

普遍故障下神经网络隐层冗余容错的分析与应用

许荔秦, 胡东成, 高建波
(清华大学自动化系, 北京 100084)

摘要: 隐层神经元冗余是提高神经网络容错性的一个有效的方法, 在神经网络分类器的容错设计中, 这一方法得到了良好的效果, 对单故障可以做到完全容错. 但是这一应用仅仅只能应用于输出层为硬限幅函数的前向网络, 并且只证明了对网络中单故障有效. 在实际应用中, 网络中的各个节点和权值的故障往往是普遍存在的, 因此本文提出了一种隐层冗余结构, 对普遍故障存在下隐层神经元冗余容错方法做以评估, 得出的结论是应用这种隐层神经元冗余结构可以减小网络的全局故障率; 并提出了针对一般前向神经网络的实用的隐层神经元容错方法, 这种方法可以有效地提高网络在普遍故障下的容错能力.

关键词: 神经网络; 容错; 冗余

中图分类号: TP18 文献标识码: A 文章编号: 0372-2112 (2001) 05-0682-04

The Analysis and Application of Redundancy on Hidden2Layer Neurons Under Universal Faults

XU Liliqin, HU Dongcheng, GAO Jianbo
(Department of Automation, Tsinghua University, Beijing 100084, China)

Abstract: Redundancy on hidden2layer neurons has been proven useful in the fault tolerance of neural networks. This approach has been applied successfully in the fault tolerance design of classification neural networks, thus the complete single fault tolerance can be gained. But this approach can only be applied to the feed forward networks which has hard limit activation functions in output layer. And it is proved that this approach is valid only to single fault. There are universal faults of neurons and weights in actual applications, so we evaluated this approach under universal faults in feed forward networks. We proved that the global fault rate is reduced though the redundancy on hidden2layer neurons. And we presented a practical and valid method of redundancy of hidden2layer neurons to gain fault tolerance.

Key words: neural networks; fault tolerance; redundancy

1 引言

多层前向神经网络的容错性在近几年来已得到了很大的重视, 已有不少文献作过这方面的研究^[1-7]. 从研究方法上来看, 提高 MLP 的容错性主要有两种方法: 对 MLP 进行结构冗余, 改进 MLP 的学习算法. 文献[5~7]都是对传统的学习算法进行改进来进行容错. 这种方法可以在不改变网络结构的条件下改善网络的容错性, 缺点是需要牺牲大量的学习时间, 对权值故障进行容错的效果并不好. 而通过对 MLP 结构进行冗余处理提高容错性则可以避免这样的限制. 文献[1, 2]应用神经网络隐层冗余的方法提出了输出层为硬限幅函数的神经网络对单故障的容错方法, 文[3]提出了一些改进.

但是上述隐层冗余方法仅仅适用于输出层为硬限幅函数的神经网络对单故障的容错. 而实际应用中大量神经网络的输出层是可微作用函数, 因此上述方法有很大限制. 实际应用

的神经网络是一个故障普遍存在的系统, 包括权值短路, 节点短路等硬故障与权值漂移等软故障, 因此讨论网络在普遍故障存在下的性能和容错方法才是有意义的.

本文将研究的网络范围扩大到输出层为任意单调函数的前向网络, 研究这类网络在普遍故障下的隐层冗余方法.

2 隐层神经元冗余结构

本文研究网络为应用广泛的单隐层前向网络, 隐层神经元作用函数一般为 Sigmoid. 用 $w_j^{(n)}$ 表示连接第 $n-1$ 层第 j 个神经元与第 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, 用 I_i 表示第 i 个输出层神经元的净输入, 则有:

$$I_i = \sum_{j=1}^{N_1} (w_j^{(2)} o_j^{(1)}) \quad (1)$$

$$y_i^{(2)} = f(I_i) \quad (2)$$

其中 N_1 为隐层神经元数目, $f(\cdot)$ 为输出层作用函数.

