

深度信念网在模拟电路故障诊断中的应用研究

颜学龙, 邵 伟

(桂林电子科技大学 电子工程与自动化学院, 广西 桂林 541004)

摘 要: 针对模拟电路故障诊断中特征提取的难题, 引入深度信念网模型, 在 Leapfrog 滤波器电路上对深度信念网、单隐层 BP 网络和三隐层 BP 网络三种模型做分类对比实验, 实验证明了深度信念网应用的可行性和有效性。基于带通电路, 设计实验对比了深度信念网、小波分析方法及单隐层 BP 网络的特征提取能力, 结果表明深度信念网特征提取能力明显优于小波分析和单隐层 BP 网络, 提取的特征更能反映数据本质。

关键词: 深度学习; 深度信念网; 模拟电路; 故障诊断; 特征提取

中图分类号: TP206+.3

文献标识码: A

文章编号: 1000-7180(2016)09-0159-05

Application of DBN in Analog Circuit Fault Diagnosis

YAN Xue-long, SHAO Wei

(School of Electronic Engineering and Automation, Guilin University of Electronic Technology, Guilin 541004, China)

Abstract: In view of the problem of feature extraction for analog circuit fault diagnosis, model of deep belief network (DBN) is introduced in this paper. Comparison experiments on Leapfrog Filter with a group of models including DBN, single hidden layer BP and three hidden layer BP prove that the model of DBN is feasible and effective. Moreover, according to the experiment on band pass filters with methods of wavelet analysis, DBN and single hidden layer BP network, the results show that the ability of feature extraction of DBN is better and the feature of extraction is closer to the essence of data.

Key words: deep learning; deep belief network; analog circuit; fault diagnosis; feature extraction

1 引言

特征提取是模拟电路故障诊断中的一个关键环节, 也一直是主要难题。目前, 模拟电路故障诊断常用的特征提取方法主要有主成分分析^[1] (PCA)、小波^[2] (包) 分析、核分析等。这些方法都有其局限性, 例如 PCA 方法只适用于线性特征提取, 小波(包) 分析和核分析要涉及小波基和核参数等诸多因素的选择和考量, 受经验的影响较大, 而且本质上这些分析方法和数据本身是相互孤立的, 很难保证提取的特征是数据的本质特征。深度学习^[3] 在特征提取上表现出特殊的优势, 能够从数据中自主学习特征, 学习到的特征更能反映数据本质。目前深度学习在模拟电路故障诊断领域的应用几乎是空白, 本文尝试将深度学习的主要模型——深度信念网用于模拟电路


的故障特征提取, 通过两个实验论证了其有效性。

2 深度信念网基本原理

2.1 受限波尔茨曼机 (Restricted Boltzmann Machine, RBM)^[4]

深度信念网 (Deep Belief Network, DBN) 是由 RBM 逐层叠加形成的生成模型, 后一层 RBM 的输入是前一个 RBM 的输出, 第一层 RBM 的输入为训练样本。顶层和次顶层之间的连接是双向的, 次顶层以下的层间连接有方向性, 如图 1(b) 所示。

RBM 是一个两层网络, 层间每个单元间有双向的连接, 层内单元间没有连接, 其图模型如图 1(a) 所示, 受限波尔茨曼机本质上是一种能量模型, 定义联合组态能量:

图1 RBM模型与DBN模型^[6]

$$E(v, h) = - \sum_{i \in V} a_i v_i - \sum_{j \in H} b_j h_j - \sum_{i, j} v_i h_j w_{ij} \quad (1)$$

这里假设单元为二值单元, v_i, h_j 分别为可视层单元 i 和隐藏层单元 j 的二值状态, a_i, b_j 为各层的偏置, W_{ij} 为层间单元权值。

定义联合概率(2), 其中 Z 称为分配函数, 由式(3)计算所得:

$$p(v, h) = \frac{1}{Z} e^{-E(v, h)} \quad (2)$$

$$Z = \sum_{v, h} e^{-E(v, h)} \quad (3)$$

由以上两式可得可视层的概率为

$$p(v) = \frac{1}{Z} \sum_h e^{-E(v, h)} \quad (4)$$

训练一个 RBM 模型, 学习其中的参数 $\Theta = \{W, a, b\}$, 就是使似然概率 $p(v | \Theta)$ 最大化, 则对数似然函数对参数求导得:

$$\frac{\partial \log p(v)}{\partial w_{ij}} = \langle v_i h_j \rangle_{\text{data}} - \langle v_i h_j \rangle_{\text{model}} \quad (5)$$

