII. félév)

Belső konzulens: Csikósné Pap Andrea

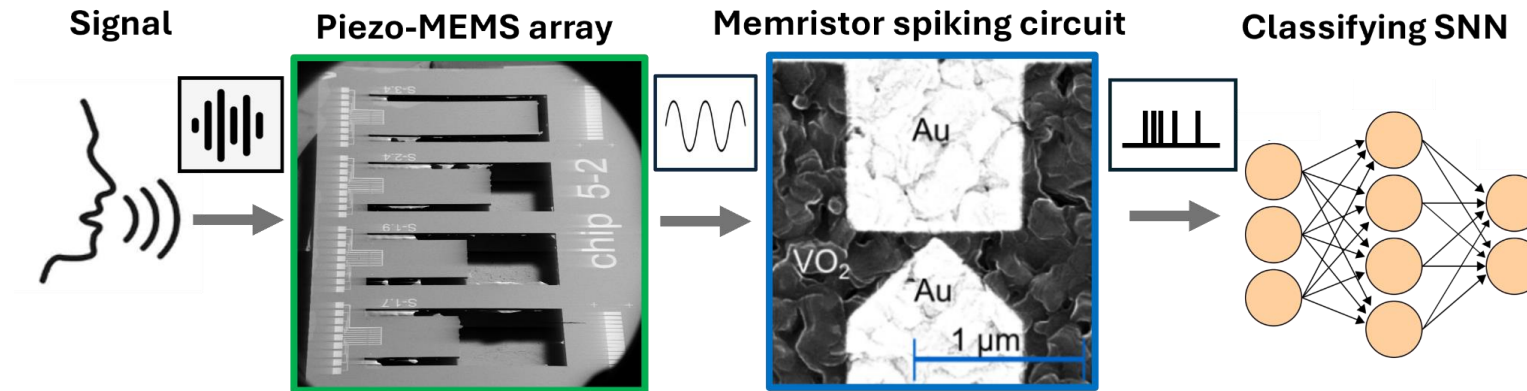
Külső konzulens: Volk János

HUN-REN EK MFA, Nanoérzékelők Laboratórium (2022. októbertől)

PhD téma: Vékonyréteg technológiával megvalósítható intelligens érzékelés

Kutatásom Célja

Érzékelő: mely alkalmas tüzelő neurális hálózat (SNN)-alapú ⁽¹⁾, bioinspirált ⁽²⁾, intelligens ⁽³⁾, és osztályozási funkciók ellátására



- Hangolt rezgőnyelvekkel DSP ⁽⁴⁾-mentes hardvert
- Memrisztoros interfésszel, SNN kompatibilis, neuromorf jeleket
- Bioinspirált, kompakt SNN kialakítással peremhálózati ⁽⁵⁾ IoT megoldást

⁽¹⁾ SNN (Spiking Neural Network): egy olyan típusú neurális hálózat, amely a biológiai idegsejtek spiking jellegét utánozza

⁽²⁾ C. Mead, "Neuromorphic electronic systems," Proceedings of the IEEE, vol. 78, no. 10, pp. 1629–1636, Oct. 1990, doi: 10.1109/5.58356

⁽³⁾ Intelligens szenzor: A környezeti jeleket az érzékelésen túl, az érzékelés közelében, hatékonyan előfeldolgozza. Pl. kamerákban pixelenkénti előfeldolgozás

⁽⁴⁾ DSP: Digital Signal Processing 10.1109/5.58356

⁽⁵⁾ Peremhálózat vagy "Edge Computing": Feldolgozás helyben történik szemben a felhőben történő feldolgozással


