

面向入侵检测系统的 EBP 算法研究

马占飞^{1,2}, 张 涵²

(1 内蒙古科技大学包头师范学院 计算机系, 内蒙古 包头 014030;

2 内蒙古科技大学信息工程学院 计算机系, 内蒙古 包头 014010)

摘 要: BP 算法是入侵检测系统(IDS)的一种重要检测方法,但是该算法存在检测时间长、效率低下等局限性. 为了解决以上问题,通过对 BP 算法的深入剖析,提出了一种面向入侵检测系统的新算法——EBP(Enhanced BP)算法. EBP 算法通过改进误差函数、增加可自适应放大的误差信号等方法,较好地解决了 IDS 的检测速度慢、检测效率低下等问题. 实验结果表明,EBP 算法相比经典的 BP 算法和 MBP 算法,不仅在网络训练的收敛速度上有了明显改善,而且在 IDS 的检测效率上分别提高了 14.0%和 8.1%,在误报率上分别降低了 4.45%和 1.5%.

关键词: EBP 算法;神经网络;入侵检测;饱和度;收敛速度

中图分类号: TP393

文献标识码: A

文章编号: 1000—7180(2016)06—0117—06

The Research of EBP Algorithm for Intrusion Detection System

MA Zhan-fei^{1,2}, ZHANG Han²

(1 Department of Computer, Baotou Teachers College, Inner Mongolia University of
Science and echnology, Baotou 014030, China;

2 Department of Computer, School of Information Engineering, Inner Mongolia
University of Science and Technology, Baotou 014010, China)

Abstract: Although BP algorithm is a very important method in the intrusion detection systems (IDS), it can cause the system problems of long time detection and low detection rate. To solve these problems, through analyzing the BP algorithm, a novel EBP algorithm (Enhanced BP algorithm) for IDS is constructed. An improved error function is designed in EBP algorithm to solve some disadvantages of the IDS, such as the slower detection speed and detection efficiency. Moreover, a self-adaptive method of magnifying error signal is also proposed. The results show that the EBP algorithm is an efficient algorithm. Compared with the classical BP algorithm and the MBP algorithm, the EBP algorithm can not only increases the convergence speed of network training obviously, but also improves the detection rate of IDS to 14.0% and 8.1% respectively. Besides, the decrease in false positive rate of EBP algorithm is 4.45% and 1.5% than other two algorithms respectively.

Key words: EBP algorithm;neural networks;intrusion detection;saturation degree;convergence rate

1 引言

入侵检测系统(Intrusion Detection System, IDS)作为一种主动的网络安全防御技术,其目的是用于防范外部网和内部网的攻击行为,现已被广大研究人员所关注^[1-2]. 但是,IDS 在实际的应用中依

然存在很多不足,如检测效率低下以及误报比率较高等. 特别是随着网络规模的复杂化和大型化,网络攻击行为的智能化和多样性,如何有效地防范黑客入侵、信息泄密等网络安全问题,已成为一个亟待解决的问题.

目前,大多数的 IDS 是基于规则的,这种检测

收稿日期: 2015—08—03; 修回日期: 2015—09—25

基金项目: 国家自然科学基金项目(61163025); 内蒙古自治区自然科学基金项目(2010BS0904); 内蒙古自治区高等学校科学研究基金项目(NJ10162, NJZY14242, NJZY201); 包头市科学研究基金项目(2014S2004-3-1-26)

技术一般只能检测出规则库中已有的攻击类型,对于一些新的攻击类型或者变异攻击,传统的 IDS 则显得无能为力,因此,研究一种智能化程度高、自适应性强的入侵检测系统已刻不容缓。一些研究表明,神经网络具有较好的自适应性和动态扩展性,它可以通过学习和训练获得较好的预测能力,不仅能检测出新的攻击行为,而且能适应不断扩大的动态网络环境^[3-4]。其中,BP(Back Propagation,反向传播)算法作为神经网络较常用的一种方法,其在分类检测、模式识别等方面有着较为广泛的应用,然而该算法也存在收敛速度较慢、容易陷入局部极小化等问题,这些不仅使网络系统的整体性能受到较大影响,而且也制约了 BP 算法在 IDS 中的高效应用。

