

SCIENTIFIC PAPERS
OF THE UNIVERSITY OF PARDUBICE
Series B
The Jan Perner Transport Faculty
5 (1999)

APLIKACE NEURONOVÝCH SÍTÍ PRO DETEKCI PORUCH SIGNÁLŮ

Michal MUSIL

Katedra provozní spolehlivosti, diagnostiky a mechaniky v dopravě

1. Úvod


Neuronové sítě představují v současné době jeden z hlavních prostředků pro vytváření systémů s umělou inteligencí. Aplikační oblast neuronových sítí je značně rozsáhlá. Neuronové sítě jsou označovány jako tzv. učící se systémy. Při procesu učení se sítě jsou na vstupy sítě přiváděny tzv. trénovací obrazce pro které je předem známý správný výstup. Na základě konfrontace správného výstupu a skutečného výstupu sítě jsou prováděny zásahy do neuronové sítě tak aby výsledná odchylka byla minimální. Po ukončení procesu učení se sítě je již síť použita pro konkrétní vstupní signály pro které síť generuje příslušné výstupní signály.

Obsahem tohoto článku bude seznámení se se základními neuronovými sítěmi a některými algoritmy a pravidly pro učení se sítě. Dále bude popsán způsob implementace neuronových sítí v prostředí Matlabu. Jako konkrétní aplikace neuronových sítí zde bude popsáno použití sítí pro predikci a detekci poruch signálů.

2. Neuronová síť - základní pojmy

V rozsahu tohoto článku se budeme zabývat pouze jednou třídou neuronových sítí, tzv. vícevrstevných perceptronových sítí (Multi-Layer Perceptron networks – MLP networks).

Elementární neuron je tvořen konečným počtem vstupů x_i , aktivační funkcí a_i , přenosovou funkcí f_i a jedním výstupem y_i . Každý vstup neuronu může být modifikován prostřednictvím váhy vstupu w_{ij} , která reprezentuje možnost působení konkrétního vstupu na výstup neuronu. Výpočty vah vstupů neuronů představují hlavní část učících algoritmů sítí. Počáteční nastavení vah je buď provedeno automaticky na určité výchozí hodnoty nebo na konkrétní hodnoty zadané uživatelem.



Obr.1 Elementární neuron

- x_i vstupy neuronu
- y_i výstup neuronu
- a_i aktivační funkce
- f_i přenosová funkce
- w_{ji} váhy jednotlivých vstupů

Každý neuron transformuje vstupní hodnoty alespoň dvěma funkcemi :

Aktivační funkce

agreguje hodnoty vstupů a posouvá agregovanou hodnotu vzhledem k určitému aktivačnímu prahu. Tato funkce je zpravidla lineární :

$$a_i(k) = \sum_{j=1}^n w_{ij}(k) \cdot x_{ij}(k) + x_{i0}$$

Přenosová funkce :

převádí hodnotu aktivační funkce do hodnoty výstupu neuronu. Zpravidla se používají tyto přenosové funkce :

- lineární

$$y_i(k) = K \cdot a_i(k)$$

- skoková

$$y_i(k) = 1, a_i(k) \geq h1$$

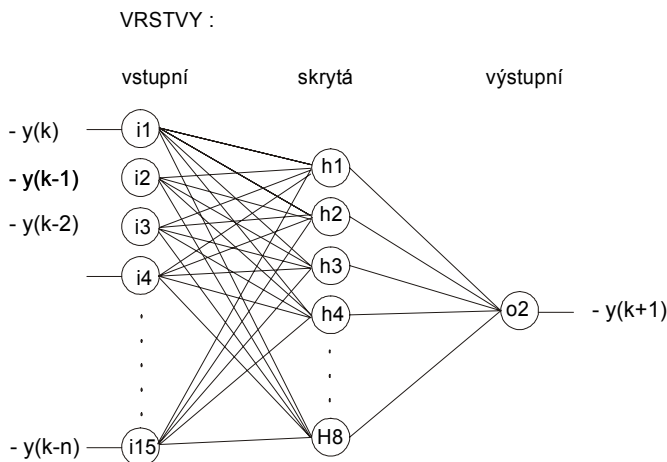
$$y_i(k) = 0, a_i(k) \leq h1$$

- sigmoidální

$$y_i(k) = 1/(1 + \exp(-ba_i(k)))$$

Konkrétním propojením vstupů a výstupů více neuronů vzniká neuronová síť. Neuronová síť je charakterizována třemi hlavními vlastnostmi. První vlastností je topologie sítě, která určuje vlastní propojení jednotlivých neuronů sítě. Dalšími vlastnostmi jsou typ přenosové funkce sítě a metoda učení se sítě.

