

COEVOLUTION OF CARTESIAN DEVELOPMENTAL NETWORK

Adam Kolář

Master Degree Programme (2), FIT BUT

E-mail: xkolar14@stud.fit.vutbr.cz

Supervised by: František Zbořil, Michaela Šikulová

E-mail: zboril@fit.vutbr.cz, isikulova@fit.vutbr.cz

Abstract: The aim of this work is to verify synergy of genetic programming and neural networks in the dynamically changing tasks. Solution is represented by *Cartesian Genetic Programming Developmental Network (CGPDN)*, that is characterized by ability to solve its topology as well as functions controlling potential spreading and connections' weights estimations. Coevolutionary method will be compared with other existing approaches on variety benchmark problems. We propose also optimization based on evolution of *CGPDN* initial parameters.

Keywords: Coevolution, Cartesian Genetic Programming, Cartesian Developmental Network, Back-propagation, Artificial Neuron, Chromosome, Indirect Encoding

1 ÚVOD

Neuronové sítě představují matematický výpočetní model vycházející z funkce biologických struktur. Často jsou používány pro řešení složitých klasifikačních a asociačních úloh. Ve své předchozí práci jsem se zabýval použitím *Hopfieldovy neuronové sítě* pro řešení úlohy hledání *Hamiltonovských kružnic* či adaptačním učením sítě určené pro optimalizaci správné opravy slov.

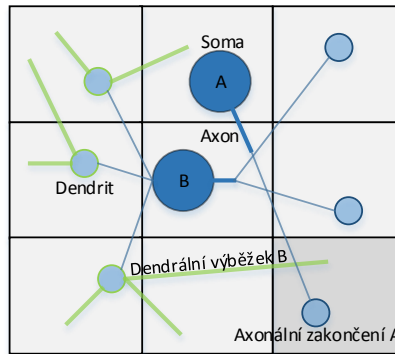
Ukazuje se, že současné návrhy neuronových sítí jsou aplikačně specifické a složité přenositelné na typově odlišné úlohy. V případě rozsáhlejších topologií používajících například gradientní učení je třeba velmi velká trénovací množina. Šíření úpravy vah do hlubších vrstev podléhá evaporaci a aproximace správného řešení trvá neúměrně dlouhý čas.

Motivací pro experimentování s *Cartesian Developmental Network (CGPDN)* [1] je snaha nalézt robustní neuronovou síť, která je schopna učení nad stavově velmi rozsáhlým, dynamicky se měnícím prostředím. Zároveň požadujeme, aby tato síť byla schopna evolvovat svou topologii, stejně tak jako chování funkcí řídících šíření potenciálu sítí a propojování funkčních komponent. Takové chování přesněji reflektuje reálné fungování mozku, který je předobrazem pro všechny modely neuronových sítí.

2 DEVELOPMENTAL NETWORK

Pro tvorbu sítě použijeme komplexní model neuronu. Ten se skládá z pěti typů komponent: *somy*, *dendritů*, *axonu*, *axonálních zakončení* a *dendrálních výběžků*. Neurony jsou umístěny do mřížky. Spojení neuronů (*jak lze vidět na obrázku 1*) je definováno plošně. Axonální zakončení a dendrální výběžky neuronů *A* a *B* ve shodné části mřížky tvoří spojení. Základní odlišností od běžných neuronových sítí je, že se komponenty mohou v mřížce pohybovat, vznikat a zanikat. Toto chování ovlivňuje jeden z atributů. Každá komponenta je definována pomocí množiny atributů. Atributy představují vstupy pro několik typů funkcí (chromozomů), které znovuupravují jejich hodnoty. Ty jsou prahovány a rozhodují o tvaru topologie, nastavení vah spojení a směru šíření potenciálu od vstupů k výstupům sítě.

Funkce upravující propojení sítě, její tvar a způsob šíření potenciálu jsou programy evolvované kartézským genetickým programováním.



Obrázek 1: Obrázek ukazující propojení neuronů v mřížce.

