

A6M33NIN — instrukce ke cvičení

autoři:

Eduard Bakstein^o, Daniel Novák
<http://nit.felk.cvut.cz>, 2012

^ocvičící pro LS 2011/2012

25. dubna 2012

Toto je podpůrný text pro cvičení v rámci magisterského předmětu A6M33NIN. Pro zájemce o hlubší znalost lze doporučit knihu [2], která je dobře čitelná. Česká kniha [1] je přehledová a zpracovává látku z lékařského hlediska.

Obsah

1 Numerické metody	1
2 Modelování membrány a synapse 1 - jednodušší modely	2
3 Modelování membrány a synapse 2 - Hodgkin Huxley a Wilsonův model	4
4 Modelování spiketrains	7
5 Simulace neuronových sítí	9
6 Hebbovské učení	10
7 Self organizing maps	11

1 Numerické metody

Příklad 1.1 Úkolem je numericky derivovat funkci $\frac{dx}{dt} = t - x + 1$ pomocí Eulerovy metody (1 a 2 řádu) a metody Runge-Kutta pro následující počáteční podmínky $x(0) = 1$.

Úkol 1.1 (2 b) Vykreslete řešení $x(t) = f(t)$ pro $t = 0, \dots, 2s$ pomocí Eulerovy x_{Euler} , Runge-Kutta x_{Runge} a analytické metody x_{exact} , jednak grafem, jednak ve formě tabulky (nápověda: složte vektory $t, x_{Euler}, x_{Runge}, x_{exact}$ do jedné matice).

Úkol 1.2 (1 b) Vykreslete závislost $|x_{exact} - x_{Euler}| = f(t)$ pro $t = 0, \dots, 2s$

Úkol 1.3 (1 b) Vykreslete závislost $|x_{exact} - x_{Euler}| = f(\Delta t)$ pro různou délku integračního kroku $\Delta t = 0, \dots, 1$ s v čase $t = 1$ s


Poznámka: Runge-Kutta metoda je implementována v Matlabu pomocí funkce `ode45`.

2 Modelování membrány a synapse 1 - jednodušší modely

Příklad 2.1 (RC model) Namodelujte chování membrány pomocí RC členu - viz obrázek 1. Vstupní proud membrány I_{stim} je obdélníkový signál $10pA$ po dobu $20ms$. Je nutné stimulační proud převést na stejné jednotky jako proudy I_{Cl} a I_C , které jsou vztaženy k ploše elektrody¹, která současně stimuluje a snímá proudy buňky v cm^2 . Tedy $I'_{stim} = I_{stim}/A \approx 10^{-11} \cdot 10^6 \approx 10^{-5}$. Parametry membrány jsou následující:

kapacita membrány: $C_m = 1 \mu F/cm^2$,
 vodivost membrány: $g_{Cl} = 0.3 ms/cm^2$,
 časová konstanta: $\tau = C_m/g_{Cl}$,
 povrch membrány: $A \approx 1 \cdot 10^{-6} cm^2$
 Nerstův potenciál Cl: $V_{Cl} = -68 mV$,
 počáteční podmínky: $V(0) = 0 mV$, $I_{Cl}(0) = 0 \mu A/cm^2$, $I_C(0) = 0 \mu A/cm^2$.

Úkol 2.1 (2 b) Vykreslete závislost $V(t)$, $I_{Cl}(t)$, $I_C(t)$



Obrázek 1: Model membrány s volným iontovým Cl kanálem

Platí

$$I_C(t) = C_m \frac{dV}{dt}(t) \quad (2.1)$$

$$I_C(t) = \frac{I_{stim}(t)}{A} - I_{Cl}(t) \quad \rightarrow I_{stim} = A \cdot I_C(t) + A \cdot I_{Cl}(t) \quad (2.2)$$

$$I_{Cl}(t) = g_{Cl}(V(t) - V_{Cl}) \quad (2.3)$$

$$\tau \frac{dV}{dt} = V_{Cl} - V(t) + \frac{I_{stim}(t)}{Ag_{Cl}} \quad (2.4)$$

$$\tau = \frac{C_m}{g_{Cl}} \quad (2.5)$$

Eulerova metoda (dopředná)

$$\tau \frac{V(j) - V(j-1)}{dt} = V_{Cl} - V(j-1) + \frac{I_{stim}(j-1)}{Ag_{Cl}} \quad (2.6)$$

$$V(j) = V(j-1) + \frac{dt}{\tau} [V_{Cl} - V(j-1) + \frac{I_{stim}(j-1)}{Ag_{Cl}}] \quad (2.7)$$

¹Ve skutečnosti se tedy jedná o proudové hustoty, které by bylo správnější značit dle konvencí ρ . Pro konzistenci s přednáškami se však přidržíme značení I .

