

基于退化数据和 DBN 算法的 IGBT 健康参数预测方法

陈冰¹, 鲁刚², 房红征^{3,4}, 张明敏¹, 董云帆^{3,4}

(1. 海军工程大学 电子工程学院, 武汉 430033; 2. 海军装备部, 北京 100055;

3. 北京航天测控技术有限公司, 北京 100041;

4. 北京市高速交通工具智能诊断与健康重点实验室, 北京 100041)

摘要: 绝缘栅双极型晶体管 (IGBT) 等电子元器件被广泛用于运输和能源部门, 其健康状态对于设备安全和有效至关重要; 在对 IGBT 的结构和损伤机制分析基础上, 结合 NASA 艾姆斯中心开展的 IGBT 加速退化试验, 选择集电极-发射极关断峰值电压作为失效特征参数, 提出了一种基于深度信念网络的预测模型对其进行分析和预测; 以 Levenberg-Marquardt (LM) 算法模型作为对比, 实验结果显示文章提出的三隐藏层 DBN 模型相比于 LM 模型有更好的预测性能和更高的预测精度。

关键词: 绝缘栅双极型晶体管; 深度信念网络; 失效特征; 预测

Prediction Method of IGBT Health Parameters based on Degradation Data and DBN Algorithm

Chen Bing¹, Lu Gang², Fang Hongzheng^{3,4}, Zhang Mingmin¹, Dong Yunfan^{3,4}

(1. College of Electronic Engineering, Naval University of Engineering, Wuhan 430033, China;

2. Equipment Department of Navy, Beijing 100055, China;

3. Beijing Aerospace Measure & Control Corp. Ltd, Beijing 100041, China;

4. Beijing Key Laboratory of High-speed Transport Intelligent Diagnostic and Health Management, Beijing 100041, China)

Abstract: Insulated Gate Bipolar Transistor (IGBT) and other electronic components are widely used in the transport and energy sector, its health status for equipment safety and effectiveness is essential. Based on the analysis of the structure and failure mechanism of the IGBT, the peak of the collector-transmitter voltage is selected as the failure characteristic parameter combining with the accelerated degradation experiment data from NASA Ames Center. Then a prediction method based on the Deep Belief Network (DBN) is proposed for the analysis and prediction of the trend of the IGBT. Comparing with the Levenberg-Marquardt (LM) algorithm model, the experimental results show that the proposed three hidden layer DBN model has better prediction performance and higher prediction accuracy than LM model.

Keywords: insulated gate bipolar transistor; deep belief network; failure characteristic; prediction

0 引言

IGBT (绝缘栅双极型晶体管) 是由 BJT (双极型三极管) 和 MOSFET (绝缘栅型场效应管) 组成的复合全控型电压驱动功率半导体器件, 兼有 MOSFET 的高输入阻抗和 GTR (电子晶体管) 的低导通压降两方面的优点。目前, IGBT 广泛应用于交流电机、变频器、开关电源等民用领域, 而且在航空航天等军事领域也有广阔的发展前景。随着 IGBT 的广泛应用, 对其可维护性的要求也越来越高。因此, 研究 IGBT 的健康状态问题, 对于装备电子器件的可靠运行和安全生产无疑具有十分重要的意义^[1-4]。

当前常见的针对 IGBT 等电子器件预测方法可以分为 3 种: 1) 失效物理方法。通常以定义模型作为起始, 这需要具备元器件的失效物理特性的知识。然而在实际应用中, 由于系

统的复杂性, 很难建立一个准确的物理模型, 因此其使用范围和效果而受到限制。2) 数据驱动方法。以获取数据为起始步骤, 在实际失效预测过程中, 元器件在其寿命周期的不同阶段被传感器所接收的历史数据常常作为数据信息的重要资源。数据通常包含足够信息来进行预测, 所以需要开发一种基于传感器获取数据的预测模型来预测失效。具体包括参数统计、机器学习等方法。3) 融合方法。集合了失效物理方法和数据驱动方法的优点, 克服两种方法的局限性, 可以提供更为精确的预测结果。

