

MODELOVANIE DYNAMIKY IMPULZNÝCH  
NEURÓNOVÝCH SIETÍ (MODEL SRM)

MICHAL GLAUS

2006





UNIVERZITA KOMENSKÉHO V BRATISLAVE  
FAKULTA MATEMATIKY, FYZIKY A INFORMATIKY  
KATEDRA APLIKOVANEJ INFORMATIKY

---

MODELOVANIE DYNAMIKY IMPULZNÝCH  
NEURÓNOVÝCH SIETÍ (MODEL SRM)

(Diplomová práca)

MICHAL GLAUS

---

Štúdiijný odbor: Informatika

Vedúci práce: Ing. Igor Farkaš, PhD.

Bratislava, 2006



Čestne prehlasujem, že som diplomovú prácu vypracoval samostatne s použitím uvedenej literatúry a s odbornou pomocou školiteľa.

Bratislava, máj 2006

Michal Glaus

## Pod'akovanie

Touto cestou by som sa chcel pod'akovat' môjmu školiteľovi, Ing. Igorovi Farkašovi, PhD., za odborné konzultácie, cenné pripomienky a rady pri tvorbe tejto práce. Ďalej by som rád pod'akoval Nine Kolesárovej za pripomienky k zrozumiteľnosti textu a oporu pri písaní práce.

## Abstrakt

Impulzné neurónové siete predstavujú špeciálny typ umelých neurónových sietí, ktorý modeluje správanie nervových buniek a ich vzájomných prepojení. Ak je do takéhoto modelu zahrnuté aj oneskorenie prenosu impulzov a synaptická plasticita, môžu sa neuróny siete samoorganizovať do zoskupení.

Táto práca vyhodnocuje správanie impulznej neurónovej siete s neurónmi založenými na modeli SRM. Analyzuje natrénovanú sieť po modelovaní 24 hodinovej aktivity. V sieti sa vytvárajú neurálne zoskupenia, aj keď sú neuróny stimulované len náhodným vstupom. Vlastnosti zoskupení boli vyhodnotené a porovnané s výsledkami publikovanými v práci [7].

Pozornosť sa ďalej venuje synchronizovanému vstupu. Sieť vykazuje rozdielnu mieru odozvy po jeho aplikovaní na rôzne množiny neurónov. Ďalej je preskúmaná adaptácia siete na takýto vstup. Vplyvom konkurencie jednotlivých synchronizovaných vstupov sa sieť prispôbuje vstupu, ktorý vyvoláva najvyššiu odozvu.

**Kľúčové slová:** impulzné neurónové siete, neurálne zoskupenia, samoorganizácia, SRM.

# Obsah

<b>1 Úvod</b>	<b>10</b>
1.1 Cieľ práce . . . . .	11
<b>2 Impulzné neurónové siete</b>	<b>12</b>
2.1 Neuróny a synapsy . . . . .	12
2.2 Model neurónu . . . . .	14
2.2.1 Spike Response Model . . . . .	14
2.3 Synaptická plasticita . . . . .	16
2.4 Zoskupenia neurónov . . . . .	16
<b>3 Model siete</b>	<b>18</b>
3.1 Nastavenia . . . . .	18
3.1.1 Obmeny nastavení . . . . .	20
3.2 Implementačné optimalizácie . . . . .	21
<b>4 Identifikácia neurálnych zoskupení</b>	<b>23</b>
4.1 Postup 1 . . . . .	23
4.2 Postup 2 . . . . .	24
4.2.1 Nedostatky algoritmu . . . . .	27
<b>5 Štruktúrovaný vstup</b>	<b>29</b>
5.1 Sledované zmeny . . . . .	29
<b>6 Výsledky</b>	<b>31</b>
6.1 Normálna simulácia . . . . .	31
6.1.1 Stav siete . . . . .	32



6.1.2 Neurálne zoskupenia . . . . .	34
6.2 Aplikovanie štruktúrovaného vstup . . . . .	34
<b>7 Záver</b>	<b>40</b>
<b>Literatúra</b>	<b>41</b>

# Kapitola 1

## Úvod

Mozog je jedným z najzložitejších biologických systémov. Výskum mozgu odhalil množstvo informácií o jeho zložení, štruktúre a fyzikálnych a chemických procesoch, ktoré v ňom prebiehajú. Napriek intenzívnemu štúdiu viaceré jeho funkcie ešte neboli uspokojivo vysvetlené. Je to spôsobené komplikovanou štruktúrou a obmedzenými možnosťami súčasných technológií používaných na sledovanie aktivity neurónov.

Mozgová kôra pozostáva z miliárd neurónov a každý z nich je spojený rádovo s tisíckami svojich susedov. Aj malá oblasť mozgu teda obsahuje veľké množstvo neurónov a ďaleko viac spojení medzi nimi. Pri tak zložitom priestorovom usporiadaní nie je možné skúmať jednotlivé prepojenia neurónov a impulzy, ktoré sa nimi prenášajú.

K pochopeniu činnosti jednotlivých častí mozgu prispieva ich rozdelenie na funkčné celky. Každý neurón sa pripája na množstvo iných neurónov. Nie všetky spojenia sú ale rovnako dôležité. Keď vieme, cez ktoré neuróny sa podnety zo sensorov prenášajú, môžeme lepšie pochopiť procesy, ktoré v týchto častiach prebiehajú. Simulácia častí mozgu je preto vhodný spôsob na štúdium ich vnútorného usporiadania.

Modelovaním procesov, ktoré prebiehajú v mozgu, vznikajú hypotézy o jeho stavbe. Tieto hypotézy môžu byť následne overené v praxi. Simulácia impulzných neurónových sietí nám pomáha objasniť spôsob, akým mozog funguje, kóduje informácie, z akých častí sa skladá a ako sú tieto časti navzájom prepojené.

## 1.1 Cieľ práce

Viacere štúdie [5, 7] sa venovali skúmaniu vzniku zoskupení neurónov a vlastnostiam týchto zoskupení. Ako vonkajší vstup neurónov bol zväčša použitý iba náhodný šum. To ale nezodpovedá vstupu neurónov v mozgovej kôre, ktoré sú aktivované výstupmi neurónov z iných vrstiev, prípadne priamo podnetmi zo senzorov. Mojim cieľom bolo získať výsledky v oblastiach, ktorým sa ostatné práce detailne nevenovali. Táto práca je zameraná aj na správanie neurónovej siete aktivovanej štruktúrovaným vstupom.

Práca pozostáva z dvoch úloh. Prvou z nich je implementovať model impulznej neurónovej siete. Tento model bude následne použitý na simuláciu aktivity neurónovej siete. Cieľom simulácie je popísať správanie siete, najmä vznik synchronizovaných neurálnych zoskupení. Výsledky pozorovaní budú porovnané s podobnými experimentami v spomenutých prácach. Pozornosť sa venuje adaptácii siete na stimuláciu štruktúrovaným vstupom. Tiež sú zhrnuté zmeny správania siete pozorované rozdielnym nastavením niektorých parametrov modelu.

