

# Modelování a simulace mozkové aktivity

Adam Volný

---

Bakalářská práce  
2016



Univerzita Tomáše Bati ve Zlíně  
Fakulta aplikované informatiky

---

Univerzita Tomáše Bati ve Zlíně  
Fakulta aplikované informatiky  
akademický rok: 2015/2016

## ZADÁNÍ BAKALÁŘSKÉ PRÁCE

(PROJEKTU, UMĚLECKÉHO DÍLA, UMĚLECKÉHO VÝKONU)

Jméno a příjmení: **Adam Volný**  
Osobní číslo: **A13727**  
Studijní program: **B3902 Inženýrská informatika**  
Studijní obor: **Informační a řídicí technologie**  
Forma studia: **prezenční**

Téma práce: **Modelování a simulace mozkové aktivity**  
Téma anglicky: **The Modelling and Simulation of Brain Activity**

Zásady pro vypracování:

1. Vypracujte literární rešerši na dané téma.
2. Prověřte možnosti různých simulačních prostředí a simulátorů umělé inteligence a multiagentních systémů.
3. Ve zvoleném programovacím prostředí a se zvolenou metodikou implementace umělé inteligence vytvořte a otestujte zpětnovazební systém.
4. Otestujte vytvořený systém na simulaci abstrakce.
5. Diskutujte možnosti prediktivního chování a dalších možností.

Rozsah bakalářské práce: -  
Rozsah příloh: -  
Forma zpracování bakalářské práce: tištěná/elektronická

Seznam odborné literatury:

1. ZELINKA, Ivan. Umělá inteligence v problémech globální optimalizace. BEN, 2002, 190 s. ISBN 80-7300-069-5.
2. IBA, Hitoshi. Agent-based modeling and simulation with Swarm. Boca Raton, Florida: CRC Press, 2013, 1 online zdroj (xx, 297 pages). ISBN 1299706029.
3. FERBER, Jacques. Multi-agent systems: an introduction to distributed artificial intelligence. 1st ed. Harlow: Addison Wesley, 1999, xviii, 509 s. ISBN 0201360489.
4. MAŘÍK, V., ŠTĚPÁNKOVÁ, O., LAŽANSKÝ, J.: Umělá inteligence, Academia, 1993, ISBN 80-200-0496-3.
5. MAŘÍK, V., ŠTĚPÁNKOVÁ, O., LAŽANSKÝ, J.: Umělá inteligence 4., Academia, 2003, ISBN 80-200-1044-0.
6. RUSSELL, Stuart J a Peter NORVIG. Artificial intelligence: a modern approach. 3rd ed. Upper Saddle River: Prentice Hall, 2010, xviii, 1132 s. ISBN 978-0-13-604259-4.
7. KENNEDY, James, Russell C EBERHART a Yuhui SHI. Swarm intelligence. San Francisco: Morgan Kaufmann, c2001, xxvii, 512 s. ISBN 1-55860-595-9.
8. JONES, M. Artificial intelligence: a systems approach. Sudbury: Jones and Bartlett Publishers, 2008, 498 s. ISBN 978-0-7637-7337-3.

Vedoucí bakalářské práce: **doc. Ing. Roman Šenkeřík, Ph.D.**  
Ústav informatiky a umělé inteligence  
Datum zadání bakalářské práce: **19. února 2016**  
Termín odevzdání bakalářské práce: **27. května 2016**

Ve Zlíně dne 19. února 2016



doc. Mgr. Milan Adámek, Ph.D.  
*děkan*



prof. Ing. Vladimír Vašek, CSc.  
*ředitel ústavu*

### **Prohlašuji, že**

- beru na vědomí, že odevzdáním diplomové/bakalářské práce souhlasím se zveřejněním své práce podle zákona č. 111/1998 Sb. o vysokých školách a o změně a doplnění dalších zákonů (zákon o vysokých školách), ve znění pozdějších právních předpisů, bez ohledu na výsledek obhajoby;
- beru na vědomí, že diplomová/bakalářská práce bude uložena v elektronické podobě v univerzitním informačním systému dostupná k prezenčnímu nahlédnutí, že jeden výtisk diplomové/bakalářské práce bude uložen v příruční knihovně Fakulty aplikované informatiky Univerzity Tomáše Bati ve Zlíně a jeden výtisk bude uložen u vedoucího práce;
- byl/a jsem seznámen/a s tím, že na moji diplomovou/bakalářskou práci se plně vztahuje zákon č. 121/2000 Sb. o právu autorském, o právech souvisejících s právem autorským a o změně některých zákonů (autorský zákon) ve znění pozdějších právních předpisů, zejm. § 35 odst. 3;
- beru na vědomí, že podle § 60 odst. 1 autorského zákona má UTB ve Zlíně právo na uzavření licenční smlouvy o užití školního díla v rozsahu § 12 odst. 4 autorského zákona;
- beru na vědomí, že podle § 60 odst. 2 a 3 autorského zákona mohu užít své dílo – diplomovou/bakalářskou práci nebo poskytnout licenci k jejímu využití jen s tím, že licenční smlouva uzavřená mezi mnou a Univerzitou Tomáše Bati ve Zlíně s tím, že vyrovnání případného přiměřeného příspěvku na úhradu nákladů, které byly Univerzitou Tomáše Bati ve Zlíně na vytvoření díla vynaloženy (až do jejich skutečné výše) bude rovněž předmětem této licenční smlouvy;
- beru na vědomí, že pokud bylo k vypracování diplomové/bakalářské práce využito softwaru poskytnutého Univerzitou Tomáše Bati ve Zlíně nebo jinými subjekty pouze ke studijním a výzkumným účelům (tedy pouze k nekomerčnímu využití), nelze výsledky diplomové/bakalářské práce využít ke komerčním účelům;
- beru na vědomí, že pokud je výstupem diplomové/bakalářské práce jakýkoliv softwarový produkt, považují se za součást práce rovněž i zdrojové kódy, popř. soubory, ze kterých se projekt skládá. Neodevzdání této součásti může být důvodem k neobhájení práce.

### **Prohlašuji,**

- že jsem na diplomové/bakalářské práci pracoval samostatně a použitou literaturu jsem citoval. V případě publikace výsledků budu uveden jako spoluautor.
- že odevzdaná verze diplomové práce a verze elektronická nahraná do IS/STAG jsou totožné.

Ve Zlíně, dne 1.6.2016

  
.....  
podpis diplomanta

## **ABSTRAKT**

Výzkum lidského mozku je jednou z největších výzev lidského pokolení. V první části této práce jsou diskutovány různé přístupy výzkumu a ústřední předpoklady, ze kterých se při studiu mozku vychází. Dále je probrána problematika umělých neuronových sítí, a jak s výzkumem souvisí. Ve druhé části poté vytvoříme lingvistický model, který se bude učit generovat text bez znalosti explicitních pravidel jazyka.

Klíčová slova: Mozek, Umělá inteligence, Umělá neuronová síť

## **ABSTRACT**

Research of the human brain is one of the biggest challenges of mankind. In the first part of this work, different approaches of the research are discussed as well as the core assumptions used in studies of the brain. Further, we discuss artificial neural networks and how they relate to the research. In the second part of this work we create a linguistic model, which will learn how to generate text without any explicit knowledge of the rules of the language.

Keywords: Brain, Artificial Intelligence, Artificial Neural Network

Tímto bych rád poděkovat vedoucímu bakalářské práce doc. Ing. Romanu Šenkeříkovi Ph.D. za odbornou pomoc a vedení v průběhu tvorby této práce. Také bych rád poděkoval svým rodičům za podporu v průběhu celého studia.

Prohlašuji, že odevzdaná verze bakalářské/diplomové práce a verze elektronická nahraná do IS/STAG jsou totožné.

## OBSAH

<b>OBSAH</b> .....	<b>7</b>
<b>ÚVOD</b> .....	<b>9</b>
<b>I. TEORETICKÁ ČÁST</b> .....	<b>10</b>
<b>1 KOGNITIVNÍ VĚDA</b> .....	<b>11</b>
<b>1.1 PRINCIPY ZKOUMÁNÍ</b> .....	<b>11</b>
1.1.1 PŘÍRODOVĚDNÝ PŘÍSTUP .....	11
1.1.2 FENOMENOLOGICKÝ PŘÍSTUP .....	12
1.1.3 KONSTRUKTIVNÍ PŘÍSTUP .....	13
<b>1.2 POPIS „SHORA“ A „ZDOLA“</b> .....	<b>14</b>
<b>1.3 EMERGENCE</b> .....	<b>14</b>
<b>1.4 KONEKCIONISMUS</b> .....	<b>15</b>
<b>2 UMĚLÉ NEURONOVÉ SÍTĚ</b> .....	<b>16</b>
<b>2.1 BIOLOGICKÝ NEURON</b> .....	<b>16</b>
<b>2.2 MATEMATICKÝ NEURON</b> .....	<b>17</b>
<b>2.3 ZÁKLADNÍ TOPOLOGIE NEURONOVÝCH SÍTÍ</b> .....	<b>18</b>
<b>2.4 UČENÍ NEURONOVÝCH SÍTÍ</b> .....	<b>20</b>
2.4.1 TRÉNOVACÍ A TESTOVACÍ MNOŽINA .....	20
2.4.2 FUNKCE NEURONOVÉ SÍTĚ .....	20
2.4.3 CHYBOVÁ FUNKCE .....	21
2.4.4 ALGORITMUS BACKPROPAGATION .....	21
2.4.5 VARIACE ALGORITMU BACKPROPAGATION.....	23
<b>2.5 SIMULAČNÍ PROSTŘEDÍ PRO NEURONOVÉ SÍTĚ</b> .....	<b>23</b>
2.5.1 EMERGENT NEURAL NETWORK SIMULATION SYSTÉM .....	24
2.5.2 WOLFRAM MATHEMATICA NEURAL NETWORKS.....	24
2.5.3 NEUROPH.....	25
<b>II. PRAKTICKÁ ČÁST</b> .....	<b>27</b>
<b>3 LINGVISTICKÝ MODEL</b> .....	<b>28</b>
<b>3.1 PRINCIP MODELU</b> .....	<b>28</b>
<b>3.2 POUŽITÝ MODEL</b> .....	<b>29</b>
3.2.1 VSTUPNÍ VRSTVA.....	29
3.2.2 LONG SHORT TERM MEMORY .....	29
3.2.3 SOFTMAXOVÁ VRSTVA .....	31
3.2.4 CELKOVÁ TOPOLOGIE .....	32
3.2.5 UČÍCÍ ALGORITMUS .....	32
<b>3.3 IMPLEMENTACE MODELU</b> .....	<b>33</b>
<b>3.4 TRÉNOVACÍ MNOŽINA</b> .....	<b>34</b>
3.4.1 FORMÁT TEXTU .....	34
3.4.2 MNOŽINA ZNAKŮ.....	35
3.4.3 KATEGORIE .....	35
<b>4 VYHODNOCENÍ VÝSLEDKŮ</b> .....	<b>37</b>

<b>4.1 DATASET VELIKOSTI 20 MB .....</b>	<b>37</b>
<b>4.2 DATASET VELIKOSTI 50 MB .....</b>	<b>38</b>
<b>4.3 DATASET VELIKOSTI 860 MB .....</b>	<b>39</b>
4.3.1 EPOCHA 0,11 .....	39
4.3.2 EPOCHA 1,01 .....	40
4.3.3 EPOCHA 3,48 .....	40
4.3.4 EPOCHA 6,39 .....	41
4.3.5 EPOCHA 10,76 .....	41
4.3.6 EPOCHA 15,14 .....	42
4.3.7 TEPLOTA 0,8.....	42
4.3.8 TEPLOTA 0,5.....	43
4.3.9 TEPLOTA 0,2.....	44
<b>ZÁVĚR .....</b>	<b>45</b>
<b>SEZNAM POUŽITÉ LITERATURY.....</b>	<b>46</b>
<b>SEZNAM POUŽITÝCH SYMBOLŮ A ZKRATEK.....</b>	<b>48</b>
<b>SEZNAM OBRÁZKŮ .....</b>	<b>49</b>
<b>SEZNAM TABULEK.....</b>	<b>50</b>
<b>SEZNAM PŘÍLOH.....</b>	<b>51</b>

## ÚVOD

Lidský mozek je ten nejsložitější objekt, na jaký jsme doposud ve vesmíru narazili.

