


# PREDOBDELAVA IN IZLOČANJE ČASOVNIH TER PROSTORSKIH ZNAČILK, I

- Faze procesiranja signalov EEG med interakcijo možgani računalnik
- Zajemanje signalov
- Faze procesiranja signalov EEG med interakcijo možgani računalnik
- Motnje
- Predobdelava, izločanje motenj
- Faze procesiranja signalov EEG med interakcijo možgani računalnik
- Komponente VMR so filtri
- Izločanje značilk
- Statični filtri
- Prostorski filtri
- Prostorske značilke
- Tipične arhitekture VMR


# 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




# Zajemanje signalov

- Segment signala je lahko predstavljen kot vsota mnogih sinusoid različnih amplitud in frekvenc, ki so med seboj premaknjene:

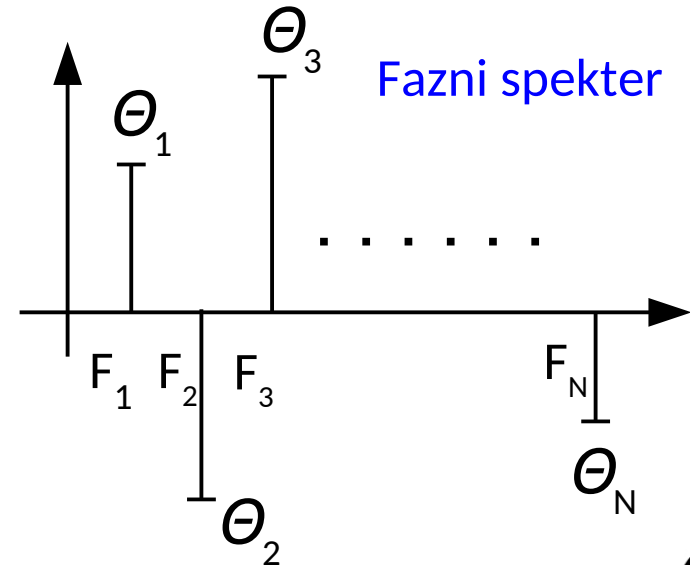


$$x(t) = \sum_{i=1}^N A_i \sin(2\pi F_i t + \theta_i)$$

- kjer so  $\{A_i\}$ ,  $\{F_i\}$ , in  $\{\theta_i\}$  množice amplitud, frekvenc in premikov (faz)
- [Kaj je \(frekvenčni\) spekter?](#)



$$\begin{aligned}
 F_2 &= 2 \cdot F_1 \\
 F_3 &= 3 \cdot F_1 \\
 &\vdots \\
 F_N &= N \cdot F_1
 \end{aligned}$$



# Zajemanje signalov

- Kosinusni (sinusni) signal

$$x_a(t) = A \cos(\Omega t + \theta), \quad -\infty < t < \infty$$


$A$  je amplituda

$\Omega$  je frekvenca v radianih na sekundo [ $rad/s$ ],  $\Omega = 2 \pi F$

$\theta$  je faza radianih [ $rad$ ]


$T_p$  je trajanje enega cikla v sekundah [ $s$ ]

$F = 1 / T_p$  je frekvenca v ciklih na sekundo ali Hertz-ih [ $Hz$ ],  $Hz = 1/s$



# Zajemanje signalov

- **Diskretni signal** (diskretno časovni signal),  $x(n)$ , je dobljen z vzorčenjem časovno zveznega signala,  $x_a(t) = x(t)$ ,  $x_a(t) \rightarrow x_a(nT) \rightarrow x(n)$



- Sekvenca diskretnih vzorcev signala,  $\{x(n)\} = x_a(nT)$ ,  $n = \dots, -1, 0, 1, 2, \dots$
- $T$  ( $T_s$ ) je vzorčevalna perioda ali vzorčevalni interval v [s], [sec]
- $F_s = 1/T$  je vzorčevalna frekvenca ali frekvenca vzorčenje v [smp/s], [smp/sec], [Hz]

# Vzorčenje sinusoide

- Diskretni sinusni signal,  $x(n)$


Vzorčenje:  $F t \rightarrow F n T_s = F/F_s n$

$$\begin{aligned}
 x_a(t) &= A \sin(2\pi F t + \theta) & \longrightarrow & & x_a(nT_s) &= A \sin(2\pi F/F_s n + \theta) = x(n) \\
 &= A \sin(\Omega t + \theta) & & & &= A \sin(\omega n + \theta) = x(n)
 \end{aligned}$$

$$\Omega = 2\pi F \quad \longrightarrow \quad \omega = 2\pi F/F_s \rightarrow \omega = 2\pi f$$

- $F_s$  je frekvenca vzorčenja v [smp/s] ali v [Hz],  $\text{Hz} = 1/\text{s}$

$$f = \frac{F}{F_s}$$



- $F$  - časovno zvezna frekvenca v ciklih na sekundo [cycles/sec], [cyc/s], [Hz]
- $f$  - časovno diskretna frekvenca v ciklih na vzorec [cycles/sample], [cyc/smp]

# Vzorčenje sinusoide

- Vzorčenje**

- Višja frekvenca **prekriva (aliasing)** (oziroma se zdi premaknjena) nižjo frekvenco

- $F_s = 6 \text{ kHz}$ ,  $N = 6$



- Ne moremo vedeti ali je bila frekvenca originalnega časovno zveznega signala  $x(t)$

$F$  ali  $F_1 = F_s - F$

- Kako se izogniti prekrivanju ?**

Glede na ta primer, katero bi bilo število vzorcev na sinusoido,  $N$ ,  $N = F_s / F$ , ki še vedno zagotavlja aproksimacijo sinusoide?

$N \geq ?$




# Zajemanje signalov

- Glede na to, da naj je  $N = F_s / F \geq 2$  in  $f = F / F_s \leq 1/2$ , sledi:  $F \leq F_s / 2$
- Najvišja še prisotna frekvenca vhodnega analognega signala,  $F_{max}$ , mora biti manjša ali enaka  $F_s / 2$ ,

$$F_{max} \leq F_s / 2 \quad \text{oziroma} \quad F_s \geq 2 F_{max}$$

- Izogni se prekrivanju s filtriranjem časovno zveznega signala  $x(t)$
- **Kako?** z nizko prepustnim filtrom pred vzorčenjem
- V praksi vzorči signal s frekvenco vzorčenja približno  $F_s = (3 \text{ do } 4) \cdot F_{max}$
- Elektroencefalogram:  $F_s = 125 \text{ smp/s}, 250 \text{ smp/s}, \text{ ali višje}$



$$N = \frac{F_s}{F} \left[ \frac{\text{smp}}{\text{cyc}} \right]$$


$$f = \frac{F}{F_s} \left[ \frac{\text{cyc}}{\text{smp}} \right]$$

$$N = \frac{1}{f}$$





# Zajemanje signalov



# Zajemanje signalov


Filtriranje z nizko prepustnim filtrom in vzorčenje

$$x_a(t) = A \sin(2\pi F t + \theta)$$

$$= A \sin(\Omega t + \theta)$$

$$\Omega = 2\pi F$$

( $F_s = 6 \text{ kHz}$ )



