



Uporaba kepstralne analize za klasifikacijo EEG posnetkov

AVTOR: LUKA MATIČ

MENTOR: IZR. PROF. DR. PETER ROGELJ

JUNIJ 2026

Motivacija

- ▶ EEG omogoča neinvazivno spremljanje možganske aktivnosti
- ▶ Motor imagery je del Brain-Computer Interface (BCI) sistemov, vendar bi kepstralno analizo lahko uporabljali se na mnogo drugih področjih EEG analize
- ▶ Poznamo kompleksne EEG signale in vsebujejo različne frekvenčne komponente in šume
- ▶ Klasična spektralna analiza ne zazna vedno vseh značilnosti signalov
- ▶ Potrebujemo učinkovitejše metode ekstrakcije značilk
- ▶ Kepstralna analiza lahko razkrije dodatno strukturo spektra

Cilji in pristop

- ▶ Glavni cilj - primerjati spektralno in kepstralno analizo
- ▶ PRISTOP:
- ▶ Naloga: Analizirati EEG signale na javno dostopni bazi, ki vključuje posnetke pri opravljanju motoričnih nalog
- ▶ Izločiti spektralne in kepstralne značilke iz EEG signalov
- ▶ Izvesti klasifikacijo z uporabo SVM in LDA
- ▶ Primerjati spektralno in kepstralno analizo za klasifikacijo EEG posnetkov

Cepstral Coefficients Based Feature for Real Time Movement Imagery Classification

- ▶ Članek obravnava problem EEG motor imagery klasifikacije
- ▶ Uporablja podobne metode obdelave EEG signalov
- ▶ Članek poudarja pomembnost feature extraction metod za uspešnosti klasifikacije
- ▶ V naši analizi je realizirana po metodah predlaganih v članku

ZAKAJ KEPSTRALNA ANALIZA?

- ▶ Zazna dodatno strukturo znotraj spektra
- ▶ Bolje opiše obliko spektralne ovojnice
- ▶ Lahko razkrije informacije, ki jih FFT sam ne pokaže

Teoretične osnove


- ▶ EEG meri električno aktivnost možganov z elektrodami na lasišču
- ▶ Motor imagery pomeni možgansko aktivnost ob dejanskem ali namišljenem gibanju okončin
- ▶ Pomembna frekvenčna pasova:
 - ▶ α : 8–13 Hz
 - ▶ β : 13–30 Hz
- ▶ Tipične metode spektralne analize:
 - ▶ FFT metoda
 - ▶ Welch metoda
- ▶ Kepstralna analiza:
 - ▶ analiza spektra
 - ▶ Inverzni fourierov transform logaritma spektra – „Spekter spektra”

Podatkovni vir

- ▶ Uporabljen EEG Motor Movement/Imagery Dataset
- ▶ 109 oseb
- ▶ 64 EEG kanalov
- ▶ Vzorčna frekvenca: 160 Hz
- ▶ Eksperimenti:
 - ▶ Naloga 1: oči odprte/zaprte — posnetki: R01 (odprte) in R02 (zaprte)
 - ▶ Naloga 2: motor imagery — razlikovanje med mirovanjem (dogodek T0) in gibanjem: T1 (leva roka), T2 (desna roka)
 - ▶ Posnetki: R03, R04, R07, R08, R11, R12 (6 posnetkov/subjekt)
- ▶ V analizo so vključeni kanali: C3, Cz, C4, (Cp1, Cp2)

Postopek analize

- ▶ Uvoz EEG podatkov
- ▶ Predobdelava signalov
- ▶ Filtriranje signalov
- ▶ Izpeljava značilk
 - ▶ Spektralne značilke
 - ▶ Kepstralne značilke
- ▶ Priprava učnih/testnih podatkov
- ▶ Učenje SVM in LDA modela
- ▶ Izbira značilk z MRMR (iz učne množice)
- ▶ Uspešnost modelov ocenimo s 5-kratno prečno validacijo (5-fold CV)
- ▶ Uspešnosti ocenjujemo s točnostjo razvrščanja



Metode dela

► Detajli (obe nalogi):

- epohe 4 s za EO/EC in 2s za MI
- Welch PSD + filterbank kepstrum
- Spectralne značilke: FFT
- Kepstralne značilke (koraki):
 - Welch (8–30 Hz),
 - logaritem ocenjene spektralne gostote moči,
 - DCT (Discrete Cosine Transform),
 - Cepst coefficient,
 - MVGPDF (Multivariate Gaussian Probability Density Function)
- MRMR selekcija top 20 značilke znotraj vsakega folda | 5-fold CV stratificiran | ANOVA
- Klasifikatorja: SVM (linearno jedro, BoxConstraint = 1) in LDA (linearni)





