

② 38-45

用神经网络求解 P-t 可诊断模型下的计算机系统诊断问题

Computer System Diagnosis Problem under P-t Diagnosable Model Solved by A Artificial Neural Network

唐万梅**
Tang Wangmei

陈廷槐
Chen Tinghuai

杨晓帆
Yang xianfan

TP206.3

(重庆大学计算机研究所, 重庆, 630044)

A 摘要 系统地研究了如何构造一个 Tank & Hopfield 型神经优化网络来求解计算机系统诊断的 P-t 可诊断模型的诊断问题。模拟实验表明神经网络对初始输入和连接权均具有容错性; 模拟实验得出了电容 C 、电阻 R 和放大系数 K 与网络收敛时间的关系。

关键词 计算机网络 / 神经网络; Tank & Hopfield 型神经优化网络; 计算机系统诊断; P-t 可诊断模型

中国图书资料分类法分类号 TP302.8

PMC 模型

ABSTRACT The problems were systematically studied of how to form a Tank & Hopfield-type neural optimization^[1] network to solve the diagnosis for P-t diagnosable model of computer diagnosis. The simulation seems effective to solve the computer system diagnosis problems by neural networks. The simulation also shows that the neural networks are of the character of fault tolerance to initial input and connection weights, i. e. their slight deviations do not affect the proper functions of the network; the simulation reveals the relations among capacity C , resistance R , gain K and time.

KEYWORDS computer networks / neural network; Tank & Hopfield-type neural optimization network; the computer system diagnosis; the P-t diagnosable model

0 引 言

神经网络是由结构简单, 功能不强的大量相同元件经高度互连而成的大规模动力学系统, 具有丰富的动力学特性。同时, 它具有快速的计算能力, 具有很强的鲁棒性(Robust), 适用于很多研究领域。文献^{***}用神经网络快速有效地求解了计算机系统诊断的三值 PMC 模型

* 收文日期 1993-02-06
博士点9261109资助课题

** 现在重庆师范学院数学系任教

*** Chen Tinghuai et. al. Three-Valued Computer Systems Diagnosis Implemented by Artificial Neural Network. 1992年在日本召开的亚洲测试会议上宣读。

的诊断问题,得出了唯一的诊断结果,其唯一性由文献^[1]保证。

计算机系统诊断的诊断模型有几十种。经典的 PMC 模型及由它发展而得到的 BGM 模型、模2模型等类似地均可以用神经网络来求解。本文主要研究 P-t 可诊断模型,对该模型的研究表明:Tank & Hopfield 型神经优化网络对初始输入和连接权均具有容错性——即它们的微小偏差不会影响网络本身的功能。

1 P-t 可诊断模型^[2]

计算机系统诊断的 PMC 模型是一种比较著名的诊断模型,适用于大多数情况。对 PMC 模型以及由它发展而得到的如 BGM 模型、模2模型等等,实际上是在假设各子系统的故障概率一样的基础上得到的,是一种为了简化处理而作的假设;然而,在实际的系统中,各子系统的故障概率并非都是一样的。例如,大型计算机或者使用太久而又维护不好的机器出错概率较高。因此,引入各子系统的故障概率,诊断时应从所有相容故障模式中挑选总故障概率最高的模式。

假设一个系统 S 由 n 个子系统 $\{V_1, \dots, V_n\}$ 构成,用一个有向图 $G = (V, E)$ 来表示诊断系统 S ,顶点集 V 对应于 S 所有子系统 V_i 构成的集合。 $V_i = 0$, 表示第 i 个子系统无故障; $V_i = 1$, 表示第 i 个子系统发生故障;边集 E 对应于 S 中各子系统之间的相互测试关系集;即有向弧 (V_i, V_j) 表示用 V_i 去测试 V_j , 测试输出 w_{ij} (0 或 1 值), 表示 G 中有向弧上的权。 $w_{ij} = 0$, 说明 V_i 认为 V_j 是正常的; $w_{ij} = 1$, 说明 V_i 认为 V_j 是故障的。因此,系统 S 及症候集 $w = \{w_{ij} = 0$ 或 $w_{ij} = 1, i, j = 1, \dots, n\}$ 可通过一个带权有向图表示,记为 G 。