$$x_a[nT_s] = A \sin(2\pi F/F_s n + \theta) = x[n]$$

$$= A \sin(\omega n + \theta) = x[n]$$



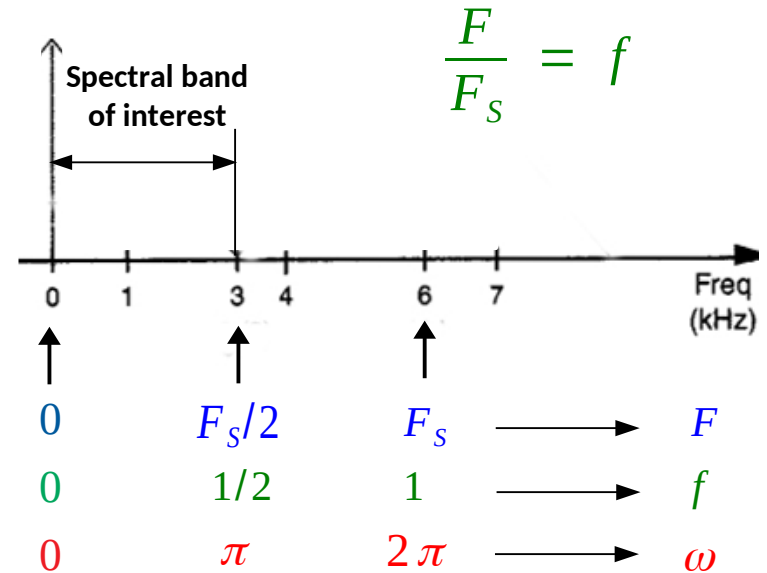
$$\omega = 2\pi F/F_s \rightarrow \omega = 2\pi f$$

$$f, \quad 0 \leq f \leq 1/2,$$

the frequency in cycles per sample [cyc/smp]


$$\omega, \quad 0 \leq \omega \leq \pi, \quad \omega = 2\pi f,$$

the frequency in radians per sample [rad/smp]




# 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



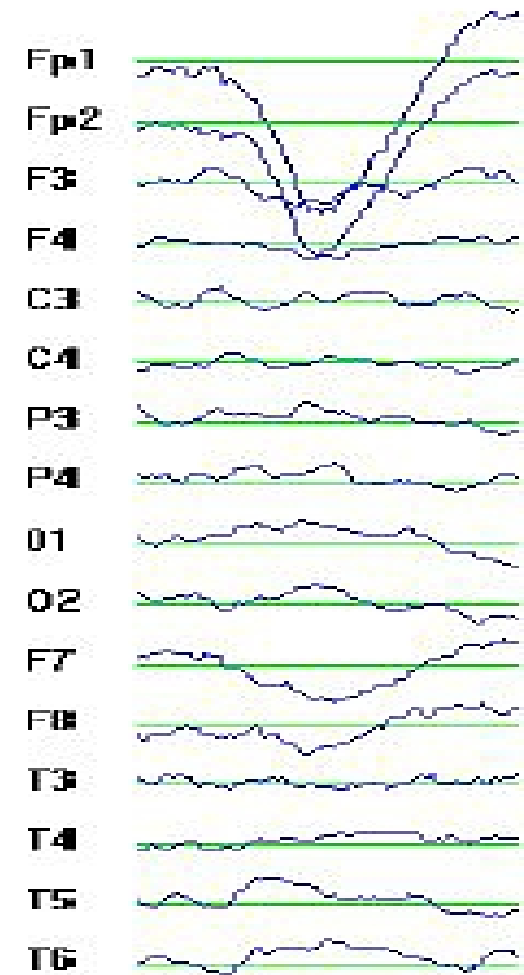

# Motnje

- Artefakti v posnetku EEG zaradi **utripanja oči**



# Motnje


- Artefakti v posnetku EEG zaradi **utripanja oči**
- Očitni so na standardnih lokacijah spredaj (Fp1 ali Fp2)




(Baztarrica)

# Motnje

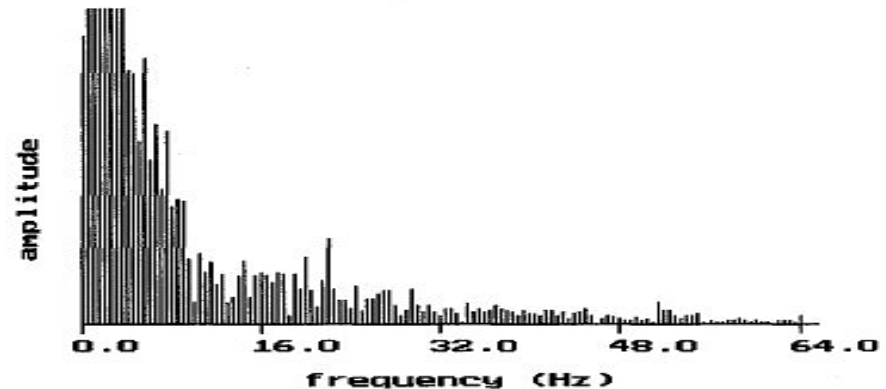
- EEG signal posnet s standardno elektrodo spredaj (Fp1) in njegov spekter



y-axis: 1cm = 10 microvolts  
x-axis: 1cm = 330 milliseconds




- EEG signal posnet s standardno elektrodo spredaj (Fp1), ki vsebuje artefakt zaradi utripanja očes in njegov spekter



# Motnje

- Štiri-sekundni večkanalni posnetek EEG kontaminiran s počasnim lezenjem signala in/ali elektromiografskimi motnjami



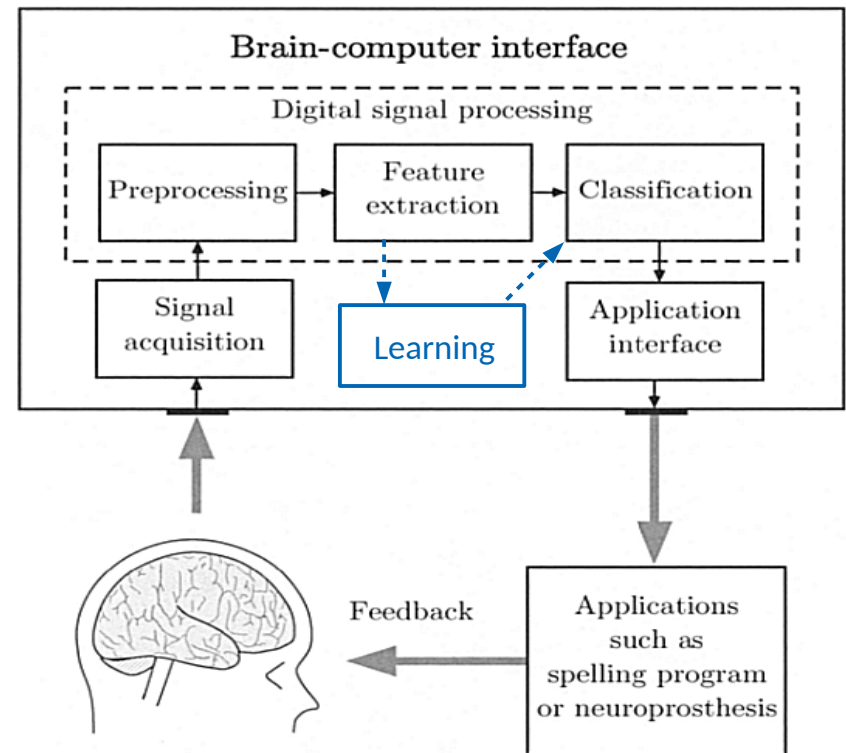
# Predobdelava, izločanje motenj

- **Izloči dele signalov z artefakti zaradi utripanja oči**
  - z metodo Analize Neodvisnih Komponent (ANK, ICA)
- **Uporabi digitalne filtre**
  - visoki filter 0.1 Hz za počasna lezenja
  - nizki filter 30 Hz za elektromiografske motnje
  - \* Za načrtovanje teh filtrov uporabi MATLAB-ove funkcije ali MATLAB orodje **filterDesigner**