Az érzékelő-hardver modellezése

érzékelő és előfeldolgozó hardver

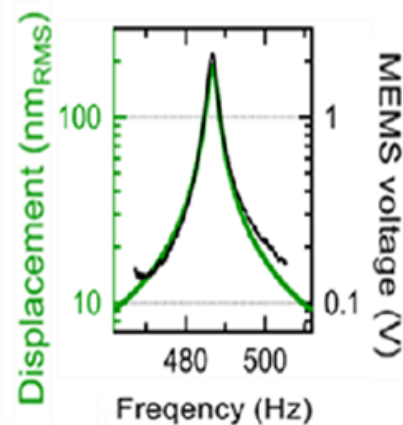


Laborban elérhető előfeldolgozó egységek


Spirális rezgőnyelv SEM




rezonanciagörbe



memrisztor SEM




Oscillátor áramkör
amplitúdó-frekvencia görbéje



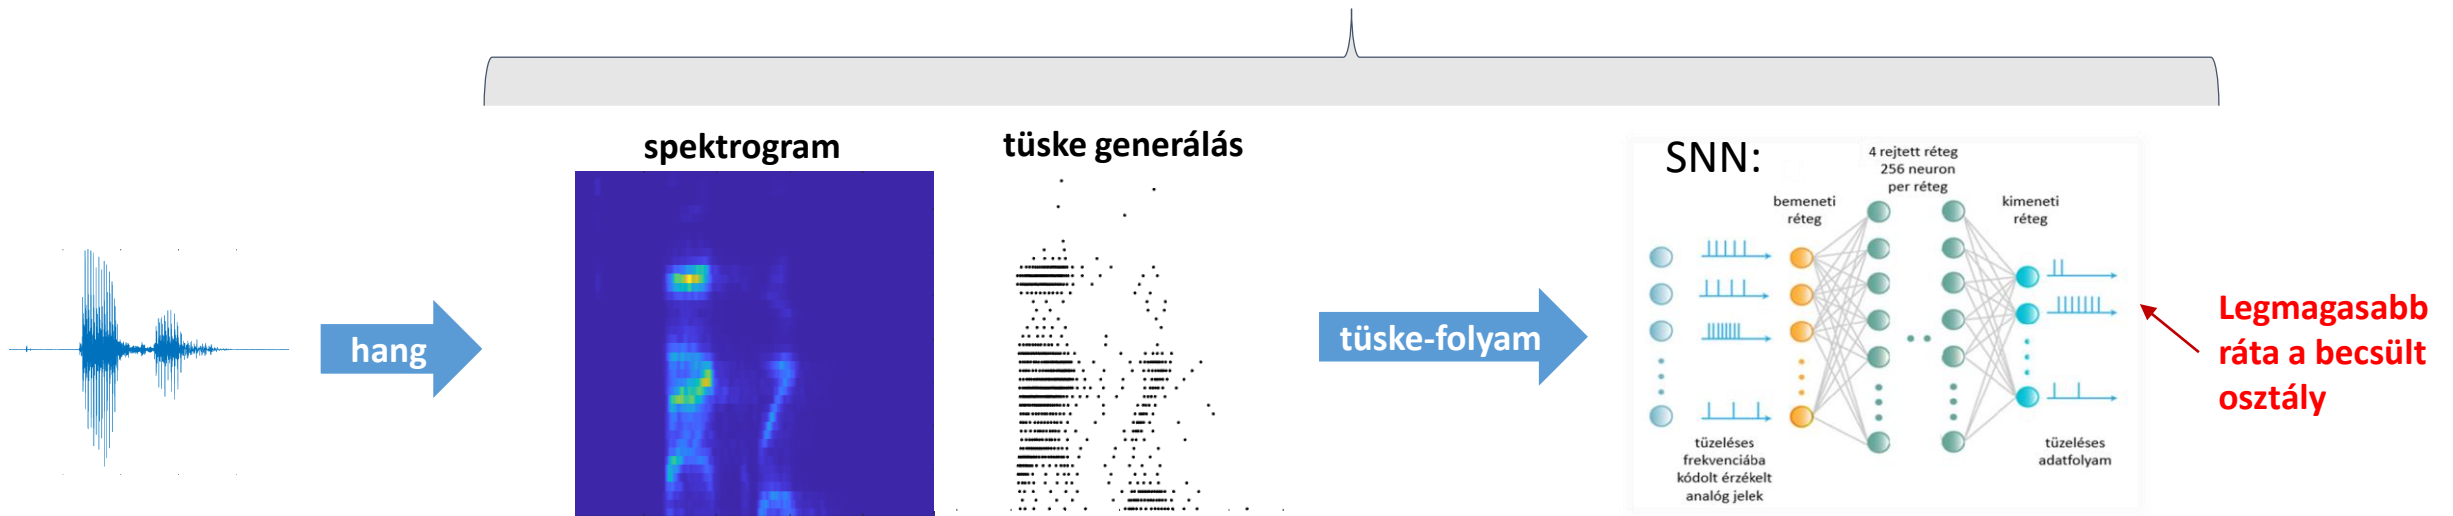
- Frekvencia szelektív piezoelektromos rezgőnyelvek
- Keskeny sávú szűrők (7 Hz). Átlagos $Q=185$
- Az amplitúdó kódolást sikerült -> memrisztoros hw-en
- tüzelési rátával kódolt amplitúdó -> memrisztoros oszcillátor áramkör
- A legyártott VO₂ memrisztor jelenleg zafír szeleten van. ☹️

tüske oszcillátor:

