



KLASIFIKACIJE IN VMR S STROJNIM UČENJEM

- Faze procesiranja signalov EEG med interakcijo možgani računalnik
- Vrste topografskih distribucij
- Ujemanje vrednosti značilk z napovedmi stanj
- Ujemanje vrednosti signalov z napovedmi stanj
- Ujemanje vrednosti spektrov z napovedmi stanj
- Izbor značilk na osnovi map R^2
- Diagram raztrosa in operatorji var , \log in Log
- Faze procesiranja signalov EEG med interakcijo možgani računalnik
- Tipične arhitekture VMR
- Nadzorovana faza učenja z uporabo SPV

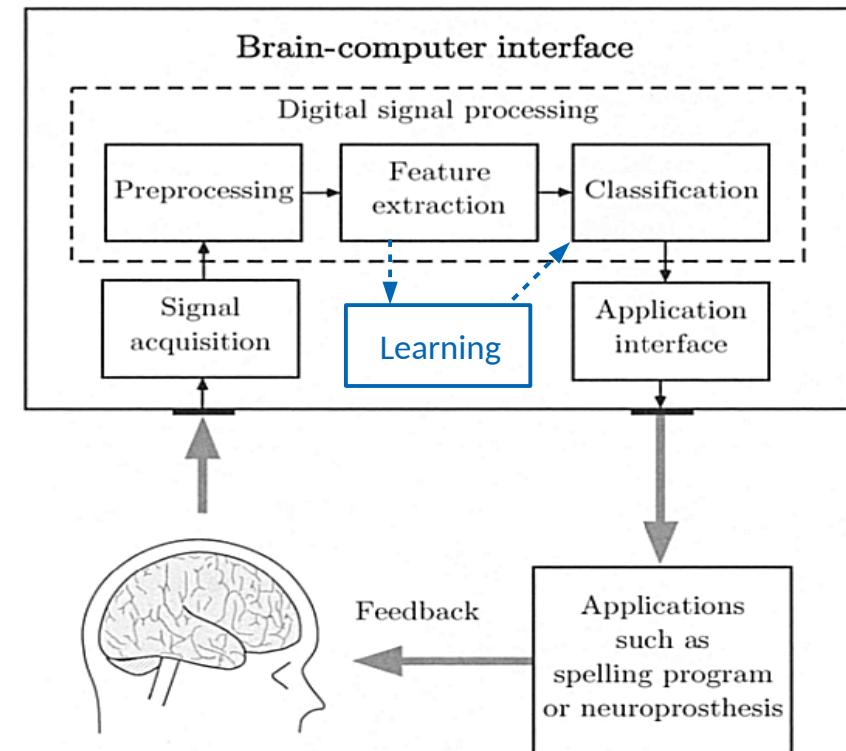


KLASIFIKACIJE IN VMR S STROJNIM UČENJEM

- Spektralni filtri, segmentacija in Skupni Prostorski Vzorci – SPV (CSP)
- Faza delovanja z uporabo SPV
- Klasifikacija
- Strategije in metode za izbor relevantnih značilk
- Studentov t -test
- Klasifikatorji
- Linearna diskriminantna analiza
- Metrike zmogljivosti
- Vrednotenje zmogljivosti
- Sekvenčna izbira značilk v smeri naprej
- Histogramska metoda s kopiranjem značilk
- Vrednotenje zmogljivosti
- (Dodatni materiali)

Faze procesiranja signalov EEG med interakcijo možgani računalnik

- **Zajemanje signalov:** EEG signali so dobljeni z možganov z uporabo invazivnih ali neinvazivnih metod (preko elektrod), signali so ojačeni in vzorčeni
- **Predobdelava:** čiščenje signalov (še posebno artefakti vsled utripanja oči) in filtriranje signalov
- **Izločanje značilk:** **prostorske, časovne, časovno prostorske značilke in značilke za ocenjevanje močnostnih spekrov**
- **Klasifikacija:** signali se procesirajo in klasificirajo z namenom ugotovitve katero vrsto mentalne naloge je subjekt opravljal
- **Interakcija z računalnikom** (vmesnik aplikacije, aplikacija): algoritem uporablja klasificirane signale za upravljanje določene aplikacije



Vrste topografskih distribucij

• Topografske distribucije

- EEG signalov, X , \tilde{X}



- ANK komponent, $Y = W \cdot X$

(ANK, ICA) $S \approx W \cdot X$

a) ANK filtrov, vrstice v W

b) neodvisnih ANK

komponent, kolone v W^{-1}



- SPV komponent, $S = W \cdot X$

(SPV, CSP) $X = W^{-1} \cdot S$

a) SPV filtrov, vrstice v W

b) SPV vzorcev, kolone v W^{-1}

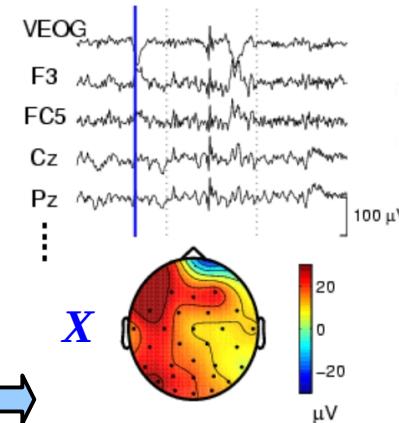
* korelacijskega koeficiente

(r)

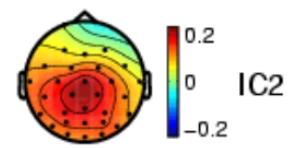
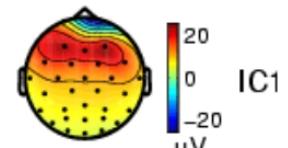
* koeficiente določenosti

$(R^2$ ali $r^2)$

X EEG signali

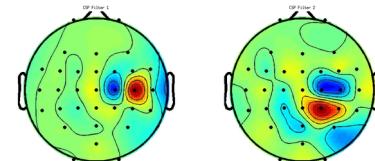


Neodvisne komponente

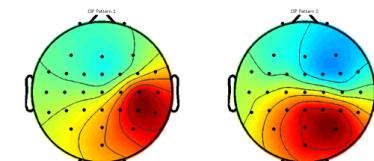


$$W^{-1}$$
$$\tilde{X} = \tilde{W}^{-1} \cdot \tilde{Y}$$

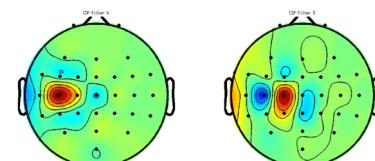
SPV filtri



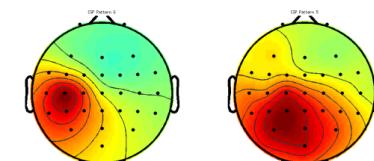
SPV vzorci



W



W^{-1}

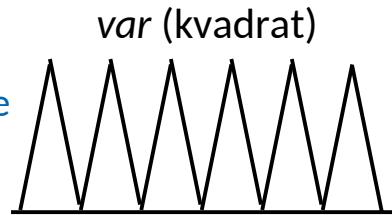


Ujemanje **vrednosti značilk** z **napovedmi stanj**

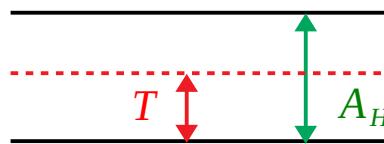
EEG signal (C4), a) ni zamišljanja aktivnosti leve roke, ali b)
zamišljanje aktivnosti desne roke



EEG signal (C4), zamišljanje aktivnosti leve roke



Glajenje, Avg (envelopa)

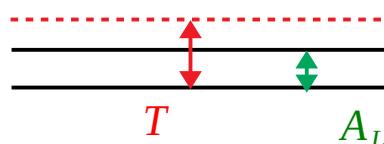


$$x = A_H \\ y = +1$$

Avg(var(.))

T - prag

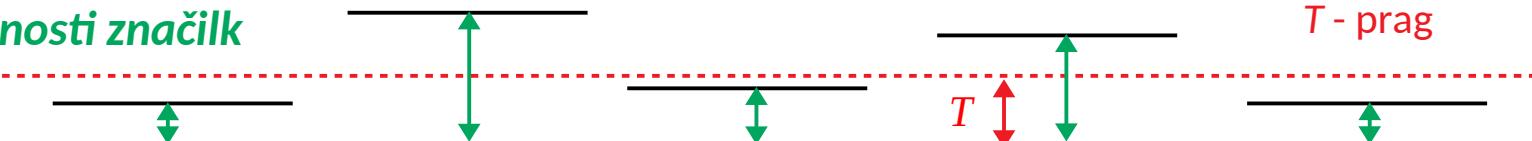
Glajenje, Avg (envelopa)



$$x = A_L \\ y = -1$$

Vrednosti značilk

Avg(var(.))



$$x_i = A_i$$

$$x_{i+1} = A_{i+1}$$

$$x_{i+2} = A_{i+2}$$

$$x_{i+3} = A_{i+3}$$

$$x_{i+4} = A_{i+4}$$

$$y_i = -1$$

$$y_{i+1} = +1$$

$$y_{i+2} = -1$$

$$y_{i+3} = +1$$

$$y_{i+4} = -1$$

Napovedi stanj

	Stanje 2 (+1)	+1	Stanje 2 (+1)	+1
Stanje 1 (-1)	-1	Stanje 1 (-1)	-1	Stanje 1 (-1)

Ujemanje *vrednosti značilk* z *napovedmi stanj*

- Vrednosti značilk kot amplitude močnostnih spekrov (npr. 8-13 Hz, μ ritem) signala C4

Zamišljanje aktivnosti leve roke
(Stanje 1 (-1))

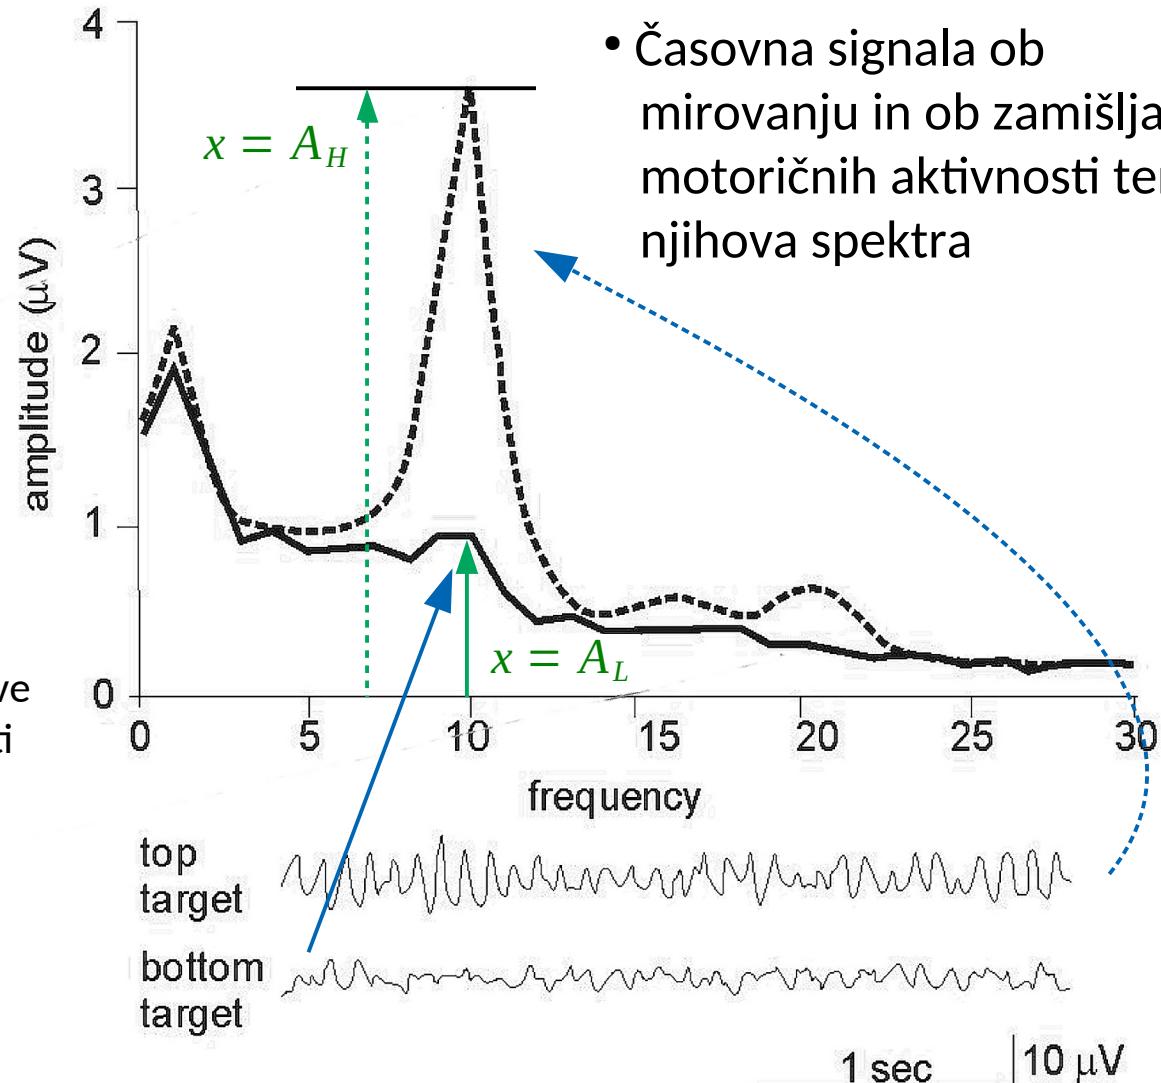
$$x_i = A_{L,i} \rightarrow y_i = -1$$

a) Ni zamišljanja aktivnosti leve Roke, ali b) zamišljanje aktivnosti desne roke

(Stanje 2, (+1))

$$x_i = A_{H,i} \rightarrow y_i = +1$$

- Časovna signal ob mirovanju in ob zamišljanju motoričnih aktivnosti ter njihova spektra



Ujemanje **vrednosti značilk** z **napovedmi stanj**

- **Linearni koreacijski koeficient (r)**

- Poda mero o tem kako močno se razlikujeta srednji vrednosti dveh distribucij v relaciji s **standardno deviacijo**
- Izračunava se vzdolž signalov (ali znotraj spektrov), ki so bili merjeni v dveh različnih stanjih glede na dve mentalni (zamišljani) nalogi
- Predstavlja frakcijo celotne **standardne deviacije** signala kot je ta določena s stanji danih nalog
- Predznaki meritev in predznaki stanj naj bodo konsistentni

$$r = \frac{Cov(\textcolor{green}{X}, \textcolor{blue}{Y})}{StDev(\textcolor{green}{X}) StDev(\textcolor{blue}{Y})} = \frac{\frac{1}{N} \sum_i (\textcolor{green}{x}_i - \bar{x})(\textcolor{blue}{y}_i - \bar{y})}{\sqrt{\frac{1}{N} \sum_i (\textcolor{green}{x}_i - \bar{x})^2} \sqrt{\frac{1}{N} \sum_i (\textcolor{blue}{y}_i - \bar{y})^2}}$$

Ujemanje **vrednosti značilk** z **napovedmi stanj**

- **Kvadrat korelacijskega koeficiente (R^2 ali r^2)**
 - poda mero o tem kako močno se razlikujeta kvadrata srednjih vrednosti dveh distribucij v relaciji z **varianco**
 - izračunava se vzdolž signalov (ali znotraj spektrov), ki so bili merjeni v dveh različnih stanjih glede na dve mentalni (zamišljani) nalogi
 - predstavlja frakcijo celotne *variance* signala kot je ta določena s stanji danih nalog
 - **je mera o tem, kako dobro se da sklepati na stanje mentalne naloge preko merjenih signalov**

$$R^2 = r^2 = \frac{Cov(\textcolor{green}{X}, \textcolor{blue}{Y})^2}{Var(\textcolor{green}{X})Var(\textcolor{blue}{Y})} = \frac{\left(\frac{1}{N} \sum_i (\textcolor{green}{x}_i - \bar{x})(\textcolor{blue}{y}_i - \bar{y}) \right)^2}{\frac{1}{N} \sum_i (\textcolor{green}{x}_i - \bar{x})^2 \frac{1}{N} \sum_i (\textcolor{blue}{y}_i - \bar{y})^2}$$