MPL 中最常见的故障为权值连接断路与神经元损坏, 同时在硬件实现中权值往往会发生偏移, 对于权值连接断路故障, 可以用权值 $W_{ij}^{(n)} \geq 2\sigma$ 来表示, 对于偏移, 则可以用相对误差 $\$$ 来表示, 分别用随机变量 $\$, X$ 来表示权值偏移以及权值 $\geq 2\sigma$ 故障的分布, 则权值实际的分布可以用随机变量 $W_{ij}^{(n)} = W_{ij}^{(n)}(1 + \$)X$ 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, 因此可以用 $O_i^{(n)} \geq 2\sigma_1$ 或 $\leq -2\sigma_1$ 来表示, 用随机变量

$$o_i^{(n)} = Z(O_i^{(n)}) = \begin{cases} -1, \\ 1 \end{cases}$$

$O_i^{(n)}$ 表示其分布. 同时, 由于输出层单元故障为非常严重的故障, 会严重影响网络输出, 因此不在本文研究范围内. 一般地说, 神经网络实现中各故障是无关的, 因此假设各 $\$, X, Z$ 独立分布, 则显然各 $w_{ij}^{(2)}, o_i^{(1)}$ 独立分布.

对于网络故障的容错, 隐层神经元冗余是一个很好的解决办法. 文[1, 2]中提出了采用对整组隐层单元冗余以取得对识别器中单故障完全容错的方法. 这种结构的缺点是冗余数太大, 因此并不实用. 文[3]中提出了一个改进方法, 对单个神经元进行冗余以减小冗余单元的成本. 在这里把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:

对原网络各隐层单元分别冗余, 第 i 个隐层单元冗余 m_i 组. 隐层单元组包括与某个隐层神经元相连的所有权值(其中包括与输出层相连的权值以及与输入层相连的权值), 这样, 在冗余之后此隐层单元组中即包含 $m_i + 1$ 个隐层神经元. 该隐层单元

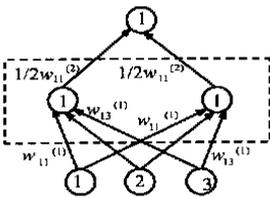


图 1 隐层神经元冗余结构

组内与输出层相连的各权值连接为原值 $W_{ij}^{(2)}$ 的 $\frac{1}{m_i + 1}$, 与输入层相连的各权值连接不变, 各层偏置不变.

这样的冗余结构能够使网络在无故障时保持性能不变, 即输出误差, 推广能力等指标完全不变.

3 普遍故障下隐层冗余对网络性能的影响

对上述网络的冗余结构在故障下对网络的影响作以评估. 对于识别器, 可以用网络在故障情况下的误识率来评估网络的容错能力, 但是, 在一般的前向网络中, 这种评估方法就不适用了. 例如, 对于用于优化, 预测的神经网络, 一般用输出误差的均方差 $P_f = \frac{1}{N_p} \sum_{p=1}^{N_p} E(\frac{1}{N_o} \sum_{o=1}^{N_o} (y_i^{(p)} - y_{id}^{(p)})^2)$ 来对网络进行评估. 因此为统一起见, 采用故障下输出层单元的净输入误差均方差来作为衡量网络容错性的标准, 即 $P_e = \frac{1}{N_{pp=1}} \sum_{p=1}^{N_p} E(\frac{1}{N_o} \sum_{o=1}^{N_o} (I_i^{(p)} - I_{id}^{(p)})^2)$, 其中 $I_i^{(p)}$ 为输出层单元的净输入分布的随机变量, $I_{id}^{(p)}$ 为无故障情况下网络输出层单元的标准净输入.

设输出层单元的作用函数为 $f(x)$, 则有 $y_{id}^{(p)} = f(I_{id}^{(p)})$, 显然, 对于一个训练良好的网络来讲, 可以近似认为 $I_{id}^{(p)}$ 即样本在无故障情况下对输出层单元的净输入.

在文[3]中, 对用于识别器的网络在单故障下的容错性作了分析, 这种结构可以使网络有良好的容错性. 但是, 网络是一个各故障普遍发生的系统, 必须对普遍故障发生的网络进行容错性分析.

定理 1 对一个隐层神经元按上节的冗余结构做 n ($n \in \mathbb{N}$) 个冗余将使网络全局故障率减小, 且全局故障率是 n 的单调递减函数. 全局故障率定义为在发生上节所述故障下网络的输出层净输入误差的均方差, 即 $P_e = \frac{1}{N_{pp=1}} \sum_{p=1}^{N_p} E(\frac{1}{N_o} \sum_{o=1}^{N_o} (I_i^{(p)} - I_{id}^{(p)})^2)$.