则梯度下降法的更新准则为

$$\Delta w_{ij} = \epsilon (\langle v_i h_j \rangle_{\text{data}} - \langle v_i h_j \rangle_{\text{model}}) \quad (6)$$

式中, ϵ 为学习率, 尖括号带下标表示在某个概率分布下求括号内值的期望, data 分布的期望容易获得, 而 model 分布的期望, 需要执行很长时间的吉布斯采样(Gibbs sampling)才能得到。2002 年, Hinton 提出了一个快速算法^[5], 将需要优化的目标函数由对数似然函数变为对比散度函数, 得到对比散度算法(CD 算法), 加快了训练速度。梯度下降法的更新准则变为

$$\Delta w_{ij} = \epsilon (\langle v_i h_j \rangle_{\text{data}} - \langle v_i h_j \rangle_{\text{recon}}) \quad (7)$$

各层偏置的更新准则只需将尖括号内乘积项换成各层独立变量即可, 具体详情可参见 2.2 节中 RBM 的 CD 算法。

2.2 深度信念网的训练算法

DBN 的训练分为预训练和整体微调两个阶段。

预训练是无监督学习, 自下而上进行, 从第一层 RBM, 输入训练样本, 经 CD1 算法训练, 训练完毕固定第一层的权值及偏置, 第一层输出作为第二层输入继续训练第二层 RBM, 这样逐层训练, 直到所有层训练完成。预训练完成后, 训练获得的各层权值和偏置作为网络参数的初始值, 在整体微调阶段使用 BP 算法对整个网络进行微调, 整体微调阶段是有监督学习。对于分类问题, 可以在 DBN 的顶层上加一个分类层, 直接针对全局损失函数使用 BP 算法整体微调。RBM 的 CD1 算法流程如下, 算法是针对二值单元, 对于其他类型的单元只需作少量调整即可使用。

RBM 训练算法(CD1)^[7]如下所示。

输入: 一个训练样本 x_0 , 学习率 ϵ , 最大训练周期 T, n, m 分别为可视层和隐层单元数。

输出: 连接权矩阵 W , 可视层偏置向量 a , 隐层偏置向量 b 。

定义 $\sigma(x) = 1/(1 + e^{-x})$ 。

初始化: 令输入 $v_1 = x_0$, W 用小值随机赋值, a 和 b 赋值为零。

For $t = 1, 2, \dots, T$

For $i = 1, 2, \dots, m$

计算 $Q(h_{1i} = 1 | v_1)$, 即计算 $\sigma(b_i + \sum_j w_{ij} v_{1j})$ 。

从 $Q(h_{1i} = 1 | v_1)$ 采样 $h_{1i} \in \{0, 1\}$ 。

End for

For $j = 1, 2, \dots, n$

计算 $P(v_{2j} = 1 | h_1)$, 即计算 $\sigma(a_j + \sum_i w_{ij} h_{1i})$ 。

从 $P(v_{2j} = 1 | h_1)$ 采样 $v_{2j} \in \{0, 1\}$ 。

End for

For $i = 1, 2, \dots, m$

计算 $Q(h_{2i} = 1 | v_2)$, 即计算 $\sigma(b_i + \sum_j w_{ij} v_{2j})$ 。

End for

$W \leftarrow W + \epsilon(v_1 h_1 - v_2 Q(h_2 = 1 | v_2))$

$b \leftarrow b + \epsilon(v_1 - v_2)$

$c \leftarrow c + \epsilon(h_1 - Q(h_2 = 1 | v_2))$

End for

3 实验及讨论

本文两个实验均是在搭载酷睿 2 双核 CPU, 主频 2.1 GHz, 内存 2 GB, 安装 Windows XP 操作系统的笔记本电脑上进行, 实验程序在 MATLAB R2014a 环境下编写和运行。

3.1 实验 1

实验 1 选用 ITC'97 国际标准电路中的 Leapfrog 滤波器电路,该电路用于低通滤波,其截止频率在 1.4 kHz 左右.应用 Multisim 软件搭建电路,如图 2 所示.图中电阻 $R_1 \sim R_{13}$ 取值 10 k Ω ;电容 C_1, C_4 取 0.01 μF ; C_2, C_3 取 0.02 μF .构建单故障集 {正常, $R_{40}, R_{45}, R_4 \uparrow, R_4 \downarrow, C_{20}, C_{25}, C_2 \uparrow, C_2 \downarrow, C_{10}$ },“S”表示短路,“O”表示开路.短路元件用 0.000 01 Ω 的电阻代替,开路元件用 200 M Ω 电阻代替, $R_4 \uparrow, R_4 \downarrow, C_2 \uparrow, C_2 \downarrow$, 为位于偏差标称值 $\pm 50\%$ 的软故障,加上无故障模式(即正常模式)共 10 种故障模式.电路中元件值设置 5% 的高斯容差漂移.

