

VYUŽITÍ IMUNITNÍCH SYSTÉMŮ V DATOVÉ ANALÝZE

Luděk Kopáček

Ústav systémového inženýrství a informatiky, FES, Univerzita Pardubice

Abstract

This paper presents basic principles of artificial immune systems as a novel approach to data clustering. Work is focused on artificial immune network - aiNet. Finally the comparison of artificial immune network and artificial neural network is presented.

Key words

Artificial Immune System, Artificial Neural Network, Resource Limited Artificial Immune Network, Artificial Immune Network.

1. Úvod

Umělé imunitní systémy (Artificial Immune System - AIS) reprezentují novou oblast výpočtové inteligence. Jsou inspirovány biologickými pochody, které zajišťují obranyschopnost živočichů proti virům a bakteriím. Původně byl imunitní systém modelován za účelem dokonalejšího pochopení skutečných pochodů v rámci imunitní odezvy. Později byl kladen více důraz na využití principů imunitního systému pro návrh nových přístupů v rámci výpočtové inteligence.

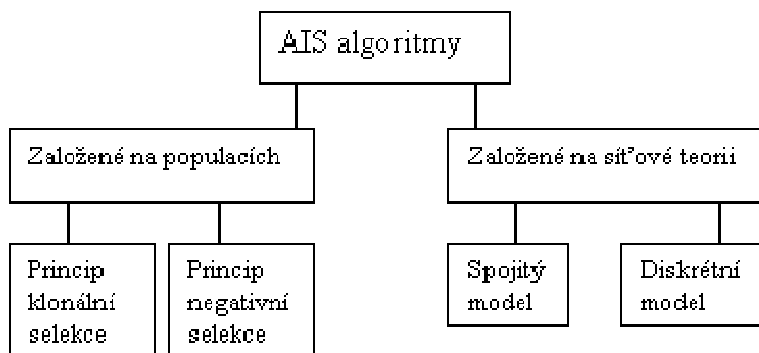
Stejně jako nervový systém člověka inspiroval k vývoji umělých neuronových sítí (Artificial Neural Network – ANN), inspiroval imunitní systém člověka návrh algoritmů založených na principech imunitního systému. Umělé imunitní systémy lze definovat jako algoritmy založené na ideách a teoriích získaných z imunitních systémů živočichů. Umělé imunitní systémy již našly své uplatnění v úlohách rozpoznávání vzorů, optimalizaci, datové analýze nebo detekci anomálií.

V tomto příspěvku je důraz kladen na algoritmy založené na síťové teorii imunitního systému, hlavně na algoritmus aiNet a jeho využití pro datovou analýzu. V závěru je uvedeno krátké srovnání popsání algoritmu s umělými neuronovými sítěmi.

2. Algoritmy založené na imunitních systémech

V posledních několika letech se v odborné literatuře prezentují a diskutují algoritmy založené na principech imunitního systému živého organismu [3, 4, 5, 6, 7, 8, 9, 10, 11, 12, 25]. Mezi první publikace zabývající se algoritmy inspirovanými imunitními systémy patří [17]. Teoretickou imunologii se zabývá [1, 15, 16, 20, 26, 27]. První publikací snažící se podat ucelený obraz algoritmů charakterizovaných imunitními systémy, včetně obecného rámce je [3]. Základní algoritmy lze rozdělit do několika skupin dle obr. 1.

Dle [3, 5, 6] je rozpoznávání v rámci umělých imunitních systémů prováděno v rámci stavového prostoru S , s multidimenzionálním metrickým prostorem, kde každá osa představuje jeden atribut charakteristický pro rozpoznávaný antigen. V rámci popisu jednotlivých algoritmů založených na imunitních systémech je předpokládán zobecněný popis v L -dimenzionálním prostoru S , kde každý bod $s \in S$ reprezentuje jednu molekulární konfiguraci (jeden typ specifity, kterou jsou schopny protilátky rozpoznat). Tvar protilátky i antigenu je v tomto stavovém prostoru dán L -dimenzionálním vektorem [5].



Obr. 1: Dělení AIS algoritmů podle jejich principu

2.1. Algoritmy založené na teorii imunitní sítě

Imunitní systém je dle [18, 19] složen ze sítě molekul a buněk schopných rozeznávat se navzájem. Navržená teorie předpokládá schopnost B-lymfocytů rozeznávat se navzájem. Některé teoretické práce z oblasti imunitních systémů [14, 24] se snažily vytvořit model imunitní sítě pro vysvětlení chování imunitního systému organismu. Navržené modely byly poté využity v oblasti výpočtové inteligence. Algoritmy výpočtové inteligence lze rozdělit do dvou hlavních skupin:

- Spojité modely imunitní sítě – jsou založeny na soustavě diferenciálních rovnic popisujících variace ve velikosti populace B-lymfocytů. Uplatnění našly v robotice, optimalizaci a řízení;
- Diskrétní modely imunitní sítě – nejsou založeny na diferenciálních rovnicích, ale na iteračních postupech, či diferenčních rovnicích. Uplatnění našly ve strojovém učení nebo datové analýze.

