

文章编号: 1000-8152(2000)02-0189-04

189-192

前馈网的知识扩充及故障恢复

石 俊

(北方方正集团·北京, 100871) (华中理工大学机械学院·武汉·430074)

陈幼平 ✓ TP18

Peter Wai-tat Tse

(香港城市大学·香港)

摘要: 针对前馈网扩充性差的问题, 提出了一种知识扩充方法, 在维持原有网络结构不变的基础上, 通过添加一个新的子网, 达到既保存现有训练结果, 又可以学习新知识的目的。同时, 本文对神经网络的故障恢复策略进行了研究, 提出了相应的补偿算法, 最后通过仿真实验对算法的有效性进行了验证。

关键词: 前馈网; 学习; 故障补偿

文献标识码: A

知识扩充 故障恢复 神经网络

Knowledge Extension and Fault Recovery of Feed-Forward Neural Networks

SHI Jun

(School of Mechanical Science and Engineering, Founder Group of Peking University·Beijing·100871, P. R. China)

CHEN Youping

(Huazhong University of Science and Technology·Wuhan, 430074, P. R. China)

Peter Wai-tat Tse

(City University of Hongkong·Hongkong)

Abstract: Aiming at the problem of poor extensibility of feed-forward neural networks, a knowledge extension method is proposed in this paper. Preserving the original neural networks, we can both retain existing training result and learn new knowledge by adding a new subnet. Simultaneously, the strategy of fault recovery of neural networks is studied and a fault compensation algorithm is given. The effectiveness of proposed algorithms is verified by numerical simulations.

Key words: FNN; learning; fault compensation

1 引言(Introduction)

前馈网与反馈网或自组织网络相比, 其特点在于算法思想简明易懂, 缺点就是扩充性极差。当要扩充新知识时, 往往需要对整个网络增加神经元重新训练, 而不能保存现有的训练结果。为了使前馈网更具有生命力, 有必要研究扩充前馈网知识的算法。另外, 硬件实现的神经网络在应用中, 不可避免地发生故障, 并导致对某些样本进行错误映射。如果对故障单元进行直接修复不现实, 则要丢弃故障单元后对网络重新进行训练。但是普通训练方法不能保留正确映射的那些样本, 学习过程长, 对网络参数的修改范围很大。因此对故障进行快速恢复是神经网络深入应用的保证。本文的提出正是着眼于以下两个问题:

1) 在扩充知识时, 尽量维持原有的知识及网络

结构, 避免全局范围的参数修改;

2) 当神经网络固化成硬件芯片并在工作中出现故障后, 尽快恢复其功能。

2 网络构建方法 (Networks construction method)

无论是知识的扩充还是故障的恢复, 其基本思想是一致的。前者要求在不影响原有学习样本的前提下, 对那些没学习过的样本进行小范围内的学习; 后者要求对错误映射的样本进行故障补偿, 而不影响其余正确映射的样本。

2.1 前馈网的知识扩充 (Knowledge extension of FNN)

设原有网络的 m 个学习样本分别为 $(x_1, y_1), (x_2, y_2), \dots, (x_m, y_m)$ 。现要增加 $(n - m)$ 个学习样本 $(x_{m+1}, y_{m+1}), (x_{m+2}, y_{m+2}), \dots, (x_n, y_n)$ 。为不影响

原有的网络,这时提出新增一个网络来学习新的样本,并通过对两个网络的输出进行组合,达到知识扩充的目的.有两种网络组合方法,一种是对输出层的输入权和进行组合,另一种是直接对输出层的输出值进行组合.两种网络构建方法分别如下.

1) 对输出层的输入权和进行组合.




图1 网络构建方法一

Fig. 1 Networks construction method 1

如图1所示,原有网络与新增网络公用一个输入层和输出层,输出层的输入是两个网络的隐层输出和.设输出层传递函数为 $f(\cdot)$,且存在反函数 $f^{-1}(\cdot)$;原有隐层 H_o 的输出为 $H_o(\cdot)$,新增隐层 H_n 的输出为 $H_n(\cdot)$.为不影响原来的学习样本,新增网络必须满足如下约束条件:

- ① $H_n(x_i) = 0$, 对于 $1 \leq i \leq m$;
- ② $H_n(x_i) = f^{-1}(y_i) - H_o(x_i)$, 对于 $m+1 \leq i \leq n$.




图2 网络构建方法二

Fig. 2 Networks construction method 2

2) 直接对两个网络的输出值进行组合.

与上述方法的区别是新增网络有自己的输出层,整个网络的输出是原有网络的输出与新增网络的输出矢量和,如图2所示.设原有输出层的输出为 $f_o(\cdot)$,新增输出层的输出为 $f_n(\cdot)$.为不影响原来的学习样本,新增网络必须满足如下约束条件:

- ① $f_n(x_i) = 0$, 对于 $1 \leq i \leq m$;
- ② $f_n(x_i) = y_i - f_o(x_i)$, 对于 $m+1 \leq i \leq n$.