# Kapitola 2

## Impulzné neurónové siete

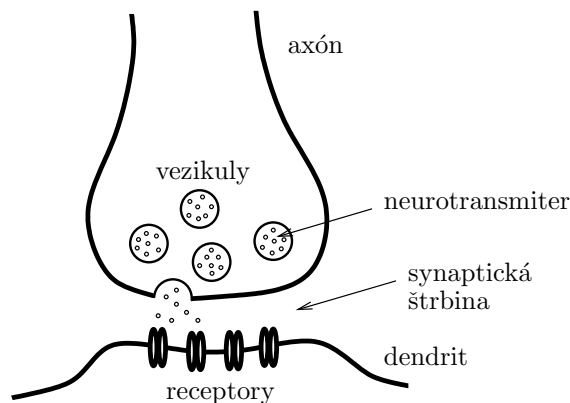
Umelé neurónové siete sa snažia napodobniť štruktúru a správanie biologických neurónových sietí. Skladajú sa z jednoduchých uzlov, jednotiek, ktoré sú navzájom prepojené a tvoria sieť. Prepojenia slúžia na výmenu informácií medzi jednotkami. Každý uzol má vnútorný stav a spracúva vstupné signály prijaté od pripojených uzlov. Výsledok spracovania sa prenáša po spojeniach do ďalších uzlov.

Impulzné neurónové siete sú špeciálnym prípadom umelých neurónových sietí. Názov je odvodený od spôsobu komunikácie – uzly komunikujú vysielaním impulzov. Jednotlivé uzly modelujú správanie nervových buniek. Dôležitú rolu zohráva správne načasovanie prijatých impulzov, potrebné na aktiváciu daného uzlu.

### 2.1 Neuróny a synapsy

Mozog sa skladá z nervových buniek, neurónov. Každý neurón je obalený membránou, v ktorej sa nachádzajú iónové kanály. Tieto aktívne aj pasívne kanály ovplyvňujú koncentráciu iónov v bunke, čím vzniká napätie na membráne – membránový potenciál. Veľkosť potenciálu závisí od aktivity neurónu. V pokojovom stave je membrána negatívne polarizovaná, napätie na membráne je  $-60$  až  $-90$  mV (hodnota závisí od typu neurónu).

Medzi neurónmi existujú prepojenia, synapsy (obrázok 2.1), cez ktoré tieto bunky komunikujú. Komunikácia je založená na jednosmernom šírení



**Obrázok 2.1:** Schéma synapsy.

elektrických impulzov. Bunka, ktorá vysiela signál, sa označuje presynaptická. Bunka, ktorá ho prijíma, je postsynaptická. Cez synaptické spojenia sa impulzy prenášajú prevažne chemicky – pomocou neurotransmiteru uloženého vo vezikulách. Po príchode impulzu sa vezikuly zlúčia s membránou a vypustia neurotransmitter do synaptickej štrbiny. Neurotransmitter sa naviaže na receptory na postsynaptickom neuróne a tie aktivujú iónové kanály. Prenosom iónov cez membránu sa zmení postsynaptický potenciál (PSP).

Synapsy môžu byť excitačné alebo inhibičné. Pri prenose signálu cez excitačnú synapsu sa vytvára excitačný postsynaptický potenciál. Napätie na membráne postsynaptickej bunky sa zvyšuje, dochádza k depolarizácii membrány. Pri inhibičnej synapse vzniká inhibičný postsynaptický potenciál. Napätie na membráne ešte viac klesá, prebieha hyperpolarizácia. Excitačný neurón je taký, z ktorého vychádzajú iba excitačné synapsy a naopak, inhibičný vytvára iba inhibičné synapsy.

Veľkosť membránového potenciálu závisí od prichádzajúcich impulzov. Ak bunka neprijíma žiadne impulzy, membránový potenciál sa postupne vráti k pokojovej hodnote. Keď sa potenciál zvýši a jeho hodnota prekročí istú hranicu (prah excitácie), neurón vygeneruje výstupný impulz – akčný potenciál. Práh excitácie je približne 15 až 30 mV nad pokojovým potenciálom.

Priebeh akčného potenciálu (príklad je v grafe 2.2) začína krátkou depolarizáciou membrány s amplitúdou okolo 100 mV, po ktorej nasleduje hyperpolarizácia. Následkom hyperpolarizácie je neurón málo citlivý na prijímané

impulzy. Veľkosť hyperpolarizácie a dĺžka jej trvania určuje charakteristiku pálenia neurónu. Rôzne správania sú popísané napríklad v [6].

## 2.2 Model neurónu

Pri modelovaní neurónových sietí je dôležité vybrať vhodný model neurónu. Existuje viacero modelov s rozdielnymi vlastnosťami.


Jedným z prvých modelov neurónu bol model Hodgkina a Huxleyho (ďalej len model H&H) [3], ktorý je založený na biofyzikálnych vlastnostiach neurónu. Správanie neurónu je riadené štyrmi diferenciálnymi rovnicami, ktoré popisujú aktiváciu iónových kanálov a zmenu membránového potenciálu. Význam tohto modelu je v presnom simulovaní dejov v nervovej bunke. Na druhej strane, detailnosť modelu sa odráža vo vysokej výpočtovej náročnosti simulácie, čo je hlavná nevýhoda. Tento model sa dá použiť na simuláciu neurónovej siete zloženej najviac z desiatok neurónov. Takýto rozsah simulácie je ale nepostačujúci pre modelovanie väčšiny procesov prebiehajúcich v mozgu.

Z modelu H&H vychádza viacero modelov, ktoré sú jeho zjednodušením. Tieto modely síce nie sú biologicky presné, ale ich správanie sa v značnej miere zhoduje s pôvodným modelom. Navyše ich výpočtová zložitosť je menšia. Jedným z nich je Spike Response Model, skrátene SRM, uvedený napríklad v [1].

### 2.2.1 Spike Response Model

Spike Response Model popisuje stav neurónu iba jednou rovnicou, ktorá určuje hodnotu membránového potenciálu. Jeho hodnota je počítaná na základe časovej histórie prijatých a vyslaných impulzov neurónu. Priebeh potenciálu určuje rovnica

$$u_i(t) = \eta(t - \hat{t}_i) + \sum_j w_{ij} \sum_f \epsilon_{ij}(t - \hat{t}_i, t - t_j^{(f)}) + \int_0^\infty \kappa(t - \hat{t}_i, s) I^{\text{ext}}(t - s) ds + u_{\text{rest}}$$



**Graf 2.2:** Priebeh postsynaptického potenciálu na neuróne modelovanom SRM so statickým prahom  $\vartheta$ . **A** – neurón prijal impulz, ktorý nie je dostatočný na generovanie akčného potenciálu, **B** – prijatý druhý impulz, neurón po prekročení prahu excitácie vytvára akčný potenciál, **C** – doba úplnej odolnosti, neurón nie je schopný za žiadnych okolností generovať akčný potenciál, **D** – hyperpolarizácia membrány.

kde  $\hat{t}_i$  je čas posledného výstupného impulzu,  $u_{\text{rest}}$  je hodnota pokojového potenciálu, funkcia  $\eta$  určuje časový priebeh potenciálu po vyslaní impulzu. Funkcia  $\epsilon$  určuje časový priebeh postsynaptického potenciálu,  $w_{ij}$  je účinnosť synapsy,  $t_j^{(f)}$  sú časy vyslania impulzov presynaptickým neurónom  $j$ . Funkcia  $\kappa$  určuje reakciu na stimuláciu externým prúdom  $I^{\text{ext}}$ . Funkcie  $\eta$ ,  $\epsilon$  a  $\kappa$  sú označované kernel. Vyslanie výstupného impulzu sa udeje, ak membránový potenciál prekročí dynamickú prahovú hodnotu  $\vartheta(t - \hat{t}_i)$ .

Vlastnosti modelu sa dajú nastaviť vhodnou voľbou funkcií  $\eta$ ,  $\epsilon$  a  $\kappa$ . Najčastejšie sa používajú exponenciálne funkcie. Špeciálnym prípadom modelu SRM je SRM<sub>0</sub>, v ktorom hodnota funkcií  $\epsilon$  a  $\kappa$  nie je ovplyvnená časom od posledného vyslaného impulzu.