Eulerova metoda (zpětná)

$$\tau \frac{V(j) - V(j-1)}{dt} = V_{Cl} - V(j) + \frac{I_{stim}(j)}{Ag_{Cl}} \quad (2.8)$$


$$V(j)(1 + \frac{dt}{\tau}) = V(j-1) + dt(\frac{V_{Cl}}{\tau} + \frac{I_{stim}(j)g_{Cl}}{Ag_{Cl}C_m}) \quad (2.9)$$

$$V(j) = \frac{V(j-1) + dt(\frac{V_{Cl}}{\tau} + \frac{I_{stim}(j)}{AC_m})}{(1 + \frac{dt}{\tau})} \quad (2.10)$$

Příklad 2.2 (EPSP model) Úkolem je analýza modelu synapse vyobrazené na obrázku 2. Jedná se model se zahrnutím tzv. "excitatory postsynaptic potential"(EPSP), tedy chování membrány dendritu postsynaptického neuronu po přijetí vzruchu. Synapse je namodelována pomocí měnící se konduktivity g_{syn} . Časová konstanta $\tau_{syn} = 1 \text{ mS}$. Konstanty jsou stejné jako v předchozím příkladě. Stimulační proud $I_{stim} = 0$, $V_{syn} = 10 \text{ mV}$. V čase $t = 1 \text{ ms}$ dojde k uvolnění neurotransmitteru, tedy $g_{syn}(1 + \delta) = 1$. Počáteční podmínky $V(1) = 0$, $I_{syn} = 0$, $g_{syn}(1) = 0$, $g_L = 1$.

$$\tau_{syn} \frac{dg_{syn}(t)}{dt} = -g_{syn}(t) + \delta(t - t_{pre} - t_{delay}) \quad (2.11)$$

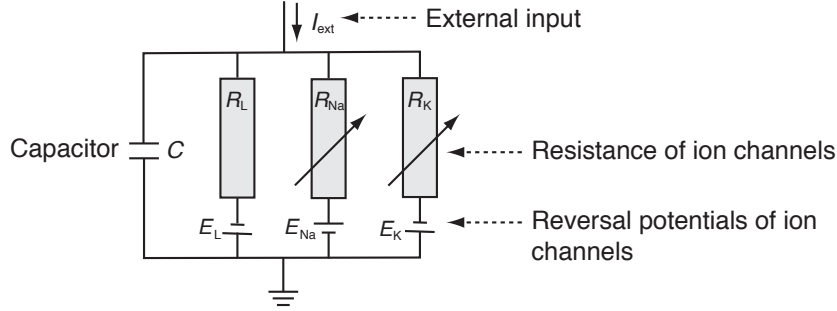
Úkol 2.2 (0 b) Vykreslete závislost $V(t)$, $I_{Cl}(t)$, $I_C(t)$, $I_{syn}(t)$. Vysvětlete souvislosti průběhů ve výsledném grafu a porovnejte je s výsledky Úkolu 2.1.



Obrázek 2: Model synapse s volným iontovým Cl kanálem

3 Modelování membrány a synapse 2 - Hodgkin Huxley a Wilsonův model

Příklad 3.1 (Hodgkin-Huxley) Úkolem je analýza Hodgkin-Huxley(HH) modelu dle schematu na obrázku 3. Na rozdíl od předchozích modelů zahrnuje HH model proměnné závislé nejen na čase, ale také na napětí, tedy Na^+ a K^+ napětím řízené kanály. Model je založen na následující sadě rovnic.



Obrázek 3: Schéma Hodgkin-Huxley modelu. Jednotlivé prvky vyjadřují vždy reverzní potenciál a rezistivitu příslušného typu kanálu: E_L, R_L - stále otevřené kanály ("Leakage channels"), E_{Na}, R_{Na} - sodíkové, napětím řízené kanály, E_K, R_K - draslíkové, napětím řízené kanály. Rezistivita napětím řízených kanálů je funkcí napětí a času.