证明 首先, 对于隐层神经元的输出 o_j ($j = 1, \dots, N_h$), 有 $o_j = Z(\sum_{m=1}^{N_i} (w_{jm}^{(1)} X_m))$, 而各 w_{jm}, 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 1 个隐层神经元输出为 $o_{k(1)}$, 记连接这个神经元与第 i 个输出神经元的权值为 $w_{ik(1)}$. 易知冗余后 $o_{k(1)}$ 的均值与方差不变, 即 $E o_{k(1)} = E o_k, D o_{k(1)} = D o_k$. 冗余前有 $w_k = W_k(1 + \$)X$, 冗余后有 $w_{k(1)} = \frac{1}{n} W_k(1 + \$)X$, 因此有 $E w_{k(1)} = \frac{1}{n} E w_k, D w_{k(1)} = \frac{1}{n^2} D w_k$, 且各 $w_{k(1)}, o_{k(1)}$ 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 $w_{ij}^{(2)} w_{k(1)}$, 即第二层的权值)

$$E(I_i - I_{id})^2 = E(\sum_{j \times k} w_{ij} o_j + w_k o_k - I_{id})^2, \text{ 记 } T = \sum_{j \times k} w_{ij} o_j - I_{id}, \text{ 则有}$$

$$E(I_i - I_{id})^2 = E T^2 + 2 E T E w_k o_k + E(w_k^2 o_k^2) \quad (3)$$

冗余后有

$$\begin{aligned} E(I_i - I_{id})^2 &= E(\sum_{j \times k} w_{ij} o_j + w_{k(1)} o_{k(1)} + w_{k(2)} o_{k(2)} - I_{id})^2 \\ &= E T^2 + 2 E T (E w_{k(1)} o_{k(1)} + E w_{k(2)} o_{k(2)}) \\ &\quad + E w_{k(1)}^2 o_{k(1)}^2 + E w_{k(2)}^2 o_{k(2)}^2 \\ &\quad + 2 E w_{k(1)} o_{k(1)} E w_{k(2)} o_{k(2)} \\ &= E T^2 + 2 E T E w_k o_k + \frac{1}{2} E(w_k^2 o_k^2) \\ &\quad + \frac{1}{2} (E w_k o_k)^2 \end{aligned} \quad (4)$$

由于 $E(w_k^2 o_k^2) > (E w_k o_k)^2$, 比较式(3), (4)知冗余后 $E(I_i - I_{id})^2$ 减小.

对于 $n \in \mathbb{N}$ 的情况, 冗余后有:

$$\begin{aligned} E(I_i - I_{id})^2 &= E(T + \sum_{l=1}^n w_{k(l)} o_{k(l)})^2 \\ &= E T^2 + 2 E T E w_k o_k + E(\sum_{l=1}^n w_{k(l)} o_{k(l)})^2 \\ &= E T^2 + 2 E T E w_k o_k + \frac{1}{n} E(w_k^2 o_k^2) \end{aligned}$$

$$+ \frac{n-1}{n} (E w_{ik} E o_k)^2$$

同样易知冗余后 $E(I_i - I_{id})^2$ 减小, 且 $E(I_i - I_{id})^2$ 随 n 的增大而减小.

对所有 $i = 1, \dots, N_o$ 有同样的结论, 对所有样本 $p = 1, \dots, N_p$ 也有同样结论, 因此命题成立.

证毕.

推论 1 对一个网络的每一个隐层神经元 i 按上节的冗余结构分别做 n_i ($n_i \in \mathbb{N}$, $E_{n_i} X_i$) 个冗余后将使网络全局故障率减小, 且全局故障率是 n_i 的单调递减函数.

由上面的分析可知按上节的结构对网络进行冗余将使得网络的全局故障率减小, 且对于一个单独的隐层节点来说, 冗余数越大, 全局故障率减小越多. 因此, 按上节的结构对网络进行冗余将使得网络的容错能力增强, 即使得网络在普遍故障发生的情况下性能得到增强.

用一个神经网络预测器来验证以上的结论. 神经网络用于对气体光谱进行分析, 预测气体中 CO 的浓度. 输入为 21 维的一定波段的光谱高度, 输出一维, 即 CO 的浓度, 用单隐层 BP 网络实现, 隐层 4 个神经元, 隐层及输出层作用函数为 sigmoid, 输入与输出向量归一化到 $[-1, 1]$ 内, 总样本数为 699 个, 抽取 350 个作为训练样本, 175 个作为训练中的校验样本, 另 174 个作为测试样本. 训练采用自适应带惯性量的 BP 算法. 采用的计算平台为 MATLAB.

