

Sistem de clasificare a semnalelor EEG folosind rețele neurale adânci

Maria-Cristina Andronache

Coordonatori:

Prof. Univ. Dr. Ing. Corneliu Burileanu
As. Univ. Drd. Ing. Ana-Antonia Neacșu

Facultatea de Electronică, Telecomunicații și
Tehnologia Informației

Iulie 2020

Cuprins

- 1 Introducere
- 2 Noțiuni introductive
- 3 Setup experimental
- 4 Metoda propusă
- 5 Rezultate
- 6 Concluzii

Introducere

Motivație și Aplicabilitate

Motivație

- Evoluția rețelelor neuronale;
- Popularitatea domeniului BCI (Brain Computer Interface).

Motivație și Aplicabilitate

Motivație

- Evoluția rețelelor neuronale;
- Popularitatea domeniului BCI (Brain Computer Interface).

Aplicabilitate

- Comunicarea cu pacienții care nu se pot mișca și/sau nu pot vorbi;
- Realitate augmentată și jocuri.

Noțiuni introductive

Semnalul EEG – definiții

Electroencefalograma (EEG) – reprezentarea grafică, în timp, a activității electrice cerebrale.




Figura: Semnal EEG

**Pentru această lucrare EEG se va referi la vectorul de valori discrete reprezentând amplitudinea tensiunii măsurate la nivelul scalpului.*

Rețele neurale





Figura: Rețea neurală - Schemă generală

Neuronul – Reprezentare generală



În cadrul fiecărui neuron au loc 2 operații:

1 O operație liniară:

$$\xi = W^T X = \sum_{i=1}^N x_i \cdot w_i + b$$

2 O operație neliniară:

$$y = g(\xi),$$

$$\text{unde } g \rightarrow \begin{cases} \tanh \\ \text{sigmoid} \\ \arctan \\ \text{softmax} \end{cases}$$

Formule pentru funcții de activare

Formule de calcul:

$$\text{sigmoid}(x) = \frac{1}{1 + e^{-x}}$$

$$\text{tanh}(x) = \frac{\sinh(x)}{\cosh(x)} = \frac{e^x - e^{-x}}{e^x + e^{-x}} = \frac{e^{2x} - 1}{e^{2x} + 1}$$

$$\text{arctan}(x) = \tan^{-1}(x) = \int_0^x \frac{1}{z^2 + 1} dz$$

$$\text{softmax}(x_i) = \frac{e^{x_i}}{\sum_{j=1}^N e^{x_j}}$$

Formule pentru funcții de activare

Formule de calcul:

$$\text{sigmoid}(x) = \frac{1}{1 + e^{-x}}$$

$$\text{tanh}(x) = \frac{\sinh(x)}{\cosh(x)} = \frac{e^x - e^{-x}}{e^x + e^{-x}} = \frac{e^{2x} - 1}{e^{2x} + 1}$$

$$\text{arctan}(x) = \tan^{-1}(x) = \int_0^x \frac{1}{z^2 + 1} dz$$

$$\text{softmax}(x_i) = \frac{e^{x_i}}{\sum_{j=1}^N e^{x_j}}$$

Funcția de cost:

$$\text{Binary Cross Entropy} \rightarrow \mathcal{L} = -\frac{1}{n} \sum_{i=1}^N y_i \log(\hat{y}) + (1 - y_i) \log(1 - \hat{y})$$

Setup experimental

Quik-Cap și amplificatorul Neuvo



neuvo¹



- 128 electrozi;
- sistemul 10-20;
- se poate conecta direct la amplificatorul Neuvo.

