

Úvod do neurovied

Informácie k zadaniu 1



Neurofyziologicalké dáta


Prvé zadanie:

Ryba *Eigenmannia* (Wessel et al., 1996)

- má špeciálny orgán, ktorým generuje slabé oscilujúce elektrické pole s frekvenciou niekoľko sto Hz
- má elektrosenzorický orgán, citlivý na takéto elektrické pole
- používa ho pre elektrolokalizáciu a komunikáciu

Experiment:


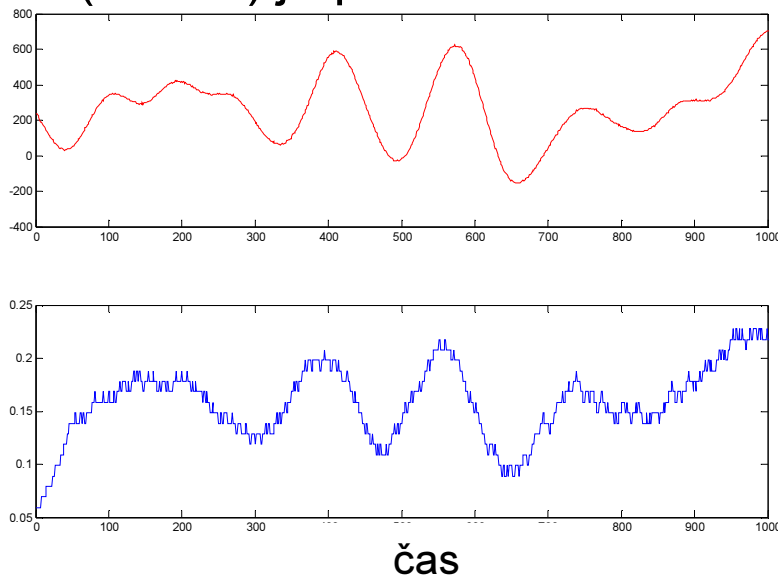
- umelo generované elektrické pole (amplitúdovo modulovaný sin signál) - červená 
- zaznamenáva sa aktivita neurónu v elektrosenzor. orgáne – modrá 
- Čo s tým???



Neurofyziological data – 1. zadanie

Tri vektory:

- čas (time, v milisek.), modulačný signál (stim), neurónové impulzy (rho)
- predošlý obrázok ukazuje signál a impulzy počas prvých 0.5 sek.
- pravdepodobnosť impulzu sa dá odvodiť konvolúciou s pravouhlým kernelom (viď neskôr)
- závislosť medzi signálom (**červená**) a pravdepodobnosťou impulzu (**modrá**) je približne lineárna



Neurofyziologicalké dáta – 1. zadanie

Takúto závislosť môžeme popísať lineárnym modelom:

$$y_i \approx a + bx_i$$

- kde y je pravdepodobnosť impulzu, x je stimul, a je priesečník priamky s osou Y , a b je smernica priamky
- a , b sú hľadané parametre modelu
- lineárny model je najpoužívanejším modelom vo všetkých disciplínach
- tento popis nebude bezchybný, dve hlavné príčiny: šum pri meraní a nelinearita dát
- štandardná metóda hľadania optimálneho a a b je metóda najmenších štvorcov, ktorá minimalizuje chybu:

$$E = \sum_{i=1}^m \frac{1}{2} (a + bx_i - y_i)^2$$

Neurofyziological data – 1. zadanie

- Definovaním podmienky, že parciálne derivácie E podľa a a b musia byť rovné 0 vznikne systém dvoch lineárnych rovníc o dvoch neznámych

$$ma + b \sum_i x_i = \sum_i y_i$$

$$a \sum_i x_i + b \sum_i x_i^2 = \sum_i y_i x_i$$

- substitúciou strednej hodnoty $\langle x \rangle$, druhého momentu $\langle x^2 \rangle$, a korelácie $\langle xy \rangle$ sa rovnica zjednoduší na

$$\langle x \rangle = \frac{1}{m} \sum_{i=1}^m x_i$$

$$\langle x^2 \rangle = \frac{1}{m} \sum_{i=1}^m x_i^2$$

$$\langle y \rangle = \frac{1}{m} \sum_{i=1}^m y_i$$

$$\langle xy \rangle = \frac{1}{m} \sum_{i=1}^m x_i y_i$$

$$\begin{aligned} a + b\langle x \rangle &= \langle y \rangle \\ a\langle x \rangle + b\langle x^2 \rangle &= \langle xy \rangle \end{aligned}$$