Imunitní systém spravuje síť B-lymfocytů, ve které jsou dvě buňky spojeny, pokud jejich vzájemná afinita překročí určitý práh [25]. Teorie imunitní sítě je založena na předpokladu, že receptory B-lymfocytů (protilátky) mají části nazývané idiotypy, které mohou být rozeznány jinými volnými protilátkami nebo receptory buněk.

2.1.1. Spojité umělé imunitní sítě

Spojité umělé imunitní sítě jsou založeny na diferenciálních rovnicích koncentrace lymfocytů. Byly formulovány za účelem snahy o matematický popis chování imunitního systému. Na jejich základě byly poté vytvořeny modely diskrétní, které se již využívají pro návrh algoritmů založených na teorii imunitní sítě.

V práci [18] je publikován první model imunitní sítě založený na popisu dynamiky skupiny identických lymfocytů diferenciálními rovnicemi. Identické lymfocyty v tomto případě představují buňky, které jsou nerozlišitelné na základě jejich receptorů (míře diferenciace). Jednotlivé skupiny jsou označovány jako typ i a c_i představuje koncentraci (počet) lymfocytů tohoto typu. Lymfocyty typu i interagují s lymfocyty typu j a naopak. Tato interakce může být posilující nebo potlačující. V [18] byl navržen vztah popisující vývoj skupiny lymfocytů jednoho typu:

$$\frac{dc_i}{dt} = c_i \sum_{j=1}^{N_1} f(E_j, K_j, t) - c_i \sum_{j=1}^{N_2} g(I_j, K_j, t) + k_1 - k_2 c_i \quad (1)$$

kde k_1 určuje míru vzniku (dozrávání) nových lymfocytů a k_2 určuje míru zániku lymfocytů. Funkce $f()$ a $g()$ určují šíření kladného nebo záporného signálu sítí. První suma je

přes všechny posilující (kladné) interakce generované idiotopy z množiny E_j a druhá suma je přes všechny potlačující interakce generované lymfocyty z množiny I_j . Pro tento model není nutný žádný externí signál reprezentovaný antigeny pro dosažení dynamického chování sítě.

V [13] je navržen model imunitní sítě založený na binárním kódování protilátek. Význam této práce spočívá v tom, že jako první spojila matematickou teoretickou imunologii s prvky výpočetní inteligence. Tento model nebere v úvahu rozdíly mezi B-lymfocyty (a jejich receptory) a volnými protilátkami, ale na rozdíl od předchozího modelu zahrnuje vliv externích antigenů.

V [28] je navržen model imunitní sítě druhé generace. V této práci byly definovány tři důležité vlastnosti imunitní sítě: struktura, dynamika a metadynamika. Dynamiku imunitní sítě lze definovat jako změnu koncentrace protilátek vlivem jejich interakce s okolím, naproti tomu metadynamika je zodpovědná za produkci a dozrávání nových prvků sítě a na druhé straně za jejich likvidaci v případě auto-reaktivity, nebo v případě, kdy nedošlo k žádné interakci s okolím.

Tento model rozlišuje mezi protilátkami a B-lymfocyty. Každý idiotop proto existuje ve formě vázané na buňku v množství $b_i(t)$ a ve formě volné protilátky $f_i(t)$. Afinity (míra interakce) mezi idiotopem i a idiotopem j je označena jako m_{ij} . Citlivost σ_i sítě na idiotop i -tého typu je dán vztahem:


$$\sigma_i = \sum_{j=1}^N m_{j,i} f_j \quad (2)$$

Volné protilátky jsou výsledkem dozrávání specifických B-lymfocytů. Pravděpodobnost dozrání B-lymfocytu je závislá na míře závislosti příslušného idiotopu s aktuální konfigurací sítě, tzn. závisí na citlivosti sítě na daný idiotop. Závislost vývoje počtu volných a vázaných protilátek popisují rovnice:

$$\frac{df_i}{dt} = k_1 b_i \text{Mat}(\sigma_i) + k_2 f_i \sigma_i - k_3 f_i \quad (3)$$

$$\frac{db_i}{dt} = k_4 b_i \text{Prol}(\sigma_i) + \text{Meta}[i] - k_5 b_i \quad (4)$$


Průběhy funkcí $\text{Mat}(\sigma_i)$ a $\text{Prol}(\sigma_i)$ znázorňuje Obr. 2. Část $\text{Meta}[i]$ zahrnuje buňky, které jsou nově začleněny do sítě. Tento model na rozdíl od předchozího modelu [13] nezahrnuje vliv antigenů.