深度学习是近年研究的一个重点领域, 是机器学习中的一个重要方面。深度信念网络 (deep belief networks, DBNs) 作为深度学习中使用较为广泛的一种重要形式, 由于其可以学习样本数据的未知特性分布, 被广泛应用于图像识别和语音识别等领域。相比于支持向量机和传统神经网络等浅层人工神经网络, 深度学习具有更多的隐藏层, 因此也需要更多的非线性数学处理。同时, 深度学习算法在计算代表特殊功能的元素和参数方面相比于浅层算法具有更好的效果。

收稿日期: 2017-03-10; 修回日期: 2017-03-17。

作者简介: 陈冰 (1979-), 女, 黑龙江哈尔滨人, 副教授, 主要从事装备维修保障技术方向的研究。

本文首先介绍了 IGBT 的结构和失效机制，其次对 IGBT 加速退化测试试验进行了分析，之后提出了一种基于 DBN 算法的预测模型，最后利用试验数据对提出的模型和方法进行了验证。

1 IGBT 的结构和失效机制

IGBT 作为中高功率电子器件，主要是以垂直结构进行集成。按照其构成沟道材料的不同，又可以分为 P 型沟道和 N 型沟道 IGBT。IGBT 的主要端口有栅极、集电极和发射极，是三端器件。IGBT 在结构上较类似于 MOSFET，不同之处是在 VDMOSFET 的 N+ 区 (MOSFET 的漏极) 上增加了一个 P+ 注入区 (IGBT 的集电极)，形成了四层结构，相当于 PNP-NPN 达林顿结构，并因此而形成了一个面积较大的 P+N 结 J1。这样使得 IGBT 导通时由 P+ 注入区向 N 基区发射少子，从而对漂移区电导率进行调制，使得 IGBT 具有很强的通流能力^[5-7]。

在具体应用中，IGBT 失效是与其动态特性相关的复杂过程，涉及热、电、机械等多方面因素。国内外相关机构已经对 IGBT 的失效机理进行了研究。功率电子设备失效的本质机制包括热载流子注入和电介质击穿以及电迁移，而外在的失效主要包括锁定，导线脱落，模具焊接剥离以及基质焊料疲劳失效。电器过应力通常是由于过电流，过电压或过功率引起的。目前已发现热循环与模具焊接退化和导线脱落有强的关联性。

2 IGBT 加速退化试验分析

2.1 实验步骤和退化数据

本文所采用的数据来源于 NASA 艾姆斯中心开展的 IGBT 加速退化试验^[8]。该机构的实验包括一套商业化的仪器，在 LabVIEW 开发的软件框架的控制下，连接到定制的硬件系统。硬件由示波器、函数发生器、NI 数据采集、红外传感器、环境室和运行 LabVIEW 和 Matlab 的 PC 计算机组成。该实验允许 IGBT 超过温度达到设定的高点 330 °C。当 IGBT 超过温度阈值时，IGBT 栅极关闭，直到其下降到低于 329 °C 的设定低点。该试验数据包含 2 378 组 PWM 温度控制器状态数据，41 752 组稳态数据和 418 组瞬态数据。每组瞬态数据包含十万个集电极发射极电压数据。每个数据的间隔为 1 ns，每组瞬变数据的时间标度 0 为 0.1 ms。该数据完全记录了 IGBT 在关断期间的集电极-发射极电压变化过程。如图 1 所示。

