

文章编号: 1001-0920(2001)05-0591-05

RBF 神经网络隐层冗余容错方法

许荔秦, 胡东成

(清华大学 自动化系, 北京 100084)

摘 要: 首先提出 RBF 隐层节点冗余结构, 然后分别分析在单故障和普遍故障下的网络特性, 并证明了这种结构可以有效容错, 最后提出了实用的隐层冗余方法, 并经仿真实验证明是可行的。

关键词: 神经网络; 容错; 冗余; 单故障; 普遍故障

中图分类号: TP 18

文献标识码: A

Hidden-layer Redundancy Method of RBF Neural Networks

XU Li-qin, HU Dong-cheng

(Department of Automation, Tsinghua University, Beijing 100084, China)

Abstract: A hidden-layer neuron redundancy architecture of RBF network is presented. Performances of the network are analyzed under both single-fault and universal faults. The performance of the network under faults can be improved significantly with this redundancy architecture. Finally, a practical method of redundancy of hidden-layer neurons to gain fault tolerance is presented. Simulation results show the validity of the method.

Key words: neural network; fault-tolerance; redundancy; single-fault; universal faults

1 引 言

近年来, 多层前向神经网络的容错性引起了人们的重视, 不少文献已做过这方面的研究^[1~7]。但这些研究所针对的神经网络都是多层感知器(MLP), 即通常所说的 BP 网络。从研究方法上看, 提高 MLP 的容错性主要有以下两种方法: 1) 对 MLP 进行结构冗余; 2) 改进 MLP 的学习算法。文献[1~3]通过对传统的学习算法进行改进来提高容错性。但这种方法将以牺牲大量的学习时间为代价; 而通过对 MLP 结构进行冗余处理来提高容错性, 则可避免这样的限制。文献[4, 5]应用神经网络隐层冗余的方法, 提出输出层为硬限幅函数的神经网络对单故

障的容错方法; 文献[6]则进一步对这种方法做了改进。

径向基(RBF)神经网络与 MLP 相比, 具有学习速度快的优点, 但对 RBF 神经网络的容错性进行分析和设计的研究则很少。在实际应用的神经网络中, 虽然绝大多数故障是单故障, 但理论上它仍是一个权值短路、节点短路等硬故障和权值漂移等软故障普遍存在的系统。因此, 讨论 RBF 神经网络存在普遍故障时的容错和性能是十分必要的。本文首先提出 RBF 的隐层节点冗余容错结构, 然后分别讨论这种冗余结构在单故障和普遍故障下的有效性, 最后提出了实用的 RBF 冗余容错方法。

收稿日期: 2000-06-07; 修回日期: 2000-08-15

作者简介: 许荔秦(1973—), 男, 福建莆田人, 博士生, 从事人工神经网络的鲁棒性分析与容错性设计研究; 胡东成(1946—), 男, 江苏常州人, 副校长, 教授, 博士生导师, 从事自动测试、故障诊断与可靠性研究。

2 隐层神经元冗余结构

RBF 神经网络的第 2 层多采用线性函数, 用 $w_{ij}^{(n)}$ 表示连接第 $n-1$ 层第 j 个神经元和第 n 层第 i 个神经元的权值 (包括偏置阈值), 用 $o_i^{(n)}$ 表示第 n 层第 i 个神经元的输出, 则有

$$y_i = \sum_{j=1}^{N_1} (w_{ij}^{(2)} o_j^{(1)}) \quad (1)$$

其中, y_i 为第 i 个输出层神经元的输出, N_1 为隐层神经元数目。

RBF 神经网络中最常见的故障为权值连接断路和神经元损坏, 而在比较可靠的网络中, 单故障占绝大多数, 因此在通常情况下可只考虑这几种故障的单故障情形, 以便简化处理。