鉴于此,本文从 BP 算法在 IDS 应用中存在的局限性入手,针对隐含层神经元中的饱和度问题,引入饱和度比例因子来改进误差函数、增加可自适应放大的误差信号等方法,以改进现有的 BP 算法(称作 EBP 算法——Enhanced BP Algorithm),有效地缓解隐含层饱和度对网络训练的影响。仿真实验表明,EBP 算法较好地解决了经典 BP 算法中存在的局限性,提高了 IDS 的入侵检测性能。

2 BP 算法的网络结构及其基本思想

2.1 BP 算法的网络结构

典型 BP 算法的网络结构分为三层:输入层、隐含层和输出层。

(1)输入层(Input Layer)负责接收来自外界的输入信息,并传递给隐含层各神经元;

(2)隐含层(Hide Layer)是内部信息处理层,负责信息变换;

(3)输出层(Output Layer)负责完成一次学习的正向传播处理过程,即由输出层向外界输出信息处理结果。

BP 算法的网络结构如图 1 所示。




图 1 BP 算法的网络结构

2.2 BP 算法的基本思想

BP 算法的基本思想是:将计算得到的误差从输

出层逐层反向反馈到输入层,并将误差分配到各层的神经元,并且修改各层的权值,直到实际误差减少到期望误差范围内为止^[5]。

BP 算法的学习过程一般包括信号的正向传播和误差的反向传播两个阶段,其属于 δ 学习规则类。该算法的具体学习过程是:在正向传播过程中,每个输入样本从输入层经过隐含层到输出层,比较得到的总误差与规定的目标值,若实际误差小于等于目标值,则此次训练结束;否则,将转为反向传播,在这个过程中,从输出层到隐含层再到输入层的权值和阈值就会随着反向误差信号的变化而改变,使误差减小,直至达到目标误差为止。

假设输入样本值是 P ,期望输出值是 T ,期望误差值是 e ,实际输出值是 Q ,隐含层的输出值是 O 。第 k 个样本的输入向量是 a_k ,期望输出向量是 T_k ,实际输出向量是 Q_k 。输入层、隐含层及输出层的神经元个数分别是 m, n, q 。BP 算法的过程描述如下所示。

Step1:初始化网络的权值 W_{ij} 和 W_{jk} ;

Step2:随机选取一些记录作为网络的训练数据;

Step3:从训练数据中任意选择一个样本,并计算此样本的误差函数值 $E(t)$ ^[6]。

$$E(t) = \frac{1}{2} \sum_{i=1}^m \sum_{k=1}^q [T_{ik} - Q_{ik}(t)]^2 \quad (1)$$

Step4:针对此样本,计算其输出层到隐含层的误差反向信号量 $\delta_{ik}(t)$:

$$\delta_{ik}(t) = (T_{ik} - Q_{ik}(t))Q_{ik}(t)(1 - Q_{ik}(t)) \quad (2)$$

同时,计算输出层到隐含层的权值改变量 ΔW_{jk} :

$$\Delta W_{jk}(t) = -L \left(\frac{\partial E(t)}{\partial W_{jk}} \right) \quad (3)$$

式中 L 为初始学习率, $L \in (0, 1)$ 。

在此基础上,修正的权值为 $W_{jk}(t+1)$:

$$W_{jk}(t+1) = W_{jk}(t) + \Delta W_{jk}(t) \quad (4)$$

Step5:计算隐含层到输入层的误差反向信号量 $\delta_{ij}(t)$:

$$\delta_{ij}(t) = O_{ij}(t)(1 - O_{ij}(t)) \sum_{k=1}^q \delta_{ik}(t)W_{jk}(t) \quad (5)$$

同时,计算隐含层到输入层权值改变量 ΔW_{ij} :

$$\Delta W_{ij}(t) = -L \left(\frac{\partial E(t)}{\partial W_{ij}} \right) \quad (6)$$

在此基础上,修正 $W_{ij}(t+1)$ 的权值为

$$W_{ij}(t+1) = W_{ij}(t) + \Delta W_{ij}(t) \quad (7)$$

Step6:取下一个数据进行训练,返回 Step3,直到所有数据训练结束;