在仿真电路中设置输入激励源为频率 1 kHz,幅度为 5 V 的交流信号,对各个故障电路分别运行 120 次蒙特卡洛(Monte-Carlo)分析,每次采样 1 ~12 各节点电压值,1 个周期内(1 ms)采样 16 次,获得 12 $\times$ 16 维的向量样本,将其按行展开得到 192 维的行向量,这样针对每个故障,均能获得 120 个 192 维的样本,一共获得 1 200 个原始故障样本.对故障采用二进制编码,即故障 1 编码表示




图 2 Leapfrog 滤波器电路

表 1 的结果显示 DBN 和单隐层的 BP 神经网络都取得了很高的分类准确度,约为 95%,这表明深度信念网即使在样本数量不多的情况下也可以有效应用,另外,单隐层的 BP 神经网络的表现不逊色于 DBN 深度网络,这可能隐含着原始数据中存在简单关系.事实上,笔者将原始数据通过主成分分析方法(PCA)映射到二维空间,发现除了 R_{45} 和 C_{20} 两个故障存在着混叠关系,其他故障都呈现鲜明的线性关系.对实验结果的进一步分析知,出现分类错误的故障类别恰恰是这两个故障. DBN 的结果较三隐层 BP 网络高出近 5%,这说明逐层预训练可以有效地克服 BP 算法在深度网络的训练难题,通过对数据的自学习使得网络参数更接近最优.

为 1000000000,依次类推.本文随机从 1 200 个故障样本中选取 200 个样本作为测试集(分别从各个故障的 120 组样本中随机选择 20 个样本),剩余的为训练集.为提高可信度,重复上述操作 10 次,分别得到 10 组训练和测试集对,最后结果取 10 组实验数据的平均值.实验 1 对比实验了 DBN,单隐层 BP 和三隐层 BP 三种算法在故障样本上的分类准确度.实验中三种模型的网络参数分别为 192-150-150-600-10,192-100-10,192-200-100-30-10,并且三种模型的最后一层均为 softmax 分类.另外,单隐层 BP 和三隐层 BP 的输入数据均利用公式 $\frac{x - x_{\min}}{x_{\max} - x_{\min}}$ 进行归一化处理,而 DBN 直接用原始数据作为输入.在预训练 DBN 第一层 RBM 时,重构层选择高斯(线性)神经元,设置小的学习率为 0.000 1,预训练其他层时,均选择 sigmoid 神经元,学习率设为 0.1.实验结果由表 1 列出.(需要说明的是,笔者同样用归一化的数据输入 DBN 模型,得到了几乎一致的结果,只是需要将学习率提高 100 倍.)

表 1 实验 1 分类结果

算法	训练集分类 准确度/%	测试集分类 准确度/%
DBN	94.56	94.4
BP(一个隐层)	94.51	94.5
BP(三个隐层)	89.67	89.25

3.2 实验 2

深度学习特别强调深度网络的特征学习能力,为检验深度网络的特征学习能力,本文设计了一个简单对比实验,基本思路是给定两个向量 A, B ,求 A, B 的夹角 $\theta = \arccos(\frac{A \cdot B}{|A||B|})$,如果 θ 越大,则向量 A, B 间的区分度就越大.那么,如果用不同的特征提取方法分别获得的特征向量 C_i ,其中 i 表示某种特征提取方法, j 表示第 j 类故障,计算同一个方法中两两故障

特征向量 $C_p, C_q (p \neq q)$ 之间的夹角,如果某种方法得到的夹角普遍较大,则说明故障间的区分度就大,也表明这类方法的特征提取能力较强.