Obr. 2: Průběhy funkcí $\text{Prol}(\sigma_i)$ a $\text{Mat}(\sigma_i)$

Analogie návrhu algoritmů podle teorie imunitní sítě je podrobně rozebírána vzhledem ke svým emergentním vlastnostem jako je učení, paměť, auto-tolerance diverzita populace a interakce s okolním prostředím. Obecně všechny uvedené modely lze shrnout do vztahu:

$$\Delta c = \text{Stimulace} - \text{Potlačení autoreaktivních Ab} + \text{Nové Ab} - \text{Odumřelé Ab} \quad (5)$$



Obr. 3: Znárodnění obecného modelu dynamiky imunitní sítě

Stimulace odpovídá stavu, kdy je paratop rozeznán idiotopem jiné protilátky nebo antigenním epitopem. Potlačení je výsledkem, kdy je idiotop rozeznán pomocí paratopu (auto-reaktivní odezva).

2.1.2. Diskrétní umělé imunitní sítě

Modely diskretních umělých imunitních sítí jsou založeny na diferenčních rovnicích a iteračních procesech, které realizují chování sítě. Tyto modely se využívají pro návrh umělých imunitních algoritmů pro řešení problémů. V případě spojitých modelů se naráží na složitost jejich řešení a převážně je pro jejich řešení nutná numerická integrace. Vedle toho, jsou diskretní modely schopny měnit nejen počet elementů sítě, ale také strukturu těchto elementů. Buňky a molekuly diskretní sítě mohou měnit svůj tvar (reprezentaci ve stavovém prostoru) za účelem zvýšení afinity. Další vlastností, kterou se liší diskretní modely od spojitých je fakt, že diskretní modely implicitně zahrnují vliv externího prostředí reprezentujícího antigeny.

Původně byly dále popsány algoritmy RAIN (*Resource Limited Artificial Immune Network*) a aiNet (*Artificial Immune NETWORK*) vyvinuty pro rozpoznávání, shlukování a datovou kompresi. Nicméně následně byly tyto algoritmy rozšířeny pro využití v optimalizaci, řízení a robotice. Pro diskretní modely stále platí teorie Jerne [19], podle které je imunitní systém složen ze sítě, jejíž dynamika je vlivem působení cizího antigenu změněna. Vlivem působení externího antigenu je v síti vytvořen interní obraz. Imunitní síť představují skupiny molekul a buněk, které korespondují se skupinami antigenů. V síti existují dva typy interakcí:

- Interakce prvků sítě s prostředím (externími antigeny);
- Interakce prvků sítě navzájem.

Algoritmus RAIN

V [25] byl navržen algoritmus nazvaný RAIN (*Resource limited Artificial Immune Network*). Jedná se o algoritmus vytvářející imunitní síť skládající se z jednotlivých elementů

reprezentujících B-lymfocyty a protilátky, která se vyvíjí v diskrétních časových krocích. Jednotlivé elementy sítě jsou reprezentovány třemi vlastnostmi: řetězcem atributů v Euklidově prostou, úrovní stimulace a záznamem o počtu držených zdrojů. Pomocí mechanismu alokace zdrojů je prováděno řízení velikosti populace prvků sítě.

Prvním krokem je inicializace sítě. Jednotlivé prvky sítě (protilátky) jsou inicializovány náhodně vybranou skupinou vstupních vzorů (antigenů). Stimulační úroveň a počet držených zdrojů je nastaven na nulu. Dalším krokem je prezentace vstupních vzorů (antigenů) každému prvku sítě. Po prezentaci všech vstupních vzorů pro prvek sítě i je vypočtena úroveň stimulace dle vztahu:

$$s_i = \sum_{j=1}^M (1 - D_{i,j}) + \sum_{k=1}^n (1 - D_{i,k}) - \sum_{k=1}^n D_{i,k} \quad (6)$$

kde M je počet antigenů, n je počet spojených B-lymfocytů, D_{ij} je Euklidovská vzdálenost mezi antigenem j a B-lymfocyttem i a D_{ik} je Euklidovská vzdálenost mezi B-lymfocyty i a k . Výraz $(1-D_{ij})$ představuje afinitu mezi buňkami.

Úroveň stimulace určuje, které buňky jsou vybrány pro expanzi (klonální expanze) a které buňky jsou ze sítě odstraněny (metadynamika). Pro určení, které buňky mají být algoritmem udržovány, byl navržen mechanismus alokace zdrojů. Pro tento mechanismus je definován konstantní počet zdrojů, o které jednotlivé prvky sítě musí soutěžit. Každému prvku sítě jsou zdroje přiřazovány podle jejich úrovně stimulace tak, že čím větší je úroveň stimulace, tím více zdrojů je příslušnému prvku sítě přiřazen. Je-li celkový počet přiřazených zdrojů větší než je stanovený maximální počet, tak jsou prvky s nejmenším počtem zdrojů ze sítě vyřazeny. Vyřazování je ukončeno v okamžiku, kdy je celkový počet přiřazených zdrojů pod stanoveným limitem. Některé ze zbylých prvků sítě jsou vybrány pro klonální expanzi podle úrovně stimulace. Vyšší úroveň stimulace odpovídá vyšší pravděpodobnosti klonální expanze a většímu počtu vytvořených klonů.