Pochopit jak funguje, může být ta nejtěžší věc, jakou tato civilizace kdy dokáže.

Avšak ani frustrace z toho, jak málo toho o mozku víme, ani těžkost, jakou provází snaha dozvědět se více, nedokáže zastavit desetitisíce, ne-li statisíce lidí, kteří jsou do této záhady nenávratně zamilováni.

Studium mozku je jednou z nejzajímavějších oblastí lidské působnosti. Původně výzkum byl převážně psychologický, s rozvojem medicíny se začal mozek zkoumat i přímo. A nyní v době informatiky je možné mozek zkoumat i nepřímo, a to pomocí vytváření modelů, které jsou inspirovány reálnými procesy v nervové soustavě.


V této práci se tedy budeme zabývat studiem mozku z pohledu informatiky. V teoretické části nejdříve rozebereme přístup kognitivních věd, poté se budeme zabývat problematikou umělých neuronových sítí.

V praktické části poté budeme diskutovat lingvistický model, který se bude učit generovat text bez jakékoliv explicitní znalosti pravidel jazyka, čímž budeme emulovat schopnost mozku učit se přirozenému jazyku.

## I. TEORETICKÁ ČÁST

## 1 KOGNITIVNÍ VĚDA

Kognitivní věda je snaha o mezioborový výzkum mysli. Slučuje dohromady disciplíny jako psychologie, umělá inteligence, filosofie, lingvistika, neurověda, biologie.



Obrázek 1 Schéma disciplín, které kognitivní věda zastřešuje

Předmětem zkoumání jsou funkce a procesy mysli jako jsou pozornost, paměť, vnímání, učení, ale také složitější fenomény, mezi které můžeme zařadit jazyk, komunikace, emoce, vůle, vědomí, atd.

### 1.1 Principy zkoumání

V kognitivních vědách lze ke zkoumání přistoupit z několika různých hledisek, každé z nich zde rozebereme.


#### 1.1.1 Přírodovědný přístup

Je založen na empirickém způsobu zkoumání pomocí měření, pozorování a laboratorních experimentů. Zde se řadí hlavně biologické, neurovědní a některé psychologické obory. Výhodou tohoto přístupu je objektivita, která vyplývá z přímé aplikace vědecké metody. Problémem tohoto přístupu je fakt, že zatím neexistuje příliš mnoho prostředků pro měření smysluplných veličin. Co se týče monitorování mozkové aktivity, existují buď makroskopické a kvantitativní metody (např. EEG, fMRI), anebo mikroskopické metody, které jsou schopny podrobně monitorovat aktivitu poměrně malé skupiny neuronů (elektrofyzilogické měření). Těmito metodami lze tedy popsat pouze globální vzory chování jedince a aktivity

mozku (např. spojení aktivity dané části mozku s konkrétní činností), anebo naopak vzory na velmi nízké úrovni, jako je chemická aktivita jednotlivých neuronů a jejich vzájemná interakce.

Tyto přístupy jsou velmi užitečné při zkoumání a diagnostice mnoha nervových onemocnění a vad. Ani jeden z těchto přístupů však není schopen vysvětlit a popsat fenomény, jako je jazyk, sociální inteligence, abstrakce, atd. Tyto jevy se zdají být spíše výsledkem složité, avšak uspořádané aktivity mnoha různých center, kterou lze přímo jen velmi těžko zkoumat.

[1]



Obrázek 2 Příklad fMRI skenu lidského mozku

### 1.1.2 Fenomenologický přístup

Dalo by se říci, že tento přístup je opakem přístupu přírodovědeckého. Zkoumání mysli je založeno na přímém zkoumání vnitřních prožitků z pohledu první osoby, jedná se tedy o přístup subjektivní. Tímto směrem se ubíral výzkum mysli až do vzniku empiricky založené experimentální psychologie v 19. století. Tento směr je zastoupen psychologickými a filosofickými obory, které vycházejí z introspekce. [1]

Zřejmou nevýhodou je absence objektivity, protože směr nevyhází z vědecké metody. Nelze však proto tuto oblast zkoumání lidského prožitku zatratit. Problém s vědeckou metodou je ten, že je založena na abstrakci, modelování, konceptualizaci. Vychází tedy z předpokladu, že daný jev lze popsat pomocí jazykových definicí, symbolů a vztahů mezi těmito symboly. Jedná se o snahu nahradit realitu dostatečně dobrým modelem tak, abychom mohli zapomenout na to, že se jedná pouze o abstraktní model.

Nelze však opomenout, že jazyk a abstrakce jsou limitovány samy sebou. Slova, věty a symboly dávají smysl pouze vzhledem k ostatním slovům, větám a symbolům. Samotné slovo, koncept neznámá nic, pokud k němu nejsou vztaženy ostatní koncepty, které s ním souvisí (např. k čemu je koncept dveří, když nevíme, že jimi můžeme projít, že se nachází v domě, že oddělují místnosti, atd.).

Vědecký přístup předpokládá, že *vše* lze popsat pomocí abstrakce a jazyka, ale co když to není pravda? Příkladem by mohlo být vědomí jako takové. Těžko lze tento fenomén exaktně definovat, ale každý intuitivně *ví*, o co se jedná. Vědomí lze popsat jako *to*, v čem se odehrává myšlení, smyslové vnímání, emoce, vzpomínání, atd. Tedy jako *to*, co je nám nejbližší, *to*, co prožívá. Co když *to*, v čem se abstrakce odehrává nelze již z principu pomocí abstrakce popsat? Co když to lze *pochopit* pouze za pomoci přímého prožívání?

Proto nelze přístup přímého prožitku zcela vyloučit a lze očekávat, že pokud má věda jako taková udělat *kvalitativní* krok vpřed, tento přístup by měl být zohledněn a zkoumán. Veškerá pozornost vědce je upřena do vnějšího světa a to lze říci i v případě zkoumání mozku a psychologie člověka. Žádná pozornost však není věnována *tomu, co zkoumá*. A možná, že právě v tom spočívá klíč k hlubšímu pochopení člověka.

### 1.1.3 Konstruktivní přístup

Je založen na vytváření umělých modelů a simulací za účelem reprodukce vzoru chování, který byl pozorován např. v mozku. Fundamentálním předpokladem tohoto přístupu je to, že mozek provádí výpočet, operuje na určité množině vstupů, výstupů a vnitřních stavů. A tedy, že jeho procesy a funkce lze modelovat pomocí určitých adaptivních algoritmů. [1]

Výhoda přístupu spočívá v tom, že nevyžaduje explicitní znalost struktury a fungování lidského mozku, umožňuje experimentovat s různými modely a různými úrovněmi znalostní o jeho fungování. Zároveň umožňuje přímé ověření správnosti modelu na základě simulace.


Do tohoto přístupu lze zařadit umělou inteligenci, např. multiagentní systémy a neuronové sítě, o kterých budeme mluvit dále.

## 1.2 Popis „shora“ a „zdola“

Tento princip již byl částečně popsán v odstavci o přírodovědném přístupu, kde byly zmíněny metody makroskopické a mikroskopické. Makroskopické metody lze přirovnat k pohledu *shora*, kdy je mozek zkoumán z hlediska globálních vzorů aktivity a psychologických funkcí zatímco pohled *zdola* zkoumá jednotlivé neurony a jejich aktivitu.

To samé dělení lze aplikovat i na metody konstruktivní. Pohled *shora* je reprezentován algoritmy, které přímo operují se symboly. V této práci se budeme zabývat pohledem *zdola*, kdy se snažíme modelovat jednotlivé neurony a vazby mezi nimi tak, aby výsledkem byla smysluplná, „inteligentní“ aktivita. [1]

Mezi úrovní jednotlivých neuronů a úrovní psychologických funkcí se nachází obrovská mezera ve vědění lidstva. Čím menší bude mezera oddělující tyto úrovně, tím více budeme rozumět tomu, jak vlastně mozek a mysl fungují. Stále není ani zdaleka jasné, jak se aktivita jednotlivých neuronů promítá do jednotlivých psychologických funkcí. Bylo nalezeno již mnoho vazeb a vodítek, která nám objasňují, jaká část mozku souvisí s příslušnou psychologickou funkcí, chybí ale ucelenější pochopení.



Obrázek 3 Neuron pod mikroskopem

## 1.3 Emergence

Jedním z hlavních paradigmat ve snaze popsat funkci lidského mozku je princip emergence. V té nejjednodušší formě jej lze popsat jako vlastnost systému, kdy z dostatečné kvantity vzejde kvalita, kterou nevykazuje žádná samostatná součást systému.

Analogií například může být voda, která je postupně ohřívána na bod varu. Nejdříve je voda stálá, nic zvláštního se neděje, postupně se ohřívá, a jakmile teplota dosáhne kritické hodnoty, nastane náhlá kvalitativní změna systému. Podobným příkladem emergentního chování je zažehnutí hvězdy, kdy se postupně zhušťuje oblak plynu, vlastní gravitací se stlačuje, tím stoupá teplota a při dosažení kritického bodu započne jaderná fúze.

Příbuzným příkladem emergence je teorie evoluce. Kdy emergentními vlastnostmi jsou přirozený výběr a princip mutace. Princip emergence lze nalézt napříč mnoha vědními obory na mnoha různých úrovních.

Nyní se dostáváme k jednomu ze základních předpokladů výzkumu mysli. A tj., že mysl je emergentní vlastností mozku.

Předpokládá se tedy, že aktivita jednotlivých neuronů na základě relativně jednoduchých pravidel dává v počtu miliard vzniku mysli a zdánlivých psychologických funkcí. Zdánlivých proto, že kdyby tomu tak bylo, tak je nelze považovat za oddělené od mozku jako takového.

Pokud by tento předpoklad byl správný, tak dalším důsledkem by bylo, že tato emergentní vlastnost by nebyla exkluzivní pouze pro mozek, ale pro jakýkoliv systém, který by splňoval určité požadavky. Bylo by tedy možné vytvořit mysl i v počítači. O jaké požadavky se jedná, není zatím zcela jasné, avšak ty přímočařejší z nich se již postupně rýsují, viz dále.

## 1.4 Konekcionismus

Jedná se o paradigma, které zastřešuje emergentní přístup v rámci kognitivních věd. Formuluje a uvažuje některé základní požadavky pro systém, který by mohl vykazovat podobné emergentní vlastnosti jako mozek.

Konekcionistický systém se skládá z množství jednotlivých prvků, přičemž každý z nich se může nacházet v určitém stavu. Tento stav je závislý na stavech ostatních prvků, případně na vstupních signálech. Míra ovlivnění mezi jednotlivými prvky je dána vahami vazeb mezi nimi, přičemž váhy mohou být jak pozitivní, tak negativní. Váhy vazeb mezi prvky se postupně mění, v závislosti na předchozí aktivitě.

Pokud budeme uvažovat prvky jako neurony a vazby jako synapse, pak postupná změna vah je analogií synaptické plasticity. Do tohoto paradigmatu spadá hlavně výzkum tzv. umělých neuronových sítí, o kterých bude řeč dále. [1]


## 2 UMĚLÉ NEURONOVÉ SÍTĚ

V této práci se budeme zabývat zpravidla problematikou umělých neuronových sítí. Jedná se o analogii ke skutečným neuronovým sítím, které tvoří nervovou soustavu živočichů, včetně člověka. Některé oblasti výzkumu umělých neuronových sítí (dále jen ANN, z anglického *Artificial Neural Network*) se zaměřují na modelování biologických neuronů a neuronových sítí, za účelem ověřit, případně obohatit výzkum z oblasti neurofyzologie. Jiné oblasti zkoumání ANN se nesnaží o přímou reprodukci biologických procesů, ale pouze využívají jistých rysů skutečných neuronových sítí. Těchto lze poté použít opět ve snaze o reprodukci procesů pozorovaných v mozku ale také pro mnoho dalších aplikací, které vyžadují *machine learning*. Za určitých podmínek je neuronová síť ekvivalentní turingově stroji [2].