Proud v iontovém kanálu lze vyjádřit dle Ohmova zákona:

$$I_{ion} = \hat{g}_{ion}(V - E_{ion}) \quad \left(= (V - E_{ion})/\hat{R}_{ion} \right), \quad (3.1)$$

kde \hat{g}_{ion} je maximální hodnota vodivosti daného kanálu, ostatní veličiny pak dle uvedeného schematu.

Dále zavádíme pomocné veličiny, závislé na čase a napětí $n(V, t)$, $m(V, t)$, $h(V, t)$, na jejich základě jsou vyjádřeny vodivosti:

$$g_K(V, t) = g_K n^4 \quad (3.2)$$

$$g_{Na}(V, t) = g_{Na} m^3 h \quad (3.3)$$

Sloučením rovnic 3.3-3.1 dostáváme

$$C \frac{dV}{dt} = -g_K n^4 (V - E_K) - g_{Na} m^3 h (V - E_{Na}) - g_L (V - E_L) + I_{ext}(t) \quad (3.4)$$

Dále definujeme časové konstanty

$$\tau_n(V) \frac{dn}{dt} = -[n - n_0(V)] \quad (3.5)$$

$$\tau_m(V) \frac{dm}{dt} = -[m - m_0(V)] \quad (3.6)$$

$$\tau_h(V) \frac{dh}{dt} = -[h - h_0(V)] \quad (3.7)$$

Pro libovolnou z proměnných dostaneme

$$\frac{dx}{dt} = -\frac{1}{\tau_x(V)} [x - x_0(V)], \quad x \in \{n, m, h\} \quad (3.8)$$

a po řešení pomocí Eulerovy metody konečně dostáváme

$$x(t + \Delta t) = \left(1 - \frac{\Delta t}{\tau_x}\right) x(t) + \frac{\Delta t}{\tau_x} x_0. \quad (3.9)$$

Pro počáteční podmínky pak platí:

$$x(0) = \frac{\alpha}{\alpha + \beta}, \quad \tau_x = \alpha\beta, \quad x \in \{n, m, h\} \quad (3.10)$$

$$\alpha_n = \frac{10 - V}{100 \left(e^{\frac{10-V}{10}} - 1 \right)}, \quad \beta_n = 0.125e^{-\frac{V}{80}} \quad (3.11)$$

$$\alpha_m = \frac{25 - V}{10 \left(e^{\frac{25-V}{10}} - 1 \right)}, \quad \beta_m = 4e^{-\frac{V}{18}} \quad (3.12)$$

$$\alpha_h = 0.07e^{\frac{V}{20}}, \quad \beta_h = \frac{1}{e^{\frac{30-V}{10}} + 1} \quad (3.13)$$

Úkol 3.1 (1 b) Implementaci modelu si stáhněte ze stránek cvičení - soubor `prikklad_2_3.m`. Zobrazte časový výstup modelu (napětí na membráně V), buzeného konstantním napětím $I_{ext} = 60 \mu A/cm^2$ (výchozí nastavení). Implementace pracuje s časem od -30s pro počáteční ustálení systému. Výstup zobrazte pro časy 0 – 100ms.

Úkol 3.2 (1 b) Rozšiřte zobrazení o časové průběhy vodivosti g jednotlivých typů kanálů, vodivosti popište (příkaz `legend`)

Úkol 3.3 (3 b) Nasimulujte a zobrazte závislost frekvence pálení na konstantním externím proudu I_{ext} - tzv. *Aktivační funkci* neuronu modelovaného HH modelem. Vstupní proud I_{ext} uvažujte v rozsahu 0 – 15 $\mu A/cm^2$. Frekvenci pálení počítejte z dostatečně ustáleného úseku časového signálu (nápověda: pomohou fce `diff`, `find` popř. `findpeaks`). Jakou obecnou funkci vám tento průběh připomíná? Při jaké hodnotě I_{ext} se významně mění průběh aktivační funkce (diskutujte).

Úkol 3.4 (3 b) Přidání šumu do budicího proudu způsobí změnu časových vlastností neuronu. Vykreslete časový průběh membránového napětí V a aktivační funkci z předchozích úkolů s přidáním šumu. Pro časový průběh použijte budicí proud $I_{ext} = 30 \mu A/cm^2$ a normální šum (`randn`) o směrodatné odchylce 60, pro aktivační funkci opět rozsah $I_{ext} = \langle 0, 15 \rangle \mu A/cm^2$ a šum o směrodatné odchylce 30. Jak se změnil tvar obou průběhů? Vyzkoušejte pro různé hodnoty šumu.

