

GENETICKÉ UČENÍ NEURONOVÝCH SÍTÍ

GENETIC LEARNING OF NEURAL NETWORKS

Roman Biskup, Anna Čermáková

Anotace:

Příspěvek se zabývá prezentací principů učení jednoho konkrétního typu neuronových sítí. Cílem práce je představení méně známé metody trénování umělých neuronových sítí, která je založena na genetických algoritmech.

Klíčová slova:

neuronové sítě, formální neuron, vícevrstvý perceptron, genetické učení

Abstract:

This article presents principles of learning one particular neural network type. Initially text describes model of simple artificial neuron and his connection to a net. The aim of this text is a presentation less well-known learning method of the neural networks, which is based on Genetic Algorithms.

Keywords:

neural networks, formal neuron, multilayer perceptron, genetic learning

ÚVOD

Stále častěji je možno se setkat s různými podpůrnými systémy řízení podniků, které umožňují efektivně využívat dostupné zdroje. V současné době se díky změnám souvisejících nejen se vstupem České republiky do EU mění podmínky, za nichž se jednotlivé firmy uplatňují na trhu. Za poměrně nestabilního prostředí stoupá na ceně práce expertů schopných podchytit důležité indikátory, na jejichž základě mohou kvalifikovaně navrhnout řešení. Při tvorbě expertního systému, jež by substituoval práci experta, je často problémem čas a neschopnost toho daného experta popsat svoje rozhodování pomocí logických úvah snadno převeditelných do *If-then-else* jazyka vhodného pro implementaci. Řešení nabízí expertní systém založený na neuronových sítích. Pro tvorbu takového expertního systému není nutná precizně popsaná rozhodovací struktura experta, stačí jen shromáždit data, podle nichž se expert (skupina expertů) rozhoduje a k nim příslušná rozhodnutí, jež byly učiněna.

Řekne-li se slovní spojení umělá neuronová síť většině lidí, kteří o neuronových sítích něco málo slyšeli, se okamžitě vybaví jeden konkrétní typ sítě a tou je vícevrstvá dopředná síť. Tito lidé znali problematiku si vzpomenou na nejběžnější způsob, jakým se do prostoru sítě dá umístit informace. Nejběžnějším a poměrně osvědčeným způsobem je učení vícevrstvé dopředné sítě s využitím algoritmu se zpětným šířením chyby, známým jako „Backpropagation“.

Tento algoritmus však není jediným způsobem jak vhodně nastavit parametry sítě a v tomto příspěvku je pojednáno o alternativním způsobu jak neuronovou síť natrénovat. Tedy nastavit váhy, prahy a parametry přenosových funkcí vícevrstvé dopředné sítě bude probíhat pomocí genetických algoritmů. Aby bylo možno uvedený algoritmus prezentovat je přece jen nutné nejprve alespoň zevrubně popsat topologii sítě.


TOPOLOGIE VÍCEVRSTÉ DOPŘEDNÉ SÍTĚ

Formální neuron

Formální neuron, jakožto zjednodušený model biologického neuronu, je složen z výkonného těla, obecně n různých vstupů a pouze jednoho výstupu. Na vstupy neuronu přicházejí informace obecně charakterizovány reálnými čísly $x_1, \dots, x_n$, z nichž neuron spočte váženou sumu, od níž ještě odečte prahovou hodnotu běžně nazývanou *bias* Θ :

$$\xi = \sum_{i=1}^n w_i x_i - \Theta. \quad (1)$$

Následně transformuje hodnotu ξ *přenosovou funkcí* σ na *výstupní hodnotu neuronu* $y = \sigma(\xi)$. Doplňme, že hodnotě ξ se říká *vnitřní potenciál neuronu* a váhám $w_1, \dots, w_n$ *váhy synaptické*. Přenosová funkce je do modelu zahrnuta z důvodů korekce výstupu daného neuronu a právě v součinnosti s biasem modeluje klasickou aktivační hodnotu biologického neuronu. Přenosová funkce bývá volena s ohledem na učicí algoritmus. Výběr je však obvykle prováděn z množiny sigmoidních funkcí¹ zobrazujících reálnou osu na omezený interval. Při zobrazení modelu formálního neuronu si představujeme váženou sumu vstupů tak, že jednotlivé vstupy ohodnocujeme jim příslušnými synaptickými váhami, jež určují míru propustnosti jednotlivých vstupů. Záporná hodnota synaptických vah pak zřejmě představuje inhibiční charakter daného vstupu. Vše názorně zobrazuje následující obrázek (Obr.1).




OBR.1: FORMÁLNÍ NEURON

Právě popsaný neuron je třeba zapojit do sítě, neboť vlastnosti formálního neuronu nejsou z hlediska přínosu k řešení reálných úloh příliš oslnivé. Například formální neuron, jak publikoval M. L. Minsky a S. A. Papert v roce 1969 [2], nedokáže řešit již jednoduchou logickou funkci XOR².