### 2.1 Biologický neuron

Neuron je základní buňka nervové soustavy. Jedná se o velmi specializovanou buňku, jejímž úkolem je tvořit, přenášet a zpracovávat nervové vzruchy, což jsou elektrochemické signály. Na (Obr. 4) vidíme náčrtek stavby neuronu. Rozlišujeme tělo buňky, které obsahuje jádro, dále dendrity, což jsou výběžky z těla neuronu, které vedou nervové vzruchy do těla neuronu. Dalším prvkem je axon, což je jeden dlouhý výběžek, který je na konci rozvětvený a umožňuje přenášet nervové vzruchy z těla neuronu k dalším neuronům.


Neurony jsou mezi sebou propojeny pomocí tzv. synapsí, které zprostředkovávají přenos signálu z nervového zakončení jednoho neuronu na membránu dendritu druhého neuronu. Děje se tak za pomoci chemické látky, kterou nazýváme neurotransmitter. [3]



Obrázek 4 Struktura neuronu

## 2.2 Matematický neuron

Matematický neuron je silně zjednodušeným modelem biologického neuronu. Označení neuron by se dalo označit až za zavádějící. Podobnými rysy je to, že neuron má několik vstupů, ale pouze jeden výstup, který může vést do několika dalších neuronů. Každá vazba, synapse mezi neurony má váhu, kterou se násobí signál procházející synapsí. Ta může být jak kladná, tak záporná, tím se simulují excitační a inhibiční charakter vazeb neuronů. Neuron jako takový zpracovává vstupní signál a generuje signál výstupní. Lze jej tedy reprezentovat nějakou funkcí vstupu a vah.



Obrázek 5 Schéma matematického neuronu

Na (Obr. 5) vidíme funkční diagram matematického neuronu. Každá vstupní hodnota je vynásobena příslušnou vahou, všechny vážené vstupy jsou sečteny, přičte se hodnota *bias* (posunutí lineární závislosti) a výsledek je použit jako vstup do aktivační funkce, pomocí které se vypočte výstup neuronu. Neuron lze tedy popsat pomocí následujících vztahů:

$$\xi = \sum_{i=1}^n x_i w_i + b \quad (1)$$

$$y = f(\xi) \quad (2)$$

Kde  $\xi$  je vnitřní potenciál neuronu,  $x$  je vektor vstupů,  $w$  je vektor vah,  $b$  je tzv. *bias*,  $y$  je výstup neuronu a  $f(\xi)$  je aktivační funkce.

V zásadě se používají převážně 3 aktivační funkce. Nejjednodušším typem je pouhá lineární závislost, tedy:

$$f(\xi) = \xi \quad (1)$$

Neuron s touto aktivační funkcí označujeme jako lineární neuron. Další, asi nejčastěji využívanou funkcí je logistická sigmoida:

$$f(\xi) = \frac{1}{1+e^{-\lambda\xi}} \quad (4)$$

Kde parametr  $\lambda$  určuje strmost funkce v okolí nuly. Třetí hojně využívanou aktivační funkcí je hyperbolický tangens:

$$f(\xi) = \frac{e^{2\xi}-1}{e^{2\xi}+1} \quad (5)$$

Poslední dvě funkce se zásadně liší ve svém charakteru, protože jak ukazuje (Obr. 6), funkce sigmoid je v rozsahu  $\langle 0; 1 \rangle$ , zatímco funkce tanh je v rozsahu  $\langle -1, 1 \rangle$ . Proto se aktivační funkce volí v závislosti na požadované aplikaci.


Obrázek 6 Porovnání funkce sigmoid a tanh

### 2.3 Základní topologie neuronových sítí


Rozlišujeme dvě základní topologická uspořádání neuronů a synapsí v neuronové síti.

- Dopředná neuronová síť (anglicky *feedforward neural network*)
- Rekurentní neuronová síť (anglicky *recurrent neural network*, dale jen RNN)

Stručně řečeno dopředná neuronová síť neobsahuje cykly, takže signál se vždy pohybuje pouze jedním směrem od vstupních jednotek k výstupním jednotkám. Zatímco rekurentní neuronová síť obsahuje cykly, takže signál z předchozího kroku se přenáší přes rekurentní synapse do aktuálního kroku. Příklad dopředné topologie sítě je na (Obr. 7). Příklad rekurentní topologie je na (Obr. 8).



Obrázek 7 Dopředné uspořádání ANN



Obrázek 8 Rekurentní uspořádání ANN

Obě topologie mají svá specifika, výhody i nevýhody. Dopředné sítě jsou zpravidla jednodušší na implementaci, a je snazší je trénovat, avšak díky neschopnosti si uchovat vnitřní stav je nezbytné, aby všechny potřebné informace vždy byly součástí vstupu. Zatímco rekurentní neuronové sítě jsou složitější, avšak jsou schopné v průběhu času uchovávat informace, tedy jsou vhodné např. na předpovídání časových řad.

## 2.4 Učení neuronových sítí

Nyní se dostáváme k té nejkritičtější součásti všech modelů neuronových sítí, tj. k procesu učení. Mít model je samo o sobě k ničemu, když neznáme způsob, jakým model přimět k tomu, aby se choval žádoucím způsobem. V tomto případě se snažíme cíleně měnit parametry modelu tak, aby se snížila jeho chybovost.

Ukážeme si princip základního algoritmu *backpropagation*, jehož princip je využíván ve většině dnes užívaných metod učení.

### 2.4.1 Trénovací a testovací množina

Neuronové sítě jsou univerzální aproximátor [4]. Za určitých předpokladů jsou tedy schopny aproximovat libovolnou reálnou funkci. Základním principem učení ANN je to, že máme nějakou množinu dvojic vstup-výstup a snažíme se dosáhnout toho, že ANN aproximuje funkci, která při daném vstupu vyprodukuje výstup co nejbližší tomu z této množiny.

Tuto množinu nazýváme *trénovací* množinou. Při učení sítě se snažíme vyhnout tomu, aby se učila přiřazovat správný výstup ke vstupu „nazpaměť“, spíše se snažíme dosáhnout schopnosti generalizace, kdy síť abstrahuje pravidla, podle kterých se daný problém řídí.

K ověření této schopnosti používáme tzv. *testovací* množinu. Princip spočívá v tom, že před začátkem učení část trénovací množiny oddělíme (např. 5 %) a ponecháme ji stranou. Tedy v průběhu učení síť tato data nikdy neuvidí, a poté je používáme pro ověření schopnosti generalizace. V případě, že se na konci učení chyba na testovací množině příliš neliší od chyby na trénovací množině, lze usoudit, že síť je generalizace schopná.

Označme si tedy množinu všech vzorů jako  $T$  a vektor vstupu pro daný vzor jako  $x$ . Každý z těchto vektorů má délku  $m$ , a  $i$ -tou hodnotu označíme dolním indexem,  $x_i$ . Vektor požadovaných výstupů pro daný vzor označíme jako  $d$  přičemž  $i$ -tou hodnotu označíme jako  $d_i$ .

### 2.4.2 Funkce neuronové sítě

Nyní si definujeme neuronovou síť jako takovou. Budeme uvažovat dopřednou topologii, tedy bez zpětných smyček, kde jsou propojeny neurony jen mezi sousedními vrstvami, a to způsobem „každý s každým“. Síť má  $m$  vstupních jednotek a  $n$  výstupních jednotek a  $h$  skrytých vrstev (tedy vrstev mezi vstupní a výstupní vrstvou). Množinu všech vah označíme  $w$ . Pro neurony  $i$  a  $j$ , které se nachází v sousedních vrstvách, označíme váhu jejich synapse

jako  $w_{ij}$ , přičemž signál putuje z  $i$  do  $j$ . Vektor výstupních funkcí sítě označíme jako  $y$ . Potom lze definovat:

$$y: \mathbb{R}^m \rightarrow \mathbb{R}^n \quad (6)$$

$$y = f(w, x) \quad (7)$$

Tedy, že výstup neuronové sítě je funkcí vstupu a vah všech propojení v síti. Zároveň pro neuron  $j$  je  $y_j$  výstupem neuronu,  $\xi_j$  vnitřním potenciálem,  $b_j$  je bias a  $X_j$  je množinou všech neuronů, které mu posílají signál na vstup, pak platí:

$$\xi_j = \sum_{i \in X_j} y_i w_{ij} - b_j \quad (8)$$

$$f(\xi_j) = \frac{1}{1 + e^{-\xi_j}} \quad (9)$$

Uvažujeme zde aktivační funkci sigmoid, bez parametru.

### 2.4.3 Chybová funkce

Když jsme definovali trénovací data a neuronovou síť, je třeba určit nějaký způsob posouzení chyby při aproximaci. Základním přístupem je použití střední kvadratické odchylky. Definujeme tedy chybovou funkci jako:

$$E = \frac{1}{2} \sum_{d \in T} \sum_{j \in Y} (d_j - y_j)^2 \quad (10)$$

Jedná se o součet odchylek všech výstupních neuronů pro každý vzor ve trénovací množině. Chybová funkce je závislostí chyby na konfiguraci vah sítě.

### 2.4.4 Algoritmus backpropagation

Dostáváme se k jádru metody učení. Pointa spočívá v tom, že se snažíme smysluplně upravit váhy jednotlivých synapsí tak, aby se snížila celková chyba sítě na trénovací množině.

Pro danou váhu  $w_{ij}$  upravíme její hodnotu podle vzorce:

$$w_{ij}^{(t)} = w_{ij}^{(t-1)} - \varepsilon \frac{\partial E}{\partial w_{ij}} \quad (11)$$

Kde  $\varepsilon$  určuje rychlost učení (anglicky *learning rate*). Horní indexy u váhy určují, o jaký časový krok se jedná, tedy váhu v aktuálním kroku vypočteme odečtením parciální derivace od váhy v předchozím kroku. Hodnota parciální derivace chyby podle váhy nám určí směrnici tečny plochy chybové funkce v daném bodě. Tato směrnice určuje směr růstu chyby, ale my se snažíme chybu zmenšit, proto ji odečítáme. Aby se jednotlivé váhy neměnily příliš

rychle, násobíme hodnotu derivace parametrem rychlosti učení, který je zpravidla vždy podstatně menší než 1.

Uvažujme neuron  $j$  ve výstupní vrstvě a neuron  $i$ , který je na neuron  $j$  napojený. Na základě pravidlu o derivaci složené funkce lze psát:

$$\frac{\partial E}{\partial w_{ij}} = \frac{\partial E}{\partial y_j} \frac{\partial y_j}{\partial \xi_j} \frac{\partial \xi_j}{\partial w_{ij}} \quad (12)$$

Poslední dva prvky, tj. derivaci výstupu a akčního potenciálu lze vypočítat přímo derivováním aktivační funkce a funkce váženého součtu vstupů. Tam tedy problém není. To co je ale na této metodě klíčové je určení derivace  $\frac{\partial E}{\partial y_j}$ . Pro neuron  $j$  ve výstupní vrstvě lze psát:

$$\frac{\partial E}{\partial y_j} = \sum_{d \in T} (d_j - y_j) \quad (13)$$

Určení této hodnoty je triviální, úprava vstupních vah výstupní vrstvy je tedy v podstatě bezproblémová. Složitější je však určení této chyby pro neurony ve skrytých vrstvách. Předpokládejme tedy neuron  $j$ , který se nachází ve skryté vrstvě, přičemž adaptujeme hodnotu váhy synapse  $w_{ij}$  (tedy z  $i$  do  $j$ ).

$$\frac{\partial E}{\partial w_{ij}} = \frac{\partial E}{\partial y_j} \frac{\partial y_j}{\partial \xi_j} \frac{\partial \xi_j}{\partial w_{ij}} \quad (14)$$

Užijeme stejného vztahu jako pro výstupní vrstvu, snažíme se určit hodnotu  $\frac{\partial E}{\partial y_j}$  pro daný neuron. Vztah vypadá následovně:

$$\frac{\partial E}{\partial y_j} = \sum_{k \in Y_j} \frac{\partial E}{\partial y_k} \frac{\partial y_k}{\partial \xi_k} \frac{\partial \xi_k}{\partial y_j} \quad (15)$$

Kde  $Y_j$  je množinou všech neuronů, na které je výstup neuronu  $j$  připojen. Protože výstup neuronu  $j$  ovlivňuje každý další neuron, na který je připojen, je třeba provést sumu přes všechny výstupy z tohoto neuronu.  $\frac{\partial y_k}{\partial \xi_k}$  a  $\frac{\partial \xi_k}{\partial y_j}$  opět vypočteme snadno ze zadaných vztahů pro daný typ neuronu a poslední prvek který zbývá určit je  $\frac{\partial E}{\partial y_k}$ , což je vlastně stejná derivace kterou se snažíme určit pro neuron  $j$ , pouze o vrstvu výše.