Step7:计算误差 E ,并与期望误差 e 进行比较,若 $E < e$,则算法训练结束;否则,返回 Step3 继续进行训练,直至满足相关条件为止。

3 BP 算法的改进

3.1 降低隐含层的神经元饱和度

经典的 BP 算法在训练前期,其输出值和期望值本身相差较大,即初期误差大,同时也会出现误差下降缓慢,甚至是“停滞”的情况,这是由于隐含层处在一种饱和的状态所造成的^[7-8]。网络在隐含层的饱和状态下不能继续学习,也就无法正向传播信号和反向传播误差,即隐含层的作用没有很好地体现。因此,在改进误差函数时需要考虑隐含层饱和度的问题,而且隐含层对权值和阈值的调整也有很大的作用。

文献[7]中提出的误差函数算法(文中将此算法记为 MBP 算法),虽然考虑到了隐含层饱和度的问题,即:

$$E = \frac{1}{2} \sum_{i=1}^m \sum_{k=1}^q (T_{ik} - Q_{ik})^2 + \frac{1}{2} \sum_{i=1}^m \sum_{k=1}^q (T_{ik} - Q_{ik})^2 \left(\sum_{j=1}^n (O_{ij} - 0.5)^2 \right) \quad (8)$$

然而该函数并不能有效地减小隐含层饱和度的影响。为此,文中提出了一种新的误差函数。该函数利用梯度下降法,并引入饱和度的思想,其目的就是在减小误差的同时能够降低隐含层饱和度对网络训练的影响。

新提出的误差函数 E 定义为

$$E = \frac{1}{2} \sum_{i=1}^m \sum_{k=1}^q (T_{ik} - Q_{ik})^2 + \beta \times \frac{1}{2} \sum_{i=1}^m \sum_{j=1}^n (O_{ij} - 0.5)^p \quad (9)$$

式(9)也可以表示为

$$E(t) = E_a(t) + \beta E_b(t) \quad (10)$$

在式(9)和(10)中, E_a 表示经典 BP 算法的误差函数, E_b 表示隐含层的误差函数, p 表示一个偶数, β 表示隐含层饱和度的比例因子,即为 $\frac{|T(t) - Q(t)|}{2}$, 其中, $T(t)$ 表示第 t 次的期望输出,而 $Q(t)$ 表示第 t 次的实际输出。(p 和 β 的具体物理意义在本小结最后有具体的解释)

由此可以定义新的输出层到隐含层的权值改变量 ΔW_{jk} 为

$$\Delta W_{jk} = -L \left(\frac{\partial E}{\partial W_{jk}} \right) = -L_1 \left(\frac{\partial E_a}{\partial W_{jk}} \right) = L_1 \sum_{i=1}^m \delta_{ik} O_{ij} \quad (11)$$

同时,定义新的隐含层到输入层的权值改变量 ΔW_{ij} 为

$$\Delta W_{ij} = -L \left(\frac{\partial E}{\partial W_{ij}} \right) = -L_1 \left(\frac{\partial E_a}{\partial W_{ij}} \right) - L_2 \left(\frac{\partial E_b}{\partial W_{ij}} \right) = L_1 \sum_{i=1}^m \delta_{ik} W_{jk} a_i - \frac{1}{2} p \beta L_2 \sum_{i=1}^m (O_{ij} - 0.5)^{p-1} C_{ij} a_i \quad (12)$$

式中, $\delta_{ik} = (T_{ik} - Q_{ik}) Q_{ik} (1 - Q_{ik})$, $C_{ij} = O_{ij} (1 - O_{ij})$; L_1 、 L_2 为学习率。

在文中,隐含层的激励函数是对数 S 型函数,如图 2 所示。从图 2 可以看出,当输出值接近于 0 或者 1 时,输入值接近于无穷小或无穷大,这样就会使网络的训练趋于停滞状态。当输入值接近于 0.5 时,隐含层的输入值即可达到极小值,因此,将隐含层的误差函数设为 E_b 的形式。




图2 对数 S 型函数

文中提出的新误差函数采用了两种误差相结合的方式,不仅可以使网络训练能够快速达到目标值,而且可以避免训练限于局部极小。当网络刚开始训练时,由于实际与期望的输出值差别较大,即 $|T(t) - Q(t)|$ 的值较大,所以 β 的值较大,此时为了减小隐含层饱和度对网络训练的影响,需要通过增加 p 的值来减小 E_b 的值,所以这个时期误差 E_a 仍然起主要作用;但是随着网络训练的进程,实际输出与期望输出的值会逐渐接近,即 β 的值会变小且接近 0,因此,隐含层饱和度对网络训练的影响也随之变小。