采用以下的故障参数: 设权值的相对偏移量 $S \sim N(0, 0.0102)$, $\Delta a_2 \geq 0$ 的概率 $P\{X = 0\} = 0.05$, 对隐层神经元 $\Delta a_2 \geq 1$ 与 $\Delta a_2 < -1$ 概率相等, 均为 0.05, 即 $P\{Z(O_i) = -1\} = P\{Z(O_i) = 1\} = 0.05$.

对前 n ($0 \leq n \leq 4$) 个隐层神经元分别做单个冗余, 用 1000 次故障仿真实验结果做平均, 分别计算训练样本的全局故障率 $P_{e,p}$ 与输出误差 $P_{f,p}$ 及测试样本的全局故障率 $P_{e,t}$ 与输出误差 $P_{f,t}$:

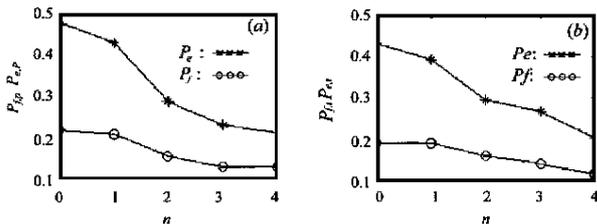


图 2 对前 n ($0 \leq n \leq 4$) 个隐层神经元分别做单个冗余的结果. (a) 训练样本; (b) 测试样本

对所有隐层神经元分别做 n 个冗余, 同样计算 $P_{e,p}$, $P_{f,p}$, $P_{e,t}$ 和 $P_{f,t}$:

由以上结果验证了定理 1 及推论 1 的正确, 即随着冗余单元的增加, 全局故障率递减. 并且对于上述输出层为 Sigmoid 型的网络, 其输出误差的方差 P_f 同样随冗余单元的增加而递减.

4 实用的隐层神经元冗余方法

由上节的结果可知, 对神经网络做前述方法的冗余可以使得网络容错能力增强. 但是从图 2 中可以看到, 不同节点的

冗余对网络容错性能的提高是不一样的, 而在实际应用中, 所能采用的冗余数是有限的, 因此必须在冗余时采用最有效的冗余结构, 即在有限的冗余单元内挑选最合适的节点进行冗余.

由上节的推导过程可知: 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 $\frac{1}{N_p * N_o} E_{i,p} \frac{1}{2}$

$[E(w_{ik}^2 o_k^{(p)^2}) - (E w_{ik} E o_k^{(p)})^2]$, 由于一般问题中样本数众多而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很困难. 对上式作以简化, 假设各 $o_k^{(p)}$ 分布相同, 设其分布为 O , 则有

$$\begin{aligned} & \frac{1}{N_p * N_o} E_{i,p} \frac{1}{2} [E(w_{ik}^2 o_k^{(p)^2}) - E(w_{ik} E o_k^{(p)})^2] \\ &= \frac{1}{2 N_o} E_i \{W_{ik}^2 E[(1+S)XO]^2 - W_{ik}^2 [E((1+S)XO)]^2\} \\ &= \frac{1}{2 N_o} D[(1+S)XO] E_i W_{ik}^2 \end{aligned}$$

这样, 就有了一个很简便的节点选择原则: 计算 $E_i W_{ik}^2$ 的大小来决定冗余节点. 这样可以得到一个简便实用的隐层节点冗余容错方法:

(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 $E_i W_{ik}^2$, 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 $t = t + 1$ 转向 (2).

这一算法不是最优的, 但却是简便实用的. 仍然用上节中的例子做对比实验, 对前 n 个节点进行单模冗余作为对比结果. 设 $R = 4$, 进行上述算法, 为得到对比结果, 在每次冗余结束后计算各 P_f, P_e :

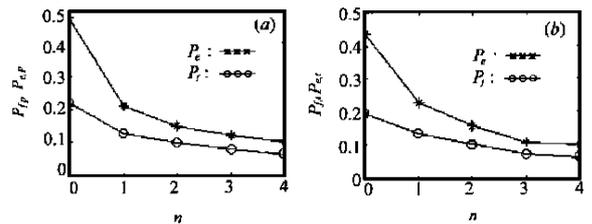


图 3 对所有隐层神经元分别做 n 个冗余的结果. (a) 训练样本; (b) 测试样本

由上面的结果可以看出, 由于采用优化选择冗余节点的方法, 每步冗余后所得到网络容错能力比无选择性地冗余所得到的要好. 由于神经网络硬件实现中节点资源所限, 必须对网络限制冗余节点数, 这种方法可以以较优的结果快速、方便地实现隐层节点冗余, 是一种实用的隐层神经网络冗余方法. 随着冗余数的增加, 网络的容错能力相应地显著提高.