Tedy předpokladem určení  $\frac{\partial E}{\partial y_j}$ , je znalost těchto derivací pro všechny neurony, na které je výstup neuronu  $j$  připojen. Proto se algoritmus nazývá *backpropagation*, česky metoda zpětného šíření. Jedná se v podstatě o opak určení výstupní hodnoty sítě, kde začínáme u vstupu a signál se postupně šíří sítí až na výstup. Během učení začneme určením chybových derivací

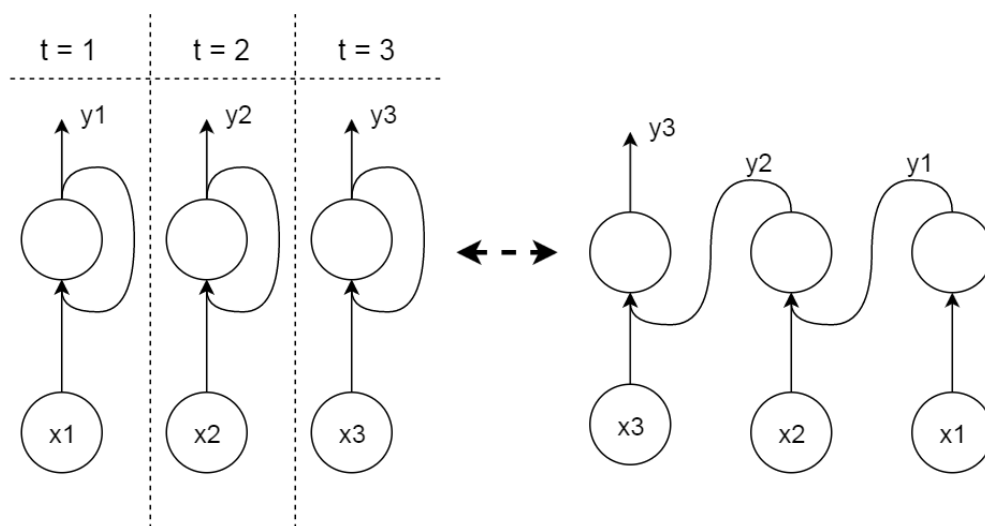
na výstupu a poté podle naznačených vztahů postupujeme směrem ke vstupu, až se dostaneme na vrstvu vah mezi vstupy a první skrytou vrstvou. Proto algoritmus zpětného šíření.

Adaptace vah tedy probíhá tak, že nejdříve určíme derivaci pro každý vzor zvlášť, postupně akumulujeme hodnoty změny pro každou váhu a po průchodu celými daty akumulovanou hodnotu upravenou rychlostí učení odečteme od příslušné váhy. Tento proces opakujeme tak dlouho, než celková chyba sítě klesne pod požadovanou hodnotu. [5]

### 2.4.5 Variace algoritmu backpropagation

Další možností je rozdělit trénovací data na několik částí a upravovat váhy po průchodu každou částí. To může být užitečné hlavně v případě velké trénovací množiny, kdy by akumulované změny vah mohly být příliš velké a tím značně zpomalit konvergenci k přijatelné chybě. Tento přístup se nazývá *mini-batch learning*.

Podstatnou variantou je algoritmus *backpropagation through time* (BPTT), který umožňuje použití algoritmu *backpropagation* (BP) na rekurentní neuronové síti. Princip spočívá v tom, že síť rekurentní převedeme na síť dopřednou podle schématu na (Obr. 9) a použijeme stejná pravidla jako pro algoritmus BP, rozdíl je pouze v tom, že rozložením sítě se některé váhy opakují, takže reálný počet vah je menší než počet synapsí v rozložené síti. [6]



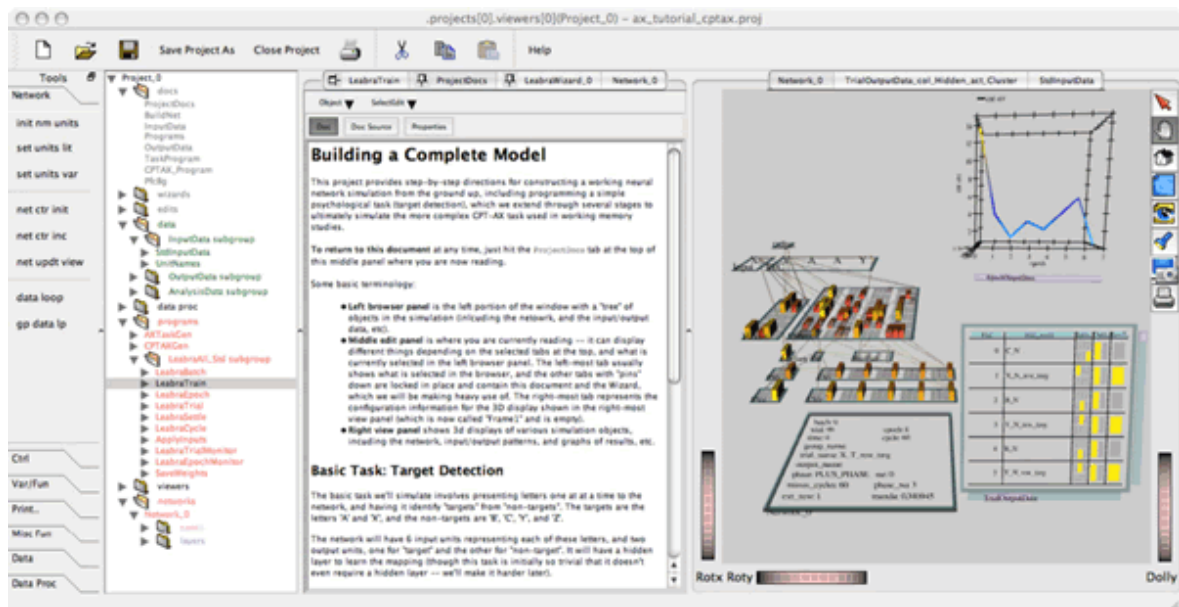
Obrázek 9 Schéma převodu rekurentní sítě na síť dopřednou pro 3 časové kroky

## 2.5 Simulační prostředí pro neuronové sítě

V této části probereme několik simulátorů umělých neuronových sítí.

### 2.5.1 Emergent Neural Network Simulation System

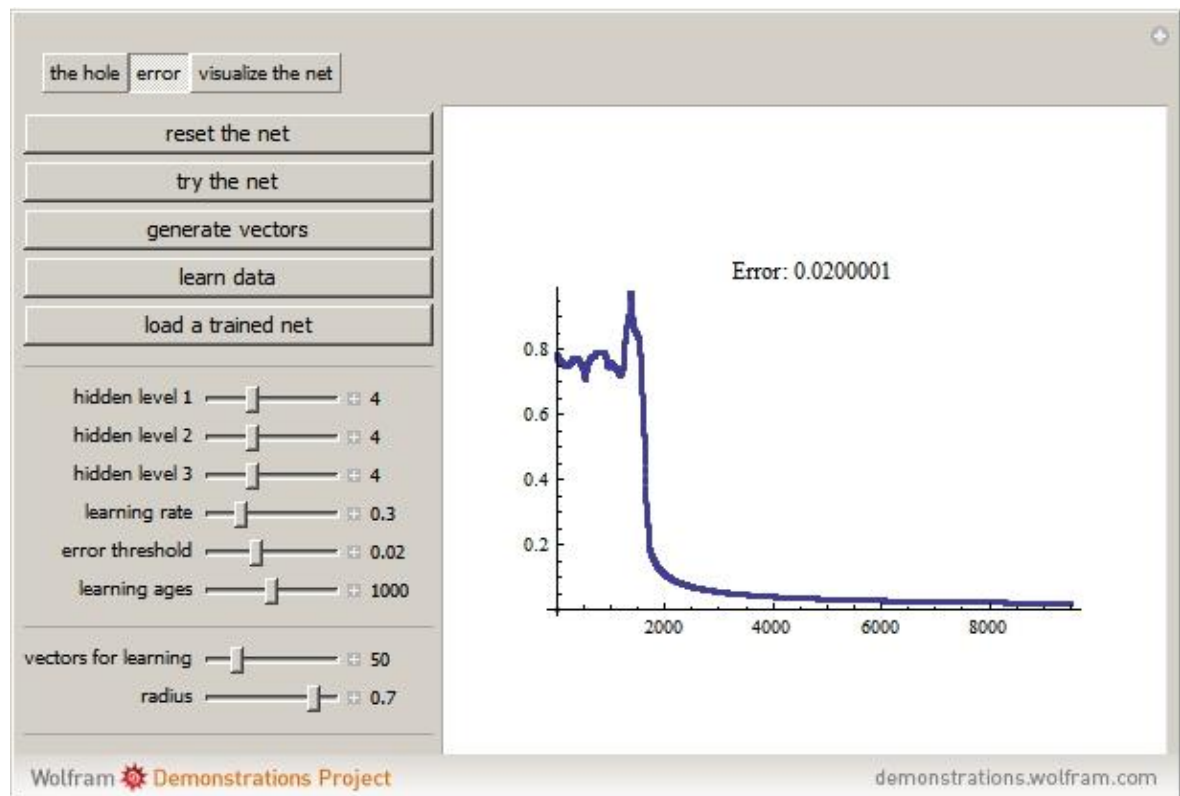
Emergent je bohatě vybavený simulátor neuronových sítí, který umožňuje vytváření a úpravu neuronových sítí ve 3D vizuálním prostředí. Systém, kromě možnosti manuálního zadávání skrze GUI, umožňuje použití skriptovacího jazyka *css* (nemá nic společného s *weby*). Tím pádem je software vhodný jak pro začátečníky, tak pro pokročilé uživatele. Podporuje paralelní výpočty na GPU, obsahuje implementace velkého množství učících algoritmů a druhů neuronových sítí. Součástí prostředí je simulátor newtonovské fyziky, který umožňuje mnohé simulace ovládnání robotů. [7]