Ujemanje **vrednosti značilk** z **napovedmi stanj**

- **Koeficient določenosti** (R^2 ali r^2) (ob naslednjih predpostavki:)

- Naj je N_1 in N_2 število meritev $x_i^{(1)}$ in $x_i^{(2)}$ pri stanjih 1 in 2

(zamišljanje aktivnosti leve (razred 1) in desne (razred 2) roke)

- Konstruira se ena dvodimensionalna sekvenca točk (x_i, y_i) ,

kjer je $y_i = -1$ ali $y_i = +1$, če je x_i merjen pri stanju 1 ali 2

$$\rightarrow N = N_1 = N_2 \quad s_k = \sum_i x_i^{(k)} \quad q_k = \sum_i x_i^{2(k)}$$

$$Cov(X, Y) = \frac{s_1 - s_2}{2N} \quad Var(X) = \frac{q_1 + q_2}{2N} - \frac{(s_1 + s_2)^2}{4N^2} \quad Var(Y) = 1$$

$$R^2 = r^2 = \frac{Cov(X, Y)^2}{Var(X)Var(Y)} = \frac{(s_1 - s_2)^2}{2N(q_1 + q_2) - (s_1 + s_2)^2} = \frac{\frac{s_1^2}{N} + \frac{s_2^2}{N} - G}{q_1 + q_2 - G} \quad G = \frac{(s_1 + s_2)^2}{2N}$$



Ujemanje vrednosti signalov z napovedmi stanj

- Črkovanje

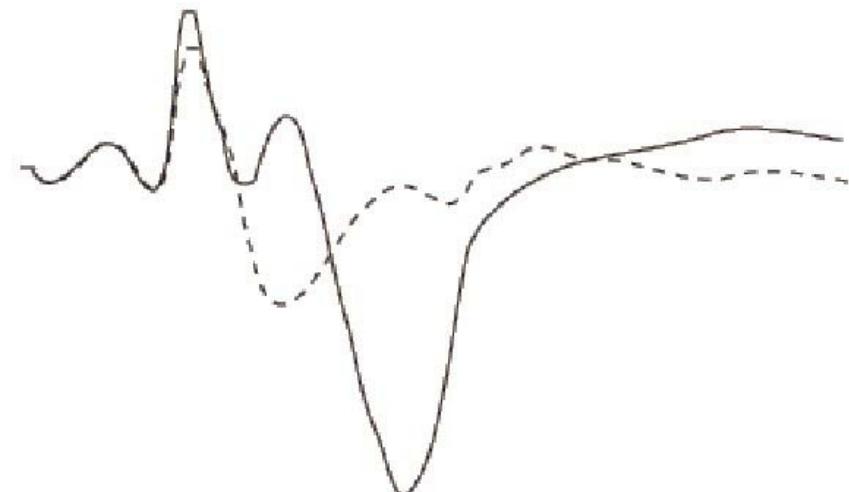


P300 Speller

Ujemanje vrednosti signalov z napovedmi stanj

- **Izzvani potenciali** P3 (val z vrhom približno 300ms za stimulusom povezanim z dano nalogo (P300)
 - **Zvezno:** splošna oblika komponente P3 izvanega potenciala (Evoked Potential – EP), P3 je kognitivni izvani potencial, ki se pojavi približno 300 ms za stimulusom povezanim z dano nalogo (najnižji negativni vrh)
 - **Črtkano:** splošna oblika odziva na stimulus, ki ni povezan z dano nalogo

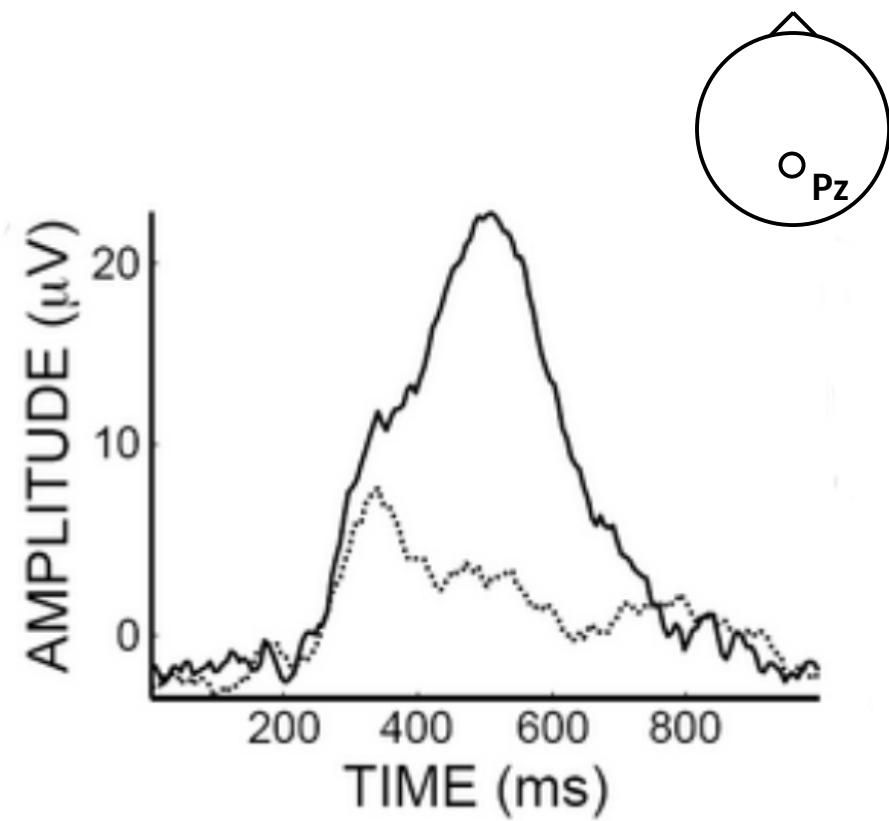
A	B	C	D	E	F
G	H	I	J	K	L
M	N	O	P	Q	R
S	T	U	V	W	X
Y	Z	1	2	3	4
5	6	7	8	9	_



Ujemanje vrednosti signalov z napovedmi stanj

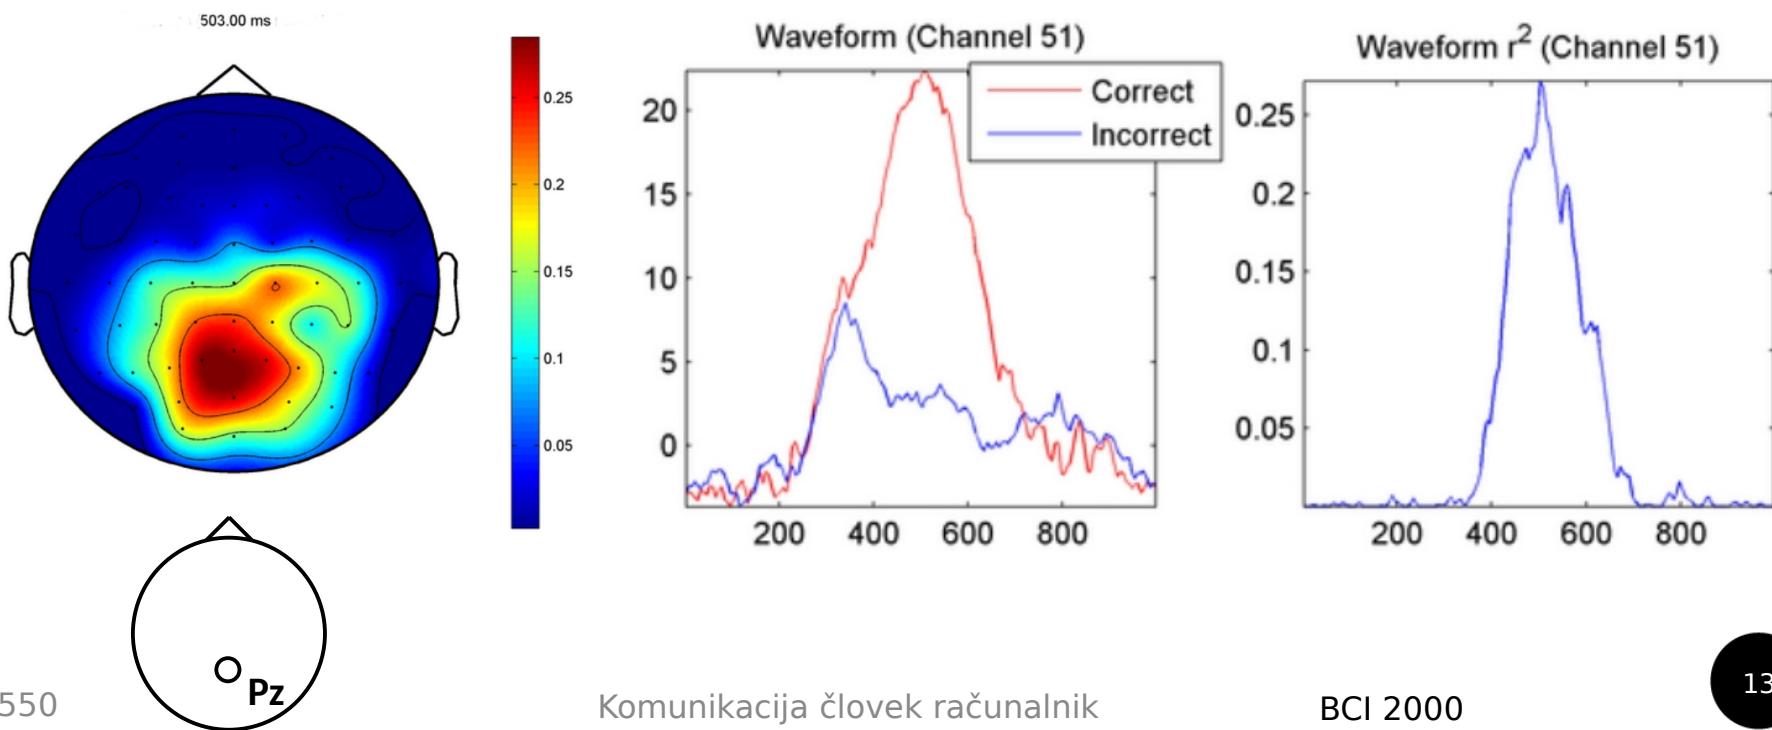
- Črkovanje, izvani potenciali P300, povprečna odziva signalov za kanal Pz

A	B	C	D	E	F
G	H	I	J	K	L
M	N	O	P	Q	R
S	T	U	V	W	X
Y	Z	1	2	3	4
5	6	7	8	9	-



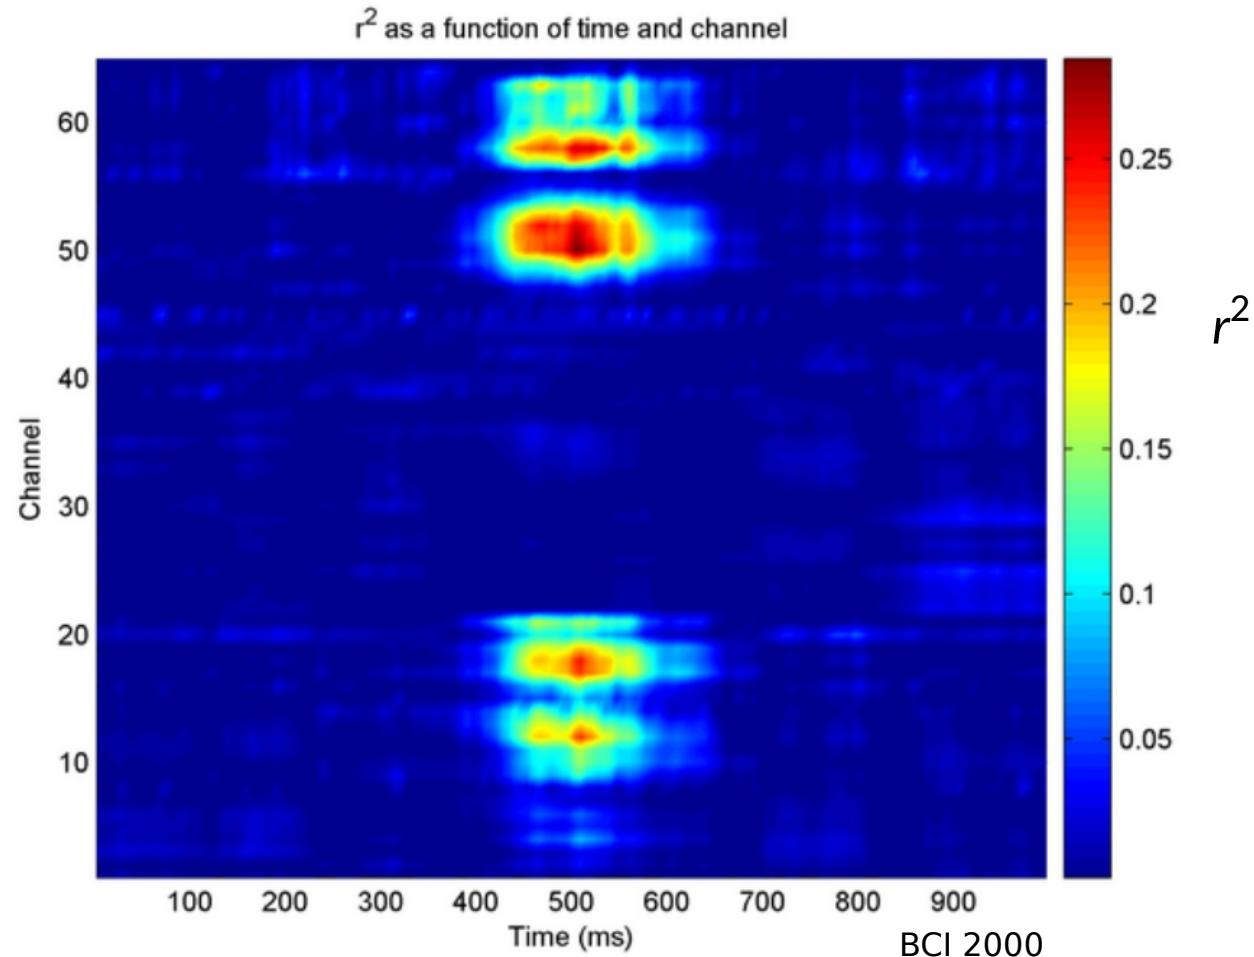
Ujemanje vrednosti signalov z napovedmi stanj

- Črkovanje, izvani potenciali P300, **topografska distribucija r^2** pri **503 ms**, kanal 51 - elektroda Pz (**amplituda signala [uV]**, čas [ms]), r^2 za kanal 51 (r^2 , čas [ms])



Ujemanje vrednosti signalov z napovedmi stanj

- Črkovanje, izvani potenciali P300, **distribucija r^2 (kanal – amplituda signala, čas)**