VÍCEVRSTVÁ DOPŘEDNÁ SÍŤ

Různé typy sítí vznikají na základě zvoleného propojení neuronů. Dopředná vícevrstvá síť vzniká spojením neuronů, jež jsou rozděleny do několika funkčních vrstev - *vrstva vstupní*, *vrstvy skryté*, či *mezilehlé* a *vrstva výstupní*. Každá vrstva je od předcházející a následující vrstvy, včetně vrstvy vstupní a výstupní, vymezena následujícím pravidly. Neurony jedné vrstvy se navzájem neovlivňují, čímž rozumíme neexistenci spoje mezi neurony. Všechny výstupy neuronů jedné vrstvy jsou vstupy pouze pro každý neuron vrstvy následující. Obdobně vstupy neuronu dané vrstvy jsou výstupy právě všech neuronů vrstvy předcházející.

Označíme-li počet vrstev $p+1$, pak vstupní (nultou) vrstvu tvoří tzv. *vstupní neurony*. Na každý z nich je přiveden pouze jeden vstup odpovídající vstupu z okolí sítě. Je-li tedy problém charakterizován n_0 vstupními hodnotami $\mathbf{x} = (x_1, \dots, x_{n_0})$, má vstupní vrstva právě n_0 neuronů. Vstupní neurony mají jen formální funkci a slouží k distribuci vstupních hodnot k další vrstvě sítě. Každý vstupní neuron přivádí data na vstup všech neuronů v první vrstvě. První



OBR.2: ARCHITEKTURA DOPŘEDNÉ VÍCEVRSTVÉ NEURONOVÉ SÍTĚ 3-4-3-2

¹ např.: saturovaná lineární funkce, logistická sigmoida, hyperbolický tangens, ...

² exkluzivní OR – vylučovací disjunkce

až $p-1$ vrstva je označována za skrytou vrstvu a společně tvoří hlavní výpočetní sílu neuronové sítě. Výstupní p -tou vrstvou označujeme neurony, jež mají za vstupy všechny výstupy neuronů předcházející $p-1$ vrstvy a samy tvoří výstup celé neuronové sítě. Je-li tedy problém charakterizován n_p výstupními hodnotami $y = (y_1, \dots, y_{n_p})$, má výstupní vrstva právě n_p neuronů. Výstupním neuronům obvykle přiřazujeme jen lineární přenosovou funkci. Bude-li mít vícevrstvá dopředná síť tři vstupy, dvě skryté vrstvy, jednu s čtyřmi, druhou se třemi neurony, a výstupní vrstvu s dvěmi neurony, pak ji můžeme graficky znázornit následujícím způsobem (Obr.2).

Právě zobrazená neuronová síť může za určitého nastavení topologie obsahovat 46 volných parametrů, jež je třeba v procesu učení najít. Z nich 9 připadá na hodnoty biasů neuronů ve skrytých vrstvách a výstupní vrstvě, 7 na parametr sigmoidní přenosové funkce skrytých neuronů a $3 \cdot 4$, $4 \cdot 3$ a $3 \cdot 2$ tedy dohromady 30 parametrů připadá na hodnoty synaptických vah. Zvolíme-li tedy typy přenosových funkcí, architekturu sítě a způsob učení, zvolili jsme celou topologii neuronové sítě. Této části procesu tvorby neuronové sítě se říká *organizační dynamika*.

Vzhledem k tréninkové metodě není nutné precizně zavádět značení, tak jako například pro metodu backpropagation.

UČENÍ NEURONOVÝCH SÍTÍ

AKTIVNÍ A ADAPTAČNÍ DYNAMIKA

Neuronovou síť můžeme chápat jako *naučitelné zobrazení* F , jehož výstup y je závislý na váhách příslušných každému neuronu sítě, vstupních hodnotách a biasech tedy $y = F(w, x, \theta)$, kde w je vektor všech synaptických vah celé neuronové sítě, x je vektor reprezentující vstup sítě a θ je vektor biasů. Z hlediska práce neuronové sítě s již určenou topologií, rozlišujeme dvě dynamiky, v nichž neuronová síť pracuje. Jednou z nich je *dynamika aktivní*. V aktivní dynamice se na vstupní neurony sítě přivádí vstupní informace a po vrstvách jsou počítány jednotlivé výstupní hodnoty všech neuronů. Pro uživatele využívajícího již adaptovanou neuronovou síť je samozřejmě podstatný pouze celkový výstup sítě y . Druhou, *adaptivní dynamikou* rozumíme modifikaci volných parametrů neuronové sítě. Tato modifikace není jednoznačně dána a záleží jen na rozhodnutí, jaká metoda bude pro vhodné nastavení vah zvolena. Tedy k již slibovanému hledání optimálního nastavení volných parametrů neuronové sítě pomocí genetických algoritmů.