Obrázek 10 Screenshot prostředí simulátoru Emergent

### 2.5.2 Wolfram Mathematica Neural Networks

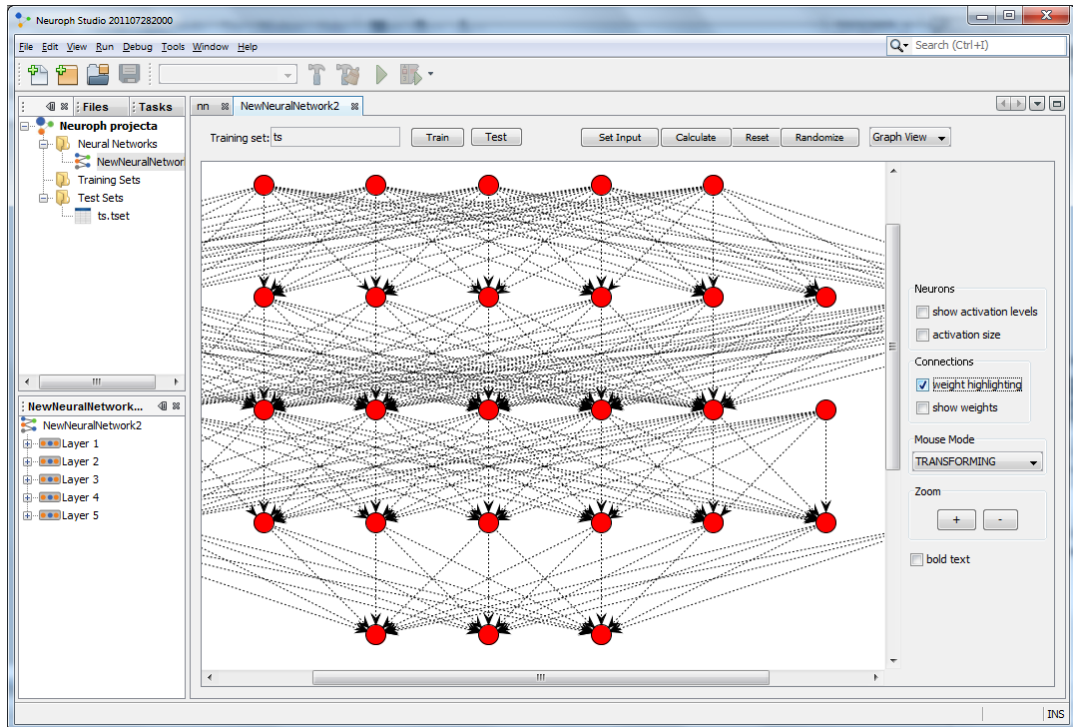
Jedná se o produkt rozšiřující prostředí programu Wolfram Mathematica. Obohacuje již tak velmi vybavené prostředí o funkce a moduly pro trénování a analýzu neuronových sítí. Podporuje jak základní algoritmy jako backpropagation, tak pokročilé algoritmy jako Levenberg-Marquardtovu metodu a Gauss-Newtonovu metodu. Obsahuje moduly pro vizualizaci učení sítí a struktury sítí. Podporuje většinu druhů neuronových sítí. Není vybaven kompletním GUI prostředím, spíše pokračuje v duchu Wolfram Mathematica, který je založen spíše na programování a skriptování. Také podporuje použití GPU při učení. [8]



Obrázek 11 Screenshot rozšíření Neural Networks pro Wolfram Mathematica

### 2.5.3 Neuroph

Neuroph je prostředí naprogramované v jazyku Java, které umožňuje vytvářet a testovat neuronové sítě v pohodlí grafického prostředí. Díky tomu, že je celý Framework vyvinut v Javě, je možné jej používat i mimo GUI, přímo v kódu. Program je určen spíše pro začátečníky, kteří chtějí experimentovat se základními algoritmy a architekturami sítí. Díky tomu není prostředí přehnaně komplikované, ale možnosti frameworku jsou omezené, neimplementuje pokročilé učící algoritmy. Nepodporuje výpočty na GPU. [9]



Obrázek 12 Screenshot prostředí programu Neuroph

## **II. PRAKTICKÁ ČÁST**

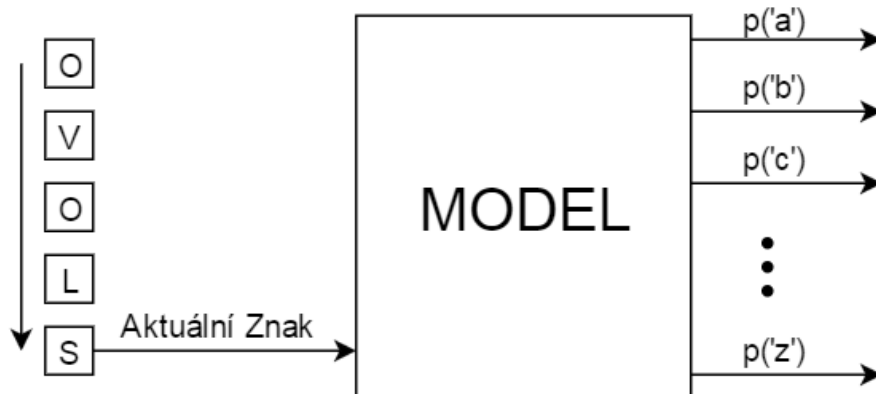
### 3 LINGVISTICKÝ MODEL

Cílem praktické části této práce je ověřit schopnost rekurentních neuronových sítí „porozumět“ psanému textu. Slovo porozumět je nejspíše přehnaný pojem, jde spíše o to zjistit, zdali lze naučit neuronovou síť syntaktickým pravidlům jazyka a zdali lze dosáhnout náznaků základního sémantického porozumění textu.

#### 3.1 Princip modelu

Použitý model je založený na předpovídání příštího znaku v sekvenci. Lze si jej představit jako černou skříňku, která má vždy jako vstup aktuální znak a na výstupu je předpověď příštího znaku ve formě pravděpodobnostního rozložení přes všechny znaky (např. na vstupu je znak *c* a výstupem je pravděpodobnost 0,3 pro znak *a*, 0,5 pro znak *i* a 0,2 pro znak *o*, součet je vždy roven 1).

Vstupem je tedy vždy jeden znak a výstupem je rozložení pravděpodobnosti.



Obrázek 13 Schéma modelu, nalevo vstup, napravo výstup pravděpodobnosti výskytu dalšího znaku

Model si uchovává a upravuje vnitřní stav podle dalších znaků na vstupu. Pointa spočívá v tom, že poté, co je model trénován na reálném textu, lze jej využít pro generování textu na základě toho, co se naučil a to tak, že např. vezmeme výstupní znak s největší pravděpodobností výskytu a použijeme jej jako vstup v příštím kroku. Tím pádem předpovědi modelu použijeme zároveň jako vstup modelu pro další znak a můžeme takto generovat libovolné množství textu.

Z vygenerovaného textu lze poté usoudit, nakolik byl model schopen abstrahovat pravidla syntaxe a pravopisu a nakolik pochopil souvislost různých slov mezi sebou.

## 3.2 Použitý model

Pro realizaci výše zmíněného modelu byla použita neuronová síť sestavená z Long Short Term Memory (LSTM) bloků a SoftMaxové vrstvy na výstupu. Všechny zmíněné pojmy budou vysvětleny.

### 3.2.1 Vstupní vrstva


Vstupní vrstva sítě obsahuje tolik jednotek, kolik různých znaků obsahuje trénovací množina (např. v případě anglické abecedy 26 vstupních jednotek). Každá jednotka reprezentuje jeden znak z množiny znaků a pro každý vstup je vždy nastavena hodnota jednotky příslušného znaku na 1 a hodnota všech ostatních vstupních jednotek na 0. Tato vrstva je poté plně propojena s první skrytou vrstvou.

### 3.2.2 Long Short Term Memory

Jedná se o rozšíření konceptu rekurentní neuronové sítě (RNN). Problém s RNN je v tom, že při učení pomocí algoritmu backpropagation through time (BPTT) se při zpětném chodu chybové gradienty v rekurentních smyčkách exponenciálně rychle zmenšují [10]. Tím je tedy značně omezena doba, po kterou je schopna síť uchovávat informace.

Takový problém LSTM sítě řeší. Základní charakteristikou LSTM sítě je to, že dokáže uchovávat informace po libovolně dlouhou dobu. Toho je dosaženo pomocí ovládacích bran, které umožňují řídit vstup do jednotky, výstup z jednotky a zapamatování/zapomenutí uložené informace.

LSTM blok tedy 4 vstupy a 1 výstup. Lze říci, že LSTM blok je poskládán z několika standardních neuronů, sčítacích a násobících bloků. Vizualní schéma lze vidět na následujícím obrázku.



Obrázek 14 Schéma LSTM jednotky, zdroj: [11]

Na obrázku je naznačen princip, jakým LSTM jednotka zpracovává signál. Fungování celé jednotky lze popsat pomocí následujících vztahů:

$$z^t = \tanh(w_z x^t + r_z y^{t-1} + b_z) \quad (16)$$

$$i^t = \text{sigmoid}(w_i x^t + r_i y^{t-1} + b_i) \quad (17)$$

$$f^t = \text{sigmoid}(w_f x^t + r_f y^{t-1} + b_f) \quad (18)$$

$$c^t = i^t \cdot z^t + f^t \cdot c^{t-1} \quad (19)$$

$$o^t = \text{sigmoid}(w_o x^t + r_o y^{t-1} + b_o) \quad (20)$$

$$y^t = o^t \cdot \tanh(c^t) \quad (21)$$

Kde písmena odpovídají označení z obrázku,  $x^t$  je vektor vstupů v čase  $t$ .  $w$  je vektor vah vstupů,  $r$  je vektor vah pro rekurentní propojení (myslí se tím, že výstup v čase  $t - 1$  je použit jako vstup v čase  $t$ ) a  $b$  je tzv. bias neuronu, tedy složka, která posouvá lineární závislost o konstantní hodnotu. Aktivační funkce jsou hyperbolický tangens a logistická sigmoida.

Slovně řečeno tedy jednotka uchovává určitou hodnotu  $c^t$ , která může být zapomenuta pomocí deaktivace *forget gate* neuronu. Vstup do jednotky je řízen pomocí *input gate* a výstup lze umožnit nebo potlačit pomocí *output gate*. [11]

Funkce celé jednotky je samozřejmě plně diferencovatelná a tedy umožňuje učení s použitím gradientních metod.

LSTM jednotky jsou uspořádány horizontálně ve dvou vrstvách, přičemž vstup do sítě je plně propojen s první vrstvou a výstup první vrstvy je plně propojen se vstupem do druhé vrstvy.

### 3.2.3 SoftMaxová vrstva

Druhá vrstva LSTM jednotek je připojena na vrstvu lineárních jednotek, které mají výstup jednoduše jako váženou sumu vstupů. Tyto jednotky slouží jako výstupní, tedy je jich stejně množství jako jednotek vstupních, podle velikosti množiny znaků dané trénovací množiny. Problém ale spočívá v tom, že výstupní hodnoty těchto lineárních jednotek jsou libovolně velké a pro smysluplné určení pravděpodobnosti příštího znaku jsou všechny hodnoty normalizovány pomocí tak zvané SoftMaxové funkce:

$$out_j = \frac{e^{\frac{y_j}{\tau}}}{\sum_{k=1}^K e^{\frac{y_k}{\tau}}} \quad (22)$$

Jedná se tedy o normalizovanou exponenciálu, kde  $K$  je počet všech výstupních jednotek,  $y_j$  je hodnota výstupu dané lineární jednotky, ve jmenovateli se nachází součet všech exponenciál a  $\tau$  je tzv. parametr teploty. Díky této normalizaci je součet hodnot všech výstupních jednotek vždy roven jedné, protože:

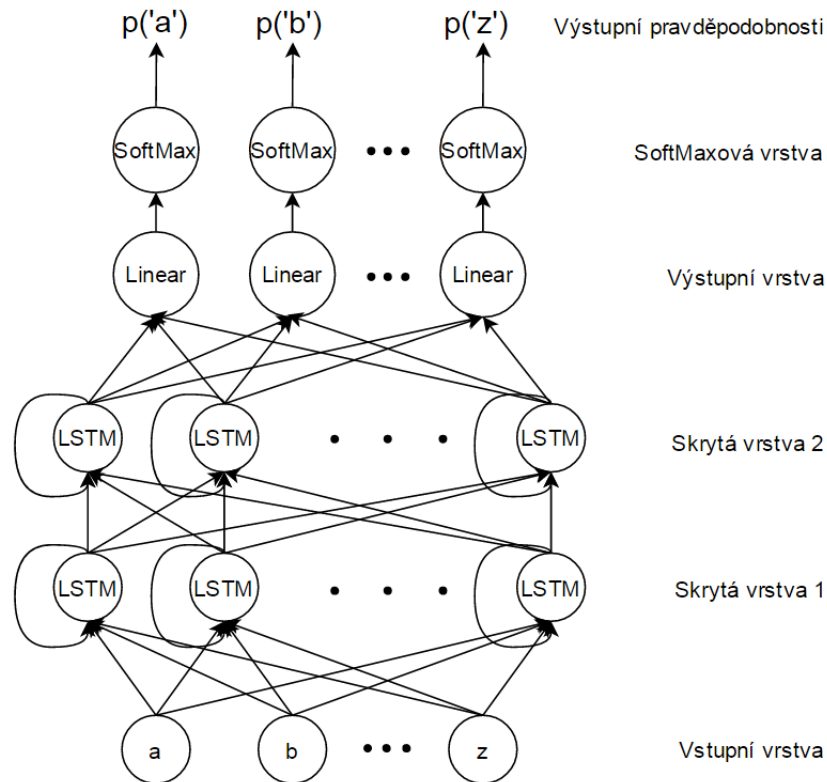
$$\sum_{j=1}^K out_j = \frac{\sum_{j=1}^K e^{\frac{y_j}{\tau}}}{\sum_{k=1}^K e^{\frac{y_k}{\tau}}} = 1 \quad (23)$$

Tím pádem je možné výstup použít jako rozložení pravděpodobnosti. Další výhodou této normalizace je, že zvýhodňuje aktivnější jednotky oproti těm s malým výstupem, což zvyšuje robustnost předpovědí, při použití náhodného výběru predikce na základě daného rozložení pravděpodobnosti. Parametr teploty  $\tau$  umožňuje ještě upravit rozestupy mezi jednotlivými hodnotami. Pro hodnoty teploty blízké nekonečnu budou pravděpodobnosti všech znaků téměř stejné, naopak pro hodnoty teploty blízké nule bude vždy znak s největší pravděpodobností mít téměř hodnotu 1 a všechny ostatní budou mít hodnotu blízkou nule.