# 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



# Komponente VMR so filtri

- S stališča procesiranja signalov vmesnik možgani računalnik pretvori vhodne EEG signale,  $x_i(n)$ , v izhodni, **kontrolni**, signal,  $y(n)$ , in nato v **napovedi stanj** (+1, -1) (stanje 2, stanje 1) (zamišljanje aktivnosti desne, leve roke)
- $y(n)$  je definiran kot transformacija,  $T$
- $T$ : Različne kategorije filtrov






# Izločanje značilk

- Metode izločanja značilk
- Značilke v časovnem prostoru
  - varianca ali logaritem signala (**statični filtri**)
  - prostorske značilke (dobljene z uporabo **prostorskih filtrov**)
  - časovne značilke (dobljene z uporabo **spektralnih filtrov**)
  - časovno prostorske značilke (dobljene z uporabo prostorskih in spektralnih filtrov)

# Statični filtri

- Kvadrat signala (varianca)

$$T := y_i(n) = x_i^2(n)$$



- Varianca

$$T := y_i(n) = \text{var}(x_i(n))$$

- Koren variance


$$T := y_i(n) = + \sqrt{\text{var}(x_i(n))}$$

- Logaritem

$$T := y_i(n) = \log(x_i^2(n))$$

# Prostorski filtri

- Transformirajo večkanalni signal  $X(n)$ , z  $N$  kanali, v signal  $Y(n)$ . Vsak  $Y(n)$  je odvisen le od  $X(n)$ . Signali  $Y(n)$  (prostor komponent) so linearni (linearna transformacija). Signali  $Y(n)$  so izboljšani na nek način, z neko matriko  $W$ .





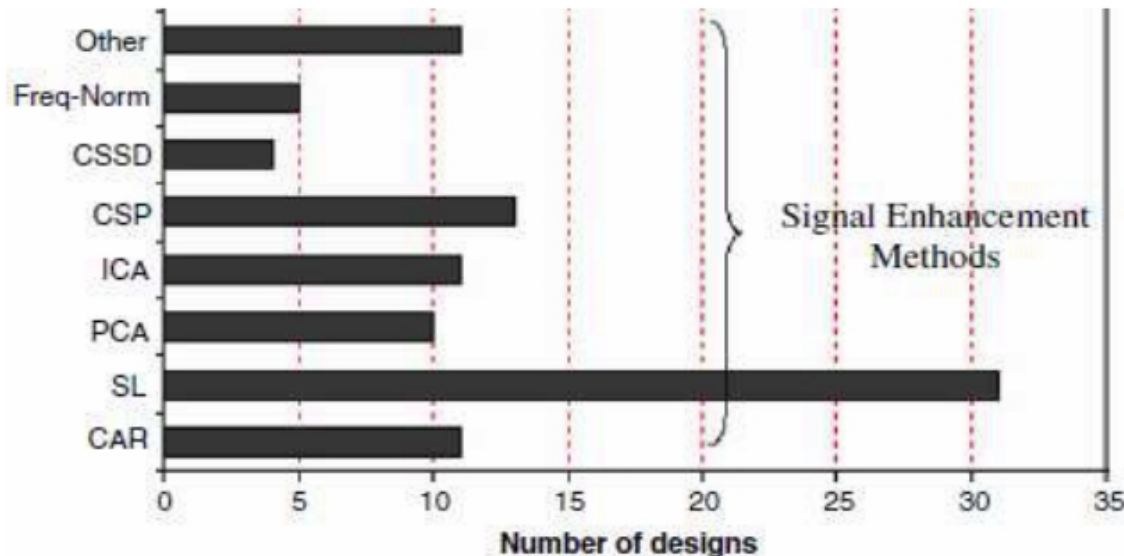
# Prostorski filtri

- **Zakaj prostor komponent?**
  - Zgraditi nove signale na osnovi neke skupine okoliških signalov
  - Redukcija števila signalov
  - EEG signali merjeni na površini glave so zamegljena verzija dejanskih možganskih signalov
    - → → Poenostaviti nadaljno analizo signalov
- **Aproksimacija dejanskih izvornih signalov oz. izboljšava vhodnih signalov**
  - redukcija šuma, učinka zamegljenosti in irelevantne informacije
  - višja **prostorska resolucija** in višja ločljivost (**separabilnost**) stanj
  - nekatere transformacije omogočijo izločanje artefaktov
- **Sledijo spektralni filtri, in/ali ocene spektrov v prostoru komponent ali pa v prostoru signalov**
  - če je analiza v prostoru signalov, je izvršena določena manipulacija v prostoru komponent pred inverzno transformacijo

# Prostorski filtri

- **Vrste prostorskih filtrov**

- Prostorski odvod drugega reda, SL - Surface Laplacian
- Analiza neodvisnih komponent, ICA - Independent component analysis
- Analiza s principalnimi komponentami, PCA - Principal component analysis
- Skupni prostorski vzorci, CSP - Common spatial patterns
- Skupna srednja referenca, CAR - Common average referencing
- Bipolarna maska, BM - Bipolar Mask
- Dekompozicija skupnega podprostora, CSSD - Common spatial subspace decomposition
- Normalizacija v frekvenčnem prostoru, Freq-Norm - Frequency normalization
- Drugo





# Prostorski filtri

- $Y(n) = SL ( X(n) )$ , **signali v prostoru komponent**

Varianta: mala, velika Laplace-ova Maska - LM, Sufrace Laplacians - SL

$$y_9(n) = x_9(n) - \frac{1}{4} [x_2(n) + x_8(n) + x_{10}(n) + x_{16}(n)] \quad y_9(n) = x_9(n) - \frac{1}{4} [x_{11}(n) + x_{32}(n) + x_{41}(n) + x_{49}(n)]$$







# Prostorski filtri

- $Y(n) = W X(n)$ , **signali v prostoru komponent**
- Varianta: **Analiza Neodvisnih Komponent - ANK, Independent Component Analysis - ICA, (ne)nadzorovana metoda**
  - **Podatkovno vodeni prostorski filtri za vsak subjekt posebjaj**
  - **Metoda ANK naredi dekompozicijo signalov v statistično neodvisne komponente**
  - Če predpostavimo, da je v možganskem signalu  $S(n)$  prisotnih  $N$  medsebojno statistično neodvisnih izvornih toda neznanih virov in imamo  $N$  merjenih signalov  $X(n)$ , ki pa so rezultat sprotnega in linearne mešanja signalov neznanih virov,  $S(n)$ , potem velja
$$X(n) = A S(n),$$
kjer je  $A$  časovno invariantna mešalna matrika ( $N \times N$ ) katere elementi morajo biti ocenjeni preko merjenih signalov  $X(n)$ .