GENETICKÉ ALGORITMY

Myšlenka genetických algoritmů je založena na základě biologické genetiky a Darwinovy evoluční teorie. Postupně jsou tvořeny generace jedinců jež se předem daným způsobem vyvíjí z generace předchozí. Při matematickém popisu genetických algoritmů bývá používána terminologie, jež je známá z biologických oborů³ viz tabulka (levý sloupec biologický význam, první pak matematické paralela):

Populace	
sled generací	vývojově uspořádaná množina generací
GENERACE	
skupina jedinců, na niž je aplikována teorie o vývoji druhů (selekce)	množina jedinců na niž je prováděn výběr pro vytvoření nové generace
Jedinec	
nositel genetické informace	reprezentant vektoru genotypu
Genotyp	
genetický popis organismu	celkový vektor, jež kóduje řešený problém
Gen	
elementární jednotka genetické informace	jedna určitá složka chromozomu, konkrétní symbol

³ jakkoliv se jeví oblast informatiky a genetiky vzdálená

Fenotyp	
fyzický popis genotypu Př.: Je-li u člověka příslušný chromozom typu XY (= genotyp) je daný člověk mužem ⁴ (= fenotyp)	výsledek transformace zakódování Př.: binární vyjádření 101 (= genotyp) odpovídá číslu 5 v dekadickém, tedy pro člověka běžném zápisu (= fenotyp)
Chromozom	
část molekuly DNA,	vektor obsahující jednu či více složek celkového vektoru, jež kóduje řešený problém, např. sekvence symbolů z nějaké abecedy (mohou to být čísla, znaky nebo jejich kombinace)
Alela	
určité místo (pozice) v chromozómu, jedna z konkrétních forem genu	množina jistých hodnot, kterých mohou geny nabývat
Fitness	
síla jedince v generaci, od ní se odvozuje šance k přežití	síla jedince v generaci, odvozuje se kriteriální funkce

Princip genetických algoritmů je v souvislosti s Darwinovou evoluční teorií následující: Vybrat optimálního jedince (algoritmus), který se nejlépe hodí pro dané prostředí (daný úkol). Na počátku je tedy z parametrického prostoru, jež je určen alelami, náhodně vygenerována množina jedinců určená svými genotypy (1. generace). Pro jednotlivé jedince se spočte tzv. *kriteriální funkce*, což je funkce, jež charakterizuje vhodnost jedince (v případě neuronových sítí je to globální chyba sítě). Následující generace je pak tvořena z té předcházející předem daným způsobem. Jedním z nejkompaktnějších přístupů je tento postup, vycházející ze skutečných principů přírody.

Část jedinců postupuje rovnou do další generace na základě nejvyšší vhodnosti, princip tzv. *elitářství* (1). Druhá část nově vznikající generace je z té předchozí náhodně vybrána, což představuje princip *nepohlavního rozmnožování* (2). Třetí část vzniká zkombinováním genotypů dvou rodičů s výsledkem dvou potomků, u nichž je genotyp vytvořen náhodnou záměnou některých sobě odpovídajících genů (3). Záměna genů může být přesně dána, nebo je volena náhodně. Poslední skupina je odvozena od těch předchozích, nově vzniknuvších, pomocí mutace – náhodné změny genu (4). V modelech genetických algoritmů bývá mutace řešena pomocí generátorů náhodných čísel a určený gen je buďto zaměněn náhodným číslem, nebo je gen původní změněn v závislosti na vygenerovaném čísle.

GENETICKÉ UČENÍ NEURONOVÝCH SÍTÍ

Předpokládejme tréninkovou datovou množinu o s prvcích, každý ve tvaru $(\mathbf{x}_k, \mathbf{d}_k)$ pro $k = 1, \dots, s$, kde $\mathbf{d}_k$ je vektor požadovaného výsledku, jež chceme síť naučit přiřadit k vstupu $\mathbf{x}_k$. Pro vyhodnocení nastavení parametrů vícevrstvé dopředné neuronové sítě vzhledem k datové množině se standardně používá *celková chyba sítě*:

$$E = \sum_{k=1}^s E_k, \text{ kde } E_k = \frac{1}{2} (\mathbf{y}_k - \mathbf{d}_k)^T (\mathbf{y}_k - \mathbf{d}_k), \text{ kde } E_k \text{ je tzv. } \textit{parciální chyba sítě},$$

Parciální chyba sítě je odchylka výstupu sítě od požadovaného výsledku pro daný k -tý vzor. Celková chyba sítě se navíc stává v genetickém algoritmu kriteriální funkcí pro hodnocení vhodnosti jedince.