Úkol 3.5 (bonus) (1 b) Vykreslete ISI histogram (inter-spike-intervalů) pro budicí proud $I_{ext} = 30 \mu A/cm^2$ a šum o směrodatné odchylce 60. Porovnejte s časovým průběhem. Průběhy vysvětlete.

Příklad 3.2 (Wilsonův model) Jak jsme viděli na předchozím příkladě, Hodgkin-Huxleyho model, přesně modelující vlastnosti neuronu krakalice, je velice složitý a neumožňuje rozsáhlejší analytické zkoumání (jak jsme viděli m.j. na příkladu výpočtu aktivační funkce). Později v historii se ukázalo, že úpravami rovnic HH modelu lze dosáhnout obdobných výsledků s výrazně nižší výpočetní složitostí. Za příklady mohou sloužit Wilsonův nebo LIF model. Wilsonovu modelu je věnována tato krátká úloha, o LIF modelu bude řeč později.

Zjednodušené modely musejí z pochopitelných důvodů zahrnovat základní mechanismy Na^+ a K^+ kanálů. Podstatou Wilsonova zjednodušení byla úvaha, že časová konstanta HH modelu τ_m (viz obrázek 4(a)) je velmi malá a tudíž zanedbatelná pro všechny možné hodnoty napětí na membráně a na ní závislá hodnota m se tak rychle blíží maximální hodnotě m , že může být touto hodnotou přímo nahrazena. Wilson dále usoudil, že otevírání K^+ kanálů je v podstatě doplňkem uzavírání Na^+ (viz obrázek 4(b) - n_0 vs h_0) kanálů a můžeme tedy použít další zjednodušení, totiž že $h = 1 - n$. Přestože výsledný model obsahuje pouze 2 následující diferenciální rovnice, je jeho výstup v zásadě srovnatelný s výstupem HH modelu.

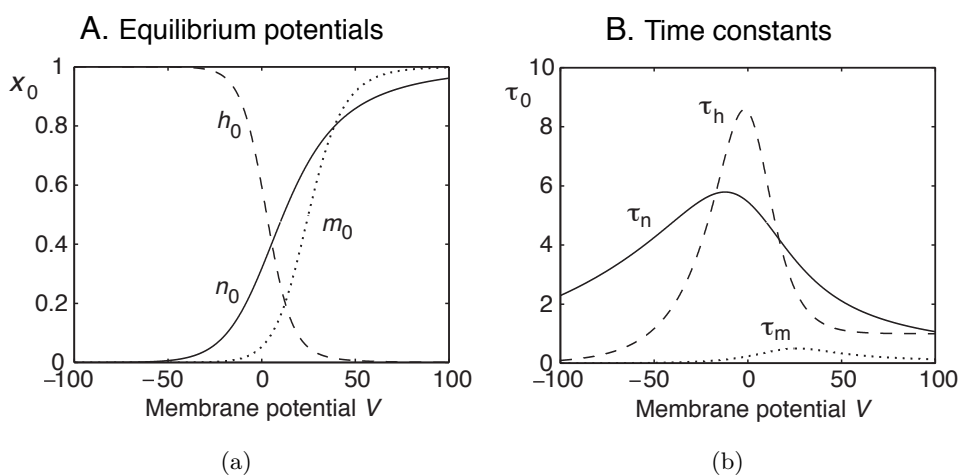
neuron type	$\tau_R[ms]$	g_T	g_H
Fast spiking (FS) neocortex	1.5	0.25	0
Regular spiking (RS)	4.2	0.2	5
Bursting	4.2	2.25	9.5

Tabulka 1: Požadovaná nastavení wilsonova modelu pro simulace z úkolu 3.6

$$C \frac{dV}{dt} = -g_K R(V - E_K) - g_{Na}(V)(V - E_{Na}) + I_{ext}(t)$$

$$\tau_R \frac{dR}{dt} = -[R - R_0(V)]$$

Úkolem tohoto cvičení je prozkoumání chování Wilsonova modelu pro různá nastavení časových konstant.



Obrázek 4: Hodgkin-Huxley: časové konstanty modelu

Úkol 3.6 (1 b) Stáhněte si ze stránek cvičení implementaci Wilsonova modelu pomocí Eulerovy metody - *wilson.m*. Vyzkoušejte modelování chování neuronů pomocí různých nastavení Wilsonova modelu z tabulky 1. Ostatní parametry ponechte ve výchozím nastavení. Výstupy zobrazte a porovnejte s grafy v přednášce 2.