SRM nepatrí k najjednoduchším modelom, ale jeho vlastnosti vyvažujú výpočtovú zložitosť. Preto je tento model vhodný aj na simuláciu rozsiahlejších sietí.

## 2.3 Synaptická plasticita

Vplyv impulzu na postsynaptický neurón závisí od účinnosti (váhy) synapsy. Účinnosť prenosu impulzu nie je konštantná, ovplyvňuje ju aktivita oboch neurónov. V prípade, keď aktivita neurónov vedie k zvýšeniu účinnosti prenosu, hovoríme o dlhodobom zefektívnení (anglicky long-term potentiation, LTP). Ak je výsledkom pokles, ide o dlhodobý útlm (long-term depression, LTD).

Jedným z modelov plasticity je model pomenovaný podľa svojich autorov Bienenstock-Cooper-Munroe [2, kapitola 10.2]. Tento model modifikuje účinnosť synapsy podľa intenzity stimulácie. Ak presynaptické impulzy prichádzajú iba zriedkavo, efektívnosť prenosu sa znižuje. Ak je ale aktivita presynaptického neurónu intenzívna, potom sa aj účinnosť prenosu zvyšuje.

Významný model, založený na načasovaní vyslaných impulzov, je model spike-timing-dependent plasticity (STDP) [2, kapitola 10.3]. Zmena efektívnosti závisí od korelácie impulzov. LTP nastáva, keď krátko po príchode presynaptického impulzu neurón generuje výstupný impulz. K posilneniu teda dochádza, ak presynaptický neurón efektívne ovplyvňuje aktivitu postsynaptického neurónu a svojou aktivitou prispieva k vzniku akčného potenciálu. Ak je načasovanie opačné, teda, keď je výstupný impulz generovaný pred príchodom presynaptického impulzu, nastáva pokles účinnosti. Hodnota, o ktorú sa zmení váha spojenia, závisí od rozdielu v načasovaní impulzov. Existujú rôzne varianty STDP, ktoré sa líšia v tom, koľko posledných presynaptických a postsynaptických impulzov sa berie do úvahy pri zmene váhy.

## 2.4 Zoskupenia neurónov

Každý neurón sa pripája na množstvo iných neurónov. Nie všetky spojenia sú ale rovnako dôležité. Iba silné spojenia, teda synapsy s veľkou účinnosťou prenosu impulzov, vyvolajú relevantnú odozvu postsynaptických neurónov. Tie môžu generovať akčný potenciál a následne vyvolať aktivitu v ďalších neurónoch. Skúmaním šírenia impulzov môžeme identifikovať zoskupenie neurónov, v ktorom je aktivita ovplyvnená niekoľkými, takzvanými iniciač-



nými, neurónmi.

Štúdiom neurálnych zoskupení sa zaoberali Izhikevich, Gally a Edelman [5]. Vo svojej práci popisujú simuláciu neurónovej siete zloženej zo 100 000 neurónov. Použili model neurónu, ktorého autorom je Izhikevich [4]. Parametre siete volili tak, aby čo najvernejšie simulovali anatómiu mozgovej kôry. Aktivita siete bola vyvolaná šumom, ktorý tvoril jediný externý vstup neurónov. Pri nízkej úrovni šumu sa sieť správala synchronizovane. Počas simulácie sa striedali obdobia s minimálnou aktivitou neurónov s obdobiami, v ktorých väčšina neurónov opakovane vysielala impulzy. Pri vyššej intenzite šumu bola aktivita siete stabilná. Neuróny sa samoorganizovali do zoskupení napriek tomu, že vstup neurónov bol len náhodný šum. Väčšina zoskupení vznikla krátko po spustení simulácie a pretrvala až do jej ukončenia. Táto stabilita dokazuje, že vznik zoskupení nie je len výsledkom dočasnej časopriestorovej štruktúry náhodného šumu. Aktivita neurónov v skupine aj napriek šumu vytvárala vzory, ktoré sa s veľkou presnosťou pravidelne opakovali.

V novšom článku píše Izhikevich [7] o minimálnom modeli siete, ktorej neuróny sú schopné vytvárať opakujúce sa vzory aktivity. Takéto správanie označil termínom polychronizácia (anglicky polychronization). Je spôsobené oneskorením prenosu impulzov medzi neurónmi a synaptickou plasticitou. Neuróny vytvárajú zoskupenia a ich aktiváciou vznikajú vzory aktivity. V článku je popísaný algoritmus na identifikáciu zoskupení.

Izhikevich navrhuje hypotézu, podľa ktorej môžu zoskupenia reprezentovať zapamätané informácie. Každé zoskupenie reprezentuje nejaký stimul. Presné načasovanie impulzov spôsobí aktiváciu niektorých zoskupení, čo predstavuje odpoveď siete na špecifický podnet. Každý neurón môže patriť do viacerých zoskupení. Počet zoskupení môže byť vyšší ako počet neurónov, dokonca vyšší ako počet spojení. Znamená to, že sieť má potenciálne rozsiahlu pamäťovú kapacitu.

# Kapitola 3

## Model siete

Pri vytváraní modelu siete som vychádzal z modelu použitého Izhikevichom v článku [7]. Dôvodom takéhoto prístupu je možnosť porovnania dosiahnutých výsledkov. Hlavný rozdiel je v modeli neurónov. Použil som implementáciu založenú na modeli SRM.

### 3.1 Nastavenia

Časový krok simulácie som zvolil 1 ms. Model neurónu nie je založený na diferenciálnych rovniciach, preto nie je potrebné prepočítavať hodnotu  $u_i$  častejšie a zvolený časový krok je postačujúci.

Sieť pozostávala z 800 excitačných a 200 inhibičných neurónov. Jednotlivé neuróny boli v každom časovom kroku stimulované náhodnými impulzmi s pravdepodobnosťou vzniku 0,001. Pri tejto pravdepodobnosti je očakávaná hodnota frekvencie náhodných impulzov 1 Hz. Náhodné impulzy sa do membránového potenciálu započítavajú rovnako ako impulzy prijaté od iných neurónov.

Žiadny iný externý vstup som nepoužil, takže z rovnice pre potenciál som odstránil časť integrujúcu externý prúd  $I^{\text{ext}}$  a  $\kappa$  kernel. Pokojový potenciál  $u_{\text{rest}}$  som nastavil na -70 mV. Ako  $\eta$  a  $\epsilon$  kernel som použil funkcie

$$\begin{aligned}\eta(t) &= -e^{-\frac{t-\Delta_{\text{abs}}}{\tau_\eta}} h(t)\theta \\ \epsilon(t, s) &= \frac{t}{\tau_t} e^{-\frac{t}{\tau_t}} \left(1 - e^{-\frac{s}{\tau_s}}\right)\end{aligned}$$

Funkcia  $h(t)$  je použitá kvôli dobe úplnej odolnosti (anglicky absolute refractory period) a má tvar

$$h(t) = \begin{cases} -\infty & t < \Delta_{\text{abs}} \\ 1 & t \geq \Delta_{\text{abs}} \end{cases}$$

Hodnoty konštant boli

$$\begin{array}{l} \text{pre excitačné neuróny} \quad \Delta_{\text{abs}} = 8, \quad \tau_{\eta} = 25, \quad \theta = 30, \quad \tau_t = 3, \quad \tau_s = 10 \\ \text{pre inhibičné neuróny} \quad \Delta_{\text{abs}} = 3, \quad \tau_{\eta} = 8, \quad \theta = 20, \quad \tau_t = 3, \quad \tau_s = 8 \end{array}$$

Inhibičné neuróny môžu vďaka rozdielnym nastaveniam dosiahnuť vyššie frekvencie pálenia pri rovnakej miere stimulácie. To zodpovedá aktivite excitačných a inhibičných neurónov v mozgovej kôre. Rozdiel frekvencií závisí od miery stimulácie.