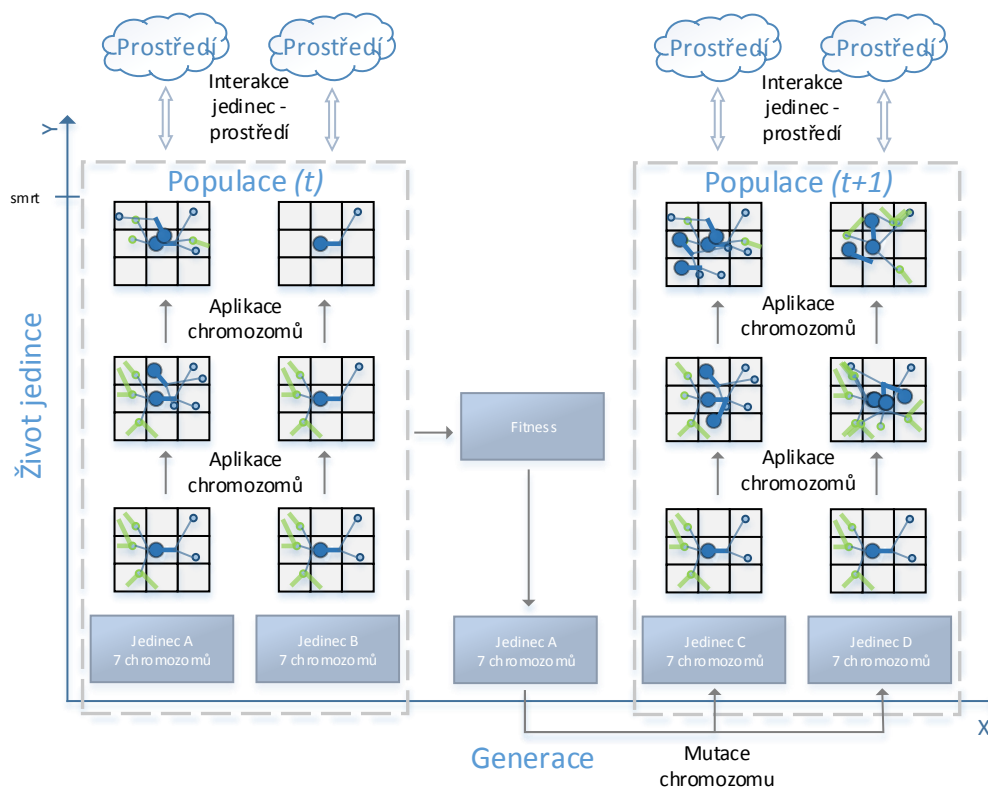
3 KARTÉZSKÉ GENETICKÉ PROGRAMOVÁNÍ

Kartézské genetické programování (CGP) [2] vychází z přístupů *genetického programování* navrženého *Johnem Kozou* a slouží pro automatizovaný návrh počítačových programů. Umělým evolučním procesem inspirovaným *Darwinovou evoluční teorií* a *neodarwinismem* vytváříme jedince s co nejlepším ohodnocením. Jedince reprezentuje orientovaný acyklický graf, v jehož uzlech jsou vybrané funkce. Při výpočtu uvažujeme několik omezujících podmínek na tvar grafu. Výsledná evolvovaná topologie bude mít n_r řádků a n_c sloupců. Celý systém má pevně daný počet n_i vstupů a n_o výstupů. Funkce se vybírají z množiny Γ , kde $|\Gamma| = n_f$ a mají až n_n parametrů (obvykle se uvažuje využití všech). Míru propojitelnosti celého systému určuje celočíselný parametr *L-back*. *L-back parametr* říká, že funkce (prvek topologie) v i . vrstvě může na své vstupy připojit výstup funkce ležící až v L předchozích vrstvách.

Hlavní výhodou tohoto přístupu je konstantní velikost chromozomů. V úloze pro *CGPDN* zjednodušíme graf na lineární posloupnost uzlů, kde $n_r = 1$ a $n_c = L\text{-back}$. Budou prováděny pouze bodové mutace měnící typ a vzájemné propojení funkcí. Každý jedinec bude definován sadou sedmi chromozomů. Tři *chromozomy životního cyklu* ovlivňují tvar topologie. Tři *chromozomy šíření potenciálu* ovlivňují šíření vstupního potenciálu sítě až k výstupním axonálním zakončením a rozhodují, zda je daný neuron aktivovaný. Síť je navržena tak, aby aktivní byly jen používané části topologie, stejně jak tomu je u lidského mozku. Posledním ze sady sedmi chromozomů je *chromozom nastavení vah spojení*.

4 KOEVOLUCE

Koevoluce nepřímým zakódováním spojuje *CGP* chromozomy a *Developmental Network (DN)*. Průběh algoritmu učení *CGPDN* můžete vidět na obrázku 2. Na ose X grafu je znázorněn počet generací uplynulých v rámci evoluce. Na ose Y je doba života jednoho jedince. Populace $P(t)$ obsahuje dva jedince A a B . Oba mají stejnou počáteční *DN* inicializovanou do mřížky a sadu sedmi chromozomů. Sady jsou odlišné, na počátku náhodně vygenerované a skládají se z kartézských programů. Síť jedince začne komunikovat prostřednictvím svých vstupů a výstupů s prostředím. Na základě funkce chromozomů a vstupů z prostředí se topologie sítě proměňuje a generuje výstupy. Jakmile se všichni jedinci vyvinou a komunikace s prostředím skončí v bodě smrt, dojde k ohodnocení chromozomů. Nejlepší jedinec je vybrán. Jsou mutovány jeho chromozomy, nikoliv jeho topologie. Vznikají noví jedinci C a D . Jejich topologie se nastaví do stejného počátečního nastavení, jako v předchozí generaci a algoritmus se opakuje. Výstupem je evolvovaná neuronová síť s chromozomy.



Obrázek 2: Evoluce sítě CGPDN.

Pomocí konstantně velkých chromozomů můžeme tedy nepřímo vygenerovat libovolně velkou topologií.

5 ZÁVĚR

V rámci diplomové práce bych chtěl otestovat chování algoritmu na jednoduchých úlohách, jako je vyvažování kyvadla, stejně jako chování pro složitější prostředí, reprezentované úlohou průchodu bludištěm s nástrahami. Dalším cílem je srovnat dosavadní výsledky z [1] při použití navržené optimalizace v podobě evoluce počátečního zakódování sítě.

CGPDN by mohl být krok k vyšší abstrakci v oblasti neuronových sítí. Stejně tak by se tento model mohl stát expertním nástrojem pro určení, jaký typ aplikačně specifických topologií a aktivačních funkcí při návrhu sítě použít.

REFERENCE

- [1] Khan, G. M.; Miller, J. F.; Halliday, D. M.: Evolution of Cartesian Genetic Programs for Development of Learning Neural Architecture. *Evolutionary Computation*, ročník 19, č. 3, 2011: s. 469–523.
- [2] Miller, J. F.: *Cartesian Genetic Programming*. 2011, 344 s. ISBN 978-3-642-17309-7.