理论上更普遍的情况是各种故障同时以一定概率发生, 我们称之为普遍故障。在硬件实现中权值往往会发生偏移 (称为软故障), 用相对误差 Δ 表示; 对于权值连接断路故障, 可用权值 $s-a-0$ 表示。如果分别用随机变量 Δ 和 X 表示权值偏移以及权值 $s-a-0$ 故障的分布, 则权值的实际分布可用随机变量 $w_{ij}^{(n)} = W_{ij}^{(n)} (1 + \Delta)X$ 表示, 其中 $W_{ij}^{(n)}$ 为标量。对于神经元损坏, 主要表现为神经元输出为正电源或负电源电位, 因此可用神经元 $s-a-1$ 或 $s-a-(-1)$ 表示, 用随机变量 $o_i^{(n)} = Z(O_i^{(n)}) = \{-1, O_i^{(n)}, 1\}$ 表示其分布。输出层单元故障是非常严重的故障, 它将严重影响网络输出, 本文对此不予讨论。一般说, 网络实现中各故障无关, 因此各 Δ, X 和 Z 独立分布, 显然各 $w_{ij}^{(2)}$ 和 $o_i^{(1)}$ 独立分布。

对于网络故障的容错, 隐层神经元冗余是一种很好的方法。文献[4, 5] 提出采用对整组隐层单元冗余以对MLP 识别器中单故障完全容错的方法, 其缺点是冗余数太大而不实用。文献[6] 提出一种新的冗余方法, 对单个隐层神经元进行冗余以减小冗余单元的成本。本文则将这种冗余方法推广到一般的单隐层前向神经网络, 其冗余结构如图 1 所示。

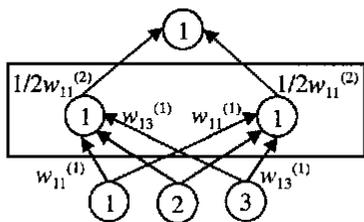


图 1 隐层神经元冗余结构

对原网络各隐层单元分别冗余, 第 i 个隐层单

元冗余 n_i 组。隐层单元组包括与某个隐层神经元相连的所有权值, 因而冗余后此隐层单元组中包含 $n_i + 1$ 个隐层神经元。该隐层单元组内与输出层相连的各权值连接为原值 $w_{ij}^{(2)}$ 的 $1/(n_i + 1)$, 与输入层相连的各权值连接及阈值不变。这样的冗余结构能使网络在无故障时保持性能不变, 即输出误差和推广能力等指标均不变。

3 隐层冗余对网络性能的影响

下面对上述网络的冗余结构在故障下对网络的影响进行评估。本文采用故障下输出层单元的输出误差均方差作为衡量网络容错性的标准, 即

$$P_f = \frac{1}{N} \sum_{p=1}^{N_p} E \left[\frac{1}{N_o} \sum_{i=1}^{N_o} (y_i^{(p)} - y_{id}^{(p)})^2 \right]$$

其中 $y_{id}^{(p)}$ 为第 p 个样本在第 i 个输出层神经元的期望输出。

由于比较可靠的网络中占绝大多数的是单故障, 故首先分析网络在单故障情况下的性能, 考虑权值断路及神经元损坏故障, 采用第 2 节中的冗余结构对网络进行冗余处理, 对第 i 个隐层神经元加入 n_i 个冗余单元 ($n_i \geq 0$)。

对冗余之前的原网络, 不妨考虑第 1 个输出节点, 令 y_{1s} 为无故障情况下的输出, y_{1d} 为期望输出, y_{1f} 为故障情况下的输出, 参照图 1 的原网络, 易知

$$y_{1s} = o_1^{(1)} w_{11}^{(2)} + \sum_{i=2}^{N_1} o_i^{(1)} w_{i1}^{(2)} \quad (2)$$

首先考虑权值断路, 不妨设 w_{11} 发生 $s-a-0$ 故障, 则有

$$y_{1f} = \sum_{i=2}^{N_1} o_i^{(1)} w_{i1}^{(2)} \quad (3)$$

设冗余后的输出为 y_{1f} , 记原第 k 个隐层单元的冗余组中第 l 个隐层神经元输出为 o_{kl} , 记连接这个神经元与第 i 个输出神经元的权值为 $w_{ik(l)}$ 。易知冗余后 o_{kl} 和 $w_{ik(l)}$ 不变, 即 $o_{kl} = o_k, w_{ik(l)} = w_{ik}^{(2)}$ 。网络中仍是冗余组中的一个 $w_{11(l)}$ 发生故障, 易知

$$y_{1f} = \frac{n_i}{n_i + 1} o_1^{(1)} w_{11}^{(2)} + \sum_{i=2}^{N_1} o_i^{(1)} w_{i1}^{(2)} \quad (4)$$