4 Modelování spiketrains

Na předchozích úlozích jsme si ukázali, jaký vliv má šum na vstupu neuronu na jeho časové a frekvenční charakteristiky. Šumový signál na vstupu neuronu podstatně lépe odpovídá praktické situaci než konstantní proud. To je dáno především tím, že vstupem neuronu je součtový signál, tvořený synapsemi mnoha dalších neuronů, zapojenými na jeho dendritech. V tomto oddíle cvičení si takový signál vygenerujeme a prozkoumáme výstup neuronu, na nějž je přiveden.

Na přednáškách jste se dozvěděli, že interspike intervaly (ISI) typických neuronů mozkové kůry vykazují logaritmicko-normální rozdělení. Než se tedy pustíme do modelování spiketrains, zkusme tuto skutečnost ověřit na modelu.

Příklad 4.1 (LIF neuron a lognorm rozdělení (Poissonovský spiketrain)) Modely, kterým jsme se věnovali v předchozích úlohách, jsou schopny velice přesně modelovat tvar akčního potenciálu na základě fyziologického modelu chování iontových kanálů. Chceme-li ale modelovat složitější sítě neuronů, ukazuje se, že i zjednodušené modely (např. Wilsonův m.) jsou pro takové použití zbytečně komplexní. Při modelování sítí neuronů není ani tak podstatný přesný tvar akčního potenciálu (ten, jak si ukážeme později, může být snadno modelován pomocí α funkcí), jako spíše správné modelování časování pálení neuronu. K těmto účelům se využívá jednoduchý *Leaky integrate and fire* neuron, popsáný v přednášce č. 4. Základním principem modelu je jednoduchý integrátor, který se po překročení nastaveného prahu resetuje na klidový potenciál (více v již zmiňované přednášce č. 4)

Úkol 4.1 (1 b) Stáhněte si model LIF neuronu ze stránek cvičení - `lif.m`. Zobrazte výstup modelu pro konstantní vstupní proud (výchozí nastavení). Vykreslete průběh výstupního napětí a okamžiky spikes v čase. Vypočtěte frekvenci pálení a zobrazte ISI histogram.

Úkol 4.2 (2 b) Upravte zadání z předchozího bodu tak, že na vstup přivedete namísto konstantního proudu šum se střední hodnotou 12 a směrodatnou odchylkou 100 (opět využijte funkci `randn`). Simulujte pro časy $0 - 10^5$ s krokem $dt = 0.01$. U ISI histogramu nastavte počet binů na 60. ISI histogram převedte na odhad pravděpodobnostní funkce ($\sum pdf = 1$).

Úkol 4.3 (3 b) Na data z předchozího bodu nařadíte logaritmicko-normální rozdělení. Předpis logaritmicko-normálního rozdělení je dán rovnicí

$$pdf^{lognormal}(x; \mu, \sigma) = \frac{1}{x\sigma\sqrt{2\pi}} e^{-\frac{(\log(x)-\mu)^2}{2\sigma^2}} \quad (4.1)$$

Jedním z možných řešení by tedy bylo použít jako vstup odhad pravděpodobnostní funkce ISI z předchozího bodu a analytickou funkci na něj nařadit pomocí funkce `fminsearch` nebo jí podobných. Vzhledem k tomu, že však jedna hodnota v pravděp. funkci neodpovídá jednomu, ale celé řadě pozorování, byl by takový postup nesprávný. Problematiku nastudujte zde: <http://www.mathworks.com/products/statistics/demos.html?file=/products/demos/shipping/stats/cfitdfitdemo.html#6>.

Z uvedených důvodů využijeme pro fitování funkci `lognfit`, která odhadne parametry rozdělení pomocí metody maximální věrohodnosti. Na základě odhadnutých parametrů vypočtete a zobrazte analytický průběh logaritmicko-normálního rozdělení na ISI pravděpodobnostní funkci. Přesnějšího zobrazení můžete dosáhnout mapř. úpravou počtu binů v histogramu.