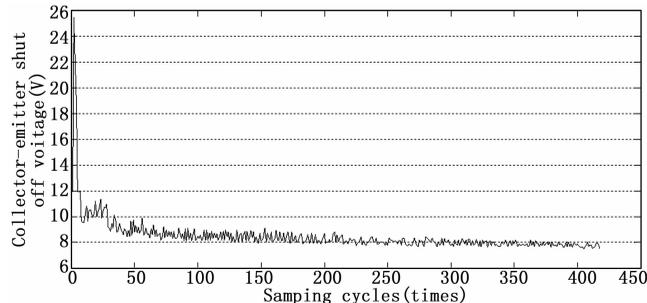


图 1 IGBT 集电极-发射极关断瞬态峰值电压示意图

2.2 退化特征选取

IGBT 的健康监测数据采集比较困难，通常采取的方式是采用加载超过额定工作范围的负载或者利用频繁的热应力循环

加速其性能退化过程。相关研究利用不同的加速退化测试平台模拟了 IGBT 的不同工作环境并测定了其瞬态、稳态性质。如实验前后的电子特性测试当中 IGBT 的瞬态电容特性、导通电压特性曲线出现了较为明显的偏移。这些变化趋势往往和 IGBT 的某些硬件损伤和损耗有着直接的联系。在 IGBT 的性能加速退化试验中，栅极信号和电流保持相当恒定。稳态电压变化很小。集电极-发射极电压特性在导通时同样变化较小。然而 IGBT 关断时的集电极-发射极的瞬态电压尖峰的下落表现出了较强的指示性，可作为温度增加和热过应力退化的特征变量函数。其产生机理是 IGBT 的寄生晶体管阻碍了阳极电流的增加，产生了一个从集电极到发射极的一个瞬态电压，与电源电压相叠加，便形成一个瞬态高于电源电压的尖峰。

对尖峰电压进行分析，给出了一定的趋势分析。通过这个研究成果进行新一轮的挖掘，可以发现以尖峰电压为故障预兆参数，并对生命周期内的尖峰电压峰值进行预测可以有效的实现 IGBT 的失效预测。

3 基于 DBN 模型的 IGBT 健康状态预测

3.1 DBN 模型的原理和构建

DBNs 模型是由多个受限玻尔兹曼机从下到上堆叠构成的^[8]，受限玻尔兹曼机 (restricted Boltzmann machines, RBMs) 由两部分组成：代表可观察量的可视单元 $V = (V_1, \dots, V_m)$ ，和用于提取可观察量之间关联特性的隐藏单元 $H = (H_1, \dots, H_n)$ 。两部分中神经节点取值都是二值的，即 $(v, h) \in (0, 1)^{m+n}$ 。比之传统玻尔兹曼机，RBMs 仅在可视层与隐藏层节点之间以 c 权重进行全连接，而同层节点之间则没有连接^[9]，如图 2 所示。

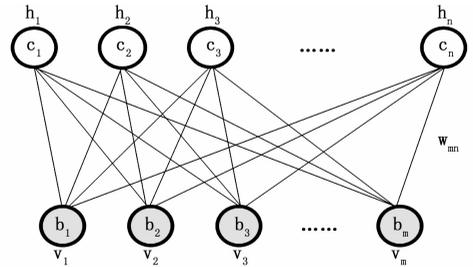


图 2 n 隐藏结点和 m 可视结点的 RBMs 结构

图 2 中， h_i ($i = 1, 2, \dots, n$) 与 v_j ($j = 1, 2, \dots, m$) 分别为隐藏层结点和可视层结点， c_i ($i = 1, 2, \dots, n$) 与 b_j ($j = 1, 2, \dots, m$) 是 RBMs 两层节点的偏差项， w_{mm} 表示连接隐藏单元和可视单元的实值权重。这样结构的优势就是可以极大地减少模型运算的复杂程度，提高其响应速度^[10]。根据理论研究分析，提出了 h 和 v 的联合概率分布公式为：

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

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

(1) 和 (2) 中，归一化因子 Z 是配分函数， E 是能量函数：

$$E(v, h) = - \sum_{i=1}^n \sum_{j=1}^m \omega_{ij} h_i v_j - \sum_{j=1}^m b_j v_j - \sum_{i=1}^n c_i h_i \quad (3)$$

其中， ω_{ij} ($i = 1, 2, \dots, n; j = 1, 2, \dots, m$) 是隐藏单元和可

视单元间的权重, b_j 和 a_i 分别是隐藏单元和可视单元的偏差项。基于条件概率的规则并使用公式 (1), 得到 h 和 v 互为初始条件时的条件概率公式为:

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

$$p(v | h) = \frac{p(v, h)}{p(h)} = \frac{\frac{1}{Z} e^{-E(v, h)}}{\frac{1}{Z} \sum_v e^{-E(v, h)}} = \frac{e^{-E(v, h)}}{\sum_v e^{-E(v, h)}} \quad (5)$$