假设各子系统 $V_i (i = 1, \dots, n)$ 的故障概率一样,就是 PMC 模型。见后页的表。

假设各子系统的故障概率不一样,设每个子系统 V_i 的故障概率为 P_i , 则与 PMC 模型相容的故障集 F 的出现概率为:

$$P_F = \prod_{V_i \in \bar{F}} (1 - P_i) \prod_{V_i \in F} P_i$$

其中 \bar{F} 与 F 中各子系统满足下列关系:

PMC 模型		
V_i	V_j	w_{ij}
0	0	0
0	1	1
1	0	φ
1	1	φ

$\varphi \in \{0, 1\}$ 。

定义: 给定 t 为 $[0, 1]$ 中一实数, P_i 为各子系统 V_i 的故障概率, 则系统 S 是 P-t 可诊断的是指: 对任何一个表示系统 S 的有向图 G , 和实际存在的测试症候集 w , 至多存在一个与 w 相容的故障集 F 使得 $P_F > t$ ^[3]。

2 诊断算法

对于给定的一个 t 可诊断系统 S , 当症候集 w 给定后, 可用 0-1 规划法求出 PMC 模型的诊断结果。即寻找相容故障集 F , 且 $|F| \leq t$, 等价于求解以下的 0-1 规划问题:

$$\begin{aligned} & \min \sum_{i=1}^n V_i \\ & \text{s. t} \\ & \left[\begin{array}{l} w_i = 0 \Leftrightarrow V_i - V_j \geq 0 \\ w_i = 1 \Leftrightarrow V_i + V_j \geq 1 \\ \sum_{i=1}^n V_i \leq t \\ V_i = 0, 1 \end{array} \right] \end{aligned}$$

对于一个给定的P-t可诊断系统S,当给定一个症候集w后,如何求出与w相容的故障集F,满足 $P_F > t$ 且使故障集F出现概率:

$$P_F = \prod_{v_i \in F} (1 - P_i) \prod_{v_i \in F^c} P_i$$

为极大?

将上式变换一下有:

$$\begin{aligned} \log P_F &= \sum_{v_i \in F} \log(1 - P_i) + \sum_{v_i \in F^c} \log P_i \\ &= \sum_{v_i \in F} \log(1 - P_i)(1 - V_i) + \sum_{v_i \in F^c} (\log P_i) V_i \\ &= \sum_{i=1}^n \left(\log \frac{P_i}{1 - P_i} \right) V_i + \sum_{i=1}^n \log(1 - P_i) \end{aligned}$$

此时的问题变为求出一个故障概率最大的相容故障集.由于 P_i 为常数,它等价于求解以下的0-1整数线性规划问题:

$$\begin{aligned} & \max \sum_{i=1}^n \left(\log \frac{P_i}{1 - P_i} \right) V_i \\ & \text{s. t} \\ & \left[\begin{array}{l} w_i = 0 \Leftrightarrow V_i - V_j \geq 0 \\ w_i = 1 \Leftrightarrow V_i + V_j \geq 1 \end{array} \right] \end{aligned}$$

以上约束条件均可一般表示为:

$$\sum_{i=1}^n D_{ij} V_i - B_j \geq 0, \quad j = 1, \dots, m$$

其中 $D_{ij} = 1, 0, -1; B_j = 0, 1; m$ 为总的测试边数.

另加一个约束条件 $P_F > t$,可改写为:

$$\log P_F - \log t > 0$$

或
$$\sum_{i=1}^n \left(\log \frac{P_i}{1 - P_i} \right) V_i + \sum_{i=1}^n \log(1 - P_i) - \log t > 0$$

即
$$- \sum_{i=1}^n \left(\log \frac{1 - P_i}{P_i} \right) V_i + K(t) > 0$$

其中令 $K(t) \equiv \sum_{i=1}^n \log(1 - P_i) - \log t$.此外 $V_i = 0, 1, i = 1, \dots, n$.