Příklad 4.2 (Lognorm spiketrain (obrácená úloha)) V minulém příkladu jsme si ukázali, jak vypadá výstup LIF modelu, buzeného signálem, silně zašuměným gaussovským šumem. Na této úloze si ukážeme, že skutečný signál, vzniklý součtem výstupů (z hlediska přijímajícího neuronu presynaptických potenciálů), Gaussovský šum v mnohém připomíná.

Na přednášce jste se dozvěděli, že vlastností *Poissonovského spiketrainu*, tedy takového, u něž počet pálení za jednotku času má poissonovské rozdělení je, že interspike intervaly (ISI) mají rozdělení exponenciální. Z fyziologických vlastností neuronu dále vyplývá, že je velice nepravděpodobné, aby byly mezi dvěma AP kratší úsek než tzv. refraktorní perioda. I tuto vlastnost tedy ve své implementaci zohledníme.

V tomto komplexním příkladě si tedy vytvoříme sadu spiketrains pomocí exponenciálního rozdělení, respektující refraktorní periodu, se kterou provedeme některé experimenty. Více již v jednotlivých úkolech.

Úkol 4.4 (5 b) Vygenerujte soubor 10000 ISI intervalů pomocí exponenciálního rozdělení se střední hodnotou $E[X] = 50$ (lze použít funkci `expnrnd`). Zobrazte histogram hodnot.

Z dat odfiltrujte ISI, které budou menší než refraktorní perioda. Ta bude opět modelována jako náhodná veličina s rozdělením $pdf = |N(0, 6)|$.

Opět zobrazte histogram a porovnejte s histogramem před filtrací. Kolik spikes jsme filtrací ztratili? Pro obě rozdělení (před a po filtraci) vypočtěte koeficient variace a mean firing rate a porovnejte.

Výsledné ISI intervaly převedte na spiketrain (logický vektor s jedničkami na pozicích spikes - nápověda: `cumsum`). Použijte časový krok $dt = 0.1ms$. Zkontrolujte správnost výsledku.

Úkol 4.5 (3 b) Abychom z binárního spiketrain získali časový průběh, pomůžeme si konvolucí s $\alpha - funkci$, která obstojně nahradí tvar akčního potenciálu.

Vygenerujte tedy průběh $\alpha - funkce$ podle vzorce:

$$I(t) = c \cdot t \cdot e^{-\frac{t}{t_{peak}}} \quad (4.2)$$

$$c = \frac{g_{peak}}{t_{peak}} e^{-1} \quad (4.3)$$

kde $g_{peak} = 0.5$, $t_{peak} = 1ms$. Průběh funkce vypočtěte pro rozsah časů $t \in \langle 0, 30 \rangle$, opět použijte časový krok $dt = 0.1ms$. Výsledný průběh zobrazte. Po zhodnocení průběhu funkce můžete časový rozsah vhodně zkrátit.

Nyní proveďte konvoluci vypočteného průběhu se simulovaným Poissonovským spiketrain z předchozího úkolu (`conv`). Výsledek opět zkontrolujte zobrazením.

Úkol 4.6 (2 b) Vypočtený časový průběh z minulého úkolu vhodným způsobem rozdělte na 100 stejně dlouhých spiketrains (`reshape`). V tomto úkolu budeme simulovat míchání presynaptických potenciálů, reprezentovaných právě našimi spiketrains, na dendritech neuronu. Výsledný celkový vstupní proud do neuronu bude dán lineární kombinací jednotlivých spiketrains. Koeficienty budou tvořeny vahami w , které si opět zvolíme jako náhodné s rovnoměrným rozdělením (`rand`). Váhy upravte tak, aby jejich celkový počet bylo možno nastavit jednou konstantou k . Hodnotu konstanty zpočátku nastavte na 100.

Za pomoci těchto vah smíchejte rozdělené spiketrains do jediného, který bude představovat součtový signál na vstupu námi zkoumaného neuronu. Signál si zobrazte a prohlédněte. Jak vypadá v porovnání s gaussovským šumem?

Úkol 4.7 (2 b) Signál z minulého úkolu přiveďte na vstup LIF neuronu z příkladu 4.1 a pozorujte výstup. Jsou na výstupu LIF neuronu nějaké spikes? Co se změní když změním konstantu k , udávající součet vah, na 150? Jak nyní vypadá histogram výstupních ISI intervalů? Chování LIF neuronu prozkoumejte a okomentujte.