5 结论

隐层神经元冗余是神经网络容错的一个有效手段, 但是在普遍故障下的对网络性能的影响在以前的研究中涉及的不

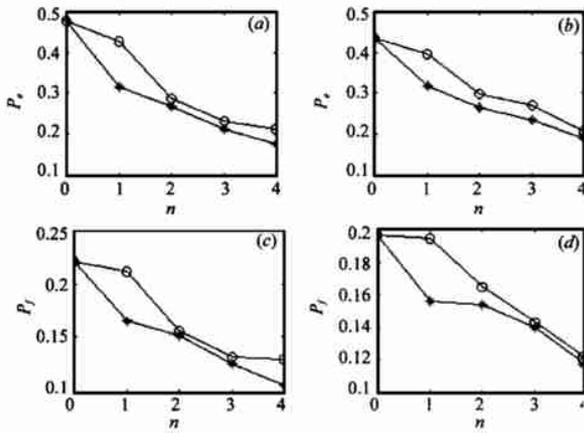


图 4 对前 n 个隐层神经冗余与优化冗余方法的比较。(a) 训练样本的全局故障率; (b) 测试样本的全局故障率; (c) 训练样本的输出误差均方差; (d) 测试样本的输出误差均方差 (优化冗余方法: - * - * - * - ; 对前 n 个隐层神经冗余: - o - o - o -)

多。而一些研究中^[4]曾得出网络的容错能力与隐层节点成反比的结论, 这样的结论使隐层节点冗余方法受到了怀疑。因此本文对隐层节点冗余在普遍故障下的情况进行了分析。

本文证明了在隐层节点冗余结构下, 网络的全局故障率将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。而文[4]得到的结论是基于隐层节点的增加是与原网络中隐层节点无关的, 而并非是某个节点的冗余, 与本文所提出的隐层冗余结构在结构上是不同的。本文提出的冗余结构能够使网络在无故障时保持误差, 推广能力等性能不变, 在发生故障时则能有效地减小全局故障率。

根据理论分析还提出了神经网络隐层冗余的实用方法, 这种方法优化了冗余节点的选择, 是一种简便有效的实用方法。通过仿真实验证明这种方法是有效的。

参考文献:

- [1] D. S. Phatak and I. Koren. Complete and partial fault tolerance of feedforward neural nets [J]. IEEE Trans. on Neural Networks, 1995, 6(2): 446- 456.
- [2] D. S. Phatak and I. Koren. Fault tolerance of feedforward neural nets for classification tasks [J]. IJCNN, 1992: 12386- 391.

- [3] 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.
- [4] 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.
- [5] Philippe Kerlinzin and Philippe Refregier. Theoretical Investigation 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.
- [6] Behnam S. Arad and Ahmed ElAnway. On fault tolerant training of feedforward neural networks [J]. Neural Networks, 1997, 10(3): 539 - 557.
- [7] Dipti Deodhare, M. Vidyasagar and S. Sathiya Keerthi. Synthesis of fault-tolerant feedforward neural networks using minimax optimization [J]. IEEE Trans. on Neural Networks, 1998, 9(5): 891- 900.

作者简介:



许荔秦 1973 年生, 1996 年获清华大学自动化系自动控制专业学士学位, 现为自动化系检测技术与装置专业直读博士研究生。现主要研究方向为人工神经网络的鲁棒性分析与容错性设计。

胡东成 1946 年生, 1970 年毕业于清华大学电机工程系, 留校于自动化系任教。1983 年至 1985 年由国家公派赴西德学习, 后又数次出国访问或合作研究。现为清华大学副校长、教授、博士生导师, 中国自动化学会理事兼教育工作委员会主任委员, 中国电子学会高级会员, 国家教委电子课程教学指导委员。长期从事电子与自动化方面的教学与科研工作, 主要研究方向为自动测试、故障诊断与可靠性。



高建波 1971 年生, 1994 和 1997 年在清华大学分别获得学士学位和硕士学位, 现为清华大学自动化系的博士生。主要从事检测技术和信号处理等领域的研究。