Namiesto dynamického prahu bol použitý statický. Prahová hodnota na generovanie impulzu  $\vartheta$  bola pevne stanovená na úroveň 30 mV nad pokojovou hodnotou potenciálu. Vlastnosti dynamického prahu nahrádza  $\eta$  kernel, v ktorom bola použitá doba úplnej odolnosti  $\Delta_{\text{abs}}$  a funkcia  $h(t)$ . Preto sa model neurónu správa ako model s dynamickým prahom.


Dynamika synaptického potenciálu je znázornená v grafe 2.2. Priebeh potenciálu bol zaznamenaný na modeli excitačného neurónu s uvedenými nastaveniami.

Prepojenia medzi neurónmi boli vytvorené náhodne tak, aby sa zabránilo viacnásobným spojeniam medzi dvojicou neurónov. Každý neurón je pripojený na 100 rôznych neurónov, pri inhibičných neurónoch to môžu byť iba excitačné.

Prenos impulzov po spojeniach nie je okamžitý. Oneskorenie spojenia je pevne dané pri jeho vytvorení a ďalej sa už nemení. Nadobúda hodnoty z rozsahu 1 až 20 ms.

Počiatkové váhy boli zvolené 0,25 pre inhibičné spojenia a 0,3 pre excitačné. Minimálna hodnota váh je 0 a maximálna hodnota je 0,5. Náhodne generované impulzy mali váhu 1.

Tieto hodnoty váh nepostačujú na vyvolanie dostatočného postsynaptického potenciálu, preto som ich musel naškálovať. Pri počítaní PSP násobím



**Graf 3.1:** Synaptická plasticita.  $\Delta t$  je predstavuje rozdiel v čase, o koľko pred postsynaptickým impulzom prišiel presynaptický.

váhy konštantou 90. Prepočtu sa dá vyhnúť použitím vyšších váh (v tomto prípade z intervalu  $\langle 0, 45 \rangle$  a hodnota 90 pre náhodné impulzy). Potom je ale nutné upraviť veľkosť plasticity pomerne k daným váham a takáto zmena je málo flexibilná.

Na modelovanie synaptickej plasticity som použil STDP (graf 3.1). Plasticita je použitá iba na váhy excitačných spojení. Zmena váh je daná rozdielom v načasovaní posledného postsynaptického a presynaptického impulzu  $\Delta t = \hat{t}_{\text{post}} - \hat{t}_{\text{pre}}$ . Rovnica STDP má tvar

$$\Delta w(\Delta t) = \begin{cases} A_+ e^{-\Delta t/\tau_+} & \Delta t \geq 0 \\ -A_- e^{\Delta t/\tau_-} & \Delta t < 0 \end{cases}$$

Parametre rovnice boli  $A_+ = 0,005$ ,  $A_- = 0,007$ ,  $\tau_+ = 20$  a  $\tau_- = 20$ .

Váhy excitačných spojení sa každú sekundu simulácie zvýšili o hodnotu 0,0005, bez ohľadu na aktivitu prepojených neurónov. Aj keď je táto hodnota nízka, jej vplyv na sieť je výrazný. Prispieva hlavne k rýchlejšiemu ustáleniu váh.

Váhy, ktoré by klesli pod minimum, alebo by stúpili nad maximum, som nastavil na príslušnú okrajovú hodnotu.

### 3.1.1 Obmeny nastavení

Overil som správanie siete po zmene niektorých parametrov modelu.

Neuróny som náhodne rozmiestnil v dvojrozmernom priestore. Pri vytváraní spojení som pre neurón obmedzil výber postsynaptických neurónov iba na tie, ktoré sa nachádzajú v jeho okolí. Táto zmena nespôsobila kvalitatívny rozdiel v správaní siete.

Ďalšia modifikácia spočívala v nastavení nižších počiatkových váh spojení. To malo za následok ich pomalšie ustálenie. Nevýhoda vyšších počiatkových váh je ale v tom, že na začiatku simulácie môžem detekovať príliš mnoho zoskupení (viď nasledujúca kapitola), ktoré nevznikli postupným posilňovaním spojení. Výsledky sú potom istý čas po spustení simulácie značne skreslené.

Namiesto silnej externej stimulácie som skúšal stimuly s náhodnou veľkosťou a vyššou pravdepodobnosťou vzniku. Potom prijatie externého impulzu neurónom väčšinou nespôsobí vytvorenie impulzu, ale iba zvýšenie potenciálu. Aktivácia niektorého neurónu sa ľahšie rozšíri na postsynaptické neuróny so zvýšeným potenciálom. Celá sieť potom vykazuje značnú synchronnú aktivitu.

## 3.2 Implementačné optimalizácie

Na zrýchlenie celej simulácie som použil rôzne optimalizácie a zjednodušenia. Pri voľbe parametrov som dbal na to, aby ich vplyv na presnosť simulácie bol minimálny.

Čím viac času uplynulo od vyslania impulzu, tým menej momentálne prispieva k membránovému potenciálu. Preto môžem zanedbať impulzy, ktoré boli generované pred istou dobou (v mojej implementácii je to 50 ms). Navyše mám pre každý neurón uložených najviac 10 posledných impulzov.

Ohraničil som maximálne hodnoty argumentov  $t$  a  $s$ , pre ktoré sa počítajú  $\eta$  a  $\epsilon$  kernely. Argument  $t$  má maximum 200 ms pri  $\eta$  kerneli a 30 ms pri  $\epsilon$  kerneli. Pre vyššie  $t$  je hodnota kernelov zanedbateľná, preto sú kernely nahradené nulovou hodnotou. Argument  $s$   $\epsilon$  kernelu má maximum 150 ms. Vyššie hodnoty  $s$  sú znížené na toto maximum. Hodnoty kernelov sa kvôli zrýchleniu simulácie dopredu vypočítali pre celočíselné hodnoty argumentov a uložili. Pri simulovaní sa používali uložené hodnoty.

Výpočet membránového potenciálu vychádza z aktuálnych hodnôt váh

spojení. Váhy sa vplyvom STDP mohli zmeniť, takže  $\epsilon$  kernel nenásobím váhou, ktorú malo spojenie v čase prijatia impulzu. Zmena váh vplyvom STDP nie je za krátky časový úsek veľká, preto táto nepresnosť nemá badateľný vplyv na hodnotu membránového potenciálu. Ukladanie si váh jednotlivých spojení v čase príchodu impulzu by navyše spôsobilo podstatné spomalenie celej simulácie.

## Kapitola 4

# Identifikácia neurálnych zoskupení

Neurálne zoskupenie je množina navzájom prepojených neurónov, pričom váhy prepojení sú dostatočne veľké na to, aby sa aktivita iniciačných neurónov rozšírila po celej tejto množine. Existuje viacero metód na identifikáciu zoskupení. Implementoval som 2 postupy, ktoré navrhol Izhikevich [5, 7]. Oba algoritmy identifikujú zoskupenia na základe vlastností prepojení neurónov a nie podľa ich skutočnej aktivity.

### 4.1 Postup 1

Prvý spôsob hľadá zoskupenia aktivované jediným iniciačným neurónom (anglicky anchor neuron). Najprv sa zvolí kandidát na iniciačný neurón. Neurón musí mať aspoň 2 silné spojenia, cez ktoré ovplyvňuje aktivitu ďalších neurónov. Takéto neuróny sa označia ako aktivované. Zaznamená sa k nim časové oneskorenie, s ktorým k nim príde impulz z iniciačného neurónu. Keď aktivované neuróny vyšlú impulzy a tie sa vďaka oneskoreniam stretnú s toleranciou 1 milisekundy na ďalšom neuróne, je aj daný neurón aktivovaný. Postup sa opakuje dovtedy, kým je možné pripojiť ďalšie neuróny.