其中, 公式 $p(v) = \sum_h p(v, h) = \frac{1}{Z} \sum_h e^{-E(v, h)}$ 为可视层变量的边缘分布。将其理解为一个随机神经网络, 其中节点和边界分别相当于神经元和突触的连接。由于公式 (6) (7), 单个变量的条件概率可以理解为在公式 $\delta(x) = \frac{1}{1 + e^{-x}}$ 条件下随机神经元的放电频率:

$$p(H_i = 1 | v) = \delta\left(\sum_{j=1}^m w_{ij} v_j + c_i\right) \quad (6)$$

$$p(V_j = 1 | h) = \delta\left(\sum_{i=1}^n w_{ij} h_i + b_j\right) \quad (7)$$

其中 $H_i = 1$ 和 $V_j = 1$ 分别是隐藏神经元 H_i 和可视神经元 V_j 。模型参数的更新规则如下列公式所示:

$$\Delta w_{ij} = p(H_i = 1 | v^{(0)}) \cdot v_j^{(0)} - p(H_i = 1 | v^{(k)}) \cdot v_j^{(k)} \quad (8)$$

$$\Delta b_j = v_j^{(0)} - v_j^{(k)} \quad (9)$$

$$\Delta c_i = p(H_i = 1 | v^{(0)}) - p(H_i = 1 | v^{(k)}) \quad (10)$$

参数 $v^{(0)}$ 是训练样本的起始值, 参数 $v^{(k)}$ 是吉布斯采样运行到第 k 次的采样值 (k 通常取值为 1)。

通过将多个 RBMs 从下向上进行组合, 可以构建成一个 DBN 模型^[11-14]。通过对 DBN 模型进行无监督训练, 最后生成一个概率产生模型。模型的联合概率分布如下所示:

$$p(x, h_1, \dots, h_l) = p(x | h_1) \left(\prod_{n=1}^{l-2} p(h_n | h_{n+1}) \right) p(h_{l-1}, h_l) \quad (11)$$

其中, $p(x | h_1)$ 是在 h_1 条件下 x 的条件概率公式, $p(h_{l-1}, h_l)$ 是 h_{l-1} 和 h_l 的联合概率密度公式, DBN 模型的结构如图 3 所示。

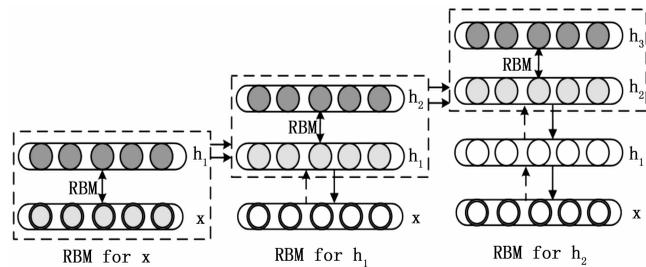


图 3 DBN 模型构建过程

3.2 DBN 模型的预测过程

基于 DBN 模型的预测方法描述如下^[16]: 首先, 根据实际预测需求, 从样本数据集提取与元件性能相关的性能参数并组建预测所需的训练样本集, 小波分析方法被用于为特征变量去

噪来消除噪声对预测效果的影响。其次, 预训练 DBN 模型过程, 即初始化模型权重和偏差项并使用训练样本迭代训练, 直到输入样本的概率分布与输出样本的概率分布偏差在设定范围内为止。然后, 将 BPNN 方法被用于微调模型参数直到预测输出数据与实际数据偏差小于特定范围后停止。最后, 将被需要预测的数据作为 DBN 模型输入, 经模型处理后即可在输出层获得预测数据。具体过程如图 4 所示, 包括:

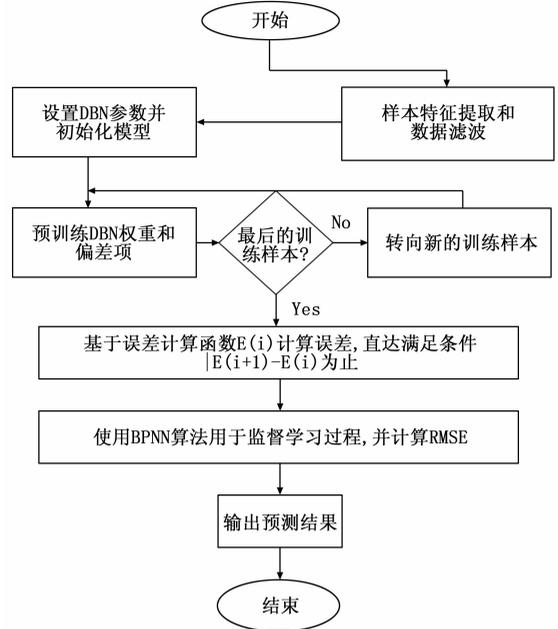


图 4 DBN 模型的算法流程

- 1) 样本数据特征提取, 数据过滤。
- 2) 根据步骤 1) 设置 DBN 模型结构, 初始化模型参数并设置最大迭代次数。其中 Δw_{ij} , Δb_j , Δc_i 通常被设置为 0。
- 3) 将预处理后的样本数据作为训练数据。使用公式 (8) ~ (10) 迭代更新模型参数直到最后一个训练样本。
- 4) 使用公式 (12) 计算第在 $k-1$ 次和 k 次吉布斯采样时条件概率误差值。

$$E_i = \sum_j p(v_j | h^{(k-1)}) - \sum_j p(v_j | h^{(k)}) \quad (12)$$

其中参数 i 是样本迭代次数, 参数 j 是训练样本集数量。

- 5) 如果相邻两次迭代 $|E_{i+1} - E_i|$ 的值超出设定范围, 继续重复步骤 4), 否则进行下一步。
- 6) 使用 BPNN 对预训练后的模型参数进行微调。
- 7) 模型输出即为预测结果, 结束。

预测过程包括两个过程。步骤 1) ~ 5) 是无监督学习过程, 用来对 DBN 模型的参数进行一个初步的处理过程。步骤 6) ~ 7) 是一个无监督训练过程, 用来微调模型参数并最终输出预测结果。

4 实验和分析

实验中发现, IGBT 的关断特性中门极信号改变不够明显, 而集电极-发射极的瞬态电压表现出显著的下降趋势。根据对集电极-发射极瞬态电压趋势的分析, 发现关断峰值电压呈现出强的负时间关联性; 从而 IGBT 的失效预测可以

将峰值电压作为失效特征参数来实现。因此选择关断瞬态电压作为退化实验数据(图1)。由于样本参数起伏较大,这里使用小波去噪对样本数据进行平滑处理。将处理后的数据作为实验数据。滤波前与滤波后实验样本曲线如图5所示。曲线中共有384个样本点。将样本点连续的前6个数据作为输入,第7个数据作为输出,共有378组数据样本组被获得。将前300组数据作为模型的训练样本,后78组数据作为评估测试数据。