- túto sústavu vyriešime vyjadrením a z prvej rovnice:

$$a = \langle y \rangle - b\langle x \rangle$$

Neurofyziologicalké dáta – 1. zadanie

- čím získame riešenie pre b v tvare:
- menovateľ tohto zlomku sa nazýva variancia (rozptyl) a udáva ako veľmi sa menia hodnoty x
- čitateľ sa nazýva kovariancia, a udáva vzájomnú závislosť medzi x a y .
- čiže na to, aby sme našli optimálny lineárny vzťah dvoch premenných, stačí nám vydeliť ich kovarianciu $\text{Cov}(x,y)$ a varianciu $\text{Var}(x)$.
- ďalší krok je už len dosadenie do rovnice pre výpočet a
- v MATLABe sa na určenie koeficientov optimálneho lineárneho modelu používa funkcia `polyfit`

$$b = \frac{\langle xy \rangle - \langle x \rangle \langle y \rangle}{\langle x^2 \rangle - \langle x \rangle^2}$$

Neurofyziologicalké dáta – 1. zadanie

- na vyhodnotenie lineárneho modelu sa používa korelačný koeficient r :

$$r = \frac{\langle xy \rangle - \langle x \rangle \langle y \rangle}{\sqrt{\langle x^2 \rangle - \langle x \rangle^2} \sqrt{\langle y^2 \rangle - \langle y \rangle^2}}$$

- r blízke ± 1 hovorí, že lineárny model je dobrý, r blízke 0 hovorí, že nie
- r je vlastne kovariancia normalizovaná súčinom štandardných odchýliek
- často sa na hodnotenie lineárneho modelu používa r^2 , ktoré hovorí, akú časť variancie v dátach je daný lineárny model schopný vysvetliť

Neurofyziologické dáta – vysvetlený zlomok variancie

Náš lineárny model je optimálny v zmysle najmenších štvorcov, t.j., chybu sme v ňom definovali ako varianciu odchýlky dát od priamky $ax+b$:

$$E = \sum_{i=1}^m \frac{1}{2} (a + bx_i - y_i)^2$$

Táto variancia (t.j., táto chyba) je nulová len keď je model dokonalý.

Význam korelačného koeficientu sa dá chápať tak, že tento koeficient meria pokles vo variancii (t.j., v chybe), ktorý získame použitím lineárneho modelu dát (model prvého rádu) oproti použitiu konštanty (čo by bol model nultého rádu). Aby sme našli najlepší model nultého rádu, stačí ak v hore uvedenej rovnici dáme $b=0$. E je v tomto prípade minimálne pre $a=\langle y \rangle$ (stredná hodnota y). Konkrétne bude hodnota E priamo úmerná variancii y .

Pri hľadaní najlepšieho modelu prvého rádu hľadáme hodnoty dvoch premenných a a b tak, aby sme minimalizovali E . Hodnota E sa v porovnaní s modelom nultého rádu zníži. A pomer tejto novej hodnoty E k tej starej je rovný $1-r^2$. To znamená, že r^2 vyjadruje zlomok variancie v y , ktorý bol vysvetlený pridaním lineárneho člena b do modelu.

Konvolúcia

- pre dva nekonečné časové rády, g_j a h_j , sa konvolúcia definuje ako

$$(g * h)_i = \sum_{j=-\infty}^{\infty} g_{i-j} h_j$$

- ak sú rády konečné, používa sa pri konvolúcii doplnenie nulami, alebo cyklické opakovanie rádoov. Po doplnení nulami sa rovnica zmení na:

$$(g * h)_i = \sum_{j=0}^{n-1} g_{i-j} h_j$$

- aj keď rády g a h sú v rovnici rovnocenné, typicky sú ich funkcie odlišné: jeden z nich je zvyčajne dlhý, a reprezentuje signál, zatiaľčo druhý je krátky, koncentrovaný okolo 0, a nazýva sa filter alebo konvolučný kernel (jadro, maska)

Konvolúcia a pravdepodobnosť impulzov

- ak má g_i dĺžku m a h_i dĺžku n , potom výsledok konvolúcie má dĺžku $m+n-1$
- $(g*h)_0$ sa vypočíta ako

\cdots	g_{m-1}	\cdots	g_1	g_0	0	0	0	0	\cdots
\cdots	0	\cdots	0	h_0	h_1	\cdots	h_{n-1}	0	\cdots
- $(g*h)_1$ sa vypočíta ako

\cdots	0	g_{m-1}	\cdots	g_1	g_0	0	0	0	\cdots
\cdots	0	\cdots	0	h_0	h_1	\cdots	h_{n-1}	0	\cdots
- v MATLABe sa na výpočet konvolúcie používa funkcia `conv`
- na výpočet pravdepodobnosti impulzov zo zaznamenanej sekvencie impulzov sa používa konvolúcia v tvare:

$$p_i = \sum_j \rho_{i-j} w_j$$

- kde ρ je binárna sekvencia impulzov, w je jadro splňajúce podmienku, že $\text{suma}(w)=1$, a p je pravdepodobnosť impulzov. Najjednoduchšie jadro, ktoré spĺňa túto podmienku je pravoúhle jadro s dĺžkou n a hodnotou $1/n$