对两种构建方法的解释如下:第一个条件保证了新网对旧样本的影响为零;第二个条件保证新网和旧网共同完成新样本的学习任务.

第一种构建方法,因为不需要输出层而使网络规模较小,但是要求输出层的传递函数可逆.第二种构建方法,网络规模较大,但是对输出层的传递函数没有要求,算法实现简单.

2.2 前馈网的故障恢复(Fault recovery of FNN)

故障恢复的两种网络构建方法与知识扩充情况并无本质区别,只是学习样本不同.设网络的学习样本为 $(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)$,并假设样本 $(x_{m+1}, y_{m+1}), (x_{m+2}, y_{m+2}), \dots, (x_n, y_n)$ 的映射出故障,映射关系变为 $(x_{m+1}, y'_{m+1}), (x_{m+2}, y'_{m+2}), \dots, (x_n, y'_n)$.由于输入层或输出层的故障是不能通过调整网络参数来补偿的,因此这里只考虑对隐层出故障的网络进行重构.

1) 对输出层的输入权和进行组合.

为不影响正确映射的样本,新增网络必须满足如下条件:

- ① $H_n(x_i) = 0$, 对于 $1 \leq i \leq m$;
- ② $H_n(x_i) = f^{-1}(y_i) - f^{-1}(y'_i)$, 对于 $m+1 \leq i \leq n$.

2) 直接对两个网络的输出值进行组合.

为不影响正确映射的样本,新增网络必须满足如下条件:

- ① $f_n(x_i) = 0$, 对于 $1 \leq i \leq m$;
- ② $f_n(x_i) = y_i - y'_i$, 对于 $m+1 \leq i \leq n$.

2.3 两种构建方法的学习算法(Algorithm of both construction methods)

对于第一种构建方法:为了得到新网的结构参数,可以把原输入层、新隐层和一层虚拟的输出层单独作为一个网络进行训练.因为新隐层的权最终要连接到原输出层上,所以虚拟输出层只用来得到新隐层和原输出层之间的权值.虚拟输出层神经元的传递函数采用 $y = x$ 的形式且阈值为0,这样才能保证输出层的输入是新网和旧网的隐层输出的矢量和.

在这种构建方法中,虚拟输出层神经元的传递函数不是sigmoid函数,因而学习算法要重新推导.参照文献[3],对于一个标准三层BP网络,设结构为 $n \times p \times q$.等 k 个样本的希望输出向量为 $Y_k = (y_1, y_2, \dots, y_q)$,实际输出向量为 $C_k = (c_1, c_2, \dots, c_q)$,两者的偏差为 $\delta_j^k = (y_j^k - c_j^k), j = 1, 2, \dots, q$.经推导得知,与标准算法的唯一差异在于输出层的一般化误差不同,标准算法为 $d_i^k = \delta_i^k c_i (1 - c_i)$,现为 $d_i^k = \delta_i^k, i = 1, 2, \dots, q$.其它公式都一致.

对于第二种构建方法:可以把原输入层、新隐层和新输出层单独作为一个网络,采用标准的BP算法进行训练.这种构建方法的学习样本都是新网必须满足的 n 个约束条件.

3 构建方法的改进(Improvement of both construction methods)

如果要新网直接学习这 n 个样本,新网的规模将和原有网络的规模相当,扩充后整个网络规模几乎为原有网络的两倍,这样的网络没有实际用途.为缩小整个网络的规模,本文采用如下方法加以解决.为统一起见,把旧样本或正确映射的样本统称旧样本,而新样本或出故障的样本统称新样本.

用一个单独的鉴别子网来判断输入样本是新样本还是旧样本.只有当输入样本是新样本时,新网才起作用,否则新网的输出为 0,这样就满足了条件①.鉴别子网可以用一个单输出的三层前馈网实现,学习样本为: $(x_i, 0), 1 \leq i \leq m; (x_i, 1), m+1 \leq i \leq n$. 新网的输出在与旧网的输出进行组合之前,先与鉴别子网的输出相乘.构建方法一的改进如图 3 所示,网络构建方法二的改进与上述方法类似.

显然,不管原有网络的规模有多大,鉴别子网的




图 3 网络构建方法一之改进
Fig. 3 Improvement of construction method 1

表 2 原有网络的参数值

Table 2 Parameters of old networks

权号	1~	1~	1~	2~	2~	2~	3~	3~	3~	4~	4~	6~	神经元	4	5	6	7
权值	3.91	-2.60	-0.87	3.91	-2.60	-0.87	3.85	-2.53	-1.09	9.98	-6.55	-3.46	阈值	-5.66	3.63	0.61	-1.08

训练结束时 8 个样本的总误差为 0.01643. 令权 $(1-5)$ 、 $(2-6)$ 和 $(6-7)$ 同时断路,样本 $(101, 1)$ 和 $(110, 1)$ 的映射关系发生故障,对应的输出分别为 0.298035 和 0.326816,而其它样本的映射关系仍成立.为补偿网络故障,先建立一鉴别子网,学习样本为:故障样本 (101) 和 (110) 的期望输出为 1,正确映射的其它样本期望输出为 0,结构取为 $3 \times 2 \times 1$ 的标准前馈网,如图 5 所示,训练结果如表 3 所示.