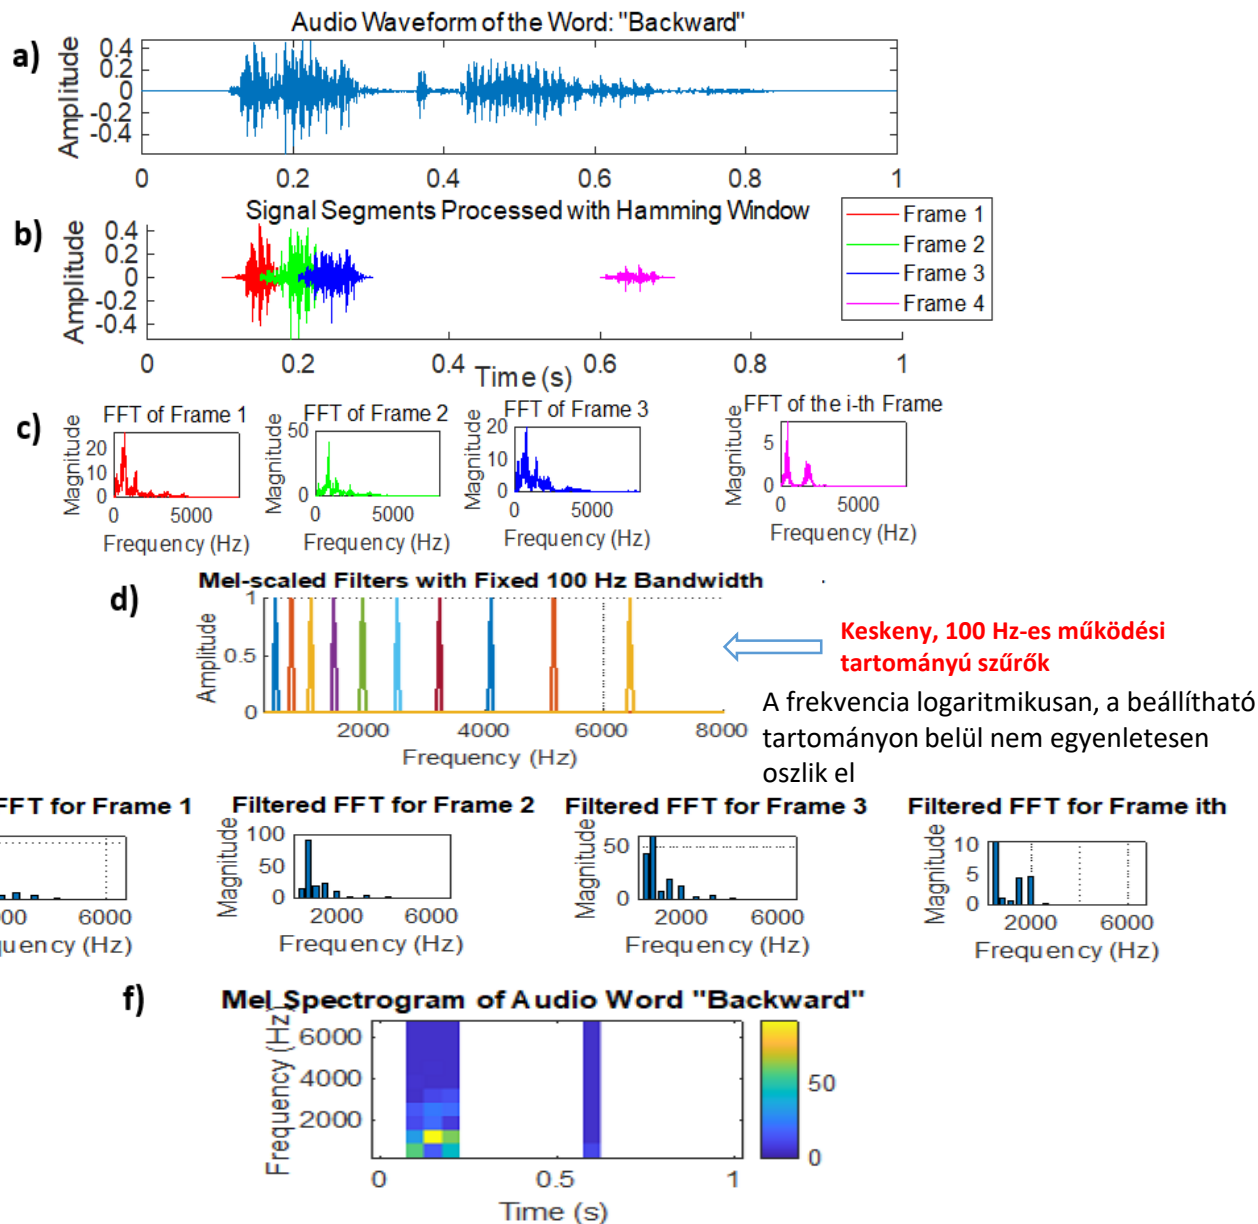


Együttes vizsgálat: intelligens érzékelő és SNN

Előfeldolgozó kódolás és SNN együttes, szoftveres optimalizálása

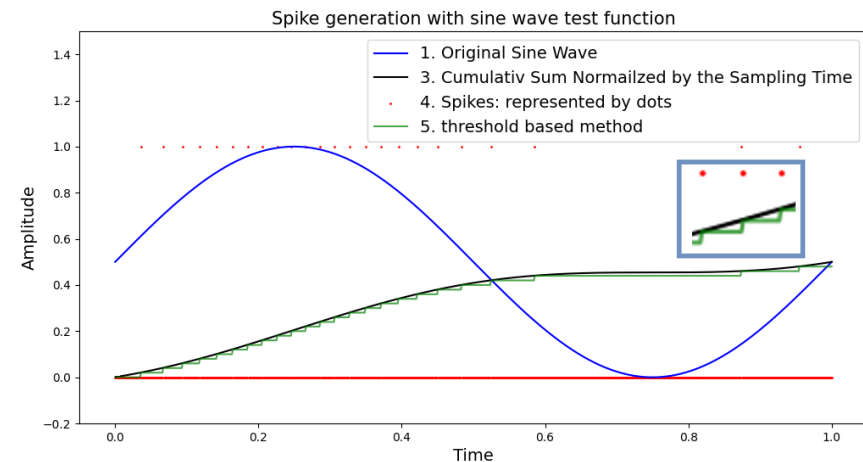


Hardver Emuláció: spektrogram és túske folyam pipeline képzése



Spektrogram képzése:

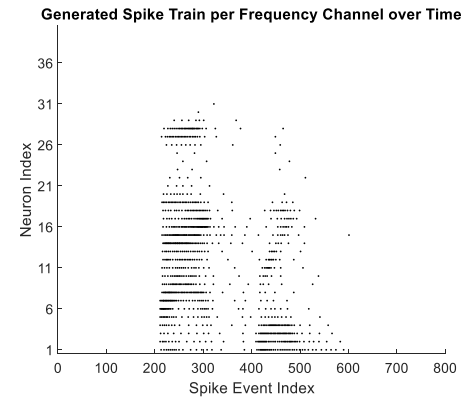
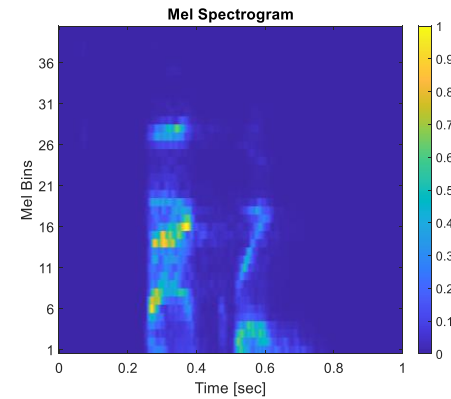
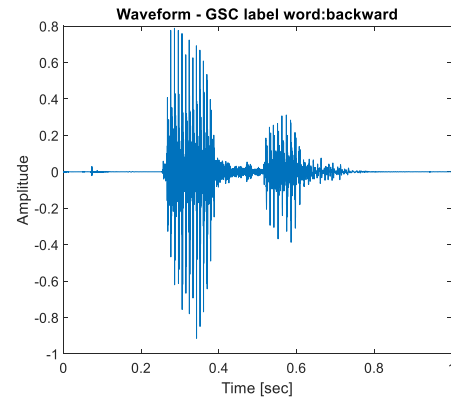
- Jel->Időablakos felbontás -> FFT -> Szűrőbank -> Spektrogram
- keskenysávú szűrők modellezik a rezgőnyelveket
- Csatornánként, időben változó amplitúdó csatornánként -> túskegenerálás