则得

$$(y_{1f} - y_{1s})^2 = \frac{1}{(n_i + 1)^2} (y_{1f} - y_{1s})^2 = \frac{1}{(n_i + 1)^2} (o_1^{(1)} w_{11}^{(2)})^2 \quad (5)$$

然后考虑神经元故障, 不妨设 o_1 发生 $s-a-1$ 故障 ($s-a-(-1)$ 时有类似的推导), 则有

$$y_{1f} = w_{11}^{(2)} + \sum_{i=2}^{N_1} o_i^{(1)} w_{1i}^{(2)} \quad (6)$$

冗余后有

$$y_{1f} = \frac{1}{n_i + 1} w_{11}^{(2)} + \frac{n_i}{n_i + 1} o_1^{(1)} w_{11}^{(2)} + \sum_{i=2}^{N_1} o_i^{(1)} w_{1i}^{(2)} \quad (7)$$

易得

$$(y_{1f} - y_{1s})^2 = \frac{1}{(n_i + 1)^2} (y_{1f} - y_{1s})^2 = \frac{1}{(n_i + 1)^2} (1 - o_1^{(1)})^2 (w_{11}^{(2)})^2 \quad (8)$$

对所有的输入样本及输出节点都有式(5)的结论。因此由上述分析可知,在单故障情况下,对第 i 个隐层神经元按第 2 节的冗余结构做 $n_i(n_i - 1)$ 个冗余,将使网络输出误差均方差减小,且输出误差均方差是 n_i 的单调递减函数。

下面对普遍故障下的容错性进行分析。

定理 1 在普遍故障下,对一个隐层神经元按第 2 节的冗余结构做 $n(n - 1)$ 个冗余,将使 RBF 网络输出误差均方差减小,且输出误差均方差是 n 的单调递减函数。输出误差均方差为

$$P_f = \frac{1}{N_p} \sum_{p=1}^{N_p} E \left[\frac{1}{N_o} \sum_{i=1}^{N_o} (y_i^{(p)} - y_{id}^{(p)})^2 \right]$$

证明 对于隐层神经元的输出 $o_j (j = 1, 2, \dots, N_h)$, 有

$$o_j = Z \left[\exp \left[\frac{\sum_{m=1}^{N_1} (X_m - w_{jm}^{(1)})^2}{\sigma^2} \right] \right]$$

而各 w_{jm} 和 Z 独立分布,在不考虑输入误差的情况下 X_m 为常量,因此各 o_j 独立分布。

对第 k 个隐层神经元做 n 个冗余后共有 $n + 1$ 个同组的隐层神经元,记组中第 l 个隐层神经元输出为 $o_{k(l)}$,记连接该神经元与第 i 个输出神经元的权值为 $w_{ik(l)}$ 。易知冗余后 $o_{k(l)}$ 的均值与方差不变,即 $E o_{k(l)} = E o_k, D o_{k(l)} = D o_k$ 。冗余前有 $w_{ik} = W_{ik}(1 + \Delta)X$,冗余后有 $w_{ik(l)} = \frac{1}{n} W_{ik}(1 + \Delta)X$,因此有 $E w_{ik(l)} = \frac{1}{n} E w_{ik}, D w_{ik(l)} = \frac{1}{n^2} D w_{ik}$,且各 $w_{ik(l)}, o_{k(l)}$ 之间相互独立。

首先证明 $n = 1$ 的情况。冗余前有(以下符号中 w_{ij} 均指 $w_{ij}^{(2)}$,即第 2 层的权值)

$$E (y_i - y_{id})^2 = E \left[\sum_{j,k} w_{ij} o_j + w_{ik} o_k - y_{id} \right]^2$$