# Prostorski filtri

- $Y(n) = W X(n)$ , signali v prostoru komponent
  - Varianta: Analiza Neodvisnih Komponent - ANK, Independent Component Analysis – ICA, *(ne)nadzorovana metoda*
  - **Kdaj lahko ocenimo ANK komponente (naredimo dekompozicijo) ?**
    - Če so  $S(n)$  medsebojno neodvisni
    - Če  $S(n)$  niso distribuirani po Gauss-u
    - (Če je število neodvisnih komponent enako število snemanih signalov)
- **Potem lahko identificiramo matriko  $W$  in mešalno matriko  $A \approx W^{-1}$**



# Prostorski filtri

- $Y(n) = \mathbf{W} X(n)$ , **signali v prostoru komponent**
- Varianta: **Analiza Neodvisnih Komponent - ANK, Independent Component Analysis – ICA, (ne)nadzorovana metoda**
- Metoda ANK (*npr. kanonična korelacijska analiza*) z uporabo signala  $\mathbf{X}$  ( $N \times M$ ),  $n = 1, \dots, M$ , izračuna matriko  $\mathbf{W}$  ( $N \times N$ ) za izračun **ocenjenih časovnih potekov aktivacij neodvisnih ANK komponent**  $Y(n)$

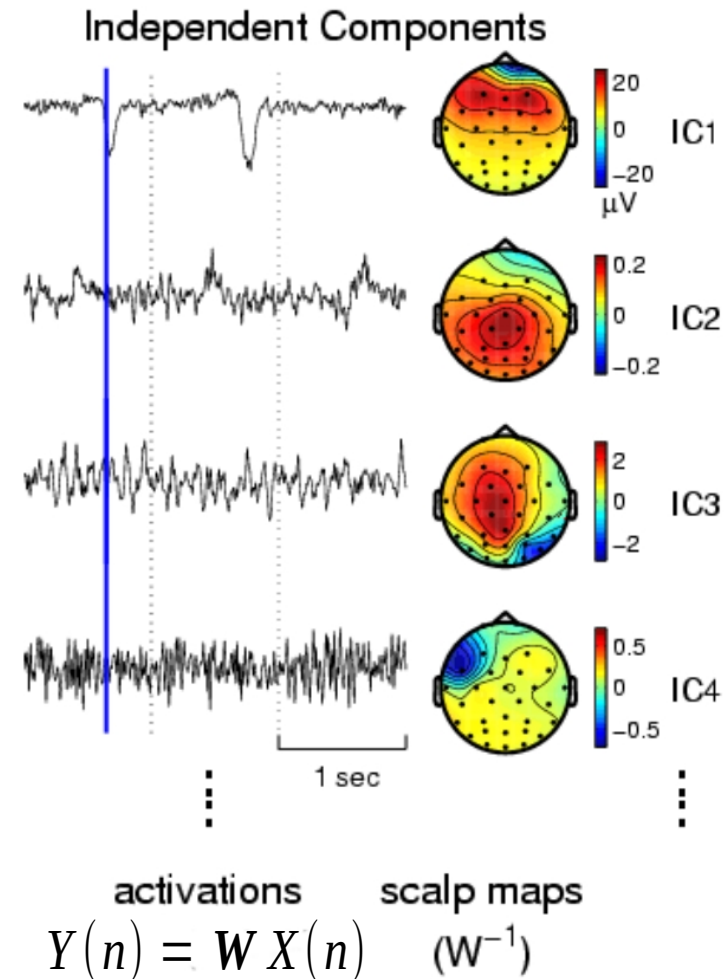


$$Y(n) = \mathbf{W} X(n) = \mathbf{W} \mathbf{A} S(n) = S'(n) \approx S(n)$$

- Po dekompoziciji signalov z uporabo ANK v prostoru komponent izberemo  $P$  relevantnih ANK komponent  $\mathbf{Y}$  ( $\mathbf{W}^{-1}$  ( $N \times P$ ),  $\mathbf{Y}$  ( $P \times M$ )) in jih uporabimo za inverzno transformacijo v prostor signalov