Špeciálny prípad sú inhibičné neuróny. Môžu byť síce zaradené do zoskupenia, ale nemôžu už aktivovať ďalšie neuróny, lebo utlmujú postsynaptické neuróny.

Počet nájdených skupín závisí od toho, ktoré spojenia považujem za silné a od voľby kritérií na ich akceptovanie. Izhikevich definoval silnými váhami tie váhy, ktoré majú hodnotu aspoň 95% z maxima. V mojej implementácii som požadoval naškálované váhy minimálne 44,95, čo predstavuje takmer 99,89%. Zoskupenie som akceptoval, ak malo aspoň 2 neuróny, ktoré nie sú aktivované priamo iniciačným neurónom. Takto definovaných zoskupení môže byť v sieti najviac toľko, koľko je excitačných neurónov.

Výsledky získané týmto postupom sa nedali použiť na vyhodnotenie správania modelu. Počet nájdených zoskupení sa blížil počtu excitačných neurónov. Možná príčina zlyhania postupu je v tom, že maximálne váhy spojenia vôbec nezabezpečujú aktiváciu postsynaptického neurónu iniciačným neurónom. Algoritmus potom identifikuje aj zoskupenia, ktoré nezodpovedajú reálnemu šíreniu aktivity. Tento postup je možné použiť iba v sieťach, kde je maximálna váha spojenia blízko hodnoty potrebnej na aktiváciu postsynaptického neurónu.


Ďalšie nevýhody tohto prístupu spočívajú v tom, že každá skupina začína jediným neurónom. V neurónovej sieti môžu existovať zoskupenia, na aktiváciu ktorých je potrebný viac ako jeden neurón. Použitie postupu je vhodné v sieťach s veľkým počtom neurónov, kde akýkoľvek iný prístup znamená príliš veľkú časovú náročnosť algoritmu.

Spomenuté nedostatky čiastočne odstraňuje druhý prístup.

## 4.2 Postup 2

Druhý algoritmus na hľadanie zoskupení je o niečo komplikovanejší. Hľadá zoskupenia, ktoré môžu byť aktivované trojicou neurónov. Vyberie sa trojica neurónov, ktoré vyšlú impulz so zvoleným časovým posunom. Ak dva impulzy dorazia po silných spojeniach na jeden neurón s toleranciou 1 milisekunda, je tento neurón aktivovaný (obrázok 4.1) a zaznamená sa čas jeho aktivácie. V tomto čase neurón vygeneruje impulz, ktorý po spojeniach s oneskorením dorazí k postsynaptickým neurónom. Pri týchto neurónoch sa rovnako vyhodnotí, či nemôže dôjsť k ich aktivácii správnym načasovaním dvoch impulzov. Postup sa opakuje kým sa neskontrolujú všetky postsy-





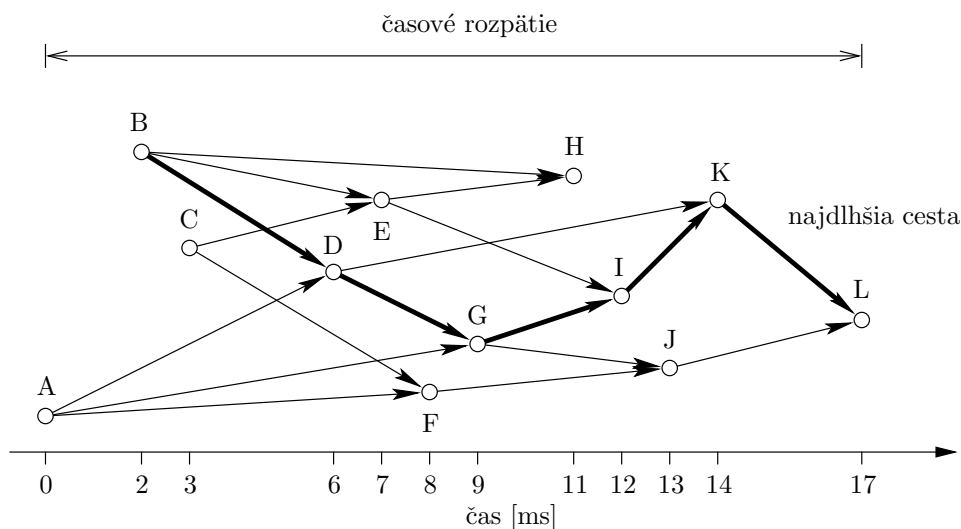
**Obrázok 4.1:** Aktivácia neurónu – impulz z neurónu A príde 1 ms po impulze z neurónu B, preto je neurón C aktivovaný v čase 9 ms od vyslania impulzu neurónom A.

naptické neuróny. Prístup k inhibičným neurónom je rovnaký ako v prvom postupe. Aktivované neuróny sú považované za zoskupenie, ak spĺňajú zvolené kritériá.

Ak používam minimálne časové oneskorenie 1 ms a maximálne 20 ms, potom časové posunutie pálenia dvojice neurónov, pri ktorom sa vyslané impulzy stretnú, môže byť najviac 19 ms. Ak vyberám iba celočíselné hodnoty pre posunutie, potom existuje 39 rôznych možností, ktoré treba vyskúšať. Pridaním tretieho neurónu mám od 39 do 58 možností pre jeho časové posunutie, podľa toho, aký je rozdiel v načasovaní prvých dvoch neurónov. Celkovo treba vyskúšať 1901 rôznych načasovaní trojice neurónov. Pri sieti s 800 excitačnými neurónmi mám 85 013 600 rôznych kombinácií pre trojicu a 1901 kombinácií pre načasovanie jej pálenia, čo predstavuje vyše 161 miliárd možných zoskupení.

Takýto postup sa nedá priamo realizovať a je nutné ho zjednodušiť. Ako trojicu vyberiem iba tie neuróny, z ktorých každé dva majú spojenie so silnou váhou na rovnaký postsynaptický neurón. Z možností pre časové posunutie vyberiem iba také, ktoré aktivujú postsynaptické neuróny. Ďalším parametrom je minimálna veľkosť skupiny. Zvolil som minimum 10 neurónov – teda 3 počiatočné a aspoň 7 ďalších ktoré sú nimi aktivované.

Pri hľadaní zoskupení je potrebné zistiť či už dané zoskupenie nebolo objavené. Ak totiž uvažujem presnosť načasovania impulzov s toleranciou 1 ms, potom môžem získať rovnaké zoskupenia s mierne posunutým pále-



**Obrázok 4.2:** Schematické znázornenie vlastností zoskupenia iniciovaného neurónmi A, B a C. Veľkosť zoskupenia je 12, časové rozpätie je 17 ms a najdlhšia cesta má dĺžku 5.

ním niektorých neurónov. Nie je jednoduché navrhnúť kritériá na posúdenie duplicitných zoskupení. Dve zoskupenia považujem za rovnaké ak spĺňajú:

1. všetky 3 počiatočné neuróny majú rovnaké s rozdielom v načasovaní najviac 1 ms,
2. aspoň 5 ďalších neurónov je rovnakých s rozdielom v načasovaní aktívacie najviac 1 ms.

Ďalší sporný prípad nastane, ak identifikujem zoskupenie, ktoré tvorí podmnožinu iného nájdeného zoskupenia. Tieto zoskupenia považujem za rôzne, lebo väčšie z nich nemusí byť aktivované, zatiaľ čo jeho podmnožina môže byť aktivovaná.