5 Simulace neuronových sítí

V předchozích příkladech jsme se zabývali modelováním a zkoumáním vlastností jednotlivých neuronů na neuronových modelech. Ukázali jsme si, jak se mění variabilita frekvence pálení neuronu při různých průbězích a směsích presynaptických potenciálů. Jak se předpokládá, je to právě časování akčních potenciálů, jež je nositelem informace v mozku. Abychom se v úlohách opět o stupeň přiblížili komplexitě reálného chování mozku, budeme se v této sekci věnovat studiu chování sítí, složených z mnoha neuronů.

Příklad 5.1 (Spontánní aktivita) V této úloze budeme modelovat spontánní aktivitu náhodné sítě neuronových modelů Izikhewichova typu - reprodukuje výstupy původního Izikhewichova článku (dostupný online zde: <http://www.izhikevich.org/publications/spikes.pdf>). Výstupem úlohy bude velice stručný textový dokument, shrnující v bodech odpovědi na jednotlivé úkoly.

Úkol 5.1 (3 b) Nastudujte Izikhewichův model neuronu z původního článku. Vysvětlete, co znamenají veličiny u a v a k čemu zhruba slouží konstanty a, b, c, d .

Prostudujte spodní dva řádky Fig 2. Co tyto grafy reprezentují? Čím jsou vykreslené průběhy dány?

Úkol 5.2 (3 b) Ze článku si do matlabu zkopírujte zdrojový kód simulace náhodné sítě o 1000 neuronech. Kód si spusťte důkladně prostudujte. Odpovězte na následující jednoduché otázky:

1. Jaké typy neuronů jsou v simulaci použity a v jakých počtech?
2. Jakého rozměru jsou konstanty a, b, c, d a čemu tyto rozměry odpovídají?
3. Co vyjadřuje proměnná S a jakým způsobem implementuje rozdílné typy neuronů?
4. Jak je modelován vstupní proud do jednotlivých typů neuronů?
5. Která část kódu reprezentuje resetování výstupního napětí neuronů po překročení prahu, jak jej definuje rovnice (3)?
6. Kód spusťte a stručně popište výstup, který generuje.

Úkol 5.3 (4 b) Implementaci z článku rozšiřte tak, aby se kromě okamžiků pálení ukládaly také postsynaptické potenciály jednotlivých neuronů. Následně rozšiřte program o následující body, výsledné grafy zkopírujte do reportu.

1. Zobrazte průběh výstupního napětí na libovolných 2 neuronech rozdílných typů. Liší se nějak výrazně tyto průběhy?
2. Zobrazte výkonové frekvenční spektrum zprůměrovaných výstupních napětí celé populace. Spektrum zobrazte v rozsahu $1 - 100\text{Hz}$. Co lze říci o charakteru spektra? Jaká je aktivita sítě z hlediska mozkových vln (co například pásmo Alfa: $8 - 13\text{Hz}$)?

6 Hebbovské učení

V předchozích simulacích jsme pracovali se neuronovou sítí s konstantními náhodnými vahami. Takový přístup ignoruje synaptickou plasticitu, tedy průběžné změny vah jednotlivých synapsí, související s korelací pálení jednotlivých presynaptických neuronů. Toto asociativní Hebbovské učení si ukážeme na následující úloze.

Příklad 6.1 (Hebbovské učení) V tomto příkladě vyjdeme z kódů, naimplementovaných pro příklad 4.2 ("Lognorm spiketrain - obrácená úloha") a příklad obohatíme o úpravy vah pomocí Hebbovského učení. To je založeno na adaptaci vah presynaptických neuronů, jejichž aktivita koreluje s postsynaptickým výstupem (tj. pálením neuronu, o jehož synaptické váhy se jedná). budeme upravovat podle následující rovnice:

$$w_{n+1} = w_n + \delta w - f_{decay}, \quad (6.1)$$

kde w_n jsou aktuální hodnoty synaptických vah, f_{decay} je konstanta zapomínání a δw je změna vypočtená z následující rovnice:

$$\delta w = \alpha_{learn} \cdot pm \cdot e^{pm \frac{\Delta t}{\tau}} \quad (6.2)$$

$$\Delta t = t_{post} - t_{pre} \quad (6.3)$$

$$pm = -sign(\Delta t) \quad (6.4)$$

Úkol 6.1 (3 b) Implementujte funkci adaptace vah dle rovnice 6.2. Parametry zvolte $\tau = 40$, $\alpha = 1$, rozdíly časů post a presynaptických AP volte v rozsahu $(-100, 100)ms$. Funkci pro daný rozsah časových rozdílů zobrazte v grafu (nezapomeňte popsat osy!). Výsledek komentujte.