因此,上面的问题可变换成下述0-1线性规划问题:

$$(I) \quad \min \sum_{i=1}^n \left(\log \frac{1-P_i}{P_0} \right) V_i$$

满足约束条件：

$$(II) \quad \begin{cases} \sum_{i=1}^m D_{ji} V_i - B_j \geq 0, & j = 1, \dots, m \\ - \sum_{i=1}^n \left(\log \frac{1-P_i}{P_0} \right) V_i + K(t) > 0 \\ V_i = 1, 0; i = 1, \dots, n \end{cases}$$

其中各子系统的故障率 $P_i (i = 1, \dots, n)$ 和 $t \in [0, 1]$ 是已知实数。

至此，对于给定的 P-t 可诊断系统 S，当给定症候集 w 及各子系统的故障概率 P_i 和 t 时，要求出与症候集 w 相容的相容故障集 F 使得 $P_F > t$ ，就等价于求解一个带约束的 0-1 规划问题 (I) 且满足约束条件 (II)。

3 用神经网络求解 P-t 可诊断模型

神经元一般是一多输入 / 单输出的非线性器件，它是神经网络的基本处理单元。如图 1。

V_1, \dots, V_n 分别是来自神经元 U_1, \dots, U_n 来的输入信号； Q_i 是第 i 个神经元的阈值； I_i 为第 i 个神经元的外部输入； T_{ji} 为第 j 个神经元与第 i 个神经元之间的连接权值； V_i 为第 i 个神经元的输出。




图 1 神经元

如何利用 Tank & Hapfield 型神经优化网络来求解第三节所遇到的 0-1 规划问题呢？首先是将带约束优化转化为无约束优化问题，根据文献（见前脚注），然后利用 Tank & Hapfield 型神经优化网络来求解。其优化的能量函数为 E ：

$$E = E_0 + E_1 + E_3$$

其中

$$E_0 = \sum_{i=1}^n \left(\log \frac{1-P_i}{P_i} \right) V_i \quad \text{为总的目标函数；}$$

$$E_1 = \beta \left[\sum_{j=1}^m \left(\sum_{i=1}^n D_{ji} V_i - B_j \right) + F' \left(K(t) - \sum_{i=1}^n \left(\log \frac{1-P_i}{P_i} \right) V_i \right) \right]$$

这里 $\sum_{i=1}^n D_{ji} V_i - B_j \geq 0$ 相对于所有测试症候的约束， $K(t) - \sum_{i=1}^n \left(\log \frac{1-P_i}{P_i} \right) V_i > 0$ 相对于约束 $P_F > t$ 。

$$E_3 = \delta \sum_{i=1}^n V_i (1 - V_i) \quad \text{是为了保证每个 } V_i = 0, 1 (i = 1, \dots, n)；$$

$$F(Z) = \begin{cases} 0 & Z \geq 0 \\ \frac{1}{2} Z^2 & Z < 0 \end{cases}, \quad f'(Z) = \frac{dF}{dZ} = \begin{cases} 0 & Z \geq 0 \\ Z & Z < 0 \end{cases}$$

$$F''(Z) = \begin{cases} 0 & Z > 0 \\ \frac{1}{2} Z^2 & Z \leq 0 \end{cases}, \quad f''(Z) = \frac{dF'}{dZ} = \begin{cases} 0 & Z > 0 \\ Z & Z \leq 0 \end{cases}$$