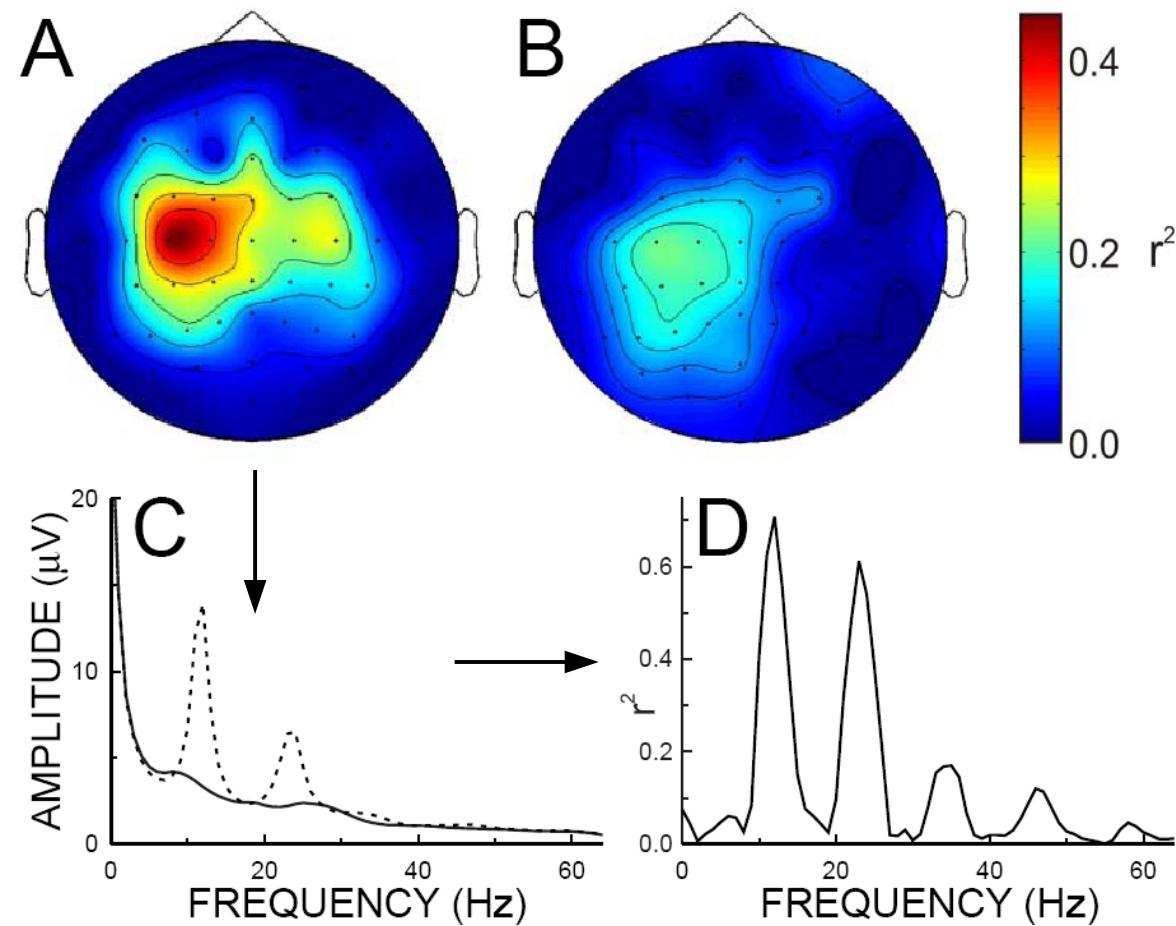


Ujemanje vrednosti spektrov z napovedmi stanj

A, B: Topografske distribucije razlik (v smislu r^2) izračunane za dejanske (A) in zamišljane (B) aktivnosti desne strani proti mirovanju za frekvenčni pas 3 Hz centriran pri 12 Hz

C: Povprečni spekter signala za dani subjekt preko elektrode C3 za primerjavo mirovanja (črtkana linija) in dejanske aktivnosti (zvezna linija) desne strani

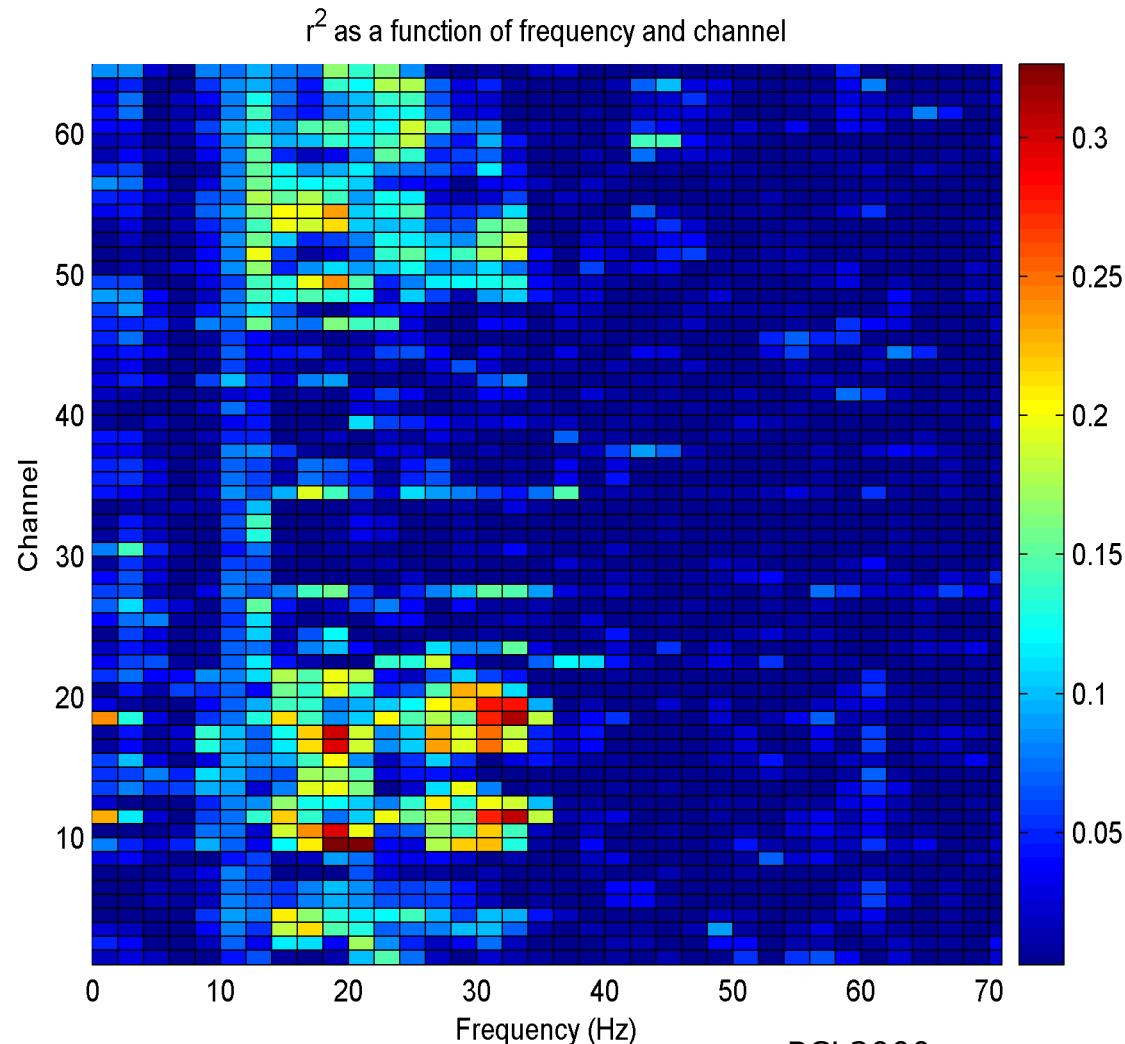
D: Pripadajoči spekter r^2 za modulacijo signala (alfa in beta frekvenčni področji vsebujejo aktivnost mi ritma)



Izbor značilk na osnovi map R^2

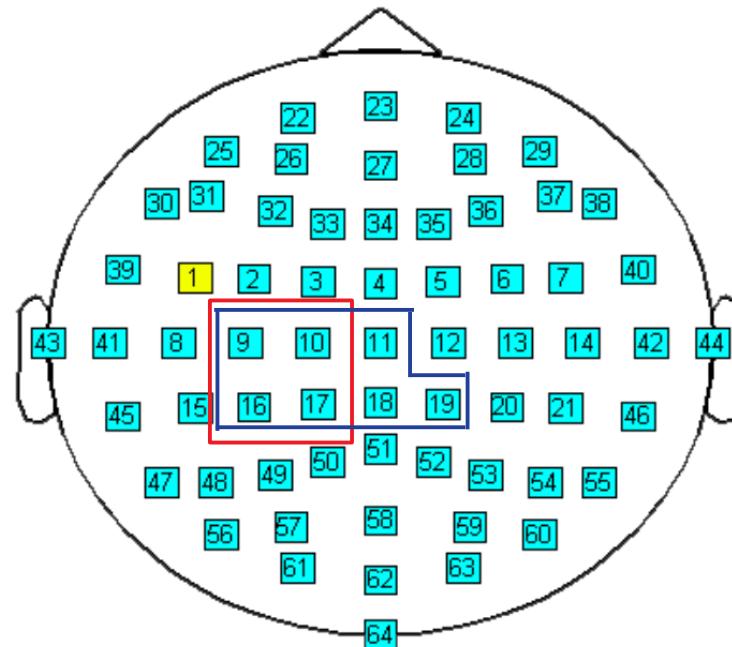
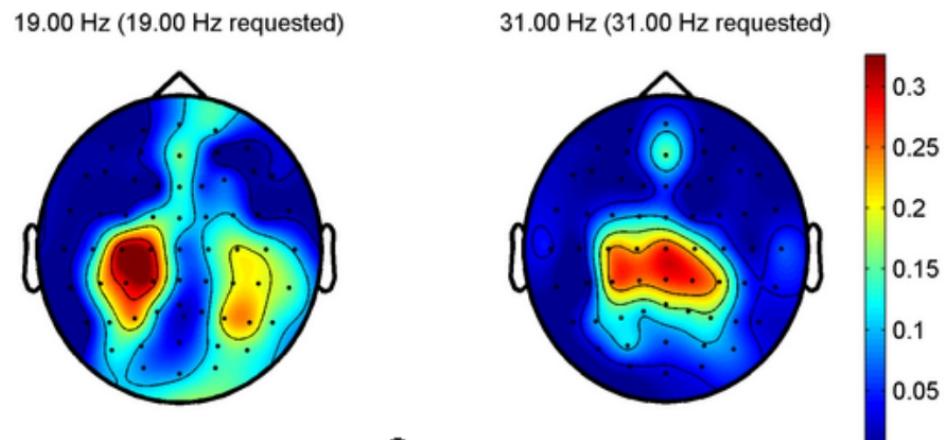
- Zamišljanje premikov nog
- Mape značilk na osnovi R^2 (kanal - amplitudni spekter, frekvenca)

- Podatki so razdeljeni na amplitude pri individualnih frekvencah in lokacijah
- Te amplitude bodo značilke
- Poišči tiste značilke, katerih vrednosti se najbolj razlikujejo med dvema stanjema, to je, določi tiste frekvence in lokacije, katerih amplitude so maksimalno korelirane z nalogo subjekta v smislu r^2
- Vrednosti r^2 zagotavljajo mero za količino do katere je dana značilka modulirana z nalogo subjekta



Izbor značilk na osnovi map R^2

- Zamišljanje premikov nog
- 19 Hz (kanali: 9, 10, 16, 17; elektrode: C3, C1, CP3, CP1)
- 31 Hz (kanali: 9, 10, 16, 17, 11, 18, 19; elektrode: C3, C1, CP3, CP1, CZ, Cpz, CP2)



Brain-Computer Interfaces Handbook,
Technological and Theoretical Advances,
2018, C S Nam, A Nijholt, F Lotte

Diagram raztrosa in operatorji var , \log in Log

a) Signala C3 in C4 (zamišljanje aktivnosti desne in leve roke)

b) Diagram raztrosa (vzorci signalov C3 in C4 ob zamišljanju aktivnosti leve roke, vzorci signalov C3 in C4 ob zamišljanju aktivnosti desne roke)

c) Diagram raztrosa po uporabi operatorja var (varianca)

d) Diagram raztrosa po uporabi operatoja \log

e) $+$, $+$

$$\text{Avg}(\log(\text{var}(X)))$$

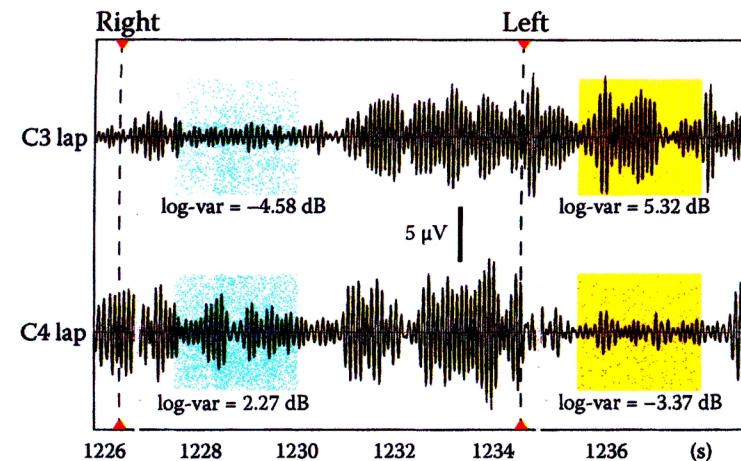
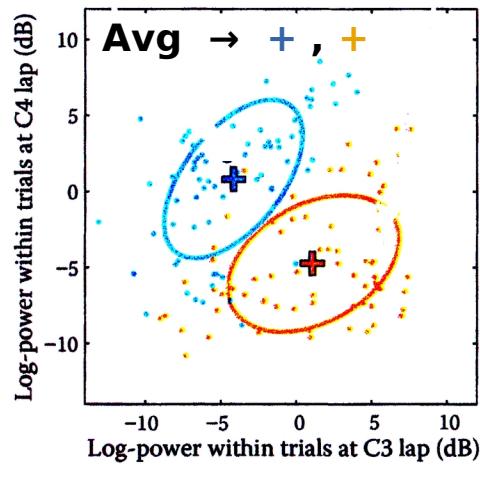
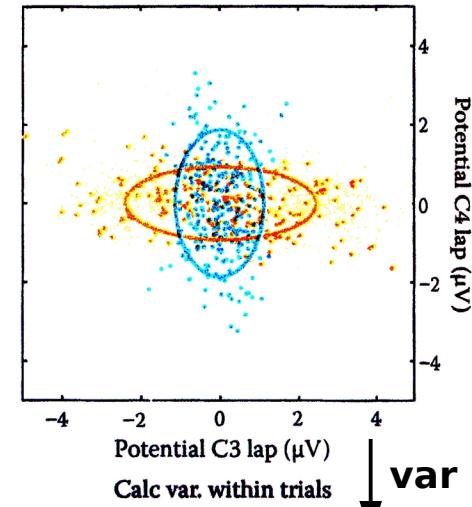
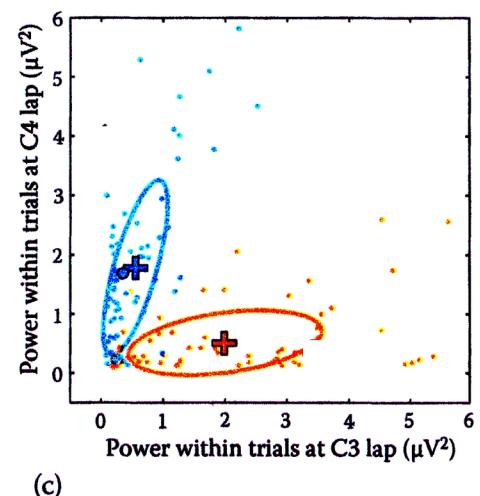