3.2 放大反向误差的传播信号

表示反传误差信号的式(2)和(5)分别包含因式: $Q_{ik}(t)(1 - Q_{ik}(t))$ 和 $O_{ij}(t)(1 - O_{ij}(t))$,可以看出当 $O_{ij}(t)$ 和 $Q_{ik}(t)$ 的值接近于 0 或者 1 时,反传

误差信号 $\delta_{jk}(t)$ 和 $\delta_{ij}(t)$ 接近于 0, 这样权值的改变量接近于 0 (从式 (11) 和 (12) 可以得到), 而此时 $T_{jk} - Q_{jk}(t)$ 的值可能很大, 训练则进入饱和区, 由此导致其收敛速度变得很缓慢^[9-10]. 在这种情况下, 权值的变化几乎很小, 这对于 BP 算法的反向传播过程来说是毫无意义的. 鉴于此, 本文提出了通过放大误差信号 $\delta_{jk}(t)$ 和 $\delta_{ij}(t)$ 的值, 即放大因式 $Q_{jk}(t)(1 - Q_{jk}(t))$ 和 $O_{ij}(t)(1 - O_{ij}(t))$ 的方法, 即使当因式的值接近于 0 时, 仍可通过增大权值的改变量, 使算法限于局部极小, 从而加快了网络的收敛速度.

本文构造的能够自适应放大的误差传播信号的函数 $\delta'_{jk}(t)$ 和 $\delta'_{ij}(t)$ 分别为

$$\delta'_{jk}(t) = (T_{jk} - Q_{jk}(t)) [Q_{jk}(t)(1 - Q_{jk}(t))]^{-e^{(Q_{jk}(t)-0.5)^2}} \tag{13}$$

$$\delta'_{ij}(t) = O_{ij}(t)(1 - O_{ij}(t))^{-e^{(O_{ij}(t)-0.5)^2}} \sum_{k=1}^q \delta'_{jk}(t) W_{jk}(t) \tag{14}$$

通过以下分析来说明其放大误差信号的有效性. 令 $Q_{jk} = x, x \in [0, 1]$, 设 $f(x) = g(x)^{h(x)}$, 其中, $g(x) = x(1 - x), h(x) = -e^{(x-0.5)^2}$. 由此可得:

(1) 由 $g(x) = x(1 - x) = -(x - 0.5)^2 + 0.25$ 可知, 当 $x = 0.5$ 时, $g(x)$ 函数的最大值为 0.25, 且在区间 $[0, 0.5]$ 上单调递增, 在 $(0.5, 1]$ 上单调递减; 当 x 的值趋于 0 或者 1 时, $g(x)$ 函数的值都趋于 0;

(2) 由函数 $h(x)$ 的导数 $h'(x) = (1 - 2x)e^{(x-0.5)^2}$ 可知, 函数 $h(x)$ 在 $[0, 0.5]$ 上单调递增, 在 $(0.5, 1]$ 上单调递减, 且 $h(0) \approx -1.284, h(0.5) = -1, h(1) \approx -1.284$;

(3) 通过上述内容分析, 可以绘制函数 $f(x)$ 图像的基本形状, 如图 3 所示.




图 3 函数 $f(x)$ 图像

从图 3 可知, 当 x 趋于 0 或者 1 时, 则函数 $f(x)$ 的值趋于无穷大, 也就是说, 当实际输出 Q_{jk} 趋于 0 或者 1 时, 误差信号放大的倍数会扩大, 同时权值的

改变量也增大了, 有效避免了算法进入饱和状态, 而且加快了其收敛速度. 因此, 误差信号放大的倍数会随着网络的训练而自动调节, 以适应网络训练的各个阶段. 同理可以验证 $\delta'_{ij}(t)$ 的有效性.

综上所述, 将 3.1 和 3.2 节提出的两种算法融合起来, 即为文中构造的 EBP 算法 (Enhanced BP 算法), 该算法描述如下所示.

Step1: 初始化权值 W_{ij} 和 W_{jk} , 并设定网络学习率为 L_1, L_2 , 期望误差为 e ;

Step2: 从实验数据中随机抽取一条记录作为样本进行训练, 计算其隐含层和输出层的输出以及实际的误差值;

Step3: 根据式 (13) 和 (14) 分别计算误差信号, 进而计算权值的改变量, 并取下一对样本训练, 转向 Step2, 直到所有样本训练结束;

Step4: 根据每条记录的误差值, 计算其总误差值 E , 当 $E < e$ 时, 则算法结束; 否则, 转入 Step2, 直到训练误差满足要求为止.