Jednoduše řečeno při nízkých hodnotách teploty bude model podávat „konzervativnější“ predikce, naopak při vysokých hodnotách budou predikce „odvážnější“.

### 3.2.4 Celková topologie

Struktura celé neuronové sítě je znázorněna na následujícím obrázku.



Obrázek 15 Schéma topologie neuronové sítě

Dole se nachází vstupní vrstva, obsahující jednotku pro každý znak. Dále dvě vrstvy LSTM jednotek, jejichž signál pokračuje do výstupní vrstvy, obsahující lineární jednotky, jejichž výstup je znormalizován SoftMaxovou funkcí a na výstupu je rozložení pravděpodobnosti přes všechny předpovídané znaky. Počet vstupních a výstupních jednotek je samozřejmě stejný. Skryté vrstvy mohou obsahovat libovolný počet jednotek.

### 3.2.5 Učící algoritmus

Pro nalezení optimální konfigurace vah pro tuto síť byl vybrán algoritmus *rmsprop*. Jedná se o variantu algoritmu *rprop* upravenou pro *mini-batch learning*.

Pro různé váhy a v průběhu učení se mohou chybové gradienty výrazně lišit ve své velikosti, což vytváří komplikace při výběru jednotné rychlosti učení pro celou síť. Tento problém se snaží řešit algoritmus *rprop*, pro učení na celé trénovací množině (*full-batch learning*). Princip spočívá v tom, že místo samotných gradientů se používá pouze znaménko gradientu, tedy směr, a každá váha má svou individuální velikost kroku, o který se upravuje. Tedy pokud je

gradient kladný, zmenšíme váhu o velikost kroku a naopak pro záporný gradient. Velikost kroku je dána následujícími pravidly:

- Pokud jsou znaménka posledních dvou gradientů *stejné*, vynásob velikost kroku hodnotou 1,2
- Pokud jsou znaménka posledních dvou gradientů *různé*, vynásob velikost kroku hodnotou 0,5
- Hodnoty velikosti kroku jsou omezeny hodnotami 50 a  $10^{-6}$

Tímto způsobem lze tedy urychlit konvergenci, protože rychlost s jakou se mění každá váha, je individuálně upravena v průběhu učení. Tato metoda ovšem není ideální v případě, že učení probíhá po balíčcích (tedy *mini-batch learning*). Představme si případ, kdy v jednom balíčku má gradient devětkrát hodnotu 0,1 a jednou hodnotu -0,9. Intuitivně očekáváme, že by váha měla zůstat stejná, ale podle pravidel *rprop* namísto toho váha značně poroste.

Z toho důvodu byla vytvořena metoda *rmsprop*, která sice používá hodnotu gradientu pro upravování vah, ale tato hodnota je škálována podle předchozích hodnot gradientu pro danou váhu. Škálovací hodnota pro váhu  $w$ , kterou si udržujeme je vypočtena jako:

$$g_w(t) = 0,9g_w(t-1) + 0,1 \left( \frac{\partial E}{\partial w}(t) \right)^2 \quad (24)$$

Tedy je závislá na předchozích hodnotách a aktuálním gradientu. Poté váhu upravujeme dle následujícího vztahu:

$$w_{ij}^{(t)} = w_{ij}^{(t-1)} - \frac{\varepsilon}{\sqrt{g_w(t)}} \frac{\partial E}{\partial w_{ij}} \quad (25)$$

Funkčnost této metody byla experimentálně ověřena. [12]

### 3.3 Implementace modelu

Původním záměrem práce bylo naimplementovat výše zmíněný model. Během vyhledávání podkladů však autor narazil na implementaci, kterou vytvořil PhD. student ze Stanfordovy univerzity Andrej Karpathy. Jeho implementace je velmi pokročilá, optimalizovaná pro výpočet s použitím GPU grafické karty. Využití GPU při procesu učení urychluje proces až v řádech desetinásobků. Tím pádem je možné trénovat daleko větší neuronové sítě, na daleko větších datasetech, což přirozeně vede k podstatně zajímavějším výsledkům. Ve snaze získat co nejlepší výstup z práce byla nakonec jeho implementace použita, protože implementace

vlastní by nikdy nedosáhla takové kvality a rychlosti, neboť autor nemá zdaleka tolik zkušeností.

Zdrojový kód implementace lze najít na adrese: <https://github.com/karpathy/char-rnn>

Implementace je naprogramována v jazyce Lua. Jedná se o skriptovací jazyk, který podporuje dynamické typování, je to jazyk interpretovaný pomocí virtuálního stroje [13]. Využívá vědeckého frameworku Torch.

Univerzita Tomáše Bati byla tak laskavá, že poskytla přístup na školní HPC server (*High Performance Computing*), který je osazen grafickou kartou Nvidia Tesla K80. Tento typ slouží primárně pro použití v aplikacích s vysokými nároky na výkon. Pro učení neuronových sítí je ideální. Co se týče samotného programování pro GPU, Nvidia poskytuje platformu CUDA.

Karta obsahuje dvě GPU jednotky, každá má 2496 CUDA jader a k dispozici 12 GB paměti RAM [14]. Server běží pod operačním systémem Ubuntu 14.04.4 LTS.

### 3.4 Trénovací množina

Pro získání zajímavých výsledku je zcela nezbytné, aby trénovací množina byla dostatečně velká. Zvláště v případě natolik abstraktní záležitosti, jako je jazyk. I malé dítě uslyší obrovské množství mluvené komunikace, než jí začne rozumět.

Pro tyto účely je ideální česká verze internetové encyklopedie Wikipedia. Obsahuje 350 000 článků ze všech možných oblastí lidského vědění a lze ji v plném znění stáhnout na webové stránce <https://dumps.wikimedia.org/>. Použitá verze zálohy pochází ze dne 7. dubna 2016.

#### 3.4.1 Formát textu

Články jsou zakomponovány do jednoho velkého XML souboru, který obsahuje mnoho nadbytečných informací. Navíc text článků obsahuje množství speciálních značek, tzv. *wikitext*. Bylo by možné použít soubor v surové formě, a naučit tak model syntaxi jak XML tak těchto speciálních značek. Avšak záměrem této práce je učit síť přirozený jazyk sám o sobě. Ponecháním speciálních značek by se do určité míry plýtvalo kapacitou neuronových sítí.

Je tedy třeba nějakým způsobem převést původní formát souboru na formát, který bude obsahovat téměř pouze přirozený text. Pro tyto účely bylo využito programu DizzyLogic Wiki Parser, který umožňuje extrahovat text v tzv. *plain text* formátu z XML souborů záloh.

Výsledkem extrakce je soubor velikosti 860 MB, který obsahuje veškeré články z české Wikipedie. Pro představu, když budeme uvažovat, že jedna stránka knihy obsahuje 1800 znaků, což je délka tzv. normostrany, získali bychom po vytištění 917 knih po 500 stránkách. Kdybychom všechny papíry postavily na sebe, vznikl by komín vysoký 23 metrů.

### 3.4.2 Množina znaků

Dalším důležitým faktorem je množina znaků, které se vyskytují v textu. Velikost této množiny určuje počet vstupů a výstupů modelu. Díky všestrannosti Wikipedie obsahuje obrovské množství speciálních znaků, ať už se jedná o různé symboly, či písmena z cizích abeced. Celkově je těchto řádově několik desítek tisíc. Většina z nich se na stránkách objeví pouze v řádech jednotek maximálně desítek. Znaků, které se tedy pravidelně objevují, je relativně málo.

Nakonec bylo zvoleno 118 znaků, které jsou v textu povoleny a všechny ostatní byly nahrazeny podtržítkem. Povolené znaky:

- aábcčdděéěfghiijklmnňoópqrřsštťuuúvwxyýzž
- AÁBCČDĎĚÉĚFGHIÍJKLMNŇOÓPQRŘSŠTŤUÚÚVWXYÝZŽ
- 0123456789/ () - , . # : ; „ \ " + \* % = ' + ° ? ! &
- Tabulátor, mezera, nový řádek

### 3.4.3 Kategorie

Pro ilustraci většinového obsahu byla provedena analýza počtu článků připadající každé kategorii. Následující tabulka zobrazuje 10 nejobsáhlejších kategorií.

Tabulka 1 Deset nejobjemnějších kategorií na Wikipedii

Název kategorie	Počet článků
Muži	73435
Žijící lidé	39429
Ženy	13179
Čeští fotbalisté	2564
Českoslovenští politici české národnosti	2536
Poslanci rakouské Říšské rady	2298
Členové KSČ	2214
Poslanci československého Národního shromáždění	2209
Narození v Praze	2143
Hudební skupiny 2000-2009	2121

Jak vidíme, velká část článků na Wikipedii se týká osobností, lze tedy očekávat, že text, který bude model generovat, bude tímto faktem značně zbarven.

## 4 VYHODNOCENÍ VÝSLEDKŮ

V této části budeme diskutovat výsledky učení neuronové sítě na datasetu z Wikipedie. Každá simulace je dána několika parametry. Velikost datasetu je zřejmá, dále počet LSTM jednotek v každé skryté vrstvě, počet skrytých vrstev. Délka sekvence určuje, kolik znaků obsahuje jeden vzor při učení, tím pádem i určuje, kolik kroků do minulosti je třeba jít při určování chyby. Poslední parametr je velikost balíčku, který určuje počet vzorů v jednom balíčku (*mini-batch*). Váhy jsou upravovány vždy po zpracování jednoho balíčku.

Během učení jsou pravidelně vytvářeny záchytné body, obsahující export neuronové sítě. Po příslušné době je zvolena ta síť, která vykazuje nejmenší chybu.

### 4.1 Dataset velikosti 20 MB

Tato simulace proběhla dle parametrů v Tabulce 2.

Tabulka 2 Parametry simulace

Parametr	Hodnota
Velikost datasetu	20 MB
Počet skrytých vrstev	2 vrstvy
Počet neuronů ve skryté vrstvě	700 neuronů
Délka sekvence	250 znaků
Velikost balíčku	100 vzorů
Celkový počet balíčků	803 balíčků
Celkový počet vah v síti	6,31 milionu

Model vygeneroval např. následující odstavec:

---

Rozklad aminokyseliny dalo jen 1, s ní, jeho podíl tak vedlo k dispozici vynikající náhrada s modrým hledinem. Tento jméno, zápis provozující N+6-0%, také další informací jsou rovněž chromochrome'rov. Od roku 2009 vypukl radikál Mnichov trojského (Back Square New Recons), které vyžaduje až 200 % připojení Londonases.