Diagram raztrosa



\log
Take the logarithm

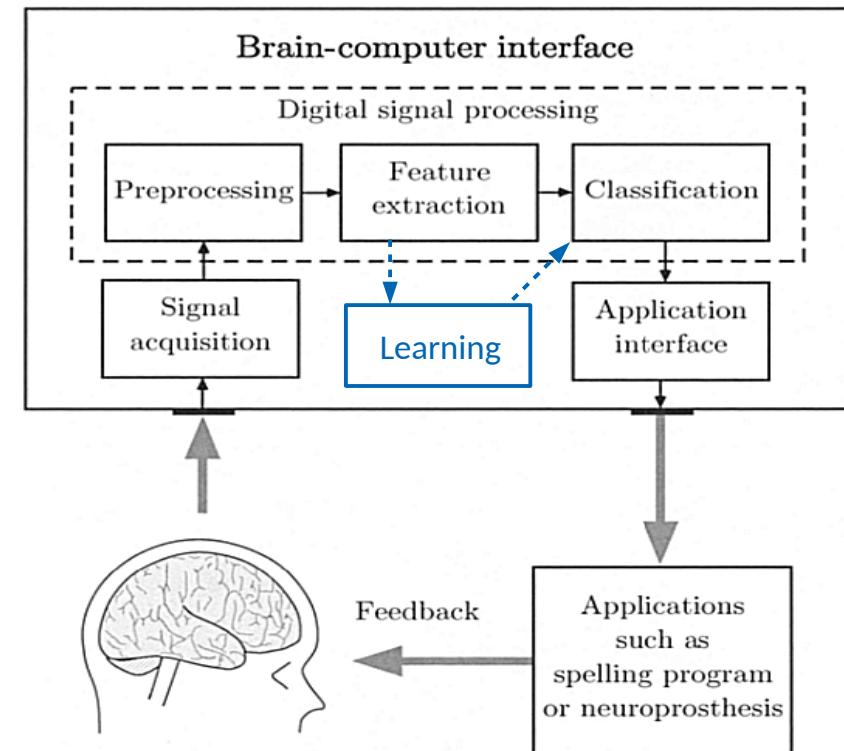


(c)

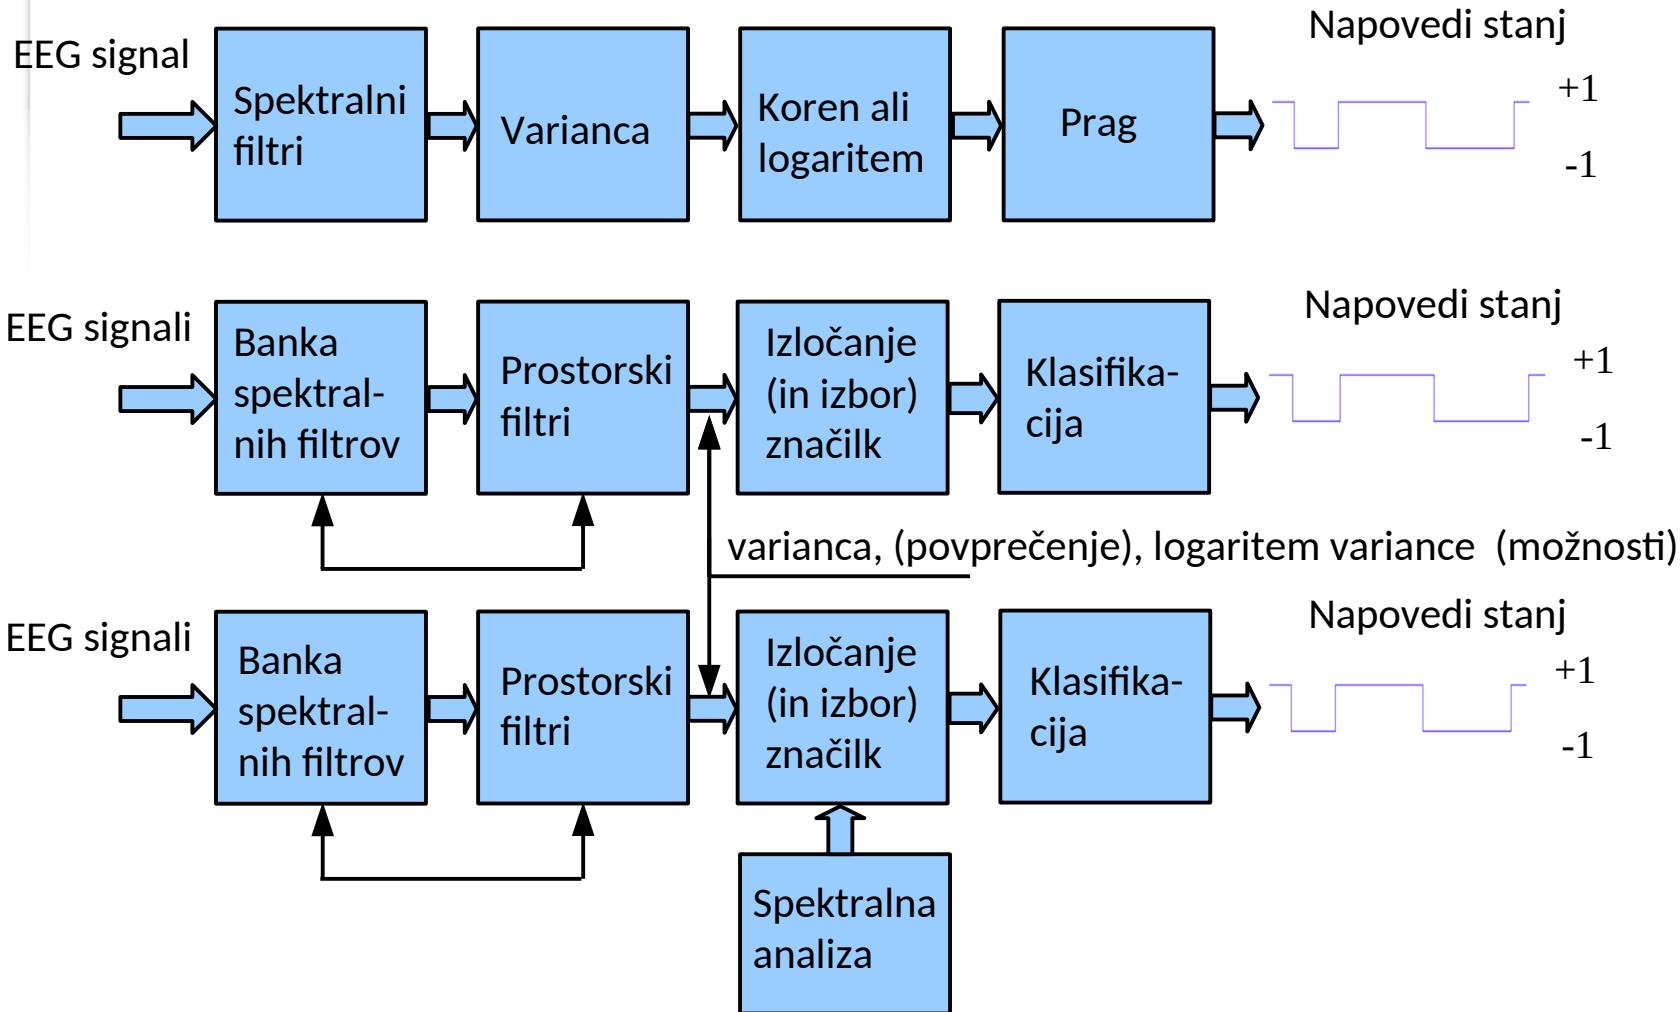
(d)

Faze procesiranja signalov EEG med interakcijo možgani računalnik

- **Zajemanje signalov:** EEG signali so dobljeni z možganov z uporabo invazivnih ali neinvazivnih metod (preko elektrod), signali so ojačeni in vzorčeni
- **Predobdelava:** čiščenje signalov (še posebno artefakti vsled utripanja oči) in filtriranje signalov
- **Izločanje značilk:** prostorske, časovne, časovno prostorske značilke in značilke za ocenjevanje močnostnih spektrov
- **Klasifikacija:** **signali se procesirajo in klasificirajo z namenom ugotovitve katero vrsto mentalne naloge je subjekt opravljal**
- **Interakcija z računalnikom** (vmesnik aplikacije, aplikacija): algoritem uporablja klasificirane signale za upravljanje določene aplikacije

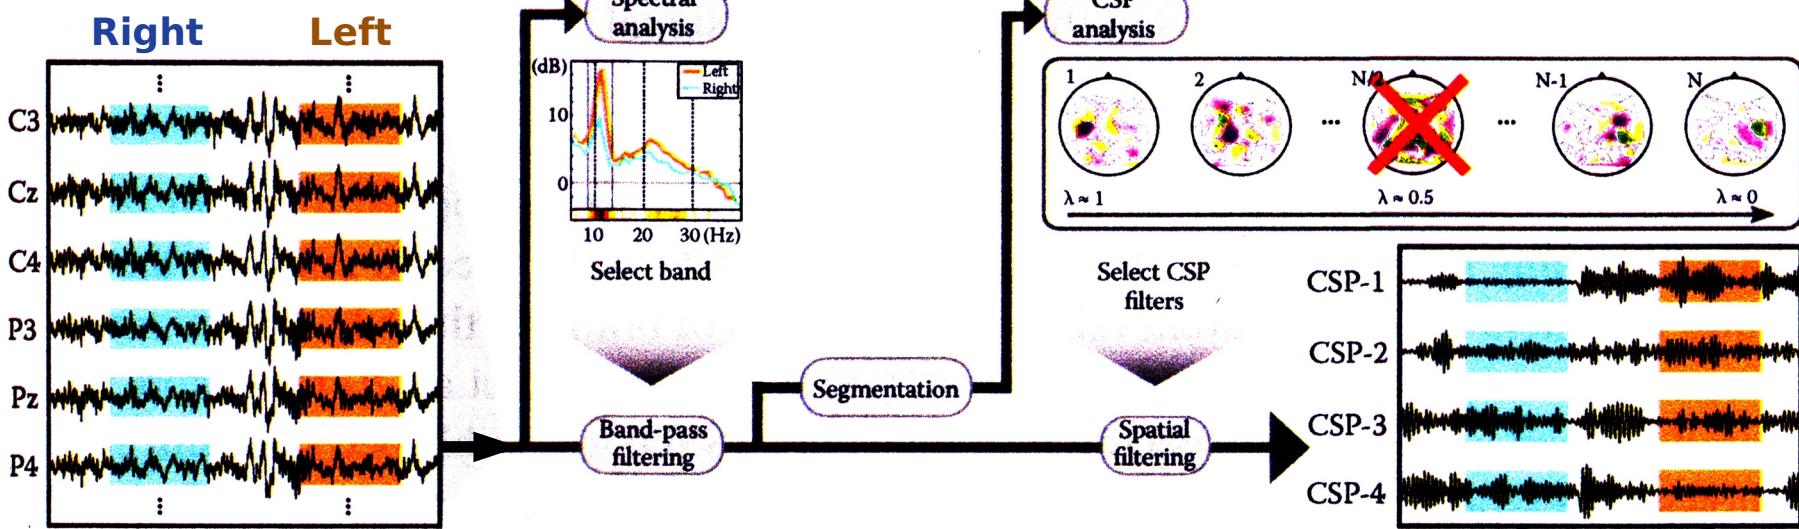


Tipične arhitekture VMR

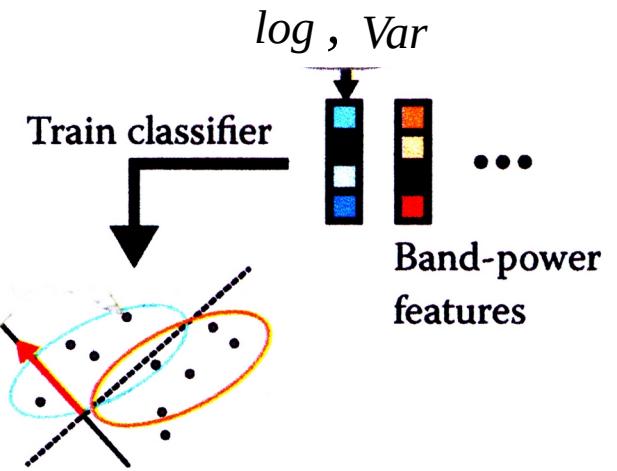


Nadzorovana faza učenja z uporabo SPV

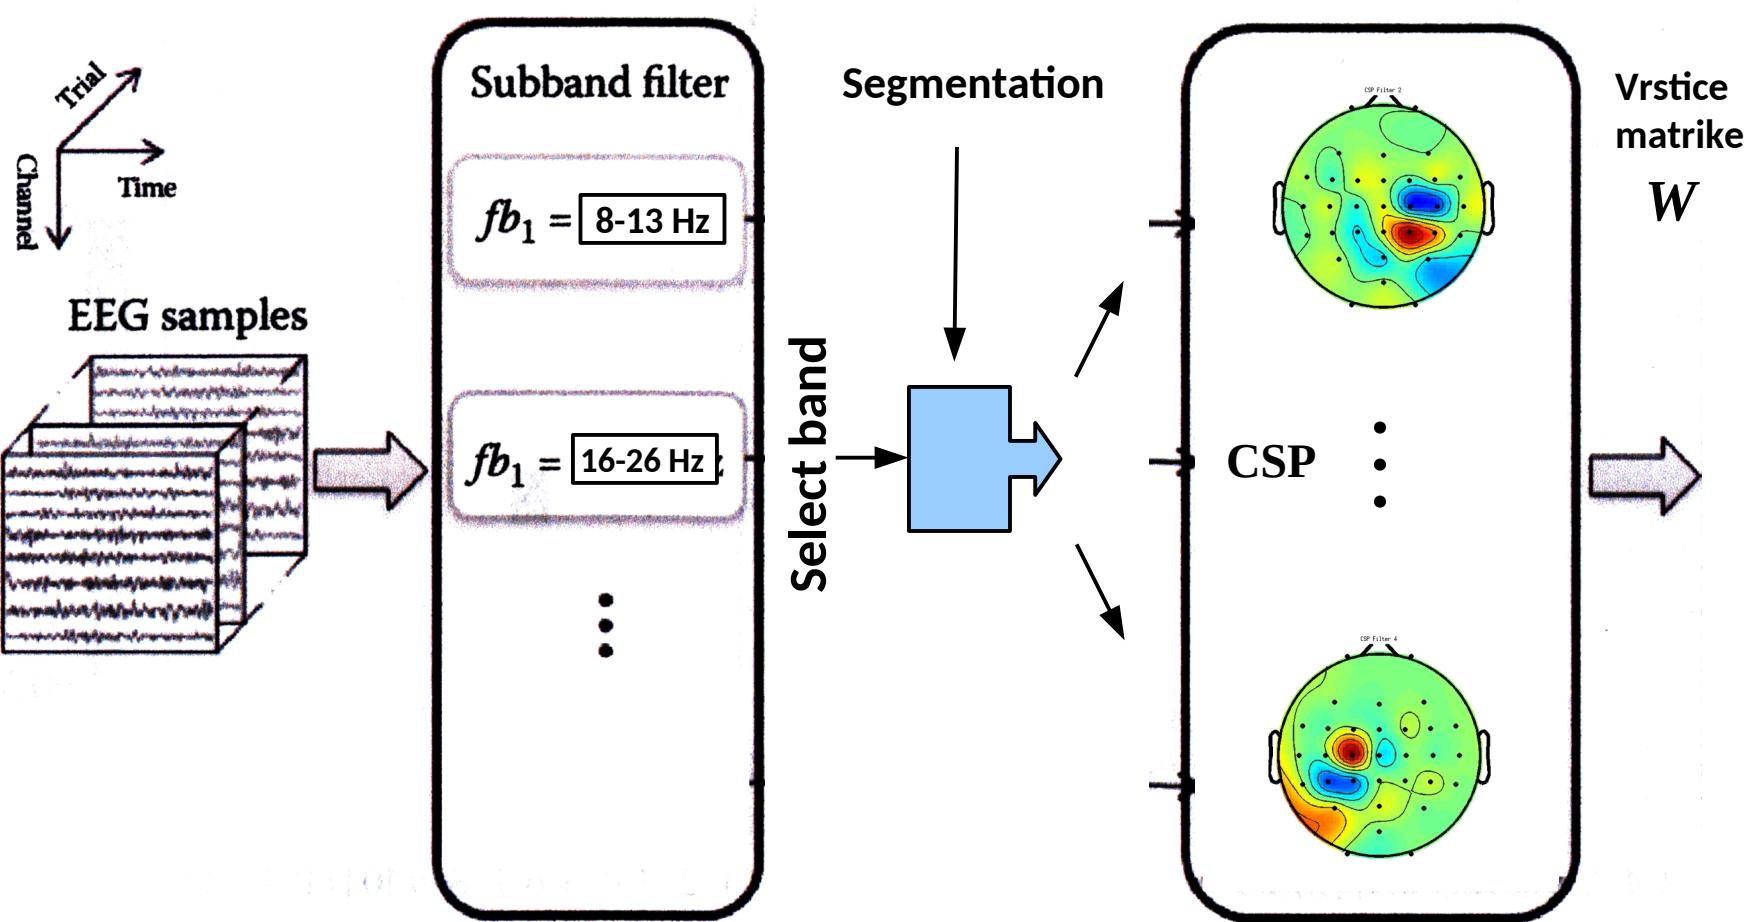
Calibration of CSP:



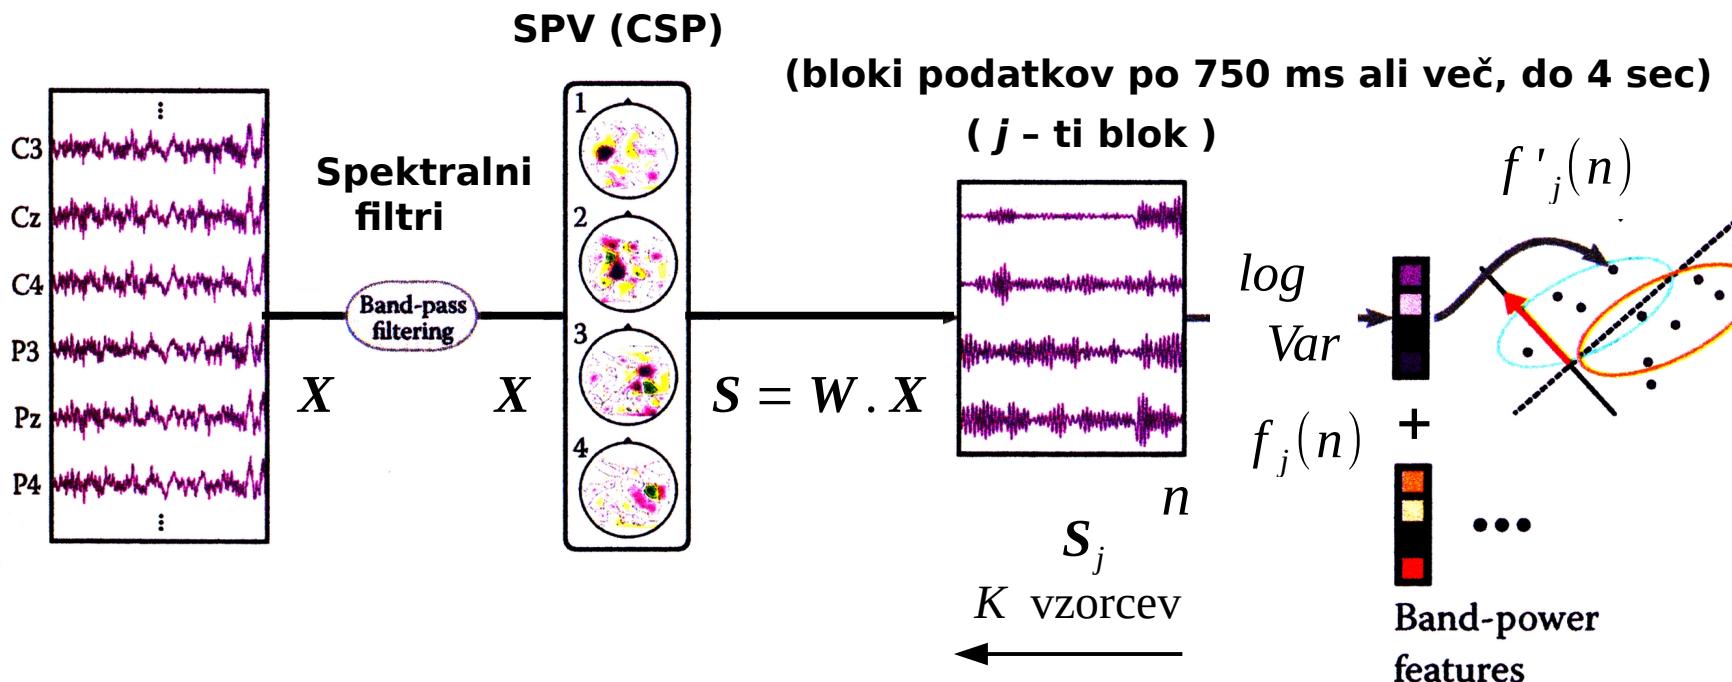
- SPV – Skupni Prostorski Vzorci
- Spektralna analiza
- Pasovni spektralni filtri
- Segmentacija (izbira intervalov)
- Izračun in izbor SPV (CSP) filtrov
- Prostorsko filtriranje s SPV filtri
- $f(n) = \log(\text{Var}(W.X)) = \log(\text{Avg}(\text{var}(W.X)))$



Spektralni filtri, segmentacija in Skupni Prostorski Vzorci – SPV (CSP)



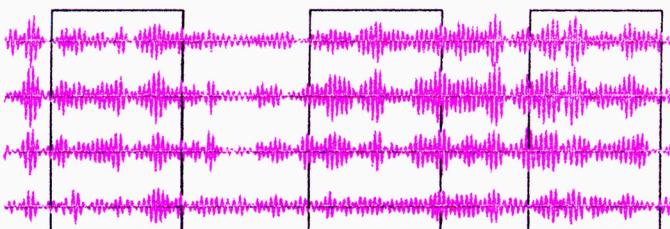
Faza delovanja z uporabo SPV



Klasifikacija

Calibration: continuous data

(markers provide information on mental states)



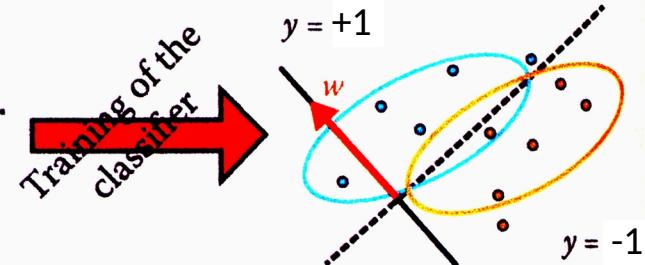
Feature extraction

Feature vectors: training data

$$\begin{array}{c} x_1 \quad x_2 \quad x_3 \\ \vdots \\ \varepsilon_1 \quad \varepsilon_2 \quad \varepsilon_3 \end{array}$$

$y_1 = -1$
 $y_2 = -1$
 $y_3 = -1$
 $y_4 = +1$

Feature space:



Training of the classifier

Feedback application: continuous data

(estimate mental state of most recent window)



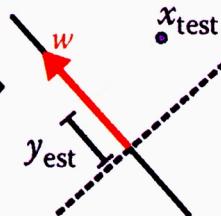
Feature extraction

'test' data

$$x_{\text{test}} = ?$$

Applying the classifier

$$y = \text{sign}(x^T w - b)$$





Strategije in metode za izbor relevantnih značilk

- Osnovni namen konstrukcije vektorjev značilk je redukcija velikega števila vhodnih podatkov
- Uporaba vseh značilk, ki so na razpolago za klasifikacijo ima lahko negativen učinek na zmogljivost klasifikacije
 - obstojajo korelации med značilkami
 - lahko pride do previsoke prilagoditve klasifikatorja učni množici (overfitting)
- Čeprav ima celotna množica značilk razložljivo vlogo (ali fiziološko interpretacijo) in pomen, je včasih nujna redukcija števila značilk z uporabo neke **strategije ali metode** iskanja značilk
 - v izogib previsoke prilagoditve klasifikatorja učni množici
 - za poenostavitev klasifikatorja
 - za izboljšano klasifikacijsko točnost



Strategije in metode za izbor relevantnih značilk

- Kategorije izbiranja značilk

- 1) **Izbor značilk je na nek način že vgrajen v predobdelavo signalov**

- Analiza Neodvisnih Komponent (ANK) - dekompozicija signalov v statistično neodvisne komponente
- Analiza s Principalnimi Komponentami (APK) - dekompozicijo signalov v nekorelirane komponente z maksimalno varianco
- Skupni Prostorski Vzorci (SPV) - maksimizacija variance signalov enega stanja in simultana minimizacija variance signalov drugega stanja

- 2) **Izbor značilk na osnovi njihove individualne zmogljivosti klasifikacije**

- Izbere se končno število značilk z najvišjimi individualnimi zmogljivostmi klasifikacije, ali najvišjimi zmogljivostmi razlikovanja med razredi v smislu Student-ovega t -testa (verjetnost, p , da dve normalno porazdeljeni distribuciji pripadata isti populaciji)



(Studentov t -test)

- **Studentov t -test** je konvencionalna statistika za merjenje **pomembnosti/izrazitosti** (verjetnosti p) razlike srednjih vrednosti dveh množic

1) Ocena standardne deviacije razlike srednjih vrednosti:

$$s_D = \sqrt{\frac{\sum_{one} (x_i - \bar{x}_{one})^2 + \sum_{two} (x_i - \bar{x}_{two})^2}{N_1 + N_2 - 2} \left(\frac{1}{N_1} + \frac{1}{N_2} \right)}$$

2) Izračun t kot:

$$t = \frac{\bar{x}_{one} - \bar{x}_{two}}{s_D}$$

3) Evaluacija vrednosti verjetnosti p za Studentovo distribucijo t , $A(t | v)$, z $v = N_1 + N_2 - 2$ stopnjami prostosti, kot: $p = 1 - A(t | v)$

- Studentova distribucija ocenjuje verjetnost, da dve normalno porazdeljeni množici pripadata *isti populaciji*
- Nizka numerična vrednost **verjetnosti** ($p = 0.05$ or 0.01) pomeni, da je opazovana razlika srednjih vrednosti "zelo pomembna / izrazita"



Strategije in metode za izbor relevantnih značilk

- Kategorije izbiranja značilk

3) *Izbor značilk na osnovi uporabe izbranega klasifikacijskega algoritma in izbrane strategije za oceno sposobnosti oziroma kvalitete dane množice značilk za razlikovanje med razredi (wrapper algorithms)*

- Množica značilk se izbere na osnovi ocenjevanja klasifikacijskih točnosti doseženih na podmnožicah značilk določenih po nekem pravilu

- **Izbrane strategije**

- * Sekvenčna Izbira v Smeri Naprej, SISN, (Sequential Forward Selection, SFS)
 - * Sekvenčna izbira v smeri nazaj (Sequential Backward Selection, SBS)
 - * Jeffrey-jeva razdalja divergencija (Jeffrey divergence distance)
 - * Optimizacija rojenja binarnih delcev (Binary Particle Swarm Optimization, BSPO)

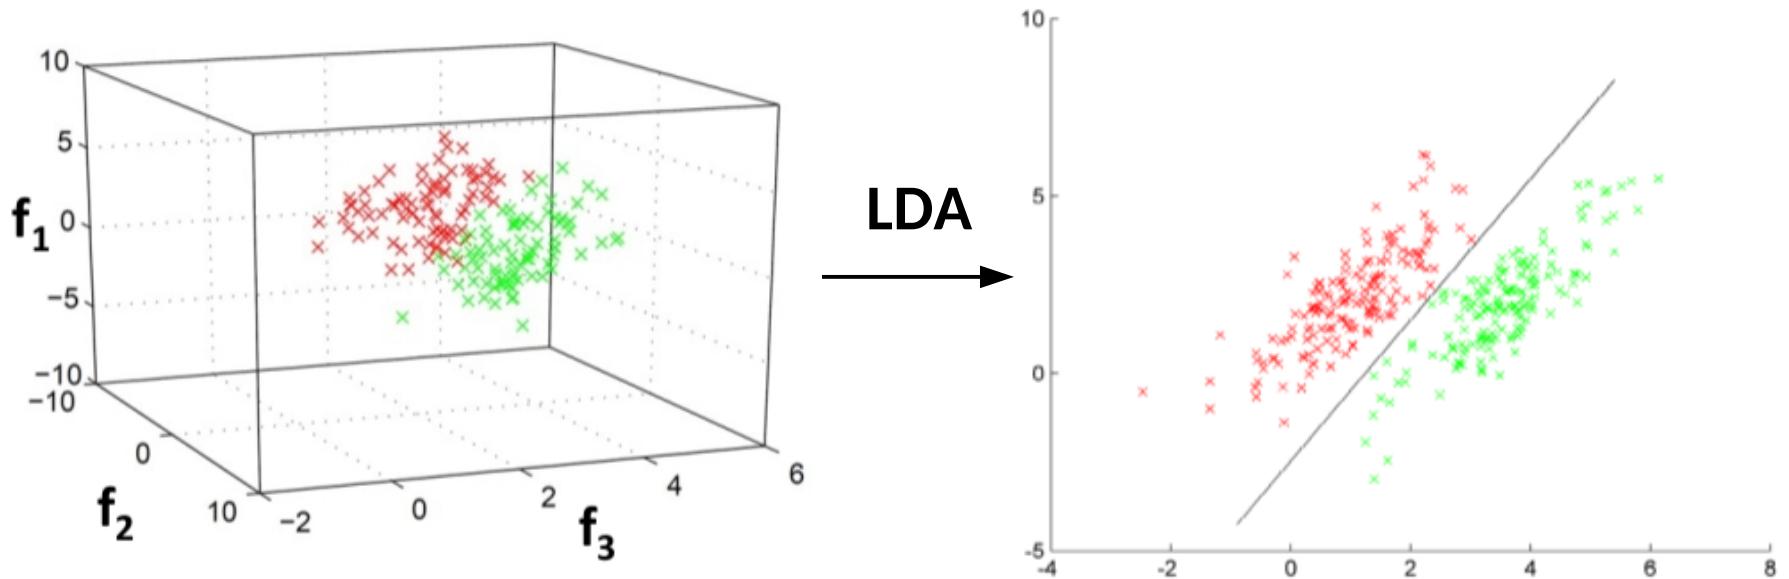


Klasifikatorji

- **Klasifikatorji uporabljeni pri VMR raziskavah**
 - **Linearna diskriminantna analiza (Linear Discriminant Analysis - LDA)**
 - **Kvadratna diskriminantna analiza (Quadratic Discriminant Analysis - QDA)**
 - Naivni Bayesov klasifikator (Naive Bayes classifier - NB)
 - Nelinerni Bayesov klasifikator (Non-linear Bayes classifier - NB)
 - Klasifikator k najbližjih sosedov (k Nearest Neighbors - kNN)
 - Odločitveno drevo (Decision Tree - DT)
 - Naključni gozdovi (Random Forests - RF)
 - Klasifikator s podpornimi vektorji (Support Vector Machine – SVM)
 - Nevronska mreža (Neural Network – NN)
 - Konvolucijska nevronska mreža (Convolutional Neural Network - CNN)
 - Ansamblji klasifikatorjev (Ada Boost - AdaB)

Linearna diskriminantna analiza

- **Linearna Diskriminantna Analiza (LDA)** (Linear Discriminant Analysis – LDA)
- LDA privzame, da so razredi linearno ločljivi
- LDA definira linearno **diskriminantno funkcijo**, ki predstavlja hiperravnino v prostoru značilk za ločevanje razredov
- V odvisnosti od tega na kateri strani ravnine je vektor značilk najden, bo določen razred kateremu vektor značilk pripada