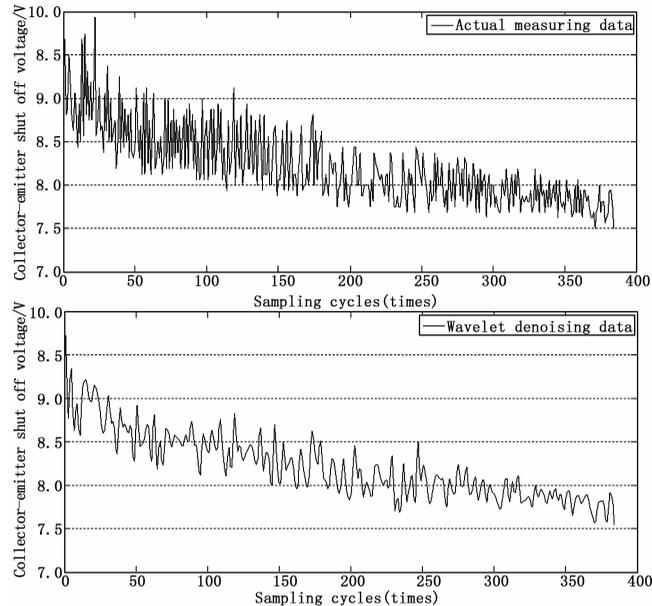


图5 实际测量和经小波去噪处理后的的实验数据

4.1 DBN模型的预测结果和分析

训练前先初始化DBN模型。初始化主要包括设置可视层,隐藏层,输出层神经元数量,以及可视层与隐藏层之间的权重,可视层神经元和隐藏层神经元的偏差项。一旦训练样本被确定则输入和输出神经元数量也随之确定。由于这里是将连续的前6个数据组合成一个DBN模型的队列输入函数,并将第7个数据作为输出,故模型有6个输入神经元1个输出神经元。拥有2个隐藏层的DBN模型被用于IGBT的性能预测实验,模型结构如图6所示。

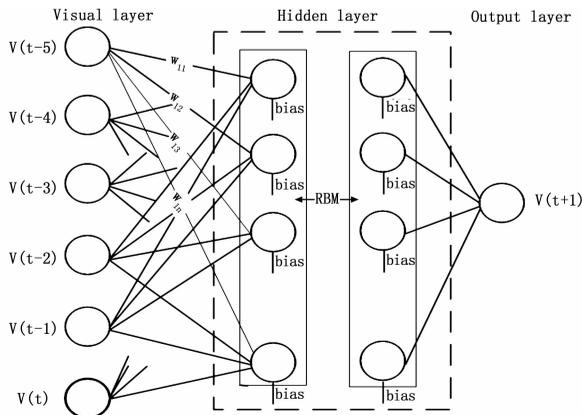


图6 两层DBN模型结构

每层RBM的权重和偏差项的偏差更新表示如下:

$$\Delta w_{ij} = \begin{bmatrix} \Delta w_{11} & \Delta w_{12} & \cdots & \Delta w_{1n} \\ \Delta w_{21} & \Delta w_{22} & \cdots & \Delta w_{2n} \\ \vdots & \vdots & \vdots & \vdots \\ \Delta w_{m1} & \Delta w_{m2} & \cdots & \Delta w_{mn} \end{bmatrix} \quad (12)$$

$$\Delta b_j = v_j^{(0)} - v_j^{(k)} \quad (13)$$

$$\Delta c_i = p(H_i = 1 | v^{(0)}) - p(H_i = 1 | v^{(k)}) \quad (14)$$

前300组训练样本被用于模型训练。当模型完成训练,剩余的78组作为评估预测数据。训练数据比例和部分模型参数如表1所示。

表1 两层DBN参数列表

训练样本比例	可视层节点数量	隐藏层节点数量	隐藏层每一层节点数量	
			第一层	第二层
0.8	6	2	19	25

令训练样本最大迭代次数为20000,学习率为1,起始权重和偏差项都设为0,预测结果如图7所示。RMSE为0.1031,预测精准度可被接受,但在图中可发现预测与实际值仍有一定差距,尤其是靠后的样本点表现出了较大的误差,这是因为在靠后部分的训练样本缺失最终导致的训练区间丢失的结果。

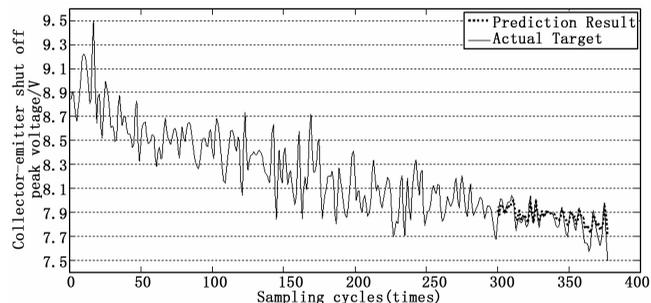


图7 完整的训练样本和两隐藏层DBN模型预测曲线

4.2 使用LM模型对比与分析结果

在元件失效特征参数预测过程中,LM算法可以较好地预测IGBT的退化趋势。本文根据参考文献[15]建立LM算法预测模型,预测的结果作为DBN模型的对照。LM(Levenberg-Marquardt)算法使用渐进二阶导数方法来避免矩阵的倒置运算,拥有比传统网络更平稳快速的收敛方式。其原则是通过减小误差来调整网络的权重和阈值,从而实现过程的最优化过程[17]。LM算法的误差指标方程为

$$E(w) = \frac{1}{2} \sum_{i=1}^N E_i^2(w) = \frac{1}{2} \sum_{i=1}^N (t_i - o_i)^2 \quad (15)$$