- 128 canale;
- frecvență de eșantionare maximă de 10kHz;
- convertor analog digital de 24 biți;

Electorozi folosiți

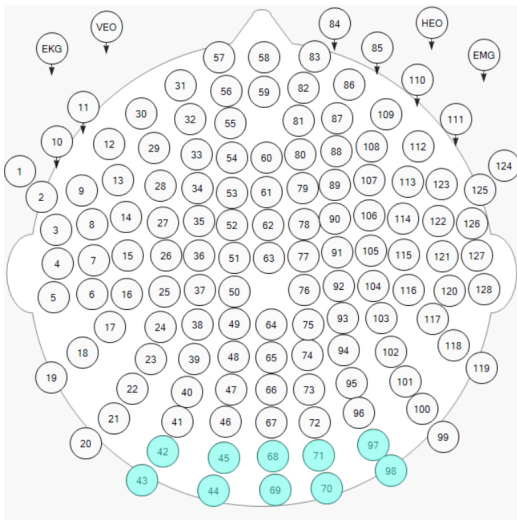


Figura: Distribuția electrozilor pe casca de achiziție

Stimuli

Semnalele EEG generate ca răspuns atunci când subiectului îi sunt prezentați stimuli vizuali, în special sub forma unor lumini pâlpâitoare, se numesc **SSVEP** (Steady State Visually Evoked Potential).

Stimuli

Semnalele EEG generate ca răspuns atunci când subiectului îi sunt prezentați stimuli vizuali, în special sub forma unor lumini pâlpâitoare, se numesc **SSVEP** (Steady State Visually Evoked Potential).

Model de paradigmă SSVEP:




Figura: Stimuli

Video

Metoda propusă

Schema proiectului




Figura: Succesiunea de etape din cadrul proiectului

Algoritmul CCA

Canonical Correlation Analysis reprezintă un algoritm folosit adesea pentru clasificarea semnalelor EEG care au drept stimul lumini pâlpâitoare. Scopul acestei metode matematice este acela de a găsi un spațiu unde datele au corelație maximă.

Algoritmul CCA

Canonical Correlation Analysis reprezintă un algoritm folosit adesea pentru clasificarea semnalelor EEG care au drept stimul lumini pâlpâitoare. Scopul acestei metode matematice este acela de a găsi un spațiu unde datele au corelație maximă.

Constrângerile algoritmului:

- 1 vectorii poziție sunt normați la unitate;
- 2 unghiul dintre vectorii de poziție $\theta \in [0, \pi/2]$ este minimizat.

Algoritmul CCA

Fie X_a și X_b 2 matrice de dimensiuni $n \times p$ și respectiv $n \times q$.

$$X_a w_a = z_a \quad X_b w_b = z_b,$$

unde $w_a \in \mathbb{R}^p$, $z_a \in \mathbb{R}^n$, $w_b \in \mathbb{R}^q$, $z_b \in \mathbb{R}^n$

$$\begin{aligned} \cos\theta_1 &= \max_{z_a^1, z_b^1 \in \mathbb{R}^n} \cos(z_a^1, z_b^1) \\ &= \max_{z_a^1, z_b^1 \in \mathbb{R}^n} \langle z_a^1, z_b^1 \rangle / \|z_a^1\| \|z_b^1\| \\ &= \max_{z_a^1, z_b^1 \in \mathbb{R}^n} \langle z_a^1, z_b^1 \rangle \end{aligned}$$

Algoritmul CCA

Fie X_a și X_b 2 matrice de dimensiuni $n \times p$ și respectiv $n \times q$.

$$X_a w_a = z_a \quad X_b w_b = z_b,$$

unde $w_a \in \mathbb{R}^p$, $z_a \in \mathbb{R}^n$, $w_b \in \mathbb{R}^q$, $z_b \in \mathbb{R}^n$

$$\begin{aligned} \cos\theta_1 &= \max_{z_a^1, z_b^1 \in \mathbb{R}^n} \cos(z_a^1, z_b^1) \\ &= \max_{z_a^1, z_b^1 \in \mathbb{R}^n} \langle z_a^1, z_b^1 \rangle / \|z_a^1\| \|z_b^1\| \\ &= \max_{z_a^1, z_b^1 \in \mathbb{R}^n} \langle z_a^1, z_b^1 \rangle \end{aligned}$$

- Pentru a găsi cea de a doua pereche (z_a^2, z_b^2) se calculează complementul ortogonal al primei perechi.
- Procedul se poate continua până nu se mai găsesc perechi.
- Vectorii w_a, w_b se pot găsi cu rezolvând probleme de valori proprii.