Linearna diskriminantna analiza

- **Linearna Diskriminantna Analiza (LDA)** (Linear Discriminant Analysis – LDA)
- Obstaja označena sekvenca $(\mathbf{x}_1, y_1), \dots, (\mathbf{x}_n, y_n)$ vektorjev značilk, \mathbf{x}_k , in pripadajočih oznak, y_k , $(-1, +1)$.
- Predpostavimo, da so vzorci obeh razredov normalno (po Gauss-u) porazdeljeni
- Gauss-ovi distribuciji večdimenzionalnih vektorjev značilk obeh razredov C_1 in C_2 sta karakterizirani s srednjima vrednostima, $\boldsymbol{\mu}_i$, in kovariančnima matrikama, $\boldsymbol{\Sigma}_i$
- Predpostavka $\boldsymbol{\Sigma}_1 = \boldsymbol{\Sigma}_2$

$$\boldsymbol{\mu}_i = \frac{1}{|C_i|} \sum_{k \in C_i} \mathbf{x}_k \quad \boldsymbol{\Sigma}_i = \sum_{k \in C_i} (\mathbf{x}_k - \boldsymbol{\mu}_i)(\mathbf{x}_k - \boldsymbol{\mu}_i)^T$$

Linearna diskriminantna analiza

- **Linearna Diskriminantna Analiza (LDA)** (Linear Discriminant Analysis – LDA)
- Odločitvena (diskriminantna) funkcija (spremenljivka), y , je predstavljena kot linearja kombinacija p komponent vektorja značilk \mathbf{x} kjer je \mathbf{w} vektor normale na optimalno hiperravnino

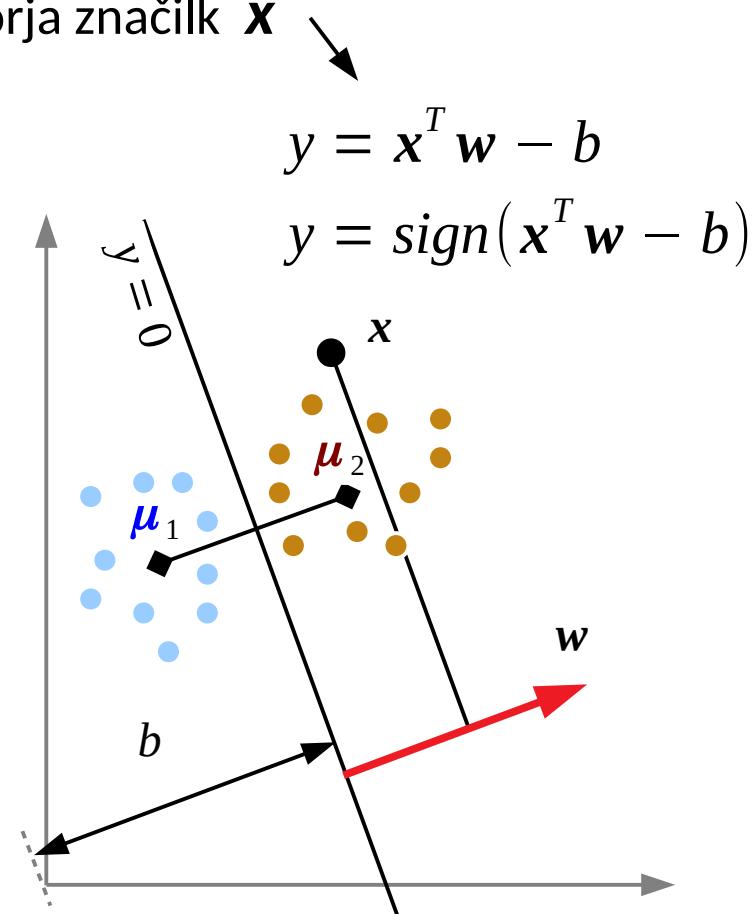
$$\mathbf{w} = (\Sigma_1 + \Sigma_2)^{-1}(\boldsymbol{\mu}_2 - \boldsymbol{\mu}_1)$$

in je b prag

$$b = \mathbf{w}^T(\boldsymbol{\mu}_2 + \boldsymbol{\mu}_1)/2$$

- Nov vektor značilk \mathbf{x} se klasificira v ustrezeni razred glede na hiperravnino

(Količnik razlik aritmetičnih sredin diskriminantne spremenljivke v obeh skupinah (C_1 in C_2) glede na varianco diskriminantne spremenljivke znotraj skupin(e) je maksimalen)





Metrike zmogljivosti

- Vrednotenje zmogljivosti

Dogodkovno usmerjena matrika (dogodek = poizkus)

		VMR	VMR
		DOGODEK	NE-DOGODEK
Referenca	dogodek	TP	FN
Referenca	ne-dogodek	FP	TN

TP – True Positives, število pravilno klasificiranih dogodkov

FN – False Negatives, število napačno klasificiranih dogodkov

FP – False Positives, število napačno klasificiranih ne-dogodkov

TN – True Negatives, število pravilno klasificiranih ne-dogodkov



Metrike zmogljivosti

- Vrednotenje zmogljivosti (dogodek = poizkus)

		VMR	VMR
		DOGODEK	NE-DOGODEK
Referenca	dogodek	TP	FN
Referenca	ne-dogodek	FP	TN

Občutljivost:

$$Se = \frac{TP}{TP + FN}$$

Razmerje dogodkov, ki so bili pravilno klasificirani kot DOGODKI

Specifičnost:

$$Sp = \frac{TN}{TN + FP}$$

Razmerje ne dogodkov, ki so bili pravilno klasificirani kot NE-DOGODKI

Točnost klasifikacije:

$$CA = \frac{TP + TN}{TP + TN + FN + FP}$$

Razmerje pravilno klasificiranih dogodkov in ne-dogodkov proti vsem dogodkom



Vrednotenje zmogljivosti

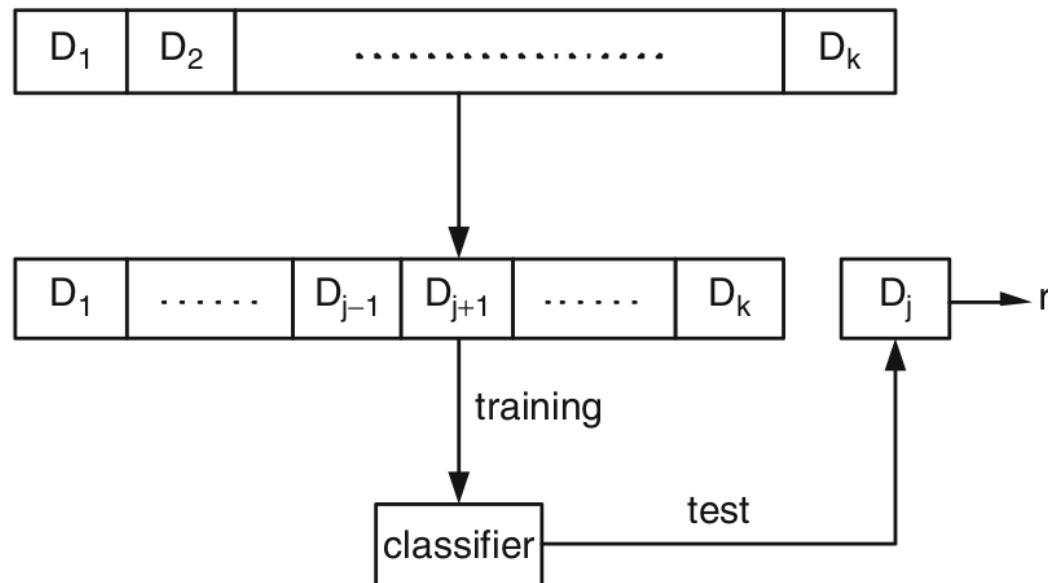
- **Testni (bodoči) podatki niso na razpolago**
(napovedovanje zmogljivosti za realni svet)
 - Vrednoti zmogljivost na učni množici
 - Učenje teče le na delu podatkov (80% - učna množica, 20% -testna množica (20% holdout))
 - Križna validacija s k deli (k - fold cross validation), $k = 5, 10$
 - Izpusti enega (učenje teče na $N-1$ vzorcih) (Leave one out)
 - Vrednotenje zmogljivosti na učni množici *in ocena robustnosti*
- M ponovitev, nato srednja vrednost in standardna deviacija zmogljivosti ($M = 30, 50, 100, 200$)
- Površina pod ROC krivuljo v diagramu Občutljivost, 1 – Specifičnost, (AUC – Area Under the ROC Curve), (ROC - Receiver Operating Characteristic - karakteristika delovanja sprejemnika)

Vrednotenje zmogljivosti

- **Testni (bodoči) podatki niso na razpolago**

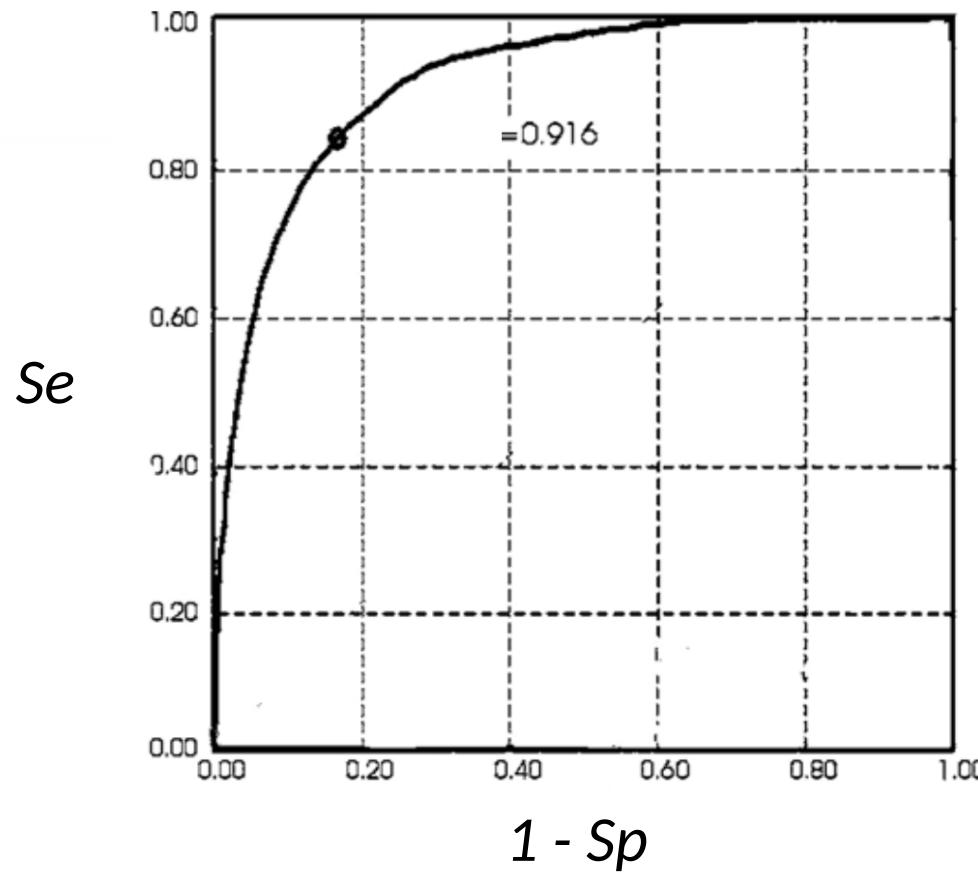
(napovedovanje zmogljivosti za realni svet)

- Križna validacija s k deli (k - fold cross validation), $k = 5, 10$
- Postopek učenja in vrednotenja se ponovi za vsak del, nato sledi povprečje k -tih zmogljivosti za učne in testne množice
- Raje uporabi bločno križno validacijo in ne naključne



Vrednotenje zmogljivosti

- Površina pod ROC krivuljo





Vrednotenje zmogljivosti

- Na razpolago so učni in (novi) testni podatki
 - Oceni parametre modela (filtr, značilke) na učni množici
 - Vrednoti zmogljivost na učni množici
 - Vrednoti zmogljivost na novi testni množici
 - Izmeri količino izgube (ali količino višje zmogljivosti) za izbrane mere zmogljivosti, npr., odstotka napačnih klasifikacij



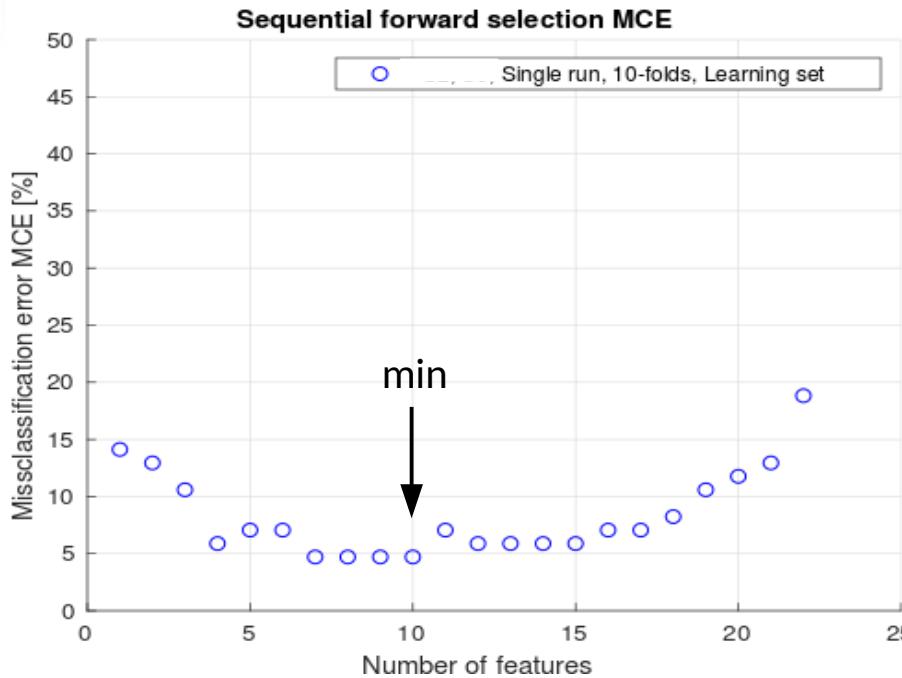
Sekvenčna izbira značilk v smeri naprej

- **Strategija Sekvenčne Izbire značilk v Smeri Naprej (SISN), (SFS strategy)**
 - Sekvenčno izbira (dodaja) značilke (začenši s prazno množico)
 - * Na začetku so značilke, kandidati, sortirane glede na njihovo individualno sposobnost ločevanja razredov v smislu p (t -test) ali klasifikacije
 - * **Učni algoritem** → npr., Kvadratna Diskriminantna Analiza, KDA (QDA)
 - * **(Podatki so razdeljeni na učno in testno množico** → 80% / 20% (→ 20% holdout)
→ (Le, če bo uporabljana tudi dodatna histogramska metoda s kopiranjem izbranih značilk)
 - * **Poženi metodo (algoritem) Sekvenčne Izbire značilk v Smeri Naprej** (MATLAB → sequentialfs)
 - Začni s prazno množico izbranih značilk
 - **V množico izbranih značilk sekvenčno dodaj značilke, eno po eno, ki še niso bile izbrane**
 - * Za vsako naslednjo **kandidatno** podmnožico značilk, izvedi križno validacijo z 10 deli (učenje z učnim algoritmom na učnih množicah)
→ **Indikator zmogljivosti** za vsako kandidatno podmnožico značilk je **Napaka Napačne Klasifikacije, NNK (MisClassification Error, MCE)**, to je, odstotek napačnih klasifikacij dobljen na učnih množicah
 - * V množico izbranih značilk dodaj tisto še ne dodano značilko, ki zagotavlja minimalno NNK
 - **Minimalna vrednost NNK**, (NNK kot funkcija števila izbranih značilk), potem **definira število izbranih (potrebnih) značilk in katere so** (ter njihovo zmogljivost)