4 基于 EBP 算法的入侵检测系统的体系结构

依据入侵检测系统的通用框架 CIDEF 及 IDWG 的设计标准, 本文构建了基于 EBP 算法的入侵检测系统的体系结构, 如图 4 所示. 该系统由四大模块组成: 数据采集模块、网络检测模块 (包括数据预处理模块、神经网络分类模块)、入侵响应模块以及数据库.

数据采集模块主要负责收集网络和主机上的数据. 网络检测模块是整个系统的核心模块, 主要是对数据进行归一化处理, 并且利用 EBP 算法优化的神经网络作为检测引擎; 其首先采用处理后的数据训练网络, 达到要求后, 再对网络进行检测分析. 入侵响应模块根据检测结果对入侵数据采取相应措施. 数据库用于记录入侵事件信息.

5 测试与分析

基于 EBP 算法的入侵检测系统, 其本质特征在于: 首先将选取的训练数据作为系统的输入, 然后利用 EBP 算法对神经网络训练, 当训练完成后, 将测试样本输入到 IDS 中进行检测与分析. 该系统的有效性测试与分析如下.

5.1 实验环境与测试数据

本系统选取的实验环境如下所示.
硬件配置: CPU 为 I5-3470 双核 3.20 GHz, 内存 8.00 GB, 硬盘 1 TB;




图 4 基于 EBP 算法的 IDS 体系结构

操作系统:Windows 8.0;
测试平台:Matlab 7.0;
实验数据:KDD CUP 99 数据集中的部分数据.

KDD CUP 99 数据集是由 DARPA 与 MIT Lincoln 实验室合作模拟的一个局域网络环境所得到的,收集了 9 个星期的网络和系统数据. KDD CUP 99 数据集中大约由 500 万条记录组成,每条记录则由 41 个特征属性构成,其中 7 个为符号特征、34 个为数值特征;最后一个为标志属性,除了 Normal 表示正常事件之外,其余标志都表示为异常 (Abnormal). 本实验之所以选取 KDD CUP 99 经典数据集中的部分数据作为实验数据,其主要在于:该数据集是入侵检测的标准数据集之一,它的攻击类型较为全面、典型,同时其实验结果基本接近于一个真实的网络环境,能够保证实验的有效性和真实性^[11-12]. 本实验从 KDD CUP 99 数据集中随机选取了 5 000 条记录,其中,测试数据 2 400 条,训练数据 2 600 条,主要用于网络训练以及测试神经网络检测和分析模块.

因为神经网络只能识别数值型的数据,因此所选取的实验数据需要进行一定的预处理,首先要对数据进行编码,然后把它们归一化到 $[0, 1]$,否则不同数量级的输入数据会影响到实验的结果. 为此,在进行网络训练之前,需要对其阈值和权值进行初始化,初始化的区间设为 $[0, 1]$ ^[7]. 根据神经网络的传输函数 $\text{logsig}(n)$,便可知数据在传输值 $(0, 1)$ 的变化比较大,如果不在此范围内,则传输值的变化会较小,不利于误差的反向传播.

5.2 测试与分析

将 EBP 算法应用到 IDS 中,采用 TCP 的基本特性就能达到较好的检测效果^[13],而其中的一些无关或冗余的特征属性可能会降低算法的检测精度和速度. 为此,本文选用了 TCP 的 6 个基本特性和其他 9 个较为重要特性作为检测特征. 在本文构建的网络拓扑结构中,只设置了一个隐含层,因为包含单一隐含层的神经网络能够使用任意精度逼近所有的非线性连续函数^[14-15].

KDD CUP 99 数据集中包含四种攻击类型: DOS、Probe、U2L、R2L,把它们分别编码为:0001、0010、0100、1000,正常数据编码为 0000.

根据以上分析,将神经网络的输入层神经元数设置为 15,隐含层神经元数设置为 10,输出层神经元数设置为 5. 其他参数分别设置为:训练的最大循环次数 $\text{pochs}=3\ 000$,期望误差 $e=0.002$,初始学习率 $L_1=0.05$;EBP 算法的输入层与隐含层的学习率设置为 $L_2=0.35$.