Fig. 2. Proposed Methodology



Rezultati



Rezultati

- ▶ **Naloga 1: Oči odprte vs. zaprte — povprečna testna točnost (5-fold CV):**
 - ▶ SVM-Spec: 67.19 % $\pm$ 1.53 % | LDA-Spec: 65.23 % $\pm$ 2.69 %
 - ▶ SVM-Ceps: 69.08 % $\pm$ 0.92 % | LDA-Ceps: 69.11 % $\pm$ 0.97 %
 - ▶ ANOVA: SVM $p = 0.045$ (Δ 1.90 %), LDA $p = 0.016$ (Δ 3.88 %) — kepsralne stat. značilno boljše
- ▶ **Naloga 2: T0 vs. T1+T2 (motor imagery) — povprečna testna točnost (5-fold CV):**
 - ▶ SVM-Spec: 52.31 % $\pm$ 0.50 % | LDA-Spec: 52.80 % $\pm$ 0.62 %
 - ▶ SVM-Ceps: 55.22 % $\pm$ 1.43 % | LDA-Ceps: 55.24 % $\pm$ 1.47 %
 - ▶ ANOVA: SVM $p = 0.003$ (Δ 2.92 %), LDA $p = 0.009$ (Δ 2.43 %) — kepsralne stat. značilno boljše
- ▶ **Skupni sklep:**
 - ▶ Kepsralne značilke konsistentno boljše pri obeh nalogah in klasifikatorjih;
 - ▶ motor imagery bistveno težji problem (~52–55 % vs. ~67–69 %)

Rezultati



Težave

- ▶ EEG signali vsebujejo veliko šuma
- ▶ Velika biološka variabilnost med subjekti
- ▶ Majhne razlike med razredi (Razlike niso tako velike)
- ▶ Overfitting pri učnem modelu (Učna množica nezadostno opiše variabilnost med osebami)
- ▶ Točnost ostaja relativno nizka (oči: ~67–69 %) medtem ko motor imagery: (~52–55 % — blizu praga naključnega ugibanja)

Ugotovitve

- ▶ Spektralne značilke zajamejo osnovno frekvenčno energijo
- ▶ Kepstralne značilnice zajamejo dodatne informacije o spektru
- ▶ Razlike med subjekti močno vplivajo na klasifikacijo
- ▶ Sklepamo da generalni model težko postavi mejo in deluje za vse subjekte
- ▶ Oči open/closed — ANOVA: SVM $p = 0.045$ ($\Delta 1.90\%$), LDA $p = 0.016$ ($\Delta 3.88\%$) — kepstralne stat značilno boljše
- ▶ Motor imagery — ANOVA: SVM $p = 0.003$ ($\Delta 2.92\%$), LDA $p = 0.009$ ($\Delta 2.43\%$) — kepstralne stat. značilno boljše
- ▶ Kepstralne značilke konsistentno boljše pri obeh nalogah — motor imagery bistveno težji problem ($\sim 52\text{--}55\%$ vs. $\sim 67\text{--}69\%$)

Smernice za nadaljno delo

- ▶ Preizkus na klasifikaciji znotraj oseb (ang. intrasubject) – močno variranje med subjekti
- ▶ Pregled vpliva različnih elektrod – zmanjšanje odvečnosti med značilkami (zajeli širši prostorski vzorec)
- ▶ Integracija kepstralne analize v druge pristope analiz (analiza povezljivosti) – vpliv ene elektrode na drugo

Zaključek

- ▶ Kepstralna metoda je učinkovitejša od spektralne
- ▶ Globja poglobitev v kepstralno analizo je smiselna
- ▶ Ugotovili smo EEG klasifikacija je zahteven problem
- ▶ Spektralna analiza poda osnovne frekvenčne informacije
- ▶ Kepstralna analiza omogoča dodatni vpogled v strukturo spektra
- ▶ Variabilnost med subjekti predstavlja velik izziv
- ▶ Izbira značilk močno vpliva na uspešnost klasifikacije
- ▶ Nadaljnje izboljšave so možne z naprednejšimi metodami

Hvala za pozornost

- ▶ Kakšno vprašanje?

VIR IN LITERATURA

- ▶ <https://www.enggjournals.com/ijet/docs/IJET16-08-01-008.pdf>
- ▶ https://ch.mathworks.com/help/matlab-copilot/index.html?s_tid=hc_panel
- ▶ <https://ch.mathworks.com/help/stats/support-vector-machine-classification.html>
- ▶ <https://www.youtube.com/watch?v=EAQcu6DLAS0>