$$\tilde{\mathbf{X}}(n) = \mathbf{W}^{-1} \mathbf{Y}(n)$$

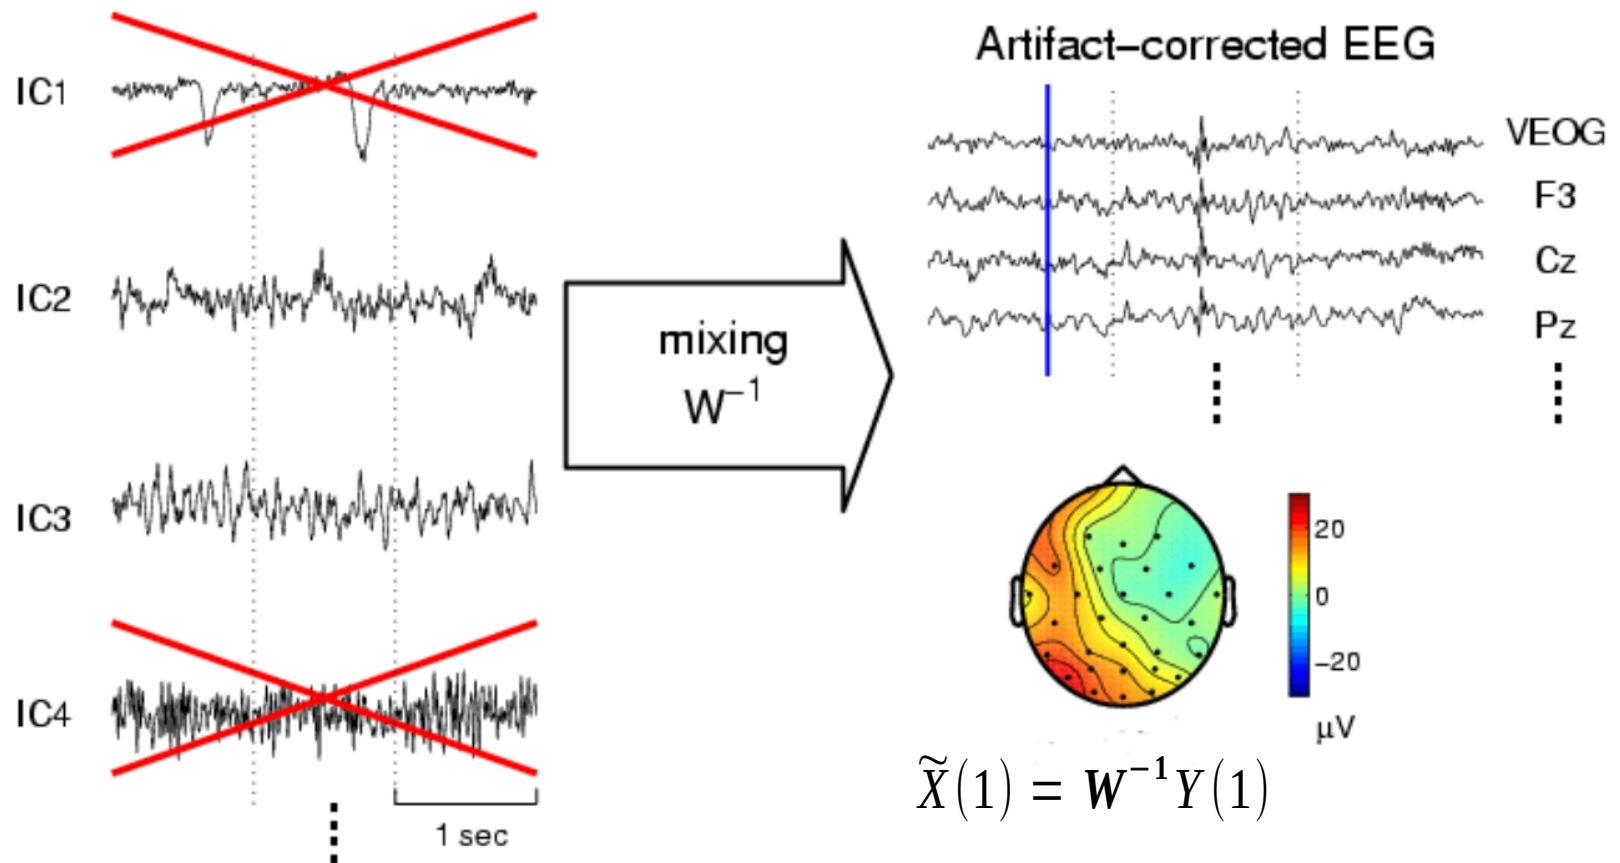
# Prostorski filtri

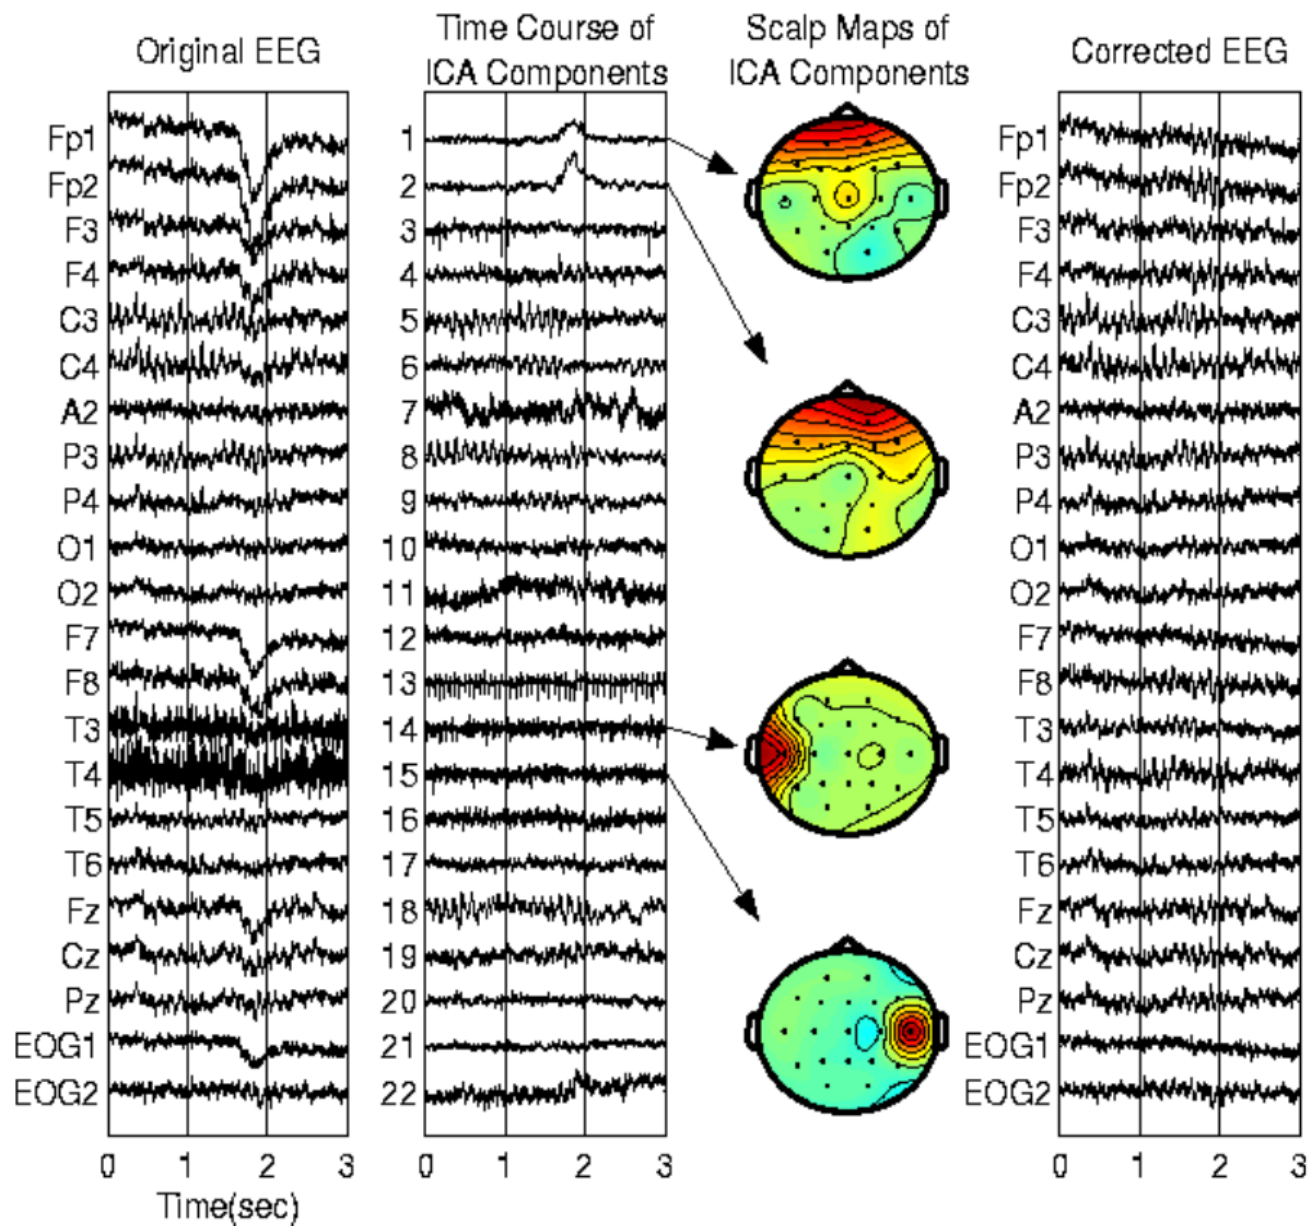
- Kolone v  $W^{-1}$  povedo relativno moč projekcije neznanih virov (neodvisnih ANK komponent) pri vsaki elektrodi
- V smislu topografskih distribucij povedo kje ležijo fiziološki viri neznanih virov (lokalizacija, separacija virov)