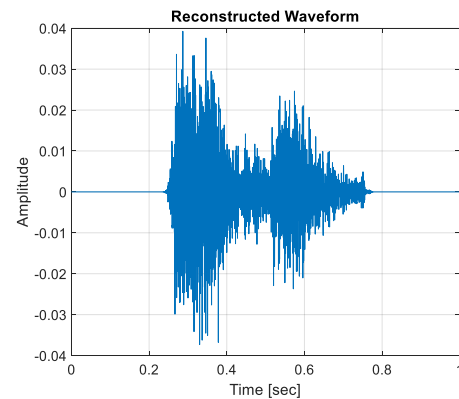
Túskegenerálás szinusz, tesz függvényen bemutatva (a prezentáció érdekében):

- Diszkrét integrál téglalap módszer (fekete), majd
- minden delta értéknövekedés esetén:
 - ha a növekedés meghaladja a küszöbértéket, túske generálunk ($Out(t_i) = 1$).
 - ha nem, nincs túske ($Out(t_i) = 0$).

Hiperparaméter becslés: előfeldolgozási folyamatlánc és annak inverz műveletének segítségével

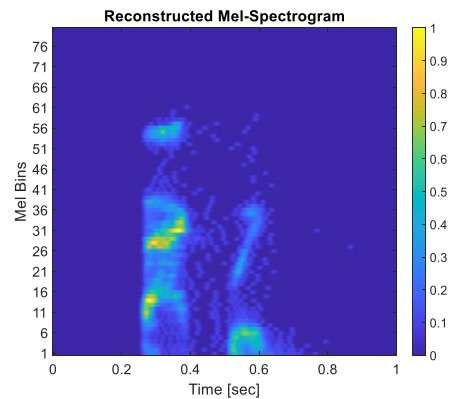
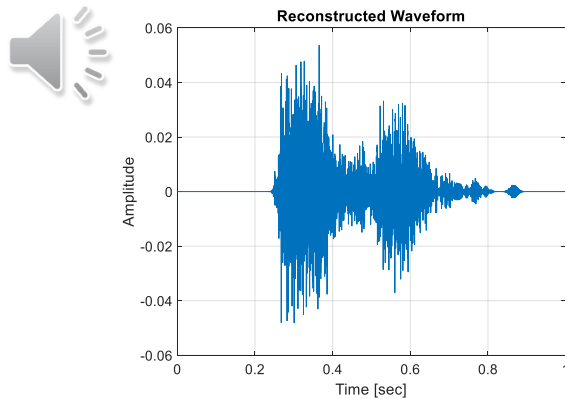

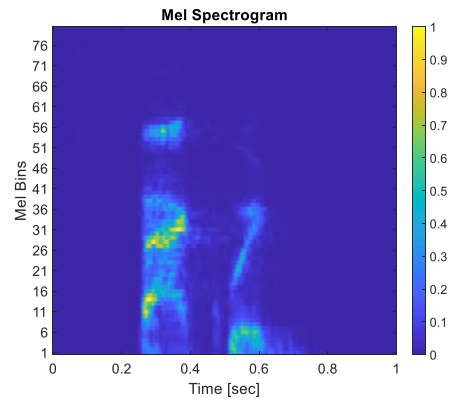
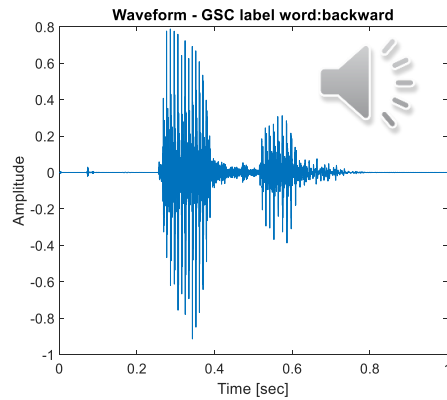


- előfeldolgozás (felső sor):
- rekonstruált szakaszok (alsó sor)
- Optimális beállítások a táblázatban



Hyper-parameters	Value
Filter Type	100Hz bandwidth
FFT Frame Length	512 sample
Frequency Range	300-8000 Hz
Hop Length	20 time steps
Time Steps (the number of spike index)	800
Threshold (for normalized magnitude)	7e-5
Number of Channels	40