Dále je každý prvek sítě podroben mutaci v inverzní proporci k úrovni stimulace. Vyšší úroveň stimulace odpovídá menší pravděpodobnosti mutace. To odpovídá stavu, kdy prvky s vysokou úrovní stimulace podstupují jemnému doladění, naproti tomu prvky s malou úrovní stimulace podstupují velkým změnám. Nakonec jsou všechny mutované klony porovnány oproti síti a je spočítána jejich afinita. Pokud jejich afinita padne do stanoveného prahu jsou nové mutace zapojeny do sítě.

Algoritmus aiNet

V [3, 5, 6, 10] byl publikován algoritmus aiNet (*Artificial Immune NETWORK*). Cílem učícího algoritmu aiNet je vytvořit množinu protilátek, která rozpozná a reprezentuje vstupní data včetně jejich struktury. Model umělé imunitní sítě aiNet lze formálně definovat jako hranově vážený graf, složený z uzlů nazývaných protilátky a z hran s přiřazenou vahou (sílu spojení) [5, 6, 10]. Interní obraz antigenu je množina protilátek, které jsou rozpoznány stejnou skupinou protilátek jako cizí antigen. Jinými slovy, protilátky představující interní obraz mají podobné povrchové vlastnosti (jsou rozeznány stejnou skupinou protilátek) jako cizí antigen. Stejného mechanismu je využíváno v procesu učení umělé imunitní sítě aiNet, kde na základě externích dat (nebo jejich shluků) je vytvářen jejich interní obraz v rámci umělé imunitní sítě. V rámci učení aiNet bez učitele dochází k vytváření reprezentace dat imunitní sítí. Výsledný počet protilátek v síti aiNet je mnohem menší než je množství vstupních vzorků, ale větší než je počet shluků v datech. Přesto je zachováno prostorové pravděpodobnostní rozložení uzlů (protilátek) sítě jaké bylo ve vstupních datech. Interakce protilátek a antigenů (vstupních dat) je reprezentována vzdálenostní metrikou (euklidovská vzdálenost, vzdálenost v blocích, apod.). Afinita antigenu a protilátky je v inverzním vztahu se vzdáleností ve stavovém

prostoru mezi jejich reprezentanty. Čím je menší vzdálenost mezi reprezentanty, tím je jejich afinita větší.

Pro popis algoritmu aiNet byla v [5] zavedena tato notace:

- **Ab**: množina všech dostupných protilátek ($Ab \in \mathbf{Ab}^{N \times L}$, $\mathbf{Ab} = \mathbf{Ab}_d \cup \mathbf{Ab}_m$, kde N je počet všech dostupných protilátek a L je počet atributů popisujících protilátku);
- **Ab_m**: množina paměťových protilátek ($Ab_m \in \mathbf{Ab}_m^{m \times L}$, $m < N$, kde m je počet paměťových protilátek);
- **Ab_d**: množina d nově přidaných protilátek do množiny **Ab**;
- **Ag**: populace antigenů ($Ag \in \mathbf{Ag}^{M \times L}$);
- **f_j**: vektor obsahující afinitu mezi antigenem Ag_j a všemi protilátkami Ab_i ($i = 1, \dots, N$). Afinita protilátky a antigenu je inverzní k jejich vzdálenosti ve stavovém prostoru;
- **S**: matice podobnosti mezi všemi páry protilátek Ab_i-Ab_j ($i, j = 1, \dots, N$). Prvek matice s_{ij} vyjadřuje afinitu mezi protilátkami Ab_i a Ab_j . Matice **S** je symetrická matice s nulovou diagonálou;
- **C**: množina N_c klonů vygenerovaných z množiny **Ag**;
- **C'**: množina **C** po procesu afinitní maturace;
- **d_j**: vektor obsahující afinitu mezi prvky množiny **C'** a antigenem Ag_j ;
- ζ : množství zralých protilátek k výběru (vyjádřeno v procentech);
- σ_d : práh přirozené smrti;
- σ_s : práh potlačení

Pro popis algoritmu budou použity následující funkce:

- **[Ab]** = generate(N, L): funkce náhodně vygeneruje N protilátek popsanych L atributy a vrátí je ve formě matice **Ab**.
- **[S]** = affinity(**Ab1**, **Ab2**): funkce vypočítá afinitu mezi maticí protilátek **Ab1** a maticí protilátek **Ab2**. Výsledná matice má rozměr $N_1 \times N_2$, kde N_1 je počet protilátek v matici **Ab1** a N_2 je počet protilátek v matici **Ab2**.
- **[Ab_n]** = select(**Ab**, **f**, n): funkce vybere n protilátek z matice **Ab** podle nejvyšší hodnoty afinity ve vektoru **f**.
- **[C]** = clone(**Ab_n**, **f**): funkce vygeneruje množinu klonů **C** z množiny **Ab_n** podle jejich afinity **f**.
- **[C']** = dmut(**C**, Ag_j , **f_j**): funkce vygeneruje množinu zmutovaných klonů **C'**. Mutace se řídí vztahem:

$$C'_k = C_k + \alpha_k (Ag_j - C_k); \quad \alpha_k \propto \frac{1}{f_{ij}}; \quad k = 1, \dots, N_c; i = 1, \dots, N. \quad (7)$$