# Prostorski filtri

## Summed Projection of Selected Components

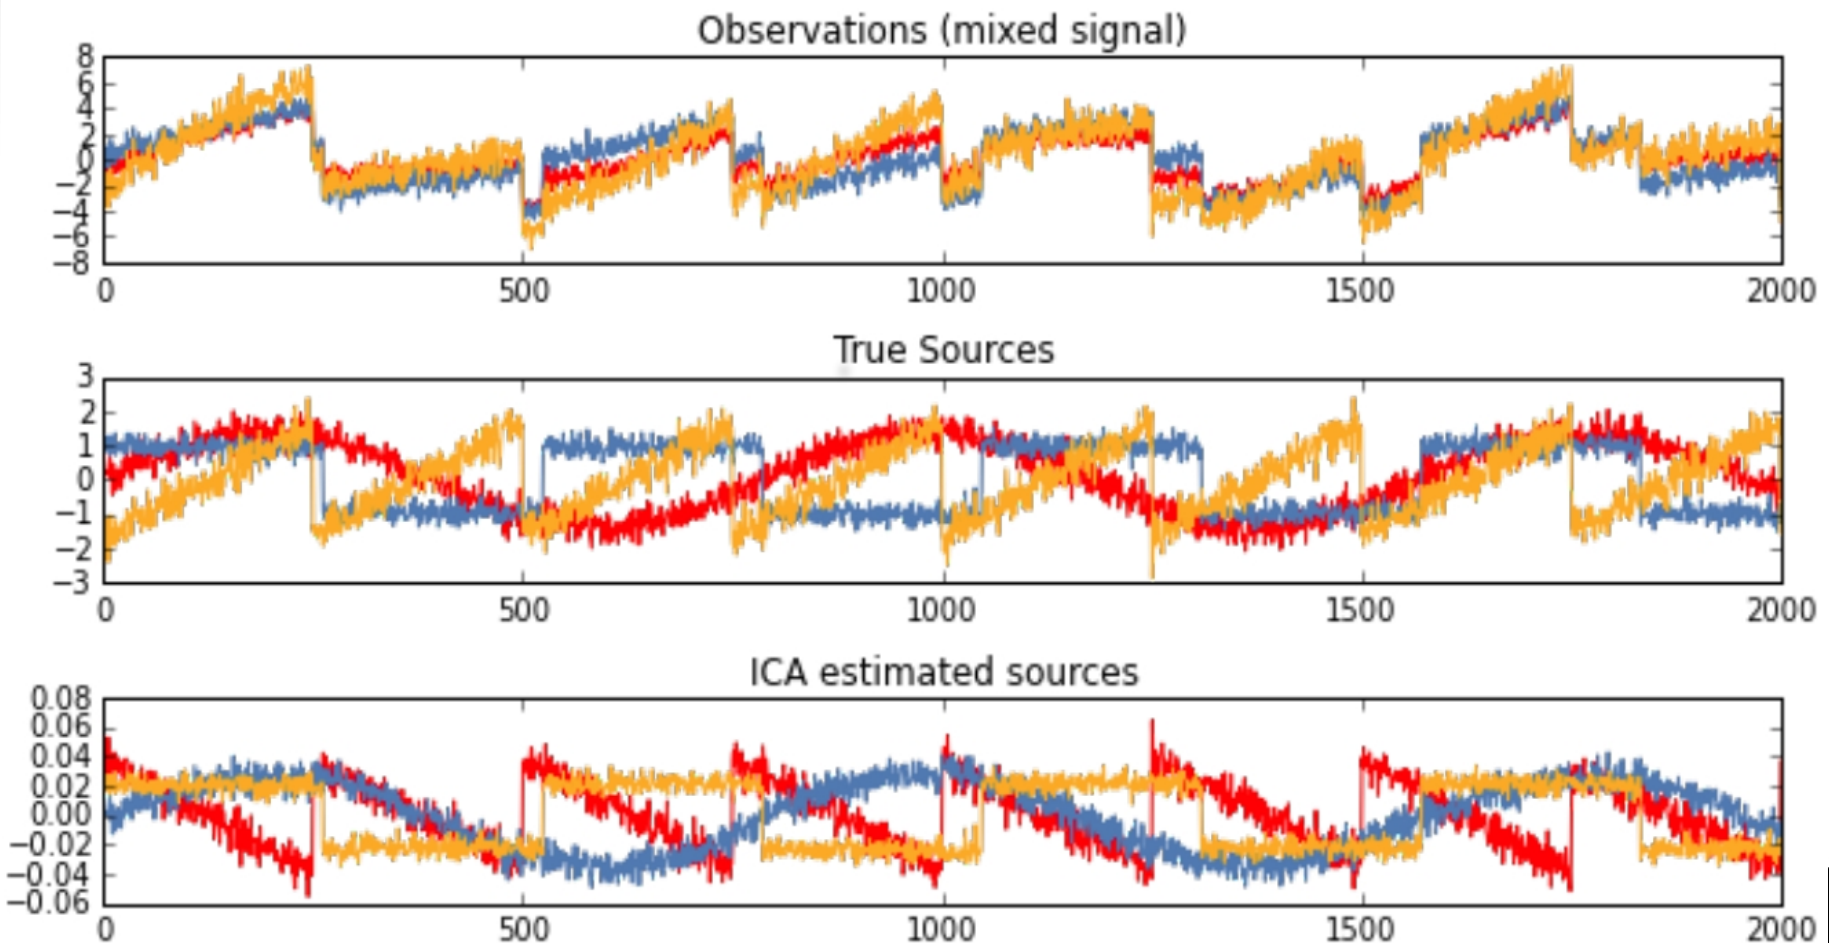






# Prostorski filtri

- Varianta: Analiza neodvisnih komponent – ANK, (*Sintetični primer*)





# Prostorski filtri

- $Y(n) = \mathbf{W} X(n)$ , signali v prostoru komponent
- Varianta: Analiza s Principalnimi Komponentami - APK, Principal Component Analysis – PCA, *(ne)nadzorovana metoda*
- **Podatkovno vodeni prostorski filtri za vsak subjekt posebj**
- **Metoda APK naredi dekompozicijo signalov v nekorelirane komponente z maksimalno varianco**
- Če je  $\mathbf{X} (N \times M)$ ,  $n = 1, \dots, M$ , večkanalni signal, potem zgradimo matriko  $\mathbf{V} (N \times N)$ ,  $\mathbf{V} = [ V(1), \dots, V(N) ]$ , v kateri so stolpci  $V(i)$  normirani ortogonalni **lastni vektorji** kovariančne matrike  $\mathbf{C} (N \times N)$ ,  $\mathbf{C} = \mathbf{X} \mathbf{X}^T$ , ki ustrezajo  $N$  različnim lastnim vrednostim,  $\lambda_1, \dots, \lambda_N$ , (v padajočem vrstem redu), kovariančne matrike  $\mathbf{C}$





# Prostorski filtri

- $Y(n) = \mathbf{W} X(n)$ , signali v prostoru komponent
- Varianta: Analiza s Principalnimi Komponentami - APK,  
Principal Component Analysis – PCA, (ne)nadzorovana metoda
- **Podatkovno vodeni prostorski filtri za vsak subjekt posebj**

- Transformacija APK je potem definirana z ( $\mathbf{W} = \mathbf{V}^T$ )