根据这一思路,实验 2 选择模拟电路故障诊断最常用的特征提取方法——小波分析及单隐层 BP 网来对比深度信念网络的特征提取能力.为使结果更可信,本文选择 11 种常用的小波基作比较,它们分别为 haar,db2,db3,db5,db9,bior1.3,bior2.2,rbio1.3,rbio2.2,coif1,sym2.另外,参照文献[8]和文献[9]的方法得到两个方案的特征向量.定义小波分解得到的各层系数序列为 $[a_N, d_N, d_{N-1}, \dots, d_1]$,其中 N 为分解层数, a_N 和 d_N 是序列向量.方案一对各层系数序列绝对值求和得特征向量 $L_1 = [\sum |a_N|, \sum |d_N|, \sum |d_{N-1}|, \dots, \sum |d_1|]$,方案二对各层系数序列平方求和得特征向量 $L_2 = [\sum a_N^2, \sum d_N^2, \sum d_{N-1}^2, \dots, \sum d_1^2]$.

实验电路如图 3 所示的带通电路.电路元件正常参数是: $R_1=5.18\text{ k}\Omega, R_2=1\text{ k}\Omega, R_3=2\text{ k}\Omega, R_4=R_5=4\text{ k}\Omega, C_1=C_2=5\text{ nF}$.仿真中设置电阻 5% 高斯容差漂移,电容 10% 高斯容差漂移.设置单故障集{正常, $R_1 \uparrow, R_1 \downarrow, R_2 \uparrow, R_3 \uparrow, R_3 \downarrow, C_1 \uparrow, C_1 \downarrow, C_2 \uparrow, C_2 \downarrow$ },共 10 种故障,“ $\uparrow$ ”,“ $\downarrow$ ”分别表示上偏 20% 和下偏 20%.为使获得的信号包含丰富的信息,激励源选择幅度 5 V,脉冲宽度 10 μs 的脉宽信号.




图 3 带通电路

进行以下步骤:

(1)在 Multisim 软件中对每个故障分别进行 100 次蒙特卡洛仿真,采样输出电压获得原始故障样本 $X_j^i, i \in \{1, 2, \dots, 10\}, j \in \{1, 2, \dots, 100\}$,共得到 1 000 个维数为 265 的故障样本.


(2)根据上面两个方案的特征向量生成方法,分别获得基于 11 种小波基的特征向量,其中分解层数 N 设为 5,则特征向量的维数为 $N+1=6$.将 X 作为训练样本,学习一个 DBN 和一个单隐层 BP 网络,为在同一条件下比较,DBN 的顶层神经元数设为 6,网络训练完成后,输入样本 X 计算 DBN 和 BP 的顶层输出,则输出即为 DBN 和 BP 的特征向量.为了对比各种方法对原始样本本质特征的刻画能

力,也将原始样本作为一种特殊的特征向量.


(3)利用各种方法获取特征向量后,对每种方法的特征向量(包括原始特征向量)按故障类别求平均值,即使得每个方法有 10 个特征向量,一个故障一个特征向量.

(4)对每种方法求各个故障特征向量之间的夹角并显示.

实验中 DBN 和 BP 模型参数分别在 265-300-100-6,265-100 取得最好的分类结果,此时 DBN 取得 95.3% 的分类正确率,而 BP 为 75%.图 4 显示了对比结果,图中横坐标 1~45 表示 45 个 10 种故障两两对比模式,例如坐标值 1 表示故障 1 与故障 2 的对比,2 表示故障 1 与故障 3 的对比,以此类推.纵坐标表示向量夹角角度.为显示清楚,图中省略了一些方法的曲线.从图中可以清楚地看到无论哪种方案,DBN 的表现都是最好的,它提取的特征之间的夹角几乎都是所有方法中最大的,也就是说 DBN 提取的特征各个故障间具有最好的区分度.两个方案 db9 方法都表现个别夹角较大,其余夹角较小,这表明 db9 对某些故障特征有更好的提取. Haar 在方案 2 的表现比方方案 1 更好.需要说明的是,图中未显示方法的曲线走势基本上都在 haar 和 sym2 曲线之间.从图中可以发现 DBN, BP 方法曲线的走势和原始样本的曲线走势几乎是一致的,这说明 DBN, BP 方法更能解读出样本中的本质特征,只是 DBN 比 BP 表现得更好.