- **[Ab_m, f]** = suppress(**Ab_m**, **S**, σ_d): funkce eliminuje paměťové protilátky, jejichž afinita $s_{ij} < \sigma_d$.
- **[Ab]** = insert(**Ab_m**, **Ab_d**): funkce sloučí matice **Ab_m** a **Ab_d** a vytvoří výslednou matici **Ab**.

```
function [Abm, S] = aiNet(Ag, L, gen, n, ζ, σd, σs, d)
begin
1. Ab := generate(N0, L); // Náhodné vygenerování počáteční populace
                           // protilátek.
2. for t = 1 to gen // Opakuj pro všechny generace.
2.1. for j = 1 to M // Opakuj pro všechny antigeny z množiny Ag.
2.1.1. f := affinity(Ab, Ag(j, :)); // Urči afinitu všech protilátek z Ab proti Agj.
2.1.2. Abn := select(Ab, f, n); // Vyber n protilátek s nejvyšší afinitou.
2.1.3. C := clone(Abn, f); // Pro n vybraných protilátek vygeneruj Nc klonů.
2.1.4. C' := dmut(C, Ag(j, :), f); // Na množině C proved' mutaci dle vztahu (7).
```

```

2.1.5.    f := affinity(C', Ag(j, :)); // Vypočítej afinitu zmutovaných klonů C' proti Agj.
2.1.6.    Abm := select(C', f, ζ); // Z C' vyber ζ% protilátek s nejvyšší afinitou.
2.1.7.    [Abm, f] := suppress(Abm, f, σd); // Eliminuj všechny paměťové protilátky s afinitou
// nižší než daný práh σd.
2.1.8.    S := affinity(Abm, Abm); // Vypočítej afinitu zbylých paměťových protilátek.
2.1.9.    [Abm, S] := suppress(Abm, S, σs); // Eliminuj všechny paměťové protilátky s afinitou
// nižší než daný práh σs.

    end;
2.2.    S := affinity(Abm, Abm); // Vypočítej afinitu paměťových protilátek.
2.3.    [Abm, S] := suppress(Abm, S, σs); // Eliminuj všechny paměťové protilátky s afinitou
// nižší než daný práh σs.
2.4.    Abd := generate(d, L); // Vygeneruj množinu Abd nových protilátek.
2.5.    Ab := insert(Abm, Abd); // Vytvoř novou populaci protilátek spojením
// paměťových Abm a nových Abd protilátek.

    end;
end;

```

Síť je inicializovaná malým počtem náhodně vygenerovaných prvků. Každý prvek sítě reprezentuje B-lymfocyt nebo molekulu protilátky (v rámci tohoto modelu jsou považovány za totožné) [5]. Dalším krokem je prezentace antigenů. Každý antigen je prezentován všem prvkům sítě a je vypočítána jejich afinita. Protilátky s největší afinitou řídí aktivaci imunitní sítě a začnou se dělit a diferencovat podle principu klonální selekce. Protilátky s nízkou afinitou jsou postupně eliminovány. Část vysoce afinních prvků je vybráno pro vytvoření klonální paměti. Případné auto-reaktivní protilátky jsou také eliminovány.