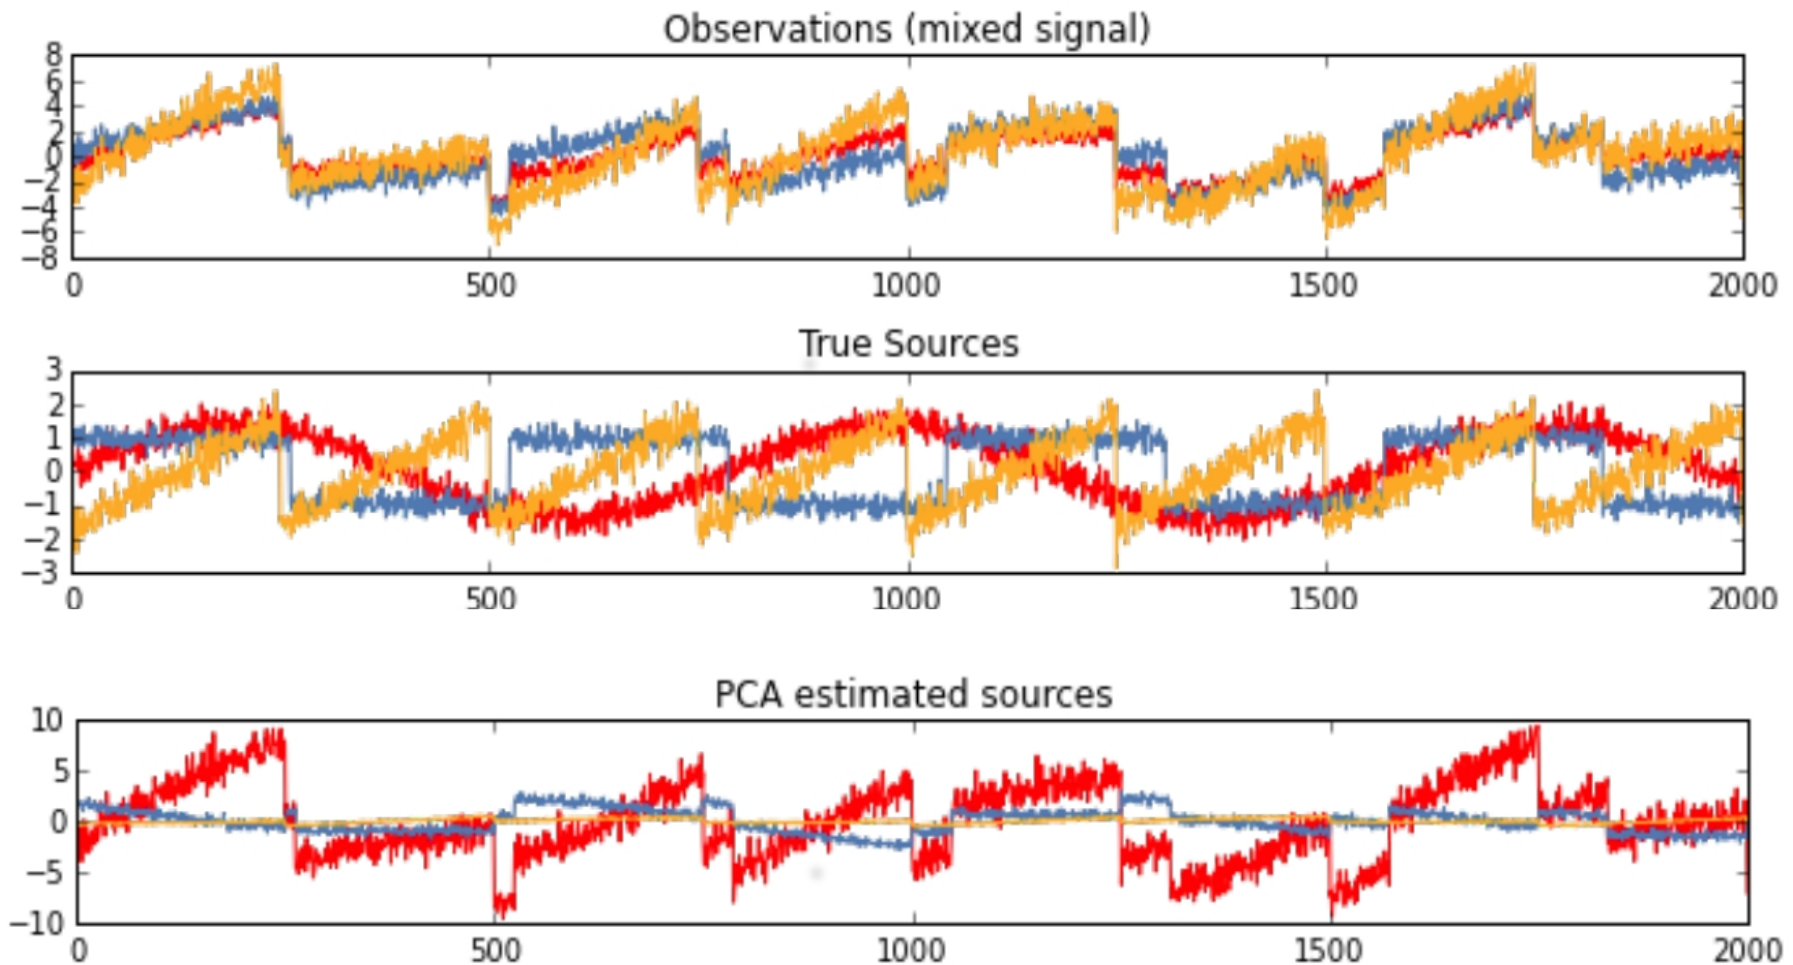
$$Y(n) = \mathbf{W} X(n)$$

- Vrstice v transformiranem izhodnem signalu  $Y$  so **nekorelirane** med sabo
- APK maksimizira varianco prve komponente v prostoru komponent
- **Izberemo le prvih  $P$  dominantnih kolon v  $V$  oziroma prvih  $P$  dominantnih vrstic v  $W$**  (komponente z najvišjimi lastnimi vrednostmi odražajo najvišje variance moči možganskih signalov)



# Prostorski filtri

- Varianta: Analiza s Principalnimi Komponentami - APK, (*Sintetični primer*)





# Prostorski filtri

- $S(n) = W X(n)$ , **signali v prostoru komponent**  
Varianta: **Skupni Prostorski Vzorci - SPV, Common Spatial Patterns – CSP, nadzorovana metoda**
  - **Podatkovno vodeni prostorski filtri za vsak subjekt posebjaj**
  - **SPV najde transformacijo, ki maksimizira varianco signalov enega stanja in simultano minimizira varianco signalov drugega stanja**
  - Koeficienti v  $W$  maksimizirajo razmerje v variancah dveh različnih stanj (dve različni mentalni nalogi) oziroma v dveh različnih razredih
  - Če je  $X (N \times M)$ ,  $n = 1, \dots, M$ , večkanalni signal, potem vsebuje prva SPV komponenta, prva vrstica v  $W X$ , največ variance razreda 1 (in najmanj razreda 2), medtem ko vsebuje zadnja komponenta, zadnja vrstica v  $W X$ , najmanj variance razreda 1 (in največ razreda 2)

$$S(n) = W X(n)$$

# Prostorski filtri

- $S(n) = \mathbf{W} X(n)$ , **signali v prostoru komponent**

Varianta: **Skupni Prostorski Vzorci - SPV, Common Spatial Patterns – CSP**

- SPV uporablja prostorske filtre  $\mathbf{W}$ , ki **ekstremizirajo** (maksimizirajo in minimizirajo) naslednjo funkcijo (Rayleigh-ev količnik):

$$J_{CSP}(\mathbf{W}) = \frac{\mathbf{W} \mathbf{X}_1 \mathbf{X}_1^T \mathbf{W}^T}{\mathbf{W} \mathbf{X}_2 \mathbf{X}_2^T \mathbf{W}^T} = \frac{\mathbf{W} \mathbf{C}_1 \mathbf{W}^T}{\mathbf{W} \mathbf{C}_2 \mathbf{W}^T} = \frac{\text{var}(\mathbf{W} \mathbf{X}_1)}{\text{var}(\mathbf{W} \mathbf{X}_2)}$$

kjer sta  $\mathbf{X}_i$  matriki signalov razredov 1 in 2 ter  $\mathbf{C}_i$  kovariančni matriki signalov razredov 1 in 2 (*v praksi: povprečni kovariančni matriki*),