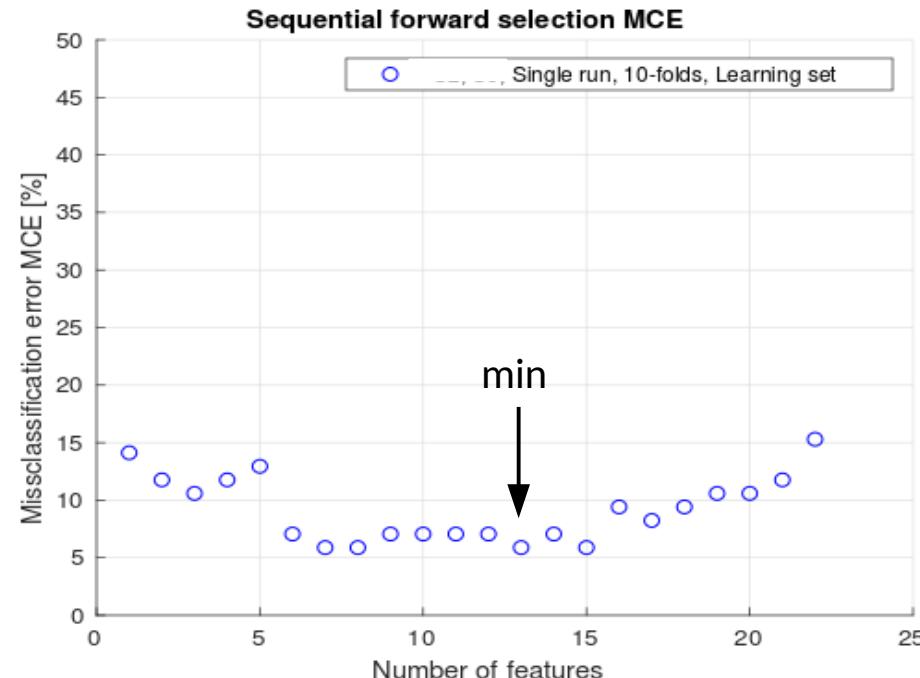
Sekvenčna izbira značilk v smeri naprej

- Funkcija NNK (MCE) in izbrane značilke za nalogo klasifikacije med zamišljanjem aktivnostmi leve in desne roke z uporabo značilk spektrov signalov v mi frekvenčnem področju (22 značilk, na začetku sortiranih po individualni klasifikacijski zmogljivosti)

Prvi tek SISN, SFS



Drugi tek SISN, SFS



10 značilk: 6 7 9 2 11 16 4 17 12 15

13 značilk: 6 7 3 12 16 2 15 13 20 5 9 22 14

→ Nestabilnost

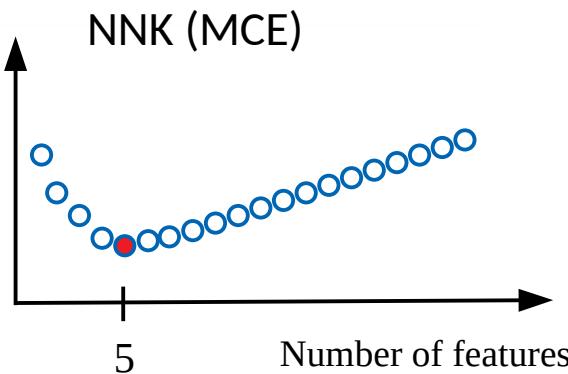


Histogramska metoda s kopičenjem značilk

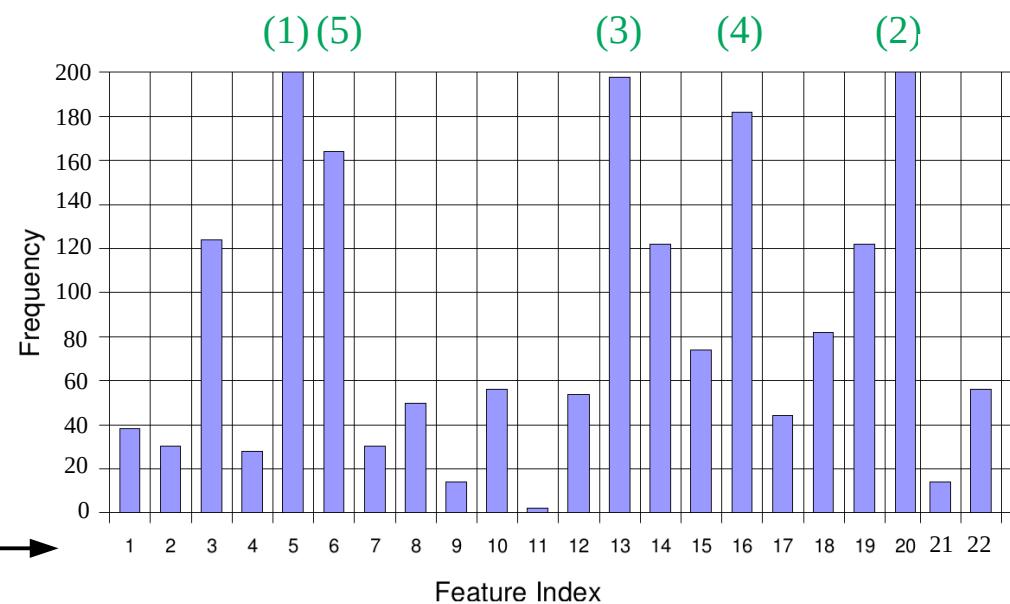
- Strategija Sekvenčne Izbire značilk v Smeri Naprej, SISN, (SFS strategy)
 - različni teki SISN metode (algoritma) rezultirajo v različne podmnožice izbranih značilk
 - v izogib tej nestabilnosti in za konstrukcijo stabilne podmnožice napovednih značilk uporabi **histogramsko metodo s kopičenjem izbranih značilk** z, npr. 200 ponovitvami teka SISN algoritma kjer so vsakič podatki razdeljeni naključno v smislu (80%, 20%), (20% holdout)
- **Minimum povprečne NNK (MCE) funkcije** definira število izbranih (potrebnih) značilk
- **Vrhovi histograma z nakopičenimi izbranimi značilkami** potem definirajo dokončno izbrane značilke

Histogramska metoda s kopičenjem značilk

- **Histogramska metoda s kopičenjem izbranih značilk**
 - **POVPREČNA NNK (MCE) funkcija**
(SISN (SFS) 200 tekov)
 - **Histogram nakopičenih izbranih značilk po 200 združenih tekih**



- **Minimum pri petih značilkah**
→ izbrane značilke:
5 20 13 16 6
- (1) (2) (3) (4) (5)



- **Minimum** povprečne NNK (MCE) funkcije definira število potrebnih značilk
- značilke 5, 20, 13, 16 in 6, so izbrane glede na vrhove histograma



Vrednotenje zmogljivosti

- Mera prenosa informacije (Information Transfer Rate)

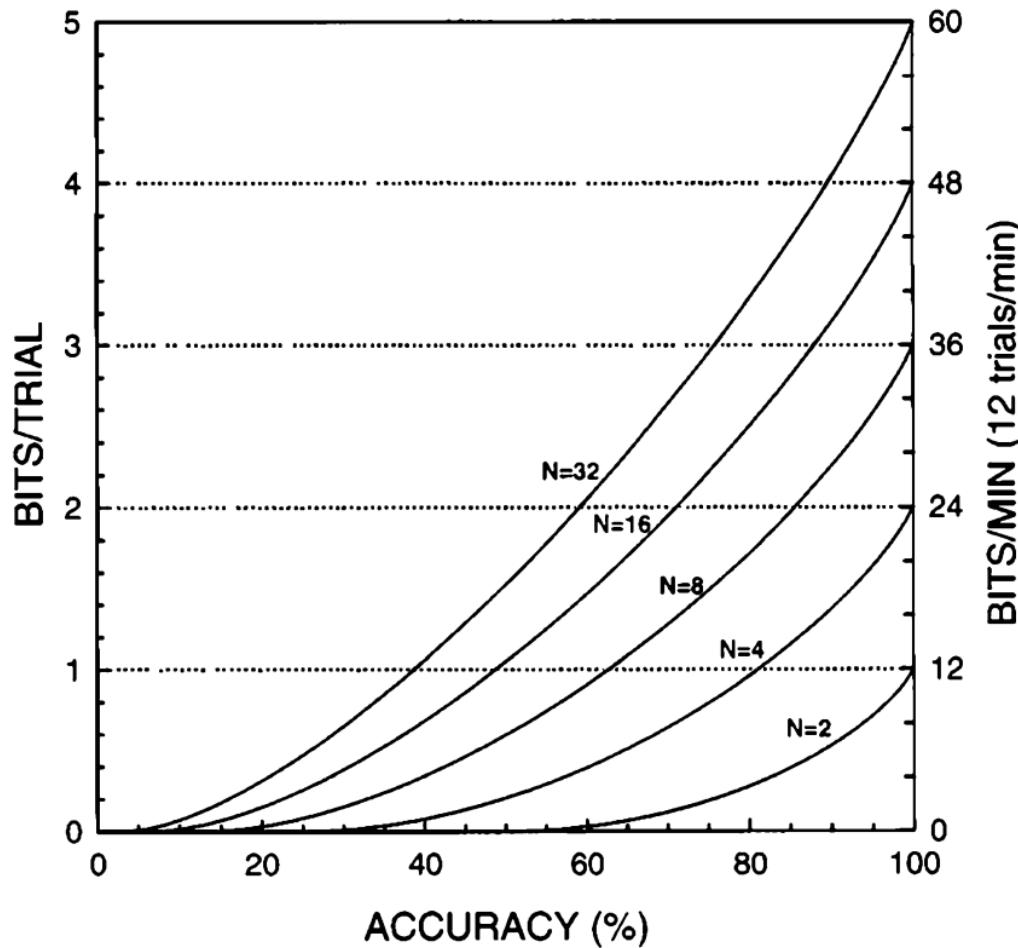
$$ITR = \frac{1}{c} \left\{ \log_2 N + p \log_2 p + (1 - p) \log_2 \left(\frac{1 - p}{N - 1} \right) \right\} \quad [bit/sec]$$

kjer je c čas na poizkus, N je število možnosti na poizkus in p je klasifikacijska točnost

- Predpostavke
 - Uporabnik bo imel N različnih nalog (običajno dve, levo, desno)
 - Uporabnik se bo odločil in uspešno izvršil vsako od nalog z isto verjetnostjo
 - Klasifikacijska točnost, p , bo ostala konstantna vzdolž časa
 - Napake bodo uniformno distribuirane preko vseh poizkusov

Vrednotenje zmogljivosti

- Mera prenosa informacije (Information Transfer Rate)



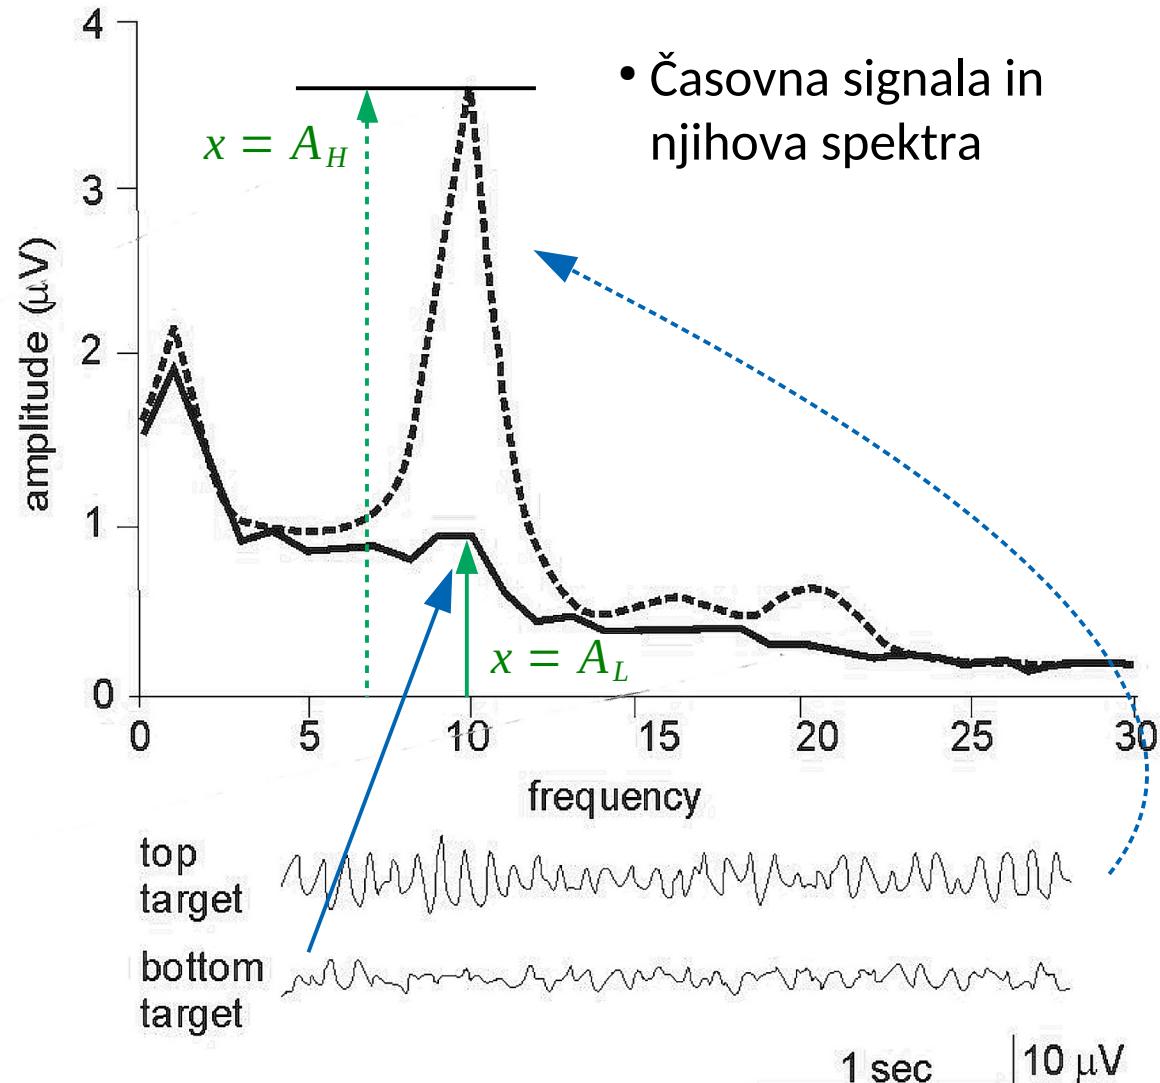


(Dodatni materiali)

- Premikanje kurzorja na osnovi zamišljanja motoričnih aktivnosti
- Izbrane značilke (elektrode)

Premikanje kurzorja na osnovi zamišljanja motoričnih aktivnosti

- Spektralne značilke (amplitude v mi) frekvenčnem področju, 8 – 13 Hz)
- Zamišljanje aktivnosti leve roke → premakni kurzor v levo
- Zamišljanje aktivnosti desne roke → premakni kurzor v desno