Úkol 6.2 (7 b) V tomto úkolu použijeme kód pro LIF neuron buzený šumovým signálem z příkladu 4.2. Kód doplňte o adaptaci vah pomocí Hebbovského učení. Váhy budete upravovat pokaždé, když zaznamenáte na výstupu LIF neuronu AP. Konstanty volte stejné jako v předchozím úkolu, navíc nastavte konstantu zapomínání na $f_{decay} = 0.01$ a v kódu upravte počáteční sumu vah $k = 600$.

Zobrazte časový průběh součtového pre-synaptického potenciálu v čase včetně AP, generovaných LIF neuronem. Dále zobrazte vývoj vah v čase (lze použít např. `imagesc`). Jak se mění hodnoty vah během prvních 500ms? A jak v následujícím čase? Experimentujte s nastavením parametrů učení a výsledky komentujte.

7 Self organizing maps

Toto cvičení bude (doufám) oddychové. Zkusíme si metody clusterování pomocí samoorganizujících map (SOM, někdy také Kohonenovy sítě). Využijeme implementaci v Matlab Neural Network Toolbox.

Příklad 7.1 (Iris dataset) V úloze využijeme klasický dataset Iris http://en.wikipedia.org/wiki/Iris_flower_data_set, představující naměřené parametry okvětních lístků několika na pohled obtížně rozlišitelných druhů kosatců.

Úkol 7.1 Provedte shlukování dat iris za pomoci samoorganizující mapy. Výsledky vhodně vizualizujte. Postupujte podle následujícího návodu:

1. Načtěte iris dataset z repozitáře matlabu pomocí `load iris_dataset`. Načtou se pole `irisInputs` (samotná data) a `irisTargets` (skutečné třídy - druhy kosatců, označené expertem)
2. Inicializujte samoorganizující mapu: `net = selforgmap([8 8], "topologyFcn", "hextop");`. Co znamenají jednotlivé parametry? Co znamená `topologyFcn` a jaké možnosti toolbox nabízí. Vyzkoušejte různé topologie a zobrazte je pomocí `plotsomtop`.
3. Naučte síť na Iris datech pomocí `net = train(net, irisInputs);`
4. Zobrazte jednotlivé neurony jako pozici v prostoru vah - `plotsompos`
5. Zobrazte počty "zásahů"(hits) jednotlivých neuronů pomocí `plotsomhits`. Zobrazte stejné grafy pro jednotlivé třídy (jako parametr vložíte data, která vytřídíte na základě `irisTargets`). Grafy porovnejte.
6. Vyzkoušejte další možnosti vizualizace SOM (lze použít grafické okno, které se otevře během učení.)

Příklad 7.2 (Shlukování samohlásek - bonus) Předmětem úlohy je shlukování vyslovaných samohlásek pomocí SOM a vizualizace jejích výstupů. Jedná se o bonusovou úlohu, pokud už jste předchozí úkoly splnili, pusťte se do ní!

Úkol 7.2 Z UCI machine learning repository si stáhněte veřejně dostupný dataset "Vowel Recognition"[http://archive.ics.uci.edu/ml/datasets/Connectionist+Bench+\(Vowel+Recognition+-+Deterding+Data\)](http://archive.ics.uci.edu/ml/datasets/Connectionist+Bench+(Vowel+Recognition+-+Deterding+Data)). Potřebujete především soubor `vowel-context.data`, ostatní slouží pro porozumění datům.

Soubor načtěte do matlabu pomocí `D = importdata cesta-k-souboru/vowel-context.data`. Instance dat (příklady) jsou v souboru v řádcích, atributy ve sloupcích. Budeme potřebovat čtvrtý až třináctý atribut, poslední sloupec oddělíme zvlášť - jedná se o anotaci dat (třídy). První tři atributy zahodíme. Data transponujeme (`'`).

Inicializujeme kohonenovu mapu rozumně zvolených parametrů a naučíme na data. Sledujeme výstupy sítě pro jednotlivé třídy, výstupy porovnáváme. Postup je obdobný úloze 7.1.

Reference

- [1] František Koukolík. *Lidský mozek*. Galen, 2012.
- [2] Thomas Trappenberg. *Fundamentals of Computational Neuroscience*. Oxford University Press, USA, June 2010.