Neuronová síť má také určitý počet vrstev. Na obr. 2 je zobrazena síť obsahující tři vrstvy - vstupní, skrytou a výstupní. Vstupní a výstupní vrstvy jsou určeny počtem a typem vstupních a výstupních proměnných modelovaného systému. Počet neuronů skryté vrstvy není zcela libovolný a je dán typem sítě a aplikací sítě. Např. velký počet neuronů urychluje dobu učení se sítě, ovšem znesnadňuje testování sítě.



Obr.2 Neuronová síť

3. Proces učení se sítě

Proces učení sítě představuje ve většině případů ladění vah vstupů neuronů. Jen v ojedinělých případech se uvažuje o změně topologie sítě. Procedury nastavování vah v sobě obsahují jednak určitou strategii a jednak numerické postupy vyjádřené matematickými vztahy. Základ pro algoritmy učení se sítí poskytují dvě pravidla a to jsou **Hebbovo pravidlo** a **Delta pravidlo**.

Hebbovo pravidlo :

$$\Delta w_{ij}(k + 1) = \eta \cdot a_i(k) \cdot y_j(k)$$

Delta pravidlo:

$$\Delta w_{ij}(k + 1) = \eta \cdot (s_i(k) - a_i(k)) \cdot y_j(k)$$

kde

$\Delta w_{ij}(k+1)$ je změna váhy $w_{ij}(k)$.

Předpokládá se korekce $w_{ij}(k+1) = w_{ij}(k) + \Delta w_{ij}(k+1)$, kde

$a_i(k)$ představuje aktivační funkci a i -tém neuronu

$s_i(k)$ představuje vzor na který je i -tý neuron
trénován

η konstanta určující rychlost učení se sítě

Dalším algoritmem pro učení se sítí je tzv. "Back Propagation", který je založen na postupné minimalizaci kvadrátu odchylky gradientovou metodou (Detaily např. ve zdrojích [1], [2], [3]).

4. Implementace neuronových sítí

Jednou ze snadno dostupných možností pro práci s neuronovými sítěmi se jeví využití systému Matlab-Simulink a jeho Neural Network Toolbox. Tento toolbox umožňuje implementaci několika typů sítí a různých algoritmů učení se sítě.

V Simulinku je vytvořeno blokové schéma systému, kde je možno nastavit základní parametry neuronové sítě. Vlastní proces učení se sítě probíhá na úrovni Matlabu. Proces učení se sítě je realizován pomocí funkcí pro inicializaci sítě (`initff`), simulaci běhu sítě (`simuff`), trénování sítě algoritmem back propagation (`trainbp`).

Na obr. 3 je blokové schéma systému s neuronovou sítí vytvořeného v prostředí Simulink.

Obr. 3 Blokové schéma neuronové sítě určené pro predikci signálů


5. Využití neuronových sítí pro predikci a detekci poruch signálů

Konkrétní aplikací neuronových sítí implementovaných v prostředí Matlabu je využití těchto sítí pro predikci a detekci poruch signálů. Tento systém nachází uplatnění tam kde je nutné testovat signály zda se v nich nevyskytují chyby, které mohou vzniknout při snímání nebo přenosu signálů, další využití je u diagnostických systémů, kde výstupní signál zařízení má svůj konkrétní tvar a při určitých poruchách zařízení se toto projeví ve výstupním (např. akustickém) signálu.

Úkolem neuronové sítě je detekovat chyby v signálu a na základě jejich struktury tyto chyby jednoznačně rozpoznat. Využití neuronové sítě pro rozpoznávání chyb v signálech přináší mnohem přesnější určení konkrétních chyb než např. při klasické frekvenční analýze signálu.

Princip detekce poruch pomocí predikce průběhu signálu je následující: Neuronová síť provádí predikci průběhu vstupního signálu vždy z několika předcházejících vzorků signálu. Vzorek signálu $y(k+1)$ (resp. $y(k+m)$) je predikován např. z pěti předcházejících vzorků tedy ze vzorků $y(k)$, $y(k-1)$, $y(k-2)$, $y(k-3)$, $y(k-4)$. Na první pohled by se mohlo zdát, že kvalita predikce roste z délkou zpracovávané "historie" signálu. Ovšem není tomu tak a je třeba pro každý signál najít optimální n – délku historie.

Na druhé straně je však téměř jisté, že s rostoucí délkou predikce (m) se kvalita predikovaného signálu zhoršuje.