本文将 BP 算法、MBP 算法以及 EBP 算法作对比实验,这三种算法采用相同的实验环境和训练数据分别进行网络训练,其中,BP 算法的网络训练步数为 1 703,MBP 算法和 EBP 算法的训练步数分别为 468 和 135. 由于 BP 算法收敛缓慢,为了得到这三个算法更加清晰的训练对比图,因此,本文只截取了网络训练的前 600 步,三种算法的网络训练结果如图 5 所示.




图 5 三种算法训练对比图

从图 5 可以看出,经典 BP 算法和 MBP 算法在网络训练步数达到 200 左右后,网络训练收敛速度特别缓慢,这将使得网络学习时间增大;而 EBP 算法训练的网络能够快速收敛到目标值,并且网络学习时间少.

为了确保测试实验的可靠性,测试结果取五次

实验的平均值. 各类型数据测试样本数如表 1 所示, 总共 2 400 个样本.

表 1 各类型数据测试样本数

数据类型 样本数	正常 数据	异常数据			
		DOS	Probe	U2L	R2L
测试样本数	1 268	378	252	305	197

从图 6 可知,各算法对四种攻击类型检测率的比较,EBP 算法对 DOS、Probe、U2L、R2L 的检测率分别为 87.6%、88.1%、90.5%以及 91.8%,从柱状图中看出 EBP 算法对四种攻击类型的检测率均高于另外两种算法,说明基于 EBP 算法的 IDS 能更为精确的检测出各类型入侵事件.




图 6 三种算法对四种攻击类型的检测率比较

图 7 和图 8 反映了三种算法的入侵检测性能, EBP 算法检测率为 89.2%,明显高于另外两种算法;误报率为 1.75%,低于两种算法.

通过以上实验可以证明,基于 EBP 算法的 IDS 有更好的入侵检测性能.




图 7 三种算法检测率比较

6 结束语

本文通过对经典 BP 算法的剖析,从降低隐含层神经元饱和度着手,提出了一种高性能的算法——EBP 算法. 该算法不仅使神经网络训练步数大幅度减少,收敛速度加快,同时也解决了经典 BP




图 8 三种算法误报率比较

算法易出现的局部极小等问题. 通过仿真实验验证, EBP 算法相比经典 BP 算法和 MBP 算法,在 IDS 的网络训练速度和检测效率上均有较为明显的优势,较好地改善了 IDS 的检测性能.

参考文献:

[1] Luo B, Xia J. A novel intrusion detection system based on feature generation with visualization strategy [J]. Expert Systems with Applications, 2014, 41 (9): 4139-4147.

[2] Panda M, Abraham A, Patra M R. A hybrid intelligent approach for network intrusion detection [J]. Procedia Engineering, 2012, 30(1): 1-9.

[3] Liao H J, Richard Lin C H, Lin Y C, et al. Intrusion detection system: A comprehensive review[J]. Journal of Network and Computer Applications, 2013, 36 (1): 16-24.

[4] 杨雅辉, 黄海珍, 沈晴霓, 等. 基于增量式 GHSOM 神经网络模型的入侵检测研究[J]. 计算机学报, 2014, 37(5): 1216-1224.

[5] Wang Y, Gu D, Li W, et al. Network intrusion detection with workflow feature definition using bp neural network[M]. Advances in Neural Networks - ISNN 2009. Berlin Heidelberg: Springer, 2009: 60-67.

[6] Zweiri Y H, Whidborne J F, Seneviratne L D. A three-term backpropagation algorithm[J]. Neurocomputing, 2003, 50(1): 305-318.

[7] Wang X G, Tang Z, Tamura H, et al. A modified error function for the backpropagation algorithm[J]. Neurocomputing, 2004, 57(5): 477-484.

[8] 程明, 刘琼琼. 一种放大误差信号的 BP 算法[J]. 计算机应用研究, 2011, 28(2): 529-531.

[9] Ng S C, Cheung C C, Leung S H. Magnified gradient function with deterministic weight modification in adaptive learning[J]. Neural Networks, IEEE Transactions on, 2004, 15(6): 1411-1423.

冗余,如表 1 所示.