Pri skúmaní zoskupení vyhodnocujem ich veľkosť (počet neurónov), časové rozpätie (čas medzi vypálením prvého a posledného impulzu neurónmi zoskupenia) a najdlhšiu cestu (obrázok 4.2). Z pohľadu celej simulácie môžeme tiež zisťovať životnosť zoskupení. Na to je potrebné pamätať si zoskupenia, nájdené pri predchádzajúcom spustení algoritmu na ich identifikáciu. Nové zoskupenia sa potom porovnávajú so starými, aby sme mohli zistiť,

či neboli sformované už skôr. Nemožno očakávať, že sa zoskupenie od jeho prvého objavenia vôbec nezmení. Zmeny sú prejavom "sút'aženia" medzi dvojicami zoskupení o neuróny, ktoré prijímajú impulzy od oboch zoskupení. Preto je potrebné pri hľadaní porovnávať s určitou toleranciou. Použil som rovnaký postup ako pri posudzovaní duplicitných zoskupení. Každých 10 minút simulácie som overoval, ktoré z nájdených zoskupení ešte existujú.

Najskôr som za silné spojenia pokladal tie, z ktorých dva prijaté impulzy s rozdielom časov 1 ms vyvolajú aktiváciu neurónu. Hodnota naškálovaných váh takýchto spojení musí byť aspoň 41,8. Počet zoskupení ktoré som identifikoval bol vyše 9,5 miliónu, čo je nepomerne viac ako 5 až 6 tisíc, ktoré pri svojom modeli uvádza Izhikevich [7]. Toľko zoskupení nie je možné počas simulácie pravidelne analyzovať kvôli časovej a pamäťovej náročnosti celého postupu.

Zníženie počtu zoskupení som dosiahol iba prísnyim určením váhy silných spojení. Za silné spojenia som považoval len tie, ktorých naškálované váhy mali hodnotu aspoň 44,95, čo predstavuje takmer maximum hodnoty. Toto nastavenie som použil aj pri vyhodnocovaní výsledkov. Nie je však ideálne z dvoch príčin:

1. maximálne hodnoty váh nie sú stabilne udržateľné – stačí jediný impulz z presynaptického neurónu a váha z maxima vplyvom plasticity klesne,
2. na aktiváciu neurónu stačia aj 2 impulzy, ktoré prídu po spojeniach s nižšími váhami.

Ak znížim limit pre hodnoty váh silných spojení, algoritmus nájde rádovo viac zoskupení.

#### 4.2.1 Nedostatky algoritmu

Ako už Izhikevich uviedol vo svojom článku [7], postup identifikuje iba zoskupenia iniciované trojicou neurónov. Mnoho zoskupení môže začínať viacerými neurónmi, ale kvôli zúženému výberu zostanú neodhalené.

Ďalšia nevýhoda postupu spočíva v tom, že na aktiváciu sa používa dvojica impulzov s toleranciou 1 ms. Pritom v mnohých prípadoch môže byť

neurón aktivovaný aj väčším počtom neurónov s väčšou toleranciou v načasovaní.

Posledná výhrada smeruje k reálnosti nájdených zoskupení. Algoritmus identifikuje zoskupenia na základe vlastností siete. Tieto zoskupenia nemusia byť pri simulácii nikdy aktivované a vzory pálenia sa nemusia objaviť vo výslednej aktivite siete.

# Kapitola 5

## Štruktúrovaný vstup

Pojmom štruktúrovaný vstup označujem taký vstup, ktorého časopriestorové usporiadanie nie je náhodné, vyskytuje sa v ňom istá pravidelnosť. Takýto vstup môže mať rôzne formy.

*Synchronizovaný vstup* – vyberie sa množina neurónov, ktorým bude súčasne aplikovaný aktivačný vstup. Výsledkom stimulácie je, že aktivované neuróny vyšlú naraz impulzy. Tie prídu vplyvom oneskorenia synaptického prenosu na postsynaptické neuróny v rozdielnom čase a aktivita sa rozsynchronizuje. Výhoda použitia synchronizovaného vstupu je v ľahšom sledovaní následnej aktivity v sieti.

*Aktivačný vzor* – vytvorí sa vzor, ktorý dostávajú neuróny na vstup. Tento vzor môžem použiť buď na celú sieť, alebo iba na množinu neurónov. Modifikácie tohto prístupu spočívajú vo vytvorení viacerých vzorov, ktoré sa striedajú. Ďalej môžem neuróny rozdeliť do viacerých množín a následne ich aktivovať rôznymi vzormi.

Vo výsledkoch som vyhodnotil použitie synchronizovaného vstupu, aplikovaného postupne na viacero množín neurónov.

### 5.1 Sledované zmeny

Keď sieť stimulujem štruktúrovaným vstupom, môžem sledovať

- vývoj odozvy siete na vstup pri jeho dlhodobom aplikovaní

- zmenu váh spojení
- ako sa zmení zloženie zoskupení - veľkosť, dĺžka, . . . ,
- koľko zoskupení vznikne,
- ako sa zmenia existujúce zoskupenia,
- porovnať štruktúru zoskupení so štruktúrou použitých vzorov.

# Kapitola 6

## Výsledky


Na ustálenie správania siete bola spustená simulácia po dobu 24 hodín modelového času. Po skončení simulácie boli spracované výsledky.

### 6.1 Normálna simulácia

Počas simulácie bolo vyslaných 446 miliónov impulzov, z toho 19,4% bolo vygenerovaných náhodne ako aktivačný vstup a zvyšných 80,6% bolo výsledkom aktivity neurónov. K tomuto údaju treba dodať, že každý impulz vyslaný neurónom sa šíril do 100 postsynaptických neurónov, zatiaľ čo náhodne generované impulzy boli prijaté iba jediným neurónom.

Aktivita neurónov počas 1 sekundy je zachytená v grafe 6.1. Z grafu vidieť, že v sieti sa pravidelne opakuje súčasná aktivita viacerých neurónov. Pri pozorovaní dlhšieho časového úseku je možné stanoviť frekvenciu takejto aktivity na 12 Hz až 13 Hz. Frekvencia aktivity je stabilná, neobjavujú sa badateľné výkyvy. Opakovanie s touto frekvenciou možno pozorovať už po pol hodine od začiatku simulácie. Pravdepodobne to súvisí s dobou, ktorú potrebuje neurón na zotavenie po vyslaní impulzu. Aktivita sa nemôže opakovať s vyššou frekvenciou, lebo membrána veľkého počtu neurónov je určitú dobu hyperpolarizovaná po predchádzajúcej vlne aktivity.

Intenzita aktivity nie je rovnaká, nepravidelne sa mení. Dôvodom nižšej aktivity môže byť aktivácia inhibičných neurónov, ktoré pôsobia práve na tie excitačné neuróny, cez ktoré by sa inak aktivita ďalej rozšírila.



**Graf 6.1:** Aktivita neurónov počas 1 sekundy po 24 hodinovej simulácii. Neuróny s indexom 800 a vyšším sú inhibičné.


Ak sieť nestimulujem náhodnými impulzmi, aktivita neurónov úplne zanikne. Generované náhodné impulzy sú nevyhnutné pre aktiváciu neurónov a šírenie aktivity.