(a) 方案一



(b) 方案二

图 4 DBN, BP 神经网络和小波方法的特征提取能力比较

4 结束语

本文将深度信念网应用于模拟电路的故障诊断中,设计了两个实验,实验1在Leapfrog滤波器仿真电路上对比了深度信念网(DBN),单隐层BP网络及三隐层BP网络的故障诊断正确率,结果证明DBN在模拟电路故障诊断中的应用是可行的,实验2在带通电路上对比了DBN,单隐层BP和小波分析方法的特征提取能力,结果表明DBN特征提取能力优于其他两种方法,而且提取的特征更能反映数据本质.深度学习给模拟电路故障诊断提供了一个优质选择.

参考文献:

- [1] 孟凡斌,唐圣学,谭子尤. 基于小波和主元分析的容差电路的故障诊断方法[J]. 微电子学与计算机,2010,21(11):135-138.
- [2] 刘美容,张立玮. 基于小波分解和模糊聚类的模拟电路软故障诊断[J]. 微电子学与计算机,2014,31(12):140-143.
- [3] Hinton G E, Salakhutdinov R R. Reducing the dimensionality of data with neural networks[J]. Science, 2006, 313(5786):504-507.
- [4] Hinton G E. A practical guide to training restricted boltzmann machines[M]. Neural Networks: Tricks of

the Trade of the series Lecture Notes in Computer Science,2012,9(1):599-619.

- [5] Hinton G E. Training products of experts by minimizing contrastive divergence[J]. Neural Computation, 2002, 14(8):1771-1800.
- [6] Geoffrey H. Where do features come from? [J]. Cognitive Science A Multidisciplinary Journal, 2013, 38(6):1078-1101.
- [7] Bengio Y. Learning deep architectures for AI[J]. Foundations & Trends in Machine Learning, 2009, 2(1):1-127.
- [8] 王承,陈光福,谢永乐. 小波-神经网络在模拟电路故障诊断中的应用[J]. 系统仿真学报,2005,17(8):1936-1938.
- [9] Zhang L, Sun L, Cai X, et al. Analog circuit fault diagnosis based on the wavelet analysis and EM algorithm of limited gaussian mixture model[J]. International Journal of Advancements in Computing Technology, 2013,10(5):32-42.

作者简介:

颜学龙 男,(1962-),教授,硕士研究生导师.研究方向为可测性设计、故障诊断和边界扫描技术.

邵伟(通讯作者) 男,(1987-),硕士研究生.研究方向为机器学习和故障诊断. E-mail:592226162@qq.com

(上接第158页)

务量进行分区计算,获取海量数据调度任务中的子任务,从而构建海量数据调度任务和数据节点间的映射关系.依据目标数据在服务器的传输状态求出海量数据通信的任务量,构建海量数据优化调度模型.实验结果表明,采用所提模型对海量数据进行调度,不仅吞吐量高,而且传输速率快,具有很高的调度性能.

参考文献:

- [1] 王菲.无线传感网络低空干扰下的通信优化模型仿真[J]. 计算机仿真,2015,32(1):331-334.
- [2] 孙卫真,王秀锦,徐远超. 交通信息分布式处理中的Hadoop调度算法优化[J]. 计算机工程与设计,2014,35(4):1269-1273.
- [3] 贾江涛. 基于动态规划框架下的水电系统优化调度[J]. 西安工程大学学报,2015,29(4):420-425.
- [4] 刘彤. 海量非线性网络流量数据分类模型的仿真分析[J]. 计算机仿真,2015,32(12):255-258.

- [5] 陈丽平,郭鑫. 最小能耗优化云模型中的动态图挖掘方法[J]. 计算机工程,2015,41(8):23-31.

- [6] 黄少卿,胡立强. 基于改进SALS算法的大数据挖掘效率优化探究[J]. 微型机与应用,2015,34(12):11-13.

- [7] 王艳. 云计算环境下差异性资源调度特征匹配算法[J]. 中国西部科技,2015,14(12):82-84.

- [8] 申倩,许美玉,姜春茂. 云计算环境下任务调度研究综述[J]. 智能计算机与应用,2014,4(6):75-77.

- [9] 熊最,王可人,金虎,等. 一种基于干扰对齐的多跳网络吞吐量优化模型[J]. 系统仿真学报,2015,27(6):1240-1246.

- [10] 何鹏举,吴来斌,宋凯华,等. 基才粒子群算法的嵌入式云计算资源调度[J]. 电子设计工程,2014,22(10):88-90.

作者简介:

武怀生 男,(1977-),硕士研究生,讲师.研究方向为信息技术与教育. E-mail:wuhuaisheng765@163.com