

UBAL: Univerzálny biologicky-motivovaný algoritmus s lokálnym pravidlom

Kristína Malinovská, Ľudovít Malinovský a Igor Farkaš

Centrum pre kognitívnu vedu, KAI FMFI UK, Univerzita Komenského v Bratislave
Mlynská dolina, 84248 Bratislava
Email: malinovska@fmph.uniba.sk

Abstrakt

Metóda spätného šírenia chyby (error backpropagation, BP) pre učenie umelých neurónových sietí trpí nedostatkom biologickej plauzibilnosti. Alternatívou sú modely ako O'Reillyho GeneRec využívajúce len lokálne aktivačné hodnoty siete. V príspevku predstavíme univerzálny biologicky-motivovaný algoritmus s lokálnym pravidlom UBAL, rozšírenie modelu BAL odvodeného od GeneRec. Pri vhodnom nastavení nových parametrov sa model dokáže naučiť sa nie len asociatívne, ale aj kategorizačné úlohy.

1 Úvod

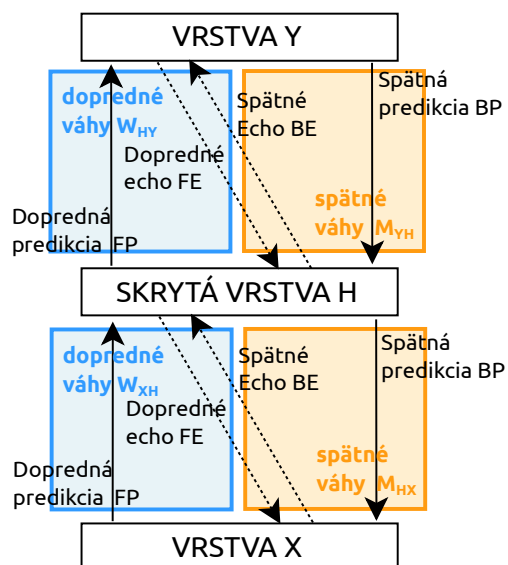
BP (?) je doteraz najprominentnejším algoritmom učenia neurónových sietí s učiteľom, no jeho biologická plauzibilita je diskutabilná. ? navrhol algoritmus zovšeobecnenej recirkulácie GeneRec, ktorý, podobne ako učenie v mozgu, funguje na báze lokálnych rozdielov aktivácií. Model pozostáva z 3-vrstvovej siete, ktorou sa aktivácia šíri dvoma smermi cez rovnaké váhy. V mínusovej fáze sieť produkuje odhad a v plusovej fáze, sa na výstup zafixuje cieľový vzor (angl. clamping), ktorý sa sieť má naučiť a aktivácia sa šíri naopak a učenie prebieha na báze ich rozdielu:

$$\Delta w_{pq} = \lambda a_p^-(a_q^+ - a_q^-), \quad (1)$$

kde p označuje presynaptický a q postsynaptický neurón. Pre potreby obojsmernej asociácie abstraktných reprezentácií v robotickom modeli zrkadliacich neurónov (Rebrová¹ a kol., ?) sme v minulosti na základe GeneRec modelu navrhli algoritmus obojsmerného učenia na základe aktivačných fáz BAL (?). BAL má tiež 3 vrstvy, no pre každý smer aktivácie resp. vstupno-výstupnej asociácie používa odlišné matice váh a pre každý smer používa pravidlo učenia ako GeneRec. Aj keď bol BAL v experimentoch porovnateľný s GeneRec, nedosiahol 100% konvergenciu na základných úlohách (kódovanie 4-2-4) ani použitím ideálnych parametrov a dvoch rýchlostí učenia (?).