Hiperparaméter becslés az előfeldolgozási folyamatláncban




Hyper-parameters	Value
Filter Type	100Hz bandwidth
FFT Frame Length	512 sample 2048
Frequency Range	300-8000 Hz
Hop Length	20 time steps 80
Time Steps (the number of spike index)	800
Threshold (for normalized magnitude)	7e-4
Number of Channels	20.....80

Ajánlott mindezt több mintán megnézni a tanító adatkészleten

Hiperparaméterek keresése SNN-hez (tanítások)

Hiperparaméterek:

Hyperparameters	Value	pipeline
1. Filter Type	$f_{BW}=100\text{Hz}$	SNN modell
2. FFT Frame Length	512 sample	
3. Frequency Range	300-8000 Hz	
4. Hop Length	20 time step	
Time Steps (the number of spike index)	800 time steps	
5. Threshold (for normalized magnitude)	7e-5	
6. Number of Channels = Input Number of SNN	40	
7. Number of Layers	4 (homogeneous)	
8. Number of neurons per layer	256	
9. Neuron Type	LIF (Leaky, Integrate, and Fire)	
10. LIF Neuron Threshold	0.6 (homogeneous)	
11. LIF beta: LIF membrane potential decay rate setting	0.9 (11.8 ms) (homogeneous)	
12. Learning rate	0.001 (with and without ⁽¹⁾ learning rate scheduler)	
Loss Function (not changed)	Mean Square Error	
Optimization Method (not changed)	Adaptive Moment Estimation (ADAM)	
Learning (not changed)	Surrogate Gradient	











SNN paraméterek meghatározása tanításokkal:

- Modell paraméter változtatás és szakirodalmi adatok alapján
- MEMS két paraméterének meghatározása

Confusion matrix és metrikák

$$\text{Érzékenység} = \frac{TP}{TP+FN}$$

$$\text{Pontosság} = \frac{TP}{TP+FP}$$

		
 valódi osztály		(FN) 
	(FP) 	
	becsült osztály	

TP - True Positiv:

a helyesen osztályozott minták

(FN) - False Negativ:

Tévesen sorolja bemáshová.
















Tüskét lát a rózsában.

(FP) - False Positiv:

Tévesen sorolja be saját magához
















Rózsát lát a tüskében.