Obr 4. Predikce k -tého vzorku signálu z n předcházejících vzorků

Prvním krokem musí být samozřejmě proces učení sítě, kdy je na vstup sítě přiváděna posloupnost tzv. „učebních párů“. Prvním členem páru je n -tice vzorků $y(k)$, ..., $y(k-n+1)$, druhým členem páru je hodnota $y(k+1)$ (rep. $y(k+m)$) učeného signálu.. Na obr. 3. je naznačeno zpracování učebních párů, kdy odezva sítě (tj. $y^*(k+1)$, (resp. $y^*(k+m)$) na vložený vstupní pár je porovnávána se skutečnou hodnotou signálu $y(k+1)$, (resp. $y(k+m)$) průběhem signálu a na základě zjištěných rozdílů se provádí korekce vah vstupů jednotlivých neuronů. Proces učení končí v okamžiku dosažení chyby (rozdílu signálů) předem zadané uživatelem. Poté je již "naučená" síť provozována v pracovním režimu, kdy je na vstup sítě přiváděn reálný signál obsahující chyby. Protože síť byla

naučená na bezchybný signál, bude zde každá chyba patrná protože průběh predikovaného vzorku bude odlišný od průběhu vzorku signálu s chybou. Každý tento rozdíl se projeví na výstupu sítě, kde je vzájemně porovnáván signál vstupní a signál predikovaný. Program využívající inicializačních, simulačních a trénovacích funkcí prostředí Matlab/Simulink umožňuje vypisovat jak okamžité, tak i celkové chyby signálu. Na obr. 3 je zřejmé blokové schéma systému pro detekci poruch signálu jenž je predikován z pěti předchozích vzorků.

Prvním konkrétním příkladem je rozpoznávání chyb v čistě sinusovém signálu ve kterém jsou simulovány chyby výpadku několika vzorků signálu. Síť je tedy nejprve naučena na bezchybný průběh signálu (v tomto případě 1000 vzorků) a dále je na vstup sítě přiváděn signál obsahující chyby (jako příklad byla zvolena chyba cyklického výpadku několika vzorků signálu). Průběh tohoto signálu je zřejmý z obr. 5 kde je zobrazen jednak průběh predikovaného signálu a jednak průběh chybového vstupního signálu. V grafu je zároveň zobrazována i okamžitá chyba signálu, zde jsou jednotlivé chybné vzorky jednoznačně zřejmé. Výstupem neuronové sítě je tedy kromě okamžité chyby signálu také celková chyba jejíž hodnota je pro různé typy chyb odlišná. Na základě testování několika chybových signálů s různými chybami lze tedy stanovit konkrétní hodnoty nebo intervaly celkové chyby odpovídající konkrétním chybám, takto lze tedy detekovat nejen to že signál obsahuje chyby, ale lze určit i o jakou chybu se jedná. Je tedy ovšem nutné předem provést testování všech uvažovaných chybových signálů. Je jasné že v určitých případech bude docházet k překrývání se typů chyb proto je nutné vždy předem provést rozdělení chyb a jednoznačné přiřazení celkové chyby ke konkrétnímu chybovému signálu. Je tedy nutné přesně znát strukturu uvažovaných chyb která se určuje z možného reálného výskytu chyb a tyto signály otestovat neuronovou sítí a zjistit do jaké míry je síť schopna jednotlivé chyby rozlišit.

Obr. 5 Detekce poruch v sinusovém signálu (poruchy = výpadky vzorků signálu)


Struktura použité neuronové sítě : vstupní vrstva (FL) - 9 tansig neuronů, skrytá vrstva (SL) - 15 tansig neuronů, výstupní vrstva (OL) - 1 purelin neuron, počet trénovacích vektorů (TV) - 1000, velikost povolené chyby (Err) - 0,0001 rychlost učení se sítě (LR) - 0,0005, počet epoch (E) - 5000.

Dále je uveden příklad chyby která se projevuje limitací špiček sinusového signálu, na obr.6 je průběh vstupního reálného signálu a na obr. 7 je průběh chybového signálu vypočteného jako rozdíl vstupního signálu a predikovaného signálu. Na průběhu chybového signálu jsou jednoznačně patrná místa výskytu jednotlivých chyb. Síť je nejprve neučena na bezchybný průběh signálu se stejnými parametry jako v předcházejícím případě (obr. 5)

Obr. 6 Reálný signál obsahující chyby typu limitace špiček

Obr. 7 Chybový signál vypočtený jako rozdíl skutečného a predikovaného signálu

Dalším příkladem je detekce výskytu chyby výpadku vzorků v reálném signálu získaném při tenzometrických měřeních. Na obr. 8 je vstupní signál a na obr. 9 signál chybový, kde je opět jednoznačně zřejmé místo výskytu poruchy (chybový signál je 20 x zvětšený).



Obr. 8 Reálný signál obsahující chyby typu výpadky vzorků (vlevo) a průběh signálu predikovaného neuronovou sítí (vpravo)

Struktura neuronové sítě : vstupní vrstva (FL) - 26 tansig neuronů, skrytá vrstva (SL) - 50 tansig neuronů, výstupní vrstva (OL) - 1 purelin neuron, počet trénovacích vektorů (TV) - 1000, velikost povolené chyby (Err) - 0,001, rychlost učení se sítě (LR) - 0,0005, počet epoch (E) - 5000.