$\mathbf{W} \mathbf{X}_i$  je prostorsko filtriran signal razreda  $i$  in

$\mathbf{W} \mathbf{X}_i \mathbf{X}_i^T \mathbf{W}^T$  je varianca (moč) prostorsko filtriranega signala razreda  $i$

- Ekstremizacijo  $J_{CSP}(\mathbf{W})$  izvršimo s splošno dekompozicijo lastnih vrednosti (Generalized Eigen Value Decomposition – GEVD) matrik  $\mathbf{C}_i$



# Prostorski filtri


- $S(n) = \mathbf{W} X(n)$ , **signali v prostoru komponent**  
Varianta: **Skupni Prostorski Vzorci - SPV, Common Spatial Patterns – CSP**
- **prostorski filtri  $\mathbf{W}$  so potem tisti lastni vektorji**, ki ustrezajo najvišjim in najnižjim lastnim vrednostim kovariančnih matrik  $\mathbf{C}_1$  in  $\mathbf{C}_2$  po ekstremizaciji
- Tipično vzamemo 6 filtrov (tri pare), ki ustrezajo trem najvišjim in trem najnižjim lastnim vrednostim matrik  $\mathbf{C}_1$  in  $\mathbf{C}_2$  ter zgradimo skupno matriko  $\mathbf{W}$  ( $P \times N$ ;  $P =$  število filtrov,  $P = 6$  ali  $P = 4$ ).
- Ko so **filtri (vrstice v  $\mathbf{W}$ )** dobljeni, so definirani signali v prostoru komponent  $\mathbf{S}$  ( $P \times M$ )

$$\mathbf{S} = \mathbf{W} \mathbf{X} \quad S(n) = \mathbf{W} X(n)$$



# Prostorski filtri

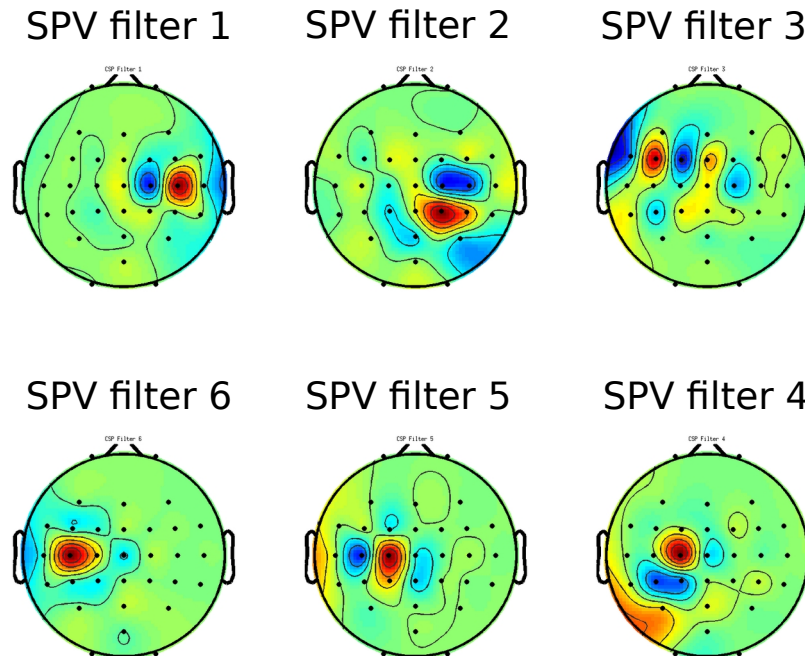
- $S(n) = W X(n)$ , **signali v prostoru komponent** (Skupni Prostorski Vzorci - SPV)
  - Filtra 1 in 2: maksimizacija variance razreda 1 (zamišljanje aktivnosti leve roke)  
in minimizacija variance razreda 2 (zamišljanje aktivnosti desne roke)
  - filtra 4 in 3: maksimizacija variance razreda 2 (zamišljanje aktivnosti desne roke)  
in minimizacija variance razreda 1 (zamišljanje aktivnosti leve roke)



# Prostorski filtri

- $S(n) = \mathbf{W} X(n)$ , Skupni Prostorski Vzorci – SPV
  - **Topografske distribucije SPV filtrov** (vrstice v  $\mathbf{W}$ ),  $\mathbf{W}$  ( $P \times N$ ,  $P = 6$ )
  - Koeficienti filtrov razlagajo kateri kanali so pomembni pri izločanju značilnosti virov signalov

Zamišljanje  
aktivnosti  
leve strani




Zamišljanje  
aktivnosti  
desne strani

# Prostorski filtri


- $S(n) = \mathbf{W} X(n)$ , Skupni Prostorski Vzorci – SPV  $X(n) = \mathbf{W}^{-1} S(n)$  ( $N \times M$ )
  - **Topografske distribucije SPV vzorcev** (kolone v  $\mathbf{W}^{-1}$ ),  $\mathbf{W}^{-1}$  ( $N \times P$ ,  $P = 6$ )
  - Koefficienti SPV vzorcev razlagajo prispevke vzorcev k posameznim kanalom, oziroma razlagajo kateri viri so pomembni (in kje približno so) pri generaciji mešanih signalov  $\mathbf{X}$ . **SPV vzorci dajo skupno oceno o distribuciji intenzitet možganskih ritmov med zamišljanjem motoričnih aktivnosti.**

Zamišljanje  
aktivnosti  
leve strani


SPV vzorec 1



SPV vzorec 2




SPV vzorec 3




$\mathbf{W}^{-1}$

Zamišljanje  
aktivnosti  
desne strani


SPV vzorec 6



SPV vzorec 5



SPV vzorec 4






# Prostorski filtri

- Prostorski filtri,  $S(n) = \mathbf{W} X(n)$ , so inverzne operacije.


$$S(n) = \mathbf{W} X(n)$$

$$X(n) = \mathbf{W}^{-1} S(n)$$


SPV filter 1




SPV filter 2




SPV filter 3




SPV vzorec 1




SPV vzorec 2




SPV vzorec 3




SPV filter 6




SPV filter 5




SPV filter 4




SPV vzorec 6



SPV vzorec 5




SPV vzorec 4



# Prostorske značilke

$W (P \times N, P = 4)$



- SPV značilke  $f(n)$  (znotraj danega okna, ali drsečega okna !) so potem dane z:

$$f = \text{var}(W X) \quad f(n) = \text{Var}(W X) \quad \text{ali} \quad f(n) = \log(\text{Var}(W X))$$

# Tipične arhitekture VMR