Confusion Matrix értékelése példával

FP: tévesen sorolja be saját magához

FN: tévesen sorolja be másóvá

Pontosság (Precision): TP aránya az FP-hez képest

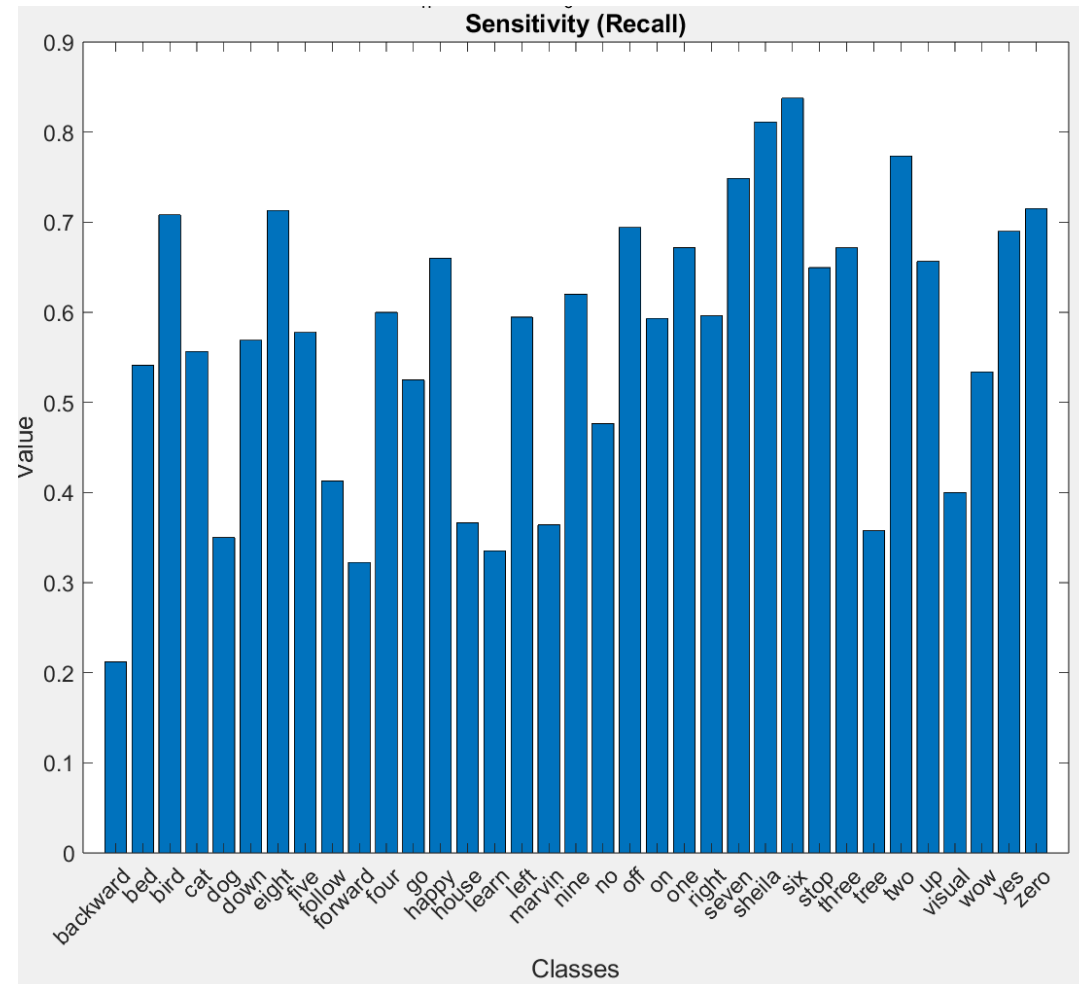
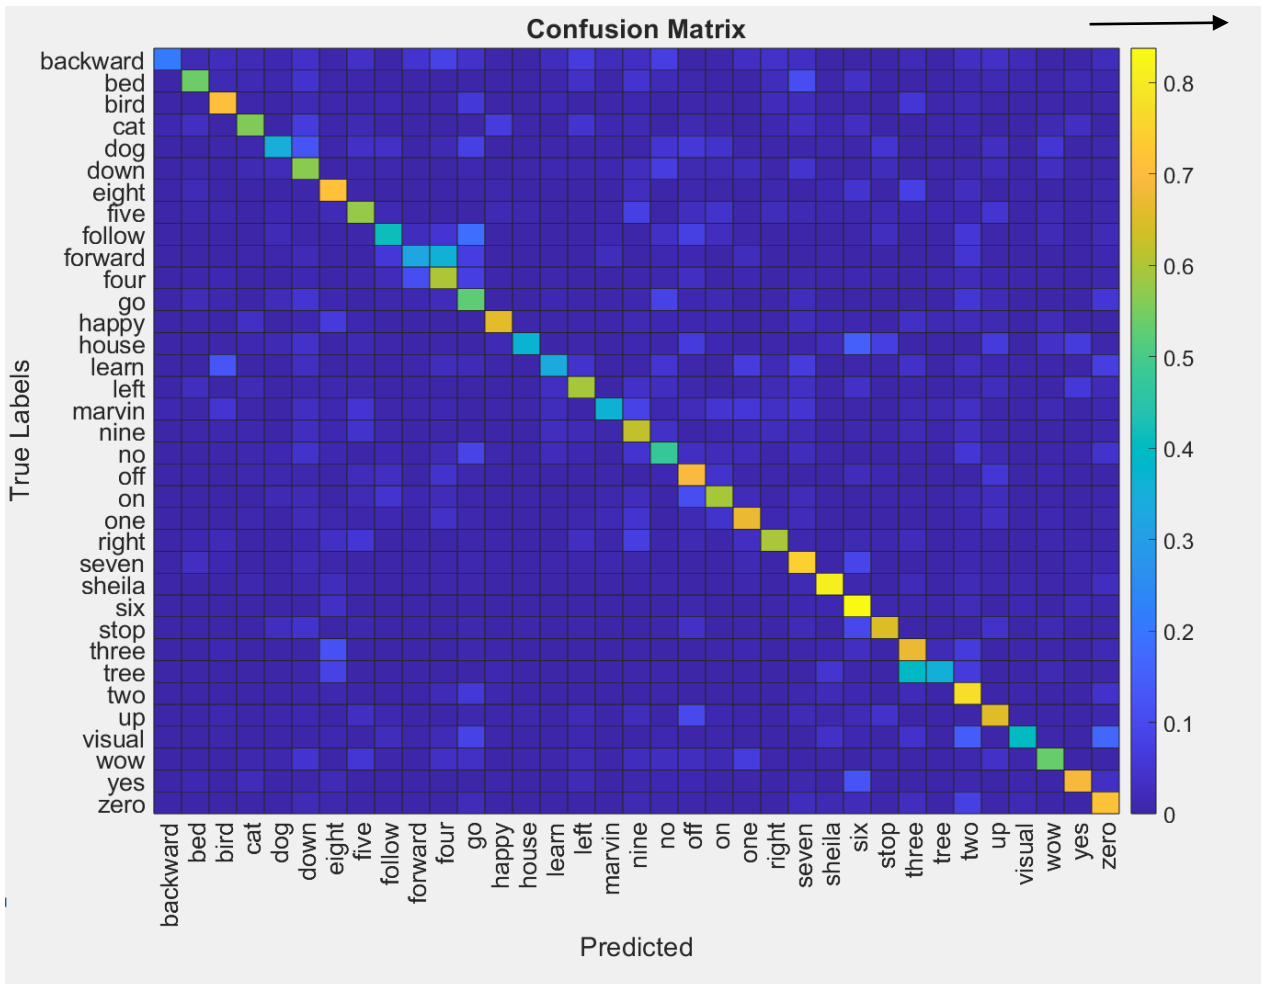
Érzékenység (Sensitivity): TP aránya az FN-hez képest