Obr. 9 Chybový signál vypočtený jako rozdíl skutečného a predikovaného signálu

Závěr

Hlavním cílem tohoto článku bylo popsat možnosti aplikace neuronových sítí pro detekce poruch signálů. Pro aplikaci na libovolný typ signálu s různými typy chyb je vždy

nejprve nutné síť "naučit" na bezchybný signál a dále síť otestovat se všemi uvažovanými typy chyb a provést jednoznačné přiřazení chybového signálu ke konkrétnímu typu chyby. S jednou sítí však vystačíme pouze v nejjednodušších případech (eventuálně pro jedinou poruchu). V případech složitějších, s možností výskytu několika poruch naráz, je nutno pracovat s několika sítěmi (pro každou poruchu minimálně jedna síť) a často je nutno programové prostředky doplňovat speciálními teoretickými konstrukcemi, viz: např. [4]. Mnohdy je jedнокroková predikce pomocí MLP sítí velmi optimistická (silná korelace na hodnotu $y(k)$) a je nutno ji doplnit případy vícečrokových predikcí. Mnohdy ani to nestačí a pro opravdu složité signály je nutno využít sítí s radiální bázovou funkcí (RBF), jak bylo ukázáno např. v práci [7], anebo aplikovat některý ze speciálních typů sítí (např. z rodiny ART – detaily ve zdroji [2]).

Aplikace neuronových sítí v diagnostice je v současné době velmi častá [5], [6] a obtojí ve srovnání s klasickými i neklasickými diagnostickými metodami [8], [9],[10].

Lektoroval: Prof. Ing. Jiří Bíla, DrSc.

Předloženo: v prosinci 1999.

Literatura

- [1] Bíla, J. : Umělá inteligence a neuronové sítě v aplikacích. (2. přepracované vydání). Vydavatelství ČVUT, Praha 1998.
- [2] Šnorek, M. a Jiřina, M.: Neuronové sítě a neuropočítače. ČVUT, Praha, 1996.
- [3] Drábek, V. : Spolehlivost a diagnostika. SNTL, Brno 1983
- [4] Bíla, J. and Kořan, L.: Application of Matroids in Fault Detection. In: Proc. Of 12th Int. Conference „Process Control 99“, High Tatras, S.R., Vol. 1., 1999: pp. 78-82.
- [5] Bíla, J., Kreild, M., Houfek, P- and Koran, L.: Neural Networks in Ultrasonic Testing of Thin Walled Welded Constructions used in Aerospace Industry. In: Proc. Of 5th Int. Conference on Sof Computing – MENDEL 99, Brno, C.R., 1999: pp. 325-328.
- [6] Kreidl, M. : Diagnostické systémy. Vydavatelství ČVUT, Praha 1995
- [7] Vitkaj, J.: Analysis of Chaotic Signals by means of Nonlinear Methods. In: Proc. Of 4th Int. Conf. on Soft Computing, Brno, C.R., 1998: pp. 296-299.
- [8] Lánský, M. : Teorie automatizovaných diagnostických systémů v dopravě a spojích. Nadas, Praha 1990
- [9] Natke, H.G. : Einführung in Theorie und Praxis der Zeitreihenanalyse und Modalanalyse. Vieweg, Wiesbaden 1983
- [10] Sýkora, J. : Diagnostika telekomunikačních zařízení. Vydavatelství ČVUT, Praha 1991

Resumé

APLIKACE NEURONOVÝCH SÍTÍ PRO DETEKCI PORUCH SIGNÁLŮ

Michal MUSIL

Příspěvek se zabývá využitím neuronových sítí v oblastech predikce signálů a detekce poruch signálů. Je zde také popisována teorie principu algoritmů pro učení se neuronových sítí a dále implementace neuronových sítí v prostředí programového systému Matlab a Simulink.

Summary

THE APPLICATION NEURAL NETWORKS FOR DETECTION DISTURBANCES SIGNAL

Michal MUSIL

The paper deals with under-used to be utilise neural networks in area predicate signal and detection disturbances signal. Is here also state theory tenet algorithm for study neural networks and further implementation neural networks in world programmatic system Matlab and Simulink.

Zusammenfassung

DIE APPLIKATION DER NEURONNETZE FÜR NACHWEISE DEFEKTEN SIGNALE

Michal MUSIL

Der Beitrag beschäftigt sich mit die Verwendung der Neuronnetze im Bereich der Prädikat der Signale und Nachweise Deffekten Signale. Im Beitrag wird auch die Theorie des Prinzipes der Algorithmus für Lernen der Neuronnetze und weiter Implementanz der Neuronnetze in Milieu des Programmsystems Matlab und Simulink beschrieben.