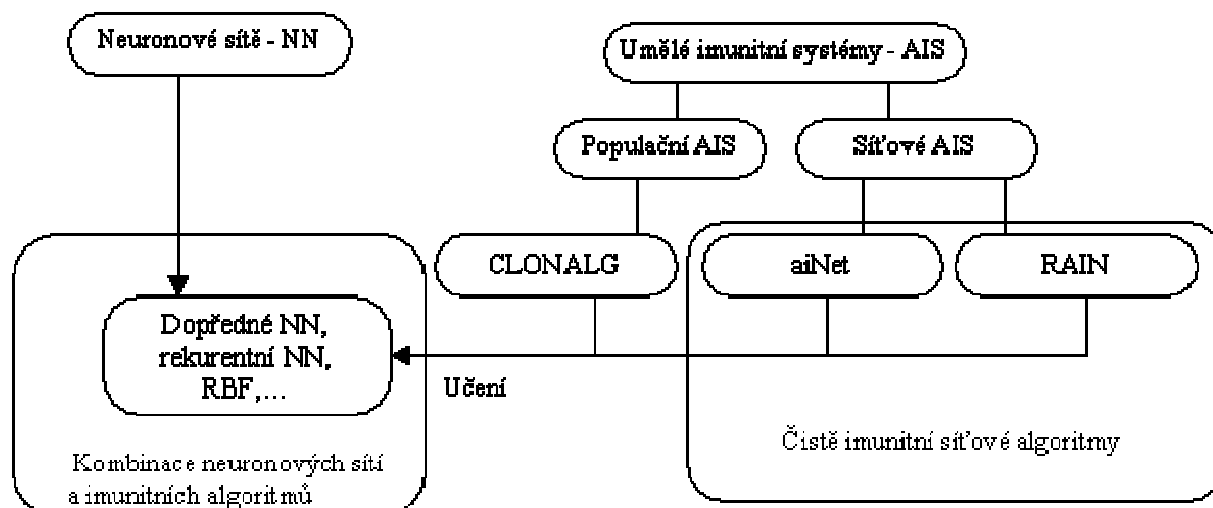
Po ukončení fáze učení reprezentuje imunitní síť protilátek interní obraz prezentovaných antigenů (vstupních dat). V průběhu učení dochází ke změně koncentrace a afinity protilátek. Výstupem fáze učení je množina paměťových protilátek \mathbf{Ab}_m reprezentovaných svými souřadnicemi ve stavovém prostoru a matice afinity mezi jednotlivými protilátkami \mathbf{S} . Matice \mathbf{Ab}_m reprezentuje naučený interní obraz antigenů (definuje umístění jednotlivých uzlů sítě ve stavovém prostoru) a matice \mathbf{S} určuje propojení jednotlivých uzlů (popisuje obecnou strukturu sítě). Tato reprezentace je nevhodná pro extrakci struktury naučené sítě. Cílem procesu extrakce struktury naučené aiNet sítě je učení počtu shluků v datech (počtu různých tříd) a přiřazení jednotlivých protilátek ve výsledné paměťové množině k jednotlivým shlukům. Algoritmus aiNet slouží k extrakci znalostí z množiny dat a následná analýza výsledné sítě představuje vlastní interpretaci předzpracovaných dat. Pro interpretaci aiNet sítě se využívají metody hierarchického shlukování. Vstupní data algoritmů hierarchického shlukování jsou reprezentována množinou paměťových protilátek, které jsou výsledkem učení aiNet sítě. Jedním ze způsobů reprezentace je dendrogram, pomocí kterého lze stanovit nejen počet shluků, ale také příslušnost jednotlivých vrcholů do shluků.

Algoritmus aiNet koresponduje se základní rovnicí znázorněnou na Obr. 3. Změna populace protilátek je dána nárůstem o nově vygenerované protilátky (body 2.4 a 2.5), minus eliminace nestimulovaných protilátek (bod 2.1.7), plus nárůst o klony stimulovaných protilátek (bod 2.1.3) a minus eliminace auto reaktivních protilátek (body 2.1.9 a 2.3)

Složitost algoritmu je závislá na mnoha faktorech jako jsou: počet atributů vstupních vektorů L , počtu vstupních vzorů M , počtu klonů protilátek Nc a počtu paměťových buněk m . Dle [5] je nejnáročnějším bodem vyhodnocení afinity mezi paměťovými protilátkami. Algoritmická složitost jedné iterace algoritmu aiNet je $O(m^2)$, kde m je počet paměťových buněk. Počet prvků množiny paměťových protilátek se mezi iteracemi algoritmu mění [5]. Algoritmická složitost celého algoritmu aiNet je závislá na ukončovacím kritériu a nelze ji stanovit obecně.

3. Neuronové a imunitní sítě

Neuronové i imunitní sítě jsou přístupy inspirované biologickými postupy. V literatuře bylo publikováno mnoho variant kombinací neuronových sítí a imunitních algoritmů [3, 4, 5, 6, 7, 8, 9, 10], jak již populačně nebo síťově založených. Hranice mezi oběma přístupy není pevně vymezena. Na Obr. 4 jsou znázorněny možné kombinace a rozhraní mezi neuronovými a imunitními sítěmi.



Obr. 4: Znázornění kombinací neuronových a imunitních sítí

V literatuře bylo publikováno mnoho variant neuronových sítí, od dopředných vícevrstevných perceptronů, přes různé varianty rekurentních sítí (např. Hopfieldovy sítě, ART), až po samoorganizující se mapy [21, 22, 23]. Varianty neuronových sítí lze dělit také podle způsobu učení na učení bez učitele, kdy dochází k nastavování sítě na základě stanované metriky, a na učení s učitelem, kdy jsou v průběhu učení nastavovány váhy synapsí podle trénovacích vzorků s definovaným výstupem.

Algoritmy aiNet a RAIN reprezentují skupinu algoritmů čistě inspirovaných teorií imunitní sítě. Jedná se o algoritmy učení bez učitele, primárně určené pro klasifikaci, které pracují na principech samoorganizace. Základní rozdíl mezi algoritmem aiNet a neuronovými sítěmi spočívá ve funkci uzlů a hran mezi nimi. V případě algoritmu aiNet představují uzly sítě vnitřní obraz prezentovaných vstupních vzorů a váhy na hranách představují sílu spojení (podobnost). Naproti tomu v případě neuronových sítí představují uzly sítě výkonný element a váhy jednotlivých hran reprezentují získanou (naučenou) znalost.