Accuracy: TP aránya az összes mintához képest

$$Pontosság_{rózsa} = \frac{TP_{rózsa}}{TP_{rózsa} + FP_{rózsa}} \cdot 100 = 74\%$$

$$Érzékenység_{rózsa} = \frac{TP_{rózsa}}{TP_{rózsa} + FN_{rózsa}} \cdot 100 = 90\%$$

CM + Érzékenység - Eredmény kiértékelése



Hiperparaméterek és a tanulási eredmények

Az osztályozó teljesítmény metrikák szűrőbank típusok és 20, 40, 80 csatornaszámok esetén

Szélessávú vagy standard szűrők (std)					Keskenysávú szűrő (nb)				
Modell név	Precision	Sensitivity	F1-Score	Test Accuracy	Modell név	Precision	Sensitivity	F1-Score	Test Accuracy
ch20_std	0.62	0.58	0.58	0.62	ch20_nb	0.57	0.52	0.52	0.56
ch40_std	0.63	0.59	0.58	0.62	ch40_nb	0.61	0.57	0.56	0.60
ch80_std	0.63	0.57	0.57	0.61	ch80_nb	0.61	0.58	0.57	0.60

Szélessávú szűrőbankoknál egyforma értékű metrikák

- Keskenysávú szűrőbank típusú és minimum 40 csatornával rendelkező modell megközelíti szélessávú modellek teljesítményét
- 40 csatorna felett már nincs metrika növekedés

Az együttes, szoftveres szimulációs tervezés a két paramétert határozza meg a hardver megalkotásához:

1. 40 csatornaszámot és
2. 100 Hz sávszélességű rezgőnyelveket.

Kitekintés

- Új leválasztási technikával elkészültek a VO₂ szeletek. Ezért a gyártása idén lehetővé válik
- elektronsugaras áramköri tervet megkezdtem
- Gyártás után
- Mikroelectromechanikai teszt
- Oszcillátoros ák.-k Tesztje
- SNN teljesítmény tesztje

Félévi publikációs tevékenység

Konferencia: Zeffner, Tamás ; Török, Tímea Nóra ; Pósa, László ; Braun, Ferenc ; Halbritter, András ; Volk, János “Towards fully hardware-based neuromorphic encoding for efficient vibration signal recognition”, EUROSENSORS

A fenti munkából folyóiratcikk kézírata elkészült:

T.Zeffner, T. Török, A.Csikosné Papp, J. Volk - Towards fully hardware-based neuromorphic encoding for efficient speech recognition

Benyújtott folyóiratcikk:

A.M. Ámon, E. Simonyi, T. Zeffner, Ö. Kovács, B.Cornelis, A.Soumelidis, T. Dózsa - Adaptive continuous wavelet transform based model driven neural networks for fault detection, IEEE Signal Processing Letters

Vége

Köszönöm a figyelmet.