记 $T = \sum_{j,k} w_{ij} o_j - y_{id}$,则有

$$E (y_i - y_{id})^2 = E T^2 + 2 E T E w_{ik} E o_k + E (w_{ik}^2 o_k^2) \quad (9)$$

冗余后有

$$E (y_i - y_{id})^2 = E \left(\sum_{j,k} w_{ij} o_j + w_{ik(1)} o_{k(1)} + w_{ik(2)} o_{k(2)} - y_{id} \right)^2 = E T^2 + 2 E T E w_{ik} E o_k + \frac{1}{2} E (w_{ik}^2 o_k^2) + \frac{1}{2} (E w_{ik} E o_k)^2 \quad (10)$$

由于 $E (w_{ik}^2 o_k^2) > (E w_{ik} E o_k)^2$,比较式(10)和(11)知冗余后 $E (y_i - y_{id})^2$ 减小。

对于 $n > 2$ 的情况,冗余后有

$$E (y_i - y_{id})^2 = E \left[T + \sum_{l=1}^n w_{ik(l)} o_{k(l)} \right]^2 = E T^2 + 2 E T E w_{ik} E o_k + \frac{1}{n} E (w_{ik}^2 o_k^2) + \frac{n-1}{n} (E w_{ik} E o_k)^2$$

易知冗余后 $E (y_i - y_{id})^2$ 减小,且 $E (y_i - y_{id})^2$ 随 n 的增大而减小。

对所有 $i = 1, 2, \dots, N_1$ 有同样的结论,对所有样本 $p = 1, 2, \dots, N_p$ 也有同样结论,因此命题成立。(证毕)

推论 1 在普遍故障下,对 RBF 网络的每一个隐层神经元 i 按第 2 节的冗余结构分别做 $n_i(n_i - 1)$ 个冗余,将使网络输出误差均方差减小,且输出误差均方差是 n_i 的单调递减函数。

由上述分析可知,按第 2 节的结构对 RBF 网络进行冗余,将使网络的输出误差均方差减小,且对于一个单独的隐层节点而言,冗余数越大,输出误差均方差减小越多,RBF 网络的容错能力越强。

4 实用的隐层神经元冗余方法

由上述结果可知,不同节点的冗余对网络容错性能的提高是不同的。实际应用中,必须在有限的冗余单元内挑选最合适的节点进行冗余。

下面对普遍故障意义下的推导过程进行分析。对第 k 个隐层节点增加一个冗余节点后,对全局故障率的提高为

$$\frac{1}{N_p N_o} \sum_{i,p} \frac{1}{2} [E (w_{ik}^2 o_k^{(p)2}) - (E w_{ik} E o_k^{(p)})^2]$$

由于一般问题中样本数众多,并且考虑到网络对未知样本的推广能力,要具体估算上式的值是很困难

的。我们对上式做如下简化, 假设各 $o_k^{(p)}$ 分布相同, 设其分布为 O , 则有

$$\frac{1}{N_p N_o} \sum_{i,p} \frac{1}{2} [E(w_{ik}^2 o_k^{(p)2}) - (E w_{ik} E o_k^{(p)})^2] =$$

$$\frac{1}{2N_o} \sum_i \{W_{ik}^2 E[(1 + \Delta)XO]^2 -$$

$$W_{ik}^2 [E((1 + \Delta)XO)]^2\} =$$

$$\frac{1}{2N_o} D[(1 + \Delta)XO] \sum_i W_{ik}^2$$

这样便得到一个简便的节点选择原则, 即计算 W_{ik}^2 的大小来决定冗余节点。由推导的式(6)和(9)知, 上述方法同样适用于对单故障的分析。

于是得到一个实用的隐层节点冗余容错方法如下:

- 1) 设最大冗余数为 R , 初始冗余数 $R(0) = 0$, 初始步数 $t = 0$;
- 2) 计算各隐层节点的 W_{ik}^2 , 挑选其中最大的作为冗余节点, 做单模冗余, $R(t) = R(t) + 1$;
- 3) 若冗余数 $R(t) > R$, 则冗余结束; 否则 $t = t + 1$, 转 2)。