Porovnání neuronových a imunitních sítí publikované například v [5, 10], je zaměřeno na srovnání imunitních sítí a samoorganizujících se map SOFM (Self-Organizing Feature Map) [22, 23], jakožto podskupinu neuronových sítí. Základní rozdíl mezi algoritmem aiNet a samoorganizujícími se mapami spočívá v generování topologie adaptované mapy. V případě samoorganizujících se map SOFM je topologie dána předem, naproti tomu v případě algoritmu aiNet je topologie generována v průběhu vlastního algoritmu na základě vstupních dat. Další rozdíly aiNet a neuronových sítí jsou shrnuty v

Tab. 1 [10].

Vedle algoritmů aiNet a RAIN založených čistě na imunitních principech, byly publikovány kombinace neuronových sítí a algoritmů založených na imunitních principech [7, 8, 9]. Do této kategorie spadají algoritmy, kde hlavní výkonnou část zastávají neuronové sítě a imunitní algoritmy jsou použity pro počáteční nastavování nebo učení neuronové sítě.

Tab. 1: Srovnání vlastností algoritmu aiNet a neuronových sítí reprezentovaných algoritmem SOFM

<i>Charakteristika</i>	<i>aiNet</i>	<i>Neuronová síť (SOFM)</i>
Základní prvek	Buňky nebo protilátky reprezentované řetězcem atributů.	Neuron složený z aktivační funkce a aktivačního prahu.
Interakce mezi prvky sítě	Buňky jsou spojeny vahami, které indukují míru interakce s ostatními buňkami. Váhy jsou stanoveny podle schopnosti rozeznat se navzájem.	Váhový vektor může obsahovat kladné i záporné hodnoty indukující povzbuzující nebo potlačující aktivaci.
Učení	Nastavování atributů a asociovaných vah jednotlivých buněk.	Modifikace váhových vektorů.
Naučená znalost	Uložena v nastavení jednotlivých atributů buněk a v síle jejich vazeb.	Uložena ve vahách sítě.
Robustnost	Auto-tolerance, flexibilita a odolnost proti šumům.	Vysoká flexibilita a odolnost proti šumům.
Komunikace	Pomocí buněčné afinity, reprezentované silou spojení.	Pomocí spojení jednotlivých neuronů.
Dynamika	Změna koncentrace a afinity buněk v čase.	Změna síly vazeb mezi neurony v čase.

4. Závěr

Cílem této práce bylo shrnout základní mechanismy a principy, ze kterých vycházejí algoritmy založené na imunitních systémech. Pozornost byla soustředěna na skupinu vycházející z teorie imunitní sítě a hlavně pak na algoritmus aiNet, který patří do skupiny učení bez učitele. Algoritmus aiNet slouží k extrakci znalostí z množiny dat a následná analýza výsledné sítě představuje vlastní interpretaci předzpracovaných dat. Tím je algoritmus aiNet využitelný v široké škále aplikací. V [2] bylo publikováno rozšíření na úlohu optimalizace ve smyslu nalezení extrému účelové funkce, které přináší další prostor využití a dalšího výzkumu. V pracích [3, 5, 6, 10] byly uvedeny výsledky algoritmu aiNet na testovacích úlohách, které byly vytvořeny s důrazem na názornost dosažených výsledků a z tohoto důvodu byly poměrně jednoduché. Další oblastí je uplatnění imunitních algoritmů na řešení reálných aplikací, kde není stavový prostor možných řešení kvůli názornosti omezen maximálně na dimenzi 3. Přínosnou prací by také bylo srovnání s výsledky získanými na reálných aplikacích v kontrastu s jinými přístupy, jako jsou již zmiňované neuronové sítě nebo genetické algoritmy.

V závěru bylo uvedeno krátké porovnání síťového algoritmu aiNet s umělými neuronovými sítěmi, hlavně se samoorganizujícími se mapami SOFM. Dále byly naznačeny možné varianty kombinací umělých neuronových sítí a imunitních algoritmů. Některé kombinace již byly publikovány v uvedené literatuře, ale vzhledem k tomu, že se jedná o poměrně nové přístupy, zůstává otevřený velký prostor pro další vývoj a přizpůsobení publikovaných algoritmů pro konkrétní účely.

5. Literatura

- [1] Bartůňková, J. - Šedivá, A. *Imunologie - minimum pro praxi*. Praha: TRITRON, 1999. ISBN 80-7254-045-9.
- [2] Castro, L. N. - Timmis, J. I. An Artificial Immune Network for Multimodal Function Optimization. *In Proceedings of IEEE CEC'02*, May. 2002. vol. 1, pp. 699-674.
- [3] Castro, L. N. - Timmis, J. I. *Artificial Immune Systems: A New Computational Intelligence Approach*. London: Springer-Verlag, 2002. ISBN 1-85233-594-7.