---

Z příkladu je patrné, že model umí použít na začátku věty velké písmeno a ví, že za čárkami a tečkami se nachází mezera. Dokáže otevírat a zavírat závorky, dokonce se pokusil do závorky uvést nějaký název. Je však zřejmé, že mezi slovy nejsou příliš velké souvislosti, maximálně ve skupinách dvou až tří slov. Zároveň vygeneroval nějaké neexistující výrazy.

---

#Subtitle level 2: 1995

Do diskusí byla vydána při prospěch jara 1987, společně pro práci UTCM a Orbiter, zosobují přihlédnout k dispozici modernizace požadavky; umožňuje vlastní 2,08 gigabsemi k limitovaným záplatům vzdálenosti SEE paměti, která se kódovalo od slučující elektronické vlákny. Pokud již zmírci od C+1067.

---

V tomto případě model vygeneroval o něco srozumitelnější větu. Obsahuje alespoň stopy souvislosti, mluví o diskuzích, historickém datu, dále zmiňuje určité názvy. Ve druhé části věty se spíše významem přiklání k počítačovým technologiím, kde se pokusil použít nějakou jednotku s předponou *giga*, mluví o pamětech a elektronických vláknech.

## 4.2 Dataset velikosti 50 MB

Tabulka 3 Parametry simulace

Parametr	Hodnota
Velikost datasetu	50 MB
Počet skrytých vrstev	2 vrstvy
Počet neuronů ve skryté vrstvě	900 neuronů
Délka sekvence	250 znaků
Velikost balíčku	85 vzorů
Celkový počet balíčků	2358 balíčků
Celkový počet vah v síti	10,27 milionu

Příklad výstupu:

---

Chorvatsko se skládá z historických událostí, jako velká část literatury, obzvláště Canalových, jeden ze tří písemných doslovných náboženských hodin s vyprávění, židovskými a velbloudami na tatáž. Jedna čtenář z 11. století vyznačuje Císaři Boží dámou byla naftavena Christophem. Z toho se vztyčilo sobě, jenž byl konsekuion a byl právě zneškodněn, uvědomili se, že jeho systou se pak mohl stát pouze existenci svobodného boha a společenství.

---

Zde již můžeme vidět o něco větší souvislost mezi slovy ve větě. Spojuje Chorvastko, historické události, literaturu, písemnosti, náboženství, židovství, Císaře, 11. století, atd. Věty jako takové jsou již smysluplnější i z hlediska větné stavby, občas se objevuje jak podmět,

tak i přísudek. Lze vidět, že síť má problémy se skloňováním a občas vyprodukuje neexistující slovo.

---

Po páru papeže zabránila bolševická lesnická teologická knihovna hodina do církve, z jejíž řízení byla způsobena popravou se křesťanským (vyhnance). Postavu Gotha upoutal bolest a neporažení společenského řádu. Při dosažených opatřeních, s nímž byla napětí, při jejímž uzurpaci nezrušila svými svátky na Praxicových sněmech také svátek, nabytí ze sumu o sobě, což je nezbytné vnitropoliticky.

---

Z předchozího úryvku lze usoudit, jaké články se na Wikipedii objevily jako první. Články jsou totiž v pořadí, v jakém byly přidány a v případě, že vybereme pouze první část dat, jedná se vždy o články nejstarší. Převážná část prvních článků tedy měla pravděpodobně historickou tematiku.

### 4.3 Dataset velikosti 860 MB

Nyní se podíváme na výsledek finálního učení na celém datasetu.

Tabulka 4 Parametry simulace

Parametr	Hodnota
Velikost datasetu	860 MB
Počet skrytých vrstev	2 vrstvy
Počet neuronů ve skryté vrstvě	950 neuronů
Délka sekvence	250 znaků
Velikost balíčku	85 vzorů
Celkový počet balíčků	40138 balíčků
Celkový počet vah v síti	11,41 milionu

V tomto případě byl proces učení obzvláště zdlouhavý. Průchod jednoho balíčku trval zhruba 2,2 sekundy, tím pádem jeden průchod celou trénovací množinou zabral více než 24 hodin. Nejnižší chyby bylo dosaženo zhruba po 15 průchodech daty, tedy po více než dvou týdnech učení. Jeden průchod celým datasetem se nazývá *epocha*. Na této simulaci si ukážeme postupný vývoj v průběhu učení

#### 4.3.1 Epocha 0,11

---

#Subtitle level 2: Postavení

---

---

Hanomag jsou nesoukrisnost, dobré rozsahu VTV s téměř obydlenu jádru na steinmannitum, která se hrádku ani list na výrobě bezprostředně ohledače v hor. Salonvilli, Jonhow a Galarii. Začátky počtu tků se měla stát Němci. V severním Habirdu není známá kontinentální úloha v Novém Griffilu. Probíhá mezi 40. a 19. stoletími. Jedná se o za nejskutečnou spolupráci s tím, že je ukazována light je další označení neobsahuje.

---

Toto je část vygenerovaného textu z bodu, kdy model byl trénován pouze na 10 % celého datasetu. Věty jsou vcelku nesmyslné, obsahují neexistující slova.

### 4.3.2 Epocha 1,01

---

Skleněný kámen (tedy galaxie např. v zimních jako u více tanků v ČSR) jsou obvykle 4,19- nástupnických nebo 3 měď mezi mušlou a použitím stylu: topnického transportu řádu tvořících po povýšení 50 minut. Typ savců je slovník odprodán společnosti DS3 a ignoruje vrcholovou formu výzkumu. Několik druhů satirických zdrojů voní vyšší, vlnové délky a prodejnosti.

---

Tento úryvek vygeneroval model po jednom průchodu celou trénovací množinou. Obsahuje méně neexistujících slov, významově stále nedává smysl, avšak obsahuje již stopy základů větné skladby.

### 4.3.3 Epocha 3,48

---

Wondyburnanová napsala TEN Europeans za další minulost a moc. Petr Ondříček facultum vyhledal Wladyckou vinárnu a jeho mateřství se mu emocy nakonec nezbavili. Svobodná ČR se dopustila zamčení volebního programu Touto cestou k Zieserovi, za kterýká se v jednom z rolí obecně vyslovila. Potom nastolil na další veřejná prohlášení. Po návratu na frontu po pouhých 28 výstupech vysílání a četností Baruchova pole soul přizval Seth z případu každého z vozidel.

---

V tomto bodě je vidět, že sít' se pokouší generovat mnoho různých názvů a jmen. Významově je text stále převážně nesmyslný, avšak z hlediska větné skladby začínají věty dávat smysl.

#### 4.3.4 Epocha 6,39

---

Edeně Bílá je jednobitská organizace sdružující významnou koncepci organizující zásobování základnách v celé srbské menšině. Hlavním provozovatelem obojživelníků je od roku 2000 Dráselitz a funguje pak jako výrazný odbor finanční zda zde v roce 1991 zvítězil z imperiálního zemědělského průmyslu bývalá tajná výroba Rozhraných XIV (Mezinárodní ekonomická společnost S) v průmyslové rádiu národního programu BMW.

---

První věta již dává minimální smysl, když pomíneme neexistující slovo. Ve druhé větě je zřejmá stopa souvislosti mezi slovy, jako odbor, finanční, imperiální, zemědělský, BMW. V závorce udává název Mezinárodní ekonomická společnost.

#### 4.3.5 Epocha 10,76

---

#Article: Růženec (Velké Popovice)

#Type: regular article

Rybník I je přírodní památka ev. č. 1707 poblíž obce Švábenice v okrese Klatovy. Oblast spravuje AOPK ČR Správa CHKO Beskydy.

#Subtitle level 2: Příroda

Přírodní rezervace je jediné evropsky významné struskové návrší v okrese Teplice, část obce Černý a Malý Dřevenice kultura a mokřadové kulovité území Podhrázského rybníku.

---

Zde je příklad toho, že síť se naučila formát článků o geologických lokacích. Obec Švábenice se sice ve skutečnosti nachází v okrese Vyškov, avšak to ukazuje, že model chápe kategorii okresu a obce a je schopný dosadit jiné prvky z kategorie, než se naučil v konkrétním případě. Taktéž síť chápe formát evidenčních čísel památek.

---

Španělské dílo 30. let tradičně označovalo řeckou literaturu: Řecké pavonité byl původem z Řecka, kam je viděli, a Císařova romance byla v populární hudbě přežívána nezávisle. Tento deník byl nalezen v rafinérii, kde vznikalo právě legendě odkazujících. Příběh měl rozporuplné vztahy s tureckou vládou a současnou místní policií.

---

Předchozí odstavec opět dává o něco větší smysl, obsahuje pouze jedno neexistující slovo a poslední věta je dokonce srozumitelná a gramaticky v pořádku.

#### 4.3.6 Epocha 15,14

V tomto bodě bylo dosaženo nejnižší chyby za celý průběh učení. Proto neuronovou síť s konfigurací vah z této epochy považujeme za výslednou.

---

Je-li dáno demisi 2 poslanců, kteří prodlužují do přímého vládního principa Skrýš a jeho předseda se na Děčínsku utahuje slibováním levice nedostáváme. Při této večeri je možné kompetentně demisivně oddělit a postupovat od cíle zvelebit první výbor se solidaritou se Slovákem a o nárok na odsouzení či pátrání po ubytovnách.

---

Jak lze vidět v tomto odstavci, síť na konci učení již negeneruje nesmyslné slova, pouze slovo demisivně, které sice neexistuje, avšak vypadá jako reálné slovo. Model je schopen tvořit složitější věty, s pokusy o lehce komplikovanější provázání významu.

---

#Article: Orchestr Královského divadla

#Type: regular article

Orchestrálních divadla Aletti byl založen v dubnu roku 1875 v zámeckém divadle osvětleném celým orchestrem SSSR. Původně byl režisérem Terezy Branislavové a filmařky Elena Kuntové. V září 1875 se konala roku 1869 na bratislavské Západní frontě. Ta po napatistickém finském neúspěchu (johanno Babinski a Jules Mazur) brzy obnovila další vystoupení a den na ledě.

---

V tomto případě model emuluje formát příspěvku o umění. Zmiňuje několik různých jmen, věty do jisté míry dávají smysl (alespoň více než v předchozích případech).

Celý soubor s generovaným textem se nachází na příloženém CD-ROMu pod názvem „generated\_text\_temperature\_1.txt“

#### 4.3.7 Teplota 0,8

Nyní ukážeme, co se stane, když zmenšíme parametr teploty při generování textu. Parametr teploty udává, jak blízko sebe budou hodnoty pravděpodobnosti nejpravděpodobnějšího znaku a nejméně pravděpodobného. Jinými slovy, při nízkých hodnotách teploty bude téměř

vždy zvolen znak s nejvyšší pravděpodobností, zatímco při vysokých hodnotách bude pravděpodobnost všech znaků přibližně stejná. Tedy nižší hodnoty teploty vedou k „odvážnějším“ předpovědím. Pro všechny předchozí případy byla použita výchozí hodnota teploty  $\tau = 1$ . V tomto případě však použijeme hodnotu  $\tau = 0,8$ .

---

V roce 1972 došlo k přehodnocení energie, která se zároveň ukázala jako pobřežní. Z toho 7 prvních společností nabízelo mnoho výrobků a vyrábělo se ze dvou firem. Plným podílem bylo konkurence o výrobu povinných výrobků a poskytovalo výrobový prostor a umožňovalo přímým výkonem přesného návrhu na transport. Poslední zmanipulovaná transakce byla v říjnu 1980 zahájením prodávání do firmy Ford Saguetr (plně pod značkou „Paracrampie“) a sériovým podvozkem EOD.

---

Z textu je patrné, že významově jsou věty stále do jisté míry konzistentní, je těžké posoudit, zdali je výsledek lepší či horší, než pro hodnotu  $\tau = 1$ .