其中 t_i 和 o_i 为期望输出和实际输出, N 是输出矩阵的维度,假设 $E(w) = [E_1(w) E_2(w) \cdots E_N(w)]^T$, 那么雅可比矩阵 $J(w)$ 为

$$J(w) = \begin{bmatrix} \frac{\partial E_1(w)}{\partial w_1} & \frac{\partial E_1(w)}{\partial w_2} & \cdots & \frac{\partial E_1(w)}{\partial w_M} \\ \frac{\partial E_N(w)}{\partial w_1} & \frac{\partial E_N(w)}{\partial w_2} & \cdots & \frac{\partial E_N(w)}{\partial w_M} \end{bmatrix} \quad (16)$$

LM算法是一种改进的高斯-牛顿方法,运算规则如下

$$\Delta w = -[J^T(w)J(w) + \mu I]^{-1} J(w)E(w) \quad (17)$$

其中 I 是单位矩阵, μ 是大于零的常数。

把两隐层 DBN 模型和 LM 模型根据 RMSE 进行预测精度比较, 比较结果见表 2。从数据可知两种预测模型的预测精度相仿, 并且预测值与实际值的误差都可以被接受。然而预测结果和实际值之间仍然有较大差距。接下来, 提出一个三层 DBN 模型来增强预测精度。

表 2 二层 DBN 模型与 LM 模型 RMSE 对比

预测方法	RMSE
DBN 算法(二隐层)	0.1031
LM 算法	0.1103

新的 DBN 模型的隐藏层被调整为三层结构, 其中模型学习率被调整为 0.46, 并且根据对比均方误差来调整每一层神经元数量。最优节点数量和数据比例如表 3 所示。

如图 8 和图 9 所示, 三隐藏层 DBN 模型产生的预测误差比其他两种模型的误差明显较小。三隐藏层 DBN 模型预测曲线的 RMSE 值为 0.0719。

表 3 三层 DBN 模型参数列表

训练样本比例	可视层节点数量	隐藏层节点数量	隐藏层每一层节点数量		
			第一层	第二层	第三层
0.8	6	3	10	10	10

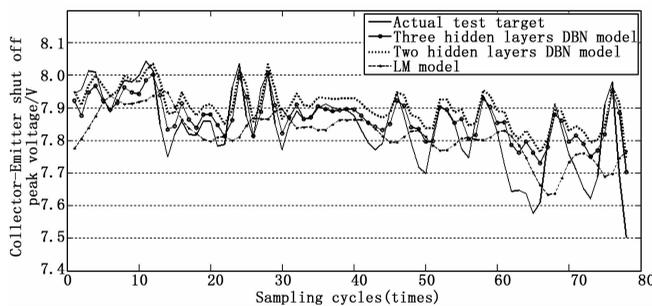


图 8 DBN 模型和 LM 模型中实际数据与预测数据曲线

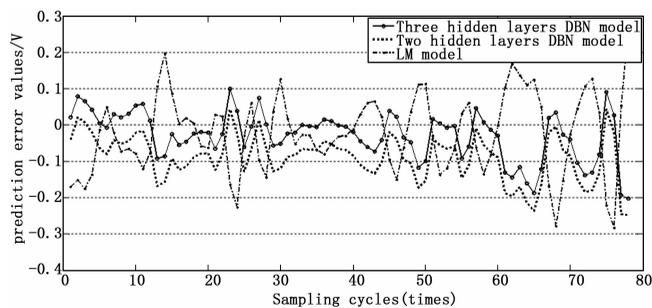


图 9 DBN 模型和 LM 模型预测误差曲线

比较 3 种模型预测的精准度可以发现, 两隐藏层 DBN 模型和 LM 模型是相近的, 三隐藏层 DBN 拥有更高的预测精度。同时, DBN 算法可以通过无监督学习过程来优化模型消耗, 减少拟合时间, 这表明 DBN 模型有较高的学习效率, 是一种高预测精度的算法。