Rezultate

Organizare straturi ascunse

7 straturi identice - funcție de activare tanh

Nr. neuroni	antrenare		testare	
	cost	acuratețe [%]	cost	acuratețe [%]
8	0.63	64.00	0.40	84.62
16	0.59	65.71	0.34	87.18
32	0.57	69.71	0.32	87.18
64	0.57	71.71	0.35	87.18
128	0.58	71.43	0.33	87.18
256	0.58	70.86	0.33	84.62

Tabela: Rezultate

Organizare straturi ascunse

2 straturi identice - funcție de activare sigmoid

Nr. neuroni	antrenare		testare	
	cost	acuratețe [%]	cost	acuratețe [%]
8	0.51	72.00	0.36	84.62
16	0.51	74.00	0.37	84.62
32	0.54	70.29	0.41	84.62
64	0.52	72.57	0.40	79.49
128	0.55	72.00	0.41	84.62
256	0.64	63.43	0.55	71.79

Tabela: Rezultate

Organizare straturi ascunse

6 straturi identice - funcție de activare **arctan**

Nr. neuroni	antrenare		testare	
	cost	acuratețe [%]	cost	acuratețe [%]
8	0.57	73.71	0.34	89.74
16	0.54	76.57	0.36	84.62
32	0.56	70.57	0.33	84.62
64	0.55	73.71	0.33	82.05
128	0.55	74.29	0.34	84.62
256	0.56	70.57	0.34	84.62

Tabela: Rezultate

Concluzii

Contribuții personale

Pentru această lucrare de diplomă am adus următoarele contribuții personale:

- realizarea stării artei pentru clasificarea de semnale EEG;
- realizarea paradigmei experimentale pentru colectarea semnalelor de tip SSVEP;
- colectarea datelor folosind casca Quik-Cap, amplificator Neuvo și software-ul Curry 7;
- filtrarea semnalelor EEG;
- segmentarea datelor;
- aplicarea algoritmului CCA;
- testarea diverselor structuri de rețele neuronale.

Dezvoltări ulterioare

Metode prin care poate scala proiectul:

- achiziții ulterioare de date în aceleași condiții pentru a augmenta baza de date și astfel să crească relevanța experimentelor cu rețele neuronale;
- achiziții de date și cu alți subiecți în încercarea de a crea un sistem care este independent de utilizator;
- repetarea experimentelor cu un număr mai mare de stimuli;
- colectarea datelor EEG și când subiectul nu privește niciun stimul pentru a putea face diferența dintre intenția de a comunica cu sistemul BCI și simpla privire a mediului înconjurător.

Referințe



Masaki Nakanishi, Yijun Wang, Yu-Te Wang, and Tzyy-Ping Jung

A comparison study of canonical correlation analysis based methods for detecting steady-state visual evoked potentials
PloS one, 10(10), 2015



Yong Jiao, Yu Zhang, Yu Wang, Bei Wang, Jing Jin, and Xingyu Wang

A novel multilayer correlation maximization model for improving CCA-based frequency recognition in SSVEP brain-computer interface
International journal of neural systems, 28(04):1750039, 2018



Fabien Lotte, Laurent Bougrain, Andrzej Cichocki, Maureen Clerc, Marco Congedo, Alain Rako-tomamonjy, and Florian Yger

A review of classification algorithms for EEG-based brain-computer interfaces: a 10 year update
Journal of neural engineering, 15(3):031005, 2018



Natalia Y Bilenko and Jack L Gallant.

Pyrcca: regularized kernel canonical correlation analysis in python and its applications to neuroimaging
Frontiers in neuroinformatics, 10:49, 2016

Vă mulțumesc pentru atenție!