这一算法虽然不是最优的冗余节点选择方法, 但却是简便实用的。应用这一算法对 RBF 神经网络进行冗余, 可使网络在单故障及普遍故障情况下的

容错性能同时得到显著增强。

下面用一个仿真实验例子来验证这一算法的可行性。采用一个进行函数逼近的 RBF 网络, 在 $[0, 6]$ 之间逼近函数 $y = \sin(x)$, 网络为单输入、单输出, 采用 $[0, 6]$ 间均匀分布的 61 个数据点作为学习样本。学习得到一个隐层为 9 个节点的 RBF 网络, 学习的目标误差值为 0.01。用 $[0, 6]$ 间随机选取的 100 个数据点作为测试样本对网络进行测试。

分别对网络在无故障、发生权值单故障和发生隐层神经元单故障的 3 种情况进行测试, 分别计算输出误差均方差 E , E_w 和 E_o ; 然后计算普遍故障发生情况下的输出误差均方差 E_a 。各参数如下: 权值的相对偏移量 $\Delta \sim N(0, 0.05)$, $s-a=0$ 的概率 $P\{X=0\} = 0.05$ 。隐层神经元 $s-a=1$ 与 $s-a=(-1)$ 概率相等, 均为 0.05, 即 $P\{Z(O_i) = -1\} = P\{Z(O_i) = 1\} = 0.05$ 。

分别对网络做最大冗余数 $R = 0, 1, 2, 5, 9$ 的冗余处理, 计算各 E, E_w, E_o 和 E_a , 结果如图 2 所示。

由图 2 可以看出, 由于采用了优化选择冗余节点的方法, 使所得到的网络容错能力有了较大的提高。随着冗余数的增加, 网络的容错能力将相应地显著提高。

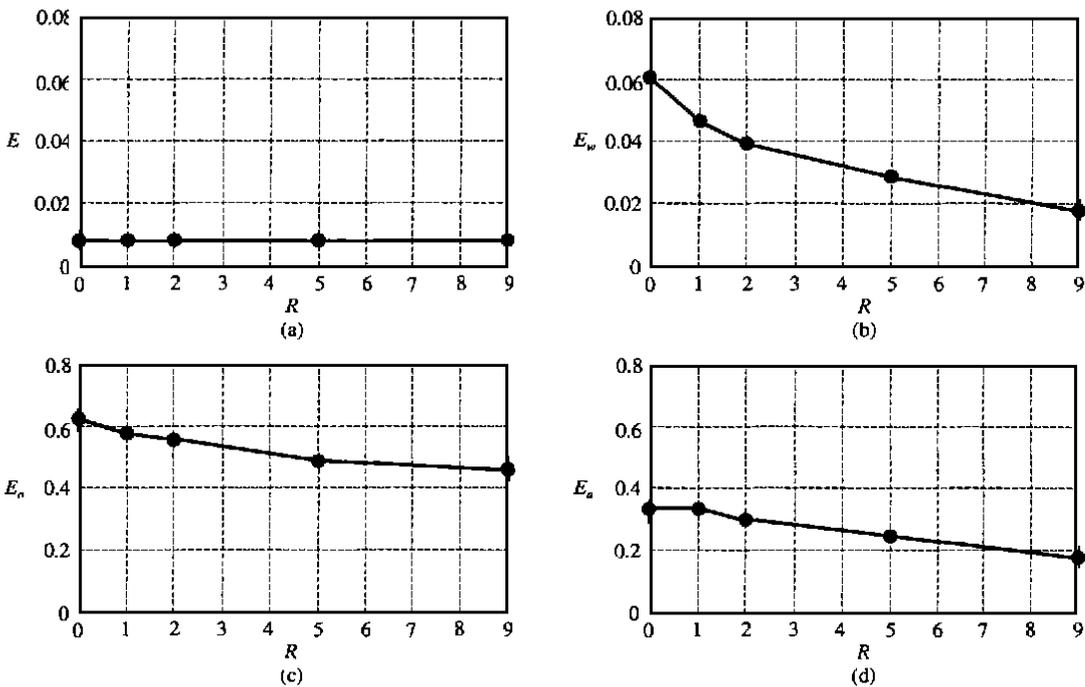


图 2 各种故障情况下冗余数对网络输出均方差的影响

(a) 无故障情况 (b) 权值单故障情况 (c) 隐层节点单故障情况 (d) 普遍故障情况

(下转第 598 页)