表 3 鉴别子网的参数值

Table 3 Parameters of discrimination networks

权号	1-8	1~	2~	2~	3~	3~	8-1	9-1	神经元	8	9	10
权值	-13.56	-0.49	8.08	2.88	8.25	2.89	-13.1	15.57	阈值	0.60	-0.7	-8.0

映射关系始终非常简单,实现时规模很小.而且新网只学习数目很少的新样本,规模也很小,从而保证了整个网络的规模不至于增加太大.

4 仿真实验(Numerical simulation)

为验证所提出的网络构建方法有效性,本文做了如下仿真实验.由于图 3 所示的构建方法难度相对较大,而且故障补偿算法比知识扩充算法相对较难,因此,这里讨论用图 3 的构建方法来对网络的隐层故障进行补偿.限于篇幅,此处仅提出三层 BP 网的构造方法.原始网络为标准的三层 BP 网,结构取为 $3 \times 3 \times 1$ (见图 4),解决多数表决问题.多数表决的逻辑关系如表 1,训练结果如表 2.




图 4 原有网络的结构
Fig. 4 Structure of old networks

表 1 多数表决的逻辑关系

Table 1 Logic of majority vote

输入	000	001	010	011	100	101	110	111
输出	0	0	0	1	0	1	1	1




图 5 鉴别子网的结构
Fig. 5 Structure of discrimination networks

对于旧网,映射出错的样本为(101,0.29804)和(110,0.32682),结合新网必须满足的两个条件和 sigmoid 反函数的具体形式,采用近似的方法($x \geq 5$ 时 $y \rightarrow 1$),分别要求输出层神经元的输入权值和为 5.85667 和 5.72262.因而为补偿网络故障,新网的学习样本为




图 6 新网的结构
Fig. 6 Structure of new networks

(101,5.85667)和(110,5.72262).新网取为 $3 \times 1 \times 1$ 的结构,如图 6 所示.采用本文推导出的算法进行学习,经训练收敛后,网络参数值如表 4 所示:

表 4 新网的参数值

Table 4 Parameters of new networks

权号	1-11	2-11	3-11	11-12	神经元	11	12
权值	1.6939	0.0172	1.8189	5.8839	阈值	1.8578	0

最后,去掉新网的神经元 12,把 11 与 12 的权与鉴别子网的输出同时通过乘法器连接到原输出神经元 7 上.按图 3 进行组合,经测试得到各样本的映射关系如表 5 所示.

表 5 网络测试结果

Table 5 Result of networks test

测试样本	(000)	(001)	(010)	(011)	(100)	(101)	(110)	(111)
实际输出	0.00059	0.01024	0.01192	0.99871	0.00299	0.99300	0.99301	0.99957

把表 5 与表 1 进行比较,可以看出,网络的实际输出与期望输出一致,网络的故障得到了补偿.网络规模如下:原有神经元 7 个,连接权共 12 条;现在添加神经元 4 个,连接权 12 条,乘法器一个.可见,新增网络比原有网络的规模小.当原有网络做成芯片不可更改时,采用这种方法能够以最小的代价扩充网络的知识或恢复网络的故障.

5 结束语(Conclusion)

本文提出了基于新增网络的方法,用于对前馈网的知识进行扩充或对网络故障进行补偿.该方法在小范围内进行学习,避免了对网络进行整个范围的重构.由于在本实验中是解决一个简单的多数表问题,原有网络规模不大,而通过本方法构建的网络整体规模相对较大,看不出其优越性.但是当原有网络规模较大时,本方法在减小网络规模和缩短训练时间上的优越性就充分体现出来了.这种网络构建方法还可以用来构造多神经网络的学习算法.

参考文献(References)

- [1] 石俊.容错神经网络理论及开发平台的研究[D].武汉:华中理工大学,1998
- [2] Wei W. Re-constructing high reliable BP-model neural networks[C]. IEEE/INNS Int'l Joint Conf. on Neural Networks, 1993, 142-23
- [3] 王伟. 人工神经网络原理——入门与应用[M]. 北京:北京航空航天大学出版社,1995
- [4] 何永勇,钟秉林,黄仁.基于人工神经网络的旋转机械多故障同时性诊断[J].东南大学学报,1996,26(5):39-43

本文作者简介

石 俊 1973 年生,硕士毕业于华中理工大学机电控制及自动化专业,现就职于北大方正,从事系统集成工作.研究领域:神经网络、分布式数控系统.

陈幼平 本科及硕士毕业于上海交通大学自动控制系统.博士毕业于华中理工大学,曾在英国伯明翰大学做博士后研究.现为华中理工大学教授.研究领域为数控系统,智能制造,专家系统等.

Peter Wai-tat Toe 副教授,香港城市大学机械工程与工程管理学系.研究领域主要为制造系统的故障诊断,神经网络及小波分析等.