2 Algoritmus UBAL

Pri hľadaní riešenia pre bezchybnú konvergenciu sme adaptovali pôvodný BAL na univerzálnejší algoritmus UBAL. Ten tiež používa rôzne matice váh pre dva hlavné smery šírenia aktivácie (W a M), teda dopredný (F) a spätný (B) beh, pričom každý z nich ešte obsahuje 2 fázy: predikciu a echo, pričom predikcia vzniká z externého stimulu na vstupno-výstupných vrstvách X a Y a echo reprezentuje odraz predikcie cez váhy z opačného smeru. Šírenie aktivácie v 3-vrstvovej sieti vyjadruje Obr. ?? a Tab. ??.



Obr. 1: Šírenie aktivácie v UBAL s 3 vrstvami.

Fáza	Zn.	Výpočet aktivácie
Dopr. predik.	FP	$q_j^{FP} = \sigma(\sum_i W_{ij} p_i^{FP} + b_j)$
Dopr. echo	FE	$p_i^{FE} = \sigma(\sum_j M_{ji} q_j^{FP} + d_i)$
Spätná predik.	BP	$p_i^{BP} = \sigma(\sum_j M_{ji} q_j^{BP} + d_i)$
Spätná echo	BE	$q_j^{BE} = \sigma(\sum_i W_{ij} p_i^{BP} + b_j)$

Tab. 1: Šírenie aktivácie medzi dvoma vrstvami p a q .

¹Kristína Malinovská, za slobodna Rebrová.

Pre vyjadrenie pravidla pre úpravu váh definujeme v Tab. ?? medzivýpočtové členy: cieľ (target, t) a odhad (estimate, e), ktoré ovplyvňujú parametre β a γ . Vďaka β a γ môžeme naše lokálne pravidlo učenia popísané v rovniciach ?? a ?? adaptovať, aby emulovalo rôzne typy učenia.

$$\Delta W_{ij} = \lambda t_i^B (t_j^F - e_j^F) \quad (2)$$

$$\Delta M_{ij} = \lambda t_j^F (t_i^B - e_i^B) \quad (3)$$

Člen	Zn.	Výpočet
Dopredný cieľ	t_j^F	$\beta_q^F q_j^{FP} + (1 - \beta_q^F) q_j^{BP}$
Dopredný odhad	e_j^F	$\gamma_q^F q_j^{FP} + (1 - \gamma_q^F) q_j^{BE}$
Spätný cieľ	t_i^B	$(1 - \beta_p^B) p_i^{BP} + \beta_p^B p_i^{FP}$
Spätný odhad	e_i^B	$\gamma_p^B p_i^{BP} + (1 - \gamma_p^B) p_i^{FE}$

Tab. 2: Členy v rovniciach učenia. β kombinuje predikcie z rôznych smerov ($\beta_q^B = 1 - \beta_q^F$), γ kombinuje predikciu a echo z tých istých váh (γ_q^F a γ_p^B sú nezávislé).

3 Experimenty

Prezentované experimenty s UBAL možno zhrnúť do 2 skupín podľa typu úlohy a konfigurácie parametrov β a γ . Testovali sme 3-vrstvové siete s náhodne inicializovanými váhami z normálnej distribúcie $\mathcal{N}(0.0, 0.1)$ ($\mathcal{N}(1.0, 2.0)$) a okrem β a γ sme menili rýchlosť učenia λ a veľkosť skrytej vrstvy h . Úspešnosť vyjadrujeme mierou F1.

3.1 Asociácia

Kanonická asocičná úloha je kódovanie 4-2-4, kde sú 4 rôzne binárne vzory autoasociované cez 2 skryté neuróny. V tejto úlohe, na rozdiel od modelov GeneRec a BAL, skonverguje pri vhodnej rýchlosti učenia 100% UBAL sietí (Obr. ??).


Pre overenie schopnosti heteroasociatívneho obojsmerného mapovania sme testovali model na náhodne generovaných riedkych binárnych vzoroch (200 párov po 100 bitov, 10 pozitívnych). Vplyv h a λ na priemerné F1 a počet epoch potrebných pre 100% úspešnosť zobrazujeme na Obr. ?. Hodnoty β a γ pre asocičné úlohy sú v Tab. ??