5 结论

本文的主要工作是提出了一种基于 DBN 的预测算法模型, 用于预测 IGBT 失效特征参数。利用美国 NASA 艾姆斯中心

的 IGBT 加速退化实验所得到的数据作为原始样本, 分别评估了 DBN 模型和 LM 模型的预测性能。预测结果显示三层 DBN 预测模型相比 LM 算法模型具有更高的预测精度, 并且可以帮助实现根据 IGBT 状况进行设备的维护, 增强电子设备可靠性等功能, 因此本文所提出的预测方法在实际生产中具有实用价值。

参考文献:

- [1] Smet V, Forest F, Huselstein J J, et al. Ageing and failure models of IGBT modules in high-temperature power cycling. *IEEE Transactions on Industrial Electronics* [J]. 2011, 58 (10): 4931-4941.
- [2] Alghassi A, Perinpanayagam S, Samie M. Stochastic RUL calculation enhanced with TDNN-based IGBT failure modeling [J]. *IEEE Transactions on Reliability*, 2016, 65 (2).
- [3] Grant R D A, Power J. *Power MOSFET-theory and applications* [M]. New York: Wiley, 1989.
- [4] Sze S M. *Physics of semiconductor devices* [M]. New York: Wiley, 1981.
- [5] Han H Oh B, McCluskey P, Han Ch, et al. Physics of failure, condition monitoring, and prognostics of insulated gate bipolar transistor modules: a review [J]. *IEEE Transaction Power Electronics*, 2015, 30 (5), 2413-2426.
- [6] Shamma N. Y. A. Present problems of power module packaging technology, *Microelectronic Reliability* [J]. 2003, 43 (4), 519-527.
- [7] Coquery G G, Lefranc G, Licht T, et al. High temperature reliability on automotive power modules verified by power cycling tests up to 150 C [J]. *Microelectronic Reliability*, 2003, 43 (9), 1871-1876.
- [8] Sonnenfeld G, Goebel K, Celaya J R. An agile accelerated aging, characterization and scenario simulation system for gate controlled power transistors [C]. in *Proceeding of IEEE Auto-test Conference*, 2008.
- [9] Ackley D H, Hinton G E, Sejnowski T J. A learning algorithm for Boltzmann machines [J]. *Cognitive Science*, 1985, 9, 147-169.
- [10] Bengio Y, Delalleau O. Justifying an generalizing contrastive divergence [J]. *Neural Computation*, 2009, 21 (6), 1601-1621.
- [11] Koller D, Friedman N; *Probabilistic graphical models. Principles and Techniques* [M], MIT Press, 2009.
- [12] Bengio Y. Learning deep architectures for AI. foundations and trends in machine learning [J]. 2009, 21 (6), 1601-1621.
- [13] Hinton G E, Osindero S, Teh Y-W. A. Fast learning algorithm for deep belief nets [J]. *Neural Computation*, 2006, 18 (7): 1527-1554.
- [14] Wei W, Peisheng C. Simulation of wavelet denosing based on MATLAB [J]. *Information and Electronic Engineering*, 2008, Jun 6 (3).
- [15] Jian L, Minfang X. Research on the combined application of analog circuits soft faults and lm algorithm [J]. *Electric Power Science and Engineering*, 2015, 31 (5).
- [16] 夏春江, 王培良. 基于 DBN-PID 的木材干燥窑参数检测系统 [J]. *计算机测量与控制*, 2015, 23 (1): 99-101.
- [17] 张 华, 刁永发, 于 伟. 基于 LM-BP 神经网络的气阀故障诊断方法 [J]. *计算机测量与控制*, 2015, 23 (10): 3307-3309.