V prvním kroku je náhodně vygenerováno dostatečné množství (m) jedinců (=neuronových sítí s různým nastavením volných parametrů), jejichž genotypem jsou hodnoty volných parametrů trénované sítě. Pro každého z nich je vypočtena hodnota kriteriální funkce $E^{l,1}$, kde $l = 1, \dots, m$, jež slouží k ukončení genetického učení, respektive k ohodnocení každého z jedinců. Z hodnoty kriteriální funkce $E^{l,1}$ je dále spočtena *vhodnost* $v^{l,1}$. Vhodnost je transformovaná hodnota kriteriální funkce do intervalu $[0,1]$, která umožňuje vybrat do další generace zástupce s možností zvýhodňovat lepší jedince a při tom zachovat princip náhody. Za „vhodnostní“ transformaci se nabízí zvolit:

⁴ nutno dodat, že jsou v historii známy případy kdy genotyp neodpovídá fenotypu – v souvislosti příkladem může být jedinec genotypicky žena a fenotypicky muž

$$v^{l,1} = 1 - \frac{E^{l,1}}{\max_{1 \leq l \leq m} \{E^{l,1}\}} \text{ nebo}$$

$$v^{l,1} = \frac{Q^{l,1}}{\sum_{i=1}^m Q^{i,1}}, \text{ kde } Q^{l,1} = C - E^{l,1}, \text{ pro } l = 1, \dots, m \text{ a } C \in \mathbb{R} \text{ je maximální chyba sítě či její}$$

odhad.

Prvý vzorec může být s výhodou použit při turnajovém výběru jedinců, kdy proti sobě soupeří dva jedinci. Výsledek jejich soupeření závisí pouze na náhodě a vhodnosti. Tedy každému jedinci je vygenerováno náhodně číslo jež je váženo vhodností, jedinec s vyšším číslem vítězí. Tímto způsobem jsou přímo vybráni elitní jedinci – princip (1) tj. ti, jenž měli nejvíce vítězství a dále pak kandidáti ke křížení – princip (2). Náhodně bez ohledu na vhodnost jsou zařazeni další jedinci – princip (3). Na konec je na náhodně vybraných jedincích provedena mutace a to buď na jedincích nově vzniknuvších nebo jsou vybraní jedinci zdvojeni a mutace je provedena na kopii.

Druhý vzorec bývá volen při postupu, jenž je všeobecně nazýván ruletová selekce. Nejprve jsou vybráni elitní jedinci podle absolutní velikosti vhodnosti. Výběr pro křížení pak probíhá tak, že každému jedinci je přiřazena výše dle vhodnosti a tím šance postoupit do další generace. Principy náhodnosti a mutace jsou obdobné postupu popsanému výše.

Již popsanými principy je vytvořena nová generace, jež zdrojem pro generaci následující. Výběr a modifikace jedinců probíhá opět podle pravidel (1) – (4), uvedené vzorce zůstávají v platnosti jen index „1“ se změní na příslušný index generace. Proces generování nových generací je ukončen v okamžiku dosažení předepsané celkové chyby sítě, nebo po předepsaném počtu kroků.

ZÁVĚR

Tento postup je formálně méně složitý než backpropagation. Při výběru přenosové funkce není nutné omezení na její dvojnásobnou diferencovatelnost nutnou pro gradientní metodu, jež je podstatou učení se zpětným šířením chyby. Genetický algoritmus prohledávající parametrický prostor s m jedinci v populaci, pracuje zhruba tak rychle jako m^3 izolovaných hledačů (viz [3]). Mechanismus genetického algoritmu v němž jedinci prochází parametrický prostor a navzájem se ovlivňují pomocí předem daných pravidel – genetických operátorů, bývá označován jako *implicitní paralelismus*. Tím je dosahováno synergetického efektu, díky němuž populace jedinců dosáhne kýženého řešení rychleji. Dále křížení a mutace zabraňuje uvíznutí algoritmu v lokálních minimech celkové chyby sítě.

Literatura:

- [1] Holeňa, M. *Matematické základy umělých neuronových sítí*. Praha 1996, ČVUT studijní text
- [2] Minsky, M. L. – Papert, S. A. *Perceptrons*. MIT Press Cambridge M, 1969.
- [3] Šíma, J. – Neruda, R. *Teoretické otázky neuronových sítí*. Praha 1996, ISBN 80-85863-18-9.

Kontaktní adresa:

Mgr. Roman Biskup, biskup@zf.jcu.cz

Prof. RNDr. Anna Čermáková, CSc., annacer@zf.jcu.cz

Jihočeská univerzita v Českých Budějovicích, Zemědělská fakulta, Katedra aplikované matematiky a informatiky, Studentská 13, 387 05 České Budějovice