### 6.1.1 Stav siete

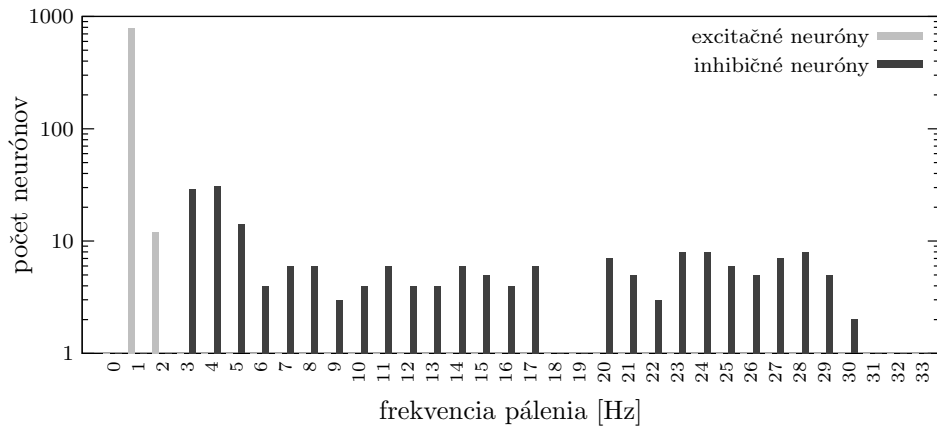
Váhy spojení sa už po pol hodine simulácie dostali na pomerne stabilnú úroveň. Po 24 hodinách (graf 6.2) má 49,4% váh hodnotu menšiu ako 0,01 (blízko minima) a 29,5% váh hodnotu väčšiu ako 0,49 (blízko maxima). Synaptická plasticita spôsobila, že sila spojenia má tendenciu konvergovať k niektorej z okrajových hodnôt.

Frekvencia pálenia neurónov (graf 6.3) bola vyhodnotená ako priemer za posledných 10 minút simulácie. Frekvencia je výrazne odlišná pre excitačné a inhibičné neuróny. Je to jednak spôsobené ich rozdielnym nastavením, ale aj tým, že inhibičné neuróny nie sú utlmované, lebo prijímajú vstup iba od excitačných neurónov.






**Graf 6.2:** Distribúcia excitačných váh po 24 hodinovej simulácii. Graf je v logaritmickej mierke.



**Graf 6.3:** Distribúcia frekvencie pálenia po 24 hodinovej simulácii. Graf je v logaritmickej mierke.



**Graf 6.4:** Vývoj počtu neurálnych zoskupení. Na začiatku simulácie je identifikovaných množstvo zoskupení (najviac 26564 v čase 1 hodina), čo je dôsledok vyšších počiatočných váh.

### 6.1.2 Neurálne zoskupenia

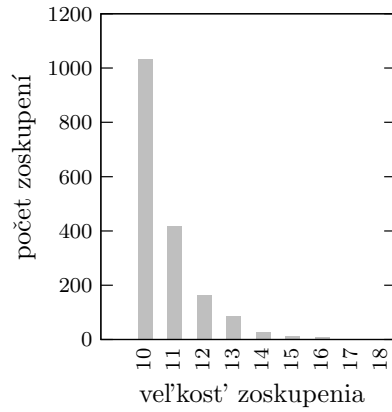
Analyzoval som neurálne zoskupenia identifikované podľa 2. postupu. Časový vývoj počtu zoskupení (graf 6.4) nemá rastúcu, ani klesajúcu tendenciu. Počet je nestály a v priebehu simulácie sa mení. Po 24 hodinách bolo v neurónovej sieti nájdených 1749 zoskupení.

Počet zoskupení klesá exponenciálne vzhľadom k ich veľkosti (graf 6.5). Časové rozpätie zoskupení (graf 6.6) má priemernú hodnotu 17,9 ms.

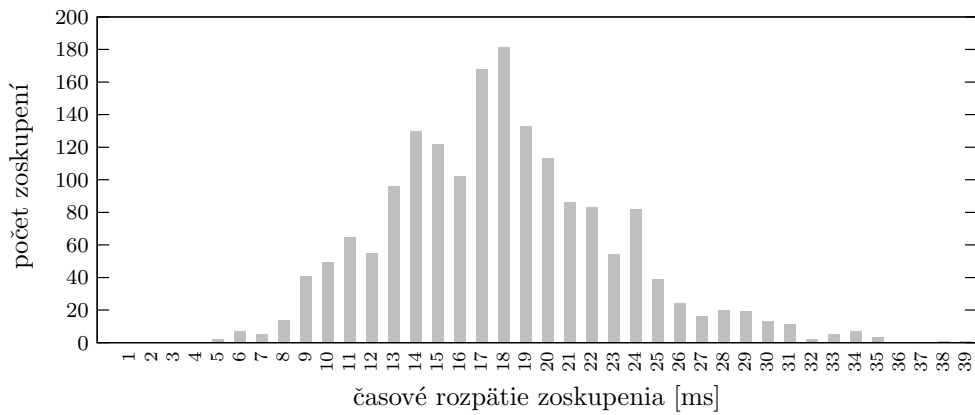
Životnosť zoskupení bola v porovnaní s výsledkami, ktoré publikoval Izhikevich [7], veľmi nízka. Len 0,17% nájdených zoskupení existovalo po dobu aspoň 10 minút simulácie (teda bolo nájdených v ďalšom behu algoritmu na ich identifikáciu) a najdlhší čas bol menej ako 40 minút. Príčina je v stanovení kritérií na akceptovanie zoskupení. Voľbou menej prísnych kritérií by bolo možné dosiahnuť vyššiu životnosť zoskupení. Časové a pamäťové nároky simulácie by ale rapídne stúpili na neúnosnú mieru.

## 6.2 Aplikovanie štruktúrovaného vstup

So štruktúrovaným vstupom som uskutočnil viaceré pozorovania na natrénovanej sieti. Vstupom som stimuloval tri disjunktné množiny 10 neurónov. Iba dve množiny neurónov nepostačujú na pozorovanie niektorých javov



**Graf 6.5:** Distribúcia veľkosti neurálnych zoskupení po 24 hodinovej simulácii.



**Graf 6.6:** Distribúcia časového rozpätia zoskupení po 24 hodinovej simulácii.

(napríklad dočasná adaptácia na 2 vstupy, vid' nižšie) a viac ako 3 množiny nie sú potrebné. Počet 10 neurónov bol zvolený tak, aby bola zabezpečená aktivácia viacerých postsynaptických neurónov. Na druhej strane, pri tomto počte by sa nemala aktivita preniesť na všetky neuróny v sieti.


Prvé pozorovanie zist'ovalo odozvu na synchronizovaný vstup. Najskôr bolo po dobu 500 ms vypnuté generovanie externých impulzov, aby sa aktivita v sieti utlmila a neovplyvňovala ďalšie výsledky. Potom som vybral 3 množiny po 10 neurónov a každá z nich bola 4krát stimulovaná. Jednotlivé stimulácie množiny mali rozostup 100 ms a okrem neurónov z množiny žiadne iné neuróny nedostávali externý vstup. Výber troch množín som uskutočnil z piatich testovaných množín. Indexy neurónov v množine nasledovali za sebou, aby bolo v grafoch lepšie vidieť, ktoré neuróny boli vybraté. Index neurónu v sebe nenesie žiadnu inú informáciu, preto takýto výber neskresľuje výsledok. Z množín som vybral také, ktorých stimulácia vyvolala rôznu mieru odozvy, aby som poukázal na existujúce rozdiely.

Výsledná aktivita je zachytená v grafe 6.7. V grafe vidno rozdielnu mieru aktivácie siete pre rôzne množiny neurónov. Stimulácia prvej množiny vyvolala v priemere 370 impulzov, pri druhej to bolo až 599 a pri tretej iba 155 impulzov. Možno teda usúdiť, že silné spojenia nie sú rovnomerne rozdelené medzi neuróny. V sieti je nevyváženosť.