$F(Z), F'(Z)$ 均称为罚函数。

为了能用 Tank & Hopfield 型神经优化网络^[3] 来求解以及为了保证该网络的稳定性, 必须另加上项 E_2 , 其中 $E_2 = \gamma \sum_{i=1}^n \frac{1}{R_i} \int_0^{V_i} g^{-1}(v) dv$. 这里 $\frac{1}{R_i} = \frac{1}{R} + \sum_{j=1}^n T_{ij}$, R 为第 i 个神经元中与电容 C 并联的电阻; T_{ij} 为第 i 个神经元与第 j 个神经元之间的连接权值; g^{-1} 是第 i 个神经元的输入输出函数 g (这里取每个神经的输入输出函数均为 g) 的逆函数, 其中 $V_i = g(u_i) = \frac{1}{1 + e^{-u_i}}$; β, γ, δ 为优化参数, 所以, 最后要优化的能量函数为 $E = E_0 + E_1 + E_2 + E_3$.

将 E 作为一个适当的 Lyapunov 能量函数, 根据文献^[3] 建立 Tank & Hopfield 型神经优化网络的动力学方程:

$$\begin{aligned} C \frac{du_i}{dt} &= - \frac{\partial E}{\partial V_i} \\ &= - \log \frac{1-P_i}{P_i} - \beta \left[\sum_{j=1}^n D_{ji} f \left(\sum_{k=1}^n D_{jk} V_k - B_j \right) \right. \\ &\quad \left. \left(\log \frac{1-P_i}{P_i} \right) f' \left(K(t) - \sum_{k=1}^n \left(\log \frac{1-P_k}{P_k} \right) V_k \right) \right] - \gamma \frac{u_i}{R_i} - \delta (1 - 2V_i) \\ &= - \log \frac{1-P_i}{P_i} - \delta - \beta \left[\sum_{j=1}^n D_{ji} f \left(\sum_{k=1}^n D_{jk} V_k - B_j \right) \right. \\ &\quad \left. \left(\log \frac{1-P_i}{P_i} \right) f' \left(K(t) - \sum_{k=1}^n \left(\log \frac{1-P_k}{P_k} \right) V_k \right) \right] - \gamma \frac{u_i}{R_i} - 2\delta (1 - 2V_i) \\ &= - \log \frac{1-P_i}{P_i} - \delta_f \left[\sum_{j=1}^n D_{ji} \left(\sum_{k=1}^n D_{jk} V_k - B_j \right) \right. \\ &\quad \left. - \left(\log \frac{1-P_i}{P_i} \right) f' \left(K(t) - \sum_{k=1}^n \left(\log \frac{1-P_k}{P_k} \right) V_k \right) \right] - \gamma \frac{u_i}{R_i} + 2\delta V_i \end{aligned}$$

与 Tank & Hopfield 型神经优化网络的动力学方程 $C \frac{du_i}{dt} = - \frac{\partial E}{\partial V_i}$ 相比较, 得到