5 结 语

本文研究一类线性参数变化时滞系统的 H 控制问题。利用其参数可以实时测量的特点, 基于线性矩阵不等式的解构造出一种依赖于参数的动态输出反馈 H 控制器。该控制器能保证闭环系统渐近稳定, 而且从干扰输入到控制输出的 H 范数不超过预期指标。

参考文献:

[1] Apkarian P, Gahinet P. A convex characterization of gain-scheduled H controllers[J]. IEEE Trans on Autom Contr, 1995, 40(5): 853-864

[2] Apkarian P, Gahinet P, Becker G. Self-scheduled H control of linear parameter-varying systems: A design example[J]. Automatica, 1995, 31(9): 1251-1261.
 [3] Kose IE, Jabbari F, Schmitendorf W E. A direct characterization of L_2 -gain controllers for LPV systems[J]. IEEE Trans on Autom Contr, 1998, 43(9): 1302-1307.
 [4] Kokame H, Kobayashi H, Mori T. Robust performance for linear delay-differential systems with time-varying uncertainties[J]. IEEE Trans on Autom Contr, 1998, 43(2): 223-226.
 [5] Gahinet P, Apkarian P. A linear matrix inequality approach to H control[J]. Int J Rob and Nonl Contr, 1994, 4: 421-448

(上接第 594 页)

5 结 论

隐层神经元冗余是神经网络容错的有效手段之一, 但对 RBF 神经网络容错的研究则很少。而一些研究^[7]曾得出网络的容错能力与隐层节点成反比的结论, 这使得隐层节点冗余方法受到了怀疑。为此, 本文提出一种 RBF 神经网络隐层节点冗余结构, 对 RBF 网络中隐层节点冗余在单故障下和普遍故障下的情形进行分析研究。

本文证明了在所提出的隐层节点冗余结构下, 无论是在单故障情况下还是在普遍故障情况下, RBF 网络的输出均方差均随着冗余数的增加而降低。因此按这种结构对网络的隐层节点进行冗余容错是可行的。本文提出的冗余结构能使网络在无故障时保持误差, 推广能力等性能保持不变, 在发生故障时能有效地减小 RBF 神经网络的输出误差。

本文提出的 RBF 神经网络隐层冗余的方法, 优化了冗余节点的选择, 是一种简便有效的实用方法。仿真实验证明这种方法是有效的。

参考文献:

[1] Philippe Kerlinzin, Philippe Refregier. Theoretical in-

vestigation of the robustness of multilayer perceptrons: Analysis of the linear case and extension to nonlinear networks[J]. IEEE Trans on Neural Networks, 1995, 6(3): 560-571.
 [2] Behnam S A rad, Ahmed El A way. On fault tolerant training of feedforward neural networks [J]. Neural Networks, 1997, 10(3): 539-557.
 [3] Dip ti Deodhare, M V idyasagar, S Sathiya Keerthi. Synthesis of fault-tolerant feedforward neural networks using min max optimization[J]. IEEE Trans on Neural Networks, 1998, 9(5): 891-900.
 [4] D S Phatak, I Koren. Complete and partial fault tolerance of feedforward neural nets [J]. IEEE Trans on Neural Networks, 1995, 6(2): 446-456.
 [5] D S Phatak, I Koren. Fault tolerance of feedforward neural nets for classification tasks[A]. IEEE Proc of the 1992 Int Joint Conf of Neural Networks [C]. Nagoya, 1992. II: 386-391.
 [6] 许荔秦, 胡东成. 一种新的前向神经网络部件冗余容错方法[J]. 电子学报, 2000, 28(5): 99-101.
 [7] 张涛. 人工神经网络容错性分析与设计的理论和应用[D]. 北京: 清华大学自动化系, 1999