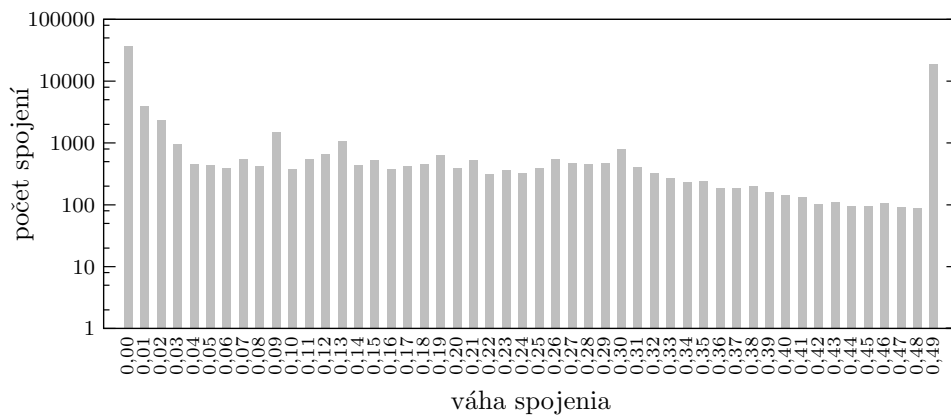
V druhom pozorovaní som zist'oval adaptáciu siete na synchronizovaný vstup. Použil som 3 množiny z predchádzajúceho pozorovania. Každých 100 ms bola v rovnakom poradí stimulovaná iná množina. Okrem neurónov z tejto množiny žiadne iné neuróny nedostávali externý vstup. Simulácia bežala 10 minút, aby sa sieť stihla adaptovať. Výsledkom sú adaptované váhy (graf 6.8). Klesol počet spojení s váhou blízko maxima aj minima. Počet zoskupení vzrástol na 213 230, čo prekračuje všetky doterajšie úrovne. Príčinou je vysoká korelácia vstupov a ňou zapríčinené zmeny váh.

Na takto adaptovanej sieti som zopakoval prvé pozorovanie. Výsledkom adaptácie (graf 6.9) je výrazné posilnenie odozvy na stimuláciu 1. a 2. množiny (v priemere 1187 a 1456 impulzov po stimulácii). Naopak sa oslabila odozva na stimuláciu 3. množiny neurónov (iba 36 impulzov).


Zmena odozvy je dôsledkom "sút'aženia" medzi stimulovanými množina-



**Graf 6.7:** Stimulácia synchronizovaným vstupom. Postupne boli stimulo-  
vané 3 množiny neurónov (neuróny s indexmi 400 až 409, 300 až 309 a 200  
až 209), každá z nich 4krát.



**Graf 6.8:** Váhy po 10 minútovej stimulácii synchronizovaným vstupom.



**Graf 6.9:** Stimulácia synchronizovaným vstupom po 10 minútovej adaptácii.

mi neurónov o postsynaptické neuróny. Silnejšia odozva siete znamená vyšší počet spojení, cez ktoré prídu impulzy do neurónu a aj väčšiu šancu jeho aktivácie. Ak dôjde k aktivácii, využitá spojenia sa vplyvom plasticity posilnia a váhy ostatných spojení môže poklesnúť. Tento neurón potom ovplyvní ďalšie postsynaptické neuróny. Takto sa rozširuje počet ovplyvnených neurónov. Pokles váh "nevyužitých" spojení spôsobuje zmenšenie odozvy siete na synchronne stimulovanie ostatných množín.

Pri predĺžení doby adaptácie siete z 10 minút na 1 hodinu sa odozva ďalej menila. Sieť prestala reagovať aj na stimuláciu 1. množiny neurónov, výsledok je v priemere iba 75 impulzov. Posilnenie odozvy nastalo pri 2. množine (2132 impulzov). Odozva pri 3. množine zostala takmer nezmenená – iba 35 impulzov. Naplno sa tak prejavilo "sút'áženie" medzi neurónmi. Váhy sa upravili. Až 79,8 % má hodnotu nižšiu ako 0,01 a 20,0 % hodnotu vyššiu ako 0,49. Iba 0,02 % váh má hodnotu medzi týmito extrémami.

Pre objektivnosť uvádzam v tabuľke 6.1 porovnanie s výsledkami získanými úplne náhodným výberom množín. Náhodný výber som opakovane 3krát. Vo všetkých prípadoch sa sieť úplne adaptovala na vstup, ktorý na začiatku vyvolal aktiváciu v najvyššiemu počtu neurónov.

výber	bez adaptácie			10 min adaptácia			1 h adaptácia		
	m 1	m 2	m 3	m 1	m 2	m 3	m 1	m 2	m 3
1	370	599	155	1187	1456	36	75	2132	35
2	140	1014	780	38	2178	66	29	2280	47
3	85	1144	477	35	2347	53	33	2401	43
4	761	467	542	2266	28	62	2290	28	44

**Tabuľka 6.1:** Porovnanie odozvy na synchronný vstup pre 4 rôzne výbery trojice množín. Číslo udáva počet impulzov generovaných neurónmi po aplikovaní vstupu na danú množinu.

# Kapitola 7

## Záver

V práci som ukázal, že model SRM je možné použiť na simulovanie impulzných neurónových sietí, v ktorých sa neuróny organizujú do zoskupení. Počas simulácie sa váhy spojení ustália a neuróny sa samoorganizujú do zoskupení. Vznik zoskupení spôsobuje synaptická plasticita. Tá pri náhodnej aktivácii neurónu posilní spojenia, ktorými prišli impulzy potrebné na aktiváciu. Tým sa zvýši pravdepodobnosť nasledujúcej aktivácie a teda aj ďalšieho posilnenia váh relevantných spojení. Klesá miera náhodnosti a aktivita sa rozširuje rovnakými spojeniami. Sieť dokáže generovať pravidelnú aktivitu, aj keď je vstup náhodný a nekorelovaný.

Životnosť vzniknutých zoskupení bola však nižšia, ako som očakával. Dôvodom boli prísne pravidlá na ich identifikáciu. To sa odrazilo aj na malej veľkosti nájdených zoskupení.

Overil som adaptáciu siete na štruktúrovaný vstup, ktorý synchronizovane aktivuje množinu neurónov. Pri dlhodobom stimulovaní siete striedavým aplikovaním synchronizovaného vstupu na rôzne množiny neurónov sa sieť adaptuje na vstup. To znamená, že jednotlivé váhy sa veľkosťou prispôbia časopriestorovej charakteristike vstupu. Posilňuje sa najsilnejšia odozva siete a naopak, najslabšia odozva sa postupne stráca. Je to prejavom "sút'aženia" neurónov o vplyv na postsynaptické neuróny.



# Literatúra

- [1] Gerstner, W. (1995). Time structure of the activity in neural network models. *Physical Review E*, 51:738-758
- [2] Gerstner, W. and Kistler, W.M. (2002). *Spiking Neuron Models*. Cambridge University Press, Cambridge.
- [3] Hodgkin, A.L. and Huxley, A.F. (1952). A quantitative description of membrane current and its application to conduction and excitation in nerve. *Journal of Physiology*, 117:500-544.
- [4] Izhikevich, E.M. (2003). Simple Model of Spiking Neurons. *IEEE Transactions on Neural Networks*, 14:1569-1572.
- [5] Izhikevich, E.M., Gally, J.A. and Edelman, G.M. (2004). Spike-Timing Dynamics of Neuronal Groups. *Cerebral Cortex*, 14:933-944.
- [6] Izhikevich, E.M. (2004). Which Model to Use for Cortical Spiking Neurons? *IEEE Transactions on Neural Networks*, 15:1063-1070.
- [7] Izhikevich, E.M. (2006). Polychronization: Computation with Spikes. *Neural Computation*, 18:245-282.