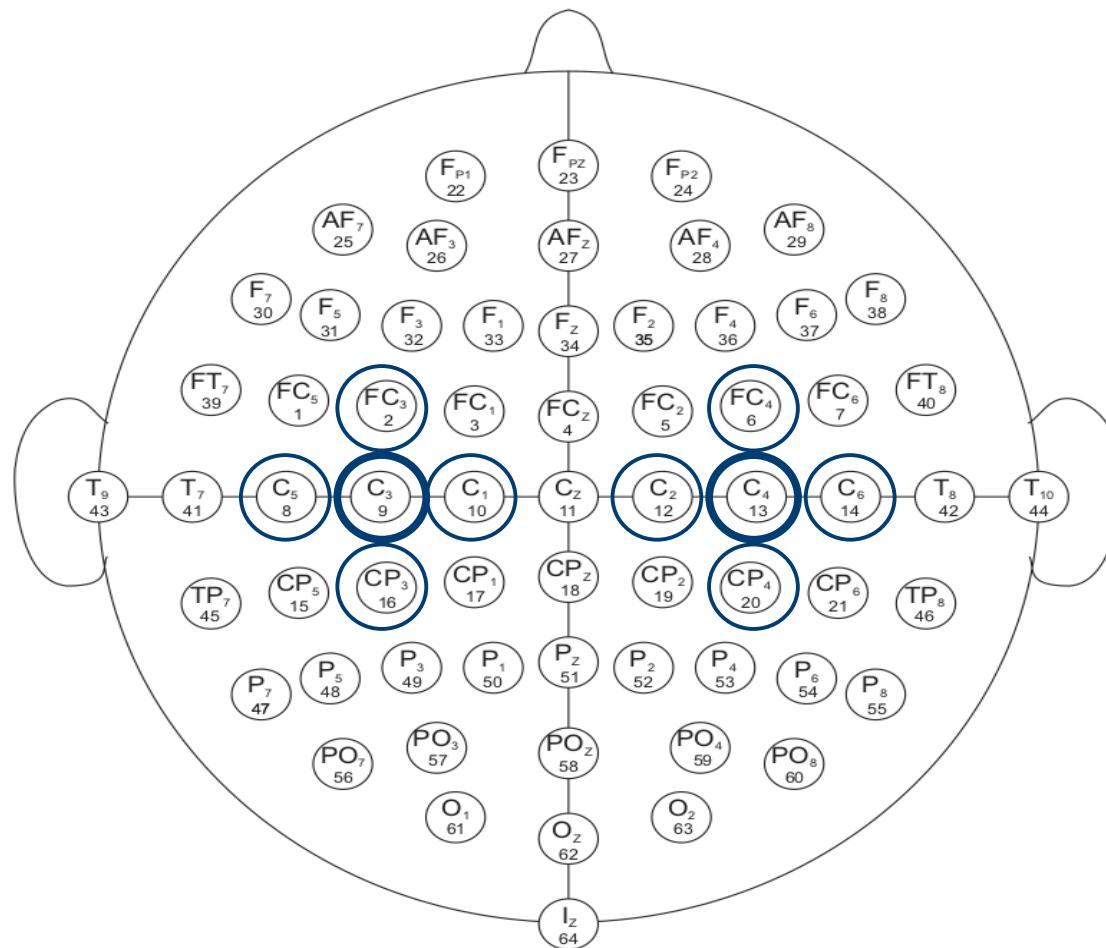
Premikanje kurzorja na osnovi zamišljanja motoričnih aktivnosti

- Položaji elektrod
- Pogoste uporabljene elektrode (Laplace-ova maska)

→ EEGMMI DS

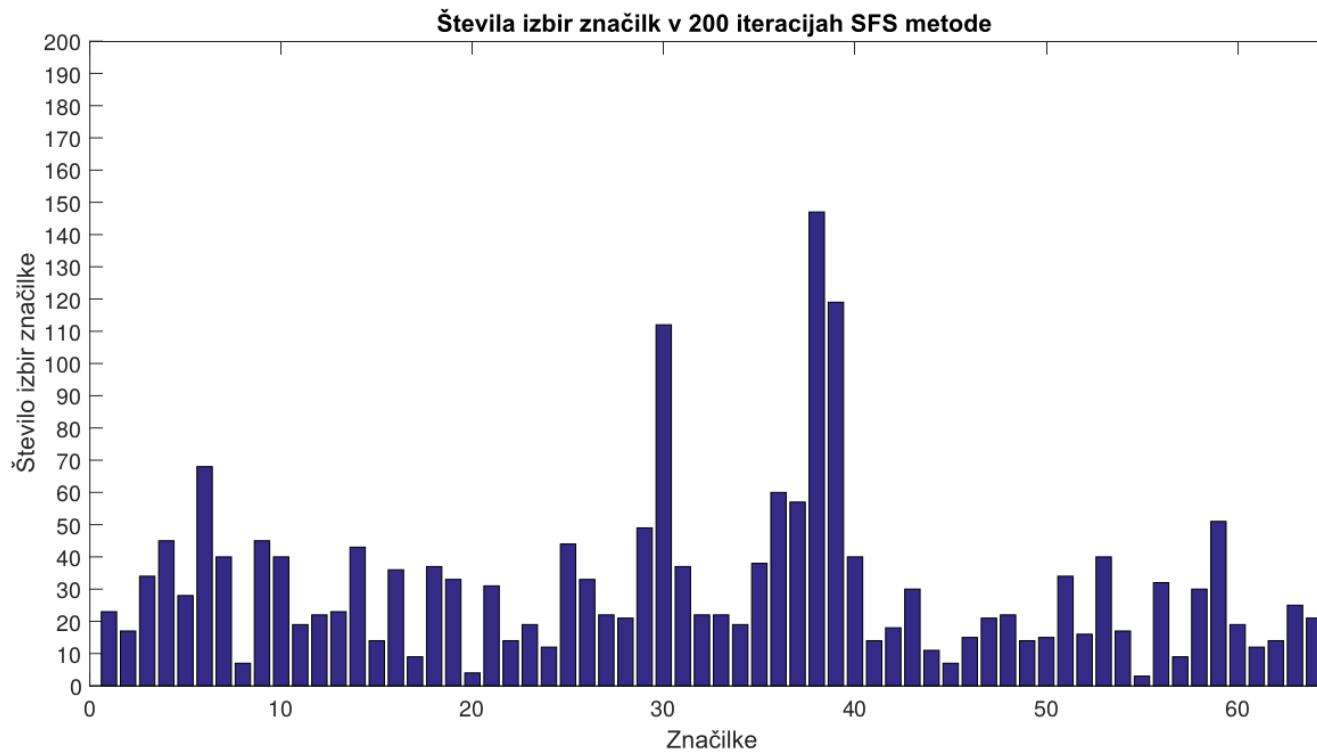
→ 64 značilk

to je, 64 amplitud spektrov v mi frekvenčnem področju, ena na vsak kanal



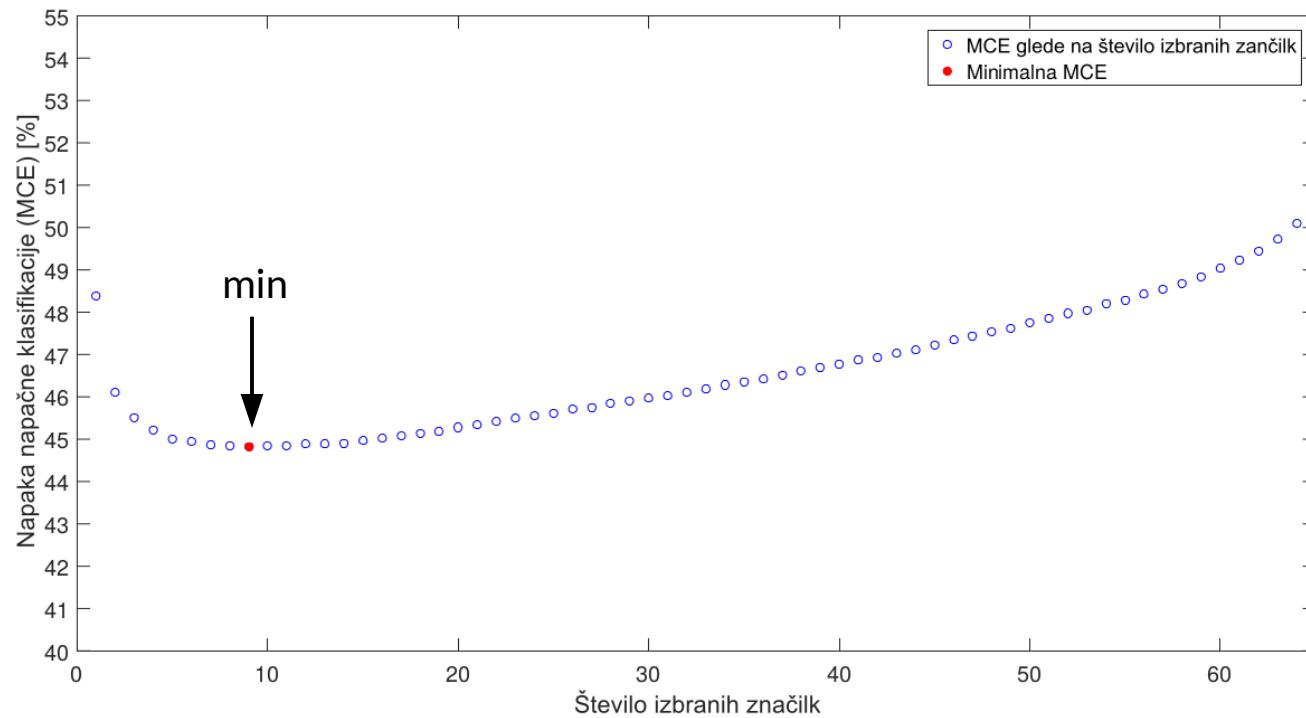
Premikanje kurzorja na osnovi zamišljanja motoričnih aktivnosti

- Histogram nakopičenih izbranih značilk za nalogu klasifikacije med zamišljanjem motoričnih aktivnosti (na osnovi posnetkov javno dostopne baze EEGMMI DS), (SISN (SFS), 200 tekov, QDA, (80%, 20%), križna validacija z 10 deli na učnih množicah)



Premikanje kurzorja na osnovi zamišljanja motoričnih aktivnosti

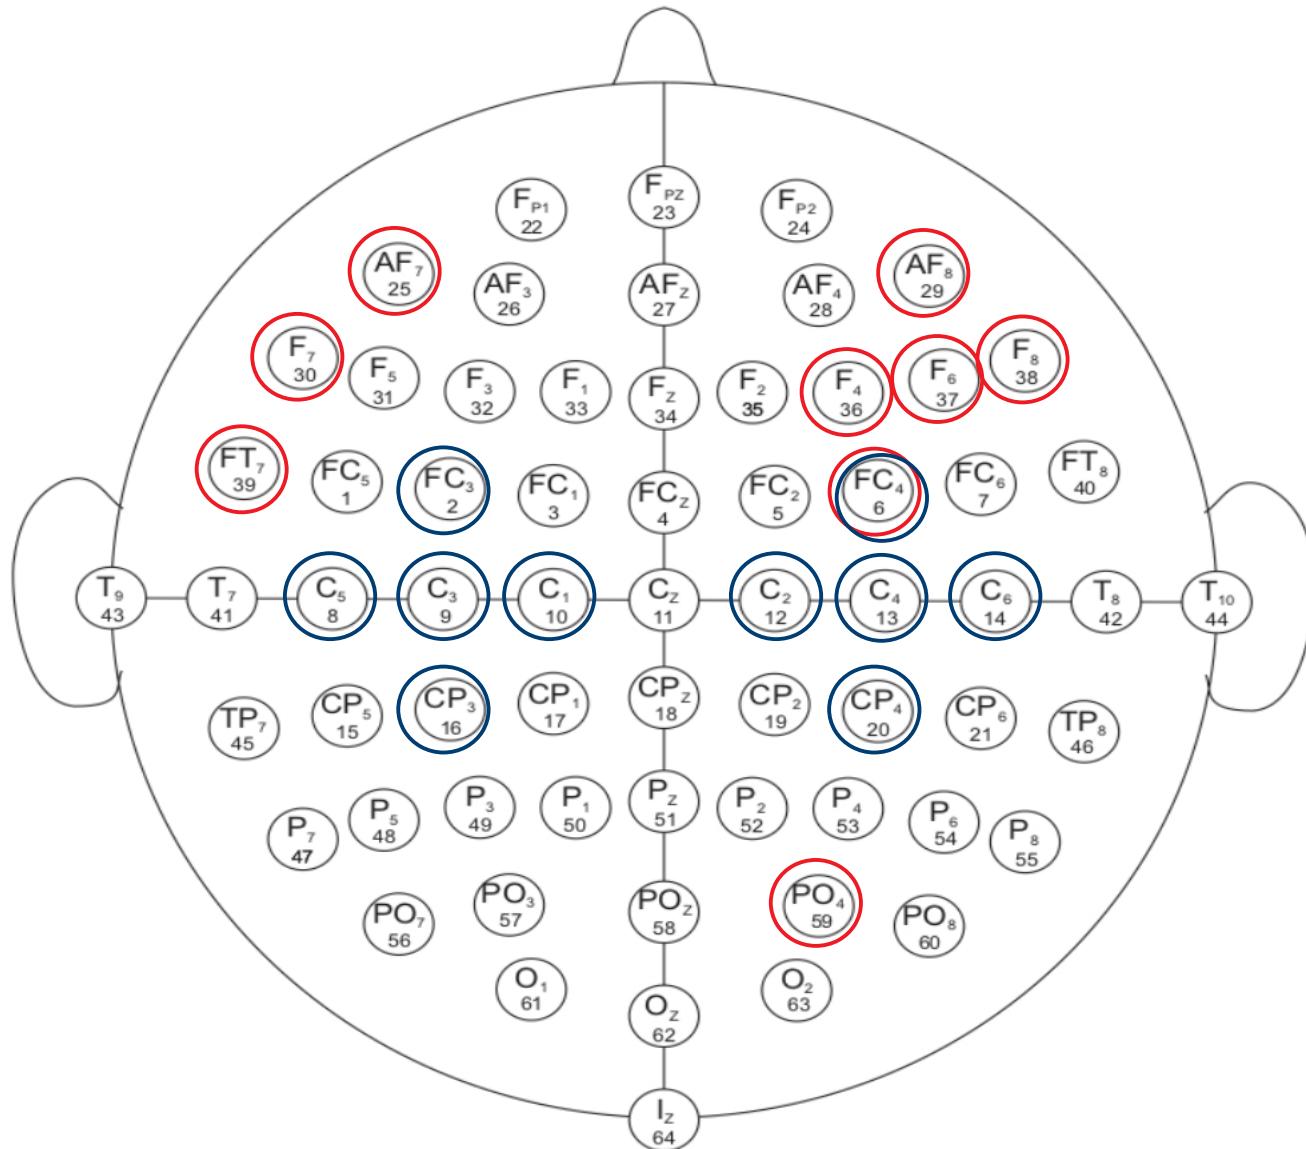
- Povprečna NNK (MCE) funkcija, in izbrane značilke (elektrode) za nalogu klasifikacije med zamišljanjem motoričnih aktivnosti (200 tekov)



- Izbrane značilke (elektrode) (9):
F8 (38), FT7 (39), F7 (30), FC4 (6), F4 (36), F6 (37), PO4 (59), AF8 (29), AF7 (25)

- Izbrane
značilke
(elektrode)

1. F8 (38)
2. FT7 (39)
3. F7 (30)
4. FC4 (6)
5. F4 (36)
6. F6 (37)
7. PO4 (59)
8. AF8 (29)
9. AF7 (25)





Premikanje kurzorja na osnovi zamišljanja motoričnih aktivnosti

- Izbrane zmogljivosti klasifikacije
(za izbrane subjekte podatkovne baze EEGMMI DS, QDA klasifikator, križna validacija z 10 deli, 30 ponovitev)
- Uporaba značilk z izbranih elektrod
 $Se = 90.5\%$, $Sp = 95.2\%$, $CA = 92.9\%$
- Uporaba značilk z elektrod, ki so razvrščene po Laplace-ovi maski okrog elektrod C3 in C4
 $Se = 71.4\%$, $Sp = 85.7\%$, $CA = 78.6\%$