$$T_{ij} = \begin{cases} 2\delta & i = j \\ 0 & \text{否则} \end{cases}$$

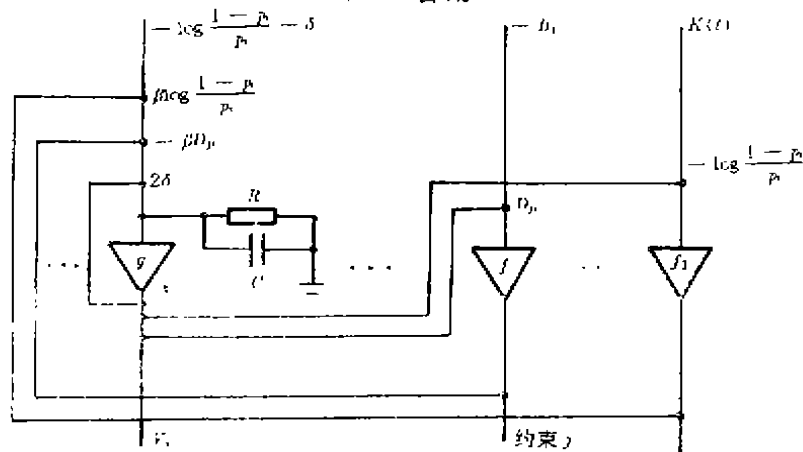


图 2 神经网络图

神经元的输出作为预处理元件(图 2 右边的 f, f' 部分, 即完成惩罚功能) f 的输入, 与典

型的 Tank & Hapfield 型神经优化网络相比较,则得到第 j 个预处理元件 f 与第 i 个神经元之间的连接权为 $-\beta D_{ji}$; f^i 预处理元件与第 i 个神经元之间的连接权值为 $\beta \log \frac{1-P_i}{P_i}$; 第 i 个神经元的外部输入为 $-\log \frac{1-P_i}{P_i} - \delta_i$; 各预处理元件的外部输入分别为 $-B_j$ 和 $K(t)$, 其中

$$K(t) = -\log t + \sum_{i=1}^n \log(1 - P_i), \text{如图 2.}$$

考察图 2 所示网络的稳定性:

$$\begin{aligned} \frac{dE}{dt} &= \sum_{i=1}^n \frac{dE}{dV_i} \cdot \frac{dV_i}{dt} \\ &= \sum_{i=1}^n (-C) \frac{du_i}{dt} \cdot \frac{dV_i}{dt} \\ &= - \sum_{i=1}^n C g^{-1}(V_i) \left(\frac{dV_i}{dt} \right)^2 \\ &\leq 0 \quad (\because g^{-1} \text{ 为单调增函数}) \end{aligned}$$

且

$$\frac{dE}{dt} = 0 \Leftrightarrow \frac{dV_i}{dt} = 0, i = 1, \dots, n$$

根据 Lyapunov 稳定性定理,说明该网络是稳定的,并且网络的平衡点就是对应于 E 的局部极小值点。

4 模拟实验

例: 考察一个具有 5 个结点(子系统)的 P-t 可诊断系统的诊断问题。系统 S 用一个有向图 $G = (U, E)$ 来表示, V 中的每个顶点对应于系统 S 的一个子系统; E 中的每条边对应于各子系统间的相互测试关系,如图 3。同时图中标明了每个顶点(子系统)的故障概率。

症候集 W 表示为图中边上的值;各子系统的故障概率如图中顶点上的值;这里取 $t = 0.1, n = 5$ 。

根据前面的讨论知道,对一个 P-t 可诊断系统要诊断出它的相容故障集 F , 等价于求解以下的 0-1 整数线性规划问题:

$$\min \sum_{i=1}^n \left(\log \frac{1-P_i}{P_i} \right) V_i$$

满足以下约束:




图 3 5 个结点的 P-t 可诊断系统所对应的图 $G(V, E)$

$$\left\{ \begin{array}{l} W_{12} = 0 \Leftrightarrow V_1 - V_2 \geq 0 \\ W_{14} = 0 \Leftrightarrow V_1 - V_4 \geq 0 \\ W_{23} = 0 \Leftrightarrow V_2 - V_3 \geq 0 \\ W_{31} = 0 \Leftrightarrow V_3 + V_1 \geq 0 \\ W_{35} = 0 \Leftrightarrow V_3 - V_5 \geq 0 \\ W_{42} = 0 \Leftrightarrow V_4 + V_2 - 1 \geq 0 \\ W_{43} = 0 \Leftrightarrow V_4 - V_3 \geq 0 \\ W_{51} = 0 \Leftrightarrow V_5 + V_1 - 1 \geq 0 \\ W_{54} = 0 \Leftrightarrow V_5 + V_4 - 1 \geq 0 \\ \sum_{i=1}^n \left(\log \frac{1 - P_i}{P_i} \right) V_i < K(t) \\ V_i = 0, 1, i = 1, \dots, n \end{array} \right.$$

这里 $K(t) = \log t + \sum_{i=1}^n \log(1 - P_i) = \log 2.1384$.