- [4] Castro, L. N. - Timmis, J. I. Artificial Immune Systems as a Novel Soft Computing Paradigm. *Soft Computing Journal*. 2003, vol. 7, no. 7, pp. 526-544.
- [5] Castro, L. N. - Zuben, F. J. *Data Mining: A Heuristic Approach*. Abbass H. A. - Sarker R. A. - Newton C. S. USA: Idea Group Publishing, 2001. Chapter XII, aiNet: An Artificial Immune Network for Data Analysis, pp. 231-259.
- [6] Castro, L. N. - Zuben, F. J. An Evolutionary Immune Network for Data Clustering. *In Proceedings of the IEEE Brazilian Symposium on Artificial Neural Networks*. Rio de Janeiro, 2000. pp. 84-89.
- [7] Castro, L. N. - Zuben, F. J. An Immunological Approach to Initialize Centers of Radial Basis Function Neural Networks. *In Proceedings of CBRN'01*. 2001. pp. 79-84.
- [8] Castro, L. N. - Zuben, F. J. An Immunological Approach to Initialize Feedforward Neural Network Weights. *In Proceedings of ICANNGA'01*. 2001. pp. 126-129.
- [9] Castro, L. N. - Zuben, F. J. Automatic Determination of Radial Basis Function: An Immunity-Based Approach, *International Journal of Neural Systems (IJNS), Special Issue on Non-Gradient Learning Techniques*. 2002, vol. 11, no. 6, pp. 523-535.
- [10] Castro, L. N. - Zuben, F. J. Immune and Neural Network Models: Theoretical and Empirical Comparisons. *International Journal of Computational Intelligence and Applications (IJCIA)*. 2001, vol. 1, no. 3, pp. 239-257.
- [11] Castro, L. N. - Zuben, F. J. Learning and Optimization Using the Clonal Selection Principle. *IEEE Transactions on Evolutionary Computation, Special Issue on Artificial Immune Systems*. 2002, vol. 6, no. 3, pp. 239-251.
- [12] Dasgupta, D. et. al. *Artificial Immune Systems and Their Applications*. Springer-Verlag, 1999.
- [13] Farmer, J. D. et. al. Adaptive Dynamic Networks as Models for the Immune System and Autocatalytic. *Ann. of the N.Y. Acad. of Sci.* 1987. pp. 118-131.
- [14] Farmer, J.D. et. al. The immune system, adaptation, and machine learning, *Physica*. 1986, no. 22D, pp. 187-204
- [15] Fučíková, T. *Klinická imunologie v praxi*. Praha: Garlén, 1995. ISBN 80-85824-24-8.
- [16] Hořejší, V. - Bartůňková, J. *Základy imunologie*. Praha: TRITRON, 1998. ISBN 80-85875-73-X
- [17] Ishida, Y. et. al. *Immunity Based Systems-Intelligent Systems by Artificial Immune Systems*. Corona Pub. Co. Japan, 1998.
- [18] Jerne, N. K. Clonal Selection in a Lymphocyte Network. *Cellular Selection and Regulation in the Immune Response*. Raven Press, NY 1974. pp. 39.
- [19] Jerne, N. K. Towards a Network Theory of the Immune System. *An Immunologica*. 1974, pp. 373-389
- [20] Krejsek, J. - Kopecký, O. - Fixa, B. *Kapitoly z lékařské imunologie*. Univerzita Karlova, vydavatelství Karolinum Praha, 1993. ISBN 80-7066-723-0.
- [21] Kvasnička, V. a kol. *Úvod do teorie Neuronových sítí*. Bratislava: IRIS, 1997. ISBN 80-88778-30-1.
- [22] Mařík, V. - Štěpánková, O. - Lažanský, J. *Umělá inteligence 1*. Praha: Academia, 1993. ISBN 80-200-0496-3.
- [23] Mařík, V. - Štěpánková, O. - Lažanský, J. *Umělá inteligence 4*. Praha: Academia, 2003. ISBN 80-200-1044-0.
- [24] Perelson, A. S. Immune network theory, *Immunological Review*. 1989, no. 110, pp.5-36.
- [25] Timmis, J. *Artificial Immune Systems: A novel data analysis technique inspired by the immune network theory*. University of Wales. Department of Computer Science, 2001.
- [26] Trojan, S. a kol. *Lékařská fyziologie*. Grada Publishing, 1996. ISBN 80-7169-311-1.
- [27] Šterzl, J. *Imunitní systém a jeho fyziologické funkce*. Praha: Česká imunologická společnost, 1993.
- [28] Varela, F. J. - Countinho, A. Second Generation Immune Networks. *Immunology Today*. 1991.

Kontaktní adresa:

Ing. Luděk Kopáček
 USII/FES Univerzita Pardubice
 Studentská 84, Pardubice, 53210
 e-mail: ludek.kopacek@upce.cz