表 1 综合后的面积、延迟、功耗综合对比

MLG 电路	面积/ μm ²	面积冗余 百分比/ %	延迟/ ns	面积冗余 百分比/ %	功耗/ mW	面积冗余 百分比/ %
传统 MLG 电路	73.6	100	1.58	100	0.0705	100
本文 MLG 电路	40.4	54.89	1.02	64.55	0.0279	39.57

4 结束语

本文在排序网络的基础上,提出了一种新的低开销的大数逻辑门电路来进行大数逻辑译码.该电路避免了传统大数逻辑门电路随输入的增加冗余呈指数倍增加的缺点.因而,非常适合于现有高速、低功耗、小面积抗辐射加固设计方法的趋势.

参考文献:

[1] Martinie S, Autran J-L, Sauze S, et al. Underground experiment and modeling of alpha emitters induced soft-error rate in CMOS 65 nm SRAM[J]. IEEE Transactions on Nuclear Science, 2012, 59 (4): 1048-1053.

[2] Baumann R C. Soft errors in advanced semiconductor devices—Part I: the three radiation sources[J]. IEEE Transactions on Device and Materials Reliability, 2001, 1(1): 17-22.

[3] Dodd P E, Massengill L. Basic mechanisms and modeling of single-event upset in digital microelectronics [J]. IEEE Transactions on Nuclear Science, 2003, 50 (3): 583-602.

[4] Hughes H L, Benedetto J M. Radiation effects and

hardening of MOS technology: devices and circuits[J]. IEEE Transactions on Nuclear Science, 2003, 50(3): 500-521.

[5] Baumann R C. Radiation-induced soft errors in advanced semiconductor technologies[J]. IEEE Transactions on Device and Materials Reliability, 2005, 5(3): 305-316.

[6] Lin S, Daniel J, Costello J. 差错控制编码 (第 2 版) [M]. 北京: 机械工业出版社, 2007: 43-742.

[7] Liu S-F, Reviriego P, Maestro J A. Efficient majority logic fault detection with difference-det codes for memory applications[J]. IEEE Transactions on Very Large Scale Integration (VLSI) Systems, 2012, 20 (1): 148-156.

[8] Naeimi H, DeHon A. Fault secure encoder and decoder for nano memory applications[J]. IEEE Transactions on Very Large Scale Integration (VLSI) Systems, 2009, 17(4): 473-486.

[9] Reviriego P, Maestro J A, Flanagan M F. Error detection in majority logic decoding of euclidean geometry low density parity check (EG-LDPC) codes[J]. IEEE Transactions on Very Large Scale Integration (VLSI) Systems, 2013, 21(1): 156-159.

[10] Cormen T H, Leiserson C E, Rivest R L, et al. Introduction to Algorithms (第二版)[M]. 北京: 机械工业出版社, 2008: 433-442.

作者简介:

孙 宇 男,(1983-),博士,工程师.研究方向为超大规模集成电路可靠性设计与测试技术.
E-mail:Sunyu5088@163.com.

(上接第 122 页)

[10] Haruhiko T, Hidehiko K, Terumine H. Partially weight minimization approach for fault tolerant multi-layer neural networks[C]//Neural Networks, Proceedings of the 2002 International Joint Conference on. Japan:IEEE, 2002: 1092-1096.

[11] Cho J, Lee C, Cho S, et al. A statistical model for network data analysis: KDD CUP 99’data evaluation and its comparing with MIT Lincoln Laboratory network data[J]. Simulation Modelling Practice and Theory, 2010, 18(4): 431-435.

[12] 史美林, 钱俊, 许超. 入侵检测系统数据集评测研究 [J]. 计算机科学, 2006, 33(8): 1-8.

[13] 许鹏飞. 基于神经网络的入侵检测系统的研究与实现

[D]. 山东: 山东大学, 2008:31-32.

[14] 周国雄,沈学杰,李琳,等. 基于 AdaBoost 的网络入侵智能检测[J]. 系统仿真学报,2014,25(7):1517-1521.

[15] Simon H. Neural networks, a comprehensive foundation [M]. Beijing; China, Machine Press, 2004: 109-175.

作者简介:

马占飞 男,(1973-),博士,教授,硕士生导师,CCF 高级会员(07270S).研究方向为计算机网络技术与信息安全、人工智能. E-mail:mazhanfei0402@163.com.

张 涵 女,(1990-),硕士研究生.研究方向为计算机网络技术与信息安全.