就本例题来说,与症候集 W 相容的故障集有两个:

$$F_1 = \{V_1, V_4\}, \quad F_2 = \{V_1, V_2, V_4\}$$

但是 $P(F_1) > P(F_2)$, 因此,最后求出的相容故障集应是 F_1 . 从后面的模拟实验可以看出,最后求出的相容故障集的确是 F_1 .

对初值的各种不同取法及所依赖的其他优化参数和网络到达收敛的迭代次数的关系简单地列表如下:(其中 $C = 0.01, R = 10$).

优化参数 γ, β, δ, K 与 n 之间的关系

	γ	β	δ	K	到达收敛的迭代次数 n
1° 初值均取 0.05	1	20	20	10	13
2° 初值接近正确解	1	20	20	10	11
3° 初值接近正确解的反	1	20	20	10	17
4° 初值均在 0.50 ± 0.10 范围内随机产生	1	20	20	10	11 ~ 17
5° 初值均在 0.50 ± 0.20 范围内随机产生	1	20	20	10	14 ~ 18
6° 所有连接权 $T_i (i = 1, \dots, n)$ 发生微小偏差 $\varepsilon \in (-0.10, 0.10)$	1	20	20	10	13 ~ 17
7° 只让 g 对应的连接权发生微 小偏差 $\varepsilon \in (-0.10, 0.10)$	1	20	20	10	10 ~ 33
8° 只让 f 对应的连接权发生微 小偏差 $\varepsilon \in (-0.10, 0.10)$	1	20	20	10	13 ~ 23
9° 让所有连接发生偏差 $\varepsilon \in (-0.05, 0.10)$	1	20	20	10	12 ~ 26
10° 让所有连接权发生偏差且左右 两边连接权发生的偏差不同, 但都属于范围 $(-0.05, 0.10)$	1	20	20	10	10 ~ 19

备注: 6° ~ 10° 五种情况的初值都是取 0.50.

4° 和 5° 两种情况说明神经网络对初始输入具有容错, 即输入的微小偏差不会影响网络本身的功能。

6° ~ 10° 五种情况均说明: 神经网络的连接权具有容错性, 且连接权的值正向偏差时对网络的收敛时间没有多大影响。

因为神经网络是大规模互连系统, 在具体的 VLSI 实现时, 由于网络本身的高度互连, 在直线时会产生相互影响, 因而连接权肯定会产生偏差。根据我们的模拟实验结果表明, 电阻偏差在一定范围内就可实现这种 Tank & Hofield 型神经优化网络, 并且对输入和连接权均具有容错性, 从而可用它来快速地求得一个优化问题的好解, 特别对于系统诊断的诊断问题能够求得唯一解, 其唯一性由文献^[3] 保证。

对初值均取 0.5 的情况, 模拟实验得出了电容 C 、电阻 R 及放大系数 K 与网络收敛时间的关系如图 4 的 (a), (b), (c)。




图 4 电容 C 、电阻 R 及放大系数 K 与网络收敛时间的关系

从上面三个关系图可看到, 这和我们的理论分析是一致的。

5 结 论

本文用 Tank & Hofield 型神经优化网络求解了 $P-t$ 可诊断模型, 获得了唯一的诊断结果, 其唯一性由^[3] 保证。模拟实验表明神经网络对求解计算机系统诊断的诊断问题的有效性, 同时表明神经网络对初始输入和连接权均具有容错性, 即它们的微小偏差不会影响整个网络的功能; 模拟实验还表明不宜取太大的电容 C , 但电阻 R 和放大系数 K 则宜取大些。

参 考 文 献

- 1 陈廷槐. 数学系统的测试与容错, 南京: 东南大学出版社出版
- 2 Shachindra N. Maheshwari & Hakimi. On Models for Diagnosable Systems and Probabilistic Fault Diagnosis. IEEE trans. on Comput. 1977, c-25(3)
- 3 Tank D W, Hofield J J. Simple "Neural" Optimization Networks, An A/D Converter, Signal Decision Circuit, and a Linear Programming Circuit. IEEE trans. on Circuits & Systems, 1986, CAS-33(5)