3.2 Kategorizácia

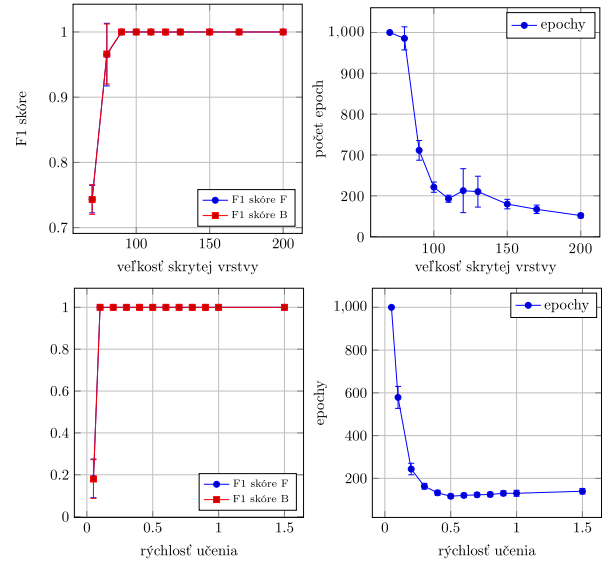
Na rozdiel od modelu BAL, nový UBAL možno prispôbením parametrov β a γ (Tab. ??) premeniť z heteroasociatívnej na kategorizačnú sieť. Obr. ?? ukazuje vplyv h a λ na konvergenciu siete.

Parameter/vrstva	X — H — Y
β^F	1.0 — 0.5 — 0.0
γ^F	0.5 — 0.5
γ^B	0.5 — 0.5

Tab. 3: Parametre β a γ pre asociáciu, $\beta^B = 1 - \beta^F$.



Obr. 2: Výsledky: kódovanie 4-2-4.



Obr. 3: Výsledky: mapovanie náhodných vzorov.


Aby sme overili UBAL na známom benchmarku, použili sme podmnožinu z MNIST. Predbežné výsledky experimentov ukazujú, že UBAL dosahuje porovnateľnú úspešnosť ako štandardná BP. Na Obr. ?? zobrazujeme vplyv λ na úspešnosť siete s $h = 700$.

4 Záver

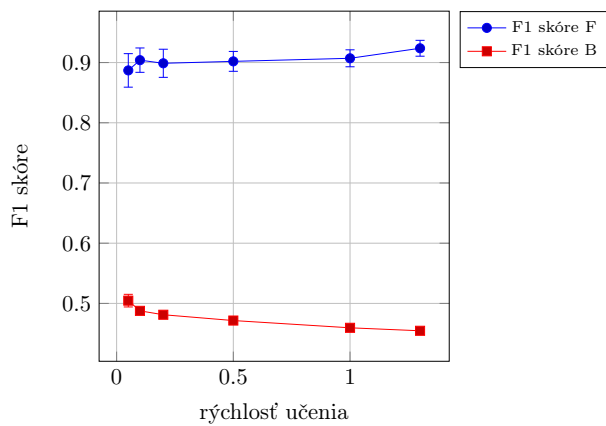
Základné experimenty potvrdili, že UBAL možno použiť na rôzne typy úloh. V jeho univerzálnosti a biologickej plauzibilite vidíme veľký potenciál pre kognitívne modelovanie. Tiež je potrebné preskúmať ďalšie vlastnosti a aplikácie algoritmu.

Parameter/vrstva	X — H — Y
β_{XOR}^F	0.0 — 1.0 — 0.0
β_{MNIST}^F	0.01 — 1.0 — 0.0
γ^F	0.0 — 0.0
γ^B	0.0 — 0.0

Tab. 4: Parametre β a γ pre kategorizáciu, $\beta^B = 1 - \beta^F$.



Obr. 4: Výsledky: XOR



Obr. 5: Výsledky: MNIST tréovanie s rôznymi λ

PodĎakovanie

Tento príspevok vznikol za podpory grantovej agentúry VEGA v rámci grantovej úlohy 1/0686/18 a KEGA v rámci grantovej úlohy 017UK-4/2016.