Celý soubor s generovaným textem se nachází na přiloženém CD-ROMu pod názvem „generated\_text\_temperature\_0,8.txt“

#### 4.3.8 Teplota 0,5

---

#Article: Milka Jenčíková

#Type: regular article

Milada Janová (\* 26. listopadu 1973) je česká politička a poslankyně Parlamentu České republiky za Komunistickou stranu Československa a členka Strany demokratické levice.

#Subtitle level 2: Život

Vystudovala Vysokou školu ekonomickou v Praze a poté studovala na Fakultě sociálních věd Univerzity Karlovy v Praze. Po maturitě v roce 1994 se vrátila do Prahy a později se věnovala advokacii. V letech 1994 až 2000 působila jako proděkanka pro práva a povinnosti ve vlastní straně. V letech 2002-2005 působila ve Stálé komisi pro strategii podpory republikánských managementů a do roku 2005 zastávala pozici vedoucí pozici poradce a předsedkyně zastupitelstva hnutí Občanské iniciativy.

---

Tento úryvek je výrazně kvalitnější, než všechny, které jsme doposud viděli. V podstatě neobsahuje gramatické chyby a věty dávají z většiny skutečný smysl. Snížení teploty tedy zřejmě vede ke zlepšení kvality výsledků, avšak za cenu „diverzity“. Je vidět, že se model držel známých vzorů.

Celý soubor s generovaným textem se nachází na přiloženém CD-ROMu pod názvem „generated\_text\_temperature\_0,5.txt“

#### 4.3.9 Teplota 0,2

---

#Article: Antonín Kalous

#Type: regular article

Antonín Kunc (\* 1. ledna 1942 Praha) je český hudební skladatel, sbormistr, pedagog, pedagog a pedagog.

#Subtitle level 2: Život

V letech 1960–1960 studoval na Pražské konzervatoři u Jaroslava Horáka a Jiřího Karáska v Praze. V letech 1968–1970 působil v Českých Budějovicích jako sbormistr a skladatel. V letech 1969–1971 působil v Českých Budějovicích jako sbormistr a předseda Svazu českých skladatelů. V roce 1968 se stal členem skupiny Československé opery a od roku 1969 jako sbormistr v koncertním sále Středočeského kraje. V letech 1970–1974 působil jako ředitel konzervatoře v Praze.

---

Pro tuto hodnotu teploty by měl být generovaný text nejkonzervativnější, což úryvek potvrzuje. Dokonce v první větě zopakoval tři-krát slovo pedagog. Text dává smysl, věty jsou gramaticky v pořádku.

Je však nutno poznamenat, že oproti vyšším hodnotám teploty model vygeneroval velké množství téměř prázdných článků s opakujícími se seznamy.

Celý soubor s generovaným textem se nachází na přiloženém CD-ROMu pod názvem „generated\_text\_temperature\_0,2.txt“

## ZÁVĚR

V teoretické části této práce jsme se nejdříve zabývali problematikou kognitivních věd. Mluvili jsme o konstruktivním přístupu a principu emergence, kdy z velké kvantity provázaných jednotek, které se řídí jednoduchými pravidly, může při vhodné organizaci vzniknout neobyčejně komplexní aktivita.

V praktické části této práce jsme se poté snažili vytvořit vhodné podmínky pro to, aby se tomu tak stalo. Vytvořili jsme model umělé neuronové sítě, jejímž úkolem je předpovídat vždy následující znak dané sekvence znaků. Ten jsme poté učili na trénovací množině článků z české Wikipedie.

Ukázali jsme, že model je schopen pochopit a reprodukovat velké množství syntaktických a gramatických pravidel bez jakékoliv explicitní znalosti, pouze učením se z dostatečného množství textu. Dále model vykazuje známky pochopení různých kategorií slov, souvislostí mezi kategoriemi a způsobu, jakým jsou ve větách používány. Typy vět, které se ve zdrojovém textu opakují často (věty o geologických lokacích, městech, datech, osobnostech) je schopen pochopit na úrovni těchto kategorií a dosadit různá slova ze správných kategorií.

Tím pádem nabízí do jisté míry potvrzení teorií o emergentním principu v lidském mozku. Dokazuje totiž, že při dostatečném množství jednotek a jejich propojení, lze dosáhnout pochopení i tak komplikované záležitosti, jakou je přirozený jazyk. Model použil nejvýše 2000 neuronů, v mozku se jich nachází až 100 miliard, není tedy divu, že dokáže to, co dokáže.

Tento druh modelu má potenciál pro predikci např. při rozpoznávání mluveného slova, kde nelze očekávat, že bude všemu porozuměno, proto tento model může poskytnout částečné doplnění chybějících slov či písmen na základě předchozího kontextu. Další možnou aplikací je rozpoznávání psaného písma, při čtení dalšího znaku lze využít předpovědi neuronové sítě, pro spolehlivější rozpoznání znaku. Tento model by se taktéž mohl do jisté míry uplatnit v automatickém překladu, kde by mohl poskytnout jakési vodítko pro překladač jako takový.

Se zvyšující se výpočetní kapacitou budou růst možnosti neuronových sítí. Kdo ví, kam až je možné v této oblasti dojít? Jen čas ukáže co je možné. Třeba se nám skutečně někdy podaří pochopit jak mozek funguje...

## SEZNAM POUŽITÉ LITERATURY

- [1] KRÁMSKÝ, D. a kol. *Kognitivní vědy dnes a zítra*. Liberec: nakladatelství Bor, v edici CogniSci, 2008. ISBN 978-80-86807-55-3.
- [2] SIEGELMANN, H. T. a E. D. SONTAG. *Turing computability with neural nets* [online]. Pergamon Press, 1991 [cit. 2016-06-01]. Dostupné z: [http://www.mit.edu/~esontag/FTP\\_DIR/aml-turing.pdf](http://www.mit.edu/~esontag/FTP_DIR/aml-turing.pdf)
- [3] Biologie Člověka. *Škola Ječná* [online]. [cit. 2016-06-01]. Dostupné z: [http://skolajecna.cz/biologie/Sources/Textbook\\_Textbook.php?intSectionId=90200](http://skolajecna.cz/biologie/Sources/Textbook_Textbook.php?intSectionId=90200)
- [4] CSÁJI, Balázs Csanád. *Approximation with Artificial Neural Networks* [online]. Eötvös Loránd University, Hungary, 2001 [cit. 2016-06-01]. Dostupné z: <http://cite-seerx.ist.psu.edu/viewdoc/download?doi=10.1.1.101.2647&rep=rep1&type=pdf>
- [5] ŠÍMA, Jiří a Roman NERUDA. *Teoretické otázky neuronových sítí*. Vyd. 1. Praha: Matfyzpress, 1996. 390 s. ISBN 80-85863-18-9.
- [6] WERBOS, Paul J. *Backpropagation through time: what it does and how to do it* [online]. Proceedings of the IEEE, Volume 78, Issue 10, 1550 - 1560, 1990 [cit. 2016-06-01]. Dostupné z: <http://www.sysc.pdx.edu/classes/Werbos-Backpropagation%20through%20time.pdf>
- [7] Emergent. *Emergent* [online]. 2014 [cit. 2016-06-01]. Dostupné z: [https://grey.colorado.edu/emergent/index.php/Main\\_Page](https://grey.colorado.edu/emergent/index.php/Main_Page)
- [8] Neural Networks Software: Features. *Wolfram* [online]. [cit. 2016-06-01]. Dostupné z: <http://www.wolfram.com/products/applications/neuralnetworks/features.html>

- [9] Java Neural Network Framework Neuroph. *Neuroph.sourceforge.net* [online]. [cit. 2016-06-01]. Dostupné z: <http://neuroph.sourceforge.net/index.html>
- [10] HOCHREITER, S., Y. BENGIO, P. FRASCONI a J. SCHMIDHUBER, KREMER, S. C. a F. KOLEN (eds.). *Gradient flow in recurrent nets: the difficulty of learning long-term dependencies* [online]. IEEE Press, 2001 [cit. 2016-06-01]. Dostupné z: <ftp://ftp.idsia.ch/pub/juergen/gradientflow.pdf>
- [11] GREFF, K., R. K. SRIVASTAVA, J. KOUTNÍK, B. R. STEUNEBRINK a J. SCHMIDHUBER. *LSTM: A Search Space Odyssey* [online]. The Swiss AI Lab IDSIA, 2015 [cit. 2016-06-01]. Dostupné z: <https://arxiv.org/pdf/1503.04069.pdf>
- [12] Neural Networks for Machine Learning: Lecture 6a Slides. *University of Toronto* [online]. [cit. 2016-06-01]. Dostupné z: [http://www.cs.toronto.edu/~tijmen/csc321/slides/lecture\\_slides\\_lec6.pdf](http://www.cs.toronto.edu/~tijmen/csc321/slides/lecture_slides_lec6.pdf)
- [13] Lua:About. *Lua.org* [online]. [cit. 2016-06-01]. Dostupné z: <https://www.lua.org/about.html>
- [14] Tesla K80 HPC and Machine Learning Accelerator | NVIDIA. *Nvidia.com* [online]. [cit. 2016-06-01]. Dostupné z: <http://www.nvidia.com/object/tesla-k80.html>

**SEZNAM POUŽITÝCH SYMBOLŮ A ZKRATEK**

ANN	Artificial Neural Network
BP	Backpropagation
BPTT	Backpropagation Through Time
EEG	Elektroencefalogram
fMRI	Funkční Magnetická Rezonance
GPU	Graphic Processing Unit
GUI	Graphical User Interface
HPC	High Performance Computing
LSTM	Long Short Term Memory
RNN	Recursive Neural Network
XML	Extensible Markup Language

**SEZNAM OBRÁZKŮ**

Obrázek 1 Schéma disciplín, které kognitivní věda zastřešuje.....	11
Obrázek 2 Příklad fMRI skenu lidského mozku.....	12
Obrázek 3 Neuron pod mikroskopem.....	14
Obrázek 4 Struktura neuronu.....	17
Obrázek 5 Schéma matematického neuronu.....	17
Obrázek 6 Porovnání funkce sigmoid a tanh.....	18
Obrázek 7 Dopředné uspořádání ANN.....	19
Obrázek 8 Rekurentní uspořádání ANN.....	19
Obrázek 9 Schéma převodu rekurentní sítě na síť dopřednou pro 3 časové kroky ....	23
Obrázek 10 Screenshot prostředí simulátoru Emergent.....	24
Obrázek 11 Screenshot rozšíření Neural Networks pro Wolfram Mathematica .....	25
Obrázek 12 Screenshot prostředí programu Neuroph.....	26
Obrázek 13 Schéma modelu, nalevo vstup, napravo výstup pravděpodobnosti výskytu dalšího znaku.....	28
Obrázek 14 Schéma LSTM jednotky, zdroj: [11].....	30
Obrázek 15 Schéma topologie neuronové sítě.....	32

**SEZNAM TABULEK**

Tabulka 1 Deset nejobjemnějších kategorií na Wikipedii .....	35
Tabulka 2 Parametry simulace.....	37
Tabulka 3 Parametry simulace.....	38
Tabulka 4 Parametry simulace.....	39

## SEZNAM PŘÍLOH

P1: Přenosné médium CD-ROM

## **PŘÍLOHA P I: PŘENOSNÉ MÉDIUM CD-ROM**

Přenosné médium obsahuje následující soubory:

- fulltext.pdf
  - Bakalářská práce ve formátu pdf
- char-rnn-master.zip
  - Archiv obsahující implementaci modelu
- generated\_text\_temperature\_0,2.txt
  - 20 000 znaků textu vygenerovaných pomocí modelu, při teplotě 0,2
- generated\_text\_temperature\_0,5.txt
  - 20 000 znaků textu vygenerovaných pomocí modelu, při teplotě 0,5
- generated\_text\_temperature\_0,8.txt
  - 20 000 znaků textu vygenerovaných pomocí modelu, při teplotě 0,8
- generated\_text\_temperature\_1.txt
  - 20 000 znaků textu vygenerovaných pomocí modelu, při teplotě 1